


# Schlussbericht



**ITS.ML**

## **Intelligente Technische Systeme der nächsten Generation durch Maschinelles Lernen**

Forschungsvorhaben zur automatisierten Analyse von Daten  
mittels Maschinellen Lernens

### **Projektleitung:**

Prof. Dr. Barbara Hammer, AG Maschinelles Lernen  
Forschungsinstitut für Kognition und Robotik, Universität Bielefeld, D-33594 Bielefeld

### **Vertreter des Konsortiums:**

Prof. Dr. Eyke Hüllermeier, Universität Paderborn  
Prof. Dr.-Ing. Volker Lohweg, Technische Hochschule Ostwestfalen-Lippe  
Prof. Dr. Axel Schneider, Prof. Dr.-Ing. Wolfram Schenck, Fachhochschule Bielefeld

Weitere Autoren: Dr. Ulrike Kuhl, Universität Bielefeld; Marco Braun, Universität Bielefeld; Anton Pfeifer, Technische Hochschule Ostwestfalen-Lippe; Christoph-Alexander Holst, Technische Hochschule Ostwestfalen-Lippe; Malte Schmidt, Technische Hochschule Ostwestfalen-Lippe; Dr. Gunnar Schomaker, Universität Paderborn; Tanja Tornede, Universität Paderborn

Das diesem Bericht zugrunde liegende Vorhaben wurde mit Mitteln des Bundesministeriums für Bildung und Forschung unter dem Förderkennzeichen 01IS18041 gefördert. Die Verantwortung für den Inhalt dieser Veröffentlichung liegt bei den Autoren.

GEFÖRDERT VOM



Bundesministerium  
für Bildung  
und Forschung

## Impressum

*Schlussbericht ITS.ML:*

*Intelligente Technische Systeme der nächsten Generation durch Maschinelles Lernen*

*Forschungsvorhaben zur automatisierten Analyse von Daten mittels Maschinellen Lernens*

Barbara Hammer, Eyke Hüllermeier, Volker Lohweg, Axel Schneider, Wolfram Schenck, Ulrike Kuhl, Marco Braun, Anton Pfeifer, Christoph-Alexander Holst, Malte Schmidt, Gunnar Schomaker und Tanja Tornede

*Konzept und Entwicklung im Rahmen des BMBF-Verbundprojektes "ITS.ML"*

Förderkennzeichen 01IS18041, Laufzeit 08/2018 bis 01/2022

Verbundpartner: Universität Bielefeld, Universität Paderborn, Technische Hochschule Ostwestfalen-Lippe, Fachhochschule Bielefeld

*Herausgeber*

Forschungsinstitut für Kognition und Robotik (CoR-Lab)

Universität Bielefeld

D-33594 Bielefeld

E-Mail: [info@its-ml.de](mailto:info@its-ml.de)

DOI: <http://doi.org/10.4119/unibi/2965622>

August 2022



Diese Arbeit ist unter folgender Creative Commons-Lizenz lizenziert:

<https://creativecommons.org/licenses/by-nc/4.0/>

GEFÖRDERT VOM



Bundesministerium  
für Bildung  
und Forschung



DLR Projektträger

# 1 Kurze Darstellung

**Aufgabenstellung.** Ziel des Forschungsvorhabens war es, maschinelles Lernen (ML) für Intelligente Technische Systeme (ITS) entlang der gesamten Wertschöpfungskette nachhaltig verfügbar zu machen und ML als Service insbesondere für kleine und mittlere Unternehmen (KMU) zu etablieren. Dieses erforderte Entwicklung und Transfer neuester ML-Innovationen auf die in ITS zentralen Handlungsfelder, um ML-Technologien in die Produkte und in die Produktionsketten zu bringen. Umgekehrt gelang die Schärfung des Bewusstseins regionaler Unternehmen, wann und wie ML in agile Geschäftsmodelle und Produktionsketten integriert werden kann. Der Term ITS bezieht sich dabei auf Technologien, die auf intelligente Verfahren im Kern aufbauen und in spezifischer Hardware oder physikalischen Umgebungen eine spezifische Funktion realisieren. Beispiele sind intelligente optische Systeme, Qualitätsüberwachungskomponenten in der Industrie 4.0 oder Komponenten in der Medizintechnik. ITS bilden eine Kernkomponente, die für industrielle Erfolge etwa in der Automatisierung oder Qualitätskontrolle relevant ist – allerdings steht der effiziente Einsatz des maschinellen Lernens hier oft vor Herausforderungen: es sind teils nur beschränkte Datenmengen verfügbar, Daten in der Praxis unterliegen starken Variationen und Drift, und Hardwarebeschränkungen oder Restriktionen durch die physikalischen Gegebenheiten sind einzubeziehen. Zudem ist die Evaluation im praktischen Betrieb eine große Herausforderung, da oft nicht effizient und umfassend in realen Bedingungen getestet werden kann.

Im Projekt **ITS.ML** wurde die Strategie verfolgt, Methoden, Materialien und Informationen zu erarbeiten und bereitzustellen. Diese unterstützen Unternehmen auf ihrem Weg beim Einsatz von ML im Kontext von ITS und befähigen sie, Methodiken sicher und gewinnbringend auch ohne eigene Forschungsexpertise oder dedizierte Forschungsabteilung zu bewerten und anzuwenden. Dieses geschah auf drei Ebenen:

1. **Innovationen im Bereich ML:** Es wurden in fünf relevanten Innovationsbereichen Algorithmen des ML weiterentwickelt. Das erlaubt ihren Einsatz auch in Situationen, die nicht durch klassische Formulierungen des ML abgedeckt sind. Insbesondere wurden hier exemplarische Methoden Open-Source als Notebooks zur Verfügung gestellt, die eine exemplarische Anwendung unmittelbar möglich machen.
2. **Modellierungsparadigmen und -beispiele:** Anhand von relevanten Praxisbeispielen innerhalb von sechs hochaktuellen Handlungsfeldern und unter Einbezug von Anwendungspartnern wurde die Entwicklung von zentralen ML-Innovationen für die agile ITS demonstriert, und deren Transfer in die Praxistauglichkeit ermöglicht. Die Ergebnisse dieser Arbeit sind in einer Web-Plattform verstetigt.
3. **Ausbildung und Informationstransfer:** Zudem wurden unterschiedliche Formate etabliert und getestet, die zur Qualifizierung der für die Umsetzung der technischen Innovationen zentralen Personen beitragen. Im besonderes Fokus stehen hier Mitarbeiter der

KMU und MINT-Studierende der Hochschulen. Hier wurden konkret Materialien zur praxisnahen Weiterbildung entwickelt und zur Verfügung gestellt.

Es wurde unter der Domäne <https://its-ml.de/> eine Plattform geschaffen, die Zugang zu allen Materialien schafft, die im Zuge dieser Maßnahmen entstanden sind.

**Voraussetzungen, unter denen das Vorhaben durchgeführt wurde.** Die Akteure im Projekt **ITS.ML** kombinieren ausgewiesene Einrichtungen für ML und konnten hervorragendes theoretisches als auch praktisches Know-how zur Verfügung stellen. Zum Aufbau von **ITS.ML** hatten sich dabei Forschende der **Universität Bielefeld (UBI)**, **Universität Paderborn (UPB)**, **Hochschule Ostwestfalen-Lippe (HSOWL)**, **Fachhochschule Bielefeld (FHBI)** in einem kreativem Team zusammengeschlossen, welches durch seine Verwurzelung in zahlreichen renommierten wissenschaftlichen Einrichtungen und Instituten auf ein reichhaltiges Netzwerk von relevanten Kompetenzen und Infrastrukturen zurückgriff.

Die **Universität Bielefeld** (PIs im Projekt B. Hammer, S. Wrede) ist mit den Einrichtungen CoR-Lab - Forschungsinstitut für Kognition und Robotik, dem CITEC - Cluster für Intelligente Interaktionstechnologie, und JAII - dem gemeinsamen AI Institut mit der Universität Paderborn im Bereich ML herausragend ausgewiesen. Die Einrichtungen und Akteure kombinieren Exzellenz in der Grundlagenforschung des ML, der Mensch-Maschine Interaktion und kognitiven Robotik mit innovativen technologischen Realisierungen und komplementieren dieses mit Expertise in den Datenwissenschaften.

Die **Universität Paderborn** (PIs im Projekt E. Hüllermeier, G. Schomaker) mit den Einrichtungen SICP – Software Innovation Campus Paderborn, SFB 901 – On-The-Fly Computing und dem PC<sup>2</sup> – Paderborn Center For Parallel Computing, und dem Heinz-Nixdorf Institut



Abbildung 1: ML revolutioniert die Wertschöpfungskette und schafft Mehrwert, indem aus Daten Wissen wird. Daten aus ITS bieten dazu einen Anwendungsbereich mit bereits hoher digitaler Durchsetzung und entsprechend veredelten Daten.

weist langjährige Grundlagenforschung in maschinellem Lernen und der Prozessautomatisierung sowie eine vertiefte Expertise für intelligente Informationssysteme auf. Themen decken etwa Präferenzlernen, den Umgang mit Unsicherheiten und digitale Geschäftsmodelle ab.

Die **Hochschule Ostwestfalen-Lippe** am Standort Lemgo: (PI V. Lohweg) mit den Einrichtungen SmartFactory OWL und inIT – Institut für industrielle Informationstechnik, kombinieren eine langjährige Expertise in der intelligenten Industrieautomation mit einer herausragenden Erfahrung im forschungsgetriebenen industriellen Transfer etwa im Bereich Internet of Things (IoT).

Die **Fachhochschule Bielefeld**, Standorte Bielefeld und Gütersloh, (PIs W. Schenck, A. Schneider) mit den Einrichtungen ISyM – Institut für Systemdynamik und Mechatronik und CfADS – Center for Applied Data Science Gütersloh kombiniert Expertise zur Verarbeitung von Big Data beispielsweise für die Digitalisierung und Optimierung von Arbeits- und Geschäftsprozessen mit Expertise zur Biomechatronik.

Spezifische Expertise, auf die aufgebaut wurde, liegt in folgenden Bereichen: B. Hammer und E. Hüllermeier sind ausgewiesene Forscher im Kerngebiet des maschinellen Lernens und künstlicher Kognition, speziell Relevanzlernen, Online-Lernen, Lernen auf Datenströmen, Lernen mit Drift, interpretierbare ML-Modelle, Multi-Target Prediction, Präferenzlernen, komplexe Fehlermaße, verstärkendes Lernen, generative neuronale Modelle und Deep Learning, komplementiert durch klassische Methoden wie Mustererkennung, Sensor- und Informationsfusion (Lohweg), Greybox-Lernen (Schneider) und statistische Verfahren (Schenck) [Bus+14; Dem+12; Dem+14; Hül+08; KSM10; Szö+15; LHW18; Göp+18]. A. Schneider erforscht hybride Ansätze und Greybox-Modelle in der Mechatronik. Innovative ML für Robotik wird intensiv im CoR-Lab erforscht, etwa im Rahmen energieeffizienter Realisierung autonomer Systeme oder bioinspirierter Robotik [Pas+13; Pas+15]. Software-Engineering wird durch S. Wrede (Software-Engineering für eingebettete und technische Systeme) repräsentiert. Intelligente technische Systeme in der Produktion erfordern aktuellste Technologien und Methoden aus dem Bereich der Automatisierungstechnik, speziell was die Ausstattung mit Sensoren und die Vernetzung der Anlagen in der Industrie 4.0 betrifft [PNW17]. Das inIT (Lohweg, Niggemann) und Forscher des CoR-Lab (Wrede) und im CfADS (Schenck) verfügen in diesem Bereich über langjährige Erfahrung.

Das Projekt konnte zudem für Realexperimente auf drei ML-Labs mit unterschiedlichen Schwerpunkten aufbauen: die **SmartFactory OWL** ist eine herstellerunabhängige und offene Industrie 4.0 Forschungs- und Demonstrationsplattform und zugleich Testfeld für den Mittelstand. Die **CITEC Central Labs** und das **Cor-Lab Transferlabor** stellen Plattformen für Mensch-Maschine Interaktion, innovative Industrierobotik und interaktive Fertigung zur Verfügung. Der **Software Innovation Campus (SICP)** mit dem Big Data Center SCAD in Paderborn offeriert einen dedizierten Bereich für Smart Systems sowie ein Software-Quality-Lab. Für das Hochleistungsrechnen auf klassischen Computerclustern (inklusive Big-Data-Technologien) standen Hardware und

Know-How zur Verfügung: Das PC<sup>2</sup> der Universität Paderborn<sup>1</sup> und Data-Analytics-Cluster im CfADS. An allen Standorten war zudem dedizierte Hardware für die Durchführung des Projekts verfügbar, einschließlich High-Performance-Computing- und Cloud-Architekturen, TPUs, sowie Komponenten für Edge-Computing.

Das Vorhaben baute auf den von regionalen KMU hervorragend initiierten technischen Digitalisierungsstrategien und die ausgewiesene Exzellenz der beteiligten Partner in ML auf, um den Schritt zu einer inhaltlichen Nutzung digitaler Daten durch ML zu realisieren. Als assoziierte Partner unterstützten dabei zahlreiche lokale Unternehmen und Multiplikatoren, die in **ITS.ML** mit den Partnern in Begleit- und Umsetzungsprojekten sowie Transfermaßnahmen kooperierten oder bei der Durchführung des Projekts Input aus Sicht der Praxis liefern konnten.

**Planung und Ablauf des Vorhabens.** Der Fokus des Projekts lag auf sechs aktuellen Handlungsfeldern beim Einsatz von ITS im Rahmen der in der Region OWL bereits erfolgreich fortgeschrittenen industriellen Digitalisierung. Diese bündelten für mehrere Wirtschaftszweige hochrelevante Herausforderungen, für die neueste ML-Technologien innovative Lösungen ermöglicht. Die ITS Handlungsfelder wurden flankiert von fünf aktuellen Innovationsbereichen des ML. Im Forschungsvorhaben wurden diese neu entwickelten Technologien des ML für KMU nutzbar gemacht. Die so gewonnenen Erkenntnisse wurden in Services einer ML-Plattform eingebunden, um so Persistenz und Übertragbarkeit auf andere Bereiche zu garantieren.

## Handlungsfelder für Intelligente Technische Systeme

Produkte wie mobile Plattformen, Roboter oder Fahrzeuge sammeln Daten und nutzen diese zur Optimierung ihres Verhaltens. Aber auch Produktionssysteme verwenden zunehmend Daten, um agiler auf neue Marktentwicklungen und Kundenbedarfe zu reagieren und Produkte optimal unter den gegebenen Ressourcen zu produzieren. ML spielt hier eine zentrale Rolle. Dabei ist der lokale Einsatz von schlanken ML-Verfahren in Produkten und Produktionssystemen nahe am Ursprung der Daten besonders vielversprechend. In **ITS.ML** wurden Services und Forschungsschwerpunkte um für ITS zentrale Handlungsfelder gruppiert, die für mehrere Branchen (insbesondere die regional stark vertretenen Branchen Maschinen- und Anlagenbau, Verfahrenstechnik, elektrische Automation, Lebensmittel-, Gesundheits- und Medizintechnologien) relevant sind, und für die ML einen methodischem Ansatz der Wahl darstellt (siehe Fig. 2).

**(H1) Predictive Maintenance und Condition Monitoring:** Die Digitalisierung von Anlagen und deren Ausstattung mit entsprechender Sensorik bietet sich an, Zustandsüberwachung und Wartung von Maschinen intelligent durch digitale Sensorwerte der Anlagen zu steuern [NS+12; Bin+16]. Da eine exakte Modellierung hier in der Regel nicht möglich ist, stellen

---

<sup>1</sup>Das PC<sup>2</sup> stellt mit dem Hochleistungsrechner Noctua einen der zehn leistungsstärksten Rechner an deutschen Universitäten zur Verfügung.

Ansätze aus dem Gebiet des ML oftmals die beste Lösung dar. Im Rahmen des Projekts entstanden hier unter anderem die Publikationen [PL21; Tor+21a; HL21; Tor+20; EHN19].

- (H2) Lernende Assistenzsysteme:** Moderne Assistenzsysteme erhalten laufend digitale Rückmeldung ihrer Benutzer, die sowohl explizit (z.B. erfasst über natürlichsprachige Dialogsysteme [Ung+]) als auch implizit (z.B. abgeleitet aus dem Nutzerverhalten) sein kann. Hierdurch ergeben sich vielversprechende Möglichkeiten zur Personalisierung solcher Systeme [RFR; Ngo+13]. Eine wichtige Voraussetzung ist die inhärente Adaptivität der Systeme, also der Einsatz verlässlicher Lernverfahren. Publikationen, die im Rahmen des Projekts **ITS.ML** in diesem Bereich entstanden sind, beinhalten [Van+22; Gop+21; Buc+21; Sha+21; Kum+21].
- (H3) Kognitives Plug and Work:** Komplexe Anlagen setzen sich aus vielfältigen verteilten Komponenten zusammen, die durch digitale Daten gesteuert optimal zusammenspielen. Es entstehen Herausforderungen an die Kalibrierung einzelner Komponenten, um einen Plug-and-Work Modus zu ermöglichen. ML-Technologien erlauben eine intelligente Adaptation der Schnittstellen [Paa+17]. Publikationen, die im Rahmen des Projekts **ITS.ML** in diesem Bereich entstanden sind, beinhalten [BW21; BW20].
- (H4) Kognitive Optimierung:** Das Vorliegen umfangreicher digitaler Informationen beinhaltet das Potenzial, Prozesse datengetrieben intelligent zu optimieren. So kann auf der Basis realer Anforderungen und Auftragslagen statt basierend auf etwaig unzulässigen Annahmen agiert werden. Hier spielen intelligente Verfahren, etwa zur Bedarfsprognose komplexer Prozesse, eine große Rolle [Büt+17]. Publikationen, die im Rahmen des Projekts **ITS.ML** in diesem Bereich entstanden sind, beinhalten [Buc+21; BH20b; SH20].
- (H5) Kognitives Qualitätsmanagement:** Digitale Informationen an verschiedensten Punkten eines Prozesses ermöglichen es einerseits, sehr frühzeitig im Prozess die Qualität einzelner Komponenten zu überwachen. Andererseits kann dies auch nach der Auslieferung eines Produktes gezielt geschehen. Dies eröffnet neue Möglichkeiten, die Produktqualität mit Hilfe von ML effizient und zielgenau zu garantieren [Bri+16]. Publikationen, die im Rahmen des Projekts **ITS.ML** in diesem Bereich entstanden sind, beinhalten [Gop+21; HL21; HL19; Göp+19].
- (H6) ML in der Evolution von IKT Systemen:** Der Prozess der digitalen Transformation und die Durchdringung in Unternehmen bis hin zu Arbeit 4.0 wird durch die Weiterentwicklung der im Markt befindlichen IKT Technologien und Komponenten stark beeinflusst. Insbesondere die industrielle Kommunikation der Zukunft, getrieben durch Entwicklungen wie z.B. 5G, wird die Architekturen adäquater ML-Lösung vorgeben – wo und wie findet ML am besten statt? Entwicklungen dieser Art zu erfassen, zu reflektieren und Potenziale durch Neuerungen in den Handlungsfeldern (H1)-(H5) zu erschließen, garantiert die Nachhaltigkeit und Anschlussfähigkeit in allen Feldern [San+17]. Publikationen, die im Rahmen des Projekts **ITS.ML** in diesem Bereich entstanden sind, beinhalten [Tor+21b; HL20].

Das Forschungsvorhaben **ITS.ML** hatte zum Ziel, durch am Ort der Daten angesiedelte ML-Technologie einen Paradigmenwechsel herbeizuführen, der eine agile und schnelle Anpassung von Produkten und Produktionsprozessen an neue Bedarfe oder Marktgegebenheiten erlaubte. Die Herausforderungen lagen entlang der gesamten Produktionskette von Produktdesign, Produktionsplanung, Garantie der Produktionsqualität, Auslieferung, über Monitoring und Anpassung bis hin zur Personalisierung von Produkten. Die Handlungsfelder wurden dabei in einer Reihe konkreter Projekte mit unterschiedlichen Partnern aus Industrie als auch Anwendungspartnern der Hochschulen durchgeführt und dokumentiert.

## Innovationen aus dem Maschinellen Lernen

Klassische ingenieurtechnische Modellierungen sind in ihrer Adaptivität begrenzt. Adaptive, hoch performante ML-Technologien sind für Anwender, insbesondere KMU, aber nicht leicht verfügbar. Die Herausforderungen (H1)-(H6) korrespondieren zu aktuellen Forschungsfeldern des ML, die zum überwiegenden Teil nicht für spezifische Handlungsfelder angepasst oder in der Praxis getestet wurden. Es war daher zentraler Punkt im Projekt, **Innovationen aus der aktuellen Forschung im Bereich des maschinellen Lernens (ML)** in Beispielen der konkreten Handlungsfelder zu integrieren und zu übertragen.

- (I1) **Lernen auf Datenströmen:** Sowohl Condition Monitoring als auch Assistenzsysteme sind mit fortlaufenden, sich dynamisch entwickelnden Datenströmen konfrontiert. Dies geht mit speziellen Anforderungen an maschinelle Lernverfahren einher: sie müssen inkrementell arbeiten und Daten ‚on the fly‘ analysieren, auf Concept Drift reagieren können und Ressourcenbeschränkungen berücksichtigen. Im Projekt wurden neueste Forschungsergebnisse bereitgestellt, die eine automatisierte Konfiguration von ML-Verfahren und die kontinuierliche Adaption von Modellen auf Datenströmen unterstützen. Solche Ansätze erlauben den Einsatz der Methoden in geschlossenen Regelkreisen, wie sie typisch für autonome und automatisierte Systeme sind [LHW16]. Publikationen, die im Rahmen des Projekts **ITS.ML** in diesem Bereich entstanden sind, beinhalten [BH20b; NSH22; HAH20; HKH20; BHS19].
- (I2) **Interpretierbarkeit von Modellen:** Wichtige Anforderungen und Prozesse – etwa Nutzerinteraktionen bei lernenden Assistenzsystemen, die intuitive Wartbarkeit intelligenter Komponenten oder zuverlässiges datengetriebenes Qualitätsmanagement – basieren zentral auf Interpretierbarkeit der betrachteten Modelle des ML. Im Rahmen des Projekts wurde Forschungsexpertise für moderne Visualisierungsverfahren, Relevanzlernen, Regelextraktion und Lernen interpretierbarer Modelle, die Garantien wie etwa das Einhalten von Randbedingungen erfüllen können, bereitgestellt und in entsprechende Anwendungen integriert [Ngo+13; RKN14; RSS17; SGH15]. Publikationen, die im Rahmen des Projekts **ITS.ML** in diesem Bereich entstanden sind, beinhalten [KAH22a; KAH22b; SL21; KSS21; HKH20; SHH20; Pfa+20; Pfa+19].

- (I3) **24/7 Benchmarking:** Die klassische Evaluation von Methoden des ML mit statischen Benchmark-Daten deckt in keiner Weise die Erfordernisse der Praxis ab. Hier ist eine Validitätsprüfung intelligenter Verfahren im Kontext bestehender Anlagen und sich ändernde Anforderungen (z.B. Security, Safety) gefragt. Evaluation von nicht einfach quantitativ fassbarer Eigenschaften wie Interpretierbarkeit ist zudem ein Problem. Die Projektpartner stellten daher Benchmarkszenarien, Benchmarkdaten und Technologien bereit, die eine skalierbare Validitätsprüfung der Methoden des ML in dynamischen Umgebungen erlauben [FHW16a; RUN17; Sch+17]. Publikationen bzw. Ressourcen, die im Rahmen des Projekts **ITS.ML** in diesem Bereich entstanden sind, beinhalten [Mec+22b; KAH22b; Tor+21a].
- (I4) **Greybox-Lernen:** Für Plug-and-Work Technologie, aber auch datengetriebene Optimierung in komplexen Anlagen, ist ein Lernen auf der Basis weniger Daten nötig. Dieses erfordert die Integration von Vorwissen und einen zuverlässigen Umgang mit auftretenden Unsicherheiten im Entwurf der intelligenten Systeme. Die Projektpartner konnten hier auf neue Forschungsergebnisse aus dem Bereich der so genannten Greybox-Modelle zurückgreifen [BS15; QRS16]. Publikationen, die im Rahmen des Projekts **ITS.ML** in diesem Bereich entstanden sind, beinhalten [Les+22; Sha+22; Van+22; BW21; BW21; Sha+21; BW20].
- (I5) **Eingebettetes Lernen:** Für eine ressourceneffiziente und kostengünstige Realisierung intelligenter Verfahren ist häufig eine verteilte Implementation auf eingebetteten Systemen oder eine Realisierung auf speziellen Plattformen erforderlich. Die am Projekt beteiligten Wissenschaftler stellten hier Ansätze zur Verfügung, die auf Energieeffizienz, Dateneffizienz und die Notwendigkeit weniger Label achten. Dabei konnten die PIs auf langjährige Expertise bei der effizienten Hard- und Softwarerealisierung auf unterschiedlichsten Plattformen unter Berücksichtigung von Industriestandards zurückgreifen [Lac+13; PNW17]. Publikationen, die im Rahmen des Projekts **ITS.ML** in diesem Bereich entstanden sind, beinhalten [Tor+21b; BH20a].

