

Bildbasierte Weichgeweberegistrierung in der Laparoskopie

Zur Erlangung des akademischen Grades eines
Doktors der Ingenieurwissenschaften

bei der Fakultät für Informatik
des Karlsruher Instituts für Technologie (KIT)

genehmigte
DISSERTATION

von

Daniel Reichard
aus Lindenberg im Allgäu

Datum der mündlichen Prüfung:	29. November 2017
Erster Gutachter:	Prof. Dr.-Ing. Rüdiger Dillmann
Zweiter Gutachter:	Prof. Dr.-Ing. Stefanie Speidel
Dritter Gutachter:	Prof. Dr. med. Dr. h.c. Uwe Spetzger



Dieses Werk ist lizenziert unter einer Creative Commons Namensnennung -
Weitergabe unter gleichen Bedingungen 4.0 International Lizenz (CC BY-SA 4.0):
<https://creativecommons.org/licenses/by-sa/4.0/deed.de>

Danksagung

Die Endlosigkeit des wissenschaftlichen Ringens sorgt unablässig dafür, daß dem forschenden Menscheng Geist seine beiden edelsten Antriebe erhalten bleiben und immer wieder von neuem angefacht werden: Die Begeisterung und die Ehrfurcht.

-Max Planck

Diese Arbeit entstand im Rahmen meiner Tätigkeit als wissenschaftlicher Mitarbeiter am Institut für Anthropomatik und Robotik am Karlsruher Institut für Technologie (KIT). Meine Promotion wurde durch die Unterstützung der Tschira Stiftung ermöglicht, wofür ich mich hiermit bedanken möchte. Meine Arbeit wurde außerdem durch die Zusammenarbeit mit dem Sonderforschungsbereich „Cognition-guided Surgery“ geprägt. Während dieser Zeit wurde ich von vielen Personen unterstützt, denen ich meinen Dank aussprechen möchte.

Zuallererst möchte ich mich bei meinem Doktorvater Prof. Rüdiger Dillmann bedanken, der es mir ermöglicht hat, an seinem Lehrstuhl zu promovieren, und mich und meine Arbeit immer vollständig unterstützt hat. Weiterhin möchte ich mich bei Prof. Uwe Spetzger und meiner ehemaligen Gruppenleiterin Prof. Stefanie Speidel für die Übernahme des Korreferats sowie Prof. Heinz Wörn und Jun. Prof. Boris Neubert für die Mitwirkung als Prüfer herzlich bedanken.

Ein besonderer Dank gebührt natürlich Steffi, die mir zusammen mit Sebastian zunächst ermöglicht hat meine Diplomarbeit am Lehrstuhl durchzuführen und mich später wieder aus der Industrie gelockt hat, um meine Promotion in Angriff zu nehmen. Ich blicke mit viel Freude an meine Zeit als Doktorand zurück und bin sehr dankbar, dass Sie mir diese Erfahrungen ermöglicht hat. Zu diesen schönen Erinnerungen haben auch meine engagierten Kollegen der „Chirurgischen Assistenzsysteme“ Gruppe maßgeblich beigetragen. Auch nach meiner Diplomarbeit konnte ich immer auf die Programmiererfahrung von Sebastian zählen, wenn ich in MediAssist mal nicht weiter wusste. Stefan führte mich behutsam und geduldig in die Welt der Kontinuumsmechanik ein. Yoo-Jin, Darko und Michael möchte ich für interessante Diskussionen und unterhaltsame Kaffeepausen danken.

Auch den restlichen Kollegen vom Lehrstuhl H²T (Prof. Tamim Asfour) möchte ich für das angenehme und anregende Arbeitsklima im 3. Stock der alten Kinderklinik danken. Ohne Christian, Ömer, Isabel, Peter und alle anderen wären die

Mittagspausen nur halb so interessant gewesen. Besonders hervorheben möchte ich unser unermüdliches Sekretariat. Christine, Isa, Diana und Graziella waren immer zur Stelle, wenn wir Doktoranden uns einmal wieder im Dschungel der Univerwaltung verirrt.

Neben den Kollegen vor Ort wurde ich auch von zahlreichen Kollegen aus Heidelberg unterstützt. Vor allem Beat, Hannes, Martin und Benni möchte ich für Ihre unersetzlichen medizinischen Kompetenzen, Ideen und Ratschlägen danken. Bei den oft langen CT-Experimenten fanden Sie trotz des stressigen Arztalltags immer Zeit für uns und bewiesen was interdisziplinäre Forschung leisten kann. Daneben möchte ich auch unseren Kollegen rund um Lea Maier-Hein vom DKFZ für die tolle Zusammenarbeit danken.

Mein größter Dank geht an die Studenten Dominik Häntsch, Markus Gern, Martin Weiss, Oliver Neumann, Tobias Meißner, Leonard Plotkin, Olivier Boder, Alexander Müller, die im Rahmen von Bachelor-, Master- und Diplomarbeiten zur Realisierung dieser Arbeit beitrugen. Insbesondere möchte ich mich bei Dominik Häntsch bedanken, der mich als Hiwi und Programmierexperte bei vielen Projekten tatkräftig unterstützte.

Für den wichtigen Ausgleich im Badminton möchte ich mich bei Martin, Tobi und Vencia bedanken. Auch für die entspannenden Kartenrunden mit Vencia, Marvin, Raphael und Dominik möchte ich meinen Dank aussprechen.

Zuletzt möchte ich natürlich meiner Frau Sonja, meinen Eltern Marlies und Andreas und meinen Brüdern Johannes und Fabian dafür danken, dass sie mein Leben ermöglicht und bereichert haben. Ich widme Ihnen deshalb auch diese Arbeit.

Zusammenfassung

Die minimal-invasive Chirurgie bietet viele Vorteile für den Patienten. Durch die Reduzierung des Operationstraumas und der damit beschleunigten Rekonvaleszenz des Patienten können zudem die Zeit der stationären Behandlung und damit auch die Kosten für das Gesundheitssystem reduziert werden. Dem gegenüber steht die höhere Belastung der Chirurgen während der Operation. Erst nach jahrelangem Training sind Ärzte in der Lage, die Herausforderungen dieser speziellen Operationstechnik zu meistern. Um Chirurgen bei dieser schwierigen Aufgabe zu unterstützen, wurden in den letzten Jahren durch die Verfügbarkeit von neuen Technologien verstärkt computergestützte Assistenzsysteme entwickelt.

Während beispielsweise in der Neurochirurgie schon kommerzielle Assistenzsysteme existieren, gibt es in der Laparoskopie ein großes ungelöstes Problem: die Weichgeweberegistrierung. Um die detaillierten Organmodelle aus präoperativen Planungsdaten (bspw. aus der Computertomografie) während der Operation nutzen zu können, müssen diese an die Position, Ausrichtung und Form des intraoperativen Organs angeglichen werden. Diese nicht-rigide Anpassung des Modells wird als Weichgeweberegistrierung bezeichnet. Dabei werden die Verschiebungen und Deformationen der Organe des Patienten sowohl durch zuvor verursachte Änderungen, wie der Lagerung des Patienten oder dem Anlegen des Pneumoperitoneums (Füllen und Aufblähen des Bauchraums mit CO₂-Gas), als auch durch dynamische Ereignisse während der Operation, wie der Atmung des Patienten oder Manipulationen der chirurgischen Instrumente, verursacht. Im Rahmen dieser Arbeit wurden die verschiedenen Bestandteile und Schritte für die laparoskopischen Weichgeweberegistrierung untersucht.

Zur Erzeugung von intraoperativen 3D-Modellen wurde ein auf *Convolutional* Neuronalen Netzen basiertes Stereorekonstruktionsverfahren entwickelt, welches Disparitäten endoskopischer Bilddaten durch das Training mit domänenspezifischen Trainingsdaten bestimmt. Da für endoskopische Bilddaten nur sehr schwer eine Referenz für die Tiefendaten bestimmt werden kann, wurde ein mehrstufiger Trainingsprozess entwickelt. Aufgrund der speziellen Endoskop-Optik und den Eigenheiten dieser Bildgebung, bspw. Glanzlichter und texturarme, kantenfreie Oberflächen, sind endoskopische Trainingsdaten jedoch unverzichtbar, um bestmögliche Resultate zu erzielen. Hierzu wurden einerseits virtuelle Stereobilder von endoskopischen Simulationen erzeugt, andererseits wurden vorhandene reale Aufnahmen genutzt, um daraus durch die Erkennung von Landmarken,

vollautomatisch dünnbesetzte Referenzkarten zu erzeugen. Das Verfahren wurde mit einem öffentlichen Datensatz evaluiert und konnte eine hohe Genauigkeit bei geringer Laufzeit demonstrieren.

Für den eigentlichen Registrierungsprozess wurde ein zweistufiges Verfahren entwickelt. Im ersten Schritt wird zu Beginn der Operation eine initiale Weichgeweberegistrierung durchgeführt. Da die Verschiebungen, Rotationen und Deformationen zwischen präoperativer Aufnahme und Operation sehr groß sein können, ist hier ein möglichst umfangreiches intraoperatives Modell des betrachteten Organs wünschenswert. Mit dem in dieser Arbeit entwickelten Mosaikverfahren kann ein globales Oberflächenmodell aus mehreren Rekonstruktionsfragmenten der einzelnen Aufnahmen erzeugt werden. Die Evaluation zeigt eine starke Verringerung des Registrierungsfehlers, im Vergleich zur Nutzung von einzelnen Oberflächenfragmenten.

Um dynamische Deformationen während der Operation auf das präoperative Modell zu übertragen, wurde ein Verfahren zur dynamischen Registrierung entwickelt. Dabei werden die präoperativen Daten durch ein biomechanisches Modell repräsentiert. Dieses Modell wird durch die Projektion in das aktuelle Kamerabild mit den Punkten der intraoperativen 3D-Rekonstruktion verknüpft. Diese Verknüpfungen dienen anschließend als Randbedingungen für eine FEM-Simulation, die das biomechanische Modell in jedem Zeitschritt an das intraoperative Organ anpasst. In einer *in silico* Evaluation und einem ersten Tierversuch konnte das Verfahren vielversprechende Ergebnisse vorweisen.

Neben den eigentlichen Verfahren zur Weichgeweberegistrierung ist auch deren Evaluation von Bedeutung. Hier zeigt sich, dass künstliche Organmodelle ein wichtiges Bindeglied zwischen Simulationen und Tierversuchen darstellen. Für die Evaluation von Registrierungsalgorithmen sind vor allem die mechanischen Eigenschaften des Organmodells von Bedeutung. Der Guss von Silikonorganen ist einfach und kostengünstig, hat aufgrund des verwendeten Silikons allerdings den Nachteil, dass die Modelle deutlich härter als vergleichbares Weichgewebe sind. Um ein weiches Organmodell zu erstellen und gleichzeitig die Vorteile des Silikongusses beizubehalten, wurde in dieser Arbeit ein spezielles 3D-Druckverfahren erforscht. Dabei wird ein Negativgussmodell des Organs aus wasserlöslichem Material mit einem 3D-Drucker hergestellt. Die Besonderheit ist eine Gitterstruktur, die sich durch das ganze Gussmodell zieht. Nach dem Einfüllen und Aushärten des Silikons kann die Gussform mitsamt der innen liegenden Gitterstruktur aufgelöst werden. Dadurch entstehen überall im Silikonmodell kleine Hohlräume, welche die Struktur des Modells schwächen. In dem die Gitterstruktur vor dem Druckprozess angepasst wird kann der Härtegrad des späteren Modells in einem Rahmen von 30-100% des Silikon-Vollmodells eingestellt werden. Mechanische Experimente konnten die zuvor in der Simulation berechneten Kennwerte bestätigen.

Inhaltsverzeichnis

1	Einleitung	1
1.1	Fragestellung	2
1.2	Zielsetzung und Beitrag	5
1.3	Aufbau der Arbeit	6
2	Minimal-invasive Chirurgie	7
2.1	Vor- und Nachteile der minimal-invasiven Chirurgie	10
2.2	Laparoskopische Werkzeuge	11
2.2.1	Endoskop	11
2.2.2	Stereoendoskop	13
2.2.3	Instrumente	14
2.2.4	Robotiksysteme	15
2.3	Computer-assistierte Chirurgie	17
2.4	Zusammenfassung	18
3	Stand der Forschung	21
3.1	Intraoperative 3D-Rekonstruktion	21
3.1.1	Aktive Rekonstruktion	22
3.1.2	Passive Rekonstruktion	23
3.2	3D-Modellgenerierung	26
3.3	Registrierung von intra- und präoperativen Modellen	27
3.4	Künstliche Organmodelle	30
3.5	Zusammenfassung	31
4	3D-Rekonstruktion des Operations-Situs	33
4.1	Stereoendoskopie	34
4.1.1	Lochkameramodell	34
4.1.2	Erweitertes Lochkameramodell	34
4.1.3	Optische Linsenverzerrung	36
4.1.4	Kamerakalibrierung	37
4.1.5	Stereo-Triangulation	37
4.1.6	Epipolargeometrie	39
4.1.7	Rektifizierung	40
4.2	Neuronale Netze	41
4.2.1	Perzeptron	41
4.2.2	Mehrlagige neuronale Netze	42
4.2.3	Training	43
4.2.4	Convolutional Neuronale Netze	46

4.3	CNNs für die endoskopische Stereorekonstruktion	50
4.3.1	Methoden	50
4.3.2	Akquirierung von Trainingsdaten	50
4.3.3	Training des Netzes	58
4.3.4	Ergebnisse	63
4.3.5	Zusammenfassung	65
5	Initiale Weichgeweberegistrierung	67
5.1	Bildübergreifende Oberflächen-Rekonstruktion	70
5.1.1	Rekonstruktion und Segmentierung	70
5.1.2	Integration in das TSD-Volumen	72
5.1.3	Kamerapose	74
5.2	Ergebnisse	74
5.2.1	In Silico	76
5.2.2	Leberphantom	78
5.2.3	Ex vivo Schweineleber	83
5.2.4	In vivo Schweineleber	85
5.3	Zusammenfassung	88
6	Dynamische Weichgeweberegistrierung	93
6.1	Methoden	94
6.1.1	Intraoperative Oberflächenrekonstruktion	95
6.1.2	Biomechanisches Model	95
6.1.3	Initiale Registrierung	97
6.1.4	Dynamische Registrierung	97
6.2	Ergebnisse	101
6.2.1	In silico Lebermodell	101
6.2.2	In vivo Schweinemilz	104
6.3	Zusammenfassung	105
7	3D-Druck für realistische Silikon-Organe	107
7.1	Physikalische Eigenschaften der Leber	108
7.2	Zielwerte des Leberphantoms	110
7.3	Wahl eines geeigneten Materials	110
7.4	Wasserlösliche Gussformen	112
7.5	Ergebnisse	115
7.5.1	Zylindrische Testkörper	115
7.5.2	Lebersilikonmodell	119
7.6	Zusammenfassung	120
8	Schlussbetrachtung	123
8.1	Zusammenfassung und Diskussion	123
8.2	Ausblick	125

Anhang	131
A Technische Daten	133
A.1 Datenblätter für 3D-Druck	133
A.2 Detaillierte Messergebnisse der Silikonproben	139

Kapitel 1

Einleitung

Die medizinische Versorgung ruht heutzutage neben der guten Ausbildung des medizinischen Personals auch auf den technischen Errungenschaften der Medizintechnik. Eine der erfolgreichsten technischen Neuerungen der letzten Jahrzehnte ist hierbei die laparoskopische Chirurgie. Bei dieser minimal-invasiven Operationstechnik, die auch als „Schlüsselloch-Chirurgie“ bezeichnet wird, werden die Bauchhöhle und die darin enthaltenen Organe durch kleine Zugänge in der Bauchhaut behandelt. Mit der ersten laparoskopischen Appendektomie¹ im Jahre 1983 von Kurt Semm, der als gelernter Instrumentenbauer auch selbst an der Entwicklung laparoskopischer Instrumente arbeitete, wurde zunächst gegen einigen Widerstand eine neue Ära der Chirurgie eingeleitet (Litynski, 1996). Im selben Jahr benutzte der britische Urologe John E. A. Wickham zum ersten Mal den Begriff der „Minimal-invasiven Chirurgie“. Zwei Jahre danach, im September 1985, führte der Böblinger Chirurg Erich Mühe erstmals eine laparoskopische Cholezystektomie² durch (Schollmeyer & Schollmeyer, 2001). Er nutzte dabei die von Kurt Semm speziell für die Laparoskopie entwickelten Instrumente. Nach nur eineinhalb Jahren konnte Erich Mühe bereits auf 97 erfolgreiche Operationen mit dieser Technik zurückblicken. Seitdem hat sich die Laparoskopie bei vielen Eingriffen als Goldstandard etabliert und ist aus der modernen Chirurgie nicht mehr wegzudenken.

Um den Chirurgen bei diesen anspruchsvollen Eingriffen zu unterstützen, wurde in den letzten Jahrzehnten intraoperative, computergestützte Assistenzsysteme erforscht und zum Einsatz gebracht. Das bekannteste Assistenzsystem in der Laparoskopie ist hierbei sicherlich der da Vinci[®] Telemanipulator der Firma Intuitive Surgical Inc.³. Während diese Systeme eine präzise Führung von Instrumenten erlauben, bedeutet Computer-assistierte Chirurgie aber auch, dass Zielstrukturen (bspw. die Position eines verdeckten Tumors) oder Risikostrukturen (Gefäße oder Nerven, die nicht verletzt werden dürfen) während der Operation angezeigt werden. Mit diesen Informationen können bei minimalem Schaden des gesunden Gewebes, Tumore bestmöglich entfernt werden. Um die Lokalisierung und Visualisierung dieser Strukturen zu ermöglichen, müssen präoperativ

¹Entfernung des Wurmfortsatzes

²Gallenblasenentfernung

³<https://www.intuitivesurgical.com/>

CT- oder MRT-Aufnahmen akquiriert werden. Aus diesen Aufnahmen können im nächsten Schritt die benötigten Strukturen als 3D-Modelle extrahiert werden. Um diese dann letztendlich während der Operation mit den intraoperativen Daten fusionieren zu können, werden die präoperativen Modelle mit den intraoperativ erfassten Daten registriert.




Abbildung 1.1: Beispiel einer laparoskopischen Aufnahme, die während einer Operation aufgezeichnet wurde.

In der Neurochirurgie und der orthopädischen Chirurgie werden solche Systeme bereits eingesetzt (Rhoten *et al.*, 1997). In der laparoskopischen Chirurgie (siehe Abbildung 1.1), bei der starken Weichgewebedeformationen durch Atmung, Herzschlag oder laparoskopische Instrumente auftreten, ist die intraoperative in weiten Teilen ein ungelöstes Problem. Durch die Deformationen können die präoperativen Bilddaten der Patienten nicht rigide mit den intraoperativen Strukturen registriert werden. Doch gerade wegen dieser starken Veränderungen wäre hier eine genaue Navigation sehr wichtig.

1.1 Fragestellung

Eine präzise Weichgeweberegistrierung ist die Grundlage vieler Assistenzansätze in der laparoskopischen Chirurgie. Nur wenn präoperative Daten und Modelle an die aktuelle Situation im Operationsraum angepasst werden, können sinnvolle Visualisierungen und Schlüsse aus diesen Daten erzeugt und gezogen werden. Die Organe des Patienten werden sowohl vor und während der Operationsvorbereitung verschoben bzw. deformiert, hier spielen vor allem die Lagerung des

Patienten und das Anlegen des Pneumoperitoneums⁴ eine Rolle. Während der Operation sind es physiologische Abläufe, wie die Atmung oder der Herzschlag des Patienten, die neben den Manipulationen des Chirurgen für Deformationen sorgen. Das Zusammenspiel von initialer und dynamischer Registrierung ist in Abbildung 1.2 illustriert. Grundvoraussetzung für beide Registrierungsschritte ist die 3D-Rekonstruktion der intraoperativen Szene durch endoskopische Aufnahmen.

Im Rahmen dieser Arbeit wurden beginnend mit der endoskopischen Stereorekonstruktion, über die initiale Registrierung bis hin zur dynamischen Registrierung, wichtige Schritte in der laparoskopischen Weichgeweberegistrierung untersucht. Dabei nimmt in dieser Arbeit die intraoperative Bildgebung durch das Stereoendoskop, sowie die Erzeugung von intraoperativen Modellen einen zentralen Platz ein. In Hinblick auf das angestrebte System zur intraoperativen Weichgeweberegistrierung ergeben sich folgende Fragestellungen:

- **Wie können aus Stereoendoskopbildern robuste intraoperative Modelle in Echtzeit gewonnen werden?**

Bei regulären minimal-invasiven Eingriffen bietet das Endoskop als einzige Bildquelle einen Einblick ins Innere des Patienten. Die Nutzung dieser Datenquelle hat den großen Vorteil, dass keine zusätzlichen Geräte im Operationsraum benötigt werden und die Endoskopaufnahmen schon fest im Operationsablauf integriert sind. Bedingt durch das spezielle Anwendungsfeld haben endoskopische Bilder besondere Eigenschaften, die eine maschinelle Bearbeitung deutlich erschweren. Dabei spielt neben den optischen Eigenschaften, wie Verzerrungen, Vignettierungen oder dem geringen Abstand der beiden Bildsensoren, auch der Inhalt der Bilder eine große Rolle. Vor diesem Hintergrund soll untersucht werden, wie eine robuste und genaue Stereorekonstruktion dieser Daten erreicht werden kann. Im Gegensatz zu bestehenden Verfahren sollen die Besonderheiten und Herausforderungen der endoskopischen Bildgebung hierbei mit neuen Lernverfahren selbst erlernt werden.

- **Wie können die großen Verschiebungen und Verformungen zwischen präoperativen Aufnahmen und der Operation erfasst werden?**

Ein einzelnes endoskopisches Bild liefert meist nur einen kleinen Ausschnitt des Operationsfelds und der darin enthaltenen Organe. Ein daraus rekonstruiertes 3D-Modell beinhaltet daher auch nur ein Fragment der eigentlichen Organoberfläche. Bei der Registrierung von großen Transformationen bieten solche Fragmente jedoch oft keine ausreichenden Informationen, um die Transformation zweifelsfrei zu bestimmen. Hier muss untersucht werden, wie mehr Informationen gewonnen werden können, um eine robuste initiale Registrierung der präoperativen Modelle mit der aktuellen Operationsszene zu ermöglichen.

⁴Füllen und Aufblähen des Bauchraums mit CO₂-Gas

- **Wie können dynamische Deformationen auf die präoperativen Daten übertragen werden?**

Neben den Verschiebungen und Deformationen zwischen den diagnostischen Aufnahmen und dem Operationsbeginn sind während der Operation zusätzlich dynamische Veränderungen des Operationsfelds zu beachten. Durch physiologische Abläufe (Atmung, Herzschlag) und die Manipulation des Gewebes durch chirurgische Instrumente ist die Lage und Form der Organe ständigen Änderungen unterworfen. Hier stellt sich grundsätzlich die Frage, wie die sich mit jedem Zeitschritt ändernde Morphologie der Organe zeitnah auf das präoperative Modell übertragen werden kann. Es soll dabei erforscht werden, wie zusätzliche Informationen, in Form von Modellwissen oder Randbedingungen des Problems, zur Lösung dieses Problems beitragen können.

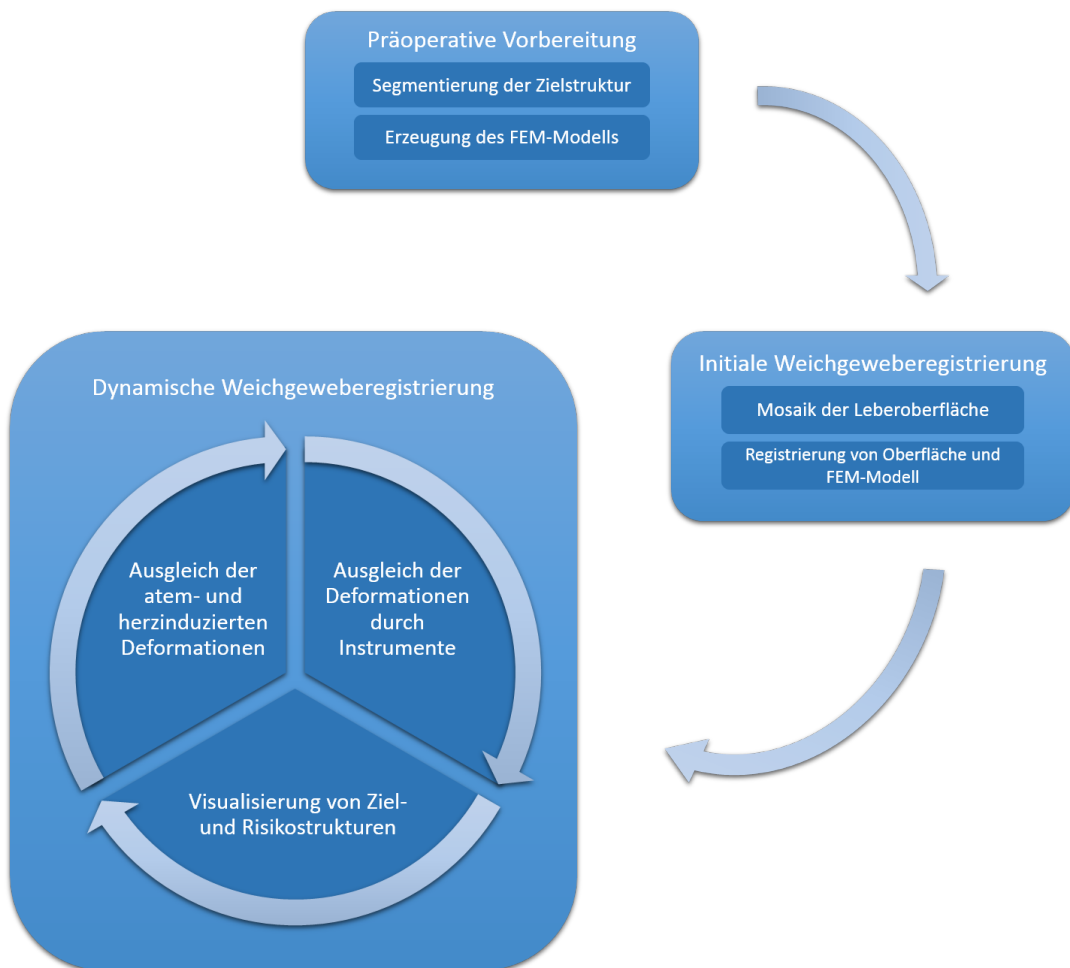


Abbildung 1.2: Prozesskette der Weichgeweberegistrierung.

1.2 Zielsetzung und Beitrag

Die vorliegende Arbeit befasst sich mit den zuvor genannten Fragestellungen. Es werden neue und effiziente Methoden zur laparoskopischen Weichgeweberegistrierung und den damit verbundenen Aufgaben vorgestellt. Im Folgenden werden die einzelnen Forschungsansätze und -ergebnisse kurz zusammengefasst:

Intraoperative 3D-Rekonstruktion Das (Stereo-) Endoskop ist eine der wichtigsten Informationsquellen während eines minimal-invasiven Eingriffs. Durch eine Stereorekonstruktion können Teilerflächen von Organen und Geweben aus den endoskopischen Bilddaten gewonnen werden. Detaillierte intraoperative Organmodelle sind essentiell für anschließende Weichgeweberegistrierungen. In dieser Arbeit wird ein neues Rekonstruktionsverfahren auf Basis von *Convolutional* Neuronalen Netzen (CNN) vorgestellt, das verschiedene Ansätze zur Erzeugung von Trainingsdaten nutzt und einen speziell auf die Herausforderungen der laparoskopischen Bildgebung ausgerichteten Lösungsansatz bietet. Neben der geringen Laufzeit, liegt die Stärke dieses Verfahrens besonders darin, das System mit zusätzlichen Trainingsdaten schnell auf neue Endoskop-Hardware oder neue Eingriffe optimieren zu können.

Initiale Weichgeweberegistrierung Um eine robuste initiale Registrierung der prä- und intraoperativen Modelle zu erreichen, sollte das intraoperative Modell einen möglichst großen Teil des betreffenden Organs erfassen. Da in einem einzelnen endoskopischen Bildpaar jedoch nur ein kleiner Teil des Operationsfelds sichtbar ist, wurde in dieser Arbeit ein neues automatisches Mosaikverfahren entwickelt, welches großflächige Modelle aus einzelnen Rekonstruktionsfragmenten erzeugt (Reichard *et al.*, 2015, Bodenstedt *et al.*, 2015, Reichard *et al.*, 2016) und robuste Registrierungen ermöglicht (Suwella, 2015).

Dynamische Weichgeweberegistrierung Das Ergebnis einer initialen Registrierung ist häufig nur für kurze Zeit gültig. Deformationen und Verschiebungen des Organs durch den Chirurgen oder physiologische Vorgänge (Atmung) machen eine Aktualisierung der Registrierung notwendig. Da für jeden Aktualisierungsschritt nur wenige intraoperative Informationen zur Verfügung stehen, wurde ein dynamisches Registrierungsverfahren auf der Basis eines biomechanischen Modells des Organs entwickelt (Reichard *et al.*, 2017). Während des gesamten Prozesses sind keine manuellen Eingriffe (Landmarken, Saatpunkte, usw.) des Operationspersonals notwendig.

Mechanisch realistische Silikon-Organ Zwischen virtuellen Testdaten und dem Experiment im lebenden Tier sind künstliche Organmodelle ein wichtiger Schritt in der Evaluation neuer medizinischer Verfahren. Das Ziel dieser Arbeit war die Entwicklung eines einfach herzustellenden und günstigen Organmodells mit realistischen mechanischen Eigenschaften. Hierzu

wird eine neue Methode zur Herstellung von wasserlöslichen 3D-gedruckten Gussformen für Silikon-Organmodelle vorgestellt (Reichard *et al.*, 2018).

1.3 Aufbau der Arbeit

Die vorliegende Arbeit ist in acht Kapitel gegliedert. Im Folgenden wird ein kurzer Überblick der einzelnen Kapitel gegeben:

Kapitel 2 vermittelt notwendige medizinische Grundlagen für das Verständnis von computergestützten Assistenzsystemen. Es werden die Besonderheiten der minimal-invasiven Chirurgie erläutert. Zusätzlich wird ein Einblick in heute bereits eingesetzte Systeme gegeben.

Kapitel 3 stellt den gegenwärtigen Stand der Forschung in den betroffenen Gebieten vor. Hierbei wird insbesondere auf die Stereorekonstruktion in der endoskopischen Bildgebung, sowie auf die verschiedenen intraoperativen Registrierungsansätze eingegangen.

Kapitel 4 befasst sich mit der Nutzung des Stereoendoskops zur intraoperativen 3D-Rekonstruktion. Dabei werden zunächst Grundlagen der Stereorekonstruktion und der *Convolutional* Neuronalen Netze (CNN) vermittelt, welche später zur Lösung dieses Problems verwendet werden. Eine wichtige Rolle spielt hierbei die Erzeugung von Trainingsdaten für das maschinelle Lernverfahren.

Kapitel 5 widmet sich dem ersten Schritt der intraoperativen Weichgeweberegistrierung: Der initialen Registrierung. Hierbei sind vor allem ein möglichst umfangreiches intraoperatives dreidimensionales Organmodell und die damit mögliche robuste initiale Registrierung des prä- und intraoperativen Modells von Bedeutung.

Kapitel 6 führt das Thema der Weichgeweberegistrierung weiter zur dynamischen Registrierung. Anders als bei der initialen Registrierung stehen hier nun Deformationen und Verschiebungen während der Operation im Mittelpunkt. Dazu muss das präoperative Modell fortlaufend (dynamisch) an die intraoperativen Geschehnisse angepasst werden.

Kapitel 7 beschreibt die Entwicklung und Herstellung von mechanisch realistischen Silikon-Organmodellen, die einen wichtigen Platz im Evaluationsprozess medizinischer Systeme einnehmen. Es wird dabei ein neues Verfahren zur Herstellung von wasserlöslichen Gussformen vorgestellt, das die Erzeugung von weichen Silikonmodellen mit strukturierten Hohlräumen erlaubt.

Kapitel 8 beinhaltet eine abschließende Zusammenfassung dieser Arbeit und bietet einen Ausblick auf anschließende Forschungsarbeiten.

Kapitel 2

Minimal-invasive Chirurgie

Die Gesundheit ist eines der höchsten Güter des Menschen. Vom Bader und Medicus des Mittelalters zu den Chirurgen, Neurologen, Radiologen und Anästhesisten der Moderne. Die medizinische Versorgung hat sich in der Geschichte der Menschheit stetig verbessert. War es früher nicht vorstellbar durch Röntgenstrahlung oder Magnetresonanz-Bilder aus dem Innern des lebenden Menschen zu erzeugen, so war es lange auch nur eine Vision mithilfe von optischen Geräten unter die Haut des Menschen blicken zu können.

Ein großer Schritt zur Verwirklichung dieser Vision wurde 1853 durch Antonin J. Desormeaux erbracht (Davis & Filipi, 1995). Er nutzte die seit der Antike bekannten Spekula, röhrenförmige Instrumente zur Betrachtung des Inneren durch natürlichen Körperöffnungen, und kombinierte diese mit Konkavspiegeln und dem neu verfügbaren hellen Licht der Gaslampen. Durch ihn wurde der bis heute verwendete Begriff des Endoskops (griechisch: éndon - innen; skopein - beobachten) geprägt, mit dem wir heute optische Geräte bezeichnen, die das Innere von Organismen oder auch Hohlräume von technischen Geräten sichtbar machen.

In den Jahren um 1988 wurde in diesem Zusammenhang der Begriff der minimal-invasiven Chirurgie eingeführt, welcher beschreibt, dass ein Endoskop während des operativen Eingriffs verwendet wird. Die Endoskope wurden anfangs vor allem für die Diagnose von Erkrankungen des Patienten eingesetzt. Später wurden sie auch für den chirurgischen Eingriff selbst verwendet.

Bei einem minimal-invasiven Eingriff erfolgt, im Gegensatz zur offenen Chirurgie, der Zugang ins Innere des Patienten nur über kleine Einschnitte in die Haut oder über natürliche Körperöffnungen. Um den Körper des Patienten vor dem Eindringen von Verunreinigungen und mechanischen Belastungen der Instrumente zu schützen, werden in diese Einschnitte zunächst röhrenförmige hohle „Pforten“, Trokare genannt, eingebracht.

Bei laparoskopischen Eingriffen (Bauchraum) dienen Trokare mit durchstoßbaren Dichtungen zusätzlich dazu, das Pneumoperitoneum zu erhalten (siehe Abbildung 2.1). Das Pneumoperitoneum ist eine künstlich erzeugte CO₂ Atmosphäre im Bauchraum des Patienten. Durch die Aufblähung der Bauchdecke wird ein Arbeitsraum zwischen den Organen und der Bauchdecke geschaffen, in dem der Chirurg arbeiten kann. Eine in das Endoskop eingekoppelte Kaltlichtquelle dient

zur notwendigen Beleuchtung im Innern des Patienten. Unter dem Begriff der Laparoskopie werden verschiedene endoskopische Eingriffe im Abdomen beschrieben. Dabei sind beispielsweise die Leber, der Darm oder die Nieren betroffen. Neben der Viszeralchirurgie wird auch in der Gynäkologie und der Urologie laparoskopisch operiert. Bei den Eingriffen werden typischerweise Teil- oder Komplettresektionen an den zuvor genannten Organen aufgrund von Entzündungs- oder Tumorerkrankungen durchgeführt (Soper *et al.*, 2008).

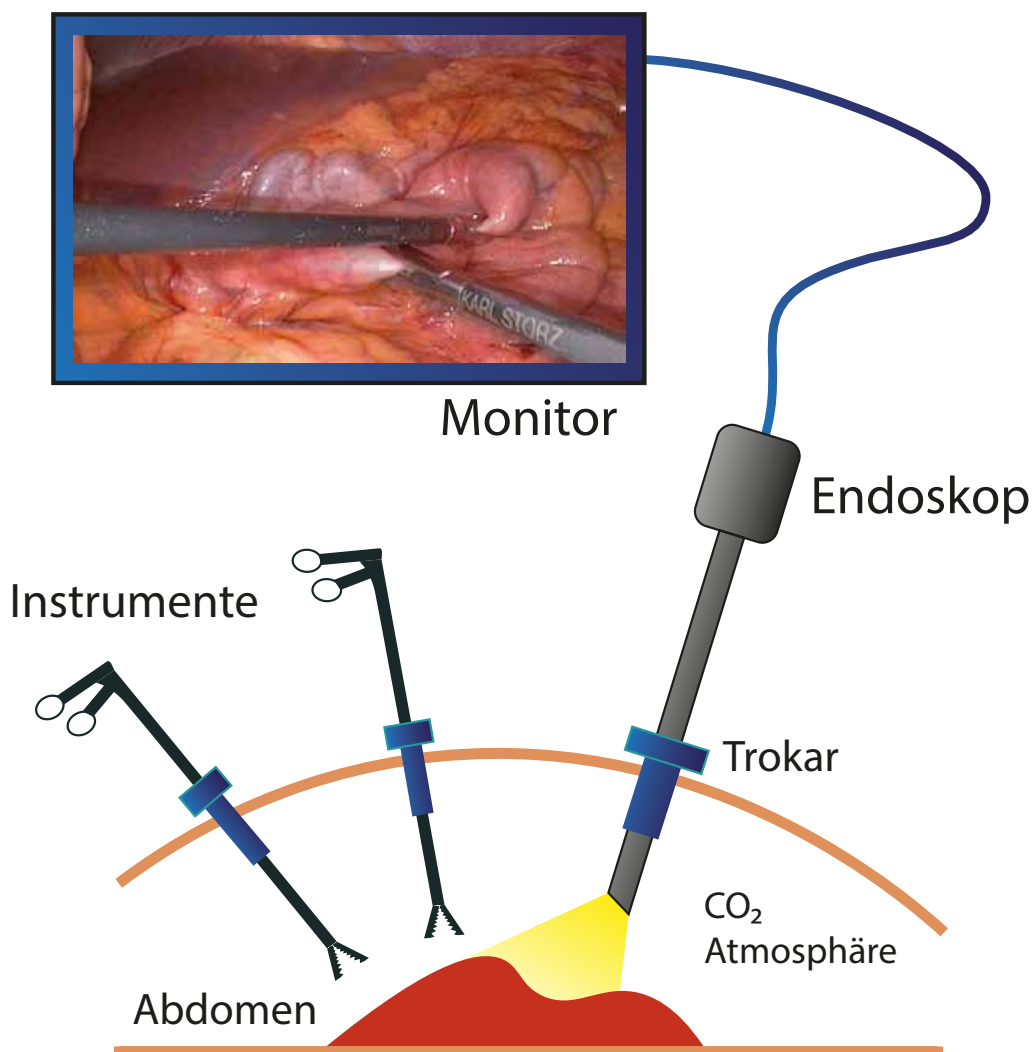



Abbildung 2.1: Schematische Darstellung eines laparoskopischen Eingriffs. Endoskop und Instrumente werden durch Trokare in den mit CO₂ gefüllten Bauchraum eingeführt. Der Chirurg verfolgt die Bewegungen der Instrumente am Bildschirm der Endoskopstation.

Neben dem Zugang für das bildgebende Endoskop, werden zusätzlich noch Zugänge für die benötigten chirurgischen Instrumente benötigt. Um die Manipulation der Organe und Gewebe durch den Trokar hindurch zu ermöglichen, wurden

lange stabförmige Instrumente speziell für die minimal-invasive Chirurgie entwickelt (siehe Abbildung 2.1). Hierbei gibt es heute eine Vielzahl verschiedener Instrumente, die jeweils genau auf den angedachten Einsatzzweck zugeschnitten sind.



linkes Endoskopbild

rechtes Endoskopbild

Abbildung 2.2: Beispielaufnahme eines Storz HD Stereoendoskops. Durch die horizontale Verschiebung zwischen den Bildsensoren und Objektiven sind auch die Aufnahmen der Szene leicht versetzt abgebildet. Mit einem 3D-Monitor kann der Chirurg durch die stereoskopischen Aufnahmen einen Teil seiner Tiefenwahrnehmung zurückerlangen.

Vor allem die Entwicklung der Video-Endoskopie in den 80er Jahren brachte die minimal-invasive Chirurgie in vielen Operationssälen zum Einsatz. Statt mit dem Auge direkt am Endoskop zu verharren, können Chirurgen nun die Vorgänge im Innern des Körpers über einen oder mehrere Bildschirme im Operationsraum verfolgen (siehe Abbildung 2.2). Gleichzeitig ist nun auch das weitere Operationspersonal in der Lage das Operationsgeschehen zu verfolgen (Feuerstein, 2007). Da während den Eingriffen meist zwei Instrumente gleichzeitig bedient werden müssen, konnten die Video-Endoskope nun auch von Assistenzärzten geführt werden, um den leitenden Chirurgen zu entlasten.

In vielen Bereichen, wie der Arthroskopie, der Neurochirurgie oder der Herzchirurgie, sind minimal-invasive Eingriffe bereits der Standard (Zittel & Beck, 1963). Durch technische Fortschritte wie der „Single Port Laparoscopy“ (SPL), bei der flexible Instrumente und das Endoskop durch einen einzigen Zugang eingeführt werden, ist zu erwarten, dass auch weitere medizinische Felder durch die minimal-invasive Chirurgie erschlossen werden.

2.1 Vor- und Nachteile der minimal-invasiven Chirurgie

Im Vergleich zur klassischen, offenen Chirurgie konnten in der minimal-invasiven Chirurgie zusätzliche Vorteile für den Patienten erreicht werden (Keck & Germer, n.d.). Das durch die kleinen Einschnitte reduzierte Operationstrauma des Patienten spielt dabei eine große Rolle. Die Verkleinerung der Zugangswege führt dabei gleichzeitig zu einer Senkung des Infektionsrisikos. Die stationäre Unterbringung der Patienten während ihrer Rekonvaleszenz nach größeren chirurgischen Eingriffen ist ein wichtiger Kostenfaktor der operativen Versorgung. Hier kann der Patient oft durch schnellere Wundheilung und einer geringeren Dosis an Schmerzmedikation früher entlassen und damit Kosten ohne Einbußen der Versorgungsqualität eingespart werden.

Während in der Gallenblasenentfernung, der Fundoplicatio (Bildung einer Fundusmanschette um den abdominalen Anteil der Speiseröhre) oder der Adipositaschirurgie (Magenbypass) schon standardmäßig minimal-invasiv operiert wird, konnte sich diese Operationstechnik noch nicht in allen Bereichen durchsetzen. Dies ist vor allem den Schwierigkeiten und Herausforderungen geschuldet, welche die minimal-invasive Chirurgie für den Operierenden mit sich bringt und welche im Folgenden erläutert werden (Brühl, 1966, Feuerstein, 2007, van der Putten *et al.*, 2008, Keck & Germer, n.d., Kenngott, 2010, Carus, 2014):

Hand-Auge-Koordination: Blickrichtung und Rotation des endoskopischen Bilds ändert sich während der Operation stetig. Eine Bewegung des Instrumentes mit einer linken Handbewegung kann auf dem Bild eine Bewegung nach oben entsprechen. Hierzu kommt, dass durch den Pivot-Punkt am Trokar der Instrumente, die Bewegungsachsen innerhalb des Körpers invertiert werden.

Sichtbereich und Bildqualität: Die Sicht des Operateurs ist durch die Brennweite des Endoskops und dessen Entfernung zum Objekt eingeschränkt. Zusätzlich sorgen Abbildungsfehler zu Verzerrungen der Aufnahme und geringe Ausleuchtung zu Bildrauschen. Glanzlichter auf feuchten Organoberflächen stören den optischen Eindruck zusätzlich. Da der Zugangspunkt durch den Trokar fest ist, kann das Endoskop nur begrenzt bewegt und geneigt werden.

Dreidimensionales Sehen: Durch den Blick auf den zweidimensionalen Bildschirm verliert der Chirurg die Fähigkeit zur Tiefenwahrnehmung. Dies ist besonders bei koordinativ anspruchsvollen Aufgaben, wie das Nähen oder Knoten von Fäden, hinderlich. Die Entwicklung neuer Stereoendoskopiesysteme mit stereoskopischen Monitoren tritt diesem Problem entgegen.

Haptisches Feedback: Die Länge der stabförmigen Instrumente und die damit einhergehenden Hebelkräfte verringern das haptische Empfinden des Chirurgen erheblich. Hinzu kommt die durch den Trokar verursachte Reibung

bei linearen Bewegungen. Ein Abtasten des Gewebes durch den Chirurg ist dadurch nicht mehr möglich.

Instrumentenbewegung: Jedes Instrument braucht einen eigenen Zugang in den Bauchraum. Werden andere Instrumente benötigt, müssen diese aufwendig durch den Trokar aus- und eingeführt werden. Die Eingebachten Instrumente können wie beim Endoskop nur linear hinein geschoben bzw. herausgezogen werden und um den Pivot-Punkt des Trokars rotiert werden. Zusätzlich findet die zuvor erwähnte Bewegungsumkehr innerhalb des Körpers statt.

Operationsplanung: Da die Position der Instrumente und des Endoskops nach der Durchführung der Einschnitte nicht mehr verändert werden kann, müssen diese genau geplant werden um alle Bereiche von Bedeutung sicht- und erreichbar zu machen.

Komplikationen: Kommt es während des minimal-invasiven Eingriffs zu Komplikationen, wie starken Blutungen, kann der Chirurg nur sehr begrenzt reagieren. Meist muss das Operationsfeld geöffnet und weiter offen operiert werden. Durch die Öffnung des Patienten vergeht zudem wertvolle Zeit in kritischen Situationen.

Ergonomie: Die Haltung des Chirurgen wird durch die Lage der Instrumente und des Bildschirms oft negativ eingeschränkt. Da diese Positionen für mehrere Stunden eingehalten werden müssen, ist diese zusätzliche Anstrengung des Chirurgen nicht zu vernachlässigen.

2.2 Laparoskopische Werkzeuge

Neben dem Endoskop existiert noch eine Vielzahl an weiteren laparoskopischen Instrumenten. Während das Endoskop die Sicht auf den Operationssitus gewährt, werden mit den manipulativen Instrumenten die eigentlichen chirurgischen Eingriffe durchgeführt (Kalk & Wildhirt, 1962, Zittel & Beck, 1963).

2.2.1 Endoskop

Anders als bei der offenen Chirurgie haben der Operateur und das Operationspersonal keine direkte Sicht auf die Zielstrukturen der Operation. Dies macht das Endoskop zur wichtigsten Informationsquelle während eines minimal-invasiven Eingriffs. Das durch einen kleinen Einschnitt eingeführte Endoskop gibt das Innere des Körpers in Echtzeit auf einer beliebigen Anzahl von Anzeigegeräten wieder. Während bei laparoskopischen Eingriffen auf starre Endoskope zurückgegriffen wird (siehe Abbildung 2.3), existieren auch flexible Endoskope. Diese werden für Operationen oder Diagnosen innerhalb von Organen, wie der Speiseröhre oder dem Darm, genutzt. Rigide Endoskope haben typischer Weise eine

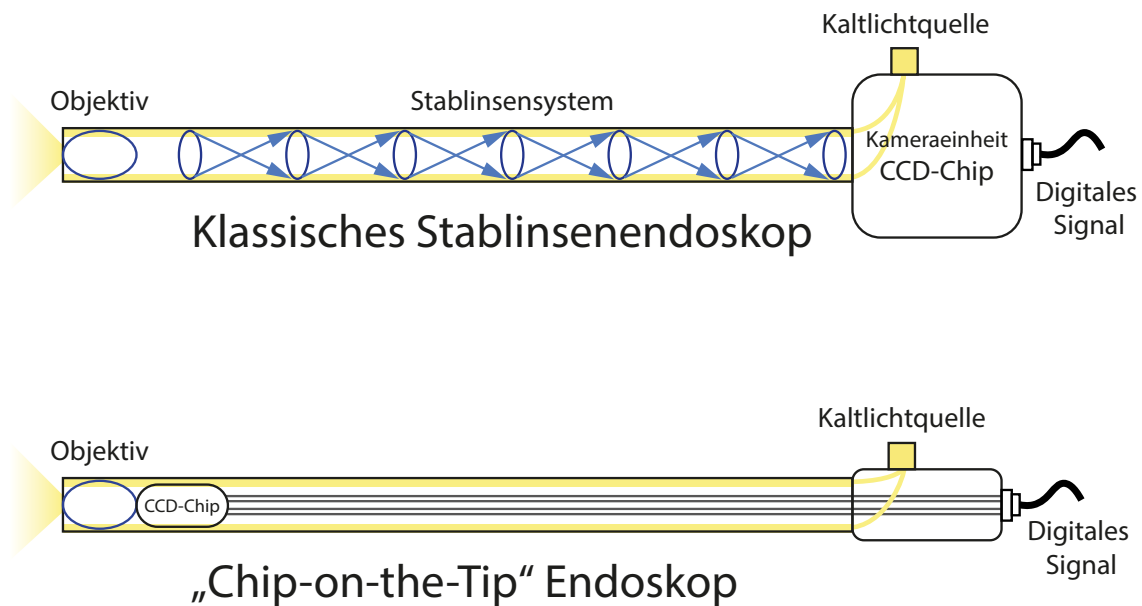


Abbildung 2.3: Schematische Darstellung eines klassischen, mit mehreren optischen Linsen bestückten Endoskops und eines neuartigen Chip-on-the-Tip Endoskops. Durch die Verlegung der Bildsensoren kann auf die aufwendige Linsenkonstruktion verzichtet werden. Die Kalibrierung von Stablinsenendoskopen ist anfällig für mechanische Veränderungen (Temperaturunterschiede, äußere Krafteinwirkung). Auch nimmt die Bildqualität mit jedem Linsenkontakt ab. Folgen sind unter anderem Vignettierungen und Verzerrungen.

Länge von 20 cm bis zu 40 cm und einen Durchmesser von 2 mm bis zu 12 mm (Kalk & Wildhirt, 1962).

