

Datengetriebene Modellierung und Merkmalsselektion für die automatische Kalibrierung eines Sensorsystems für die mikromagnetische Materialcharakterisierung

Felix Wittich¹, Andreas Kroll¹

¹Fachgebiet Mess- und Regelungstechnik
Universität Kassel

Mönchebergstraße 7, 34125 Kassel

E-Mail: {felix.wittich, andreas.kroll@mrt.uni-kassel.de}

Kurzfassung

Der industrielle Echtzeiteinsatz zerstörungsfreier Prüfverfahren bietet ein großes Potenzial für die Analyse oberflächennaher Werkstückeigenschaften. Neben einer möglichen Zeit- und Kostenreduktion durch die direkte Integration von Prüfverfahren in den Bearbeitungsprozess, die bisher nur offline durchführbar war, ermöglicht dies eine Überwachung und gezielte Regelung von relevanten Werkstückeigenschaften im laufenden Prozess. Eine zentrale Herausforderung beim Einsatz mikromagnetischer Materialcharakterisierungsverfahren (MMV) [1] ist dabei deren Kalibriermodellerstellung. Die MMV können beispielsweise bei der Prozessdatenerfassung für die Prozessparameteroptimierung in der Fertigung eingesetzt werden [2], ohne dabei aufwendige ex-process Referenzmessungen durchführen zu müssen. In diesem Beitrag wird ein Ansatz für die datengetriebene Kalibriermodellerstellung für die mikromagnetische (MM) Messung vorgestellt und anhand eines Hartdrehdatensatzes untersucht.

1 Einführung

Die mikromagnetische Materialcharakterisierung ermöglicht die zerstörungsfreie in-process Messung mechanischer Eigenschaften ferromagnetischer Werkstücke. Das Potential liegt dabei in der vielfältigen Einsetzbarkeit in Bezug auf die Zielgrößen wie u. a. Eigenspannung, Härte, Härtetiefe, Streckgrenze, sowie der Breite der potentiellen Anwendungsfelder in verschiedenen Fertigungsprozessen (Urformen, Umformen, Fügen, Trennen). Der Randschichtzustand eines Bauteils bestimmt dessen Funktionalität, Belastbarkeit und Lebensdauer. Eine gezielte Einstellung dieser Eigenschaften erfordert daher eine in-process Erfassung des Randschichtzustands. Wichtige Zielgrößen wie die Eigenspannung werden bisher sehr zeitaufwendig und / oder zerstörend röntgenografisch oder mittels der Bohrlochmethode erfasst. Auch die Oberflächenhärte wird konventionell über die Eindringtiefe eines Prüfkörpers quantifiziert und die Streckgrenze wird zerstörend mittels Zugversuch bestimmt. Die vorgenannten Prüfverfahren müssen ex-process durchgeführt werden und eignen sich daher nicht für ein prozessintegriertes Steuerungs- oder Regelungskonzept. Hier bietet die mikromagnetische zerstörungsfreie Messung das Potential, aufwendige Laboruntersuchungen zeit- und kosteneffizient zu ersetzen und die Fertigungsprozesse zu regeln.

Um auf Basis von MMV die Randschichteigenschaften zu quantifizieren, muss der funktionale Zusammenhang zwischen den mikromagnetischen Messgrößen und den resultierenden Eigenschaften bekannt sein. Bei der MMV werden verschiedene Messmethoden genutzt: die Oberwellenanalyse der Magnetfeldstärke, das Barkhausenrauschen und die Analyse des Mehrfrequenzwirbelstroms sowie der Überlagerungspermeabilität. Entsprechend besteht die Herausforderung darin, die gemessenen Zeitreihen auf skalare Zielgrößen abzubilden. Eine Modellierung dieser Zusammenhänge basierend auf physikalischen Ansätzen ist aufgrund der komplexen, nicht vollständig verstandenen Zusammenhänge nicht zielführend [3]. Vielmehr hat sich ein datengetriebener Ansatz etabliert, basierend auf einfachen Regressionsansätzen mit schrittweiser Merkmalsselektion, mit dem aber teilweise keine guten Ergebnisse erzielt werden können [4]. Trotz des großen Potenzials zur Zeit- und Kostenreduzierung steht dem breiten

