

HSBI

Hochschule
Bielefeld
University of
Applied Sciences



iDaS

Institute for Data Science
Solutions of HSBI

Kongress KI@HSBI2023 Solutions im Fokus -Posterbeiträge-

Schriftenreihe des Institute for Data Science Solutions

Nr. 1/ 2024

DOI: <https://doi.org/10.60802/sidas.2024.1>
ISSN: 2943-3509



Dieses Dokument ist lizenziert gemäß CC BY <https://creativecommons.org/licenses/by/4.0/> Ausgenommen von der Lizenz sind alle Wort-/Bildmarken und Logos

Die Autor*innen tragen die Verantwortung für die Einhaltung der urheberrechtlichen Bestimmungen. Zum Zeitpunkt der Drucklegung führten die Verweise auf Internetseiten zu den gewünschten Inhalten. Sollten zu einem späteren Zeitpunkt die Internetseiten verändert worden sein, distanzieren sich die Autor*innen von den inhaltlichen Aussagen der Internetseiten.

Inhaltsverzeichnis

Einleitung: Poster auf dem Kongress KI@HSBI2023 an der Hochschule Bielefeld	3
C. Bermpfer	
Utilizing Sensitivity Analysis in Data Generation for Machine Learning Training	4
N. Grimmelsmann	
Predicting the Extent of Co-Activation of One Muscle Head by sEMG-Measurements from the Other Muscle Head of the Biceps Brachii Using Linear Regression and Shallow Feedforward Neural Networks	6
T. Herzig	
KI-gestütztes Monitoring zur Unterstützung in der häuslichen Pflege (KIMUP) – Ein Projekt aus dem Reallabor Geriatrie	9
K. Hunke	
Bioinspired Feature Extraction for the Electric Field-based Determination of Object Size and Position.....	11
B. Jaster	
Active Learning for Regression with Ensemble Methods. Exploring the trade-off between quality and computational effort.....	14
P. Jünemann	
Comparative Study of a Parameter Tuned Bioinspired Binaural Sound Source. Localization Algorithm and a Standard Beamformer	16
F. Karau	
Approximation einer modellprädiktiven Antriebsregelung durch ein neuronales Netz	18

J. Kösters

Machine Learning Methoden für geringe Datenmengen – Grundlage für datenbasierte industrielle Auslegungen20

F. Maoro

Erklärbarkeit vertrauenswürdiger KI-Sprachmodelle für den transparenten Gebrauch bei Sicherheitsbehörden22

M. Mechtenberg

Improvement of sEMG Exoskeleton Control Based on Prediction of the Myotendinous System State24

M. Niederhaus

Validierung einer Prescriptive-Analytics-Plattform für Produktionsanlagen.-VIP4PAPS-.....26

M. Schöne

AI for Scarce Data (AI4ScaDa) – Maschinelles Lernen und Informationsfusion zur nachhaltigen Nutzung von Labor- und Kundendaten.....28



Poster auf dem Kongress KI@HSBI2023 an der Hochschule Bielefeld

Am 30. November 2023 fand an der Hochschule Bielefeld der Kongress KI@HSBI 2023 statt. Unter dem Motto „Solutions im Fokus“ tauschten sich rund 360 Teilnehmende, darunter Vertreterinnen und Vertreter von Unternehmen als auch Studierende, Lehrende und Promovierende der HSBI, über aktuelle Entwicklungen sowie über Einsatzmöglichkeiten und Anwendungsbereiche von Künstlicher Intelligenz aus.

Neben vielen verschiedenen Formaten wie Vorträgen, Workshops oder einer KI-Expo, zeigten Studierende und Promovierende auf insgesamt 27 Postern ihre Projekte, Vorhaben oder Ergebnisse.

Organisiert wurde der Kongress vom Institute for Data Science Solutions (IDaS) der HSBI, das sich in seiner Arbeit inhaltlich auf die Themen Data Science, KI, sowie Optimierung und Simulation fokussiert. Dabei stehen die Daten und deren Anwendung für den Einsatz von Künstlicher Intelligenz im Mittelpunkt. Die Anwendungsdomänen ergeben sich aus aktuellen gesellschaftlichen Herausforderungen. So entwickelt das IDaS gemeinsam mit Partnern aus der Wirtschaft und anderen Forschungseinrichtungen Lösungen mittels KI zum Beispiel zu den Themen Nachhaltigkeit, Klimaschutz, Sicherheit, Produktivität, u.v.m.

Die große Anzahl an Teilnehmenden an dem Kongress verdeutlichte die Aktualität des Themas und den starken Bedarf an KI-gesteuerten Prozessen. Allerdings wurde auch aufgezeigt, wie viele Hürden und Herausforderungen noch bestehen. Die Wissenschaft muss gemeinsam mit Unternehmen und anderen Praxisanwender*innen diese Herausforderungen angehen und Wege erarbeiten, damit KI und Mensch zukünftig ergänzend zusammenarbeiten können. Das IDaS möchte dazu einen Beitrag leisten und mit den hier publizierten Erkenntnissen aus der Postersession einem breiteren Publikum die Möglichkeit geben, sich über aktuelle KI-Projekte zu informieren.

.



Utilizing Sensitivity Analysis in Data Generation for Machine Learning Training

Chrissula Bermperi, Andreas Heuermann, Bernhard Bachmann

This poster explores sensitivity analysis, a technique for assessing how uncertainties in a mathematical model's output relate to variations in its inputs. It focuses on sensitivity indices, particularly the total-order index, which quantifies each input parameter's impact on the model's output. The main objective is to identify and remove parameters with minimal influence, thereby simplifying the model. The study centers on the Adapted Rosenbrock function, a challenging optimization problem often used for algorithm testing. Multiple neural network training sessions were conducted on different datasets, each configured with varying input setups. Employing the SALib Python library, the study followed a modular approach to sensitivity analysis. Initial findings suggest the potential exclusion of insignificant parameters, but further investigation with extended training and larger datasets is necessary for conclusive insights.



Utilizing Sensitivity Analysis in Data Generation for Machine Learning Training

Chrissula Bermperi, Andreas Heuermann, Bernhard Bachmann

Introduction

Sensitivity analysis is the examination of how uncertainty in the output of a mathematical model or system can be attributed to various sources of uncertainty in its inputs. This examination often involves assigning a numeric value to the sensitivity of each input, known as the sensitivity index. The sensitivity indices are classified according to interactions with other inputs, with the total-order index being particularly significant due to its ability to provide a comprehensive view of model behavior. The importance lies not only in identifying the most sensitive inputs but also in emphasizing the parameters with the least sensitivity — so negligible that one may contemplate their potential removal from the model.

Research question

The overarching objective is to identify parameters with minimal or no impact on the model through sensitivity analyses and have them removed from the model, thereby reducing the number of parameters and decreasing complexity. In conclusion, consideration is given to whether the enhancement of neural network training can be achieved through the exclusion of less significant inputs from the dataset.

Adapted Rosenbrock function

$$f(x, y) = (a - x)^2 + b(y - x^2)^2$$

The Rosenbrock function is a mathematical function frequently employed for testing and evaluating optimization algorithms. It features a distinctive narrow, curved valley with a global minimum, making it a complex optimization challenge.

Sensitivity analysis according the method of Sobol:						
	For output x[1]		For output x[2]		For output x[3]	
	ST	ST_conf	ST	ST_conf	ST	ST_conf
y	0.9961	0.0579	0.9927	0.0674	0.8788	0.0638
v[1]	0.0014	0.0001	0.0048	0.0003	0.0043	0.0003
v[2]	0.0012	0.0001	0.0012	0.0001	0.1158	0.0111
v[3]	0.0011	0.0001	0.0011	0.0001	0.0010	0.0001

Table 1: Total-order sensitivity indices resulting from sensitivity analysis. Sensitivity analysis identifies y as the most influential input, while v[3] is the least significant. Concerning the variables, y is a state variable and v is a new included parameter to the function.

Methods

- Trained a neural network ten times on three different datasets for the adapted Rosenbrock function.
- Utilized an unchanged dataset, one without v[3], and a dataset containing only five data points of v[3].
- Compared loss functions and established a fixed value of $1e-5$ as a reference point.

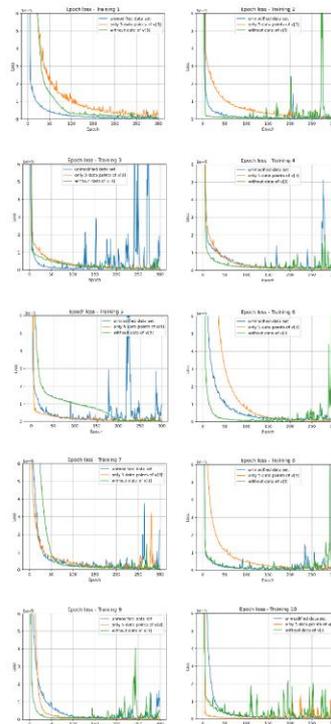


Figure 1: Epoch loss plots of ten training sessions. Five out of ten training sessions are faster when v[3] is excluded. The oscillations towards the end occur due to the increase in the weighting of the momentum (optimizer: Adam).

Material

SALib is an open-source Python library for sensitivity analyses. It follows a modular approach, managing input generation with sample functions and sensitivity index computation with analyze functions. A standard SALib sensitivity analysis comprises four steps:

- Identifying the model inputs and specifying their sample ranges.
- Executing the sample function to generate model inputs.
- Evaluating the model using the generated inputs, while saving the model outputs.
- Running the analyze function on the outputs to compute the sensitivity indices.

Results

- Integrated training of the neural network into a FMU for each session and dataset.
- Calculated relative errors with respect to the reference solution of each dataset according each output for each training session.
- Determined the average relative error for each training session.

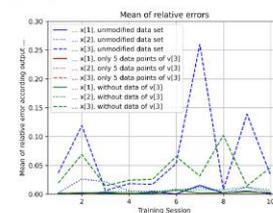


Figure 2: Average relative error of each output over ten training session. All means of relative errors are lower than 0.3. Greatest deviation for output x[3]. A clear statement regarding training velocity cannot be made

Conclusion

- Demonstration of adapted Rosenbrock function shows the possibility of excluding an insensitive parameter from the model.
 - Ten training sessions are insufficient to make a conclusive statement, especially given the stochastic nature of training neural networks.
- ⇒ Far more interesting with extended training and larger dataset.

Predicting the Extent of Co-Activation of One Muscle Head by sEMG-Measurements from the Other Muscle Head of the Biceps Brachii Using Linear Regression and Shallow Feedforward Neural Networks

Nils Grimmelsmann, Malte Mechtenberg, Axel Schneider,

Institute of System Dynamics and Mechatronics (ISyM), supported by the ministry of culture and science of the State of North Rhine-Westphalia as part of the research training group Dataniinja (Trustworthy AI for Seamless Problem Solving: Next Generation Intelligence Joins Robust Data Analysis)

Ziel

Vision: An intuitive control of exoskeletal devices which requires lag-free responses of its actuated joints. Surface electromyography (sEMG) allows for intuitive and lag-free control. By using a Hill-type model of the main muscles (here biceps brachii and triceps brachii) of a biological joint the internal delays of the muscle can be exploited to predict a joint angle with no time delay to the real joint angle

This poster introduces a method to train a virtual sEMG-sensor as a replacement for the real sEMG signal of a muscle head. The virtual sensor is trained based on data from the sensor of the other muscle head. For validation of the virtual sensor, the sensor is used as a replacement input in a domain-knowledge based model (Grimmelsmann et al., 2023).

By comparison of the virtual sensor signal and the measured sensor signal a sEMG assessment can be done

Methode

This work is based on a published dataset (Mechtenberg et al., 2023). sEMG signals of both biceps brachii and the two triceps brachii heads were recorded. sEMG signals contain frequency components from about 10 Hz to 400 Hz (Merletti, Farina, and Holobar, 2018). The target angle of the elbow (dumbbell curls) is at about 0.5 Hz. Therefore, the sEMG was not directly used as the target value of the virtual sensor regression. It is further converted into the activation of the muscle.

In the domain model, the activation of the muscle is calculated by a nonlinear low-pass filter that represents the activation dynamics of the muscle head (Zajac, 1989). The resulting signal thus has lower frequency components than the sEMG.

Ergebnisse

The regression on individual experiment varies between the recorded subjects. Small Extension in the Architecture Makes Interpretation Possible. The Virtual Sensor is Viable for Using it in a Biomechanical Model for Movement Prediction and the Virtual Sensor compared to Measured Signal can serve as sEMG Assessment.

Quellenangaben

Grimmelsmann, Nils, Malte Mechtenberg, Wolfram Schenck, Hanno Gerd Meyer, and Axel Schneider. 2023. "sEMG-Based Prediction of Human Forearm Movements Utilizing a Biomechanical Model Based on Individual Anatomical/ Physiological Measures and a Reduced Set of Optimization Parameters." Edited by Emiliano Cè. PLOS ONE. Public Library of Science (PLoS).

<https://doi.org/10.1371/journal.pone.0289549>.



Mechtenberg, Malte, Nils Grimmelsmann, Hanno Gerd Meyer, and Axel Schneider. 2023. "Surface Electromyographic Recordings of the Biceps and Triceps Brachii for Various Postures, Motion Velocities and Load Conditions." FH Bielefeld. <https://doi.org/10.57720/2290>.

Zajac, Felix E. 1989. "Muscle and tendon: properties, models, scaling, and application to biomechanics and motor control." *Critical reviews in biomedical engineering* 17, no. 4: 359-411.

