

AUTONOME SYSTEME

Zustandsüberwachung von Mühlenpanzerungen durch maschinelles Lernen

Um eine übermäßige Abnutzung der Trommeln von Erzmühlen zu verhindern, werden diese mit austauschbaren Panzerungen ausgestattet. ABB und die Berner Fachhochschule haben ein Überwachungssystem für Mühlenpanzerungen entwickelt, das mithilfe von Beschleunigungssensoren und maschinellen Lernverfahren den besten Zeitpunkt zum Austausch der Panzerung bestimmt und somit Stillstandskosten reduziert.

—
Venkat Nadipuram
 ABB Process Industries,
 Mining, Aluminium and
 Cement
 Baden-Dättwil, Schweiz

venkat.nadipuram@
 ch.abb.com

—
Marco Jordi
Prof. Dr. Axel FÜRST
 Berner Fachhochschule
 Institut für Intelligente
 Industrielle Systeme I3S
 Burgdorf, Schweiz

In großen Bergwerken wird das Erz vor Ort gemahlen, um wertvolle Mineralien zu gewinnen. Die Mühlen, die diese Extraktion durchführen, bestehen aus einer großen Trommel, in der das Erz und ggf. auch Stahlkugeln den physikalischen Mahlprozess durchführen. Während sich die Trommel dreht, werden das Erz und die Stahlkugeln im Mühleninneren durch das Profil der Panzerung bis zum sogenannten Kaskadenwinkel gehoben. Dann fällt das Erz ins Mahlbett und wird zerschlagen bzw. rutscht ins Mahlbett und wird zerrieben.

Mit einem Durchmesser von bis zu 10 m sind solche Trommeln sehr teuer. Um Schäden zu verhindern, werden sie daher mit speziellen Panzerungen aus Metall oder Gummi versehen. Da auch der Austausch dieser Panzerungen aufgrund der erforderlichen Stillstandzeit und Ersatzteile mit hohen Kosten verbunden ist, sollte der Austausch so spät wie möglich, aber auch zu einem Zeitpunkt erfolgen, an dem sich die Produktionseinbußen in Grenzen halten. Dies lässt sich nur erreichen, wenn die tatsächliche Abnutzung der Panzerung bekannt ist. Der Verschleiß lässt sich zwar im Mühleninneren messen, doch auch hierfür muss die Produktion unterbrochen werden. Wünschenswert ist also ein Verfahren, das eine Verschleißerkennung im laufenden Betrieb ermöglicht →1.

Schwingungsüberwachung


Wenn das Erz auf die Panzerung trifft, entstehen Schwingungen. Die Tatsache, dass diese Schwingungen und deren Übertragungsfunktion sich mit der Dicke der Panzerung verändern, liefert einen Ansatz zur Messung des Verschleißes. Dies hat ABB und das Institut für Intelligente Industrielle Systeme (I3S) der Berner Fachhochschule dazu veranlasst, Frequenzgang- und transiente Simulationen durchzuführen, um dieses Verhalten genauer zu untersuchen. Die Ergebnisse zeigen eindeutig, dass die Amplitude des Beschleunigungssignals einer abgenutzten Panzerung höher ist als die einer neuen Panzerung.

—
Der Austausch sollte so spät wie möglich und zu einem Zeitpunkt erfolgen, an dem sich die Produktionseinbußen in Grenzen halten.


Um diese Erkenntnisse zu verifizieren, wurde zunächst ein maßstabgetreues Modell einer Mühle erstellt →2, weil der Zugang zu einer echten

—
 01 Die Überwachung des Verschleißes von Panzerungen in Erzmühlen mit hohem Durchsatz ist entscheidend, wenn es darum geht, die Prozessverfügbarkeit zu maximieren. Das Bild zeigt eine Mühle in einem Bergwerk von Boliden im schwedischen Garpenberg, wo mindestens seit 375 v. Chr. Bergbau betrieben wird. Heute werden in dem Bergwerk jährlich 2,5 Millionen Tonnen Erz abgebaut.





