

Künstlich Neuronale Netze zur Hochdruckdampf-Temperaturreglung

Christian Gierend, Sebastian Georg, Reinhard Schreiner, Robert von Raven und Martin Murer

1.	Einleitung.....	333
1.1.	Motiv.....	334
1.2.	Ziel	334
2.	Lösungsansatz.....	335
2.1.	Datenanalyse.....	335
2.2.	Berechnung der Heißdampf-temperatur hinter Überhitzer 1	336
2.3.	Prädiktion der Heißdampf-temperatur hinter Überhitzer 1	339
3.	Zusammenfassung und Ausblick.....	341
4.	Quellen	342

1. Einleitung

Die thermische Behandlung von Abfällen hat sich über Jahrzehnte hinweg als zuverlässige Maßnahme zur umweltschonenden Reduktion des Abfallvolumen etabliert.[4] Aufgrund der Brennstoffgegebenheiten in Abfallverwertungsanlagen kommt der Regelungstechnik eine wichtige Rolle beim zuverlässigen Anlagenbetrieb zu.

Kenntnisse über das zukünftige Prozessverhalten ermöglichen gezielte Regelungsvorgänge, die einen sanften Übergang zwischen den Zuständen gewährleisten und die Regelabweichung minimieren. Der verbleibende Fehler kann effizient durch klassische (PID-)Regler oder wissensbasierte Systeme (Fuzzy-Regler) ausgeglichen werden. Dies führt zu geringeren Abweichungen des Prozesses vom Sollzustand bei gleichzeitig optimiertem Rohstoffeinsatz und in der Folge zu einem optimierten Betrieb hinsichtlich Umweltschutz, Sicherheit und Wirtschaftlichkeit.

Künstliche Neuronale Netze (KNN) erlernen physikalische Zusammenhänge in Prozessen durch das Training mit realen Datensätzen. Ihr Funktionsprinzip ist angelehnt an die Funktionsweise biologischer Neuronen, wie sie beispielsweise im Gehirn zu finden sind. Diese Netze werden mit Datensätzen aus realen Prozessen trainiert, um Zusammenhänge zwischen Eingangs- und Ausgangsdaten zu erlernen und Einflussgrößen und Optimierungspotentiale aufzuzeigen. Ihre Stärke liegt in der Vorhersage von Ausgangsgrößen bei der Variation von Eingangsgrößen, in einem zuvor ausreichend trainierten Arbeitsraum und ohne zeitliche Varianz.

Am Beispiel eines im Jahr 2014 durchgeführten Forschungsvorhabens mit einem Auftraggeber aus dem Anlagenbau werden der aktuelle Stand in der Entwicklung von KNN, deren Fähigkeiten zur Prognose und begleitende Herausforderungen aufgezeigt.

1.1. Motiv

Das Wissen über die Zusammenhänge liegt als implizites Modell im Arbeitsraum vor und wird durch den inneren Zustand des KNN abgebildet. Aufgrund dieser Eigenschaft ist die Verifikation schwierig und in der Vergangenheit hat sich gezeigt, dass Netze, trotz guter Ergebnisse bei den Lerndatensätze, bei Testdaten versagen können.[2] Dieses Verhalten tritt bei KNN immer zu Tage und hängt damit zusammen, dass das Netz versucht das einmal gelernte undifferenziert auf alle Eingangsdaten anzuwenden, unabhängig davon ob das angebracht ist oder nicht.[3]

Bei einem eng umgrenzten Prozess sind weniger schwerwiegende Probleme zu erwarten, so dass genauere Vorhersagen und Analysen an diesem weniger komplexen System möglich sind. Damit ist es einfacher zuverlässige und reproduzierbare Ergebnisse sicherzustellen und den Arbeitsraum exakt zu definieren, wodurch ein produktiver Einsatz Künstlicher Neuronaler Netze denkbar ist.