In Abbildung 2.3 sind sowohl ein klassisches Stablinsenendoskop als auch ein neuartiges Chip-on-the-Tip Endoskop dargestellt. Bei beiden Verfahren wird das Licht der Szene zunächst durch ein Objektiv gebündelt. Mit der klassischen Optik werden die Lichtstrahlen über viele Linsenpaare innerhalb des Endoskopschafts zum hinteren Ende des Endoskops weitergeleitet. Dort befindet sich die eigentliche Kameraeinheit, mit der die optischen Signale durch den Bildsensor in digitale Signale umgewandelt werden. Das mehrfache Umleiten des Lichts führt zwangsläufig zu Einbußen in der Bildqualität. Die digitalen Bilder weisen meist Vignettierungen und Verzerrungen auf. Zusätzlich ist die Abbildung auf den Kamerasensor durch mechanische Veränderungen des Schafts ständig kleinen Veränderungen unterworfen. Dazu genügen Temperaturunterschiede oder eine äußere Krafteinwirkung auf den Endoskopschaft.

Das Chip-on-the-Tip System verzichtet auf das komplizierte Linsensystem im Schaft und platziert den Bildsensor direkt an die Spitze des Endoskops. Diese

große Vereinfachung der Optik wurde durch die Entwicklung kleinster Bildsensoren ermöglicht. Während diese Technik sicherlich die Zukunft der endoskopischen Bildgebung darstellt, ist ihre Verbreitung im klinischen Alltag noch sehr begrenzt.

Generell verfügen Endoskope, starre sowie flexible, ein System zur aktiven Beleuchtung der Operationsszene. Dazu wird eine externe Kaltlichtquelle über einen Glasfaser-Lichtwellenleiter an das Endoskop eingekoppelt. Innerhalb des Endoskops wird das Licht weiter über optische Leiter bis an die Spitze des Schafes transportiert. Dort befinden sich meist ein bis zwei Leuchtflächen neben dem Aufnahmeobjektiv. Da die Beleuchtungs- und Aufnahme-richtung nahezu identisch sind, ist bei endoskopischen Aufnahmen oft das Phänomen der Glanzlichter zu beobachten. Dies wird zusätzlich durch die feuchte Oberfläche der Organe verstärkt.

2.2.2 Stereoendoskop



Abbildung 2.4: Darstellung des Stereoendoskops des da Vinci Systems. ©2017 Intuitive Surgical¹, Inc.

Als eine Erweiterung des Standardendoskops, verfügen Stereoendoskope über zwei Objektive und zwei Bildsensoren. Sie bilden damit das stereoskopische Sehen des Menschen nach. Bei klassischen Stablinnenkonstruktionen, wie dem in

Abbildung 2.4 dargestellten da Vinci Stereoendoskopiesystem, werden beide optischen Signale getrennt über eigene Linsensysteme an die Bildsensoren weitergeleitet. Die Distanz zwischen beiden Objektiven beträgt typischerweise zwischen 1 mm und 5 mm (Kalk & Wildhirt, 1962). Durch die höhere Komplexität sind die Preise solcher Systeme deutlich über denen der Monoendoskope. Bei Chip-on-the-Tip Systemen genügt ein zweites Objektiv mit direkt angeschlossenem Bildsensor. Durch die höheren Kosten und der späteren Entwicklung ist die Verbreitung der Stereoendoskope in den Operationssälen sehr begrenzt. Als eine Erweiterung des Standardendoskops, verfügen Stereoendoskope über zwei Objektive und zwei Bildsensoren. Sie bilden damit das stereoskopische Sehen des Menschen nach. Bei klassischen Stablinnenkonstruktionen, wie dem in Abbildung 2.4 dargestellten da Vinci Stereoendoskopiesystem, werden beide optischen Signale getrennt über eigene Linsensysteme an die Bildsensoren weitergeleitet. Die Distanz zwischen beiden Objektiven beträgt typischerweise zwischen 1 mm und 5 mm (Röhl, 2013). Durch die höhere Komplexität sind die Preise solcher Systeme deutlich über denen der Monoendoskope. Bei Chip-on-the-Tip Systemen genügt ein zweites Objektiv mit direkt angeschlossenem Bildsensor. Durch die höheren Kosten und der späteren Entwicklung ist die Verbreitung der Stereoendoskope in den Operationssälen sehr begrenzt.

Mit einem geeigneten Wiedergabesystem kann der Chirurg dank des stereoskopischen Signals des Stereoendoskops einen großen Teil seiner Tiefenwahrnehmung wiederherstellen (siehe Abschnitt 2.1). Das Da Vinci System bietet hierzu eine Bedienungskonsole, in der das Operationsfeld in je einem Monitor für die beiden Augen des Chirurgen dargestellt wird. Heute existieren weiterhin hochqualitative 3D-Monitore, die dem Operateur und dem gesamten Operationspersonal einen dreidimensionalen Blick ins Innere des Patienten erlauben.

Für informationstechnische Systeme eröffnen Stereoendoskope die Möglichkeit, durch Stereokorrespondenzfindung und -rekonstruktion ein dreidimensionales Modell des Operationsfelds zu erzeugen. Wozu diese Informationen genutzt werden können, wird in Abschnitt 2.3 weiter erläutert.

2.2.3 Instrumente

Außer dem Endoskop werden in der minimal-invasiven Chirurgie noch viele weitere Instrumente benötigt. Mit ihnen kann der Chirurg Gewebe schneiden, anheben, vernähen, clippen, oder veröden. Im Folgenden ist eine Auswahl der meist verwendeten Instrumente aufgelistet (Kalk & Wildhirt, 1962):

Trokar: Hohlrohr, das durch die vorbereiteten Einschnitte in den Bauchraum eingeschoben werden. Dort fixiert, halten sie durch Dichtungen das Pneumoperitoneum aufrecht und erlauben gleichzeitig das Einführen eines Instrumentes oder des Endoskops.

¹<https://www.intuitivesurgical.com/>

Schere: Chirurgische Scheren werden zum Schneiden von Organen und Gewebe (beispielsweise bei einer Resektion), der Freilegung von Strukturen und dem Trennen von chirurgischem Garn oder Textilien verwendet.

Greifer: Wie der Name suggeriert, werden mit chirurgischen Greifern Organe und Gewebe gegriffen, bewegt, fixiert oder aus dem Abdomen entnommen. Dabei gibt es für die Anforderungen der verschiedenen Greifsituationen auch eine Vielzahl verschiedener Greifer, welche sich in Form, Größe und Stabilität unterscheiden.

LigaSure: Ähnlich wie die chirurgischen Scheren können mit dem LigaSure Organe und Gewebe durchtrennt bzw. geschnitten werden. Anders wie bei den Scheren wird hierbei aber Strom als trennende Kraft verwendet. Durch die Hitze des erzeugten elektrischen Stroms wird das Gewebe gleichzeitig kauterisiert (zerstört) was Blutungen stark reduziert.

Saug-und Spülinstrument: Um Organe und Gewebe von Blut und anderen Verschmutzungen zu befreien, können laparoskopische Sauginstrumente verwendet werden. Diese haben neben der Fähigkeit, Flüssigkeiten und kleine Partikel einzusaugen, oft auch die Möglichkeit mit einer (Salz-)Lösung zu spülen.

Ligatur-Clip: Vor der Durchtrennung blutführender Gefäße, können diese mit Titan-Clips zeitsparend verschlossen werden. Hierbei wird die blutführende Seite zweifach mit einem Clip versiegelt, um das Risiko eines starken Blutverlusts zu minimieren.

2.2.4 Robotiksysteme

Die Erwartungen, welche durch die Euphorie in den 90er Jahren geschürt wurden, konnten Chirurgieroboter bislang noch nicht erfüllen (Kenngott *et al.*, 2012). Zwar sind beispielsweise in der Chirurgierobotik-Datenbank MeRoDa (Pott, 2014) über 500 Projekte für robotische Systeme in der Chirurgie gelistet, wirklich kommerziell umgesetzt wurden davon aber nur ein verschwindend kleiner Teil. Einen Überblick der erfolgreichen und weniger erfolgreichen Robotiksystemen und deren Einfluss auf den chirurgischen Alltag, kann in den Artikeln von Gomes (2011), Najarian *et al.* (2011), Kenngott *et al.* (2012) und Pott (2014) gefunden werden.

Das unbestritten erfolgreichste Chirurgierobotiksystem stammt von Intuitive Surgical und trägt den Namen „da Vinci“ (siehe Abbildung 2.5). Es handelt sich hierbei um ein Master-Slave System, bei dem bis zu drei, von Roboterarmen geführten Instrumente und ein Endoskoparm von einer Teleoperationsstation aus gesteuert werden können (Gomes, 2011). Das Steuerungssystem kompensiert hierbei kleine Tremorbewegungen des Chirurgen und stabilisiert damit die Position der Instrumente. Durch die Verwendung eines Stereoendoskops kann das Operationsfeld durch den Chirurgen mit zwei Augenmonitoren dreidimensional wahrgenommen werden. Anfangs wurde da Vinci hauptsächlich für Operationen am



Abbildung 2.5: Darstellung des da Vinci Systems. Das System besteht im Kern aus einer Telemanipulationseinheit (links) und dem Robotik-Aktuator (Mitte). ©2017 Intuitive Surgical, Inc.

Herzen verwendet. Seine weite Verbreitung verdankt es aber seiner vielfältigen Einsetzbarkeit bei minimal-invasiven Eingriffen. Besonders in der Urologie wird das System heutzutage in Kliniken täglich verwendet.

Chirurgieroboter wie das da Vinci System erleichtern vor allem die Arbeit des Chirurgen. Durch den Teleoperator kann eine deutlich entspanntere Haltung eingenommen werden, was sich in Eingriffen mit Operationszeiten von oft über drei Stunden deutlich auf das Wohlfühl des Chirurgen auswirkt. Im Kontrast dazu steht der noch immer sehr hohe Kostenfaktor des Chirurgieroboters. Auch nach der Anschaffung fallen regelmäßig hohe Service- und Ersatzteilgebühren an. Auch die höheren Operationszeiten sind bei der Auslastung der Operationssäle zu beachten. Als letzter Punkt, muss hier auch der oft schwer nachweisbare Nutzen für den Patienten selbst berücksichtigt werden, da Investitionen im klinischen Sektor in der Regel entweder das Ziel haben die Patientenversorgung zu verbessern oder ein bestehendes Niveau mit geringeren Mitteln zu erreichen (Kenngott *et al.*, 2012).

2.3 Computer-assistierte Chirurgie

Bei der computer-assistierten Chirurgie soll dem Operateur ein virtueller Assistent zur Seite gestellt werden. Welche Assistenzfunktionen möglich und gewollt sind, hängt von dem jeweiligen Einsatz des Systems ab. Eine häufige Variante, welche für diese Arbeit maßgeblich ist, stellt die intraoperative Navigation dar. Die Intention gleicht dabei der eines Automobil-Navigationsgeräts. Statt der Position des Autos werden hier die Positionen der Instrumente und des Endoskops verfolgt, das Kartenmaterial beschreibt den Körper des Patienten und das Ziel ist beispielsweise ein Tumor oder eine bestimmte Stelle zur Entnahme einer Biopsieprobe.

Eine der Hauptaufgaben eines Assistenzsystems ist der einfache Zugang zu detaillierten Informationen aus den präoperativen, diagnostischen Aufnahmen wie der Computertomografie (CT) oder der Magnetresonanztomografie (MRT). So können dem Chirurgen, nach den im Folgenden beschriebenen Schritten, beispielsweise verdeckte Strukturen (bspw. Tumore) im Endoskopbild als erweiterte Realität (AR) dargestellt werden. Diese Hilfen sollen die kognitive Belastung des Chirurgen senken, um ihm die Möglichkeit zu geben seine Aufmerksamkeit und Konzentration auf andere Gebiete zu fokussieren.

Um ein Weichgewebenavigationssystem zu entwerfen, sind die folgenden Punkte zu beachten:

Präoperative Planung Um dem Chirurgen während der Operation wichtige Daten und Strukturen anzeigen zu können, müssen diese aus der präoperativen Diagnostik gewonnen werden. Hierbei bieten sich die meist schon vorhandenen Computertomografie oder Magnetresonanztomografie Aufnahmen an. Aus ihnen können detaillierte dreidimensionale Organmodelle oder Gefäßbäume extrahiert werden.

Intraoperative Bildgebung Da sich Organe und Gewebe zwischen diagnostischen Aufnahmen und dem eigentlichen chirurgischen Eingriff deutlich deformieren und verschieben können, ist für ein Assistenzsystem eine aktuelle dreidimensionale Repräsentation des Patientenintern notwendig. Das Stereoendoskop ist dabei einer der wichtigsten intraoperativen Sensoren. Durch die aufgenommenen kalibrierten Stereobilder können durch Stereorekonstruktions-Algorithmen intraoperative 3D-Modelle der Zielstrukturen erzeugt werden.

Intraoperative Lokalisierung Um Informationen relativ zu Endoskop und Patient auswerten zu können, muss die aktuelle Position und Ausrichtung der Endoskopkamera bekannt sein. Besonders wenn wie in Kapitel 5 verschiedene Aufnahmen miteinander in Verbindung gebracht werden sollen, ist eine genaue Positionsbestimmung der Kamera essentiell. Im klinischen Einsatz werden hierzu vor allem optische Trackingsysteme, wie das Polaris System von Northern Digital, verwendet. Dabei wird am Endoskop

(und nach Bedarf auch an Instrumenten) ein Markerkreuz angebracht. Über ein Infrarot-Stereokamerasystem können die 3D-Positionen der Markerkugeln bestimmt werden. Durch die Position von mindestens drei Punkten kann auch auf die Pose des Instruments geschlossen werden. Neben dem beschriebenen optischen Trackings gibt es außerdem noch elektromagnetisches Tracking und bildbasiertes Tracking. Letzteres spielt hauptsächlich im Forschungsumfeld eine Rolle und könnte zukünftig externe Systeme ersetzen.

Intraoperative Registrierung Mithilfe der intraoperativen Modelle und der Lokalisierung des Endoskops, können präoperative Modelle an die aktuelle Operationsszene angepasst werden. Dies wird als Registrierung bezeichnet. Um beispielsweise die Position eines Lebertumors intraoperativ anzuzeigen, muss zunächst das damit verknüpfte Oberflächenmodell der Leber mit dem aktuellen intraoperativen Modell registriert werden.

Intraoperative Visualisierung Die verbreitetste Form der intraoperativen Assistenz sind Visualisierungssysteme. Die Visualisierung kann hierbei auf zusätzlichen Monitoren oder direkt im Anzeigebild des Endoskops dargestellt werden. Um bei dem Beispiel mit dem Lebertumor zu bleiben, könnte das präoperativ extrahierte Modell des Tumors in das aktuelle Endoskopbild der Leber integriert werden und dem Chirurgen damit eine Art „Röntgenblick“ ermöglichen. Damit die Position und Ausrichtung des Tumors mit der angezeigten Leber übereinstimmt, müssen wie zuvor beschrieben, das prä- und intraoperative Modell registriert und damit ins gleiche Koordinatensystem gebracht werden.

2.4 Zusammenfassung

Die minimal-invasive Chirurgie ist in den letzten Jahrzehnten in immer neue Bereiche vorgedrungen und ist heutzutage nicht mehr aus dem chirurgischen Alltag wegzudenken. Sie hat dabei vor allem die Schonung des Patienten, durch geringere Traumata und schnelleren Genesungszeiten, bei chirurgischen Eingriffen verbessert. Leider sind diese Vorteile für den Patienten auch mit Nachteilen für den Chirurgen verbunden. Die anspruchsvollen und körperlich anstrengenden minimal-invasiven Eingriffe können nur von erfahrenen Chirurgen durchgeführt werden und verlangen hartes Training für angehende minimal-invasiven Chirurgen (MIC). Um die Chirurgen bei dieser schwierigen Aufgabe zu unterstützen, wurden in diesem Kapitel verschiedene Ansätze und Systeme vorgestellt.

Neben technischen Fortschritten wie dem Stereoendoskop oder teleoperierten Chirurgierobotern, sind es vor allem computer-assistierte Assistenzsysteme, die eine Entlastung des Chirurgen versprechen. In der Neurochirurgie werden schon seit einigen Jahren erfolgreich Assistenzsysteme im operativen Alltag eingesetzt. Durch markierte Zeiger (Pointer) können hier Stellen der Kopfhaut des Patienten

abgetastet werden und dabei gleichzeitig die dazugehörigen Planungsdaten aus dem CT angezeigt werden. So können beispielsweise Kraniotomien (Öffnung des Schädels) deutlich verkleinert werden, da sich der Arzt zuvor versichern kann, wo der Hirntumor genau verborgen liegt. Auch für die Behandlung von Epilepsieformen, bei denen bestimmte Hirnareale mit einer Stabelektrode stimuliert werden müssen, ist die Computer-Assistenz ein Segen. Durch das Tracking der Elektrode kann der Chirurg zu jeder Zeit überprüfen ob der eingeschlagene Weg sich immer noch im Zielvektor befindet. Wenn die Elektrode am Zielort angekommen ist, kann durch einen Blick auf die virtuelle Karte überprüft werden ob Planungspunkt und Realität übereinstimmen (Orringer *et al.*, 2012).

Für laparoskopischen Eingriffen streben erste Systeme, wie das CAS-One von CAScination² an den Markt. Weichgewebedeformationen und -verschiebungen vor und während der Operation machen die Verknüpfung von prä- und intraoperativen Daten vielfach schwerer. Da aber gerade hier großen Nutzen aus computer-assistierten Systemen gezogen werden kann, muss es das Ziel der Forschung sein, auch hier weitere chirurgische Navigationssysteme für Weichgewebe zu entwickeln und zu etablieren.

²<http://cascination.ch/products/cas-one-liver/>

Kapitel 3

Stand der Forschung

Die computer-assistierte Chirurgie (CAS) hält in immer mehr medizinischen Feldern Einzug. Bei Hirnoperationen (Reinhardt *et al.*, 1996) und Wirbelsäuleneingriffen (Nolte *et al.*, 1995) können CAS-Systeme schon heute Operateure mit präzisen Lokalisationshilfen unterstützen. Bei CAS Systemen für die Laparoskopie und die Weichgewebechirurgie im Allgemeinen wird umfangreich daran geforscht, eine solche Hilfe oder Navigation auch für Weichgewebe bieten zu können. Anders als bei Hirn und Wirbelsäule treten zwischen präoperativen Aufnahmen und der eigentlichen Operation mitunter starke Verschiebungen und Deformationen der Organe und des Weichgewebes auf. Dies wird durch das Pneumoperitoneum noch deutlich verstärkt. Um präoperative Planungs- und Bilddaten für ein „Weichgewebe-CAS“ zu nutzen, müssen sie durch eine detaillierte Repräsentation der intraoperativen Operationssituation an die aktuelle Lage und Deformation der Zielstrukturen angeglichen werden (Devernay *et al.*, 2001, Mountney *et al.*, 2010, Nicolau *et al.*, 2011). Dieser Vorgang wird als Weichgeweberegistrierung bezeichnet. Die dafür benötigte intraoperative Konfiguration (Form und Position) der Organe kann mit verschiedenen, im Folgenden vorgestellten, 3D-Rekonstruktionsverfahren aus intraoperativen Bilddaten erfasst werden.

3.1 Intraoperative 3D-Rekonstruktion

Für die intraoperative 3D-Rekonstruktion von Organen und Strukturen steht eine Reihe von Methoden zur Verfügung. Die Verfahren werden dabei meist in aktive und passive Rekonstruktionsansätze unterteilt. Maier-Hein *et al.* (2013) und Mirota *et al.* (2011) geben jeweils einen umfangreichen Überblick der potentiell nutzbaren Verfahren für die intraoperative Bildgebung.

Maier-Hein *et al.* (2014) führten außerdem eine Vergleichsstudie durch, in der ein Verfahren mit strukturiertem Licht (Clancy *et al.*, 2011), drei Stereo-Rekonstruktionsverfahren (Stoyanov *et al.*, 2010, Röhl *et al.*, 2012, Chang *et al.*, 2013) und ein experimentelles Time of Flight (ToF) Endoskop der Richard Wolf GmbH (Maier-Hein *et al.*, 2014) miteinander verglichen wurden. Um eine aussagekräftige Vergleichsbasis zu erreichen, wurde ein Datensatz mit verschiedenen Aufnahmen

von ex vivo Schweineorganen bereitgestellt. Die Daten enthalten typische Merkmale wie Glanzlichter, Blut und Rauch, welche zu den Herausforderungen der laparoskopischen 3D-Rekonstruktion zählen.

In den Ergebnissen waren die Stereo-Kamera Verfahren in Genauigkeit und Robustheit deutlich überlegen. Unter den Stereoverfahren waren die Methoden von Röhl *et al.* (2012) und Chang *et al.* (2013), die eine dichte (d.h. nicht nur vereinzelte Merkmale werden rekonstruiert) Rekonstruktion verfolgen, der Methode von Stoyanov *et al.* (2010) mit einer dünn besetzten Rekonstruktion überlegen. Beim Abdeckungsbereich der Rekonstruktion (d.h. welcher Anteil des Bildes rekonstruiert wurde) konnte sich Röhl *et al.* (2012) durchsetzen. Bei Robustheit und Genauigkeit lieferte das Verfahren von Chang *et al.* (2013) die besten Ergebnisse. Für die Erzeugung von strukturiertem Licht ist bei der Methode von Clancy *et al.* (2011) zusätzlich ein Projektionsgerät notwendig. Auch Stereoendoskope sind nicht in allen Operationsräumen vorhanden, finden aber immer größere Verbreitung, nicht zuletzt durch chirurgische Robotiksysteme wie dem da Vinci Surgical Tele-Operator (Maier-Hein *et al.*, 2013).

Für eine genauere Betrachtung können Rekonstruktionsansätze zunächst in zwei Typen aufgeteilt werden: aktive und passive Rekonstruktionsverfahren.

3.1.1 Aktive Rekonstruktion

Bei aktiven Rekonstruktionen in die Beleuchtung der Szene eingegriffen (Maier-Hein *et al.*, 2013). Diese kontrollierte Beleuchtung soll die Tiefe der Bildpunkte einfacher erfassbar machen.

ToF-Kameras

Wie der Name „Time of Flight“ suggeriert, bei ToF-Kameras die Entfernung zwischen Kamera und einem Objekt berechnet, indem die Zeit t zwischen dem Senden eines Lichtimpulses und dem Empfang des reflektierten Impulses gemessen wird. Die Entfernung z kann dann mit $2 \cdot z = c \cdot t$ bestimmt werden, wobei $c \approx 30\text{cm/ns}$ die Lichtgeschwindigkeit ist Lange & Seitz (2001). Es können zwei Verfahren zur Messung unterschieden werden:

Pulse Runtime Methode Hierbei wird direkt die Zeit zwischen Senden und Empfangen des Impulses gemessen. Dies erfordert sehr genaue und damit auch sehr kostspielige Uhren, die im Pikosekundenbereich messen können.

Phase Shift Determination Um die direkte Messung zu umgehen, wird bei diesem Verfahren mit amplitudenmoduliertem Infrarotlicht gearbeitet. Statt der Zeit, kann so die Entfernung indirekt durch die Phasenverschiebung am Empfänger gemessen werden.

Strukturiertes Licht

Anders als bei ToF nutzen Verfahren mit strukturiertem Licht normale RGB- oder Grauwert-Kameras. Dafür wird mit einer externen Lichtquelle ein Muster mit festgelegter Geometrie auf die Szene projiziert. Diese Muster wird im Kamerabild erkannt und die Tiefeninformation daraus trianguliert (Robinson *et al.*, 2004). Dazu muss allerdings die Transformation zwischen Kamerazentrum und Projektor bekannt sein. Ein großer Vorteil dieses Verfahrens, gerade in der Endoskopie, ist die Erzeugung von künstlichen Landmarken, die auch homogene und texturarme Oberflächen messbar machen.

Um dieses Verfahren in der Endoskopie einsetzen zu können, muss ein solcher Projektor in den Bauchraum des Patienten eingeführt werden. Maurice *et al.* (2012) nutzen dazu zwei separate Endoskope, wobei eines für die Bildakquise und eines für die Projektion des Musters verwendet wird. In den von Clancy *et al.* (2011) und Lin *et al.* (2015) vorgestellten Verfahren, wird eine separate Sonde zur Projektion eingesetzt. Abdalbari *et al.* (2013) und Edgcumbe *et al.* (2015) wiederum nutzen miniaturisierte Projektoren und gewöhnliche Endoskope zur 3D-Rekonstruktion. Schmalz *et al.* (2012) stellen in ihrer Arbeit einen hybriden Sensor vor, welcher Kamera und Projektor in einem Gerät vereint. Die Auflösung der erfassten Bilder liegt allerdings nur bei geringen 400×400 Pixeln. Diesem Ansatz ähnlich, passen Furukawa *et al.* (2015) einen miniaturisierten Projektor in den Instrumentenschacht eines Singleport-Endoskops ein.

3.1.2 Passive Rekonstruktion

Im Gegensatz zu den aktiven Ansätzen, nutzen passive Verfahren gewöhnliche RGB-Bildsensoren und schon vorhandene Lichtquellen. Je nach Ansatz werden dazu entweder mehrere Bilder einer Kamera oder gleichzeitige Bilder von mehreren Kameras verwendet (Maier-Hein *et al.*, 2013).

Stereo-Kamerasysteme

Stereo-Kamerasysteme bestehen aus zwei, meist horizontal versetzten, Kameras, welche möglichst parallel ausgerichtet sind (Abbildung 3.1). Eine ausführliche Beschreibung eines Stereo-Kamerasystems und der Stereo-Rekonstruktion wird im Abschnitt 4.1 gegeben.

Um 3D-Punkte aus Stereo-Bildpaaren zu rekonstruieren, müssen die korrespondierenden Projektionen des ursprünglichen Punktes in beiden Kamerabildern ermittelt werden. Mit einer bekannten Kalibrierung, die intrinsischen und extrinsischen Parameter des Stereo-Kamerasystems beinhaltet, kann damit via Triangulation der ursprüngliche 3D-Punkt berechnet werden Longuet-Higgins (1987). Eine möglichst genaue Kalibrierung spielt bei der Qualität der Rekonstruktion




Abbildung 3.1: Da ein Oberflächenpunkt für eine 3D-Rekonstruktion von beiden Kameras beobachtet werden muss, kann nur Teil des Bildes rekonstruiert werden. Im überlappenden Bereich (grün) kann es außerdem zu Verdeckungen kommen, welche die Sicht einer Kamera blockieren (rot). In solchen Bereichen kann eine Rekonstruktion ebenfalls nicht gelingen.

eine große Rolle. Eine Kalibrierung kann beispielsweise mit der direkten linearen Transformation (DLT) berechnet werden (Stefansic *et al.*, 2002).

Diese Korrespondenzen für alle Pixel eines Bildpaares in Echtzeit zu finden, dies wird auch dichte Rekonstruktion genannt, ist ein aktives Forschungsfeld im Bereich maschinelles Sehen. Es wurden verschiedene Ansätze zur Lösung dieses Problems entwickelt. Hirschmüller (2008) setzen auf Transinformation oder gegenseitige Information, um eine Energiefunktion über die Korrespondenz zu minimieren. Ein vielversprechender Ansatz von Atzpadin *et al.* (2004) nutzt zeitliche und räumliche Informationen um Korrespondenzen auf Pixel- und Blockebene zu bestimmen.

Neuronale Netze und im besonderen *Convolutional* Neural Networks (CNNs) dringen in den letzten Jahren immer stärker in den Bereich des maschinellen Sehens (computer vision) vor. Mit Bildklassifizierung begonnen (LeCun *et al.*, 1989), werden CNNs auch zur pixelweisen Schätzung von beispielsweise semantischer Segmentierung genutzt (Long *et al.*, 2015). Erst kürzlich wurden sie dann auch eingesetzt, um den optischen Fluss und Disparitäten von Stereobildern zu bestimmen (Dosovitskiy *et al.*, 2015, Mayer *et al.*, 2016). CNN basierte Verfahren bieten eine große Chance für die laparoskopische 3D-Rekonstruktion. Denn anders als konventionelle Verfahren, die meist auf nicht-klinische Gebiete optimiert

wurden, sind neuronale Netze durch ihre Struktur nur grob für eine Aufgabe konzipiert. Die Anpassung an das genaue Problem findet hauptsächlich durch die Wahl der Trainingsdaten statt.

Beim bekannten Middlebury Datensatz¹ sind nun auch 6 der 10 besten Verfahren bei der 3D-Rekonstruktionsherausforderung CNN basierte Methoden (Scharstein & Szeliski, 2002, 2003, Scharstein & Pal, 2007, Hirschmüller & Scharstein, 2007, Scharstein *et al.*, 2014).

Ein ähnliches Bild bietet der KITTI Datensatz², bei dem ebenfalls viele CNN basierte Methoden unter den bestplatzierten Einreichungen gehören (Geiger *et al.*, 2012, Fritsch *et al.*, 2013, Menze & Geiger, 2015).

Seit zwei Jahrzehnten wird nun auch daran geforscht die Stereo-Rekonstruktion in der laparoskopischen Chirurgie zu lösen. Neue Einsatzgebiete wie die operative Telemanipulation mit Geräten wie dem da Vinci System, machen die 3D-Rekonstruktion immer wichtiger für den moderne Chirurgie (Bernhardt *et al.*, 2017a, Su *et al.*, 2009). In der Herzchirurgie werden thin-plate Spline Interpolationen von Bildmerkmalen untersucht, um die Herzbewegung während des Eingriffs zu stabilisieren (Richa *et al.*, 2011).

In der Laparoskopie nahm sich zuerst Devernay *et al.* (2001) das Problem der Stereo-Rekonstruktion mithilfe von korrespondenzbasierten Methoden an. Stoyanov *et al.* (2010) und Totz *et al.* (2014) befassen sich mit der Erzeugung von halbdichten Korrespondenzkarten für die Laparoskopie. Basierend auf dem hybriden rekursiven Korrespondenzverfahren von Atzpadin *et al.* (2004) entwickelte Röhl *et al.* (2012) ein dichtes Verfahren, das auf die Ansprüche des medizinischen Kontextes spezialisiert wurde. Zuletzt entwickelte Chang *et al.* (2013) ein dichtes Verfahren auf Basis einer konvexen Optimierung einer Kostenfunktion. Wie zuvor erwähnt, erreichte die konvexe Optimierung die höchste Genauigkeit in der Vergleichsstudie von Maier-Hein *et al.* (2014).

Structure from Motion

Structure from Motion (SfM) folgt dem gleichen Prinzip wie die Stereo-Kamerasysteme. Statt zweier Kameras wird allerdings nur eine einzelne Kamera verwendet, die dafür mehrere Aufnahmen von verschiedenen Blickpunkten aus generiert. Anders als bei der bekannten Geometrie der Stereokamera, kommt hier allerdings nun die unbekannt Transformation der Bildzentren der verschiedenen Aufnahmen hinzu. Mit einer statischen Szene kann diese Transformation jedoch nach Hartley & Zisserman (2003) bis auf einen unbekannt Skalierungsfaktor berechnet werden. Scaramuzza *et al.* (2009) nutzen nicht-holonome Zwangsbedingungen um den Skalierungsfaktor zu bestimmen.

¹<http://vision.middlebury.edu/stereo> (Stand: 01.06.2017)

²<http://www.cvlibs.net/datasets/kitti/index.php> (Stand: 01.06.2017)

Da sich die Szene in der Weichgewebechirurgie kontinuierlich wandelt, ist der Einsatz dieser Systeme jedoch problematisch. Es existieren zwar Methoden, SfM auch für sich wandelnden Szenen anzuwenden (Malti *et al.*, 2011, Hu *et al.*, 2012), diese können aber nicht in Echtzeit berechnet werden (Bernhardt *et al.*, 2017b). Malti *et al.* (2011) stellen ein Verfahren vor, welches SfM mit dem im folgendem beschriebenen *Shape from Shading* kombiniert, um die Herausforderung der laparoskopischen Szene anzugehen.

Shape from Shading

Bei *Shape from Shading* wird anders als bei Stereo oder SfM nur ein Bild für Tiefenbestimmung benötigt. Bei dieser Methode wird betrachtet, wie das Licht den Schattenwurf in der Szene beeinflusst um die dreidimensionale Form der Szenenobjekte zu schätzen (Prados & Faugeras, 2006).

Collins & Bartoli (2012) untersuchten *Shape from Shading* für die Nutzung in der Laparoskopie, kamen aber zu dem Schluss, dass die Lichtsituation und die organische Szene nicht genug Schattenmerkmale bietet um gute Ergebnisse zu erzielen.

3.2 3D-Modellgenerierung

Da intraoperative Modelle für die Registrierung unverzichtbar sind, wurden dazu viele Ansätze erforscht. In einem frühen Ansatz nutzten Herline *et al.* (2000) eine Sonde um die Organoberfläche mechanisch abzutasten. Die Sonde wurde dabei mit einem aktiven Positionierungssystem verfolgt. Um Gewebeschäden zu verhindern, wird in neueren Methoden auf optische Sensoren zurückgegriffen. Clements *et al.* (2008) nutzen beispielsweise einen Laserscanner zur Organrekonstruktion. Dieser liefert sehr genaue Daten, kann aber nur in der offenen Chirurgie angewendet werden. Zudem wird dadurch zusätzliche Hardware im Operationssaal notwendig. Autorino *et al.* (2014), Dwyer *et al.* (2015) setzen andererseits auf Ultraschallsonden, um die Oberflächen der Organe und sogar das Gewebe im Innern der Organe aufzunehmen.

Bei optischen Rekonstruktionsverfahren wie der Stereo-Rekonstruktion, SfM oder *Shape from Shading* kann immer nur ein kleiner Teil des Operationssitus rekonstruiert werden. Für eine robuste initiale Registrierung sind allerdings größere Regionen notwendig. Die Daten mehrerer Aufnahmen in ein Modell zu integrieren, ist ein typisches Problem der Robotik (Thrun *et al.*, 2002, Nüchter, 2009, Olson, 2008). Um es zu lösen, muss die eigene Position im Raum verfolgt werden, während gleichzeitig der Sichtbereich in eine interne Repräsentation kartografiert wird. Dies wird auch Simultaneous Localization and Mapping (SLAM) genannt.

3.3 Registrierung von intra- und präoperativen Modellen

Es liegt nahe, diese Methoden auch für die computer-assistierte Chirurgie nutzbar zu machen. So stellte Mountney *et al.* (2006) ein Verfahren für die laparoskopische Chirurgie vor, welches einen stereoendoskopischen SLAM-Ansatz nutzt, um die Oberfläche der Leber während des operativen Eingriffs zu erfassen. Dabei nutzen sie eine kleine aber robuste Menge von Texturlandmarken, welche mithilfe eines erweiterten Kalmanfilters über die Zeit verfolgt werden. Das erweiterte Kalmanfilter (Julier & Uhlmann, 2004) dient hierbei vor allem der Schätzung des Bewegungsmodells des Stereoendoskops. In einer Erweiterung dieser Arbeit, wurde ein Bewegungsmodell für die Atembewegung des Patienten hinzugefügt, um periodische Deformationen des Gewebes in die Positionsschätzung einfließen zu lassen (Mountney & Yang, 2010). Um das Atemmodell einzulernen, wird das Endoskop fixiert damit statt der Endoskopbewegung zunächst die Bewegung der Texturmerkmale auf den Organen geschätzt werden kann. Nachdem das Atemmodell eingelernt wurde, kann die Bewegungsschätzung des Endoskops deutlich genauer erfolgen.

Um Landmarken oder Merkmalspunkte auch nach Verdeckungen oder plötzlichen großen Endoskopbewegungen wieder zuverlässig zu finden, entwickelte Puerto-Souza *et al.* (2013a,b) einen robusten Merkmalsvergleich, den *hierarchical multi-affine* Algorithmus (HMA). Bei Versuchen mit realen laparoskopischen Eingriffen, konnte gezeigt werden, dass das HMA Verfahren die zuvor existierenden Methoden in Anzahl der Korrespondenzen, Laufzeit, Genauigkeit und Robustheit in diesem Einsatzgebiet übertrifft.

Auch Monokamerasysteme können für SLAM genutzt werden. Grasa *et al.* (2011, 2014) nutzen SfM, um schwach besetzte Tiefenkarten von statischen endoskopischen Szenen in Echtzeit zu erzeugen. Wie in Abschnitt 3.1.2 erwähnt, kann die Szenegeometrie bei SfM im Allgemeinen aber nur in einer relativen Skalierung ermittelt werden (Scaramuzza *et al.*, 2009).

Erst vor einigen Jahren stellten Newcombe *et al.* (2011), Izadi *et al.* (2011) ihr vielbeachtetes Verfahren vor, das Szenen in Raumgröße in Echtzeit mit einem Microsoft Kinect³ Sensor rekonstruiert. Die Kinect arbeitet dabei mit strukturiertem Licht um Tiefeninformationen zu erlangen (Zhang, 2012, Janoch *et al.*, 2013). Haase *et al.* (2013) entwickelten auf der Basis von Newcombe *et al.* ein laparoskopisches Verfahren, das eine 160 x 120 Pixel Time of Flight Kamera nutzt, um den Operationssitus mit mehreren Bildausschnitten zu rekonstruieren.

3.3 Registrierung von intra- und präoperativen Modellen

Vor dem Eingriff werden zunächst präoperative Daten in Form von CT- oder MRT-Aufnahmen für eine Diagnose und die Eingriffsplanung angefertigt. Die-

³<http://support.xbox.com/de-DE/browse/xbox-360/accessories/Kinect>

se Aufnahmen bieten ein präzises Abbild der Organe und Gewebestrukturen des Patienten. In 3D-Modelle umgewandelt, meist Dreiecksnetze oder *Meshs*, bieten sie dem Betrachter eine virtuelle Sicht auf das Innenleben des Patienten.

Diese Daten können auch in Form eines Assistenzsystems während der Operation genutzt werden. Dazu bieten sich beispielsweise Techniken der erweiterten oder virtuellen Realität an (Nicolau *et al.*, 2011). Da sich die Form und Lage von Organen allerdings zwischen Aufnahme und Operation verändert, als einer der Hauptfaktoren ist hier das Erzeugen des Pneumoperitoneums zu nennen, müssen diese Modelle an die intraoperative Szene angeglichen werden. Dieser Vorgang wird *Registrierung* genannt. Die intraoperative Bildgebung, maßgeblich das Endoskop, sind der präoperativen apparativen Geräten zwar deutlich in Genauigkeit unterlegen, sind aber dennoch ein wichtiger Bestandteil für eine intraoperative Registrierung. Die in Abschnitt 3.1 und 3.2 beschriebenen Methoden zur intraoperativen 3D-Rekonstruktion erzeugen Oberflächenmodelle, mit deren Hilfe die präoperativen Modelle mit der aktuellen Szene registriert werden können.

Die ersten intraoperativen Registrierungsansätze basieren meist auf rigiden Transformationen, wie dem Iterative Closest Point (ICP) Verfahren. Auch ist dabei oft auch eine manuelle initiale Ausrichtung des CT-Modells mit den intraoperativen Modellen notwendig. Die Arbeit von Su *et al.* (2009) für partielle Nephrektomien (Nierentumorentfernung) ist für diese Strategie ein gutes Beispiel. Hier werden ausgewählte Oberflächenpunkte mit einem Stereo-Endoskop verfolgt, um das präoperative CT-Modell mit einem ICP Ansatz mit diesen Punkten zu registrieren. Durch das Verfolgen von festen Landmarken konnte auf Marker verzichtet werden.

Rigide Registrierungsalgorithmen haben allerdings den großen Nachteil, dass sie Weichgewebedeformationen nicht abbilden können. Ändert sich die Form eines Organs zwischen der Aufnahme des CT-Bildes und der eigentlichen Operation, ist es nicht möglich die prä- und intraoperativen Modelle Deckungsgleich zu überlagern. Weichgewebedeformationen sind in der Laparoskopie bzw. der Weichgewebechirurgie im Allgemeinen nicht zu vermeiden und haben verschiedene Ursachen. Wie von Herline *et al.* (1999) beschrieben, können Deformationen durch das Pneumoperitoneum, Atembewegungen, Herzschlag oder Operationsbesteck ausgelöst werden.

Auch in der Robotik und des maschinellen Sehens allgemein, sind Deformationen während RGB-Stereo-Rekonstruktionen ein aktives Forschungsfeld. Bregler *et al.* (2000) nutzen Linearkombinationen aus einer festen Menge von dreidimensionalen Grundformen, um die Pose, Konfiguration und Form der nicht-rigiden Zielstruktur zu schätzen. Dies wurde erfolgreich auf nicht-rigide Modelle für menschliche Gesichter und Tiermodelle angewendet. Aufbauend auf das rigide Rekonstruktionsverfahren KinectFusion (Newcombe *et al.*, 2011), erarbeiteten Newcombe *et al.* (2015) das Verfahren DynamicFusion. Das volumetrische Voxelmodell wird hierbei um ein 6 dimensionales Bewegungsfeld ergänzt, welches die geschätzte Geometrie in die Konfiguration des aktuellen Bildes verformen

3.3 Registrierung von intra- und präoperativen Modellen

kann. Da diese Verformungsfelder kontinuierlich verlaufen, können große geometrische Veränderungen wie das Zerteilen einer Form nur schlecht abgebildet werden. Das Verfahren wurde erfolgreich bei vielen bewegten Objekten und Gesichtern getestet. Gupta *et al.* (2016) bauen wiederum auf die Arbeit von Newcombe *et al.* (2015) auf und nutzen LSD-SLAM (Engel *et al.*, 2014) und einen 2D-3D Segmentierungsansatz, um eine Rekonstruktion auch mit einer Monokamera zu ermöglichen.

Um den Deformationen in der Laparoskopie zu begegnen, setzen viele Methoden auf biomechanische Modelle, die vielversprechende Ergebnisse liefern. In einer der ersten Arbeiten, kombinierten Pratt *et al.* (2010) physik-basierte Modell mit bildbasierten Randbedingungen, um Registrierungs-genauigkeit eines 4D CT-Scans eines schlagenden Herzens zu optimieren. Oktay *et al.* (2013) nutzen biomechanische Modelle, um den Deformationsprozess während der Insufflation des Bauchraums nachzubilden. Dies soll helfen die Daten eines präoperativen CTs mit den denen eines intraoperativen C-Bogen CTs zu registrieren und die Planungsdaten somit für die neue Weichgewebegeometrie zu aktualisieren.

In der offenen Leberchirurgie arbeiten Rucker *et al.* (2014) an einem Verfahren, das präoperative CT-Scans mit intraoperativen Laserscans der Leber registrieren soll. Ein biomechanisches Modell wird hierbei genutzt, um Randbedingungen zu definieren, die konsistent mit der präparierten Lage der Leber für die Leberresektion sind. Um den eigentlichen Registrierungsvorgang von einem prä- und intraoperativen Modell geht es in der Arbeit von Suwelack *et al.* (2014). Das entwickelte Physics based Shape Matching (PBSM) nutzt ein System von elektrostatischen Anziehungskräften, die ein biomechanisches Modell langsam der Geometrie des intraoperativen Modells anpasst. Hierbei wird wie bei den meisten biomechanischen Verfahren die Summe aus inneren und äußeren Kräften minimiert. Die inneren Kräfte wären hierbei den Erhaltungsdrang der ursprünglichen Form und die äußeren Kräfte wären die sich anziehenden elektrostatischen Ladungen der Modelloberflächen.

Um die initiale Registrierung zu vereinfachen, nutzt Plantefève *et al.* (2015) eine manuelle Segmentierung eines Leberligaments, das einem ICP Algorithmus erlaubt die Lage der Leber zuverlässig zu bestimmen. Biomechanische Verfahren können auch genutzt werden, indem sie Formparameter eines Objektmodells mit intraoperativen Randbedingungen optimieren. Allgemein können biomechanische Registrierungsalgorithmen mit dichten (Collins *et al.*, 2016) oder schwach besetzten (dos Santos *et al.*, 2014) Tiefenkarten für das intraoperative Modell genutzt werden. Schwach besetzte Modelle sind dabei auf robuste und verfolgbare Merkmale angewiesen.

3.4 Künstliche Organmodelle

Künstliche Organphantome sind wichtige Werkzeuge in der Evaluation von CAS-Methoden und Algorithmen. Obwohl menschliche in vivo Versuche natürlich den Goldstandard in der Evaluation darstellen, sind diese nur möglich, wenn die nötigen Daten ohne eine Gefährdung des Patienten passiv erhoben werden können. Auch Tierversuche sollten aus ethischen Gründen auf ein Minimum beschränkt werden. Umso wichtiger ist es, dass Organphantome möglichst genau den Eigenschaften der menschlichen Organe entsprechen. Im Folgenden werden eine Auswahl von universitären und kommerziellen Phantomen vorgestellt (Gern, 2016).

ELITE-Phantom

Das ELITE-Phantom, kurz für endoskopisch-laparoskopische interdisziplinäre Trainingseinheit, wurde als Trainingssimulator für laparoskopische Eingriffe konzipiert (Fiolka *et al.*, 2010). Zur Simulation des Pneumoperitoneums kann entweder eine Hartschalenbauchdecke oder eine aufpumpbare elastische Bauchdecke genutzt werden. Zusätzlich zu laparoskopischen Eingriffen, können auch offene Operationen ohne Bauchdecke und Operationen mit Zugängen durch natürliche Körperöffnungen simuliert werden. Die Organe sind aus Silikonen und Kunststoffen gefertigt, wobei diese nicht näher spezifiziert wurden. Für einen realistischen visuellen Eindruck können außerdem Organe aus einer Gelatine-Kollagenmischung genutzt werden. Während der Simulator von Ärzten generell als sehr gut eingeschätzt wurde, konnte das Materialverhalten der Organe nicht überzeugen.

OpenHELP-Phantom

Das Open-Source Heidelberger Laparoskopie Phantom (OpenHELP) wurde in einer Kooperation der Heidelberger Universitätschirurgie, der Abteilung für medizinische und biologische Informatik des Deutschen Krebsforschungszentrums (DKFZ) und der Nachwuchsgruppe Computergestützte Chirurgie des Instituts für Anthropomatik und Robotik (IAR) am Karlsruher Institut für Technologie (KIT) entwickelt (Kenngott *et al.*, 2015). Der Rumpf und die Organmodelle wurden aus einem realen anonymisierten CT-Scan eines jungen, gesunden Mannes gewonnen. Diese Modelle sind online frei zugänglich⁴. Der Rumpf wurde durch selektives Lasersintern aus Polyamid hergestellt. Die Zusammensetzung der Organe wurde durch eine visuelle Analogskala (VAS) bestimmt, mit denen Chirurgen die Realismusgrad der Organe einschätzten. Für das Rektum wurde beispielsweise eine Mischung von 4:1 aus EcoFlex[®] 00-30 Silikon und einem Elastizitätserhöhendem Additiv (Slacker) gewählt. Für die Simulation eines Pneumo-

⁴<http://opencas.webarchiv.kit.edu/>

peritoneums stehen die gleichen Möglichkeiten wie die des ELITE-Phantoms zur Verfügung.

Kommerzielle Systeme

Da der Markt für Evaluationsmitteln für die Forschung zu klein für marktwirtschaftliche Produkte ist, haben die meisten kommerziellen Systeme die Weiterbildung von Chirurgen und Chirurgiestudenten im Fokus. Die Firma Simulab, nach eigenen Angaben Marktführer im Bereich Weichgewebesimulation, bietet Traumatrainer, Ultraschalltrainer und kleine laparoskopische Übungssysteme an⁵.

Boxtrainer, die den Bauchraum mit Instrumenten- und Endoskopzugängen simulieren, sind eine verbreitete Art von Simulatoren. SurgTrac⁶, PyruX⁷ und 3B Scientific⁸ sind Beispiele für kommerzielle Boxtrainer. Für die T9 Serie von 3B Scientific gibt es außerdem von Kyoto Kagaku Co., Ltd Organe, die unter dem Namen Abdominal Intraoperative & Laparoscopic Ultrasound Phantom *IOUS-FAN*⁹ angeboten werden.

3.5 Zusammenfassung

Im Prozess der Weichgeweberegistrierung sind eine Reihe von Problemen zu lösen. In diesem Kapitel wurden angefangen bei der 3D-Rekonstruktion, über die intraoperativen Modellbildung, bis zu der eigentlichen rigiden und nicht-rigiden Registrierung Verfahren des maschinellen Sehens und der computer-assistierte Chirurgie vorgestellt. Da die computer-assistierte Chirurgie ein noch recht junges Feld ist, finden viele existierende Methoden und Algorithmen aus der Robotik, Objekterkennung und des autonomen Fahrens hier Einzug. Dabei ist es wichtig zu bedenken, dass die Arbeitsumgebung von navigierenden Robotern und eines minimal-invasiv arbeitenden Chirurgen sich nicht unerheblich unterscheiden. Gerade in der 3D-Rekonstruktion, die auf die Erkennung von Merkmals- oder Bildbereichspaaren angewiesen ist, wird dies deutlich. Moderne Stereo-Rekonstruktionsverfahren können Räume und Gebäude schon relativ zuverlässig und mit hoher Genauigkeit vermessen. Dabei greifen sie auf die reichhaltig verfügbaren geometrischen Merkmale zurück, die in menschengemachten Strukturen häufig zu finden sind. Im Innern des Körpers gibt es eine andere Ordnung. Hier herrschen sanfte Kurven und Biegungen vor und alles ist einer Mischung von Rot- und Gelbtönen gefärbt. Blut und texturarme Oberflächen erschweren eine Rekonstruktion zusätzlich. Es ist nicht verwunderlich, dass Verfahren die

⁵<https://simulab.com>

⁶<http://www.eosurgical.com/collections/simulators-individual>

⁷<http://www.inovus.org>

⁸<https://www.3bscientific.de>

⁹<https://www.kyotokagaku.com/products/detail03/us-3.html>

Kapitel 3 Stand der Forschung

nicht für diese Umgebung ausgelegt wurden, deutlich hinter ihrer Leistung in ihrer angestammten Umgebung zurückbleiben. So ist es die Aufgabe der computergestützten Chirurgie, diese Verfahren für sich anzupassen und auch weiter zu entwickeln.