Merletti, Roberto, Dario Farina, and Ales Holobar. 2018. "Surface Electromyography (sEMG)." Wiley Encyclopedia of Electrical and Electronics Engineering. Wiley.
<https://doi.org/10.1002/047134608x.w8371>.



Predicting the Extent of Co-Activation of One Muscle Head by sEMG-Measurements from the Other Muscle Head of the Biceps Brachii Using Linear Regression and Shallow Feedforward Neural Networks

Nils Grimmelsmann, Malte Mechtenberg, Axel Schneider

Motivation

- intuitive control of exoskeletal devices which requires lag-free responses of its actuated joints
- frequently used signal domain is surface electromyography (sEMG) allows for intuitive and lag-free control
- by using a Hill-type model of the main muscles (here biceps brachii and triceps brachii) of a biological joint the internal delays of the muscle can be exploited to predict a joint angle with no time delay to the real joint angle
- this poster introduces a method to train a virtual sEMG-sensor as a replacement for the real sEMG signal of a muscle head
- virtual sensor is trained based on data from the sensor of the other muscle head
- for validation of the virtual sensor, the sensor is used as a replacement input in a domain-knowledge based model (Grimmelsmann et al., 2023)
- by comparison of the virtual sensor signal and the measured sensor signal a sEMG assessment is possible

State-of-the-art models

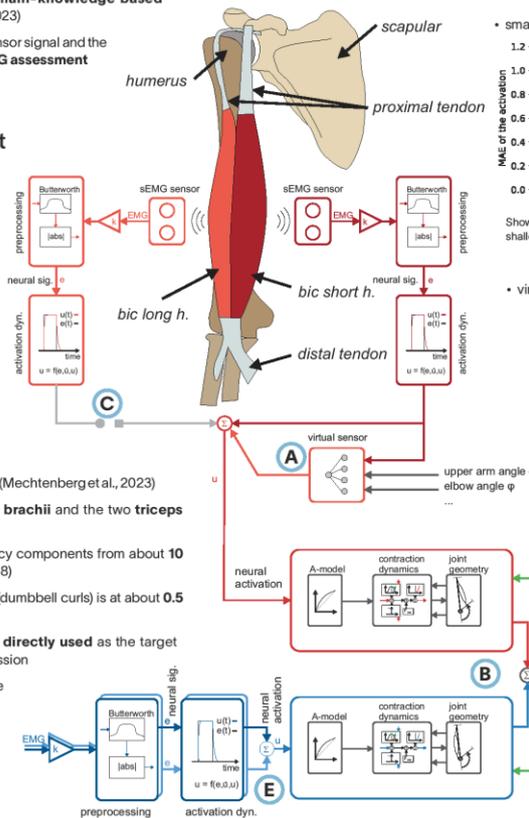
- biomechanical limb and joint models including Hill-type muscle sub-model or deep machine learning models
- both types depend on the measured sEMG signals of all relevant muscle and on their respective signal quality

Dataset used

- based on a published dataset (Machtenberg et al., 2023)
- sEMG signals of both biceps brachii and the two triceps brachii heads were recorded
- sEMG signals contain frequency components from about 10 Hz to 400 Hz (Merletti et al., 2018)
- the target angle of the elbow (dumbbell curls) is at about 0.5 Hz
- therefore, the sEMG was not directly used as the target value of the virtual sensor regression
- it is further converted into the activation of the muscle

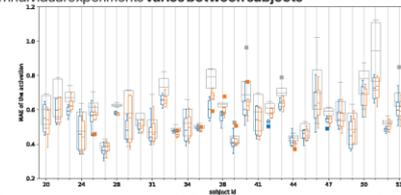
Activation as input feature

- in the domain model, the activation of the muscle is calculated by a nonlinear low-pass filter that represents the activation dynamics of the muscle head (Zajac, 1989)
- the resulting signal thus has lower frequency components than the sEMG



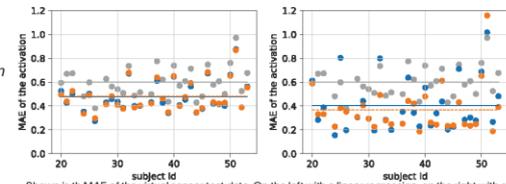
Results

- regression on individual experiments varies between subjects



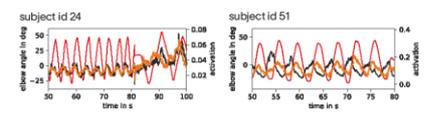
The box marks the interquartile range (IQR), and the whiskers represent data of 1.5-IQR. The MAE for the test set is shown. Blue = virtual sensor for the short head, Orange = virtual sensor for the long head. The corresponding data for the training is shown in grey.

- small extension in the architecture makes interpretation possible



Shown is the MAE of the virtual sensor test data. On the left with a linear regression, on the right with a shallow FFN. The different colors represent the train MAE (grey) and the test MAE for short to long head

- virtual sensor compared to measured signal can serve as sEMG assessment



The virtual sensor for the short head (orange) is shown. The angle of the elbow is plotted in red and the activation derived from the measured sEMG plotted in black. The measurements of the left is in phase (= high signal quality), the right measurement is out of phase.

Summary

- architectures for regression of two muscle heads, ranging from linear regression to shallow FFN with five inputs
- trained virtual sensors suitable as input for biomechanical models
- results fit the hypothesis that the two biceps heads are usually co-activated
- virtual sensors usable for sEMG assessment
- shallow structure of the FFN allows researchers to train similar models for their own data

biomechanical model
Grimmelsmann
et al., 2023

sEMG data set
Machtenberg
et al., 2023



Supported by:

Ministry of Culture and Science
of the State
North Rhine-Westphalia



hsbi.de

KI-gestütztes Monitoring zur Unterstützung in der häuslichen Pflege (KIMUP) – Ein Projekt aus dem Reallabor Geriatrie

Herzig, T., Marschner, C., Held, S., Jungeblut, T., Baudisch, J., Ostrau, C., Klemm, M., Uphaus, A., Amelung, R. & Nauerth, A.

Hochschule Bielefeld & Ambulante Geriatriische Rehabilitation Bielefeld GmbH & Co.KG

Ziel des von der Hochschule Bielefeld (HSBI) durchgeführten fächerübergreifenden und translationalen Forschungsvorhaben TransCareTech (01.11.2021 – 31.10.2024; Ministerium für Kultur und Wissenschaft des Landes Nordrhein-Westfalen) ist es, (A) die Teilhabe und Autonomie sowie das Wohlergehen von Klient*innen/Patient*innen zu steigern. Darüber hinaus sollen auch (B) die Fachlichkeit und Arbeitszufriedenheit bei den Beschäftigten im Gesundheitswesen gestärkt sowie (C) die Effizienz und Effektivität im Versorgungssektor erhöht werden. Erreicht werden soll dies durch die Entwicklung von Maßnahmen zur Verstetigung integrativer und technologisch innovativer Versorgungsformen in Bielefeld und der Region OWL.

Methodisch sind die Forschungsprojekte im Rahmen dieses gemeinsamen Vorhabens in Form unterschiedlicher regional angesiedelter »Reallabore« aufgebaut. Diese bieten als Erprobungs- und Experimentierräume einen Rahmen, in dem Wissenschaftler*innen sowie Praxisakteure partizipativ mit Nutzenden von Versorgungsleistungen an konkreten Lösungen für Versorgungsprobleme ansetzen [1, 2]. Gemeinsam werden bspw. die Entwicklung und Optimierung technischer Systeme sowie die Arbeits- und Organisationskontexte im Versorgungssystem adressiert. Forschung, Entwicklung und Transfer erfolgen in einem engen Verbund von Hochschule und Praxispartnern.

Mit dem »Reallabor Geriatrie« sollen zukünftig neue Versorgungs- und Stabilisierungsangebote sowie technische Hilfsmittel als auch Assistenzsysteme in der Häuslichkeit der Patient*innen entwickelt, erprobt und in ihrer Wirkung untersucht werden. Die Zielgruppe sind Menschen, die Einschränkungen der Kognition, des Hörens und Sehens bzw. der Kommunikationsfähigkeit, seelische Leiden, eine reduzierte Belastbarkeit durch Herz- und Lungenerkrankungen und/oder Immobilitäten aufweisen. Bei ihnen besteht auf der Individualebene häufig eine unzureichende Versorgungsstruktur im Bereich der geriatrischen Rehabilitation [3]. Auf der Kollektivebene hingegen liegt ein Problem darin, dass infolge der demografischen Entwicklung die doppelte Überalterung der Gesellschaft zunimmt [4].

Das Vorgehen orientiert sich gegenwärtig am Aufbau der Ambulanten Geriatriischen Rehabilitation Bielefeld GmbH & Co.KG (Praxispartner) als neue Versorgungsform am Standort Bielefeld als auch der Umsetzung einer interdisziplinären Forschungsprogrammatisierung an der HSBI.

Literatur

- [1] Beecroft, Richard & Parodi, Oliver. 2016. „Reallabore als Orte der Nachhaltigkeitsforschung und Transformation: Einführung in den Schwerpunkt.“ TATuP-Zeitschrift für Technikfolgenabschätzung in Theorie und Praxis 2, no. 3: 4-8
- [2] Rose, Michael, Wanner, Matthias & Hilger, Annaliesa. 2019. „Das Reallabor als Forschungsprozess und -infrastruktur für nachhaltige Entwicklung: Konzepte, Herausforderungen und Empfehlungen.“ (Wuppertal Paper, 196). Institut für Klima, Umwelt, Energie gGmbH. <https://nbn-resolving.org/urn:nbn:de:bsz:wup4-opus-74333>
- [3] Marschner, Christian, Herzig, Tim, Held, Stephan, Uphaus, Andreas, Rickermann, Jonas, Klemm, Michael & Nauerth, Annette. 2023. „Reallabor »Mobile Geriatriische Rehabilitationseinheit Bielefeld«, Versorgungsstrukturen entwickeln, umsetzen und erforschen.“ Poster anlässlich der Clusterkonferenz 2023 – Alternsmedizin NRW, 07. März 2023, Düsseldorf.
- [4] GKV Spitzenverband. 2021. „Gemeinsame Empfehlungen zur mobilen Rehabilitation“. <https://doi.org/10.1055/a-1675-5105>



KI-gestütztes Monitoring zur Unterstützung in der häuslichen Pflege (KIMUP)

Ein Projekt aus dem Reallabor Geriatrie

Das Reallabor Geriatrie

Ziel des gegenwärtig im Aufbau befindlichen Reallabors Geriatrie ist es, neue Versorgungsangebote zu entwickeln, diese in der Praxis zu erproben sowie wissenschaftlich zu begleiten. Die meist übergeordneten Fragen zur Wirksamkeit und dem allgemeinen Nutzen dieser Versorgungsangebote sollen hierdurch beantwortet werden. Die in diesem Zuge gegründete *Ambulante Geriatrie Rehabilitation Bielefeld GmbH & Co.KG* ermöglicht den notwendigen Praxiszugang für Forschung und Entwicklung.

Die Zielgruppe sind rehabilitierende, geriatrische Patient*innen, die Einschränkungen der Kognition, der Kommunikationsfähigkeit (Hören und Sehen), seelische Leiden, eine reduzierte Belastbarkeit durch Herz- und Lungenerkrankungen und/oder Immobilitäten aufweisen. Die Therapieziele sind dabei vielfältig und erstrecken sich bspw. über den Erhalt bzw. das Wiederherstellen der größtmöglichen Selbstständigkeit, die (technische) Assistenz im Wohnumfeld, die Unterstützung von Angehörigen, bis hin zu einer Förderung der Unabhängigkeit in Quartieren.



Die im Kontext von CareTech OWL der HSBI stattfindenden Forschungsaktivitäten sind trans- und interdisziplinär angelegt. Die beteiligten Disziplinen der Gesundheits-, Sozial-, Ingenieurs- und Wirtschaftswissenschaften arbeiten eng und in einem permanenten Austausch zusammen. Das im Folgenden dargestellte Forschungs- und Entwicklungsprojekt ist eines von mehreren konkreten Projekten im Rahmen des Reallabors Geriatrie.

KIMUP

Vier von fünf Pflegebedürftigen werden in Deutschland zuhause versorgt¹. Die Unterstützung durch Angehörige spielt dabei eine wichtige Rolle und ist zugleich mit zahlreichen Herausforderungen verbunden. Als vielversprechende Idee für gemeinwohlorientierte KI-Anwendungen steht das Projekt KIMUP: KI-gestütztes Monitoring zur Unterstützung in der häuslichen Pflege.

Ziel von KIMUP ist die Umsetzung eines app-basierten Systems zum Monitoring der Aktivität von Patient*innen in ihrer häuslichen Umgebung. Hierzu werden die Gewohnheiten der Patient*innen gelernt, um Abweichungen typischer Verhaltensmustern zu erkennen und im Bedarfsfall die Angehörigen zu benachrichtigen.

Die Vielzahl und Heterogenität von Smart-Home-Komponenten erfordern bisher die manuelle Auswertung und Interpretation der Informationen. Moderne KI-Verfahren bieten hingegen die Möglichkeit, gewohnte Verhaltensmuster automatisiert zu lernen und Abweichungen (Anomalien in den Aktivitätsmustern) zu erkennen². Transferlernen bietet einen Ausgangspunkt für ein neues Modell basierend auf bereits trainierten Modellen anderer Wohnungen³. Maschinelle Lernverfahren ermöglichen es mit schleichenden Veränderungen der Daten umzugehen bspw. durch neue Gewohnheiten oder aufgrund langsam fortschreitender degenerativer Erkrankungen.