1.2. Ziel

Ziel ist, durch den Einsatz von Künstlichen Neuronalen Netzen in einer Abfallverbrennungsanlage die Heißdampf- und deren Tendenz – hinter Überhitzer 1 mit einem Prognosehorizont von mehreren Minuten vorherzusagen, damit Einspritzregler 1 früher reagieren kann. Das Fließschema zu dieser Aufgabenstellung ist in Bild 1 dargestellt. Die Stelle der gemessenen bzw. durch das KNN vorhergesagten Temperatur ist als *Temperaturmessstelle* bezeichnet.

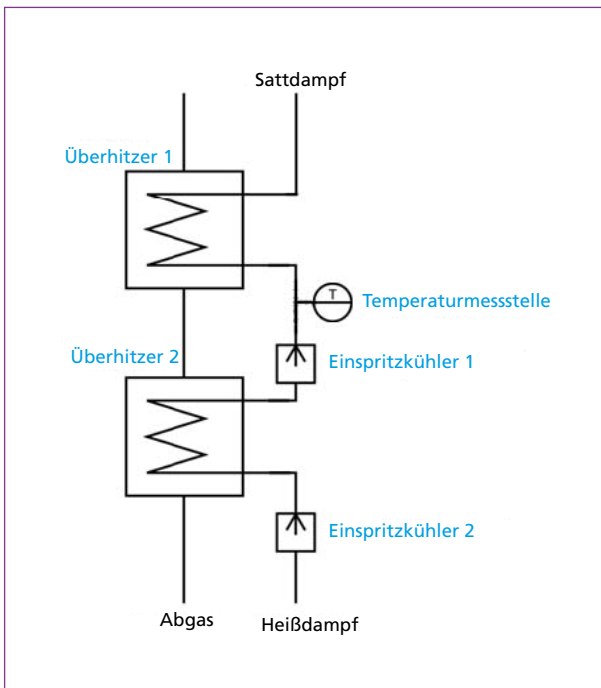


Bild 1:

Fließschema der Heißdampferzeugung

Mit KNN sollen Einflussgrößen auf die Temperatur des Heißdampfs, hinter Überhitzer 1 und vor Einspritzkühler 1, ermittelt werden. Darauf aufbauend soll das Neuronale Netz eine Prognose für die Heißdampf-Temperatur errechnen, die als zusätzliche Eingangsgröße für einen Regler dient. Mit dieser Vorhersage kann eine vorausschauende Regelung umgesetzt und die Regelgüte verbessert werden. Einspritzregler 1 wird gewählt, da der nachgeschaltete Einspritzregler 2 einem ungünstigen Regelungseingriff des Reglers 1 entgegenwirken und somit die Prozessstörung mindern kann. Es werden der aktuelle Stand in der Entwicklung von KNN und deren Fähigkeiten zur Prognose aufgezeigt.

2. Lösungsansatz

Grundlage des Trainings bilden Betriebsdaten die im Verlauf eines Jahres durch das Prozessleitsystem erfasst wurden und vom Anlagenbetreiber bereitgestellt werden. Um eine geeignete Trainingsgrundlage zu erhalten, werden die Daten gesichtet und Zeitreihen ausgewählt, die die relevanten Messgrößen bei unterschiedlichen Anlagenzuständen enthalten.

Basierend auf der Analyse der Anlagendaten werden geeignete KNN entwickelt und mit diesen Daten trainiert. Dazu kommt das Error-Back-Propagation-Verfahren zum Einsatz, das den Fehler zwischen Soll- und Istzustand beim Training effizient minimiert. Das Ergebnis ist ein KNN, welches auf die entsprechenden Anlagen trainiert ist und als Blackbox die Zusammenhänge zwischen Eingangs- und Ausgangsgrößen erlernt hat.

Die verwendeten KNN bestehen aus

- einer Eingangsschicht, in der jede Eingangsgröße durch ein Neuron abgebildet wird,
- einer verdeckten Schicht, in der jede Ausgangsgröße durch ein Neuron abgebildet wird und
- einer verdeckten Schicht, die Ein- und Ausgangsschicht miteinander verknüpft.

