

Abschätzung der Messunsicherheit in smarten Sensornetzwerken mittels künstlichem Rauschen und maschinellem Lernen

Tanja Dorst¹, Patrick Christoffel², Julian Kunze², Andreas Schütze^{1,2}

¹ZEMA – Zentrum für Mechatronik und Automatisierungstechnik gGmbH, Saarbrücken, Deutschland

²Universität des Saarlandes, Lehrstuhl für Messtechnik, Saarbrücken, Deutschland

Kontakt: t.dorst@zema.de

Einleitung

Kalibrierung, Messunsicherheiten und damit Rückführbarkeit auf das internationale Einheitensystem SI (*Système International d'Unités*) zählen zu den bedeutendsten metrologischen Grundprinzipien. Zur Bewertung der Datenqualität und damit auch der Qualität und Verlässlichkeit von Ergebnissen des maschinellen Lernens ist die Kenntnis über die Größe der Messunsicherheit der Messwerte erforderlich. Zur genauen Bestimmung der Messunsicherheit ist in der Regel eine Kalibrierung der verwendeten Sensoren nötig, was sehr aufwendig und teuer sein kann. Daher wird aus Kostengründen in neuen Prüfständen oft auf kalibrierte Sensoren verzichtet und auch bei bestehenden Prüfständen gestaltet sich ein Sensorausbau zur Rekalibrierung oft schwierig bis unmöglich. Für grobe Abschätzungen der zu erwartenden Messunsicherheiten bei den verwendeten Sensoren und damit der Datenqualität an sich können Informationen aus den Datenblättern der Sensorhersteller herangezogen werden. Auch dies gestaltet sich schwierig, da gerade bei älteren Sensoren oft keine Datenblätter mehr zur Verfügung stehen und Datenblätter nicht immer alle benötigten Informationen beinhalten; zudem stellt dies eine sehr pessimistische Abschätzung dar.

Aus den genannten Gründen zeigt dieser Beitrag, wie auch ohne Informationen aus Herstellerdatenblättern und ohne teure Kalibrierung die Messunsicherheit der Sensorrohdaten mit Hilfe von künstlich erzeugtem additivem weißem Rauschen und einer Mustererkennung mittels maschinellem Lernen abgeschätzt werden kann. Mit Hilfe von Kurvenfits an die Kurve, die aus den Klassifikationsergebnissen der verschiedenen Rauschlevel entsteht, können Rückschlüsse von den Klassifikationsergebnissen auf die Standardmessunsicherheit des Sensors gezogen werden, da ein Rauschen größer als die Standardmessunsicherheit zu einer Verschlechterung der Klassifikationsergebnisse führt.

Grundlagen und allgemeine Vorgehensweise

Um Messunsicherheiten nach dem *Guide to the Expression of Uncertainty in Measurement (GUM)* [1] und seinen beiden Ergänzungen [2,3] bestimmen zu können, werden neben den eigentlichen Messwerten auch die zugeordneten Standardmessunsicherheiten benötigt. Um diese Unsicherheiten in diesem Beitrag abzuschätzen, wird ein Datensatz eines hydraulischen Systems betrachtet [4]. In diesem in Abb. 1