Neben der Algorithmik sind weitere Herausforderung auch die Akzeptanz durch die Anwender*innen und der Umgang mit personenbezogene Daten. Föderales Lernen ermöglicht jedoch die lokale Modellbildung in der Häuslichkeit, ohne sensible personenbezogene Daten in die Cloud schicken zu müssen⁴.

Die mit KIMUP verbundene Vision ist es, dass geriatrische Patient*innen länger zuhause wohnen bleiben können und Angehörige bei ihrer pflegenden Tätigkeit entlastet werden, um mehr Zeit für die eigentlich notwendige Fürsorge und soziale Interaktion zu ermöglichen.

CIVIC Innovation Platform

KIMUP wurde Anfang 2023 beim Ideenwettbewerb der CIVIC Innovation Platform ausgezeichnet. Ziel der Förderung ist es vielversprechende Ideen für gemeinwohlorientierte KI-Anwendungen zu tragfähigen Konzepten weiterzuentwickeln.

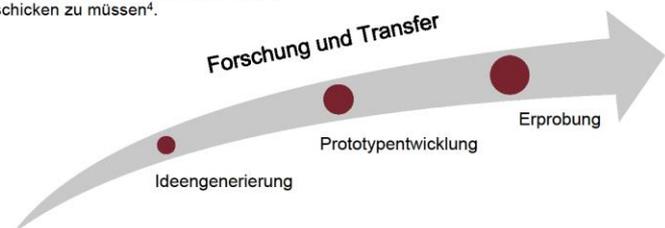
An der Hochschule Bielefeld verortet sich das Projekt im Reallabor Geriatrie. Projektpartner sind die *Ambulante Geriatrie Rehabilitation Bielefeld GmbH & Co.KG*, die *PVM GmbH* sowie der *KogniHome e.V.*

¹ Statistisches Bundesamt, Destatis (2023). Pflegebedürftige nach Versorgungsart

² Baudisch, J., Richter, B. & Jungeblut, T. (2022). A Framework for Learning Event Sequences and Explaining Detected Anomalies in a Smart Home Environment. *Künstl Intell* 36, 259–266 (2022). <https://doi.org/10.1007/s13218-022-00775-5>

³ Pinto, G. et al. (2022). Transfer learning for smart buildings: A critical review oalgorithms, applications, and future perspectives: <https://doi.org/10.1016/j.adapen.2022.100084>

⁴ Nguyen, Dinh C. et al. (2022). Federated learning for smart healthcare: A survey. *ACM Computing Surveys (CSUR)* 55.3 (2022): 1-37. <https://dl.acm.org/doi/abs/10.1145/3501296>



Bioinspired Feature Extraction for the Electric Field-based Determination of Object Size and Position

Kevin Hunke, Jacob Engelmann and Axel Schneider

1. Fish Sensory Systems

A few fish species can actively generate weak electric fields and use them to explore their environment. The ability to locate objects within about twice their body length is called active electrolocation (Von der Emde 1999). A well-studied fish species that uses active electrolocation is the weakly electric fish *Gnathonemus petersii*, Peter's elephant-nose fish. During active electrolocation, this fish generates a three-dimensional dipole-like electric field surrounding its body through specialized muscle cells located in its tail (Von der Emde 1999). The fish perceives the self-generated electric field with electroreceptors, called mormyromasts, which are distributed on the skin surface (Von der Emde 2006). The presence of a conductive object in the vicinity of the fish's self-generated electric field results in a two-dimensional image on the fish's electroreceptive skin. This image is also referred to as an electric image (Engelmann et al. 2008). Based on the concept of electric imagery, there is a correlation between object properties and perceived signal parameters.

2. Measurement Scenarios to Determine Size and Position

The analytical simulation model of the bio-template consists of an electrical dipole and a sensor line that represents the fish's electroreceptive skin. This model is utilized to identify various features from the voltage profile, which can be used to determine the object's size and position. The model distinguishes between static and dynamic localization features: one with a stationary and one with a moving sensor line.

2.1 Static Localization Features

The symmetrical shape of the voltage profile allows the evaluation of localization features such as amplitude, maximum slope, and full width at half maximum (FWHM). The object distance can be determined from the slope to amplitude ratio (Von der Emde 2006) or with the FWHM (Chen et al. 2005). However, if the slope and amplitude are considered separately, both object distance and object size can be derived (Hunke et al. 2022).

2.2 Dynamic Localization Features

The movement of the sensor line along an object, creates a voltage profile with a maximum (peak) that appears and disappears again (left position to right position). This results in an imaginary maximum trace (Peak Trace) with different widths for objects at different vertical distances from the sensor line. The peak trace (Hunke et al. 2021) is therefore a localization feature for object distance and position.

References

Chen, Ling, Jonathan L. House, Rüdiger Krahe, and Mark E. Nelson. 2005. "Modeling signal and background components of electrosensory scenes." *Journal of Comparative Physiology A* 191: 331-345. <https://doi.org/10.1007/s00359-004-0587-3>

Engelmann, Jacob, João Bacelo, Michael Metzen, Roland Pusch, Beatrice Bouton, Adriana Migliaro, Angel Caputi, Ruben Budelli, Kirsty Grant, and Gerhard Von Der Emde. 2008. "Electric imaging through active electrolocation: implication for the analysis of complex scenes." *Biological cybernetics* 98: 519-539. <https://doi.org/10.1007/s00422-008-0213-5>

Hunke, Kevin, Jacob Engelmann, Hanno Gerd Meyer, and Axel Schneider. 2021. "Motion parallax for object localization in electric fields." *Bioinspiration & Biomimetics* 17, no. 1: 016003. <https://doi.org/10.1088/1748-3190/ac3215>



Hunke, Kevin, Jacob Engelmann, and Axel Schneider. 2022. "Feature extraction from a static and a moving one-dimensional voltage sensor line for the electric field-based determination of object size and position in aqueous media." *IEEE Instrumentation & Measurement Magazine* 25, no. 9: 10-18. <https://doi.org/10.1109/MIM.2022.9955466>

Von der Emde, Gerhard. 1999. "Active electrolocation of objects in weakly electric fish." *Journal of experimental biology* 202, no. 10 (1999): 1205-1215. <https://doi.org/10.1242/jeb.202.10.1205>

Von der Emde, Gerhard. 2006. "Non-visual environmental imaging and object detection through active electrolocation in weakly electric fish." *Journal of Comparative Physiology A* 192: 601-612. <https://doi.org/10.1007/s00359-006-0096-7>

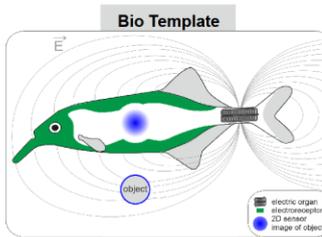


Bioinspired Feature Extraction for the Electric Field-based Determination of Object Size and Position

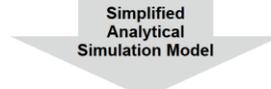
Kevin Hunke, Jacob Engelmann, Axel Schneider

Fish Sensory Systems

A few fish species can actively generate weak electric fields and use them to explore their environment. The ability to locate objects within about twice their body length is called **active electrolocation** [1]. A well-studied fish species that uses active electrolocation is the weakly electric fish *Gnathonemus petersii*, Peter's elephant-nose fish. During active electrolocation, this fish generates a **three-dimensional dipole-like electric field** surrounding its body through specialized muscle cells located in its tail [1].



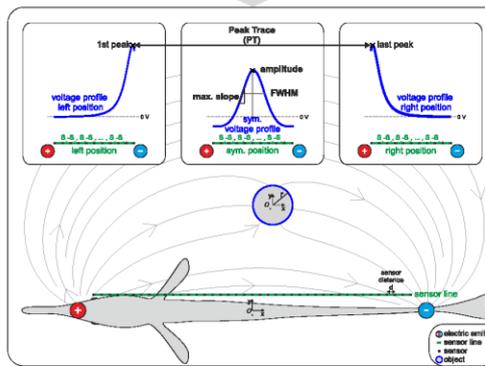
The fish perceives the self-generated electric field with **electroreceptors**, called mormyromasts, which are distributed on the skin surface [2]. The presence of a conductive object in the vicinity of the fish's self-generated electric field results in a **two-dimensional image** on the fish's electroreceptive skin. This image is also referred to as an electric image [3]. Based on the concept of electric imagery, there is a **correlation between object properties and perceived signal parameters**.



Static Localization Features

The symmetrical shape of the voltage profile allows the evaluation of localization features such as **amplitude**, **maximum slope**, and **full width at half maximum (FWHM)**. The object distance can be determined from the **slope to amplitude ratio** [2] or with the **FWHM** [4]. However, if the **slope and amplitude** are considered separately, both **object distance and object size** can be derived [6].

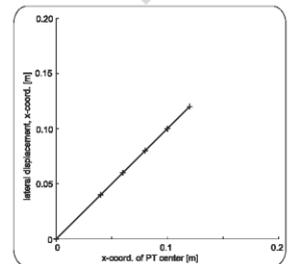
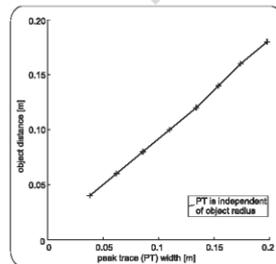
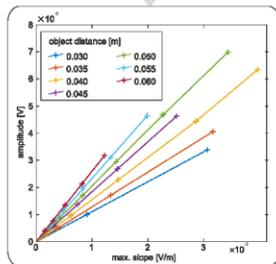
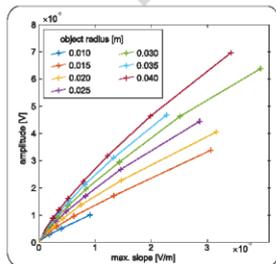
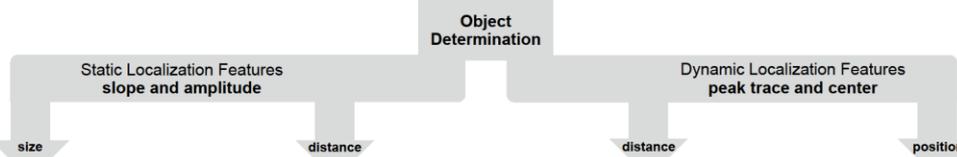
Hunke et al., 2022



Dynamic Localization Features

The movement of the sensor line along an object, creates a voltage profile with a **maximum (peak)** that appears and disappears again (left position to right position). This results in an **imaginary maximum trace (Peak Trace)** with different widths for objects at different vertical distances from the sensor line. The **peak trace** [5] is therefore a localization feature for **object distance and position**.

Hunke et al., 2021



[1] G. von der Emde, "Active electrolocation of objects in weakly electric fish," J. Experimental Biology, 1999
 [2] G. von der Emde, "Non-visual environmental imaging and object detection through active electrolocation in weakly electric fish," Journal of Comparative Physiology, 2009
 [3] J. Engelmann et al., "Electric imaging through active electrolocation: implications for the analysis of complex scenes," Biological Cybernetics, 2008

[4] L. Chen et al., "Modeling signal and background components of electroreceptive scenes," J. Comparative Physiology A, 2005
 [5] K. Hunke et al., "Motor parallel for object localization in electric fish," Bioinspiration & Biomimetics, 2021
 [6] K. Hunke et al., "Feature Extraction from a Static and a Moving One-Dimensional Voltage Sensor Line for the Electric Field-Based Determination of Object Size and Position in Aqueous Media," IEEE Instrumentation & Measurement Magazine, 2022

Active Learning for Regression with Ensemble Methods. Exploring the trade-off between quality and computational effort

Bjarne Jaster, Martin Kohlhase – Institut für Data Science Solutions (IDaS) Hochschule Bielefeld

Method

Active learning with ensembles is typically called *Query-by-Committee*, but because the variance of the predictions of the models is not used directly but computed into an uncertainty score, the compared active learning methods are categorized as *Uncertainty Sampling*. This work compares ensembles of three different base-models, namely Gaussian Processes (GPs), Decision Trees (ensemble is called Random Forest (RFs)) and Neural Networks (NNs). These models all show good predictive capabilities on small datasets, with RFs typically presenting the best results (Fernández-Delgado, Cernadas, Barro and Amorim 2014).

Different uncertainty estimators are used for all ensembles. The FB-GPs use either the variance of the predictions or the average size of the predicted confidence-interval or a combination of both as the active learning criterion. For the RFs the Jackknife and the Infinitesimal Jackknife estimator (Wager, Hastie and Efron 2014) are used to determine the uncertainty in a prediction. These provide an efficient computation of the Leave-One-Out-Error. Because the training of Neural Networks is computationally expensive, especially when an ensemble of a hundred different networks is trained. Therefore implicit ensembling-methods like Dropout (Srivastava, Srivastava, Krizhevsky and Salakhutdinov, 2014) and DropConnect (Wan et al., 2013) are used. These methods randomly deactivate parts of the network during training to avoid overfitting. When this is done during inference, several different predictions can be obtained. These can be used to obtain an uncertainty estimate.

Acknowledgement

The author acknowledges financial support by the project “SAIL: SustAinable Life-cycle of Intelligent Socio-Technical Systems” (Grant ID NW21-059B), which is funded by the program “Netzwerke 2021” of the Ministry of Culture and Science of the State of Northrhine Westphalia, Germany.

