

Innovative Prozeßführung in der thermischen Abfallbehandlung mit Künstlichen Neuronalen Netzen

Zur Erlangung des akademischen Grades eines
Doktors der Ingenieurwissenschaften
von der Fakultät Maschinenbau der
Universität Karlsruhe (TH)

genehmigte
Dissertation

von
Dipl.- Inform. Bernd Müller
aus Brake

Tag der
mündlichen Prüfung: 25.07.2000

Hauptreferent: Prof. Dr.- Ing. habil. Georg Bretthauer
Korreferent: Prof. Dr.- Ing. habil. Jürgen Wernstedt

Inhalt

	Abbildungsverzeichnis	IV
1	Einführung	1
1.1	Bedeutung der Prozeßführung in der thermischen Abfallbehandlung.....	2
1.2	Darstellung des Entwicklungsstandes.....	5
1.3	Ziele und Inhalt dieser Arbeit	10
2	Anlagen- und Systembeschreibung.....	13
2.1	Aufbau einer Müllverbrennungsanlage.....	13
2.2	Verbrennung	20
2.2.1	Abbrand eines Partikels	20
2.2.2	Verbrennung auf dem Rost	22
2.2.3	Einfluß der Stellgrößen auf die Verbrennung.....	26
2.2.4	Reaktionen zur NO-Bildung	29
2.3	Regelung	30
3	Methodik zur Modellierung und Simulation des Müllverbrennungsprozesses mit Künstlichen Neuronalen Netzen	33
3.1	Auswahl und Repräsentation der Meßdaten	34
3.1.1	Erfassung der Meßdaten	34
3.1.2	Auswahl relevanter Eingabeparameter	34
3.1.3	Abschätzung der Modellordnung.....	42
3.2	Ermittlung nichtlinearer Modelle.....	47
3.2.1	Typen nichtlinearer Modelle.....	48
3.2.2	Auswahl eines geeigneten Netztyps.....	49
3.3	Modellierung mit Multilayer Perceptrons.....	51
3.3.1	Training von Multilayer Perceptrons	52
3.3.2	Repräsentation der Daten für die nichtlineare Modellierung	56
3.4	Modellierung mit Netzen mit Radialen Basisfunktionen.....	62
3.4.1	Machbarkeitsstudie zum Einsatz von RBF – Netzen.....	63
3.4.2	Training der RBF-Netze.....	70
3.5	Simulation	71
3.5.1	Simulationsergebnisse.....	73
3.5.2	Anmerkungen zur Validität des Modells	77
3.6	Ergebnisse und Schlußfolgerungen.....	78
4	Prozeßregelung von Müllverbrennungsanlagen mit Künstlichen Neuronalen Netzen...79	

4.1	Einschränkungen durch die Anlagenfahrweise.....	80
4.2	Statische Stellgrößengewinnung.....	81
4.2.1	Gewinnung der Stellgrößen durch systematische Suche	83
4.2.2	Gewinnung der Stellgrößen durch Rückpropagierung durch das Anlagenmodell.....	83
4.2.3	Experimenteller Vergleich Stellgrößenerzeugung.....	85
4.2.4	Anwendung der statischen Stellgrößengewinnung auf die Regelung eines inversen Pendels.....	87
4.2.5	Anwendung der statischen Stellgrößengewinnung auf das Prozeßmodell der Müllverbrennung.....	91
4.3	Prozeßregelung mit optimaler Stellgrößenvorgabe.....	93
4.3.1	Bestimmung einer optimalen Handlungssequenz	94
4.3.2	Algorithmische Optimierung	97
4.3.3	Bestimmung eines Vertrauensindexes	101
4.4	Experimentelle Ergebnisse.....	102
4.4.1	Ergebnisse im open-loop Betrieb.....	102
4.4.2	Ergebnisse im closed loop Betrieb.....	104
4.5	Rechentechnische Realisierung	106
4.5.1	System zur Prozeßführung der Anlage 1	106
4.5.2	System zur Prozeßführung der Anlage 2 (INSPECT).....	108
4.6	Zusammenfassung.....	111
5	Gewinnung von Prozeßgrößen mit Infrarot-Thermographie zur Unterstützung der Prozeßführung.....	113
5.1	Motivation.....	113
5.2	Wärmestrahlung und Infrarotmessung.....	116
5.2.1	Eigenschaften der Wärmestrahlung	116
5.2.2	Aufzeichnen der Verbrennung mit Infrarot-Thermographie.....	119
5.2.3	Einbau der Meßblanze	119
5.3	Merkmalsextraktion aus Infrarotbildern und Meßdaten	121
5.3.1	Bildentzerrung.....	121
5.3.2	Erstellung der raum-zeitlichen Emissionsprofile.....	125
5.3.3	Erstellung von raum-zeitlichen Profilen der Primärluft.....	126
5.3.4	Modellierung der Emissionen als Funktion der Primärluftzufuhr	128
5.4	Zuweisung der Merkmale zu Emissionen	132

5.4.1	Training des Künstlichen Neuronalen Netzes	132
5.4.2	Einsatz von RBF-Netzen	134
5.5	Schlußfolgerung und Ausblick	136
6	Zusammenfassung.....	139
7	Literatur	141
8	Anhang.....	151
8.1	Parameterbeschreibung Anlage 1	151
8.2	Parameterbeschreibung Anlage 2	152
8.3	Modellbildung der Anlage 2	154
8.4	Simulationen der Anlage 2.....	156
8.5	Einschränkungen der Anlagenfahrweise bei Anlage 1	157
8.6	Open Loop Steuerung der Anlage 1.....	158
9	Index.....	163

Abbildungsverzeichnis

Abbildung 2.1:	Seitenansicht des Kessels einer Müllverbrennungsanlage	14
Abbildung 2.2:	Beschickung, Rost und Feuerraum einer Müllverbrennungsanlage	15
Abbildung 2.3:	Roststab Luftführung	16
Abbildung 2.4:	Drei Feuerraumtypen	18
Abbildung 2.5:	Rauchgasreinigung einer Müllverbrennungsanlage.....	18
Abbildung 2.6:	Dampferzeugung, integriert in den Feuerraum.....	19
Abbildung 2.7:	Gaszusammensetzung in einem homogenen Gutbett.....	24
Abbildung 2.8:	Schematische Darstellung der Reaktionsvorgänge im Gutbett einer Rostfeuerung	25
Abbildung 2.9:	Brennbettprofil bei unterschiedlicher Luftzufuhr.....	27
Abbildung 2.10:	O ₂ , CO - und Temperaturverlauf bei der kalten Verbrennung.....	29
Abbildung 3.1:	Autokorrelationsmatrix der Prozeßparameter.....	36
Abbildung 3.2:	Varianz der transformierten Daten in Abhängigkeit der Dimension des Bildraums	38
Abbildung 3.3:	Vergleich von HKA-Kompression zweier verschiedener Kompressionsfaktoren	39
Abbildung 3.4:	Korrelation zwischen Datensätzen. Das Diagramm zeigt die Summe der Korrelationen anhand der Einträge in die Korrelationsmatrix.	42
Abbildung 3.5:	Grafische Darstellung der Matrixkoeffizienten von Matrix A	46
Abbildung 3.6:	Grafische Darstellung der Matrixkoeffizienten von Matrix A2	46
Abbildung 3.7:	Differenz der Matrizen A und A2.....	47
Abbildung 3.8:	Aufbau eines Multilayer-Perceptrons mit einer verdeckten Schicht und sigmoider Aktivierungsfunktion.. ..	51
Abbildung 3.9:	Durchschnittsfehler und Varianz des Fehlers beim Trainieren von 300 Netzen mit Standard-Backpropagation.	54
Abbildung 3.10:	Durchschnittsfehler und Varianz des Fehlers beim Trainieren von 300 Netzen mit Rprop.	54
Abbildung 3.11:	Schema eines zweischichtigen Netzes mit einer nichtlinearen Ausgabeschicht	55
Abbildung 3.12:	Struktur eines RBF-Netzes.....	63
Abbildung 3.13:	Varianz in Abhängigkeit der Kompressionsrate.....	64
Abbildung 3.14:	Zwei topologisch benachbarte Neuronen eines Kohonennetzes.....	65

Abbildung 3.15:	Netz bei konvergentem Training und Netz mit topologischem Defekt	66
Abbildung 3.16:	Kohonen Subnetz mit sortierter Initialisierung der Gewichte nach Beenden der Lernphase.....	68
Abbildung 3.17:	Schematische Darstellung der lokalen linearen Approximierung von Eingabedaten durch Neuronen eines Kohonennetzes.....	69
Abbildung 3.18:	Fehler der Trainings- und Validierungsdaten in Abhängigkeit des Parameters σ	71
Abbildung 3.19:	Paralleles Modell.	72
Abbildung 3.20:	Serien-Parallelmodell.....	72
Abbildung 3.21:	CO-Gehalt und Simulation.....	73
Abbildung 3.22:	O ₂ -Gehalt und Simulation.....	74
Abbildung 3.23:	Dampfmenge und Simulation	74
Abbildung 3.24:	Rauchgastemperatur 1 und Simulation	75
Abbildung 3.25:	Rauchgastemperatur 2 und Simulation	75
Abbildung 3.26:	Rauchgastemperatur 3 und Simulation	76
Abbildung 3.27:	Fehler in Abhängigkeit des Prädiktionshorizonts.....	77
Abbildung 4.1:	Stellgrößengewinnung durch Rückpropagierung durch das Anlagenmodell	82
Abbildung 4.2:	Rückpropagierung der verbesserten Schätzwerte für die Stellgrößen.	85
Abbildung 4.3:	Fehlerfunktion in Abhängigkeit zweier Gewichte.....	86
Abbildung 4.4:	Inverses Pendel. Die Kraft F bewegt den Wagen, um den Stab in aufrechter Position zu halten.....	87
Abbildung 4.5:	Konfiguration der Regelung des inversen Pendels.....	89
Abbildung 4.6:	Darstellung des Winkels φ des Systems.	89
Abbildung 4.7:	Darstellung der Stabausrichtung φ des Systems.	90
Abbildung 4.8:	Konfiguration der Regelung des Anlagenmodells.....	91
Abbildung 4.9:	Meßdaten (links) und Simulationsergebnisse unter Verwendung statischer Stellgrößengewinnung.	92
Abbildung 4.10:	Aufbau einer modellprädiktiven Regelung.....	93
Abbildung 4.11:	Schematische Darstellung des Versuchs der Bestimmung einer geeigneten Referenztrajektorie.....	94
Abbildung 4.12:	Verlauf des Pendels bei Referenzmodellvorgabe.	95
Abbildung 4.13:	Verlauf des Pendels bei Einsatz der Suchstrategie für optimierte Handlungssequenz	96

Abbildung 4.14:	Verteilung der Minimalabstände der Validierungsdaten zu den Trainingsdaten	102
Abbildung 4.15:	Meßdaten (links) und Simulation der Prozeßgrößen (rechts) im open-loop Betrieb.....	103
Abbildung 4.16:	Führungsgrößen und Stellgrößen des realen Prozeßverlaufs.....	104
Abbildung 4.17:	Closed Loop Simulation mit den Koeffizienten $(j_1, j_2, j_3) = (1, 0, 0)$	104
Abbildung 4.18:	Closed Loop Simulation mit den Koeffizienten $(j_1, j_2, j_3) = (1, 1, 0)$	105
Abbildung 4.19:	Closed Loop Simulation mit den Koeffizienten $(j_1, j_2, j_3) = (1, 1, 1)$	105
Abbildung 4.20:	Zusammenspiel der einzelnen Komponenten	107
Abbildung 4.21:	Benutzerschnittstelle zu Simulation und Regelung	108
Abbildung 4.22:	Schematischer Aufbau des INSPECT Systems	109
Abbildung 4.23:	Konfiguration von INSPECT mit loser Kopplung von Komponenten.....	111
Abbildung 5.1:	Emissionsprofile von Müll für verschiedene Arten von Abfällen.....	115
Abbildung 5.2:	Emissionskurven eines schwarzen Körpers bei verschiedenen Temperaturen.	117
Abbildung 5.3:	Meßblanze mit eingebauter Infrarotkamera.....	120
Abbildung 5.4:	Einbau der Meßblanze	120
Abbildung 5.5:	Leerer Feuerraum.....	122
Abbildung 5.6:	Feuerraum mit Rostbegrenzungen	122
Abbildung 5.7:	Koordinatensystem des entzerrten Bildes.....	123
Abbildung 5.8:	Entzerrtes Bild des Verbrennungsrostes.....	125
Abbildung 5.9:	Schematischer Aufbau des Verbrennungsrostes bzgl. seiner steuerbaren Zonen.	125
Abbildung 5.10:	Schematische Verlauf einer Müllfraktion auf der linken Rosthälfte über die Zeit (schwarzer Pfeil).....	126
Abbildung 5.11:	Primärluftverteilung, interpoliert durch die vier Luftversorgungen pro Rosthälfte	127
Abbildung 5.12:	Profil der Luftzufuhr	127
Abbildung 5.13:	Zusammenhang zwischen Luftmenge und Massenumsatzrate bei der Verbrennung von Koks.....	128
Abbildung 5.14:	Entzerrung der Emissionen durch Normalisieren der aufgenommenen Luftmenge	130
Abbildung 5.15:	Thermische Emissionen der linken Rosthälfte.	131
Abbildung 5.16:	Thermische Emissionen normalisiert durch die Müllmenge.	131

Abbildung 5.17:	Zwei Neuronen eines Counterpropagation Netzes	132
Abbildung 5.18:	Ausgabe des Counterpropagation Netzes	133
Abbildung 5.19:	Tatsächliche Emissionen und Schätzung des Counterpropagation Netzes.	134
Abbildung 5.20:	Netzausgabe des RBF-Netzes	135
Abbildung 5.21:	Über ein RBF-Netz errechnete Emissionen zu tatsächlichen Emissionen .	136
Abbildung 5.22:	Integration der Infrarot-Thermographie in das Regelungskonzept.....	138
Abbildung 8.1:	Kreuzkorrelationen der Meßdaten von Anlage 2.....	154
Abbildung 8.2:	Systemmatrix von Datensatz 1.....	154
Abbildung 8.3:	Systemmatrix von Datensatz 2.....	155
Abbildung 8.4:	Differenz der Systemmatrizen	155
Abbildung 8.5:	Simulation der Zustandsgrößen der Anlage 2.....	157
Abbildung 8.6:	Das Öffnen der Luftklappen durch das Prozeßleitsystem [in %].	159
Abbildung 8.7:	Antrieb des Aufgaberosts und des Verbrennungsrosts durch das Prozeßleitsystem.	159
Abbildung 8.8:	Luftklappen, errechnet von der prädiktiven Regelung	160
Abbildung 8.9:	Die Antriebe von Aufgabe- und Verbrennungsrost, errechnet von der prädiktiven Regelung	160
Abbildung 8.10:	Dampfmenge; realer Wert des Prozeßleitsystems, mittels Simulation abgeleiteter Wert und Dampfsollwert.....	161

1 Einführung

Thermische Abfallbehandlung stellt in der heutigen Zeit eine sehr verbreitete Methode zur Kompaktierung von Hausmüll dar. Diese Form der Abfallbehandlung ist technisch aufwendig, da die bei der Verbrennung entstehenden Schadstoffe über aufwendige Reinigungsverfahren gefiltert und entsorgt werden müssen. Die vorliegende Arbeit soll einen Beitrag zu einer besseren Prozeßführung liefern, um die Entstehung von Schadstoffen zu verringern.

Der Prozeß der Müllverbrennung ist in seiner chemisch-physikalischen Struktur schwer zu beschreiben, und eine explizite mathematische Modellierung ist bislang nicht möglich. Dies und ein weiterer Faktor erschweren die Prozeßführung: Gegenwärtige Prozeßleitsysteme erhalten nicht alle notwendigen Informationen, um den Prozeß optimal führen zu können. Die zeitlich variierende Müllbeschaffenheit ist mit der bestehenden Sensorik in Müllverbrennungsanlagen nicht meßbar, und daher geht der schwankende Heizwert des Mülls als Störgröße in die Regelung ein. Diese Unzulänglichkeiten führen zu einer suboptimalen Prozeßführung und damit zu einer ungleichmäßigen Verbrennung. Die hieraus entstehenden Temperaturschwankungen sind z.T. verantwortlich für eine erhöhte Entstehung von Schadstoffen.

Innovative Regelungsverfahren versprechen durch eine bessere Prozeßführung eine Einschränkung der thermischen Schwankungen, und somit eine Einschränkung der Schadstoffentstehung. Mangels einer expliziten mathematischen Modellierung war eine modellbasierte Regelung bislang nicht möglich. Künstliche Neuronale Netze (KNN) bieten aufgrund ihrer Selbstorganisation die Möglichkeit, aufgrund von vorgegebenen Datensätzen ein Black-Box Verhalten zu erlernen, mit dem das Ein/Ausgabeverhalten des Prozesses gegebenenfalls beschrieben werden kann.

Mit einem KNN-basierten Modell kann dann eine Regelung durchgeführt werden, die mit der Vorhersage künftiger Prozeßzustände arbeitet. Dies liefert Vorteile gegenüber der konventionellen Feedback-Regelung.

Um die Beobachtbarkeit des Prozesses zu gewährleisten und den Einfluß von Schwankungen von Müllverbrennungscharakteristiken zu minimieren, wird ein zusätzlicher Sensor eingeführt. Mit einer Infrarotkamera lassen sich thermische Emissionsprofile auf dem Rost anzeigen und hieraus über eine zeitliche Verfolgung des Profils Informationen über die Verbrennungseigenschaften ermitteln. Die Kombination einer modellbasierten Regelung mit einer verbesserten Sensorik liefert ein Prozeßführungssystem, mit dem sich diese Arbeit befaßt.

1.1 Bedeutung der Prozeßführung in der thermischen Abfallbehandlung

Abfallentsorgung ist ein Thema, die ständig an Aktualität gewinnt. Durch den Anstieg der industriellen Produktion wird das Problem der Entsorgung der dabei entstehenden Abfälle immer größer. Angestoßen durch die Industrialisierung wuchs die chemische Industrie, und somit wuchs auch die in den Produktions-Konsum-Zyklus eingebrachte Müllmenge.

Bis ins 19. Jahrhundert wurden Abfälle auf speziell vorgesehenen Gebieten deponiert. Aber mit der industriellen Revolution und der damit verbundenen Ballung von Lebensräumen mußten hygienischere Alternativen der Entsorgung gefunden werden. In Paddington (England) wurde daraufhin 1870 die erste Abfallverbrennungsanlage in einem speziellen Ofenhaus errichtet. Unter den mehr als 200 Müllverbrennungsanlagen, die in England in der zweiten Hälfte des 19. Jahrhunderts gebaut wurden, galt Manchester als die erste betriebssichere Anlage, die ohne nennenswerte Änderungen bis zum Jahre 1903 in Betrieb blieb. Dabei wurden Durchsatzleistungen von 8-10 t Abfall pro Tag bei Verbrennungstemperaturen von 700-900°C ohne nennenswerte Staub- und Geruchsbelästigungen erreicht und eine harte, glasige Schlacke erzeugt [87]. Die um die Jahrhundertwende geforderte Nutzung der frei werdenden Energie ließ sich in Form von Dampf, Fernwärme und Strom realisieren. Die Anlagen wurden daher relativ stadtnah gebaut, womit sich auch die Anfahrtswege für die Abfallanlieferung kurz halten ließen.

Die Entwicklung der Abfallverbrennung führte in den 30er Jahren zu einer weitgehenden kontinuierlichen Fahrweise mit Beschickung, Verbrennung und Entschlackung in geschlossenen Verbrennungsöfen.

Im zweiten Weltkrieg wurden in Deutschland viele dieser Anlagen zerstört. Das Fehlen ausreichender Verbrennungskapazität hat sich besonders in den 50er und 60er Jahren in Form von wilden Deponien in Deutschland bemerkbar gemacht, worauf der Bau neuer Verbrennungsanlagen wieder einsetzte.

In den 70er Jahren entstand ein Bewußtsein für eine nachhaltige Entsorgung, und der Begriff Umweltschutz wurde geprägt [10]. Umweltschützer verlangten eine drastische Begrenzung sichtbarer und unsichtbarer Emissionen in Luft, Wasser und Boden. Einige maßgebliche Regelungen sind das 1986 entstandene Abfallgesetz (AbfG), die Technische Anleitung zur Reinhaltung der Luft (TA Luft), die 17. Verordnung zum Bundesemissionsschutzgesetz zur Emissionsminimierung von Abfallverbrennungsanlagen (17. BLMschV vom 1. 12.1990) mit der erstmaligen Festlegung eines Dioxingrenzwertes von 0.1 ng/m³. Für die Deponierung von Reststoffen ist die Technische Anleitung Siedlungsabfall herausgekommen, die Richtlinien bzgl. der Qualität von Deponiegut vorgibt. Diese Richtlinien sind gegenwärtig und in Zukunft von den Anlagebetreibern einzuhalten.

Ziel ist es jedoch, das Abfallproblem schon im Ansatz anzugehen. Die Basis moderner, zukunftsorientierter Abfallwirtschaftskonzepte besteht somit im Vermeiden, Vermindern und Verwerten von Abfällen. Trotzdem verbleiben immer Reststoffe, die zu entsorgen sind. Restmüll ist in eine ökologisch unbedenkliche Form zu überführen, d.h. er muß chemisch möglichst inert gemacht werden, um dann kompaktiert auf einer Deponie abzulagern. Somit müssen die im Müll enthaltenen toxischen Stoffe entweder zerstört, oder vom Müll getrennt werden (z.B.Schwermetalle).

Für die Behandlung des Restmülls leistet die Müllverbrennung einen wichtigen Beitrag. Das Volumen wird bei der Verbrennung reduziert (bei Hausmüll um ca 80-90 %), das Material wird inertisiert und Schadstoffe (Schwermetalle, Halogene etc.) werden getrennt. Der Heizwert des Mülls wird zur Energieerzeugung genutzt.

Die verbleibende Schlacke kann als Wertstoff im Straßenbau verwendet werden. Die wichtigsten Systeme, die zur thermischen Abfallbehandlung herangezogen werden, sind Rostfeuerung, Wirbelschichtfeuerung und Drehrohröfen. In der Markteinführung sind Thermoselect [95] und das Schwel-Brennverfahren [12].

Für die Verbrennung von Hausmüll, hausmüllähnlichem Gewerbemüll und Sperrmüll hat sich die Rostfeuerung durchgesetzt.

1993 betrug die in den alten Bundesländern aus dem öffentlichen und privaten Sektor sowie aus Handel und produzierendem Gewerbe anfallenden hausmüllähnlichen Restabfallmenge 25-30 Mio. t. Davon wurden 9 Mio. t in 47 Müllverbrennungsanlagen thermisch behandelt [88].

Gegenwärtig sind in Deutschland 53 Müllverbrennungsanlagen mit einer Jahreskapazität von ca. 12 Millionen t in Betrieb. Im Bau oder im Genehmigungsverfahren befinden sich weitere 13 Anlagen. Um von 2005 an die Anforderungen der Technischen Anleitung Siedlungsabfall erfüllen zu können, reichen diese Kapazitäten nicht aus. Es müssen weitere thermische Behandlungsanlagen gebaut werden [36].

Durch die Verbrennung wird der auf dem Rost befindliche Müll chemisch reduziert, und die Schadstoffe werden in Form von Flugstäuben und Rauchgas extrahiert. Die in den Flugstäuben und im Rauchgas enthaltenen Schadstoffe müssen gesammelt werden, um in konzentrierter Form entsorgt werden zu können, was mit hohem technischen und finanziellem Aufwand verbunden ist.

Neben diesen sogenannten sekundären Maßnahmen der Rauchgasreinigung können durch geeignete Maßnahmen Schadstoffe in der Entstehung vermieden werden (primäre Maßnahmen).

Hierzu gibt es viele verfahrenstechnische Verbesserungen. Tabelle 1 zeigt das Verbesserungspotential verschiedener primärer und sekundärer Maßnahmen.

Primärmaßnahmen

<i>Maßnahmen</i>	<i>Reduktionspotential</i>	<i>Technische Reife</i>
Homogenisierung des Brennguts	bis etwa 20%	Stand der Technik
Rauchgasrückführung	bis etwa 20%	Stand der Technik
Stufung und Regelung der Luftzugabe	bis etwa 20%	Stand der Technik

Sekundärmaßnahmen

<i>Maßnahmen</i>	<i>Reduktionspotential</i>	<i>Technische Reife</i>
Selektive nichtkatalytische Reduktion (SNCR)	bis etwa 80%	Stand der Technik
Selektive katalytische Reduktion (SCR)	bis etwa 90%	Stand der Technik
Aktivkoksverfahren	bis etwa 60%	in Erprobung
Naßverfahren	bis etwa 70%	in Erprobung

Tabelle 1.1: *Primär und Sekundärmaßnahmen zur NO_x Reduktion [99]*

Während früher eine maximale Durchsatzrate (und eine maximale Energieausbeute) das Optimierungskriterium war, ist es heute zunehmend eine geringe Schadstoffentstehung.

Auch eine ungleichmäßige Prozeßfahrweise führt zur Entstehung von Schadstoffen. So entstehen durch Temperaturspitzen thermische Stickoxide, und unterstöchiometrische Verbrennung erzeugt freie Radikale, die direkt und indirekt an der Entstehung von Stickoxiden teilhaben [48].

Somit ist eine gleichmäßige Fahrweise des Prozesses für eine verminderte Schadstoffentstehung wünschenswert. Abgesehen vom ökologischen Aspekt bringt eine gleichmäßige Fahrweise auch Vorteile ökonomischer Art:

- Durch eine gleichmäßige Fahrweise verminderte Schadstoffentstehung führt zu einem verminderten Einsatz der Rauchgasreinigung, damit zu einem seltenerem Auswechseln der Filterstoffe und somit zu weniger Schadstoffen in der Entsorgung.

- Das durch die Fahrweise erzeugte gleichmäßige Temperaturprofil führt zu einer geringeren Belastung der Anlagenkomponenten (z.B. Rostbelag) so daß die Lebensdauer einzelner Komponenten erhöht wird und hieraus geringere Wartungs- und Reparaturkosten resultieren.
- Primäre Maßnahmen bilden zudem (von den Entwicklungskosten abgesehen) eine kostengünstige Variante in der Nachrüstung zum Zweck der Anlagenverbesserung, da verfahrenstechnische Eingriffe (in Form von Baumaßnahmen) individuell für den Anlagentyp entwickelt werden müssen.

Fazit: Thermische Abfallbehandlung und insbesondere Rostfeuerung stellen heute und in Zukunft eine wichtige Methode zur Restmüllkompaktierung dar.

Die auch europaweit immer strenger werdenden Gesetze fordern eine verstärkte Schadstoffverminderung. Diese kann u.a. durch primäre Maßnahmen erreicht werden, wobei sich außerdem ein ökonomischer Vorteil für die Anlagenbetreiber ergibt.

1.2 Darstellung des Entwicklungsstandes

Neben verfahrenstechnischen Verbesserungen aus Tabelle 1 wurden folgende primäre Maßnahmen zur Schadstoffverringerung implementiert:

Beim **Syncom-Verfahren** (Kurzform für "Synthetic Combustion", engl. für künstliche Verbrennung) wird der natürliche Sauerstoffgehalt der Luft (21%) durch Zuführen von Sauerstoff künstlich erhöht. Bei 28 bis 35 % Sauerstoff in der Verbrennungsluft brennt der Müll heißer und vollständiger aus. Von unten wird der Sauerstoff in den Mittelbereich des Rostes eingeblasen. Wann und wohin Sauerstoff zugegeben wird, wird durch einen Rechner mit einer Infrarot-Kamera festgelegt. Die temperaturunempfindliche Kamera an der Decke des Ofens erfaßt, wo die Glut auf dem Rost hell bzw. dunkel ist. Aus dieser Information ergibt sich, an welcher Stelle der Sauerstoff hineingeblasen werden muß, damit eine gleichmäßige hohe Temperatur erreicht wird [99]. Die Zugabe von Sauerstoff macht dieses Verfahren für herkömmlichen Hausmüll recht teuer.

Das **Noell-Konversionsverfahren** wurde entwickelt, um auch bei strengsten Emissionsgrenzwerten und nahezu vollständiger Verwertung der Reststoffe eine sichere Entsorgung von Müll und Klärschlamm zu gewährleisten. Bei diesem Prozeß werden Abfallstoffe nach einem Pyrolyseschritt unter erhöhtem Druck und hohen Temperaturen vergast. Dadurch wird die Bildung von Dioxinen und Furanen unterdrückt und auch die in Abfallstoffen bereits enthaltenen Di-

oxine und Furane zerstört. Ein weiterer Vorteil beim Noell-Konversionsverfahren ist die Erzeugung von vermarktbareren Wertstoffen (Synthesegas, verglaste Schlacke, Schwefel, Eisen und Nichteisenmetalle [99]). Aber auch das Noell-Konversionsverfahren ist aufgrund des verfahrenstechnischen Aufwandes zur Verwertung von Hausmüll nicht rentabel.

Andere primäre Maßnahmen betreffen die Regelung des Verbrennungsprozesses. Zur Regelung der Rostfeuerung sind folgende Prozeßparameter relevant: Dampfmenge, O₂-Gehalt im Rauchgas, und CO-Gehalt im Rauchgas. Die Regelung wird erschwert durch die Prozeßdynamik, die Totzeit (Änderungen der Müllaufgabe wirken sich erst nach frühestens zehn Minuten auf die Feuerung aus) und die Störgrößen, die sich durch die Heterogenität und den damit verbundenen Heizwertschwankungen äußern.

Es gibt prinzipiell zwei Arten der Regelung:

- Festlastregelung
- Verbrennungsluftregelung.

Bei der **Festlastregelung** wird die Luftzufuhr konstant gehalten und eventuelle Verbrennungsschwankungen durch die Müllbeschickung und den Vorschubrost geregelt. Dies sorgt für einen relativ konstanten Durchsatz der Anlage, aber durch die verzögerte Reaktion auf eine Änderung der Beschickung können kurzfristige Schwankungen in der Dampferzeugung auftreten, die durch Variationen der Vorschubrostgeschwindigkeit ausgeglichen werden müssen. Hierbei sollte der Vorschubrost mit einer starken Schürwirkung versehen sein. Die produzierende Dampfmenge wird als fester Sollwert (Festlast) vorgegeben.

Bei der **Verbrennungsluftregelung** wird die Müllbeschickung konstant gehalten, die Primär- und Sekundärluftzufuhr sorgen für ein schnelles Ausgleichen der Dampferzeugung.

In der thermischen Abfallbehandlung kommen diverse Varianten dieser beiden Methoden auch in Kombination zum Einsatz. In der Regel wird jedoch auf eine multivariate Regelung verzichtet, und einzelne Regelkreise werden voneinander entkoppelt.

In den letzten Jahren hat sich Fuzzy-Logik in der industriellen Anwendung bewährt ([1],[53],[9],[65],[39]). Bisher wird jedoch speziell im Bereich der industriellen Automatisierung an konventionellen, bewährten Konzepten festgehalten. Für Regelungsaufgaben werden meist Zweipunkt- oder PID-Regler eingesetzt. Wenn der Prozeß in einem stabilen Zustand ist, arbeiten PID-Regler meist zufriedenstellend, mangelhaft jedoch in den folgenden Fällen:

- starke Störungen

- zeitabhängige Prozeßparameter
- große Totzeiten.

Ursache hierfür ist, daß ein PID-Regler für ein lineares Prozeßverhalten ausgelegt ist. In einem stabilen Arbeitspunkt gilt diese Vereinfachung oft, aber starke Störungen können den Prozeßzustand weit von dem Arbeitspunkt wegbewegen. Dann gelten die Vereinfachungen eines linearen Prozeßmodells nicht mehr. Dasselbe passiert, wenn sich die Prozeßparameter über die Zeit ändern. In diesen Fällen hat sich gezeigt, daß durch die Ergänzung des PID-Reglers mit Fuzzy-Logik oder dessen Ersatz durch Fuzzy-Logik eine Verbesserung erzielt werden kann [57] [81]. Der Entwurf und die Implementierung eines Fuzzy-Reglers sind hierbei in der Regel einfacher und intuitiver als andere Alternativen wie Zustandsregler oder adaptive Regler.

Ein Problem bei der Regelung von Müllverbrennungsanlagen ist das Fehlen einer für die meisten Regelungsverfahren notwendigen analytischen Regelstreckenbeschreibung. Die physikalischen und chemischen Vorgänge bei der Verbrennung sind zwar bekannt, so daß qualitative Aussagen über das Zusammenspiel einzelner Stell- und Zustandsgrößen getroffen werden können. Von der Kenntnis der Parameter einer Anlage unabhängige, quantitative Aussagen lassen sich jedoch nicht treffen, und die Ermittlung der exakten Übertragungsfunktion von Brennraum, Kessel und Rost für jede Anlage ist sehr aufwendig.

Ist aber ein Modell gefunden, so läßt es sich für eine modellbasierte prädiktive Regelung verwenden. Eine modellbasierte prädiktive Regelung bietet folgende Vorteile:

- Durch die Existenz eines Prozeßmodells wird die Prozeßdynamik in die Regelung mit einbezogen.
- Störungen können in einem zeitlichen Horizont beseitigt werden.
- Durch das Betrachten eines zeitlichen Horizonts können unzulässige Prozeßzustände umgangen werden

Modellbasierte prädiktive Regelungen wurden bereits auf verschiedenen technischen Anlagen wie Raffinerien, chemischen Anlagen und in der Papierindustrie angewendet [84][85].

Die hohe Leistungsfähigkeit heutiger Computer ermöglicht die Erforschung neuartiger Problemlösungsstrategien. Als ein Ableger der Künstlichen Intelligenz ist die Computational Intelligence (CI) ein Feld, das aus neuartigen Verfahren zur rechnerischen Lösung von Problemen gegenüber konventionellen Verfahren neue Möglichkeiten bietet [43][67][45][102]. Unter CI fallen die Methoden Fuzzy-Logik, Künstlichen Neuronale Netze und Evolutionäre Algorithmen, sowie hybride Ansätze dieser Methoden.

Fuzzy-Logik [109] verarbeitet Wissen in unscharfen Regeln. Die Vorgehensweise erfolgt in einem dreistufigen Verfahren: Fuzzyfizierung, Inferenz und Defuzzyfizierung. Anwendungen von Fuzzy-Logik finden sich dort, wo numerische Daten mit einer Regelbasis verarbeitet werden sollen. Der Vorteil von Fuzzy-Logik liegt in der expliziten Repräsentation von Wissen durch Fuzzy-Regeln. Auf diese Art lassen sich mit relativ geringen Aufwand Fuzzy-Regler erstellen, die ein nichtlineares Übertragungsverhalten aufweisen.

Künstliche Neuronale Netze [91][92][59] eignen sich zur Funktionsapproximation und zur Klassifizierung. Sie sind die technische Realisierung biologisch motivierter Modelle der Informationsverarbeitung in Gehirn und Nervensystem. Kennzeichen sind lernfähige, dezentrale, parallele Strukturen aus einfachen informationsverarbeitenden Elementen (Neuronen). Als Alternative zu herkömmlichen Black-Box-Modellen (Wiener/ Hammerstein-Modelle) bieten sie sich außerdem zur Systemidentifikation an [49].

Evolutionäre Algorithmen [2] stellen eine Alternative zu herkömmlichen heuristischen Suchverfahren dar. Es werden Kandidaten einer Problemlösung als Individuen einer Lösungspopulation betrachtet. Die Qualität der Lösungen wird mit einer Fitnessfunktion bewertet und die Lösungspopulation wird daraufhin selektiert. Um neue Kandidaten zu erhalten, werden bestehende Individuen modifiziert. Evolutionäre Strategien[86][94] nutzen als Modifikation einen Mutationsoperator, während die von Holland entwickelten Genetischen Algorithmen [34], Individuen als binäre Zeichenketten (Bitstrings) kodieren und als Veränderungsoperator ein teilweises Austauschen zweier Bitstrings eingesetzt wird (Crossover).

In der vorliegenden Arbeit wird die Prozeßmodellierung durch ein Künstliches Neuronales Netz realisiert. Durch den Einsatz eines nichtlinearen Modells ergibt sich eine verbesserte Übereinstimmung mit dem realen Prozeß. Die Lernfähigkeit KNNs ermöglicht eine Modellierung auf Basis von vorhandenen Trainingsdaten, während eine mathematische Modellierung des Prozesses bislang nicht möglich war.

Dann wird eine modellbasierte prädiktive Regelung mit einem nichtlinearen Modell in Form des KNNs implementiert. Die Bestimmung der optimalen Vorsteuerung kann über lokale Suchstrategien, z.B. Newton Verfahren, Varianten von Gradientenabstiegsverfahren bestimmt werden. Ein Nachteil bei der Suche nach einer optimalen Handlungssequenz liegt bei dem Einsatz nichtlinearer Modelle in der Tatsache, daß die zu minimierende Fehlerfunktion nicht mehr konvex ist. Das absolute Minimum ist also aufgrund der Größe des Suchraums und der Präsenz vieler lokaler Minima nahezu unauffindbar. Zum Einsatz kommen daher oft heuristische Ver-

fahren wie evolutionäre Algorithmen [5], Hooke-Jeeves Verfahren [100] und nichtlineare Least Squares Algorithmen [40][59].

In dieser Arbeit kommt eine Baum-Suchstrategie zum Einsatz, die bezogen auf die Problemstellung echtzeitfähig ist, und deren Lösung nur geringfügig vom Optimum abweicht, da eine Breitensuche durchgeführt wird.

Ergänzend zu einer prädiktiven Regelung kann das Prozeßverhalten durch ein frühzeitiges Erkennen von Störungen (primär in Form von Heizwertschwankungen) verbessert werden. Denn eine weitere Ursache für die starken Schwankungen im Betrieb von Müllverbrennungsanlagen (MVA) ist in der sehr heterogenen Zusammensetzung und den unterschiedlichen Eigenschaften des Brennstoffs Müll begründet. Müll ändert sich ständig bezüglich seiner Dichte und seiner Partikelgröße, so daß aus einem bestimmten, in den Brennraum eingebrachten Müllvolumen nicht auf die eingebrachte Müllmasse geschlossen werden kann. Die Feuchte des Mülls variiert stark, was zu unterschiedlichen Trocknungszeiten führt. Die chemische Zusammensetzung des Mülls hängt in hohem Maße von der jeweiligen Müllfraktion (Sperrmüll, Hausmüll etc.) ab. Aus diesen Gründen ändern sich die für eine vollständige Oxidation des Brennstoffs nötige Sauerstoffmenge sowie die bei der Reaktion freiwerdende Energie und damit die Dampfmenge ständig.

Um genauere Informationen über den Verbrennungszustand zu erhalten, kann die Grundausstattung der Anlage um weitere Sensoren erweitert werden [41]. Hierfür existieren folgende Ansätze:

- In [108] werden **Pyrodetektoren** als zusätzliche Sensoren eingesetzt. Durch einen Vorschubrost, bei dem feldweise Verbrennungsluft, Hubgeschwindigkeit sowie Hublänge und Hubfolge variiert werden können, besteht der Bedarf nach einem Beobachtersystem, das die räumliche Verbrennung aufzeichnet und sich abzeichnende Heizwertschwankungen im Vorfeld sichtbar macht. Hierzu wird eine Matrix aus Pyrodetektoren eingesetzt. Leider sind diese Pyrodetektoren räumlich sehr selektiv, so daß nicht wirklich ein räumliches Profil der Verbrennung aufgezeichnet wird.
- In [62] wird mit einer Infrarotkamera eine Feuerlageregelung durchgeführt. Um aus dem Infrarotbild Größen zur Regelung herzuleiten, werden aus den Bildinformationen zwei Parameter errechnet, mit denen die Position des Feuers auf dem Rost und seine Ausdehnung in Rostlängsrichtung beschrieben werden. Um die ideale Position des Feuers auf dem Rost

zu bewirken, wird die Feuerlage durch die Primärluftverteilung und die Rostgeschwindigkeit geregelt.

- Um einen vollständigen Abbrand des Mülls auf dem Rost zu gewährleisten, wurde am Institut für Angewandte Informatik, (Forschungszentrum Karlsruhe) eine kamerageführte **Ausbrandsteuerung** entwickelt, die unverbranntes Material detektiert und über eine Fuzzy-Regelung die Luftzufuhr der Ausbrandzone individuell regelt [46][47][68][38][51][52]. Somit wird ein hoher Reinheitsgrad der entstehenden Schlacke sichergestellt. Ein Vorteil des System ist die relativ einfache Nachrüstung in bestehende Anlagen, da nur in zwei Punkten in die Anlage eingegriffen wird: Eine Kamera muß installiert werden, und eine Schnittstelle zum Prozeßleitsystem zur Übertragung der Sollwerte für die Luftzufuhr wird benötigt. Eine Beeinträchtigung der Feuerleistungsregelung findet nicht statt.
- Bisher wurden in [13] und [41] Infrarotaufnahmen benutzt, um eine Feuerlageregelung zu realisieren, d.h die Lage des Brennbetts wird konstant gehalten bzw. der Last-Sollvorgabe angepaßt. Nachteilig hierbei ist, daß eine Regelung vollständig neu zu implementieren ist.

In dieser Arbeit wird im Unterschied zu obigen Ansätzen mit einer Infrarotkamera über eine Merkmalsextraktion aus dem Abbrand des Mülls die Verbrennungseigenschaften in Form von abstrakten Parameter prognostiziert [69][70].

Die Bestimmung expliziter skalarer Werte ermöglicht das einfache Nachrüsten praktisch jeder Anlage mit der neuen Komponente, da der Sollwert für die Dampfmenge aus dem Heizwert direkt hergeleitet werden kann.

1.3 Ziele und Inhalt dieser Arbeit

Ziel dieser Arbeit ist der Einsatz von Methoden der Computational Intelligence (CI) zur Regelung des Müllverbrennungsprozesses in mehreren Bereichen:

- Zuerst wird der Verbrennungsprozeß anhand eines Black-Box-Modells mit KNNs modelliert. Hierzu muß abgeschätzt werden, welche Aspekte des Prozesses modelliert werden können. Dadurch werden prinzipielle qualitative Aussagen über die Abbildbarkeit des Prozesses auf ein statisches (nicht rekurrentes) Feedforward-Netz erhalten. Mit Hilfe einer linearen Abschätzung wird eine Prozeßdynamik ermittelt, die Aufschluß über die Modellgröße gibt. Hiervon ausgehend wird die Modellgüte durch globale und lokale Optimierungsverfahren in der Struktur bei gleichbleibender Prädiktionsqualität minimiert. Durch mehrmalige Iteration des Modells wird dann dessen Prädiktionshorizont abgeschätzt.

- Auf Basis dieses Modells wird eine Regelung aufgebaut, die die Stellgrößen aus dem Modell selbst ableitet. Hierzu werden mehrere Varianten qualitativ untersucht. Um dynamische Effekte im Vorfeld zu minimieren, werden die beiden vorherigen Komponenten Modell und Stellgrößenerzeugung im Rahmen einer modellbasierten prädiktiven Regelung zusammengefaßt. Das sich ergebende Problem der Optimierung einer Handlungssequenz wird durch Diskretisierung des Suchraums mit einer globaler Suchstrategie im Rahmen des Prädiktionshorizonts durchgeführt. Der Rechenaufwand muß zugunsten der Echtzeitfähigkeit einer groben Diskretisierung des Zustandsraums Rechnung tragen. Eine Reduktion des Rechenaufwandes wird durch Einsatz effizienter Suchalgorithmen bewirkt.

Diese Methodik wird für zwei großtechnische Müllverbrennungsanlagen angewendet.

- In einem weiteren Teil der Arbeit wird eine Infrarotkamera als zusätzlicher Sensor in der Thermischen Abfallbehandlung eingeführt. Mit der Kamera ist es möglich, ein räumliches Temperaturprofil der Verbrennungszone auf dem Rost zu erhalten. Verbrennungsorte auf dem Rost werden zeitlich verfolgt, und es entstehen Trajektorien, die die thermischen Emissionen dieser Verbrennungsorte beschreiben. Aus den Trajektorien wird letztendlich die Information über die gesamte mit der Kamera erfaßten thermischen Energie des Verbrennungsortes erhalten. Es werden Merkmale extrahiert, aus denen sich mittels einer überwachten Klassifikation die gesamte thermische Emission grob bestimmen läßt mit dem Nutzen, aus früh erkennbaren Merkmalen diese Emissionen ermitteln zu können. Somit können frühzeitig Heizwertänderungen im Müll entdeckt werden, und die Regelung kann rechtzeitig darauf reagieren.

Die entwickelten neuen Module werden in das System INSPECT integriert. Dieses Client-Server Basierte System besteht aus frei konfigurierbaren Komponenten wie Prozeßbankopplung, Fuzzy-Controller, Bilderfassung, Bildverarbeitung usw.

Die Arbeit gliedert sich wie folgt:

Im Kapitel 2 wird die Funktionsweise einer Müllverbrennungsanlage erklärt, und der Prozeß der Verbrennung wird beschrieben. Aus prototypischen Aussagen über spezielle Typen von Brennstoffen werden generelle Aussagen über das Verhalten der Verbrennung auf dem Rost abgeleitet. Insbesondere wird auf die Wirkung der Stellgrößen des Prozesses eingegangen.

In Kapitel 3 wird beschrieben, wie aus den Prozeßdaten ein Prozeßmodell erzeugt wird. Hierzu wird mit Kovarianzabschätzungen eine Modellordnung festgelegt, und eine Abschätzung der zu erwartenden Modellgüte wird mit einem linearen Modell erzeugt. Das Training der KNNs basiert auf Gradientenabstiegsverfahren. Die Konvergenz wird durch geeignete Repräsentationen der Trainingsdaten und geeignete Lernverfahren verbessert.

Kapitel 4 befaßt sich mit der Erzeugung der Stellgrößen aus dem KNN-basierten Modell und der Suche nach einer optimalen Handlungsstrategie gemäß einer modellbasierten prädiktiven Regelung. Zur Illustration und Verifikation wurden alle Ansätze am Beispiel des inversen Pendels getestet und dann mit Daten der realen Anlagen experimentell erprobt.

Kapitel 5 beschreibt die Methodik zur Integration der Infrarotkamera für die Abschätzung des Brennverhaltens des Mülls. Es wird zunächst eine Merkmalsextraktion durchgeführt, basierend auf dem zeitlichen Abbrandverhalten der Müllfraktionen. Mit KNNs wird eine Zuordnung zu den Gesamtemissionen der gemessenen Trajektorien erstellt. Zuletzt wird die Integration aller Komponenten in ein Gesamtkonzept beschrieben.

Kapitel 6 enthält eine Zusammenfassung der erzielten Ergebnisse.

2 Anlagen- und Systembeschreibung

Im diesem Kapitel werden die funktionalen Einheiten einer Müllverbrennungsanlage (MVA) beschrieben. Dabei wird auf den Verbrennungsraum und die bislang bekannten Vorgänge bei der Verbrennung detaillierter eingegangen. Zum Abschluß des Kapitels werden bestehende Varianten der Regelung des Müllverbrennungsprozesses vorgestellt.

2.1 Aufbau einer Müllverbrennungsanlage

In kommunalen Müllverbrennungsanlagen wird Hausmüll, Sperrmüll, und Müll aus industrieller Quelle (hausmüllartiger Industriemüll) verbrannt.

In einer MVA findet die Verbrennung im Müllkessel statt, d.h. er wird mit Müll beschickt und liefert am Ende des Verbrennungsprozesses chemisch träge Schlacke sowie verbranntes Rauchgas, das an die Rauchgasreinigung weitergeleitet wird. Abbildung 2.1 zeigt die Seitenansicht auf einen Müllkessel. In dem Aufgabebereich (1) wird der Müll dem Aufgaberost zugeführt. Dort wird er in die Verbrennungszone auf das Verbrennungsrost (2) transportiert. Die Hauptverbrennung findet über dem Verbrennungsrost statt (3), und freiwerdende Gase werden weiterhin in der Nachbrennkammer verbrannt (3,4). Das heiße Rauchgas verläuft entlang der Kesselzüge, deren Wände mit Wasserrohren durchzogen sind. Diese führen den Wärmetausch durch, und das erhitzte Wasser gelangt in den Dampfkessel (5), in dem der Wasserdampf in elektrische Energie umgesetzt wird. Nach dem Durchlaufen der Kesselzüge hat das Rauchgas sich abgekühlt und passiert die Rauchgasreinigung (6). Die Reinigung besteht aus folgenden Verfahrensschritten

- Entstaubung,
- Abscheidung von Salz- und Flußsäure (HCl und HF),
- Abscheidung von Schwefeldioxid (SO₂),
- Abscheidung von Stickoxiden und Abscheidung von Dioxin.

Die ausgebrannte Schlacke gelangt am Ende der Verbrennung in einen Schlackenauffangbehälter (7) und wird dort gekühlt. Die Verweilzeit des Mülls auf dem Verbrennungsrost beträgt 30-45 Minuten. Das Rauchgas verweilt in den Kesselzügen wenige Sekunden.

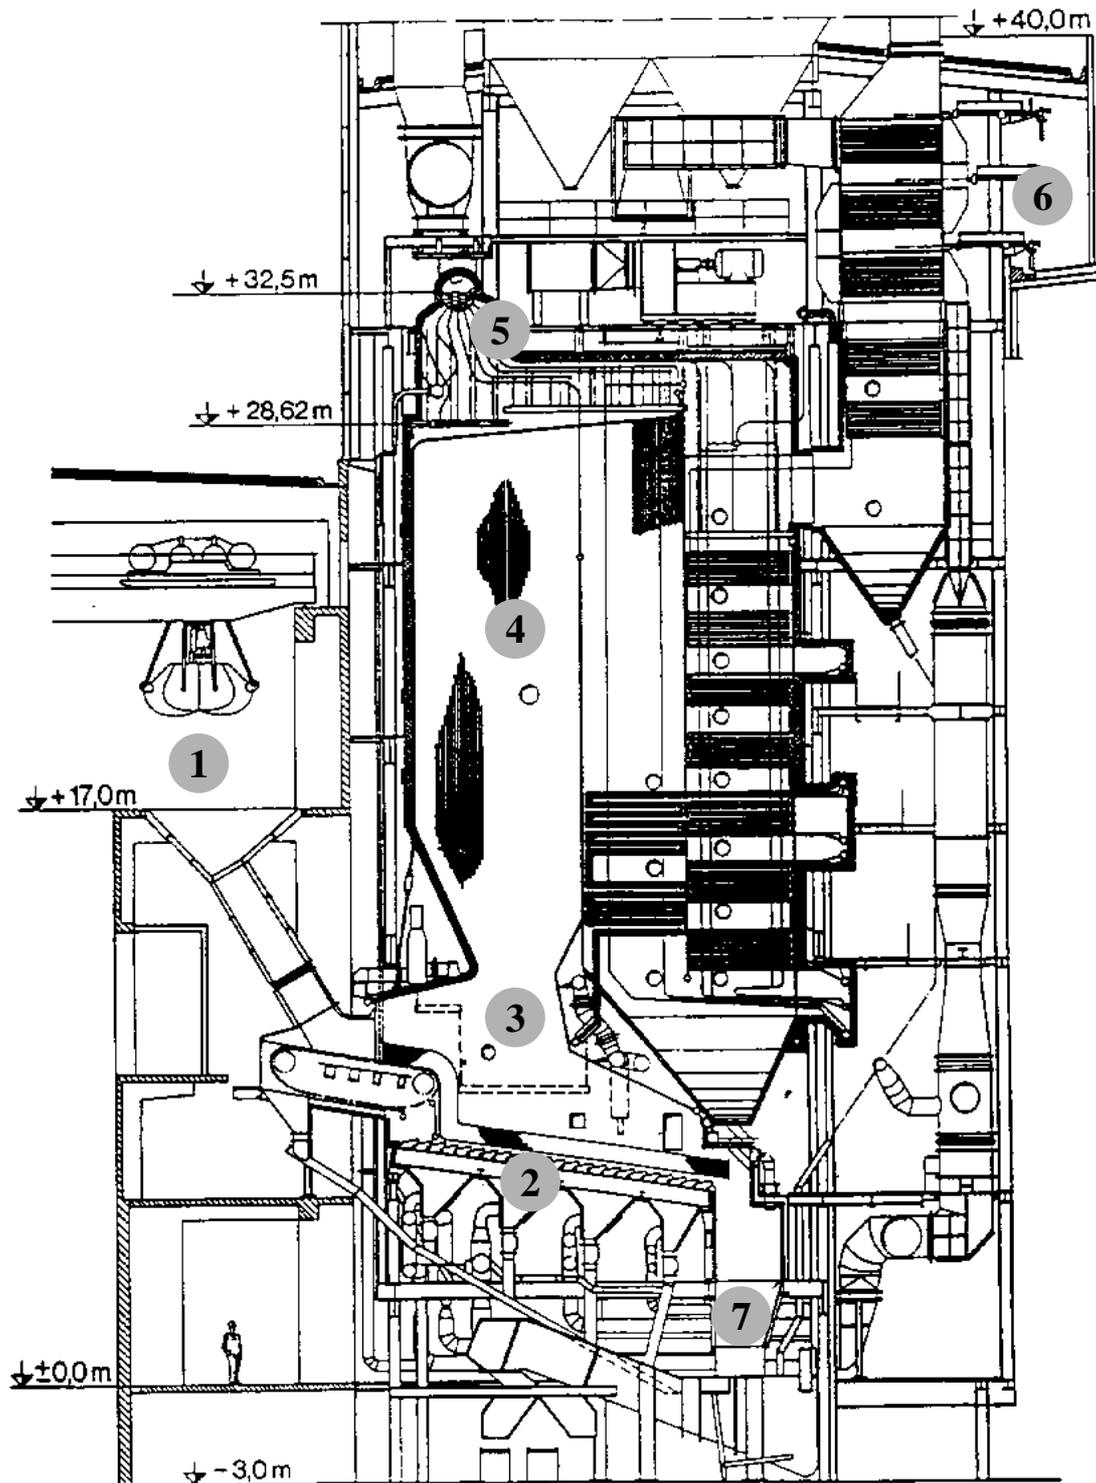


Abbildung 2.1: Seitenansicht des Kessels einer Müllverbrennungsanlage

Im folgenden werden der Aufbau und die Funktion der Anlagenkomponenten genauer beschrieben.

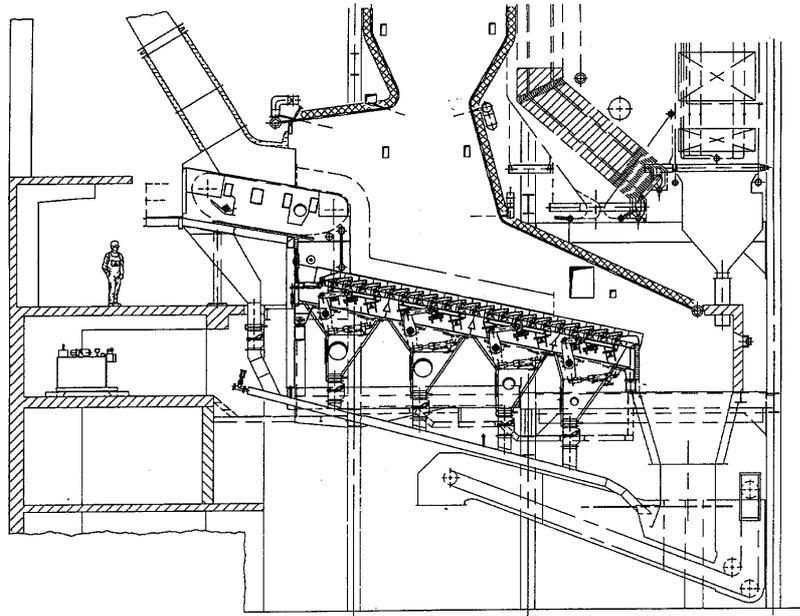


Abbildung 2.2: Beschickung, Rost und Feuerraum einer Müllverbrennungsanlage

Beschickung

Der Müll wird zuerst im Müllbunker grob zerkleinert. Von hier gelangt er über einen Kran in den Aufgabetrichter und wird durch eines der beiden folgenden Verfahren zum Verbrennungsrost geleitet:

- Aufgaberost (teure Variante). Er liefert kontinuierlich den Müll zum Verbrennungsrost. Durch die Rostgeschwindigkeit kann die Müllmenge bestimmt werden. Verklumpungen und Stauungen können dabei starke Variationen verursachen.
- Aufgabestößel. Er schiebt den durch sein Eigengewicht aus dem Trichter herabrutschenden Müll auf den Rost. Die Hubfrequenz liefert in Kombination mit dem spezifischen Gewicht und der Körnigkeit des Mülls nur eine ungenaue Aussage über den Müllmassenstrom.

Rost

Der (Verbrennungs-) Rost setzt sich aus Roststäben oder Rostwalzen zusammen. Er hat neben der Aufgabe des Mülltransports auch für die räumlich differenzierte Luftzufuhr zu sorgen. Der Rost ist hierzu in mehrere Primärluftzonen segmentiert, die über separate Luftklappen angesteuert werden (s. Abbildung 2.2).

In der Müllverbrennung sind drei Rosttypen vorzufinden: Der Walzenrost, der Rückschubrost und der Vorschubrost.

Der Walzenrost besteht aus horizontalen Walzen, die durch ihre Drehbewegung den Müll vorantreiben. Dies ermöglicht einen gleichmäßigen Transport. Walzenroste sind relativ wartungsintensiv, da durch die Zwischenräume kleine Müllpartikel fallen können, und dies zu einer Blockierung der Walzen führen kann.

Ein Vorschubrost bewegt den Müll durch Relativbewegungen abwechselnd angeordneter, feststehender und beweglicher Rostabreihen in Richtung des Schlackeabwurfs. Die feststehenden Rostabreihen liegen auf dem Rahmen, die beweglichen Rostabreihen auf den bewegten Rostwagen. Benachbarte Roststäbe einer Rostabreihe sind gebündelt, um das Eindringen von Fremdkörpern und Schmelzen zwischen den Roststäben zu verhindern. Die Luft wird durch Öffnungen im Rostbelag gepreßt. Abbildung 2.3 zeigt zwei benachbarte Rostsegmente eines Vorschubrostes.

