

Schwachstellen der Feuerleistungsregelung mit neuronalen Netzen

Christian Gierend, Uwe Schneider und Sebastian Georg

1.	Motiv zum empirischen KNN-Modell.....	254
2.	Zielstellungen und frühere Lösungsansätze	255
3.	Schwachstellen Neuronaler Netze.....	258
4.	Ausblick und Zusammenfassung	264
5.	Literaturverzeichnis	266

Die thermische Behandlung von Abfällen basiert auf der Verbrennung von Abfällen. Sie ist eine Weiterentwicklung der primär der Abfallbeseitigung dienenden Abfallverbrennung der letzten Jahrzehnte aufgrund einer geänderten Aufgabenstellung [1]. Die Verbrennung mittels Rostfeuerung hat sich über viele Jahrzehnte als ein Verfahren zur thermischen Behandlung von Hausmüll und hausmüllähnlichem Gewerbemüll bewährt. Neben der sicheren Entsorgung stehen der emissionsarme Anlagenbetrieb, die energetische Verwertung und eine weitgehend stoffliche Nutzung der Reststoffe im Vordergrund.

Somit kommt in Zeiten fortschreitender abfallwirtschaftlicher Maßnahmen dem umweltschonenden Energierecycling von Abfällen eine zunehmende Bedeutung zu. Von großer Relevanz sind dabei die Optimierung des Verbrennungsvorganges (gleichmäßige Wärmefreisetzung und ungestörte Verbrennungsabläufe, stabile Feuerlage, Feuerlänge und Feuerintensität) und die damit verbundene Verbesserung des Ausbrandes, der Abgaszusammensetzung und der festen Verbrennungsrückstände. Wichtige Voraussetzung für minimale Emissionen ist die Feuerungsregelung, die Unregelmäßigkeiten beim Verbrennungsvorgang ausregeln kann. Dies geschieht dann, wenn sichere Informationen zu Feuerlage, Feuerlänge und Feuerintensität vorhanden sind und diese Informationen auch in die Feuerleistungsregelung Einfluss finden oder deren Relevanz bei Handeingriffen zum Tragen kommt. Eine optimale Feuerleistungsregelung basiert auf ihrem mathematischen Modell und deren Validierung. Aktuelle wirtschaftliche, rechtliche und ökologische Rahmenbedingungen erfordern eine ständige Weiterentwicklung und Optimierung der Prozessregelung und der innovativen Feuerleistungsregelungen. Um im derzeitigen Wettbewerbsumfeld bestehen zu können, sind unter anderem eine gleichbleibend hohe bzw. eine ständig verbesserte Qualität der Regelung des Feststoff- und Gasausbrandes erforderlich. Auf der Basis eines hinreichend genauen Anlagenmodells können optimale Betriebspunkte sowie verbesserte Anlagenfahrweisen berechnet werden. Zur Entwicklung eines entsprechenden Modells können prinzipiell zwei Wege eingeschlagen werden:

- Rigoroses Modell auf der Basis physikalischer, chemischer bzw. verfahrenstechnischer Beziehungen (bspw. Fuzzy Control).

- Empirisches Modell (z.B. Regressionsansatz, neuronales Netz) unter Verwendung von Messdaten.

Beide Methoden weisen Vor- und Nachteile auf. Die Entwicklung eines rigorosen Modells führt in der Regel zu einem tieferen Anlagenverständnis. Darüber hinaus besteht bei einem rigorosen Modell gegebenenfalls die Möglichkeit zur Extrapolation der Erkenntnisse auf neu zu errichtende Anlagen [2].

Diesen Vorteilen steht jedoch eine Reihe von Nachteilen gegenüber. So sind für viele interessante, aber auch kritische Anlagenzustände entsprechende physikalische Beziehungen online überhaupt nicht verfügbar und/oder gar nicht vollends bekannt. Dies ist der Inhomogenität des Brennstoffs Abfall geschuldet und trifft insbesondere für (makroskopische) Qualitätsgrößen zu, wie zum Beispiel: Dampfleinbrüche, optische Flammenbild-Eigenschaften, Anbackungsneigungen und Wächtenbildung im Feuer-raum, Heißgasstrahlenbildung, Kohlenmonoxid-Spitzen und viele mehr. Weiterhin liegt die mit rigorosen Modellen erreichbare Modellierungsgenauigkeit in der Regel deutlich unter der Genauigkeit empirischer Modelle, sofern der Brennstoff in seinen elementaren Zusammensetzungen und dem Entgasungs- und Verbrennungsverhalten bekannt wäre. Eine präzise Formulierung der Qualitätsgrößen eines Prozesses auf der Basis sämtlicher Einflussfaktoren (einige Dutzend bis mehrere Hundert) mit physikalischen Beziehungen erreichen zu wollen, erscheint aussichtslos. Eine Verbesserung der Betriebspunkte einer Anlage in der Größenordnung von einigen Prozent (alle darüber hinausgehenden Versprechungen sind eher unrealistisch), setzt ja eine Modellgenauigkeit voraus, die mindestens in dieser Größenordnung liegt. Ein weiterer wesentlicher Vorteil der Verwendung empirischer Modelle ist der relativ geringe Modellierungsaufwand. Ausgehend von Messdaten, die bei modernen Anlagen ohnehin anfallen, kann die Modellierung durch eine geeignete Software (Künstlich Neuronale Netztechniken KNN) mehr oder weniger automatisch durchgeführt werden. Der Modellierungsaufwand liegt in der Größenordnung von einigen Manntagen. Als Standardverfahren zur Modellierung auch nichtlinearer Zusammenhänge haben sich neuronale Netze etabliert. Im Folgenden werden zunächst das Motiv, das Ziel und die Methodik zur Entwicklung empirischer Modelle vorgestellt.

