

Gefördert durch:



aufgrund eines Beschlusses
des Deutschen Bundestages



Forschungsvereinigung:	VDZ Technology gGmbH (Zementwerke)
Forschungseinrichtung 1:	VDZ Technology gGmbH Forschungsinstitut der Zementindustrie
Forschungseinrichtung 2:	Zentrum für Innovative Energiesysteme (ZIES) Hochschule Düsseldorf
IGF-Vorhaben-Nr.:	21152 N
Bewilligungszeitraum	01.10.2020 – 31.03.2023
Veröffentlicht VDZ-Webseite	Link zum Online-Projektsteckbrief

Forschungsthema:

Untersuchung der Robustheit von KI-Anwendungen zur Prozessoptimierung bei der Zementherstellung

1 Ausgangssituation

Über die letzten Jahre wurden die Prozesse der Zementindustrie kontinuierlich in Hinblick auf Energieeffizienz und Nachhaltigkeit optimiert. Der Anteil an alternativen Rohmaterialien, Brennstoffen und Hauptbestandteilen im Zement wurde schrittweise erhöht und der spezifische Energiebedarf in einigen Bereichen gesenkt (Hoenig 2013). Dies hat jedoch Auswirkungen auf die Stabilität der Prozessführung. Fluktuationen in den Rohmaterialströmen und Brennstoffen können sich sehr stark auf die Betriebsweise der verfahrenstechnischen Anlagen auswirken und zu einer reduzierten Effizienz oder gar Anlagenstörungen führen. Ferner wirken sich die stofflichen Veränderungen auch auf die Qualität der Endprodukte aus. Dies betrifft sowohl den Klinkerbrenn- als auch den Mahlprozess. Da die komplexen Prozesse oft messtechnisch eingeschränkt zugänglich und Laboranalysen von Qualitätsdaten nur zeitversetzt verfügbar sind, müssen Prozesssteuerer die Anlagen in der Regel mit ausreichenden Sicherheiten und auf Basis von Erfahrungswerten betreiben. Dies hat negative Auswirkungen auf die Energie- und Ressourceneffizienz der Prozesse.

In der Praxis existieren eine Vielzahl von unterstützenden Expertensystemen zur Regelung und Überwachung der Produktionsanlagen (Erfurt 2019). Diese decken aber nur Teilbereiche ab oder sind in einigen Fällen auf Grund mangelnder Stabilität abgeschaltet worden. Die unter dem Oberbegriff von Industrie 4.0 zusammengefassten Technologien und Methoden wie vernetzte Sensoren, die Verarbeitung und Auswertung von großen Datenmengen und vor allem das maschinelle Lernen bzw. die künstliche Intelligenz (KI) stellen vielversprechende Möglichkeiten zur Verbesserung der Prozessstabilität und -effizienz bereit. Datengetriebene Modelle

können z.B. in Form von virtuellen Sensoren, auch Softsensoren genannt, physisch nicht oder nur schwer erfassbare Messwerte bestimmen oder zukünftige Messwerte vorhersagen. Sie können ferner Anomalien im Prozess eigenständig erkennen oder optimale Betriebsparameter vorgeben. Um die Methoden des maschinellen Lernens im Rahmen von diesen „intelligenten“ Anwendungen, die den Prozesssteuerer aktiv unterstützen, erfolgreich in den Prozess zu integrieren, müssen diese ausreichend robust ausgelegt sein. Sie müssen unter den Alltagsbedingungen der Zementindustrie kontinuierlich und dauerhaft belastbare Ergebnisse liefern. Dies ist sowohl in Hinblick auf die Betriebssicherheit der komplexen, verketteten Anlagen und die hohen Kosten für Stillstandzeiten als auch in Bezug auf die praktische Akzeptanz durch das Leitstandpersonal von großer Bedeutung. Liefern derartige Lösungen mit der Zeit unbrauchbare oder falsche Ergebnisse, werden diese im Produktionsalltag nicht mehr genutzt und mit der Zeit abgeschaltet (Müller-Pfeiffer et al. 2018). Dieser Effekt stellt eines der größten Hemmnisse für die Digitalisierung der Prozessindustrie dar.

Dabei sind die Einflüsse und Störgrößen auf die Qualität von Vorhersagen oder Empfehlungen aus Anwendungen des maschinellen Lernens vielfältig und komplex. Datengetriebene Modelle sind auf belastbare aktuelle und historische Messdaten aus dem Prozess angewiesen und reagieren entsprechend empfindlich auf Ausfälle von Sensoren, unzureichend kalibrierte Sensoren oder unterschiedliche Veränderungen über die Zeit (z.B. Verschmutzung). Aber nicht nur die Messtechnik, sondern auch der Prozess selbst verändert sich sowohl kontinuierlich (z.B. durch Verschleiß) als auch diskret (durch Wartungseingriffe). Und auch die zu Grunde liegenden Softwarelösungen und Modelle unterliegen verschiedenen Einflussgrößen, die die Ergebnisse beeinflussen. Da KI-Modelle immer auf Basis von Trainingsdaten angelernt werden, haben ebendiese Daten einen erheblichen Einfluss auf die Qualität (Zuverlässigkeit) des aus dem KI-Modell aufgebauten virtuellen Sensors. So können bereits kleine Variationen in den Trainingsdaten für erhebliche Unterschiede in den Modellen sorgen (Becker et al. 2017). Bei Modellen, die sich immer wieder (automatisiert) an veränderte Prozesse adaptieren, spielt dies eine wesentliche Rolle. Es muss sichergestellt sein, dass der virtuelle Sensor auch bei sich adaptierenden Modellen immer ein gesichert zuverlässiges Ergebnis ausgibt. Bisher existieren noch keine gezielten Untersuchungen, die die Einflussgrößen auf die Vorhersagequalität von KI-Anwendungen in der Zementindustrie bzw. der Prozessindustrie im Allgemeinen systematisch aufzeigen und quantifizieren. Dabei ist es vor allem wichtig, dass diese Untersuchungen sowohl die verfahrenstechnischen als auch die informatischen Randbedingungen und ihre Wechselwirkungen gemeinsam betrachten. Dies erfordert einen interdisziplinären Forschungsansatz.