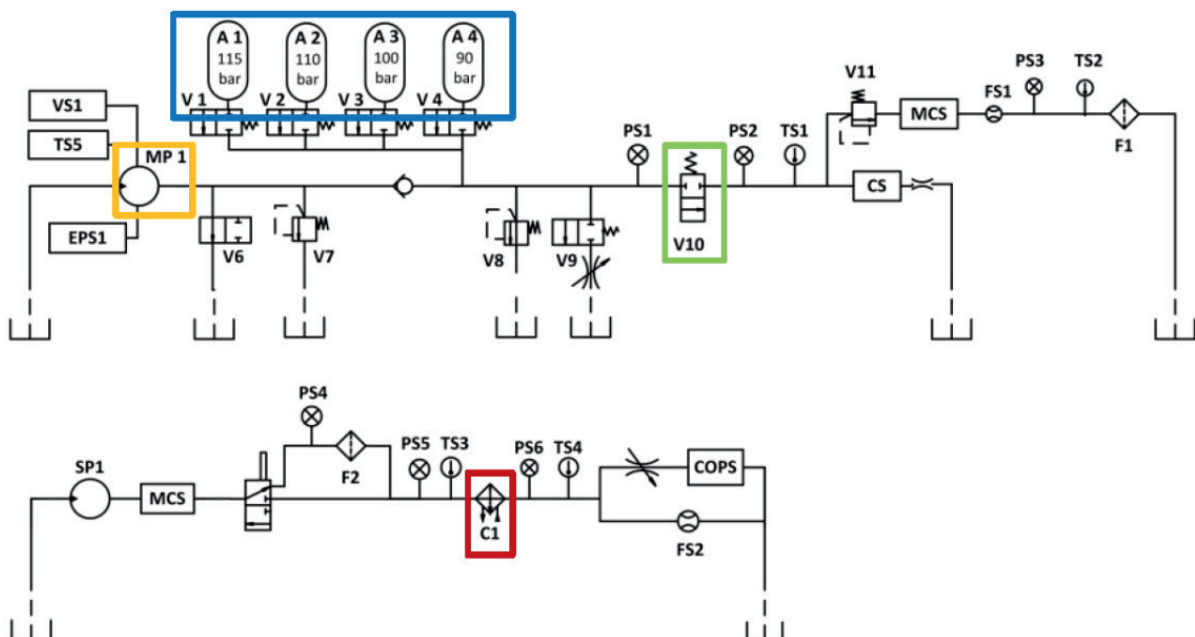


Abb. 1: Hydraulisches System, in welchem verschiedene Fehlerzustände der Hydrospeicher A1 - A4 (blau), der Pumpe MP1 (gelb), des Ventils V10 (grün) und des Kühlers C1 (rot) simuliert werden [5]

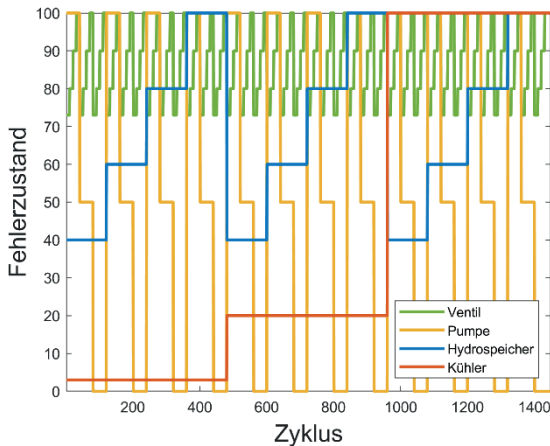


Abb. 2: Fehlerzustände von Ventil, Pumpe, Hydrospeicher und Kühler für die verschiedenen Zyklen.

gezeigten hydraulischen System werden zyklensweise verschiedene Fehlerzustände bei Pumpe, Hydrospeicher, Ventil und Kühler simuliert und die Daten mit Hilfe von 17 Sensoren erfasst [5, 6]. Die vier verschiedenen Fehlerzustände pro Zyklus werden wie in Abb. 2 gezeigt systematisch kombiniert, so dass der Datensatz Zyklen mit jeder Kombination der Fehlerzustände enthält. Zur Abschätzung der Messunsicherheit eines Sensors werden je ein Sensor und ein Fehlerzustand aus dem Datensatz des hydraulischen Systems ausgewählt.

Die Sensorrohdaten $S \in \mathbb{R}^{m \times n}$ werden durch additives weißes gaußsches Rauschen $N \in \mathbb{R}^{m \times n}$ manipuliert (siehe Abb. 3), d.h. es gilt für die verrauschten Daten

$$G = S + N \in \mathbb{R}^{m \times n},$$

mit $n(t) = \sigma \cdot rand$, $\sigma \in \mathbb{R}$. $rand \in \mathbb{R}^{m \times n}$ bezeichnet die normalverteilten Zufallszahlen derselben




Abb. 3: Signal des Drucksensors PS1 (vgl. Abb. 1) mit additivem weißem gaußsches Rauschen verschiedener Intensitäten.