1. Motiv zum empirischen KNN-Modell

Die erfolgreiche Applikation innovativer Technologien in einfachen Regelkreisen, insbesondere die Anwendung von Künstlich Neuronalen Netz-Systemen, weckte in der letzten Zeit die Hoffnung, solche Technologien ohne weiteres für Systemlösungen auf komplexe Prozesse mit direkter Feuerleistungsregelung übertragen zu können. Technische und wirtschaftliche Grenzen bei Mehrgrößenproblemen in der Kraftwerkstechnik, speziell in der Feuerungstechnik und in wärmetechnischen Prozessen mit Feuerlage, Feuerlänge, Feuerintensität, ebenso Wärmestrahlung von unverbrannten Gasen, fordern noch effektiver anlagenspezifische Kenntnisse aus den verfahrenstechnisch nachvollziehbaren Reaktionsabläufen der Feuerung in optimierte Regelungsmodelle einzubringen.

Diese Umstände und die ständig kritische Diskussion der Abfallverbrennung in der Öffentlichkeit zwingen die Betreiber zu noch deutlicheren Verbesserungen. Gerade weil von den Abfallverbrennungsanlagen sich viele dem Druck ausgesetzt sehen, dass nicht objektiv über ihre Arbeit in öffentlichen und privaten Medien berichtet wird, entsteht hier mitunter ein neuer Markt für innovative Technik zur Optimierung von komplizierten Verbrennungsprozessen.

Die Verbesserung jeglicher Regelungen in thermischen Abfallbehandlungsanlagen stellt hinsichtlich einer Minimierung der Betriebskosten und der sich ständig verschärfenden gesetzlichen Emissionsgrenzwerte eine wichtige Aufgabenstellung dar, für Forschung und Wissenschaft, als auch primär für den Anlagenbau. Aus diesem Grund werden gerade von Anlagenbetreibern immer deutlichere Forderungen an die Industrie lauter. Worüber sich aber alle, die heute Forderungen an eine innovative und intelligente Feuerleistungsregelung stellen, einig sind, ist der Umstand, dass folgende Anforderungen erfüllt sein sollten:

- Die Regelung der Prozesse ist so komplex, dass auch die Insider des Automatisierungsgeschäfts dazu ausschließlich so genannte *Multivariable Kennfeldregler* empfehlen und fordern.
- Lernfähige und vorausschauende Softwaretools zur Unterstützung der wissensbasierten Regelungen sollen folgen. Das heißt, dass sich die Anlagen mit ihrem eigenen Wissensspektrum optimieren wollen und somit eine noch stärkere Unabhängigkeit gegenüber externer Service-Leistung aufbauen möchten (Eigenständigkeit ist angesagt, keine Black-Box-Systeme)
- Immer ein Auge am Feuer (Glas-, Stahl- und Kraftwerksindustrie steht im Vordergrund). Diese Forderung geht nur mit verbesserter Flammenbeobachtung, mittels Kamertechnik und Auswertesoftware.
- Einfache und schnelle Kopplung via OPC mittels TCP/IP-Protokolle, usw.
- Verständliche Regelanweisungen, womöglich rein mit Sprachbefehlen, vom Verfahrenstechniker für den Verfahrenstechniker oder vom Betriebsmann für den Betriebsmann. Ein Produkt, das in der Lage ist mit Sprache komplexe und mehrgrößenbehaftete Regelungsaufgaben zu übernehmen, womöglich verbal vorhandenes Wissen direkt in eine maschinenlesbare Schreibweise zu transferieren.

Dem gegenüber steht das Versprechen von einigen wenigen Industrievertretern, dies alles nur anhand von empirischer Modellgenerierung mittels künstlich neuronaler Netztechnologie zu bewältigen und auch zu beherrschen.

2. Zielstellungen und frühere Lösungsansätze

In den Problemstellungen, in denen Systemwissen nur in Form von Daten vorliegt, verspricht die Technologie Künstlich Neuronaler Netze (KNN) eine Lösung. Mit Hilfe Künstlich Neuronaler Netze (KNN) kann das Systemverhalten automatisch aus den vorliegenden Daten erlernt werden. Es gibt jedoch nur sehr wenige kommerzielle

Anwendungen von Künstlich Neuronale Netzen (KNN) zur Regelung, wobei prädikative Modelle und Fuzzy Control dagegen als Entwicklungstechnik in Asien und Europa als Regelung beispielsweise sehr verbreitet sind. Der zögernde Einsatz und einige Bruchlandungen Künstlich Neuronaler Netze (speziell auch in der Automobilindustrie) haben vielerlei Gründe.

- Zunächst sind die Lösungen, die durch Neuronale Netze gefunden wurden und werden, nicht transparent. Sie besitzen den Charakter einer *Black Box*. Der Benutzer kann weder spezifizieren, was ein spezielles Verhalten auslöst, noch kann er das Künstlich Neuronale Netz (KNN) manuell so ändern, dass es ein spezielles Verhalten besitzt.
- Zweitens erfordern Künstlich Neuronale Netze (KNN) einen erheblichen Berechnungsaufwand. Die Einführung von Datenvorverarbeitungstechniken, beispielsweise Cluster-Verfahren, haben diesen Rechenaufwand jedoch reduziert.
- Drittens sind die Wahl des für die Anwendung passenden Netz-Modells und die Justierung der Parameter des Lern-Algorithmus immer noch eine *heuristische Vorgehensweise* und erfordern große Erfahrung.

Zur Regelung von Abfallverbrennungsprozessen wäre es wünschenswert, umfassende Kenntnisse der verbrennungstechnischen Abläufe zeitnah erfassen und bewerten zu können. Dies geht und ging mit dem menschlichen Auge ganz gut. Geschulte und erfahrene Anlagenfahrer kennen den Verbrennungsprozess in ihre Anlage und können Veränderungen beispielsweise im Flammenbild, in der Temperatur und in der Dampfentwicklung unmittelbar einem vorausgehenden feuerungstechnischen Ereignis und einem Umstand zuordnen. Schwankungen in der Abfallzusammensetzung können vom geschulten Personal anhand von diesen Parametern sehr früh erkannt werden. Leider liegt heute die Aufmerksamkeit des Wartenpersonals nicht mehr primär bei der Feuerung, sondern wird von Sekundärprozessen, wie der komplexen Abgasreinigung und deren Aggregate eingefordert [3]. Ein neuer Lösungsansatz muss daher dringend entwickelt werden und wurde in KNN gesehen.

