

Methodische Evaluation von Verfahren zur Korrektur atmosphärischer Turbulenz in Bildsequenzen

Zur Erlangung des akademischen Grades einer
Doktorin der Ingenieurwissenschaften

von der KIT-Fakultät für Informatik
des Karlsruher Instituts für Technologie (KIT)

genehmigte Dissertation

von

Dipl.-Math.

Claudia Susanne Hübner

Tag der mündlichen Prüfung:

19.12.2022

Erster Gutachter:

Prof. Dr.-Ing. habil. Jürgen Beyerer

Zweiter Gutachter:

Prof. Dr. rer. nat. Oskar von der Lühe

Kurzzusammenfassung

Bei langen horizontalen Ausbreitungswegen in Bodennähe ist die Atmosphäre und nicht die Qualität moderner bildgebender Systeme ausschlaggebend für die Qualität aufgenommener Bilddaten. Besonders wird die Bildqualität durch atmosphärische Turbulenz beeinträchtigt, die je nach Schweregrad zeitlich und räumlich variierende Unschärfe, (scheinbare) Bildbewegungen und geometrische Deformationen, sowie Intensitätsfluktuationen (Szintillation), verringerten (Farb-)Kontrast und Rauschen verursacht.

Korrekturverfahren haben entsprechend die Aufgabe, einen, mehrere oder ggf. alle dieser Turbulenzeffekte in Bilddaten zu reduzieren und diese bestmöglich zu rekonstruieren. Im Idealfall wäre eine solche Rekonstruktion identisch mit einer Aufnahme am Diffraktionslimit ohne Turbulenz. Diverse Anwendungsgebiete, die mit der Akquisition von Bilddaten über ausgedehnte (horizontale) Wegstrecken unter potenziell turbulenten Bedingungen befasst sind, können von einer effizienten Turbulenzkorrektur deutlich profitieren. Neben speziellen Formen optischer Kommunikation betrifft dies insbesondere klassische Fernerkundungsaufgaben, wie z. B. militärische Aufklärung oder (Grenz-)Überwachung. Während für Beobachtungen punktförmiger, (annähernd) statischer Objekte über vertikalen Ausbreitungswegen bereits etablierte Korrekturmethoden existieren (z. B. Adaptive Optik für astronomische Anwendungen oder optische Freiraumkommunikation), handelt es sich bei der Turbulenzkorrektur für horizontale Bilderfassung ausgedehnter und u. U. bewegter Objekte hingegen nach wie vor um ein aktives Forschungsfeld. Hierfür bieten sich vor allem softwarebasierte Verfahren an, deren Hauptvorteile gegenüber Hardware-Lösungen nicht nur in

den vergleichsweise geringen Materialkosten liegen, die zur Herstellung und Nutzung erforderlich sind, sondern hauptsächlich in ihrer Flexibilität (inkl. Mobilität) und Vielzahl von Anwendungsmöglichkeiten, wie insbesondere für den Fall ausgedehnter und ggf. bewegter Objekte.

Diese Arbeit beschäftigt sich vor allem mit den praktischen Aspekten der Frage, wie genau (d. h. mit welchen Methoden) man solche Turbulenzbeinträchtigungen am besten (oder ggf. am schnellsten) abmildern und die Qualität der Bilddaten mit Hilfe von problemspezifisch selektierten Rekonstruktionsverfahren gezielt verbessern kann. Ein besonderer Fokus liegt dabei auf Bildsequenzen, die insbesondere auch (gerichtete) Objektbewegung enthalten, sowie auf einer potenziellen Echtzeitfähigkeit der einzelnen Methoden. In dieser Arbeit werden verschiedene Verfahren zur Korrektur der am stärksten ausgeprägten Turbulenzeffekte untersucht. Dies umfasst die Auswahl und Implementierung geeigneter Algorithmen, sowie eine bewertende Diskussion ihrer Leistungsfähigkeit im Vergleich. Neben Entfaltungsmethoden zur Rekonstruktion hoher Frequenzanteile und Verbesserung der Bildschärfe ist dabei die Kompensation globaler und speziell lokaler Bildbewegungen mithilfe von "Block Matching"-Algorithmen und Schätzverfahren für den Optischen Fluss ein zentrales Thema. Insbesondere wird eine gerichtete lokale Bildstapelung zur Kompensation von Objektbewegungen und Reduktion von Bewegungsunschärfe konzipiert und umgesetzt, wobei es sich um eine innovative Kombination aus Bewegungsschätzung und modifizierter Bildstapelung handelt. Ein grundlegender Aspekt ist dabei die Differenzierung von eigenständiger Objektbewegung und Bewegung, die durch Turbulenz verursacht wird. Des Weiteren wird eine modifizierte mehrstufige Form der iterativen blinden Entfaltung nach Ayers und Dainty mit spezieller Gewichtung der Kanten im Bild vorgestellt, womit sich "Ringing"-Effekte in homogenen Bildregionen reduzieren lassen.

Einen weiteren Kernpunkt der Arbeit bildet zudem die Entwicklung einer Methodik zum Vergleich derartiger Rekonstruktionsverfahren unter Berücksichtigung anwendungsspezifischer Prioritäten bei der Bewertung. Zwar existiert eine Vielzahl an Qualitätsmetriken, die zu Vergleichen herangezogen werden können, jedoch ist eine objektive Ergebnisevaluation ohne verfügbare "Ground Truth"-Daten eine nicht-triviale Aufgabe. Es wird daher ein tabellarischer Lösungsansatz vorgeschlagen, anhand dessen sich ähnliche Voraussetzungen zusammenfassen lassen, um Algorithmen für typische Anwendungsszenarien besser miteinander vergleichbar zu machen.

Abstract

In the case of long horizontal propagation paths near the ground, the atmosphere and not the quality of modern imaging systems is the determining factor for the quality of acquired image data. Image quality is particularly affected by atmospheric turbulence, which, depending on its severity, causes temporally and spatially varying blurring, (apparent) image motion and geometric deformations, as well as intensity fluctuations (scintillation), reduced (colour) contrast and noise. Accordingly, correction methods are tasked with reducing one, several or possibly all of these turbulence effects in image data and reconstructing them in the best possible way. Ideally, such a reconstruction would be identical to an image at the diffraction limit without turbulence.

Various application areas that are concerned with the acquisition of image data over extended (horizontal) distances under potentially turbulent conditions can benefit significantly from efficient turbulence correction methods. In addition to special forms of optical communication, this applies in particular to classic remote sensing tasks, such as military reconnaissance or (border) surveillance. While established correction methods exist for observations of point-like, (approximately) static objects over (near) vertical propagation paths (e.g. adaptive optics for astronomical applications or optical free-space communication), turbulence correction for horizontal imaging of extended and possibly moving targets is still an area of active research. For this purpose, software-based methods are particularly well suited, since their main advantages over hardware solutions include not

only the comparatively low costs of materials required for their production as well as their utilisation, but also their flexibility (incl. mobility) and the large number of possible applications, especially in the case of extended and potentially moving objects.

This thesis is primarily concerned with the practical aspects of the question of how exactly (i. e. with which methods) such turbulence impairments can be mitigated most effectively (or most rapidly, as the case may be) and how the quality of the image data can be specifically improved by employing problem-specific reconstruction methods. A special focus is placed on image sequences that also contain (directional) object motion in particular, as well as on a potential real-time capability of the individual methods. In this work, different methods for the correction of the most pronounced turbulence effects are investigated. This includes the selection and implementation of suitable algorithms, as well as an evaluative discussion of their performance by comparison.

A central topic here, in addition to deconvolution methods for reconstructing high frequency components and improving image sharpness, is the compensation of global and especially local image movements with the aid of block matching algorithms and estimation methods for the optical flow. More specifically, directional local image stacking is proposed and implemented to compensate for object motion and reduce motion blur, involving an innovative combination of motion estimation and modified image stacking. A fundamental aspect is the differentiation of independent object motion and motion caused by turbulence. Furthermore, a modified multi-stage form of iterative blind deconvolution according to Ayers and Dainty with special weighting of the edges in the image is presented, with which ringing effects in homogeneous image regions can be substantially reduced.

Another key point of the work is the development of a methodology for comparing such reconstruction methods, taking into account priorities in the evaluation that are specific to the application. Although there is a wide range of quality metrics that can be used for such comparisons, an objective evaluation of results is a non-trivial task without available ground truth data. Therefore, a tabular solution approach is proposed, which can be used to summarise similar prerequisites in order to make algorithms for typical application scenarios easier to compare with each other.

Inhaltsverzeichnis

Kurzzusammenfassung	i
Abstract	iii
Symbolverzeichnis	xi
1 Einleitung	1
1.1 Motivation	2
1.2 Problemstellung	10
1.3 Lösungsansatz	12
1.4 Wissenschaftliche Beiträge	17
1.5 Gliederung	18
2 Stand der Forschung und Technik	21
2.1 Adaptive Optik	22
2.1.1 Wellenfrontsensoren	23
2.1.2 Deformierbare Spiegel	23
2.1.3 Zernike-Polynome	24
2.2 Softwarebasierte Verfahren	25
2.2.1 “Speckle Interferometry”	26
2.2.2 “Lucky Imaging”	27
2.2.3 Bildbewegung - Bildstabilisierung	28
2.2.4 Bildverzerrung - Bewegungskompensation	30
2.2.5 Bildunschärfe - Entfaltung	33

2.2.6	Objektbewegung - Detektion und Tracking	35
2.2.7	“Superresolution”	38
2.2.8	“Deep Learning”	39
2.3	Hybrid-Ansatz	42
2.4	Diskussion	43
2.4.1	Hardwarebasierte Ansätze	43
2.4.2	Softwarebasierte Ansätze	44
3	Theoretische Grundlagen	47
3.1	Definitionen aus der Statistik	48
3.1.1	Stationäre stochastische Prozesse	48
3.1.2	Momente μ_k	49
3.1.3	Erwartungswert μ und Standardabweichung σ	49
3.1.4	Die Gauß-Funktion	50
3.1.5	Die Strukturfunktion	50
3.1.6	Die Kovarianzfunktion	50
3.1.7	Das Wiener-Khinchin Theorem	51
3.2	Turbulenz in der Fluidodynamik	52
3.2.1	Fluide mit turbulenter Strömung	52
3.2.2	Die Reynoldszahl Re	52
3.2.3	Die Navier-Stokes Gleichungen	53
3.2.4	Das Turbulenzmodell von Kolmogorov	54
3.2.5	Der Brechungsindex n	56
3.2.6	Die Strukturfunktionen für Kolmogorov-Turbulenz	57
3.2.7	Powerspektren für Kolmogorov-Turbulenz	59
3.3	Isoplanasie und Anisoplanasie	60
3.3.1	Der isoplanatische Winkel θ_0	61
3.3.2	Der Fried-Parameter r_0	62
3.3.3	Der Strukturparameter C_n^2	62
3.3.4	Die Taylor-Hypothese	65
3.3.5	Die Kohärenzzeit τ_0	66
3.4	Grundlagen aus der Optik	66
3.4.1	Lichtwellen und Wellenfronten	67
3.4.2	Wellenfront W	67
3.4.3	Phasoren	68
3.4.4	Elektrische Feldstärke E	69

3.4.5 Bildentstehung	69
3.4.6 PSF, OTF und MTF	70
3.4.7 Die Pupillenfunktion P	71
3.4.8 Optische Auflösung	72
3.4.9 Limitierende Einflüsse	73
3.4.10 Systembedingte Einflüsse auf die Bildqualität	74
4 Bewegungskompensation	81
4.1 Situationsabhängige Bewegung	82
4.1.1 Bewegungsdetektion	83
4.1.2 Bewegungsschätzung	85
4.1.3 Abhängigkeit vom Szeneninhalt	86
4.2 "Block Matching"-Algorithmen	89
4.2.1 Vollständige Suche	91
4.2.2 "Adaptive Rood" Suchmuster	93
4.2.3 Kreuzkorrelation	94
4.3 Optischer Fluss	96
4.3.1 Grundprinzip	96
4.3.2 Horn-Schunk	98
4.3.3 Lucas-Kanade	101
4.3.4 Farnebäck	103
4.4 Evaluierung	106
4.4.1 Testdaten	107
4.4.2 Bildhomogenität	109
4.4.3 Qualitative Evaluation	110
4.4.4 Laufzeit-Evaluierung	113
4.4.5 Anwendung auf Turbulenz	115
5 Deblurring	119
5.1 Blinde Entfaltung	120
5.1.1 Inverser Wiener Filter	121
5.1.2 Richardson-Lucy Entfaltung	124
5.1.3 Iterative blinde Entfaltung	126
5.1.4 Entfaltung mittels Hauptkomponentenanalyse	128
5.2 Resultate	132
5.2.1 Spezifikation der Testdaten und Instrumente	132

5.2.2	Entfaltungsergebnisse im Vergleich	136
5.2.3	Spezialfall: stark anisoplanatische Turbulenz	140
5.3	Evaluierung	142
5.3.1	Diskussion: IWF, LRD und IBD	142
5.3.2	PCA: Multiple Observation und Single Observation	143
5.4	Zusammenfassung und Diskussion	146
5.4.1	Vor- und Nachteile der Algorithmus-Typen	146
5.4.2	Überblick über die Algorithmen	147
5.4.3	Anmerkungen	149
6	Turbulenzkorrektur	151
6.1	Testsequenzen	152
6.1.1	“China Lake”-Sequenz	153
6.1.2	“Dayton”-Sequenzen	155
6.2	Theoretische PSFs	160
6.2.1	Gauß-förmige PSF	161
6.2.2	Beugungsbegrenzte PSF	162
6.2.3	Frieds “short” und “long exposure” PSFs	164
6.3	Turbulenzschätzung aus Videodaten	165
6.3.1	Schätzverfahren für r_0	165
6.3.2	Homogenitätskarten	168
6.4	Bildvorverarbeitung bei Turbulenz	177
6.4.1	Kontrastverbesserung	177
6.4.2	Rauschreduktion	178
6.4.3	Einzelframe-Deblurring	178
6.4.4	Bewegung und Turbulenz	179
6.5	“Motion Compensated Averaging”	181
6.5.1	Referenzbild-Selektion	181
6.5.2	MCA mit “Block Matching”	183
6.5.3	Lokale Bildstapelung	184
6.6	Mehrstufige gewichtete IBD	191
6.7	Korrekturbeispiele	194
6.7.1	Schwache Turbulenz, statische Szene, große Entfernung	195
6.7.2	Moderate Turbulenz, statische Szene, mittlere Entfernung	196
6.7.3	Starke Turbulenz, moderate Objektbewegung, mittlere Entfernung	198

6.7.4	Extreme Turbulenz, statische Sequenz, Nahbereich, aktive Illumination	200
6.8	Farbbilddaten	202
6.8.1	Demosaicing	203
6.8.2	Verwendung des LAB-Farbraumes	204
6.9	Turbulenzsimulation	208
6.9.1	Simulationsprinzip	208
6.9.2	Parametereinstellungen und Implementierung	209
6.9.3	Simulationsergebnisse	210
6.9.4	Tiefenkarten	211
6.9.5	Synthetische "Ground Truth" mit Objektbewegung	214
6.9.6	Videosimulation	216
6.9.7	Korrekturresultate	217
7	Methodik zur Evaluierung	221
7.1	Bildqualität	222
7.1.1	Qualitätsmetriken	223
7.1.2	"Full Reference"-Metriken	223
7.1.3	"No Reference"-Metriken	225
7.2	Qualitative Beurteilung durch Beobachter	227
7.2.1	TOD-Testmethode	228
7.2.2	Merkmalsorientierte Bewertung	229
7.3	Evaluierungskonzept für Algorithmen zur Turbulenzkorrektur	230
7.3.1	Auswahl- und Bewertungskriterien	230
7.3.2	Hauptaspekte und Einflussfaktoren	233
7.3.3	Anwendungs- und Algorithmusprofile	236
7.4	Zusammenfassung	241
8	Abschlussbemerkungen	243
8.1	Zusammenfassung	243
8.2	Ausblick	244
Eigene Publikationen		247
Verwendete Literatur		249
Abbildungsverzeichnis		265

Tabellenverzeichnis	275
----------------------------	------------

Abkürzungsverzeichnis	277
------------------------------	------------

Symbolverzeichnis

Allgemeine Notation

α, β, \dots	Winkel (Griechische Kleinbuchstaben) auch: skalare Parameter
A, B, \dots	Matrizen (Großbuchstaben, kursiv) kontextabhängig auch: Konstanten oder (ganzzahlige) Variablen
C_x^2	Strukturparameter (z. B. C_n^2, C_T^2, \dots)
D_x	Strukturfunktionen (z. B. D_ϕ, D_T, \dots)
$f(\cdot), g(\cdot), \dots$	Funktionen
\bar{f}, \bar{g}, \dots	Mittelwert eines Pixelblocks
Φ_x	Powerspektren (z. B. Φ_ϕ, Φ_n, \dots)
\vec{X}, \vec{Y}, \dots	Vektorfelder
\vec{x}, \vec{y}, \dots	(Orts-)Vektoren in kartesischen Koordinaten
x, y, \dots	Parameter (Kleinbuchstaben, kursiv)
\vec{r}, \dots	(Orts-)Vektoren in Polarkoordinaten

Mengen

\mathbb{C}	Menge der komplexen Zahlen
\mathbb{N}_0	Menge der natürlichen Zahlen einschließlich Null
\mathbb{N}	Menge der natürlichen Zahlen
\mathbb{R}^d	d -dimensionaler Raum der reellen Zahlen
\mathbb{R}_0^+	Menge der positiven reellen Zahlen einschließlich Null
\mathbb{R}	Menge der reellen Zahlen
\mathbb{Z}	Menge der ganzen Zahlen

Operatoren und Funktionen

$ \cdot $	Absolutbetrag einer reellen oder komplexen Größe
$\ \cdot\ $	Euklidische Norm eines Vektors
$*$	Faltungsoperator
$\forall x$	Allquantor, Aussage gilt für alle definierten x
$n!$	Fakultät der Zahl n , ($n \in \mathbb{N}$)
Δ	Laplace-Operator, dient hier i. A. zur Kennzeichnung einer Differenz
$\frac{df}{dx}$	Ableitung der Funktion f nach der Variablen x
$\frac{\partial f}{\partial x}$	Partielle Ableitung der Funktion f nach der Variablen x
$E\{\cdot\}, \langle \cdot \rangle$	Erwartungswert
\mathcal{F}	Fouriertransformation
f^*	Komplex Konjugierte von f
f^T	Transponierte von f

$\mathcal{I}(\cdot)$	Imaginärteil einer komplexen Zahl
\max	Maximum einer Funktion oder Menge
argmin	Argument des Minimums
\min	Minimum einer Funktion oder Menge
$\vec{\nabla}$	Nabla-Operator, Vektor der partiellen Ableitungsoperatoren $\frac{\partial}{\partial x_i}$
\mathcal{O}	Landau-Symbol (auch: O-Kalkül), asymptotische obere Schranke für die Rechnenkomplexität eines Algorithmus
$\operatorname{Prob}\{\cdot\}$	Die Wahrscheinlichkeit eines Ereignisses
$\mathcal{R}(\cdot)$	Realteil einer komplexen Zahl

Griechische Symbole

δx	(Kleine) Verschiebung in x -Richtung
η	Dynamische Viskosität
κ	Ortsfrequenz
λ	Wellenlänge des Lichts (sofern nicht anders angegeben)
μ	Erwartungswert
μ_k	k -tes Moment
ν	Kinematische Viskosität
ω	Kreisfrequenz
Φ_ϕ	Powerspektrum der Phasenfluktuationen
ϕ	Phase
Φ_n	Powerspektrum der Fluktuationen im Brechungsindex

ρ	Dichte
Σ	Summenzeichen
σ	Standardabweichung
σ^2	Varianz
τ_0	Kohärenzzeit
Θ	Phasenänderungen
θ	Phase
θ_0	Isoplanatischer Winkel
v	Mittlere Strömungsgeschwindigkeit

Lateinische Symbole

A	Amplitude
A_n	Numerische Apertur
c_0	Lichtgeschwindigkeit im Vakuum
C_n^2	Strukturparameter der Brechungsindexfluktuationen
C_T^2	Strukturparameter der Temperaturfluktuationen
D	Aperturdurchmesser
d	Auflösungsgrenze
D_ϕ	Strukturfunktion der Phasenfluktuationen
D_T	Strukturfunktion der Temperaturfluktuationen
E	Elektrische Feldstärke
\hat{f}	Schätzung für f

$f(x,y)$	2-dimensionale Funktion f der (Orts-)Koordinaten x und y , hier i. A. : ungestörtes, ideales Bild)
F	Fouriertransformierte von f kontextbezogen auch: Blendenzahl
f	Funktion f kontextbezogen auch: Brennweite
$g(x,y)$	hier i. A. : durch Turbulenz gestörtes, reales Bild
$h(x,y)$	hier i. A. : (atmosphärische) Filterfunktion
I_i	hier i. A. : i -tes Bild einer Bildsequenz
i, j	Imaginäre Einheit, d. h. die Wurzel aus (-1) kontextbezogen hier auch als Laufindex verwendet
k	Polarisierungsausrichtung
L_0	Äußere Skalenlänge
l_0	Innere Skalenlänge
L	Optische Weglänge
$n(x,y)$	hier i. A. : Noise-Komponente
n	Brechungsindex
n_L	Brechungsindex von Luft
n_W	Brechungsindex von Wasser
P	Pupillenfunktion
p_s	Pixelgröße auf dem Sensor (in Radians)
px	Pixel
r_0	Kohärenzlänge (Fried-Parameter)

Re Reynoldszahl

R_i hier i. A. : i -tes Referenzbild zu einer Bildsequenz

W Wellenfront

1

Einleitung

Atmosphärische Turbulenz und ihre negativen Auswirkungen auf elektrooptische (EO) Systeme spielen vornehmlich in der Fernerkundung eine große Rolle. Dies gilt insbesondere für militärische Aufklärungsaufgaben, aber es gibt zunehmend auch in Anwendungen der zivilen Sicherheit Bedarf an der Korrektur bzw. Abmilderung von Turbulenzeffekten, z. B. bei der Grenzüberwachung in ariden Gebieten oder der Personenerkennung in der Strafverfolgung.

Im Allgemeinen gilt, je größer die Entfernung ist, desto stärker wirkt sich Turbulenz auf die Bildqualität bei der Datenerfassung aus. Dennoch gibt es auch auf kleinem Raum Anwendungsmöglichkeiten für Verfahren zur Turbulenzkorrektur. So ist in der medizinischen Bildverarbeitung z. B. die Beeinträchtigung der Bildqualität von MRT Aufnahmen aufgrund von Turbulenz innerhalb von MRT Geräten durchaus ein Thema, ebenso wie entsprechende Verfahren zur Bildverbesserung. Daneben ist in der Zukunft auch für Sportübertragungen die Anwendung von Turbulenzkorrektur in Echtzeit vorstellbar, insbesondere z. B. bei Autorennen, bei denen sich häufig ein Flimmern in der Luft über dem aufgeheizten Asphalt beobachten lässt.

Anmerkungen

Leider gibt es für einige wiederkehrende Begriffe und Konzepte keine adäquate deutsche Übersetzung, weshalb die englischen Begriffe verstärkt auch in deutschen Texten verwendet werden. Dies betrifft insbesondere atmosphärisches “Blurring”, das sich auf die Weichzeichner-Wirkung und den Tiefpass-Filter-Effekt der Atmosphäre bezieht, wodurch ein beobachtetes Objekt unscharf erscheint. Ein weiterer solcher Begriff ist “Noise”, der zwar als “Rauschen” sinnvoll übersetzt werden kann, welches aber nicht den vollen Umfang der Bedeutung widerspiegelt. Aus diesem Grund werden in dieser Arbeit die englischen Begriffe verwendet, sofern dies angebracht ist.

1.1 Motivation

Dank der technologischen Fortschritte der letzten Jahre bei der Entwicklung moderner hochwertiger elektrooptischer Systeme sind es inzwischen längst nicht mehr Qualität und Design, die deren Leistungsfähigkeit limitieren. Stattdessen sind es vielmehr die Atmosphäre, sowie die vorherrschenden meteorologischen Bedingungen, die der Performanz derartiger bildgebender Sensoren eine obere Grenze setzen. Speziell auf langen Ausbreitungswegen zwischen Beobachter und beobachtetem Objekt in warmen Klimaregionen, wie z. B. häufig bei Aufklärungsaufgaben in der Fernerkundung der Fall, machen sich atmosphärische Effekte bei der Erfassung von Bilddaten negativ bemerkbar. Die Abbildung 1.1 zeigt ein Beispiel für die Auswirkungen atmosphärischer Turbulenz- und Refraktionseffekte.



Abbildung 1.1: Beispiel für atmosphärische Turbulenz- und Refraktionseffekte (St. Peter Ording, Foto: M. Hebel)

Die Ursache dafür sind die vorherrschenden kontinuierlichen und rapiden Änderungen von Temperatur und Druck innerhalb der Atmosphäre. Hierdurch entsteht ein turbulenter Fluss von Luftzellen, welcher sich mit Hilfe der Gesetze der Fluidodynamik beschreiben lässt [Kol41]. Die Folge sind zufällige zeitliche und räumliche Variationen im optischen Brechungsindex entlang des Ausbreitungswegs. Die daraus resultierenden Effekte werden gemeinhin unter dem Begriff „*optische Turbulenz*“ zusammengefasst. Besonders ausgeprägt ist Turbulenz innerhalb der „Troposphäre“, der untersten Schicht der Erdatmosphäre, wobei hierin die „Peplosphäre“, die atmosphärische Grenzschicht nahe der Erdoberfläche (engl. „Atmospheric Boundary Layer“, ABL), deutlich am stärksten betroffen ist.

Die Abbildung 1.2 visualisiert das inhomogene Gemisch aus unterschiedlich großen Zellen kälterer und wärmerer Luft, die wie Linsen mit unterschiedlichem Brechungsindex agieren. Eine einfallende ebene (Licht-)Wellenfront (wie sie von einer punktförmigen Lichtquelle in großer Entfernung ausgeht, z. B. von einem Stern), die sich durch dieses turbulente Gemisch ausbreitet, wird aufgrund dessen sukzessive immer weiter abgelenkt und deformiert. Es sind in erster Linie Turbulenzen in der Nähe der Optik für die Phasenverzerrungen der eintreffenden Wellenfronten verantwortlich, welche den Gehalt an Raumfrequenzen eines Bildes determinieren, während Volumenturbulenzen über eine größere Entfernung wiederum Phasenverzerrungen

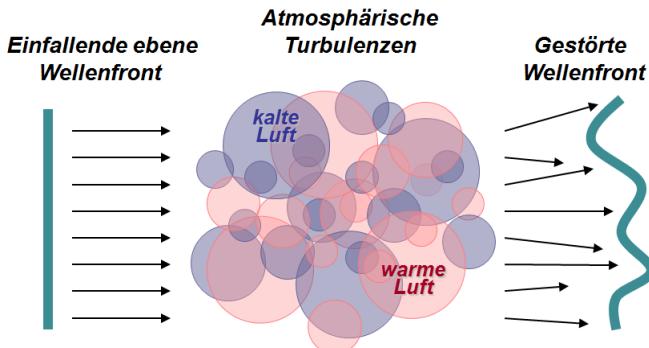


Abbildung 1.2: Auswirkung atmosphärischer Turbulenz auf eine ebene Wellenfront

in Amplitudenverteilungen umwandeln, was allgemein als *Szintillation* bezeichnet wird ([Rog96]). In der Astronomie beschreibt Szintillation zufällige Fluktuationen in der Helligkeit von Sternen, wodurch der Anschein erweckt wird, dass diese funkeln. Szintillation tritt vor allem bei langen Ausbreitungs wegen des Lichts durch die Atmosphäre auf, weshalb sie sich bei Sternen am stärksten in der Nähe des Horizonts bemerkbar macht. Unterschiedliche Deformationen der Wellenfront, verursacht durch atmosphärische Turbulenz, können bei der Ausbreitung zu konstruktiver oder destruktiver Interferenz führen. Die resultierenden Amplitudenschwankungen lassen sich vor allem mit Optiken wahrnehmen, die kleine Aperturen haben, wie z. B. auch die Pupille des menschlichen Auges. Die entstehenden Interferenzmuster sind sehr gut an den beiden Beispielen in der Abbildung 1.3 zu erkennen.

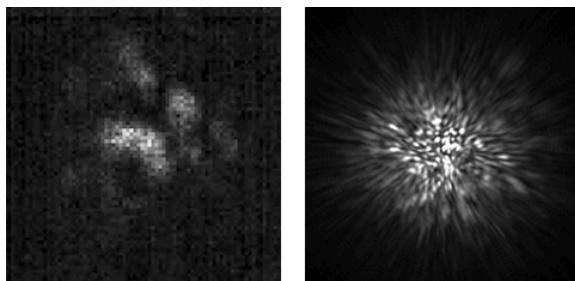


Abbildung 1.3: Szintillationseffekte bei starker Turbulenz. Links: reale Messung eines Laserspots; rechts: simulierte PSF.

Die dominantesten zu beobachtenden Turbulenzeffekte bei der Aufnahme von Bildern sind jeweils zeitlich und räumlich variierende Unschärfe (“*Image Blurring*”), scheinbare Bewegungen des ganzen Bildes (“*Image Dancing*”) und geometrische Deformationen (“*Image Warping*”), sowie die oben beschriebenen Intensitätsfluktuationen, d. h. Szintillation. In den Abbildungen 1.4 und 1.5 sind Beispiele für derartige turbulenzbedingte Bildunschärfe bzw. Bilddeformationen zu sehen.

Bei der Erfassung von Bilddaten durch Turbulenz spielt insbesondere die Belichtungs- bzw. Integrationszeit eine wichtige Rolle. Bei längeren Belichtungszeiten, d. h. wenn die Belichtungszeit die Dauer der Turbulenz übersteigt, werden Turbulenzzellen aller Größenordnungen gemittelt. Dabei



Abbildung 1.4: Beispiel für turbulenzbedingte Bildunschärfe. Links: Originalbild, rechts: Ausschnittsvergrößerung.

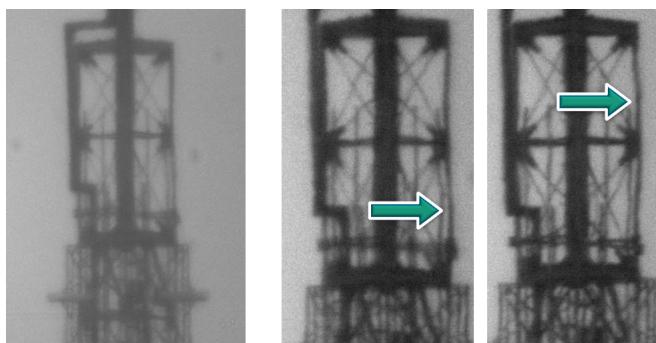


Abbildung 1.5: Beispiel für turbulenzbedingte Bilddeformationen. Links: Originalbild, Mitte u. rechts: Ausschnittsvergrößerung zweier weiterer Frames mit jeweils unterschiedlichen Deformationen.

sind es die größten Zellen, welche größer sind als der Durchmesser der verwendeten Optik, die überwiegend für den “Image Dancing” Effekt verantwortlich sind, während sie sich über die Öffnung der Optik bewegen. Bei kurzen Belichtungszeiten hingegen werden diese großen Zellen gleichsam “eingefroren” und nur die kleinen Turbulenzzellen, die für die Unschärfe verantwortlich sind, bewegen sich so schnell, dass sie sich im Bild bemerkbar machen. Im Wesentlichen bedeutet dies, dass die Geometrie einer Szene erhalten bleibt, d. h. Linien bleiben gerade, während Details verschwimmen. Dieser Umstand wird in Abschnitt 5.2 in der Abbildung 5.2 demonstriert.

Bilddeformationen werden wiederum von Turbulenzzellen verursacht, welche einerseits kleiner sind als die Apertur, andererseits aber größer (auf der Bildebene) als die Objektstrukturen.

Kontrastreduktion und *chromatischer Verlust* zählen ebenfalls zu den nachteiligen Effekten atmosphärischer Turbulenz, wie beispielhaft in der Abbildung 1.6 gezeigt. Die Abbildung verdeutlicht insbesondere auch den verstärkenden Effekt von Rekonstruktionsmethoden auf (Farb-)Rauschen.



Abbildung 1.6: Beispiel für turbulenzbedingten Verlust von (Farb-)Kontrast. Links: Originalbild, Mitte: Rekonstruktion mit Rauschverstärkung, rechts: Detailvergrößerung.

Die Abbildung 1.7 zeigt überdies, dass atmosphärische Turbulenz im infraroten Wellenlängenbereich (IR) grundsätzlich die gleichen negativen Turbulenzeffekte verursacht wie im visuellen Spektrum (VIS), auch wenn deren Ausprägung etwas geringer ausfällt aufgrund der größeren Wellenlänge. Zusätzlich lassen sich Luftspiegelungen über dem (durch Sonneneinstrahlung) aufgeheizten Rollfeld beobachten, ein Effekt, welcher im VIS ebenfalls auftritt. Insbesondere illustriert die Abbildung 1.7 wie sich längere Ausbreitungswege durch die turbulente Atmosphäre in Bildaufnahmen auswirken. Hier sollte angemerkt werden, dass alle vier Sequenzen mit demselben EO-System akquiriert wurden, mit einer Originalauflösung von 640×480 Pixeln. Die Bildausschnitte wurden absichtlich so gewählt, dass der Jet überall (nahezu) gleich groß ist. Zwar wird dadurch die relative Bildauflösung mit zunehmender Distanz geringer, dennoch lässt sich erkennen, dass es die Turbulenzeinflüsse sind, die in den Aufnahmen dominieren.

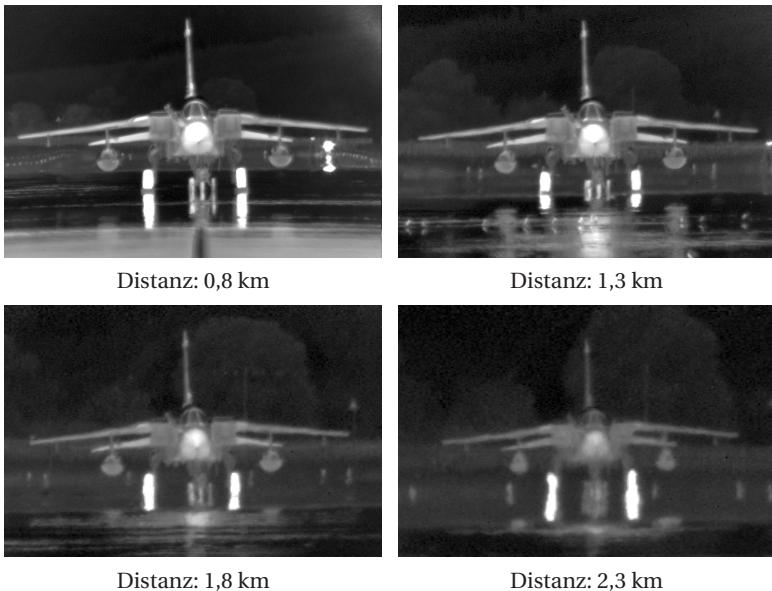


Abbildung 1.7: Infrarot-Aufnahmen eines Jets in unterschiedlichen Entfer-
nungen zur Kamera unter vergleichbaren Turbulenzbedingungen.

Turbulenz ist naturgemäß nicht auf atmosphärische Turbulenzen beschränkt. Optische Turbulenz kann in jedem flüssigen und transparenten Medium beobachtet werden. Und obwohl sich der Großteil der Forschung in der Fachliteratur mit atmosphärischen Turbulenzeffekten befasst, hat die Zahl der Studien über Unterwasserturbulenzen in den letzten Jahren zugenommen. Dennoch sind Anwendungen für atmosphärische Korrekturen nach wie vor weitaus häufiger als für Unterwasser. Dies liegt vor allem an der vergleichsweise kurzen Sichtweite von nur wenigen Metern, während Sonarsysteme bis zu Hunderte von Metern (abhängig von der Betriebsfrequenz) durchdringen können. Obwohl der Schwerpunkt hier also auf Luft und nicht auf Wasser liegt, gelten die in diesem Abschnitt beschriebenen atmosphärischen Effekte auch für Wasser. Allerdings sind die optischen Turbulenzen unter Wasser aufgrund der unterschiedlichen Brechungseigenschaften des

Wassers, die je nach Salzgehalt und Verschmutzung variieren, viel stärker ausgeprägt. Da sich Turbulenz über den Strukturparameter der Fluktuationen im Brechungsindex des Ausbreitungsmediums charakterisieren lässt, spielen naturgemäß die Eigenschaften dieses Mediums eine entscheidende Rolle in der Ausprägung der optischen Turbulenz. So hat Wasser einen deutlich höheren refraktiven Index als Luft ($n_W \approx 1.3330$, $n_L \approx 1.000292$). Standardmäßig wird der Brechungsindex n für Flüssigkeiten bei $T = 20\text{ }^\circ\text{C}$ angegeben, während bei Gasen $T = 0\text{ }^\circ\text{C}$, $P = 1\text{ atm}$ als Standardwerte gelten. Turbulenz unter Wasser wie im Beispiel in Abbildung 1.8 kann mithilfe von Heizplatten an den Seiten eines Wassertanks erzeugt werden.

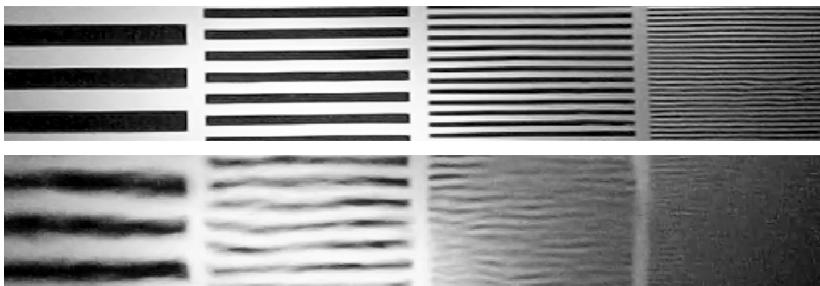


Abbildung 1.8: Beispiel für Unterwasserturbulenz. Oben: Wasser im Ruhezustand; unten: mithilfe von Heizplatten künstlich erzeugte Turbulenz.

Die Abbildung 1.9 veranschaulicht am einfachen Beispiel eines binären zeitabhängigen Signals wie sehr sich bereits Szintillation (dargestellt als grüne Sinuskurve) allein in Verbindung mit Rauschen (violett eingezeichnet) auf die Signalintensität auswirken kann. Das Ausgangssignal (schwarze Linie ganz oben in der Grafik) wird aufgrund der durch Szintillation verursachten Amplitudenschwankungen teilweise völlig ausgelöscht bzw. verfälscht wie die letztlich gemessenen Daten (schwarze Linie ganz unten in der Grafik) erkennen lassen. In welchem Ausmaß dieser Effekt durch das vorliegende Rauschen weiter verstärkt wird, hängt dabei sowohl vom durchschnittlichen Rauschpegel ab, als auch vom eingestellten Detektionsschwellwert. Das Beispiel unterstreicht die Bedeutung und die Notwendigkeit entsprechender Korrekturmethoden, insbesondere für die optische Kommunikation.

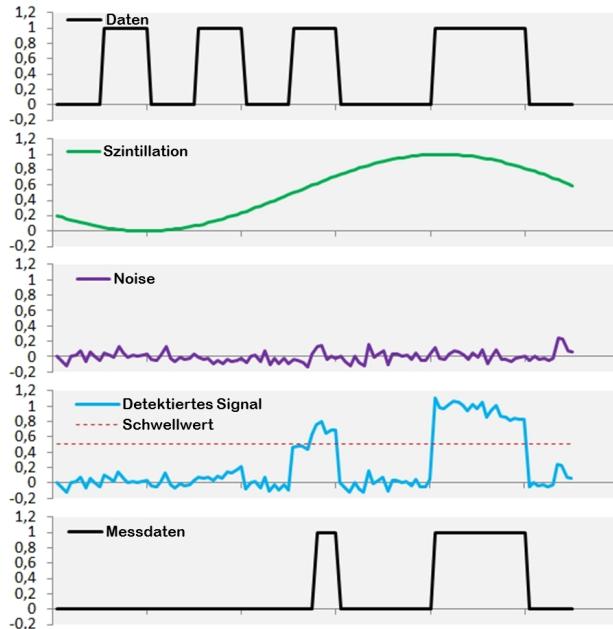


Abbildung 1.9: Wirkung von Szintillation und Rauschen auf ein binäres Signal (x -Achse: Zeit t , y -Achse: Intensität, skaliert auf $[0,1]$).

Es gibt eine ganze Reihe von Anwendungsbereichen, die aufgrund von atmosphärischer Turbulenz signifikant beeinträchtigt werden können. Dies betrifft vor allem die nachfolgend aufgelisteten Anwendungen:

- Bilderfassung (“Imaging”) über ausgedehnte Wegstrecken
- Fernerkundung (“Remote Sensing”), z. B. Aufklärung (“Reconnaissance”) oder (Grenz-)Überwachung (“Surveillance”)
- Astronomische Beobachtungen
- LIDAR (optische Entfernungsmessung)
- Optische Freiraumdatenübertragung (“Free-Space Optical communication”, FSO)
- Satelliten-Laserkommunikation (Uplink und Downlink)

1.2 Problemstellung

Verfahren zur Turbulenzkompensation haben die Aufgabe, einen, mehrere oder ggf. sogar alle der zuvor beschriebenen Turbulenzeffekte in erfassten Bilddaten (oder anderen optischen Signalen) zu reduzieren und diese so gut wie möglich zu rekonstruieren. Im Idealfall wäre eine solche Rekonstruktion identisch mit einer Aufnahme am Diffraktionslimit, ohne jede (optische) Turbulenz.

In diesem Zusammenhang stellt sich auch die Frage nach der Evaluierung solcher Rekonstruktionsergebnisse. Aufgrund der Diversität aktueller Korrekturverfahren ist es nahezu unmöglich, die Korrekturresultate unterschiedlicher Verfahren tatsächlich objektiv zu beurteilen und miteinander zu vergleichen. Zum einen ist bei Bilddaten, die durch reale Turbulenz beeinträchtigt sind, davon auszugehen, dass keine zugehörigen "Ground Truth"-Daten vorliegen und somit eine (weitgehend) objektive Beurteilung über einen direkten Vergleich entfällt. Zum anderen unterscheiden sich die Zielstellungen und Leistungsparameter dieser Verfahren z. T. signifikant voneinander, so wie ihrerseits auch die Anforderungen und Prioritäten verschiedener Anwendungen stark variieren können. Aufgrund dessen wäre ein einheitliches Konzept sehr von Nutzen, welches eine methodische Evaluierung solch heterogener Verfahren ermöglicht, ohne dabei die problemspezifischen Vorgaben und Ziele unterschiedlicher Anwendungen aus dem Auge zu verlieren.

Die Bildbeeinträchtigungen aufgrund von Turbulenz bei der Erfassung eines realen Bildes g lassen sich vereinfacht als *Faltung* ("Convolution") des *idealen*, d. h. nicht durch Turbulenz gestörten *Bildes* f mit der *atmosphärischen Punktspreizfunktion* h beschreiben, wie in der Abbildung 1.10 veranschaulicht, zuzüglich einer additiven *Noise*-Komponente n . Diese vereinfachte Darstellung ist in der Literatur weit verbreitet und wird entsprechend häufig verwendet.

Dabei ist zu beachten, dass es sich um eine Momentaufnahme für einen bestimmten Zeitpunkt $t = t_0$ handelt, und dass h , f und n nicht nur von den Ortskoordinaten (x, y) abhängen, sondern auch zeitlich veränderliche Funktionen darstellen (und dementsprechend auch g).

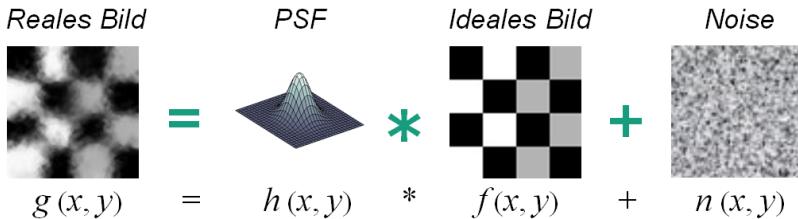


Abbildung 1.10: Modellierung des turbulenzbedingten Degradationsprozesses von Bilddaten in Form einer Faltung mit der atmosphärischen Filterfunktion.

Die Gleichung aus der Abbildung 1.10 lautet dann entsprechend:

$$g(x, y, t) = h(x, y, t) * f(x, y, t) + n(x, y, t) \quad (1.1)$$

Ob sich das zugrundeliegende ideale Bild f tatsächlich mit der Zeit verändert, ist zwar vom Inhalt der abgebildeten Szene abhängig, die Annahme der zeitlichen Veränderlichkeit von f stellt jedoch keine Einschränkung dar. Streng genommen müsste die Filterfunktion h auch nicht nur die genannten Turbulenzeffekte beinhalten, sondern ebenso die Störeinflüsse des verwendeten optischen Systems. In der Praxis werden für Forschungsarbeiten (wie die vorliegende) mit besonderem Fokus auf die negative Auswirkung atmosphärischer (bzw. optischer) Turbulenz nahezu ausschließlich qualitativ hochwertige elektrooptische Systeme zur Erfassung entsprechender Bilddaten eingesetzt. Die Turbulenzeffekte (sofern vorhanden) überwiegen daher im Normalfall deutlich gegenüber Beeinträchtigungen, wie sie z. B. durch eine minderwertige Optik verursacht werden. Somit ist es durchaus gerechtfertigt, letztere in dem abgebildeten Turbulenzmodell zu vernachlässigen und etwaige Abbildungsfehler als Teil der atmosphärischen Störungen zu behandeln.

Es sollte dazu angemerkt werden, dass die Parameter des jeweils verwendeten optischen Systems sehr wohl in zahlreiche Korrekturverfahren mit einfließen, entweder direkt oder indirekt. Ebenso werden häufig weitere (oder ggf. andere) Turbulenzeffekte berücksichtigt, insbesondere der Verlust von (Farb-)Kontrast.

1.3 Lösungsansatz

Zielsetzung dieser Arbeit ist die methodische Evaluierung verschiedener Verfahren zur Korrektur atmosphärischer Turbulenz mit Hinblick auf die praktischen Aspekte bei der Anwendung auf Bilddaten mit realen Beeinträchtigungen aufgrund von Turbulenzeinflüssen. Dies umfasst die Auswahl und Implementierung geeigneter Algorithmen, sowie eine bewertende Diskussion ihrer Leistungsfähigkeit im Vergleich. Ein besonderes Augenmerk liegt jeweils auf Bildsequenzen, die insbesondere auch gerichtete Objektbewegung enthalten.

Die Turbulenzeinflüsse lassen sich als eine Reihe von Turbulenzeffekten interpretieren, die voneinander (mehr oder weniger) unabhängig sind. Insbesondere lassen sich Bildbewegungen und Bildunschärfe sehr effektiv von einander getrennt betrachten und behandeln, ebenso wie z. B. auch der Bildkontrast. Es liegt daher nahe, ein Verfahren zur Turbulenzkorrektur modular aufzubauen, so dass diese Turbulenzeffekte mithilfe entsprechender Methoden jeweils einzeln, nacheinander korrigiert werden (in einer geeigneten Reihenfolge). In der Abbildung 1.11 sind die generell am stärksten ausgeprägten Turbulenzeffekte mit Auflistungen möglicher Korrekturansätze verknüpft, die sich eignen, um den jeweiligen Effekt zu korrigieren

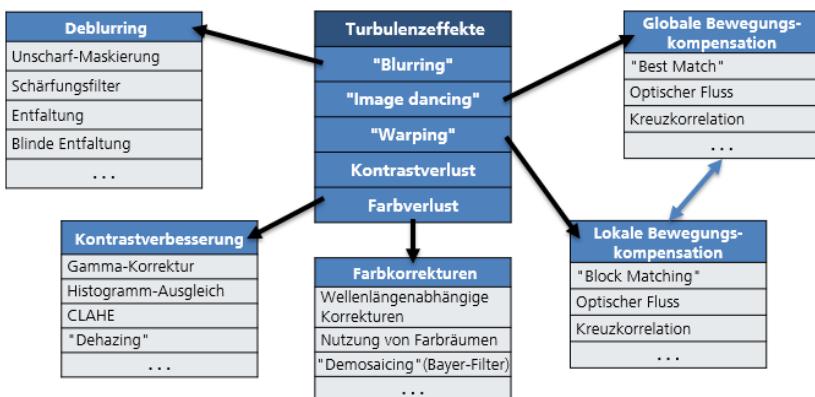


Abbildung 1.11: Typische Turbulenzeffekte und zugehörige Korrekturansätze

bzw. abzumildern. Durch die Punkte “...” soll hier angedeutet werden, dass es sich um beliebig erweiterbare Listen handelt und kein Anspruch auf Vollständigkeit besteht.

Die Problematik der Turbulenzkorrektur wird hier in vier Hauptaufgaben eingeteilt:

1. “Bewegungskompensation” (Kapitel 4)
2. “Deblurring” (Kapitel 5)
3. “Turbulenzkorrektur” (Kapitel 6)
4. “Methodik zur Evaluierung” (Kapitel 7)

Zu 1. “Bewegungskompensation”:

“Block Matching”-Algorithmen und Methoden zur Bestimmung des optischen Flusses können ebenso wie eine Kreuzkorrelation zur Bewegungsdetektion und Bewegungsschätzung eingesetzt werden. Anhand dieser Informationen lassen sich globale und lokale Bildbewegungen kompensieren, wobei ein bewegungskompensierender gleitender Mittelwert bestimmt und als Referenz zur Registrierung verwendet wird. Dadurch wird im Video eine bildstabilisierende Wirkung und Reduktion von Bildverformungen erzielt. Überdies werden Bewegungen, die gewisse Kriterien erfüllen, als Objektbewegungen kategorisiert, z. B. wenn sie einen bestimmten Schwellwert überschreiten. Eine Unterscheidung zwischen bewegten und statischen Bildregionen ermöglicht eine separate Behandlung von bewegten Objekten im Vordergrund und dem (zumindest temporär) statischen Hintergrund. Dadurch kann die Anzahl gemittelter Frames im Vordergrund gezielt reduziert und im Hintergrund erhöht werden, ohne Bewegungsunschärfe dabei zu verstärken.

Zu 2. “Deblurring”:

Wie der Gleichung (1.1) zu entnehmen ist, liegt der Turbulenzkorrekturaufgabe im Prinzip ein *inverses Problem* zugrunde, das im mathematischen Sinn *schlecht gestellt* ist. Bei einem inversen Problem wird zu einer Abbildung $f: X \rightarrow Y$, $y = f(x)$ die zugehörige Umkehrabbildung f^{-1} gesucht, wobei

nur Beobachtungen y aus dem Bildbereich Y vorliegen, während die zugehörigen Elemente x des Definitionsbereichs X unbekannt sind ([Bey12]). Gemäß *Hadamard* ist ein Problem im mathematischen Sinn schlecht gestellt, wenn keine eindeutige Lösung existiert, die zudem stabil ist, also stetig von den gegebenen Eingangsdaten abhängt. Speziell für ein inverses Problem bedeutet dies dann, dass keine bijektive und stetige Umkehrabbildung f^{-1} existiert. Lösungsansätze für das Problem der *Entfaltung* ("Deconvolution") stützen sich daher auf Zusatzinformationen, wie etwa Vorwissen und Randbedingungen, die z. B. nur für ganz bestimmte Situationen Gültigkeit haben. Vorwissen kann z. B. aus früheren Schleifendurchläufen stammen oder für eine gegebene Position aus einer lokalen Umgebung extrapoliert werden. Es können zusätzlich auch (häufig vereinfachende) Annahmen getroffen werden, oder bestimmte Eigenschaften der Lösung gefordert werden (wie z. B. Glattheit), so dass Ausreißer unterdrückt werden.

Der gesamte Vorgang von der durch Turbulenz verursachten Bildverschlechterung bis hin zur näherungsweisen Bildrekonstruktion \hat{f} des idealen Bildes ist schematisch in der Abbildung 1.12 dargestellt.

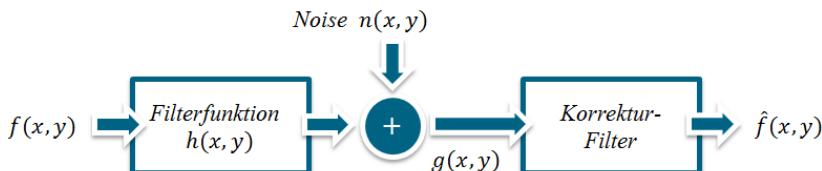


Abbildung 1.12: Schematische Darstellung turbulenzbedingter Bildbeeinträchtigung und Bildrekonstruktion mittels inverser Filterung

Bildbewegungen sind in dieser Darstellung zwar nicht explizit berücksichtigt, aber falls eine effiziente Bewegungskompensation durchgeführt wird, können (nahezu) isoplanatische Bedingungen angenommen werden, so dass die atmosphärische Filterfunktion h (näherungsweise) als räumlich invariant betrachtet werden kann.

Zu 3. "Turbulenzkorrektur":

In diesem Aufgabenblock wird thematisch alles zusammengeführt, das zusätzlich zu Algorithmen zur Bewegungskompensation und Entfaltung mit

zum Themenfeld Turbulenzkorrektur gehört. Neben Schätzmethoden für die Turbulenzstärke und Möglichkeiten zur PSF-Approximation werden hier vor allem eigene Arbeiten und Ergebnisse vorgestellt, insbesondere die MCA und LIS Korrekturprinzipien zur Bewegungskompensation, sowie auch die WIBD Modifikation für eine abschließende blinde Entfaltung.

Des Weiteren werden praktische Aspekte beleuchtet, wie z. B. sinnvolle Möglichkeiten zur Vorverarbeitung der Bilddaten unter verschiedenen Bedingungen, um die Rekonstruktion zu unterstützen. Eine besonders hohe Frame rate kann beispielsweise zusätzliche Maßnahmen erfordern, um Objektbewegung zwischen Frames detektieren zu können. Gleichermaßen gilt auch bei ausgeprägten lokalen Bildbewegungen infolge starker Turbulenz, die u. U. gegenüber Objektbewegungen überwiegen können.

Die Abbildung 1.13 zeigt die verschiedenen Stufen im hier vorgestellten Lösungsansatz zur Turbulenzkompensation, angefangen mit einer optionalen Vorverarbeitung der Eingabedaten über eine Bewegungsdetektion und Bewegungsschätzung zur Bewegungskompensation mit abschließendem Deblurring.

Während der Bewegungsdetektion/-schätzung wird zunächst entschieden, ob eine Kamerabewegung vorliegt, die sich mithilfe entsprechender Maßnahmen ausgleichen lässt. Bei einer gleichmäßigen Schwenkbewegung kann z. B. "Stitching" eingesetzt werden. Andernfalls, d. h. bei schnellen nicht präzisierbaren Bewegungen, muss auf eine Bewegungskompensation (zeitweilig) verzichtet werden. Dies gilt im Übrigen auch für abrupte Szenenwechsel oder Änderungen des Zoomfaktors seitens der Optik.

Des Weiteren wird ermittelt, ob bewegte Objekte enthalten sind und ggfs. eine Segmentierung in Vorder- und Hintergrund, d. h. bewegte und statische Bildregionen, vorgenommen. Bei der Bewegungskompensation werden die ermittelten Informationen zur Bildstabilisierung mittels bewegungskompensierender Bildstapelung (MCA) eingesetzt, wobei eine separate Korrektur des Vordergrunds mittels gerichteter lokaler Bildstapelung (LIS) durchgeführt wird.

Das Resultat der Bewegungskompensation kann im Idealfall als (weitgehend) unverzerrtes Bild betrachtet werden, welches allerdings noch eine Unschärfe in der gleichen Größenordnung aufweist wie die zugehörige statistische "short exposure"-PSF (s. a. Gleichung (6.14)). Als abschließender Schritt wird daher noch ein entsprechendes Deblurring durchgeführt.

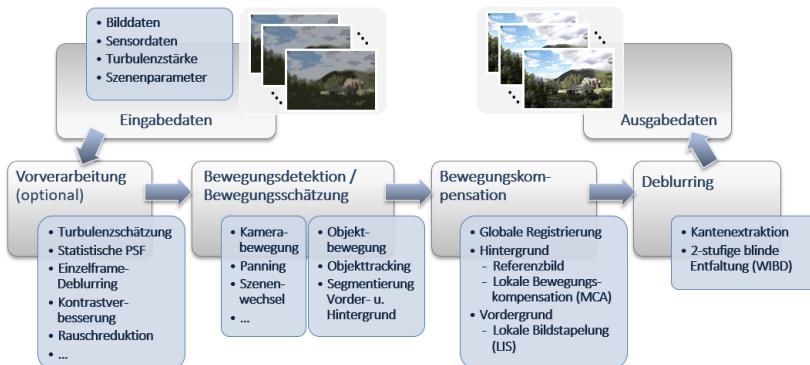


Abbildung 1.13: Prozessierungskette mit den wesentlichen Verfahrensschritten zur Turbulenzkorrektur

Dieser Ansatz zur Turbulenzkorrektur ist vergleichsweise robust, da er auch bei starker Turbulenz noch eine deutliche Verbesserung zu erzielen kann. Zudem lässt er sich ohne zusätzliche Modifikationen auch auf andere Spektralbereiche wie IR anwenden, inklusive aktiver Beleuchtung.

Zu 4. „Methodik zur Evaluierung“:

Im letzten Aufgabenblock geht es hingegen darum, die Rekonstruktionsergebnisse verschiedener Verfahren zur Turbulenzkorrektur vergleichend zu bewerten, um daraus eine Aussage über die Leistungsfähigkeit der korrespondierenden Algorithmen ableiten zu können. Zu diesem Zweck werden die jeweiligen Vor- und Nachteile unterschiedlicher Typen von Metriken diskutiert, sowie alternative Möglichkeiten zur Bewertung der Rekonstruktionsqualität erörtert. Zur Lösung wird ein tabellarischer Ansatz vorgeschlagen, in dem eine Kombination ausgewählter Metriken als Kriterien zur Bewertung der Rekonstruktionsergebnisse herangezogen wird, wobei eine anwendungsbezogene Priorisierung ermöglicht wird. Zusätzlich werden die Eingabedaten kategorisiert, da unterschiedliche Ausgangsszenarien unterschiedliche Korrekturmaßnahmen erfordern. Insbesondere können die Prioritäten bei der Bewertung stark von der jeweiligen Anwendung abhängen.

1.4 Wissenschaftliche Beiträge

Die Hauptbeiträge dieser Arbeit zum Stand der Forschung und Technik lassen sich zusammenfassen wie folgt:

- ▷ Entwicklung und Realisierung eines ganzheitlichen Verfahrens zur schritthaltenden Turbulenzkorrektur (s. a. Abbildung 1.13), das aufgrund zahlreicher optionaler Komponenten (z. B. Vorverarbeitung), sowie etlicher Freiheitsgrade sehr flexibel nutzbar ist. In diversen Korrekturbeispielen (u. a. in Abschnitt 6.7) wird die Verbesserungsleistung spezifischer Komponenten demonstriert.
- ▷ Umfassende Untersuchung verschiedenster Algorithmen zur Bewegungsdetektion und zur Bewegungsschätzung hinsichtlich ihrer Anwendbarkeit auf turbulenzgestörte Daten zur Bewegungskompensation [Hue16] (Kapitel 4).
- ▷ Konzipierung und Umsetzung einer gerichteten lokalen Bildstapelung (“Local Image Stacking”, LIS), einer innovativen Kombination aus Bewegungsschätzung mittels “Block Matching” und modifizierter Bildstapelung, zur Kompensation von gerichteten Objektbewegungen in atmosphärisch beeinträchtigten Bildsequenzen [Hue11] (Abschnitt 6.5.3).
- ▷ Qualitative und quantitative Evaluierung verschiedener Entfaltungsmethoden in Bezug auf ihre Eignung in unterschiedlichen Turbulenzbedingungen unter Berücksichtigung des (potenziellen) Echtzeit-Aspekts, sowie Untersuchung des Einflusses ultra-kurzer Integrationszeiten auf die Bildrekonstruktion [Hue08], [Gre08].
- ▷ Entwicklung und Implementierung einer mehrstufigen Variante des IBD-Entfaltungsalgorithmus mit besonderer Gewichtung der Kanten im Bild [Hue09] (Abschnitt 6.6).
- ▷ Untersuchung verschiedener Qualitätsmetriken zur Identifikation der besten und schlechtesten Frames mit dem Ziel, bessere Frames mit einer stärkeren Gewichtung in die Korrektur einfließen zu lassen, während die schlechtesten Frames verworfen werden [Hue10].

- ▷ Entwurf und Erstellung einer synthetischen Videosequenz als “Ground Truth”-Basis für Turbulenzsimulationen. Erzeugung von Videosequenzen mit unterschiedlicher Turbulenzstärke (isoplanatischer Simulation) als Testdaten für diverse Korrekturverfahren [Hue12b] (Abschnitt 6.9).
- ▷ Untersuchung der Einflüsse verschiedener Farbräume auf die Kontrastverbesserung atmosphärisch beeinträchtigter Farbbilddaten, mit besonderem Fokus auf dem CIE LAB-Farbraum [Hue15].
- ▷ Modifikation und Implementierung eines Verfahrens zur Schätzung des Fried-Parameters r_0 anhand von hinreichend langen Bildsequenzen.
- ▷ Entwicklung und Implementierung einer auf dem Lakunaritätsmaß basierenden Methode zur Erstellung von Homogenitätskarten (Abschnitt 6.3.2), womit sich die Zuverlässigkeit der geschätzten Turbulenzstärke (r_0) erhöhen lässt.
- ▷ Erstellung eines Konzepts zur methodischen Evaluation von Verfahren zur Turbulenzkorrektur anhand eines tabellarischen Ansatzes unter Berücksichtigung anwendungsspezifischer Prioritäten.

1.5 Gliederung

Dieser Einleitung schließt sich in Kapitel 2 eine Übersicht über den derzeitigen Stand der Forschung und Technik zum Thema Turbulenzkorrektur an. Diese Übersicht beginnt mit der hardwarebasierten “Adaptiven Optik” in Abschnitt 2.1. Es folgt ein Literaturüberblick über softwarebasierte Korrekturansätze mit Bezug zu den hier behandelten Aufgabenstellungen in Abschnitt 2.2. Dazu werden repräsentativ ausgewählte Verfahren vorgestellt und diskutiert, geordnet jeweils nach Turbulenzeffekten mit geeigneten Korrekturprinzipien. Eine abschließende Diskussion von hardware- und softwarebasierten Korrekturansätzen wird in Abschnitt 2.4 gegeben.

Die Einflüsse des Phänomens “Turbulenz” erstrecken sich auf eine ganze Reihe von Forschungsgebieten. Daher sind im Kapitel 3 die für die weiteren

Kapitel relevanten theoretischen Grundlagen zu diesem Themenkomplex fachübergreifend zusammengefasst. Dies beinhaltet zunächst Definitionen aus der Statistik im Abschnitt 3.1, sowie einige Grundbegriffe aus der Fluidynamik im Abschnitt 3.2. Hinzu kommen wichtige Definitionen aus der Astronomie, wie insbesondere Isoplanasie und Anisoplanasie im Abschnitt 3.3, sowie einige Grundprinzipien aus der Optik im Abschnitt 3.4, einschließlich einer Diskussion diverser systembedingter limitierender Einflüsse.

Zahlreiche softwarebasierte Korrekturverfahren verwenden eine Bewegungskompensation, um turbulenzbedingte Bildbewegungen auszugleichen oder Eigenbewegungen von Objekten zu detektieren. Aus diesem Grund werden typische Algorithmen zur Bewegungsdetektion und Bewegungsschätzung ausführlich in Kapitel 4 beschrieben und bzgl. ihrer Eignung zur Turbulenzkorrektur diskutiert. Neben einer Diskussion verschiedener Bewegungstypen in Abhängigkeit von der vorliegenden Situation in Abschnitt 4.1, beinhaltet dies zum einen verschiedene "Block Matching"-Algorithmen im Abschnitt 4.2 und zum anderen mehrere Methoden zur Bestimmung des "Optischen Flusses" im Abschnitt 4.3. In Abschnitt 4.4 werden diese Algorithmen vergleichend evaluiert und sowohl mit Hinblick auf den Einsatz bei Objektbewegung diskutiert, als auch hinsichtlich der praktischen Anwendung auf turbulenzgestörte Bilddaten.

Bildunschärfe hat einen signifikanten Anteil an turbulenzbedingten Beeinträchtigungen der Bildqualität. Deshalb enthalten Verfahren zur Turbulenzkorrektur in der Regel auch ein "Deblurring", d. h. eine Methode zur Verbesserung der Bildschärfe. In Kapitel 5 geht es speziell darum, die Eignung verschiedener Entfaltungsmethoden für einen Einsatz bei zunehmend starker Turbulenz zu bewerten. Dazu werden zunächst verschiedene Entfaltungsalgorithmen genauer beschrieben (in Abschnitt 5.1). Es handelt sich dabei in erster Linie um etablierte Methoden, da sich auch viele neuere Entfaltungsalgorithmen im Kern auf die ein oder andere dieser Methoden zurückführen lassen. Denn wie u. a. der Artikel von Hardie et al. [Har17] erkennen lässt, haben auch etablierte Verfahren wie "Wiener Filter" und "Block Matching" ihre Relevanz noch nicht verloren. In Abschnitt 5.2 sind einige repräsentative Entfaltungsergebnisse (für eine Auswahl dieser Algorithmen) abgebildet, die in Abschnitt 5.3 verglichen und evaluiert werden. In dem Abschnitt 5.4 werden die Eigenschaften der verschiedenen Algorithmus-Typen noch einmal vergleichend zusammengefasst und diskutiert.

Das Kapitel 6 bildet den Schwerpunkt dieser Arbeit und befasst sich mit den verschiedenen praktischen Aspekten, die rund um das Thema Turbulenzkorrektur zu berücksichtigen sind. In Abschnitt 6.1 werden die Anforderungen an geeignete Testsequenzen erörtert und die Spezifikationen der hier bevorzugt verwendeten Testsequenzen angegeben. In Abschnitt 6.2 geht es um konkrete Möglichkeiten, die atmosphärische Filterfunktion (PSF) mithilfe verfügbarer Informationen statistisch zu approximieren. Messwerte der hierzu erforderlichen Kohärenzlänge (r_0) stehen jedoch nur im Ausnahmefall zur Verfügung, daher wird in Abschnitt 6.3 eine modifizierte Methode zur zuverlässigen Abschätzung dieser Information anhand von Bildsequenzen vorgestellt. Je nach Ausmaß der turbulenzbedingten Beeinträchtigungen in gegebenen Bilddaten, können entsprechende Korrekturverfahren auch von einer angemessenen Vorverarbeitung dieser Daten profitieren, wofür die besten Optionen in Abschnitt 6.4 diskutiert werden. Es folgt eine Beschreibung eigener Korrekturverfahren, wobei die Funktionsweise der lokalen Bewegungskompensation (MCA) und das Prinzip der lokalen Bildstapelung (LIS) in Abschnitt 6.5 erläutert werden. Die entwickelte Entfaltungsmethode wird überdies in Abschnitt 6.6 im Detail beschrieben. Repräsentative Resultate dieser Verfahren werden insbesondere in Abschnitt 6.7 gezeigt. Für eine objektive Bewertung von Korrekturalgorithmen liegen idealerweise ungestörte Bilddaten vor, die mit den Rekonstruktionsergebnissen verglichen werden können. Dies ist in der Regel nur bei simulierten Daten der Fall, die den zusätzlichen Vorteil bieten, dass der Szeneninhalt nach Bedarf ausgewählt werden kann. Maximale Flexibilität besteht insbesondere, wenn es sich um eine vollständig synthetische Simulation handelt, wie sie in Abschnitt 6.9 beschrieben ist.

In Kapitel 7 geht es schlussendlich um die methodische Evaluierung von Turbulenzkorrekturverfahren. In Abschnitt 7.1 wird der Begriff der Bildqualität in Zusammenhang mit der jeweiligen Anwendung gebracht, und es werden verschiedene Metriken zur Bestimmung der Bildqualität vorgestellt. Welche Einflussfaktoren zu berücksichtigen sind, wird in Abschnitt 7.3 diskutiert. Eine abschließende Zusammenfassung ist in Abschnitt 7.4 gegeben.

2

Stand der Forschung und Technik

Generell lassen sich Verfahren zur Turbulenzkorrektur in Bilddaten in zwei Kategorien einteilen: hardware- und softwarebasierte Lösungen, wobei durchaus auch Hybrid-Ansätze existieren, welche sowohl Hardware- als auch Software-Elemente miteinander vereinen.

Wenn man von reinen Hardware-Systemen zur Kompensation von Turbulenzeffekten spricht, handelt es sich in der Regel um *Adaptive Optik*-Systeme, welche einfallendes Licht (von einer punktförmigen Quelle) durch Adaptierung einer Optik so modifizieren können, dass die Abbildungsqualität verbessert wird.

Das Spektrum an softwarebasierten Korrekturverfahren ist hingegen deutlich vielfältiger. Zu den wohl bekanntesten und verbreitetsten Prinzipien zählen dabei *“Lucky Imaging”* und *“Speckle”-Interferometrie*, ebenso wie zahlreiche Methoden zur *Bewegungskompensation*. Insbesondere diese bewegungskompensierenden Verfahren, darunter diverse *“Block Matching”* und *“Optical Flow”* Algorithmen, werden häufig in Verbindung mit *“Super-resolution”*-Algorithmen oder einer Form von *“Deblurring”* eingesetzt, z. B. (mehr oder weniger) *“Blinde” Entfaltung*.

2.1 Adaptive Optik

Adaptive Optik (AO) dient dazu, die Leistungsfähigkeit elektrooptischer Systeme zu erhöhen. Ursprünglich für Anwendungen der Astronomie entwickelt, wird AO inzwischen auch für viele Laseranwendungen, wie z. B. in der Laserkommunikation eingesetzt. Insbesondere in der Astronomie, z. B. in der Sonnenphysik, kommen heutzutage zusätzlich zur Hardware-Korrektur auch softwarebasierte Verfahren zum Einsatz, aufgrund dessen unter günstigen Bedingungen mitunter ein Verbesserungsgrad nahe dem Diffraktionslimit erreicht werden kann.

Wie das Funktionsschema in Abbildung 2.1 veranschaulicht, werden bei AO-Systemen zunächst die Wellenfronten einfallenden Lichts mit Hilfe von Wellenfrontsensoren gemessen und etwaige Verformungen ermittelt. Dies geschieht in der Regel unter der Annahme, dass sich die betreffende (punkt-förmige) Lichtquelle in hinreichend großer Entfernung befindet, so dass die Wellenfront idealerweise planar sein müsste. Somit können Abweichungen bestimmt und mit Hilfe eines deformierbaren Spiegels korrigiert werden.

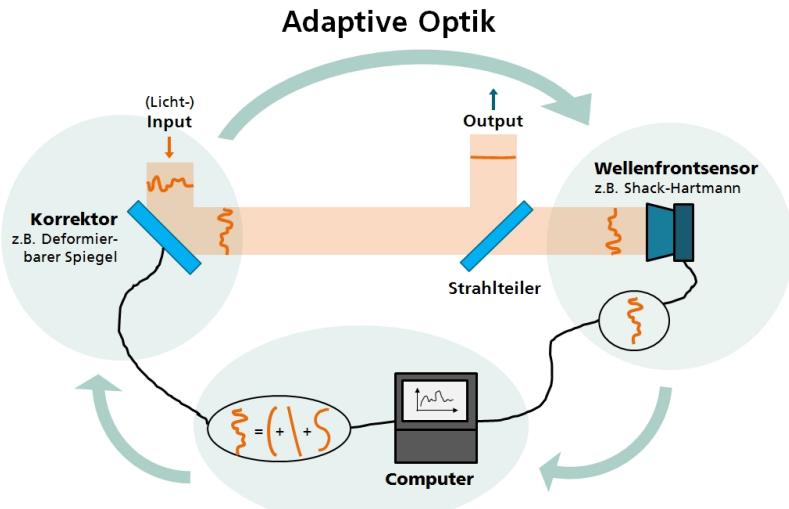


Abbildung 2.1: Funktionsschema eines AO-Systems (Grafik: A. Zepp)

2.1.1 Wellenfrontsensoren

Besonders verbreitet unter den Wellenfrontsensoren sind sogenannte Shack-Hartmann Sensoren. Diese bestehen aus einem Mikrolinsenarray, welches das einfallende Licht in kleine Subaperturen aufteilt und auf einen Bildsensor fokussiert, so dass jede Linse einen eigenen Fokus erzeugt. Aus den relativen Positionen dieser Foki lässt sich dann die (aufgrund von Turbulenz gestörte) Form der einfallenden Wellenfront anhand von geometrischen Betrachtungen und mittels entsprechender Algorithmen ermitteln. Zwar existieren auch andere Methoden zur Wellenfrontmessung, deren Einsatzmöglichkeiten sind jedoch meist auf bestimmte Anwendungen beschränkt. Beispielsweise ist der (noch im Entwicklungsstadium befindliche) Ansatz eines holografischen Wellenfrontsensors, wie in [Zep13] beschrieben, durchaus vielversprechend, nicht zuletzt dank seiner Unempfindlichkeit gegenüber Szintillation. Aufgrund seiner konstruktionsbedingten Limitierung auf einzelne Wellenlängen ist sein Einsatz jedoch nur für schmalbandige Anwendungen wie die Laserkommunikation geeignet.

2.1.2 Deformierbare Spiegel

Die eigentliche Korrektur erfolgt schließlich mit Hilfe eines deformierbaren Spiegels, welcher aus einer sehr dünnen spiegelnden Membran besteht. Unterhalb dieser Membran befindet sich ein Array von Aktuatoren, welche über Anlegung einer Spannung (nahezu) unabhängig voneinander gesteuert werden können. Dies bedeutet, dass sich die Spiegeloberfläche über entsprechende Steuersignale gezielt lokal verformen lässt, um die (Turbulenzverursachten) Deformationen der Wellenfront auszugleichen und auf diese Weise zu kompensieren.

Diese Art der Spiegel-Kontrolle über eine Feedback-Schleife zu einem Wellenfrontsensor bezeichnet man als "*Closed-Loop*". Naturgemäß müssen die Messungen hinreichend schnell wiederholt (und in entsprechende Steuersignale umgewandelt) werden, bevor sich die einfallende Wellenfront aufgrund von Turbulenz zu stark verändert hat. Alternativ lässt sich der deformierbare Spiegel aber auch in einer sogenannten "*Open-Loop*" ansteuern. Dabei wird anstelle von aktuell gemessenen Wellenfronten eine Menge

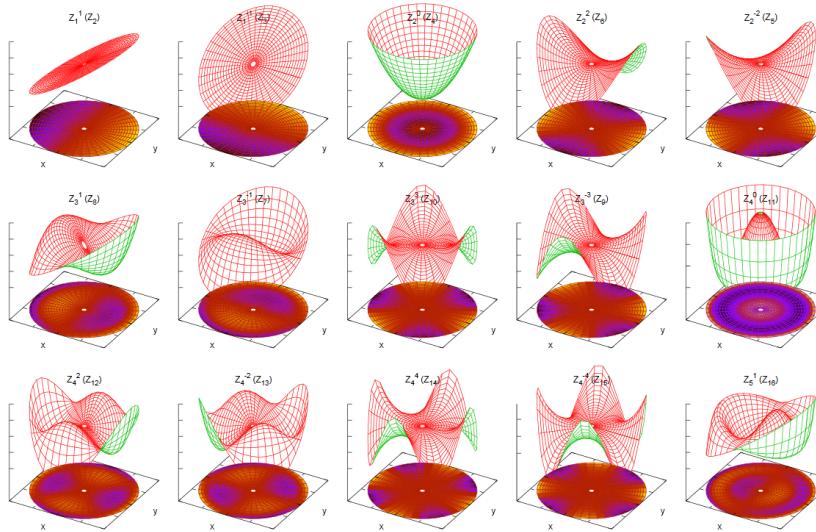
an vorab berechneten oder gespeicherten Wellenfront-Formen verwendet, anhand derer iterativ nach einer möglichst optimalen Lösung gesucht wird.

2.1.3 Zernike-Polynome

Für die Steuerung der Aktuatoren wiederum muss natürlich eine geeignete Beschreibung der erwünschten Oberflächenform vorliegen, welche dann in geeignete Steuersignale umgewandelt werden kann. Hierzu wird zumeist eine Zerlegung in sogenannte *Zernike-Polynome* vorgenommen, welche in Abhängigkeit von Radius und Azimutwinkel ausgedrückt werden. Jeder Term in einer solchen Zerlegung repräsentiert einen spezifischen Aberrationstyp. So beschreiben Terme 1. radialer Ordnung sogenannte „*Tip-Tilt*“ Störungen, welche globalen Bildbewegungen entsprechen, genauer „Verkippungen“ in horizontaler bzw. in vertikaler Richtung. Analog korrespondieren Terme 2. radialer Ordnung zu den Aberrationstypen „*Defocus*“ (in Längsrichtung) sowie *Astigmatismus* (in schräger bzw. in vertikaler Richtung), und Terme 3. radialer Ordnung korrespondieren zu den Aberrationstypen „*Coma*“ (in horizontaler bzw. vertikaler Richtung) sowie „*Trefoil*“ (in schräger bzw. in vertikaler Richtung).

Zur Veranschaulichung zeigt Abbildung 2.2 die zugehörigen Formen der (orthogonalen) Zernike-Polynome 1. bis 4. (sowie eines 5.) radialer Ordnung. Mit steigender (radialer) Ordnung lässt die Stärke des Einflusses der individuellen Aberrationen deutlich nach. Demgemäß können bereits Korrekturen der niedrigeren Ordnungen signifikante Verbesserungen der Bildqualität erzielen. Aus diesem Grund beschränken sich zahlreiche AO-Anwendungen nur auf die Korrektur der ersten 2 bis 3 radialen Ordnungen, nicht zuletzt zur Laufzeitbeschleunigung bzw. zur Erhöhung der Iterationsrate bei der Spiegelkontrolle.

Es sollte angemerkt werden, dass die Zernike-Polynome zwar im mathematischen Sinn „orthogonal“ und demgemäß voneinander unabhängig sind, dass physikalisch betrachtet jedoch das Vorhandensein von Aberrationen höherer Ordnung normalerweise auch das Vorhandensein der korrespondierenden Aberrationen niederer Ordnung bedeutet (d. h. Aberrationen mit niederer radialer Ordnung, aber von gleicher azimutaler Ordnung).

Abbildung 2.2: Zernike-Polynome 1. bis 4. Ordnung¹

2.2 Softwarebasierte Verfahren

Neben klassischen Verfahren wie der nachfolgend vorgestellten “Speckle”-Interferometrie und dem “Lucky Imaging” gibt es noch eine Vielzahl von anderen Algorithmen, die mit der Korrektur von einem oder mehreren der in der Abbildung 1.11 aufgelisteten Turbulenzeffekten befasst sind. Aufgrund der großen Fülle an existierenden Verfahren zur Turbulenzkorrektur, die sich in der Literatur finden lassen, wäre hier eine vollständige Auflistung kaum möglich und wenig zielführend. Stattdessen wurden einige Korrekturansätze ausgewählt, die für den Themenkomplex in der vorliegenden Arbeit besonders relevant sind. Jedem dieser Ansätze wurden beispielhaft ein oder mehrere repräsentative Verfahren zugeordnet und ggfs. eingehender diskutiert.

¹ Quelle: R. J. Mathar, CC BY-SA 3.0, via Wikimedia Commons https://commons.wikimedia.org/wiki/File:Zernike_polynomials3.pdf

2.2.1 “Speckle Interferometry”

Statt von “Speckle”-Interferometrie (SI) spricht man oft auch von “*Speckle Imaging*”, wobei es sich um ein hochauflösendes Bildgebungsverfahren handelt. SI geht auf Arbeiten des französischen Astronoms Antoine Labeyrie von 1970 zurück [Lab70] und findet in erster Linie Anwendung in der Astronomie, ebenso wie die Adaptive Optik. Während bei der AO Störungen der Phase (d. h. der elektrischen Feldstärke) ankommender Wellenfronten mittels geeigneter Sensorik gemessen und kompensiert werden (siehe Abschnitt 2.1), werden bei der SI die Amplitude und die Phase der Fouriertransformierten der Bildintensitätswerte rekonstruiert. Genauer wird die sogenannte *Bispektrum*-Methode verwendet, erstmalig beschrieben von Gerd Weigelt in [Wei75], um Schätzungen für die tatsächliche Phase zu bekommen. Hierbei wird eine möglichst große Anzahl von Interferogrammen (d. h. von Bildern, deren Belichtungszeit so kurz ist, dass die Variationen in der atmosphärischen Turbulenz quasi “eingefroren” sind) einer Fourier-Analyse unterzogen und das durchschnittliche Bispektrum berechnet. Die eigentliche Rekonstruktion erfolgt dann über dessen Invertierung.

Durch SI kann die Winkelauflösung bodengebundener Teleskope signifikant erhöht werden. Allerdings ist die Anwendung normalerweise auf helle (und idealerweise punktförmige) Zielobjekte beschränkt, wodurch der Einsatz für ausgedehnte Ziele nur mit viel zusätzlichem Aufwand möglich ist und hohe Rechenleistung erfordert. In der Sonnenphysik ist speziell die Rekonstruktion ausgedehnter Areale auf der Sonnenoberfläche ein grundlegendes Forschungsthema (z. B. zur Beobachtung von Sonnenflecken) [Lüh93]. Verfahren wie die *Knox-Thompson-Methode* [Kno74] und die heute vorwiegend verwendete *Triplekorrelation* [Lüh83, Rod86] wurden speziell für die solare Bilderfassung entwickelt, um die Erstellung photometrisch exakter Karten der Intensität von kleinmaßstäblichen Strukturen auf der solaren Oberfläche zu ermöglichen. Mithilfe dieser Techniken können Sichtfelder beliebiger Größe rekonstruiert werden, sogar wenn diese viel größer sein sollten als der isoplanatische Patch (siehe Abschnitt 3.3). Die Abbildung 2.3 zeigt am Beispiel eines Sonnenfleckens auf der solaren Oberfläche ein Korrekturergebnis der Triplekorrelationsmethode.