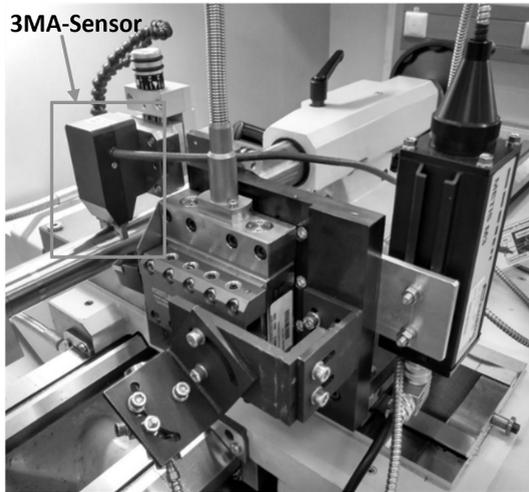


Bild 1: Versuchsaufbau mit 3MA-Sensor an der Hartdrehmaschine

industriellen Einsatz die erforderliche komplexe Kalibriermodellerstellung entgegen [5].

Verschiedene Arbeiten befassen sich mit der datengetriebenen Kalibrierung von MMV-Systemen. In [6] wird eine klassifikationsbasierte und eine kontinuierliche Quantifizierung mittels multipler linearer Regression betrachtet. Auf der in [6] durchgeführten regressionsbasierten Zugspannungsquantifizierung aufbauend, wird in [7] eine Regression mittels Multi Layer Perceptron (MLP), Support Vector Machine (SVM) und multipler linearer Regression verglichen, wobei allerdings lediglich lineare Aktivierungsfunktionen und Kernelfunktionen betrachtet werden und keine Merkmalsselektion stattfand. In [8] wird eine geeignete Gewichtung der betrachteten Merkmale zur robusten kNN-basierten Klassifikation mittels GA untersucht. In [9] wurde ein MLP mit logistischen Aktivierungsfunktionen als nichtlinearer Ansatz mit multipler linearer Regression für die Zielgröße Einsatzhärtungstiefe ohne den Einsatz einer Merkmalsselektion verglichen. Die vorgestellten Arbeiten zeigen, dass einzelne Ansätze für spezifische Anwendungen gute Ergebnisse liefern können. Eigene Untersuchungen [4] haben aber gezeigt, dass die Standardverfahren für das

Beispiel der oberflächennahen Eigenspannungsmessungen keine zuverlässigen Ergebnisse liefern. Daher soll in diesem Beitrag ein nichtlinearer Regressionsansatz mit Gaußprozessregression und Merkmalsselektion untersucht werden, der eine Kalibriermodellerstellung für die mikromagnetischen Messung des Eigenspannungszustandes ermöglicht. Die verwendeten Daten stammen dabei aus einem industriellen Hartdrehprozess. Der Versuchsaufbau hierzu ist in Abbildung 1 zu sehen.

2 Methode

In diesem Beitrag werden empirische Modellierungsansätze betrachtet, die es ermöglichen, nichtlineare Systeme auf Basis kleiner Datensätze zu modellieren. Es soll ein funktionaler Zusammenhang zwischen n Eingangsgrößen $\mathbf{x} \in \mathbb{R}^n$ und den Ausgangsgrößen $y \in \mathbb{R}$ hergestellt werden

$$y(l) = f(\mathbf{x}(l)) + e(l), l = 1, \dots, N, \quad (1)$$

mit dem Datensatz $Z^N = \{\mathbf{x}(l), y(l)\}_{l=1}^N$ mit N Elementen. Die Funktion $f : \mathbb{R}^n \rightarrow \mathbb{R}$ ist die nichtlineare Funktion, die das Systemverhalten modellieren soll. Der Term $e(l)$ berücksichtigt Messfehler und andere Störungen, sowie Modelldefizite. Die Umsetzung der Methoden erfolgte in MATLAB 2023b.

Aufgrund der hohen Anzahl an Eingangsgrößen wird ein einfaches, auf ANOVA basierendes Verfahren zur Vorselektion der Merkmale angewendet. Hierzu wird die kontinuierliche Ausgangsgröße in 10 gleichgroße Gruppen eingeteilt. Für jedes Merkmal wird dann eine ANOVA durchgeführt, bzw. die F -Statistik berechnet. Jeder F -Test prüft die Hypothese, dass die Gruppen der Ausgangsgröße, die nach den Werten der Prädiktorvariablen gruppiert sind, aus Populationen mit gleichem Mittelwert stammen, gegen die alternative Hypothese, dass die Populationsmittelwerte nicht alle gleich sind. Ein kleiner p -Wert der Teststatistik deutet darauf hin, dass der entsprechende Prädiktor wichtig ist. Zur Bewertung wird ein Predictor-Importance-Score in der Form