Die erste Implementierung Künstlich Neuronaler Netze (KNN) liegt bereits 50 Jahre zurück. Seitdem konzentriert sich die Forschung auf die Entwicklung von Lernverfahren und Algorithmen. Einer der Meilensteine in der Entwicklung der Technologie der Neuronale Netze war der sogenannte Error-Backpropagation Algorithmus, der vor etwa 15 Jahren entwickelt wurde.

Lernen mit dem Error-Backpropagation-Algorithmus

Wegen seiner hohen Leistungsfähigkeit wurde der Error-Backpropagation-Algorithmus sehr schnell zum Standard bei der Implementierung Künstlich Neuronaler Netze (KNN). Das Verfahren beginnt damit, dass zunächst ein Beispiel aus dem Trainingsdatensatz gewählt wird. Aus den Eingangswerten dieses Beispiels werden die Ausgangsgrößen des Künstlich Neuronale Netzes (KNN) berechnet. Daraufhin werden die vom Neuronale Netz berechneten Werte mit denen des Beispieldatensatzes verglichen.

Die so bestimmte Differenz, also der Fehler, wird dazu verwendet, die Gewichte des Neuronalen Netzes zu modifizieren. Die mathematische Abbildung des Fehlers auf die Neuronen des Netzes wird Error- Backpropagation genannt.

Error-Backpropagation im Zusammenhang mit Fuzzy-Systemen

Das Verfahren Error-Backpropagation kann bei Fuzzy-Systemen nicht direkt angewandt werden, es erfolgt auf Umwegen, anhand der Regelgewichtung für die einzelnen Fuzzy-Regeln. Zur Bestimmung des Einflusses der einzelnen Neuronen auf die Größe des Fehlers werden im Error-Backpropagation-Algorithmus die Aktivierungsfunktionen der Neuronen differenziert. Ein Problem ist hier, dass die Fuzzy Logic-Inferenz nicht differenziert werden kann. Um dieses Problem zu lösen, verwenden einige Neuro-Fuzzy Entwicklungswerkzeuge eine erweiterte Fuzzy Logic-Inferenz-Methode. Eine der häufigsten Methoden ist die Verwendung der sogenannten Fuzzy Associated Maps (FAM). Eine FAM ist eine gewichtete Fuzzy-Regel. Die Gewichtung erfolgt über den Plausibilitätsgrad (DoS) jeder einzelnen Regel. Es existiert ein mathematischer Rahmen, über den die FAMs auf die Neuronen des Künstlich Neuronales Netzes (KNN) abgebildet werden. Somit ist die Anwendung eines modifizierten Error-Backpropagation-Algorithmus auf Fuzzy-Systeme möglich. Die heutigen NeuroFuzzy-Werkzeuge sind Hilfsmittel für den Systementwurf. Sie stellen Hilfen für die Erzeugung und Optimierung der Zugehörigkeitsfunktionen und der Regelbasis aus Beispieldaten dar. In einigen Beispielen der Automobilindustrie fanden diese Error-Backpropagation-Algorithmen Anwendung und werden in der Präsentation in Berlin am 29. Januar 2013 dargestellt.

Die Bewertung eines KNN richtete sich ebenfalls nach den erarbeiteten Kriterien für Stabilität, Flexibilität und Dynamik der bestehenden Regelung und des zuvor entwickelten Reglermodells. Dabei wurden praxisnahe betriebliche Aspekte konzeptionell berücksichtigt. Zum einen sollte die Qualität der Feuerleistungsregelung weiter verbessert werden und die Entwicklungskosten für das Engineering gesenkt werden. Zum anderen wurde die Hypothese aufgestellt, dass aus den Lerndaten bisher unberücksichtigte essentielle verfahrenstechnische Grundzusammenhänge offengelegt werden können.

Anforderungen für ein gelungenes Künstlich Neuronales Netz

Ganz spezifische Anforderungen müssen in der Praxis bestehen und erfüllt sein, die von einem KNN zweifellos vollständig abgedeckt werden sollten. Dies sind insbesondere folgende Punkte [2]:

- **Sehr schneller** (praktisch immer konvergenter) **Lernalgorithmus**, um auch große Probleme in vernünftiger Zeit bewerkstelligen zu können. KNN sollten Aufgabenstellungen mit bis zu 1500 Parametern und bis zu 130.000 Datensätzen berechnen.
- schnellstmögliches Handling der Rohdaten zur **Datenvorverarbeitung**. Es muss für beliebige Probleme aus der Praxis möglich sein, aus den Rohdaten nach spätestens einem halben Tag ein neuronales Netz zu generieren. Falls die Rohdaten gewisse Minimalforderungen bzgl. der Datenstruktur erfüllen, reduziert sich die Zeit auf wenige Minuten plus der reinen Laufzeit des Lernalgorithmus (typischerweise ebenfalls in der Größenordnung von Sekunden bis einigen Stunden).

- **Automatische Bestimmung optimaler Inputs:** Bei verfahrenstechnischen Anlagen hat man es oft mit der Situation zu tun, dass eine große Zahl (mehr oder weniger korrelierter) Eingangsgrößen prinzipiell für eine Modellierung der gewünschten Zielgrößen zur Verfügung stehen. Ein KNN müsste diesbezüglich eine sogenannte *Automatische Inputoptimierung* selbstständig der Modellierungsgenauigkeit optimalen Eingangsgrößen bestimmen.

Neben der Software zur Erstellung der Netze stehen darüber hinaus verschiedene Optimierungswerkzeuge zur Auswertung der erstellten Modelle zur Verfügung. Insbesondere lässt sich damit die sogenannte *inverse Fragestellung* beantworten. Das empirische Modell beschreibt zunächst die Abhängigkeit der Ausgangsgrößen (z.B. Qualitätsgrößen) von den Eingangsgrößen (z.B. Betriebsparameter). D.h. das Modell wird mit den Betriebsparametern gefüttert, danach wird eine Prognose für die Qualitäten ermittelt. Von besonderem Interesse ist jedoch die folgende Frage:

Wenn ich diese oder jene Qualitäten erreichen will, wie müssen dann die Betriebsparameter sein?