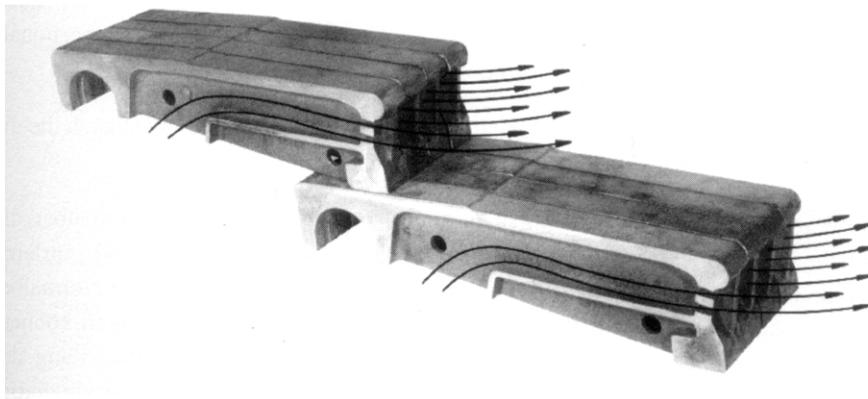


Abbildung 2.3: Roststab Luftführung (aus [31])

Der Einfluß von Inhomogenitäten der Müllschicht auf die Luftverteilung wird um so geringer, je größer der Strömungswiderstand des Rostbelages gegenüber dem der Müllschicht ist. Der Strömungswiderstand des Rostes (3.5 bis 7 mbar) ist eine Größenordnung höher als der durch den Müll verursachte Strömungswiderstand (0.8 bis 1.2 mbar), so daß die Verteilung der Luft auf dem Rost weitgehend unabhängig von der Müllbeschaffenheit ist. Die Luft tritt zunächst horizontal in die Müllschicht ein und wird dort in die Vertikale umgelenkt. So beschreibt die Luft einen längeren Weg durch die Müllschicht als bei einem vertikalen Luftaustritt, und dies resultiert in einer besseren Luftverteilung in Rostlängsrichtung. Außerdem sorgt der Rost für eine Schürwirkung und Zerkleinerung des Mülls.

Die dritte Variante ist der Rückschubrost [13], bei dem der Vorwärtstransport des Mülls analog dem Prinzip des Vorschubrostes durch einen Schub erfolgt, der allerdings entgegengesetzt der Transportrichtung des Mülls ist. Der Mülltransport erfolgt durch die horizontale Neigung des Rostes und durch die Schürwirkung, die den Müll segmentweise entlang des Rostes weiterbewegt. Dies bewirkt eine Umwälzung des Mülls und damit einen homogeneren Kontakt mit der Primärluft, die den Müll umgibt.

Feuerraum und Nachbrennkammer

Der Feuerraum ist das räumliche Gebiet über der Verbrennungszone. Hier findet die Verbrennung statt. Nur ein geringer Teil findet auf dem Rost oder kurz über dem Rost statt. Die Aufgabe des Feuerraums ist es, die Verbrennung durch Verwirbelung des Rauchgases und Verweilen des Rauchgases bei einer bestimmten Temperatur zu unterstützen.

Die Gestaltung des Feuerraums unterliegt den Gegebenheiten der Brennstoffeigenschaften, welchen durch die Gleich-, Mittel- und Gegenstromverbrennung Rechnung getragen wird. Bei der Gleichstromverbrennung ziehen Brennstoff und Abgase in gleicher Richtung durch den Feuerraum. Der Abgasabzug liegt am Ende des Rostes. Dabei wird relativ wenig Energie mit dem Brennbett ausgetauscht. Dieses Prinzip wird insbesondere für heizwertreichen Müll angewandt, da eine zu hohe Feuerraumtemperatur vermieden wird, und die Trocknungszone verlängert wird.

Bei der Gegenstromverbrennung strömen die Abgase dem Brenngut entgegen. Der Abgasabzug liegt direkt am Beginn des Rostes. Guter Wärmeaustausch wird durch Strahlung und Konvektion erzielt.

Abfälle mit schlechten Verbrennungseigenschaften benötigen eine längere und intensivere Trocknung. Das heiße Abgas trägt zur Trocknung und Vorwärmung des Brennguts bei, weshalb sich dieses Prinzip für feuchten und heizwertarmen Müll eignet.

Für die üblicherweise stark schwankenden Abfallqualitäten werden beide Systeme in der Mittelstromfeuerung kombiniert.

Der Feuerraum ist als Kessel gebaut, d.h. die abgegebene Wärme wird durch in den Wänden liegende Verdampferrohre getauscht. Im oberen Bereich des Feuerraumes wird dem Rauchgas die Sekundärluft zugegeben.

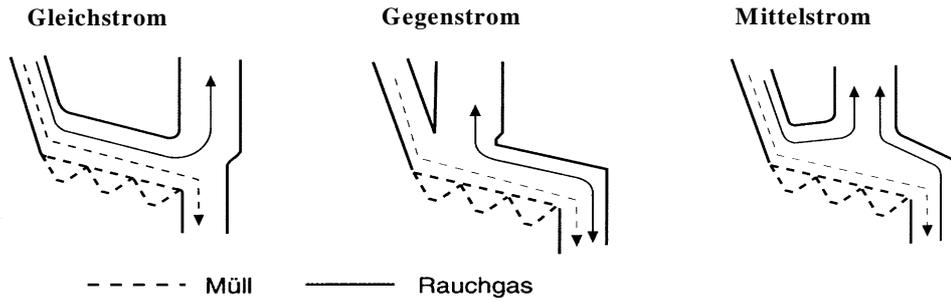


Abbildung 2.4: Drei Feuerraumtypen

Der Bereich ab der letzten Zugabestelle von Sekundärluft heißt Nachbrennkammer. Hier werden die nicht vollständig oxidierten Rauchgase nachverbrannt. Auch in dieser Kammer wird die abgegebene Energie über Konvektionswärmetauscher abgeleitet.

Rauchgasreinigung

Die für die Reinigung des Abgases Anwendung findenden Sekundärmaßnahmen bestehen aus einer Kette mehrerer Verfahrensschritte (Abbildung 2.5).

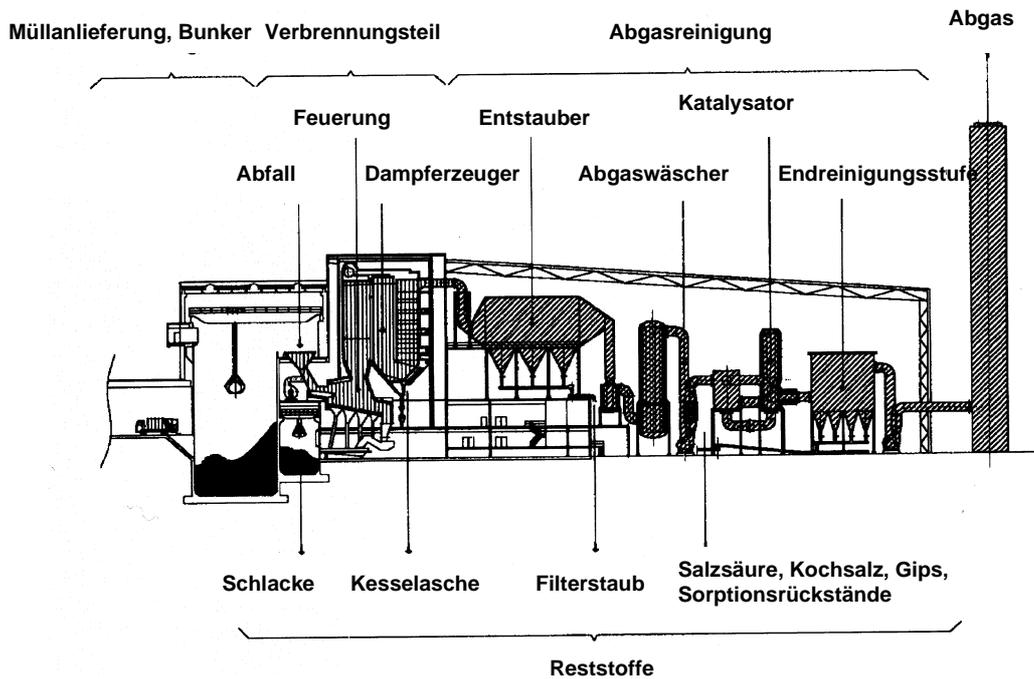


Abbildung 2.5: Rauchgasreinigung einer Müllverbrennungsanlage[99]

Zur Absonderung des metalloxidhaltigen Flugstaubes werden elektrostatische Entstauber oder Gewebeatstauber zur Filterung eingesetzt.

In einem Abgaswäscher werden die sauren Abgasbestandteile (SO_2 , HCl , HF) durch Naßsorption mittels sogenannter Waschstufen mit verschiedenem pH-Wert extrahiert. Aus den Rückständen werden Salzsäure, Kochsalz und Gips gewonnen.

Dann werden über Trockensorption (mechanische Filterung) organische Spurenstoffe herausgefiltert.

Das gereinigte Abgas verläßt über einen Tropfenabscheider die Wäsche und wird in weiteren Reinigungsstufen, wie z.B. einem SCR-Reaktor (selektive katalytische Reduktion) von Stickoxiden (NO_x) und durch einen Flugstromabsorber von den restlichen Schwermetallen und Dioxinen/Furanen befreit. Bei den katalytischen Verfahren werden die Stickoxide unter Zugabe von Ammoniakwasser an einem Katalysator zu Stickstoff und Wasserdampf umgesetzt.

Dampferzeugung

Neben der Kompaktierung von Restmüll ist auch die Energiegewinnung ein Ziel von Müllheizkraftwerken. Energie wird gewonnen durch Umsetzen der thermischen Energie über einen Wärmetauscher zur Dampferzeugung. Der entstehende Wasserdampf wird über Turbinen in elektrische Energie umgewandelt.

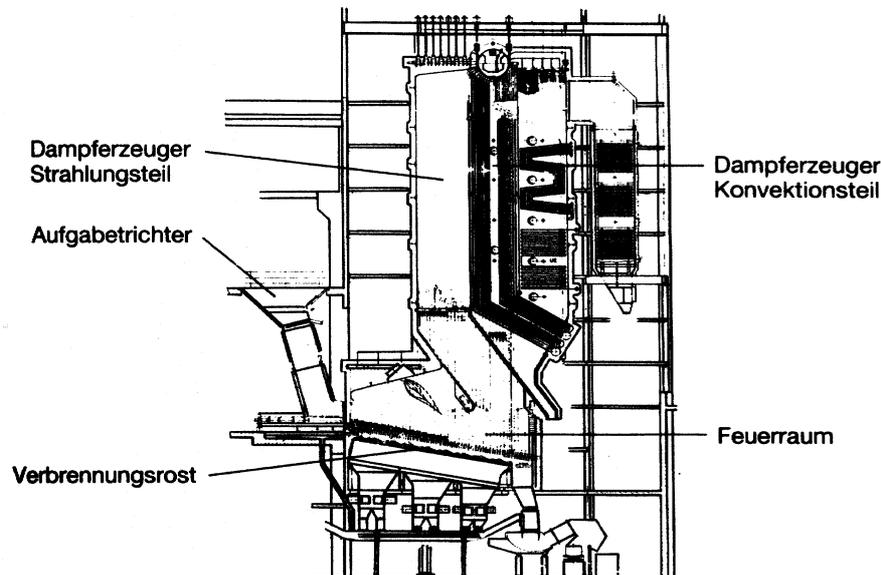


Abbildung 2.6: Dampferzeugung, integriert in den Feuerraum

Großwasserraumkessel arbeiten hierbei mit natürlichem Wasserumlauf. An den stark beheizten Stellen in der Nähe des Feuerraums steigt das Wasser vermisch mit den Dampfblasen nach

oben in die Kesseltrommel, wo sich Dampfblasen und Wasser entmischen. An den schwach oder gar nicht beheizten Stellen, z.B. an den Kesselaußenwänden, fällt das Wasser wieder nach unten. Durch den natürlichen Wasserumlauf müssen die beheizten und unbeheizten Wasserrohre so angeordnet sein, daß allein durch den Dichteunterschied eine Zirkulation des Wassers stattfindet. Die Fallrohre sollen durch möglichst senkrechte Lage das Wasser nach unten strömen lassen. Eine Speisewasserversorgung hält die Wassermenge im Umlauf konstant, da der erzeugte Frischdampf für die Energieversorgung dem Kreislauf entweicht. Die Dampferzeugung ist primär abhängig von der Brennkammertemperatur und reagiert je nach Anlagenkonstruktion mit einer Totzeit von wenigen Sekunden bis einer Minute.

2.2 Verbrennung

Anfang des 20. Jahrhunderts wurde mit der systematischen Erfassung der Vorgänge in einem brennenden Gutbett begonnen. Die untersuchten Brennstoffe waren Kohle und Koks. Ziel der Arbeiten war es, einen sicheren und wirtschaftlichen Betrieb der Verbrennungsanlagen zu ermöglichen und deren Leistung zu steigern [3]. In jüngster Zeit wurden die Bildung und Freisetzung von Schadstoffen auf dem Gutbett untersucht.

Bei der Übertragung der Ergebnisse von der Kohleverbrennung auf die Verbrennung von Hausmüll müssen die unterschiedlichen Brennstoffeigenschaften berücksichtigt werden. Hausmüll hat im Gegensatz zu Kohle einen hohen Sauerstoff-, Wasserstoff-, Asche- und Wassergehalt. Aufgrund der hohen Müllfeuchte kann der Wärmetransport in einem Partikel den Abbrand bestimmen. Jeder Bereich des Partikels muß erst getrocknet werden, bevor er entzündet werden kann. Die wesentlichen Ergebnisse aus den Versuchen zur Kohleverbrennung können jedoch auf die Müllverbrennung übertragen werden, wie in [28] gezeigt wurde.

Alle Arbeiten wurden an Laborapparaturen durchgeführt, die den Verbrennungsablauf auf einem Rost simulieren: Ein wärmeisolierter Behälter wird mit Brennstoff gefüllt. Die Verbrennungsluft strömt von unten durch den Behälter. Der Versuch beginnt, indem die Oberfläche des Brennstoffs entzündet wird. Der zeitliche Verlauf des Abbrandes entspricht den Verbrennungszonen entlang des Rostes. Das sind die Trocknungs- Verbrennungs- und Ausbrandzone.

2.2.1 Abbrand eines Partikels

Die Grundlage für die Verbrennung im Verbund ist der Abbrand eines Partikels. Detaillierte Ergebnisse liegen für die Verbrennung von Kohlekörnern vor, wobei die hier beschriebenen Zusammenhänge für alle festen Brennstoffe gelten. Es werden folgende Stufen der Verbrennung fester Brennstoffe unterschieden:

- Erwärmung und Trocknung
- Entgasung und Verbrennung flüchtiger Bestandteile
- heterogene Verbrennung des Restkokes.

Für die Erwärmung und Trocknung ist es notwendig, die Wärmemenge dem Partikel zuzuführen und in das Korninnere zu transportieren. Außerdem muß der Wasserdampf aus diesem Korn abtransportiert werden. Die notwendige Wärmemenge wird durch die Wärmekapazität des Partikels, vor allem aber durch den Wassergehalt bestimmt. Hier werden zwei Trocknungsphasen unterschieden. In der ersten Phase (1. Trocknungsabschnitt) wird die von der Oberfläche verdunstende Wassermenge ständig aus dem Korninneren ersetzt. Die Trocknungsgeschwindigkeit wird durch den Stofftransport von der Oberfläche der Partikel an die Umgebung bestimmt und ist unabhängig von der Feuchte des Brennguts. Wird die verdunstete Wassermenge nicht mehr durch den kapillaren Flüssigkeitstransport nachgeliefert, so wandert der Trocknungsspiegel in das Korninnere. Die Trocknungsgeschwindigkeit wird dann durch zusätzliche Stoff- und Wärmeübergangswiderstände verringert und ist von der Lage des Trocknungsspiegels, d.h. von der Brenngutfeuchte abhängig. Die Trocknungsgeschwindigkeit sinkt weiter, wenn die hygroskopische Brenngutfeuchte eines Partikels unterschritten wird, da dann zusätzlich der Dampfdruck des enthaltenen Wassers abnimmt. In der zweiten Trocknungsphase kann die Temperatur der Oberfläche gegenüber derjenigen im Kern eines trockenen Partikels deutlich ansteigen, so daß Trocknung, Entgasung und Zersetzungsprozesse parallel in einem Partikel ablaufen können.

Bei der Entgasung werden flüchtige Bestandteile aus dem Korn freigesetzt. Die dabei ablaufenden Prozesse sind die Austreibung flüchtiger Bestandteile, die Abspaltung funktioneller Gruppen und die Zersetzung hochmolekularer Verbindungen. Der Gehalt an flüchtigen Bestandteilen im Hausmüll ist groß. Der mittlere Wert, der bei der Pyrolyse bei einer Aufheizung auf 900°C bestimmt wurde, liegt bei 65 Gew.% der feuchten Substanz (davon 30% H₂O). Die Gase bestehen aus aromatischen und aliphatischen Kohlenwasserstoffen sowie niedermolekularen Zersetzungsprodukten (z.B. CO, CO₂, H₂O, HCl).

Die Zündung der flüchtigen Bestandteile setzt in der Umgebung des Korns ein, sobald deren Konzentration innerhalb der Zündgrenzen liegt und die Zündtemperatur überschritten wird. Der Abstand der Reaktionszone von der Oberfläche hängt von dem Entgasungsverlauf, der Diffusion der flüchtigen Bestandteile und des Sauerstoffs sowie dem Temperaturprofil in der Umgebung des Korns ab. Je größer die Menge an freigesetzten Gasen und je langsamer der Sauerstoff

im Vergleich zu den flüchtigen Bestandteilen diffundiert, desto größer ist der Abstand der Flammenzone von der Kornoberfläche. Bei Braunkohle beträgt der Abstand Kornoberfläche-Reaktionszone ca. 10-12 Partikeldurchmesser, während bei Kohlekörnern mit einem Durchmesser kleiner $15\mu\text{m}$ keine Hüllflamme mehr auftritt [42].

Als letzter Schritt erfolgt die heterogene Verbrennung des verbleibenden Restkokes. Folgende Teilvorgänge sind für die Verbrennung notwendig:

- Transport des Sauerstoffs zur äußeren und inneren Kornoberfläche
- Die Kohlenstoff (C-)-Verbrennung und der Abtransport der Reaktionsprodukte

Die wichtigsten Reaktionen sind C-Verbrennung, Boudouard-Reaktion und heterogene Wassergas Reaktion. Die chemische Reaktion sowie die Poren und Grenzfilmdiffusion der beteiligten Gasspezies bestimmen abhängig vom jeweiligen Temperaturbereich den Verbrennungsablauf.

Für niedrige Temperaturen (bis ca. 750°C) ist die chemische Reaktion die geschwindigkeitsbestimmende Größe. Die Konzentration der Sauerstoff heranzuführenden Verbindungen sind im gesamten Korn gleich der Konzentration im Gasstrom außerhalb des Kornes. Im Temperaturbereich ab 750°C ist die chemische Reaktion so schnell, daß das Korninnere an Sauerstoff verarmt. In den Poren entsteht ein Konzentrationsgefälle, so daß Porendiffusion den Verbrennungsablauf bestimmt. Hier spielt im Gegensatz zum vorhergehenden Bereich die Korngröße eine Rolle, da eine Verkürzung der Diffusionswege den Umsatz erhöht.

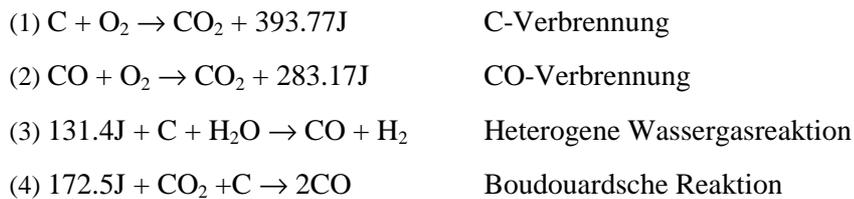
2.2.2 Verbrennung auf dem Rost

Im Verbrennungssofen wird der feste Brennstoff in Gas umgesetzt. Diese Umsetzung zu einem Rauchgas erfolgt in vier Phasen:

1. **Trocknung:** Hier wird dem Müll unter äußerer Energieeinwirkung die Feuchtigkeit entzogen. Die Temperaturen betragen bis zu 100°C .
2. **Entgasung:** Dem Müll werden unter Energieeinwirkung leicht flüchtige Stoffe entzogen wie Schwefelgase, Kohlenwasserstoffe. Es finden keine chemischen Reaktionen statt. Da die Zündtemperatur dieser Entsorgungsprodukte relativ niedrig ist, wird es unter Anwesenheit von Oxidationsmitteln sofort zur Zündung kommen. Die Temperaturen betragen um 250°C .

3. **Vergasung:** Hier wird der in den festen Bestandteilen des Mülls gebundene Kohlenstoff bei Temperaturen von 500-600°C zu gasförmigen Produkten umgesetzt. Energiezufuhr, Sauerstoff und Wasserdampf wirken hier reaktionsfördernd.
4. **Verbrennung:** Großteils exotherme Reaktion durch vollständige Oxidation der in den vorigen Phasen entstandenen Gase.

Innerhalb der Verbrennung auf dem Rost treten analog zum vorigen Abschnitt die vier dominierenden chemischen Reaktionen auf [104]:



Diese Reaktionen treten parallel auf je nach vorhandenen Ressourcen. Die verfügbaren Ressourcen sind innerhalb der Brennkammer verschieden.

Zuerst findet Reaktion 1 statt, und mit weiterer Höhe über dem Brennbett verringert sich der O₂-Gehalt, so daß die Reaktionen 2 und 3 ablaufen. Nach Hinzugabe der Sekundärluft und Überschuß an CO wird vorwiegend Reaktion 4 stattfinden.

In Abbildung 2.7 wird eine typische Gaszusammensetzung in einer Brennzzone in Abhängigkeit der Höhe über dem Rost gezeigt. Zwei Bereiche werden hier unterschieden, das Gebiet mit freiem Sauerstoff in Rostnähe und das mit Sauerstoffmangel. Beide Bereiche werden durch die sogenannte neutrale Zone, d.h. das Gebiet, in dem der Sauerstoff gerade gebunden ist, getrennt. Oberhalb der neutralen Zone wird der Brennstoff zu CO und dann in der Nachbrennkammer größtenteils zu CO₂ verbrannt.

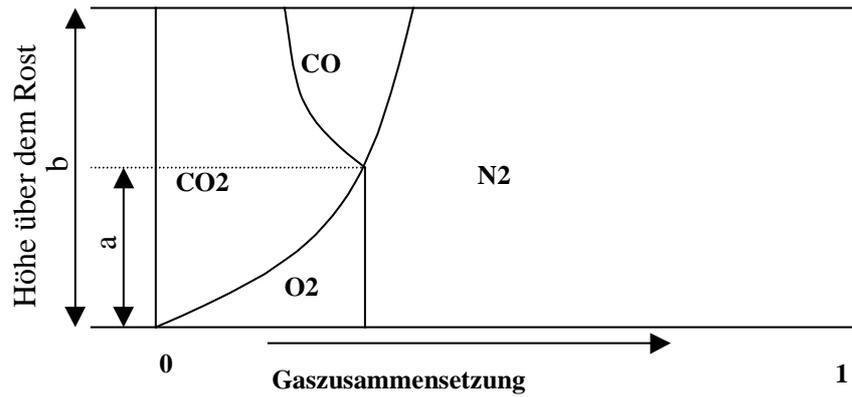


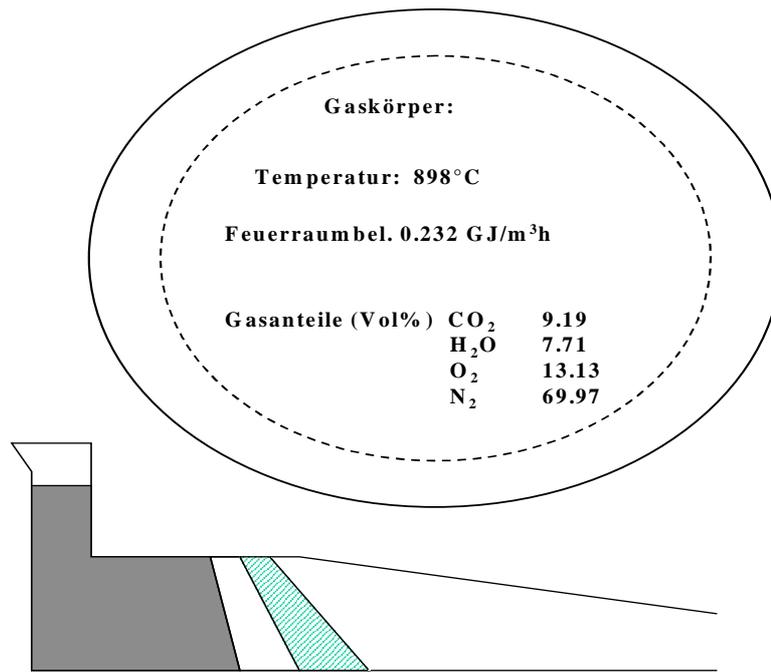
Abbildung 2.7: Gaszusammensetzung in einem homogenen Gutbett

Der Brennstoff wird mit Umgebungstemperatur auf dem Rost aufgebracht. Dort wird er durch die warme Verbrennungsluft, die das Gutbett durchströmt, von unten und durch die Wärmestrahlung von oben erwärmt und getrocknet. Aufgrund des Wassergehaltes und der schlechten Wärmeleitung des Gutbettes ändert sich im Kern der Schüttung die Temperatur nur unwesentlich. Der Wärmestrom auf die Gutbettoberfläche durch Wärmestrahlung ist wesentlich größer als die eingebrachte Wärmemenge durch die Verbrennungsluft. Daher zündet das Gutbett an der Oberfläche. Das Gutbett brennt von oben nach unten ab.

Nachdem das Feuer den Rost erreicht hat, brennen alle Bereiche, in denen noch Brennstoff vorhanden ist. Der Massenumsatz in Rostnähe ist größer, da dort die Sauerstoffkonzentration am höchsten ist. In Abbildung 2.8 ist der oben geschilderte Vorgang schematisch dargestellt.

Zur Zündung des Brennstoffs ist es notwendig, die Brennstoffoberfläche zu trocknen und auf Zündtemperatur zu erwärmen. Daher sind Müllfeuchte und Wärmekapazität des Brennstoffs wesentliche Faktoren für die Zeitdauer bis zur Zündung [3].

Bei Hausmüll liegt die Zündtemperatur mit 235-320 °C aufgrund des hohen Gehalts an leicht flüchtigen Bestandteilen im Vergleich zu anderen festen Brennstoffen niedrig. Die Zündtemperatur von Torf und Braunkohle beträgt unter Rostfeuerungsbedingung etwa 250°C, die von Steinkohle je nach Gehalt an flüchtigen Bestandteilen zwischen 300°C (Flammkohle) und 500°C (Anthrazit) und von Koks etwa zwischen 650°C und 700°C. Dabei ist mit Zündung die Entflammung brennbarer Entgasungsbestandteile, deren Freisetzung temperaturabhängig ist, gemeint.



der Umsetzung heißt die Massenumsatzrate. Sie ist bis auf einen kurzen Anlauf- und Ausklingvorgang für dicke Brennstoffschichten entlang des Rosts weitgehend konstant.

Die Brennzone wird an der Unterseite durch die Zündfront, die in den frischen Brennstoff eindringt, und an der Oberseite durch die ausgebrannte Brennstoffschicht begrenzt. Die Dicke der Brennzone ergibt sich aus der Differenz zwischen Zündrate und Massenumsatzrate. Je schneller der Brennstoff entzündet wird und je langsamer er verbrennt, desto dicker ist die Brennzone. Unter den Verbrennungsbedingungen in technischen Rostfeuerungen übersteigt die Zündrate die Massenumsatzrate.

Die oben beschriebenen Vorgänge laufen in einem idealisierten, homogenen, wandernden Gutbett ab, wobei eine Durchmischung auf dem Rost nicht berücksichtigt ist. In einem realen, inhomogenen Müllbett überschneiden und überlagern sich die Teilvorgänge Trocknung, Entgasung und Restkoksverbrennung abhängig von den Aufheizraten eines Korns, der Partikelfeuchte und -größe. Außerdem werden Stofftransportvorgänge durch Ascheschichten um die Partikel behindert. Unverbrannte Bestandteile können durch zähflüssige Schlacke vollständig umschlossen werden. Neben den dargestellten Zusammenhängen beeinflussen bei der Hausmüllverbrennung auch katalytisch wirkende Substanzen den Verbrennungsablauf, wobei hierauf nicht näher eingegangen wird.

2.2.3 Einfluß der Stellgrößen auf die Verbrennung

Der Verbrennungsablauf auf dem Rost kann durch die Rostbewegung, den Müllmassenstrom, die Primärlufttemperatur, die Strahlungstemperatur des Überbettraums und die Primärluftmenge beeinflusst werden.

Auf **Änderungen des Müllmassenstroms** reagiert eine Großanlage mit einer Totzeit von bis zu einer viertel Stunde bei Müllverweilzeiten im Feuerraum von etwa einer halben Stunde.

Etwas schneller kann der Verbrennungsablauf mit der **Rostbewegung** beeinflusst werden. Durch die Schürwirkung von Vorschubrosten wird der Müll kurzfristig erhöht mit Sauerstoff versorgt. Diese Wirkung ist jedoch nur temporär.

Eine **Erhöhung der Primärlufttemperatur** führt zu kürzeren Trocknungszeiten des Mülls. In der Hauptverbrennungsphase hat die Primärlufttemperatur keinen Einfluß.

Die Strahlungstemperatur des Überbettraums (Brennkammertemperatur) darf eine Temperatur von 700°C nicht unterschreiten. Kommt es zu einer Unterschreitung dieser Temperatur, so wird ein Gasbrenner aktiviert, um die Temperatur zu erhöhen.

Änderungen der Primärluft stellen die schnellste und direkteste Beeinflussung des Verbrennungsablaufes dar. Eine Rostfeuerung reagiert auf Primärluftänderungen binnen weniger Se-

kunden. Die Massenumsatzrate steigt linear mit der Primärluftmenge an, bis sie so groß ist wie die Zündrate. Dann stellt die Zündrate die Grenze für den Abbrand dar. Der Brennstoff kann nicht schneller verbrennen, als er gezündet wird. Mit den Punkten I, II und III werden drei mögliche stabile Verbrennungszustände bezeichnet, die in Abbildung 2.9 näher erläutert werden.

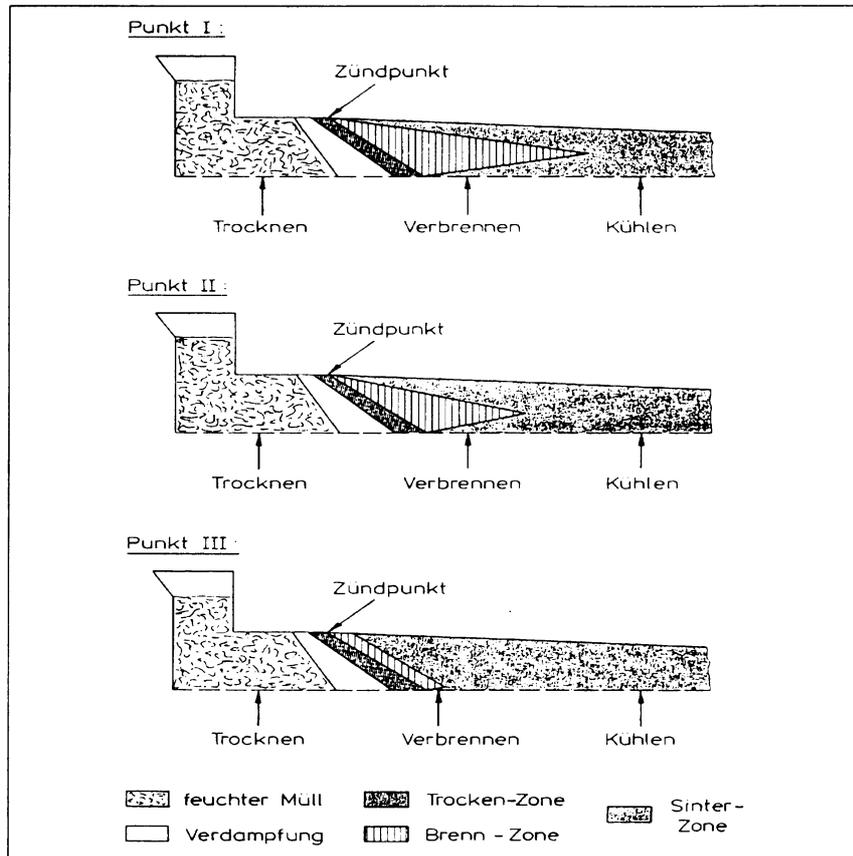


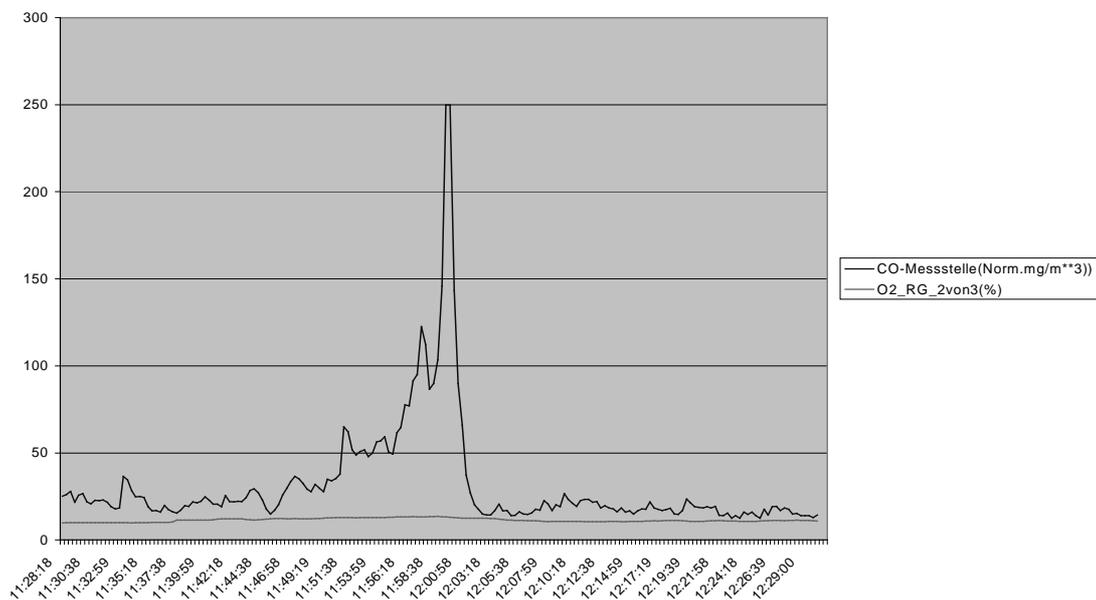
Abbildung 2.9: Brennbettprofil bei unterschiedlicher Luftzufuhr [3]

Erhöht sich die Primärluft von Betriebszustand I auf II, so steigt die verbrennungskontrollierte Massenumsatzrate deutlich an. Die Zündrate bleibt annähernd konstant. Die Brennzone verkleinert sich, da der Brennstoff etwa gleich schnell gezündet wird, aber schneller abbrennt. Bei einer weiteren Primärluftherhöhung (Punkt III) ist die Zündrate die Grenze für die Massenumsatzrate. Der Brennstoff wird mit einer schmalen Reaktionszone umgesetzt. Mit zunehmender Luftmenge nimmt die Massenumsatzrate ab, da das Gutbett durch die Primärluft gekühlt und die Zündung so verzögert wird, d.h. Punkt III wandert auf der „Zündkurve“ nach rechts.

An Großanlagen zur Hausmüllverbrennung werden im Normalfall die Betriebszustände I und II gefahren, d.h. die Massenumsatzrate für den Brennstoff Müll wird nicht durch die Zündrate begrenzt.

Durch weitere Zugabe von Primärluft kann die Verbrennung quasi ausgeblasen werden. In diesem Fall findet die sogenannte kalte Verbrennung statt. Hier passiert folgendes: Die Primärluft kühlt die Hauptverbrennungszone so weit ab, daß die bei der Vergasung entstehenden flüchtigen Stoffe sich nicht mehr automatisch entzünden. Trotz eines hohen O_2 -Gehalts findet keine Oxidation mehr statt. Die inneren Kornteile, in denen die erhöhte Luftzufuhr nicht zum Tragen kommt, werden langsamer abgekühlt, und die unvollständige Verbrennung im Korninneren findet immer noch statt. Durch O_2 -Mangel entsteht CO, das in den höheren Schichten über dem Brennbett nicht mehr weiter oxidiert wird. Aus diesem Grund wird automatisch ein Lastbrenner bei einer Abkühlung des Brennraums unter $700^\circ C$ eingeschaltet. Dieser Brenner sitzt relativ hoch, so daß zuerst das im Brennraum enthaltene CO vollständig zu CO_2 oxidiert wird. Die Verbrennung breitet sich dann von oben nach unten aus, bis die Strahlung das Gutbett wieder aufheizt.

Abbildung 2.10 zeigt die Situation einer kalten Verbrennung.



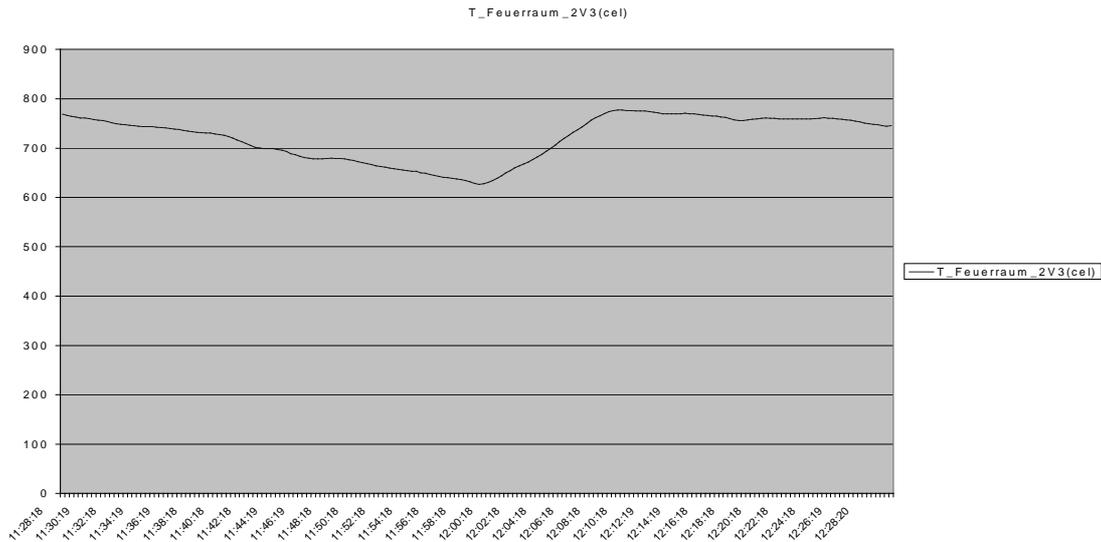


Abbildung 2.10: O₂-, CO - und Temperaturverlauf bei der kalten Verbrennung

An der Anlage 2 wurde manuell die Primärluftzufuhr um 11.45 um 30% erhöht (s. Abbildung 2.10). Dies wirkt sich in einer sofortigen Erhöhung des CO und des O₂ – Gehalts aus. Die Feuerraumtemperatur sinkt stetig. Um 12.00°C setzt der Lastbrenner ein, um die Feuerraumtemperatur zu erhöhen. Eine sofortige Oxidation des CO und O₂ ist die Folge. Die Feuerraumtemperatur steigt langsam und erreicht nach 10 Minuten ihren alten Wert von 780°C.

2.2.4 Reaktionen zur NO-Bildung

Primärmaßnahmen haben u.a. das Ziel der Verminderung von Stickoxiden. In der Müllverbrennung werden drei Arten der NO-Entstehung unterschieden:

Die **Thermische NO-Bildung** (tritt nur bei hohen Verbrennungstemperaturen auf) entsteht durch eine hohe Anregungsenergie der Reaktion. Der Stickstoff wird aus der anwesenden Luft bezogen. Die Reaktionen sind als Zeldovic Mechanismus bekannt [105].

- $O + N_2 \leftrightarrow NO + N$
- $N + O_2 \leftrightarrow NO + O$
- $N + OH \leftrightarrow NO + H$

Prompte NO-Bildung entsteht durch unterstöchiometrische Verbrennung in der Hauptreaktionszone der Flammen, also bei hoher Radikalendichte (Fenimore Mechanismus). Intermediär

gebildetes CH reagiert mit dem Luftstickstoff, wobei Blausäure gebildet wird, welche dann schnell zu NO weiter reagiert [104].

NO-Bildung aus Brennstoff tritt vorwiegend bei der Kohlefeuerung auf. Auch sehr reine Kohle enthält immerhin noch 1% gebundenen Stickstoff. Die stickstoffhaltigen Verbindungen entweichen bei der Entgasung zum größten Teil und führen dann in der Gasphase zu NO-Bildung.

2.3 Regelung

Der Müllverbrennungsprozeß wird durch die Parameter Luftzufuhr, Rostgeschwindigkeit und Müllmenge geregelt. Als Regelgrößen werden der Sauerstoffgehalt im Rauchgas, die Wärmeentbindung (bzw. damit erzeugte Dampfmenge) und optional die Lage des Feuers auf dem Rost verwendet.

Es gibt zwei Arten der Feuerleistungsregelung:

1. Festlastregelung
 2. Verbrennungsluftregelung.
-
1. Bei der **Festlastregelung** wird die Luftzufuhr konstant gehalten und eventuelle Verbrennungsschwankungen werden durch die Müllbeschickung und den Vorschubrost geregelt. Dies sorgt für einen konstanten Durchsatz der Anlage, aber durch die verzögerte Reaktion auf eine Änderung der Beschickung können kurzfristige Schwankungen in der Dampferzeugung auftreten.
 2. Bei der **Verbrennungsluftregelung** wird die Müllbeschickung konstant gehalten, und die Primär- und Sekundärluftzufuhr sorgen für ein schnelles Ausgleichen der Dampferzeugung.

Die beiden Verfahren können kombiniert werden und kommen in Form von verschiedenen Strategien zum Einsatz.

Exemplarisch sind hier einige im Einsatz befindliche Regelungen aufgeführt:

- Die Regelung der als Dampfmenge gemessenen Wärmeentbindung erfolgt über die Primärluftmenge, wobei die Verteilung der Primärluft auf die Rostzonen zwar verstellbar, aber nicht in die Regelung mit eingebunden ist. Zum Erzielen einer konstanter Rauchgasmenge, -temperatur und -zusammensetzung wird die Sekundärluftmenge gegensinnig zur Primär-

luftmenge geregelt. Längerfristige Abweichungen des O_2 -Gehaltes im Rauchgas werden als Brennstoffmangel- oder Überfluß interpretiert und zur Ansteuerung des Zuteilers verwendet [87].

- Die Regelung der Dampfmenge erfolgt über die Primärluftzufuhr, der O_2 Gehalt im Rauchgas wird über die Sekundärluft konstant gehalten. Die Feuerlage wird durch die aufgegebene Müllmenge geregelt. Über Infrarot-Thermographie wird aus den O_2 Sollwerten und der Dampfmenge Vorschub und Primärluftmenge für jedes Segment geregelt [99].
- Eine Infrarotkamera ist an der Decke des Feuerraums befestigt und erfaßt die Temperaturverteilung vor allem über den Verbrennungszonen 2, 3 und 4. Die Brennbettoberflächentemperatur über den Zonen 3 und 4 wird über die Primärluft auf ein maximales Temperaturprofil ausgeregelt, um einen vollständigen Schlackeausbrand zu gewährleisten. Die Regelung der Brennbetttemperatur über Zone 2 erfolgt durch die Müllbeschickung. Über die Stellgröße „Lage Hauptbrandzone“ bzw. „Schieflage“ wird die vom Heizwert abhängige Lage der Hauptverbrennungszone auf dem Rost etwa am Ende der Zone 3 gehalten. Dies erfolgt durch Schürung und Variation der Rostgeschwindigkeit [13].

In der in dieser Arbeit betrachteten realen Anlage 1 werden Schwankungen der Dampfmenge über die Primärluftzufuhr ausgeregelt. Der Sollwert für die Dampfmenge wird über einen manuell bestimmten Heizwert des auf dem Rost befindlichen Mülls festgelegt. Der Sollwert für den O_2 -Gehalt im Rauchgas ist konstant. Geregelt wird dieser Parameter über Variation in der Vorschubgeschwindigkeit des Verbrennungsrostes. Die Geschwindigkeit des Aufgabestößels ist an den Vorschub gekoppelt, was eine konstante Höhe der Müllschicht bewirkt.

Gegenwärtig ist die Feuerleistungsregelung der Anlage 2 durch einen Fuzzy-Regler realisiert [24]. Somit kann das Regelverhalten durch umgangssprachliche Terme beschrieben werden. Bei Vorgabe der Dampfmenge und (implizit) Vorgabe des Müllbrennwerts wird der Prozeß über die Luftzufuhr und die Zufuhr von Müll gesteuert. Schwankungen der Dampfmenge werden kurzfristig über die Primärluftmenge ausgeglichen. Abweichungen vom O_2 -Sollwert (liegt bei ca. 8-9%) werden prinzipiell über die Aufgabegeschwindigkeit (und damit die Müllmenge) kompensiert. Der Fuzzy-Regler produziert eine Kombination beider Führungsgrößen für die Stellgrößen. Bei zu geringer Dampfmenge werden die Luftzufuhr und die Vorschubgeschwindigkeit des Aufgaberoestes erhöht. Dies ist motiviert durch die Annahme, daß sich zu wenig Brennstoff auf dem Rost befindet. Allerdings kann sich auch das Entzündungsverhalten des Mülls bei gleichbleibendem Brennwert geändert haben. Dann ist der obige Eingriff nicht sinn-

voll, da zuviel Müll auf den Rost gelangt. Um solche mißverständlichen Prozeßsituationen zu vermeiden, wird der O₂-Gehalt des Rauchgases zur Ermittlung des Sollwerts für die Vorschubgeschwindigkeit des Aufgaberostes mit herangezogen. Die folgende Tabelle zeigt die auftretenden Prozeßsituationen und die Antwort der Regelung:

	Hoher O ₂ Wert	Niedriger O ₂ Wert
Dampfmenge ausreichend	Zuviel Luft	Zuviel Brennstoff
Reaktion	Luft verringern	Weniger Brennstoff
Dampfmenge gering	Brennstoffmangel	zu wenig Luft
Reaktion	Mehr Brennstoff	Mehr Luft

Tabelle 2.1: Regelschema eines Fuzzy-Reglers

Die Geschwindigkeit der Vorschubroste ist ein Erfahrungswert und wird nicht automatisch vom Prozeßleitsystem aufgrund von sich ändernden Sensorwerten geändert, d.h. sie bleibt konstant.

Der Vorschubrost hat neben dem Mülltransport die Aufgabe der Mischung und Schürung des Mülls. Hierzu werden nach einem langen Hub Zwischenhübe gefahren.

Der Rost ist in vier Zonen (längs) a zwei Segmente (quer) aufgeteilt. Jedes Segment kann einzeln mit Luft versorgt werden. In Zone 1 und 2 werden die Segmente mit gleichviel Luft angesteuert, um die Dampfmenge zu regeln. In Zone 3 und 4 werden die Segmente (im Normalfall) konstant gefahren, wobei jeweils zwei Luftstöße gegenläufig abgegeben werden.

CO ist als Prozeßparameter vorhanden, wird aber nicht in die Regelung mit einbezogen. Eine Variation der Rostgeschwindigkeit und räumlich-individuelle Luftsteuerung der Segmente einer Zone sind mangels Steuerbarkeit nicht vorgesehen. Die früher im Einsatz befindlichen Pyrodetektoren gaben ein Signal, das räumlich zu selektiv war und aus dem sich kein Temperaturprofil des Brennbetts ableiten ließ, was zu einer differenzierten Ansteuerung der einzelnen Segmente notwendig wäre.

Die in diesem Kapitel vorgestellten technischen Gegebenheiten der Anlagenkonstruktion und der Theorie der Verbrennung bilden die Ausgangssituation für die im nächsten Kapitel beschriebene Modellierung des Prozeßverhaltens.

3 Methodik zur Modellierung und Simulation des Müllverbrennungsprozesses mit Künstlichen Neuronalen Netzen

Die Systemmodellierung kann zum Zweck einer analytischer Beschreibung interner Strukturen und Interaktionen eines Systems eingesetzt werden. Modellierung wird aber auch verwendet, um einen Prozeß zu simulieren, d.h sein Verhalten nachzubilden. In diesem Fall ist die Beschreibung der internen Strukturen durch das Modell nebensächlich, denn es kommt bei der Simulation primär auf ein möglichst genaues Verhalten des Modells im Vergleich zum Original an [73].

Da eine analytische Beschreibung des Prozesses fehlt, müssen entsprechende nichtlineare Modelle auf experimentelle Art geschaffen werden [106]. Die Systemtheorie erlaubt die Entwicklung von Black-Box-Modellen, wie Volterra- und Hammerstein-Modelle [37]. Black-Box-Modelle sind im Allgemeinen in ihrer Struktur von der Struktur des zu modellierenden Prozesses verschieden. Grundlage von Hammerstein-Modellen ist die Approximation mittels Polynomen. Allerdings sind sehr viele Modellparameter zu bestimmen, und der polynomiale Ansatz kann zu unerwünschten Extrapolationseigenschaften führen, da Polynomfunktionen rasch große Werte annehmen, und unbeschränkt sind. Alternativ sind Künstliche Neuronale Netze (KNNs) aufgrund ihrer Fehlertoleranz, ihrer Extrapolationseigenschaften und ihres Selbstorganisationsvermögens als Black-Box-Modelle für eine Approximation nichtlinearer Prozesse einsetzbar. Die KNNs werden deshalb oft zur Beschreibung des nichtlinearen Übertragungsverhaltens des Prozesses verwendet [44][66][71].

In vorliegenden Kapitel werden Modelle auf Basis Künstlicher Neuronaler Netze zur Verhaltensmodellierung des Müllverbrennungsprozesses entwickelt. Es wird die Methodik zum Erlangen von Modellen mit möglichst geringen Modellfehler für diese spezielle Anwendung beschrieben. Die Parameter der Modellierung sind:

- der Typ des KNN-Modells,
- die Ordnung des Modells,
- die Repräsentation der Daten,
- die Modellstruktur.

Hauptaufgabe des Kapitels ist also, diese Strukturparameter für die Modellierung des Müllverbrennungsprozesses zu bestimmen.

Die erzeugten Modelle werden in einem weiteren Verfahrensschritt hinsichtlich ihrer Struktur optimiert. Ziel dieser Modellierung ist der Einsatz der Modelle zur Mehrschrittprädiktion. Da-

mit bilden sie die Grundlage und einen zentralen Teil der im nächsten Kapitel vorgestellten KNN-basierten Regelung. Die Vorgehensweise der Modellbildung und Simulation wird anhand der Daten zweier großtechnischer Anlagen (hier Anlage 1 und Anlage 2) dargestellt.

Die Methodik zur Modellierung wird in den folgenden Abschnitten beschrieben. Zuerst wird die Auswahl der relevanten Meßdaten für die Modellierung bestimmt (Abschnitt 3.1). Dann wird die Verwendung verschiedener Netzarchitekturen zu dynamischen Systemmodellierung diskutiert (Abschnitt 3.2) und eine Modellierung mit zwei Netzarchitekturen durchgeführt (Abschnitt 3.3 und Abschnitt 3.4). Abschnitt 3.5 beschreibt dann die Simulationsergebnisse der so gewonnenen Modelle.

3.1 Auswahl und Repräsentation der Meßdaten

Zunächst wird eine Datenanalyse durchgeführt, um eine möglichst redundanzfreie Datenrepräsentation als Eingabe für die Modelle zu erhalten. Die Vorgehensweise wird exemplarisch an den Daten der Anlage 1 demonstriert. Im Anhang finden sich zusammengefaßt die Ergebnisse für die Daten der Anlage 2.

3.1.1 Erfassung der Meßdaten

Ein Datensatz der Anlage 1 umfaßt 28 Meßgrößen, die über einen Zeitraum von acht Tagen alle zehn Sekunden gemessen wurden. Auf diese Weise wurden rund 70.000 Datensätze für die Erstellung eines Modells erhalten. Dieser Datenumfang eignet sich gut zu Analyse Zwecken.

Die Meßgrößen lassen sich in folgende Gruppen unterteilen:

- Stellgrößen (Luftzufuhr, Gasbrenner, Rost- und Aufgabegeschwindigkeit)
- Größen zur Ermittlung der Verbrennungsleistung (Dampfmenge, O₂-Gehalt, Feuerraumtemperaturen)
- Größen zum Erfassen der Belastung der Anlagenkomponenten (Druck, Rosttemperatur)

Eine genaue Beschreibung der Parameter findet sich in Anhang (8.1 und 8.2).

3.1.2 Auswahl relevanter Eingabeparameter

Ein Modell erfordert eine geeignete Datenrepräsentation als Eingabe. Die Vielzahl der Parameter muß auf eine verarbeitbare Menge reduziert werden. Die meisten Verfahren zum datenbasierten Training von nichtlinearen Modellen gehen davon aus, daß die relevanten Eingabeparameter bekannt sind. Bei der Modellierung des Müllverbrennungsprozesses sind die relevanten Eingabevariablen und ihr zeitlich relevantes Auftreten allerdings aufgrund der Komplexität und

der Dynamik des Prozesses a priori nicht gegeben. Mehrere Methoden eignen sich zur Bestimmung der relevanten Eingabeparameter:

1. Eine manuelle Auswahl der Daten aufgrund von Expertenwissen über die Relevanz einzelner Parameter wird durchgeführt. Hier werden also a priori nichtrelevante Daten eliminiert.
2. Alle Eingabevariablen werden für das Modell verwendet. Dadurch entstehen hochdimensionierte Netze, die ein suboptimales Lernen und einen hohen Trainingsaufwand zur Folge haben.
3. Eine systematische Auswahl an Eingabevariablen wird verwendet. Bei einer kleineren Menge von Eingabevariablen ist dies möglich und führt dazu, daß jede Auswahl umfassend ausprobiert und getestet werden kann.
4. Die Eingabeparameter werden komprimiert, um eine (nicht)-lineare Kombination des Eingaberaumes zu erhalten (Hauptkomponentenregression, neuronale Komprimierung [56][15][79][80]). Durch die Kompression können wichtige Informationen und auch die Interpretierbarkeit der resultierenden Eingabedaten verlorengehen.
5. Die relevanten Eingabevariablen werden durch Minimierung des Modellfehlers mit Hilfe von automatischen Methoden ausgewählt. Bei nichtlinearen Anwendungen führt dies zu einer Optimierung der Netzstruktur. Dies erfordert eine Suche in einem großen Suchraum, die mit heuristischen Methoden (z.B. genetischen Algorithmen,[5][34]) durchgeführt werden kann.

Die Methoden 1, 4 und 5 werden auf ihre Eignung für die Modellierung geprüft. Schließlich wird eine Kombination dieser Methoden eingesetzt.

3.1.2.1 Abschätzung der Redundanz

In diesem Unterabschnitt wird die Dimension der Eingabeparameter des Modells bestimmt. Hierbei wird die Redundanz der Größen eines Datensatzes, sowie Redundanz der Größen aufeinanderfolgender Datensätze (Kreuzkorrelation) untersucht, um die Möglichkeit der Datenkompression auf ihre Eignung zu testen.

Die Meßdaten werden vor ihrer Weiterverarbeitung standardisiert, d.h. neu skaliert, so daß ihr Mittelwert Null ist, und ihre Standardabweichung Eins. Aus Gründen der Redundanz wird der Mittelwert aus sechs aufeinanderfolgenden Datensätzen bestimmt, da eine Aktualisierung der Stellgrößen im realen Betrieb einmal pro Minute erfolgt. Die Erfassungsdauer wird auf diese Weise auf einen Datensatz pro Minute reduziert.

Die Korrelationsanalyse dient dem Nachweis von linearen Abhängigkeiten zwischen den Parametern.

Sei $X(t)$ ein (standardisierter und über den Bereich einer Minute gemittelter) Datensatz zum Zeitpunkt t , und $X_i(t)$ die i -te Komponente des Datensatzes. Dann ist ein Koeffizient $K_{i,j}$ der Korrelationsmatrix K bei n Datensätzen definiert durch

$$K_{i,j} = \frac{1}{n} \sum_{t=0}^n X_i(t) X_j(t)^T \tag{3.1}$$

Abbildung 3.1 zeigt signifikante Korrelationen der 28 Parameter untereinander. Ein '+' beschreibt Einträge > 0.9 und '-' beschreibt Einträge kleiner -0.9 .

	tot_air_mass_flow	crude_gas_temp	crude_gas_CO	crude_gas_O	heating_val_correction	steam_mass_flow	steam_nominal_value	prim_air_mass_flow	prim_air_flow_temp	pos_air_flap1	pos_air_flap2	pos_air_flap3	pos_air_flap4	crude_gas_mass_flow	crude_gas_temp_washer	crude_gas_temp_exit	crude_gas_temp_exit2	crude_gas_temp_neck	crude_gas_temp_interface	grid_drive	grid_temp1	grid_temp2	sec_air_mass_flow	ram_drive	gas_mass_flow	main_air_flap	press_combust_chamber	press_crude_gas
tot_air_mass_flow	+	+	+	+
crude_gas_temp	+	+	+	+
crude_gas_CO	.	.	+
crude_gas_O	.	.	.	+
heating_val_correction	+
steam_mass_flow	+
steam_nominal_value	+	+
prim_air_mass_flow	+	+
prim_air_flow_temp
pos_air_flap1
pos_air_flap2
pos_air_flap3
pos_air_flap4
crude_gas_mass_flow	+	+
crude_gas_temp_washer
crude_gas_temp_exit
crude_gas_temp_exit2
crude_gas_temp_neck
crude_gas_temp_interface
grid_drive
grid_temp1
grid_temp2
sec_air_mass_flow
ram_drive
gas_mass_flow
main_air_flap
press_combust_chamber	+
press_crude_gas

Abbildung 3.1: Autokorrelationsmatrix der Prozeßparameter. '+' und '-' beschreiben signifikante positive und negative Korrelationen.

Die Korrelationsmatrix wird im weiteren für die Hauptkomponentenanalyse verwendet (s. folgender Abschnitt). Die Einträge in der Korrelationsmatrix sind minimal minus Eins und maximale Eins. Jeder Parameter ist mit sich selbst korreliert (Kreuze auf der Hauptdiagonalen), aber darüber hinaus treten noch viele Korrelationen auf, die eine Redundanz der Meßwerte implizieren. Diese Redundanzen können mit der im nächsten Abschnitt beschriebenen Hauptkomponentenanalyse eliminiert werden.

3.1.2.2 Datenkompression

Ein Datensatz aus Meßwerten besteht aus 28 Prozeßparametern. Eine Reduktion auf weniger Parameter ist wünschenswert. Daher wird untersucht, ob eine Datenkompression als Vorverarbeitungsschritt sinnvoll ist. Zunächst werden alle Parameter eines Datensatzes einer Hauptkomponentenanalyse (HKA) [32] unterzogen.

Die HKA transformiert Datensätze so, daß die Elemente eines transformierten Datenvektors keine Korrelationen aufzeigen. Zusätzlich wird die Länge (Dimension) der Transformierten dadurch verringert, daß nur solche Komponenten des Eingaberaums abgebildet werden, die einen bestimmten Anteil der Varianz der Originaldaten erzeugen.