$$-\log(p) \quad (2)$$

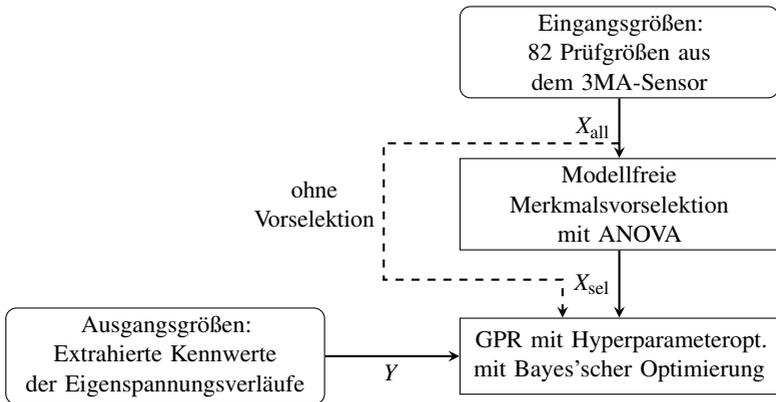


Bild 2: Vorgehen bei der Modellierung

verwendet.

Als Modellansatz wird die Gaußprozessregression (GPR) als nichtparametrische Methode verwendet. Für eine umfangreiche Beschreibung der GPR wird auf [10] verwiesen. Für die Kalibriermodellerstellung wurde GPR ausgewählt, da hiermit sehr gute Ergebnisse bei vergleichbaren Modellierungsproblemen mit kleinen Datensätzen erzielt werden konnten [2, 11]. In eigenen Versuchen mit weiteren nichtlinearen Modellansätzen wie MLPs oder SVMs konnten keine besseren Ergebnisse als mit GPR erreicht werden. Die Idee hinter einem Gauß-Prozess ist es, eine Wahrscheinlichkeitsverteilung über Funktionen zu definieren. Für die Regression wird die A-priori-Verteilung der zu erlernenden Funktion definiert als:

$$\hat{y}(l) = \text{GP}(m(\mathbf{x}(l)), \kappa(\mathbf{x}(l), \mathbf{x}'(l))) \quad (3)$$

wobei $m(\mathbf{x})$ die Basis- bzw. Mittelwertfunktion und $\kappa(\mathbf{x}, \mathbf{x}')$ die Kovarianz-funktion für zwei Punkte \mathbf{x} und \mathbf{x}' im Eingangsraum ist (Index l im Folgenden weggelassen):

$$m(\mathbf{x}) = \mathbb{E}[f(\mathbf{x})] \quad (4)$$

$$\kappa(\mathbf{x}, \mathbf{x}') = \mathbb{E}[(f(\mathbf{x}) - m(\mathbf{x}))(f(\mathbf{x}') - m(\mathbf{x}'))^\top] \quad (5)$$

Tabelle 1: Entwurfsentscheidungen des Gaußprozessmodells bei BO

Hyperparameter	Varianten
Basisfunktion	{keine; konstant; linear; quadratisch}
Kernelfunktion	{exponentiell; rational-quadratisch; exponentiell-quadratisch; Matern32; Matern52; exponentiell mit ARD; rational-quadratisch mit ARD; exponentiell-quadratisch mit ARD; Matern32 mit ARD; Matern52 mit ARD }
Standardisierung	{true; false}

mit einen positiv-definiten Kernel $\kappa(\mathbf{x}, \mathbf{x}')$. Der Gauß-Prozess definiert eine gemeinsame Gauß-Verteilung für eine endliche Menge von Punkten:

$$p(y|\mathbf{X}) = \mathcal{N}(y|\mathbf{m}, \mathbf{K}) \quad (6)$$

mit der Designmatrix (zusammengesetzt aus den Eingangsdaten) $\mathbf{X} \in \mathbb{R}^{N \times n}$, der Kovarianzmatrix $\mathbf{K} \in \mathbb{R}^{N \times N}$, $K_{i,j} = \kappa(\mathbf{x}(i), \mathbf{x}(j))$, und dem Mittelwertvektor $\mathbf{m} = [m(\mathbf{x}(1)) \dots m(\mathbf{x}(N))]^T \in \mathbb{R}^N$. Der Kernel spielt eine Schlüsselrolle in Gauß-Prozessen, da er die Abhängigkeiten zwischen den Datenpunkten beschreibt. Dies beeinflusst das Verhalten des Modells maßgeblich.

