

Künstliche Intelligenz Strategie

Digitale Agenda Wien

INHALTSVERZEICHNIS

1	Management Summary	5
2	Wirkungsbereich	6
3	Strategische Ziele auf Ebene der Teilstrategie	7
3.1	Einordnung der KI-Strategie in die Digitale Agenda	7
3.2	Vision und Mission	7
3.3	Strategische Ziele	8
4	Künstliche Intelligenz	9
4.1	Geschichte der Künstlichen Intelligenz	9
4.2	Begriffsdefinition	9
4.2.1	Künstliche Intelligenz	9
4.2.2	Maschinelles Lernen	10
4.2.3	Künstliche Neuronale Netze und Deep Learning	10
4.3	Algorithmen des Maschinellen Lernens	11
4.3.1	Klassifikationsverfahren	11
4.3.2	Regressionsverfahren	11
4.3.3	Instanzbasierte Verfahren	11
4.3.4	Entscheidungsbäume	12
4.3.5	Bayes-Klassifikatoren	12
4.3.6	Clustering	12
4.3.7	Künstliche Neuronale Netze	12
4.4	Lernstile des Maschinellen Lernens	13
4.4.1	Überwachtes Lernen	13
4.4.2	Unüberwachtes Lernen	13
4.4.3	Teilüberwachtes Lernen	13
4.4.4	Bestärkendes Lernen	14

5 Herausforderungen beim Einsatz von Künstlicher Intelligenz	15
5.1 Datenhandhabung	15
5.2 Datenqualität.....	17
5.3 Unvoreingenommenheit der Ausgangsdaten.....	18
5.4 Nachvollziehbarkeit der Entscheidungen	18
5.5 Ethik und Risiken der Künstlichen Intelligenz.....	19
6 Trends und Fortschritte der KI	21
7 Anwendungsgebiete der KI.....	23
7.1 Maschinelle Verarbeitung natürlicher Sprache (Natural Language Processing)	23
7.2 Kognitive Assistenten	23
7.3 Computer Vision	24
7.4 Intelligente Entscheidungsunterstützung.....	25
7.5 Business Analytics.....	25
7.6 Roboter und Sensoren	25
7.7 Robotic Desktop bzw. Process Automation & Cognitive Computing	26
7.8 Autonome Transportmittel	27
8 KI-Framework.....	28
8.1 KI-Framework nach Gartner	28
8.2 Cloud Computing Anbieter	29
9 Umsetzungserfolg der KI-Strategie	30
9.1 Generische Anwendungsfälle zur Identifikation möglicher Anwendungsfälle	30
9.1.1 Auswertung von unstrukturierten Daten in Textform	30
9.1.2 Zeitreihenanalyse.....	32
9.1.3 Anomalie-Erkennung	33
9.1.4 Computer Vision.....	35
9.1.5 Chatbots & Assistenten	36
9.2 Empfohlenes Vorgehen bei der Umsetzung eines KI-Projektes	36

10 Zusammenfassung und Handlungsempfehlungen.....	38
10.1 Prozess zur Identifikation von zusätzlichen KI-Anwendungsfällen.....	38
10.2 Implementation von konkreten KI-Anwendungsfällen	38
10.3 Aufbau von KI-Kompetenzen in der Stadtverwaltung	38
10.3.1 Kompetenzprofile KI / Machine Learning.....	39
10.3.2 Kompetenzprofile Data Science / Data Engineer	39
10.4 Standardisierung.....	40
10.5 KI-Framework.....	40
10.6 Bereitstellung einer Prototyping-Umgebung für Entwicklerinnen und Entwickler	41
10.7 Sicherstellung von menschenzentrierter KI	41
11 Literaturverzeichnis.....	43
12 Abbildungsverzeichnis	45
13 Abkürzungsverzeichnis	46

1 Management Summary

Künstliche Intelligenz ist als Schlüsseltechnologie zukünftig auch für den öffentlichen Bereich von Relevanz. Auch die Wiener Stadtverwaltung räumt dieser Technologie einen wesentlichen Stellenwert als Teil der IKT-Strategie ein und möchte konkrete Ansätze und Vorschläge liefern, wie Künstliche Intelligenz dazu beitragen kann, die Lebensqualität in der Stadt Wien weiter zu verbessern.

Die vorliegende KI-Strategie wurde von September 2018 bis Jänner 2019 ausgearbeitet und beschreibt in den Kapiteln 2 und 3 den Wirkungsbereich bzw. legt die strategische Ausrichtung hinsichtlich Künstlicher Intelligenz in der Wiener Stadtverwaltung dar.

Kapitel 4 bis 6 beschreiben die technischen Grundlagen von Künstlicher Intelligenz und befassen sich darüber hinaus mit den zu erwarteten Herausforderungen beim Einsatz von Künstlicher Intelligenz im öffentlichen Bereich, sowie aktuellen Trends und Fortschritten. Um ein Verständnis über den umfassenden Einsatz von Künstlicher Intelligenz in verschiedenen Arbeits- und Lebensbereichen zu bekommen, werden in Kapitel 7 deren Anwendungsgebiete im Detail beschrieben. Um eine reibungslose Implementierung dieser Technologie zu ermöglichen, wird in Kapitel 8 ein mögliches KI-Framework beschrieben, welches den Rahmen für den nachhaltigen Einsatz von Künstlicher Intelligenz liefern soll.

Kern der KI-Strategie ist die Identifizierung, Entwicklung und der Einsatz von konkreten KI-Anwendungsfällen, welche im Rahmen der Erstellung der KI-Strategie auf Basis der in Kapitel 9.1 beschriebenen generischen Anwendungsfälle ausgearbeitet werden. Diese generischen Anwendungsfälle sollen auch als Bausteine für zukünftige Anwendungsfälle verstanden werden und dienen somit der Möglichkeit, selbstständig potenzielle KI-Anwendungsfälle für die Stadt Wien zu identifizieren.

Die Zusammenfassung der Ergebnisse und Darlegung von Handlungsempfehlungen werden in Kapitel 10 beschrieben.

2 Wirkungsbereich

Die KI- Strategie der Wiener Stadtverwaltung richtet sich an alle Organisationseinheiten, die in Wien KI-Projekte durchführen und in den Wirkungsbereich der Wiener Stadtverwaltung fallen. Das sind insbesondere die Dienststellen der Stadt Wien und ihre Unternehmungen.

3 Strategische Ziele auf Ebene der Teilstrategie

3.1 Einordnung der KI-Strategie in die Digitale Agenda

Die KI-Strategie der Wiener Stadtverwaltung ist als Teil der IKT-Strategie zu verstehen und soll den strategischen Rahmen zur Umsetzung von KI-Projekten in der Stadt Wien vorgeben. Das vorliegende Dokument wurde partizipativ unter Einbindung von Expertinnen und Experten, wesentlicher Stakeholder der Stadtverwaltung sowie der interessierten Bürgerinnen und Bürger erarbeitet.

3.2 Vision und Mission

Künstliche Intelligenz hat in den letzten Jahren eine neue Reifephase erreicht und entwickelt sich zum Treiber von Innovation und der Digitalisierung von Systemen in allen Lebensbereichen. Auch die europäische Kommission hat im Jahr 2018 eine Strategie zum Thema Künstliche Intelligenz entwickelt¹ und darin ein Konzept vorgeschlagen, das den Menschen in den Mittelpunkt der KI-Entwicklung stellt („menschenzentrierte KI“). Sämtliche Bereiche der Stadtverwaltung können von Künstlicher Intelligenz profitieren. Der Einsatz erfolgt dabei stets unter Berücksichtigung von ethischen und moralischen Grundsätzen. Die Grundsätze von Wirtschaftlichkeit, Effizienz, Sicherheit, und Nutzen für Bürgerinnen und Bürger sind Voraussetzung für eine erfolgreiche Umsetzung von KI-Projekten.

Wir wollen mit Hilfe des Einsatzes von Methoden der Künstlichen Intelligenz neue Services in der Wiener Stadtverwaltung schaffen und in allen Bereichen bestehende Services effizienter und einfacher für die Bürgerinnen und Bürger gestalten. Die Effizienzsteigerung wird durch die völlig neuen Möglichkeiten der Künstlichen Intelligenz im Bereich der Automatisierung und Prozessunterstützung erreicht.

Durch die Zusammenarbeit mit den Unternehmen und Startups in Wien beim Einsatz von KI-Methoden in der Wiener Stadtverwaltung wird auch der Wirtschaftsstandort Wien weiter gestärkt. Somit kann der Einsatz von KI-Methoden einen wesentlichen Beitrag auf dem Weg Wiens zur digitalen Hauptstadt Europas leisten.

Die hohe Geschwindigkeit bei der Entwicklung von KI-Methoden und Anwendungen bedingt, dass nur jene, die jetzt beginnen Künstliche Intelligenz aktiv einzusetzen, in der digitalen Gesellschaft bestehen werden. Die Gesellschaft, Wirtschaft, Verwaltung und Wissenschaft sind dabei aufgefordert, sich den Chancen und Risiken der KI zu stellen.