3.1.2.3 Erstellung der Transformationsmatrix

Eine Transformation zu Kompressionszwecken wird durch eine Transformationsmatrix A durchgeführt: $X_{trans} = AX$.

A ist eine $(28*m)$ Matrix, bei der das Verhältnis $28:m$ den Kompressionsfaktor definiert. Diese Matrix wird folgendermaßen erstellt:

- Bildung der Korrelationsmatrix K gemäß Formel (3.1).
- Bestimmung der Eigenwerte λ_i und der zugehörigen Eigenvektoren e_i von K . Die Eigenvektoren, deren Eigenwerte groß sind, tragen einen großen Anteil zur Transformation bei.
- Auswahl der Eigenvektoren mit den größten Eigenwerten. Die Anzahl m der ausgewählten Eigenvektoren bestimmt dann die Kompressionsrate.
- Erstellen der Transformationsmatrix A nach der Vorschrift: $A = (e_1, \dots, e_m)$.

Die ausgewählten m Eigenvektoren stellen die Basis der linearen Abbildung dar. Werden alle Eigenvektoren verwendet, erhält man eine quadratische Matrix und die Abbildung ist bijektiv. Zur Datenkompression ist es jedoch zweckmäßig, nur Eigenvektoren mit betragsmäßig großen

Eigenwerten zu verwenden. Dann ist die Transformationsmatrix rechteckig, und die lineare Abbildung nicht mehr bijektiv.

Die Datensätze werden durch die entstehende Transformationsmatrix auf einen Unterraum transformiert, der die Richtungen mit der größten Varianz beibehält. In Abhängigkeit der Ordnung m der Transformationsmatrix ergibt sich eine Abbildung in einen m -dimensionalen Unterraum.

Abbildung 3.2 zeigt, die Varianz der transformierten Daten in Abhängigkeit der Dimension des Bildraums, welche der Ordnung m der Transformationsmatrix entspricht. Die Varianz errechnet sich aus der Summe der (betragsmäßig absteigend sortierten) ersten m Eigenwerte:

$$V(m) = \sum_{i=1}^m e_i \quad (3.2)$$

Die Eigenwerte sind stets reell und nichtnegativ, da die Korrelationsmatrix K symmetrisch und positiv definit ist.

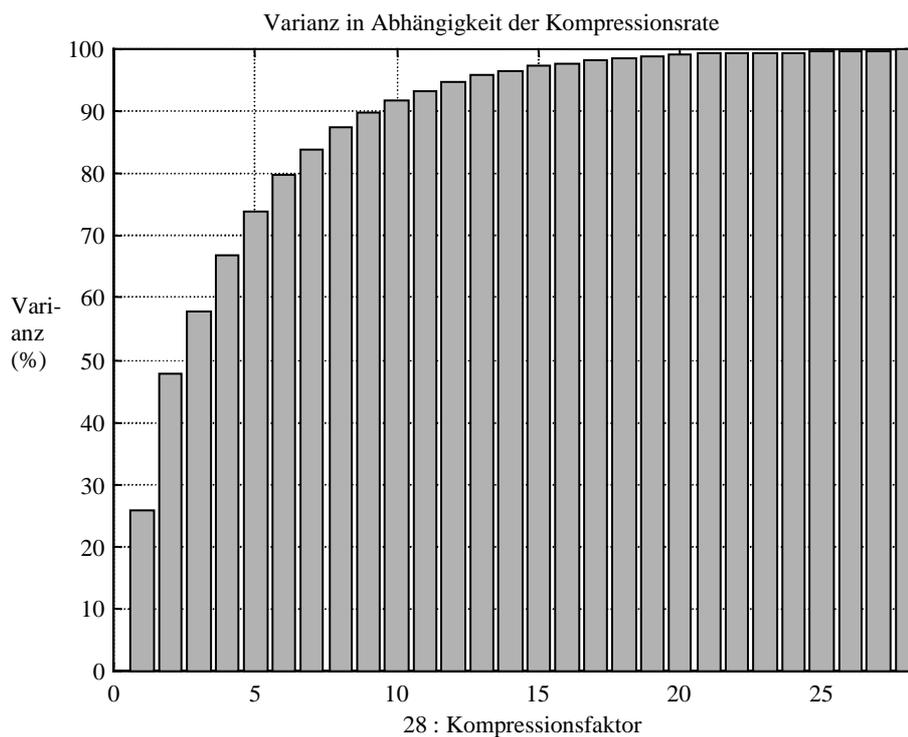


Abbildung 3.2: Varianz der transformierten Daten in Abhängigkeit der Dimension des Bildraums

Es zeigt sich, daß ca. 80% der Varianz der Daten erhalten bleibt, wenn der Bildraum die Dimension $m = 6$ hat, d.h. eine Kompressionsrate von 28:6 gewählt wurde.

Die Transformationsmatrix A ist orthonormal, d.h. die Pseudoinverse ist die Transponierte A^T . Somit kann die Kompressionsqualität der Transformationsmatrix bewertet werden. Nun werden Originaldaten den durch Kompression und Dekompression erzeugten Daten gegenübergestellt. Abbildung 3.3 zeigt exemplarisch an dem Prozeßparameter *Dampfmenge* die Diskrepanz zwischen Originaldaten X und restaurierten Daten $(AA^T)X$ über einen Zeitraum von 200 Minuten im Vergleich.

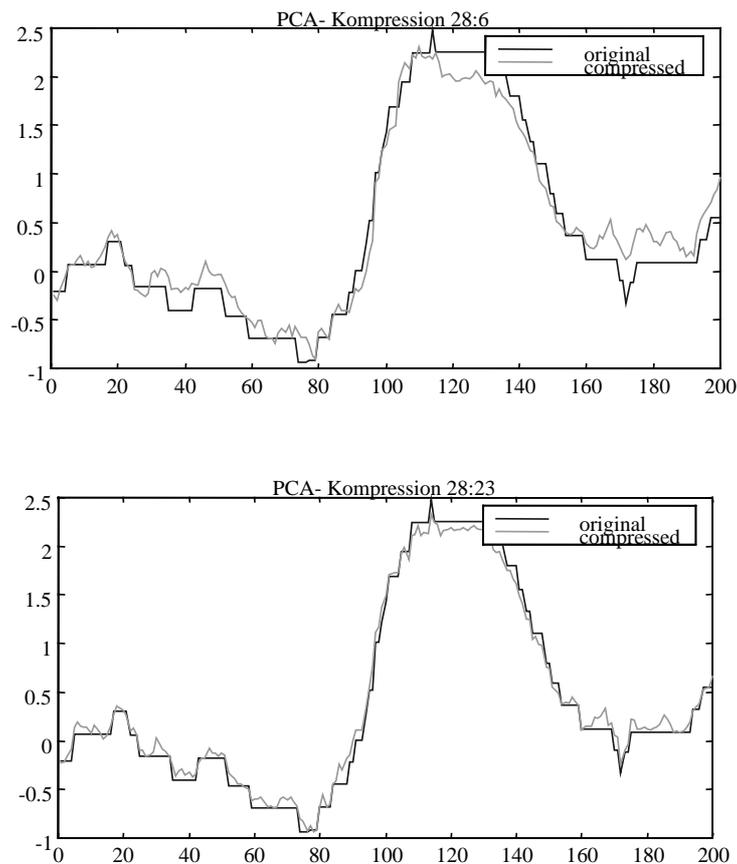


Abbildung 3.3: Vergleich von HKA-Kompression zweier verschiedener Kompressionsfaktoren

Die Erhaltungsqualität bei einer Kompression von 28 auf 6 Dimensionen ist nicht ausreichend. Erst bei einem Rückgang der Kompression von 28 auf 22 Dimensionen ist die Erhaltungsqualität zufriedenstellend. Für diesen geringen Vorteil der Kompression ergibt sich allerdings der Nachteil, daß die erhaltenen Modelleingaben keine semantische Bedeutung besitzen und keinen Prozeßparametern mehr zugewiesen werden können. Daher wird von einer Vorverarbeitung der Meßwerte durch Datenkompression abgesehen. Alternativ läßt sich der Umfang der Meßwerte

durch explizite Streichung nicht sinnvoller Größen reduzieren, was im folgenden Abschnitt beschrieben wird.

3.1.2.4 Auswahl signifikanter Daten

Nun werden spezifische Eigenarten der Anlagen beschrieben, die bei der Modellierung individuell berücksichtigt werden müssen. Bei einer genaueren Betrachtung der Prozeßdaten sind nicht alle gemessenen Daten relevant und brauchen daher zur Modellierung nicht herangezogen werden. Anhang A liefert eine genaue Beschreibung der gemessenen Prozeßdaten. Hier werden nur die Prozeßdaten vorgestellt, die sich für eine Modellierung des Systemzustands und der Eingabegrößen eignen. Diese Auswahl ist in Einklang mit den Parametern, die zur jetzigen Regelung benutzt werden. Betrachtet werden die großtechnischen Anlagen 1 und 2, wobei der Reihe nach die Sollwerte, Stellgrößen und die Zustandsgrößen angegeben werden.

Anlage 1:

Sollwerte:

- Der O_2 -Sollwert ist konstant und wird daher nicht als Prozeßparameter gemessen.
- Parameter 7: Dampfsollwert. Dieser Wert gibt die gewünschte Dampfmenge an. Er wird durch den manuell geschätzten Heizwert des Mülls vorgegeben.

Stellgrößen:

- Parameter 8: Primärluftmenge. Die gesamte Luftmenge, die als Primärluft den Verbrennungsrost beschickt und die zur Kühlung der Seitenwände verwendet wird.
- Parameter 9: Temperatur der Primärluft nach der Vorwärmung.
- Parameter 10: Öffnung von Luftklappe 1 für Zone 1.
- Parameter 11: Öffnung von Luftklappe 2 für Zone 2.
- Parameter 12: Öffnung von Luftklappe 3 für Zone 3.
- Parameter 20: Rostgeschwindigkeit, Geschwindigkeit des Verbrennungsrosts.
- Parameter 23: Sekundärluftmenge.
- Parameter 24: Geschwindigkeit des Aufgabestößels. Diese steuert die dem Rost nachgelieferte Müllmenge.
- Parameter 26: Position der Hauptluftklappe. Die Hauptluftklappe versorgt die Primär- und Sekundärluftzufuhr und ist den Luftklappen 1 – 3 vorgeschaltet.

Zustandsgrößen:

- Parameter 3: Kohlenmonoxidgehalt des Rauchgases nach Passieren des Wärmetauschers. Dieser Parameter wird direkt vor Eintritt in die Rauchgasreinigung gemessen .
- Parameter 4: Sauerstoffgehalt des Rauchgases nach Passieren des Wärmetauschers. Dieser Parameter wird direkt vor Eintritt in die Rauchgasreinigung gemessen.
- Parameter 6: Dampfmenge.
- Parameter 16: Rauchgastemperatur. Gemessen am Ausgang der zweiten Verbrennungskammer.
- Parameter 18: Temperatur des Rauchgases an der Nackenseite der Feuerungskammer.
- Parameter 19: Temperatur des Rauchgases an der Stirnseite der Feuerungskammer.

Für die Anlage 1 werden somit nur 16 Parameter in die weiteren Betrachtungen einbezogen. (Der O₂-Sollwert wird nicht als Prozeßparameter gemessen).

Anlage 2:

Für die Anlage 2 sind 42 Prozeßparameter erhältlich. Der Verbrennungsrost ist zwar in einzelne Segmente aufgeteilt, aber diese werden nicht individuell angesteuert. Die Rostgeschwindigkeit ist konstant. Eine individuell einstellbare Luftzufuhr für jedes Segment ist vorhanden, aber benachbarte Segmente der Zonen 1 und 2 werden gleich versorgt. Segmente der Zonen 3 und 4 werden in der Regel konstant gefahren.

Sollwerte:

- Parameter 41: Sollwert Dampfmenge.
- Parameter 42: Sollwert O₂.

Stellgrößen:

- Parameter 1: Gesamtluft.
- Parameter 2: Sekundärluft.
- Parameter 14: Luftmenge Feld 5_1.
- Parameter 16: Luftmenge Feld 6_1.
- Parameter 23: Drehzahl Aufgaberost.

Zustandsgrößen:

- Parameter 8: Dampfmenge.
- Parameter 9: Temperatur Feuerraum.
- Parameter 11: CO Gehalt des Rauchgases.
- Parameter 32: O₂ Gehalt des Rauchgases.

Für die Anlage 2 werden somit neun Parameter (Stellgrößen und Zustandsgrößen) zur Weiterverarbeitung ausgewählt.

3.1.3 Abschätzung der Modellordnung

Nun wird beschrieben, wie aus den Meßdaten die Dynamik des Prozesses abgeschätzt wird. Die Prozeßdynamik gibt an, in welchem zeitlichen Rahmen Veränderungen in der Vergangenheit den aktuellen Prozeßzustand beeinflussen. In einem ersten Schritt wird die Dynamik mit Hilfe von linearen Methoden abgeschätzt.

Zur Bestimmung der Korrelationen über der Zeit wird eine Kreuzkorrelationsfunktion verwendet. Die Kreuzkorrelation $c_{i,j}$ eines Parameters X_i mit einem Parameter X_j bei einem zeitlichen Abstand Δt bei n Datensätzen ist:

$$c_{i,j}(\Delta t) = \frac{1}{n} \sum_{t=t_0}^n X_i(t) X_j(t - \Delta t) \quad (3.3)$$

Dann werden für die Kreuzkorrelationsmatrix $((c_{i,j}(\Delta t)))$ die signifikanten Einträge gezählt. Die Matrix hat die Größe (28*28). Abbildung 3.4 zeigt die Anzahl der signifikanten Einträge als Funktion des zeitlichen Abstands Δt für die Meßdaten der Anlage 1.

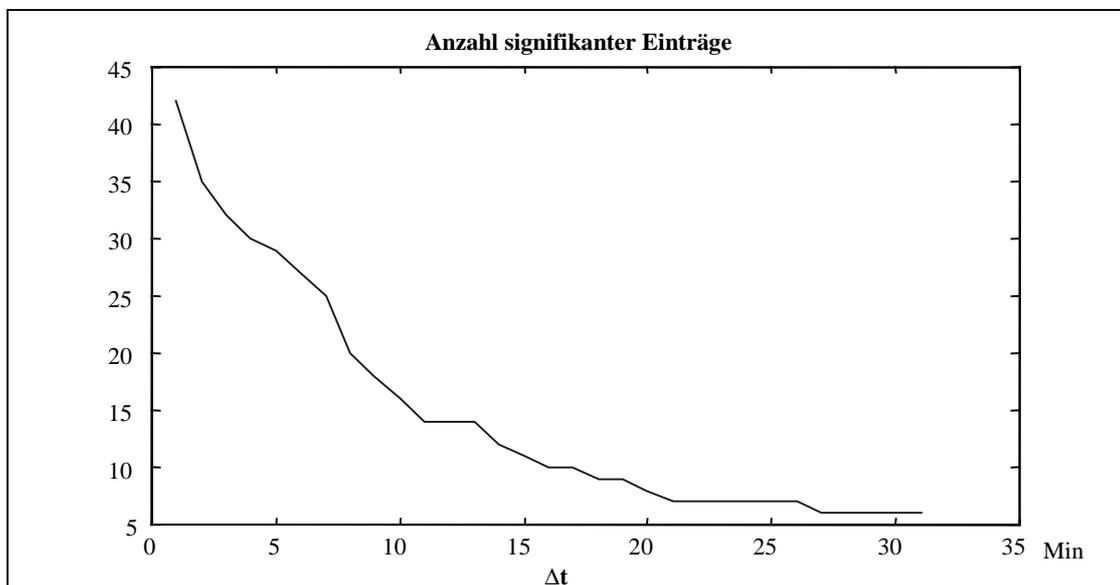


Abbildung 3.4: Korrelation zwischen Datensätzen. Das Diagramm zeigt die Summe der Korrelationen anhand der Einträge in die Korrelationsmatrix.

Es wird deutlich, daß die meisten Korrelationen zwischen den Datensätzen bis zu einem Zeitpunkt von 10 Minuten zurückreichen. Überraschenderweise treten Korrelationen der Prozeßdaten auch über diesen Punkt hinaus bis 30 Minuten auf. Diese Korrelationen sind allerdings auf träge Reaktionen von Thermoelementen zur Rosttemperaturüberwachung zurückzuführen.

Die Ergebnisse zeigen lineare Ursache-Wirkungsbeziehungen (zeitliche lineare Abhängigkeiten) zwischen den Parametern. Nichtlineare Abhängigkeiten zwischen den Parametern lassen sich allerdings mit Korrelationstests nicht nachweisen.

Die lineare Abschätzung der Prozeßordnung zeigt, daß bei einer Beschreibung des Prozeßzustands Parameter mit einer Verzögerung von 10 Minuten berücksichtigt werden müssen. Da aus der expliziten Parameterauswahl ein Datensatz 16 Parameter umfaßt, ergeben sich trotz Zusammenfassung der Daten im Zeitraum einer Minute 160 Eingabeparameter für einen Simulationsschritt, was immer noch zu viel ist. Daher wird nun versucht, eine stärkere Einschränkung der Prozeßordnung durch Untersuchung von linearen Modellen zu finden. Für den Rest des Kapitels werden stets die Meßdaten der Anlage 1 verwendet.

3.1.3.1 Ermittlung linearer Modelle

In diesem Unterabschnitt werden zeitdiskrete lineare Modelle des Prozesses mit verschiedenen Ordnungen erzeugt, um grundlegende Informationen über die Prozeßdaten zu erhalten. Solche Informationen umfassen die Modellgüte in Abhängigkeit der Modellordnung und eine empirische Untersuchung zur Zeitinvarianz des Systems.

Der Vorteil der linearen Modellierung liegt in einer deterministischen und optimalen (hinsichtlich eines linearen Modells) Anpassung der Modellparameter.

3.1.3.2 Ordnung des linearen Modells

Ein einfaches lineares Modell besteht in der linearen, zeitinvarianten Approximation des Übertragungsverhaltens des Prozesses. Dazu wird eine Parameterbestimmung durchgeführt mit dem Ziel, den Modellfehler zu minimieren. Es wird ein zeitinvariantes Ein/Ausgabemodell erzeugt durch:

$$\hat{y}(k+1) = A[y(k)^T, \dots, y(k-N)^T, u(k)^T, \dots, u(k-N)^T]^T + B \quad (3.4)$$

N ist die Ordnung des Modells. \hat{y} ist im folgenden stets eine Modellausgabe. Die Matrizen und Vektoren haben folgende Größen:

$$y \in \mathfrak{R}^{(n_y \times 1)}, u \in \mathfrak{R}^{(n_u \times 1)}, A \in \mathfrak{R}^{(n_y \times N(n_y + n_u))}, B \in \mathfrak{R}^{(n_y \times 1)}$$

Hier ist $y(k)$ der Vektor der Ausgangsgrößen des Prozesses der Größe n_y und $u(k)$ der Stellgrößenvektor zum Zeitpunkt t_k mit der Größe n_u . A ist eine Matrix mit konstanten Koeffizienten und B ist ein Vektor mit konstanten Koeffizienten. A und B werden ermittelt durch Minimieren des quadratischen Fehlers:

$$E = E(A, B) = \sum_k (y(k) - \hat{y}(k))^2 \quad (3.5)$$

Diese Minimierung ist eindeutig, da die quadratische Funktion E konvex ist und stets ein Minimum besitzt, d.h. die Koeffizienten von A und B können eindeutig ermittelt werden. Dies geschieht durch Aufstellen und Lösen der linearen Gleichungssysteme

$$\frac{\partial E}{\partial a_{i,j}} = 0 \quad \text{und} \quad \frac{\partial E}{\partial b_i} = 0 \quad (3.6)$$

Die Qualität der linearen Modelle wird durch den Mean Square Error (MSE) angegeben gemäß:

$$MSE = \frac{1}{T} \sum_{t=0}^T (y(k) - \hat{y}(k))^2, \quad (3.7)$$

mit T = Umfang der Meßdaten. Die Meßdaten wurden in zwei Sätze mit einem Meßdatenumfang von jeweils einer halben Woche aufgeteilt. Datensatz 1 wurde zur Erzeugung von A und B verwendet, und Datensatz 2 ermittelt die Validierungsfähigkeit des linearen Modells. In Abhängigkeit der Modellordnung N ergeben sich folgende Fehler für die linearen Modelle:

MSE	Trainingsfehler (Datensatz 1)	Validierungsfehler (Datensatz 2)
$N=1$	0.004711	0.004815
$N=2$	0.003021	0.003138
$N=3$	0.002956	0.003104
$N=4$	0.002914	0.003078
$N=5$	0.002874	0.003056
$N=6$	0.002843	0.003059

$N=7$	0.002822	0.003077
$N=8$	0.002800	0.003100
$N=9$	0.002778	0.003156
$N=10$	0.002764	0.003165

Tabelle 3.1: Fehler in Abhängigkeit der Modellordnung

Aus Tabelle 3.1 ist ersichtlich, daß die Approximationsgüte von Trainings- und Validierungsdatensatz sich nicht groß unterscheiden, sondern in der selben Größenordnung liegen.

Für die lineare Modellbildung und auch für die weitere Verarbeitung wurden die Daten normiert, so daß das Maximum eines jeden Parameters bei 1.0 liegt und die minimale Ausprägung bei 0.0, d.h. der Wertebereich der normierten Werte liegt jeweils zwischen 0 und 1. Somit kann der MSE auf eine prozentuale Abweichung umgerechnet werden:

$$\text{Fehler (in \%)} = 100 * \sqrt{MSE} \quad (3.8)$$

d.h. ein MSE von 0.00474 entspricht einer mittleren Abweichung der Modellausgabe vom realen Wert um 2.8% pro Modellausgabe.

Die Validierungsfähigkeit verschlechtert sich wieder ab $N = 5$. Ab $N = 2$ tritt keine nennenswerte Verbesserung des Modells mehr auf. Der MSE verringert sich durch Einbeziehung der letzten acht Zustände nur um weitere 10%.

Die linearen Modelle stellen eine untere Abschätzung der Modellgüte dar, an der sich die Modellgüte nichtlinearer Modelle messen läßt. Dies ist erforderlich, da eine optimale Parameter-einstellung nichtlinearer Modelle oft nicht realisierbar ist und eine suboptimale Lösung bei dem Einsatz heuristischer Suchstrategien auftreten kann.

Die Erhöhung des Validierungsfehlers ab der Ordnung $N=5$ gibt Anlaß, dies als obere Schranke der Modellordnung für eine später durchzuführende nichtlineare Modellierung zu verwenden.

3.1.3.3 Zeitinvarianz

Eine Modellierung mit einem zeitinvarianten Modell ist nur sinnvoll, wenn der zu modellierende Prozeß auch zeitinvariant ist.

Im folgenden soll untersucht werden, inwieweit ein lineares Modell in verschiedenen Prozeß-situationen gültig ist. Dies läßt sich dann zu einer Aussage über die Zeitvarianz/ -invarianz des Modells bzgl. der Daten formulieren.

Für die zu untersuchende Zeitinvarianz werden Prozeßdaten der Anlage 1 verwendet. Die Modelle wurden aus Datensatz 1 und Datensatz 2 zusammengestellt. Aus beiden wird die Matrix A und der Bias B für ein Modell gemäß Formel (3.6) erzeugt.

Die Modelleingabe besteht aus fünf aufeinanderfolgenden Datensätzen aus jeweils 16 Parametern (den Stellgrößen), die Ausgabe besteht aus 6 Parametern (den Ausgangsgrößen der Daten aus Anlage 1). D.h. die Matrix A ist eine 6×80 Matrix.

Abbildung 3.5 zeigt die Matrix A , erzeugt aus Datensatz 1. Zum Zwecke der Übersichtlichkeit werden die Matrixeinträge durch Graustufen dargestellt, die anhand der Legende in Zahlenwerte umgewandelt werden können.

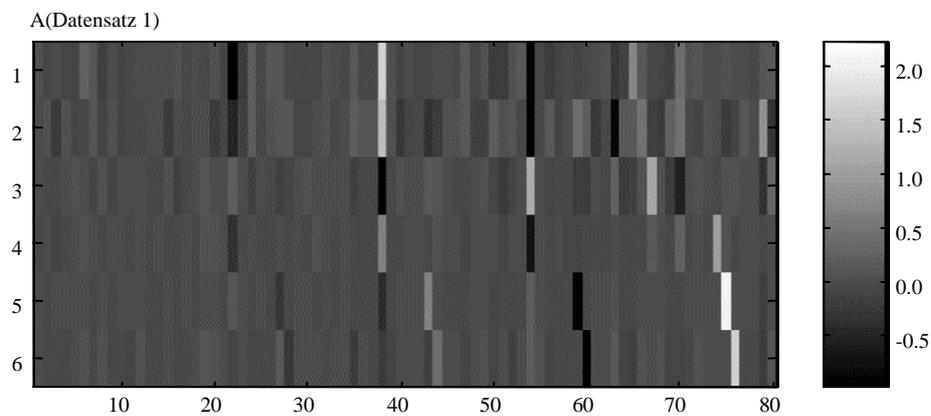


Abbildung 3.5: Grafische Darstellung der Matrixkoeffizienten von Matrix A

Abbildung 3.6 zeigt die Matrix A_2 , erzeugt aus Datensatz 2.

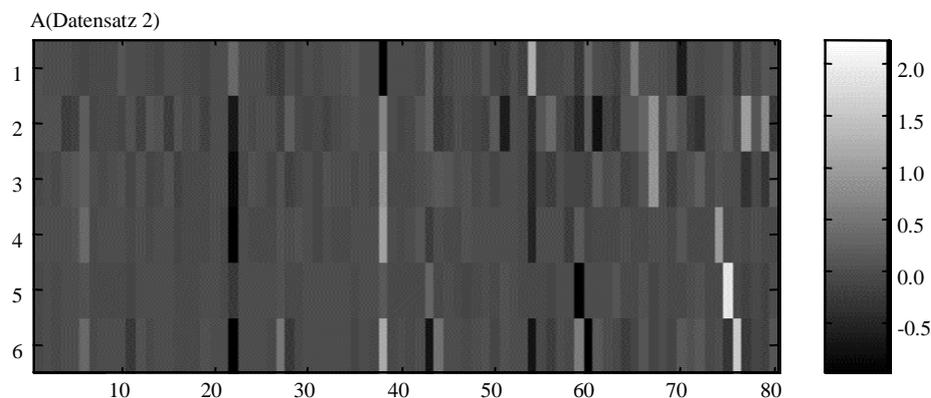


Abbildung 3.6: Grafische Darstellung der Matrixkoeffizienten von Matrix A_2

Die Differenz zwischen den Matrizen A und A2 ist in Abbildung 3.7 zu sehen.

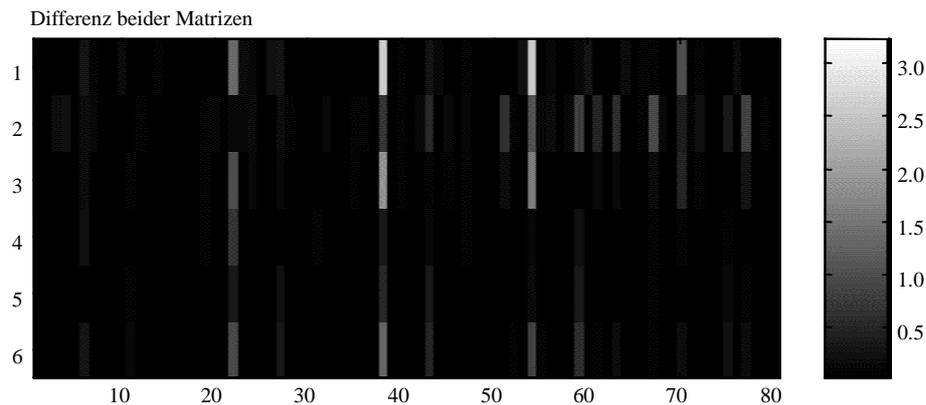


Abbildung 3.7: Differenz der Matrizen A und A2

Abbildung 3.7 verdeutlicht, daß die Matrizen in ihrer Struktur sich stark ähneln. Ein schwarzer Eintrag bedeutet keine Differenz zwischen den Einträgen. Der größte betragsmäßige Unterschied beträgt 2.8. Somit offenbart die Matrix invariante Strukturen in den Daten, und der Einsatz zeitinvarianter Modelle ist sinnvoll.

Für den im folgenden Abschnitt beschriebenen Einsatz nichtlinearer Modelle sind somit folgenden Konfigurationsparameter bekannt:

- Typ des Modells: zeitinvariant
- Ordnung des Modells: ≤ 5
- Ausahl der Eingabeparameter nach 3.1.2.4

3.2 Ermittlung nichtlinearer Modelle

Im vorigen Abschnitt wurde der Prozeßzustand als Linearkombination vorheriger Ein- und Ausgänge dargestellt (s. Gl. (3.4)).

In diesem Abschnitt wird der Einsatz nichtlinearer Modelle diskutiert. Sie versprechen eine bessere Abbildung auf den nichtlinearen Prozeß der Müllverbrennung. Zuerst werden verschiedene Typen nichtlinearer Modelle vorgestellt und dann die Auswahl eines Netztyps vorgenommen.

3.2.1 Typen nichtlinearer Modelle

Bei der nichtlinearen Modellierung wird die Matrix A ersetzt durch eine nichtlineare Abbildung der Eingabeparameter auf den Ausgangszustand, d.h. der Müllverbrennungsprozeß wird als eine diskrete nichtlineare zeitinvariante Eingabe-Ausgabecharakteristik betrachtet.

$$\hat{y}(k+1) = f(y(k), y(k-1), \dots, y(k-N), u(k), u(k-1), \dots, u(k-M)) \quad (3.9)$$

Wie bei der linearen Modellierung wird nicht von einem Zustandsraummodell ausgegangen, sondern von einem einfachen Ein/Ausgabemodell. Narendra [75] schlägt vier charakteristische Modelltypen für diskrete nichtlineare zeitinvariante Systeme vor. Modell I geht von einer linearen Kombination der Ausgangsgrößen aus:

$$\text{(Modell I)} \quad \hat{y}(k+1) = \sum_{i=0}^N A_i * y(k-i) + g(u(k), u(k-1), \dots, u(k-N)) \quad (3.10)$$

Modell II, das von einer linearen Abhängigkeit der Stellgrößen ausgeht, eignet sich für die Auslegung von Steuerungen, da das Verfahren zur Erzeugung der Stellgrößen für diesen Fall bekannt ist [76].

$$\text{(Modell II)} \quad \hat{y}(k+1) = f(y(k), y(k-1), \dots, y(k-N)) + \sum_{i=0}^M B_i * u(k-i) \quad (3.11)$$

Modell III basiert auf einer linearen Trennung von Rückkopplung und Steuerung.

$$\text{(Modell III)} \quad \hat{y}(k+1) = f(y(k), y(k-1), \dots, y(k-N)) + g(u(k), u(k-1), \dots, u(k-M)) \quad (3.12)$$

Modell IV ist eine Verallgemeinerung der Modelle I-III. Dieses Modell wird dem Verbrennungsprozeß zugrunde gelegt.

$$\text{(Modell IV)} \quad \hat{y}(k+1) = f(y(k), y(k-1), \dots, y(k-N), u(k), u(k-1), \dots, u(k-M)) \quad (3.13)$$

In den Modellen I-IV bezeichnen f und g die nichtlinearen Funktionen und die Matrizen A_i und B_i die zu bestimmenden Parameter. Die Identifizierung besteht in der Abschätzung der Parameterwerte und dem Aufbau der Funktionen f und g .

Bei allen Modellen wird die Anlage als kausal betrachtet. Jede nichtlineare Anlage kann mit Modell IV beschrieben werden. Ist allerdings bekannt, daß die Anlage einem anderen Modell entspricht, so ist dessen Verwendung wünschenswerter, denn Modell IV liefert wenig Informationen über die Anlagenstruktur. Bei dem Modell des nichtlinearen Prozesses der Müllverbrennung muß allerdings von einer Struktur nach Modell IV ausgegangen werden. Die Funktion f aus (3.13) wird im folgenden durch ein künstliches Neuronales Netz (KNN) realisiert. Der zeitliche Horizont der Berücksichtigung von Stellgrößen und Ausgabegrößen wird als gleich vorausgesetzt (d.h. $N = M$):

3.2.2 Auswahl eines geeigneten Netztyps

Es gibt zwei Arten von KNNs, die oft im Zusammenhang mit der Identifikation von dynamischen Systemen zum Einsatz kommen:

- Feedforward-Netze (Multilayer Perceptrons, MLP) und
- Rekurrente Netze.

Bei rekurrenten Netzen ist die Dynamik im Netz selbst realisiert, während Feedforward-Netze statische nichtlineare Abbildungen darstellen. Feedforward Netze können extern mit einer Dynamik versehen werden, indem die Modellausgabe zurück zur Eingabe geleitet wird. In dieser Arbeit werden ausschließlich statische Netze als Ein-Ausgabemodell mit einer externen Dynamik verwendet.

Im folgenden Abschnitt werden statische Netzarchitekturen und ihr Einsatzgebiet diskutiert.

3.2.2.1 Feedforward-Netze/Multilayer Perceptrons

In *Feedforward*-Netzen sind die einzelnen Schichten vollständig mit den nachfolgenden Schichten verbunden. Die Netzausgabe wird unter Verwendung aller Neuronen und Gewichte berechnet, so daß die Änderung eines einzigen Gewichts das gesamte Ausgabeverhalten beeinflussen kann. Aufgrund dieser globalen Darstellung ist eine Erklärbarkeit des Ausgabeverhaltens problematisch. Andererseits erlaubt die kompakte Struktur des Netzes die Modellierung von Systemen mit hochdimensionalem Eingaberaum. Die Strukturparameter bei diesem Netztyp umfassen die Anzahl der versteckten Neuronen (*hidden neurons*) und versteckten Schichten (*hidden layers*). Sie sind wichtig für das Verhalten des Netzes. Ist keine ausreichende Anzahl

von Neuronen im *hidden layer* vorhanden, kann das funktionelle Verhalten nicht ausreichend gut vom Netz approximiert werden. Sind zu viele Neuronen im *hidden layer* vorhanden, werden die Daten, mit denen das Netz trainiert wurde, gut approximiert, während die Validierungsdaten schlecht approximiert werden. Das Netzverhalten zeigt eine schlechte Generalisierung.

3.2.2.2 Selbstorganisierende Karten

Selbstorganisierende Karten (Kohonenetze) [55] sind Netze mit lokaler Zuständigkeit. Lokale Zuständigkeit bedeutet, daß bei der Berechnung einer Ausgabe die jeweiligen Eingabedaten einzelnen Neuronen zugeordnet werden. Kohonenetze eignen sich hier nur bedingt als Simulationsmodell, da ihre Anzahl der Neuronen exponentiell mit der Anzahl der Eingabeparameter und folglich mit der Eingabedimension zunimmt.

Die Datenverarbeitung mit Kohonenetzen (SOFM = Self Organizing Feature Maps) erfolgt unüberwacht. Die Selbstorganisation dieses Netztyps besteht in dem automatischen Nachweis der (nichtlinearen) Untermannigfaltigkeit der Daten. Das Ausgabeverhalten ist nicht festgelegt, kann jedoch leicht hinzugefügt werden. Im Falle einer konstanten Ausgabe pro Neuron erhält man ein Counterpropagation-Netz [30]. Das Netz verwendet als Lerngesetz das "winner-takes-it-all" Prinzip. Das heißt, daß nur ein Neuron aktiviert wird. Die Ausgabe des Netzes entspricht also der Aktivierung eines einzigen Neurons. So wird eine diskrete Ausgabe erzeugt. Die Qualität der Approximation hängt dann nur von der Darstellungsdichte des Netzes im Eingaberaum und somit von der Anzahl der Neuronen ab. Je höher die Anzahl der Neuronen ist, um so besser ist das Ergebnis. Ein anderer zu berücksichtigender Parameter ist die topologische Dimension des Netzes, welche mit der topologischen Dimension des Eingaberaums übereinstimmen sollte.

3.2.2.3 Radiale Basisfunktionen

Netze mit Radialen Basisfunktionen (RBF-Netze) stellen eine Mischung zwischen einer lokalen und einer globalen Darstellung dar, denn mehrere Neuronen haben in Abhängigkeit von ihrer Entfernung zum Aktivierungszentrum, das den rezeptiven Feldern der einzelnen Neuronen zugeordnet wird, mit ihrer Ausgabe Anteil an einer Netzausgabe. Im Gegensatz zu Kohonenetzen ist die Ausrichtung der Aktivierungszentren der Neuronen nicht Bestandteil des Lernverfahrens. Sie müssen manuell ausgerichtet werden, bzw. werden in einer vorhergehenden Trainingsphase wie Kohonenetze selbstorganisiert.

In den folgenden zwei Abschnitten wird die Modellierung mit Multilayer Perceptrons und mit Radialen Basisfunktionen beschrieben.

3.3 Modellierung mit Multilayer Perceptrons

Das Multilayer Perceptron ist ein vorwärtsgerichtetes KNN, das eine Eingabeschicht, einen oder mehrere versteckte Schichten (hidden Layers) und eine Ausgabeschicht besitzt. Jede Schicht besteht aus einer Menge von Funktionseinheiten, den Neuronen. Dabei übernehmen die Neuronen der Eingabeschicht lediglich die Funktion der Weiterleitung der von außen angelegten Signale an die nächste Schicht, d.h. die Übertragungsfunktion der Neuronen der Eingabeschicht ist die Identität.

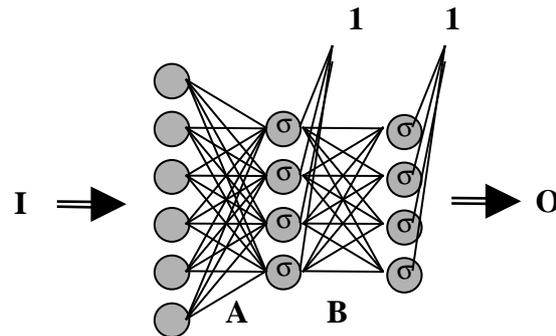


Abbildung 3.8: Aufbau eines Multilayer-Perceptrons mit einer versteckten Schicht und sigmoider Aktivierungsfunktion. A und B sind die Gewichtsmatrizen.

Abbildung 3.8 zeigt ein Multilayer Perceptron mit sechs Eingängen einer versteckten Schicht mit vier Neuronen und einer Ausgabeschicht aus vier Neuronen. Die Neuronen sind durch Gewichte miteinander verbunden. Die Neuronen der versteckten und der Ausgabeschicht sind mit einer (nichtlinearen) sigmoiden Funktion versehen, die die eigentlichen nichtlinearen Verarbeitungseinheiten sind. Die sigmoide Funktion hat die Form

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (3.14)$$

und wird für die Verarbeitung von Vektoren X der Länge n zu folgender Form erweitert:

$$\sigma(X) = [\sigma(x_1) \ \sigma(x_2) \ \dots \ \sigma(x_n)]^T \quad (3.15)$$

Unter Vorgabe eines Eingabevektors I errechnet sich die Ausgabe bei einem MLP mit einer versteckten Schicht zu:

$$O = f(I) = \sigma(B\sigma(AI)) \quad (3.16)$$

Beim Einsatz KNNS werden zwei Betriebsmodi unterschieden:

1. Trainingsphase
2. Arbeitsphase

Die Trainingsphase dient der Einstellung der Gewichte zur Erzeugung der Approximation der gewünschten Nichtlinearität und in der Arbeitsphase wird das trainierte Verhalten durch Anlegen von Eingabemustern evaluiert.

3.3.1 Training von Multilayer Perceptrons

Training von MLPs ist eine Vorgehensweise zur geeigneten Bestimmung der Gewichte mit dem Ziel, den Fehler zwischen Ausgabe des Netzes und Ausgabe der Trainingsdatenmenge zu minimieren. Hierzu existieren verschiedene Varianten [40]:

1. Gradientenabstiegsverfahren
2. Newton-Verfahren
3. Levenberg-Marquardt Methode

Aufgrund der Größe der hier verwendeten Netze kommen nur die Gradientenabstiegsverfahren in Betracht, da für die Methoden (2) und (3) der Speicheraufwand quadratisch zur Anzahl der Gewichte steigt.

Alle hier durchgeführten Trainings wurden mit dem Stuttgarter Neuronale Netze Simulator (SNNS) [110] durchgeführt.

3.3.1.1 Gradientenabstiegsverfahren

Zu einem Anfangszustand sind die Gewichte eines Netzes zufällig initialisiert. Eine Optimierung der Gewichte findet durch Gradientenabstiegsverfahren statt, was mit Training bezeichnet wird. Gesucht sind Werte der Gewichte, mit denen das Netzwerk eine vorgegebene Anzahl von Eingabemustern X^v in vorgegebenen Ausgabemuster Y^v , $v = 1 \dots p$ abbildet. Hierfür wird ein Eingabemuster an das Netz gelegt, und dieses Muster gemäß der Formel (3.16) durch das Netz propagiert. Am Netzausgang wird aus der Differenz zu der gewünschten Ausgabe die Fehlerfunktion berechnet:

$$E = \frac{1}{2} \sum_{v=1}^p \sum_i (Y_i^v - f_i(X^v))^2 \quad (3.17)$$

Dann wird der Gradient der Fehlerfunktion bezüglich der Gewichte gebildet, und die Gewichte in Richtung des Gradienten aktualisiert.

Bei Standard-Backpropagation wird dieser Gradient mit einer konstanten Lernrate multipliziert. Andere Lernverfahren wählen ein anderes Maß für den Betrag des Gradienten. Lernverfahren zweiter Ordnung beziehen das vorherige Aktualisieren der Gewichtsfunktion in die Ermittlung der aktuellen Schrittweite mit ein.

Zum Training wird neben Standard Backpropagation der Lernalgorithmus Rprop verwendet (Resilient Backpropagation [90]). Ein Vorteil dieses Algorithmus besteht in der automatischen Einstellung der Trainingsparameter. Heuristiken, wie z.B. die Einstellung der Lernrate, sind daher nicht erforderlich. Andere Vorteile bestehen in seiner gleichmäßigen Konvergenz über das Netz und seiner gewöhnlich guten Konvergenz unter den Gradientenabstiegsverfahren.

3.3.1.2 Qualitativer Vergleich von Standard Backpropagation und Rprop

Um die Leistungsfähigkeit von Rprop gegenüber Standard – Backpropagation zu untersuchen, wird im folgenden eine empirische Studie zum Trainingsverhalten beider Gradientenabstiegsverfahren durchgeführt. 300 Netze mit gleicher Topologie und zufälliger Initialisierung werden mit einem Trainingsdatensatz der Anlage 1 (Datensatz 1) trainiert und der Fehler in Abhängigkeit der durchlaufenen Lernzyklen aufgezeichnet. Jedes Netz enthält eine Schicht aus zehn versteckten Neuronen. Abbildung 3.9 und Abbildung 3.10 zeigen den Trainingsfehler und die Varianz.

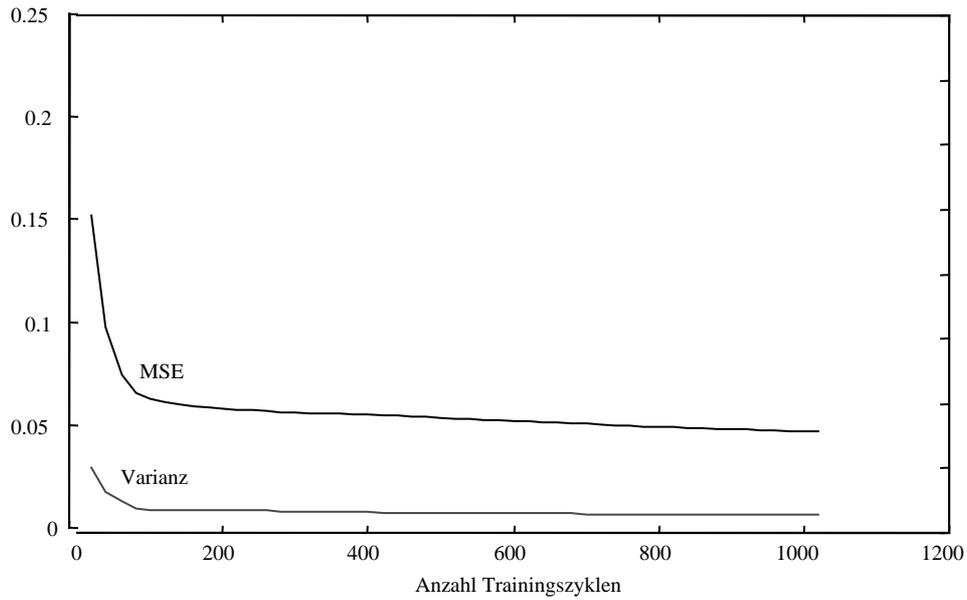


Abbildung 3.9: Durchschnittsfehler und Varianz des Fehlers beim Trainieren von 300 Netzen mit Standard-Backpropagation.

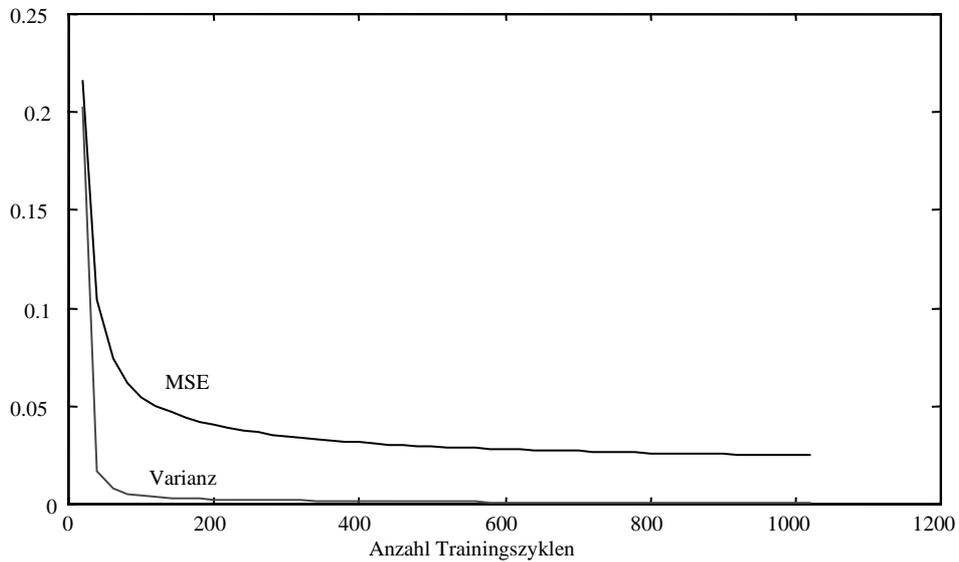


Abbildung 3.10: Durchschnittsfehler und Varianz des Fehlers beim Trainieren von 300 Netzen mit Rprop.

Die Abbildungen zeigen, daß der MSE beim Training mit Rprop (0.0226 nach 1000 Trainingszyklen) viel geringer als beim Training mit Standard Backpropagation ist (0.05 nach 1000 Trai-

ningszyklen), und die Varianz sogar gegen Null geht. Die fast verschwindende Varianz der Trainingsqualität bei Rprop bedeutet, daß unabhängig von der Initialisierung vor der Trainingsphase das Training von gleicher Qualität ist. Somit ist es nicht erforderlich, mehrere Netze mit unterschiedlicher Initialisierung zu trainieren, da ein Training ausreicht, um ein typisches Trainingsergebnis zu erzielen.

Die geringe Varianz des Trainingsfehlers bei Rprop verleitet zu der Annahme, daß das globale Minimum der Fehlerfunktion gefunden wurde. Diese Vermutung wird nun überprüft.

3.3.1.3 Vergleich von Gradientenabstiegsverfahren mit globaler Optimierung

Im folgenden wird überprüft, wie nahe Gradientenabstiegsverfahren ein globales Minimum der Fehlerfunktion approximieren. Ein Netz mit nur zwei Schichten wird trainiert. Die erste Schicht hat nur die Aufgabe, die Eingangssignale an die zweite Schicht zu verteilen. Die Nichtlinearität in Form einer sigmoiden Funktion sitzt an der Ausgabe der zweiten Schicht. Abbildung 3.11 zeigt die Konfiguration des verwendeten Netzes.

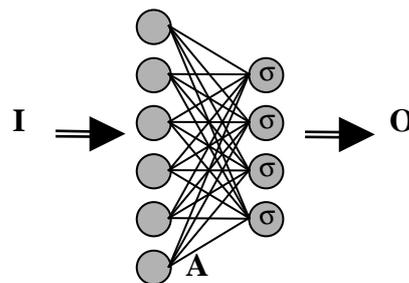


Abbildung 3.11: Schema eines zweischichtigen Netzes mit einer nichtlinearen Ausgabeschicht

Es gilt:

$$O = \sigma(AI) \quad (3.18)$$

mit

$$\sigma(x) = 1/(1 + e^{-x}) \quad (3.19)$$

Der Eingavektor I wird mit der Gewichtsmatrix A multipliziert und das Ergebnis mit der sigmoiden Funktion σ verknüpft. Das Netz stellt eine nichtlineare Abbildung von I nach O dar. Ein Training entspricht dem Optimieren der Gewichte, um den Modellfehler zu minimieren. Die Gewichte gehen nichtlinear in die Fehlerfunktion ein.

Ein Training mit Standard Backpropagation ergibt bei 1000 Trainingszyklen einen MSE von 0.0038, Rprop erzeugt einen MSE von 0.002. Das globale Minimum der Fehlerfunktion läßt sich aber explizit angeben. Es werden neue Ausgabedatensätze $P := \sigma^{-1}(O)$ definiert. σ ist bijektiv im Bereich $x \in (0,1)$, und die Daten werden auf diesen Bereich normiert. Dann ist als $P=A*I$. Nun lassen sich die Matrixkoeffizienten zur Minimierung des MSE zwischen P und der Ausgabe des linearen Modells nach Gl. (3.6) eindeutig bestimmen. Der MSE liegt bei der expliziten Gewichtsbestimmung bei 0.0012. Also ist schon bei relativ einfachen Netzen das globale Minimum durch Gradientenabstieg nicht erreicht worden. Soviel zur qualitativen Bewertung von Gradientenabstiegsverfahren zur Fehlerminimierung.

Durch die schlechten Konvergenzeigenschaften von Gradientenabstiegsverfahren sollten generell Newton-Verfahren oder Levenberg-Marquardt Verfahren eingesetzt werden, sofern dies der Speicherbedarf zuläßt.

3.3.2 Repräsentation der Daten für die nichtlineare Modellierung

Bisher wurden die Daten direkt als Modellein- und ausgabe verwendet. Wie in Abschnitt 3.1 gezeigt wurde, sind die Daten stark untereinander, und in Serie aufeinanderfolgender Datensätze korreliert. Letzteres bedeutet, daß aufeinanderfolgende Daten einander ähnlich sind. Somit ist die Modellbildung hinsichtlich eines MSE dadurch gefährdet, daß die Identität (als ein triviales und falsches Modell) einen geringen MSE, und somit ein gutes Ergebnis liefert. Abhilfe schaffen Modelle unter Verwendung der numerischen Ableitung (Differenzenquotienten). Sie sind überlegen, was die Konvergenz von Optimierungsalgorithmen betrifft, denn numerische Ableitungen aufeinanderfolgender Ordnungen sind weniger stark korreliert [35].

Beweis: Es wird eine Reihe einer Prozeßgröße x_t, x_{t-1} betrachtet. Sei der Mittelwert dieser Variablen Null, die Varianz von x $V(x)$ und die Kovarianz zweier Parameter x,y gleich $Cov(x,y)$. Der Korrelationskoeffizient zwischen x_t und x_{t-1} ergibt sich fast zu Eins (3.20).

$$r_t = r(x_t, x_{t-1}) = \frac{Cov(x_t, x_{t-1})}{\sqrt{V(x_t)V(x_{t-1})}} = \frac{Cov(x_t, x_{t-1})}{V(x)} \approx 1 \quad (3.20)$$

Der Korrelationskoeffizient zwischen x_t und der ersten numerischen Ableitung $x_t^{(1)} = (1/\Delta_t)(x_t - x_{t-1})$ ist

$$r(x_t, x_t^{(1)}) = r(x_t, \frac{1}{\Delta_t}(x_t - x_{t-1})) \quad (3.21)$$

$$\begin{aligned}
&= \frac{\text{Cov}(x_t, x_t - x_{t-1}) / \Delta_t}{\sqrt{V(x_t)V(x_t - x_{t-1})} / \Delta_t} \\
&= \frac{\text{Cov}(x_t, x_t) - \text{Cov}(x_t, x_{t-1})}{\sqrt{V(x)2V(x)}}.
\end{aligned}$$

Aus der Definition von r_t ist dies gleich $\frac{V(x) - r_t V(x)}{V(x)\sqrt{2}} = \frac{1 - r_t}{\sqrt{2}} \approx 0$, da r_t nahe bei Eins liegt.

Der Einsatz der numerischen Ableitung entspricht einer Orthogonalisierung von Eingabe- und Ausgabedatensatz. Die sich ergebende verbesserte Konvergenz durch Einsatz numerischer Ableitungen beim Optimieren (Training) wird später an praktischen Ergebnissen demonstriert.

Es ergeben sich zwei neue Varianten der Datenrepräsentation für das Modell IV. Im folgenden sei $\Delta y(k) = y(k) - y(k-1)$.

1. Variante: Anstelle eines neuen Datensatzes wird die Differenz zum alten Datensatz als Modellausgabe verwendet:

$$\Delta \hat{y}(k) = f(y(k-1), \dots, y(k-N), u(k-1), \dots, u(K-N)) \quad (3.22)$$

2. Variante: In der Modelleingabe werden numerische Ableitungen aufeinanderfolgender Datensätze verwendet:

$$\Delta \hat{y}(k) = f(y(k-1), \Delta y(k-2), \dots, \Delta y(k-N), u(k-1), \dots, \Delta u(k-N)) \quad (3.23)$$

Für das nun durchgeführte Training werden diese Varianten hinsichtlich einer Konvergenzbeschleunigung verglichen.

3.3.2.1 Durchführung des Trainings

Ein trainiertes KNN sollte neben der Reproduktion des Gelernten auch neue Daten möglichst gut reproduzieren. Diese Fähigkeit heißt Generalisierung. Die Generalisierungsfähigkeit eines KNN hängt ab von der Anzahl der Trainingszyklen und der Anzahl der versteckten Neuronen. Ist beides zu hoch, so ist das Netz zu stark spezialisiert. Das Finden der optimalen Anzahl an Trainingszyklen sowie das Bestimmen der optimalen Anzahl der versteckten Neuronen wird nun diskutiert und experimentell anhand von Daten der Anlage 1 ermittelt.

Anzahl der Trainingszyklen

Bei dieser Anwendung, bei der die Datensätze in großer Menge zur Verfügung gestellt werden, wird nur ein Teil aller möglichen Muster für das Training verwendet. Um die beste Generalisierung zu erreichen, werden die Prozeßdaten in drei Teile aufgeteilt:

- Der **Trainingssatz** dient zum Trainieren eines KNN. Der Fehler zwischen Netzausgabe und tatsächlicher Ausgabe dieses Datensatzes wird im Laufe des Trainings minimiert.
- Der **Validierungssatz** wird zur Bestimmung der Leistung eines KNN verwendet. Er besteht aus Mustern, die nicht zum Training verwendet wurden.
- Der **Testsatz** dient zur abschließenden Überprüfung der gesamten Leistung eines KNN. Er besteht aus Mustern, die weder zum Training noch zum Validieren verwendet wurden.

Das Training sollte dann beendet werden, wenn der Fehler des Validierungssatzes minimal ist. Dann generalisiert das Netz am besten (early stopping). Wird das Lernen nicht beendet, kommt es zu einem Übertrainieren und die Leistung des Netzes in bezug auf die gesamten Daten nimmt ab, obwohl der Fehler der Trainingsdaten weiterhin geringer wird.

Nach Beendigung der Trainingsphase sollte das Netz mit dem dritten Datensatz, dem Testsatz, abschließend überprüft werden. Der Testsatz ist ein unabhängiger Nachweis für die Generalisierungsfähigkeit des Netzes, denn die Informationen der Validierungsdaten werden zur Beendigung des Trainings verwendet (um so den besten Validierungsfehler zu erreichen). Dieses Vorgehen wurde getestet. Im Anhang findet sich eine Tabelle zum Verlauf verschiedener Trainingsphasen und deren Anzahl der Lernschritte bis zum Anstieg des Validierungsfehlers. Die Anzahl der Lernschritte bis zum Anstieg des Validierungsfehlers ist mit einer hohen Varianz versehen, wobei manche Trainingsphasen recht lange dauern, bis der Validierungsfehler ansteigt. Dabei verringert sich der Fehler ab 1000 Lernzyklen nicht mehr wesentlich. Daher ist diese Vorgehensweise nicht praktikabel. Early Stopping findet generell bei Konfigurationen mit geringem Umfang an Trainingsdaten Anwendung.

Anzahl der versteckten Neuronen

Im folgenden werden die Netze mit einer konstanten Anzahl an Lernzyklen trainiert und nur der Trainings- und der Validierungsfehler angezeigt. Die folgenden Tabellen zeigen den MSE der trainierten Netze nach 1000 Lernschritten. Die Tabellen unterscheiden sich in der Repräsentation der Daten.

Netztyp (Anzahl hidden Neurons)	Trainingsfehler	Validierungsfehler
$\hat{y}(t) = f(y(t-1), u(t-1))$		
10	0.00372378	0.00366049
20	0.0029183	0.00279461
30	0.0039291	0.00376266
40	0.00421118	0.00412847
$\hat{y}(t) = f(y(t-1), y(t-2), u(t-1), u(t-2))$		
10	0.00406207	0.00414952
20	0.00462237	0.00486701
30	0.00335934	0.0040724
40	0.00311741	0.00360185
$\hat{y}(t) = f(y(t-1), \dots, y(t-3), u(t-1), \dots, u(t-3))$		
10	0.00454839	0.00497114
20	0.00486331	0.00676355
30	0.00495097	0.00565351
40	0.00407193	0.00471112
$\hat{y}(t) = f(y(t-1), \dots, y(t-4), u(t-1), \dots, u(t-4))$		
10	0.00508156	0.00519383
20	0.00481098	0.00507111
30	0.00699176	0.00789745
40	0.00895668	0.0110344
$\hat{y}(t) = f(y(t-1), \dots, y(t-5), u(t-1), \dots, u(t-5))$		
10	0.00541799	0.00688171
20	0.00462471	0.005457
30	0.00530937	0.00672669
40	0.00814814	0.00985231

Tabelle 3.2: Ein- und Ausgabedaten werden als Trainingsdaten verwendet.

Aus Tabelle 3.2 ist ersichtlich, daß mit zunehmender Ordnung des Modells der Trainings- und der Validierungsfehler zunimmt.