Während die Anzahl der Neuronen in Ein- und Ausgangsschicht festgelegt ist besitzt die verdeckte Schicht eine variable Anzahl an Neuronen, die üblicherweise zwischen zwei und 32 beträgt. Das Training erfolgte mit einer optimierten Variante des Error-Back-Propagation-Verfahrens. Diese Art von Netzen hat sich bereits in der Industrie bewährt.[1] Die Netzerstellung, das Training und die Prognose auf Basis von Testdatensätzen wird in der Software NN-Tool von Bärmann Software realisiert.

2.1. Datenanalyse

Ein Vorteil der KNN ist, dass sie selbstständig die Relevanz von Eingangsgrößen auf die Ausgangsgrößen erkennen können – Einflussanalyse. Im Verlauf des Projektes wurde die Einflussanalyse regelmäßig genutzt um die Wechselwirkungen von Eingangsgrößen und deren Bedeutung für die Ausgangsgröße zu bestimmen. Darüber hinaus wurde dieses Werkzeug eingesetzt um die optimalen Eingangsgrößen für die KNN zu bestimmen. Damit konnte in mehreren Schritten die Anzahl der Eingangssignale

von 174 auf 23 reduziert werden. Im Hinblick auf die Auswahl der Eingangssignale war auch die Kategorisierung der verfügbaren Messstellen hilfreich, die durch den Auftraggeber erarbeitet wurde.

In Bild 2 ist exemplarisch eine frühe Einflussanalyse für die Heißdampftemperatur dargestellt. Die Balken stellen den Einfluss der einzelnen Eingangsgrößen auf die Ausgangsgröße, für den betrachteten Datensatz, grafisch dar. Die Länge des Balkens ist proportional zur Stärke des Einflusses, die Richtung des Balkens gibt Aufschluss über die Art des Einflusses: Positiv korreliert – Balken nach rechts – oder negativ korreliert – Balken nach links. Dabei werden auch nichtlineare Zusammenhänge berücksichtigt. Je nach Auswahl von Eingangsgrößen, Trainingsdaten und Lernverfahren zeigen die Einflussanalysen zum Teil sehr unterschiedliche Ergebnisse. Anhand der Einflussanalyse wird eine Vorauswahl von Eingangsgrößen getroffen, die am stärksten mit dem Ausgangssignal verknüpft sind.

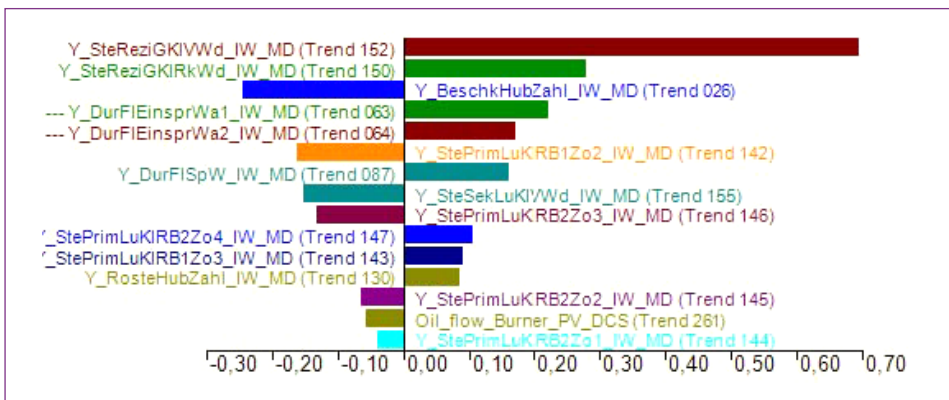


Bild 2: Einflussanalyse Heißdampftemperatur nach Kessel

Nach der Vorauswahl werden die verbleibenden Eingangsgrößen genauer untersucht. Hierbei sind insbesondere Eigenschaften wie Totzeit, Abtastrate und Signal-Rausch-Verhältnis für jedes einzelne Signal von Belang. Neben der Entscheidung ob ein Eingangssignal für das KNN geeignet ist hängt von den Eigenschaften auch eine gegebenenfalls notwendige Vorverarbeitung ab. Basierend auf diesen Erkenntnissen wurden letztendlich für das Training der KNN 23 Eingangsgrößen ausgewählt, die sich in mehreren Trainingsdurchläufen mit unterschiedlicher Datengrundlage als die wichtigsten herausgestellt haben.