02a



02b

Erzmühle im Betrieb nicht ohne Weiteres möglich ist. An diesem Modell wurde eine Vielzahl von experimentellen Messungen mit unterschiedlichen Panzerungsdicken durchgeführt. Die Messdaten wurden mithilfe von tiefen neuronalen Netzen analysiert und mit hoher Genauigkeit nach Verschleißklassen klassifiziert.

Zur Übertragung dieses Verfahrens vom Labormaßstab auf eine reale Mühlenumgebung wurden entsprechende Messungen an einer echten Erzmühle durchgeführt. Mithilfe dieser Daten entwickelten das I3S und ABB einen Prototyp, der die Messung des Panzerungszustands und der Prozessparameter einer Mühle im laufenden Betrieb ermöglicht.

Simulationen

Frequenzganganalysen und transiente Simulationen von Panzerungsmodellen nach der Finite-Elemente-Methode (FEM) in ANSYS [1] bekräftigten die Idee, dass das Beschleunigungssignal, das jeweils

durch das Auftreffen des Erzes auf der Trommelwand verursacht wird, bei neuen und abgenutzten Panzerungen einen messbaren Unterschied aufweist. So sind z. B. die Frequenzen bei einer abgenutzten Panzerung höher als bei einer neuen, da sich die Dämpfungseigenschaften des Gummis mit zunehmendem Verschleiß verschlechtern. Die größten messbaren Unterschiede bei den Simulationen liegen jedoch in den Amplituden →3. Dies stimmt mit der Theorie überein, dass eine dünne Gummischicht zu einem stärkeren Stoß führt, was wiederum höhere Anregungskräfte hervorruft.

Panzerungsverschleiß


Die Dicke der Panzerung wurde indirekt mithilfe von Beschleunigungssensoren an der Außenseite der Modelltrommel gemessen.

Aus dem Rohsignal dieser Sensoren wurden durch Vorverarbeitung Merkmale extrahiert, die in einem tiefen neuronalen Netz zur Mustererkennung verwendet werden können. Das zur Klassifizierung der Panzerungsdicke verwendete Mustererkennungsnetz („patternet“) umfasste eine Eingabeschicht, drei versteckte Schichten mit jeweils 500 Neuronen und eine Ausgabeschicht.

Die Ergebnisse zeigten eine sehr hohe Genauigkeit von nahezu 98 %, d. h. nur 2 % aller Messdatensätze wurden falsch klassifiziert.

Mithilfe dieser Konfiguration wurden sowohl die am maßstäblichen Modell als auch die in den Feldversuchen gewonnenen Daten klassifiziert. Im Labor wurden sieben verschiedene Panzerungszustände mit Dicken zwischen 2 und 17 mm und verschiedenen Lasten mithilfe des Modells simuliert. Das Ziel bestand darin, das vorverarbeitete Signal in eine von sieben entsprechenden Klassen einzuordnen. Die Ergebnisse zeigten eine sehr hohe Genauigkeit von nahezu 98 % für die Messungen am Modell, d. h. nur 2 % aller Messdatensätze wurden falsch klassifiziert. Dies spiegelt die Ergebnisse der Trainings- (70 %) und der Testdaten (30 %) wider. →4 zeigt die Konfusionsmatrix der Testdaten. Darin ist zu sehen, dass auch die Daten, die nicht korrekt klassifiziert wurden, in der Nähe der Diagonalen erscheinen, d. h. der Klassifizierungsfehler ist gering.

Auch die Ergebnisse der Feldmessungen wiesen eine hohe Genauigkeit auf. Hier war aufgrund der Umwelteinflüsse zwar eine deutlich geringere



03

02 Maßstabgetreues Modell

02a Modell einer Autogenmühle für Versuchsmessungen im Labor. Das Modell besteht aus einer Stahltrommel, die über einen Zahnriemen von einem kleinen Elektromotor angetrieben wird. Eine austauschbare Gummischicht im Trommelinneren simuliert die Panzerung.

