

Datengetriebenes Prognosemodell für den BOF-Konverter – Anwendung von Data Mining in der AG der Dillinger Hüttenwerke

Hans-Jürgen Odenthal, Mike Löpke, Jochen Schlüter, Norbert Uebber
SMS Siemag AG, Eduard-Schloemann-Straße 4, 40237 Düsseldorf

Einleitung

Die maschinelle Produktion mit Dampf- und Wasserkraft bildete im 18. Jahrhundert den Ausgangspunkt der ersten industriellen Revolution. Mit der Einführung der Elektrizität und der zunehmenden Automatisierung folgte am Ende des 19. Jahrhunderts die zweite industrielle Revolution, bevor mit der Erfindung des Computers ab ca. 1970 die dritte industrielle Revolution einsetzte; hier stand die Automatisierung durch IT-Anwendungen und Elektronik im Vordergrund. Die Vernetzung von Maschinen und die Digitalisierung von Daten stehen seit Ende des 20. Jahrhunderts im Mittelpunkt der vierten industriellen Revolution. Industrie 4.0 steht für eine komplexe Vernetzung von Produktionsprozessen. Alltägliche Gebrauchsgegenstände werden zunehmend intelligent und besitzen teilweise selbst lernende Fähigkeiten. Insbesondere der letzte Aspekt ist Ausgangspunkt einer neuen Entwicklung im Bereich der stahlerzeugenden Industrie.

Bei der Stahlerzeugung ist die Einsparung von Einsatzstoffen und Energie von großer Bedeutung. Vor diesem Hintergrund sind alle technischen Entwicklungen gefragt, welche die Nachhaltigkeit und die Produktivität bei der Stahlerzeugung langfristig erhöhen. Die Methoden der Industrie 4.0 können nicht nur alternative Wege aufzeigen, sondern den Stahlherstellungsprozess auch unterstützen, so dass Stahl sich noch kostengünstiger und umweltfreundlicher produzieren lässt.

Konverterprozess

Stahl wird heute über zwei Prozessrouten erzeugt, entweder über die Elektrostahlroute, bei der Schrott in einem Elektrolichtbogenofen eingeschmolzen wird, oder über die Hochofenroute in einem integrierten Hüttenwerk. Im letzten Fall bildet der BOF-Konverter (*engl. Basic Oxygen Furnace*) ein wichtiges metallurgisches Aggregat, **Bild 1**.



Bild 1: Roheisenchargierung am 190 t BOF-Konverter der Dillinger Hütte

Im BOF-Konverter werden Roheisen und Stahlschrott eingefüllt und so genannte Schlackenbildner, wie z. B. Kalk, zugegeben. Über die Blaslanze wird Sauerstoff mit Überschallgeschwindigkeit

in die Schmelze eingeblasen, man spricht vom Frischen des Roheisens. Hierbei verbrennen die Begleitelemente, wie z. B. Schwefel, Phosphor, Kohlenstoff, und gehen in die Schlacke sowie das Abgas über. Ziel des BOF-Prozesses ist es, zum Ende des Sauerstoffblasens (Blasendpunkt, *engl. End of Blow - EoB*) eine Stahlschmelze mit definierten Eigenschaften zu erhalten. Die **Zielgrößen** sind die Abstichtemperatur T , der Kohlenstoffgehalt [%C] und der Phosphorgehalt der Schmelze [%P] sowie der Eisengehalt der Schlacke (%Fe). Im Folgenden werden diese Zielgrößen stets auf den Zustand „Blasendpunkt“ bezogen, d. h. $T = T_{EoB}$. Die **Einflussgrößen** des BOF-Prozesses, beispielhaft seien Schrott- und Roheisenmenge, verblasene Sauerstoffmenge, Menge an Kühl- und Heizmitteln oder Konverteralter genannt, korrelieren mit den Zielgrößen. Um die Zielgrößen zum Blasendpunkt vorherzusagen, werden konventionelle, so genannte metallurgische Modelle verwendet, die die Einsatzstoffe berechnen und dem Betreiber während des Prozesses weitere Korrekturvorschläge unterbreiten. Berechnet wird auch die Menge an Sauerstoff, die bis zum Blasendpunkt benötigt wird. Die Vorhersagegenauigkeit konventioneller Modelle hängt davon ab, wie exakt man die Einflussgrößen (Schrottmenge, Schrottanalyse usw.) kennt. Wird der Blasendpunkt nicht hinreichend getroffen, sind zeit- und kostenintensive Korrekturmaßnahmen (Nachblasen, Zugabe von Heiz-/Kühlmittel) erforderlich; nachteilig ist auch das Überblasen der Schmelze. In allen Fällen verringert sich das Ausbringen und es erhöht sich der Verschleiß der feuerfesten Steine im BOF-Konverter.