2.2. Berechnung der Heißdampftemperatur hinter Überhitzer 1

Die Fähigkeiten von KNN können gut dargestellt werden, indem die Anforderung der Prognose zunächst nicht berücksichtigt wird. Es wird die Heißdampftemperatur hinter Überhitzer 1 aus dem gegenwärtigen Zustand der Anlage berechnet, um die Einspritzregelung 1 zu beeinflussen.

Um die Heißdampf­temperatur zuverlässig berechnen zu können, wurden mehrere Ansätze getestet. Die Datengrundlage wurde regelmäßig mit neuen Datensätzen aktualisiert und deren Vorverarbeitung einer Revision unterzogen.

Im Folgenden werden drei KNN vorgestellt, in welche die bisherigen Untersuchungen eingeflossen sind. Diese KNN berechnen die momentane Temperatur hinter Überhitzer 1. Es werden drei separate Datensätze zum Training genutzt, die den Anlagenzustand zu verschiedenen Zeiten über das Jahr und die Reisezeit widerspiegeln – DS1, DS2 und DS3. Die Diagramme umfassen jeweils einen Zeitraum von drei Stunden und stellen die Berechnung der KNN den tatsächlichen Messwerten gegenüber. Der hier gezeigte Vergleich wird mit Live-Daten zehn Monate nach DS3 durchgeführt.

In Bild 3 ist ein Verlauf­plot dargestellt, mit der Berechnung eines KNN, das mit Daten trainiert wurde, die kurz nach einer Kesselrevision gesammelt wurden (DS1-Daten). Trotz des großen zeitlichen Abstands zwischen Trainingsdaten und Validierungsdaten, folgt das KNN dem tatsächlichen Temperaturverlauf sehr gut. Langfristige Tendenzen werden zuverlässig vorhergesagt und die Abweichung zwischen gemessener und berechneter Temperatur ist gering. Bei niedrigen Temperaturen kann das Netz dem Temperaturverlauf nicht ganz folgen und überschätzt die Temperatur. Der Korrelationskoeffizient beträgt 0,922 und ist damit äußerst hoch, was die allgemeine Aussage zur Netzqualität stützt.




Bild 3: Netztraining mit Datensatz 1

Das zweite KNN wurde mit den DS2-Daten trainiert. Das Ergebnis ist in Bild 4 dargestellt. Die berechneten Temperaturen liegen deutlich höher als die gemessenen. Die Tendenzen stimmen gut überein und die Differenz zwischen Berechnung und Messung ist nahezu konstant. Das Netz kann nicht die gesamte Bandbreite an Änderungen abbilden. In diesem Fall sind Einflussgrößen in den Trainingsdaten unterrepräsentiert. Der Korrelationskoeffizient beträgt 0,857. Dieser Wert ist zwar niedriger als der von DS1, allerdings immer noch sehr hoch. Die Tendenzen der berechneten Werte folgen also den Messwerten sehr gut. Zur Genauigkeit der Werte macht der Korrelationsgrad keine Aussage. Die mittlere Abweichung zu den Messwerten beträgt 8,81 °C. Bezogen auf die Temperaturspanne von 315 °C bis 330 °C beträgt der relative Fehler 58,7 Prozent. Diese Abweichung ist als Eingangswert für einen Regler untauglich. Denkbar wäre allerdings die Verwendung der Ableitung des Ausgangssignals.