Für die großflächige Anwendung bestehender KI-Lösungen wie auch für deren erfolgreiche Weiterentwicklung bedarf es klarer Regeln für die Auslegungen, Integration, Wartung und Überwachung von datengetriebenen Modellen und ihrer zu Grunde liegenden Infrastruktur. Dazu müssen die unterschiedlichen Einflussgrößen unter realen Prozessbedingungen untersucht und ausgewertet werden. Diese Erkenntnisse können dann genutzt werden, um Anwendungsregeln zu formulieren und Methoden zur internen Selbstüberwachung und -bewertung von KI-Anwendungen zu konzipieren.

Die Zementindustrie verfügt in Hinblick auf die Digitalisierung über gute Voraussetzungen. Prozess- und Labordaten liegen vielfach bereits digital vor (RWTH Aachen 2019). Die weitere Verwendung dieser Daten zur Analyse, Optimierung und Vorhersage findet jedoch kaum statt. Das Projekt stellt eine wichtige Grundlage für die nachhaltige Digitalisierung der Zementindustrie

und anderer Prozessindustrien dar, indem es umfassende Grundlagen für die Bewertung der Verlässlichkeit und Robustheit von KI-Anwendungen schafft. Damit werden sowohl die Einstiegshürden für neue Technologien als auch die Risiken für Anlagenbetreiber reduziert.

2 Ziele des Forschungsvorhabens

Das Forschungsziel ist die Entwicklung einer Vorgehensweise zur Bewertung und Sicherstellung der Robustheit und Vorhersagequalität von Modellen des maschinellen Lernens zur verfahrenstechnischen Optimierung im industriellen Umfeld. Das dafür gewählte Anwendungsbeispiel ist ein virtueller Sensor (Softsensor), welcher auf Basis von Prozessdaten die Feinheit des Mahlproduktes vorhersagen soll. Dieser Anwendungsfall wurde gewählt, da die Mahlanlage zunächst einen typischen verfahrenstechnischen Prozess der Zementindustrie darstellt. Darüber hinaus reagieren Kugelmöhlen im Vergleich zu anderen Anlagentypen langsam auf Veränderungen, so dass die Erprobung ohne größere Risiken durchgeführt werden kann. Über den Projektzeitraum werden Mahlanlagen aus zwei Zementwerken regelmäßig verfahrenstechnisch untersucht.

Da es für die grundlegende Modellentwicklung eines Softsensors gute Vorarbeiten gibt, wurde dieser bekannte und gut überschaubare Anwendungsfall gewählt. Die Bewertung der Qualität bzw. der Robustheit der KI-Anwendung kann sowohl anhand des Energiebedarfs der Mahlanlage als auch über die Produktqualität des Zementes erfolgen.

Die Robustheit der KI-Anwendung wurde auch von Seiten der Informatik untersucht und verfahrenstechnische Einflüsse wurden gegenübergestellt. Die verwendeten Modelle und Methoden reagieren unterschiedlich stark auf Veränderung in den Trainingsdaten. Dies ist von besonderer Bedeutung, wenn Modelle durch Prozessveränderungen regelmäßig erneuert bzw. angepasst werden müssten. Ebenso wie die Daten und die verwendete Software einen Einfluss auf die Vorhersagequalität haben, kann auch die Rechengenauigkeit der verwendeten Hardware einen Einfluss haben. Gegenstand des Projekts war u.a. auch eine umfassende Analyse dieser Abhängigkeiten. Eine weitere Betrachtung war der Frage, ob sich bestimmte Zustandsgrößen über ihre Abhängigkeit von anderen Größen, z.B. Betriebsstunden von Komponenten, mit Hilfe von Maschinellem Lernen modellieren lassen.

Nachdem alle möglichen Einflüsse separat untersucht wurden, konnte abschließend gezielt ausgewertet werden, wie sich Veränderungen und Probleme anlagenseitig im Zusammenspiel mit dem implementierten Modell final auswirken. Dies umfasst insbesondere die Fragestellung, ob aus unzureichend genauen Vorhersagen möglicherweise aus verfahrenstechnischer Sicht falsche Stellhandlungen abgeleitet werden können.

3 Umfang der Untersuchungen

Die Untersuchung der Robustheit von KI-Anwendungen erfolgte im industriellen Umfeld anhand eines Softsensors zur Vorhersage der Mahlfineinheit einer Zementmühle. Die KI-Anwendungen wurden zu Beginn der Projektlaufzeit implementiert und systematisch unter sich kontinuierlich verändernden realen Bedingungen untersucht. Das System wurde ferner auch mittels künstlich erzeugter Testdaten („Stress-Test“) unter extremen Bedingungen getestet und im Laufe des Projektes schrittweise optimiert. Abbildung 3-1 stellt das Vorgehen zur Untersuchung der Robustheit von KI-Anwendungen grafisch dar.