02b Funktionszeichnung des Modells mit Ablöse- und Auftreffwinkel sowie WLAN-Beschleunigungssensor zur Messung der Schwingungen an der Trommelaußenseite. Das Beschleunigungssignal ist die abhängige Variable, die Panzerungsdicke und Mühlenlast sind unabhängige Variablen, Drehzahl, Temperatur, Erzgröße und -qualität sind kontrollierte Variablen. Gemessen wurden Panzerungsdicken von 2–17 mm bei Lasten von 1–4 kg, wobei für jeden Zustand mindestens zwei Beschleunigungsmessungen von 2 min mit einer Abtastfrequenz von 970 Hz durchgeführt wurden.

03 Beschleunigungssignale einer transienten Simulation mit einer neuen und einer abgenutzten Panzerung. Das Signal der abgenutzten Panzerung weist aufgrund der geringeren Dämpfung höhere Amplituden und Frequenzen auf.

04 Konfusionsmatrix zur Klassifizierung der Panzerungsdicke in sieben Klassen (2, 5, 7, 10, 12, 15, 17 mm) auf Basis der Messungen am maßstäblichen Modell.

Genauigkeit zu erwarten, doch mit einem angepassten tiefen neuronalen Netz auf der Basis von Tensorflow [2] konnte dennoch eine relativ hohe Genauigkeit von 82,9 % erreicht werden. Das Ziel ist es, eine weitere Verbesserung der Genauigkeit durch mehr Trainingsdaten zu erreichen.

Ablöse- und Auftreffwinkel

Die Kaskadenwinkel in der Erzmühle wurden mithilfe der Beschleunigungssignaldaten von einer Umdrehung der realen Mühle bestimmt. Das Beschleunigungssignal einer Umdrehung ist in →5 dargestellt. In der Auftreffzone, in der die Steine auf die Panzerung treffen, sind hohe Amplituden zu erkennen. Auch im Bereich des Ablösewinkels, an dem sich die Steine von der Panzerung lösen,

treten Signalveränderungen auf. Diese entstehen dadurch, dass die Erzbrocken in diesem Bereich lose aufeinander liegen. Der Kraftvektor verschiebt sich dabei mit der Position des Erzes, und das Erz beginnt, das Erzbett zu verlassen und in Richtung Bettmittelpunkt zu rutschen, was Schwingungen am Mühlenmantel verursacht.

Zur Bestimmung des Ablöse- und Auftreffwinkels wird die Informationsentropie des Signals berechnet. Die Entropie des Signals (über ein bestimmtes gleitendes Fenster) repräsentiert die im Signal enthaltene Menge an Informationen [3]. Mit anderen Worten, je zufälliger und unvorhersehbarer das Beschleunigungssignal aufgrund der Stöße ist, desto größer ist seine Entropie. Dank dieser Berechnung lassen sich Veränderungen im Beschleunigungssignal und somit der Ablöse- und Auftreffwinkel erkennen. Ein wichtiger Parameter ist die Fensterlänge des errechneten Index. In diesem Fall liefert eine Fensterlänge von 1.180 Abtastwerten gute Ergebnisse.


Mit einem angepassten tiefen neuronalen Netz auf der Basis von Tensorflow konnte eine relativ hohe Genauigkeit von 82,9% erreicht werden.

