

Betriebsoptimierung eines braunkohlegefeuerten Kessels mit prädiktiver Regelung

M. Schreiber, M. Starke, M. Haug, Aachen

W. Derichs, A. Mittelstädt, Köln

1. Einleitung

Schwankende Kohlequalitäten und höhere Heizwerte führen zu verstärkter Verschmutzung von braunkohlegefeuerten Kraftwerkskesseln. Erhöhte Stillstandszeiten und zeitintensive Reinigungen sind die Folge. Während leichte Ansatzbildungen durch den Einsatz von Dampf- und Wasserbläsern entfernt werden können, versagen diese Verfahren jedoch bei festen, schlackeförmigen Ansätzen. Daher ist das vornehmliche Ziel, die Ursachen der Ansatzbildung zu bekämpfen. Neben der Verbesserung des Kohlemanagements, stellt die prädiktive modellbasierte Regelung einen vielversprechenden Lösungsansatz dar. Durch eine „intelligente“ Verbrennungsführung werden Betriebszustände mit hoher Ansatzbildung gezielt vermieden. Hierbei erfasst ein auf neuronalen Netzen basierendes Prozessmodell die unterschiedlichen Betriebszustände des Kessels und ermittelt unter Berücksichtigung verschiedener Einflussgrößenkombinationen deren optimale Verstellung. Um den Installationsaufwand zu minimieren, wird die prädiktive Regelung in die bestehende Regelinfrastruktur integriert. Um einen daraus resultierenden Zielkonflikt im Regelungssystem auszuschließen, berechnet die prädiktive Regelung Sollwerte, die als dynamische Größen den bestehenden Reglern vorgegeben werden. Das System wird zunächst im open-loop getestet.

2. Hintergrund und Zielsetzung

In Kesseln der RWE Rheinbraun AG, die mit Braunkohle befeuert werden, treten seit einigen Jahren vermehrt Verschmutzungs- und Verschlackungserscheinungen auf. Dies liegt zum einen an emissionsbedingten Veränderungen der Fahrweise (gestufte Verbrennung), zum anderen an einer veränderten Zusammensetzung der Braunkohle. Die bestehende Kesselregelung ist 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 basierendem Prozessmodell, das eine zuverlässige Prognose der Zielgröße „Ansatzbildung“ erlaubt, erfolgt eine optimale

Verstellung der relevanten Einflussgrößen mit einer modellprädiktiven Regelung (Model Predictive Control – MPC).

3. Modellprädiktive Regelung

Das Kesselverhalten wird mit einem auf einem neuronalen Netz basierenden Modell abgebildet. Die Aufgabe des Reglers besteht nun darin, diejenige Kombination von Stellgrößen zu ermitteln, die für einen bestimmten Zeitraum das Kesselverhalten in Bezug auf Verschmutzung optimiert. Im ersten Schritt wird ein neuronales Modell des Kessels erstellt (Systemidentifikation). Im nächsten Schritt wird dieses Modell verwendet, um das Kesselverhalten zu prognostizieren und dabei die Stellgrößen im Hinblick auf die Zielfunktion zu optimieren. Zur Systemidentifikation wird ein Versuchsprogramm gefahren, in dem die Stellgrößen – in diesem Fall handelt es sich um die Sollwertvorgaben im Kohle-Luft-System des Blocks – systematisch variiert werden. Mit den resultierenden Outputs (Zielgröße) können die neuronalen Modelle trainiert werden. 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. Da neuronale Netze nur begrenzt extrapolationsfähig sind, ist es erforderlich, dass die Trainingsdaten über eine ausreichende Varianz verfügen, die alle zu erwartenden Betriebsbereiche abdeckt [1,2]. In Bild 1 ist die Struktur der modellprädiktiven Regelung dargestellt.

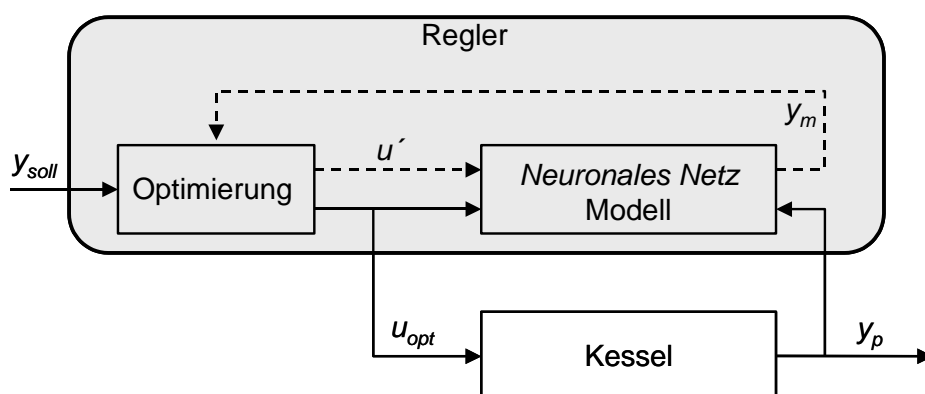


Bild 1: Prinzip der modellprädiktiven Regelung (u Stellgröße, y Regelgröße)