(inverse Fragestellung zur Wissensabfrage, analog zu Fuzzy Control-Systemen)

Bei dieser Fragestellung treten typischerweise noch Nebenbedingungen auf. So ist es in der Regel der Fall, dass bestimmte Betriebsdaten mit gewissen Minimal- bzw. Maximalkonzentrationen auf jeden Fall vertreten sein müssen oder Betriebsparameter in bestimmten Grenzen gehalten werden müssen.

3. Schwachstellen Neuronaler Netze

Der größte Vorteil Künstlich Neuronaler Netze (KNN) ist in ihrer Lernfähigkeit anhand systembeschreibender Datensätze zu sehen. Aus dem Grund wird ein Beispiel verwendet, wo genau dieser Umstand zu einem größeren Problem geführt hat, zumal dieser mit einfachen Maßnahmen hätte vermieden werden können. Wenn nun Daten aus einer Abfallverbrennungsanlage ungefiltert, das heißt ohne Validierung und Cluster-Verfahren gelernt werden, wird ein KNN die Systemzusammenhänge anhand einer nachweislichen Lernerfolgsrate mit einem mehr oder weniger großen relativen Fehler bestätigen.

Aus verfahrenstechnischer Sicht ist das Wissen um die Zusammenhänge einzelner Messgrößen entscheidend. Dies führt dazu, dass KNN so konzipiert werden, dass sie die direkten Abhängigkeiten der Eingangsgrößen auf die zu analysierende Ausgangsgröße aufzeigen. In den Bildern 1 und 2 ist nach erfolgreichem Training diese Abhängigkeit bezogen auf den Frischdampf dargestellt.

Für jeden Datensatz des Testset ist hier der berechnete (prognostizierte) gegen den vorgegebenen (gemessenen) Wert aufgetragen. Darüber hinaus sind die *Winkelhalbierende* (blaue Linie) sowie die Ausgleichsgerade (rote Linie beziehungsweise Geradengleichung) durch die Punktwolke eingetragen. Zur Beurteilung der Modellgenauigkeit lässt sich ein Verlaufplot (Bild 2) heran ziehen. Bei dieser Darstellung werden für die

einzelnen Datensätze des Testsets (beziehungsweise Lernsets) der prognostizierte und der gemessene Wert über der Nummer des Datensatzes aufgetragen. Die Ergebnisse des Lernsets waren deutlich besser und wurden aus Übersichtlichkeitsgründen ausgelassen.

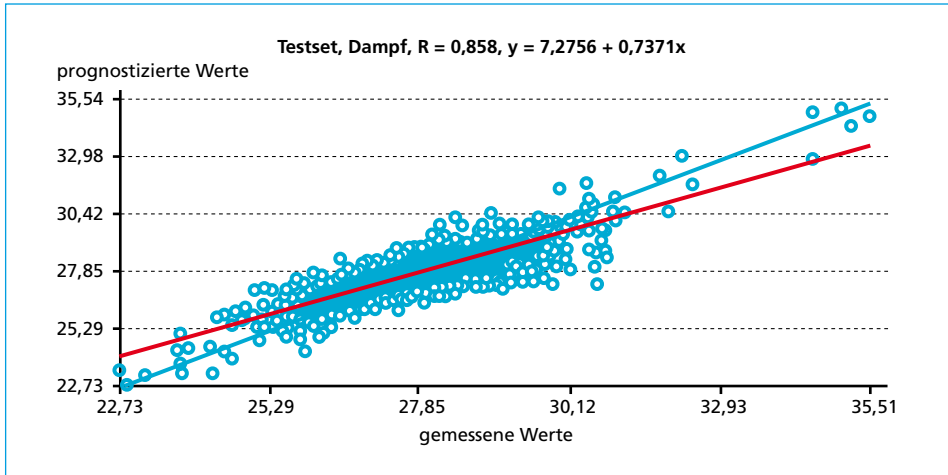


Bild 1: Testset für Dampf mit einem Korrelationskoeffizienten von 0,858




Bild 2:

Darstellung des Verlaufplots für Dampf

Die sehr gute Korrelation der gelernten Daten mit den Testdaten bei einem Korrelationswert von $R = 0,858$ lässt auch vermuten, dass in diesem Beispiel viele repräsentative Datensätze zur Verfügung standen und dass die Anzahl der inneren Knoten sehr hoch sein wird (im Regelfall zwischen vier Knoten für einfache Anwendungen und 32 innere Knoten für komplexe Anwendungen). In Bild 3 sind der *Relative Fehler* über der Anzahl der Datenmengen und der Anzahl der inneren Knoten eines KNN vereinfacht dargestellt. Ein KNN lernt, wenn es nicht überwacht (supervised learning) lernt alle Datenzusammenhänge und bildet dabei eine maximale Anzahl von inneren Knoten aus.

Im Anschluss daran, wird wenn der relative Fehler klein genug ist, ein unbekannter Datensatz zum Testen herangezogen. Der Verlauf des Testsets wird erfahrungsgemäß immer schlechter als der Lernset-Verlauf aussehen. Ab einer bestimmten Zahl von inneren Knoten kann davon ausgegangen werden, dass das KNN aus den Lerndaten den sogenannten inneren Fehler einer Anlage mitgelernt hat. Dies wird dadurch erkennbar, dass gegenüber dem Lernerfolg der Verlauf des Testsets zu höheren relativen Fehlern abweicht. Dies ist in Bild 3 dargestellt. An dieser Stelle würde die automatische Netzgenerierung die Zahl der inneren Knoten für eine stabile Fahrweise genau festsetzen und begrenzen (durch den schwarzen Doppelpfeil gekennzeichnet).