Netztyp (Anzahl hid- den Neurons)	Trainingsfehler	Validierungsfehler
$\Delta\hat{y}(t) = f(y(t-1), u(t-1))$		
10	0.00197083	0.0021076
20	0.00204352	0.00206818
30	0.00188301	0.0020159
40	0.00219872	0.00226085
$\Delta\hat{y}(t) = f(y(t-1), y(t-2), u(t-1), u(t-2))$		
10	0.0018389	0.00193493
20	0.00181509	0.00191688
30	0.00170447	0.00210275
40	0.00144804	0.00182497
$\Delta\hat{y}(t) = f(y(t-1), \dots, y(t-3), u(t-1), \dots, u(t-3))$		
10	0.00166343	0.00146125
20	0.0024755	0.0028585
30	0.00213152	0.00247889
40	0.0044738	0.00365479
$\Delta\hat{y}(t) = f(y(t-1), \dots, y(t-4), u(t-1), \dots, u(t-4))$		
10	0.00176648	0.00162316
20	0.00284388	0.00271662
30	0.00312551	0.00400183
40	0.0043939	0.00532027
$\hat{y}(t) = f(y(t-1), \dots, y(t-5), u(t-1), \dots, u(t-5))$		
10	0.00151625	0.00132942
20	0.00222129	0.00204026
30	0.00430648	0.00337507
40	0.00318356	0.00456587

Tabelle 3.3: Statt der Ausgabe wird die numerische Ableitung zum Training verwendet.

Wird statt der Ausgabemuster die numerische Ableitung zum Training verwendet, so sinken Trainings- und Validierungsfehler signifikant (Tabelle 3.3). Bei höherer Modellordnung vergrößern sich die Fehler mit zunehmender Anzahl versteckter Neuronen.

Netztyp hidden Neurons)	(Anzahl	Trainingsfehler	Validierungsfehler
$\Delta\hat{y}(t) = f(y(t-1), u(t-1))$			
10		0.00197083	0.0021076
20		0.00204352	0.00206818
30		0.00188301	0.0020159
40		0.00219872	0.00226085
$\Delta\hat{y}(t) = f(y(t-1), \Delta y(t-2), u(t-1), \Delta u(t-2))$			
10		0.00150629	0.00152129
20		0.00167381	0.00171625
30		0.00131664	0.00155242
40		0.00133982	0.0016801
$\Delta\hat{y}(t) = f(y(t-1), \dots, \Delta y(t-3), u(t-1), \dots, \Delta u(t-3))$			
10		0.00120982	0.00126251
20		0.00204478	0.00141896
30		0.00188318	0.00246534
40		0.00209084	0.00243556
$\Delta\hat{y}(t) = f(y(t-1), \dots, \Delta y(t-4), u(t-1), \dots, \Delta u(t-4))$			
10		0.00163678	0.00180473
20		0.00154377	0.00189377
30		0.00193283	0.00258053
40		0.00225708	0.00290561
$\Delta\hat{y}(t) = f(y(t-1), \dots, \Delta y(t-5), u(t-1), \dots, \Delta u(t-5))$			
10		0.00122842	0.00117349
20		0.00189662	0.00194858
30		0.00204961	0.00227552
40		0.00202657	0.00261116

Tabelle 3.4: Ein- und Ausgabedaten werden als numerische Ableitungen repräsentiert.

In Tabelle 3.4 wird die numerische Ableitung von Ein- und Ausgabedaten zum Training verwendet. Dies führt zu einer weiteren geringfügigen Herabsenkung des Trainings- und Validierungsfehlers. Die Fehler vergrößern sich bei höherer Modellordnung nicht signifikant.

Es zeigt sich, daß die Repräsentationen der Daten von Tabelle 3.3 und Tabelle 3.4 gegenüber der Standard-Repräsentation (Tabelle 3.2) zu einer starken Verbesserung des Konvergenzverhaltens beim Training führt. Der Modellfehler ist um den Faktor 4 geringer. Ob Repräsentation 2 oder Repräsentation 3 angewendet wird, ist für das Trainingsergebnis nicht wesentlich. Das Netz mit den besten Trainings- und Validierungsergebnis hat die Ordnung 5, 10 versteckte Neuronen und es wurde mit einer Repräsentation der Daten nach Typ 3 trainiert. Eine Erhöhung der Anzahl der versteckten Neuronen bringt für höhere Modellordnungen in der Regel keine Verringerung des Trainings- bzw. Validierungsfehlers.

Die KNN-basierten Modelle stellen eine bessere Approximation des Übertragungsverhaltens des Prozesses dar, als die linearen Modelle (Tabelle 3.1)

Die Konvergenz kann also durch eine geeignete Repräsentation der Trainingsdaten verbessert werden. Aber das Problem der schlechten Konvergenz von Gradientenabstiegsverfahren als lokale Optimierung der Gewichte besteht weiterhin. Daher wird im folgenden Abschnitt die Eignung von Netzen mit Radialen Basisfunktionen (RBF-Netze) für die Modellierung des Müllverbrennungsprozesses geprüft. Das Training der RBF-Netze erfolgt nicht über Gradientenabstiegsverfahren, sondern deterministisch.

3.4 Modellierung mit Netzen mit Radialen Basisfunktionen

Das RBF-Netz wurde ursprünglich für die Lösung von Interpolationsproblemen entwickelt [29]. Es kann jedoch auch für die Approximation nichtlinearer Funktionen herangezogen werden. Die Struktur ist durch

$$F(X) = \sum_{i=1}^N w_i G_i(X) \quad (3.24)$$

gegeben, wobei N die Anzahl der versteckten Neuronen ist, und eine endliche Menge von Basisfunktionen $G_i(X)$ benutzt wird. Die in der Literatur am häufigsten anzutreffende Elementarfunktion ist die Gaußsche radiale Basisfunktion $G_i(X) = e^{-\frac{\|X-Z_i\|^2}{\sigma}}$. Z_i ist ein fest vorgegebener Basisvektor, an dem die radiale Basisfunktion ihr Maximum besitzt. Jedes Neuron der versteckten Schicht besitzt einen eigenen Basisvektor. Eine geeignete Positionierung der Basisvektoren im Eingaberaum kann entweder manuell oder mit Clusterverfahren [19][54] bestimmt werden. Die Eingabeschicht dient allein der Verteilung aller Komponenten an alle versteckten Neuronen (Abbildung 3.12).

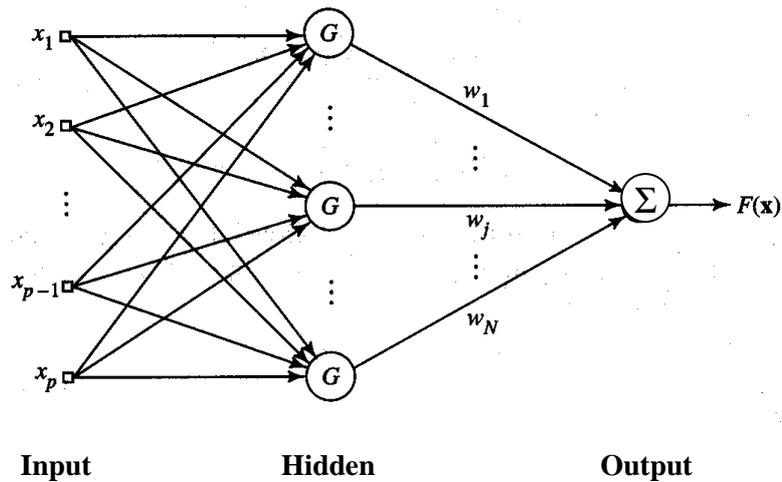


Abbildung 3.12: Struktur eines RBF-Netzes

RBF-Netze lassen sich bezüglich ihrer Gewichte optimal einstellen. Somit wird ein suboptimales Training durch lokale Minima in der Fehlerfunktion vermieden. Doch zuerst wird geprüft, ob eine lokale Repräsentation der Datensätze generell möglich ist. Daher wird im folgenden Abschnitt gezeigt, wie groß die topologische Dimension [97] des Eingaberaums ist. Denn es kann nicht der gesamte euklidische Raum durch Stützstellen repräsentiert werden, da die Anzahl der Stützstellen exponentiell mit der Dimension des Eingaberaums ansteigt (Curse of Dimensionality).

3.4.1 Machbarkeitsstudie zum Einsatz von RBF-Netzen

Wie in Abschnitt 3.1.2.2 gezeigt wurde, läßt sich der hochdimensionale Eingaberaum der Meßdaten mit einer Hauptkomponententransformation in einen Raum mit viel kleinerer Dimension heruntertransformieren. Dies bezog sich auf Daten zu einem Zeitpunkt. Nun wird eine Hauptkomponententransformation auf auf einen Vektor von fünf aufeinanderfolgenden Datensätzen durchgeführt mit dem Zweck zu untersuchen, auf wieviel Dimensionen sich abhängig vom Varianzverlust die Daten transformieren lassen.

Im folgenden bestehe ein Eingabevektor X aus 5 aufeinanderfolgenden Datensätzen. Ein Datensatz besteht aus 16 Komponenten, so daß X die Länge 80 besitzt.

$$X = [y(k) \ u(k) \ \dots \ \dots \ y(k-4) \ u(t-4)]^T \quad (3.25)$$

Abbildung 3.13 zeigt daß sich 73% der Varianz der Daten erhalten bei einer Transformation auf einen 4 dimensionalen Unterraum.

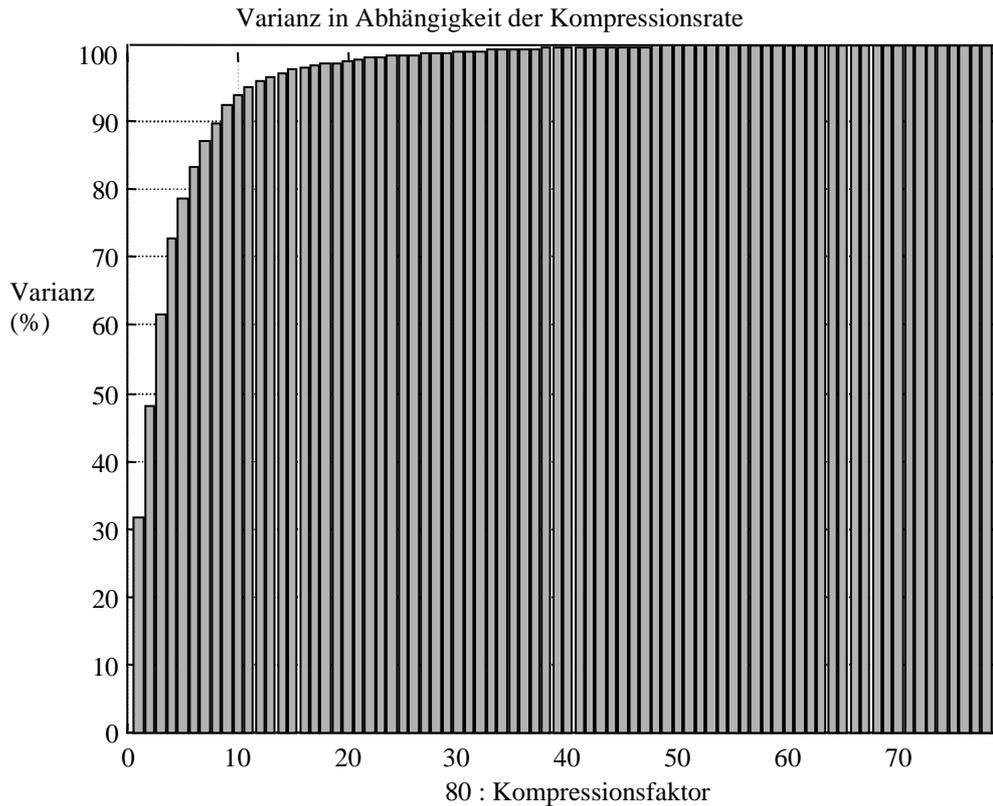


Abbildung 3.13: Varianz in Abhängigkeit der Kompressionsrate.

Nun wird geprüft, ob eine weitere Erhöhung der Varianz der Daten durch Transformation in lokale lineare Unterräume möglich ist. Hierzu werden im folgenden Abschnitt Stützstellen zur Unterteilung des Eingaberaums in lokale Unterräume mit Kohonennetzen ermittelt.

3.4.1.1 Funktionsweise von Kohonennetzen

Mit Hilfe von Kohonennetzen lassen sich Eingabedaten auch auf nichtlineare Untermannigfaltigkeiten abbilden. Jedem Neuron r eines Kohonennetzes ist ein Gewichtsvektor W_r zugewiesen, der die Dimension des Eingaberaums besitzt. Die Gewichtsvektoren sind die adaptiven Komponenten des Netzes, die während einer Trainingsphase geändert werden. Die Neuronen sind in einem (zwei- oder höherdimensionalen) Gitter durch nicht gewichtete Verknüpfungen zwischen den Neuronen organisiert. Ein Kohonennetz hat eine Struktur wie in Abbildung 3.14 dargestellt.

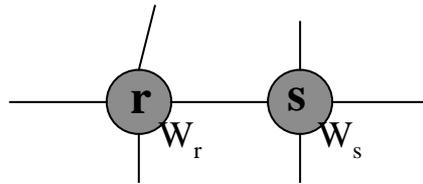


Abbildung 3.14: Zwei topologisch benachbarte Neuronen eines Kohonennetzes

In der Abrufphase bildet das Kohonennetz einen Vektor des Eingaberaums auf ein einzelnes Neuron ab. Hierzu wird das Neuron ermittelt, dessen Gewichtsvektor dem Eingabevektor am nächsten ist (gemessen mit einem euklidischen Abstandsmaß). Als Ausgabe wird dieses Neuron gewählt.

$$neuron = \min_{i \in Neuronen} \|W_i - X\| \quad (3.26)$$

Kohonennetze arbeiten nach dem Winner-takes-it-all Prinzip [55][91].

3.4.1.2 Trainingsphase der Kohonennetze

Zu Anfang sind alle Gewichtsvektoren mit Zufallswerten initialisiert. Dann besteht ein Lernschritt aus den folgenden Teilschritten:

1. Gebe einen zufällig gewählten Eingabedatensatz X vor.
2. Bestimme das Neuron, dem dieser Eingabedatensatz zugeordnet ist gemäß (3.26)
3. Adaptiere die Gewichtsvektoren aller Neuronen

$$\text{durch: } W_r^{neu} = W_r^{alt} + \varepsilon(t) h_{rs}(t) (X - W_r^{alt})$$

mit der über die Zeit abnehmenden Lernrate $\varepsilon(t) = \varepsilon_0 (1 / \varepsilon_1)^{\frac{1}{t_{max}}}$ und dem Koeffizienten, der die Entfernung von Neuron r und Neuron s im Gitter bestimmt. $h_{r,s} = \exp(-(r - s)^2 / 2\sigma(t)^2)$.

Der Radius σ dieser Erregungsfunktion bestimmt die Längenskala, auf der die Eingangsreize Korrekturen an dem Gitter vornehmen. In der Regel ist es vorteilhaft, wenn sich das Gitter zuerst in der Grobstruktur bilden kann, bevor die lokale Feinstruktur entsteht. Dies wird ermöglicht, wenn σ als langsam mit der Zahl t der Lernschritte abnehmende Funktion $\sigma(t)$ gewählt wird. Dies entspricht einer zeitlich zunehmenden Selektivität der einzelnen Neuronen.

Ziel des Trainings ist die Entflechtung des Neuronengitters bei zu Anfang mit Zufallswerten initialisierten Gewichtsvektoren. Die Netzarchitektur wird durch die Topologie des Netzes vor-

gegeben. Es können Tetraeder, Hexaeder und n-dimensionale Gitter verwendet werden. Eine genaue Beschreibung von Kohonennetzen und ihren Lernverfahren findet sich in [55].

Wie in Abbildung 3.13 gezeigt, lassen sich 73% der Varianz des Eingaberaums der aufgenommenen Meßdaten aus Anlage 1 durch eine Hauptkomponentenregression mit den ersten 4 Hauptkomponenten nachbilden. Durch Kohonennetze lassen sich die Daten noch genauer repräsentieren.

3.4.1.3 Training eines Kohonennetzes mit Datensatz 1

Der Datensatz 1 wird nun verwendet, um ein Kohonennetz zu trainieren. Nach der Trainingsphase werden die Gewichtsvektoren der Neuronen des Kohonennetzes später die Erregungszentren der einzelnen Radialen Basisneuronen sein. Trainiert wird ein Netz der topologischen Dimension 4 mit 625 Neuronen. D.h. das Netz stellt ein 4-dimensionales Gitter der Kantenlänge 5 dar. Der Gewichtsvektor der Neuronen hat analog zur Länge eines Meßdatensatzes die Dimension 80, so daß sich die Gewichtsvektoren im Eingaberaum organisieren können. Bei Netzen mit vielen Neuronen und hoher topologischer Dimension (Kohonen schlägt 2-dimensionale Karten vor) ist die Auswahl der Lernparameter problematisch. Bei schlechter Wahl der Trainingsparameter findet ein unvollständiges Ordnen der Neuronen statt, das Netz kann in sich verdreht sein und so ein optimales Entfalten in den Eingaberaum unterbinden (siehe Abbildung 3.15).

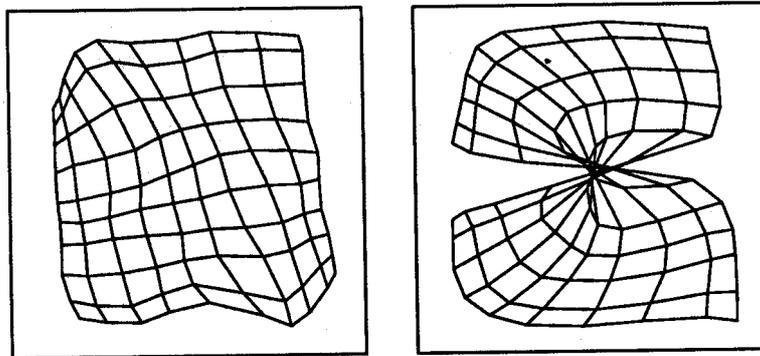


Abbildung 3.15: Netz bei konvergentem Training (links) und Netz mit topologischem Defekt (rechts). Schematische Darstellung aus [91]

Um die Konvergenz des Lernverfahrens zu stabilisieren und topologische Defekte beim Trainieren des Netzes zu unterbinden wird eine im Rahmen dieser Arbeit entwickelten Vorinitialisierung der Gewichtsvektoren vor dem Training vorgenommen:

1. Jeder Eingabevektor X wird durch eine Hauptkomponententransformation in einen vierdimensionalen Unterraum transformiert gemäß $X' = AX$, wobei A die Matrix aus den ersten vier Hauptkomponenten des Datensatzes 1 ist. A ist eine (80,4) Matrix.
2. Auf den transformierten Daten wird in jeder der vier Dimensionen das Minimum und das Maximum gebildet. Auf diese Weise werden die Eckpunkte eines vierdimensionalen Würfels erhalten.
3. Der Würfel wird entlang der Kanten 5 mal unterteilt und die entstandenen Knoten bilden neue Stützstellen. Dann werden diese Stützstellen wieder in den Eingaberaum transformiert gemäß $X = A^T X'$. A^T ist die Pseudoinverse der Hauptkomponententransformationsmatrix A .
4. Die sortierte Punktmenge wird zur Initialisierung den Neuronen des vierdimensionalen Gitters zugeordnet und deren Gewichtsvektoren hiermit belegt.

Da ein Lernschritt zu Beginn der Trainingsphase globale Auswirkungen hat, wird die Trainingsphase nicht bei $t=0$ gestartet, sondern bei $t=100000$ und endet nach $t=500000$ Schritten.

3.4.1.4 Auswertung des Trainingsergebnisses

Ein Maß für die Konvergenz des Netzes erfordert ein Kriterium, daß die "Ordnung", also ein Maß für die Nachbarschaftserhaltung bei ähnlichen Eingaben bestimmt.

Eine Visualisierung des 4-dimensionalen Gitters ist schwierig, und daher wird ein 3-dimensionales Untergitter grafisch dargestellt.

Abbildung 3.16 zeigt ein Gitter mit zum Initialisierungszeitpunkt sortierten Werten der ersten 4 Hauptkomponenten, nach einem Training des Netzes mit 500 000 Schritten. Hierbei wurden die Gewichte für die ersten 100 000 Schritte eingefroren, da zu Anfang der Trainingsphase eine globale Organisation des Netzes stattfindet, die durch die explizite Vorgabe einer topologischen Ordnung nicht erwünscht ist. Die Abbildung zeigt eine Projektion der Kanten des trainierten Netzes, positioniert in dem Unterraum der ersten 3 Hauptkomponenten des Eingaberaums. Eine globale Ordnung ist sichtbar, topologische Defekte treten nicht auf.

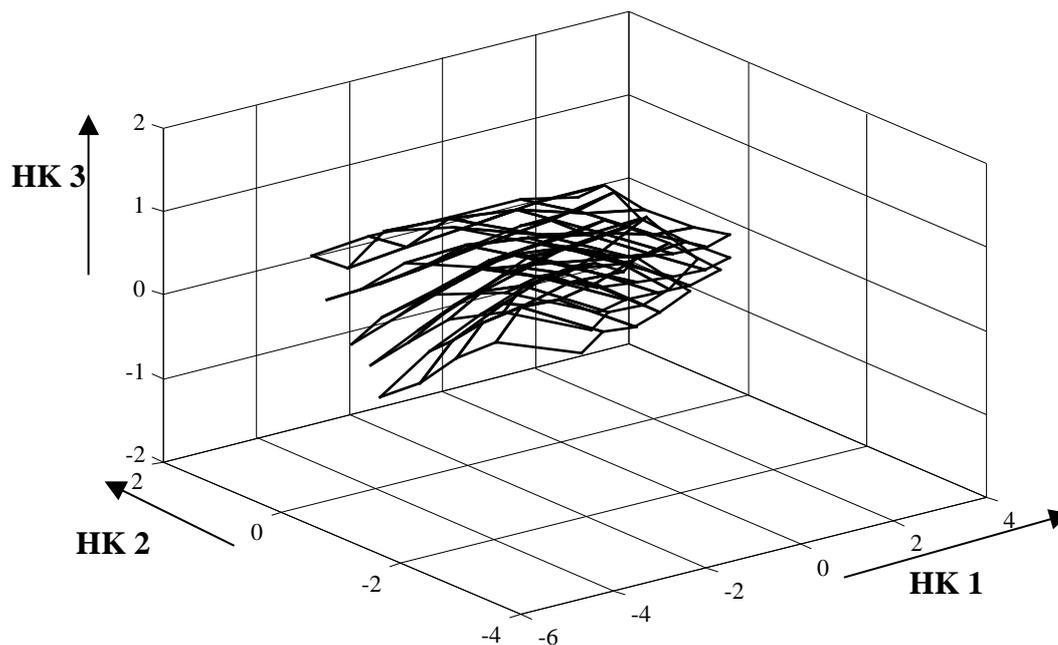


Abbildung 3.16: Kohonen Subnetz mit sortierter Initialisierung der Gewichte nach Beenden der Lernphase.

Diese subjektive Wahrnehmung der "Netzordnung" läßt sich quantifizieren. Hierzu wird der Eingaberaum in lokale lineare Unterräume unterteilt und eine lokale lineare Approximation der Meßdaten vorgenommen. Die Differenz zwischen der Approximation und den tatsächlichen Meßdaten liefert einen Ordnungskoeffizienten für das Kohonengitter. Jeder Gewichtsvektor eines Neurons stellt hierfür den Ursprung eines lokalen Koordinatensystems dar. Die Koordinatenvektoren ergeben sich aus den Ortsvektoren zu den topologisch benachbarten Neuronen. Abbildung 3.17 zeigt schematisch drei benachbarte Neuronen eines dreidimensionalen Gitters. Ein Meßdatensatz X des Eingaberaums aktiviert Neuron 1, d.h. dessen Vektor ist X am ähnlichsten. Hat sich das Netz organisiert, so läßt sich X durch folgende Linearkombination approximieren:

$$\hat{X} = G_1 + a(G_2 - G_1) + b(G_3 - G_1) + c(G_4 - G_1) \quad (3.27)$$

mit a, b, c skalar und G_1 bis G_4 Gewichtsvektoren der Neuronen 1...4. Der Punkt \hat{X} ist dann die lokale lineare Darstellung in dem von den Gewichten der Neuronen N1-N4 aufgespannten Ko-

ordinatensystem. Dieser hier formulierte Ordnungsbegriff ist ein Derivat der aus der Literatur bekannten Topographischen Funktion [103].

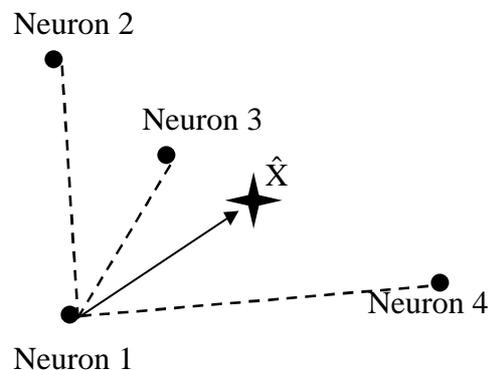


Abbildung 3.17: Schematische Darstellung der lokalen linearen Approximierung von Eingabedaten durch Neuronen eines Kohonennetzes.

Der Algorithmus:

1. Errege das Netz mit einem Stimulus (Eingabevektor).
2. Finde das Gewinnerneuron.
3. Finde den Quadranten, in dem der Eingabevektor zur Lage des Gewinnerneurons liegt.
4. Bestimme gemäß Gl.(3.27) die Koeffizienten a, b, c, d , die den Fehler $(X - \hat{X}(a, b, c, d))$ minimieren.
5. Gebe den Fehler zurück.

Der so erhaltene Fehler zeigt den Abstand des Punktes X zur durch die Neuronen um X aufgespannte Hyperebene. Eine fehlende Ordnung des Netzes durch Verdrehen oder sonstiges führt zu einer schlechten Approximation von X durch \hat{X} , da die Ähnlichkeit benachbarter Neuronen nicht stark ist.

Ergebnisse: Der MSE, der durch die Hauptkomponentenregression erzeugten Regressanten ist 0.27. Der MSE eines mit Zufallswerten initialisiertem Netz ist 0.29 und der MSE bei vorsortiertem Netz beträgt 0.07. Die erhaltene Varianz des Eingaberaums (in %) errechnet sich aus dem MSE zu:

$$V = (1 - MSE) * 100 \quad (3.28)$$

Somit wurde eine lokale lineare Repräsentation der Daten durch Knoten in einem 4-dimensionalen Gitter gefunden, die 93% der Varianz des Eingaberaums wiedergibt. Dies bedeutet, daß eine lokale Aufteilung des Eingaberaums und somit eine Repräsentation des Eingaberaums durch Netze mit lokaler Repräsentation möglich ist.

Zur Bestimmung der Erregungszentren der Neuronen können auch Learning Vector Quantification [54] oder andere Clustering Algorithmen [63] verwendet werden, aber durch die Repräsentation der Eingabedaten in einem Gitter wurde validiert, daß die Daten sich durch eine vierdimensionale nichtlineare Untermannigfaltigkeit mit ausreichender Genauigkeit darstellen lassen.

Neben dieser Machbarkeitsstudie zum Einsatz von RBF-Netzen wurden außerdem Erregungszentren gefunden, die als Basisvektoren der radialen Basisfunktion zur Initialisierung verwendet werden können. Die Basisvektoren sind nämlich gerade die Gewichte des trainierten Kohonennetzes.

3.4.2 Training der RBF-Netze

Die Gewichte des Kohonennetzes werden nun als Erregungszentren der RBF-Netze verwendet. Die feste Vorgabe der Zentren ist nicht optimal im Sinne einer optimalen Funktionsapproximation, aber sie ist (theoretisch) optimal im Sinne einer Clustering der Daten und somit eine angemessene Heuristik zum weiteren Vorgehen.

Ein RBF-Netz errechnet seine Ausgabe zu $O(I) = \sum_n W_n e^{-\left(\frac{\|I-Z_n\|}{\sigma}\right)^2}$

mit W_n = Gewichtsvektor des n -ten Neurons und Z_n = Basisvektor des n -ten Neurons. Der Wert σ bestimmt den globalen Einfluß der Ausgabe des Neurons n auf das Gesamtergebnis. Die Basisvektoren Z_n wurden bereits im vorigen Abschnitt ermittelt. Somit bleibt das Bestimmen der Gewichtsvektoren W_n , die aber linear bezüglich der Fehlerfunktion sind, und es lassen sich diese Koeffizienten eindeutig im Sinne der Minimierung der Fehlerfunktion errechnen.

Den MSE von Trainings- und Validierungsdaten (Datensatz 1 und Datensatz 2) zeigt folgendes Diagramm in Abhängigkeit des manuell eingestellten Wertes σ .

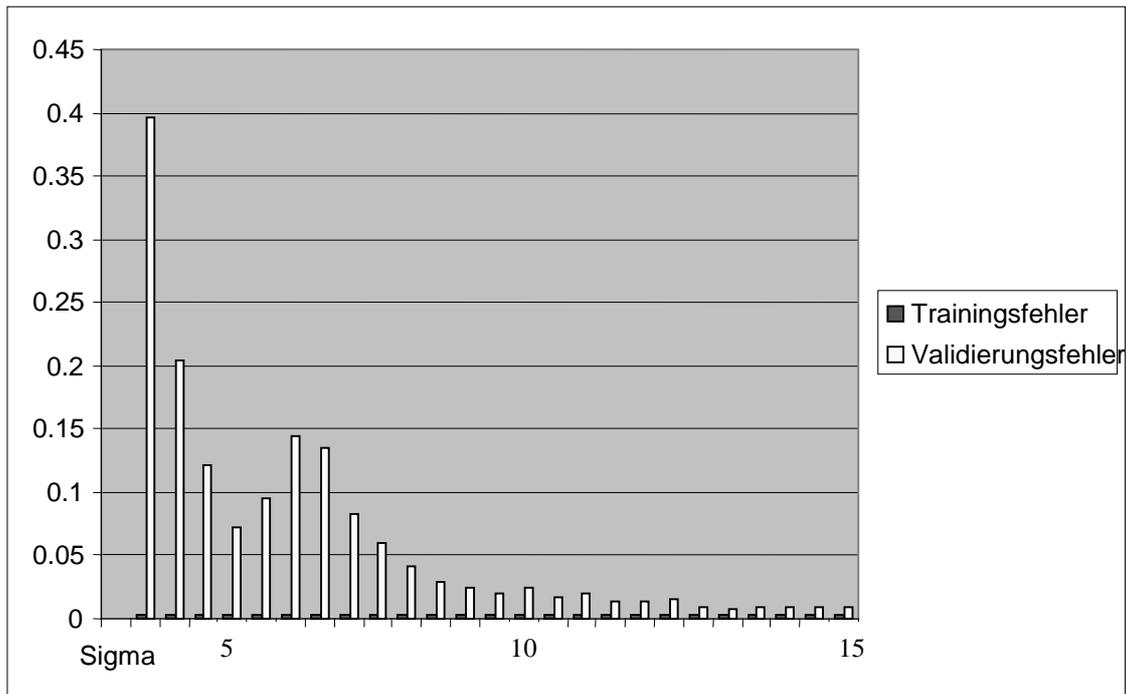


Abbildung 3.18: Fehler der Trainings- und Validierungsdaten in Abhängigkeit des Parameters σ .

Es zeigt sich, daß unabhängig vom gewählten Parameter σ der Validierungsfehler stets mindestens dem zweifachen des Trainingsfehlers beträgt. Ein Erhöhen der Neuronendichte könnte hier Abhilfe schaffen, aber das hier verwendete Netz ist mit seinen 625 ($=5^4$) Neuronen bereits recht groß und der Rechenaufwand erheblich. Aus diesem Grund werden weitere Untersuchungen von RBF-Netzen in dieser Anwendung nicht verfolgt und die Modellierung erfolgt weiterhin ausschließlich mit MLPs.

3.5 Simulation

In diesem Abschnitt wird die Simulation der Zustandsgrößen beschrieben und durchgeführt. Als Simulator wird ein trainiertes neuronales Modell zur Simulation aller Zustandsgrößen für die Vorhersage des Prozeßzustands eingesetzt. Hierbei unterscheidet man zwei Simulationsmodelle:

Paralleles Identifikationsmodell

Die Identifikation mittels eines parallelen Modells der Anlage (Modell IV) läßt sich folgendermaßen ausdrücken:

$$\hat{y}(k+1) = f(\hat{y}(k), \hat{y}(k-1), \dots, \hat{y}(k-N), u(k), u(k-1), \dots, u(k-N)) \quad (3.29)$$

Die Modellausgabe zum Zeitpunkt $k+1$ ist von den letzten N Modelleingaben und den vorangegangenen N Modellausgaben abhängig.

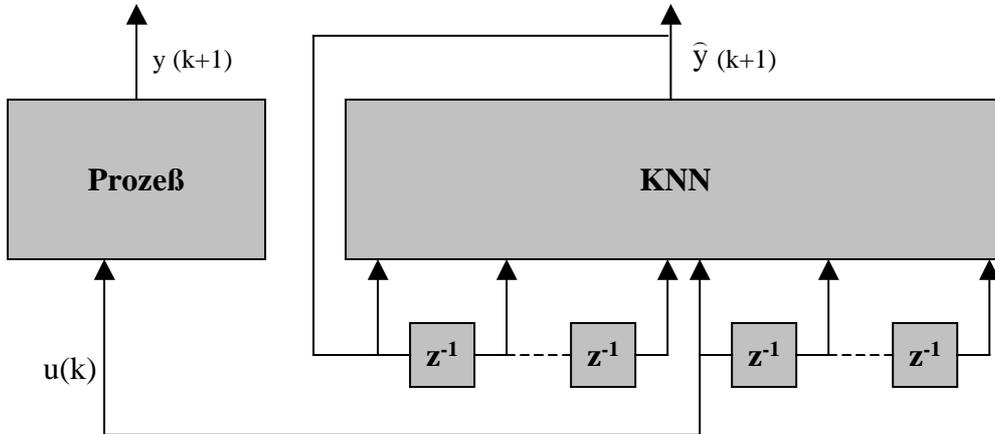


Abbildung 3.19: Paralleles Modell.

Serien-Parallelmodell

Beim Serien-Parallelmodell werden die realen Meßdaten anstelle der Modellausgabe zum Identifikationsmodell zurückgeleitet. Die Identifikation läßt sich folgendermaßen ausdrücken:

$$\hat{y}(k+1) = f(y(k), y(k-1), \dots, y(k-N), u(k), u(k-1), \dots, u(k-N)) \quad (3.30)$$

Die Modellausgabe zum Zeitpunkt $k+1$ ist von den letzten N Modelleingaben und den vorangegangenen N Meßdatentupeln abhängig.

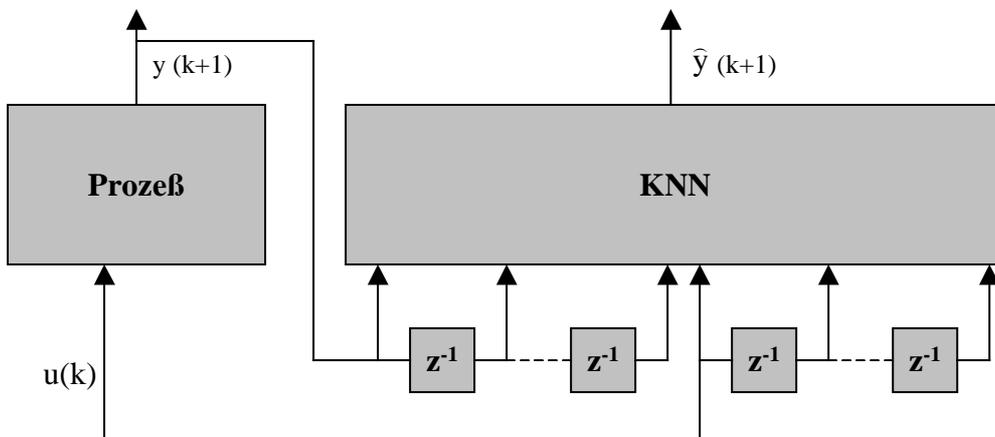


Abbildung 3.20: Serien-Parallelmodell.

3.5.1 Simulationsergebnisse

Die Trainingsergebnisse aus Abschnitt 3.3.1 stellen eine statische Validierung für die trainierten KNNs dar. Sie liefern Modelle, die direkt für den seriell-parallelen Betrieb herangezogen werden können. Im Gegensatz dazu muß für den parallelen Modus noch eine Überprüfung der Qualität des dynamischen Modellverhaltens erfolgen, um die Tauglichkeit des Modells für eine Mehrschrittprädiktion zu überprüfen.

Das Training der KNNs erfolgte gemäß dem Serien-Parallelmodell. In der Anwendungsphase wird ein KNN-Modell als Parallelmodell eingesetzt, um die Prädiktionsfähigkeit des Modells zu beurteilen. Das hierfür gewählte KNN hatte das beste Ergebnis bei der statischen Validierung gemäß Tabelle 3.4. Die Konfiguration des Netzes ist:

- Modellordnung: 5
- Anzahl versteckter Neuronen: 10
- Repräsentation der Daten: Numerische Ableitung an Ein- und Ausgabe.

Die zugrundeliegenden Meßdaten für die Validierung des Modells entstammen Datensatz 2. Die folgenden Abbildungen zeigen eine Simulation der Zustandsgrößen der Anlage 1 nach dem Serien-Parallelmodell. Ab dem Zeitschritt $t=50$ wird gemäß dem Parallelmodell eine Mehrschrittprädiktion gefahren.

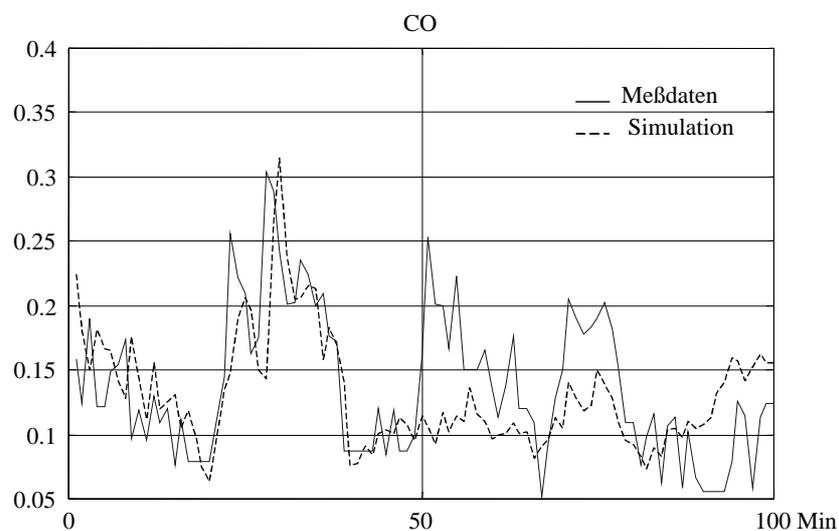


Abbildung 3.21: CO-Gehalt und Simulation

Das Simulationsergebnis für den CO-Gehalt weicht von dem Originalverlauf unabhängig vom Simulationsmodus relativ stark ab. Aber der sichtbare Wertebereich umfaßt einen geringeren Umfang, als der der anderen Meßwerte (<30% der Breite des Meßumfangs).

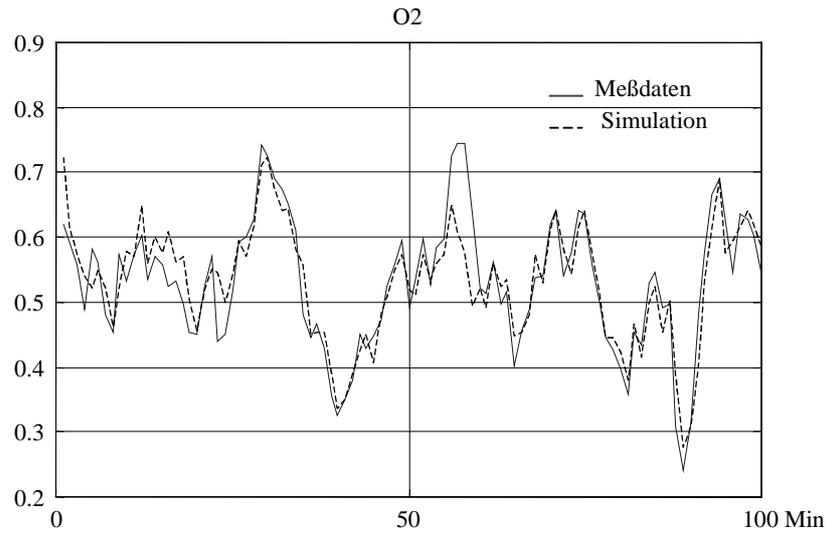


Abbildung 3.22: O₂-Gehalt und Simulation

Die Simulation des Prozeßparameters O₂-Gehalt zeigt auch bei Verwendung des Parallelmodells eine hohe Prädiktionsgüte. Dies ist auf eine statische Abhängigkeit von der Primärluft zurückzuführen, die auch im realen Prozeß vorliegt.

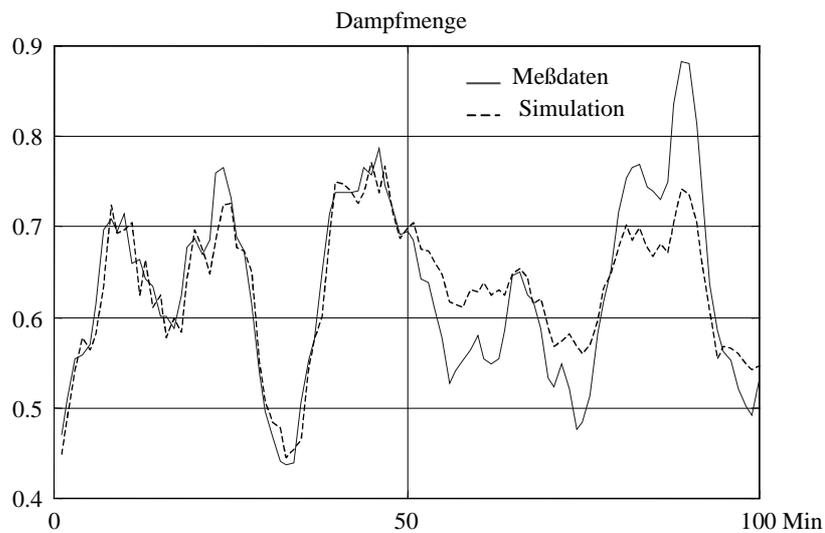


Abbildung 3.23: Dampfmenge und Simulation

Die Simulation der Dampfmenge stimmt im Serien-Parallelmodus gut mit der realen Dampfmenge überein und zeigt im Parallelmodus eine leichte Divergenz.

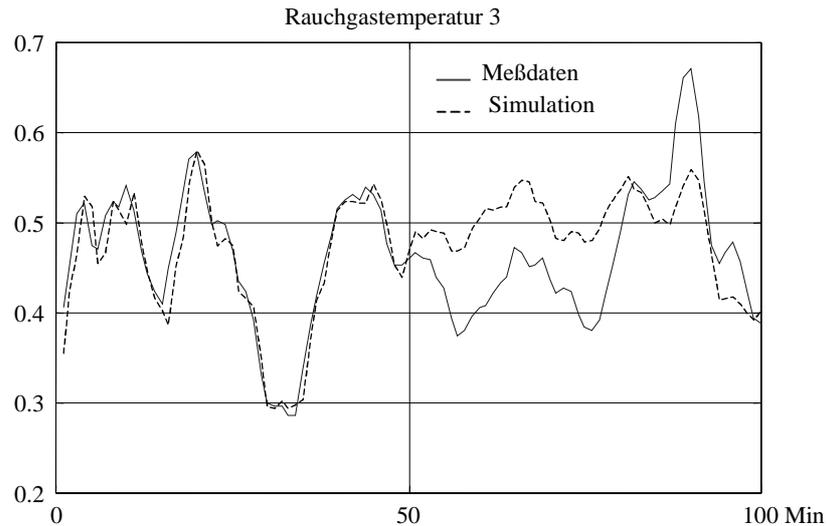


Abbildung 3.26: Rauchgastemperatur 3 und Simulation

Die Simulation von Rauchgastemperatur 3 zeigt eine sofortige Divergenz in der freilaufenden Simulation.

Generell verringert sich die Simulationsqualität mit zunehmender Iterationstiefe, aber die Stellgrößen liefern weiterhin einen Beitrag zum modellierten Signal. Die Genauigkeit der Vorhersage nimmt mit der Iterationstiefe ab, da sich Modellunsicherheiten bei jeder Iteration fortpflanzen und bei der freien Simulation (im Gegensatz zum realen Prozeß) keine externen Störeinflüsse wirken.

Um ein Maß für die Divergenz der freilaufenden Simulation zum realen Prozeßverhalten zu bekommen, wird nun das trainierte Netz dynamisch validiert. D.h. es wird der Fehler der Prädiktion in Abhängigkeit der Iterationstiefe für alle aus den Validierungsdaten erzeugbaren Anfangszustände gemessen. Der Fehler der dynamischen Validierung bei einem Prädiktionshorizont T einer Modellordnung N und M Datensätzen ergibt sich zu:

$$MSE(T) = \frac{1}{M - T} \sum_{k=N}^{M-T} (\hat{y}(k + T) - y(k + T))^2 \quad (3.31)$$

Für $T=1$ ergibt sich die Formel zur Errechnung der statischen Validierung.

$$MSE = \frac{1}{M - 1} \sum_{k=N}^{M-1} (\hat{y}(k + 1) - y(k + 1))^2 \quad (3.32)$$

$\hat{y}(k+T)$ läßt sich rekursiv errechnen gemäß folgender Vorschrift:

$$\hat{y}(k+1) = f(y(k), \dots, y(k-N), u(k), \dots, u(k-N))$$

$$\hat{y}(k+2) = f(\hat{y}(k+1), y(k), \dots, y(k+1-N), u(k+1), \dots, u(k+1-N))$$

...

$$\hat{y}(k+T) = f(\hat{y}(k+T-1), \hat{y}(k+T-2), \dots, \hat{y}(k+T-N), u(k+T-1), \dots, u(k+T-N))$$

Abbildung 3.27 zeigt die Ergebnisse der dynamischen Validierung.

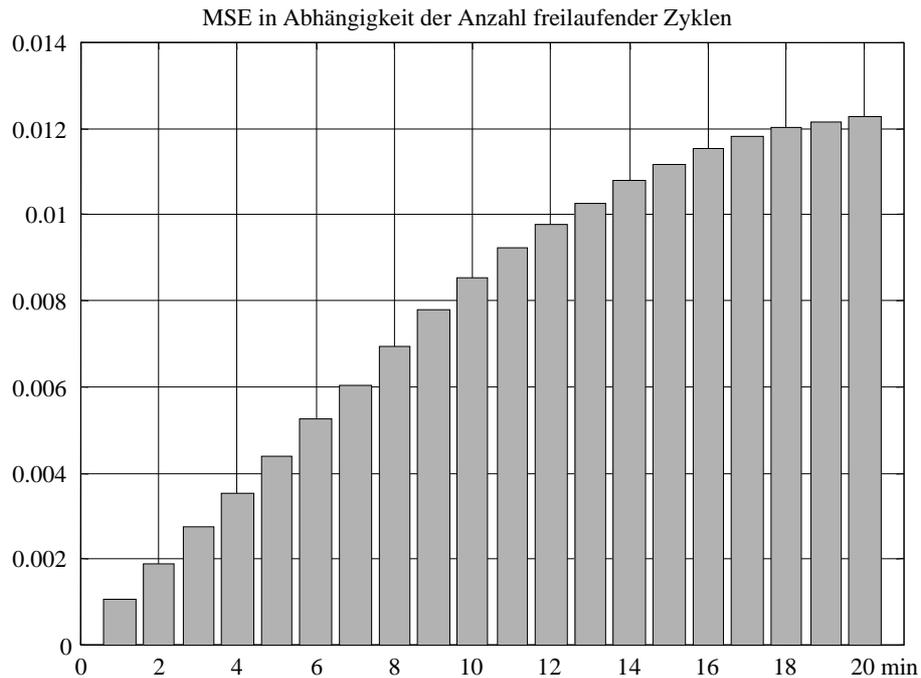


Abbildung 3.27: Fehler in Abhängigkeit des Prädiktionshorizonts.

Bei einer Iterationstiefe von 5 Schritten (d.h. einer Vorhersagezeit von 5 Minuten) wird ein Durchschnittsfehler von 0.005 erreicht, das entspricht einer mittleren Abweichung von ca 7% vom Originalsignal (nach Gl. 3.8). Für die Nutzung des Modells zur prädiktiven Regelung (s. Kapitel 4) ist ein Prädiktionshorizont von 5 Schritten (= 5 Minuten) ausreichend.

3.5.2 Anmerkungen zur Validität des Modells

Es können keine exakten Aussagen über die Modellgültigkeit auf die Anwendung neuer Datensätze getroffen werden.

Die Daten zum Training wurden dem geregelten Prozeß entnommen, um das Störverhalten des Prozesses zu simulieren. Daher besitzt das Modell nur eine lokale Gültigkeit um den gefahrenen

Arbeitspunkt. Eine andere Regelstrategie ändert die Dimensionalität des Eingaberaums bzw. wird das bestehende Modell für den praktischen Einsatz unbrauchbar machen. Durch eine Abstandsbestimmung zu den Trainingsdaten kann zumindest die Ähnlichkeit neuer Daten mit den trainierten Daten abgeschätzt werden. Dies kann zur Erstellung eines Vertrauensindex für das Simulationsergebnis genutzt werden. Hier ist der Einsatz folgender Vertrauensindexte möglich:

- Verwendung aller Trainingsdatensätze. Dieses liefert den Nachteil, daß bei jedem Simulationsschritt alle Datensätze durchsucht werden müssen nach dem minimalen Abstand zum gegenwärtig angelegten Datensatz.
- Verwendung der Stützstellen, die durch den Einsatz von Kohonennetzen gefunden wurden. Dadurch wird der Suchaufwand verringert.

Um ein über mehrere Arbeitspunkte gültiges Simulationsergebnis zu erhalten, bietet sich der Einsatz von Multi-Modellen [82][60][6][7] an, bei denen jedes einzelne Modell für einen speziellen Arbeitspunkt trainiert wird.

3.6 Ergebnisse und Schlußfolgerungen

In diesem Kapitel wurde eine Methodik zur Bestimmung der Konfiguration zur Generierung KNN-basierter Modelle vorgestellt. Folgende Ergebnisse resultieren aus den durchgeführten Arbeiten:

- Eine a-priori-Abschätzung der Modellordnung durch Korrelationsanalyse und Einsatz linearer Modelle lieferte als obere Schranke für die Modellordnung $N=5$.
- Das Training von Multilayer-Perceptrons gestaltete sich aufgrund der schlechten Konvergenz der verwendeten Gradientenabstiegsverfahren als problematisch, aber eine Konvergenzverbesserung konnte durch eine geeignete Datenrepräsentation erzielt werden.
- Eine empirische Studie zum Konvergenzverhalten von Gradientenabstiegsverfahren belegt, daß mit dem Lernverfahren Rprop eine hohe Verlässlichkeit der Trainingsergebnisse unabhängig von der Initialisierung der KNNs vorliegt.
- Die trainierten KNNs zeigten eine höhere Approximationsqualität als lineare Modelle.
- Die Einsatztauglichkeit von RBF-Netzen wurde überprüft. Es läßt sich prinzipiell der Eingaberaum durch geeignete Auswahl an Stützstellen abdecken, aber durch die schlechte Generalisierungsfähigkeit der trainierten RBF-Netze resultiert eine schlechte Modellgüte.

Die entstandenen Modelle sind die Basis für eine modellbasierte Regelung, die im nächsten Kapitel vorgestellt wird.

4 Prozeßregelung von Müllverbrennungsanlagen mit Künstlichen Neuronalen Netzen

Im vorigen Kapitel wurden Künstliche Neuronale Netze zur funktionalen Approximation des nichtlinearen Übertragungsverhaltens des Müllverbrennungsprozesses eingesetzt.

Nun wird beschrieben, wie mit Hilfe eines KNN-basierten Modells Stellgrößen zur Prozeßregelung hergeleitet werden. Die Regelung des Prozesses soll hinsichtlich einer Kostenfunktion, die die Fahrweise des Prozesses bewertet, optimal sein. In der Regelungstechnik wird dieses bei linearen Systemmodellen z.B. durch Regler mit linearer Zustandsrückführung realisiert [22][61]. Für nichtlineare Modelle ist eine explizite optimale Bestimmung der Stellgrößen für die meisten Modellklassen bislang nicht als geschlossene Lösung erhältlich.

In diesem Kapitel wird das Problem der Stellgrößengewinnung zur optimalen Regelung in zwei Komplexe aufgeteilt. Im ersten Komplex werden aus dem KNN-basierten Modell Stellgrößen gewonnen, die das Modell unter Vorgabe der Sollwerte ohne Berücksichtigung der Dynamik des Prozesses zu diesen Sollwerten führt. Das Vorgehen entspricht dem IMC (Internal Model Control [74][27]). Dieses Verfahren eignet sich für das Halten des Systems in einem Gleichgewichtszustand. Bei einer größeren Abweichung vom Sollwert oder bei Sollwertsprüngen können Stellgrößen nicht immer ermittelt werden, die das System in einem Zeitschritt zum Sollwert führen. Es müssen daher Sollwerte vorgegeben werden, die auch erreichbar sind.

Der zweite Komplex umfaßt die Berücksichtigung der dynamischen Eigenschaften des Modells. D.h. hier werden die Sollwerte definiert, die zu einer optimalen Handlungssequenz führen. Theodoro [98] hat Temporal Difference Learning Ansätze [101][89] hierfür untersucht. Bellmann [4] schlägt den Ansatz der dynamischen Programmierung vor. Er ist aber nur anwendbar, wenn das System diskrete Zustände annimmt, oder sich alle möglichen Folgezustände diskretisieren lassen. Diese Voraussetzungen sind aber hier nicht gegeben, da der Eingabevektor des Systemmodells zu hochdimensional ist. Daher wird ein Ansatz verwendet, mit dem sukzessive alle Folgezustände durch Variieren der Führungsgrößen in einem Suchbaum eingetragen werden, der dann mit einer Kostenfunktion ausgewertet wird.

Komplex 2 und Komplex 1 werden dann in einer Kaskadenregelung zusammengefaßt. Die vorgestellten Verfahren werden am Beispiel des inversen Pendels und im geschlossenen Regelbetrieb am Anlagenmodell getestet und gemäß ihrer Leistungsfähigkeit bewertet. Das Kapitel gliedert sich wie folgt:

Zuerst werden starre Kopplungen der Stellgrößen durch die gegebene Anlagenfahrweise beschrieben. In Abschnitt 2 werden mehrere Verfahren zur statischen Stellgrößengewinnung diskutiert, und im praktischen Vergleich bezüglich ihrer Leistungsfähigkeit bewertet. Danach wird ein Adaptionsschritt zur Eliminierung von Modellunsicherheiten beschrieben. In Abschnitt 4 wird das Problem der Suche nach der optimalen Handlungssequenz beschrieben. Baumsuchverfahren werden durch mehrere Algorithmen bzgl. ihrer Geschwindigkeit optimiert, und diese Verfahren werden untereinander verglichen. Abschnitt 5 beschreibt die rechentechnische Realisierung der Regelung für beide Anlagen. In Abschnitt 6 werden praktische Ergebnisse an der Anlage 2 vorgestellt und diskutiert. Ergebnisse zur Anlage 1 befinden sich im Anhang.

4.1 Einschränkungen durch die Anlagenfahrweise

Bevor verschiedene modellbasierte Reglerkonzepte vorgestellt werden, sind ein paar Anmerkungen zu den im vorigen Kapitel gewonnenen Prozeßmodellen notwendig. Es gibt prinzipiell nur zwei Parameter, die als Stellgrößen in den Prozeß eingehen. Dies ist die Primärluftmenge und die aufgetragene Müllmenge (und damit die Geschwindigkeit des Aufgaberosts). Alle anderen Stellgrößen sind statische Abbildungen dieser Parameter. Es lassen sich also funktionale Abhängigkeiten für die restlichen Stellgrößen ermitteln. Im folgenden werden die funktionalen Zusammenhänge zwischen diesen Stellgrößen als starr gekoppelt betrachtet. Ein Entkoppeln/Variieren dieser redundanten Stellgrößen untereinander wird zu einem unvorhersehbaren Verhalten des Modells führen, da es keine Trainingsbeispiele für eine andere Fahrweise gibt. Die funktionalen Abhängigkeiten zwischen den Stellgrößen werden hier für Anlage 2 aufgeführt:

Abhängigkeiten der Parameter der Luftzufuhr:

Die Funktionsweise der drei Luftklappen ist starr miteinander verkoppelt, d.h. aus dem Wert einer Luftklappe können die anderen hergeleitet werden.

Die Sekundärluftmenge ist annähernd konstant. Sie variiert während der ganzen Meßkampagne zwischen 11-12 TM^3/H .

Die Rostgeschwindigkeit ist konstant.

Die Parameter Luft Feld 5_1 und Luft Feld 6_1 lassen sich durch eine Linearkombination aus den Größen Dampfsollwert, Drehzahl_Aufgaberost und der Gesamtluft errechnen.

Da die linearen Abhängigkeiten während des gesamten Prozeßverlaufs gelten, ist es möglich, die Stellgrößen für das Modell auf die Gesamtluftmenge und die Aufgaberostgeschwindigkeit

unter Vorgabe der Dampfsollmenge zu reduzieren. Alle anderen Stellgrößen können hieraus hergeleitet werden.

Die Abhängigkeiten gelten im gesamten Prozeßverlauf, und werden für die modelprädiktive Regelung beibehalten. Eine Verbesserung der bestehenden Regelung durch Variierung der gekoppelten Stellgrößen ist nicht Thema dieses Kapitels.

Daher wird im folgenden die Ermittlung der Stellgrößen Luftzufuhr und Müllmenge beschrieben, und die anderen Stellgrößen hieraus errechnet. Zunächst wird die statische Stellgrößenberechnung beschrieben.

4.2 Statische Stellgrößengewinnung

Die Schwierigkeit beim Suchen geeigneter Stellgrößen zur Annäherung des Systems an Sollwertvorgaben liegt in der impliziten Darstellung der Lösung. Bekannt ist der gewünschte Sollwert, aber nicht die Stellgrößen u , die das System zu diesem Sollwert führen.

In diesem Abschnitt wird daher eine Funktion g gesucht, die die Stellgrößen aufgrund der vorgegebenen Sollwerte und dem aktuellen Prozeßzustand ermittelt. Im folgenden seien u_s die Stellgrößen, die das Prozeßmodell $f(\dots)$ in den gewünschten Folgezustand bzgl. der Sollwerte Dampfmenge und O_2 führen. Dann soll gelten:

$$g(y(k), y(k-1), \dots, y(k-N), u(k-1), \dots, u(k-N)) = u_s(k) \quad (4.1)$$

mit

$$f(y(k), \dots, y(k-N), u_s(k), u(k-1), \dots, u(k-N)) = \hat{y}(k+1) \quad (4.2)$$

wobei die Führungsgrößen von $\hat{y}(k+1)$ die Sollwerte trifft. Im folgenden werden mögliche Varianten der Stellgrößengewinnung diskutiert.