Konfusionsmatrix


Ausgangsklassen	1	2	3	4	5	6	7	
1	159 14,2 %	0 0,0 %	0 0,0 %	1 0,1 %	0 0,0 %	1 0,1 %	1 0,1 %	98,1 % 1,9 %
2	0 0,0 %	159 14,2 %	0 0,0 %	0 0,0 %	0 0,0 %	0 0,0 %	1 0,1 %	99,4 % 0,6 %
3	0 0,0 %	0 0,0 %	160 14,3 %	0 0,0 %	0 0,0 %	0 0,0 %	0 0,0 %	100 % 0,0 %
4	0 0,0 %	0 0,0 %	0 0,0 %	153 13,7 %	0 0,0 %	5 0,4 %	1 0,1 %	96,2 % 3,8 %
5	0 0,0 %	0 0,0 %	0 0,0 %	0 0,0 %	153 13,7 %	1 0,1 %	3 0,3 %	97,5 % 2,5 %
6	1 0,1 %	0 0,0 %	0 0,0 %	6 0,5 %	0 0,0 %	153 13,7 %	1 0,1 %	95,0 % 5,0 %
7	0 0,0 %	1 0,1 %	0 0,0 %	0 0,0 %	7 0,6 %	0 0,0 %	153 13,7 %	95,0 % 5,0 %
	99,4 % 0,6 %	99,4 % 0,6 %	100 % 0,0 %	95,6 % 4,4 %	95,6 % 4,4 %	95,6 % 4,4 %	95,6 % 4,4 %	97,3 % 2,7 %
	1	2	3	4	5	6	7	

Zielklasse

04



05



06

Feldversuche

Zur Verifizierung der mathematischen Modelle wurden Feldversuche durchgeführt. Dabei wurde die empfindliche Sensorausrüstung mit einem robusten Metallgehäuse gegen die raue und schmutzige Mühlenumgebung geschützt. Die Ausrüstung umfasste eine Batterie, einen Zeitgeber, mehrere Treiber für die Beschleunigungssensoren, einen Analog-Digital-Wandler und ein Datenerfassungsgerät. Die Beschleunigungssensoren selbst wurden mit Magneten direkt an der Mühltrommel befestigt. Das System wurde an einer in Betrieb befindlichen Mühle installiert, wo es über einen Zeitraum von mehreren Wochen Daten erfasste.

Da das Schwingungssignal aufgrund der vielen Stöße stark verrauscht ist, müssen die Rohdaten vorverarbeitet werden.

Datenanalyse mit maschinellen Lernverfahren

Da das Schwingungssignal aufgrund der vielen während der Rotation aufgezeichneten Stöße stark verrauscht ist und sich die verschiedenen Panzerungszustände nur schwer unterscheiden lassen, ist eine Vorverarbeitung der Rohdaten erforderlich. Und da die Anwendung maschineller Lernalgorithmen nur mit einer standardisierten Datenbasis möglich ist, wurde in vielen Iterationen das bestmögliche Klassifizierungsmodell bestimmt.

Vorverarbeitung der Daten

Die Tatsache, dass der Mühlendrehwinkel beim Start der Messungen nicht immer derselbe ist, führt zu Unterschieden zwischen den Datensätzen. Doch da für eine einwandfreie Auswertung eine einheitliche Datenbasis erforderlich ist, wurde ein Phasendetektor in das System integriert. Das Ursprungssignal wurde durch einen Tiefpassfilter (mit einer Grenzfrequenz von 2 Hz) gefiltert und anschließend einer Kurvenanpassung und Trendbereinigung unterzogen. So konnte die Phase in den

05 Polardiagramm der Ablöse- und Auftreffwinkel bei einer Umdrehung einer realen Erzmühle.

06 Vorverarbeitung der Beschleunigungsdaten. Das verschobene Signal wird aus dem Ursprungssignal und dem trendbereinigten und gefilterten Signal berechnet.

07 Neuronales Netz zur Klassifizierung der Panzerungsdicke.

Literaturhinweise

[1] ANSYS® Academic Research Mechanical, Release 18.1, ANSYS, Inc.

[2] M. Abadi et al.: „TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems“. Preliminary White Paper, November 2015. Verfügbar unter: download.tensorflow.org/paper/whitepaper2015.pdf

[3] S. Vajapeyam: „Understanding Shannon's Entropy metric for Information“. März 2014. Verfügbar unter: arxiv.org/ftp/arxiv/papers/1405/1405.2061.pdf

[4] MATLAB Neural Network Toolbox 2016a. The MathWorks, Inc. Natick, Massachusetts, USA.

trendbereinigten und gefilterten Daten bestimmt werden. Diese wurde dann verwendet, um die Originaldaten so zu verschieben, dass der Ausgangspunkt bei allen Datensätzen gleich ist →6.