Bild 3:

Verlauf von Lern- und Testdaten über relative Fehler und Datenmenge, bzw. innere Knoten

Mit der kontinuierlichen Darstellung des Verlaufs für Lernen und Testen kann ein ungeübter Anwender sicher davon ausgehen, dass er ohne großartig ein KNN aufzublähen mit dem geringsten Aufwand, den größten möglichen Nutzen erzielen wird.

1	1	30	96.9913
1	1	40	97.1293
1	1	50	97.0171
1	1	60	96.9447
1	1	70	96.8791
1	1	80	96.7902
1	1	90	96.1934
1	1	100	96.1436
1	2	10	93.2413
1	2	20	93.8719
1	2	30	93.9267
1	2	40	94.2359
1	2	50	94.6587
1	2	60	95.1082
1	2	70	95.3161
1	2	80	95.8956
1	2	90	96.2009
1	2	100	96.4868
1	4	10	14.7310
1	4	20	-52.4875
1	4	30	-60.4636
1	4	40	-64.2192
1	4	50	-65.3625
1	4	60	-65.5096

Bild 4: Testverlauf eines KNN mit Abbruchkriterium für Ventilator-drehzahl

1	2	60	94.0479
1	2	70	94.3524
1	2	80	94.5444
1	2	90	94.7614
1	2	100	94.9986
1	4	10	94.9870
1	4	20	94.9043
1	4	30	95.0559
1	4	40	95.2624
1	4	50	95.4165
1	4	60	95.4961
1	4	70	95.5451
1	4	80	95.5634
1	4	90	95.5925
1	4	100	95.6740
1	8	10	89.7100
1	8	20	13.0185
1	8	30	-47.9815
1	8	40	-62.2053
1	8	50	-68.8287
1	8	60	-72.2907
1	8	70	-75.1423
1	8	80	-76.1082
1	8	90	-76.5207

Bild 5: Testverlauf eines KNN mit Abbruchkriterium für Ofendrehzahl

Ein solcher Verlauf des Lern- und Testverhaltens zeigt Bild 4. Darin sind in der ersten Spalte die Netzanzahl, in der zweiten Spalte die inneren Knoten (1, 2, 4, 8, 16, maximal 32 Knoten), in der dritten Spalte die Lernschritte (in Zehner-Schritten 10 bis 100) und in der vierten Spalte die Korrelation zu sehen. Ein effektives Programm als auch ein sicheres Programm für die Entwicklung von verlässlichen Reglerstrukturen ist NN-Tool. Dieses Programm zeigt definitiv die Schwachstellen, wenn unbeobachtet und nicht überwacht gelernt wird. Das Programm testet in Bild 4 gerade die Fähigkeiten des gelernten Netzes und zeigt dem Benutzer, das notwendige Abbruchkriterium. Für die in diesem Beispiel gelernte Regelung der Ventilator Drehzahl eines Drehrohrofens, würde eine einfache Regelung mittels KNN aufbauend auf zwei inneren Knoten völlig ausreichen und wäre mit einer Korrelation von 96 % absolut praxistauglich.

Bild 5 zeigt für die Regelung der Ofendrehzahl, dass das Abbruchkriterium bei vier inneren Knoten liegt und eine Korrelation von 95 % aufweist. Mit diesem KNN-Design ist ebenfalls eine sehr gute praxistaugliche Regelung möglich.

Wenn sich nun aber herausstellen sollte, dass mit dem gelernten und den getesteten Datensätzen nur an einem Arbeitspunkt die Feuerung optimieren lässt, dann wird es notwendig, das dynamische Verhalten hinsichtlich von Totzeiten, Verschmutzungen und Brennstoffinhomogenität fortlaufend zu trainieren und neu zu lernen. In diesem neuen Ansatz für die Regelung von Abfallverbrennungsvorgängen liegt bei vielen KNN, die auf dem Markt verfügbar sind, ein schwerwiegendes Problem. Mit steigender Dynamik werden vom Netz selbst die Struktur und die Anzahl der inneren Knoten festgelegt, so dass ein deterministisches Verfolgen des Zustandekommens der Regelungseingriffe nicht mehr möglich wird. Das System ist ein *Black-Box*-System und vollzieht einen unverantwortlichen Blindflug. Sollte sich im Falle eines Anlagenschadens oder einer Havarie der Feuerung herausstellen, dass nicht nachvollziehbar war, nach welchen Kriterien das KNN regelungstechnische und sicherheitsrelevante Entscheidungen getroffen hat, wird dies zum Versicherungsausschluss führen und der Versicherungsgeber wird Garantieleistungen nicht erbringen (was einleuchtend ist). Dem ist bei weitem nicht genug geschuldet, denn es zeigt sich immer wieder, dass KNN-Regelungen unverständliche Regeleingriffe vollziehen, die der nachweislichen Logik in keinsten Weise gehorchen. Systeme, die aufgrund ihres stark dynamischen Veränderungsverhaltens fortlaufend neue Netzstrukturen erzeugen, neigen zur sogenannten *Maschinellen Schizophrenie*. Dieses Auftreten der *Maschinellen Schizophrenie* wird an einem Beispiel erläutert, das zum ersten Mal vermehrt auch in der Automobilindustrie zu großen Verstimmungen und noch größerem Erstaunen geführt hat.

Das Phänomen, das hierbei auftritt, wird anhand von Bild 6 erläutert. Viele Systemsoftwaretools empfehlen dem Anwender die maximal höchste Zahl von inneren Knoten, bei deren Anwesenheit das Regelungsverhalten angeblich stabil und mit hoher Korrelation verlief. Der angestrebte wirtschaftliche Hintergrund ist in der Vortäuschung von einem geringen relativen Fehler zu sehen. Solch aufgeblähte KNN-Strukturen verschlingen aber nicht nur unendlich viel Rechnerleistung, sondern sind auch nicht weniger effektiv als KNN-Strukturen mit geringerer Zahl an inneren Knoten. Um so tragischer wirkt sich dann aus, dass ein dynamisch angepasstes Verhalten der inneren Knoten zu einer fatalen Fehlentscheidung im Gesamtregelungsverhalten führt.