Wird das KNN-basierte Modell als statisch betrachtet, so lassen sich die Stellgrößen durch Lösen eines nichtlinearen Gleichungssystems finden. Bezogen auf den geregelten Müllverbrennungsprozeß ergeben sich verschiedene Varianten, mittels KNNs Stellgrößen zu ermitteln:

1.) Approximierung der vorhandenen Regelung durch ein KNN.

Es wird ein Netz mit gegenwärtigem Systemzustand und Sollwert als Netzeingabe und den Stellgrößen als Netzausgabe trainiert. Dieses Verfahren kann dann verwendet werden, wenn der Regler bekannt, aber in der Praxis nicht verfügbar ist (menschlicher Experte usw.). In einigen Fällen können effektivere Steuerungsrichtlinien und ein einfacherer Regler die Folge sein. Ziel dieser Anwendung ist allerdings nicht eine Nachahmung, sondern eine Verbesserung der vorhandenen Regelung.

2.) Extraktion der Stellgrößen aus dem Anlagenmodell durch systematische Suche.

Im Gegensatz zur realen Anlage kann mit dem Anlagenmodell experimentiert werden, um die Stellgrößen für eine Sollwertberechnung zu bestimmen. Der einfachste Fall wird über ein Probieren verschiedener Stellgrößen und Abschätzung des Effekts auf den Folgezustand erhalten. Über eine Intervallschachtelung kann eine Konvergenz beschleunigt werden. In [20] wurden evolutionäre Algorithmen zur Bestimmung der optimalen Stellgrößen bzgl. des Erreichens des Sollwerts eingesetzt.

3.) Extraktion der Stellgrößen durch Gradientenbildung (Differentiation des Anlagenmodells).

Da das Anlagenmodell durch ein Multilayer Perceptron realisiert wurde, läßt sich die Differenzierbarkeit des Modells für eine Bestimmung der Stellgrößen nutzen. Hierzu wird in einem iterativen Prozeß unter Vorgabe beliebiger Stellgrößen an das Anlagenmodell in einem Feedforward Schritt eine Ausgabe erzeugt. Die Differenz der Ausgabe zu den Sollwerten bezüglich der Führungsgrößen wird durch das KNN zurückpropagiert und liefert am Eingang des KNN bezüglich der Stellgrößen eine verbesserte Schätzung für die Stellgrößen (Abbildung 4.1).

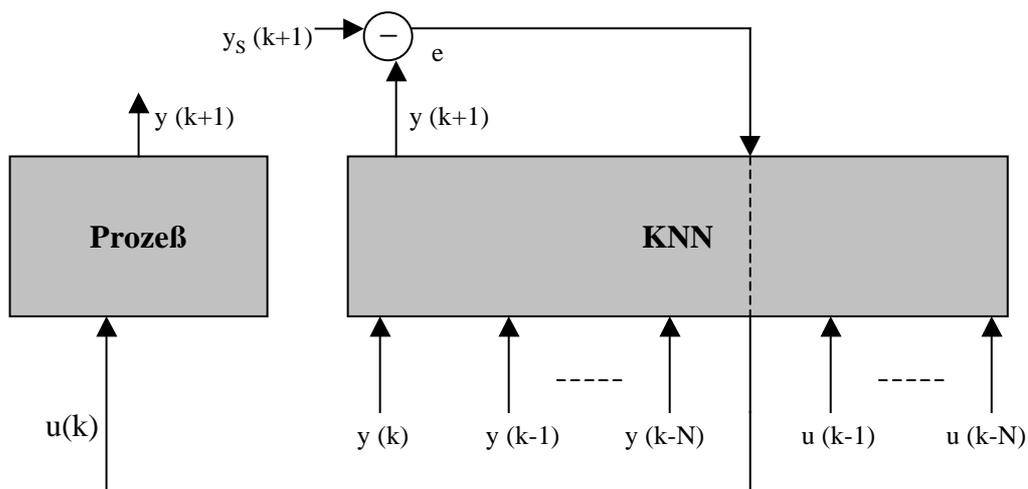


Abbildung 4.1: Stellgrößengewinnung durch Rückpropagierung durch das Anlagenmodell.

Ein großer Nachteil dieser Methode wird deutlich, wenn verschiedene Systemeingaben zu der gleichen Ausgabe führen. Dann ist die systeminverse Anlage nicht definiert, und das Regelungsnetz würde mit Hilfe einer Mittelung Ausgaben zur gleichen Eingabe in Beziehung setzen [93]. Für den Einsatz in der Müllverbrennung ist allerdings die Anzahl der Stellgrößen gleich der Anzahl der Sollwerte, so daß eine bijektive Abbildung in den meisten Fällen gegeben ist.

Die Punkte 2 und 3 werden nun genauer beschrieben und getestet.

4.2.1 Gewinnung der Stellgrößen durch systematische Suche

Bei Systemen mit ein oder zwei gesuchten Stellgrößen können diese durch sukzessives Einsetzen verschiedener Werte am Modelleingang ermittelt werden. Hierzu wird der Suchraum diskretisiert. Mit der Größe des Suchraums steigt aber auch der Rechenaufwand bzw. sinkt bei einer groberen Diskretisierung die Genauigkeit der gefundenen Lösung. Ist der Suchraum einigermaßen "glatt", d.h. er enthält nicht viele lokale Minima, so kann die Suche nach dem Optimum schneller erfolgen durch Intervallschachtelung. Hierzu wird der n-dimensionale Suchraum in n-dimensionale, äquidistante Intervalle zerlegt, und dann rekursiv das Intervall mit der besten gefundenen Lösung feiner unterteilt. Der Aufwand des Algorithmus steigt exponentiell mit der Anzahl der Freiheitsgrade, aber im zweidimensionalen Fall ist er einsetzbar.

Der Algorithmus:

Unterteile den Definitionsbereich jeder gesuchten Stellgröße in 10 gleichgroße Intervalle.

Für jedes Intervall I

 bilde den Mittelpunkt $X(I)$

 Berechne aus den Vorschlag $X(i)$ die restlichen erforderlichen Stellgrößen.

 Gebe den aktuellen Systemzustand und die Stellgrößen als Eingabe an das Systemmodell.

 Berechne die Netzausgabe und den Stellgrößenfehler (Differenz zwischen Ist- und Sollwert).

 Falls die Eingabe einen geringeren Stellgrößenfehler erzeugt, als vorige Eingaben, merke diese Stellgrößen.

Für die besten Stellgrößen $X(I)_{\text{best}}$ zerlege das umgebende Intervall I in 10 gleichgroße Intervalle I' und wende den Algorithmus auf die Intervalle I' an, falls maximale Rekursionstiefe nicht erreicht.

Eine Rekursionstiefe von drei führt zu ausreichend genauen Ergebnissen für die Stellgrößen, da mit jedem Rekursionsschritt die Genauigkeit um eine Zehnerpotenz steigt.

4.2.2 Gewinnung der Stellgrößen durch Rückpropagierung durch das Anlagenmodell

Das bestehende Systemmodell ist mit MLPs realisiert. Somit kann die Differenz von Mo-

dellausgabe und Sollwert auf Eingaben von Stellgrößen zurückpropagiert werden.

In einem *Feedforward*-Schritt werden der Systemzustand und die bisher abgegebenen Stellgrößen in das Netz eingegeben. Daraus wird der resultierende Prozeßzustand bestimmt. Die Differenz zwischen dem berechneten Zustand und dem gewünschten Prozeßzustand wird zurückpropagiert, ohne daß die Gewichte des Modells geändert werden. So wird der Fehler zurück zur Eingabe des Modells propagiert. Der Gradient bezüglich der Stellgrößen liefert eine verbesserte Schätzung für die Stellgrößen, welche daraufhin aktualisiert werden. Diese Schritte werden mehrmals durchlaufen, bis keine nennenswerte Veränderung der Stellgrößen mehr auftritt.

Der Algorithmus:

Schalte vor jedes Eingabeneuron, das eine Stellgröße repräsentiert, ein neues Eingabeneuron.

Setze die Eingabe der Eingabeneuronen auf 1

Initialisiere die Gewichte der Eingabeneuronen

Für jeden Zeitschritt gilt

Solange Ausgabefehler jenseits einer bestimmten Schwelle:

Eingabemuster auf Netz anwenden und vorwärts propagieren.

Differenz zwischen gewünschtem und realem Wert zurück bis zum zusätzlichen Eingabeneuron propagieren.

Gewicht des Eingabeneurons aktualisieren (ursprünglich 1) für bessere Abschätzung des fehlenden Parameters

Bis Gewichtswechsel einen Grenzwert unterschreitet oder maximale Anzahl Zeitschritte erreicht.

Die neu berechneten Gewichte sind nun die Stellgrößen.

Abbildung 4.2 zeigt die Erweiterung des Systemmodells an den Eingängen der Stellgrößen.

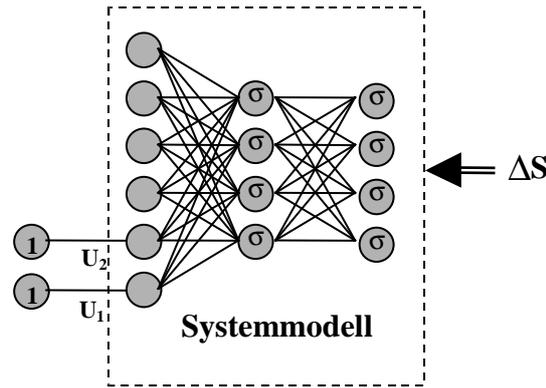


Abbildung 4.2: Rückpropagierung der verbesserten Schätzwerte für die Stellgrößen.

ΔS sind die Abweichungen von Ist- und Sollwert der Führungsgrößen Dampfmenge und O_2 -Gehalt.

Nun werden die Verfahren aus 4.2.1 und 4.2.2 experimentell hinsichtlich ihrer Leistungsfähigkeit verglichen.

4.2.3 Experimenteller Vergleich Stellgrößenerzeugung

Die explizite Suche von Stellgrößen am Modell und die Stellgrößengewinnung durch Gradientenbildung am Anlagenmodell werden nun auf ihre Leistungsfähigkeit getestet. Kriterien sind

- die Güte der erzeugten Stellgrößen (gemessen an der Abweichung von Sollwert und Istwert des durch die Größen produzierten Folgezustands) und
- der rechnerische Aufwand beim Bestimmen dieser Stellgrößen.

Die Meßdaten der Anlage 2 wurden zum Training eines Anlagenmodells gemäß der in Kapitel 3 vorgestellten Methodik gewonnen. Im Unterschied zur Modellierung von Anlage 2 werden die redundanten Stellgrößen nicht als Modelleingänge verwendet, sondern das Anlagenmodell sieht nur zwei Stellgrößen (Geschwindigkeit des Aufgaberostes und Primärluftzufuhr) vor. Die Führungsgrößen sind die erzeugte Dampfmenge und der O_2 -Gehalt des Rauchgases.

Es wurden für 1000 Testbetriebszustände und vorgegebene Sollwerte die Stellgrößen ermittelt. Tabelle 4.1 zeigt die Approximationsqualität und den rechnerischen Aufwand der beiden Verfahren.

	MSE(Ist,Soll)	Gesamtrechenzeit
Explizite Suche nach 4.2.1	0.002	0.8 s
Rückpropagierung des Anlagenmodells nach 4.2.2	0.1	1.12 s

Tabelle 4.1: Genauigkeit der Stellgrößen und Rechenzeit zu ihrer Ermittlung.

Der rechnerische Aufwand beider Verfahren liegt in der gleichen Größenordnung. Der Vergleich des MSE zwischen Ist- und Sollwert zeigt jedoch, daß die Intervallschachtelung, d.h. die explizite Suche nach Stellgrößen, qualitativ bessere Stellgrößen erzeugt. Bei der Methode der Rückpropagierung durch das Anlagenmodell kann bei manchen Betriebszuständen das Optimum nicht erreicht werden, was den Gradientenabstiegsverfahren zuzuschreiben ist:

Ein teilweise schlechtes Konvergenzverhalten wird verursacht durch die partielle Aktualisierung der Gewichte. Während im Training eines vollständigen Netzes alle Gewichte gemäß dem Gradienten der Fehlerfunktion aktualisiert werden, ist bei der hier eingesetzten Differentiation des Modells nur eine Gewichtsaktualisierung an den Eingängen für die Stellgrößen erlaubt. Die Gewichte des Modells bleiben unverändert. Folgende Abbildung illustriert den Effekt der partiellen Aktualisierung anhand der Fehlerfunktion.

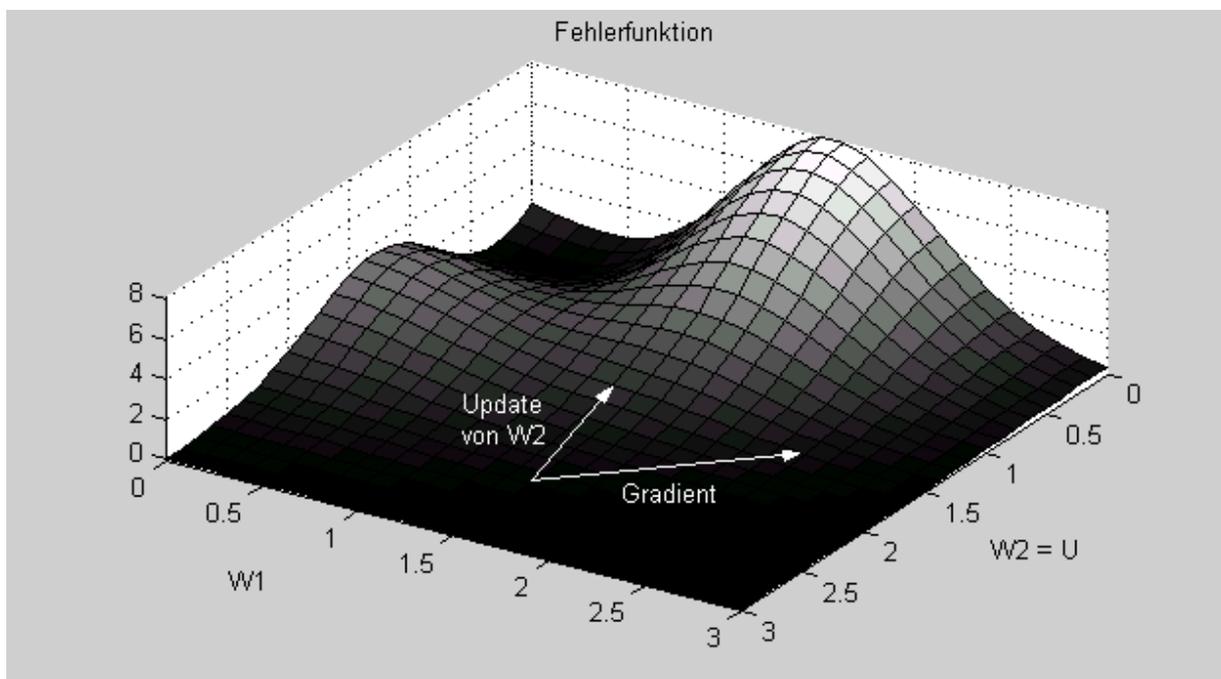


Abbildung 4.3: Fehlerfunktion in Abhängigkeit zweier Gewichte. Während der Gradient das lokale Extremum der Fehlerfunktion umläuft, führt die partielle Aktualisierung von $W1$ in eine Sackgasse.

Durch die partielle Aktualisierung findet eine Projektion des Gradienten auf die Gewichte an den Eingängen des Netzes statt. Lokale Extrema werden so gegebenenfalls nicht mehr umgangen.

Die systematische Suche liefert verlässlichere Stellgrößen und wird im folgenden weiter zur statischen Stellgrößengewinnung verwendet.

Nun wird die Methode der statischen Stellgrößengewinnung für die Regelung eines Spielzeugbeispiels (inverses Pendel) verwendet. Danach wird sie auf das KNN-basierten Modell des Müllverbrennungsprozesses angewandt.

4.2.4 Anwendung der statischen Stellgrößengewinnung auf die Regelung eines inversen Pendels

Die Funktion des oben beschriebenen Verfahrens soll nun anhand eines Beispiels veranschaulicht werden. Dabei handelt es sich um die Simulation eines inversen Pendels. Da das System durch Differentialgleichungen beschrieben wird, ist hiermit eine ‚Anlage‘ vorhanden, an der experimentiert werden kann.

4.2.4.1 Systembeschreibung des inversen Pendels

Auf einem in horizontaler Richtung beweglichen Wagen befindet sich ein inverses Pendel, das drehbar auf dem Wagen befestigt ist (Abbildung 4.4). Der Wagen muß über die horizontal wirkende Kraft F so gesteuert werden, daß der Stab in aufrechter Position und die Geschwindigkeit des Wagens bei Null gehalten wird. Die Stabposition wird durch den Winkel φ gemessen. Weitere Zustandsgrößen sind die Winkelgeschwindigkeit $\dot{\varphi}$, die Wagenposition x und die Geschwindigkeit \dot{x} .

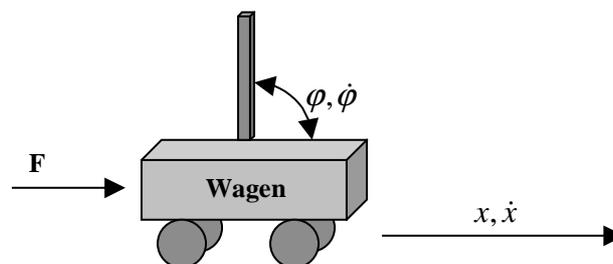


Abbildung 4.4: Inverses Pendel. Die Kraft F bewegt den Wagen, um den Stab in aufrechter Position zu halten.

Die Dynamik des Pendels läßt sich mit Hilfe der folgenden Differentialgleichungen beschreiben [16]:

$$\begin{aligned} \left(\frac{F}{m} - g \sin \varphi \cos \varphi + l \dot{\varphi} \sin \varphi\right) / \frac{M}{m} + \sin^2 \varphi &= \ddot{x} \\ -\left(\frac{F}{m} \cos \varphi + (M + m) \frac{g}{m} \sin \varphi - l \dot{\varphi}^2 \sin \varphi \cos \varphi\right) / L \left(\frac{M}{m} + \sin^2 \varphi\right) &= \ddot{\varphi} \end{aligned} \quad (4.3)$$

(M = Masse des Wagens, m = Masse des Pendels, l = Länge des Pendels)

Gl. (4.3) beschreibt das nichtlineare Systemmodell. Mit diesem Systemmodell werden Trainingsdaten für ein KNN erzeugt. Die Eingaben umfassen den Winkel, die Winkelgeschwindigkeit, die Position des Wagens, seine Geschwindigkeit und die ausgeübte Kraft in x-Richtung. Die Ausgabe beschreibt die Differenz von gegenwärtigem zum nachfolgenden Zustand von Stab und Wagen unter Einwirkung der Kraft F .

Das System des inversen Pendels wurde mit dem Verfahren nach Runge-Kutta 4. Ordnung implementiert [83]. Die Meßzeit für jede Integration beträgt 0,2 Sekunden. Das Pendel steht aufrecht bei einem Winkel von 0 Grad. Ein MLP wird mit Mustern der folgenden Struktur trainiert:

Eingabe: $\varphi(t), \dot{\varphi}(t), x(t), \dot{x}(t), F(t)$

Ausgabe: $\Delta\varphi(t+1), \Delta\dot{\varphi}(t+1), \Delta x(t+1), \Delta\dot{x}(t+1)$

Trainingsdaten wurden innerhalb der folgenden Intervalle geliefert:

$\varphi \in [-1,1], \dot{\varphi} \in [-1,1], x = 0, \dot{x} \in [-5,5]$ und $F \in [-2,2]$

Die Position des Wagens ist nicht beschränkt und wird daher stets mit einem Anfangswert von Null modelliert.

Dieses trainierte Netz wurde zur Ermittlung der statischen Stellgrößengewinnung nach (4.2.1) verwendet.

Die folgende Abbildung zeigt die Regelung des Pendels durch statische Stellgrößenbestimmung. Die Kraft als aufzubringende Stellgröße wird mit Hilfe der durch die statische Stellgrößengewinnung errechneten Funktion g berechnet.

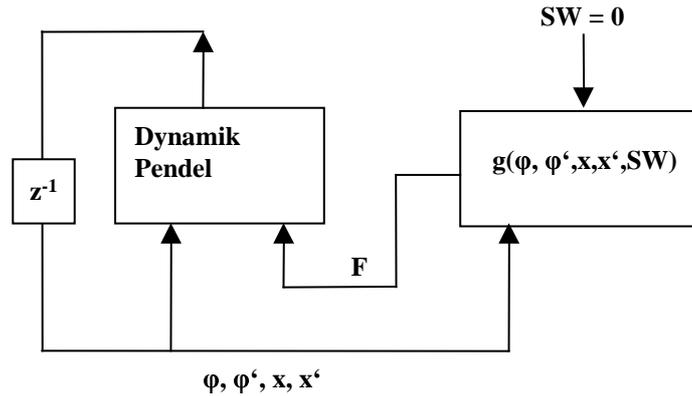


Abbildung 4.5: Konfiguration der Regelung des inversen Pendels.

Das Modell ist Bestandteil der Funktion zur Stellgrößenberechnung. Es erhält die Ausgabe des Systems als Systemzustand und es wird benutzt, um die Stellgröße F zu bestimmen, die zu einer aufrechten Position des Stabes ($\varphi = 0$) führt.

Nach dem Training des Modells wurde das Pendelmodell auf einen Winkel von 57° geneigt. Abbildung 4.6 zeigt die Neigung des Pendels unter Einwirkung der Regelung.

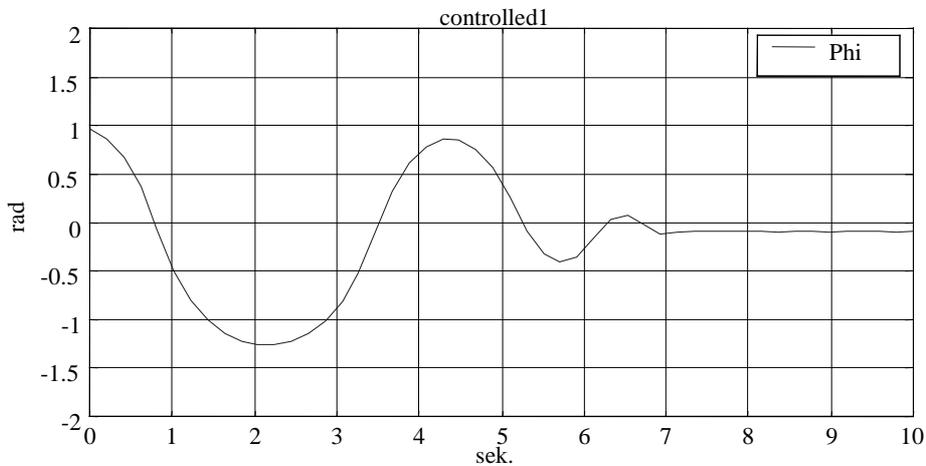


Abbildung 4.6: Darstellung des Winkels φ des Systems.

Nach dem Einschwingvorgang von ca 35 Zeitschritten (ca. 7 Sekunden) ist durch Differenz von Modellausgabe und Prozeß ein ständiger Offset vorhanden, der nicht ausgeregelt werden kann. Als Effekt ergibt sich ein ständiges Abgeben von Stellgrößen, die laut Modell genau zum Sollwert, aber im realen Prozeß zu einer Abweichung des Sollwerts führen.

4.2.4.2 Eliminierung des Offsets durch Modellfehler

Abhilfe kann durch einen Adaptionsschritt geschaffen werden. Die Differenz von System und Modellausgabe im vorigen Zeitschritt wird subtrahiert von dem aktuellen Systemzustand $y(t)$ im Argument der Stellgrößenfunktion $g(\cdot)$. D.h. anstelle von $g(y(t), S)$ wird $g(y(t) - \Delta(t), S)$ zur Stellgrößenerzeugung verwendet [14].

Diese Istwertkorrektur von y führt zu einer Elimination des Offsets, wenn das Modell stetig ist, und somit lokale Linearität vorausgesetzt werden kann. Sei $\Delta(t)$ der Modellfehler, f das KNN-Modell der Anlage und g die Funktion zur Stellgrößenerzeugung. Dann gilt:

$$\Delta(t) = \hat{y}(t) - y(t) \quad (4.4)$$

$$\hat{y}(t+1) = f(y(t), g(y(t), S)) \quad (4.5)$$

$$\begin{aligned} y(t+1) &= f(y(t), g(y(t), S)) + \Delta(t) \\ &\approx f(y(t) - \Delta(t), g(y(t), S)) \\ &\approx f(y(t), g(y(t) - \Delta(t), S)) \end{aligned} \quad (4.6)$$

D.h. die erhaltene Schätzung für u verringert den Modellfehler $\Delta(t+1)$. Folgende Abbildung zeigt die Neigung des Pendels durch die so erzeugten Stellgrößen.

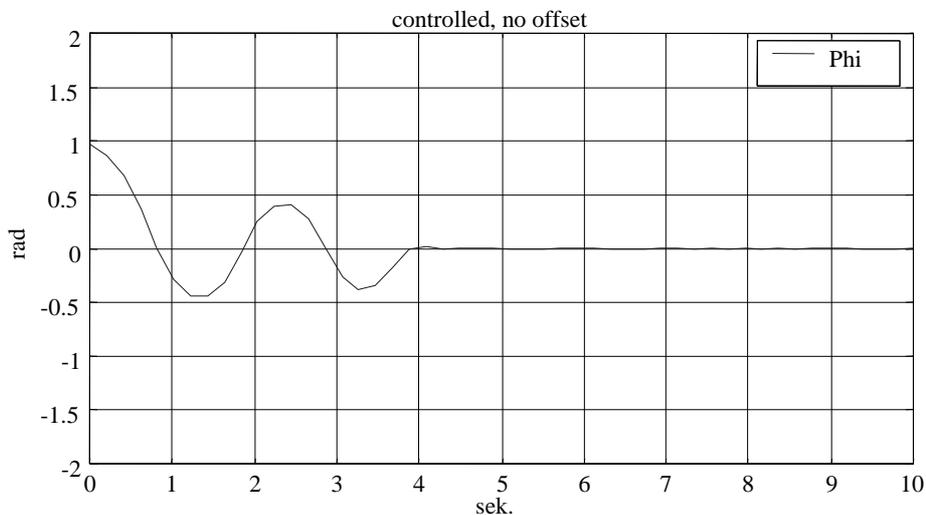


Abbildung 4.7: Darstellung der Stabausrichtung φ des Systems.

Die Stellgrößen wurden erzeugt nach Differenz von vergangenem Modellfehler zu jetzigem Zustand. Abbildung 4.7 zeigt, daß der Offset wirklich verschwindet und das Pendel schneller in die gewünschte Position gerät.

Somit ist gezeigt, daß durch die modellbasierte Regelung das System des inversen Pendels geregelt werden kann und durch die Stellgrößeberechnung mit dem Verfahren der Offseteliminierung schneller in einen stabilen Zustand gebracht wird.

4.2.5 Anwendung der statischen Stellgrößengewinnung auf das Prozeßmodell der Müllverbrennung

Das Verfahren der Stellgrößengewinnung wird nun zur Regelung der Dampfmenge und des O₂-Gehalts mittels Luftzufuhr und Rostgeschwindigkeit verwendet. Die folgende Abbildung zeigt, wie die Stellgrößen von einem Simulator ermittelt und auf einen anderen Simulator (der anstelle der realen Verbrennungsanlage verwendet wird) angewandt werden können. Es wurden zwei unterschiedliche Modelle gewählt, um die Modellunsicherheit einzubringen. (Die Ergebnisse der Modellierung von Anlage 2 sind dem Anhang zu entnehmen). Abbildung 4.8 zeigt die Konfiguration, die analog der Konfiguration zur Regelung des inversen Pendel funktioniert. Anstelle des inversen Pendels tritt hier ein KNN-basiertes Anlagenmodell auf.

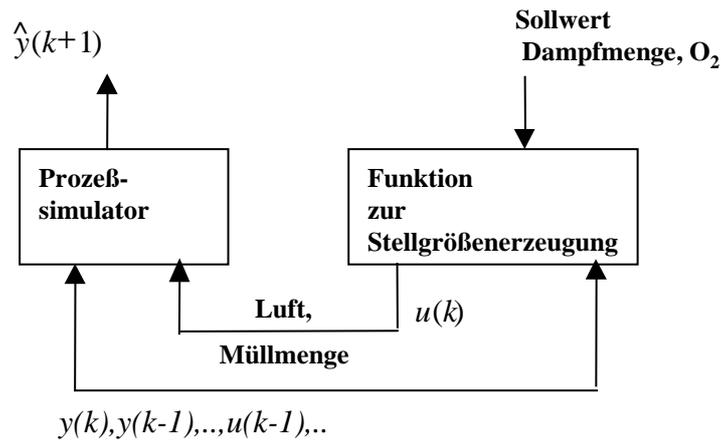


Abbildung 4.8: Konfiguration der Regelung des Anlagenmodells.

Der Prozeßsimulator stellt hier das zu regelnde dynamische System dar. Das Modell zur Stellgrößenerzeugung dient allein der Erzeugung der Stellgrößen unter Vorgabe der Sollwerte für Dampfmenge und O₂-Gehalt. Hierbei wird die Methode der Eliminierung des Offsets benutzt, das am Beispiel des inversen Pendels beschrieben wurde. Die erzeugten Stellgrößen werden dann an den Prozeßsimulator gegeben, der den nachfolgenden neuen Prozeßzustand erzeugt. Dies erfolgt nach dem Serien-Parallelmodell, d.h. die Modellausgabe wird nicht an den Eingang rückgeführt.

Abbildung 4.9 zeigt das Verhalten des Prozeßsimulators aufgrund der mit Hilfe dieser Methode ermittelten Stellgrößen. Alle Größen sind auf den Bereich $[0,1]$ normiert. In der linken Hälfte werden die Originaldaten des Prozesses gezeigt, in der rechten Hälfte die Daten des Prozeßsimulators nach einem Zeitschritt nach Anlegen der durch die statische Stellgrößengewinnung erzeugten Stellgrößen.

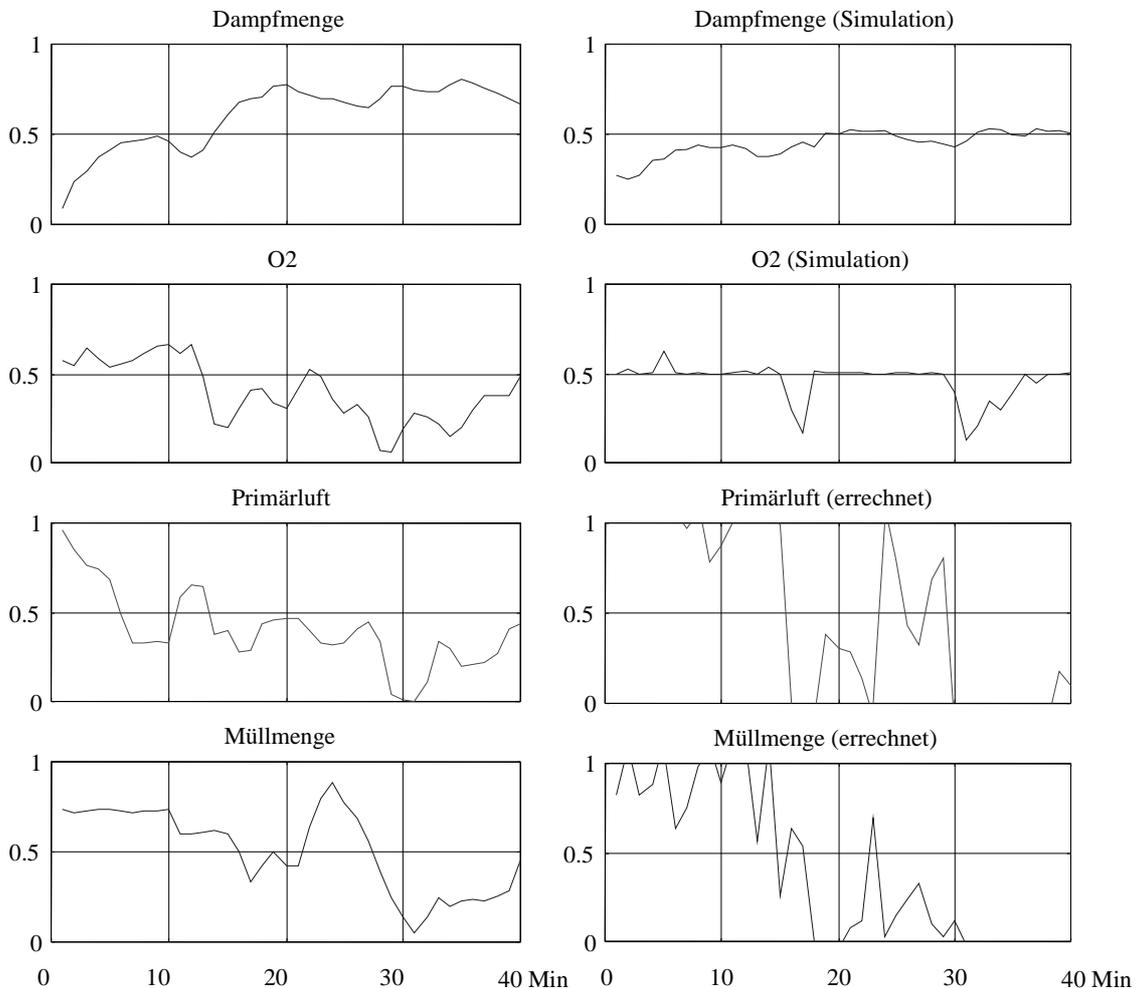


Abbildung 4.9: Meßdaten (links) und Simulationsergebnisse unter Verwendung statischer Stellgrößengewinnung.

Die errechneten Führungsgrößen der linken Bildhälfte (Dampfmenge und O₂-Gehalt) erreichen die Sollwerte (hier 0.5) auf dem Simulator. Wo die Sollwerte nicht erreicht werden, reichen die Stellgrößen nicht aus, um die Sollwerte in einem Zeitschritt zu erreichen. Hier besitzen die so erzeugten Stellgrößen sehr hohe Werte, da versucht wird, die Sollwerte in einem Zeitschritt unabhängig von dem gegenwärtigem Wert der Führungsgrößen zu erlangen.

Abhilfe kann z.B. durch ein Referenzmodell geschaffen werden, das die Führungsgrößen langsam an die Sollwerte zuführt. Alternativ kann eine Trajektorie (Sequenz aus Sollwerten) erzeugt werden, die aus der Minimierung einer Kostenfunktion durch mehrmaliges Anwenden des Modells auf sich selber entsteht. Diese Vorgehensweise wird im folgenden Abschnitt beschrieben.

4.3 Prozeßregelung mit optimaler Stellgrößenvorgabe

Im vorangegangenen Abschnitt wurde ein Prozeßmodell mit Hilfe eines inversen Modells gesteuert. Dies führte zu Schwingungen bei der Abgabe von Stellgrößen, da die Systemdynamik nicht berücksichtigt wurde. Diese Anwendung der Bestimmung der direkten Inversen der Regelstrecke eignet sich nur für Systeme mit minimalen Totzeiten und für Situationen, in denen die Führungsgrößen bereits nahe am Sollwert sind. In diesem Abschnitt soll nun ein Verfahren zur Generierung einer Referenztrajektorie vorgestellt werden, mit dessen Hilfe der geschlossene Regelkreis in einen stabilen Zustand gezwungen wird.

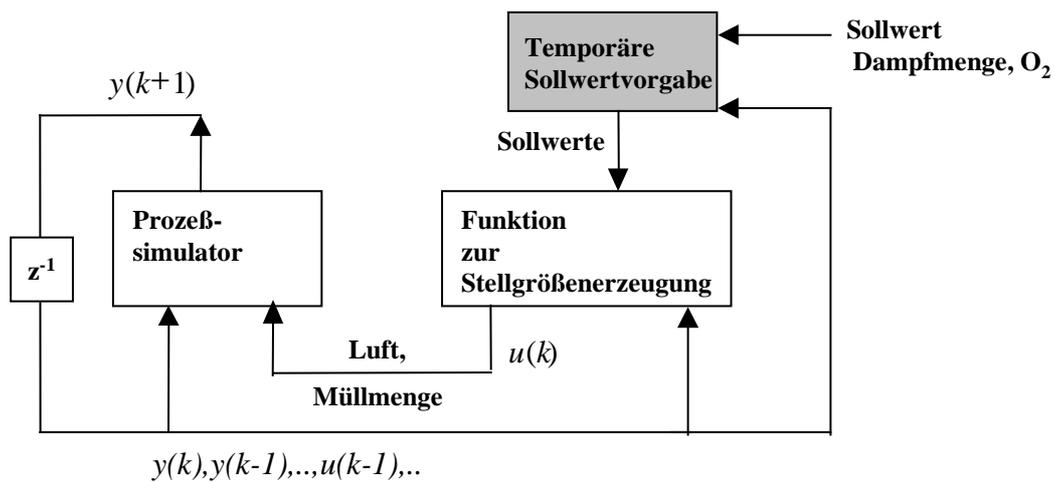


Abbildung 4.10: Aufbau einer modellprädiktiven Regelung

Es ist nicht erforderlich, den gewünschten Prozeßzustand in einem Schritt zu erreichen, insbesondere, wenn zwischen dem aktuellen und dem gewünschten Prozeßzustand ein großer Unterschied besteht. Mit Unterstützung des KNN-basierten Modells wird daher eine Handlungskette bestimmt, die den Prozeß in mehreren Zeitschritten von dem aktuellen Zustand in einen endgültigen Zustand unter Berücksichtigung von Optimierungskriterien überführt. Hierzu werden temporäre Vorgaben (Sollwerte) über einen bestimmten zeitlichen Horizont gesucht. In der in Abbildung 4.10 dargestellten Konfiguration wird nun der Block ‚temporäre Sollwertvorgabe‘ vorgestellt.

4.3.1 Bestimmung einer optimalen Handlungssequenz

Ausgehend von dem aktuellen Prozeßzustand zum Zeitpunkt t_0 wird der beste Weg zu dem gewünschten Sollwert S^* innerhalb einer bestimmten Zeit t_1 benötigt. Hierzu werden mehrere Wege konstruiert und bewertet. Ausgehend von einem momentanen Sollwert werden mehrere temporäre Sollwerte in Richtung des endgültigen Sollwerts vorgeschlagen. Es findet also eine Diskretisierung des Suchraums der temporären Sollwerte statt. Die Stellgrößen werden durch statische Stellgrößengewinnung bestimmt, wie in 4.2.1 beschrieben. Die Suchtiefe der Handlungssequenz wird auf einen Vorhersagehorizont von vier Iterationen festgelegt. Danach werden die Trajektorien mit Hilfe einer Gütefunktion gemessen und die Trajektorie, die das Kriterium am besten erfüllt, wird ausgewählt und der erste temporäre Sollwert angewandt (Abbildung 4.11).

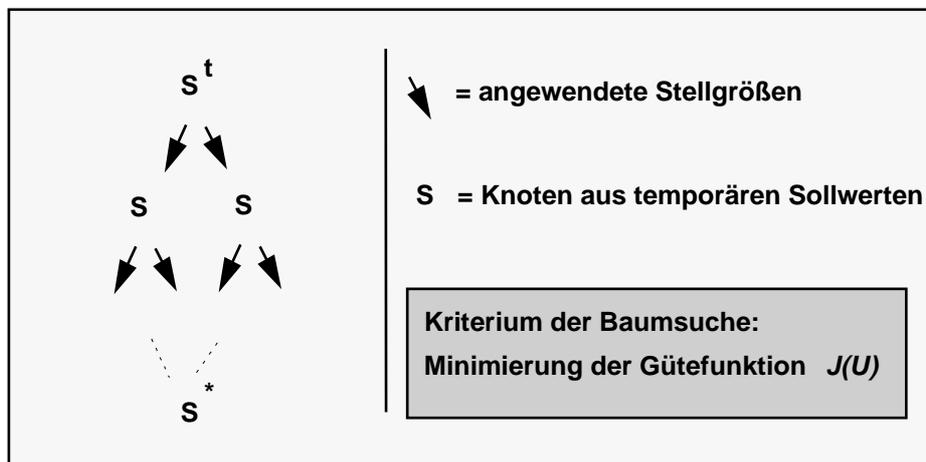


Abbildung 4.11: Schematische Darstellung des Versuchs der Bestimmung einer geeigneten Referenztrajektorie.

Das Kriterium besteht in diesem Fall darin, geringe Stellgrößen zu verwenden und den Sollwert S^* so schnell wie möglich zu erreichen. Dies geschieht durch Minimierung der Gütefunktion

$$J(U) = \sum_{t=T_0}^{T_1} j_1 (S(t) - S^*)^2 + j_2 U(t)^2 + j_3 T(t)^2 \quad (4.7)$$

mit $U = (U(T_0), \dots, U(T_1))$, wobei j_1, j_2, j_3 konstante Gewichtungen der einzelnen Terme darstellen. Durch Einbeziehen der Stellgrößen $U(t)$ werden große Stellgrößen bestraft. $T(t)$ ist ein Vertrauensindex, der ein Abweichen des Arbeitspunkts vom Arbeitspunkt des trainierten Mo-

dells anzeigt. Der Vertrauensindex kann z.B. durch den Algorithmus aus Abschnitt 3.3.4.1 errechnet werden. Eine starke Gewichtung des Vertrauensindex führt zum Favorisieren von Lösungen, deren Trajektorie sich nah am Arbeitspunkt des trainierten Modells befinden, wie später an praktische Ergebnissen gezeigt wird.

In der praktischen Anwendung wird zu jedem Zeitschritt ein ganzer Baum aufgestellt, jeder Pfad des Baumes bewertet und dann die Stellgrößen des ersten Abschnitts des besten Pfades als Ausgabe genommen. Die Knoten des Baumes sind temporäre Sollwerte S^t für die Führungsgrößen Dampfmenge und O_2 -Gehalt.

Nun wird das Verfahren zur Vorgabe temporärer Sollwerte mit dem Einsatz eines Referenzmodells am Beispiel des inversen Pendels hinsichtlich ihrer Leistungsfähigkeit miteinander verglichen.

4.3.1.1 Vorgabe eines Referenzmodells

Das Ermitteln der Referenztrajektorie soll hier wieder am Beispiel des inversen Pendels gezeigt werden.

Folgende Abbildung zeigt die Vorgabe der Sollwerte anhand eines Referenzmodells der Form

$$y(k + 1) = 0.3 y^*(k) + 0.7 y_{ist}(k) \tag{4.8}$$

wobei y^* der finale Sollwert ist.

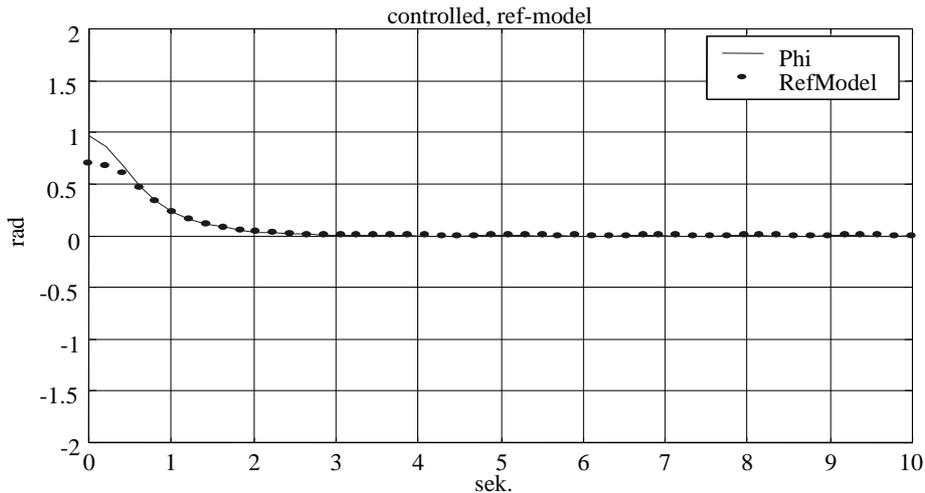


Abbildung 4.12: Verlauf des Pendels bei Referenzmodellvorgabe.

Abbildung 4.12 zeigt, daß das Referenzmodell gut eingehalten wird, aber der transiente Vorgang zum Erreichen des Sollwerts (Pendelstellung = Null Grad) nicht in minimaler Zeit erfolgt. Es kann zwar ein Referenzmodell verwendet werden, das schneller gegen die Sollwerte konvergiert, aber das Pendel ist dann nicht mehr in der Lage, dem Referenzmodell zu folgen, (wie dies bereits in den ersten drei Schritten in Abbildung 4.12 ersichtlich ist).

4.3.1.2 Einsatz der temporären Sollwertvorgabe

Zur Regelung des inversen Pendels wurde die temporäre Sollwertvorgabe implementiert und angewendet. Die Suchtiefe beträgt hier 4 Zeitschritte und die Anzahl der Verzweigungen pro Teilpfad ist fünf. Somit hat der aufgestellte Baum 625 Pfade. Folgende Abbildung zeigt den Einsatz der über die Suchstrategie gefundenen Referenzwerte. Das Pendel hat sich in einer Sekunde auf den Sollwert eingestellt hat. Ein Überschwingen über den Sollwert hinaus, wie bei direktem Anwenden der inversen Dynamik auf einen stationären Sollwert tritt fast nicht auf.

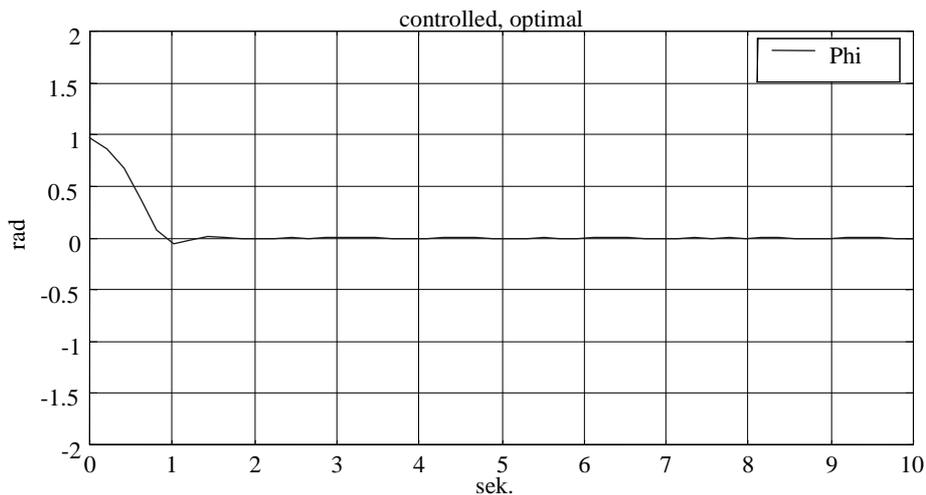


Abbildung 4.13: Verlauf des Pendels bei Einsatz der Suchstrategie für optimierte Handlungssequenz

Das Durchsuchen des vollständigen Baums kann für das Problem des inversen Pendels noch in relativ kurzer Zeit durchgeführt werden, da es sich um ein System mit nur einer Führungsgröße handelt. Für die Regelung des multivariaten Systems der Müllverbrennung ist der Suchraum größer und muß mit algorithmischen Mitteln eingeschränkt werden, bevor das Verfahren auf die Regelung der Müllverbrennung angewendet werden kann.

4.3.2 Algorithmische Optimierung

Die Aufstellung des Suchbaums sowie die Berechnung des kostengünstigsten Pfades erfordert einen hohen rechnerischen Aufwand. Eine Diskretisierung des Suchraums in vier mögliche Alternativen pro Führungsgröße (hier Dampfmenge und O₂-Gehalt) ergibt bei einem Prädiktionshorizont von 4 Zeitschritten einen Baum mit $4^{24} = 65536$ Pfaden.

Um nicht den ganzen Suchbaum aufzubauen und nach einem besten (kürzesten) Weg durchsuchen zu müssen, werden Suchstrategien eingesetzt, die die Rechenzeit erheblich reduzieren. Diese Strategien nutzen die Monotonie der Kostenfunktion über den zeitlichen Horizont. Hierzu bieten sich die nachfolgend beschriebenen Möglichkeiten an.

4.3.2.1 Branch and Bound Suche:

Bei der Branch and Bound Suche [107] wird der Suchbaum sukzessive aufgebaut. Während der Suche gibt es viele unvollständige Wege, die sich für eine weitere Betrachtung anbieten. Der kürzeste davon wird um eine Ebene erweitert, wobei so viele unvollständige Wege wie vorhandene Zweige geschaffen werden. (Hierbei ist ein Weg kurz, wenn die Kostenfunktion ihn gering bewertet, ein Weg ist vollständig, wenn er die Länge des Prädiktionshorizonts hat). Diese neuen Wege werden dann zusammen mit verbleibenden alten Wegen betrachtet, und wiederum wird der kürzeste erweitert. Dies wird bis zum Prädiktionshorizont wiederholt. Da zur Erweiterung immer der kürzeste Weg gewählt wurde, kann der das Ziel erreichende Weg mit Sicherheit als optimal angesehen werden. Allerdings kann der letzte Schritt zum Erreichen des Ziels lang genug sein, um die vermutete Lösung länger zu machen als einen oder mehrere unvollständige Wege. Es besteht die Möglichkeit, daß nur ein winziger Schritt einen der unvollständigen Wege bis zum Zielpunkt erweitern wird. Um dies zu verhindern, wird eine stärkere Abbruchbedingung gefordert: Der Algorithmus wird erst beendet, wenn der kürzeste unvollständige Weg länger als der gefundene (vollständige) Weg ist. In der praktischen Anwendung ergibt sich durch diese Abbruchbedingung keine Leistungseinbuße.

Algorithmus für Branch and Bound.

Es wird ein rekursiver Abstieg durch den Suchbaum gemacht.

Branch and Bound (bisheriger Pfad)

- 1 Bilde eine Liste aus neuen Pfaden durch Anhängen von Teilmengen an den bisherigen Pfad
- 2 Für jeden neuen Pfad bestimme die Kosten zum Durchlaufen des Pfades.

```

2a1 Falls Kosten größer als bisher günstigste Kosten für ei-
    nen vollständigen Pfad:
    Gehe zu 2
Sonst:
2a2 Falls maximale Pfadlänge erreicht ist:
    bisher_günstigste_Gesamtkosten := Kosten zum Durchlaufen
    des neuen Pfades
    Günstigster Pfad := neuer Pfad.
    Gehe zu 2
Sonst:
2a3 Branch and Bound (neuer Pfad)

```

Die Routine wird aufgerufen mit dem aktuellen Systemzustand (als Pfad der Länge Null). Zuerst wird ein Pfad mit vollständiger Tiefe durchgegangen und mit den bisher günstigsten Gesamtkosten versehen. Nachfolgende Teilwege werden nur noch vollständig durchlaufen, falls ihre Kosten bei Pfadlänge minus Eins die bisher niedrigsten Gesamtkosten unterbieten.

Die bisher niedrigsten Gesamtkosten und der günstigste Pfad sind hierbei globale Variablen, d.h. sie sind einmalig vorhanden und von jeder Rekursionstiefe sichtbar.

Obiger Algorithmus kann noch effizienter gestaltet werden, indem eine Abschätzung der Restkosten bei der Aufstellung von Teilwegen durchgeführt wird.

4.3.2.2 A* Baumsuche

Die Prozedur A* ist eine Branch and Bound Suche mit einer Abschätzung der verbleibenden Entfernung nach dem Prinzip der dynamischen Programmierung [96]. Wenn die Abschätzung der Restentfernung ein unterer Grenzwert der tatsächlichen Entfernung ist, dann ergeben sich aus A* optimale Lösungen. Im allgemeinen kann die Abschätzung als untere Grenzwertschätzung angenommen werden, wenn es keine ausdrücklich anderslautende Festlegung gibt. Dies bedeutet, daß die Lösungen von A* normalerweise optimal sind.

Eine Abschätzung des verbleibenden Weges betrifft alle drei Terme der Gütefunktion (4.7) und wird folgendermaßen vorgenommen:

1. Die Abschätzung des verbleibenden Weges muß eine untere Schranke für die tatsächlich entstehenden Kosten sein. Eine konservative Abschätzung ist z.B. $(S(t) - S^*)^2$ ($S(t)$ = gegenwärtiger Sollwert, S^* = endgültiger Sollwert). D.h. unabhängig von der aktuellen Tiefe

im Suchbaum liefert diese untere Abschätzung den Abstand des temporären Sollwertes vom endgültigen. Der Beweis der unteren Schranke erfolgt mit der Dreiecksungleichung.

2. Eine untere Abschätzung für die verbleibenden anzuwendenden Stellgrößen ist Null.
3. Eine untere Abschätzung für den Vertrauensindex ist Null.

Je genauer die Abschätzung des verbleibenden Restweges ist, desto effizienter arbeitet der Algorithmus, und bei einer exakten Bestimmung des Restweges würde A* den besten Weg zuerst propagieren.

Algorithmus für A*

A_stern(pfad)

- 1 Bilde eine Liste aus neuen Pfaden durch Anhängen von Teilwegen an den bisherigen Pfad
- 2 Sortiere die Liste nach der Summe der bisher aufgelaufenen Kosten und der Abschätzung einer unteren Grenze der Restkosten, und setze die Wege, die die niedrigeren Kosten verursacht haben, an die Spitze.
- 3 Für jeden neuen Pfad bestimme die Kosten zum Durchlaufen des Pfades.
 - 3a1 Falls Kosten größer als bisher günstigste Kosten für einen vollständigen Pfad:
Gehe zu 3
 - Sonst:
 - 3a2 Falls maximale Pfadlänge erreicht ist:
bisher_günstigste_Gesamtkosten := Kosten zur Durchlaufen des neuen Pfades.
Günstigster Pfad := neuer Pfad.
Gehe zu 2
 - Sonst:
 - 3a3 A_stern (neuer Pfad)

Der Unterschied zu Branch and Bound ist die Anordnung der Teilwege sortiert nach den geschätzten verbleibenden Kosten. Je genauer diese Abschätzung ist, desto weniger Knoten werden durchlaufen, da eine frühzeitige Festlegung des optimalen Pfades zu einem frühzeitigen Abbrechen beim Durchwandern suboptimaler Pfade führt.

Im folgenden wird der Rechenaufwand der Suchstrategien miteinander verglichen.

4.3.2.3 Experimenteller Vergleich der algorithmischen Optimierungsmethoden

Mit einem Systemmodell nach Kapitel 3 wird auf Datensätzen der Anlage 2 die modellprädiktive Regelung durchgeführt. Hierzu wurden 1000 Testbetriebszustände aus den Meßdaten der Anlage 2 zusammengestellt.

Tabelle 4.2 zeigt für die verschiedenen Suchstrategien die Anzahl der durchlaufenen Knoten, sowie die in Anspruch genommene Rechenzeit. Gemäß der 1000 Testbetriebszustände wurden 1000 Baumsuchen durchgeführt. Die Bäume haben einen Verzweigungsgrad von 16 (4 pro Führungsgröße) und eine Tiefe von 4, so daß ein vollständiger Baum aus 16^4 Suchpfaden besteht.

Die Gütefunktion besteht nur aus einem Term zur Bewertung der Führungsgrößen. Die Stellgrößen und der Vertrauensindex werden nicht bewertet. D.h. $k_1 = 1$, $k_2, k_3 = 0$.

Mittlere Anzahl durchlaufener Pfade		
Keine Optimierung	Branch&Bound	A*
65536	36	48
Mittlere Anzahl durchlaufener Knoten		
Keine Optimierung	Branch&Bound	A*
69888	308	137
Gesamtrechenzeit		
Keine Optimierung	Branch&Bound	A*
ca 18 000 sec	330 sec	181 sec

Tabelle 4.2: Knotendurchlaufzahl und Rechenzeit der verschiedenen Suchstrategien

Die algorithmische Optimierung beschleunigt das Suchverfahren um bis zu dem Faktor 100. Die Rechenzeit bei B&B und A* ist nicht proportional zu der Anzahl der durchlaufenen Pfade und Knoten. Dies liegt an dem Mehraufwand für die Berechnung des Abschätzung für den verbleibenden Weg und der Sortierung der temporären Sollwerte. Obwohl A* mehr Pfade durchläuft als Branch and Bound, ist A* der effizientere Suchalgorithmus zum Finden des optimalen Weges im Baum. Die Suchtiefe wird von vornerein eingedämmt durch das Favorisieren besserer Lösungen mittels Abschätzung des Restweges.

Es wird betont, daß obige optimierte Verfahren echtzeitfähig sind, d.h. ein Suchvorgang liegt im Durchschnitt bei weit unter einer Minute, und somit können die Suchverfahren mit algorithmischer Optimierung in der von der Anlage vorgegebenen Antwortzeit von einer Minute geliefert werden. Falls bis zu einem bestimmten Zeitpunkt der Suchvorgang nicht abgeschlossen wurde, steht die zur Zeit günstigste Lösung bereit.

Das Baumsuchverfahren mit algorithmischer Optimierung ist universeller einsetzbar als die Methode der dynamischen Programmierung [4][23], die auf dem Optimalitätsprinzip beruht, das besagt ‚Alle Teilwege eines optimalen Weges sind optimal.‘ Auch das Prinzip der dynamischen Programmierung arbeitet mit der Diskretisierung der Wertausprägungen von Zustandsgrößen. Angewendet auf das Anlagenmodell ist diese Zustandsgröße aber der gesamte Eingabevektor des Anlagenmodells und das Verfahren kann aufgrund der hohen Dimension des Eingabevektors hier nicht eingesetzt werden. Das in Abschnitt 4.3.1 vorgeschlagene Baumsuchverfahren arbeitet lediglich mit einer Diskretisierung der Führungsgrößen (Dimension = 2).

Um einen Indikator für die Modellgültigkeit und damit für die erzeugten Stellgrößen zu erhalten, wird ein einfacher Vertrauensindex eingeführt, der einen Datensatz der Modelleingabe auf eine Ähnlichkeit überprüft.

4.3.3 Bestimmung eines Vertrauensindex

Ein einfacher Vertrauensindex besteht z.B. aus der Abstandsbestimmung des minimalen Abstandes zwischen dem Eingabevektor und den Vektoren, die zum Training des Anlagenmodells verwendet wurden. D.h.

$$V(X) = \min_{Y \in \text{Trainingsdaten}} \|X - Y\| \quad (4.9)$$

Um die Größenordnung für den Vertrauensindex von Anlage 2 zu erhalten, wird nun der Vertrauensindex für alle Validierungsdaten aus Anlage 2 zu den Trainingsdaten gebildet.