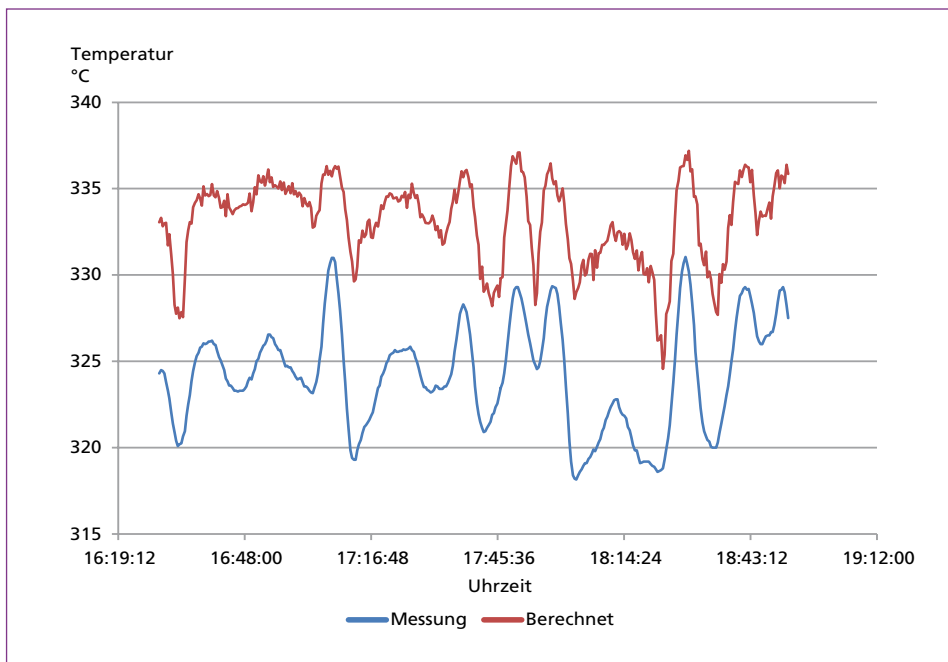


Bild 4: Netztraining mit Datensatz 2

Das dritte KNN wurde mit den DS3-Daten trainiert. Das Ergebnis ist in Bild 5 dargestellt. Hier ist kaum eine Übereinstimmung zwischen berechneten und gemessenen Temperaturen zu erkennen. Der Korrelationskoeffizient beträgt 0,508 was einer schwachen bis durchschnittlichen Übereinstimmung entspricht. Die mittlere Abweichung vom Messwert beträgt 15,7 °C, was die beobachtete Temperaturspanne der Messwerte übersteigt. In diesem Fall ist die Datengrundlage nicht geeignet um den Anlagenzustand abzubilden. Dies ist eine gefährliche Situation und muss unbedingt vermieden werden, da dem Regler sonst Werte zugeführt werden, die nichts mit dem tatsächlichen Anlagenzustand zu tun haben.