¹ ec.europa.eu/newsroom/dae/document.cfm?doc_id=51625

3.3 Strategische Ziele

1. Wir setzen die Potenziale der Künstlichen Intelligenz ein, um die Services für die Bürgerinnen und Bürger nachhaltig zu verbessern und auch neue Services unter Berücksichtigung der Interessen der Bürgerinnen und Bürger zu schaffen.
2. Durch den Einsatz von Künstlicher Intelligenz wird die Benutzerfreundlichkeit der Services für die Bürgerinnen und Bürger erhöht und die Nutzung der Services vereinfacht.
3. Wir setzen auf nachhaltige, wiederverwertbare und universell einsetzbare KI-Basisinfrastrukturkomponenten. Sämtliche Services und Anwendungen sollen prinzipiell Zugang zu diesen KI-Komponenten erhalten und sie in ihre Verarbeitungen integrieren können.
4. Generische Anwendungsszenarien und konkrete Fallbeispiele sind eine Orientierung für den sinnvollen und zweckmäßigen Einsatz von Künstlicher Intelligenz und bieten so eine Grundlage zur Beurteilung von KI-Projekten.
5. Die Stadt Wien wird unter Berücksichtigung der Marktreife der KI-Technologien, Sicherheit, Verfügbarkeit, Stabilität und Funktionalität von KI-Systemen geeignete Anwendungsfälle identifizieren und umsetzen.
6. KI-Kompetenzen werden innerhalb der IKT-Abteilung der Stadt Wien und den Fachabteilungen sukzessive aufgebaut.
7. Durch einen verantwortungsvollen Umgang mit Künstlicher Intelligenz wird sichergestellt, dass Entscheidungen nicht völlig einem Computersystem überlassen werden. Die Entscheidungshoheit liegt in der Verantwortung des Menschen.
8. Wir setzen bei der Weiterentwicklung von KI-Anwendungen auf Kooperationen mit Unternehmen, Startups und Einrichtungen der Forschung und Entwicklung.

4 Künstliche Intelligenz

Künstliche Intelligenz ist ein Teilgebiet der Informatik mit dem Ziel, Maschinen zu befähigen, Aufgaben „intelligent“ auszuführen (Fraunhofer-Gesellschaft, 2018). Fasst man den Begriff weit, so versteht man unter Künstlicher Intelligenz Computersysteme, die zu intelligentem Verhalten fähig sind. Solche Systeme werden also typischerweise nicht nur einprogrammierte Anweisungen abarbeiten, sondern ihr Verhalten unter Berücksichtigung der zur Verfügung stehenden Informationen jeweils an die aktuellen Gegebenheiten anpassen. Häufig spielt dabei Maschinelles Lernen eine wichtige Rolle: Ein System lernt zum Beispiel aus einer Datensammlung aus der Vergangenheit, in welcher jeweils das ideale Verhalten des Systems bekannt ist, wie es sich in Zukunft verhalten soll, wenn eine ähnliche Situation eintritt.

Von praktischer Relevanz sind derzeit nur KI-Systeme, die jeweils auf eine konkrete Aufgabenstellung spezialisiert sind. Hier kommt es auch durchaus vor, dass sie innerhalb dieser Aufgabenstellung menschliche Expertinnen und Experten übertreffen.

4.1 Geschichte der Künstlichen Intelligenz

Bereits in den 1940er-Jahren entstanden Konzepte von Künstlichen Neuronalen Netzen und fanden zehn Jahre später erste Implementierungen. Nach ersten Erfolgen in den 1950er und 1960er-Jahren stagnierte die Forschung und Entwicklung in den 1970er-Jahren aufgrund zu hoher Komplexität und zu langsamer Computer, diese Periode ist auch als erster „KI-Winter“ bekannt. Ein erneuter Aufschwung gelang erst in den 1980er-Jahren durch die Entwicklung von sogenannten Expertensystemen, deren Wissensbasis aus manuell eingegebenen logischen Regeln besteht. Auch hier stellte sich jedoch rasch heraus, dass ein konsistenter Aufbau von Wissensbasen immer schwieriger würde und praktisch niemals alle denkbaren Vorbedingungen für eine Aktion explizit angegeben werden können. Ende der 1980er-Jahre führte dies zum zweiten „KI-Winter“. Fortschritte in der Computertechnologie und die gesteigerte Verfügbarkeit großer Datenmengen ermöglichten um die Jahrtausendwende das Lernen von komplexen Künstlichen Neuronalen Netzen, womit der Erfolg der heutigen Künstlichen Intelligenz eingeleitet wurde (Döbel, et al., 2010, S. 9f).

4.2 Begriffsdefinition

4.2.1 Künstliche Intelligenz

Der Begriff der Künstlichen Intelligenz ist auf unterschiedlichste Art und Weise definiert und interpretiert. John McCarthy, einer der Pioniere der Künstlichen Intelligenz, definierte 1955 als Erster den Begriff mit dem Ziel, „Maschinen zu entwickeln, die sich verhalten, als verfügten sie über Intelligenz“. Scheinbar kom-

plexes Verhalten lässt sich jedoch mit einfachen elektrischen Verschaltungen erzeugen, womit diese Definition nicht ausreichend ist, da sich die Künstliche Intelligenz das Ziel gesetzt hat, viele schwierige praktische Probleme zu lösen, die über einfache Schaltungen hinausgehen.

In der Encyclopedia Britannica ist der Begriff wie folgt definiert: „Künstliche Intelligenz ist die Fähigkeit digitaler Computer oder computergesteuerter Roboter, Aufgaben zu lösen, die normalerweise mit den höheren intellektuellen Verarbeitungsfähigkeiten von Menschen in Verbindung gebracht werden“. Auch diese Definition hat Schwächen, da z.B. einem Computer, welcher einen langen Text speichern und jederzeit abrufen kann bzw. in der Lage ist, komplexe Multiplikationen vorzunehmen, intelligente Fähigkeiten zugestanden werden können.

Elaine Rich und Kevin Knight lösen dieses Dilemma, indem sie Künstliche Intelligenz „als Lehre davon, wie Computer Dinge tun können, in denen Menschen besser sind – wenigstens im Moment noch“ definieren. Auch im Jahr 2050 wird diese Definition immer noch aktuell sein (Ertl, 2016, S. 1ff).

4.2.2 Maschinelles Lernen

Maschinelles Lernen ist aus den Methoden der Statistik und der Künstlichen Intelligenz hervorgegangen und verfolgt das Ziel, aus Daten zu „lernen“ und möglichst treffende Vorhersagen zu generieren. Das Lernergebnis (die gelernte Funktion) wird auch als Modell bezeichnet. Fast alle Modelle, die ML-Verfahren aus Beispielen erzeugen, sind letztlich statistische Modelle, weshalb Statistik ein Fundament für die Theorie des Maschinellen Lernens bildet (Fraunhofer-Gesellschaft, 2018). Das Trainieren der Modelle ist oft mit einem hohen Rechen- und somit Kostenaufwand verbunden. Zwar existieren für manche Zwecke bereits vortrainierte Modelle, auf welche zurückgegriffen werden kann, jedoch eignen sich diese oft nur für spezifische und somit eingeschränkte Anwendungsfälle, z.B. der einfachen Identifikation von Objekten in Bildern.

4.2.3 Künstliche Neuronale Netze und Deep Learning

Das Themengebiet der Künstlichen Neuronalen Netze ist eine Teilmenge des Maschinellen Lernens und verzeichnete ab 2006 enorme Fortschritte, insbesondere in der Analyse von Bild- und Video-, sowie Sprach- und Textdaten. Maschinen mit Künstlichen Neuronalen Netzen können Texte übersetzen, Fragen beantworten, Nachrichten komprimieren und selbst Bilder oder Texte generieren (Döbel, et al., 2010). Innerhalb dieser Künstlichen Neuronalen Netze passiert ein Eingabewert mehrere Berechnungs-Ebenen, um einen Ausgabewert zu generieren. Erforderlich sind dabei mindestens drei Ebenen, um entsprechende Muster aus den Rohdaten zu extrahieren (Reder, 2018). Als besonders erfolgreich haben sich „tiefe“ Netze mit sehr vielen Ebenen herausgestellt, wodurch sich der Begriff „Deep Learning“ etabliert hat.

4.3 Algorithmen des Maschinellen Lernens

Es gibt eine große Zahl von Modelltypen und Algorithmen des Maschinellen Lernens, die jeweils für unterschiedliche Aufgaben geeignet sind. Dieser Abschnitt bietet einen Überblick über Klassifikations- und Regressionsverfahren, instanzbasierte Verfahren, Entscheidungsbäume, Bayessche Modelle, Clustering und Künstliche Neuronale Netze mit Informationen darüber, wie sie jeweils funktionieren und für welche Aufgaben sie sinnvoll eingesetzt werden können. Bei der Auswahl der passenden Algorithmen ist es wesentlich, logisch zu verstehen, welchen Mehrwert diese für den jeweiligen Anwendungsfall bieten und welche Daten dafür benötigt werden.

4.3.1 Klassifikationsverfahren

Bei der Klassifikation werden Objekte anhand übereinstimmender Merkmale in unterschiedliche Klassen eingeteilt, z.B. können so Bilder anhand ihrer Inhalte sortiert werden. Die Anzahl der Klassen kann dabei variieren, so ist es z.B. bei einer Handschrifterkennung für Zahlen notwendig, für jede Ziffer eine Klasse zu bilden. Klassifikationsverfahren entscheiden sich meistens jedoch nicht strikt für eine Klasse des Objekts, sondern sagen diese mit einer gewissen Wahrscheinlichkeit voraus (Zeigermann & Nguyen, 2018, S. 24f).

4.3.2 Regressionsverfahren

Bei Regressionsproblemen ist das Ziel, einen Wert vorherzusagen, sofern eine Kontinuität bei der Ausgabe vorliegt. Zum Beispiel kann mit diesem Verfahren das jährliche Einkommen einer Person anhand des Bildungsgrades, des Alters und des Wohnorts vorhergesagt werden. Mathematisch gesehen unterscheiden sich Regression und Klassifikation nicht sehr stark voneinander, jedoch im Zweck der Anwendung: Bei der Regression sollen stetige Werte vorhergesagt werden, (z.B. die Temperatur einer Maschine), bei der Klassifikation hingegen Klassen unterschieden werden (z.B. die Maschine überhitzt oder überhitzt nicht) (Müller & Guido, 2017, S. 32f).