Abbildung 4.14 zeigt das Histogramm des Vertrauensindex der Validierungsdaten zu den Trainingsdaten. Der durchschnittliche Vertrauensindex liegt bei 0.77.

Der Vertrauensindex gibt lediglich Information über die Ähnlichkeit neuer Daten zu den Trainingsdaten des Modells. Hiermit wird keine Abschätzung des Modellfehlers gemacht.

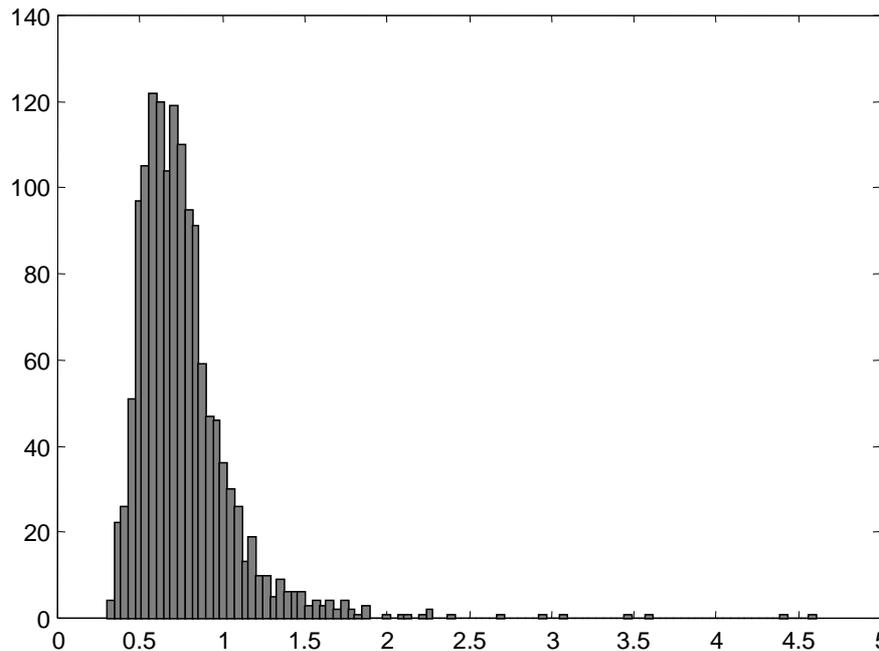


Abbildung 4.14: Verteilung der Minimalabstände der Validierungsdaten zu den Trainingsdaten

Im folgenden Abschnitt wird die modellbasierte Regelung auf den Müllverbrennungsprozeß von Anlage 2 angewandt.

4.4 Experimentelle Ergebnisse

Die Regelung wird nun auf den offenen Regelkreis und den geschlossenen Regelkreis unter Vorgabe der Validierungsdaten angewendet.

4.4.1 Ergebnisse im open-loop Betrieb

Folgende Abbildungen zeigen die modellprädiktive Regelung angewendet auf die Validierungsdaten im Open Loop Betrieb, d.h. es findet kein Eingriff in den Prozeß statt, und somit kommt auch keine Rückkopplung über die erzeugten Stellgrößen. Um den Effekt der errechneten Stellgrößen zu beschreiben, wurden die Stellgrößen einer Simulation im Serien-Parallelmodell zugeführt.

Abbildung 4.15 zeigt in der rechten Bildhälfte das simulierte Verhalten der Führungsgrößen unter den darunter abgebildeten Stellgrößen. Die Gütefunktion bewertet nur das Verhalten der Führungsgrößen. Größe der Stellgrößen und der Vertrauensindex wurden nicht bewertet. Der Vertrauensindex wurde für die Simulation aufgezeichnet. Zu zwei Zeitpunkten ist der Vertrauensindex betragsmäßig groß, und zu diesen Zeitpunkten weichen die Führungsgrößen stark vom Sollwert ab.

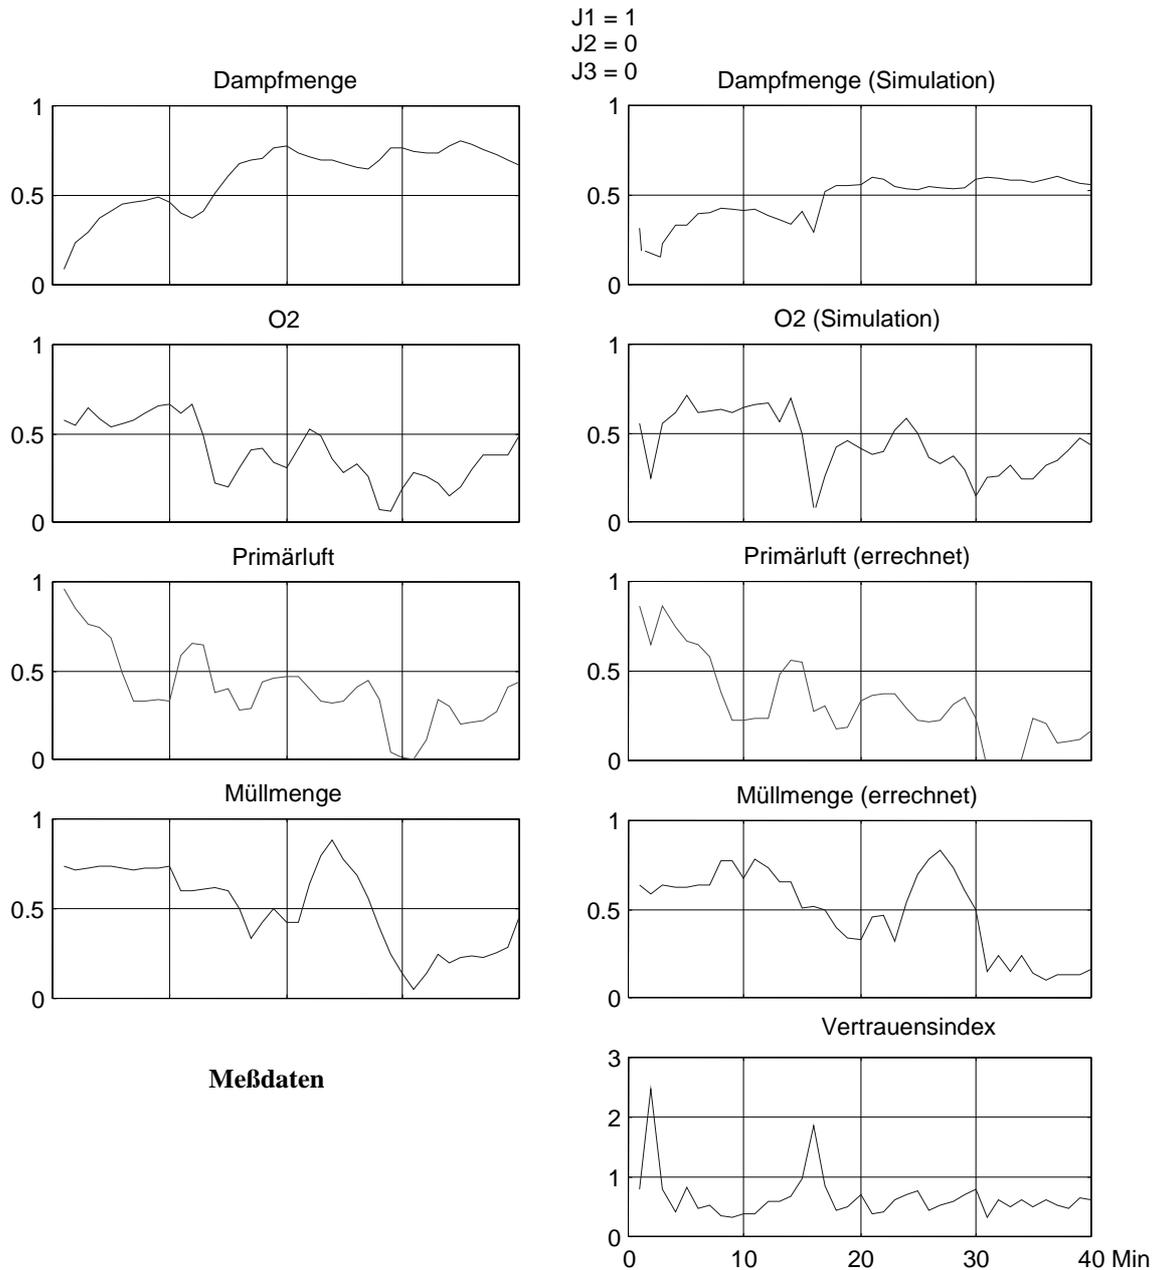


Abbildung 4.15: Meßdaten (links) und Simulation der Prozeßgrößen (rechts) im open-loop Betrieb

Da nur jeweils der erste Schritt der Handlungssequenz ausgeführt wurde, sind aufgrund der fehlenden Rückkopplung keine weiteren Aussagen zum Verhalten des geschlossenen Regelkreises möglich.

4.4.2 Ergebnisse im closed loop Betrieb

Um die Regelung im geschlossenen Regelkreis zu erproben, wird der Prozeß durch ein KNN simuliert. Im realen Anlagenbetrieb wurde die Regelung noch nicht erprobt, da der Schreibzugriff auf die Anlage zum gegenwärtigen Zeitpunkt noch nicht implementiert ist.

Abbildung 4.16 zeigt die Führungsgrößen und Stellgrößen des realen Prozesses, die dem geschlossenen Regelkreis unter Einsatz eines Prozeßsimulators mit der modellbasierten Regelung bei unterschiedlichen Gütekriterien gegenübergestellt sind (Abbildungen 4.17 –4.19).

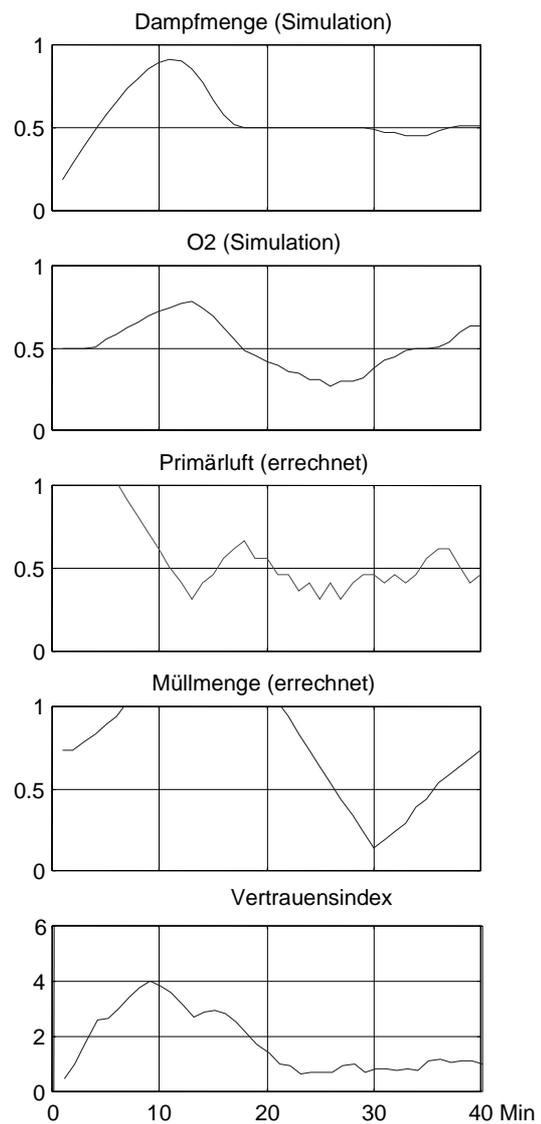
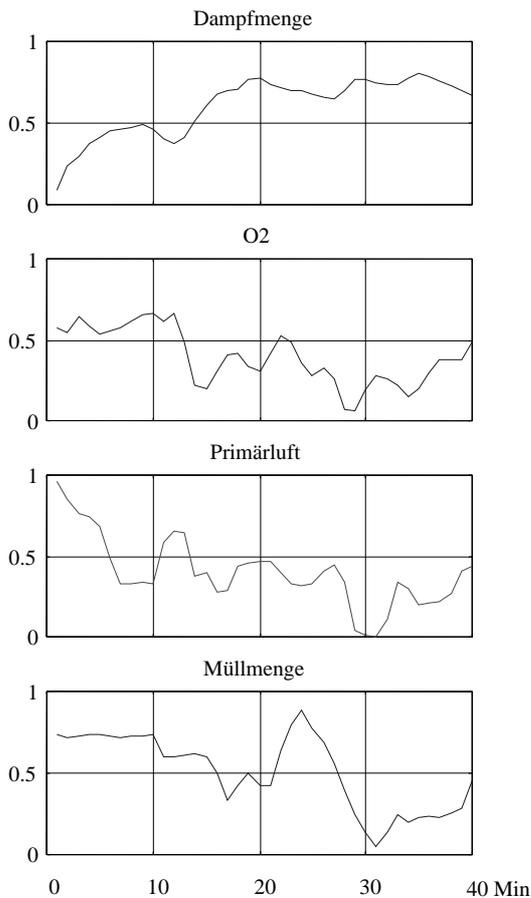


Abbildung 4.16: Führungsgrößen und Stellgrößen des realen Prozeßverlaufs.

Abbildung 4.17: Closed Loop Simulation mit den Koeffizienten $(j_1, j_2, j_3) = (1, 0, 0)$

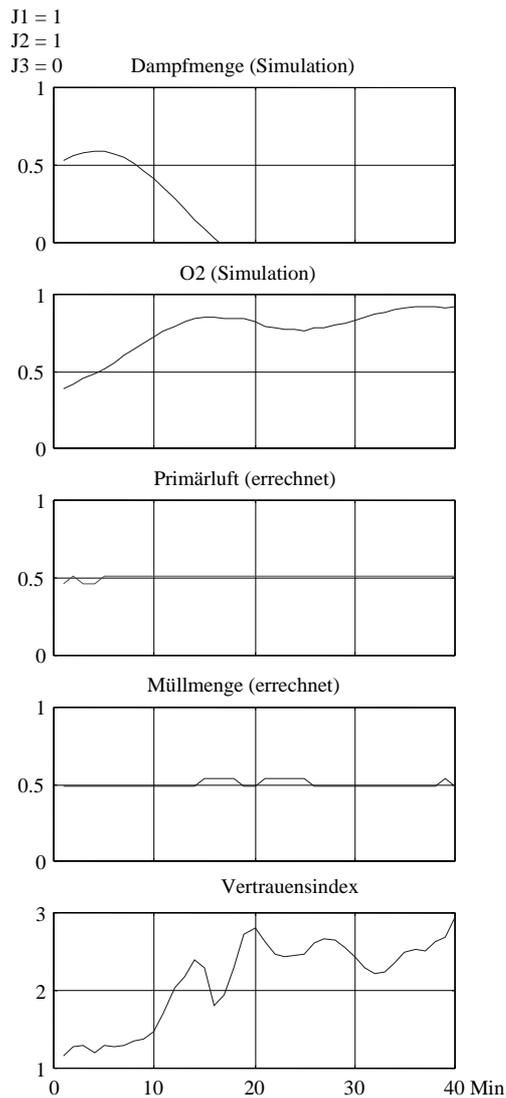


Abbildung 4.18: Closed Loop Simulation mit den Koeffizienten $(j_1, j_2, j_3) = (1, 1, 0)$

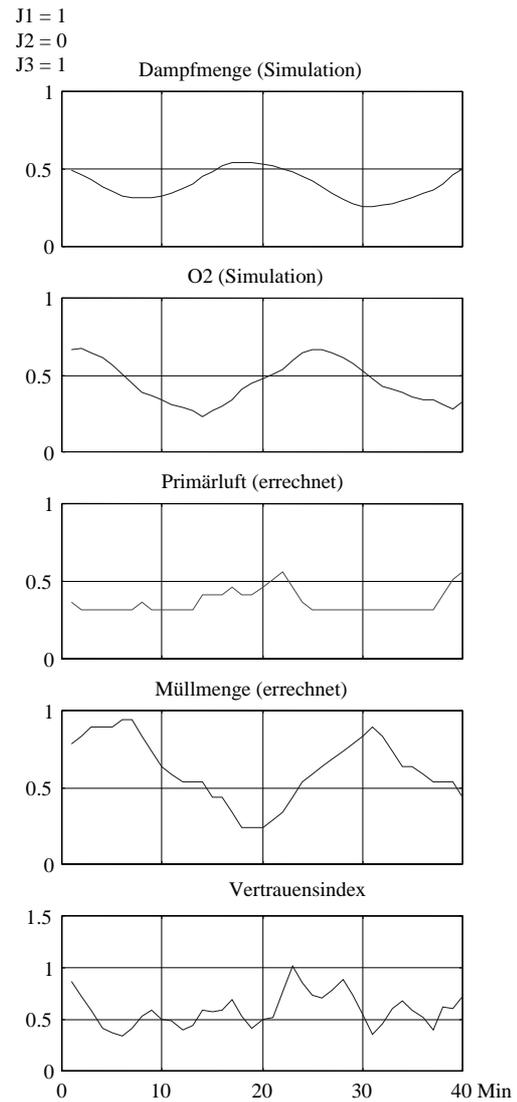


Abbildung 4.19: Closed Loop Simulation mit den Koeffizienten $(j_1, j_2, j_3) = (1, 1, 1)$

In Abbildung 4.17 werden gleich zu Anfang zu hohe Stellgrößen abgegeben. Der Arbeitspunkt bewegt sich schnell vom trainierten Arbeitspunkt weg, was durch den aufgezeichneten Vertrauensindex ersichtlich ist. Nach 20 Minuten bewegt sich der geschlossene Regelkreis wieder in den Bereich der trainierten Daten. Die Stellgrößen werden geringer, und die Führungsgrößen nähern sich den Sollwerten signifikant.

Abbildung 4.18 zeigt den geschlossenen Regelkreis bei einer Gütefunktion, die neben den Führungsgrößen auch die Größe der Stellgrößen bewertet. Dadurch fallen die Stellgrößen betragsmäßig klein aus, aber die Sollwerte werden nicht erreicht.

Wird in der Gütefunktion auch der Vertrauensindex bewertet (Abbildung 4.19), so zeigen die Führungsgrößen ein leichtes Schwingverhalten um die Sollwerte. Der Arbeitspunkt liegt nahe bei dem Arbeitspunkt der trainierten Daten. Die Stellgrößen erreichen nie maximale Werte.

4.5 Rechentechnische Realisierung

Zur Regelung der Anlage 1 und der Anlage 2 ist jeweils ein eigenes Regelungssystem auf Basis der hier vorgestellten Algorithmen entwickelt worden. Beide Systeme werden nun kurz beschrieben.

4.5.1 System zur Prozeßführung der Anlage 1

Im Rahmen des EU Projekts CLEAN [72] wurde die im Rahmen dieser Arbeit entwickelten Algorithmen in ein Client-Server basiertes System eingebettet. Die einzelnen Komponenten sind:

- **Grafische Benutzeroberfläche:**
Die grafische Benutzeroberfläche zur Simulation und Regelung wurde so ausgelegt, daß sie einem Anlagenbediener die von ihm benötigte Information zum Prozeß übersichtlich darstellt. In dieser ersten Implementierung ist der Bediener Teil der Regelung, indem er Vorschläge der Regelung an das Prozeßleitsystem manuell weitergibt. So durchgeführt, bietet das System die Eigenschaft eines (manuellen) geschlossenen Regelkreislaufs.
- **Simulator/Regler**
Diese Komponente wurde bereits ausführlich beschrieben. In einem Zeitschritt werden die neuen Prozeßwerte angefordert und ausgehend von den mitgelieferten Sollwerten neue Stellgrößen berechnet.
- **Prozeßankopplung**
Auf der Seite des Prozeßleitsystems bietet die Softwareschnittstelle EXCOM die Möglichkeit, Daten über eine serielle Schnittstelle auszutauschen. Auf der anderen Seite der seriellen Schnittstelle werden die empfangenen Daten nach Bedarf abgerufen.

Diese Komponenten können auf verschiedenen Rechnern laufen, da der Datenaustausch über das TCP/IP Protokoll realisiert wird. Das User Interface ist hierbei der Client, die anderen Komponenten sind als Server konfiguriert. Somit übernimmt das User Interface die Kontrolle über den Datenfluß. Zyklisch werden erst Daten von der Prozeßankopplung eingelesen. Je nach Betriebsart des User Interface werden die Meßdaten angezeigt, und sie werden an das Simulator/Regler Modul transferiert. Dieses liefert Stellgrößen zurück, die als Vorschlag auf dem User Interface dargestellt werden.

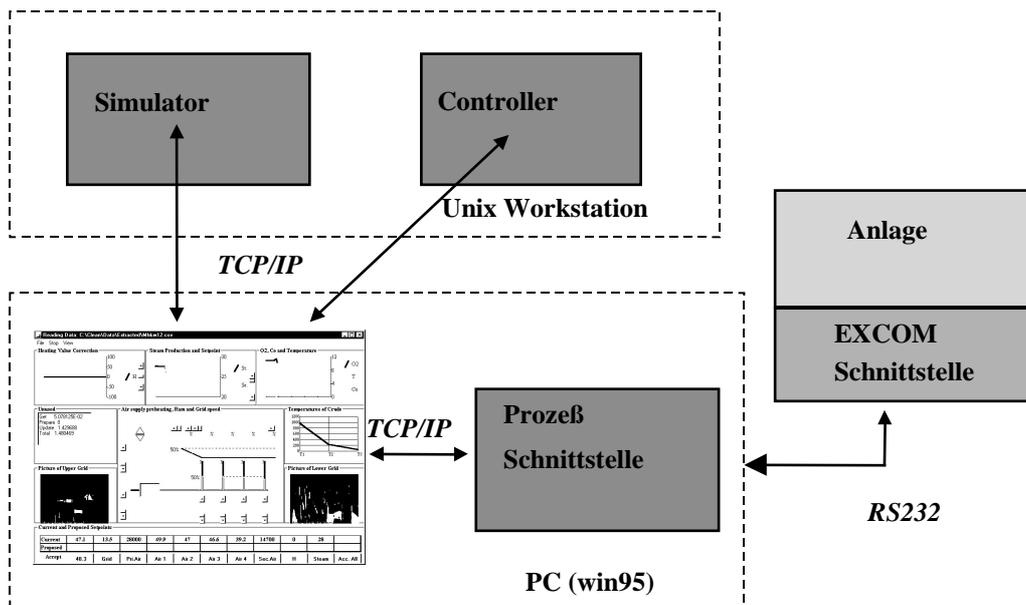


Abbildung 4.20: Zusammenspiel der einzelnen Komponenten

Die Implementierung des Systems liefert Vorschläge für zu ändernde Stellgrößen und der Bediener kann diesen Vorschlägen folgen und die Größen manuell ändern. Das Problem beim Einsatz KNNs ist die fehlende Erklärungsfähigkeit seiner Ausgaben. Daher muß die grafische Darstellung in der Lage sein, dem Operator die notwendige Information geben, um die Vorschläge hinsichtlich ihrer Plausibilität verifizieren zu können (Trend, Abweichung vom Sollwert usw.). Somit bewirkt das Display eine Steigerung der Akzeptanz von Seiten des Benutzers. Abbildung 4.21 zeigt das Interface.

Prozeßparameter werden grafisch dargestellt, und Werte können manuell an den Ausgabeelementen mit Hilfe von Schieberegler modifiziert werden.

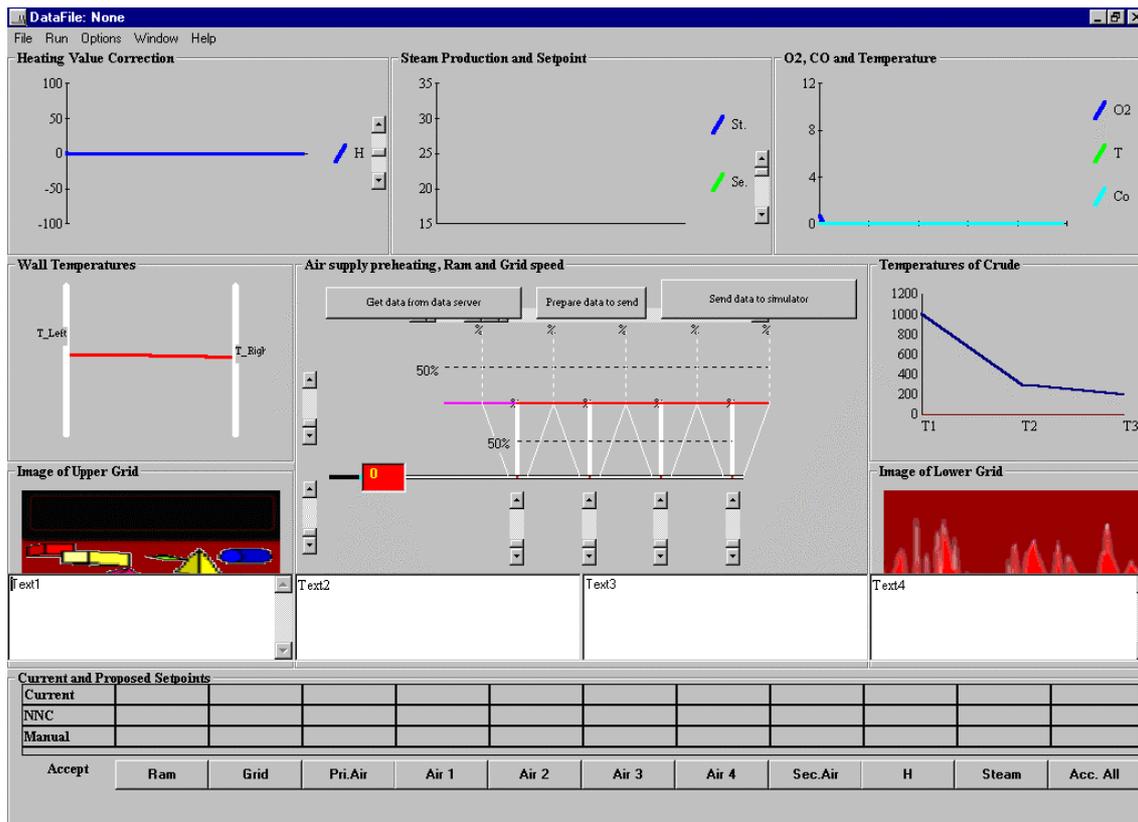


Abbildung 4.21: Benutzerschnittstelle zu Simulation und Regelung [50]

4.5.2 System zur Prozeßführung der Anlage 2 (INSPECT)

In der Gruppe MICS (Machine Intelligence for Complex Systems) wurde das Werkzeug INSPECT entwickelt, das es erlaubt, verschiedene Aufgaben wie Bilderfassung, Bildverarbeitung, Fuzzy- oder Neuromodule, Prozeßankopplungen und Benutzerinteraktion in ein Gesamtsystem zu integrieren. Erfahrungen anderer Projekte zeigten, daß wechselnde Anforderungen der Anwender am einfachsten zu bedienen sind, wenn ein überschaubarer Systemkern, der die Rapid Prototyping-Technik unterstützt, und einzelne autark arbeitende Komponenten zu Grunde gelegt werden. Die einzelnen Komponenten sollten dabei effizient, überschaubar und flexibel handhabbar sein. Daher wird dem Systemkern ein Skript-basierter Ansatz zugrunde gelegt. Komponenten (Module) kommunizieren über eine definierte Kommunikationsschnittstelle mit dem Systemkern. Somit ist es sehr rasch möglich, auf unterschiedliche Anforderungen aus verwandten technischen Gebieten zu reagieren, denn der Anwender kann aus einer Liste von Bausteinen sein individuelles System zusammensetzen. Aus der strengen Modularisierung resultiert eine vereinfachte Pflege und Fortschreibung des Systems.

Auf eine direkte Schnittstelle zwischen den einzelnen Komponenten wurde zugunsten eines Variablenpools verzichtet. Abbildung 4.22 zeigt den schematischen Aufbau des Systems.

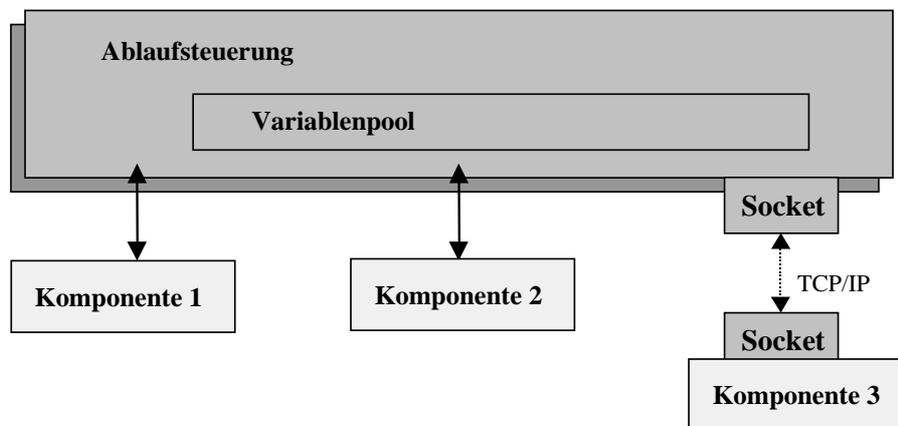


Abbildung 4.22: Schematischer Aufbau des INSPECT Systems

4.5.2.1 Ablaufsteuerung

Die Ablaufsteuerung bildet den Kern des Systems. Um die Ablaufsteuerung rasch entwickeln und auch vor Ort ohne eine vorhandene Entwicklungsumgebung Anpassungen vornehmen zu können, wurde ein Skript-basierter Ansatz gewählt. Die Ablaufsteuerung wurde in der Interpretersprache PERL implementiert. Aufgabe der Ablaufsteuerung ist die Koordinierung der einzelnen Komponenten bei der Initialisierung, beim normalen Betrieb und in kritischen Zuständen, wenn einzelne Komponenten durch Störungen ausfallen oder gewartet werden müssen. Hierbei wurde auf aufwendig zu entwickelnde und aufwendig zu wartende asynchrone Techniken zugunsten einer zyklisch ablaufenden Prozeßkontrolle verzichtet. Stattdessen besitzen die Standardkomponenten gleiche Priorität und werden in vorgegebenen regelmäßigen Abständen zyklisch aufgerufen. Der neue Zustand der jeweils aufgerufenen Komponenten kann im Variablenpool abgelegt und durch andere Komponenten erfragt werden.

4.5.2.2 Komponenten

Im INSPECT-System arbeiten die Komponenten autark, und eine Kommunikation zwischen Komponenten findet ausschließlich über die Ablaufsteuerung statt. Jede Komponente besitzt nur eine viergeteilte Schnittstelle zur Ablaufsteuerung und zum Auslesen und Modifizieren der Variablen im zentralen Variablenpool. Drei Schnittstellenfunktionen dienen dabei zum Initiali-

sieren, zum Abmelden und zum regelmäßigen Aktivieren der Komponente. Eine Komponente kann sowohl eng gekoppelt als auch über Netz lose an die INSPECT-Ablaufsteuerung gekoppelt sein. Eine eng gekoppelte Komponente ist direkt über eine Funktionsschnittstelle eingebettet. Eine über Netz angekoppelte Komponente besitzt über die drei Schnittstellenfunktionen hinaus ein definiertes Standard-Protokoll über TCP/IP, mit dessen Hilfe es möglich ist, einen Netzwerk-Client an das INSPECT-System anzukoppeln und verteilt zu arbeiten (Abbildung 4.23). Durch die Unterstützung dieses Client/Server-Prinzips können die Ressourcen auf der Seite der Ablaufsteuerung geschont werden, was vor allem bei zeitkritischen Aktivitäten von Bedeutung sein kann.

Komponenten, die direkt an die Ablaufsteuerung gekoppelt sind, können in jeder beliebigen Programmiersprache entwickelt worden sein, sofern die Bibliotheken der Komponenten über den XS oder SWIG an PERL Skripte anbindbar sind [11]. XS und SWIG stellen hierbei Mechanismen dar, die Bibliotheken anderer Programmiersprachen an Perl Funktionen anbinden. Bei einer Kopplung über TCP/IP sind keine Anforderungen an die Interoperabilität mit PERL gegeben.

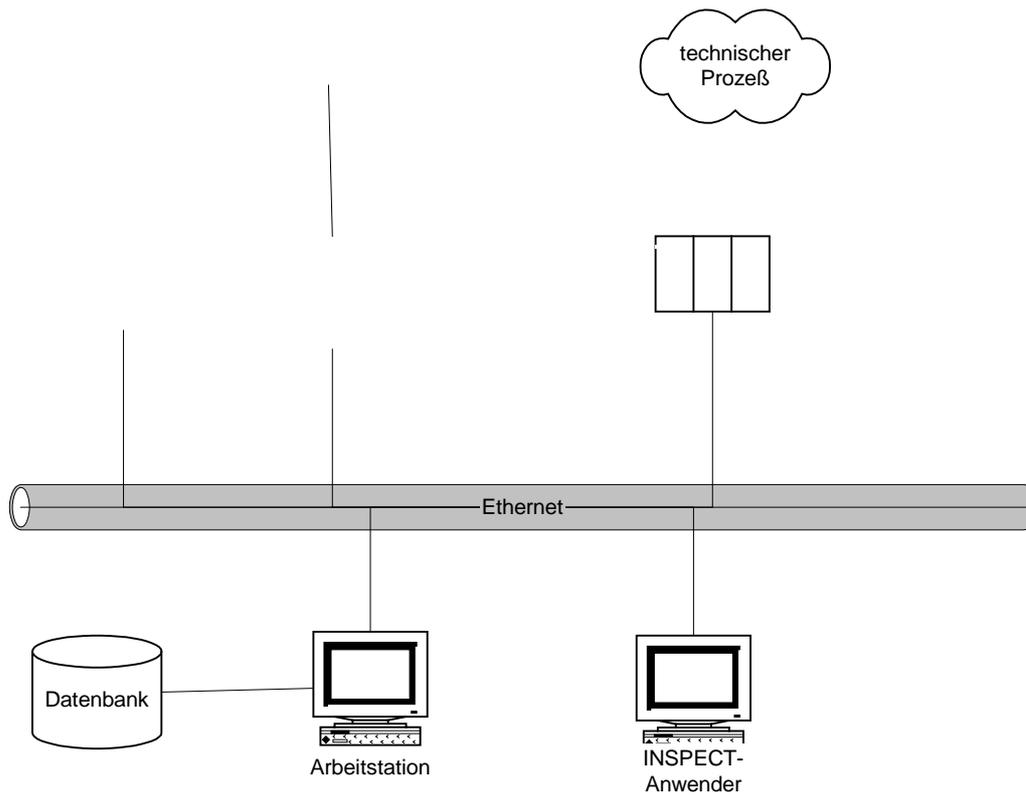
Folgende Komponenten wurden im Rahmen dieser Arbeit für das INSPECT-System entwickelt:

- Video-Bilderfassung (C)
- IR-Bilderfassung (C)
- Benutzer-Interface/Visualisierung (Kopplung über TCP/IP, Java)
- Bildverarbeitung (C, aus Matlab Code generiert)
- KNN-basierter Regler (C, aus Matlab Code generiert)

Weitere Komponenten für das INSPECT-System sind:

- Fuzzy-Regler
- Objekterkennung
- Meßwerterfassung
- Meßwert-Archivierung
- Bilddaten-Archivierung
- Standard-Netzwerks-Clientanwendung

Die Erweiterung des Systems um neue Komponenten ist möglich, sofern deren Aufgabe eine zyklische Bearbeitung im Online-Betrieb am technischen Prozeß ist.



Durch eine Erweiterung der Gütefunktion um nichtkonstante Koeffizienten können sehr leicht Constraints (z.B. verbotene Betriebszustände) realisiert werden.

Kernstück der modellbasierten Regelung ist ein nach der Methodik von Kapitel 3 erzeugtes KNN-basiertes Modell. Dieses Modell stellt eine bessere Approximation des realen Prozesses dar, als ein lineares Modell. Allerdings wurden durch den Einsatz eines nichtlinearen Modells folgende Nachteile in Kauf genommen:

- Das Erzeugen des neuronalen Modells kann nur heuristisch geschehen, bzw. durch Gradientenabstiegsverfahren, wobei die Konvergenz von der Datenrepräsentation, dem Lernverfahren und dessen Parameter abhängt.
- Für eine modellbasierte Regelung mit einem nichtlinearen Black-Box-Modell gibt es zur Zeit keine Kriterien, um die Stabilität des geschlossenen Regelkreises zu beweisen. Unter der Voraussetzung der Validität des Modells ist das Verfahren robust, da durch die Mehrschrittprädiktionen eine Abschätzung auf die Folgezustände des Prozesses gemacht und diese bewertet werden.

Eine Untersuchung zur Stabilitätsbetrachtung der hier vorgestellten Regelung wird in dieser Arbeit nicht durchgeführt. Hier sei auf Arbeiten zur Stabilitätskriterien nichtlinearer System in der Literatur verwiesen [33][64][8][18].

Der Prädiktionshorizont der Simulation wird beschränkt durch die Modellgenauigkeit und durch das Einfließen von Störgrößen. Diese bestehen zum großen Teil in Form von schwankenden Brenneigenschaften des eingehenden heterogenen Mülls.

Im folgenden Kapitel wird beschrieben, wie aus Infrarotaufnahmen vom Verbrennungsrost Merkmale zur Ermittlung der schwankenden Verbrennungseigenschaften des in den Prozeß eingehenden heterogenen Mülls ermittelt werden.

5 Gewinnung von Prozeßgrößen mit Infrarot-Thermographie zur Unterstützung der Prozeßführung

Wichtige in den Verbrennungsprozeß eingehende Störgrößen sind die Heterogenität des Mülls und somit die schwankenden Verbrennungseigenschaften des Mülls. Mit der in den Anlagen üblichen Sensorik können die Verbrennungseigenschaften des Mülls nicht ermittelt werden.

Durch Aufzeichnen des Verbrennungsprozesses auf dem Verbrennungsrost mit Infrarot-Thermographie wird Information über die räumliche Temperaturverteilung auf dem Rost gewonnen. In diesem Kapitel wird ein Verfahren vorgestellt, mit dem qualitative Aussagen über die Verbrennungseigenschaften von Müll aus thermographischen Aufnahmen abgeleitet werden, die dann zur Verbesserung der Prozeßführung eingesetzt werden können.

Zuerst wird eine Motivation zur Ermittlung der Verbrennungseigenschaften des Mülls gegeben. In Abschnitt 5.2 wird auf physikalische Grundlagen der Entstehung und auf die Messung der Infrarotstrahlung eingegangen. In Abschnitt 5.3 wird die Methodik vorgestellt, mit der aus den Infrarotbildern Merkmale gewonnen werden, welche in Abschnitt 5.4 mit überwachtem Lernen den Verbrennungseigenschaften zugewiesen werden.

5.1 Motivation

In den vorgestellten Anlagen wird der Müllheizwert vom Anlagenpersonal geschätzt. Die Information des Heizwerts wird zur Bestimmung des Arbeitspunkts für die Regelung des Verbrennungsprozesses verwendet. Die Schätzung basiert hauptsächlich auf visuellen Eindrücken.

In manchen modernen Anlagen wird die Verbrennungszone durch Pyrodetektoren, Videokameras und -seltener- Infrarotkameras ermittelt. Die entsprechenden Sensoren liefern die Lage der Hauptverbrennungszone an das Prozeßleitsystem, um die Luftverteilung auf dem Rost zu regeln.

Es gibt mehrere Ansätze, Infrarotkameras für verbesserte Prozeßführung zu nutzen. In [13] und [41] wird die Temperaturverteilung auf dem Rost für eine Feuerlageregelung gemessen. Weitere Eigenschaften werden aus den Infrarotmessungen nicht abgeleitet. In [62] wird eine Infrarotspektroskopie eingesetzt, um die Feuchtigkeit des Mülls zu messen.

Durch eine frühzeitige Ermittlung der Verbrennungseigenschaften (Heizwert, Feuchte, Brennbarkeit) kann eine vorausschauende Fahrweise im Sinne einer exakteren Dosierung des Mülls

und gegebenenfalls eine Änderung des Arbeitspunkts erzielt werden. Dies ist besonders wichtig bei einer Änderung der Zusammensetzung des eingehenden Mülls.

In Abschnitt 2.3 wurde die Regelungsstrategie der Anlage 2 vorgestellt. Die dort beschriebene Regelung ist nur sinnvoll, wenn sich der Prozeß um einen "normalen" Arbeitspunkt bewegt. Durch Änderung der bestehenden Müllfraktion kann dieser Arbeitspunkt jedoch verlassen werden, und die Eingriffe des Prozeßleitsystems können einen nicht erwünschten Effekt bewirken. Als Beispiel sei folgende Situation geschildert:

Normaler Hausmüll befindet sich auf dem Rost, und der Prozeß wird nach den in Kapitel 2 beschriebenen Methoden geregelt. Nun erhöhen sich Heizwert sowie die Feuchte des Mülls. Eine längere Trocknungsphase führt zu einer Verminderung der Verbrennung und somit zu einer Verringerung der Dampfmengenproduktion bei gleichzeitiger Zunahme des O₂-Gehalts im Rauchgas. Dann wird die Müllaufgabe erhöht. Dies ist jedoch in dieser Situation falsch, da eine Erhöhung der Müllaufgabe zu einer Überschüttung des Rostes und somit zu einem zu hohen Massenumsatz führt. Bei verspäteter Zündung ist dann zuviel Müll auf dem Rost, und die Verbrennung findet in einem stark überhöhten Maße statt. Die Temperatur steigt signifikant an, und die Dampfmengenproduktion überschreitet den Sollwert. Dann wird die Regelung dem entgegenwirken und die Luftmenge sowie die Müllaufgabe reduzieren.

Aus dieser Fahrweise resultieren Temperaturspitzen, die zu thermischer NO_x-Bildung führen können, sowie Temperaturschwankungen, die sich negativ auf die Lebensdauer der Anlage (Rost, Wände) auswirken.

Im Folgenden sind Mehrdeutigkeiten im Prozeß aufgeführt, die ihre Ursachen in der unbekanntem Müllzusammensetzung haben.

- Müll hat zuwenig Heizwert, um den Sollwert zu erreichen. In diesem Fall wird dem Müll zuviel Primärluft zugegeben, und die Verbrennung wird ausgeblasen.
- Müll ist trocken, hat aber geringen Heizwert. Entzündet er sich schnell, so verlagert sich das Brennbett in Richtung Aufgaberost. Die Regelung wird die Aufgabegeschwindigkeit herabsenken. Da der Heizwert gering ist, wird der Müll schnell ausgebrannt sein, und das Brennbett verkürzt sich. Nun kommt nicht genug Müll nach, und die Dampfmenge sinkt rapide.

Generell kommt es zu Fehlreaktionen, wenn die Entzündbarkeit (z.B. durch Feuchte) sich gegensätzlich zum erwarteten Heizwert verhält, d.h. wenn der Müll anfänglich schlecht entzündbar ist, wird von der Regelung hierdurch auf einen geringen Heizwert geschlossen und umgekehrt.

Daher ist es erstrebenswert, automatisch den Sollwert zu ändern, sobald sich die Verbrennungseigenschaften des eingehenden Mülls ändern. Ein weiteres Ziel dieser Arbeit ist daher die Ableitung eines Verfahrens zur frühzeitigen Ermittlung der Änderungen der Müll-Verbrennungseigenschaften anhand der gemessenen thermischen Emissionen.

Der Heizwert läßt sich anhand der während der Verbrennung freigesetzten Energie bestimmen, welche zum Großteil aus thermischen Emissionen besteht. Abbildung 5.1 zeigt eine schematische Darstellung der Emissionsprofile verschiedener Abfallarten zu Beginn der Verbrennung.

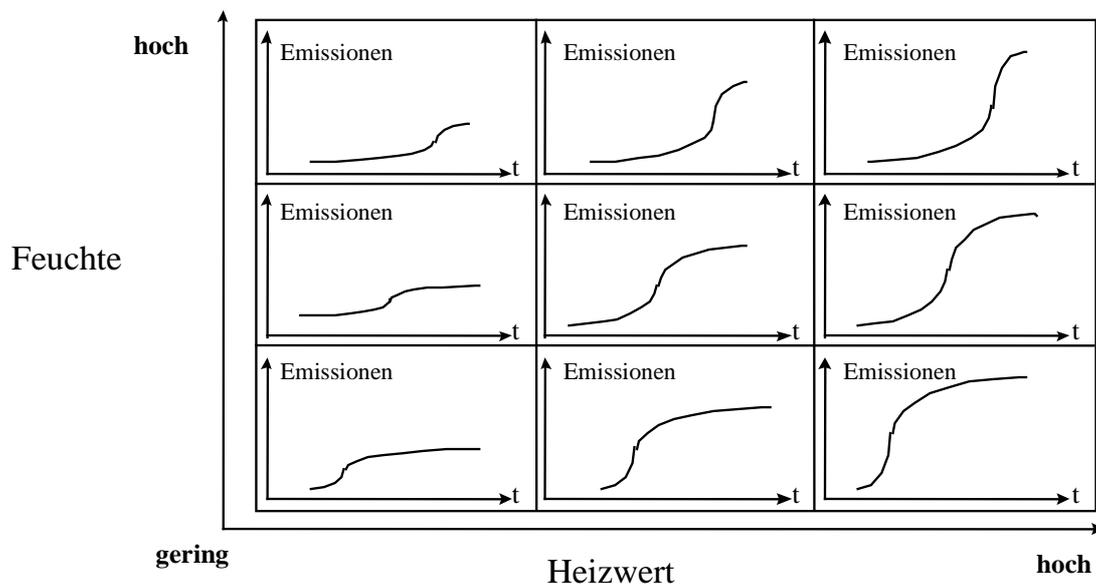


Abbildung 5.1: Emissionsprofile von Müll für verschiedene Arten von Abfällen. Jedes Unterdiagramm zeigt thermische Emissionen in Abhängigkeit der Zeit.

Folgende Brenneigenschaften des Mülls haben Einfluß auf den Verlauf der Verbrennung und können qualitativ mit einer Infrarotkamera ermittelt werden:

- Die Feuchtigkeit des Mülls hat Einfluß auf den Entzündungszeitpunkt. Eine verzögerte Entzündung ist auf eine längere Trocknungszone und damit auf feuchteren Müll zurückzuführen.
- Der Heizwert von Abfällen kann auf der Grundlage der freigesetzten Energie, die während der Zeit, die sich der Müll auf dem Rost befindet, abgeschätzt werden.

Zur Ermittlung der Emissionsprofile wird in Anlage 2 eine Infrarotkamera eingesetzt, die die Hauptverbrennungszone überwacht. Im folgenden Abschnitt wird auf die charakteristischen Eigenschaften der thermischen Emissionen eingegangen und die Eigenschaften der hier verwendeten Meßtechnik beschrieben.

5.2 Wärmestrahlung und Infrarotmessung

Die auf dem Rost freigesetzte Energie wird hauptsächlich in Form von thermischer Emission abgegeben. Mit Infrarotmeßtechnik ist es möglich, einen Teil dieser Emission zu messen.

5.2.1 Eigenschaften der Wärmestrahlung

Alle Objekte oberhalb des absoluten Nullpunktes emittieren Energie in Form von elektromagnetischer Strahlung. Diese Strahlung kann wiederum von anderen Objekten zu einem bestimmten Teil absorbiert werden. Kirchhoff demonstrierte 1860, daß ein gut absorbierender Körper auch ein guter Strahler ist und somit ein perfekt absorbierender Körper ein perfekter Strahler. Ein Körper, der alle Strahlung, die in ihm auftritt, absorbiert, wird als schwarzer Strahler bezeichnet. Nun wird der physikalische Zusammenhang zwischen Temperatur und Emissionen beschrieben.

5.2.1.1 Strahlung eines schwarzen Körpers

Die Emission der Strahlung eines schwarzen Körpers wird durch das Plancksche Gesetz beschrieben. In Abhängigkeit von der Temperatur T und der spezifischen Wellenlänge λ emittiert ein schwarzer Körper die spektrale spezifische Ausstrahlung [25]

$$\frac{dR(\lambda, T)}{d\lambda} = \frac{2\pi hc^2 \lambda^{-5}}{e^{\left(\frac{hc}{\lambda T}\right)} - 1} \quad (5.1)$$

(Plancksches Gesetz)

mit den Konstanten

$$c = 289 \cdot 10^6 \text{ m/sec (Lichtgeschwindigkeit)}$$

$$h = 6.6256 \cdot 10^{-34} \text{ Js (oder Ws}^2\text{) (Planck Konstante)}$$

$$k = 1.38054 \cdot 10^{-23} \text{ JK}^{-1} \text{ (Boltzmann Konstante).}$$

λ wird angegeben in μm , und die absolute Temperatur T in Kelvin.

Die spektrale Ausstrahlung in Abhängigkeit von λ bei konstanter Temperatur enthält ein Maximum. Dieses Maximum kann in Abhängigkeit von der Temperatur angegeben werden durch $\lambda_{\max} = 2898/T$ (μm) über Differentiation des Planckschen Gesetzes.

Die folgende Abbildung zeigt spektrale Ausstrahlungen eines schwarzen Körpers bei unterschiedlichen Temperaturen.

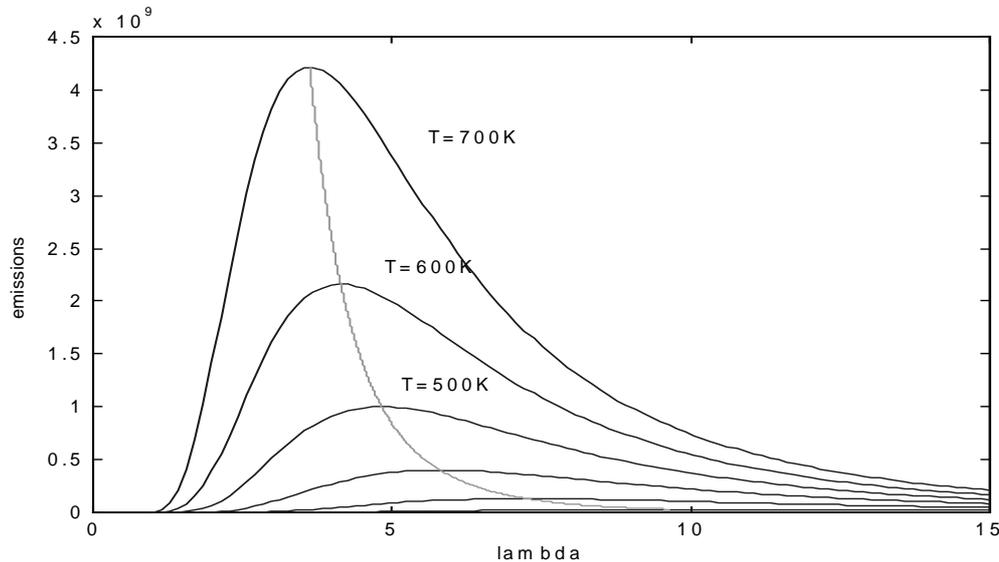


Abbildung 5.2: Emissionskurven eines schwarzen Körpers bei verschiedenen Temperaturen. Die gestrichelte Linie zeigt die Maxima der Emissionen in Abhängigkeit der Temperatur.

Hiernach hat ein Objekt bei einer Temperatur von 700 K ein Maximum bei einer Wellenlänge $\lambda = 3.5 \mu\text{m}$, während die Sonne bei einer Temperatur von 6000K maximale Emissionen bei einer Wellenlänge von $0.5 \mu\text{m}$ erzeugt. Dies ist gerade das maximale Erregungszentrums des menschlichen Auges [25].

5.2.1.2 Abhängigkeit zwischen Temperatur und Emission

Die Integration der Emission über das gesamte Frequenzband liefert den folgenden Zusammenhang zwischen Emission und Temperatur:

$$f(\lambda, T) = \frac{dR(\lambda, T)}{d\lambda} \quad (5.2)$$

$$\int_0^{\infty} f(\lambda, T) d\lambda = \sigma T^4 \quad (5.3)$$

(Stefan-Boltzmann Gesetz)

mit

$$\sigma = 2 \pi^5 k^4 / (15 c^2 h^3) = 5.67 * 10^{-8} \text{ Wm}^2\text{K}^{-4} \quad (\text{Stefan Konstante}) \quad (5.4)$$

Der Zusammenhang zwischen Temperatur und Emission ist für die Temperaturermittlung durch eine Messung mit einer Infrarotkamera erforderlich. Reale Objekte sind keine schwarzen Körper, und die obigen Gesetze gelten für sie nur mit Einschränkungen.

5.2.1.3 Andere Strahlertypen

Nicht-schwarze Körper absorbieren nur einen Bruchteil A der auf sie auftreffenden Strahlung. Sie reflektieren einen Teil R (Reflektion) und lassen einen Teil T (Transmission) durch. Diese verschiedenen Faktoren sind außerdem von der Wellenlänge abhängig [21][26].

Die Emissivität ε ist gleich der Absorption, d.h. $\varepsilon(\lambda)=A(\lambda)$.

Es gilt
$$A(\lambda) + R(\lambda) + T(\lambda) = 1. \quad (5.5)$$

Folgende Spezialfälle illustrieren die Eigenschaften verschiedener Körper:

- Schwarzer Körper: $\varepsilon(\lambda) = \varepsilon = 1, R, T=0$.
- Undurchsichtiger Körper: $T(\lambda)=0, \varepsilon(\lambda) + R(\lambda)=1$.
- Perfekter Spiegel: $R(\lambda)=1, T, \varepsilon=0$.
- Grauer Körper: $\varepsilon(\lambda) = \text{const. } R(\lambda) = \text{const.}$

Die spektrale Ausstrahlung für einen allgemeinen Körper kann in Form des Planckschen Gesetzes folgendermaßen ausgedrückt werden:

$$\frac{dR(\lambda, T)}{d\lambda} = \varepsilon(\lambda) \frac{dR_{bb}(\lambda, T)}{d\lambda} \quad (5.6)$$

mit R_{bb} = Strahlung des schwarzen Körpers.

5.2.1.4 Probleme der Emissivität

Die Energie, die mit einem Infrarotdetektor (z.B. eine Kamera) gemessen werden kann, ist eine a priori unbekannte Funktion der Emissivität und der Temperatur strahlender Elemente. Angenommen, von einem unbekanntem Körper sei die Menge der Emissionen gegeben, und seine

Temperatur soll berechnet werden. Bei der Annahme eines schwarzen Körpers gilt $\varepsilon(\lambda) = \varepsilon = 1$ und $T = \sqrt[4]{\int R(\lambda, T) dt}$. Handelt es sich um einen grauen Körper mit $\varepsilon(\lambda) = \varepsilon = 0.5$, so ergibt

sich die Temperatur zu $T = \sqrt[4]{0.5 \int R(\lambda, T) dt}$

Die Emissivität ist bei Hausmüll nicht a priori bekannt. Es wird daher von einer Mischung ausgegangen, deren Emissivität bei 0.8 liegt. Diese Abschätzung hat zur Folge, daß die Temperatur nicht genau gemessen werden kann. Daher sind die Emissionsmessungen rein qualitativer Natur. In [78] und [77] wird mit mehreren Pyrodetektoren, die bei verschiedenen Wellenlängen sensitiv sind, die Emissivität des gemessenen Körpers errechnet. Eine Infrarotkamera ist hierzu nicht in der Lage; es werden alle Emissionen über ein festes Frequenzband integriert.

5.2.2 Aufzeichnen der Verbrennung mit Infrarot-Thermographie

Für die an der Anlage 2 durchgeführten Messungen wird eine Infrarotkamera vom Typ AVIO TVS 100 eingesetzt. Sie besteht aus einem Infrarot Sensor Array mit 320*200 Elementen. Dieses Array wird angesprochen wie das CCD Array einer Videokamera, allerdings in einem anderen Wellenlängenbereich. Die Emission eines aufzuzeichnenden Objekts durchläuft mehrere nichtlineare Absorptionsspektren (Absorptionsspektrum der Atmosphäre, Absorptionsspektren der Filter und der Optik) und erregt dann einzelne Zellen des Arrays innerhalb des Spektralbandes von 3-5µm. Aus den Erregungen werden anschließend unter Vorgabe eines festen Emissionskoeffizienten ε die übermittelten Temperaturen aus einer Tabelle ausgelesen.

In das Objektiv ist ein Flammenfilter geschaltet, das die Gasstrahlung (Bandenstrahlung) von H₂O und CO₂ unterdrückt. Diese Bandenstrahlung entsteht in den Flammen. Durch Unterdrückung der Bandenstrahlung ist ein Durchsehen durch die Flammen auf das Brennbett möglich.

Der Filter ist ein Bandpaß im spektralen Bereich von 3.8-4µ.

5.2.3 Einbau der Meßlanze

Die Infrarotkamera (IR-Kamera) wird mit einer Optik versehen, die zum einen die Funktionalität eines Objektivs besitzt. Mit dem Objektiv erreicht die Kamera einen Einstrahlwinkel von 54° horizontal und 50° vertikal. Außerdem dient die Optik der Verlängerung des Einstrahlpunktes, denn dieser muß sich im Feuerraum befinden. Die Kamera liegt so außerhalb, es wird aber innerhalb des Feuerraums gemessen. Abbildung 5.3 zeigt die Meßlanze und Abbildung 5.4 zeigt die Position des Einbaus zur Beobachtung des Verbrennungsrosts.