References

Fernández-Delgado, Manuel, Eva Cernadas, Senén Barro, and Dinani Amorim. 2014. “Do we Need Hundreds of Classifiers to Solve Real World Classification Problems?” *Journal of Machine Learning Research*, 15, 3133–3181. <https://www.jmlr.org/papers/volume15/delgado14a/delgado14a.pdf>

Srivastava, Nitish, Geoffrey Hinton, Alex Krizhevsky, and Ruslan Salakhutdinov. 2014. “Dropout: A Simple Way to Prevent Neural Networks from Overfitting.” *Journal of Machine Learning Research*, 15, 1929–1958. <https://www.jmlr.org/papers/volume15/srivastava14a/srivastava14a.pdf>

Wager, Stefan, Trevor Hastie, and Bradley Efron. 2014. “Confidence Intervals for Random Forests: The Jackknife and the Infinitesimal Jackknife.” *Journal Of Machine Learning Research*, 15: 1625-1651. <https://www.jmlr.org/papers/volume15/wager14a/wager14a.pdf>

Wan, Li, Matthew Zeiler, Sixin Zhang, Yann Lecun, and Rob Fergus. 2013. “Regularization of Neural Networks using DropConnect.” *International Conference on Machine Learning*, 1058–1066. <http://proceedings.mlr.press/v28/wan13.pdf>





Active Learning for Regression with Ensemble Methods

Exploring the trade-off between quality and computational effort

Bjarne Jaster – Institute for Data Science Solutions
 Hochschule Bielefeld, Schulstr. 10, 33330 Gütersloh
 bjarne.jaster@hsbi.de

Martin Kohlhasse – Institute for Data Science Solutions
 Hochschule Bielefeld, Interaktion 1, 33619 Bielefeld
 martin.kohlhasse@hsbi.de

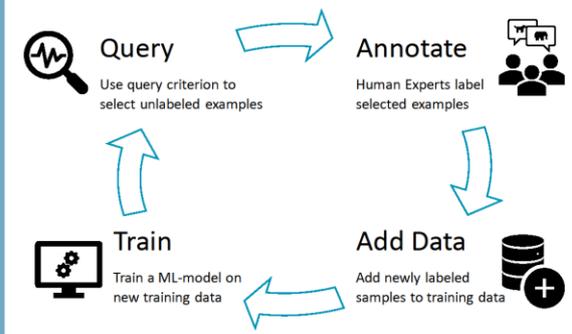
1. MOTIVATION

The interest in active learning grows especially in industrial applications due to the **large amounts of data** that are produced by factories, machines, etc. A common problem is that often **no labels are available** and therefore the data cannot be used for machine learning. Active learning addresses this problem as it provides methods that show which data samples are the best to **choose for labeling**. This also **reduces the cost** of labeling, which is expensive if human experts are used for labeling, as active learning tries to minimize the amount of labeled data. [1]

An effective way to deal with active learning is the use of **(Fully-Bayesian) Gaussian Processes** (ensembles of Gaussian Processes) and their uncertainty estimates. They provide very good results but have the disadvantage of high computational cost. [2] Therefore, this work explores the use of other methods (especially ensemble methods), and their uncertainty estimates for active learning. The comparison takes the **quality and computational cost** of different methods into consideration.

2. ACTIVE LEARNING

Active learning describes an efficient and effective way of **querying the most valuable data samples** for labeling, which is done by human experts. The value of a sample is defined by a criterion which is unique to each active learning strategy. The selection of the best datapoints reduces the amount of manual labeling, optimizes resource allocation, and enhances model performance in real-world scenarios. [1]



3. UNCERTAINTY ESTIMATION

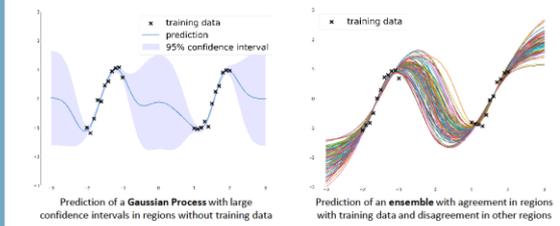
Uncertainty describes the **lack of confidence** a machine learning method has in its prediction. The uncertainty can be caused by:

- inherent randomness in the data, like noise, commonly named **aleatoric uncertainty**
- lack of knowledge that results from low amounts of data or poorly distributed data, commonly named **epistemic uncertainty**.

The uncertainty can be used to reject predictions with low accuracy and minimize errors this way. [3]

There are different types of uncertainty estimators. Two types used in this work are:

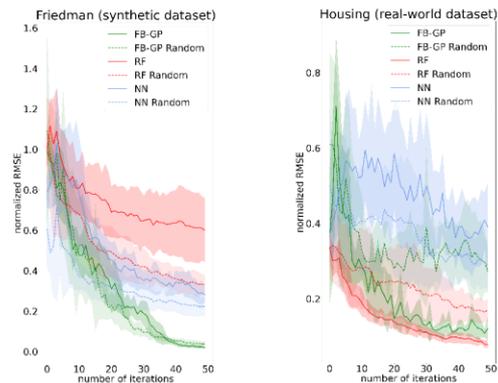
1. **Intrinsic uncertainty estimation:** Probabilistic machine learning methods provide mathematically well-founded confidence intervals that can be used as uncertainty estimates. The most common of those Machine Learning-methods are **Gaussian Processes (GPs)** and **Bayesian Neural Networks (BNNs)**.
2. **Ensembles:** Uncertainties for other machine learning methods can be estimated with an ensemble of similar but not identical models. If the ensemble heavily agrees on a prediction the uncertainty is small, while strong disagreement indicates high uncertainty. This technique is commonly applied to **Neural Networks (NNs)**.



[1] Thrun, A. & Schenck, W. Balancing Exploration and Exploitation: A novel active learner for imbalanced data. Knowledge-Based Systems. 10 pp. 106500 (2020,12)
 [2] Risi, C., Antunes, F., Boe, F., Carlos, H., Azevedo, L. & Pereira, F. Bayesian Active Learning with Fully Bayesian Gaussian Processes. Advances in Neural Information Processing Systems. pp. 12341-12353 (2022)
 [3] Hüllermeier, E. & Waegeman, W. Aleatoric and epistemic uncertainty in machine learning: an introduction to concepts and methods. Machine Learning. 110, 457-506 (2021,3)

4. RESULTS

This work compares the use of **Fully-Bayesian Gaussian Processes (FB-GPs)**, **Random Forests (RFs)** and **Neural Networks (NNs)** for uncertainty-based active learning. Additionally, a **passive baseline** for every ML-method is provided, where the training samples are drawn randomly (indicated by the dashed lines).



Exemplary results for a synthetic dataset. The score is averaged over 10 runs, and the standard deviation is shown by the shaded area

The two figures show results that are close to the overall results. To explore the quality of the methods **7 synthetic** [4] and **13 real-world datasets** are used. The **key observations**, which are also (mostly) visible in the figures are the following:

- For synthetic dataset, FB-GPs are the best active learning method, outperforming RFs and NNs on every dataset.
- On real-world datasets, RFs and FB-GPs perform similarly well, while NNs are by far the worst for every dataset.
- The random (passive learning) baseline for NNs outperforms active learning NNs on most datasets, indicating unsuitable uncertainty estimates for active learning.
- The same can be observed for RFs but only on synthetic datasets, indicating some weaknesses in the uncertainty estimates for RFs.

The **speed** of the different active learning methods averaged over 10 runs is shown in the following table:

FB-GP	RF	NN	FB-GP	RF	NN
1597 sec. (26.6 min)	9 sec.	202 sec. (3.4 min)	2851 sec. (47.5 min)	6 sec.	137 sec. (2.3 min)
synthetic datasets			real-world datasets		

One key observation when looking at the differences between real-world and synthetic datasets, is that the **computational time for FB-GPs is dominated by the number of dimensions of the data**, which is larger on real-world dataset. For NNs and RFs the **dominating factor is the number of unlabeled datapoints**, which is higher on the synthetic datasets. [5]

5. CONCLUSION & OUTLOOK

The following statements summarize the key observations of the comparison:

1. **FB-GPs are an overall good model-choice** for active learning if computational time is not important or expensive.
2. **Random Forests are most of the time preferable for real-world data**, because they are much faster and show a slight advantage over FB-GPs on passive learning, which makes them a generally better model choice for real-world data. [6]
3. **Neural Networks are not suitable** for active learning on small datasets or when only a few datapoints are queried. Their sensitivity to hyperparameters and general poor performance on smaller datasets make them a suboptimal choice.

Outlook and Future Research:

One key observation is the **difference of the results for the synthetic and real-world datasets**. Additionally, there are some datasets where all compared active learning methods fail to outperform their passive learning baseline. These observations arise the questions **which characteristics of a datasets are crucial for a good active learning performance** and what **improvements can be used to increase the active learning quality?**

[4] Surjanovic, S. & Bingham, D. Virtual Library of Simulation Experiments: Test Functions and Datasets. (Retrieved September 12, 2023, from <http://www.sfu.ca/ssurjano>)
 [5] Jaster, B. & Kohlhasse, M. Active Learning for Regression Problems with Ensemble Methods. Proceedings 33. Workshop Computational Intelligence. pp. 9-29 (2023, 10)
 [6] Fernandez-Delgado, M., Cernadas, E., Barro, S. & Amorim, D. Do we Need Hundreds of Classifiers to Solve Real World Classification Problems?. Journal Of Machine Learning Research. 15 pp. 3133-3181 (2014)



Comparative Study of a Parameter Tuned Bioinspired Binaural Sound Source Localization Algorithm and a Standard Beamformer

Philipp Jünemann, Malte Mechtenberg, Axel Schneider, Joachim Waßmuth Institute of System Dynamics and Mechatronics (ISyM)

Motivation

We want to present an optimized sound source localization method that is inspired by biology and uses fewer microphones than typical acoustic cameras. The parasitoid fly *Ormia ochracea* is known to be very good at localizing sound events despite its small body size and small distance between its tympanal membranes. This precise directional hearing is due to a mechanical coupling of its auditory canals that consists of masses, springs, and dampers (Miles et al.). This hearing system is well known but tuned to a specific sound source frequency and direction.

As a sound source localization system needs to localize sound sources of a broader frequency spectrum and range of directions. We presented a method to tune the model of *the Ormia ochracea*'s hearing system to multiple directions of incidence (Jünemann 2023a) and to a broader frequency spectrum (Jünemann 2023b).

Research question

How does the bioinspired binaural method based on *Ormia ochracea*'s hearing system compare to a standard beamformer?

Method

To compare the novel binaural bioinspired beamformer to a standard beamformer a simulation environment is set up where the sound source location and frequency can be controlled. Two bioinspired binaural beamformers configurations were compared to standard beamformers with 10 or 20 microphones.

Results

Up to the angle of incidence of 30° the novel bioinspired beamformer performed significantly better than the standard beamformer (10 and 20 microphones). This is a significant result and demonstrates the outstanding performance of the bioinspired binaural beamformer. For a detailed discussion of the results please refer to the conference paper (Jünemann 2023b).

Literature

Jünemann et al. 2023. "Direction-of-Arrival Estimation for Acoustic Signals Based on Direction-Dependent Parameter Tuning of a Bioinspired Binaural Coupling System." Bioinspiration & Biomimetics. IOP Publishing. <https://doi.org/10.1088/1748-3190/ace50a>.

Jünemann et al. 2023. "Comparative Study of a Bioinspired Sound Source Localization Algorithm and a Standard Beamformer." Engineering for a Changing World: Proceedings : 60th ISC Ilmenau Scientific Colloquium (December): 2023. <https://doi.org/10.22032/DBT.59141>.



Comparative Study of a Parameter Tuned Bioinspired Binaural Sound Source Localization Algorithm and a Standard Beamformer

Philipp Jünemann, Malte Mechtenberg, Axel Schneider, Joachim Waßmuth

Motivation

Current acoustic camera systems require multiple microphones for sufficiently accurate spatial resolution.

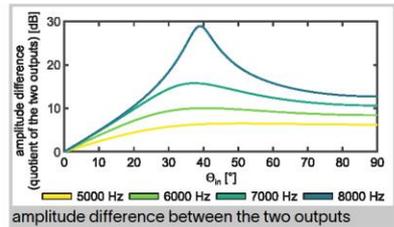
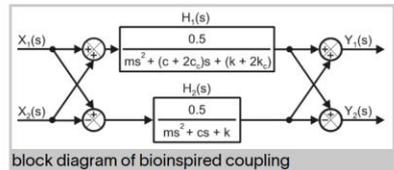
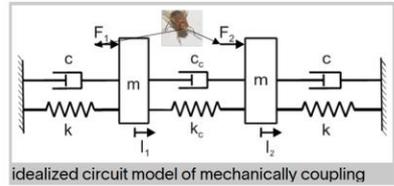
Spatial and temporal sampling of a sound field using microphone arrays and beamforming algorithms.

Optimal spatial resolution for localization of low-frequency sound sources requires large microphone distances.

Parasitoid fly *Ormia ochracea* represents a biological phenomenon in the localization of sound sources [1].

Despite its small body size, the fly uses interaural time and intensity difference (ITD and IID) to locate its cricket host.

The precise directional hearing is due to a mechanical coupling of its auditory canals.



Methodology

Using this bioinspired approach for a technical system with only two microphones.

Analytical description of the coupling system under spherical wave excitation.

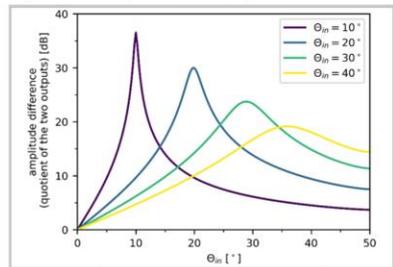
Parameter optimization for the most sensitive angle of incidence and a given frequency using ML-based methods.

Extension of parameter optimization for a broader frequency band with gradient descent using the trust-region-reflective algorithm.

Simulation results with the bioinspired binaural method

Localization of a simulated acoustic point source for all possible angles of incidence (0.25° to 90°).

The absolute error of the method between the simulated and the calculated angle is less than or equal to 1° in 90% of all simulations.