Es wurden in den letzten Jahren viele Fortschritte gemacht, aber bis ein Verfahren zur Weichgeweberegistrierung routinemäßig im Operationssaal eingesetzt werden kann, ist es noch ein weiter Weg. Diese Arbeit soll dazu beitragen, die computer-assistierte Chirurgie näher an dieses Ziel heranzubringen und damit die medizinische Versorgung in unserer Gesellschaft weiter zu verbessern.

Kapitel 4

3D-Rekonstruktion des Operations-Situs

Die Entwicklung von Stereoendoskopen eröffnet der computer-assistierten Chirurgie neue Möglichkeiten in der intraoperativen Bildgebung. Ein wichtiger Teil computergestützter Systeme ist die Bereitstellung von präoperativen Modellen während der Operation. Da sich Position, Ausrichtung und zuletzt auch die Form von Organen und Gewebestrukturen zwischen den CT oder MRT Aufnahmen und der intraoperativen Szene deutlich unterscheiden können, ist eine Registrierung dieser Daten mit der intraoperativen Szene notwendig. Um dies zu ermöglichen, müssen die Strukturen während der Operation für das Assistenzsystem erfassbar gemacht werden.

Aus Sicht der Datenqualität und -quantität würde hierbei natürlich ein intraoperatives CT den Goldstandard setzen. Doch auch wenn diese Methode es erlaubt selbst Zielstrukturen im Innern von Organen, wie Tumore, zu erfassen, ergeben sich erhebliche Nachteile für die Operation und den Patienten. Zunächst gibt es nur wenige Operationssäle, welche intraoperative CTs bereitstellen. Wie jeder Art des Röntgens, ist die Strahlenbelastung des Patienten und auch des Operationspersonals durch diese Systeme ein nicht zu vernachlässigbarer Faktor. Ein weiterer Nachteil ist, dass nur einzelne wenige oder sogar nur eine Aufnahmen gemacht werden können und die Operation für jede dieser Aufnahmen eine gewisse Zeit unterbrochen werden muss. So können dynamische Deformationen nach oder zwischen den Aufnahmen nicht erfasst werden.

Obwohl sie weniger Informationen bereitstellen, bieten Endoskope den großen Vorteil, dass sie fest im Operationsablauf verankert sind. Da der Chirurg auf das Endoskop als Bildgebung angewiesen ist, können diese Daten ohne Eingriff in den Operationsablauf gewonnen werden. Mithilfe von Stereoendoskopen können 3D-Rekonstruktionen der Organoberflächen erstellt und für die Registrierung von präoperativen Modellen genutzt werden. Diese Verknüpfung erlaubt es das Endoskopbild mit in der Tiefe verborgenen Informationen aus den präoperativen Daten zu bereichern.

4.1 Stereoendoskopie

Im Folgenden werden die wichtigsten Konzepte des stereoskopischen maschinellen Sehens beschrieben.

4.1.1 Lochkameramodell

Das Lochkameramodell ist ein einfaches mathematisches Modell, um die perspektivischen Eigenschaften einer Kamera nachzubilden (Azad *et al.*, 2007, Scharstein, 1999).

In diesem Modell werden alle Punkte der Szene mit einer geraden Linie durch das Projektionszentrum auf die Bildebene projiziert. Da es in der Realität kein unendlich kleines Projektionszentrum geben kann und übliche Kameras Linsensysteme besitzen, ist dies nur ein vereinfachtes Modell. Es bietet allerdings bei vertretbarer Abschätzung des realen Modells eine einfache und praktische Möglichkeit den Vorgang der Bilderzeugung zu beschreiben (Forsyth & Ponce, 2012).

Durch Anwendung der Strahlensätze gelangt man für die Abbildung von Objekt zu Bildebene zu

$$\begin{pmatrix} u \\ v \end{pmatrix} = \frac{f}{z} \begin{pmatrix} x \\ y \end{pmatrix} \quad (4.1)$$

Die Pixel werden im 2D *Bildkoordinatensystem* (u - und v -Achse) angegeben, dessen Ursprung in der oberen linken Ecke liegt. Punkte auf der Bildebene, die wieder in den 3D-Raum zurücktransformiert werden, befinden sich im *Kamerakoordinatensystem*, dessen Ursprung im Projektionszentrum liegt. Die x - und y -Achse des Kamerakoordinatensystems sind an der u - und v -Achse des Bildkoordinatensystems ausgerichtet und die z -Achse zeigt zur Bildebene.

4.1.2 Erweitertes Lochkameramodell

Durch die Verwendung des erweiterten Kameramodells, kann die Gleichung 4.1 allgemeiner gefasst werden. Pixel werden nicht mehr als quadratisch angenommen. In dem der Kameraparameter f für die u - und v -Achse mit f_x und f_y getrennt definiert wird, können Pixel unterschiedliche Seitenverhältnisse besitzen (Hartley & Zisserman, 2003).




Abbildung 4.1: Lochkameramodell mit Brennweite f , Objektkoordinaten x, y, z (in Kamerakoordinaten [mm]) und den Bildkoordinaten u, v (in Bildkoordinaten [Pixel]) (Reichard, 2014). Die Projektionsebene wird in positiver Position gesetzt um die Invertierung der Achsen zu vermeiden.

Außerdem wird mit der Einführung des Hauptpunktes festgelegt, wo sich der Ursprung des Bildebenenkoordinatensystems befindet. Durch diese Änderungen erhält man:

$$\begin{pmatrix} u \\ v \end{pmatrix} = \begin{pmatrix} c_x \\ c_y \end{pmatrix} + \frac{1}{z} \begin{pmatrix} f_x \cdot x \\ f_y \cdot y \end{pmatrix} \quad (4.2)$$

Diese Abbildung wird in der Literatur als Kalibrierungsmatrix K definiert. Dazu werden homogene Koordinaten verwendet, um Skalierung und Translation in einer Matrix darzustellen.

$$K = \begin{pmatrix} f_x & 0 & c_x \\ 0 & f_y & c_y \\ 0 & 0 & 1 \end{pmatrix}, \quad \begin{pmatrix} u \cdot z \\ v \cdot z \\ z \end{pmatrix} = K \begin{pmatrix} x \\ y \\ z \end{pmatrix} \quad (4.3)$$

Nachdem die intrinsischen Parameter durch die Kalibrierungsmatrix zusammengefasst wurden, müssen nun noch die extrinsischen Parameter eingearbeitet werden. Sie beschreiben die Transformation der Weltkoordinaten x_w in die Kamerakoordinaten x_k . Diese besteht aus einer Rotation R und einer Translation t :

$$\mathbf{x}_k = R \mathbf{x}_w + \mathbf{t} \quad (4.4)$$

Durch die erneute Verwendung der homogenen Koordinaten kann die Kalibrierungsmatrix und die extrinsischen Parameter in eine Projektionsmatrix P integriert werden:

$$P = K (R | \mathbf{t}), \quad \begin{pmatrix} u \cdot w \\ v \cdot w \\ w \end{pmatrix} = P \begin{pmatrix} x \\ y \\ z \\ 1 \end{pmatrix} \quad (4.5)$$

4.1.3 Optische Linsenverzerrung

Wie zuvor erwähnt, bildet das Lochkamarasystem keine optischen Verzerrungen ab, die durch Linsen des Kameraobjektivs verursacht werden. Da diese Verzerrungen aber gerade bei endoskopischen Systemen nicht zu vernachlässigen sind, wird das Modell um eine Verzerrungsfunktion δ_r erweitert, die radiale Verzerrungen der Linsen beschreibt (Bradski & Kaehler, 2008, Brown, 1966). Durch die Annahme, die Funktion δ_r sei symmetrisch, kann sie durch die geraden Koeffizienten ihrer Taylorreihe angenähert werden:

$$\begin{aligned} \begin{pmatrix} x_r \\ y_r \end{pmatrix} &= \begin{pmatrix} f_x(\tilde{x} + \delta_r(r)) + c_x \\ f_y(\tilde{y} + \delta_r(r)) + c_y \end{pmatrix} \\ \delta_r(r) &= 1 + k_1 r^2 + k_2 r^4 \\ r &= \sqrt{\tilde{x}^2 + \tilde{y}^2} \\ \begin{pmatrix} \tilde{x} \\ \tilde{y} \end{pmatrix} &= \begin{pmatrix} \frac{x - c_x}{f_x} \\ \frac{y - c_y}{f_y} \end{pmatrix} \end{aligned} \quad (4.6)$$

Hierbei sind x und y die ursprünglichen Bildkoordinaten, x_r und y_r die Bildkoordinaten unter Berücksichtigung der Verzerrung und k_1, k_2 die ersten Koeffizienten der Taylorreihe.

4.1.4 Kamerakalibrierung

Um reale Kamerasysteme präzise nutzen zu können, müssen diese zunächst kalibriert werden. Hierbei müssen intrinsische, extrinsische und Verzerrungsparameter jeder Kamera bestimmt werden. Die Methode von Zhang (2000) nutzt ein Schachbrettmuster mit bekannter Geometrie, um die Homographie zu bestimmen, welche die Transformation von dreidimensionalem Objekt zur zweidimensionalen Bildebene beschreibt. Mithilfe mehrerer Homographien, die von unterschiedlichen Aufnahmen des Schachbretts bestimmt werden, können intrinsische und extrinsische Kameraparameter analytisch berechnet werden. Da die Verzerrungsparameter nur geschätzt werden können, muss hierfür eine iterative Levenberg-Marquardt Optimierung angewendet werden (Zhang, 2000).

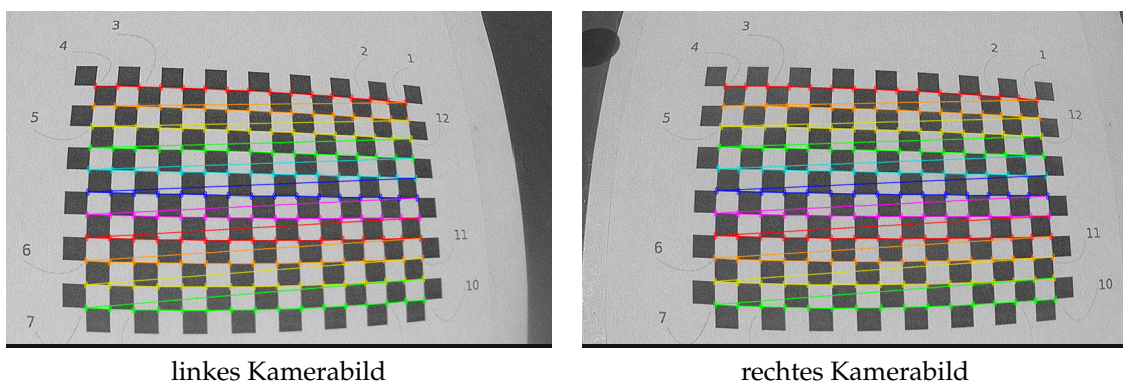


Abbildung 4.2: Die Eckpunkte des Schachbrettmusters werden auf den Kamerabildern durch Detektoren ermittelt und zur Kalibrierung der Kameraparameter genutzt.

4.1.5 Stereo-Triangulation

Ein Stereo-Kamerasystem ermöglicht es, aus zwei Bildern einer Szene, die ursprünglichen dreidimensionalen Punkte wieder zu rekonstruieren. Dazu muss zunächst die Abbildung des gesuchten Punktes in beiden Bildebenen gefunden werden. Wird nun je eine Gerade durch die Projektionszentren der Kameras und den Bildpunkten gelegt, treffen sich die Geraden im ursprünglichen Punkt der Szene (siehe Abbildung 4.3).

Um diese Geraden berechnen zu können, müssen wie in Abschnitt 4.1.4 beschrieben, die intrinsischen und extrinsischen Kameraparameter beider Kameras bestimmt werden. Anstatt die beiden Kameras separat mit einem Weltkoordinatensystem zu verbinden, wird ein virtuelles Stereo-Kameraobjekt definiert. Das lokale Koordinatensystem dieses Objektes wird identisch zum System der linken Kamera gewählt. Hierbei ist die y-Achse der Oben-Vektor, die x-Achse nach rechts gerichtet und die z-Achse in Blickrichtung der linken Kamera. Die Lage

und Ausrichtung der rechten Kamera wird nun nur noch in Relation zur linken Kamera, beziehungsweise zum Koordinatensystem des Stereo-Kamerasystems angegeben.

Mithilfe der inversen Kalibrierungsmatrizen K_l^{-1} , K_r^{-1} können zunächst die Vektoren v_l , v_r vom jeweiligem Kamerazentrum zu Bildpunkten p_l , p_r berechnet werden (Azad *et al.*, 2007):

$$\begin{aligned} v_l &= K_l^{-1} \begin{pmatrix} p_l \\ 1 \end{pmatrix} \\ v_r &= K_r^{-1} \begin{pmatrix} p_r \\ 1 \end{pmatrix} \end{aligned} \tag{4.7}$$

Für einen Schnitt, müssen beide Geraden im gleichen Koordinatensystem liegen. Dazu wird der Vektor v_r mit den extrinsischen Parametern R_r und \mathbf{t}_r in das Stereo-Kamerasystem transformiert. Damit können nun die zwei Geradengleichungen g_1 und g_2 aufgestellt werden:

$$\begin{aligned} g_1 : \mathbf{x} &= r \cdot v_l \\ g_2 : \mathbf{x} &= s \cdot (v_r + R_r^T \mathbf{t}_r) - R_r^T \mathbf{t}_r \end{aligned} \tag{4.8}$$

Der Schnittpunkt beider Geraden kann durch deren Gleichsetzung bestimmt werden:

$$- R_r^T \mathbf{t}_r = r \cdot v_l - s \cdot (v_r + R_r^T \mathbf{t}_r) \tag{4.9}$$

Unter realen Bedingungen ist es allerdings sehr unwahrscheinlich, dass sich die Geraden tatsächlich schneiden. Durch Ungenauigkeiten in der Bestimmung von v_l , v_r und Diskretisierungsfehlern liegen die Geraden windschief zueinander. Für eine Abschätzung kann statt eines Schnittpunktes nun der Mittelpunkt der kürzesten Distanzlinie zwischen den Geraden verwendet werden. Dazu wird die Gleichung 4.9 zunächst als überbestimmtes lineares Gleichungssystem formuliert und mithilfe der Methode der kleinsten Fehlerquadrate nach r und s gelöst (Azad *et al.*, 2007):

$$\begin{aligned}
(v_l - v_r + R_r^T) \begin{pmatrix} r \\ s \end{pmatrix} &= \mathbf{A} \begin{pmatrix} r \\ s \end{pmatrix} = -R_r^T \mathbf{t}_r \\
\begin{pmatrix} r \\ s \end{pmatrix} &= -(\mathbf{A}^T \mathbf{A}^{-1}) \mathbf{A}^T R_r^T \mathbf{t}
\end{aligned} \tag{4.10}$$

Mit den bestimmten Werten r und s kann nun der Punkt \mathbf{p} bestimmt werden, welcher den minimalen quadratischen Abstand zu beiden Geraden besitzt:

$$\mathbf{p} = \frac{r \cdot v_l + s \cdot (v_r + R_r^T \mathbf{t}_r) - R_r^T \mathbf{t}_r}{2} \tag{4.11}$$

4.1.6 Epipolargeometrie

Wie in Abschnitt 4.1.5 beschrieben, müssen zur Triangulierung die korrespondierenden 2D Abbildungen des ursprünglichen 3D Punktes gefunden werden. Diese Suche bedeutet mit heute üblichen Bildauflösungen von bis zu 20 Millionen Pixeln einen erheblichen Berechnungsaufwand, welcher nur schwer in Echtzeit bewältigt werden kann. Mithilfe der Epipolargeometrie, speziell den Epipolarlinien, ist es möglich den Suchraum von 2D auf 1D entlang der Epipolarlinie zu reduzieren (siehe Abbildung 4.3). Dies erhöht zudem die Robustheit der Korrespondenzsuche, da viele mögliche Korrespondenzen schon im Vorhinein ausgeschlossen werden können (Azad *et al.*, 2007).

Im Zentrum der Epipolargeometrie liegt die Fundamentalmatrix F . Sie beschreibt die Relation beider Kameraprojektionen, wie beispielsweise das Projektionszentrum der linken Kamera in der Bildebene der rechten Kamera abgebildet wird (Hartley & Zisserman, 2003). Die Fundamentalmatrix F :

$$\mathbf{F} = K_r^{-T} E K_l^{-1} \tag{4.12}$$

kann mithilfe der Kalibrierungsmatrizen beider Kameras und der Essentialmatrix E bestimmt werden. Die Essentialmatrix E beschreibt die Transformation zwischen beiden Kamerakoordinatensystemen:

$$\mathbf{E} = \begin{pmatrix} 0 & -t_{r3} & t_{r2} \\ t_{r3} & 0 & -t_{r1} \\ -t_{r2} & t_{r1} & 0 \end{pmatrix} R_r \tag{4.13}$$




Abbildung 4.3: O_L und O_R sind die Projektionszentren der beiden Kameras. Auf den blauen Bildebenen sind die Abbildungen x_L und x_R des Punktes x zu sehen. Das Korrespondenzproblem soll zu einem Punkt x_L den Punkt x_R finden, der den gleichen ursprünglichen Punkt x darstellt (Nordmann).

Die Epipolarlinien l_l und l_r können durch die Fundamentalmatrix F nun auf einfache Weise berechnet werden:

$$\begin{aligned}
 l_l &= F^T \begin{pmatrix} p_r \\ 1 \end{pmatrix} \\
 l_r &= F \begin{pmatrix} p_l \\ 1 \end{pmatrix}
 \end{aligned}
 \tag{4.14}$$

4.1.7 Rektifizierung

Die Rektifizierung von Stereo-Bildpaaren hat das Ziel, die Epipolarlinien horizontal auszurichten und korrespondierende Epipolarlinien auf die gleiche v Bildkoordinaten abzubilden (Azad *et al.*, 2007). Werden diese Bedingungen erfüllt, müssen Korrespondenzen zwischen den Bildern nur noch entlang der gleichen Bildzeile gesucht werden. Sei ein Korrespondenzpaar p_l und p_r gefunden, so kann durch ihren Abstand auf der u -Bildachse $d = p_{u_l} - p_{u_r}$, welcher auch Disparität genannt wird, der ursprüngliche 3D-Punkt eindeutig trianguliert werden.

Um die zuvor genannten Bedingungen zu erfüllen müssen zwei Homographien bestimmt werden, welche die Bildebenen auf neue, rektifizierte Bildebenen abbilden. Diese Homographien können beispielsweise mit dem Verfahren von Fusiel-

Io *et al.* (2000) berechnet werden, welches die Kameras virtuell bewegt, um die Epipole horizontal ins Unendliche zu verschieben.

4.2 Neuronale Netze

In Abschnitt 4.1 wurde beschrieben, wie 3D-Punkte aus Stereobild-Korrespondenzen rekonstruiert werden können. Zur Lösung des Korrespondenzproblems wird in Abschnitt 4.3 ein Verfahren auf Basis neuronaler Netze vorgestellt. Deshalb werden im Folgenden die wichtigsten und relevanten Konzepte der künstlichen neuronalen Netze vorgestellt.

4.2.1 Perzeptron




Abbildung 4.4: Ein Perzeptron besitzt eine beliebige Anzahl von Eingängen und einen Ausgang. Mithilfe der Aktivierungsfunktion Φ wird bestimmt, ob der Ausgang eine 1 oder eine 0 annimmt.

Rosenblatt (1958) entwickelte in den 1950er und 1960er Jahren das Modell des Perzeptrons - eines künstlichen Neurons (Abbildung 4.4). Ein Perzeptron besitzt eine beliebige Anzahl x_1, x_2, \dots, x_n von Eingängen, aus denen mit einer einfachen Regel eine Ausgabe erzeugt wird. Dazu wird zunächst jedem Eingang x_i eine Gewichtung w_i zugeordnet, die den Einfluss der verschiedenen Eingaben beschreiben. Aus diesen Werten wird nun die gewichtete Summe $\sum_i w_i x_i$ über alle Eingaben gebildet. Ist diese Summe größer als ein festgelegter Schwellwert, so wird der Ausgang des Perzeptrons auf 1 gesetzt. Ist sie darunter, nimmt der Ausgang eine 0 an (Nielsen, 2015, Duda *et al.*, 2001):

$$Ausgang = \begin{cases} 0, & \text{wenn } \sum_i w_i x_i \leq \text{Schwellwert} \\ 1, & \text{wenn } \sum_i w_i x_i > \text{Schwellwert} \end{cases} \quad (4.15)$$

Der Schwellwert wird oft als festgelegte Neigung b (*bias* genannt) des Neurons beschrieben:

$$\text{Ausgang} = \begin{cases} 0, & \text{wenn } \sum_i w_i x_i + b \leq 0 \\ 1, & \text{wenn } \sum_i w_i x_i + b > 0 \end{cases} \quad (4.16)$$

Moderne neuronale Netze werden üblicher Weise mit einem Gradientenabstiegsverfahren trainiert. Die Aktivierungsfunktion der Perzeptronen ist zwar einfach zu berechnen, kann aber durch ihre Unstetigkeit nicht abgeleitet werden. Aus diesem Grund werden in der Regel, wie auch in dieser Arbeit, eine der folgenden Funktionen als Aktivierungsfunktion für künstliche Neuronen gewählt (Dieleman *et al.*, 2015):

Sigmoid $\Phi(x) = \frac{1}{1+e^{-x}}$

ReLU $\Phi(x) = \max(0, x)$

Tanh $\Phi(x) = \tanh(x)$

Softmax $\Phi(x)_j = \frac{e^{x_j}}{\sum_{n=0}^N e^{x_n}}$,

N ist hierbei die Anzahl der Ausgabeneuronen und j das aktuell betrachtete Ausgabeneuron.

4.2.2 Mehrlagige neuronale Netze

Durch die Verknüpfung von mehreren Perzeptronen können künstliche neuronale Netze erstellt werden, deren Möglichkeiten weit über die der einzelnen Perzeptronen hinausgehen. Wie in Abbildung 4.5 zu sehen, werden Netze üblicherweise in Schichten dargestellt. Neben einer immer vorhandenen Ein- und Ausgabeschicht, besitzen Mehrlagige Perzeptronen, auch Multilayer Perceptron (MLP) genannt, noch eine beliebige Anzahl von verdeckten Schichten, die sich zwischen der Ein- und Ausgabeschicht befinden. Eine einzelne Neuronenschicht kann eine Eingabe nur in linear separierbare Klassen teilen. Mehrlagige Netze können hingegen theoretisch die optimale Lösung für jedes Klassifikationsproblem bestimmen.

Nach Duda *et al.* (2001) wird mit einer Eingabe $x_j \in \mathbb{R}^N = [x_j^0, x_j^1, \dots, x_j^K]$ an Schicht j die Ausgabe $y_j \in \mathbb{R}^M$ wie folgt berechnet:




Abbildung 4.5: Durch die Verbindungen von mehreren Perzeptronen können Netze gebildet werden, die komplexe Aufgaben bewältigen können.

$$y_j = \Phi(z_j)$$

$$z_j = W_j \cdot x_j + b_j$$

$$b_j = (b_j^1, b_j^2, \dots, b_j^M)$$

(4.17)

$$W_j = \begin{pmatrix} w_j^{1,1} & \dots & w_j^{K,1} \\ \vdots & & \vdots \\ w_j^{1,M} & \dots & w_j^{K,M} \end{pmatrix}$$

wobei Φ die Aktivierungsfunktion, $W_j \in \mathbb{R}^{K \times M}$ die Gewichtsmatrix der K Eingänge von M Neuronen der Schicht j und $b_j \in \mathbb{R}^M$ der Bias-Vektor der Neuronen der Schicht j ist.

4.2.3 Training

Generell kann ein neuronales Netz beliebige Funktionen berechnen. Um ein Netz nun aber auf ein bestimmtes Problem zu trainieren, müssen alle Gewichte und Bias-Werte des Netzes für dieses Problem bestimmt werden. Die Optimierung dieser Parameter wird dabei meist mit einer Form des Gradientenabstiegs, *Back-propagation* oder Fehlerrückführung genannt, durchgeführt.

Dabei werden an das zunächst untrainierte und mit zufälligen Werten initialisierte Netz nach und nach Trainingsbeispielen angelegt und die erwartete mit der tatsächlichen Ausgabe verglichen. Die Differenz zwischen erwarteten Werten t (*target*) und gemessenen Werten y wird dann durch optimieren der Netzparameter minimiert. Um diese Differenz messbar zu machen muss eine Kostenfunktion C definiert werden. Dafür gibt es mehrere Ansätze (Dieleman *et al.*, 2015):

Absoluter Fehler $C(y, t) = |y - t|$

Quadratischer Fehler $C(y, t) = (y - t)^2$

Kategorische Kreuz-Entropie $C(y, t)_i = - \sum_j t_{i,j} \log(y_{i,j})$
(für Klassifikationsprobleme)

Wurde eine Kostenfunktion gewählt, kann das Netzwerk trainiert bzw. die Kostenfunktion minimiert werden, indem die Gewichte und Bias-Werte in Richtung des Gradientenabstiegs geändert werden:

$$\begin{aligned}\Delta W_j &= -\eta \frac{\partial C}{\partial W_j} \\ \Delta b_j &= -\eta \frac{\partial C}{\partial b_j}\end{aligned}\tag{4.18}$$

$$W_{j,neu} = W_j + \Delta W_j$$

$$b_{j,neu} = b_j + \Delta b_j$$

Hierbei ist η die Lernrate und damit verantwortlich für die Größe der Lernschritte, W_{neu} die geänderten Gewichte und b_{neu} die geänderten Bias-Werte. Um die partiellen Ableitungen $\frac{\partial C}{\partial W_j}$ und $\frac{\partial C}{\partial b_j}$ zu berechnen wird der zuvor erwähnte Backpropagation-Algorithmus verwendet. Dieser besteht im Kern aus den folgenden vier Gleichungen. δ_j beschreibt im Folgenden die Fehler der Neuronen der Schicht j und ist definiert als $\delta_j \equiv \frac{\partial C}{\partial z_j}$. Für eine genauere Beschreibung des Verfahrens siehe Duda *et al.* (2001) und Nielsen (2015).

$$\begin{aligned}\delta_J &= \nabla_y C \odot \Phi'(z_J) \\ \delta_j &= ((W_j)^T \delta_{j+1}) \odot \Phi'(z_j) \\ \frac{\partial C}{\partial b_j} &= \delta_j \\ \frac{\partial C}{\partial W_j} &= y_{j-1} \delta_j\end{aligned}\tag{4.19}$$

$\nabla_y C$ ist ein Vektor dessen Einträge die partiellen Ableitungen von $\partial C / \partial y_j$ sind. Mit der quadratischen Fehlerfunktion wäre $\nabla_y C$ somit $\nabla_y C = (y_j - t)$. Zur Veranschaulichung wird im Folgenden der Ablauf des Backpropagation-Verfahrens beschrieben:

- 1. Eingabe x_1 :** Das Trainingsbeispiel wird an die Eingabeschicht x_1 angelegt.
- 2. Vorwärtsberechnung:** Berechne $z_j = W_j \cdot x_j + b_j$ und $y_j = \Phi(z_j)$ für alle Schichten $j = 1, 2, \dots, J$.
- 3. Ausgabefehler δ_J :** Bestimme den Ausgabefehler der letzten Schicht: $\delta_J = \nabla_a C \odot \Phi'(z_J)$.
- 4. Backpropagation:** Berechne die Fehler $\delta_j = ((W_j)^T \delta_{j+1}) \odot \Phi'(z_j)$ der inneren Schichten, mithilfe des Fehlers der jeweils nachfolgenden Schicht δ_{j+1} .
- 5. Ausgabe:** Der Gradient der Kostenfunktion $\frac{\partial C}{\partial b_j} = \delta_j$ für die Gewichte und $\frac{\partial C}{\partial W_j} = y_{j-1} \delta_j$ für die Bias-Werte können nun für jede Schicht j bestimmt werden.

Für den Lernschritt in Gleichung 4.18 gibt es mehrere Variationen um das Konvergenzverhalten zu beeinflussen. Hierzu sollen zwei bekannte Varianten vorgestellt werden. Zunächst das Nesterov Momentum (Nesterov, 1983):

$$\begin{aligned}v_{neu} &= m \cdot v - \eta \frac{\partial C}{\partial W_j} \\ W_{j,neu} &= W_j + m \cdot v_{neu} - \eta \frac{\partial C}{\partial W_j}\end{aligned}\tag{4.20}$$

wobei m ein vom Nutzer festgelegtes Momentum ist. Die Größe des Momentums m bestimmt wie stark die Gewichte über mehrere Schritte geglättet werden. Die zweite Variante ist die Adam Regel (Kingma & Ba, 2014):

$$\begin{aligned}v_{neu} &= \frac{\beta_2 v + (1 - \beta_2) \cdot \left(\frac{\partial C}{\partial W_j}\right)^2}{1 - \beta_2} \\m_{neu} &= \frac{\beta_1 m + (1 - \beta_1) \cdot \frac{\partial C}{\partial W_j}}{1 - \beta_1} \\W_{j,neu} &= W_j - \frac{\eta}{\sqrt{v_{neu} + \epsilon}} \cdot m_{neu}\end{aligned}\tag{4.21}$$

wobei β_1 und β_2 wiederum vom Nutzer festgelegte Werte sind, welche dazu genutzt werden können um das Konvergenzverhalten zu verbessern.

4.2.4 Convolutional Neuronale Netze

In Abschnitt 4.2.2 wurden mehrlagige neuronale Netze vorgestellt. Diese sind in der Regel voll vernetzt, was bedeutet, dass jedes Neuron der Schicht j mit jedem Neuron der Schicht $j + 1$ verbunden ist. Diese Struktur generalisiert zwar gut bei beliebigen Problemen, lässt andererseits interessante Informationen über den Zusammenhang der Eingabedaten ungenutzt. Des Weiteren stoßen voll vernetzte Netze mit zunehmender Anzahl der verdeckten Schichten an die Grenzen des Backpropagation Algorithmus. Durch die vielen Schichten wird der berechnete Gradient zunehmend instabil, was auch „vanishing gradient problem“ genannt wird (Hochreiter *et al.*, 2001). Dies hat zur Folge, dass die Gewichte und Bias-Werte der ersten Schichten entweder deutlich zu langsam oder deutlich zu schnell geändert werden.

In der Bildverarbeitung hat sich aus diesen Gründen eine spezielle Art von neuronalen Netzen etabliert: die „Convolutional Neural Networks (CNNs)“ (LeCun *et al.*, 1998). CNNs nutzen drei Prinzipien, lokale rezeptive Felder, geteilte Gewichte und „Pooling“, um Probleme in der Bilderkennung effektiver zu lösen. Im Folgenden werden diese drei Prinzipien erläutert.

Lokale Rezeptive Felder

Wie bereits erwähnt, werden bei vollvermaschten Netzen keine a priori Informationen über die Eingabedaten genutzt. In der Bildverarbeitung spielt es allerdings eine große Rolle in welchem Bereich sich ein Bildpunkt befindet und welche Bildpunkte seine Nachbarn sind. Ähnlich wie im menschliche Auge sollen

CNNs diese lokalen Bildbereiche, auch *lokale rezeptive Felder* genannt, in ihrer Lösungsfindung mit einbeziehen (Lindeberg, 2013, Hubel, 1963). In Abbildung 4.6 ist gezeigt, wie die Eingabeneuronen statt eines Vektors auch als 2D Struktur dargestellt werden kann, die den Pixeln des Eingabebilds entsprechen - in diesem Fall 10x10 Neuronen.

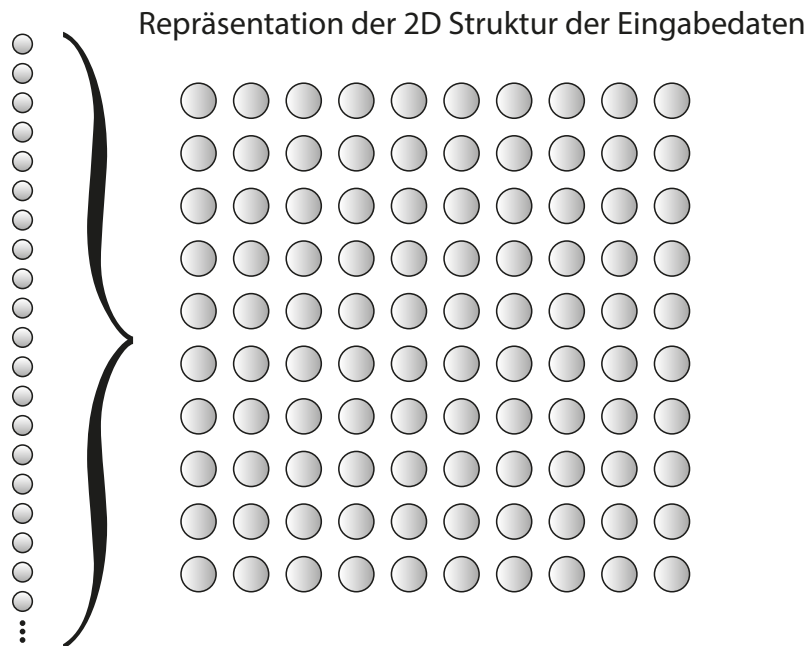


Abbildung 4.6: Statt eines eindimensionalen Eingabevektors, wird die inhärente Struktur der Daten, in diesem Fall die lokalen Beziehungen der zweidimensionalen Bildpunkte, genutzt.

Die Neuronen der ersten verdeckten Schicht werden nun nicht mehr mit allen Eingabeneuronen verbunden, sondern beziehen sich nur noch auf die Neuronen ihres rezeptiven Felds (siehe Abbildung 4.7). Hier sind starke Parallelen zu den klassischen Bildfaltungsverfahren wie beispielsweise des Sobelfilters zu erkennen (Sobel & Feldman, 1968). Wie in der Abbildung zu sehen ist, verkleinert sich die verdeckte Schicht, da die äußeren Neuronen kein vollständiges rezeptives Feld besitzen, um $f_{x/y} - 1$ wobei $f_{x/y}$ die Größe des Filterkerns ist. Als Variation kann die Schrittweite der Faltung angepasst werden. So wird bei einer Schrittweite von 2 nur noch von jedem zweiten Neuron ein rezeptives Feld mit zugehörigem verdeckten Neuron erstellt. Dies verkleinert die verdeckte Schicht natürlich zusätzlich um den Faktor der Schrittweite.

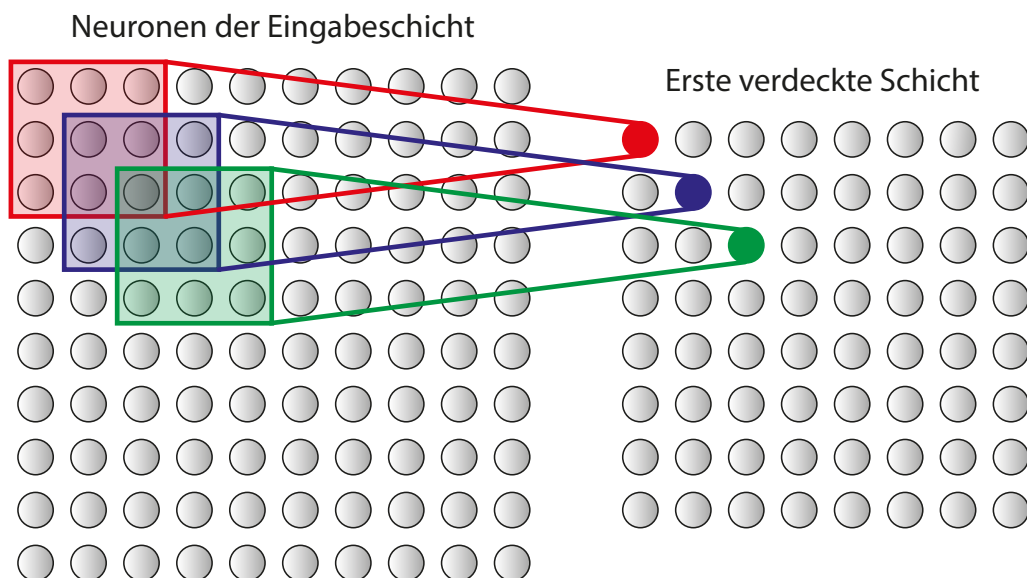


Abbildung 4.7: Bei der Nutzung des lokalen rezeptiven Felds werden nicht mehr alle Neuronen zweier Schichten miteinander verbunden. Die Abhängigkeiten der Neuronen einer Schicht werden durch einen Faltungskern um das entsprechende Neuron begrenzt, welcher die lokale Abhängigkeit der Datenpunkte repräsentiert.

Geteilte Gewichte

Im vorhergehenden Abschnitt wurde erläutert, dass jedes verdeckte Neuron mit dem dazugehörigen rezeptiven Feld der Eingabeneuronen verbunden ist. Für ein Feld der Größe 3x3 bedeutet dies, dass dazu 9 Gewichte und ein Bias-Wert für jedes verdeckte Neuron bestimmt werden müssen. Anstatt diese Werte nun für jedes Neuron einzeln zu bestimmen werden sie für alle Neuronen einer Schicht geteilt. Diese geteilten Gewichte und Bias-Werte werden in der Literatur mit *shared weights and biases* bezeichnet. Dies hat zur Folge, dass verschiedene Bereiche des Eingabebildes mit dem gleichen Filterschema verarbeitet werden. Im Fall des zuvor erwähnten Sobelfilters, würde mit der entsprechenden Gewichtskonfiguration, ein Kantensfilter auf das Eingabebild angewendet.

Ein weiterer Vorteil der geteilten Gewichte ist die Reduktion der zu lernenden Netzparameter. Im Beispiel von Abbildung 4.7 müssen statt $(8 \cdot 8) \cdot 10 = 640$ Parameter, nur noch $1 \cdot 10$ Parameter für die verdeckte Schicht gelernt werden. Die Ausgabe der verdeckten Neuronen mit geteilten Gewichten und Bias-Werten wird wie folgt berechnet:

$$y^{p,q} = \Phi \left(\sum_{k=0}^i \sum_{m=0}^i w^{k,m} y^{p+k,q+m} + b \right) \quad (4.22)$$

Die Operation in Gleichung 4.22 gibt den CNNs zugleich ihren Namen. Sie wird in der Mathematik auch als Faltung bezeichnet (Faltung - Convolution).

Pooling

Nach einer Convolution Schicht wird oft eine sogenannte *Pooling* Schicht angehängt. Sie haben die Aufgabe, die Ergebnisse der *Convolutional* Schicht zu vereinfachen und zu bündeln. Dazu werden Neuronen zu Regionen zusammengefasst und ein gemeinsamer Wert stellvertretend für alle beteiligten Neuronen ermittelt. Beim Max-Pooling entspricht der gebündelte Wert dem maximalen Ausgabewert innerhalb der Region. Ein Beispiel einer Max-Pooling Schicht mit 2x2 Regionen kann in Abbildung 4.8 betrachtet werden. Durch das zusammenfassen der Neuronenausgaben wird natürlich die Größe der Schicht verkleinert. In diesem Beispiel von 10x10 auf 5x5 Neuronen.

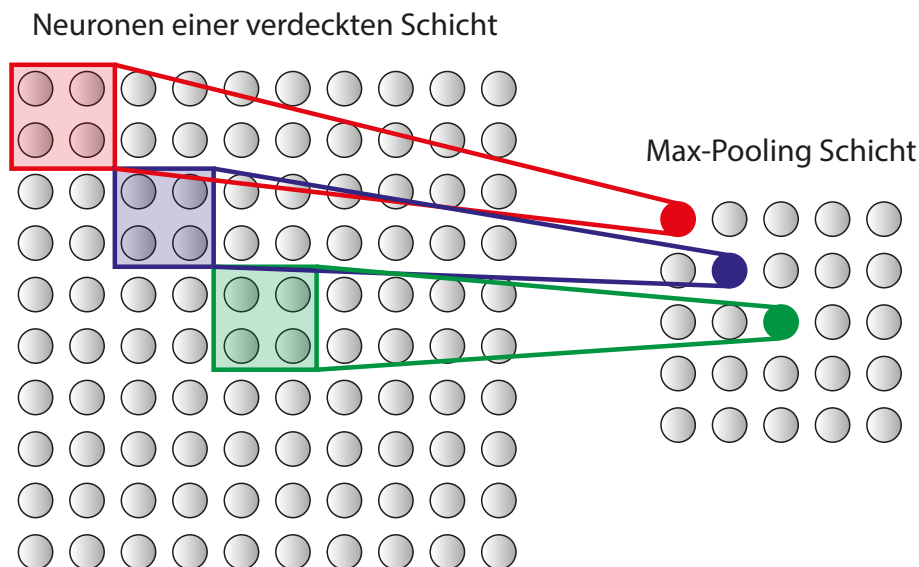


Abbildung 4.8: Nach einer faltenden Schicht wird oft ein sog. Pooling angewendet. Dabei werden die Ausgaben der vorherigen Schicht immer zu Bündeln zusammengefasst. Hier werden beispielsweise je 2x2 Werte zu einem Wert in der Pooling Schicht. Max-Pooling bedeutet, dass der größte Wert des Bündels in die neue Schicht übernommen wird.

Ein anderes weit verbreitetes Verfahren ist das L2 Pooling. Hier wird anstatt des Maximums der Neuronenausgaben, die Quadratwurzel der summierten Quadrate der Ausgabewerte einer Region als Bündelungsmaß verwendet:

$$y^{p,q} = \sqrt{\sum_{k=0}^i \sum_{m=0}^i y^{p+k,q+m}} \quad (4.23)$$

4.3 CNNs für die endoskopische Stereorekonstruktion

In diesem Abschnitt wird eine Methode zur endoskopischen Stereorekonstruktion vorgestellt. Inspiriert von der erfolgreichen Arbeit von Mayer *et al.* (2016) über die Nutzung von CNNs für die Berechnung des optischen Flusses und der Disparitätenschätzung, wurden diese Methoden für die Herausforderungen der endoskopischen Bildgebung erweitert. Hierbei wurde besonders daran geforscht, wie mit endoskopischen Simulationsdaten und realen endoskopischen Aufnahmen die Leistung des Systems deutlich verbessert werden kann. Im Anschluss zur Methodik werden Evaluationsergebnisse vorgestellt, bei denen das Verfahren auf Basis eines öffentlichen Datensatzes (Maier-Hein *et al.*, 2014) mit anderen Verfahren auf dem Stand der Forschung verglichen wird.

4.3.1 Methoden

Bei maschinellen Lernverfahren spielen die Qualität und Quantität der Trainingsdaten eine tragende Rolle. Dies trifft in besonderem Maße auf neuronale Netze und CNNs zu. Da die Netze eine enorme Anzahl an lernbaren Parametern (Gewichte und Bias-Werte, siehe Abschnitt 4.2.3) besitzen, sind sie auch auf eine große Anzahl an Trainingsbeispielen angewiesen. Aus diesem Grund spielt die Erzeugung und Wahl der Trainingsdaten für einen CNN-Disparitätsschätzer eine ebenso große Rolle wie Wahl der Netzwerkarchitektur.

4.3.2 Akquirierung von Trainingsdaten

Um das Netzwerk auf die charakteristischen Eigenschaften und Probleme der endoskopischen Bildgebung zu optimieren, sind Trainingsdaten von typischen endoskopischen Szenen notwendig. Während die Beschaffung von großen Datensätzen mit stereoendoskopischen Bilddaten durchaus möglich wäre, so fehlt diesen Daten ein wichtiger Bestandteil des Trainings: Die Referenzwerte der Disparitätskarten. Praktisch stellt es sich als sehr schwierig heraus, während eines endoskopischen Eingriffs Referenzdaten der Szenengeometrie zu erhalten. Diese müssten zudem in Relation zur endoskopischen Abbildung ermittelt werden.

Aus diesem Grund werden im Folgenden mehrere Ansätze vorgestellt, um ein Netzwerk mit unterschiedlichen Trainingsdaten zu optimieren (siehe Abbildung 4.9). Als erstes werden hierbei die großen öffentlichen Datensätze (Mayer *et al.*, 2016) aus der allgemeinen Domäne des maschinellen Sehens genutzt, um das Netzwerk einem Vortraining zu unterziehen. Danach wird das Netzwerk aus einer Kombination aus synthetisierten endoskopischen Bilddaten und realen endoskopischen Bilddaten mit berechneten dünnbesetzten Referenzdaten spezialisiert.

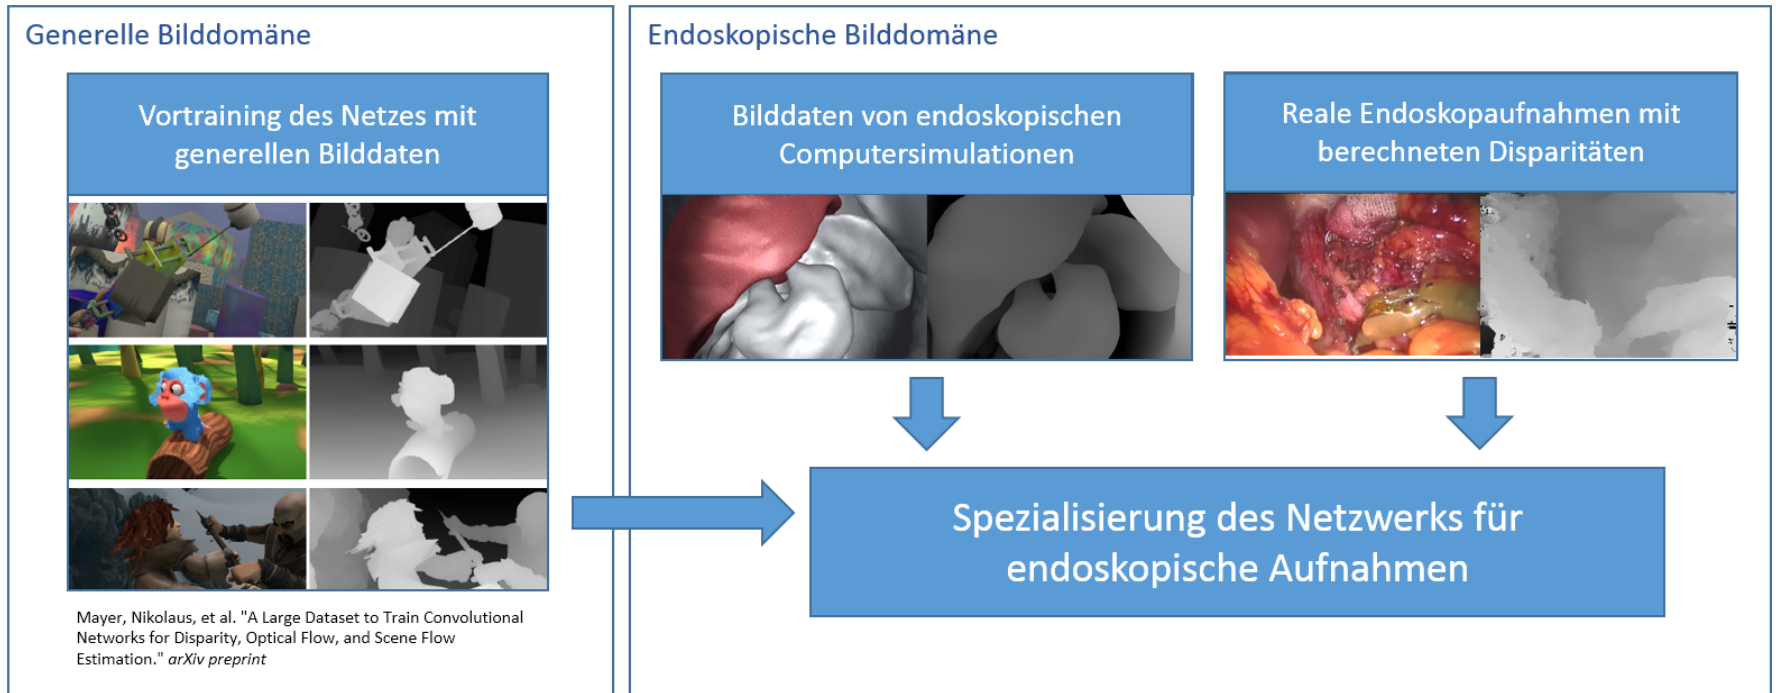


Abbildung 4.9: Trainingsdaten für die endoskopische Stereorekonstruktion]

Synthetische endoskopische Bilddaten

Um eine große Anzahl von synthetischen Trainingsdaten erzeugen zu können, wurde ein Bildsynthese-Framework auf Basis der Unity3D¹ Spiel-Engine entwickelt (Weiss, 2017). Die fotorealistische Bildsynthese ist mittlerweile ein großer und wichtiger Teil der Computergrafik (Lyu & Farid, 2005). Unity3D macht es möglich, viele dieser nützlichen und ansonsten schwer nachzubildenden Verfahren zu nutzen ohne in monatelange Eigenentwicklungen investieren zu müssen. Einige zu nennenden Vorteile sind:

- Nutzerfreundlicher Szeneneditor
- Einfache Bereitstellung von Texturierungsverfahren
- Eingebaute Verbindung zur OpenGL-Shading Pipeline
- Virtuelle Kameraobjekte erlauben einfaches Rendering der Szene

Das Kernstück des Frameworks ist das dem Endoskop nachempfundene Stereokamerasystem. Es besteht aus zwei virtuellen Kameraobjekten und einer fokussierten Lichtquelle, welche sich zwischen den Kameras befindet. Um den realen Daten möglichst nahe zu kommen, wurden die Kameraparameter eines Richard Wolf (PAL/SD) Stereoendoskops erfasst und für die virtuellen Kameras verwendet. Dafür wurden eigens Optionsmenüs in Unity3D angelegt, um Änderungen transparent und einfach zu ermöglichen (siehe Abbildung 4.10). Da Unity3D eine Kamera über einen Field of View (FOV) Parameter definiert, mussten intrinsischen Kameraparameter zunächst in einem Nachverarbeitungsschritt in diese Repräsentation umgewandelt werden.