Für die Punktziel-Problematik gibt es eine relativ gut funktionierende Lösungsmethode, die speziell in der solaren Astronomie seit ca. 1985 im Ein-

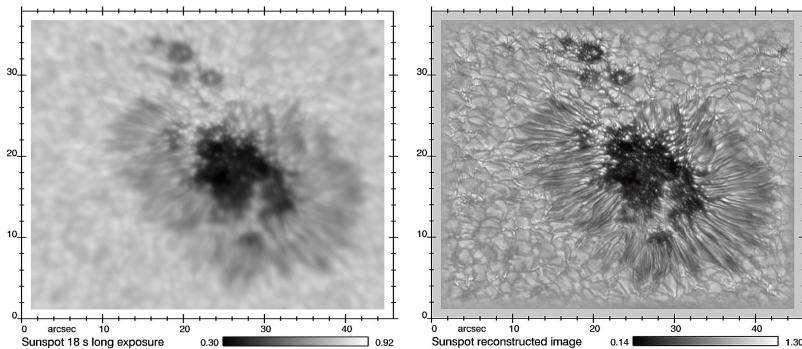


Abbildung 2.3: Beispielrekonstruktion eines Sonnenfleckens mittels Triplekorrelation.²

satz ist. Diese besteht darin, dass große Bilder in kleinere Kacheln unterteilt werden, die jeweils einzeln korrigiert werden. Anschließend werden sie wieder zusammengefügt und die Übergänge zwischen den Kacheln mithilfe von Hamming-Windows überblendet. Diese Methode wurde insbesondere von Carmen Carrano (LLNL, USA) für horizontale Bilderfassung eingesetzt [Car02]. Eine entsprechende Implementierung der Firma EM Photonics auf FPGAs [Cur09] kann unter optimalen Bedingungen sogar eine Korrektur in Echtzeit durchführen (abgesehen von einem zeitlichen Delay am Anfang).

2.2.2 “Lucky Imaging”

Bei dem “Lucky Imaging” (LI) Prinzip wird ausgenutzt, dass die Bildqualität im Verlauf einer Sequenz lokal variiert aufgrund von lokalen Schwankungen im Brechungsindex der Atmosphäre. Es besteht sogar die Chance, dass die turbulenten Luftsichten das einfallende Licht vom Zielobjekt stellenweise so gut fokussieren wie es im Idealfall ohne Turbulenz möglich wäre. Einzelne Bildregionen können also kurzzeitig nur geringfügig bis gar nicht durch

² Quelle: Bildmaterial freundlicherweise von Prof. O. v. d. Lühe vom Leibniz-Institut für Sonnenphysik (KIS) zur Verfügung gestellt.

Turbulenz beeinträchtigt sein. Die Wahrscheinlichkeit dafür, dass dieser Fall eintritt, lässt sich gemäß [Fri78] statistisch bestimmen.

Um diese “Glücksfälle” nutzen zu können, wo und wann immer sie auftreten, wird eine Art Qualitätskarte zur Bewertung der lokalen Bildqualität für die Einzelbilder einer Sequenz benötigt. Hierzu können geeignete *Qualitätsmetriken* (“Image Quality Metrics”, IQM) verwendet werden (s. a. Abschnitt 7.1). Anhand dessen können die jeweils besten Bildregionen (innerhalb eines gegebenen Zeitraums) identifiziert und zu einem neuen, stabilisierten Bild zusammengesetzt werden. Auf diese Weise kann unter besonders günstigen Bedingungen (und mit entsprechend qualitativ hochwertiger Optik) sogar ein Verbesserungsgrad nahe dem Diffractionslimit erreicht werden. Angesichts der synthetischen Konstruktionsweise wird diese Technik häufig auch als “Lucky Region Fusion” oder “Synthetic Imaging” bezeichnet.

Die Abbildung 2.4 zeigt ein Beispiel für eine “Lucky Imaging”-Korrektur gemäß dem in [Aub08] beschriebenen Ansatz, welcher z. T. auf den Arbeiten in [Joh03] beruht. Die Bewegungsartefakte im unteren Bildbereich stammen von einem Vogel, der durch das Bild fliegt. Dies geschieht aufgrund der neuen Information, die gleich in mehreren Einzelbildern hintereinander an unterschiedlichen Stellen auftaucht. Dadurch wird dem Algorithmus suggeriert, dass sich dort etwas qualitativ Hochwertiges befindet, das erhalten werden muss. Daran lässt sich gleich die Haupt-Problematik dieser Methode erkennen: sie ist nicht (bzw. nicht ohne zusätzliche Maßnahmen) für Szenen geeignet, die bewegte Objekte enthalten. Überdies ist im vorliegenden Fall keine echte Verbesserung gegenüber dem besten Einzelbild der Sequenz erkennbar, auch nicht in den Bildregionen ohne Einwirkung von Störobjekten. Ob die Methode letzten Endes zu einer Bildverbesserung führt, kann also tatsächlich “Glücksache” sein.

2.2.3 Bildbewegung - Bildstabilisierung

Anwendungen von Turbulenzkorrekturverfahren sind überwiegend an einem ganzheitlichen Lösungsansatz interessiert. Das heißt, idealerweise soll eine Korrektur sämtlicher Turbulenzeffekte durchgeführt und eine optimale

³ Quelle: M. Vorontsov, G. Carhart

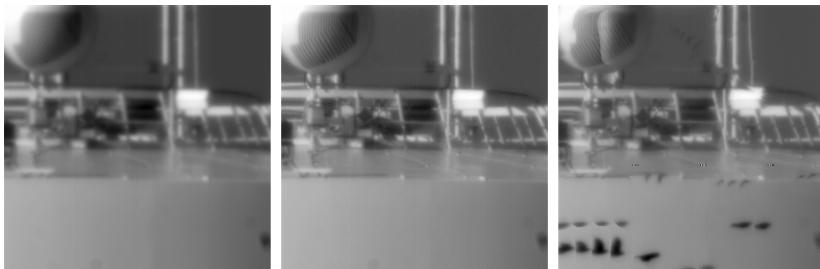


Abbildung 2.4: “Synthetic Imaging”-Korrektur einer Beispieldsequenz. Links: Mittelwert von 930 Frames, Mitte: bester Frame, rechts: Korrekturergebnis mit Bewegungsartefakten.³

Verbesserung des Eingangsbildes erzielt werden. Spezialisierte Algorithmen priorisieren allerdings häufig die Korrektur ganz bestimmter Turbulenzefekte (ohne zwangsläufig darauf beschränkt zu sein). Beispielsweise gibt es Verfahren, die in erster Linie auf eine Bildstabilisierung von Videos setzen wie z. B. beschrieben in den Arbeiten von Li [Li09] und Yifei et al. [Lou13]. Zur Videostabilisierung wird häufig eine zeitliche Glättung der Pixelintensitäten eingesetzt, sowie insbesondere auch der CARES-Algorithmus⁴ von G. Potvin (DRDC, Kanada) [Pot14]. Speziell bei diesem Algorithmus wird sowohl eine zeitliche als auch eine räumliche Filterung durchgeführt. Dazu werden die zeitlichen Intensitätsfluktuationen der einzelnen Pixel über einen vorgegebenen Zeitraum analysiert (unter Verwendung eines Bildpuffers). Hinreichend große Intensitätsänderungen, deren Dauer eine vorgegebene Grenze nicht überschreitet, werden als Bewegung erkannt und beibehalten, während kleine Fluktuationen mittels Tiefpassfilterung geglättet werden. Genauer wird eine Zerlegung des Eingangsbild unter Verwendung einer Laplace-Pyramide vorgenommen in mehrere Tiefpass- und Hochpass-, sowie auch Bandpass-Komponenten, deren Gesamtsumme wiederum das Eingangsbild ergibt. Zuvor werden auf die jeweiligen Komponenten noch unterschiedliche auto-regressive exponentielle Glättungsfilter (ARES-Filter)

⁴ CARES: “Cascaded Auto-Regressive Exponential Smoothing”

angewendet. Das Ergebnis der folgenden Aufsummierung wird abschließend wieder mit einem Schärfungsfilter behandelt.

Der CARES-Algorithmus überzeugt durchaus bei der Bildstabilisierung von Video-Streams, ohne Zusatzmaßnahmen kann er jedoch trotz Schärfungsfilter keine völlig zufriedenstellende Bildqualität erzielen. Daher bietet sich hierfür z. B. ein nachträgliches Deblurring der einzelnen Ausgabebilder an. Die Abbildung 2.5 zeigt am Beispiel der “China Lake”-Testsequenz (für Details siehe Abschnitt 6.1.1), wie sehr der CARES-Algorithmus mit Standardeinstellungen (Mitte) von einer zusätzlichen blinden Entfaltung (rechts) profitieren kann. Hier wurde dazu der WIBD-Algorithmus aus Abschnitt 6.6 verwendet. Insbesondere lässt die Mustertafel im Hintergrund erkennen, dass die Bildverformungen bei so starker Turbulenz, wie sie in der Sequenz vorliegt, nur unzureichend abgemildert werden können. Dazu sollte noch erwähnt werden, dass diese Methode für die zeitliche Analyse der Pixelintensitäten eine Bildpufferung einsetzt, aufgrund derer sich für das Ausgabevideo ein Delay (d. h. eine zeitliche Verzögerung) von einer halben Pufferlänge ergibt. Für anisoplanatische Turbulenzbedingungen müsste dieser Puffer gegenüber der Standardgröße deutlich vergrößert werden, um eine hinreichende Glättung zu erzielen. Allerdings hätte dies wiederum eine unerwünschte Verstärkung der Unschärfe zur Folge, verbunden mit potenziellem Detailverlust.

Des Weiteren wird das Thema “Bewegungskompensation” mit Hinblick auf die Korrektur turbulenzbedingter Bildbewegungen auch eingehend in Kapitel 4 behandelt.

2.2.4 Bildverzerrung - Bewegungskompensation

In weiteren Verfahren geht es vornehmlich um eine Korrektur geometrischer Bildverzerrungen wie z. B. in dem Artikel von Fraser et al. [Fra06] oder Anantrasirichai et al. [Ana13], sowie Furhad et al. [Fur16].

Dabei besteht eine gewisse Verwandtschaft zu den Methoden zur Bildstabilisierung, denn eine geschickte Bewegungskompensation (global, sowie lokal) stellt nicht nur eine Möglichkeit zur Reduktion geometrischer Bilddeformierungen dar, sondern hat durchaus auch eine stabilisierende Wirkung. Neben klassischen pixelbasierten Algorithmen zur Bewegungsschätzung (und Bewegungskompensation) so wie “Block Matching” oder der “Opti-



Abbildung 2.5: Beispieldaten des CARES-Algorithmus. Links: Originalframe; Mitte: CARES-Korrekturergebnis; rechts: mit zusätzlicher blinder Entfaltung (mittels WIBD).

sche Fluss" existieren noch weitere Möglichkeiten für eine effektive (lokale) Bildregistrierung. Beispielsweise kann eine Kreuzkorrelation zur Bildregistrierung eingesetzt werden oder auch eine nicht-rigide Bildregistrierung unter Verwendung von "B-Splines" (unter zusätzlichen Symmetrievorgaben) wie in dem Ansatz von Zhu und Milanfar [Zhu13] vorgeschlagen wird.

Ein nicht un wesentliches Problem der meisten dieser bewegungskompen sierenden Verfahren besteht allerdings in der Frage nach einem geeigneten Referenzbild, welches sinnvollerweise als Grundlage für jede Art von Bildregistrierung dienen kann. Selektiert man ein beliebiges Einzelbild einer Sequenz, wird dieses Bild ebenfalls turbulenzbedingte Verformungen aufweisen. Verwendet man stattdessen einen Mittelwert, werden solche Bildverzerrungen zwar reduziert, zugleich erhöht sich aber der Unschärfe grad, wodurch wiederum die Registrierung erschwert wird. Von Furhad et al. [Fur16] (UNSW, Australien) wird deshalb ein Lösungsansatz vorgeschlagen, bei dem ein geeignetes Referenzbild nach dem "Lucky Shot"-Prinzip konstruiert wird. Hierzu wird erst die Bildschärfe der einzelnen Frames über eine Summierung der hohen Frequenzanteile des Bildes ermittelt. Dazu ließen sich allerdings auch andere Metriken verwenden, die den Schärfe bzw. Unschärfe grad eines Bildes hinreichend gut quantisieren können, wie z. B. die "Blur"-Metrik von Dolmire et al. [Dol07] (s. a. Abschnitt 7.1.3), die zudem den Vorteil hat, dass die Werte auf das Intervall $[0,1]$ normiert sind. Anhand ihres jeweiligen Schärfegrades werden die Frames unter Verwendung einer "k-Means" Clusteranalyse in Kategorien mit unterschiedlichem

Schärfegrad eingeteilt ($k = 3$). Aus den beiden Gruppen mit mittlerer und bester Bildschärfe werden mittels “Lucky Imaging”-Verfahren die “besten” Bildregionen ausgewählt und fusioniert, wobei die Teilmenge mit dem geringsten Schärfegrad nicht berücksichtigt wird. Mit dem Fusionsergebnis als Referenz wird daraufhin eine lokale Bildregistrierung der gesamten Bildsequenz durchgeführt (gemäß [Zhu13]) mit abschließender blinder Entfaltung wie es bei der Mehrzahl von Turbulenzkorrekturverfahren der Fall ist.

Dieser Ansatz hat den Nachteil, dass eine Bildsequenz erst vollständig analysiert wird, bevor eine Ausgabe erzeugt wird. Das bedeutet, dass er zunächst nicht für Echtzeitanwendungen geeignet ist. Denkbar wäre allerdings die Verwendung eines Bildpuffers, so dass es im Idealfall nur eine Verzögerung gäbe, die der Pufferlänge entspricht. Das würde aber voraussetzen, dass der Rechenaufwand die Kapazitäten moderner Systeme nicht übersteigt.

Auch der Ansatz von Anantrasirichai et al. [Ana13] verwendet eine Art von “Lucky Imaging”, wobei hier eine “Dual Tree” komplexe Wavelet-Transformation (DT-CWT) eingesetzt wird, um eine rekursive Fusion auf Merkmalsebene statt auf Pixelebene durchzuführen und so auch semantische Fusionsregeln berücksichtigen zu können. Die DT-CWT verwendet zwei verschiedene (reelle) diskrete Wavelet-Transformationen (DWT), eine für den Realteil und die andere für den Imaginärteil der CWT. Von Vorteil ist hier zum einen, dass die Phase von DT-CWT-Koeffizienten gegenüber zeitlichen Intensitätsschwankungen, sowie auch Rauschen relativ robust ist, und zum anderen, dass sie nahezu invariant gegenüber Verschiebungen ist. Letztlich wird dadurch eine Glättung der zeitlichen Intensitätsschwankungen für jede Pixelspalte erreicht. Statt blinder Entfaltung zum Abschluss wird hier jedoch nur eine Kontrastverbesserung mittels adaptivem Histogrammausgleich durchgeführt (unter Verwendung des CLAHE-Algorithmus von Zuiderveld [Zui94]). Die Fusionsergebnisse sind etwas schärfer als es bei Verfahren mit einer Form von Bildmittelung typischerweise der Fall ist. Diese Art der Fusion kann auch auf bewegte Objekte angewendet werden, dazu müsste allerdings zuvor eine Segmentierung der bewegten Objekte und des statischen Hintergrunds vorgenommen werden.

Die Problematik eines geeigneten Referenzbildes wird im Übrigen auch in Kapitel 4 behandelt und wird noch einmal im Abschnitt 6.5.1 in Kapitel 6 aufgegriffen. Beschreibungen eigener Methoden zur lokalen Bewegungs-

kompensation sind darüber hinaus in [Hue09], sowie insbesondere im Abschnitt 6.5 zu finden.

2.2.5 Bildunschärfe - Entfaltung

Andere Verfahren konzentrieren sich wiederum besonders auf eine Schätzung und Reduktion der Unschärfe wie es z. B. in den Arbeiten von Yitzhaky et al. der Fall ist ([Yit97a],[Yit98]), sowie auch in Greco et al. [Gre08].

Für diese Korrekturaufgabe bieten sich insbesondere Algorithmen zur (blinden) Entfaltung an, u. U. in Verbindung mit einer Schätzmethode für die atmosphärische Filterfunktion wie z. B. von Molina et al. [MM15] für anisoplanatische Bedingungen beschrieben. In diesem Ansatz wird zunächst die Turbulenzstärke (d. h. die Kohärenzlänge r_0 , siehe Abschnitt 3.3.2) direkt aus einer Bildsequenz geschätzt anhand der “Angle of Arrival” Varianzen. Mithilfe der Kohärenzlänge lässt sich eine statistische PSF konstruieren, die anschließend zur Entfaltung verwendet wird. Die verwendete Schätzmethode für r_0 folgt dem von Gladysz et al. beschriebenen Verfahren [Gla13], das auf den Arbeiten von Beaumont et al. [Bea98], sowie von Zamek und Yitzhaky [Zam06] aufbaut. Aber auch neuere Ansätze wie z. B. der von McCrae et al. [McC17] basieren in der Regel auf einer ähnlichen Grundidee.

Einen allgemeinen Überblick über klassische Entfaltungsalgorithmen geben z. B. Kundur und Hatzinakos in [Kun96b] sowie Chaudhuri et al. in ihrem Buchkapitel [Cha14]. Levin et al. haben ihren Fokus in [Lev09] speziell auf etwas neuere Entfaltungsalgorithmen gelegt, die sie anhand der jeweiligen Rekonstruktionsergebnisse für künstlich erzeugte Bildstörungen evaluieren. Bei den Testdaten handelte es sich ausschließlich um Simulationen von Kamerabewegungen, die sich global auf das gesamte Bild auswirken, so wie sie z. B. im Fall einer handgehaltenen Kamera auftreten können. Über die Leistungsfähigkeit der einzelnen Algorithmen unter realen Turbulenzbedingungen kann entsprechend keine schlüssige Aussage getroffen werden. Bei der Schätzung von Kamerabewegungen in Einzelbildern vermochte speziell der Algorithmus von Fergus et al. aus [Fer06] zu überzeugen. Ob sich dieser Erfolg ohne Weiteres auch auf turbulenzgestörte Daten übertragen ließe, darf hingegen angezweifelt werden. Zum einen sorgen turbulenzbedingte lokale Bildbewegungen nicht nur für eine zeitliche, sondern auch für eine räumlich veränderliche Filterfunktion, und zum anderen werden durch den

Tiefpassfilter-Effekt der Atmosphäre höherfrequente Signalanteile entfernt (d. h. kleine Details), die für die Funktionsweise dieser Methode benötigt werden. Es ist bedeutend leichter ein im Grunde genommen scharfes Bild zu rekonstruieren, das global mit einer einzigen PSF gefiltert wurde, als eines, das bereits eine gewisse Grundunschärfe aufweist und mit einer lokal variablen Filterfunktion gefiltert wurde.

Während in der Mehrheit vergleichbarer Ansätze eine räumliche Invarianz der atmosphärischen Filterfunktion angenommen wird, wird in dem Ansatz von Hirsch et al. [Hir10] neben der zeitlichen Variabilität über mehrere Bilder einer Sequenz speziell auch die räumliche Veränderlichkeit mitberücksichtigt. Zwar liegen die potenziellen Vorteile dieser Herangehensweise auf der Hand, das gilt allerdings auch für die Nachteile. Statt einer einzigen Filterfunktion pro Bild müsste hier für jedes Teilbild eine eigene Filterfunktion geschätzt werden, im schlimmsten Fall sogar für jedes einzelne Pixel (zzgl. einer Umgebung). Dabei wächst der Rechenaufwand mit der Bildgröße und Framerate, was u. U. extrem viel Rechenzeit in Anspruch nehmen kann. Ohnehin ist die Annahme räumlicher Invarianz für diverse Fälle durchaus zutreffend, wie z. B. in isoplanatischen Turbulenzbedingungen (s. a. Abschnitt 3.3). Zudem kann auch in anisoplanatischen Bedingungen eine räumliche Invarianz ggfs. (näherungsweise) künstlich erzeugt werden, z. B. über eine intelligente Bildmittlung und/oder mithilfe lokaler Bildregistrierungstechniken. Alternativ wird von Dudorov und Eremina in [Dud18] die Verwendung eines Multi-Apertur-Systems vorgeschlagen, wobei derartige Systeme bislang höchstens als Spezialanfertigungen erhältlich sind. Daher wird mithilfe einer Simulation gezeigt, dass sich aus den kleinen Teilbildern, die von den Subaperturen erfasst werden, ein großes Gesamtbild zusammensetzen lässt, das selbst ebenfalls isoplanatisch ist. Um dies zu erreichen, sollten die einzelnen Subaperturen aber nicht größer als die Kohärenzlänge r_0 sein (s. a. Abschnitt 3.3.2). Die synthetische Zusammensetzung der Teilbilder zu einem Gesamtbild erfolgt nach dem gleichen Prinzip wie die Bildformierung bei einer Lichtfeldkamera mit einer Multi-Linsen-Optik, wenn auch in etwas vereinfachter Form, da die 3-D Informationen nicht berücksichtigt werden ([Ng06]). Das Potenzial zur Bildverbesserung mithilfe dieser Art der Aufnahmetechnik ist unbestreitbar. Ob sie sich in absehbarer Zukunft jedoch für horizontale Bilderfassung durchzusetzen vermag, bleibt abzuwarten. An dieser Stelle ist anzumerken, dass es sich bei vielen

“neuen” Entfaltungsalgorithmen vor allem um Weiterentwicklungen oder Optimierungen bewährter Verfahren handelt. Insbesondere werden häufig Regularisierungen zur Problemlösung eingesetzt.

An dieser Stelle sei für eine weiterführende Behandlung des Themas auf das Kapitel 5 verwiesen, das sich schwerpunktmäßig mit der Beschreibung und Evaluierung von Entfaltungsalgorithmen bei atmosphärischer Turbulenz befasst.

2.2.6 Objektbewegung - Detektion und Tracking

Zu den bisherigen Verfahren kommen weitere, deren Fokus insbesondere auf Szenen mit bewegten Objekten liegt wie z. B. in Carrano und Bräse [Car04] oder in [Pao14], sowie in diversen Publikationen des TNO (Niederlande), darunter z. B. Dijk et al. [Dijk16], sowie Nieuwenhuizen et al. [Nie19]. Im Großen und Ganzen ist die Literatur rund um das Thema Objektbewegung und Turbulenz dennoch als vergleichsweise spärlich zu bezeichnen, und erst in der jüngeren Vergangenheit ist das wissenschaftliche Interesse an diesem Themenkomplex enorm angestiegen. Es sollte deshalb nicht unerwähnt bleiben, dass eigene Arbeiten durchaus mit zu den ersten Veröffentlichungen auf diesem Gebiet gehören, vor allem [Hue11] und [Hue12a], insbesondere aber auch [Hue16].

Bei [Car04] handelt es sich lediglich um eine Erweiterung des “Speckle Imaging”-Verfahrens für ausgedehnte Objekte bei horizontalem Ausbreitungsweg in [Car02], um auch bewegte Objekte berücksichtigen zu können. Bei dem originalen SI-Verfahren werden für ein Ausgabebild u. a. jeweils ca. 100 Kurzzeitbelichtungen registriert und gemittelt. Dabei sollten die Aufnahmen über einen Zeitraum von mindestens einer Sekunde verteilt erfolgen mit einer Belichtungszeit im Millisekundenbereich, so dass die atmosphärischen Störungen weitgehend unkorreliert sind, während die Turbulenz in den Einzelbildern zugleich quasi “eingefroren” ist. Entsprechend bedeutet jede zusätzliche Bewegung auch eine Verstärkung der (Bewegungs-)Unschärfe im Ergebnis der Bildmittelung. Aus diesem Grund funktioniert die vorgeschlagene Anpassung auch nur für bewegte Objekte (z. B. Fahrzeuge), die mithilfe einer (manuellen) Nachführung der Kameraoptik vergleichsweise statisch und mittig im Bild gehalten werden, während sich stattdessen der Hintergrund zu bewegen scheint.

Die eigentliche Modifikation besteht darin, dass der ursprüngliche Algorithmus nur auf einen kleinen rechteckigen Bildausschnitt mit dem betreffenden Objekt angewendet wird (wobei die eigentliche Segmentierung vom Hintergrund über ein Gauß-Fenster erfolgt), anstelle des gesamten (gekachelten) Bildes wie zuvor. Das Ergebnis wird anschließend zurück in die Rohdaten eingeblendet, wobei die Überblendung wie beim Hauptalgorithmus wieder unter Verwendung von Hamming-Fenstern erfolgt. Es überrascht demnach nicht, dass sich diese Methode besonders gut in Verbindung mit dem Tracking von Flugkörpern u. Ä. eignet, wobei der Hintergrund in der Regel ohnehin sehr homogen ist und sich nur wenig verändert.

In [Pao14], sowie auch in [Kel17] liegt der Fokus auf Lösungsansätzen für drei verschiedene Bewegungsszenarios (s. a. Abschnitt 4.1) im Zusammenhang mit einer Echtzeit-Implementierung dieses SI-Verfahrens (unter der Bezeichnung ATCOM). Für Kameraschwenks wird z. B. eine dynamische Aktualisierung des Mittelwerts vorgeschlagen, während Tracking mit einem gleitenden ROI für Szenarien mit Flugkörpern oder Fahrzeugen (wie zuvor beschrieben) vorgeschlagen wird. Für komplexere Szenarien mit strukturierten Hintergründen und nicht-linearen Bewegungsmustern (z. B. Personen) wird zusätzlich ein mehrstufiges Prädiktionssystem zur Detektion von echter Objektbewegung zur Unterscheidung von turbulenzbedingter Bewegung vorgeschlagen. Genauer wird aus dem Verlauf vergangener Frames unter Verwendung einer Hauptkomponentenanalyse extrapoliert wie der nachfolgende Frame aller Wahrscheinlichkeit nach aussehen wird. Besonders große Abweichungen von dieser Vorhersage werden als Objektbewegung gekennzeichnet.

Eine objektive Beurteilung dieser Lösungsvorschläge wird dadurch erschwert, dass die Autoren weitgehend auf die Angabe spezifischer Details verzichtet haben, wahrscheinlich aus proprietären Gründen. So wird auch bzgl. des eingesetzten Tracking keine spezielle Methode genannt, sondern nur auf eine Übersicht verschiedener Tracking-Verfahren verwiesen in [Yil06]. In diesem Zusammenhang ist der Artikel von Chen et al. [Che14] deutlich informativer, da es dort ganz konkret um die Detektion und das Tracking von bewegten Objekten unter Turbulenzbedingungen geht, speziell in einer Entfernung von mehreren Kilometern. Ein Ergebnisvergleich verschiedener Methoden macht deutlich, wie sehr die Leistungsfähigkeit selbst der besten unter den getesteten Algorithmen beeinträchtigt wird, wenn die Turbulenz-

stärke zunimmt und damit auch die Turbulenzeffekte.

Bei den am TNO entwickelten Korrekturverfahren hingegen liegt ein besonderer Fokus auf maritimen Anwendungen, nicht zuletzt aufgrund seiner geographischen Nähe zur Küste. Unter anderem wurde dort ein Software-System zur Bildrekonstruktion für die Fernerkundung bei moderater Turbulenz über See entwickelt (je nach Version auch mit Hardware-Komponenten), um Schiffe in großer Entfernung besser klassifizieren und identifizieren zu können. An dessen Entwicklung waren u. a. Adam van Eekeren [vE12], Maarten Kruithof [Kru12], Klamer Schutte [Sch12] und Judith Dijk [Dij16] maßgeblich beteiligt.

Bei diesem Ansatz wird als erstes eine globale Bildregistrierung durchgeführt, auf die eine Objekterkennung hinreichend großer Objekte folgt (mind. 10×10 px). Für jedes detektierte Objekt wird ein ROI definiert, dessen Spur in Relation zum Hintergrund verfolgt wird, während die Bewegung innerhalb des ROIs kompensiert wird. Dabei ist anzumerken, dass für das Tracking auch Auf- und Abwärtsbewegungen der Schiffe, sowie seitliche Neigungen (d. h. Teilrotationen) aufgrund des Wellengangs berücksichtigt werden. Ähnlich wie auch bei der Modifikation des SI-Algorithmus in [Car04] erfolgt die eigentliche Turbulenzkorrektur, bezeichnet als "Dynamic Superresolution" (DSR) [Sch03], nur auf den ROIs. Dabei handelt es sich im Wesentlichen um eine lokale Bildregistrierung und Rauschreduktion in Verbindung mit einem Schärfungsfilter und einer adaptiven Kontrastverbesserung. Die Auswahl (und Parametereinstellungen) der tatsächlich durchzuführenden Korrekturschritte ist aber letztlich abhängig von der Qualität der Eingabedaten und den Randbedingungen bei der Aufnahme. Bei besonders geringem Kontrast und starkem Rauschen kann die Bildregistrierung z. B. nicht mehr sinnvoll durchgeführt werden, so dass nur eine Rauschreduktion mit nachfolgender Kontrastverstärkung durchgeführt wird.

Dieses Software-System wird im Übrigen permanent überarbeitet und erweitert, wie z. B. in [Nie19] durch eine ähnliche Bildstabilisierung wie beim CARES-Algorithmus. Dort wird die Bewegung zwischen den einzelnen Frames mithilfe des Algorithmus von Lucas und Kanade [Luc81] zur Bestimmung des Optischen Flusses pixelgenau bestimmt. Dann wird ein einfacher zeitlicher autoregressiver Filter verwendet, der so eingestellt ist, dass er auch Objektbewegung erkennen und berücksichtigen kann.

Auf diesem Themenbereich liegt ein besonderer Schwerpunkt in dieser Arbeit, daher sei für eine weiterführende Diskussion dieser Problematik insbesondere auf den Abschnitt 4.1, sowie auch auf den Abschnitt 6.4.4 verwiesen.

2.2.7 “Superresolution”

Der Begriff “*Superresolution*” taucht sehr häufig in Verbindung mit Algorithmen zur Bildverbesserung und Rekonstruktion auf. Eine diesbezügliche Evaluierung verschiedener Superresolution-Algorithmen hinsichtlich ihrer Leistungsfähigkeit bei realen Bilddaten ist z. B. in [vE07] gegeben.

Es hat sich gezeigt, dass sich nur vergleichsweise selten eine echte Erhöhung der Bildauflösung erzielen lässt, falls die Bildqualität der Eingabedaten zu stark durch Turbulenzeffekte beeinträchtigt ist. Deshalb wird unter derartigen Turbulenzbedingungen z. B. bei der zuvor erwähnten DSR-Bildkorrektur des TNO [Sch03] auf den Versuch einer solchen Auflösungsverbesserung sogar verzichtet.

Bei geringer bis moderater Turbulenz können hingegen Algorithmen wie das Verfahren von Kruithof et al. [Kru12] überzeugen, welches ganz speziell auf die Erkennung und Rekonstruktion von Schriftzügen zugeschnitten ist, wie z. B. von Schiffskennungen oder Nummernschildern. Dabei wird ausgenutzt, dass der Hintergrund eines Schildes normalerweise unifarben ist und sich der zugehörige Bildausschnitt als dünn besetzte Matrix interpretieren lässt. Die Rekonstruktion von Schriftzügen erfolgt hier unter Verwendung einer hinreichend großen Bibliothek von simulierten Templates, die für Buchstaben (und ggfs. Zahlen) typische Teilstrukturen enthalten. Dabei ist zu beachten, dass dieses Verfahren nicht auf beliebige Bildinhalte anwendbar ist. Bereits für unterschiedliche Arten von Schildern (z. B. bei Kursivschrift) können verschiedene Template-Bibliotheken erforderlich sein.

In dem Ansatz von Andrew Lambert et al. [Lam02] (UNSW, Australien) wird wiederum postuliert, dass “*Superresolution*” nur unter anisoplanatischen Bedingungen möglich ist, d. h. falls eine positionsabhängig veränderliche PSF der Atmosphäre vorliegt. Aufgrund von Turbulenz werden einige Frequenzanteile des abgebildeten Objekts so stark abgelenkt, dass sie nicht mehr von der verwendeten Optik aufgenommen werden. Die Idee besteht darin,

diese Frequenzanteile unter Ausnutzung Fresnelscher Diffraktionseffekte wiederherzustellen.

Dabei sollte angemerkt werden, dass es bei diesem Ansatz nicht um “Superresolution” durch analytische oder nicht-lineare Extrapolation geht, sondern um eine aktive Veränderung des optischen Systems, vergleichbar mit der Verschiebung von einem Gitterraster. Zwar wird durchaus ein gewisses Potenzial bzgl. einer Erhöhung der Auflösung angedeutet, aber ein funktionelles “Superresolution”-Verfahren für atmosphärische Turbulenz konnte dort nicht demonstriert werden.

In der Theorie klingt “Superresolution” sehr vielversprechend und tatsächlich lässt sich mithilfe solcher Algorithmen eine signifikante Bildverbesserung mit echter Erhöhung der Bildauflösung erreichen, sofern nur geringe oder gar keine Turbulenz vorliegt. Für die im Rahmen dieser Arbeit bevorzugt betrachteten Anwendungsfälle von moderater bis sehr starker Turbulenz sind derartige Ansätze hingegen weniger gut geeignet, weshalb sie bei der Konzeption eigener Verfahren auch nicht speziell berücksichtigt wurden. Für die Diskussion in Kapitel 7 gilt diese Einschränkung allerdings nicht, hier sind prinzipiell alle Arten von Verfahren zugelassen.

2.2.8 “Deep Learning”

Verfahren, in denen eine “Deep Learning”-Architektur mit künstlichen neuronalen Netzen (insbesondere CNNs) eingesetzt werden, haben sich in den letzten Jahren in nahezu allen wissenschaftlichen Forschungsgebieten rasant ausgebreitet. Diese Art von Verfahren entstammt einem Teilgebiet des *Maschinellen Lernens* und stützt sich vor allem auf umfangreiche Mengen an Trainingsdaten. Am besten sind sie zur Erkennung und / oder Klassifikation von Objekten geeignet, die denen möglichst ähnlich sind, auf die sie gezielt trainiert wurden.

Eine sehr beliebte Anwendung für “Deep Learning” ist die Erkennung von Gesichtern. Gleichzeitig gibt es inzwischen auch entsprechende Verfahren zur Bildrekonstruktion und Bildverbesserung. Der Ansatz von Yasarla und Patel [Yas20] ist z. B. speziell auf die Rekonstruktion von Gesichtern bei Bildbeeinträchtigungen aufgrund von (milder) Turbulenz ausgelegt. Dadurch werden diese beiden Anwendungsbereiche sowohl miteinander als auch mit der Turbulenzthematik verbunden.

Das Kernprinzip derartiger Verfahren ist im Grunde genommen immer das Gleiche, allerdings muss die verwendete Architektur jeweils individuell an die vorliegende Anwendung angepasst werden. Insbesondere ließe sich sehr wahrscheinlich auch das “Superresolution”-Verfahren in [Kru12] zur Erkennung von Schriftzügen mithilfe einer passenden “Deep Learning”-Architektur umsetzen.

Da die möglichen Einsatzbereiche für solche Algorithmen sehr weit gefächert sind, werden entsprechend unterschiedliche Architekturen benötigt. Welche Art von “Deep Learning”-Architektur sich besonders gut für die Rekonstruktion turbulenzgestörter Bilddaten bei langen Ausbreitungswege eignet, wird z. B. in dem Artikel von Vint et al. [Vin20] behandelt. Dort werden die Rekonstruktionsergebnisse für die Implementierungen mehrerer unterschiedlicher Architekturen miteinander verglichen, wobei stets dieselben (simulierten) Trainingsdaten verwendet wurden. Rekonstruiert wurden hier in erster Linie Bilddaten mit simulierter Turbulenz, um die Qualität und Korrektheit der Rekonstruktionsergebnisse mithilfe der “Ground Truth” evaluieren zu können. Dieselben Architekturen wurden aber auch an Bildmaterial mit realen Turbulenzbeeinträchtigungen getestet.

“Deep Learning”-Verfahren lassen sich im Zusammenhang mit dem Themenkomplex “Turbulenz” nicht nur für die Rekonstruktion von Bilddaten, sondern auch anderweitig zur Charakterisierung von Turbulenz einsetzen. Von Vorontsov et al. [Vor20] wird “Deep Learning” beispielsweise zur Vorhersage des Strukturparameters der Fluktuationen des atmosphärischen Brechungsindex bei Turbulenz (d. h. C_n^2) verwendet. Als Trainingsdaten dienen hier zahlreiche Kurzzeitaufnahmen von Laserstrahlprofilen mit turbulenzbedingter Szintillation, sowie die zugehörigen C_n^2 -Messwerte.

Auf den ersten Blick erscheint “Deep Learning” fast wie eine Art Wunderlösung. Dennoch gibt es einige Gründe, weshalb derartige Verfahren für die vorliegende Arbeit nicht näher in Betracht gezogen wurden. Beispielsweise ist das “Black Box”-Prinzip von “Deep Learning”-Verfahren etwas kritisch zu sehen, da Rekonstruktionsergebnisse zwar optisch plausibel aussehen mögen, zugleich aber nicht verifizierbar ist, ob sie tatsächlich auch der Realität entsprechen. Insbesondere muss alles, was später rekonstruiert werden soll, zuvor entsprechend erst antrainiert werden. Dadurch besteht ein Risiko, dass Objekte falsch erkannt werden, weil sie z. B. gar nicht in den Trainingsdaten vorkommen, oder weil sie mit sehr ähnlichen Objekten verwechselt wurden.

Ein nicht unbeträchtlicher Anteil von Turbulenzkorrekturanwendungen sind in der Fernerkundung zu finden, darunter nicht wenige im Zusammenhang mit militärischer Erkundung oder Aufklärung. Entsprechend kommt es hier weniger darauf an, ob ein Ergebnisbild "gut" aussieht, als vielmehr darauf, dass die abgebildeten Objekte durch die Rekonstruktion nicht zusätzlich verfälscht werden. In der Abbildung 2.6 ist z. B. eine Person zu sehen, die ein Sprechfunkgerät in der Hand hält. Stattdessen könnte es sich jedoch auch um eine Waffe handeln. Es liegt auf der Hand, dass eine solche Verwechslung nicht akzeptabel wäre. Das heißt, eine optisch gute, aber faktisch inkorrekte Rekonstruktion könnte durchaus schlimmer sein als eine schlechtere oder ggf. gar keine Rekonstruktion.

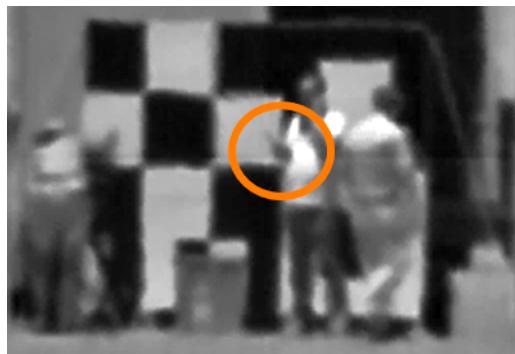


Abbildung 2.6: Beispielbild einer Person mit Funkgerät bei starker Turbulenz ("China Lake"-Testsequenz, Standardturbulenzkorrektur)

Ein zusätzlicher Kritikpunkt ist die Störanfälligkeit dieser Algorithmuskasse gegenüber sogenannten "Adversarial Attacks", wobei bereits an Lösungsansätzen hierfür gearbeitet wird (GANs). Insbesondere werden auch bei dem Verfahren von Gao et al. [Gao19] GANs eingesetzt. Es handelt sich hier in gewisser Weise um eine Weiterentwicklung von [Ana13], wobei nun "Deep Learning" mit den zuvor entwickelten Algorithmen verknüpft werden.

Hinzu kommt eine mangelnde Flexibilität bzgl. der Eingabedaten, denn diese Verfahren sind so stark spezialisiert, dass bereits relativ kleine Änderungen der Eingangsdaten die Leistungsfähigkeit des Verfahrens stark einschränken können. In einem solchen Fall werden geeignete neue (oder

modifizierte) Trainingsdaten benötigt, mit denen das System entweder zusätzlich oder ggfs. sogar komplett neu trainiert werden muss. Das bedeutet, dass jedes Mal große Mengen an spezifischen Trainingsdaten benötigt werden, die nur mithilfe entsprechender Simulationen sinnvoll zur Verfügung gestellt werden könnten. Eine Änderung des verwendeten Spektralbereichs (z. B. von VIS nach IR) könnte dies u. U. bereits erforderlich machen oder auch Änderungen am (Bewegungs-)Inhalt der abgebildeten Szene (wie z. B. Objektbewegung). Selbst eine Verstärkung des Turbulenzgrades in den Eingabedaten kann dies bewirken, falls die Turbulenzeffekte zu sehr von denen in den (alten) Trainingsdaten abweichen sollten.

Im Übrigen wurden die ersten verhältnismäßig praktikablen Ansätze zur Turbulenzkorrektur mit “Deep Learning” Unterstützung erst in den letzten 1-2 Jahren veröffentlicht, von denen sich keiner in überzeugender Weise mit der Problematik bewegter Objekte auseinandersetzt. Zwar wird das Verfahren in [Gao19] auch an einer Sequenz mit einem Fahrzeug getestet, aber da sich dieses frontal auf die Kamera zu bewegt, handelt es sich lediglich um Änderungen in der Größenskalierung.

In dieser Arbeit liegt der Fokus zwar weitgehend auf konventionellen Korrekturverfahren, dennoch sind auch Verfahren, die auf “Deep Learning” basieren, nicht von der Diskussion in Kapitel 7 ausgeschlossen.

2.3 Hybrid-Ansatz

Ein typischer Hybrid-Ansatz, so wie in [Vor96] oder [Pol99] beschrieben, besteht aus einem (hardwarebasierten) AO-System, welches (softwarebasierte) Qualitätsmetriken verwendet anstelle eines Wellenfrontsensors, um die Form des deformierbaren Spiegels in einem iterativen Prozess zu optimieren, z. B. mittels SPGD-Algorithmus (“Stochastic Parallel Gradient Descent”) wie in [Vor97] vorgeschlagen und eingesetzt in [Sch10].

Deutlich verbreiteter sind hingegen klassische AO-Systeme, die zusätzlich auch eine Software-Korrektur einsetzen, wie beispielsweise ein Deblurring. Allerdings handelt es sich dabei nicht um Hybrid-Systeme im eigentlichen Sinne. Unter Umständen ließe sich noch die “Speckle”-Interferometrie bei den Hybrid-Ansätzen einordnen, da das zugrundeliegende Prinzip einige Ähnlichkeiten mit dem AO-Prinzip aufweist. Streng genommen handelt es sich dennoch im Wesentlichen um eine softwarebasierte Methode. Echte

Hybrid-Systeme sind tatsächlich vergleichsweise selten, weshalb an dieser Stelle auch nicht näher darauf eingegangen werden soll.

2.4 Diskussion

2.4.1 Hardwarebasierte Ansätze

In der Regel sind Hardware-Systeme mit Adaptiver Optik relativ kostenintensiv aufgrund der notwendigen (teuren) optischen Elemente. Überdies sind sie typischerweise als stationäre Aufbauten konzipiert und verhältnismäßig unflexibel, sowohl bezüglich ihrer Mobilität als auch im Hinblick auf jede Parameteränderung, die ggf. mit umständlichen Änderungen des optischen Aufbaus verbunden sein kann. Hinzu kommt, dass AO am besten für nahezu punktförmige oder zumindest relativ klein erscheinende Objekte in großer Entfernung funktioniert, wie z. B. für Sterne oder Laserstrahlen, weshalb sie zurzeit sicherlich die erste Wahl für Anwendungen in der Astronomie und in der Laserkommunikation darstellt. Ideal ist dabei zudem eine möglichst vertikale Ausrichtung, weil so der Weg durch die turbulente Atmosphäre minimiert wird.

Obwohl eine Anwendung auf ausgedehnte Objekte nicht unmöglich ist, werden hierbei dennoch mehr Probleme aufgeworfen als gelöst. So ist beispielsweise jede Korrektur mit Hilfe von AO genau auf das Pixel im Zentrum des Bildes ausgerichtet, und je größer die Distanz von diesem Zentrum ist, desto weniger ist die Korrektheit dieser "Korrektur" gewährleistet. Im Gegenteil, statt einer Verbesserung kann in den äußeren Regionen hierdurch sogar eine Verschlechterung bewirkt werden. Zwar gibt es bereits Lösungsansätze für dieses Problem, wie z. B. der Einsatz eines ganzen AO-Arrays, aber dies führt wiederum zu ähnlichen Apodisationsproblemen wie sie bei der Bispectrum-Methode (Speckle-Interferometrie) auftreten.

Sollen auch noch Bewegungen im Bild berücksichtigt werden, sei es durch Objektbewegung oder aufgrund von Kamerabewegungen, werden abermals neue Probleme aufgeworfen. Das Hauptaugenmerk in dieser Arbeit liegt jedoch gerade auf der Verbesserung von Bilddaten mit ausgedehnten Objekten, inklusive der Berücksichtigung möglicher Bewegungen. Angesichts

der diesbezüglich überwiegenden Nachteile, wurde der Hardware-Ansatz im Rahmen dieser Arbeit nicht näher in Betracht gezogen.

Für die in Abschnitt 2.3 erwähnten Hybrid-Ansätze gelten im Übrigen die gleichen Beschränkungen wie für klassische Hardware-Systeme, weshalb auch diese hier nicht weiter verfolgt wurden.

2.4.2 Softwarebasierte Ansätze

Softwarebasierte Korrekturverfahren sind ihrerseits i. A. nicht auf teure Komponenten angewiesen, wobei der Einsatz von Hochleistungsrechnern oder spezieller Computer-Hardware wie z. B. GPUs oder FPGAs durchaus mit höheren Kosten verbunden sein kann. Die Hauptvorteile gegenüber Hardware-Lösungen liegen jedoch nicht nur in den vergleichsweise geringen Materialkosten, die zur Herstellung und Nutzung erforderlich sind, sondern vor allem in ihrer Flexibilität und Vielzahl von Anwendungsmöglichkeiten.

Ein Nachteil der meisten Methoden ist die vergleichsweise lange Rechenzeit, die sie benötigen, um bestmögliche Korrekturen zu erzielen. Mithilfe einer geeigneten Implementierung, z. B. über eine Parallelisierung der Algorithmen oder eine Hardware-Implementierung, lassen sich einige Methoden aber bereits jetzt in (oder zumindest nahe) Echtzeit ausführen.

Wie sich in dem Überblick über die verschiedenen Verfahren in Abschnitt 2.2 bereits abzeichnet, bietet sich am ehesten ein modularer Lösungsansatz an. Damit ist gemeint, dass die einzelnen Turbulenzeffekte quasi nach dem Baukastenprinzip voneinander (relativ) getrennt betrachtet und behandelt werden können, so wie es ohnehin von den meisten ganzheitlichen Turbulenzkorrekturverfahren gehandhabt wird, u. a. in [Fur16], sowie in [Dij16]. Eine solche Vorgehensweise bietet die besten Optionen und ermöglicht die größte Flexibilität, da z. B. einzelne Komponenten je nach Bedarf neu hinzugefügt oder gegen modifizierte Versionen ausgetauscht werden können. Dabei ist die Reihenfolge der einzelnen Komponenten zwar nicht zwingend festgelegt, im Normalfall ist sie allerdings auch nicht völlig frei wählbar, da sie zu einem gewissen Grad von dem Informationsfluss zwischen den Komponenten abhängt. Zum einen müssen erforderliche Informationen rechtzeitig vorliegen, sobald sie benötigt werden, und zum anderen sollten Informationen, die für mehrere Komponenten nutzbar sind (z. B. Bewegungsvektoren) sinnvollerweise nur einmal ermittelt werden und bei Bedarf an weitere Komponenten übergeben werden. Die Austauschbarkeit dieser

Komponenten wird dadurch entsprechend eingeschränkt, wobei sich insbesondere eine Bildregistrierung zu Beginn und ein Deblurring zum Abschluss bewährt hat.

Zwar werden hier überwiegend konventionelle Methoden zur Bewegungsschätzung (siehe Kapitel 4), sowie zur Entfaltung (siehe Kapitel 5) behandelt, dennoch betrifft diese Einschränkung nicht das Evaluierungskonzept in Kapitel 7. Wie zudem der Artikel von Hardie et al. [Har17] erkennen lässt, haben auch etablierte Verfahren wie z. B. “Block Matching” und Wiener Filterung ihre Relevanz noch nicht verloren.

Wenngleich im Abschnitt 2.2.8 einige Argumente gegen die Verwendung von “Deep Learning”-Architekturen in der vorliegenden Arbeit angeführt wurden, ist anzunehmen, dass es in Zukunft höchstwahrscheinlich noch sehr viel mehr dieser Verfahren geben wird. Es ist daher wahrscheinlich, dass auch Lösungen für derzeit noch bestehende Probleme gefunden werden können.

3

Theoretische Grundlagen

Bei der Erfassung von Bilddaten durch eine turbulente Atmosphäre sind diverse Turbulenzeffekte zu beobachten. Einige Beispiele für die markantesten Effekte (d. h. Unschärfe, Bildbewegung und Deformierung) wurden bereits in der Einleitung in den Abbildungen 1.4 und 1.5 gezeigt. Verantwortlich dafür sind zufällige Fluktuationen im Brechungsindex des Ausbreitungsmediums (i. A. Luft oder ggf. Wasser), wodurch einfallende ebene Lichtwellen kumulativ gebeugt und die Wellenfronten deformiert werden.

Will man die Effekte optischer Turbulenz in Bilddaten korrigieren, ist es zunächst wichtig zu verstehen wie Turbulenz überhaupt erst entsteht, und wie sie sich unter bestimmten Umständen auf den Bilderfassungsprozess auswirkt. Zu diesem Zweck werden entsprechende Werkzeuge benötigt. Die notwendige Terminologie hierfür entstammt verschiedenen ineinander greifenden Forschungsfeldern, insbesondere der Statistik, der Strömungslehre, sowie der Astronomie und nicht zuletzt der Optik. In diesem Kapitel sind deshalb die wichtigsten Definitionen und Konzepte zur Charakterisierung und Modellierung von Turbulenz aus diesen Bereichen zusammengefasst, mit besonderem Augenmerk auf den Eigenschaften atmosphärischer Turbulenz. Die Ausbreitung von (Licht-)Wellen durch eine turbulente Atmosphäre lässt sich näherungsweise mithilfe theoretischer Modelle beschreiben. Weit verbreitet ist beispielsweise Kolmogorovs „Power Spectral Density“ Modell, wel-

ches nach wie vor verwendet wird. Die wegweisenden Beiträge von Kolmogorov [Kol41], Tatarskii [Tat61], [Tat71], von Kármán [Kár37a], [Kár37b] und Fried [Fri66], [Fri82] bilden die theoretische Grundlage für fast alle nachfolgenden Arbeiten in der atmosphärischen Optik.

3.1 Definitionen aus der Statistik

Turbulenz ist in hohem Maße instabil, und das chaotische Verhalten eines turbulenten Mediums ist analytisch nicht präzise vorhersagbar. Es liegt daher nahe, Turbulenz stattdessen anhand ihrer statistischen Eigenschaften zu charakterisieren. Die zufällige Natur von Turbulenz kann z. B. mithilfe *stochastischer Prozesse* modelliert werden. Insbesondere lässt sich die durch Turbulenz verursachte Phasenverzerrung einer einfallenden Lichtwelle sehr gut über eine *Gauß-Verteilung* quantifizieren.

Die *Wahrscheinlichkeitsdichtefunktion* (“Probability Density Function”, PDF) $p(f)$ einer *Zufallsvariablen* F mit Wert f ist ganz allgemein definiert wie folgt [Dai00]:

$$p(f) df := \text{Prob} \{ f \leq F < f + df \} \quad (3.1)$$

Das bedeutet, dass sich keine genaue Aussage über den Wert f der Zufallsvariablen F treffen lässt. Man kann nur die Wahrscheinlichkeit (“Prob”) angeben, mit der F (im diskreten Fall) einen bestimmten Wert annimmt bzw. (im kontinuierlichen Fall) innerhalb eines bestimmten Intervalls liegt.

3.1.1 Stationäre stochastische Prozesse

Ein *stochastischer Prozess* (auch: Zufallsprozess) $F(x)$ beschreibt eine Menge von Zufallsvariablen, die zeit- und/oder ortsabhängig sind. Die Phase einer Lichtwelle, die eine turbulente Atmosphäre durchquert hat, entspricht z. B. einem räumlich und zeitlich veränderlichen Zufallsprozess.

Der Wert eines Zufallsprozesses zu einem gegebenen Punkt x ist eine Zufallsvariable mit zugehöriger PDF $p(f|x)$, Erwartungswert $\mu(x)$ und Varianz $\sigma(x)$. Falls die PDF invariant ist gegenüber Translationen bzgl. x , handelt es sich um einen *stationären Prozess*. Das bedeutet, dass keine der Zustands-

größen von x abhängig ist und die statistischen Eigenschaften (d. h. μ , σ und die Autokorrelationsfunktion) überall konstant sind. Das trifft insbesondere auch auf atmosphärische Turbulenz zu, bei der es sich (in guter Näherung) um einen stationären Prozess handelt.

3.1.2 Momente μ_k

In der Praxis ist es zuweilen von Vorteil, das Verhalten von Zufallsvariablen mithilfe der sogenannten *Momente* $\mu_1, \mu_2, \dots, \mu_N$, ($N \in \mathbb{N}$) zu beschreiben, anstatt die gesamte Funktion $p(f)$ zu bestimmen. Diese Momente sind definiert durch:

$$\mu_k = \langle f^k \rangle = \int_{-\infty}^{+\infty} p(f) f^k \, df \quad (k = 1, \dots, N) \quad (3.2)$$

3.1.3 Erwartungswert μ und Standardabweichung σ

Die beiden wichtigsten Parameter zur Beschreibung einer Zufallsvariablen sind der *Erwartungswert* μ und die *Varianz* σ^2 , die sich über die ersten beiden Momente μ_1 und μ_2 ausdrücken lassen wie folgt:

$$\mu = \mu_1 \quad (3.3)$$

$$\sigma^2 = \mu_2 - \mu_1^2 \quad (3.4)$$

Insbesondere wird σ , d. h. die Wurzel aus der Varianz, als *Standardabweichung* bezeichnet. Es hängt von der jeweiligen Anwendung ab, welcher der beiden Ausdrücke besser geeignet ist. In der AO wird z. B. bevorzugt die Varianz eingesetzt.

Hierbei ist anzumerken, dass in dieser Arbeit sehr häufig diskrete Messdaten betrachtet werden. Nachfolgend sind deshalb auch die entsprechenden Schätzungen $\hat{\mu}$ und $\hat{\sigma}$ für den diskreten Fall notiert, d. h. für eine Anzahl von $n \in \mathbb{N}$ diskreten Messwerten x_1, \dots, x_n :

$$\hat{\mu} = \frac{1}{n} \sum_{k=1}^n x_k \quad (3.5)$$

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{k=1}^n (x_k - \mu)^2 \quad (3.6)$$

3.1.4 Die Gauß-Funktion

Die Wahrscheinlichkeitsdichtefunktion einer *Gaußschen Normalverteilung* wird häufig auch *Gauß-Funktion* genannt. Sie lässt sich vollständig mithilfe des Erwartungswertes μ und der Varianz σ^2 beschreiben. Die Gauß-Funktion f ist definiert wie folgt:

$$f(x) = \frac{1}{\sqrt{2\pi} \cdot \sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (-\infty < x < +\infty) \quad (3.7)$$

3.1.5 Die Strukturfunktion

Die *Strukturfunktion* $D_x(r_1, r_2)$ einer Zufallsvariablen x entspricht dem Erwartungswert der Differenz der an den Stellen r_1, r_2 gemessenen Werte von x , d. h. D_x ist definiert durch:

$$D_x(r_1, r_2) := \langle |x(r_1) - x(r_2)| \rangle \quad (3.8)$$

Nähere Ausführungen zur physikalischen Bedeutung von Strukturfunktionen im Zusammenhang mit Kolmogorov-Turbulenz sind in Abschnitt 3.2.6 zu finden.

3.1.6 Die Kovarianzfunktion

Die Wahrscheinlichkeitsdichtefunktion $p(f)$ beschreibt nur die stochastischen Eigenschaften in einem einzigen Punkt x , deshalb spricht man auch von einer PDF 1. Ordnung. Es bedarf jedoch einer PDF 2. Ordnung, um auch die zeitliche und/oder räumliche Struktur eines Zufallsprozesses zu erfassen. Von besonderem Interesse ist hier, wie hoch die Geschwindigkeit ist, mit der Veränderungen eintreten.

Auch die PDF 2. Ordnung lässt sich wieder mithilfe ihrer Momente ausdrücken, insbesondere anhand der wichtigen *Kovarianzfunktion* $C(x')$. Die

Kovarianzfunktion C eines reellwertigen stationären stochastischen Prozesses lässt sich gemäß [Dai00] folgendermaßen formulieren:

$$C(x') := \langle (f(x) - \langle f \rangle) \cdot (f(x + x') - \langle f \rangle) \rangle \quad (3.9)$$

Falls $\langle f \rangle = 0$ gilt, stimmt die Kovarianzfunktion mit der *Autokorrelationsfunktion* überein, und die Varianz σ^2 lässt sich folgendermaßen ausdrücken:

$$\sigma^2 = C(x' = 0) = \langle f^2 \rangle - \langle f \rangle^2 \quad (3.10)$$

Im Fall atmosphärischer Turbulenz ist die Kovarianzfunktion nicht ohne Weiteres messbar, daher wird stattdessen die folgende Strukturfunktion D definiert:

$$D(x') := \langle (f(x) - f(x + x'))^2 \rangle = 2 \cdot (C(0) - C(x')) \quad (3.11)$$

3.1.7 Das Wiener-Khinchin Theorem

Das *Wiener-Khinchin Theorem*¹ (auch: “Wiener-Chintchin-Kolmogorov”) besagt, dass die Autokorrelationsfunktion eines stationären stochastischen Prozesses mit der zugehörigen *spektralen Leistungsdichte* (“Power Spectral Density”) korrespondiert, die generell als auch *Powerspektrum* bezeichnet wird. Anders ausgedrückt, das Powerspektrum Φ eines stationären Prozesses ist für die Ortsfrequenz κ definiert als die Fourier-Transformierte der Kovarianzfunktion in Gleichung (3.9):

$$\Phi(\kappa) = \int_{-\infty}^{+\infty} C(x') e^{-2\pi i \kappa x'} dx \quad (3.12)$$

Mit Hilfe des Powerspektrums lässt sich die Struktur eines Zufallsprozesses im Fourier-Raum beschreiben, siehe auch Abschnitt 3.2.7.

¹ So benannt nach dem amerikanischen Mathematiker Norbert Wiener (1894 bis 1964) und dem russischen Mathematiker Aleksandr Yakovlevich Khinchin (1894 bis 1959)

3.2 Turbulenz in der Fluidodynamik

Viele Beschreibungen atmosphärischer Turbulenz lassen sich auf Erkenntnisse und Begrifflichkeiten aus der Strömungslehre, speziell der Fluidodynamik, zurückführen. Hier wird Turbulenz als der Zustand eines physikalischen Systems betrachtet, das von einem Gleichgewichtszustand weit entfernt ist. Ursache dafür ist die gegenseitige Wechselwirkung zahlreicher Einflussfaktoren. Dieser Zustand ist instabil und irregulär, sowohl in zeitlicher als auch in räumlicher Hinsicht.

3.2.1 Fluide mit turbulenter Strömung

Fluide bezeichnen sowohl Flüssigkeiten als auch Gase, somit handelt es sich auch bei der Atmosphäre um ein Fluid. Man unterscheidet Fluide nach ihrem Strömungsverhalten. Fluide mit *laminarer Strömung* fließen geordnet und in einem regelmäßigen, gleichbleibenden Strömungsmuster, wobei sich benachbarte Schichten mit unterschiedlichen Fließgeschwindigkeiten nicht gegenseitig stören. Fluide mit *turbulenter Strömung* verhalten sich hingegen ungeordnet und chaotisch, wobei sich das Strömungsmuster permanent verändert. Besonders charakteristisch für eine turbulente Strömung ist dabei die Entstehung von Verwirbelungen.

3.2.2 Die Reynoldszahl Re

Zur Unterscheidung von laminarer und turbulenter Strömung kann die sogenannte *Reynoldszahl*² Re eingesetzt werden. Bei der Reynoldszahl handelt es sich um eine dimensionslose Kennzahl in der Strömungslehre, die das Verhältnis von Trägheitskräften zu viskosen Kräften innerhalb eines Fluids beschreibt. Mit ihrer Hilfe kann jede Strömung beschrieben werden. Liegt Re unterhalb eines kritischen Wertes handelt es sich um laminare Strömung, und falls Re darüber liegt, handelt es sich um turbulente Strömung. In Bodennähe, wo die Atmosphäre hochgradig turbulent ist, liegt die Reynoldszahl beispielsweise in der Größenordnung $Re \sim 10^5$.

² So benannt nach dem britischen Physiker Osborne Reynolds (1842-1912)

Die Reynoldszahl Re ist definiert als:

$$Re = \frac{\rho \cdot v \cdot d}{\eta} = \frac{v \cdot d}{\nu} \quad (3.13)$$

Während ρ die Dichte (in kg/m^3), v die mittlere Strömungsgeschwindigkeit (in m/s) und d die jeweilige Bezugslänge (in m) bezeichnen, repräsentiert η die *dynamische Viskosität*, ein Maß für die Zähflüssigkeit und das Fließverhalten von Fluiden. Die *kinematische Viskosität* ν ist insbesondere definiert als $\nu = \eta/\rho$.

Da die Viskosität von Luft sehr nahe bei Null liegt, kann die zugehörige Reynoldszahl infolgedessen extrem groß werden. Luft um den Gefrierpunkt besitzt beispielsweise eine kinematische Viskosität von $\nu = 0,132 \text{ cm}^2/\text{s}$.

3.2.3 Die Navier-Stokes Gleichungen

Mathematisch lässt sich das Strömungsverhalten von *Fluiden* (d. h. Flüssigkeiten oder Gasen mit einem ähnlichen Strömungsverhalten) ganz allgemein mithilfe der *Navier-Stokes*³ Differentialgleichungen beschreiben. Darin muss zwischen *kompressiblen* Fluiden und *inkompressiblen* Fluiden unterschieden werden. Das heißt, bei kompressiblen Fluiden ändert sich die Dichte bei Druckeinwirkung, wohingegen die Dichte bei inkompressiblen Fluiden unverändert bleibt.

Gase gehören zur Gruppe der kompressiblen Fluide, deshalb wird zur Modellierung der Atmosphäre die Navier-Stokes Differentialgleichung für kompressible Fluide benötigt, in der sowohl die Impulserhaltung als auch die Energieerhaltung, sowie die Zustandsgleichung des Gases berücksichtigt werden. Die allgemeine Form der Navier-Stokes Gleichung für kompressible Fluide lautet:

$$-\vec{\nabla}p + \eta\Delta\vec{v} + \rho\vec{f} + (\lambda + \eta)\vec{\nabla}(\vec{\nabla} \cdot \vec{v}) = \rho\frac{\partial}{\partial t}\vec{v} + \rho(\vec{v} \cdot \vec{\nabla})\vec{v} \quad (3.14)$$

³ So benannt nach dem französischen Mathematiker und Physiker Claude Louis Henri Navier (1785 bis 1836), sowie dem irischen Mathematiker und Physiker George Gabriel Stokes (1819 bis 1903)

Dabei bezeichnet p den Druck, $\vec{\nabla}p$ entspricht der Druckgradient und \vec{f} ist die Kraftdichte. Der Parameter λ bezeichnet hier ausnahmsweise die (erste) Lamé-Materialkonstante⁴ (in N/m²), die den Zusammenhang zwischen Dehnung und der daraus resultierenden Spannung beschreibt.

Die Navier-Stokes Gleichungen sind komplizierte nicht lineare Differenti-algleichungen, die zu den sieben *Millennium-Problemen* der Mathematik zählen. Das heißt, es gibt bis heute keine analytische Lösung für die Gleichungen (im dreidimensionalen Fall). In der Praxis werden daher numerische Lösungsverfahren eingesetzt, wobei die Ausgangsgleichung soweit möglich vereinfacht wird. Insbesondere lässt sich die Navier-Stokes Gleichung (3.14) zur Beschreibung des Verhaltens einer turbulenten Atmosphäre aufgrund der vernachlässigbar geringen Viskosität η von Luft (d. h. $\eta \approx 0$) auf die nachfolgende *Euler Gleichung* (3.15) reduzieren:

$$-\vec{\nabla}p + \rho\vec{f} = \rho\frac{\partial}{\partial t}\vec{v} + \rho(\vec{v} \cdot \vec{\nabla})\vec{v} \quad (3.15)$$

3.2.4 Das Turbulenzmodell von Kolmogorov

Das physikalische Turbulenzmodell von Kolmogorov⁵ (auch: Kolmogorow) hat seinen Ursprung in der Strömungslehre und fußt u. a. auf von Kármáns Arbeiten zur statistischen Theorie von isotroper Turbulenz [Kár37a]. Es handelt sich um ein vergleichsweise einfaches physikalisches Modell, das zunächst zur analytischen Evaluation der Auswirkungen von Turbulenz in turbulenten Strömungen entwickelt wurde [Kol41]. Innerhalb des Gültigkeitsbereichs lässt es sich jedoch weitgehend auch auf atmosphärische Turbulenz anwenden.

Grundannahme in dem Modell ist, dass dem turbulenten Medium von außen auf großen räumlichen Skalen Energie zugeführt wird, wodurch sich turbulente Luftwirbel (“Eddies”) bilden, die dann in einer selbstähnlichen Kaskade in immer kleinere Wirbel zerfallen. Die Abbildung 3.1 visualisiert die Mechanismen, die in dem Turbulenzmodell von Kolmogorov wirken.

⁴ So benannt nach dem französischen Mathematiker und Physiker Gabriel Lamé (1795 bis 1870)

⁵ So benannt nach dem russischen Mathematiker Andrei Kolmogorov (1903 bis 1987)

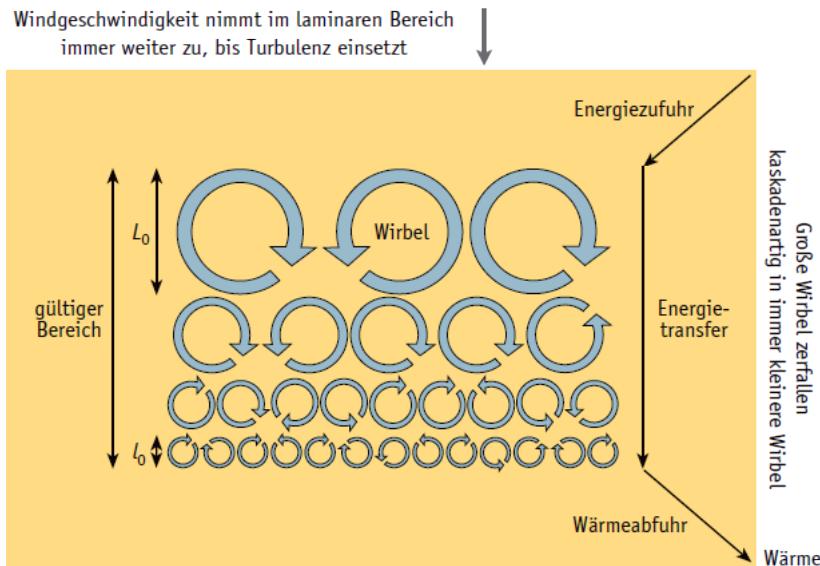


Abbildung 3.1: Mechanisches Turbulenzmodell von Kolmogorov⁶

Im sogenannten *Produktionsbereich* befinden sich die größten und zugleich energiereichsten Wirbel, wobei man häufig auch von Turbulenzzellen spricht. Dabei gibt die *äußere Skalenlänge* L_0 ("Outer Scale") die Größenordnung an, in der kinetische Energie in das System gesteckt wird. Im Fall atmosphärischer Turbulenz ist dies z. B. die Erwärmung durch Sonneneinstrahlung in Verbindung mit Scherwinden, welche die Anfangsenergie (nicht nur) in der äußeren Skalenlänge zuführen. Typische Windgeschwindigkeiten, mit denen während der Bilderfassung über horizontalen Ausbreitungs wegen in den häufigsten Anwendungsszenarien zu rechnen ist, liegen in der Größenordnung von 2 m/s bis 7 m/s.

Im *Trägheitsbereich* ("Inertial Subrange") befindet sich die Energiekaskade, innerhalb derer die großen Turbulenzwirbel in immer kleinere Wirbel

⁶ Quelle: [Hip04] www.spektrum.de/pdf/suw-2004-10-s032-pdf/834028?file
(Grafik leicht modifiziert)

zerfallen bis schließlich die kinetische Energie der kleinsten Wirbel mit der *inneren Skalenlänge* ("Inner Scale") l_0 im *Dissipationsbereich* durch viskose Reibung (der Luft) in Wärme umgewandelt wird ([Rod81]).

Während die äußere Skalenlänge L_0 die Grenze zwischen Produktions- und Trägheitsbereich angibt, entspricht die innere Skalenlänge l_0 der Grenze zwischen Trägheits- und Dissipationsbereich.

Typische Größenordnungen der Skalenlängen im Fall horizontaler Bilderfassung in (relativer) Bodennähe liegen für l_0 im Millimeterbereich und für L_0 in der Größenordnung von wenigen Metern. In astronomischen Anwendungen kann L_0 u. U. aber auch 100 m übersteigen, wobei erwähnt werden sollte, dass L_0 generell nur schwer korrekt messbar ist [Dai00].

Insbesondere besteht die folgende Beziehung zur Reynoldszahl Re :

$$Re = \frac{v_0 L_0}{\nu_0} \quad \Rightarrow \quad l_0 = \frac{L_0}{Re^{3/4}} \quad (3.16)$$

Hier bezeichnet v_0 die mittlere Geschwindigkeit der Turbulenz bei der äußeren Skalenlänge L_0 . Demnach wird l_0 größer, wenn sich die Geschwindigkeit v_0 erhöht (unter der Annahme, dass sich die äußere Skalenlänge L_0 dabei nicht verändert).

Für die Bilderfassung ist dabei relevant, dass es vor allem die großen Turbulenzzellen der Größenordnung L_0 sind, welche die Phase einfallender ebener (Licht-)Wellenfronten am stärksten beeinträchtigen. Sie sind insbesondere für die stärksten Tilt-Effekte verantwortlich, wohingegen Szintillation von den kleinsten Turbulenzzellen der Größenordnung l_0 verursacht wird.

3.2.5 Der Brechungsindex n

Die Geschwindigkeit c von Licht der Wellenlänge λ und Frequenz f im jeweiligen Ausbreitungsmedium ist von dessen Brechungsindex n abhängig, d. h. es gilt:

$$c = \lambda \cdot f = \frac{c_0}{n} \quad (3.17)$$

wobei c_0 die Lichtgeschwindigkeit im Vakuum bezeichnet ($c_0 \approx 3 \cdot 10^8$ m/s).

Der Brechungsindex n von Luft ist im Grunde genommen eine Funktion der Temperatur T (in K), des Drucks P (in mbar) und der Wellenlänge λ (in μm):

$$n = \left(1 + 7,52 \cdot 10^{-3} \frac{1}{\lambda^2} \right) \cdot \frac{P}{T} \quad (3.18)$$

Im vorliegenden Zusammenhang ist die Abhängigkeit vom (Luft-)Druck allerdings weitestgehend vernachlässigbar, weil sich Fluktuationen des Drucks mit Schallgeschwindigkeit bereits wieder ausgleichen. Das Verhalten von Temperaturschwankungen ist hingegen deutlich träger, weshalb es die Temperatur ist, welche die Statistik der Fluktuationen des Brechungsindex entscheidend bestimmt. Bei den Fluktuationen des Brechungsindex n handelt es sich insbesondere um eine Funktion der Zeit t und des Orts r , wobei sich diese zufälligen Fluktuationen in hinreichender Näherung als Gaußförmiger Zufallsprozess darstellen lassen ([Dai00]). Die statistischen Größen *Erwartungswert* und *Standardabweichung* (bzw. *Varianz*) werden dabei am häufigsten zur Charakterisierung verwendet.

3.2.6 Die Strukturfunktionen für Kolmogorov-Turbulenz

Homogene isotrope Turbulenz beschreibt eine idealisierte Form der Turbulenz, bei der die statistischen Eigenschaften invariant sind gegenüber jeder Art von Translation und Rotation, sowie auch Spiegelung an den Koordinatenachsen. In diesem Fall hängen zugehörige Strukturfunktionen nur von der Distanz $\Delta r = \|\vec{r}_1 - \vec{r}_2\|$ der Punkte \vec{r}_1, \vec{r}_2 im Raum ab.

Die Strukturfunktion der Brechungsindexfluktuationen D_n

In der Literatur ist allgemein anerkannt, dass das Powerspektrum der Fluktuationen im Brechungsindex mit dem Powerspektrum der Temperatur übereinstimmt und dass Temperaturfluktuationen dem gleichen $2/3$ -Potenzgesetz unterliegen, das auch für Fluktuationen der Geschwindigkeit gilt, wie von Kolmogorov in [Kol41] mithilfe von Dimensionsanalyse (“Dimensional Analysis”) gezeigt wurde. Die Strukturfunktion D_n des Brechungsindex n ist dementsprechend gegeben durch (s. a. Abschnitt 3.1.5):

$$D_n(\Delta r) = \langle |n(\vec{r}_1) - n(\vec{r}_2)|^2 \rangle = C_n^2(z) \cdot \Delta r^{2/3} \quad (l_0 < \Delta r < L_0) \quad (3.19)$$

Das bedeutet, dass die durchschnittliche Differenz des Brechungsindex zwischen zwei Raumpunkten \vec{r}_1 und \vec{r}_2 innerhalb des Trägheitsbereichs gemäß dem 2/3-Potenzgesetz ansteigt, je mehr sich ihr Abstand $\Delta r = \|\vec{r}_1 - \vec{r}_2\|$ vergrößert. Die äußere Skalenlänge entspricht dabei einem Maß für die physikalische Grenze, ab der diese mittlere Differenz nicht weiter zunimmt. Die Abbildung 3.2 zeigt dazu noch eine andere, etwas vereinfachte Darstellung des Turbulenzmodells von Kolmogorov, worin insbesondere die Bedeutung der Distanz r (bzw. Δr) veranschaulicht wird.

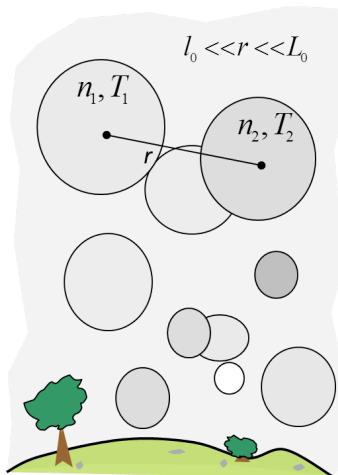


Abbildung 3.2: Darstellung des Turbulenzmodells von Kolmogorov (Grafik: K. Weiß-Wrana)

Es sollte noch angemerkt werden, dass der Strukturparameter der Fluktuationen des Brechungsindex $C_n^2(z)$ von der Höhe z abhängig ist, wobei dies vor allem für astronomische Beobachtungen mit (nahezu) vertikalem Beobachtungswinkel relevant ist. Im Fall horizontaler Bilderfassung ist die Höhe dagegen relativ konstant, denn auch bei leichter Schrägsicht haben etwaige Höhenunterschiede nur vernachlässigbar geringe Auswirkungen auf $C_n^2(z)$. Deshalb spricht man in diesem Zusammenhang zuweilen auch von einer Strukturkonstante. Hier wird daher bis auf weiteres auf die explizite Nennung der Höhenabhängigkeit verzichtet.

Speziell auf die Signifikanz von C_n^2 als Maß zur Beschreibung der Turbulenzstärke wird im Folgenden noch in Abschnitt 3.3 näher eingegangen.

Die Strukturfunktion der Temperaturfluktuationen D_T

Analog zu Gleichung (3.19) lässt sich auch eine Strukturfunktion für die Temperaturfluktuationen mithilfe eines korrespondierenden Strukturparameters C_T^2 formulieren:

$$D_T(\Delta r) = C_T^2 \cdot \Delta r^{2/3} \quad (l_0 < \Delta r < L_0) \quad (3.20)$$

Dabei unterscheiden sich C_n und C_T nur um einen Faktor, der vom Druck P und der Temperatur T abhängt und die Dimension mbar/K² aufweist.

Die Strukturfunktion der Phasenfluktuationen D_ϕ

Für Kolmogorov-Turbulenz lässt sich auch eine Strukturfunktion D_ϕ für die Phasenfluktuationen mithilfe von r_0 formulieren ([Dai00]):

$$D_\phi(\vec{x}) = 6,88 \cdot \left(\frac{\|\vec{x}\|}{r_0} \right)^{5/3} \quad (l_0 < \|\vec{x}\| < L_0) \quad (3.21)$$

Dabei bezeichnet \vec{x} einen zweidimensionalen Ortsvektor in der Pupillenebene. (3.39)

3.2.7 Powerspektren für Kolmogorov-Turbulenz

Das Powerspektrum Φ_n

Das Powerspektrum der Fluktuationen im Brechungsindex Φ_n ist definiert für dreidimensionale Variablen \vec{r} und $\vec{\kappa}$ und ergibt sich zu ([Dai00]):

$$\Phi_n(\vec{\kappa}) = 0,033 \cdot C_n^2 \|\vec{\kappa}\|^{-11/3} \quad (1/L_0 < \|\vec{\kappa}\| < 1/l_0) \quad (3.22)$$

Hierbei ist zu beachten, dass das Spektrum gegen unendlich strebt, wenn $\|\vec{\kappa}\| \rightarrow 0$.

Für endlich große Skalenlängen l_0 und L_0 gilt das *modifizierte "von Kármán"-Spektrum* ([Dai00]):

$$\Phi_n(\vec{\kappa}) = \frac{0,033 \cdot C_n^2}{(\|\vec{\kappa}\|^2 + \kappa_0^2)^{11/6}} \cdot \exp\left(-\frac{\|\vec{\kappa}\|^2}{\kappa_m^2}\right) \quad (3.23)$$

Dabei ist $\kappa_0 = 2\pi/L_0$ und $\kappa_m = 5,92/l_0$.

Das Powerspektrum Φ_ϕ

Das Powerspektrum der Phasenfluktuationen Φ_ϕ lässt sich in ähnlicher Weise zu Φ_n formulieren ([Dai00]):

$$\Phi_\phi(\vec{\kappa}) = \frac{0,023}{r_0^{5/3}} \cdot \|\vec{\kappa}\|^{-11/3} \quad (3.24)$$

3.3 Isoplanasie und Anisoplanasie

Bei der Abbildung ausgedehnter Objekte (d. h. mit großer Winkelausdehnung) durch ein turbulentes Medium muss Licht, das von verschiedenen Bereichen des Objekts ausgeht, Gebiete unterschiedlicher Turbulenz durchqueren bevor es die Optik erreicht, was zu einer räumlichen und zeitlichen Dekorrelation der Wellenfront führt.

Der maximale Winkel, innerhalb dessen man davon ausgehen kann, dass einfallende Lichtwellen nahezu identische Regionen atmosphärischer Störungen durchquert haben, wird allgemein als *isoplanatischer Winkel* bezeichnet, siehe Abbildung 3.3.

Für die Bilderfassung bedeutet dies somit, dass im Optimalfall der isoplanatische Winkel größer als das Sichtfeld ("Field of View", FOV) der verwendeten Optik ist, da dann das gesamte Bild den gleichen Turbulenzstörungen unterworfen ist. Genauer, das Licht, welches die einzelnen Detektorelemente des Bildsensors beleuchtet, hat auf seinem Weg vom Objekt zum Sensor die gleichen atmosphärischen Turbulenzen durchquert. Man spricht in diesem Fall von *Isoplanasie*. Dementsprechend tritt der ungünstigste Fall ein, wenn der isoplanatische Winkel genauso groß (oder kleiner) ist als das jeweilige Sichtfeld der einzelnen Detektorelemente ("Instantaneous Field Of View",

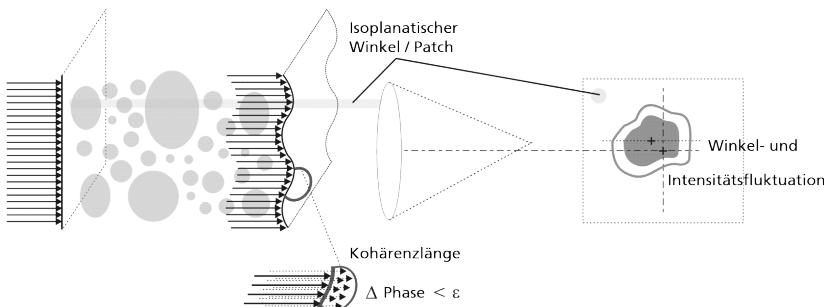


Abbildung 3.3: Illustration des isoplanatischen Winkels und der Kohärenzlänge r_0 (Grafik: E. Mauer [Mau04])

IFOV), was bedeutet, dass das Licht für jedes Pixel völlig andere Turbulenzgebiete durchquert hat. Man spricht in diesem Fall von (totaler) *Anisoplanasie*. Mit “lokaler Isoplanasie” wird entsprechend eine Mischung aus beidem bezeichnet, wobei zwar nicht das gesamte Bild, aber zusammenhängende Bildregionen unter gleichen atmosphärischen Bedingungen entstanden sind. Diese Bildregionen liegen innerhalb sogenannter *isoplanatischer Patches*.

3.3.1 Der isoplanatische Winkel θ_0

Gemäß [Fri82] lässt sich der isoplanatische Winkel θ_0 für eine gegebene Wellenlänge λ ausdrücken wie folgt:

$$\theta_0 = 0,95 \cdot \left(\frac{2\pi}{\lambda} \right)^{-6/5} L^{-8/5} (C_n^2)^{-3/5} \quad (3.25)$$

Dies gilt unter der Annahme, dass C_n^2 , der Strukturparameter der Fluktuationen im Brechungsindex von Luft n , entlang des horizontalen Ausbreitungspfads L konstant ist. Tatsächlich ist der Brechungsindex n eine Funktion der Wegstrecke s , und L entspricht der *optischen Weglänge*, d. h. es gilt:

$$L = \int n(s) ds$$

Aufgrund der zufälligen Natur der Fluktuationen im Brechungsindex und des integrierenden Messprinzips von (Laser-)Szintillometern, wie sie auch zu Messungen von C_n^2 für hier verwendete Bilddaten eingesetzt wurden, ist die Betrachtung eines konstanten C_n^2 Wertes durchaus sinnvoll.