Um die Ausgabe y_* für einen neuen Eingangswert \mathbf{x}_* vorherzusagen, wird die bedingte A-posteriori-Verteilung berechnet, indem die multivariate Gauß-Verteilung konditioniert wird (Mittelwert von 0 und kein Rauschen werden zur Vereinfachung angenommen):

$$p(y_*|\mathbf{x}_*, \mathbf{X}, \mathbf{y}) = \mathcal{N}(y_*|m_*, \kappa_*) \quad (7)$$

mit dem neuen Eingangswert $\mathbf{x}_* \in \mathbb{R}^n$ und dem Vektor der Ausgangsgrößen $\mathbf{y} \in \mathbb{R}^N$.

Während die Kernel-Parameter und die Varianz des Rauschens beim Modell-training durch Maximierung der Log-Marginal-Likelihood-Funktion bestimmt werden können, ist dies für weitere Hyperparameter nicht möglich. Daher wird

hier die Bayes'sche-Optimierung (BO) eingesetzt, um die Basisfunktion und die Kernelfunktion auszuwählen. Zudem werden die beiden Fälle standardisierter und nicht-standardisierter Daten betrachtet. Die Kernelparameter und die Rauschvarianz werden bei der BO mitoptimiert. Als Gütemaß wird dabei der kreuzvalidierte MSE herangezogen. In Tabelle 1 sind die Hyperparameter und deren Variationen dargestellt, die während der BO optimiert werden. Die BO wurde mit der Matlab-Funktion „`bayesopt`“ umgesetzt, die als Surrogatfunktion für die zu optimierende Zielfunktion ebenfalls ein GPR-Modell verwendet. Das zusammengefasste Vorgehen bei der Modellierung ist in Abbildung 2 dargestellt.

Die mit dem 3MA-Sensor bereitgestellte Toolbox verwendet eine multiple lineare Regression (MLR) folgender Form ohne Interaktionsterme

$$f(\mathbf{x}) = \sum_{k=1}^n a_k x_k^{b_k}, a_k \in \mathbb{R}, b_k \in \{0; 0,5; 12\} \quad (8)$$

mit einer schrittweisen Vorwärtsselektion und einer quadratischen Gütefunktion. Die Signifikanz eines hinzugefügten Modellterms wird mittels eines F -Tests bewertet. Dieser bewertet schrittweise die Güte von zwei Modellen, mit verschiedenen Teilmengen von Regressoren, ausgehend von einem konstanten Modell und folgt einer 'greedy' Suchstrategie folgt.

3 Daten

Die Daten stammen aus einem industriellen Hartdrehprozess mit vergütetem Stahl 51CrV4. Die Proben wurden bei unterschiedlichen Temperaturen gehärtet und angelassen, sodass sich drei verschiedene Ausgangshärtegrade ergaben: 400 HV, 500 HV und 600 HV. Durch die anschließende Hartdrehbearbeitung wurden die Prozessparameter nach einem vollfaktoriellen Versuchsplan variiert, wodurch verschiedene Oberflächenzustände der Werkstücke resultierten. Je Härtecharge wurden 27 Proben mit variierten Prozessparameterkombinationen erzeugt. Insgesamt sind also 81 Proben vorhanden. Die MM-Messungen wurden

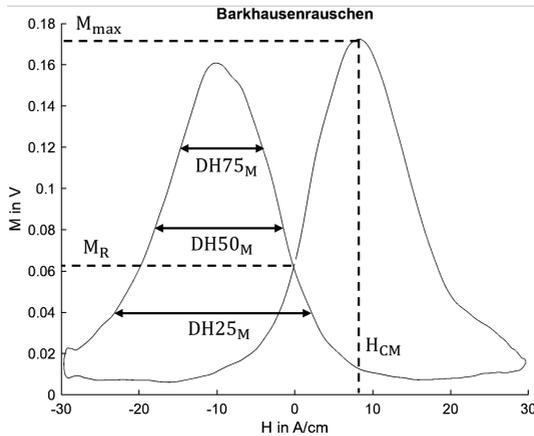


Bild 3: Beispielhafte Darstellung der sechs ermittelten Prüfgrößen aus den Messungen des Barkhausenrauschens

mit einem 3MA-II-Gerät des Fraunhofer IZFP durchgeführt. Der Versuchsaufbau mit dem 3MA-Sensor an der Drehmaschine ist in Abbildung 1 zu sehen.