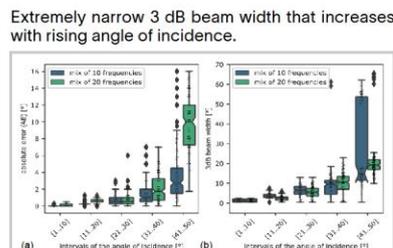


1000 simulated acoustic point sources and sound signals and with randomly chosen angles of incidence in 5 intervals.

Frequency interval from 200 Hz to 2000 Hz at a microphone distance d=0.06 m (from 2000 Hz to 4000 Hz at a microphone distance d=0.03 m).

3 dB beam width as a feature for localization accuracy.

Extremely narrow 3 dB beam width that increases with rising angle of incidence.

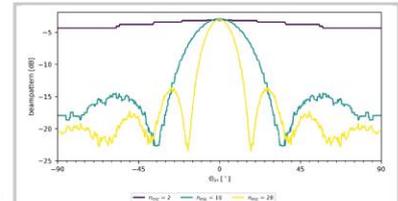


frequency range from 200 Hz to 2000 Hz and microphone distance d=0.06 m, (a) absolute error, (b) 3 dB beam width

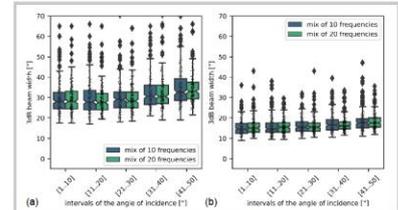
Comparison with a standard beamformer

Delay-&-sum beamformer with two microphones has very flat beampattern that does not reach 3 dB attenuation.

3 dB beam width with ten microphones is about 30° and with twenty about 16°.



beampattern of a standard beamformer with 2, 10 and 20 microphones



3 dB beam width of a standard beamformer with 10 (a) and 20 (b) microphones in a linear array

Conclusion

The 3 dB beam width of the 2-mic bioinspired SSL is even smaller than that of the 10-mic and 20-mic delay-&-sum beamformer.

Allows more compact and more resource-efficient microphone arrays.

Enables new application possibilities, e.g. on care beds for high-privacy speech dialog systems for interactive assistance functions.

Integration of AI models for the detection of acoustic events and speech recognition with small microphone arrays.

Literature

[1] R.N. Miles, D. Robert, and R.R. Hoy, Mechanically coupled ears for directional hearing in the parasitoid fly *Ormia ochracea*. The Journal of the Acoustical Society of America, vol. 98, no. 6, pp. 3059-70, 1995

Jünemann et al., 2023

Approximation einer modellprädiktiven Antriebsregelung durch ein neuronales Netz

Fabian Karau, Michael Leuer Hochschule Bielefeld – Campus Gütersloh Motion Control – Elektrische Antriebe und Steuerungstechnik

Die modellprädiktive Regelung (MPC von engl. Model Predictive Control) ist ein modernes Regelverfahren, das auf der wiederholten Lösung eines Optimierungsproblems basiert. Anhand eines mathematischen Modells der Regelstrecke kann der Verlauf der Regelgrößen in Abhängigkeit des aktuellen Streckenzustandes und der Stellgrößen prädiziert werden. Zudem wird ein Gütefunktional definiert, welches das Regelungsziel abbildet, wie zum Beispiel eine geringe Regelabweichung. Dann wird der optimale Stellgrößenverlauf im Sinne des definierten Gütefunktionals durch die Lösung des Optimierungsproblems berechnet. Zustands- und Stellgrößenbeschränkungen können dabei in Form von Nebenbedingungen berücksichtigt werden. Der Regelkreis wird geschlossen, indem von diesem optimalen Stellgrößenverlauf nur der erste Wert gestellt wird und in jedem Abtastschritt wiederholt die Erfassung aller Streckenzustände sowie die erneute Lösung des Optimierungsproblems erfolgt. Mit einer MPC ist eine deutlich bessere Regelperformance im Vergleich zu klassischen PID-Reglern erreichbar. Allerdings besteht ein hoher Rechenbedarf, bedingt durch die Lösung des Optimierungsproblems in jedem Abtastschritt. Gerade bei hochdynamischen Systemen, die kleine Abtastzeiten erfordern oder bei der Realisierung auf kostengünstiger Hardware mit beschränkter Rechenleistung stellt dies ein Problem dar.

Zur Reduzierung der benötigten Rechenleistung besteht der Ansatz darin, die MPC durch ein neuronales Netz zu approximieren. Während das rechenintensive Training offline erfolgt, sind mit dem trainierten neuronalen Netz nur noch Matrix-Vektor-Multiplikationen erforderlich, die ressourcensparend berechnet werden können. Es wird gezeigt, dass sich hierdurch die erforderliche Berechnungszeit drastisch reduziert. Bei der betrachteten Applikation führt die Anwendung der approximierten MPC zu einer durchschnittlichen Berechnungszeit von $1,2 \mu\text{s}$ gegenüber $1379 \mu\text{s}$ bei der originalen MPC. Dabei ist ein vergleichbares Regelverhalten inklusive der verlässlichen Ausregelung von Störungen festzustellen. Darüber hinaus ist das Regelverhalten der MPC bzw. ihrer Approximation dem Regelverhalten einer klassischen PI-Regelung überlegen. Die Algorithmen werden von einem Standard-Industrie-PC (IPC) ausgeführt. Dank der reduzierten Rechenleistung kann der IPC für weitere Steuerungsaufgaben eingesetzt werden.



Approximation einer modellprädiktiven Antriebsregelung durch ein neuronales Netz

Fabian Karau, Michael Leuer

Ansatz und Ergebnisse auf einen Blick

- Approximation einer rechenintensiven modellprädiktiven Antriebsregelung durch ein neuronales Netz
- Implementiert auf einem Industrie-PC (IPC) und verifiziert an einem realen System (Wippe)
- Reduktion der Rechenzeit um Faktor > 1000

Einleitung

- Performante Regelungen sind in vielen industriellen Prozessen unerlässlich
- Modellprädiktive Regelungen (MPC) ermöglichen überlegendes Regelverhalten gegenüber PID-Reglern
 - Grundlage bildet ein mathematisches Modell der Regelstrecke
 - Stellgröße durch Minimierung eines Gütefunktionals berechnet
 - Berücksichtigung von Beschränkungen und Nichtlinearitäten möglich
- Hohe Rechenleistung für MPC erforderlich
 - Lösung des Optimierungsproblems in jedem Abtastschritt
- Neuronales Netz (NN) zur Approximation der MPC (AMPC)
- Mit trainierten NN nur noch Matrix-Vektor-Multiplikationen erforderlich → ressourcensparende Berechnung

Modellprädiktive Regelung

- Mathematisches Modell der Regelstrecke um die Reaktion auf bestimmte Stellgrößen zu präzisieren

$$x(k+1) = f(x(k), u(k))$$

Zustand x

$$y(k) = g(x(k), u(k))$$

Eingang / Stellgröße u
Ausgang / Regelgröße y

- Bestimmung der optimalen Stellgröße durch Lösen des Optimierungsproblems mit Nebenbedingungen

$$J(y, u) = \sum_{i=1}^{n_p} (y_{\text{Soll}}(k+i) - y(k+i))^2 q + \Delta u(k+i-1)^2 r$$

Gütefunktional Gewichtungen Regelfehler & Stellaufwand
Quadratischer Regelfehler Stellgrößenänderung

$$\Delta u_{\text{opt}} = \arg \min_{\Delta u} J(y, u)$$

$$\text{u.B.v. } x_{\text{min}} \leq x(k+i) \leq x_{\text{max}}$$

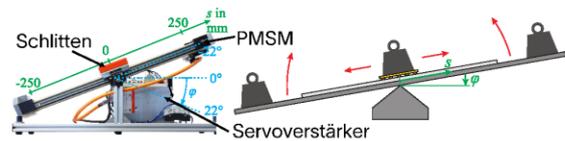
$$u_{\text{min}} \leq u(k+i) \leq u_{\text{max}}$$

Neuronales Netz zur Nachbildung der MPC

- Reales System mit entworfener MPC betreiben
 - Sollwerte, Zustände und Stellgrößen als Trainingsdaten sammeln
- Multi-Layer-Perceptron (MLP) trainieren
 - 17-dimensionaler Eingangsraum
 - 3 verdeckte Schichten mit je 10 Neuronen
 - 1 Neuron in der Ausgabeschicht
 - 411 Gewichte

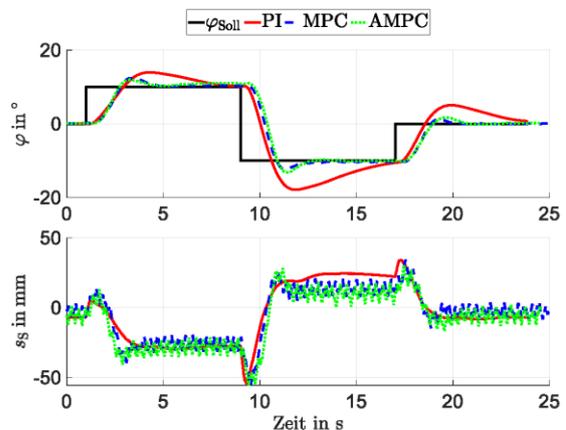
Verifizierung an der Regelstrecke "Wippe"

- Versuchsaufbau zur Demonstration von Regelungskonzepten
 - Linearachse ist drehbar gelagert
 - Durch Schlittengewicht wirkt ein Drehmoment auf die Wippe
 - Encoder zur Erfassung des Wippenwinkels
 - Regelungsziel ist das Anfahren bzw. das Halten eines Wippenwinkels
- Nichtlineares System mit arbeitspunktabhängigen Parametern



Ergebnisse

- Regelungsalgorithmen auf einem Industrie-PC des Typs C6930-0050 (Beckhoff Automation) implementiert
 - i7-4700EQ 2,4 GHz Prozessor, 1 Kern verwendet
 - Zweimal 4096 MB DDR3-RAM Arbeitsspeicher
- Regelverhalten der MPC ist dem Regelverhalten der PI-Regelung überlegen
- Verhalten der AMPC vergleichbar mit MPC



- Elastische Encoder-Aufhängung führt bei der MPC aufgrund der dynamischen Eigenschaften zu Schwingungen
 - Lösungsmöglichkeit: Berücksichtigung der Encoder-Aufhängung im Streckenmodell
- Neuronales Netz (AMPC) benötigt deutlich weniger Rechenzeit als die klassische MPC
 - Gemessen mit dem Funktionsbaustein Profiler
 - $\bar{T}_{\text{Calc.PI}} < 1 \mu\text{s}$
 - $\bar{T}_{\text{Calc.MPC}} = 1379 \mu\text{s}$
 - $\bar{T}_{\text{Calc.AMPC}} = 1,2 \mu\text{s}$
 - Reduktion der Rechenzeit um Faktor > 1000
- Zielplattform (hier IPC) wird kaum belastet und kann weitere Steuerungsaufgaben übernehmen



Machine Learning Methoden für geringe Datenmengen – Grundlage für datenbasierte industrielle Auslegungen

Justus Kösters; Center for Applied Data Science Gütersloh der Hochschule Bielefeld, Forschungsmaster Data Science HSBI;

Ziel

Im Rahmen des Forschungsvorhabens gilt es, Methoden des maschinellen Lernens zu identifizieren, die auch bei geringen Datenmengen eine hohe Modellperformance bieten. In einem weiteren Schritt können mit diesen Methoden Unternehmen bei der Nutzung ihres vorhandenen Datenpotentials unterstützt werden.

Forschungsfrage

Welche Methoden des maschinellen Lernens sind für die datenbasierte Approximation von Zusammenhängen in geringen Datenmengen geeignet?

Wie können diese Datenmengen mithilfe der identifizierten Methoden gezielt angereichert werden?

Ergebnisse

Aus einem Benchmarking in einer vorherigen Untersuchung (Kösters, Schöne, und Kohlhase 2023) geht hervor, dass Entscheidungsbäume mit dem GUIDE-Algorithmus für die Approximation von geringen Datenmengen geeignet sind. Der GUIDE-Algorithmus (Loh 2002) ist eine Methode zur Erzeugung von Entscheidungsbäumen für die Klassifikation und Regression, welche eine unverzerrte Merkmalsauswahl auf Basis einer Interaktionsdetektion durchführt und numerische und kategorische Eingangsmerkmale simultan nutzen kann. Aufgrund der interpretierbaren Baumstrukturen wird die Akzeptanz zur Nutzung bei den Anwendern gestärkt (Ribeiro, Singh, und Guestrin 2016). Eine Anreicherung der geringen Datenbasis kann, wie in (Kösters und Schöne 2023) gezeigt, mit dem Ansatz des Active Learnings durchgeführt werden. Ein informationsbasierter Ansatz zeigt dabei vielversprechende Ergebnisse.

Quellenangaben

Kösters, Justus, Marvin Schöne, und Martin Kohlhase. 2023. „Benchmarking of Machine Learning Models for Tabular Scarce Data“. 3729. Gütersloh: Center for Applied Data Science, Bielefeld University of Applied Sciences. <https://www.hsbi.de/publikationsserver/record/3729>.

Loh, Wei-Yin. 2002. „Regression trees with unbiased variable selection and interaction detection“. *Statistica sinica*, 361–86. <http://www.jstor.org/stable/24306967>.

