

Einsatz von neuronalen Netzen zur Optimierung des Kesselbetriebs

Max Starke, Michael Haug, Michael Schreiber

EUtech Scientific Engineering GmbH, Aachen

Willy Derichs, Alfred Mittelstädt

RWE Rheinbraun AG, Köln

Einleitung

Der vermehrte Einsatz von Kohlen schwankender Qualitäten führt zu einer Zunahme der Verschmutzung von Kraftwerkskesseln. Daraus resultieren aufwendige Reinigungsmaßnahmen sowie höhere Stillstandszeiten.

Während leichte Ansatzbildungen durch den Einsatz von Reinigungseinrichtungen (z.B. Dampf- oder Wasserbläsern) entfernt werden können, versagen diese Verfahren jedoch bei festen, schlackeförmigen Ansätzen. Als Folge müssen die Kessel häufiger abgeschaltet und grundgereinigt werden.

Daher ist das vornehmliche Ziel, die Ursachen der Ansatzbildung zu bekämpfen.

Eine vielversprechende Lösung liegt in der „intelligenten“ Regelung der Verbrennungsführung mit Hilfe neuronaler Netze. Betriebszustände mit hoher Ansatzbildung sollen dadurch gezielt vermieden werden.

Ein auf neuronalen Netzen basierendes Prozessmodell erfasst die unterschiedlichen Betriebszustände eines Kessels und ermöglicht eine einfache anlagenspezifische Anpassung der Fahrweise. Das Systemverhalten des Kessels wird abgebildet und das neuronale Netz prognostiziert den zeitlichen Verlauf der Verschmutzung. Daraus werden gezielt Regelungsstrategien für einen optimierten Anlagenbetrieb abgeleitet.

Das System kann sowohl im open-loop als auch im closed-loop Betrieb eingesetzt werden. Dies erlaubt eine hohe Flexibilität bei der Integration in bestehende

leittechnische Systeme unter Berücksichtigung anlagenspezifischer

Randbedingungen.

Hintergrund und Zielsetzung

In Kesseln der RWE Rheinbraun AG, die mit Braunkohle befeuert werden, treten Probleme hinsichtlich der Verschmutzung und Verschlackung auf. Dies liegt zum einen an emissionsbedingten Veränderungen der Fahrweise (gestufte Verbrennung), zum anderen an einer veränderten Zusammensetzung der Braunkohle.

Ziel ist es daher, die bestehende Kesselregelung so zu verbessern, dass die Ansatzbildung vermindert wird, ohne die vorgegebenen Randbedingungen (z.B. Kesselleistung, Stickoxid- und Kohlenmonoxid-Emissionen) zu verletzen. Mit einem auf neuronalen Netzen basierenden Prozessmodell, das eine zuverlässige Prognose der Zielgröße „Ansatzbildung“ erlaubt, erfolgt eine optimale Verstellung der relevanten Einflussgrößen.

Neuronale Netze

(Künstliche) Neuronale Netze bilden in vereinfachter Weise die Informationsverarbeitung des Gehirns nach. Eine Vielzahl von Neuronen sind in mehreren Schichten angeordnet und über gewichtete Verbindungen miteinander verknüpft. Durch systematische Veränderung dieser Gewichte mit Hilfe eines Lernalgorithmus sind neuronale Netze in der Lage, den Zusammenhang zwischen Eingangs- und Ausgangsgrößen zu erlernen und über eine entsprechende Abbildungsvorschrift darzustellen. Einschränkend ist zu bemerken, dass neuronale Netze nur begrenzt extrapolationsfähig sind. Dies macht es erforderlich, dass die Trainingsdaten über eine ausreichende Varianz verfügen, die alle zu erwartenden Betriebsbereiche abdeckt [1,2].