Bei diesen Arbeiten wurde deutlich, dass die KMU-typischen Herausforderungen an ML im Bereich ITS aufgrund der Ansprüche an Wartbarkeit, Echtzeitfähigkeit, Zertifizierbarkeit und Privacy zum Teil erheblich von den durch große Internetfirmen derzeit in ML adressierten Fragestellungen abweichen. Populäre Modelle wie etwa Deep Networks waren in diesen Bereichen nur zum Teil einsetzbar [NYC14]. Das Forschungsvorhaben adressierte diese Lücke dadurch, dass es auf ein breites Repertoire unterschiedlicher, auch hybrider oder für spezielle Hardware optimierter Ansätze der Computational Intelligence und deren effiziente Realisierungen zurückgreifen konnte. Es stellte Methoden zur Verfügung, die für einen lokalen Einsatz direkt am Ort der Daten, d.h. in den Produkten und Anlagen geeignet ist. Die im Rahmen von Forschungsvorhaben gewonnen Erkenntnisse und Modellierungen sind dabei von allgemeiner Bedeutung für ITS, auch wenn sie oft in speziellen Anwendungen entwickelt wurden: Die Ergebnisse fanden

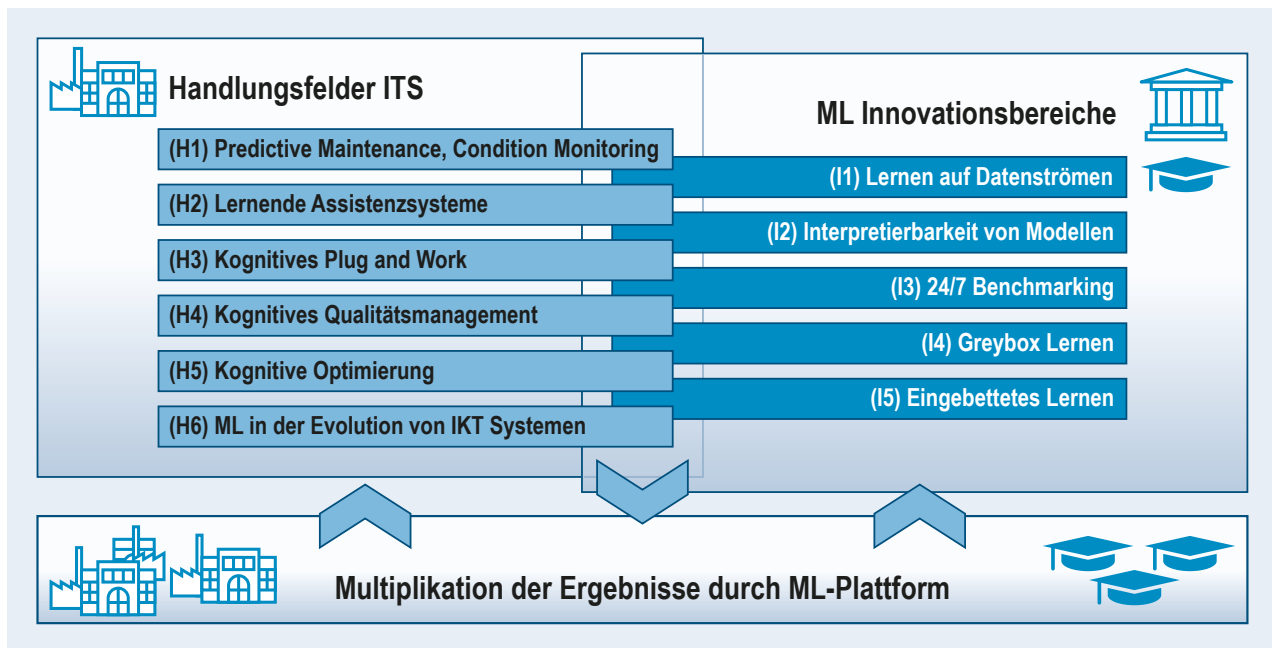


Abbildung 2: Inhaltliche Schwerpunkte von ITS.ML lagen in sechs zentralen und für mehrere Branchen relevanten Handlungsfeldern der ITS. Deren Lösungen orientieren sich an Innovationen aus dem ML. Die Ergebnisse wurden strukturell durch den Transfer der Erkenntnisse in eine ML-Plattform verstetigt.

Eingang in die ML-Plattform des Projekts, um weitere Transferaktivitäten effizient realisieren zu können.

Die Arbeit an diesen inhaltlichen Schwerpunkten und Handlungsfeldern profitierte im Projekt wesentlich von begleitenden strukturellen Maßnahmen, die eine Identifikation typischer Anforderungen und Bedarfe von KMU, eine Integration der Methoden und Technologien, und den Transfer in konkrete Anwendungen erheblich erleichterten. Zu den strukturellen Maßnahmen im Projekt ITS.ML gehörten dabei folgende Aspekte:

- **Unterstützen von Stakeholdern:** Die gewonnenen Erkenntnisse wurden in Form einer Plattform auf der Domäne des Projekts <https://its-ml.de/> bereitgestellt. So wurden Beispiele für Modellierungen in konkreten Anwendungen, neue ML-Technologien und Erkenntnisse als Open-Source-Code, und auch Informationsmaterial etwa zur Ausbildung persistent verfügbar gemacht. Dieses ist sowohl für Vertreter von KMU als auch potentiellen Anwendern von KI Methodiken aus der Wissenschaft interessant und relevant.
- **Qualifizieren von Personal:** Ein Bündel von Qualifizierungsmaßnahmen adressierte verschiedene Personengruppen auf unterschiedlichem Niveau und mit unterschiedlichen Bedürfnissen. Mitarbeiter in Unternehmen konnten in Schulungen und Informationsveranstaltungen Kompetenzen des ML auf verschiedenen Einstiegstufen erlangen. MINT Studierende als zukünftiges Fachpersonal wurden frühzeitig mit Fragestellungen der Industrie konfrontiert. Als hochdynamisches Feld ist ML ein Paradebeispiel eines Themas, in dem

technologische Neuerungen lebenslang gelernt werden müssen, und in dem industrielle Anwendung und Spitzenforschung Hand in Hand gehen müssen.

- **Demonstrieren des Potenzials von ML:** Um bei verschiedenen Stakeholdern ein tiefgreifendes Verständnis für die Möglichkeiten von ML in der digitalen Welt zu schaffen, muss das Potenzial von ML in der Praxis erlebbar gemacht werden. In den bestehenden ML-Labs in OWL (SmartFactoryOWL, CITEC Central Labs, CoR-LaB Transferlabor, SCAD) mit unterschiedlichen Schwerpunkten (Industrieautomation, Robotik, High Performance Computing und Big Data) wurden im Rahmen des Projekts Demonstrationsbeispiele realisiert bzw. synchronisiert. Dabei wurden durch digitale Formate Herausforderungen der Organisation adressiert, die sich durch Kontaktbeschränkungen während der Covid-19-Pandemie ergaben.

**Wissenschaftlicher und technischer Stand, an den angeknüpft wurde.** ML ist zentraler Treiber personalisierter Werbung, Prognose und Logistik. Darüber hinaus Versprechen Methoden des ML, Bereiche wie Transport und autonomes Fahren zu revolutionieren. Die Marktführung in diesen Bereichen liegt dabei derzeit jedoch zumeist in der Hand großer amerikanischer Internetkonzerne. Die durch ML ermöglichte automatisierte Extraktion von Wissen aus Daten hat das Potenzial, die auch in Deutschland rapide umgesetzte Digitalisierung und damit einhergehende Produktion von großen oder heterogenen digitalen Daten auf ein neues Niveau zu heben. Schlüssel dazu ist, Informationen aus den Daten zu in der Produktion verwertbarem Wissen zu veredeln. Trotz dieser enormen Möglichkeiten sind derzeit Standardisierungen, einfach zu bedienende Werkzeuge, ein Repertoire an einfach zugänglichen Best Practice Beispielen, sowie dedizierte Aus- und Weiterbildungsmaßnahmen häufig noch schwer zu finden.

Infolge dessen wird die durch ML bereitgestellte Leistungsstärke insbesondere in KMU mit einem Schwerpunkt auf der Produktion derzeit nur unzureichend genutzt, insbesondere da diese nicht selber Datenverarbeitungsservices anbieten. Im Projekt wurde gezielt Wert darauf gelegt, Open-Source Verfahren und Modelle, die einen uneingeschränkten Transfer erlauben, zu verwenden. Benutzte Verfahren bauten dabei unmittelbar auf der aktuellen Forschung auf und nutzten hinsichtlich der Modelle zum Teil bekannte und für spezifische Aufgaben trainierte Architekturen (etwa zu Bildsegmentierung). Dabei wurde exemplarisch in besonders relevanten Anwendungsgebieten in der speziellen Domäne der ITS der State-of-the-art des ML nutzbar gemacht.

ML stellt aktuell in Bereichen wie der Sensorfusion, der Bilderkennung, dem autonomen Fahren, dem personalisierten Marketing, der Logistik oder autonomen Robotik die Methode der Wahl dar [Col18; Boh+; EMH17; Car17; Fag17]. Tiefe Netze (*deep neural networks*) als eine der prominentesten Methoden erlauben hier ein sogenanntes *end-to-end learning*. D.h. sie bieten eine automatisierte Extraktion grundlegender Gesetzmäßigkeiten auf der Basis großer Datenmengen ohne die Notwendigkeit von einer komplexen Datenaufbereitung oder von speziellem Domänenwissen [BCV13; Sch15]. Dazu sind allerdings in der Regel in klassischen Anwen-

dungen sehr große Datenmengen nötig, die die betrachteten Gesetzmäßigkeiten beschreiben (mehrere Millionen Datenpunkte), sowie dedizierte Hardware wie zumeist spezifische Grafikprozessoren (GPU), um das Training in realistischer Zeit durchzuführen [Lea17]. Ansätze des Transferlernens, die unter Ausnutzen bekannter und bereits trainierter Architekturen mit nur relativ wenigen Daten eine Anpassung auf neue Szenarien erlauben, sind zentral darauf angewiesen, dass trainierte Modelle in ähnlichen Anwendungen bereits existieren. Aufgrund dieser Spezifität sind sie damit für bestimmte Anwendungen spezialisierter KMU tendenziell problematisch. Daher sind tiefe Netze durch ihre inhärente Flexibilität besonders attraktiv für Bereiche, in denen diese Datenmengen verfügbar sind und das Training der Verfahren einmalig vor dem Einsatz erfolgen kann. Beispiele für solche Einsatzfelder sind die Sprachverarbeitung, die Bilderkennung oder automatisierte Übersetzungen [Rav; Wu+]. Andererseits sind tiefe Netze eher ungeeignet für Anwendungen, die eine inkrementelle Anpassung und ein Lernen während der Produktion erfordern, sowie Situationen, in denen die Anzahl an Datenpunkten beschränkt ist, und insbesondere in spezifischen, hoch spezialisierten Domänen. Es ist anzumerken, dass eine beschränkte Anzahl an Datenpunkten nicht gleichbedeutend mit kleinen Datenmengen ist: in der Produktion etwa gibt es oft eine Fülle an Varianten und Signalen, die zwar eher wenige Situationen oder Produkte beschreiben, diese aber mit einer großen Fülle von Charakteristika: es ergeben sich hier wenige, aber hochdimensionale Punkte, sogenannte *fat data* statt *big data* [CC14]. In KMU mit einer hoch individualisierten Produktpalette ist dies oft der Regelfall bei einem entsprechend fortgeschrittenen Grad der Individualisierung.

Zusätzlich zu Zeitbeschränkungen und nicht ausreichenden Daten wird der Einsatz von Technologien wie neuronalen Netzen durch weitere Aspekte erschwert: die Wahl einer geeigneten Netzarchitektur sowie eines Trainingsverfahrens ist in der Regel hochgradig nicht trivial und bedarf neben Rechenressourcen auch erhebliche Einblicke in die ML-Verfahren, d.h. Zugang zu entsprechender Expertise. In den letzten Jahren wurden aufgrund dieser Problematik Lösungen entwickelt, die es erlauben, Teile dieser Prozesse zu automatisieren, insbesondere sogenannte Auto-ML-Ansätze [Kot+17; Kle+17]. Der Vorteil dieser Verfahren liegt darin, dass sie dem Nutzer Teile dieser Optimierung abnehmen. Allerdings sind Auto-ML-Methodiken zumeist noch beschränkt in der Hinsicht, dass nur eine Parametrisierung optimiert wird und nicht die gesamte Pipeline, und die initiale Modellierung des Problems in der Form eines Lernproblems ebenfalls nicht betrachtet wird. Zudem sind die Verfahren in der Regel auf statisch gegebene Datenmengen beschränkt. Das bedeutet, diese Methoden können die Optimierung der ML-Verfahren in Teilen für klassische Szenarien einfacher machen, aber derzeit nicht wirklich ML-Expertise ersetzen.

Weitere Problematiken ergeben sich aus folgenden Sachverhalten: Erstens werden ML-Verfahren oft in nicht klassischen Szenarien mit a priori gegebenen Daten verwandt, sondern Daten werden als fortlaufender Strom verfügbar. Es bedarf daher angepasster, auf die Daten unmittelbar reagierender Technologien [BKP; Dit+15]. Zweitens werden ML-Verfahren nicht als alleinstehende, unabhängige Methoden verwandt, sondern sie müssen in eine Prozesskette eingebunden werden. Eine solche Kette gibt einerseits Schranken vor, die von den ML-Technologien respek-

tiert werden müssen. Andererseits sind dadurch die Ansprüche an eine Wartbarkeit und Einsicht in die Funktionsweise der ML-Methoden erhöht. Für diese Fragestellungen sind zum Teil Forschungsergebnisse in den letzten Jahren entstanden, aber nur in Ausnahmen in die Praxis umgesetzt und in der Regel noch so realisiert, dass die Verfahren ML-Expertise für ihren Einsatz verlangen [CRR12; Lip; ANR17]. Eine weitere Anforderung gerade in hoch spezialisierten KMU sind eine lokale Datenhaltung und -verarbeitung, um etwa die Hoheit über die Daten zu behalten und somit das Risiko von Industriespionage zu minimieren. Gleichzeitig ist eine effiziente Verarbeitung etwa durch minimierte Latenzzeiten gewünscht. KMU tendieren daher zu so genanntem Edge Computing, statt globale Dienste der Cloud zu nutzen [Lin17]. Diese Tatsachen machen die Notwendigkeit von dedizierten, im Projekt verfolgten Maßnahmen deutlich, die die zum Teil hoch performanten Techniken so aufbereiten, dass sie für KMU als Service nutzbar werden.

Derzeit gibt es eine Fülle von Open-Source-Software für Maschinelles Lernen, die zum Teil in dieser Form insbesondere in Unternehmen mit dem Fokus auf Datenanalytik zum Einsatz kommen: populäre generelle Frameworks zu Data Mining und ML sind etwa das Java basierte Weka, welches insbesondere eine Datenanalyse mit Hilfe einer grafischen Oberfläche gestattet und in neuen Varianten auch die Verarbeitung größerer Datenmengen erlaubt [FHW16b]. Scikit-Learn stellt eine sehr flexible und populäre Suite an ML-Methoden in Python bereit. Die Tatsache, dass diese anhand von sogenannten Notebooks in einer Symbiose von anschaulicher Dokumentation und Pipeline eine unmittelbare intuitive, dabei aber hoch flexible und performante Verwendung ermöglicht, macht sie besonders attraktiv [Pe11]. Rapid Miner ist eine in ihrer vollen Funktionalität kostenpflichtige Software, die eine grafische Oberfläche für eine integrierte Datenanalyse und Datenspeicherung ermöglicht und als Open-Source-Software Erweiterungen in R und Python erlaubt. Rapid Miner wird allerdings auch aufgrund des Geschäftsmodells oft nicht unter den Top-Ten-Frameworks für Machine Learning gelistet, anders als etwa Weka oder Scikit-Learn. Daher ist es für den Zweck des Projekts, nämlich den prototypischen Transfer von aktuellen Entwicklungen des ML in einer großen Breite und in einem KMU-tauglichen Format, weniger geeignet [Yeg17]. Dedizierte Modelle für Datenströme werden in der Suite MOA bzw. dem Folgetool River angeboten, sowie – in einer Erweiterung für große Daten – SAMOA. Allerdings sind diese weniger komfortabel zu erweitern, da diese zum Teil auf Java basieren [Bif+10]. Frameworks für Datenströme und große Datenmengen, die mitunter Analytics Tools mitbringen, oder eine Verschränkung mit solchen erlauben, sind etwa Apache Spark oder Flink [FT16; Zah+]. Diese bieten allerdings nur limitierte Methoden etwa im Bereich moderner nicht-linearer Dimensionsreduktion oder Auto-ML, da sie primär für die Anwendung auf große Daten zielen. Infolge dessen werden sie weniger für die Entwicklung von neuen ML-Methoden im Bereich etwa hochdimensionaler Daten von Forschern zur Entwicklung eingesetzt. Ein Framework, das explizit spezielle Datenstrukturen wie Graphen und das Semantic Web adressiert und mit Flink oder Spark verknüpft werden kann, ist etwa SANSA [Erm+17].

Dedizierte Frameworks für tiefes Lernen, die insbesondere auch eine automatische effiziente Parallelisierung der Verfahren auf geeigneter GPU unterstützen, reichen von Googles TensorFlow, über PyTorch, Keras als Schnittstelle, Deeplearning4j bis zu Caffe. Diese Frameworks

sind dabei zumeist ähnlich mächtig und flexibel und unterscheiden sich in der Regel nur anhand von kleineren Design-Entscheidungen. Durch seinen Fokus auf Tensoren etwa ist in TensorFlow die Verarbeitung von Graphen eher aufwändig zu realisieren, dafür aber eine Verknüpfung verschiedener Module zur Berechnung eines globalen Gradienten sehr effizient und elegant. Die meisten populären Tools, die eine Schnittstelle zu Python anbieten, sind nahtlos kompatibel mit Scikit-Learn, welches im vorgeschlagenen Projekt zur Entwicklung verwandt werden soll. Scikit-Learn erfreut sich großer Popularität, und bietet eine einfache Verfügbarkeit und elegante Möglichkeiten, Dokumentation, Pipelining und aktuellen Code nahtlos zu verschränken. Zu erwähnen sind noch kommerzielle Tools wie etwa SAP-Hana, welches allerdings aufgrund der Proprietarität in der Forschung zu ML keine zentrale Rolle spielt, da es mit dem weit verbreiteten Open-Source-Gedanken der Community weniger kompatibel ist. Obschon eine breite Palette von ML-Suiten verfügbar ist, gibt es derzeit keine größeren, dezidiert für den einfachen Einsatz bei KMU entworfenen Open-Source-Plattformen mit typischen Benchmarks und Pipelines. Dies stellt eine fundamentale Lücke dar, denn anhand einer solchen Plattform kann Personen mit geringer Expertise im ML der Gebrauch der Methoden für den Einsatz in der Produktion nahe gebracht werden, während gleichzeitig in diesem Bereich notwendige neue ML-Methoden aus Forschungsinnovationen angemessen abgedeckt werden.

Einsatzgebiete des ML erstrecken sich in Deutschland über die Bereiche autonomes Fahren, autonomer Transport, Robotik, Supply Chain Management, Logistik, intelligente Fabrikanlagen, Prozessautomation, Smart Homes, Gesundheit, Finanzcontrolling, bis hin zu intelligenten cyber-physischen Services [AR17; JBe18]. Gleichzeitig sind in der deutschen Forschungslandschaft einige Hubs im Bereich des ML prominent an verschiedenen Hochschulen vertreten. Um nur einige in Deutschland herausragend repräsentierte Kompetenzen zu nennen, gehören hierzu Domänen wie Selbstorganisation, Lernen mit Kernen und Lerntheorie, statistisches relationales Lernen, Semantic Computing, und Auto-ML. Flankiert wird diese Expertise von praxisnahen Hubs mit der dezidierten Mission des Industrietransfers in Entwicklung und Ausbildung von statistischer Datenanalyse oder ML. Hier sind etwa die Fraunhofer Gesellschaft oder das DF-KI zu nennen. Damit ist Deutschland exzellent aufgestellt, um die Transferkette des ML in die unternehmerische Praxis, mit dem Fokus auf in Deutschland traditionell starke Wirtschaftszweige wie Mechatronik oder Automatisierung, zu adressieren. Dieses geschieht bereits an vielen Standorten, insbesondere im Bereich von ML-Startups und großen Unternehmen mit eigenen Forschungsabteilungen im Bereich ML (wie etwa bei allen großen Automobilherstellern). Es besteht jedoch derzeit eine Lücke des Transfers von ML für KMU, deren Geschäftsmodell selber nicht die Digitalisierung ist, und die oft als familiengeführte Traditionsunternehmen einen der wesentlichen Eckpfeiler der deutschen Wirtschaft bilden.

Im vorgeschlagenen Projekt wurde diese Lücke in einem besonders relevanten und in der Region Ostwestfalen-Lippe (OWL) stark vertretenen Bereich adressiert: Intelligente technische Systeme (ITS). Diese basieren auf einer nahtlosen Symbiose von Ingenieurwissenschaften und Informatik, und zeichnen sich durch ein enges funktionales Zusammenspiel zwischen Hard- und Software aus. OWL besitzt einen international herausragenden Schwerpunkt für Innova-

tion, Wertschöpfung und Beschäftigung in den Bereichen Maschinenbau, Elektro- und Elektronikindustrie sowie Automobilzulieferindustrie. Durch innovative Projekte, insbesondere dem Spitzencluster *it's OWL* (Intelligente Technische Systeme OstWestfalenLippe), ist es hier *in beispielhafter Weise gelungen, die Digitalisierung voranzutreiben* und Unternehmen, Hochschulen, und Forschungseinrichtungen in einem *leistungsfähigen Netzwerk* zusammenzubringen. Gleichzeitig bündelt die Region eine *herausragende wissenschaftliche Exzellenz* für *Kognition und intelligente Systeme*.