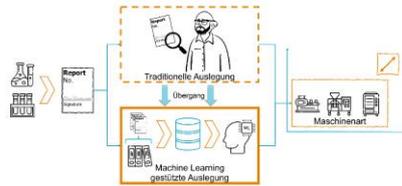
Ribeiro, Marco Tulio, Sameer Singh, und Carlos Guestrin. 2016. „Why Should I Trust You?': Explaining the Predictions of Any Classifier“. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 1135–44. San Francisco California USA: ACM. <https://doi.org/10.1145/2939672.2939778>.

Kösters, Justus, und Marvin Schöne. 2023. „Active Learning mit dem GUIDE-Entscheidungsbaum“. 3731. Gütersloh: Center for Applied Data Science, Bielefeld University of Applied Sciences. <https://www.hsbi.de/publikationsserver/record/3731>.

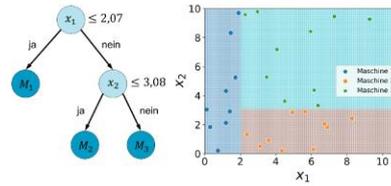


Machine Learning Methoden für geringe Datenmengen

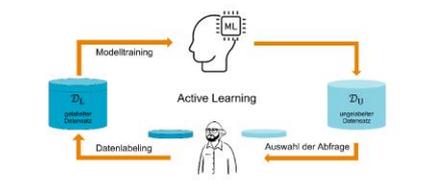
Grundlage für datenbasierte industrielle Auslegungen



Traditionelle, auf Domänenexpertise basierende, Auslegung gegenüber der ML-gestützten Auslegung auf Basis von vorhandenen Labordaten.



Ein Entscheidungsbaum mit Entscheidungsgrenzen basierend auf dem dargestellten Klassifikationsdatensatz.



Die Methode des pool-based Active Learnings. Das Modell entscheidet selber, mit welchen Daten es trainiert werden möchte, und lässt diese durch Experten labeln.

1 Motivation

Für die Auslegung von Maschinen in der Industrie werden häufig Laboruntersuchungen und Maschinentests abgehalten. Auf Basis der daraus resultierenden Ergebnisse entscheiden Domänenexperten über eine optimale Maschinenart sowie die benötigte Dimensionierung für beispielsweise den angeforderten Durchsatz. Machine Learning Modelle können dabei helfen, diese Domänenexpertise zu konservieren und die Auslegungs- sowie Vertriebsprozesse zu vereinfachen [1]. Dabei gilt es die in den Unternehmen bereits vorhandene, häufig spärliche Datenbasis aus alten Versuchsberichten zu extrahieren und den Auslegungsprozess mit geeigneten Machine Learning Modellen abzubilden [2, 3].

2 Fragestellung des Forschungsvorhabens

Im Rahmen des Forschungsvorhabens gilt es die Herausforderungen und Potential von spärlichen Daten für die Auslegung und Adaption von industriellen Prozessen aufzudecken. Um diese Fragestellung zu beantworten, werden Machine Learning Modelle identifiziert, die auch bei geringen Datenmengen eine hohe Performance aufweisen. Des Weiteren werden Anforderungen an Modellperformance, Interpretierbarkeit und Vorhersagesicherheit untersucht, welche erfüllt sein

müssen, damit eine datengetriebene Auslegung in der Industrie konveniert. Schlussendlich werden Methoden identifiziert, mit denen ein zuverlässiges Verhalten des Modells sichergestellt wird und Schwachstellen ausbessert werden können.

3 Methode: Entscheidungsbäume mit Active Learning

Entscheidungsbäume sind für die Klassifikation und Regression geeignet und stellen die Prädiktionen für den Nutzer interpretierbar dar. Sie partitionieren den Eingangsdatenraum rekursiv entsprechend der jeweiligen Trainingsdaten und erstellen so ihre Vorhersagen. Im Rahmen eines Benchmarkings konnten Entscheidungsbäume auf Basis des GUIDE-Algorithmus [4] als für geringe Datenmengen sinnvoll erkannt werden. Dies liegt an der Performance und der intrinsischen Interpretierbarkeit. Eine Methode, die ebenfalls für den Umgang mit geringen Datenmengen und die Anwendung von Entscheidungsbäumen geeignet ist, ist das Active Learning [5]. Der Grundgedanke beim Active Learning ist, dass der Active Lerner selber die Datenpunkte auswählt, mit denen er trainiert wird. Die Basis für die Auswahl kann der Informationsgehalt auf Basis von Entscheidungsbaumvorhersagen sein. Abgebildet ist das Active Learning mit der pool-based Abfragestrategie, bei der ein

Active Lerner aus einem Pool von ungelabelten Datenpunkten einen Punkt, der gelabelt werden soll, auswählt und das Modell daraufhin mit der aktualisierten gelabelten Datenbasis trainiert. Das Labeling der abzufragenden Datenpunkte wird durch das Orakel, welches beispielsweise ein Domänenexperte ist, durchgeführt.

4 Ausblick

Im weiteren Verlauf des Forschungsvorhabens gilt es dieses Vorgehen auf realen im Forschungsprojekt AHSCaDa angefallenen Daten zu testen und zu validieren. Untersucht werden dabei ein sinnvolles Vorgehen beim Nachtrainieren der Entscheidungsbäume im Hinblick auf Stabilität sowie die Prädiktionsicherheit und das Verhalten von Datenanreicherung im Bereich von Entscheidungsgrenzen.

Quellen

- [1] K. Guo et al., "Artificial intelligence and machine learning in design of mechanical materials," *Materials Horizons*, vol. 8, pp. 1153-1172, 2021.
 [2] P. Larrageta et al., "Industrial Applications of Machine Learning," *Data Mining and Knowledge Series*. Boca Raton, Florida: CRC Press, 2019.
 [3] A. Adeli, "A survey on data-efficient algorithms in big data era," *Journal of Big Data*, vol. 8, 2021.
 [4] W. Loh, "Regression Trees with Unbiased Variable Selection and Interaction Detection," *Statistica sinica*, vol. 12, pp. 361-386, 2002.
 [5] B. Settles, "From theories to queries: Active learning in practice," *Active learning and experimental design workshop in conjunction with AISTATS 2010: JMLR Workshop and Conference Proceedings*, 2011.

Hochschule Bielefeld
Interaktion 1, 33619 Bielefeld



Fachbereich IuM
Justus Kösters
justus.koesters@hsbi.de



hsbi.de

Erklärbarkeit vertrauenswürdiger KI-Sprachmodelle für den transparenten Gebrauch bei Sicherheitsbehörden

Falk Maoro, Michaela Geierhos Universität der Bundeswehr München

VIKING - Projektbeschreibung

Im Teilprojekt zur Erklärbarkeit vertrauenswürdiger KI-Sprachmodelle widmet sich das Forschungsinstitut CODE der Universität der Bundeswehr München der KI-basierten Textauswertung. Ziel ist die damit einhergehende Herstellung von Fairness und Transparenz.

Klassifikationsszenarien

In der polizeilichen Textauswertung kann KI eingesetzt werden, um große Textkorpora mit hoher Geschwindigkeit nach verdächtigen Inhalten zu durchsuchen.

Eine in dieser Forschung entwickelte Methode ist die semantische Modellierung, bei der drei Klassifikationsaufgaben kombiniert werden, um Tathergänge oder Personenbeschreibungen aus Texten zu extrahieren, in ein strukturiertes Datenmodell zu überführen und es Anwendern über eine Webanwendung zu ermöglichen, die Ergebnisse interaktiv zu erkunden. Dazu werden Texte zunächst dahingehend klassifiziert, welche Delikttypen in den Texten vorkommen. In der nächsten Stufe wird die Named Entity Recognition eingesetzt, bei der alle Wörter des Texts klassifiziert werden, um z. B. Ortsangaben oder Personenreferenzen zu markieren. Zwischen Entitäten können Beziehungen bestehen, die von einem dritten Klassifikationsmodell erkannt werden. Eine Beziehung zwischen einer Ortsangabe und einer Personenreferenz gibt beispielsweise an, an welchem Ort sich die jeweilige Person aufgehalten hat. Die Aggregation mit Metadaten erlaubt zusätzlich eine Präzisierung von beispielsweise Orts- und Zeitangaben oder die Verbindung zu weiteren Ermittlungsergebnissen.

Fairness und Erklärbarkeit von KI

Obwohl die Klassifikationsergebnisse von Sprachmodellen sehr präzise sein können, ist in der Regel nicht nachvollziehbar, auf Basis welcher Merkmale Modellentscheidungen getroffen werden. Da Fehlentscheidungen im polizeilichen Kontext unter Umständen schwerwiegende Folgen haben können, müssen eingesetzte KI-Verfahren verschiedenen Anforderungen im Hinblick auf Performance, Fairness und Nachvollziehbarkeit genügen. Die Erforschung von Methoden zur Herstellung von Fairness gegenüber z. B. der Herkunft, dem Alter oder der Bildung einer Person sowie Methoden zur Erklärung von KI-Modellen und KI-Entscheidungen in polizeilichen Szenarien zur Textklassifikation stellen den Mittelpunkt der Forschungsarbeit dar.



Falk Maoro, M. Sc.
Forschungsinstitut CODE
E-Mail: falk.maoro@unibw.de

Prof. Dr. Michaela Geierhos
Forschungsinstitut CODE
E-Mail: michaela.geierhos@unibw.de

Vertrauenswürdige Künstliche Intelligenz für polizeiliche Anwendungen

Wie kann **Künstliche Intelligenz** in der **Polizeiarbeit** unterstützend eingesetzt werden und dabei sowohl **fair** als auch **nachvollziehbar** sein?

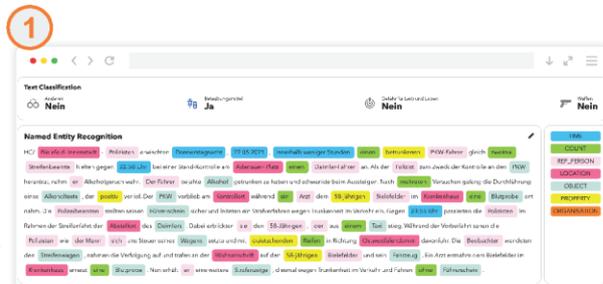


Projektbeschreibung

Polizeibehörden untersuchen in Ermittlungen Millionen Texte aus z. B. Chats, sozialen Medien, Foren und Nachrichten. Die Auswertung dieser Datenmenge ist längst nicht mehr manuell möglich. Daher werden KI-Verfahren zur Textauswertung entwickelt, die Ermittler:innen Unterstützung beim Finden und Analysieren von relevanten Textinhalten bieten. Um hohen ethischen und rechtlichen Anforderungen zu genügen, werden Methoden zur Erkennung und Minimierung von Bias sowie zur Erklärung von KI-Verfahren und KI-Entscheidungen eingesetzt.

Semantische Modellierung von Polizeiberichten

Die Semantische Modellierung kombiniert KI-Modelle zur Textauswertung, sodass **Inhalte extrahiert**, als **strukturierte Daten** gespeichert und intuitiv **visualisiert** werden können. Ermittler:innen untersuchen Texte in drei Schritten:

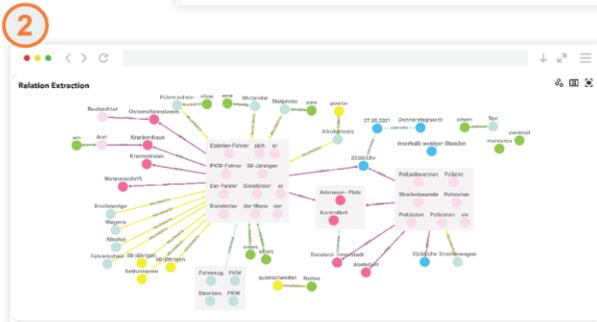


Textklassifikation

Ein Sprachmodell klassifiziert, welche **Straftaten** und **Deliktstypen** im Text enthalten sind. So können Textsammlungen nach groben Phänomenbereichen durchsucht werden.

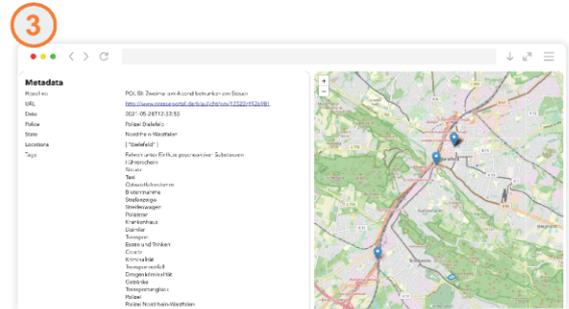
Named Entity Recognition

Alle Wörter eines Texts werden klassifiziert, um Ortsangaben, Personenreferenzen, Zeitangaben oder Objekte (sog. **Entitäten**) zu markieren.



Relation Extraction

Zwischen Entitäten bestehen Beziehungen, die durch ein Modell erkannt werden können. So können **Personenprofile** erstellt und Fragen wie „Wer war wann wo?“ beantwortet werden.



Aggregation mit Metadaten

Die Metadaten der Website *presseportal.de*, wie z. B. das Datum und Städtenamen, werden mit der Textauswertung kombiniert. Die im Text gefundenen **Orte** können dann mit **Geodaten** angereichert und auf einer Karte angezeigt werden. Zudem lassen sich **Tatzeitpunkte** genau berechnen.

KI-Fairness

Entscheidungen von KI-Modellen dürfen nicht auf Grundlage von sensiblen Attributen getroffen werden. Es werden **Debiasing-Methoden** verwendet, die Benachteiligungen von z. B. **Geschlechtern**, **Nationalitäten** oder **Altersgruppen** erkennen und verhindern.