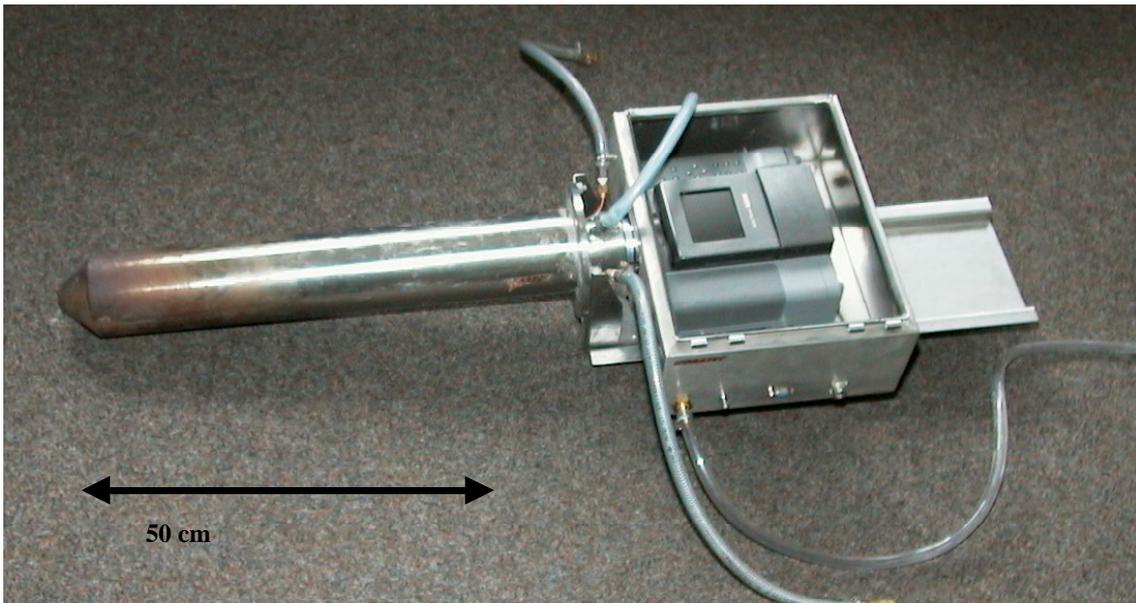


Abbildung 5.3: Meßlanze mit eingebauter Infrarotkamera

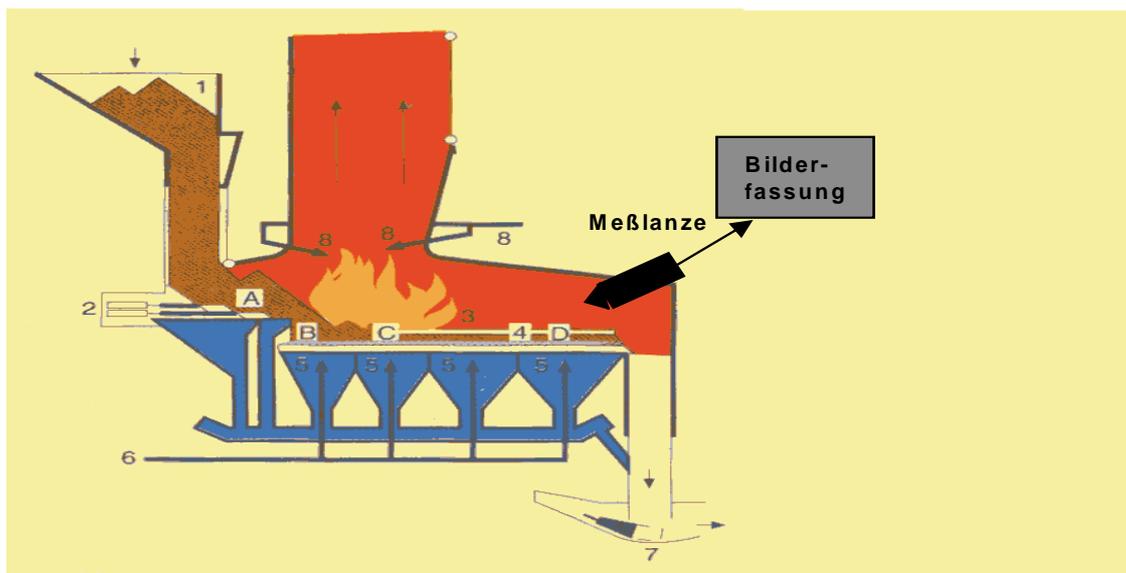


Abbildung 5.4: Einbau der Meßlanze

Das Objektiv der Kamera wird durch eine Kühlwasserversorgung vor Überhitzung geschützt. Damit das Objektiv nicht durch Flugpartikel verschmutzt, wird der Einstrahlpunkt des Objektivs mit Sperrluft freigeblasen.

5.3 Merkmalsextraktion aus Infrarotbildern und Meßdaten

Dieser Abschnitt beschreibt die Merkmalsextraktion aus gemessenen Infrarotbildern. Folgende Schritte werden hierfür durchgeführt:

1. Der Müll auf dem Brennbett wird in horizontale Fraktionen unterteilt, die während ihrer Zeit auf dem Rost aufgezeichnet werden.
2. Für jede Fraktion S wird eine Trajektorie $E_S(t)$ erzeugt, die die abgegebene thermische Energie beschreibt. Diese Trajektorie ist eine Funktion der Emissionen in Abhängigkeit von der Zeit.
3. Die erzeugten Trajektorien werden um die ihnen widerfahrenen Stellgrößen (Luftzufuhr und Müllmenge) bereinigt.

Die bereinigten Trajektorien und ihre zugewiesenen Emissionen werden als Trainingsdaten für ein Künstliches Neuronales Netz verwendet, um aus frühen Abschnitten der Trajektorie die Emissionen vorherzusagen.

Die Meßblanze ist relativ flach zum Verbrennungsrost installiert, was zu perspektivischen Verzerrungen bei der Sicht auf den Rost führt. Bevor die Infrarotaufnahmen weiterverarbeitet werden können, müssen die perspektivischen Verzerrungen rechnerisch eliminiert werden.

5.3.1 Bildentzerrung

Aus den Kameraaufnahmen wird ein perspektivisches Bild des Brennbetts gewonnen. Eine Entzerrung des Bildes ist notwendig, um eine gleichmäßige Bewegung der Müllfraktion zu erhalten, die mit der Position der darunterliegenden Luftzufuhr übereinstimmt. Erst dann kann eine Zuordnung von Luftzufuhr zu der jeweiligen Müllfraktion geschehen. Um die perspektivische Verzerrung durch die Aufnahmeposition zu erfassen, wurde zunächst der Feuerraum bei leerem Verbrennungsrost aufgezeichnet, um die geometrische Auslegung des Müllkessels zu erkennen. Abbildung 5.5 zeigt den Kessel in der Aufwärmphase (keine Verbrennung). Bei laufendem Betrieb wird durch die Müllauflage und die Reflexion an den Seitenwänden die Position des Verbrennungsrosts unkenntlich.

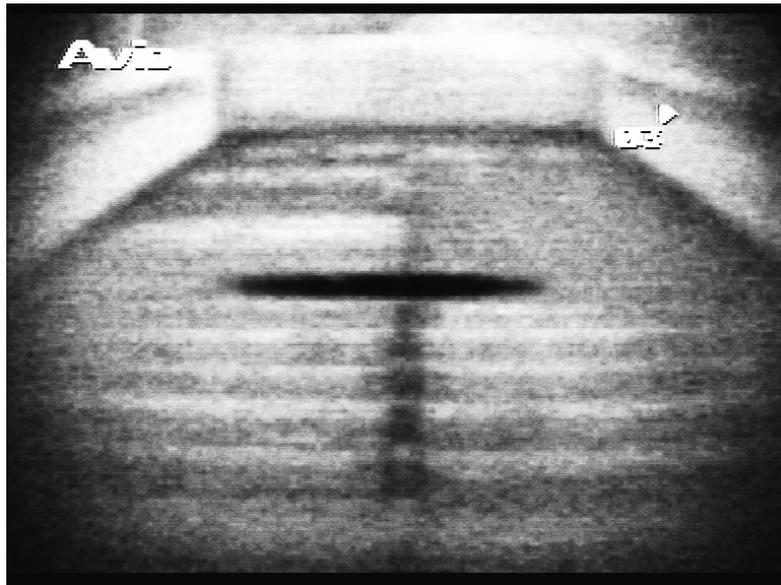


Abbildung 5.5: Leerer Feuerraum

Nun können die so ermittelten Begrenzungen des Verbrennungsrostes über das Bild der in Betrieb befindlichen Anlage eingetragen werden. Somit wird den Bereich des Bildes erhalten, der für die weitere Auswertung relevant ist. (Abbildung 5.6)

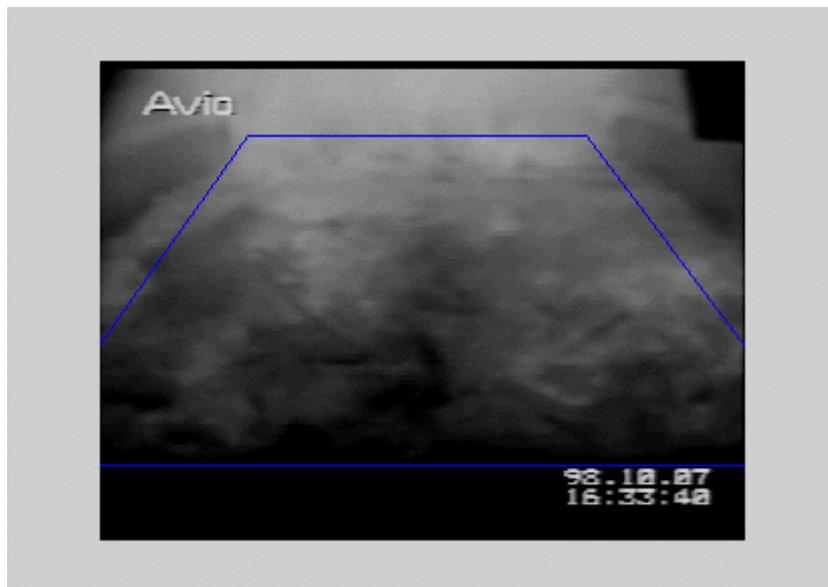


Abbildung 5.6: Feuerraum mit Rostbegrenzungen

Um das so ermittelte Trapez zu entzerren, wird jedes Pixel aus diesem Trapez in ein rechteckiges Gebiet transformiert. D.h. x- und y-Koordinaten werden zu jedem Pixel neu bestimmt. Dazu

wird eine Koordinatentransformation in ein neues Koordinatensystem (die Draufsicht) vorgenommen, das den Feuerraum räumlich entzerrt wiedergibt (Abbildung 5.7).

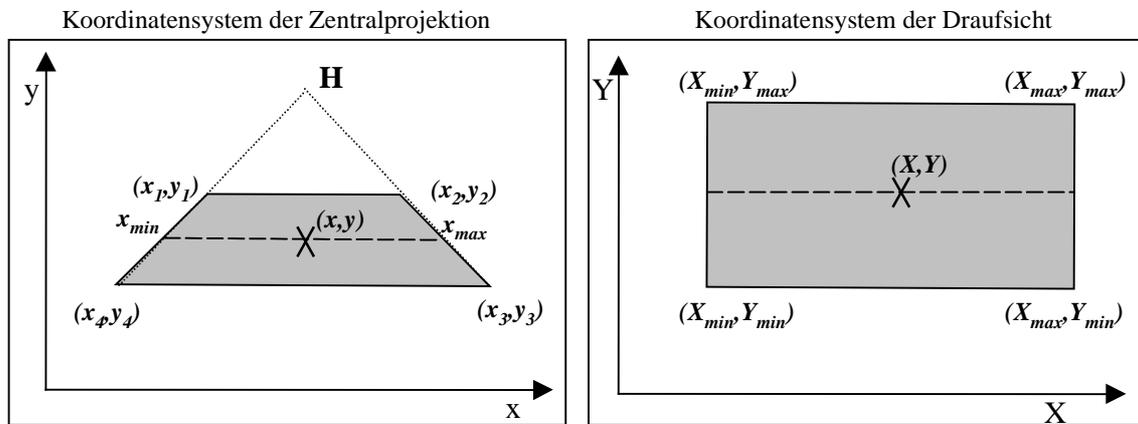


Abbildung 5.7: Links Koordinatensystem des aufgezeichneten Bildes, Rechts Koordinatensystem des entzerrten Bildes

Die Transformation ist eine geometrische Abbildung von der Zentralperspektive in die Draufsicht. Die Eckpunkte des transformierten Bereichs in der Draufsicht können beliebig vorgegeben werden, z.B. $(X_{min}, Y_{min}) = (1, 1)$ und $(X_{max}, Y_{max}) = (200, 200)$.

5.3.1.1 Transformation der x-Koordinate

Eine Transformation der x-Koordinate eines Pixels erfolgt nach folgender Formel:

$$X = X_{min} + \frac{x - x_{min}}{x_{max} - x_{min}} X_{max} \quad (5.7)$$

wobei $x_{max}(y)$ und $x_{min}(y)$ die vertikalen Endpunkte des umschließenden Trapezes darstellen (siehe Abbildung 5.7).

$x_{max}(y)$ berechnet sich zu

$$x_{max}(y) = x_3 + \frac{x_3 - x_2}{y_3 - y_2} y \quad (5.8)$$

und $x_{min}(y)$ berechnet sich zu

$$x_{\min}(y) = x_4 + \frac{x_4 - x_1}{y_4 - y_1} y \quad (5.9)$$

5.3.1.2 Transformation der y-Koordinate

Die Transformation einer Koordinate y nach Y ist aufwendiger. Der Punkt H (der Horizont) der Zentralperspektive wird in der Draufsicht auf (X, ∞) abgebildet. Je näher y gegen H geht, desto größer ist die Transformierte Y . H ist eine Asymptote und ist geometrisch der Schnittpunkt der Verlängerung der vertikalen Schenkel des Trapezes.

Der Horizont H errechnet sich als Schnittpunkt der Verlängerung der vertikalen Schenkel. Die Geraden der vertikalen Schenkel in Parameterdarstellung werden gleichgesetzt. Aus diesem Gleichungssystem mit zwei Unbekannte lassen sich die Koeffizienten eindeutig bestimmen, und somit der Horizont errechnen.

Für die Transformation der y -Koordinate wird nun der folgende funktionale Ansatz verwendet.

$$Y = \frac{a}{(y-b)} + c \quad (5.10)$$

Hierbei ist a ein Stauchungsfaktor und b die bekannte y -Koordinate des Horizonts H . c ist ein vertikaler Verschiebungsfaktor. a und c werden durch Lösen des linearen Gleichungssystems

$$\begin{pmatrix} Y_{\min} \\ Y_{\max} \end{pmatrix} = \begin{pmatrix} \frac{1}{y_4 - b} & 1 \\ \frac{1}{y_1 - b} & 1 \end{pmatrix} \begin{pmatrix} a \\ c \end{pmatrix} \quad (5.11)$$

ermittelt. Da von den vier Eckpunkten des Trapezes die Transformierten bekannt sind, lassen sie sich die korrespondierenden Punkte in (5.11) eintragen.

Abbildung 5.8 zeigt eine mit der Koordinatentransformation errechneten Draufsicht.



Abbildung 5.8: Entzerrtes Bild des Verbrennungsrostes.

Durch die Bildentzerrung wird eine direkte Draufsicht auf das Verbrennungsrost errechnet, so daß wandernde Müllpartikel mit einer konstanten Geschwindigkeit durch das Bild laufen.

5.3.2 Erstellung der raum-zeitlichen Emissionsprofile

Alle 30 Sekunden wird ein Bild vom Brennbett mit der IR-Kamera aufgenommen. Jedes Pixel entspricht einer Temperatur, und somit liefert die Kamera ein Temperaturprofil des Brennbetts. Eine Bildsequenz liefert dann zeitliche Trajektorien von Emissionen einzelner Müllfraktionen. Die thermischen Emissionen einer Fraktion werden über den Durchschnitt einer Rosthälfte gemessen.

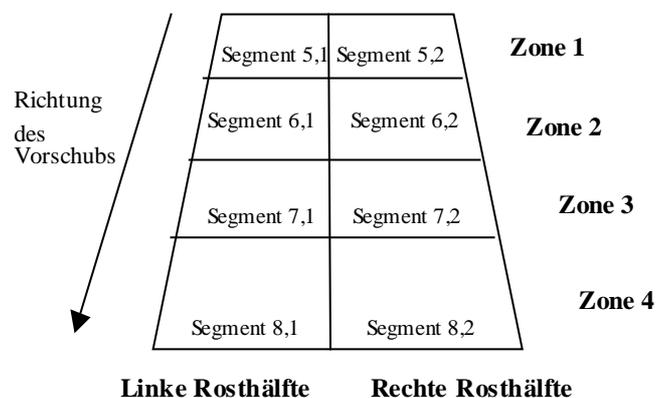


Abbildung 5.9: Schematischer Aufbau des Verbrennungsrostes bzgl. seiner steuerbaren Zonen.

Abbildung 5.9 zeigt schematisch den Verbrennungsrost aus der Sicht der Kamera. Jedes Segment ist mit einer eigenen Luftzufuhr ausgestattet. Aus Gründen der mangelnden Steuerbarkeit

werden mit Ausnahme von Zone 4 Segmente einer Zone mit gleicher Luftzufuhr versorgt. Die Infrarotkamera zeichnet nun die Temperatur der Verbrennung (und somit implizit die Emissionen) auf dem Rost in konstanten zeitlichen Abständen auf. Die Emissionen (Temperaturen) werden über die Rosthälften integriert und in eine Tabelle eingetragen. Die Werte der Tabelle über einen festgelegten Zeitraum werden in Abbildung 5.10 in Graustufen dargestellt, wobei helle Zonen hohe Temperaturen darstellen und dunkle Zonen niedrige Temperaturen.

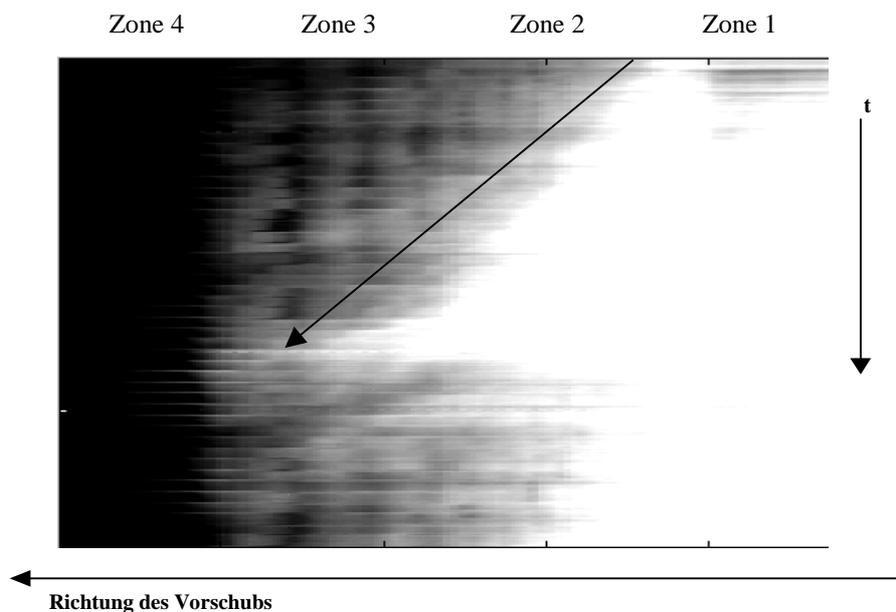


Abbildung 5.10: Schematische Verlauf einer Müllfraktion auf der linken Rosthälfte über die Zeit (schwarzer Pfeil). Gemessen werden die Emissionen.

Im oberen Bild ist schematisch der Verlauf einer Müllfraktion dargestellt. Um die Fraktion im Auge zu behalten, muß über die Rostgeschwindigkeit die gegenwärtige Position der Fraktion auf dem Rost errechnet werden. Die Rostgeschwindigkeit ist in der Anlage konstant.

Da die Rostbewegungen die Auflage räumlich verteilen, kann die Position einer Fraktion auf der letzten Rostzone nicht mehr präzise angegeben werden. Dies ist aber vernachlässigbar, da in den letzten beiden Zonen eine Verbrennung kaum noch stattfindet.

5.3.3 Erstellung von raum-zeitlichen Profilen der Primärluft

Für jedes Segment gibt es eine individuelle Primärluftversorgung, wobei Segmente einer Zone gleich angesteuert werden. Aus den vier Luftversorgungen pro Rosthälfte wird eine Primärluftverteilung über die Länge des Rostes linear interpoliert (siehe Abbildung 5.11).

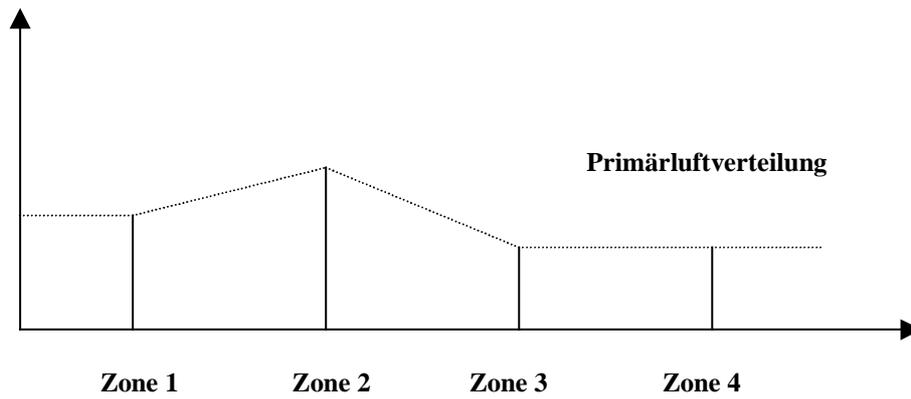


Abbildung 5.11: Primärluftverteilung, interpoliert durch die vier Luftversorgungen pro Rosthälfte

Die zeitliche Aneinanderfügung der Luftverteilungen ist in Abbildung 5.12 zu sehen. Die Darstellungsweise erfolgt analog zu Abbildung 5.10. Helle Zonen stellen nun hohe Luftzufuhr und dunkle Zonen stellen eine niedrige Luftzufuhr dar.

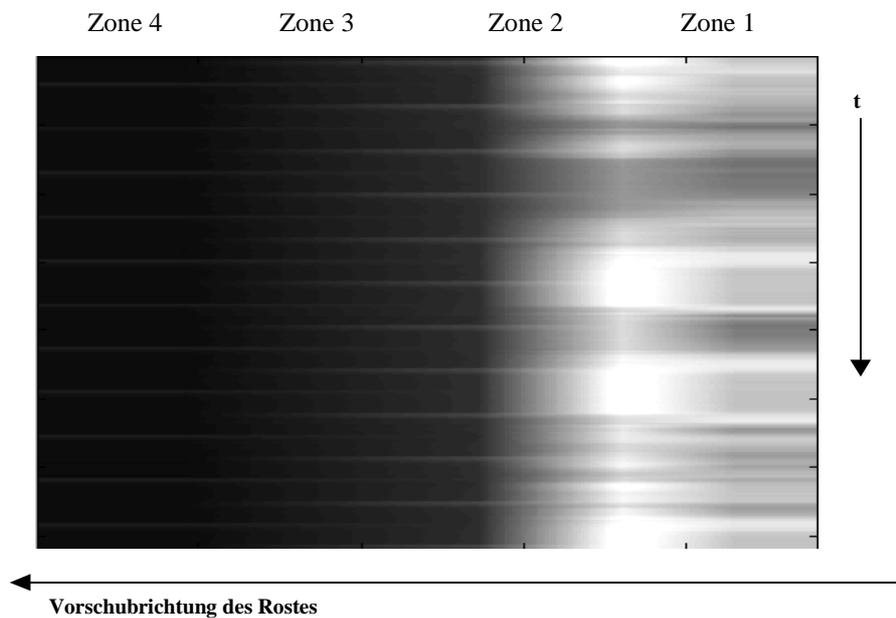


Abbildung 5.12: Profil der Luftzufuhr

Diese Profile stellen korrespondierende raum-zeitliche Verteilungen von Luftversorgung und gemessenen Emissionen (Abbildung 5.10) dar. Im folgenden Abschnitt werden unter Einsatz eines Modells die Einflüsse der Luftversorgung auf die Müllfraktion eliminiert.

5.3.4 Modellierung der Emissionen als Funktion der Primärluftzufuhr

Die Verbrennung ist von der Luftzufuhr innerhalb eines bestimmten Intervalls linear abhängig. Wie in Abschnitt 2.2.3 beschrieben wurde, ist der Einfluß der Luftzufuhr auf den Verbrennungsprozeß stark und unmittelbar sichtbar. Die Rostfeuerung reagiert auf Änderungen der Primärluft binnen weniger Sekunden. Die Massenumsatzrate steigt linear mit der Primärluftmenge an, bis sie so groß ist wie die Zündrate.

Abbildung 5.13 zeigt die lineare Kennlinie zwischen Massenumsatzrate und Luftzufuhr bei konstantem Heizwert. Hierbei beschreiben I-III Arbeitspunkte der Verbrennung. Erhöht sich die Luftzufuhr nach II weiterhin, so ist die Zündrate der begrenzende Faktor der Verbrennung.

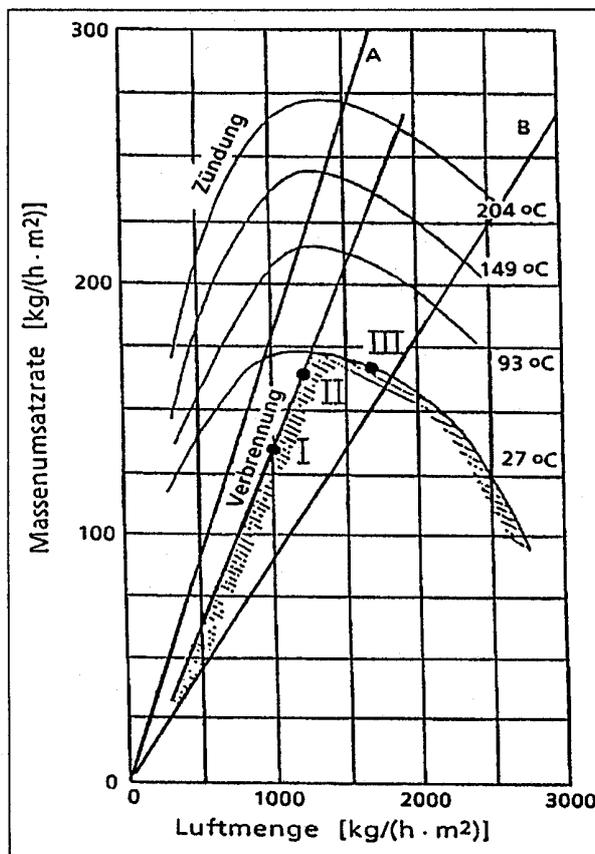


Abbildung 5.13: Zusammenhang zwischen Luftmenge und Massenumsatzrate bei der Verbrennung von Koks (aus [3]).

Wird mehr Primärluft zugeführt, so erzeugt dies einen Kühlungseffekt auf die Verbrennung. Die Massenumsatzrate nimmt wieder ab. Es ist ersichtlich, daß die Massenumsatzrate im Arbeitspunkt des Verbrennens (I-II) proportional zur Luftmenge ist.

Der lineare Zusammenhang zwischen Primärluft und Massenumsatzrate bildet die Basis für folgenden Ansatz zur Modellierung einer brennenden Müllfraktion unter Primärlufteinfluß mit dem Ziel, den Primärlufteinfluß herauszurechnen.

Emissionen $e(t)$ werden in einem zeitlichen Rahmen (von t_0 bis t_1) gemessen und zu einer Gesamtemission akkumuliert. Die Gesamtemission eines Partikels innerhalb eines Zeitraums $[t_0 t_1]$ ergibt sich dann zu

$$E(t_1) = \int_{t_0}^{t_1} e(t) dt \quad (5.12)$$

Um die Emission in Abhängigkeit der umgesetzten Luftmenge zu beschreiben, wird das Integral der Luftzufuhr über die Zeit $l(t)$ gebildet.

$$L(t_1) = \int_{t_0}^{t_1} l(t) dt \quad (5.13)$$

$L(t_1)$ ist die umgesetzte Luftmenge im Zeitraum $[t_0 t_1]$. Wird die Gesamtemission als eine Funktion der abgegebenen Luftmenge betrachtet, dann gilt aufgrund der Substitutionsregel der Zusammenhang

$$E_{gesamt} = \int_{l_0}^{l_1} e(L) dL \quad \text{mit } l_0 = L(t_0) \quad \text{und } l_1 = L(t_1) \quad (5.14)$$

$$E_{gesamt} = \int_{t_0}^{t_1} e(L(t)) L'(t) dt = \int_{t_0}^{t_1} e(L(t)) l(t) dt \quad (5.15)$$

Da $L(t)$, $l(t)$ und E_{gesamt} bekannt sind, läßt sich die Emission als Funktion der Luftmenge folgendermaßen beschreiben:

$$e(L) = \frac{d}{dt} \int_{t_0}^{t_1} e(L(t)) l(t) dt \quad (5.16)$$

$l(t)$ ist die abgegebene Luftmenge zum Zeitpunkt t an der Stelle x auf dem Rost. $e(L)$ läßt sich numerisch berechnen.

Im diskreten Fall wird zur Berechnung von $e(L)$ die Emissionskurve $e(x)$ in Rechtecke unterteilt, deren Form bei gleichbleibendem Flächeninhalt durch die umgesetzte Luft gestreckt oder gestaucht wird. Abbildung 5.14 zeigt schematisch das Vorgehen:

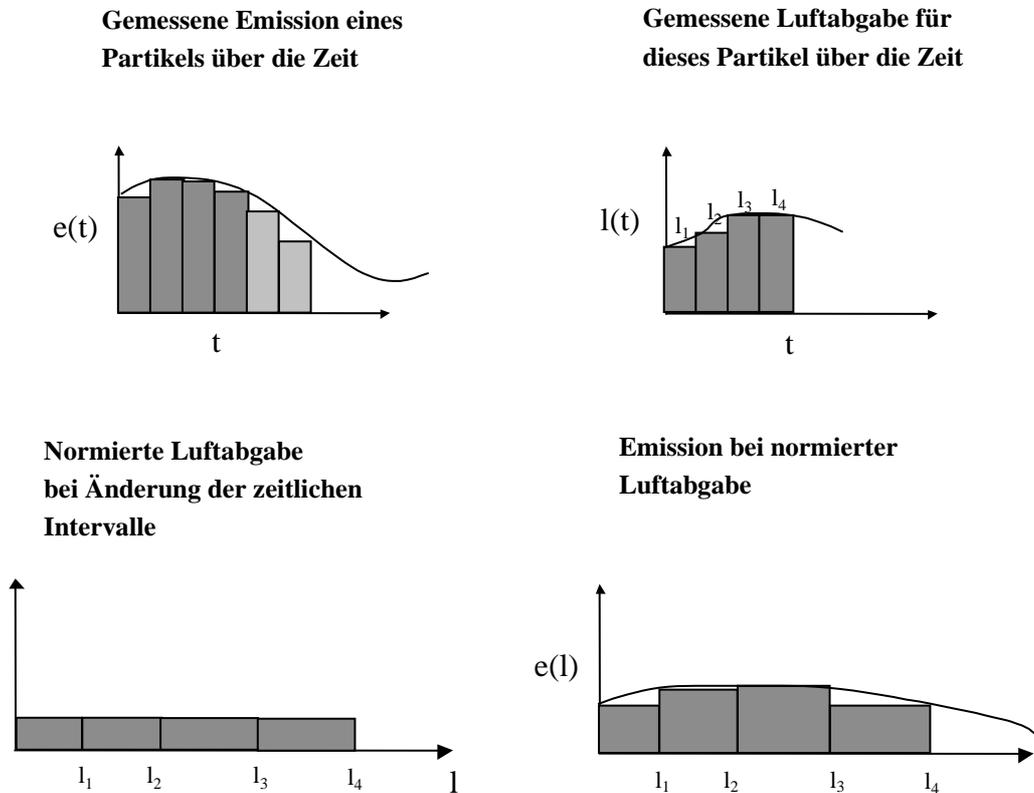


Abbildung 5.14: Entzerrung der Emissionen durch Normalisieren der aufgenommenen Luftmenge

Jedes Rechteck der Emission bei normierter Luftabgabe hat den gleichen Flächeninhalt wie das korrespondierende Rechteck unter $e(t)$.

$e(L)$ stellen nun die Emissionen in Abhängigkeit der Luftzufuhr dar. Folglich liegen die Emissionen nicht mehr als implizite Funktion der Luftzufuhr vor.

Zuletzt wird $e_S(L)$ (die Emission einer Müllfraktion S unter bisheriger Primärluftzufuhr L) normalisiert durch die Menge der Müllaufgabe, die zu jedem Zeitpunkt bekannt ist. Die Integration der resultierenden Trajektorie liefert einen Parameter, der mit dem Heizwert der Fraktion korreliert ist.

Die folgenden Abbildungen zeigen die thermischen Gesamtemissionen einzelner Müllfraktionen, die der Reihe nach den Rost verlassen. Abbildung 5.15 zeigt die Gesamtemissionen vor –

und Abbildung 5.16 nach Normalisierung durch die Müllmenge. Die Y-Werte sind dimensionslos.

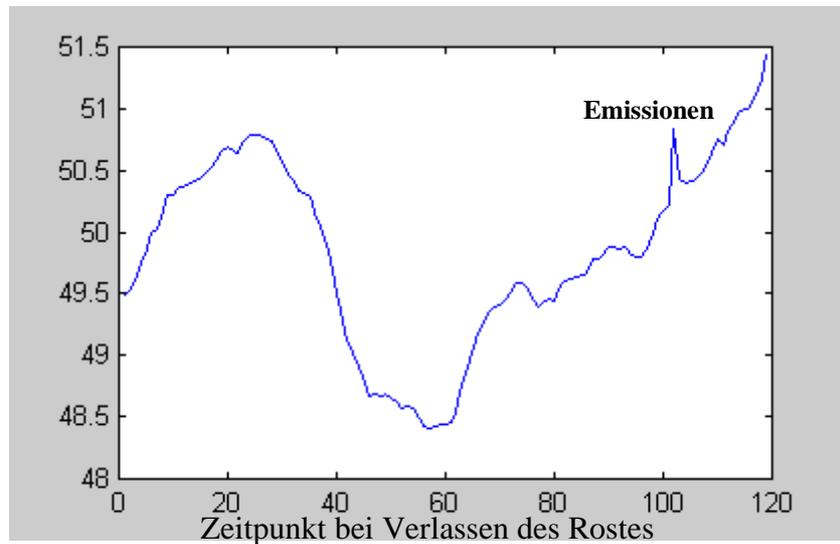


Abbildung 5.15: Thermische Emissionen der linken Rosthälfte.

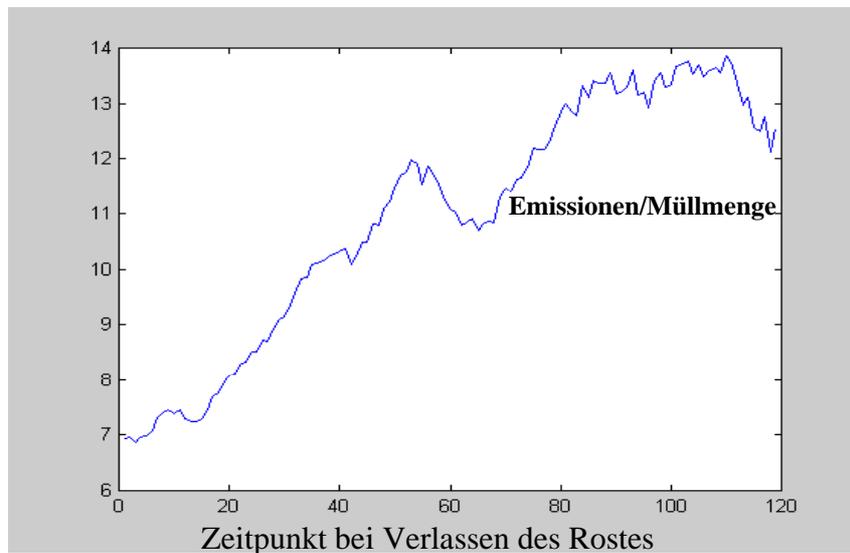


Abbildung 5.16: Thermische Emissionen normalisiert durch die Müllmenge.

Somit wird ein Wert der spezifischen Emissionsmenge pro Mülleinheit erhalten.

In diesem Abschnitt wurde durch ein lineares Modell eine Merkmalsextraktion der thermischen Emissionsprofile unter Einfluß der Stellgrößen durchgeführt. Ein Merkmal ist eine Trajektorie der Emissionen unter Herausrechnung der Stellgrößen.

Durch die Eliminierung der Stellgrößeneinflüsse aus dem Emissionsprofil werden invariante Emissionsprofile erzeugt, die nun einer überwachten Klassifikation unterzogen werden.

5.4 Zuweisung der Merkmale zu Emissionen

Die erhaltenen Trajektorien werden für ein überwachtes Training eines Künstlichen Neuronales Netzes eingesetzt. Aufgrund der Trainingsdaten soll das Netz frühzeitig die entstehenden Emissionen ermitteln.

Das Netz soll die funktionale Abbildung aus Merkmalen der Trajektorie und der Gesamtheit der Emissionen für ein Partikel lernen. Als Merkmale werden der Zeitpunkt der maximalen Verbrennung sowie der Betrag der maximalen Emissionen, bereinigt um den Einfluß der Luftzufuhr, verwendet. Dies erscheint sinnvoll aufgrund der Betrachtungen in Abschnitt 5.1. Es werden also Paare gesammelt $((x,y)_{max}, \int E(x)dx)$

5.4.1 Training des Künstlichen Neuronales Netzes

Zuerst wird prototypisch ein Netz mit Trainingsdaten im Umfang von einer Stunde trainiert. Der Zweck des Trainings ist noch nicht eine gute funktionale Approximation, sondern zunächst eine Klassifikation, die zeigt, ob die Daten überhaupt eine funktionale Abbildung zulassen. Als Netztyp wird ein Counterpropagation Netz verwendet, wie es von Hecht-Nielsen 1990 vorgeschlagen wurde [30]. Dieses Netz ist ein Kohonennetz (siehe Abschnitt 3.4.1.1), um eine pro Neuron konstante Ausgabe erweitert (siehe Abbildung 5.17). Die Eingabe besteht aus einem n-dimensionalen Vektor, dessen Komponenten in allen Neuronen einer Kohonen-Schicht ohne Gewichtung eingegeben werden. Die Ausgabeschicht besteht aus einem einzigen linearen Assoziator. Die Gewichte zwischen der Kohonen- und Ausgabeschicht werden durch ein Lernverfahren, analog zur Selbstorganisation eines Kohonennetzes ermittelt. Die Kohonen-Schicht erstellt eine topografische Karte des Eingaberaums. Am Ende des Lernverfahrens hat sich jedes Neuron in der Kohonen-Schicht auf ein bestimmtes Gebiet des Eingaberaums spezialisiert.

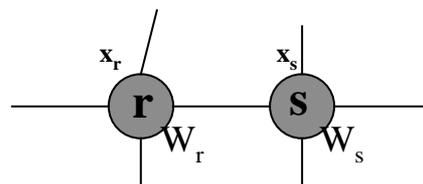


Abbildung 5.17: Zwei Neuronen eines Counterpropagation Netzes

In der Abrufphase wird das Neuron mit der größten Ähnlichkeit von Gewichtsvektor zu Eingabevektor feuern. Dessen Ausgabegewicht hat sich im Laufe des Lernzyklus auf den Mittelwert der ihm zugeordneten Ausgaben justiert.

Ergebnisse

Aus einer einstündigen Meßkampagne wurden Trajektorien aufgezeichnet und deren Merkmale für das Training eines Counterpropagation Netzes extrahiert. Das Netz wurde mit 120 Datensätzen trainiert. Das Netz hat die Topologie eines 5*5 Gitters. Der Eingaberaum ist zweidimensional, die Ausgabe pro Neuron konstant. Die Eingabedaten wurden zugunsten einer gleichmäßigen Verteilung normalisiert. Nach dem Training zeigt das Netz eine Funktionalität von Eingabe zu Ausgabedaten. Abbildung 5.18 zeigt die Transferfunktion des trainierten Netzes auf dem zweidimensionalen Eingaberaum.

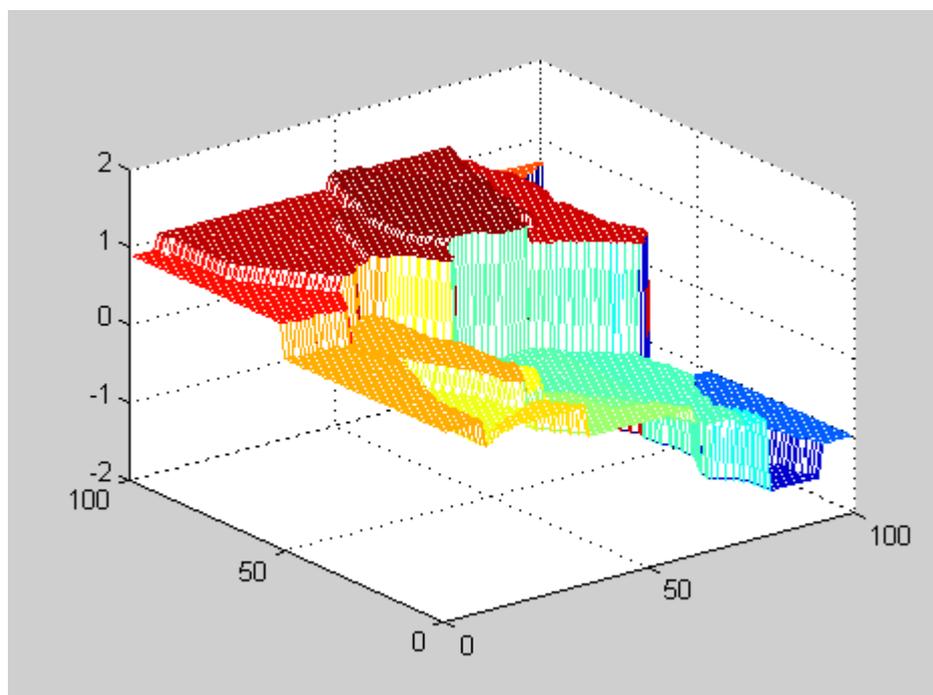


Abbildung 5.18: Ausgabe des Counterpropagation Netzes

Die Ausgabewerte sind stückweise konstant, und jedes Plateau steht für ein rezeptives Feld des jeweiligen Neurons.

Abbildung 5.19 zeigt die Netzausgabe zu real abgegebene Emissionen. Je näher eine Schätzung (gekennzeichnet mit '+') an der Hauptdiagonalen liegt, desto genauer stimmt sie mit den real gemessenen Emissionen überein. Es findet eine gute Übereinstimmung statt, die eine bestehende funktionale Abhängigkeit zwischen Ein- und Ausgabedaten bestätigt. Schließlich wurden ca. 5 Eingaben auf ein Neuron abgebildet.

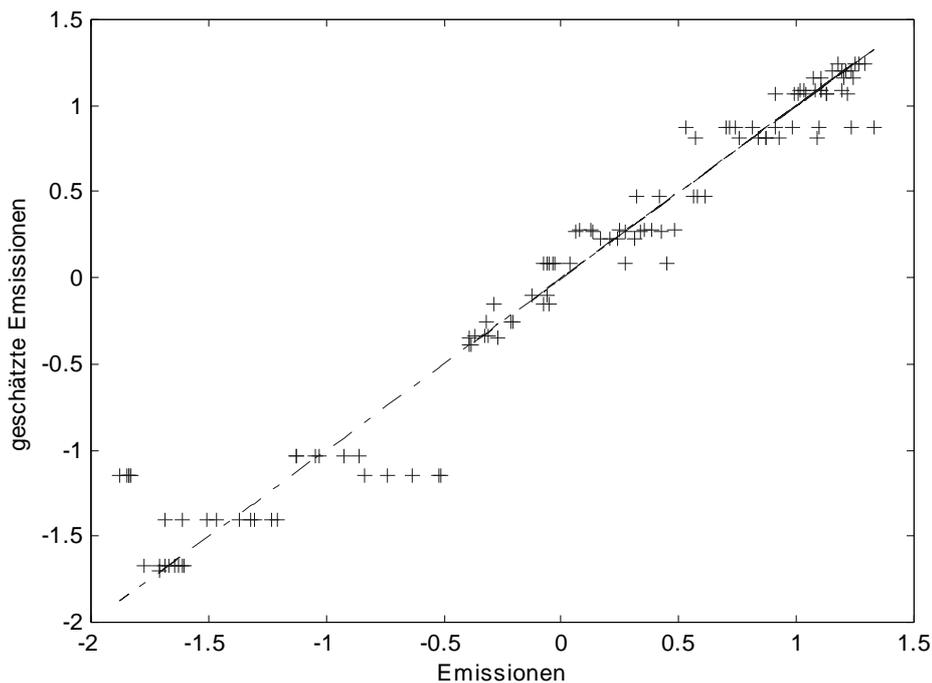


Abbildung 5.19: Tatsächliche Emissionen und Schätzung des Counterpropagation Netzes

Das Netz ist ähnlichkeiterhaltend, d.h. ähnliche Eingaben werden auf ähnliche Ausgaben abgebildet. Ließen die Trainingsdaten keine funktionale Abbildung zu, so würden ähnliche Eingabedaten auf entfernte Ausgabedaten abgebildet, und die resultierende konstante Ausgabe pro Neuron wäre ein Mittelwert.

Die obigen Ergebnisse wurden mit einem Counterpropagation Netz erzeugt, um die Tauglichkeit der Daten hinsichtlich ihrer funktionalen Abbildungsfähigkeit zu erhalten.

Für die Verbesserung des Schätzwerts bestehen die folgende Möglichkeiten:

- 1 Lineare Interpolation anstelle von konstanter Ausgabe
- 2 Einsatz von RBF-Netzen.

Im folgenden Abschnitt wird versucht, die funktionale Approximation unter Einsatz von RBF-Netzen zu verbessern.

5.4.2 Einsatz von RBF-Netzen

Die obige Vorgehensweise hat gezeigt, daß die Daten eine Nachbarschaftsbeziehung erhalten. Nun eignen sich Counterpropagation Netze aufgrund ihrer konstanten Ausgabe eher zur Klassifikation als zur stetigen funktionalen Approximation. Anstelle einer stückweise konstanten Ausgabe ist eine Interpolation zwischen den Ausgaben der einzelnen Neuronen wünschenswert. In diesem Zusammenhang werden RBF-Netze als Erweiterung des Counterpropagation Kon-

zepts gesehen, da hier die Lokalität der Erregungszentren mit einer kontinuierlichen Ausgabe gekoppelt wird. Eine Beschreibung von RBF-Netzen wurde bereits in Abschnitt 3.4 gegeben. Um die Leistungsfähigkeit der beiden Modelle zur Funktionsapproximation direkt zu vergleichen, werden die beim Counterpropagation- Ansatz trainierten Erregungszentren als Basisvektoren eines RBF-Netzes gewählt. Dann erfolgt ein überwachtes deterministisches Training, um die linearen Koeffizienten des Netzes zu bestimmen.

Abbildung 5.20 zeigt die Oberfläche des RBF-Netzes, bestehend aus einem Gitter von 5*5 Neuronen, deren Erregungszentren die des Counterpropagation Netzes sind.

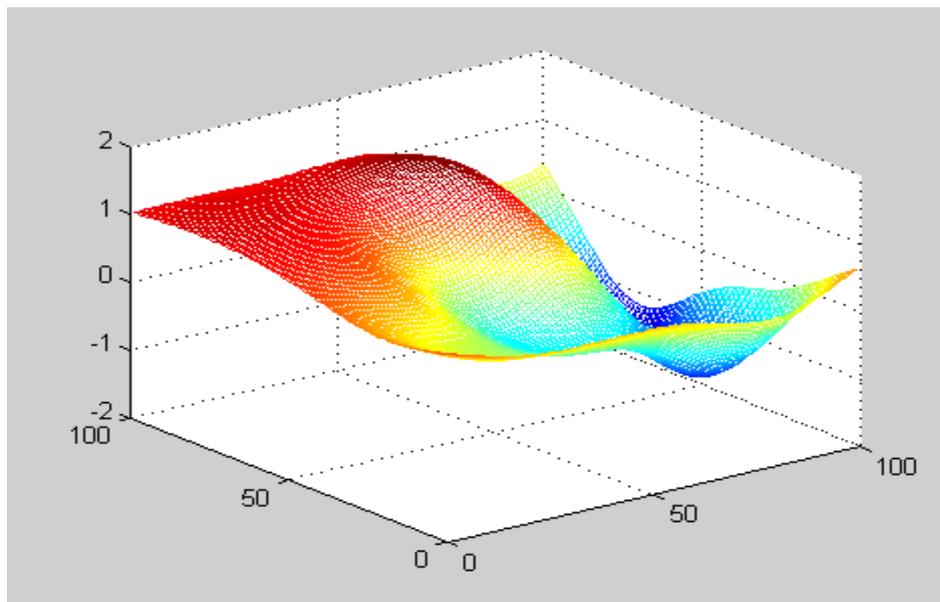


Abbildung 5.20: Netzausgabe des RBF-Netzes

Die glatte Oberfläche ermöglicht eine kontinuierliche, stetige Ausgabe als Funktion der Trainingsdaten. Abbildung 5.21 zeigt die Netzausgabe gegen die tatsächlichen Emissionen. Die Approximation der Emissionen wird durch den Einsatz eines RBF-Netz nicht verbessert.

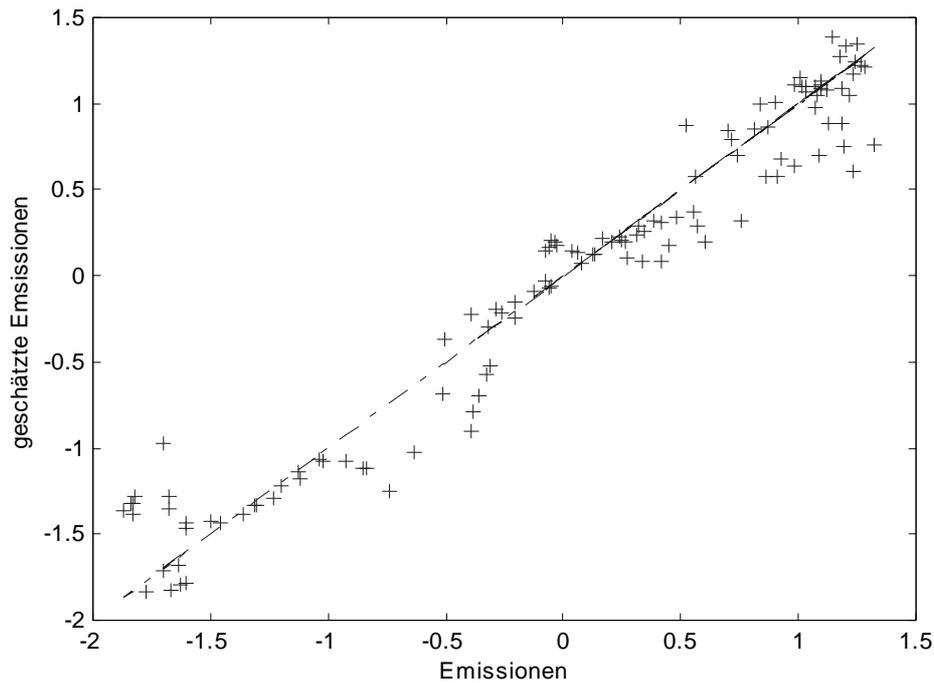


Abbildung 5.21: Über ein RBF-Netz errechnete Emissionen zu tatsächlichen Emissionen .

Die Klassifikation mit Counterpropagation Netzen wurde durch den Einsatz eines RBF-Netzes zu einer funktionalen Abbildung erweitert. Allerdings ergeben sich dadurch keine verbesserten Vorhersagen.

Es gibt mehrere Unsicherheiten meßtechnischer Seite, die Trainingsdaten verfälschen können: Die schlechte Aufnahmeperspektive, eine schlechte Modellierung der Luftverteilung auf dem Rost und unbekannte Einflüsse durch die Meßtechnik (Flugstäube, Reflektionen).

Daher ist eine genauere funktionale Approximation erst sinnvoll, wenn obige meßtechnische Unsicherheiten beseitigt sind.

5.5 Schlußfolgerung und Ausblick

In diesem Kapitel wurden Infrarotbilder vom brennenden Müll auf dem Verbrennungsrost aufgenommen, um das Brennverhalten des Mülls über die Verweilzeit auf dem Rost zu beobachten. Daraus wurden Trajektorien extrahiert, die die Emission einzelner Müllpartikel auf dem Rost über die Zeit anzeigen. Eine Klassifikation dieser Trajektorien erfolgte nach folgenden Schritten:

- Die Emissionslinien wurden unter Einsatz eines linearen Modells um den Betrag der eingreifenden Luftmenge bereinigt.

- Aus den bereinigten Linien wurden Merkmale gewonnen und einem Counterpropagation Netz zur überwachten Klassifikation gegeben. Hierbei wurde mit wenig Neuronen ein relativ guter Klassifikator gewonnen.
- Es wurde eine kontinuierliche Erweiterung des Klassifikators durch ein RBF-Netz gebildet. Die kontinuierliche Erweiterung führte aber nicht zu einer präziseren Bestimmung der Gesamtemissionen.

Eine präzisere Bestimmung der Emissionen kann nur unter genaueren Meßbedingungen erfolgen. Hierzu ist erforderlich:

- Aufnahmen senkrecht auf das Rost zu machen, damit der Rostanfang präziser aufgelöst werden kann.
- Labormessungen zum Strömungsverhalten der Primärluft auf dem Rost zu machen, damit die Primärluftverteilung auf dem Rost präziser ermittelt werden kann.

Von den gemessenen thermischen Emissionen muß dann noch eine Zuordnung zur Sollwertvorgabe für die Dampfmenge mit Unterstützung des Anlagenpersonals gemacht werden.

Integration in das Regelungskonzept

Durch Vorgabe der thermischen Emissionen (und damit implizit des Heizwerts) kann die in den Kapiteln 3 und 4 dargestellte Regelung verbessert werden. Globale Änderungen stellen sich ein, wenn ein neuer Abfalltyp verbrannt wird.

Bisher wird der Heizwert durch das Betriebspersonal geschätzt. Dann wird ein Parameter der Prozeßsteuerung manuell eingestellt. Dies erfolgt nicht automatisch und unregelmäßig. Es können Änderungen im Heizwert nicht regelmäßig und in einem präzisen Maße aktualisiert werden. Durch die in diesem Kapitel vorgestellte Methodik zur frühzeitigen Klassifikation der Gesamtemissionen kann eine automatische Bestimmung eines neuen Sollwertes schneller erfolgen.

Abbildung 5.22 zeigt die Integration des hier entwickelten Klassifikators in das Gesamtkonzept der modellbasierten prädiktiven Regelung.

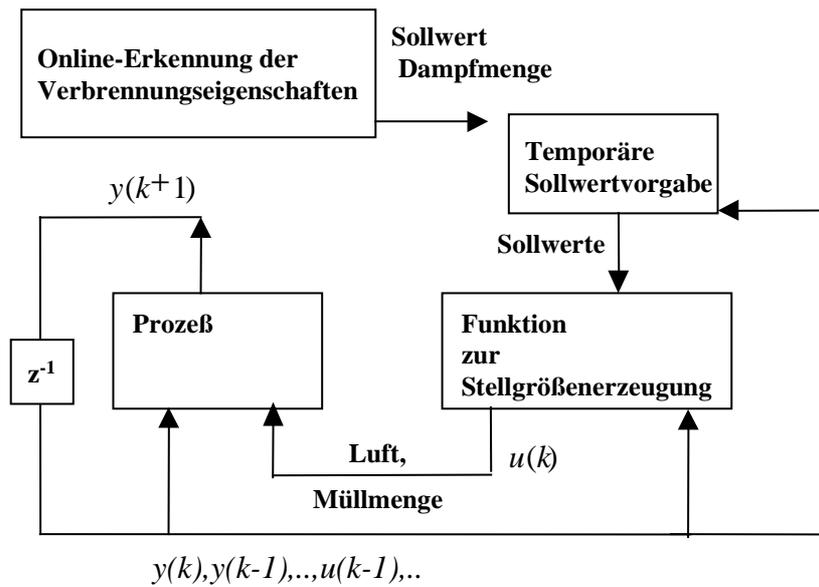


Abbildung 5.22: Integration der Infrarot-Thermographie in das Regelungskonzept von Kapitel 4

Die in diesem Kapitel beschriebene Früherkennung der Verbrennungseigenschaften des Mülls wurde ebenfalls in das System INSPCET integriert. Realisiert werden muß noch die Zuordnung von Gesamtemission zum Dampfsollwert. Hierzu sind weitere Meßreihen zum Bestimmen dieser Zuordnung nötig.

6 Zusammenfassung

Das Ziel der Arbeit bestand in der Entwicklung primärer Maßnahmen zur Verbesserung der Prozeßführung in der thermischen Abfallbehandlung.

Es wurde eine modellbasierte Regelung mit einem KNN-basiertem Modell entwickelt, implementiert, und getestet. Diese Regelung besteht aus den Komponenten Modell, Stellgrößenherleitung und temporärer Sollwertvorgabe.

Des weiteren wurden mit einer Infrarotkamera Merkmale aus dem Abbrandverhalten von Müll gewonnen und mit Künstlichen Neuronalen Netzen klassifiziert. Die Klassifikationsergebnisse liefern weitere bisher nicht verfügbare Informationen zur gegenwärtigen Situation der Verbrennung.

Die inhaltlichen Schwerpunkte der Arbeit umfassen:

- Bestimmung der Modellkonfiguration für ein KNN als Modell des Müllverbrennungsprozesses.
- Aufbau einer modellbasierten prädiktiven Regelung auf Basis des zuvor erstellten Neuronalen Modells.
- Verminderung der Störeinflüsse durch frühzeitige Bestimmung der Verbrennungseigenschaften des verbrennenden Mülls.

Im folgenden werden die wichtigsten Ergebnisse der Arbeit zusammengestellt, die neue Aspekte bzw. Modifikationen und Erweiterungen des bisherigen Wissensstands enthalten:

1. Eine Nichtlineare Modellierung auf der Basis von Künstlichen Neuronalen Netzen wurde für den Prozeß der Müllverbrennung erstmals eingesetzt.
2. Bei der Auswahl wurden Multilayer-Perceptrons und RBF-Netze untersucht. Die Modellierung mit Multilayer-Perzeptrons zeigte ein besseres Generalisierungsverhalten des Modells.
3. Zur Untersuchung der Einsatztauglichkeit von RBF-Netzen wurde eine lokale lineare Darstellung durch ein Kohonennetz gewählt. Hierbei sorgte eine neuartige Initialisierung des Netzes für eine bessere Konvergenz.
4. Die Konvergenzgeschwindigkeit- und güte beim Training von MLPs konnte durch eine redundanzfreie Repräsentation der Trainingsdaten in Form von numerischen Ableitungen erheblich gesteigert werden.

5. Bei der Stellgrößengewinnung aus dem KNN-basierten Modell konnten bei etwa gleichem rechnerischem Aufwand durch globale Suche mit Intervallschachtelung bessere Stellgrößen gefunden werden als durch Gradientenbildung durch das Modell.
6. Für eine prädiktive Regelung erfordert der Einsatz eines nichtlinearen Modells einen hohen rechnerischen Aufwand, der jedoch durch optimierende Suchstrategien entscheidend gesenkt werden konnte. Das entwickelte Verfahren ist echtzeitfähig.
7. Ein neues Verfahren zur Merkmalsextraktion von Infrarotbildern zur Klassifikation des Abbrandverhaltens wurde entwickelt.

Die modellbasierte Regelung wurde für zwei Müllverbrennungsanlage implementiert.

8. Für Anlage 1 wurde ein monolithisches System, bestehend aus den Komponenten Simulation, Regelung, Prozeßankopplung und TCP/IP Schnittstelle zu einer grafischen Benutzeroberfläche in der Programmiersprache C implementiert.
9. Für die Anlage 2 wurde das Prozeßführungssystem INSPECT entwickelt, das sich durch modularen Aufbau auszeichnet. Es wurden die Komponenten Simulation, Regelung und Bildverarbeitungsoperatoren zur Merkmalsextraktion integriert.
10. Die modellbasierte Regelung von Anlage 2 zeigt im geschlossenen Regelkreis bei einer Simulation ein besseres Verhalten der Führungsgrößen als die bestehende. Das Finden einer optimalen Handlungssequenz in Kombination mit einer frei definierbaren Gütefunktion macht die modellbasierte prädiktive Regelung vielseitig einsetzbar.