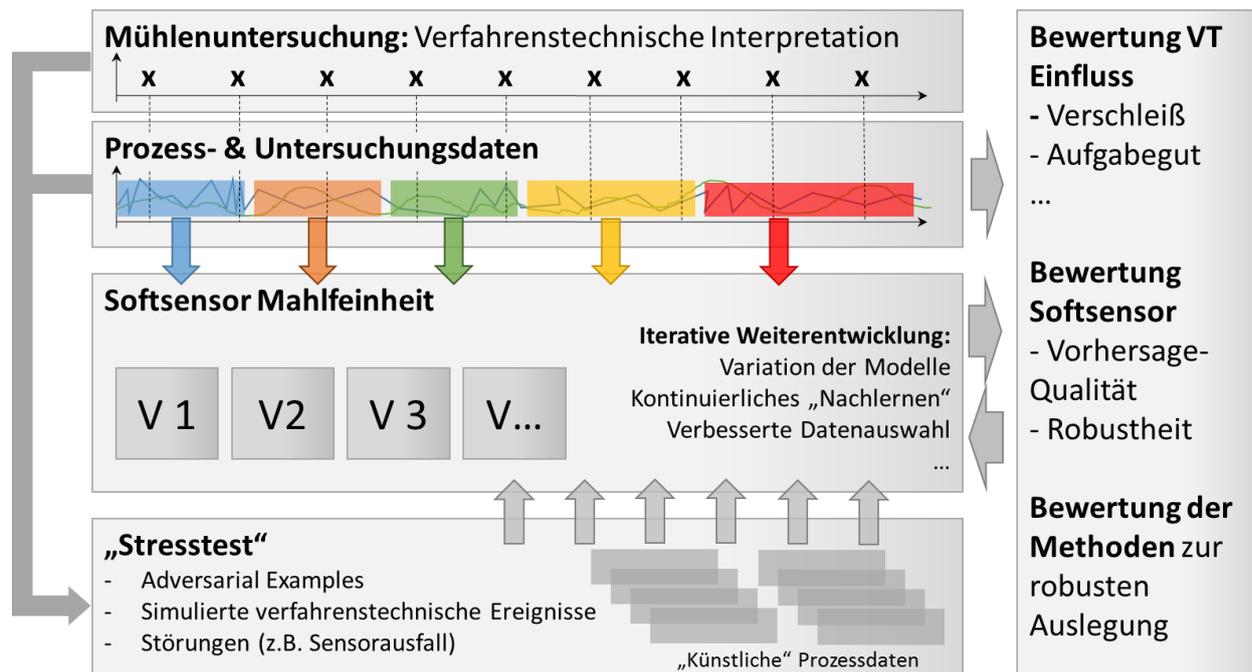


Abbildung 3-1 Schematische Darstellung des Projektablaufs. Es findet eine parallele Untersuchung der verfahrenstechnischen und informatischen Einflüsse auf die Robustheit

4 Zusammenfassung der Ergebnisse

Die Einführung von Künstlicher Intelligenz (KI) kann in der praktischen Anwendung durch ungenügende Robustheit gegenüber äußeren Einflüssen scheitern (z.B. Verschleiß, Anlagenänderungen, Änderungen in den Eingangsmaterialien, Änderung der Datenbeschaffenheit). Um Rückschlüsse auf die Robustheit von KI-Modellen (z.B. Softsensoren) ziehen zu können, müssen zeitliche Veränderungen an der Anlage bekannt sein oder untersucht werden. In diesem Forschungsprojekt wurden zwei Kugelmühlen-Sichter-Kreisläufe (nachfolgend Mahlanlage genannt) zur Zementmahlung aus unterschiedlichen Zementwerken betrachtet.

In diesem Projekt wurden Softsensoren entwickelt, welche die Korngrößenverteilung des Produktes anhand der Betriebsparameter vorhersagen sollen. Die Korngrößenverteilung wird dabei durch die beiden Kenngrößen Lageparameter (x') und Steigungsmaß (n) nach RRSB beschrieben. Diese sind damit die beiden Zielgrößen zur Vorhersage durch Methoden des Maschinellen Lernens. Allgemein ist zu berücksichtigen, dass die Messung der Korngrößenverteilung durch das Lasergranulometer Offline, hier automatisiert im Labor, erfolgt. Die Messung wird in der Regel in festen Intervallen (z.B. 2-stündig) oder bei Bedarf durchgeführt. Die Proben werden händisch transportiert oder per Rohrpost durch das Werk zum Labor verschickt und dort analysiert. Beides reduziert die Aktualität des Messwertes im Leitstand.

4.1 Bewertung der verfahrenstechnischen und mechanischen Einflussgrößen

Die Ergebnisse der verfahrenstechnischen Untersuchungen an beiden Mahlanlagen sind in Tabelle 4-1 zusammengefasst. Es zeigten sich prozessbedingte Änderungen, gemessen am Materialfüllgrad, von Mahlanlage 1 über die Projektlaufzeit.

Der Materialfüllgrad von Mahlanlage 1 war bei den Untersuchungen sehr unterschiedlich. Die Bewertung des Materialfüllstands wurde während der Mühlenbegehungen dokumentiert und schwankte in Kammer 2 (K2) zwischen voll (01.11.2020) und leer (11.11.2021). Kammer 1 (K1) wurde stets mit zu leer bewertet. Kammer 2 von Mahlanlage 2 zeigte einen konstant sehr hohen Materialfüllgrad und bis zur Kugelauffüllung in der Winterrevision im Januar 2023 einen konstant zu niedrigen Mahlkörperfüllstad.

In der Projektlaufzeit konnten, anders als ursprünglich angenommen, keine Anlagenänderungen aufgrund von Verschleiß nachgewiesen werden.

Tabelle 4-1 Übersicht über die Entwicklung von Verschleiß und Zustand während des Untersuchungszeitraums

Mahlanlage 1:

	Materialfüllgrad		Panzerung Verschleiß		Übertragungswand		Kugeln		Verpelzung		Austragswand		Sichter		Zementsorte	Zementsorte
	K1	K2	K1	K2	Schlitze	Verschleiß	Deformationen	Gebrochen	Kammer 1	Kammer 2	Schlitze	Verschleiß	Verschleiß	Ablagerung		
01.11.2020	0	3	--	o	o	o	o	o	o	o	--	o	o	--	1	CEM I
Winterreperatur Dez. '20																
08.06.2021	1	2	--	o	o	o	--	-	o	-	--	o	o	--	1	CEM I
02.08.2021	1	3	--	o	o	o	--	--	o	-	--	o	o	--	1	CEM I
11.11.2021	0	1	--	o	o	o	--	-	o	o	-	o	o	--	1	CEM I
12.11.2021	0	1	--	o	o	o	--	-	o	o	-	o	o	--	6	CEM III
Winterreperatur Dez. '21																
24.10.2022	0	3	--	o	o	o	--	-	o	-	-	o	o	--	1	CEM I

Mahlanlage 2:

	Materialfüllgrad		Panzerung Verschleiß		Übertragungswand		Kugeln		Verpelzung		Austragswand		Sichter		Zementsorte	Zementsorte
	K1	K2	K1	K2	Schlitze	Verschleiß	Deformationen	Gebrochen	Kammer 1	Kammer 2	Schlitze	Verschleiß	Verschleiß	Ablagerung		
24.08.2022	2	4	-	-	o	-	-	-	o	o	o	-	o	o	1	CEM I
06.12.2022	2	4	-	-	o	-	-	-	o	o	o	-	o	o	1	CEM I
Winterreperatur Jan. '23																
08.02.2023	2	3	-	-	o	-	-	-	o	o	o	-	o	o	1	CEM I

leer	0	leer / keine														
wenig	1	geringe Einläufrillen und Auswaschungen					wenig									
super	2	deutliche Einläufrillen und Auswaschungen					deutlich									
voll	3															
überfüllt	4															

4.2 Untersuchung der Robustheit der Softsensoren

Zur Vorhersage der beiden Zielgrößen (Lageparameter und Steigungsmaß der RRSB-Verteilung) wurden mehrere Methoden des maschinellen Lernens miteinander verglichen. Hierunter einfache Modelle (erwartbar eher höherer Robustheit) und komplexere Modelle (**Tabelle 4-2**).

Tabelle 4-2 Übersicht über die verwendeten Verfahren

Methoden	Kategorie	Komplexität
Lineare Regression (LR)	Maschinelles Lernen	Einfach
eXtreme Gradient Boosting (XGBoost)		Mittel
Gaussian Process Regression (GPR)	Wahrscheinlichkeitsverteilung	Komplex
Convolutional Neuronal Network (CNN)	Deep Neuronal Network	
Long Short Term Memory (LSTM)		

Alle Vorhersagemodelle wurden mit einem vorgeschalteten Autoencoder zur Ausreißerkorrektur kombiniert. Der Autoencoder wurde dabei einmal gelernt und die Vorhersagemodelle entsprechend variiert. Die Modelle wurden falls möglich mit Hyperparametervariation (Grit Search) und Kreuzvalidierung trainiert. Die Vorhersage mit den komplexen Modellen war besonders genau. Abbildung 4-1 zeigt exemplarisch die Vorhersage einer Zeitreihe durch die Modelle. Für den betrachteten Zeitraum ist zu erkennen, dass besonders die Trends des Lageparameters sehr gut abgebildet werden. Die Vorhersage des Steigungsmaßes durch das CNN-Modell wich teils stark von den gemessenen Werten (Ground Truth) ab. Aufgrund mangelnder Genauigkeit wurden die Lineare Regression und eXtreme Gradient Boosting nicht weiter betrachtet.

Zur Untersuchung der Robustheit der gelernten Softsensor-Modelle wurden die Eingangsdaten der Modelle systematisch manipuliert, mit dem Ziel Fehlfunktionen der Modelle zu provozieren. Die so erzeugten Beispiele zur Manipulation der Modelle werden „Adversarial Examples“ genannt. Die Eingangsdaten weichen dabei teils nur sehr gering von den ursprünglichen Daten ab, wodurch der Betrachter, z.B. den Leistandfahrer, keine Anomalie erkennen kann.

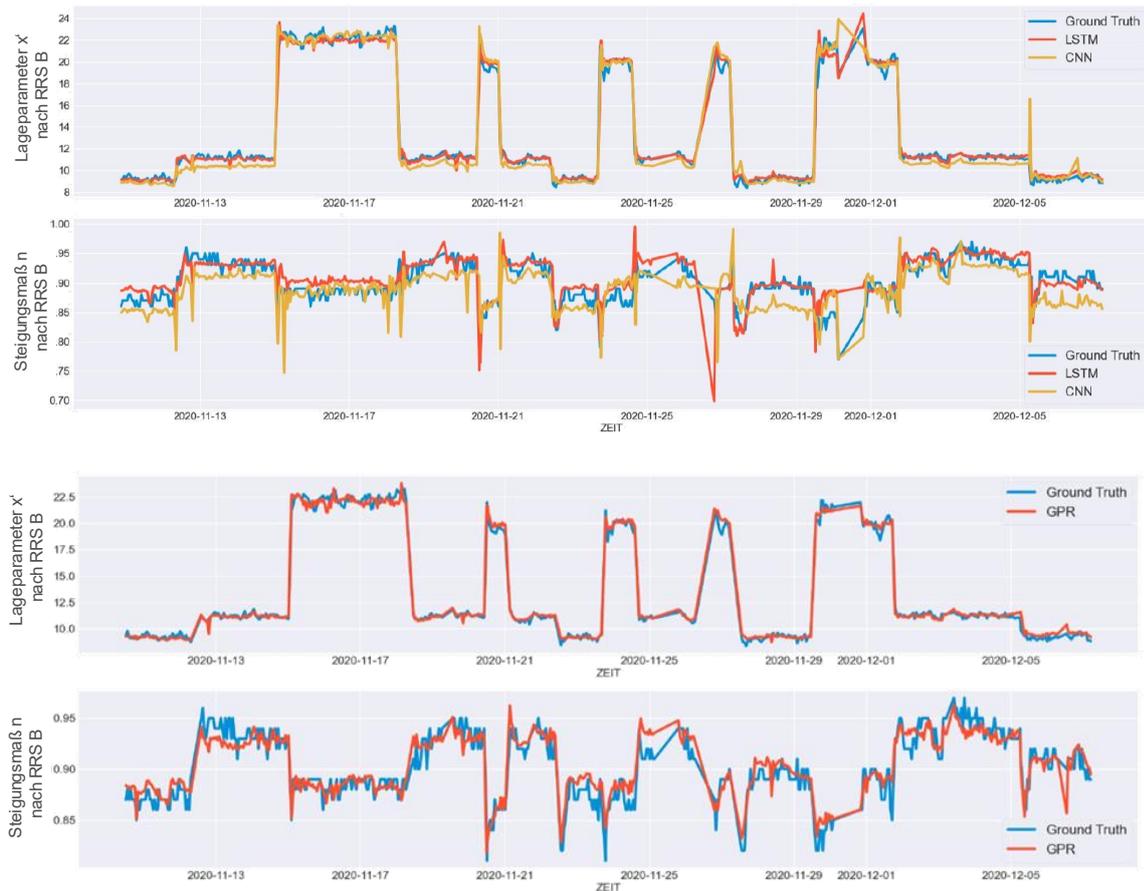


Abbildung 4-1 Vergleich der Prognose der RRSB-Parameter durch verschiedene Modelle