Ausgangsparameter		Lerndatensätze	Testdatensätze	Innere Knoten
Anlage 2 Systemventilator		3606	901	4
Drehzahl Sollwert		Iteration	Korrelation	Relative Fehler
		10	0,7894	5,8859
1	2	60	95,5451	
1	2	70	95,7751	
1	2	80	96,1006	
1	2	90	96,3535	
1	2	100	96,7631	
1	4	10	78,9410	
1	4	20	-25,2708	
1	4	30	-51,6961	
1	4	40	-61,0688	
1	4	50	-65,8729	
1	4	60	-67,0957	
1	4	70	-67,6952	
1	4	80	-68,4367	
1	4	90	-68,6756	
1	4	100	-68,6326	
1	8	10	-67,5091	
1	8	20	-37,3264	
1	8	30	18,3050	
1	8	40	88,0432	
1	8	50	96,3744	
1	8	60	96,7927	
1	8	70	96,5163	
1	8	80	96,3259	
1	8	90	95,9204	

Bild 6:

Verlauf von Lern- und Testdaten über relative Fehler und Datenmenge, bzw. innere Knoten

Bei diesem Verhalten von Lern- und Testverlauf wird der sogenannte interne Fehler der Anlage mitgelernt und kann dem System vortäuschen, dass es weiterhin erfolgreich lernen und testen kann mit verbesserten relativen Fehlerraten. Sobald in solchen Systemen, die mit *Maschinellem Schizophrenie* behaftet sind, willkürlich das System die Anzahl der inneren Knoten nach nicht nachvollziehbaren Algorithmen verändert, werden Anlagenschäden durch Fehlverhalten der Regelung nicht auszuschließen sein. Dass ein KNN-System dazu in der Lage ist, zeigt anschaulich Bild 7.



Bild 7:

Testverlauf eines KNN mit Abbruchkriterium für Ofendrehzahl

Mit entsprechender Softwarespezifikation kann ein System auch die Netzstruktur an der Stelle anhalten, an der diese Phase der *Maschinellen Schizophrenie* beginnen wird. In Bild 7 stoppt die Netzstruktur den Netzaufbau genau beim vierten inneren Knoten, damit der Anwender sieht, dass ab Knoten vier und den ersten 10 Iterationen die Korrelation von 96 % auf 78 % und dann weiter fällt. Bis Ende Knoten vier mit Übergang zu Knoten acht ist erst nach 40 Rechenschritten eine stabile KNN-Netzstruktur wieder erreicht und ebenfalls ein kleinerer relativer Fehler. Wäre diese Netzstruktur mit 16 inneren Knoten später in einer Feuerleistungsregelung aktiv und könnte nach nicht nachvollziehbaren Algorithmen sich selbst die Zahl der inneren Knoten bestimmen, so könnte dies katastrophale Folgen für die Anlage haben.

Wie schwerwiegend eine solche Fehlentscheidung sein kann, ist in Bild 8 zu sehen.

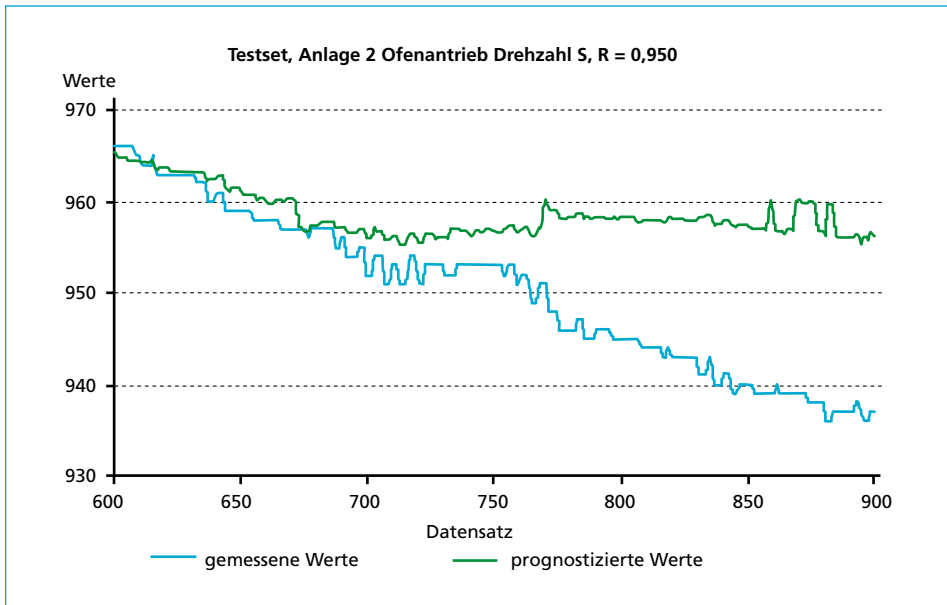


Bild 8: Darstellung der gemessenen, realen Werte und der prognostizierten Werte (Regelungswerte, Vorhersage)

Der Testdatensatz wird bei dem zuvor erzeugten Netz aufgespielt. Das Netz hat maximal 16 innere Knoten und ist absolut stabil und erreicht eine Korrelation von 95%. Dieses Netz ändert gewollt die Zahl der inneren Knoten von 16 auf vier und wird ab dem 700. Datensatz instabil, so dass die real gemessenen Werte von denen der Regelung (prognostizierten Werte) sofort abweichen und eine ganz andere Richtung nehmen. Für die Regelung einer Drehrohrofenanlage wäre diese Fahrweise irreparabel. Ein KNN mit diesen Schwächen würde die Entsorgungssicherheit mehr als in Frage stellen.

Anhand der oben genannten Punkte zeigt sich, dass eine Methode zur Verifikation und Optimierung Künstlich Neuronaler Netze (KNN) fehlt, was ihren Einsatz sehr beschränkt. Künstlich Neuronale Netze (KNN) stellen eine implizite Wissensrepräsentation dar. Das System kann jedoch nur schwer interpretiert und modifiziert werden

und schon gar nicht durch sich selbst. Eine Lösung für die Schwachstellen und die Störanfälligkeit würde die Kombination aus einem stabilen wissensbasierten Fuzzy-System mit KNN darstellen.