Dimension wie die Sensorrohdaten S . Für die quadrierte Standardunsicherheit gilt

$$\sigma^2 = 10^{\frac{sp-snr}{10}} \quad (1)$$

wobei $sp \in \mathbb{R}$ den Signalpegel (engl. *signal power*) und $snr \in \mathbb{R}$ das Signal-Rausch-Verhältnis (SNR, engl. *signal-to-noise ratio*) eines Zyklus, d.h. einer Zeile der Matrix S , bezeichnet. Der Signalpegel berechnet sich durch

$$sp = 10 \cdot \log_{10} \frac{\|s\|_2^2}{n},$$

wobei s einen Zyklus aus S , $\|s\|_2$ die euklidische Norm und n die Anzahl der Datenpunkte in einem Zyklus bezeichnet.

Zur Abschätzung der Messunsicherheiten wird eine der 15 möglichen Kombinationsmöglichkeiten aus Merkmalsextraktion (ME) und -selektion (MS) aus der Toolbox für automatisiertes maschinelles Lernen [7, 8], deren Schema in Abb. 4 gezeigt ist,

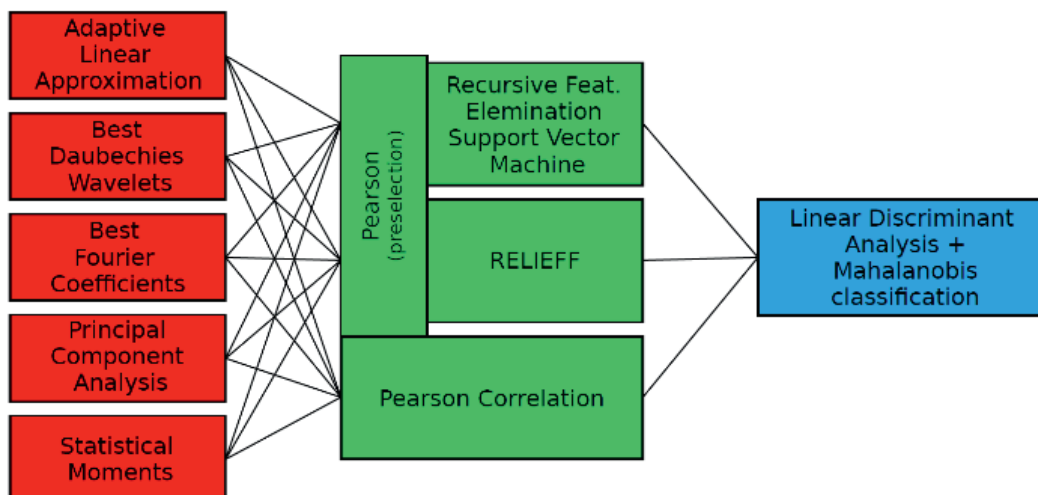


Abb. 4: Automatisierte Toolbox für maschinelles Lernen mit Merkmalsextraktion (ME, rot), Merkmalsselektion (MS, grün) und Klassifikation (blau) [9].

ausgewählt. Während bei der ME Merkmale aus den Sensorrohdaten generiert werden, wird bei der MS die Anzahl der Merkmale deutlich reduziert und redundante Merkmale oder Merkmale mit wenig bis kaum Informationsgehalt werden aus der Menge aller extrahierten Merkmale entfernt. Vor der Klassifikation wird zunächst eine weitere Dimensionsreduktion mittels Linearer Diskriminanzanalyse (LDA) durchgeführt, anschließend erfolgt die eigentliche Klassifikation mittels Mahalanobis Distanz zu den Gruppenmittelpunkten. Die drei Schritte ME, MS und abschließende Klassifikation werden mit den künstlich durch additives weißes gaußsches Rauschen verschiedener Rauschlevel verrauschten Sensorrohdaten durchgeführt.

Ergebnisse der Messunsicherheitsabschätzung durch maschinelles Lernen

Um Messunsicherheiten abschätzen zu können, muss zunächst gezeigt werden, dass ein Zusammenhang zwischen dem Klassifikationsergebnis und dem Rauschlevel der Eingangsdaten in die automatisierte Toolbox für maschinelles Lernen besteht.