Metallurgische Modelle basieren auf Massen- und Energiebilanzen. Soweit möglich, werden in der Massenbilanz alle Stoffströme (Schmelze, Schlacke, Gase, Stäube), die über die Bilanzgrenzen des Konverters ein- und ausfließen, erfasst. Die Energiebilanz lässt sich auf zwei Arten realisieren. Einerseits kann mit Hilfe von Wärmekapazitäten oder mit Reaktionswärmen für Stoffumwandlungen bilanziert werden. Andererseits können den Stoffströmen auch Enthalpien zugewiesen werden, über die summiert wird. Prozessgrößen, die nicht mit fundamentalen Regeln erfasst werden können, werden als freie Parameter deklariert.

Durch neu entwickelte Verfahren zur Verarbeitung großer Datenmengen (*engl. Big Data*) ist es heute möglich, verschiedene Datenquellen oder Sensordaten zur Prognose und Regelung des BOF-Prozesses im Sinne von Industrie 4.0 zu verwenden. **Datengetriebene Modelle** sagen die Zielgröße auf der Basis von gemessenen Einflussgrößen voraus. Bei der Wahl der Einflussgrößen ist man nicht eingeschränkt, weil statistische Verfahren universell eingesetzt werden. Extrem große Datenbestände, die nicht mehr manuell zu bearbeiten sind, lassen sich mit Verfahren des Data Mining systematisch durchsuchen, mit dem Ziel, neue, d. h. charakteristische Muster zu erkennen. Die Zusammenhänge zwischen Ziel- und Einflussgrößen werden durch moderne Regressionsalgorithmen berechnet. Dies können lineare Regressionen oder die im Folgenden beschriebenen Stützvektormethoden (*engl. Support Vector Machine - SVM*) mit Kernfunktion sein. Je mehr sinnvolle Daten für die Modellierung verwendet werden, umso zuverlässiger ist die Vorhersage. Voraussetzung für hochdimensionale Berechnungen ist, dass aus der gesamten Datenmenge eine Teilmenge an Trainingsdaten, man spricht auch von Lerndaten, entnommen werden.

Kooperationspartner

Im Rahmen einer Kooperation zwischen der AG der Dillinger Hüttenwerke (DH), der Technischen Universität Dortmund (TUD), Lehrstuhl für Künstliche Intelligenz, Prof. Dr. Morik, und der SMS Siemag AG (SMS) wurde ein datengetriebenes Prognosemodell (*engl. Data-driven Prediction Model - DdPM*) für den BOF-Konverter entwickelt. Primäres Ziel ist es, die Vorhersagegenauigkeit der vier Zielgrößen T , [%P], [%C], (%Fe) zum Blasendpunkt am 190 t BOF der Dillinger Hütte zu verbessern.

In die L1/L2-Prozessautomation der Dillinger Hütte wurde ein IBA-PC integriert, um die Prozessdaten zu erfassen. **90 statische Prozessgrößen**, wie z. B. Roheisengewicht, Schrottgewicht, Roheisenanalyse, Konverteralter und Lanzentalter, werden auf diese Weise detektiert. Zu den statischen Prozessgrößen zählen auch bestimmte Ereignisse, wie z. B. Zeitpunkt und Menge der zugegebenen Heizmittel (Ferro-Silizium - FeSi) und Kühlmittel (Erz, Dolomit).

Um die Vorhersagegenauigkeit weiter zu erhöhen, werden **36 dynamische Prozessgrößen**, wie z. B. Abgaszusammensetzung (CO , CO_2 , O_2), Kühlwassermenge und Kühlwassertemperatur, mit

bis zu 1 kHz gemessen. Neben dieser konventionellen Messtechnik wurden weitere Sensoren aus den Bereichen Schwingung, Schall und Optik installiert: Ein 3D-Beschleunigungssensor an der Lanze, ein Mikrofon am Konvertermund und ein Strahlungspyrometer zur Überwachung der Abgasflamme, **Bild 2**. Grundsätzlich sind weitere zeitabhängige Messgrößen denkbar.