**Zusammenarbeit mit anderen Stellen.** Im Projekt **ITS.ML** bestanden intensive Kooperationen mit verschiedenen Stakeholdern auf verschiedenen Ebenen:

- Im Rahmen von Anwendungsbeispielen wurde intensiv mit verschiedenen KMU und Unternehmen kooperiert, die die Anforderungen der Problematik und Echtweltdaten zum Test zur Verfügung stellten. Diese Kooperationen haben zum Teil im Projekt zu Publikationen in internationalen wissenschaftlichen Zeitschriften geführt, bei denen Vertreter der Unternehmen als Koautoren auftreten [Gop+21; Buc+21]. Zum Teil treten die Unternehmen bzw. KMU namentlich in den auf der Plattform <https://its-ml.de/> dargestellten Applied Modeling Examples auf. In einigen Fällen werden die Unternehmen hier aufgrund möglicher Konkurrenzsituationen nicht genannt, sondern die Anwendungsbeispiele formalisiert und in ihrer grundsätzlich Charakteristik beschrieben. Neben Unternehmen waren hier auch Behörden, die Zugriff zu mit ML zu analysierenden Daten haben, Anwendungspartner (etwa Amt für Verkehr der Stadt Bielefeld).
- Die Entwicklung von Innovationen in den im Projekt adressierten Herausforderungen im Kernbereich der KI wurde durch Anwendungsproblematiken und von Anwendungspartnern aus anderen Bereichen der Wissenschaft bereitgestellten realen Daten gestützt. In mehreren Fällen ergaben sich auch hier gemeinsame, die Ergebnisse dokumentierende Publikationen in Fachgremien. Dieses betrifft Partner in der Domäne Physik, Mikroskopie [Sha+22; Sha+21], Partner aus den Computational Neuroscience [KSS21], sowie Partner im Bereich der Medizin [Kum+21].
- Algorithmische Entwicklungen im Kernbereich der KI etwa zu der Frage des Nutzen von Label-Information, des Umgangs mit etwaig driftenden Datenströmen, oder der robusten Realisierung von Erklärkomponenten für wichtige Methoden wurden zum Teil in Kooperation mit internationalen KI-Experten in den jeweiligen Bereichen untersucht. Es entstanden auch hier mehrere Publikationen in anerkannten Publikationsorganen der KI [Pfa+20; Pfa+19; BHS19; HL21; Göp+19].
- Im Rahmen von Veranstaltungen zum Transfer der Methoden in die Industrie wurde intensiv mit Multiplikatoren aus der Region zusammengearbeitet. Etwa der Data-Science-Day konnte in Kooperation mit der IHK Lippe stattfinden, eine virtuelle Präsentation des Projekts auf der Hannover Messe 2020 gliederte sich in die von der OstWestfalenLippe GmbH

und owl maschinenbau in Kooperation mit dem Spitzencluster it's OWL koordinierten Summit Industrial Pioneers OWL ein, und sorgte so für eine größere Multiplikationswirkung. Es wurde zudem im gesamten Projekt intensiv mit Vertretern von Transferprojekten im Bereich ML kooperiert, insbesondere dem übergreifenden Technologienetzwerk it's OWL zu Intelligenten Technischen Systemen.

## 2 Eingehende Darstellung

### Erzielte Ergebnisse

Im Projekt wurde einerseits der Tatsache Rechnung getragen, dass in der wirtschaftlichen Praxis verfügbare ML-Technologien viele Anforderungen nicht erfüllen: Datenakquise und -analyse erfolgen zumeist durch Experten in einem Offline-Prozess. In technischen Systemen wird in vielen Fällen jedoch eine Echtzeitreaktion auf Prozessänderungen benötigt. Physikalische Zusammenhänge technischer Systeme erfordern eine explizite Integration von Domänenwissen [NL15]. Hohe Datendimensionalität, Heterogenität und Dynamik der Systeme, die Umsetzung in verteilten Hardwaretopologien und die Notwendigkeit einfach wartbarer und verlässlicher Komponenten gehen mit weiteren Herausforderungen einher. Obschon moderne ML-Technologien, insbesondere Deep Learning, in letzter Zeit Bereiche wie Bild- oder Spracherkennung revolutioniert haben [LBH15], sind diese Verfahren durch ihre Black-Box-Charakteristik, die Notwendigkeit großer Datenmengen zum Training, und den oft erheblichen zentralen Rechenaufwand limitiert: sie genügen den Anforderungen von KMU hinsichtlich Nachvollziehbarkeit, Verlässlichkeit, Wartbarkeit, und Agilität nicht. Zudem sind sie oft angesichts hoch individualisierter Prozesse sowie eingeschränkter Rechenressourcen in der Industrie 4.0 nicht anwendbar. Statt zentraler Black-Box-Verfahren werden hier dezentrale und schlanke ML-Methoden benötigt, die direkt in den Produkten und Produktionsanlagen angesiedelt werden können, und die ingenieurwissenschaftliche Modellierungen nahtlos integrieren.

Umgekehrt stellt der Einsatz von ML-Technologien in agilen Produktionsprozessen Hersteller technischer Systeme vor neue Herausforderungen: Neue Produktentwicklungs- und Engineeringansätze werden benötigt, welche Raum für Adaptivität lassen. Auch die Einführung neuer, datenbasierter Geschäftsmodelle erfordert komplexe Anpassungsprozesse. Diese überfordern gerade KMU oft, denn es sind keine standardisierten Verfahren zur erfolgreichen Kommerzialisierung von lernenden technischen Systemen verfügbar. Gerade für Unternehmen ohne eigene Forschungsabteilung ist das schnelle Fortschreiten theoretischer, technischer und technologischer Lösungen im Fachgebiet des ML eine große Hürde beim Einsatz von ML-Technologien. Hauptziel des Forschungsvorhabens ITS.ML war es, Unternehmen, insbesondere KMU, zu befähigen, das enorme Potenzial des ML entlang der gesamten Wertschöpfungskette von ITS nutzbar zu machen. Dies sollte gelingen, indem schlanke ML-Technologien entwickelt und lokal in die Produkte und Produktionsanlagen gebracht werden (siehe Fig. 1).

Im Folgenden werden die unter Verwendung der Zuwendung erzielten Ergebnisse eingehend dargestellt, gegliedert in die fünf Arbeitsbereiche (AB) des originalen Arbeitsplans.

## **AB1: Projektleitung und Dissemination (Leitung: Universität Bielefeld)**

Ziel dieses Arbeitsbereichs war die Realisierung einer effizienten Organisationsstruktur und das Management des Portfolios. Dies beinhaltete die globale Administration und Evaluation der Leistungen, die Darstellung und Vernetzung der Kompetenzen in der Öffentlichkeit, sowie die strategische Weiterentwicklung des Konzepts. Ein besonderer Schwerpunkt lag in der Vernetzung zu existenten Forschungs- und Transferprojekten mit wirtschaftlicher Ausrichtung (insbesondere KMU) in der Region OWL, um das Umsetzungspotenzial der in **ITS.ML** entwickelten ML-Verfahren zu stärken. Es wurden hier folgende Ergebnisse erzielt:

**Aufbau Webportal** Unter der Adresse <https://its-ml.de> wurde ein Webportal aufgebaut, in dem über die Ziele, Leistungen und Ergebnisse des Projekts berichtet wird. Speziell soll diese für KMU im Bereich der intelligenten technischen Systeme Informationen und Ansprechpartner für spezielle Fragestellungen des ML benannt werden. Insbesondere dient das Portal als Einstieg zur Plattform **FIT.ML** (<https://its-ml.de/index.php/fit-ml/>) und der dort bereitgestellten Wissensbasis von typischen ML-Anwendungen bzw. Notebooks für typische industrielle Fragestellungen. Dieses Portal bleibt über das Projektende hinaus verfügbar, um einen persistenten Zugang zu allen Projektergebnissen sowie der Plattform **FIT.ML** zu sichern.

**Kommunikationskonzept** Durch die Ermöglichung des effizienten Datenaustausches (Plattform Sciebo), Schaffung einer Mailingliste, regelmäßige Newsletter und die Durchführung regelmäßiger virtueller Treffen wurde unser Konzept für kollaboratives Arbeiten etabliert.

**Verbesserung der Wahrnehmung von ML in KMU** In der Darstellung des Webportals, der Realisierung der Veranstaltungen der weiteren Arbeitsbereiche (Machine Learning Innovation Day, Schulungen), sowie dem Interface zur Plattform **FIT.ML** spiegelt sich unser Konzept zur Verbesserung der Wahrnehmung von ML in KMU wider.

Insbesondere ist der rege Austausch mit Transferpartnern und Clusterprojekten im industriellen Bereich, wie mit wissenschaftlichen Vertretern des Konsortium ML4Pro2, sowie der im Spitzencluster it's OWL relevanten Einheit zu KI, zu nennen. Darüber hinaus wurden Einzelgespräche mit Vertretern von Unternehmen geführt, um die Bedarfe wichtiger Unternehmen festzustellen. Für die Außendarstellung besteht ein Twitteraccount unter dem Handle [@\\_its\\_ml](#).

### **Meilensteine:**

- **M1.1: Aufbau Webportal:** Dieses ist erreichbar unter <https://its-ml.de>

- **M1.2: Vernetzungstreffen mit Projektkonsortien von relevanten Industrieprojekten in der Region:** Koordination mit Transferpartnern und Vernetzung durch Meetings mit Vertretern insbesondere des Projekts ML4Pro2 in it's OWL (Okt/Nov/Dez 2019) sowie mehrere Treffen mit Vertretern von Unternehmen fanden statt.

## AB2: Begleitprojekte – APPLICATION.ML (Leitung: FH Bielefeld)

In diesem Arbeitsbereich wurde die industrielle Umsetzung von ML-Forschungsergebnissen in den Handlungsfeldern (H1)-(H6) untersucht und realisiert. Zusammen mit Unternehmen der Region wurden exemplarische Modellierungsstrategien entworfen und so die breite Einsetzbarkeit des ML für unterschiedlichste Handlungsfelder demonstriert. Der Transfer in die Unternehmen erfolgte in Form von Beratungsdienstleistungen. Modellierungsbeispiele hielten als Blaupause Einzug in die Plattform FIT.ML. Dabei wurden neben komplexen Modellierungen auch Beispiele dokumentiert, in denen einfache klassische Modellierung (etwa lineare Modelle) ausreichen. Es wurden folgende Ergebnisse erzielt:

**Begleitprojekte.** Es wurden eine Reihe von Begleitprojekten durchgeführt, die durch neue Entwicklungen im Bereich ML gelöst wurden und deren Erprobung und Schärfung in konkreten Anwendungsbereichen realisiert wurden. Dabei sind in den Begleitprojekten praktische Daten durch Anwendungspartner (etwa Industrie) oder entsprechend komplexe Benchmarks gegeben. Die Begleitprojekte adressieren dabei dezidiert sechs im Projekt adressierte Handlungsfelder, die für KMU hoch relevant sind: **H1.** Predictive Maintenance und Condition Monitoring, **H2.** Lernende Assistenzsysteme, **H3.** Kognitives Plug and Work, **H4.** Kognitive Optimierung, **H5.** Kognitives Qualitätsmanagement und **H6.** ML in der Evolution von IKT Systemen. Ziel der Begleitprojekte war dabei je auch ein Beitrag zur ML-Toolbox im Sinn eines Modellierungsbeispiels. In einigen Fällen, in denen die spezifische Anwendung Gegenstand von Geheimhaltungsvereinbarungen war, wurde die jeweilige Darstellung des Ergebnisses durch eine Abstraktion des Falles ermöglicht.

**Begleitprojekt: Kontrafaktische Erklärung zur Interpretation Automatisierter Kreditvergabe (Universität Bielefeld)** Immer mehr Unternehmen setzen ML-Verfahren ein, um Vorhersagen zu treffen und Prozesse zu automatisieren. Durch ihren Black-Box Charakter sind viele Verfahren des maschinellen Lernens jedoch nicht ad-hoc interpretierbar. D.h., die Gründe, aus denen eine bestimmte Vorhersage getroffen wird, bleiben dem Anwender verborgen. Die fehlende Nachvollziehbarkeit automatisierter Entscheidungen macht es schwer, zu erkennen, ob sich ein ML-Systeme verhält, wie beabsichtigt, oder ob es Probleme wie z.B. mangelnde Fairness gibt. Zudem räumt die EU-Datenschutzverordnung jedem Menschen das Recht auf Erklärung automatisierter Entscheidungen ein. Im Zentrum dieses Begleitprojekts stand die Entwicklung und Testung von Erklär-Verfahren zur Generierung kontrafaktischer Erklärungen für ML-Modelle.

Kontrafaktische Erklärungen sind post-hoc Erklärungen, die anzeigen, was in der Vergangenheit anders hätte sein müssen, um den aktuellen Ist-Zustand zu verändern. Im Zuge des Projekts wurde eine Beispielimplementation realisiert<sup>2</sup>, die auf der an der Universität Bielefeld entwickelten Toolbox 'Counterfactuals for Explaining Machine Learning models' (CEML)<sup>3</sup> aufbaut. Im Rahmen des Projekts **ITS.ML** wurde unter anderem auch eine dedizierte Evaluationsumgebung für Erklärungen geschaffen [KAH22b], die den Effekt in einer generellen und allgemeinverständlichen Versuchsumgebung anhand des Erfolgs der mit der KI interagierenden Person evaluiert, und verschiedene Arten von Counterfactual Explanations experimentell verglichen [KAH22a]. Diese basiert auf einem Runden-basierten Spiel, in dem es darum geht, 'Aliens' (d.h. Entitäten mit unbekanntem und hier durch ein KI Modell generierten Verhaltens) zu füttern. Das Ziel ist, Wachstum der Herde zu erreichen; dieses kann quantitativ evaluiert werden. Dabei agieren Personen je nach Versuchsbedingung mit spezifischen Erklärungen des zugrundeliegenden KI-Modells.

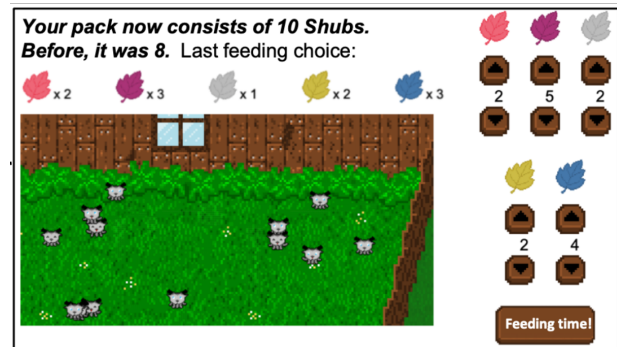


Abbildung 3: *Evaluationsumgebung für Erklärungen von KI in Form eines 'serious game'.*  
Quelle: Universität Bielefeld/AG ML

**Relevante ITS-Handlungsfelder:** Kognitives Qualitätsmanagement; Interpretierbarkeit von Modellen

**Begleitprojekt: Lernen auf Basis von Manipulations-Primitiv Netzen für die Roboterbasierte Montage (Universität Bielefeld)** Die roboterbasierte Automatisierung von Montageprozessen für individualisierte Fertigung ist ein herausforderndes Problem. Insbesondere kontaktreiche Interaktionen ist mit klassischen Methoden aufwändig zu spezifizieren und manuelle Optimierung ist notwendig, um eine robuste Ausführung zu erreichen, die die Anforderungen der Praxis erfüllt. Auf Reinforcement-Lernen (RL) basierte Methoden sind eine vielversprechende Lösung, aber das Lernen von Grund auf erfordert in der Regel eine große Anzahl von Trainingsdaten. Daher ist die Einbeziehung von Vorwissen ein Schlüssel dazu, lernbasierten Methoden in der Praxis umsetzbar zu machen. In der Industrie gibt es oft den Anwendungsfall, dass Komponenten und deren Pose mit Hilfe von Kamertechnik erkannt werden und diese anschließend montiert werden sollen, um die Produktion zu flexibilisieren. Dabei sind Komponenten etwa in ihren Abmessungen




Abbildung 4: *Forschungsszenario für individualisierte Fertigung.* Quelle: Universität Bielefeld/CoR-Lab

<sup>2</sup><https://its-ml.de/index.php/credit-score-counterfactuals/>

<sup>3</sup><https://github.com/andreArtelt/ceml>

variabel und etwaig nicht a priori genau spezifiziert. Für präzise Montageprozesse, die eine hohe Genauigkeit erfordern, müssen Positionsunsicherheiten aufgrund von Fehlern bei der Erkennung der Posen kompensiert werden. Dieses Begleitprojekt entwickelte einen Grey-Box-Learning Ansatz, der es ermöglicht, Vorwissen von Prozessexperten mit lernbasierten Methoden zu kombinieren. Der Ansatz wurde im CoR-LaB Transferlabor auf einem Industrieroboter realisiert und evaluiert. Ein Video, sowie die dezidierte Beschreibung dieses Anwendungsfalls ist auf der Plattform [FIT.ML](#) verfügbar.<sup>4</sup> Im Rahmen des Projekts wurde die neu entwickelte Methode in internationalen Tagungen publiziert [[BW20](#); [BW21](#)]. Mit der Hilfe dieser ML-Ansätze können Montageprozesse flexibler gestaltet und deren Programmierung vereinfacht werden. Das Training macht durch den Einsatz von Vorwissen deutlich weniger Trainingsdaten notwendig als beim Lernen von Grund auf.

**Relevante ITS-Handlungsfelder:** Lernen mit Vorwissen; Eingebettetes Lernen

**Begleitprojekt: Transferlernen für Handprothesen im Alltagseinsatz (Universität Bielefeld)**

Intelligente nicht-invasive Prothesensteuerung kann auf der Messung von Muskelsignalen an der Hautoberfläche basieren. Spezifische Signalmuster, die bestimmten Armbewegungen entsprechen, werden gelernt und dienen zur Steuerung. Dabei ist als ‘Steuerung’ die Einteilung in die beabsichtigte grobe Bewegung zu verstehen, die dann als Bewegungsablauf vor-kodiert ist. Dieses reduziert das Problem im Kern auf ein Klassifikationsproblem von Signalen zu Aktivitäten (etwa Öffnen / Schließen der Hand). Ein Problem im laufenden Betrieb, welches hier spezifisch adressiert wurde, ist Folgendes: Sensorverschiebungen, die besonders beim An- und Absetzen von Prothesen auftreten können, führen zu Veränderungen der gemessenen Signalmuster. Dies stört eine zuverlässige Steuerung. Ziel dieses Begleitprojekts war die robuste Steuerung von Prothesen im Alltagseinsatz, insbesondere in Bezug auf Sensorverschiebungen. In diesem Projekt wurde eine auf Vorwissen basierende Strategie zum Daten-effizienten Transferlernen modelliert, welche auf einem Prototyp-basierten Ansatz und einer spezifischen Problem-spezifischen adaptierten Metrik basiert. Aufgrund der Relevanz von Ansätzen des Transferlernens, um Modelle unter sich gegebenenfalls ändernden Anforderungen effizient anpassen zu können, wurde hier eine Beispielimplementation zur Verfügung gestellt.<sup>5</sup> Die im Projekt verwandten Daten wurden in diesem Projekt von Anwendungspartnern im Bereich der Medizin zur Verfügung gestellt, siehe etwa die gemeinsame Publikation [[Paa+17](#)].



Abbildung 5: *Beispiel einer Steuerung durch individualisierte KI Modelle. Quelle: Universität Bielefeld*

**Relevante ITS-Handlungsfelder:** Lernende Assistenzsysteme, Datengetriebene Optimierung, Lernen auf Datenströmen, Lernen mit Vorwissen, Eingebettetes Lernen

<sup>4</sup><https://its-ml.de/index.php/roboterbasierte-montage/>

<sup>5</sup>[https://its-ml.de/index.php/transfer\\_learning\\_emg/](https://its-ml.de/index.php/transfer_learning_emg/)

**Begleitprojekt: *Metriklernen zur Erklärung eines kontinuierlich lernenden Ansatz (Universität Bielefeld)*** Kontinuierliches Lernen auf Datenströmen stellt eine große Herausforderung dar, da die Stationarität der Datenverteilung – eine grundlegende Annahme des klassischen ML – verletzt sein kann. Drift und sich ändernde Verteilungen können durch unterschiedliche Faktoren induziert sein, etwa alternde Sensoren oder auch sich ändernde Nutzerpräferenzen. Aufgrund der großen Relevanz dieser Thematik wurden verschiedene Algorithmen vorgeschlagen, die mit solchen Situationen umgehen können, und diese sind in entsprechenden Toolboxes für die Allgemeinheit verfügbar. Eine solche Toolbox ist Python-Toolbox River [Mon+21], in der unter anderem das an der Universität Bielefeld entwickelte Lernverfahren SAM-kNN als eine Methode integriert ist [LHW16]. Dieses baut auf einer nächste-Nachbar Klassifikation zusammen mit intelligenten Speicherstrukturen und Regeln auf, welche Daten für den Klassifikator im Detail verwendet werden. Kritisch ist dabei die Wahl der Metrik, da sie einen k-NN Klassifikator substantiell beeinflusst und zudem durch eine Gewichtung der Relevanz der einzelnen Merkmale für Interpretierbarkeit des sich ergebenden Modells sorgt. Im Rahmen des Projekts wurden Verfahren vorgeschlagen und evaluiert, die während des Lernens auf Datenströmen auch die Metrik entsprechend adaptieren, sodass einzelne Merkmale sowie deren Korrelation entsprechend ihres Einflusses gewichtet werden. Dieses erhöht die Güte und erlaubt gleichzeitig eine Einsicht in die Wichtigkeit der einzelnen Merkmale, d.h. eine bessere Interpretierbarkeit der Ergebnisse. Es wurde hier im Rahmen des Projekts Code bereitgestellt<sup>6</sup> sowie eine Publikation eingereicht [KSH22].

**Relevante ITS-Handlungsfelder:** Lernen auf Datenströmen; Interpretierbarkeit

**Begleitprojekt: *Reject Optionen für Partikelfilter basiertes Objekttracking in medizinischen Anwendungen (Universität Bielefeld)*** Intelligente Unterstützungssysteme werden auch im Bereich der Medizin immer relevanter. Dabei spielt der Aspekt der Verlässlichkeit eine besondere Rolle. In Kooperation mit Wissenschaftlern der RWTH Aachen bzw. der Universitätsklinik Aachen wurde in diesem Begleitprojekt ein Ansatz untersucht, der Objekttracking bei Operationen mit Hilfe von Kamerabildern verfolgt. Im vorliegenden Fall wurde dies mit dem Ziel verfolgt, um eine für die Operation nötige Maske auf ein Objekt kontinuierlich zu projizieren. Der vorliegende Ansatz verfolgt dabei das Objekt mit Hilfe von Partikelfiltern, und funktioniert in der Regel gut. Allerdings geht das Tracking bei Deplatzierung oder Verdeckung gegebenenfalls verloren. Ziel des Begleitprojekts war es daher, diesen Ansatz mit einer expliziten 'Reject-Option' auszustatten, d.h. der Fähigkeit, Situationen zu identifizieren, in denen das Objekt verloren wurde. Obschon Partikelfilter explizite Wahrscheinlichkeiten berechnen, sind diese ungeeignet, um zuverlässig ein Reject anzuzeigen. Das Problem wurde daher als explizites Lernproblem aufgefasst, und einerseits mit Hilfe einer Regression (Abstand von der Zielposition) bzw. einer Schar von Klassifikatoren (Abstand ist größer als eine gewählte Schwelle) adressiert. Es zeigen sich erheblich bessere Ergebnisse hinsichtlich der Zuverlässigkeit. Zudem kann das Problem mit nur wenigen Klassifikatoren die gesamte Front für verschiedene Schwellen gut abdecken. Das Er-

<sup>6</sup><https://its-ml.de/index.php/metric-learning-with-sam-for-explaining-feature-drift/>

gebnis wurde in [Kum+21] publiziert, und weitere Informationen sind auf der Plattform FIT.ML verfügbar.<sup>7</sup>

**Relevante ITS-Handlungsfelder:** Lernen mit Datenströmen; Lernende Assistenzsysteme

**Begleitprojekt: Überwachtes Transferlernen zur Eventdetektion in Videodaten am Beispiel von Fußballübertragungen (Universität Bielefeld)** Die manuelle Markierung von Ereignissen in Videos ist extrem zeitaufwändig. Eine vollständige Markierung eines Fußballspiels erfordert zum Beispiel oft 20 Stunden oder mehr. Das Begleitprojekt "Überwachtes Transferlernen zur Eventdetektion in Videodaten am Beispiel von Fußballübertragungen", widmete sich dem automatischen Erkennen von Sportevents in Videodaten mit Hilfe Neuronaler Netze. Es wurden hierbei verschiedene, zum Teil rekurrente tiefe Netzarchitekturen verglichen und evaluiert. Dabei wurden Zeitstempel relevanter Events extrahiert, indem Interaktionsmuster zwischen Spieler und dem Ball gelernt wurden. Das Projekt fand in Kooperation mit einem Unternehmen statt, welches die Daten zur Verfügung stellte. Mehr Informationen sind auf der Plattform FIT.ML verfügbar.<sup>8</sup>

**Relevante ITS-Handlungsfelder:** Kognitive Optimierung

**Begleitprojekt: Intelligente Datenanalyse zur Vorhersage des Verkehrsaufkommens (Universität Bielefeld)** Staus und erhöhtes Verkehrsaufkommen werden ein immer größeres Problem in Städten. Moderne Kreuzungsanlagen sind mit Detektoren ausgestattet, und liefern so Daten zum Verkehrsfluss. Diese werden schon heute erhoben, aber nicht immer intelligent genutzt. Das Projekt "Intelligente Datenanalyse zur Vorhersage des Verkehrsaufkommens" widmete sich der Frage, wie mit den vorhandenen Daten Systeme entwickelt werden können, um Stau zu reduzieren. Eine grundsätzliche Herausforderung ist die Detektion von sich bildenden Staus sowie die Prognose des zu erwartenden Verkehrsaufkommens auf der Basis von historischen Daten an einzelnen Kreuzungen. Im Projekt wurden reale vom Amt für Verkehr der Stadt Bielefeld zur Verfügung gestellte Daten mehrere Kreuzungen analysiert. Es wurde anhand von im Netz verfügbarer Zusatzinformation ein Labeling vorgenommen und anhand mehrerer klassischer als auch moderner KI Modelle getestet, inwieweit eine Prognose an einzelnen Kreuzungen möglich ist und inwieweit die Modelle sich zwischen verschiedenen Orten einfach übertragen lassen. Mehr Informationen sind auf der Plattform FIT.ML verfügbar.<sup>9</sup>