Für Bildverarbeitungsalgorithmen bietet die Literatur viele Beispiele zur Untersuchung der Robustheit. Für Zeitreihenproblematiken, wie Prozessdaten in der Zementindustrie, finden sich jedoch nur wenige systematische Untersuchungen. Um die Robustheit der Modelle durch Manipulation der vorliegenden Eingangsdaten zu untersuchen, wurden:

1. die Eingangsdaten mit sprunghaften Änderungen (Offsets) manipuliert, wobei sich zeigte, dass das LSTM-Modell robustere Vorhersagen als das CNN-Modell lieferte.
2. die Daten wurden mit einem Gauß'schem Rauschen überlagert, wobei der entstehende Fehler in den Eingangsdaten sich nicht signifikant in den Vorhersageergebnissen widerspiegelte
3. der Einfluss der Datenstruktur war besonders hoch, da hier verschiedenste Problemstellungen auftreten können. Besonders die Umbenennung der Merkmale wirkte sich stark aus, da besonders viele Merkmale nicht korrekt zugeordnet werden konnten.
4. verfahrenstechnischer Änderungen während der Projektlaufzeit, wie Änderungen des Materialfüllstands, wirkten sich nicht nachweisbar auf die Robustheit der Sensoren aus.
5. die Eingangsdaten wurden systematisch mit der FGS-Methode manipuliert. Zur Erzeugung relevanter Falsch-Vorhersagen die deutliche Manipulation der Eingangsparameter (Abbildung 4-2) bei der GPR und dem LSTM-Modell notwendig. Zufällige Fehler in den Daten und damit verbundene Vorhersagefehler sind dementsprechen unwahrscheinlich.

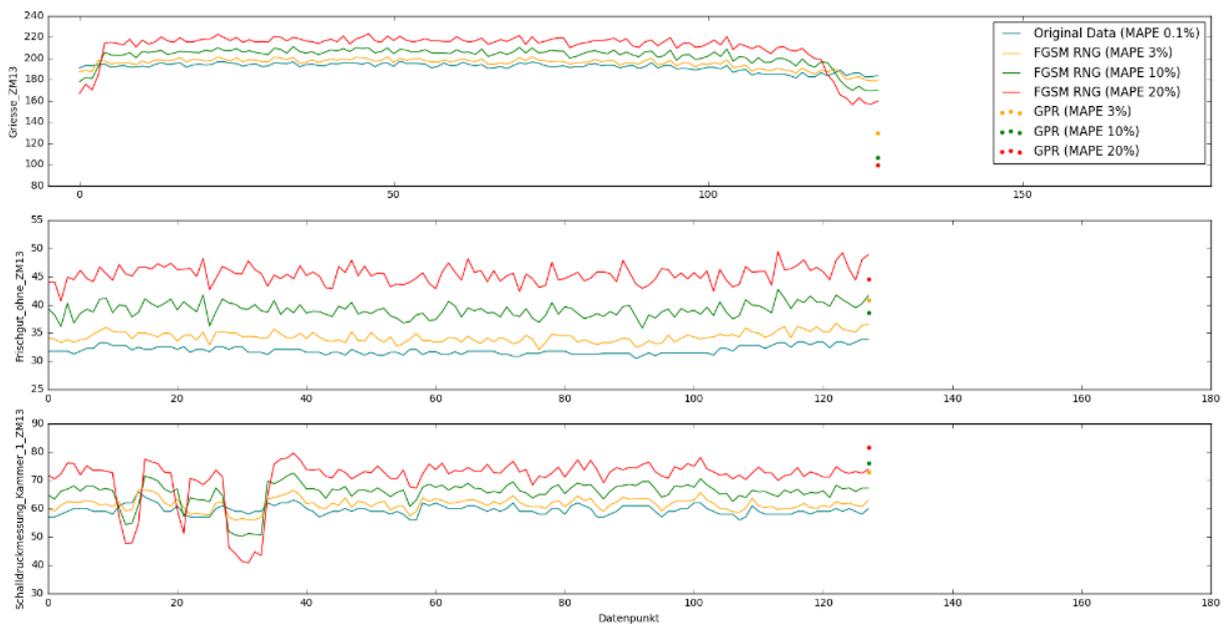


Abbildung 4-2 Manipulation aller Eingangsdatensätze durch FGSM und Ergebnis auf die Vorhersage des Lageparameters gemessen nach MAPE (Mahlanlage 1)

4.3 Ableitung von allgemeinen Regeln für die robuste Auslegung und Überwachung von KI-Anwendungen

4.3.1 Prozessnahe Maßnahmen

Um die Auswirkungen durch den Einsatz von KI-Modellen richtig beurteilen zu können, wird eine Grundcharakterisierung der Anlage (z.B. Ofensystem oder Mahlanlage) zu Beginn der Entwicklung sowie fortlaufende Untersuchungen zur Dokumentation des Anlagenzustand durch einen externen Mitarbeiter (Dienstleister oder Experte aus anderen Werken) empfohlen.

Untersuchungen an verfahrenstechnischen Anlagen werden oft nur bei Bedarf durchgeführt. Aus verfahrenstechnischen Erfahrungen werden oft turnusgemäße Untersuchungen empfohlen. Die Auslöser für zusätzliche Untersuchungen können u.a.:

- dem Verschleiß der Anlage,
- Änderungen im Prozessverhalten,
- Änderungen in der Prozessführung oder an den Anlagen und
- Änderung der Eingangsmassenströme sein.

Änderungen an den Anlagen, den Sensoren und der Datenstruktur können sich auf die Robustheit der Vorhersagen von Softsensoren auswirken. Dementsprechend muss bei der Grundcharakterisierung und der Anlagenüberwachung auch die Datenstruktur aller relevanten Informationen betrachtet und dokumentiert werden.