4.3.3 Instanzbasierte Verfahren

Instanzbasierte Algorithmen vergleichen neue Daten mit bereits vorher antrainierten, welche als wichtig angesehen werden. Typischerweise werden dabei neue Daten mit zuvor in einer Datenbank abgelegten Beispieldaten verglichen und der Datensatz mit der größten Ähnlichkeit zur Klassifizierung verwendet. Man nennt diese Algorithmen daher auch „Winner takes all“-Methoden, da hier nur der ähnlichste Datensatz zur Klassifizierung reicht. Unterschiede in den Algorithmen bestehen hier in der Ähnlichkeitsmessung, eine Art Abstandsmessung zwischen den Ereignissen (Kropp & Töbel, 2017, S. 16).

4.3.4 Entscheidungs bäume

Ein Entscheidungsbaum dient der Aufteilung von Objekten anhand geeigneter Merkmale in Gruppen hinsichtlich einer vorgegebenen Zielgröße. Der Entscheidungsgraph hat dabei eine baumartige Struktur mit einer Wurzel, mehreren inneren Knoten und Endknoten. Will man ein Objekt mit einem Entscheidungsbaum klassifizieren, so startet man an der Wurzel und ordnet das Objekt so lange an den inneren Knoten einer neuen Unterteilung zu, bis das Objekt durch einen Endknoten eindeutig klassifiziert wird. In der Praxis wird dieser Algorithmus häufig bei der Reaktionsanalyse von Werbemitteln, bei der Wirksamkeitsprüfung von Medikamenten oder bei der Kreditwürdigkeitsprüfung von Bankkunden angewendet (Bankhofer & Vogel, 2008, S. 273).

4.3.5 Bayes-Klassifikatoren

Bestimmte Algorithmen und Methoden verwenden für Klassifikation und Regression den Satz von Bayes. Dieser beschreibt die Wahrscheinlichkeit des Eintretens eines Ereignisses, basierend auf dem Zusammenspiel unabhängiger Ereignisse (Kropp & Töbel, 2017). Bayes-Klassifikatoren kommen z.B. bei der Identifikation von unerwünschten E-Mails zum Einsatz. Mithilfe von Trainingsdaten lernt der Algorithmus, die Klassen „erwünscht“ und „unerwünscht“ zu definieren und ermittelt im Anschluss die relativen Häufigkeiten von Begriffen und Phrasen, die oft in sogenannten Spam-E-Mails vorkommen. Kommen z.B. die Begriffe „Geld“ und „reich“ mehrfach in einer Nachricht vor, ist die Wahrscheinlichkeit hoch, dass es sich um Spam handelt. Enthält der Text hingegen den Begriff „Geld“ und Spam-unübliche Wörter wie z.B. „Schließfach“, ist die Wahrscheinlichkeit hoch, dass es sich nicht um eine unerwünschte Nachricht handelt.

4.3.6 Clustering

Clustering ist ein Beispiel für unüberwachtes Lernen, d.h. ein System erzeugt Informationen über einen Datensatz, für den keine „richtigen“ Antworten (wie z.B. die Zuordnung der einzelnen Datenpunkte zu Kategorien) vorliegen. Dabei wird eine automatische Kategorisierung der Daten vorgenommen und diese in zusammenhängende Gruppen bzw. Haufen („Cluster“) sortiert, ohne diese Gruppen vorher zu definieren. Erst die Interpretation der Gruppen erfordert menschliches Zutun (Zeigermann & Nguyen, 2018, S. 28f).

4.3.7 Künstliche Neuronale Netze

Künstliche Neuronale Netze (KNN) bestehen aus Schichten von Knoten, die als künstliche Neuronen bezeichnet werden. Die Verbindungen zwischen den Neuronen sind als Zahlenwerte bzw. Gewichte dargestellt und werden beim „Lernen“ des Neuronalen Netzes so lange verändert, bis die Ausgaben gut genug sind (Döbel, et al., 2010, S. 11). Jeder Knoten (Neuron) besitzt eine Aktivierungsfunktion, die entscheidet, ob und wie der Knoten die Signale (Zahlen) weiterleitet, die er selbst von seinen Vorgängern erhalten hat.

KNNs können dabei aus hunderten von Schichten und Milliarden von zu lernenden Gewichten bestehen und so komplizierte mathematische Funktionen approximieren. Im Vergleich zu anderen Algorithmen werden bei KNNs sehr große Datenmengen benötigt, um sie sinnvoll anwenden zu können (Hecker, Dr., et al., 2017, S. 8f).

4.4 Lernstile des Maschinellen Lernens

Bei maschinellen Lernverfahren können Lernstile unterschieden werden, die für verschiedenste Zwecke geeignet sind. Eingeteilt werden die Lernstile dabei in „Überwachtes Lernen“, „Unüberwachtes Lernen“, „Teilüberwachtes Lernen“ und „Bestärkendes Lernen“.

4.4.1 Überwachtes Lernen

Beim überwachten Lernen wird der Algorithmus mit Hilfe von bekannten Ergebnissen trainiert, um eine Abbildungsfunktion zwischen den Eingabe- und den Ausgabedaten zu erstellen. Der Trainingsdatensatz enthält dabei bereits bekannte Datensätze und die zugehörigen vorherzusagenden Ergebnisse. Das trainierte Modell wird im Anschluss auf neue Datensätze angewendet, um eine Vorhersage zu erstellen.

Beim überwachten Lernen gibt es dabei zwei Arten der Auswertung: Klassifikation und Regression. Ergebnis der Klassifikation sind passende und frei wählbare Kategorien, wohingegen bei der Regression als Ergebnis ein kontinuierlicher und reeller Wert ausgegeben wird (Kropp & Töbel, 2017).

4.4.2 Unüberwachtes Lernen

Beim unüberwachten Lernen muss das System versuchen, ohne Anleitung zu lernen, da die Trainingsdaten nicht gekennzeichnet sind oder eine unbekannte Struktur besitzen. Ziel ist es, diese unbekannte Struktur herauszufinden, um unbekannte Zusammenhänge zu entdecken (Dörn, 2018, S. 18). Der bekannteste Anwendungsfall dieser Methode ist das Clustering, bei welchem z.B. Personen anhand Ihrer bekannten Eigenschaften segmentiert werden können, ohne die Segmente vorher genau zu definieren (z.B. klein, mittel und groß bei Kleidergrößen). Ein weiterer Fall wäre das Clustering von Dokumenten nach Ihren Inhalten, ohne vorher Kategorien zu benennen.

4.4.3 Teilüberwachtes Lernen

Oft besteht das Problem, dass im Verhältnis zur Gesamtdatenmenge zu wenig gekennzeichnete Daten zur Verfügung stehen und es somit nicht möglich ist, ein repräsentatives und ausgeglichenes Modell zu erstellen und mittels Überwachtem Lernens zu trainieren. Teilüberwachtes Lernen kann hier Abhilfe schaffen, da mit diesem Lernverfahren ein kleiner Teil gekennzeichneter Daten für das Training verwendet werden kann und die nichtgekennzeichneten Daten dafür verwendet werden, die Genauigkeit des Modells zu ver-

bessern (Bonaccorso, 2018, S. 19f). Als Beispiel wird Teilüberwachtes Lernen bei der Sentimentanalyse angewandt, um einen Text nach dessen Stimmungslage (z.B. positiv oder negativ) zu bewerten. Somit können nichtgekennzeichnete Sätze aufgrund ihrer Ähnlichkeit zu gekennzeichneten Sätzen dennoch zur Verbesserung des trainierten Modells beitragen.

4.4.4 Bestärkendes Lernen

Da man oft nicht weiß, was richtig oder falsch ist, um zum gewünschten Ergebnis zu kommen, können die Daten oft auch nicht entsprechend gekennzeichnet werden. Für eine solche Problemstellung werden Methoden aus dem Bereich des Bestärkenden Lernens angewandt, welche immer mit agentenbasierten Ansätzen verknüpft werden. Der Agent (eine Software, welche bestimmte Operationen mit einem gewissen Grad an Unabhängigkeit ausführt) erhält eine kontinuierliche Rückmeldung in Form einer Belohnung bzw. Bestrafung, wodurch er über den zeitlichen Verlauf eine (möglichst) optimale Strategie lernen soll, um das Problem zu lösen (Frochte, 2018, S. 23f).

Mit dieser Methode könnte der Agent z.B. selbstständig lernen, Schach zu spielen, indem jeder von ihm getätigte Zug nach vordefinierten Kriterien mit „gut“, „schlecht“ oder „neutral“ bewertet wird und so konstant die Fähigkeiten des Agenten verbessert.

5 Herausforderungen beim Einsatz von Künstlicher Intelligenz

Im Vergleich zur klassischen Programmierung gibt es beim Maschinellen Lernen als datengestützte Technologie andere Herausforderungen. Je mehr Trainingsdaten zur Verfügung stehen, desto besser ist das Modell und desto geringer dessen Fehlerquote. Gleichzeitig müssen die Ausgangsdaten von hoher Qualität und unvoreingenommen sein.

Schwierigkeiten bestehen weiters darin, das Modell allgemein genug zu halten, damit es auch mit unbekanntem Daten, welche nach der Trainingsphase entstanden sind, umgehen kann. Ebenso müssen die Modelle robust sein, d.h. auf ähnliche Eingaben eine ähnliche Reaktion liefern (Döbel, et al., 2010).

5.1 Datenhandhabung

Die voranschreitende Digitalisierung der Arbeit und des Privatlebens ermöglicht heutzutage eine erhöhte Datenverfügbarkeit hinsichtlich der Quantität, der Qualität, der Datentypen, des Zugriffs und der Tatsache, dass Massendaten miteinander verbunden werden können. Die Stadt Wien verfolgt im Rahmen der Data Excellence Strategie das Ziel, verlässliche Informationen und Daten als zentralen Wert einer offenen Verwaltung der Zukunft zur Verfügung zu stellen. Ein Enterprise Data Management, Datenqualitätsmanagement und eine organisationsweite Data Governance bilden hierfür die Grundsäulen.

