

Künstliche Intelligenz mit AutoML, Low-Code und No-Code – Eine Markterhebung von Soft- ware-Tools

Autoren:
Martin Simons
Malte Roloff
Dr. Andrea Liebe
Martin Lundborg



WIK

Wissenschaftliches Institut
für Infrastruktur und
Kommunikationsdienste

Bad Honnef, Dezember 2023

Impressum

WIK Wissenschaftliches Institut für
Infrastruktur und Kommunikationsdienste GmbH
Rhöndorfer Str. 68
53604 Bad Honnef
Deutschland
Tel.: +49 2224 9225-0
Fax: +49 2224 9225-63
E-Mail: info@wik.org
www.wik.org

Vertretungs- und zeichnungsberechtigte Personen

Geschäftsführerin und Direktorin	Dr. Cara Schwarz-Schilling
Direktor Abteilungsleiter Smart Cities/Smart Regions	Alex Kalevi Dieke
Direktor Abteilungsleiter Netze und Kosten	Dr. Thomas Plückebaum
Direktor Abteilungsleiter Regulierung und Wettbewerb	Dr. Bernd Sörries
Leiter der Verwaltung	Karl-Hubert Strüver
Vorsitzender des Aufsichtsrates	Dr. Thomas Solbach
Handelsregister	Amtsgericht Siegburg, HRB 7225
Steuer-Nr.	222/5751/0722
Umsatzsteueridentifikations-Nr.	DE 123 383 795

Stand: Dezember 2023

ISSN 1865-8997

Bildnachweis Titel: © Robert Kneschke - stock.adobe.com

Weitere Diskussionsbeiträge finden Sie hier:

<https://www.wik.org/veroeffentlichungen/diskussionsbeitraege>

In den vom WIK herausgegebenen Diskussionsbeiträgen erscheinen in loser Folge Aufsätze und Vorträge von Mitarbeitern des Instituts sowie ausgewählte Zwischen- und Abschlussberichte von durchgeführten Forschungsprojekten. Mit der Herausgabe dieser Reihe bezweckt das WIK, über seine Tätigkeit zu informieren, Diskussionsanstöße zu geben, aber auch Anregungen von außen zu empfangen. Kritik und Kommentare sind deshalb jederzeit willkommen. Die in den verschiedenen Beiträgen zum Ausdruck kommenden Ansichten geben ausschließlich die Meinung der jeweiligen Autoren wieder. WIK behält sich alle Rechte vor. Ohne ausdrückliche schriftliche Genehmigung des WIK ist es auch nicht gestattet, das Werk oder Teile daraus in irgendeiner Form (Fotokopie, Mikrofilm oder einem anderen Verfahren) zu vervielfältigen oder unter Verwendung elektronischer Systeme zu verarbeiten oder zu verbreiten.

Inhalt	
Zusammenfassung	VII
Summary	VIII
1 Einleitung	1
2 Künstliche Intelligenz und Maschinelles Lernen	5
2.1 Maschinelles Lernen als Basis Künstlicher Intelligenz	5
2.2 Elemente der Künstlichen Intelligenz	9
2.3 Einführung in innovative Ansätze zur Entwicklung und Implementierung von Maschinellern Lernen	10
2.3.1 Automated Machine Learning (AutoML)	11
2.3.2 Low-Code und No-Code	13
2.3.3 Systematisierung	14
2.4 Nutzen von AutoML, Low-Code und No-Code	15
2.4.1 Bedarfe der KMU bei der KI-Integration	16
2.4.2 Potenziale und Vorteile von AutoML, Low-Code und No-Code	17
2.4.3 Limitierungen von AutoML, Low-Code und No-Code	20
2.4.4 Geringere Erklärbarkeit von automatisierten Softwarelösungen	22
2.4.5 Zwischenfazit	23
3 Erhebung des Marktangebotes von AutoML, Low-Code und No-Code	25
3.1 Methodik der Produktidentifizierung	25
3.2 Methodik der Produkterfassung	27
3.3 Erfassung von (Software-)Lösungen	29
3.4 Zwischenfazit	38
4 Potenziale und Herausforderungen für den Mittelstand	40
4.1 Strukturmerkmale des deutschen Mittelstands	40
4.2 Befragung der Mittelstandsexpert:innen	41
4.3 Implikationen der Umfrage	47
5 Schlussbetrachtung	48
5.1 Synopse: Anwendung von AutoML, Low Code- und No-Code Lösungen in KMU	48
5.2 Ausblick	50
Literaturverzeichnis	52
Anhang	57
A1: KI Readiness	57
A2: Deep Dive zu neuronalen Netzen	59
A3: Steckbriefe identifizierter Softwarelösungen	62
A4: Online-Befragung	77
A4.1 Befragte Institutionen	77
A4.2 Fragebogen Online-Befragung	79
A4.3 Weitere Auswertung Online-Befragung	85

Abbildungsverzeichnis

Abbildung 1-1:	Google Trends Zeitverlauf zu Low-Code, No-Code und AutoML (Deutschland)	2
Abbildung 1-2:	Methodische Vorgehensweise	3
Abbildung 2-1:	Definition und Abgrenzung KI und ML	6
Abbildung 2-2:	ML-Taxonomie	8
Abbildung 2-3:	Periodensystem der KI	9
Abbildung 2-4:	Trainingsprozesse von ML und AutoML	12
Abbildung 2-5:	Systematisierung des Untersuchungsgegenstandes	15
Abbildung 2-6:	Einfluss von AutoML, Low-Code und No-Code auf die KI-Readiness von Unternehmen	19
Abbildung 3-1:	Reduktion des identifizierten Marktangebots um einheitlich festgelegte Auswahlkriterien	27
Abbildung 3-2:	Produktsteckbrief Clarifai	30
Abbildung 3-3:	Anbieterübersicht identifizierter AutoML, Low-Code und No-Code Produkte	31
Abbildung 3-4:	Sankey-Diagramm der Anbieter in Abhängigkeit der Software-Lizensierung	33
Abbildung 3-5:	Sankey-Diagramm der Softwareumgebung in Abhängigkeit des Bereitstellungsmodells	34
Abbildung 3-6:	Sankey-Diagramm der Softwareumgebung in Abhängigkeit der Software-Lizensierung	35
Abbildung 3-7:	Produktpalette, dargestellt im Sunburst-Diagramm	37
Abbildung 4-1:	Wie schätzen Sie den Umfang des tatsächlichen Einsatzes von AutoML, No-Code und Low-Code sowie integrativen Lösungen im Mittelstand ein?	43
Abbildung 4-2:	Welche Bedeutung kommt Ihrer Meinung nach den folgenden Kriterien bei der Auswahl von Software-Lösungen im Bereich Low-Code, No-Code und AutoML im Mittelstand zu?	44
Abbildung 4-3:	Bitte geben Sie an, wie hoch Sie den Nutzen des Einsatzes von AutoML, Low-Code und No-Code für den Mittelstand in den folgenden Bereichen einschätzen?	45
Abbildung 4-4:	Bitte geben Sie an, wie ausschlaggebend Sie die folgenden Gründe für einen bis dato fehlenden Einsatz von AutoML, Low-Code und No-Code im Mittelstand ansehen?	46
Abbildung A-1:	KI-Readiness Framework	57
Abbildung A-2:	Künstliches Feedforward Neuronales Netz mit einem Hidden Layer	59
Abbildung A-3:	Künstliches Rekurrentes Neuronales Netz mit einem Hidden Layer	60
Abbildung A-4:	Künstliches Neuron	61

Abbildung A-5:	Wie schätzen Sie den Umfang des tatsächlichen Einsatzes von No-Code Lösungen im Mittelstand ein?	85
Abbildung A-6:	Wie schätzen Sie den Umfang des tatsächlichen Einsatzes von AutoML, integriert in No-Code Lösungen, im Mittelstand ein?	85
Abbildung A-7:	Wie schätzen Sie den Umfang des tatsächlichen Einsatzes von Low-Code Lösungen im Mittelstand ein?	86
Abbildung A-8:	Wie schätzen Sie den Umfang des tatsächlichen Einsatzes von AutoML, integriert in Low-Code Lösungen, im Mittelstand ein?	86
Abbildung A-9:	Wie schätzen Sie den tatsächlichen Einsatz von folgenden Lösungen im Mittelstand gegenwärtig ein?	87
Abbildung A-10:	Wie schätzen Sie den tatsächlichen Einsatz von folgenden Lösungen im Mittelstand in 5 Jahren ein?	87
Abbildung A-11:	Wie schätzen Sie den tatsächlichen Einsatz von folgenden Lösungen im Mittelstand in 10 Jahren ein?	88

Abkürzungsverzeichnis

A

AutoML Automatisiertes Maschinelles Lernen, Automated Machine Learning

C

CV Computer Vision

D

DL Deep Learning

G

GUI Graphical User Interface

K

KI Künstliche Intelligenz

KMU Kleine und mittlere Unternehmen

KNN Künstliche Neuronale Netze

M

ML Machine Learning

N

NLP Natural Language Processing

R

RL Reinforcement Learning

Zusammenfassung

Automatisiertes Maschinelles Lernen (AutoML) sowie Low-Code und No-Code versprechen, im Sinne des Citizen Developer-Konzepts eine einfachere Nutzung von Künstlicher Intelligenz (KI) indem die erforderlichen Programmierkenntnisse bzw. der Entwicklungsaufwand reduziert werden. Diese neuen Ansätze erleichtern somit insbesondere kleinen und mittleren Unternehmen (KMU) den Einstieg und bieten damit das Potenzial für eine schnelle Verbreitung und stärkere Nutzung von KI-Lösungen. Ziel dieser Studie ist es zu untersuchen, ob diese Versprechen eingelöst werden können.

Bei der Forschungsmethodik wird vor allem auf qualitative Ansätze zurückgegriffen. Nach einer theoretischen Einführung in die Konzepte des maschinellen Lernens (ML), AutoML sowie Low- und No-Code, werden Nutzen und Grenzen dieser Software-Tools erörtert. Daran anschließend werden verschiedene No-Code-, Low-Code- und AutoML-Tools erfasst, um darauf basierend anhand erstellter Produktportfolios einen nicht-repräsentativen Einblick in den entsprechenden Markt zu geben. Eine anschließende theoretische Betrachtung der Strukturmerkmale des deutschen Mittelstands, die Auswirkungen auf eine Implementierung von KI-Lösungen haben können, wird durch die Auswertung einer Online-Befragung von KI-Expert:innen mit Mittelstandsbezug abgerundet. Diese dient der Einordnung von ML-Softwareentwicklungstools hinsichtlich ihrer Entwicklungspotenziale und Einsatzmöglichkeiten in KMU.

Die alternativen Entwicklungsumgebungen Low-Code und No-Code in Verbindung mit AutoML erfüllen teilweise das Versprechen einer vereinfachten Zugänglichkeit zu KI-Anwendungen: Die bestehende Produktlandschaft bietet bereits ein umfangreiches Angebot an derartigen Software-Lösungen, so dass der Einsatz von Personal und Ressourcen in Unternehmen für zeitaufwändige, sich wiederholende Aufgaben wie die Datenbereinigung reduziert werden kann. Langfristig wird die Einführung dieser Tools die Art des erforderlichen Fachwissens verändern, kann aber die Notwendigkeit von ML-Fachkompetenz nicht ersetzen. Der Einsatz von ML in Unternehmen wird daher auch in Zukunft KI-Spezialist:innen und damit einen entsprechenden Know-how-Aufbau vor allem in KMU erfordern. Diese menschliche Expertise bzw. das Datenverständnis wird z.B. benötigt, um die richtigen Anwendungsfälle zu identifizieren in denen ML einen echten Mehrwert bietet, oder um die Nutzbarmachung dieser Modelle in den Geschäftsprozessen zu realisieren. Auch im Hinblick auf Datenschutz- und Compliance-Anforderungen sowie die Einhaltung ethischer Standards bleibt dieses Wissen weiterhin von Bedeutung.

Die Ergebnisse der Online-Befragung zeigen, dass es für den Mittelstand besonders entscheidend ist, wie funktional und benutzerfreundlich die Lösungen gestaltet sind und ob datenschutzrechtliche Vorgaben eingehalten werden können. Nach Einschätzung der Befragten wird der Einsatz von AutoML-, Low-Code- und No-Code-Lösungen im deutschen Mittelstand in den nächsten Jahren stark zunehmen. Um diese Verbreitung zu realisieren, bedarf es jedoch noch weiterer Aufklärung über die Potenziale der Software-Tools, insbesondere in KMU.

Summary

Automated Machine Learning (AutoML), low-code and no-code promise to make artificial intelligence (AI) easier to use, in line with the citizen developer concept, by reducing the programming skills and development effort required. These new approaches therefore make it easier for small and medium-sized enterprises (SMEs) in particular to get started. They thus offer the potential for rapid dissemination and greater use of AI solutions. The aim of this study is to investigate whether these promises can be realised.

The research methodology is mainly based on qualitative approaches. After a theoretical introduction to the concepts of machine learning (ML), AutoML, low-code and no-code, the advantages and limitations of these software tools are discussed. Several no-code, low-code and AutoML tools are then analysed. They provide a non-representative insight into the relevant market based on product portfolios. Subsequently, the structural characteristics of German SMEs, which may have an impact on the implementation of AI solutions, are considered from a theoretical point of view. The analysis is rounded off by the evaluation of an online survey of AI experts from SMEs. The survey aims to categorise ML software development tools in terms of their development potential and possible applications in SMEs.

The alternative development environments of low-code and no-code in conjunction with AutoML partially fulfil the promise of simplified access to AI applications: The existing product landscape already offers a wide range of such software solutions. This can reduce the amount of time and resources that organisations spend on time-consuming, repetitive tasks such as data cleansing. In the long term, the introduction of these tools will change the type of expertise required. However, it cannot replace the need for ML expertise. The use of ML in companies will therefore continue to require AI specialists and thus a corresponding build-up of expertise, especially in SMEs. This human expertise and understanding of data is needed, for example, to identify the right use cases where ML can add real value, or to realise the usability of these models in business processes. This knowledge also remains important with regard to data protection and compliance requirements, as well as adherence to ethical standards.

The results of the online survey show that the functionality and ease of use of the solutions are particularly important to SMEs. The ability to comply with data protection regulations is also important. According to the respondents, the use of AutoML, low-code and no-code solutions in German SMEs will increase significantly over the next few years. However, in order to achieve this diffusion, more information is needed about the potential of the software tools, especially in SMEs.

1 Einleitung

Künstliche Intelligenz (KI) ist eines der Zukunftsthemen schlechthin. Bereits in den vergangenen Jahren haben diverse Entwicklungen dazu beigetragen, dass KI vermehrt eingesetzt wird, ein Wachstum der Umsätze in diesem Segment erfolgt ist und nahezu einhellig von namhaften Marktforschungsinstituten auch weiterhin für die kommenden Jahre prognostiziert wird.¹

Sowohl etablierte Unternehmen weiten ihre Ökosysteme im Bereich KI aus als auch neue Unternehmen investieren erheblich und steigen als Start-ups neu in den Markt ein. So war z.B. das Technologieunternehmen OpenAI, insbesondere bekannt für die KI-basierte Anwendung ChatGPT, Anfang 2023 weltweit das Start-up mit den meisten Investitionen. Mehr als eine Milliarde US-Dollar erhielt das Unternehmen bislang von Investoren.²

In der aktuellen Zeit müssen Unternehmen oft sehr schnell auf Veränderungen von Märkten, Lieferketten und Kundenwünschen reagieren. Dabei spielen individuelle Anwendungen eine große Rolle. Traditionelle Entwicklungsprozesse gelten dabei regelmäßig als träge und komplex und es erscheint nur schwer möglich, die Anforderungen nach Flexibilität und Individualität zu bedienen. Entwicklungen aus den Bereichen des Machine Learnings (ML) in Form von Automated ML (AutoML) sowie Low-Code und No-Code versprechen hier Erleichterung.

Für den Mittelstand bietet der Einsatz von KI ein erhebliches Potenzial, um beispielsweise Geschäftsprozesse effizienter zu gestalten, Produkte schneller und kostengünstiger zu entwickeln und neue Absatzmärkte zu erschließen. Ihre Verbreitung in Deutschland ist allerdings stark ausbaufähig wie aktuelle Studien unter anderem zur KI-Readiness und dem KI-Reifegrad belegen.³ Hemmnisse für den Einsatz von digitalen Technologien sind unklare Kosten-Nutzen-Verhältnisse, fehlende Fachkräfte und Fachexpertise sowie Rechtsunsicherheiten und Bedenken wegen der IT-Sicherheit.⁴

AutoML-, Low-Code- und No-Code-Entwicklungen versprechen hier anzusetzen, und durch das Automatisieren von datengestützten Geschäftsprozessen und das Einbinden von nicht-professionellen Entwickler:innen (sogenannte Citizen Developer⁵) die Hürden für den Einsatz von KI zu senken. Mehr Teilhabe an KI-Anwendungsprozessen für Mitarbeitende, die über keine oder nur geringfügige IT- und Programmierkenntnisse verfügen, kann langfristig den KI-Fachkräftemangel mindern und für den Aufbau von KI-Know-how in Unternehmen sorgen.

Gerade diese Themen sind es auch, die einer Google-Trends-Analyse folgend gerade in den vergangenen Monaten an Relevanz und Interesse hinzugewonnen haben (siehe Abbildung 1-1). Gleichzeitig scheint der bisherige wissenschaftliche Fokus vor allem auf den technischen Aspekten von neuartigen ML-Anwendungen zu liegen - ökonomische Markterhebungen und -analysen

¹ Vgl. dazu Statista (2022a).

² Vgl. NFX (2023).

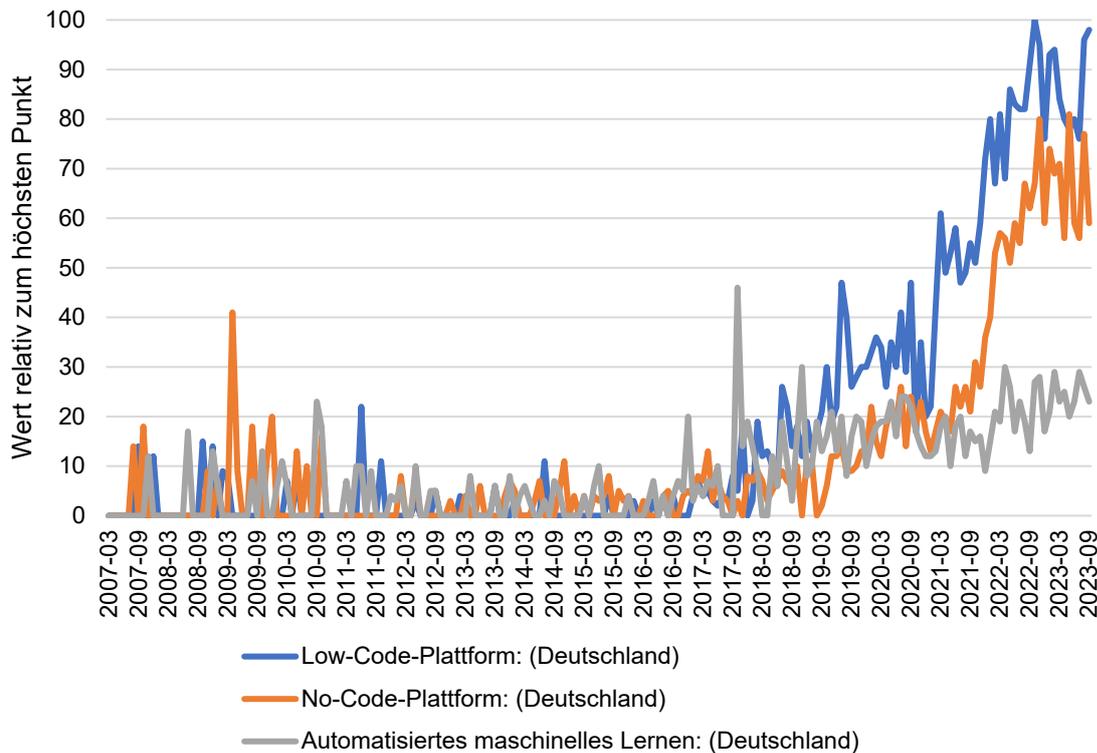
³ Beides sind Modelle, die den Entwicklungsstand und die Fortschritte von Organisationen im Umgang mit KI bewerten: Vgl. BNetzA (2023) sowie Liebe et al. (2022).

⁴ Vgl. BNetzA (2023).

⁵ Als „Citizen Developer“ werden Mitarbeitende bezeichnet, die außerhalb der IT-Abteilung arbeiten, keine professionellen Programmierer:innen sind und Anwendungen mithilfe von Tools wie Low- und No-Code für den eigenen Arbeitsbereich innerhalb ihrer Organisation erstellen. Dieses Konzept soll dem vorherrschenden Mangel an IT-Fachkräften entgegenwirken. Vgl. dazu Lebens et al. (2021).

sind weniger präsent. Der vorliegende Diskussionsbeitrag soll vor allem diesen Bereich, der in der Literatur weniger im Fokus steht, beleuchten.

Abbildung 1-1: Google Trends Zeitverlauf zu Low-Code, No-Code und AutoML (Deutschland)



Quelle: WIK, eigene Darstellung in Anlehnung an Google Trends.⁶

Das Ziel der Studie besteht darin, den Status Quo und die Entwicklungen von AutoML, Low-Code- und No-Code-Software im Bereich ML zu untersuchen. Dies geschieht insbesondere durch einen Überblick über das bestehende Marktangebot und damit über die konkret angebotenen Softwaretools. Basierend auf diesen Erkenntnissen werden potenzielle Implikationen für den Mittelstand sowie das Software-Ökosystem abgeleitet.

Vor diesem Hintergrund sind die folgenden Forschungsfragen abzuleiten:

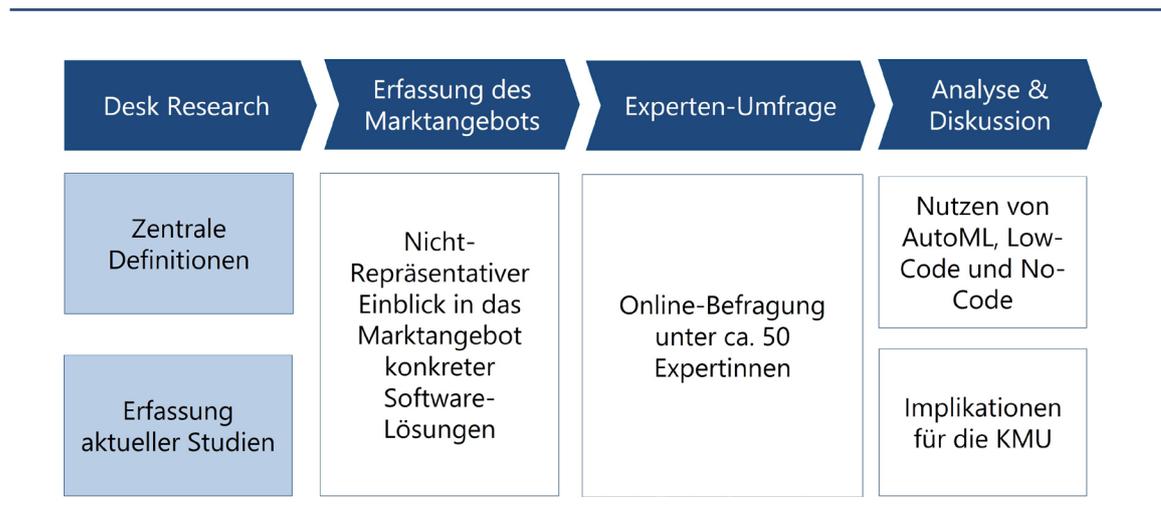
- In welchem Verhältnis stehen die Begriffe AutoML, Low-Code und No-Code zueinander und worin liegen die grundsätzlichen Vorteile der dahinterstehenden Software bei der Implementierung von KI?

⁶ Daten abrufbar unter: https://trends.google.com/trends/explore?date=2007-01-03%202023-11-02&geo=DE&q=%2Fq%2F11c6cx4nrr,%2Fq%2F11gy7wrlwj,%2Fq%2F11f2sl5v8_&hl=de [Zuletzt abgerufen am 04.09.2023].

- Wie sieht das aktuelle Marktangebot von AutoML-, Low-Code- und No-Code Lösungen aus? Was sind wesentliche Charakteristika, wie sind diese ausgeprägt und worin unterscheiden sich die Lösungen?
- Wie sieht die praktische Anwendung gegenwärtig aus? Welchen Nutzen hat speziell der Mittelstand bei der Implementierung derartiger Lösungen? Wo werden Hemmnisse gesehen?
- Was sind die Auswirkungen von AutoML, Low-Code und No-Code und auf welche Herausforderungen, Potenziale und Grenzen stoßen kleine und mittlere Unternehmen (KMU)?

Um diese Forschungsfragen systematisch zu beantworten, wurden die folgenden Forschungsdesigns bedient: Neben einer theoretischen Betrachtung basierend auf Desk Research wurde eine Auswahl tatsächlich am Markt verfügbarer Softwarelösungen eingehend analysiert. Anschließend wurde eine Online-Befragung von Expert:innen durchgeführt. Basierend auf diesen Vorarbeiten wurde abschließend eine Analyse hinsichtlich der Implikationen für KMU durchgeführt. Das Vorgehen bzw. die Arbeitspakete sind in der nachfolgenden Darstellung skizziert.

Abbildung 1-2: Methodische Vorgehensweise



Quelle: WIK, eigene Darstellung.

In Kapitel 2 ist die systematische Darstellung des Untersuchungsgegenstandes und der damit verbundenen Begrifflichkeiten enthalten. Das Verhältnis der Begriffe AutoML, Low-Code und No-Code wird dargelegt und die grundsätzlichen Vorteile der Konzepte bei der Implementierung von KI werden erläutert. Dazu werden auch die Ergebnisse aus dem Desk Research zum potenziellen Mehrwert und Nutzen von AutoML, Low-Code und No-Code dargelegt.

Kapitel 3 erläutert einerseits die Vorgehensweise bzw. Methodik der Erfassung relevanter Software-Angebote im beleuchteten Bereich, ehe dort die erfassten Marktangebote anhand entwickelter Kriterien systematisch dargestellt werden.

In Kapitel 4 werden die Strukturmerkmale des Mittelstands sowie das Umfragedesign einer Online-Befragung von Expert:innen zum Einsatz der Software-Tools dargestellt. Darauf folgen die Einschätzungen der befragten Expert:innen.

Kapitel 5 enthält eine Diskussion zu Herausforderungen, Potenzialen und Grenzen automatisierter und grafisch aufbereiteter ML-Prozesse für KMU sowie zu möglichen Auswirkungen auf das bestehende ML-Softwareökosystem und endet mit einem Ausblick.

2 Künstliche Intelligenz und Maschinelles Lernen

Dieses Kapitel dient dazu, ein konsistentes Verständnis des Untersuchungsgegenstandes aufzubauen. Dazu erfolgt zunächst eine theoretische Einführung in maschinelles Lernen (Kapitel 2.1) und KI (Kapitel 2.2), ehe das Verhältnis der Begriffe AutoML, Low-Code und No-Code zueinander dargelegt wird (Kapitel 2.3). Das Kapitel schließt mit einer Untersuchung der potenziellen Vorzüge sowie Grenzen dieser Entwicklungen im Softwarebereich (Kapitel 2.4).

2.1 Maschinelles Lernen als Basis Künstlicher Intelligenz

In den letzten Jahren ist KI in nahezu allen Bereichen der Wirtschaft und des gesellschaftlichen Lebens angekommen.⁷ Im Alltag sind die Anwendungsfälle mannigfaltig und bereits heute nicht mehr wegzudenken. Empfehlungsalgorithmen sammeln beispielsweise beim Online-Streaming oder Online-Shopping Daten zum Nutzungsverhalten und lernen Präferenzen kennen, Suchmaschinen optimieren Suchergebnisse, indem sie natürliche Sprache berücksichtigen und Verknüpfungen zwischen Inhalten herstellen, und ein Algorithmus hat bei der Gesichtserkennung des Smartphones erlernt, Gesichter unabhängig von Tagesform, Make-up und Lichtverhältnissen zu erkennen. Smart Home, Fahrassistenten und digitale Sprachassistenten sind weitere Anwendungsfälle im privaten Umfeld.⁸ In der Wirtschaft sind es ganz ähnliche Technologien, die in nahezu allen Bereichen der Wertschöpfung angewendet werden. Aus der Kommunikation mit Kund:innen und Lieferant:innen, aus der Logistik, aber auch aus der industriellen Produktion und der Individualisierung von Produkten sind derartige Technologien nicht mehr wegzudenken.⁹

Auch wenn die Anwendungsfälle sehr heterogen sind, handelt es sich stets um Programme und Anwendungen auf der Basis von Algorithmen. Sie haben das Ziel, menschliche Intelligenz nachzubilden und bauen diesen Schritt für Schritt durch ML-Prozesse auf. Entsprechend ist hier bereits das Verhältnis von KI und ML ersichtlich: ML ist Basis und damit Teil der KI.

Dieser Auffassung soll auch hier gefolgt werden.¹⁰ Unter KI versteht man alle computergestützten Methoden, mithilfe derer man menschliches intelligentes Verhalten simuliert, das durch Wahrnehmen, Verstehen, Handeln und Lernen gekennzeichnet ist.¹¹ ML ist ein Ansatz, KI durch Algorithmen in Forschungs- und Anwendungspraxis umzusetzen, wobei für Lernprozesse auf Daten bzw. Erfahrungen zurückgegriffen wird.¹² Als besonders lernfähig haben sich in jüngster Vergangenheit Deep Learning (DL) bzw. Künstliche Neuronale Netze (KNN)¹³ hervorgetan, die sich

⁷ Bei der Definition von KI werden, je nach Herausgeber, unterschiedliche Merkmale hervorgehoben. Die Bundesregierung unterscheidet beispielsweise zwischen starker und schwacher KI, wobei im Rahmen dieser Studie die schwache KI, im Rahmen derer konkrete Anwendungsfälle auf der Basis mathematischer Methoden und solcher der Informatik angegangen werden, im Vordergrund steht. Im Gegensatz dazu hat eine starke KI die gleichen intellektuellen Fertigkeiten wie der Mensch. Gegenwärtig ist die starke KI weniger in der Realität als im Bereich des Science Fiction anzutreffen.

⁸ Vgl. Statista (2022a).

⁹ Vgl. KPMG (2019).

¹⁰ Zum Unterschied zwischen Machine Learning und Künstlicher Intelligenz, vgl. auch <https://www.datarevenue.com/de-blog/der-unterschied-zwischen-machine-learning-und-kuenstlicher-intelligenz> [Letzter Abruf 24.04.2023].

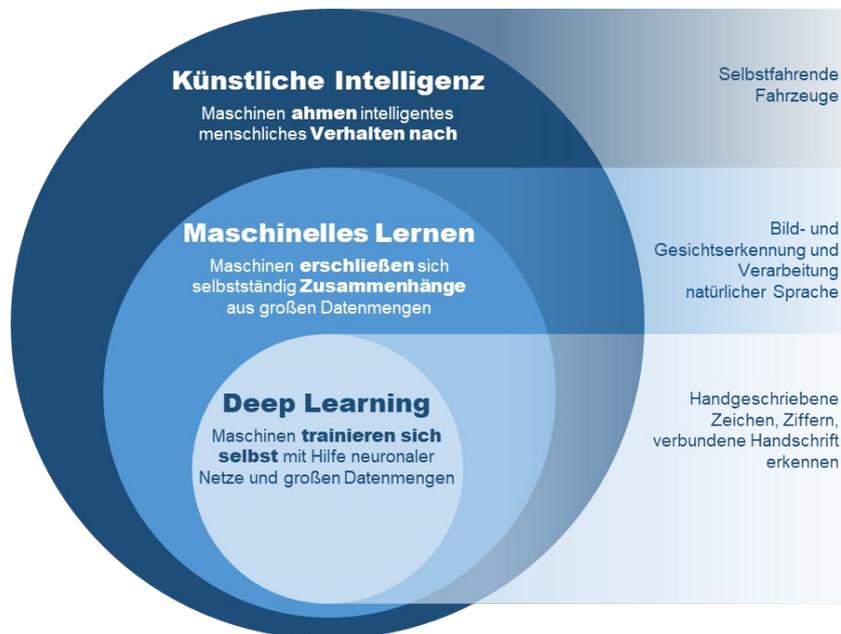
¹¹ Vgl. Wirtz und Weyerer (2019).

¹² Vgl. Dindorf et al. (2023).

¹³ Für detaillierte Ausführungen zu Künstlichen Neuronalen Netzen (KNN) sei an dieser Stelle auf Anhang A2 verwiesen.

insbesondere durch ihre universellen Approximationseigenschaften auszeichnen.¹⁴ Die nachstehende Abbildung 2-1 illustriert die dargestellten Zusammenhänge.

Abbildung 2-1: Definition und Abgrenzung KI und ML



Quelle: WIK, eigene Darstellung, in Anlehnung an: Sarker (2021).¹⁵

Grundsätzlich lassen sich die folgenden drei Arten von ML unterscheiden: Unüberwachtes, Überwachtes und Verstärkendes Lernen. Letzteres wird auch als sogenanntes Reinforcement Learning (RL) bezeichnet.¹⁶

- Beim Unüberwachten Lernen (auch **Unsupervised Learning**) erhält der Algorithmus während des Lernens kein Feedback. Er ist auf sich selbst gestellt, um immanente Strukturen in den Daten zu identifizieren und aus diesen zu lernen. Zu den unüberwachten Lernmethoden gehören alle ähnlichkeitsbasierten Verfahren, wie zum Beispiel die Clusteranalyse, welche ähnliche Objekte zu Gruppen zusammenfassen.¹⁷ Diese Methoden wiederum machen sich verschiedene Verfahren zu Nutze. Im Falle der Clusteranalyse gibt es mehrere Verfahren. Die zwei bekanntesten sind das partitionierende und das

¹⁴ Vgl. Hornik et al. (1989).

¹⁵ Vgl. Sarker (2021).

¹⁶ Vgl. Trabold (2021).