Oft erfolgt die Dokumentation von Anlagenänderungen in unstrukturierter Form oder als analoge Ablage. Diese Informationen sind für Dritte aktuell nur schwer oder gar nicht zugänglich

und können so auch nicht bei der Entwicklung oder dem Produktivbetrieb von KI-Modellen genutzt werden. Relevante Anlagenänderungen können sein:

- Kalibrierung von Sensoren,
- Anpassung der Förderwege (z.B. Ersatz eines Bandes durch eine Luftförderrinne),
- Austausch eines Anlagenteils (z.B. eines Brenners im Ofen oder eines Sensors) sowie
- Instandsetzung von Anlagen (Neuzustellen eines Ofens, Nachfüllen von Kugeln in der Kugelmühle)

Bei verfahrenstechnischen Anlagen können sich die Eingangsstoffe ändern. Dies kann Brennstoffe und alle anderen Eingangsstoffe betreffen, welche die betrachtete Systemgrenze überschreiten. Diese Eingangsstoffe können aus natürlichen Vorkommen des Werkes oder aus externen Quellen stammen sowie Zwischenprodukte aus anderen Teilprozessen sein.

Eingangsstoffe werden meist qualitativ überwacht. Informationen aus vorherigen Teilprozessen und Überwachungsdaten der Eingangsstoffe sollten für Entwickler von Modellen des Maschinellen Lernens einfach verfügbar sein. Die Entwicklung einer standardisierten Schnittstelle zur Übertragung von Betriebsdaten kann die zukünftige Entwicklung von KI-Modellen vereinfachen.

Die Datenstrukturen in Zementwerken sind oft nicht standardisiert, gleiches gilt für den Export der Daten aus den Datenbanken. Bei der Übertragung von Daten sollten:

- standardisierte Bezeichnungen verwendet werden, die nicht geändert werden können. Die Verwendung von Synonymen (z.B. Griese / Rückgut) ist zu vermeiden.
- eindeutige Bezeichnungen für Merkmale und Datensätze verwendet werden, z.B. durch Verwendung des Universal Unique Identifier, UUID.
- die Einheit der Information gekennzeichnet werden, wobei SI-Einheiten zu bevorzugen sind.
- die Grundlage zur Berechnung von Werten durch Meta-Daten beschrieben werden. Berechnete Werte sollten zudem als solche kenntlich gemacht werden und die Rohdaten ebenfalls bereitgestellt werden.
- ein einheitlicher Zeittempel nach der Unixzeit-Definition als 64-Bit Zahl verwendet werden.

Diese organisatorischen Maßnahmen helfen dem Werkspersonal unmittelbar, indem die Berechnung von Kennzahlen vereinfacht wird. Durch die Vermeidung systematischer Fehler bei der Datenübergabe wird auch die Grundlage zur Verbesserung der Robustheit von zukünftigen KI-Modellen geschaffen.

Als weitere technische Maßnahme können Datensätze durch Korrelationsanalyse überprüft und gegebenenfalls zugeordnet werden. Korrekturen an den Eingangsdaten, wie durch Ausreißerererkennung und Korrelationsanalysen, sollten in den Datensätzen markiert werden und dem Betrachter zugänglich sein.

Jede verfahrenstechnische Anlage durchläuft während des Betriebs verschiedene Zustände. Die Identifikation und Markierung dieser Zeiträume ist aus mehreren Gründen für die Arbeit an KI-Projekten wichtig:

- Bei dem Training der Modelle sollten Datensätze entfernt werden, wenn die Anlage ausgeschaltet ist. Auch in diesen Zeiten können Hilfsaggregate in Betrieb sein sowie Temperatur- und Drucksensoren Daten liefern.
- Bei Training und Test der Modelle muss darauf geachtet werden, dass die gelernten Zustände (z.B: Anfahren des Ofens, Prozessstörungen) ausreichend häufig in den Daten repräsentiert sind.

Die Information zum aktuellen Betriebszustand ist auch für verfahrenstechnische Auswertungen, z.B. bei der Berechnung von Kennzahlen, interessant. Betriebsdaten außerhalb des Normalbetriebs können eliminiert oder gesondert bewertet werden.

Tabelle 4-3 zeigt gängige Betriebszustände verfahrenstechnischer Anlagen sowie Beispiele für deren Identifikation anhand von Daten. Bei der Identifikation der Zustände müssen die Bilanzgrenzen festgelegt werden, da nachgeschaltete Anlagenteile teils erst später abgefahren werden

Tabelle 4-3 Beschreibung typischer Betriebszustände anhand von Daten

Zustand	Beispiele zur Identifikation des Betriebszustands
Normalbetrieb	<ul style="list-style-type: none"> - Alle Haupt-Anlagenteile (z.B. Mühlenmotor, Gebläse, Materialaufgabe) sind im Betrieb - Hilfs-Antriebe sind ausgeschaltet - Parameter der Anlagenteile sind im Normalbereich
Anfahrbetrieb	<ul style="list-style-type: none"> - Beginnt wenn der erste Haupt-Anlagenteil gestartet ist - Kein Normalbetrieb - Ausschussmaterial wird in einem separaten Silo gesammelt
Abfahrbetrieb	<ul style="list-style-type: none"> - Beginnt, wenn die Materialaufgabe ausgeschaltet wird, aber keine Störung vorliegt - Kein Normalbetrieb - Ausschussmaterial wird in einem separaten Silo gesammelt - Endet im Anlagenstillstand
Stillstand	<ul style="list-style-type: none"> - Die Haupt-Anlagenteile sind ausgeschaltet, ggf. laufen Hilfsantriebe noch - Keine Materialaufgabe
Störung (verfahrenstechnisch)	<ul style="list-style-type: none"> - Einzelne Betriebsparameter sind außerhalb des Normalbereiches
Störung (elektrisch) Störung (mechanisch)	<ul style="list-style-type: none"> - Motoren oder Aktoren Soll-Wert und Ist-Wert-Rückmeldung sind nicht identisch
Sorten- / Rohstoffwechsel	<ul style="list-style-type: none"> - Anlage nicht im Stillstand - Benutzereingriff, zum Beispiel durch Anpassung der Betriebsparameter (z.B. Eingangsmassenströme) - Änderung des Produktsilos

4.3.2 Verbesserung der Robustheit der Modelle

Die Optimierung von Modellen des Maschinellen Lernens kann sowohl durch eine vertiefte Einsicht in den Prozess als auch durch spezialisierte Schritte wie die Weiterentwicklung der Modelle selbst erfolgen. Das Erwerben von Domain-Wissens ermöglicht es dem Modellentwickler verfügbare Informationen und Daten einordnen zu können.