**Relevante ITS-Handlungsfelder:** Lernende Assistenzsysteme; Kognitive Optimierung; Kognitives Qualitätsmanagement; ML in der Evolution von IKT Systemen

<sup>7</sup><https://its-ml.de/index.php/partikelfilterbasiertesobjekttracking/>

<sup>8</sup><https://its-ml.de/index.php/transferlernen-sportdetekt/>

<sup>9</sup><https://its-ml.de/index.php/traffic-congestion/>

**Begleitprojekt: *ML-gestützte, hybride Modellbildung im Bereich Biosignale für die Ansteuerung von Exoskeletten (Fachhochschule Bielefeld)*** Der menschliche Stütz- und Bewegungsapparat wird durch eine willentlich ansteuerbare Muskulatur aktuiert. Bestimmte Regionen im Rückenmark, sog. Motorsäulen, beinhalten periphere neuronale Strukturen zur Ansteuerung der Muskeln. In den Motorsäulen verschalten Ensembles von Motoneuronen mit ihren Ausgängen (Axone) auf die Muskelfasern (Innervation) und steuern diese an. Dies geschieht über bioelektrische Signale, sog. Aktionspotenziale, die die Axone hinabwandern, biochemisch auf die Muskelfaser (Innervationspunkte) übertragen werden und dort wiederum als Aktionspotenziale die Muskelfasern bis zu den Sehnenansätzen entlangwandern. Die Aktionspotenziale sorgen dabei für eine Freisetzung von Kalzium-Ionen in die Feinstrukturen des Muskels und bewirken so die eigentliche Kontraktion. Dabei prägen die Aktionspotenziale elektromagnetische Felder aus und können so an der Hautoberfläche oberhalb von Muskeln über Hautelektroden als Oberflächenpotenziale (surface electromyograms, sEMG) gemessen werden. Ziel des Projekts war eine Optimierung der Modelle, die in solchen Exoskeletten die gemessenen Daten in zur Steuerung benutzbare Information überführen. Hierbei sind die biologischen (biochemischen, biomechanischen, bioelektrischen) Teilkomponenten der beschriebenen Signalkaskade bekannt und wurden im Zuge dieses Begleitprojekts mathematisch modelliert und zu einem biomechanischen Gesamtmodell für eine Gliedmaßenbewegung zusammengeführt. Sie repräsentieren das bisher meist nicht genutzte biologische Domänenwissen. Jedoch spielen für diese Art der Modellierung – etwa für das Ellenbogensystem des Menschen – etwa 30 Parameter eine Rolle, die über Optimierungsverfahren mit physiologisch plausiblen Nebenbedingungen eingestellt wurden [Gri+22; Mec+22a]. Als Grundlage für die Optimierung wurden Daten von insgesamt etwa 30 Proband:innen in einer Bewegungsstudie aus drei Messkampagnen erhoben und in einer Datenpublikation veröffentlicht [Mec+22b]. Die genannten maschinell optimierten Modelle dienen generell als Referenz für weitere Modellierungsschritte. Aufbauend auf diesen Referenzen wurden für die Bewegungsvorhersage umfangreiche Feature-Sets identifiziert und getestet, die auf Basis von sEMGs berechnet und die für eine ausschließlich ML-basierte, datengetriebene Bewegungsvorhersage verwendet werden können [Les+22]. Die Kombination aus Domänenansatz und datengetriebenem Ansatz stellt die Grundlage für eine hybride Modellbildung bzw. Greybox-Lernen dar. Für die genannten Verfahren existieren entsprechende Toolchains und Implementierungen, die beispielhaft in einem Jupyternotebook zur Verfügung gestellt wurden (siehe AP3.1




Abbildung 6: *Greybox Modellierung der Informationsverarbeitung in intelligenten Orthesen. Quelle: Fachhochschule Bielefeld/AG Biomechatronik*

Abbildung 6: *Greybox Modellierung der Informationsverarbeitung in intelligenten Orthesen. Quelle: Fachhochschule Bielefeld/AG Biomechatronik*

Umsetzungsprojekte). Die hybride Modellbildung für eine Bewegungsvorhersage wurde außerdem um die Betrachtung sog. Motor Skills in unterschiedlichen Aktionsszenarien ergänzt [Van+22]. Dies rundet die ML-basierte Vorhersage von Gliedmaßenbewegungen und die ML-basierte Unterstützung von Handlungen im Bereich der Assistenzsysteme ab. Weitere Informationen sind auf der Plattform FIT.ML verfügbar.<sup>10</sup>

**Relevante ITS-Handlungsfelder:** Lernende Assistenzsysteme; Datengetriebene Optimierung; Lernen mit Vorwissen; Hybride Modelle (Greybox-Lernen); Interpretierbarkeit

**Begleitprojekt: ML-gestützte Signalverarbeitung höherdimensionaler Sensordaten (Fachhochschule Bielefeld)**

Lichtmikroskopische Bilder unterliegen hinsichtlich ihrer Vergrößerung und Auflösung prinzipiellen Einschränkungen. Die physikalisch mögliche Auflösung beispielsweise ist durch die Wellenlänge des Lichts (Abbe-Limit) oder durch Beugungseffekte begrenzt. Die Auflösung kann jedoch verbessert werden, wenn die Probe mit strukturiertem Licht (Super-Resolution Structured-Light-Illumination) beleuchtet und ein höher aufgelöstes Bild daraus errechnet wird (sog. SR-SIM). Zur Abbildung lebender Zellen können nur kurze Belichtungszeiten verwendet werden, um die Probe nicht durch die Einbringung von zu viel Energie zu beschädigen. Dies führt wiederum zu geringen Lichtintensitäten auf dem verwendeten Bildsensor und erhöht das Bildrauschen, das zu einem verschlechterten Signal-zu-Rausch-Verhältnis führt.

Ziel des Projekts war der Entwurf von Methoden des maschinellen Lernens, insbesondere des tiefen Lernens, um hier eine qualitativ hochwertige Rekonstruktion der zugrundeliegenden Informationen zu adressieren. Zur Rauschunterdrückung wurden im vorliegenden Teilprojekt zunächst zwei ML-Modellverfahren (RED-NET und U-NET) implementiert und auf vorhandene Bilddatensätze des Kooperationspartners angewendet (Univer-




Abbildung 7: Beispielhafte Ergebnisse einer Signalrekonstruktion durch tiefes Lernen. Quelle: Fachhochschule Bielefeld/CfADS

sität Bielefeld, Fak. für Physik, AG Biomolekulare Photonik). In der Folge konnte nachgewiesen werden, dass mit Hilfe angepasster tiefer neuronaler Netze (SR-REDSIM, RED-fairSIM) eine stabile Rekonstruktion der mit SR-SIM aufgenommenen verrauschten Bilddaten erzielt werden kann [Sha+21]. Die Robustheit dieser Methoden wurde umfangreich gegenüber Referenzverfahren getestet. Für die genannten Verfahren existieren entsprechende Toolchains und Implementierungen, die beispielhaft in einem Jupyternotebook zur Verfügung gestellt wurden (siehe AP3.1

<sup>10</sup><https://its-ml.de/index.php/ml-based-torque-adjustment/>

Umsetzungsprojekte). Für das Training der tiefen neuronalen Netze hat insbesondere die Formulierung der Loss-Funktion einen zentralen Einfluss auf die Qualität der Ergebnisse. Hierzu wurde eine umfangreiche Untersuchung mit eigens für das Problem der Verbesserung des Signal-zu-Rausch-Verhältnisses neu entwickelten Loss-Funktionen durchgeführt. Darüber hinaus wurde erforscht, wie das Signal-zu-Rausch-Verhältnis durch Veränderungen der Bilddatenrepräsentation (z.B. Frequenzraum) und durch neuartige Architekturen der tiefen neuronalen Netze weiter erhöht werden kann [Sha+22]. Weitere Informationen sind auf der Plattform [FIT.ML](#) verfügbar.<sup>11</sup>

**Relevante ITS-Handlungsfelder:** Datengetriebene Optimierung; Datengetriebenes Qualitätsmanagement; Interpretierbarkeit

**Begleitprojekt: Vorausschauende Wartung: Systemgesundheit eines Cyber-Physikalischen Produktionssystems (Technische Hochschule Ostwestfalen-Lippe)** Viele Cyber-Physikalische Produktionssysteme (Cyber-Physical Production System, CPPS) enthalten unterschiedliche Komponenten, die mit der Zeit verschleiben. Eine nicht rechtzeitig ausgetauschte Komponente führt dazu, dass unnötige Ausfallzeiten aufgrund von Reparaturen entstehen oder die Produktion/Maschine ausfällt. Insbesondere, wenn die Maschine unregelmäßig gewartet wird oder auswechselbare Teile mit leicht unterschiedlichen Spezifikationen verwendet werden, kann die manuelle Modellierung des Verschleißes mühsam und zeitaufwendig sein.

In diesem Modellierungsbeispiel gruppiert eine Maschine lose Flaschen oder Dosen in festgelegten Packungsgrößen. Ein wichtiger Bestandteil der Maschine ist die Schneidevorrichtung. Das Messer kann während des Betriebs nicht visuell inspiziert werden, da es von einem Metallgehäuse umschlossen ist und eine hohe Rotationsgeschwindigkeit aufweist. Das Ziel war es, basierend auf einer kontinuierlichen Überwachung der Schneidklingen die Zuverlässigkeit der Maschine zu erhöhen und unerwartete Ausfallzeiten, die durch fehlgeschlagene Schnitte verursacht werden, zu reduzieren. Die ML-Lösung wurde auf Grundlage eines Autoencoders implementiert, um Anomalien zu erkennen oder den Verschleiß der Komponente anzuzeigen. Die Beispielimplementierung dieser Lösung wurde zusätzlich als Jupyter Notebooks auf dem Github-Account des ITS.ML Projekts zur Verfügung gestellt. Die verwendete Autoencoderarchitektur wurden im Rahmen des Projekts publiziert [EHN19]. Weitere Informationen und ein Link zum Code sind auf der Plattform [FIT.ML](#) publiziert.<sup>12</sup>

**Relevante ITS-Handlungsfelder:** Predictive Maintenance; Condition Monitoring

**Begleitprojekt: Intelligente Unterstützung bei der Medikamentendosierung von Parkinson-Patienten: PD Assist (Technische Hochschule Ostwestfalen-Lippe)** Das idiopathische Parkinson-Syndrom ist eine neurodegenerative Erkrankung, die typischerweise zu einer Verlangsamung der Bewegungen (Bradykinese), einer vermehrten Muskelsteifigkeit (Rigor) und zu

<sup>11</sup><https://its-ml.de/index.php/dl-denoising-reconstruction/>

<sup>12</sup><https://its-ml.de/index.php/pdm-systemgesundheit/>

Zittern der Extremitäten (Tremor) führt. mit Hilfe von tragbaren elektronischen Geräten wie Smart Watches und Smartphones lassen sich Bewegungsanalysen im Alltag erfassen und auch Störungen physiologischer Bewegungsabläufe erkennen. Bisherige Studien beschäftigen sich hauptsächlich damit, die Symptome und deren Vorkommen über Smartphones und Wearables zu überwachen. Um die Betreuung von Patienten und Patientinnen nachhaltig verbessern zu können, muss das häusliche Umfeld und somit der Alltag mehr in Studien mit einbezogen werden.

Je patientenzentrierter ein System ist, desto höher ist auch der Grad der Betreuung, die ein einzelner Patient\*in erhält. Ziel des Projekts war es, entsprechende intelligente Services eingebettet in den Alltag als Smartphone-App zu realisieren. Das AME „Intelligente Unterstützung bei der Medikamentendosierung von Parkinson-Patienten: PD Assist“ ordnet sich in den Handlungsbe- reich (H5) ein. In diesem AME wurde basierend auf Daten, die im häuslichen Umfeld aufgenommen wurden, eine Vorhersage über den Medikationszustand von Patienten und Patientinnen getroffen. Die ML-Lösung wurde auf Grundlage der App PD Assist und der öffentlichen Parkinson Studie mPower entwickelt. Die Datenanalyse fand dabei mit unterschiedlichen Modellen aus dem Bereich der KI statt. Ein Schwerpunkt war dabei, die Modelle so zu gestalten, dass sie problemlos auf einem Smartphone realisiert werden können. Weitere Informationen sind auf der Plattform [FIT.ML](#) erhältlich.<sup>13</sup>



Abbildung 8: Intelligente Healthcare-App. Quelle: TH OWL/inIT

**Relevante ITS-Handlungsfelder:** Lernende Assistenzsysteme, eingebettete Systeme

**Begleitprojekt: Intervall-basierte interpretierbare Entscheidungsbäume für die Zeitreihenklassifikation (Technische Hochschule Ostwestfalen-Lippe)** Im industriellen Umfeld sind verifizierbare ML-Verfahren von großer Bedeutung. Einen wichtigen Beitrag zur Verifikation leistet die Interpretierbarkeit des Modells, um dessen Entscheidungen beurteilen zu können und einen „Clever Hans“-Effekt auszuschließen. Daher wurde im Rahmen dieses Begleitprojekts an einem Intervall-basierten interpretierbaren Entscheidungsbaum für die Zeitreihenklassifikation gearbeitet. Die Zeitreihenklassifikation ist im Handlungsfeld (H1) Predictive Maintenance und Condition Monitoring ein wichtiger Anwendungsfall, da Industriemaschinen in der Regel Sensordaten in Form von Zeitreihen liefern, die den Zustand der Maschine repräsentieren und von einer zustandsgetriebenen Wartung profitieren können. Es handelt sich hierbei um eine datengetriebene Optimierung und der Fokus liegt auf der Interpretierbarkeit der Modelle. Um ein robustes und industrietaugliches ML-Verfahren zu entwickeln, wurde ein inhärent interpretierbarer Ansatz verfolgt. Inhärent interpretierbare Modelle liefern durch ihre logische Struktur die Erklärung für die entsprechenden Entscheidungen zum Zeitpunkt der Vorhersage gleich mit.

<sup>13</sup><https://its-ml.de/index.php/pd-assist/>

Im Gegensatz dazu gibt es eine Vielzahl von Methoden die ein Modell post-hoc erklären. Diese Art der Erklärung ist fehleranfälliger, weil nicht nur das Modell selbst falsch interpretiert werden kann, sondern auch die Methode zur Erklärung fehlerhaft sein kann. Spezifisch wurden hier intervall-basierte Entscheidungsbäume entwickelt und anhand von realen Beispieldaten getestet, die flexibel mit Zeitreihen und aus diesen auf der Basis von Intervallen inferierten Merkmalen umgehen können. Die Ergebnisse wurden im Rahmen des Projekts publiziert [SL21], außerdem sind weitere Information auf der Plattform [FIT.ML](#) verfügbar.<sup>14</sup>




Abbildung 9: *Beispiel einer interpretierbaren Klassifikation.* Quelle: TH OWL/inIT

**Relevante ITS-Handlungsfelder:** Predictive Maintenance und Condition Monitoring; Interpretierbarkeit von Modellen

**Begleitprojekt: *Entwicklung von Methoden zum Entwurf von Fusionsarchitekturen (Technische Hochschule Ostwestfalen-Lippe)*** Der Einsatz von Informationsfusion verfolgt das Ziel, maschinelles Lernen in dynamischen Umgebungen verfügbar zu machen. Durch die Fusion teilreduzanter Informationen (Sensordaten, Merkmale) werden Degradationseffekte in ihrem Einfluss auf die Performance von ML-Methoden abgemildert. Dazu werden Fusionsarchitekturen hinsichtlich der Redundanz von Informationsquellen strukturiert. Insbesondere in Anwendungsfällen, in denen wenig Trainingsdaten zur Verfügung stehen (Scarce Data, Small Data), sind hierfür Methoden des Stands der Technik häufig wenig praktikabel. Im Rahmen des Projekts wurden Methoden auf Basis der Möglichkeitstheorie (Possibility Theory) entwickelt, die auch bei wenig Trainingsdaten in der Lage sind, Redundanzen zu bewerten und Architekturen zu entwerfen [HL19; HL20; HL21].

**Relevante ITS-Handlungsfelder:** Predictive Maintenance und Condition Monitoring; Kognitives Plug and Work; Kognitives Qualitätsmanagement; Lernen auf Datenströmen; Interpretierbarkeit von Modellen

**Begleitprojekt: *Klassifizierung von Fehlern in Cyber-Physical Systems mit komplexwertigen neuronalen Netzen (Technische Hochschule Ostwestfalen-Lippe)*** Komplexwertige Neuronale Netze haben aufgrund ihrer mehrwertigen Aktivierungsfunktion eine hohe Effizienz und werden für verschiedene Klassifizierungs-, Vorhersage- und Bildfilterungsprobleme angewendet. In einem im Projekt verfolgten Ansatz wurde ein spezieller Typ komplexer neuronaler Netze (Multilayer Feedforward Neural Networks based on Multi-valued Neurons, MLMVN) auf ein Klassifizierungsproblem im Kontext Cyber-physischer Produktionssysteme (CPPS) angewendet. Das Ziel war die Klassifizierung einzelner Zustände eines Motors (einen fehlerfreien

<sup>14</sup><https://its-ml.de/index.php/ibit/>

Zustand und 10 verschiedene Fehlerzustände) mit Hilfe von MLMVNs auf einem Referenzdatensatz. Für das Mehrklassen-Klassifizierungsproblem wurde eine Bewertung ausgewählter reellwertiger und komplexwertiger neuronaler Netze in Betracht gezogen. Ein Ergebnis ist, dass MLMVN in Bezug auf die Genauigkeit ähnlich konstruierte reellwertige neuronale Netze auf dem Referenzdatensatz übertreffen. Somit könnte die hohe Effizienz solcher Netze bei der lokalen Verarbeitung von Daten von Vorteil sein, um die Robustheit und Leistung zu verbessern und den Energieverbrauch des verwendeten Systems zu senken. Die Arbeiten führten unter anderem zu zwei Publikationen im Projekt [PL21; Kna22].

**Relevante ITS-Handlungsfelder:** Predictive Maintenance und Condition Monitoring; ML in der Evolution von IKT Systemen

**Begleitprojekt: Restlebenszeitvorhersage mittels maschinellen Lernens (Universität Paderborn)**

Die frühzeitige Vorhersage des Ausfall eines kritischen Bauteils wie ein Flugzeugtriebwerk kann eine unerwartete Zwischenlandung vermeiden oder gar einen Absturz verhindern. Eine notwendige Wartung kann entsprechend geplant, Ersatzteile zeitlich passend bestellt und Wartungspersonal eingeplant werden. Dazu wurden bestehende Daten eines simulierten Flugzeugtriebwerks verwendet, die durch Simulation verschiedener Sensoren an unterschiedlichen Stellen des Flugzeugtriebwerks generiert wurden. Aus diesen Daten ist der aktuelle Zustand des simulierten Triebwerks ersichtlich, und sie können zur Herleitung der verbleibenden Restlebenszeit verwendet werden. Da der personelle Aufwand zur Entwicklung eines passenden maschinellen Lernverfahrens oft recht hoch und die dazu benötigt Expertise häufig rar ist, wurde in diesem Begleitprojekt ein Verfahren entwickelt, das automatisch KI/ML-Methoden kombiniert und konfiguriert (AutoML). Eine vom AutoML-Verfahren generierte Lösung besteht auf der einen Seite aus Verfahren zur Merkmalsextraktion aus Zeitreihendaten, und auf der anderen Seite aus einem Regressionsverfahren, das für die Vorhersage der Restlebenszeit verantwortlich ist. Die Güte einer vom AutoML Verfahren gefundenen ML-Lösung wird hierbei anhand einer asymmetrischen Fehlerfunktion bestimmt. Diese bestraft Unterschätzungen der Restlebenszeit weniger hart als Überschätzungen, wodurch vorwiegend ML-Lösungen bevorzugt wurden, die tendenziell unterstatt überschätzen. Zuerst wurde hierzu ein bestehendes AutoML Verfahren adaptiert, um den neuen Herausforderungen der Zeitreihendaten gerecht zu werden. Dieses Verfahren basierte auf hierarchischer Auftragsnetz-Planung, bei der die Grundidee darin besteht, Aufgaben hierarchisch in immer kleinere Teilaufgaben zu unterteilen, bis eine ausführbare Kette von Methoden, die diese Aufgaben lösen können, vorliegt. Dabei hat sich herausgestellt, dass dieses Verfahren für die gegebenen Problemstellungen aufgrund seiner Struktur und der langen Evaluationszei-

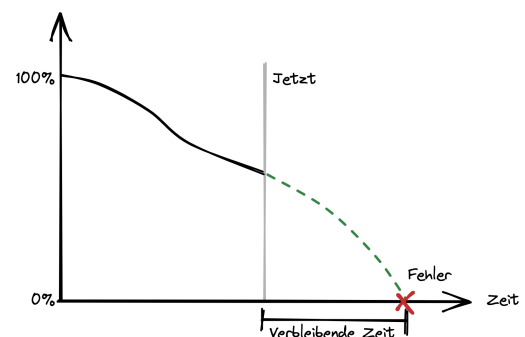


Abbildung 10: Schematische Darstellung einer Restlebenszeitvorhersage; Quelle: Universität Paderborn/AG ISML

ten einzelner Kandidaten eher ungeeignet ist. Daraufhin ist die Idee entstanden, eine passende ML-Lösung per kooperativer Ko-Evolution zu suchen, wodurch sowohl die Güte der Kombinationen als auch die Güte der Merkmalsextraktion, sowohl einzeln als auch gemeinsam, bewertet werden. Dies beeinflusst maßgeblich, welche Kandidaten im weiteren Verlauf betrachtet wurden. Die spätere Evaluation hat ergeben, dass dieses Auto-ML-Verfahren den Herausforderungen der Zeitreihendaten deutlich besser gewachsen ist. Die Ergebnisse wurden im Rahmen des Projekts publiziert [Tor+21a; Tor+20], außerdem sind weitere Informationen auf der Plattform [FIT.ML](#) verfügbar.<sup>15</sup>

**Relevante ITS-Handlungsfelder:** Predictive Maintenance und Condition Monitoring, Lernen auf Datenströmen, Kognitives Plug and Work

**Begleitprojekt: *Ökologisches automatisiertes maschinelles Lernen (Universität Paderborn)*** Die manuelle Entwicklung passgenauer maschineller Lernverfahren wird immer mehr durch einen automatisierten Prozess ersetzt, dem so genannten automatisierten maschinellen Lernen (AutoML). Wie im vorigen Begleitprojekt zur Restlebenszeitvorhersage bereits beschrieben, ist dieser Prozess aufwändig und benötigt daher viel Rechenleistung, was wiederum einen großen ökologischen Fußabdruck verursacht. Dieses Begleitprojekt befasste sich mit verschiedenen Strategien, die den gesamten AutoML Prozess verkürzen oder effizienter gestalten können. Um einen ökologischen Fußabdruck eines AutoML Verfahrens bestimmen zu können, bedarf es zuerst eines angemessenen Messverfahrens. Darauf aufbauend können dann verschiedene Aspekte des AutoML Verfahrens angepasst werden, um den ökologischen Fußabdruck zu reduzieren. Dazu wurden bereits bestehende Strategien analysiert und von einem neuen Blickwinkel betrachtet. Die Evaluation von AutoML Verfahren, das so genannte Benchmarking, und dessen Einfluss auf den ökologischen Fußabdruck wurde thematisiert und damit verbundene bewährte Strategien zusammengetragen. Zudem wurde aufgerufen, diesen transparent bei Publikationen anzugeben und vermehrt auf deren ökologischen Fußabdruck zu achten. Die Ergebnisse wurden im Rahmen des Projekts publiziert [Tor+21b].