Insgesamt stehen 126 Prozessgrößen für das datengetriebene Prognosemodell zur Verfügung.

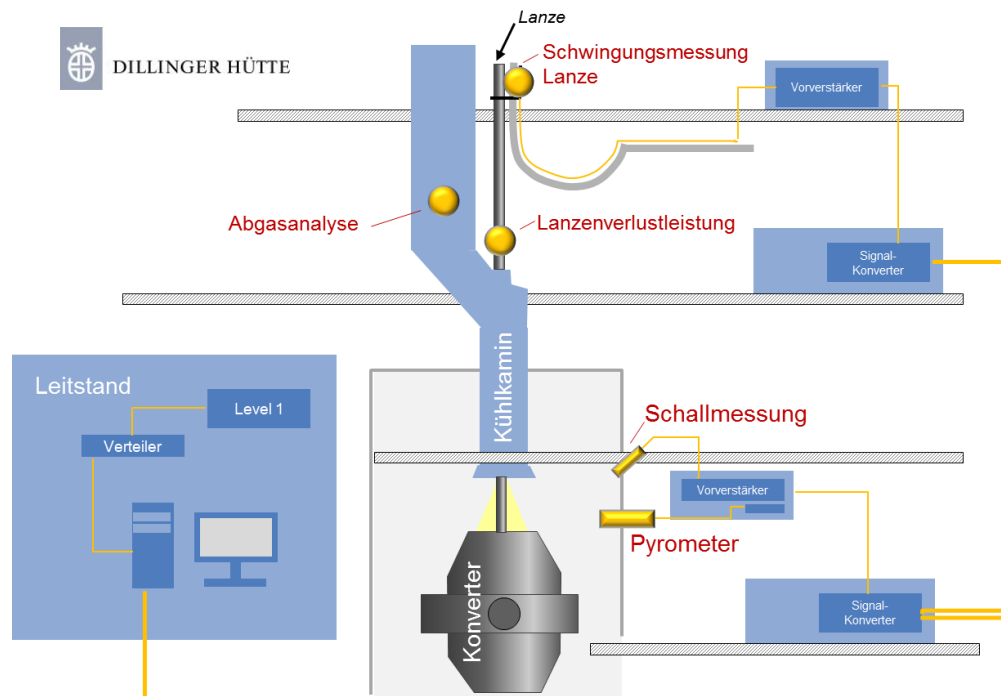


Bild 2: Übersicht der Infrastruktur der Messsysteme am 190 t BOF-Konverter der Dillinger Hütte

Datengetriebenes Prognosemodell

Nach der Einbindung des datengetriebenen Prognosemodells in die L1/L2-Prozessautomation der Dillinger Hütte zeigte sich, dass die Daten- und Modellhandhabung (Sammeln/Aufbereiten von Rohdaten, Lernen des Modells, Modellprognose, Statistik) sehr zeitaufwändig war, weil viele Datensätze manuell bearbeitet werden müssen. Daher wurde entschieden, eine objektbasierte Speicherung auf Basis eines SQL-basierten Indexes zu entwickeln, mit der sich große Datenmengen effizient speichern und über den SQL-Index abrufen lassen. Die Datenbank verwaltet folgende Datenobjekte:

- **Rohdaten:** Daten, die aus der L1/L2-Prozessautomation in der Reihenfolge ihrer Übermittlung in Dateien abgespeichert werden. Zu den Rohdaten gehören alle statischen und dynamischen Daten.
- **Aufbereitete Prozessdaten:** Daten, die synchronisiert, bereinigt sowie für das Modelllernen und die Modellanwendung nutzbar sind, werden direkt in der Datenbank gespeichert. Nicht nutzbare Daten werden auf Basis definierter Regeln oder Statistiken identifiziert.
- **Prozessmerkmale:** Ausgewählte Prozessgrößen, die mit den Zielgrößen direkt zusammenhängen, wie z. B. Startkohlenstoffgehalt des Roheisens, maximaler CO₂-Gehalt im Abgas während einer Charge. Die Prozessgrößen werden in der Datenbank gespeichert. Prinzipiell können alle aufgezeichneten Rohdaten auch Prozessmerkmale sein. Aus Effizienz- und Redundanzgründen (Rechenleistung, begrenzte Lerndatensätze usw.) werden nur bestimmte Prozessmerkmale verwendet. Es ist auch möglich, neue Prozessmerkmale zu konstruieren, z. B. den nicht direkt messbaren Wärmestrom des Lanzenkühlwassers aus Wassermenge, spezifischer Wärmekapazität und Differenz der Kühlwassertemperatur.