Durch interdisziplinären Austausch können, zum Beispiel:

- angepasste Fehlermetriken und Verlustfunktionen entwickelt werden,
- geeignete zeitliche Diskretisierungen der Daten gewählt werden,
- der Zeitversatz zwischen den Anlagenteilen eingeschätzt werden (*TimeLag*) oder
- Typische Wertebereiche der Daten bestimmt werden.

Die Robustheit und auch die Genauigkeit der Vorhersagen kann so gesteigert werden. Dies muss jedoch im Einzelfall untersucht werden.

Es hat sich gezeigt, dass bei Zeitreihenproblematiken eine vorgeschaltete Ausreißererken-
nung wesentlich robustere Vorhersagen erzeugt. Bewährt hat sich eine Kombination eines
Autoencoders mit mindestens einem nachgeschalteten Modell des Maschinellen Lernens.
Untersuchungen im Forschungsprojekt haben gezeigt, dass Modelle die über ein Kurzzeit-
gedächtnis (z.B. CNN oder RNN) verfügen robustere Vorhersagen treffen können, als Mo-
delle die nur einen Zeitschritt betrachten.

Für die Problemstellung grundsätzlich in Frage kommende Modelle sind in einem ersten
Schritt zu Vergleichen und objektiv gegenüberzustellen. Hyperparameterstudien ermögli-
chen es die Robustheit der Methoden zu bewerten und die Genauigkeit zu optimieren. Ziel-
führend erweist sich auch die Kombination mehrerer starker Modelle, wie (Stöhr & Zielke,
2022) zeigte.

Anlagenänderungen können sich deutlich auf die Vorhersagegenauigkeit auswirken. Die An-
lagenänderungen müssen dokumentiert, maschinenlesbar verfügbar und bewertet sein.
Große Änderungen an den Anlagen erfordern das Nachlernen der Modelle, wobei die
„Größe“ der Anlagenänderungen interdisziplinär zu bewerten ist. In Abhängigkeit der Ände-
rung an der Anlage kann auch das „Vergessen“ von alten Datensätzen die Vorhersage ver-
bessern.

4.3.3 Möglichkeiten zur Untersuchung der Robustheit

Zur Bewertung der Robustheit von datengetriebenen Modellen muss untersucht werden welche Modelleingangsparameter wie stark verändert werden müssen, um einen höchstmöglichen Vorhersagefehler zu verursachen. Die systematische Änderung der Eingangsdaten wird „Adversarial Examples“ genannt. Es sollten:

1. prozessbedingte Veränderungen von Sensorwerten durch die händische Änderung einzelner Eingangsdaten untersucht werden.
Üblicherweise liegt auf dem Signal der Sensoren ein Rauschen, Neukalibrierungen verursachen Sprünge und Sensoren Driften durch z.B. Verschmutzung
Auch können Sensoren ausfallen und für eine bestimmte Zeit kein Signal liefern.
2. ungünstige, unbeabsichtigte und zufällige Variationen der Eingangsdaten nachgebildet werden, indem die Eingangsdaten (z.B. Änderung der Bezeichnungen von Eingangsdaten) bewusst manipuliert werden, z.B. durch Fast Gradient Sign Method, FGSM.
Hier sollte die Manipulation einzelner, mehrerer und sämtlicher verfügbarer Eingangsdaten automatisiert untersucht werden.

Die Kombination der verschlagenen Untersuchungen hat sich als besonders zielführend erwiesen. Es kann davon ausgegangen werden, dass Sensoren regelmäßig neu kalibriert werden. Sensoren die dies häufig betrifft sind in den Werken bekannt.

Verfahrenstechnische Änderungen resultieren meist in der Änderung mehrere oder aller Eingangsdaten. Sensoren (z.B. Füllstandsmessung mit dem elektrischen Ohr) werden dann oft nicht neu kalibriert, obwohl dies nötig wäre. Ungünstige Kombinationen können zu hohen Vorhersagefehlern führen. Diese Kombinationen können durch Methoden bestimmt werden, welche die Eingangsdaten automatisiert manipulieren, wie die FGSM.

Es zu beachten, dass die automatisierte Manipulation der Eingangsdaten auch zu Fehlinterpretationen führen kann. Die Nutzung manipulierter Prozessdaten resultiert in einer anderen Vorhersage, welcher einem Fehler entsprechen kann oder einer korrekten Vorhersage aufgrund anderer Betriebsbedingungen.

4.4 Zusammenfassung der Ergebnisse

Modelle des Maschinellen Lernens weisen einen hohen Reifegrad auf und können mit entsprechendem Know-How trainiert und implementiert werden. Die Untersuchungen am Beispiel der Vorhersage der Mahlfeinheit, gemessen an den Parametern der RRSB-Verteilung, zeigen, dass verschiedene Methoden ausreichende genau und robust sind. Zur Bewertung der Robustheit wurden Empfehlungen aufgestellt, die

1. verfahrenstechnische und prozessnahe Maßnahmen einschließen und
2. die Entwicklung der Modelle sowie die Untersuchungen der Robustheit am Beispiel verfahrenstechnischer Anlagen aus der Zementindustrie aufzeigen.

Die verfahrenstechnischen Untersuchungen der Mahlanlagen konnten den erwarteten Verschleiß in der Projektlaufzeit nicht bestätigen, der Einfluss auf die Robustheit der KI-Anwendungen konnte daher nicht festgestellt werden. Auf Grundlage der Mühlenuntersuchungen wurden verschiedene verfahrenstechnische Verbesserungsmaßnahmen vorgeschlagen. An

Mahlanlage 2 wurde die Kugelmenge erhöht, was einen deutlichen Einfluss auf die Vorhersageergebnisse der Softsensoren hatte und sich damit deutlich auf die Robustheit der Sensoren auswirkte.