Vertrauenswürdigkeit

Sollen z. B. Sexualstraffäter in Online-Chats durch KI erkannt werden, so würden **fehlerhafte Entscheidungen** verheerende Folgen haben. Um den Entscheidungen eines Modells vertrauen zu können, muss beantwortet werden, wie das **Modell funktioniert**, mit welchen **Daten** es trainiert wurde und **wieso** eine **Entscheidung** getroffen wurde.

Negative Stimmung Neutrale Stimmung Positive Stimmung

Modell-Ausgabe Worteinfluss

negativ (0.99) Gib mir das **Geld zurück** oder du **wirst es bereuen**

positiv (0.85) Gib mir die **Süßigkeiten** oder du **wirst es bereuen**



Improvement of sEMG Exoskeleton Control Based on Prediction of the Myotendinous System State

Malte Mechtenberg, Nils Grimmelsmann, Axel Schneider

1. Introduction

Current force-controlled exoskeletons react to the user's movements with an unpleasant delay. The muscle activity measured by surface electromyography (sEMG) can be used to create a control scheme with significantly lower delay. And better knowledge of the current state of the human subsystem helps to improve the underlying musculoskeletal models. We have published new methods, which will improve the movement prediction for exoskeleton control.

2. Methods

The low frequency sEMG components relate to the level of muscle activity. The sEMG shape (higher freq. comp.) depends on the muscle geometry. So, it should be possible to deduce muscle geometry properties from the sEMG. We have therefore presented a new method for estimating the innervation zone (IZ) from sEMGs (Mechtenberg and Schneider 2023). And we evaluated it in a new sEMG simulator (Mechtenberg, et al. 2024).

We also presented a new method to measure the properties of the lower biceps brachii tendon in vivo (Mechtenberg, et al. 2022), using ultrasound videos under varying load conditions and elbow angles.

3. Results

The IZ estimation performed well ($AE < 1\%$ of the sEMG IED). The tendon model fitted relatively well to the collected in vivo data. It was considered preferable for small tendon forces ($< 20\%$ maximum voluntary contraction, MVC) compared to linear models in the literature. Above 20% MVC there was no significant difference to these linear models.

References

Mechtenberg, Malte, Nils Grimmelsmann, Hanno Gerd Meyer, and Axel Schneider. 2022. "Manual and Semi-Automatic Determination of Elbow Angle-Independent Parameters for a Model of the Biceps Brachii Distal Tendon Based on Ultrasonic Imaging." PLOS ONE. PLoS. <https://doi.org/10.1371/journal.pone.0275128>.

Mechtenberg, Malte, and Axel Schneider. 2023. "A method for the estimation of a motor unit innervation zone center position evaluated with a computational sEMG model." Frontiers in Neurobot. 17. <https://doi.org/10.3389/fnbot.2023.1179224>.

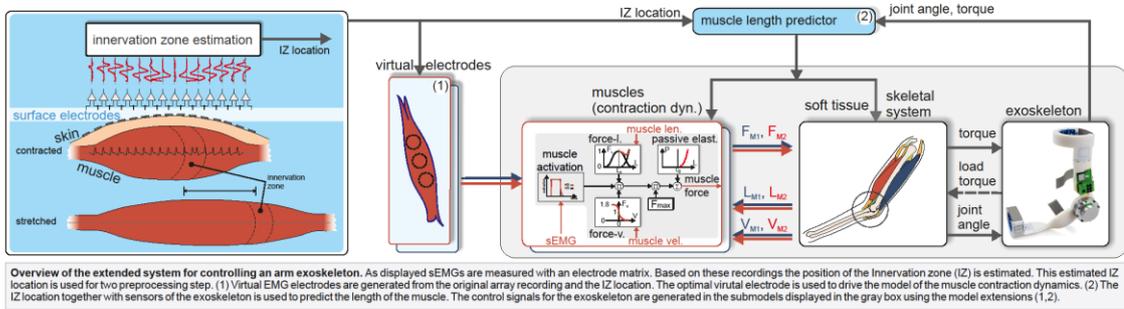
Mechtenberg, Malte, Nils Grimmelsmann, and Axel Schneider. 2024. "A New Algorithm for Innervation Zone Estimation Using Surface Electromyography: A Simulation Study Based on a Simulator for Continuous sEMGs." Proc. 17th Intl. Joint Conf. on Biomed. Engr. Systems and Technologies. SCITEPRESS - Volume 1, pages 629-636. <https://doi.org/10.5220/0012375100003657>



Improvement of sEMG Exoskeleton Control Based on Prediction of the Myotendinous System State

Malte Mechtenberg, Nils Grimmelsmann, Axel Schneider

There are active exoskeletons that are controlled by force sensors and support the wearer's complex movements. Such exoskeletons react to the user's movements with a noticeable and unpleasant delay. The muscle activity measured by surface electromyography (sEMG) can be used create a control scheme with significantly lower delay. Furthermore, better knowledge of the current state of the biological system helps to improve the underlying muscle models. Therefore, we have developed new methods to enhance accuracy of the model state.

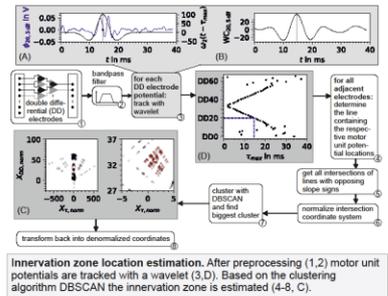


Observing the location of the innervation zone of a muscle with an sEMG array

The innervation zone (IZ) is a region of the muscle where the neurons from the peripheral nervous system connect to the muscle. This region is at a fixed location relative to the two muscle tendon junctions.

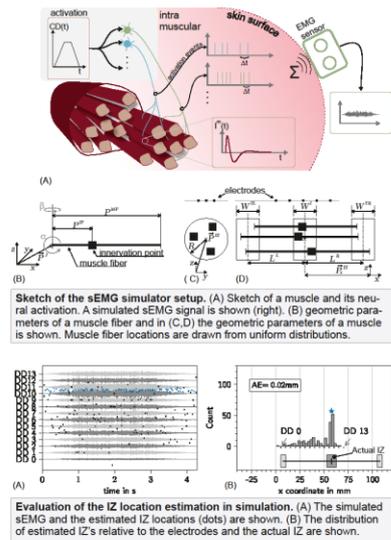
The innervation zone moves with the muscle contraction. The IZ also disturbs the sEMG recording. Knowledge about the location of the innervation zone can increase the quality of the sEMG by generating an optimal sEMG recording from an array while avoiding the innervation zone.

A muscle length predictor will use the innervation zone estimate and the state of the exoskeleton. The estimated muscle length will be used to correct the state of the Hill based muscle model.



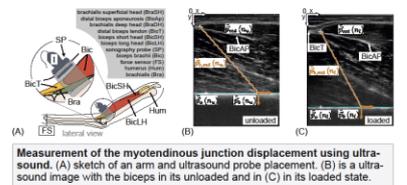
A sEMG simulator was used to evaluate the innervation zone estimation

The sEMG simulator is capable to simulate sEMG signals of a complete muscle, consisting of hundreds of motor units.

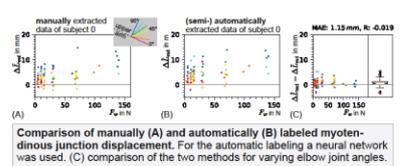


Using an artificial neural network to measure the tendon movement in u-sound videos

Tendons are soft tissue (mostly collagen). The compliant nature protects the muscle structure and acts as energy storage. They transmit the muscle force to the skeletal system. Therefore, they are of great interest for the movement prediction models used in exoskeleton control.



In vivo data of the tendon's behavior is important for the model of the skeletal system. We proposed a method to gather in vivo data of the biceps brachii distal tendon utilizing a convolutional neural network.



Validierung einer Prescriptive-Analytics-Plattform für Produktionsanlagen.-VIP4PAPS-

Marvin Niederhaus, Mortimer Dockhorn, Nico Migenda, Martin Kohlhase, Wolfram Schenck

Center for Applied Data Science, Hochschule Bielefeld

Kooperationspartner: Fraunhofer Institute for Mechatronic Systems Design, Paderborn

Die Anforderungen an produzierende Unternehmen nach einer schnellen Bereitstellung von individuellen Produkten sind in Zeiten von Globalisierung und Automatisierung hoch. Unternehmen jeglicher Größe müssen unter hohem Druck effizient und wirtschaftlich arbeiten und schnell auf veränderte Bedarfe reagieren. Verfahren der Prescriptiven Analytics und der künstlichen Intelligenz ermöglichen eine ganzheitliche Modellierung flexibler Produktionsabläufe zur Fehleranalyse, Optimierung und Effizienzsteigerung moderner Fertigungsprozesse.

Das Ziel des Forschungsvorhabens ist die Entwicklung und Validierung einer Prescriptiven Analytics Plattform. Diese Plattform soll anhand von Produktionsdaten zukünftig auftretende Fehler voraussagen und entsprechende Handlungsempfehlungen geben. Diese Handlungsempfehlungen berücksichtigen die gewählte Strategie des Anwenders, um beispielsweise eine optimal ausgelastete Maschinenbelegung zu gewährleisten.

Die Plattform beinhaltet dabei eine Datenanbindung an eine Produktionsumgebung, eine Datenbank zur Datenspeicherung, die Prescriptive Komponente zur Generierung von Handlungsempfehlungen und die grafische Benutzeroberfläche. Aufgebaut wird die Plattform modular, durch die Nutzung einer Microservice-Architektur. Jede Komponente wird in einem separaten Docker-Container ausgeführt und durch eine standardisierte API miteinander verbunden.

Der Einsatz kombinierter Methoden ermöglicht im Fall eines Sensorfehlers die Nutzung von synthetischen Messdaten, anstelle von realen Daten. Sobald eine Abweichung der realen Sensordaten vom internen Simulationsmodell festgestellt wird, werden die synthetisch generierten Daten anstelle der fehlerhaften Sensordaten verwendet. Gleichzeitig wird sowohl eine Fehlermeldung als auch eine Handlungsempfehlung für den Nutzer generiert.

In der Literaturrecherche wurden bestehende Prescriptive Plattformen untersucht und die dazugehörigen Papers in drei Kategorien eingeteilt. Die Kategorie „Prescription“ enthält alle Papers, die für die Entwicklung der Plattform relevante Prescriptive Aspekte beinhalten. „Konzeptuelle Frameworks & Architekturen“ enthalten alle theoretischen Plattformkonzepte, die nicht umgesetzt wurden und „Validierte Plattformen“ enthalten die umgesetzten, implementierten Plattformen.

Zukünftig ist es möglich, dass Large Language Models (LLMs) eine wichtige Komponente von Prescriptiven Analytics Plattformen werden. LLMs haben den Vorteil, dass Handlungsempfehlungen in natürlicher Sprache generiert werden können und Feedback des Nutzers hinsichtlich der Relevanz der Handlungsempfehlung effizient integriert werden kann.





Validierung einer Prescriptive-Analytics-Plattform

für Produktionsanlagen -VIP4PAPS-

Plattform, Fehlertolerante Systeme, Recommender

Marvin Niederhaus*, Mortimer Dockhorn, Nico Migenda, Martin Kohlase, Wolfram Schenck

Center for Applied Data Science, Hochschule Bielefeld, Schulstraße 10, 33330 Gütersloh
*marvin.niederhaus@hsbi.de



Zielsetzung:

- Entwicklung und Validierung einer Plattform welche anhand von Produktionsdaten zukünftig auftretende Fehler voraussagt und entsprechende Handlungsempfehlungen generiert (**Prescription**)

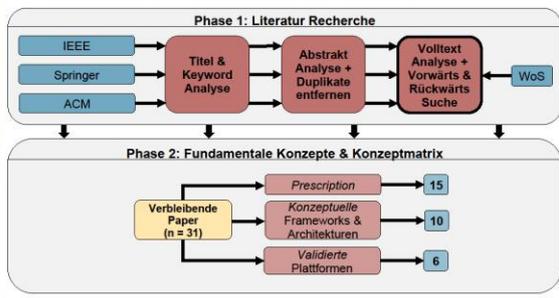
Motivation:

- Produzierende Unternehmen sind interessiert an der Anwendung von neuen KI-Technologien
- Aktuell sind keine Prescriptive Plattformen für die Industrie verfügbar
- Ausreichende Datenmengen werden in modernen Produktionsanlagen bereits erzeugt (**Industrie 4.0**)

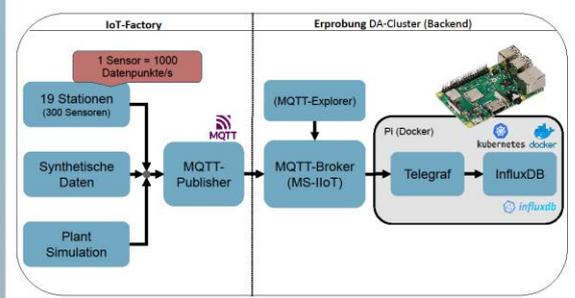
Ergebnis:

- An einer realen Produktionsanlage validierter Recommender, der mithilfe von Sprachmodellen Handlungsempfehlungen generiert

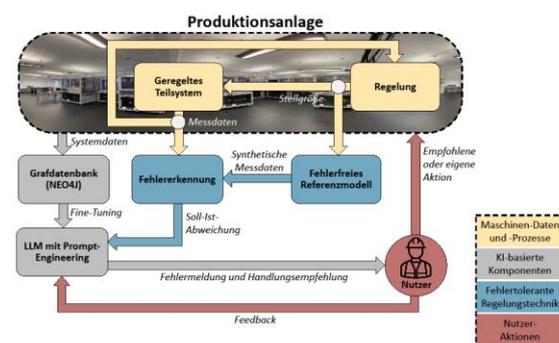
1. STRUKTURIERTE LITERATURRECHERCHE



2. PLATTFORMKONZEPT



3. EINSATZ KOMBINIERTER METHODEN



4. HANDLUNGSEMPFEHLUNG



AI for Scarce Data (AI4ScaDa) – Maschinelles Lernen und Informationsfusion zur nachhaltigen Nutzung von Labor- und Kundendaten

Marvin Schöne, Julian Bülteemeier; Center for Applied Data Science Gütersloh der Hochschule Bielefeld, Institut für industrielle Informationstechnik der Technischen Hochschule Ostwestfalen-Lippe;

Kooperationspartner: GEA Westfalia Separator Group GmbH, Miele & Cie KG, SAATEN-UNION BIOTEC GmbH

1. Ziel

Das Ziel vom Projekt AI4ScaDa ist es, spärliche Daten für KI-Modelle zu nutzen, um Verfahren, Produkte und Prozesse zu optimieren. Das Projekt betrachtet drei Use-Cases mit spärlichen Daten aus Labor- und Kundenberichten, in denen die Optimierung industrieller und biologischer Prozesse verfolgt wird.