Da das System später Organe und Gewebestrukturen rekonstruieren soll, wurden für die virtuelle Szene auch Organmodelle aus CT-Scans genutzt. Da aus CT-Daten leider nur geometrische Informationen hervorgehen, mussten Texturen auf eine andere Weise erzeugt werden. Aus endoskopischen Bildern von realen Operationen konnten Texturstücke von Organen gewonnen werden. Durch eine Nachverarbeitung zu nahtlos kachelbaren Texturen, konnten daraus optisch überzeugende Organtexturen generiert werden. Dies hat natürlich den Nachteil, dass die Beleuchtung der ursprünglichen Szene fest in den Bilddaten eingepreßt ist. Physikalisch korrekter wäre die Nutzung der Bidirektionale Reflektionsverteilungsfunktionen (BRDF, *bidirectional reflection distribution functions*), um die Materialeigenschaften direkt zu messen (Schlick, 1994, Ngan *et al.*, 2005). Dazu wären allerdings Messungen mit aufwendigen Versuchsaufbauten notwendig, welche gerade im Operationsraum schwer durchzuführen sind.

Besonderes Augenmerk wurde auf die schwierigen Beleuchtungsbedingungen bei der endoskopischen Bildgebung gerichtet. Hier spielt vor allem das Zusammenspiel von starker Punktlichtquelle mit dem feuchten Gewebe eine wichtige Rolle, da es hierbei zu großen Glanzlichtern auf den Bildern kommen kann.

¹<https://unity3d.com>

4.3 CNNs für die endoskopische Stereorekonstruktion

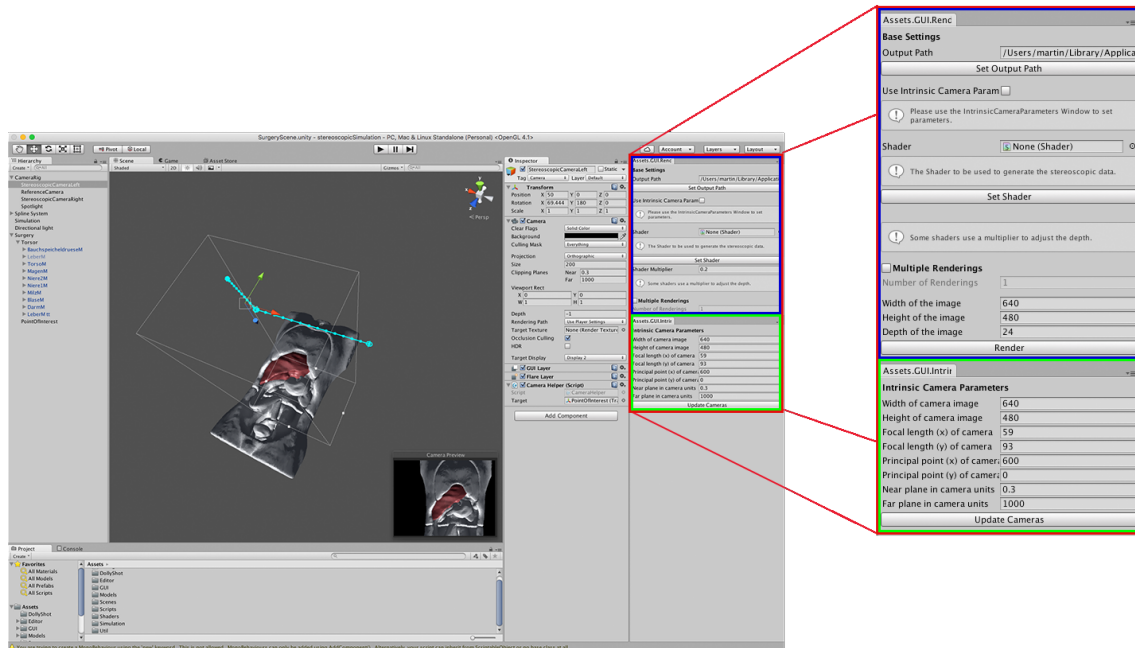


Abbildung 4.10: Das Unity3D-Interface wurden um zusätzliche Optionsfenster erweitert, um Anpassungen an den Simulationsparametern schnell und einfach durchführen zu können (Weiss, 2017).

Glanzlichter stellen Systeme zur Stereo-Korrespondenzfindung auf eine harte Probe: Durch den Reflexionswinkel auf der Organoberfläche sind Glanzlichter in der linken und rechten Kamera an unterschiedlichen Oberflächenteilen zu finden. Eine naive Zuordnung der von den Glanzlichtern betroffenen Bildbereiche würde somit zu falschen Disparitätswerten führen (siehe Abbildung 4.11). Aus diesem Grund ist es wichtig viele unterschiedliche Trainingsbeispiele dieses Phänomens zu generieren und das System darauf zu sensibilisieren.

Um auf eine einfache Weise viele Trainingsdaten generieren zu können, wurde ein Wegpunktsystem entworfen. Der Nutzer kann eine beliebige Anzahl von Wegpunkten in der Szene definieren, entlang deren sich das Stereokamerasystem in einer simulierten Kamerafahrt entlang bewegt (siehe Abbildung 4.12). In den in Abbildung 4.10 gezeigten Optionsfenstern, kann der Nutzer anschließend die Anzahl der Aufnahmen für die gesamte Sequenz definieren. Die Positionen der Aufnahmen werden dann in gleichen Abständen auf das Wegpunktsystem verteilt, wobei hierbei linear zwischen den Positionen der einzelnen Wegpunkte interpoliert wird.

Für die Berechnung der Disparitäten wurde ein eigenes Shaderprogramm entworfen. Es wäre zwar möglich, die Disparitäten direkt aus dem Tiefenpuffer der OpenGL-Pipeline zu gewinnen, was allerdings unnötige Ungenauigkeiten erzeugen würde. Da der Tiefenpuffer oftmals nur eine Auflösung von 8 Bit besitzt und die Tiefe logarithmisch repräsentiert, hat die Entfernung zur Kamera einen großen Einfluss auf Diskretisierungsfehler. Da die genaue Bestimmung (Diskreti-

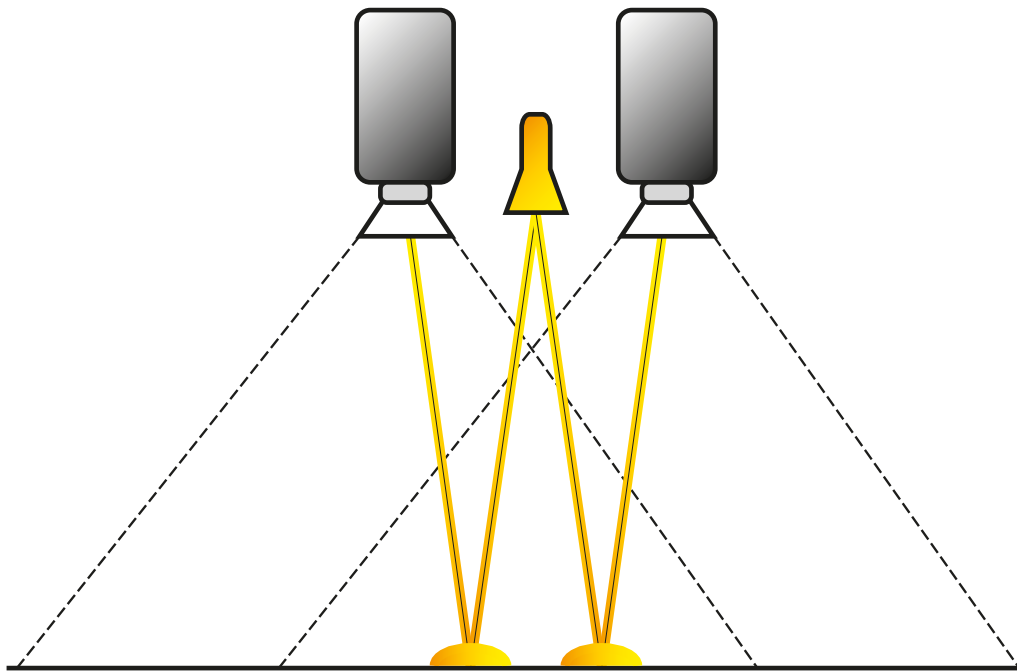


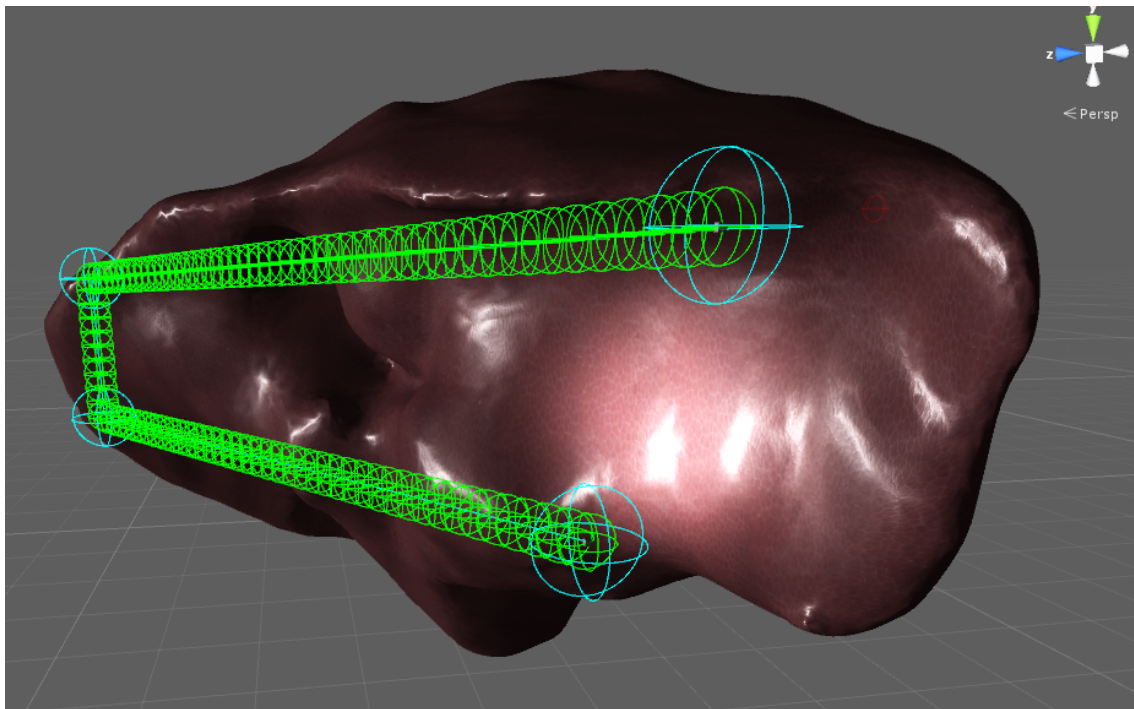
Abbildung 4.11: Wie in diesem Beispiel zu sehen ist, werden durch die unterschiedlichen Positionen der Kameras Glanzlichter an verschiedenen Positionen erzeugt. Bei einer Korrespondenzschätzung der Glanzpunkte würde dieser Versatz fälschlicherweise mitberücksichtigt. Somit würden deutlich höhere Disparitätswerte ermittelt werden, als eigentlich von der Geometrie vorgegeben sind.

sierungsfehler durch die begrenzte Auflösung von Datentypen bleiben natürlich bestehen) mit geringem Aufwand in einem Hardware-Shader möglich ist, wurde diese Variante gewählt (siehe Abbildung 4.13).


Durch die beschriebenen Methoden und Ansätze können große Mengen an synthetischen endoskopischen Bilddaten mit geringem Aufwand generiert werden. Für die Erzeugung einer Bildserie von 1000 Bildern benötigt das System rund 10 Minuten. Die Einbettung in Unity3D erlaubt zudem eine einfache Portierung auf andere Systeme und auch die Erweiterung des Systems durch andere Anwender. In Abbildung 4.12 ist eine Beispielszene mit Wegpunktsystem und den Ausgabedaten dargestellt.

Dünnbesetzte Referenzkarten für reale endoskopische Bilddaten

Im vorhergehenden Abschnitt wurde beschrieben, wie eine große Anzahl von synthetischen Trainingsdaten generiert werden kann. Die so generierten Bilder sind allerdings nur eine grobe Approximation der realen optischen Eigenschaften des Endoskops und den Materialeigenschaften der betrachteten Organe und



Kamerafahrt entlang eines Lebermodells



linkes Kamerabild

rechtes Kamerabild

Disparitätskarte

Abbildung 4.12: Mit dem Szeneneditor können Kamerafahrten entlang einzelner oder mehrerer Organmodellen definiert werden. Für dieses Modell wurden reale Texturen einer Schweineleber genutzt. Durch Unity3D-Shader wurden Glanzlichter hinzugefügt, um den Charakter von feuchtem Gewebe zu simulieren. Für jede Position wird ein linkes und rechtes Kamerabild, sowie eine Disparitätskarte (hier für die linke Kamera) generiert.

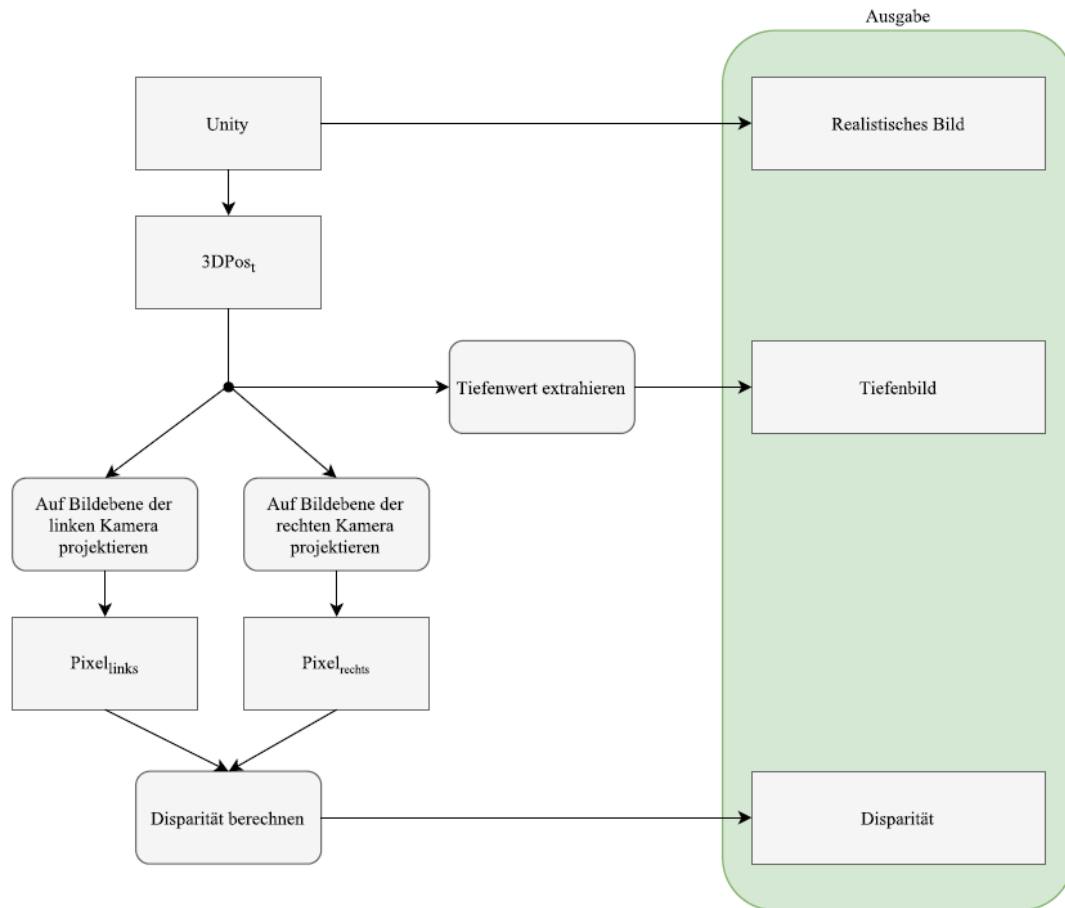


Abbildung 4.13: Flussdiagramm des entworfenen OpenGL Shaders zur Berechnung der Disparitätswerte (Weiss, 2017). Das System generiert RGB-Bilder für beide Kameras, eine Disparitätskarte im Binärformat und ein Tiefenbild für eine mögliche menschliche Plausibilitätsprüfung.

Gewebestrukturen. Aus diesem Grund wird im Folgenden ein Verfahren beschrieben, mit dem zusätzlich zu den virtuellen Daten auch reale Bilddaten für das Training genutzt werden können.

Wie schon zuvor erwähnt, existiert zwar eine substantielle Anzahl von endoskopischen Bilddaten, welche aber keine Referenz für die Disparitätskarten vorweisen. Um diese Daten trotzdem für das Training nutzbar zu machen, sollen robust erfassbare Landmarken für die Schätzung einer dünnbesetzten Referenzkarte genutzt werden. Damit wird das schwierig lösbare Problem der dichten Stereorekonstruktion auf das einfachere Problem des Landmarken-Matchings reduziert.

SIFT (Lowe, 1999) und SURF (Bay *et al.*, 2006) Merkmalsdetektoren und -deskriptoren sind eine häufig genutzte Möglichkeit, schnell und robust lokale Merkmale aus Bildern zu extrahieren. Auch für den hier vorgesehenen Einsatz, müs-




Abbildung 4.14: SIFT und SURF Merkmalsdetektoren und die *nearest neighbor* Suche wurden genutzt, um dünnbesetzte aber akurate Disparitätskarten von vorhandenen endoskopischen Stereoaufnahmen zu erstellen.

sen zunächst die SIFT und SURF Merkmale im linken und rechten Bild getrennt voneinander detektiert werden. Merkmalsdeskriptoren dienen im Anschluss als Ähnlichkeitsmaß, um Merkmale in den beiden Bildern vergleichen zu können. Zusammen mit einer Nearest Neighbor Suche (Ertel, 2016) können damit korrespondierende Punkte im linken und rechten Kamerabild gefunden werden (Abbildung 4.14). Die Suche wird außerdem auf den rektifizierten Bilddaten (siehe Abschnitt 4.1.7) ausgeführt, um den Umstand zu nutzen, dass Korrespondenzen auf derselben Bildzeile (y -Achse), oder bedingt durch kleine Abbildungsfehler zumindest in den benachbarten Bildzeilen befinden müssen. Die Qualität der Korrespondenzen kann durch eine obere Schranke in der euklidischen Distanz zwischen den beiden Merkmalsdeskriptoren gesteuert werden. Umso restriktiver dabei selektiert wird, werden natürlich auch weniger Korrespondenzen gefunden. So gilt es die Balance zwischen Qualität und Anzahl der Korrespondenzen zu finden. Mit einer akzeptablen Qualität konnten je endoskopischem Stereobild 20-300 Korrespondenzen gefunden werden.

Wie in Abschnitt 4.3.2 sind auch hier Glanzlichter von besonderer Bedeutung. Durch die unterschiedlichen Positionen der Kameras relativ zur Lichtquelle, zeigen sich mögliche Glanzlichter in den Kamerabildern in unterschiedlichen Oberflächenbereichen. Dies betrifft auch die Korrespondenzfindung über die SIFT und SURF Merkmale, da potenziell Ränder von Glanzlichtern als korrespondierende Merkmale gefunden werden, die eigentlich aber unterschiedliche Oberflächenpunkte beschreiben. Um diesem Problem zu begegnen werden zwei Nachbearbeitungsschritte genutzt:

Gefundene Merkmale die eine niedrige Sättigung und eine hohe Intensität aufweisen, charakteristisch für Glanzlichter, werden aus der Menge der gefundenen Korrespondenzen entfernt.

Künstliche Glanzlichter werden durch Alpha Blending über ein oder mehrere der gefundenen Korrespondenzen gelegt. Die Größe, Parameter der Ellipse und Verschiebung zwischen den Bildern wird zufällig gewählt. Diese künstlichen Glanzlichter sollen dem Netz Trainingsbeispiele liefern, um es zu sensibilisieren, dass in Bereichen mit Glanzlichtern Korrespondenzen nicht einfach durch Form und Textur bestimmt werden können.

4.3.3 Training des Netzes

Der Aufbau des neuronalen Netzes basiert auf der DispNet Architektur (Mayer *et al.*, 2016). Das Netzwerk besteht aus einem kontrahierenden und expandierenden Teil (siehe Abbildung 4.15). Im kontrahierenden Teil wird durch 10 *Convolutional* (siehe *lokale rezeptive Felder* in Abschnitt 4.2.4) Schichten die Eingabe Auflö-

Name	Kernel	Str.	Ch I/O	InpRes	OutRes	Input
conv1	7 × 7	2	6/64	768 × 384	384 × 192	Images
conv2	5 × 5	2	64/128	384 × 192	192 × 96	conv1
conv3a	5 × 5	2	128/256	192 × 96	96 × 48	conv2
conv3b	3 × 3	1	256/256	96 × 48	96 × 48	conv3a
conv4a	3 × 3	2	256/512	96 × 48	48 × 24	conv3b
conv4b	3 × 3	1	512/512	48 × 24	48 × 24	conv4a
conv5a	3 × 3	2	512/512	48 × 24	24 × 12	conv4b
conv5b	3 × 3	1	512/512	24 × 12	24 × 12	conv5a
conv6a	3 × 3	2	512/1024	24 × 12	12 × 6	conv5b
conv6b	3 × 3	1	1024/1024	12 × 6	12 × 6	conv6a
pr6+loss6	3 × 3	1	1024/1	12 × 6	12 × 6	conv6b
upconv5	4 × 4	2	1024/512	12 × 6	24 × 12	conv6b
iconv5	3 × 3	1	1025/512	24 × 12	24 × 12	upconv5+pr6+conv5b
pr5+loss5	3 × 3	1	512/1	24 × 12	24 × 12	iconv5
upconv4	4 × 4	2	512/256	24 × 12	48 × 24	iconv5
iconv4	3 × 3	1	769/256	48 × 24	48 × 24	upconv4+pr5+conv4b
pr4+loss4	3 × 3	1	256/1	48 × 24	48 × 24	iconv4
upconv3	4 × 4	2	256/128	48 × 24	96 × 48	iconv4
iconv3	3 × 3	1	385/128	96 × 48	96 × 48	upconv3+pr4+conv3b
pr3+loss3	3 × 3	1	128/1	96 × 48	96 × 48	iconv3
upconv2	4 × 4	2	128/64	96 × 48	192 × 96	iconv3
iconv2	3 × 3	1	193/64	192 × 96	192 × 96	upconv2+pr3+conv2
pr2+loss2	3 × 3	1	64/1	192 × 96	192 × 96	iconv2
upconv1	4 × 4	2	64/32	192 × 96	384 × 192	iconv2
iconv1	3 × 3	1	97/32	384 × 192	384 × 192	upconv1+pr2+conv1
pr1+loss1	3 × 3	1	32/1	384 × 192	384 × 192	iconv1

Abbildung 4.15: Die Architektur des *Convolutional* Neuronalen Netzwerks. Die *Convolutional* Schichten *conv1* - *conv6* bilden den kontrahierenden Teil des Netzes. Im expandierenden Teil wechseln sich die Paare von *Upconvolutional* und *Convolutional* Schichten [*upconv5,iconv5*] - [*upconv1,iconv1*] mit den Ausgabe- und Fehler-schichten [*pr6+loss6*] - [*pr1+loss1*] ab.

sung von 768x384 auf 12x6 Pixel reduziert. Gleichzeitig werden die 6 Eingangskanäle der beiden RGB-Bilder auf 1024 Filter-Kanäle erweitert. Im expandierenden Teil wird dieser Prozess umgekehrt und die Auflösung nach 5 Paaren aus *Upconvolutional* und *Convolutional* Schichten wieder auf 384x192 erhöht. Da die Ausgabe eine Disparitätskarte schätzen soll, werden die Filter-Kanäle von 1024 auf einen reduziert.

Nach jedem *Upconvolutional/Convolutional* Schichtpaar im expandierenden Teil des Netzes wird eine Fehlerfunktion $[loss_1, \dots, loss_6]$ berechnet. Anschaulich beschrieben, bilden die Ausgaben *pr6-pr1* eine AuflösungsPyramide. Die Intention dieser Architektur ist, dass in den gering aufgelösten Schichten mit den gleichen Filtergrößen größere Bildbereiche einbezogen werden können. So lassen sich große Strukturen und Merkmale erfassen. In den hochauflösenden Schichten können wiederum feine Details in den Bildern erfasst werden (siehe Abbildung 4.16). Damit die feinen Details nicht im Flaschenhals der AuflösungsPyramide verloren gehen, werden zusätzlich die Schichten mit gleicher Auflösung in kontrahierendem und expandierendem Teil miteinander verbunden. Konkret bedeutet dies, dass der Ausgang *pr1* aus *pr2+upconv1+conv1* zusammengesetzt ist (indirekt über eine vorgelagerte zusätzliche Convolution *iconv1*). Das gleiche Schema gilt für die Ausgabeschichten *pr2-pr5*.

Das neuronale Netz wurde mit Python² 3 (Raschka, 2015, Harrington, 2012) realisiert. Dabei wurden die Bibliothek für maschinelles Lernen Theano (Theano Development Team, 2016), sowie die darauf aufbauende, auf *Convolutional* Neuronale Netze spezialisierte Bibliothek Lasagne (Dieleman *et al.*, 2015) verwendet. Zur Optimierung des Netzes wurde auf den Adam Optimizer (Kingma & Ba, 2014) mit den Standardwerten $\beta_1 = 0.9$ und $\beta_2 = 0.999$ zurückgegriffen. Zur Berechnung der Kostenfunktion $C(y, t)$ wurde der absolute Fehler zwischen geschätzten und Referenzdisparitäten

$$C(y, t) = |y - t|$$

über alle Pixel gemittelt.

Vortraining

Als erster Schritt im Training des Netzes, wurden 44000 Bildpaare aus dem Datensatz "Flying Things"³ genutzt. Dies hat den Sinn, das Netz für die Aufgabe der endoskopischen Stereorekonstruktion vorzubereiten. So lernt das neuronale Netz mit diesen Daten Bildmerkmale zu extrahieren und Disparitätsschätzungen zu erzeugen. Wie später in den Ergebnissen zu sehen sein wird, können so zwar keine guten Schätzungen für endoskopische Bilddaten generiert werden, sehr wohl

²<https://www.python.org/>

³<http://lmb.informatik.uni-freiburg.de/resources/datasets/SceneFlowDatasets.en.html>




Abbildung 4.16: Unter den Eingabebilddaten sind die Schätzungen der einzelnen Ausgabeschichten pr_5 - pr_1 zu sehen. Die Auflösung der Ausgabe wird nach jeder Schicht jeweils verdoppelt. In der rechten Spalte ist die dünnbesetzte Referenz-Disparitätenkarte für jede Auflösungsstufe abgebildet.

aber bietet ein auf dieser Weise vortrainiertes Netz eine deutlich bessere Startposition für neue Lernschritte als ein zufällig initialisiertes Netzwerk. Bildlich gesprochen lernt das Netz durch das Vortraining die Funktionsweise des stereoskopischen Sehens. Durch die endoskopischen Trainingsdaten wird das erlernte Sehen für diesen Anwendungszweck optimiert. Das Vortraining dient damit auch als Ausgleich für die begrenzte Anzahl an spezialisierten endoskopischen Trainingsdaten.

Als initiale Lernrate λ wurde für das Vortraining $1e^{-4}$ gewählt und kontinuierlich um $\lambda_e = \lambda / (\text{epoch} + 1)$ reduziert. In der Arbeit von Mayer *et al.* (2016) konnte gezeigt werden, dass eine Gewichtung der Kostenfunktion vorteilhaft für das Lernergebnis ist. Aus diesem Grund wurde eine normalisierte Dreiecksfunktion genutzt, die kontinuierlich, von der innersten $[0, 0, 0, 0, 0, 1]$ zur äußersten Schicht $[1, 0, 0, 0, 0, 0]$, über die Kostenfunktion geschoben wird. Das Netz wurde für damit für 300 Epochen und einer Batch-Größe von 24 Bildpaaren trainiert.

Spezialisierung

In diesem Schritt soll das zuvor mit allgemeinen Daten trainierte Netzwerk für endoskopische Bilddaten spezialisiert werden. Da das Netz nur noch verfeinert werden soll, wird dabei nur die Kostenfunktion $loss_1$ der äußersten Schichten aktiviert. Da für die realen endoskopischen Daten nur dünnbesetzte Referenzkarten existieren, muss der Trainingsprozess darauf hingehend angepasst werden. Zunächst werden die Eingangsdaten um eine Maske m erweitert, welche $m_{x,y} = 1$ ist, wenn ein Referenzdisparitätswert für den Pixel x, y existiert und $m_{x,y} = 0$ ist, wenn nicht. Die neue Kostenfunktion ist dann wie folgt aufgebaut:

$$loss = \sum_{x,y} |prediction_{x,y} - reference_{x,y}| \cdot m_{x,y}$$

Für das Training mit realen endoskopischen Bilddaten standen 12000 Bildpaare aus zwei in vivo Schweineeingriffen und einem ex vivo Schweineleber Versuch zur Verfügung. Die dazugehörigen dünnbesetzten Referenzdaten wurden, wie in Abschnitt 4.3.2 beschrieben, erzeugt.

Zusätzlich wurden für das spezialisierte Training 15000 Bildpaare aus dem in Abschnitt 4.3.2 vorgestellten Framework für endoskopische Bildsynthese genutzt. Das Netzwerk wurde mit diesen Datensätzen weitere 50 Epochen trainiert. Die Batch-Größe betrug abermals 24 Bildpaare. Für die initiale Lernrate wurde $\lambda = 1e^{-6}$ gewählt und pro Epoche um $\lambda_e = \lambda / (\text{epoch} + 1)$ reduziert.




Abbildung 4.17: Eine Auswahl der Bilddaten des öffentlichen Vergleichsdatensatzes von Maier-Hein *et al.* (2014). Die Herausforderungen der endoskopischen Bildgebung sind gut zu sehen. Darunter: schlechte Ausleuchtung der Szene, Glanzlichter und homogene Texturierung.

4.3.4 Ergebnisse

Um eine aussagekräftige quantitative Evaluation zu ermöglichen, wurde auf den öffentlichen Vergleichsdatensatz von Maier-Hein *et al.* (2014) zurückgegriffen. Der Datensatz „D-All“ besteht aus 35 Stereoaufnahmen von verschiedenen *in vitro* Versuchen mit Schweineorganen und Organphantomen. In Abbildung 4.17 ist eine Auswahl dieser Aufnahmen zu sehen. Es wurde besonderen Wert darauf gelegt, die besonderen Herausforderungen in der Endoskopie wiederzugeben. So bieten die Aufnahmen Beispiele für schlecht ausgeleuchtete Szenen, Glanzlichter auf feuchten Oberflächen und homogene Texturierung von organischen Strukturen.

Der Datensatz enthält für jedes Bildpaar eine separate Stereokalibrierung, die genutzt wurde um die Bilder zu entzerren und zu rektifizieren. Ein Evaluierungsprogramm auf Basis des MITK-Frameworks (Wolf *et al.*, 2005, Nolden *et al.*, 2013) wurde ebenfalls bereitgestellt. Damit können Oberflächenrekonstruktionen und Referenzmodelle der Aufnahmen visuell und quantitativ verglichen werden.

In Tabelle 4.1 sind

- der durchschnittliche Root Mean Square Error (RMSE),
- der durchschnittliche Median,
- die durchschnittliche Anzahl an rekonstruierten Punkten,
- die durchschnittliche Oberflächenabdeckung

der hier vorgestellten Methode und den Methoden von Stoyanov *et al.* (2010) (UCL) und Röhl *et al.* (2012) (KIT) aufgezeichnet. Mit einem durchschnittlichen RMSE von 2,31 mm liegt das Ergebnis sehr eng am Stand der Forschung mit 1,77 - 1,83 mm. Hier muss außerdem berücksichtigt werden, dass die Genauigkeit der Referenzdaten mit 1-2 mm von den Autoren angegeben wird. Somit liegen die Ergebnisse aller drei Methoden in einem Bereich, der schon innerhalb des Fehlerpielraums der Referenzdaten liegt. Werden die Rekonstruktionen in Abbildung 4.18 verglichen, kann eine im Vergleich glattere und gegen Ausreißer robustere Rekonstruktion dieser Methode beobachtet werden. Der störende Einfluss von Glanzlichtern auf die Rekonstruktionsergebnisse konnten durch die Verwendung von künstlichen Glanzlichtern in den synthetischen und realen Datensätzen deutlich verringert werden. Komplette eliminiert werden konnte er jedoch nicht.

Die Evaluation wurde auf einer Workstation mit einer NVIDIA GeForce GTX 1080 Grafikkarte und einem Intel 3,4 GHz Hexa-Core CPU durchgeführt. Die Schätzung eines Bildpaares benötigte 36 ms. Da für die Bearbeitung eines vollen Batches von 24 Bildpaaren keine nennenswerten zusätzlichen Verzögerungen entstehen, kann der Durchsatz auf diese Weise drastisch erhöht werden. Dies geht natürlich auf Kosten der Latenz, da erst 24 Bildpaare gesammelt werden müssen, um den Prozess starten zu können. Diese Einschränkung gilt natürlich nur für den Einsatz in Live-Systeme.

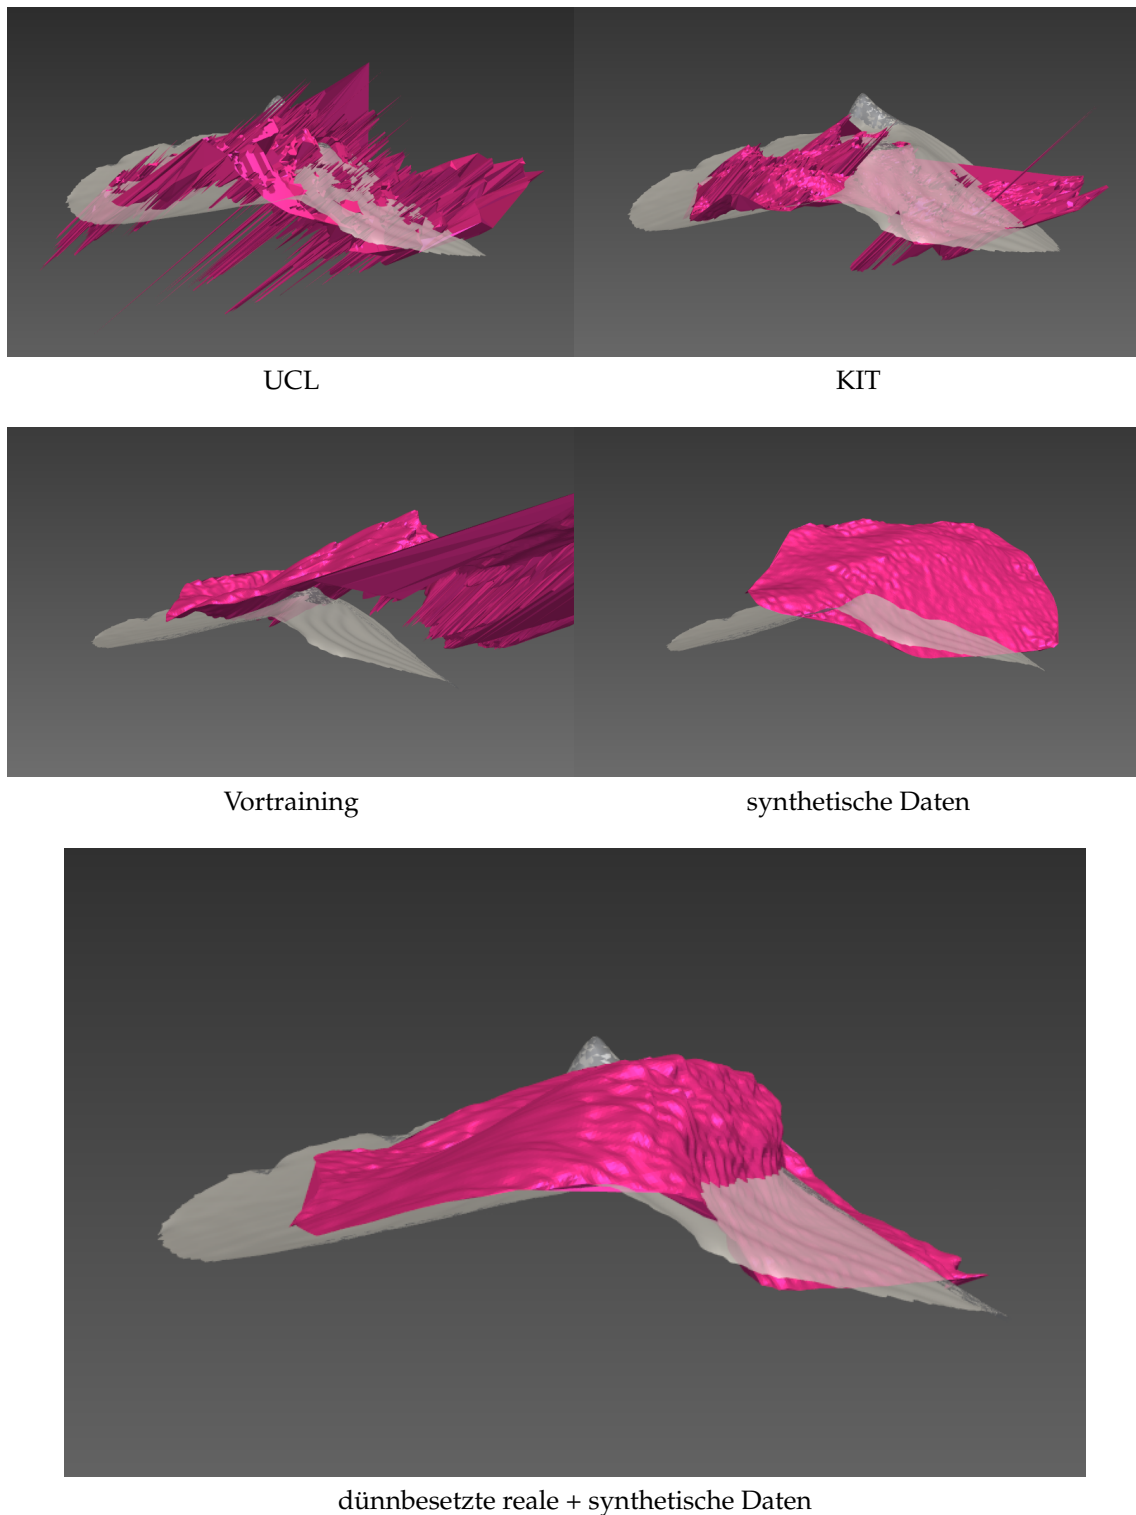


Abbildung 4.18: Rekonstruktionsergebnisse für den öffentlichen Datensatz von Maier-Hein *et al.* (2014). Die Daten enthalten zudem Vergleichsergebnisse der Arbeiten von Stoyanov *et al.* (2010) (UCL) und Röhl *et al.* (2012) (KIT). Die Verbesserung der Rekonstruktion durch die Verwendung der dünnbesetzten realen Datensätze ist deutlich zu sehen.

Methode	RMSE (mm)	Median (mm)	Punkte (#)	Abdeckung (%)
PT	8.14 ± 2.14	7.22 ± 2.02	30628 ± 10623	72.67 ± 23.53
S + PT	7.60 ± 3.78	6.87 ± 3.78	30628 ± 10623	56.69 ± 32.04
SP+ S + PT	2.31 ± 1.21	1.71 ± 1.00	32244 ± 10597	93.90 ± 9.35
UCL	1.83 ± 0.79	0.98 ± 0.40	29764 ± 11522	92.63 ± 16.76
KIT	1.77 ± 1.36	0.73 ± 0.46	31831 ± 10531	95.84 ± 10.02

Tabelle 4.1: Stoyanov *et al.* (2010)Röhl *et al.* (2012)Rekonstruktionsergebnisse für den öffentlichen Datensatz von Maier-Hein *et al.* (2014). PT: Vortraining, S: synthetisierte Daten und SP: Reale Endoskopdaten mit dünnbesetzten Referenz-Tiefenkarten

4.3.5 Zusammenfassung

In diesem Abschnitt wurde ein neuer Ansatz überwachter Lernansatz für die Schätzung von endoskopischen Disparitätskarten vorgestellt. Der Hauptbeitrag liegt dabei in der Entwicklung von neuen Trainingstechniken, welche die Lücke zwischen den limitierten Referenzdatensätzen in der Endoskopie und dem hohen Verlangen an Trainingsdaten für große neuronale Netze und CNNs schließen soll.

Die Ergebnisse zeigen, dass sich die hier vorgestellte Methode mit dem Stand der Forschung messen kann und dichte, glatte Rekonstruktionen generieren kann. Durch die automatische Erzeugung von dünnbesetzten Referenzkarten für reale endoskopische Bildpaare, können praktisch unüberwacht neue Bildsequenzen mit geringem Aufwand eingelernt werden. Dies erlaubt es theoretisch auch, das System durch einige zusätzliche Aufnahmen für bestimmte Hardwareprodukte und Operationssituationen speziell zu optimieren. Mit leistungsstarken Recheneinheiten könnte dieser Prozess in Zukunft möglicherweise sogar direkt vor und während Operationen erfolgen, um das System mit jedem Einsatz kontinuierlich zu verbessern. Die potenziellen Möglichkeiten von synthetischen Trainingsdaten reichen sicherlich weit über den Einsatz in dieser Arbeit hinaus. Gerade in Bezug auf die Texturierung und (indirekte) Beleuchtung sind hier noch viele Verbesserungen vorstellbar. Durch die Natur von maschinellen Lernverfahren ist anzunehmen, dass dieses Verfahren stark von der Vergrößerung der Trainingssets profitieren würde. So soll hier vor allem das Potential eines solchen Systems gezeigt werden.

Kapitel 5

Initiale Weichgeweberegistrierung

Das Ziel der computerassistierten Chirurgie ist die Unterstützung der Chirurgen während eines Eingriffs. Hierbei sollen zusätzliche Informationen bereitgestellt werden, um die Entscheidungsfindung und Durchführung chirurgischer Arbeiten zu verbessern. Eine wichtige Informationsquelle sind präoperative Modelle, die aus CT- oder MRT-Scans gewonnen werden. Eine populäre Methode diese Daten im Operationsraum zugänglich zu machen ist die Erweiterte Realität (augmented reality - AR). Hierbei werden Zielstrukturen von Interesse mittels Alpha Blending mit dem Endoskopbild fusioniert (Botden & Jakimowicz, 2009, Teber *et al.*, 2009, Navab *et al.*, 2012). Um die Fusionierung der Bilddaten zu ermöglichen, müssen das Organmodell und das im Kamerakoordinatensystem live dargestellte Organ, in Lage und Orientierung ausgerichtet werden. Dieser Vorgang wird als Registrierung bezeichnet.

Neben den starke Deformationen durch das Anlegen des Pneumoperitoneums (Bano *et al.*, 2012, Zijlmans *et al.*, 2012) und der unterschiedlichen Lagerung des Patienten kommt es auch während der Operation zu weiteren Deformationen. Beispiele hierfür sind die Verschiebung von Organen durch die Atmung des Patienten, oder die Manipulation an Organen durch laparoskopische Instrumente, wie eines Greifers, durch den Operateur. Da sich die erste Problemstellung, eine große initiale Verschiebung und Rotation zu ermitteln, schlecht mit der dynamischen Registrierung von kleinen aber kontinuierlich auftretenden Deformationen verbinden lässt, wird dieses schwierige Gesamtproblem in dieser Arbeit in einen initialen Registrierungsschritt und einen dynamischen Registrierungsschritt aufgeteilt. Die dynamische Registrierung, in Kapitel 6 vorgestellt, nutzt als initialen Zustand das Ergebnis der initialen Registrierung, die in den Inhalt dieses Kapitels ist.

In Kapitel 4 wurde erläutert, wie mithilfe der intraoperativen Bildgebung Stereorekonstruktionen des Operationsfeldes von einzelnen Bildpaaren erzeugt werden können (siehe Abbildung 5.1). Der sich überschneidende Bereich in beiden Kamerabildern enthält bei endoskopischen Aufnahmen, die durch die Bauchwand bedingt sehr nah an der Szene liegen, immer nur einen kleinen Ausschnitt der Oberfläche eines Organs. Diese 3D-Rekonstruktionsflicken enthalten meist nicht

genug Informationen, um sie auf der Oberfläche des präoperativen Modells zweifelsfrei zu verorten. Anders als bei alltäglichen Objekten, fehlen hier auch nützliche Merkmale wie Ecken und Kanten, die als Referenzpunkte verwendet werden könnten. Gerade für die Registrierung von großen rotatorischen Unterschieden, wie beispielsweise einer Drehung um 180 Grad, ist deshalb ein möglichst umfassendes 3D-Modell des intraoperativen Organs wünschenswert, um nicht in lokalen Minima stecken zu bleiben.




Abbildung 5.1: Das linke Kamerabild (links) wird zusammen mit dem rechten Bild, den intrinsischen und extrinsischen Stereokameraparametern dazu genutzt eine Tiefenkarte der aufgenommenen Szene zu generieren (rechts). Das Stereokorrespondenzproblem zur Bestimmung der Disparitäten wurde mithilfe des Hybrid Recursive Matching (HRM) Verfahrens gelöst (Röhl *et al.*, 2012).

In diesem Kapitel wird ein Verfahren vorgestellt, welches durch einen Mosaikprozess aus vielen endoskopischen Bildpaaren, eine möglichst große Oberfläche des Zielorgans in einem globalen Modell rekonstruiert. Diese Arbeit wurde in Reichard *et al.* (2015) und Bodenstedt *et al.* (2015) veröffentlicht.

Als Basis für das globale Organmodell dienen die 3D-Rekonstruktionen, in diesem Fall werden 3D-Punktwolken verwendet, die durch das Hybrid Recursive Matching (HRM) Verfahren von Röhl *et al.* (2012) erzeugt werden. In einem Vergleich verschiedener Rekonstruktionsverfahren von Maier-Hein *et al.* (2014) sind die Ergebnisse des HRMs auf dem Stand der Forschung.

Um das gewünschte Organ aus der rekonstruierten Szene zu extrahieren, muss zusätzlich zur Rekonstruktion auch eine Segmentierung der Bilder erfolgen. Dazu wird ein auf Random Forests basierender Klassifikator (Schroff *et al.*, 2008) angewendet, der auf den RGB-Kanälen der Bilder arbeitet. So wird eine Maske erstellt, in der jeder Pixel als Hintergrund oder als Teil des Organs gelabelt wird. Die so gelabelten 3D-Punktwolken werden nach jedem Bild-Frame in ein Voxel-Volumen integriert, in welchem das globale Modell repräsentiert wird. Der Ansatz des Voxel-Volumens stammt von der viel beachteten Arbeit KinectFusion von Newcombe *et al.* (2011). Durch neue Blickwinkel und Sichtpunkte kann so ein Modell erzeugt werden, dass eine deutlich robustere initiale Registrierung erlaubt (siehe Abbildung 5.2).




Abbildung 5.2: Das Mosaikmodell wird mit jedem aufgenommenen Bildpaar erweitert und verbessert. Die beispielhaft dargestellten Mosaikstücke bestehen in Wirklichkeit aus dutzenden einzelnen Oberflächenfragmenten. Das finale Mosaikmodell ist auf die vom Endoskop beobachteten Oberflächenbereiche beschränkt und kann deshalb auch Lücken enthalten.

Die in diesem Kapitel vorgestellte Methode stellt einen neuen Ansatz vor, mit dem ganze endoskopische Szenen aus mehreren Blickpunkten live rekonstruiert werden können. Dazu wird nur auf eine schon im Operationsraum vorhandene Bildquelle zurückgegriffen: dem Stereoendoskop. Gleichzeitig werden mit jedem Bild die Klassifikationen von Organ und Hintergrund optimiert. Die wichtigsten Beiträge dieser Kapitel sind:

Rekonstruktions-Mosaik aus einzelnen Stereobild-Rekonstruktionen durch eine Frame-zu-Modell Registrierung mit einem optionalen Trackinggerät (z.B. NDI Polaris).

Dichtes Oberflächenmodell, das live generiert wird und nach jedem Frame verfügbar ist.

Frameweise Segmentierung, die durch einen echtzeitfähigen GPU (Graphics Processing Unit) Random Forest Ansatz erreicht wird.

Globale Segmentierung, die es erlaubt, dass die Segmentierungen eines globalen Oberflächenpunktes aus der Summe der Segmentierungen jedes einzelnen Frames bestimmt werden können. Die Kombination der Frame-für-Frame Segmentierungen führt zu einer höheren und robusteren Erkennungsrate.

Im Folgenden wird zunächst eine detailliertere Beschreibung des Rekonstruktionsablaufs vorgestellt. Danach folgt eine Evaluation des Verfahrens durch in silico, Phantom, ex vivo und in vivo Daten. Die ex und in vivo Studien wurden mithilfe von Schweineversuchen durchgeführt. Zusätzlich werden drei Methoden des Kameratrackings evaluiert: optisches Tracking mit einem NDI Polaris

Gerät¹, Iterative Closed Point (ICP) Tracking und eine Kombination dieser Ansätze. Das Verfahren und die Evaluation sind im Kontext der laparoskopischen Leberchirurgie beschrieben. Der Einsatz für weitere endoskopische Eingriffe ist allerdings ebenso denkbar und kann durch weitere Studien beurteilt werden.

5.1 Bildübergreifende Oberflächen-Rekonstruktion

Für die Rekonstruktion der Operationsszene werden mehrere Schritte benötigt (siehe Abbildung 5.3). Zunächst werden aus den einzelnen Stereobild-Frames dreidimensionale Punktwolken rekonstruiert. Parallel dazu werden die Stereobilder segmentiert, um die Bildpunkte als Hintergrund oder Zielorgan zu klassifizieren. Anschließend werden die 3D Punktwolken mit den Segmentierungsergebnissen gebündelt und in ein Truncated Signed Distance (TSD) Volumen integriert. Aus dem TSD Volumen kann nach jedem Integrationsschritt ein neues Mosaik aus den kombinierten Rekonstruktionen extrahiert werden.

Das TSD Volumen erlaubt es, die Informationen der einzelnen Rekonstruktionen aus verschiedenen Sichtpunkten in ein globales Modell zu integrieren. Dabei wird durch die zusätzlichen Informationen von sich überlappenden Bildbereichen Rauschen aus den Aufnahmen und Fehler aus den Rekonstruktionen reduziert.