Wie in Abb. 5 ersichtlich, besteht eine Korrelation zwischen dem SNR und der Anzahl an korrekt klassifizierten Daten, die eine statistische Relevanz aufweist. Es ist anzumerken, dass sich die Ergebnisse für einen einzelnen Sensor bezogen auf ein einzelnes Target repräsentativ reproduzieren lassen und bei schlechter werdendem SNR eine Verschlechterung der Klassifizierung, bis hin zu einem Punkt, an dem die Daten gleichverteilt einer zufälligen Klasse zugeordnet werden, aufweisen. Bei Verwendung mehrerer Sensoren ist dieses Verhalten nicht mehr garantiert, da die zusätzlichen Sensoren unter Umständen zu viel Information zur Klassifizierung beitragen,

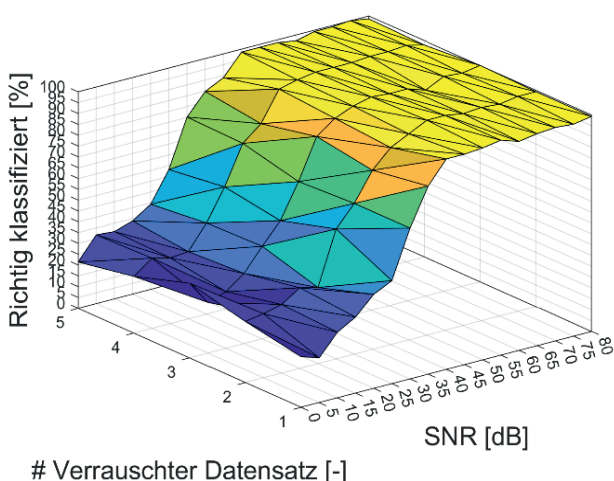


Abb. 5: Klassifikationsergebnisse für verschiedene Rauschintensitäten und den Akkumulator mit Hauptkomponentenanalyse (PCA) als ME und Pearson Korrelation als MS.

wodurch es einerseits zu einer starken Verzögerung bei der Verschlechterung der Ergebnisse kommen kann, andererseits tritt bedingt durch die Redundanz der Sensordaten oftmals gar keine Verschlechterung der Klassifikation ein. Im in Abb. 5 gezeigten Fall werden Fehlerzustände des Hydrospeichers (vier verschiedene Vordrücke) mittels Drucksensor PS1 klassifiziert. Dabei zeigt die ME mittels Hauptkomponentenanalyse (PCA) in Kombination mit anschließender MS mittels Pearson Korrelation gute und zuverlässige Ergebnisse, je nach ausgewähltem Sensor und Art der benötigten Information kann es jedoch notwendig sein, andere Methoden zu verwenden.

Um aus den gewonnenen Erkenntnissen einen Rückschluss auf die Messunsicherheit ziehen zu können, wurde nachfolgend versucht, mittels verschiedener Methoden eine Berechnungsvorschrift abzuleiten. Wie in Abb. 6 ersichtlich ist eine Rückrechnung durch eine Exponentialfunktion mit zwei Termen als approximierende Kurve möglich, wobei die Approximation speziell im Bereich großer SNR-Werte nicht immer zu brauchbaren Ergebnissen führt.

Auch andere Modellfunktionen, u.a. einfache lineare Funktionsansätze, aber auch deutlich aufwändigere Fourierreihenansätze

$$f(x) = a_0 + a_1 \cdot \cos(x \cdot p) + b_1 \cdot \sin(x \cdot p) + a_2 \cdot \cos(2 \cdot x \cdot p) + b_2 \cdot \sin(2 \cdot x \cdot p),$$

weisen ähnlich Probleme auf. Dies lässt sich auf die hohe Dichte an Datenpunkten in diesem Bereich zurückführen, wodurch dort vermehrt redundante Punkte auftreten, während die Anzahl an Punkten im Bereich schlechter werdender Klassifikationsergebnisse immer weiter abnimmt. Eine Möglichkeit, das Ergebnis zu verbessern, besteht in der Einschränkung des Definitionsbereichs beispielsweise auf Klassifikationsraten zwischen 70% und 100%, da