3.3.2 Der Fried-Parameter r_0

Mit dem isoplanatischen Winkel eng verwandt, und für die Charakterisierung von Turbulenz ein ganz zentraler Parameter, ist der sogenannte *Fried-Parameter*⁷ r_0 , der auch als atmosphärische *Kohärenzlänge* bekannt ist ([Fri66]) und üblicherweise in der Einheit "cm" angegeben wird. Der Fried-Parameter ist definiert als der Durchmesser (d. h. nicht der Radius, trotz der "r" Notation) eines Teleskops, welches ohne jede Turbulenz dieselbe optische Auflösung erzielen würde wie ein Teleskop mit unendlichem Durchmesser, aber unter Turbulenzbedingungen. Für ein gegebenes Teleskop dient r_0 somit als Maß für die damit maximal erzielbare optische Auflösungsqualität. Anders ausgedrückt beschreibt r_0 den Durchmesser des kreisförmigen Gebiets, innerhalb dessen das quadratische Mittel des Wellenfrontfehlers bei ≈ 1 rad liegt.

Für den Fall horizontaler Ausbreitung von sphärischen (Licht-)Wellen lässt sich die Kohärenzlänge r_0 für eine gegebene Wellenlänge λ (d. h. *Wellenzahl* $k = 2\pi/\lambda$) gemäß [Fri82] analog zu (3.25) ausdrücken:

$$r_0 = 3,02 \cdot \left(\frac{2\pi}{\lambda} \right)^{-6/5} L^{-3/5} (C_n^2)^{-3/5} \quad (3.26)$$

3.3.3 Der Strukturparameter C_n^2

Aus praktischen Gründen kann es u. U. zweckdienlicher sein, C_n^2 anstelle von r_0 zu verwenden. Die Gleichung (3.26) lässt sich ganz einfach diesbezüglich umstellen:

$$C_n^2 = 0,16 \cdot r_0^{-5/3} \lambda^2 L^{-1} \quad (3.27)$$

d. h. für C_n^2 ergibt sich die Dimension $\text{m}^{-2/3}$.

⁷ So benannt nach dem amerikanischen Wissenschaftler David L. Fried

Für große Teleskope, wie sie in der Astronomie Verwendung finden, liegt der Fried-Parameter r_0 typischerweise in der Größenordnung von 10 cm bis 30 cm im sichtbaren Spektralbereich und zwischen 30 cm bis 150 cm im IR. Bei horizontaler Bilderfassung in Bodennähe, die in der Regel mithilfe mobiler EO-Systeme erfolgt (mit vergleichsweise sehr viel kleineren Optiken), wirkt sich die Beeinträchtigung durch Turbulenz ungleich stärker aus. Entsprechend liegen typische Werte für r_0 im Millimeter- (VIS) bis Zentimeterbereich (IR).

Die Abbildung 3.4 zeigt, wie die Kohärenzlänge r_0 mit zunehmendem Ausbreitungsweg L und ansteigender Turbulenz (v.o.n.u.) unterschiedlich im visuellen Spektralbereich (links) und im IR (rechts) abnimmt. Hierzu wurden Turbulenzstärken in häufig vorkommenden Größenordnungen ausgewählt:

- $C_n^2 = 10^{-15} \text{ m}^{-2/3}$: leichte bis moderate Turbulenz
- $C_n^2 = 10^{-14} \text{ m}^{-2/3}$: moderate bis starke Turbulenz
- $C_n^2 = 10^{-13} \text{ m}^{-2/3}$: starke bis sehr starke Turbulenz
- $C_n^2 = 10^{-12} \text{ m}^{-2/3}$: sehr starke bis extreme Turbulenz

Aus dem sichtbaren Spektrum, welches den Wellenlängenbereich von 380 nm bis 780 nm abdeckt, wurden repräsentativ die Wellenlängen $\lambda = 500 \text{ nm}$ (grün), $\lambda = 600 \text{ nm}$ (gelb-orange) und $\lambda = 700 \text{ nm}$ (rot) ausgewählt. Aus dem daran anschließenden infraroten Spektrum, welches von 780 nm bis 1 mm reicht, wurden repräsentativ die Wellenlängen $\lambda = 1,55 \mu\text{m}$, $\lambda = 3,5 \mu\text{m}$ und $\lambda = 8,5 \mu\text{m}$ selektiert (unter Berücksichtigung wesentlicher Wasserabsorptionslinien und verbreiteter Detektoren).

Im Zuge dessen sollte noch erwähnt werden, dass extreme Turbulenz der Größenordnung $C_n^2 = 10^{-12} \text{ m}^{-2/3}$ (oder größer) normalerweise nicht allein durch Sonneneinstrahlung erreicht wird. Hierzu sind größere Temperaturunterschiede erforderlich, wie sie z. B. in der Nähe eines Feuers oder des Abgasstrahls eines Flugzeugtriebwerks entstehen (s. a. Abbildung 3.5).

Der modifizierte Fried-Parameter

Bei dem Verhältnis D/r_0 aus dem Aperturdurchmesser D der Optik des verwendeten EO-Systems und der Kohärenzlänge r_0 , welches auch als *modifizierter Fried-Parameter* bezeichnet wird (u. a. in [Rod81]), handelt es

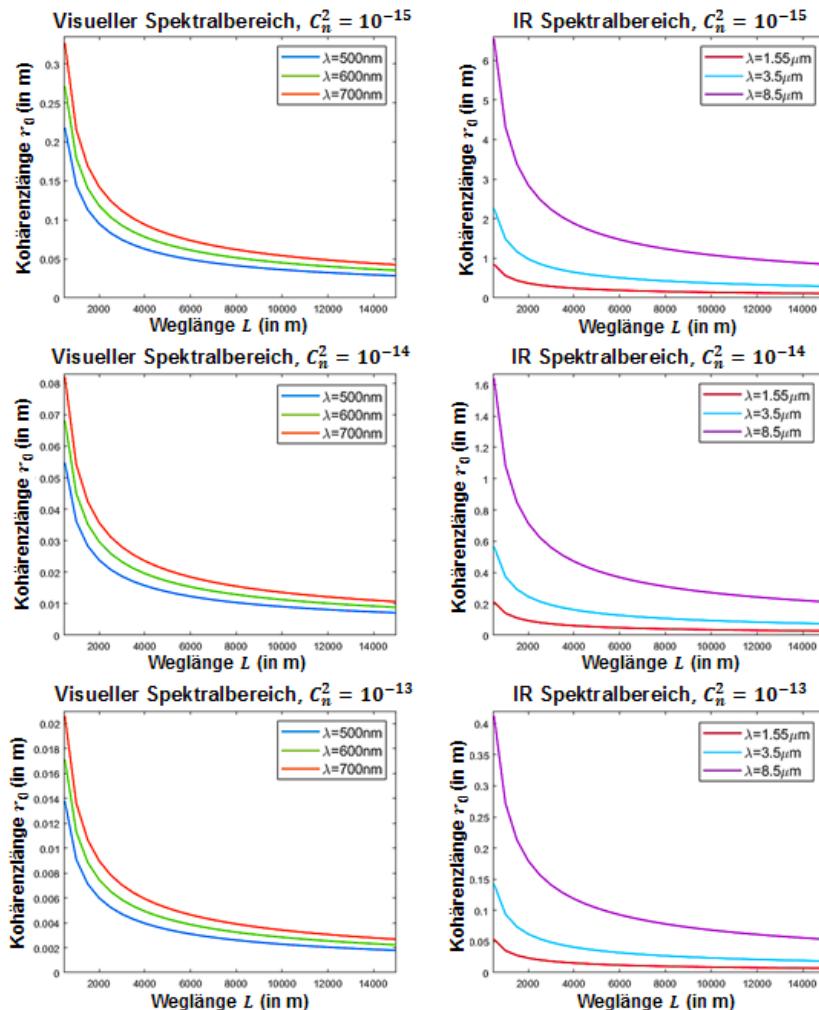


Abbildung 3.4: Die Kohärenzlänge r_0 in Abhängigkeit von der Wegstrecke L für ausgewählte Turbulenzstärken C_n^2 (in $\text{m}^{-2/3}$, v.o.n.u. zunehmend) und Wellenlängen λ . Links: VIS, rechts: IR.



Abbildung 3.5: Extreme Turbulenz verursacht durch den Abgasstrahl eines Jet-Triebwerks

sich um ein verbreitetes Maß zur Charakterisierung der Turbulenzstärke in Bilddaten. Denn je kleiner r_0 ist in Relation zur Apertur D , desto stärker ist die Turbulenz, und dementsprechend größer ist die Beeinträchtigung der Bildqualität durch Turbulenzeffekte. Das heißt r_0 dient gewissermaßen als Normierungsfaktor für die Apertur. Auch hier wird D/r_0 später (siehe Abschnitt 7.3) als ein solches Maß verwendet. Insbesondere gilt der Zusammenhang $D = f/F$, wobei f die Brennweite und F die Blendenzahl der Optik bezeichnen. Alternativ wird auch der Kehrwert r_0/D als *normierter Fried-Parameter* verwendet ([Lüh84]).

Die Abbildung 6.41 zeigt überdies einen Vergleich der aus verschiedenen Turbulenzstärken C_n^2 resultierenden PSF-Größen anhand von simulierten Daten.

3.3.4 Die Taylor-Hypothese

Die *Taylor-Hypothese* besagt, dass man annehmen kann, dass Turbulenzwirbel gewissermaßen “eingefroren” sind, während sie sich an der verwendeten Optik vorbei bewegen, da die zeitliche Größenordnung für Veränderungen des “Turbulenzmusters” deutlich darüber liegt.

Dieser Annahme liegt ein Schichtenmodell zugrunde, in dem die Turbulenz als eine Schicht (“Layer”) mit eingefrorenem Turbulenzmuster modelliert

wird oder auch als eine Reihe von solchen Schichten, deren Zwischenräume jeweils turbulenzfrei sind. Jede Schicht bewegt sich mit Windgeschwindigkeit fort (in Windrichtung), wobei jede Schicht eine etwas andere Geschwindigkeit und Richtung haben kann.

3.3.5 Die Kohärenzzeit τ_0

Zur Kohärenzlänge r_0 gehört auch die *Kohärenzzeit* τ_0 atmosphärischer Turbulenz. Dabei handelt es sich um die Zeit, die eine Turbulenzzelle benötigt, um sich mit der (Wind-)Geschwindigkeit v um die eigene Größe bzw. die Distanz r_0 fortzubewegen. Dementsprechend ist τ_0 definiert durch:

$$\tau_0 := \frac{r_0}{v} \quad (3.28)$$

Im Schichten-Modell des vorangegangenen Abschnitts 3.3.4 entspricht die Geschwindigkeit v in Gleichung (3.28) dann der Geschwindigkeit der dominanten Schicht.

Die räumliche Strukturfunktion D_ϕ in Gleichung (3.21) lässt sich mithilfe der Kohärenzzeit τ_0 auch als zeitliche Strukturfunktion ausdrücken:

$$D_\phi(t) = 6,88 \cdot \left(\frac{t}{\tau_0} \right)^{5/3} \quad (3.29)$$

Insbesondere entspricht die Kohärenzzeit dem Zeitraum, über den die PSF annähernd konstant bleibt. Das bedeutet, dass τ_0 eine effektive Obergrenze für die Belichtungsdauer des bildgebenden Systems darstellt. Demnach handelt es sich für $t \gg \tau_0$ um den “long exposure” Fall, während $t \leq \tau_0$ den “short exposure” Fall beschreibt.

3.4 Grundlagen aus der Optik

Der vielschichtige Charakter von Licht, sei es als geradlinige Lichtstrahlen, als transversale Lichtwellen oder als Teilchen (d. h. Photonen) erfordert unterschiedliche Modelle zu seiner Beschreibung. Das Strahlenmodell wird nach wie vor in der geometrischen Optik eingesetzt, während das Wellen-

modell speziell in der Wellenoptik Anwendung findet. Das Teilchenmodell wiederum wird in der Quantenphysik verwendet und ist insbesondere beim Einsatz von Lasern relevant, z. B. für die Laserkommunikation.

Im Zusammenhang mit der Lichtausbreitung durch die Atmosphäre spielen mehrere Aspekte eine signifikante Rolle. Einerseits ist das Strahlenmodell zweckdienlich für die Betrachtung des Brechungsindex in den verschiedenen Luftsichten, andererseits wird das allgemeinere Wellenmodell und das Konzept der Phase benötigt, um Eigenschaften wie Kohärenz und Interferenz, sowie die atmosphärisch bedingte Verformung von Wellenfronten sich ausbreitender Lichtwellen zu erklären.

3.4.1 Lichtwellen und Wellenfronten

Bei elektromagnetischen Wellen im Allgemeinen und Lichtwellen im Besonderen handelt es sich um *Transversalwellen*, d. h. sie breiten sich orthogonal zu ihrer Schwingungsrichtung aus. Punktlichtquellen im freien Raum erzeugen kreisförmige Wellenfronten, wobei der Radius der Wellenfronten von sehr weit entfernten Objekten wie z. B. Sternen so groß ist, dass die Wellenfronten als eben angenommen werden können. Entsprechend muss im Fall horizontaler Bilderfassung in Bodennähe von einer sphärischen Form der Wellenfronten ausgegangen werden, die sich radial von ihrem Ursprung entfernen. Dies ist in Abbildung 3.6 veranschaulicht.

Die Abbildung ausgedehnter Objekte kann man sich gemäß des *Huygenschen Prinzips* so vorstellen, dass jeder Punkt eines Objekts der Ausgangspunkt einer (halb-)kugelförmigen Elementarwelle ist. Die kombinierte Wellenfront ergibt sich aus der Überlagerung all dieser Elementarwellen.

3.4.2 Wellenfront W

Eine Wellenfront beschreibt die zusammenhängende Menge aller Punkte, die zeitlich die gleiche Entfernung zu ihrem Ursprung haben. Die Punkte innerhalb einer Wellenfront befinden sich also im gleichen Schwingungszustand, d. h. sie schwingen in gleicher Phase.

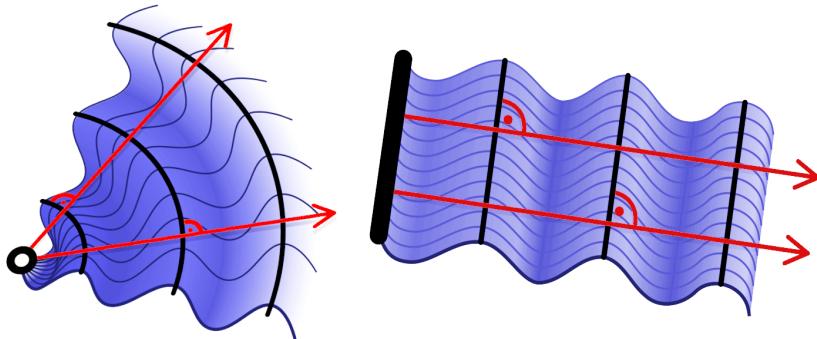


Abbildung 3.6: Beispiele für Transversalwellen. Links: kreisförmige Wellenfront (schwarz) mit radialer Ausbreitungsrichtung (rot); rechts: gerade Wellenfront (schwarz) mit geradliniger Ausbreitungsrichtung (rot).

Der Zusammenhang zwischen einer Wellenfront $W(\vec{x})$ und der Phase $\phi(\vec{x})$ lässt sich für jeden Ort \vec{x} in der (2-D) Pupillenebene folgendermaßen ausdrücken:

$$W(\vec{x}) = \frac{\lambda}{2\pi} \cdot \phi(\vec{x}) \quad \Longleftrightarrow \quad \phi(\vec{x}) = \frac{2\pi}{\lambda} \cdot W(\vec{x}) \quad (3.30)$$

3.4.3 Phasoren

Eine Sinusfunktion kann auch über ihren *Phasor* (eigentlich *Phasenvektor*, auch *komplexe Amplitude*) beschrieben werden. Es handelt sich dabei um eine komplexe Konstante, die von der Amplitude und der Phase abhängig ist. Genauer wird der Term $Ae^{i\theta}$ als Phasor einer Sinusfunktion der Form $A \cos(\omega t + \theta) + i \cdot A \sin(\omega t + \theta)$ bezeichnet, mit Amplitude A , Kreisfrequenz ω und Phase θ . Unter Verwendung der *Eulerschen Formel* ($e^{i\alpha} = \cos \alpha + i \cdot \sin \alpha$) lässt sich somit schreiben:

$$A \cos(\omega t + \theta) + i \cdot A \sin(\omega t + \theta) = Ae^{i(\omega t + \theta)} = Ae^{i\theta} \cdot e^{i\omega t} \quad (3.31)$$

3.4.4 Elektrische Feldstärke E

Die *elektrische Feldstärke* E ist definiert für den Ort \vec{r} und die Zeit t wie folgt:

$$E(\vec{r}, t) = a(\vec{r}) \cdot e^{i(\omega t - \vec{k}\vec{r})} \quad (3.32)$$

Dabei bezeichnen a (bzw. a^2) die Intensität, ω die Frequenz und $\vec{k}\vec{r}$ die Phase, wobei \vec{k} die Ausrichtung angibt, die für die Polarisation und die Form der Wellenfront verantwortlich ist. Insbesondere entspricht $\|\vec{k}\|$ der Wellenzahl k .

3.4.5 Bildentstehung

Der 3-D Objektraum wird mithilfe eines EO-Kamerasystems auf die 2-D Bildebene abgebildet, wobei räumliche Informationen durch diese Projektion verloren gehen. Genauer fällt das Licht, welches von den beobachteten Objekten ausgeht, durch die Optik auf den in der Bildebene der Kamera befindlichen Sensor bzw. Detektor und wird in ein 2-D digitales Signal umgewandelt. Hierzu werden die eintreffenden Photonen in den einzelnen Detektorelementen erfasst und je nach ihrer Anzahl in entsprechende "Bins" eingeordnet, die jeweils Intensitätswerten innerhalb eines vorgegebenen Wertebereichs (i. A. 8-Bit Kodierung mit 256 Grauwerten) entsprechen. Das 2-D Signal, das man letztlich erhält, ist eine Matrix-Repräsentation der beobachteten Szene, d. h. das eigentliche *Bild*.

Mathematisch kann ein solches Bild als vektorielle Funktion $g : \mathbb{R}^2 \rightarrow \mathbb{R}^d$ formuliert werden, die jeder (2-D) Position $\vec{x} \in \Omega_g$ im Bild einen *Bildwert* $\vec{y} = g(\vec{x})$ zuordnet:

$$g : \Omega_g \longrightarrow \mathbb{R}^d, \quad \Omega_g \subseteq \mathbb{R}^2 \quad (3.33)$$

$$g(\vec{x}) = \begin{pmatrix} g_1(\vec{x}) \\ g_2(\vec{x}) \\ \vdots \\ g_d(\vec{x}) \end{pmatrix} \quad \text{mit} \quad \vec{x} = \begin{pmatrix} x \\ y \end{pmatrix} \quad (3.34)$$

Die Zahl $d \in \mathbb{N}$ gibt hier die Zahl der Farbkanäle an, d. h. im Fall von Grauwertbildern ist $d = 1$ und bei RGB-Farbbildern ist $d = 3$.

3.4.6 PSF, OTF und MTF

Bislang wurde die Punktabbildungsfunktion vornehmlich als Filterfunktion der Atmosphäre betrachtet (siehe Abschnitt 5.1). Genau genommen beschreibt die PSF jedoch die Systemantwort auf einen Dirac-Impuls, wobei der Begriff "System" sehr allgemein zu verstehen ist und sowohl sämtliche im Einsatz befindliche Sensorik als auch die aktuell vorherrschenden atmosphärischen Eigenschaften beinhaltet.

Neben der PSF sind auch die *optische Transferfunktion* (OTF), und die *Modulationstransferfunktion* (MTF) wichtige Kenngrößen zur Beschreibung der Abbildungsqualität optischer Systeme. Genauer handelt es sich bei der OTF um die Fouriertransformierte der PSF, d. h. eine komplexwertige Funktion, die das Verhalten eines abbildenden Systems als Funktion der Ortsfrequenz beschreibt. Es gilt also:

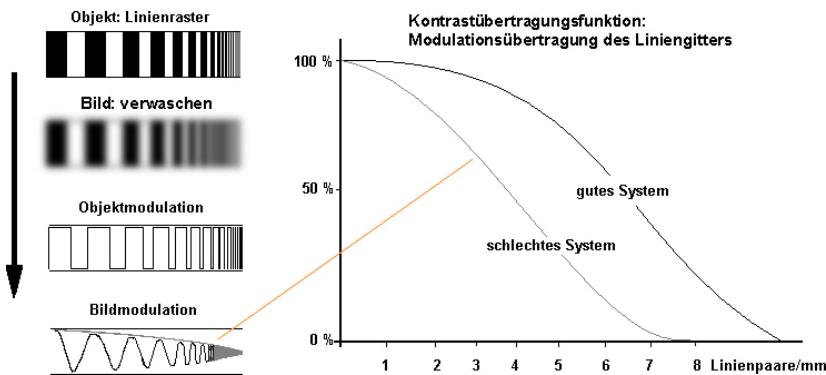
$$\text{OTF}(f) = \mathcal{F}(\text{PSF}(r)) \quad (3.35)$$

Die (reellwertige) MTF ist wiederum definiert als Absolutbetrag der OTF und entspricht der Amplitudenantwort des optischen Systems auf Sinusschwingungen unterschiedlicher Ortsfrequenzen. Mithilfe der MTF lässt sich der relative Kontrast beschreiben, d. h. die Dämpfung der Modulation bei zunehmender Frequenz, weshalb die MTF auch als Kontrastübertragungsfunktion bezeichnet wird. Der Kontrastverlust wird dabei durch das Verhältnis von Objekt- zu Bildmodulation beschrieben, d. h.

$$\text{MTF}(f) = |\text{OTF}(f)| = \frac{\text{Bildmodulation}(f)}{\text{Objektmodulation}(f)} \quad (3.36)$$

In diesem Zusammenhang bezieht sich *Modulation* zunächst nur auf die Veränderung eines Signals durch ein bildgebendes System. Aber auch Veränderungen durch atmosphärische Störeinflüsse, speziell Turbulenz, lassen sich mithilfe ihrer zugehörigen MTF charakterisieren.

Das Beispiel in Abbildung 3.7 zeigt wie das Linienmuster des Objekts unscharf abgebildet wird und mit zunehmender Frequenz an Kontrast verliert, so dass höhere Frequenzen gar nicht mehr aufgelöst werden können. Dadurch wird aus der rechteckigen Signalform des Objekts ein sinusförmiges Signal, dessen Amplitude immer stärker gedämpft wird.

Abbildung 3.7: Grafische Darstellung der MTF⁸

3.4.7 Die Pupillenfunktion P

Die *Pupillenfunktion* P ist eine komplexe Funktion, mit deren Hilfe sich die relativen Änderungen der Amplitude und Phase einer Lichtwelle bei der Durchquerung eines abbildenden optischen Systems beschreiben lassen. Sie ist ganz allgemein definiert durch:

$$P(\vec{r}) = A(\vec{r}) \cdot e^{i\Theta(\vec{r})} \quad (3.37)$$

Hier bezeichnen \vec{r} einen Vektor in der Pupillenebene, A die Amplitude der einfallenden Lichtwelle und Θ die Phasenänderungen, wobei sämtliche Einflüsse zusammengefasst sind, die zwischen der Fokal- und der Bildebene auf die Phase der Lichtwelle einwirken.

Mit der Gleichung (3.30) kann P auch über die Wellenfront W beschrieben werden:

$$P(\vec{r}) = e^{i k W(\vec{r})} \quad (3.38)$$

Insbesondere kann die kreisförmige Apertur einer Optik mit Durchmesser D

⁸ Quelle: Wikipedia https://commons.wikimedia.org/wiki/File:MBq_MTF.jpg

mithilfe der Pupillenfunktion eines idealen Systems P_0 beschrieben werden. Die Amplitude und Phase bleiben in einem solchen System unverändert, so dass P nur angibt, wo Licht durchgelassen wird und wo nicht:

$$P_0(\vec{r}) = \begin{cases} 1, & \|\vec{r}\| \leq D/2 \\ 0, & \|\vec{r}\| > D/2 \end{cases} \quad (3.39)$$

Im Fall eines diffraktionslimitierten optischen Systems kann die Phasenänderung $\Theta(\vec{r})$ als Zufallsvariable im Punkt \vec{r} interpretiert werden. Wenn $l(\vec{r})$ die zufälligen Fluktuationen des Logarithmus der Amplitude bezeichnet (wobei ohne Beschränkung der Allgemeinheit angenommen werden kann, dass die Amplitude der einfallenden Welle ohne Störeinflüsse gleich Eins ist), dann lassen sich die Amplituden- und Phasenfluktuationen gemäß [Fri66] in einer komplexen Größe U zusammenfassen wie folgt:

$$U(\vec{r}) = P(\vec{r}) \cdot e^{l(\vec{r}) + i\Theta(\vec{r})} \quad (3.40)$$

3.4.8 Optische Auflösung

Die optische bzw. räumliche *Auflösung* eines abbildenden Systems entspricht der minimalen Distanz d , die zwei nebeneinanderliegende Punktobjekte voneinander haben müssen, um in einer Abbildung dieses Systems noch als separate Objekte wahrnehmbar zu sein.

Die Auflösungsgrenze d ist gegeben durch:

$$d = 0,61 \cdot \frac{\lambda}{A_n} \quad \text{mit} \quad A_n = n \cdot \sin \alpha \quad (3.41)$$

A_n beschreibt die sogenannte *numerische Apertur*, welche über den Brechungsindex n des Materials zwischen Fokus und Linse und über den halben (objektseitigen) Öffnungswinkel α des Objektivs definiert ist.

Insbesondere besagt das *Rayleigh-Kriterium*, dass zwei punktförmige Lichtquellen als zwei verschiedene Objekte erkannt werden können, wenn das Zentrum der Airy-Disk des einen Objekts mindestens so weit vom Zentrum der Airy-Disk des anderen Objekts entfernt ist, wie dessen erste Nullstelle.

3.4.9 Limitierende Einflüsse

Es lassen sich grundsätzlich drei Fälle unterscheiden, die einen limitierenden Einfluß auf die Abbildungsqualität eines bildgebenden Systems haben:

1. Turbulenzlimitierung
2. Beugungsbegrenzung
3. Detektorlimitierung

In den Fällen 1 und 2 lassen sich näherungsweise passende PSFs berechnen, mit deren Hilfe sich erfasste Bilddaten korrigieren lassen (geeignete Methoden finden sich in den Kapiteln 5 und 6), wobei Verfahren zur Reduktion der Turbulenzlimitierung das zentrale Thema dieser Arbeit ist.

Im Fall 3, d. h. bei einer Limitierung seitens des Detektors befindet sich die Leistungsfähigkeit des Systems hingegen bereits an der äußersten Grenze. Mit herkömmlichen Methoden können deshalb keine zusätzlichen Verbesserungen erzielt werden, da die Bildqualität weder durch die Optik noch Turbulenz beeinträchtigt ist.

Die Faktoren λ/D und λ/r_0 können zur Fallunterscheidung eingesetzt werden, um die Art der bestehenden Limitierung festzustellen. Der detektorlimitierte Fall tritt z. B. ein, falls die folgende Bedingung erfüllt ist:

$$\text{IFOV} > \frac{1}{2} \frac{\lambda}{D} \quad \text{und} \quad \text{IFOV} > \frac{1}{2} \frac{\lambda}{r_0} \quad (3.42)$$

Der diffraktionslimitierte Fall tritt ein, falls

$$\text{IFOV} < \frac{1}{2} \frac{\lambda}{D} \quad \text{und} \quad \frac{\lambda}{D} > \frac{\lambda}{r_0} \quad (3.43)$$

Falls keine der beiden Bedingungen erfüllt ist, tritt der turbulenzlimitierte Fall ein.

Die Abbildung 3.8 zeigt beispielhafte Simulationen für diese drei Fälle (Originalbild in Abbildung 6.42 im Abschnitt 6.9.3).



Abbildung 3.8: Beispielhafte Simulation der limitierenden Einflüsse auf die Bildgebung. Links: Beugungsbegrenzung; Mitte: Detektor-Limitierung; rechts: Turbulenzlimitierung. (Simulationen: S. Gladysz)

3.4.10 Systembedingte Einflüsse auf die Bildqualität

Zusätzlich zu atmosphärischen Einflüssen können auch systembedingte Abbildungsfehler die Qualität erfasster Bilddaten beeinträchtigen. Dies betrifft hauptsächlich Fehler in den verwendeten Optiken, vor allem durch fehlerhafte Linsen (z. B. Unregelmäßigkeiten, Verzeichnungen), sowie Detektorbedingte Probleme, speziell aufgrund geringer Größe (relativ zur Optik) und hoher Pixeldichte. Aber auch die Umgebung spielt eine Rolle, da Sensorrauschen beispielsweise durch schlechte Lichtverhältnisse oder auch hohe Umgebungstemperaturen noch verstärkt wird.

Verzeichnungen der Optik

Je nach Art und Qualität der verwendeten Linsen können bei der Bildgewinnung verschiedene Verzeichnungen auftreten. Dies kann durchaus gewollt sein, wie z. B. im Fall von Fischaugen- oder Shift-Objektiven, systembedingt wie z. B. Vignettierung oder aber ungewollt wie im Fall von Linsenfehlern. Die Abbildung 3.9 zeigt einige Beispiele für verschiedene optische Verzeichnungen, wie z. B. Simulationen einer Tonnen- ("barrel") und Kissenverzeichnung ("pincushion"), sowie eines Fischaugenobjektivs.

Im Gegensatz zu Linsentrübungen oder Unebenheiten lässt sich diese Art von Verzeichnung verhältnismäßig leicht korrigieren, während sich Abbildungsfehler wie z. B. sphärische oder chromatische Aberrationen nur eingeschränkt vermeiden lassen.

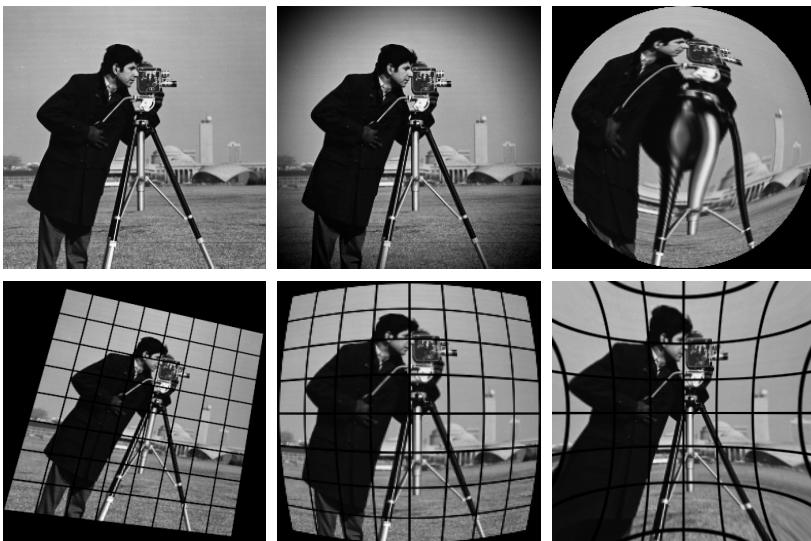


Abbildung 3.9: Simulierte Beispiele für typische Optik-Verzeichnungen.
Obere Reihe (v.l.n.r.): unverzerrtes Originalbild, Vignette-Effekt, Fischaugen-objektiv; untere Reihe (v.l.n.r.): perspektivische Verzeichnung, Tonnen- und Kissenverzeichnung

Aus praktischen Erwägungen wird im weiteren Verlauf angenommen, dass die Abbildungseigenschaften der verwendeten Optiken stets einwandfrei sind, da etwaige Linsenfehler ggfs. als Bestandteil der atmosphärischen Filterfunktion behandelt (und korrigiert) werden können.

“Interlacing”

Des weiteren können Effekte wie “Interlacing” oder “Rolling-Shutter” auftreten. Die Abbildung 3.10 zeigt ein Beispiel dafür, wie sich speziell die Effekte des Zeilensprungverfahrens im Turbulenzfall noch verstärken. Das hat auch entsprechende Auswirkungen auf Algorithmen zur Turbulenzkorrektur wie insbesondere in [Lou13] zu bemerken ist.

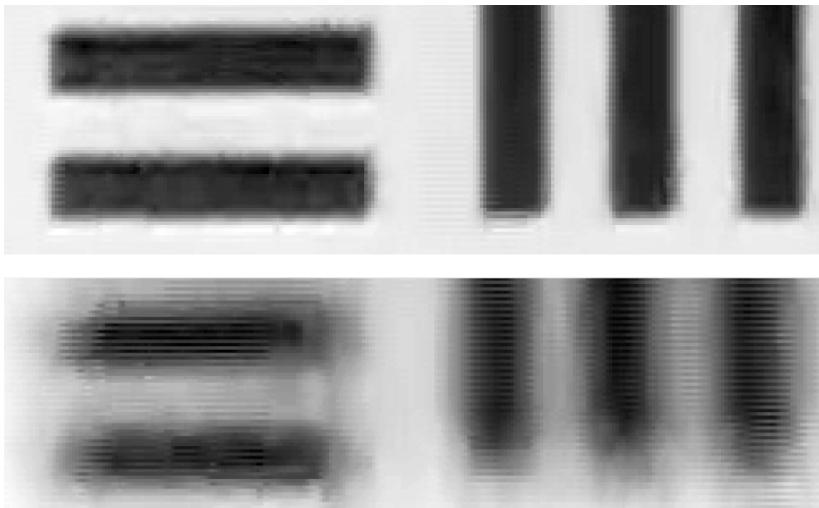


Abbildung 3.10: Beispiel für “Interlacing”-Effekte. Oben: Bildausschnitt ohne Turbulenz; unten: mit Heizgerät künstlich erzeugte Turbulenz.

In solchen Fällen sollte vor Anwendung einer Turbulenzkorrektur zusätzlich noch ein Deinterlacing durchgeführt werden, um diese Effekte zu minimieren. Häufig geschieht dies bereits anhand einer speziellen Kamera-Software des Herstellers. So sind in den Daten, die hier verwendet wurden, keine nennenswerten Interlacing-Effekte zu beobachten.

“Rolling-Shutter”-Effekte sind dagegen bedeutend schwieriger zu identifizieren, da es im Turbulenzfall nicht ohne weiteres möglich ist, zwischen Bildverzerrungen aufgrund von Turbulenz und Verzerrungen aufgrund der Aufnahmetechnik zu unterscheiden. Dies näher zu untersuchen, würde den Rahmen dieser Arbeit sprengen, insbesondere, da die konkrete Ursache für Bildverformungen für die hier vorgestellten Algorithmen letztlich unerheblich ist.

Bildrauschen

Unter dem Begriff *Bildrauschen* (bzw. “Image Noise”) lassen sich mehrere technisch bedingte Effekte zusammenfassen, die Einfluss auf die elektro-optische Bilddatengewinnung nehmen. Im Hinblick auf Turbulenz sind in diesem Zusammenhang grundsätzlich dieselben Arten von Rauschen zu erwarten, wie sie auch ohne Turbulenz auftreten.

Sogenanntes *Schrotrauschen* (“Shot Noise”) tritt z. B. durch die Messung einzelner Photonen auf und lässt sich über eine Poisson-Verteilung modellieren, die das Auftreten von unabhängigen Zufallsereignissen beschreibt. Mit zunehmender Anzahl gemessener Photonen nähert sich diese Poisson-Verteilung einer Normalverteilung an. Sogenanntes *Dunkelrauschen* ist dagegen unabhängig von einfallendem Licht und kann auf elektronische, aber auch auf thermische Effekte zurückgeführt werden, d. h. es wird durch hohe Detektortemperaturen noch verstärkt. Insbesondere lässt sich diese Art Rauschen mithilfe einer Gauß-Normalverteilung modellieren. Neben Schrot- und Dunkelrauschen gibt es noch eine weitere Noise-Arten, die durch die Aufnahme- und Auslesetechnik verursacht werden, wie z. B. zufällige Bitfehler, die bei der Datenübertragung auftreten, oder Ausleserauschen (“Readout Noise”), welches hauptsächlich durch den Ausleseverstärker verursacht wird. Hinzu kommt periodisches Rauschen, welches z. B. durch elektrische oder elektromechanische Störungen während der Bildaufnahme verursacht wird, sowie sogenanntes “Fixed Pattern Noise”, wobei es sich um ein spezifisches Rauschmuster des Sensor-Arrays handelt, welches aufgrund unterschiedlicher Empfindlichkeiten der einzelnen Pixel entsteht (bei identischer) Beleuchtung. In diesem Zusammenhang sollten auch noch Pixelfehler auf dem Detektor erwähnt werden, speziell tote Pixel (“dead pixel”), die immer dunkel sind, oder überempfindliche Pixel (“hot pixel”), sowie Pixel, die immer dieselbe (maximale) Intensität anzeigen (“stuck pixel”).

Die Abbildung 3.11 zeigt einige Beispiele für besonders häufig vorkommende bzw. markante Rauscharten, wobei das jeweilige Rauschen simuliert wurde. Die Unterschiede sind ohne Vergrößerung nicht unbedingt auf den ersten Blick erkennbar. Ein Vergleich speziell der grauen, sowie der dunklen Bildregionen verdeutlicht die Unterschiede.

Je nach Anwendungsbereich können allerdings auch andere Rauschtypen an Signifikanz gewinnen. So tritt Chromianzrauschen (bzw. Farbrauschen)

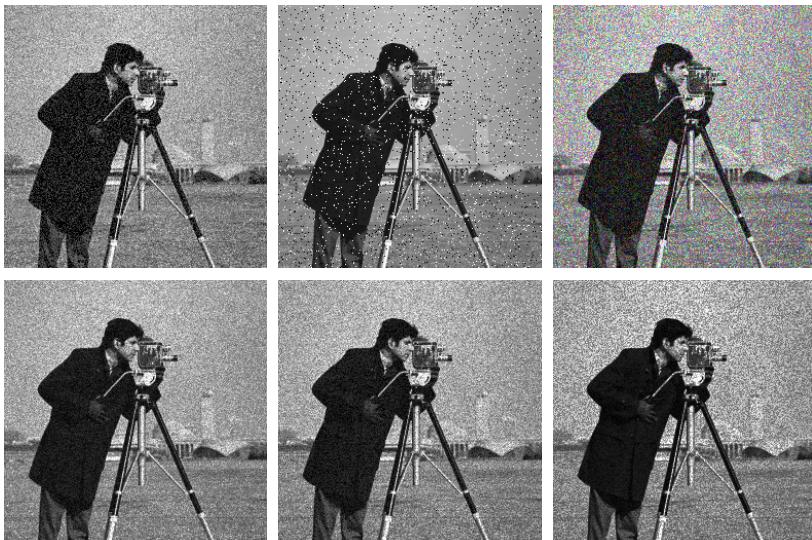


Abbildung 3.11: Simulationsbeispiele häufig vorkommender Rauschtypen.
Obere Reihe (v.l.n.r.): Gauss-verteiltes Rauschen, Salz-und-Pfeffer Rauschen, Farbrauschen; untere Reihe (v.l.n.r.): Poisson-verteiltes Rauschen, Gauss-verteiltes Rauschen mit lokaler Varianz, Speckle-Rauschen

nur auf, wenn mehrere Farbkanäle vorhanden sind. Zudem gibt es spezielle Farbkameras, bei denen ein einzelner Farbkanal (z. B. der blaue Kanal) mehr verstärkt wird als die anderen, so dass dieser Kanal entsprechend auch mehr Rauschen aufweisen kann. Aufgrund der Wellenlängendifferenzen zwischen den einzelnen Kanälen, kann es insbesondere infolge von Turbulenz zu einer Verstärkung des Farbrauschen kommen.

Des Weiteren ist die Sensorik thermischer Bildgeber, neben "normalem" Bildrauschen, auch sehr anfällig für systematisches Rauschen in Form von starker Streifenbildung, z. B. verursacht durch das mechanische Abtastsystem älterer 2-D Spiegelscanner, sowie für ganze Cluster von benachbarten toten sowie heißen Pixeln. Wenngleich moderne IR-Systeme inzwischen bereits von Herstellerseite mit entsprechenden Korrekturmethoden ausge-

stattet sind, kann zusätzlich eine spezifische Rauschreduktion erforderlich sein, da es ansonsten bei der Anwendung von Verfahren zur Turbulenzkorrektur zu einer übermäßigen Rauschverstärkung kommen kann.

An dieser Stelle sollte noch erwähnt werden, dass von der EMVA zur Vereinheitlichung von Messverfahren und der Datendarstellung der Standard 1288⁹ definiert wurde, um Vergleiche von Kameras und Bildsensoren zu erleichtern. Dies schließt insbesondere auch die Spezifikation der Rauschcharakteristiken solcher Geräte mit ein.

⁹ <https://www.emva.org/standards-technology/emva-1288/>

4

Bewegungskompensation

Die meisten der existierenden Bildverarbeitungsmethoden zur Turbulenzkorrektur zielen nach wie vor ausschließlich auf die Verarbeitung von statischen Szenen ab. Dennoch besteht ein zunehmendes Interesse daran, diese Methoden so zu modifizieren, dass auch bewegte Objekte berücksichtigt werden können. Das bedeutet allerdings, dass auch Bewegungsunschärfe auftreten und die Bildqualität beeinträchtigen kann.

Im Umgang mit atmosphärisch gestörten und verrauschten Daten ist es beinahe unvermeidlich, zur Reduzierung dieser Störungen irgendeine Form der Mittelwertbildung anzuwenden. Infolgedessen ist die Bildstapelung zu einem integralen Bestandteil diverser Turbulenzkompensationsverfahren geworden. Das bedeutet allerdings auch, dass jede Bewegungsunschärfe (real oder durch die Mittelung erzeugt) proportional zur Anzahl der gestapelten Bilder verstärkt wird. Dadurch kann eine Art "Geistereffekt" auftreten wie das Beispiel in der Abbildung 4.1 demonstriert. Darin sind das erste und letzte Bild einer Reihe von 150 Frames abgebildet, die den Beginn und das Ende einer Bewegung zeigen, sowie der Durchschnitt der 150 Frames, worin die Person in Bewegung (rechts im Bild) transparent zu sein scheint. Nicht zuletzt daran lässt sich die besondere Bedeutung erkennen, die der Verwendung von Bewegungsdetektion und Bewegungsschätzung zur Bewegungskompensation im Zusammenhang mit Turbulenzkorrekturverfahren zukommt.



Abbildung 4.1: Beispiel für den “Geistereffekt”, der durch Bewegung bei der Mittelwertbildung entsteht. Links u. Mitte: Einzelbilder von Anfang bis Ende des Bewegungsablaufs; rechts: zugehöriger Mittelwert (150 Frames)

4.1 Situationsabhängige Bewegung

Im Kontext turbulenzgestörter Bildaufnahmen können grundsätzlich die folgenden vier Situationen unterschieden werden:

1. Statischer Beobachter, statische Szene.
2. Dynamischer Beobachter, statische Szene.
3. Statischer Beobachter, dynamische Szene.
4. Dynamischer Beobachter, dynamische Szene.

Der “Beobachter” entspricht hier dem beobachtenden bzw. bildgebenden Sensorsystem, z. B. einer Kamera. Entsprechend bezieht sich der “statische” Beobachter auf eine unbewegliche Kamera, die z. B. auf einem Stativ steht, ebenso wie sich der “dynamische” Beobachter auf eine bewegte Kamera bezieht, die z. B. schwenkt oder von Hand geführt wird.

Bei der “Szene” handelt es sich demgemäß um die vom Sensorsystem erfasste 2-D Projektion der real beobachteten dreidimensionalen Umgebung mit statischem oder dynamischem Bildinhalt. Diese Szene wird als dynamisch bezeichnet, sofern sie ein oder mehrere bewegte Objekte enthält.

4.1.1 Bewegungsdetektion

Bei der *Bewegungsdetektion* in Bilddaten geht es um die Segmentierung von Vorder- und Hintergrund, d. h. um die grundsätzliche Unterteilung der abgebildeten Szene in dynamische Elemente (Vordergrund) und in statische Elemente (Hintergrund). Im Kontext der Turbulenzkorrektur bedeutet dies, dass statische und dynamische Bildelemente separat behandelt und korrigiert werden können, z. B. indem unterschiedliche Parameter verwendet werden oder auch verschiedene Methoden angewendet werden.

Jede Bewegung verursacht Änderungen zwischen aufeinanderfolgenden Bildern einer Sequenz. Bei der "Kamerabewegung" handelt es sich ausschließlich um Bewegungen auf globaler Ebene, welche zu Änderungen des gesamten Bildes führen. Individuelle "Objektbewegung" beschreibt dagegen in erster Linie Bewegungen auf lokaler Ebene, so dass es nur zu Änderungen einzelner Bildbereiche kommt. Vorausgesetzt ist hier, dass die Objektgröße (in der Bildebene) kleiner als die Bildgröße ist. "Turbulenzbewegung" bezieht sich wiederum auf die scheinbaren Bewegungen, welche aufgrund optischer Turbulenz wahrgenommen werden. In Abhängigkeit von der vorliegenden Turbulenzstärke können sich diese Bewegungen sowohl global als auch lokal auswirken. Es lassen sich also drei Hauptbewegungstypen unterscheiden:

- Kamerabewegung
- Objektbewegung
- Turbulenzbewegung

Situation 1

Die Situation 1 beschreibt den einfachsten Fall, da weder globale Szenenänderungen noch individuelle Objektbewegung zu erwarten sind. Stattdessen wird jede wahrnehmbare Bewegung durch optische Turbulenzeffekte verursacht, wobei das Ausmaß dieser Bewegung von der vorherrschenden Stärke der Turbulenz abhängt. Dieser Fall wird von allen bekannten Verfahren zur Turbulenzkorrektur abgedeckt.

Situation 2

Zur Einschätzung des Schwierigkeitsgrades der Situation 2 kommt es auf die Art der Kamerabewegung an. Die gleichmäßige Translationsbewegung eines langsam schwenkenden Systems (“Panning”) ist z. B. vergleichsweise gutartig. Mittels globaler Bildregistrierung aufeinanderfolgender (größtenteils überlappender) Frames lässt sich dieser Fall innerhalb eines Zeitfensters, das durch die Geschwindigkeit der Schwenkbewegung limitiert ist (und die gewählte Pufferlänge), gewissermaßen auf die Situation 1 zurückführen. Wird die Geschwindigkeit zu hoch, wird das Zeitfenster (und damit der Überlappungsbereich) für eine effektive Turbulenzkorrektur allerdings zu klein. In begrenztem Umfang ist eine solche Korrektur dennoch möglich, z. B. in Form einer Einzelbildkorrektur. Kommt es außerdem auch noch zu Bewegungsunschärfe aufgrund der Kamerabewegung, wird das Korrekturergebnis zusätzlich beeinträchtigt. Handelt es sich speziell um eine regelmäßige Hin- und Herbewegung (“Swivelling”) kann mittels “Stitching” sogar ein Mosaik des gesamten abgebildeten Bereichs zusammengesetzt und so das Problem wiederum in die Situation 1 überführt werden.

Im Falle unvorhersehbarer Kamerabewegungen, z. B. durch Schütteln oder ruckartige Bewegungen einer von Hand geführten Kamera, sieht es wieder anders aus. Neben globalen Translationsbewegungen müssen auch noch Rotation und Skalierungs- sowie Schereffekte (d. h. nicht-lineare Translation) mit berücksichtigt werden. Hinzu kommt, dass Aufnahmen dieser Art in der Regel von geringer Qualität und Aussagekraft sind und durch eine Turbulenzkorrektur kaum an Informationsgehalt gewinnen würden. Der Aufwand würde den möglichen Gewinn bei weitem übersteigen, daher wird dieser Spezialfall im Rahmen dieser Arbeit auch nicht explizit behandelt.

Situation 3

Ein typisches Anwendungsszenario für die Situation 3 entspricht einem statischen Sensorsystem, mit dem über eine größere Entfernung ein oder mehrere bewegte Objekte beobachtet werden, z. B. Personen oder Fahrzeuge. Dies bedeutet, dass nur mit Bewegungen auf lokaler Ebene zu rechnen ist, wobei die wesentliche Aufgabe darin besteht, gerichtete lokale Objektbewe-

gungen von ungerichteten lokalen Turbulenzbewegungen zu unterscheiden. Auf diesen Anwendungsfall richtet sich das Hauptaugenmerk dieser Arbeit.

Situation 4

Die Situation 4 ist natürlich die komplexeste von allen, da hier drei Bewegungsarten zugleich zu berücksichtigen (und insbesondere voneinander zu trennen) sind. Wie bereits in der Situation 2 kann ein Verfahren zur Turbulenzkorrektur auch hier nur dann sinnvoll eingesetzt werden, wenn es sich bei der Kamerabewegung im Wesentlichen um eine nicht zu schnelle Translationsbewegung handelt, so dass Kamera- und Objektbewegungen separierbar sind.

4.1.2 Bewegungsschätzung

Bei der *Bewegungsschätzung* geht es darum, Bewegungsvektoren zu extrahieren, mit deren Hilfe sich ein Bild in ein anderes transformieren lässt. Üblicherweise handelt es sich dabei um aufeinanderfolgende Einzelbilder einer Videosequenz. Diese Aufgabe ist ein im mathematischen Sinn schlecht gestelltes Problem, da es sich bei Bildern um 2-D Projektionen der realen 3-D Welt handelt. Entsprechend lassen sich Bewegungsvektoren nie wirklich exakt berechnen, weshalb man i. A. von Bewegungsschätzungen anstelle von Berechnungen spricht.

Bewegungsvektoren können einerseits eine globale Bewegung des gesamten Bildes beschreiben oder aber nur die lokale Bewegung einzelner Bildelemente. Sogenannte "Block Matching" (BM)-Algorithmen (siehe auch Abschnitt 4.2) unterteilen Bilder beispielsweise in gleichgroße (typischerweise quadratische) Pixelblöcke, wobei es theoretisch auch möglich ist, ganz willkürliche Formen zu verwenden oder sogar einzelne Pixel. Generell lassen sich Verfahren zur Bewegungsschätzung in zwei Hauptkategorien einteilen: *indirekte merkmalsbasierte Methoden* und *direkte Methoden*.

Beim *merkmalsbasierten Ansatz* wird zunächst separat für jedes Bild eines Bildpaares eine Menge von charakteristischen Punkten bestimmt, z. B. unter Verwendung des "Harris Corner"-Detektors. Korrespondenzen zwischen den Punktmenzen, und damit entsprechend auch zwischen den Bildern, werden unter Ausnutzung der statistischen Eigenschaften der Punkte und

ihrer lokalen Umgebung hergestellt. Ein Überblick über merkmalsbasierte Methoden findet sich in [Tor00].

Direkte Methoden zur Bewegungsdetektion stützen sich im Allgemeinen auf die Unterschiede zwischen zwei oder mehreren aufeinanderfolgenden Bildern. Hierbei werden pixelbasierte Fehlermaße eingesetzt und für jedes Pixel eine Korrespondenz bestimmt. Damit eng verwandt ist das Konzept des "Optischen Flusses" (OF), bei dem Bewegungsvektoren der wahrgenommenen Pixelbewegung entsprechen. Verfahren zur OF-Bestimmung können zu den direkten Methoden gezählt werden ebenso wie BM-Verfahren. Eine allgemeine Übersicht über direkte Methoden findet sich in [Ira00], während [Hor81] eine genauere Beschreibung des OF-Konzeptes bietet.

4.1.3 Abhängigkeit vom Szeneninhalt

Algorithmen zur Kompression von Videodaten, wie z. B. die im nächsten Abschnitt beschriebenen BM-Algorithmen, speichern nicht jedes Bild einer Sequenz einzeln, sondern detektieren und codieren lediglich die Änderungen (und speziell Bewegungen) zwischen aufeinanderfolgenden Frames. Dazu müssen sie Veränderungen aller Art berücksichtigen, d.h. nicht nur Objekte, die sich bewegen, sondern auch Kamerabewegungen und Änderungen des Hintergrunds müssen einbezogen werden. Die Abbildung 4.2 zeigt die verschiedenen Fälle, die auftreten können mit aufsteigendem Komplexitätsgrad, wobei (a) der einfachste Fall ist, da keinerlei Änderungen vorliegen, und (e) der komplexeste, da bei einem Szenenwechsel das gesamte Bild neu codiert werden muss.

Die Bewegungsvektoren selbst sind bei diesen Algorithmen von untergeordneter Bedeutung. Beim Objekttracking ist dies dagegen ganz anders, denn hier sind es hauptsächlich die Bewegungen der einzelnen Objekte, die interessieren. Alles andere, d.h. der Hintergrund, geringfügige Kamerabewegungen ebenso wie vernachlässigbare, kleinere Bewegungen (z. B. verursacht durch Regen, Schnee, fallende Blätter, etc., und insbesondere auch durch atmosphärische Turbulenz) muss wie Rauschen herausgefiltert werden. Entsprechend gibt es eine ganze Anzahl von potentiellen Schwierigkeiten für jede Art von Bewegungsdetektions- und Trackingalgorithmen, von denen die wesentlichen die folgenden sind:

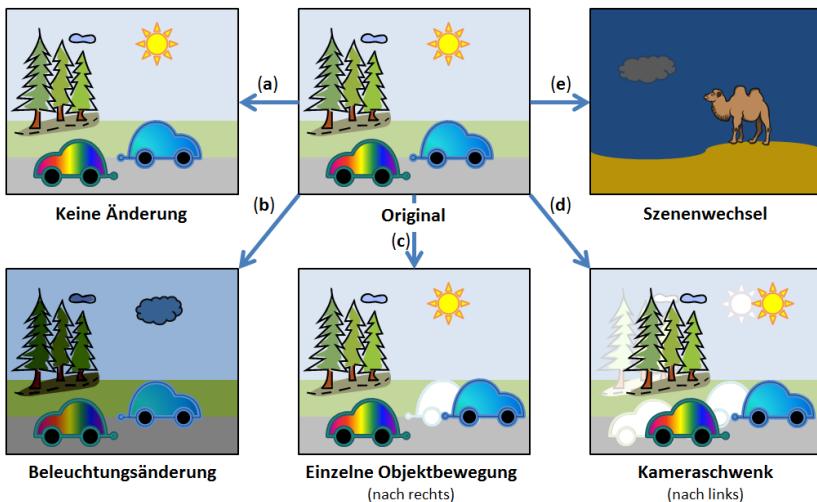


Abbildung 4.2: Mögliche Szenarien in Videosequenzen

- Okklusion, d. h. vollständige oder Teilverdeckung von einem oder mehreren Objekten (möglicherweise gegenseitig)
- Verschwindende Objekte, die sich z. B. aus dem Bild heraus bewegen
- Neue Objekte, die sich z. B. erst in das Bild hinein bewegen
- Objekte, die ihre Form verändern, z. B. weil sich der Aspektwinkel zwischen Objekt und Beobachter verändert
- Objekte, die als Hintergrund erscheinen, z. B. weil sie sich nicht oder nur wenig vom Hintergrund unterscheiden (ähnliche Farbe, Form, etc.)
- Objekte, die als Rauschen erscheinen, z. B. wenn sie sich in dunkle oder neblige Bildregionen bewegen, aber auch wenn sie (noch) zu weit entfernt und zu klein im Bild sind
- Rauschen mit ähnlichen Charakteristiken wie echte Szenenelemente, wie z. B. Regen oder Schnee

- Globale Beleuchtungsänderungen, z. B. dadurch, dass eine Wolke temporär die Sonne verdeckt oder eine Lichtquelle in der Szene ein- oder ausgeschaltet wird
- Lokale Beleuchtungsänderungen, z. B. weil sich Lichtreflexionen an der Oberfläche eines Objekts aufgrund von Bewegungen des Objekts (oder der Lichtquelle) ändern können
- Das sogenannte *Aperture-Problem* tritt in homogenen Bildbereichen auf, wenn diese größer sind als die (Teil-)Fläche (z. B. ein Block), für die eine Bewegung bzw. Änderung ermittelt werden soll

Inzwischen wurden zahlreiche mehr oder weniger anspruchsvolle Verfahren entwickelt, insbesondere in der Robotik oder für Überwachungs- und Aufklärungsaufgaben, die eine solche Analyse des vorliegenden Szeneninhalts einschließen und in der Lage sind, diverse dieser limitierenden Faktoren, wenn auch nicht alle, zu überwinden. Allerdings ist es solchen Algorithmen nur dann möglich, die Änderungsinformationen in Form von (geschätzten) Bewegungsvektoren korrekt zu interpretieren und ggf. ein Modell der sichtbaren Szene zu erstellen, falls einerseits hinreichendes a priori Wissen über den vorliegenden Szeneninhalt verfügbar ist und andererseits bestimmte Annahmen getroffen werden können, welche die limitierenden Faktoren signifikant einschränken können. A priori Wissen über Szeneninhalt kann beispielsweise bedeuten, dass ein Roboter sich nur innerhalb von Büroräumen bewegt, in denen z. B. der Boden ein bekanntes Muster aufweist, das bei der Navigation helfen kann. In diesem Fall ist allerdings davon auszugehen, dass atmosphärische Einflüsse weder bei der Bilddatenerfassung noch bei der Datenauswertung eine Rolle spielen.

“Block Matching” (BM)-Algorithmen (s. Abschnitt 4.2) sind vergleichsweise unkompliziert und benötigen üblicherweise kein derartiges a priori Wissen. Das ist von Vorteil vor dem Hintergrund, dass die Zielsetzung hier letztendlich die Korrektur atmosphärischer Turbulenzeffekte in Bilddaten ist. Üblicherweise können für Daten, die eine solche Korrektur benötigen, in der Regel nur wenige Vorannahmen gemacht werden, wobei zumeist einige Informationen über das verwendete Sensorsystem vorliegen und gelegentlich auch Messdaten zur Schätzung der Turbulenzstärke zum Zeitpunkt der Aufnahme verfügbar sind. Das bedeutet nicht, dass zusätzliche Informatio-

nen über den vorliegenden Szeneninhalt (sofern verfügbar) nicht genutzt werden können, um das Korrekturergebnis zu verbessern. Sollten also beispielsweise die Größe eines beobachteten Objekts und die Entfernung vom Objekt zum Sensor bekannt sein, ist es u. a. möglich über die korrespondierende Größe des Objekts in der Bildebene auf eine geeignete Blockgröße für einen der BM-Algorithmen in Abschnitt 4.2 zu schließen. BM-Algorithmen können auch eingesetzt werden, um ganz grundsätzlich Objektbewegungen zu detektieren, vorausgesetzt die Eigenbewegungen der Objekte sind größer als die scheinbaren Bewegungen aufgrund atmosphärischer Turbulenz.

4.2 “Block Matching”-Algorithmen

“Block Matching” (BM)-Algorithmen sind Standardverfahren zur Kompression von Videodaten, bei denen Änderungen zwischen zwei Frames, und insbesondere wahrgenommene Bewegungen, detektiert und codiert werden. Hierzu wird ein Einzelframe typischerweise in gleichgroße quadratische (nicht überlappende) Blöcke der Größe B unterteilt. Jede Bewegung bzw. Änderung in Bezug auf den vorangegangenen Frame in der Sequenz wird blockweise detektiert. Genauer wird jeder der Blöcke über einen vorgegebenen Suchraum (auch “Search Space” genannt) von bis zu N Pixeln in jeder Richtung verschoben, so dass er bestmöglich mit dem korrespondierenden Block im nachfolgenden Frame übereinstimmt. Die jeweils resultierenden Verschiebungen werden in Form von Verschiebungsvektoren (“Shift Vectors”) bzw. Bewegungsvektoren (“Motion Vectors”) beschrieben, die aus horizontalen und vertikalen Komponenten δx bzw. δy bestehen. Hierbei ist zu beachten, dass nur Verschiebungen kleiner oder gleich der halben Blockgröße sinnvoll bestimmt werden können, d. h. es muss $N \leq B/2$ sein. Ansonsten wären nicht mehr genug Informationen im Überlappungsbereich enthalten, um diese Entscheidung treffen zu können.

Es muss auch erwähnt werden, dass sich der Einsatz von BM-Algorithmen zur Bewegungskompensation bei atmosphärischer Turbulenz in einem kleinen, aber signifikanten Punkt von der Standardanwendung (Kompression von Videodaten) unterscheidet. Es geht nicht darum, Neues mit Hilfe alter Informationen zu codieren, sondern darum Neues mit Hilfe von Vorwissen zu korrigieren. Statt die Bewegungen des vorherigen Bildes I_{i-1} in Bezug auf

das aktuelle Bild I_i zu bestimmen, werden daher die Bewegungen des aktuellen Bildes I_i in Bezug auf ein gegebenes Referenzbild R_i bestimmt. Dies geschieht, um turbulenzbedingte lokale Bildbewegungen (“Image Dancing”) zu kompensieren, bei denen sich einzelne Bildbereiche in verschiedene Richtungen bewegen. In Ermangelung von “Ground Truth” Daten, die es im Fall realer Turbulenzaufnahmen in der Regel gar nicht gibt, kann beispielsweise ein gleitender Mittelwert als Referenz R_i dienen. Je nach Anzahl der gemittelten Bilder (und Turbulenzstärke) liegt der Vorteil bei einem solchen Mittelwert darin, dass sich kleine Bildbewegungen statistisch ausmitteln, wodurch R_i potenziell korrektere Informationen über die (statische) Geometrie der abgebildeten Szene enthält als das vorherige Bild I_{i-1} . Der Nachteil liegt in der erhöhten Unschärfe. Mittelungsbedingt gehen feine Details verloren, so dass Übereinstimmungen zwischen korrespondierenden Blöcken u. U. nicht korrekt gefunden werden können.

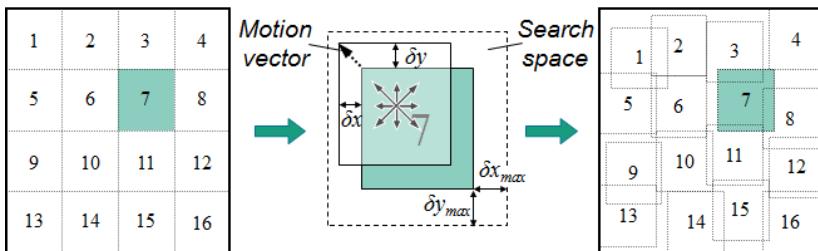


Abbildung 4.3: Illustration des “Block Matching” Grundprinzips

Abbildung 4.3 illustriert das BM-Grundprinzip mit der Neuanordnung individueller Pixelblöcke in Bezug auf ein gegebenes Referenzbild. Die Grafik lässt Bereiche erkennen, in denen mehrere Blöcke überlappen, ebenso wie Lücken, in die gar kein Block eingepasst wurde. Dementsprechend ist der Einsatz eines Interpolationsverfahrens erforderlich. Um Blockstrukturen im Endergebnis zu vermeiden, kann das BM auch als “*Sliding Neighbourhood*” Operation, d. h. mit überlappenden Blöcken, implementiert werden. Falls die entsprechend hohe Berechnungsdauer unerwünscht sein sollte, besteht auch die Möglichkeit Hamming-Windows o. Ä. zu verwenden, um überlappende Blöcke ineinander zu blenden.

Die folgenden Abschnitte bieten einen Überblick über die interessantesten der untersuchten BM-Methoden, wobei die wesentlichen Unterschiede in den Suchmustern bestehen, die zur Bestimmung der bestmöglichen Verschiebung verwendet werden. Die Auswahlkriterien waren hierfür zuallererst die Qualität der Ergebnisse gefolgt von der Geschwindigkeit bei der Ausführung der Berechnungen. Dies wird insbesondere in den Veröffentlichungen [Hue11], [Hue12a], sowie [Hue16] detailliert.

4.2.1 Vollständige Suche

Wie die Bezeichnung bereits nahelegt, führt dieser Algorithmus eine vollständige Suche des kompletten Suchraums durch. Das heißt, jede mögliche Suchrichtung wird geprüft und erst nach Abschluss des gesamten Suchvorgangs steht die resultierende Verschiebungsrichtung fest. Demzufolge spielt es auch keine Rolle, in welcher Reihenfolge die einzelnen Richtungen durchsucht werden. Entsprechend ist dieser spezielle BM-Algorithmus zugleich der gründlichste (und potentiell genaueste), sowie erwartungsgemäß auch der (Zeit-)aufwändigste.

Parameter

Die Hauptparameter des Basis-Algorithmus sind die Blockgröße B und der Suchraum N . Jede Vergrößerung des Suchraumes erhöht automatisch die Berechnungskomplexität gemäß $(2N + 1)^2$, so dass nur Suchraumgrößen von wenigen Pixeln (z. B. $N \leq 5$) wirklich praktikabel sind, zumindest ohne effiziente Parallelisierung des Algorithmus. Um Subpixel-Genauigkeit zu erreichen, müsste der Algorithmus in zwei Stufen implementiert werden: einmal, um in ganzen Pixel-Schritten die “grobe” Richtung herauszufinden, und ein zweites Mal, um das Ergebnis auf Subpixel-Ebene zu verfeinern. Angesichts der ohnehin sehr langen Laufzeiten und des zusätzlich erforderlichen hohen Rechen- und Zeitaufwandes wurde hier jedoch darauf verzichtet, dieses Verfahren mit Subpixel-Genauigkeit zu implementieren. Die Wahl der Blockgröße ist ebenfalls nicht ganz trivial. Einerseits kann eine größere Blockgröße Abhilfe hinsichtlich des Apertur-Problems schaffen, das in homogenen Bildregionen auftritt, die größer als $B \times B$ Pixel sind. Andererseits verbessern kleinere Blöcke die Objektkonturen.

Insbesondere hat sich in [Hue12a] gezeigt, dass bei stärkerer Turbulenz größere Blöcke (z. B. 32×32 px) zu bevorzugen sind, wodurch bessere Ergebnisse erzielt werden. Das liegt zum einen an der Tiefpassfilterwirkung der Atmosphäre und zum anderen an der Mittelwertbildung, denn die daraus resultierende Verringerung der Bildschärfe und des Kontrastes hat eine Ausweitung der unstrukturierten (homogenen) Bildregionen zur Folge.

Algorithmus

Nachfolgend bezeichnen I_n und I_{n+1} das jeweils n -te bzw. $(n+1)$ -te Eingabebild, $\vec{x} = (x, y)^T$ die zugehörigen Pixelkoordinaten (2-D), N die Größe des Suchraumes, wobei $N_{max} = (2N + 1)^2$ die maximale Anzahl an Suchrichtungen angibt, so dass $M \in \mathbb{Z} \times \mathbb{Z}$, $M(\vec{x}) = (\delta x, \delta y)$ den Vektor bezeichnet, der alle möglichen (ganzzahligen) Verschiebungen $\delta x, \delta y \in \{-N, -(N-1), \dots, -1, 0, 1, 2, \dots, N\}$ enthält. Alle möglichen “Shift”-Varianten S_n^i des Eingabebildes I_n lassen sich somit ausdrücken als:

$$S_n^i(\vec{x}) = I_n(\vec{x} + M(\vec{x})), \quad (i = 1, \dots, N_{max}) \quad (4.1)$$

“Best Match” Kriterien

Als Entscheidungskriterium, was in diesem Kontext tatsächlich die “beste” oder vielmehr “genaueste” Übereinstimmung ausmacht, kommen diverse Ansätze in Frage. Der Vorteil einfacher Fehlersummationsmetriken, wie z. B. dem mittleren absoluten Fehler MAE (“Mean Absolute Error”), dem mittleren quadratischen Fehler MSE (“Mean Square Error”) oder der Wurzel aus dem mittleren quadratischen Fehler $RMSE$ (“Root Mean Square Error”) liegt in ihrer vergleichsweise geringen Berechnungskomplexität, wodurch sie sich relativ schnell berechnen lassen:

$$MAE(\vec{x}) = \frac{1}{XY} \sum_{\vec{y} \in Nbh(\vec{x})} |I_{n+1}(\vec{y}) - S_n^i(\vec{y})| \quad (4.2)$$

$$MSE(\vec{x}) = \frac{1}{XY} \sum_{\vec{y} \in Nbh(\vec{x})} |I_{n+1}(\vec{y}) - S_n^i(\vec{y})|^2 \quad (4.3)$$

$$RMSE(\vec{x}) = \sqrt{MSE} \quad (4.4)$$

Hierbei bezeichnen X, Y die Dimensionen der (rechteckigen) Umgebung Nbh (“Neighbourhood”) von \vec{x} . Die beste Übereinstimmung zwischen I_{n+1} und S_n^i erhält man bei diesen Metriken über Minimierung des ausgewählten Fehlermaßes, wie z. B. für $RMSE$:

$$\text{BestMatch}_{RMSE}(I_n, I_{n+1}) = \min_{i=1, \dots, N_{max}} (RMSE) \quad (4.5)$$

4.2.2 “Adaptive Rood” Suchmuster

Dieser spezielle BM-Algorithmus, vorgeschlagen in [Nie02], setzt sogenannte “Adaptive Rood Patterns” (ARP) ein, d. h. adaptive kreuzähnliche Suchmuster. Dabei handelt es sich um reduzierte Suchmuster mit nur wenigen verteilten Suchpunkten zur Detektion kleiner Bewegungen. Die Geschwindigkeit und die Genauigkeit solcher Algorithmen hängen zum einen stark von der Größe der Suchmuster ab, zum anderen sind sie mit dem Ausmaß des angestrebten Bewegungsvektors verknüpft. Aus diesem Grund arbeitet dieser Algorithmus in zwei Phasen, eine *Initialphase* und eine *Verfeinerungsphase*. In der Initialphase wird ein ARP verwendet wie z. B. in der Abbildung 4.4 dargestellt ist.



Abbildung 4.4: Beispiel für AR-Suchmustersarten. Der blaue Punkt markiert den aktuellen Block, und grün kennzeichnet die Blöcke, die zur Prädiktion verwendet werden.

Die tatsächliche Form des ARP wird dynamisch bestimmt in Abhängigkeit von prädiziertem Bewegungsverhalten des aktuell betrachteten Blocks. Diese Prädiktion basiert auf bereits verfügbaren (d. h. geschätzten) Bewegungsvektoren benachbarter Blöcke und nutzt den Umstand aus, dass sich benachbarte Blöcke mit hoher Wahrscheinlichkeit in ähnlicher Weise verhalten, d. h. mit vergleichbarer Geschwindigkeit in ähnlicher Richtung bewegen werden. In der Verfeinerungsphase wird eine weitere lokale Suche auf Pixelebene ausgeführt zur Verfeinerung der Ergebnisse aus der Initialphase.

Hierfür wird dieses Mal ein festes Suchmuster mit Einheitsgröße verwendet und vollständig durchsucht. Typischerweise handelt es sich dabei entweder um die direkte 4-er oder 8-er Nachbarschaft des aktuell betrachteten Pixels. Da der ARP-Algorithmus reduzierte Suchmuster einsetzt, arbeitet er wesentlich schneller als die vollständige Suche bei vergleichbar guten Endergebnissen.

4.2.3 Kreuzkorrelation

Alternativ kann z. B. eine Suche auf Basis der *Kreuzkorrelation* durchgeführt werden. Dabei handelt es sich um ein ähnlich direktes Block-Matching wie bei der vollständigen Suche. Allerdings setzt man hier die normalisierte Kreuzkorrelation als Kriterium der besten Übereinstimmung zwischen korrespondierenden Blöcken ein, woraus sich die resultierende Verschiebung direkt ableiten lässt.

Die (normalisierte) Kreuzkorrelations eines Bildes bzw. Blocks $f(x, y)$ und eines Templates bzw. korrespondierenden Blocks $g(u, v)$ lässt sich über die Korrelationskoeffizienten γ_{xcorr} ausdrücken wie folgt:

$$\gamma_{xcorr}(u, v) = \frac{\sum_{x, y} [f(x, y) - \bar{f}_{u, v}] [g(x - u, y - v) - \bar{g}]}{\sqrt{\sum_{x, y} [f(x, y) - \bar{f}_{u, v}]^2 \sum_{x, y} [g(x - u, y - v) - \bar{g}]^2}} \quad (4.6)$$

Dabei bezeichnet \bar{g} den Mittelwert des Templates bzw. Blocks g und $\bar{f}_{u, v}$ den Mittelwert des Areals von f , das unter dem Template bzw. Block g liegt. Demnach kann f zwar größer sein aber nicht kleiner als der Block g , der um die Koordinaten (u, v) zentriert ist, welche wiederum innerhalb des (lokalen) Koordinatenbereichs (x, y) von f liegen. Die Abweichung der Position des Korrelationsmaximum vom Zentrum liefert die relative lokale Verschiebung zwischen $f(x, y)$ und $g(u, v)$. Die Normalisierung ist wichtig für Robustheit gegenüber von Intensitätsvariationen, z. B. infolge von Änderungen in der Illumination.

Die Abbildung 4.5 visualisiert das Ergebnis einer Kreuzkorrelation am Beispiel zweier Einzelframes einer Bildsequenz mit simulierter Turbulenz, wobei 4.5a und 4.5b eine 2-D bzw. 3-D Ansicht zeigt, während 4.5c einen Einzelframe der Sequenz zeigt.

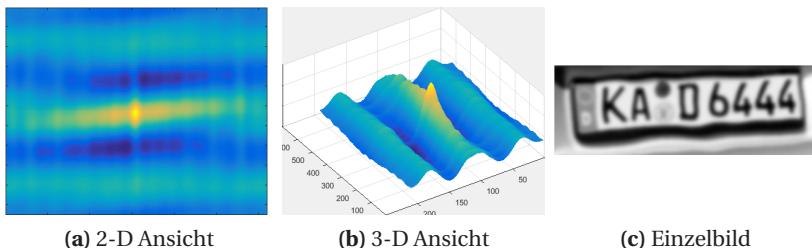


Abbildung 4.5: Beispielhafte Visualisierung des Korrelationsergebnisses (a) 2-D und (b) 3-D für (c) zwei Frames einer simulierten Bildsequenz.

Die Kreuzkorrelation bietet den Vorteil, dass die erforderliche Berechnungskomplexität von der Größe des Suchraumes unabhängig ist und mit relativ einfachen Mitteln (d. h. vorherige Bildvergrößerung) eine hohe Subpixelgenauigkeit erreicht werden kann. Prinzipiell könnte immer das gesamte Bild f nach der besten Übereinstimmung mit dem jeweiligen Block g durchsucht werden. Dies würde allerdings die Fehleranfälligkeit erhöhen, da z. B. sich wiederholende Strukturen im Bild mehrere Korrelationsmaxima und damit mehrere mögliche Verschiebungsvektoren erzeugen würden. Im Normalfall ist diese Art der Implementierung daher wenig sinnvoll.

Auch bei der Kreuzkorrelation gilt, dass nur Verschiebungen in heterogenen Bildregionen sinnvoll geschätzt werden können. Der Korrelationskoeffizient γ_{xcorr} ist auf das Vorhandensein von Strukturen im Bild angewiesen, da er in Regionen ohne Varianz (d. h. homogenen Bereichen) nicht definiert ist.

Eine mögliche Lösung besteht darin, die lokale Varianz oder Standardabweichung einzusetzen (oder auch Lakunarität), um homogene Bereiche zu identifizieren und Bewegungsvektoren dort entsprechend direkt auf Null zu setzen (s. a. Abschnitt 6.3.2). Im Kontext der Turbulenzkorrektur gewinnt dies zunehmend an Signifikanz angesichts des Verlustes hoher Frequenzanteile und dem damit verbundenen Informationsverlust infolge atmosphärischen Blurrings. Der Grad an Homogenität wächst mit zunehmender Turbulenz, während zugleich der Bildkontrast abnimmt.

4.3 Optischer Fluss

Der *Optische Fluss* (OF) bezieht sich auf die augenscheinliche Bewegung, die ein Beobachter wahrnimmt, während er sich selbst durch die 3-D Welt bewegt. Statische Objekte scheinen sich zu bewegen, obwohl es der Beobachter ist, der sich an ihnen vorbei bewegt. Je kleiner die Entfernung zu den Objekten ist, desto schneller erscheint ihre Bewegung. Im Sinne der Bildverarbeitung beschreibt OF die Bewegung zwischen aufeinanderfolgenden Frames einer Bildsequenz, d. h. es wird die Transformation von einem Frame in den nächsten beschrieben.

In "Computer Vision"-Anwendungen wird OF-Schätzung oft eingesetzt, um die Bewegung von Objekten in einem Videostream sofort quantitativ zu beschreiben, insbesondere in der bewegungsorientierten Objektdetektion oder für Trackingsysteme.

4.3.1 Grundprinzip

Wenn man Objektbewegung schätzen will, muss man unterscheiden zwischen der Bewegung, die im 2-D Bild wahrgenommen wird und der theoretischen Projektion der tatsächlichen 3-D Bewegung in die Bildebene. Genauer lässt sich die Bewegung von Objekten in der beobachteten 3-D Szene in Bezug auf eine abbildende Optik mit Hilfe eines Vektorfeldes beschreiben. Dieses Vektorfeld enthält eine zugehörige Geschwindigkeit und Richtung für jeden Punkt des 3-D Objektraums, der nach Projektion in die Bildebene sichtbar ist.

Differenzielle, d. h. Gradienten-basierte Methoden, wie die von Horn und Schunck eingeführte [Hor81] oder von Lucas und Kanade entwickelte [Luc81], basieren auf Approximationen der Taylor-Reihe. Das heißt, es werden partielle Ableitungen des Intensitätsbildes I verwendet, wobei $I = I(x, y, t)$, mit räumlichen Koordinaten x, y und zeitlichen Koordinaten t .

Es wird die folgende Annahme getroffen: für ein Teilstück eines bewegten Objekts bleibt die Intensität an korrespondierenden Positionen (x, y, t) in aufeinanderfolgenden Frames einer Bildsequenz konstant, so dass die Intensität an einer nur wenig entfernten Position und zu einem nur wenig späteren Zeitpunkt $(x + \Delta x, y + \Delta y, t + \Delta t)$ übereinstimmen. Damit erhält man

eine Bedingung für die Konstanz der Helligkeit, die auch als "*Brightness Constancy Constraint*" bekannt ist:

$$I(x, y, t) = I(x + \Delta x, y + \Delta y, t + \Delta t) \quad (4.7)$$

Die Intensitätsverschiebung lässt sich mittels lokaler Taylor-Approximation folgendermaßen ausdrücken, wobei R die verbleibenden Terme höherer Ordnung bezeichnet:

$$I(x + \Delta x, y + \Delta y, t + \Delta t) = I(x, y, t) + \frac{\partial I}{\partial x} \Delta x + \frac{\partial I}{\partial y} \Delta y + \frac{\partial I}{\partial t} \Delta t + R \quad (4.8)$$

Nimmt man an, dass es sich um eine lineare Bewegung handelt, d. h. $R \equiv 0$, ergibt sich die folgende Bedingung:

$$\frac{\partial I}{\partial x} \Delta x + \frac{\partial I}{\partial y} \Delta y + \frac{\partial I}{\partial t} \Delta t = 0 \quad (4.9)$$

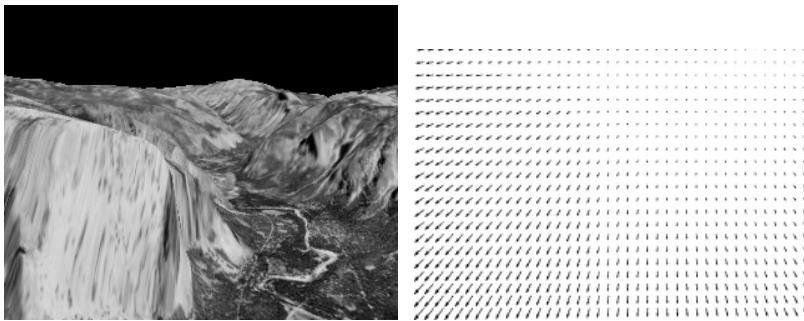
Teilen durch Δt liefert:

$$\frac{\partial I}{\partial x} \frac{\Delta x}{\Delta t} + \frac{\partial I}{\partial y} \frac{\Delta y}{\Delta t} + \frac{\partial I}{\partial t} \frac{\Delta t}{\Delta t} = 0 \quad (4.10)$$

Oder anders ausgedrückt, wobei V_x und V_y jeweils die Geschwindigkeit in x - bzw. y -Richtung bezeichnen:

$$I_x V_x + I_y V_y = -I_t \quad (4.11)$$

Unglücklicherweise handelt es sich bei dieser grundlegenden OF-Gleichung (4.11) um ein im Sinne von Hadamard schlecht gestelltes Problem. Das bedeutet, um diese Gleichung lösen zu können, sind zusätzliche Bedingungen bzgl. der Glattheit der Bewegung erforderlich. Aus diesem Grund beinhalten alle OF-Algorithmen Zusatzbedingungen für die Schätzung des tatsächlichen Flusses, d. h. des Geschwindigkeitsvektorfeldes $(u, v)^T$. Eine Leistungsevaluierung der verbreitetsten Verfahren ist gegeben in [Bar92]. Die Abbildung 4.6a zeigt einen Einzelframe der synthetisch erzeugten Yose-



(a) Yosemite-Testsequenz

(b) Optischer Fluss "Ground Truth"

Abbildung 4.6: Optischer Fluss am Beispiel der "Yosemite" Testsequenz.

mite-Sequenz¹, bei der es sich um eine beliebte Standardtestsequenz für OF-Schätzungsverfahren handelt. Als Vorlage bei der Erstellung der Sequenz diente eine digitale topographische Karte mit Bergketten in unterschiedlichen Entfernung².

Die Sequenz ist vergleichsweise komplex, denn sie beinhaltet nicht nur ein divergierendes OF-Feld, sondern auch Okklusionen, sowie Bewegungsunterschiede und multiple Bewegungen am Horizont. Da es sich um eine synthetisch erzeugte Sequenz handelt, existieren "Ground Truth"-Daten, exemplarisch gezeigt in 4.6b. Aus diesem Grund wird diese Sequenz in den nachfolgenden Abschnitten zur evaluativen Demonstration der vorgestellten Algorithmen herangezogen.

4.3.2 Horn-Schunck

Das *Horn-Schunck* Verfahren folgt dem bereits erwähnten, differenziellen Ansatz zur Schätzung des optischen Flusses. Es handelt sich dabei zudem um eine *globale* Methode, die die Annahme trifft, dass der Fluss global, d. h. über dem gesamten Bild glatt ist. Um das Apertur-Problem zu umgehen,

¹ <http://vision.middlebury.edu/flow/data> (Middlebury Optical Flow Evaluation Datasets)

² <http://cs.brown.edu/people/mjblack/Sequences/yosFAQ.html>

wird eine entsprechende globale Glattheitsbedingung eingeführt. Diese bewirkt, dass der Algorithmus Verzerrungen im OF-Vektorfeld minimiert, während glattere Lösungen bevorzugt werden.