Die Referenzmessungen der Eigenspannungen wurden mittels Röntgendiffraktometrie (XRD) ermittelt. Das 3MA-Gerät liefert für eine Messung 41 Prüfgrößen, die aus den gemessenen Zeitreihen abgeleitet werden. In Abbildung 3 sind beispielhaft 6 Prüfgrößen dargestellt, die aus einer Zeitreihe der Messung des Barkhausenrauschens abgeleitet werden. Dabei bezeichnet M_{\max} die maximale Rauschamplitude, M_R die Rauschamplitude im Remanenzpunkt, H_{CM} die Feldstärke im Rauschmaximum und DH_{xM} die Kurvenaufweitung bei $x\%$ der Kurvenhöhe. Für eine genauere Beschreibung der Prüfgrößen, auch der weiteren Messverfahren, wird auf [6] verwiesen. Die Messungen wurden mit zwei Magnetisierungsamplituden durchgeführt, wodurch $2 \times 41 = 82$ Prüfgrößen resultieren, die als Merkmale, bzw. potentielle Eingangsgrößen für das Kalibriermodell dienen. In Abbildung 4 ist die Korrelationsmatrix für den paarweisen Vergleich der Prüfgrößen dargestellt. Dabei handelt es sich bei den Größen 1-41 und 42-81 jeweils um die Prüfgrößen für die beiden Magnetisierungsamplituden. Es ist erkennbar, dass teilweise starke Korrelationen zwischen den Prüfgrößen auftreten, was eine Merkmalsselektion motiviert. So sind Blöcke mit stark

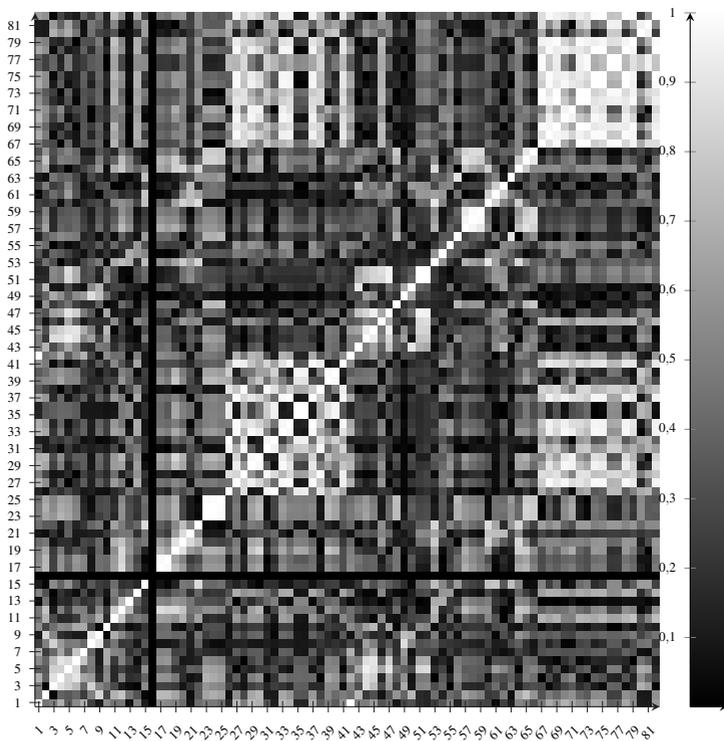


Bild 4: Korrelationsmatrixplot der Eingangsgrößen (Pearson-Korrelations-Koeffizient)

korrelierten Größen erkennbar. Dabei handelt es sich um die Kenngrößen aus den Wirbelstrommessungen, die offenbar teilweise redundante Informationen liefern.

Aus den mit XRD gemessenen Eigenspannungsverläufen in den ersten 200 μm der Werkstücke werden charakteristische Kennwerte extrahiert, die dann als Ausgangsgröße für die Kalibriermodelle eingesetzt werden. Aus Werkstoff- und Produktionstechnischer Sicht sind hierbei die Oberflächeneigenspannung sowie die maximale Druckeigenspannung von Interesse, da diese erheblichen Einfluss

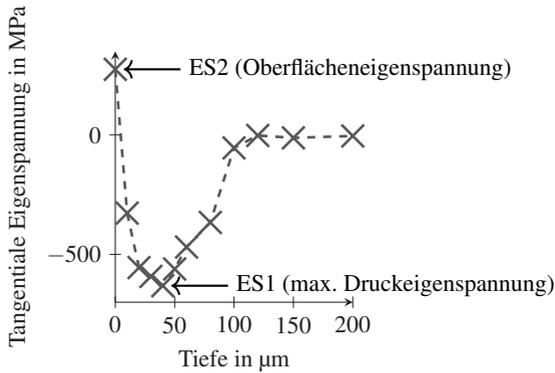


Bild 5: Beispielhafter Eigenspannungstiefenverlauf mit den charakteristischen Kennwerten

auf die Bauteileigenschaften wie Ermüdungsfestigkeit und Bruchzähigkeit haben [12]. In Abbildung 5 sind die Kennwerte in einem beispielhaften mit XRD gemessenen Eigenspannungstiefenverlauf dargestellt. ES1 ist dabei die Oberflächeneigenspannung und ES2 die maximale Druckeigenspannung.