**Relevante ITS-Handlungsfelder:** Kognitives Plug and Work

**Begleitprojekt: *Ensemble-basierte Quantifizierung aleatorischer und epistemischer Unsicherheit (Universität Paderborn)*** Methoden des maschinellen Lernens haben sich in den letzten Jahren in vielen Anwendungsgebieten etabliert und stark an praktischer Bedeutung gewonnen. Doch trotz aller Erfolge werden solche Methoden nach wie vor auch mit Skepsis betrachtet, vor allem in sicherheitskritischen Anwendungen, in denen Fehlentscheidungen fatale Folgen haben können. Wichtig für solche Anwendungen ist es, dass ein Lernverfahren sich seiner eigenen Unsicherheit bewusst ist und diese adäquat repräsentieren kann. Generell wird zwischen aleatorischer und epistemischer Unsicherheit unterschieden: Während es sich bei aleatorischer Unsicherheit um Zufälligkeit im engeren Sinn handelt, wird epistemische Unsicherheit

<sup>15</sup><https://its-ml.de/index.php/rul/>

durch einen Mangel an Wissen verursacht. Epistemische Unsicherheit kann durch zusätzliche Information also prinzipiell reduziert werden, während aleatorische Unsicherheit inhärent ist.

In diesem Begleitprojekt wurde die Bildklassifikation im Kontext des autonomen Fahrens betrachtet, die jede Prädiktion mit Information über das jeweilige Ausmaß an Unsicherheit ergänzt. Falsche Vorhersagen können dabei weitreichende Folgen haben. Ein Lernverfahren sollte daher in der Lage sein, die Unsicherheit einer Vorhersage einzuschätzen und entsprechend zu reagieren, z.B. durch die Abgabe der Kontrolle an den menschlichen Nutzer/Experten oder die gezielte Akquise zusätzlicher Daten. Die ML-Lösung wurde auf der Grundlage so genannter Ensemble-Methoden entwickelt. Jedes dieser Modelle ist in der Lage, eine neue Anfrageinstanz probabilistisch zu klassifizieren, also Aussagen über die aleatorische Unsicherheit zu machen. Die grundlegende Idee besteht darin, dass sich der epistemische Anteil der Unsicherheit in der „Diversität“ der einzelnen Vorhersagen manifestiert. Die Güte quantifizierter Unsicherheiten lässt sich nicht einfach bestimmen, vor allem mangels einer (beobachtbaren) „Wahrheit“, also einem korrekten Maß an Unsicherheit. Vorhersagen über die Unsicherheit wurden daher indirekt evaluiert, indem sie für eine bestimmte Aufgabe, wie beispielsweise die Enthaltung (Verweigern einer Vorhersage) eingesetzt wurden. Im Kontext dieser Arbeiten entstandene Publikationen sind [NSH22; SH20]. Außerdem sind weitere Informationen auf der Plattform FIT.ML verfügbar.<sup>16</sup>




Abbildung 11: Schematische Darstellung von epistemischer Unsicherheit (durch einen Mangel an Wissen) und aleatorischer Unsicherheit (Zufälligkeit im engeren Sinn); Quelle: Universität Paderborn/AG ISML

Aussagen über die aleatorische Unsicherheit zu machen. Die grundlegende Idee besteht darin, dass sich der epistemische Anteil der Unsicherheit in der „Diversität“ der einzelnen Vorhersagen manifestiert. Die Güte quantifizierter Unsicherheiten lässt sich nicht einfach bestimmen, vor allem mangels einer (beobachtbaren) „Wahrheit“, also einem korrekten Maß an Unsicherheit. Vorhersagen über die Unsicherheit wurden daher indirekt evaluiert, indem sie für eine bestimmte Aufgabe, wie beispielsweise die Enthaltung (Verweigern einer Vorhersage) eingesetzt wurden. Im Kontext dieser Arbeiten entstandene Publikationen sind [NSH22; SH20]. Außerdem sind weitere Informationen auf der Plattform FIT.ML verfügbar.<sup>16</sup>

**Relevante ITS-Handlungsfelder:** Interpretierbarkeit von Modellen

**Öffentlichkeitsarbeit/Transfer im Rahmen der Begleitprojekte:** Es wurden verschiedene Veranstaltungen realisiert, um einerseits Bedarfe der Anwendungspartner zu erfassen und andererseits die erzielten Ergebnisse publik zu machen. Dazu zählt ein dezidierter Machine Learning Day mit Vertretern aus der Anwendung, insbesondere industrielle Partner, der zusammen mit der IHK Lippe zu Detmold durchgeführt wurde. Hier wurden Konzepte vorgestellt und mit den Teilnehmenden diskutiert, sowie eine in Kollaboration mit dem Verbundprojekt ML4Pro2 (it's OWL) anonyme Umfrage zu den Bedarfen von Anwendungspartnern durchgeführt. Eine Präsentation und Diskussion der Ergebnisse fand auf der virtuellen Hannover Messe in 2020 als Teil der digitalen Innovationsschau Industrial Pioneers OWL statt. Zudem wurde ein Diskussionsforum 'Meet the Experts' in einem digitalen Format angeboten.

**Meilensteine:**

<sup>16</sup><https://its-ml.de/index.php/uncertainty-quant/>

- **M2.1: Machine Learning Innovation Day:** Der ML-Innovation-Day wurde an der Universität Bielefeld am 29.11.2019 mit rund 50 Vertretern aus Firmen in Kooperation mit der IHK Lippe zu Detmold durchgeführt.
- **M2.2: Dokumentation von Begleitprojekten als Blaupause für eine Wissensbasis:** Mit Projektabschluss enthält unsere Wissensbasis auf der Plattform **FIT.ML** mehr als fünfzehn Applied Modelling Examples (AMEs), die Überblick über die oben näher beschriebenen durchgeführten Begleitprojekte geben als auch einige weitere Projekte, deren Vorgehen und Ergebnis für die Wissensbasis formalisiert wurde.

## 2.1 AB3: Umsetzungsprojekte – INNOVATION.ML (Leitung: Technische Hochschule OWL)

Zur Schärfung des Profils von **ITS.ML** und Dissemination der Ergebnisse wurden entlang der ML-Innovationen **I1**. Lernen auf Datenströmen **I2**. Interpretierbarkeit von Modellen **I3**. 24/7 Benchmarking **I4**. Greybox-Lernen **I5**. Eingebettetes Lernen typische Prozessketten realisiert. Diese wurden Anwendern in Form von einfach bedienbaren Jupyter Notebooks zur Verfügung gestellt. Die Prozessketten wurden dabei auf der Basis des im Verbund existenten Expertenwissens zu ML entwickelt und im Rahmen von Beratungsleistungen durch größere, auf technische Anwendungen fokussierende Verbundprojekte, wie z.B. ML4Pro2 im Spitzencluster it's OWL, oder dem Center for Applied Data Science (CfADS) Gütersloh auf ihre Praxistauglichkeit überprüft. Es entstanden so Referenzimplementationen von wichtigen Paradigmen des ML für konkrete Handlungsfelder des ITS, die für Nutzer der IKT aufgrund der Kapselung der ML-Spezifika leicht zugänglich sind.

**Umsetzungsprojekte** Im Folgenden wird die im Rahmen der Umsetzungsprojekte entstandene Open-Source-Software beschrieben. Neben der Kompatibilität mit der Software Suite Scikit-Learn (betreffend ML) bzw. PyTorch (betreffend speziell Deep Learning). bietet die Realisierung als Jupyter-Notebooks den Vorteil, dass die Beschreibung der Verfahren, die Datenauswertung, sowie Code für die eigentlichen ML Schritte nahtlos in einem Dokument präsentiert werden. Damit ist eine sehr eingängige, reproduzierbare und maximal transparente Handhabung gewährleistet. Im Unterschied zu AB2, in dem die Dokumentation der Modellierung durch ML im Vordergrund stand, ging es in AB3 um die genauen Softwarepipelines und praktische Realisierungen. Diese beinhalten neben der Modellierung auch die Validierung und etwaig benötigte generische Datenaufbereitung. Alle hier genannten Projekte wurden als Open-Source-Software in der ML-Plattform **FIT.ML** zur Verfügung gestellt, wobei in jedem Fall auch Beispieldaten zum Test vorhanden sind.

### Lernen auf Datenströmen:

■ *Transferlernen für Handprothesen im Alltagseinsatz:*

[https://its-ml.de/index.php/transfer\\_learning\\_emg/](https://its-ml.de/index.php/transfer_learning_emg/)

Das Notebook bietet ein Beispiel eines Ansatzes zum Transferlernen, welches ein trainiertes Modell anhand möglichst weniger neuer Daten auf eine neue Umgebung überträgt. Dadurch bietet sich dieses Prinzip an, um ein funktionierendes KI Modell an eine besondere Gegebenheit oder auch einen individuellen Nutzer anzupassen. Das spezifische Notebook realisiert dabei das initiale Modell als Prototyp-basierten Klassifikator [Paa+17]. Im Gegensatz zu etwa tiefem Lernen kann dieser anhand relativ weniger Beispiele initial trainiert werden. Das Transferlernen basiert im betrachteten Notebook auf einer Regularisierung mit der Annahme, dass die Daten der initialen Trainingsmenge und einer neuen Situation durch einen spezifischen linearen Datentransfer ineinander übergehen. Im betrachteten Anwendungsfall ist dieses durch die physikalische Geometrie der Situation nahegelegt. Im Notebook ist dann erstens ein Protokoll gespeichert, das die einfache Erhebung neuer Daten zum Transferlernen erlaubt. Zweitens ist eine Methode hinterlegt, um Transferlernen auf der Basis dieser erhobenen Daten durchzuführen. Das trainierte Modell kann schließlich in der Praxis angewendet werden.

■ *Wahrscheinlichkeitsschätzung für Rekurrente Neuronale Netze mit Platt Scaling:*

<https://its-ml.de/index.php/plattscaling/>

Im betrachteten Notebook werden rekurrente neuronale Netze, spezieller LSTM Architekturen, eingesetzt, um die verbleibende Lebenszeit technischer Produkte zu prognostizieren. Als erste Komponente wird daher eine Pipeline angeboten, um ein entsprechendes LSTM Modell anhand bereitgestellter Daten zu trainieren und zu evaluieren. Dabei wird dem Charakter von Zeitreihen durch eine rekurrente Architektur, sowie eine Verarbeitung der Eingabe in Zeitfenstern Rechnung getragen. Der spezielle Fokus des Notebook liegt darin, die Modellausgabe in eine sinnvoll kalibrierte Wahrscheinlichkeitsschätzung umzuwandeln. Dazu wird der populäre Ansatz des Platt-Scaling verfolgt, das die Ausgabe anhand einer adjustierbaren Sigmoiden kalibriert. Das Notebook stellt hierbei eine Trainingspipeline bereit, um solche Parameter anhand der Daten zu bestimmen. Außerdem enthält es Funktionalitäten, um das erhaltene Ergebnis bezogen auf bestehende Wahrscheinlichkeitsverteilungen zu inspizieren. Dabei werden auch alternative Modelle zur Realisierung von Wahrscheinlichkeitsschätzungen, insbesondere Monte-Carlo Dropout, als Vergleich herangezogen.

■ *Vorausschauende Wartung: Systemgesundheit eines Cyber-Physikalischen Produktionssystems:*

<https://its-ml.de/index.php/pdm-systemgesundheit-notebook/>

Dieses Notebook beschreibt die Vorhersage des Gesundheitszustandes einer Schneidklinge im Kontext eines Cyber-Physikalischen Produktionssystems. Das Produktionssystem gruppiert lose Flaschen oder Dosen in festgelegten Packungsgrößen. Die Schneidvorrichtung des Systems kann während des Betriebs nicht visuell inspiziert werden, da es von einem Metallgehäuse umschlossen ist und eine hohe Rotationsgeschwindigkeit

aufweist. Die Beispielimplementierung beschreibt die ersten Schritte einer explorativen Datenanalyse und -vorverarbeitung. Im zweiten Schritt wird ein Autoencoder mit den normalen „gut“ Daten der Maschine trainiert, während das Modell anschließend an der verschlissenen Komponente getestet wird. Die Annahme ist: der Verschleiß einzelner Komponenten verursachen einen höheren Rekonstruktionsfehler. Anschließend kann der Rekonstruktionsfehler in einen geschätzten Gesundheitszustand umgewandelt werden, der den aktuellen Zustand der Maschine widerspiegelt. Abschließend wird die Schätzung des Gesundheitszustandes und die Lokalisierung von Anomalien graphisch aufbereitet.

■ *Restlebenszeit-Vorhersage von Flugzeugtriebwerken:*

<https://its-ml.de/index.php/pdm-rul-notebook/>

Den Ausfallzeitpunkt von Maschinen im Voraus zu kennen, ist sowohl für die Wartungs- als auch die Auftragsplanung eine große Erleichterung. Ein maschinelles Lernmodell dafür zu entwickeln ist allerdings nicht einfach. Am Beispiel von Zeitreihendaten von Flugzeugtriebwerken wird der Prozess von der Datensichtung, über die Auswahl geeigneter Eigenschaften und deren Transformationen, bis hin zur ML-Modellerstellung aufgezeigt. Zudem werden verschiedene Metriken zur Evaluierung des ML-Modells vorgestellt, die abschließend zur Evaluierung von vier exemplarischen ML-Modellen genutzt werden. Außerdem werden die Vorhersagen der verschiedenen Modelle den wahren Werten grafisch gegenübergestellt.

### **Interpretierbarkeit von Modellen:**

■ *Kontrafaktische Erklärung zur Interpretation automatisierter Kreditvergabe:*

<https://its-ml.de/index.php/credit-score-counterfactuals/>

KI-Modelle liefern gegebenenfalls Prognosen, für die eine Erklärung oder Interpretation durch den Betrachter schwierig ist. Daher ist Interpretierbarkeit von Modellen insbesondere in Anwendungen mit potentiell kritischen Auswirkungen (etwa wichtige Entscheidungen zu einzelnen Personen) eine wesentliche Eigenschaft von Modellen. Eine populäre Form, um einzelne Entscheidungen von Black-Box Modellen zu erklären, sind kontrafaktische Erklärungen: diese geben eine minimal notwendige Änderung der Eingabe an, um die Entscheidung zu ändern. Im Beispiel der Kreditvergabe wären dieses etwa notwendige Änderungen der Charakteristika einer Person, die dazu führen, dass ein Kredit nicht mehr abgelehnt würde. Im Notebook werden Klassifikatoren für einen Benchmarkdatensatz zur Kreditvergabe trainiert. Der Kern des Notebooks sind Algorithmen zur Berechnung und Darstellung einer kontrafaktischen Erklärung eines gegebenen Modells und einer gegebenen Eingabe. Eine Besonderheit ist dabei, dass auf besondere Effizienz der Berechnung geachtet wird: für mehrere relevante Modelle kann die Berechnung von kontrafaktischen Erklärungen als konvexes Optimierungsproblem formalisiert und effizient mit einem garantierten Optimum gelöst werden. Im Notebook ist dieses dabei durch die Integration der Counterfactual Explanation Toolbox CEML [AH19] realisiert.

- *Visualisierung von trainierten Klassifikatoren auf hochdimensionalen Daten (DeepView Toolbox):*

<https://its-ml.de/index.php/deepview/>

Aspekte einer globalen Interpretation von Modellen betreffen Fragen wie die Komplexität der Trennungsebene, das Verhalten von Modellen für extreme Datenpunkte oder die Art und Position der Fehler, die auf einem Trainingsdatensatz noch gemacht werden. In der Praxis wird bei einfachen Modellen eine Visualisierung als Scatter-Plot eingesetzt, die die (niedrigdimensionalen) Daten und Entscheidungsebenen als Visualisierung in einer Projektionsebene darstellen. Insbesondere für tiefe Netze ist dieses allerdings ein Problem, da hier die Herausforderung einer hohen Dimensionalität und einer komplexen Entscheidungsgrenze zusammen kommen. Das Notebook bietet eine geschickte Visualisierungstechnik, die es erlaubt, eine gegebene Trainingsmenge von Daten und eine durch ein tiefes Netz induzierte Klassifikationsvorschrift in der Ebene darzustellen. Dazu werden die Datenpunkte mit einer diskriminativen (also einer nur die für das tiefe Netz relevanten Richtungen beachtenden) Dimensionsreduktion in die Ebene projiziert. Es wird dann modulo für das Modell irrelevante Richtungen eine approximative Inverse bestimmt, so dass die Daten und Abstände zu den Trennungslinien als Höhenlinien in einer Visualisierung eingezeichnet werden können. Hierbei wurde besonderer Wert auf eine effiziente Realisierung gelegt, indem geschickte Approximationen der Fisher-Information für einen metrischen Tensor entworfen wurden, und auf das gut skalierende Verfahren UMAP als Dimensionsreduktion referenziert wird.

- *Metric Learning with Self Adjusting Memory for Explaining Feature Drift*

<https://its-ml.de/index.php/metric-learning-with-sam-for-explaining-feature-drift/>

Das Verfahren SAM-k-NN wurde als State-of-the-art Verfahren zum lebenslangen inkrementellen Lernen unter potentiell Drift vorgeschlagen [LHW16]. Es basiert dabei im Kern auf einem k-nächste-Nachbar-Klassifikator und geschickten Strategien die definieren, welche Datenpunkte auch bei möglichem Drift noch relevant gespeichert werden. Das vorgeschlagene Notebook erweitert SAM-kNN um eine Komponente zur globalen Erklärung, welche die Relevanz der einzelnen Merkmale bestimmt und diese Gewichte auch in die Klassifikation miteinbezieht. Dazu kombiniert das Notebook den SAM-kNN Algorithmus mit einem periodisch durchgeführten Algorithmus zum Metriklernen (hier LMNN). Angereichert wird das Notebook um eine Möglichkeit der Visualisierung der Merkmalsrelevanz, indem die Diagonaleinträge entsprechend dargestellt werden. Das Notebook ist direkt ausführbar mit einer Reihe von dafür zur Verfügung gestellten Benchmarks, in denen die Relevanz der Eingaben sich periodisch ändert.

- *Quantifizierung von Unsicherheit*

<https://its-ml.de/index.php/uncertainty-quantification/>

Methoden des maschinellen Lernens haben sich in den letzten Jahren in vielen Anwendungsgebieten etabliert und stark an praktischer Bedeutung gewonnen. Doch trotz aller

Erfolge werden solche Methoden nach wie vor auch mit Skepsis betrachtet, vor allem in sicherheitskritischen Anwendungen, in denen Fehlentscheidungen fatale Folgen haben können. Wichtig für solche Anwendungen ist es, dass ein Lernverfahren sich seiner eigenen Unsicherheit bewusst ist und diese adäquat repräsentieren kann. Am Beispiel eines Benchmark-Datensatzes für überwachtetes Lernen von binären Klassifikationen wird gezeigt, wie die Unsicherheit eines Random Forest gemessen werden kann. Dabei wird zwischen aleatorischer und epistemischer Unsicherheit unterschieden. Schließlich wird der Ansatz im Kontext der Klassifikation mit Enthaltung evaluiert, wobei das Lernverfahren eine Vorhersage in Fällen hoher Unsicherheit ablehnen kann.

### 24/7 Benchmarking:

- *Generierung synthetischer Daten am Beispiel elektromyographischer Messungen für intelligente Prothesensteuerung*

<https://its-ml.de/index.php/benchmarking-myo-data/>

Valides Training und Evaluation von KI Modellen basieren oft auf ausreichend großen Trainingsdatensätzen. Diese sind allerdings für spezifische Anwendungen nicht immer verfügbar. Dadurch entsteht das Risiko, dass Modelle nicht wirklich gut evaluiert werden können. Hier können Verfahren nützen, die auf der Basis von gegebenen Daten neue generieren, die den gemessenen Daten hinsichtlich relevanter statistischer Eigenschaften folgen. Das vorliegende Notebook zeigt dieses am Beispiel von Zeitreihenmessungen von sEMG Signalen. Dieser Ansatz basiert auf dem generellen Prinzip, aus den gegebenen Daten ein generatives Modell zu trainieren, aus dem dann neue Daten gezogen werden können. Im speziellen Fall werden Copula Modelle trainiert. Das Notebook bietet zudem mehrere Funktionen, die Güte der so erzeugbaren künstlichen Daten quantitativ zu evaluieren. Dazu werden unterschiedliche klassische Evaluationsmaße zum Vergleich von Datenverteilungen exemplarisch getestet. Angereichert ist das Notebook mit einer Reihe von Visualisierungen der so erzielbaren Ergebnisse.

### Greybox Lernen:

- *Grey-Box Learning für die roboterbasierte Montage*

<https://its-ml.de/index.php/roboerbasierete-montage/>

Die im Projekt entwickelte Grey-Box Learning Methode für roboterbasierte Manipulationsprozesse wurde in zwei konkreten Montage-Szenarien umgesetzt und evaluiert.

Eine erste Umsetzung erfolgt in einem Glühbirnen-Montageprozess. Das Einschrauben einer Glühbirne erfordert eine hohe Genauigkeit. Im Idealfall sind die Posen der manipulierten Bauteile exakt bekannt und eine fixe Trajektorie kann abgefahren werden. Dieses ist aber in der Realität nicht der Fall, vor allem, wenn Prozesse flexibel umgesetzt werden sollen. Werden bspw. Bauteilposen über ein Kamerabild erkannt, ist das Ergebnis eine mit Positionsunsicherheiten behaftete Schätzung. Im Montageprozess muss auf diese

Unsicherheiten reagiert werden. Um den Montageprozess auch unter dem Einfluss dieser Unsicherheiten robust ausführen zu können, muss die Regelung des Roboters diese Positionsunsicherheiten ausgleichen. In der Umsetzung wird hierzu die interne Kraftsensorik des Manipulators genutzt. Das Verhalten zum Ausgleichen von Unsicherheiten in der Annäherungsphase wird über Reinforcement Learning Methoden gelernt. Durch autonomes Training lernt der Roboter, die Glühbirne vor dem Einschraubvorgang präzise im Sockel auszurichten. Die entwickelte Grey-Box Learning Methodik bietet die Grundlage dafür, vor- und nachgelagerte Prozessschritte, wie das Greifen der Glühbirne und den eigentlichen Schraubvorgang modellbasiert zu spezifizieren, sowie Einschränkungen für das zu lernende Verhalten sicher zu stellen. Der Lernprozess erfolgt anschließend auf Basis dieser partiellen Verhaltensbeschreibung. Nach bereits 200 Versuchen ist ein robustes Verhalten gelernt.

Eine zweite Umsetzung erfolgte in einem industriellen Anwendungsfall. Die Montage von Modulen für Han-Modular Industriesteckverbinder der HARTING Technologiegruppe bietet besondere Herausforderungen. Zum einen sitzen die Module sehr passgenau im Rahmen und weisen nur 0.2 mm Spiel auf. Zum anderen gibt es eine Vielzahl unterschiedlicher Module mit unterschiedlichen geometrischen Formen. Die vollständige Programmierung des Roboterhaltens unter dem Einfluss von Positionsunsicherheiten ist daher sehr aufwendig, da für alle unterschiedlichen Module auch unterschiedliches Verhalten modelliert werden muss. Mit der entwickelten Grey-Box Learning Methode ist es möglich, ein adaptives Verhaltensmodell zu spezifizieren, das sich durch autonomes Lernen an die unterschiedlichen Modul Geometrien anpasst und auch zustandsabhängig auf Positionsunsicherheiten reagiert. Ein robustes Verhalten zum Einführen der Module ist bereits nach 500 Versuchen (ca. 0.5h) gelernt.