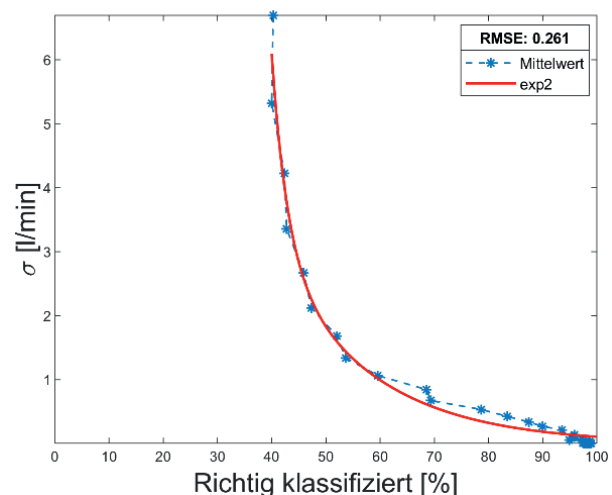


Abb. 6: Kurvenfit der Standardabweichung über den korrekt klassifizierten Daten für den Durchflusssensor FS1 (vgl. Abb. 1) mittels Exponentialfunktion (Modellfunktion:

$$f(x) = a \cdot \exp(b \cdot x) + c \cdot \exp(d \cdot x)).$$




Abb. 7: Kurvenfit mittels Feedforward Neural Network der Standardabweichung über dem Prozentsatz der korrekt klassifizierten Daten für den Durchflusssensor FS1 (vgl. Abb. 1).

schlechtere Klassifikationsraten in einem realen System keinen nennenswerten Nutzen mehr haben. Hierdurch kann je nach verwendetem Sensor ein nahezu linearer Verlauf angenommen werden. Da dies jedoch nicht auf alle Sensoren anwendbar ist, ist es naheliegend, eine allgemeinere Methode zur Kurvenanpassung zu finden.

Eine Möglichkeit hierfür bieten neuronale Netze (NN), die als universeller Interpolator auch komplexe Kurvenverläufe präzise und zuverlässig abbilden können. Abb. 7 zeigt das Ergebnis eines *Feedforward Neural Network* mit einem *Hidden Layer* und fünf Neuronen, wobei als Trainingsalgorithmus *Bayesian Regularization* zum Einsatz kam. Das NN bildet den Zusammenhang zwischen der Klassifikationsrate und dem vorhandenen Rauschen bei dem vorliegenden Beispiel sowie bei anderen Sensoren des Hydraulikdatensatzes zuverlässig ab, jedoch ist der Rechenaufwand im Vergleich zu anderen Interpolationsmethoden häufig höher. Zudem besteht bei neuronalen Netzen immer die Gefahr des Overfittings, d.h. der Überanpassung des Modells an die Daten.

Zuletzt wird die Möglichkeit der Abschätzung über eine Sigmoidfunktion betrachtet. Im Folgenden wird der sich aus der Simulation ergebende Anteil der korrekt klassifizierten Messzyklen in Abhängigkeit vom SNR als C bezeichnet. An diese diskreten Werte wird eine analytische kontinuierliche Funktion $C(snr)$ gefittet. Um eine inverse $snr(C)$ bestimmen zu können, muss $C(snr)$ streng monoton sein. Außerdem lassen sich Grenzwerte durch die im Folgenden beschriebenen Überlegungen definieren.

Geht SNR gegen 0, so ist zu erwarten, dass die Messzyklen gleichverteilt sind und zufällig in eine Klasse eingeordnet werden. Daher gilt

$$\lim_{snr \rightarrow 0} C(snr) = C_{min} \approx \frac{1}{n_{classes}} \quad (2)$$

Für sehr großes SNR hingegen sollte sich $C(snr)$ einem maximalen Wert annähern, der der Klassifikationsrate ohne Rauschen entspricht. In diesem Fall soll also

$$\lim_{snr \rightarrow \infty} C(snr) = C_{max} \quad (3)$$

gelten. Schließlich soll sich die analytische kontinuierliche Funktion $C(snr)$ durch möglichst wenige, interpretierbare Parameter beschreiben lassen. Eine mögliche Funktionenklasse, die diese Eigenschaften erfüllt, sind Sigmoidfunktionen. Insbesondere die logistische Funktion [10]

$$f(x) = \frac{L}{1 + e^{-t(x-x_0)}} \quad (4)$$

bietet sich als Ausgangspunkt an. Da die gefittete Standardunsicherheit $\sigma(C)$ von Interesse ist und diese unter anderem, wie in (1) beschrieben, von einem Term $10^{g(snr,sp)}$ abhängig ist, wird die Sigmoidfunktion so modifiziert, dass an Stelle der Basis e (Eulersche Zahl) die Basis 10 verwendet wird. Wie noch gezeigt wird, ergibt sich somit eine elegantere Beschreibung von $\sigma(C)$.