4 Ergebnisse

Für die Bewertung der Modellgüte wird das für Regressionsmodelle übliche empirische Bestimmtheitsmaß R^2

$$R^2 = 1 - \frac{\sum_{l=1}^N (y(l) - \hat{y}(l))^2}{\sum_{l=1}^N (y(l) - \bar{y})^2} \quad (9)$$

mit dem Mittelwert \bar{y} verwendet. Um die Generalisierungsfähigkeit der Modelle zu bewerten, wird ein k -fach kreuzvalidiertes (CV) Bestimmtheitsmaß R_{CV}^2 verwendet. Dabei wird $k = 30$ gewählt, um bei dem kleinen Datensatz in jedem der k Folds relativ große Trainingsdatensätze zu erhalten. In Abbildung 6 sind die Predictor-Importance-Scores (Gleichung (2)) der 82 gerankten Merkmale dargestellt. Die Anzahl der vorselektierten Merkmale wird mit 25 festgelegt, da hier ein Knick im Ranking mit einem Abfall des Scores zu erkennen ist. Die Ergebnisse für GPR und MLR sind in Tabelle 2 für die Zielgrößen ES2

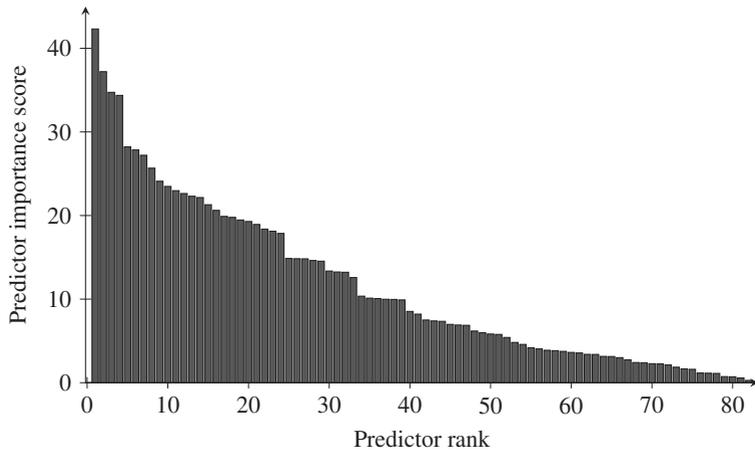


Bild 6: Ranking der Merkmale nach Predictor-Importance-Score für Zielgröße ES2

und ES1 dargestellt. Die GPR liefert deutlich bessere Ergebnisse als die MLR. Die Variante mit der Vorselektion liefert etwas bessere Ergebnisse und zeichnet sich daneben durch einen geringeren Rechenaufwand beim Training des GPR aus. Die mit BO ermittelten Hyperparameter der GPR-Modelle sind in Tabelle 3 dargestellt. Während die Standardisierung der Daten für beide Zielgrößen angewendet wird, wurden unterschiedliche optimale Basis- und Kernelfunktionen bestimmt. In Abbildung 7a und 7b ist ein Vergleich der prädizierten zu den wahren Werten für die Validierungsdaten der GPR mit Vorselektion sowie der MLR dargestellt. Bei MLR ist auffällig, dass die Streuung insbesondere bei den Werten um 0 sehr groß ist. Diese Ausreißer werden durch das GPR besser abgebildet. In Abbildung 7c und 7d sind die Fehler e in Abhängigkeit der prädizierten Werte dargestellt. Es ist erkennbar, dass das GPR im Vergleich zum MLR nur wenige Fehler $e > |200|$ MPa aufweist, also zu deutlich weniger großen Abweichungen in den Prädiktionen führt.

Um die Ergebnisse mit dem GPR-Model mit Vorselektion (welches im obigen Vergleich die besten Ergebnisse erzielte) direkt mit den Ergebnissen mit dem Standardverfahren für die Kalibrierung des 3MA-Sensors zu vergleichen, wird das selbe Szenario wie in [4] verwendet. Hier wird nur die 500 HV-Charge. Da ein ursprünglich ein vollfaktorieller Experimententwurf mit 3 Faktoren

Tabelle 2: Vergleich der Modellgüten mit Kreuzvalidierung für die Zielgrößen ES2 (maximale Druckeigenspannung) und ES1 (Oberflächeneigenspannung)

Ausgangsgröße	Modell	R^2_{CV}
ES2	GPR ohne Vorselektion	0,9035
	GPR mit Vorselektion	0,9169
	MLR mit SWR wie in [4]	0,692
ES1	GPR ohne Vorselektion	0,8836
	GPR mit Vorselektion	0,8901
	MLR mit SWR wie in [4]	0,6452

Tabelle 3: Mit BO ermittelte Hyperparameter der GPR-Modelle für die Zielgrößen ES1 und ES2.