■ *Deep-Learning-basierte Rauschunterdrückung und Rekonstruktion von Mikroskopbildern (Deep-Learning based Denoising and Reconstruction of Super-Resolution Structured Illumination Microscopy Images)*

Training: <https://its-ml.de/index.php/srmicro-img-recon-denoise-train/>

Testen: <https://its-ml.de/index.php/sr-microscopy-image-reconstruction-denoising-testing/>

In der Fluoreszenzmikroskopie werden Proben mit strukturiertem Licht beleuchtet, um die optische Beugungsbegrenzung zu umgehen und so die Auflösung der Aufnahmen zu erhöhen (Super-Resolution Structured-Illumination-Microscopy, SR-SIM). Viele biologische Zellen reagieren jedoch empfindlich auf eine zu große energetische Anregung durch das eingebrachte Licht. Daher arbeitet man hier mit möglichst kurzen Belichtungs- bzw. Beleuchtungszeiten oder verringerter Laserleistung. Dies wiederum führt zu einem niedrigen Signal-zu-Rausch-Verhältnis (SNR, signal-to-noise-ratio) in den Signalen (Abbildungen) der bildgebenden Kamerachips. Klassische SIM-Algorithmen sind nicht in der Lage, das Rauschen zu entfernen. Im Gegenteil bringen sie sogar rauschbasierte Artefakte in die rekonstruierten Abbildungen ein. Zur Lösung dieses Problems wurde ein Ende-zu-Ende-Workflow basierend auf Deep Learning entworfen, der in der Lage ist, ausgehend von verrauschten SIM-Abbildungen hochauflösende SR-SIM Abbildungen zu rekonstruieren. Hier-

zu wurden zwei Jupyter-Notebooks vorgelegt, die sowohl das Training als auch das Testen des beschriebenen Modells zeigen. Das Verfahren erlaubt prinzipiell Einblicke in die verschiedenen Schichten des tiefen neuronalen Netzes (ggf. physikalische Interpretierbarkeit der entstandenen Faltungskerne) und kann zusammen mit Domänenmodellen eingesetzt werden (Greybox-Lernen).

### Eingebettetes Lernen:

- *ML-basierte Vorhersage von Gelenkbewegungen (ML-based Torque Adjustment in Hybrid Models for Limb Movement Prediction)*

<https://its-ml.de/index.php/ml-based-torque-adjustment-in-hybrid-models-for-limb-movement-prediction/>

Die Entwicklung der nächsten Generation von Körperassistenzsystemen (Exoskelette und Orthesen), die Menschen möglichst dezent dort unterstützen, wo körperlich belastende Tätigkeiten ausgeführt werden (z.B. Personal in der Pflege), erfordert neuartige Regelungsalgorithmen. Diese basieren auf einer kontinuierlichen Bewegungsvorhersage der zu unterstützenden Gliedmaße. Das vorgelegte Jupyter-Notebook stellt ein Beispiel für einen datengetriebenen Ansatz zur Vorhersage des Drehmoments im Ellenbogengelenk auf Basis von Elektromyographiesignalen (EMG-Signalen) dar. Das Notebook beinhaltet ein neuronales Netz (FF-KNN), das vorverarbeitete EMG-Signale als Eingabe erhält und das die daraus resultierenden Drehmomente im Ellenbogen vorhersagt. Das Netz kann in der Folge auf Basis von Datenströmen weiter trainiert und so effizient implementiert werden, dass es auch auf eingebetteter Hardware mit eingeschränkter Rechenleistung läuft. Weiterhin ist der Ansatz geeignet, um parallel zu einem Domänenmodell betrieben zu werden und dieses – im Sinne eines Greybox-Ansatzes – zu ergänzen.

### Meilensteine:

- **M3.1: Realisierung von Jupyter-Notebooks im Rahmen der Plattform FIT.ML:** Mit Projektabschluss enthält unsere Wissensbasis auf der Plattform **FIT.ML** elf Notebooks zu Umsetzungsprojekten, die neue Ergebnisse und Methoden des ML einfach verfügbar machen.
- **M3.2: ML ThinkTank** Im Zuge der Schulung ‚Getting AI-ready: Von intelligenten Assistenzsystemen bis zu erklärbarem Maschinenlernen‘, die virtuell am 26.11.2021 stattfand, luden Universität und Fachhochschule Bielefeld zur Denkfabrik ‚ML für Intelligente Systeme‘ interessierte Vertreter aus Wirtschaft und Forschung zum Expertengespräch.

## 2.2 AB4: ML-Plattform – FIT.ML (Leitung: Universität Bielefeld)

Ziel war die Schaffung einer leistungsfähigen Infrastruktur mit Leuchtturmcharakter für die Anwendung von ML für ITS, die an Services geknüpft wird, die das Potenzial zu einer Verstärkung haben. Die Plattform sollte insbesondere als standardisierte Schnittstelle dienen, um Synergieeffekte mit in der Region angesiedelten industrienahen Forschungsprojekten optimal ausnutzen zu können, und so den Bedarf an ML-Technologie aufzuzeigen. Die Aufbereitung der

ML-Verfahrensketten und Materialien in einem für KMU nutzbaren Format sind dabei zentral, um den Einsatz von Maschinellern für intelligente technische Systeme der nächsten Generation voranzutreiben.

Die Erkenntnisse aus Umsetzungs- und Begleitprojekten flossen dabei direkt in die gemeinsame ML-Plattform **FIT.ML**, sodass Verwertung und Transfer auf neue Domänen sichergestellt werden. In AB 4 wurden diese einzelnen Modellierungsbeispiele sowie die einzelnen Notebooks in eine strukturierte Form überführt, die den Austausch von Komponenten ermöglicht und eine einfache Recherche anhand von klaren Kriterien durch Nutzer realisiert. Hierdurch wurden die Ergebnisse von AB2 und AB3 so aufbereitet, dass sie als Blaupausen für Stakeholder und Entwickler – insbesondere von KMU – dienen und eine einfache Erweiterbarkeit und Persistenz gegeben wird.

**Datenbank anwendungsgetriebener ML-Modellierungen** In Begleitprojekten entwickelte prototypische Modellierungsbeispiele für spezielle Anwendungsdomänen wurden zum Aufbau einer Anwender unterstützenden Modellierungs-Wissensbasis genutzt. Diese ermöglicht durch die Verknüpfung mit einem Kriterienkatalog dem Anwender, die Eignung von ML abzuschätzen und im Fall, dass diese vielversprechend ist, die effiziente Modellierung eines Problems als ML-Problem zu imitieren.

Eine Strukturierung erfolgte dabei entlang der ML-Innovationsthemen (I1)-(I5) (s. AB3), die eine leichte Einordnung eines gegebenen Problems etablieren. Zudem wurden je Charakteristika der Daten eine kurze Formalisierung der Ist-Situation und des anvisierten Ziels formuliert.

Die Plattform wird an der Universität Bielefeld unter einer eigenen Domäne gehostet. Die bereitgestellten Notebooks nutzen durchgängig Scikit-Learn kompatible Komponenten.

Die in AB2 bearbeiteten Projekte und deren Lösungen wurden für die Wissensbasis in schriftlicher Form aufbereitet. Die Kriterien für dieses von uns entwickelte Format der 'Applied Modelling Examples' basieren auf den "Umsetzungshilfen Arbeit 4.0" (S.45ff)<sup>17</sup>, herausgegeben von der "Offensive Mittelstand – Gut für Deutschland" der Stiftung "Mittelstand – Gesellschaft - Verantwortung". Dieses generelle Format richtet sich nicht nur an ML-Experten, sondern auch an Berater und interessierte Akteure in den Unternehmen. So ist unter anderem sichergestellt, dass die Wissensbasis auch für Personen ohne vertiefte ML- oder Softwarekenntnisse einen Mehrwert darstellt.

Zudem berücksichtigt das von **ITS.ML** genutzte AME (Applied Modeling Example) Format Anforderungen zur Vertraulichkeit, sodass die in **FIT.ML** vorgestellten Modelle keine proprietären Informationen preisgeben. Dieses wurde zusätzlich durch Rücksprache mit den Industriepartnern bzw. Anwendungspartnern garantiert.

---

<sup>17</sup><https://www.offensive-mittelstand.de/serviceangebote/mittelstand-40/umsetzungshilfen-arbeit-40>

Zusätzlich zur Suche nach vorgegebenen Kriterien bzw. anhand der Innovationsthemen besteht die Möglichkeit, Problembeschreibungen als natürlichsprachigen Text in die Wissensbasis einzugeben und anhand dessen ähnliche bekannte Modellierungen zu erhalten. Dies sorgt zusätzlich für einen stark vereinfachten Zugang. Diese Funktionalität wurde im Projekt anhand einer intelligenten Suche realisiert, die natürliche Sprache direkt verarbeitet um den dem Eingabetext ähnlichsten Treffer zu liefern.

**Integration von Referenzimplementationen für die ML-Innovationen (I1)-(I5)** Neben den AMEs sind die Ergebnisse der in AB3 beschriebenen Umsetzungsprojekte in die Wissensbasis **FIT.ML** eingeflossen. Auf diese Weise bietet sie Referenzimplementationen für ML-Innovationen (I1)-(I5) als Jupyter Notebooks, in Kompatibilität mit populären Open-Source-ML-Suiten wie etwa Scikit-Learn. Neben der html-Version des Codes sind alle Notebooks auch über das ITS.ML Github Repository abrufbar: <https://github.com/itsml/itsml>. Hier ermöglicht die Bereitstellung von Software zusammen mit exemplarischen Daten eine einfache Ausführung aller relevanten Pipelines in Python.

Ein besonderes Augenmerk liegt auf der Tatsache, dass aus Unternehmen stammende Daten in der Regel proprietär sind. Daher wurden stattdessen typische Beispieldaten mit charakteristischer Form und Statistik künstlich generiert. Die entsprechenden Daten sind im Github verfügbar. Dabei sind Beispieldaten immer folgend der Charakteristik echter Daten generiert, sodass eine valide Evaluation und ein praxisnaher Test möglich sind. Um auch diese Methodik für den Anwender verfügbar zu machen, ist sie im Bereich des "Benchmarking" als eigenes AME und Notebook unter dem Projekt "Generierung synthetischer Daten am Beispiel elektromyographischer Messungen für intelligente Prothesensteuerung" nachgehalten.

Jedes Notebook ist mit einer entsprechenden Dokumentation angereichert, die deren Ausführung kommentiert und auch eine Interpretation und Visualisierung der jeweiligen Ergebnisse beinhaltet.

**Evaluation der ML-Verfahren** Formalisierung und Realisierung von Tests typischer ML-Pipelines durch die Bereitstellung von Gütekriterien und Benchmarkdatensätzen mit geeigneten Kriterien erlauben eine valide Evaluation der ML-Verfahren im Rahmen der gesamten Pipeline. Um dies zu gewährleisten, wurden für den Bereich (I1) *Lernen auf Datenströmen* ein entsprechender Benchmarkdatensatz, und genereller für den Einsatz von ML in der Robotik Gütekriterien entwickelt. Letztere wurden als Teil unserer Plattform **FIT.ML** veröffentlicht.

**Vernetzung der bestehenden ML-Labs in OWL** Die bereits bestehenden ML-Labs in OWL mit unterschiedlichen Schwerpunkten wurden im Rahmen des Projekts vernetzt. Dies geschah unter anderem durch Integration und Erlebarmachung dezidierter ML-Technologien in Demonstratoren.

Im Zuge des ML-Innovation-Day an der Universität Bielefeld in Kooperation mit IHK Lippe zu Detmold am 29.11.2019 nahmen rund 50 Vertreter aus Firmen an einer Lab-Tour teil, bei der die Teilnehmenden einen Einblick in aktuelle Arbeit aus den verschiedenen Laboren erhielten. Ein zweiter virtueller Lab Day wurde als KI-Slams realisiert, bei dem junge Forschende mit kurzen Videos zu ihren Forschungsthemen rund um das Thema Künstliche Intelligenz begeistern konnten. Dieser fand im Zuge der Schulung ‚Getting AI-ready: Von intelligenten Assistentensystemen bis zu erklärbarem Maschinenlernen‘ am 26.11.2021 statt. Die Beiträge sind über die Homepage zugänglich: <https://its-ml.de/index.php/ki-slam-getting-ai-ready-voting/>.

#### **Meilensteine:**

- **M4.1: Aufbau einer Plattform und eines standardisierten Formats für die Wissensbasis von Best Practice Modelling Beispielen und Notebooks zu ML-Pipelines:** Begleitprojekte (AB2) unserer Wissensbasis sind in schriftlicher Form als AME nachgehalten. Diese enthält auch Jupyter Notebooks zu ML-Pipelines der Umsetzungsprojekte (AB3).
- **M4.2: Zwei Lab-Touren zur Bekanntmachung der Plattform:** Im Zuge des ML-Innovation-Day an der Universität Bielefeld in Kooperation mit IHK Lippe zu Detmold am 29.11.2019 wurde die erste Lab-Tour veranstaltet. Ein zweiter virtueller Lab Day wurde als KI-Slam am 26.11.2021 realisiert.
- **M4.3: Strukturierte Integration von Modellen und Pipelines zusammen mit einem Kriterienkatalog:** Modelle und Pipelines in der Wissensbasis orientieren sich entlang der ML-Innovationsthemen (I1)-(15), zusammen mit Benchmarking Datensätzen und Gütekriterien zu ‚ML in der Robotik‘.

## **2.3 AB5: Qualifizierungsangebote – LEARN.ML (Leitung: Universität Paderborn)**

Ziel des AB5 war die Schaffung von zielgerichteten Lernmaterialien, die Akteuren im Bereich der ITS relevante ML-Technologien bedarfsgerecht nahe bringt. Durch die Standardisierung der Ausbildungsinhalte wurde zur Schaffung einer Kultur des Wissenstransfers von Hochschulen und Unternehmen beigetragen. Materialien wurden in der Lernplattform bereitgestellt und zwei relevante Schulungen entwickelt. **ITS.ML** adressierte in diesem Arbeitsbereich die Aus- und Weiterbildung von ML für den Einsatz in der industriellen Praxis, speziell in ITS. Dies wurde durch ein Bündel von Qualifizierungsmaßnahmen für unterschiedliche Klientel realisiert. Die Maßnahmen wurden standardisiert und durch die Integration der Materialien von Schulungen und ML-Modulen in die ML-Plattform persistent gehalten.

**Aufbau und Angebot von zwei Schulungen** Die für die Workshops/Schulungen erzeugten Materialien wurden auf der **ITS.ML**-Webseite veröffentlicht (<https://its-ml.de/index.p>

[hp/learn-ml/frei-zugaengliche-lehrmaterialien/](https://learn-ml/frei-zugaengliche-lehrmaterialien/)) und können auch als Kurseinheiten innerhalb des hochschulübergreifenden Moduls (“ML für Intelligente Systeme”) verwendet werden.

- **Inside Out: The Essentials of Predictive Maintenance:** Die Universität Paderborn und die Technische Hochschule Ostwestfalen-Lippe haben im Rahmen des Projekts den Workshop “Inside Out: The Essentials of Predictive Maintenance” entworfen und durchgeführt. Der Workshop ist in vier Sessions organisiert und an KMU gerichtet, die Predictive Maintenance in ihrem Unternehmen etablieren möchten. Um das Schulungsangebot auch langfristig für KMU zur Verfügung zu stellen, wurde der Workshop zu einer Videoreihe weiterentwickelt, die 13 Videos umfasst. Diese Videoreihe richtet sich an Personen mit unterschiedlichen Erfahrungen im Bereich des maschinellen Lernens und der vorausschauenden Wartung. Interessierte können auf der Plattform [LEARN.ML](#) mit denen für ihr Erfahrungslevel geeigneten Videos in den Workshop einsteigen. Des Weiteren wurden unterstützende Codebeispiele in Form von Jupyter Notebooks zur Verfügung gestellt. Die Schulung deckt dabei alle Schritte ab, die notwendig sind, um von gegebenen Daten zu funktionierenden Verfahren zur Prognose der Restlebenszeit bzw. zu einer vorausschauenden Wartung zu kommen.
- **Getting AI-ready: Von intelligenten Assistentensystemen bis zu erklärbarem Maschinlernen:** Die Fachhochschule Bielefeld und die Universität Bielefeld haben gemeinsam den Workshop “Getting AI-ready: Von intelligenten Assistentensystemen bis zu erklärbarem Maschinlernen” entworfen und am 26.11.2021 durchgeführt. Das Workshop-Konzept beinhaltet drei inhaltliche Sessions und adressiert mit seinem Domänenthema *Assistenzsysteme* ein breites Zielpublikum aus kleinen und mittelständischen Unternehmen. Das Workshop-Konzept bildet dabei eine Brücke von eher grundlegenden Fragestellungen zu transferierbaren Aspekten aus der Anwendungsforschung. Insbesondere ist das Thema *Assistenzsysteme* auch für Unternehmen der Gesundheitswirtschaft (von Pflegedienstleistern bis zu Orthopädieversorgern) von steigendem Interesse. Die drei Sessions beleuchten grundlegende Fragen zur Erklärbarkeit von ML-Ansätzen (“XAI: Die richtige Erklärung zur richtigen Zeit”), zur Verwendung von biologischen Domänenwissen beim maschinellen Erlernen von Gliedmaßenbewegungen (“Hybride ML-Modelle zur Vorhersage von Gliedmaßenbewegungen basierend auf Biosignalen”) sowie zum Erlernen von Bewegungsabläufen basierend auf Kameradaten (“KI für assistierende Systeme zum Erlernen von Bewegungsabläufen anhand von Kameradaten”). Dabei wurden bewusst Aspekte, die Tutorial Charakter haben (etwa eine Übersicht verschiedener Ansätze zur Erklärung von KI Modellen) mit konkreten Anwendungen aus der Praxis der beteiligten Hochschulen kombiniert.

**Hochschulübergreifende Lernmaterialien :** Im Projekt wurden Kurseinheiten zu innovativen Aspekten des ML, insbesondere den Innovationsgebieten (I1)-(I5) realisiert. Diese können

einzelnen oder im Verbund für Lehrmodule der beteiligten Hochschulen dienen. Dabei haben die Teilmodule Stand-Alone-Charakter, um die Einheiten einfach in Bestandsmodule zu integrieren oder sie zum Selbststudium einzusetzen. Teile der Materialien werden etwa bereits für eine Vorlesung zum Thema 'Deep Learning', welches von Hörern der Universitäten als auch der FHs besucht werden kann, benutzt. Dabei richten sich die Materialien an Studierende mit unterschiedlichen Vorkenntnissen und Schwerpunkten.

**Kooperation mit der lokalen Gründerszene:** Im Rahmen des Projekts wurde einerseits direkt mit Startups kooperiert (siehe AB3), andererseits wurden verschiedene Veranstaltungen mit Multiplikatoren aus diesem Bereich realisiert. Beispiele sind die Teilnahme bei Veranstaltungen wie dem von BSI und TÜV veranstalteten Workshop 'Auditing AI-Systems: From Principles to Practice' in 2020 mit anschließendem White Paper<sup>18</sup>, Vorträge bei Workshops oder Makeathons wie dem KI-Sommercampus des KI-Innovationswettbewerbs, oder dem AI-Day des KI-Marktplatz, sowie die Ko-Organisation von Workshops mit starkem Anwendungsbezug, etwa die Bildverarbeitung in der Automation (BVAu) 2020 oder der Workshop Künstliche Intelligenz in der Anwendung 2019. Durch diese Veranstaltungen konnte eine entsprechende Multiplikatorwirkung erzielt werden.

### Meilensteine

- **M5.1: Entwurf und Durchführung von zwei Schulungen zu aktuellen ML-Themen**
- **M5.2: Durchführung eines ML-ThinkTanks:** Am 26.11.2021 luden Universität und Fachhochschule Bielefeld zur Denkfabrik 'ML für Intelligente Systeme' interessierte Vertreter aus Wirtschaft und Forschung zum Expertengespräch.
- **M5.3: Realisierung einer praxisorientierten Kurseinheit zu ML und Integration in die ML-Plattform [FIT.ML](#)**

### Wichtigste Positionen des zahlenmäßigen Nachweises

Gegenstand der Förderung waren hauptsächlich

- Personalmittel, um Personen zur Durchführung der Projektarbeiten einstellen zu können,
- Mittel für Hilfskräfte zur Unterstützung bei den Programmieraktivitäten und der Aufbereitung der Ergebnisse,
- Reisemittel für Projekttreffen, Treffen mit Firmenvertretern/Multiplikatoren und Teilnahme an Tagungen zur Präsentation der Ergebnisse,

<sup>18</sup>[https://www.bsi.bund.de/SharedDocs/Downloads/EN/BSI/KI/Towards\\_Auditable\\_AI\\_Systems.pdf?\\_\\_blob=publicationFile&v=6](https://www.bsi.bund.de/SharedDocs/Downloads/EN/BSI/KI/Towards_Auditable_AI_Systems.pdf?__blob=publicationFile&v=6)

- Mittel für die Durchführung von Veranstaltungen und dafür benötigtes Material,
- Mittel für Server/Hardware.

Die Kosten wichen dabei aufgrund der Pandemiebedingungen zum Teil von der initialen Planung ab. Spezifische Mittel je Projektpartner waren:

- Universität Bielefeld:

- Personalmittel für zwei Stellen TVL-13 für wissenschaftliches Personal für die gesamte Laufzeit zur Durchführung von Projektarbeiten
- Personalmittel für eine Stelle TVL-14 für die gesamte Laufzeit (minus Elternzeit) zur Durchführung und Koordination von Projektarbeiten
- Personalmittel TVL-13 als Vertretung der TVL-14 Stelle; es konnte hier keine geeignete Person für TVL-14 gefunden werden, daher wurden die Aufgaben durch mehrere als TVL-13 beschäftigte wissenschaftliche Mitarbeitende übernommen. Aufgrund der Eingruppierung der Personen, Tarifsteigerungen, sowie Zusatzkosten etwa durch Corona-Zuschlag waren die Personalkosten insgesamt geringfügig höher als geplant.
- Mittel für Hilfskräfte für den gesamten Zeitraum, hier war insbesondere unter Pandemiebedingungen die Gewinnung und Integration von Hilfskräften problematisch, zudem entfiel der Bedarf der Unterstützung durch Hilfskräfte bei Präsenzveranstaltungen, sodass hier weniger Mittel ausgegeben wurden als geplant.
- Reisetätigkeiten wurden aufgrund der Pandemiebedingungen nur in deutlich geringerem Umfang wahrgenommen als geplant.
- Sachausgaben für die Durchführung von Veranstaltungen waren geringer als geplant, da Mittel für Bewirtung, Raummiete, Material wie Rollups etc. entfiel. Es entstanden in geringerem Umfang Kosten für die Durchführung digitaler Veranstaltungen (etwa Zoom-Lizenzen zu Beginn der Pandemie, Kosten für Digitalisierungsplattform, Videos, ...).
- Kosten für einen Server zur Bereitstellung der **FIT.ML** Plattform waren höher als geplant, da aufgrund von Lieferschwierigkeiten und Chipmangel die Preise hier deutlich gestiegen sind.

- Universität Paderborn:

- Personalmittel wurden für die Einstellung von wissenschaftlichen Mitarbeitenden (fast ausschließlich TVL-13) verausgabt, wobei die Mittel über den gesamten Zeitraum anfielen. Die Mitarbeitenden waren notwendig, um die im Projekt vorgestellten Verfahren zu entwickeln, evaluieren und umzusetzen.

- Beschäftigungsentgelte für studentische Hilfskräfte über den gesamten Zeitraum des Vorhabens. Es wurden Hilfskräfte zur Unterstützung der Arbeiten, insbesondere Programmiertätigkeit und Vorbereitung von Material / Schulung eingestellt. Diese Mittel wurden geringfügig überzogen aufgrund der gebotenen spezifischen Ausgestaltung der Verträge.
- Reisemittel wurden geringer als geplant verausgabt, da Dienstreisen unter Pandemiebedingungen zum großem Teil durch virtuelle Treffen ersetzt wurden.
- Angesetzte Kosten für Verbrauchsmaterial waren deutlich geringer als geplant, da hier geplante Kosten durch den Ersatz von Präsenzveranstaltungen durch virtuelle Veranstaltungen nicht entstanden.

#### ■ Fachhochschule Bielefeld:

- Personalmittel für eine Stelle TVL-13 (05.2019 bis 05.2021) zur Durchführung von Projektarbeiten
- Personalmittel für eine Stelle TVL-13 (07.2019 bis 01.2022) zur Durchführung von Projektarbeiten
- Personalmittel für eine Stelle TVL-13 (08.2021 bis 01.2022) zur Durchführung von Projektarbeiten
- Mittel für Hilfskräfte für den gesamten Zeitraum, hier war insbesondere unter Pandemiebedingungen die Gewinnung und Integration von Hilfskräften problematisch, sodass hier weniger Mittel ausgegeben wurden als geplant.
- Reisetätigkeiten wurden aufgrund der Pandemiebedingungen nur in deutlich geringerem Umfang wahrgenommen als geplant.
- Mittel für zwei mobile Workstations für vor-Ort-Aufnahmen von Datenströmen und deren direkte Analyse im Feld.