5.1.1 Rekonstruktion und Segmentierung

Die Bildakquise erfolgt intraoperativ ausschließlich durch ein Stereoendoskop. Dieses erzeugt pro Zeitschritt, auch Frame genannt, ein linkes und ein rechtes RGB-Kamerabild. Diese Bilder werden zunächst für das Rekonstruktionsverfahren vorverarbeitet. Dazu werden die Bilder mithilfe der intrinsischen und extrinsischen Kameraparameter zuerst entzerrt und danach rektifiziert. Dies hat den Vorteil, dass die Epipolarlinien in rektifizierten Stereobildern horizontal verlaufen und damit Korrespondenzen für die Disparitätsschätzung nur noch in derselben Bildzeile gesucht werden müssen (siehe Abschnitt 4.1.6 und 4.1.7 in Kapitel 4). Damit ist eine erhebliche Beschleunigung der Stereorekonstruktion möglich.

Mit der Hybrid Recursive Matching (HRM) Korrespondenzanalyse von Röhl *et al.* (2012) wird eine dichte Disparitätskarte aus den endoskopischen Bildpaaren erzeugt. Das Verfahren ist für die GPU (Graphics Processing Unit) optimiert und begrenzt echtzeitfähig (je Auflösung und Hardware zwischen 50-150 ms pro Rekonstruktion). Aus der Disparitätskarte werden mithilfe der Kameraparameter die ursprünglichen 3D Punkte trianguliert und als 3D-Punktwolke R_i für jeden Frame i gespeichert.

¹<https://www.ndigital.com/medical/products/polaris-family/>

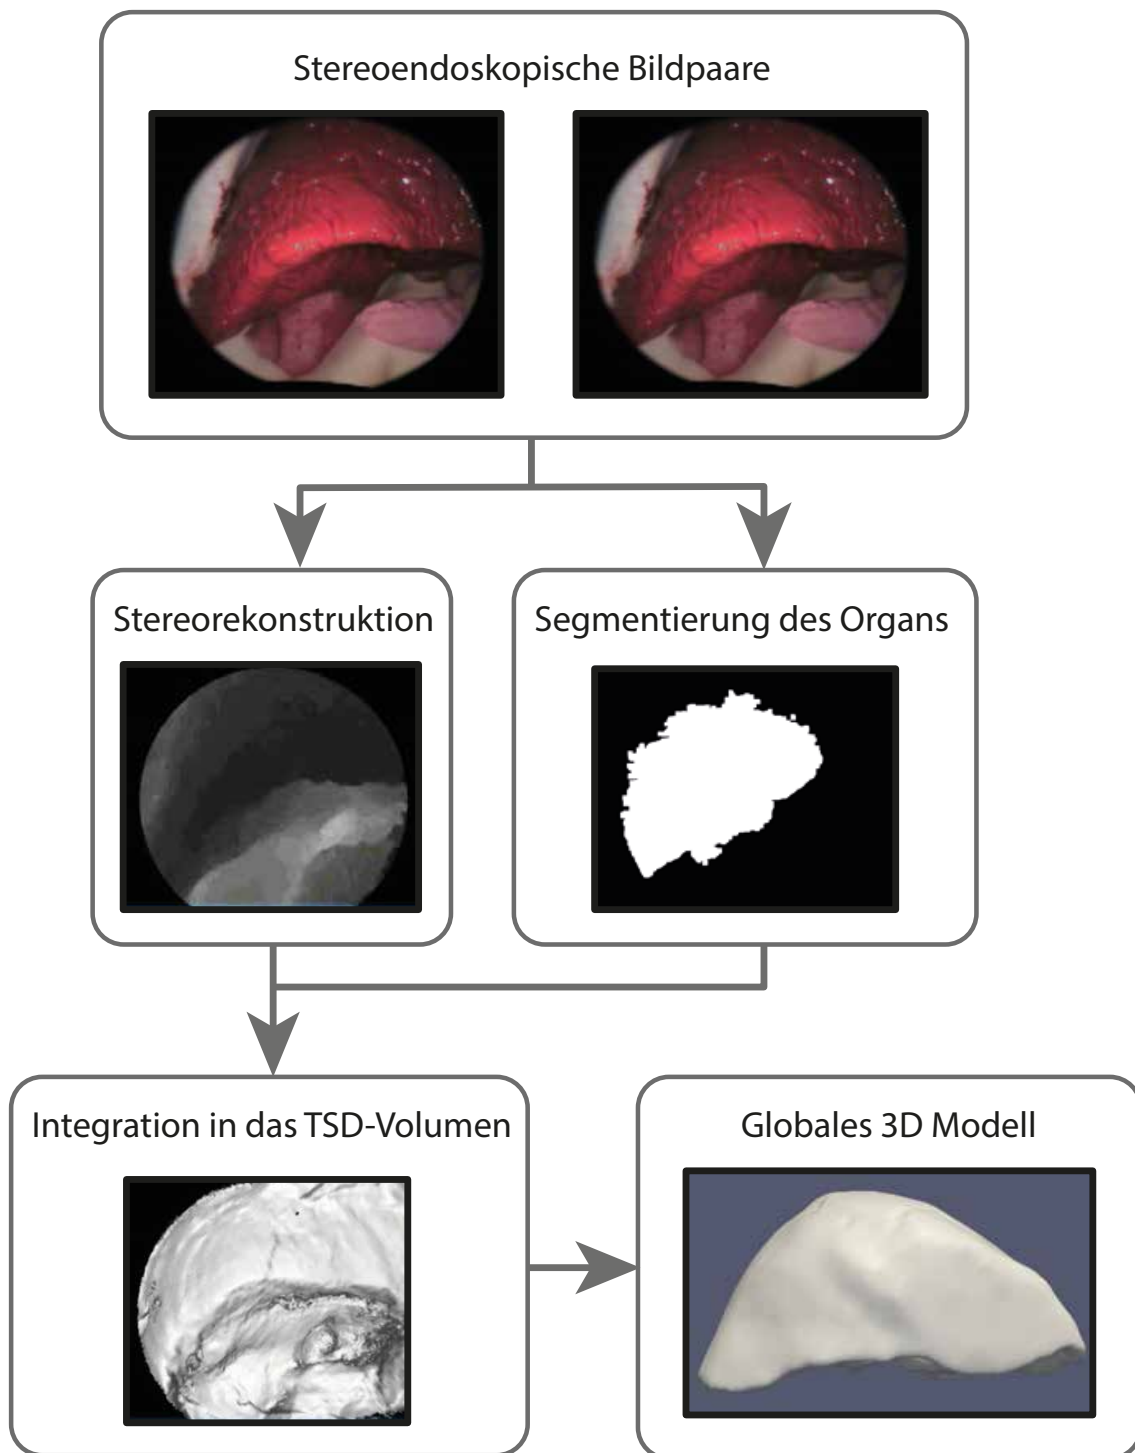


Abbildung 5.3: Ablaufdiagramm des Mosaikprozesses

Für die Segmentierung werden alle Pixel des linken Kamerabilds parallel durch einen Random Forest Schroff *et al.* (2008) in Zielorgan und Hintergrund klassifiziert. Der Random Forest kann zuvor mit Trainingsbeispielen auf verschiedene Organe spezialisiert werden. Für das Training wurden die Merkmale Farbwert und Sättigung aus dem HSV Farbraum (Sural *et al.*, 2002) und die auf der Gegenfarbtheorie basierenden a und b Dimensionen des LAB Farbraums genutzt. Der Klassifikator bietet damit eine Zuweisung

$$C_i(\mathbf{p}) \rightarrow \{1 \dots n\}, \mathbf{p} \in R_i$$

für jeden 3D Punkt \mathbf{p} zu einem Klassenlabel C_i für jeden Zeitschritt i .

Der Random Forest wurde mit je 15 gelabelten Bildern (Leber und Hintergrund) für die in und ex vivo Evaluation trainiert. Um Echtzeitberechnung zu ermöglichen, wurde der Klassifikationsteil des Algorithmus auf die GPU portiert.

5.1.2 Integration in das TSD-Volumen

Wie in Abbildung 5.3 dargestellt, werden Stereorekonstruktion bzw. 3D Punktwolke und die Organklassifikation nach jeder endoskopischen Aufnahme in das TSD-Volumen integriert. Dazu werden die 3D Punktwolke R_i zunächst aus dem Kamerakoordinatensystem in das Weltkoordinatensystem $R_i^W = P_i(R_i)$ transformiert. Dazu muss die aktuelle Kameraposition P_i bekannt sein (siehe Abschnitt 5.1.3). Zu jedem Zeitschritt i wird R_i^W in das TSD-Volumen

$$S_i(\mathbf{p}) \rightarrow \{F_i(\mathbf{p}), K_i(\mathbf{p}, j), W_i(\mathbf{p})\}$$

integriert, wobei \mathbf{p} ein Voxel (dreidimensionaler Pixel) im TSD-Volumen ist. Die TSD-Werte $F_i(\mathbf{p})$ und Gewichtung der Eingabe $W_i(\mathbf{p})$ werden wie in Newcombe *et al.* (2011) vorgeschlagen berechnet:

$$F_i(\mathbf{p}) = \frac{W_{i-1}(\mathbf{p}) F_{i-1}(\mathbf{p}) + W_{R_i}(\mathbf{p}) F_{R_i}(\mathbf{p})}{W_{i-1}(\mathbf{p}) + W_{R_i}(\mathbf{p})}, \quad (5.1)$$

$$W_i(\mathbf{p}) = W_{i-1}(\mathbf{p}) + W_{R_i}(\mathbf{p}), \quad (5.2)$$

wobei $W_{R_i}(\mathbf{p})$ die Gewichtung des Voxels \mathbf{p} im aktuellen Zeitschritt ist. Die Gewichtung kann genutzt werden, um die Integrationswerte aus verschiedenen Zeitschritten unterschiedlich zu gewichten. Dabei kann beispielsweise die Unsicherheit des aktuellen Wertes (falls vorhanden) für die Berechnung des neuen TSD-Wertes F_{R_i} miteinbezogen werden. Für diese Arbeit wurden die Punkte aus allen Zeitschritten gleichgewichtet in F_{R_i} integriert. F_{R_i} wird wie folgt berechnet:

$$F_{R_i}(\mathbf{p}) = \Psi\left(\lambda^{-1} \|\mathbf{t}_i - \mathbf{p}\|_2 - R_i(\mathbf{x})\right), \quad (5.3)$$

$$\lambda = \|K^{-1} \dot{\mathbf{x}}\|_2, \quad (5.4)$$

$$\mathbf{x} = [K T_i^{-1} \mathbf{p}], \quad (5.5)$$

$$\Psi(\eta) = \begin{cases} \min\left(1, \frac{\eta}{\mu}\right) \operatorname{sgn}(\eta) & , \quad \eta \geq -\mu \\ \text{undefined} & , \quad \text{else} \end{cases}, \quad (5.6)$$

wobei K die Kamerakalibrierungsmatrix, $\dot{\mathbf{x}}$ die homogenisierte Bildkoordinate \mathbf{x} , $[\cdot]$ das Nearest Neighbor Suchergebnis, T_i die Kameratransformation und \mathbf{t}_i der Translationsteil von T_i ist. λ^{-1} konvertiert die Kamerastrahldistanz $\|\mathbf{t}_i - \mathbf{p}\|_2$ in einen Tiefenwert im Kamerakoordinatensystem. Die Funktion $\Psi(\eta)$ spezifiziert den Bereich in dem der Voxel F_{R_i} von R_i beeinflusst wird. Der Parameter μ steuert dabei die maximale Distanz, bevor der Einfluss eines Punkts aus R_i nicht mehr berücksichtigt (truncated) wird.

Für die Klassifizierung der Punkte in die Klassen \mathbf{p} , wurde $K_i(\mathbf{p}, j)$ in das Volumen integriert:

$$K_i(\mathbf{p}, j) = \frac{W_{i-1}(\mathbf{p})K_{i-1}(\mathbf{p}, j) + W_{R_i^W}(\mathbf{p})K_{R_i^W}(\mathbf{p}, j)}{W_{i-1} + W_{R_i^W}}, \quad (5.7)$$

$$K_{R_i^W}(\mathbf{p}, j) = \begin{cases} 1 & , \quad \text{if } C_i(R_i^W(\mathbf{p})) = j \\ 0 & , \quad \text{else} \end{cases}, \quad (5.8)$$

wobei $R_i^W(\mathbf{p})$ den Punkt aus R_i^W repräsentiert, der in \mathbf{p} abgebildet wird und j die Kategorie des Klassifikators angibt.

Die Klassenzugehörigkeit $C_i(\mathbf{p})$ eines Punktes $R_i^W(\mathbf{p})$ für den aktuellen Zeitschritt i wird wie folgt bestimmt:

$$C_i(\mathbf{p}) = \operatorname{argmax}_{j \in \{1..n\}} K_i(\mathbf{p}, j) \quad (5.9)$$

Die Gewichtung der Klassifikationsergebnisse aus verschiedenen Zeitschritten erlaubt dem System, einzelnen Fehlklassifizierungen durch zusätzliche Aufnahmen des gleichen Bildausschnitts entgegenzuwirken.

5.1.3 Kamerapose

Um die aktuelle 3D Punktwolke R_i in das TSD-Volumen zu integrieren zu können, muss auch die aktuelle Pose P_i des Endoskops bekannt sein. In dieser Arbeit wurden drei Ansätze für die Schätzung der Pose P_i evaluiert:

- ICP** Wie in der Arbeit von Newcombe *et al.* (2011) basiert dieser Ansatz auf der Annahme, dass sich die Kamerapose zwischen zwei aufeinanderfolgenden Zeitschritten P_{i-1} und P_i nur leicht verändert. Kann eine Framerate im Echtzeitbereich erreicht werden, ist diese Bedingung bei typischen Aufnahmen zu erfüllen. Um P_i zu bestimmen, wird die relative Transformation zwischen der aktuellen Punktwolke R_i und einem Raycast des TSD-Volumens aus dem Zeitschritt $i - 1$ mit dem Projective Data Association Iterative Closest Point Algorithmus von Blais & Levine (1995) berechnet. Durch die Annahme der kleinen relativen Transformationen können mit der Projective Data Association alle Pixel des aktuellen Bildes für die Bestimmung von P_i genutzt werden.
- Polaris** Da optische Trackingsysteme wie die NDI Polaris Reihe schon in vielen Operationsräumen eingesetzt werden, wurde diese Art des Trackings als zweite Möglichkeit evaluiert. Dabei werden sowohl das Endoskop sowie der Patient (das Versuchsobjekt) getrackt, um kleine Lageänderungen des Patienten ausgleichen zu können.
- Mixed** Da beide Verfahren parallel genutzt werden können, wurde ebenfalls ein kombinierter Trackingansatz getestet. Dazu wurde die Posenschätzung des Polarisystems als initiale Transformation P'_i für den projektiven ICP Algorithmus genutzt. Auf diese Weise muss die Bedingung der kleinen Transformationen nicht mehr erfüllt werden, da eine erste nahe Schätzung der aktuellen Position schon vorliegt.

5.2 Ergebnisse

Für die Evaluation des Verfahrens wurden *in silico*, Phantom, *ex vivo* und *in vivo* Experimente durchgeführt. Dabei wurde jeweils die Leber als Testobjekt genutzt. Für die Silikonphantome wurde eine Laser-Scan als Referenz für die Form des Organs. Als Referenzform für die Schweinelebern in den *ex vivo* und *in vivo* Versuchen wurden CT-Scans gefahren. In jedem Versuch wurde das Stereoendoskop über die erreichbaren Bereiche des Organs geführt, um alle Oberflächenpunkte mindestens einmal aufzunehmen. Aus den erstellten Stereoaufnahmen wurden dann pro Frame je eine Stereorekonstruktion und eine Segmentierung der Leber erstellt.

Für jedes Experiment wurden drei Organmosaikte als Ergebnis erzeugt, je eines für das Kameratracking mit projektiven ICP, optischen Tracking und der Kombination der Trackingverfahren (siehe 5.1.3). Als Fehlermaß wurde der durchschnittliche Abstand der rekonstruierten Modellpunkte zum nächsten Punkt des Referenzmodells gewählt. Um einen Vergleich zu den einzelnen Frame-zu-Frame Rekonstruktionen R_i^W zu ermöglichen, wurde dieses Fehlermaß ebenfalls für die frameweisen Rekonstruktionen berechnet. Die Registrierung der Mosaikmodelle zu den Referenzmodellen wurde ebenfalls mit dem Polarissystem hergestellt. Um Fehler der Registrierung nicht mit dem Fehler der Rekonstruktion zu mischen, wurde als Nachbearbeitungsschritt eine ICP Registrierung der Modelle durchgeführt.

Nr.	PC Konfiguration			Endoskop
	CPU	Grafik	RAM	
1	i7-2700k	GeForce GTX 650Ti	16 Gbyte	Richard Wolf - PAL (720 × 576 Pixel)
2	i7-5820k	GeForce GTX 970	16 Gbyte	Storz 3D TIPCAM®1 (1920 × 540 Pixel)

Nr.	Durchschnittliche Laufzeit				
	HRM	TSDF Integration	Segmentierung	Gesamt	Framerate
1	0,134	0,024	0,045	0,252	≈ 4
2	0,131	0,027	0,030	0,241	

Tabelle 5.1: Die PC Workstations und endoskopische Hardware, die für die Versuche verwendet wurden. Beide Stereoendoskope wurden vor dem Einsatz kalibriert, besitzen keinen Zoom und haben eine fixierte Fokussierung. Die Laufzeitberechnung zeigt, dass die höheren Berechnungskosten durch eine höhere Auflösung (HD Halbbild) durch rechenstärkere Hardware ausgeglichen werden kann.

Für das optische Tracking wurde in allen Versuchen das NDI Polarissystem Spectra² verwendet. Die beiden Experimente mit Silikonphantom und das erste ex vivo Experiment wurden mit einem kalibrierten PAL Stereoendoskop der Firma Wolf aufgezeichnet und von einer PC Workstation verarbeitet (siehe Tabelle 5.1, Nummer 1). Für das zweite ex vivo Experiment und das in vivo Experiment wurden ein kalibriertes HD Stereoendoskop mit chip-on-the-tip Technologie der Firma Storz und ebenfalls eine PC Workstation zur Datenverarbeitung verwendet.

Mit durchschnittlich 250 Millisekunden für die Integration eines Frames, konnte mit beiden Konfigurationen eine Framerate von circa 4 Frames per Second (fps)

²<https://www.ndigital.com/medical/products/polaris-family/>

erreicht werden. Genauere Informationen über die Laufzeit können der Tabelle 5.1 entnommen werden. Der Großteil der Laufzeit entfällt hierbei auf die Stereorekonstruktion. Die TSD Funktionsintegration und die Segmentierung sind gemeinsam nur für circa 60-70 Millisekunden verantwortlich. So wären mit anderen Rekonstruktionsverfahren, wie dem in Kapitel 4 vorgestellten CNN basierten Verfahren, Laufzeitverbesserungen möglich ohne den eigentlichen Mosaikalgorithmus zu verändern.


5.2.1 In Silico

Damit das Verhalten und die Genauigkeit des Mosaikverfahrens auch getrennt von der Qualität der Stereorekonstruktion (HRM) beurteilt werden kann, wurde das Verfahren zunächst mit synthetischen endoskopischen Bilddaten getestet. Dafür wurde mithilfe eines Simulationsframeworks eine kreisförmige Kamerafahrt um ein texturiertes CT-Lebermodell generiert. Für alle 320 Stereobilder wurden eine Tiefenkarte und die Kameraposition berechnet bzw. aufgezeichnet (siehe Abbildung 5.4).

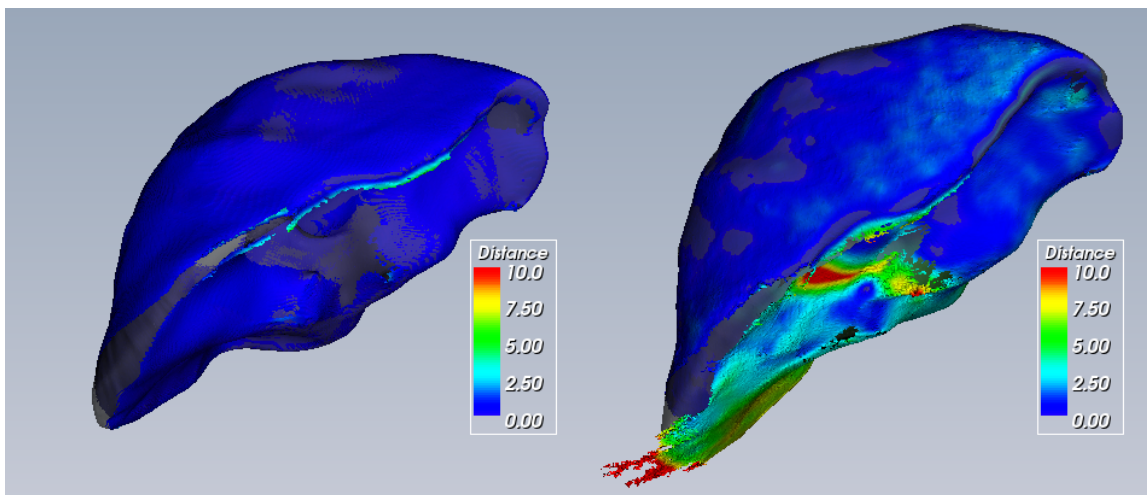
Zusätzlich zu dem mit der Referenz-Tiefenkarte erstellten Mosaik, wurde zum Vergleich auch ein Mosaik mit den vom Hybrid Recursive Matching (HRM) geschätzten Tiefendaten berechnet (Abbildung 5.4 (c)). Mit den synthetischen Eingabedaten konnte ein durchschnittlicher Root-mean-square Fehler (RMSE) von 0,02 mm für alle drei Kameratrackingverfahren erreicht werden (siehe Tabelle 5.2. Für das Mosaik mit HRM-Tiefendaten reicht der RMSE von 0,47 mm bis 2,00 mm. Interessant ist hierbei, dass der durchschnittliche RMSE des Mosaiks mit optischen Tracking (entspricht hier den Referenzposen des Endoskops) mit 0,47 mm geringer ausfällt als der durchschnittliche RMSE aller einzelnen Rekonstruktionen des HRMs. Dies unterstützt die These, dass das hier vorgestellte Mosaikverfahren das Rauschen der Eingabedaten durch kombinierte Integration zu reduzieren vermag.

Das Simulationsframework wurde in einem zweiten Schritt dazu verwendet, das Verhalten des Mosaikverfahrens auf Rauschartefakte in den Tiefendaten zu untersuchen. Dazu wurden die Referenz-Tiefendaten durch ein Perlin Rauschmodell (Perlin, 1985) angepasst. Das Perlinmodell wurde gewählt, da die Rauschartefakte empirisch ähnliche Eigenschaften zeigen wie die des Hybrid Recursive Matchings.

Drei unterschiedlich starke Rauschstufen (Tabelle 5.2 Rauschen 1-3) wurden auf die Tiefenkarten angewendet. Der RMSE für die Mosaikmodelle stieg dabei von 1,12 mm \pm 0,86 mm für Rauschen 1, über 2,30 mm \pm 1,68 mm für Rauschen 2, zu 3,36 mm \pm 2,49 mm für Rauschen 3 (siehe Abbildung 5.5). Ähnlich zu den Ergebnissen mit den Daten des HRMs, kann auch hier beobachtet werden, dass der Mosaikprozess das Rauschen der Tiefendaten durch die Integration in das globale Mosaik reduzieren kann. So wird beispielsweise der Rauschfehler der



(a)



(b)

(c)

Abbildung 5.4: (a) Texturiertes Lebermodell aus dem Simulationsframework. (b) Fehlerverteilung des Mosaiks mit Referenz-Tiefendaten und (c) mit Tiefendaten aus dem Hybrid Recursive Matchings (HRM).

Simulation	Endoskopposition			einzelner Frame mit Referenz Position
	Referenz	ICP	Kombiniert	
Referenz-Tiefenkarte	0,02 ±0,01	0,02 ±0,01	0,02 ±0,01	-
mit Rauschen 1	0,02 ±0,01	0,84 ±0,35	0,19 ±0,09	0,81 ±0,36
mit Rauschen 2	0,10 ±0,05	4,94 ±2,15	1,14 ±0,98	1,61 ±0,73
mit Rauschen 3	1,16 ±0,60	20,62 ±9,78	3,86 ±1,81	2,39 ±1,38
HRM	0,47 ±0,25	2,00 ±0,92	1,82 ±0,68	0,69 ±0,31

Tabelle 5.2: Der Root-mean-square Fehler (RMSE) zwischen den Mosaikmodellen und dem Referenzmodell in *mm*. Die letzte Spalte gibt den durchschnittlichen RMSE für die einzelnen 3D-Rekonstruktionen für jeden Frame an. In der letzten Zeile ist der RMSE des Mosaiks angegeben, dass mit den Daten des HRM erzeugt wurde (anstatt mit den Referenz Tiefendaten).

Tiefendaten von $0,81 \text{ mm} \pm 0,36 \text{ mm}$ auf $0,10 \text{ mm} \pm 0,01$ im Mosaik reduziert werden (mit Verwendung der Referenzposen).

5.2.2 Leberphantom

Nach den erfolgreichen *in silico* Versuchen wurde das Mosaikverfahren in fünf Silikonphantom Experimenten mit drei verschiedenen Leberphantomen evaluiert (siehe Abbildung 5.6). Für die mit Silikonleber 1 und Silikonleber 2 bezeichneten Silikonmodelle wurde sowohl mit dem Wolf PAL Stereoendoskop als auch mit dem Storz HD Stereoendoskop Aufnahmen durchgeführt. Für das Modell Silikonleber 3 wurde ausschließlich das HD Stereoendoskop von Storz verwendet. In Abbildung 5.9 sind die RMS Fehlerkarten der Versuche abgebildet.

Bei den Aufnahmen für das erste (Wolf PAL Endoskop 1, Storz HD Endoskop 1) und das dritte (Storz HD Endoskop 3) Silikonphantom wurden die Silikonlebern auf einer flachen Oberfläche bedeckt mit Operationstüchern platziert. Das zweite Leberphantom ist Teil des OpenHELP Systems (Kenngott *et al.*, 2015) und wurde deshalb auch für die Aufnahmen (Wolf PAL Endoskop 2, Storz HD Endoskop 2) in der vorgesehenen Stelle im 3D gedruckten OpenHelp Patientenphantom platziert (siehe Abbildung 5.6).

Wie schon zuvor erwähnt, wurde das optische Trackingsystem NDI Polaris Spectra für die Ermittlung der Posen des Stereoendoskops eingesetzt. Um die Telexperimente mit ausschließlichem projektiven ICP Tracking evaluieren zu können, wurde die Endoskoppose des ersten Frames mit dem Polaris Spectra System ermittelt und als Registrierung des Mosaiks zum Referenzmodell genutzt.

Die Ergebnisse, in Tabelle 5.3 dargestellt, zeigen eine Verbesserung der Rekonstruktionsgenauigkeit und der Stabilität des Verfahrens durch die Verwendung

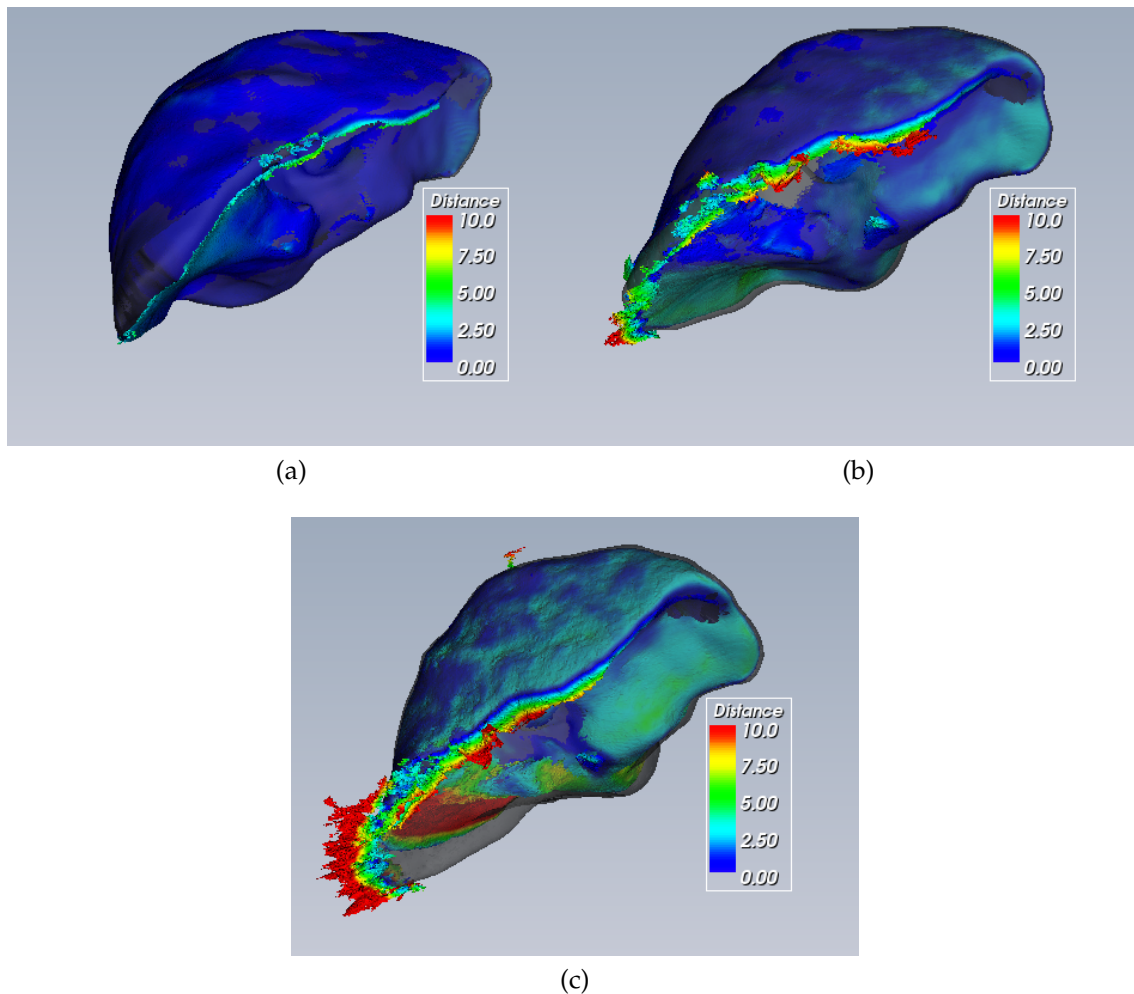


Abbildung 5.5: Root-mean-square (RMS) Fehlerverteilung der Mosaik für (a) Rauschen 1, (b) Rauschen 2 und (c) Rauschen 3.

des neueren Storz HD Stereoendoskops. In Bezug zum verwendeten Trackingansatz mit dem Wolf PAL Stereoendoskop, konnten die besten Ergebnisse mit dem reinen optischen Polaris Tracking erreicht werden. Bei den Aufnahmen mit dem Storz HD Stereoendoskop zeigt sich hier eine Veränderung. Das beste Tracking verschiebt sich hier in Richtung kombiniertem Tracking. Das reine projektive ICP Tracking schnitt bei allen Aufnahmen am schlechtesten ab.

In Abbildung 5.8 sind Beispiele gescheiterter Mosaik zu sehen, bei denen ein reines und kombiniertes ICP Tracking verwendet wurde. Hier führen große Fehler in der Schätzung der Kameraposition und -orientierung während mehreren Zeitschritten oft zu einer Art Bruch des globalen Modells. Das System kann die vorherige (korrekte) Lage des globalen Modells dann nicht wiederherstellen. Dieses Problem besteht beim optischen Tracking nicht, da hier jeweils unabhängige absolute Kameraposen für jeden Zeitschritt bestimmt werden.

Um festzustellen, ob das hier vorgestellte Mosaikverfahren für die rigide initia-



(a)



(b)



(c)



(d)

Abbildung 5.6: (a) Experimentelles Phantom Setup: Stereoendoskop, optisches Trackingsystem (NDI Polaris Spectra) und das OpenHELP Patientenphantom (Kenngott *et al.*, 2015). (b) Silikonleber 1. (c) Silikonleber 2. (d) Silikonleber 3.

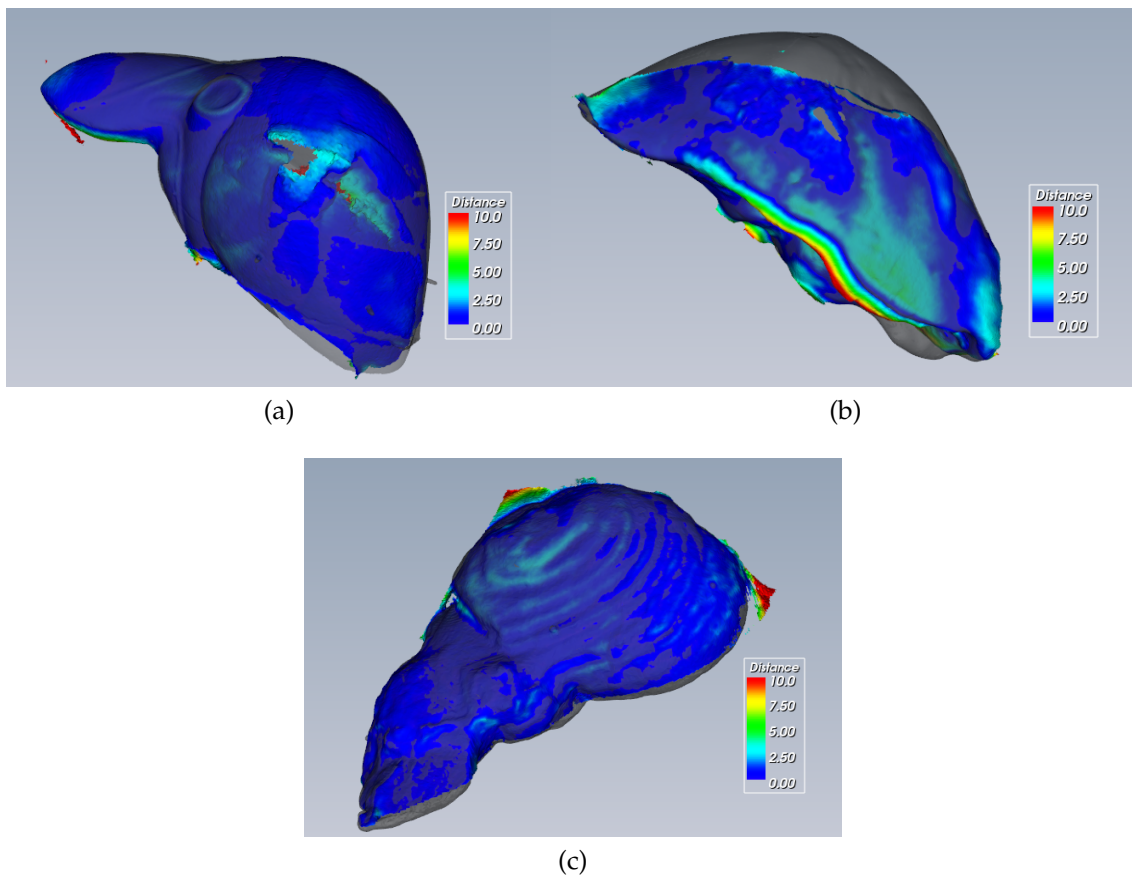


Abbildung 5.7: RMS Fehlerverteilung für die HD stereoendoskopischen Aufnahmen in (a) Silikonleber 1, (b) Silikonleber 2 und (c) Silikonleber 3. Die Fehlerverteilungen für die Aufnahmen mit dem Wolf PAL Stereoendoskop können in der Veröffentlichung (Bodenstedt *et al.*, 2015) betrachtet werden.

Phantomversuch	Endoskopposition			einzelner Frame
	Polaris	ICP	Kombiniert	Polaris Tracking
Wolf PAL Endoskop 1	1,89 ±1,97	5,04 ±4,66	3,79 ±3,37	2,88 ±2,14
Wolf PAL Endoskop 2	3,64 ±3,55	6,73 ±5,97	6,14 ±5,59	5,36 ±5,33
Storz HD Endoskop 1	1,04 ±0,98	1,64 ±1,26	0,73 ±0,61	2,12 ±1,69
Storz HD Endoskop 2	2,13 ±1,78	3,76 ±3,42	1,36 ±1,27	3,31 ±2,58
Storz HD Endoskop 3	1,56 ±1,29	4,32 ±3,83	1,27 ±0,94	2,48 ±2,04

Tabelle 5.3: Der Root-mean-square Fehler (RMSE) zwischen den Mosaikmodellen und den Referenzmodellen in *mm*. Die Qualität des Mosaiks konnte durch die Verwendung des neueren Storz HD Stereoendoskops in beiden Fällen verbessert werden. Die ersten beiden Aufnahmen (Zeile 1 und 2) zeigen eine starke Abhängigkeit des finalen Mosaiks von der Qualität der einzelnen HRM Rekonstruktionen. So spiegeln sich die Fehlergrößen der einzelnen HRM Rekonstruktionen (letzte Spalte) in den Fehlern für das Mosaik wieder.

le Registrierung eines präoperativen Modells nutzbar ist, wurde auch hierzu ein Versuch durchgeführt. Als erstes wurde das Laser Referenzmodell der Silikonleber 1 zufällig rotiert und translatiert. Dieser Vorgang wurde wiederholt, um 600 unterschiedliche zufällige Transformationen des Referenzmodells zu erhalten.

Für die rigide Registrierung zwischen Mosaik und transformiertem Referenzmodell wurde im ersten Schritt das Fast Point Feature Histograms (FPFH) Verfahren von Rusu *et al.* (2009) genutzt. Die Stärke dieser Methode liegt in ihrer Fähigkeit Objekte auch trotz großer Transformationen zu registrieren und dabei nicht in lokalen Minima zu verharren. Viele andere Verfahren benötigen eine Grobe initiale Ausrichtung der Objekte für eine zuverlässige Registrierung. Die Iterative Closest Point Methode fällt ebenfalls in diese Kategorie. Da ICP aber gerade bei kleinen Transformationen gute Ergebnisse liefert, wird die erste Ausrichtung des Mosaiks durch das FPFH Verfahren zusätzlich mit der ICP Methode verfeinert.

Der durchschnittliche Abstandsfehler (RMSE) über die 600 zufälligen Transformationen beträgt $13,19 \text{ mm} \pm 23,39 \text{ mm}$, wobei 90% der Registrierungen einen Fehler von unter 10 mm aufweisen. Als Vergleich wurde die gleiche Registrierungs-pipeline auch auf einzelne zufällig ausgewählten HRM Stereorekonstruktionen angewendet. Für die ebenfalls 600 Registrierungen ergibt sich hier ein Fehler von $89,92 \text{ mm} \pm 20,48 \text{ mm}$. Somit konnte in diesem Versuch durch die Erstellung eines Mosaikmodells, der Registrierungsfehler von 89,92 mm auf 13,19 mm und damit um 85% gesenkt werden.

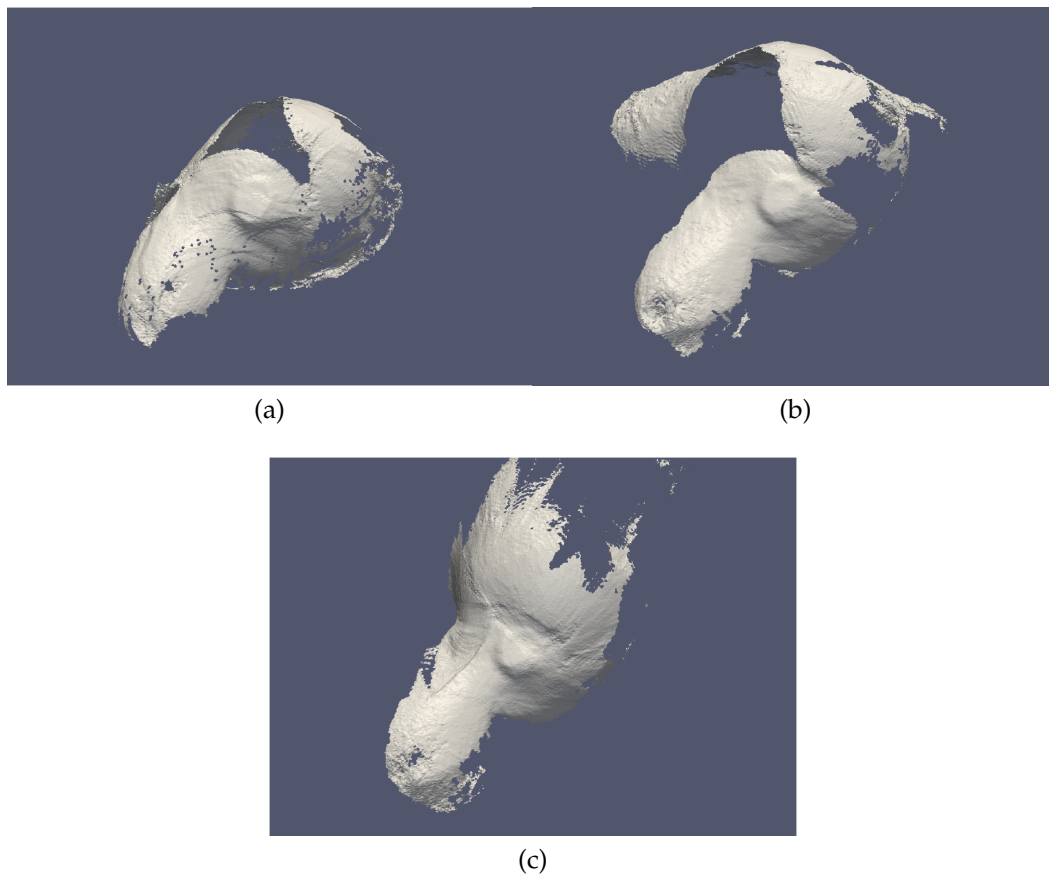


Abbildung 5.8: Beispiele eines ICP Fehlers mit Silikonleber 1: (a) zeigt eine korrekte Rekonstruktion mit reinem optischen Tracking. Die fehlenden Punkte in der Mitte des Modells wurden nicht durch die Aufnahmen abgedeckt. (b) zeigt ein Mosaik, welches mit reinem ICP Tracking erzeugt wurde. Der Bereich in dem das Tracking versagte ist deutlich zu erkennen. Das Mosaik wirkt wie auseinandergebrochen. Auch beim kombinierten Tracking in (c) kann es durch den Einfluss des ICPs zu großflächigen Rekonstruktionsfehlern kommen.

5.2.3 Ex vivo Schweineleber

Als erster Schritt zu realen Operationsbedingungen wurden zwei ex vivo Experimente mit je einer Schweineleber durchgeführt. Die Organe wurden von einer Schlachtereier bezogen. Die Schweinelebern wurden ähnlich zu den Silikonlebern 1 und 3 auf einer ebenen Fläche gelagert. Statt eines Operationstuchs wurden ausgedruckte endoskopische Bilder von einer Bauchhöhle auf die Fläche gelegt, um einem in vivo Setting so nahe wie möglich zu kommen.

Im ersten Versuch (Leber 1) wurde das Wolf PAL Stereoendoskop zu Bildakquise verwendet. Die Referenzdaten stammen von einem kurz vor der Aufnahme erstelltem Laserscan. Für den zweiten ex vivo Versuch (Leber 2) wurde das




Abbildung 5.9: Fehlerverteilung (RMSE) für die ex vivo Experimente: (a) Ex vivo mit Wolf Stereoendoskop. Blau signalisiert einen Fehler unter 2 mm und rot einen Fehler über 2 mm . (b) Ex vivo mit Storz HD Stereoendoskop.

Storz HD Stereoendoskop für die Stereobildakquise und eine danach erstellte CT-Aufnahme verwendet (Abbildung 5.9).

Durch die komplexeren Oberflächeneigenschaften (Textur und Feuchtigkeit) des echten Organs, liegt die Genauigkeit erwartungsgemäß leicht unter den Ergebnissen der Phantomversuche 5.4. Mit dem Wolf PAL Stereoendoskop (Wolf PAL ex vivo) konnte ein durchschnittlicher RMSE von $4,21\text{ mm} \pm 3,78\text{ mm}$ erreicht werden. Dieses Ergebnis ist nur geringfügig schlechter als bei Wolf PAL Endoskop 1 mit $1,89\text{ mm} \pm 1,97\text{ mm}$ und Wolf PAL Endoskop 2 mit $3,64\text{ mm} \pm 3,55\text{ mm}$. Bei der Aufnahme mit dem Storz HD Stereoendoskop (Storz HD ex vivo) war die Genauigkeit des Mosaiks mit $1,57\text{ mm} \pm 1,63\text{ mm}$ sogar höher als bei der Phantomaufnahme „Storz HD Endoskop 2“ mit $2,13\text{ mm} \pm 1,78\text{ mm}$.

Ex vivo	Endoskopposition			einzelner Frame Polaris Tracking
	Polaris	ICP	Kombiniert	
Wolf PAL ex vivo	$4,21 \pm 3,78$	$10,37 \pm 5,67$	$10,94 \pm 5,48$	$6,88 \pm 6,11$
Storz HD ex vivo	$1,57 \pm 1,63$	$2,23 \pm 1,97$	$1,51 \pm 1,21$	$6,38 \pm 4,79$

Tabelle 5.4: Der Root-mean-square Fehler (RMSE) zwischen den Mosaikmodellen und den Referenzmodellen in mm . Durch die Verwendung des neueren chip-on-the-tip HD Stereoendoskops von Storz konnte die Genauigkeit des Mosaiks deutlich verbessert werden. Dies demonstriert den großen Einfluss der Bildqualität und der Auflösung für das Rekonstruktionsergebnis und damit auch für die Qualität des Mosaiks.

Die qualitativ vergleichbaren Ergebnisse bei den Phantomversuchen, unter der Verwendung der gleichen Hardwarekomponenten, zeigen dass die Stereorekon-

struktion für die reale Leberoberfläche und -textur geeignet ist. Durch die Verwendung des Storz HD Stereoendoskops (Storz HD ex vivo) konnte der Fehler im Vergleich zu der „Wolf PAL ex vivo“ Aufnahme von $4,21 \text{ mm} \pm 3,78 \text{ mm}$ auf $1,57 \text{ mm} \pm 1,63 \text{ mm}$ reduziert werden. Zwar lassen die Unterschiede im Versuchsaufbau Raum für kleine Abweichungen der Ergebnisse, eine Verbesserung in dieser Größenordnung lässt sich aber nur durch die verbesserten optischen Eigenschaften des neuen Storz HD Stereoendoskops erklären.

5.2.4 In vivo Schweineleber

Um den Gegebenheiten einer echten Operation so nahe wie möglich zu kommen, wurde neben den ex vivo Versuchen auch ein in vivo Tierversuch am Schwein durchgeführt. Dafür wurde das Schwein zunächst durch die Chirurgen für die Operation vorbereitet. Mit einsetzen der Narkose wurde das Schwein auf den fahrbaren Tisch des CT-Geräts umgelagert (siehe Abbildung 5.10). Für die Lagerung wurde eine Vakuummatte verwendet, die durch Absaugen der Luft erstarrt und damit das Schwein stabilisieren kann. Auf dem CT-Tisch wurden anschließend die Ports (Zugänge) für die CO_2 -Insufflation, das Stereoendoskop und für die laparoskopischen Instrumente gesetzt.

Nach dem Anlegen des Pneumoperitoneums (Füllen des Bauchraums mit Gas) und des Einbringens der Instrumente und des Stereoendoskops, wurden drei Aufnahmereihen angefertigt. Dabei wurde je Sequenz das Stereoendoskop über die gesamte sichtbare Oberfläche der Schweineleber geführt. Direkt nach jeder endoskopischen Aufnahmesequenz wurde ein CT-Scan des Schweinetorsos gefahren, welcher als Referenzmodell zur Evaluation der anschließend durchgeführten Rekonstruktionen dient. Um Atemdeformationen zwischen den endoskopischen und den CT-Aufnahmen zu minimieren, wurde die Atmung in diesem Zeitraum pausiert.

In vivo	Endoskopposition			einzelner Frame
	Polaris	ICP	Kombiniert	Polaris Tracking
In vivo 1	$0,75 \pm 0,65$	$1,97 \pm 1,72$	$0,54 \pm 0,36$	$5,11 \pm 3,96$
In vivo 2	$1,87 \pm 1,03$	$2,48 \pm 1,33$	$0,97 \pm 0,79$	$7,25 \pm 5,53$
In vivo 3	$1,92 \pm 1,54$	$2,21 \pm 1,27$	$1,07 \pm 1,02$	$6,03 \pm 4,60$

Tabelle 5.5: Der Root-mean-square Fehler (RMSE) zwischen den Mosaikmodellen und den Referenzmodellen in *mm*. Nach jeder Aufnahme wurde ein CT-Scan für die Erzeugung eines Referenzmodells durchgeführt. Die Aufnahmen wurden durch je unterschiedliche und frei gewählte Endoskopbewegungen durch den Chirurgen erzeugt. Die unterschiedlichen Fehlerwerte der einzelnen Sequenzen deuten darauf hin, dass die Handhabung des Endoskops während der Aufnahme einen nicht zu vernachlässigenden Einfluss auf das Rekonstruktionsergebnis hat.