Das OF-Vektorfeld lässt sich mit Hilfe eines globalen Energiefunktional E ausdrücken, welches für das Geschwindigkeitsvektorfeld $(u, v)^T$ gelöst werden kann:

$$E = \iint [(I_x u + I_y v + I_t)^2 + \alpha^2 (|\Delta u|^2 + |\Delta v|^2)] dx dy \quad (4.12)$$

Hierbei stehen I_x , I_y und I_t jeweils für die partiellen Ableitungen der Intensitätswerte entlang der Dimensionen x , y und t , d. h. $\partial I / \partial x$, $\partial I / \partial y$ und $\partial I / \partial t$.

Der Horn-Schunck Algorithmus liefert ein relativ dichtes OF-Vektorfeld, in dem fehlende Informationen in homogenen Regionen anhand der Vektoren an den Bewegungsbegrenzungen (d. h. beispielsweise an den Übergängen

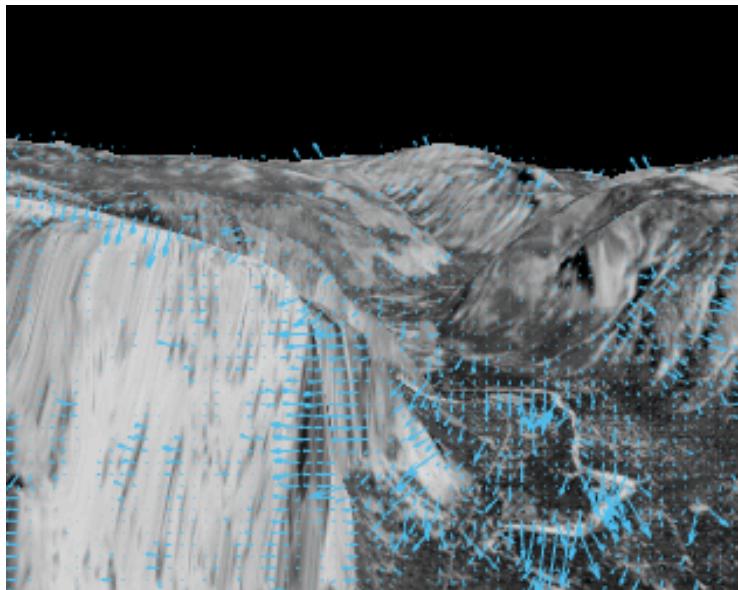
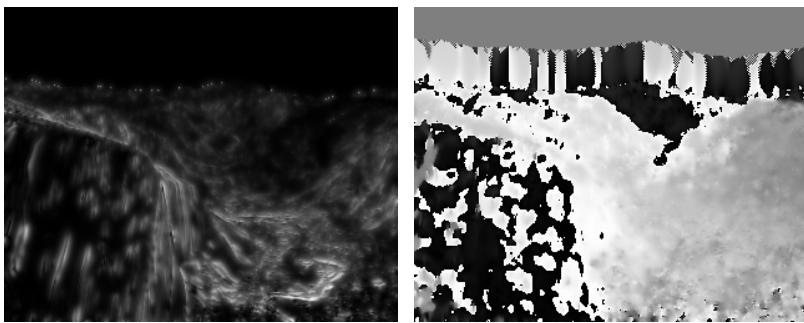


Abbildung 4.7: Schätzung des optischen Flusses mittels Horn-Schunk Algorithmus

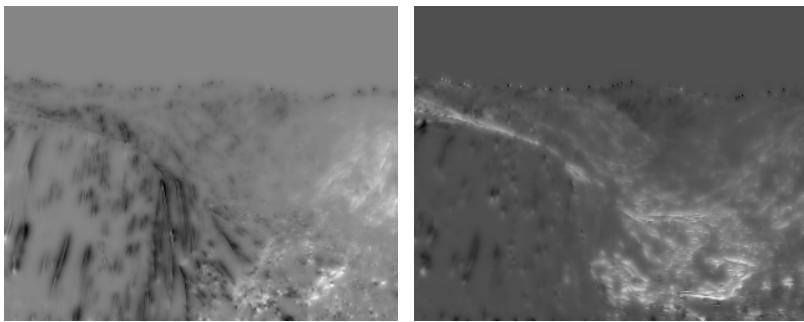
zwischen einem Bildbereich mit Bewegung und einem statischen Bildbereich) ergänzt werden. Unglücklicherweise bedeutet dies, dass der Algorithmus anfälliger ist gegenüber Rauschen als dies bei lokalen Methoden der Fall ist, wie z. B. bei dem nachfolgend beschriebenen Lucas-Kanade Verfahren. Die Abbildung 4.7 zeigt ein Beispielergebnis des Horn-Schunk Verfahrens,



(a) OF-Betrag

(b) OF-Orientierung

Abbildung 4.8: Optischer Fluss mittels Horn-Schunk Algorithmus: (a) Betrag und (b) Orientierung der geschätzten Bewegungsvektoren.



(a) Horizontale Komponente

(b) Vertikale Komponente

Abbildung 4.9: Optischer Fluss mittels Horn-Schunk Algorithmus: (a) horizontale und (b) vertikale Komponenten der geschätzten Bewegungsvektoren.

wobei die Bewegungsvektoren zur besseren Veranschaulichung vergrößert, d. h. nicht maßstabsgerecht, eingezeichnet sind. Es muss erwähnt werden, dass die Wahl der Parameter einen großen Einfluss auf die resultierende Qualität und Dichte des OF-Vektorfeldes hat.

Die Abbildungen 4.8 und 4.9 visualisieren zwei verschiedene Repräsentationen der einzelnen Komponenten des OF-Vektorfelds, wobei 4.8a den Betrag (Magnitude) und 4.8b den Phasenwinkel (Orientierung) der Bewegungsvektoren im OF-Vektorfeld darstellt, während 4.9a direkt die horizontalen und 4.9b vertikalen Komponenten der Verschiebungsvektoren anzeigt.

4.3.3 Lucas-Kanade

Das ähnlich weit verbreitete *Lucas-Kanade* Verfahren wurde bereits 1981 in [Luc81] vorgestellt und folgt ebenfalls einem differentiellen Ansatz. Hierbei

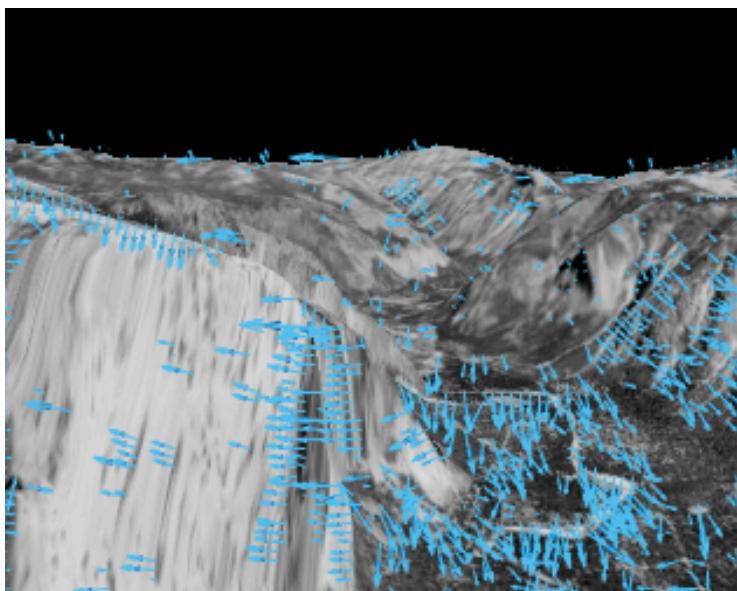


Abbildung 4.10: Schätzung des optischen Flusses mittels Lucas-Kanade Algorithmus

handelt es sich um eine *lokale* Methode, die die Annahme trifft, dass Bildverschiebungen zwischen zwei aufeinanderfolgenden Frames einer Sequenz sehr klein sein müssen, d. h. < 1 Pixel. Überdies wird angenommen, dass das Geschwindigkeitsfeld $[u, v]^T$ innerhalb einer lokalen Umgebung einer gegebenen Pixelposition (x, y) näherungsweise konstant ist. Die zugrunde liegende Gleichung (4.11) kann somit für alle Pixel in dieser Umgebung mittels "Least Squares" Methode (d. h. Methode der kleinsten Quadrate) gelöst werden. Das Ergebnis kann weiter verbessert werden, indem bei der Least Squares Methode eine Gewichtung eingeführt wird: Pixel innerhalb der lokalen Umgebung des zentralen Pixels werden in Abhängigkeit ihrer radialen Entfernung vom Zentrum gewichtet, wobei Pixel im näheren Umkreis höher gewichtet werden.

Die Abbildung 4.10 zeigt ein Beispielergebnis des Lucas-Kanade Verfahrens, wobei auch hier die Dichte des resultierenden Vektorfeldes von der Parameterwahl abhängt und die Bewegungsvektoren nicht maßstabsgerecht eingezeichnet sind.

In den nachfolgenden Abbildungen 4.11 und 4.12 sind jeweils die beiden zu 4.8 und 4.9 korrespondierenden Visualisierungen der einzelnen Komponenten des OF-Vektorfelds dargestellt (d. h. Betrag und Phasenwinkel, sowie die horizontalen und vertikalen Anteile der Verschiebungsvektoren).

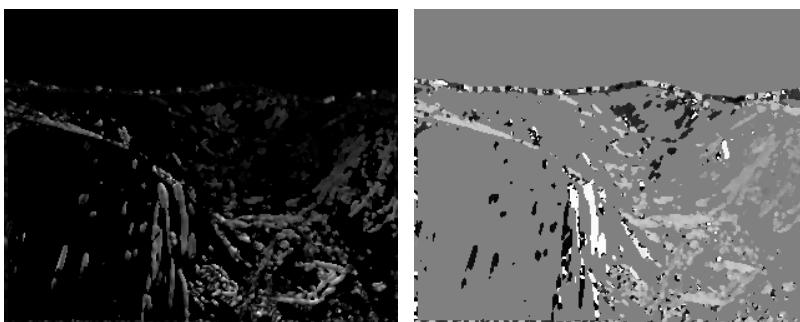
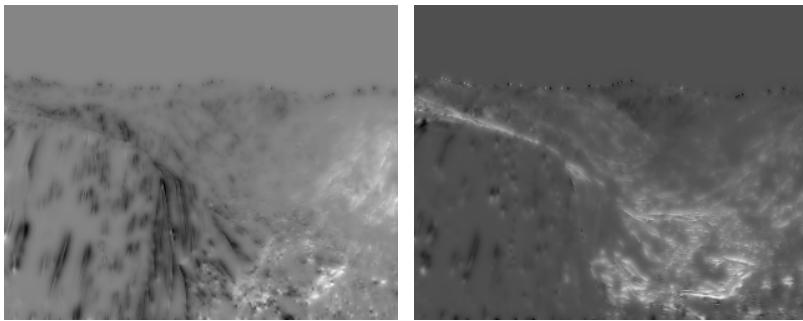


Abbildung 4.11: Optischer Fluss mittels Lucas-Kanade Algorithmus: (a) Betrag und (b) Orientierung der geschätzten Bewegungsvektoren.



(a) Horizontale Komponente

(b) Vertikale Komponente

Abbildung 4.12: Optischer Fluss mittels Lucas-Kanade Algorithmus: (a) horizontale und (b) vertikale Komponenten der geschätzten Bewegungsvektoren.

Damit auch größere Bewegungen berücksichtigt werden können, welche die Annahme der kleinen Bewegungen nicht erfüllen würden, wird Lucas-Kanade typischerweise über einen pyramidalen Ansatz implementiert. Genauer bedeutet dies, dass das Verfahren jeweils auf mehrere Versionen der Eingabedaten mit unterschiedlicher (reduzierter) Auflösung angewendet wird (erst grob, dann feiner werdend). Eine weitere Option besteht in einer zeitlichen und/oder räumlichen Gauß-Filterung der Eingabedaten, um das geschätzte (primär globale) Bewegungsvektorfeld zu glätten. Dies geschieht allerdings auf Kosten kleinerer, abrupter Bewegungen, die dadurch unterdrückt werden.

4.3.4 Farnebäck

Das etwas später entwickelte *Farnebäck*-Verfahren wurde zuerst in [Far03] vorgestellt. Hierbei werden Bewegungen zwischen zwei Frames mit Hilfe sogenannter *polynomialer Expansion* geschätzt. Nach [Far02] handelt es sich bei polynomialer Expansion um eine Transformation, die ein Signal an jedem Punkt in eine Menge von Koeffizienten mit Bezug auf ein polynomiales lokales Signalmodell überführt. Die Expansionskoeffizienten werden dazu mit Hilfe normalisierter Faltung (im Ortsraum) bestimmt.

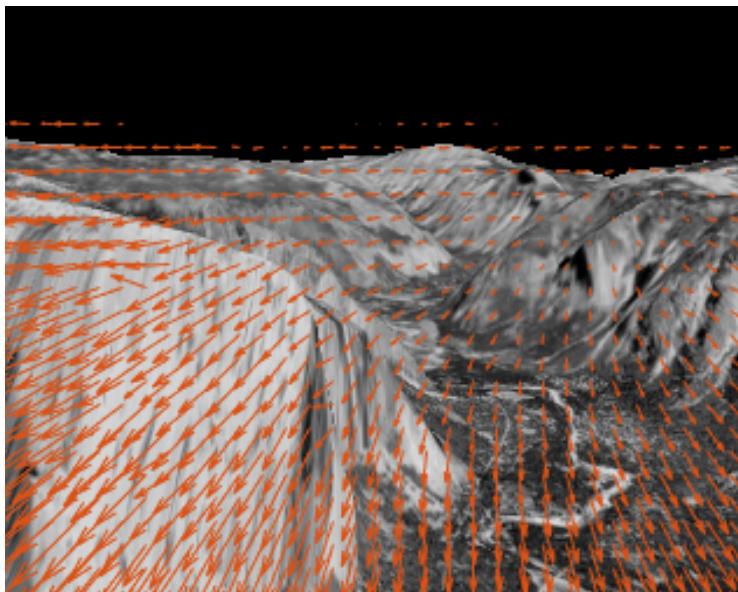
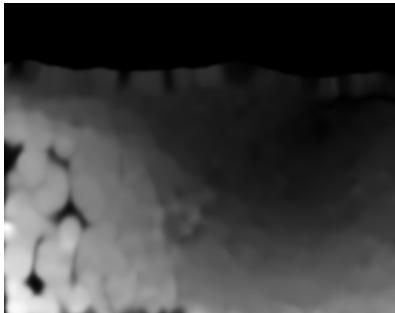


Abbildung 4.13: Schätzung des optischen Flusses mit Farnebäck Algorithmus

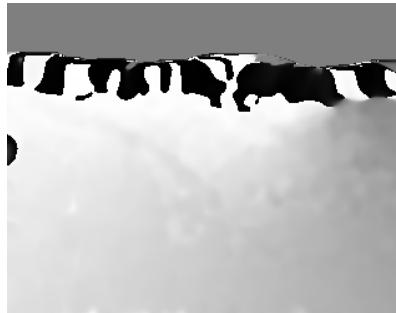
Bei der OF-Schätzmethode von Farnebäck wird zuerst für jedes Pixel eine vorher festgelegte lokale Umgebung mittels polynomialer Expansion zweiten Grades approximiert. Die korrespondierenden Expansionskoeffizienten hierfür lassen sich mit Hilfe der Ausgleichsrechnung bestimmen, genauer der Methode der kleinsten Quadrate, wobei ein ähnliches Gewichtungsschema verwendet wird wie bereits für das Lucas-Kanade Verfahren umrissen. Das Farnebäck-Verfahren folgt dann einem pyramidalen Ansatz, bei dem multiple Auflösungen zur Bestimmung des OF-Vektorfeldes eingesetzt werden, zuerst grob danach immer feiner werdend. Es gilt die Annahme, dass sich Verschiebungen nur langsam verändern, so dass a priori Informationen über die lokale Umgebung eines Pixels verwendet werden können. Darüber hinaus kann das Vektorfeld mit den Verschiebungen für ein lineares Bewegungsmodell des Geschwindigkeitsvektorfelds $[u, v]^T$ parametrisiert werden, um die Robustheit des Verfahrens zu verbessern. Im Gegensatz zu

Horn-Schunck und Lucas-Kanade ist die hohe Dichte des resultierenden Vektorfeldes relativ unabhängig von der Parameterwahl.

Die Abbildung 4.13 zeigt ein repräsentatives Ergebnis des Farnebäck-Verfahrens wieder am Beispiel der Yosemite-Sequenz, wobei auch hier die Bewegungsvektoren nicht maßstabsgerecht eingezeichnet sind.

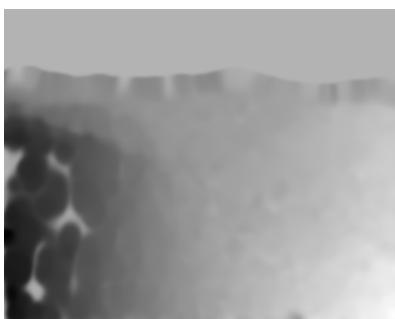


(a) OF-Betrag



(b) OF-Orientierung

Abbildung 4.14: Optischer Fluss mittels Farnebäck Algorithmus: Visualisierung (a) des Betrags und (b) der Orientierung der geschätzten Bewegungsvektoren.



(a) Horizontale Komponente



(b) Vertikale Komponente

Abbildung 4.15: Optischer Fluss mittels Farnebäck Algorithmus: Visualisierung (a) der horizontalen und (b) der vertikalen Komponenten der geschätzten Bewegungsvektoren.

Die Abbildungen 4.14 und 4.15 zeigen wie zuvor die beiden zu 4.8 und 4.9 korrespondierenden Visualisierungen der einzelnen Komponenten des OF-Vektorfelds (d. h. Betrag und Phasenwinkel, bzw. die horizontalen und vertikalen Anteile der Verschiebungsvektoren).

4.4 Evaluierung

In realen Situationen können sich eine ganze Anzahl von Schwierigkeiten ergeben, die im gleichen Maße bei der OF-Schätzung und der Evaluierung von OF-Algorithmen Probleme bereiten können wie bei der BM-Bewegungsschätzung und der Evaluierung von BM-Algorithmen. Ein beliebtes Beispiel für eine solche Situation ist eine rotierende Kugel, deren homogene, unifarben Oberfläche Lambertsche Reflexionseigenschaften aufweist. Bei konstanter Beleuchtung durch eine statische Lichtquelle ist es unmöglich, die Bewegung allein aufgrund visueller Informationen in den Bilddaten zu eruieren [Hor81]. Auf der anderen Seite würde eine Lichtquelle, die um eine statische Kugel (gleicher Art) herum bewegt wird infolge sich gleitend verändernder Intensitätswerte den Eindruck erzeugen, dass es die Kugel ist, die sich in Bewegung befindet.

Wie bereits zuvor in Abschnitt 4.1.3 diskutiert, können noch eine ganze Reihe anderer Probleme auftreten, verursacht z. B. durch Schatten, veränderliche Beleuchtung, Spiegelungen, Transparenz, komplexe Oberflächenstrukturen, unstetige Bewegungen, Objekte, die das Blickfeld der Kamera verlassen oder betreten, Kamera-Noise, Kamerabewegung und - nicht zu vergessen - atmosphärische Effekte, vor allem Turbulenz.

Während BM-Methoden Bewegung generell nur lokal erfassen können, indem Verschiebungen zwischen korrespondierenden Blöcken zweier aufeinanderfolgender Frames geschätzt werden, sind OF-Methoden etwas vielseitiger. OF kann einerseits eingesetzt werden, um eine mehr oder weniger globale Bewegung des Beobachters zu schätzen, z. B. bei einer Kamera, die auf einer bewegten Plattform befestigt ist und rundum oder von einer Seite zur anderen schwenkt. Andererseits können auch spezifische Bewegungen individueller Objekte geschätzt werden, z. B. Fahrzeuge oder Personen, die mehr auf lokaler Ebene betrachtet werden müssen.

Für alle OF-Verfahren gilt, dass im Vorfeld eine Entscheidung darüber getrofen werden muss, welcher Art Anwendung die höhere Priorität beigemessen werden sollte, da die Parameterwahl in direktem Zusammenhang mit dem Glattheitsgrad des OF-Vektorfeldes steht. Für globale Bewegung sollte die Glattheit möglichst hoch sein, im Gegensatz zu lokaler Bewegung, bei der stattdessen eher potenziell abrupte Bewegungen erhalten bleiben sollten. Das Beispiel in Abbildung 4.16 verdeutlicht diesen Unterschied in der Herangehensweise. Links werden die großen, langsam Bewegungen der Kamera und des Kindes in der Mitte erkannt, während rechts die kleinen, schnellen Bewegungen des Balls und des Kindes an der rechten Seite angezeigt werden. Welche Priorisierung zu bevorzugen ist, hängt jeweils von der entsprechenden Anwendung ab. Denkbar ist auch eine Kombination der Ergebnisse aus mehreren Durchläufen mit unterschiedlichen Parametrisierungen. Der damit verbundene erhöhte Rechenaufwand steht dem allerdings (zurzeit noch) entgegen.

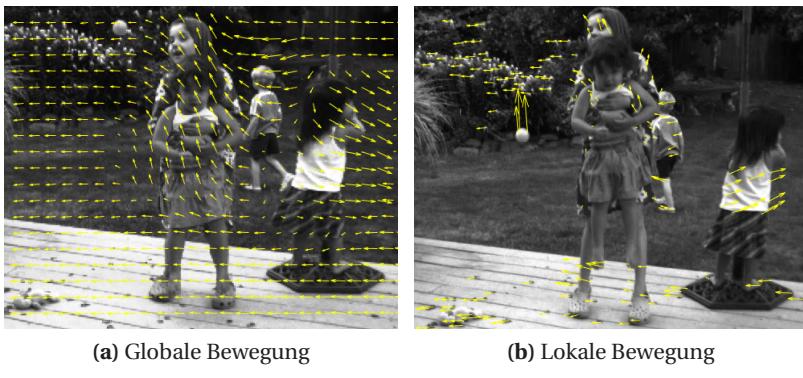


Abbildung 4.16: Optischer Fluss: (a) Globale und (b) lokale Bewegung

4.4.1 Testdaten

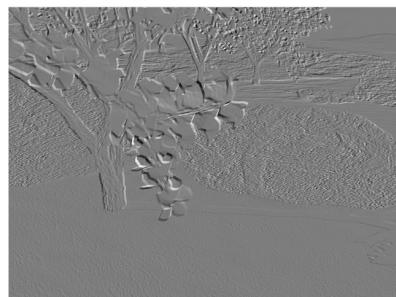
In Anbetracht der Tatsache, dass “Ground Truth”-Daten für den optischen Fluss üblicherweise nicht zur Verfügung stehen (außer die Daten wurden künstlich erzeugt oder von Hand erfasst und aufgezeichnet), erfolgten die meisten der durchgeführten Tests auf Basis synthetischer Testsequenzen

aus der Middlebury Datenbank³. Die dort vorliegenden “Ground Truth”-Daten bestehen aus Geschwindigkeitsvektoren mit je zwei Komponenten für jedes Pixel, d. h. jeweils der horizontalen und vertikalen Komponenten der Verschiebungen zwischen dem aktuellen und dem vorherigen Frame mit Subpixel-Genauigkeit. Alle OF-Schätzmethoden generieren automatisch dieselbe Art von Information für jedes Pixel. Da bei BM-Methoden pro Block jeweils nur ein einziger Verschiebungsvektor ermittelt wird, wurde diese Information allen im Block enthaltenen Pixeln zugewiesen, um den direkten Vergleich von OF- und BM-Methoden zu erleichtern.

Auf den folgenden Seiten sind zum Vergleich exemplarische Ergebnisse der hier vorgestellten BM-Methoden (vollständige Suche, “Adaptive Rood” Suchmuster und Kreuzkorrelation) gezeigt, gefolgt von den korrespondierenden Ergebnissen der aufgeführten OF-Schätzverfahren (Horn-Schunck, Lucas-Kanade, sowie Farnebäck). Verwendet wurde hierfür die sogenannte “Grove” Sequenz, bei der es sich um eine synthetischen Bildfolge handelt, die ebenfalls der Middlebury Datenbank³ entstammt und für die “Ground Truth” Daten verfügbar sind. Zum besseren Verständnis des Bewegungsinhalts der vorliegenden Szene ist in der Abbildung 4.17a zunächst ein Einzelbild der Sequenz gezeigt, sowie das zugehörige Differenzbild in Bezug auf den nächsten Frame der Sequenz in der Abbildung 4.17b.



(a) Einzelbild



(b) Differenzbild

Abbildung 4.17: Beispielsequenz “Grove”

³ <http://vision.middlebury.edu/flow/data>

4.4.2 Bildhomogenität

Die lokale Standardabweichung kann sehr gut zur Beurteilung der Homogenität bzw. Heterogenität von Bilddaten eingesetzt werden. Dies ist insbesondere aufgrund des Apertur-Problems relevant, denn große homogene Bereiche bereiten allen der hier vorgestellten Verfahren zur Bewegungsschätzung Probleme. Entsprechend liefert die "Homogenitätskarte" in Abbildung 4.18 Hinweise darauf, wo die verschiedenen Algorithmen keine zuverlässigen Werte liefern können (d. h. in den dunklen Regionen). Somit kann die Karte 4.18a gewissermaßen als Indikator für die erreichbare Zuverlässigkeit eines Algorithmus dienen, die umso höher ist, je heller die Karte ist. Die binärisierte Version 4.18b zeigt hauptsächlich wo es sinnvoll ist, ermittelte Werte zu berücksichtigen (weiß) und wo nicht (schwarz).

Zur Erstellung dieser speziellen Art von Homogenitätskarte wird die Standardabweichung für ein Einzelbild (oder auch für ein Array aus mehreren Frames) blockweise ermittelt, unter Einsatz einer ganzen Reihe von verschiedenen Blockgrößen. Anschließend wird an jedem Pixel der Mittelwert (oder Median) aus den Ergebnissen aller Blockgrößen bestimmt und das Ergebnis auf das Intervall $[0,1]$ skaliert. Für weitere Details und Alternativen sei auf den Abschnitt 6.3.2 verwiesen.



(a) STD-Karte

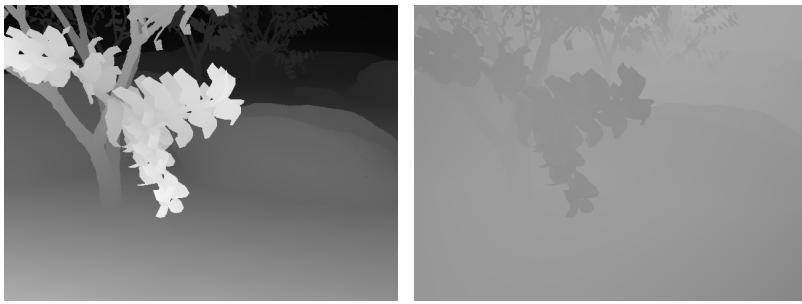


(b) Binärkarte

Abbildung 4.18: Homogenitätskarte für die "Grove" Sequenz: (a) Karte lokaler Standardabweichung und (b) binärisierte Version

4.4.3 Qualitative Evaluation

Die Ground Truth für die “Grove” Sequenz ist in Abbildung 4.19 zu sehen, wie zuvor aufgeteilt in horizontale 4.19a und vertikale Verschiebungskomponenten 4.19b des OF-Vektorfeldes.



(a) Horizontale Komponente

(b) Vertikale Komponente

Abbildung 4.19: Ground Truth für “Grove” Sequenz aufgeteilt in (a) horizontale und (b) vertikale Komponenten

Nachfolgend sind in der Abbildung 4.20 die Ergebnisse der drei ausgewählten BM-Algorithmen für die “Grove” Sequenz dargestellt, angefangen mit der vollständigen Suche (obere Reihe), gefolgt von der “Adaptive Rood Pattern”-Suche (in der Mitte) und der Suche mittels normalisierter Kreuzkorrelation (unten). Dabei ist links jeweils die horizontale Komponente und rechts die vertikale Komponente abgebildet.

Es sollte angemerkt werden, dass bei den BM-Verfahren keine besondere Behandlung der Ränder erfolgt ist. Aufgrund dessen weisen die zugehörigen Ergebnisse dort teils erratische Werte auf. Zur Erhaltung des originalen Maßstabs und Bildformats wurde aber darauf verzichtet, diese Ränder für die Darstellung hier zu entfernen.

In analoger Weise sind in der Abbildung 4.21 die Ergebnisse der drei ausgewählten OF-Schätzverfahren dargestellt, angefangen mit dem Schätzverfahren nach Horn-Schunck (obere Reihe), gefolgt von dem Schätzverfahren nach Lucas-Kanade (Mitte) und dem Schätzverfahren nach Farnebäck (unten).

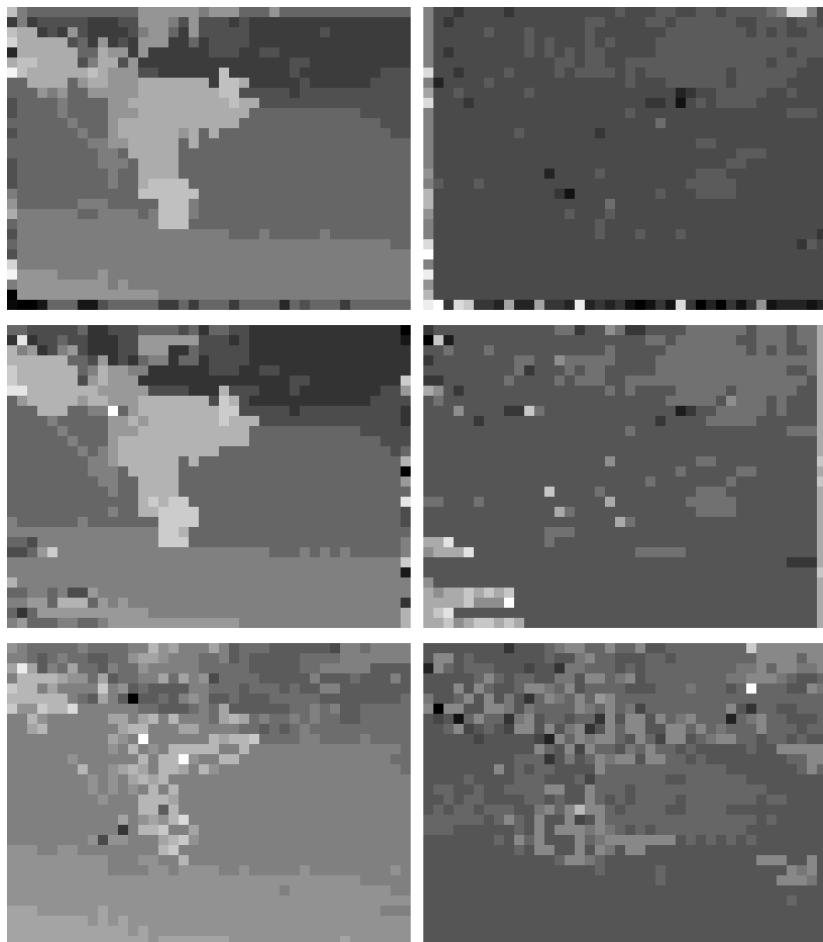


Abbildung 4.20: “Block Matching”-Ergebnisse, links: horizontale Komponente, rechts: vertikale Komponente. Oben: vollständige Suche; Mitte: “Adaptive Rood Pattern”-Suche; unten: Korrelationsbasierte Suche

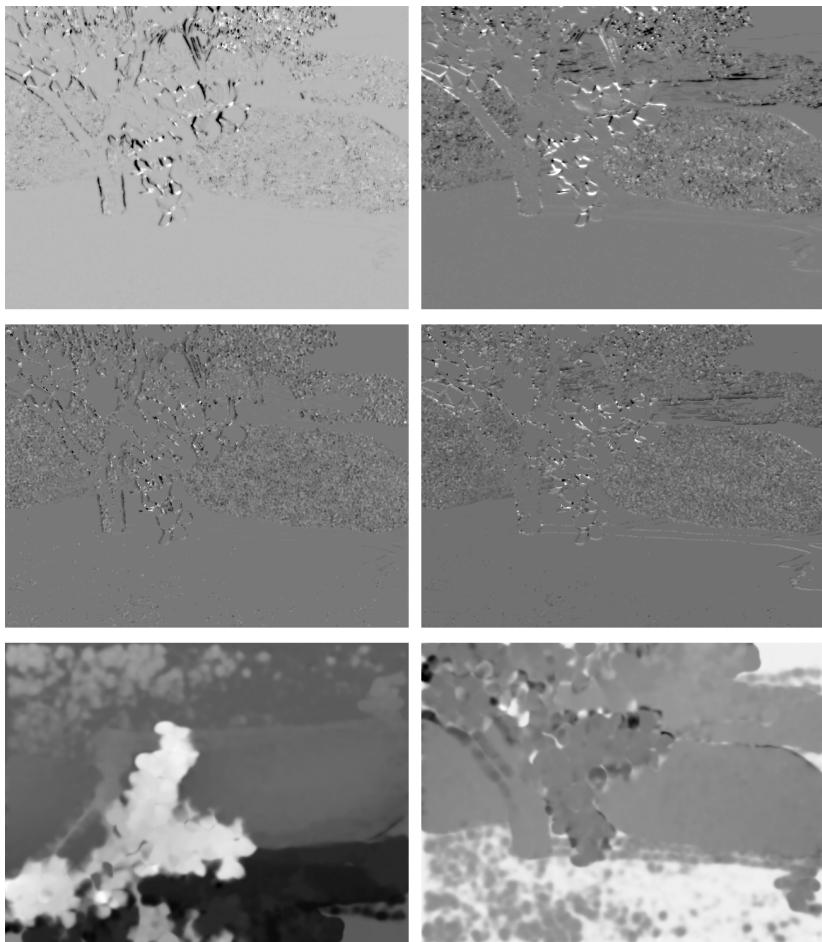


Abbildung 4.21: “Optical Flow”-Ergebnisse, links: horizontale Komponente, rechts: vertikale Komponente. Oben: Schätzverfahren nach Horn-Schunck; Mitte: Schätzverfahren nach Lucas-Kanade; unten: Schätzverfahren nach Farnebäck

Ein Vergleich der vorliegenden Ergebnisse mit der Ground Truth in der Abbildung 4.19 zeigt, dass die Qualität der Ergebnisse stark variiert, wobei das OF-Schätzverfahren nach Farnebäck alle anderen Methoden qualitativ deutlich übertrifft. Die größten Abweichungen zur Ground Truth finden sich erwartungsgemäß in weitgehend homogenen Bildbereichen wie der Vergleich mit der Homogenitätskarte in der Abbildung 4.18 verdeutlicht. Weder das OF-Schätzverfahren nach Horn-Schunck noch das nach Lucas-Kanade vermag Informationen über den optischen Fluss in homogene Regionen hinein zu extrapolieren. Beide sind darauf beschränkt, Verschiebungen entlang von horizontalen bzw. vertikalen Kanten zu bestimmen, was sich entsprechend in den Ergebnissen in der Abbildung 4.21 (oben und Mitte) niederschlägt.

Unter den BM-Algorithmen schneiden die vollständige Suche und die “Adaptive Rood Pattern” Suche vergleichbar gut ab, wobei die Auflösung der Ergebnisse naturgemäß aufgrund der inhärenten Blockstruktur wesentlich geringer ausfällt als die der OF-Schätzverfahren.

4.4.4 Laufzeit-Evaluierung

Bei der Auswahl bestimmter Methoden sollte grundsätzlich immer die Qualität der Ergebnisse im Vordergrund stehen. In Abhängigkeit von der geplanten Anwendung können die Ausführungszeiten der zugrundeliegenden Algorithmen dennoch eine nicht unwesentliche Rolle spielen. So schwingt in dieser Arbeit in Bezug auf die Turbulenzkorrektur insbesondere immer die Frage nach der potenziellen Echtzeitfähigkeit mit. Bei vergleichbar guten Ergebnissen wird demnach die Geschwindigkeit der entscheidende Faktor sein bzw. im Umkehrschluss werden bei gleichen Geschwindigkeiten die besseren Ergebnisse den Ausschlag geben.

Die Abbildungen 4.22 und 4.23 vergleichen die Ausführungszeiten von BM-Methoden und OF-Schätzverfahren. Hierfür wurden alle Verfahren auf 8 verschiedene Sequenzen aus aus der Middlebury Datenbank angewendet. Die Sequenzen sind z. T. von unterschiedlicher Länge (meist 2 oder 7 Frames), daher wurde pro Sequenz nur die jeweils durchschnittliche Berechnungszeit pro Bildpaar verwendet. In den Legenden der Plots werden Abkürzungen der Verfahrensbezeichnungen verwendet: “ARPS” in 4.22 steht für “Adaptive Rood Pattern Search”, “ES” steht für “Exhaustive Search” und “CS” steht für

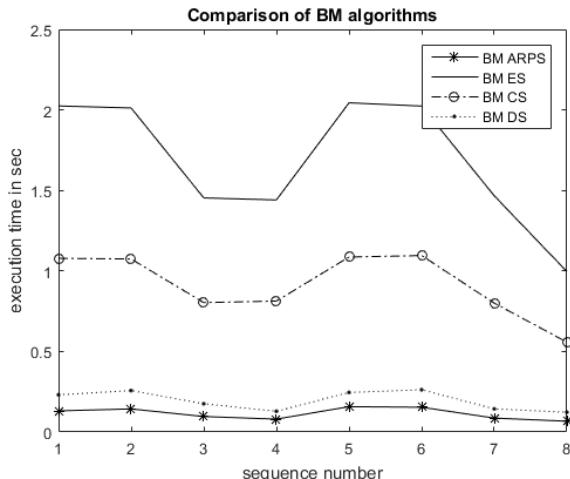


Abbildung 4.22: Geschwindigkeit von BM-Algorithmen im Vergleich

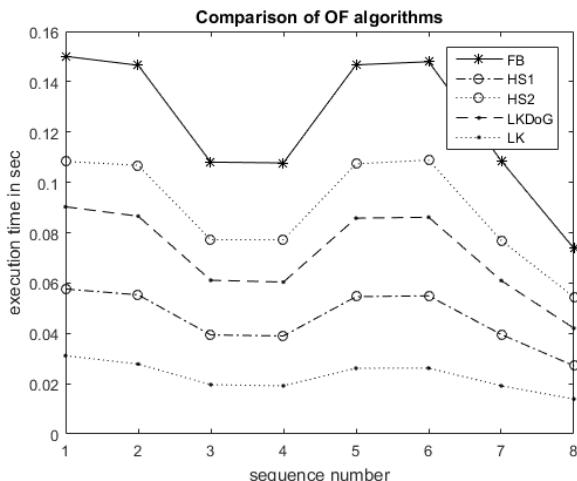


Abbildung 4.23: Geschwindigkeit von OF-Schätzverfahren im Vergleich

“Correlation based Search”; “FB” in 4.23 steht für “Farnebäck”, “HS” steht für “Horn-Schunck”, wobei “HS1” sowie “HS2” unterschiedliche Parametereinstellungen bedeuten, und “LK” steht für “Lucas-Kanade”.

Wie zu erwarten war, ist die vollständige Suche zugleich die langsamste aller getesteten Methoden und die beste bzw. genaueste unter den BM-Methoden, während das “Adaptive Rood”-Suchmuster bei vergleichbar guten Ergebnissen am schnellsten unter den BM-Algorithmen abschneidet. Das Lucas-Kanade Verfahren (mit minimalen Parametereinstellungen) ist wiederum das insgesamt schnellste aller getesteten Methoden (inklusive der BM-Methoden). Obwohl das Farnebäck-Verfahren unter den OF-Schätzverfahren das langsamste ist, liegt die durchschnittliche Ausführungszeit in der gleichen Größenordnung wie der schnellste BM-Algorithmus.

Anmerkungen

Neben den vorgestellten Verfahren wurden für den Vergleich noch ein paar weitere Varianten mit getestet. Bei den BM-Algorithmen wurde z. B. noch die “Adaptive Rood Pattern”-Suche mit festem Suchmuster in Diamantform eingesetzt (in 4.22 mit “DS” gekennzeichnet), während bei den OF-Verfahren noch das Verfahren nach Lucas-Kanade mit “Derivative of Gaussian” Kantenfilter getestet wurde (in 4.23 mit “LKDoG” gekennzeichnet). Da sich diese Varianten jedoch weder in der Funktionsweise noch in den Ergebnissen nennenswert von den zugrundeliegenden Verfahren unterscheiden, wurde hier darauf verzichtet, näher auf sie einzugehen.

Es sollte noch angemerkt werden, dass die Ausführungszeiten der BM-Methoden nur deshalb so hoch ausgefallen sind, weil es sich um Software-Implementationen handelt, während sie typischerweise mit Hardwareunterstützung eingesetzt werden.

4.4.5 Anwendung auf Turbulenz

Abbildung 4.24 zeigt ein Einzelbild aus einer Beispieldsequenz, aufgenommen im IR, mit simulierter Turbulenz. Für die Simulation wurde die GPU-basierte Software IMOTEP [Mon14] verwendet, wobei ein Ausbreitungspfad von $L = 3$ km und Turbulenzbedingungen von $C_n^2 = 10^{-14} \text{ m}^{-2/3}$ angenommen wurden.



(a) Original

(b) Simulierte Turbulenz

Abbildung 4.24: IR Beispieldsequenz (a) originaler Einzelframe, (b) Frame mit simulierter Turbulenz

Die Abbildung 4.25 verdeutlicht die Hauptproblematik, die alle bekannten Registrierungsmethoden gleichermaßen beeinträchtigt. Besonders deutlich wird das in den Detailausschnitten in der Abbildung 4.26. Mit zunehmender Turbulenz verstärkt sich auch der atmosphärische Blurring-Effekt, wodurch wiederum der Kontrast verringert wird und (Objekt-)Strukturen verschmieren oder ggfs. ganz verschwinden. Zurück bleiben (nahezu) homogene Bildregionen, innerhalb denen die Schätzung von Bewegungsvektoren, wie zuvor bereits erwähnt, entsprechend fehleranfällig ist.



Abbildung 4.25: Beispiel für OF-Schätzung nach Horn-Schunck bei simulierter Turbulenz

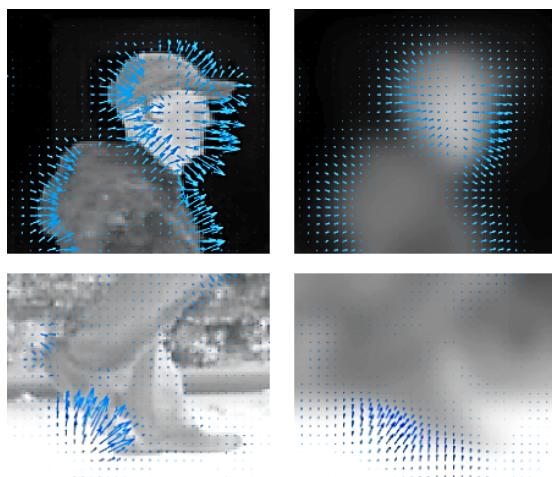


Abbildung 4.26: Beispiel für OF-Schätzung nach Horn-Schunck, Ausschnittsvergrößerung. Oben: Kopfdetail, unten: Fußdetail

5

Deblurring

“Deblurring” bedeutet so viel wie “die Entfernung von Unschärfe” und stellt einen wesentlichen Aspekt bei den meisten Verfahren zur Turbulenzkorrektur dar. Dies gilt insbesondere für alle der hier vorgestellten MCA-Varianten. Deblurring-Methoden reichen von einfachen *Schärfungsfiltern* über die Methode der *Unscharf-Maskierung* bis hin zu (*Blinden*) *Entfaltungsverfahren*. Jedoch bieten weder Schärfungsfilter noch Unscharf-Maskierung hinreichende Lösungen für Turbulenz-bedingte Bildunschärfe. Zudem haben diese Methoden den Nachteil, dass vorhandenes Rauschen übermäßig verstärkt wird. In dieser Arbeit liegt der Fokus daher auf Entfaltungsverfahren, welche in dieser Hinsicht deutlich leistungsfähiger sind. Bei den in den nachfolgenden Abschnitten beschriebenen Entfaltungsmethoden handelt es sich lediglich um eine repräsentative Teilmenge derartiger Methoden. Darüber hinaus gibt es natürlich es noch eine Vielzahl anderer Lösungsmöglichkeiten für das Entfaltungsproblem. So verwendet das in [Ori10a] vorgeschlagene Entfaltungsverfahren, die sogenannte *Unsupervised Wiener-Hunt Deconvolution* (UWH), beispielsweise ein Bayes’sches Wahrscheinlichkeitsmodell. Die Parameterschätzung (einschließlich der PSF-Parameter) erfolgt hierin mithilfe von *Markov-Ketten* und *Monte-Carlo-Simulation* (“Markov Chain Monte Carlo”, MCMC). Einen umfassenderen Überblick über die breite Fülle existierender Verfahren zur blinden Entfaltung von Bilddaten kann man u. a. mithilfe der Publikationen [Kun96a], [Kun96b] und [Cha14] gewinnen.

5.1 Blinde Entfaltung

Bei einer *Entfaltung* (“Deconvolution”) handelt es sich um ein *inverses Problem*. Prinzipiell geht es dabei um die scheinbar einfache Aufgabe der Separierung zweier gefalteter Funktionen f und h . Wenn h ebenfalls unbekannt ist, spricht man speziell von *Blinder Entfaltung* (“Blind Deconvolution”). Im Ortsraum nimmt diese Problemstellung die folgende Form an (s. a. Abbildung 1.10):

$$g(x, y) = h(x, y) * f(x, y) + n(x, y) \quad (5.1)$$

Hierbei bezeichnen $g = g(x, y)$ das real beobachtete Bild an der Stelle (x, y) im Koordinatenraum, h die (typischerweise) unbekannte Blurring-Filterfunktion, f das (hypothetische) ideale Bild, $*$ den Faltungsoperator und n eine ebenfalls unbekannte, additive Noise-Komponente.

Die Filterfunktion h wird dabei generell als *PSF*, d. h. “*Point Spread Function*” bzw. Punktspreizfunktion bezeichnet. Es sollte noch angemerkt werden, dass h in dieser Arbeit des öfteren auch als *atmosphärische Filterfunktion* umschrieben wird. Tatsächlich ist h in dieser Problemformulierung nicht ausschließlich durch die störenden Einflüsse der Atmosphäre (zum Zeitpunkt der Aufnahme) bestimmt, sondern beinhaltet grundsätzlich auch die Abbildungseigenschaften des verwendeten optischen Systems. Bei vorliegender Turbulenz sind die atmosphärischen Einflüsse allerdings in der Regel so dominant, dass alles andere im Vergleich vernachlässigbar ist.

Zur Vereinfachung lässt sich die Problemstellung (5.1) vom Ortsraum in den Fourier-Raum transferieren, wo gemäß dem *Faltungstheorem* aus einer relativ komplexen Faltungsoperation eine einfache Multiplikation wird:

$$G(u, v) = H(u, v) \cdot F(u, v) + N(u, v) \quad (5.2)$$

Hierbei bezeichnen G , H , F und N jeweils die zu g , h , f und n korrespondierenden *Fourier-Transformierten* (FT) an der Stelle (u, v) im Frequenzraum. Auf den ersten Blick erscheint die Aufgabe der Entfaltung recht einfach. Dieser Eindruck täuscht allerdings, da das Problem als solches *schlecht gestellt* ist. Aufgrund der additiven Rauschkomponente N (bzw. n), welche zwangsläufig unbekannt bleibt, ist es quasi unmöglich, das ungestörte Bild

f tatsächlich zu 100% korrekt zu rekonstruieren, auch falls die Filterfunktion H (bzw. h) genauestens bekannt sein sollte.

Für dieses Entfaltungsproblem gibt es verschiedene Lösungsansätze, von denen einige der verbreitetsten Algorithmen, wie z. B. der *Inverse Wiener Filter* (IWF) oder die *Lucy-Richardson Dekonvolution* (LRD), in den nachfolgenden Abschnitten vorgestellt werden. Diese Algorithmen unterscheiden sich grundlegend in zweierlei Hinsicht. Zum einen unterscheiden sie sich darin, ob es sich jeweils um *blinde* oder *nicht-blinde* Methoden handelt, d. h. ob die PSF dafür bekannt sein muss oder nicht. Es sollte angemerkt werden, dass "unbekannt" in diesem Zusammenhang bedeutet, dass nicht die PSF als Ganzes bekannt sein muss, sehr wohl aber der *Träger* ("Support") der Filterfunktion (d. h. die Stellen, an denen die PSF nicht Null ist bzw. verschwindend klein wird).

Zum anderen unterscheiden sich die Algorithmen auch darin, ob es sich dabei jeweils um *iterative* oder *direkte* (bzw. *explizite*) Methoden handelt, d. h. ob die Lösung zunächst mehr oder weniger grob geschätzt wird und in weiteren Algorithmus-Folgedurchläufen immer besser approximiert wird oder ob die Lösung bereits direkt im ersten Durchlauf gefunden werden kann. Die nachstehende Tabelle 5.1 ordnet die hier aufgeführten Algorithmen in diese grundlegenden Kategorien ein.

Typ	Nicht-blinde Methoden PSF bekannt (oder Schätzung)	Blinde Methoden (PSF-Träger bekannt)
Iterativ	Lucy / Richardson (LRD)	Iterative Blinde Entfaltung (IBD) ⇒ Blinde Version von LRD
Direkt	Inverser Wiener Filter (IWF)	PCA-basierte Entfaltung

Tabelle 5.1: Übersicht über Typen von Entfaltungsalgorithmen

5.1.1 Inverser Wiener Filter

Der sicherlich einfachste Ansatz zur Lösung von Gleichung (5.2) besteht in direkter inverser Filterung, wobei eine Schätzung \hat{F} für F (die FT des ungestörten idealen Bildes f) formuliert werden kann wie folgt [Gon08]:

$$\hat{F}(u, v) = \frac{G(u, v)}{H(u, v)} \iff \hat{F}(u, v) = F(u, v) + \frac{N(u, v)}{H(u, v)} \quad (5.3)$$

Dieser “naive” Ansatz führt allerdings zu Problemen infolge einer Division durch (nahezu) Null im Frequenzraum, denn typischerweise wird H (die FT von h) zahlreiche Nullen oder zumindest verschwindend kleine Werte enthalten, wodurch der Quotient auf der rechten Seite der Gleichung (5.3) signifikante Fehler in der Schätzung \hat{F} erzeugen und diese ggf. sogar überwiegend bestimmen wird. Mit zunehmenden Raumfrequenzen wird die Ratio (N/H) noch weiter anwachsen, so dass bereits geringes Rauschen überproportional verstärkt wird, selbst wenn die Noise-Komponente N als solches vernachlässigbar ist.

Ausgefeilte inverse Filter Varianten machen sich aus diesem Grund zusätzliche Informationen zunutze, insbesondere über die zu erwartenden Noise-Charakteristika. Über geschickte Einschränkungen der Randbedingungen lassen sich u. U. dennoch sehr gute Näherungslösungen finden. Sogenannte *pseudoinverse* Filter führen z. B. eine gesonderte Behandlung der Nullstellen (bzw. verschwindend kleinen Werte) von H durch. Eine andere effektive Methode besteht darin, die Filterfrequenzen auf die nähere Umgebung ringsum den Ursprung einzuschränken. In diesem Bereich sind die Werte am größten, weshalb die Wahrscheinlichkeit für verschwindende Werte dort entsprechend am geringsten ist.

Speziell beim *Inversen Wiener Filter*¹ (IWF) wird der folgende Fehler zwischen der Schätzung \hat{f} und dem idealen Bild f minimiert ([Gon08]):

$$err^2 = E \{ (f - \hat{f})^2 \} \quad (5.4)$$

Die Größen \hat{f} und f (so wie im übrigen auch g und h) werden dabei als Zufallsvariablen interpretiert. Tatsächlich beschreibt die Gleichung (5.4) die mittlere quadratische Abweichung (MSE) als Fehlermaß. Wenn R, C die Dimensionen, d. h. die Anzahl an Zeilen und Spalten (“rows” und “columns”) von f und \hat{f} bezeichnen, lässt sich der MSE insbesondere folgendermaßen formulieren (vgl. auch Gleichung (4.3)):

$$MSE = \frac{1}{RC} \sum_{y=0}^{R-1} \sum_{x=0}^{C-1} [f(x,y) - \hat{f}(x,y)]^2 \quad (5.5)$$

¹ zuerst 1942 von Norbert Wiener vorgeschlagen, bekannt als Begründer der Kybernetik

Zur Vereinfachung des Problems werden beim IWF drei wesentliche Annahmen getroffen ([Gon09]):

1. Das Bild f und das Rauschen n sind unkorreliert.
2. f oder n hat den Mittelwert Null
3. Die Intensitätswerte der Schätzung \hat{f} sind eine lineare Funktion der Werte im real gemessenen Bild g .

Unter diesen Voraussetzungen lässt sich die Lösung \hat{F} , welche die Gleichung (5.4) (bzw. (5.5)) minimiert, im Frequenzraum ausdrücken wie folgt:

$$\begin{aligned}\hat{F}(u, v) &= \left[\frac{H^*(u, v)S_f(u, v)}{S_f(u, v)|H(u, v)|^2 + S_n(u, v)} \right] G(u, v) \\ &= \left[\frac{H^*(u, v)}{|H(u, v)|^2 + S_n(u, v)/S_f(u, v)} \right] G(u, v) \\ &= \left[\frac{1}{H(u, v)} \frac{|H(u, v)|^2}{|H(u, v)|^2 + |N(u, v)|^2 / |F(u, v)|^2} \right] G(u, v)\end{aligned}\quad (5.6)$$

Hierbei bezeichnet H^* die Konjugierte von H , wobei insbesondere ausgenutzt wird, dass gilt:

$$H^*(u, v)H(u, v) = |H(u, v)|^2$$

Weiterhin bezeichnen $S_f(u, v) = |F(u, v)|^2$ bzw. $S_n(u, v) = |N(u, v)|^2$ das jeweilige *Powerspektrum* (auch *spektrale Leistungsdichte* oder *Autokorrelation*) des ungestörten Bildes f bzw. der Rauschkomponente n .

Der besondere Vorteil in der Formulierung von Gleichung (5.6) liegt darin, dass hier die Probleme des direkten inversen Filters mit verschwindenden Werten in der Filterfunktion H nicht auftreten. Insbesondere reduziert sich der Ausdruck in Gleichung (5.6) auf den direkten inversen Filter in Gleichung (5.3), falls die Rauschkomponente ganz verschwindet (d. h. $n = 0$ und somit $|N|^2 = 0$).

Das Verhältnis $S_n(u, v)/S_f(u, v)$ (für $S_n \neq 0$) der Powerspektren ist normalerweise nicht genau bekannt und muss entsprechend approximiert bzw. geschätzt werden. Häufig wird stattdessen auch der Kehrwert des damit

verbundenen *Signal-zu-Rausch* Verhältnisses (“Signal-to-Noise Ratio”, SNR) bzw. ein Schätzwert dafür eingesetzt. Im Frequenzraum lässt sich SNR näherungsweise über das Verhältnis $SNR = MPS_f / MPS_n$ der korrespondierenden (skalarwertigen) mittleren Powerspektren MPS_f und MPS_n beschreiben, wobei:

$$MPS_f = \sum_{u=0}^{M-1} \sum_{v=0}^{N-1} S_f(u, v) \quad \text{und} \quad MPS_n = \sum_{u=0}^{M-1} \sum_{v=0}^{N-1} S_n(u, v).$$

Genauer wird der Quotient S_n / S_f in Gleichung (5.6) in einigen Varianten des IWF durch den Skalarwert $R = 1 / SNR$ ersetzt, wobei es im übrigen auch Varianten gibt, in denen jeweils die Quadratwurzel verwendet wird. R kann somit als Regularisierungsparameter fungieren und die Qualität der Schätzung \hat{f} kann über das Variieren von R gesteuert werden.

Die zugehörigen Powerspektren von f bzw. n sind allerdings oftmals unbekannt. Speziell im Zusammenhang von Turbulenz-gestörten Bilddaten ist dies sogar der Normalfall. Eine Möglichkeit, dennoch eine gute Lösung \hat{f} zu finden, besteht darin, die Gleichung (5.6) über eine Konstante K zu parametrisieren:

$$\hat{F}(u, v) = \left[\frac{1}{H(u, v)} \frac{|H(u, v)|^2}{|H(u, v)|^2 + K} \right] G(u, v) \quad (5.7)$$

Tatsächlich würde das Noise-Powerspektrum beispielsweise im Fall von spektralem weißen Rauschen einer Konstante entsprechen.

5.1.2 Richardson-Lucy Entfaltung

Bei der *Richardson-Lucy Entfaltung*² (“Lucy-Richardson Deconvolution”, LRD), beschrieben in [Ric72] sowie in [Luc74], handelt es sich um eine nicht-blinde Methode ebenso wie der IWF. Das bedeutet, die Filterfunktion h (oder eine gute Schätzung dafür) wird hier ebenfalls als bekannt vorausgesetzt, wobei weiterhin die Bezeichnungen aus Gleichung (5.1) verwendet werden. Im Gegensatz zum IWF handelt es sich bei der LRD allerdings auch um einen nicht-linearen und insbesondere iterativen Algorithmus.

² 1972 von William H. Richardson und 1974 von Leon B. Lucy unabhängig voneinander entwickelt

Die LRD ist aus der Bayes'schen Wahrscheinlichkeitstheorie abgeleitet, d. h. Bilddaten werden wie beim inversen Wiener Filter als Zufallsvariablen interpretiert. Genauer entsteht die LRD aus der sogenannten “*Maximum Likelihood Estimation*” (MLE, auch “Schätzungsmethode der maximalen Mütmaßlichkeit”) heraus. Dabei handelt es sich um ein Verfahren zur Schätzung der Parameter einer Verteilungsfunktion mit dem Ziel, dass die Messdaten (bzw. statistischen Beobachtungen) die größte Wahrscheinlichkeit für das zugrunde gelegte statistische Modell aufweisen. Dies geschieht über iterative Maximierung einer entsprechenden Wahrscheinlichkeitsfunktion (“Likelihood Function”). Im vorliegenden Fall wird speziell die Wahrscheinlichkeit, dass das geschätzte Bild \hat{f} nach Faltung mit der PSF h (bis auf Noise) identisch mit dem gemessenen Bild g ist, als eine solche Likelihood Function formuliert. Dabei gilt die Annahme, dass die Schätzung nur Poisson-verteiltes Rauschen enthält, während etwaiges Gauß-verteiltes Rauschen ignoriert wird.

Ein punktförmiges Objekt in einem Bild g , das mithilfe eines EO-Systems aufgenommen wurde, wird in dieser Aufnahme nicht mehr als Punkt erscheinen, sondern vielmehr die Gestalt der Punktspreizfunktion h selbst annehmen. Dementsprechend können ausgedehnte Objekte in die Summe vieler einzelner Punktobjekte unterteilt werden, so dass das reale Bild g auch als Matrixoperation mit der Filterfunktion h dargestellt werden kann, die auf dem idealen Bild f ausgeführt wird. Dabei beschreiben die Matrixelemente $h(x,y)_{(i,j)}$ den jeweiligen Lichtanteil, der vom Pixel (i,j) ausgeht und am Pixel (x,y) gemessen wird, so dass die Filtermatrix h auch einfach durch den räumlichen Abstand (“Offset”) zwischen dem “Quellpixel” (i,j) und dem “Messpixel” (x,y) ausgedrückt werden kann:

$$h(x,y)_{(i,j)} = h(x - i, y - j) = h(\Delta x, \Delta y)$$

In [She82] wurde empirisch gezeigt, wenn die folgende Iterationsvorschrift zur Schätzung von \hat{f} konvergiert, dass sie gegen die Lösung der maximalen Wahrscheinlichkeit für f konvergiert, wobei “ (k) ” die jeweils k -te Iteration kennzeichnet.

$$\hat{f}^{(k+1)}(x,y) = \hat{f}^{(k)}(x,y) \left[h(-x, -y) * \frac{g(x,y)}{h(x,y) * \hat{f}^{(k)}(x,y)} \right] \quad (5.8)$$

Hervorzuheben ist hierbei, dass es die Division durch die Schätzung \hat{f} ist, welche die nichtlinearen Eigenschaften des Algorithmus ausmacht.

So wie im Fall der meisten nicht-linearen Methoden, lässt sich auch bei der IBD die Frage nach der “richtigen” Anzahl von Iterationen (bzw. geeigneten Stopp-Kriterien) nicht allgemeingültig beantworten. Ansätze hierfür beinhalten in der Regel eine Prüfung, ob die aktuelle Schätzung bestimmte Eigenschaften erfüllt, deren Auswahl jeweils von der vorliegenden Anwendung abhängig sind.

Die Ergebnisqualität lässt sich u. U. noch verbessern, beispielsweise über die Verwendung einer Gewichtungsmatrix, in der jedem Pixel ein Gewichtungsfaktor zugeordnet wird, welcher dessen Qualität widerspiegelt. Besonders schlechte Pixel oder sogar ganze Bereiche (z. B. an den Bildrändern) können somit über eine Gewichtung mit Faktor Null aus weiteren Iterationen ausgenommen werden. Weitere Verbesserungen lassen sich auch über die Einführung eines zusätzlichen Schwellwerts für die zulässige Abweichung der aktuellen Schätzung \hat{f} von der vorherigen Iteration erreichen. Wenn weitere Iterationen an denjenigen Stellen (bzw. Pixeln) unterdrückt werden, an denen dieser Schwellwert überschritten wird, lassen sich Bilddetails besser erhalten, während zugleich vermieden wird, dass Rauschen sowie “Ringing” weiter verstärkt werden.

5.1.3 Iterative blinde Entfaltung

Bei der *iterativen blinden Entfaltung* (“Iterative Blind Deconvolution”, IBD), wie in [Aye88] von Ayers und Dainty vorgeschlagen, handelt es sich im Prinzip um eine blinde Version der im vorangegangenen Abschnitt beschriebenen LRD. Das heißt, es werden weiterhin die Bezeichnungen aus Gleichung (5.1) verwendet. Entsprechend muss die (Filter-)Funktion h hierfür auch nicht bekannt sein, sondern lediglich der Träger von h . Überdies wird vorausgesetzt, dass f und h beide reellwertig und überall nicht-negativ sind. Bei der IBD wird die iterative Maximierung der LRD-Likelihood Function mit zusätzlichen Nebenbedingungen durchgeführt, um gleichzeitig mit der Schätzung \hat{f} für das Bild f auch eine Schätzung \hat{h} für die Filterfunktion h zu bestimmen.

Der IBD-Algorithmus zeichnet sich durch eine Rechenkomplexität der Größenordnung $\mathcal{O}(N \log N)$ pro Iteration aus, wobei N der Gesamtzahl der Pixel in

einem einzelnen Frame entspricht, während normalerweise mehr als eine Iteration für seine Konvergenz erforderlich ist. Insbesondere wird bei der IBD auch die Fourier-Phase mit berücksichtigt, anders als bei vergleichbaren iterativen Algorithmen, wie z. B. bei dem Verfahren von Lane und Bates [Lan87].

Die Abbildung 5.1 illustriert die generelle Struktur von Entfaltungsalgorithmen wie sie auch in [Aye88] beschrieben ist. Im Wesentlichen bestehen Entfaltungsalgorithmen aus einer vorgegebenen Anzahl von Iterationen der acht nachfolgend beschriebenen Schritte. Der Parameter k kennzeichnet dabei die jeweils k -te Iteration ($k \in \mathbb{N}_0$). Zuvor wird als Input allerdings noch eine initiale Schätzung $\hat{h}_0 \in \mathbb{R}^+$ (d. h. $k = 0$) für die Filterfunktion benötigt. Eine einfache Möglichkeit ist hierfür z. B. eine Bildmatrix, die über dem (als bekannt vorausgesetzten) Träger von h aus Einsen besteht.

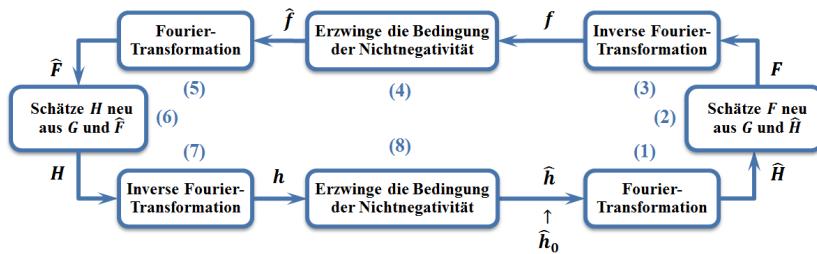


Abbildung 5.1: Grundlegender Ablauf eines Entfaltungsalgorithmus

Basis-Algorithmus für IBD

- (1) Fourier-Transformation zur Überführung des Problems in den Fourier-Raum:

$$\hat{h}_0(x, y) \Rightarrow \hat{H}_0(u, v) \text{ bzw. } \hat{h}_k(x, y) \Rightarrow \hat{H}_k(u, v)$$

- (2) Inverse Filterung liefert (neue) Schätzung für F , d. h.

$$F_0 = G / \hat{H}_0 \text{ bzw. } F_k = G / \hat{H}_k$$

- (3) Inverse Fourier-Transformation zur Rückkehr in den Ortsraum:

$$F_0(u, v) \Rightarrow f_0(x, y) \text{ bzw. } F_k(u, v) \Rightarrow f_k(x, y)$$

- (4) Erfüllung der Nichtnegativität im Bildbereich, indem alle Punkte der Schätzung f_0 bzw. f_k , die einen negativen Wert haben, auf Null gesetzt werden. Dies ergibt eine neue, positive Schätzung \hat{f}_0 bzw. \hat{f}_k für das ideale Bild f .
- (5) Erneute Fourier-Transformation:

$$\hat{f}_0(x, y) \Rightarrow \hat{F}_0(u, v) \text{ bzw. } \hat{f}_k(x, y) \Rightarrow \hat{F}_k(u, v)$$

- (6) Inverse Filterung liefert neue Schätzung für H , d. h.

$$H_1 = G/\hat{F}_0 \text{ bzw. } H_{k+1} = G/\hat{F}_k$$

- (7) Inverse Fourier-Transformation zur Rückkehr in den Ortsraum:

$$H_1(u, v) \Rightarrow h_1(x, y) \text{ bzw. } H_{k+1}(u, v) \Rightarrow h_{k+1}(x, y)$$

- (8) Erfüllung der Nichtnegativität, indem alle Punkte der Schätzung h_1 bzw. h_{k+1} mit negativem Wert, sowie alle Punkte außerhalb des Trägers auf Null gesetzt werden. Dies ergibt eine neue, positive Schätzung \hat{h}_1 bzw. \hat{h}_{k+1} für die Filterfunktion h .

Dabei bringt die inverse Filterung in den Schritten (2) und (6) natürlich die bereits in Abschnitt 5.1.1 diskutierten Probleme mit sich. Hinzu kommt, dass Nullen bei bestimmten Raumfrequenzen in F oder H dazu führen, dass in der Faltung dort keine Informationen vorhanden sind. Auch hat sich gezeigt ([Aye88]), dass die Bedingung der Nichtnegativität im Bildbereich in den Schritten (4) und (8) zu verbesserter Konvergenz führt, wenn zugleich bei jeder Iteration auf die Energieerhaltung (bzgl. der Intensitätsverteilung) geachtet wird. Dies lässt sich realisieren, indem die Summe der negativen Werte gleichmäßig über die jeweilige Schätzung umverteilt wird.

Für die eigentliche Bildentfaltung (des Originalbildes und der geschätzten PSF) wird jeweils der LRD-Algorithmus verwendet.

5.1.4 Entfaltung mittels Hauptkomponentenanalyse

Wie der IWF ist auch die *Entfaltung mittels Hauptkomponentenanalyse* (“Principal Component Analysis”, PCA), gemäß dem Ansatz von [Li07], ein direkter (also nicht-iterativer) Algorithmus und wird vergleichsweise schnell ausgeführt. Anders als beim IWF handelt es sich hier jedoch insbesondere

um eine blinde Methode, die je nach Variante nur minimale bzw. gar keine Zusatzinformationen (wie die Größe des Filter-Supports) vorab benötigt. Darüber hinaus ist der Algorithmus robust gegenüber weißem Rauschen. Die Bildunschärfe entfernt hochfrequente Komponenten aus einem Bild oder einer Bildsequenz, was bedeutet, dass die räumliche Varianz eines Bildes reduziert wird. Der PCA-Algorithmus zielt darauf ab, die durch atmosphärische (und systemische) Unschärfe verursachte Korrelation zwischen Bildmatrixspalten zu de-korrelieren, um so diese hochfrequenten Komponenten aus einem Bild oder einer Sequenz wiederherzustellen. Hierfür werden in [Li07] gleich zwei Implementierungen des Algorithmus vorgeschlagen, von denen die eine Version als wahrhaft blinde Entfaltung funktioniert, welche auf einer Folge von mehreren Bildern desselben Motivs (als *“Multiple Observations”* bezeichnet) operiert, auf Basis derer ein einzelnes Ausgabebild berechnet wird. Die andere Version operiert direkt auf Einzelbildern (*“Single Observations”*) und benötigt ebenso wie die IBD zusätzliche Informationen über die Größe des Trägers der Filterfunktion. In [Gre08] wird zusätzlich noch eine Verallgemeinerung des ursprünglichen Algorithmus vorgeschlagen.

Es wird das folgende Modell für die Turbulenzbedingten Störungen zugrunde gelegt, wobei hier die Bezeichnungen (wie sie speziell auch in [Gre08] und [Hue08] verwendet wurden) etwas angepasst wurden, um die Konsistenz mit der zuvor verwendeten Notation so gut wie möglich zu wahren:

$$g_m(x, y) = h_m(x, y) * f(x, y) + n_m(x, y), \quad (m = 1, 2, \dots, M) \quad (5.9)$$

Das bedeutet, es gibt eine Anzahl von M durch Turbulenz gestörte *Beobachtungen* (d. h. Bildaufnahmen) g_m von derselben Szene (mit der ungestörten Abbildung f), wobei sich die Filterfunktion h ebenso wie die Rauschkomponente n mit der Zeit verändern, so dass diese für jede der Beobachtungen etwas unterschiedlich sind (d. h. $h = h_m$ und $n = n_m$).

Hierbei sollte angemerkt werden, dass die Beobachtungen zeitlich nicht zu weit auseinanderliegen sollten (z. B. im Millisekundenbereich), da der Algorithmus von der Prämisse ausgeht, dass das ungestörte Bild für alle M Beobachtungen identisch ist. Dies gilt vor allem, falls bewegte Objekte in der beobachteten Szene enthalten sind (speziell hierzu sei auf Abschnitt 4 über Bewegungskompensation verwiesen).

(A) PCA - “Multiple Observations”

Bei dem PCA-Ansatz für “Multiple Observations” (MO) werden die M Beobachtungen g_1, \dots, g_M zunächst vektorisiert, d. h. in Vektoren $\vec{g}_1, \dots, \vec{g}_M$ der Länge L umgeformt ($L = RC$, wobei R, C wieder die Bilddimensionen bezeichnen). Die Vektoren $\vec{g}_1, \dots, \vec{g}_M$ können als Realisierungen voneinander unabhängiger Zufallsvektoren $\{\vec{G}_1, \vec{G}_2, \dots, \vec{G}_M\} \in \mathbb{R}^L$ mit identischen Verteilungen und dem Mittelwert $\mu_{\vec{G}}$ betrachtet werden.

Der Algorithmus sucht nun eine lineare Transformation \vec{s} ($\vec{s} \in \mathbb{R}^M$) für die Zufallsvektoren \vec{G}_m , ($m = 1, \dots, M$), welche die Varianz des Ergebnisses, d. h. der Schätzung \hat{F} , maximiert. Dazu muss die folgende Kostenfunktion $K(\vec{s})$ maximiert werden ([Li07]):

$$K(\vec{s}) = \left\langle (\hat{F} - \mu_{\hat{F}})^T (\hat{F} - \mu_{\hat{F}}) \right\rangle \quad (5.10)$$

Die Schätzung für das ungestörte Bild f wird dabei durch eine Realisierung \hat{f} des Zufallsvektors \hat{F} repräsentiert, wobei insbesondere gilt: $\mu_{\hat{F}} = \mu_{\vec{G}}$. Den korrespondierenden Zufallsvektor \hat{F} gewinnt man mit Hilfe der folgenden linearen Transformation:

$$\hat{F} = [\vec{G}_1 - \mu_{\vec{G}}, \vec{G}_2 - \mu_{\vec{G}}, \dots, \vec{G}_M - \mu_{\vec{G}}] \vec{s} + \mu_{\vec{G}} \quad (5.11)$$

Unter Einführung der Variablen X und A lässt sich die Kostenfunktion $K(\vec{s})$ vereinfacht ausdrücken:

$$K(\vec{s}) = \vec{s}^T A \vec{s}$$

Dabei gelten für die Variablen X und A die folgenden Definitionen:

$$\begin{aligned} X &:= [\vec{G}_1 - \mu_{\vec{G}}, \vec{G}_2 - \mu_{\vec{G}}, \dots, \vec{G}_M - \mu_{\vec{G}}] \\ A &:= \langle X^T X \rangle \end{aligned}$$

Derartige Maximierungsprobleme (sowie entsprechende Lösungsmethoden) sind in der Literatur weit verbreitet [Jen79]. Im vorliegenden Fall handelt es sich bei der Lösung \vec{s} um einen Vektor der Länge M . Für die Bestimmung von \vec{s} müssen zunächst die Eigenwerte $\{\alpha_m\}$ sowie die zugehörigen Eigenvektoren $\{\vec{v}_m\}$, ($m = 1, \dots, M$) für die folgende Gleichung berechnet

werden:

$$\hat{A} \vec{v}_m = \alpha_m \vec{v}_m \quad (5.12)$$

Dabei wurden die folgenden Definitionen verwendet:

$$\begin{aligned} \hat{A} &:= \vec{x}^T \vec{x} \\ \vec{x} &:= [\vec{g}_1 - \hat{\mu}_{\vec{G}}, \dots, \vec{g}_M - \hat{\mu}_{\vec{G}}] \\ \hat{\mu}_{\vec{G}} &:= \frac{1}{M} \sum_{m=1}^M \vec{g}_m \end{aligned}$$

Das heißt, \hat{A} ist eine (skalierungsinvariante) Stichprobenschätzung von A , und bei $\hat{\mu}_{\vec{G}}$ handelt es sich um die mittlere Stichprobenschätzung von $\mu_{\vec{G}}$. Die Lösung des Maximierungsproblems für M gestörte Beobachtungen ergibt sich aus dem maximalen Eigenwert α_1 und dem zugehörigen Eigenvektor \vec{v}_1 :

$$\begin{cases} K(\vec{s} = \vec{v}_1) = \alpha_1 \\ \hat{f} = \vec{x} \vec{v}_1 + \hat{\mu}_{\vec{G}} \end{cases} \quad (5.13)$$

Die lineare Transformation \vec{s} kann als Hochfrequenzfilterung betrachtet werden, welche es ermöglicht, die maximale räumliche Varianz innerhalb der M gestörten Eingangsbilder (d. h. Beobachtungen) zu extrahieren. Ziel dabei ist es, die hochfrequenten Komponenten, die zuvor durch den Blurring-Filtereffekt der turbulenten Atmosphäre entfernt wurden, so gut wie möglich wiederherzustellen. Die Schätzung \hat{f} in Gleichung (5.13) entspricht dem Rekonstruktionsergebnis des unbekannten idealen Bilds f nach blinder Entfaltung.

(B) PCA - “Single Observations”

Der PCA-Ansatz für “Single Observations” (SO) benötigt zusätzlich die Information über die Größe des Trägers der Filterfunktion, wobei jedoch nur ungerade Filtergrößen berücksichtigt werden. Zwar folgt diese Algorithmus-Variante im Grunde dem MO-Ansatz, die erforderliche Anzahl von M Beobachtungen wird aber künstlich erzeugt über Verschiebungen des Eingangs-

bildes (ganzzahlige ungerade Pixel-Shifts), wobei M gleich der Pixelanzahl im Träger der Filterfunktion ist.

5.2 Resultate

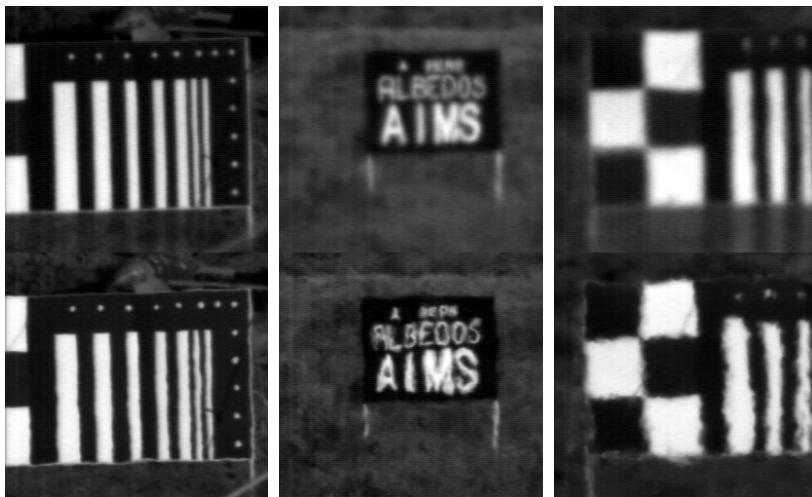
Eine ausführliche Evaluation der Leistungsfähigkeit dieser Algorithmen wurde in [Gre08] anhand von simulierten Turbulenzdaten (d. h. mit vorliegenden "Ground Truth"-Daten) durchgeführt, während in [Hue08] eine entsprechende Evaluierung anhand von realen Turbulenzdaten unterschiedlichen Schweregrades (ohne "Ground Truth"-Daten) vorgenommen wurde, von denen hier im folgenden einige repräsentative Ergebnisse gezeigt werden.

5.2.1 Spezifikation der Testdaten und Instrumente

Die nachfolgend als Testsequenzen verwendeten Bildsequenzen wurden unter verschiedenen Turbulenzbedingungen aufgezeichnet, welche von relativ leichter bis sehr starker Turbulenz reichen. Sie wurden aus insgesamt über 100 Videosequenzen ausgewählt, die vom damaligen FGAN-FOM³ im Rahmen einer NATO Messkampagne der RTG 40 auf der "White Sands Missile Range" in New Mexico, USA, im Jahr 2005 aufgezeichnet wurden [Rep06]. Beispielbilder der ausgewählten Sequenzen sind in der Abbildung 5.2 zu sehen.

Alle Sequenzen hatten jeweils eine Länge von 1000 Einzelbildern und eine Bildauflösung von 240×256 Pixeln, wobei jede Sequenz ein Paneel mit einem Testmuster zeigt, welches in einer Entfernung von 1 km von der Optik angebracht ist. Die Sequenzen wurden jeweils paarweise ausgewählt, so dass jedes der insgesamt drei Sequenzpaare ein unterschiedliches Musterpaneel zeigt. Die jeweiligen Aufnahmezeiten der Sequenzen eines solchen Paares lagen dabei nicht mehr als max. 10 Minuten auseinander, so dass man von nahezu identischen Turbulenz- (und Licht-)Bedingungen ausgehen kann.

³ FGAN-FOM: früherer Name des Ettlinger Teils des heutigen Fraunhofer IOSB (FGAN: ForschungsGesellschaft für Angewandte Naturwissenschaften, FOM: Forschungsinstitut für Optronik und Mustererkennung)



Oben: Seq. 1(7:15),
unten: Seq. 2 (7:20).

Oben: Seq. 4(7:48),
unten: Seq. 3 (7:48).

Oben: Seq. 6(8:22),
unten: Seq. 5 (8:12).

Abbildung 5.2: Testsequenzen (v.l.n.r.) mit leichter, mittlerer und starker atmosphärischer Turbulenz; oben: extrem kurze Integrationszeit (Seq. 1 u. 3: <0,1 ms, Seq. 5: 0,045 ms), unten: 1 ms Integrationszeit.

Ein wesentliches Auswahlkriterium war insbesondere die unterschiedliche Belichtungszeit, welche für eine Sequenz jeden Paars immer bei 1,0 ms (Kurzzeit-Belichtung) lag und für die andere Sequenz unter 0,1 ms (extrem kurze Belichtungszeit). Generell sind kurze Integrationszeiten von Vorteil, weil dies bedeutet, dass die Turbulenz gewissermaßen eingefroren ist. In der Regel geht man davon aus, dass dies bereits bei Aufnahmen in der Größenordnung von wenigen Millisekunden der Fall ist [Rog96]. Ein Vergleich der Sequenzen mit extrem kurzer Integrationszeit (<0,1 ms, jeweils oben in der Abbildung 5.2) zeigt, dass die Geometrie der abgebildeten Objekte korrekter wiedergegeben wird als bei der etwas längeren Integrationszeit (1,0 ms), unten in Abbildung 5.2. Dabei fällt auf, dass diese Sequenzen trotz der verbesserten Geometrie mehr Unschärfe aufweisen. Das liegt darin begründet, dass nur größere (und langsamere) Turbulenzzellen tatsächlich im Bild ein-

gefroren sind, welche insbesondere ja die Ursache für turbulenzbedingte Bildverformungen sind (s. a. Abschnitt 1.1). Je kleiner die Turbulenzzellen sind, desto schneller bewegen sie sich, insbesondere sehr kleine Turbulenzzellen in der Größenordnung ≤ 1 Pixel. Das Resultat erscheint als eine gleichförmige Unschärfe des ganzen Bildes.

Um nicht nur geometrisch rechtwinklige Muster zu berücksichtigen, deren Rekonstruktion u. U. leichter fällt, wurden ganz bewusst die Sequenzen 3 und 4 selektiert, in denen stattdessen eine Tafel mit einem Schriftzug abgebildet ist, der sowohl diagonale als auch runde Strukturen beinhaltet. Es sollte noch erwähnt werden, dass die Nummerierung der Sequenzen 1-7 rein chronologisch gemäß ihrer Aufnahmzeit vorgenommen wurde.