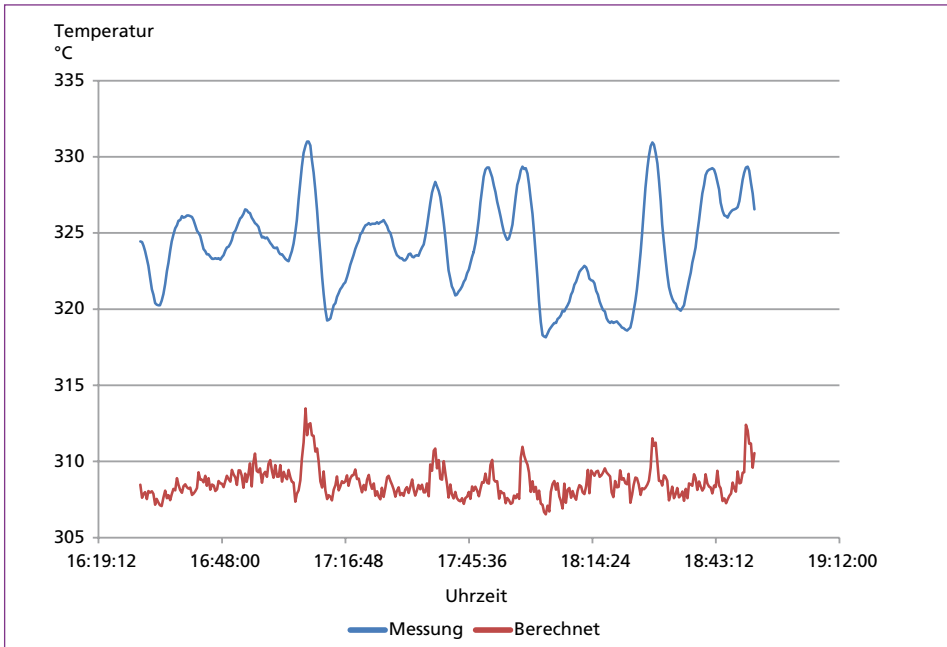


Bild 5: Netztraining mit Datensatz 3

Die Versuche zeigen, dass die Auswahl und Aufbereitung der Trainingsdaten eine wichtige Rolle spielen. Aus dem ersten Versuch, dessen Trainingsdaten zum Zeitpunkt des Versuchs mehr als zwölf Monate alt waren und dessen Vorhersage eine hohe Übereinstimmung mit den Messwerten zeigt, kann auch geschlossen werden, dass ein einzelnes KNN bei optimalem Training über längere Zeit seine Vorhersagefähigkeit bewahrt, solange der Zustand durch die Trainingsdaten abgebildet wird.

2.3. Prädiktion der Heißdampf Temperatur hinter Überhitzer 1

Um die Heißdampf Temperatur regelungstechnisch besser beeinflussen zu können ist eine voreilende Berechnung bzw. Prädiktion der Temperatur wünschenswert. Es wurden mehrere Versuche durchgeführt, in denen die Prädiktionfähigkeit der KNN im Bereich zwischen dreißig Sekunden und sechs Minuten untersucht wurde. Dabei hat sich herausgestellt, dass für einen Zeithorizont bis zwei Minuten gute bis sehr gute Ergebnisse zu erwarten sind.

In Bild 6 und Bild 7 werden Verläufe dargestellt, die die berechneten Vorhersagen der tatsächlichen Messung gegenüberstellen. Dabei werden KNN verwendet, die einen Prognosehorizont von zwei Minuten haben. Das erste dargestellte Ergebnis (P1) stammt von einem Netz, das mit allen 23 Eingangssignalen trainiert wurde. Bei dem zweiten Netz (P2) wurden Eingangsgrößen weg gelassen, die sich nach eingehender Prüfung als ungeeignet erwiesen haben. Das Training mit längeren Prognosehorizonten führt zu Netzen, die keine akzeptablen Werte vorhersagen können. Die Kurven stellen die gemessene Temperatur mit der zum gleichen Zeitpunkt vorhergesagten Temperatur gegenüber. Die Kurve der berechneten Werte ist also um zwei Minuten voreilend.

Bei P1 beträgt der Korrelationskoeffizient 0,713 was einer guten Übereinstimmung entspricht. Die mittlere Abweichung vom Messwert beträgt 2,58 °C, dies entspricht 17,2 Prozent der Temperaturspanne. Auffällig ist allerdings die starke Streuung der berechneten Werte, was auf Eingangsgrößen hindeutet, die stark mit Rauschen behaftet sind. Auch beträgt der tatsächliche Prognosehorizont, der über eine Kreuzkorrelation ermittelt wurde nur 90 Sekunden, statt der beabsichtigten zwei Minuten.