#### ■ Technische Hochschule OWL:

- Personalmittel für eine Stelle TVL-13 für wissenschaftliches Personal für die Laufzeit vom 09.2018 bis zum 03.2019.
- Personalmittel für eine Stelle TVL-11 für wissenschaftliches Personal für die Laufzeit vom 04.2019 bis zum 09.2019. Es konnte hier keine geeignete Person für TVL-13 gefunden werden, daher wurden die Aufgaben durch einen erfahrenen als TVL-11 beschäftigten wissenschaftlichen Mitarbeiter übernommen.
- Personalmittel für eine halbe Stelle TVL-13 für wissenschaftliches Personal für die Laufzeit vom 07.2019 bis zum 04.2020.
- Personalmittel für eine halbe Stelle TVL-13 für wissenschaftliches Personal für die Laufzeit vom 07.2020 bis zum 11.2021.

- Personalmittel für eine Stelle TVL-13 für wissenschaftliches Personal für die Laufzeit vom 10.2019 bis zum 01.2022.
- Aufgrund der Eingruppierung der Personen, Tarifsteigerungen, sowie durch den Corona-Zuschlag waren die Personalkosten insgesamt geringfügig höher als geplant.
- Die Mittel für Hilfskräfte für den gesamten Zeitraum waren geringer als geplant.
- Aufgrund der Pandemiebedingungen wurden Reisetätigkeiten in deutlich geringerem Umfang wahrgenommen als geplant.

## Notwendigkeit und Angemessenheit der geleisteten Arbeit

Die im Antrag angegebenen Meilensteine und Ziele wurden erreicht. Um die Arbeiten sachgemäß durchzuführen, wurde eine kostenneutrale Verlängerung beantragt. Diese war einerseits damit begründet, dass aufgrund der Konkurrenz am Arbeitsmarkt eine verspätete Einstellung des Personals erfolgte. Andererseits traten aufgrund der Pandemiebedingungen und den damit notwendige Änderung der Form von Veranstaltungen in ein digitales Format Verzögerungen auf, die so bei Beantragung des Projekts nicht absehbar waren. Der Zeitplan wurde in diesem Rahmen eingehalten. Die beantragten Mittel für Personal wurden für die Durchführung der Forschungs- und Transfertätigkeiten benötigt und sachgemäß ausgegeben. Die beantragten Personalmittel waren dabei angemessen, um die betrachtete Anzahl an Handlungsfeldern und Innovationsgebieten abzudecken, die für den Transfer von KI insbesondere zu KMU hochgradig relevant sind. Aufgrund von Synergieeffekten war es dabei geraten, die Gebiete zusammen zu betrachten. So sind etwa je mehrere Innovationsgebiete für ein Handlungsfeld relevant. Jenseits von Personalkosten entstanden geringe Kosten für die angemessene Durchführung von Transferveranstaltungen und die Publikation der Ergebnisse, die notwendig waren, um die beabsichtigten Transfereffekte zu erreichen.

Aufgrund der klaren Orientierung an der Umsetzbarkeit und einer engen Verzahnung von wissenschaftlicher Forschung des ML mit den in Unternehmen anzutreffenden Besonderheiten, war eine Förderung des Projekts durch eher Grundlagen-orientierte Forschungsförderung, wie durch Stiftungen oder Forschungsgemeinschaften gegeben, ausgeschlossen. Eine potentielle Förderung des geplanten Vorhabens durch das aktuelle EU-Rahmenprogramm für Forschung und Innovation, Horizont 2020, haben die Antragsteller mit den EU-Büros der beteiligten Hochschulen erörtert. Bedingt durch die Konsortialstruktur mit Partnern aus der Region sowie den eher regional ausgerichteten inhaltlichen Fokus war eine europäische Förderung auszuschließen. Weiterhin konnte die Förderung der Maßnahmen in dieser Form nicht direkt durch industrielle Partner übernommen werden, da die Maßnahmen noch keine Marktreife besitzen und damit das Risiko nicht von KMU getragen werden kann.

## Voraussichtlicher Nutzen

Die Ergebnisse tragen substantiell zum Forschungstransfer in dem aktuellen Gebiet der KI bei, wobei der Fokus auf intelligenten technischen Systemen (ITS) liegt. ITS stellt einen hoch relevanten Bereich der Wirtschaft dar, in welchem etwa durch große Tech-Konzerne bereitgestellte KI-Komponenten oft nicht unmittelbar genutzt werden. Umsetzungsschranken bestehen aus den Anforderungen von möglichst großen Datenmengen und der eher generische Einsatzsituationen, statt Spezifika der Anwendung auch in physikalischer Hinsicht zu integrieren. Im Projekt wurden daher gezielt Aspekte adressiert, die über solche klassischen Modellierungen durch tiefe Netze hinausgehen. Diese Gesichtspunkte umfassen Lernen aus wenigen Daten, Lernen mit sich etwaig ändernden Gegebenheiten, Lernen unter Einbezug der physikalischen Einschränkungen und 'on the edge', erklärbare Verfahren, Verfahren unter Einbeziehung von Vorwissen, Auto-ML-Modelle, etc. Die erzielten Ergebnisse haben einen unmittelbaren Nutzen bezogen auf verschiedene Stakeholder, insbesondere KMU, und adressieren die folgende Ziele:

- Erhöhen der Awareness für Themen in KMU, die mit Hilfe von ML angegangen werden können und so das wirtschaftliche Potenzial der Unternehmen vergrößern: Diese Facette hatte zum Ziel, zu einem realistischen Bild beizutragen, wo ML-Verfahren eingesetzt werden können und wo Grenzen bestehen. Ein spezifischer, im Projekt adressierter Aspekt waren etwa Reject Optionen bzw. die Quantifizierung von Unsicherheiten, um für spezifische Modelle gezielt Schranken ihres Gültigkeitsbereichs zu explizieren.
- Entwicklung und Übertragung von aktuellen ML-Themen in die wirtschaftliche Praxis: Dadurch, dass die im Projekt entwickelten Themen auch mit kleinen, lokalen Datenmengen, Vorwissen, und energieeffizienter Realisierung umgehen können, entstand hier das Potenzial eines regional verankerten Spezifikums der deutschen mittelständischen Industrie. Im Projekt wurden konkrete Kooperationen mit Unternehmen bzw. Anwedungspartnern durchgeführt, die dieses demonstrierten, etwa im Bereich der Materialprüfung und -optimierung auf der Basis visueller Inspektionen [Buc+21].
- Bereitstellung von Konzepten, wie Probleme effizient modelliert werden können, und die Bereitstellung von Benchmarkimplementationen relevanter Pipelines: Durch den einfachen Zugang zu typischen Modellierungsbeispielen wurde eine Möglichkeit geschaffen, die Einsetzbarkeit neuer ML-Verfahren einschätzen zu können. Diese Bereitstellung stellt einen Schritt hin zur Realisierung von ML-Tools "as a service" dar. Im Projekt wurde diese Zielrichtung zusätzlich dadurch unterstützt, dass Tools und Algorithmen zur Automatisierung des ML-Entwurfs in wichtigen Anwendungsbereichen wie der Predictive Maintenance entwickelt wurden [Tor+20].

Wissenschaftliche Erkenntnisse wurden in folgender Hinsicht erreicht, dokumentiert durch die im Projekt erzielten Publikationen in einschlägigen internationalen Organen.

- Entwicklung und Transfer von ML-Verfahren für hoch relevante Konzepte wie Lernen mit Drift, Reject Optionen für Modelle, Interpretierbarkeit von Modellen, Einbezug von Vorwissen in die Praxistauglichkeit.
- Entwicklung von Konzepten, die es erlauben, ML-Verfahren für intelligente technische Systeme als Service anzubieten, insbesondere AutoML-Methoden.
- Schritte zur Standardisierung von Modellierungskonzepten und Verfahrensketten, die eine nahtlose Integration moderner ML-Technologien in Unternehmen ermöglichen. Dieses ist etwa im Bereich der flexiblen Fertigung und der Integration physikalischen Vorwissens in effiziente Reinforcement-learning-Ansätze geschehen.

Das Projekt hat eine hohe Anschlussfähigkeit durch die Nutzung der entwickelten Materialien und die strategische Ausrichtung, die zahlreiche Anschlussarbeiten und -projekte ermöglicht. Dieses betrifft spezifisch

- die Integration der entwickelten Materialien in Module in der Ausbildung in diesem Bereich an den Hochschulen für Fachkräfte in Industrie als auch universitärem Kontext,
- die Nachnutzung von Materialien für Veranstaltungen zum Transfer der Ergebnisse in die Wirtschaft,
- die Nutzung der Ergebnisse als Plattform für durch externe Mittelgeber geförderte Projekte.

Die hier benannten Verwertungskomponenten sind für alle Partner im Projekt relevant. Im Folgenden werden kurz spezifische Aspekte der einzelnen Partner benannt:

- Universität Bielefeld:
  - Integration der Technologien in das Portfolio der zentralen wissenschaftlichen Einrichtung CoR-Lab mit dem Ziel des Wissenschaftstransfers von Anwendungen in den Bereichen Robotik und intelligente Automation; Nutzung für angewandte Projekte als auch Weiterbildungsmaßnahmen;
  - Weitere Publikation der Ergebnisse in Fachzeitschriften und Konferenzen; hier sind im Rahmen des Projekts an der Universität Bielefeld bereits sechzehn Publikationen entstanden bzw. in Begutachtung;
  - Integration der Lehrmaterialien in die MSc Studiengänge Intelligente Systeme, Data Science, sowie den gemeinsamen MSc Studiengang Biomechatronik;
  - Nutzung der Ergebnisse und Infrastruktur zur Einwerbung weiterer Drittmittel; es ist unter anderem aufbauend auf den Ergebnissen und der Infrastruktur des Projekts bereits gelungen, einen Verbundantrag (Forschungsnetzwerke NRW)<sup>19</sup> einzuwerben,

<sup>19</sup><https://www.land.nrw/pressemitteilung/81-millionen-euro-landesfoerderung-fuer-fuenf-exzellente-forschungsnetzwerke>

der sich mit dem gesamten Lebenszyklus und der Nachhaltigkeit intelligenter technischer Systeme beschäftigt.

- Die Ergebnisse des Projekts und hier erarbeiteten Materialien werden durch das CoR-Lab weiterhin gehostet und stehen dadurch einfach zur Verfügung <https://its-ml.de/>.

#### ■ Universität Paderborn:

- Integration der Ergebnisse, Technologien und Lernmaterialien in das Leistungs-Portfolio der zentralen wissenschaftlichen Einrichtung SI-Lab, mit dem Ziel des Wissenschaftstransfers und Austauschs hin zu neuen Anwendungsfeldern (KI/ML).
- Nutzung der spezifischen Erkenntnisse in den Workshops im Kontext nachhaltige digital Infrastrukturen und sozio-technische Ökosysteme in der Wechselwirkung mit KI/ML, insbesondere im Kooperationsverbund SICP.
- Nutzung der Ergebnisse und Erkenntnisse zur Einwerbung weiterer Drittmittel; Hier werden in 2022 voraussichtlich in zwei Vorhaben im Anwendungsbereich Energie und Rechenzentren beginnen.
- Weiterführende Nutzung der Erkenntnisse in zukünftigen wissenschaftlichen Publikationen und Fachzeitschriften.
- Integration der identifizierten Herausforderungen in studentische wissenschaftliche Arbeiten.
- Nicht wissenschaftlich aber wichtig, die Nutzung der Erkenntnisse zur Durchführung von Vorhaben während einer Pandemie.

#### ■ Fachhochschule Bielefeld:

- Publikation der Ergebnisse in Fachzeitschriften: Im Rahmen des Projekts sind an der Fachhochschule Bielefeld sechs Publikationen/Manuskripte entstanden.
- Die in den Teilprojekten der Fachhochschule Bielefeld erhobenen Experimentaldaten wurden in Form von Datenpublikationen veröffentlicht bzw. befinden sich in der Veröffentlichung.
- Verwendung der Ergebnisse für die Einwerbung weiterer Drittmittel; z.B. erfolgreiche Beteiligung am oben genannten Verbundantrag (Forschungsnetzwerke NRW);
- Integration der Lehrmaterialien in den BEng Studiengang Ingenieurinformatik sowie in den gemeinsamen MSc Studiengang Biomechatronik.
- Integration der entwickelten Algorithmen in Tool-Chains des CfADS;
- Die gewonnenen Erkenntnisse werden über das ISyM und das CfADS in verschiedene Anwendungen transferiert (itsOWL-TP-PsyMe, itsOWL-Transferprojekt "Computer Vision in der Abfallwirtschaft").

#### ■ Technische Hochschule OWL:

- Publikation der Ergebnisse in Fachzeitschriften: Im Rahmen des Projekts sind an der Technischen Hochschule OWL sieben Publikationen entstanden.
- Die fortschreitenden Entwicklungen der adressierten Themenschwerpunkte flossen direkt in den Aufbau des Bachelorkurses „Künstliche Intelligenz“ der Technischen Hochschule OWL ein. Der Kurs wird seit dem Wintersemester 2020/2021 als Wahlpflichtmodul im Fachbereich Elektrotechnik und Technische Informatik angeboten. Die bestehenden Lehrveranstaltungen „Maschinelles Lernen“ (Bachelorkurs) und „Information Fusion“ (Masterkurs) konnten durch neue Erkenntnisse weiterentwickelt werden.
- Die entwickelten theoretischen und praktischen Erkenntnisse und das gewonnene Erfahrungswissen dienen als Ausgangsbasis für weitere Forschungsarbeiten. So vertieft z.B. der erfolgreich eingereichte Verbundantrag „SAIL - SustAInable Life-cycle of Intelligent Socio-Technical Systems“ die bestehende Kooperationsstrukturen im Bereich der KI und entwickelt sie, mit dem Ziel diese langfristig zu verstetigen, weiter.
- Ein Wissenstransfer und -austausch mit regionalen Unternehmen und Forschungseinrichtungen findet in regelmäßigen Workshops und Seminaren statt. Eine sinnvolle Aufarbeitung und Präsentation der Ergebnisse ist unter anderem in dem Arbeitswelt.Plus Workshop „KI in der Anwendung – Vorausschauende Wartung“ möglich. Der Workshop führt kleine und mittelständische Unternehmen in OWL in das Themengebiet des maschinellen Lernens ein, klärt die Voraussetzungen für die vorausschauende Wartung im eigenen Unternehmen und zeigt Wege der erfolgreichen Umsetzung auf.

## Fortschritte auf dem Gebiet bei anderen Stellen

Die im Projekt **ITS.ML** betrachteten Themen sind generell von großer Relevanz und Gegenstand von Forschung und Entwicklung. Im Projekt wurde der Stand der Technik regelmäßig recherchiert und in der Projektarbeit entsprechend berücksichtigt. Dieses geschah auf folgenden Ebenen:

- **Forschung:** Im Bereich der Forschung haben sich in den letzten Jahren mehrere der im Projekt vorgeschlagenen Innovationsbereiche aufgrund ihrer Relevanz als zentrale Schwerpunkte in der KI-Forschung etabliert. Dazu gehört der Aspekt der Erklärbarkeit von KI-Modellen [Mol22], Energie-effizientes Lernen [Xu+21], Daten-effizientes Lernen [Son+22], die hohe Relevanz von Auto-ML Methoden [ZH19], und die stetige Entwicklung neuer tiefer Architekturen für relevante Herausforderungen etwa in der Bildverarbeitung [Alz+21]. Diese Entwicklungen wurden im Projekt widergespiegelt und hinsichtlich ihrer Relevanz für den speziellen Fokus des Projekts auf die Anwendbarkeit für den Bereich der intelligenten technischen Systeme gelegt.

- **Rechtliche Rahmenbedingungen und Anforderungen:** Im Bereich der KI entstehen neben der rein funktionalen Anforderung an Algorithmen und Produkte Anforderungen aus der Perspektive des Datenschutzes, der Sicherheit, Fairness und die Vermeidung von Diskriminierung, sowie des Erhalt der Selbstbestimmung des menschlichen Akteurs. Unter anderem arbeitet die Europäische Union an entsprechenden Anforderungen, die dann in konkrete Gesetze überführt werden.<sup>20</sup> Im Rahmen des Projekts wurde diesem dadurch Rechnung getragen, dass gezielt Aspekte untersucht wurden, die über die reine Funktionalität hinausgehen. Dieses betraf zum Einen Möglichkeiten der Erklärung von KI-Modellen sowie Methoden, diese Erklärungen zu evaluieren [KAH22a; KSH22; SL21]. Untersuchungen zu einem intuitiven Umgangs mit KI und der Möglichkeit, diese als naiver Nutzer zu gestalten [Gop+21], Des Weiteren fielen hierunter Methoden zur expliziten Modellierung von Beschränkungen von KI-Modellen [NSH22; Kum+21], Verfahren, die geeignet sind, die Robustheit von KI-Modellen im laufenden Betrieb zu erhöhen [HL22; HL21], sowie Methoden mit minimiertem Energieverbrauch [Tor+21b].
- **Infrastruktur und Anwendungsdomänen:** Im Projekt wurde darauf Wert gelegt, dass insbesondere Software-Entwicklungen mit gebräuchlichen Programmierumgebungen und ML-Tools kompatibel sind (etwa Scikit-Learn, PyTorch, River). Neben industriellen Anwendungen spielen die entwickelten Methoden eine große Rolle auch im medizinischen Kontext. Auch in diesem Bereich wurden bereits erste Erfahrungen im Rahmen von Anwendungsprojekten gemacht [Kum+21].

## Veröffentlichung der Ergebnisse

Im Rahmen des Projekts konnten folgende Publikationen in internationalen Organen publiziert bzw. eingereicht werden:

- [BHS19] Albert Bifet, Barbara Hammer und Frank-Michael Schleif. „Recent trends in streaming data analysis, concept drift and analysis of dynamic data sets“. In: *Proc. European Symposium on Artificial Neural Networks* (24. Apr. 2019). URL: <https://www.elen.ucl.ac.be/Proceedings/esann/esannpdf/es2019-3.pdf> (besucht am 01.01.2019). published.
- [EHN19] Benedikt Eiteneuer, Nemanja Hranisavljevic und Oliver Niggemann. „Dimensionality Reduction and Anomaly Detection for CPPS Data using Autoencoder“. In: *International Conference on Industrial Technology* (4. Juli 2019). DOI: [10.1109/ICIT.2019.8755116](https://doi.org/10.1109/ICIT.2019.8755116). URL: <https://ieeexplore.ieee.org/document/8755116> (besucht am 01.01.2019). published.

<sup>20</sup>Etwa: White Paper on Artificial Intelligence: a European approach to excellence and trust, 19 February 2020, [https://ec.europa.eu/info/publications/white-paper-artificial-intelligence-european-approach-excellence-and-trust\\_de](https://ec.europa.eu/info/publications/white-paper-artificial-intelligence-european-approach-excellence-and-trust_de)

- [Göp+19] Christina Göpfert u. a. „When can unlabeled data improve the learning rate?“ In: *arXiv preprint arXiv:1905.11866* (25. Juni 2019). URL: <https://arxiv.org/abs/1905.11866> (besucht am 01.01.2019). published.
- [HL19] Christoph-Alexander Holst und Volker Lohweg. „Feature fusion to increase the robustness of machine learners in industrial environments“. In: *at - Automatisierungstechnik* 67.10 (27. Sep. 2019), S. 853–865. DOI: [10.1515/auto-2019-0028](https://doi.org/10.1515/auto-2019-0028). (Besucht am 01.01.2019). published.
- [Pfa+19] Lukas Pfannschmidt u. a. „Feature Relevance Bounds for Ordinal Regression“. In: *Proc. European Symposium on Artificial Neural Networks, 2019*. (20. Feb. 2019). URL: <https://www.ele.ucl.ac.be/Proceedings/esann/esannpdf/es2019-162.pdf> (besucht am 01.01.2019). published.
- [BW20] Marco Braun und Sebastian Wrede. „Incorporation of Expert Knowledge for Learning Robotic Assembly Tasks“. In: *2020 IEEE 25th International Conference on Emerging Technologies and Factory Automation (ETFA)*. IEEE, 8. Sep. 2020. ISBN: 978-1-7281-8956-7. DOI: [10.1109/ETFA46521.2020.9211917](https://doi.org/10.1109/ETFA46521.2020.9211917). URL: <https://ieeexplore.ieee.org/document/9211917/>. published.
- [BH20a] Johannes Brinkrolf und Barbara Hammer. „Sparse Metric Learning in Prototype-based Classification“. In: *28th European Symposium on Artificial Neural Networks, Computational Intelligence and Machine Learning, ESANN 2020, Bruges, Belgium, October 2-4, 2020*. 2. Okt. 2020, S. 375–380. URL: <https://www.esann.org/sites/default/files/proceedings/2020/ES2020-138.pdf> (besucht am 02.10.2020). published.
- [BH20b] Johannes Brinkrolf und Barbara Hammer. „Time integration and reject options for probabilistic output of pairwise LVQ“. In: *Neural Computing and Applications* 32.24 (1. Dez. 2020), S. 18009–18022. DOI: [10.1007/s00521-018-03966-0](https://doi.org/10.1007/s00521-018-03966-0). URL: <https://doi.org/10.1007/s00521-018-03966-0> (besucht am 01.12.2020). published.
- [HAH20] Fabian Hinder, André Artelt und Barbara Hammer. „Towards Non-Parametric Drift Detection via Dynamic Adapting Window Independence Drift Detection (DAWIDD)“. In: *Proceedings of the 37th International Conference on Machine Learning, ICML 2020, 13-18 July 2020, Virtual Event*. Bd. 119. Proceedings of Machine Learning Research. PMLR, 1. Nov. 2020, S. 4249–4259. URL: <http://proceedings.mlr.press/v119/hinder20a.html> (besucht am 01.01.2020). published.
- [HKH20] Fabian Hinder, Johannes Kummert und Barbara Hammer. „Explaining Concept Drift by Mean of Direction“. In: *Artificial Neural Networks and Machine Learning - ICANN 2020 - 29th International Conference on Artificial Neural Networks, Bratislava, Slovakia, September 15-18, 2020, Proceedings, Part I*. Hrsg. von Igor Farkas, Paolo Masulli und Stefan Wermter. Bd. 12396. Lecture Notes in Computer Science. Springer, 1. Sep. 2020, S. 379–390. DOI: [10.1007/978-3-030-61609-0\\_30](https://doi.org/10.1007/978-3-030-61609-0_30). URL:

- [https://doi.org/10.1007/978-3-030-61609-0\\_30](https://doi.org/10.1007/978-3-030-61609-0_30) (besucht am 01.01.2020). published.
- [HL20] Christoph-Alexander Holst und Volker Lohweg. „A Redundancy Metric based on the Framework of Possibility Theory for Technical Systems“. In: *2020 IEEE 25th International Conference on Emerging Technologies and Factory Automation (ETFA)*. Bd. 1. IEEE, 5. Okt. 2020, S. 1571–1578. DOI: [10.1109/ETFA46521.2020.9212080](https://doi.org/10.1109/ETFA46521.2020.9212080). (Besucht am 01.01.2020). published.
- [Pfa+20] Lukas Pfannschmidt u. a. „Feature Relevance Determination for Ordinal Regression in the Context of Feature Redundancies and Privileged Information“. In: *Neurocomputing* (9. Apr. 2020). DOI: [10.1016/j.neucom.2019.12.133](https://doi.org/10.1016/j.neucom.2019.12.133). URL: <https://www.sciencedirect.com/science/article/abs/pii/S0925231220305038> (besucht am 20.03.2020). published.
- [SHH20] Alexander Schulz, Fabian Hinder und Barbara Hammer. „DeepView: Visualizing Classification Boundaries of Deep Neural Networks as Scatter Plots Using Discriminative Dimensionality Reduction“. In: *Proceedings of the Twenty-Ninth International Joint Conference on Artificial Intelligence, IJCAI-20*. Hrsg. von Christian Bessiere. Main track. International Joint Conferences on Artificial Intelligence Organization, 1. Juli 2020, S. 2305–2311. DOI: [10.24963/ijcai.2020/319](https://doi.org/10.24963/ijcai.2020/319). URL: <https://doi.org/10.24963/ijcai.2020/319> (besucht am 01.01.2020). published.
- [SH20] Mohammad Hossein Shaker und Eyke Hüllermeier. „Aleatoric and Epistemic Uncertainty with Random Forests“. In: *arXiv:2001.00893* (3. Jan. 2020). arXiv: 2001.00893. URL: <http://arxiv.org/abs/2001.00893> (besucht am 27.06.2022). published.
- [Tor+20] Tanja Tornede u. a. „AutoML for Predictive Maintenance: One Tool to RUL Them All“. In: *IoT Streams for Data-Driven Predictive Maintenance and IoT, Edge, and Mobile for Embedded Machine Learning*. Bd. 1325. Communications in Computer and Information Science. Springer, 14. Sep. 2020, S. 106–118. DOI: [10.1007/978-3-030-66770-2\\_8](https://doi.org/10.1007/978-3-030-66770-2_8). published.
- [BW21] Marco Braun und Sebastian Wrede. „Combining Manipulation Primitive Nets and Policy Gradient Methods for Learning Robotic Assembly Tasks“. In: *Proceedings of the DGR Days 2021*. 6. Okt. 2021. URL: <https://indico.scc.kit.edu/event/2389/attachments/4350/6716/DGR-2021-Proceedings.pdf> (besucht am 06.10.2021). published.
- [Buc+21] Florian Buckermann u. a. „Automating the optical identification of abrasive wear on electrical contact pins“. In: *Autom.* 69.10 (1. Okt. 2021), S. 903–914. DOI: [10.1515/auto-2021-0021](https://doi.org/10.1515/auto-2021-0021). URL: <https://doi.org/10.1515/auto-2021-0021> (besucht am 01.10.2021). published.