Die Handhabung dieser Datenmengen erfordert eine Vielzahl von Teilkompetenzen von Datenakquise und -aufbereitung bis Datenanalyse und -visualisierung und folgt in der gängigen Praxis dem CRISP-DM (Cross-Industry Standard Process for Data Mining).

CRISP-DM Phasen:

- **Business Understanding (Geschäftsverständnis):** Festlegung der Ziele und Anforderungen; Ableitung der konkreten Aufgabenstellung und der groben Vorgehensweise
- **Data Understanding (Datenverständnis):** Datensammlung bzw. erste Sichtung der zur Verfügung stehenden Daten; Ermittlung möglicher Probleme mit der Datenqualität
- **Data Preparation (Datenvorbereitung):** Erstellung des finalen Datensatzes für die Modellierung
- **Modeling (Modellierung):** Anwendung geeigneter Data Mining-Verfahren, Optimierung der Parameter; gewöhnlich Ermittlung mehrerer Modelle
- **Evaluation (Evaluierung):** Auswahl des Modells, das die Aufgabenstellung am besten erfüllt. Sorgfältiger Abgleich mit der Aufgabenstellung
- **Deployment (Bereitstellung):** Aufbereitung und Präsentation der Ergebnisse; evtl. Integration des Modells in einen Entscheidungsprozess des Auftraggebers (Seiter, 2017, S. 3ff).




Abbildung 1: CRISP-DM Prozess

5.2 Datenqualität

Die Qualität der Trainingsdaten bestimmt weitgehend die Qualität des Modells. Werden dem Algorithmus z.B. zu viele falsche Beispiele gezeigt, kann er daraus nicht die richtigen Antworten lernen (Döbel, et al., 2010). Eine hohe Qualität der Trainingsdaten wird u.a. durch folgende Maßnahmen gewährleistet:

- Unterschiedliche oder falsche Schreibweisen von Namen oder Begriffen stellen eine potentielle Fehlerquelle dar, die es zu vermeiden gilt.
- Gut strukturierte und standardisierte Daten bilden die Grundlage für einen sinnvollen Einsatz von Künstlicher Intelligenz.
- Je nach Anwendungsfall werden mehr oder weniger Daten benötigt, damit relevante Muster identifiziert und entsprechende Schlussfolgerungen getroffen werden können.
- Duplikate von Datensätzen führen zu verzerrten Ergebnissen, somit müssen die Daten vorab gesäubert werden.
- Daten sind meist auf eine Weise zeitbezogen. Veraltete Daten sollten daher nicht mit einbezogen werden, falls z.B. Vorhersagen auf zukünftige Ereignisse getroffen werden sollen.

- Daten erfordern vorab meist eine händische Annotation bzw. Kategorisierung durch Domänenexperten und Experten, um die Qualität des Ergebnisses zu erhöhen.
- Stamm- und Bewegungsdaten aus verteilten Systemen (z.B. CRM-, Ticketing- oder ERP-Systeme) sollen möglichst zusammengeführt werden.

5.3 Unvoreingenommenheit der Ausgangsdaten

Die Leistungsfähigkeit heutiger KI-Systeme basiert wesentlich auf der Quantität und Qualität der verfügbaren Daten. Ein wichtiger zu berücksichtigender Faktor ist jedoch, dass KI-Systeme bestehende Diskriminierungen in den Datensätzen reproduzieren. Wenn sich beispielsweise in historischen Daten zeigt, dass Männer häufiger Führungspositionen eingenommen haben als Frauen, kann dies ein KI-System zu der falschen Schlussfolgerung verleiten, dass Männer für solche Positionen grundsätzlich besser geeignet seien. Die Systeme selbst können allerdings keine Auskunft über die Voreingenommenheit der zugrundeliegenden Daten geben. Selbst bei unzureichender Datengrundlage werden sie immer ein Ergebnis erzeugen, auch wenn dieses nicht aussagekräftig ist. Dazu kommt erschwerend, dass subtilere Formen datenbasierter Diskriminierung nur schwer zu erkennen sind, z.B. wenn andere Faktoren mit dem Geschlecht korrelieren und so einen Einfluss auf das Ergebnis haben. Je weniger offensichtlich diese Korrelation ist, umso schwieriger wird es, sie allein an den Ergebnissen abzulesen (Dickow & Jacob, 2018, S. 5ff). Daher sollten folgende Aspekte der Unvoreingenommenheit gewährleistet sein:

- KI-Systeme sollten so gestaltet sein, dass sie offenlegen, wie repräsentativ die Trainingsdaten für die reale Datenanwendung sind und mit welcher Fehlerquote die Analyse behaftet ist.
- Speziell bei Kundendaten muss gewährleistet sein, dass diese objektiv sind und die Quelldaten geografisch und kulturell unbefangen sind und der jeweiligen Zielgruppe entsprechen.
- Oft dienen Daten einer bestimmten Agenda. Es muss somit sichergestellt sein, dass die Datenquelle renommiert, vertrauenswürdig, glaubwürdig und nicht tendenziös ist.
- Domänenwissen: Es sollte verständlich sein, wie Daten gesammelt wurden und welche Methoden (z.B. bei Marktforschung) dabei angewandt wurden. Bei schlechter Konstruktion eines Fragebogens wird auch die Qualität der Daten gering sein.

5.4 Nachvollziehbarkeit der Entscheidungen

Die Nachvollziehbarkeit der Entscheidungen eines Modells kann eine große Herausforderung darstellen. Bei Entscheidungsbäumen lässt sich diese sehr leicht herstellen, tiefe Neuronale Netze hingegen bieten wenig Nachvollziehbarkeit (Döbel, et al., 2010). Soll eine KI zum Beispiel lernen, Katzen und Hunde anhand von Bildern zu unterscheiden, sind die Motive des Trainingsdatensatzes in der Regel eindeutig als Katzen oder Hunde gekennzeichnet. Die KI „kennt“ sozusagen die richtige Antwort, aber nicht den Weg, diese zu

erlangen. Selbst wenn die KI in der Lage ist, die Bilder richtig und zuverlässig zuzuordnen, ist immer noch nicht klar, worauf diese Zuordnung beruht. Während Menschen einen Hund an seinem typischen Aussehen erkennen, legt eine KI ihrer Zuordnung möglicherweise das Auftreten bestimmter Farbkontraste oder Bildkanten zugrunde, die Menschen gar nicht wahrnehmen. Ein Weg um dieses Verfahren der Bilderkennung transparenter zu gestalten, besteht zum Beispiel darin, Bildelemente hervorzuheben, welche zu einer bestimmten Klassifizierung geführt haben.

Mutet dies bei der Erkennung von Katzen und Hunden relativ harmlos an, ist es in vielen Anwendungsfällen von entscheidender Bedeutung, die Gründe aus denen eine KI zu einem bestimmten Ergebnis kommt, nachvollziehen und kritisch hinterfragen zu können. Die Entwicklung transparenter und nachvollziehbarer KI-Verfahren ist auch über die hier als Beispiel verwendete Bilderkennung hinaus in vielen Bereichen eine Voraussetzung für den sicheren Einsatz von KI (Otto & Gräf, 2018).

Die Nachvollziehbarkeit eines Modells steht oft in einem Zielkonflikt mit dessen Komplexität. Ein lineares Modell bildet einfache Zusammenhänge ab und ist somit leicht zu erklären, jedoch begrenzt die Simplizität gleichzeitig den Anwendungsbereich. Viele Problemstellungen folgen komplexeren Regeln und werden mittels Neuronalen Netzen mit hoher Abstraktion modelliert. Schwierige Probleme können so erfolgreich gelöst werden, gleichzeitig sinkt aber die Durchschaubarkeit der Lösungsfindung.

5.5 Ethik und Risiken der Künstlichen Intelligenz

Die Gesellschaft befindet sich in einem Transformationsprozess, welcher durch die Digitalisierung und im Speziellen die Möglichkeiten der Künstlichen Intelligenz wesentlich beeinflusst wird, und dessen Geschwindigkeit und Ende nicht bekannt ist. Aus heutiger Sicht kann davon ausgegangen werden, dass menschliche Arbeit nicht komplett durch Computer ersetzt werden kann, manche Tätigkeiten und Berufe jedoch zunehmend durch maschinelle Automatisierung ersetzt werden. Die Betrachtung von ethischen Fragen in diesem Zusammenhang bekommt somit eine immer größere Bedeutung.

Ausgehend von Überlegungen darüber, was alles unter "Moral" verstanden werden kann und wie dieser Begriff im Rahmen der Ethik bestimmt wird, werden zwei Bereiche untersucht, in denen ethische Überlegungen für die "Künstliche Intelligenz" bedeutsam sind, nämlich einerseits die Konsequenzen, die sich für Menschen ergeben, wenn sie mit Computersystemen umgehen, die als "intelligent" gelten, andererseits aber Fragen der Verantwortung, die sich beim Einsatz solcher Systeme stellen.

Wesentliche Fragen in dem Zusammenhang wurden bereits von Joseph Weizenbaum 1979 in „Once More: The Computer Revolution“ thematisiert:

- I. Welche Menschen sind die Nutznießer des vielpropagierten technischen Fortschritts, und welche Menschen sind seine Opfer?

- II. Welche Beschränkungen sollten die Menschen im Allgemeinen sowie die Wissenschaftler und Techniker im Besonderen dem Einsatz von Computern mit Rücksicht auf menschliche Belange auferlegen?

Unabhängig vom ersten Punkt bezieht sich Weizenbaums Forderung auch darauf, dass bestimmte kognitive Vorgänge (insbesondere Vorgänge, welche die Analyse und Bewertung komplexer Situationen und darauf aufbauende Entscheidungen mit weitreichenden Konsequenzen betreffen) nicht völlig einem Computersystem zu überlassen sind, wie perfekt dieses auch immer sein mag, sondern dass Computer von Menschen nur als Werkzeuge zu verwenden sind, die ihnen erlauben, eine komplexe Situation besser, umfassender und schneller zu analysieren, dass aber die eigentliche Bewertung der Situation ebenso wie alles Entscheiden und Handeln in der Hand bzw. im Geist von Menschen bleibt (Neumaier, 1994, S. 41-64).

Die Überlegungen zu Verantwortung und Ethik von Weizenbaum wurden in den strategischen Zielen in Kapitel 3.3 und Handlungsempfehlungen in Kapitel 10 dieser KI-Strategie berücksichtigt.

6 Trends und Fortschritte der KI

Laut einer Studie von Gartner (Andrews & Herschel, 2017) werden bereits im Jahr 2020 40% aller in Unternehmen neu implementierte Applikationen KI-Technologie verwenden. Diese Applikationen werden vorrangig im Bereich der interaktiven Chatbots bzw. der modernen Analytik zum Einsatz kommen, überall dort wo eine große Menge an Daten vorhanden ist und der Einsatz von KI in der Automatisierung, bei Empfehlungssystemen und beim Treffen von Entscheidungen wesentliche Verbesserungen bringen wird. Die Umsetzung erfolgt dabei entlang von bestehenden Businessprozessen, indem stückweise einzelne Prozessschritte durch KI übernommen werden. Dieser Vorgang wird wesentlich durch drei erwartete Trends geprägt werden:

1. Fortschritte bei der Verarbeitung natürlicher Sprache werden die Nutzung von KI-basierten Applikationen wesentlich vereinfachen.
2. Eine breite Integration von KI in bestehende Applikationen und die gleichzeitig erhöhte Verfügbarkeit von Daten aus dem Internet der Dinge werden zur Verbesserung von Businessprozessen beitragen.
3. KI-basierte Applikationen und Systeme werden miteinander agieren und so in Kooperation die gewünschten Ziele verfolgen (Andrews & Herschel, 2017, S. 2ff).

Während bei Expertensystemen noch die gesamte Wissensbasis manuell konstruiert werden musste, reicht beim Maschinellen Lernen lediglich die sorgfältige Auswahl der Merkmale. Neuronale Netze lernen in ihren verdeckten Schichten automatisch abstraktere Repräsentationen und erledigen die Merkmalswahl gleich selbst mit (Hecker, Dr., et al., 2017, S. 10). Ermöglicht werden diese Fortschritte durch die Entwicklung von verbesserten Algorithmen, die steigende Verfügbarkeit großer Datenmengen und durch die Bereitstellung von ausreichender Rechenleistung zur Verarbeitung.

Auch das „Internet der Dinge“ (Internet of Things, IoT) sollte im engen Zusammenhang mit der Entwicklung im Bereich der Künstlichen Intelligenz betrachtet werden. Die vernetzten Dinge liefern Daten in einem bislang ungekannten Maße und umgekehrt wird erst eine intelligente Auswertung und Steuerung von Datenprozessen durch den Einsatz von KI dem IoT zum Durchbruch verhelfen. Seit die Kosten für KI und Sensoren signifikant sinken und die Anwendungsreife gleichzeitig zunimmt, wird die Wechselwirkung zwischen KI und IoT immer offensichtlicher (Tiedemann, 2018).

Die heute eingesetzten Systeme werden dabei der „schwachen KI“ zugeordnet, da diese meist nur ein spezifisches Problem lösen können und individuell für eine Aufgabe optimiert wurden. „Starke KI“ hingegen verspricht eine flächendeckende Anwendung und würde Aufgaben ähnlich wie ein Mensch erfassen und lösen, jedoch ist heute umstritten, ob dies jemals der Fall sein wird (Cearley, Burke, Searle, & Walker, 2017,

S. 4f). Aktuell wird an einer neuen Generation von KI-Systemen geforscht, welche Expertenwissen nutzen und abstrahieren können, damit sie robuster, breiter anwendbar und selbsterklärend werden (Hecker, Dr., et al., 2017, S. 6).

7 Anwendungsgebiete der KI

Die Einsatzgebiete von Künstlicher Intelligenz sind vielfältig. Die Systeme können eher autonom oder eher unterstützend und kooperativ agieren und sind in der Regel in Prozesse der physischen Welt eingebettet, oder in digitale Umgebungen eingebunden. Auf KI basierte Dienste können Wissens- oder Sacharbeiten automatisieren, vorausschauen, überwachen oder auch Maßnahmen vorschlagen (Hecker, Dr., et al., 2017, S. 8). Dieses Kapitel gibt einen groben Überblick über die derzeit wichtigsten Anwendungsgebiete Künstlicher Intelligenz.

7.1 Maschinelle Verarbeitung natürlicher Sprache (Natural Language Processing)

Natural Language Processing (NLP) ist eine Technologie, die zum Ziel hat, menschliche Sprache mit Computern zu verarbeiten. Grundlage ist dabei, dass jegliche Form von Sprache, gesprochen oder geschrieben, von der KI auf einer für den jeweiligen Anwendungsfall adäquaten Ebene „verstanden“ werden muss. Wichtig ist dabei nicht nur das jeweils einzelne Wort, sondern sein Zusammenhang mit anderen Wörtern, ganzen Sätzen oder Sachverhalten. Um dies zu ermöglichen, erkennt das System allgemeine Muster, mit deren Hilfe es zum Beispiel komplexe Zusammenhänge verstehen und Fragestellungen beantworten kann.

Programme, aus dem Bereich NLP betrachten beispielsweise folgende Problemstellungen (Ryte Wiki, 2018):

- Kategorisierung von Textdokumenten
- Extraktion von Information aus Textdokumenten
- Übersetzung von Texten in andere Sprachen
- Sentiment-Analyse von Texten
- Vereinfachen von Text
- Text in gesprochene Sprache umwandeln (Text-to-speech, Sprachsynthese)
- Gesprochene Sprache in Text umwandeln (Speech-to-text, Spracherkennung)
- Such-Anfragen in natürlicher Sprache verstehen
- Erweiterte Fragen und Folgefragen erkennen
- Plausibilität von Antworten prüfen
- Antworten in Form von Text bereitstellen

7.2 Kognitive Assistenten

Unter kognitiven Assistenten werden Assistenzsysteme verstanden, die in Form von Text oder Stimme mit dem Nutzer kommunizieren und Menschen bei der Ausführung kognitiver Aufgaben und Entscheidungs-

findungen unterstützen bzw. ersetzen sollen. Diese Systeme sind lernend, kooperativ und überwiegend digital und sie verwenden typischerweise eine oder mehrere der im vorherigen Kapitel behandelten NLP-Technologien. Der Begriff „Kognitive Assistenten“ wird dabei als Synonym für virtuelle, intelligente, kognitive Assistenten, intelligente und virtuelle Agenten, (Chat)Bots, Smarte Assistenz, Cognitive Computing oder Companion Systems verwendet.

Kognitive Assistenten existieren sowohl im privaten, als auch im gewerblichen Gebrauch und lassen sich in digitale Assistenten (z.B. Apple Siri, Amazon Alexa oder IPSoft Amelia) sowie Assistenzsysteme zur Entscheidungsunterstützung (intelligente Anwendungen, die bei spezifischen Aufgaben in Echtzeit Entscheidungshilfen bieten) unterscheiden. Als Sprachtechnologien sind insbesondere relevant:

- Speech-to-text
- Text-to-speech
- Sprachinterpretation und Sprachverarbeitung (Reagieren auf gesprochene oder geschriebene Sprache)
- Wissensrepräsentation (Organisation, Kategorisierung und Kontextualisierung sprachlicher Information)
- Dialog (Austausch komplexer Äußerungen in einer Unterhaltung)
- Sprechererkennung (Identifikation des Sprechers)

Lernende Assistenten werden mit historischen Dialogen trainiert und dadurch kontinuierlich verbessert. Dabei kann die Verfügbarkeit von Lerndaten in der jeweiligen Sprache eine technische Herausforderung darstellen, falls vorhandene Daten nicht ausreichend strukturiert sind bzw. aus rechtlichen Gründen nicht verwendet werden dürfen. Auch die Nutzerakzeptanz ist neben dem technologischen Fortschritt als Voraussetzung für die Verbreitung dieser Systeme zu betrachten (Hecker, Dr., et al., 2017, S. 36f).

7.3 Computer Vision

Computer Vision (Maschinelles Sehen) beschreibt die Fähigkeit von Systemen, Objekte, Szenen und Aktivitäten in Bildern und Videos zu identifizieren. Dabei werden komplexe Bildanalyseaufgaben in einzelne Kanten, Linien und Texturen von Objekten zerlegt, um zu bestimmen, ob die in einem Bild identifizierten Merkmale mit einer gewissen Wahrscheinlichkeit ein Objekt darstellen, welches dem System bereits bekannt ist. Maschinelles Sehen kommt bei unterschiedlichen Anwendungen zum Einsatz, z.B. zur Diagnose von Krankheiten, zur Gesichtserkennung oder zu Sicherheits- und Überwachungszwecken (Gentsch, 2017, S. 39). Computer Vision ist eines jener Anwendungsgebiete, welches besonders stark von den aktuellen Entwicklungen im Bereich Künstlicher Neuronaler Netze (Deep Learning) profitieren.

7.4 Intelligente Entscheidungsunterstützung

Bereits in den 1980er und 1990er Jahren wurden Expertensysteme als Vorfahren der intelligenten Entscheidungsunterstützung entwickelt, diese waren jedoch aufgrund der nicht vorhandenen Datenmengen bzw. der technischen Möglichkeiten stark limitiert. Die heute zur Verfügung stehenden Algorithmen ermöglichen Entscheidungsunterstützung z.B. in der Medizin oder im Rechtswesen und unterstützen dort Menschen bei der Diagnostik oder bei der Auffindung von Präzedenzfällen (Bitkom, 2017, S. 35).

Insbesondere mit Künstlichen Neuronalen Netzen trainierte Entscheidungsmodelle erfordern Transparenz und Nachvollziehbarkeit, was nicht ohne Weiteres gegeben ist. Um Ungleichbehandlungen und Diskriminierungen zu vermeiden, muss sichergestellt sein, dass die zum Trainieren von lernenden Systemen verwendeten Daten repräsentativ sind. Ebenso muss darauf geachtet werden, dass KI-Anwendungen die Sensitivität für bestimmte Kontexte fehlt, insbesondere wenn es zu unvorhergesehenen Fällen kommt, auf welche die Anwendungen nicht trainiert wurden (Djeffal, 2018, S. 8).

7.5 Business Analytics

Das Ziel von Business Analytics ist es, Problemstellungen im gesamten Managementzyklus von Planung, Steuerung und Kontrolle evidenzbasiert zu lösen. Unter Evidenzen werden dabei begründete und objektive Einsichten in einen Sachverhalt verstanden, welche von Daten aus verschiedensten Bereichen innerhalb und außerhalb einer Organisation mittels Algorithmen aus den Bereichen Statistik, Data Mining und Machine Learning gewonnen werden. Die mithilfe von Business Analytics lösbaren Problemstellungen und deren jeweilige Datenbasis sind dabei in einer Vielzahl von Bereichen innerhalb einer Organisation vorhanden, wie anhand einiger Beispiele verdeutlicht werden kann (Seiter, 2017, S. 1ff):

- Erstellung von Prognosen der zukünftigen Bevölkerungsentwicklung einzelner Städte oder Stadtteile.
- Evaluierung der Nachfrage nach bestimmten Services basierend auf Daten aus sozialen Medien bzw. internen ERP-Systemen.
- Überprüfung, ob die Eigenschaften einer Stellenkandidatin oder eines Stellenkandidaten mit den bereits in der Organisation arbeitenden Personen übereinstimmen, um die Stelle bestmöglich zu besetzen.
- Vorhersage des Verkehrsaufkommens für verschiedene Wochentage bzw. Uhrzeiten.

7.6 Roboter und Sensoren

In der industriellen Fertigung sind Roboter bereits seit den 1970er-Jahren im Einsatz und führen seitdem in einer gesicherten und strukturierten Umgebung repetitive Tätigkeiten aus. Während Roboter der ersten

Generation noch strikt von Menschen getrennt waren, sind moderne Roboter sicherer, selbstständiger, flexibler und können als autonome Roboter auch ihre Umgebung wahrnehmen und ihr Verhalten entsprechend anpassen. Das autonome Handeln von Robotersystemen ist dabei maßgeblich den Methoden der Künstlichen Intelligenz zu verdanken, da sie dadurch ihre Umgebung laufend mit bekannten Daten und Mustern abgleichen und so eigenständig neues Wissen generieren und auf Basis dessen Entscheidungen treffen.

Grundsätzlich kann der Markt für Robotik in Industrierobotik und Servicerobotik eingeteilt werden. Im industriellen Umfeld übernehmen Roboter zunehmend in Kombination mit Menschen komplexere Aufgaben, Serviceroboter führen außerhalb der industriellen Produktion teil- oder vollautomatisiert Dienstleistungsaufgaben zum Nutzen menschlichen Wohlbefindens durch (z.B. Staubsaugen, Rasenmähen oder Pool-Reinigung).

Die Kooperationsmöglichkeiten zwischen Menschen und Robotern werden dabei durch Fortschritte im Bereich der Sprach- und Gestensteuerung laufend erweitert. Als Herausforderungen gelten zukünftig u.a. fehlende Akzeptanz, optimierungsbedürftige Entwicklungsschritte und eine sichere Mensch-Maschine-Interaktion (Hecker, Dr., et al., 2017, S. 12ff).

7.7 Robotic Desktop bzw. Process Automation & Cognitive Computing

Neben mechanischen Aufgaben können Roboter mittlerweile auch administrative Tätigkeiten übernehmen. Die Technologie Robotic Desktop Automation (RDA) arbeitet anhand vorab definierter Interaktionen zwischen Computer und Mensch und eignet sich insbesondere für dezentrale Anwendungen auf einzelnen Desktops, beispielsweise die Änderung von Stammdaten oder Bewegungsdaten in einem bzw. über mehrere Systeme. Die RDA-Software ist dabei jedoch nicht in der Lage, selbstständig Lösungen für einzelne Problemstellungen zu erarbeiten, auch geschieht die Initiierung der Arbeitsschritte durch Mitarbeiterinnen und Mitarbeiter. Die Anwendungsfälle sind dabei visuell sichtbar, kommen meist häufig vor und weisen eine geringe Komplexität auf.

Einen Schritt weiter geht Robotic Process Automation (RPA). Diese Technologie unterscheidet sich von RDA vorrangig durch die nicht notwendige Sichtbarkeit der automatisierten Prozesse am Monitor, die größere technische Integrationstiefe und den nicht erforderlichen manuellen Auslöser. RPA nimmt somit teil- bzw. vollautomatisiert die Bearbeitung von strukturierten Anwendungen vor und zeichnet die Tätigkeiten gleichzeitig revisions- und prüfungssicher auf.

Künstliche Intelligenz kommt erst im Bereich des Cognitive Computing (CC) zum Einsatz. CC ist in der Lage, Aufgaben ohne vorab definierte Abläufe zu lösen und kann so durch Erfahrungen und neu hinzugewonnenes Wissen Entscheidungen treffen und Lösungsansätze selbstständig generieren. Die Technologie ist

somit nicht auf strukturierte Prozesse oder Daten angewiesen und kann z.B. auch Bilder oder Sprache verarbeiten. Anwendung findet CC somit bei spezifischen, komplexen und anspruchsvollen Funktionen und Aufgaben (Alexander, Haisermann, Schabicki, & Frank, 2018, S. 12f).

7.8 Autonome Transportmittel

Autonome Transportmittel umfassen Vehikel mit verschiedenen Automatisierungsgraden, die mit reduzierter oder gänzlich ohne menschliche Intervention navigieren bzw. operieren können. Dabei werden verschiedene Stufen unterschieden, deren Basis die Aufgaben des Systems sowie die Notwendigkeit des Eingreifens eines menschlichen Fahrers bilden. Diese sind:

- Stufe 0: Selbstfahrer
- Stufe 1: Assistent
- Stufe 2: Teilautomatisiert
- Stufe 3: Hochautomatisiert
- Stufe 4: Vollautomatisiert
- Stufe 5: Fahrerlos

Im Bereich des Individualverkehrs existieren für Stufe 1 bereits Lösungen am Markt, die Stufen 2-5 sind aktuell stark im Fokus der Forschung. Derzeit wird damit gerechnet, dass im Jahr 2025 Stufe 5 erreicht wird. Das Potential am Mobilitätssektor ist enorm, neben autonomen PKWs stehen insbesondere autonome LKWs und Landmaschinen im Fokus der Entwicklung (CPS.HUB NRW, 2018, S. 15f).

Fahrerlose U-Bahnen sind in zahlreichen Städten der Welt bereits etabliert und auch die in Wien derzeit im Bau befindliche U5 wird fahrerlose Züge einsetzen. Auch ein autonomer Autobus wird 2019 in der Wiener Seestadt eingeführt.

8 KI-Framework

Zum jetzigen Stand der Technik gibt es kein Werkzeug, welches sämtliche KI-Problemstellungen umfassend lösen kann. Je nach Aufgabenstellung kommen unterschiedliche Werkzeuge und Methoden zum Einsatz. Aus diesem Grund empfiehlt sich ein KI-Framework als Rahmen, um KI umfassend in einer Organisation bzw. Unternehmen einzuführen. Das KI-Framework hilft, die Entstehung von Insellösungen und einzelnen KI-Anwendungsfällen, die nicht in eine ganzheitliche Wertschöpfungskette eingebunden sind, zu vermeiden. Das KI-Framework bietet zudem ein Vorgehensmodell zur Umsetzung von KI-Anwendungsfällen.

8.1 KI-Framework nach Gartner

A Framework for Applying AI in the Enterprise

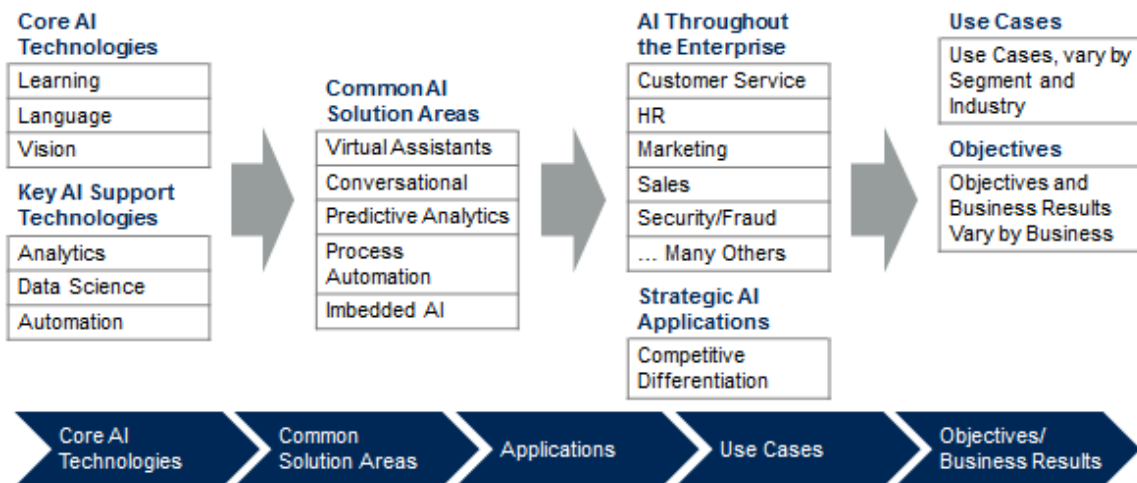


Abbildung 2: KI-Framework (Bern & Whit, 2017)

Das Schema in Abbildung 2: KI-Framework ist sowohl von rechts nach links, als auch umgekehrt zu lesen. Es veranschaulicht, wie KI in einer Organisation umfassend implementiert werden kann. Ausgehend von den Unternehmenszielen (Objectives) und daraus abgeleiteten Anwendungsfällen (Use Cases) ergeben sich ein oder mehrere Unternehmensbereiche (Customer Service, HR, etc.), die in eine gesamtheitliche Lösung einzubeziehen sind. Der Use Case bestimmt dann auch, welche allgemeine KI-Lösungs- und Anwendungsgebiete (Common AI Solution Areas) bei der Umsetzung des Use Cases benötigt werden.

Das Schema zeigt auch, dass einzelne bzw. mehrere KI-Kern- und Schlüsseltechnologien (Learning, Language, Vision, Analytics, Data Science, Automation, etc.) zur Umsetzung von Use Cases aus allen Unternehmensbereichen eingesetzt werden können.

8.2 Cloud Computing Anbieter

Amazon, Google, IBM und Microsoft sind die vier größten Anbieter von Cloud-Lösungen und bieten eine große Auswahl an Infrastruktur-Komponenten und Machine Learning Werkzeugen. Die Abgrenzung findet dabei vor allem über die angebotenen Services, Betriebsmodelle und Plattform-Dienste statt. Die Portfolios bestehen im Wesentlichen aus Computer (Rechenleistung), Storage (Speicher) und Netzwerk.

Im Unterschied zu lokalen Architekturen bieten Cloud Computing-Betriebsmodelle den Vorteil, dass bestimmte Komponenten des Managements und der Server-Provisionierung automatisiert sind und somit der Aufwand für laufende Wartung und Management entfällt. Gleichzeitig stellt der Service sicher, dass die Anwendung ständig ausreichend Ressourcen zur Verfügung hat und übernimmt die automatische Skalierung der Server-Infrastruktur. Da der Aufbau und Betrieb von performanten und skalierbaren KI-Systemen mit hohen Kosten verbunden sind, fördert der leichte und flexible Zugang zu Cloud Computing so direkt die Entwicklung von neuen KI-Anwendungen.

Um den Zugang zu Maschinellem Lernen weiter zu vereinfachen, stellen viele Cloud Computing Anbieter darüber hinaus eine Reihe an Anwendungen und Werkzeugen als „Machine Learning as a Service“ (MLaaS) zur Verfügung. Für spezifische Zwecke (z.B. im Bereich Datenvisualisierung, Computer Vision, NLP, Spracherkennung oder bei Vorhersagen) kann hier auf bereits trainierte Modelle zurückgegriffen werden, um so in der Entwicklung und beim Trainieren der Modelle Zeit und Ressourcen zu sparen. Mittlerweile existieren eine Vielzahl an MLaaS-Anbietern mit einer stetig wachsenden Anzahl an möglichen Anwendungsfällen.

Cloud Services sind auch in Form von Company Cloud/On-Premise Cloud realisierbar. Auch die Weiterverarbeitung vortrainierter Modelle ist vor Ort in gewissem Rahmen möglich. Die Nutzung von Cloud-basierten Services wird durch die IKT-Richtlinie der Stadt Wien geregelt. Die diesbezüglichen Bestimmungen sind dabei zu beachten.

9 Umsetzungserfolg der KI-Strategie

Ein Verständnis der Möglichkeiten von KI und des Einsatzpotenzials in der eigenen Organisation ist als Grundbaustein zur Identifikation von möglichen Anwendungsfällen zu betrachten. Die Identifizierung und Implementation von konkreten KI-Anwendungsfällen ist ein wesentlicher Faktor, um den Umsetzungserfolg der KI-Strategie zu gewährleisten. Bei der Entwicklung und Auswahl der KI-Anwendungsfälle wird das Hauptaugenmerk daraufgelegt, im Einklang mit den in Kapitel 3 erwähnten strategischen Zielen der KI-Strategie zu liegen.

9.1 Generische Anwendungsfälle zur Identifikation möglicher Anwendungsfälle

Die folgenden Unterkapitel beschreiben geeignete generische KI-Anwendungsfälle, welche als Grundlage zur Identifikation von konkreten Anwendungsfällen für die Stadt Wien dienen. Zum allgemeinen Verständnis wird dabei für jeden generischen KI-Anwendungsfall beschrieben, welche Eingangsinformationen (Input) sich dafür eignen, bzw. welches Ergebnis (Output) dabei erzeugt werden kann. Zusätzlich wird für jeden Anwendungsfall ein Ablaufdiagramm gezeigt, welches die technischen Schritte und das notwendige Modelltraining beschreibt. Die Beispiellösungen sind illustrativ zu verstehen; im konkreten Einzelfall sollten alle verfügbaren Technologien und Lösungs-Architekturen in Betracht gezogen, sowie etwaige aktuelle Weiterentwicklungen berücksichtigt werden.

9.1.1 Auswertung von unstrukturierten Daten in Textform

Geschäftliche Informationen sind nicht nur in Tabellen oder Datenbanken gespeichert, sondern liegen in Textform und damit in der Regel unstrukturiert vor – als Dokumente (z.B. Anträge, Gutachten, Bescheide), E-Mails, sowie in Form von maschinell erzeugten Protokollen. Hinzu kommen Textinhalte aus dem Internet, wie z.B. Postings in sozialen Netzwerken oder Diskussionsforen. Bei der Auswertung von unstrukturierten Daten ist viel Entwicklungspotenzial enthalten, da sich einerseits in „älteren“ Datenquellen sehr viel Wissen verbirgt und andererseits auch mit modernen Dokumentationssystemen noch immer sehr viel „Freitext“ erzeugt wird.

Dank neuer Analysetools und der Weiterentwicklung von semantischem Verständnis und Maschinellern haben Organisationen die Möglichkeit, unstrukturierte Daten auszuwerten und zu nutzen. Mögliche Anwendungsfälle reichen dabei von einfacher Textextraktion und Zusammenfassungen bis hin zur automatischen Unterstützung bei Entscheidungsfindungen, wie z.B. der Bewertung von Gutachten.



Abbildung 3: Input & Output bei Auswertung von unstrukturierten Daten in Textform

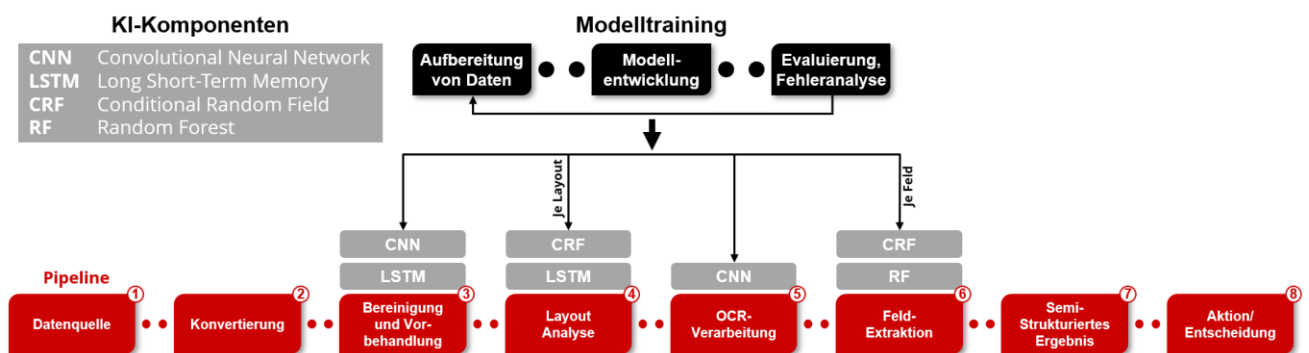


Abbildung 4: Beispielhaftes Ablaufdiagramm zur Auswertung von unstrukturierten Daten in Textform

- 1) Textinhalte in nicht-maschinenlesbarer Form (z.B. handschriftlicher Text oder Scans von geringer Qualität)
- 2) Konvertierung in ein einheitliches Format (z.B. PDF oder TIFF)
- 3) Um die Erfolgsrate von OCR zu verbessern, wird ein Set an Routinen ausgeführt, um z.B. Bildrauschen zu entfernen
- 4) Identifikation von Überschriften, Absätzen und Tabellen im jeweiligen Layout. Je Layout werden mindestens 1000 Dokumente nach Sprache, Schriftart, Freitext vs. Formular, Handschrift etc. analysiert
- 5) Transformation von unstrukturierten Daten in Zeichen
- 6) Extrahieren von Informationen aus vorab definierten Feldern
- 7) Ergebnisse liegen in semistrukturierter Form vor
- 8) Weiterverarbeitung bzw. Entscheidungsfindung

9.1.2 Zeitreihenanalyse

Allgemein sind Zeitreihen Sammlungen von Werten, die in zeitlicher Folge beobachtet wurden. Dies können z.B. Bevölkerungs- und Wirtschaftsdaten, Bedarfe nach Gütern oder Versorgungsleistungen, Besucherzahlen, Transaktionsdaten, Verkehrsdaten oder auch Klimadaten sein. Die Zeitreihenanalyse hat die Prognose des Zeitreihenverlaufes in der Zukunft sowie das Aufdecken von Strukturen wie Trends und plötzlichen Veränderungen zum Ziel und findet so breite Anwendungsmöglichkeiten.