	ES1	ES2
Basisfunktion	konstant	linear
Kernelfunktion	rational-quadr. m. ARD	exponentiell-quadr.
Standardisierung	true	true

und 3 Faktorstufen verwendet wurde, ergibt sich also ein Datensatz mit $N = 27$. Es werden 5 Hold-Out(HO)-Daten für die Validierung eingesetzt. Die Ergebnisse sind in Tabelle 4 für ES2 und ES1 dargestellt. Auch hier sind die Ergebnisse mit dem GPR deutlich besser. Allerdings ist die Validierung mit 5 Datenpunkten bei 22 Trainingsdaten nur bedingt aussagekräftig, im Vergleich zur Kreuzvalidierung. Zudem ist der Trainingsdatensatz, der nur die 500-HV-Charge beinhaltet, sehr klein.

5 Zusammenfassung und Ausblick

In diesem Beitrag wurde ein Ansatz für die datengetriebene Modellierung für die Erstellung von Kalibriermodellen vorgestellt. Es konnte für ein mikromagnetisches Sensorsystem gezeigt werden, dass der Ansatz zur nichtparametrischen Modellierung gut geeignet ist und eine Modellgüte erreicht, die einen Einsatz

Tabelle 4: Vergleich der Modellgüten mit Hold-Out-Testdaten, wie in [4] für die Zielgrößen ES2 (maximale Druckeigenspannung) und ES1 (Oberflächeneigenspannung)

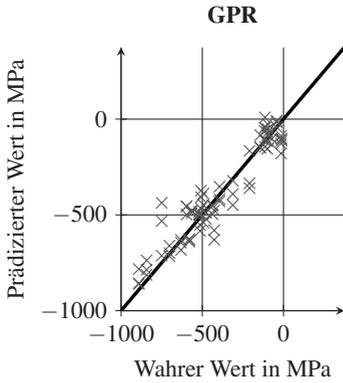
Ausgangsgröße	Modell	R_{HO}^2
ES2	GPR mit Vorselektion	0,8625
	MLR mit SWR wie in [4]	0,6317
ES1	GPR mit Vorselektion	0,8731
	MLR mit SWR wie in [4]	0,6474

in der Prozessüberwachung oder für eine Prozesssteuerung bzw. -regelung ermöglicht.

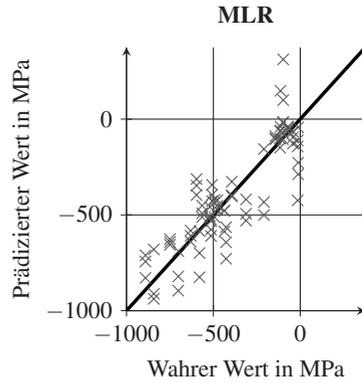
Dabei wurde ein einfaches Verfahren zur Vorselektion der Merkmale verwendet. In der Zukunft sollen hier weitere Wrapper-, Filter-, und Embedded-Verfahren untersucht werden. Darauf aufbauend soll das Verfahren um eine ensemblebasierte Merkmalsextraktion und -selektion erweitert werden. Dabei sollen die Rohdaten, also die gemessenen Zeitreihen des mikromagnetischen Sensors, verwendet werden. Damit soll es möglich sein, mit einem automatisierten Ansatz die Kalibriermodellerstellung für eine große Bandbreite an Werkstoffen und Zielgrößen zu ermöglichen. Neue Experimente und Messungen für diese Untersuchungen werden momentan durchgeführt. Dabei wird auch die Oberflächenhärte erfasst, um die Übertragbarkeit auf andere Zielgröße zu untersuchen.

6 Danksagung

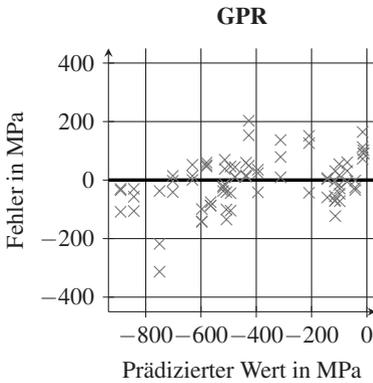
Gefördert durch die Deutsche Forschungsgemeinschaft (DFG) - Projektnummer 532921704. Die Autoren danken dem Fachgebiet Metallische Werkstoffe der Universität Kassel für die Durchführung der Hartdrehversuche sowie die Durchführung der Referenz- sowie mikromagnetischen Messungen.