Als Zielgröße dient die vom Kesseldiagnosesystem berechnete Effektivität der Heizflächen, aus der indirekt auf die Ansatzbildung geschlossen werden kann. Betrachtet werden diejenigen Heizflächen, die unmittelbar von der Verschmutzung betroffen sind. Am stärksten wirken sich Verschmutzungen am Überhitzer aus, der direkt über dem Feuerraum angeordnet ist [3]. Bei der hier konzipierten modellprädiktiven Regelung handelt es sich um eine Nachlaufregelung: Die Festwertregelung des Kessels bleibt bestehen, erhält als Input jedoch dynamisch generierte Sollwerte, die von der Fahrweise und vom Kesselzustand abhängen. Die Prognose der Zielgröße erfolgt auf Basis der jeweiligen Eingangsgrößen-Konstellation, die systematisch optimiert wird, um den gewünschten Wert der Zielgröße zu erreichen. Parallel wird die Zuverlässigkeit der prognostizierten Stellgrößenänderungen laufend über gesonderte Netze überwacht und bewertet.

4. 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 zum Einsatz der Reinigungseinrichtungen. Weiterhin standen ergänzende Messungen zur Temperaturverteilung, zum Druckabfall im Kessel sowie bildoptische Informationen zur Ansatzbildung, die mit einer speziellen Kamera aufgenommen wurden, zur Verfügung [3]. 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. 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]. 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. Die Netzarchitektur beruht auf Feed-Forward-Netzen mit ein bis zwei verdeckten Schichten. Ihr Vorteil liegt im einfachen und robusten Aufbau.

5. Prognose

Die trainierten Feed-Forward-Netze zeichnen sich durch eine hohe Prognosequalität aus. In Bild 2 sind exemplarisch die Originalmesswerte, die geglätteten Messwerte und die Prognosewerte für NO_x dargestellt:




Bild 2: Prognose der NO_x-Emission. Messwerte (fluktuierend), geglättete Messwerte (fett) und Prognose (gestrichelt).

Eine „gute“ Prognosequalität alleine ist jedoch nicht ausreichend. Die 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 Prognosegüte. Ferner ist es für die modellprädiktive 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. Bild 3 zeigt eine solche Mehrschrittprognose: 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. 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.




Bild 3: Mehrschrittprognose der Effektivität der Heizflächen an verschiedenen Betriebspunkten (Prognosehorizont 30 Minuten).

6. Erste Ergebnisse

Ziel ist die Begrenzung der Ansatzbildung an den Heizflächen durch eine betriebspunktabhängige Verstellung der Sollwerte. Die Einhaltung der Randbedingungen (Kesselleistung, NO_x und CO) ist dabei jederzeit zu gewährleisten. Derzeit wird der Regler als „Vorschlagssystem“ im open-Loop-Betrieb als eine add-on Lösung realisiert. 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. 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. In Bild 4 sind die zeitlichen Verläufe der Heizflächeneffektivität und der NO_x -Emissionen ohne und mit Regeleingriff dargestellt. Die Regelung führt in diesem Beispiel sowohl zu einer Verminderung der Verschmutzung als auch zu einer Abnahme der NO_x -Emissionen.




Bild 4: Vergleich der prognostizierten Effektivität der Heizflächen und der NO_x-Emissionen mit und ohne Stellgrößeneingriffe.

7. Zusammenfassung

Die modellprädiktive Regelung erscheint ein erfolgversprechender Ansatz zu sein, um die Verschmutzungsproblematik des Kessels besser beherrschen zu können. Voraussetzung hierzu ist eine zuverlässige Prognose der Verschmutzung sowie der NO_x und CO Emissionen als wichtigen Randbedingungen. Die Modelle arbeiten robust und bieten die Möglichkeit, über Modellfehler und Datendichte die Vertrauenswürdigkeit zu bewerten. Mehrschrittprognosen bis zu 30 Minuten sind möglich. Mit dem neuronalen Kesselmodell kann ein modellprädiktives Reglerkonzept umgesetzt werden. Durch eine online-Datenanbindung können Handlungsempfehlungen für eine optimierte Fahrweise des Kessels abgeleitet werden, ohne wesentliche Eingriffe in die bestehende Leittechnik vornehmen zu müssen.

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)