Ausblick: Durch eine Änderung des Arbeitspunkts bzw. des Betriebsverhaltens kann sich die Modellgüte der modellbasierten prädiktiven Regelung verschlechtern. Abhilfe kann der Einsatz mehrerer Modelle schaffen, die für verschiedene Betriebsverhalten trainiert worden sind.

Parametrisierbare Koeffizienten der Gütefunktion zur Bewertung der Handlungssequenzen liefert ein Feld zur weiteren Forschung. So lassen sich z.B. verbotene Betriebszustände in der Gütefunktion darstellen.

Zu einer präziseren Ermittlung der Brenneigenschaften durch Infrarot-Thermographie sind weitere meßtechnische Verbesserungen erforderlich. Die frühzeitige Bestimmung des Abbrandverhaltens des Mülls zur automatischen Dampfmengensollwertvorgabe mit der in Kapitel 5 vorgestellten Methodik stellt ein Verbesserungspotential für viele Müllverbrennungsanlagen dar.

7 Literatur

- [1] Altrock, Ch.; Krause, T; Limper, S.: Regelung einer Müllverbrennungsanlage mit Fuzzy Logik. aus „Fuzzy Logic“, Oldenbourg Verlag, München; 1994
- [2] AT Sonderheft 3 '95: Evolutionäre Algorithmen, Oldenbourg Verlag; 1995
- [3] Behrendt, T.: Thermodynamische Modellierung des Betriebsverhaltens von Hausmüllverbrennungsanlagen am Beispiel TAMARA. VDI Fortschrittberichte. Reihe 15, Umwelttechnik. Nr. 99. 1993
- [4] Bellmann, R.: Dynamische Programmierung und selbstanpassende Regelprozesse. Oldenbourg; 1967
- [5] Braun H., Ragg T.: ENZO - Evolution of Neural Networks, User Manual and Implementation Guide. Technical Report 21/96, Universität Karlsruhe, Fakultät für Informatik; 1996
- [6] Bretthauer, G.: Anwendung der statistischen Entscheidungstheorie für die Identifikation gestörter Regelstrecken. MSR Berlin 22, S. 202-207; 1979
- [7] Bretthauer, G.: Über die Anwendung der statistischen Entscheidungstheorie zur Systemidentifikation durch Modellsektion an der offenen Wirkungskette und am geschlossenen Regelkreis. Dissertation, TU Dresden, 1977
- [8] Bretthauer, G.; Opitz, H.P.: Stability of Fuzzy Systems – A Survey. Preprints, Second European Congress on Intelligent Techniques and Soft Computing. Aachen, Vol. 1, pp.283-290; 1994
- [9] Bretthauer, G.; Straube, B.: Einsatzmöglichkeiten für Fuzzy Regler. Studie, SMWK-7541.82-EPS/1, S. 1-208, Dresden; 1992
- [10] Brockhaus Enzyklopädie, Brockhaus Verlag Leipzig, Mannheim; 1988
- [11] Brown, M. C.: Perl programmer's reference. Berkeley; McGraw-Hill, 1999
- [12] Burgbacher, R.: Thermische Behandlung und Kompostierung. Expert Verlag; 1993

- [13] Busch M., Rampp, F., Martin, J., Horn, J.: Entwicklung einer kamerageführten Feuerungsregelung zur Verbesserung des Verbrennungs-, Ausbrand- und Emissionsverhalten einer Abfallverbrennungsanlage. VGB Kraftwerkstechnik 73, Heft 7, S. 614-618; 1993
- [14] Dayal, B.; Taylor, P, Macgregor J.: The Design of Experiments, Training and Implementation of Nonlinear Controllers based on Neural Networks. The Canadian Journal of Chemical Engineering, Vol. 72, pp. 1066-1079; 1994
- [15] Dony, R. D. Haykin, S.: Neural Network Approaches to Image Compression. Proc. of the IEEE, Vol 83 No 2. Feb; 1995
- [16] Dyntar, D.: Fuzzy Logic Control im Vergleich mit modellbasierten Entwurfsverfahren. Zentralschweizerisches Technikum Luzern, pp.279-204; März 1993
- [17] Fahlman, S.: An Empirical Study of Learning Speed in Back-Propagation Networks <http://www.boltz.cs.cmu.edu/tech-report.html>, Technical Report; 1988
- [18] Föllinger, O.: Nichtlineare Regelungen. Oldenbourg, 1982
- [19] Fritzke, B.: Growing Cell Structures- A self Organizing Network for Unsupervised Learning. Neural Networks Vol 7, No 9, pp 1441-1460; 1994
- [20] Froese, Th.: Optimierung von Polymerisationsprozesses mit Neuronalen Netzen und Genetischen Algorithmen. ATP 5/98, pp 49-53, 1998
- [21] Gaussorgues, G.: Infrared Thermography. Chapman Hall; 1994
- [22] Geering, H.: Regelungstechnik: mathematische Grundlagen, Entwurfsmethoden, Beispiele. Berlin u.a. Springer, 1996
- [23] Gessner, P.; Wacker, H.: Dynamische Optimierung. Muenchen, Hanser; 1972
- [24] Gierend Ch.: Fuzzy Logic Control of a Waste incineration Plant. 5. Aachener Fuzzy Symposium; 1995
- [25] Glückert, U.: Erfassung und Messung von Wärmestrahlung: Eine praktische Einführung in die Pyrometrie und Thermographie. München, Franzis; 1992

- [26]Guenzler, H; Heise, Herbert M.: IR-Spektroskopie: eine Einführung. Weinheim u.a. : VCH; 1996
- [27]Häck M., Köhne M.: Internal Model Control mit neuronalen Netzen zur Regelung eines Prozeßanalysators. AT 1/97, pp14-23; 1997
- [28]Hämmerli, H.: Trocknungs- Verbrennungs- und Sinterungsvorgänge bei der Müllverbrennung. Phoenix Int. 4 (1986), S. 26-32; 1986
- [29]Haykin,S.: Neural Networks. Macmillan, New York, 1994
- [30]Hecht-Nielsen, R.: Neurocomputing. Addison-Wesley; 1991
- [31]Heinz, G.; Schroth, G.: EVT- Vorschubrost für die Abfallverbrennung. aus "Rostfeuerungen zur Abfallverbrennung“, EF- Verlag für Energie und Umwelttechnik GmbH, Berlin; 1991
- [32]Henrion, G.: Multivariate Datenanalyse : Methodik und Anwendung in der Chemie und verwandten Gebieten. Berlin, Springer; 1995
- [33]Henson, M.: Nonlinear Process Control. Prentice Hall, 1997
- [34]Holland, J. H.: Adaptation in natural and artificial Systems. The University of Michigan Press, Ann Arbor, MI; 1975
- [35]Hrycej, T.: Neurocontrol: towards an industrial control methodology. New York u.a. Wiley; 1997
- [36]http://www.itas.fzk.de/deu/projekt/achte_97.htm
- [37]Isermann, R.: Identifikation dynamischer Systeme. Band II, Springer Verlag Heidelberg; 1988
- [38]Jaeschke, A., Keller, H. B.: Innovative Prozeßleittechnik in der thermischen Abfallbehandlung. aus "Einsatz von wissensbasierten Systemen, Fuzzy Reglern und neuronalen Netzen". ÖVE-Verbandszeitschrift e&i, 111. Jg. (1994) Wien, Heft 9, S. 463-469; 1994

- [39]Jäkel, J. Ehrlich, H.: Fuzzy- Reglerentwurf auf der Basis eines unscharfen Prozeßmodells. Proc. Fachtagung Moderne Methoden des Regelungs- und Steuerungsentwurfs, Magdeburg, S. 242-249; 1997
- [40] Jang, R.; Sun, C.; Mizutani, E.: Neuro-fuzzy and soft computing: a computational approach to learning and machine intelligence. Prentice Hall, 1997
- [41]Jochem, M.; Schumacher, W.: Einsatz der IR Thermographie über einem Steinmüller Vorschubrost zur Feuerleistungsregelung. aus: Rostfeuerungen zur Abfallverbrennung, EF-Verlag für Energie- und Umwelttechnik GmbH, Berlin; 1991
- [42]Juniper, L.; Wall, T.: Combustion of particles in a large pulverized Brown Coal. Flame, Combustion and Flame 39 (1980) S. 69-81; 1980
- [43]Keller, H. B.: Maschinelle Intelligenz - Grundlagen, Methoden und Anwendungen. Vieweg; 2000
- [44]Keller, H. B.: Neural Nets in Environmental Applications. In: Avouris, N.; Page, G.: Environmental Informatics - Methodology and Applications. Dordrecht: Kluwer Academic Publishers; 1995
- [45]Keller, H. B.; Fick, A.; Kugele, E., Müller, B: Computational Intelligence Methods for the Optimisation of Thermal Waste Treatment. 7th European Congress on Intelligent Technologies and Soft Computing, Aachen, Germany, Sept. 13-16; 1999
- [46]Keller, H.; Kugele, E., Jaeschke, A; Albert, F.W.: Ein Videobild-gestütztes System zur Optimierung des Ausbrandes in der thermischen Abfallbehandlung. Wasser & Boden, 49 (1997) Nr. 6, S. 15-17; 1997
- [47]Keller, H.; Kugele, E., Müller, B; Große Osterhues, B.; Albert, F.; Bloy, U.: Ein Fuzzy-System zur Ausbrandoptimierung in der termischen Abfallbehandlung. Grauel, A. (Hrsg.) Fuzzy-Neuro-Systeme '97- Computational Intelligence: Beiträge zum 4. Internat. Workshop, Soest, 12-14. März 1997, S. 277-282; 1997
- [48]Keller, H.; Müller, B.: Anwendungen neuronaler Netze im Umweltbereich. In: Grützner, R. (Hrsg.) Modellbildung und Simulation im Umweltbereich, S. 33-54 (Fortschritte in der Simulationstechnik).Wiesbaden (u.a.), Vieweg; 1997

- [49]Keller, H.; Müller, B.: Modellbildung und Simulation in der Müllverbrennung mit Neuronalen Netzen. Meß- und Automatisierungstechnik: Kongress, Baden-Baden, 10.-11. Sept. 1996, Düsseldorf, S. 669-74, (VDI-Berichte; 1282). VDI-Verlag; 1996
- [50]Keller, H.; Müller, B.; Paulsen, J., Weber, S.: Ein neuronales Werkzeug zur Entscheidungsunterstützung in der Feuerleistungsregelung einer Müllverbrennungsanlage. Engels, R. (Hrsg.), Beiträge zum 10. Fachgruppentreffen 'Maschinelles Lernen' der GI Fachgruppe 1.1.3, Karlsruhe, , August 1997, Karlsruhe: Universität Karlsruhe; 1997
- [51]Keller, H.B.; Jaeschke, A.; Kugele, E.; Grosse Osterhues, B.; Müller, B.: Innovative Prozeßleittechnik in der thermischen Abfallbehandlung. Nachrichten - Forschungszentrum Karlsruhe, 28 (1996) S.258-65; 1996
- [52]Keller, H.B.; Müller, B.; Kugele,E.; Fick, A.; Fuzzy Control und Neuronale Netze in der thermischen Abfallbehandlung. GMA Kongress '98; Meß - und Automatisierungstechnik, Ludwigsburg, 18.-19. Juni 1998, VDI- Berichte 1397, S.637-643; 1998
- [53]Kiendl, H.: Fuzzy Control methodenorientiert. Oldenbourg- Verlag, München; 1997
- [54]Kohonen T.; Kangras J.; Laaksonen J.; Torkkola K.: LVQ_PAK: A Program package for the correct application of Learning Vector Quantisation algorithms. IEEE Proc. Of the int. Joint Conference on Neural Networks pp725-730, Baltimore; 1992
- [55]Kohonen, T.: Self-organizing maps. Berlin Springer; 1997
- [56]Kramer, M.: Nonlinear Principal Component Analysis using Autoassociative Neural Networks. AIChE Journal Feb; 1991
- [57]Krause, B. Altrock, C. v. Limper, K. Schäfers, W.: Development of a Fuzzy Knowledge-Based System for the Control of a Refuse Incineration Plant. aus: FuzzyTECH Application paper, http://www.fuzzytech.com/e_a_mull.htm
- [58]Kugele E., Keller, H., Albert F.: Verbesserung der Prozeßführung von Müllverbrennungsanlagen. Primärbericht, Kernforschungszentrum Karlsruhe; 1993
- [59]Leary, T.: Neuropolitics. Los Angeles: Starseed/Peace Press, 1977

- [60]Leitch R.; Ravindranatham M.: Model Switching in intelligent Control Systems. Artificial Intelligence in Engineering 19 pp175-187, Elsevier; 1999
- [61]Lunze, J.: Regelungstechnik. Springer, Berlin, 1999
- [62]Martin, J.: Moderne Abfallverbrennung nach dem Martin System. aus "Zeitgemäße automatische Rostfeuerungsstechnik", VDI- Bildungswerk Düsseldorf, März 1991
- [63]Martinetz, T.: Selbstorganisierende neuronale Netzwerkmodelle zur Bewegungssteuerung. Dissertation zur Künstlichen Intelligenz, Sankt Augustin : Infix; 1992
- [64]Mikut, R.: Modellgestützte on-line Stabilitätsüberwachung komplexer Systeme auf der Basis unscharfer Ljapunov-Funktionen. Dissertation, Düsseldorf : VDI-Verl., 1999
- [65]Mikut, R.; König, S.; Dumitriu, B.; Garbe, J.: Erhöhung der Qualität moderner Stranggießanlagen durch den Einsatz moderner Fuzzy Technologie. Proc., GMA- Kongreß Meß- und Automatisierungstechnik '96 (VDI- Bericht 1282), S. 627-636;1996
- [66]Moeller, D.: Modellbildung, Simulation und Identifikation dynamischer Systeme. Berlin Springer; 1992
- [67]Müller, B.; Keller, H. B.: Einsatz von Computational Intelligence Methoden in der thermischen Abfallbehandlung. Workshop "Intelligente Systeme in Umwelthanwendungen". KI98, Bremen; 1998
- [68]Müller, B.; Keller, H. B.; Kugele, E.; Albert, F.; Bloy, U.; Fuzzy Control in Thermal Waste Treatment. EUFIT 98, Aachen. S. 1497-1501; 1998
- [69]Müller, B.; Keller, H. B.: Neural Networks for On Line Estimation of the Heating Value in Thermal Treatment of Waste. in "New Frontier in Computational Intelligence and its Applications", IOS Press, pp. 68-75; 1999
- [70]Müller, B.; Keller, H. B.: Neural Networks for On Line Estimation of the Heating Value in Thermal Treatment of Waste. CIMCA - International Conference on Computational Intelligence for Modelling, Control and Automation Wien, 17.2.-19.2.1999

- [71]Müller, B.; Keller, H.: Neural Networks for Combustion Process Modelling. Proc. of the Internat. Conf. On Engineering Applications of Neural Networks (EANN '96), London, GB, June 17-19, pp. 87 - 90; 1996
- [72]Müller, B.; Keller, H.B.: Clean Innovative Technology in Automatic Control. European Workshop on Environmental Technologies 1998, Darmstadt, pp. 156-166; 18. Juni 1998
- [73]Müller, B; Keller, H. B.: Neural Networks for Combustion Process Modelling. in "Solving Engineering Problems with Neural Networks", Proceedings of the Internat.Conf.on Engineering Applications of Neural Networks (EANN '96), London, GB, June 17-19, pp.87 – 90; 1996
- [74]Nahas, E.P., Henson M.A., Seborg D.E.: Nonlinear Internal Model Control Strategy for Neural Network Models. Comput. Chem. Eng 16; pp. 1039-1057; 1992
- [75]Narendra, K.; Parthasarathy, K.: Identification and Control of Dynamical Systems using Neural Networks, IEEE Transactions on Neural Networks, Vol.1; 1990
- [76]Narendra, K.; Parthasarathy, K.: Gradient Methods for the Optimisation of Dynamical Systems Containing Neural Networks. IEEE Transactions on Neural Networks. Vol 2.; 1991
- [77]Obertacke, R.: Ein emissionstomographisches Sensorsystem für die Bestimmung zweidimensionaler Temperatur- und Radikalfelder in Feuerungen" Berichte zur Energie- und Verfahrenstechnik : Schriftenreihe ; 95,1. Erlangen-Nürnberg, Univ., Diss.; 1995.
- [78]Obertacke, R.; Leipertz, A.; Spiegel, H.; Wintrich, F.: Regelung von Verbrennungsprozessen über die spektroskopische Erfassung von Temperatur und Schadstoffkonzentrationen. VDI- Berichte Nr. 10; 1993
- [79]Oja, E.: Beyond PCA: Statistical Expansions by Nonlinear Neural Networks. Proc. Of the ICANN 94; 1994
- [80]Oja, E.: Pricpal Components, Minor Components and Linear Neural Networks. Neural Networks. Vol.5; 1992
- [81]Ono, H.; Ohnishi, T.; Terada, Y: Combustion Control of Refuse incineration plant by Fuzzy Logic. Fuzzy Sets and Systems 32, p 193-206, North Holland; 1989

- [82]Pickhard, R.: Adaptive Regelung auf der Basis eines Multi-Modells bei einer Transportregelstrecke für Schüttgüter. Automatisierungstechnik 3'97. Oldenbourg Verlag; 1997
- [83]Press, W. H: Numerical Recipes in C : the art of scientific computing. Cambridge Univ. Press; 1997
- [84]Qin, S. J.; Badgwell, Th.: An Overview of Nonlinear Predictive Control Applications., Nonlinear MPC Workshop, Ascona, 2-6 June, Switzerland; 1998
- [85]Qin, S.; Martinez, V. M.: .An Interpolating Model Predictive Control Strategy with Application to a Waste Treatment Plant. Comp. and Chem. Eng.; Vol. 36, pp. 881-886; 1997
- [86]Rechenberg, I.: Evolutionsstrategie: Optimierung technischer Systeme nach den Prinzipien der biologischen Evolution. Frommann Holzboog, Stuttgart; 1993
- [87]Reimann, D.: Abfallentsorgung mit integrierter Abfallverbrennung- Verfahren von gestern und heute. aus: Rostfeuerungen zur Abfallverbrennung, EF- Verlag für Energie- und Umwelttechnik GmbH, Berlin; 1991
- [88]Reimann, D.: Zeitgemäße Restabfallverbrennung. Schriftenreihe Umweltschutz, Bamberg; 1993
- [89]Riedmiller M.: Learning to control Dynamic Systems. Proc. of the European Meeting on Cybernetics and Systems Research, Vienna; 1996
- [90]Riedmiller, M.; Braun, H.: A Direct Adaptive Method for Faster Backpropagation Learning: The RPROP Algorithm. Proc. of the IEEE International Conference on Neural Networks; 1993
- [91]Ritter, H.; Martinetz, T.; Schulten, K.: Neuronale Netze: eine Einführung in die Neuroinformatik selbstorganisierender Netzwerke. Addison-Wesley; 1991
- [92]Rojas, R.: Theorie der neuronalen Netze : eine systematische Einführung. - Berlin u.a. : Springer; 1993
- [93]Schmidhuber J.: Networks adjusting networks. In J. Kindermann and A. Linden, editors, Proceedings of 'Distributed Adaptive Neural Information Processing', St.Augustin, 24.-25.5. 1989, pages 197-208. Oldenbourg; 1990

- [94]Schwefel, H.P.: Evolutionsstrategie und numerische Optimierung. Dissertation, TU Berlin; 1975
- [95]Schweitzer, F. J.: Thermoselect- Verfahren zur Ent- und Vergasung von Abfällen., EF-Verlag für Energie und Umwelttechnik GmbH, Berlin; 1994
- [96]Sedgewick, R.: Algorithmen. Addison-Wesley; 1992
- [97]Speckmann H.; Raddatz G.; Rosenstiel W.: Relations between generalized fractal dimensions and Kohonen's self-organizing map. Neural Networks and their Applications, Marseilles, 15-16 December; 1994
- [98]Thesauro, G.: Practical Issues in Temporal Difference Learning. Machine Learning 8, Kluwer Academic Publishers, pp. 257-277; 1992
- [99]Thome-Kozmiensky: Thermische Abfallbehandlung. EF-Verlag für Energie und Umwelttechnik GmbH, Berlin; 1994
- [100]Tolle, H. Ersü, E.: Neurocontrol. Lecture Notes in Control and Information Science 172, Springer Verlag; 1992
- [101]Tsitsiklis, J.: An Analysis of Temporal Difference Learning with Function Approximation. IEEE Transactions on automatic Control, Vol 42, pp. 674-689; 1997
- [102]VDI-Berichte 1526: Computational Intelligence im industriellen Einsatz. VDI-Verlag; Baden Baden, 2000
- [103]Villmann, T.: Estimation of Topography in Self Organizing Maps and Data Driven Growing of suitable Network Structures. Proc of the EUFIT pp. 235-244 Aachen; 1998
- [104]Warnatz, J. Dibble, U. R. W.: Verbrennung : physikalisch-chemische Grundlagen, Modellierung und Simulation, Experimente, Schadstoffentstehung . Berlin u.a., Springer Verlag; 1997
- [105]Warnatz, J.; Mass, U.: Technische Verbrennung: physikalisch-chemische Grundlagen, Modellbildung, Schadstoffentstehung. Berlin u.a. : Springer Verlag; 1993
- [106]Wernstedt, J.: Experimentelle Prozeßanalyse. Verlag Technik, Berlin; 1989

- [107]Winston, P. H.: Artificial intelligence. Addison-Wesley; 1984
- [108]Wintrich, F. Mindermann K.: Einsatz von Pyrodetektoren als Steuerungshilfen für Feuerungsanlagen am Beispiel des MHKW Essen Karnap. aus „Rostfeuerungen zur Abfallverbrennung., EF- Verlag für Energie und Umwelttechnik GmbH, Berlin; 1991
- [109]Zadeh, L.A.: Fuzzy sets, fuzzy logic, and fuzzy systems. World Scientific Publ. Co., 1996
- [110]Zell, A.: SNNS - Stuttgart Neural Network Simulator: user manual, version 4.0. University of Stuttgart. Institut for Parallel and Distributed High Performance Systems (IPVR). – Stuttgart; 1995

8 Anhang

8.1 Parameterbeschreibung Anlage 1

- 1) Gesamtluftmenge in [m³/h]. Berechnete Summe aller Luftzuführungen zur Verbrennungskammer (Primär- Sekundär, und Kühlluft).
- 2) Rauchgastemperatur hinter dem Boiler in [C]: Dieser Wert wird an einer Meßstelle kurz vor Eintritt in die Rauchgasreinigung gemessen.
- 3) CO- Konzentration des Rauchgases nach dem Boiler [mg/m³]: Dieser Wert wird an einer Meßstelle kurz vor Eintritt in die Rauchgasreinigung gemessen.
- 4) O₂ Gehalt des Rauchgases nach dem Boiler.[%]: Dieser Wert wird an einer Meßstelle kurz vor Eintritt in die Rauchgasreinigung gemessen.
- 5) Korrekturwerte des Heizwerts [keine Maßangabe]: Dieser Wert wird vom Anlagenfahrer aufgrund seiner Heizwertschätzung manuell eingegeben.
- 6) Dampfmenge [Mg/h]: Die Gesamtmenge an produziertem Dampf.
- 7) Dampfsollwert [Mg/h]: Dieser Wert ist abhängig von Parameter 5
- 8) Primärluftmenge [m³/h]
- 9) Temperatur der Primärluft nach Vorwärmung. [C]
- 10) Position der Luftklappe für Verbrennungszone 1 in [%]: Dieser und die nächsten 3 Werte beschreiben die Primärluftverteilung unter dem Rost.
- 11) Position der Luftklappe für Verbrennungszone 2 in [%]
- 12) Position der Luftklappe für Verbrennungszone 3 in [%]
- 13) Position der Luftklappe für Verbrennungszone 4 in [%]
- 14) Rauchgasmenge [Nm³/h]: Dieser Wert wird nach dem Boiler gemessen.
- 15) Rauchgastemperatur nach dem Wäscher in der Rauchgasreinigung. [C]
- 16) Rauchgastemperatur 1 am Ausgang der zweiten Verbrennungskammer in [C]
- 17) Rauchgastemperatur 2. Durchschnittswert zweier Thermoelemente[C].
- 18) Rauchgastemperatur gemessen an der Nackenseite Hauptverbrennungszone in [C]
- 19) Rauchgastemperatur gemessen an der Stirnseite Hauptverbrennungszone in [C].
- 20) Rostgeschwindigkeit in [%]
- 21) Rosttemperatur rechts [C], gemessen mit Thermoelementen.
- 22) Rosttemperatur links [C]
- 23) Sekundärluftmenge in [Nm³/h]:

- 24) Müllaufgabe in [%]
- 25) Gasmenge des Gasbrenners. [Nm³/h]: Dieser wird eingesetzt, wenn die Verbrennungstemperatur unter 850°C fällt.
- 26) Position der Hauptluftklappe in [%]
- 27) Druck in der Hauptverbrennungskammer in [mbar]
- 28) Rauchgasdruck nach dem Boiler in [mbar]

8.2 Parameterbeschreibung Anlage 2

- 1) Luft_gesamt[TM³/H] Summe aus Primär- Sekundär und Kühlluft.
- 2) Sekundaerluft_gesamt[TM³/H] wird konstant der Nachbrennkammer [vorne und hinten] zugeführt.
- 3) F_GAS_LASTBRENNER[m³/H]. Gasmenge. Fällt die Feuerraumtemperatur unter 800°C, so wird der Gasbrenner entzündet.
- 4) F_Speisewasser[T/H] Menge an nachgeliefertem Speisewasser zur Dampferzeugung
- 5) T_Speisewasser[C] Temperatur des nachgeliefertem Speisewasser.
- 6) P_Frischdampf_P2[Bar] Druck vom Frischdampf
- 7) T_Frischdampf_T2[C] Temperatur Frischdampf
- 8) F_Frischdampf[T/H] Die erzeugte Frischdampfmenge
- 9) T_Feuerraum_2V3[C] Mittelwert aus 2 Meßstellen
- 10) T_Frilu_Hi_DaLuvo[C] Die Temperatur der Frischluft, nachdem ein Wärmetausch mit dem Rauchgas durchgeführt wurde.
- 11) CO-Messstelle[Norm.mg/m³] CO Gehalt des Rauchgases
- 12) F_Luft_Aufgaberost_Li[TM³/H] Luftzufuhren der Roste
- 13) F_Luft_Aufgaberost_Re[TM³/H]
- 14) F_Luft_VRost_Feld51[TM³/H]
- 15) F_Luft_VRost_Feld52[TM³/H]
- 16) F_Luft_VRost_Feld61[TM³/H]
- 17) F_Luft_VRost_Feld62[TM³/H]
- 18) F_Luft_VRost_Feld71[TM³/H]
- 19) F_Luft_VRost_Feld72[TM³/H]
- 20) F_Luft_VRost_Feld81[TM³/H]
- 21) F_Luft_VRost_Feld82[TM³/H]
- 22) T_Luft_vor_Rost_Re[CEL] Primärlufttemperatur

- 23) Drehzahl_Aufgaberost[m/h] Rostgeschwindigkeiten
- 24) Geschw_Feld_51[mm/min]
- 25) Geschw_Feld_52[mm/min]
- 26) Geschw_Feld_61[mm/min]
- 27) Geschw_Feld_62[mm/min]
- 28) Geschw_Feld_71[mm/min]
- 29) Geschw_Feld_72[mm/min]
- 30) Geschw_Feld_81[mm/min]
- 31) Geschw_Feld_82[mm/min]
- 32) O2_RG_2von3[%] Sauerstoffgehalt der Rauchgases, gemittelt
- 33) Hub_feld_51[mm] Stellung des Verbrennungsrostes
- 34) Hub_feld_52[mm]
- 35) Hub_feld_61[mm]
- 36) Hub_feld_62[mm]
- 37) Hub_feld_71[mm]
- 38) Hub_feld_72[mm]
- 39) Hub_feld_81[mm]
- 40) Hub_feld_82[mm]
- 41) Sollwert_Dampfmenge[T/H]
- 42) Sollwert_O2[%]

8.3 Modellbildung der Anlage 2

Hier werden die Auswertungen gemäß Kapitel 3 für die Anlage 2 ausgeführt.

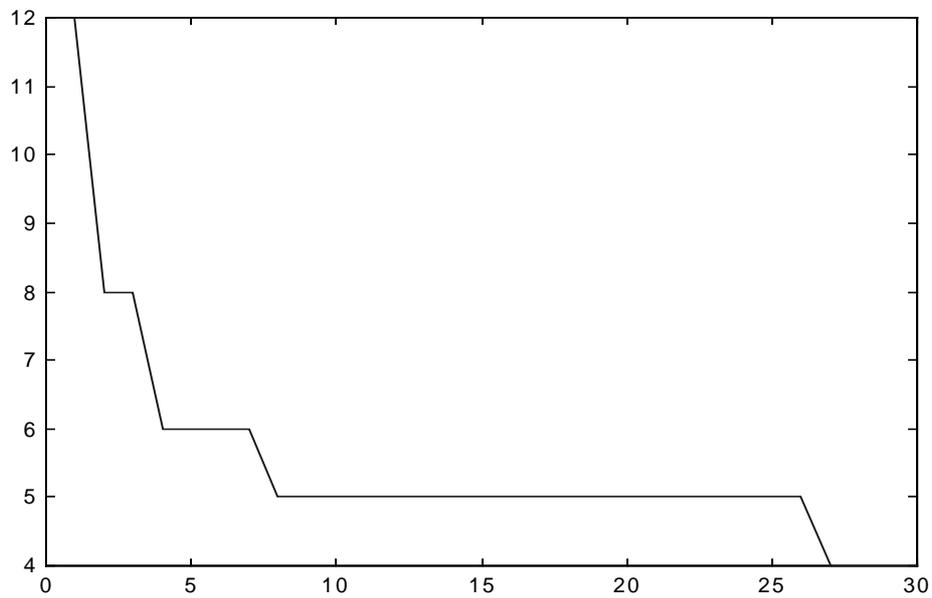


Abbildung 8.1: Kreuzkorrelationen der Meßdaten von Anlage 2 im Zeitraum von 30 Minuten

Lineare Systemmatrizen der Anlage 2

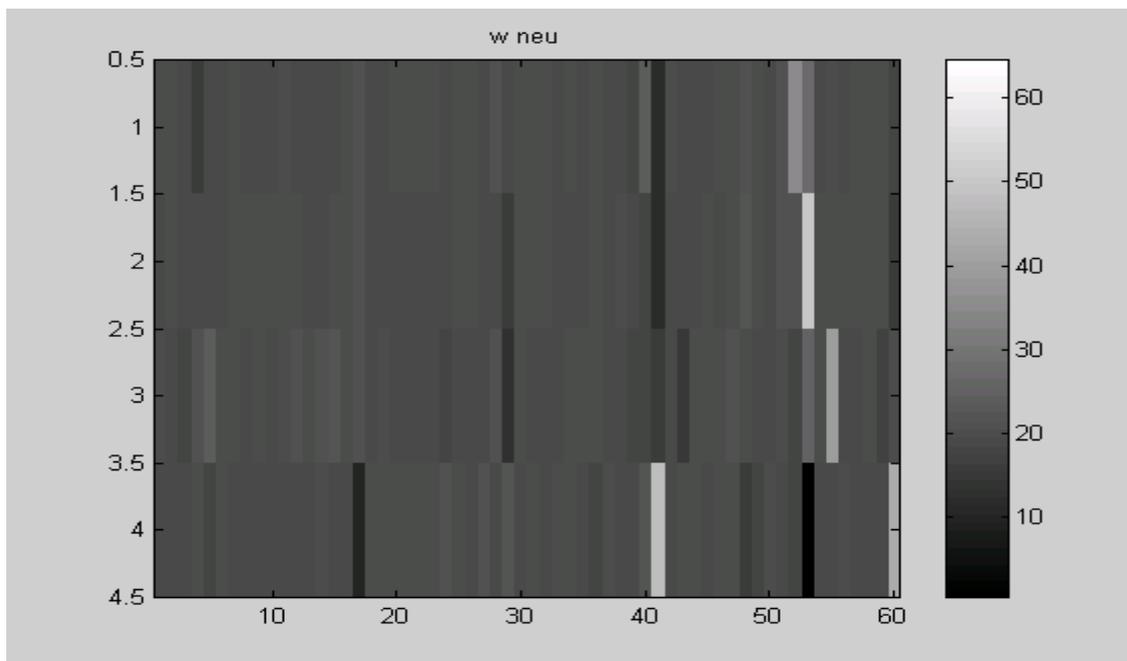


Abbildung 8.2: Systemmatrix von Datensatz 1

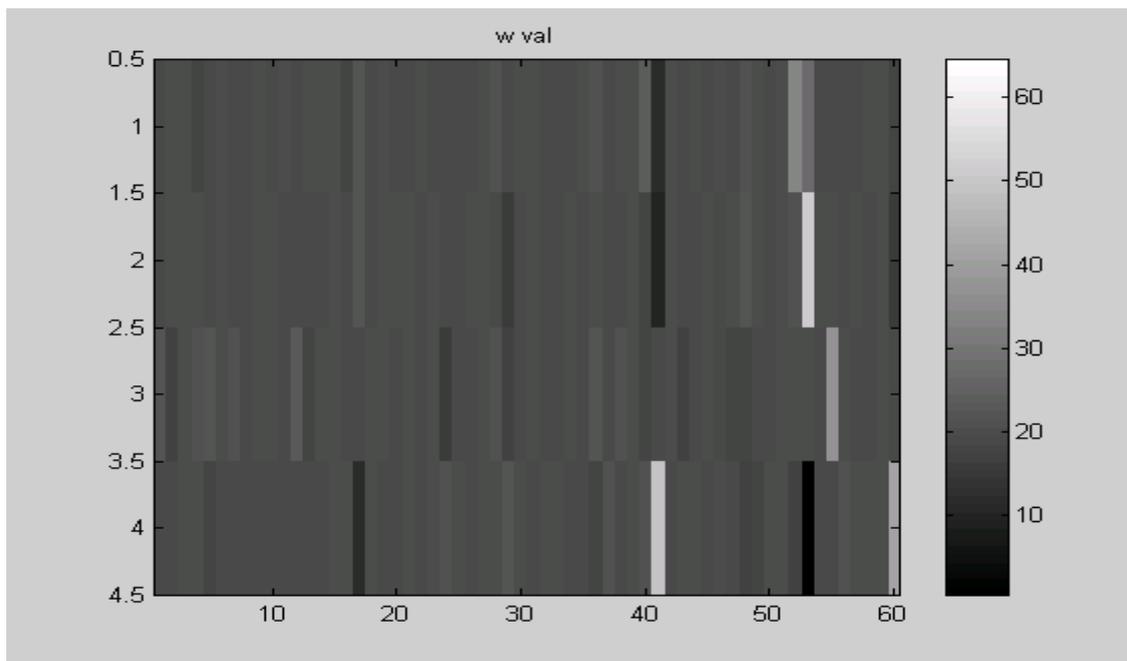


Abbildung 8.3: Systemmatrix von Datensatz 2

Differenz der beiden Matrizen



Abbildung 8.4: Differenz der Systemmatrizen

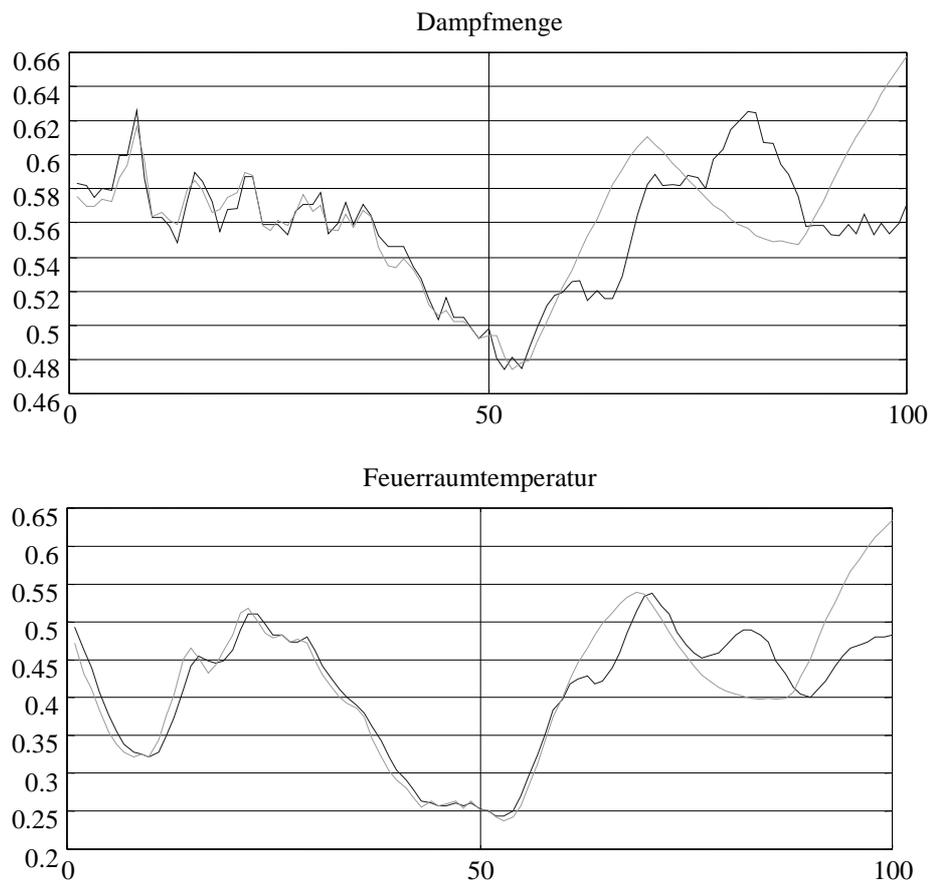
MSE in Abhängigkeit der Ordnung der Abbildung:

Ordnung von A	Training Set	Validierungs Set
5	0.00313	0.00354
4	0.00318	0.00362
3	0.00326	0.00359
2	0.00340	0.00369
1	0.00400	0.00549

Tabelle 8.1: MSE des linearen Modells aus den Meßdaten der Anlage 2

8.4 Simulationen der Anlage 2

Simulation der Zustandsgrößen auf Validierungsdaten. Ab Zeitschritt $t=50$ wird vom Serien-Parallelmodell zum reinen Parallelmodell gewechselt.



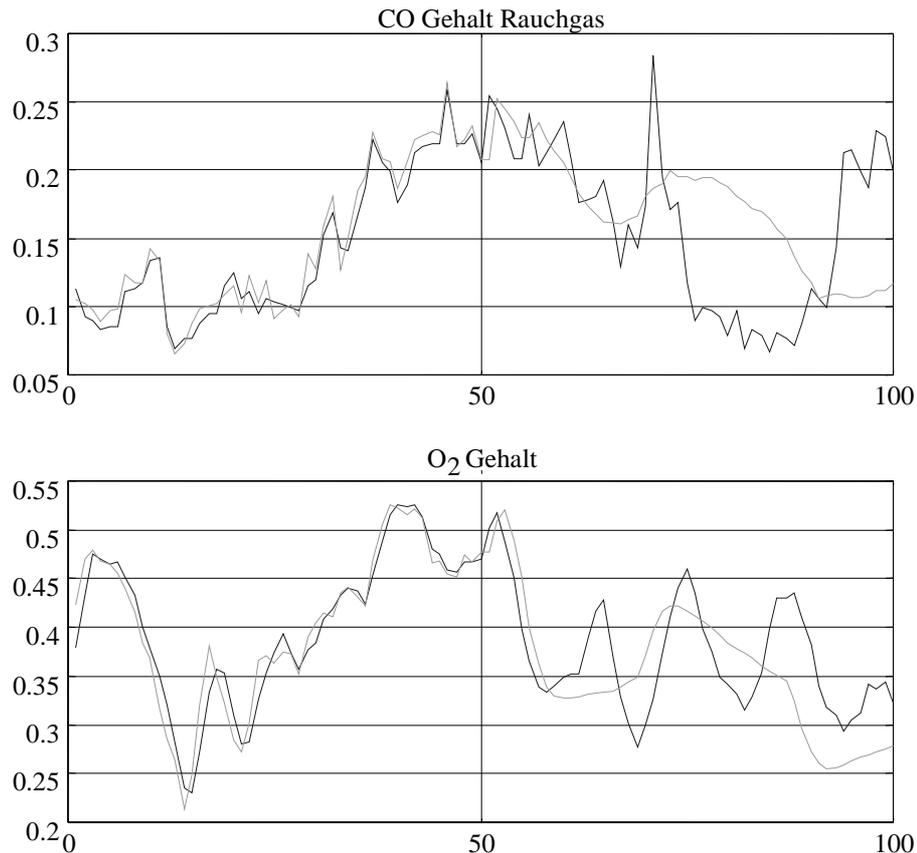


Abbildung 8.5: Simulation der Zustandsgrößen der Anlage 2

8.5 Einschränkungen der Anlagenfahrweise bei Anlage 1

Abhängigkeiten der Parameter der Luftzufuhr:

Die Funktionsweise der drei Luftklappen ist starr miteinander verkoppelt, d.h. aus dem Wert einer Luftklappe können die anderen hergeleitet werden.

Die Primärluftmenge wird durch die Hauptluftklappe gesteuert, welche durch den Dampfsollwert bestimmt wird.

Abhängigkeiten zwischen Müllmenge und Rostgeschwindigkeit:

Die Müllaufgabemenge wird durch die Dosierung der Luftzufuhr, Dampfsollmenge und Rostgeschwindigkeit eindeutig festgelegt.

Da diese Abhängigkeiten während des gesamten Prozeßverlaufs gelten, ist es möglich, die Stellgrößen für das Modell auf die Hauptluftklappe³ und die Rostgeschwindigkeit unter Vorgabe der Dampfsollmenge zu reduzieren. Alle anderen Stellgrößen können aus diesen hergeleitet werden.

Diese Abhängigkeiten gelten im gesamten Prozeßverlauf, und werden für die modelprädiktive Regelung beibehalten. Eine Verbesserung der bestehenden Regelung durch Variierung der gekoppelten Stellgrößen ist nicht Thema dieses Kapitels.

Daher wird im folgenden die Ermittlung der Stellgrößen Luftzufuhr und Rostgeschwindigkeit beschrieben, und die anderen Stellgrößen hieraus errechnet. Zunächst wird die statische Stellgrößenberechnung beschrieben.

8.6 Open Loop Steuerung der Anlage 1

Während einer Meßkampagne an Anlage 1 wurde das Regelungsmodul mit einer Benutzerschnittstelle [hergestellt von RISØ, Dänemark] und mit dem Prozeßleitsystem verbunden. Abbildung 8.6 und Abbildung 8.7 zeigen die von dem Prozeßleitsystem innerhalb eines Zeitraums von ca. 2,5 Stunden [10.55-14.20] ermittelten Stellgrößen. Die Linien sind diskontinuierlich, da die Messung dreimal kurz unterbrochen wurde.

Abbildung 8.6 zeigt die Position der Luftklappen und Abbildung 8.7 die Rostgeschwindigkeit und die Abfallmenge auf dem Aufgaberost in % des realen Prozesses. Es ist ersichtlich, daß der Rost zweimal vom Operateur gesteuert wurde. Grund dafür war die Tatsache, daß der Abfall über sehr schlechte Verbrennungseigenschaften verfügte und daher noch etwas länger auf dem Rost bleiben mußte. Um 11.25 Uhr trat die Situation ein, daß das Prozeßleitsystem nicht in der Lage war, den Abfall auf dem Rost ordnungsgemäß zu verbrennen. Dies wurde vom Operateur registriert, und die manuelle Regelung wurde eingeschaltet. Zunächst wurde die Geschwindigkeit des Rostantriebs erhöht, um den Abfall aufzuwirbeln. Danach wurde die Rostbewegung ganz unterbunden, um dem Abfall Zeit zum Ausbrennen zu geben.

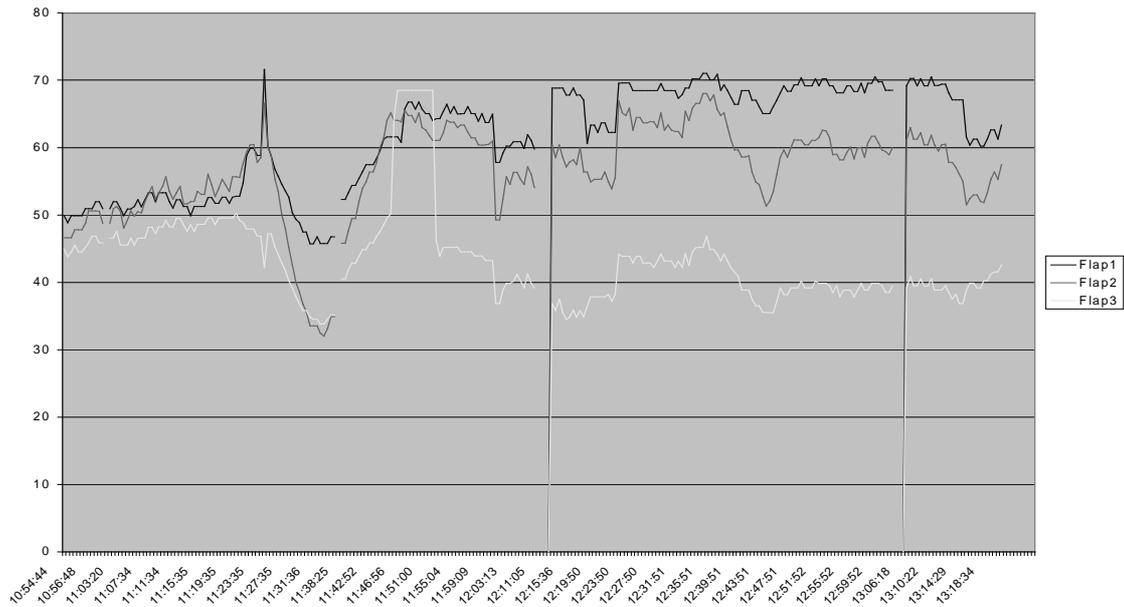


Abbildung 8.6: Das Öffnen der Luftklappen durch das Prozeßleitsystem [in %].

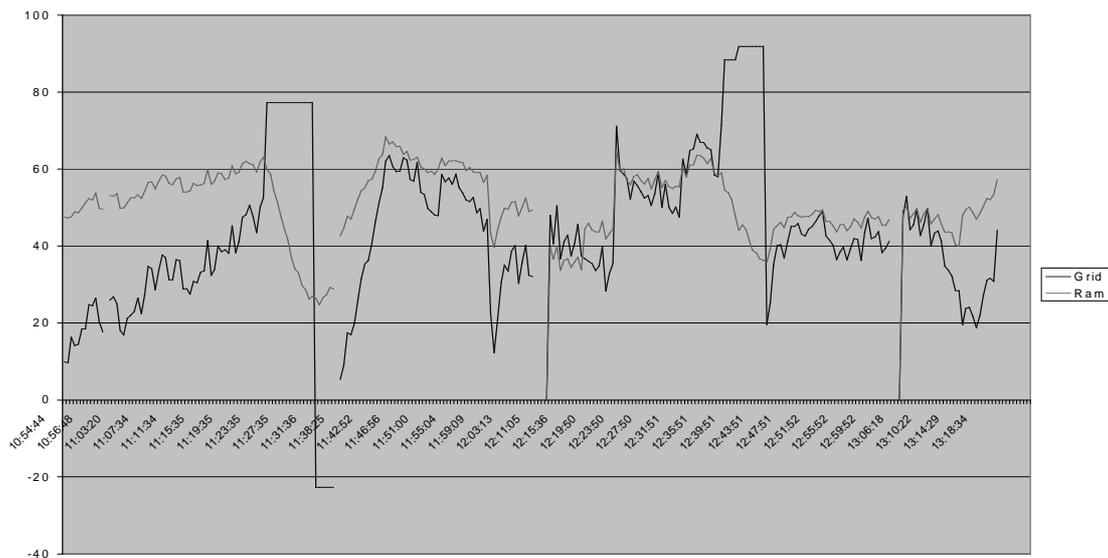


Abbildung 8.7: Antrieb des Aufgaberosts und des Verbrennungsrosts durch das Prozeßleitsystem.

Abbildung 8.8 und Abbildung 8.9 zeigen die von KNN-basierten Regler errechneten Vorschläge. Der Regler produziert eine parallele Anregung der Rostgeschwindigkeit und des Aufgaberosts gemäß der Vorgabe durch die bestehende Fahrweise. Damit wird die Schichtstärke auf dem Rost unabhängig von der Rostgeschwindigkeit konstant gehalten. Die Luftzufuhr ent-

spricht nahezu den Werten des Prozeßleitsystems. Klappe 4 wird von der prädiktiven Regelung nicht verwendet, da diese im realen Prozeß bei nicht ausgebrannten Müll vom Operateurs manuell bedient wird.

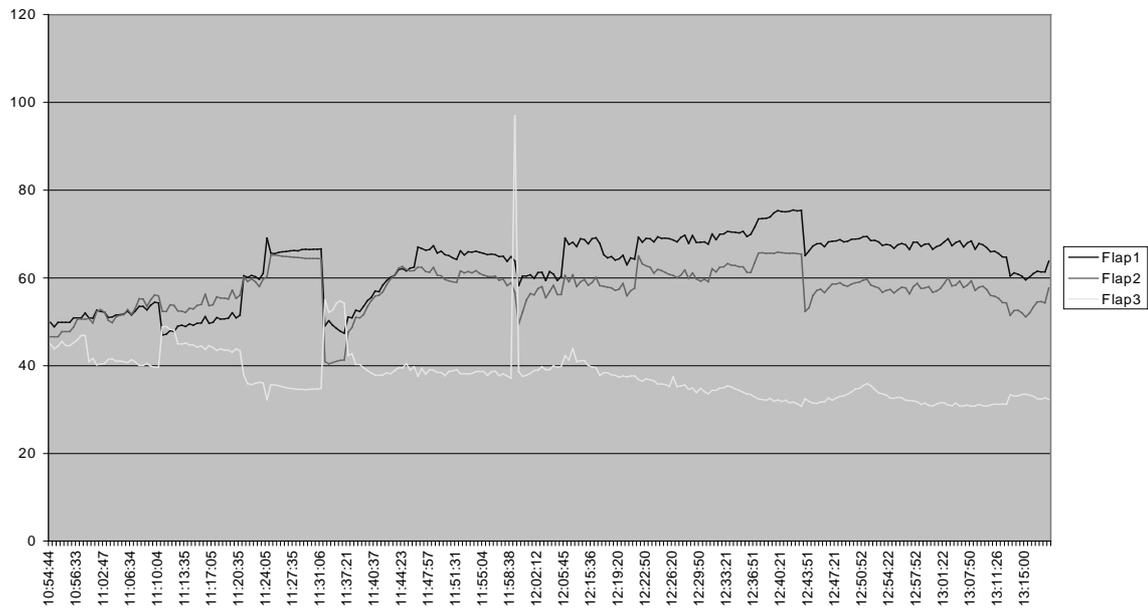


Abbildung 8.8: Luftklappen, errechnet von der prädiktiven Regelung

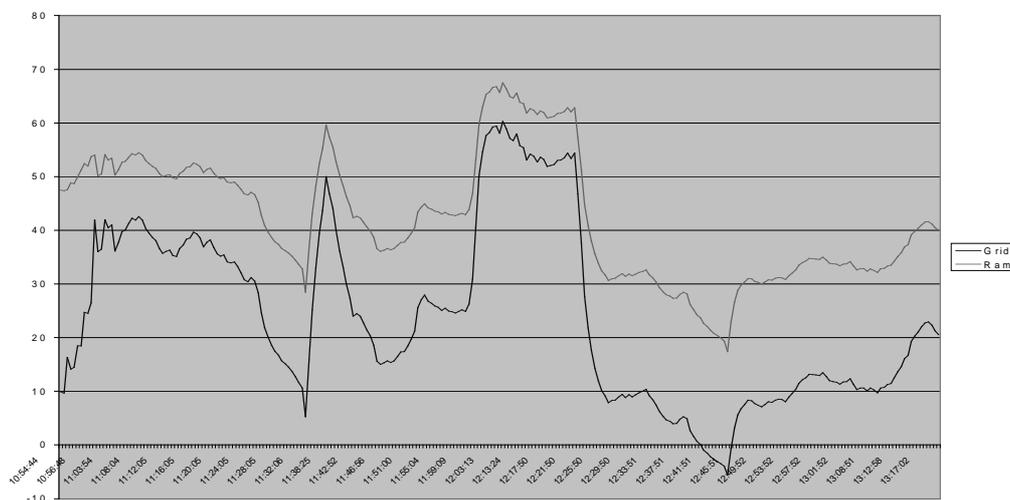


Abbildung 8.9: Die Antriebe von Aufgabe- und Verbrennungsrost, errechnet von der prädiktiven Regelung

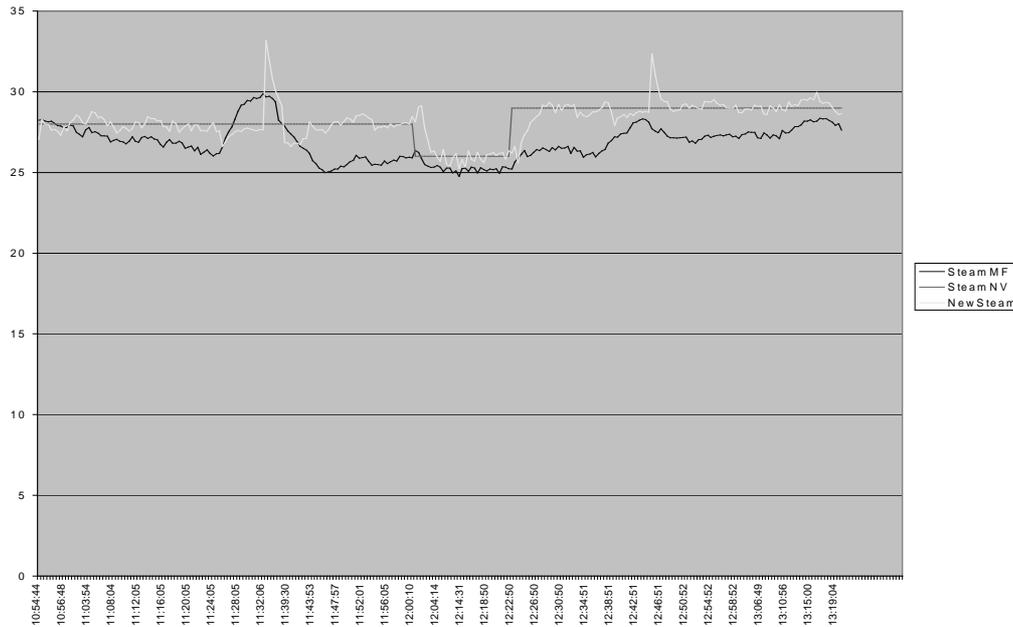


Abbildung 8.10: Dampfmenge; realer Wert des Prozeßleitsystems [Verwendung der realen Stellgrößen], mittels Simulation abgeleiteter Wert [unter Verwendung der errechneten Stellgrößen] und Dampfsollwert.

Abbildung 8.10 zeigt die während des Prozesses gemessenen aktuelle Dampfmenge sowie den vom Simulator unter dem Einfluß der Stellgrößen vom KNN-basierten Regler abgeleitete Dampfmenge. Die mittels Simulation bestimmte Dampfmenge erreicht den Sollwert besser als die des gegenwärtig verwendeten Prozeßleitsystems. Allerdings ist für die Anlage 1 eine Vertrauensindex nicht implementiert, so daß keine Aussagen über die Modellgültigkeit gemacht werden können.

9 Index

- A* Baumsuche 98
- Absorption 118
- Aufgaberost 15
- Aufgabestößel 15

- Boudouard-Reaktion 22
- Branch and Bound Suche 97

- Counterpropagation Netz 132
- C-Verbrennung 22

- Dampferzeugung 19

- Emissivität 118
- Entzündbarkeit 114
- Explizite Suche 85

- Feedforward-Netze 49
- Festlastregelung 6
- Feuerraum 17
- Fuzzy-Controller 31
- Fuzzy-Regelung 10

- Gegenstromverbrennung 17
- Gleichstromverbrennung 17
- Gradientenabstiegsverfahren 52
- Grauer Körper 118
- Gütefunktion 94

- Hauptkomponentenanalyse 37
- Hauptkomponentenregression 69
- heterogene Wassergas Reaktion 22
- Heterogenität des Mülls 113

- hidden layer 49
- hidden neurons 49

- Infrarot Sensor Array 119
- Infrarotspektroskopie 113
- INSPECT-System 109
- Internal Model Control 79
- inverses Pendel 87

- Kaskadenregelung 79
- Kohonennetz 64
- Kreuzkorrelationsfunktion 42

- Learning Vector Quantification 70
- lineare Modelle 43

- Martin System 9
- Massenumsatzrate 26, 128
- Mean Square Error 44
- Meßlanze 119
- Mittelstromfeuerung 17
- Modellordnung 44
- Müllbunker 15
- Müllkessel 13

- nichtlineare Modellierung 48
- NO-Bildung aus Brennstoff 30
- Noell-Konversionsverfahren 5

- Paralleles Identifikationsmodell 71
- perspektivische Verzerrung 121
- Plancksches Gesetz 116
- primäre Maßnahmen 3
- Prompte NO Bildung 29

- Pseudoinverse 39
- Pyrodetektoren 9

- Radiale Basisfunktionen 50
- Rauchgas 13
- Rauchgasreinigung 18
- RBF-Netze 134
- Referenzmodell 96
- rekursiver Abstieg 97
- Resilient Backpropagation 53
- Rückschubrost 16

- Schürwirkung 16
- schwarzer Körper 116
- Sekundärmaßnahmen* 4
- Selbstorganisierende Karten 50
- Serien-Parallelmodell 72
- Simulationsergebnisse 73
- SOFM *Siehe* Selbstorganisierende Karten
- Speisewasserversorgung 20
- Standard Backpropagation 54
- Statische Stellgrößengewinnung 81
- Stefan-Boltzmann Gesetz 118
- Suchstrategie 97
- Syncom-Verfahren 5

- Thermische NO-Bildung 29
- Trainingsdaten 70
- Trainingsphase 58
- Trocknungsgeschwindigkeit 21
- Trocknungsphase 21
- TVS 100 119

- Untermannigfaltigkeit 64

- Validierungsdaten 58, 70
- Validierungsfehler 58
- Variablenpool 109
- Verbrennungsluftregelung 6
- Verbrennungsrost 15
- Verbrennungszone 17
- Vertrauensindex 94
- Vorschubrost 16

- Walzenrost 16
- Wärmestrahlung 116

- Zündrate 25, 128
- Zündung 21