- **Prozessmetadaten:** Daten, die zur Bewertung des BOF-Prozesses benötigt werden, wie z. B. Sensorverfügbarkeit oder Prozessklassifikation (vor, während oder nach dem Blasen).
- **Gelernte Submodelle:** Für jede Zielgröße ist mindestens ein gelerntes Submodell vorhanden. Das Konzept sieht weiterhin vor, für jede Zielgröße mehrere Submodelle bereit zu stellen, die sich in Art und Auswahl der Prozessmerkmale und Trainingsdatensätze unterscheiden.
- **Ergebnisse der Submodelle:** Die Submodelle werden entsprechend ihrer Güte (z. B. absoluter Fehler, Standardabweichung) angewendet. Die Vorhersageergebnisse einzelner Chargen und die Submodellgüte werden in der Datenbank abgespeichert.

Die Softwareumgebung, wie sie am 190 t BOF-Konverter der Dillinger Hütte realisiert wurde, besteht aus den folgenden Modulen:

(1) Datenerfassung: Die statischen und dynamischen Prozessdaten aus der L1/L2-Prozessautomation werden durch den IBA-PC erfasst. Generell ist die Datenerfassung so aufgebaut, dass die Daten, auch manuell eingegebene, von unterschiedlichen Aggregaten/Konvertern/Sensoren stammen können.

(2) Verbindung/Synchronisierung: Alle Datensätze werden zu einem **Datenstrom** zusammengefasst, zeitlich synchronisiert und auf Konsistenz überprüft. Für jede Charge werden die zu einem Datenstrom aufbereiteten Rohdaten mit 1 kHz aufgezeichnet.

Es ist eine Basis geschaffen worden, um einzelne Chargen zu einem späteren Zeitpunkt aus der Datenbank zu extrahieren und zu analysieren (Offline-Modus). Am Büroarbeitsplatz (Stichwort: **Stahlwerk im Büro**) lassen sich Testrechnungen, so genannte Playback-Experimente, mit verschiedenen Prognosemodellen und Chargen durchführen. Eine Online-Anbindung für Testrechnungen ist nicht mehr notwendig.

(3) Stahlwerkdatenbank: Grundsätzlich können historische Daten aus der Datenbank des Stahlwerks verwendet werden; diese Option wurde in der Dillinger Hütte nicht genutzt.

(4) Datenmanagement: Alle Datenströme zwischen der Datenbank und den übrigen Modulen werden durch das zentrale Datenmanagement gesteuert. Das Datenmanagement ermöglicht den Zugriff auf alle Modellebenen und zu allen Daten.

(5) Vorverarbeitung der Daten: Die synchronisierten und zusammengefassten Rohdatenströme werden aufbereitet und formatiert. Diese Rohdatenströme enthalten fast immer fehlerhafte Werte, weil z. B. Sensoren defekt sind. Diese Ausreißer werden identifiziert und automatisch durch sinnvolle Werte ersetzt. Darüber hinaus ist die Datenaufbereitung Voraussetzung für die nachfolgende Normierung.

Die automatische Auswahl relevanter Prozessmerkmale ist der Schlüssel für die Qualität des maschinellen Lernens. Zusätzlich werden einige Merkmale aus den Rohdaten konstruiert und in Echtzeit extrahiert. Prozessmerkmale haben bestimmte Größenordnungen ($0 < \text{Roheisengewicht} < 10^5$ kg; $0 < \text{Schwefelgehalt Roheisen} < 10^{-3}$ ppm). Um Konvergenzprobleme im Zusammenhang mit der Skalierung und der numerischen Vorverarbeitung zu vermeiden, werden alle Prozessmerkmale 0-1-normiert.

(6) Lernen Submodelle: Je Zielgröße wird ein Submodell mit der nicht-linearen Regression der Support Vector Machine gelernt. Die SVM ist ein mathematisches Verfahren zur Klassifikations- und Regressionsanalyse. Ausgangspunkt bildet die Darstellung der Prozessdaten als Ortsvektoren in einem Vektorraum bzw. Hilbert-Raum.