Vorgehen

Im Rahmen der Voruntersuchungen werden die vorhandenen Daten gesichtet, aufbereitet und eine Systemanalyse durchgeführt. Als Zielgrößen dienen die Effektivitäten der Heizflächen, die unmittelbar von der Verschmutzung abhängen. Am stärksten wirken sich Verschmutzungen am Überhitzer aus, der direkt über dem Feuerraum angeordnet ist [3].

Zunächst werden die wesentlichen Einfluss- und Stellgrößen erfasst. Die späteren Regeleingriffe können dabei nur über unabhängige Größen (Stellgrößen)

vorgenommen werden. Die Prognose der Zielgröße erfolgt auf Basis der jeweiligen Eingangsgrößen-Konstellation, die systematisch optimiert wird, um den gewünschten Wert der Zielgröße zu erreichen (modellprädiktive Regelung). Parallel wird die Zuverlässigkeit der prognostizierten Stellgrößenänderungen laufend über gesonderte Netze überwacht und bewertet.

Über eine Sensitivitätsanalyse werden die wichtigsten Einflussgrößen identifiziert.

Datengewinnung

Für die Untersuchungen wurden ca. 570 Messgrößen zumeist als Minutenwerte über einen Zeitraum von mehreren Monaten bereitgestellt. Dazu gehörten neben Werten aus der Leittechnik und dem angeschlossenen Kesseldiagnosesystem zusätzlich die Emissionswerte, Angaben zu Kohlequalität, Wärmedurchgang, Luftmengen und Klappenstellungen sowie Einsatz der Reinigungseinrichtungen. Weiterhin standen ergänzende Messungen zur Temperaturverteilung, zum Druckabfall im Kessel und optische Informationen zur Ansatzbildung zur Verfügung.

Diese Vielzahl an Informationen aus unterschiedlichen Datenquellen erfordert eine umfangreiche Datenaufbereitung und Synchronisation aller Daten.

Die Systemanalyse erfolgte schrittweise über eine globale Datenanalyse, Filterungs- bzw. Glättungsverfahren und Korrelationsanalysen. Vornehmliches Ziel war es dabei, Fehlstellen und Ausreißer zu eliminieren, redundante Daten auszuschließen und die charakteristischen Totzeiten zu identifizieren. Dabei stellte sich schnell heraus, dass sich keine „einfachen“ Regressionsmodelle ableiten lassen.

Modellierung

Für die Konzeption einer modellprädiktiven Regelung ist ein auf unabhängigen Stellgrößen basierendes Prozessmodell Voraussetzung. Als Eingangsgrößen finden sowohl die Zeitreihen der Zielgröße als auch der Stellgrößen Verwendung.

Die Zeitreihen der Zielgrößen enthalten theoretisch die gesamte Information über die Systemdynamik. Berücksichtigt man hinreichend viele Elemente einer Zeitreihe, so ist dies äquivalent zu einer vollständigen Beschreibung der zugrundeliegenden Systemdynamik [4].

Als Zielgröße dient die vom Kesseldiagnosesystem berechnete Effektivität der Heizflächen, aus der indirekt auf die Ansatzbildung geschlossen werden kann. Der Einfluss der Reinigungseinrichtungen, die in periodischen Abständen einen Teil der Ansätze entfernen, ist dabei schwierig zu berücksichtigen. Für das Training der neuronalen Netze wurden daher nur Zeiträumen betrachtet, in denen die Reinigungseinrichtungen nicht aktiv waren. Als Restriktionsziele wurden die Emissionen an Stickoxiden (NO_x) und an Kohlenmonoxid (CO) berücksichtigt, für die jeweils eigenständige Modelle entwickelt wurden.

Als Eingangsgrößen für die Modelle dienten ausschließlich die unabhängigen Stellgrößen, die zur Verringerung der Modellordnung sinnvoll zusammengefasst wurden.