Zum Setup des Experiments ist zu sagen, dass der Ausbreitungsweg in einer Höhe von ca. 1,8 m parallel zum Boden verlief. In der gleichen Höhe wurden gleichzeitig Messungen von C_n^2 , dem Strukturparameter der Schwankungen im Brechungsindex der Luft durchgeführt, so dass für jede der Sequenzen korrespondierende Werte vorliegen. Für diese Messungen wurde ein Scintec BLS900 Szintillometer verwendet. Alle Bilddaten wurden von einer Photron Fastcam PCI-R2 Kamera mit einer Auflösung von 240×256 Pixeln mit einem Texas Instruments TC237B CCD-Sensor mit Progressive Scan und einer Nikon Nikkor ED 800 Optik mit 800 mm fester Brennweite aufgezeichnet. Für die Sequenzen wurde in den Fällen extrem kurzzeitiger Integrationszeit ($<0,1$ ms) die (bestmögliche) Blendenskala $f/5,6$ verwendet und entweder $f/16$ oder $f/22$ für die restlichen Sequenzen. Alle wesentlichen Daten für die ausgewählten Sequenzen sind noch einmal in der Tabelle 5.2 zusammengefasst, einschließlich der Daten für eine zusätzliche Sequenz, die während der Mittagshitze aufgezeichnet und wegen der zu diesem Zeitpunkt besonders starken Turbulenz ausgewählt wurde.

Der Fried-Parameter r_0 in der Tabelle wurde mithilfe der Gleichung (3.26) berechnet, wobei L der Entfernung zwischen dem abgebildeten Objekt (d. h. der jeweiligen Mustertafel) und dem Sensor (d. h. dem Kameraobjektiv) entspricht. Unter Verwendung der aus der Optik wohlbekannten Beziehung $f_{\text{nr}} = f/D$ (d. h. $D = f/f_{\text{nr}}$) zwischen der Blendenzahl f_{nr} , der Apertur D und der Brennweite f , wurde damit auch die Turbulenzstärke D/r_0 bestimmt. Die Größen "Kantenbreite", "Gauß-PSF" und "Noise" in der Tabelle 5.2 beziehen sich dagegen auf geschätzte Parameter, da ja sowohl für den IWF als auch für den LRD-Algorithmus eine Schätzung der PSF als Input be-

Uhrzeit	0715	0720	0745	0748	0812	0822	1307
Belichtung (sec)	1/11000	1e-3	1e-3	1/11000	1e-3	1/22000	1e-3
Blendenzahl	5.6	16	22	5.6	22	5.6	16
Brennweite (mm)	800	800	800	800	800	800	800
Frames	1000	1000	1000	1000	1000	1000	1000
Auflösung (px)	240×256	240×256	240×256	240×256	240×256	240×256	240×256
Entfernung (km)	1	1	1	1	1	1	1
C_n^2 (m/s ²)	4e-15	2,36e-15	5,09e-14	4,85e-14	9,3e-14	1,23e-13	7,56e-13
r_0 (cm)	7,02	9,64	1,52	1,57	1,06	0,89	0,3
D/r_0	2,034	0,512	2,382	9,091	3,412	15,889	16,532
Kantenbreite (px)	3	3	5	5	5	7	9
Gauß-PSF (σ)	1.0	1.0	1.5	1.5	3.0	4.5	9.5
Noise (σ)	0,0036	0,0076	0,0054	0,0052	0,0437	0,0088	0,0011

Tabelle 5.2: Eckdaten der Testsequenzen, zeitlich geordnet

nötigt wird. In den nachfolgend gezeigten Beispielen wurde die einfachste Approximation für eine solche atmosphärische Filterfunktion verwendet, d. h. ein Gauß-Filter. Dies ist eine durchaus sinnvolle Annahme, da die optische Turbulenz im Wesentlichen als Tiefpassfilter wirkt, welcher die hohen Ortsfrequenzen herausfiltert, wodurch scharfe Kanten und punktförmige Objekte verwischt werden. Das Hauptproblem besteht darin, die richtige Filtergröße in Bezug auf den Mittelwert μ und die Standardabweichung σ zu schätzen. Wird σ zu groß gewählt, führt dies zu sogenannten “Ringing”-Effekten (siehe Anmerkungen in Abschnitt 5.4.3), und falls es zu klein gewählt wird, bleibt zu viel Unschärfe im Ergebnis zurück. Da bereits zuvor in [Rep08] für jede der Sequenzen entsprechende Statistiken über die Turbulenzbedingungen erstellt und mit speziellem Fokus auf die Verbreiterung der Kanten in Abhängigkeit von der Turbulenzstärke ausgewertet worden waren, konnten diese Informationen über die Kantenverbreiterung mit den gemessenen C_n^2 -Werten korreliert werden und daraus geeignete σ -Werte abgeleitet werden. Natürlich gibt es auch andere Möglichkeiten zur PSF-Schätzung. Unter anderem lässt sich die zugehörige theoretische (mittlere) PSF bestimmen (Näheres dazu in Abschnitt 6.2).

5.2.2 Entfaltungsergebnisse im Vergleich

Bei der LRD wie auch der IBD besteht die Möglichkeit, Zusatzinformationen über die Rauschcharakteristiken der Daten einfließen zu lassen. Hier wurde zur Noise-Abschätzung die zeitliche Varianz einer Bildregion mit homogenen Grauwerten verwendet. Zur Rauschreduktion wurde darüber hinaus ein gleitender Mittelwert ("Average") von je 100 Frames als Basis für die Entfaltung verwendet. Dies ist relativ unkritisch, da es sich um statische Szenen handelt, die zudem mit einer hohen Frequenz aufgenommen wurden. Dennoch gehen feine Strukturen bei dieser Art der Mittelwertbildung verloren. Zur Erhaltung solcher Details wurde daher auch ein (gleitender) temporaler Median von je 100 Frames mit den Entfaltungsalgorithmen getestet.

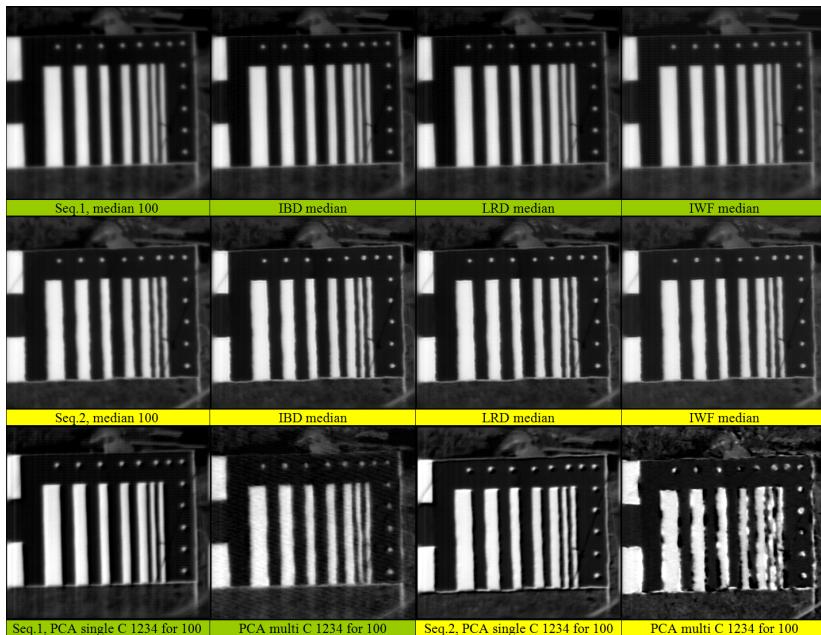


Abbildung 5.3: Beispielergebnisse für Seq. 1 (grün markiert) u. Seq. 2 (gelb).

1.+2. Reihe (v.l.n.r.): temp. Median von 100 Frames, Entfaltungsergebnisse für IBD, LRD und IWF; unten: Ergebnisse für PCA-basierte Entfaltung (SO- und MO-Version) jeweils für alle vier HK (1 + 2 + 3 + 4).



Abbildung 5.4: Beispielergebnisse für Seq. 3 (grün markiert) u. Seq. 4 (gelb). 1.+2. Reihe (v.l.n.r.): temp. Median von 100 Frames, Entfaltungsergebnisse für IBD, LRD und IWF; unten: Ergebnisse für PCA-basierte Entfaltung (nur SO-Version) für verschiedene HK (1 + 4), (2 + 3), (1 + 2 + 3 + 4).

Tatsächlich ist das Ergebnis dieses Medians ein wenig besser als das des Mittelwerts. Aber da die Unterschiede zwischen Mittelwert und Median visuell kaum wahrnehmbar sind (insbesondere bei den Sequenzen 1 bis 6), werden in den nachfolgenden Abbildungen 5.3, 5.4 und 5.5 nur einige repräsentative Ergebnisse gezeigt, die aus dem Medianbild resultieren.

Die Ergebnisse sind paarweise angeordnet, d. h. die Abbildung 5.3 enthält repräsentative Entfaltungsergebnisse für die Sequenzen 1 und 2 (7.15 Uhr und 7.20 Uhr) mit moderater Turbulenz. Die Abbildung 5.4 enthält korrespondierende Ergebnisse für die Sequenzen 3 und 4 (7.45 Uhr und 7.48 Uhr) mit mittlerer bis starker Turbulenz. Die Abbildung 5.5 enthält schließlich Ergebnisse für die Sequenzen 5 und 6 (8.12 Uhr und 8.22 Uhr) mit starker

Turbulenz. Die Bildunterschriften sind farblich entsprechend unterlegt, um die Zuordnung der Ergebnisse zu den einzelnen Sequenzen zu erleichtern. Jeder Satz an Entfaltungsergebnissen beinhaltet den zeitlichen Median von 100 Frames als Referenz (d. h. als Input für die Algorithmen), sowie die zugehörigen Restaurierungsergebnisse für IWF, LRD und IBD.

Für die PCA-basierte Entfaltung sind in erster Linie Ergebnisse der SO-Version abgebildet für verschiedene Hauptkomponenten (HK). Dabei bedeutet "C 23" beispielsweise, dass speziell die Komponenten 2 und 3 ausgewertet wurden unter Verwendung der in [Gre08] hergeleiteten Verallgemeinerung. Hintergrund für die scheinbare Inkonsistenz bei der Auswahl der Haupt-

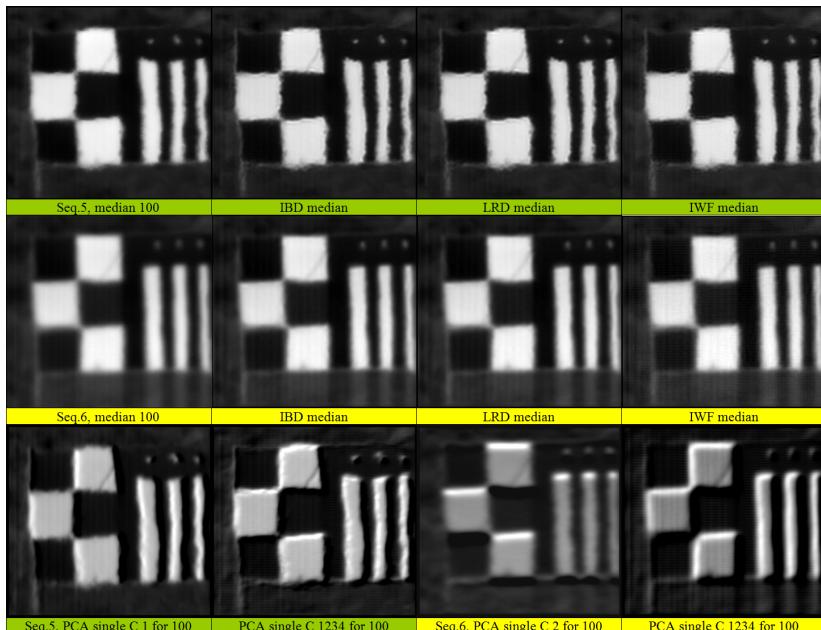
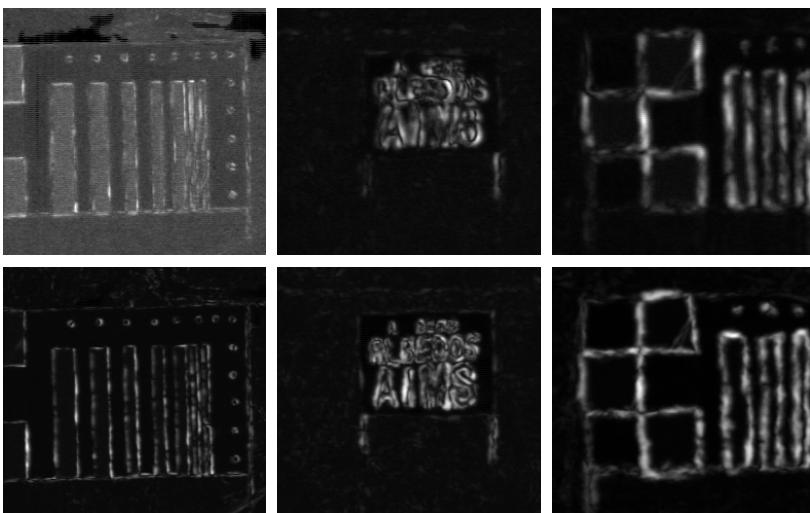


Abbildung 5.5: Beispielergebnisse für Seq. 5 (grün markiert) u. Seq. 6 (gelb). 1.+2. Reihe (v.l.n.r.): temp. Median von 100 Frames, Entfaltungsergebnisse für IBD, LRD und IWF; unten: Ergebnisse für PCA-basierte Entfaltung (nur SO-Version) für verschiedene HK (1), (2), (1 + 2 + 3 + 4).

komponenten war die unterschiedliche und teilweise schlechte Qualität der Ergebnisse, weshalb hier auch nur für die Sequenzen 1 und 2 Ergebnisse für beide Versionen (d. h. SO und MO) abgebildet sind.

Zur Visualisierung des turbulenzbedingten Bewegungsinhalt in den gemessenen Daten, enthält die Abbildung 5.6 die zeitliche Standardabweichung (STD) der Sequenzen 1 bis 6, jedes Mal betrachtet über die gesamte Sequenzlänge (1000 Frames). Dazu wurden die Grauwerte jeweils auf das Intervall $[0,1]$ skaliert, was insbesondere das etwas unterschiedliche Aussehen für die STD in der Sequenz 1 erklärt. Die Breite der Kanten (gemessen in Pixeln) lässt entsprechende Rückschlüsse darauf zu, wie große turbulenzbedingte Bewegungen aus statistischer Sicht zu erwarten sind, und wie groß (in Pixeln) der Support für die atmosphärische PSF folglich sein muss.



Oben: Seq. 1(7:15),
unten: Seq. 2 (7:20).

Oben: Seq. 4(7:48),
unten: Seq. 3 (7:45).

Oben: Seq. 6(8:22),
unten: Seq. 5 (8:12).

Abbildung 5.6: Standardabweichung der Testsequenzen (v.l.n.r.) mit leichter, mittlerer und starker atmosphärischer Turbulenz; oben: extrem kurze Belichtung (Seq. 1 u. 3: $<0,1$ ms, Seq. 5: 0,045 ms), unten: 1 ms Belichtung.

5.2.3 Spezialfall: stark anisoplanatische Turbulenz

Der Fokus in dieser Arbeit liegt zu einem nicht unbeträchtlichen Teil auf starker und real gemessener Turbulenz. Aus diesem Grund wurde, wie im Abschnitt 5.2.1 zuvor erwähnt, zusätzlich die Testsequenz 7 selektiert, die in der Mittagshitze unter stark anisoplanatischen Turbulenzbedingungen aufgenommen wurde (Aufnahmemezeit 13:07 Uhr). Beispieldaten hierfür sind nachfolgend in den Abbildungen 5.7 und 5.8 abgebildet.

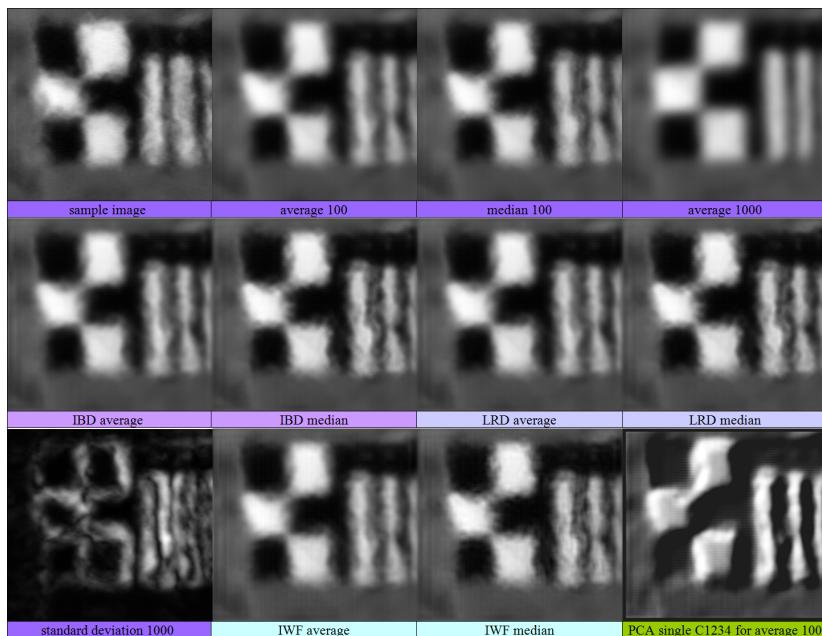


Abbildung 5.7: Beispieldaten für Seq. 7, Teil 1: IBD, LRD u. IWF.

Oben (v.l.n.r.): Einzelframe, Mittelwert u. Median (je 100 Fr.), MW (1000 Fr.); Mitte: IBD- u. LRD-Ergebnisse jeweils für MW u. für Med. (je 100 Fr.); unten (v.l.n.r.): STD σ (1000 Fr.), IWF-Ergebnisse für MW u. Med. (100 Fr.), Ergebnis für PCA (SO) für alle vier HK (1 + 2 + 3 + 4).

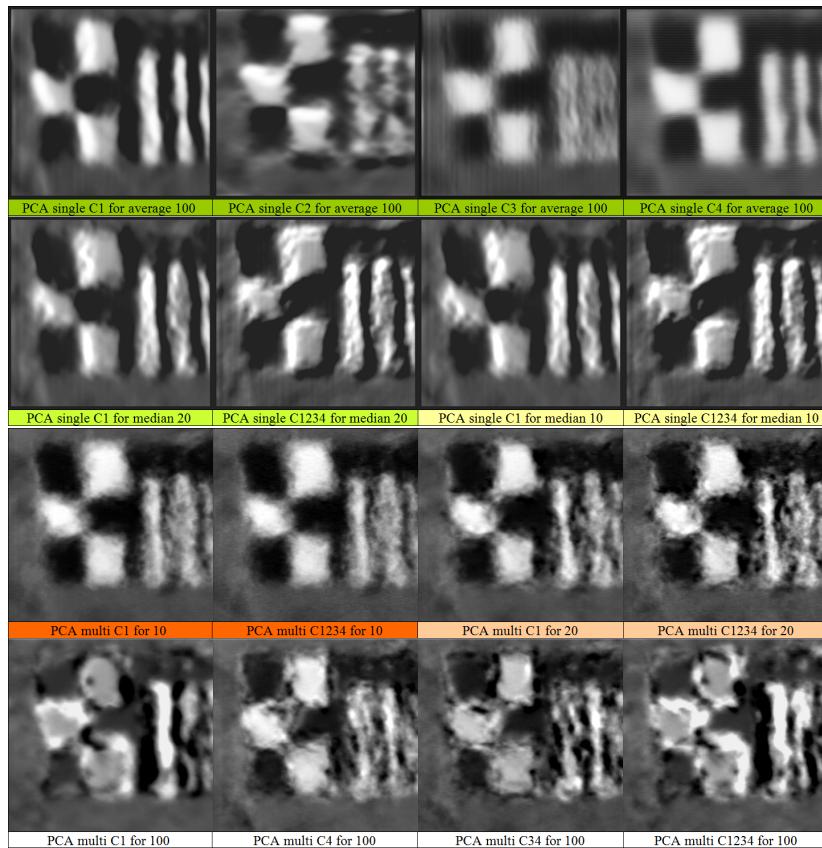


Abbildung 5.8: Beispieldaten für Seq. 7, Teil 2: Entfaltung mit PCA.
1.+2. Reihe: SO-Version; 1. Reihe: Ergebnisse für jede der 4 HK für MW
(100 Fr.); 2. Reihe: Ergebnisse für 1. HK u. alle 4 HK für Med. (20 Fr. u. 10 Fr.).
3.+4. Reihe: MO-Version; 3. Reihe: Ergebnisse für 1. HK u. alle 4 HK für Med.
(20 Fr. u. 10 Fr.); 4. Reihe: Ergebnisse für HK (1), (4), (3 + 4) u. alle 4 HK.

5.3 Evaluierung

Am Einzelbild der Sequenz 7 in der Abbildung 5.7 (1. Reihe, ganz links) fällt besonders der scheinbare *Raucheffekt* (oder *Wolkeneffekt*) auf, der sich erst bei mittlerer oder starker Turbulenz beobachten lässt. Dieser Effekt macht sich vorwiegend in den Grenzbereichen zwischen hellen und dunklen Musteranteilen bemerkbar und resultiert daraus, dass das einfallende Licht von größeren Turbulenzzellen (d. h. $> r_0$ aber $< D$) abgelenkt und über die (Farb-)Grenzen in benachbarte Bildregionen hinein gestreut wird. Dadurch entsteht in eigentlich homogen schwarzen bzw. weißen Bildbereichen ein Farbgemisch an Grautönen, und es bilden sich Strukturen, Rauchschwaden ähnlich, mit höheren (Raum-)Frequenzanteilen und größerer Standardabweichung (STD). Diese unechten, durch Turbulenz erzeugten Strukturen stellen besondere Herausforderungen für Korrekturverfahren dar und können unerwünschte Artefakte in den Ergebnissen verursachen.

Erwartungsgemäß sind die Ergebnisse für die Sequenzen 1, 4 und 6 mit einer ultra-kurzen Belichtungszeit ($< 0,1$ ms) generell exakter hinsichtlich der zugrundeliegenden Geometrie der abgebildeten Szene, siehe die Abbildungen 5.3, 5.4 und 5.5. Währenddessen sehen die Ergebnisse der Sequenzen 2, 3, 5 und 7 mit etwas längerer Belichtungszeit (1 ms) entsprechend schärfer aus, weisen einen vergleichsweise höheren Kontrast auf und enthalten mehr Details.

Die Ergebnisqualität von IBD, LRD und IWF ist weitgehend ähnlich, und die zumeist geringfügigen Unterschiede lassen sich in erster Linie mit der geschätzten (Gauß-)PSF begründen, die für die nicht-blinden Methoden (IWF und LRD) verwendet wurde. Die Qualität der Ergebnisse für die PCA-basierte Entfaltung variiert hingegen signifikant, was speziell für die MO- aber auch für die SO-Version des Algorithmus gilt.

5.3.1 Diskussion: IWF, LRD und IBD

Größtenteils lassen sich die Ergebnisse von IBD, LRD und IWF kaum unterscheiden und bieten für die Sequenzen 1, 2, 5 und 6 vergleichsweise wenig Verbesserung gegenüber dem Median-Referenzbild, das als Basis für die Entfaltung verwendet wurde. Dagegen sind die Unterschiede in den Sequenzen 3 und 4 deutlicher ersichtlich. Speziell in der Sequenz 3 liefert

der IWF die beste Auflösung insofern, dass dieser als einziger die erste Textzeile "A BEAR" lesbar aufzulösen vermag. Davon abgesehen ist es allerdings der IBD-Algorithmus, der für die Sequenzen 3 und 4 das schärfste Ergebnis liefert, während der LRD-Algorithmus das glatteste Ergebnis liefert (besser erkennbar in der originalen Bildgröße), ohne zugleich unscharf wie die PCA-Ergebnisse zu sein. Für alle anderen Sequenzen (einschließlich Sequenz 7) sehen IBD- und LRD-Resultate im Wesentlichen gleich aus. Dies in Verbindung mit den zufriedenstellenden IWF-Ergebnissen bedeutet, dass die verwendeten (Gauß-)PSF-Schätzungen durchaus annehmbare Näherungen darstellen.

Es sollte noch erwähnt werden, dass die Anzahl an Iterationen für die LRD und IBD bewusst gering (d. h. 5-10 Iterationen) gehalten wurde. Ein spezieller Aspekt dieser Untersuchung war das Potential für Echtzeitfähigkeit der getesteten Algorithmen, wobei jede zusätzliche Iteration in dieser Hinsicht wertvolle Zeit kostet. Aus diesem Grund wurde eine qualitative Untersuchung darüber durchgeführt, wie viele Iterationen zu einem gegebenen Datensatz mindestens erforderlich sind, um ein akzeptables Ergebnis zu erzielen. Hinzu kamen rein praktische Erwägungen, denn aufgrund der hohen Framerate, mit der die Sequenzen aufgezeichnet wurden, lag insgesamt eine verhältnismäßig große Menge an Rohdaten vor, die mit mehreren verschiedenen Parametersätzen verarbeitet werden musste.

Bezüglich des verwendeten Rauschparameters konnte weder eine Verbesserung noch eine Verschlechterung festgestellt werden gegenüber den Ergebnissen, in denen das Rauschen zu Null angenommen wurde. Dies liegt aller Wahrscheinlichkeit nach daran, dass der Rauschparameter in den untersuchten Fällen ohnehin sehr gering ausfiel (s. a. Tabelle 5.2) weil als Basis für die Entfaltung der Mittelwert (bzw. Median) einer relativ großen Anzahl an Frames (z. B. 100 Frames) verwendet wurde, wodurch das ursprünglich enthaltene Rauschen in den Daten entsprechend reduziert wurde.

5.3.2 PCA: Multiple Observation und Single Observation

Wie eingangs bereits erwähnt, kann der durch Turbulenz bedingte Wolkenefekt eine beeinträchtigende Wirkung auf Korrekturverfahren haben, speziell auf die hier vorgestellten Entfaltungsverfahren. Die PCA-basierte Entfaltung ist hierfür besonders anfällig, wie die entsprechenden Ergebnisse in den

Abbildungen 5.3 bis 5.8 zeigen, wobei die MO-Version des Algorithmus deutlich stärker beeinträchtigt wird als die SO-Version. Dies liegt u. a. daran, dass hierin, anders als bei allen anderen Methoden, die unveränderten Rohdaten verwendet wurden. Das heißt, es wurde keine temporale Mittelwert- oder Median-Filterung zur Glättung der Daten durchgeführt (mit entsprechender Reduktion des Raucheffekts). Stattdessen wurden bestehende Varianzen zwischen den Einzelbildern maximiert.

Die PCA-basierte Entfaltung (in beiden Varianten) gehört zu denjenigen Algorithmen, die den Kontrast eines Bildes anhebt und höhere Frequenzanteile (z. T. extrem) verstärkt. Dadurch wird sie anfällig für die Verstärkung von Rauschen, was zu unnatürlichen Hochfrequenzkomponenten und hohem Kontrast führt. Die Ergebnisse in den beiden untersten Reihen von Abbildung 5.8 verdeutlichen, dass sich dies nicht notwendigerweise positiv auswirkt. Insbesondere werden starker Kontrast und hohe Frequenzanteile von zahlreichen (Bild-)Qualitätsmetriken als positiv bewertet.

Wie das letzte Bild (d. h. ganz unten rechts) in der Abbildung 5.3 mit moderater Turbulenz bereits anmuten lässt, ist die originale MO-Version für anisoplanatische Bedingungen eher ungeeignet. Zwar erscheint das Ergebnis durchaus scharf, und einige Details sind tatsächlich besser erkennbar (z. B. das Seil rechts unten im Bild, Objekte im Hintergrund), dennoch sind es die fälschlich erhaltenen Deformationen, die das Endergebnis dominieren. Wie sehr zunehmende Turbulenz diesen Effekt noch negativ verstärkt verdeutlicht die Abbildung 5.8. Dabei kann die MO-Version bei schwacher Turbulenz durchaus gute Ergebnisse liefern, wie unter anderem in [Li07] und [Gre08] gezeigt. Betrachtet man vor allem die zugrundeliegende Geometrie der abgebildeten Mustertafeln, stellt sich allerdings heraus, dass sich die Ergebnisse mit zunehmender Turbulenzstärke immer mehr verschlechtern. Wie die Abbildung 5.3 erkennen lässt, wirkt sich dies bereits bei moderater Turbulenz signifikant aus. Bei starker Turbulenz wie in Sequenz 7 versagt die MO-Variante des Algorithmus bei 100 Eingabebildern sogar völlig, wie speziell die unterste (4.) Bildreihe in der Abbildung 5.8 demonstriert. Die entsprechenden Ergebnisse (in der 3. Reihe) mit reduzierter Anzahl an Eingabebildern, d. h. nur 10 oder 20, fallen etwas besser aus. Deren Qualität reicht dennoch nicht an die der anderen Entfaltungsalgorithmen heran oder auch nur an die des einfachen temporalen Medians oder Mittelwert (bei gleicher Anzahl an Eingabebildern).

Die Ergebnisse der SO-Version des PCA-Algorithmus schneiden dagegen verhältnismäßig gut ab. Bei schwacher Turbulenz wurden damit sogar die besten Ergebnisse erzielt, z. B. für die Sequenzen 1 und 2 (siehe Abbildung 5.3, unterste Reihe). Besonders überzeugt die Fähigkeit des Algorithmus, horizontale und vertikale Linien gut aufzulösen. Dies ist auch bei moderaten und sogar bei starken Turbulenzbedingungen der Fall, wie die Ergebnisse für die Sequenzen 5 bis 7 belegen (siehe Abbildungen 5.5, 5.7 und 5.8). Interessanterweise funktioniert diese Methode nicht so gut für die feineren, teilweise organischen Strukturen und runden Konturen, wie sie in den Sequenzen 3 und 4 enthalten sind (siehe Abbildung 5.4). Dies liegt vor allem an einer horizontalen bzw. vertikalen Verstärkung, die den ersten Hauptkomponenten (HK) inhärent ist. Die 1. Bildreihe in der Abbildung 5.8 veranschaulicht die charakteristische Gestalt der vier einzelnen HK am Beispiel von Sequenz 7. Daran lässt sich erkennen, dass die 1. HK eine besonders starke vertikale Ausprägung aufweist, während die 2. HK deutlich horizontal ausgerichtet ist. Die 3. und 4. HK weisen ebenfalls vertikale und horizontale Strukturen auf, allerdings in einer kleineren Größenordnung. Dem PCA Prinzip nach sollte grundsätzlich die 1. HK das beste Ergebnis liefern. Die Anwendung hat allerdings gezeigt, dass es in der Realität zumeist Kombinationen mehrerer Komponenten waren, die zu einem gegebenen Testdatensatz tatsächlich die besten Ergebnisse liefern konnten.

Auffällig ist bei der SO-Version zudem ein scheinbarer 3-D Eindruck. Betrachtet man z. B. das letzte Ergebnis für die Sequenz 6 in der Abbildung 5.5, lässt sich eine gerichtete Kontrastverstärkung an den Kanten im Bild erkennen. Die weißen Quadrate und Streifen des Schachbrettmusters auf der Mustertafel erscheinen in der Hauptsache hellgrau, wobei die Kanten oben und links (fast) weiß sind, während die Kanten unten und rechts (fast) schwarz sind. Dies vermittelt fälschlicherweise den optischen Eindruck, dass die weißen Areale nach vorne aus der Mustertafel herausragen. Dieser unerwünschte 3-D Effekt hängt zum einen mit der horizontalen bzw. vertikalen Ausprägung der Hauptkomponenten zusammen, und zum anderen damit, dass die erforderliche Anzahl von Beobachtungen anhand von Verschiebungen des Eingangsbildes künstlich erzeugt wurde. Die Stärke dieses Effekts ist insbesondere von der (geschätzten) Größe des PSF-Supports (entspricht der Kantenbreite" in der Tabelle 5.2) abhängig, weshalb er sich mit zunehmender Turbulenz verstärkt. Dies ist bei leichter Turbulenz (mit

kleiner PSF) relativ unkritisch, wie die Ergebnisse für die Sequenzen 1 und 2 in Abbildung 5.3 belegen. Mit zunehmender und insbesondere bei starker Turbulenz wie im Fall von Sequenz 7 (siehe Abbildung 5.8) dominiert dieser Effekt die Ergebnisse und verfälscht z. T. den tatsächlichen Bildinhalt.

Wie sich speziell für die Verarbeitung von ganzen Videosequenzen als problematisch herausgestellt hat, kann es des öfteren zu künstlichen Verschiebungen zwischen den Entfaltungsergebnissen aufeinander folgender Einzelbilder kommen. Die Größe der Verschiebungen (in Pixeln) entspricht dabei maximal der Größe der PSF. Werden diese Ausgabebilder zu einem Video zusammengefügt, erscheinen diese Verschiebungen wie Sprünge bzw. Ruckeln im Video. Dieser Effekt lässt sich nicht mithilfe einer einfachen Bildregistrierung beseitigen, da der unechte 3-D Effekt auch quasi "umkippen" kann. Das heißt, es sind nicht nur positionelle, sondern auch (Bild-)inhaltliche Unstetigkeiten möglich.

5.4 Zusammenfassung und Diskussion

Bei den eingangs beschriebenen Entfaltungsmethoden handelt es sich lediglich um eine repräsentative Teilmenge an Entfaltungsmethoden. Darüber hinaus gibt es natürlich es noch eine Vielzahl anderer Lösungsmöglichkeiten für das Entfaltungsproblem. Ziel der Auswahl hier war es, für jeden der in Tabelle 5.1 aufgelisteten Algorithmus-Typen speziell ein typisches Verfahren herauszugreifen und vorzustellen. Die Auswahlkriterien hierfür waren in erster Linie auf den Bekanntheitsgrad der jeweiligen Algorithmen beschränkt und darauf, wie weit diese verbreitet sind und tatsächlich eingesetzt werden.

5.4.1 Vor- und Nachteile der Algorithmus-Typen

Direkte vs. iterative Entfaltungsmethoden

Der größte Vorteil direkter Entfaltungsmethoden gegenüber iterativen Methoden im Hinblick auf Turbulenzkorrekturverfahren liegt auf der Hand. Algorithmen, welche die gesuchte Lösung innerhalb eines einzigen Programmdurchlaufs liefern können, bieten (potenziell) eine höhere Geschwindigkeit und u. U. sogar Echtzeitfähigkeit. Dies gilt speziell für den IWF, der

selbst für große Bilder Ergebnisse mit ausreichender Bildrate für Echtzeitwiedergabe liefern kann. Bei der ebenfalls direkten PCA-basierten Entfaltung sieht das ein wenig anders aus. Obwohl es sich hierbei um eine direkte und tatsächlich relativ schnelle Methode handelt, benötigt die Ausführung in der Regel dennoch deutlich mehr Zeit als dies beim reinen IWF der Fall ist, bei dem die PSF-Schätzung separat erfolgen muss.

Blinde vs. nicht-blinde Entfaltungsmethoden

Entsprechend offensichtlich ist auch der diesbezüglich größte Nachteil von nicht-blinden Entfaltungsverfahren gegenüber blinden Verfahren, welcher in der im Normalfall (d. h. für den vorliegenden Turbulenz-Kontext "normal") unbekannten PSF begründet liegt. Das bedeutet, dass vor der eigentlichen Dekonvolution erst noch die Filterfunktion h mit Hilfe einer geeigneten Methode bestimmt (bzw. geschätzt) werden muss. Hierfür müssen somit zusätzliche Ressourcen eingesetzt werden. Tatsächlich ist die Schätzung derartiger Blurring-Funktionen eines der schwierigsten Probleme bei der Bildrekonstruktion überhaupt. Entsprechend kann jede Art von Vorwissen über die Natur der aktuell vorliegenden Störungen bei der Rekonstruktion von Vorteil sein. Speziell bei bekannten Rahmenbedingungen, wie z. B. bei Anwendungen in der medizinischen Bildverarbeitung häufig der Fall, können blinde Entfaltungsverfahren auch zu *kurzsichtigen* ("myopic") Verfahren werden.

5.4.2 Überblick über die Algorithmen

IWF-Algorithmus

Der IWF zählt zu den direkten Entfaltungsmethoden, während er zugleich auch zu den nicht-blinden Methoden gehört, inklusive aller im vorangegangenen Abschnitt aufgeführten Vor- (Echtzeitfähigkeit) und Nachteile (PSF unbekannt). Darüber hinaus ist insbesondere seine extreme Sensibilität bereits gegenüber minimalem Rauschen negativ hervorzuheben. Ebenso nachteilig ist der erforderliche hohe Aufwand, um sinnvolle Parametrisierungen zu finden, die speziell auf die jeweilige Anwendung angepasst sind. Würde man darauf verzichten, hätte dies im Regelfall signifikante Beein-

trächtigungen in der Ergebnisqualität zur Folge.

Nichtsdestoweniger werden spezialisierte Versionen des IWF in zahlreichen Verfahren zur Korrektur optischer Turbulenz eingesetzt.

LRD-Algorithmus

Bei dem relativ robusten LRD-Algorithmus handelt es sich um eine iterative, aber nicht-blinde Entfaltungsmethode. Das bedeutet, es müssen Abbruchkriterien gefunden werden, welche darüber entscheiden, wann bzw. ob eine hinreichende Konvergenz der Schätzung \hat{f} des ungestörten Bildes f erreicht wurde. Zudem muss eine möglichst gute PSF-Schätzung \hat{h} gefunden werden. An dieser Stelle sei auf den nachfolgend diskutierten IBD-Algorithmus verwiesen, welcher dieses Problem löst.

Der LRD-Algorithmus dient im übrigen häufig als qualitativer Vergleichsmaßstab für reine (d. h. nicht-blinde) Entfaltungsalgorithmen. Seine Geschwindigkeit hängt insbesondere von der Bildgröße und der Anzahl von Iterationen ab. Je nachdem können die Berechnungen mehrere Sekunden bis hin zu mehreren Tagen in Anspruch nehmen.

IBD-Algorithmus

Der IBD-Algorithmus zählt zu den iterativen, sowie blinden Entfaltungsmethoden und ist im Grunde genommen, wie zuvor erwähnt, eine blinde LRD-Variante. Auch der IBD-Algorithmus dient häufig als eine Art Referenzverfahren, allerdings speziell für blinde Entfaltungsalgorithmen. Seine Geschwindigkeit hängt ebenfalls von der Bildgröße und der Anzahl von Iterationen ab. Genauer zeichnet sich dieser Algorithmus durch eine Rechenkomplexität der Größenordnung $\mathcal{O}(N \log_2 N)$ pro Iteration aus, wobei N der Gesamtzahl der Pixel in einem einzelnen Frame entspricht, während normalerweise mehr als eine Iteration für seine Konvergenz erforderlich ist.

PCA-Algorithmus

Als sowohl blinde wie auch direkte Entfaltungsmethode gehört der PCA-Algorithmus zu der sicherlich am seltensten vorkommenden Algorithmus-Kategorie und vereinigt in sich somit die (potenziellen) Vorteile beider Arten.

Das heißt, für die MO Variante (mit mehreren Engabebildern) ist tatsächlich keinerlei Vorwissen über die PSF erforderlich, während für die SO-Version (mit nur einem einzigen Engabebild), ebenso wie im Fall der meisten blinden Entfaltungsmethoden, nur die Größe des Trägers der PSF bekannt sein muss. Die Bildrekonstruktion erfolgt direkt, d. h. in einem einzigen Schritt, wodurch das Rekonstruktionsergebnis vergleichsweise schnell vorliegt. Dabei erhöht sich zwar die Komplexität mit der Filtergröße, die Bildgröße wirkt sich dafür aber deutlich weniger auf die Geschwindigkeit aus als dies bei den anderen der hier vorgestellten Methoden der Fall war. Im Hinblick auf (potenzielle) Echtzeit-Anwendungen stellt dies einen enormen Vorteil dar. Ein zusätzlicher Vorteil liegt in der Robustheit des Algorithmus gegenüber weißem Rauschen. Nachteilig ist dagegen die überproportionale Kontrastanhöhung, sowie auch die Verstärkung hoher Frequenzanteile, einschließlich hochfrequentem Rauschen. Je nach Anwendung kann es überdies auch von Nachteil sein, dass der Algorithmus keine explizite Bestimmung der Filterfunktion zulässt.

Aus den im vorangegangenen Abschnitt 5.3 diskutierten Ergebnissen aus Abschnitt 5.2 geht hervor, dass beide Versionen des Algorithmus am besten für schwache, insbesondere isoplanatische Turbulenz geeignet sind. Mit zunehmender Turbulenzstärke steigt auch die Rauschanfälligkeit der MO-Version an, sowie der unechte 3-D Effekt der SO-Version. Daher ist diese Entfaltungsmethode für stärkere, insbesondere anisoplanatische Turbulenz nicht empfehlenswert. Aufgrund der guten Auflösungsfähigkeit der SO Variante, speziell von vertikalen und horizontalen Mustern, ist deren Einsatz je nach Anwendungsgebiet dennoch auch bei starker Turbulenz vorstellbar. So sind z. B. Applikationen im Bereich *Maschinelles Sehen* denkbar, bei denen die Auflösung geometrischer Muster den höchsten Stellenwert hat. Sobald es hingegen um Objekterkennung bzw. -klassifizierung geht oder auch (visuell) ästhetische Gesichtspunkte im Vordergrund stehen, sind im Regelfall andere Methoden besser geeignet.

5.4.3 Anmerkungen

“Padding” zur Randbehandlung

Aufgrunddessen, dass die meisten Entfaltungsverfahren Fourier-Transformationen einsetzen, sollte noch angemerkt werden, dass diese in der Regel

bessere Ergebnisse liefern, wenn die Eingangsdaten an den Randbereichen entsprechend optimiert werden. Weit verbreitet ist hierfür der Einsatz sogenannter *“Padding”*-Methoden, bei denen die Bilder über den eigentlichen Bildrand hinaus erweitert werden. Am einfachsten ist die Erweiterung mit Nullen (bekannt als *“Zero-Padding”*), wobei das Kopieren oder die Spiegelung des Bildinhalts am Bildrand (auch bekannt als einfache oder symmetrische Replikation) ebenfalls weit verbreitet sind.

“Ringing”-Effekte

Unter *“Ringing”* in (Bild-)Signalen versteht man Störungen bzw. Artefakte im Bild, die in der Umgebung scharfer Kanten auftreten. Das Bildsignal oszilliert scheinbar um die Kanten herum, wodurch Phantom-Kanten als eine Art Echo der echten Kanten erzeugt werden. Dekonvolutionsalgorithmen sind sehr anfällig für solche *“Ringing”*-Effekte, speziell inverse Filtertechniken wie das Wiener Filter.

Zur Reduktion solcher *“Ringing”*-Effekte wird häufig sogenanntes *“Edge tapering”* eingesetzt, wobei Diskontinuitäten an den Bildkanten mithilfe gradueller Kontrastreduktion vermindert werden.

Für zusätzliche Möglichkeiten der sinnvollen Bildvorverarbeitung im Fall Turbulenz-gestörter Bilddaten sei insbesondere auf den Abschnitt 6.4 verwiesen.

6

Turbulenzkorrektur

Der Themenkomplex *Turbulenzkorrektur* in diesem Kapitel befasst sich vor allem damit, Korrekturmethoden ganz konkret an Turbulenzbedingungen anzupassen. Algorithmen zur Bewegungskompensation und Deblurring, die wesentliche Bestandteile gängiger Korrekturverfahren bilden, wurden bereits in den vorangegangenen Kapiteln 4) und 5) behandelt. Jedoch ist die Anwendbarkeit dieser Algorithmen auf turbulenzgestörte Daten nicht immer ohne Weiteres gewährleistet. In Abschnitt 6.4 ist daher beschrieben, inwieweit eine entsprechende Vorverarbeitung der Eingangsdaten die Performanz diverser Verfahren verbessern kann.

Für eine gegebene Turbulenzstärke lässt sich gemäß [Fri82] eine theoretische durchschnittliche PSF berechnen, sofern alle relevanten Informationen über das abbildende System und die abgebildete Szene vorliegen (siehe Abschnitt 6.2). Die resultierende PSF kann anschließend für ein effektives Deblurring einzelner Frames eingesetzt werden, insbesondere auch als Teil der Vorverarbeitungskette.

Während Informationen wie die Spezifikationen des eingesetzten Kamerasystems zumeist verfügbar sind, liegen in der Praxis hingegen nur vergleichsweise selten Informationen über die Stärke der vorherrschenden Turbulenz (in Form von aktuellen Messdaten für r_0 bzw. C_n^2) zu einem gegebenen Datensatz vor. Daher liegen die Vorteile einer funktionsfähigen und hinrei-

chend genauen Methode zur automatischen Schätzung der Turbulenzstärke anhand eines solchen Bilddatensatzes auf der Hand. Ein entsprechendes Verfahren wird in Abschnitt 6.3 erläutert.

Des weiteren können auch die Testdaten eine Rolle spielen, deshalb gibt der nachfolgende Abschnitt 6.1 zunächst eine detaillierte Beschreibung der in dieser Arbeit am häufigsten verwendeten Testsequenzen.

6.1 Testsequenzen

Um die Leistungsfähigkeit von Korrekturverfahren adäquat beurteilen zu können, sind zunächst entsprechend geeignete Daten unerlässlich. Dabei ist die Fragestellung nach der Eignung einer gegebenen Bildsequenz für einen bestimmten Algorithmus eng verknüpft mit der Zielsetzung der zugrundeliegenden Anwendung.

Grundsätzlich gilt für Testdaten, dass im Idealfall mehrere möglichst unterschiedlich geartete Objekte in der abgebildeten Szene vorkommen sollten, um die ganze Bandbreite der Leistungsfähigkeit eines Korrekturverfahrens testen zu können. Dazu gehören insbesondere die folgenden Szenenelemente:

- Geraadlinige (meist künstliche) Strukturen, d. h. Linien und Kanten, sowohl mit horizontaler als auch vertikaler und diagonaler Ausrichtung (z. B. eine Testmustertafel, ein Haus oder ein Strommast)
- Statische (unbewegliche) Elemente und bewegte Elemente
- Organische Strukturen, d. h. Formen mit Rundungen, sowohl natürlichen Ursprungs (wie z. B. Personen, Tiere oder Pflanzen) als auch künstlich (z. B. ein Schriftzug oder eine spezielle Mustertafel)
- Bereiche mit hohem Kontrast und mit geringem Kontrast
- Feine Strukturen und grobe Strukturen

Das bedeutet nicht, dass gleich all diese Elemente in einer einzigen Sequenz vorkommen müssen. Nicht selten sollen ganz spezifische Fähigkeiten eines gegebenen Algorithmus getestet werden, so dass Daten benötigt werden, die vor allem solche Objekte bzw. Objektarten beinhalten, welche die entsprechenden Strukturen aufweisen.

Weiterhin sollten die üblichen Anforderungen an die Aufnahmegerätqualität erfüllt sein (d. h. qualitativ hochwertiges Equipment, hohe Bildauflösung, kurze Integrationszeit etc.)

Ein zusätzlicher Aspekt ist die allgemeine Verfügbarkeit spezieller Datensätze. In der Regel ist sinnvoll, neu entwickelte oder verbesserte Algorithmen an Daten zu testen, die auch von anderen verwendet werden dürfen, um eine bessere Vergleichsmöglichkeit verschiedener Methoden untereinander zu haben.

Nachfolgend werden die in der vorliegenden Arbeit häufiger vorkommenden Testsequenzen genauer beschrieben.

6.1.1 “China Lake”-Sequenz

Die hier als “China Lake” bezeichnete Sequenz wurde am 18. Juli 2001 um 13:18 Uhr vom FGAN-FOM während einer Messkampagne der TG11 (NATO RTG SET) auf der “Naval Air Weapons Station China Lake”, am westlichen Rand der Mojave-Wüste in Kalifornien (USA) aufgenommen. Die Informationen über die Erfassung dieser Testsequenz (Spezifikationen, C_n^2 , etc.) wurden aus [Sei01] übernommen.

Die Sequenz umfasst 4096 Frames mit einer Auflösung von 256×256 Pixeln bei einer Bildrate von 300 fps. Der Ausbreitungsweg zwischen Referenzziel und Kamerasystem verlief parallel zum Boden in einer Höhe von ca. 1,5 m und mit einer Weglänge von ca. 1,3 km.

Für die Erfassung der Daten wurde eine “RETICON MD4256C” Hochgeschwindigkeitskamera mit Siliziumdetektor verwendet. Ihre Spezifikationen und die der verwendeten Optiken sind in der Tabelle 6.1 zusammengefasst.

RETICON MD4256C von EG&G High-Speed Kamera mit Si-Detektor		OPTIK	
Empfindlichkeit	max. $\lambda = 800$ nm	Apertur	$D = 125$ mm
Bit pro Pixel	8 bpp	Brennweite	$f = 1250$ mm
Framerate	max. 1000 fps	Blendenzahl	10
Bildauflösung	256×256 pixels	FOV	0.19° (3.28 mrad)
Eff. Pixelgröße	$14 \mu\text{m} \times 16 \mu\text{m}$ (H \times B)	IFOV	$11.2 \mu\text{rad} \times 12.8 \mu\text{rad}$ (H \times B)
Pixelabstand	$16 \mu\text{m} \times 16 \mu\text{m}$	Winkelauflösung	$d\phi = 1.22 \lambda/D$ → $d\phi = 7.8 \mu\text{rad}$ ($\lambda = 800$ nm)

Tabelle 6.1: Gerätespezifikationen de RETICON MD4256C Kamera

Das linke Bild in der Abbildung 6.1 zeigt die Mustertafel, die für die Sequenz verwendet wurde und vermittelt einen Eindruck von dem Standort. Die vollständigen Abmessungen der Mustertafel sind noch einmal in der Abbildung 6.2 rechts im Detail zu sehen. Rechts in der Abbildung 6.1 ist auf einem Beispielbild der Sequenz die Anzahl der Pixel gekennzeichnet, die der Breite des Tafel entsprechen. Daraus ergibt sich eine Auflösung von ca. 70 Pixeln pro Meter, d. h. 1 Pixel im Bild entspricht ungefähr 1,4 cm in der realen Szene.

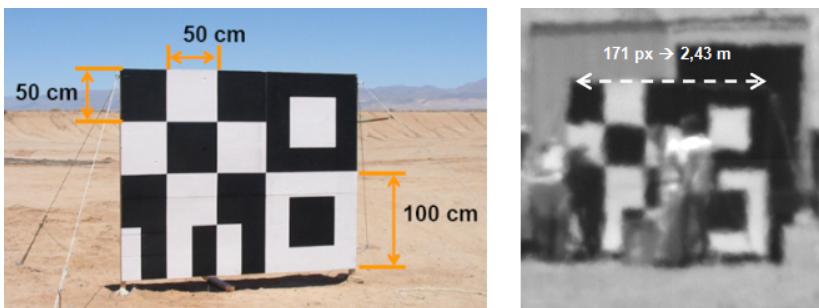


Abbildung 6.1: Links: Referenzziel am Standort; rechts: Beispielbild aus der Testsequenz mit Abmessungen.

Während des gesamten Tages wurden durchgängig C_n^2 Messungen mit einem "Boundary Layer Scintillometer" BLS900 der Scintec AG durchgeführt. In der Abbildung 6.2 ist der komplette C_n^2 Tagesgang für den Aufnahmetag zu sehen (links). Da die Sequenz während der Mittagshitze aufgenommen wurde, ist die Turbulenz zu diesem Zeitpunkt mit $C_n^2 = 1,3 \cdot 10^{-13} \text{ m}^{-2/3}$ als sehr starke Turbulenz einzustufen. Das bedeutet insbesondere, dass es sich trotz der sehr kurzen Belichtungszeit von $\approx 3,3 \text{ ms}$ (300 fps) um einen Langzeitbelichtungsfall handelt, da die zugehörige Kohärenzzeit τ_0 überschritten wird.

Unter Zuhilfenahme der vorliegenden Informationen ergibt sich aus der Gleichung (3.26) für $\lambda = 800 \text{ nm}$ eine Kohärenzlänge $r_0 = 1,17 \text{ cm}$ und für $\lambda = 550 \text{ nm}$ ergibt sich $r_0 = 0,75 \text{ cm}$. Analog ergeben sich aus der Gleichung (3.25) für $\lambda = 800 \text{ nm}$ ein isoplanatischer Winkel $\theta_0 = 2,84 \mu\text{rad}$, sowie $\theta_0 = 1,81 \mu\text{rad}$ für $\lambda = 550 \text{ nm}$.

Da das IFOV des optischen Systems deutlich größer ist als die so berechneten isoplanatischen Winkel, müssen die Bedingungen während der Bildaufnahme als völlig anisoplanatisch eingestuft werden.

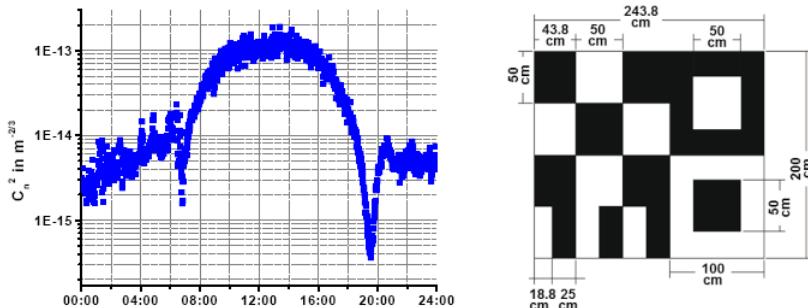


Abbildung 6.2: Links: Tagesgang von C_n^2 am 18. Juli 2001; rechts: Maße des Referenzziels.

Im übrigen ist noch zu erwähnen, dass nicht nur die statische Mustertafel in der abgebildeten Szene zu sehen ist, sondern auch drei Personen, von denen sich eine Person überhaupt nicht bewegt, die zweite nur geringfügig und die dritte etwas mehr, indem sie sich einige Schritte vor der Tafel bewegt. Dies war die erste verfügbare Testsequenz mit gut dokumentierten Rahmenbedingungen, die überhaupt Objekte mit Eigenbewegung enthielt. Aus diesem Grund wurden viele der in dieser Arbeit beschriebenen Methoden und Effekte speziell an dieser Sequenz demonstriert.

6.1.2 “Dayton”-Sequenzen

Im Rahmen einer Messkampagne der NATO RTO SET 165 Gruppe wurde im Zeitraum vom 8. bis zum 13. Oktober 2011 auf dem Gelände der Universität in Dayton (Ohio, USA) eine ganze Serie von Bildsequenzen aufgezeichnet ([Vel12]). Darunter wurden von den Teilnehmern drei repräsentative Sequenzen ausgewählt, die nachfolgend genauer beschrieben werden, um daran Algorithmen zur Turbulenzkorrektur zu testen.

Insbesondere wurden diese Sequenzen auch in [van14] verwendet, um die Ergebnisse des TNO und die im Rahmen dieser Arbeit erhaltenen Ergebnisse miteinander zu vergleichen.

Der Aufnahmestandort befand sich auf dem Universitätsgelände, genauer im “Intelligent Optics Laboratory” oben auf dem “College Park Center” in einer Höhe von ca. 15 m. Von dort aus wurden alle drei dieser Sequenzen am 12. Oktober nachmittags (zwischen 15:30 Uhr und 16:20 Uhr) aufgezeichnet. Bei der verwendeten Kamera handelte es sich um eine monochrome “AVT Stingray F-080B” mit einer maximalen Bildauflösung von 1032×778 Pixeln und einer Bit-Tiefe von 14 Bit-pro-Pixel. Dazu wurde eine “Celestron C8” Optik eingesetzt.

Eine Übersicht der weiteren Eckdaten zu den Sequenzen ist (soweit vorhanden) in der Tabelle 6.2 gegeben.

Sequenz	NATO/Mannequin	Antenne	Stadium Lamps
Datum	12. 10. 2011	12. 10. 2011	12. 10. 2011
Uhrzeit	15 h 34 m 37 s	16 h 14 m 51 s	16 h 19 m 46 s
Turbulenz C_n^2	$5 \cdot 10^{-16} \text{ m}^{-2/3}$	$10^{-15} \text{ m}^{-2/3}$	$10^{-15} \text{ m}^{-2/3}$
Entfernung	ca. 7 km	6-7 km	2-3 km
Apertur \mathcal{O}	66 mm	66 mm	200 mm
Auflösung	1032×264 px	552×776 px	776×776 px
Framerate	69,0 fps	31,6 fps	31,6 fps
Framezahl	500	500	300
Dynamikumfang	16,19 dB	22,72 dB	7,90 dB

Tabelle 6.2: Eckdaten der Dayton-Sequenzen.

Die Abbildungen 6.3, 6.4, sowie 6.5 zeigen Beispielbilder der einzelnen Sequenzen. Um einen Eindruck von den Qualitätsschwankungen innerhalb des Aufnahmezeitraums zu vermitteln, sind hier jeweils der beste und der schlechteste Frame jeder Sequenz abgebildet. Dabei erfolgte die Bewertung der Bildqualität mithilfe der in [Dol07] vorgeschlagenen Blur-Metrik.

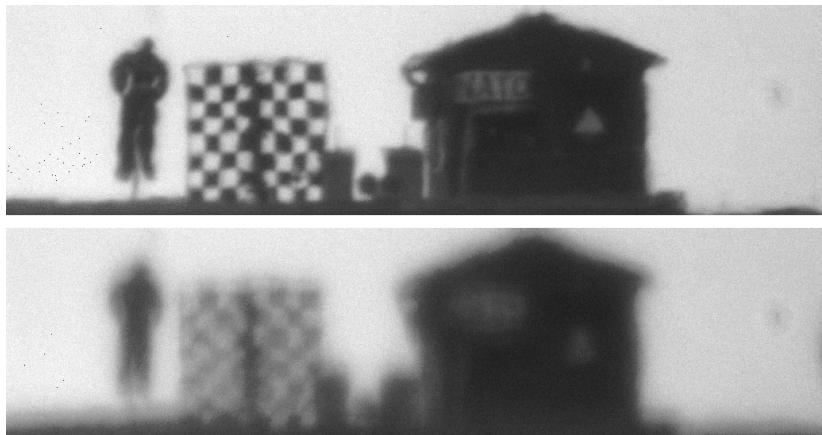
“NATO / Mannequin”-Sequenz

Abbildung 6.3: Oben: bester Frame der “NATO / Mannequin”-Sequenz; unten: schlechtester Frame.

Die in der “NATO / Mannequin”-Sequenz aufgenommene Szene befand sich auf dem Dach des “Dayton VA Medical Center” in einer Höhe von ca. 40 m und in einer Entfernung von ca. 7 km Luftlinie vom Aufnahmeort. Dabei wurden gleich mehrere verschiedene Testobjekte erfasst:

- Eine Übungspuppe (“Mannequin”) zur Beurteilung der Beeinträchtigung von Personendetektion durch Turbulenz.
- Ein Schachbrettmuster aus Metall mit quadratischen Öffnungen anstelle von weißen Quadraten, um die Stärke der Bildverformungen einschätzen zu können.
- Zwei Signallaser (“Beacon”), u. a. zur Bestimmung der (lokalen) PSF.
- Ein Schild mit der Aufschrift “NATO” (an einem Schuppen angebracht), um die Performanz von Korrekturverfahren beurteilen zu können, z. B. indem bewertet wird, ob und wie gut die Schrift vor und nach Anwendung der Korrektur lesbar ist.

- Ein Dreieck, an dem sich im Fall von starker Turbulenz zeigt, ob die Ausrichtung der Spitze noch erkennbar ist.

Diese Sequenz eignet sich gerade aufgrund der Unterschiedlichkeit dieser Testobjekte als Testsequenz für Algorithmen zur Turbulenzkorrektur.

Die gemessene Turbulenzstärke zum Aufnahmezeitpunkt (ca. 15:35 Uhr Ortszeit) war mit $C_n^2 \approx 5 \cdot 10^{-16} \text{ m}^{-2/3}$ vergleichsweise schwach. Aufgrund des relativ langen Ausbreitungswegs waren die atmosphärischen Beeinträchtigungen dennoch zeitweise stark ausgeprägt.

“Antenne”-Sequenz

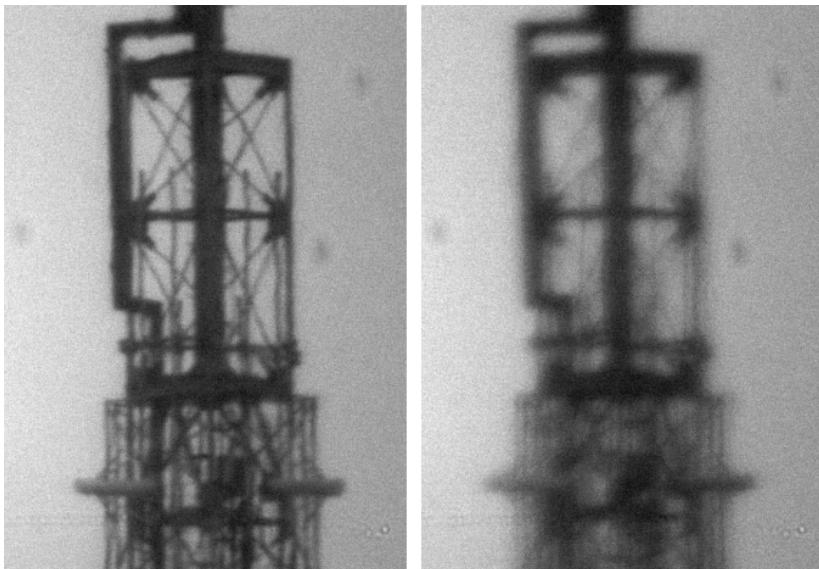


Abbildung 6.4: Links: bester Frame der “Antenne”-Sequenz; rechts: schlechterer Frame.

Diese Sequenz wurde ca. 40 min später aufgezeichnet als die “NATO / Mannequin”-Sequenz. Bei der “Antenne” handelt es sich um einen Funkmast der “Greater Dayton Public Television” Sendestation, welcher sich mit

geschätzten 6-7 km in vergleichbarer Entfernung von der Universität Dayton befindet. Die Turbulenzstärke hatte sich in der Zwischenzeit allerdings auf $C_n^2 \approx 10^{-15} \text{ m}^{-2/3}$ erhöht.

Da die Metallkonstruktion des Funkmasts ausschließlich aus geraden Linien besteht, lassen sich Verformungen daran besonders gut erkennen wie bereits in Abbildung 1.5 in der Einleitung demonstriert wurde. Diese Sequenz eignet sich vor allem für Rekonstruktionsmethoden, die auf statischen Szenen operieren, insbesondere aber auch für Methoden, die darauf basieren gerade Linien zu detektieren und wiederherzustellen, wie z. B. in [Hof19].

“Stadium Lamps”

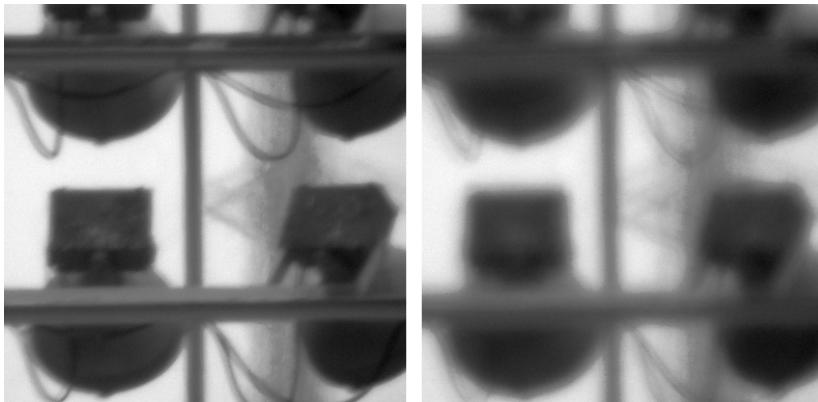


Abbildung 6.5: Beispielframe der “Stadium Lamps”-Sequenz

In dieser Sequenz wurden die Stadionlampen im “Welcome Stadium” erfasst, welches sich in geschätzten 2-3 km Entfernung (Luftlinie) zum Aufnahmeort befindet. Der Aufnahmezeitpunkt hier war gegen 16:20 Uhr, d. h. nur ca. 5 min später als die “Antenne”-Sequenz, so dass die Turbulenz immer noch in der gleichen Größenordnung lag, d. h. bei $C_n^2 \approx 10^{-15} \text{ m}^{-2/3}$. Dennoch waren die Turbulenzauswirkungen aufgrund der verringerten Distanz etwas geringer. Im Hintergrund der Lampen ist etwas schemenhaft noch ein Strommast zu erkennen, der sich offensichtlich in größerer Entfernung

befindet. Bereits in den Einzelbildern in Abbildung 6.5 und mehr noch im laufenden Video fallen die Doppelkonturen auf, die dieser Strommast zu haben scheint. Ähnlich wie im Fall von Refraktionseffekten lassen sich deerartige Doppelkonturen allerdings normalerweise nicht mithilfe verbreiteter Turbulenzkorrekturverfahren beseitigen. Das bedeutet, während sich die Lampen selbst vergleichsweise gut korrigieren lassen ([van14]), funktioniert dieselbe Korrektur für diese zweite DistanzEbene nicht so überzeugend.

6.2 Theoretische PSFs

Wie im vorangegangenen Kapitel 5 bereits anhand von Methoden zur Blinden Entfaltung erörtert, beinhalten Ansätze zur Bildrekonstruktion stets eine näherungsweise Bestimmung der PSF. Dabei gibt es mehrere theoretische Approximationen für die Filterfunktion der Atmosphäre. Beispielsweise kann in erster Näherung eine Gauß-Form der PSF angenommen werden, oder es können die statistischen Eigenschaften der Atmosphäre ausgenutzt werden, um eine durchschnittliche PSF zu gegebenen Umgebungsbedingungen zu formulieren ([Fri66]).

Für alle nachfolgend aufgeführten Ansätze sind neben der Kohärenzlänge r_0 (oder C_n^2) diverse Kamera- und Sensorspezifikationen erforderlich. Genauer werden über das abbildende System die folgenden Kamera- und Sensordaten benötigt:

- der Aperturdurchmesser D (in Meter)
- die Wellenlänge λ (in Meter)
- die Pixelgröße auf dem Detektor p_s (IFOV) (in Radians)

Die Spezifikationen des eingesetzten Kamerasystems liegen in der Regel vor, so dass dies kein Problem darstellt. Zwar ist der Öffnungswinkel pro Pixel nicht immer bekannt, jedoch lässt sich das IFOV hinreichend gut über die Pixelauflösung und die Sensorgröße abschätzen.

Des weiteren werden noch verschiedene inhaltliche Informationen über die abgebildete Szene benötigt:

- die Objektentfernung L (in Meter)
- die Objektgröße O_s (FOV) (in Pixeln)

Insbesondere lässt sich die Größe der abgebildeten Szene über das IFOV und die Pixelauflösung im Zusammenhang mit der Entfernung bestimmen, wobei die Objektentfernung nicht immer ohne Weiteres verfügbar ist. Sofern erforderlich, können jedoch ggfs. digitale Messungen in "Google Earth", sowie Erfahrungswerte und gutes Augenmaß bei der Abschätzung von Nutzen sein.

6.2.1 Gauß-förmige PSF

Die einfachste Näherung an eine atmosphärische Filterfunktion ist eine Gauß-förmige PSF, da die optischen Turbulenzen im Grunde wie ein Tiefpassfilter wirken, indem sie die hohen Ortsfrequenzen herausfiltern, wodurch scharfe Kanten und punktförmige Objekte verwischt werden.

Zur Bestimmung der 2-D Gauß-Funktion muss in erster Linie die zugehörige Standardabweichung σ abgeschätzt werden ($\mu = 0$). Für die entsprechende Halbwertsbreite ("Full Width Half Maximum", FWHM) einer Punktquelle (visualisiert in der Abbildung 6.6) gilt bei Turbulenz, dass $\text{FWHM} \sim \lambda / r_0$.

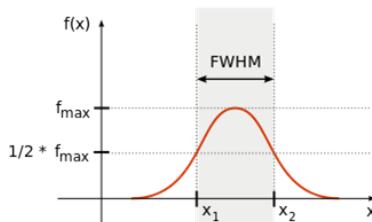


Abbildung 6.6: "Full Width Half Maximum" einer Gauß-Glocke.¹

Zwischen der Halbwertsbreite und σ besteht die folgende Beziehung:

$$\sigma \approx \frac{1}{2,355} \cdot \text{FWHM} \quad (6.1)$$

¹ Quelle: https://www.abs.uni-wuppertal.de/fileadmin/site/abs/Lehrunterlagen/2018_05_07_Versuchsanleitung_GC.pdf (S.11)

Der FWHM-Wert lässt sich mithilfe des “Tilt”-Winkels α_j (j steht für “Jitter”) bestimmen:

$$\text{FWHM} = \sqrt{\left(1,22 \cdot \frac{\lambda}{D}\right)^2 + (2,7 \cdot \alpha_j)^2} \cdot \frac{1}{p_s} \quad (6.2)$$

wobei sich α_j (in einer Achsenrichtung) unter Verwendung des Fried-Parameters r_0 berechnen lässt wie folgt:

$$\alpha_j = \sqrt{0,182 \cdot \left(\frac{D}{r_0}\right)^{5/3}} \cdot \frac{\lambda}{D} \quad (6.3)$$

6.2.2 Beugungsbegrenzte PSF

Befindet sich ein bildgebendes System am Diffraktionslimit, dann nimmt die zugehörige beugungsbegrenzte PSF einfach die Form einer “Airy-Disk”² (auch: “Airy”-“Scheibchen”) an. Die Abbildung 6.7 zeigt ein Beispiel für eine solche beugungsbegrenzte PSF. Das symmetrische “Airy”-Beugungsmuster besteht aus einer Reihe abwechselnd schmaler dunkler und breiterer heller

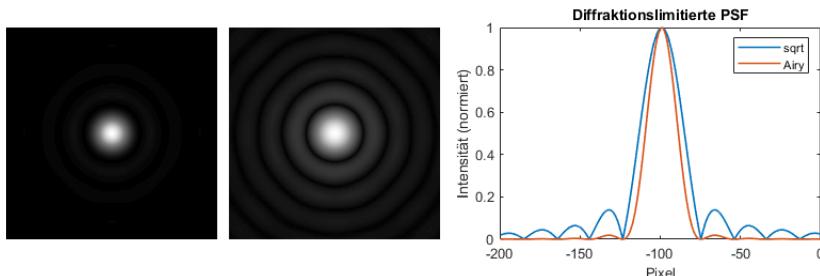


Abbildung 6.7: Beispiel einer theoretischen diffraktionslimitierten PSF. Links: “Airy”-Beugungsmuster für $\lambda = 4 \cdot 10^{-6}$, $D = 20$ cm, IFOV = 10^{-6} , $L = 20$ km; Mitte: Quadratwurzel des Airy-Patterns; rechts: Querschnittsvergleich (Intensitäten auf 1 normiert)

² So benannt nach dem britischen Mathematiker und Astronom George Biddell Airy (1801-1892)

Ring. Es entsteht durch Fraunhofer Diffraktion an einer kreisförmigen Blende, d. h. im (zentralen) Querschnitt entspricht es dem Beugungsmuster an einem Spalt mit der gleichen Breite wie der Blendendurchmesser.

Im Grunde genommen entspricht das "Airy"-Beugungsmuster dem Betragsquadrat der 2-D Fourier-Transformation der Pupillenfunktion eines idealen Systems aus Gleichung (3.39) (skaliert bzgl. $1/p_s \cdot \lambda/D$), d. h. $I \sim |\mathcal{F}(P_0)|^2$. Auf diese Weise wurde auch die PSF in der Abbildung 6.7 generiert.

Mathematisch lassen sich die Intensitätswerte I des "Airy-Patterns" mithilfe der *Bessel-Funktion* 1. Ordnung J_1 beschreiben:

$$I(\theta) = I_0 \cdot \frac{2 J_1(\frac{\pi D}{\lambda} \sin \theta)}{\frac{\pi D}{\lambda} \sin \theta} = I_0 \cdot \frac{2 J_1(x)}{x} \quad (\text{mit } x = \frac{\pi D}{\lambda} \sin \theta) \quad (6.4)$$

Dabei bezeichnet I_0 die maximale Amplitude des zentralen Airy-Scheibchens und θ den Beobachtungswinkel zwischen der Zentrallinie und dem Beobachtungspunkt in der Bildebene (siehe dazu Abbildung 6.8).

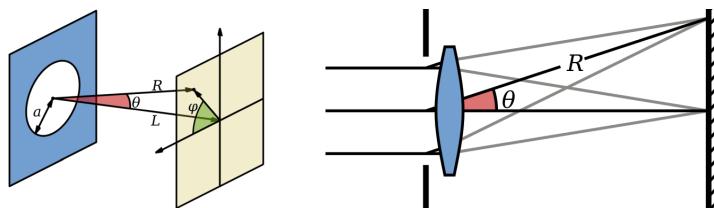


Abbildung 6.8: Beugung an einer kreisförmigen Blende. Links: ohne Linse; rechts mit Linse

Die Bessel-Funktion 1. Ordnung ist wiederum mithilfe der *Eulerschen Gammafunktion* Γ definiert:

$$J_1(x) = \sum_{k=0}^{\infty} \frac{(-1)^k}{k! \Gamma(k+2)} \left(\frac{x}{2}\right)^{2k+1} \quad (6.5)$$

wobei Γ für die Menge der natürlichen Zahlen definiert ist als:

$$\Gamma(n) = (n-1)! \quad (\forall n \in \mathbb{N}) \quad (6.6)$$

Die zentrale “Airy-Disk” enthält ca. 86% der Gesamtenergie des “Airy”-Musters. Bei einem Radius von $\rho = 0,514 \lambda/D$ sinkt die Energie auf ca. 50% mit zugehöriger Halbwertsbreite FWHM = $1,028 \lambda/D$.

Das innere “Airy”-Scheibchen kann auch mithilfe einer 2-D Gauß-Funktion approximiert werden:

$$I(\rho) = I_0 \cdot e^{\frac{-\rho^2}{2\sigma^2}} \quad (6.7)$$

wobei ρ die radiale Entfernung vom Mittelpunkt der “Airy”-Disk bezeichnet. Für die zugehörige Standardabweichung σ ergibt sich ein Näherungswert von $\sigma \approx 0,42 \lambda f/D$ (bzw. $\sigma \approx 0,45 \lambda f/D$, falls die Approximation die gleiche Gesamtintensität aufweisen soll wie das gesamte “Airy”-Muster).

6.2.3 Frieds “short” und “long exposure” PSFs

Im Fall einer Turbulenzlimitierung können die Definitionen der statistischen mittleren atmosphärischen PSFs gemäß Fried ([Fri66]) verwendet werden. Dabei wird zwischen den Fällen “short exposure” und “long exposure” unterschieden. Die von Fried geprägte Bezeichnung “short exposure” PSF ist allerdings etwas irreführend, da es sich nicht um eine tatsächliche Kurzzeitbelichtung handelt, sondern um eine “long exposure” PSF ohne Bildbewegung. Deshalb weist die zugehörige Gaußglocke auch eine etwas schmalere Form auf als die der “long exposure” PSF.

PSF_{LE}, die PSF für den “long exposure” Fall, und PSF_{SE}, die PSF für den “short exposure” Fall, erhält man mithilfe der jeweiligen OTF, wobei OTF_{LE} und OTF_{SE} folgendermaßen definiert sind ([Fri66]):

$$\text{OTF}_{LE}(\nu) = \text{OTF}_0(\nu) \cdot e^{-1/2 D_{LE}(\nu)} \quad (6.8)$$

$$\text{OTF}_{SE}(\nu) = \text{OTF}_0(\nu) \cdot e^{-1/2 D_{SE}(\nu)} \quad (6.9)$$

Dabei bezeichnet OTF₀ hier die OTF eines optischen Systems am Diffraktionslimit (d. h. ohne Turbulenz), die als normalisierte Autokorrelationsfunktion der Teleskoppupille formuliert werden kann. Die Raumfrequenzen ν hängen von der radialen Entfernung zum Mittelpunkt der Bildebene ab und sind bzgl. der Bild- und Pixelgröße skaliert.

Unter Verwendung der Parametersubstitution $f = v\lambda/D$ lässt sich OTF₀ vereinfacht schreiben als:

$$\text{OTF}_0(f) = \frac{2}{\pi} \arccos(f) - \left(f \sqrt{1 - f^2} \right) \quad (6.10)$$

Die zugehörigen Strukturfunktionen D_{LE} und D_{SE} sind gegeben durch:

$$D_{LE}(f) = 6,88 \cdot \left(f \frac{D}{r_0} \right)^{5/3} \quad (6.11)$$

$$D_{SE}(f) = D_{LE}(f) \cdot (1 - f^{1/3}) \quad (6.12)$$

Die gesuchten PSFs resultieren dann aus den OTFs über Invertierung der Gleichung (3.35):

$$\text{PSF}_{LE}(r) = \mathcal{F}^{-1}(\text{OTF}_{LE}(v)) \quad (6.13)$$

$$\text{PSF}_{SE}(r) = \mathcal{F}^{-1}(\text{OTF}_{SE}(v)) \quad (6.14)$$

6.3 Turbulenzschätzung aus Videodaten

In der Literatur existieren verschiedene Ansätze zur Bestimmung der Kohärenzlänge r_0 (bzw. C_n^2) anhand von einer Bildsequenz. Hier und insbesondere in [Hue15] wurde der in [MM15] beschriebene Ansatz gewählt, der weitgehend auf den Arbeiten [Yit97a], [Bea98] und [Zam06] beruht. Auswahlkriterium war einerseits eine hinreichende Genauigkeit der Schätzung, und andererseits ein akzeptabler Rechenaufwand im Interesse einer potenziellen Echtzeitanwendbarkeit.

6.3.1 Schätzverfahren für r_0

Genauer werden hierbei die Bewegungsvektoren zwischen aufeinanderfolgenden Einzelbildern der Sequenz berechnet, z. B. mittels "Block Matching" oder einer der anderen in Kapitel 4 vorgestellten Methoden, und deren Varianz ausgewertet. Dabei geht es in diesem Zusammenhang ausschließlich um turbulenzbedingte Bewegung, d. h. diese Form der r_0 -Schätzung kann ausschließlich auf statischem Bildinhalt von Bildsequenzen durchgeführt

werden. Jede Eigenbewegung von Objekten würde die Schätzungen verfälschen, wobei dies neben naheliegenden Bewegtobjekten, wie Fahrzeugen oder Lebewesen, beispielsweise auch ziehende Wolken und Rauchschwaden mit einschließt oder durch Windböen verursachte Bewegung von Pflanzen, Windhosen etc. Leichter kontinuierlicher Wind, der z. B. das Blattwerk von Bäumen bewegt, ist vergleichsweise unkritisch, da der Wind die Turbulenz ohnehin beeinflusst. Optimalerweise sollte der Szeneninhalt für die Dauer der r_0 -Schätzung jedoch vorwiegend aus unbeweglichen oder unbewegten Elementen bestehen.

Ähnliches gilt für unstrukturierte Bereiche, da dort eine zuverlässige Bewegungsschätzung kaum möglich ist, wie in Abschnitt 4.4 diskutiert wurde. Für spezielle Möglichkeiten zur Identifikation der strukturierten Bereiche, und insbesondere zur Erstellung von geeigneten Homogenitätskarten für das vorliegende Bildmaterial (siehe z. B. Abbildung 6.15), sei im folgenden auf den Abschnitt 6.3.2 verwiesen.

Zusätzlich zu den Bilddaten sind wiedereinige Sensorik- und auf die zugrundeliegende Szene bezogene Informationen für die Bestimmung von r_0 erforderlich, genauer der Aperturdurchmesser D , die Wellenlänge λ und das IFOV p_s . Ebenfalls werden einige Informationen über die zugrundeliegende Szene benötigt, nämlich die Objektentfernung L , sowie die Objektgröße O_s . Die “Tip” und “Tilt” Neigungswinkel α und β in x - und y -Richtung lassen sich gemäß [Dai00] als partielle Ableitungen der Wellenfront W oder der Phase ϕ definieren (s. a. Gleichung (3.30)):

$$\alpha(x, y) = \frac{\partial}{\partial x} W(x, y) = \frac{\lambda}{2\pi} \cdot \frac{\partial}{\partial x} \phi(x, y) \quad (6.15)$$

$$\beta(x, y) = \frac{\partial}{\partial y} W(x, y) = \frac{\lambda}{2\pi} \cdot \frac{\partial}{\partial y} \phi(x, y) \quad (6.16)$$

Das bedeutet, wenn es sich bei ϕ um eine Gauß-Funktion handelt, trifft dies auch auf α und β zu. In [Bea98] wurde gezeigt, dass entsprechend auch die Bildbewegungen in der Bildebene Gauß-verteilt sind (unter isotropen Bedingungen).

Die “Angle of Arrival”-Fluktuationen α_j aus der Gleichung (6.3) können näherungsweise auch über die durchschnittlichen Varianz der Bildbewegungen abgeschätzt werden. Dazu werden die Bewegungsvektoren zwischen

mehreren aufeinanderfolgenden Frames ermittelt und jeweils die durchschnittliche Varianz der horizontalen und der vertikalen Vektorkomponenten bestimmt, d. h. σ_x^2 und σ_y^2 . Damit lässt sich α_j abschätzen zu:

$$\alpha_j \approx \frac{1}{2} \left(\sigma_x^2 + \sigma_y^2 \right) \cdot p_s^2 \quad (6.17)$$

Tatsächlich ist die Varianz in horizontaler Richtung häufig etwas größer als in vertikaler Richtung (d. h. $\sigma_x^2 \geq \sigma_y^2$), da die Luftbewegung in dieser Richtung infolge von Windeinwirkung zumeist etwas stärker ist.