Für eine Regressionsrechnung werden hunderte von Trainingschargen (Trainingsdaten, Lerndaten) verwendet. Die SVM ermittelt für jede Zielgröße eine eigene Funktion, welche die Abhängigkeit von den Prozessmerkmalen widerspiegelt, also z. B. Abstichtemperatur = $f(\text{Prozessmerkmale})$.

In der Regel sind diese Zusammenhänge nicht linear, so dass die herkömmliche lineare Regression versagt. Die SVM benutzt so genannte Kernfunktionen, um die Prozessmerkmale in einen höherdimensionalen Raum zu transformieren. In diesem höherdimensionalen Raum können die Daten linear durch eine Hyperebene getrennt und der Zusammenhang zwischen Ziel- und Einflussgröße kann hinreichend genau beschrieben werden. Dabei wird die Hyperebene durch soge-

nannte Stützvektoren (*engl. support vector*) bestimmt. Es wird die Hyperebene gewählt, bei der der Abstand zwischen Hyperebene und dem zur Hyperebene nächstgelegenen Stützvektor maximal wird. Um das Submodell zu lernen, wird ein Optimierungsproblem gelöst. Letztlich erhält man einen nichtlinearen Zusammenhang der Form:

$$T = f(m_{HM}, T_{HM}, m_{scrap}, \max O_2, \min CO_2, \dots) \quad (1)$$

Das Lösen des Optimierungsproblems der SVM auf den Trainingschargen bezeichnet man als „Lernen des Modells“. Sowohl die Auswahl der Merkmale als auch die Auswahl der Trainingschargen beeinflussen die Modellgüte. Die SVM ist Bestandteil der RapidMiner-Software, die in das datengetriebene Prognosemodell integriert ist. Die gelernten Submodelle der Zielgrößen werden durch das Submodellmanagement verwaltet.

(7) Submodellmanagement: Bei einer Verschlechterung Submodellgüte wird entweder ein neues Submodell gelernt oder ein anderes, bereits gelerntes Submodell verwendet. Die Entscheidung, welche Lern- und Anwendungsprogramme genutzt werden, wird vom Submodellmanagement getroffen.

(8) Anwendung Submodelle: Das gelernte Submodell anwenden bedeutet, die Zielgröße mit der gelernten Zielfunktion unter Berücksichtigung aktueller Prozessdaten vorherzusagen. Die Rechenzeit hierfür beträgt ca. 1 ms, man kann daher von einer echten Online-Applikation sprechen. Das Modul ermittelt auch die Submodellgüte, die im Stahlwerk typischerweise durch Erwartungswert $E(x)$ und Standardabweichung $\sigma(x)$ der Zielgröße x bestimmt ist.

(9) Darstellung und Benutzereingabe (*engl. Human Machine Interface - HMI*): Prozessmerkmale und -ergebnisse werden in Form von alphanumerischen Werten und Diagrammen angezeigt. Ab ca. 80 % der verblasenen Sauerstoffmenge zeigt das datengetriebene Prognosemodell die Werte für T , [%C], [%P], (%Fe), die zum Blasenpunkt vorhergesagt werden. Eine zeitlich kontinuierliche Darstellung dieser Größen über die Blasdauer ist nicht erforderlich.

Das HMI ist in **Bild 3** dargestellt. In Spalte (1) werden die aktuelle Roheisenmenge und -analyse sowie die Schrottmenge angezeigt.

Spalte (2) zeigt die Bestellrechnung für T , [%C], [%P] und (%Fe). Die aktuellen Mengen an Zuschlagstoffen und die aktuell verblasene Sauerstoffmenge zeigt Spalte (3).

Die vom metallurgischen Modell vorhergesagte gesamte Sauerstoffmenge zeigt Spalte (4). Diese Informationen dienen nur der Orientierung des Betreibers, sie sind für das datengetriebene Prognosemodell nicht erforderlich.