Die verwendeten Modelle enthalten ca. 15 – 20 Eingangsgrößen:

Stellgrößen	Anzahl
Heißluft Hauptbrenner	8
Drehzahl Kohlemühle	8
Zuteilerdrehzahl Kohlemühle	8
Primärluft Mühlen	8
Sekundärluft Mühlen	8
Ausbrandluft Ebene 1	16
Ausbrandluft Ebene 2	16
Rostluftklappe	1
Oberluft untere Brennerebene	8
Unterluft untere Brennerebene	8
Oberluft obere Brennerebene	8
Unterluft obere Brennerebene	8
Ölbrennerluft obere Ebene	8
Ölbrennerluft untere Ebene	8

Die Netzarchitektur beruht auf Feed-Forward-Netzen mit ein bis zwei verdeckten Schichten. Ihr Vorteil liegt im einfachen und robusten Aufbau.

Ergebnisse

Die trainierten Feed-Forward-Netze zeichnen sich durch eine hohe Prognosequalität aus. In der folgenden Abbildung 1 sind exemplarisch die Originalmesswerte, die geglätteten Messwerte und die Prognosewerte für NO_x dargestellt:




Abbildung 1: Prognose der NO_x -Emission. Messwerte (blau), geglättete Messwerte (rot, fett) und Prognose (grün, gestrichelt).

Für die Verwendung neuronaler Netze in Regelungen ist eine gute Prognosequalität alleine jedoch nicht ausreichend. Eine zuverlässige Abschätzung des modellbedingten Prognosefehlers und des zulässigen Prognosebereiches ist genauso wichtig. Dazu werden zusätzliche neuronale Netze mit dem Prognosefehler und der beim Training des Prognosenetzes verwendeten Datendichte trainiert. Fasst man diese Informationen zusammen, so ergeben sich belastbare Aussagen über die Prognosequalität.

Ferner ist es für die Regelung wichtig, das Systemverhalten über einen ausreichend langen Zeitraum prognostizieren zu können (Mehrschrittprädiktion). Dabei greift das Netz schrittweise auf bereits prognostizierte Ergebnisse zurück und verwendet diese als neue Eingangsgrößen für den nächsten Prognoseschritt. Der Fehler wächst mit zunehmendem Prognosehorizont.

Dieses Verfahren wurde bis zu einem Prognosehorizont von 30 Minuten getestet und erwies sich für den vorgesehenen Zweck als ausreichend genau. Ausgehend von einem bekannten Anfangspunkt erfolgt die Prognose ausschließlich auf Basis der

Stellgrößeninformationen und der historischen Daten. Die folgende Abbildung 2 zeigt eine solche Mehrschrittprognose:




Abbildung 2: Mehrschrittprognose der Effektivität der Heizflächen an verschiedenen Betriebspunkten (Prognosehorizont 30 Minuten).

Das Prozessmodell zur Mehrschrittprognose der Effektivität der Heizflächen ist in der Lage, den zeitlichen Verlauf der Effektivität gut nachzuvollziehen und nimmt teilweise sogar Richtungsänderungen vorweg.

Für die Reglerauslegung ist es hilfreich, den Einfluss von Stellgrößenänderungen auf das System quantifizieren zu können. Mit Hilfe einer Sensitivitätsanalyse wird der Einfluss der Stellgrößen auf die Zielgröße quantifiziert. Es zeigt sich, dass die Sensitivität der einzelnen Stellgrößen vom jeweiligen Betriebspunkt abhängt und keineswegs konstant ist. Eine auf statischen Anweisungen basierende Regelstrategie ist daher nur bedingt erfolgversprechend.

Optimierung

Ziel des Regelungskonzepts ist die Begrenzung der Ansatzbildung an den Heizflächen durch eine betriebspunktabhängige Verstellung der Stellgrößen. Die Einhaltung der Randbedingungen (Kesselleistung, NO_x und CO) ist dabei jederzeit zu gewährleisten.