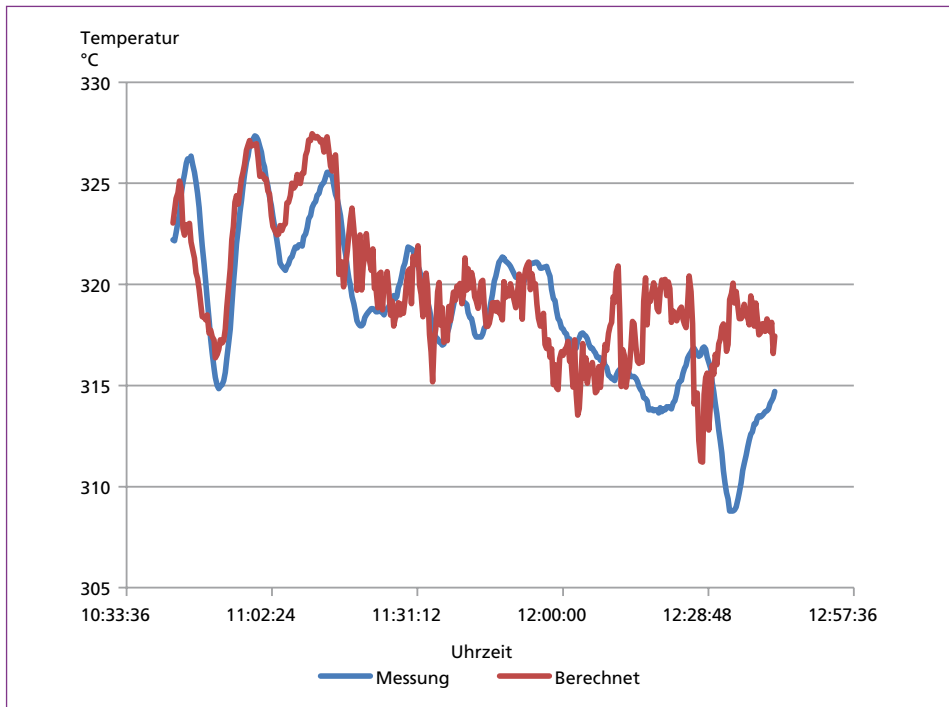


Bild 6: Prognose der Heißdampf­temperatur nach Überhitzer 1, 2 min Prognosehorizont (P1)

Bei P2 wurden Eingangssignale weg gelassen um das Verhalten beim Training und bei der Vorhersage zu verbessern, davon abgesehen wurde das Netz mit den gleichen Prämissen wie P1 erstellt. Der Korrelationskoeffizient beträgt 0,891 und ist damit sehr hoch. Die mittlere Abweichung vom Messwert ist mit 1,35 °C sehr gering und beträgt lediglich 9 Prozent der Temperaturspanne von 315 °C bis 330 °C. Auch die Streuung der berechneten Werte fällt bei P2 im Vergleich zu P1 deutlich geringer aus. Der durch Kreuzkorrelation ermittelte Prognosehorizont liegt mit 130 Sekunden dicht an dem Ziel von zwei Minuten. Dies zeigt, dass durch Revision der Eingangsdaten die Netzqualität noch einmal deutlich gesteigert werden kann.

In diesen beiden Versuchen mit Live-Daten zeigt sich deutlich die Fähigkeit, Temperaturverläufe vorherzusagen. Bei beiden Versuchen werden längerfristige Tendenzen der Temperaturverläufe zuverlässig prognostiziert. Vor allem bei P2 zeigt sich das Verbesserungspotential, wenn schnell schwankende Eingangsgrößen nicht berücksichtigt oder stärker geglättet werden und der Umfang an Eingangsdaten generell reduziert wird.




Bild 7: Prognose der Heißdampfetemperatur nach Überhitzer 1, zwei Minuten Prognosehorizont, reduzierte Menge an Eingangsgrößen (P2)

3. Zusammenfassung und Ausblick

In den Versuchen zeigt sich, dass KNN in der Lage sind, Temperaturverläufe zu berechnen und auch zukünftige Werte vorherzusagen. Das Ergebnis ist stark von dem verwendeten Trainingsdatensatz abhängig. Je nach Anlagenzustand, der durch die Trainingsdaten abgebildet wird. Die Güte der Vorhersage hängt maßgeblich von der Auswahl der Eingangsgrößen und den verwendeten Trainingsdaten ab. Trainingsverfahren und Netzstruktur haben einen geringeren Einfluss und entscheiden lediglich darüber ob das Training gelingt oder nicht.

Um die Zuverlässigkeit der KNN zu verbessern ist die Datengrundlage von großer Bedeutung. Da sich durch Verschmutzung, variable Brennstoffzusammensetzung, Umbaumaßnahmen u.ä. das Verhalten der Anlage im Laufe der Zeit ändert, ist die Gültigkeit eines optimalen KNN zeitlich begrenzt. Der Versuch ein Netz zu verwenden, das für einen anderen Zustand trainiert wurde muss zwangsläufig scheitern. Durch ein Training mit immer aktuellen Datensätzen kann die Anlage besser abgebildet werden. Das Programm zur Verarbeitung des KNN beinhaltet darum die optionale Funktion, das Netz in regelmäßigen Abständen neu zu trainieren.