Einsetzen in die linke Seite der Gleichung (6.3) und Umstellen nach r_0 liefert:

$$\alpha_j^2 = 0,182 \cdot D^{-1/3} r_0^{-5/3} \lambda^2 \quad (6.18)$$

$$\Rightarrow r_0^{5/3} = 0,182 \cdot D^{-1/3} \left(\frac{\lambda}{\alpha_j} \right)^2 \quad (6.19)$$

Daraus ergibt sich die folgende Schätzung für die Kohärenzlänge r_0 :

$$r_0 = \left(0,182 \cdot D^{-1/3} \left(\frac{\lambda}{\alpha_j} \right)^2 \right)^{3/5} = 0,36 \cdot D^{1/3} \left(\frac{\lambda}{\alpha_j} \right)^{6/5} \quad (6.20)$$

Daraus folgt insbesondere für C_n^2 :

$$C_n^2 = 0,16 \cdot r_0^{-5/3} \lambda^2 L^{-1}$$

Anmerkungen

Die Zuverlässigkeit der Schätzungen nimmt mit der Länge der Sequenz zu, die ausgewertet wird. Normalerweise erhält man bereits mit ca. 10 Frames mittlerer Größe (z. B. 640×480 px) verhältnismäßig gute Werte, dennoch sollten mindestens 20 Frames verwendet werden, um eine hinreichende Genauigkeit der Schätzung gewährleisten zu können. Wie der Graph in der Abbildung 6.9 für das Beispiel der “NATO/Mannequin”-Sequenz deutet (s. a. Abbildung 6.15 in Abschnitt 6.3.2), konvergiert das Verfahren in der Regel bei ca. 100 Frames. Dabei spielt allerdings auch die tatsächliche Anzahl effektiv ausgewerteter Bewegungsvektoren eine signifikante

Rolle. Diese Zahl hängt zum einen von der Bildgröße und der gewählten Blockgröße ab (z. B. 16×16 px), zum anderen aber auch vom Bildinhalt. Vektoren, die in überwiegend homogenen Bildregionen bestimmt wurden, sollten sicherheitshalber verworfen werden, um die Berechnungen von r_0 nicht zu beeinträchtigen (s. a. Abschnitt 6.3.2). Die “NATO/Mannequin”-Testsequenz enthält beispielsweise viele und große Bildanteile, die bis auf Rauschen (nahezu) völlig homogen sind, d. h. unstrukturiert und unifarben. Entsprechend bedeutet es gegenüber der maximal möglichen Anzahl von Bewegungsvektoren einen erheblichen Informationsverlust, wenn lediglich Verschiebungsvektoren in der Nähe von Kanten im Bild (s. a. Abbildung 6.15) für die Berechnung von r_0 verwendet werden können. Dementsprechend kann die für eine Konvergenz erforderliche Frameanzahl in solchen Fällen also durchaus die genannten 100 Frames überschreiten.

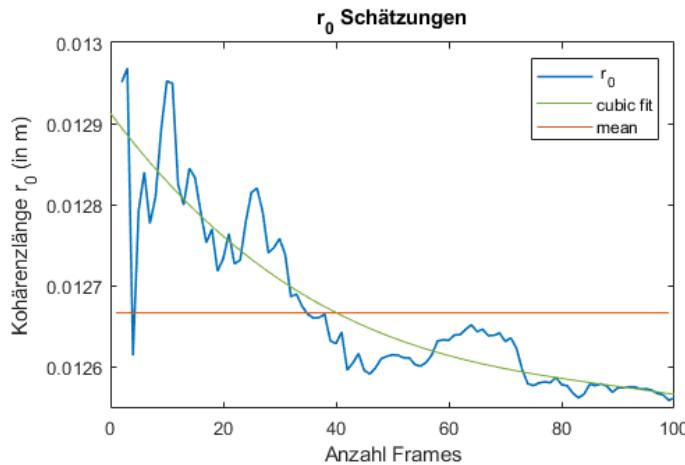


Abbildung 6.9: Schätzwerte für r_0 bei ansteigender Framezahl

6.3.2 Homogenitätskarten

In Kapitel 4 wurde bereits erwähnt, dass die Berechnung von Bewegungsvektoren in homogenen Bildregionen kein sinnvolles Ergebnis liefern kann. Aus diesem Grund dürfen nur Bewegungsvektoren aus hinreichend hete-

rogenen, d. h. strukturierten Regionen in die Berechnung der Varianz mit einfließen. Hierzu ist ein entsprechendes Maß zur Bewertung der Bildhomogenität erforderlich, wobei eine naheliegende Möglichkeit darin besteht, die lokale Grauwertvarianz (bzw. die Standardabweichung) zu verwenden wie bereits in Abschnitt 4.4.2 vorgeschlagen.

Die oberste Priorität bei der Erstellung und Verwendung von Homogenitätskarten ist dafür zu sorgen, dass potenziell fehlerbehaftete Bewegungsvektoren nicht in die Berechnungen von C_n^2 mit einfließen können, um möglichst gute Schätzungen zu bekommen. Die Genauigkeit der Karten spielt dabei eine eher untergeordnete Rolle, wobei die Maxime gilt, dass eher zu viele Bewegungsvektoren verworfen werden sollten als zu wenige.

Lokale STD als Homogenitätsmaß

Zur Erstellung einer Homogenitätskarte mithilfe eines geeigneten Maßes wie der lokalen Standardabweichung gibt es mehrere Möglichkeiten, wobei eine blockweise Implementierung mit fester Blockgröße naheliegt. Idealerweise sollte die Berechnung in Echtzeit oder nahezu Echtzeit möglich sein, wobei dies nicht zwingend erforderlich ist, da die Turbulenzschätzung nicht fortlaufend durchgeführt werden muss, sondern lediglich in bestimmten Intervallen oder bei Bedarf. Dennoch sollte die Rechenzeit in überschaubarem Rahmen bleiben (d. h. <1 sec), weshalb hier auf eine rechenintensive Implementierung in Form einer gleitenden Nachbarschaftsoperation für jedes einzelne Pixel verzichtet wurde. Stattdessen wird eine Blockverarbeitung ohne Überlappung der Blöcke für eine Anzahl k verschiedener (jeweils fester) Blockgrößen b_1, \dots, b_k durchgeführt. In der Abbildung 6.10 sind beispielsweise die jeweiligen Ergebnisse für die Blockgrößen 4×4 px, 8×8 px, 12×12 px, 16×16 px abgebildet, wobei das "Kameramann"-Bild als Testbild verwendet wurde. Die Gesamtheit dieser einzelnen Resultate wird dann mithilfe einer geeigneten Funktion zusammengefasst, z. B. durch einfache Mittelwertbildung oder den Median wie in der Abbildung 6.11 gezeigt. Dies hat den Vorteil, dass die Konturen der Strukturen im Bild gegenüber der einfachen Blockprozessierung verfeinert werden, wodurch nicht zu viele große Bildregionen verworfen werden.

Für die eigentliche Homogenitätskarte ist indes nur eine binäre Information von Interesse, um entscheiden zu können, ob ein Bewegungsvektor

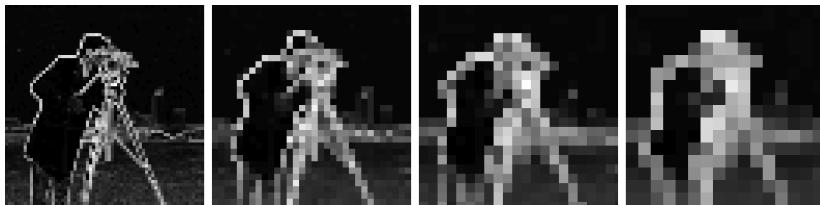


Abbildung 6.10: Lokale Standardabweichung mittels Blockverarbeitung und verschiedene Blockgrößen (v.l.n.r.): 4×4 px, 8×8 px, 12×12 px, 16×16 px



Abbildung 6.11: Vergleich von Mittelwert (links) und Median (rechts) zu Abb. 6.10 mit jeweils korrespondierendem Schwellwertbild.

akzeptiert werden soll oder nicht. Deshalb muss noch eine Binarisierung mit einem geeigneten Schwellwert vorgenommen werden. Hier wurde der Einfachheit halber der Mittelwert als globaler Schwellwert gesetzt, da dieser einfach und schnell zu berechnen ist und in den meisten Fällen zufriedenstellende Ergebnisse liefert. Es können dazu jedoch auch andere, ausgefeilte Methoden verwendet werden, die z. B. adaptiv lokal variierende Schwellwerte bestimmen. In der Abbildung 6.12 sind einige Beispiele solcher Homogenitätskarten mit verschiedenen (maximalen) Blockgrößen gezeigt.

Es sollte noch erwähnt werden, dass die Binarisierung hauptsächlich der Vereinfachung dient. Es ist auch vorstellbar, die (nicht binäre) Homogenitätskarte als eine Art Zuverlässigkeitsskarte zu interpretieren und in eine Form der Gewichtung umzuwandeln. Diese Idee wurde hier jedoch aus Zeitgründen nicht weiter verfolgt.

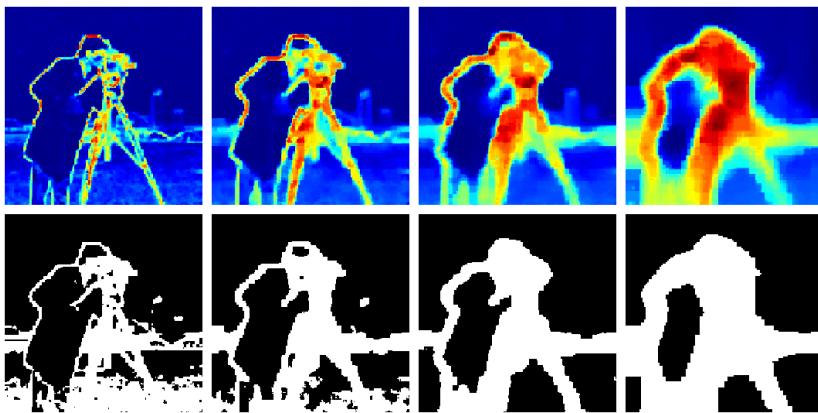


Abbildung 6.12: Standardabweichung für verschiedene maximale Blockgrößen (v.l.n.r.): 8 px, 16 px, 32 px, 64 px. Oben: Falschfarbendarstellung; unten: korrespondierende Homogenitätskarten, Mittelwert als Schwellwert.

Die Lakunarität L

Eine interessante Alternative bietet die sogenannte *Lakunarität* (“Lacunarity”) einsetzen, die sich bereits für ähnliche Aufgaben in anderen Forschungsgebieten als erfolgreich erwiesen hat. Beispielsweise wird in der Sonardatenauswertung inzwischen ein modifiziertes Lakunaritätsmaß zur Bestimmung und Bewertung der Komplexität des Meeresbodens genutzt, um anhand dessen die Schwierigkeit der Minenjagd in diesem Gebiet zu bewerten ([Hue18]).

Ursprünglich wurde Lakunarität als Maß für die Lückenhaftigkeit (“Gapiness”) von Fraktalen entwickelt [Man83]. Obwohl zunächst nur für Binärbilder konzipiert, lässt sich das Prinzip mittels kleiner Modifikationen verallgemeinern, so dass es auch für Grauwertbilder nutzbar ist ([Plo96]). Genauer quantifiziert Lakunarität die Lückenhaftigkeit von Texturen, so dass Muster mit mehr Lücken oder auch mit größeren Lücken höhere Lakunaritätswerte erhalten als Muster mit weniger Lücken bzw. mit kleineren Lücken.

Nach [Wil15] ist die Lakunarität L einer abzählbaren Menge N von n (Pixel-)Intensitätswerten $x_i \in N$, ($i = 1, \dots, n$) definiert als der Quotient der Varianz σ^2 und des Quadrats des Mittelwerts der Intensitätswerte μ^2 , d. h.

$$L = \frac{\sigma^2}{\mu^2} \quad (6.21)$$

unter Verwendung der zugehörigen Definitionen in den Gleichungen (3.5) und (3.6). Durch Umformungen unter Berücksichtigung der Rechenregeln bei Summen kann man zeigen, dass gilt:

$$\sum_{i=1}^n (x_i - \mu)^2 = \sum_{i=1}^n x_i^2 - n \cdot \mu^2 \quad (6.22)$$

Damit lässt sich die Lakunarität in Gleichung (6.21) dann folgendermaßen ausdrücken:

$$L = n \frac{\sum_{i=1}^n x_i^2}{(\sum_{i=1}^n x_i)^2} - 1 \quad (6.23)$$

Die Lakunarität ist zwar grundsätzlich für völlig beliebige (Pixel-)Mengen N definiert, lässt sich aber am besten für ganze (Grauwert-)Bilder berechnen. Dabei ist von Vorteil, dass es im Fall von rechteckigen Pixelblöcken möglich ist, Integralbilder zu nutzen, um die Berechnungen zu beschleunigen. Zu diesem Zweck ist das *Integralbild* J eines Bildes I an der Stelle (r, c) in Anlehnung an [Wil15] definiert wie folgt:

$$J(r, c) = \sum_{r' \leq r, c' \leq c} I(r', c') \quad (6.24)$$

Dies lässt sich auch als rekursive Berechnungsvorschrift formulieren:

$$J(r, c) = I(r, c) + J(r, c-1) + J(r-1, c) - J(r-1, c-1) \quad (6.25)$$

Aufgrund der beiden Summen in Gleichung (6.23) werden auch zwei Integralbilder benötigt. Das zu I gehörige Integralbild sei J_1 , während zu I^2 entsprechend J_2 gehört, wobei hier mit I^2 die elementweise Quadrierung der Bildmatrix I gemeint ist. Dann lässt sich die Summe der Pixel in ei-

ner rechteckigen Bildregion um ein zentrales Pixel an der Stelle (r, c) relativ schnell berechnen über S_p , ($p = 1, 2$):

$$S_p(r, c) = J_p(r - \tilde{r}, c - \tilde{c}) - J(r - \tilde{r}, c + \tilde{c}) - J(r + \tilde{r}, c - \tilde{c}) + J(r + \tilde{r}, c + \tilde{c}) \quad (6.26)$$

Dabei bezeichnen \tilde{r} , \tilde{c} die halben Seitenlängen der aktuellen Boxgröße, d. h. $n = 4\tilde{r}\tilde{c}$ entspricht der Anzahl der Pixel eines Bildausschnitts in dieser Boxgröße.

Die Lakunarität lässt sich dann berechnen mittels:

$$L = n \cdot \frac{S_2}{S_1^2} - 1 \quad (6.27)$$

Statt von Blockgrößen spricht man in diesem Zusammenhang normalerweise von “Boxgrößen” (der Begriff stammt aus der fraktalen Geometrie), zum einen weil die Boxen nicht quadratisch sein müssen, zum anderen weil auch die Vorgehensweise bei der Berechnung etwas anders ist als bei einer Standard-Blockverarbeitung. Die jeweilige Boxgröße korrespondiert zu der Größe der Strukturen, die das Lakunaritätsmaß erfassen kann. Daher ist es üblich, die Lakunarität eines Bildes für sämtliche möglichen Boxgrößen zu bestimmen, d. h. angefangen mit den kleinsten 2×2 Pixelblöcken bis hin zur kompletten Bildgröße.

Um letztendlich eine Art Homogenitätskarte der Bilddaten zu erhalten, bietet sich somit wieder eine blockweise Implementierung bei jeweils fester Blockgröße an wie im Fall der Standardabweichung in Abschnitt 4.4.2, z. B. als gleitende Nachbarschaftsoperation, um so Informationen über die lokale Lakunarität zu gewinnen.

In der Abbildung 6.13 ist die lokale Lakunarität am Beispiel des “Kameramann”-Bildes dargestellt wie sie beispielsweise auch zur Ermittlung von Auffälligkeiten (z. B. zur Detektion Seeminen in Verbindung mit ATR-Algorithmen³) in Sonarbildern eingesetzt werden kann. Die Abbildung 6.14 zeigt zusätzlich einen Vergleich der lokalen Lakunarität für verschiedene (maximale) Boxgrößen in Falschfarbendarstellung (obere Reihe), sowie der daraus resultierenden (binären) Homogenitätskarten, um deren unterschiedliche Wirkung zu verdeutlichen. Die Binarisierung erfolgt wieder mithilfe eines geeigneten Schwellwerts.

³ ATR (“Automatic Target Recognition”): Verfahren zur automatischen Zielerkennung

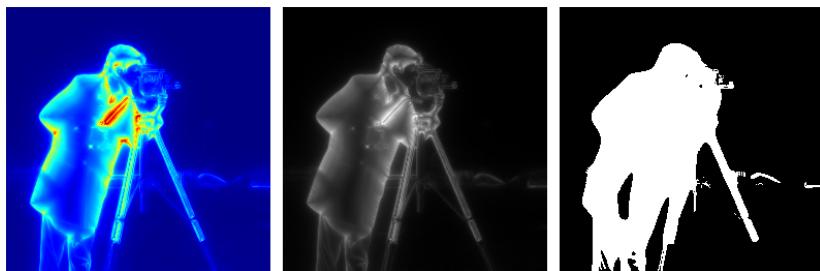


Abbildung 6.13: Lakunarität als Homogenitätsmaß. Links: Falschfarbendarstellung; Mitte: Grauwertbild; rechts: binarisiertes Bild.

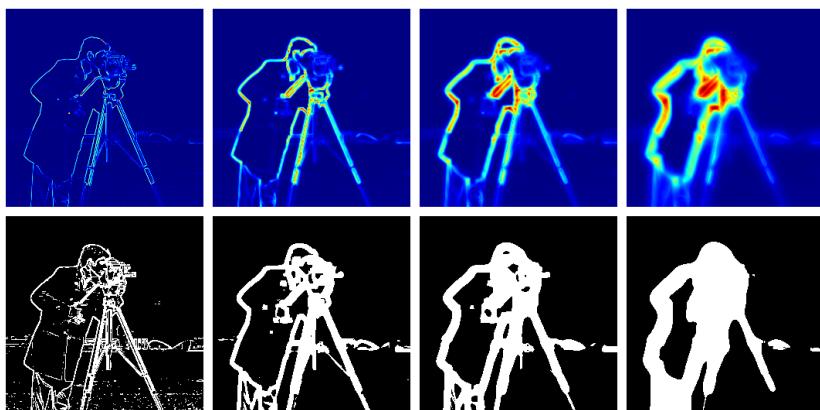


Abbildung 6.14: Lakunarität bei verschiedenen maximalen Boxgrößen (v.l.n.r.): 1 px, 4 px, 8 px, 16 px. Oben: Falschfarbendarstellung; unten: korrespondierende Homogenitätskarten (Mittelwert als Schwellwert).

In der praktischen Anwendung auf reale Bilddaten, die unter Turbulenzbedingungen aufgenommen wurden, ist damit zu rechnen, dass die Bilder unscharf und möglicherweise verrauscht sind. In der Abbildung 6.15 ist ein Beispiel dazu gezeigt anhand der “NATO/Mannequin”-Sequenz aus Abschnitt 6.1.2.

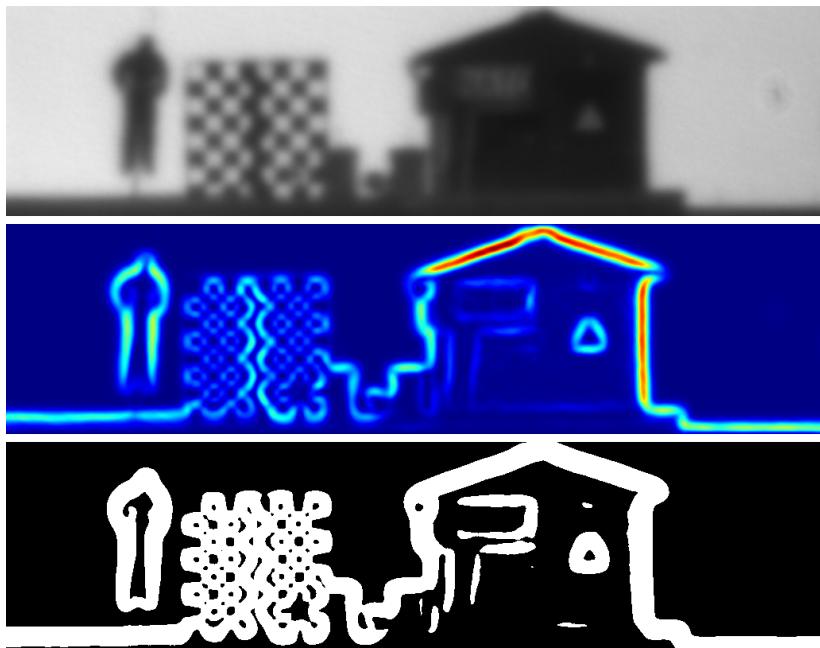


Abbildung 6.15: Anwendung auf Bilddaten mit realer Turbulenz. Oben: Mittelwert von 100 Frames der “NATO/Mannequin”-Testsequenz; Mitte: lokale Lakunarität in Falschfarbendarstellung; unten: resultierende binäre Homogenitätskarte.

Da die r_0 -Schätzungen für hinreichend lange Bildsequenzen konzipiert sind, ist es von Vorteil (zur Zeitersparnis) nur eine einzige Homogenitätskarte für die gesamte Sequenz zu bestimmen. Dazu bietet sich wieder der zeitliche Mittelwert (oder Median) an, da dieser im Rahmen einer Turbulenzkorrektur u. U. ohnehin berechnet wird.

Reduziert man die Boxgröße bis zu 1 oder 2 Pixel, fungiert diese Lakunariätsberechnung wie ein Kantenfilter, wie das linke Bild in der Abbildung 6.14 leicht erkennen lässt. Einfache Kantenfilter wie Sobel oder Canny wären allerdings ungeeignet, denn einerseits können Einzelframes u. U. sehr verrauscht sein, wodurch die Kantenerkennung gestört würde, und andererseits

haben Kantenfilter Probleme, Kanten in allzu verschwommenen Bildern zu detektieren (z. B. infolge starker Turbulenz) wie ein Vergleich der Kantenbilder zur “NATO / Mannequin”-Testsequenz in der Abbildung 6.16 verdeutlicht, bei dem die Kanten im Mittelwertbild stärker ausgeprägt sind.

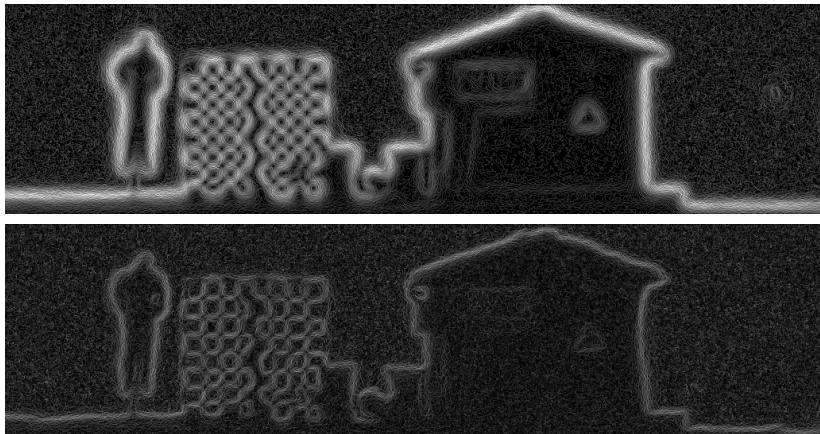


Abbildung 6.16: Kantenbilder für die “NATO/Mannequin”-Testsequenz.
Oben: Kantenbild des Mittelwerts von 100 Frames; unten: Kantenbild eines Einzelbildes (5. Frame).

Es sollte noch angemerkt werden, dass die Berechnungen von Homogenitätskarten mittels Standardabweichung u. U. sehr viel Zeit in Anspruch nehmen können, vor allem für kleine Blockgrößen. Für Bilder derselben Größe (256×256 Pixel) wie das Testbild in Abbildung 6.12 (links) wurden durchschnittlich über ca. 2 sec pro Bild zur Berechnung auf einem normalen Laptop benötigt, während zur Berechnung der Lakunarität in Abbildung 6.14 (links) lediglich ca. 0,7 sec erforderlich waren. Dabei ist es durchaus möglich, dass eine optimierte Implementierung diesen zeitlichen Unterschied stark reduzieren könnte. Im Hinblick auf Echtzeitszenarios sind allerdings auch 0,7 sec immer noch sehr viel Zeit. Da dieser Schritt jedoch nur in gewissen zeitlichen Abständen oder bei Bedarf wiederholt werden muss, z. B. wenn sich die Umweltbedingungen wahrnehmbar geändert haben oder falls die letzten Messungen nicht zufriedenstellend gewesen sein sollten, spielt der Zeitfaktor nur eine untergeordnete Rolle.

6.4 Bildvorverarbeitung bei Turbulenz

Die Vorverarbeitung von Einzelbildern kann einen großen Unterschied zum Gesamtergebnis eines jeden Algorithmus zur Bildverbesserung in Videodaten beitragen, abhängig von der Beschaffenheit und Qualität der betreffenden Rohdaten. Auch im Fall von Turbulenzkorrekturverfahren hat es sich als vorteilhaft erwiesen, turbulenzgestörte Daten zunächst einigen Vorverarbeitungsschritten zu unterziehen, um die Korrekturergebnisse zu optimieren. Dazu gehört insbesondere eine Kontrastverbesserung, die sich nicht zuletzt auch bei der Bewegungsschätzung positiv auswirken kann, da die Kanten detektion dadurch unterstützt wird. Bei stark verrauschten Daten ist es überdies von Vorteil, wenn zuvor eine Form von Mittelwertbildung durchgeführt werden kann (ggfs. mit Bildregistrierung), da sich dadurch das SNR verbessern lässt. Weiterhin kann auch ein direktes Deblurring der Eingangsdaten das finale Rekonstruktionsergebnis positiv beeinflussen. Dabei ist die Reihenfolge dieser Vorverarbeitungsschritte, die jeweils optional sind und nicht zuletzt von der Qualität der Eingabedaten abhängen, nicht fest vorgeschrieben und kann je nach Bedarf abgeändert werden.

6.4.1 Kontrastverbesserung

Hinsichtlich des Bildkontrasts gilt, je stärker die Turbulenz ist, desto größer ist auch der Kontrastverlust in Relation zu dem gleichen Bild unter Idealbedingungen (d. h. ohne Turbulenz). Sämtliche in dieser Arbeit diskutierten Methoden benötigen deutliche Strukturen in den Bilddaten, um funktionieren zu können. Das trifft auf Entfaltungsverfahren ebenso zu wie auf Algorithmen zur Bewegungsschätzung. Eine Kontrastverbesserung ist daher in vielen Fällen angebracht, um die weitere Verarbeitung zu erleichtern.

Es gibt verschiedene Möglichkeiten zur Kontrastanhebung, angefangen mit einfacher Spreizung der tatsächlich in den Daten vorhandenen Intensitäts werte auf den vollen Dynamikbereich über ausgleichende Histogramm Modifikationen bis hin zu komplexeren “Dehazing”-Methoden für Szenen mit unterschiedlichen Entfernungsbereichen (z. B. weiter entfernte Gebirgs züge etc.). Hier wurde bevorzugt eine Kontrastverbesserung mittels adaptivem Histogramm-Ausgleich durchgeführt, genauer mittels CLAHE (“Contrast Limited Adaptive Histogram Equalization”) gemäß [Zui94], wobei ein

gegebenes Bild in Kacheln unterteilt wird, für die der lokale Kontrast bestimmt und verstärkt wird.

6.4.2 Rauschreduktion

Bei atmosphärisch gestörten und verrauschten Daten ist es oft nahezu unvermeidlich, zumindest irgendeine Form von Mittelwertbildung anzuwenden. Da unter Turbulenzbedingungen der Informationsgehalt eines Einzelbildes nicht notwendigerweise größer ist als der eines Kurzzeitmittelwertes, speziell bei einer kurzen Integrationszeit mit hoher Datenrate, überwiegen die Vorteile (z. B. verbessertes SNR, sowie glattere und geometrisch korrektere Strukturen) in der Regel die Nachteile eines solchen Vorgehens.

Generell gilt bei der Erfassung von Bilddaten durch atmosphärische Turbulenz, dass die Integrationszeit idealerweise $\leq \tau_0$ sein sollte. Gerade bei starker Turbulenz kann dies extrem kurze Belichtungszeiten bedeuten, wodurch sich der Rauschpegel in Abhängigkeit von den aktuellen Lichtverhältnissen signifikant erhöhen kann. In solchen Fällen kann u. U. der Einsatz zusätzlicher rauschreduzierender Maßnahmen erforderlich werden. Hierzu können 2-D Rauschfilter für Bilddaten eingesetzt werden, so wie z. B. ein 2-D Median oder Wiener Filter.

6.4.3 Einzelframe-Deblurring

Die optionale Vorverarbeitungskette aus Kontrastanhebung und Rauschreduktion kann zusätzlich um ein Einzelbild-Deblurring ergänzt werden, bei dem Einzelbilder einer Sequenz mit einer geeigneten theoretischen PSF entfaltet und so geschärft werden (siehe Abschnitt 6.2 und insbesondere Abschnitt 6.2.3). Die Wahl dieser theoretischen PSF erfolgt je nach vorliegender Limitierung und hängt von den jeweiligen Systemparametern (Wellenlänge, Teleskopdurchmesser, IFOV), den physikalischen Gegebenheiten der beobachteten Szene (Objekt-Entfernung, tatsächliche Objektgröße), sowie der gemessenen oder geschätzten Turbulenzstärke C_n^2 ab.

Da jede Form der Bildstapelung die Gefahr birgt, dass Unschärfe entsteht oder verstärkt wird, sollte dennoch nicht auf eine abschließende Entfaltung verzichtet werden, wenn das Ziel eine bestmögliche Bildrekonstruktion ist.

6.4.4 Bewegung und Turbulenz

Wenn eine Sequenz mit hoher Framerate aufgezeichnet wurde und die abgebildete Szene bewegte Objekte enthält, lässt sich diese Eigenbewegung zwischen zwei Einzelbildern u. U. nicht detektieren und insbesondere nicht von Turbulenzbewegungen unterscheiden. Eine Möglichkeit, die Bewegungsdetektion in solchen Fällen zu erleichtern und zugleich den Rauschpegel zu senken, besteht darin, einige (wenige) Einzelbilder zu ihrem Mittelwert zusammenzufassen, ggf. nach entsprechender Registrierung. Bereits durch eine Bildmittelung von nur einigen wenigen Frames lässt sich das SNR deutlich verbessern. Dies trifft insbesondere auch im Fall der “China Lake”-Sequenz zu. Die Abbildung 6.17 vermittelt einen Eindruck vom Bewegungsinhalt der Sequenz und zeigt die durchschnittliche Differenz zwischen den Einzelbildern (links) als eine Art Bewegungskarte (“Motion Map”), sowie die durchschnittliche Betragsgröße der Bewegungsvektoren (rechts), wobei hierfür eine Blockgröße von 8×8 Pixeln gewählt wurde.

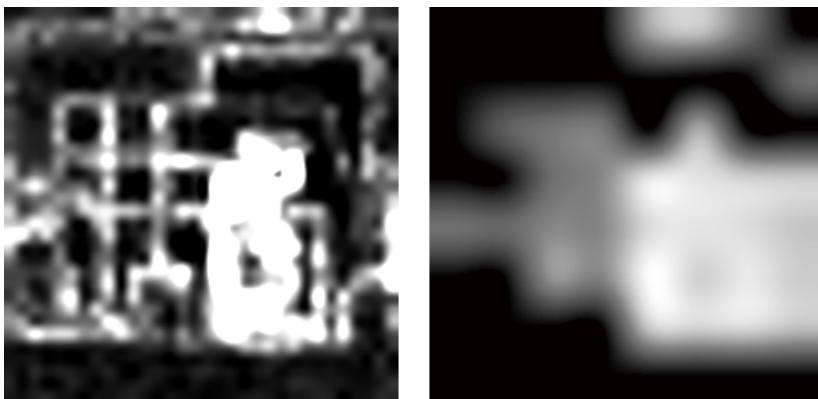


Abbildung 6.17: Bewegungsinhalt der “China Lake”-Sequenz. Links: durchschnittliche Differenz zwischen den Bildern als Bewegungskarte; rechts: durchschnittlicher Betrag der Bewegungsvektoren.

Dass die Bewegungskarte die Eigenschaften eines Kantenbildes aufweist, resultiert aus dem Apertur-Problem, da das Schachbrettmuster auf der Tafel im Bild aus gleichmäßig gefärbten Bereichen besteht, die größer sind als die gewählte Blockgröße. Zudem wird das von benachbarten Bereichen

ausgehende Licht aufgrund der Turbulenz über die Ränder hinaus verteilt, was zu einer scheinbaren Bewegung führt.

Angesichts der großen Bildrate (4097 Bilder, 300 fps) in Verbindung mit den relativ kleinen Bewegungen, die in der beobachteten Szene enthalten sind, ist es ein logischer Schritt, die Anzahl der Bilder geschickt zu reduzieren. Daher wurde zunächst ein Abschnitt mit 1250 Frames gewählt, in dem die meisten Bewegungen auftreten. Wenn man nur eines von fünf Bildern nimmt, d. h. die Sequenzlänge effektiv auf 250 Bilder reduziert, wird die Bewegung ausreichend beschleunigt, um eine Bewegungsdetektion zu ermöglichen. Speziell im Fall von Beeinträchtigungen durch Turbulenz lässt sich die Genauigkeit der Bewegungsdetektion noch etwas erhöhen, wenn jeweils der Durchschnitt aller fünf Einzelbilder genommen wird, anstatt nur eines von je fünf Bildern auszuwählen. Das hängt damit zusammen, dass Kanten im Mittelwertbild etwas gerader und glatter erscheinen, weniger "aufgebrochen" und "zerrissen" als in den Einzelbildern. Zusätzlich kann auch die Verwendung einer kleinen Kontrastverbesserung die Ergebnisse weiter verbessern. Die Abbildung 6.18 zeigt ein Beispielergebnis für eine solche Bildvorverarbeitung von einem Einzelbild (links) zu dem Mittelwert von 5 Frames mit zusätzlicher CLAHE-Kontrastverstärkung.



Abbildung 6.18: Beispiel für Bildvorverarbeitung bei Turbulenz. Links: originales Einzelbild aus der "China Lake"-Sequenz (300 fps); rechts: Ergebnis einer Kontrastverbesserung mittels CLAHE.

6.5 “Motion Compensated Averaging”

Die bewegungskompensierende Bildmittelung (“Motion Compensated Averaging”, MCA) wie sie u. a. in [Hue08] vorgestellt wurde, entspricht im Wesentlichen normaler Bildintegration. Der Hauptunterschied besteht darin, dass das nächste Bild der Eingangssequenz vor der Integration innerhalb eines vorgegebenen Suchraums um eine bestimmte Anzahl von Pixeln in jeder Richtung leicht verschoben wird, so dass das Eingangsbild am besten mit einem vorgegebenen Referenzbild übereinstimmt. Es sollte angemerkt werden, dass sich dies mit Subpixelgenauigkeit implementieren lässt.

Das Ergebnis dieser bzgl. globaler Bewegungen kompensierter Bildmittelung entspricht idealerweise einem Bild am Diffraktionslimit, welches wiederum mit der entsprechenden theoretischen PSF für den “Short Exposure” Fall (Gl. (6.9)) gefaltet wurde. Aus diesem Grund sollte an dieser Stelle noch ein abschließendes Deblurring erfolgen, z. B. unter Verwendung einer der Entfaltungsalgorithmen aus Abschnitt 5 bzw. der in Abschnitt 6.6 beschriebenen mehrstufigen gewichteten IBD.

Es existieren zahlreiche Varianten dieser Methode, die im Zusammenhang mit Speckle-Imaging auch als “Shift & Add” bezeichnet wird ([Car02]). Die Hauptunterschiede liegen in der Wahl der “Matching”-Methoden und -Kriterien begründet. Einige solcher Methoden wurden in Abschnitt 4.2 vorgestellt und diskutiert.

6.5.1 Referenzbild-Selektion

Im Idealfall ist dieses Referenzbild ein Bild, das durch die Atmosphäre und das optische System nicht beeinträchtigt wird. Da ein solches Idealbild normalerweise nicht zur Verfügung steht, stellt ein gleitender Mittelwert einen einfachen und sinnvollen Ersatz dar. Alternativen sind der zeitliche Median oder der zeitliche Modalwert der Sequenz, wie insbesondere in [Hue10] im Detail untersucht wurde.

Temporaler Median

Ein Medianfilter wird im Gegensatz zum Mittelwert nicht von Ausreißern in einem Datensatz beeinflusst, was bedeutet, dass er potenziell den Verlust

von Details reduzieren kann. Der Preis für diese höhere Auflösung ist jedoch die Einführung von Artefakten, wenn Bewegungen auftreten, die langsam genug sind, um in das (gleitende) Medianbild aufgenommen zu werden. Da es sich dabei auch um Bewegung durch Turbulenz handeln kann, können für den Median bei starken Turbulenzbedingungen ggf. doppelt so viele Frames erforderlich sein, um die gleiche Art von geometrischer Korrektheit des Hintergrunds zu erhalten wie es beim Mittelwert der Fall ist. Hinzu kommt, dass sämtliche Artefakte durch die abschließende Entfaltung noch verstärkt werden, so dass selbst minimale Artefakte deutlich erkennbar werden.

Temporaler Modalwert

Ein verwandtes Konzept in der Statistik ist der zeitliche *Modalwert* (auch “Modus”), wobei der Modalwert einer diskreten Wahrscheinlichkeitsverteilung dem Wert mit der höchsten Wahrscheinlichkeit entspricht. Bezogen auf Bildsequenzen bedeutet dies, dass jedes Pixel des modalen Bildes denjenigen Intensitätswert annimmt, der im Laufe der Zeit an dieser Position am häufigsten aufgetreten ist.

Diskussion

Um die visuellen Unterschiede über einen hinreichend langen Zeitraum zu veranschaulichen, werden in der Abbildung 6.19 der zeitliche Mittelwert, Median und Modalwert für jeweils dieselben 250 sequentiellen Bilder miteinander verglichen. Dabei wurde bewusst ein Zeitabschnitt gewählt, der auch einige Bewegungen enthält.

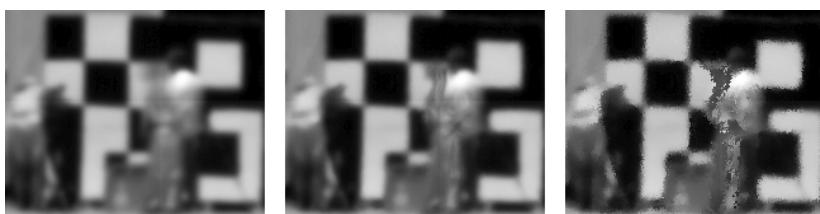


Abbildung 6.19: Vergleich von Mittelwert (links), Median (Mitte) und Modalbild (rechts), jeweils für 250 Frames der Sequenz

Bildschärfe und Kontrast sind beim modalen Bild eindeutig am besten. Aber während der Modus offensichtlich sehr gut innerhalb homogener Bildregionen funktioniert, sind die Kanten ziemlich stark verrauscht. So grenzen die schwarz und weiß kontrastierenden Felder nicht unmittelbar aneinander, sondern sind durch graue (Mischfarbe) Bereiche getrennt, deren Breite der Größe der Turbulenzbewegungen (in Pixeln) entspricht. Das heißt, Bewegungen haben einen stärkeren Einfluss auf den Modalwert als auf den Median, insbesondere auch abrupte und schnelle Bewegungen. Der Mittelwert verhält sich etwas “nachsichtiger” gegenüber solchen “Ausreißern” durch bewegte Objekte ebenso wie durch starke Turbulenzbewegungen. Hinzu kommt, dass er sich wesentlich schneller berechnen lässt als die beiden anderen Werte. Es sollte dennoch erwähnt werden, dass in [Pot10] eine Möglichkeit zur Reduktion dieser Übergangseffekte beim Modalwert vorgeschlagen wird.

Eine weitere gebräuchliche Alternative besteht darin, einfach das erste Bild der Sequenz zu verwenden und in regelmäßigen Abständen durch eine aktuelle Version zu ersetzen. Der Vorteil dieser Methode liegt auf der Hand, da keine gesonderten Berechnungen durchgeführt werden müssen. Der Nachteil ist, dass etwaige Bildverformungen in diesem Referenzframe als korrekt betrachtet werden und daher im Rekonstruktionsprozess erhalten bleiben. Bei isoplanatischen Bedingungen ist dies eine durchaus praktische und sinnvolle Lösung. Bei anisoplanatischen Bedingungen wäre hingegen eine der anderen Lösungen (d. h. Mittelwert oder Median) zu empfehlen.

6.5.2 MCA mit “Block Matching”

Unter anisoplanatischen bzw. lokal isoplanatischen Bedingungen führen turbulenzbedingte Bildbewegungen nicht nur zu globalen Bildverschiebungen, sondern auch zu lokalen Verschiebungen zwischen aufeinanderfolgenden Frames. Zur Berücksichtigung dieser Verschiebungen wurde speziell der MCA-Algorithmus in [Hue09] zusätzlich um ein “Block Matching” gemäß [Gya03] erweitert, um gleichmäßig verschobene Bildteile zu identifizieren und neu anzutragen (s. a. Abschnitt 4.2 für weitere BM-Algorithmen). Genauer wird ein “Block Matching” auf Pixelebene durchgeführt, wobei die Pixel des aktuellen Bildes blockweise mit denen eines Referenzbildes verglichen und für optimale Übereinstimmung verschoben werden.

Anmerkungen zur Implementierung

Zur Laufzeitbeschleunigung kann der pixelbasierte BM-Algorithmus durch ein FFT-basiertes Verfahren ersetzt werden, welches die beste Übereinstimmung anhand von Korrelationsberechnungen zwischen den Blöcken ermittelt. Hierdurch kann eine signifikante Beschleunigung (ca. 20-30 fach) erzielt werden, da die Geschwindigkeit nicht mehr von der Größe des gewählten Suchraumes abhängig ist. Als problematisch hat sich hierbei allerdings herausgestellt, dass die Genauigkeit der berechneten Verschiebungsvektoren umso mehr abnimmt, je kleiner die Blockgröße gewählt wird (ab ca. 16×16 Pixel). Dies hängt u. a. mit dem Apertur-Problem zusammen, denn je kleiner die Bildblöcke sind, desto größer ist die Wahrscheinlichkeit, dass der Bildinhalt nur wenige oder gar keine Strukturen enthält zwischen denen sich sinnvolle Korrelationen berechnen lassen (z. B. Bildausschnitte, die nur Himmel oder Asphalt zeigen). Ein möglicher Lösungsansatz besteht darin, das korrelationsbasierte Verfahren über einen pyramidalen Ansatz zu implementieren, d. h. mehrstufige Ausführung mit sukzessive halbierten Blockgrößen, um so Ausreißer unter den errechneten Vektoren besser erkennen zu können. Eine denkbare, wenn auch eher unpraktische Alternative wäre eine Kombination beider Verfahren, bei der das pixelbasierte Verfahren gleichsam als Kontrollinstanz fungiert.

6.5.3 Lokale Bildstapelung

Der MCA-Algorithmus mit “Block Matching” funktioniert am besten für statische Szenen bzw. für Szenen, in denen die Bewegung vernachlässigbar ist. Denn im Fall von Objektbewegung hat der Einsatz von Bildmittelung zur Folge, dass auftretende Bewegungsunschärfen proportional zur Anzahl der gestapelten Bilder verstärkt werden. Dabei spielt es keine Rolle, ob es sich tatsächlich um reale Bewegungsunschärfe handelt oder ob diese erst durch die Mittelung erzeugt wird.

Eine Lösungsmöglichkeit, die zuerst in [Hue11] vorgestellt wurde, besteht in einer gerichteten lokalen Bildstapelung (“Local Image Stacking”, LIS) ausschließlich für die bewegten Objekte in der Szene. Hierbei wird “Block Matching” dazu verwendet, gerichtete Bewegung von Objekten zu detektieren und von turbulenzbedingter, ungerichteter Bewegung zu unterscheiden.

Sofern die Objektbewegung gegenüber der Turbulenzbewegung deutlich überwiegt, ermöglicht dies eine Segmentierung von statischen Szenenelementen und bewegten Objekten, so dass Vorder- und Hintergrund getrennt voneinander verarbeitet werden können.

Zugrundeliegende Idee

Die Abbildung 6.20 vermittelt einen Eindruck von der Effektivität der lokalen Bildstapelung, indem hier das “Stacking” zu Demonstrationszwecken global ausgeführt wurde. Das heißt, in der turbulenzfreien “Ettlinger Tor”-Testsequenz⁴ (links) ist die Bewegungskompensation auf die Korrektur der Bewegung des Busses ausgerichtet, wobei eine Stapeltiefe von 6 Bildern verwendet und eine konstante Verschiebung von 1 Pixel in beide Richtungen angenommen wurde. Währenddessen ist sie in der “China Lake”-Sequenz (rechts) auf die horizontale Personenbewegung ausgerichtet, wobei eine durchschnittliche horizontale Verschiebung von 0,666 Pixeln zwischen den Frames angenommen und eine Stapeltiefe von 8 Bildern verwendet wurde. Die “Ettlinger Tor”-Sequenz mit Objektbewegung, aber ohne Turbulenz, war bewusst gewählt worden, um zunächst einen “Proof of Concept” für das Funktionsprinzip zu erhalten. Wie die Nahaufnahme in der Abbildung 6.21 (links) verdeutlicht, funktioniert das Verfahren bei linearen Bewegungen tatsächlich sehr gut, denn das Heck des Busses ist ebenso klar definiert wie im Einzelbild (Mitte). Die leicht erhöhte Unschärfe an seiner Vorderseite zeigt, dass der Bus nicht ganz gerade, sondern eine leichte Kurve fährt. Die Verbesserung im Vergleich zu dem gewöhnlichen Durchschnitt von 6 Bildern (rechts), ist dennoch deutlich zu erkennen.

Bei den durch Turbulenz gestörten Daten wirkt der Fokussierungseffekt weit weniger ausgeprägt, wie in der Abbildung 6.20 (rechts) zu sehen ist. Zum einen liegt dies daran, dass Gehbewegungen von Personen in der Realität nicht völlig linear in horizontaler Richtung verlaufen. Arm- und Beinbewegungen haben z. B. immer auch eine kleine vertikale Komponente, deren Korrektur hier vernachlässigt wurde. Zum anderen sorgt die ungerichtete

⁴ Quelle: KOGS/IAKS Universität Karlsruhe, verfügbar unter: [http://i21www.ira.uka.de/
image_sequences/](http://i21www.ira.uka.de/image_sequences/); Aufnahme der “Ettlinger Tor”-Sequenz: Henner Kollnig

Turbulenzbewegung infolge der starken Turbulenz in der Sequenz ohne hin für einen hohen Grundpegel an Unschärfe. Hinzu kommt, dass einem menschlichen Beobachter der optische Unterschied zwischen einem gestochten scharfen Bild und einem etwas unscharfen Bild unverhältnismäßig viel stärker auffällt als der Unterschied zwischen dem etwas unscharfen Bild und einem doppelt so unscharfen Bild.



Abbildung 6.20: Demonstration des gerichteten Stapeleffekts. Links: Bildstapel auf die Bewegung des Busses ausgerichtet, Stapeltiefe: 6 Frames; rechts: Bildstapel für horizontale Bewegung, Stapeltiefe: 8 Frames.



Abbildung 6.21: Bildausschnitt zur Veranschaulichung des Effekts der lokalen Bildstapelung; Links: Bildstapel auf die Bewegung des Busses ausgerichtet; Mitte: Einzelbild; rechts: normaler Durchschnitt von 6 Bildern.

Das LIS-Prinzip

Die Abbildung 6.22 veranschaulicht das Grundprinzip des LIS, welches es ermöglicht, die Vorteile der Bildstapelung beizubehalten ohne den Nachteil erhöhter Unschärfe in Kauf nehmen zu müssen. Es wird dabei eine rückwirkende gerichtete lokale Bildstapelung für die bewegten Elemente durchgeführt, wodurch die Bewegungsunschärfe, die sonst durch Mittelwertbildung entstehen würde, effektiv reduziert wird und das finale Rekonstruktionsergebnis insgesamt verbessert.

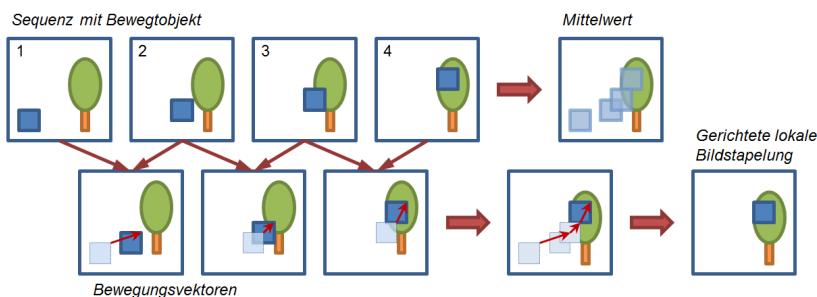


Abbildung 6.22: Prinzip der lokalen Bildstapelung

Die Umsetzung erfordert ein paar zusätzliche Modifikationen des MCA-Grundalgorithmus. Für die Bilder sowie für die zugehörigen Bewegungsvektoren, die für jedes Paar aufeinanderfolgender Bilder berechnet werden, wird ein Kurzzeitpuffer verwendet (z. B. der Länge $n = 5$ oder $n = 10$, je nach Umfang der Bewegung) zusätzlich zu dem bereits vorhandenen Langzeitpuffer, der nach wie vor für die statischen Bildregionen benötigt wird. Die Bilder $I^{(1)}, \dots, I^{(n)}$ dieses Kurzzeitpuffers werden in umgekehrter Reihenfolge gestapelt. Das heißt, jeder Pixelblock des Bildes $I^{(n)}$ wird entsprechend den Verschiebungen, die durch den korrespondierenden Bewegungsvektor gegeben sind, verschoben und zu dem passenden (nicht verschobenen) Block im vorherigen Bild $I^{(n-1)}$ hinzugefügt. Das resultierende Ergebnis wird wiederum so verschoben, dass er mit dem Bild aus dem Schritt zuvor übereinstimmt, d. h. $I^{(n-2)}$. Dies wird für die gesamte Länge des Puffers wiederholt, bis das erste Element im Puffer erreicht ist. Das Endergebnis muss

noch durch die Anzahl der aufsummierten Blöcke geteilt werden. Da diese Anzahl je nach Position variiert, muss ein pixelgenauer Zähler mitgeführt werden.

Unterscheidung zwischen Turbulenz- und Objktbewegung

Obwohl die durch atmosphärische Turbulenzen verursachte Bewegung potenziell omnidirektional ist, wie links in der Abbildung 6.23 angedeutet, ist sie in der Realität nicht völlig zufällig. Sie ist vor allem vom vorherrschenden Seitenwind abhängig, d. h. von der Windgeschwindigkeit und dem Winkel in Bezug auf die Sensorposition. Außerdem ist es statistisch betrachtet sehr wahrscheinlich, dass gerade bei hohen Bildraten und entsprechend kurzen Belichtungszeiten ($< \tau_0$) eine gewisse Korrelation zwischen aufeinanderfolgenden Bildern besteht, weshalb auch turbulenzbedingte Bewegungen nicht zwangsläufig allzu schnell oder drastisch die Richtung ändern. Daher ist zu erwarten, dass die Trennung zwischen derartiger halb ungerichteter Bewegung von realer Objektbewegung nur dann effektiv funktionieren kann, wenn die Größenordnung der Objektbewegung die der Turbulenz übersteigt. Nachdem die Bewegungsvektoren für eine bestimmte Anzahl von Frames geschätzt wurden, muss entschieden werden, ob die berechnete Verschiebung als Teil einer gerichteten Objektbewegung betrachtet werden kann

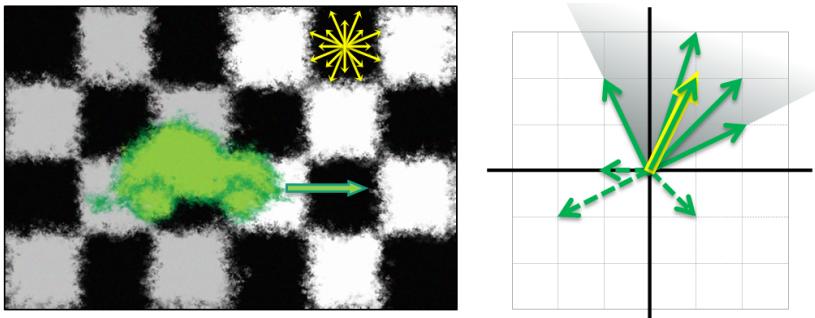


Abbildung 6.23: Akzeptabler Bereich der Vektorwinkel (grau) für gerichtete Bewegung und resultierende Hauptrichtung (roter Pfeil), abweichende Vektoren sind gestrichelt dargestellt.

oder nicht. Zur Reduktion von Falsch-Detektionen werden nur Verschiebungsvektoren als "Bewegung" akzeptiert, falls der durchschnittliche Betrag der berechneten Vektoren über einem vorgegebenen Schwellwert liegt. Alle anderen werden unterdrückt.

Als weiteres Entscheidungskriterium bietet sich der Winkel zwischen benachbarten Vektoren an. Da eine maximale Abweichung innerhalb eines 90° -Winkels leicht durch die Überprüfung des Skalarprodukts zwischen den Vektoren überprüft werden kann (wenn das Skalarprodukt ≥ 0 ist, ist der Winkel zwischen den Vektoren $\leq 90^\circ$), wurde dieser als akzeptabler Winkel gewählt. Das rechte Bild in der Abbildung 6.23 veranschaulicht die Situation, in der die Mehrheit der Vektoren innerhalb des akzeptablen 90° -Winkels liegt, während die anderen als Ausreißer betrachtet werden.

Die Abbildung 6.24 zeigt die geschätzten lokalen Bildverschiebungen über den Verlauf der "China Lake"-Sequenz exemplarisch für die im Bild markierte Position. Der linke Plot enthält die Orientierungen und Längen der auftretenden Verschiebungsvektoren und der rechte Plot enthält die zugehörige Häufigkeitsverteilung.

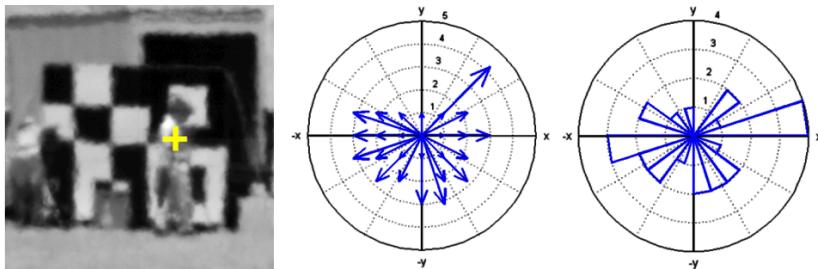


Abbildung 6.24: Lokale Bildverschiebungen (in Pixeln) an markierter Position im linken Bild. Mitte: während der Sequenz auftretende Verschiebungsvektoren; rechts: Häufigkeitsverteilung der Verschiebungen.

Die Abbildung 6.25 zeigt einen Vergleich des Ergebnisses lokaler Bildstapelung, für das insgesamt 40 Bilder verwendet wurden, mit dem normalen Mittelwert von 20 Bildern. Obwohl doppelt soviel Frames gemittelt wurden, ist das LIS-Ergebnis dennoch sichtlich schärfer und klarer definiert als der einfache Mittelwert.



Abbildung 6.25: Vergleich lokaler und normaler Bildstapelung. Links: Mittelwert aus 8 vorverarbeiteten Bildern (d. h. Mittelwert aus je 5 Frames) bei lokaler Bildstapelung mit Blockgröße 32, d. h. entspricht dem Mittelwert aus 40 Bildern; rechts: normaler Mittelwert aus jeweils 20 Bildern.

Vorschläge zur Optimierung

Besteht das Ziel in einer bestmöglichen Bildrekonstruktion, die z. B. offline ohne zeitliche Einschränkungen (und nicht schritthaltend) durchgeführt werden kann, lässt sich das Rekonstruktionsergebnis noch etwas optimieren, indem sowohl eine räumliche als auch eine zeitliche Nachbarschaft der geschätzten Verschiebungsvektoren einer Art Plausibilitätsprüfung unterzogen wird. Idealerweise werden dazu zunächst die Bewegungsvektoren über den gesamten Verlauf der Sequenz bestimmt, analysiert und ggf. korrigiert, wobei Ausreißer z. B. durch einen (gewichteten) Mittelwert der räumlich und/oder zeitlich benachbarten Vektoren ersetzt werden können.

Speziell für das LIS-Ergebnis in Abbildung 6.25 wurden jeweils die beiden zeitlich vorhergehenden Bewegungsvektoren und die beiden nachfolgenden Vektoren an der gleichen lokalen Position überprüft (insgesamt 4 Vektoren), während räumlich insgesamt 24 umgebende Bewegungsvektoren (zum gleichen Zeitpunkt) mithilfe des Skalarprodukts hinsichtlich ihrer jeweiligen Winkel zueinander analysiert wurden. Zwar ist es denkbar, größere Nachbarschaften zu verwenden, der zusätzliche Informationsgewinn nimmt aber mit zunehmendem Abstand zur Position des zu überprüfenden Vektors schnell ab, wobei auch die gewählte Blockgröße eine Rolle spielt. Abhilfe schafft ein ergänzendes Gewichtungssystem, welches die Nachbarvektoren entsprechend ihrer Entfernung zu dem aktuell zu prüfenden Vektor gewich-

tet, so dass die unmittelbaren Nachbarn die größtmögliche Gewichtung bekommen. Sollte der Vektor als Ausreißer identifiziert worden sein, wird der betreffende Vektor durch die (jeweils gewichteten) mittleren Verschiebungen in vertikaler und horizontaler Richtung ersetzt.

6.6 Mehrstufige gewichtete IBD

Bei geringer Turbulenz kann Einzelframe-Deblurring durchaus ausreichend sein. Für ein optimales Rekonstruktionsergebnis ist jedoch bei stärkerer Turbulenz in der Regel zusätzliches Deblurring erforderlich, z. B. mithilfe blinder Entfaltung (siehe Kapitel 5).

Zu diesem Zweck wurde in [Hue09] eine *mehrstufige gewichtete iterative blinde Entfaltung* (“Weighted Iterative Blind Deconvolution”, WIBD) vorgeschlagen, zur Verbesserung der Ergebnisqualität speziell des klassischen IBD-Algorithmus. Es handelt sich dabei um eine Erweiterung des IBD-Algorithmus, die im Wesentlichen aus einer Verkettung mehrerer gewöhnlicher Entfaltungsschritte besteht, jeweils mit variierender Trägergröße der Filterfunktion und unterschiedlicher Anzahl zugehöriger Iterationen. Der Hauptunterschied zum Standardalgorithmus liegt dabei in der Verwendung einer Gewichtungsfunktion, mit deren Hilfe die schärfende Wirkung der Entfaltung lokal an den Kanten verstärkt wird, während gleichzeitig Ringing-Effekte in unstrukturierten Bildregionen reduziert werden.

Genauer lässt sich der mehrstufige Entfaltungsprozess in die folgenden drei Phasen unterteilen:

1. $\hat{f}^{(m)} = \text{IBD des Eingabebildes } g \text{ mit den Filterfunktionen } h_1, \dots, h_m \text{ und zugehörigen Iterationen } i_1, \dots, i_m$
2. $\hat{f}^{(k)} = \text{IBD des Zwischenergebnisses } \hat{f}^{(m)} \text{ mit den Filterfunktionen } h_{m+1}, \dots, h_k \text{ und zugehörigen Iterationen } i_{m+1}, \dots, i_k$
3. $\hat{f} = \text{mittels Kantenbild } M \text{ gewichtete Summe aus } \hat{f}^m \text{ und } \hat{f}^k$

Das heißt, sowohl in der ersten als auch in der zweiten Phase wird das beobachtete Eingabebild g unter Verwendung des klassischen IBD-Algorithmus iterativ in insgesamt k Wiederholungen entfaltet, wobei in jedem Schritt eine andere Filterfunktion h_j mit unterschiedlicher Trägergröße und Anzahl Iterationen i_j eingesetzt wird. Das Zwischenergebnis im m -ten Schritt

$\hat{f}^{(m)}$ wird dabei separat abgespeichert, da es später noch benötigt wird. Die generelle Iterationsvorschrift lässt sich folgendermaßen formulieren:

$$\hat{f}^{(j)} = \text{IBD}(\hat{f}^{(j-1)}, h_{j-1}, i_{j-1}) \quad (j = 2, \dots, k) \quad (6.28)$$

Die Reihenfolge der h_j spielt dabei keine Rolle, wobei es aus praktischer Sicht naheliegt, für beide Phasen jeweils auf- oder absteigende Trägergrößen zu wählen. Diese gestaffelte Vorgehensweise ist durchaus sinnvoll, da Turbulenzzellen unterschiedlicher Größe vor der Optik vorbeiziehen und so Bildstörungen und Bildbewegungen verursachen, welche unterschiedlichen PSF-Größen entsprechen. Es hat sich in der Praxis als erfolgreich erwiesen, diese Art von Störungen getrennt in mehreren Schritte zu korrigieren.

In der dritten Phase dient das Sobel-gefilterte Referenzbild (d. h. der gleitende Mittelwert oder temporale Median) als Gewichtungsfunktion, wobei ebenso andere Kantenfilter, wie z. B. der Canny- oder der Laplace-Filter, eingesetzt werden könnten.

Genauer fungiert das resultierende Kantenbild als Maske M (d. h. $M(x, y) \in [0, 1] \forall (x, y)$), mit deren Hilfe sich die Schätzung \hat{f} für alle Pixel (x, y) als gewichtete Summe aus der m -ten und der k -ten Iterationsstufe bei der Entfaltung ausdrücken lässt, d. h. $\hat{f}^{(m)}$ und $\hat{f}^{(k)}$:

$$\hat{f}(x, y) = M(x, y) \cdot \hat{f}^{(m)}(x, y) + (1 - M(x, y)) \cdot \hat{f}^{(k)}(x, y) \quad (6.29)$$

Das heißt insbesondere, dass die Bildbereiche auf und in der Nähe von Kanten überwiegend Anteile der späteren Iteration $\hat{f}^{(k)}$ enthalten, während homogene Bildbereiche weiter weg von den Kanten hauptsächlich aus der früheren Iteration $\hat{f}^{(m)}$ bestehen. Dadurch erscheinen die Kanten deutlich schärfer, während sich zugleich Ringing-Effekte (siehe Abschnitt 5.4.3) an Kanten erfolgreich reduzieren lassen.

Die Abbildung 6.26 (mittlere Reihe) zeigt einen Vergleich der Ergebnisse der mehrstufigen gewichteten Entfaltung (WIBD) mit Ergebnissen der klassischen IBD, sowie mit einem Einzelbild der Sequenz und dem einfachen Mittelwert. Das Bild unten links in der Abbildung zeigt zusätzlich die zugehörige Gewichtungsfunktion. Im Vergleich mit dem entsprechenden Kantenbild des Resultats der WIBD-Entfaltung (unten rechts) sind insbesondere die besser definierten Kanten infolge verbesserter Bildschärfe klar ersichtlich.

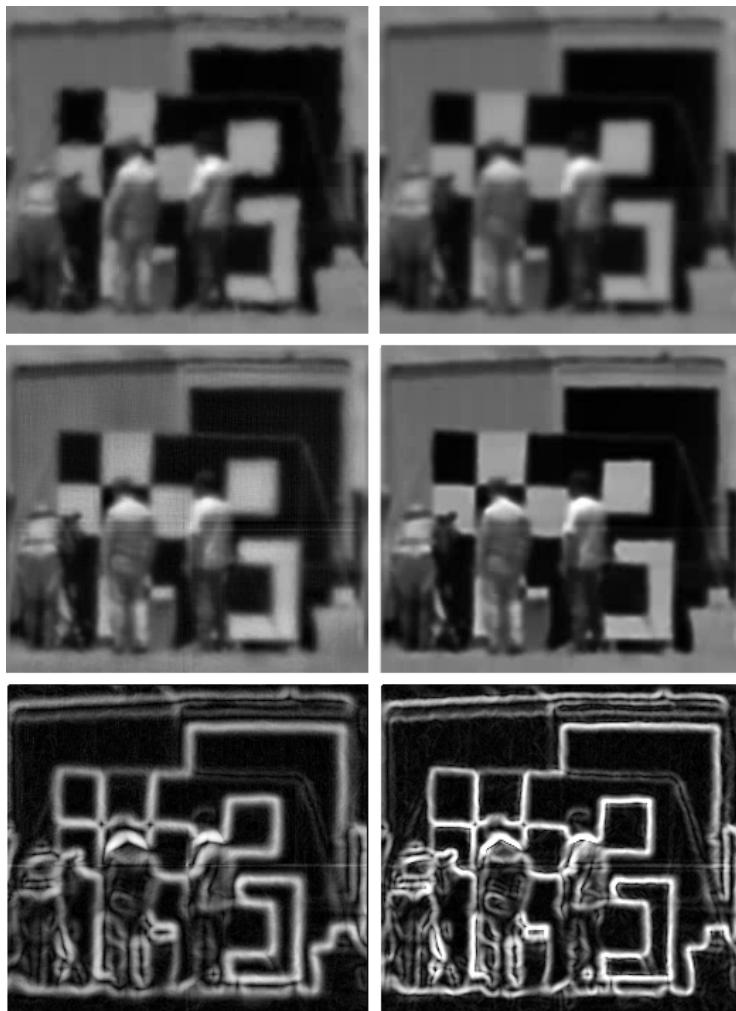


Abbildung 6.26: Oben: Original (links) u. Mittelwert 100 Frames mit globaler Registrierung (rechts); Mitte: Turbulenzkorrektur mit IBD (links) u. mit mehrstufiger WIBD (rechts) im Vergleich; unten: Sobel-gefitertes Mittelwertbild als Gewichtungsfunktion u. Sobel-gefiterter Resultat der WIBD (rechts).

Anmerkungen

Es sollte noch angemerkt werden, dass dieses mehrstufige Prinzip einschließlich einer Gewichtungsfunktion für Bildkanten ggfs. auch unter Verwendung anderer Entfaltungsverfahren durchgeführt werden kann.

Ebenfalls sollte erwähnt werden, dass durch die Verkettung von blinden Entfaltungsschritten unter Verwendung unterschiedlicher Filtergrößen u. U. Artefakte erzeugt werden können, die wie Schraffuren erscheinen. In der Abbildung 6.27 ist dazu ein Beispiel zu sehen, worin die Schraffuren in einem Detailausschnitt mithilfe von Kontrastverstärkung sichtbar gemacht wurden. Diese Artefakte lassen sich jedoch mithilfe einer Kantengewichtung wieder reduzieren.



Abbildung 6.27: Schraffur-Artefakte infolge mehrstufiger Entfaltung mit unterschiedlichen Filtergrößen. Links: Beispielbild; rechts: Ausschnittsvergrößerung, zur Verdeutlichung mit Schärfungsfilter und Kontrastverstärkung.

6.7 Korrekturbeispiele

In diesem Abschnitt sind einige weitere Korrekturergebnisse für die verschiedenen Verfahren aus den vorangegangenen Abschnitten zusammengestellt. Die Beispiele sind inhaltlich gemäß zunehmenden Schwierigkeitsgrades sortiert, d. h. entsprechend den vorherrschenden Turbulenzbedingungen und den damit verbundenen zu erwartenden Einschränkungen bzgl. der möglichen Rekonstruktionsqualität. In die Sortierung wird zusätzlich der Bewegungsinhalt (sofern vorhanden), sowie die Entfernung miteinbezogen. Sofern nicht explizit etwas anderes angegeben ist, handelt es sich um Aufnahmen im visuellen Spektrum.

6.7.1 Schwache Turbulenz, statische Szene, große Entfernung

Die Abbildung 6.28 zeigt ein Korrekturergebnis für eine statische Szene in sehr großer Entfernung (der Funkturm am Fremersberg in Baden-Baden, Distanz ca. 27 km). Die Daten wurden morgens (ca. 9:00 Uhr) bei verhältnismäßig schwacher Turbulenz (trotz Sonneneinstrahlung) mithilfe einer Hochgeschwindigkeitskamera aufgezeichnet. Als Grundlage für die Korrektur dienten die zwei besten Frames der aufgenommenen Sequenz. Sie wurden zunächst registriert und gemittelt, bevor ein Deblurring mittels mehrstufiger WIBD-Entfaltung durchgeführt wurde. Die erhöhte Bildqualität des Rekonstruktionsergebnisses ist offensichtlich, insbesondere die verbesserte Erkennbarkeit der Details, wie z. B. der am Turm angebrachten Aufbauten. Dies liegt einerseits daran, dass die Umweltbedingungen zu diesem Zeitpunkt verhältnismäßig gut waren (d. h. geringe Turbulenz, gute Lichtverhältnisse, geringe Luftfeuchtigkeit etc.), und andererseits auch daran, dass die Integrationszeit sehr kurz gewählt wurde (< 1 ms), um die Kohärenzzeit nicht zu überschreiten.

Es sollte auch erwähnt werden, dass sich der Vignettierungseffekt in den Bilddaten ggfs. noch zusätzlich korrigieren ließe.



Abbildung 6.28: Beispiel für Turbulenzkorrektur. Links: Originalaufnahme, Objektentfernung ca. 27 km, bei schwacher Turbulenz; rechts: Korrekturergebnis, mehrstufige blinde Entfaltung, aus zwei registrierten Einzelbildern.

6.7.2 Moderate Turbulenz, statische Szene, mittlere Entfernung

Das Beispiel in Abbildung 6.29 stammt aus der “Stadium Lamps”-Sequenz (s. a. Abschnitt 6.1.2). Da es sich um ein rein statisches Objekt handelt, wurde keine explizite Bewegungskompensation durchgeführt. Unter den gegebenen Bedingungen wäre der Informationsgewinn nur minimal, wohingegen der zusätzliche Rechenaufwand signifikant ansteigen würde (speziell in Verbindung mit LIS). Stattdessen wurde nur eine globale Registrierung der Frames durchgeführt bevor der gleitende Mittelwert von je 100 (registrierten) Frames einem WIBD-Deblurring und einer leichten CLAHE-Kontrastanhebung unterzogen wurde.

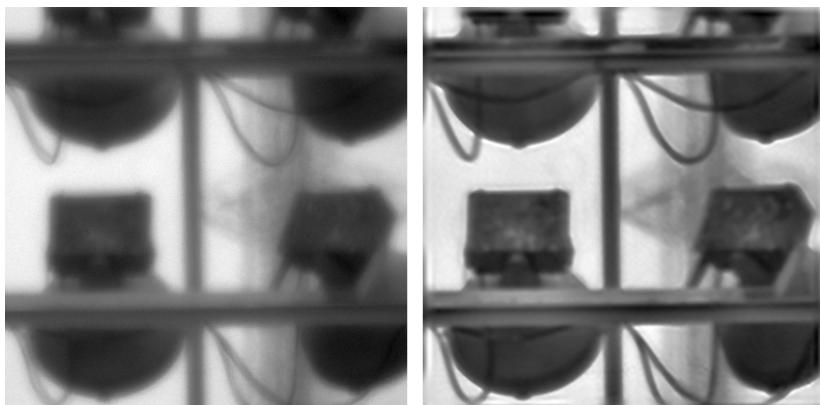


Abbildung 6.29: Turbulenzkorrektur statischer Objekte am Beispiel der “Stadium Lamps”-Sequenz. Links: unverändertes Einzelbild, Objektentfernung ca. 2-3 km, moderate Turbulenz; rechts: Deblurring des global registrierten Mittelwerts (100 Frames) mittels mehrstufiger blinder Entfaltung zzgl. minimaler CLAHE-Kontrastverstärkung.

Dies trifft weitgehend auch auf die anderen beiden in Dayton aufgenommenen Sequenzen zu, insbesondere auf die “NATO / Mannequin”-Sequenz (s. a. Abschnitt 6.1.2) in der Abbildung 6.30. Mit $C_n^2 = 5 \cdot 10^{-16} \text{ m}^{-2/3}$ war die Turbulenz zum Aufnahmezeitpunkt relativ schwach, weshalb sich trotz der

größeren Entfernung (ca. 7-8 km) die gleiche Art von Korrektur ohne allzu viele Modifikationen einsetzen ließ. Auch konnte auf eine zusätzliche Kontrastverstärkung verzichtet werden.

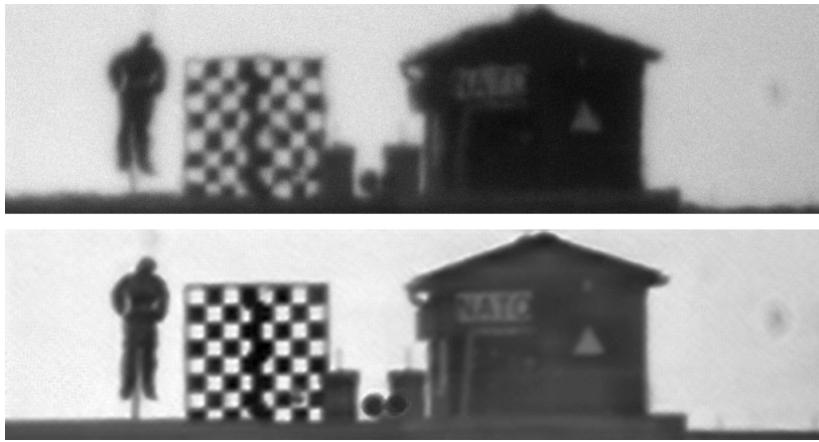


Abbildung 6.30: Turbulenzkorrektur statischer Objekte am Beispiel der “NA-TO / Mannequin”-Sequenz. Oben: unverändertes Einzelbild, Objektentfernung ca. 7-8 km, moderate Turbulenz; unten: Deblurring mittels mehrstufiger blinder Entfaltung.

Der Funkmast in der “Antenne”-Sequenz (s. a. Abschnitt 6.1.2) befand sich ebenfalls in ca. 7 km Entfernung. Allerdings herrschte während der Erfassung die gleiche erhöhte Turbulenzstärke wie zuvor in der “Stadium Lamps”-Sequenz. Um der schlechteren Bildqualität entgegen zu wirken, wurden deshalb für das Ergebnis in der Abbildung 6.31 nur die besten 250 Frames (von 500) ausgewählt, wobei die “Blur”-Metrik aus [Dol07] als Selektionskriterium verwendet wurde. Anschließend wurde wieder eine globale Registrierung durchgeführt und der resultierende gleitende Mittelwert einem WIBD-Deblurring unterzogen (ohne zusätzliche Kontrastverbesserung).

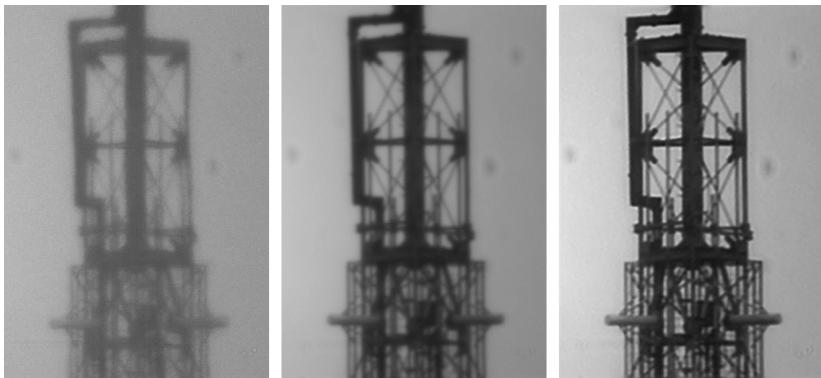


Abbildung 6.31: Beispiel für Turbulenzkorrektur statischer Objekte. Links: unverändertes Einzelbild, Objektentfernung ca. 7 km, moderate Turbulenz; Mitte: Mittelwert der besten 250 Frames (von 500) nach globaler Registrierung; rechts: Deblurring mittels mehrstufiger blinder Entfaltung.

6.7.3 Starke Turbulenz, moderate Objektbewegung, mittlere Entfernung

Der Schwierigkeitsgrad der Rekonstruktionsaufgabe erhöht sich im Fall der “China Lake”-Sequenz (s. a. Abschnitt 6.1.1) noch einmal deutlich. Sowohl die stärkere Turbulenz ($C_n^2 = 1,3 \cdot 10^{-13} \text{ m}^{-2/3}$), als auch die zusätzliche Objektbewegung machen zusätzliche Maßnahmen erforderlich, vor allem eine lokale Bewegungskompensation.

Das mittlere Bild in der Abbildung 6.32 zeigt ein Beispielergebnis der mittels “Block Matching” erweiterten lokalen MCA-Bewegungskompensation (siehe Abschnitt 6.5.2). Genauer handelt es sich um das Durchschnittsbild aus 100 aufeinander folgenden Einzelbildern, die sowohl global als auch lokal registriert wurden. Das zugehörige Resultat einer mehrstufigen gewichteten blinden Entfaltung ist rechts in der Abbildung zu sehen. Zum Vergleich ist links auch eines der verwendeten unveränderten Einzelbilder abgebildet. Das Beispiel in der Abbildung 6.33 enthält hingegen deutlich mehr Objektbewegung, so dass die Rekonstruktion basierend auf dem Mittelwert von 150 bewegungskompensierten Frames (links) entsprechende Bewegungs-

unschärfe aufweist. Das mittlere Bild zeigt das Ergebnis der lokalen Bildstapelung gemäß LIS-Prinzip (siehe Abschnitt 6.5.3), wobei eine Blockgröße von 32×32 px verwendet wurde und eine Stapeltiefe von 8 vorverarbeiteten Frames (je Mittelwert von 5 Frames, d. h. 40 Frames insgesamt).



Abbildung 6.32: Beispiel für MCA mit lokaler Bewegungskompensation. Links: unverändertes Einzelbild, Entfernung ca. 1 km, starke Turbulenz; Mitte: MCA mit BM, d. h. Mittelwert von jeweils 100 global u. lokal registrierten Frames; rechts: MCA mit BM und abschließendem WIBD-Deblurring.



Abbildung 6.33: Beispiel für LIS-Turbulenzkorrektur. Links: WIBD-Ergebnis für den Mittelwert von 150 Frames (10 Iterationen); Mitte: LIS und WIBD (Blockgröße 32, Stapeltiefe 8); rechts: LIS und WIBD mit separater Korrektur des Hintergrunds.

Eine zusätzliche Verbesserung lässt sich noch über eine Separierung und unterschiedliche Korrektur von Vorder- und Hintergrund erzielen, wie am rechten Bild in der Abbildung 6.33 zu erkennen. Hier wurden nur die bewegten Objekte im Vordergrund der Szene einer LIS-Bewegungskompensation un-

terzogen, so dass der kürzere Zeitrahmen (40 Frames) Bewegungsunschärfe minimieren kann. Währenddessen sind solche zeitlichen Beschränkungen weniger für die statischen Szenenelemente im Hintergrund erforderlich. Aus diesem Grund wurde hier ein Langzeitmittelwert (150 Frames) als Basis verwendet, wobei die normale MCA mit BM Bewegungskompensation durchgeführt wurde.

Wenngleich die Kanten der Mustertafel im mittleren Bild auf den ersten Blick ein wenig schärfer erscheinen mögen als in dem rechten Bild, weisen sie nicht die gleiche geometrische Korrektheit auf. Zudem fällt die stabilisierende Wirkung geringer aus, was sich allerdings besser in einem Video beobachten lässt.

Es sollte noch erwähnt werden, dass die für die einzelnen Rekonstruktionen verwendeten Entfaltungsparameter (PSF-Größen, Anzahl der Iterationen) nicht alle identisch gewählt wurden, sondern individuell für ein möglichst optimales Ergebnis im Rahmen der Möglichkeiten.

6.7.4 Extreme Turbulenz, statische Sequenz, Nahbereich, aktive Illumination

Wie das Beispiel in der Abbildung 6.36 demonstriert, lassen sich die gleichen Verfahren nicht nur für Kamerasysteme einsetzen, die im VIS- oder im IR-Spektrum operieren, sondern auch für bildgebende Lasersysteme.

Im vorliegenden Fall handelt es sich um eine mit einem VIS-Laser beleuchtete Mustertafel ($\lambda = 532$ nm). Die extrem starke Turbulenz zwischen Sensorik und Objekt wurde mithilfe eines im Maßstab 1 : 3 herunter skalierten Jet-Triebwerks erzeugt. Die Messungen fanden auf dem Gelände der Firma "VOLVO Aero" in Trollhättan, Schweden statt. Innerhalb der Abgasfahne (oder auch: "Plume") wurden C_n^2 -Werte zwischen $6,3 \cdot 10^{-10} \text{ m}^{-2/3}$ und $2,5 \cdot 10^{-10} \text{ m}^{-2/3}$ gemessen, in Abhängigkeit vom Durchmesser der Abgasfahne. Eine Skizze des experimentellen Aufbaus ist in der Abbildung 6.34 dargestellt.

Die Abbildung 6.35 zeigt überdies einen Vergleich der Aufnahmen bei ausgeschaltetem Triebwerk (d. h. ohne Turbulenz) und mit eingeschalteten Triebwerk bei unterschiedlich langer Betriebsdauer. Es ist deutlich zu erkennen, wie die Turbulenz mit der Zeit zunimmt und sich die Größenordnung der Speckle-Muster entsprechend verändert.

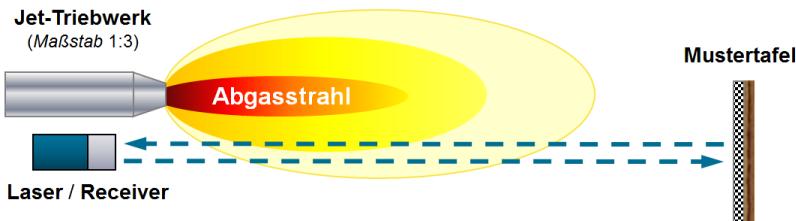


Abbildung 6.34: Experimenteller Aufbau der Messungen bei "VOLVO Aero" entlang des Abgasstrahls eines Jet-Triebwerks (Maßstab 1 : 3)

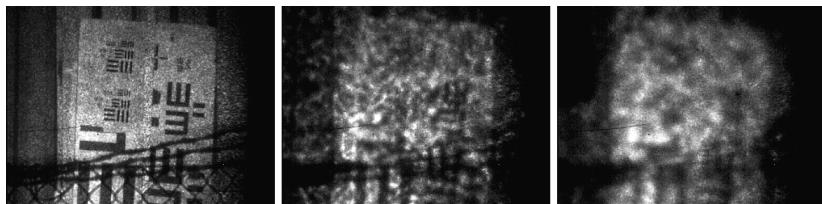


Abbildung 6.35: Beispiel für aktive Beleuchtung bei extremer Turbulenz. Links: bei ausgeschaltetem Triebwerk; Mitte: Triebwerk vor kurzem eingeschaltet; rechts: nach längerer Betriebsdauer des Triebwerks

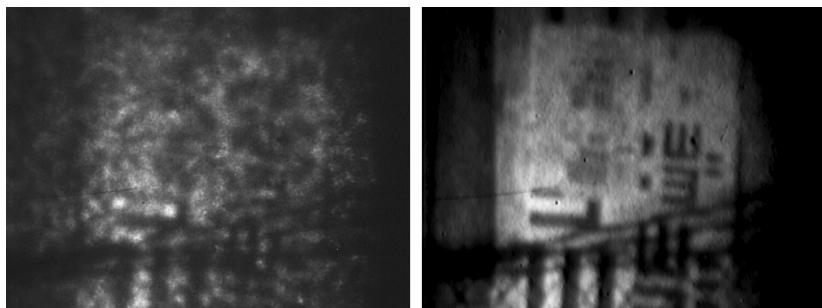


Abbildung 6.36: Beispiel für Turbulenzkorrektur im Fall aktiver Beleuchtung. Links: unverändertes Einzelbild, starke Turbulenz in der Nähe eines laufenden Jet-Triebwerks; rechts: PCA-basierte blinde Entfaltung eines gleitenden Mittelwerts (40 Frames)

Dazu sollte angemerkt werden, dass auch im laufenden Original-Video nicht mehr Details zu erkennen sind als in dem hier abgebildeten Einzelbild (Abb. 6.35 links), da die Speckle-Muster infolge der extremen Turbulenz sehr stark ausgeprägt sind und permanent variieren.