Vom Prinzip her werden diejenigen Stellgrößen vertrimmt, die im aktuellen Betriebspunkt eine zielkonforme Änderung der Zielgröße bewirken. Der optimale Stelleingriff wird aus einem Stellgrößenkennfeld ermittelt, das sich aus allen

möglichen Stellgrößenvariationen im Bereich des Betriebspunktes ergibt. Dabei wird geprüft, ob für die vorgeschlagene Stellgrößenkombination eine ausreichend hohe Datendichte und ein niedriger Prognosefehler vorliegt. Nur wenn dies gewährleistet ist, wird eine Regelanweisung zur Umsetzung freigegeben. Über die Mehrschrittprognose ist es zudem möglich, die Reglerdynamik abzuschätzen, um zu häufige Stellgrößenänderungen zu vermeiden.




Abbildung 3: Vergleich der prognostizierten Effektivität der Heizflächen und der NO_x -Emissionen mit und ohne Stellgrößeneingriffe.

In Abbildung 3 sind die zeitlichen Verläufe der Heizflächeneffektivität und der NO_x -Emissionen ohne und mit Regeleingriff dargestellt. Die Regleraktivität führt in diesem Beispiel sowohl zu einer Verminderung der Verschmutzung als auch zu einer Abnahme der NO_x -Emissionen. Für den open-loop Betrieb wird die Regelaktivität auf eine Stellgrößenänderung alle 5 Minuten beschränkt. Dies verhindert zudem eine zu starke Regleraktivität und gewährleistet ein stabiles Verhalten.

Derzeit wird der Regler als „Vorschlagssystem“ im open-Loop-Betrieb als eine add-on Lösung realisiert: Die bestehende Leittechnik, die mit statischen Sollwerten arbeitet, erhält vom Regler dynamische Sollwertvorgaben. Diese Strategie verhindert, dass es zu Reglerkonflikten mit der bestehenden Leittechnik kommt. Der Rechner ermittelt in definierten Abständen Handlungsvorschläge (Sollwertänderungen) sowie eine Bewertung dieser Vorschläge im Hinblick auf Zuverlässigkeit und Güte. Die Umsetzung der Empfehlung erfolgt im open-loop Betrieb noch manuell.

Zusammenfassung

Mit neuronalen Netzen ist eine zuverlässige Prognosen der Verschmutzung sowie der NO_x und CO Emissionen möglich.

Die Modelle arbeiten sehr robust und bieten die Möglichkeit, über Modellfehler und Datendichte die Vertrauenswürdigkeit der eigenen Prognosen zu bewerten.

Mehrschrittprognosen bis zu 30 Minuten sind möglich. Über die Analyse der Sensitivitätskoeffizienten konnte ein modellprädiktives Reglerkonzept erstellt werden.

Durch eine online-Datenanbindung kann ein solcher Regler genutzt werden, Handlungsempfehlungen für eine optimierte Fahrweise des Kessels abzuleiten, ohne Eingriffe in die bestehende Leittechnik vornehmen zu müssen (open-loop). Durch eine weitere Optimierung und die Erweiterung des Trainingsbereichs wird es zukünftig möglich sein, das System closed-loop in die Kesselregelung zu integrieren.

Literatur

- [1] Scherer A.: Neuronale Netze - Grundlagen und Anwendungen, Vieweg (1997)
- [2] Zakharian S.; Ladewig-Riebler P.; Thoer S.: Neuronale Netze - Grundlagen und Anwendungen, Vieweg (1997)
- [3] Haug M.; Schulpin H.-J.; Schreiber M.; Derichs W.; Robiné H.: Intelligente Heizflächenüberwachung und -reinigung in Kesselanlagen, Vortrag bei der VDI-Gesellschaft Energietechnik Tagung „Fortschrittliche Energiewandlung und –anwendung 2003“, 11. März 2003 in Stuttgart
- [4] Swingler K.: Applying Neural Networks – A Practical Guide, Academic Press (1996)