¹⁷ Vgl. zu ML mittels Clusteranalyse: Liebe et al. (2022).

hierarchische Verfahren. Der K-Means Algorithmus, als bekanntester Algorithmus, der dieser Methode zugeordnet werden kann, zählt wiederum zu den partitionierenden Verfahren.¹⁸

- Beim Überwachten Lernen (auch **Supervised Learning**) ist eine Feedbackschleife nach jedem Trainingsbeispiel möglich, die der Algorithmus eigenständig aus den Trainingsdaten entnimmt. Voraussetzung dafür ist, dass die richtige Antwort (Label) zu jedem Datenpunkt in den Trainingsdaten integriert ist. Ein Beispiel dafür ist das Trainieren von Klassifikations- oder Regressionsmodellen. Letztlich basieren die meisten KI-Anwendungen auf dieser Art des ML. Es gibt vier wesentliche Verfahren bei der Klassifikation von Objekten: Entscheidungsbäume, Neuronale Netze, die Bayes-Klassifikation und das Nächste-Nachbarn-Verfahren.¹⁹
- Beim **Verstärkenden Lernen** (auch RL) gibt es nicht zu jedem Datenpunkt ein Feedback, sondern häufig erst nach vielen durchlaufenen Schritten. Ähnlich verhält es sich zum Beispiel bei vielen Spielen, bei denen es für das Gewinnen ein positives und für das Verlieren ein negatives Feedback, jeweils am Ende des Spiels, gibt. Um eine bessere Strategie zu entwickeln, muss in jedem Fall mehrfach gespielt werden. Es wird auch von Belohnen und Bestrafen oder Trial and Error gesprochen.²⁰ Dieser Lernansatz greift dazu auf verschiedene spezifische Algorithmen zurück, die nach zwei wesentlichen Ansätzen kategorisiert werden können: Markov Decision Process und Bandit.²¹

Andere Variationen des ML, die in der hier getätigten Betrachtung weniger von Relevanz sein werden, beinhalten bspw. Teilüberwachtes sowie Aktives Lernen.

- **Teilüberwachtes Lernen** (auch Semi-Supervised Learning) ist eine Mischung aus Unüberwachten und Überwachten Lernen. In einigen Fällen gibt es ein Feedback wie im Überwachten Lernen, zu einigen Fällen aber auch nicht. Ein Beispiel ist die Identifikation von Betrug. Für entdeckte Betrugsfälle ist bekannt, dass es sich um Betrug handelt. Für die übrigen Daten ist die Wahrscheinlichkeit, dass es sich um Betrug handelt, gering, gleichwohl werden sich noch unentdeckte Fälle unter den Daten befinden.²²
- Dem **Aktiven Lernen** (auch Active Learning) liegt die Erkenntnis zugrunde, dass es in einigen Anwendungsfällen nicht möglich oder teuer ist, die richtigen Antworten für alle Datenpunkte in Betracht zu ziehen. Ein Anwendungsfall sind etwa Empfehlungssysteme. Eine Kundin wäre z.B. nicht bereit, Unmengen von Filmen zu bewerten, bevor sie passende Vorschläge erhält. Mit jedem Film jedoch den die Kundin auswählt, erhält der

¹⁸ Der K-Means Algorithmus gruppiert ähnliche Datenpunkte und ermöglicht so, zugrunde liegende Muster in Daten zu erkennen. Vgl. <https://datatab.de/tutorial/k-means-clusteranalyse> [Letzter Abruf 06.06.2023].

¹⁹ Vgl. Definition zur Klassifikation von Objekten mit ähnlichen Merkmalsausprägungen nach vordefinierten Klassen: <https://www.datenbanken-verstehen.de/lexikon/klassifikation/#:~:text=Es%20gibt%20vier%20wesentliche%20Verfahren%20bei%20der%20Klassifikation,Entscheidungsba%C3%A4ume%2C%20Neuronale%20Netze%2C%20die%20Bayes-Klassifikation%20und%20das%20N%C3%A4chste-Nachbarn-Verfahren.> [Letzter Abruf 06.06.2023].

²⁰ Vgl. Trabold (2021).

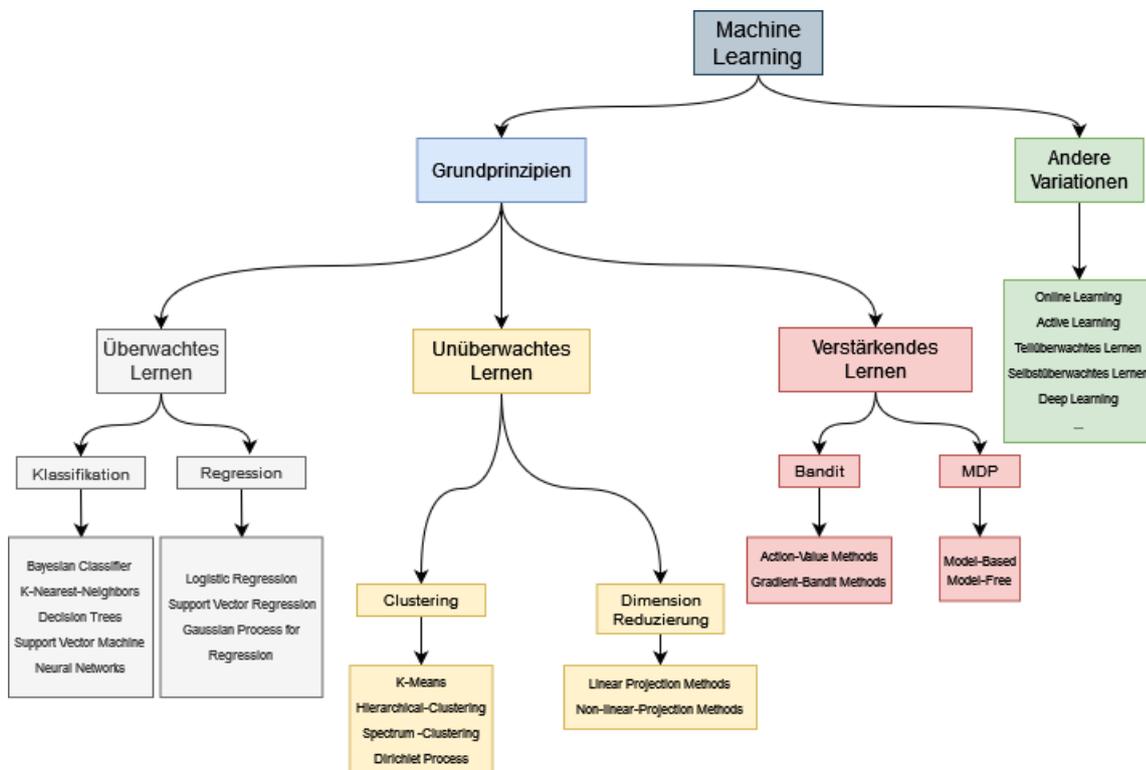
²¹ Vgl. Hussien (2021).

²² Vgl. Trabold (2021).

Algorithmus ein Feedback zu ihren Präferenzen. Das System wählt aktiv aus, welche Empfehlungen gemacht werden.²³

Eine Taxonomie der ML-Arten und einzelnen ML-Algorithmen ist in Abbildung 2-2 dargestellt. Für einen Großteil der realen (Business-)Use-Cases werden Algorithmen des Überwachten Lernens verwendet, wobei üblicherweise einzelne ML-Algorithmen nacheinander evaluiert und miteinander verglichen werden, um das geeignetste Modell zu finden.

Abbildung 2-2: ML-Taxonomie



Quelle: WIK, eigene Darstellung, in Anlehnung Hossain et al. (2020).²⁴

Die dargestellte Definition stellt die Grundlage für die zu identifizierenden Software-Lösungen dar. Diese werden in Kapitel 3 nach den verschiedenen aufgeführten Lernansätzen klassifiziert.

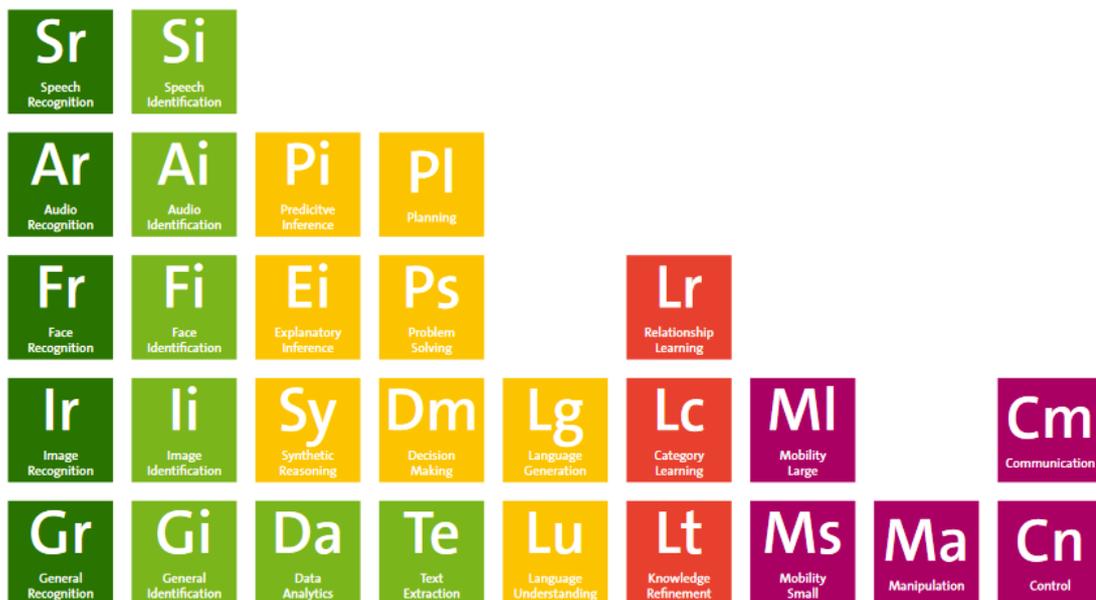
²³ Vgl. Schmidt (2020) sowie Tas und Wiewiorra (2022).

²⁴ Vgl. Hossain et al. (2020).

2.2 Elemente der Künstlichen Intelligenz

Die Anwendungen der KI sind, wie in der Literatur umfangreich aufgearbeitet wurde, sehr individuell, dynamisch und verschieden.²⁵ Im Rahmen dieser Studie werden die Elemente betrachtet, die hinter einer KI-Anwendung stehen. Zu dieser Betrachtung bietet sich das sogenannte Periodensystem der KI zur Systematisierung an.²⁶ Es dient dazu, KI anschaulich darzustellen und in ihre Einzelteile zu zerlegen. Es wird deutlich, dass eine KI-Anwendung aus der Kombination verschiedener Elemente besteht, wobei jedes einzelne KI-Element des Periodensystems eine Teilfunktion repräsentiert und einer von drei Gruppen, auf die noch näher einzugehen ist, zugeordnet wird. Um einen typischen KI getriebenen Verarbeitungsschritt zu definieren, bedarf es eines Elements aus jeder Gruppe.²⁷ Die Einzelteile sind Elemente der KI.

Abbildung 2-3: Periodensystem der KI



Quelle: Klingholz, L., Holtel, S., Hartmann, T. (2018).²⁸

In die erste Gruppe („Assess“) zählen die in Abbildung 2-3 grün und hellgrün dargestellten Elemente, die für das Erfassen und Erkennen von Daten verschiedenster Arten stehen. Dazu gehören z.B. das Erkennen von gesprochener Sprache oder bestimmter Arten von Geräuschen in einem

²⁵ Vgl. Lundborg und Märkel (2019) sowie Lundborg et al. (2019).

²⁶ Vgl. dazu und im Folgenden Klingholz et al. (2018).

²⁷ Folgendes Beispiel soll dazu gegeben werden: Assess: z.B. die Verkehrssituation im Umfeld eines Roboterautos in Millisekunden erfassen, Infer: z. B. die Wahrscheinlichkeit eines Auffahrunfalls für die nächsten 3 Sekunden kalkulieren und Respond: z. B. das Brems- oder Ausweichmanöver des Roboterautos einleiten.

²⁸ Vgl. Klingholz et al. (2018).

Audiosignal und das Erkennen von Gesichtern oder bestimmter Objekttypen in Bildern und Videosignalen.

Die zweite Gruppe („Infer“) enthält die gelben und roten Elemente aus Abbildung 2-3, die Analysen, Kalkulationen, Erklärungen und Schlussfolgerungen vornehmen und Lösungen vorschlagen. Dazu zählen unter anderem das Vorhersagen von Ereignissen oder Zuständen in der Zukunft auf der Grundlage eines Verständnisses des aktuellen Zustandes, das Erstellen eines Aktionsplans auf der Grundlage einer Reihe von Zielen, eines Verständnisses des realen Zustands und des Wissens über Handlungen und deren Konsequenzen aber auch das Erkennen von Beziehungen zwischen Merkmalen, die dazu verwendet werden können, das Vorhandensein eines Satzes von versteckten Merkmalen vorherzusagen (z.B. Korrelationen).

Die dritte Gruppe („Respond“), in Abbildung 2-3 violett dargestellt, umfasst die Elemente, die Reaktionen erfolgen lassen, wie z.B. Mechanismen, die das Ausführen verschiedener Formen der Kommunikation zwischen Mensch und Maschine unterstützen. Typische Beispiele sind das autonome Steuern von Fahrzeugen, das Steuern von Robotern etc.

Erst die Kombination von Elementen der verschiedenen Gruppen, die dazu notwendig ist einen typischen KI getriebenen Verarbeitungsschritt zu definieren, führt dazu, dass Anwendungen intelligent und menschlichem Handeln ähnlich oder gar überlegen, erscheinen.

Wenn Unternehmen KI-Lösungen einsetzen, dann ist es wichtig zu verstehen, dass diese Lösungen sowohl einzelne Elemente von KI abbilden als auch ggf. ganze Pakete darstellen können.

Für die in Kapitel 3 folgende Erhebung angebotener Software-Tools, werden insbesondere die verschiedenen Lernansätze sowie die ML-Methoden als Ausgangspunkt für die Darstellung der tatsächlich vorhandenen AutoML, No-Code und Low-Code-Angebote herangezogen.

2.3 Einführung in innovative Ansätze zur Entwicklung und Implementierung von Maschinellem Lernen

Der Zugang zu KI erfordert oft fundierte Programmier- und ML-Kenntnisse, was für nicht-professionelle Entwickler:innen eine Hürde darstellt. Zur Verbesserung der Zugänglichkeit werden zunehmend ML-Schritte durch AutoML automatisiert, und herkömmliche Entwicklungsumgebungen durch grafische Benutzeroberflächen wie beispielsweise No-Code und Low-Code ersetzt. Diese Ansätze vereinfachen die KI-Nutzung und beschleunigen die Bereitstellung von Lösungen, unabhängig von Unternehmensgröße oder technischem Know-how. Sie bieten somit das Potenzial die Technologienutzung zukünftig grundlegend verändern zu können.

Der bisherige Forschungsstand in diesem Gebiet ist geprägt von Studien aus dem Bereich der Informationstechnik, die die technischen Implementierungsverfahren und Möglichkeiten innovativer KI-Anwendungen wie AutoML, No-Code und Low-Code skizzieren. Die ökonomische Komponente, die z.B. Markterhebungen und -analysen zu einzelnen ML-Tools umfasst und die beleuchtet werden muss, damit sich Unternehmen mit dem Einsatz solcher Methoden auseinandersetzen, hat bisher kaum Eingang in die wissenschaftliche Diskussion gefunden. Diese Komponente wird, wie eingangs dargestellt, daher im Folgenden im Fokus der Ausführungen stehen.

In den folgenden Unterkapiteln werden die Begrifflichkeiten AutoML (Kapitel 2.3.1) sowie Low-Code und No-Code (Kapitel 2.3.2) definiert, ehe abschließend eine systematische Einordnung (Kapitel 2.3.3) dieser für diese Studie erfolgt.

2.3.1 Automated Machine Learning (AutoML)

KI-Anwendungen zu implementieren und in der Praxis zu nutzen, stößt trotz ihres großen Nutzens auf verschiedene Hindernisse. Vor allem fehlende personelle Ressourcen und das zwingende Erfordernis umfangreicher Daten sind dafür verantwortlich, dass KI-Systeme von Unternehmen weniger eingesetzt werden, als dies ökonomisch sinnvoll wäre.²⁹ Die Kosten für Fachkräfte mit entsprechenden Kenntnissen sind hoch und die gegenwärtige Verfügbarkeit gering. Themen rund um den Teilbereich ML haben dabei in den vergangenen Jahren in der öffentlichen Diskussion deutlich an Bedeutung gewonnen.³⁰

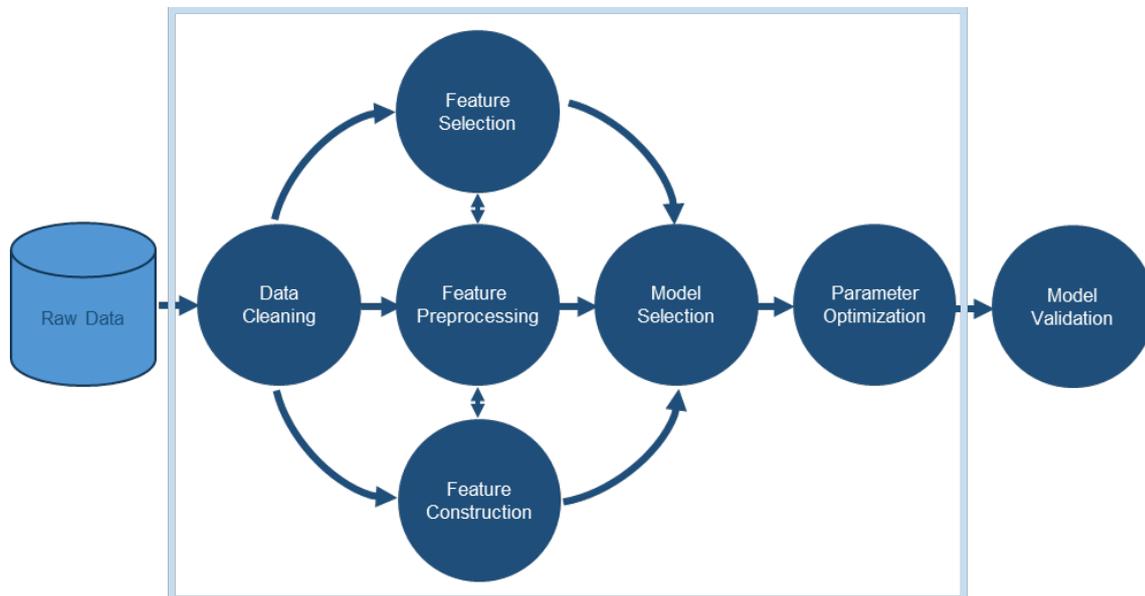
ML besteht aus zyklischen Prozessen, die getrennt voneinander und grundsätzlich nicht automatisiert ablaufen. Wie in Abbildung 2-4 dargestellt, zählt zu den ersten Schritten die Datenerhebung, die Datensichtung sowie die Vorbereitung der Daten. Unter letzteres fallen bspw. die Bereiche Feature-Selection, -Preprocessing und -Construction. Zu den dann folgenden Schritten zählen Feature Engineering, Auswahl des passenden ML-Modells, Training des Modells und Vorhersage durch das Modell. Üblicherweise bedarf es mehrerer Anläufe, bis das passende Feature Engineering (Einstellung der modellexogenen Parameter) und das effektivste Modell gefunden wurden.

AutoML stellt die Automatisierung der einzelnen Schritte des klassischen ML-Prozesses dar und hat das Ziel, die menschliche Arbeitszeit am Prozess zu reduzieren, dadurch, dass die manuellen Schritte des klassischen, iterativen Prozesses obsolet werden. Aktuell werden vor allem das Feature Engineering sowie Selektion, Training und Validierung eines ML-Modells und die Optimierung der Hyperparameter automatisiert. Perspektivisch wird der Grad der ML-Automatisierung im Laufe der kommenden Jahre weiter ansteigen.

²⁹ Vgl. Berg (2022).

³⁰ So zeigt eine Studie der Stanford University, dass sich die Anzahl der KI-Publikationen zu ML weltweit, differenziert nach Fachbereichen, innerhalb von drei Jahren verdoppelt hat. Vgl. Statista (2022a).

Abbildung 2-4: Trainingsprozesse von ML und AutoML



Quelle: WIK, eigene Darstellung, in Anlehnung an Olson, R. L. et al (2016).³¹

Abbildung 2-4 stellt den kompletten ML-Trainingsprozess dar. Dabei kann der Teil des Prozesses, der dort innerhalb des dargestellten Kastens abläuft, durch AutoML automatisiert werden. Aufgaben, die bisher nicht maschinell übernommen werden können, und damit noch immer menschliche Expertise erfordern, bestehen bspw. in der Definition der Trainingsdaten als Eingabe, der Begutachtung der Modellergebnisse und der Nutzbarmachung entsprechender ML-Modelle in den Geschäftsprozessen.³²

Gleichwohl ist die erhebliche Reduktion von menschlichem Arbeitseinsatz einer der großen Vorteile von AutoML.³³ AutoML wird daher auch als Türöffner für den Einsatz von ML in KMU gesehen, für die gerade die Kosten sowie das notwendige Know-how bis dato eine Einstiegshürde darstellten.³⁴ Zahlreiche Anbieter haben diese Entwicklungen aufgegriffen und bieten verschiedene sogenannter AutoML Frameworks und Plattformen am Markt an. Beispiele hierfür sind AWS SageMaker Canvas (Amazon)³⁵, Azure AutoML (Microsoft)³⁶ und Vertex AI (Google bzw. Alphabet)³⁷. Derartige Lösungen werden im folgenden Kapitel 3 im Vordergrund stehen.

³¹ Vgl. Olson et al. (2016).

³² Etwa 80% der Zeit eines ML-Projektes wird der aufwändigen Datenvorbereitung zugeschrieben: Vgl. Olsowski, et al. (2022).

³³ Vgl. Polink (2021) sowie Wuttke (o.J.a).

³⁴ Vgl. Wuttke (o.J.b) sowie Janakiram (2018).

³⁵ Vgl. <https://aws.amazon.com/de/sagemaker/autopilot/?sagemaker-data-wrangler-whats-new.sort-by=item.additionalFields.postDateTime&sagemaker-data-wrangler-whats-new.sort-order=desc> [Letzter Abruf 27.04.2023].

³⁶ Vgl. <https://learn.microsoft.com/de-de/azure/machine-learning/concept-automated-ml> [Letzter Abruf 27.04.2023].

³⁷ Vgl. <https://cloud.google.com/automl?hl=de> [Letzter Abruf 27.04.2023].

2.3.2 Low-Code und No-Code

Low-Code- und No-Code-Lösungen sind weitere Optionen die aktuell in der Diskussion stehen, um KI, unter anderem für den Mittelstand einfacher nutzbar zu machen. Auch hier besteht der Hebel darin, dass auf umfangreiche Fachkräftekapazitäten verzichtet und sowohl Zeit als auch Kosten eingespart werden können.

„Low-Code ist ein visueller Ansatz für die Softwareentwicklung, der eine schnellere Bereitstellung von Anwendungen durch minimale manuelle Kodierung ermöglicht.“

Quelle: IBM.³⁸

Low-Code-Anwendungsentwicklung beschreibt, wie auch anhand obenstehender Definition aufgezeigt wird, die Erstellung von Anwendungssoftware mit visuellen Tools und modellgesteuerten Prozessen. Dazu werden visuelle Oberflächen (auch GUI – Graphical User Interfaces – genannt) mit einer simplen Logik, die oftmals intuitiv anwendbar ist, sowie Drag-and-Drop-Funktionen verwendet. Sie steht damit der traditionellen codebasierten Programmierung entgegen: Der Umfang des erforderlichen Programmieraufwands wird reduziert und ein Zugang zur Entwicklung mit niedrigen Einstiegshürden wird ermöglicht.

Eine Low-Code-Plattform kann von einer einfachen, kostenlosen (Online- bzw. Offline-) Software bis hin zu einer ausgefeilten Anwendungsentwicklungsmaschine reichen, die hochkomplexe Prozesse unterstützt.³⁹ Oftmals sind es Apps, die sehr spezifisch für unternehmensindividuelle Anwendungen erstellt werden. Im Low-Code Bereich sind nur marginale Programmierkenntnisse erforderlich, was Anwendende mit Fachwissen aber geringen Programmierkenntnissen ermöglicht, (ML-)Software-Lösungen implementieren zu können und somit die Umsetzung von Anpassungs- und Optimierungserfordernissen deutlich beschleunigt.

„Eine No-Code-Entwicklungsplattform (NCDP) [ermöglicht] Benutzern die Erstellung von Unternehmensanwendungen über Drag-and-drop-Schnittstellen anstelle von traditionellem manuellen Programmieren.“

Quelle: IBM.⁴⁰

No-Code hingegen wird als Möglichkeit definiert, den Benutzern die Erstellung von Unternehmensanwendungen über Drag-and-drop-Schnittstellen anstelle der herkömmlichen manuellen Programmierung zu ermöglichen.

Der Unterschied zwischen Low-Code- und No-Code-Plattformen besteht darin, dass No-Code Plattformen keinerlei Programmieraufwand erfordern, wohingegen Low-Code-Plattformen eine

³⁸ Vgl. <https://www.ibm.com/de-de/topics/low-code> [Letzter Abruf 16.11.2023].

³⁹ Vgl. [https://www.pega.com/de/low-code?utm_source=google&utm_medium=cpc&utm_campaign=G_DACH_NonBrand_LowCode_IA_Exact_\(CPN-111045\)_DE&utm_term=low-code&gclid=9044708&utm_content=pcrid%7c607396105853%7cpcpw%7ckwd-1414945224686%7cpmt%7ce%7cpdv%7cc%7c&qad=1&gclid=EAlaQobChMI-tYSn5IjK_gIV7S4GAB0KzwwqKEAAYASAAEgKekvD_BwE&gclid=aw_ds](https://www.pega.com/de/low-code?utm_source=google&utm_medium=cpc&utm_campaign=G_DACH_NonBrand_LowCode_IA_Exact_(CPN-111045)_DE&utm_term=low-code&gclid=9044708&utm_content=pcrid%7c607396105853%7cpcpw%7ckwd-1414945224686%7cpmt%7ce%7cpdv%7cc%7c&qad=1&gclid=EAlaQobChMI-tYSn5IjK_gIV7S4GAB0KzwwqKEAAYASAAEgKekvD_BwE&gclid=aw_ds) [Letzter Abruf 27.04.2023].

⁴⁰ Vgl. <https://www.ibm.com/de-de/topics/low-code> [Letzter Abruf 16.11.2023].

leicht höhere Komplexität haben und individuelles Programmieren zulassen. Sie benötigen entsprechend IT Know-how und mehr Schulungsaufwand. Mit ihnen können größere und auch komplexere Anwendungen erstellt werden als dies mit einer No-Code Plattform möglich wäre.⁴¹ Entsprechend sind No-Code Plattformen eher für Citizen Developer konzipiert, wohingegen Low-Code Lösungen diese Gruppe, aber auch die professionellen Entwickler:innen ansprechen.⁴²

Zusammenfassend kann festgehalten werden, dass Low-Code / No-Code ein Sammelbegriff für Software-Applikationen zur Entwicklung von ML-Anwendungen mit unterschiedlichem Grad an Komplexität und Funktionsumfang ist.

2.3.3 Systematisierung

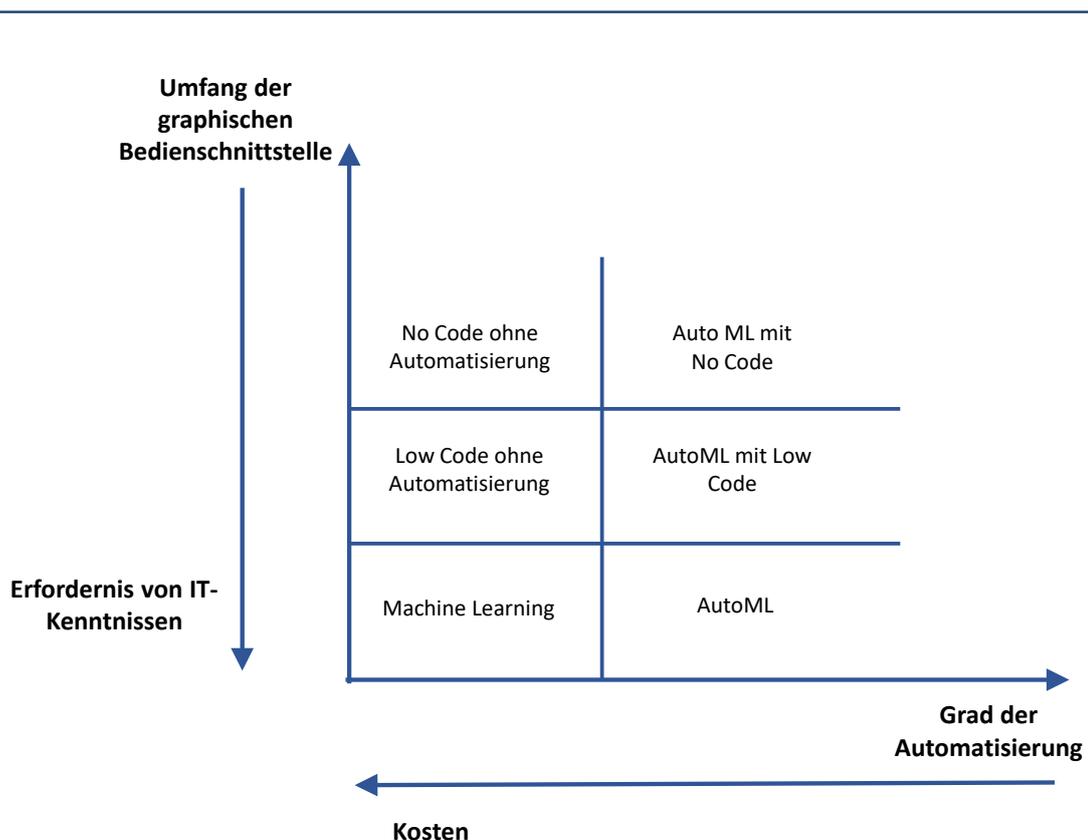
Zur Systematisierung wird für diese Studie eine Matrix zwischen dem *Grad der Automatisierung* und dem *Umfang der graphischen Bedienschnittstelle* (GUI), definiert. Die graphische Bedienschnittstelle hat dabei die Aufgabe, Anwendungssoftware mittels graphischer Symbole, Steuerelemente oder ähnlichem intuitiv bedienbar zu machen. Steigt der Umfang der graphischen Bedienschnittstelle, sinkt das Erfordernis von IT-Kenntnissen. Auf der anderen Seite gilt, dass wenn der Grad der Automatisierung steigt, die Kosten für ein Unternehmen tendenziell sinken. Abbildung 2-5 zeigt die verschiedenen Ansätze von ML, AutoML sowie No-Code und Low-Code in den jeweiligen Ausprägungen der beiden Dimensionen.

In Abhängigkeit der beiden Dimensionen lassen sich also in untenstehender Abbildung 2-5 sechs Felder identifizieren. Das Feld, des klassischen ML, das dem Ursprung am nächsten ist, wird in dieser Studie und in der nachfolgenden Produktauswahl nicht weiter beleuchtet. Die übrigen dargestellten Felder, werden zur Einordnung der in Kapitel 3 identifizierten Software-Produkte herangezogen.

⁴¹ Vgl. Sahay et al. (2020).

⁴² Vgl. Techconsult (2021).

Abbildung 2-5: Systematisierung des Untersuchungsgegenstandes



Quelle: WIK, eigene Darstellung.

Nachdem nun die Basis eines konsistenten Verständnisses des Untersuchungsgegenstandes gelegt und damit die erste Forschungsfrage beantwortet wurde, stehen im nächsten Unterkapitel der potenzielle Mehrwert und Nutzen der innovativen Software-Tools aber auch deren Grenzen im Fokus.

2.4 Nutzen von AutoML, Low-Code und No-Code

Im Gegensatz zu herkömmlichen ML-Implementierungsverfahren versprechen alle in Abb. 2-5 dargestellten AutoML, Low- bzw. No-Code Ansätze eine einfachere automatisierte Bereitstellung von ML-Lösungen sowie eine bessere Zugänglichkeit zu ML-Anwendungen für unerfahrene Nutzende (die aber ggf. Domänenwissen besitzen).⁴³ Im Folgenden soll der unternehmerische Nutzen von AutoML sowie von Low- und No-Code sowohl mit als auch ohne Automatisierungskomponenten unter diesen Gesichtspunkten näher betrachtet werden:

- 1) Was sind die aktuellen Herausforderungen von Unternehmen bei der Integration von KI vor dem Hintergrund von „KI Readiness“? (Kapitel 2.4.1)

⁴³ Vgl. Wennker (2020).

- 2) Was sind die Potenziale und Vorteile von AutoML, No- und Low-Code insbesondere im Hinblick auf Citizen Developer und deren Beitrag zur KI-Readiness von Unternehmen? (Kapitel 2.4.2)
- 3) Wo liegen die Grenzen von AutoML und ML-Bausteinlösungen wie Low- und No-Code? (Kapitel 2.4.3)
- 4) Tragen stark automatisiertes ML und Drag-and-Drop-ML zu einem Verlust der Erklärbarkeit von ML-Modellen bei? (Kapitel 2.4.4)

2.4.1 Bedarfe der KMU bei der KI-Integration

Das Konzept der „KI-Readiness“ umfasst einen theoretischen Rahmen, der die Bereitschaft und Fähigkeit von Organisationen bewertet, die KI-Technologie in ihre Geschäftsprozesse zu integrieren. In der Literatur haben sich bislang verschiedene Modelle und Indizes herausgebildet, die unterschiedliche Indikatoren aufführen, die die KI-Readiness eines Unternehmens beeinflussen können.⁴⁴

Ausgehend von diesen KI-Readiness Indikatoren und Faktoren tragen Bettoni's et al. (2021) Interviewergebnisse zusammen, um daran aufzuzeigen, an welchen Punkten Unternehmen aktuell bei einer KI-Integration scheitern:⁴⁵

- KI-Lösungen sind häufig zu komplex für Unternehmen, die bisher nicht mit ML-Methoden in Berührung gekommen sind.
- Unternehmen fällt es schwer, bezahlbare anpassungsfähige KI-Lösungen für ihre spezifischen Anwendungsfälle zu finden. Fehlende Personalisierbarkeit wie beispielsweise ein Fehlen oder ein Übermaß von Features bei standardisierten Anwendungen verstärken diese Problematik.
- Es finden keine KI-Lebenszyklusanalysen statt, daher nehmen viele Unternehmen KI als zu hohen Kostenfaktor wahr. Obwohl dies in vielen Fällen zutreffen kann, fehlt es grundsätzlich an verlässlichen Instrumenten für Kosten-Nutzen Prognosen.
- Fehlendes KI-Talent, soweit ausschließlich nicht-professionelle Entwickler:innen im Unternehmen tätig sind. Erst durch umfangreiches zeitintensives Training kann Mehrwert für ein Unternehmen geschaffen werden.
- Zu wenig Daten, um KI zu trainieren, da Unternehmen relevante Daten nur manuell oder kaum sichern. Für das erfolgreiche Implementieren von KI-Lösungen bedarf es langfristiger systematischer Datenerhebung und strukturierter Datenaufbereitung.

In weiteren Interviews mit KMU werden ähnliche Probleme bei der KI-Integration aufgeführt.⁴⁶ So stellt das Sammeln und Speichern relevanter Daten für die Entwicklung und das Training von ML-Modellen für KMU eine große Herausforderung dar.⁴⁷ Öffentlich zugängliche Daten eignen sich in der Regel nicht für die unternehmensspezifischen Anwendungsfälle, gleichzeitig eignen die

⁴⁴ Vgl. dazu Anhang A1.

⁴⁵ Vgl. Bettoni et al. (2021).

⁴⁶ Vgl. Raghavendran (2022).

⁴⁷ Vgl. Gull et al. (2021).

Unternehmen dazu, Datenstrukturen und Datenqualität zu vernachlässigen, die ein ML-Modell für einen erfolgreichen Trainingsprozess benötigt. Dadurch treten häufig Probleme wie inkompatible Datenformate, Datensilos, fehlende Annotation-Schemata⁴⁸ sowie das Erfordernis von manueller Datenerhebung auf, was eine Integration von ML-Lösungen für KMU erschwert und damit unattraktiv erscheinen lässt.⁴⁹

2.4.2 Potenziale und Vorteile von AutoML, Low-Code und No-Code

Bei der Nutzung von KI-Anwendungen in Unternehmen bestehen vor allem im Bereich der Datenaufbereitung noch Potenziale, diese stark zu vereinfachen bzw. zu automatisieren. Dies zeigt sich z.B. daran, dass Data Scientists laut aktuellen Studien etwa 60% bis 80% ihrer Arbeitszeit mit der Aufbereitung und Organisation von Daten verbringen.⁵⁰ Sowohl AutoML⁵¹ als auch Low- und No-Code mit und ohne Automatisierungskomponente sind geeignete Instrumente, um diese zeitaufwändigen und komplexen ML-Prozesse zu verschlanken. Die Software-Tools ermöglichen es dadurch, den in Kapitel 2.4.1 genannten Herausforderungen im Rahmen der KI-Integration besser begegnen zu können, was sich positiv auf die KI-Readiness der Unternehmen auswirken kann.

Dies wird einerseits anhand der Software-Tools durch die Automatisierung der für die Erstellung eines ML-Modells erforderlichen Prozessschritte erreicht, was den Zugang zu diesen vereinfacht.⁵² Insbesondere die zeitaufwändige Suche nach einer optimalen Parameterkonfiguration kann durch die neuen Lösungen effizienter gestaltet werden, wobei es auch für das klassische codebasierte ML bereits Anbieter gibt, die Teile des ML-Prozesses automatisieren können (z.B. Ray oder Optuna).⁵³ Insbesondere AutoML scheint in dieser Hinsicht bereits vielfältig eingesetzt zu werden. So liefert es im Bereich Computer Vision (CV) in einigen Fällen vergleichbare Resultate wie klassisch programmierte Lösungen, schneidet aber bei Problemen des Natural Language Processing (NLP) bisher deutlich schlechter ab. AutoML wird derzeit auch in den Bereichen Datenkompression, maschinelles Lernen, Bildbeschreibung, Empfehlungssysteme sowie bei der Suche nach Verlust- und Aktivierungsfunktionen eingesetzt.⁵⁴

Eine unmittelbare Auswirkung der durch die Software-Tools erleichterten Zugänglichkeit ist, dass sie eine stärkere Beteiligung der Mitarbeitenden im Rahmen des „Citizen-Developer“-Ansatzes ermöglichen, was den Bedarf an Fachkräften verringert und deren Aufgabenbereich verschiebt.

⁴⁸ Annotations-Schemata helfen beim Vervollständigen von Datensätzen. Bei ML werden häufig Datensätze verwendet, mit denen Neuronale Netzwerke mit Überwachtem Lernen trainiert werden. Hier sind für ein erfolgreiches Training Labels oder Annotationen (Outputdaten für die jeweiligen Inputdaten) notwendig. Vgl. <https://www.v7labs.com/blog/when-to-annotate-data> [Letzter Abruf 16.11.2023].

⁴⁹ Vgl. Olsowski et al. (2022).

⁵⁰ Vgl. ebd.

⁵¹ AutoML-Plattformen werden aktuell vor allem für die Datenaufbereitung, die Suche nach der passenden Architektur für KNN (Neural Architecture Search (NAS)) und die Optimierung der Modellparameter (Training und Evaluierung des Modells) sowie der Hyperparameter verwendet: vgl. Olsowski, et al. (2022).

⁵² Vgl. Abb. 2-4.

⁵³ Ray und Optuna sind spezialisierte Frameworks und Plattformen, die in ML-Projekten verwendet werden können, aber nicht die breite Palette von Aufgaben abdecken, die typischerweise von AutoML-Produkten übernommen werden. Während AutoML-Produkte die Automatisierung von Aufgaben wie Feature Engineering, Modellauswahl und Modelltraining anbieten, bieten Ray und Optuna spezifische Automatisierungsfunktionen für andere Aspekte des ML-Workflows. Vgl. <https://docs.ray.io/en/latest/ray-overview/index.html> [Letzter Abruf 16.11.2023] sowie <https://optuna.org/> [Letzter Abruf 16.11.2023].

⁵⁴ Vgl. He et al. (2021).

So verspricht die Einbindung von Citizen Developer in ML-Prozesse insbesondere für Unternehmen, die über wenig KI-Know-how verfügen, die Chance, digitale KI-Anwendungen schnell, einfach und kostengünstig in ihre Unternehmensstrukturen zu integrieren. Perspektivisch verschieben sich die Tätigkeiten der ML-Expert:innen infolge der zunehmenden Automatisierung des kompletten ML-Frameworks von Fleißarbeiten (wie der Datenaufbereitung) hin zu komplexeren Themenfeldern. Langfristig könnten sie sich auf kritische Entwicklungsschritte von ML-Lösungen fokussieren, in denen fundiertes Fachwissen erforderlich ist, wie beispielsweise das gemeinsame Identifizieren von Anwendungsfällen mit den Domänenexpert:innen. Diese Entwicklungen können daher dazu beitragen, die KI-Readiness von Unternehmen zu erhöhen.⁵⁵

Ein weiterer unmittelbarer Effekt der Automatisierung und der damit verbundenen vereinfachten Zugänglichkeit zur Erstellung von ML-Modellen ist, dass die Software-Tools insbesondere für KMU ein wirtschaftliches Prototyping ermöglichen. Dadurch, dass erste Modelle auch ohne datenwissenschaftliche Expertise von Citizen Developern erstellt werden können, können Sandbox- und Entwicklungskosten reduziert werden. AutoML, Low- und No-Code können somit vor allem hinsichtlich der KI als Innovationstreiber in Unternehmen dienen.⁵⁶

KMU und Großunternehmen sowie IT- und Businessentscheider:innen haben eine differenzierte Sichtweise auf die Auswirkungen der Software-Tools und den vermehrten Einsatz von Citizen Developern, gehen aber von einem positiven Einfluss auf die KI-Readiness aus. Während KMU den hohen Automatisierungsgrad und die Effizienzsteigerung in den Vordergrund stellen, sehen Großunternehmen die Vorteile vor allem in einer höheren Mitarbeitermotivation, kürzeren Release-Zyklen und einer schnelleren Umsetzung der Digitalisierung im Unternehmen. Für IT-Entscheider:innen spielt die Entlastung der IT eine entscheidende Rolle, während für Business-Entscheider:innen der Effizienzgewinn, die Steigerung der digitalen Kompetenz und die Senkung der Implementierungskosten deutlich wichtiger sind. Mit Blick auf die Produktivität scheinen demnach positive Effekte hervorzustechen.⁵⁷

In Anlehnung an das KI-Reifegradmodell von Etlinger⁵⁸ lässt sich der Mehrwert von AutoML, No-Code und Low-Code im Rahmen der KI-Readiness somit vor allem den ersten beiden Reifegraden „Ausprobieren“ und „Experimentieren“ zuordnen. In beiden Fällen können sowohl AutoML-Lösungen als auch ML-Baukastenprinzipien einen substanziellen Beitrag zur unternehmerischen KI-Readiness leisten.⁵⁹ Die folgende Abbildung (Abb. 2-6) fasst die Auswirkungen von AutoML, Low-Code und No-Code auf die KI-Readiness von Unternehmen zusammen.

⁵⁵ Vgl. Raghavendran (2022).

⁵⁶ Vgl. Olsowski et al. (2022).

⁵⁷ Vgl. Olsowski et al. (2022) sowie techconsult (2021).

⁵⁸ Vgl. Etlinger (2018). Das Reifegradmodell unterteilt sich in vier Grade, das veranschaulicht, wie der typische Integrationsprozess von KI in einem Unternehmen abläuft:

- 1) Ausprobieren Auseinandersetzung mit KI in Form von Austausch mit KI-Expert:innen, Anwendungsfälle, keine signifikante Zeit- oder Kosten investiert.
- 2) Experimentieren KI auf eine Reihe von Anwendungsfälle anwenden.
- 3) Formulieren KI wird Bestandteil von Unternehmensabläufen, Daten werden Kernkompetenz.
- 4) Integrieren KI wird Unternehmensbestandteil, eingebunden in Datenprozesse, Produkte und Dienstleistungen.

⁵⁹ Vgl. ebd.

Abbildung 2-6: Einfluss von AutoML, Low-Code und No-Code auf die KI-Readiness von Unternehmen



Quelle: WIK, eigene Darstellung.

Der Vergleich von AutoML, Low-Code und No-Code⁶⁰ zeigt, dass Software-Tools mit einer AutoML-Komponente komparativ zu Tools ohne Automatisierungskomponente die Erstellung von ML-Modellen auf Kosten der Flexibilität vereinfachen. No-Code- und Low-Code-Lösungen ohne Automatisierungskomponente lassen dem Anwendenden im Vergleich zu anderen Lösungen, die eine Automatisierungskomponente enthalten, mehr Freiheiten bei der Auswahl des ML-Modells, der Modellparameter oder der zu verwendenden Features. Auch kann mit diesen individuell über die Automatisierung der in Abbildung 2-4 dargestellten Prozessschritte entschieden werden, wobei für die einzelnen Schritte auch unterschiedliche Anbieter genutzt werden können. Produkte mit einer Automatisierungskomponente hingegen nehmen die Auswahl der zu testenden Modelle automatisch vor⁶¹ und automatisieren in der Regel den gesamten Prozess, was vor allem Vorteile hinsichtlich der vorausgesetzten ML-Kenntnisse bietet.⁶²

Perspektivisch können die Anbindung der Instrumente an bestehende Systeme und ein zukünftig steigender Automatisierungsgrad der Anwendungen die Attraktivität der Tools weiter erhöhen. In Verbindung mit Cloud-basierten Services, die zusätzlich auch Function as a Service (FaaS)⁶³ und

⁶⁰ Vgl. dazu auch die in Abb. 2-5 definierten Dimensionen.

⁶¹ An dieser Stelle sei darauf hingewiesen, dass die hier dargelegten Ausführungen theoretischer Natur sind. Mit Blick auf die am Markt angebotenen Lösungen kann später festgestellt werden, dass AutoML ein wesentlicher Bestandteil aller Produkte der identifizierten Produktpalette ist.

⁶² Vgl. He et al. (2021).

⁶³ Function-as-a-Service ist ein Cloud-Computing-Service, der es ermöglicht, Mikroservice-Anwendungen ohne komplexe Infrastruktur auszuführen. Vgl. <https://www.ibm.com/de-de/topics/faas> [Letzter Abruf 16.11.2023].

Infrastructure as a Service (IaaS)⁶⁴ anbieten, kann die Bedienung von AutoML sowie Low- und No-Code, sowohl mit als auch ohne Automatisierungskomponente, vereinfacht werden.⁶⁵ Das „Pay-as-you-use“-Prinzip, das viele Cloud-Dienstleister anbieten, macht sie dazu kosteneffektiv. Ein weiterer Vorteil ist, dass derartige ML-Lösungen durch die Bereitstellung trainierter Modelle über API-Schnittstellen einfach zu integrieren sind, wobei insbesondere auf die Einhaltung des Datenschutzes geachtet werden muss.⁶⁶ Mit zunehmender Reife kann davon ausgegangen werden, dass zukünftige AutoML- sowie No- und Low-Code-Produkte, sowohl mit als auch ohne Automatisierungskomponente, mehr Funktionen übernehmen können. So wirbt bereits IBM damit, dass ihr AutoAI-Produkt das KI-Lebenszyklusmanagement, die Bereinigung von Verzerrungen, Transferlernen sowie erweiterte Datenverfeinerung automatisieren kann.⁶⁷

2.4.3 Limitierungen von AutoML, Low-Code und No-Code

Wie aufgezeigt werden konnte, können die Software-Tools sinnvoll zur Automatisierung von Prozessschritten für die Erstellung von ML-Modellen eingesetzt werden und die Zugänglichkeit zu diesen damit vereinfachen. Mit der Erhöhung des Automatisierungsgrades der Anwendungen gehen jedoch Limitierungen einher. Grundsätzlich stehen AutoML sowie No- und Low-Code-Lösungen, sowohl mit als auch ohne Automatisierungskomponente, konventionellen ML-Implementierungen häufig in Flexibilität, Interpretierbarkeit, Reproduzierbarkeit und Robustheit nach.⁶⁸ Dass durch umfangreiche Automatisierungen bzw. No- und Low-Code-Lösungen Expert:innen vollständig ersetzt werden können, ist demnach bisher nicht abzusehen und erscheint auch nicht sinnvoll.

Wie bereits in Kapitel 2.4.2 erläutert, schränkt die Automatisierung von ML-Prozessschritten, die Flexibilität der entsprechenden Anwendungen ein. So können No- und Low-Code Ansätze ohne Automatisierungskomponente durch das Bausteinprinzip mehr Auswahlmöglichkeiten bieten, setzen jedoch eine fundierte KI-Expertise voraus. Im Vergleich dazu schränken vollständig automatisierte ML-Prozesse die selbstständige Modellauswahl oder die Selektion von Features ein, erfordern aber weniger Fachwissen.⁶⁹

Die Interpretierbarkeit der Modelle ist in realen Anwendungsfällen erforderlich, da dort Modellparameter manuell optimiert werden müssen. Auch dies erfordert in der Regel entsprechendes Fachwissen. Der höhere Automatisierungsgrad der untersuchten Softwaretools trägt jedoch häufig dazu bei, dass die Vorgehensweise bei der Parameteroptimierung nicht eindeutig nachvollziehbar

⁶⁴ Infrastructure-as-a-Service ist ein Cloud-Computing-Service, der technische Infrastruktur wie Rechner, Speicher, und Netzwerkressourcen on-demand als pay-as-you-go Prinzip anbietet. Vgl. <https://azure.microsoft.com/de-de/resources/cloud-computing-dictionary/what-is-iaas> [Letzter Abruf 16.11.2023].

⁶⁵ Vgl. Raghavendran (2022).

⁶⁶ Vgl. ebd.

⁶⁷ Vgl. <https://www.ibm.com/de-de/cloud> [Letzter Abruf 16.11.2023].

⁶⁸ Die „Tiefe“ der ML-Modelle nimmt mit Menge und Komplexität der Daten zu, was häufig dazu führt, dass die „innere Logik“, aus welchen Gründen das Modell Entscheidung trifft, nicht mehr erkennbar ist. Die Vielzahl an anwendungsspezifischen Parametern erschwert zusätzlich, dass Ergebnisse schnell und einfach reproduziert werden können. Hier spielt auch die Robustheit der Modelle eine zentrale Rolle. Diese beschreibt, wie gut ein Modell mit sich stetig verändernder Umgebungsbedingungen sowie Störquellen („Noise“) in den Datensätzen umgehen kann. Vgl. Hamon et al. (2020).

⁶⁹ Vgl. He et al. (2021).

ist. Aufgrund ihrer geringeren Anpassbarkeit werden sie daher im Vergleich zu konventionellen ML-Implementierungen seltener für Big-Data-Projekte eingesetzt.⁷⁰

Die Reproduzierbarkeit der Ergebnisse stellt mit Blick auf die Software-Tools eine Schwierigkeit dar, da bei automatisierten Lösungen viele Parameter vorab definiert werden müssen. Diese Vorauswahl an Einstellungsmöglichkeiten (Features, Modell, Modellgröße, Parameter) wird von den Anbietern vorgenommen, da eine manuelle parallele Optimierung von Hyperparametern und KNN-Architektur (hyperparameters and architecture optimization (HAO)) aufgrund der Vielzahl an Kombinationsmöglichkeiten oft sehr zeit- und rechenintensiv ist. Zudem können bereits geringe Abweichungen zu gravierenden Unterschieden führen. Diese Vorauswahl beschränkt die Anpassungsfähigkeit der Modelle auf spezifische Anwendungsfälle.⁷¹

Die Erstellung von ML-Modellen mithilfe der Software-Tools geht außerdem mit potenziellen Limitierungen hinsichtlich der Robustheit einher. Grundsätzlich führen unvollständige, fehlerhafte oder verzerrte Daten, wie sie in vielen Unternehmen vorliegen, zu Problemen beim robusten Training der Modelle.⁷² AutoML, Low- und No-Code sind jedoch nicht in der Lage ungeeignete oder verzerrte Datensätze zu korrigieren.⁷³ Das notwendige menschliche Feedback kann am Beispiel öffentlich zugänglicher „Big Data“-Modelle aufgezeigt werden. So werden etwa im Fall von ChatGPT die Trainingsdaten auf manuelle Weise semantisch klassifiziert, um bevorzugtes Entscheidungsverhalten beim Training des Modells zu fördern.⁷⁴

Es konnte gezeigt werden, dass Software-Werkzeuge zwar den Wissensbedarf für die Erstellung eines ML-Modells reduzieren, für die sinnvolle Nutzung dieser Modelle aber nach wie vor fundiertes Wissen erforderlich ist. Beispielsweise sind wichtige menschliche Fachkenntnisse und Handlungsfähigkeiten, wie soziales Verantwortungsbewusstsein, Fähigkeiten, die nicht an automatisierte computergestützte Verfahren ausgelagert werden sollten.⁷⁵ Ein zukünftiges Verhältnis zwischen automatisierten Softwarelösungen und Anwendern könnte daher symbiotisch sein, wobei sich die menschliche Initiative auf kritische Bereiche wie das Abwägen von Interessen, die korrekte Formulierung von Hypothesen und die Festlegung klarer Ziele beschränkt.⁷⁶

70 Vgl. Rokis und Kirikova (2022). Darüber hinaus sei an dieser Stelle darauf hingewiesen, dass im Bereich AutoML, Low- und No-Code bereits erste Produkte wie Auto-ViML existieren, die diese Thematik aufgreifen und entsprechende Frameworks integrieren: Vgl. https://github.com/AutoViML/Auto_ViML [Letzter Abruf 16.11.2023].

71 Vgl. He et al. (2021).

72 Vgl. ebd.

73 Vgl. ebd.

74 Für die Datenaufbereitung und die nachträgliche Feinjustierung von den LLM-Modellen sind häufig manuelle Arbeiten nötig, die nach medialer Recherche insbesondere in Niedriglohnländern unter fragwürdigen Arbeitsbedingungen durchgeführt werden. Tausende Textausschnitte müssen individuell geprüft und mit einem Label versehen werden. Viele der manuellen Arbeiten wurden nach Kenia ausgelagert, wo den Angestellten rund 2 US-Dollar pro Stunde bezahlt wurde. Vgl. Ruffle et al. (2023).

75 Vgl. Xin et al. (2021).

76 Vgl. ebd.

2.4.4 Geringere Erklärbarkeit von automatisierten Softwarelösungen

AutoML, No-Code- und Low-Code-Lösungen können grundsätzlich dazu beitragen, die „Black-Boxes“ von ML-Modellen und insbesondere KNN aufzuschlüsseln, bieten aber auch das Risiko, eine geringere Erklärbarkeit ebendieser zu erzeugen.⁷⁷ Die Black-Box Eigenschaft eines ML-Modells sorgt dafür, dass nicht mehr nachvollzogen werden kann, wie die berechnete Ausgabe zu einem gegebenen Input zustande kommt. In einigen Bereichen kann eine lückenlose Rückverfolgung irrelevant sein, bei Anwendungsfällen in denen ML-Modelle potenziell diskriminierende (bspw. im Personalmanagement, in Sozialen Medien, bei Chatbots) oder kritische (bspw. in der Medizin, beim autonomen Fahren, in der Rüstungsindustrie) Entscheidungen treffen, ist allerdings maximale Transparenz erforderlich.⁷⁸

Insbesondere in den letzten Jahren sind komplexe ML-Modelle veröffentlicht worden, die mithilfe riesiger Datensätze (vor)trainiert wurden. Im Fall vom Large Language Modell ChatGPT-3 der Firma OpenAI geht man mit steigender Tendenz von mehreren Terrabyte an Trainingsdaten und mehrerer Milliarden Modellparameter aus, die während des Trainingsprozess optimiert worden sind.⁷⁹ Es lässt sich demnach erkennen, dass dort die Erklärbarkeit des Modells nicht im Fokus steht. Auch bei weiteren stochastischen⁸⁰ ML-Modellen dieser Größenordnungen ist es selbst den Entwickler:innen nicht mehr möglich, die Ausgaben der Modelle eindeutig zu erklären.

Die geplante KI-Verordnung der EU zielt beispielsweise unter anderem darauf ab, mehr Transparenz, Rechenschaftspflicht und Verständlichkeit bei der Gestaltung von KI-Systemen zu integrieren.⁸¹ Einen Schritt weiter ist bereits die BaFin, die einen aufsichtsrechtlichen Rahmen formuliert hat, der den KI-Einsatz in der Bankenbranche reguliert. In diesem wird explizit auf die „Black-Box“ Problematik von ML-Modellen eingegangen und festgesetzt, dass bei komplizierten, selbstlernenden ML-Methoden die grundlegende Aufgabenbeschreibung und die maßgebenden Entscheidungsparameter erklär- und kontrollierbar sein müssen.⁸² Auch die europäische Datenschutzgrundverordnung (DSGVO) schränkt den Gebrauch von intransparenten ML-Modellen bereits soweit ein, dass (potenzielle) Kund:innen keinen (Geschäfts-)Entscheidungen unterliegen dürfen, die allein aus einer automatisierten Verarbeitung ihrer personenbezogenen Daten resultieren.⁸³ Das Entscheidungsverhalten von ML-Modellen muss also objektiv begründet und nachvollziehbar gestaltet sein. Um die Intransparenz in AutoML sowie No-Code- und Low-Code-Ansätzen sowohl mit als auch ohne Automatisierungskomponente, zu reduzieren, ist es wichtig, transparente

⁷⁷ Vgl. Wennker (2020).

⁷⁸ Vgl. Schmidt und Buxmann (2019).

⁷⁹ Für die konkrete Anzahl der Werte mit Stand vom 11.09.2022, vgl. GPT-3 Statistiken. <https://businessolution.org/de/gpt-3-statistics/> [Letzter Abruf 16.11.2023].

⁸⁰ Klassische Algorithmen folgen einem deterministischen regelbasierten Prinzip. Der Output zu einem Input ist eindeutig und erklärbar, da die Verhaltensregeln des Algorithmus vorher festgelegt wurden. Im Unterschied dazu leiten datenbasierte ML-Algorithmen Verhaltensregeln aus Daten ab. Dafür nutzen sie Lernalgorithmen, die selbstständig Beziehungsmuster zwischen den Eingabe- und Ausgabedaten finden. Das trägt dazu bei, dass selbst bei unvollständigen und nicht-linearen Datensätzen ML-Algorithmen fähig sind, Muster abzuleiten. Im Gegensatz zu deterministischen Ansätzen sind sie stochastisch und basieren damit auf Wahrscheinlichkeiten, daher kann dieselbe Eingabe zu unterschiedlichen Outputs führen. Vgl. Sonnet, (2022a).

⁸¹ Vgl. Regulatorisches Framework zu AI: <https://digital-strategy.ec.europa.eu/en/policies/regulatory-framework-ai> [Letzter Abruf 16.11.2023].

⁸² Vgl. § 25a KWG, MaRisk, BAIT, vgl. auch Schmidt und Buxmann. (2019).

⁸³ Gemäß Artikel 22 Abs. 1 DSGVO, vgl. auch Schmidt und Buxmann. (2019).

Prozesse und Werkzeuge zur Modellerklärung zu integrieren. Dies kann dazu beitragen, dass die Entscheidungsfindung der Modelle besser nachvollziehbar wird.

2.4.5 Zwischenfazit

Zusammenfassend lässt sich konstatieren, dass AutoML-, Low-Code- und No-Code-Technologien einen bedeutenden Beitrag zur Steigerung der KI-Readiness von Unternehmen und insbesondere KMU leisten können. Sie bergen das technische Potenzial, eine effizientere und zugänglichere Möglichkeit für nicht-professionelle Entwickler:innen zu schaffen. Unternehmen, die bisher aus diversen Gründen noch nicht von der KI-Technologie profitieren bzw. sich mit dieser noch nicht auseinandersetzen konnten, wird dadurch ein einfacher Zugang zur selbstbestimmten Entwicklung von ML-Modellen ermöglicht. Diese neuen innovativen Entwicklungsumgebungen bieten dadurch das Potenzial, die digitale Transformation zu beschleunigen und die Entwicklung von KI-Anwendungen und KI-Lösungen in Unternehmen partizipativer zu gestalten. Einschränkend bleibt mit Blick auf die dargestellten innovativen Ansätze zur Entwicklung und Implementierung von ML-Modellen jedoch festzuhalten, dass diese gerade im Vergleich zu klassischen Entwicklungsumgebungen auch Limitierungen aufweisen. Eine fehlende Erklärbarkeit der Modelle oder ihre geringere Anpassungsfähigkeit scheinen den Einsatz derartiger Lösungen einzuschränken bzw. mit anderen Kosten zu behaften.

Nachdem in diesem Kapitel neben den technischen Potenzialen von AutoML, Low-Code und No-Code für die Integration von KI-Lösungen und insbesondere ML-Modellen auch die Grenzen solcher Ansätze untersucht wurden, stehen im nächsten Kapitel die konkreten Produktlösungen und deren Anwendungsbereiche im Fokus und wie diese technischen Möglichkeiten in aktuellen Marktangeboten umgesetzt werden.

Die nachstehenden Textboxen fassen die Erkenntnisse dieses Kapitels in Bezug auf die Vorteile der vorgestellten ML-Anwendungstools sowie deren mögliche Limitierungen zusammen.

Vorteile für Unternehmen

Beschleunigte Entwicklung: Diese Ansätze ermöglichen es Unternehmen, Anwendungen und Modelle schneller zu entwickeln, da weniger Zeit für die Programmierung und technische Details aufgewendet werden muss.

Kosteneffizienz: Die Verwendung von Low-Code und No-Code-Plattformen kann die Entwicklungskosten reduzieren, da weniger spezialisierte Entwickler:innen benötigt werden und der Entwicklungsprozess beschleunigt wird.

Skalierbarkeit: Unternehmen können leichter skalierbare Anwendungen erstellen, da diese Ansätze oft auf vorgefertigten Bausteinen und Diensten basieren.

Bessere Nutzung von Ressourcen: Nicht-technische Mitarbeitende können an der Entwicklung teilnehmen, was die Nutzung von Ressourcen im Unternehmen optimieren kann.

Fehlerreduktion: Die Verwendung von AutoML kann dazu beitragen, menschliche Fehler bei der Modellentwicklung zu minimieren, da viele Prozesse automatisiert sind.

Vorteile für Citizen Developer

Einfacher Einstieg: Personen ohne umfangreiche technische Kenntnisse können mit Low-Code und No-Code leichter in die Anwendungsentwicklung und Datenanalyse einsteigen.

Schnellere Umsetzung von Ideen: Nicht-professionelle Entwickler:innen können Ideen schneller in funktionierende Anwendungen oder Modelle umsetzen, ohne tiefgehende Programmierkenntnisse zu benötigen.

Niedrigere Einstiegshürden: Diese Ansätze verringern die Notwendigkeit, viel Zeit und Geld in die Ausbildung von Entwickler:innen zu investieren, was den Einstieg in technologieorientierte Projekte erleichtert.

Mehr Autonomie: Individuen und Teams können eigenständig Projekte durchführen, ohne auf IT-Abteilungen oder externe Entwickler:innen angewiesen zu sein.

Priorisierung: Nicht-professionelle Entwickler:innen können sich stärker auf die Geschäftsaspekte ihrer Projekte fokussieren, da sie weniger Zeit mit technischen Details verbringen müssen.

Potenzielle Limitierungen

Automatisierung ohne Kontrolle: Bei AutoML werden viele Entscheidungen im Modellierungsprozess automatisiert, einschließlich der Auswahl von Hyperparametern, Feature Selektion und Feature Engineering. Dies kann dazu führen, dass Entwickler:innen weniger Einblick in die Entscheidungsfindung des Modells haben, da viele dieser Prozesse automatisiert ablaufen.

Abstraktionsebene: No-Code und Low-Code-Plattformen abstrahieren oft die technischen Details des Modellierungsprozesses. Während dies die Anwendung von Machine Learning für Nicht-Expert:innen erleichtert, kann es dazu führen, dass die Nutzenden weniger Verständnis für die inneren Arbeitsweisen der Modelle haben.

Black-Box-Modelle: AutoML-Tools verwenden oft komplexe Modelle wie neuronale Netzwerke, die als "Black-Box-Modelle" bekannt sind. Diese Modelle sind schwer zu interpretieren, da sie keine klaren Zusammenhänge zwischen Eingabe und Ausgabe haben, was die Erklärbarkeit erschwert.

Mangelnde Kontrolle über Daten: No-Code und Low-Code Plattformen verwenden häufig vorgefertigte Datenvorverarbeitungsschritte, bei denen Nutzende weniger Kontrolle über die Daten haben. Dies kann dazu führen, dass unerwünschte oder nicht nachvollziehbare Transformationen auf die Daten angewendet werden.

Verdeckte Bias und Fehler: Wenn Entwickler:innen die Details der Modellerstellung nicht verstehen, können verdeckte Bias oder Fehler in den Modellen übersehen werden. Dies kann zu unbeabsichtigten Diskriminierungen oder falschen Entscheidungen führen.

3 Erhebung des Marktangebotes von AutoML, Low-Code und No-Code

Grundsätzlich besteht die Idee, den Zugang zu und die Erstellung von ML-Modellen für Nutzende durch Automatisierung von Aufgaben oder die Integration grafischer Bedienelemente zu erleichtern, schon länger.⁸⁴ Einige Software-Tools im Bereich AutoML, Low- und No-Code wurden bereits entwickelt und am Markt angeboten.

Im Fokus des vorliegenden Kapitels stehen nun die aktuell wichtigsten am Markt vorhandenen Produkte im Bereich AutoML, Low-Code und No-Code. Der zu gebende Überblick erhebt keinen Anspruch auf Vollständigkeit. Aufgrund der derzeitigen Aktualität der Thematik KI, scheint eine dynamische Entwicklung dieses Softwaremarktes wahrscheinlich, die hier jedoch nicht weiter abgebildet werden kann, da die Erhebung als Status Quo erfolgt.

Für den Einblick in die identifizierte Produktpalette folgt zunächst eine Beschreibung der Produktidentifizierung (Kapitel 3.1) sowie der Erfassungsmethodik (Kapitel 3.2). Daran anschließend werden in einem nächsten Schritt in diesem Kapitel die wichtigsten Ergebnisse beispielhaft dargestellt sowie einer deskriptiven Analyse unterzogen (Kapitel 3.3). Das Kapitel schließt mit einem Fazit zur Erhebung des Marktangebots (Kapitel 3.4).

3.1 Methodik der Produktidentifizierung

Im Rahmen der Identifizierung von Produkten aus dem Bereich AutoML, Low-Code und No-Code wurde auf die Methodik des Desk Researchs zurückgegriffen. Dazu wurden Internetrecherchen in Suchmaschinen und Literaturdatenbanken durchgeführt, um in Ranglisten, Blogs, Fachliteratur und Fallstudien angebotene Lösungen des genannten Bereichs zu ermitteln. Bei der Erstellung dieser Vorauswahl fanden a priori noch keine Anforderungen Berücksichtigung, die zu einem Ausschluss geführt hätten. Es konnten damit zunächst 74 Produkte identifiziert werden.

Um in einem nächsten Schritt die angedachte tiefergehende Analyse der Produkte zielgerichtet zu gestalten, wurden Kriterien herangezogen, anhand derer eine Auswahl stattfand. Damit sollte sichergestellt werden, dass nur die Produkte berücksichtigt werden, die für den Untersuchungsgegenstand von Relevanz sind.

Zunächst wurde geprüft, ob bei den Produkten der Vorauswahl die Erstellung von ML-Modellen im Fokus steht. Damit wurden Lösungen, die auf die Vereinfachung allgemeiner Digitalisierungsaspekte, wie bspw. der Digitalisierung von Urlaubsanträgen, abzielen, nicht weiter berücksichtigt.⁸⁵ Unberücksichtigt blieben dadurch auch diejenigen Angebote, die zur Verfolgung eines anderen primären Ziels auf KI bzw. ML lediglich als Hilfstool zurückgreifen. Die Technologie wird in Plattformen beispielsweise dazu verwendet, die Dateneingabe über eine Dokumentenerfassung zu automatisieren. Die Erstellung von ML-Modellen ist über solche Produkte jedoch nicht möglich

⁸⁴ So datiert etwa der Start von Microsofts Azure Machine Learning Studio, das erste grafische Bedienelemente zur vereinfachten Erstellung von ML-Modellen nutzte, auf das Jahr 2014: vgl. <https://azure.microsoft.com/en-us/blog/diving-deep-into-what-s-new-with-azure-machine-learning/> [Letzter Abruf 16.11.2023].

⁸⁵ Vgl. dazu bspw. das für die long-list identifizierte Tool „Simplifier“: <https://simplifier.io/> [Letzter Abruf 16.11.2023].

bzw. steht dort nicht im Fokus.⁸⁶ Die Vorauswahl konnte dadurch um 22 Lösungen auf 52 identifizierte Produkte reduziert werden.

In dieser Studie sollen diejenigen Lösungen im Fokus stehen, die die Befähigung kleiner und mittlerer Unternehmen außerhalb des IT-Sektors erhöhen, KI- oder ML-basierte Lösungen eigenständig zu implementieren. In einem nächsten Schritt wurde daher geprüft, ob die verbliebenen Angebote auf den Einsatz in Anwender-Unternehmen abzielen. Es wurden somit die Angebote ausgeschlossen, die auf die Vereinfachung für professionelle IT-Entwickler:innen abstellen.⁸⁷ Damit konnten weitere 13 Produkte ausgeschlossen werden.

In einer nächsten Iteration wurden nur die Use-Cases aufgenommen, die eine generische Anwendung statt einer einzelnen definierten Anwendung ermöglichen, d.h. die Angebote, die die Befähigung der Unternehmen erhöht, sich unabhängig vom jeweiligen Anwendungsfall eigenständig mit der Entwicklung eines ML-Modells auseinanderzusetzen und dieses potenziell implementieren zu können, wurden weiter berücksichtigt. Software-Tools mit einem zu spezifischen Fokus auf einzelne Anwendungen, Branchen oder Nischenmärkte hingegen wurden aussortiert.⁸⁸ Die Liste der Vorauswahl konnte damit um vier weitere Produkte reduziert werden.

Als letztes Kriterium, wurden nur Produkte in die tiefergehende Untersuchung einbezogen, die über eine ausreichende Dokumentation (sogenannte „Doks“) verfügen sowie durch Updates regelmäßig aktuell gehalten werden. Dadurch wird sichergestellt, dass eine tiefergehende Analyse des jeweiligen Produkts überhaupt erst möglich und sinnvoll ist. Anhand dieses Kriteriums konnten nochmals sechs Produkte ausgeschlossen werden, womit 29 Produkte identifiziert werden konnten, die im Fokus der weiteren Analyse stehen.

⁸⁶ Vgl. dazu bspw. das für die Long-List identifizierte Tool „DeepCognition“: <https://deepcognition.ai/introduction/> [Letzter Abruf 16.11.2023].

⁸⁷ Vgl. dazu bspw. das für die Long-List identifizierte Tool „Neptune.Ai“, das auf eine Nutzung von ML-Ingenieuren und Data-Scientists abzielt: <https://neptune.ai/> [Letzter Abruf 16.11.2023].

⁸⁸ Für ein Produkt mit spezifischem Use-Case-Fokus, vgl. bspw. das für die Long-List identifizierte Tool „Splunk“, welches sich insbesondere auf die Analyse von Logs, Metriken und weiteren Daten von Applikationen, Servern und Netzwerkgeräten zu Sicherheitszwecken fokussiert: <https://www.splunk.com/> [Letzter Abruf 16.11.2023].

Abbildung 3-1: Reduktion des identifizierten Marktangebots um einheitlich festgelegte Auswahlkriterien



Quelle: WIK, eigene Darstellung.

3.2 Methodik der Produkterfassung

Die 29 Produkte, die anhand der in Kapitel 3.1 beschriebenen Methodik aus dem Bereich AutoML, Low-Code und No-Code identifiziert werden konnten, wurden in einem nächsten Schritt einer tiefergehenden Analyse unterzogen, die das Ziel verfolgt, die angebotenen Software-Tools einerseits in ihre einzelnen (technischen) Bestandteile zu zerlegen sowie andererseits anhand definierter Kriterien zu clustern. Dazu wurden folgende Indikatoren definiert, die vor allem auf den Erkenntnissen aus Kapitel 2 beruhen:

- Einordnung des Produkts in die Systematisierung des Untersuchungsgegenstands (Entwicklungsumgebung):** Die einzelnen Produkte werden in die in Abbildung 2-5 des Kapitels 2.3.3 aufgespannte Matrix eingeordnet. Da die Möglichkeit existiert, dass ein Produkt mehrere der in der Matrix dargestellten Ebenen bspw. anhand einer Plattformstruktur adressieren kann, wird diese Einordnung nicht konkret in der Grafik, sondern anhand eines Checks der zutreffenden dort definierten und vom Produkt adressierten Dimensionen vorgenommen. Zur Auswahl stehen damit die folgenden Bereiche: (1) *AutoML*, (2) *No-Code* sowie (3) *Low-Code*. Da nicht immer eine explizite Zuordnung zu diesen Kategorien vorlag, wurde zur Unterscheidung vor allem auf Produktbeschreibungen und Erklärungen, die auf der Produktwebseite zu finden waren, zurückgegriffen. Anhand dessen wurde bspw. der Prozess zur Erstellung eines ML-Modells analysiert, um zu bestimmen, welche Bereiche vom entsprechenden Software-Tool abgedeckt werden.
- Lernansatz:** Zur weiteren technischen Entflechtung der identifizierten Produkte werden diese im nächsten Schritt nach den unterschiedlichen Lernansätzen kategorisiert. Dazu wurde auf die Erkenntnisse aus Kapitel 2.1 und insbesondere auf die Grundprinzipien des ML, dargestellt in Abbildung 2-2, zurückgegriffen. Damit wird zwischen den Ansätzen des Überwachten-, Unüberwachten-, Teilüberwachten- und Verstärkendem Lernen unterschieden. Die Zuordnung der genannten Lernansätze zu den jeweiligen Produkten findet auf Grundlage der Dokumentationen der Angebote statt.

- **ML-Methoden:** Darüber hinaus werden den angebotenen Software-Tools allgemeine ML-Methoden, wie etwa Classification, Regression, Clustering etc. zugeordnet. Die Zuordnung dieser findet ebenfalls auf Grundlage der entsprechenden Dokumentation *ohne Beschränkung* auf bestimmte Methoden statt. Die konkreten Algorithmen, wie etwa K-Means, Entscheidungsbäume, Neuronale Netze, etc., die wiederum den allgemeinen Methoden zugeordnet werden können, wurden an dieser Stelle nicht untersucht.⁸⁹

Darüber hinaus wurden die identifizierten Produkte auch nach folgenden, allgemeinen bzw. nicht ML-spezifischen Indikatoren klassifiziert:

- **Produktname und Größe des Anbieters:** Bezüglich der Größe findet eine Differenzierung zwischen den Größenklassen *Top 10 des S&P 500*; *Top 100 des S&P 500*; *Sonstige Großunternehmen* sowie *KMU und Start-ups unter 500 MA* sowie *Sonstige* statt.
- **Vorausgesetzte IT-Kenntnisse:** Für die Klassifizierung der vorausgesetzten IT-Kenntnisse wird zwischen den beiden Klassifizierungen *Ohne Coding-Skills* sowie *Basic Coding-Skills* differenziert. Dazu wurde vor allem auf die Angaben der Anbieter, aber auch auf entsprechende Produktbeschreibungen und -visualisierungen der Produktwebseiten zurückgegriffen.
- **Softwareumgebung:** In dieser Kategorie wird untersucht, in welcher Umgebung die Softwarelösung dem Kunden zur Verfügung gestellt wird. Dabei wird zwischen *Package (Erweiterung)*, *App (Anwendung)*, *KI-Plattform* und *Web-GUI* unterschieden. Die entsprechende Angabe wird der Dokumentation des Produkts entnommen.⁹⁰
- **Software-Lizensierung:** Wie auch andere Software-Produkte, werden die in diesem wissenschaftlichen Diskussionsbeitrag beleuchteten Angebote lizenzrechtlich auf verschiedene Weisen zur Verfügung gestellt. Als wichtigstes Unterscheidungsmerkmal wird zwischen *proprietär* angebotenen Produkten und *Open-Source* Software unterschieden.
- **Bereitstellungsmodell:** Mit Blick auf die Bereitstellungsmodelle von Software-Angeboten wird zwischen den Methoden *Cloud* und *On-Premise* unterschieden, um den für Unternehmen relevanten Umstand des Betriebs der Lösungen einzubeziehen. Es sei darauf hingewiesen, dass ein Produkt auch in beiden Modellen angeboten werden kann.⁹¹

Um die oben aufgeführten allgemeinen und spezifischen Indikatoren der entsprechenden Produkte ausfindig zu machen, wird einerseits auf Primärquellen der Anbieter zurückgegriffen. So sind im Regelfall die technischen Spezifikationen in den Dokumentationen zu finden. Produkte, die über diese nicht verfügen, blieben unberücksichtigt. Die restlichen dadurch nicht auswertbaren

⁸⁹ Für eine ausführliche Auflistung konkreter ML-Algorithmen, sei an dieser Stelle dazu auf <https://scikit-learn.org/> [Letzter Abruf 16.11.2023] bzw. für Reinforcement-Algorithmen auf <https://numpy-ml.readthedocs.io/> [Letzter Abruf 16.11.2023] verwiesen.

⁹⁰ Für eine tiefergehende Erklärung dieser Begrifflichkeiten des Bereichs „Softwareumgebung“ sei an dieser Stelle auf die nachfolgende Textbox dieses Unterkapitels verwiesen.

⁹¹ Dabei greifen Unternehmen ohne KI-Infrastruktur bereits vermehrt auf „AI as a Service“ (AlaaS) oder „AI service platforms“ zurück, um KI-Anwendungsfälle on demand und Cloud-basiert entwickeln und implementieren zu können vgl. dazu Sundberg und Holmström (2023). AlaaS-Anbieter werben außerdem mit einfacher KI-Implementierung und Benutzung von KI durch den Wegfall externer Hardware-Infrastruktur und der Redundanz von KI-Expertise. Dafür bieten sie umfangreiche ML-Algorithmen und ML-Anwendungen und das Bereitstellen von APIs zur reibungslosen Integration von trainierten Modellen an. Vgl. dazu Wisneski (2022).

Indikatoren werden anhand von Sekundärquellen (bspw. Fachartikel) recherchiert. Deren Fokus liegt in der Regel weniger auf den technischen Faktoren, sondern eher auf den oben gelisteten nicht-technischen Kriterien.

Erklärung der Begrifflichkeiten des Bereichs „Softwareumgebung“

Package (Erweiterung): Ein Package ist eine Sammlung von Modulen. Module sind vorgefertigte Code-Pakete, die es ermöglichen, bestimmte Funktionen direkt zu nutzen, ohne sie selbst programmieren zu müssen. In dieser Studie wird der Begriff im Rahmen der Open-Source-Bewegung verstanden, womit ein Package den gesamten Quellcode umfasst, der in der weiteren Entwicklung erweitert oder angepasst werden kann. Eine Integration dieser Packages ist im Rahmen des ML in ein Software-Framework wie z.B. PyTorch oder TensorFlow möglich. Packages werden häufig auf Plattformen wie Github veröffentlicht und/oder über „Package Manager“ wie PyPI (Python Package Index) bezogen. Eine Sammlung von Packages wird als Bibliothek bezeichnet.

App (Anwendung): Eine App ist eine spezifische Softwareanwendung, die zur Ausführung auf bestimmten Geräten entwickelt wurde. Hinsichtlich der Implementierung gibt es keine Einschränkungen, so dass sowohl native Apps als auch Web-Apps in diese Kategorie fallen. Eine App bietet den Benutzern spezifische Funktionen und Dienste, die sich in dieser Studie auf die Erstellung von ML-Modellen beziehen. Im Vergleich zu Packages sind Apps idR weniger flexibel und können nicht angepasst werden.

KI-Plattform: Eine KI-Plattform ist ein integrierter Technologiebaukasten, der es Menschen ermöglicht, ML- und DL-Modelle zu entwickeln, zu testen, anzuwenden und zu aktualisieren. Im Vordergrund der in dieser Studie verwendeten Definition steht, dass es sich um eine grundlegende Struktur für die Erstellung von ML-Modellen handelt, die eine aufwandsarme Integration von vordefinierten Tools, Modellen und anderer Komponenten zur Spezifikation ermöglicht.

Web-GUI: Eine Web-GUI ist eine spezifische Softwareanwendung, die nur über einen Webbrowser zugänglich und nutzbar ist. Diese Anwendung wird auf Webservern gehostet und ermöglicht den Benutzenden den Zugriff auf Funktionen über das Internet, die im Rahmen dieser Studie hauptsächlich Funktionen zur Erstellung eines ML-Modells umfassen. Eine Installation auf lokalen Geräten ist nicht erforderlich.

Quelle: In Anlehnung an Techtargget – Computer Glossary.⁹²

3.3 Erfassung von (Software-)Lösungen

Auf Grundlage der oben beschriebenen Erfassungsmethodik konnten 29 Produkte ausgemacht werden. Eine detaillierte Dokumentation der einzelnen Produkte und ihrer Eigenschaften ist in Anhang A3 aufgeführt.⁹³ Im Folgenden werden die untersuchten Merkmale des Produkts Clarifai (dargestellt in Abb. 3-2) exemplarisch betrachtet, ehe in einem nächsten Schritt die identifizierten Produkte auf Gesamtebene dargestellt und untersucht werden.

Der namensgebende Anbieter des Produkts Clarifai kann der Kategorie KMU und Start-ups unter 500MA sowie Sonstige zugeordnet werden. Das Produkt wird sowohl in der Form eines Packages als auch in der Form einer KI-Plattform angeboten. Als KI-Plattform eröffnet Clarifai Personen mit keinen oder geringen Programmierkenntnissen den Zugriff auf ML-Anwendungen, während sich die Package-Variante vor allem an Personen mit grundlegenden Programmierkenntnissen richtet. Für beide Softwareumgebungsformen bietet das Produkt die Wahl auf diese On-Premise oder in der Cloud zuzugreifen, wobei das Lizenzmodell proprietär ist. Grundsätzlich fallen die angebotenen ML-Methoden in die Bereiche des Überwachten-, Teilüberwachten- sowie des

⁹² Vgl. Techtargget – Computer Glossary, abrufbar unter: <https://www.techtargget.com/whatis/> [Letzter Abruf 01.12.2023].

⁹³ Vgl. Kapitel A2. In der Auswertung der Ergebnisse werden die spezifischen Lernansätze (überwachtes, unüberwachtes, teilüberwachtes und verstärkendes Lernen), obwohl erhoben, vernachlässigt, da eine klare Zuordnung der ML-Methoden zu den einzelnen Lernansätzen nicht möglich ist.

Unüberwachten Lernens und decken damit insbesondere Anwendungsfelder ab, in denen CV, NLP und generative Modelle eingesetzt werden können.

Abbildung 3-2: Produktsteckbrief Clarifai

Clarifai ⁹⁴
Anbieter <ul style="list-style-type: none"> • Anbieter: Clarifai • Größe des Anbieters: KMU und Start-ups unter 500 MA sowie sonstige
Produkt <ul style="list-style-type: none"> • Produktname: Clarifai • Softwareumgebung: Package, KI-Plattform • Zielgruppe: Ohne Coding-Skills und Basic Coding-Skills • Matrixbereich: AutoML, Low-Code, No-Code • Bereitstellungsmodell: On-Premise, Cloud • Software-Lizensierung: Proprietär
ML-Spezifikation <ul style="list-style-type: none"> • Lernansatz: <ul style="list-style-type: none"> ○ Überwachtes Lernen, Teilüberwachtes Lernen, Unüberwachtes Lernen • ML-Methoden: <ul style="list-style-type: none"> ○ CV, NLP, Generative Modelle

Quelle: WIK, eigene Darstellung.

Abbildung 3-3 stellt die identifizierten AutoML-, Low-Code- und No-Code-Produkte im Überblick dar. Dazu werden der Produktname sowie die Unternehmensgröße des Anbieters aufgeführt. Es erfolgt eine Einordnung, welche spezifischen ML-Methoden durch das Produkt abgedeckt werden und ob AutoML-, No-Code- und Low-Code-Lösungen Teil des jeweiligen Produktes sind.

Produktportfolio: Grundsätzlich lässt sich anhand von Abbildung 3-3 konstatieren, dass AutoML bei allen identifizierten Anbietern Teil des Produktportfolios ist und (optional) im Verbund mit No-Code bzw. Low-Code angeboten wird. Damit basieren alle in dieser Studie als relevant identifizierten Produkte auf AutoML. Top 100 S&P500 Unternehmen wie Microsoft, IBM und Google scheinen mit Ihren Produkten die komplette Bandbreite von klassischen AutoML Produkten über Low-Code Umgebungen für AutoML Lösungen bis hin zu No-Code Umgebungen abzudecken und ermöglichen somit allen Erfahrungsstufen der Nutzenden einen Zugang zu ihren ML-Softwarelösungen.

⁹⁴ Vgl. <https://docs.clarifai.com/> [Letzter Abruf 16.11.2023].

Die letzte Spalte der Tabelle in Abbildung 3-3 zeigt, dass die überwiegende Mehrheit der Produkte eine Vielzahl von Standard-ML-Methoden abdeckt (Regression, Klassifikation, Clustering, CV, Vorhersage, NLP). Diese breite Methodenabdeckung ist unabhängig vom Lizenzierungsmodell, d.h. unabhängig davon, ob das Produkt proprietär oder Open-Source angeboten wird. Dies lässt darauf schließen, dass die Anwendenden der Produkte bei der Auswahl einer ML-Methode für einfache Anwendungsfälle nicht wesentlich eingeschränkt sind. Nur spezifischere ML-Methoden wie "Strategische Analyse und Gefahrenerkennung" oder "Multimodale Modelle" sind in der Regel mit Kosten verbunden und werden über KI-Plattformen oder als Apps angeboten.⁹⁵

Abbildung 3-3: Anbieterübersicht identifizierter AutoML, Low-Code und No-Code Produkte

Unternehmenstyp	Produktname	AutoML	No-Code	Low-Code	ML-Methode
KMU und Startups unter 500 MA sowie Sonstige					
	Akkio	✓	✓		Klassifikation, Regression, CV, NLP
	Appypie	✓	✓		NLP
	Auto-ViML	✓			Klassifikation, Regression, CV, NLP, Entscheidungsmodelle
	Auto-SKLearn	✓			Klassifikation, Regression, Optimierung
	AutoGluon	✓			Multimodale Modelle, Klassifikation, Regression, CV, Time Series
	Auto-Keras	✓			Klassifikation, NLP, Regression
	BigML	✓	✓		Klassifikation, Regression, Zeitreihen, Dimensionsreduktion, Clusteranalyse
	Graphite Note	✓	✓		Klassifikation, Regression, Time Series, Vorhersage, Clusteranalyse
	H2O AutoML	✓	✓	✓	Klassifikation, Regression, Clusteranalyse
	MLJar	✓			Klassifikation, Regression
	Levity	✓	✓		Klassifikation, NLP, CV
	Clarifai	✓	✓	✓	CV, NLP, Generative Modelle
	Obviously AI	✓	✓		Klassifikation, Regression, Time Series
	Pecan	✓	✓		Vorhersage, Regression
	Primer	✓	✓		Strategische Analyse, Gefahrenerkennung
	PyCaret	✓			Regression, Klassifikation, Time Series, Clusteranalyse, Anomalie-Erkennung
	Rapid Miner	✓	✓	✓	Vorhersage, Regression, Optimierung, Time Series
	Runway AI/ML	✓	✓		Multimodale Modelle
	Tazi.ai	✓		✓	Klassifikation, Regression, Clustering, Anomalieerkennung
	Teachable Machine	✓		✓	Klassifikation, CV
Top 10 S&P500					
	AWS SageMaker Canvas	✓	✓	✓	Klassifikation, Regression, Vorhersage, NLP, CV
	Vertex AI (Google)	✓	✓	✓	Klassifikation, NLP, CV
	Lobe (Microsoft)	✓	✓		CV
	Power Apps (Microsoft)	✓	✓		Vorhersage, CV, NLP, Klassifikation
	MS Azure AutoML (Microsoft)	✓	✓	✓	Klassifikation, Vorhersage, Regression, CV, NLP
Top 100 S&P500					

⁹⁵ Vgl. dazu bspw. die Produkte „IBM Watson Studio“ sowie „Primer“ in Anhang A3.

Unternehmenstyp	Produktname	AutoML	No-Code	Low-Code	ML-Methode
KMU und Startups unter 500 MA sowie Sonstige					
	TransmogriAI (Salesforce)	✓			Vorhersage, Klassifikation, Regression
	IBM Watson Studio	✓	✓	✓	Vorhersage, Klassifikation, Regression, Entscheidungsmodelle, Multimodale Modelle, Clusteranalyse, Time Series, NLP, CV
Sonstige Großunternehmen					
	Data Robot	✓	✓	✓	Generative Modelle, Vorhersage, Klassifikation, Clusteranalyse, Multimodale Modelle, Segmentierung
	Dataiku	✓	✓	✓	Vorhersage, Clusteranalyse, CV, Klassifikation, Time Series

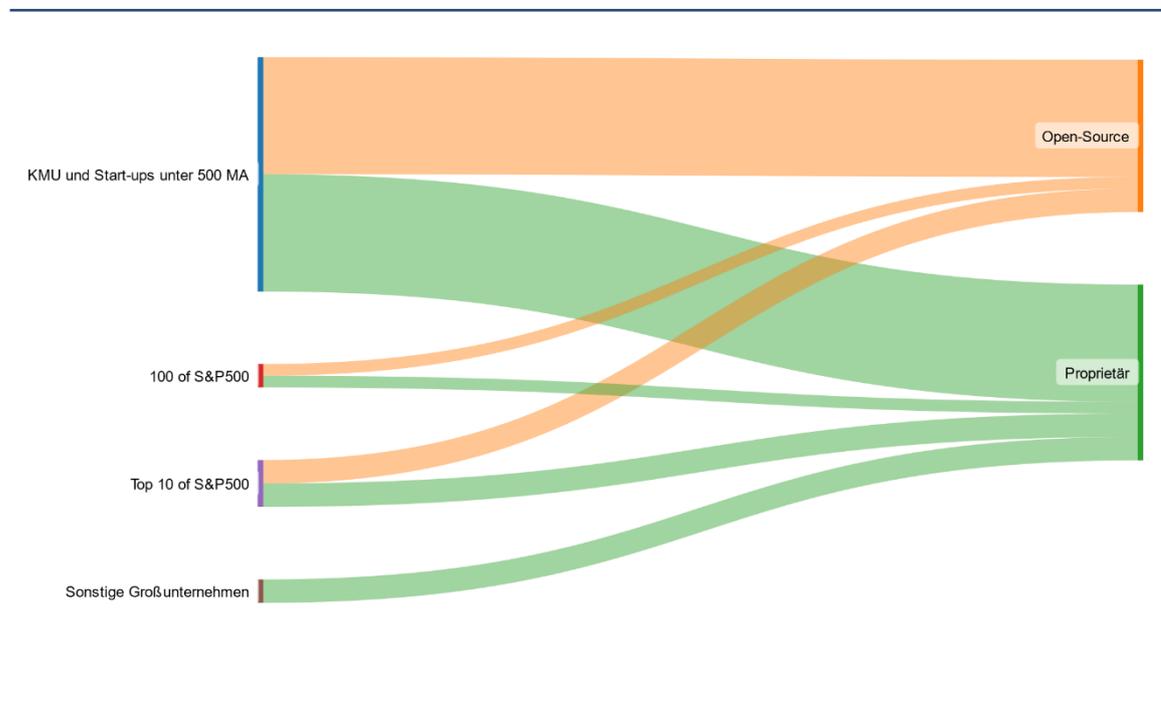
Quelle: WIK, eigene Darstellung.

Zur Veranschaulichung der Ergebnisse der Produkterhebung werden im Folgenden Sankey-Diagramme verwendet. Diese stellen die Mengenverhältnisse in Form eines Flussdiagramms dar, wobei die Breite der Streifen die maßstabsgetreuen Mengen wiedergibt.

Unternehmenstyp und Software-Lizensierung: In Abb. 3-4 werden die erfassten Unternehmenstypen der Produkthanbieter auf der linken Seite den unterschiedlichen Software-Lizensierungsformen der Produkte (proprietär und Open-Source) auf der rechten Seite gegenübergestellt. Ein Großteil der identifizierten Produkte wird von KMU und Start-ups unter 500 Mitarbeitende angeboten. Nur einige wenige werden von Unternehmen aus den Top 10 bzw. Top 100 des S&P500 Aktienindex und lediglich zwei von sonstigen Großunternehmen angeboten. Mit 16 Stück, wird die knappe Mehrheit der identifizierten Produkte proprietär und die übrigen als Open-Source-Lizensierung zur Verfügung gestellt.

KMU und Start-ups unter 500 Mitarbeitende vertreiben, auch aufgrund ihrer zahlenmäßigen Überlegenheit, gleichzeitig die meisten Open-Source- sowie proprietären Produkte. Die von Anbietern dieser Unternehmensgröße angebotenen Software-Tools teilen sich in etwa hälftig auf die beiden Lizensierungsformen auf. Produkte, die von Unternehmen des S&P500 Aktienindex angeboten werden, teilen sich ebenfalls gleichmäßig auf beide Lizensierungs-Modelle auf, sind aber in der identifizierten Produktpalette verhältnismäßig weniger vertreten.

Abbildung 3-4: Sankey-Diagramm der Anbieter in Abhängigkeit der Software-Lizenzierung



Quelle: WIK, eigene Darstellung.

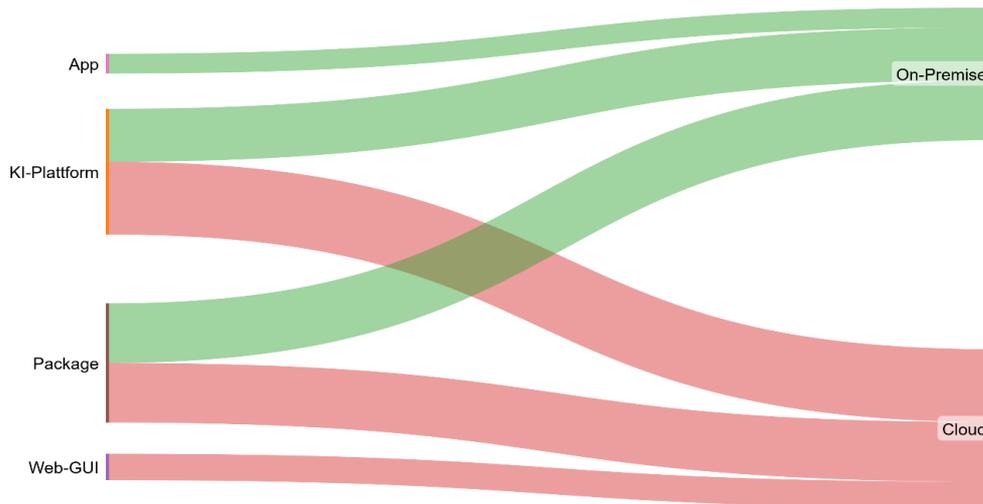
Softwareumgebung und Bereitstellungsmodell: Abb. 3-5 stellt die Softwareumgebungen der identifizierten Produkte auf der linken Seite den Bereitstellungsmodellen der Produkte auf der rechten Seite gegenüber. Es scheint, dass KI-Plattformen und Packages als Softwareumgebungen überwiegen, während Apps und Web-GUIs selten vorkommen. Zu beachten ist an dieser Stelle jedoch, dass ein einzelnes Produkt sowohl in der Cloud als auch On-Premise betrieben werden kann. Produkte, für die das zutrifft, werden auf der linken Seite von Abb. 3-5 doppelt dargestellt. Damit wird das Verhältnis der Software-Umgebungen relativ zur Gesamtzahl der Produkte verzerrt dargestellt.⁹⁶ Des Weiteren wird ersichtlich, dass die Verteilung der identifizierten Produkte zwischen On-Premise- und Cloud-Lösungen in etwa gleich ist.

KI-Plattformen und Packages teilen sich zu je etwa gleichen Teilen auf beide Bereitstellungsmodelle auf. Dies ist darauf zurückzuführen, dass fast alle identifizierten Produkte der beiden Bereitstellungsmodelle, dem Nutzenden die Wahl bieten, das jeweilige Produkt in der Cloud oder On-Premise zu Betreiben. Nur selten können Produkte der beiden Softwareumgebungen nur auf eine Art betrieben werden. Diesbezüglich scheinen nur wenige KI-Plattformen auf einen Betrieb in der Cloud beschränkt zu sein.

⁹⁶ Für eine unverzerrte Darstellung der Softwareumgebungen der identifizierten Produkte vgl. Abb 3-6.

Apps hingegen werden ausschließlich On-Premise und Web-GUI-Anwendungen ausschließlich in der Cloud ausgeführt. Für in der Cloud betriebene Produkte wird Rechenleistung benötigt, die nur selten ohne anfallende Gebühren zur Verfügung gestellt wird.⁹⁷

Abbildung 3-5: Sankey-Diagramm der Softwareumgebung in Abhängigkeit des Bereitstellungsmodells



Quelle: WIK, eigene Darstellung.

Softwareumgebung und Software-Lizenzierung: Abbildung 3-6 stellt die Softwareumgebungen der identifizierten Produkte auf der linken Seite deren Softwarelizenzierungen auf der rechten Seite gegenüber. Da im Vergleich zu obenstehender Abbildung einem Angebot eindeutig ein Lizenzierungsmodell zuordbar ist, ist hier das Verhältnis der Softwareumgebungen relativ zur Gesamtzahl aller Produkte unverzerrt dargestellt. KI-Plattformen und Packages überwiegen also als Softwareumgebungen, wobei erstgenannte am häufigsten vorkommen. Apps und Web-GUIs kommen hingegen selten vor. Mit Blick auf die Softwarelizenzierung ist feststellbar, dass die identifizierten Angebote zu etwa gleichen Teilen als Open-Source oder als proprietäres Lizenzmodell verfügbar sind.

Weiterhin wird anhand von Abb. 3-6 ersichtlich, dass die erfassten Packages bzw. Erweiterungen ausschließlich als Open-Source-Modell zugänglich gemacht werden. Grundsätzlich erlauben diese Open-Source Packages/Erweiterungen eine flexible Integration von AutoML in ML-Schritte (Feature Selektion, Feature Engineering, Modell Selektion, Modell Evaluation, Parameter Suche/Modell-Optimierung).⁹⁸ Diese Flexibilität geht jedoch mit der Notwendigkeit von Basis-Programmierkenntnissen für die Anwendenden einher.

⁹⁷ Google Colab bietet beispielsweise ohne Gebühr limitiertes Cloud-Computing mit GPUs an. Vgl. <https://colab.research.google.com/signup> [Letzter Abruf 16.11.2023].

⁹⁸ Die Flexibilität der Integration von Packages in ML-Schritte äußert sich zum einen darin, dass Anwendende flexibel darüber entscheiden können, welche in Abb. 2-4 dargestellten Schritte mithilfe der Packages automatisiert werden sollen. Zum anderen können Anwendende dazu unterschiedliche Packages, also unterschiedliche Anbieter heranziehen.

Im Gegensatz dazu werden KI-Plattformen und Apps, bis auf wenige Ausnahmen, proprietär zur Verfügung gestellt und erfordern meist eine Zahlung. Hier müssen sich Nutzende an dem vorgegebenen restriktiveren ML-Entwicklungsprozess des Anbieters orientieren. Der Vorteil besteht jedoch darin, dass im Vergleich zu Open-Source-Angeboten meist kaum oder keine Programmierfähigkeiten erforderlich sind.

Identifizierte Web-GUIs werden zumeist als Open-Source, teilweise aber auch als proprietäre Lizenzierung angeboten.

Anwendungen, die auf integrierten Entwicklungsumgebungen wie Packages basieren und damit mehr Expertise erfordern haben den Vorteil, dass dort eine Kombination von ML-Frameworks und ML-Packages verschiedener Anbieter üblich ist. Proprietäre Anwendungen hingegen sind in der Regel nicht dafür ausgelegt.

Abbildung 3-6: Sankey-Diagramm der Softwareumgebung in Abhängigkeit der Software-Lizensierung



Quelle: WIK, eigene Darstellung.

Im nachfolgenden Sunburst-Diagramm (Abb. 3-7) sind alle erfassten Produkte segmentiert und hierarchisch angeordnet. Das Diagramm ist vom Zentrum aus zu betrachten. Jede Hierarchieebene wird durch einen Ring oder Kreis veranschaulicht. Die kategorische Unterteilung der ersten Hierarchieebene (Entwicklungsumgebung) determiniert den weiteren Farbverlauf und ordnet diesem alle nachfolgenden Segmentierungen unter. Der rot markierte Bereich stellt diejenigen Produkte dar, die hinsichtlich des Umfangs der graphischen Benutzeroberfläche No-Code einsetzen. Im orangen markierten Bereich findet sich das Produkt, das hinsichtlich des Umfangs der

graphischen Bedienschnittstelle Low-Code einsetzt. Der grün markierte Bereich umfasst klassische AutoML-Lösungen. Blau markiert ist der Bereich, der Produkte umfasst, die hinsichtlich des Umfangs der graphischen Bedienschnittstelle sowohl Low-Code als auch No-Code nutzen und mit Blick auf die Automatisierung auch klassische AutoML-Umgebungen bieten. Die nächstäußeren Hierarchieebenen umfassen jeweils die Softwareumgebung und den Unternehmenstyp des Anbieters. In der letzten, d.h. der äußersten Ebene sind die Produktnamen dargestellt.

Matrixbereich/ML-Zugänglichkeit: Abb. 3-7 verdeutlicht, dass AutoML mindestens optional bei allen erfassten Produkten Teil des Leistungsspektrums ist. Des Weiteren werden alle in Form eines Packages angebotenen Produkte ausschließlich in klassischer Entwicklungsumgebung (hier grün dargestellt) sowie als Open-Source-Variante vertrieben.⁹⁹ Dies entspricht der Definition klassischer AutoML-Lösungen.

Erfasste No-Code Produkte (hier rot dargestellt), werden ausschließlich von KMU und Start-ups unter 500 MA und zwar als Plattform, Web-GUI oder App angeboten. Diese Softwareumgebungen und damit auch die Produkte des No-Code Bereichs werden fast ausschließlich proprietär angeboten.¹⁰⁰

Mit Blick auf die Unternehmensgröße scheinen KMU & Start-ups demnach ihre Produkte entweder in No-Code, Low-Code oder klassischer Umgebung anzubieten. Große Anbieter der Top 10/100 des S&P500 wie Amazon, Google, Microsoft und IBM, die in absoluter Häufigkeit weniger stark vertreten sind, finden sich fast ausschließlich im blauen Bereich wieder. Diese decken mit Ihren Produkten also die komplette Bandbreite von klassischen AutoML-Produkten über Low-Code Umgebungen für AutoML Lösungen bis hin zu No-Code Umgebungen ab. Sie ermöglichen somit allen Erfahrungsstufen einen Zugang zu ihren ML-Softwarelösungen.

Unter den erfassten Produkten befindet sich lediglich eine ausschließliche Low-Code Lösung. Neben der Möglichkeit diese als Web-GUI zu nutzen, bietet der Anbieter dieser Lösung, H2O AutoML, gleichzeitig auch die Möglichkeit, die Software in Form eines Packages einzubetten.

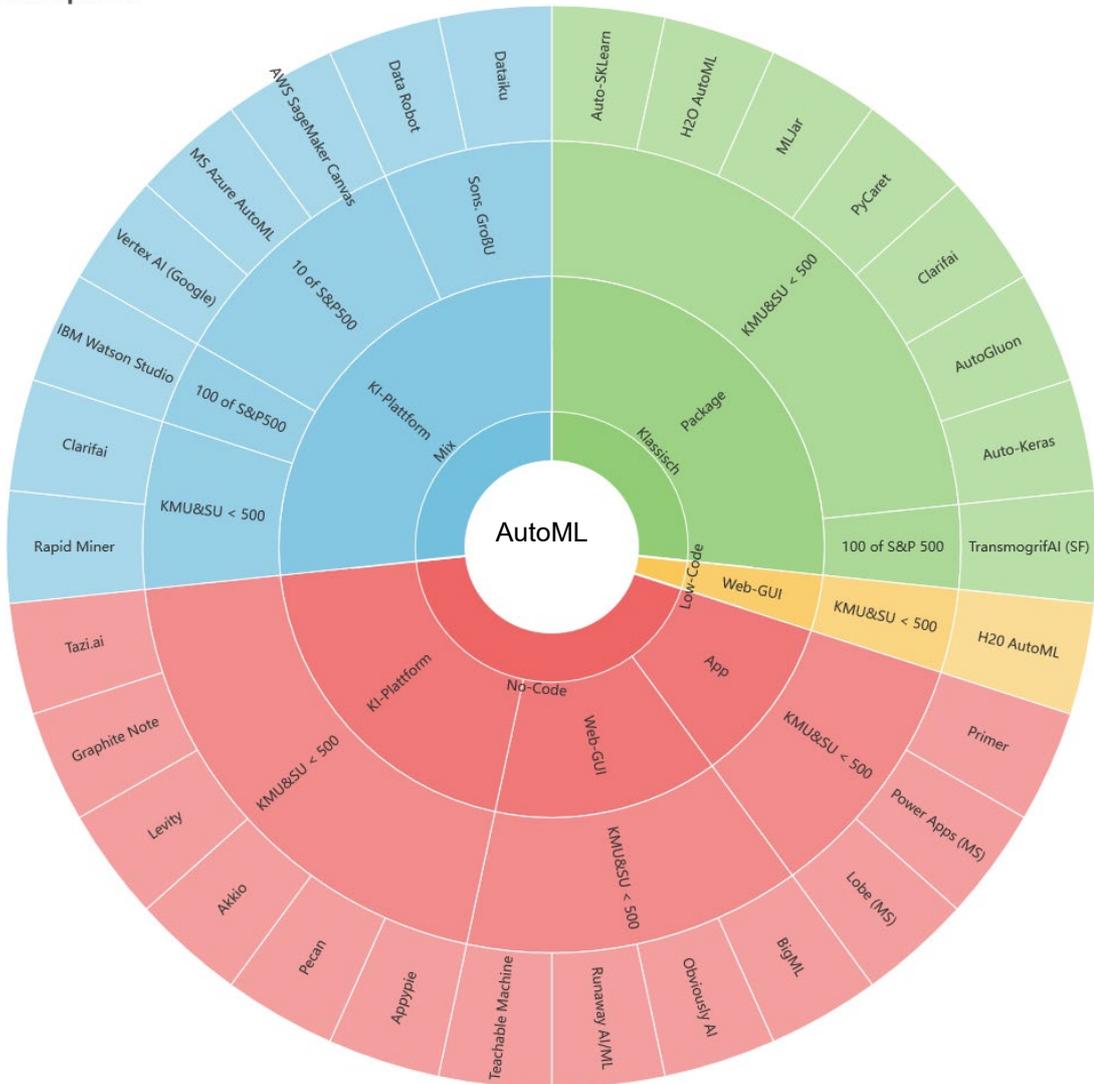
Mit Blick auf den Umfang der grafischen Bedienschnittstelle, der hier farblich voneinander getrennt dargestellt ist, zeigt sich darüber hinaus, dass es sich bei der Mehrheit der aufgeführten Produkte um ausschließliche No-Code Anwendungen mit Automatisierungs-komponente handelt. KI-Plattformen die jede Dimension der grafischen Bedienschnittstelle, d.h. klassisch, Low- und No-Code abdecken (hier in blau dargestellt), sind ähnlich häufig vertreten wie Packages in integrierter Entwicklungsumgebung (hier in grün dargestellt).

⁹⁹ Vgl. dazu Abb. 3-5.

¹⁰⁰ Vgl. ebd.

Abbildung 3-7: Produktpalette, dargestellt im Sunburst-Diagramm

Produktpalette

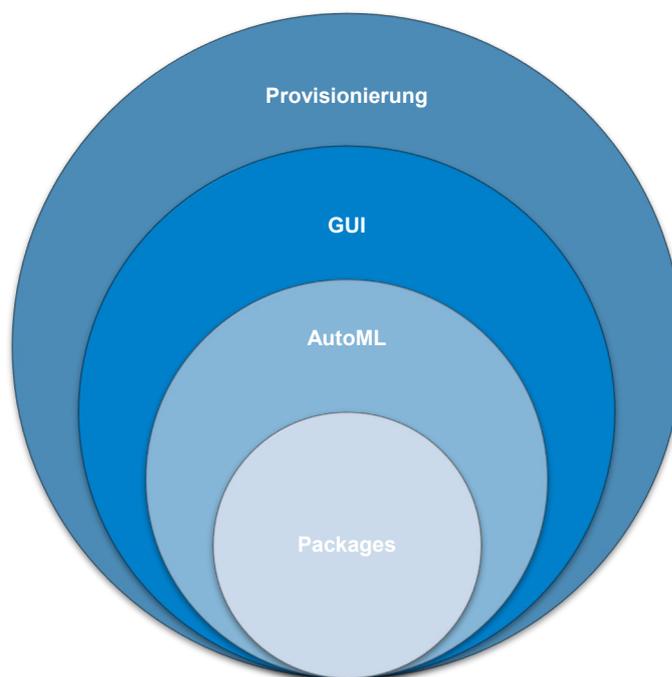


Quelle: WIK, eigene Darstellung.

Wertschöpfungskette: Low-Code- und No-Code-Produkte ersetzen die klassischen Code-zentrierten Entwicklungsumgebungen durch grafische Benutzeroberflächen oder sogenannte GUIs als Front-End-Lösung. Dass im Back-End häufig bereits bestehende Open-Source-Packages wie NumPy, Pandas, und SciPy verwendet werden, und diese somit Teil der Wertschöpfungskette von proprietären ML-Softwarelösungen sind, ist in Abb. 3-8 dargestellt. Tatsächlich werden

sie üblicherweise genutzt, um Daten zu importieren, zu transformieren und zu analysieren.¹⁰¹ Für (automatisiertes) ML, das Bestandteil aller erfassten Low- und No-Code-Lösungen ist, wird ebenfalls im Back-End auf Open-Source-Frameworks wie TensorFlow, PyTorch oder Keras zurückgegriffen, um ML-Modelle zu erstellen, zu trainieren und bereitzustellen. No-Code- und Low-Code-Plattformen unterstützen zudem häufig die Integration von Cloud-Diensten wie Amazon-Web-Services (AWS), MS Azure oder Google Cloud, die wiederum Open-Source-Technologien für verschiedene Aufgaben wie Datenverarbeitung, Speicherung und ML nutzen.

Abbildung 3-8: Wertschöpfungskette AutoML, No-Code und Low-Code



Quelle: WIK, eigene Darstellung.

3.4 Zwischenfazit

Für die durchgeführte Produktanalyse wurden 29 AutoML, Low-Code und No-Code Software-Lösungen untersucht. Es konnte gezeigt werden, dass die aufgestellten Kriterien *Zielgruppe*, *Softwareumgebung*, *Software-Lizensierung*, *Bereitstellungsmodell*, *Lernansatz* und *ML-Methoden* mehrfach und in divergierenden Ausprägungen von unterschiedlichen Anbietern adressiert werden und damit keine Anzeichen für eine Konzentration auf einzelne Anbieter besteht. Relativierend ist jedoch anzuführen, dass diese Aussage unabhängig von einer detaillierten Marktanteilsbetrachtung getroffen wurde.

¹⁰¹ Front-End beschreibt grundsätzlich die Präsentationsebene oder grafische Benutzeroberfläche, die für die Endanwendenden nutzbar und sichtbar sind. Im Gegensatz dazu fasst Back-End alles zusammen, was im Hintergrund der Website oder Applikation passiert und für die Endanwendenden nicht einsehbar ist.

KMU und Start-ups unter 500 MA sind in jeder Produktkategorie (AutoML, No-Code und Low-Code) vertreten und machen die deutliche Mehrheit aller Anbieter aus. Eine Vielzahl der globalen Marktführer in den Bereichen der Suchmaschinen sowie Cloud- und Softwarelösungen wie Google/Alphabet, Salesforce, Microsoft, IBM und Amazon-Web-Services (AWS) sind ebenfalls vertreten. Die von ihnen angebotenen KI-Plattformen ermöglichen die Entwicklung von ML-Lösungen sowohl in klassischen Entwicklungsumgebungen als auch in Form innovativer No-Code- und Low-Code-GUIs. Diese ganzheitlichen Lösungen bieten Anwendungsmöglichkeiten für Nutzende aller Kenntnis- und Erfahrungsstufen.

Auffällig ist, dass alle Produkte, die Open-Source als Lizenzierungsmodell nutzen, in klassische Entwicklungsumgebungen eingebunden werden müssen und grundlegende Coding-Fähigkeiten voraussetzen. Sie richten sich daher vorrangig an (semi-)professionelle Entwickler:innen, reduzieren aber die benötigten Kenntnisse im Bereich Data-Science. Low- und No-Code-Produkte hingegen adressieren vorrangig Citizen Developer als Zielgruppe und greifen fast ausschließlich auf ein proprietäres Lizenzierungsmodell zurück. Während es die meisten Open-Source Produkte dem Nutzenden überlassen, ob er diese On-Premise oder in der Cloud betreiben möchte, bieten proprietäre Produkte häufig nur die Wahl eines Bereitstellungsmodells an. Mit Blick auf die untersuchten Produkte scheint erkenntnisreich, dass einige KI-Plattformen dem Nutzenden jedoch beide Möglichkeiten offenhalten.

Hinsichtlich der Software-Provisionierung konnte aufgezeigt werden, dass proprietäre Produkte für ML-spezifische Aufgaben im Backend meist auf Open-Source-Packages zurückgreifen.

Nachdem nun in diesem Kapitel die identifizierte Produktpalette analysiert wurde, soll im nächsten Kapitel anhand der Auswertung einer Online-Befragung der Mittelstand im Fokus stehen.

4 Potenziale und Herausforderungen für den Mittelstand

In Kapitel 2.4.1 wurden bereits die unternehmerischen Herausforderungen hinsichtlich der KI-Integration aufgeführt. Auffällig ist, dass insbesondere der Mittelstand träge auf die Einführung von KI in Geschäftsprozessen reagiert. Daher wurde in Form einer Expertenumfrage um Einschätzungen von Expert:innen aus dem mittelstandsnahen Transferbereich gebeten.¹⁰² Nach der Darstellung der Strukturmerkmale des deutschen Mittelstands in Kapitel 4.1, werden die Umfrageergebnisse der Expertenbefragung in Kapitel 4.2 dargelegt. Das Kapitel schließt mit einer Zusammenfassung der Bedeutung der Umfrageergebnisse für den deutschen Mittelstand in Kapitel 4.3.

4.1 Strukturmerkmale des deutschen Mittelstands

Der Mittelstand nimmt innerhalb der deutschen Volkswirtschaft eine besondere Stellung ein¹⁰³ und die Implementierung von KI in mittelständischen Unternehmen, wie sie im Fokus der vorliegenden Studie steht, stellt eine besondere Herausforderung dar. Geprägt wird der Mittelstand durch einige charakteristische Strukturmerkmale, auf die hier kurz eingegangen werden soll.¹⁰⁴

Die in vielen KMU beobachtete Einheit von Eigentum und Unternehmensführung, die Unternehmenserfolg, Vermögenssituation sowie Haftung miteinander verbindet, lässt einerseits darauf schließen, dass der langfristige Erfolg des Unternehmens im Mittelpunkt der Unternehmensleitung steht. Andererseits scheinen davon jedoch auch gegenüber einem externen Management Auswirkungen auf eine erhöhte Risikoaversion auszugehen, was sich auch auf die Implementierung neuer digitaler Technologien wie KI auswirken kann.¹⁰⁵

Darüber hinaus ist der Mittelstand durch spezifisches Know-how sowie entsprechende Prozesse zur Produktion von Gütern in Spezialmärkten geprägt. Dieses Merkmal, das von den Unternehmen oft als entscheidender Vorsprung im Wettbewerb angesehen wird, wirkt sich auch auf eine entsprechende Sensibilisierung bezüglich Daten und Geschäftsgeheimnisse aus. Teilweise werden daher wichtige Informationen nicht digital dokumentiert, was einen Mangel an qualitativen Daten verursachen kann. Diese bilden jedoch die Grundlage für die Adaptionfähigkeit von KI-Lösungen und ML-Modellen.¹⁰⁶

Die im deutschen Mittelstand praktizierte langfristige Mitarbeiterbindung hat erhebliche Vorteile für den Aufbau von Prozesswissen, führt aber auch zur Entstehung von wenig dokumentiertem Expertenwissen sowie der entsprechenden Prozesse, was die Grundlage für den Einsatz digitaler Tools wie KI-Modellen darstellt. Gemeinsam mit dem im Mittelstand prägnanten

¹⁰² Mit Transferbereich ist der Wissenstransfer zwischen akademischen Einrichtungen und der Akteure der Wirtschaft gemeint.

¹⁰³ Für volkswirtschaftliche Kennzahlen des Mittelstands sei an dieser Stelle auf Märkel et al. (2022) verwiesen.

¹⁰⁴ Dafür sei im Folgenden auf die Ausführungen von Märkel et al. (2021) verwiesen.

¹⁰⁵ Vgl. ebd.

¹⁰⁶ Vgl. ebd.

Fachkräftemangel, der vor allem hinsichtlich der IT-Fachkräfte¹⁰⁷ besonders ausgeprägt scheint, stellt der niedrige digitale Reifegrad ein relevantes Hindernis für einen potenziellen KI-Einsatz dar.¹⁰⁸

Durch die im Vergleich zu Großunternehmen limitierten finanziellen Ressourcen von KMU werden dort vor allem kurzfristige Projekte mit wenig Unsicherheit priorisiert. Insbesondere die zum Teil nicht ausgereiften digitalen Technologien, wie etwa KI, sind hinsichtlich ihrer betriebswirtschaftlichen Bewertung jedoch einer erhöhten Unsicherheit ausgesetzt und schrecken KMU damit von potenziellen Investitionen ab.¹⁰⁹

Aufgrund der Heterogenität des deutschen Mittelstands sind die oben beleuchteten Strukturmerkmale lediglich als Tendenzaussagen zu verstehen. Allgemeingültige Aussagen hängen von einer Vielzahl weiterer Faktoren ab und sind daher schwer zu treffen.¹¹⁰

Die herangezogenen Expert:innen der nachfolgend dargestellten Befragung sind sowohl mit der Technologie der KI als auch mit den oben aufgeführten Strukturmerkmalen des deutschen Mittelstands vertraut.

4.2 Befragung der Mittelstandsexpert:innen

Im Zeitraum vom 29.06.2023 bis 27.07.2023 hat WIK Wissenschaftliches Institut für Infrastruktur und Kommunikationsdienste eine Expertenbefragung, die keinen Anspruch auf Repräsentativität erhebt, durchgeführt. Im Rahmen dieser Online-Befragung wurden neben Expert:innen aus Handelskammern, wie dem DIHK sowie aus Branchenverbänden wie dem KI-Bundesverband oder dem eco-Verband, viele weitere Expert:innen aus Forschungsinstituten wie dem DFKI sowie mehrerer Fraunhofer-Institute befragt.¹¹¹ Diese Expert:innen aus dem mittelstandsnahen Transferbereich sind sowohl mit der Technologie der KI als auch mit den Strukturmerkmalen des deutschen Mittelstands vertraut. Ziel war es einen Einblick zur Verbreitung von No-Code-, Low-Code- und AutoML-Lösungen im deutschen Mittelstand sowie Einschätzungen sowohl zu deren zukünftigen Einsatzmöglichkeiten als auch zu Ansatzpunkten für potenziellen Unterstützungsbedarf des Mittelstands zu erhalten. Es konnten Antworten von 54 Expert:innen erfasst werden.¹¹²

Die Expert:innen wurden gebeten eine Einschätzung zum Status Quo in den Bereichen abzugeben, die an die Systematisierung des Untersuchungsgegenstands aus Kapitel 2.3.3 angelehnt sind. Darüber hinaus wurden die Expert:innen gebeten, relevante Kriterien für die Software-Auswahl sowie Aspekte zum Nutzen und zu den Hemmnissen der Tools zu beurteilen.

¹⁰⁷ Vgl. Icks und Brink (2023) sowie Statista (2022b).

¹⁰⁸ Als Folge dessen stellt Kompetenzmangel das größte Hemmnis der KI-Implementierung im Mittelstand dar. Vgl. Deloitte (2021).

¹⁰⁹ Vgl. Märkel et al (2021).

¹¹⁰ Darüber hinaus sei darauf hingewiesen, dass es sich lediglich um ausgewählte Strukturmerkmale handelt, die Einfluss auf die Adaptionfähigkeit von KI-Lösungen und ML-Modellen haben und den Mittelstand gegenüber Großunternehmen nicht in einem negativen Bild darstellen soll. Letztlich bleibt die hohe Agilität der KMU ein wichtiges Kriterium, um sich im Bedarfsfall schnell an den Markt anpassen zu können.

¹¹¹ Für eine abschließende Auflistung aller Institutionen, die angefragt wurden, an der Umfrage teilzunehmen, sei an dieser Stelle auf Anhang A4.1 verwiesen.

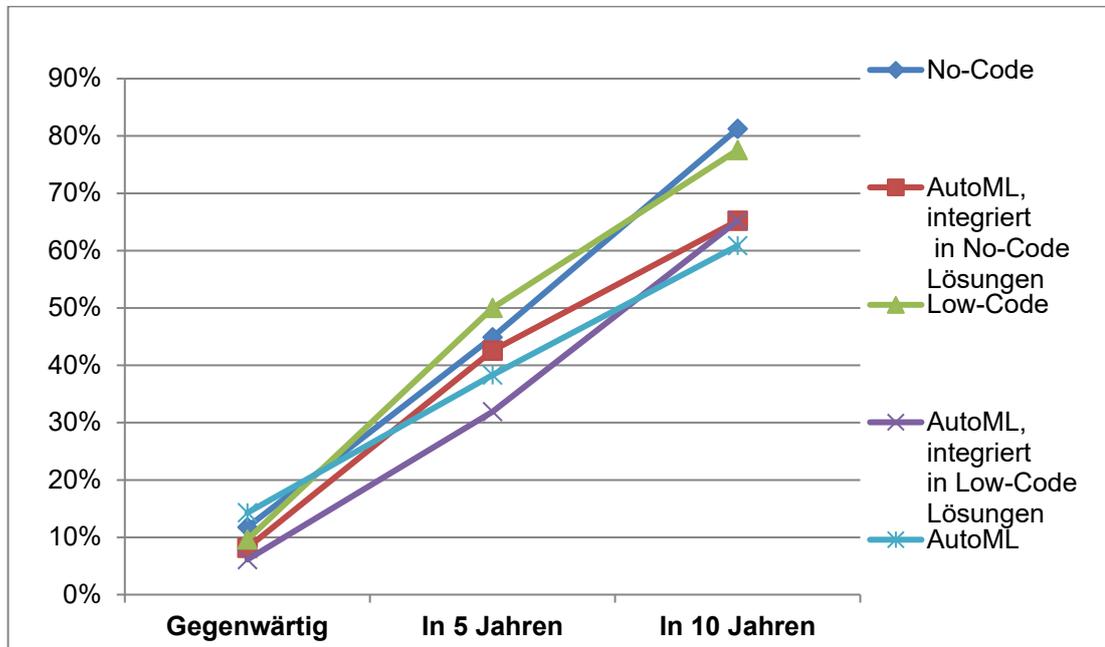
¹¹² Der gesamte Fragebogen ist in Anhang A4.2 dargestellt.

Im Folgenden werden (Teil-)Ergebnisse der Online-Befragung visualisiert und deskriptiv ausgewertet. Die gesamten Auswertungen sind in Anhang A4.3 aufgeführt.¹¹³ Die hier dargestellten relativen Werte beziehen sich immer auf die sogenannte „TOP 2 Box“, stellen also kumuliert bspw. den Anteil der Expert:innen dar, die eher zustimmen oder voll zustimmen.

Anhand von Abbildung 4-1 ist grundsätzlich erkennbar, dass die Expert:innen der Ansicht sind, dass sich der Umfang des tatsächlichen Einsatzes von AutoML, Low-Code und No-Code und integrativen Lösungen im Mittelstand in den kommenden fünf Jahren bis zu vervierfachen und in fünf bis zehn Jahren abermals verdoppeln wird. Gegenwärtig sind die Befragten der Ansicht, dass AutoML und No-Code am häufigsten genutzt werden. Mit Blick auf die Zukunft prognostizieren sie, dass No-Code und Low-Code sowie integrative Lösungen in den nächsten fünf bis zehn Jahren stärker verbreitet sein werden als AutoML-Ansätze. Low-Code-Lösungen werden nach Einschätzung der Expert:innen in fünf Jahren und No-Code-Lösungen in zehn Jahren die dominierende Rolle einnehmen.

¹¹³ Vgl. dazu Anhang A4.3.

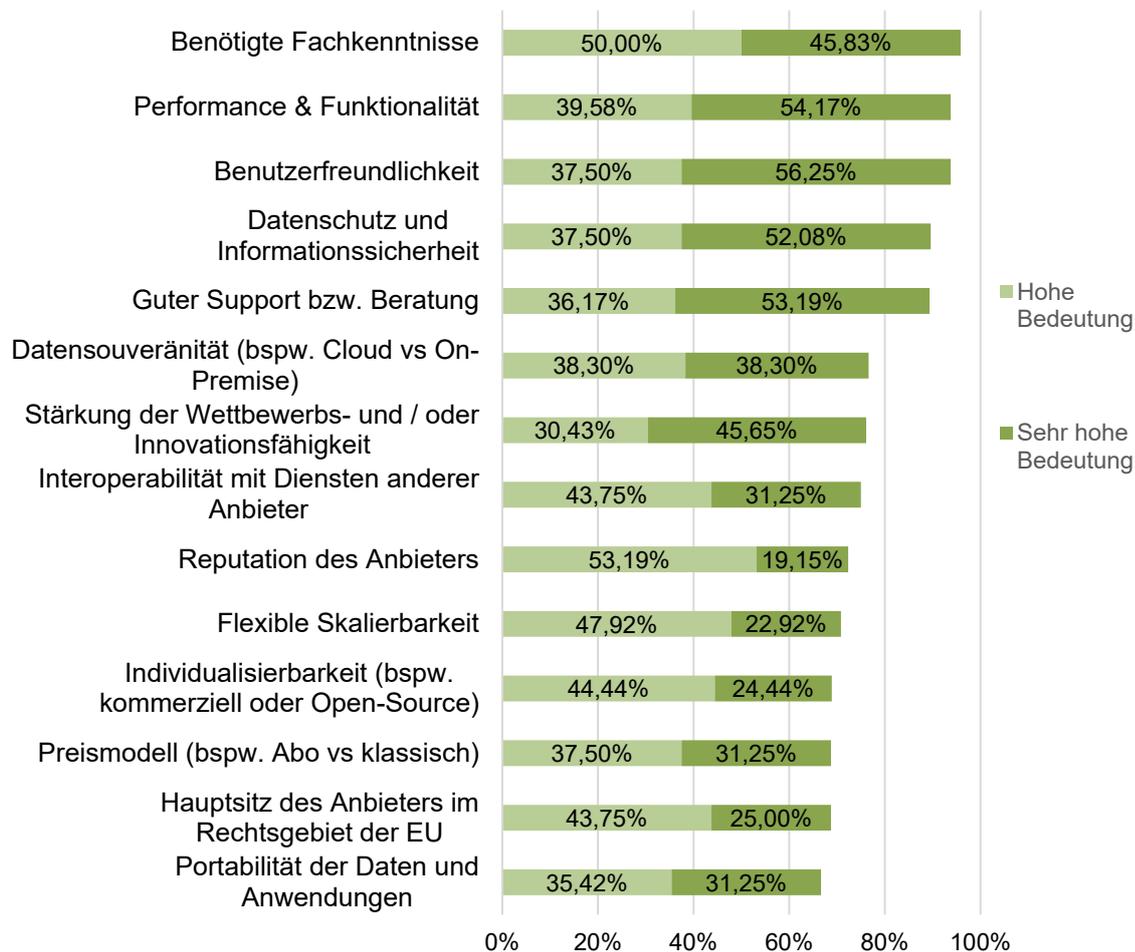
Abbildung 4-1: Wie schätzen Sie den Umfang des tatsächlichen Einsatzes von AutoML, No-Code und Low-Code sowie integrativen Lösungen im Mittelstand ein?



Quelle: WIK, eigene Darstellung, n=53.

Abbildung 4-2 illustriert, dass generell allen zur Wahl gestellten Kriterien bei der Software-Auswahl eine hohe Bedeutung beigemessen wird. Mit einer Zustimmung von über 90% ragen jedoch die Kategorien "Benötigte Fachkenntnisse", "Performance & Funktionalität" sowie "Benutzerfreundlichkeit" deutlich heraus. Auch die Kategorien „Datenschutz und Informationssicherheit" sowie "Support bzw. Beratung“ scheinen mit einer Zustimmung von über 80% eine wichtige Rolle für den Mittelstand bei der Auswahl von Software-Lösungen zu spielen. Die Kriterien "Preismodell", "Hauptsitz des Anbieters im Rechtsgebiet der EU" und "Portabilität der Daten und Anwendungen" werden von den Expert:innen als weniger bedeutsam erachtet.

Abbildung 4-2: Welche Bedeutung kommt Ihrer Meinung nach den folgenden Kriterien bei der Auswahl von Software-Lösungen im Bereich Low-Code, No-Code und AutoML im Mittelstand zu?

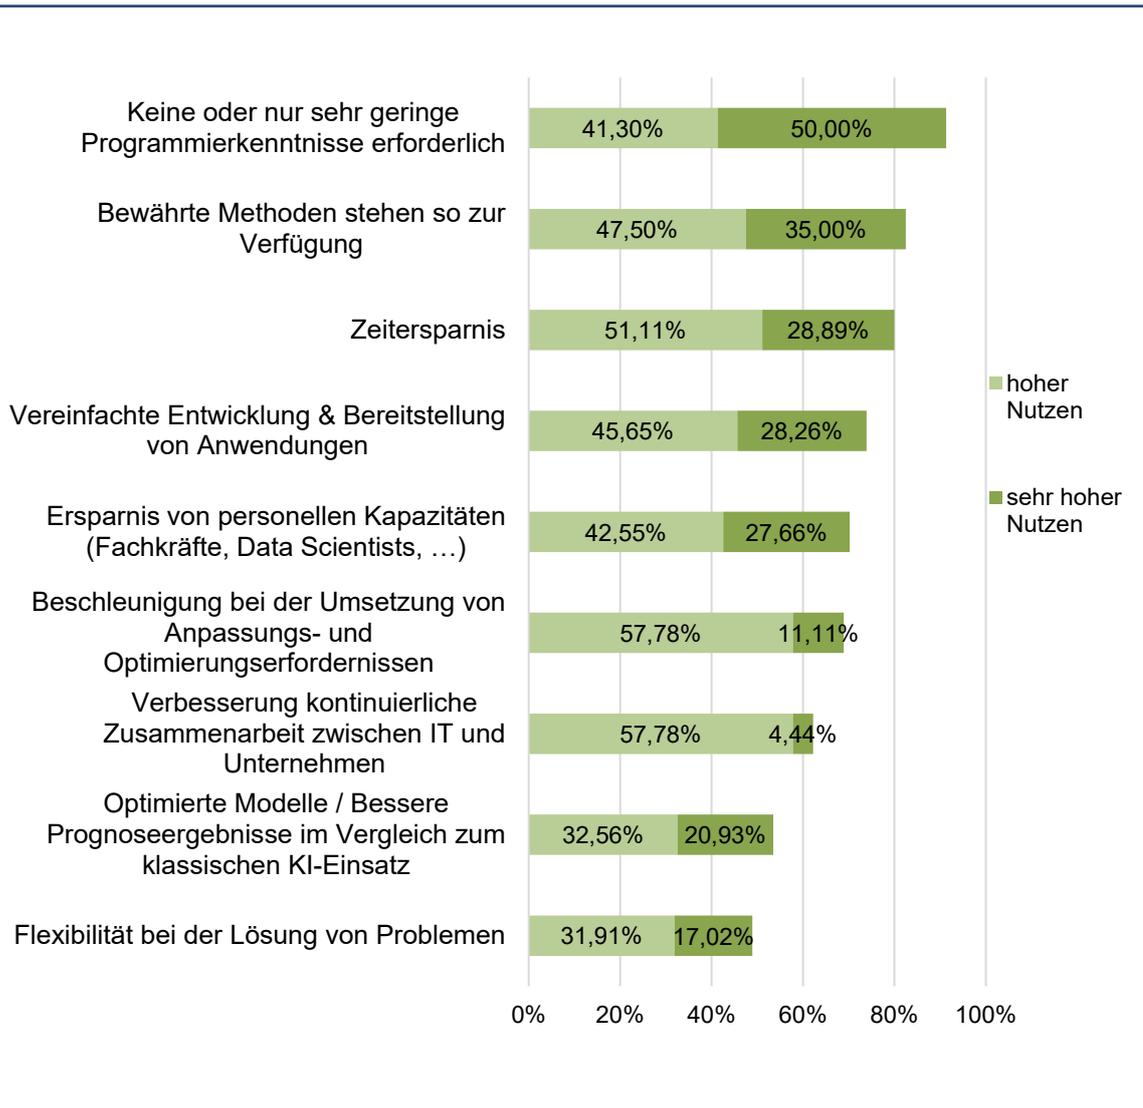


Quelle: WIK, eigene Darstellung, n=54.

Anhand von Abbildung 4-3 ist zu erkennen, dass die Befragten in den Bereichen AutoML, Low- und No-Code einen erheblichen Mehrwert für den Mittelstand sehen. Mehr als 90% attestieren dem Einsatz von AutoML, No-Code und Low-Code hinsichtlich der Bewältigung von Herausforderungen wie fehlender oder begrenzter Programmierkenntnisse einen hohen oder sehr hohen Nutzen. Darüber hinaus sehen über 80% der Expert:innen einen hohen oder sehr hohen Nutzen darin, dass dem Mittelstand bewährte Methoden so zur Verfügung stehen. Dies bedeutet, dass Lösungsansätze, wie an dieser Stelle ML-Methoden, die sich bereits in anderen Unternehmen, Branchen oder Bereichen bewährt haben, durch die neuen Tools verfügbar gemacht werden. Auch in der Zeitersparnis, die die neuen Ansätze bei der Implementierung von ML-Modellen mit sich bringen, sehen noch 80% der Expert:innen einen hohen oder sehr hohen Nutzen. Weniger bedeutend, aber dennoch von Relevanz sind die Potenziale zur Ressourceneinsparung im personellen Bereich, die Beschleunigung von Transformationsprozessen und eine verbesserte Kooperation zwischen der IT-Abteilung und dem Unternehmen.

Als weniger bedeutend für den Mittelstand schätzen die Expert:innen den Nutzen von AutoML, Low-Code und No-Code hinsichtlich präziseren Prognoseergebnissen im Vergleich zu traditionellen ML-Methoden und einer gesteigerten Flexibilität bei der Lösung von Problemen ein.

Abbildung 4-3: Bitte geben Sie an, wie hoch Sie den Nutzen des Einsatzes von AutoML, Low-Code und No-Code für den Mittelstand in den folgenden Bereichen einschätzen?

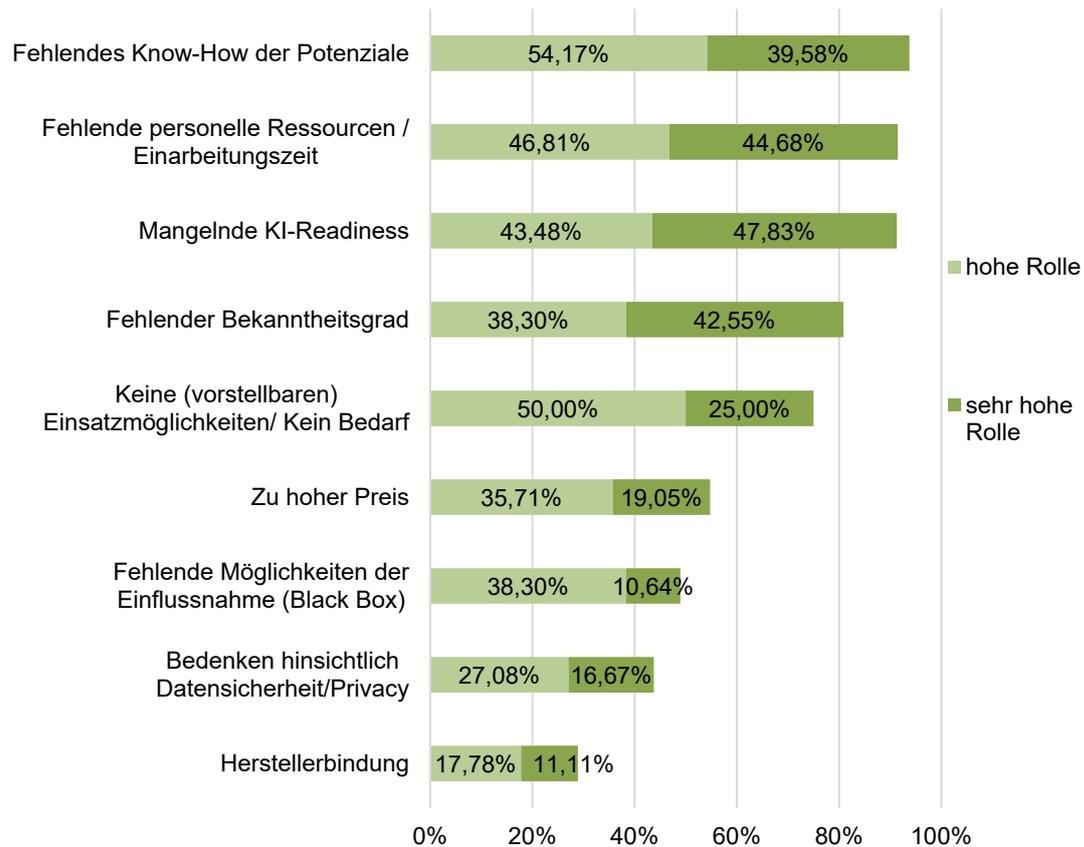


Quelle: WIK, eigene Darstellung, n=54.

Abbildung 4-4 zeigt auf, dass über 90% der Expert:innen vor allem in einem fehlenden Know-how der Potenziale, fehlenden personellen Ressourcen bzw. der Einarbeitungszeit sowie einer mangelnden KI-Readiness Hindernisse für einen mangelnden Einsatz von AutoML, No-Code und Low-Code im Mittelstand sehen. Zusätzlich mangelt es an einer fehlenden Bekanntheit derartiger ML-Softwarelösungen. Weniger relevant als Hindernis für einen Einsatz der Software-Tools scheinen keine vorstellbaren Einsatzmöglichkeiten bzw. der fehlende Bedarf zu sein. Deutlich weniger scheinen nach Einschätzung der Experten „Bedenken hinsichtlich der Datensicherheit bzw.

Privacy“ sowie eine potenzielle „Herstellerbindung“ dem Einsatz der innovativen Ansätze im Mittelstand im Wege zu stehen.

Abbildung 4-4: Bitte geben Sie an, wie ausschlaggebend Sie die folgenden Gründe für einen bis dato fehlenden Einsatz von AutoML, Low-Code und No-Code im Mittelstand ansehen?



Quelle: WIK, eigene Darstellung, n=54.

Insgesamt konnte die Expertenbefragung einerseits aufzeigen, dass AutoML, Low- und No-Code nach Einschätzung der Expert:innen gegenwärtig nur eine geringe Verbreitung im Mittelstand finden. Andererseits wurde aber auch deutlich, dass dem Einsatz für die kommenden fünf bis zehn Jahre ein deutliches Wachstum prognostiziert wird. Hinsichtlich der Anforderungen des Mittelstands an die Produkte scheint für die Befragten entscheidend, wie funktional und benutzerfreundlich die Lösungen gestaltet sind, ob Datenschutz und IT-Sicherheit gewährleistet sind und in welchem Umfang Fachkenntnisse erforderlich sind.

4.3 Implikationen der Umfrage

Die Einschätzungen der Expert:innen legen nahe, dass KMU AutoML-, Low-Code- und No-Code-Lösungen bisher, vor allem aufgrund mangelnder Kenntnis der Potenziale der Tools, nicht einsetzen. Es besteht offensichtlich Unterstützungsbedarf der KMU zur Sensibilisierung und des Transfers von Know-how in Hinblick auf Low-Code-, No-Code- und AutoML-Tools für eine einfachere Implementierung von KI-basierten Lösungen. Die Tatsache, dass die Expert:innen darüber hinaus begrenzte personelle und zeitliche Ressourcen sowie eine mangelnde KI-Readiness als Hemmnisse sehen, und die Tools gerade diese adressieren, scheint einerseits den Unterstützungsbedarf hinsichtlich des Kenntnisstands zu den Potenzialen zu bestätigen. Andererseits deutet dies darauf hin, dass KMU auch im Vorfeld der Implementierung von KI noch Schwierigkeiten mit Ressourcenengpässen bei der allgemeinen Digitalisierung haben, um eine ausreichende KI-Readiness zu entwickeln. Es lässt sich daher vermuten, dass im Mittelstand auch über den Wissenstransfer hinaus Unterstützungsbedarf vorliegt.

Deutlich wurde auch, dass spezifisches KI-Fachwissen sowie Expertise im Bereich Data-Science nicht durch die Software-Tools ersetzt werden können. Dies macht weitere Unterstützung notwendig. Erst so kann eine Integration von KI in Geschäftsprozesse langfristig erfolgreich und sinnvoll gestaltet werden. Hier scheint zudem der Bedarf zu bestehen, Nutzende im Umgang mit den identifizierten Software-Tools insbesondere hinsichtlich des Datenschutzes, der IT-Sicherheit, der Datensouveränität, der Modellgüte sowie der Fachexpertise zu sensibilisieren.

Bezüglich der aufgeworfenen Punkte ist das gezielte Aufsetzen eines Förderprogramms oder die Justierung bestehender Fördermaßnahmen notwendig, um einerseits den herausgearbeiteten Unterstützungsbedarf zu adressieren und andererseits Know-how beim Personal aufzubauen und dieses in Richtung Citizen Developer zu schulen.

5 Schlussbetrachtung

Das vorliegende Kapitel dient zunächst dazu, die im Rahmen dieses Diskussionsbeitrags erlangten Erkenntnisse zu den theoretischen technischen Potenzialen und Grenzen der Tools sowie den evaluierten Softwareprodukten mit den mittelstandspezifischen Herausforderungen der Umsetzung zusammenzuführen und Handlungsbedarfe zu adressieren (Kapitel 5.1). Das Kapitel schließt mit einem Ausblick auf den Einfluss, den die untersuchten Software-Tools auf die zukünftige Entwicklung insbesondere in KMU im Bereich der KI-Implementierung ausüben können (Kapitel 5.2).

Im Rahmen der theoretisch-technischen Betrachtung wurde festgestellt, dass AutoML, Low- und No-Code vielversprechende Software-Tools sind, um die KI-Readiness von Unternehmen zu erhöhen. Durch die Automatisierung der Prozessschritte erhöhen sie die Zugänglichkeit von ML-Modellen und reduzieren den Umfang benötigter IT-Kenntnisse. Dadurch können zeitintensive Datenvorbereitungs- und Bereinigungsprozesse wegfallen und eine Prototypenentwicklung durch vereinfachtes „Sandbox-Modeling“ und optimiertes Parameter-Tuning gefördert werden. Durch die Einbindung von Citizen Developern, die durch die Software-Tools ermöglicht wird, kann der Bedarf an Fachkräften reduziert werden. Limitierungen weisen die Software-Tools im Hinblick auf Flexibilität, Interpretierbarkeit, Reproduzierbarkeit und Robustheit auf. Diese werden durch eine geringere Erklärbarkeit aufgrund einer möglichen Black-Box-Problematik verstärkt.

Auf Basis der evaluierten Softwareprodukte konnte festgestellt werden, dass aufgrund der Vielzahl der existierenden Anbieter, ein vielfältiges Angebot vorhanden ist und derzeit keine oder nur eine geringe Konzentration auf einen oder wenige Anbieter besteht. KMU und Start-ups stellen die Mehrheit der Anbieter, aber auch globale Marktführer wie Google, Microsoft, IBM und AWS sind aktiv. Diese setzen vor allem auf Plattformen und decken damit alle Kenntnis- und Erfahrungsebenen ab. Auffällig ist, dass AutoML, Low-Code- und No-Code-Tools, die als Open-Source Lizenzierung angeboten werden, eine höhere Flexibilität gewährleisten, jedoch gleichzeitig mehr IT-Kenntnisse voraussetzen. Ohne entsprechende Fähigkeiten sind die Unternehmen auf proprietäre Produkte angewiesen.

Die im Rahmen einer Expertenbefragung untersuchten mittelstandsspezifischen Herausforderungen deuten zum einen darauf hin, dass AutoML-, Low-Code- und No-Code-Lösungen in KMU derzeit noch wenig verbreitet sind, jedoch eine deutliche Zunahme des Einsatzes zu erwarten ist. Darüber hinaus scheinen KMU die Software-Tools aufgrund mangelnden Bewusstseins über deren Potenziale nicht ausreichend zu nutzen. Daher erscheint eine Unterstützung der KMU sinnvoll, um diese über die Tools zu informieren und damit die KI-Readiness der Unternehmen zu erhöhen. Dabei ist es wichtig, die Themen Datenschutz und IT-Sicherheit sowie Benutzerfreundlichkeit und Funktionalität der Tools zu adressieren.

5.1 Synopse: Anwendung von AutoML, Low Code- und No-Code Lösungen in KMU

Im Rahmen der Studie konnte aufgezeigt werden, dass große Potenziale für den deutschen Mittelstand bestehen, die derzeit nicht gehoben werden und **Unterstützungsbedarf** induzieren. Gleichwohl divergieren die Anforderungen und werden von einer Vielzahl möglicher Lösungen, die der Markt bereithält, adressiert.

Breit gefächertes wettbewerbliches Marktangebot als Korrektiv

- Die Vielzahl der identifizierten Software-Produkte impliziert für KMU, dass zum einen individuelle Passgenauigkeiten berücksichtigt werden können und zum anderen potenzielle Abhängigkeiten von einzelnen Tools geringgehalten werden können. Die Befürchtung einer Abhängigkeit von einzelnen Dienstleistern und Lösungen, verbunden mit Lock-in-Effekten, fehlender Preiskontrolle und Black-Box-Problematiken wurde als potenzielles Risiko und Hindernis für die Implementierung einer No-Code- oder Low-Code-Lösung identifiziert. Basierend auf der Analyse des Marktangebotes kann wiederum abgeleitet werden, dass dieses Risiko für die KMU in einem sinnvollen Kosten-Nutzen-Verhältnis steht.

Auswahl der Tools mit Sachverstand

- Im Rahmen der Marktanalyse konnte gezeigt werden, dass Produkte existieren, die ein hohes Maß an Automatisierung und eine Vielzahl von ML-Anwendungsbereichen abdecken. Kostenpflichtige Angebote setzen dabei vermehrt auf Software-Umgebungen wie KI-Plattformen, die ML in klassischer Entwicklungsumgebung sowie in einer grafischen Benutzeroberfläche einbetten und damit Anwendenden mit unterschiedlich ausgeprägten KI-Fähigkeiten die Möglichkeit bieten, ML-Methoden anzuwenden. Im Gegensatz dazu ermöglichen Open-Source Produkte die Integration von AutoML fast ausschließlich in Form von Packages in klassischer Entwicklungsumgebung. Kostenfreie No-Code oder Low-Code Software ist kaum zu finden. Anwendende, die vollständig auf das Programmieren verzichten wollen, müssen folglich zwangsläufig auf kostenpflichtige Services zurückgreifen.
- Um potenzielle Abhängigkeiten und mögliche Lock-in-Effekte zu minimieren, sollten Unternehmen prüfen, wie sich die verwendete KI-Technologie in die im Unternehmen bestehende IT-Landschaft einfügt, welche Datenformate und Standards unterstützt werden, wie transparent und anpassungsfähig die Lösungen sind, und wie sich die Kostenstruktur darstellt. Sie sollten auch die Entwicklung von Strategien für die Portabilität und Migration ihrer Lösungen in Betracht ziehen, um zukünftige Flexibilität zu gewährleisten. Beispielsweise werden KI-Modelle von den Anbietern häufig automatisch für bestimmte Datensätze und Konfigurationen optimiert. Nutzende, die diese Plattformen verwenden, könnten Schwierigkeiten haben, ihre Modelle in andere Umgebungen oder auf andere Plattformen zu migrieren.

Aufbau von IT- und Data-Kenntnissen erforderlich für Beibehaltung der Flexibilität

- Die Tatsache, dass Open-Source-lizenzierte Produkte, die einen Flexibilitätsvorteil bieten, Coding-Fähigkeiten voraussetzen und Unternehmen ohne diese auf proprietäre Produkte angewiesen sind, lässt es sowohl aus Unternehmenssicht als auch aus gesamtwirtschaftlichen Überlegungen sinnvoll erscheinen, Schulungen oder Qualifizierungsformate in diesem Bereich anzubieten.

Regulatorische Vorgaben erfordern Berücksichtigung bei der Auswahl von Tools

- Bei der Verarbeitung personenbezogener Daten in entsprechenden ML-Modellen, müssen Unternehmen die Datenschutzgrundverordnung (DSGVO) berücksichtigen. In diesem Rahmen kann auch dem entsprechenden Bereitstellungsmodell (Cloud oder On-Premise) verwendeter Software-Tools eine wichtige Rolle zukommen. Auch hier konnte festgestellt werden, dass die identifizierten Produkte in der Regel eine Wahlmöglichkeit bieten.

5.2 Ausblick

Es ist festzuhalten, dass die im Rahmen dieser Studie erfassten Tools eine Reduzierung von Zeiteinsatz und Programmierfähigkeiten für die Erstellung von KI-Software mit sich bringen, was die Entwicklung und Implementierung von ML-Methoden in Geschäftsprozessen beschleunigen kann. Das Marktangebot ist vielfältig und vermag die Bedürfnisse des Mittelstands zu adressieren. Gleichwohl scheinen diese Software-Tools kein Selbstläufer zu sein, um ML-Modelle für den Mittelstand zugänglicher zu machen. Die bereits in zahlreichen Studien adressierten vorgelagerten Digitalisierungsschritte müssen zunächst vollzogen werden, damit entsprechende Lösungen implementiert werden können. Weiterhin ist der Zugang zu relevanten und nutzbaren Daten in ausreichender Qualität eine notwendige Bedingung, um ML-Modelle nutzen zu können. Um diese vorgelagerten Digitalisierungsschritte durchführen und um die untersuchten Software-Tools auf die Bedarfe des Mittelstands anpassen zu können, ist eine Vernetzung von Entwicklern und KMU sinnvoll.

Es wurden in den letzten Jahren zunehmend innovative Ansätze entwickelt, um nicht-professionelle Entwickler:innen mit KI-Technologien vertraut zu machen und KI in unternehmerische Geschäftsprozesse stärker einzubinden. Die in dieser Studie vorgestellten alternativen Entwicklungsumgebungen wie Low-Code und No-Code in Verbund mit AutoML versprechen, dass sie die Zugänglichkeit zu ML-Anwendungen erhöhen und somit ermöglichen, dass Personen ohne tiefgehende technische Kenntnisse ML-Anwendungen und ML-Modelle in Unternehmen integrieren und automatisieren können. Langfristig soll dies nicht nur zu einer breiteren Beteiligung an der Erstellung von ML-Modellen in Unternehmen führen, sondern auch den Einsatz von Personal und Ressourcen für zeitintensive repetitive Arbeitsschritte wie das Aufbereiten von Daten reduzieren. Hier wird die Beobachtung interessant sein, wie sich die Arbeitswelten in KMU mit der Nutzung verändern werden.

Die Einführung von Low-Code und No-Code Technologien verändert die Art des benötigten Fachwissens langfristig, ersetzt aber nicht zwangsläufig die Notwendigkeit für Fachkompetenz. Komplexe und hochspezialisierte ML-Aufgaben werden voraussichtlich auch in Zukunft den Einsatz von klassischem ML, bei dem tiefgehendes Fachwissen und Programmierkenntnisse von Nöten sind, erforderlich machen. Obwohl AutoML, Low-Code- und No-Code-Plattformen die technische Umsetzung von ML vereinfachen, bleibt ein tiefgehendes Verständnis der geschäftlichen Herausforderungen und Ziele unerlässlich. Fachleute müssen in der Lage sein, klar definierte ML-Ziele zu setzen und die richtigen Anwendungsfälle zu identifizieren, in denen ML einen echten Mehrwert bietet. Ein starkes Datenverständnis bleibt somit nach wie vor von entscheidender Bedeutung, insbesondere hinsichtlich Datenschutz- und Compliance-Anforderungen sowie der Einhaltung ethischer Standards. Hier ist Fachexpertise bei der Interpretation von ML-Modellen gefragt. Expert:innen müssen KI-Modelle verstehen, deren Ergebnisse einordnen können und sicherstellen,

dass Verzerrungen oder Diskriminierungen in Datensätzen vor dem Training von Modellen korrigiert werden.

Die Online-Befragung von Expert:innen bekräftigt die hohen Erwartungen an Anwendungen, die AutoML, No-Code und Low-Code beinhalten und zeigt gleichzeitig Herausforderungen auf, an denen (mittelständische) Unternehmen aktuell bei einer Integration von KI in Geschäftsprozesse scheitern. Die Ergebnisse geben wieder, dass Unternehmen einen fünf bis zehnjährigen Zeitrahmen benötigen werden, um KI-Lösungen in Form von No-Code und Low-Code zu integrieren. Um dies sicherzustellen, sollten auch die Anforderungen des Mittelstands an die Software-Tools hinsichtlich Funktionalität, Benutzerfreundlichkeit, Datenschutz oder IT-Sicherheit gewährleistet werden. Letztlich bleibt abzuwarten, ob die neuen Software-Tools als Sandbox dazu geeignet sind, die wirtschaftliche Unsicherheit bzgl. der Bewertung des Einsatzes von ML-Modellen zu reduzieren, um damit auch zu einer Erhöhung der KI-Readiness des deutschen Mittelstands beitragen zu können. Vor diesem Hintergrund wäre eine erneute Befragung mittelfristig interessant.

Literaturverzeichnis

- Alsheibani, S., Cheung, Y., Messom, C. (2018):** Artificial Intelligence Adoption: AI-readiness at Firm-Level, PACIS 4 (2018): 231-245, abrufbar unter: https://researchmgt.mcnash.edu/ws/portalfiles/portal/273209396/254798983_oa.pdf, zuletzt abgerufen am 26.11.2023.
- Berg, A. (2022):** Künstliche Intelligenz – Wo steht die deutsche Wirtschaft?, Bitkom Umfrage, abrufbar unter https://www.bitkom.org/sites/main/files/2022-09/Charts_Kuenstliche_Intelligenz_130922.pdf, zuletzt abgerufen am 16.11.2023.
- Bettoni, A., Metteri, D., Montini, E., Gladysz, B., Carapanzano, E. (2021):** An AI adoption model for SMEs: A conceptual framework, IFAC-PapersOnLine 54.1: 702-708, abrufbar unter: <https://www.sciencedirect.com/science/article/pii/S2405896321008259>, zuletzt abgerufen am 16.11.2023.
- Bundesnetzagentur [BNetzA] (2023):** Digitalisierung und ökologische Nachhaltigkeit in Unternehmen, abrufbar unter: https://data.bundesnetzagentur.de/Bundesnetzagentur/DE/Fachthemen/Digitalisierung/Mittelstand/Downloads/studie_langfassung.pdf, zuletzt abgerufen am 16.11.2023.
- Cisco (2023):** Cisco AI Readiness Index, abrufbar unter: https://www.cisco.com/c/dam/m/en_us/solutions/ai/readiness-index/documents/cisco-global-ai-readiness-index.pdf, zuletzt abgerufen am 24.11.2023.
- Deloitte (2021):** Künstliche Intelligenz im Mittelstand, abrufbar unter: https://www2.deloitte.com/content/dam/Deloitte/de/Documents/Mittelstand/Erfolgsfaktorenstudie_K%C3%BCnstliche%20Intelligenz%20im%20Mittelstand.pdf, zuletzt abgerufen am 16.11.2023.
- Dindorf, C., Bartaguiz, E., Gassmann, F., Fröhlich, M. (2023):** Eine kurze Einführung in die Künstliche Intelligenz, Künstliche Intelligenz in Sport und Sportwissenschaft: Potenziale, Herausforderungen und Limitationen, abrufbar unter: https://link.springer.com/chapter/10.1007/978-3-662-67419-2_2, zuletzt abgerufen am 16.11.2023.
- Distler, J., Flicker, I., Hepp, M., Krüger, F., Seara, J. (2019):** Ready for A(I)nything, abrufbar unter: https://web-assets.bcg.com/img-src/Ready-for-AI-nything_tcm9-232714.pdf, zuletzt abgerufen am 24.11.2023.
- Etlinger, S. (2018):** The AI Maturity Playbook: Five Pillars of Enterprise Success, Altimeter@Prophet Research Report (2018), abrufbar unter: <https://de.slideshare.net/Altimeter/report-preview-the-ai-maturity-playbook-five-pillars-of-enterprise-success>, zuletzt abgerufen am 16.11.2023.
- Gull, I., Liebe, A., Steffen, N., Wiewiorra, L. (2021):** Implementierung von KI im Mittelstand – Die Verfügbarkeit von Trainingsdaten und Förderung offener Datenstrukturen, abrufbar unter: https://www.wik.org/fileadmin/files/_migrated/news_files/WIK_Kurzstudie-KI-im-Mittelstand.pdf, zuletzt abgerufen am 16.11.2023.
- Hamon, R., Junklewitz, H., Sanchez, I. (2020):** Robustness and explainability of artificial intelligence, Publications Office of the European Union 207, abrufbar unter: <https://publications.jrc.ec.europa.eu/repository/handle/JRC119336>, zuletzt abgerufen am 16.11.2023.
- He, X., Zhao, K., Chu, X. (2021):** AutoML: A survey of the state-of-the-art, Knowledge-Based Systems 212 (2021): 106622, abrufbar unter: <https://www.sciencedirect.com/science/article/abs/pii/S0950705120307516>, zuletzt abgerufen am 16.11.2023.
- Hornik, K., Stinchcombe, M., White, H. (1989):** Multilayer feedforward networks are universal approximators." Neural networks 2.5 (1989): 359-366, abrufbar unter: <https://www.sciencedirect.com/science/article/abs/pii/0893608089900208>, zuletzt abgerufen am 16.11.2023.

- Hossain, M.A., Rafidah, M. N., Kok-Lim, A. Y., Raz, S. (2020):** Comprehensive survey of machine learning approaches in cognitive radio-based vehicular ad hoc networks, IEEE Access 8 (2020): 78054-78108, abrufbar unter: <https://ieeexplore.ieee.org/document/9076680>, zuletzt abgerufen am 16.11.2023.
- Hussien, M. (2021):** Exploring the Maze of Reinforcement Learning, abrufbar unter: <https://substance.etsmtl.ca/en/exploring-maze-reinforcement-learning>, zuletzt abgerufen am 16.11.2023.
- Icks, A., Brink, S. (2023):** Zukunftspanel Mittelstand 2023: Erhöhter Wettbewerbsdruck fordert die Unternehmen heraus, abrufbar unter: https://www.ifm-bonn.org/fileadmin/data/redaktion/publikationen/chartbooks/Chartbook_Zukunftspanel_Mittelstand_2023.pdf, zuletzt abgerufen am 16.11.2023.
- Janakiram, MSV (2018):** Why AutoML Is Set To Become The Future Of Artificial Intelligence, in: Forbes, abrufbar unter <https://www.forbes.com/sites/janakirammsv/2018/04/15/why-automl-is-set-to-become-the-future-of-artificial-intelligence/?sh=40d92bc7780a>, zuletzt abgerufen am 16.11.2023.
- Kaiser, J., Terrazzas, G., McFarlane, D., de Dilva, L. (2021):** Towards low-cost machine learning solutions for manufacturing SMEs. AI & SOCIETY: 1-7, abrufbar unter: <https://link.springer.com/article/10.1007/s00146-021-01332-8>, zuletzt abgerufen am 16.11.2023.
- Klingholz, L., Holtel, S., Hartmann, T. (2018):** Digitalisierung gestalten mit dem Periodensystem der Künstlichen Intelligenz, abrufbar unter: https://www.bitkom.org/sites/default/files/2018-12/181204_LF_Periodensystem_online_0.pdf, zuletzt abgerufen am 16.11.2023.
- KPMG (2019):** How may AI assist you – Wie sie mithilfe von künstlicher Intelligenz die Customer Experience gezielt verbessern können, Studie, abrufbar unter: <https://assets.kpmg.com/content/dam/kpmg/at/pdf/studien/ki-studie-how-may-ai-assist-you.pdf>, zuletzt abgerufen am 16.11.2023.
- Lebens, M., Finnegan, R., Sorsen, S., Shah, J. (2021):** Rise of the Citizen Developer, abrufbar unter: <http://pubs.mumabusinesreview.org/2021/MBR-05-12-101-111-Lebens-CitizenDeveloper.pdf>, zuletzt abgerufen am 16.11.2023.
- Liebe, A., Lundborg, M., Puhl, P., Marques Magalhaes, K. (2022):** Chancen digitaler Reifegradmodelle für KMU – eine vergleichende Untersuchung der Messkriterien, WIK-Diskussionsbeitrag Nr. 484, abrufbar unter https://www.wik.org/fileadmin/user_upload/Unternehmen/Veroeffentlichungen/Diskus/2022/WIK_Diskussionsbeitrag_Nr_484.pdf, zuletzt abgerufen am 16.11.2023.
- Lundborg, M., Märkel C, Schrade-Grytsenko, L., Stamm, P. (2019):** Künstliche Intelligenz im Telekommunikationssektor – Bedeutung, Entwicklungsperspektiven und regulatorische Implikationen, WIK-Diskussionsbeitrag Nr. 453, Bad Honnef, abrufbar unter https://www.wik.org/fileadmin/files/migrated/news_files/WIK_Diskussionsbeitrag_Nr_453.pdf, zuletzt abgerufen am 16.11.2023.
- Lundborg, M., Märkel, C. (2019):** Künstliche Intelligenz im Mittelstand: Relevanz, Anwendungen, Transfer, abrufbar unter: <https://www.mittelstand-digital.de/MD/Redaktion/DE/Publikationen/kuenstliche-intelligenz-im-mittelstand.pdf?blob=publicationFile&v=5>, zuletzt abgerufen am 16.11.2023.
- Märkel, C., Simons, M., Stronzik, M., Papan, M., Lundborg, M., Gesmann-Nuissl, D., Beck, R. (2022):** Fachdialog Blockchain – Blockchain im Mittelstand, abrufbar unter: <https://www.bmwk.de/Redaktion/DE/Publikationen/Mittelstand/blockchain-im-mittelstand.pdf?blob=publicationFile&v=6>, zuletzt abgerufen am 16.11.2023.

- Märkel, C., Stronzik, M., Simons, M., Wissner, M., Lundborg, M. (2021):** Einsatz von Blockchain in KMU: Chancen & Hemmnisse, abrufbar unter: https://www.wik.org/uploads/media/WIK_Diskussionsbeitrag, zuletzt abgerufen am 16.11.2023.
- NFX (2023):** Weltweit führende Startups im Bereich des Maschinellen Lernens nach Investitionsvolumen bis Januar 2023, in: Statista. Abrufbar unter: <https://de.statista.com/statistik/daten/studie/1362247/umfrage/investitionen-startups-maschinelles-lernen/>, zuletzt abgerufen am 16.11.2023.
- Odermatt, M. und Saladin, T. (2018):** Bildklassifikation mit Hilfe eines neuronalen Netzes, Diss. HSR Hochschule für Technik Rapperswil, abrufbar unter: <https://eprints.ost.ch/id/eprint/745/>, zuletzt abgerufen am 16.11.2023.
- Olson, R. L., Bartley, N., Urbanowicz, R. J., Moore, J. H. (2016):** Evaluation of a Tree-based Pipeline Optimization Tool for Automating Data Science, abrufbar unter <https://arxiv.org/pdf/1603.06212.pdf>, zuletzt abgerufen am 16.11.2023.
- Olsowski, S., Schögl, S., Richter, E., Bernsteiner, R. (2022):** Investigating the Potential of AutoML as an Instrument for Fostering AI Adoption in SMEs, International Conference on Knowledge Management in Organization, Cham: Springer International Publishing, abrufbar unter: https://www.researchgate.net/publication/361732523_Investigating_the_Potential_of_AutoML_as_an_Instrument_for_Fostering_AI_Adoption_in_SMEs, zuletzt abgerufen am 16.11.2023.
- Paaß, G. (2021):** Deep Learning: Wie funktionieren tiefe neuronale Netze?, abrufbar unter: <https://lamarr-institute.org/de/blog/tiefe-neuronale-netze/>, zuletzt abgerufen am 16.11.2023.
- Polink, C. (2021):** Maschinelles Lernen 2021: Aktuelle Trends und deren Relevanz, Bitkom-Studie, abrufbar unter https://www.bitkom.org/sites/main/files/2021-02/210204_maschinelles-lernen.pdf, zuletzt abgerufen am 26.04.2023.
- Raghavendran, K. (2022):** Analysis Of Fastlane For Digitalization Through Low-Code ML Platforms, abrufbar unter: <https://tu.diva-portal.org/smash/get/diva2:1705078/FULLTEXT01.pdf>, zuletzt abgerufen am 16.11.2023.
- Rokis, K. und Kirikova, M. (2022):** Challenges of low-code/no-code software development: A literature review, International Conference on Business Informatics Research, Cham: Springer International Publishing, abrufbar unter: https://link.springer.com/chapter/10.1007/978-3-031-16947-2_1, zuletzt abgerufen am 16.11.2023.
- Rogerson, A., Hankins, E., Nettel, P.F., Rahim, S. (2022):** Government AI Readiness Index 2022, abrufbar unter: https://static1.squarespace.com/static/58b2e92c1e5b6c828058484e/t/639b495cc6b59c620c3ecde5/1671121299433/Government_AI_Readiness_2022_FV.pdf, zuletzt abgerufen am 24.11.2023.
- Ruffle, J. K., Foulon, C., Nachev, P. (2023):** The human cost of ethical artificial intelligence, Brain Structure and Function : 1-5, abrufbar unter: <https://link.springer.com/article/10.1007/s00429-023-02662-7>, zuletzt abgerufen am 16.11.2023.
- Sahay, A., Indamutsa A., Di Ruscio, D., Pierantonio, A. (2020):** Supporting the understanding and comparison of low-code development platforms, Conference Paper, abrufbar unter https://www.researchgate.net/publication/344842798_Supporting_the_understanding_and_comparison_of_low-code_development_platforms/link/5fdcbf2aa6fdccdc8ddf299/download, zuletzt abgerufen am 16.11.2023.
- Sarker, I. H. (2021):** Deep learning: a comprehensive overview on techniques, taxonomy, applications and research directions, SN Computer Science 2.6 (2021): 420, abrufbar unter: <https://link.springer.com/article/10.1007/s42979-021-00815-1>, zuletzt abgerufen am 16.11.2023.

- Schmidt, H. J., Buxmann, P. (2019):** Künstliche Intelligenz: Mit Algorithmen zum wirtschaftlichen Erfolg, Springer Gabler, abrufbar unter: <https://link.springer.com/book/10.1007/978-3-662-57568-0>, zuletzt abgerufen am 16.11.2023.
- Schmidt, J.-H. (2020):** Mit besten Empfehlungen: Grundprinzipien algorithmischer Empfehlungssysteme für öffentlich-rechtliche Medienangebote, in: Grimme Institut (2020): 56. Grimme Preis, abrufbar unter https://www.grimme-institut.de/fileadmin/Grimme_NutzerDateien/Preis/Grafiken_und_Fotos/2020/Publikation/Grimme-Preis_Publikation-2020_web.pdf, zuletzt abgerufen am 16.11.2023.
- Sonnet, D. (2022a):** Best Practice: Möglichkeiten und Grenzen Neuronaler Netze, Springer Vieweg, abrufbar unter: <https://link.springer.com/book/10.1007/978-3-658-29081-8>, zuletzt abgerufen am 16.11.2023.
- Sonnet, D. (2022b):** Neuronale Netze kompakt: Vom Perceptron zum Deep Learning, Springer Vieweg, abrufbar unter: https://link.springer.com/chapter/10.1007/978-3-658-29081-8_3, zuletzt abgerufen am 16.11.2023.
- Statista (2022a):** Künstliche Intelligenz – Hauptanwendungsfelder, Dossier, abrufbar unter: <https://de.statista.com/statistik/studie/id/38585/dokument/kuenstliche-intelligenz-statista-dossier/?locale=de>, zuletzt abgerufen am 16.11.2023.
- Statista (2022b):** Haben Sie genug Fachkräfte, um die Digitalisierung schnell und effektiv voranzutreiben?, abrufbar unter: <https://de.statista.com/statistik/daten/studie/1325545/umfrage/it-fachkraefte-fuer-digitalisierung/>, zuletzt abgerufen am 16.11.2023.
- Sundberg, L. und Holmström, J. (2023):** Democratizing artificial intelligence: How no-code AI can leverage machine learning operations, Business Horizons, abrufbar unter: <https://www.sciencedirect.com/science/article/pii/S0007681323000502>, zuletzt abgerufen am 16.11.2023.
- Tas, S., Wiewiorra, L. (2022):** Nachvollziehbarkeit und Kontrolle algorithmischer Entscheidungen und Systeme, WIK-Kurzstudie, abrufbar unter https://www.wik.org/fileadmin/files/migrated/news_files/WIK_Kurzstudie_Algorithmen.pdf, zuletzt abgerufen am 16.11.2023.
- Techconsult (2021):** Low Code-/No-Code-Development Enabler der digitalen Transformation, abrufbar unter https://www.smapone.com/fileadmin/user_upload/Whitepaper/smapOne_Studie_No_Code_Plattformen_190721.pdf, zuletzt abgerufen am 16.11.2023.
- Trabold, D. (2021):** Welche Arten von Maschinellem Lernen gibt es?, abrufbar unter: <https://machinelearning-blog.de/grundlagen/welche-arten-von-maschinellem-lernen-gibt-es/>, zuletzt abgerufen am 16.11.2023.
- Wennker, P. (2020):** Künstliche Intelligenz in der Praxis - Anwendung in Unternehmen und Branchen: KI wettbewerbs- und zukunftsorientiert Einsetzen; Springer Gabler: Wiesbaden, Germany, abrufbar unter: <https://www.springerprofessional.de/kuenstliche-intelligenz-in-der-praxis/18334316>, zuletzt abgerufen am 16.11.2023.
- Willems, K. (2017):** Keras Tutorial: Deep Learning in Python, abrufbar unter: <https://www.datacamp.com/tutorial/deep-learning-python>, zuletzt abgerufen am 16.11.2023.
- Wirtz, B. W. und Weyerer, J. C. (2019):** Künstliche Intelligenz: Erscheinungsformen, Nutzungspotenziale und Anwendungsbereiche, Wirtschaftswissenschaftliches Studium (WiSt), abrufbar unter: https://rsw.beck.de/docs/librariesprovider75/default-document-library/beitrag-wirtz-weyerer-wist-10-2019.pdf?sfvrsn=37df7424_0, zuletzt abgerufen am 16.11.2023.
- Wisneski, C. (2022):** Complete guide to AI-as-a-service (AlaaS), abrufbar unter: <https://www.akkio.com/post/ai-as-a-service>, zuletzt abgerufen am 16.11.2023.