Für den zuverlässigen Einsatz Neuronaler Netze müssen folgende Herausforderungen bewältigt werden:

- Jeder Anlagenzustand muss trainiert werden.
- Die Trainingsdaten müssen auf geeignete Weise vorbereitet werden.
- Es müssen Kontrollmechanismen implementiert werden, die eine Extrapolation in unzulässige Zustände verhindern.
- Eine hohe Zahl an Eingangssignalen führt zu einem komplexen Arbeitsraum, der aufwendiger zu trainieren ist.

KNN sind in der Lage Temperaturverläufe vorherzusagen. Aktuell liegt der Prognosehorizont bei zwei Minuten. Innerhalb dieses Horizonts können, bei korrektem Training und Berücksichtigung des Arbeitsraums, Änderungen der Temperatur mit Richtung und Stärke der Änderung vorhergesagt werden. Diese Vorhersage basiert auf der Berechnung von Absolutwerten.

4. Quellen

- [1] Bärmann: Technik und Algorithmen von NN-TOOL. Bärmann-Software, Düsseldorf, 2012
- [2] Gierend: Schwachstellen der Feuerleistungsregelung mit neuronalen Netzen. In: Energie aus Abfall, Band 10. Nietwerder: TK Verlag Karl Thomé-Kozmiensky, 2013
- [3] Mordvintsev: Inceptionism: Going Deeper into Neural Networks. Google, 2015. <http://google-research.blogspot.de/2015/06/inceptionism-going-deeper-into-neural.html>
- [4] Zahoransky: Energietechnik. Springer Vieweg, Wiesbaden, 2013



BORSIG SERVICE

Kraftwerksservice

Die **BORSIG Service GmbH**, Berlin, bietet national und international umfangreiche Serviceleistungen für die Energietechnik, Chemie und Petrochemie sowie Öl-, Gas- und Wasserversorgung. Mit über 160 Jahren Erfahrungen im Dampferzeugerbau verfügen wir über eine herausragende Kompetenz für Leistungen in Energie- und Dampferzeugeranlagen.

Unsere Leistungen im Einzelnen:

- Reparatur-, Wartungs- und Umbaumaßnahmen
- Laufende Instandhaltung
- Montagen und Demontagen
- Koordination von Fremdgewerken
- Durchführungen von Messungen, Analysen und Abnahmen
- Lieferung von Ersatzteilen und Austauschkomponenten nach Fremdzeichnungen oder eigener Konstruktion
- Apparate Neubau und -service
- Projekt-Engineering zur Optimierung oder Effizienzsteigerung
- Konstruktion bei Kesselumbauten und Kesselumrüstungen mit 2D- und 3D-CAD-Systemen
- Betreuung von kessel- und kraftwerkstechnischen Investitionsvorhaben
- 24-Stunden-Bereitschaft

Kompetent, schnell und kundennah - mit unserer leistungsstarken Service- und Montagemannschaft wird dieser Anspruch Wirklichkeit.

BORSIG Service GmbH

Egellsstraße 21, 13507 Berlin

Tel.: 030 / 4301-01

Fax: 030 / 4301-2771

E-mail: info@bs.borsig.de

www.borsig.de/bs





Minimierung von Emissionen thermischer Anlagen

- Rauchgasreinigungsanlagen
- Flugasche- und Rückstandsbehandlung
- Rostasche-Recycling

Marktführer in Europa
Ein großes Portfolio an verfügbaren Verfahren
Über 200 Fachleute

Kontakt:
LAB GmbH
Bludenzer Straße 6
D-70469 Stuttgart
Tel.: +49-711-222 49 35-0
Fax.: +49-711-222 49 35 99
Email: labgmbh@labgmbh.com

Engineering

Schlüsselfertige Installation
Service • Betrieb • Additive