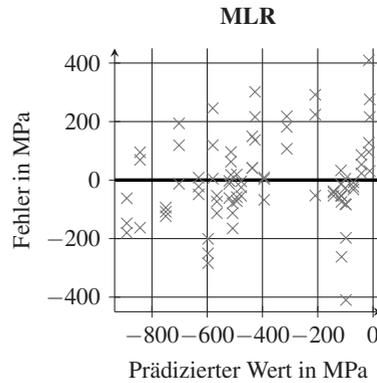
(a) Wahre Werte vs. prädizierte Werte für GPR mit Vorselektion (Validierungsdaten)



(b) Wahre Werte vs. prädizierte Werte für MLR (Validierungsdaten)



(c) Prädizierte Werte vs. Fehler für GPR mit Vorselektion (Validierungsdaten)



(d) Prädizierte Werte vs. Fehler für MLR (Validierungsdaten)

Bild 7: Vergleich von MLR und GPR bezüglich der Prädiktionen (a), (b) und Fehler (c), (d) für die Validierungsdaten der Modelle für ES2

Literatur

- [1] G. Dobmann, W. A. Theiner, and R. Becker, *Progress in the Micromagnetic Multiparameter Microstructure and Stress Analysis (3MA)*, p. 516–523. Springer Berlin Heidelberg, 1989.
- [2] F. Wittich, T. Wegener, A. Liehr, W. Zinn, T. Niendorf, and A. Kroll, “Data-driven prediction of the surface layer state in hard-turning for optimization of component quality,” *Production Engineering*, vol. 18, p. 381–392, Jan. 2024.
- [3] B. Wolter, Y. Gabi, and C. Conrad, “Nondestructive testing with 3MA—an overview of principles and applications,” *Applied Sciences*, vol. 9, no. 6, 2019.
- [4] T. Wegener, A. Liehr, A. Bolender, S. Degener, F. Wittich, A. Kroll, and T. Niendorf, “Calibration and validation of micromagnetic data for non-destructive analysis of near-surface properties after hard turning,” *HTM Journal of Heat Treatment and Materials*, vol. 77, no. 2, pp. 156–172, 2022.
- [5] N. Baak, R. Hajavifard, L. Lücker, J. Rozo Vasquez, S. Strodtick, M. Teschke, and F. Walther, “Micromagnetic approaches for microstructure analysis and capability assessment,” *Materials Characterization*, vol. 178, Aug. 2021.
- [6] S. Youssef, C. Zimmer, K. Szielasko, and A. Schütze, “Bewertung subjektiver und automatisierter Merkmalsextraktion periodischer Zeitsignale am Beispiel des 3MA-X8-Verfahrens,” *tm - Technisches Messen*, vol. 86, pp. 267–277, Jan. 2019.
- [7] S. Youssef, C. Zimmer, K. Szielasko, Z. K. Suri, and A. Schütze, “Vergleich subjektiver und automatisierter Merkmalsextraktion sowie Einsatz maschineller Lernalgorithmen zur mikromagnetischen Materialcharakterisierung,” in *Tagungsband 20. GMA/ITG-Fachtagung Sensoren und Messsysteme*, pp. 347–354, 2019.

- [8] K. Szielasko, B. Wolter, R. Tschuncky, and S. Youssef, “Micromagnetic materials characterization using machine learning: Progress in nondestructive prediction of mechanical properties of steel and iron,” *tm - Technisches Messen*, vol. 87, pp. 428–437, Oct. 2019.
- [9] R. Jedamski and J. Epp, “Non-destructive micromagnetic determination of hardness and case hardening depth using linear regression analysis and artificial neural networks,” *Metals*, vol. 11, Dec. 2020.
- [10] C. E. Rasmussen and C. K. I. Williams, *Gaussian Processes for Machine Learning*. The MIT Press, 2005.
- [11] F. Wittich, L. Kistner, A. Kroll, C. Schott, and T. Niendorf, “On data-driven nonlinear uncertainty modeling: Methods and application for control-oriented surface condition prediction in hard turning,” *tm - Technisches Messen*, vol. 87, pp. 732–741, oct 2020.
- [12] F. Hashimoto, Y. Guo, and A. Warren, “Surface integrity difference between hard turned and ground surfaces and its impact on fatigue life,” *CIRP Annals*, vol. 55, no. 1, pp. 81–84, 2006.