2. Forschungsfrage

Wie lassen sich spärliche Daten anreichern und algorithmisch approximieren?

Wie kann das Verhalten und die Güte des KI-Modells überprüft und effizient adaptiert werden?

3. Methode

Für die Anreicherung spärlicher Daten werden verschiedene Informationsfusions-, Vorverarbeitungs- und Transformationsmethoden angewendet. Spärliche Daten können zudem durch Versuchspläne systematisch erweitert werden. Da oft keine Modellannahme für Versuche möglich ist, werden in AI4ScaDa modellfreie Algorithmen für raumfüllende Versuchspläne betrachtet. Für die Approximation der Daten werden einfache interpretierbarer KI-Modelle sowie aktive Lernmethoden verwendet.

4. Ergebnisse

Während der Einarbeitung in die Use-Cases entstand ein Anforderungskatalog für Methoden und Algorithmen sowie Templates zur Datenerfassung. Aufgrund dieser Anforderungen werden im Projekt Versuchsplanungsmethoden benötigt, die numerische und kategorische Eingangsgrößen berücksichtigen. Dafür wurde ein *Simulated Annealing* Algorithmus (Ba, Brenneman, & Myers, 2014) implementiert und der *Extended Deterministic Local Search* Algorithmus (Ebert, et al., 2015) erweitert. Zudem wurde eine skalierbare Verlustfunktion entwickelt, um den Einfluss der Eingangsgrößen auf die Versuchsplanung effektiver zu berücksichtigen. Als Lernalgorithmus wurde der Entscheidungsbaum-Algorithmus *Generalized, Unbiased, Interaction Detection and Estimation* (Loh, 2002) ausgewählt und auf augmentierten Daten trainiert. Dabei wurde eine neue aktive Lernmethode speziell für Entscheidungsbäume entwickelt.

5. Literaturverzeichnis

Ba, Shan, William A. Brenneman, und William R. Myers. „Optimal Sliced Latin Hypercube Designs.“ *Technometrics*, 2014: 1537-2723.

Ebert, Tobias, Torsten Fischer, Julian Belz, Tim Oliver Heinz, Geritt Kampmann, und Oliver Nelles. „Extended Deterministic Local Search Algorithm for Maximin Latin Hypercube Designs.“ In 2015 IEEE Symposium Series on Computational Intelligence, 375-382. Cape Town, South Africa, 2015.

Loh, W.-Y. „Regression trees with unbiased variable selection and interaction detection.“ *Statistica Sinica* 12 (2002): 361-386.





AI for Scarce Data (AI4ScaDa)

Maschinelles Lernen und Informationsfusion zur nachhaltigen Nutzung von Labor- und Kundendaten



Marvin Schöne - Center for Applied Data Science Gütersloh (CfADS)
Hochschule Bielefeld, Schulstraße 10, 33330 Gütersloh
marvin.schoene@hsbi.de

Julian Bülteemeier - Institut für industrielle Informationstechnik (inT)
Technische Hochschule Ostwestfalen-Lippe, Campusallee 6, 32657 Lemgo
julian.buelteemeier@th-owl.de

1) MOTIVATION UND ZIELSETZUNG

Das it's OWL Innovationsprojekt AI4ScaDa widmet sich der Erforschung spezieller KI-Methoden, die im Kontext von Scarce Data gewinnbringend eingesetzt werden können. Scarce Data wird häufig unter kontrollierten Bedingungen in z. B. Laboren erhoben und zeichnet sich im Gegensatz zu Big Data durch eine geringe Quantität aber hohe Qualität aus (siehe Abb. 1). Die zentrale Herausforderung besteht darin, dass KI-Methoden stark von der Quantität und Qualität der verfügbaren Daten abhängen. Wenn nur sehr wenige Daten zur Verfügung stehen, können die Methoden oft nicht mit menschlicher Expertise mithalten [1].

AI4ScaDa zielt darauf ab,

- einen KI-Workflow zur Verarbeitung, Modellierung und Anreicherung spärlicher Daten zu entwickeln,
- den KI-Workflow an drei unterschiedlichen realen Anwendungsfällen zu erproben und zu generalisieren,
- Unternehmen aus OWL (speziell die beteiligten Praxispartner) die Nutzung von Scarce Data zu ermöglichen.

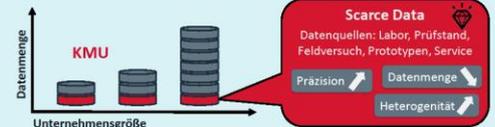


Abb. 1: Unternehmen verfügen unabhängig ihrer Größe über spärliche Daten (Scarce Data), die z. B. im Labor, bei Feldversuchen oder an Prüfständen in Form von Richen oder A. durch Experten erhoben werden. Spärliche Daten zeichnen sich durch eine hohe Präzision, hohe Heterogenität und geringe Menge aus.

2) METHODISCHES VORGEHEN

Solution im Fokus: Die spärlichen Daten (Scarce Data) werden um zusätzliche Datenquellen angereichert und mithilfe von Methoden der Informationsfusion zu einem aussagekräftigen, konsistenten Datensatz aggregiert. Dabei werden den Domänenexpert*innen bereits erste Informationen über die verfügbare Datenbasis bereitgestellt und Merkmale zum Training einer interpretierbaren KI erzeugt. Die interpretierbare KI macht neues Prozesswissen verfügbar und ermöglicht die Durchführung spezifischer Laborversuche (Designanpassung) zur gezielten Anreicherung der spärlichen Daten um wichtige Informationen. Dadurch wird eine Modellgüte erzielt, die eine modellbasierte Optimierung der Verfahren, Produkte und Prozesse der Praxispartner ermöglicht.

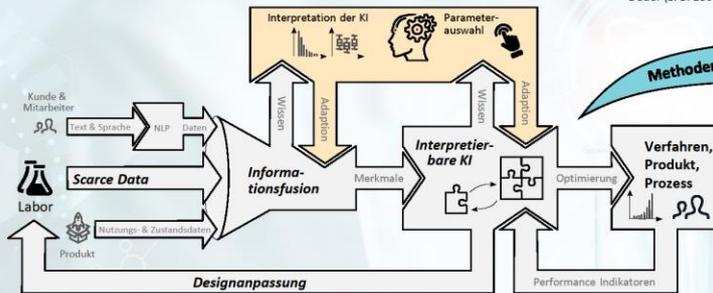
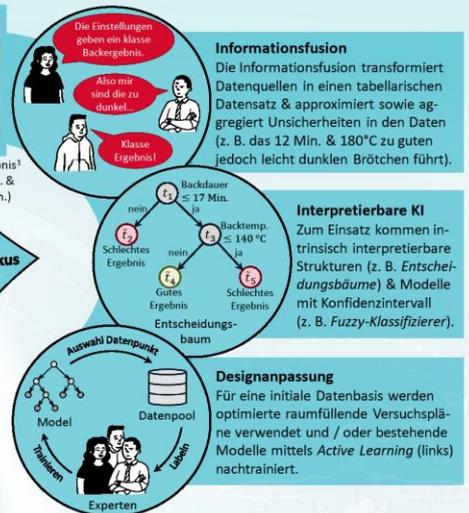


Abb. 2: KI-Workflow zur Verarbeitung und Anreicherung spärlicher Daten, der im Rahmen des Projekts realisiert wird.



Bsp.: Bewertung Backergebnis¹ in Abhängigkeit der Temp. & Dauer (z. B. 180°C, 12 Min.)



3) ANWENDUNGSFÄLLE



KI-getriebene Steuerung und Optimierung der Pflanzenaufzucht bei SU BIOTEC

Die Saaten-Union Biotech GmbH (SU BIOTEC) unterstützt die Entwicklung neuer Sorten für die landwirtschaftliche Praxis mit biotechnologischen Methoden im Gewächshaus und Labor. Die präzise Abstimmung von prozesssteuernden Maßnahmen, wie z.B. das Lichtspektrum oder Temperaturanpassungen in verschiedenen Entwicklungsstadien haben einen entscheidenden Einfluss auf den Erfolg der Produktion [2].

Ziel im Projekt: Optimierung der Anzucht, Steuerung der Anzucht durch frühzeitige Adaption, Generierung von neuem Prozesswissen.



KI-getriebene Produktauslegung von Zentrifugen bei GEA

Die GEA Westfalia Separator Group GmbH ist eine der weltweit größten Anbieter von Systemen zur mechanischen Klärung und Trennung von Flüssigkeiten in Industrien. Bei der Produktauslegung ihrer Zentrifugen müssen viele Laboruntersuchungen durchgeführt werden, die zum einen ein ausgeprägtes Expertenwissen und zum anderen viel Zeit erfordern [3].

Ziel im Projekt: Frühzeitige Spezifikation der Zentrifugen, Unterstützung bei der Auslegung/Adaption der Zentrifugen, Bewahren von Expertenwissen.



KI-getriebene Fehlerdiagnose in Haushaltsgeräten bei Miele

Die Miele & Cie. KG hat sich durch die Kombination von hochwertigen Haushaltsgeräten mit innovativer Smart-Home-Technologie erfolgreich im Smart-Home-Bereich etabliert. Zur Erhöhung der Effizienz von Trocknern müssen Informationen aus Feld- und Labortests fusioniert und verarbeitet werden.

Ziel im Projekt: Fehlererkennung mit KI, Arbeiten auf Zeitreihen aus den Feld- und Labortests, Adaption der Labortests.

4) ERSTE ERGEBNISSE UND NÄCHSTE SCHRITTE

Bei der Identifikation und Abgrenzung der Anwendungsfälle wurden verfügbare Datenquellen gesichtet und hinsichtlich ihrer Qualität zum Einsatz von KI bewertet. Basierend auf diesen Ergebnissen ist ein Anforderungskatalog entstanden, mit dem geeignete KI-Methoden (Informationsfusion, Interpretierbare KI, Designanpassung) vorausgewählt wurden und aktuell in Programmbausteine überführt werden. Für die Auswahl der interpretierbaren KI wurde ein Benchmarking [4] durchgeführt und zur Designanpassung wurden neue Active Learning Methoden [5] untersucht. Die ausgewählten Methoden werden derzeit bei GEA erprobt, wo mithilfe augmentierter Daten, die in einem raumfüllenden Versuchsplan generiert wurden, das Prozesswissen der Laboringenieur*innen erfragt und in einem Entscheidungsbaum abgebildet wird. Durch Informationsfusionen werden Unsicherheiten in den Aussagen der Laboringenieur*innen transparent und reduziert. Weil ein Großteil der verfügbaren Datenquellen Zeitreihen sind, werden zeitliche Methoden zur Transformation und Modellierung von Zeitreihen am Beispiel von Trocknerdaten bei Miele untersucht [6, 7].

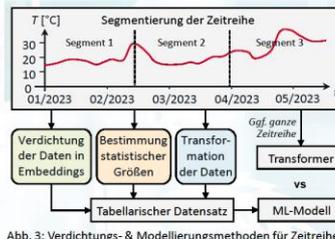


Abb. 3: Verdichtungs- & Modellierungsmethoden für Zeitreihen

Referenzen

- [1] C.-A. Holst, und V. Lohweg, Scarce Data in Intelligent Technical Systems: Causes, Characteristics, and Implications. SoS 2022, 4-48. <https://doi.org/10.33044/soS2022.4.48>
- [2] J. Böhmmeier, und M. Schöne, KI in der Pflanzenaufzucht: Mit wenig Daten zum Erfolg. 2023, <https://doi.org/10.33044/ai4sca-da-ki-in-der-pflanzenaufzucht/>, (abgerufen am 15.11.2023)
- [3] M. Schöne, und J. Böhmmeier, AI4ScaDa: KI sichert Wissen und findet das richtige Produkt. 2023, <https://doi.org/10.33044/ai4sca-da-ki-in-der-pflanzenaufzucht/>, (abgerufen am 15.11.2023)
- [4] J. Kösters, M. Schöne, und M. Kohlhase, Benchmarking of Machine Learning Models for Tabular Scarce Data. Diskussionspapier, 2023.
- [5] J. Kösters, und M. Schöne, Active Learning mit dem GUEE-Entscheidungsbaum. Diskussionspapier, 2023.
- [6] V. Kattner, Untersuchung rekurrenter Machine Learning Algorithmen für die Approximation sequentieller Daten. Forschungsprotokoll, 2023
- [7] R. Stanišauski, Untersuchung der Anwendbarkeit klassischer maschineller Lernalgorithmen auf Sensorreihen-Zeitreihen. Forschungsprotokoll, 2023

Projektpartner:



Ein Beitrag zu:

