

1 Einleitung

“People worry that computers will get too smart and take over the world, but the real problem is that they’re too stupid and they’ve already taken over the world.”

„Die Menschen machen sich Sorgen, dass Computer zu intelligent werden und die Welt übernehmen, aber das eigentliche Problem ist, dass sie zu einfältig sind und die Welt bereits übernommen haben.“

- Pedro Domingos, “The Master Algorithm” (DOMINGOS 2018, S. 286)

1.1 Ausgangssituation und Problemstellung

Eigentlich wurde schon vor dem erneuten Aufleben künstlicher Intelligenz (KI) durch generative Modelle gegen Ende des Jahres 2022 ein signifikantes Wirtschaftswachstum durch die Technologie erwartet. Eine Studie von ACCENTURE ging bei einem prognostizierten Basiswachstum von 1,5 Prozent pro Jahr in der produzierenden Industrie davon aus, dass ein Drittel des Wirtschaftswachstums künftiger Jahre allein durch KI induziert würden (vgl. PURDY U. DAUGHERTY 2017, S. 5–11). Darüber hinaus wurde vorhergesagt, dass im produzierenden Gewerbe die größten Impulse durch KI unter allen Wirtschaftszweigen verzeichnet würden (vgl. PURDY U. DAUGHERTY 2017, S. 11).

Diese Effekte sind ausgeblieben. KI liegt bezüglich des Einsatzes hinter anderen Technologien wie Internet of Things (IoT) und additiver Fertigung zurück (s. BITKOM 2022, S. 5). Prognosen und betriebliche Realität klaffen bisher auseinander, vor allem in Hinblick auf den konkreten Praxiseinsatz: Während ein Großteil der Unternehmen über den Einsatz nachdenkt, liegt nach empirischen Studien der aktive Einsatz von KI lediglich bei 8 bis 16 Prozent (s. RAMMER 2021, S. 8; GIERING 2022, S. 56–58). Diese Lücke zwischen Bekanntheit und Anwendung wird auf einige wiederkehrende Hürden zurückgeführt, darunter hohe Kosten, ungeeignete vorhandene IT-Infrastruktur, mangelnde Datenverfügbarkeit und der Mangel von Fachkräften (s. RAMMER 2021, S. 6; GIERING 2022, S. 59–61).

Aus diesen Hürden folgen verschiedene Symptome: So verfügen potenzielle nutzende Personen selten über die nötige interne Kompetenz bzw. die Ressourcen zur Akquise externer Kompetenz, um KI-Anwendungen in ihren Betrieb zu implementieren (s. RAMMER 2021, S. 10–11). Unternehmen geben zudem an, Hilfe bei der Auswahl von Modellen und den dafür passenden Daten zu benötigen (s. REDER ET AL. 2019, S. 22). Darüber hinaus besteht das Problem, dass KI-Modelle häufig intransparent sind, was zu mangelndem Vertrauen in deren Prognosen führt (RAMMER 2021, S. 6). Zusammenfassend lässt sich sagen, dass dem großen wirtschaftlichen Potenzial von Künstlicher Intelligenz Hürden bei der Praxis- und Zielgruppentauglichkeit gegenüberstehen.

Die Ankunft von generativer KI hat beobachtbar gezeigt, dass der Fachkräftemangel und dessen technologisches Begleitsymptom, die unzureichende Nutzungsfreundlichkeit der Technologie, eine besondere Hürde darstellt. Wenn wenig Fachwissen nötig ist, um KI zu nutzen, wird deren breite gesellschaftliche und professionelle Applikation

rasant möglich. Dies lässt sich aktuell verfolgen: Das Vorgängermodell von GPT3.5, nutzbar gemacht durch die Browser-Applikation ChatGPT, wurde unter dem Namen GPT2 bereits im Jahre 2018 in einem Paper vorgestellt und dessen Quellcode öffentlich gemacht (s. RADFORD ET AL. 2019). Damit war das Modell für jeden nutzbar. Bereits zu dieser Zeit verfügte das Modell über eine Leistung, die den Stand der Technik in vielen Belangen übertraf (s. RADFORD ET AL. 2019, S. 5–9) – dennoch war die Nutzung marginal. Erst mit der Bereitstellung als einfach zu verwendende Anwendung im Internetbrowser wurden große Teile von Unternehmen und der Gesellschaft für die Nutzung erschlossen (s. BULL U. KHARRUFA 2024, S. 52). Für die Nutzung von GPT2 wären rudimentäre Kenntnisse in der Programmiersprache Python und in der Nutzung von Quellcode-Repositoryn wie GitHub nötig gewesen.

Softwareunternehmen reagieren auf diese Signale, indem sie immer verwendungsfreundlichere Lösungen bereitstellen, um die Nutzung von KI-Modellen zu ermöglichen und eigene KI-Modelle zu entwickeln, darunter Softwarelösungen für automatisiertes maschinelles Lernen (kurz Auto-ML-Softwarelösungen) (s. CRISAN U. FIORE-GARTLAND 2021, S. 1). Diese verfolgen das Ziel, den Prozess der Erstellung von Modellen maschinellen Lernens teilweise oder vollständig zu automatisieren (vollständige Definition s. Kapitel 2.3 und 2.4). Auto-ML-Softwarelösungen bedienen sich dabei der Tatsache, dass die Erstellung von Modellen maschinellen Lernens einer konsistenten Logik folgt, die sich in großen Teilen für alle Anwendungsfälle wiederholt (s. Kapitel 2.2.6). Die Softwarelösungen automatisieren diese Schritte durch mathematische Heuristiken, integrieren dabei eine grafische Bedienungsoberfläche sowie Datenschnittstellen und bieten somit anwendenden Unternehmen die Möglichkeit, Personen ohne ML-Expertise Modelle erstellen zu lassen sowie erfahrenen Nutzenden, schneller Modelle zu erstellen.

Der mit dem durch diesen Trend verbundene Popularitätszuwachs resultiert in einem wachsenden Anbietermarkt mit einer stetig steigenden Zahl an Lösungen (s. XIN ET AL. 2021, S. 2). Auf diesem Anbietermarkt lassen sich drei Segmente identifizieren, innerhalb derer wiederum eine Vielzahl verschiedener Softwarelösungen existiert: Open-Source-Softwarelösungen sind meist kostenlos, verfügen jedoch nur in Teilen über eine grafische Bedienungsoberfläche und decken meist nicht den kompletten Prozess zur Erstellung von Modellen ab (s. CRISAN U. FIORE-GARTLAND 2021, S. 2). „Best-in-Class“-Lösungen stammen von Unternehmen mit KI-Expertise, die durch Spezialisierung auf diese Art von Software und eine große Zahl an Funktionen ein attraktives, kostenpflichtiges Angebot bereitstellen wollen (s. CRISAN U. FIORE-GARTLAND 2021, S. 2–3). Als letzte Gruppe versuchen Cloud- und Plattform-Unternehmen sich durch nahtlose Integration in ihr bestehendes Software-Ökosystem von der Konkurrenz abzusetzen (s. CRISAN U. FIORE-GARTLAND 2021, S. 2).

Potenzielle anwendende Unternehmen sehen sich somit einer komplexen Anbieterlandschaft gegenüber, wobei für diese neue Art von Softwarelösung noch kein strukturierter Auswahlprozess existiert (s. Kapitel 3.5). Dabei verschärfen drei Faktoren dieses Problem:

- Auto-ML Lösungen sind, ähnlich wie software-definierte Plattformen – ein präziserer Begriff für IoT-Plattformen (s. HOFFMANN 2018, 46) – die Basis für eigens entwickelte Anwendungen. Wenn festgestellt wird, dass die Lösung nicht die vorab definierten Anforderungen erfüllt, ist ein Rückbau und Neueinführung mit hohem Aufwand verbunden
- Der Begriff KI ist nur mangelhaft operationalisiert, d. h. welche Einsatzszenarien wirklich eine Nutzung von KI darstellen, ist im Unternehmenskontext fraglich (s. HOFFMANN 2018, S. 60). Dies erschwert die Abgrenzung von Auto-ML-Softwarelösungen zu anderen Datenanalysewerkzeugen.
- Die Lösungen richten sich unter anderem an Unternehmen, die über wenig KI-Expertise verfügen. Paradoxerweise ist für die korrekte Auswahl von Auto-ML-Softwarelösungen jedoch ein Grundverständnis über KI nötig, da deren Funktionsumfang KI-Algorithmen umfasst (s. Kapitel 5)

1.2 Zielsetzung

Das Dissertationsvorhaben widmet sich der Lösung der oben dargestellten Problemstellung mit dem Ziel, eine Methode zur Auswahl von Auto-ML-Softwarelösungen für Prognosen in produzierenden Unternehmen zu entwickeln. Als Zielgruppe sind insbesondere Digitalisierungsverantwortliche in produzierenden Unternehmen sowie KI-affine Führungskräfte und Verantwortliche in produzierenden kleinen und mittleren Unternehmen (KMU) als potenzielle Auto-ML-Nutzende vorgesehen. Die entwickelte Methode soll dieser Zielgruppe ein strukturiertes Vorgehen bereitstellen, mit dem sie auf Basis ihrer Anforderungen passende Softwarelösungen auswählen können.