Nach der Phasenverschiebung wurden die Daten der zweiminütigen Messungen in einzelne Abschnitte unterteilt, die jeweils einer Umdrehung der Trommel entsprechen, und durch Resampling auf 1.024 Abtastwerte umgerechnet. So konnte eine konsistente Datenbasis für den maschinellen Lernalgorithmus geschaffen werden.

Merkmalsextraktion

Maschinelle Lernalgorithmen versuchen, eine Reihe von Merkmalen den korrekten Zielwerten zuzuordnen. Daher ist die richtige Wahl dieser Merkmale von entscheidender Bedeutung. Verschiedene Merkmale, z. B. Wavelets, Entropie und Fourier-Analyse, wurden getestet. Das beste Ergebnis wurde mit einer Kombination aus statistischen Werten, den Beschleunigungsrohdaten und der schnellen Fourier-Transformation (FFT) jeder Umdrehung erzielt. Alle diese Merkmale wurden mit dem entsprechenden Zielwert in einer Tabelle zusammengefasst, die als Eingangsmatrix für das neuronale Netz dient.

Aufbau eines neuronalen Netzes zur Mustererkennung

Zur Klassifizierung der Daten wurden verschiedene maschinelle Lernverfahren wie Support Vector Machines, Entscheidungsbäume und neuronale Netze getestet, wobei neuronale Netze die besten Ergebnisse lieferten. Ein neuronales Netz ist in der Lage, Muster in einem Signal zu erkennen, die dabei helfen, das Signal in eine Zielklasse einzuordnen. Entsprechende Klassen wurden für alle Messungen aus den Versuchen mit unterschiedlichen Mühlenlasten und Panzerungsdicken definiert.

Daraufhin wurden die Eingangs- und Ausgangsmatrizen erstellt. Die Eingangsmatrix beinhaltet die oben beschriebene Tabelle mit den Merkmalen, während die Ausgangsmatrix die korrekten Zielklassen für die jeweiligen Merkmale definiert.


Anschließend wurde ein neuronales Netz [4] mit drei versteckten Schichten mit jeweils 500 Neuronen und einer Ausgangsschicht für die Klassifizierung erstellt →7.

Von den Daten wurden 70 % für das Training des neuronalen Netzes, 15 % für die Validierung und 15 % zum Testen des neuronalen Netzes verwendet. Als Trainingsverfahren für das neuronale Netz kam die sogenannte „scaled conjugate gradient backpropagation“ zum Einsatz, eine Methode, bei der kritische Modellparameter (Neuronengewicht und -Bias) auf iterative Weise aktualisiert werden. Abschließend erfolgte ein Feintuning der Hyperparameter (d. h. einflussreiche Parameter, die nicht im Kernmodell angepasst werden) für das Netz, sodass eine optimale NetzEinstellung erreicht wurde, mit der eine zuverlässige Bestimmung des Panzerungszustands möglich ist.

Dank des Systems können Panzerungen zustandsabhängig ausgetauscht werden, was Stillstandzeiten und Kosten reduziert.

Höhere Produktivität und geringere Kosten

Die Annahme, dass sich das Beschleunigungssignal deutlich in Abhängigkeit von der Panzerungsdicke verändert, wurde durch Simulationen und Messungen am maßstäblichen Modell und einer realen Mühle bestätigt. Das vom I3S und ABB entwickelte Überwachungssystem zeigt, wie Beschleunigungssensoren und maschinelle Lernverfahren genutzt werden können, um den Zustand und die Prozessparameter einer Mühle im laufenden Betrieb zu messen. Dank des Systems können Panzerungen zustandsabhängig ausgetauscht werden, was Stillstandzeiten und Kosten reduziert und Ressourcen schont. Das neue Überwachungssystem wird Mühlenbetreibern in Zukunft dabei helfen, ihre Produktivität zu steigern und Instandhaltungsmaßnahmen besser zu planen •



07