An dieser Sequenz wurden die meisten der Entfaltungsmethoden in Kapitel 5 getestet, wobei die PCA-basierte Methode (aus Abschnitt 5.1.4) in der Abbildung 6.36 die insgesamt überzeugendsten Ergebnisse liefern konnte.

6.8 Farbbilddaten

Bei der Erfassung von Bilddaten durch eine turbulente Atmosphäre werden nur vergleichsweise selten Farbbildkameras eingesetzt. In der Regel kommen monochrome EO-Systeme zur Anwendung, häufig auch IR-Kameras, da größere Wellenlängen weniger stark durch die Turbulenz beeinträchtigt werden.

Es gibt mehrere Gründe, die gegen den Einsatz von Farbbildkameras sprechen, z. B. gehen Farbinformationen aufgrund von atmosphärischer Streuung und Absorption verloren und die Anzahl der wahrnehmbaren Farben nimmt mit zunehmender Entfernung exponentiell ab ([LG14]). Entsprechend sehen Farbbilder, die über mehrere Kilometer hinweg aufgenommen wurden, verwaschen aus mit entsättigten Farben, die möglicherweise an den Objektkonturen “ausbluten” oder ineinander laufen.

Ein weiterer Grund ist in der zugrundeliegenden Sensortechnologie zu finden. Zur Erfassung von Farbinformationen, benötigt eine Kamera entweder (mindestens) drei verschiedene Sensorchips, d. h. einen pro Farbkanal (typischerweise: Rot, Grün, Blau; in selteneren Fällen: Gelb, Magenta, Cyan), jeweils mit einer entsprechenden Elektronik, was eine präzise Registrierung erfordert, oder einen einzelnen Sensorchip, der mit einem Farbfilter-Array (“Color Filter Array”, CFA) abgedeckt ist, so dass nur eine Farbe an jedem Pixel gemessen werden kann. Das bedeutet allerdings, dass die fehlenden zwei Farbwerte an jeder Pixelposition geschätzt werden müssen, wodurch die Gesamtbildauflösung effektiv reduziert wird. Es liegt auf der Hand, dass eine Ein-Sensor-Lösung mit CFA trotz ihrer Nachteile hinsichtlich der geringeren Bildauflösung günstiger zu realisieren und daher verbreiteter ist als ein Drei-Chip-Kamerasystem.

6.8.1 Demosaicing

Der Interpolationsprozess, der im Fall eines CFA zur Schätzung der jeweiligen Farbwerte an jeder Pixelposition erforderlich ist, wird allgemein als “Demosaicing” (oder “Demosacking”) bezeichnet. Das gebräuchlichste Filter-Array hat die Form eines “Bayer-Pattern”, wie es in der Abbildung 6.37 dargestellt ist. In einem CFA mit Bayer-Pattern enthält jeder 2×2 -Pixel-Block ein rotes Pixel, ein blaues Pixel und zwei diagonal gegenüberliegende grüne Pixel, wobei unterschiedliche Kombinationen gebräuchlich sind.

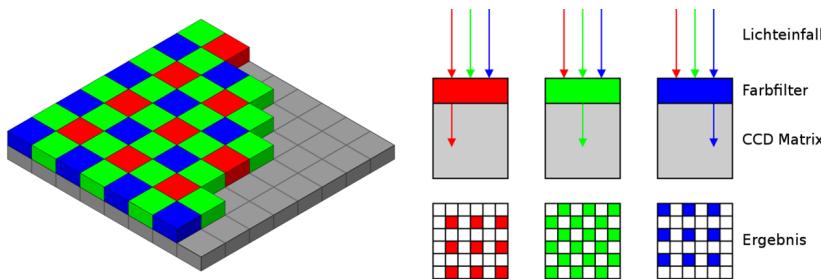


Abbildung 6.37: CFA mit Bayer-Pattern. Links: Die Farbfilter auf dem Farbfilterarray des Bayer-Sensors; rechts: Querschnitte der Farbfilter.⁵

Da die in der grünen Wellenlänge enthaltene Information über die Leuchtdichte (auch: Luminanz) höher ist, wird der grüne Kanal im Vergleich zu den anderen beiden Kanälen mit doppelter Rate abgetastet. In der Abbildung 6.38 ist exemplarisch eine Simulation der Bilddaten eines Sensors mit einem Bayer-CFA dargestellt, wobei die Farbdarstellung (rechts) nur zur Identifizierung dient, welches Pixel welche Farbinformation beinhaltet.

Es gibt mehrere Möglichkeiten, die Farbinformationen aus den in einem Bayer-Pattern gespeicherten Rohdaten zu extrahieren und drei separate Farbkanäle (RGB) zu erzeugen. Der “naive” Ansatz wäre, die roten und blauen Pixelwerte unverändert als Farbwert für ihren jeweiligen Kanal zu setzen und den Mittelwert der beiden grünen Pixel für den grünen Kanal zu neh-

⁵ Quelle: Cburnett, CC BY-SA 3.0 <<http://creativecommons.org/licenses/by-sa/3.0/>>, via Wikimedia Commons



Abbildung 6.38: Simulation eines Bayer-CFA. Links: hochauflöses Original-Farbbild “Peppers” (Quelle: MATLAB), das weiße Rechteck markiert den im folgenden verwendeten Bildausschnitt; Mitte u. rechts: Bayer-CFA-Simulation mit “RGGB”-Muster in Graustufen- (Mitte) und entsprechender Farbdarstellung (rechts).

men. Davon ist jedoch abzuraten, denn die gewählten Farbwerte stammen von unterschiedlichen Pixelpositionen, so dass die einzelnen Farbkanäle R, G und B nicht übereinstimmend ausgerichtet sind. Entsprechend wäre das Ergebnis ein unnötig unscharfes Bild. Zudem würde dies eine deutliche Reduzierung der Auflösung auf ein Viertel der ursprünglichen Sensorgröße bedeuten, wie die Abbildung 6.39 demonstriert (2. Bild von links). Bereits eine bilineare oder bikubische Interpolation der einzelnen Kanäle erzielt eine signifikante Verbesserung (2. Bild von rechts). Allerdings können dadurch auch Farbartefakte, ähnlich Moiré-Effekten, entstehen. Infolgedessen wurden im Laufe der Jahre eine Reihe von ausgefeilten Algorithmen zur Schätzung der fehlenden Farbwerte für jedes Pixel entwickelt wie z. B. das Verfahren von Malvar et al. [Mal04] (Abbildung 6.39 ganz rechts). Einen einführenden Überblick über die gebräuchlichsten und gut etablierten Methoden ist in [Gun05] gegeben.

6.8.2 Verwendung des LAB-Farbraumes

Im wissenschaftlichen Kontext haben Genauigkeit und eine hohe Auflösung der erfassten Bilddaten normalerweise einen höheren Stellenwert als chromatische Informationen, die überdies durch Turbulenz gestört sind. Dennoch wächst das Interesse an der Verarbeitung von Farbvideodaten, denn



Abbildung 6.39: Vergleich von Interpolationsmethoden für CFA. V. l. n. r.: Ausschnitt des hochauflösten Originalbildes; skaliertes Ergebnis des “nai-ven Ansatzes”; bilineare Interpolation; Demosaicing gemäß [Mal04].

Bilder im sichtbaren Spektrum, insbesondere Farbbilder, sind für einen ungeschulten menschlichen Beobachter oft leichter zu interpretieren als z. B. thermische Infrarotdaten. Da VIS stärker als IR durch Turbulenz beeinflusst wird, bedeutet dies eine entsprechend stärkere Beeinträchtigung der Bildqualität (d. h. Bildunschärfe, reduzierter Kontrast und Farbverlust) die mit der Entfernung zunimmt. Aus diesem Grund ist in Verfahren zur Turbulenzkorrektur neben einem Deblurring in der Regel auch eine Kontrastverstärkung integriert. Während die meisten Verfahren zur Kontrastverbesserung, wie z. B. ein CLAHE-Histogrammausgleich, bei monochromen Daten oder einzelnen Farbbildern recht gut funktionieren, neigen sie dazu, das Rauschen in einem Farbvideostrom überproportional zu verstärken, insbesondere in Szenen mit geringem Kontrast.

Eine Lösungsmöglichkeit besteht darin, wie in [Hue15] vorgeschlagen und ausgeführt, die Bilddaten zunächst in einen andere Farbraum zu konvertieren, genauer den CIE LAB-Farbraum (auch *LAB*- oder CIE $L^*a^*b^*$). Die eigentliche Farbinformation ist sowohl für das Deblurring als auch für die Kontrastverstärkung nur von sekundärer Bedeutung. Es ist daher naheliegend, das gegebene Problem in eine geeigneten Farbraumdarstellung zu transformieren, die es erlaubt, diese Operationen nur auf dem Bildteil durchzuführen, der die relevanten Informationen enthält.

Der LAB-Farbraum ist geräteunabhängig und ermöglicht eine sehr genaue Darstellung von Farben. Die zugrundeliegende Idee war, die Nichtlinearität des menschlichen Sehens durch ähnlich nichtlineare Beziehungen L^* , a^* und b^* zu approximieren und alle Farben im sichtbaren Spektrum so zu

beschreiben, dass der wahrnehmbare Unterschied zwischen zwei Farben proportional zu ihrem euklidischen Abstand im LAB-Raum ist.

Die L^* Komponente kommt der empfundenen Ähnlichkeit relativ nahe, wobei sich L^* auf die psychometrische Helligkeit bezieht und nicht auf die Luminanz. Die möglichen Werte für L^* liegen zwischen 0 und 100.

Die Farbkomponenten a^* und b^* sind auf Basis der Gegenfarbtheorie konstruiert, d. h. die Komponente a^* beschreibt die Achse zwischen den Gegenfarben Rot und Grün, während b^* in gleicher Weise die Gelb-Blau-Achse beschreibt. Die Werte für a^* liegen ungefähr zwischen -170 und $+100$, während die Werte für b^* ungefähr zwischen -100 und $+150$ liegen, wobei die extremen Werte nur für bestimmte Farbtöne mit mittlerer Helligkeit angenommen werden können.

In diesem Zusammenhang ist anzumerken, dass Konvertierungen vom *RGB*- in den *LAB*-Farbraum verlustfrei sind, allerdings nicht umgekehrt. Auch gibt es hierfür keine direkte Transformation, sondern jede Konvertierung erfolgt notwendigerweise über den CIE XYZ-Farbraum. Alle erforderlichen Umrechnungsformeln sind in [Hue15] zusammengestellt.

Die eigentliche Kontrastverstärkung erfolgt mit einer beliebigen Methode auf der L^* Komponente, z. B. ein Spreizen auf den vollen Dynamikumfang in Verbindung mit einem adaptiven Histogramm-Ausgleich (CLAHE). Das Beispielergebnis in der Abbildung 6.40 zeigt, wie der schwache (Farb-)Kontrast im Originalbild mithilfe einer Kontrastverstärkung im LAB-Farbraum deutlich verbessert werden kann.

Dies hat im übrigen keine größeren Auswirkung auf die Farben im Bild, d. h. die Farbtemperatur, Sättigung etc., sondern nur auf den Kontrast. Der Vorteil dabei ist, dass Farbverfälschungen und Farbrauschen auf diese Weise vermieden werden. Geht es dagegen auch um eine Erhöhung der Farbsättigung, kann eine solche Kontrastverstärkung stattdessen im HSV-Farbraum an der V - ("Value", Helligkeit) und der S -Komponente ("Saturation") durchgeführt werden.



Abbildung 6.40: Beispiel für Bildvorverarbeitung in Farbbilddaten. Linke Spalte (v.o.n.u.): Originalfarbbild (Entfernung ca. 23 km), Resultat der Bildvorverarbeitungskette (Farbkontrastanhebung und Einzelbild-Deblurring), zusätzliche Rauschreduktion; rechte Spalte: korrespondierende Kantenbilder.

6.9 Turbulenzsimulation

Eine unvoreingenommene qualitative Bewertung der jeweiligen Restaurationsergebnisse verschiedener Korrekturmethoden erweist sich generell als schwierig, wenn wenig oder keine zusätzlichen Informationen über das “wahre Bild” verfügbar sind. Vor allem Entfaltungsalgorithmen, wie sie in Kapitel 5 vorgestellt und diskutiert wurden, weisen eine Reihe von unerwünschten Nebeneffekten auf. Dazu gehören u. a. Rauschverstärkung (z. B. Wiener Filter), so wie eine überproportionale Kontrastverstärkung und Verstärkung hoher Frequenzanteile (z. B. PCA). Die Leistungsfähigkeit so genannter “No Reference”-Qualitätsmetriken (siehe Abschnitt 7.1.3) wird dadurch entsprechend eingeschränkt. Aufgrund dessen sind simulierte Turbulenzdaten ein sinnvolles Werkzeug zur Beurteilung der Ergebnisqualität eines gegebenen Algorithmus. Dies gilt umso mehr für Szenen mit bewegten Objekten, deren Verhalten in der Regel nur bedingt vorhersagbar ist.

6.9.1 Simulationsprinzip

Es existieren prinzipiell zwei unterschiedliche Ansätze zur bildhaften Simulation von Turbulenzeffekten. Dies ist zum einen eine reine Simulation der auftretenden Effekte in den resultierenden Bilddaten, d. h. Unschärfe, Bildbewegung etc. Zum anderen ist dies eine physikalisch möglichst korrekte Simulation der Ausbreitung durch die Atmosphäre unter Verwendung von Phasenschirmen (“phase screens”) zur Implementierung des Schichtenmodells in Abschnitt 3.3.4.

Die Vorteile höherer Genauigkeit des zweiten Ansatzes, d. h. einer physikalischen Simulation, liegen auf der Hand. Je genauer eine solche Simulation durchgeführt wird, desto größer ist allerdings auch der damit verbundene Rechenaufwand. Aus praktischen Erwägungen wurde daher in [Hue12b] eine atmosphärische Ausbreitungssimulation erster Ordnung eingesetzt⁶, wobei für jede Wellenlänge ein Phasenschirm verwendet wurde. In dieser Simulation wurden isoplanatische Bedingungen angenommen (d. h. nur globale Bildbewegungen), und Szintillationseffekte wurden vernachlässigt.

⁶ erstellt von S. Gladysz

Genauer wurden mit der klassischen FFT-basierten Methode von McGlamery [McG76] unabhängige Phasenschirme erzeugt, d. h. ein Array von Zufallszahlen wurde gemäß dem von-Kármán-Spektrum gefiltert und dann invers Fourier-transformiert.

Es handelt sich um eine polychromatische Simulation im VIS-Spektrum, d. h. für insgesamt zehn separate Wellenlängen λ im Bereich zwischen 500 nm und 700 nm wurde jeweils eine eigene PSF erzeugt. Dabei entspricht eine monochromatische PSF jeweils einem Phasenschirm. Man kann deshalb davon ausgehen, dass die Bilder nur Speckles von “eingefrorenen” Wellenfronten enthalten und daher sehr kurzen Integrationszeiten in der Größenordnung von 5 ms entsprechen.

Da diese Methode den Nachteil hat, dass niederfrequente Aberrationen nur unzureichend gut repräsentiert werden, wurde zusätzlich eine Subharmonischen-Korrektur gemäß [Lan92] implementiert, mit acht Stufen von Subharmonischen. Ein Vergleich der simulierten und theoretischen Phasenstrukturfunktionen ergab eine hinreichend gute Übereinstimmung.

6.9.2 Parametereinstellungen und Implementierung

Die Simulation wurde für zwei verschiedene äußere Skalenlängen L_0 durchgeführt, einmal für $L_0 = 1$ m und einmal für $L_0 = 10$ m, wobei die Apertur des Teleskops jedes Mal auf $D = 10$ cm gesetzt wurde.

Die Turbulenzstärke wurde in der Größenordnung zwischen $C_n^2 = 10^{-14} \text{ m}^{-2/3}$ und $C_n^2 = 10^{-12} \text{ m}^{-2/3}$ gewählt.

Speziell für die Phasenschirme wurden (Pixel-)Arrays der Größe 256×256 verwendet, wodurch sich eine Pupillenabtastung von 0,4 mm pro Pixel ergibt.

Die Phasenraster wurden zunächst in Phasoren umgewandelt und mit einer entsprechenden kreisförmigen Apertur-Funktion multipliziert. Das Ergebnis wurde zur Erhöhung der Genauigkeit in ein Array von Nullen der Größe 512×512 Pixel eingebettet (“zero padding”) bevor eine Fourier-Transformation durchgeführt wurde.

Die PSF ergibt sich aus dem Quadrat des Betrags des Ergebnisses der FT, wobei wiederum nur der zentrale Teil der Bilder in der Ausgangsgröße, d. h. 256×256 Pixel, gespeichert wird. Das (ursprüngliche) IFOV der PSFs beträgt

dabei $2,44 \mu\text{rad}$, was der Nyquist-Abtastung bei der kürzesten Wellenlänge entspricht.

Damit die Simulation polychromatisch ist, werden wie bereits erwähnt, PSFs für zehn Wellenlängen zwischen 500 nm und 700 nm erzeugt, wobei eine lineare Skalierung der Wellenfronten angenommen wird. Die resultierenden zehn PSFs werden aufsummiert, und das Ergebnis bildet die eigentliche rauschfreie PSF, die abschließend noch normiert wird, so dass ihre Gesamtenergie gleich eins ist.

6.9.3 Simulationsergebnisse

Die Abbildung 6.41 zeigt einige repräsentative Beispiele der mit dieser Simulation erzeugten PSFs, wobei insbesondere die unterschiedlichen PSF-Größen bei einem Vergleich der verschiedenen Turbulenzstärken auffallen. Um einen Eindruck vom Langzeitverhalten zu erhalten, wurden zusätzlich jeweils 20 PSFs integriert und in der rechten Spalte neben den Beispiel-PSFs dargestellt. Da sich zwischen den mittleren PSFs beider Skalenlängen mit bloßem Auge keine nennenswerten Unterschiede erkennen lassen, sind hier nur die Mittelwerte für $L_0 = 1 \text{ m}$ dargestellt.

Die äußere Skalenlänge beeinflusst hauptsächlich die Bildbewegung, daher sehen die PSFs mit $L_0 = 1 \text{ m}$ und $L_0 = 10 \text{ m}$ recht ähnlich aus. Währenddessen hängt die Bildauflösung und -qualität am stärksten von den jeweiligen C_n^2 -Werten ab.

Für die eigentliche Turbulenzsimulation müssen die Bilddaten, die idealerweise möglichst hoch aufgelöst sind, noch über eine Faltung mit den simulierten PSFs verknüpft werden. Für alle drei RGB-Farbkanäle wurde die gleiche PSF verwendet, da die Wellenlängenunterschiede zwischen Rot, Blau und Grün vergleichsweise gering sind.

Aufgrund des erforderlichen Oversamplings der PSF-Filterfunktionen wurden die synthetischen Bilder vor der Filterung unter Verwendung der "Nearest Neighbour"-Vergrößerungsmethode um den Faktor 2 hochskaliert. Außerdem wurde ein "Padding" mittels symmetrischer Replikation durchgeführt, einerseits um die Größenunterschiede zwischen zu filternden Bildern und Filterfunktionen auszugleichen und andererseits, um die Randeffekte infolge der Faltung abzuschwächen. Anschließend wurde das Filterergebnis (ohne "Padding") entsprechend um den Faktor 4 herunterskaliert.

Falls gewünscht, kann dem gefilterten Bild zusätzlich noch eine (additive) Rauschkomponente hinzugefügt werden (s. a. Abschnitt 3.4.10). Poisson-verteiltes Rauschen ist z. B. geeignet, um elektronisches Schrotrauschen zu simulieren, während sich Rauschen, das während der Aufnahme entsteht, mithilfe von Gauß-verteiltem Rauschen imitieren lässt.

Das Ergebnis einer solchen Simulation für Wellenlängen im IR in der Abbildung 6.42 verdeutlicht, wie stark sich unterschiedliche Entfernungen (5 km und 10 km) und Turbulenzstärken ($C_n^2 = 10^{-14} \text{ m}^{-2/3}$ und $C_n^2 = 10^{-13} \text{ m}^{-2/3}$) in den Bilddaten auswirken. Dabei ist zu beachten, dass die Originalaufnahme der Stadt Heidelberg (oben in der Abbildung), die als Grundlage für die Simulationen dient (sowie für Abbildung 3.8), im sichtbaren Spektrum aufgenommen wurde. Das bedeutet, dass die Reflektivitäten in den Simulationen nicht dem tatsächlichen IR-Spektrum entsprechen, wobei "hell" gleichbedeutend ist mit "warm" und "dunkel" mit "kalt".

6.9.4 Tiefenkarten

In der Simulation wurden diverse vereinfachende Annahmen getroffen. Dazu gehört u. a. auch die Annahme, dass alle Objekte in der abgebildeten Szene dieselbe Entfernung zur Kamera haben. In der Praxis ist dies nicht immer der Fall, insbesondere können Objekte im Hintergrund (z. B. landschaftliche Merkmale wie Berge) deutlich weiter entfernt sein. Dementsprechend ist in der Realität auch das Volumen an Turbulenz wesentlich größer, welches das von dort kommende Licht durchqueren muss.

Eine Möglichkeit zur Erhöhung der Genauigkeit besteht in der Verwendung von (synthetischen) Entfernungs- bzw. *Tiefenkarten* mit einer begrenzten Anzahl von m Entfernungs- bzw. *Tiefenebenen* in Verbindung mit entsprechend für die verschiedenen Entfernungen berechneten PSFs h_i .

Sofern vorhanden, kann eine solche Tiefenkarte M als Maske eingesetzt werden bzw. als Linearkombination einer Reihe von Masken M_i ($i = 1, \dots, m$), so dass sich das Simulationsergebnis g (d. h. das beobachtete Bild) beschreiben lässt wie folgt (mit den Bezeichnungen aus Abschnitt 5.1):

$$g = \sum_{i=1}^m M_i \cdot (h_i * f) \quad (6.30)$$

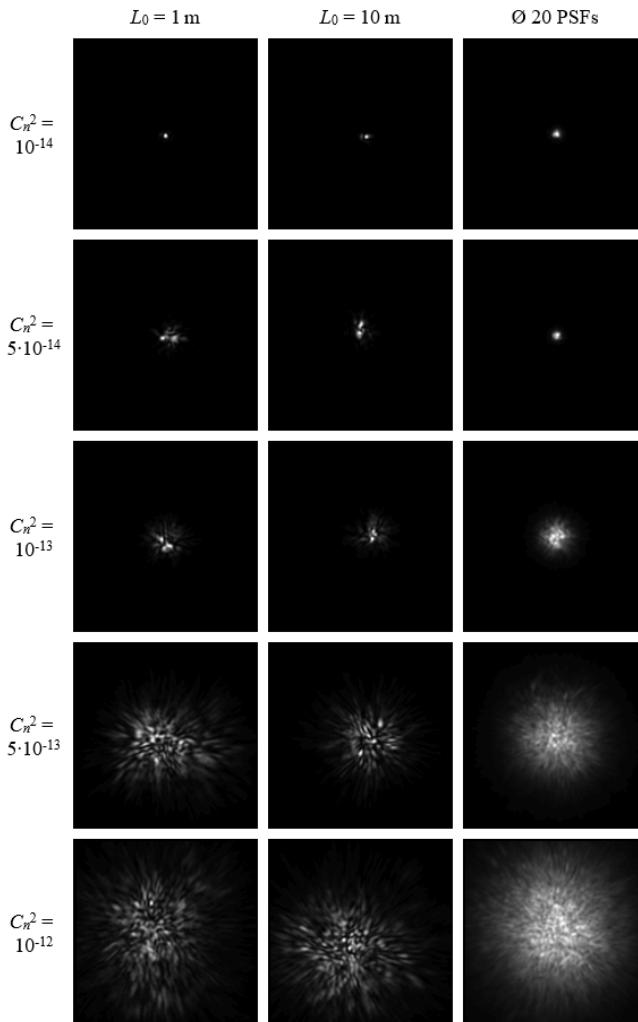


Abbildung 6.41: PSF-Simulationen im VIS-Spektrum mit äußereren Skalenlängen $L_0 = 1 \text{ m}$, $L_0 = 10 \text{ m}$ für ausgewählte Turbulenzstärken C_n^2 in den Größenordnungen zwischen 10^{-14} und 10^{-12} (in $\text{m}^{-2/3}$) im Vergleich mit dem jeweiligen Mittelwert von 20 PSFs (Quelle: [Hue12b]).

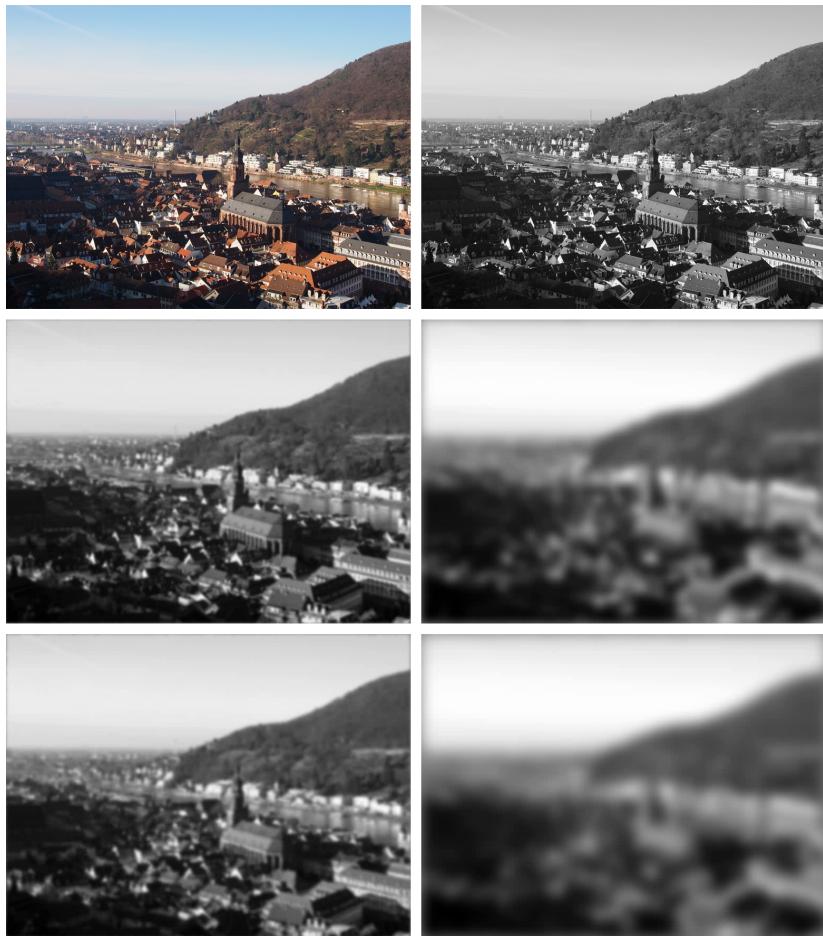


Abbildung 6.42: Turbulenzsimulationen für die Wellenlänge $\lambda = 10 \mu\text{m}$ (im IR) bei äußerer Skalenlänge $L_0 = 1 \text{ m}$ und mit Aperturdurchmesser $D = 9 \text{ cm}$. Oben: originales Farbbild (links) und zugehöriges Grauwertbild (rechts); Mitte: Turbulenzstärke $C_n^2 = 10^{-14} \text{ m}^{-2/3}$, unten: $C_n^2 = 10^{-13} \text{ m}^{-2/3}$, links: Entfernung $L = 5 \text{ km}$, rechts: $L = 10 \text{ km}$ (Foto u. Simulation: S. Gladysz).

In der Abbildung 6.43 ist eine solche Tiefenkarte M skizziert, definiert durch:

$$M = \sum_{i=1}^m i \cdot M_i \quad \text{wobei} \quad \sum_{i=1}^m M_i(x, y) = 1 \quad \forall (x, y) \quad (6.31)$$

Eine solche Vorgehensweise ist allerdings nur dann wirklich sinnvoll, wenn die Entfernungsumsätze in der Szene so groß sind, dass sich die erzeugten PSFs auch genügend voneinander unterscheiden. Hinzu kommt, dass die tatsächlichen Entfernungswerte (z. B. zu einem Gebirge im Hintergrund) häufig nicht bekannt sind und bestenfalls grob abgeschätzt werden können.

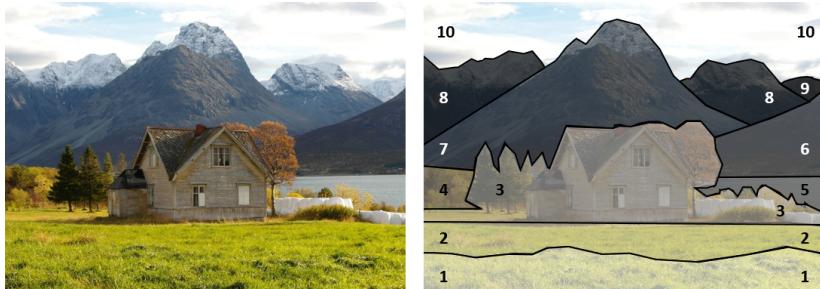


Abbildung 6.43: Beispielhafte Skizze einer Tiefenkarte. Links: Originalbild; rechts: Tiefenkarte mit 10 Tiefenebenen (Farbwahl willkürlich, unabhängig vom Entfernungswert).

6.9.5 Synthetische “Ground Truth” mit Objektbewegung

Statische Einzelbilder wie das zuvor verwendete Foto von Heidelberg in Abbildung 6.42 reichen nicht aus, um auch die Problematik bewegter Objekte zu berücksichtigen, die eine zentrale Rolle dieser Arbeit spielt. Aus diesem Grund wurde speziell eine Turbulenzsimulation mit bewegten Objekten erstellt. Dabei wurden rein synthetisch erzeugte Daten verwendet, genauer ein 3-D POV-Ray⁷ Modell, um sicherzustellen, dass die “Ground-Truth” tatsächlich vollständig bekannt ist.

⁷ POV-Ray: “Persistence of Vision”, ein 3-D “Ray Tracing”-Programm

Das Modell besteht aus einem generischen Militärlager in einem leicht unebenen Gelände und enthält zwei sich bewegende LKWs, die sich in entgegengesetzten Richtungen bewegen. Aus dem 3-D Modell wurde eine RGB-Bildsequenz von 2000 Frames im BMP-Format mit einer Auflösung von 1024×768 Pixeln gerendert⁸. Die Bewegung der beiden Fahrzeuge erstreckt sich über die kompletten 2000 Frames, um eine Hochgeschwindigkeitskamera zu imitieren. Die Abbildung 6.44 zeigt das erste und letzte Bild der erzeugten Sequenz, wobei die Bewegungsspuren beider Fahrzeuge mithilfe farbiger Pfeile dargestellt sind.

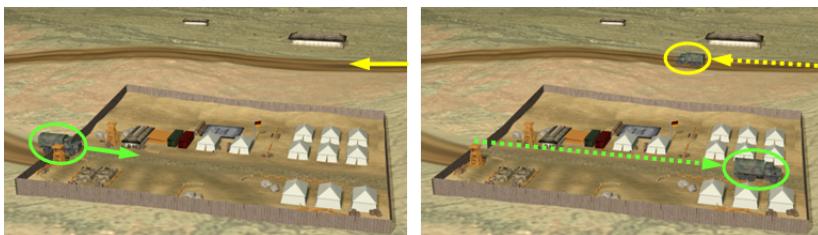


Abbildung 6.44: Erster (links) und letzter Frame (rechts) der synthetischen GT-Sequenz mit Fahrzeugen, wobei die jeweilige Bewegungsrichtung gelb bzw. grün markiert ist.

Dieses 3-D-Modell wurde vor allem wegen seiner großen Flexibilität im Hinblick auf zukünftige Anwendungen gewählt. In einem solchen Modell können z. B. problemlos Sequenzen mit höherer Auflösung erzeugt werden, wobei jedoch zu beachten ist, dass auch die für das Rendering erforderliche Rechenzeit entsprechend mit der Bildauflösung ansteigt. So dauerte das Rendering aller 2000 Bilder der hier verwendeten Sequenz bei einer Auflösung von 1024×768 auf einem herkömmlichen PC etwa 2 Stunden und 20 Minuten.

Ein weiterer offensichtlicher Vorteil ist, dass Objekte entfernt oder hinzugefügt werden können. Auch der Kamerawinkel oder die Beleuchtung lassen sich ohne größeren Aufwand verändern.

⁸ gerendert von M. Hebel

6.9.6 Videosimulation

Zur Erhöhung des Realitätsgrades einer simulierten Videosequenz wurden je 8 Frames integriert, um so eine Langzeitbelichtung zu imitieren mit standardmäßiger Video-Framerate (30 Hz). Die Anzahl der synthetischen Frames war bewusst so groß gewählt worden, dass ein einzelner Frame als kurz belichtetes Bild angesehen werden kann, während der Mittelwert einer Langzeitaufnahme entspricht.

Darüber hinaus wurde, zur Berücksichtigung von elektronischem Schrottrauschen, Poisson-Rauschen aus den Bildern selbst erzeugt, indem jedes Pixel als Mittelwert einer Poisson-Verteilung interpretiert wurde. Um auch das additive Sensorsausleserauschen zu berücksichtigen, wurde Gaußsches weißes Rauschen mit Mittelwert Null und Varianz 0,001 hinzugefügt.

Die Abbildung 6.45 zeigt ein Beispiel für eine Simulation mit solchem additiven Rauschen, sowohl als Kurzeitaufnahme (links) als auch als Langzeitaufnahme (rechts), für die 8 (PSF-gefilterte) Einzelbilder integriert wurden. Die Unterschiede lassen sich am besten in der Ausschnittsvergrößerung erkennen, wie z. B. an der Flagge oder den Zeltpitzen, die in der Langzeitaufnahme erkennbar verschwommener sind.

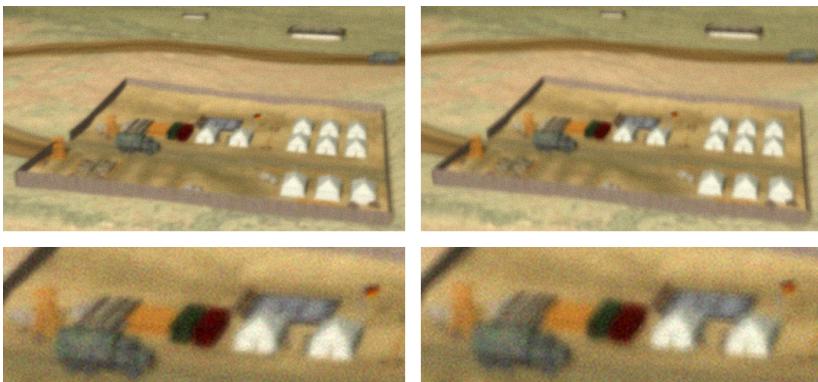


Abbildung 6.45: Simulationsbeispiel für $C_n^2 = 5 \cdot 10^{-13} \text{ m}^{-2/3}$, $L_0 = 10 \text{ m}$, mit additivem Rauschen. Links: Kurzeitaufnahme, d. h. Einzelframe mit Poisson- und Gauß-verteiltem Rauschen; rechts: Langzeitaufnahme, d. h. Mittelwert von 8 gefilterten Frames; unten: korrespondierende Detailansichten.

6.9.7 Korrekturresultate

Nachfolgend sind einige Korrekturresultate abgebildet für diverse Entfaltungsmethoden, die in Kapitel 5 vorgestellt wurden. Die Abbildung 6.46 zeigt ein Einzelbild der im vorangegangenen Abschnitt beschriebenen Simulation (Langzeitaufnahme) und ein zugehöriges Korrekturergebnis. Als Korrekturverfahren wurde dabei der registrierte gleitende Mittelwert von 20 Einzelbildern mit abschließender mehrstufiger gewichteter blinder Entfaltung (WIBD) eingesetzt. Da es sich um eine rein isoplanatische Simulation handelt, wurde auf eine lokale Registrierung verzichtet und lediglich eine globale Bildregistrierung durchgeführt.

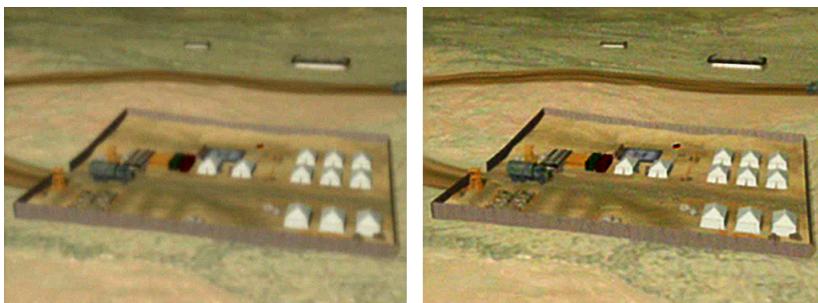


Abbildung 6.46: Links: Beispielframe der Turbulenzsimulation mit Poisson-Rauschen; rechts: Korrekturergebnis bei globaler Bildregistrierung und WIBD-Deblurring.

In der Abbildung 6.47 sind einige repräsentative Resultate der getesteten Entfaltungsmethoden zusammengefasst, die im folgenden näher erläutert werden. Zum besseren Vergleich der Ergebnisse untereinander, sowie auch mit der zugehörigen "Ground Truth" (GT) und der Turbulenzsimulation (TS), wurde ein aussagekräftiger Detailausschnitt gewählt. Die Abbildung 6.48 zeigt die dazu korrespondierenden Kantenbilder, anhand derer sich die Unterschiede zwischen den einzelnen Korrekturergebnissen leichter erkennen lassen.

Zunächst wurden einige nicht-blinde Entfaltungsmethoden getestet (siehe linke Spalte in der Abbildung 6.47), wobei hierfür stets die zugehörige

simulierte (d. h. exakt bekannte) PSF verwendet wurde. Darunter befinden sich die Richardson-Lucy-Entfaltung (LRD, siehe Abschnitt 5.1.2) mit unterschiedlicher Anzahl von Iterationen, sowie inverse Wiener-Filterung (IWF, siehe Abschnitt 5.1.1) und überdies auch die “Unsupervised Wiener-Hunt” Entfaltungsmethode (UWH [Ori10a]), deren Ergebnisqualität sich mit der von LRD vergleichen lässt, wobei UWH zugleich etwas weniger anfällig ist für Ringing-Effekte als LRD.

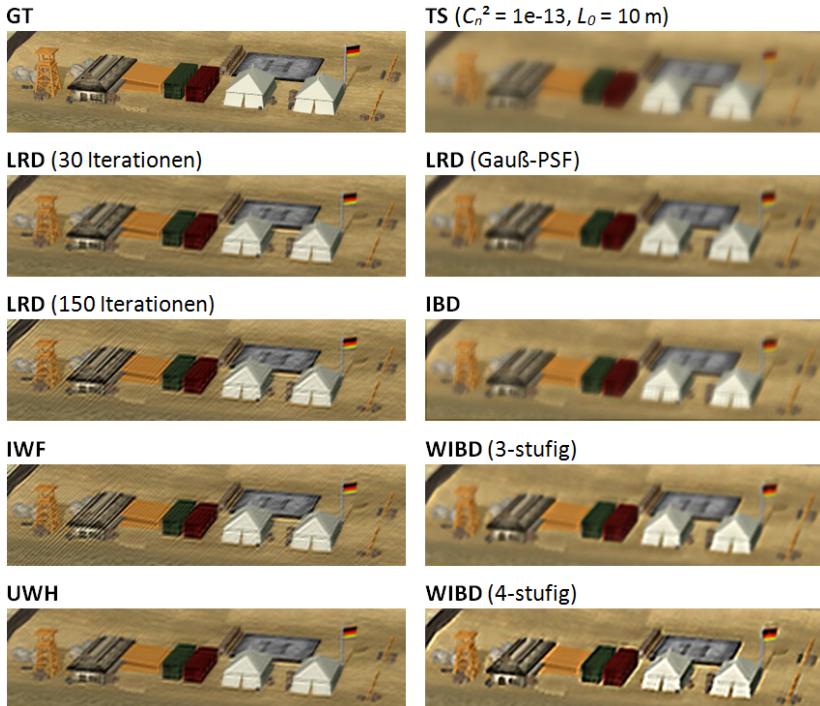


Abbildung 6.47: Turbulenzsimulation (mit $C_n^2 = 10^{-13} \text{ m}^{-2/3}$ und $L_0 = 10 \text{ m}$) und beispielhafte Korrekturresultate verschiedener Verfahren im Vergleich (Ausschnittsvergrößerung). Links: nicht-blinde Entfaltungsmethoden (exakte PSF); rechts: blinde Entfaltung.

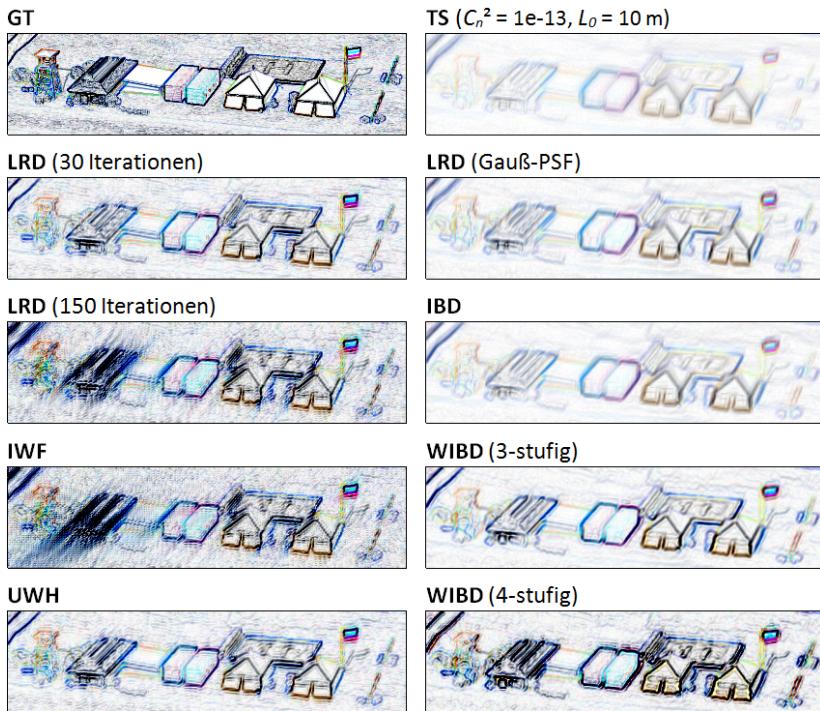


Abbildung 6.48: Kantenbilder zu Abb. 6.47 zur besseren Erkennbarkeit der Unterschiede in den Korrekturergebnissen.

Anschließend wurden auch verschiedene blinde Entfaltungsverfahren an dieser synthetischen Sequenz getestet (siehe rechte Spalte in der Abbildung 6.47 und Abbildung 6.48). Bei allen Entfaltungsmethoden im Test handelt es sich im Grunde genommen um blinde LRD-Varianten. Das schließt auch die klassische LRD mit ein, für die hier eine gaußförmige PSF angenommen wurde. Des weiteren wurden die iterative blinde Entfaltung (IBD, siehe Abschnitt 5.1.3), sowie die mehrstufige gewichtete iterative blinde Entfaltung (WIBD, siehe Abschnitt 6.6) angewendet.

Alle diese Methoden produzieren mehr oder weniger stark ausgeprägte Ringing-Effekte, wobei die Anzahl an Iterationen eine wesentliche Rolle spielt. Nicht zuletzt aus diesem Grund wurde die Anzahl an Iterationen bewusst niedrig gehalten (d. h. ≤ 20), wobei diese speziell im Fall der WIBD ohnehin zumeist einstellig ist.

Die Ergebnisqualität aller nicht-blinden Methoden ist erwartungsgemäß hoch, da alle Störungen bekannt sind und somit optimale Bedingungen für eine Rekonstruktion vorliegen. Die Inklusion dieser nicht-blinden Methoden dient vor allem als Maßstab für die bestmöglich erreichbare Ergebnisqualität, mit der die Ergebnisse der blinden Methoden verglichen werden können. Indirekt handelt es sich somit auch um ein Maß für die Güte der PSF-Schätzungen.

Es überrascht nicht, dass die Ergebnisqualität der blinden Methoden nicht ganz die hohe Qualität der nicht-blinden Methoden erreicht. Immerhin lassen alle blinden Methoden eine deutliche Verbesserung erkennen gegenüber dem simulierten Original, wobei auch die vereinfachende Annahme einer Gauß-PSF eine signifikante Verbesserung erzielt. Insgesamt schneidet die mehrstufige WIBD hier am besten ab, wobei die 3-stufige etwas schlechter gegenüber der 4-stufigen abschneidet hinsichtlich der Bildschärfe, da das Resultat weniger scharf und klar definiert erscheint. Andererseits lässt sich bei der 3-stufigen im Gegensatz zu der 4-stufigen kaum Ringing erkennen und es kommt zu weniger starken (Kontrast-)Überschwingern an den Kanten.

7

Methodik zur Evaluierung

So unterschiedlich die möglicherweise vorherrschenden Umwelt- und Turbulenzbedingungen sind, so vielfältig sind auch die Ansätze zur Korrektur von Turbulenzeffekten in Bilddaten, ebenso wie die Faktoren, die für (turbulenzbedingte) Beeinträchtigungen der Bildqualität verantwortlich sind. Hinzu kommen diverse denkbare Anwendungsbereiche für derartige Korrekturverfahren. Entsprechend schwierig gestaltet sich die Bestimmung einer geeigneten Taxonomie, die tatsächlich allen Anwendungsfällen gerecht werden kann.

Die Stärke der Turbulenz, sowie auch die Länge und der Winkel des Ausbreitungsweges durch das turbulente Medium (i. A. Luft oder ggfs. Wasser) spielen erwartungsgemäß eine entscheidende Rolle dabei, welche Ergebnisqualität ein gegebener Algorithmus innerhalb seiner (Leistungs-)Parameter überhaupt maximal erzielen kann. Dabei wirken sich nicht nur Temperaturunterschiede (z. B. aufgrund von Sonneneinstrahlung) auf die Fluktuationen im Brechungsindex aus, sondern u. a. auch die Luftfeuchtigkeit und Aerosolteilchenkonzentration, ebenso wie die Windstärke, Windrichtung und Windgeschwindigkeit. Nicht zuletzt spielen auch die Qualität und die Menge der Bilddaten eine wesentliche Rolle, wobei sowohl die Lichtverhältnisse (bzgl. Belichtungszeit, Bilddynamikkontrast) zum Zeitpunkt der Datenerfassung, als auch die Eigenschaften des verwendeten EO-Systems

(bzgl. Bildauflösung, Framerate etc.) von Bedeutung sind. Unterschiedliche Ausgangsszenarien, wie sie in Kapitel 4 diskutiert wurden, erfordern wiederum unterschiedliche Korrekturmaßnahmen. Zudem können die Prioritäten bei der Bewertung je nach gegebenem Anwendungsgebiet individuell stark variieren.

Aus all diesen Gründen wird es womöglich niemals ein einziges, allumfassendes Werkzeug für die objektive Bewertung der Gesamtheit an Korrekturverfahren für jede Form von optischer Turbulenz geben. Stattdessen wird in dieser Arbeit deshalb ein tabellarischer Ansatz vorgeschlagen, anhand dessen sich ähnliche Voraussetzungen zusammenfassen lassen, um Algorithmen für typische Szenarien miteinander vergleichbar zu machen. Genauer wird hierfür ein Bewertungssystem mit Priorisierung eingeführt, welches in Abschnitt 7.3 und insbesondere in Abschnitt 7.3.3 näher ausgeführt wird. Hierbei werden einer (erweiterbaren) Auswahl an Kriterien Werte zugeordnet, gemäß ihrer jeweiligen Priorität in einem gegebenen Kontext. Diesem Bewertungssystem kommt eine duale Funktion zu, denn einerseits kann damit eine gegebene Applikation hinsichtlich ihrer Anforderungen systematisch beschrieben werden, und andererseits kann damit ein gegebener Algorithmus hinsichtlich seiner Leistungsparameter charakterisiert werden. So erhält man entsprechende (Bewertungs-)Profile für Anwendungen ebenso wie für Korrekturverfahren, die entsprechend miteinander verglichen werden können.

Dabei sollte angemerkt werden, dass es wenig sinnvoll wäre, ein Anwendungsprofil zu erstellen, welches allen Kategorien höchste Priorität zuordnen würde, da zurzeit kein Algorithmus existiert, der dies erfüllen könnte.

7.1 Bildqualität

Im vorliegenden Zusammenhang stellt sich zunächst die Frage nach einer sinnvollen Definition des Begriffes *Bildqualität* bzw. danach, was *gute Bildqualität* im vorliegenden Zusammenhang bedeutet. Je nach Anwendung kann das Verständnis dieses Begriffes etwas variieren. Im Rahmen dieser Arbeit kann “gute” Bildqualität im Prinzip als gleichbedeutend mit hohem Kontrast bei feinen Details verstanden werden, ebenso wie auch als eine hohe Auflösung von nahe (in der Bildebene) beieinander liegenden Objekten.

In der Literatur existieren zahlreiche verschiedene Methoden, mit deren Hilfe sich die Bildqualität entweder global oder auch lokal beschreiben (und quantifizieren) lässt. Hierzu zählen u. a. die *(Bild-)Schärfe*, definiert als (normierte) Quadratwurzel aus der Summe der quadrierten (Grauwert-) Gradienten in horizontaler und vertikaler Richtung, Kanten-basierte Maße, wie z. B. die *Summe* oder *Varianz der Kanten* im Bild, die *Fisher-Information*, *Fourier-Spektralanalyse*, *“Total Variation”* oder die *Shannon-Entropie*. Eine detailliertere Übersicht über die verbreitetsten solcher Methoden ist z. B. in [Hof19], sowie in [Rio13] gegeben.

7.1.1 Qualitätsmetriken

Die qualitative Charakterisierung eines gegebenen Bildes mit Hilfe entsprechender Metriken (“*Image Quality Metrics*”, IQM) kann im Zusammenhang mit Turbulenzkorrektur gleich in mehrfacher Hinsicht von Nutzen sein. Im offensichtlichsten und zugleich kompliziertesten Anwendungsfall dient sie der Beurteilung der Ergebnisqualität eines gegebenen Korrekturverfahrens, beispielsweise um die Resultate verschiedener Verfahren miteinander vergleichen zu können. Kompliziert ist dieser Fall vor allem deshalb, weil bei realen Turbulenzdaten in der Regel keine “*Ground Truth*”-Daten (GT) als Referenz vorliegen, um zum Vergleich herangezogen werden zu können. Aus diesem Grund ist hierfür vor allem eine spezifische Klasse von IQM von Interesse, und zwar sogenannte “*No Reference*”-Metriken.

Etwas einfacher gestaltet sich die Aufgabe, den Ähnlichkeitsgrad bzw. die qualitativen Unterschiede zwischen zwei gegebenen Bildern zu bewerten. So ist es z. B. bei der Bild- oder Videokompression vergleichsweise einfach, die Qualität eines Bildes zu bestimmen, denn hierbei korrespondiert eine höhere Kompressionsrate mit einer geringeren Bildqualität. Entsprechend können “*Full Reference*”-Metriken eingesetzt werden, um das perfekte, d. h. unkomprimierte Referenzbild mit dem komprimierten Bild zu vergleichen. Ohne geeignete Referenzdaten ist dies nicht bzw. nur bedingt möglich.

7.1.2 “*Full Reference*”-Metriken

Gemäß ihrer Bezeichnung erfordern “*Full Reference*”-Metriken entsprechende (GT) Referenzdaten als Vergleichsbasis. Solche Metriken werden häufig

als qualitatives Maß für den Ähnlichkeitsgrad zwischen zwei gegebenen Bildern eingesetzt. Eine weit verbreitete Metrik ist insbesondere auch der maximale Signal-Rausch-Abstand (“Peak Signal-to-Noise Ratio”, PSNR). Letztlich hängt aber die Entscheidung darüber, was *beste Übereinstimmung* in einem bestimmten Kontext genau bedeutet und welche Kriterien am besten geeignet sind, um diese Entscheidung zu treffen, stark von der jeweiligen Anwendung ab und auch davon, welche Informationen verfügbar sind.

Im vorliegenden Turbulenz-Kontext tritt u. a. der Anwendungsfall auf, der bereits in Kapitel 4 im Unterabschnitt 4.2.1 diskutiert wurde. Dort ging es speziell um die Registrierung von Bildern innerhalb einer Sequenz mit dem Ziel der Bewegungskompensation. Genauer wurde für ein gegebenes Referenzbild (bzw. für ein Teilbild) dasjenige Bild aus einer Menge an zugehörigen Shift-Bildern (bzw. Bildblöcken) gesucht, welches die optimale Übereinstimmung mit der Referenz aufweist. Zu diesem Zweck wurde der Einsatz einfacher Fehlersummationsmetriken, wie z. B. der “Mean Absolute Error”: der mittlere absolute Fehler (MAE), der “Mean Square Error”: der mittlere quadratische Fehler (MSE) oder der “Root Mean Square Error”: die Wurzel aus dem mittleren quadratischen Fehler (RMSE) vorgeschlagen. Derartige Metriken haben zwar den Vorteil, dass sie sich effizient berechnen lassen, aber auch den Nachteil, dass sie generell nicht sehr zuverlässig zur Bewertung von Bildqualität sind, wie in [Wan09] überzeugend nachgewiesen. Dort wird stattdessen der universeller einsetzbare “Structural SIMilarity Index” (SSIM) propagiert, für den zunehmend komplexere Versionen existieren, die in [Wan02], [Wan04], sowie in [Sam09] detailliert sind, inklusive des “Complex Wavelet-Structural SIMilarity Index” (CW-SSIM). Hierbei werden die statistischen Eigenschaften zweier Bilder x und y ausgenutzt, um anstelle der Fehlerenergie bevorzugt strukturelle Verformungen zu messen. Aus diesem Grund wurde u. a. auch der SSIM (in der einfacheren Version) in [Hue08] und [Gre08] zum Vergleich von Korrekturergebnissen (aus simulierten Daten) mit den zugehörigen GT-Referenzdaten eingesetzt, wobei die folgende Definition verwendet wurde (mit den Bezeichnungen aus Abschnitt 3.1.3 (d. h. μ_x , μ_y bezeichnen jeweils die Mittelwerte von x bzw. y und σ_x , σ_y die jeweiligen Standardabweichungen, sowie σ_{xy} die zugehörige Kreuzkovarianz):

$$SSIM(x, y) = \frac{2\mu_x \mu_y}{(\mu_x)^2 + (\mu_y)^2} \frac{\sigma_{xy}}{\sigma_x \sigma_y} \frac{2\sigma_x \sigma_y}{\sigma_x^2 + \sigma_y^2} \quad (7.1)$$

Die Grundidee des komplexen CW-SSIM besteht darin, dass bestimmte Bildverzerrungen zu konsistenten Phasenänderungen in den lokalen Wavelet-Koeffizienten führen, und dass eine konsistente Phasenverschiebung der Koeffizienten den strukturellen Inhalt des Bildes nicht verändert. Zu den Vorteilen des CW-SSIM-Index gehört seine Robustheit gegenüber geringfügigen Rotationen und Translationen. Das ermöglicht den direkten Vergleich zweier Bilder ohne eine vorherige Bildregistrierung, welche für viele andere Metriken erforderlich wäre. Ein weiterer Vorteil besteht in dem vergleichsweise günstigen Rechenaufwand.

Im Zusammenhang mit optischer Turbulenz ist der Einsatz von “Full Reference”-Metriken in der Regel nur bei simulierten Daten sinnvoll, da echte GT-Daten sonst nur im Ausnahmefall verfügbar sind. Allerdings sollte die Verwendung simulierter Daten immer unter einem Vorbehalt erfolgen, da eine hinreichende Realitätsnähe der Simulationsergebnisse nicht so ohne Weiteres gewährleistet werden kann. In Abhängigkeit von dem verwendeten Algorithmus, könnten verschiedene Bildinformationen u. U. durch die Simulation so verändert werden, dass dies die Performanz von Bildqualitätsmetriken beeinflussen kann. Dabei ist es durchaus möglich, dass diese Änderungen für das bloße Auge nicht einmal wahrnehmbar sind. Als ein zusätzliches Kriterium in der Bewertung von Verfahren zur Turbulenzkorrektur sind sie aber durchaus geeignet.

Mit gewissen Einschränkungen können dennoch auch “Full Reference”-Metriken zur qualitativen Bewertung der Ergebnisse verschiedener Turbulenzkorrekturverfahren eingesetzt werden, sofern eine hinreichend gute Schätzung für die “Ground Truth” vorliegt und als Referenz dienen kann. In dieser Arbeit wurde hierfür in einigen Fällen beispielsweise ein temporaler Mittelwert oder Median (mit globaler Bewegungskompensation) ausgewählt. Alternativ ist ebenfalls die Verwendung eines besonders guten Rekonstruktionsergebnisses als Vergleichsmuster möglich, z. B. unter Einsatz von “Lucky Imaging” (s. a. Abschnitt 2.2.2).

7.1.3 “No Reference”-Metriken

Im gegebenen Kontext wird vor allem eine Metrik benötigt, die geeignet ist, die Qualität von Bildsequenzen oder Daten aus einem Live-Videostrom unabhängig von einem zusätzlichen Referenzbild zu bewerten. Sogenannte “No Reference”-Metriken machen sich bestimmte Merkmale von Bilddaten

zunutze, um den Schärfegrad in einem Bild zu beurteilen. Es können z. B. die hohen Frequenzanteile oder der Rauschanteil im Bild ermittelt und mit Standardwerten verglichen werden. Andere Metriken werten die Kanten im Bild aus, wobei generell die Assoziation einer Verbreiterung der Kanten mit einer Verstärkung der Unschärfe gilt. Gleichzeitig nimmt die Höhe der Kanten mit zunehmender Unschärfe immer weiter ab bis sie schließlich ganz verschwinden. Demnach lässt sich die Schärfe eines Bildes auch über die Anzahl (und Längen) der vorhandenen Kanten charakterisieren.

Die von [Dol07] vorgeschlagene "Blur"-Metrik nutzt dies z. B. ganz geschickt aus, indem sie anstelle des Schärfegrades eines Bildes dessen "Unschärfe-grad" misst. Genauer wird hierbei die Luminanz des originalen Bildes einer wiederholten Tiefpassfilterung unterzogen. Anschließend werden die lokalen Varianzen des Originals mit denjenigen der verschiedenen Iterationen verglichen. Die Idee dahinter ist, je schärfer das Ausgangsbild ist, desto stärker wirkt sich ein Tiefpassfilter aus, d. h. desto größer sind die Unterschiede zwischen dem ursprünglichen und dem gefilterten Bild. Iteriert man diesen Prozess der Tiefpassfilterung, verringert sich diese Varianz mit jeder zusätzlichen Iteration weiter.

Die Wirksamkeit dieser Metrik zeigt sich z. B. in der Abbildung 6.4 (siehe Abschnitt 6.1.2), wofür aus einer Testsequenz (500 Frames) mithilfe der Metrik der jeweils beste und der schlechteste Frame selektiert wurde.

Eine solche Bewertung kann insbesondere zur Selektion der besten Frames ebenso wie der Aussortierung der schlechtesten Frames innerhalb einer Sequenz verwendet werden. Dies ist insofern relevant, wenn ein Verfahren irgendeine Form der Mittelwertbildung enthält. Dies illustriert die Abbildung 7.1 am Beispiel derselben Videosequenz wie zuvor. Links ist der Mittelwert der kompletten Sequenz abgebildet, während für das Bild rechts nur die besten 250 Frames gemittelt wurden. Es sollte allerdings erwähnt werden, dass hier zusätzlich eine globale Bildregistrierung durchgeführt wurde (in beiden Fällen), wodurch ein Teil der Bewegungsunschärfe bereits kompensiert wird. Der Vergleich mit der Abbildung 6.4 verdeutlicht insbesondere auch den rauschmindernden Effekt, den die Bildmittelung hat. Der erhöhte Kontrast ist im Übrigen eine Konsequenz der resultierenden Verbesserung des PSNR. Speziell in [Hue08] wurde zudem noch eine weitere Metrik zur Bewertung der Qualität von Korrekturergebnissen untersucht, welche ursprünglich in [Vor96] vorgeschlagen wurde, während in [Hue10] Metriken aus [Yan09] eingesetzt wurden.

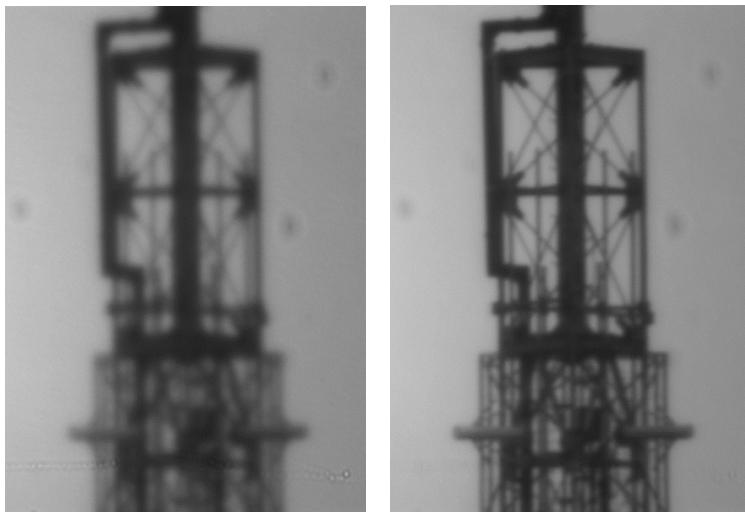


Abbildung 7.1: Links: MW aller 500 Einzelbilder der Testsequenz, rechts: MW der besten 250 Frames (gemäß Blur-Metrik)

7.2 Qualitative Beurteilung durch Beobachter

Grundsätzlich gibt es zwei mögliche Herangehensweisen, um die Qualität von Bilddaten zu beurteilen, speziell die Qualität der jeweiligen Resultate unterschiedlicher Verfahren zur Turbulenzkorrektur. Einerseits kann eine Bewertung durch menschliche Beobachter vorgenommen werden, indem diese die Bilder visuell begutachten, und andererseits kann sie computergestützt erfolgen, indem geeignete Bewertungsmaße implementiert und ausgewertet werden, wie z. B. die Metriken aus Abschnitt 7.1. Der Einsatz menschlicher Beobachter bedeutet naturgemäß, dass deren subjektive Eindrücke mit in die Bewertung einfließen. Für eine statistische Belastbarkeit solcher Bewertungsergebnisse wären daher im Grunde genommen hinreichend viele Stichproben erforderlich, d. h. eine Anzahl von Probanden in der Größenordnung von ca. 40 Personen. Der damit verbundene hohe Organisationsaufwand ist im Regelfall jedoch nicht praktikabel.

7.2.1 TOD-Testmethode

Eine sehr spezielle, aber effektive Methode zur (relativ) objektiven Bewertung durch menschliche Beobachter, auch bei einer kleineren Anzahl von Testpersonen, ist der sogenannte TOD-Test (“Triangle Orientation Discrimination”) gemäß der Beschreibung in [Bij98]. Der TOD-Test wurde ursprünglich zur Leistungsbewertung von bildgebenden EO-Systemen entwickelt, kann aber (mit kleineren Anpassungen) auch generell zur Beurteilung der Auflösungsqualität gegebener Bilddaten verwendet werden.

Mithilfe dieser Methode lässt sich die kleinste Dreiecksgröße in einem Bild bestimmen, bei der die Orientierung noch zuverlässig erkennbar ist. Genauer geht es um gleichseitige Dreiecke vor einem neutralen Hintergrund, die jeweils eine von vier möglichen Ausrichtungen annehmen können, d. h. mit der Spitze nach oben, nach unten, nach links oder nach rechts (s. a. Abbildung 7.2).



Abbildung 7.2: Beispiele für TOD-Testmuster mit den vier möglichen Orientierungen

Die Aufgabe für Beobachter besteht darin, die jeweilige Ausrichtung der Dreiecke zu erkennen, wobei sowohl die Größe als auch der Kontrast der Dreiecke variieren. Die Wahrscheinlichkeit einer korrekten Beobachterantwort steigt entsprechend zusammen mit der Größe des Dreiecks.

Da solche Testmuster üblicherweise nicht in erfassten Bilddaten enthalten sind, liegt auf der Hand, dass die TOD-Methode nur eingeschränkt (d. h. zu Testzwecken) zur Bewertung von Turbulenzkorrekturresultaten einsetzbar ist. Am ehesten lässt sich diese Methode daher für simulierte Daten verwenden, wobei auch echte Mustertafeln in vorgegebener Entfernung aufgestellt und unter Turbulenzbedingungen aufgenommen werden können. In [vE07] wurden beide Vorgehensweisen getestet und miteinander verglichen, um die Zuverlässigkeit der Simulationen als Grundlage zur Bewertung eines speziellen Korrekturalgorithmus einzuschätzen (und bestätigen) zu können.

7.2.2 Merkmalsorientierte Bewertung

Speziell im Fall von Turbulenzkorrekturergebnissen ist die Bildverbesserung zumeist offensichtlich, die gegenüber den originalen Eingabedaten erzielt wurde. So lassen sich beispielsweise schärfere, klarer definierte Strukturen am besten an Kanten im Bild erkennen, während eine Reduktion von Verzerrungen besonders an geraden Linien auffällt. Entsprechend kann eine visuelle Evaluierung, wie sie u. a. in Abschnitt 5.3 durchgeführt wurde, durchaus zweckdienlich und ausreichend sein.

Anders sieht es dagegen aus, wenn es darum geht, relativ ähnliche Ergebnisse verschiedener Verfahren miteinander zu vergleichen. Eine Möglichkeit besteht hier darin, die wichtigsten Merkmale für eine Charakterisierung der Bildqualität zur Bewertung der Ergebnisse heranzuziehen (d. h. Bildschärfe, Kontrast, Verzerrungen, Stabilisierung etc.) und durch Beobachter gemäß ihrer (subjektiven) Wahrnehmung bewerten zu lassen. (Dazu sollte ggfs. angemerkt werden, dass hiermit nicht Klassifikationsmerkmale gemeint sind). Die Ergebnisse lassen sich über alle Testpersonen mitteln und in einer Tabelle erfassen entsprechend der (erweiterbaren) Beispieldtabelle 7.1. Je nach Ausprägung können wahrgenommene Verbesserungen z. B. mittels (+) oder mit (++) bewertet werden, und Verschlechterungen analog dazu mittels (–) bzw. (––). Falls keine wesentliche Änderung erkennbar ist, kann auch dies gekennzeichnet werden, z. B. mittels (o). Hierbei ist zu beachten, dass die Teilnehmer eine Bewertungsgrundlage benötigen, anhand derer

Algorithmus	Alg. 1	Alg. 2	...
Merkmal			
Bildschärfe	+	++	–
Verzerrungen	o	–	o
Stabilisierung	–	+	–
Bildkontrast	++	+	o
Noise	++	–	+
Objektbewegung	––	o	+
...			

Tabelle 7.1: Beispieldtabelle für eine merkmalsorientierte Bewertung

entschieden werden kann, was “kleine” und was “große” Veränderungen im gegebenen Zusammenhang genau bedeuten sollen. Alternativ kann auch eine numerische Skala verwendet werden, wie z. B. $\{-2, -1, 0, +1, +2\}$. Die Anzahl der Abstufungen sollte nicht größer sein, da diese Art von Beobachtertests nicht für eine feinere Abstufung geeignet sind.

7.3 Evaluierungskonzept für Algorithmen zur Turbulenzkorrektur

Der merkmalsbasierte Ansatz aus Abschnitt 7.2.2 lässt sich auch für eine computergestützte Bewertung mithilfe diverser Metriken (s. a. Abschnitt 7.1.1) adaptieren und um zusätzliche Auswahl- und Bewertungskriterien erweitern, die im Nachfolgenden näher beleuchtet werden.

7.3.1 Auswahl- und Bewertungskriterien

Für die Auswahl eines geeigneten Verfahrens gibt es grundsätzlich 6 Bewertungskriterien zu berücksichtigen, wobei in Abhängigkeit von der betrachteten Anwendung hinter jedem dieser Punkte wiederum eine ganze Reihe von weiteren Fragestellungen steckt, die es im Vorfeld abzuklären gilt. Die wesentlichsten sind im Nachfolgenden aufgelistet:

1. Echtzeit-Fähigkeit vs. Qualität

Wie schnell müssen die Ergebnisse vorliegen? Muss die Korrektur in Echtzeit oder Nahe-Echtzeit erfolgen? Oder hat die Qualität der Ergebnisse höhere Priorität oder sogar höchste Priorität?

2. Anforderungen an Computer-Architektur

Gibt es spezielle Anforderungen an die Computer-Hardware (z. B. *CUDA*-fähige Hochleistungs-GPU¹, Multikernprozessor etc.)? Gibt es spezifische Anforderungen seitens der Software (z. B. Betriebssystem, Compiler, Bibliotheken etc.)?

¹ “CUDA (früher auch *Compute Unified Device Architectur* genannt) ist eine von Nvidia entwickelte Programmier-Technik, mit der Programmteile durch den Grafikprozessor (GPU) abgearbeitet werden können.” (Quelle: Wikipedia)

3. *Unabhängigkeitsgrad*

Wie unabhängig von äußerer Eingaben soll das Verfahren operieren? Soll es vollautomatisch gesteuert werden? Soll es teil-automatisch funktionieren? Welche Parameter sollen einem (un-)geschulten Operator überlassen werden? Welche Parameter sollen automatisch anhand der vorliegenden Daten bestimmt werden? Und welche Parameter lassen sich überhaupt sinnvoll abschätzen?

4. *Inhalt: Technische Aspekte*

Wie sehen typische Szenen aus, die korrigiert werden sollen? Handelt es sich um Lang- oder Kurzstreckenaufnahmen? Wie groß ist das Sichtfeld (FOV) im Verhältnis dazu? Wie strukturiert (kontrastreich) erscheint die abgebildete Szene in den erfassten Bilddaten? Ist eine Vorverarbeitung der Daten erforderlich (z. B. Kontrastverbesserung, Rauschreduktion, Einzelframe-Deblurring, globale Bewegungskompensation)?

5. *Bewegungsinhalt*

Handelt es sich um eine statische Szene oder gibt es Bewegungen in der Szene (welche nicht durch Turbulenz verursacht wurden)? Falls Bewegung enthalten ist, welche der Situationen aus Abschnitt 4.1 sollen dann primär berücksichtigt werden? Welche der Bewegungstypen in der Auflistung 4.1.1 sollen abgedeckt sein?

6. *Objektive und subjektive Ergebnisevaluation*

Nach welchen objektiven und subjektiven Kriterien soll die Beurteilung der Ergebnisqualität erfolgen? Sollen Bildqualitätsmetriken eingesetzt werden? Falls ja, welche Art von Bildqualitätsmetriken (siehe Abschnitt 7.1.1)? Liegt eine “Ground Truth” vor für eine objektive Bewertung? Welche Merkmale sind dabei wichtig und sollen als “gut” erkannt werden?

Diese Auflistung erhebt nicht den Anspruch auf Vollständigkeit. Die Beschränkung auf diese sechs Aspekte erfolgte vielmehr aufgrund der objektiven Tatsache, dass es sich um eine sehr weitgefasste Aufgabenstellung handelt, die es sowohl in der Breite zu überblicken als auch gesondert zu vertiefen galt. Die vorliegende Selektion erfolgte daher in dem Bestreben, ei-

ne sehr inhomogene Menge an Methoden in so wenige und klare Kategorien einzuteilen wie möglich.

Im Idealfall wären die genannten Auswahlkriterien völlig unabhängig von einander. Tatsächlich bestehen allerdings einiger (zumeist indirekte) Zusammenhänge der Punkte untereinander. Wenn z. B. ein Verfahren möglichst unabhängig operieren soll, kann die Ergebnisqualität u. U. signifikante Einbußen erleiden. Oder ein bestimmter Algorithmus kann ohne spezielle Hardware seine Echtzeitfähigkeit verlieren, um nur zwei Beispiele zu nennen.

Anmerkungen

Zu Punkt 1 sollte angemerkt werden, dass die Geschwindigkeit und die Ergebnisqualität insofern miteinander gekoppelt sind, als dass die zu erwartende Ergebnisqualität umso geringer ist, je schneller die Ergebnisse vorliegen sollen. Denkbar ist, eine Skala zur Bewertung der Wichtigkeit einzuführen (z. B. eine Skala von 1 bis 5 oder über das Intervall $[0, 1]$).

Der Punkt 2 kann u. U. für die potenzielle Portabilität eines Verfahrens von Bedeutung sein, zum einen wortwörtlich im Hinblick auf Außeneinsätze vor Ort und zum anderen hinsichtlich der Übertragbarkeit auf andere Computer-Systeme. Überdies spielt die verfügbare Hardware-/Software-Architektur eine große Rolle für die Geschwindigkeit mit der ein bestimmter Algorithmus eine gegebene Datenmenge prozessieren kann. Aber auch finanzielle Aspekte können von Belang sein und ggf. die Anschaffung teurer Hardware verhindern.

Der Punkt 3 deckt sehr viele Teilaufgaben ab, die z. T. großen Einfluss auf andere Kriterien haben. Welcher Grad an Unabhängigkeit von äußeren Eingaben überhaupt möglich ist, hängt insbesondere von der Anwendung ab. So unterscheidet sich z. B. der Fall einer Kamera, die über einem bestimmten Gebiet hin und her schwenkt, sehr stark von dem eines Teleskops, das Sterne beobachtet. Je nachdem wie die Prioritäten in den anderen Kategorien gesetzt sind, variieren die Parameter, die sich automatisch bestimmen lassen.

Der Punkt 4 ist für diverse Korrekturverfahren von Bedeutung. Je mehr über den voraussichtlichen Inhalt der Daten bekannt ist, desto besser können Algorithmen dafür angepasst werden. Das bedeutet auch, dass sich abschätzen lässt, welche Art von Korrekturmaßnahmen tatsächlich sinnvoll ist. Bei-

spielsweise ist im Fall einer Langstreckenaufnahme durch starke Turbulenz damit zu rechnen, dass Strukturen und Kontrast stark reduziert werden. Das bedeutet wiederum, dass die Anwendung von lokaler Bewegungskompen-sation u. U. keine positive Wirkung haben wird und nicht bzw. nur unter Vorbehalt durchgeführt werden sollte.

Der Punkt 5 hängt stark von der jeweiligen Anwendung ab wie bereits aus-führlich in Abschnitt 4.1 diskutiert.

Der letzte Punkt 6 unterscheidet sich von den übrigen Kriterien insofern, dass die Bewertung zunächst hauptsächlich von den verfügbaren Eingabe-daten (d. h. den korrigierten Bilddaten, ggf. mit zugehöriger Ground Truth) abzuhängen scheint und weniger von dem spezifischen Algorithmus, mit dem die Ergebnisse erzeugt wurden. Wie bereits in Abschnitt 7.1 erörtert, spielen die "Eigenarten" diverser Algorithmen durchaus eine Rolle, und soll-ten daher mit berücksichtigt werden. Entsprechend sollte diesem Kriterium nicht zu große Bedeutung bei der Auswahl eines Verfahrens beigemessen werden. Stattdessen empfiehlt es sich, die Qualitätsevaluation an das ausge-wählte Verfahren anzupassen.

7.3.2 Hauptaspekte und Einflussfaktoren

Die Auswahl- und Bewertungskriterien aus dem vorangegangenen Abschnitt 7.3.1 lassen sich für das Evaluierungskonzept im Wesentlichen auf die nach-folgenden vier Hauptaspekte kondensieren:

1. *Applikation*

Die zugrundeliegende Anwendung bestimmt was die Hauptzielset-zung ist, welche Anforderungen an einen Algorithmus gestellt werden, und wo die Prioritäten liegen.

2. *Bedingungen bei der Erfassung*

Die verwendete Sensorik und die Umweltbedingungen während der Datenerfassung limitieren die Bildqualität und somit die maximale Leistungsfähigkeit eines Algorithmus.

3. *Einschätzung der Situation*

Die Versuchsanordnung beschreibt eine gegebene Situation, d. h. das vorliegende Szenario und den voraussichtlichen Szenen- und Bewe-gungsinhalt, die ein Algorithmus berücksichtigen muss.

4. Algorithmus

Die Eigenschaften und Fähigkeiten eines Algorithmus limitieren für welche Applikationen er geeignet ist, und beeinflussen welche Methoden zur Evaluation eingesetzt werden kann bzw. sollte.

Die Abbildung 7.3 zeigt einen Überblick über diese vier Hauptaspekte, die in dem hier vorgeschlagenen Bewertungsmodell zu berücksichtigen sind. Die jeweiligen Unterpunkte, auf die hier Bezug genommen wird, wurden bereits im vorangegangenen Abschnitt 7.3.1 diskutiert bzw. werden nachfolgend näher beleuchtet.



Abbildung 7.3: Übersicht über die vier Hauptaspekte, die im vorgeschlagenen Bewertungsmodell zu berücksichtigen sind.

Angesichts der sehr weit gefassten Aufgabenstellung muss bei dem hier verfolgten Ansatz das Anwendungsspektrum etwas eingegrenzt werden. Darüber hinaus müssen die Anforderungen und erwünschten Ergebnisse einer bestimmten Anwendung berücksichtigt werden. Insbesondere, da diese den

zu erwartenden Szeneninhalt einschränken können und unterschiedliche Szenarien unterschiedliche Korrekturmaßnahmen erfordern.

Zunächst gilt es, die einflussreichsten Faktoren zu betrachten. Wie eingangs bereits erwähnt, sind bei vorhandener Turbulenz in der Regel die Umgebungsbedingungen zum Zeitpunkt der Bildaufnahme ausschlaggebend für die Bildqualität. Dementsprechend steht eine Charakterisierung der Turbulenzbedingungen an vorderster Stelle, wobei der Strukturparameter C_n^2 (bzw. r_0) hierfür besonders zweckdienlich ist (s. a. Abschnitt 3).

Daneben sollten auch die Eigenschaften der verwendeten Sensorausrüstung, sowie der jeweilige Messaufbau (d. h. das zugrundeliegende Szenario gemäß Abschnitt 4.1) bei der Wahl eines Algorithmus für eine konkrete Anwendung mitberücksichtigt werden. Die Spezifikationen des verwendeten EO-Systems und die interne Struktur der Sensorik bestimmen zum einen Parameter wie die Bildauflösung, das FOV und insbesondere das IFOV, sowie auch die Framerate und die Datenmenge, und zum anderen die Empfindlichkeit des Detektors in den verschiedenen Spektralbereichen (z. B. VIS, IR oder aktive Beleuchtung), d. h. die (Haupt-)Wellenlänge λ , und auch die Rauschempfindlichkeit (s. a. Abschnitt 3.4.10).

Wesentliche Parameter der verwendeten Optik umfassen zudem die Brennweite f (bzw. die Blendenzahl), sowie den Durchmesser D der Apertur, u. a. weil sich der Schweregrad der Turbulenzbeeinträchtigungen gut über das Verhältnis D/r_0 (s. a. Abschnitt 3.3.3) quantifizieren lässt. Es sollte erwähnt werden, dass die Abbildungsqualität des Objektives u. U. ebenfalls eine Rolle spielen kann. Da die Verwendung minderwertiger Optiken in den hier betrachteten Fällen jedoch wenig zielführend wäre, wird auf eine gesonderte Berücksichtigung verzichtet. Überdies können etwaige Abbildungsfehler auch separat von der Turbulenzthematik behandelt werden.

Des Weiteren bestimmt der Messaufbau zur Datenerfassung indirekt mit, welche Anforderungen an einen gegebenen Algorithmus gestellt werden. Genauer, welches Szenario dieser Algorithmus verarbeiten können muss, um bei den so erfassten Daten ausreichend gute Erfolgsaussichten zu haben. Dabei spielt die Pfadlänge L zwischen Kamera und beobachtetem Objekt eine entscheidende Rolle aufgrund der kumulativen Auswirkung von Turbulenzeffekten entlang des Ausbreitungsweges.

Die Abbildung 7.4 zeigt ein schematisches Szenario, wie es typischerweise in militärischen Fernerkundungsanwendungen (z. B. bei Aufklärungsein-

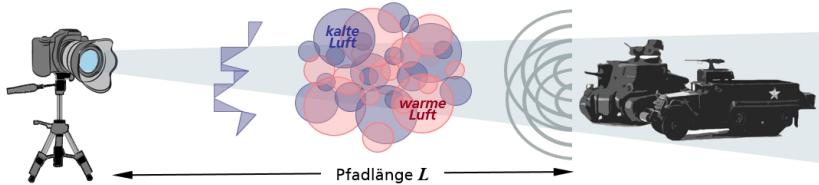


Abbildung 7.4: Typisches Anwendungsszenario in der Fernerkundung

sätzen) vorkommen kann. Zwischen dem beobachtenden Sensor und dem beobachteten Objekt erstreckt sich ein ausgedehnter Ausbreitungsweg, der eine turbulente Atmosphäre durchquert, angedeutet durch rote und blaue Wölkchen, die ein Gemisch aus wärmeren und kälteren Luftregionen mit jeweils unterschiedlichem Brechungsexponenten darstellen. Aufgrund der kumulativen Auswirkungen von Turbulenzeffekten auf langen Ausbreitungswegen, verdeutlicht dies indirekt den Zusammenhang zwischen der Pfadlänge L und C_n^2 mit dem Ausmaß an Beeinträchtigung der Bildqualität (s. a. Abschnitt 3).