Fuzzy Control verwendet eine explizite Wissensrepräsentation. Fuzzy Control-Systeme sind nicht trainierbar, so dass das System explizit beschrieben werden muss. Beide Verfahren, sowohl Künstlich Neuronale Netze (KNN), als auch Fuzzy Logic sind sehr leistungsfähige Entwicklungstechnologien mit verschiedenen Stärken und Schwächen. Künstlich Neuronale Netze (KNN) können aus vorhandenen Datensätzen lernen, während Lösungen mit Fuzzy Logic zu verifizieren und zu optimieren sind.

Die NeuroFuzzy-Technologie stellt eine Kombination der expliziten Wissensrepräsentation der Fuzzy Logic mit der Lernfähigkeit der Künstlich Neuronalen Netze (KNN) dar.

4. Ausblick und Zusammenfassung

Trotz eines ständig zunehmenden Automatisierungsgrades in allen Lebensbereichen bleiben die menschlichen Sinne und Fähigkeiten das Maß aller Dinge. Eine Automatisierung lässt sich zwar grundsätzlich beliebig weit steigern, der dafür erforderliche Aufwand ist jedoch in keiner Weise mehr vertretbar. Gerade wenn es um die Erhöhung der Produktivität moderner Produktionseinrichtungen geht, wird die Entscheidung für Mehrinvestitionen zugunsten einer weiteren Automatisierung immer schwieriger. Das Meiste ist bereits geleistet, jetzt geht es um Feinheiten, die bisher immer noch das Geschick und das Können von erfahrenem Bedienpersonal erfordern [3]. An diesem Punkt kann die Fuzzy-Technologie in Verbindung mit Künstlich Neuronalen Netzen KNN neue Impulse bringen. Verfügt man über eine Technologie, die *Technische Systeme* mit Hilfe menschlicher Denkansätze zu beschreiben sucht, so lässt sich das Feld für Automatisierungslösungen erweitern. Eben eine solche Technologie ist Fuzzy Logic in Verbindung mit KNN (Neuro-Fuzzy-System-Technologie genannt), diese ausschließlich zur Unterstützung hinsichtlich ihrer sehr guten Fähigkeiten für Prozessanalyse und Prognose der KNN zum Einsatz kommen und ein sehr gut ausgebautes Fuzzy-System nur noch unterstützen.

Die Anwendung der **Neuro-Fuzzy-System-Technologie** in der Regelungstechnik eröffnet viele Möglichkeiten, Regelungsaufgaben einfacher als mit herkömmlicher Technik zu beherrschen. Das Verhalten des Reglers wird mit einfachen sprachlichen Beschreibungen an Stelle von komplizierten mathematischen Algorithmen programmiert und das KNN analysiert die wichtigsten Prozessgrößen und kann für eine ausreichende Totzeitkompensation durch Prognosetools die letzten Optimierungsansätze bestens ausnutzen. Neuro-Fuzzy-System-Technologie verarbeitet diese Beschreibungen und erzeugt eine physikalische Stellgröße, die an den Prozess weitergegeben wird. Auch wenn man nicht Experte für Regelungstechnik ist, kann man mit dieser Technik anspruchsvolle Regelungsaufgaben lösen.

Aber auch bei der Regelung komplexer, nicht linearer Prozesse, die nur unzureichend mit Näherungen zu beschreiben sind, bietet die Neuro-Fuzzy-System-Technologie

wesentliche Vereinfachungen. Neuro-Fuzzy-System-Technologie ist eine innovative Technologie, die es ermöglicht, das gewünschte Systemverhalten zu beschreiben, indem die alltägliche Sprache benutzt wird.

Diese Vorgehensweise trägt auch der Forderung nach weitgehender Selbstgängigkeit des Verbrennungsprozesses Rechnung und verdeutlicht die Ziele, die man sich ebenfalls mit der Einführung von Kamerasoftware-Tools und Neuro-Fuzzy-System-Technologie gesetzt hat:

- Emissionen durch verbesserte Primärmaßnahmen zu verringern,
- Emissionsspitzen zu vermeiden,
- den Brennergasanteil zu reduzieren,
- eine konstant hohe Temperatur in der Nachbrennkammer sicherzustellen,
- die Schlackequalität weiter zu erhöhen,
- den Energieanteil der Abfallstoffe optimal umzuwandeln, Luft-/Brennstoffverhältnis optimieren,
- eine weitergehende Homogenisierung am Prozess und für die nachfolgenden Aggregate (Kessel und Abgasreinigung) zu erreichen.

Um diese Ziele zu erreichen, müsste der Anlagenfahrer permanent den Verbrennungsbereich, sprich die Feuerung, kontrollieren und analysieren. Das ist aus heutiger Aufgabenverteilung im Arbeitsumfeld einer Leitwarte nicht möglich und diese notwendige Zeit der Beobachtung steht dem Anlagenpersonal nicht zur Verfügung. Hauptsächlich werden diese Eingriffe bei der Stabilisierung der Ausbrandgrenze notwendig. Insofern bedarf die bestehende Regelung einer Berücksichtigung höherer dynamischer Anteile bei der Verantwortlichkeit der Flammen in der Hauptverbrennungszone [4].

Noch wichtiger wäre indes die Beobachtung der Intensitäten der Vorreaktionen der Verbrennungsabläufe (Trocknung, Pyrolyse, Zündung und Vergasung), wodurch von vorne herein eine Schwankungsbreite im Feuerleistungsverhalten minimiert werden könnte. Die Einhaltung der gesetzlichen Bestimmungen hinsichtlich der Emissionsgrenzwerte und eine wirtschaftlich nutzbare Auskopplung von Energie in Form von Strom und Dampf sind relevante Kriterien.