Als Ansatz wird die modifizierte, skalierte und verschobene Fit-Funktion

$$C(snr) = C_{min} + \frac{C_{max} - C_{min}}{1 + 10^{-t(snr_{infl} - snr)}} \quad (5)$$

mit dem Parameter

$$snr_{infl} = snr \left(\frac{C_{max} + C_{min}}{2} \right) \quad (6)$$

als Wert von snr am Wendepunkt P_{infl} der Sigmoidfunktion verwendet (vgl. Abb. 8). Der Parameter t hängt mit der Steigung s in P_{infl} über

$$s = - \frac{t \cdot \ln(10) \cdot (C_{min} - C_{max})}{4} \quad (7)$$

zusammen.

Um diesen theoretischen Ansatz zu testen, wurden mit Hilfe der automatisierten ML-Toolbox [7, 8] die Fehlerzustände des Hydrospeichers aus den Sensordaten des Durchflusssensors FS1, der Motorleistung EPS1 und des Drucksensors PS2 extrahiert. Die beste Kombination war stets Beste Fourier Koeffizienten (BFC) [11] als ME, Pearson als Vorselektion mit anschließender *Recursive Feature Elimination Support Vector Machine* (RFESVM) [12, 13] als MS. Die Klassifikation wurde immer mit LDA und Mahalanobis Distanz durchgeführt. Die Parameter C_{min} und

C_{max} werden nach Gl. (2) und (3) bestimmt, während t und snr_{infl} an die Simulationsdaten gefittet werden. In Abb. 8 ist einer dieser Fits gezeigt. Um schließlich die Standardmessunsicherheit $\sigma(C)$ aus dem Anteil der korrekt klassifizierten Datensätze zu bestimmen, wird Gl. (5) nach snr aufgelöst und in Gl. (1) eingesetzt. Mit

$$\sigma_{infl}^2 = 10^{\frac{sp-snr_{infl}}{10}} \quad (8)$$

ergibt sich somit zur Abschätzung der Standardmessunsicherheit die simple Formel

$$\sigma(C) = \sigma_{infl} \left(-\frac{C-C_{max}}{C-C_{min}} \right)^{\frac{1}{20t}}. \quad (9)$$




Abb. 8: Fit der Klassifikationsergebnisse mit dem Durchflusssensor FS1 für den Hydrospeicher durch eine Sigmoidfunktion.

Der Graph dieser Funktion für die Abschätzung der Messunsicherheit des Durchflusssensor FS1 ist in Abb. 9 gezeigt.

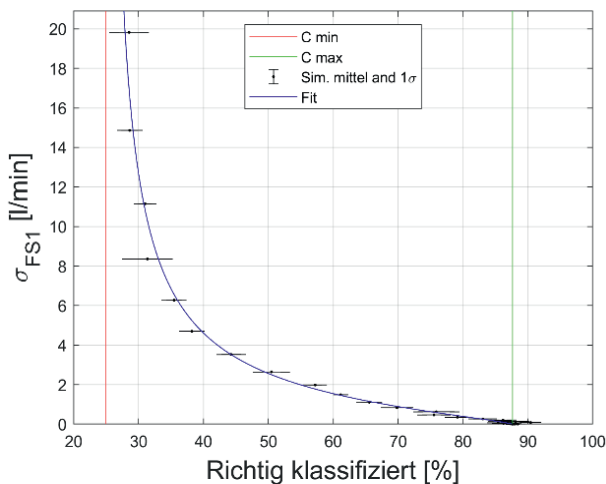


Abb. 9: Funktion $\sigma(C)$ nach Gl. (9) für die Daten des Durchflusssensor FS1 und die Fehlerzustände des Hydrospeichers als Target.