- [Gop+21] Jan Philip Gopfert u. a. „Intuitiveness in Active Teaching“. In: *IEEE Transactions on Human-Machine Systems* (13. Nov. 2021), S. 1–10. ISSN: 2168-2291, 2168-2305. DOI: [10.1109/THMS.2021.3121666](https://doi.org/10.1109/THMS.2021.3121666). URL: <https://ieeexplore.ieee.org/document/9610180/> (besucht am 13. 11. 2021). published.
- [HL21] Christoph-Alexander Holst und Volker Lohweg. „A Redundancy Metric Set within Possibility Theory for Multi-Sensor Systems“. In: *Sensors* 21.7 (3. Apr. 2021). DOI: [10.3390/s21072508](https://doi.org/10.3390/s21072508). (Besucht am 01. 01. 2021). published.
- [KSS21] Ulrike Kuhl, Sarah Sobotta und Michael A Skeide. „Mathematical learning deficits originate in early childhood from atypical development of a frontoparietal brain network“. In: *PLoS Biol* 19.9 (30. Sep. 2021), e3001407. ISSN: 1545-7885. DOI: [10.1371/journal.pbio.3001407](https://doi.org/10.1371/journal.pbio.3001407). (Besucht am 01. 01. 2021). published.
- [Kum+21] Johannes Kummert u. a. „Efficient Reject Options for Particle Filter Object Tracking in Medical Applications“. In: *Sensors* 21.6 (17. März 2021), S. 2114. DOI: <https://doi.org/10.3390/s21062114>. (Besucht am 17. 03. 2021). published.
- [PL21] Anton Pfeifer und Volker Lohweg. „Classification of Faults in Cyber-Physical Systems with Complex-Valued Neural Networks“. In: *26th IEEE International Conference on Emerging Technologies and Factory Automation (ETFA)*. IEEE, 30. Nov. 2021. DOI: [10.1109/ETFA45728.2021.9613451](https://doi.org/10.1109/ETFA45728.2021.9613451). (Besucht am 30. 11. 2021). published.
- [SL21] Malte Schmidt und Volker Lohweg. „Interval-based Interpretable Decision Tree for Time Series Classification“. In: *Proceedings - 31. Workshop Computational Intelligence*. Hrsg. von Horst Schulte, Frank Hoffmann und Ralf Mikut. KIT Scientific Publishing, 25. Nov. 2021, S. 91–111. DOI: [10.5445/KSP/1000138532](https://doi.org/10.5445/KSP/1000138532). (Besucht am 25. 11. 2021). published.
- [Sha+21] Zafran Hussain Shah u. a. „Deep-learning based denoising and reconstruction of super-resolution structured illumination microscopy images“. In: *Photonics Research* 9.5 (14. Apr. 2021), B168–B181. DOI: [10.1364/PRJ.416437](https://doi.org/10.1364/PRJ.416437). (Besucht am 14. 04. 2021). published.
- [Tor+21a] Tanja Tornede u. a. „Coevolution of remaining useful lifetime estimation pipelines for automated predictive maintenance“. In: *GECCO '21: Genetic and Evolutionary Computation Conference*. ACM, 26. Juni 2021, S. 368–376. DOI: [10.1145/3449639.3459395](https://doi.org/10.1145/3449639.3459395). published.
- [Tor+21b] Tanja Tornede u. a. „Towards Green Automated Machine Learning: Status Quo and Future Directions“. In: *CoRR* abs/2111.05850 (10. Nov. 2021). URL: <https://arxiv.org/abs/2111.05850> (besucht am 27. 06. 2022). published.
- [Gri+22] Nils Grimmelsmann u. a. „Subject independent, universal parameter determination of a musculoskeletal elbow joint model for sEMG-based movement prediction“. In: *PLOS ONE* (2022). in prep. Im Erscheinen.

- [HL22] Christoph-Alexander Holst und Volker Lohweg. „Designing Possibilistic Information Fusion - The Importance of Associativity, Consistency, and Redundancy“. In: *Metrology* 2.1 (2022). submitted. published.
- [Kna22] Julian Knaup. *Impact of Class Assignment on Multinomial Classification Using Multi-Valued Neurons*. Springer Vieweg Wiesbaden, Aug. 2022. DOI: [10.1007/978-3-658-38955-0](https://doi.org/10.1007/978-3-658-38955-0). URL: <https://link.springer.com/book/10.1007/978-3-658-38955-0>. published.
- [KAH22a] Ulrike Kuhl, André Artelt und Barbara Hammer. „Keep Your Friends Close and Your Counterfactuals Closer: Improved Learning From Closest Rather Than Plausible Counterfactual Explanations in an Abstract Setting“. In: *2022 ACM Conference on Fairness, Accountability, and Transparency (FAccT '22), June 21–24, 2022, Seoul, Republic of Korea*. 23. Juni 2022. DOI: [10.1145/3531146.3534630](https://doi.org/10.1145/3531146.3534630). (Besucht am 23.06.2022). published.
- [KAH22b] Ulrike Kuhl, André Artelt und Barbara Hammer. „Let’s Go to the Alien Zoo: Introducing an Experimental Framework to Study Usability of Counterfactual Explanations for Machine Learning“. In: *arXiv preprint* (6. Mai 2022). DOI: [arXiv:2205.03398](https://arxiv.org/abs/2205.03398). (Besucht am 06.05.2022). published.
- [KSH22] Johannes Kummert, Alexander Schulz und Barbara Hammer. „Metric Learning with Self Adjusting Memory for Explaining Feature Drift“. In: *SNCS S.I. Computational Intelligenece (2022)*. submitted. published.
- [Les+22] David Leserri u. a. „Evaluation of sEMG signal features and segmentation parameters for limb movement prediction using a feedforward neural network.“ In: *MDPI Mathematics, Special Issue on Machine Learning for Technical Systems (2022)*. Hrsg. von Wolfram Schenck und Alaa Tharwat. accepted. ISSN: 2227-7390. published.
- [Mec+22a] Malte Mechtenberg u. a. „Manual and semi-automatic determination of elbow angle-independent parameters for a model of the biceps brachii distal tendon based on ultrasonic imaging“. In: *PLOS ONE* (2022). submitted. published.
- [Mec+22b] Malte Mechtenberg u. a. „Surface electromyographic recordings of the biceps and triceps brachii for various postures, motion velocities and load conditions“. In: *Data publication, Bielefeld University of Applied Sciences (2022)*. DOI: [10.57720/1956](https://doi.org/10.57720/1956). published.
- [NSH22] Vu-Linh Nguyen, Mohammad Hossein Shaker und Eyke Hüllermeier. „How to measure uncertainty in uncertainty sampling for active learning“. In: *Machine Learning* 111.1 (1. Jan. 2022), S. 89–122. DOI: [10.1007/s10994-021-06003-9](https://doi.org/10.1007/s10994-021-06003-9). published.
- [Sha+22] Zafran Hussain Shah u. a. „Impact of different loss functions on denoising microscopic images“. In: *2022 International Joint Conference on Neural Networks*. accepted. 2022. published.

- [Van+22] Koenraad Vandevoorde u. a. „Using Artificial Intelligence for Assistance Systems to Bring Motor Learning Principles into Real World Motor Tasks“. In: *Sensors* 22.7 (2022). (DOI: 10.3390/s22072481), S. 2481. DOI: [10.3390/s22072481](https://doi.org/10.3390/s22072481). published.

Im Folgenden befindet sich alle im Bericht referenzierte Literatur, die nicht im Projekt selber entstanden ist:

## Literatur

- [Büt+17] S. Büttner u. a. „Towards Intelligent Error-Handling Assistance Trough Interactive Alarm Flood Reduction“. In: *CD-MAKE* (17).
- [Hül+08] E. Hüllermeier u. a. „Label ranking by learning pairwise preferences“. In: *Artificial Intelligence* 172 (2008), S. 1897–1917.
- [Bif+10] A. Bifet u. a. „MOA: Massive Online Analysis“. In: 11 (2010), S. 1601–1604.
- [KSM10] A. Kaiser, W. Schenck und R. Möller. „Coupled singular value decomposition of a cross covariance matrix“. In: *International Journal of Neural Systems* 20.4 (2010), S. 293–318.
- [Pe11] F. Pedregosa und et al. „Scikit-learn: Machine Learning in Python“. In: *JMLR* 12 (2011), S. 2825–2830.
- [Sch11] W. Schenck. „Kinematic motor learning“. In: *Connection Science* 23.4 (2011), S. 239–283.
- [CRR12] M. W. Chang, L. A. Ratinov und D. Roth. „Structured learning with constrained conditional models“. In: *Machine Learning* 88.3 (2012), S. 399–431.
- [Dem+12] K. Dembczynski u. a. „On label dependence and loss minimization in multi-label classification“. In: *Machine Learning* 88.1-2 (2012), S. 5–45.
- [NS+12] O. Niggemann, B. Stein u. a. „Learning Behavior Models for Hybrid Timed Systems“. In: *AAAI* (2012).
- [BCV13] Y. Bengio, A. Courville und P. Vincent. „Representation Learning: A Review and New Perspectives“. In: *in IEEE Transactions on Pattern Analysis and Machine Intelligence* 35.8 (2013), S. 1798–1828.
- [HK13] M. Hofmann und R. Klinkenberg. „RapidMiner: Data Mining Use Cases and Business Analytics Applications (Chapman and Hall/CRC Data Mining and Knowledge Discovery Series)“. In: *CRC Press, October 25* (2013).
- [KSM13] A. Kaiser, W. Schenck und R. Möller. „Solving the correspondence problem in stereo vision by internal simulation“. In: *Adaptive Behavior* 21.4 (2013), S. 239–250.
- [Lac+13] J. Lachmair u. a. „A reconfigurable neuroprocessor for self-organizing feature maps“. In: *Neurocomputing* 112 (2013), S. 189–199.

- [Ngo+13] A-C Ngonga Ngomo u. a. *Sorry, i don't speak SPARQL - translating SPARQL queries into natural language*, WWW. 2013.
- [Pas+13] J. Paskarbeit u. a. „A self-contained elastic joint drive for robotics applications based on a sensorized elastomer coupling—Design and identification, Sensors and Actuators“. In: *Physica A* 199 (2013), S. 55–66.
- [SPH13] L. Sterpone, M. Porrman und J. Hagemeyer. „A Novel Fault Tolerant and Runtime Reconfigurable Platform for Satellite Payload Processing“. In: *IEEE Transactions on Computers* 62.8 (2013), S. 1508–1525.
- [Bus+14] R. Busa-Fekete u. a. „Preference-based reinforcement learning: Evolutionary direct policy search using a preference-based racing algorithm“. In: *Machine Learning* 97.3 (2014), S. 327–351.
- [CC14] B. Clarke und J-h Chu. „Generic Feature Selection with Short Fat Data“. In: *J Indian Soc Agric Stat* 68.2 (2014), S. 145–162.
- [Dem+14] K. Dembczynski u. a. „On the Bayes-optimality of F-measure maximizers“. In: *Journal of Machine Learning Research* 15 (2014), S. 3333–3388.
- [NYC14] A. Nguyen, J. Yosinski und J. Clune. *Deep Neural Networks are Easily Fooled: High Confidence Predictions for Unrecognizable Images*. 2014. arXiv: [1412.1897](https://arxiv.org/abs/1412.1897).
- [RKN14] M. Rathke, J. Kölling und T. W. Nattkemper. „Interactive and dynamic web-based visual exploration of high dimensional bioimages with real time clustering“. In: *GCB* (2014), S. 44–53.
- [Vdi14] Vdi/vde. „Industrie 4.0 Statusreport and Wertschöpfungsketten“. 2014.
- [BS15] D. Basa und A. Schneider. „Learning point-to-point movements on an elastic limb using dynamic movement primitives“. In: *Robotics and Autonomous Systems* 66 (2015), S. 55–63.
- [Dit+15] G. Ditzler u. a. „Learning in Nonstationary Environments: A Survey“. In: *Int. Mag IEEE Comp* 10.4 (2015), S. 12–25.
- [Eic+15] J. Eickmeyer u. a. *Data Driven Modeling for System-Level Condition Monitoring on Wind Power Plants*. DX, 2015.
- [LBH15] Y. LeCun, Y. Bengio und G. Hinton. „Deep learning“. In: *Nature* 521 (2015), S. 436–444.
- [NL15] O. Niggemann und V. Lohweg. *On the Diagnosis of Cyber-Physical Production Systems*. 2015.
- [Pas+15] J. Paskarbeit u. a. „Obstacle crossing of a real compliant robot based on local evasion movements and averaging of stance heights using singular value decomposition“. In: *ICRA* 215 (2015).
- [Sch15] J. Schmidhuber. „Deep learning in neural networks: An overview“. In: *Neural Networks* 61 (2015), S. 85–117.

- [SGH15] A. Schulz, A. Gisbrecht und B. Hammer. „Using discriminative dimensionality reduction to visualize classifiers“. In: *Neural Processing Letters* 42.1 (2015), S. 27–54.
- [Szö+15] B. Szörenyi u. a. *Online F-Measure Optimization*. NIPS, 2015.
- [WNS15] S. Windmann, O. Niggemann und H. Stichweh. *Energy efficiency optimization by automatic coordination of motor speeds in conveying systems*. ICIT, 2015.
- [Bin+16] S. Bince u. a. *Towards SPARQL-Based Induction for Large-Scale RDF Data Sets*. ECAI, 2016.
- [Bri+16] J. Brinkrolf u. a. *Virtual optimisation for improved production planning*. New Challenges in Neural Computation, 2016.
- [FHW16a] L. Fischer, B. Hammer und H. Wersing. „Optimal local rejection for classifiers“. In: *Neurocomputing* 214 (2016), S. 445–457.
- [FHW16b] E. Frank, M. A. Hall und I. H. Witten. „The WEKA Workbench“. In: *Online Appendix for Data Mining: Practical Machine Learning Tools and Techniques, Morgan Kaufmann, Fourth Edition 2016* (2016).
- [FT16] E. Friedmann und K. Tzoumas. *Introduction to Apache Flink: Stream Processing for Real Time and Beyond*. O’Reilly, 2016.
- [HDH16] J. Heymann, L. Drude und R. Haeb-Umbach. *Neural Network based spectral mask estimation for acoustic beamforming, IEEE Int’l Conf. Speech, and Signal Processing: Acoustics*, 2016.
- [LHW16] V. Losing, B. Hammer und H. Wersing. *Knn Classifier with Self Adjusting Memory for Heterogeneous Concept Drift*. IEEE ICDM, 2016.
- [Mai+16] A. Maier u. a. „Internet of Things: Cybermanufacturing Systems for the Smart Factory - Solutions for Condition Monitoring, Diagnosis and Optimization“. In: 2016.
- [Mön+16] U. Mönks u. a. „Information Fusion of Conflicting Input Data“. In: *Sensors* 16 (2016), S. 11.
- [OP+16] A. Oleksiak, M. Pormann u. a. *Data centres for IoT applications: The M2DC approach*. SAMOS, 2016.
- [QRS16] J. F. Queiser, R. F. Reinhart und J. J. Steil. „Incremental bootstrapping of parameterized motor skills“. In: *Humanoids 2016* (2016), S. 223–229.
- [ANR17] C. Alippi, S. Ntalampiras und M. Roveri. „Model-Free Fault Detection and Isolation in Large-Scale Cyber-Physical Systems.“ In: *IEEE Trans on Emerging Topics in Comput. Intellig.* 1.1 (2017), S. 61–71.
- [AR17] C. Alippi und M. Roveri. „The (Not)Far-Away Path to Smart Cyber-Physical Systems: An Information-Centric Framework“. In: *IEEE Computer* 50.4 (2017), S. 38–47.

- [Car17] G. Carter. „How Machine Learning is Transforming Logistics“. In: *Globaltranz, Oct 18* (2017).
- [Ebb+17] J. Ebbers u. a. „Hidden Markov Model Variational Autoencoder for Acoustic Unit Discovery“. In: *Proc. Interspeech*, 2017.
- [EMH17] H. M. Eraqi, M. N. Moustafa und J. Honer. *End-to-End Deep Learning for Steering Autonomous Vehicles Considering Temporal Dependencies*. NIPSWorkshop MLITS, 2017.
- [Erm+17] I. Ermilov u. a. *The Tale of Sansa Spark*. Demos und Industry Tracks: International Semantic Web Conference (Posters), 2017.
- [Fag17] D. Fagella. „Machine Learning in Robotics – 5 Modern Applications“. In: *Techemerge Dc 5* (2017).
- [Höf+17] K. Höffner u. a. „Survey on challenges of Question Answering in the Semantic Web“. In: *Semantic Web 8.6* (2017), S. 895–920.
- [Irw+17] A. Irwansyah u. a. „J“. In: *Parallel Distrib. Comput.* 107 (2017), S. 146–161.
- [Kle+17] A. Klein u. a. „Fast Bayesian Optimization of Machine Learning Hyperparameters on Large Datasets“. In: *AISTATS* (2017), S. 528–536.
- [Kot+17] L. Kotthoff u. a. „Automatic model selection and hyperparameter optimization in WEKA“. In: *Journal of Machine Learning Research* 25.5 (2017), S. 25–1.
- [Lea17] Forbes Technology Council For Machine Learning. „It’s All About GPUs“. In: *Forbes Dec 1* (2017).
- [Lin17] D. Linthicum. „Make sense of edge computing vs. cloud computing“. In: *InfoWorld, May 23* (2017).
- [MEC17] P. Menke, B. Ell und P. Cimiano. „On the origin of annotations: A module-based approach to representing annotations in the Natural Language Processing Interchange Format (NIF)“. In: *Applied Ontology* 12.2 (2017), S. 131–155.
- [Paa+17] B. Paaßen u. a. *An EM transfer learning algorithm with applications in bionic hand prostheses*. ESANN, 2017.
- [PNW17] F. Pethig, O. Niggemann und A. Walter. *Towards Industrie 4.0 Compliant Configuration of Condition Monitoring Services*. INDIN, 2017.
- [RSS17] R. F. Reinhart, Z. Shareef und J. J. Steil. „Hybrid Analytical and Data-Driven Modeling for Feed-Forward Robot Control“. In: *Sensors* 17 (2017), S. 2.
- [RUN17] M. Röder, R. Usbeck und A-C Ngonga Ngomo. *GERBIL — Benchmarking Named Entity Recognition and Linking Consistently*. Semantic Web Journal, 2017.
- [San+17] C. L. Sang u. a. „An Adaptive Acknowledgement On-demand Protocol for Wireless Sensor Networks“. In: *SENSORNETS* (2017), S. 174–181.

- [Sch+17] W. Schenck u. a. „Evaluation and performance modeling of a burst buffer solution“. In: *ACM SIGOPS Operating Systems Review* 50.1 (2017), S. 12–26.
- [Yeg17] S. Yegualp. „11 open source tools to make the most of machine learning“. In: *Info-world*, Oct 5 (2017).
- [Col18] L. Columbus. „10 Ways Machine Learning Is Revolutionizing Marketing“. In: *Forbes* Feb 25 (2018).
- [Göp+18] C. Göpfert u. a. „Interpretation of linear classifiers by means of feature relevance bounds“. In: *Neurocomputing* 298 (2018), S. 69–79.
- [JBe18] O. Niggemann JBeyerer. „Machine Learning in Automation“. In: *Automatisierungstechnik* 66.4 (2018), S. 281–282.
- [LHW18] V. Losing, B. Hammer und H. Wersing. „Incremental on-line learning: A review and comparison of state of the art algorithms“. In: *Neurocomputing* 275 (2018), S. 1261–1274.
- [OVN18] J. Otto, B. Vogel-Heuser und O. Niggemann. „Online parameter estimation for cyber-physical production systems based on mixed integer nonlinear programming, process mining and black-box optimization techniques“. In: *Automatisierungstechnik* 66.4 (2018), S. 331–343.
- [AH19] André Artelt und Barbara Hammer. „On the computation of counterfactual explanations - A survey“. In: *CoRR* abs/1911.07749 (2019). arXiv: [1911.07749](https://arxiv.org/abs/1911.07749). URL: <http://arxiv.org/abs/1911.07749>.
- [ZH19] Marc-André Zöllner und Marco F. Huber. „Survey on Automated Machine Learning“. In: *CoRR* abs/1904.12054 (2019). arXiv: [1904.12054](https://arxiv.org/abs/1904.12054). URL: <http://arxiv.org/abs/1904.12054>.
- [Alz+21] Laith Alzubaidi u. a. „Review of deep learning: concepts, CNN architectures, challenges, applications, future directions“. In: *Journal of Big Data* 8.1 (März 2021), S. 53. ISSN: 2196-1115. DOI: [10.1186/s40537-021-00444-8](https://doi.org/10.1186/s40537-021-00444-8). URL: <https://doi.org/10.1186/s40537-021-00444-8>.
- [Mon+21] Jacob Montiel u. a. *River: machine learning for streaming data in Python*. 2021.
- [Xu+21] Jingjing Xu u. a. „A Survey on Green Deep Learning“. In: *CoRR* abs/2111.05193 (2021). arXiv: [2111.05193](https://arxiv.org/abs/2111.05193). URL: <https://arxiv.org/abs/2111.05193>.
- [Mol22] Christoph Molnar. *Interpretable Machine Learning. A Guide for Making Black Box Models Explainable*. 2. Aufl. 2022. URL: <https://christophm.github.io/interpretable-ml-book>.
- [Son+22] Yisheng Song u. a. *A Comprehensive Survey of Few-shot Learning: Evolution, Applications, Challenges, and Opportunities*. 2022. DOI: [10.48550/ARXIV.2205.06743](https://arxiv.org/abs/2205.06743). URL: <https://arxiv.org/abs/2205.06743>.

- [BKP] A. A. Benczur, L. Kocsis und R. Palovics. *Online Machine Learning in Big Data Streams*. arXiv: [1802.05872](#).
- [Boh+] S. Bohez u. a. Sensor Fusion for Robot Control through Deep Reinforcement Learning. arXiv: [1703.04550](#).
- [Lip] Z. C. Lipton. *The Myth of Model Interpretability*. arXiv: [1606.03490](#).
- [Rav] M. Ravanelli. *Deep Learning for Distant Speech Recognition*. arXiv: [1712.06086](#).
- [RFR] H. Riechmann, A. Finke und H. Ritter. „Using a cVEP-based Brain-Computer Interface to control a virtual agent“. In: *IEEE Transactions on Neural Systems and Rehabilitation Engineering* 24(6):692-699 2016 ().
- [SPP] R. K. Sinha, R. Pandey und R. Pattnik. „Deep Learning For Computer Vision Tasks: A review“. In: 2018 (). arXiv: [1804.03928](#).
- [Ung+] C. Unger u. a. „Template-based question answering over RDF data“. In: *WWW*. Bd. 2012.
- [Wu+] Y. Wu u. a. *Google’s Neural Machine Translation System: Bridging the Gap between Human and Machine Translation*. arXiv: [1609.08144](#).
- [Zah+] M. Zaharia u. a. „Spark: cluster computing with working sets“. In: *Proceedings of the 2nd USENIX conference on Hot topics in cloud computing (HotCloud’10)*. Berkeley, CA, USA, USENIX Association, S. 10–10.