Die Forschungsvorhaben an der HTW des Saarlandes und dem Institut für Physikalische Prozesstechnik IPP stellen sich genau diesen Zielen. Die im Ansatz diskutierten Vorhaben werden zurzeit in Anträgen zu Forschungsvorhaben erstellt und eingereicht. Die Ziele zur Offenlegung von weiteren Optimierungspotenzialen in der Feuerleistungsregelung mittels Video- und IR-Feuerraumkameras und Neuro-Fuzzy-System-Technologie sind klar formuliert:

Ziel ist es, die wissenschaftlichen Voraussetzungen zu schaffen, die innovativen und fachrichtungsübergreifenden Ingenieurleistungen von der anwendungsorientierten Forschung in praxisorientierte Produktentwicklung umzusetzen.

In der Betrachtung der Neuro-Fuzzy-System-Technologie mit IR-Kamera-Feuerraumtemperaturverfolgen müssen unbedingt die vorausschauende Instandhaltung, der Kesselschutz, die Kessel- und Feuerraumauslegung bevorzugt betrachtet werden. Die Höhe der Temperaturen an Zünd- und Seitenwanddecke, der Grad an Verschmutzung durch Anbackungen und Feuerraumwächten, wurden als weiterer Vorteil dargestellt und könnten dynamisch betrachtet werden. So könnte neben der Analyse des mechanischen Stresspotenzials durch sich schnell ändernde und zu hohe Temperaturen auch der Grad an Verschmutzungsneigung und Schlackefluss aufgenommen und zu einem Frühwarnsignal verarbeitet werden. Probleme der Wasser-Dampf-Kreislaufführung könnten somit schneller detektiert werden, Temperatur-Flächenanteile durch Summenfunktionen interpoliert und Temperaturexkursionen durch gesicherte Extrapolationsverfahren annähernd als Warnfunktion berechnet werden. Einige Künstliche Neuronale Netz-Programme verfügen zurzeit schon über diese Kapazitäten, damit eine gesicherte Extrapolation mit dem dazugehörigen Korrelationskoeffizienten jederzeit angezeigt wird.

Mit diesen Voraussetzungen steht einem kombinierten Einsatz von wissensbasierten Fuzzy Control-Systemen, Künstlich Neuronalen Netzen KNN und video-/bzw. IR-Kamera-basierter Feuerraumdetektion nicht mehr im Weg.

5. Literaturverzeichnis

- [1] Zellner, K.: Skriptum zur Vorlesung Abfallverfahrenstechnik. FH Trier, Fachbereich Versorgungstechnik, Trier, 2000
- [2] Bärmann, F.: Technik und Algorithmen von NN-TOOL. Düsseldorf 2012, Bärmann-Software
- [3] Gierend, C.: Moderne Feuerleistungsregelung, Einsatz von Kameratechnik. Institut für Physikalische Prozesstechnik, Jahresbericht 2012, HTW des Saarlandes, Saarbrücken, 2012
- [4] Keller, H.; Mattes, J.: Infrarot-basierte Optimierung des Verbrennungsprozesses in der thermischen Abfallbehandlung. KIT, IAI Karlsruhe, 2010, ci-Tec GmbH

Die Deutsche Bibliothek – CIP-Einheitsaufnahme

Energie aus Abfall – Band 10

Karl J. Thomé-Kozmiensky, Michael Beckmann.

– Neuruppin: TK Verlag Karl Thomé-Kozmiensky, 2013

ISBN 978-3-935317-92-4

ISBN 978-3-935317-92-4 TK Verlag Karl Thomé-Kozmiensky

Copyright: Professor Dr.-Ing. habil. Dr. h. c. Karl J. Thomé-Kozmiensky
Alle Rechte vorbehalten

Verlag: TK Verlag Karl Thomé-Kozmiensky • Neuruppin 2013

Redaktion und Lektorat: Professor Dr.-Ing. habil. Dr. h. c. Karl J. Thomé-Kozmiensky,

Dr.-Ing. Stephanie Thiel, M.Sc. Elisabeth Thomé-Kozmiensky

Erfassung und Layout: Petra Dittmann, Sandra Peters,

Martina Ringgenberg, Ginette Teske, Ulrike Engelmann, LL. M., Ina Böhme

Druck: Mediengruppe Universal Grafische Betriebe München GmbH, München

Dieses Werk ist urheberrechtlich geschützt. Die dadurch begründeten Rechte, insbesondere die der Übersetzung, des Nachdrucks, des Vortrags, der Entnahme von Abbildungen und Tabellen, der Funksendung, der Mikroverfilmung oder der Vervielfältigung auf anderen Wegen und der Speicherung in Datenverarbeitungsanlagen, bleiben, auch bei nur auszugsweiser Verwertung, vorbehalten. Eine Vervielfältigung dieses Werkes oder von Teilen dieses Werkes ist auch im Einzelfall nur in den Grenzen der gesetzlichen Bestimmungen des Urheberrechtsgesetzes der Bundesrepublik Deutschland vom 9. September 1965 in der jeweils geltenden Fassung zulässig. Sie ist grundsätzlich vergütungspflichtig. Zuwiderhandlungen unterliegen den Strafbestimmungen des Urheberrechtsgesetzes.

Die Wiedergabe von Gebrauchsnamen, Handelsnamen, Warenbezeichnungen usw. in diesem Werk berechtigt auch ohne besondere Kennzeichnung nicht zu der Annahme, dass solche Namen im Sinne der Warenzeichen- und Markenschutz-Gesetzgebung als frei zu betrachten wären und daher von jedermann benutzt werden dürfen.

Sollte in diesem Werk direkt oder indirekt auf Gesetze, Vorschriften oder Richtlinien, z.B. DIN, VDI, VDE, VGB Bezug genommen oder aus ihnen zitiert worden sein, so kann der Verlag keine Gewähr für Richtigkeit, Vollständigkeit oder Aktualität übernehmen. Es empfiehlt sich, gegebenenfalls für die eigenen Arbeiten die vollständigen Vorschriften oder Richtlinien in der jeweils gültigen Fassung hinzuzuziehen.