7.3.3 Anwendungs- und Algorithmusprofile

Nach Diskussion der diversen Faktoren, die das Leistungsvermögen von Verfahren zur Turbulenzkorrektur beeinflussen, sind aus praktischen Erwägungen einige Vereinfachungen erforderlich. Dazu bietet sich eine Reduktion auf die folgenden Hauptanwendungsgebiete an, wobei eine nachträgliche Ausweitung auf weitere Anwendungen jederzeit möglich ist:

- *Fernerkundung* (civil und militärisch) ⇒ statische Kamera, horizontaler Blickwinkel (ggfs. leichte Schrägsicht nach oben), langer Ausbreitungsweg (ca. 1-30 km)
- *(Grenz-)Überwachung* (Surveillance) ⇒ statische oder schwenkende Kamera, horizontaler Blickwinkel (ggfs. leichte Schrägsicht nach unten), relativ kurzer Ausbreitungsweg (ca. 0-1 km)
- *Astronomie* (stellar und solar) ⇒ statische Kamera (mit Nachführreinrichtung), vertikaler Blickwinkel oder steile Schrägsicht, maximaler Ausbreitungsweg

Überdies ist eine realistische Priorisierung der Leistungsanforderungen für eine gegebene Anwendung notwendig, d. h. absolute "must have" Leistungsmerkmale müssen gegen solche abgewogen werden, die lediglich "nice to have" wären. Eine Priorisierung bzgl. "Qualität vs. Geschwindigkeit" kann beispielsweise Werte im Intervall $[0,1]$ annehmen oder in eine gegebene Anzahl an Kategorien eingeteilt werden, z. B. in 0 ("ohne / unwichtig"), 1 ("gering / nicht sehr wichtig"), 2 ("mittel / wichtig"), 3 ("hoch / sehr wichtig"). Diese Kategorisierung hat den Vorteil, dass sie sich auf eine Vielzahl von Faktoren anwenden lässt.

Die (erweiterbare) Tabelle 7.2 gibt für die ausgewählten Anwendungsbeziehungen einen Überblick über typischerweise zu erwartenden Bedingungen, wobei diese vier Kategorien verwendet werden, u. a. um die Stärke von Bewegungen und den Unschärfegegrad einzuordnen. In einigen Fällen (z. B. Distanzen) sind auch konkrete Größenordnungen angegeben, wie sie häufig vorkommen. Die große Variationsspanne für Hochgeschwindigkeitskameras und Bildauflösungen lässt sich hingegen für manche Anwendungsbereiche nicht ohne Weiteres eingrenzen, weshalb hierfür auf die bereits in Tabelle 7.1 verwendete Wertung $(- / - / \circ / + / + +)$ zurückgegriffen wurde.

In der (ebenfalls erweiterbaren) Tabelle 7.3 werden entsprechend die Anforderungen dieser Anwendungen an potenzielle Korrekturalgorithmen in vier Prioritätskategorien, 1 bis 4, eingeteilt.

Es sollte angemerkt werden, dass diese Einteilung teils zwar etwas willkürlich scheint, dennoch weitestgehend auf Erfahrungswerten beruht. Zudem geht es hier weniger um eine präzise Quantifizierung, als vielmehr um die prinzipielle Erstellung von Anwendungs- und Algorithmusprofilen.

In der (erweiterbaren) Tabelle 7.4 werden die Korrekturfähigkeiten einer Anzahl beispielhaft ausgewählter Korrekturmethoden vergleichend bewertet. Die Leistungseinschätzung der einzelnen Algorithmen erfolgt dabei wieder unter Verwendung der $(- / - / \circ / + / + +)$ Wertung. Die aufgelisteten Bewertungsmerkmale bzw. (Wunsch-)Fähigkeiten entsprechen im Grunde genommen denen in der Abbildung 1.11.

Für den Vergleich wurden sowohl drei eigene Algorithmen herangezogen als auch drei fremde. Eine genauere Beschreibung der eigenen Verfahren findet sich in Kapitel 6, für Details zu CARES, AO und SI sei auf die Abschnitte 2.2.3, 2.1 und 2.2.1 verwiesen. Da es sich speziell bei AO und SI um ganz generelle Ansätze handelt, fällt streng genommen jedoch nur der softwareba-

Anwendung	Fern- erkundung	Surveillance	Astronomie	...
Merkmal				
Kamerabewegung	0	0-1	0*	
Objektbewegung	0-2	0-2	0-2	
Turbulenzbewegung	1-3	0-2	1-2	
Unschärfe	1-3	0-1	1-2	
Verzerrungen	0-3	0-1	0-2	
Blickwinkel	0°-30°	0°	50°-90°	
Ausbreitungsweg	1-30 km	0-2 km	50 km - ∞	
Teleskop ϕ	10-30 cm	3-12 cm	0,5-10 m	
Daten	Frames	Videostream	Frames	
Hochgeschwindigkeit	++	○	++	
Framerate	100-2000 Hz	30 Hz	>1000 Hz	
Bildauflösung	++	○/+	++	
...				

Tabelle 7.2: Beispieldatenebene für eine merkmalsorientierte Profilierung typischer Anwendungsgebiete für Turbulenzkorrekturverfahren. (*: mit Nachführreinrichtung)

sierte CARES-Algorithmus in dieselbe Verfahrenskategorie wie die eigenen Algorithmen.

Wie aus der Tabelle 7.4 ersichtlich, kann grundsätzlich von allen selektierten Methoden eine gute (+) bis sehr gute (++) Qualitätsverbesserung erwartet werden. Die Geschwindigkeit der softwarebasierten Methoden ist generell eher gering, und nur die hardwarebasierte AO vermag sehr gute Qualität bereits in Echtzeit zu liefern. Von großem Nachteil ist bei AO indessen die Beschränkung auf punktförmige Objekte. Mit geeigneter Hardwareimplementierung kann u. U. auch SI Ergebnisse in (nahezu) Echtzeit produzieren, wie bereits in Abschnitt 2.2.1 erwähnt, und das beschränkte FOV lässt sich mittels Kachelung erweitern.

Diejenigen Verfahren, die eine Form der Mittelwertwertbildung einsetzen, haben eine relativ gute bildstabilisierende Wirkung und vermögen auch Verzerrungen und Rauschen hinreichend abzumildern. Die Vor- und Nachteile

Anwendung	Fern- erkundung	Surveillance	Astronomie	...
Priorisierung				
Qualität	2	1	3	
Geschwindigkeit	1	2	0	
Stabilisierung	2	3	2	
Verzerrungen	2	1	3	
Bildschärfe	3	2	3	
Bildkontrast	1	1	2	
Noise	1	1	2	
Autonomie	2	3	0	
...				

Tabelle 7.3: Beispieldtabelle für eine prioritätsorientierte Profilierung typischer Anwendungen.

des CARES-Algorithmus (gute Stabilisierung, weniger gut gegen Unschärfe, Verzerrungen etc.) wurden bereits in Abschnitt 2.2.3 erörtert und spiegeln sich entsprechend in den Bewertungen wider.

Algorithmen mit Entfaltungsverfahren (z. B. WIBD) können indes die Bildschärfe signifikant verbessern, wenngleich nicht auf dem gleichen Niveau wie AO oder SI, dafür ohne Einschränkung des Sichtfeldes.

Speziell bei "TurKom" handelt es sich um eine Modulsammlung der in dieser Arbeit vorgestellten und diskutierten Techniken, gemäß der Grafik in Abbildung 1.13. Je nach Parameterwahl schließt dies eine automatische Turbulenzschätzung anhand der gegebenen Bilddaten mit ein. Mit geeigneten Voreinstellungen kann dieses Programm bis zu einem gewissen Grad unabhängig von weiteren Benutzereingaben funktionieren. Einige etwas widersprüchliche Bewertungen (z. B. Geschwindigkeit oder Verzerrungen) liegen darin begründet, dass sich die Laufzeit beschleunigen lässt (i. A. auf Kosten der Ergebnisqualität), indem z. B. verschiedene Schritte ausgelassen werden oder auf andere, schnellere Methoden umgeschaltet werden. Das heißt, die Ergebnisqualität hängt (ebenso wie die Geschwindigkeit) stark von den gewählten Korrekturmödulen, sowie von den Parametereinstellungen ab. Aufgrund des ganzheitlichen Ansatzes verfügt TurKom (als einziges) über diverse sehr spezielle Funktionalitäten, wie z. B. eine gesonderte Korrektur

Algorithmus Priorisierung	MCA +WIBD	MCA/LIS +WIBD	TurKom	CARES*	Speckle Imaging**	Adaptive Optik**	...
Qualität	+	++	+	+	++	++	
Geschwindigkeit	-/o	-/o	-/+	+	o/+	+	
Stabilisierung	++	+	+	+	o/+	++	
Verzerrungen	+	+	o/+	o/+	o/+	+	
Bildschärfe	+	++	+	o	++	++	
Bildkontrast	+	+	+	o	+	o/+	
Noise	+	+	+	o	o/+	o/+	
Autonomie	o	o	o/+	o	o	o/+	
Turbulenz- bestimmung	o	o	++	o	o	+	
FOV	++	++	++	++	o/+	o	
...							

Tabelle 7.4: Beispieldatenebene für eine merkmalsorientierte Evaluierung verschiedener Turbulenzkorrekturalgorithmen. Linke Seite: eigene Verfahren, rechte Seite: * CARES-Algorithmus [Pot14], sowie ** SI u. AO als generelle Ansätze.

des Farbkontrasts (s. a. Abschnitt 6.8) oder die automatische Detektion von Szenenwechseln, wodurch eine Neuinitialisierung der Turbulenzkorrektur erfolgt.

Anmerkung

Es sollte erwähnt werden, dass hier nur eine limitierte Anzahl fremder Algorithmen zur Evaluation herangezogen werden konnte. Zum einen ist entsprechende Software nur im Ausnahmefall verfügbar und zum anderen sind eigene Nachimplementierungen anhand von (oft unvollständigen oder ungenauen) Autorenbeschreibungen in der Regel zu zeitaufwändig, um praktikabel zu sein. Ein direkter Datenaustausch mit den Autoren wäre zwar eine sinnvolle Alternative, die sich nicht zuletzt aufgrund von Sicherheitsauflagen auf beiden Seiten jedoch nur selten realisieren lässt.

7.4 Zusammenfassung

In diesem Kapitel wurden die verschiedenen Möglichkeiten zur qualitativen Bewertung von Bildqualität ausführlich diskutiert im Hinblick auf die Ergebnisqualität von Turbulenzkorrekturverfahren. Dazu gehören zum einen die numerische Bewertung anhand geeigneter Qualitätsmetriken und zum anderen die merkmalsbasierte Beurteilung durch geschulte Beobachter. Des Weiteren wurde ein Konzept zur Erstellung von Algorithmus- und Anwendungsprofilen vorgestellt. Diese Art der Profilierung ermöglicht den Abgleich zwischen dem (Anwendungs-)Bedarf auf der einen Seite und den Fähigkeiten zur Verfügung stehender Algorithmen auf der anderen Seite. Im Idealfall hätte man eine hinreichend große Datenbank, gefüllt mit den entsprechenden Profilen von Turbulenzkorrektur-Algorithmen, welche überdies passend zu typischen Anwendungsszenarien geordnet werden könnten.

8

Abschlussbemerkungen

8.1 Zusammenfassung

In der vorliegenden Arbeit wurde das Thema Turbulenzkorrektur umfassend von allen Seiten beleuchtet. Zunächst wurden die physikalischen Mechanismen betrachtet, die zur Entstehung von atmosphärischer Turbulenz beitragen und die optischen Effekte beschrieben, die in Bildaufnahmen zu Qualitätsbeeinträchtigungen führen (u. a. Unschärfe, Verzerrungen,...). Anschließend wurden für die einzelnen Turbulenzeffekte spezielle Korrekturmethoden vorgestellt, darunter diverse etablierte Methoden, sowie Weiterentwicklungen und eigene Verfahren.

Ein besonderer Schwerpunkt lag dabei auf Verfahren zur Bewegungskompensation, einerseits zur Bildstabilisierung, und andererseits zur Detektion und gesonderten Korrektur von bewegten Objekten. Ein weiterer Schwerpunkt lag auf Entfaltungsverfahren zur Verbesserung der Bildschärfe und des Kontrastes.

Des Weiteren wurden die praktischen Aspekte intensiv beleuchtet, die bei einer Implementierung von Turbulenzkorrekturverfahren zu berücksichtigen sind, angefangen bei einer geeigneten Datenvorverarbeitung (inkl. spezieller Berücksichtigung von Farbbilddaten), über eine automatisierte Turbulenzschätzung aus gegebenen Bilddaten mit Generierung einer kor-

respondierenden statistischen PSF für ein Einzelbilddeblurring, sowie eine Turbulenzsimulation mit synthetischer GT, bis hin zu eigenen Korrekturverfahren (z. B. MCA, LIS-Prinzip) mit repräsentativen Korrekturbeispielen für Szenarien mit unterschiedlicher Turbulenzstärke.

Überdies wurden geeignete Werkzeuge für eine methodische Evaluierung der Qualität von Korrekturergebnissen ermittelt, insbesondere spezielle Bildqualitätsmetriken (z. B. "Full Reference" / "No-Reference"-Metriken), anhand derer man eine numerische Bewertung bestimmter Bildmerkmale (z. B. Bildschärfe, Kantenanzahl, hohe Frequenzanteile etc.) erhält, sowie auch geeignete Kriterien zur Beurteilung derartiger Bildmerkmale durch menschliche Beobachter (z. B. TOD-Methode).

Im Zuge dessen wurde insbesondere ein Konzept zur Erstellung von Anwendungs- und Algorithmusprofilen entwickelt, um die Anforderungen spezieller Anwendungen leichter mit den Fähigkeiten zur Verfügung stehender Algorithmen vergleichen zu können, und so den für diese Anwendung am besten geeigneten Algorithmus zu identifizieren.

8.2 Ausblick

Für zukünftige Arbeiten ist es denkbar "*Deep Learning*" Methoden mit *Künstlichen Neuronalen Netzen* (KNN), insbesondere "*Convolutional Neural Networks*" (CNN), einzusetzen. Hierzu müssten hinreichend große Datenmengen für die verschiedensten Turbulenzbedingungen vorliegen und sowohl annotiert als auch ausgewertet werden. Gegenüber Standard-Anwendungen, wie z. B. Objekterkennung, müsste die Datenmenge hierfür höchstwahrscheinlich um ein Vielfaches größer sein. Dasselbe Objekt kann in derselben Entfernung unter demselben Winkel bei identischer Beleuchtung je nach vorherrschenden Turbulenzbedingungen völlig unterschiedlich aussehen, insbesondere aufgrund mehr oder weniger stark deformierter Konturen. Dementsprechend wären für jedes solche Objekt wiederum zahlreiche Daten-Samples ("Templates") erforderlich.

Verfahren zur Turbulenzkorrektur liefern generell die besten Ergebnisse, wenn die Eingangsdaten bereits qualitativ so gut wie möglich sind. Ein wesentlicher Vorteil liegt z. B. in der Verwendung von Hochgeschwindigkeitskameras, welche kurze Belichtungszeiten und hohe Frameraten ermöglichen.

Hierdurch entstehen allerdings entsprechend große Datenmengen, deren Verarbeitung in Echtzeit (bzw. nahe daran) je nach Komplexität der ausgewählten Algorithmen weitere Herausforderungen aufwirft. Es ist denkbar, dass Methoden aus dem Forschungsgebiet zur Verarbeitung von *“Big Data”* auch für Anwendungen im Bereich der Turbulenzkorrektur nutzbar gemacht werden können.

Eigene Publikationen

- [1] Mario Greco, Claudia S. Huebner, and Gabriele Marchi. Quantitative performance evaluation of a blurring restoration algorithm based on principal component analysis. In Anton Kohnle, Karin Stein, and John D. Ginglewski, editors, *SPIE Proceedings*, page 71080L. SPIE, 2008.
- [2] Claudia S. Huebner and Mario Greco. Blind deconvolution algorithms for the restoration of atmospherically degraded imagery: a comparative analysis. In Anton Kohnle, Karin Stein, and John D. Ginglewski, editors, *SPIE Proceedings*, page 71080M. SPIE, 2008.
- [3] Claudia S. Huebner. Compensating image degradation due to atmospheric turbulence in anisoplanatic conditions. In Sos S. Agaian and Sabah A. Jassim, editors, *SPIE Proceedings*, page 735106. SPIE, 2009.
- [4] Claudia S. Huebner and Corinne Scheifling. Software-based mitigation of image degradation due to atmospheric turbulence. In Karin Stein and John D. Ginglewski, editors, *SPIE Proceedings*, page 78280N. SPIE, 2010.
- [5] Claudia S. Huebner. Software-based turbulence mitigation of short exposure image data with motion detection and background segmentation. In Karin Stein and John D. Ginglewski, editors, *SPIE Proceedings*, page 81780K. SPIE, 2011.

- [6] Claudia S. Huebner. Turbulence mitigation of short exposure image data using motion detection and background segmentation. In Gerald C. Holst and Keith A. Krapels, editors, *SPIE Proceedings*, page 83550I. SPIE, 2012.
- [7] Claudia S. Huebner and Szymon Gladysz. Simulation of atmospheric turbulence for a qualitative evaluation of image restoration algorithms with motion detection. In Karin Stein and John Ginglewski, editors, *SPIE Proceedings*, page 85350L. SPIE, 2012.
- [8] Adam W. M. van Eekeren, Claudia S. Huebner, Judith Dijk, Klamer Schutte, and Piet B. W. Schwering. Evaluation of turbulence mitigation methods. In Gerald C. Holst, Keith A. Krapels, Gary H. Ballard, James A. Buford, and R. Lee Murrer, editors, *SPIE Proceedings*, page 907113. SPIE, 2014.
- [9] Claudia S. Huebner. Image enhancement methods for turbulence mitigation and the influence of different color spaces. In Karin U. Stein and John D. Ginglewski, editors, *SPIE Proceedings*, page 96410J. SPIE, 2015.
- [10] Claudia S. Huebner. Local motion compensation in image sequences degraded by atmospheric turbulence: A comparative analysis of optical flow vs. block matching methods. In Karin U. Stein and John D. Ginglewski, editors, *SPIE Proceedings*, page 100020I. SPIE, 2016.
- [11] Claudia S. Huebner. Evaluation of side-scan sonar performance for the detection of naval mines. In Karin U. Stein and Ric Schleijpen, editors, *SPIE Proceedings*, page 107940J. SPIE, 2018.
- [12] Claudia S. Huebner. A profiling scheme for algorithms and applications to enable a methodological evaluation of turbulence mitigation methods. In Karin Stein and Szymon Gladysz, editors, *SPIE Proceedings*, volume 11532, page 115320M. SPIE, 2020.
- [13] Claudia S. Huebner. An appraisal of suitable evaluation methods for turbulence mitigation algorithms. In Karin Stein and Szymon Gladysz, editors, *SPIE Proceedings*, volume 12266, pages 12266–13. SPIE, 2022.

Verwendete Literatur

- [Ana13] ANANTRASIRICHAI, Nantheera; ACHIM, Alin; KINGSBURY, Nick G. und BULL, David R.: Atmospheric Turbulence Mitigation Using Complex Wavelet-Based Fusion. *IEEE Transactions on Image Processing* (2013), Bd. 22(6): S. 2398–2408
- [Aub08] AUBAILLY, Mathieu; VORONTSOV, Mikhail A.; CARHART, Gary W. und VALLEY, Michael T.: Image enhancement by local information fusion with pre-processing and composed metric. *Proc. SPIE* (2008), Bd. 7090: S. 709006
- [Aye88] AYERS, G. R. und DAINTY, J. C.: Iterative blind deconvolution method and its applications. *Opt. Lett.* (1988), Bd. 13(7): S. 547–549
- [Bar92] BARRON, J. L.; FLEET, D. J.; BEAUCHEMIN, S. S. und BURKITT, T. A.: Performance of Optical Flow Techniques. *Proc. CVPR* (1992): S. 236–242
- [Bea98] BEAUMONT, Hubert; AIME, Claude; ARISTIDI, Eric und LANTERI, H.: Image quality and seeing measurements for long horizontal overwater propagation. *Pure and Applied Optics: Journal of the European Society Part A* (1998), Bd. 6: S. 15–30
- [Bey12] BEYERER, Jürgen; LEÓN, Fernando Puente und FRESE, Christian: *Automatische Sichtprüfung - Grundlagen, Methoden und Praxis der Bildgewinnung und Bildauswertung*, Springer (2012)

- [Bij98] BIJL, P. und VALETON, J.: Triangle orientation discrimination: The alternative to minimum resolvable temperature difference and minimum resolvable contrast. *Optical Engineering - OPT ENG* (1998), Bd. 37: S. 1976–1983
- [Car02] CARRANO, Carmen J.: Speckle imaging over horizontal paths. *Proc. SPIE* (2002), Bd. 4825: S. 109–120
- [Car04] CARRANO, Carmen J. und BRASE, James M.: Adapting high-resolution speckle imaging to moving targets and platforms, in: Arthur A. Andraitis und Gerard J. Leygraaf (Herausgeber) *Airborne Intelligence, Surveillance, Reconnaissance (ISR) Systems and Applications*, Bd. 5409, International Society for Optics and Photonics, SPIE, S. 96–105
- [Cha14] CHAUDHURI, S.; VELMURUGAN, R. und RAMESHAN, R.: Blind Deconvolution Methods: A Review, in: *Blind Image Deconvolution: Methods and Convergence*, S. 37–60
- [Che14] CHEN, Eli; HAIK, Oren und YITZHAKY, Yitzhak: Detecting and tracking moving objects in long-distance imaging through turbulent medium. *Appl. Opt.* (2014), Bd. 53(6): S. 1181–1190
- [Cur09] CURT, Petersen F; BODNAR, Michael R.; ORTIZ, Fernando E.; CARRANO, Carmen J. und KELMELIS, Eric J.: Real-time embedded atmospheric compensation for long-range imaging using the average bispectrum speckle method, in: Nasser Kehtarnavaz und Matthias F. Carlsohn (Herausgeber) *Real-Time Image and Video Processing 2009*, Bd. 7244, International Society for Optics and Photonics, SPIE, S. 27–38
- [Dai00] DAINTY, J. C.: *Optical Effects of Atmospheric Turbulence*, Bd. 551 von *NATO ASI Series (Series C: Mathematical and Physical Sciences)*, Kap. 1, Springer, Dordrecht (2000), S. 1–22
- [Dij16] DIJK, Judith; SCHUTTE, Klamer und NIEUWENHUIZEN, Robert: Turbulence mitigation methods for sea scenarios, in: David A. Huckleridge; Reinhard Ebert und Stephen T. Lee (Herausgeber) *Electro-*

Optical and Infrared Systems: Technology and Applications, Bd. 9987, International Society for Optics and Photonics, SPIE, S. 119–129

- [Dol07] DOLMIERE, F.; LADRET, T. und NICOLAS, M.: The Blur Effect: Perception and Estimation with a New No-Reference Perceptual Blur Metric, in: Bernice E. Rogowitz; Thrasyvoulos N. Pappas und Scott J. Daly (Herausgeber) *Proc. SPIE*, Bd. 6492, SPIE, S. 64920I
- [Dud18] DUDOROV, Vadim V. und EREMINA, Anna S.: Computer correction of turbulent distortions of incoherent optical images using multi-aperture systems. *Proc. SPIE* (2018), Bd. 10787: S. 107870E
- [Far02] FARNEBÄCK, Gunnar: *Polynomial Expansion for Orientation and Motion Estimation*, Dissertation, Linköpings Universitet, Department of Electrical Engineering (2002)
- [Far03] FARNEBÄCK, Gunnar: Two-Frame Motion Estimation Based on Polynomial Expansion. *Proc. 13th Scandinavian Conference on Image Analysis* (2003): S. 363–370
- [Fer06] FERGUS, R.; SINGH, B.; HERTZMANN, A.; ROWEIS, S. T. und FREEMAN, W. T.: Removing camera shake from a single photograph, in: *ACM Transactions on Graphics*, Bd. 25, S. 787–794
- [Fra06] FRASER, Donald; LAMBERT, Andrew J. und CRAIG, B. I.: Image Restoration in Horizontal Surveillance by Telescope. *Journal of Battlefield Technology* (2006), Bd. 9(2): S. 27–31
- [Fri66] FRIED, D. L.: Optical Resolution Through A Randomly Inhomogeneous Medium for Very Long and Very Short Exposures. *J. Opt. Soc. Am.* (1966), Bd. 56(10): S. 1372–1379
- [Fri78] FRIED, David L.: Probability of getting a lucky short-exposure image through turbulence. *J. Opt. Soc. Am.* (1978), Bd. 68(12): S. 1651–1658
- [Fri82] FRIED, David L.: Anisoplanatism in adaptive optics. *J. Opt. Soc. Am.* (1982), Bd. 72(1): S. 52–61

- [Fur16] FURHAD, Md. Hasan; TAHTALI, Murat und LAMBERT, Andrew: Restoring atmospheric-turbulence-degraded images. *Applied Optics* (2016), Bd. 55(19): S. 5082–5090
- [Gao19] GAO, Jing; ANANTRASIRICHAI, N. und BULL, David: Atmospheric turbulence removal using convolutional neural network (2019)
- [Gla13] GLADYSZ, Szymon: Estimation of turbulence strength directly from target images, in: *Imaging and Applied Optics*, Optical Society of America, S. JW1A.4
- [Gon08] GONZALEZ, Rafael C. und WOODS, Richard E.: *Digital Image Processing, Third Edition*, Kap. 5, Prentice Hall (2008), S. 351–362
- [Gon09] GONZALEZ, Rafael C.; WOODS, Richard E. und EDDINS, Steven L.: *Digital Image Processing using MATLAB, Second Edition*, Kap. 5, Gatesmark Publishing (2009)
- [Gre08] GRECO, Mario; HUEBNER, Claudia S. und MARCHI, Gabriele: Quantitative performance evaluation of a blurring restoration algorithm based on principal component analysis, in: Anton Kohnle; Karin Stein und John D. Ganglewski (Herausgeber) *Proc. SPIE*, SPIE, S. 71080L
- [Gun05] GUNTURK, B.K.; GLOTZBACH, J.; ALTUNBASAK, Y.; SCHAFER, R.W. und MERSEREAU, R.M.: Demosaicking: color filter array interpolation. *IEEE Signal Processing Magazine* (2005), Bd. 22(1): S. 44–54
- [Gya03] GYAOUROVA, A.: Block matching for object tracking, in: *Tech. Rep. UCRL-TR-200271*, Lawrence Livermore National Laboratory
- [Har17] HARDIE, Russell C.; RUCCI, Michael A.; DAPORE, Alexander J. und KARCH, Barry K.: Block matching and Wiener filtering approach to optical turbulence mitigation and its application to simulated and real imagery with quantitative error analysis. *Optical Engineering* (2017), Bd. 56(7): S. 1–16
- [Hip04] HIPPLER, S. und KASPER, M.: Dem Seeing ein Schnippchen schlagen - Adaptive Optik in der Astronomie, Teil 1. *Spektrum: Sterne und Weltraum* (2004): S. 32–42

- [Hir10] HIRSCH, Michael; SRA, Suvrit; SCHÖLKOPF, Bernhard und HARLEMING, Stefan: Efficient filter flow for space-variant multiframe blind deconvolution, in: *2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, S. 607–614
- [Hof19] HOFMANN, Julia; GLADYSZ, Szymon und LEMASTER, Daniel A.: Straightness metric for warping strength in atmospheric turbulence affected images, in: *Propagation Through and Characterization of Atmospheric and Oceanic Phenomena*, Optical Society of America, S. PTu2D-3
- [Hor81] HORN, B.K.P. und SCHUNCK, B.G.: Determining optical flow. *Artificial Intelligence* (1981), Bd. 17: S. 185–203
- [Hue08] HUEBNER, Claudia S. und GRECO, Mario: Blind Deconvolution Algorithms for the Restoration of atmospherically degraded Imagery: a comparative Analysis, in: Anton Kohnle; Karin Stein und John D. Ginglewski (Herausgeber) *Proc. SPIE*, SPIE, S. 71080M
- [Hue09] HUEBNER, Claudia S.: Compensating image degradation due to atmospheric turbulence in anisoplanatic conditions, in: Sos S. Agaian und Sabah A. Jassim (Herausgeber) *Proc. SPIE*, SPIE, S. 735106
- [Hue10] HUEBNER, Claudia S. und SCHEIFLING, Corinne: Software-based mitigation of image degradation due to atmospheric turbulence, in: Karin Stein und John D. Ginglewski (Herausgeber) *Proc. SPIE*, SPIE, S. 78280N
- [Hue11] HUEBNER, Claudia S.: Software-based turbulence mitigation of short exposure image data with motion detection and background segmentation, in: Karin Stein und John D. Ginglewski (Herausgeber) *Proc. SPIE*, SPIE, S. 81780K
- [Hue12a] HUEBNER, Claudia S.: Turbulence mitigation of short exposure image data using motion detection and background segmentation, in: Gerald C. Holst und Keith A. Krapels (Herausgeber) *Proc. SPIE*, SPIE, S. 83550I

- [Hue12b] HUEBNER, Claudia S. und GLADYSZ, Szymon: Simulation of atmospheric turbulence for a qualitative evaluation of image restoration algorithms with motion detection, in: Karin Stein und John Gonglewski (Herausgeber) *Proc. SPIE*, SPIE, S. 85350L
- [Hue15] HUEBNER, Claudia S.: Image enhancement methods for turbulence mitigation and the influence of different color spaces, in: Karin U. Stein und John D. Gonglewski (Herausgeber) *Proc. SPIE*, SPIE, S. 96410J
- [Hue16] HUEBNER, Claudia S.: Local motion compensation in image sequences degraded by atmospheric turbulence: A comparative analysis of optical flow vs. block matching methods, in: Karin U. Stein und John D. Gonglewski (Herausgeber) *Proc. SPIE*, SPIE, S. 100020I
- [Hue18] HUEBNER, Claudia S.: Evaluation of side-scan sonar performance for the detection of naval mines, in: Karin U. Stein und Ric Schleijpen (Herausgeber) *Proc. SPIE*, SPIE, S. 107940J
- [Ira00] IRANI, M. und ANANDAN, P.: About Direct Methods. *Vision Algorithms: Theory and Practice. ICCV Workshop on Vision Algorithms. Lecture Notes in Computer Science* (2000), Bd. 1883: S. 267–277
- [Jen79] JENSON, S. K. und WALTZ, F. A.: Principal Component Analysis and Canonical Analysis in Remote Sensing. *Proc. Am. Soc. Photogr.* (1979): S. 337–348
- [Joh03] JOHN, Sarah und VORONTSOV, Mikhail A.: Multiframe information fusion for multispectral imaging through atmospheric turbulence. *Proc. SPIE* (2003), Bd. 5093: S. 740–747
- [Kár37a] KÁRMÁN, Theodore von: On the statistical theory of turbulence. *Proc. Nat. Akad. Sci.* (1937), Bd. 23(2): S. 98–105
- [Kár37b] KÁRMÁN, Theodore von und HOWARTH, Leslie: On the Statistical Theory of Isotropic Turbulence. *Proc. Roy. Soc. Lond. A* (1937), Bd. 164: S. 192–215

- [Kel17] KELMELIS, Eric J.; KOZACIK, Stephen T. und PAOLINI, Aaron L.: Practical considerations for real-time turbulence mitigation in long-range imagery. *Optical Engineering* (2017), Bd. 56(7): S. 1–12
- [Kno74] KNOX, K. T. und THOMPSON, B. J.: Recovery of Images from Atmospherically Degraded Short-Exposure Photographs. *Astrophysical Journal* (1974), Bd. 193: S. L45
- [Kol41] KOLMOGOROV, Andrey Nikolaevich: The local structure of turbulence in incompressible viscous fluid for very large Reynolds numbers. *Dokl. Akad. Nauk SSSR* (1941), Bd. 30: S. 301–305, russisches Original
- [Kru12] KRUITHOF, Maarten C.; VAN EEKEREN, Adam W. M.; DIJK, Judith und SCHUTTE, Klamer: Single image super resolution via sparse reconstruction, in: Fauzia Ahmad (Herausgeber) *Compressive Sensing*, Bd. 8365, International Society for Optics and Photonics, SPIE, S. 84–90
- [Kun96a] KUNDUR, D. und HATZINAKOS, D.: Blind Image Deconvolution. *IEEE Signal Processing Magazine* (1996), Bd. 13(3): S. 43–64
- [Kun96b] KUNDUR, D. und HATZINAKOS, D.: Blind Image Deconvolution Revisited. *IEEE Signal Processing Magazine* (1996), Bd. 13(6): S. 61–63
- [Lab70] LABEYRIE, A.: Attainment of Diffraction Limited Resolution in Large Telescopes by Fourier Analysing Speckle Patterns in Star Images. *Astronomy and Astrophysics* (1970), Bd. 6: S. 85–87
- [Lam02] LAMBERT, Andrew J.; FRASER, Donald; JAHROMI, M. Reza Sayyah und HUNT, Bobby R.: Superresolution in image restoration of wide-area images viewed through atmospheric turbulence, in: Philip J. Bones; Michael A. Fiddy und Rick P. Millane (Herausgeber) *Image Reconstruction from Incomplete Data II*, Bd. 4792, International Society for Optics and Photonics, SPIE, S. 35–43
- [Lan87] LANE, R. G. und BATES, R. H. T.: Automatic multidimensional deconvolution. *J. Opt. Soc. Am. A* (1987), Bd. 4(1): S. 180–188

- [Lan92] LANE, R. G.; GLINDEMAN, A. und DAINTY, J. C.: Simulation of a Kolmogorov phase screen. *Waves Random Media* (1992), Bd. 2: S. 209–224
- [Lev09] LEVIN, Anat; WEISS, Yair; DURAND, Fredo und FREEMAN, William T.: Understanding and evaluating blind deconvolution algorithms, in: *2009 IEEE Conference on Computer Vision and Pattern Recognition*, S. 1964–1971
- [LG14] LUZÓN-GONZÁLEZ, R.; NASCIMENTA, S. M. C.; MASUDA, O. und ROMERO, J.: Chromatic losses in natural scenes with viewing distance. *Color Research & Application* (2014), Bd. 39(4): S. 341–346
- [Li07] LI, D.; MERSEREAU, M. und SIMKE, S.: Atmospheric Turbulence-Degraded Image Restoration Using Principal Component Analysis. *IEEE Geoscience and Remote Sensing Letters* (2007), Bd. 4(3): S. 340–344
- [Li09] LI, Dalong: Suppressing atmospheric turbulent motion in video through trajectory smoothing. *Elsevier - Signal Processing* (2009), Bd. 89(4): S. 649–655
- [Lou13] LOU, Yifei; KANG, Sung Ha; SOATTO, Stefano und BERTOZZI, Andrea L.: Video stabilization of atmospheric turbulence distortion. *Inverse Problems & Imaging* (2013), Bd. 7(3): S. 839–861
- [Luc74] LUCY, L. B.: An iterative technique for the rectification of observed distributions. *Astron. J.* (1974), Bd. 79(6): S. 745–754
- [Luc81] LUCAS, B. und KANADE, T.: An iterative Image Registration Technique with Applications to Stereo Vision. *Proc. DARPA* (1981): S. 121–130
- [Lüh83] LÜHE, Oscar von der: A study of a correlation tracking method to improve imaging quality of ground-based solar telescopes. *Astronomy and Astrophysics* (1983), Bd. 119(1): S. 85–94
- [Lüh84] LÜHE, Oscar von der: Estimating Fried's parameter from a time series of an arbitrarily resolved object imaged through atmospheric turbulence. *J. Opt. Soc. Am. A* (1984), Bd. 1(5): S. 510–519

- [Lüh93] LÜHE, Oscar von der: Speckle imaging of solar small scale structure: I - Methods. *Astronomy and Astrophysics* (1993), Bd. 268(1): S. 374–390
- [Mal04] MALVAR, H.S.; WEI HE, Li und CUTLER, R.: High-quality linear interpolation for demosaicing of Bayer-patterned color images, in: *2004 IEEE International Conference on Acoustics, Speech, and Signal Processing*, Bd. 3, S. 485–488
- [Man83] MANDELBROT, B.: *The Fractal Geometry of Nature*, Bd. 173, Macmillan (1983), new York, NY, USA
- [Mau04] MAUER, Edmond: Investigation of atmospheric turbulence effects on extended objects in high speed image sequences applying automatic image analysis. *Proc. SPIE* (2004), Bd. 5237: S. 39–48
- [McC17] MCCRAE, Jack E.; BOSE-PILLAI, Santasri R. und FIORINO, Steven T.: Estimation of turbulence from time-lapse imagery. *Optical Engineering* (2017), Bd. 56(7): S. 1–9
- [McG76] MCGLAMERY, B. L.: Computer simulation studies of compensation of turbulence degraded images. *Proc. SPIE* (1976), Bd. 74: S. 225–233
- [MM15] MOLINA-MARTEL, F.; BAENA-GALLÉ, R. und GLADYSZ, S.: Fast PSF estimation under anisoplanatic conditions, in: Karin Stein und John D. Ginglewski (Herausgeber) *Proc. SPIE*, Bd. 9641, SPIE, S. 96410I
- [Mon14] MONNIER, G.; DUVAL, F. und AMRAM, S.: GPU-based simulation of optical propagation through turbulence for active and passive imaging, in: Karin Stein und John D. Ginglewski (Herausgeber) *Proc. SPIE*, Bd. 9242, SPIE, S. 92421R
- [Ng06] NG, Ren: *Digital Light Field Photography*, Stanford University (2006)
- [Nie02] NIE, Y. und MA, K.-K.: Adaptive rood pattern search for fast block-matching motion estimation. *IEEE Transactions on Image Processing* (2002), Bd. 11(12): S. 1442–1449

- [Nie19] NIEUWENHUIZEN, Robert; DIJK, Judith und SCHUTTE, Klamer: Dynamic turbulence mitigation for long-range imaging in the presence of large moving objects. *EURASIP J. Image Video Proc.* (2019), Bd. 2019(2): S. 1–22
- [Ori10a] ORIEUX, François; GIOVANNELLI, Jean-François und RODET, Thomas: Bayesian estimation of regularization and point spread function parameters for Wiener-Hunt deconvolution. *J. Opt. Soc. Am. A* (2010), Bd. 27: S. 1593–1607
- [Pao14] PAOLINI, Aaron; HUMPHREY, John; CURT, Petersen und KELMELIS, Eric: Multi-frame image processing with panning cameras and moving subjects, in: Daniel J. Henry; Davis A. Lange; Dale Linne von Berg; S. Danny Rajan; Thomas J. Walls und Darrell L. Young (Herausgeber) *Airborne Intelligence, Surveillance, Reconnaissance (ISR) Systems and Applications XI*, Bd. 9076, International Society for Optics and Photonics, SPIE, S. 56–62
- [Plo96] PLOTNICK, R.; HARGROVE, R.; HARGROVE, W.; PRESTEGAARD, K. und PERLMUTTER, M.: Lacunarity analysis: A general technique for the analysis of spatial patterns. *Phys. Rev. E* (1996), Bd. 53(5): S. 5461–5468
- [Pol99] POLEJAEV, V. I.; BARBIER, P. R.; CARHART, G. W.; PLETT, M. L.; RUSH, D. W. und VORONTSOV, M. A.: Adaptive compensation of dynamic wavefront aberrations based on blind optimization technique. *Proc. SPIE* (1999), Bd. 3760: S. 88–95
- [Pot10] POTVIN, Guy; FORAND, J. Luc und DION, Denis: Restoration of Turbulence-Degraded Images Using Pixel Histograms. *Imaging Systems* (2010): S. IWA5
- [Pot14] POTVIN, Guy: CARES: Cascading Auto-Regressive Exponential Smoothing, in: *Scientific Report*, DRC-RDDC-2014-R188, Defense Research and Development Canada, S. 1–44
- [Rep06] REPASI, E.: Image Catalogue of Video Sequences recorded by FGAN-FOM during the NATO RTO SET072/RTG-40 Field Trials. *Report distributed to group members* (2006)

- [Rep08] REPASI, E. und WEISS, R.: Analysis of Image Distortions by Atmospheric Turbulence and Computer Simulation of Turbulence Effects. *Proc. SPIE* (2008), Bd. 6941: S. 69410S
- [Ric72] RICHARDSON, W. H.: Bayesian-Based Iterative Method of Image Restoration. *J. Opt. Soc. Am.* (1972), Bd. 62(1): S. 55–60
- [Rio13] RIOS, Carlos und GLADYSZ, Szymon: No-reference image quality assessment for horizontal-path imaging scenarios. *Proc. SPIE* (2013), Bd. 8720: S. 872006
- [Rod81] RODDIER, François: The Effects of Atmospheric Turbulence in Optical Astronomy, Bd. 19 von *Progress in Optics*, Elsevier (1981), S. 281–376
- [Rod86] RODDIER, François: Triple correlation as a phase closure technique. *Optics Communications* (1986), Bd. 60(3): S. 145–148
- [Rog96] ROGGEVANN, Michael C. und WELSH, Byron M.: *Imaging Through Turbulence*, Kap. 3, NATO ASI Series (Series C: Mathematical and Physical Sciences), CRC Press, Boca Raton, Florida (1996)
- [Sam09] SAMPAT, M. P.; WANG, Z.; GUPTA, S.; BOVIK, A. C. und MARKEY, M. K.: Complex Wavelet Structural Similarity: A New Image Similarity Index. *IEEE Transactions on Image Processing* (2009), Bd. 18(11): S. 2385–2401
- [Sch03] SCHUTTE, Klamer; DE LANGE, Dirk-Jan J. und VAN DEN BROEK, Sebastian P.: Signal conditioning algorithms for enhanced tactical sensor imagery, in: Gerald C. Holst (Herausgeber) *Infrared Imaging Systems: Design, Analysis, Modeling, and Testing XIV*, Bd. 5076, International Society for Optics and Photonics, SPIE, S. 92–100
- [Sch10] SCHEIFLING, Corinne und MARCHI, Gabriele: Iterative Correction Procedure for Images degraded by Turbulence. *Proc. SPIE* (2010), Bd. 7828: S. 78280O
- [Sch12] SCHUTTE, Klamer; VAN EEKEREN, Adam W. M.; DIJK, Judith; SCHWERRING, Piet B. W.; VAN IERSEL, Miranda und DOELMAN, Niek J.: An

- overview of turbulence compensation, in: Gary W. Kamerman; Ove Steinvall; Gary J. Bishop; John Ginglewski; Mark T. Gruneisen; Miroslav Dusek; John G. Rarity; Keith L. Lewis; Richard C. Hollins und Thomas J. Merlet (Herausgeber) *Electro-Optical Remote Sensing, Photonic Technologies, and Applications VI*, Bd. 8542, International Society for Optics and Photonics, SPIE, S. 212–221
- [Sei01] SEIFFER, Dirk: Messung der optischen Turbulenz und räumlichen Turbulenzeffekte. *Interner Bericht des FGAN-FOM* (2001), Bd. 2001(30)
- [She82] SHEPP, L. A. und VARDI, Y.: Maximum Likelihood Reconstruction for Emission Tomography. *IEEE Transactions on Medical Imaging* (1982), Bd. 1(2): S. 113–122
- [Tat61] TATARSKII, V. I.: *Wave propagation in turbulent media*, McGraw-Hill (1961), russisches Original 1959
- [Tat71] TATARSKII, V. I.: *The Effects of the Turbulent Atmosphere on Wave Propagation*, Israel Program for Scientific Translations (1971), russisches Original Moskau, Nauka 1967
- [Tor00] TORR, P. H. S. und ZISSERMAN, A.: Feature Based Methods for Structure and Motion Estimation. *Vision Algorithms: Theory and Practice. ICCV Workshop on Vision Algorithms. Lecture Notes in Computer Science* (2000), Bd. 1883: S. 278–294
- [van14] VAN EEKEREN, Adam W. M.; HUEBNER, Claudia S.; DIJK, Judith; SCHUTTE, Klamer und SCHWERING, Piet B. W.: Evaluation of turbulence mitigation methods, in: Gerald C. Holst; Keith A. Krapels; Gary H. Ballard; James A. Buford und R. Lee Murrer (Herausgeber) *Proc. SPIE*, SPIE, S. 907113
- [vE07] VAN EEKEREN, Adam W. M.; SCHUTTE, Klamer; OUDEGEEST, Olivier und VLIET, Lucas Van: Performance Evaluation of Super-Resolution Reconstruction Methods on Real-World Data. *EURASIP Journal on Advances in Signal Processing* (2007): S. 1–11

- [vE12] VAN EEKEREN, Adam W. M.; KRUITHOF, Maarten C.; SCHUTTE, Klamer; DIJK, Judith; VAN IERSEL, Miranda und SCHWERING, Piet B. W.: Patch-based local turbulence compensation in anisoplanatic conditions, in: Gerald C. Holst und Keith A. Krapels (Herausgeber) *Infrared Imaging Systems: Design, Analysis, Modeling, and Testing XXIII*, Bd. 8355, International Society for Optics and Photonics, SPIE, S. 263–270
- [Vel12] VELLUET, M. T.; VORONTSOV, M.; ESPINOLA, R.; MARCHI, G.; NICOLAS, S.; SCHWERING, P. und RIKER, J.: Turbulence characterization and image processing data sets from a NATO RTO SET 165 trial in Dayton, Ohio, USA, in: Linda M. Wasiczko Thomas und Earl J. Spillar (Herausgeber) *Atmospheric Propagation IX*, Bd. 8380, SPIE, S. 154–162
- [Vin20] VINT, David; CATERINA, Gaetano Di; SORAGHAN, John; LAMB, Robert und HUMPHREYS, David: Analysis of deep learning architectures for turbulence mitigation in long-range imagery, in: *Artificial Intelligence and Machine Learning in Defense Applications II*, Bd. 11543, International Society for Optics and Photonics, SPIE, S. 1–18
- [Vor96] VORONTSOV, M. A.; CARHART, G. W.; PRUIDZE, D. V.; RICKLIN, J. C. und VOELZ, D. G.: Image quality criteria for an adaptive imaging system based on statistical analysis of the speckle field. *J. Soc. Am. A* (1996), Bd. 13(7)
- [Vor97] VORONTSOV, M. A.; CARHART, G. W. und RICKLIN, J. C.: Adaptive phase-distortion correction based on parallel gradient descent optimization. *Opt. Lett.* (1997), Bd. 22: S. 907–909
- [Vor20] VORONTSOV, Artem M.; VORONTSOV, Mikhail A.; FILIMONOV, Grigorii A. und POLNAU, Ernst: Atmospheric Turbulence Study with Deep Machine Learning of Intensity Scintillation Patterns. *Applied Sciences* (2020), Bd. 10(22): S. 1–26
- [Wan02] WANG, Z. und BOVIK, A. C.: A universal image quality index. *IEEE Signal Processing Letters* (2002), Bd. 9(3): S. 81–84

- [Wan04] WANG, Z.; BOVIK, A. C.; SHEIKH, H. und SIMONCELLI, E.: Image quality assessment: From error visibility to structural similarity. *IEEE Transactions on Image Processing* (2004), Bd. 13(4): S. 600–612
- [Wan09] WANG, Z. und BOVIK, A. C.: Mean squared error: love it or leave it? - A new look at signal fidelity measures. *IEEE Signal Processing Magazine* (2009), Bd. 26: S. 98–117
- [Wei75] WEIGELT, Gerd P.: Large Field Speckle Interferometry. *Optik* (1975), Bd. 43(2): S. 111–128
- [Wil15] WILLIAMS, David P.: Fast Unsupervised Seafloor Characterization in Sonar Imagery Using Lacunarity. *IEEE Transactions on Geoscience and Remote Sensing* (2015), Bd. 53(11): S. 6022–6034
- [Yan09] YANG, H.; LI, X. und JIANG, W.: Restoration of turbulence-degraded extended object using the stochastic parallel gradient descent algorithm: numerical simulation. *Optics Express* (2009), Bd. 17(5): S. 3052–3062
- [Yas20] YASARLA, Rajeev und PATEL, Vishal M.: Learning to Restore a Single Face Image Degraded by Atmospheric Turbulence using CNNs (2020)
- [Yil06] YILMAZ, Alper; JAVED, Omar und SHAH, Mubarak: Object Tracking: A Survey. *ACM Comput. Surv.* (2006), Bd. 38(4): S. 13–es
- [Yit97a] YITZHAKY, Yitzhak; DROR, Itai und KOPEIKA, Norman S.: Restoration of atmospherically blurred images according to weather-predicted atmospheric modulation transfer functions. *Opt. Eng.* (1997), Bd. 36(11): S. 3064–3072
- [Yit98] YITZHAKY, Y.; MOR, I.; LANTZMAN, A. und KOPEIKA, N. S.: Direct method for restoration of motion-blurred images. *J. Opt. Soc. Am. A* (1998), Bd. 15(6): S. 1512–1519
- [Zam06] ZAMEK, Steve und YITZHAKY, Yitzhak: Turbulence strength estimation from an arbitrary set of atmospherically degraded images. *J. Opt. Soc. Am. A* (2006), Bd. 23(12): S. 3106–3113

-
- [Zep13] ZEPP, A.; GLADYSZ, S. und STEIN, K.: Holographic wavefront sensor for fast defocus measurement. *Advanced Optical Technologies* (2013), Bd. 2(5-6): S. 433–437
 - [Zhu13] ZHU, Xiang und MILANFAR, Peyman: Removing Atmospheric Turbulence via Space-Invariant Deconvolution. *IEEE Transactions on Pattern Analysis and Machine Intelligence* (2013), Bd. 35(1): S. 157–170
 - [Zui94] ZUIDERVELD, Karl: Contrast Limited Adaptive Histogram Equalization, in: *Graphic Gems IV*, San Diego: Academic Press Professional, S. 474–485

Abbildungsverzeichnis

1.1	Beispiel für atmosphärische Turbulenz- und Refraktionseffekte (St. Peter Ording, Foto: M. Hebel)	2
1.2	Auswirkung atmosphärischer Turbulenz auf eine ebene Wellenfront	3
1.3	Szintillationseffekte bei starker Turbulenz. Links: reale Messung eines Laserspots; rechts: simulierte PSF	4
1.4	Beispiel für turbulenzbedingte Bildunschärfe. Links: Originalbild, rechts: Ausschnittsvergrößerung.	5
1.5	Beispiel für turbulenzbedingte Bilddeformationen. Links: Originalbild, Mitte u. rechts: Ausschnittsvergrößerung zwei weiterer Frames mit jeweils unterschiedlichen Deformationen.	5
1.6	Beispiel für turbulenzbedingten Verlust von (Farb-)Kontrast. Links: Originalbild, Mitte: Rekonstruktion mit Rauschverstärkung, rechts: Detailvergrößerung.	6
1.7	Infrarot-Aufnahmen eines Jets in unterschiedlichen Entfernung zur Kamera unter vergleichbaren Turbulenzbedingungen.	7
1.8	Beispiel für Unterwasserturbulenz. Oben: Wasser im Ruhezustand; unten: mithilfe von Heizplatten künstlich erzeugte Turbulenz.	8
1.9	Wirkung von Szintillation und Rauschen auf ein binäres Signal (x -Achse: Zeit t , y -Achse: Intensität, skaliert auf $[0,1]$).	9

1.10	Modellierung des turbulenzbedingten Degradationsprozesses von Bilddaten in Form einer Faltung mit der atmosphärischen Filterfunktion.	11
1.11	Typische Turbulenzeffekte und zugehörige Korrekturansätze	12
1.12	Schematische Darstellung turbulenzbedingter Bildbeeinträchtigung und Bildrekonstruktion mittels inverser Filterung	14
1.13	Prozessierungskette mit den wesentlichen Verfahrensschritten zur Turbulenzkorrektur	16
2.1	Funktionsschema eines AO-Systems (Grafik: A. Zepp)	22
2.2	Zernike-Polynome 1. bis 4. Ordnung	25
2.3	Beispielrekonstruktion eines Sonnenfleckens mittels Triple-korrelation.	27
2.4	“Synthetic Imaging”-Korrektur einer Beispielsequenz. Links: Mittelwert von 930 Frames, Mitte: bester Frame, rechts: Korrekturergebnis mit Bewegungsartefakten.	29
2.5	Beispielergebnis des CARES-Algorithmus. Links: Originalframe; Mitte: CARES-Korrekturergebnis; rechts: mit zusätzlicher blinder Entfaltung (mittels WIBD).	31
2.6	Beispielbild einer Person mit Funkgerät bei starker Turbulenz (“China Lake”-Testsequenz, Standardturbulenzkorrektur)	41
3.1	Mechanisches Turbulenzmodell von Kolmogorov	55
3.2	Darstellung des Turbulenzmodells von Kolmogorov (Grafik: K. Weiß-Wrana)	58
3.3	Illustration des isoplanatischen Winkels und der Kohärenzlänge r_0 (Grafik: E. Mauer [Mau04])	61
3.4	Die Kohärenzlänge r_0 in Abhängigkeit von der Wegstrecke L für ausgewählte Turbulenzstärken C_n^2 (in $\text{m}^{-2/3}$, v.o.n.u. zunehmend) und Wellenlängen λ . Links: VIS, rechts: IR.	64
3.5	Extreme Turbulenz verursacht durch den Abgasstrahl eines Jet-Triebwerks	65
3.6	Beispiele für Transversalwellen. Links: kreisförmige Wellenfront (schwarz) mit radialer Ausbreitungsrichtung (rot); rechts: gerade Wellenfront (schwarz) mit geradliniger Ausbreitungsrichtung (rot).	68

3.7	Grafische Darstellung der MTF	71
3.8	Beispielhafte Simulation der limitierenden Einflüsse auf die Bildgebung. Links: Beugungsbegrenzung; Mitte: Detektor-Limitierung; rechts: Turbulenzlimitierung. (Simulationen: S. Gladysz)	74
3.9	Simulierte Beispiele für typische Optik-Verzeichnungen. Obere Reihe (v.l.n.r.): unverzerrtes Originalbild, Vignette-Effekt, Fischaugenobjektiv; untere Reihe (v.l.n.r.): perspektivische Verzeichnung, Tonnen- und Kissenverzeichnung	75
3.10	Beispiel für "Interlacing"-Effekte. Oben: Bildausschnitt ohne Turbulenz; unten: mit Heizgerät künstlich erzeugte Turbulenz.	76
3.11	Simulationsbeispiele häufig vorkommender Rauschtypen. Obere Reihe (v.l.n.r.): Gauss-verteiltes Rauschen, Salz-und-Pfeffer Rauschen, Farbrauschen; untere Reihe (v.l.n.r.): Poisson-verteiltes Rauschen, Gauss-verteiltes Rauschen mit lokaler Varianz, Speckle-Rauschen	78
4.1	Beispiel für den "Geistereffekt", der durch Bewegung bei der Mittelwertbildung entsteht. Links u. Mitte: Einzelbilder von Anfang bis Ende des Bewegungsablaufs; rechts: zugehöriger Mittelwert (150 Frames)	82
4.2	Mögliche Szenarien in Videosequenzen	87
4.3	Illustration des "Block Matching" Grundprinzips	90
4.4	Beispiel für AR-Suchmustertypen. Der blaue Punkt markiert den aktuellen Block, und grün kennzeichnet die Blöcke, die zur Prädiktion verwendet werden.	93
4.5	Beispielhafte Visualisierung des Korrelationsergebnisses (a) 2-D und (b) 3-D für (c) zwei Frames einer simulierten Bildsequenz.	95
4.6	Optischer Fluss am Beispiel der "Yosemite" Testsequenz.	98
4.7	Schätzung des optischen Flusses mittels Horn-Schunk Algorithmus	99
4.8	Optischer Fluss mittels Horn-Schunk Algorithmus: (a) Betrag und (b) Orientierung der geschätzten Bewegungsvektoren.	100
4.9	Optischer Fluss mittels Horn-Schunk Algorithmus: (a) horizontale und (b) vertikale Komponenten der geschätzten Bewegungsvektoren.	100

4.10 Schätzung des optischen Flusses mittels Lucas-Kanade Algorithmus	101
4.11 Optischer Fluss mittels Lucas-Kanade Algorithmus: (a) Betrag und (b) Orientierung der geschätzten Bewegungsvektoren.	102
4.12 Optischer Fluss mittels Lucas-Kanade Algorithmus: (a) horizontale und (b) vertikale Komponenten der geschätzten Bewegungsvektoren.	103
4.13 Schätzung des optischen Flusses mit Farnebäck Algorithmus	104
4.14 Optischer Fluss mittels Farnebäck Algorithmus: Visualisierung (a) des Betrags und (b) der Orientierung der geschätzten Bewegungsvektoren.	105
4.15 Optischer Fluss mittels Farnebäck Algorithmus: Visualisierung (a) der horizontalen und (b) der vertikalen Komponenten der geschätzten Bewegungsvektoren.	105
4.16 Optischer Fluss: (a) Globale und (b) lokale Bewegung	107
4.17 Beispieldsequenz "Grove"	108
4.18 Homogenitätskarte für die "Grove" Sequenz: (a) Karte lokaler Standardabweichung und (b) binarisierte Version	109
4.19 Ground Truth für "Grove" Sequenz aufgeteilt in (a) horizontale und (b) vertikale Komponenten	110
4.20 "Block Matching"-Ergebnisse, links: horizontale Komponente, rechts: vertikale Komponente. Oben: vollständige Suche; Mitte: "Adaptive Rood Pattern"-Suche; unten: Korrelationsbasierte Suche	111
4.21 "Optical Flow"-Ergebnisse, links: horizontale Komponente, rechts: vertikale Komponente. Oben: Schätzverfahren nach Horn-Schunck; Mitte: Schätzverfahren nach Lucas-Kanade; unten: Schätzverfahren nach Farnebäck	112
4.22 Geschwindigkeit von BM-Algorithmen im Vergleich	114
4.23 Geschwindigkeit von OF-Schätzverfahren im Vergleich	114
4.24 IR Beispieldsequenz (a) originaler Einzelframe, (b) Frame mit simulierter Turbulenz	116
4.25 Beispiel für OF-Schätzung nach Horn-Schunck bei simulierter Turbulenz	117
4.26 Beispiel für OF-Schätzung nach Horn-Schunck, Ausschnittsvergrößerung. Oben: Kopfdetail, unten: Fußdetail	117

5.1	Grundlegender Ablauf eines Entfaltungsalgorithmus	127
5.2	Testsequenzen (v.l.n.r.) mit leichter, mittlerer und starker atmosphärischer Turbulenz; oben: extrem kurze Integrationszeit (Seq. 1 u. 3: <0,1 ms, Seq. 5: 0,045 ms), unten: 1 ms Integrationszeit.	133
5.3	Beispielergebnisse für Seq. 1 (grün markiert) u. Seq. 2 (gelb). 1.+2. Reihe (v.l.n.r.): temp. Median von 100 Frames, Entfaltungsergebnisse für IBD, LRD und IWF; unten: Ergebnisse für PCA-basierte Entfaltung (SO- und MO-Version) jeweils für alle vier HK (1 + 2 + 3 + 4).	136
5.4	Beispielergebnisse für Seq. 3 (grün markiert) u. Seq. 4 (gelb). 1.+2. Reihe (v.l.n.r.): temp. Median von 100 Frames, Entfaltungsergebnisse für IBD, LRD und IWF; unten: Ergebnisse für PCA-basierte Entfaltung (nur SO-Version) für verschiedene HK (1 + 4), (2 + 3), (1 + 2 + 3 + 4).	137
5.5	Beispielergebnisse für Seq. 5 (grün markiert) u. Seq. 6 (gelb). 1.+2. Reihe (v.l.n.r.): temp. Median von 100 Frames, Entfaltungsergebnisse für IBD, LRD und IWF; unten: Ergebnisse für PCA-basierte Entfaltung (nur SO-Version) für verschiedene HK (1), (2), (1 + 2 + 3 + 4).	138
5.6	Standardabweichung der Testsequenzen (v.l.n.r.) mit leichter, mittlerer und starker atmosphärischer Turbulenz; oben: extrem kurze Belichtung (Seq. 1 u. 3: <0,1 ms, Seq. 5: 0,045 ms), unten: 1 ms Belichtung.	139
5.7	Beispielergebnisse für Seq. 7, Teil 1: IBD, LRD u. IWF. Oben (v.l.n.r.): Einzelframe, Mittelwert u. Median (je 100 Fr.), MW (1000 Fr.); Mitte: IBD- u. LRD-Ergebnisse jeweils für MW u. für Med. (je 100 Fr.); unten (v.l.n.r.): STD σ (1000 Fr.), IWF-Ergebnisse für MW u. Med. (100 Fr.), Ergebnis für PCA (SO) für alle vier HK (1 + 2 + 3 + 4).	140
5.8	Beispielergebnisse für Seq. 7, Teil 2: Entfaltung mit PCA. 1.+2. Reihe: SO-Version; 1. Reihe: Ergebnisse für jede der 4 HK für MW (100 Fr.); 2. Reihe: Ergebnisse für 1. HK u. alle 4 HK für Med. (20 Fr. u. 10 Fr.). 3.+4. Reihe: MO-Version; 3. Reihe: Ergebnisse für 1. HK u. alle 4 HK für Med. (20 Fr. u. 10 Fr.); 4. Reihe: Ergebnisse für HK (1), (4), (3 + 4) u. alle 4 HK.	141

6.1	Links: Referenzziel am Standort; rechts: Beispielbild aus der Testsequenz mit Abmessungen.	154
6.2	Links: Tagesgang von C_n^2 am 18. Juli 2001; rechts: Maße des Referenzziels.	155
6.3	Oben: bester Frame der "NATO / Mannequin"-Sequenz; unten: schlechtester Frame.	157
6.4	Links: bester Frame der "Antenne"-Sequenz; rechts: schlechtester Frame.	158
6.5	Beispielframe der "Stadium Lamps"-Sequenz	159
6.6	"Full Width Half Maximum" einer Gauß-Glocke.	161
6.7	Beispiel einer theoretischen diffraktionslimitierten PSF. Links: "Airy"-Beugungsmuster für $\lambda = 4 \cdot 10^{-6}$, $D = 20$ cm, IFOV= 10^{-6} , $L = 20$ km; Mitte: Quadratwurzel des Airy-Patterns; rechts: Querschnittsvergleich (Intensitäten auf 1 normiert)	162
6.8	Beugung an einer kreisförmigen Blende. Links: ohne Linse; rechts mit Linse	163
6.9	Schätzwerte für r_0 bei ansteigender Framezahl	168
6.10	Lokale Standardabweichung mittels Blockverarbeitung und verschiedene Blockgrößen (v.l.n.r.): 4×4 px, 8×8 px, 12×12 px, 16×16 px	170
6.11	Vergleich von Mittelwert (links) und Median (rechts) zu Abb. 6.10 mit jeweils korrespondierendem Schwellwertbild.	170
6.12	Standardabweichung für verschiedene maximale Blockgrößen (v.l.n.r.): 8 px, 16 px, 32 px, 64 px. Oben: Falschfarbendarstellung; unten: korrespondierende Homogenitätskarten, Mittelwert als Schwellwert.	171
6.13	Lakunarität als Homogenitätsmaß. Links: Falschfarbendarstellung; Mitte: Grauwertbild; rechts: binarisiertes Bild.	174
6.14	Lakunarität bei verschiedenen maximalen Boxgrößen (v.l.n.r.): 1 px, 4 px, 8 px, 16 px. Oben: Falschfarbendarstellung; unten: korrespondierende Homogenitätskarten (Mittelwert als Schwellwert).	174
6.15	Anwendung auf Bilddaten mit realer Turbulenz. Oben: Mittelwert von 100 Frames der "NATO/Mannequin"-Testsequenz; Mitte: lokale Lakunarität in Falschfarbendarstellung; unten: resultierende binäre Homogenitätskarte.	175

6.16 Kantenbilder für die “NATO/Mannequin”-Testsequenz. Oben: Kantenbild des Mittelwerts von 100 Frames; unten: Kantenbild eines Einzelbildes (5. Frame)	176
6.17 Bewegungsinhalt der “China Lake”-Sequenz. Links: durchschnittliche Differenz zwischen den Bildern als Bewegungskarte; rechts: durchschnittlicher Betrag der Bewegungsvektoren.	179
6.18 Beispiel für Bildvorverarbeitung bei Turbulenz. Links: originales Einzelbild aus der “China Lake”-Sequenz (300 fps); rechts: Ergebnis einer Kontrastverbesserung mittels CLAHE.	180
6.19 Vergleich von Mittelwert (links), Median (Mitte) und Modalbild (rechts), jeweils für 250 Frames der Sequenz	182
6.20 Demonstration des gerichteten Stapeleffekts. Links: Bildstapel auf die Bewegung des Busses ausgerichtet, Stapeltiefe: 6 Frames; rechts: Bildstapel für horizontale Bewegung, Stapeltiefe: 8 Frames.	186
6.21 Bildausschnitt zur Veranschaulichung des Effekts der lokalen Bildstapelung; Links: Bildstapel auf die Bewegung des Busses ausgerichtet; Mitte: Einzelbild; rechts: normaler Durchschnitt von 6 Bildern.	186
6.22 Prinzip der lokalen Bildstapelung	187
6.23 Akzeptabler Bereich der Vektorwinkel (grau) für gerichtete Bewegung und resultierende Hauptrichtung (roter Pfeil), abweichende Vektoren sind gestrichelt dargestellt.	188
6.24 Lokale Bildverschiebungen (in Pixeln) an markierter Position im linken Bild. Mitte: während der Sequenz auftretende Verschiebungsvektoren; rechts: Häufigkeitsverteilung der Verschiebungen.	189
6.25 Vergleich lokaler und normaler Bildstapelung. Links: Mittelwert aus 8 vorverarbeiteten Bildern (d. h. Mittelwert aus je 5 Frames) bei lokaler Bildstapelung mit Blockgröße 32, d. h. entspricht dem Mittelwert aus 40 Bildern; rechts: normaler Mittelwert aus jeweils 20 Bildern.	190

6.26 Oben: Original (links) u. Mittelwert 100 Frames mit globaler Registrierung (rechts); Mitte: Turbulenzkorrektur mit IBD (links) u. mit mehrstufiger WIBD (rechts) im Vergleich; unten: Sobel-gefiltertes Mittelwertbild als Gewichtungsfunktion u. Sobel-gefiltertes Resultat der WIBD (rechts).	193
6.27 Schraffur-Artefakte infolge mehrstufiger Entfaltung mit unterschiedlichen Filtergrößen. Links: Beispielbild; rechts: Ausschnittsvergrößerung, zur Verdeutlichung mit Schärfungsfilter und Kontrastverstärkung.	194
6.28 Beispiel für Turbulenzkorrektur. Links: Originalaufnahme, Objektentfernung ca. 27 km, bei schwacher Turbulenz; rechts: Korrekturergebnis, mehrstufige blinde Entfaltung, aus zwei registrierten Einzelbildern.	195
6.29 Turbulenzkorrektur statischer Objekte am Beispiel der "Stadium Lamps"-Sequenz. Links: unverändertes Einzelbild, Objektentfernung ca. 2-3 km, moderate Turbulenz; rechts: Deblurring des global registrierten Mittelwerts (100 Frames) mittels mehrstufiger blinder Entfaltung zzgl. minimaler CLAHE-Kontrastverstärkung.	196
6.30 Turbulenzkorrektur statischer Objekte am Beispiel der "NATO / Mannequin"-Sequenz. Oben: unverändertes Einzelbild, Objektentfernung ca. 7-8 km, moderate Turbulenz; unten: Deblurring mittels mehrstufiger blinder Entfaltung.	197
6.31 Beispiel für Turbulenzkorrektur statischer Objekte. Links: unverändertes Einzelbild, Objektentfernung ca. 7 km, moderate Turbulenz; Mitte: Mittelwert der besten 250 Frames (von 500) nach globaler Registrierung; rechts: Deblurring mittels mehrstufiger blinder Entfaltung.	198
6.32 Beispiel für MCA mit lokaler Bewegungskompensation. Links: unverändertes Einzelbild, Entfernung ca. 1 km, starke Turbulenz; Mitte: MCA mit BM, d. h. Mittelwert von jeweils 100 global u. lokal registrierten Frames; rechts: MCA mit BM und abschließendem WIBD-Deblurring.	199

6.33 Beispiel für LIS-Turbulenzkorrektur. Links: WIBD-Ergebnis für den Mittelwert von 150 Frames (10 Iterationen); Mitte: LIS und WIBD (Blockgröße 32, Stapeltiefe 8); rechts: LIS und WIBD mit separater Korrektur des Hintergrunds.	199
6.34 Experimenteller Aufbau der Messungen bei “VOLVO Aero” entlang des Abgasstrahls eines Jet-Triebwerks (Maßstab 1 : 3)	201
6.35 Beispiel für aktive Beleuchtung bei extremer Turbulenz. Links: bei ausgeschaltetem Triebwerk; Mitte: Triebwerk vor kurzem eingeschaltet; rechts: nach längerer Betriebsdauer des Triebwerks	201
6.36 Beispiel für Turbulenzkorrektur im Fall aktiver Beleuchtung. Links: unverändertes Einzelbild, starke Turbulenz in der Nähe eines laufenden Jet-Triebwerks; rechts: PCA-basierte blinde Entfaltung eines gleitenden Mittelwerts (40 Frames)	201
6.37 CFA mit Bayer-Pattern. Links: Die Farbfilter auf dem Farbfilterarray des Bayer-Sensors; rechts: Querschnitte der Farbfilter.	203
6.38 Simulation eines Bayer-CFA. Links: hochauflösten Original-Farbbild “Peppers” (Quelle: MATLAB), das weiße Rechteck markiert den im folgenden verwendeten Bildausschnitt; Mitte u. rechts: Bayer-CFA-Simulation mit “RGGB”-Muster in Graustufen-(Mitte) und entsprechender Farbdarstellung (rechts).	204
6.39 Vergleich von Interpolationsmethoden für CFA. V. l. n. r.: Ausschnitt des hochauflösten Originalbildes; skaliertes Ergebnis des “naiven Ansatzes”; bilineare Interpolation; Demosaicing gemäß [Mal04].	205
6.40 Beispiel für Bildvorverarbeitung in Farbbilddaten. Linke Spalte (v.o.n.u.): Originalfarbbild (Entfernung ca. 23 km), Resultat der Bildvorverarbeitungskette (Farbkontrastanhebung und Einzelbild-Deblurring), zusätzliche Rauschreduktion; rechte Spalte: korrespondierende Kantenbilder.	207
6.41 PSF-Simulationen im VIS-Spektrum mit äußeren Skalenlängen $L_0 = 1 \text{ m}$, $L_0 = 1 \text{ m}$ für ausgewählte Turbulenzstärken C_n^2 in den Größenordnungen zwischen 10^{-14} und 10^{-12} (in $\text{m}^{-2/3}$) im Vergleich mit dem jeweiligen Mittelwert von 20 PSFs (Quelle: [Hue12b]).	212

6.42	Turbulenzsimulationen für die Wellenlänge $\lambda = 10 \mu\text{m}$ (im IR) bei äußerer Skalenlänge $L_0 = 1 \text{ m}$ und mit Aperturdurchmesser $D = 9 \text{ cm}$. Oben: originales Farbbild (links) und zu gehöriges Grauwertbild (rechts); Mitte: Turbulenzstärke $C_n^2 = 10^{-14} \text{ m}^{-2/3}$, unten: $C_n^2 = 10^{-13} \text{ m}^{-2/3}$; links: Entfernung $L = 5 \text{ km}$, rechts: $L = 10 \text{ km}$ (Foto u. Simulation: S. Gładysz).	213
6.43	Beispielhafte Skizze einer Tiefenkarte. Links: Originalbild; rechts: Tiefenkarte mit 10 Tiefenebenen (Farbwahl willkürlich, unabhängig vom Entfernungswert).	214
6.44	Erster (links) und letzter Frame (rechts) der synthetischen GT-Sequenz mit Fahrzeugen, wobei die jeweilige Bewegungsrichtung gelb bzw. grün markiert ist.	215
6.45	Simulationsbeispiel für $C_n^2 = 5 \cdot 10^{-13} \text{ m}^{-2/3}$, $L_0 = 10 \text{ m}$, mit additivem Rauschen. Links: Kurzzeitaufnahme, d. h. Einzelframe mit Poisson- und Gauß-verteiltem Rauschen; rechts: Langzeitaufnahme, d. h. Mittelwert von 8 gefilterten Frames; unten: korrespondierende Detailansichten.	216
6.46	Links: Beispielframe der Turbulenzsimulation mit Poisson-Rauschen; rechts: Korrekturergebnis bei globaler Bildregistrierung und WIBD-Deblurring.	217
6.47	Turbulenzsimulation (mit $C_n^2 = 10^{-13} \text{ m}^{-2/3}$ und $L_0 = 10 \text{ m}$) und beispielhafte Korrekturresultate verschiedener Verfahren im Vergleich (Ausschnittsvergrößerung). Links: nicht-blinde Entfaltungsmethoden (exakte PSF); rechts: blinde Entfaltung.	218
6.48	Kantenbilder zu Abb. 6.47 zur besseren Erkennbarkeit der Unterschiede in den Korrekturergebnissen.	219
7.1	Links: MW aller 500 Einzelbilder der Testsequenz, rechts: MW der besten 250 Frames (gemäß Blur-Metrik)	227
7.2	Beispiele für TOD-Testmuster mit den vier möglichen Orientierungen	228
7.3	Übersicht über die vier Hauptaspekte, die im vorgeschlagenen Bewertungsmodell zu berücksichtigen sind.	234
7.4	Typisches Anwendungsszenario in der Fernerkundung	236

Tabellenverzeichnis

5.1	Übersicht über Typen von Entfaltungsalgorithmen	121
5.2	Eckdaten der Testsequenzen, zeitlich geordnet	135
6.1	Gerätespezifikationen de RETICON MD4256C Kamera	153
6.2	Eckdaten der Dayton-Sequenzen.	156
7.1	Beispieldtabelle für eine merkmalsorientierte Bewertung	229
7.2	Beispieldtabelle für eine merkmalsorientierte Profilierung typischer Anwendungsgebiete für Turbulenzkorrekturverfahren. (*: mit Nachführreinrichtung)	238
7.3	Beispieldtabelle für eine prioritätsorientierte Profilierung typischer Anwendungen.	239
7.4	Beispieldtabelle für eine merkmalsorientierte Evaluierung verschiedener Turbulenzkorrekturalgorithmen. Linke Seite: eigene Verfahren, rechte Seite: * CARES-Algorithmus [Pot14], sowie **SI u. AO als generelle Ansätze.	240

Abkürzungsverzeichnis

Abkürzungen

ABL	“Atmospheric Boundary Layer”: atmosphärische Grenzschicht nahe der Erdoberfläche (Peplosphäre)
AO	“Adaptive Optics”: Adaptive Optik
ARP	“Adaptive Rood Patterns”: spezielle BM-Suchmuster
ATCOM	Software der Firma EM Photonics zur Kompensation atmosphärischer Effekte
ATR	“Automatic Target Recognition”: Atomatische Zielerkennung
BM	“Block Matching”: Algorithmus zur Codierung von Bewegung in Videodaten
BV	Bewegungsvektor
CARES	“Cascading Auto-Regressive Exponential Smoothing”: spezielle Filter zur Turbulenzreduktion
CFA	“Color Filter Array”: Farbfilter auf einem Kamerasensor
CIE LAB	3-D CIE-Farbraum aller physiologisch wahrnehmbarer Farben
CIE XYZ	Wahrnehmungsbasiertes CIE-Normvalenzsystem

CLAHE	“Contrast Limited Adaptive Histogram Equalization”: Algorithmus zur adaptiven Kontrastverbesserung in Bildern
CMY	“Cyan Magenta Yellow” Farbraum
CNN	“Convolutional Neural Network”: künstliches faltendes neuronales Netz
CUDA	“Compute Unified Device Architecture”: proprietäre Programmietechnik der NVIDIA Corporation zur Ausführung auf dem Grafikprozessor
CW-SSIM	“Complex Wavelet”-SSIM
DGL	Differentialgleichung
DSR	“Dynamic Superresolution”: spezielles Bildverbesserungsverfahren des TNO
EM	Elektromagnetisch
EO	Elektrooptisch
FOV	“Field Of View”: Sichtfeld einer Optik
FPGA	“Field Programmable Gate Array”: programmierbarer integrierter Schaltkreis
FSO	“Free-Space Optical communication”: optische Freiraumkommunikation
FT	“Fourier Transform”: Fourier Transformierte
FWHM	“Full Width Half Maximum”: Halbwertsbreite einer Punktquelle
GAN	“Generative Adversarial Networks”
GMC	“Global Motion Compensation”: Globale Bewegungskompensation

GPU	“Graphics Processing Unit”: Grafikprozessor
GT	“Ground Truth”: Grundwahrheit
HK	Hauptkomponenten
HSV	“Hue Saturation Value” Farbraum
IBD	“Iterative Blind Deconvolution”: blinde Version der LRD-Entfaltungsmethode
IFOV	“Instantaneous Field Of View”: Sichtfeld eines Detektorelements
IQM	“Image Quality Metrics”: Bildqualitätsmetrik
IR	Infrarot
IWF	Inverser Wiener Filter
KNN	Künstliches Neuronales Netz
LI	“Lucky Imaging”: Turbulenzkorrekturmethode
LIS	“Local Image Stacking”: Lokale Bildstapelung
LMC	“Local Motion Compensation”: Lokale Bewegungskompensation
LRD	“Lucy-Richardson Deconvolution”: Entfaltungsmethode gemäß Lucy bzw. Richardson
MAE	“Mean Absolute Error”: der mittlere absolute Fehler
MC	“Motion Compensation”: Bewegungskompensation
MCA	“Motion Compensated Averaging”: Bewegungskompensierte Bildstapelung
MCMC	“Markov Chain Monte Carlo”: Markov-Ketten-Monte-Carlo-Verfahren

MO	“Multiple Observations”: Variante der PCA-basierten Entfaltung für Bilderreihen
MRT	MagnetResonanzTomographie
MSE	“Mean Square Error”: der mittlere quadratische Fehler
MTF	“Modulation Transfer Function”: Kontrastübertragungsfunktion
MV	“Motion Vector”: Bewegungsvektor
OF	“Optical Flow”: ’Optischer Fluss
OTF	“Optical Transfer Function”: optische Übertragungsfunktion
PC	“Personal Computer”
PCA	“Principal Component Analysis”: Hauptkomponentenanalyse
PDF	“Probability Density Function”: Wahrscheinlichkeitsdichtefunktion
PSF	“Point Spread Function”: Punktabbildungsfunktion
PSNR	“Peak-Signal-to-Noise Ratio”: maximales Signal zu Rausch Verhältnis
RGB	“Red Green Blue” Farbraum
RMSE	“Root Mean Square Error”: die Wurzel aus dem mittleren quadratischen Fehler
ROI	“Region Of Interest”: spezieller Auswahlbereich
SI	“Speckle Imaging” bzw. “Speckle Interferometry”: Speckle-Interferometrie
SNR	“Signal-to-Noise Ratio”: Signal zu Rausch Verhältnis
SO	“Single Observations”: Variante der PCA-basierten Entfaltung für Einzelbilder

SPGD	“Stochastic Parallel Gradient Descent”: Optimierungsalgorithmus
SSIM	“Structural SIMilarity Index”
STD	“STandard Deviation”: Standardabweichung
TOD	“Triangle Orientation Discrimination”: Test zur Leistungsbewertung von EO-Systemen
TurKom	“TurbulenzKompensation”: softwarebasierte modulare Turbulenzkorrektur
TS	TurbulenzSimulation
UWH	“Unsupervised Wiener-Hunt”: spezielle Wiener-Hunt Entfaltungsmethode
VIS	Visuelles Spektrum
WIBD	“Weighted Iterative Blind Deconvolution”: IBD mit stärkerer Gewichtung der Kanten

Einrichtungen

CIE	“Commission internationale de l'éclairage”: Internationale Beleuchtungskommission
DRDC	“Defence Research and Development Canada”: staatliche Forschungsbehörde des kanadischen Verteidigungsministeriums
EMVA	“European Machine Vision Association”
FGAN	ForschungsGesellschaft für Angewandte Naturwissenschaften
FhG	Fraunhofer Gesellschaft
FOM	Forschungsinstitut für Optronik und Mustererkennung
IOSB	Institut für Optronik, Systemtechnik und Bildauswertung

KIS	Leibniz-Institut für Sonnenphysik
LLNL	“Lawrence Livermore National Laboratory”: US-amerikanische Forschungseinrichtung
NATO	“North Atlantic Treaty Organization”: Organisation des Nordatlantikvertrags
RTG	“Research Task Group”: NATO Forschungsgruppe
RTO	“Research and Technology Organization”: NATO Organisation
SET	“Sensors Electronics Technology”: NATO Panel
TNO	“Nederlandse Organisatie voor toegepast-natuurwetenschappelijk onderzoek”: Niederländische Organisation für Angewandte Naturwissenschaftliche Forschung
UNSW	“University of New South Wales”: Universität in Canberra, Australien
WTD	Wehrtechnische Dienststelle

Danksagung

Mein ausdrücklicher Dank gilt meinem Doktorvater Herrn Prof. Dr.-Ing. Jürgen Beyerer, Institutsleiter des Fraunhofer IOSB, für sein Vertrauen in meine Arbeit und für die wissenschaftliche Förderung dieser Arbeit. Bei Herrn Prof. Dr. Oskar von der Lühe, stellvertretender Direktor des Leibniz-Instituts für Sonnenphysik (KIS), bedanke ich mich ebenfalls für seine engagierte Unterstützung und für die freundliche Übernahme des Koreferats.

Die vorliegende Dissertation entstand begleitend zu meiner Tätigkeit als wissenschaftliche Mitarbeiterin am Fraunhofer-Institut für Optronik, Systemtechnik und Bildauswertung (IOSB). Für ihr großes Vertrauen und für die zur Anfertigung dieser Arbeit gewährten Freiräume gilt mein besonderer Dank Frau Dr. rer. nat. Karin Stein, außerdem bedanke ich mich hierfür nochmals bei Herrn Prof. Dr.-Ing. Jürgen Beyerer in seiner Funktion als Institutsleiter.

Allen Freunden und Kollegen, die zum Gelingen dieser Arbeit beigetragen haben, danke ich ganz herzlich für ihre Hilfsbereitschaft und ihre Unterstützung. Für die wertvollen fachlichen Diskussionen und ihre Anregungen danke ich besonders den Herren Alexey Pak, Ph.D., Assoc. Prof. Andrew Lambert, Ph.D. und Szymon Gladysz, Ph.D. Von großer Bedeutung war für mich auch die Unterstützung von Herrn Dr. rer. nat. Alexander Schwarz, insbesondere durch Korrekturlesen, sowie der regelmäßige Austausch mit meinen Zimmerkollegen und mit anderen Doktoranden.

Nicht zuletzt gilt mein größter Dank meiner Familie für ihren Rückhalt und ihre Unterstützung in allen Lebenslagen. Ganz besonders bedanke ich mich

bei meiner Mutter für ihren Glauben an mich und ihre feste Überzeugung, dass ich alles erreichen kann, was ich mir vornehme. "Last but not least" bedanke ich mich auch bei meinem Ehemann Marcus für seine Rücksichtnahme und Geduld während dieser Zeit.

Claudia Hübner

»The greatest enemy of knowledge is not ignorance, it is the illusion of knowledge.«

»Der größte Feind des Wissens ist nicht Unwissenheit, es ist die Illusion von Wissen.«

Stephen Hawking