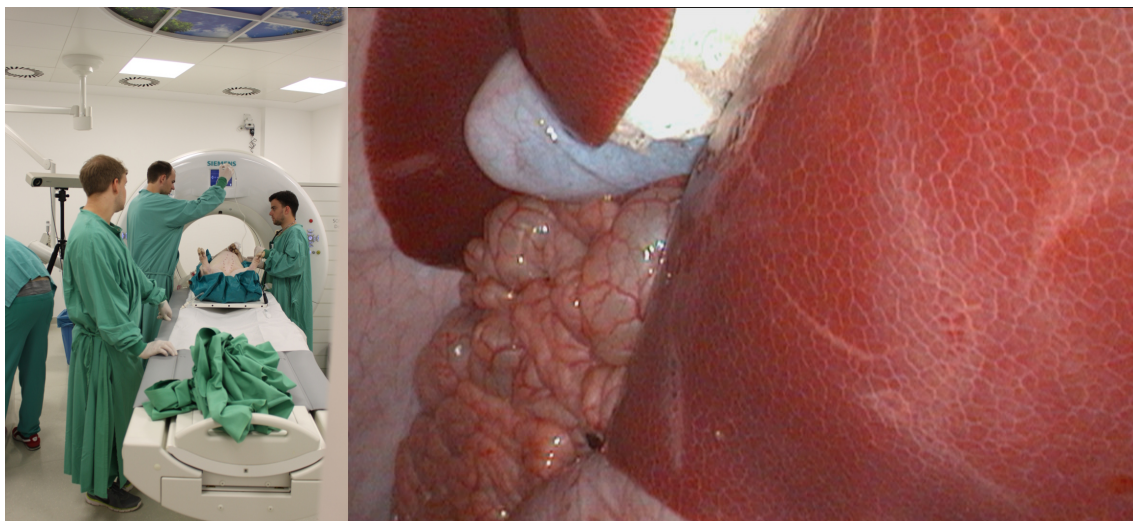


Abbildung 5.10: Aufbau des in vivo Experiments für die Evaluation unter realen Operationsbedingungen. Die Aufnahmesequenzen wurden direkt auf dem Tisch des CT-Geräts erstellt, um die Zeiträume zwischen endoskopischen und CT Aufnahmen zu minimieren. Das letzte Bild zeigt eine exemplarische Aufnahme des Stereoendoskops. Es ist die Leber, der Darm und die Gallenblase sichtbar.




Abbildung 5.11: Root-mean-square Fehlerverteilung für den in vivo Tierversuch.
(a) Polaris; (b) ICP; (c) Kombiniert


Die besten Ergebnisse in den in vivo Aufnahmen konnten mit dem kombinierten Tracking erreicht werden (siehe Tabelle 5.4 und Abbildung 5.11). Alle Aufnahmen wurden mit dem Storz HD chip-on-the-tip Stereoendoskop erzeugt. Mit einem RMSE von $0,54 \text{ mm} \pm 0,36 \text{ mm}$ (In vivo 1), $0,97 \text{ mm} \pm 0,79 \text{ mm}$ (In vivo 2) und $1,07 \text{ mm} \pm 1,02 \text{ mm}$ (In vivo 3) liegen die Fehler der in vivo Mosaik im gleichen Bereich wie die des Storz ex vivo Versuchs und der Phantomaufnahmen.

5.3 Zusammenfassung


In diesem Kapitel wurde ein Verfahren zur Rekonstruktion und Segmentierung von Organen während laparoskopischen Eingriffen vorgestellt. Hierbei wurden Mosaikmodelle eingeführt, welche aus stereoendoskopischen Bilddaten aus mehreren Blickwinkeln zusammengesetzt werden. In den vorgestellten Evaluationsergebnissen konnte gezeigt werden, dass der Rekonstruktionsfehler eines Organmosaiks geringer als die Summe der einzelnen Stereorekonstruktionsfehler ist. Darüber hinaus konnte gezeigt werden, dass der Fehler für eine rigide initiale Registrierung mit einem präoperativen Modell durch ein intraoperatives Organmosaik deutlich gesenkt wird. Im Vergleich zu einzelnen Stereorekonstruktionen eines Stereobildpaars wurde der Registrierungsfehler von 90 mm auf 13 mm reduziert.

Mithilfe des Physics Based shape matching Verfahrens (PBSM) von Suwelack *et al.* (2014) konnte eine intraoperative nicht rigide Registrierung zwischen präoperativem CT-Modell und dem hier vorgestellten Mosaikmodell erreicht werden (Suwelack *et al.*, 2014). Beim Physics Based Shape Matching wird das nicht rigide Registrierungsprozess als elektrostatisches Problem beschrieben. Dabei gleitet ein elektrisch aufgeladener elastischer Körper (das präoperative Modell) in die rigide Form des entgegengesetzt aufgeladenen intraoperativen Modells (hier das Mosaikmodell). Ein Beispiel hierfür ist in Abbildung 5.12 zu sehen. Um die elektrische Energie zu minimieren und die Deformation abzubilden, wurde die Finite Elemente Methode (FEM) genutzt. Eine ausführliche Beschreibung des PBSM Verfahrens und der hierbei verwendeten biomechanischen Modelle und Grundlagen kann in der Dissertation (Suwelack, 2015) gefunden werden.

Der Vergleich der Rekonstruktionsergebnisse des Wolf PAL Stereoendoskops und des Storz HD Stereoendoskops erlauben einen Einblick auf die Abhängigkeit der Bildqualität auf das finale Rekonstruktionsergebnis. Die Daten deuten darauf hin, dass die Bildqualität und Auflösung des Bildsensors für zwei Schritte im Mosaikprozess von besonderer Bedeutung sind. Zunächst spielt die Qualität des Bildmaterials natürlich für die Stereorekonstruktion durch das Hybrid Recursive Matching (HRM) eine entscheidende Rolle. Hier sind vor allem eine gute Ausleuchtung der Szene, geringe Verzerrungsfehler bzw. eine gute Rektifizierung und ein geringes Bildrauschen entscheidend. In Abbildung 5.13 ist zu sehen wie sich Bildrauschen aufgrund zu geringer Beleuchtung auf das Rekonstruktionsergebnis auswirken kann.




(a) Referenzmodell vor und nach Deformation (b) Registrierung mit vollständigem CT-Modell




(c) Registrierung mit partiellem CT-Modell (d) Registrierung mit dem hier vorgestellten intraoperativen Mosaikmodell

Abbildung 5.12: In Suwelack *et al.* (2014), konnte gezeigt werden, dass eine intraoperative nicht rigide Registrierung durch Physics Based Shape Matching mit der Verwendung des hier vorgestellten Mosaikverfahrens erreicht werden kann. Weitergehende Informationen können in Suwelack *et al.* (2014) und Suwelack (2015) gefunden werden.



(a)

(b)



(c)

Abbildung 5.13: Endoskopische Herausforderungen: (a) Da alle Oberflächen in das globale Modell integriert werden, verfälschen Instrumente zuvor aufgenommene Oberflächenbereiche. (b) zeigt eine schlecht ausgeleuchtete Endoskopaufnahme, die in (c) zu einer HRM-Rekonstruktion mit fehlerhaften Regionen führt.

Während Rauschartefakte in den einzelnen Stereorekonstruktionen durch die gewichtete Integration in das Mosaikmodell reduziert werden kann, hat die Qualität der HRM-Rekonstruktionen auch noch einen zweiten indirekten Einfluss auf das Mosaikmodell. Ohne die Nutzung des optischen Trackingsystems Polaris, werden die Rekonstruktionen der einzelnen Zeitschritte auch verwendet, um mit einem projektiven ICP Ansatz die Lage des neuen Teilstücks zur Lage des Mosaikmodells zu registrieren (siehe Abschnitt 5.1.3). Je nach abgebildeter Szenengeometrie führen Rausch- und Fehlerartefakte in der HRM-Rekonstruktion ab einem gewissen Grad zu großen Fehlern in der Schätzung der aktuellen Kamerapose durch das projektive ICP Verfahren. Mehrere aufeinanderfolgende fehlerhafte Kamerapositionsschätzungen führen meist zu einem kompletten Versagen in der Mosaikerzeugung (siehe hierzu auch die Abbildung 5.8).

Da bei der Nutzung eines optischen Trackingverfahrens, wie des Polaris Spectra Systems, die HRM-Rekonstruktionen keinen Einfluss auf die Kamerapositionsschätzung haben, ist die Mosaikerzeugung in diesem Modus weniger anfällig für Rekonstruktionsfehler, da hier die Teilstücke zumindest an der richtigen Stelle des Modells eingefügt werden. So besteht durch folgende Integration noch die Möglichkeit die Fehler durch die Gewichtung mehrerer verrauschter Aufnahmen zu reduzieren und die Qualität des globalen Mosaikmodells damit zu verbessern.

In den durchgeführten Experimenten wurden die besten Ergebnisse stets mit Einbeziehung des optischen Trackings erreicht. Durch technischen Fortschritt in der Hardwarekonstruktion, wie etwa die neu verfügbaren HD chip-on-the-tip Stereoendoskope, ist das Potential des bildbasierten Trackings aber noch lange nicht ausgeschöpft. So zeigen die ex vivo Ergebnisse durch die Nutzung des technisch fortschrittlicheren Storz HD Stereoendoskops, eine Reduzierung des Mosaik-Rekonstruktionsfehlers um 78%. Außerdem konnte mit dem Storz HD Stereoendoskop und dem kombinierten Trackingmodus aus ICP und Polaris, das reine optische Tracking übertroffen werden. Hierbei werden aller Wahrscheinlichkeit nach kleine Posenschätzfehler durch das optische Tracking mit dem ICP ausgeglichen. Da das optische Tracking andererseits eine robuste initiale Posenschätzung bereitstellt, kann hier von einer synergetischen Verknüpfung der Verfahren gesprochen werden.

Neben den beschriebenen Erfolgen gibt es natürlich auch Limitierungen des Verfahrens. So führen Objekte, wie beispielsweise laparoskopische Instrumente, die sich während der Aufnahme zwischen Endoskop und Organ bewegen zu Rekonstruktionsfehlern. Die Instrumente werden hierbei zwar mit hoher Wahrscheinlichkeit als Hintergrund klassifiziert, jedoch trotzdem in das globale Voxel-Volumen integriert. Dies zerstört vorhergehende korrekte Rekonstruktionen dieses Szenenbereichs. Um dieses Problem zu lösen, könnte eine zusätzliche Segmentierungsklasse für Instrumente angelegt werden. Statt diese Bereiche dann wie Hintergrund zu integrieren, würden diese Rekonstruktionspunkte von der Integration in das Voxel-Volumen ausgeschlossen werden. Für diesen Ansatz ist

allerdings eine robuste und automatische Erkennung von laparoskopischen Instrumenten notwendig (Bodenstedt, 2017).

Die Hauptfehlerquelle des Mosaikprozesses ist in der Rekonstruktionsqualität des HRM-Stereomatchings zu finden. Leichte Abweichungen von den optimalen Beleuchtungswerten der operativen Szene können zu Bildrauschen und damit verbundenen schlechten Rekonstruktionsergebnissen führen. In Abbildung 5.13 ist eine solche Situation abgebildet. Aus diesem Grund ist eine genaue Überwachung der Aufnahmeparameter für gute Rekonstruktionsergebnisse unerlässlich. Da in einem realen Einsatz des Systems das Operationspersonal für die Aufnahmen verantwortlich ist, müssten hier Wege gefunden werden, um diese Personen für die möglichen Problematiken zu sensibilisieren.

Dies gilt ebenso für die Größe der Oberflächenbereiche, die mit dem Stereodoskop aufgenommen wurde. Um genügend Oberflächeninformationen zu erhalten müssen Kameraschwenks über das Organ durchgeführt werden. Hierfür muss natürlich der nötige Bewegungsspielraum des Endoskops im Bauchraum gegeben sein. Für die Planung des Zugangsports für das Endoskop ist dies zu berücksichtigen.

Als letzten Punkt sollten die Limitierungen des ICP basierten Trackings beachtet werden. Dies gilt für das reine und das kombinierte ICP Tracking. Organe mit Oberflächenstrukturen und charakteristischen Formen, wie die Leber oder die Nieren, bieten einige Anhaltspunkte für ein bildbasiertes Tracking. Für Organe mit homogenerem Aussehen, wie die Prostata, könnte ein bildbasierter Ansatz an seine Grenzen stoßen. Allgemein ist vom jetzigen Stand des bildbasierten Trackings, auch im Vergleich mit anderen Verfahren im Stand der Forschung, für riskante Eingriffe wie bei der laparoskopischen Chirurgie nicht verantwortbar auf optische Trackingsysteme wie dem Polaris Spectra Gerät zu verzichten.

Das Studienprotokoll für den in vivo Tierversuch wurde von der lokalen Ethikkommission Heidelberg und der regionalen Kommission Karlsruhe genehmigt. Die Veterinäre Betreuung wurde durch das Personal der interfakultativen biomedizinischen Forschungsanstalt an der Universität Heidelberg geleistet. Alle Tiere wurden in Übereinstimmung mit den Kriterien der Deutschen Forschungsgemeinschaft für humane Behandlung betreut, welche im Leitfaden für die Nutzung und Behandlung von Labortieren der nationalen Institute für Gesundheit bereitgestellt wurden.

Kapitel 6

Dynamische Weichgeweberegistrierung

Im vorhergehenden Kapitel wurde die initiale Weichgeweberegistrierung behandelt, bei der das Ziel eine erstmalige robuste Registrierung des präoperativen Organmodells zur intraoperativen Szene ist. Diese initiale Registrierung ist im Normalfall jedoch nur sehr kurze Zeit gültig, da das Weichgewebe durch physiologische Vorgänge (Atmung, Herzschlag, usw.) sowie durch Manipulationen des Chirurgen während der Operation verschoben und deformiert wird (siehe Abbildung 6.1). Diese Einflüsse kontinuierlich auszugleichen ist Aufgabe der dynamischen Registrierung. Da sich hierbei das intraoperative Modell ständig verändert, können dabei keine statischen Mosaikmodelle wie in der initialen Registrierung verwendet werden.




Abbildung 6.1: Durch physiologische Vorgänge (Atmung, Herzschlag, usw.) sowie durch Manipulationen des Chirurgen während der Operation, wird das intraoperative Organ deformiert und entspricht nicht mehr der Form und Lage des zuvor generierten biomechanischen Modells

In diesem Kapitel wird ein neues Verfahren zur projektiven biomechanischen Weichgeweberegistrierung vorgestellt. Als intraoperative Datenquelle dient ein getracktes Stereoendoskop. Für eine initiale Registrierung wird das in Kapitel 5 beschriebene Verfahren verwendet, bei dem ein präoperatives biomechanisches Modell des Organs mit dessen intraoperativen Mosaik-Gegenstück registriert wird.

Nach der initialen Registrierung wird das biomechanische Modell kontinuierlich durch die berechneten Tiefendaten des Stereoendoskops dynamisch adaptiert. Hierbei werden statt einzelner Landmarken die gesamte Tiefenkarte auf das biomechanische Modell projiziert und als Randbedingungen genutzt.

Der wesentliche Beitrag dieser Arbeit ist die automatische Assoziierung des biomechanischen Modells mit den intraoperativen Tiefendaten des Stereoendoskops. Dies führt zu einer dynamischen Anpassung des Organmodells während des Eingriffs. Die dichte Assoziierung aller Rekonstruktionpunkte erlaubt die Übertragung von sowohl globalen als auch kleinen lokalen Deformationsinformationen an das biomechanische Modell.

Das Verfahren wurde zunächst an *in silico* Deformationsmodellen evaluiert, um quantitative Daten zur Registrierungsgenauigkeit zu erlangen. Zusätzlich werden qualitative Ergebnisse eines *in vivo* Schweineversuchs präsentiert, welche eine erste Einschätzung zum Verhalten des Systems unter realen Bedingungen liefern sollen.

6.1 Methoden

Das Kernstück dieses Verfahrens ist das biomechanische Modell, welches aus den präoperativen CT-Daten gewonnen wird. Der komplette Registrierungsprozess ist in zwei Hauptteile gegliedert:

- Für eine robuste initiale Registrierung des präoperativen biomechanischen Modells wird das in Kapitel 5 vorgestellte Verfahren für intraoperatives Mosaiking genutzt. Dazu wird eine kurze Aufnahmesequenz der intraoperativen Organoberfläche benötigt, währenddessen größere Deformationen des Organs vermieden werden sollten.
- Nach der initialen Registrierung folgt die fortlaufende dynamische Registrierung des zuvor an die Organoberfläche angepassten biomechanischen Modells. Damit werden Verschiebungen und Deformationen des Organs in jedem Zeitschritt sofort auf das biomechanische Modell übertragen. Da der dynamische Registrierungsprozess direkt mit dem biomechanischen Modell verbunden ist, können Auswirkungen der Rauschartefakte des Kamerasensors und der Stereorekonstruktion durch die biomechanischen Bedingungen und Kräfte des Modells gedämpft werden.

Beide Registrierungsschritte basieren auf einem dichten Abgleich aller Rekonstruktionspunkte und sind deshalb nicht von einem sensiblen Prozess der Landmarkenerkennung und -verfolgung abhängig.

6.1.1 Intraoperative Oberflächenrekonstruktion

Das Stereoendoskop dient als intraoperative Datenquelle. Um diese Daten für die Registrierungsschritte nutzen zu können, müssen diese vorverarbeitet werden:

Segmentierung Um ein intraoperatives Oberflächenmodell eines Organs zu erzeugen, müssen zunächst die Bildbereiche erkannt werden in denen sich das gesuchte Organ befindet. Dieser Segmentierungsvorgang wird in Echtzeit nach jeder Aufnahme durch ein Random Forest Ansatz mit Superpixeln durchgeführt (Bodenstedt *et al.*, 2016). Diese Segmentierungsmaske wird mit der im Folgenden erzeugten Tiefenkarte verknüpft. Da sich anders wie bei der initialen Registrierung die Geometrie ständig ändert, kann hier immer nur die Segmentierung des aktuellen Frames verwendet werden.

3D-Rekonstruktion Wie in Kapitel 4 ausführlich behandelt, können mit Stereorekonstruktionsalgorithmen dreidimensionale Oberflächenmodelle aus Stereokamerabildern gewonnen werden. Dabei wird das Hybrid Recursive Matching (HRM) Verfahren von (Röhl *et al.*, 2012) genutzt, welches speziell für laparoskopische Bilddaten optimiert wurde. Mithilfe der bestimmten Tiefenkarte und den Kameraparametern kann ein 3D Oberflächenstück S_i für jeden Frame i berechnet werden. Dieser Prozess wird sowohl für die initiale sowie auch für die dynamische Registrierung benötigt.

6.1.2 Biomechanisches Modell

Die Deformationen eines Organs vor und während einer Operation, werden durch das physikalische Verhalten des Organgewebes beschränkt. Aus diesem Grund sollte der intraoperative Registrierungsprozess auf die gleiche Weise beschränkt werden (Suwelack *et al.*, 2014, Suwelack, 2015). Um dies zu erreichen, wird ein biomechanisches Modell auf Grundlage der Finiten Elemente Methode (FEM) genutzt, welches die mechanischen Kräfte und Randbedingungen bestimmt. Das SOFA Framework¹ bietet hierzu eine gute Basis für FEM Simulationen.

Das biomechanische Modell wird durch drei Komponenten definiert:

Geometrische Form Die geometrische Form des biomechanischen Modells wird durch die präoperativen Planungsdaten bestimmt. In den meisten Fällen werden dabei Aufnahmen aus der Computertomographie (CT) oder dem

¹<https://www.sofa-framework.org/>

Magnetresonanztomografen (MRT) genutzt. Ärzte extrahieren dazu halb-automatisch Oberflächenmodelle der wichtigen Strukturen (Organe, Tumore, Gefäße) aus den dreidimensionalen Schichtbildern. In dieser Arbeit wurde MITK² (Nolden *et al.*, 2013) für diesen Segmentierungsprozess genutzt. Da biomechanische Modelle auf volumetrischen Daten basieren, müssen dabei die Oberflächen-Dreiecksnetze in volumetrische Tetraedernetze umgewandelt werden. Dafür wurde das CGAL Softwareprojekt³, wie in Abbildung 6.2 gezeigt, genutzt.




Abbildung 6.2: Zunächst wird ein Oberflächenmodell aus den CT- oder MRT-Daten extrahiert. Da das biomechanische Modell eine volumetrische Repräsentation benötigt, wird aus dem Oberflächen-Dreiecksnetz in einem weiteren Schritt ein volumetrisches Tetraedernetz erzeugt.

Materialeigenschaften Das Verhalten des volumetrischen Tetraedernetzes wird durch seine Materialeigenschaften definiert. Die Steifheit des Modells wird mit dem Elastizitätsmodul oder auch Young's Modulus beschrieben. In der Literatur sind hierzu für Weichgewebe eine große Spannweite von einigen hundert bis zu tausenden Pascal angegeben (siehe hierzu auch Kapitel 7). In dieser Arbeit wurde ein E-Modul von 3000 Pascal genutzt, da hiermit das stabilste Verhalten innerhalb des möglichen Wertebereichs erreicht werden konnte. Da die referierten Werte für die Dichte von Lebergewebe nur leicht von Wasser abweicht (1,07 g/ml), wurde eine Dichte von 1 g/ml gewählt. Der letzte Materialparameter, die Poissonzahl, gibt die Kompressibilität des Gewebes an. Da in der Literatur (Fung, 2013) Werte zwischen 0,45 und 0,49 berichtet wurden, wird in dieser Arbeit ein Mittelwert von 0,47 für die Poissonzahl verwendet.

Randbedingungen Die Interaktion zwischen der intraoperativen Tiefenkarte und dem biomechanischen Modell wird durch Randbedingungen in Form eines

²<http://mitk.org>

³<http://doc.cgal.org/latest/Manual/packages.html#PartMeshing>

Feder-Kraftfelds realisiert. In Abschnitt 6.1.4 wird die Anwendung der Federkräfte deren Parameter detaillierter beschrieben.

6.1.3 Initiale Registrierung

Wie in Kapitel 5 beschrieben, können präoperative Daten und Modelle nicht direkt auf die Operationssituation übertragen werden. Die Lage und Form der inneren Organe kann sich durch äußere Faktoren, wie die Patientenlagerung oder das Anlegen des Pneumoperitoneums, erheblich verändern.

Bevor das biomechanische Modell $\mathcal{V} = \{v_k \in \mathbb{R}\}$ für die dynamische Registrierung verwendet werden kann, ist eine ausreichend genaue initiale Registrierung mit der intraoperativen Lage und Form des Zielorgans notwendig. Da ein einzelnes Oberflächenfragment S_i eines Frames i nicht genügend Informationen enthält, um eine robuste Registrierung zu ermöglichen, wird das in Kapitel 5 vorgestellte Mosaikverfahren eingesetzt. Im Mosaikprozess Φ werden mehrere Stereorekonstruktionen von verschiedenen Endoskopposen in ein gemeinsames globales Modell $\mathcal{S}_{global} = \Phi(S_1, S_2, \dots, S_i)$, wie in Abbildung 5.2 skizziert, integriert (Reichard *et al.*, 2015).

Für die eigentliche initiale Registrierung wird das biomechanische Modell \mathcal{V} zunächst durch das Sample Consensus Initial Alignment (Rusu *et al.*, 2009) Verfahren rigide an das intraoperative Mosaikmodell ausgerichtet. Die damit erreichte grobe Ausrichtung der Modelle wird als Startpunkt für das im Anschluss durchgeführte nicht-rigide Physics based Shape Matching Registrierungsverfahren (Suwelack *et al.*, 2014) verwendet.

Diese finale nicht-rigide Registrierung des biomechanischen Modells dient im Anschluss als Initialisierungskonfiguration für die dynamische Registrierung. Ausführlichere Informationen über die initiale Registrierung und das Mosaikmodell werden in Kapitel 5 gegeben.

6.1.4 Dynamische Registrierung

Durch laparoskopische Instrumente und physiologische Prozesse, wie der Atmung oder den Herzschlag, unterliegt Weichgewebe während eines operativen Eingriffs einer sich ständige ändernden Deformation. Um präoperative Daten trotzdem zuverlässig verwenden zu können, müssen diese morphologischen Änderungen online auf das präoperative bzw. biomechanische Modell übertragen werden. Für eine konsistente Registrierung muss diese also spätestens nach einigen Bildframes aktualisiert werden.

Die hier vorgestellte Methode nutzt die intraoperative Tiefenkarte und projiziert diese in einem iterativen Prozess auf das zuvor initial registrierte biomechanische Modell. Die Abweichungen zwischen den projizierten und den biomechanischen Werten werden genutzt, um das biomechanische Modell mit temporären Randbedingungen an die neue Form des Organs anzupassen. In Abbildung 6.3 ist der gesamte dynamische Registrierungsprozess dargestellt. Eine detaillierte Beschreibung wird in Häntschi (2017) gegeben.

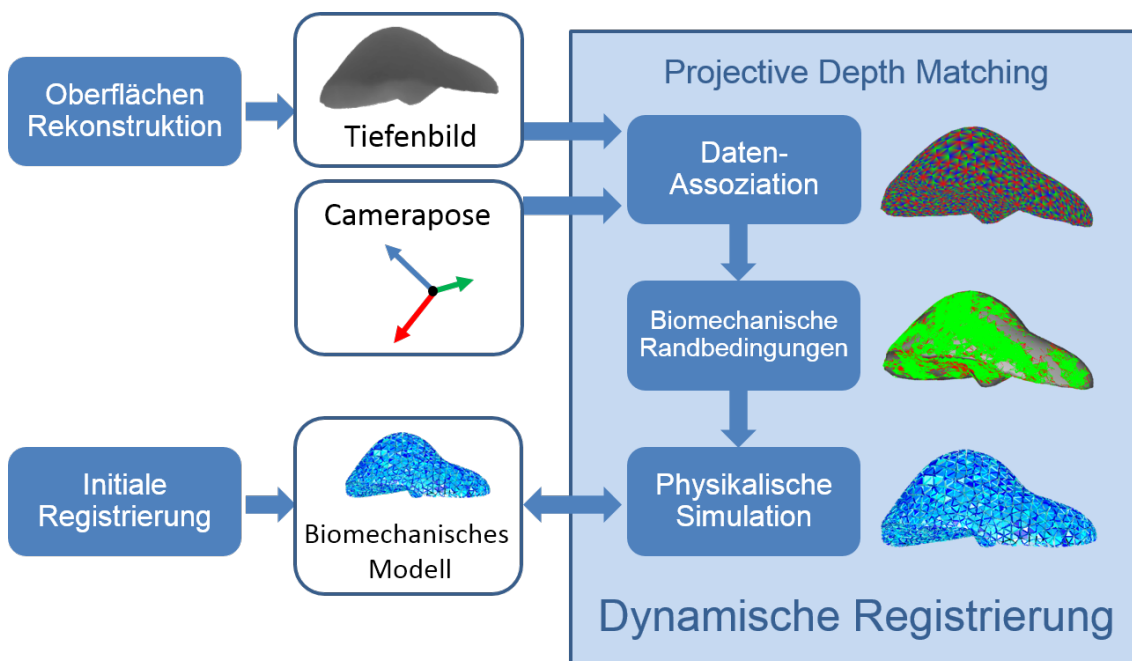


Abbildung 6.3: Ablauf der dynamischen Registrierung. Der projektive Tiefenabgleich aktualisiert das biomechanische Modell in jedem Bildframe und überträgt so morphologische Änderungen des intraoperativen Organs auf das präoperative Modell.

Die dynamische Registrierung kann in drei Teile gegliedert werden:

Datenassoziation Das biomechanische Modell wird in jedem Frame auf die aktuelle intraoperative Oberflächenrekonstruktion projiziert.

Biomechanische Randbedingungen Die Oberflächenverschiebungen zwischen biomechanischem Modell und intraoperativer Oberfläche werden als Randbedingungen für das biomechanische Modell verwendet.

Physiksimulation Die erzeugten Randbedingungen beeinflussen das biomechanische Modell durch potentielle Energie. Diese wird zusammen mit der inhärenten biomechanischen Regularisierungsenergie minimiert, um die biomechanische und intraoperative Oberfläche näher aneinander zu bringen.

Diese Schritte werden iterativ durchgeführt, wobei die Energie in jedem Durchlauf weiter minimiert wird.




Abbildung 6.4: (a) Das projizierte biomechanische Modell. Texturiert mit den OpenGL-IDs der Primitive. (b) Der intraoperative Oberflächenpunkt wird auf die Oberflächennormale des biomechanischen Modells projiziert. Dieser heuristische Schritt dient zur Gewichtung von Kräften aufgrund der Rekonstruktionsunsicherheiten und erlaubt gleichzeitig Kräfte, die nicht auf die Richtung des Kamerastrahls beschränkt sind. (c) Federn werden zwischen dem rekonstruierten Oberflächenpunkt und den assoziierten Vertices gespannt.

Datenassoziation

Für jeden Frame i wird die aktuelle Tiefenkarte \mathcal{D}_i mit der biomechanischen Modellkonfiguration \mathcal{V}_{i-1} assoziiert. Das wird erreicht, indem die Oberfläche des biomechanischen Modells $\mathcal{S}_{\mathcal{V}_{i-1}}$ in die Bildebene eines virtuellen Endoskops, mit der aktuellen Kamerapose $P_i = [R_i|T_i]$ und den intrinsischen Kameraparametern K , projiziert wird. Die Projektion erfolgt durch die OpenGL Rasterisierungs pipeline, in der das Oberflächenmodell des biomechanischen Modells mit der konfigurierten virtuellen Kamera gerendert wird.

Dabei wird jeder Oberflächenpunkt mit seinen baryzentrischen Koordinaten $\beta_{0,1,2}$ und den zugehörigen Primitiv IDs (ID des Dreiecks) mit den Vertices $v_{0,1,2}$. Pixel dem resultierenden Bild und dem Tiefenbild \mathcal{D}_i , welche die gleichen Bildkoordinaten (u, v) teilen, werden assoziiert. Dieses Vorgehen basiert auf der Annahme, dass wenn die Bewegung zwischen zwei Bildern klein ist, der Projektionsfehler ebenso klein ist. Für typische operative Szenen, die mit Frameraten über 15 fps (frames per second) aufgezeichnet werden, konnte diese Bedingung erfüllt werden.

Biomechanische Randbedingungen

Nachdem die mit den Tiefenwerte $d = \mathcal{D}_i(u, v)$ korrespondierenden Oberflächenpunkte $x_S = \beta_0 * v_0 + \beta_1 * v_1 + \beta_2 * v_2$ auf dem biomechanischen Modell gefunden wurden, kann aus den Tiefenwert und den inversen Kameraparametern eine Rückprojektion mit dem resultierenden dreidimensionalen Datenpunkt $x_D = P_i^{-1} K^{-1}(u, v, d)$ berechnet werden. In nächsten Schritt wird der aus dem Datenpunkt x_D abgeleitete Vektor $x_D - x_S$ auf den Normalenvektor des Oberflächenpunkts x_S projiziert, was einen angepassten Datenpunkt $x_E = (n_S \cdot (x_D - x_S)) n_S + x_S$ erzeugt (siehe Abbildung 6.4). Die Projektion auf die Normale bezieht einerseits die steigende Unsicherheit bei größeren Winkeln zwischen Kamerastrahl und Oberflächennormale n_S ein, außerdem werden damit Kräfte in laterale Richtungen ermöglicht. Ansonsten könnten Kräfte nur parallel zu den Kamerastrahlen (Grundlage der Projektion) angebracht werden und Bewegungen, die nicht parallel zur endoskopischen Sicht sind, damit nicht erfasst werden.

Die zuvor bestimmten angepassten Datenpunkte x_E werden nun durch lineare Federn mit dem Finiten Elemente Modell (FEM) verbunden. Für jeden Oberflächenpunkt x_S werden steife Federn, mit der Federkonstanten k , zwischen dem angepassten Datenpunkt x_E und den drei, mit dem Primitiv assoziierten Eckpunkte, aufgespannt. Die Länge der Feder (unbelasteter Zustand) wird durch die Entfernung zwischen x_S und den verbundenen Eckpunkte v_c , mit $c \in \{0, 1, 2\}$, gesetzt. Damit wird die Kraft der Federn gleich Null, wenn die Rückprojektion des Tiefenpunkts \mathcal{D}_i direkt auf der Oberfläche des assoziierten Dreiecks liegt.

Die Auslenkung der Federn wird durch $\Delta l = \|(x_E - v_c)\| - \|(x_S - v_c)\|$ bestimmt. Die dadurch resultierende potentielle Energie aller mit dem Oberflächennetz verbundenen Federn j ist damit $E_p = \sum_j \frac{1}{2} k \Delta l_j^2$. E_p ist eine implizite Repräsentation des summierten Fehlers zwischen den einzelnen assoziierten Paaren x_E und v_c .

Physiksimulation

Das verwendete biomechanische Modell basiert auf linearen Tetraederelementen, einem linearen Materialmodell und der Finiten Elemente Methode (FEM) zur numerischen Berechnung. Zusätzlich zu der zuvor berechneten äußeren Energie E_p der angebrachten Federn, besitzt das biomechanische Modell eine Regularisierungsenergie, welche die elastische Energie der aktuellen Modellkonfiguration wiedergibt:

$$E_{reg} = \int_V \tau^T \sigma dV / 2 ,$$

wobei V das Modellvolumen, τ der Verzerrungstensor, gegeben durch die räumliche Ableitungen der Verschiebungen und σ der Spannungstensor ist (Shi, 2007). Der Spannungstensor σ kann durch hookesche Gesetz bestimmt werden:

$$\sigma = M\tau,$$

wobei M die Materialmatrix, welche den Young's Modulus und die Poissonzahl enthält, ist.

Die totale potentielle Energie $E = E_p + E_{reg}$ des Systems, wird mithilfe eines konjugierten Gradientenlösers minimiert. Ist die Energiedifferenz $\Delta E = |E - E_{prev}|$ zwischen der aktuellen und der vorhergehenden Lösungsiteration geringer als ein Schwellwert (SOFA default) oder ist eine festgelegte Nummer von Iterationsschritten (in dieser Arbeit wurden 32-64 Schritte verwendet) erreicht, wird die nächste Tiefenkarte D_{i+1} verarbeitet. Bis dahin wird die Konfiguration des biomechanischen Modells durch die Schritte des projektiven Tiefenabgleichs iterativ mit den Werten der Tiefenkarte D_i aktualisiert. Der Simulationsprozess benötigt zwischen 20-25 Millisekunden und konnte durch eine Implementierung auf der GPU deutlich beschleunigt werden. Es wurde eine NVIDIA GTX 1080 Grafikkarte zur Berechnung der Physiksimulation verwendet.

6.2 Ergebnisse

In diesem Abschnitt werden experimentelle Ergebnisse des vorgestellten dynamischen Registrierungsverfahrens vorgestellt. Die Methode wurde zuerst mithilfe einer *in silico* Simulation von Leberdeformationen und dann im realen Operationsumfeld an einer *in vivo* Schweinemilz evaluiert. Durch die Nutzung des Simulationsframeworks konnten volumetrische Referenzdaten der Organdeformation erfasst und später zur quantitativen Evaluation des biomechanischen Tiefenabgleichs verwendet werden. Als Nachweis, dass die Methode auch in einem realistischen Umfeld einsetzbar ist, wurden Endoskop- und präoperative Daten eines *in vivo* Schweineexperiment aufgezeichnet und als Grundlage einer qualitativen Evaluation verwendet.

6.2.1 In silico Lebermodell

Um die Registrierungsgenauigkeit für Weichgewebedeformationen zu bestimmen, wurde ein Rendering-Framework (siehe Abbildung 6.5 und 6.7) und das Abaqus Softwarepaket⁴ genutzt. Mithilfe der Simulation von Abaqus wurden Lebermodelle deformiert und das resultierende Oberflächen- und Volumennetz für jeden Zeitschritt exportiert. Es wurden vier verschiedene Sequenzen (zwei verschiedene Deformationstypen, mit und ohne Randbedingungen, von je zwei verschiedenen Perspektiven) mit je 400 Zeitschritten erzeugt. Aus den Oberflächen-

⁴<https://www.3ds.com/de/produkte-und-services/simulia/produkte/abaqus/aktuelle-version/>

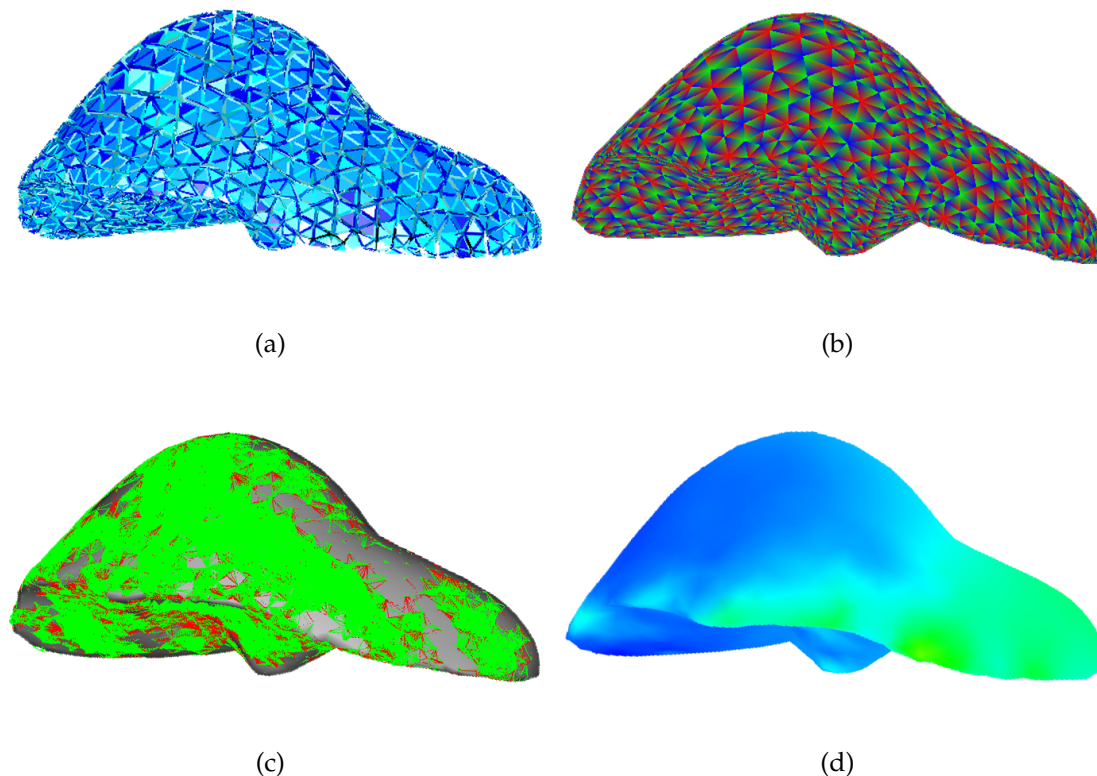



Abbildung 6.5: Diese vier Abbildungen illustrieren den auf das biomechanische Modell angewendeten Registrierungsprozess. (a) die Tetraederelemente des Volumenmodells, (b) die zur Lokalisierung der assoziierten Oberflächenpunkte gerenderten baryzentrischen Koordinaten, (c) die Federn, welche intraoperative Datenpunkte mit den biomechanischen Oberflächen-Eckpunkten verbunden werden (grün zeigt eine Kraft in Richtung der Oberflächennormale, rot eine Kraft entgegen der Normale an) und (d) der resultierende Registrierungsfehler (blau 0mm - grün 5mm)


modellen und einer organischen Textur wurden mithilfe des Rendering-Frameworks stereoendoskopische Aufnahmen der Deformationssequenz generiert.

Um den Einfluss der Modellparameter des Verfahrens zu ermitteln, wurden 200 verschiedene Parameterkombinationen getestet. Dabei wurde die Anzahl der Iterationsschritte, sowie die Federkonstante k berücksichtigt. Die Ergebnisse sind in Abbildung 6.6 dargestellt.

Die Methode zeigte sich relativ unempfindlich für Änderungen der Federkonstante und der Iterationszahl. Die Qualität der Resultate verbesserte sich jedoch generell mit einer höheren Iterationszahl. Die besten Ergebnisse konnten mit einer Federkonstante von 2000-3000 N/m und einer Iterationszahl von 64 erreicht werden.



(a)



(b)

Abbildung 6.6: (a) und (b) zeigen den Registrierungsfehler für zwei in silico Leberdeformations-Sequenzen. Es wurde die Root-mean-square (RMS) Fehlerverteilung zwischen den Eckpunkten des registrierten biomechanischen Modells und den Eckpunkten des Referenzvolumens bestimmt. Im Boxplot-Diagramm werden die Ergebnisse verschiedener Konfigurationen der Iterationsschritte und der Steifheit der Federn dargestellt.




Abbildung 6.7: Gerenderte Bilder des Lebermodells aus der in silico Simulation. Es werden zwei beispielhafte Deformationsschritte dargestellt. Das Lebermodell wurde auf der linken Seite durch Encastre Randbedingungen (E) fixiert. Die rechte Seite wurde durch eine angelegte Kraft (F) nach oben gezogen. Die maximale Verschiebung je Deformationssimulation ist ca. 4-5 cm.

6.2.2 In vivo Schweinemilz

Die intraoperativen Schweineaufnahmen wurden mit einem getrackten und kalibrierten Storz TIPCAM 1 SPIES 3D Stereoendoskop mit 30° Optik durchgeführt. Die Pose des Endoskops (Position und Ausrichtung) wurde nach jedem Zeitschritt durch das passive optische Trackingsystem von NDI (Polaris Specra) erfasst.




Abbildung 6.8: Beispiel einer dynamischen Registrierung der Schweinemilz. Das ursprüngliche Kamerabild ist auf der linken Seite abgebildet. Auf der rechten Seite ist das aktuelle biomechanische Modell mit dem aktuellen rekonstruierten Oberflächenfragment (gelb) überlagert worden. Das Instrument und das Organ wurden mit dem Segmentierungsprozess aus Abschnitt 6.1.1 getrennt.

Ein präoperatives Kontrast-CT diente zur Erstellung des präoperativen biomechanischen Modells. Da die Deformationen live im lebenden Schwein durchge-

führt wurden, ist es mit heutigen Mitteln sehr schwierig quantitative Referenzdaten zur Deformation zu bestimmen. Aus diesem Grund dient das in vivo Experiment zur qualitativen Evaluierung unter realen Operationsbedingungen.

In Abbildung 6.8 ist eine dynamische Manipulation an der Schweinemilz zu sehen. Die durch das chirurgische Instrument verursachten Deformationen werden deutlich sichtbar auf das biomechanische Oberflächenmodell übertragen. Es wurden 300 Endoskopframes für die initiale Registrierung und 200 während der dynamischen Registrierung verwendet. In Abbildung 6.9 ist die gleiche dynamische Manipulationsszene dargestellt, wobei hier das endoskopische Bild mit erweiterter Realität (ER) überlagert wird, um die Informationen des biomechanischen Modells besser vergleichbar zu machen.




Abbildung 6.9: Ähnlich wie in Abbildung 6.8 wird das Ergebnis einer dynamischen Registrierung dargestellt. Um das biomechanische Modell einfacher mit dem ursprünglichen Endoskopbild vergleichbar zu machen, wurde eine einfache erweiterte Realität Darstellung entworfen, welche das endoskopische Bild mit dem auf die Kameraebene projizierten biomechanischen Modell überlagert. Links: Endoskopbild und biomechanisches Oberflächennetz nach der initialen Registrierung. Rechts: Dynamische Deformation durch chirurgisches Instrument. Das Oberflächennetz folgt der im Bild zu sehenden Deformation.

6.3 Zusammenfassung

In diesem Kapitel wurde ein voll automatisches Verfahren zur biomechanischen Weichgeweberegistrierung für die laparoskopische Chirurgie vorgestellt. Die Methode nutzt intraoperative stereoendoskopische Bilddaten, um ein präoperatives biomechanisches Modell, erstellt aus CT-Daten, zu registrieren. Für die initiale Registrierung wird hierbei das in Kapitel 5 vorgestellte Mosaikverfahren verwendet. Nach der initialen Registrierung kann das biomechanische Modell auf neu aufgenommene Endoskopbilder projiziert werden. Durch die Assoziierung

mit der rekonstruierten Tiefenkarte können Verschiebungs-Randbedingungen erstellt werden, welche das biomechanische Modell an die morphologischen Änderungen des Organs anpasst. Durch simulierte Deformationsdaten konnte gezeigt werden, dass die Methode Registrierungs-genauigkeiten von 2-3 mm (für das gesamte Volumenmodell) ermöglicht. In einem ersten Einsatz mit realen in vivo Daten einer Schweinemilz konnte zudem gezeigt werden, dass der biomechanische Tiefenabgleich auch unter realen Operationsbedingungen eingesetzt werden kann.

Während den Experimenten wurde deutlich, dass die Qualität der Stereorekonstruktion einen wichtigen Einfluss auf das Verfahren hat. Zwar ist der Algorithmus relativ robust gegen gleichförmiges Rauschen, größere Fehler in der HRM Rekonstruktion, vor allem wenn diese für mehrere Zeitschritte andauern, können jedoch zu starken Abweichungen der geschätzten Deformation führen, die nicht ohne weiteres ausgeglichen werden können.

Außer der Rekonstruktion ist die Segmentierung des Organs ebenfalls von Bedeutung. So müssen beispielsweise chirurgische Instrumente, welche das Organ überlagern, zuverlässig erkannt werden, um falsch zugeordnete Federelemente zwischen dem biomechanischen Modell und den Instrumenten zu verhindern.

Da während der dynamischen Deformationen nur kleine Ausschnitte des Organs sichtbar sind, ist eine genaue initiale Registrierung eine Grundvoraussetzung für eine anschließend erfolgreiche dynamische Registrierung. Generell verbessert eine größere Abdeckung der Organoberfläche während der dynamischen Registrierung aber auch hier die Ergebnisse. Es ist schwierig eine minimale Oberflächenabdeckung für eine erfolgreiche Registrierung anzugeben, da dies stark von den sichtbaren Bereichen des Organs abhängt. Deformationen die nicht im Sichtfeld des Stereoendoskops liegen, können selbstverständlich nicht auf das biomechanische Modell übertragen werden.

Die Laufzeit der initialen Registrierung liegt je nach Grad der Deformation zwischen 1-2 Sekunden und wird durch die Berechnungen des Physics Based Shape Matching (PBSM) Verfahrens dominiert. Die Laufzeit der dynamischen Registrierung liegt pro Frame durchschnittlich bei 100 Millisekunden. Hier wird der größte Teil der Zeit für die Stereorekonstruktion (HRM) benötigt (60 *ms*). Dies zeigt wie bedeutend die Entwicklung neuer schnellerer Stereorekonstruktionsverfahren für Verfahren mit Echtzeitbedingungen ist.

Außer der Methode selbst ist es auch wichtig wie diese in die klinischen Arbeitsabläufe integriert werden kann. Die Entfernung eines Leberkarzinoms könnte hierfür als ein gutes Beispiel dienen. Vor der Tumorentfernung, wird eine initiale Registrierung der Leber durchgeführt und danach die dynamische Registrierung gestartet. Danach kann der Chirurg den Tumor mithilfe von erweiterter Realität im Endoskopbild betrachten. So kann der beste Zugang geplant werden, während die Lage des Tumors mit jeder Deformation aktualisiert wird.

Kapitel 7

3D-Druck für realistische Silikon-Organe

Die Evaluation und Erprobung von computergestützten Assistenzsystemen ist ein zentraler Teil in der Entwicklung dieser Systeme und Algorithmen. Dabei gliedert sich die experimentelle Evaluation meist in mehrere Abschnitte. Der erste Schritt ist die *in silico* Evaluation, bei der in einer rein virtuellen Umgebung das Verhalten des Systems getestet wird. *In silico* Versuche sind besonders während der Entwicklung des Systems wertvoll, da verschiedene Ideen und Parametereinstellungen ohne großen Aufwand am Modell getestet werden können.

Da heutige Computermodelle nur einen kleinen Teil der Realität abbilden können, ist der Schritt in eine reale Versuchsumgebung im Laufe des Entwicklungsprozesses jedoch unabdingbar. Der Goldstandard wäre hier der *in vivo* Versuch am Menschen. Dies lässt sich bei den meisten Systemen aus ethischen und legalen Gründen verständlicherweise nicht umsetzen. Deshalb werden chirurgische Systeme im letzten Schritt oft mit Tierversuchen evaluiert. Da aber auch die Nutzung von lebenden Tieren und auch entnommenen Tierorganen aus ethischen Gründen so gering wie möglich gehalten werden soll, kommt künstlichen Organmodellen eine wichtige Bedeutung zu. Diese haben zudem den Vorteil, dass Experimente mit den gleichen Versuchsparametern beliebig oft wiederholt werden können und somit belastbare Vergleiche zwischen den verschiedenen Versionen und Einstellungen der Systeme bieten.

Das Ziel dieser Arbeit ist es, ein günstig produzierbares Organmodell mit möglichst realistischen physikalischen Eigenschaften zu entwickeln. Dies soll am Beispiel eines Leberphantoms gezeigt werden. Die folgenden Anforderungen sollen erfüllt werden:

- Bestimmung der physikalischen Eigenschaften der Leber: Volumen, Dichte, Masse und E-Modul
- Herstellung von Leberphantomen mit den zuvor bestimmten mechanischen Eigenschaften
- Die Herstellung der Phantomorgane soll preiswert sein und möglichst unter 200 € realisierbar sein

Diese Arbeit wurde zusammen mit Markus Gern (Gern, 2016) in der Nachwuchsgruppe Computer-Assisted Surgery des Humanoids and Intelligence Systems Lab entwickelt.

7.1 Physikalische Eigenschaften der Leber

Elastizitätsmodul

In der von McKee *et al.* (2011) veröffentlichten Metastudie wurden verschiedenen Ergebnisse zur Messung des Elastizitätsmoduls (E-Modul) von Weichgewebe gesammelt. Das Elastizitätsmodul ist der Proportionalitätsfaktor des Quotienten aus Spannung und Dehnung. Im Spannungs-Dehnungs-Diagramm entspricht der E-Modul einer Tangente (siehe Abbildung 7.1). Der E-Modul kann bildlich mit „Je steifer ein Material, desto höher ist sein E-Modul“ beschrieben werden. Dabei ist der E-Modul nur im linear-elastischen Anfangsbereich der Kurve konstant (Holzmann *et al.*, 2012, S. 18f). Eine ausführlicher Beschreibung der mechanischen Grundlagen kann in der Thesis von Gern (2016) gefunden werden.