In Zementwerken besteht oft deutliches Potential die Datenqualität zu erhöhen. Dies kann durch die Standardisierung von Datenstrukturen und die Integration von maschinenlesbaren Informationen durch Meta-Daten gelingen. Besonders wichtig ist dabei die Dokumentation von Anlagenänderungen und Kalibrierungen von Messeinrichtungen. Die Manipulation der Datenstruktur hat in den Untersuchungen den größten Einfluss auf die Robustheit der Sensoren gehabt.

Es erwies sich auch als zielführend durch interdisziplinären Austausch zwischen den verschiedenen Arbeitsbereichen gegenseitiges Verständnis zu entwickeln. Es hat sich zum Beispiel gezeigt, dass durch geeignete Fehlermetriken die Modelle genauer angelernt werden können. Hierzu wurde durch die Zusammenarbeit der Fachdisziplinen Machine Learning und Verfahrenstechnik eine so genannte RRSB-Verlustfunktion entwickelt, welche zum Lernen der Modelle genutzt wurde.

Die Untersuchung der Robustheit der KI-Anwendung von Seiten der Informatik hat bestätigt, dass unterschiedliche Modelle und Methoden unterschiedlich stark auf Veränderung in den Trainingsdaten reagieren. Einfache Modelle sind tendenziell robuster, liefern aber oft unter idealen Bedingungen nicht die gewünschte Genauigkeit. Die Untersuchung der Robustheit dieser Modelle ist nicht zielführend. Dementsprechend ist eine Vorauswahl geeigneter Modelle nötig. Die untersuchten Neuronalen Netze (CNN und LSTM) nutzten Zeitfenster zur Vorhersage. Anders das Modell der Gaussian Process Regression (GPR) welches nur die Eingangsdaten des aktuellen Zeitpunktes nutzt. Die Neuronalen Netze wiesen eine höhere Robustheit bei etwa gleicher Vorhersagegenauigkeit auf. Hyperparameterstudien haben gezeigt, dass die Wahl der Hyperparameter des LSTM-Modells weniger Einfluss auf die Vorhersagegenauigkeit habe als bei dem CNN-Modell. Dies ist ein Hinweis auf höhere Robustheit des LSTM-Modells.

In gegenseitiger Zusammenarbeit wurden verschiedene Adversarial Examples entwickelt, um die gelernten Modelle anzugreifen. Besonders sinnvoll hat sich der Einsatz eines „Autoencoders“ zur vorgeschalteten Ausreißerererkennung erwiesen. Untersucht wurden die Kombinationen des Autoencoders mit dem LSTM- und dem CNN-Modell bei der Vorhersage von Sensorfehlern, wobei das LSTM-Modell deutlich robustere Ergebnisse geliefert hat.

Insgesamt hat sich gezeigt, dass die Kugelmühle ein sehr robustes Aggregat ist. Auch KI-Modelle, die mit den Daten der Kugelmühlen gelernt wurden, waren äußerst robust und schwer zu manipulieren. Dennoch konnten Anwendungsfälle bestimmt werden, die zu falsch-Vorhersagen führten und damit Stellhandlungen des Leitstandpersonals zur Folge hätten, welche im besten Fall den spezifischen Energiebedarf erhöhen und im schlechtesten Fall die Zementqualität negativ beeinflussen könnten. Um dem entgegenzuwirken wurden allgemeingültige Regeln zur Verbesserung der Robustheit von KI-Modellen entwickelt. Wesentlich für diese datengetriebenen Modelle ist die Verfügbarkeit von gleichbleibenden und standardisierten Eingangsdaten. Auch die Bereitstellung von Meta-Daten und Informationen aus vorhergehenden Teil-Prozessen wird empfohlen. Die systematische Untersuchung von verfahrenstechnischen Anlagen nimmt bereits heute im betrieblichen Alltag einen hohen Stellenwert ein. Durch zusätzliche Anlagenuntersuchungen nach verschiedenen Auslösern (Anlagenänderungen, Kalibrierungen wesentlicher Einrichtungen) können Entscheidungen

zum Nachtrainieren von Modellen des Maschinellen Lernens getroffen werden. Im betrachteten Fall war das Auffüllen der Kugelcharge von Mahlanlage 2 ein derartiger Auslöser.

5 Literatur

- Becker, M., Lippel, J., Stuhlsatz, A., 2017, Regularized nonlinear discriminant analysis. an approach to robust dimensionality reduction for data visualization, International Conference on Information Visualization Theory and Applications.
- Erfurt, V., 2019. Smart process control and optimization, The Global Manufacturing & Industrialization Summit, Yekaterinburg, 9 July 2019
- Hoenig, V., 2013. Energieeffizienz bei der Zementherstellung: Teil 1, Teil 2. *Cement International*, 11, pp. 50-67, 46-65.
- Müller-Pfeiffer, M. & Fleiger, P., 2018. *Trends in Grinding Technologies*. Düsseldorf, VDZ Congress.
- RWTH Aachen, 2019. Industrie 4.0 in der Zementindustrie - Status quo und perspektiven, Aachen: Construction Robotics GmbH.
- Stöhr, M., & Zielke, T. ,2022. Machine Learning for Soft Sensors and an Application in Cement Production. International Conference on Competitive Manufacturing (COMA'22).

6 Förderhinweis

Das IGF-Vorhaben Nr. 21152 N der VDZ Technology gGmbH, Toulouser Allee 71, 40476 Düsseldorf und des Zentrums für Innovative Energiesysteme (ZIES) an der Hochschule Düsseldorf wurde über die AiF im Rahmen des Programms zur Förderung der industriellen Gemeinschaftsforschung (IGF) vom Bundesministerium für Wirtschaft und Klimaschutz aufgrund eines Beschlusses des Deutschen Bundestages gefördert.

Gefördert durch:



Bundesministerium
für Wirtschaft
und Klimaschutz

aufgrund eines Beschlusses
des Deutschen Bundestages