Die Vorhersagen des datengetriebenen Prognosemodells zum Blasendpunkt ohne Korrekturmaßnahme zeigt Spalte (5), mit Korrekturmaßnahme Spalte (6). Zum aktuellen Zeitpunkt sagt das Modell die Temperatur $T_{\text{Vorhersage}} = 1720^\circ\text{C}$ zum Blasendpunkt voraus, die um 20°C unter der Zieltemperatur $T_{\text{Ziel}} = 1740^\circ\text{C}$ liegt. Das Modell empfiehlt, 300 kg Ferro-Silizium (FeSi) als Heizmittel und 800 kg an Kalk zur SiO_2 -Abbindung zuzugeben. Die mit dieser Maßnahme vorhergesagte Temperatur beträgt dann $T_{\text{mit Korrektur}} = 1738^\circ\text{C}$. Zu erwähnen ist, dass das HMI speziell an die Wünsche der Dillinger Hütte angepasst ist.

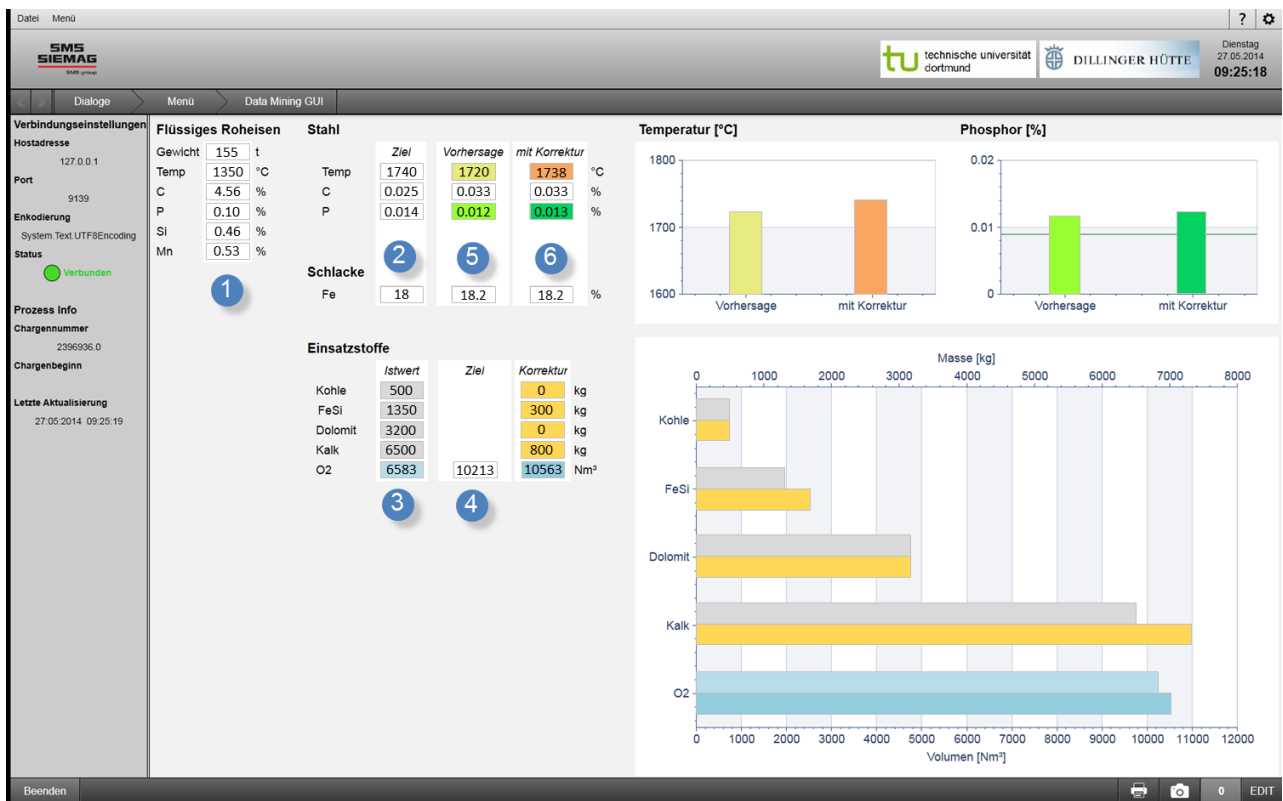


Bild 3: Bildschirmanzeige (engl. *Human Machine Interface - HMI*) des datengetriebenen Prognosemodells, realisiert im Leitstand der Dillinger Hütte

Tabelle 1 zeigt den Vergleich zwischen den vorhergesagten Zielwerten des konventionellen, metallurgischen Modells und denen des datengetriebenen Prognosemodells. Die Standardabweichung wurde für 200 aufeinanderfolgende Chargen ermittelt, die Lernbasis beruht auf 1950 Chargen, die im April 2014 aufgezeichnet wurden. Die Temperatur T zum Blasendpunkt wird durch das datengetriebene Modell deutlich genauer prognostiziert. Zudem ist das neue Modell in der Lage, auch die Zielgrößen [%P], [%C] und (%Fe) vorherzusagen, was mit dem konventionellen Modell nicht möglich ist.