Im Rahmen dieser Arbeit werden mehrere Teilziele verfolgt. Zunächst soll eine Grundlage für den Auswahlprozess geschaffen werden, indem auf Basis einer Markt- und Literaturrecherche eine generische Beschreibung der von Auto-ML-Softwarelösungen angebotenen Funktionen erstellt wird. Dies bildet ein Instrument zur strukturierten Untersuchung konkreter Lösungen. Weiterhin sollen die spezifischen Anforderungen von produzierenden Unternehmen für Prognosen mit Auto-ML-Plattformen gesammelt und beschrieben werden. Diese Anforderungsliste dient als Orientierungselement und ermöglicht es Entscheidenden, die wenig Expertise auf dem Gebiet maschinellen Lernens oder der Softwareauswahl besitzen, wohldefinierte Anforderungen zu formulieren. Unternehmen können somit auf Basis vorformulierter Anforderungen wählen, worauf sie den Fokus legen möchten.

Ein weiteres Teilziel ist es, die Zusammenhänge zwischen den Anforderungen der Unternehmen und den Funktionen, die durch die Softwarelösungen geboten werden, zu erläutern. Dadurch wird eine Verbindung zwischen der Expertise der Zielgruppe (geschäftliche Anforderungen) und den technischen Eigenschaften des auszuwählenden Werkzeugs (Funktionen der Auto-ML-Softwarelösung) geschaffen. Dies bereitet das vierte Teilziel vor: die Ableitung eines strukturierten Prozesses, mit dem Unternehmen auf Basis der vorangegangenen synthetisierten Erkenntnisse eine Auto-ML-Softwarelösung identifizieren, evaluieren und auswählen können.

Aus diesen Zielstellungen leitet sich folgende zentrale Forschungsfrage ab: Wie kann eine Methode zur Auswahl von Softwarelösungen für automatisiertes maschinelles Lernen für Prognosen in produzierenden Unternehmen gestaltet werden?

Daraus lassen sich folgende Teilforschungsfragen ableiten:

1. Wie können Softwarelösungen für automatisiertes maschinelles Lernen (kurz: Auto-ML-Softwarelösungen) systematisch beschrieben werden?
2. Wie können Anforderungen von produzierenden Unternehmen an Auto-ML-Softwarelösungen systematisch beschrieben werden?
3. Wie können die Wirkbeziehungen zwischen den Anforderungen und den Funktionen von Auto-ML-Softwarelösungen erklärt werden?
4. Wie kann ein strukturierter Prozess für die Auswahl einer geeigneten Auto-ML-Softwarelösung gestaltet werden?

1.3 Wissenschaftstheoretische Einordnung und Struktur der Untersuchung

Die vorliegende Dissertation widmet sich den Themenbereichen des Ingenieurwesens, der Betriebswirtschaftslehre und der Wirtschaftsinformatik, die wissenschaftstheoretisch den Realwissenschaften zugeordnet werden können (s. ULRICH U. HILL 1976b, S. 305; HOFFMANN 2018, S. 6). Im Gegensatz zu den Formalwissenschaften, wie Mathematik und Logik, die sich auf die Konstruktion von Zeichensystemen konzentrieren, fokussieren sich die Realwissenschaften auf die Untersuchung und Beschreibung von subjektiv wahrgenommenen Ausschnitten der Wirklichkeit (s. ULRICH U. HILL 1976b, S. 305–306).

Ziel dieser Arbeit ist die Entwicklung einer Methode zur Auswahl von Softwarelösungen für automatisiertes maschinelles Lernen, das insbesondere Prognosen in produzierenden Unternehmen ermöglicht. Diese Aufgabenstellung lässt sich innerhalb der realwissenschaftlichen Unterkategorie der Handlungswissenschaften verorten, zu denen auch die Ingenieurwissenschaften und die Betriebswirtschaftslehre gehören (s. ULRICH U. HILL 1976b, S. 305). Die darin enthaltenen Disziplinen beschäftigen sich mit der Analyse menschlicher Handlungsalternativen, um soziale und technische Systeme durch die Entwicklung von Entscheidungsmodellen bzw. -prozessen zu gestalten (s. ULRICH U. HILL 1976b, S. 305–306).