Wuttke, L. (o.J.a): Machine Learning: Definition, Algorithmen, Methoden und Beispiele, abrufbar unter <https://datasolut.com/was-ist-machine-learning/#Trainingsdaten>, zuletzt abgerufen am 16.11.2023.

Wuttke, L. (o.J.b): Ist Auto ML die Zukunft von Data Science?, abrufbar unter <https://datasolut.com/aufbau-eines-data-science-teams/>, zuletzt abgerufen am 16.11.2023.

Xin, D., Wu, E., Lee, D., Salehi, N., Parameswaran, A. (2021): Whither automl? understanding the role of automation in machine learning work-flows, proceedings of the 2021 CHI Conference on Human Factors in Computing Systems, abrufbar unter: <https://arxiv.org/abs/2101.04834>, zuletzt abgerufen am 16.11.2023.

Anhang

A1: KI Readiness

Das Konzept der „KI-Readiness“ versucht einen theoretischen Rahmen zu schaffen, um die Bereitschaft und Fähigkeit von Organisationen zu untersuchen, die KI-Technologie in ihre Geschäftsprozesse zu integrieren. Um Handlungsempfehlungen abzuleiten, deren Umsetzung die KI-Readiness von Organisationen oder Unternehmen erhöht, nehmen diese Ansätze häufig Bezug auf Innovations- und Transformationstheorien. In der Regel werden KI-Readiness-Checks mit unternehmerischen Umfragen und Selbstanalysen zu einzelnen Faktoren und Indikatoren geprüft.¹¹⁴

Alsheibani et al. (2018) führen beispielsweise Technologie-, Organisation- sowie Umweltfaktoren (siehe Abbildung 2-6) als zentrale Indikatoren für KI-Readiness an.¹¹⁵ Als Technologiefaktor, der sich auf die KI-Readiness eines Unternehmens auswirken kann, wird dort der relative Vorteil von KI in unternehmerischen Geschäftsprozesse gegenüber anderen Technologien angeführt. Als Organisationsfaktoren werden etwa Größe eines Unternehmens, die Managementstrukturen sowie die Ressourcenverfügbarkeit genannt. Die damit verbundene Unterstützung durch das Topmanagement, die Unternehmensgröße sowie Personal-, Unternehmens- und Technologieressourcen können als Faktoren dieses Bereichs die KI-Readiness eines Unternehmens beeinflussen. Um die Anpassungsfähigkeit eines Unternehmens zu bewerten, werden Umgebungsfaktoren wie der unternehmerische Umgang mit Wettbewerb und staatlicher Regulierungen als treibende Kräfte angeführt. Wettbewerbsdruck und staatliche Vorschriften werden somit als Faktoren gesehen, die die KI-Readiness eines Unternehmens beeinflussen können.¹¹⁶

Weitere KI-Readiness-Indizes wie der von Oxford Insights¹¹⁷, der Cisco Readiness-Index¹¹⁸ oder der KI-Readiness-Index von BCG¹¹⁹ beziehen Faktoren wie Infrastruktur, Humankapital, Innovation, Regulierung und Datenschutz sowie Datenqualität, Algorithmenkompetenz, Anwendungsbereiche und Umsetzungsfähigkeit in ihre Bewertung der KI-Readiness von Organisationen ein. Diese Bewertung ist oft kontextabhängig, da sie individuelle Ziele und Herausforderungen berücksichtigt. Um die vielfältigen Faktoren und Indikatoren bei der Bewertung der KI-Readiness einer Organisation angemessen zu erfassen, variieren die Frameworks und Modelle entsprechend.¹²⁰

Abbildung A-1: KI-Readiness Framework

¹¹⁴ Vgl. KI-Readiness-Check des Mittelstand-Digital Zentrum Kaiserlauten: <https://digitalzentrum-kaiserslautern.de/unsere-angebote/self-service/ki-readiness-check> [Letzter Abruf 17.11.2023].

¹¹⁵ Ob Organisationen ausreichend Kompetenzen besitzen, erfolgreich neue Technologien zu implementieren, kann aus unterschiedlichen Perspektiven betrachtet werden. Der „Technology, Organisation, and Environment“ (TOE) Rahmen beschreibt die Adaptionfähigkeit von Innovationen auf Organisationsebene, während in der „Diffusion of Innovation“ (DOI) Theorie insbesondere auf soziale Prozesse und technologischen Charakteristiken eingegangen wird. Vgl. Alsheibani et al. (2018).

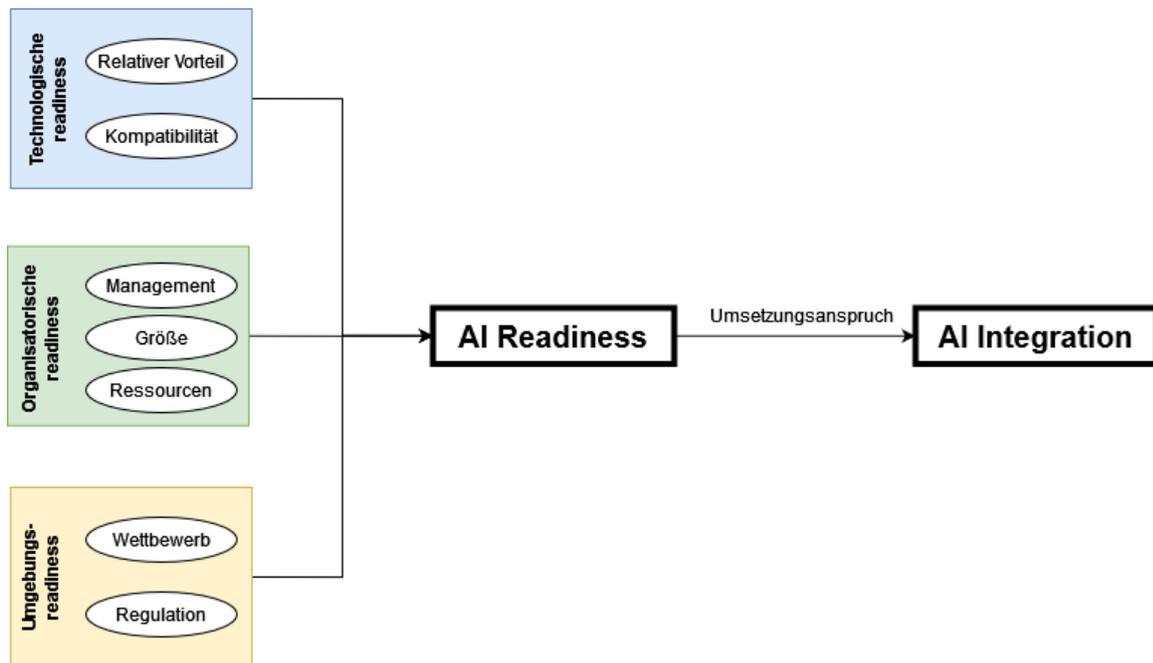
¹¹⁶ Vgl. Alsheibani et al. (2018).

¹¹⁷ Vgl. Rogerson et al. (2022).

¹¹⁸ Vgl. Cisco (2023).

¹¹⁹ Vgl. Distler et al. (2019).

¹²⁰ Vgl. Alsheibani et al. (2018).

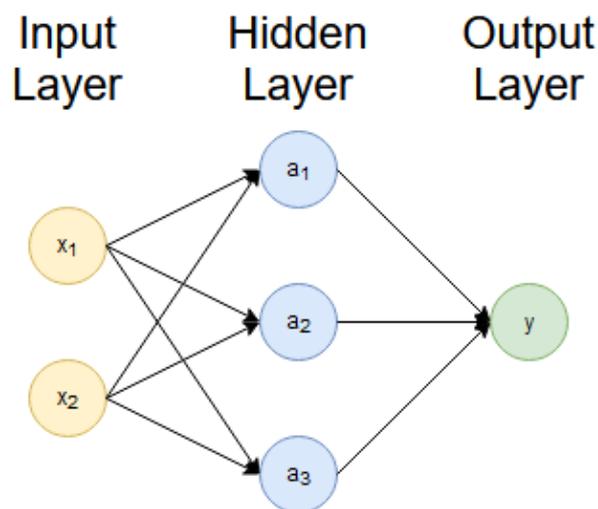


Quelle: WIK, eigene Darstellung in Anlehnung an Alsheibani et al. (2018).¹²¹

A2: Deep Dive zu neuronalen Netzen

Das universelle Approximations-Theorem besagt, dass ein ausreichend groß dimensioniertes oder „tiefes“ KNN, grundsätzlich dazu in der Lage ist, jeden funktionalen Zusammenhang zwischen einer Eingabe (Input) und einer Ausgabe (Output) zu approximieren.¹²²

Abbildung A-2: Künstliches Feedforward Neuronale Netz mit einem Hidden Layer



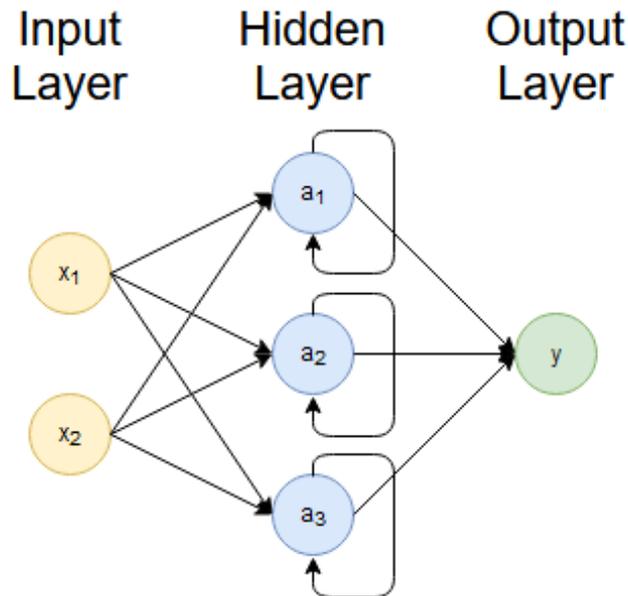
Quelle: WIK, eigene Darstellung.

Die einfachste Version eines KNN besitzt eine Eingabeschicht (Input Layer), eine verborgene Schicht (Hidden Layer) und eine Ausgabeschicht (Output Layer), die jeweils aus einzelnen Neuronen bestehen. Die Struktur des KNN kann als Graph dargestellt werden, siehe Abbildung A-2. Die Informationsverarbeitung erfolgt sequenziell, hier von links nach rechts in Form von Pfeilen modelliert, ausschließlich in eine Richtung. KNN, die dieser Struktur folgen, werden als Feedforward-Netze beschrieben. Abwandlungen, in denen Informationen auch rückgerichtet weitergeleitet werden, bezeichnet man als Rekurrente Netze, siehe Abbildung A-3.¹²³

¹²² Vgl. Hornik et al. (1989).

¹²³ Vgl. Sonnet (2022b).

Abbildung A-3: Künstliches Rekurrentes Neuronales Netz mit einem Hidden Layer

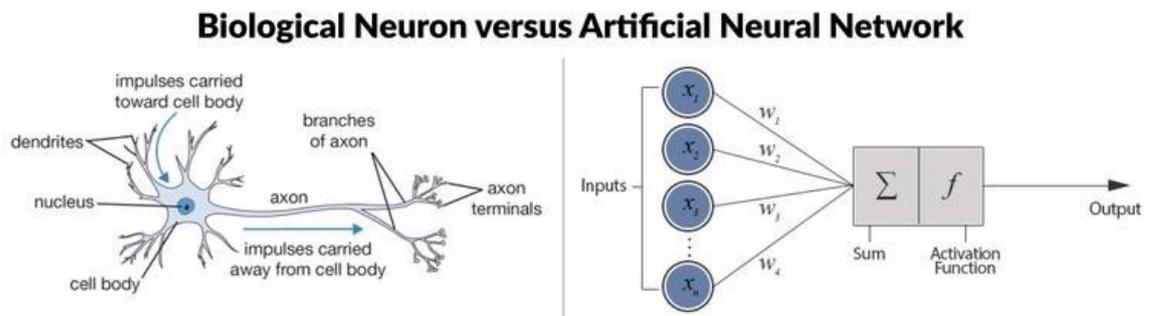


Quelle: WIK, eigene Darstellung.

Die Anzahl der Neuronen in der Eingabeschicht, hier als Knoten dargestellt, entspricht der Dimension der Informationen, die verarbeitet werden sollen, während die Anzahl der Neuronen in der verborgenen Schicht und Ausgabeschicht arbiträr gewählt werden kann. Der Aufbau und die Funktionsweise eines künstlichen Neurons ist von biologischen Neuronen inspiriert, gleicht diesen aber nur bedingt. Das Grundprinzip der Informationsweitergabe ist diesen in sehr einfacher Weise nachempfunden. Im künstlichen Neuron finden zwei Verarbeitungsprozesse statt. In einem ersten Schritt werden die einzelnen Eingabedaten verschieden gewichtet und in einer linearen Funktion zusammengeführt (üblicherweise aufsummiert). In einem zweiten Schritt wird das Ergebnis in einer Aktivierungsfunktion weiterverarbeitet, was dem KNN eine nicht-lineare Eigenschaft hinzufügt und so erlaubt, komplexe nicht-lineare Daten zu verarbeiten. Die Aktivierungsfunktion determiniert, welche Information das künstliche Neuron ausgibt. Es existieren eine Reihe von Aktivierungsfunktionen, die unterschiedliche Verhaltensweisen aufweisen und für verschiedene Anwendungsfälle eingesetzt werden. Die zurzeit am häufigsten verwendete Aktivierungsfunktion ist die Rectified Linear Unit (ReLU) Funktion.¹²⁴ Die Ausgabe der Aktivierungsfunktion ist somit auch die Ausgabe eines künstlichen Neurons.

¹²⁴ Die ReLU-Aktivierungsfunktion, $f(x) = \max(0, x)$, gibt eine Null zurück, wenn sie eine negative Eingabe empfängt. Ist die Eingabe positiv, leitet die ReLU Funktion genau diesen Wert weiter. Vgl. Odermatt und Saladin (2018).

Abbildung A-4: Künstliches Neuron



Quelle: Willems, K. (2017).¹²⁵

Der Lern- oder Trainingsprozess von KNN findet durch Lern- bzw. Trainingsalgorithmen statt. Eine weit verbreitete Variante ist der Backpropagation Algorithmus, der in einem iterativen Prozess die Gewichte aller Neuronen in einem KNN so adjustiert, dass die Abweichung zwischen der vom KNN vorhergesagten Ausgabe und einer tatsächlichen Ausgabe minimiert wird.¹²⁶ Unter Deep Learning (DL) versteht man KNN, die mehr als eine verborgene Schicht besitzen, wobei die Anzahl der verborgenen Schichten üblicherweise mit der Komplexität der Daten und des zu lösenden Problems steigt.¹²⁷ DL ist heutzutage die gängigste Praxis bei der Anwendung von KNN.¹²⁸

DL geht vor wie der Mensch, indem es nach Erhalt einer Information diese analysiert und dann eine Schlussfolgerung zieht. Es verwendet dazu eine Struktur aus verschiedenen Algorithmus-Schichten, die als künstliches neuronales Netz bezeichnet werden. Der Aufbau eines solchen Netzes wird dabei immer wieder mit dem menschlichen Gehirn verglichen. Damit ist DL der Teil der KI, der dem Menschen am ähnlichsten ist.¹²⁹

¹²⁵ Vgl. Willems (2017).

¹²⁶ Vgl. Schmidt und Buxmann (2019).

¹²⁷ Vgl. Sonnet (2022a).

¹²⁸ Vgl. ebd.

¹²⁹ Vgl. Paaß (2021) sowie <https://www.zendesk.de/blog/machine-learning-and-deep-learning/#georedirect> [Letzter Abruf 25.04.2023] und <https://www.iks.fraunhofer.de/de/themen/kuenstliche-intelligenz.html> [Letzter Abruf 25.04.2023].

A3: Steckbriefe identifizierter Softwarelösungen

Nr. 1: Akkio ¹³⁰
Basisangaben Anbieter <ul style="list-style-type: none"> • Anbieter: Akkio • Größe des Anbieters: KMU und Startups unter 500 MA sowie sonstige
Basisangaben Produkt <ul style="list-style-type: none"> • Produktname: Akkio • Softwareumgebung: KI-Plattform • Zielgruppe: Ohne Coding-Skills • Matrixbereich: No-Code • Bereitstellungsmodell: Cloud • Software-Lizensierung: Proprietär
ML-Spezifikation <ul style="list-style-type: none"> • Lernansatz: <ul style="list-style-type: none"> ○ Überwachtes Lernen, Unüberwachtes Lernen • ML-Methoden: <ul style="list-style-type: none"> ○ Klassifikation, Regression, Computer Vision, NLP

Nr. 2: Amazon SageMaker Canvas ¹³¹
Basisangaben Anbieter <ul style="list-style-type: none"> • Anbieter: Amazon • Größe des Anbieters: Top 10 of S&P500
Basisangaben Produkt <ul style="list-style-type: none"> • Produktname: Amazon SageMaker Canvas • Softwareumgebung: KI-Plattform • Zielgruppe: Ohne Coding-Skills und Basic Coding-Skills • Matrixbereich: Auto-ML, Low-Code, No-Code • Bereitstellungsmodell: Cloud • Software-Lizensierung: Proprietär
ML-Spezifikation <ul style="list-style-type: none"> • Lernansatz: <ul style="list-style-type: none"> ○ Überwachtes Lernen, Teilüberwachtes Lernen, Unüberwachtes Lernen • ML-Methoden: <ul style="list-style-type: none"> ○ Klassifikation, Regression, Computer Vision, NLP, Vorhersage

¹³⁰ Vgl. <https://docs.clarifai.com/> [Letzter Abruf 16.11.2023].

¹³¹ Vgl. <https://docs.aws.amazon.com/sagemaker/latest/dg/canvas.html> [Letzter Abruf 16.11.2023].

Nr. 3: Appypie ¹³²
<p>Basisangaben Anbieter</p> <ul style="list-style-type: none"> • Anbieter: Appypie • Größe des Anbieters: KMU und Startups unter 500 MA sowie sonstige
<p>Basisangaben Produkt</p> <ul style="list-style-type: none"> • Produktname: Appypie • Softwareumgebung: KI-Plattform • Zielgruppe: Ohne Coding-Skills • Matrixbereich: No-Code • Bereitstellungsmodell: On-Premise, Cloud • Software-Lizensierung: Proprietär
<p>ML-Spezifikation</p> <ul style="list-style-type: none"> • Lernansatz: <ul style="list-style-type: none"> ○ Überwachtes Lernen, Unüberwachtes Lernen • ML-Methoden: <ul style="list-style-type: none"> ○ NLP

Nr. 4: AutoGluon ¹³³
<p>Basisangaben Anbieter</p> <ul style="list-style-type: none"> • Anbieter: AutoGluon • Größe des Anbieters: KMU und Startups unter 500 MA sowie sonstige
<p>Basisangaben Produkt</p> <ul style="list-style-type: none"> • Produktname: AutoGluon • Softwareumgebung: Package • Zielgruppe: Basic Coding-Skills • Matrixbereich: Auto-ML • Bereitstellungsmodell: On-Premise, Cloud • Software-Lizensierung: Open-Source
<p>ML-Spezifikation</p> <ul style="list-style-type: none"> • Lernansatz: <ul style="list-style-type: none"> ○ Überwachtes Lernen, Teilüberwachtes Lernen, Unüberwachtes Lernen • ML-Methoden: <ul style="list-style-type: none"> ○ Klassifikation, Regression, Computer Vision, Zeitreihen, Multimodale Modelle

¹³² Vgl. <https://developer.appypie.com/docs/getting-started> [Letzter Abruf 16.11.2023].

¹³³ Vgl. <https://auto.gluon.ai/stable/index.html> [Letzter Abruf 16.11.2023].

Nr. 5: Auto-Keras¹³⁴**Basisangaben Anbieter**

- Anbieter: Auto-Keras
- Größe des Anbieters: KMU und Startups unter 500 MA sowie sonstige

Basisangaben Produkt

- Produktname: Auto-Keras
- Softwareumgebung: Package
- Zielgruppe: Basic Coding-Skills
- Matrixbereich: Auto-ML
- Bereitstellungsmodell: On-Premise, Cloud
- Software-Lizensierung: Open-Source

ML-Spezifikation

- Lernansatz:
 - Überwachtes Lernen, Teilüberwachtes Lernen, Unüberwachtes Lernen
- ML-Methoden:
 - Klassifikation, Regression, NLP

Nr. 6: Auto-SKLearn¹³⁵**Basisangaben Anbieter**

- Anbieter: Auto-SKLearn
- Größe des Anbieters: KMU und Startups unter 500 MA sowie sonstige

Basisangaben Produkt

- Produktname: Auto-SKLearn
- Softwareumgebung: Package
- Zielgruppe: Basic Coding-Skills
- Matrixbereich: Auto-ML
- Bereitstellungsmodell: On-Premise, Cloud
- Software-Lizensierung: Open-Source

ML-Spezifikation

- Lernansatz:
 - Überwachtes Lernen
- ML-Methoden:
 - Klassifikation, Regression, Optimierung

¹³⁴ Vgl. <https://autokeras.com/> [Letzter Abruf 16.11.2023].

¹³⁵ Vgl. <https://automl.github.io/auto-sklearn/master/> [Letzter Abruf 16.11.2023].

Nr. 7: Auto-ViML ¹³⁶
<p>Basisangaben Anbieter</p> <ul style="list-style-type: none"> • Anbieter: Auto-ViML • Größe des Anbieters: KMU und Startups unter 500 MA sowie sonstige
<p>Basisangaben Produkt</p> <ul style="list-style-type: none"> • Produktname: Auto-ViML • Softwareumgebung: Package • Zielgruppe: Basic Coding-Skills • Matrixbereich: Auto-ML • Bereitstellungsmodell: On-Premise, Cloud • Software-Lizensierung: Open-Source
<p>ML-Spezifikation</p> <ul style="list-style-type: none"> • Lernansatz: <ul style="list-style-type: none"> ○ Überwachtes Lernen, Teilüberwachtes Lernen, Unüberwachtes Lernen • ML-Methoden: <ul style="list-style-type: none"> ○ Klassifikation, Regression, Computer Vision, NLP, Entscheidungsmodelle

Nr. 8: BigML ¹³⁷
<p>Basisangaben Anbieter</p> <ul style="list-style-type: none"> • Anbieter: BigML • Größe des Anbieters: KMU und Startups unter 500 MA sowie sonstige
<p>Basisangaben Produkt</p> <ul style="list-style-type: none"> • Produktname: BigML • Softwareumgebung: Web-GUI • Zielgruppe: Ohne Coding-Skills • Matrixbereich: No-Code • Bereitstellungsmodell: Cloud • Software-Lizensierung: Proprietär
<p>ML-Spezifikation</p> <ul style="list-style-type: none"> • Lernansatz: <ul style="list-style-type: none"> ○ Überwachtes Lernen, Teilüberwachtes Lernen, Unüberwachtes Lernen • ML-Methoden: <ul style="list-style-type: none"> ○ Klassifikation, Regression, Zeitreihen, Dimensionsreduktion, Clusteranalyse

¹³⁶ Vgl. https://github.com/AutoViML/Auto_ViML [Letzter Abruf 16.11.2023].

¹³⁷ Vgl. <https://bigml.com/documentation/> [Letzter Abruf 16.11.2023].

Nr. 9: Clarifai¹³⁸
Basisangaben Anbieter <ul style="list-style-type: none"> • Anbieter: Clarifai • Größe des Anbieters: KMU und Startups unter 500 MA sowie sonstige
Basisangaben Produkt <ul style="list-style-type: none"> • Produktname: Clarifai • Softwareumgebung: Package, KI-Plattform • Zielgruppe: Ohne Coding-Skills und Basic Coding-Skills • Matrixbereich: AutoML, Low-Code, No-Code • Bereitstellungsmodell: On-Premise, Cloud • Software-Lizensierung: Proprietär
ML-Spezifikation <ul style="list-style-type: none"> • Lernansatz: <ul style="list-style-type: none"> ○ Überwachtes Lernen, Teilüberwachtes Lernen, Unüberwachtes Lernen • ML-Methoden: <ul style="list-style-type: none"> ○ Computer Vision, NLP, Generative Modelle

Nr. 10: DataRobot¹³⁹
Basisangaben Anbieter <ul style="list-style-type: none"> • Anbieter: DataRobot • Größe des Anbieters: Sonstige Großunternehmen
Basisangaben Produkt <ul style="list-style-type: none"> • Produktname: DataRobot • Softwareumgebung: KI-Plattform • Zielgruppe: Ohne Coding-Skills und Basic Coding-Skills • Matrixbereich: AutoML, Low-Code, No-Code • Bereitstellungsmodell: On-Premise, Cloud • Software-Lizensierung: Proprietär
ML-Spezifikation <ul style="list-style-type: none"> • Lernansatz: <ul style="list-style-type: none"> ○ Überwachtes Lernen, Teilüberwachtes Lernen, Unüberwachtes Lernen • ML-Methoden: <ul style="list-style-type: none"> ○ Klassifikation, Generative Modelle, Vorhersage, Clusteranalyse, Multimodale Modelle, Segmentierung

¹³⁸ Vgl. <https://bigml.com/documentation/> [Letzter Abruf 16.11.2023].

¹³⁹ Vgl. <https://docs.datarobot.com/> [Letzter Abruf 16.11.2023].

Nr. 11: Dataiku ¹⁴⁰
<p>Basisangaben Anbieter</p> <ul style="list-style-type: none"> • Anbieter: Dataiku • Größe des Anbieters: Sonstige Großunternehmen
<p>Basisangaben Produkt</p> <ul style="list-style-type: none"> • Produktname: Dataiku • Softwareumgebung: KI-Plattform • Zielgruppe: Ohne Coding-Skills und Basic Coding-Skills • Matrixbereich: AutoML, Low-Code, No-Code • Bereitstellungsmodell: On-Premise, Cloud • Software-Lizensierung: Proprietär
<p>ML-Spezifikation</p> <ul style="list-style-type: none"> • Lernansatz: <ul style="list-style-type: none"> ○ Überwachtes Lernen, Teilüberwachtes Lernen, Unüberwachtes Lernen, Verstärkendes Lernen • ML-Methoden: <ul style="list-style-type: none"> ○ Algorithmen von Scikit-Learn und XGBoost

Nr. 12: Graphite Note ¹⁴¹
<p>Basisangaben Anbieter</p> <ul style="list-style-type: none"> • Anbieter: Graphite Note • Größe des Anbieters: KMU und Startups unter 500 MA sowie sonstige
<p>Basisangaben Produkt</p> <ul style="list-style-type: none"> • Produktname: Graphite Note • Softwareumgebung: KI-Plattform • Zielgruppe: Ohne Coding-Skills • Matrixbereich: AutoML, No-Code • Bereitstellungsmodell: Cloud • Software-Lizensierung: Proprietär
<p>ML-Spezifikation</p> <ul style="list-style-type: none"> • Lernansatz: <ul style="list-style-type: none"> ○ Überwachtes Lernen, Teilüberwachtes Lernen, Unüberwachtes Lernen, Verstärkendes Lernen • ML-Methoden: <ul style="list-style-type: none"> ○ Klassifikation, Regression, Zeitreihen, Vorhersage, Clusteranalyse

¹⁴⁰ Vgl. <https://doc.dataiku.com/dss/latest/> [Letzter Abruf 16.11.2023].

¹⁴¹ Vgl. <https://docs.graphite-note.com/graphite-note-documentation/get-started/welcome> [Letzter Abruf 16.11.2023].

Nr. 13: H2O AutoML¹⁴²

Basisangaben Anbieter

- Anbieter: H2O AutoML
- Größe des Anbieters: KMU und Startups unter 500 MA sowie sonstige

Basisangaben Produkt

- Produktname: H2O AutoML
- Softwareumgebung: Package, Web-GUI
- Zielgruppe: Basic Coding-Skills
- Matrixbereich: AutoML, Low-Code
- Bereitstellungsmodell: On-Premise, Cloud
- Software-Lizensierung: Open-Source

ML-Spezifikation

- Lernansatz:
 - Überwachtes Lernen, Unüberwachtes Lernen
- ML-Methoden:
 - Klassifikation, Regression, Clusteranalyse

Nr. 14: IBM Watson Studio¹⁴³

Basisangaben Anbieter

- Anbieter: IBM
- Größe des Anbieters: Top 100 of S&P500

Basisangaben Produkt

- Produktname: IBM Watson Studio
- Softwareumgebung: KI-Plattform
- Zielgruppe: Ohne Coding-Skills und Basic Coding-Skills
- Matrixbereich: AutoML, Low-Code, No-Code
- Bereitstellungsmodell: Cloud
- Software-Lizensierung: Proprietär

ML-Spezifikation

- Lernansatz:
 - Überwachtes Lernen, Teilüberwachtes Lernen, Unüberwachtes Lernen
- ML-Methoden:
 - Klassifikation, Regression, Vorhersage, Entscheidungsmodelle, Multimodale Modelle, Clusteranalyse, Zeitreihen, NLP, Computer Vision

¹⁴² Vgl. <https://docs.h2o.ai/h2o/latest-stable/h2o-docs/automl.html> [Letzter Abruf 16.11.2023].

¹⁴³ Vgl. <https://cloud.ibm.com/developer/watson/documentation> [Letzter Abruf 16.11.2023].

Nr. 15: Leivity ¹⁴⁴
Basisangaben Anbieter <ul style="list-style-type: none">• Anbieter: Leivity• Größe des Anbieters: KMU und Startups unter 500 MA sowie sonstige
Basisangaben Produkt <ul style="list-style-type: none">• Produktname: Leivity• Softwareumgebung: KI-Plattform• Zielgruppe: Ohne Coding-Skills• Matrixbereich: AutoML, No-Code• Bereitstellungsmodell: On-Premise, Cloud• Software-Lizensierung: Proprietär
ML-Spezifikation <ul style="list-style-type: none">• Lernansatz:<ul style="list-style-type: none">○ Überwachtes Lernen, Teilüberwachtes Lernen, Unüberwachtes Lernen• ML-Methoden:<ul style="list-style-type: none">○ Klassifikation, Computer Vision, NLP

Nr. 16: Lobe ¹⁴⁵
Basisangaben Anbieter <ul style="list-style-type: none">• Anbieter: Microsoft• Größe des Anbieters: Top 10 of S&P500
Basisangaben Produkt <ul style="list-style-type: none">• Produktname: Lobe• Softwareumgebung: App• Zielgruppe: Ohne Coding-Skills• Matrixbereich: No-Code• Bereitstellungsmodell: On-Premise• Software-Lizensierung: Open-Source
ML-Spezifikation <ul style="list-style-type: none">• Lernansatz:<ul style="list-style-type: none">○ Überwachtes Lernen, Unüberwachtes Lernen• ML-Methoden:<ul style="list-style-type: none">○ Computer Vision

¹⁴⁴ Vgl. <https://leivity.ai/> [Letzter Abruf 16.11.2023].

¹⁴⁵ Vgl. <https://www.lobe.ai/docs/welcome/welcome> [Letzter Abruf 16.11.2023].

Nr. 17: MS Azure AutoML¹⁴⁶

Basisangaben Anbieter

- Anbieter: Microsoft
- Größe des Anbieters: Top 10 of S&P500

Basisangaben Produkt

- Produktname: MS Azure AutoML
- Softwareumgebung: KI-Plattform
- Zielgruppe: Ohne Coding-Skills und Basic Coding-Skills
- Matrixbereich: AutoML, Low-Code, No-Code
- Bereitstellungsmodell: Cloud
- Software-Lizensierung: Open-Source

ML-Spezifikation

- Lernansatz:
 - Überwachtes Lernen, Teilüberwachtes Lernen, Unüberwachtes Lernen, Verstärkendes Lernen
- ML-Methoden:
 - Klassifikation, Regression, Vorhersage, NLP, Computer Vision

Nr. 18: MLJar¹⁴⁷

Basisangaben Anbieter

- Anbieter: MLJar
- Größe des Anbieters: KMU und Startups unter 500 MA sowie sonstige

Basisangaben Produkt

- Produktname: MLJar
- Softwareumgebung: Package
- Zielgruppe: Basic Coding-Skills
- Matrixbereich: AutoML
- Bereitstellungsmodell: On-Premise, Cloud
- Software-Lizensierung: Open-Source

ML-Spezifikation

- Lernansatz:
 - Überwachtes Lernen, Teilüberwachtes Lernen
- ML-Methoden:
 - Klassifikation, Regression

¹⁴⁶ Vgl. <https://learn.microsoft.com/en-us/azure/machine-learning/?view=azureml-api-2> [Letzter Abruf 16.11.2023].

¹⁴⁷ Vgl. <https://supervised.mljar.com/> [Letzter Abruf 16.11.2023].

Nr. 19: Obviously AI ¹⁴⁸
Basisangaben Anbieter <ul style="list-style-type: none">• Anbieter: Obviously AI• Größe des Anbieters: KMU und Startups unter 500 MA sowie sonstige
Basisangaben Produkt <ul style="list-style-type: none">• Produktname: Obviously AI• Softwareumgebung: Web-GUI• Zielgruppe: Ohne Coding-Skills• Matrixbereich: No-Code• Bereitstellungsmodell: Cloud• Software-Lizensierung: Open-Source
ML-Spezifikation <ul style="list-style-type: none">• Lernansatz:<ul style="list-style-type: none">○ Überwachtes Lernen, Teilüberwachtes Lernen• ML-Methoden:<ul style="list-style-type: none">○ Klassifikation, Regression, Zeitreihen

Nr. 20: Pecan ¹⁴⁹
Basisangaben Anbieter <ul style="list-style-type: none">• Anbieter: Pecan• Größe des Anbieters: KMU und Startups unter 500 MA sowie sonstige
Basisangaben Produkt <ul style="list-style-type: none">• Produktname: Pecan• Softwareumgebung: KI-Plattform• Zielgruppe: Ohne Coding-Skills• Matrixbereich: No-Code• Bereitstellungsmodell: Cloud• Software-Lizensierung: Open-Source
ML-Spezifikation <ul style="list-style-type: none">• Lernansatz:<ul style="list-style-type: none">○ Überwachtes Lernen, Teilüberwachtes Lernen• ML-Methoden:<ul style="list-style-type: none">○ Regression, Vorhersage

¹⁴⁸ Vgl. <https://developers.obviously.ai/reference/welcome> [Letzter Abruf 16.11.2023].