Tabelle 1: Standardabweichung σ der Prozessgrößen am Blasendpunkt, (kleiner ist besser), 190 t BOF

Zielgröße ¹⁾	σ - Konventionelles Modell	σ - Datengetriebenes Prognosemodell ²⁾	Einheit
T	23.0	16.2	°C
[%P]	n.a.	25	ppm
[%C]	n.a.	55	ppm
(%Fe)	n.a.	1.4	%

¹⁾ ohne Sublanzenmessung, ²⁾ ohne Korrekturmaßnahmen

Wirtschaftlicher Gewinn

Zur Beantwortung der Frage, wie hoch der wirtschaftliche Gewinn bei der Stahlerzeugung ist, wenn anstelle des bisherigen Prognosemodells das neue datengetriebene Prognosemodell verwendet wird, müssen viele Teilaspekte berücksichtigt werden. Der Gewinn errechnet sich u.a. anhand folgender Aspekte:

- Erhöhung der Stahlproduktion durch die Reduzierung der Nachblasrate und der Überblasrate.
- Verringerung der Prozesskosten (z. B. Energie) und Einsatzstoffe (z. B. Sauerstoff, Heizmittel, Kühlmittel).
- Verringerung des Verschleißes der feuerfesten Konverterausmauerung.
- Erhöhung des so genannten Ausbringens von Stahl aus dem Konverter.
- Reduzierung von Personalkosten.

Je nach Stahlwerk und Produktionsprozess sind diese Faktoren unterschiedlich gewichtet.

Nimmt man für den 190 t Konverter der Dillinger Hütte eine Verbesserung der Temperatureffizienz um 5°C an, so ergibt sich ein **Einsparpotential** pro Jahr von rd. 0.5 Mio € durch die Reduzierung der Heizmitteln und der Nachblasrate, und setzt eine Stahlproduktion von 2 Mio. t/a an,.

Fazit

- Das neu entwickelte, datengetriebene Prognosemodell hat die Fähigkeit, selbstständig aus großen Datenbeständen zu lernen und in Echtzeit vorherzusagen.
- Mit dem datengetriebenen Prognosemodell konnten signifikant bessere Ergebnisse erzielt werden als mit dem konventionellen Modell.
- Das System steuert den Blasprozess, indem Korrekturvorschläge in Echtzeit ermittelt werden.
- Das Software-System und die Algorithmen sind robust aufgebaut und arbeiten seit vielen Monaten zuverlässig in der IT-Umgebung des Stahlwerks der Dillinger Hütte.
- Die Verbesserungspotentiale hinsichtlich Datennutzung und Modellmanagement sind in der jetzigen Entwicklungsphase noch nicht ausgeschöpft.
- Datengetriebene Prognosemodelle besitzen keine fixierten physikalischen Regeln zur Vorhersage. Die Modelle lassen sich bei vorhandener Datenbasis und mit Hilfe des neu entwickelten Softwaresystems mit vergleichsweise wenig Aufwand auf andere Anwendungen übertragen. Dies gilt sowohl für die Anwendung auf andere Konverter als auch auf andere metallurgische Aggregate.
- Auch wenn datengetriebene Prognosemodelle im Grundsatz eine andere Methodik verwenden als herkömmliche, metallurgische Modelle, so gibt es keinen Grund, eines dieser Konzepte exklusiv betreiben zu müssen. Vielmehr ist anzustreben, die vielfältigen Möglichkeiten zu nutzen, beide Welten miteinander zu kombinieren. Neben dem außerordentlichen Potential, Leistungsfähigkeit und Nutzungsbreite des datengetriebenen Prognosemodells auszubauen, wird die effiziente Kombination mit metallurgischen Modellen zu den zukünftigen Aufgaben gehören.