Abbildung 7.1: Beispielabbildung einer Spannungs-Dehnungskurve. Der E-Modul wird durch die Steigung repräsentiert (Holzmann *et al.*, 2012, S. 26)

In der Metastudie konnte eine Differenz der Ergebnisse für Zug- und Druckversuche festgestellt werden. Während bei den Zugversuchen ein durchschnittliches E-Modul von 10 MPa gemessen wurde, zeigten die Messungen bei Druckversuchen ein durchschnittliches E-Modul von nur 190 kPa. Es wurden zwei Hypothesen für die unterschiedlichen Messwerte angeführt:

Zugverformung global, Druckverformung lokal Bei einer Zugverformung wird das Gewebe global belastet, bei einer Druckverformung hingegen nur lokal. Bei einer lokalen Belastung kann das in der Leber eingeschlossene inkompressible Wasser (Blut) in umliegende, nicht belastete Bereiche ausweichen. Bei einer globalen Belastung ist dies nicht möglich.

Gewebefasern Muskelfasern oder auch Kollagenfasern sind bei Zugverformungen deutlich belastbarer als bei Druckverformungen.

Die Autoren der Metastudie kamen abschließend zu dem Ergebnis, dass für mikroskopische Eigenschaften die Kompressionstests und für makroskopische Eigenschaften die Zugtests als Referenz herangezogen werden sollten. Weitere Studien, die aufgrund von Ergebnissen bis in den nicht-elastischen Bereich nicht in der Metastudie vertreten waren, ermittelten E-Module im Bereich von 640 Pa - 2 kPa (Yeh *et al.*, 2002) und 270 kPa (Carter *et al.*, 2001).

Volumen

Einfacher als der E-Modul lässt sich das durchschnittliche Volumen einer Leber bestimmen. In der Studie von Kan & Hopkins (1979) wurden 22 gesunde Probanden mithilfe eines Einzelphotonenemissionscomputertomografen untersucht, um das Lebervolumen *in vivo* zu messen. Das durchschnittliche Volumen der 22 Lebern wurde mit 1500 ml angegeben. In einer zweiten Studie von Sahin *et al.* (2003) wurde überprüft, ob das Volumen *in vivo* mithilfe eines Magnetresonanztomografens korrekt bestimmt werden kann. Dazu wurde an fünf posthum entfernten Lebern das Volumen durch Wasserverdrängungstests gemessen. Das durchschnittliche Volumen betrug hierbei 1060 ml.

Gewicht

Mit insgesamt 232 Proben von Männer- und Frauenlebern aus den Studien von Molina & DiMaio (2011a) und Molina & DiMaio (2011b), existiert eine recht verlässliche Datenbasis zur Bestimmung des durchschnittlichen Gewichts einer gesunden Leber. Bei den Frauenlebern lag das durchschnittliche Gewicht bei 1288 g und bei Männerlebern bei 1561 g.

Kennwert	Intervall	Quelle
E-Modul	640 Pa – 10 MPa	(Yeh <i>et al.</i> , 2002), (McKee <i>et al.</i> , 2011)
Volumen	1060 ml – 1500 ml	(Sahin <i>et al.</i> , 2003), (Kan & Hopkins, 1979)
Gewicht	1288 g – 1561 g	(Molina & DiMaio, 2011a), (Molina & DiMaio, 2011b)

Tabelle 7.1: Physikalischer Werkstoffeigenschaften menschlicher Lebern aus der Literatur (Gern, 2016)

In Tabelle 7.1 sind die vorhergehenden Kennzahlen noch einmal zusammenfassend abgebildet. Während es bei Volumen und Gewicht nur eine vertretbare Streuung der Messwerte gibt, unterscheiden sich der Höchst- und Tiefstwerte des E-Moduls um einen Faktor von über 100000.

7.2 Zielwerte des Leberphantoms

Um den großen Bereich der E-Modul Werte sinnvoll einzugrenzen, wurden weitere Studien ausgewertet. In der Studie von Kemper *et al.* (2010) wurden Zugversuche an der menschlichen Leber durchgeführt, um die biomechanischen Eigenschaften zu erforschen. Die Messungen aus vier Experimentgruppen ergaben die E-Module 0,12 MPa, 0,17 MPa, 0,17 MPa und 0,27 MPa, welche durch die Graphen aus (Kemper *et al.*, 2010) bestimmt wurden. Durch die hohe Anzahl frischer menschlicher Leberproben und der geringen Abweichung der verschiedenen Versuchsproben, wurde der Durchschnittswert von 0,18 MPa als Zug-E-Modul für das Leberphantom gewählt.

Da für den Druck-E-Modul in den vorhandenen Studien mit 0,27 MPa, 0,19 MPa und 0,00064 MPa (Carter *et al.*, 2001, Yeh *et al.*, 2002, McKee *et al.*, 2011) keine sinnvolle Durchschnittsbildung möglich war, wurde auf einen festen Soll-Wert verzichtet und nur ein Rahmen von 0,64 kPa bis 270 kPa festgelegt. Die Zielwerte können in Tabelle 7.2 gesammelt betrachtet werden.

Kennwert	Intervall	Referenz
E-Modul	640 Pa – 10 MPa	Zug: 180 kPa, Druck: 0.64 kPa – 270 kPa
Volumen	1060 ml – 1500 ml	1280 ml
Gewicht	1288 g – 1561 g	1424.5 g
Dichte	-	1.11 g cm ⁻³

Tabelle 7.2: Tabelle 7.1, erweitert um die Zielwerte für das geplante Leberphantom. Für das Druck-E-Modul konnte aufgrund der schlechten Datenlage nur ein plausibler Wertebereich angegeben werden.

7.3 Wahl eines geeigneten Materials

Um die in Abschnitt 7.2 bestimmten mechanischen Zielwerte für ein Organphantom umzusetzen, wurden in Tabelle 7.3 verschiedene Materialien auf ihre Tauglichkeit hin untersucht. Die meisten Hersteller geben in ihren Datenblättern die Härte der Stoffe in der Shore-Skala an (Weißbach *et al.*, 2015). Die Shore-Skala gibt an, wie weit ein zylindrischer Stab, mit einem Kegelstumpf als Spitze, in die Probe eindringt. Dringt der Stab um mehr als 2,5 mm ein, entspricht dies einer Härte

von 0 ShA. Dringt der Stab gar nicht ein, entspricht dies einem Wert von 100 ShA. Materialien, die eine Härte unter 0 ShA besitzen, werden in der Shore-00-Skala gemessen.

Werkstoff	Shore-Härte	Eigenschaften
additionsvernetzende Silikone (RTV)	00-10 – 90 ShA	- günstig - genaue Abformung - einfache Handhabung - sehr breites Spektrum an Härten
kondensationsvernetzende Silikone	10 – 60 ShA	- ähnlich zu RTV - Elastizität ist etwas begrenzter - leichtes Schrumpfen
TangoPlus (3d-druckbares, weiches Filament)	26 – 77 ShA	- teuer - Bruchdehnung geringer als RTV - beliebige Formen/Strukturen druckbar
Porolay/Lay-Fomm 40 (mikroporöses 3D-Druck-Filament)	40 ShA	- braucht bis zu 4 Tage um maximal weich zu werden - beliebige Formen/Strukturen druckbar
Selektives Laser Sintering (flex)	20– 80 ShA	- recht hart - mittlerer Preis - beliebige Formen/Strukturen druckbar
Polyurethan-Weichschaum	40 – 70 ShA	- sehr weich - starke bis extreme Ausdehnung - sehr niedrige Dichte
Polyurethan-Harze	18 – 47 ShA	- chemisch beständig - recht hart - gut passende Dichte

Tabelle 7.3: Eine Aufstellung verschiedener Materialien und Herstellungsverfahren (Gern, 2016). Die Shore-Skala gibt an, wie weit ein zylindrischer Stab, mit einem Kegelstumpf als Spitze, in die Probe eindringt. Dringt der Stab um mehr als 2,5 mm ein, entspricht dies einer Härte von 0 ShA. Dringt der Stab gar nicht ein, entspricht dies einem Wert von 100 ShA. Der Wert 00-10 ist nach der Shore-00-Skala gemessen.

Die Möglichkeit mit TangoPlus, Porolay oder Flex Laser Sintering (Tabelle 7.3) Organmodelle direkt 3D zu drucken, musste leider auf Grund der sehr Hohen Material- und Maschinenkosten verworfen werden. Auch die hohe Abweichung der gegebenen Härte zu den Zieldaten macht die Nutzung dieser Verfahren schwierig. Beim Vergleich der möglichen Materialien wurden in dieser Arbeit additionsvernetzende Silikone (RTV) als Basis für ein Organmodell gewählt. Dies hat folgende Gründe:

- Günstige Beschaffung und Verarbeitung des Materials möglich

- Einfache Handhabung und bereits Erfahrungen mit RTV am Lehrstuhl vorhanden
- Breites Spektrum an Härtegraden, bietet das weichste Material im Vergleich
- Dichte ist nahe an den Zielwerten für Weichgewebe/Leber

Um eine Wahl für ein Silikon zu treffen, wurden verschiedene Materialproben bei einem Materialhändler (Kaupo¹) bezogen. Die gelieferten Materialien Ecoflex[®] 00-30, Ecoflex[®] 00-50, Ecoflex[®] 5, Dragon Skin[®] 10, Dragon Skin[®] 20, Dragon Skin[®] 30, Dragon Skin[®] FX-Pro, Sorta-Clear[®] 18, Rebound[®] 40, Body double[®] und Soma Foama[®] 15 stammen dabei alle vom amerikanischen Hersteller Smooth-On².

Ein haptischer Vergleich der Materialien durch einen Experten offenbarte, dass viele der Silikonvarianten für Weichgewebemodelle deutlich zu hart sind. Selbst die weichste Probe Ecoflex[®] 00-30 wurde als zu hart eingestuft. Somit lag es nahe mit diesem weichsten Material zu arbeiten. Dies wird durch die Erfahrungen des OpenHELP Phantoms gestützt, bei dem ebenfalls Ecoflex[®] 00-30 mit der Zugabe von additiven Weichmachern genutzt wurde (Kenngott *et al.*, 2015).

7.4 Wasserlösliche Gussformen

Anders als bei 3D-Druckmaterialien wie TangoPlus oder Porolay, kann Silikon nicht von sich aus in eine vorgegebene Form gebracht werden. Nach dem Anrühren des A und B Bestandteils kann das Silikon während der Topfzeit (bei Ecoflex[®] 00-30 ca. 45 Minuten) in Negativformen oder andere Gegenstände gefüllt werden (siehe Datenblatt A.2 für mehr Informationen zu Ecoflex[®] Silikon). Für die Herstellung von Negativ-Gussformen für Organe, werden meist Organmodelle aus CT-Scans extrahiert und ein Negativ dieser Modelle mithilfe eines 3D-Druckers gefertigt. In diese kann dann das noch flüssige Silikon zum Aushärten gefüllt werden.

Das Ziel dieser Arbeit ist die Herstellung eines Organmodells mit möglichst realistischen mechanischen Eigenschaften. Da das zur Verfügung stehende Silikon nun aber härter als die zuvor bestimmten Zielwerte für Weichgewebe ist, müssen neue Wege in der Herstellung des Modells gefunden werden. Für die im Folgenden vorgestellte neue Herstellungsmethode, lag diese Idee zugrunde:

„Wenn die Eigenschaften des Materials nicht geändert werden können, beeinflussen wir eben das Verhalten des Modells durch seine makroskopische Struktur“

¹<https://www.kaupo.de/>

²<https://www.smooth-on.com/>

Durch diese Überlegung inspiriert wurde nach Möglichkeiten geforscht, die Struktur des Organmodells durch Hohlräume zu schwächen. Dabei stellt sich die Frage wie Elemente der Gussform, welche nach dem Guss innerhalb des Organs liegen, später wieder entfernt werden können. Die Lösung für dieses Problem fand sich in einem gänzlich anderen Zusammenhang im FDM 3D-Druck. Um starke Überhänge oder in der Luft beginnende Modellteile erfolgreich zu drucken, werden sogenannte Stützstrukturen (support material) verwendet. Da die anschließende Trennung von Stützmaterial und eigentlichem Modell ein mitunter aufwendiger Prozess sein kann, wurden wasserlösliche Stützmaterialien aus Polyvinylalkohol (PVA) entwickelt. Nach dem Druck kann das Werkstück nun einfach in warmes Wasser gelegt werden, bis die PVA-Stützstrukturen sich von selbst aufgelöst haben.




Abbildung 7.2: (1) Vollvolumen-Testkörper, (2) innere Gitter-Struktur, (3) entstehendes Silikonmodell und (4) Gussform der 3D-Struktur

Statt als Stützstruktur wird das PVA Material nun als Hauptmaterial zum Druck verwendet. Wie in Abbildung 7.2 gezeigt, wurden Funktionsmuster in der Form einer Filmdose (Zylinder mit Höhe: 50 mm und Durchmesser: 30 mm) entworfen, bei denen die Gussform durch eine innen liegende Gitterstruktur ergänzt wurde. Nach dem Auflösen der PVA-Form bleibt in Abbildung 7.2 (3) ein mit balkenförmigen Hohlräumen durchzogenes Silikonmodell zurück. Um die Formen zuverlässiger drucken zu können, wurde das Gitter vertikal und horizontal ausgerichtet. Entgegen theoretischer Überlegungen, ließen sich horizontale Stege mit Brücken über den vertikalen Stützen besser drucken als ein gedrehtes Gitter mit konstanten Überhängen von 45 Grad.

Am Modell des durch die Gitter-Gussform entstandenen Körpers, wurden in PTC Creo³ Simulationen zur Bestimmung des E-Moduls angestellt (siehe Abbildung 7.3). Um das E-Modul zu bestimmen, wurde eine Kraft von 2 N an das obere Ende des Probenzylinders angesetzt. Die durch die Kraft angestoßene Simulation ergibt eine Verschiebung Δl der oberen Fläche des Modells. Die negative Dehnung ε (Stauchung) des Modells kann mit der Gesamtlänge l des Modells mit $\varepsilon = \Delta l/l$ berechnet werden. Aus der Größe der Oberfläche und der angelegten Kraft erfolgt die mittlere Spannung $\sigma = F/A$. Mit dem hookschen Gesetz

³<http://www.ptc-de.com/cad/creo>

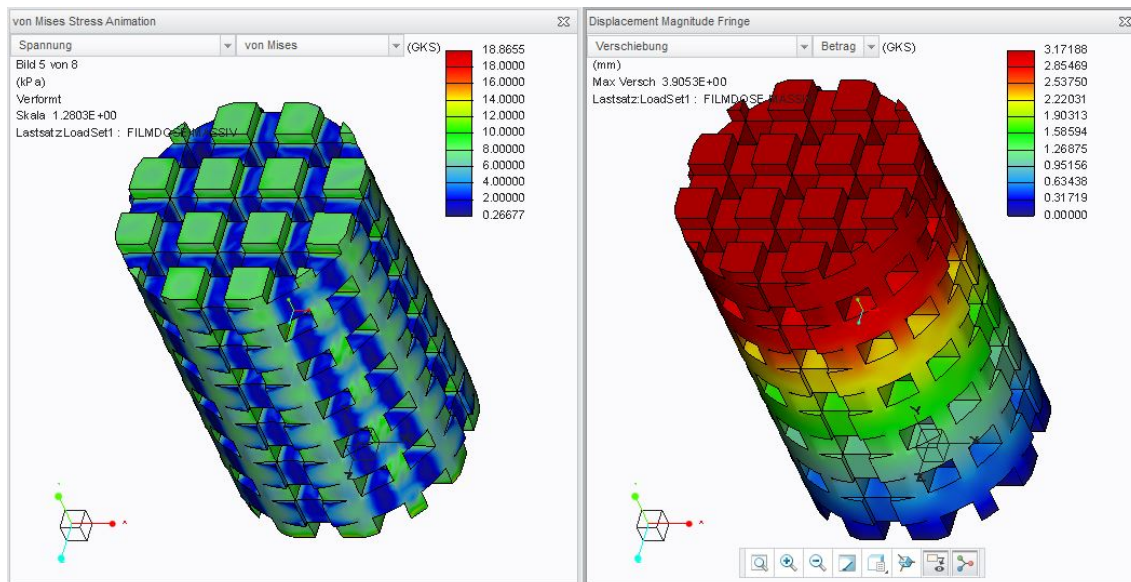


Abbildung 7.3: Ergebnisse einer Belastungssimulation in PTC Creo. Das E-Modul verringert sich wie angenommen proportional zu der Stegdicke der Gitterstruktur.

für linear-elastische Verformung und dem einachsigen Verformungszustand folgt das E-Modul des Körpers mit $E = \sigma/\varepsilon$.




Abbildung 7.4: Simulationsergebnisse mit dem relativen E-Modul über der Stegdicke der Gitterstruktur aufgetragen (Gern, 2016).

Das E-Modul wurde auf diese Weise zunächst für einen Vollkörper bestimmt und mit dem vom Hersteller gegebenen E-Modul von 60 kPa (Ecoflex[®] 00-30) verglichen. Mit einer Verformung von 2,29 mm und dem damit berechneten E-Modul

von 61,9 kPa, konnte der reale Wert durch die Simulation bis auf ca. 3% Abweichung bestimmt werden.

Wie in Abbildung 7.4 aufgetragen, wurden Simulationen für Stegdicken von 1,0 mm, 1,5 mm, 2,0 mm, 2,5 mm und 3,0 mm durchgeführt. Die Abstände der einzelnen Gitterelemente betragen dabei immer 8 mm, sodass sich das Verhältnis von Silikon und Hohlraum je nach Stegdicke ändert.

7.5 Ergebnisse

Um die Simulationsdaten zu überprüfen, wurden mehrere Testkörper mit unterschiedlichen Stegdicken hergestellt. Das Verfahren wurde anschließend verwendet, um die Eignung für die Erzeugung eines menschlichen Lebermodells zu evaluieren.

7.5.1 Zylindrische Testkörper

Für die Herstellung der Testkörper wurden folgende Schritte durchgeführt:

3D-Druck der Gussform

Für den 3D-Druck wurde der X400 PRO von German RepRap verwendet (siehe Abbildung A.4). Das Hot-End des Druckers wurde durch das hochwertigere E3D-v6 System der Firma e3D ersetzt. Ein zusätzlicher Lüfter für das Werkstück wurde ebenfalls ergänzt. Die Drucktemperatur wurde dem Datenblatt des verwendeten PVA-Materials entnommen (siehe Abbildung A.3). Der Durchmesser des Filaments betrug 2,85 mm. Die Düse des 3D-Druckers hatte einen Durchmesser von 0,4 mm. Für den Druck der 50 mm x 30 mm großen Testkörper wurde bei moderaten Druckgeschwindigkeiten ca. drei Stunden benötigt (siehe Abbildung 7.5). Wie zuvor erwähnt, waren die Ergebnisse der waagrecht ausgerichteten Gitter deutlich genauer als die der um 45 Grad gedrehten.

Guss des Silikons

Das Einfüllen des flüssigen Silikons stellte bei allen Proben kein Problem dar. Durch ein vorheriges Vakuumieren der Silikonmasse können Luftblasen im späteren Guss vermieden werden. Da diese bei den Versuchen jedoch keine Probleme verursachten, wurde auf diesen zusätzlichen Arbeitsschritt verzichtet. Nach 45 Minuten beginnt Ecoflex[®] 00-30 auszuhärten (Topfzeit).



Abbildung 7.5: Erster erfolgreicher Druck eines PVA Funktionsmusters.

Auswaschen der Gussform

Nach dem Aushärten des Silikons, wurden die Proben jeweils in heißes Wasser gegeben. Um die Oberflächenspannung des Wassers zu brechen, wurde eine kleine Menge Spülmittel hinzugegeben. Die Gussform inklusive der Gitterstruktur konnte nach ca. 16 Stunden fast vollständig aufgelöst werden (siehe Abbildung 7.6). Die Unterschiede in der Stegdicke spielten hierbei keine Rolle. Die Effekte durch die kleinere Angriffsfläche wurden dabei scheinbar durch die Reduzierung des aufzulösenden Materials ausgeglichen.




Abbildung 7.6: (1) Referenzkörper, (2) schräge Struktur mit 3 mm Stegdicke, (3) senkrechte Struktur mit 1,5 mm Stegdicke und (4) senkrechte Struktur mit 3 mm Stegdicke

Geometrische Eigenschaften der Proben

Die Proben wurden zunächst auf ihre Abmessungen und Dichte hin geprüft. Um das vorgegebene Silikon/Luft Verhältnis zu erfüllen, müssen Stegdicke und die Abstände zwischen den Stegen (hier Zellen genannt) korrekt umgesetzt werden. In Tabelle 7.4 sind alle Messdaten hierzu gesammelt. Die Zellen haben bei allen Proben, die massive Probe ausgenommen, eine Größe von 8 mm. Während die Dichte sehr genau den Vorgaben entspricht, gibt es Abweichungen in der Stegdicke. Durch die Umwandlung der Geometrie in Maschinencode (G-Code) mit der „Slicer“ genannten Software und Ungenauigkeiten im Materialfluss, wurden die Stege in allen Fällen zu dick gedruckt. Hier sind durch Anpassung der Fertigungsbedingungen deutliche Steigerungen der Abbildungsgenauigkeit zu erwarten.

Probe	Stege/Zellen	Volumen	Gewicht	Dichte ist (soll)
Massiv	-/-	30.39 cm ³	31.5 g	1,04 (1,06) g cm ⁻³
schräg, 3 mm	≈ 3.5 mm / 8 mm	31.04 cm ³	22.8 g	0,73 (0,74) g cm ⁻³
senkrecht, 1.5 mm	≈ 2 mm / 8 mm	29.72 cm ³	28.7 g	0,97 (0,97) g cm ⁻³
senkrecht, 3 mm	≈ 3.75 mm / 8 mm	31.07 cm ³	23.0 g	0,74 (0,74) g cm ⁻³

Tabelle 7.4: Ergebnisse der Probenvermessungen (Gern, 2016)

Mechanische Eigenschaften der Proben

Um die Härte der Proben zu messen, wurde in Kooperation mit Prof. (apl.) Dr.-Ing. Kay Weidenmann vom Institut für Angewandte Materialien-Werkstoffkunde (IAM-WK) Messungen durchgeführt. Dabei wurde eine Zwick-Universalprüfmaschine genutzt, um die Drucksteifigkeit der Proben zu bestimmen. Zur Vereinfachung kann angenommen werden, dass die Drucksteifigkeit dem Elastizitätsmodul entspricht. Eine ausführliche Darstellung der Spannungs-Stauchungs-Diagramme ist im Anhang A.2 zu finden.

Aus den Spannungs-Stauchungs-Werten wurde die Elastizität der Proben abgeleitet. In Abbildung 7.8 wurden die Messungen mit den Simulationsergebnissen verglichen. Hierbei wurde die Simulation zuvor an die tatsächlichen Maße (Stegdicken) der Proben angepasst. Außerdem wurde bei den Messungen am Vollkörper festgestellt, dass der vom Hersteller angegebene E-Modul nicht mit den ermittelten Daten übereinstimmt. Statt 60 kPa wurden die gemessenen 89,6 kPa für die Simulation verwendet.

Der von 0 mm bis 3 mm Stegdicke gemittelte Fehler der Simulationswerte mit der Regression der Messwerte betrug 5,67%. Berücksichtigt man den zuvor beschriebenen systematischen Simulationsfehler von 3 % und die Ungenauigkeiten der Probenvermessung, verspricht die Simulation eine genaue mechanische Beschreibung der realen Proben.




Abbildung 7.7: Messaufbau der Zwick-Universalprüfmaschine




Abbildung 7.8: Vergleich der linearen Regression der realen Proben (unten) mit der angepassten Simulation (oben)

7.5.2 Lebersilikonmodell

Um zu bestätigen, dass dieses Verfahren auch für größere Organmodelle anwendbar ist, wurde ein großer Teil einer menschlichen Leber hergestellt. Hierzu wurde das CT-Lebermodell des OpenHELP Projekts (Kenngott *et al.*, 2015) genutzt. Wie bei den Modellproben wurde auch hier eine Gitterstruktur in die Negativ-Form des Organs eingefügt (Abbildung 7.9). Da sich die Experten für die weichste Probe ausgesprochen haben und diese sich auch im Zielbereich des ermittelten Weichgewebe-E-Moduls befindet, wurde für das Organmodell ebenfalls eine Stegdicke von 3 mm gewählt.




Abbildung 7.9: Da es während des Drucks aufgrund einer fehlerhaften Düse zu mehreren Abbrüchen kam, wurden drei Teilstücke später zusammengefügt. Da PVA auch als Klebstoff verwendet wird, konnten die Teile mithilfe eines Wasserfilms verbunden werden.

Um Material zu sparen, wurden die Stege im Innern hohl gedruckt. Wie in Abbildung 7.10 (4) sichtbar ist, waren diese Hohlräume nicht gänzlich dicht und konnten vom Silikon aufgefüllt werden. Auch wenn dies die mechanischen Eigenschaften nicht bedeutend verändern dürfte, sollte dieser Parameter für weitere Versuche angepasst werden.




Abbildung 7.10: Verschiedene Ansichten der hergestellten Leber, rechts unten mit Detailaufnahme der Unterseite unter starker Deformation

7.6 Zusammenfassung

In diesem Kapitel wurde ein neuartiges Verfahren zur Herstellung von Silikonorganen vorgestellt. Hierbei wurde der Fokus auf ein möglichst realistisches mechanisches Verhalten der Silikonmodelle gelegt, um neue Entwicklungen in der Computer-assistierten Chirurgie sinnvoll evaluieren zu können. Für eine realistische Modellierung der mechanischen Eigenschaften, wurde zunächst eine Recherche über Studien von Weichgewebeeigenschaften durchgeführt. So konnten realistische Wertebereiche für das Volumen, das Gewicht und das E-Modul ermittelt werden. Da beim Druck-E-Modul zu große Unterschiede bei den verschiedenen Messstudien festgestellt wurden, erschien es sinnvoller das haptische Empfinden von Experten als Bewertungskriterium heranzuziehen.

Durch die Verwendung von wasserlöslichem PVA Druckmaterial, konnten Gussformen mit integrierter Gitterstruktur produziert werden. Die nach dem Auflösen der Gussform entstehenden Hohlräume im Silikonphantom erlauben es, die Härte des Modells zu reduzieren. So konnten die mechanischen Limitierungen der verfügbaren Silikone überwunden werden. Mithilfe von Messproben und einer Universalprüfmaschine konnte gezeigt werden, dass die zuvor in einer

CAD-Software simulierten mechanischen Eigenschaften mit den daraus erzeugten Funktionsmustern übereinstimmen.

Mit der hier vorgestellten Fertigungsmethode können individuell angepasste Organ-Silikongussformen erzeugt werden. Dazu werden nur ein 3D-Drucker und die verwendeten Verbrauchsmaterialien benötigt, was eine sehr günstige Herstellung von unter 200 € erlaubt. So erhalten auch kleine Forschungsgruppen die Möglichkeit spezielle mechanisch angepasste Organmodelle herzustellen.

Kapitel 8

Schlussbetrachtung

In der vorliegenden Arbeit wurden Verfahren und Algorithmen für die laparoskopische Weichgeweberegistrierung untersucht. In diesem Kapitel werden die wesentlichen Beiträge zusammengefasst und die erzielten Ergebnisse diskutiert. Anschließend wird ein Ausblick auf mögliche Erweiterungen und zukünftige Entwicklungen gegeben.

8.1 Zusammenfassung und Diskussion

Das Ziel der vorliegenden Arbeit war die Erforschung und Entwicklung einer automatischen Registrierung von prä- und intraoperativen Weichgewebestrukturen in der Laparoskopie. Während präoperativen Planungsdaten heutzutage in beeindruckender Qualität durch dreidimensionale Schichtscans von Computertomografen und Magnetresonanztomografen zur Verfügung stehen, ist die intraoperative Nutzung dieser Daten durch die fehlende Weichgeweberegistrierung sehr begrenzt. Ohne aufwendige und teure CT-Geräte, welche nur in wenigen Operationsräumen zu finden sind, steht während des eigentlichen chirurgischen Eingriffs vor allem das Endoskop bzw. Laparoskop als Bildquelle zur Verfügung.

Neue technische Entwicklungen haben allerdings auch hier nicht halt gemacht. So können Chirurgen heute auf moderne HD-Endoskope mit stereoskopischen Aufnahmemodulen zurückgreifen. Diese Stereoaufnahmen des Bauchraums ermöglichen die dreidimensionale Rekonstruktion von intraoperativen Organmodellen und stellen damit eines der wichtigsten Teile eines Weichgewebe-Rekonstruktionsverfahrens dar. Nach einer umfassenden Literaturrecherche über aktuelle Forschungsansätze wurden beginnend von der endoskopischen Stereorekonstruktion, über ein Mosaikverfahren zur Erzeugung großflächiger intraoperativer Organmodelle und Verfahren zur initialen und dynamischen Registrierung, viele Problemstellungen dieses Themengebiets untersucht und bearbeitet. Die entwickelten Methoden wurden mit geeigneten Evaluationsverfahren auf ihre Robustheit und Genauigkeit überprüft. Zusammenfassend wurden die folgenden Aspekte näher untersucht:

Stereorekonstruktion Es wurde ein auf *Convolutional* Neuronalen Netzen basiertes Stereorekonstruktionsverfahren entwickelt, welches Disparitäten endoskopischer Bilddaten durch das Training mit domänenspezifischen Trainingsdaten bestimmt. Da für endoskopische Bilddaten keine Referenz für die Tiefendaten bestimmt werden kann, wurde ein mehrstufiger Trainingsprozess entwickelt. Um die Anzahl der benötigten endoskopischen Trainingsdaten zu reduzieren, wurde das Netzwerk zunächst mit allgemeinen Bilddaten aus dem Bereich des maschinellen Sehens trainiert.

Durch dieses Vortraining erlernt das Netz die Grundzüge der Disparitätsschätzung und kann später schneller für ähnliche Aufgaben trainiert werden. Aufgrund der speziellen Endoskop-Optik und den Eigenheiten dieser Bildgebung, bspw. Glanzlichter und texturarme, kantenfreie Oberflächen, sind endoskopische Trainingsdaten jedoch unverzichtbar für bestmögliche Resultate. Hierzu wurden einerseits virtuelle Stereobilder von endoskopischen Simulationen erzeugt, andererseits wurden vorhandene reale Aufnahmen genutzt, um mit der Erkennung von Landmarken, vollautomatisch dünnbesetzte Referenzkarten zu erzeugen. Das Verfahren wurde mit einem öffentlichen Datensatz evaluiert und konnte eine hohe Genauigkeit bei geringer Laufzeit demonstrieren.

Initiale Weichgeweberegistrierung Auf Basis der mit dem Stereoendoskop rekonstruierten Oberflächenfragmente, wurde ein Verfahren zur Erstellung eines globalen Oberflächenmodells entworfen. Dabei werden die Oberflächenfragmente der einzelnen Bilder online nach und nach in ein globales Voxelvolumen integriert. Durch überlappende Oberflächenbereiche, konnten so auch Rauschartefakte und Rekonstruktionsfehler aus den einzelnen Bildern, im globalen Modell reduziert werden. Ein großflächiges intraoperatives Oberflächenmodell ist essentiell für eine initiale Registrierung mit dem präoperativen Modell. Nur so kann robust und eindeutig eine Transformation zwischen den Modellen gefunden werden.

Um das präoperative Modell auch trotz Deformationen des intraoperativen Organs registrieren zu können (nicht-rigide), wurde in Zusammenarbeit mit Suwelack *et al.* (2014) die Registrierung mit einem auf biomechanischen Simulationen basierten Verfahren durchgeführt. In den Evaluationsversuchen konnte gezeigt werden, dass sich der Registrierungsfehler durch die großflächigen Mosaikmodelle gravierend verbessern lässt. Auch wiesen die globalen Modelle einen geringeren Rekonstruktionsfehler als die zugrunde liegenden Rekonstruktionsfragmente auf.

Dynamische Weichgeweberegistrierung Anders als bei der initialen Registrierung können statisch erstellte globale Modelle hier nicht verwendet werden. Die dynamischen Deformationen der Organe müssen nach jeder Aufnahme auf das präoperative Modell übertragen werden, um dieses stets aktuell zu halten. Nach der initialen Registrierung besteht die dynamische Registrierung aus einem sich immer wiederholenden Prozess, bei dem ein biomechanisches Modell der präoperativen Daten an die intraoperative Geometrie angepasst wird. Um die Änderungen auf das biomechanische Modell

zu übertragen, wird dieses in jedem Zeitschritt auf die Bildebene des Endoskops projiziert. Zwischen den so erstellten Assoziationen von Bildpunkten und biomechanischen Knotenpunkten, werden anschließend mechanische Federn gespannt. Diese dienen als Randbedingungen der biomechanischen Modellierung und erlauben es, das Modell durch FEM-Simulationen an die intraoperative Oberfläche anzunähern. In Simulationen konnte das Verfahren eine hohe Registrierungsgenauigkeit bei vorlaufenden Deformationen erreichen. Im in vivo Schweineversuch lieferte das Verfahren ebenfalls vielversprechende Ergebnisse.

Realistische Silikonorgane Neben den eigentlichen Verfahren zur Weichgeweberegistrierung, ist auch ein Blick auf die Evaluation dieser Verfahren lohnenswert. Hier zeigt sich, dass künstliche Organmodelle ein wichtiges Bindeglied zwischen Simulationen und Tierversuchen darstellen. Für die Evaluation von Registrierungsalgorithmen sind vor allem die mechanischen Eigenschaften des Organmodells von Bedeutung. Der Guss von Silikonorganen ist einfach und kostengünstig, hat aufgrund des verwendeten Silikons allerdings den Nachteil, dass die Modelle deutlich härter als vergleichbares Weichgewebe sind.

Um ein weiches Organmodell zu erstellen und gleichzeitig die Vorteile des Silikongusses beizubehalten, wurde in dieser Arbeit ein spezielles 3D-Druckverfahren erforscht. Dabei wird ein Negativgussmodell des Organs aus wasserlöslichem Material im 3D-Drucker hergestellt. Die Besonderheit ist eine Gitterstruktur, die sich durch das ganze Gussmodell zieht. Nach dem Einfüllen und Aushärten des Silikons kann die Gussform mitsamt der innen liegenden Gitterstruktur aufgelöst werden. Dadurch entstehen überall im Silikonmodell kleine Hohlräume, welche die Struktur des Modells schwächen. In dem die Gitterstruktur vor dem Druckprozess angepasst wird kann der Härtegrad des späteren Modells in einem Rahmen von 30-100% des Silikon-Vollmodells eingestellt werden.

8.2 Ausblick

Die in dieser Arbeit vorgestellten Methoden und Algorithmen eröffnen die Möglichkeit, präoperative Modelldaten im Rahmen eines Assistenzsystems mit laparoskopischen Bilddaten zu registrieren und damit zu verknüpfen. Es liegt in der Natur der Grundlagenforschung, dass hierbei noch vielfältige Verbesserungen und Erweiterungen der entwickelten Methoden möglich sind.

Das Fundament einer präzisen Weichgeweberegistrierung ist die intraoperative 3D-Rekonstruktion. Ohne ein genaues (Teil-)Modell der Organe während der Operation, können auch gute Registrierungsalgorithmen keine zufriedenstellenden Ergebnisse generieren. Das hier vorgestellte Stereorekonstruktionsverfahren

auf Basis von *Convolutional* Neuronalen Netzen ist vor allem ein Konzeptnachweis für die Möglichkeiten des maschinellen Lernen in der intraoperativen Bildgebung. Das Verfahren kann durch weitere Trainingsdaten stetig verbessert werden. Hierbei könnten gerade aus dem Bereich der Computergrafik, Erkenntnisse zur photorealistischen Bildsynthese einen wichtigen Beitrag zur Generierung von synthetischen Trainingsdaten liefern. Durch den Einsatz des automatischen, dünnbesetzten Lernens auf realen Endoskopsequenzen, kann das Verfahren ebenfalls durch die Akquirierung von neuen Aufnahmen aus Operationen verbessert werden.

Sowohl die initiale als auch die dynamische Weichgeweberegistrierung nutzen dichte Tiefenkarten als intraoperative Datenquelle. Neben den beschriebenen Vorteilen, hat dieses Vorgehen auch einige Nachteile zufolge. Hier ist vor allem der tangential Drift des prä- und intraoperativen Modells zu beachten. Bei homogenen geometrischen Formen hat es gerade die dynamische Registrierung schwer die korrespondierenden Oberflächenbereiche richtig zuzuordnen. Abhilfe könnten hier landmarkenbasierte Verfahren aus dem Stand der Forschung bieten. Ohne die Vorteile der dichten Tiefenkarte zu verlieren, könnten einzelne Landmarken als Anker dienen um einen Drift der Oberflächen zu verhindern und diese an bekannten Korrespondenzen zu fixieren.

Weiteres Potential besteht hier auch in einem rein bildbasierten Trackingansatz für die endoskopische Bildgebung. So könnte auf zusätzliche Geräte wie das Polaris Spectra System verzichtet und somit auf eine zusätzliche Kalibrierung, Marker, Geld für Kauf, Wartung und Raum eingespart werden. Ohne die Einschränkungen der „Line of Sight“ (das Trackingsystem muss zu allen Marker ununterbrochen Sichtkontakt haben) können Systeme zudem einfacher genutzt werden. In ersten Versuchen mit einer Kombination aus dichtem ICP-Tracking und Landmarkentracking und -matching, welche durch ein Kalmanfilter-Schema verbunden wurden, konnte eine Verbesserung im Vergleich zu den einzelnen Verfahren gezeigt werden Reichard *et al.* (2016). Um den strengen Qualitätsstandards für die Behandlung von menschlichem Leben gerecht zu werden, muss hier dennoch viel Arbeit in robuste und akkurate Trackingansätze investiert werden.

Die in dieser Arbeit vorgestellten Herstellungsmethoden für wasserlösliche Gussformen wurden nur für die Produktion von weichen Organphantomen erforscht und genutzt. Das Verfahren hat jedoch auch großes Potential für andere Bereiche der künstlichen Organherstellung. So könnte mit den wasserlöslichen Hohlräumen ein Organ mit Gefäßsystem geschaffen werden, welches die Simulation des Blutflusses erlaubt. Für die Forschung in der Radiologie und Krebsforschung können Hohlräume für Tumore geschaffen werden, um diese anschließend mit radioaktiven Markern zu füllen. Auch denkbar wäre die Nutzung des Verfahrens für ein poröses, mit Luft gefülltes Lungenmodell, welches mit einer klassischen Gussform nicht realisiert werden könnte.

Der Weg zur computer-assistierten Weichgewebechirurgie ist mit vielen Problemen, welche für sich schon eine Herausforderung darstellen, gepflastert. Vergangene Arbeiten und auch diese Arbeit haben ihren Beitrag dazu geleistet, diesen

Weg mit Lösungen zur 3D-Rekonstruktion, Instrumentendetektion, Workflowanalyse, Organdeformation, Registrierung und vielen weiteren Feldern gangbar zu machen und das Ziel in Sichtweite zu rücken.

Abkürzungsverzeichnis

- AR** Augmented Reality
- CAS** Computerassistierte Chirurgie
- CNN** Convolutional Neural Network
- CT** Computer Tomographie
- CV** Computer Vision
- DLT** Direkte lineare Transformation
- FDM** Fused Deposition Modeling
- HMA** Hierarchical Multi-Affine Algorithm
- ICP** Iterative Closest Point
- MIC** Minimal-invasive Chirurgie
- MLP** Multilayer Perceptron
- MRT** Magnetresonanztomografie
- PbSM** Physics based Shape Matching
- PVA** Polyvinylalkohol
- RSME** Root-mean-square Error
- SfM** Structure from Motion
- SLAM** Simultaneous Localization And Mapping
- ToF** Time of Flight

Anhang

Anhang A

Technische Daten

A.1 Datenblätter für 3D-Druck

PRÄZISE ABFORMEN.
DETAILGETREU REPRODUZIEREN.



KauPo Plankenhorn e.K.
Max-Planck-Straße 9/3
D-78549 Spaichingen
Fon +49 (0) 74 24 - 9 58 42 - 3
Fax +49 (0) 74 24 - 9 58 42 - 55
info@kaupo.de - www.kaupo.de

ECOFLEX® SERIE

Additionsvernetzende, extrem weiche Silikone

A. Produktbeschreibung

Ecoflex® sind additionsvernetzende Silikone, die vielseitig einsetzbar und einfach in der Anwendung sind. Sie werden 1A : 1A nach Gewicht oder Volumen gemischt und härten bei Raumtemperatur mit vernachlässigbarer Schrumpfung aus. Die niedere Viskosität verspricht einfaches Mischen und Entlüften. Durch Verwendung der Doppelkartuschen in einer Dosierpistole wird die Handhabung noch einfacher.

Ecoflex® Silikone sind sehr weich, sehr stabil und extrem dehnbar. Sie lassen sich unzählige Male ziehen ohne zu reißen und nehmen immer wieder ihre Originalform an. Sie sind transluzent und können deshalb gut mit unseren Silc-Pig® Farbpigmenten eingefärbt werden um eine Vielzahl von Farbeffekten zu erzielen. Um Ecoflex® noch flüssiger einzustellen kann unser Silikone Thinner® verwendet werden. Um Ecoflex® streichfähig einzustellen verwendet

man Ure-Fil® 9. Hinweis: Thi-Vex® II Silikonverdicker ist nur für Ecoflex® 0010 und Ecoflex® 5 geeignet.

Weich, weicher, am weichsten....Ecoflex® Silikone basieren auf Smooth-On's Dragon Skin® Formel und sind in 5 Shore Härten erhältlich: 5A, 00-50, 00-30, 00-20 und 00-10. Sie sind hervorragend geeignet für die Erstellung von Spezialeffekten (Animatroniken, Make-up FX, Masken etc.). Auch im Bereich der Orthopädietechnik (Silikonliner, Polsterungen, Dämpfungen) ergeben sich viele Anwendungsmöglichkeiten für dieses Produkt.

Ecoflex® 5 hat eine Topfzeit von 1 Minute und eine Entformzeit von 5 Minuten - erhältlich nur in Doppelkartuschen zum schnellen Mischen in einer Dosierpistole.

EcoFlex® 00-10, 00-30, 00-20 und 00-50 sind in verschiedenen Gebindegrößen erhältlich; 00-30 und 00-50 auch in der Doppelkartusche.

B. Technische Daten

ECOFLEX®	00-10	00-20	00-30	00-50	5
Mischung n. Volumen	1A:1B	1A:1B	1A:1B	1A:1B	1A:1B
Mischung n. Gewicht	1A:1B	1A:1B	1A:1B	1A:1B	1A:1B
Viskosität gemischt (mPas)	14000	3000	3000	8000	13000
Spez. Gewicht (g/cm³)	1,04	1,07	1,07	1,07	1,07
Farbe	transluzent	transluzent	transluzent	transluzent	transluzent
Topfzeit (Min.)	30	20	45	18	1
Entformzeit (Std.)	4	4	4	3	5 Min.
Shore Härte	00-10	00-20	00-30	00-50	5A
Zugfestigkeit (N/mm²)	0,38	1,10	1,38	2,17	2,41
E-Modul (N/mm²)	0,06	0,06	0,07	0,08	0,10
Reißdehnung (%)	800	845	900	980	1000
Reißfestigkeit (N/mm)	3,92	5,35	6,78	8,92	13,38
Schrumpfung (%)	<0,1	<0,1	<0,1	<0,1	<0,1

Angaben bei Raumtemperatur (23°C) und nach 7 Tagen (max. physikalische Eigenschaften) gemessen. Prüfnorm: ASTM-Standard.

C. Lagerung • Haltbarkeit

Bei Raumtemperatur (ca. 23 °C) lagern und verwenden. Nach Öffnung der beiden Behälter verkürzt sich die Haltbarkeit des Materials. Restmengen daher so schnell wie möglich verarbeiten. Nach Materialentnahme die beiden Behälter sofort

wieder verschließen. Wärmere Temperaturen verkürzen die Lagerzeit zusätzlich. Auch die Topf- und Entformzeit fallen bei wärmeren Temperaturen deutlich kürzer aus.

D. Vorbereitung • Versiegelung • Trennmittelauftrag

In gut belüfteter Umgebung verarbeiten. Das Tragen von Augenschutz, Gummihandschuhen und langärmeliger Bekleidung wird empfohlen. Keine Latexhandschuhe verwenden (Vernetzungsstörung!). Die Vernetzung von Silikonen kann durch manche Fremdstoffe (z. B. Schwefel, unvernetztes Epoxid- und Polyesterharz, Latex, Kondensations silikon,

Polyurethankautschuk) gestört werden, wobei die Oberfläche klebrig bleibt oder sogar die gesamte Silikonmasse nicht aushärtet. Um eine solche Vernetzungsstörung zu vermeiden, muss eine Schutzschicht aufgetragen werden (z.B. Acryllack, evtl. mehrere Schichten - gut trocknen lassen).

Technisches Merkblatt

Abbildung A.1: Datenblatt der Ecoflex-Serie (http://www.kaupo.de/shop/out/media/ECOFLEX_SERIE.pdf, Abruf am 03.08.2017)

PRÄZISE ABFORMEN.
DETAILGETREU REPRODUZIEREN.

KauPo
Kautschuk + Polyurethane

KauPo Plankenhorn e.K.
Max-Planck-Straße 9/3
D-78549 Spaichingen
Fon +49 (0)74 24 - 958 42 - 3
Fax +49 (0)74 24 - 958 42 - 55
info@kaupo.de - www.kaupo.de

ECOFLEX® 00-35

Sehr weiches Additionssilikon

A. Produktbeschreibung

Ecoflex® 00-35 ist ein additionsvernetzendes Silikon, das vielseitig einsetzbar und einfach in der Anwendung ist. Es wird 1A : 1B nach Gewicht oder Volumen gemischt und härtet bei Raumtemperatur mit vernachlässigbarer Schrumpfung aus. Die niedere Viskosität verspricht einfaches Mischen und Entlüften. Ecoflex® 00-35 ist sehr weich, sehr stabil und extrem dehnbar. Es lässt sich unzählige Male ziehen ohne zu reißen und nimmt immer wieder seine Originalform an. Es ist transluzent und kann deshalb gut mit unseren Silc-Pig® Farbpigmenten eingefärbt werden um eine Vielzahl von Farbeffekten zu erzielen. Um Ecoflex® 00-35 noch flüssiger einzustellen kann unser Silicone Thinner® verwendet

werden. Um es streichfähig einzustellen verwendet man Thi-Vex (siehe Technisches Merkblatt).

Biokompatibilität: Ecoflex® 00-35 ist nach dem internationalen Standard OECD TG 439 (Hautirritation) geprüft und als unbedenklich für den Hautkontakt eingestuft, auch im flüssigen Zustand. Damit lässt es sich auch problemlos für Körperabformungen verwenden und kann direkt auf die Haut aufgetragen werden (Trenncreme erforderlich).

Des Weiteren ist es hervorragend geeignet für die Erstellung von Spezialeffekten (Animatroniken, Make-up FX, Masken etc.). Auch im Bereich der Orthopädietechnik (Silikonliner, Polsterungen, Dämpfungen) ergeben sich viele Anwendungsmöglichkeiten für dieses Produkt.

B. Technische Daten

Mischung n. Volumen	1A:1B
Mischung n. Gewicht	1A:1B
Viskosität gemischt (mPas)	3500
Spez. Gewicht (g/cm ³)	1,07
Farbe	weiß-transluzent
Topfzeit (Min.)	2,5
Entformzeit (Std.)	5
Shore Härte	00-35
Zugfestigkeit (N/mm ²)	1,38
E-Modul (N/mm ²)	0,07
Reißdehnung (%)	900
Reißfestigkeit (N/mm)	6,78
Schrumpfung (%)	<0,1
Einsatztemperatur (°C)	-53 bis +205

Angaben bei Raumtemperatur (23°C) und nach 7 Tagen (max. physikalische Eigenschaften) gemessen. Prüfnorm: ASTM-Standard.

C. Lagerung • Haltbarkeit

Bei Raumtemperatur (ca. 23 °C) lagern und verwenden. Nach Öffnung der beiden Behälter verkürzt sich die Haltbarkeit des Materials. Restmengen daher so schnell wie möglich verarbeiten. Nach Materialentnahme die beiden Behälter sofort

wieder verschließen. Wärmere Temperaturen verkürzen die Lagerzeit zusätzlich. Auch die Topf- und Entformzeit fallen bei wärmeren Temperaturen deutlich kürzer aus.

D. Vorbereitung • Versiegelung • Trennmittelauftrag

In gut belüfteter Umgebung verarbeiten. Das Tragen von Augenschutz, Gummihandschuhen und langärmeliger Bekleidung wird empfohlen. Keine Latexhandschuhe verwenden (Vernetzungsstörung!). Die Vernetzung von Silikon kann durch manche Fremdstoffe (z. B. Schwefel, unvernetztes Epoxid- und Polyesterharz, Latex, Kondensations-Silikon, Polyurethankautschuk) gestört werden, wobei die Oberfläche klebrig bleibt oder sogar die gesamte Silikonmasse nicht

aushärtet. Um eine solche Vernetzungsstörung zu vermeiden, muss eine Schutzschicht aufgetragen werden (z.B. Acryllack, evtl. mehrere Schichten - gut trocknen lassen).

Wichtig: Additionssilicone härten trotz Versiegelung nicht auf schwefelhaltigem Ton und manchen Plastelintypen aus. Generell empfehlen wir bei Unsicherheiten über die Verträglichkeit zwischen dem Silikonkautschuk und der

Technisches Merkblatt

Abbildung A.2: Datenblatt des Silikons Ecoflex 00-35 (http://www.kaupo.de/shop/out/media/ECOFLEX_0035.pdf, Abruf am 03.08.2017)

Technical Data Sheet



Product name: AquaSolve™ - PVA

Date of issue: 29 October 2015

Version: v2

AquaSolve™ PVA is an “easy to use” high-end PVA (PolyVinyl Alcohol) type of 3D printer filament. AquaSolve™ PVA is a rapidly cold water soluble PolyVinyl Alcohol type of filament, which bonds extremely well to (thermo)plastics and because of its process stability is “easy to print” at relatively low temperatures.

AquaSolve™ PVA has a limited smell during printing and is non-toxic and biodegradable once dissolved in water.