¹⁴⁹ Vgl. <https://pecan.readthedocs.io/en/latest/> [Letzter Abruf 16.11.2023].

Nr. 21: Power Apps¹⁵⁰

Basisangaben Anbieter

- Anbieter: Microsoft
- Größe des Anbieters: Top 10 of S&P500

Basisangaben Produkt

- Produktname: Power Apps
- Softwareumgebung: App
- Zielgruppe: Ohne Coding-Skills
- Matrixbereich: No-Code
- Bereitstellungsmodell: On-Premise
- Software-Lizensierung: Proprietär

ML-Spezifikation

- Lernansatz:
 - Überwachtes Lernen, Teilüberwachtes Lernen, Unüberwachtes Lernen, Verstärkendes Lernen
- ML-Methoden:
 - Klassifikation, Computer Vision, NLP, Vorhersage

Nr. 22: Primer¹⁵¹

Basisangaben Anbieter

- Anbieter: Primer
- Größe des Anbieters: KMU und Startups unter 500 MA sowie sonstige

Basisangaben Produkt

- Produktname: Primer
- Softwareumgebung: App
- Zielgruppe: Ohne Coding-Skills
- Matrixbereich: No-Code
- Bereitstellungsmodell: On-Premise
- Software-Lizensierung: Proprietär

ML-Spezifikation

- Lernansatz:
 - Überwachtes Lernen, Teilüberwachtes Lernen
- ML-Methoden:
 - Strategische Analyse, Gefahrenerkennung

¹⁵⁰ Vgl. <https://learn.microsoft.com/de-de/power-apps/> [Letzter Abruf 16.11.2023].

¹⁵¹ Vgl. <https://primer.ai/products/primer-automate/> [Letzter Abruf 16.11.2023].

Nr. 23: PyCaret ¹⁵²
<p>Basisangaben Anbieter</p> <ul style="list-style-type: none"> • Anbieter: PyCaret • Größe des Anbieters: KMU und Startups unter 500 MA sowie sonstige
<p>Basisangaben Produkt</p> <ul style="list-style-type: none"> • Produktname: PyCaret • Softwareumgebung: Package • Zielgruppe: Basic Coding-Skills • Matrixbereich: AutoML • Bereitstellungsmodell: On-Premise, Cloud • Software-Lizensierung: Open-Source
<p>ML-Spezifikation</p> <ul style="list-style-type: none"> • Lernansatz: <ul style="list-style-type: none"> ○ Überwachtes Lernen, Teilüberwachtes Lernen, Unüberwachtes Lernen • ML-Methoden: <ul style="list-style-type: none"> ○ Klassifikation, Regression, Zeitreihen, Clusteranalyse, Anomalieerkennung

Nr. 24: Rapid Miner ¹⁵³
<p>Basisangaben Anbieter</p> <ul style="list-style-type: none"> • Anbieter: Rapid Miner • Größe des Anbieters: KMU und Startups unter 500 MA sowie sonstige
<p>Basisangaben Produkt</p> <ul style="list-style-type: none"> • Produktname: Rapid Miner • Softwareumgebung: KI-Plattform • Zielgruppe: Ohne Coding-Skills und Basic Coding-Skills • Matrixbereich: AutoML, Low-Code, No-Code • Bereitstellungsmodell: On-Premise, Cloud • Software-Lizensierung: Proprietär
<p>ML-Spezifikation</p> <ul style="list-style-type: none"> • Lernansatz: <ul style="list-style-type: none"> ○ Überwachtes Lernen, Teilüberwachtes Lernen • ML-Methoden: <ul style="list-style-type: none"> ○ Regression, Vorhersage, Zeitreihen, Optimierung

¹⁵² Vgl. <https://pycaret.readthedocs.io/en/latest/> [Letzter Abruf 16.11.2023].

¹⁵³ Vgl. <https://docs.rapidminer.com/> [Letzter Abruf 16.11.2023].

Nr. 25: Runway AI/ML¹⁵⁴**Basisangaben Anbieter**

- Anbieter: Runaway AI/ML
- Größe des Anbieters: KMU und Startups unter 500 MA sowie sonstige

Basisangaben Produkt

- Produktname: Runaway AI/ML
- Softwareumgebung: Web-GUI, App
- Zielgruppe: Ohne Coding-Skills
- Matrixbereich: No-Code
- Bereitstellungsmodell: Cloud
- Software-Lizensierung: Proprietär

ML-Spezifikation

- Lernansatz:
 - Überwachtes Lernen, Teilüberwachtes Lernen, Unüberwachtes Lernen
- ML-Methoden:
 - Multimodale Modelle

Nr. 26: Tazi.ai¹⁵⁵**Basisangaben Anbieter**

- Anbieter: Tazi.ai
- Größe des Anbieters: KMU und Startups unter 500 MA sowie sonstige

Basisangaben Produkt

- Produktname: Tazi.ai
- Softwareumgebung: KI-Plattform
- Zielgruppe: Ohne Coding-Skills
- Matrixbereich: AutoML, No-Code
- Bereitstellungsmodell: On-Premise, Cloud
- Software-Lizensierung: Proprietär

ML-Spezifikation

- Lernansatz:
 - Überwachtes Lernen, Teilüberwachtes Lernen, Unüberwachtes Lernen
- ML-Methoden:
 - Klassifikation, Regression, Clusteranalyse, Anomalieerkennung

¹⁵⁴ Vgl. <https://docs.runway.team/> [Letzter Abruf 16.11.2023].

¹⁵⁵ Vgl. <https://tazi.ai/> [Letzter Abruf 16.11.2023].

Nr. 27: Teachable Machine ¹⁵⁶
Basisangaben Anbieter <ul style="list-style-type: none">• Anbieter: Google• Größe des Anbieters: Top 10 of S&P500
Basisangaben Produkt <ul style="list-style-type: none">• Produktname: Teachable Machine• Softwareumgebung: Web-GUI• Zielgruppe: Ohne Coding-Skills• Matrixbereich: AutoML, No-Code• Bereitstellungsmodell: Cloud• Software-Lizensierung: Open-Source
ML-Spezifikation <ul style="list-style-type: none">• Lernansatz:<ul style="list-style-type: none">○ Überwachtes Lernen, Teilüberwachtes Lernen, Unüberwachtes Lernen• ML-Methoden:<ul style="list-style-type: none">○ Klassifikation, Computer Vision

Nr. 28: TransmogriAI ¹⁵⁷
Basisangaben Anbieter <ul style="list-style-type: none">• Anbieter: Salesforce• Größe des Anbieters: Top 100 of S&P500
Basisangaben Produkt <ul style="list-style-type: none">• Produktname: TransmogriAI• Softwareumgebung: Package• Zielgruppe: Basic Coding-Skills• Matrixbereich: AutoML• Bereitstellungsmodell: On-Premise, Cloud• Software-Lizensierung: Open-Source
ML-Spezifikation <ul style="list-style-type: none">• Lernansatz:<ul style="list-style-type: none">○ Überwachtes Lernen• ML-Methoden:<ul style="list-style-type: none">○ Klassifikation, Regression, Vorhersage

¹⁵⁶ Vgl. <https://teachablemachine.withgoogle.com/> [Letzter Abruf 16.11.2023].

¹⁵⁷ Vgl. <https://docs.transmogri.ai/en/stable/> [Letzter Abruf 16.11.2023].

Nr. 29: Vertex AI¹⁵⁸**Basisangaben Anbieter**

- Anbieter: Alphabet/Google
- Größe des Anbieters: Top 10 of S&P500

Basisangaben Produkt

- Produktname: Vertex AI
- Softwareumgebung: KI-Plattform
- Zielgruppe: Ohne Coding-Skills und Basic Coding-Skills
- Matrixbereich: AutoML, Low-Code, No-Code
- Bereitstellungsmodell: Cloud
- Software-Lizensierung: Proprietär

ML-Spezifikation

- Lernansatz:
 - Überwachtes Lernen, Teilüberwachtes Lernen, Unüberwachtes Lernen, Verstärkendes Lernen
- ML-Methoden:
 - Klassifikation, Computer Vision, NLP

158 Vgl. <https://cloud.google.com/vertex-ai/docs?hl=de> [Letzter Abruf 16.11.2023].

A4: Online-Befragung

A4.1 Befragte Institutionen

Folgende Institutionen wurden für eine Beantwortung der Online-Umfrage angefragt:

Acatech
Accenture
Applied AI
AWSi gGmbH
Bayern Innovativ
BTU Cottbus-Senftenberg
Bundesverband IT-Mittelstand e.V. (BITMi)
de:hub Karlsruhe
Deutsche Industrie- und Handelskammer (DIHK)
Deutsches Forschungszentrum für Künstliche Intelligenz GmbH (DFKI)
eco – Verband der Internetwirtschaft e. V.
embeteco GmbH & Co. KG
Ernst-Abbe-Hochschule Jena
Faunhofer IAO
Forschungszentrum L3S
fortiss GmbH
Fraunhofer FIT
Fraunhofer IEM
Fraunhofer IFF
Fraunhofer IGCV
Fraunhofer IIS
Fraunhofer IML
Fraunhofer IOSB-INA
Fraunhofer IPA
Fraunhofer IWU
FZI Forschungszentrum Informatik
Gesellschaft für Informatik
GFE - Gesellschaft für Fertigungstechnik und Entwicklung Schmalkalden e.V.
GreenAI
GS1 Germany GmbH
Hasso-Plattner-Institut (HPI)
Hasso-Plattner-Institut für Digital Engineering gGmbH
Hochschule Bonn-Rhein-Sieg
Hochschule der Medien
Hochschule Osnabrück - Institut für Management und Technik
HTWK Leipzig
IMMS Institut für Mikroelektronik- und Mechatronik-Systeme gemeinnützige GmbH (IMMS GmbH)
Industrie 4.0
Institut für Fertigungstechnik und Werkzeugmaschinen

Institut für Innovations- und Informationsmanagement (ifii)
Institut für Integrierte Produktion gGmbH
KI-Bundesverband
Münchner Kreis AG Mittelstand
münsterLAND.digital e.V.
MWIKE NRW
Otto-von-Guericke-Universität Magdeburg
Plattform lernende Systeme
RCKT GmbH
RKW Rationalisierungs- und Innovationszentrum der Deutschen Wirtschaft
e.V.
RWTH Aachen
Scale-up NRW
Springer
Technische Hochschule Wildau
Technische Universität Chemnitz
Technische Universität Darmstadt
Technische Universität Hamburg
TH Köln
TU-Ilmenau
Uni Bielefeld
Universität Siegen
VDI VDE
WIRI e.V.
ZEFAS
ZeMA gGmbH
Zentrum für Sonnenenergie- und Wasserstoff-Forschung BW

A4.2 Fragebogen Online-Befragung



No-Code, Low-Code und AutoML im Mittelstand

Vielen Dank für Ihre Bereitschaft, an der Umfrage zum Thema "AutoML, Low Code und No Code" teilzunehmen.

Die Beantwortung des Fragebogens wird ca. 10 Minuten in Anspruch nehmen.

Die Umfrage findet im Rahmen des WIK-Forschungsprojekts "Künstliche Intelligenz mit AutoML, Low Code und No Code" statt und wird von WIK-Consult durchgeführt.

**Bei Fragen zur Umfrage wenden Sie sich bitte an
Martin Simons oder an Christian Märkel.**

Mail: m.simons@wik.org // c.maerkel@wik.org

Tel.: +49 2224 9225-701 // +49 2224 9225-67





Fragen zu Low-Code, No-Code und AutoML im Mittelstand

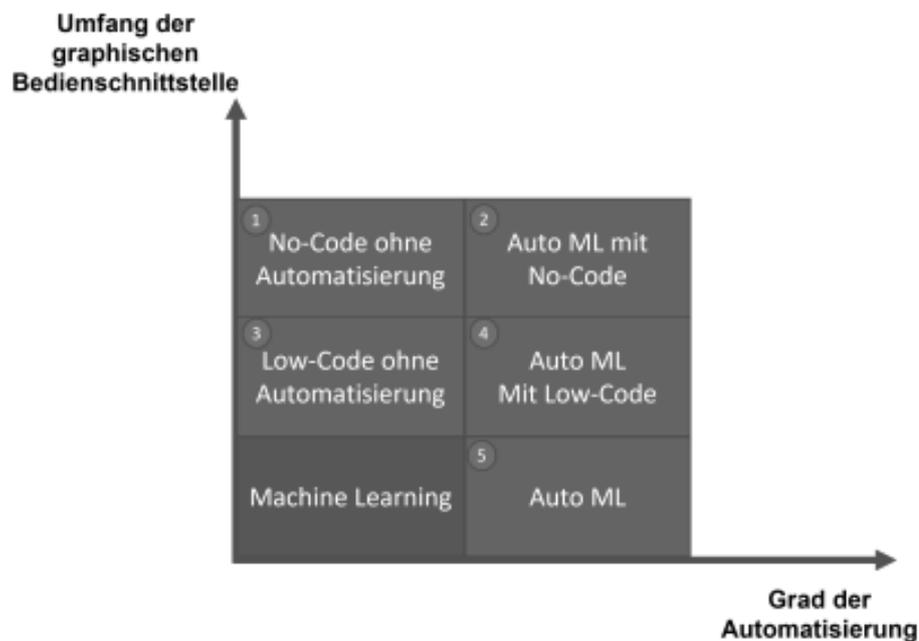
Untersuchungsgegenstand dieser Umfrage sind No-Code, Low-Code und AutoML im Zusammenhang mit aktuellen Entwicklungen im Machine Learning, das eine Teilmenge der Künstlichen Intelligenz darstellt.

Automatisiertes Maschinelles Lernen (AutoML) stellt die Automatisierung der einzelnen Schritte des Maschinellen Lernens dar und lässt damit die manuellen Schritte des klassischen, iterativen Prozesses obsolet werden.

Low-Code-Anwendungsentwicklung beschreibt die Erstellung von Anwendungssoftware mit visuellen Tools und modellgesteuerten Prozessen und reduziert den Umfang der erforderlichen harten Codierung. Bestandteil dieser Umfrage ist die Low-Code-Anwendungsentwicklung für Machine-Learning-Anwendungen.

No-Code-Anwendungsentwicklung erfordert im Vergleich zu Low-Code keinerlei Codierung und zielt daher eher auf die sogenannten Citizen Developer ab. Bestandteil dieser Umfrage ist die No-Code-Anwendungsentwicklung für Machine-Learning-Anwendungen.

Der betrachtete Bereich lässt sich in Abhängigkeit vom Grad der Automatisierung und dem Umfang der graphischen Benutzeroberfläche in sechs Anwendungsfelder aufteilen, von denen die fünf in untenstehender Abbildung grün gefärbten Felder im Fokus der Betrachtung stehen. Bitte beurteilen Sie im Folgenden die Bedeutung der fünf dargestellten Anwendungsfelder im Mittelstand.



1. Wie schätzen Sie den Umfang des tatsächlichen Einsatzes von **No-Code Lösungen** im Mittelstand ein?

	niedrig	eher niedrig	eher hoch	hoch	k. A.
Gegenwärtig	<input type="radio"/>				
In 5 Jahren	<input type="radio"/>				
In 10 Jahren	<input type="radio"/>				

2. Wie schätzen Sie den Umfang des tatsächlichen Einsatzes von **AutoML, integriert in No-Code Lösungen**, im Mittelstand ein?

	niedrig	eher niedrig	eher hoch	hoch	k. A.
Gegenwärtig	<input type="radio"/>				
In 5 Jahren	<input type="radio"/>				
In 10 Jahren	<input type="radio"/>				

3. Wie schätzen Sie den Umfang des tatsächlichen Einsatzes von **Low-Code Lösungen** im Mittelstand ein?

	niedrig	eher niedrig	eher hoch	hoch	k. A.
Gegenwärtig	<input type="radio"/>				
In 5 Jahren	<input type="radio"/>				
In 10 Jahren	<input type="radio"/>				

4. Wie schätzen Sie den Umfang des tatsächlichen Einsatzes von **AutoML, integriert in Low-Code Lösungen**, im Mittelstand ein?

	niedrig	eher niedrig	eher hoch	hoch	k. A.
Gegenwärtig	<input type="radio"/>				
In 5 Jahren	<input type="radio"/>				
In 10 Jahren	<input type="radio"/>				

5. Wie schätzen Sie den Umfang des tatsächlichen Einsatzes von **AutoML** im Mittelstand ein?

	niedrig	eher niedrig	eher hoch	hoch	k. A.
Gegenwärtig	<input type="radio"/>				
In 5 Jahren	<input type="radio"/>				
In 10 Jahren	<input type="radio"/>				



Einschätzung zu Kriterien der Auswahl entsprechender Software-Lösungen

6. Welche Bedeutung kommt Ihrer Meinung nach den folgenden Kriterien bei der Auswahl von Software-Lösungen im Bereich Low-Code, No-Code und AutoML im Mittelstand zu.

	keine Bedeutung	geringe Bedeutung	hohe Bedeutung	sehr hohe Bedeutung	k. A.
Preismodell (bspw. Abo vs klassisch)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Reputation des Anbieters	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Hauptsitz des Anbieters im Rechtsgebiet der EU	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Benötigte Fachkenntnisse	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Datenschutz und Informationssicherheit	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Datensouveränität (bspw. Cloud vs On-Premise)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Performance & Funktionalität (z.B. Zuverlässigkeit, Verfügbarkeit, geringe Fehlerraten etc.)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Flexible Skalierbarkeit (incl. z.B. Zubuchbarkeit weiterer Module)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Benutzerfreundlichkeit	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Portabilität der Daten und Anwendungen	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Interoperabilität mit Diensten anderer Anbieter	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Stärkung der Wettbewerbs- und / oder Innovationsfähigkeit	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Individualisierbarkeit (bspw. kommerziell oder Open-Source)	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>
Guter Support bzw. Beratung	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>	<input type="radio"/>

Sonstiges Kriterien



Einschätzung zu Nutzen & Hemmnisse von No-Code, Low-Code und AutoML

7. Bitte geben Sie an, wie hoch Sie den Nutzen des Einsatzes von AutoML, Low-Code und No-Code für den Mittelstand in den folgenden Bereichen einschätzen.

	kein Nutzen	geringer Nutzen	hoher Nutzen	sehr hoher Nutzen	k. A.
Zeitersparnis	<input type="radio"/>				
Keine oder nur sehr geringe Programmierkenntnisse erforderlich	<input type="radio"/>				
Bewährte Methoden stehen so zur Verfügung	<input type="radio"/>				
Ersparnis von personellen Kapazitäten (Fachkräfte, Data Scientists, ...)	<input type="radio"/>				
Flexibilität bei der Lösung von Problemen	<input type="radio"/>				
Vereinfachte Entwicklung & Bereitstellung von Anwendungen	<input type="radio"/>				
Verbesserung kontinuierliche Zusammenarbeit zwischen IT und Unternehmen	<input type="radio"/>				
Optimierte Modelle / Bessere Prognoseergebnisse im Vergleich zum klassischen KI-Einsatz	<input type="radio"/>				
Beschleunigung bei der Umsetzung von Anpassungs- und Optimierungserfordernissen	<input type="radio"/>				

Sonstige Bereiche

8. Bitte geben Sie an, wie ausschlaggebend Sie die folgenden Gründe für einen bis dato fehlenden Einsatz von AutoML, Low Code und No Code im Mittelstand ansehen.

	keine Rolle	geringe Rolle	hohe Rolle	sehr hohe Rolle	k. A.
Fehlender Bekanntheitsgrad	<input type="radio"/>				
Fehlendes Know-How der Potenziale	<input type="radio"/>				
Keine (vorstellbaren) Einsatzmöglichkeiten/Kein Bedarf	<input type="radio"/>				
Fehlende Möglichkeiten der Einflussnahme (Black Box)	<input type="radio"/>				
Bedenken hinsichtlich Datensicherheit/Privacy	<input type="radio"/>				
Zu hoher Preis	<input type="radio"/>				
Fehlende personelle Ressourcen / Einarbeitungszeit	<input type="radio"/>				
Mangelnde KI-Readiness	<input type="radio"/>				
Herstellerbindung	<input type="radio"/>				

Sonstige Hemmnisse



Vielen Dank für Ihre Teilnahme an der Umfrage!

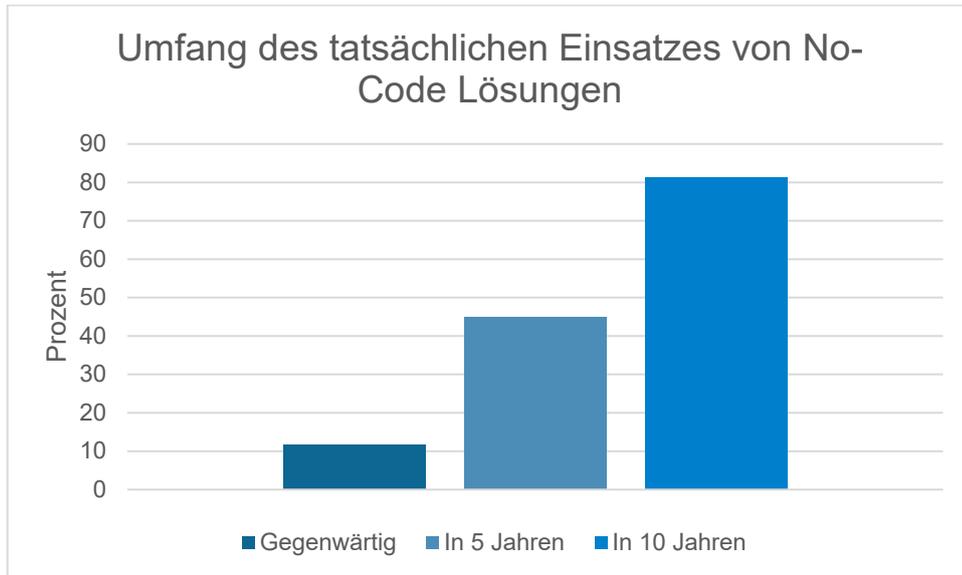
Dies ist das Ende der Umfrage. Wir bedanken uns für Ihre Teilnahme an unserer Umfrage und wünschen einen angenehmen Tag.

**Sollten Sie noch Fragen oder Anmerkungen zur Umfrage haben, wenden Sie sich bitte an
Martin Simons oder Christian Märkel.**

**Mail: m.simons@wik.org // c.maerkel@wik.org
Tel.: +49 2224 9225-701 // +49 2224 9225-67**

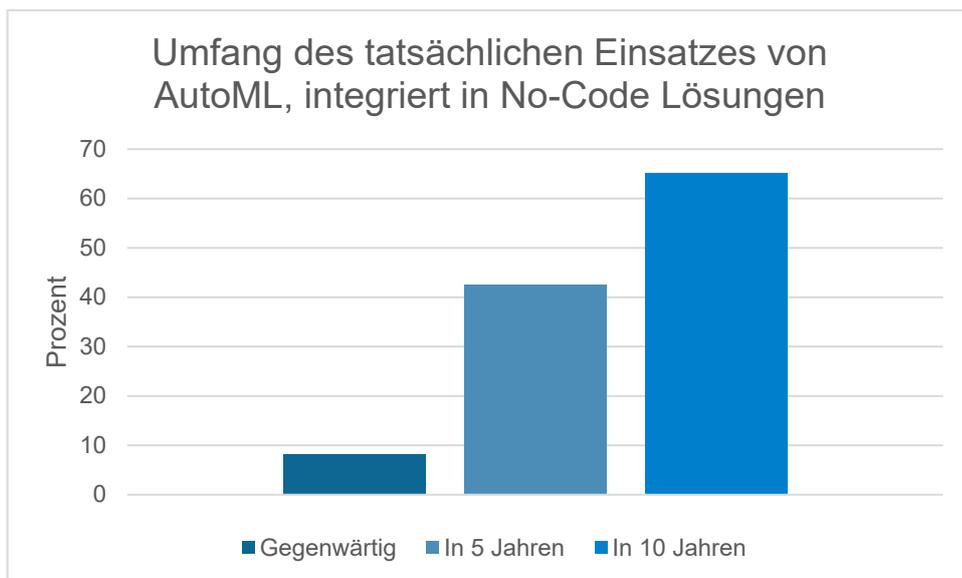
A4.3 Weitere Auswertung Online-Befragung

Abbildung A-5: Wie schätzen Sie den Umfang des tatsächlichen Einsatzes von No-Code Lösungen im Mittelstand ein?



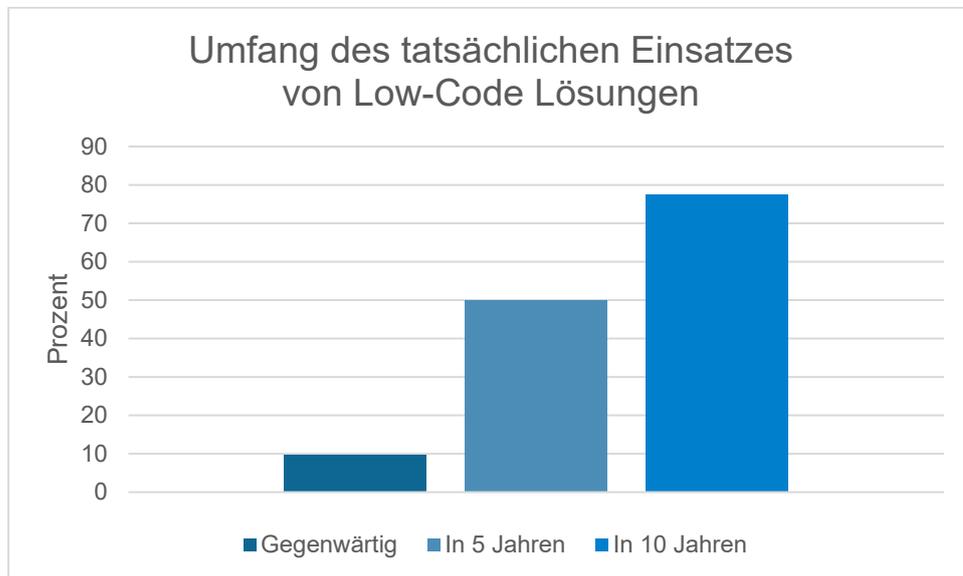
Quelle: WIK, eigene Darstellung, N=53.

Abbildung A-6: Wie schätzen Sie den Umfang des tatsächlichen Einsatzes von AutoML, integriert in No-Code Lösungen, im Mittelstand ein?



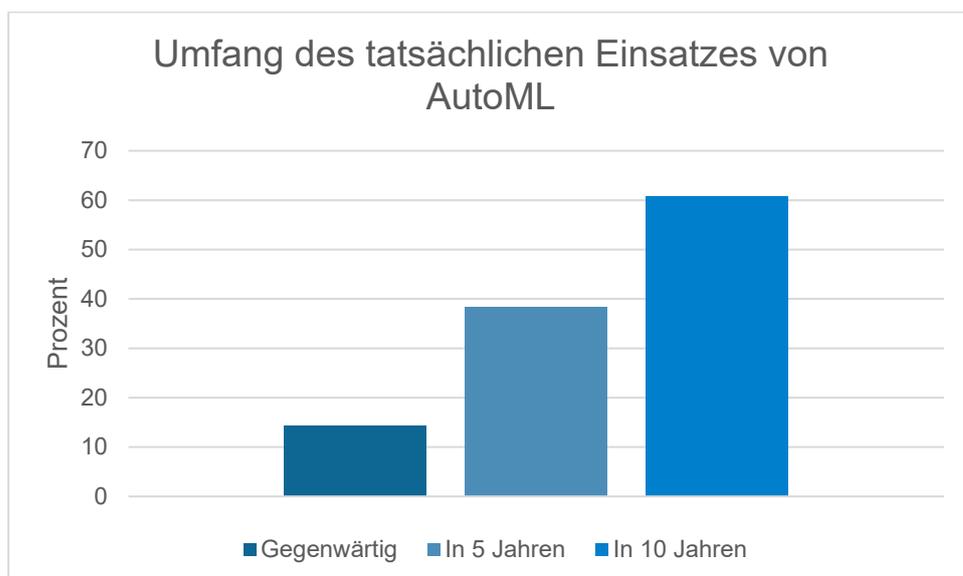
Quelle: WIK, eigene Darstellung, N=54.

Abbildung A-7: Wie schätzen Sie den Umfang des tatsächlichen Einsatzes von Low-Code Lösungen im Mittelstand ein?



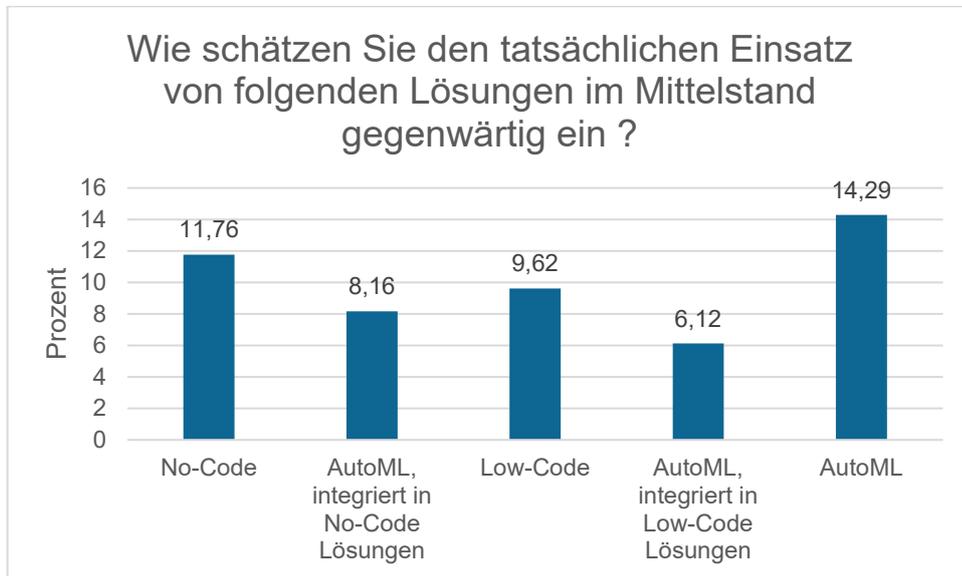
Quelle: WIK, eigene Darstellung, N=54.

Abbildung A-8: Wie schätzen Sie den Umfang des tatsächlichen Einsatzes von AutoML, integriert in Low-Code Lösungen, im Mittelstand ein?



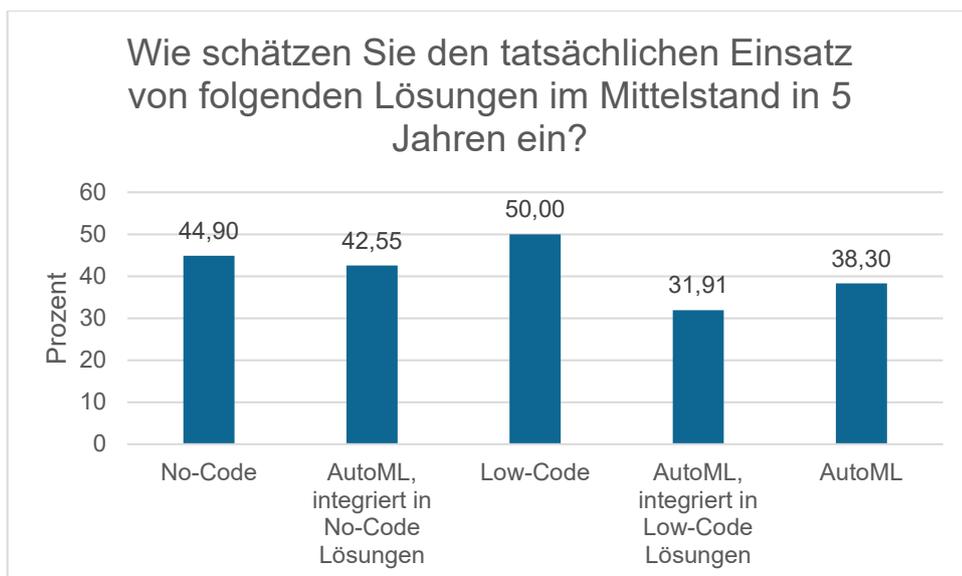
Quelle: WIK, eigene Darstellung, N=54.

Abbildung A-9: Wie schätzen Sie den tatsächlichen Einsatz von folgenden Lösungen im Mittelstand gegenwärtig ein?



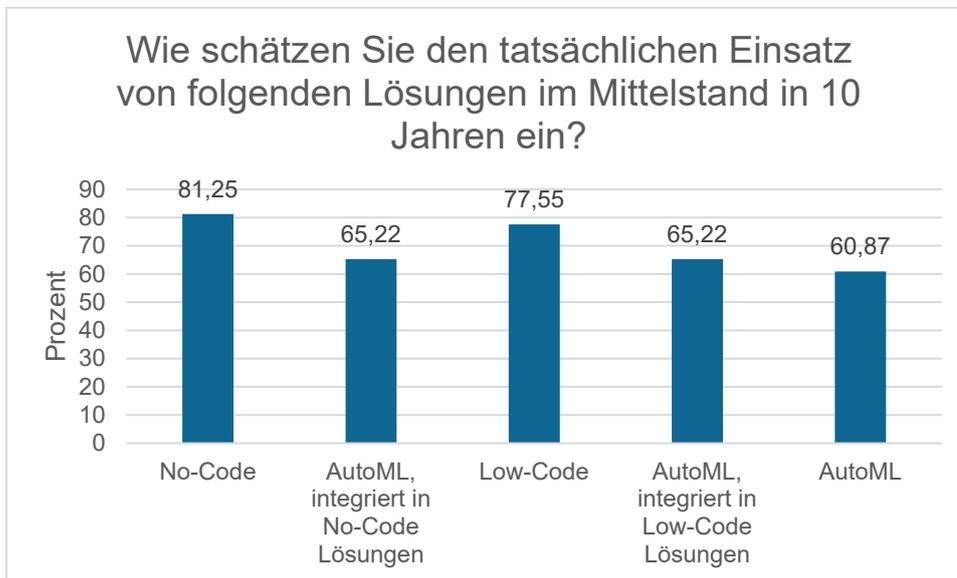
Quelle: WIK, eigene Darstellung, N=54.

Abbildung A-10: Wie schätzen Sie den tatsächlichen Einsatz von folgenden Lösungen im Mittelstand in 5 Jahren ein?



Quelle: WIK, eigene Darstellung, N=54.

Abbildung A-11: Wie schätzen Sie den tatsächlichen Einsatz von folgenden Lösungen im Mittelstand in 10 Jahren ein?



Quelle: WIK, eigene Darstellung, N=54.

ISSN 1865-8997