Zusammenfassung und Ausblick

In diesem Beitrag wurde gezeigt, wie man mittels künstlicher erzeugtem weißen gaußschen Rauschen nützliche Abschätzungen bzgl. der Standardmessunsicherheit von Sensoren durchführen kann, da Abschätzungen mit Hilfe der Datenblätter der Sensorhersteller meist sehr grob sind. Zur Abschätzung wurden zum einen einfache Kurvenfits u.a. mit linearen und exponentiellen Funktionen, Fourierreihenansätzen sowie der Sigmoidfunktion verwendet, zum anderen kamen auch neuronale Netze zum Einsatz. Ein guter Kompromiss zwischen Laufzeit und Genauigkeit zeigt dabei die Sigmoidfunktion. Neuronale Netze zeigen zwar sehr gute Ergebnisse, allerdings bei deutliche größerem Rechenaufwand.

Für die Zukunft ist geplant, diese so abgeschätzten Standardmessunsicherheiten mit Hilfe von Kalibrierdaten und somit wahren Messunsicherheitswerten verschiedener Sensoren auf ihre Genauigkeit zu untersuchen.

Literatur

- [1] Joint Committee for Guides in Metrology, "JCGM 100: Evaluation of measurement data — Guide to the expression of uncertainty in measurement," JCGM100:2008, 2008.
- [2] Joint Committee for Guides in Metrology, "JCGM 101: Evaluation of measurement data — Supplement 1 to the 'Guide to the expression of uncertainty in measurement' — Propagation of distributions using a Monte Carlo method," JCGM101:2008, 2008.
- [3] Joint Committee for Guides in Metrology, "JCGM 102: Evaluation of measurement data — Supplement 2 to the 'Guide to the expression of uncertainty in measurement' — Extension to any number of output quantities," JCGM102:2011, 2011.
- [4] T. Schneider, S. Klein, and M. Bastuck, "Condition monitoring of hydraulic systems Data Set at ZeMA," Apr. 2018, doi: 10.5281/ZENODO.1323611.
- [5] N. Helwig, E. Pignanelli, and A. Schütze, "Condition monitoring of a complex hydraulic system using multivariate statistics," Conf. Rec. - IEEE Instrum. Meas. Technol. Conf., pp. 210–215, 2015, doi: 10.1109/I2MTC.2015.7151267.
- [6] N. Helwig, E. Pignanelli, and A. Schütze, "Detecting and Compensating Sensor Faults in a Hydraulic Condition Monitoring System," Proc. Sens. 2015, pp. 641–646, 2015, doi: 10.5162/sensor2015/D8.1.
- [7] T. Schneider, N. Helwig, and A. Schütze, "Automatic feature extraction and selection for classification of cyclical time series data," Tech. Mess., vol. 84, no. 3, pp. 198–206, 2017, doi: 10.1515/teme-2016-0072.
- [8] T. Schneider, N. Helwig, and A. Schütze, "Industrial condition monitoring with smart sensors using automated feature extraction and selection," Meas. Sci. Technol., vol. 29, no. 9, 2018, doi: 10.1088/1361-6501/aad1d4.
- [9] T. Dorst, Y. Robin, T. Schneider, and A. Schütze, "Automated ML Toolbox for Cyclic Sensor Data," MSMM 2021, pp. 149–150, 2021.

- [10] L. J. Reed, and J. Berkson, "The Application of the Logistic Function to Experimental Data.," *J. Phys. Chem.*, vol. 33, no. 5, pp. 760–779, May 1929, doi: 10.1021/j150299a014.
- [11] F. Mörchen, "Time series feature extraction for data mining using DWT and DFT," *Dep. Math. Comput. Sci. Univ. Marburg, Ger. - Tech. Rep.*, vol. 33, pp. 1–31, 2003.
- [12] A. Rakotomamonjy, "Variable Selection Using SVM-based Criteria," *J. Mach. Learn. Res.*, vol. 3, pp. 1357–1370, 2003.
- [13] I. Guyon, and A. Elisseeff, "An introduction to variable and feature selection," *J. Mach. Learn. Res.*, vol. 3, pp. 1157--1182, 2003.