Wissenschaftstheoretisch werden die in dieser Arbeit gestellten Fragen mit Mitteln der Systemtheorie in der Betriebswirtschaftslehre beantwortet. Das Ziel der Systemtheorie in der Betriebswirtschaft ist es, trotz einer theoretischen Fundierung, eine praxisnahe Unternehmensführungslehre zu bieten, die sich realen Problemen widmet (s. ULRICH U. HILL 1976b, S. 308). Detaillierte Erläuterungen zur Systemtheorie und die daraus für diese Arbeit abgeleitete Theorie der Modellbildung zur Lösung betriebswirtschaftlicher Probleme werden im vierten Kapitel vorgestellt (s. Kapitel 4.2). Ein strukturierter Prozess, der sich in diesen wissenschaftstheoretischen Rahmen einfügt, wurde von ULRICH postuliert (s. ULRICH 1981, S. 20). Die darauf basierende Gliederung der

Dissertation wird übersichtlich in Abbildung 1-1 dargestellt und bietet somit einen strukturierten Überblick über die methodische Herangehensweise dieser Forschungsarbeit.

| Kapitel der Arbeit | Inhalt | Phasen der angewandten Forschung nach Ulrich |
|---|---|--|
| 1 Einleitung | <ul style="list-style-type: none"> Problemstellung Forschungsfragen | 1 Erfassung und Typisierung praxisrelevanter Probleme |
| 2 Grundlagen | <ul style="list-style-type: none"> Begriffe und Grundlagen Eingrenzung des Forschungsbereichs | 2 Erfassung & Interpretation relevanter Verfahren der empirischen Grundlagenwissenschaften |
| 3 Stand der Erkenntnisse | <ul style="list-style-type: none"> Relevante Vorarbeiten Forschungslücke | 3 Erfassung und Spezifizierung problemrelevanter Verfahren der Formalwissenschaften |
| 4 Herleitung des Konzeptansatzes | <ul style="list-style-type: none"> Anforderungsdefinition Methodische Grundlagen | 4 Erfassung und Untersuchung des relevanten Anwendungszusammenhangs |
| 5 Beschreibung der Funktionen | <ul style="list-style-type: none"> Identifikation des Funktionsumfangs Strukturierung der Funktionen | 5 Ableitung von Beurteilungskriterien, Gestaltungsregeln und -modellen |
| 6 Beschreibung der Anforderungen | <ul style="list-style-type: none"> Erfassung von Fallstudien Anforderungsaufnahme | 6 Prüfung der Regeln und Modelle im Anwendungszusammenhang |
| 7 Wirkungen zwischen Funktionen und Anforderungen | <ul style="list-style-type: none"> Herleitung der Bewertungskriterien Erklärung der Wirkzusammenhänge | 7 Beratung der Praxis |
| 8 Gestaltung des Auswahlprozesses | <ul style="list-style-type: none"> Integration der Teilmodelle Gestaltung des Prozesses | |
| 9 Evaluation | <ul style="list-style-type: none"> Formale Evaluation Fallstudien | |
| 10 Zusammenfassung und Ausblick | <ul style="list-style-type: none"> Handlungsempfehlungen Forschungsbedarf | |

Abbildung 1-1: Gliederung der Arbeit in Phasen der angewandten Forschung (i. A. a. ULRICH 1981, S. 20)

Zunächst werden in Kapitel 1 die Ausgangssituation sowie die Problemstellung und Zielsetzung erläutert. Darauf aufbauend erfolgt in Kapitel 2 die Definition der relevanten Begriffe sowie eine Eingrenzung des Untersuchungsbereiches. Anschließend werden in Kapitel 3 relevante Vorarbeiten beleuchtet und durch eine Analyse der Veröffentlichungen die Forschungslücke herausgearbeitet. In Kapitel 4 wird der Konzeptansatz hergeleitet, indem auf Basis einer Anforderungsdefinition die notwendigen methodischen Grundlagen identifiziert und integriert werden.

Darauf beginnt die Synthese des ersten Modells und der Beschreibung der Funktionen von Auto-ML-Softwarelösungen in Kapitel 5. In Kapitel 6 wird durch Fallstudienforschung eine Liste der Anforderungen von produzierenden Unternehmen an Auto-ML-Softwarelösungen erstellt. In Kapitel 7 werden die Wirkungen zwischen diesen deskriptiven Teilmodellen durch ein Erklärungsmodell näher beleuchtet. Dieser Schritt ermöglicht die darauffolgende Gestaltung eines Auswahlprozesses für Auto-ML-Softwarelösungen in Kapitel 8. Mit der abschließenden Evaluation in Kapitel 9 wird die Praxistauglichkeit sowie die Erfüllung der in Kapitel 4 postulierten Modellanforderungen geprüft. Kapitel 10 bietet eine Zusammenfassung der Erkenntnisse sowie einen Ausblick auf weiteren Forschungs- und Handlungsbedarf.