Properties	Typical value	Test Method	Test condition
Physical			
Specific gravity	1.23 g/cc	ASTM D1505	-
Melt flow rate	14-20 g/10min	-	190° C/21.6Kg
Water absorption	-	-	-
Moisture absorption	-	-	-
Mechanical			
Impact strength	1.6 KJ/m²	ISO 179	Charpy Notched @23° C (73° F)
Tensile strength	78 Mpa	ISO 527	Stress @ Yield 23° C
Tensile modulus	3860 Mpa	ISO 527	-
Elongation at break	9.90%	ISO 527	Nominal Strain at Break, 23° C
Flexural strength	-	-	-
Flexural modulus	-	-	-
Hardness	-	-	-
Thermal			
Print temperature	± 180 - 205° C	-	-
Melting temperature	± 163	-	-
Viscat softening temp.	± 60.2° C	ISO 306	VST/A/50 (50° C/h, 10N)
Optical			
Haze	-	-	-
Transmittance	-	-	-
Gloss	-	-	-

Product details, certifications and compliance		Diameter	Tolerance	Roundness
HS Code	39169090	1.75mm	± 0.05mm	≥ 95%
REACH compliant	Yes	2.85mm	± 0.10mm	≥ 95%
RoHS certified	Yes			
FDA compliant	No			

Formfutura VOF	CoC: 55502105	Tel: +31 (0)85 002 0881
Groenestraat 215	VAT: NL851741083B01	Email: info@formfutura.com
6531 HH Nijmegen	EORI: NL851741083	Website: www.formfutura.com
The Netherlands		

All information supplied by or on behalf of Formfutura in relation to its products, whether in the nature of data, recommendations or otherwise, is supported by research and, in good faith, believed reliable, but Formfutura assumes no liability and makes no warranties of any kind, express or implied, including, but not limited to, those of title, merchantability, fitness for a particular purpose or non-infringement or any warranty arising from a course of dealing, usage, or trade practice whatsoever in respect of application, processing or use made of the forementioned information or product. The user assumes all responsibility for the use of all information provided and shall verify quality and other properties or any consequence from the use of all such information. Typical values are indicative only and are not to be construed as being binding specifications.

Abbildung A.3: Datenblatt des PVA-Druckmaterials (<http://www.formfutura.com/service/downloads/>, Abruf am 03.08.2017)





ENGINEERED AND MADE IN GERMANY

TECHNISCHE DATEN

DRUCK
Druckverfahren
 FFF (Fused Filament Fabrication)

Druckbereich
 390 x 400 x 330 mm

Schichtauflösung min.
 100 Micron bzw. 0,1 mm

Düsendurchmesser
 0,3 / 0,4 / 0,5 (Standard) / 1,00 mm

Filament-Durchmesser
 3mm oder 1,75mm*
 *anderes Hotend wird benötigt

Material
 PLA, ABS, PA, PS, etc.*
 *manche Filamente benötigen ein Heizbett

Connectivity
 USB, WLAN*, Ethernet*, SD-Karte
 *via opt. PrintBox

Bauteiltoleranz (theoretische Bauteiltoleranz)
 +/- 0,1 mm

MASSE UND BETRIEB
Betriebsspannung
 115 / 230 V~

Leistungsaufnahme
 ca. 50 W

Abmessungen
 660 x 660 x 770 mm

Gerätgewicht / Versandgewicht
 55 kg / 70 kg

GROSSER DRUCKRAUM
 Mit seinem Druckraum von 390 x 400 x 330 cm lässt der X400 sowohl beim Druck großer Objekte als auch für die Kleinserienfertigung wenig Wünsche offen.

SCHNELL UND PRÄZISE:
 Der X400 ist nicht nur schnell, sondern druckt auch präzise mit einer Schichtauflösung von bis zu 0,1 mm. Hochwertige Komponenten mit spielarmen Antrieben und gefrästen Metallverbindungen dienen einer hohen Wiederholgenauigkeit.

ENTWICKELT FÜR DEN PROFESSIONELLEN EINSATZ
 Unsere Kunden sind die beste Referenz. Der X400 befindet sich vielfach im Einsatz, unter anderem in der Automobilindustrie, dem Formen- und Werkzeugbau, in Gießereien, bei Kleinserienfertigern, bei 3D-Druck-Dienstleistern, der Baubranche genauso wie bei Architekten, Künstlern oder Designern.

DUAL-DRUCK
 Mit zwei Extrudern drucken Sie mit zwei Farben oder zwei Materialien. Wählen Sie zwischen verschiedenen Düsen (0,3 bis 1 mm) je nachdem ob Sie schneller oder in höherer Auflösung drucken möchten.

PROFESSIONELLER SERVICE
 Der X400 hat seine Zuverlässigkeit im Dauerbetrieb bewiesen. Zugeschnitten auf die Bedürfnisse im industriellen Einsatz erhalten Sie von uns und unseren autorisierten Vertriebspartnern einen optionalen Wartungsvertrag und professionellen Vor-Ort-Service.

HERVORRAGENDES PREIS-LEISTUNGSVERHÄLTNIS
 Unsere X400 Serie ist bekannt für ihr gutes Preis-Leistungsverhältnis.

Wählen Sie aus verschiedenen Produktvarianten das Modell, das Ihren Bedürfnissen entspricht.

MEHR DETAILS UNTER
WWW.GERMANREPRAP.COM/PRODUKTE/3D-DRUCKER/X400

Überreicht von



German RepRap  **Future in 3D Printing**

German RepRap GmbH
 Kapellenstr. 9
 85622 Feldkirchen
 Deutschland

Fon: +49 89 2488986 – 0
 Fax: +49 89 2488986 – 99
 E-Mail: info@germanreprap.com
 Web: www.germanreprap.com

German RepRap ist ein eingetragenes Warenzeichen der German RepRap GmbH.

Abbildung A.4: Datenblatt des X400 PRO 3D-Druckers (<https://www.germanreprap.com/produkte/3d-drucker/x400/>, Abruf am 03.08.2017)

A.2 Detaillierte Messergebnisse der Silikonproben




Abbildung A.5: Spannungs-Stauchungs-Kurven des Referenz-Vollzylinders. Diese und alle folgenden Messungen wurden durchgeführt mit einer Zwick-Universalprüfmaschine (bis 2.5 kN), einer Kraftmessdose (bis 1 kN), einer Verfahrensgeschwindigkeit von 3 mm min^{-1} und einer maximale Stauchung bis 10 mm. Es wurden jeweils drei Messungen durchgeführt.




Abbildung A.6: Spannungs-Stauchungskurve der Probe mit schräger Struktur




Abbildung A.7: Spannungs-Stauchungskurve der Probe mit senkrechter Struktur und 1.5 mm-Stegdicke




Abbildung A.8: Spannungs-Stauchungskurve der Probe mit senkrechter Struktur und 3 mm-Stegdicke

Abbildungsverzeichnis

1.1	In vivo Laparoskopie	2
1.2	Ablauf der Weichgeweberegistrierung	4
2.1	Schematische Darstellung Laparoskopie	8
2.2	Stereoendoskopbild Beispiel	9
2.3	Schematische Darstellung Endoskop	12
2.4	DaVinci Stereoendoskop	13
2.5	DaVinci Chirurgieroboter	16
3.1	Stereokamera	24
4.1	Lochkameramodell	35
4.2	Schachbrett	37
4.3	Stereokamera	40
4.4	Perzeptron	41
4.5	Neuronales Netz	43
4.6	2D Anordnung der Neuronen	47
4.7	Faltungen der Netzschichten	48
4.8	Max-Pooling	49
4.9	Trainingsdaten für die endoskopische Stereorekonstruktion	51
4.10	Unity3D Interface	53
4.11	Glanzlichter	54
4.12	Bildsynthese	55
4.13	Disparitäts-Shader	56
4.14	SIFT und SURF für dünnbesetzte Disparitätskarten	57
4.15	CNN Architektur	58
4.16	CNN Disparitätsschätzung	60
4.17	Endoskopischer Vergleichsdatensatz	62
4.18	Ergebnisse zur CNN Disparitätsschätzung	64
5.1	Kamerabild und Tiefenkarte in silico	68
5.2	Mosaik eines Leberphantoms	69
5.3	Ablaufdiagramm des Mosaikprozesses	71
5.4	Mosaik-Fehlerverteilung für Simulation	77
5.5	Mosaik-Fehlerverteilung bei Rauschen	79
5.6	Versuchsaufbau für Mosaik-Phantomversuche	80
5.7	Mosaik-Fehlerverteilung für Phantomversuche	81
5.8	ICP Fehler bei Mosaikerstellung	83
5.9	Mosaik-Fehlerverteilung für ex vivo Versuche	84

Abbildungsverzeichnis

5.10	Versuchsaufbau für Mosaik in vivo	86
5.11	Mosaik-Fehlerverteilung für in vivo Versuche	87
5.12	Physics Based Shape Matching	89
5.13	HRM Rekonstruktionsfehler	90
6.1	Weichgewebedeformation durch Instrumente	93
6.2	Tetraeder-Volumenmodell einer Leber	96
6.3	Ablauf der dynamischen Registrierung	98
6.4	Projektive Zuweisung der Tiefenwerte	99
6.5	Illustrierung des biomechanischen Modells	102
6.6	Dynamischer Registrierungsfehler in silico	103
6.7	In silico Deformation	104
6.8	Dynamische Registrierung in vivo	104
6.9	Dynamische Registrierung in vivo II	105
7.1	Beispielabbildung einer Spannungs-Dehnungskurve	108
7.2	Renderings der Gitterstruktur, Gussform und Prüfkörper	113
7.3	Simulationsergebnisse in Creo	114
7.4	Simulationsergebnisse von E-Modul über Stegdicke	114
7.5	Erster erfolgreicher Druck eines PVA Funktionsmusters.	116
7.6	Bilder der Silikonproben	116
7.7	Messaufbau der Zwick-Universalprüfmaschine	118
7.8	Vergleich Regressionen der Messwerte mit Simulation	118
7.9	Bilder der drei Gussformen	119
7.10	Verschiedene Ansichten der fertigen Leber	120
A.1	Datenblatt der Ecoflex-Serie	134
A.2	Datenblatt des Ecoflex 00-35	135
A.3	Datenblatt des PVA-Druckmaterials	136
A.4	Datenblatt des X400 PRO 3D-Druckers	137
A.5	Spannungs-Stauchungskurve des Vollzylinders	139
A.6	Spannungs-Stauchungskurve Probe I	140
A.7	Spannungs-Stauchungskurve Probe II	141
A.8	Spannungs-Stauchungskurve Probe III	142

Tabellenverzeichnis

4.1	Ergebnisse zur CNN Disparitätsschätzung	65
5.1	Hardware für Mosaikversuche	75
5.2	In siliko Mosaikergebnisse	78
5.3	Phantom Mosaikergebnisse	82
5.4	Ex vivo Mosaikergebnisse	84
5.5	In vivo Mosaikergebnisse	85
7.1	Mechanische Eigenschaften der Leber	109
7.2	Mechanische Eigenschaften der Leber II	110
7.3	Mögliche Materialien für ein Organphantom	111
7.4	Ergebnisse der Probenvermessungen	117

Literaturverzeichnis

- Abdalbari, Anwar, Huang, Xishi, & Ren, Jing. 2013. Endoscopy-MR Image Fusion for Image Guided Procedures. *Journal of Biomedical Imaging*, **2013**(Jan.), 23:23–23:23.
- Atzpadin, Nicole, Kauff, Peter, & Schreer, Oliver. 2004. Stereo analysis by hybrid recursive matching for real-time immersive video conferencing. *Circuits and Systems for Video Technology, IEEE Transactions on*, **14**(3), 321–334.
- Autorino, Riccardo, Cicione, Antonio, Rassweiler, Jens, & Lima, Estevao. 2014. Intraoperative ultrasound overlay in robot-assisted partial nephrectomy: first clinical experience. *European urology*, **65**(3).
- Azad, Pedram, Gockel, Tilo, & Dillmann, Rüdiger. 2007. *Computer Vision: Das Praxisbuch*. Elektor-Verlag Aachen.
- Bano, Jordan, Hostettler, Alexandre, Nicolau, SA, Cotin, Stephane, Doignon, Christophe, Wu, HS, Huang, MH, Soler, Luc, & Marescaux, Jacques. 2012. Simulation of pneumoperitoneum for laparoscopic surgery planning. *Pages 91–98 of: International Conference on Medical Image Computing and Computer-Assisted Intervention*. Springer.
- Bay, Herbert, Tuytelaars, Tinne, & Van Gool, Luc. 2006. Surf: Speeded up robust features. *Pages 404–417 of: European conference on computer vision*. Springer.
- Bernhardt, Sylvain, Nicolau, Stéphane A, Soler, Luc, & Doignon, Christophe. 2017a. The status of augmented reality in laparoscopic surgery as of 2016. *Medical image analysis*, **37**, 66–90.
- Bernhardt, Sylvain, Nicolau, Stéphane A., Soler, Luc, & Doignon, Christophe. 2017b. The status of augmented reality in laparoscopic surgery as of 2016. *Medical Image Analysis*, **37**, 66 – 90.
- Blais, Gérard, & Levine, Martin D. 1995. Registering multiview range data to create 3D computer objects. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, **17**(8), 820–824.
- Bodenstedt, Sebastian. 2017. *Image-Based Scene Analysis for Computer-Assisted Laparoscopic Surgery*. KIT Scientific Publishing.
- Bodenstedt, S, Reichard, D, Suwelack, S, Wagner, M, Kenngott, H, Müller-Stich, B, Dillmann, R, & Speidel, S. 2015. Intraoperative on-the-fly organ-mosaicking for laparoscopic surgery. *Pages 94151S–94151S of: SPIE Medical Imaging*. International Society for Optics and Photonics.

- Bodenstedt, Sebastian, Görtler, Jochen, Wagner, Martin, Kenngott, Hannes, Müller-Stich, Beat Peter, Dillmann, Rüdiger, & Speidel, Stefanie. 2016. Superpixel-based structure classification for laparoscopic surgery. *Proc. SPIE*, **9786**, 978618–978618–6.
- Botden, Sanne MBI, & Jakimowicz, Jack J. 2009. What is going on in augmented reality simulation in laparoscopic surgery? *Surgical endoscopy*, **23**(8), 1693.
- Bradski, Gary, & Kaehler, Adrian. 2008. *Learning OpenCV: Computer vision with the OpenCV library*. Ö'Reilly Media, Inc."
- Bregler, Christoph, Hertzmann, Aaron, & Biermann, Henning. 2000. Recovering non-rigid 3D shape from image streams. *Pages 690–696 of: Computer Vision and Pattern Recognition, 2000. Proceedings. IEEE Conference on*, vol. 2. IEEE.
- Brown, D.C. 1966. Decentering Distortion of Lenses. *Photogrammetric Engineering*, **7**, 444–462.
- Brühl, W. 1966. Zwischenfälle und Komplikationen bei der Laparoskopie und gezielten Leberpunktion. *DMW-Deutsche Medizinische Wochenschrift*, **91**(51), 2297–2299.
- Carter, F.J., Frank, T.G., Davies, P.J., McLean, D., & Cuschieri, A. 2001. Measurements and modelling of the compliance of human and porcine organs. *Medical Image Analysis* **5**(4): 231-236, **5**, 231–236.
- Carus, Thomas. 2014. *Operationsatlas Laparoskopische Chirurgie: Indikationen-Operationsablauf-Varianten-Komplikationen*. Springer-Verlag.
- Chang, Ping-Lin, Stoyanov, Danail, Davison, Andrew J, *et al.* 2013. Real-time dense stereo reconstruction using convex optimisation with a cost-volume for image-guided robotic surgery. *Pages 42–49 of: International Conference on Medical Image Computing and Computer-Assisted Intervention*. Springer.
- Clancy, Neil T., Stoyanov, Danail, Maier-Hein, Lena, Groch, Anja, Yang, Guang-Zhong, & Elson, Daniel S. 2011. Spectrally encoded fiber-based structured lighting probe for intraoperative 3D imaging. *Biomed. Opt. Express*, **2**(11), 3119–3128.
- Clements, Logan W, Chapman, William C, Dawant, Benoit M, Galloway Jr, Robert L, & Miga, Michael I. 2008. Robust surface registration using salient anatomical features for image-guided liver surgery: algorithm and validation. *Medical physics*, **35**(6), 2528–2540.
- Collins, Toby, & Bartoli, Adrien. 2012. *Towards Live Monocular 3D Laparoscopy Using Shading and Specularity Information*. Berlin, Heidelberg: Springer Berlin Heidelberg. Pages 11–21.
- Collins, Toby, Bartoli, Adrien, Bourdel, Nicolas, & Canis, Michel. 2016. Robust, Real-Time, Dense and Deformable 3D Organ Tracking in Laparoscopic Videos. *Pages 404–412 of: International Conference on Medical Image Computing and Computer-Assisted Intervention*. Springer.

- Davis, Chad J, & Filipi, Charles J. 1995. A history of endoscopic surgery. *Pages 3–20 of: Principles of Laparoscopic Surgery*. Springer.
- Devernay, Frédéric, Mourgues, Fabien, & Coste-Manière, Ève. 2001. Towards endoscopic augmented reality for robotically assisted minimally invasive cardiac surgery. *Pages 16–20 of: Medical Imaging and Augmented Reality, 2001. Proceedings. International Workshop on*. IEEE.
- Dieleman, Sander, Schlüter, Jan, Raffel, Colin, Olson, Eben, Sønderby, Søren Kaae, Nouri, Daniel, Maturana, Daniel, Thoma, Martin, Battenberg, Eric, Kelly, Jack, Fauw, Jeffrey De, Heilman, Michael, diogo149, McFee, Brian, Weideman, Hendrik, takacs84, peterderivaz, Jon, instagibbs, Rasul, Dr. Kashif, CongLiu, Britefury, & Degrave, Jonas. 2015 (Aug.). *Lasagne: First release*.
- dos Santos, Thiago Ramos, Seitel, Alexander, Kilgus, Thomas, Suwelack, Stefan, Wekerle, Anna-Laura, Kenngott, Hannes, Speidel, Stefanie, Schlemmer, Heinz-Peter, Meinzer, Hans-Peter, Heimann, Tobias, *et al.* 2014. Pose-independent surface matching for intra-operative soft-tissue marker-less registration. *Medical image analysis*, **18**(7), 1101–1114.
- Dosovitskiy, Alexey, Fischer, Philipp, Ilg, Eddy, Hausser, Philip, Hazirbas, Caner, Golkov, Vladimir, van der Smagt, Patrick, Cremers, Daniel, & Brox, Thomas. 2015. Flownet: Learning optical flow with convolutional networks. *Pages 2758–2766 of: Proceedings of the IEEE International Conference on Computer Vision*.
- Duda, Richard O., Hart, Peter E., & Stork, David G. 2001. *Pattern classification*. 2. ed. edn. New York: Wiley.
- Dwyer, George, Giataganas, Petros, Pratt, Philip, Hughes, Michael, & Yang, Guang-Zhong. 2015. A miniaturised robotic probe for real-time intraoperative fusion of ultrasound and endomicroscopy. *Pages 1196–1201 of: Robotics and Automation (ICRA), 2015 IEEE International Conference on*. IEEE.
- Edgcumbe, Philip, Pratt, Philip, Yang, Guang-Zhong, Nguan, Christopher, & Rohling, Robert. 2015. Pico Lantern: Surface reconstruction and augmented reality in laparoscopic surgery using a pick-up laser projector. *Medical Image Analysis*, **25**(1), 95 – 102.
- Engel, Jakob, Schöps, Thomas, & Cremers, Daniel. 2014. LSD-SLAM: Large-scale direct monocular SLAM. *Pages 834–849 of: European Conference on Computer Vision*. Springer.
- Ertel, Wolfgang. 2016. *Grundkurs künstliche Intelligenz: eine praxisorientierte Einführung*. Springer-Verlag.
- Feuerstein, Marco. 2007. *Augmented Reality in Laparoscopic Surgery: New Concepts for Intraoperative Multimodal Imaging*. Technische Universität München.
- Fiolka, A., Gillen, S., Knödgen, F., Wolf, M., Meyer, M., Schneider, A., & Feußner, H. 2010. Das chirurgische Operationsphantom ELITE – die Alternative zu Box- und virtuellen Trainern. *In: Computer- und Roboterassistierte Chirurgie (CURAC)*.

- Forsyth, D.A., & Ponce, J. 2012. *Computer Vision: A Modern Approach*. Always learning. Pearson Education, Limited.
- Fritsch, Jannik, Kuehnl, Tobias, & Geiger, Andreas. 2013. A New Performance Measure and Evaluation Benchmark for Road Detection Algorithms. *In: International Conference on Intelligent Transportation Systems (ITSC)*.
- Fung, Yuan-cheng. 2013. *Biomechanics: mechanical properties of living tissues*. Springer Science & Business Media.
- Furukawa, R., Masutani, R., Miyazaki, D., Baba, M., Hiura, S., Visentini-Scarzanella, M., Morinaga, H., Kawasaki, H., & Sagawa, R. 2015 (Aug). 2-DOF auto-calibration for a 3D endoscope system based on active stereo. *Pages 7937–7941 of: 2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*.
- Fusiello, Andrea, Trucco, Emanuele, & Verri, Alessandro. 2000. A compact algorithm for rectification of stereo pairs. *Machine Vision and Applications*, **12**, 16–22. 10.1007/s001380050120.
- Geiger, Andreas, Lenz, Philip, & Urtasun, Raquel. 2012. Are we ready for Autonomous Driving? The KITTI Vision Benchmark Suite. *In: Conference on Computer Vision and Pattern Recognition (CVPR)*.
- Gern, Markus. 2016. *Masterarbeit: Entwicklung eines biomechanisch realistischen Leberphantoms zur Einbettung in einen Operationssimulator*. IAR Dillmann, Pylatiuk, Karlsruhe Institute of Technology.
- Gomes, Paula. 2011. Surgical robotics: Reviewing the past, analysing the present, imagining the future. *Robotics and Computer-Integrated Manufacturing*, **27**(2), 261–266.
- Grasa, Oscar G, Civera, Javier, & Montiel, JMM. 2011. EKF monocular SLAM with relocalization for laparoscopic sequences. *Pages 4816–4821 of: Robotics and Automation (ICRA), 2011 IEEE International Conference on*. IEEE.
- Grasa, Oscar G, Bernal, Ernesto, Casado, Santiago, Gil, Iñigo, & Montiel, JM. 2014. Visual SLAM for handheld monocular endoscope. *Medical Imaging, IEEE Transactions on*, **33**(1), 135–146.
- Gupta, Tanmay, Shin, Daeyun, Sivagnanadasan, Naren, & Hoiem, Derek. 2016. 3DFS: Deformable Dense Depth Fusion and Segmentation for Object Reconstruction from a Handheld Camera. *arXiv preprint arXiv:1606.05002*.
- Haase, Sven, Bauer, Sebastian, Wasza, Jakob, Kilgus, Thomas, Maier-Hein, Lena, Schneider, Armin, Kranzfelder, Michael, Feußner, Hubertus, & Hornegger, Joachim. 2013. 3-D Operation Situs Reconstruction with Time-of-Flight Satellite Cameras Using Photogeometric Data Fusion. *Pages 356–363 of: Mori, Kensaku, Sakuma, Ichiro, Sato, Yoshinobu, Barillot, Christian, & Navab, Nassir (eds), Medical Image Computing and Computer-Assisted Intervention – MICCAI 2013. Lecture Notes in Computer Science*, vol. 8149. Springer Berlin Heidelberg.

- Häntschi, Dominik. 2017. *Diplomarbeit: Projective biomechanical depth matching for soft-tissue registration in laparoscopic surgery*. IAR Dillmann, Karlsruhe Institute of Technology.
- Harrington, Peter. 2012. *Machine learning in action*. Vol. 5. Manning Greenwich, CT.
- Hartley, Richard, & Zisserman, Andrew. 2003. *Multiple view geometry in computer vision*. Cambridge university press.
- Herline, Alan J, Stefansic, James D, Debelak, Jacob P, Hartmann, Steven L, Pinson, C Wright, Galloway, Robert L, & Chapman, William C. 1999. Image-guided surgery: preliminary feasibility studies of frameless stereotactic liver surgery. *Archives of Surgery*, **134**(6), 644–650.
- Herline, Alan J, Herring, Jeannette L, Stefansic, James D, Chapman, William C, Galloway, Robert L, & Dawant, Benoit M. 2000. Surface registration for use in interactive, image-guided liver surgery. *Computer Aided Surgery*, **5**(1), 11–17.
- Hirschmüller, Heiko. 2008. Stereo processing by semiglobal matching and mutual information. *IEEE Transactions on pattern analysis and machine intelligence*, **30**(2), 328–341.
- Hirschmüller, Heiko, & Scharstein, Daniel. 2007. Evaluation of cost functions for stereo matching. *Pages 1–8 of: Computer Vision and Pattern Recognition, 2007. CVPR'07. IEEE Conference on*. IEEE.
- Hochreiter, Sepp, Bengio, Yoshua, Frasconi, Paolo, & Schmidhuber, Jürgen. 2001. *Gradient flow in recurrent nets: the difficulty of learning long-term dependencies*.
- Holzmann, Günther, Meyer, Heinz, & Schumpich, Georg. 2012. *Technische Mechanik Festigkeitslehre*. Springer-Verlag.
- Hu, Mingxing, Penney, Graeme, Figl, Michael, Edwards, Philip, Bello, Fernando, Casula, Roberto, Rueckert, Daniel, & Hawkes, David. 2012. Reconstruction of a 3D surface from video that is robust to missing data and outliers: Application to minimally invasive surgery using stereo and mono endoscopes. *Medical Image Analysis*, **16**(3), 597 – 611. Computer Assisted Interventions.
- Hubel, David H. 1963. The visual cortex of the brain.
- Izadi, Shahram, Kim, David, Hilliges, Otmar, Molyneaux, David, Newcombe, Richard, Kohli, Pushmeet, Shotton, Jamie, Hodges, Steve, Freeman, Dustin, Davison, Andrew, & Fitzgibbon, Andrew. 2011. KinectFusion: real-time 3D reconstruction and interaction using a moving depth camera. *Pages 559–568 of: Proceedings of the 24th annual ACM symposium on User interface software and technology*. UIST '11. New York, NY, USA: ACM.
- Janoch, Allison, Karayev, Sergey, Jia, Yangqing, Barron, Jonathan T, Fritz, Mario, Saenko, Kate, & Darrell, Trevor. 2013. A category-level 3d object dataset: Putting the kinect to work. *Pages 141–165 of: Consumer Depth Cameras for Computer Vision*. Springer.

- Julier, Simon J, & Uhlmann, Jeffrey K. 2004. Unscented filtering and nonlinear estimation. *Proceedings of the IEEE*, **92**(3), 401–422.
- Kalk, Heinz, & Wildhirt, Egmont. 1962. *Lehrbuch und Atlas der Laparoskopie und Leberpunktion*. Georg Thieme.
- Kan, Michael K., & Hopkins, G. Bruce. 1979. Measurement of Liver Volume by Emission Computed tomography. *Journal of Nuclear Medicine*, **20**, 514–520.
- Keck, Tobias, & Germer, Christoph T. Minimalinvasive Viszeralchirurgie.
- Kemper, Andrew R., Santago, Anthony C., Stitzel, Joel D., Sparks, Jessica L., & Duma, Stefan M. 2010. Biomechanical response of human liver in tensile loading. *Annals of Advancement of Automotive Medicine*, **54**, 15–26.
- Kenngott, H. G., Wunscher, J. J., Wagner, M., Preukschas, A., Wekerle, A. L., & Neher, P. 2015. OpenHELP (Heidelberg laparoscopy phantom): development of an open-source surgical evaluation and training tool. *Surgical endoscopy*, **29**, 3338–3347.
- Kenngott, Hannes Götz. 2010. Entwicklung und Evaluation eines Navigationssystems für die Weichgewebechirurgie am Beispiel der minimal invasiven, transhiatalen, Telemanipulator-gestützten Ösophagektomie.
- Kenngott, HG, Fischer, L, Nickel, F, Rom, J, Rassweiler, J, & Müller-Stich, BP. 2012. Status of robotic assistance—a less traumatic and more accurate minimally invasive surgery? *Langenbeck's archives of surgery*, **397**(3), 333–341.
- Kingma, Diederik, & Ba, Jimmy. 2014. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- Lange, Robert, & Seitz, Peter. 2001. Solid-state time-of-flight range camera. *IEEE Journal of quantum electronics*, **37**(3), 390–397.
- LeCun, Yann, Boser, Bernhard, Denker, John S, Henderson, Donnie, Howard, Richard E, Hubbard, Wayne, & Jackel, Lawrence D. 1989. Backpropagation applied to handwritten zip code recognition. *Neural computation*, **1**(4), 541–551.
- LeCun, Yann, Bottou, Léon, Bengio, Yoshua, & Haffner, Patrick. 1998. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, **86**(11), 2278–2324.
- Lin, Jianyu, Clancy, Neil T., & Elson, Daniel S. 2015. An endoscopic structured light system using multispectral detection. *International Journal of Computer Assisted Radiology and Surgery*, **10**(12), 1941–1950.
- Lindeberg, Tony. 2013. A computational theory of visual receptive fields. *Biological cybernetics*, **107**(6), 589–635.
- Litynski, Grzegorz S. 1996. *Highlights in the history of laparoscopy: the development of laparoscopic techniques—a cumulative effort of internists, gynecologists, and surgeons*. Barbara Bernert Verlag.

- Long, Jonathan, Shelhamer, Evan, & Darrell, Trevor. 2015. Fully convolutional networks for semantic segmentation. *Pages 3431–3440 of: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition.*
- Longuet-Higgins, H Christopher. 1987. A computer algorithm for reconstructing a scene from two projections. *Readings in Computer Vision: Issues, Problems, Principles, and Paradigms*, MA Fischler and O. Firschein, eds, 61–62.
- Lowe, David G. 1999. Object recognition from local scale-invariant features. *Pages 1150–1157 of: Computer vision, 1999. The proceedings of the seventh IEEE international conference on*, vol. 2. Ieee.
- Lyu, Siwei, & Farid, Hany. 2005. How realistic is photorealistic? *IEEE Transactions on Signal Processing*, **53**(2), 845–850.
- Maier-Hein, L, Mountney, P, Bartoli, A, Elhawary, H, Elson, D, Groch, A, Kolb, A, Rodrigues, Marcos, Sorger, J, Speidel, Suzanne, *et al.* 2013. Optical techniques for 3D surface reconstruction in computer-assisted laparoscopic surgery. *Medical image analysis*, **17**(8), 974–996.
- Maier-Hein, L, Groch, A, Bartoli, A, Bodenstedt, S, Guillaume, B, Chang, P, Clancy, N, Elson, D, Haase, S, & Stoyanov, D. 2014. Comparative Validation of Single-Shot Optical Techniques for Laparoscopic 3D Surface Reconstruction.
- Malti, Abed, Bartoli, Adrien, & Collins, Toby. 2011. Template-Based Conformal Shape-from-Motion from Registered Laparoscopic Images. *Page 6 of: MIUA*, vol. 1.
- Maurice, X., Albitar, C., Doignon, C., & de Mathelin, M. 2012 (Aug). A structured light-based laparoscope with real-time organs' surface reconstruction for minimally invasive surgery. *Pages 5769–5772 of: 2012 Annual International Conference of the IEEE Engineering in Medicine and Biology Society.*
- Mayer, Nikolaus, Ilg, Eddy, Hausser, Philip, Fischer, Philipp, Cremers, Daniel, Dosovitskiy, Alexey, & Brox, Thomas. 2016. A large dataset to train convolutional networks for disparity, optical flow, and scene flow estimation. *Pages 4040–4048 of: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition.*
- McKee, Clayton T., Last, Julie A., Russell, Paul, & Murphy, Christopher J. 2011. Indentation Versus Tensile Measurements of Young's Modulus for Soft Biological Tissues. *Tissue Engineering*, **17**, 155–164.
- Menze, Moritz, & Geiger, Andreas. 2015. Object Scene Flow for Autonomous Vehicles. *In: Conference on Computer Vision and Pattern Recognition (CVPR).*
- Mirota, Daniel J., Ishii, Masaru, & Hager, Gregory D. 2011. Vision-Based Navigation in Image-Guided Interventions. *Annual Review of Biomedical Engineering*, **13**(1), 297–319. PMID: 21568713.

- Molina, D. Kimberley, & DiMaio, Vincent. 2011a. Normal Organ Weights in Men: Part II - The Brain, Lungs, Liver, Spleen, and Kidneys. *The American Journal of Forensic Medicine and Pathology*, **33**, 368–372.
- Molina, D. Kimberley, & DiMaio, Vincent. 2011b. Normal Organ Weights in Women: Part II - The Brain, Lungs, Liver, Spleen, and Kidneys. *The American Journal of Forensic Medicine and Pathology*, **36**, 182–187.
- Mountney, Peter, & Yang, Guang-Zhong. 2010. Motion compensated SLAM for image guided surgery. *Pages 496–504 of: Medical Image Computing and Computer-Assisted Intervention–MICCAI 2010*. Springer.
- Mountney, Peter, Stoyanov, Danail, Davison, Andrew, & Yang, Guang-Zhong. 2006. Simultaneous stereoscope localization and soft-tissue mapping for minimal invasive surgery. *Pages 347–354 of: Medical Image Computing and Computer-Assisted Intervention–MICCAI 2006*. Springer.
- Mountney, Peter, Stoyanov, Danail, & Yang, Guang-Zhong. 2010. Three-dimensional tissue deformation recovery and tracking. *IEEE Signal Processing Magazine*, **27**(4), 14–24.
- Najarian, S, Fallahnezhad, M, & Afshari, E. 2011. Advances in medical robotic systems with specific applications in surgery—A review. *Journal of medical engineering & technology*, **35**(1), 19–33.
- Navab, Nassir, Blum, Tobias, Wang, Lejing, Okur, Asli, & Wendler, Thomas. 2012. First deployments of augmented reality in operating rooms. *Computer*, **45**(7), 48–55.
- Nesterov, Yuri. 1983. A method for unconstrained convex minimization problem with the rate of convergence $O(1/k^2)$. *Doklady an SSSR*.
- Newcombe, Richard A., Izadi, Shahram, Hilliges, Otmar, Molyneaux, David, Kim, David, Davison, Andrew J., Kohli, Pushmeet, Shotton, Jamie, Hodges, Steve, & Fitzgibbon, Andrew. 2011. KinectFusion: Real-time dense surface mapping and tracking. *Pages 127–136 of: Proceedings of the 2011 10th IEEE International Symposium on Mixed and Augmented Reality*. ISMAR '11. Washington, DC, USA: IEEE Computer Society.
- Newcombe, Richard A, Fox, Dieter, & Seitz, Steven M. 2015. Dynamicfusion: Reconstruction and tracking of non-rigid scenes in real-time. *Pages 343–352 of: Proceedings of the IEEE conference on computer vision and pattern recognition*.
- Ngan, Addy, Durand, Frédo, & Matusik, Wojciech. 2005. Experimental Analysis of BRDF Models. *Rendering Techniques*, **2005**(16th), 2.
- Nicolau, Stéphane, Soler, Luc, Mutter, Didier, & Marescaux, Jacques. 2011. Augmented reality in laparoscopic surgical oncology. *Surgical oncology*, **20**(3), 189–201.
- Nielsen, Michael A. 2015. *Neural Networks and Deep Learning*. Determination Press.

- Nolden, Marco, Zelzer, Sascha, Seitel, Alexander, Wald, Diana, Müller, Michael, Franz, Alfred M, Maleike, Daniel, Fangerau, Markus, Baumhauer, Matthias, Maier-Hein, Lena, *et al.* 2013. The medical imaging interaction toolkit: challenges and advances. *International journal of computer assisted radiology and surgery*, **8**(4), 607–620.
- Nolte, LP, Zamorano, L, Visarius, H, Berlemann, U, Langlotz, F, Arm, E, & Schwarzenbach, O. 1995. Clinical evaluation of a system for precision enhancement in spine surgery. *Clinical Biomechanics*, **10**(6), 293–303.
- Nordmann, Arne. *File:Epipolar geometry.svg - Wikipedia, the free encyclopedia*.
- Nüchter, Andreas. 2009. *3D robotic mapping: the simultaneous localization and mapping problem with six degrees of freedom*. Vol. 52. Springer.
- Oktay, Ozan, Zhang, Li, Mansi, Tommaso, Mountney, Peter, Mewes, Philip, Nicolau, Stéphane, Soler, Luc, & Chéfd'hotel, Christophe. 2013. Biomechanically driven registration of pre-to intra-operative 3D images for laparoscopic surgery. *Pages 1–9 of: International Conference on Medical Image Computing and Computer-Assisted Intervention*. Springer.
- Olson, Edwin B. 2008. Robust and efficient robotic mapping.
- Orringer, Daniel A, Golby, Alexandra, & Jolesz, Ferenc. 2012. Neuronavigation in the surgical management of brain tumors: current and future trends. *Expert review of medical devices*, **9**(5), 491–500.
- Perlin, Ken. 1985. An image synthesizer. *ACM Siggraph Computer Graphics*, **19**(3), 287–296.
- Plantefève, Rosalie, Peterlik, Igor, Haouchine, Nazim, & Cotin, Stéphane. 2015. Patient-Specific Biomechanical Modeling for Guidance During Minimally-Invasive Hepatic Surgery. *Annals of biomedical engineering*, 1–15.
- Pott, PP. 2014. *Medical robotic database: MeRoDa*.
- Prados, E., & Faugeras, O. 2006. *Shape From Shading*. Boston, MA: Springer US. Pages 375–388.
- Pratt, Philip, Stoyanov, Danail, Visentini-Scarzanella, Marco, & Yang, Guang-Zhong. 2010. Dynamic guidance for robotic surgery using image-constrained biomechanical models. *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2010*, 77–85.
- Puerto-Souza, Gustavo, Mariottini, Gian-Luca, *et al.* 2013a. A fast and accurate feature-matching algorithm for minimally-invasive endoscopic images. *Medical Imaging, IEEE Transactions on*, **32**(7), 1201–1214.
- Puerto-Souza, Gustavo A, Castaño-Bardawil, Alberto, & Mariottini, Gian-Luca. 2013b. Real-time feature matching for the accurate recovery of augmented-reality display in laparoscopic videos. *Pages 153–166 of: Augmented Environments for Computer-Assisted Interventions*. Springer.

- Raschka, Sebastian. 2015. *Python machine learning*. Packt Publishing Ltd.
- Reichard, Daniel. 2014. *Diplomarbeit: 3D-Kartografierung in der laparskopischen Chirurgie*. IAR Dillmann, Karlsruhe Institute of Technology.
- Reichard, Daniel, Gern, Markus, Bodenstedt, Sebastian, Wagner, Martin, Kenngott, Hannes, Müller-Stich, Beat, Dillmann, Rüdiger, & Speidel, Stefanie. Using water-soluble additive manufacturing for cheap and soft silicon organ models. *Submitted to Medical Imaging: Image Processing*.
- Reichard, Daniel, Bodenstedt, Sebastian, Suwelack, Stefan, Mayer, Benjamin, Preukschas, Anas, Wagner, Martin, Kenngott, Hannes, Müller-Stich, Beat, Dillmann, Rüdiger, & Speidel, Stefanie. 2015. Intraoperative on-the-fly organ-mosaicking for laparoscopic surgery. *Journal of Medical Imaging*, **2**(4), 045001.
- Reichard, Daniel, Bodenstedt, Sebastian, Suwelack, Stefan, Wagner, Martin, Kenngott, Hannes, Müller-Stich, Beat P, Dillmann, Rüdiger, & Speidel, Stefanie. 2016. Robust endoscopic pose estimation for intraoperative organ-mosaicking. *Page 97841Q of: Medical Imaging: Image Processing*.
- Reichard, Daniel, Häntsch, Dominik, Bodenstedt, Sebastian, Suwelack, Stefan, Wagner, Martin, Kenngott, Hannes, Müller-Stich, Beat, Maier-Hein, Lena, Dillmann, Rüdiger, & Speidel, Stefanie. 2017. Projective biomechanical depth matching for soft tissue registration in laparoscopic surgery. *International Journal of Computer Assisted Radiology and Surgery*, 1–10.
- Reinhardt, HF, Trippel, M, Westermann, B, Horstmann, GA, & Gratzl, O. 1996. Computer assisted brain surgery for small lesions in the central sensorimotor region. *Acta neurochirurgica*, **138**(2), 200–205.
- Rhoten, RL Patrick, Luciano, Mark G, & Barnett, Gene H. 1997. Computer-assisted endoscopy for neurosurgical procedures. *Neurosurgery*, **40**(3), 632–638.
- Richa, Rogério, Bó, Antônio PL, & Poignet, Philippe. 2011. Towards robust 3D visual tracking for motion compensation in beating heart surgery. *Medical Image Analysis*, **15**(3), 302–315.
- Robinson, Alan, Alboul, Lyuba, & Rodrigues, Marcos. 2004. Methods for indexing stripes in uncoded structured light scanning systems.
- Röhl, Sebastian. 2013. *Intraoperative Modellierung und Registrierung für ein laparoskopisches Assistenzsystem*. KIT Scientific Publishing.
- Röhl, Sebastian, Bodenstedt, Sebastian, Suwelack, Stefan, Kenngott, Hannes, Müller-Stich, Beat P, Dillmann, Rüdiger, & Speidel, Stefanie. 2012. Dense GPU-enhanced surface reconstruction from stereo endoscopic images for intraoperative registration. *Medical Physics*, **39**, 1632.
- Rosenblatt, Frank. 1958. The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological review*, **65**(6), 386.

- Rucker, D Caleb, Wu, Yifei, Clements, Logan W, Ondrake, Janet E, Pheiffer, Thomas S, Simpson, Amber L, Jarnagin, William R, Miga, Michael, *et al.* 2014. A mechanics-based nonrigid registration method for liver surgery using sparse intraoperative data. *Medical Imaging, IEEE Transactions on*, **33**(1), 147–158.
- Rusu, Radu Bogdan, Blodow, Nico, & Beetz, Michael. 2009. Fast point feature histograms (fpfh) for 3d registration. *Pages 3212–3217 of: Robotics and Automation, 2009. ICRA'09. IEEE International Conference on*. IEEE.
- Sahin, Bünyamin, Emirzeoglu, Mehmet, Uzun, Ahmet, Incesu, Lütfi, Bek, Yüksel, Bilgic, Sait, & Kaplan, Süleyman. 2003. Unbiased estimation of the liver volume by the Cavalieri principle using Magnetic resonance images. *European Journal of Radiology* **47**, 164–170.
- Scaramuzza, Davide, Fraundorfer, Friedrich, Pollefeys, Marc, & Siegwart, Roland. 2009. Absolute scale in structure from motion from a single vehicle mounted camera by exploiting nonholonomic constraints. *Pages 1413–1419 of: Computer Vision, 2009 IEEE 12th International Conference on*. IEEE.
- Scharstein, Daniel. 1999. *View synthesis using stereo vision*. Berlin, Heidelberg: Springer-Verlag.
- Scharstein, Daniel, & Pal, Chris. 2007. Learning conditional random fields for stereo. *Pages 1–8 of: Computer Vision and Pattern Recognition, 2007. CVPR'07. IEEE Conference on*. IEEE.
- Scharstein, Daniel, & Szeliski, Richard. 2002. A taxonomy and evaluation of dense two-frame stereo correspondence algorithms. *International journal of computer vision*, **47**(1-3), 7–42.
- Scharstein, Daniel, & Szeliski, Richard. 2003. High-accuracy stereo depth maps using structured light. *Pages I–I of: Computer Vision and Pattern Recognition, 2003. Proceedings. 2003 IEEE Computer Society Conference on*, vol. 1. IEEE.
- Scharstein, Daniel, Hirschmüller, Heiko, Kitajima, York, Krathwohl, Greg, Nešić, Nera, Wang, Xi, & Westling, Porter. 2014. High-resolution stereo datasets with subpixel-accurate ground truth. *Pages 31–42 of: German Conference on Pattern Recognition*. Springer.
- Schlick, Christophe. 1994. An Inexpensive BRDF Model for Physically-based Rendering. *Pages 233–246 of: Computer graphics forum*, vol. 13. Wiley Online Library.
- Schmalz, Christoph, Forster, Frank, Schick, Anton, & Angelopoulou, Elli. 2012. An endoscopic 3D scanner based on structured light. *Medical Image Analysis*, **16**(5), 1063 – 1072.
- Schollmeyer, Manfred, & Schollmeyer, Thoralf. 2001. *Georg Kelling und die sächsischen Wurzeln der Laparoskopie: 100 Jahre Laparoskopie (1901-2001)*. Verein Oschatzer Frauenärzte.
- Schroff, F., Criminisi, A., & Zisserman, A. 2008. Object Class Segmentation using Random Forests. 54.1–54.10. doi:10.5244/C.22.54.

- Shi, Hongjian. 2007. *Finite element modeling of soft tissue deformation*. University of Louisville.
- Sobel, Irwin, & Feldman, Gary. 1968. A 3x3 isotropic gradient operator for image processing. *a talk at the Stanford Artificial Project in*, 271–272.
- Soper, Nathaniel J, Swanström, Lee L, & Eubanks, Steve. 2008. *Mastery of endoscopic and laparoscopic surgery*. Lippincott Williams & Wilkins.
- Stefansic, James D, Herline, Alan J, Shyr, Yu, Chapman, William C, Fitzpatrick, J Michael, Dawant, Benoit M, & Galloway, Robert L. 2002. Registration of physical space to laparoscopic image space for use in minimally invasive hepatic surgery. *Pages 12–pp of: Biomedical Imaging, 2002. 5th IEEE EMBS International Summer School on*. IEEE.
- Stoyanov, Danail, Scarzanella, Marco Visentini, Pratt, Philip, & Yang, Guang-Zhong. 2010. Real-time stereo reconstruction in robotically assisted minimally invasive surgery. *Pages 275–282 of: International Conference on Medical Image Computing and Computer-Assisted Intervention*. Springer.
- Su, Li-Ming, Vagvolgyi, Balazs P, Agarwal, Rahul, Reiley, Carol E, Taylor, Russell H, & Hager, Gregory D. 2009. Augmented reality during robot-assisted laparoscopic partial nephrectomy: toward real-time 3D-CT to stereoscopic video registration. *Urology*, **73**(4), 896–900.
- Sural, Shamik, Qian, Gang, & Pramanik, Sakti. 2002. Segmentation and histogram generation using the HSV color space for image retrieval. *Pages II–II of: Image Processing. 2002. Proceedings. 2002 International Conference on*, vol. 2. IEEE.
- Suwelack, Stefan. 2015. *Real-time biomechanical modeling for intraoperative soft tissue registration*. KIT Scientific Publishing.
- Suwelack, Stefan, Röhl, Sebastian, Bodenstedt, Sebastian, Reichard, Daniel, Dillmann, Rüdiger, dos Santos, Thiago, Maier-Hein, Lena, Wagner, Martin, Wünsch, Josephine, Kenngott, Hannes, Müller, Beat P., & Speidel, Stefanie. 2014. Physics-based shape matching for intraoperative image guidance. *Medical Physics*, **41**(11), 111901–n/a. 111901.
- Teber, Dogu, Guven, Selcuk, Simpfendorfer, Tobias, Baumhauer, Mathias, Güven, Esref Oguz, Yencilek, Faruk, Gözen, Ali Serdar, & Rassweiler, Jens. 2009. Augmented reality: a new tool to improve surgical accuracy during laparoscopic partial nephrectomy? Preliminary in vitro and in vivo results. *European urology*, **56**(2), 332–338.
- Theano Development Team. 2016. Theano: A Python framework for fast computation of mathematical expressions. *arXiv e-prints*, **abs/1605.02688**(May).
- Thrun, Sebastian, *et al.* 2002. Robotic mapping: A survey. *Exploring artificial intelligence in the new millennium*, **1**, 1–35.

- Totz, Johannes, Thompson, Stephen, Stoyanov, Danail, Gurusamy, Kurinchi, Davidson, Brian R., Hawkes, David J., & Clarkson, Matthew J. 2014. *Fast Semi-dense Surface Reconstruction from Stereoscopic Video in Laparoscopic Surgery*. Cham: Springer International Publishing. Pages 206–215.
- van der Putten, E. P. Westebring –, Goossens, R. H. M., Jakimowicz, J. J., & Dankelman, J. 2008. Haptics in minimally invasive surgery – a review. *Minimally Invasive Therapy & Allied Technologies*, **17**(1), 3–16.
- Weiss, Martin. 2017. *Bachelorarbeit: Stereoskopische Simulation eines chirurgischen Eingriffs*. IAR Dillmann, Karlsruhe Institute of Technology.
- Weißbach, Wolfgang, Dahms, Michael, & Jaroschek, Christoph. 2015. *Werkstoffkunde - Strukturen, Eigenschaften, Prüfung*. Springer-Verlag.
- Wolf, Ivo, Vetter, Marcus, Wegner, Ingmar, Böttger, Thomas, Nolden, Marco, Schöbinger, Max, Hastenteufel, Mark, Kunert, Tobias, & Meinzer, Hans-Peter. 2005. The medical imaging interaction toolkit. *Medical image analysis*, **9**(6), 594–604.
- Yeh, Wen-Chun, Li, Pai-Chi, Jeng, Young-Ming, Hsu, Hey-Chi, Kuo, Po-Ling, Li, Meng-Lin, Yang, Pei-Ming, & Lee, Po Huang. 2002. Elastic Modulus Measurement of Human Liver and Correlation with Pathology. *Ultrasound in Medicine & Biology*, **28**, 467–474.
- Zhang, Zhengyou. 2000. A flexible new technique for camera calibration. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, **22**(11), 1330–1334.
- Zhang, Zhengyou. 2012. Microsoft kinect sensor and its effect. *IEEE multimedia*, **19**(2), 4–10.
- Zijlmans, Mariken, Langø, Thomas, Hofstad, Erlend Fagertun, Van Swol, Christiaan FP, & Rethy, Anna. 2012. Navigated laparoscopy–liver shift and deformation due to pneumoperitoneum in an animal model. *Minimally Invasive Therapy & Allied Technologies*, **21**(3), 241–248.
- Zittel, RX, & Beck, K. 1963. Die Bedeutung der Laparoskopie in der Chirurgie. *DMW-Deutsche Medizinische Wochenschrift*, **88**(41), 1999–2006.