Abbildung 5: Input & Output bei Zeitreihenanalyse

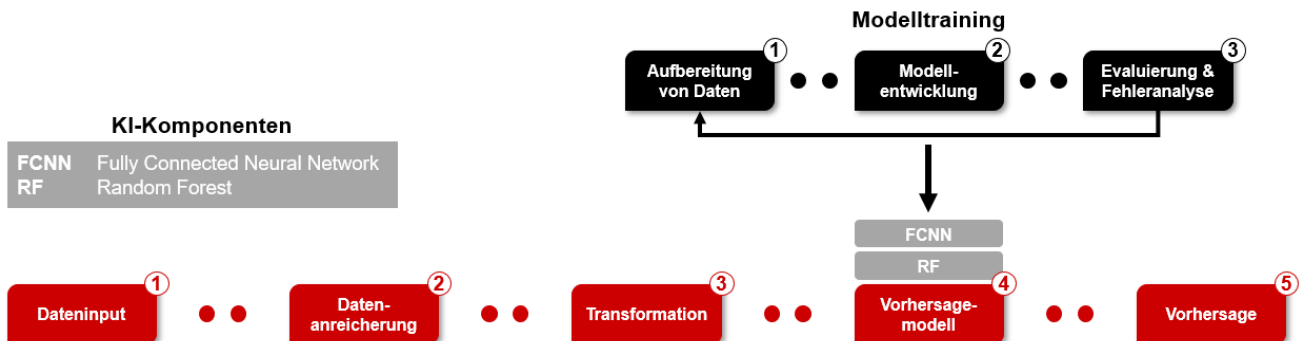


Abbildung 6: Beispielhaftes Ablaufdiagramm zur Zeitreihenanalyse

- 1) Input von Zeitreihendaten in strukturierter Form
- 2) Anreicherung mit weiteren Datenquellen, welche Einfluss auf die Vorhersage haben können
- 3) Auswahl und Transformation der Daten in geeignete Zeitfenster (z.B. tages- oder monatsweise)
- 4) Entwicklung und Training des Vorhersagemodells mit geeigneter Methodik. Das Training und die Evaluierung des Modells erfolgen laufend, sobald neue Ist-Daten generiert wurden
- 5) Vorhersage des gewünschten Wertes

9.1.3 Anomalie-Erkennung

Eine Anomalie bezeichnet ein Ereignis, dessen Eigenschaften stark von der Norm abweichen und so eine Auffälligkeit darstellen. Bei kleineren Datenmengen kann eine Anomalie noch per Hand identifiziert werden, große Datenmengen jedoch erfordern die Unterstützung durch intelligente Algorithmen. Zum Beispiel können so Zugriffe auf das interne IT-System aus dem Ausland zu ungewöhnlicher Zeit oder das geänderte Kaufverhalten mittels einer gestohlenen Kreditkarte ein anomales Signal darstellen, welches auf eine Abweichung vom Normalzustand hinweist. Darüber hinaus lassen sich auch Auffälligkeiten beim Zustand von Maschinen und IT-Geräten identifizieren, welche ein Signal für vorausschauende Wartung liefern können (Ott, 2018, S. 26f).



Abbildung 7: Input & Output bei Anomalie-Erkennung

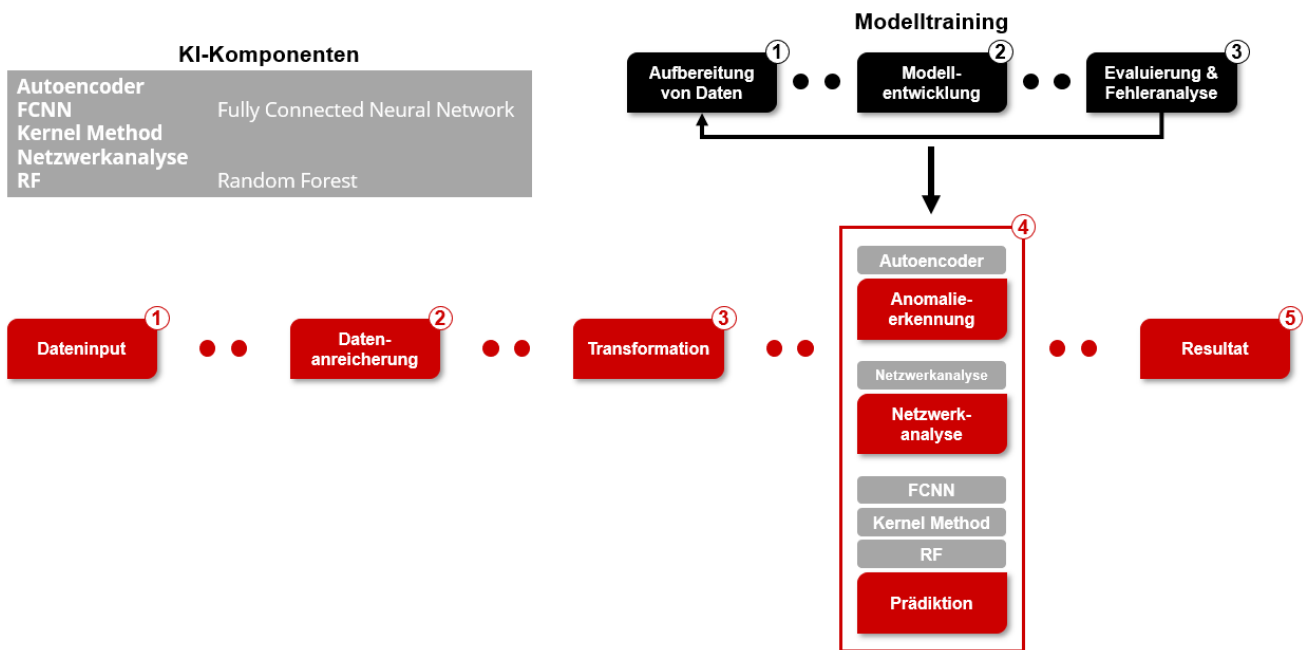


Abbildung 8: Beispielhaftes Ablaufdiagramm zur Anomalie-Erkennung

- 1) Input von Stammdaten und ggf. bekannten Anomalien
- 2) Verknüpfung mit Wissensbasis und Erweiterung um periphere Daten bzw. Netzwerke
- 3) Überführung der Daten in eine für das Modell geeignete Struktur
- 4) Auswahl eines geeigneten Modells
 - a. Anomalie-Erkennung: Identifizierung von statistischen Auffälligkeiten
 - b. Netzwerkanalyse: Analyse von Anomalien auf Zusammenhangsebene
 - c. Prädiktion: Vorhersage basierend auf bekannten Anomalien
- 5) Identifikation von Anomalien

9.1.4 Computer Vision

Bei Anwendungen im Bereich Computer Vision eignen sich Bilder und Videos aus unterschiedlichsten Quellen. Das Ziel liegt immer darin, Objekte oder Szenen aufgrund der Bild- bzw. Videoinhalte semantisch zu erkennen bzw. zu interpretieren. Das gezeigte Ablaufdiagramm beschreibt hier den Sonderfall der Fotogrammetrie, bei welchem aus Fotografien (z.B. Luftbildern) und genauen Referenzkoordinaten eines Objektes seine räumliche Lage oder dreidimensionale Form bestimmt wird.



Abbildung 9: Input & Output bei Computer Vision

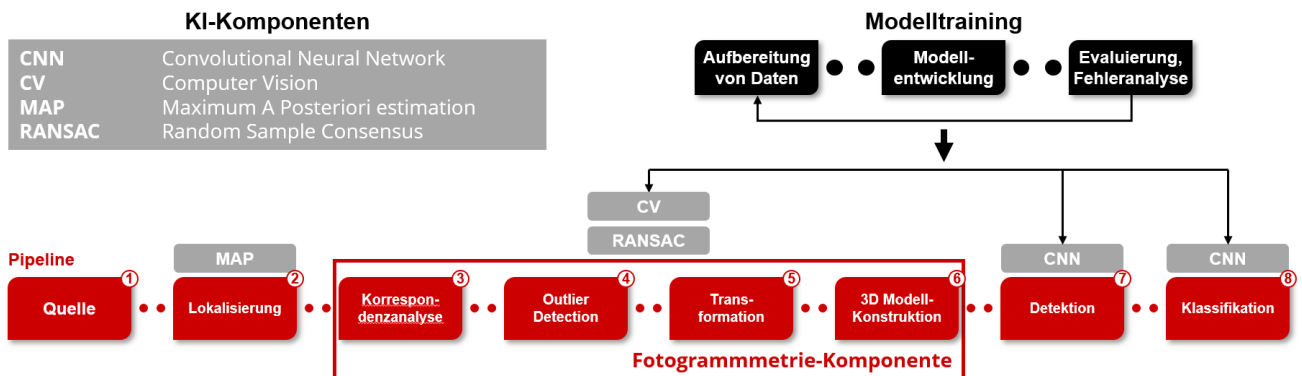


Abbildung 10: Beispielhaftes Ablaufdiagramm zu Computer Vision (Fotogrammetrie)

- 1) Input von Stadtplänen, Fahrdaten, Bildsequenzen oder GPS-Bewegungsdaten
- 2) Sensor-Fusion und Abgleich des Bildes auf den jeweiligen Standort
- 3) Distanzbestimmung der 3D-Scanpunkte
- 4) Plausibilisierung der korrespondierenden Punkte, Erkennung von fehlerhaften Zuordnungen
- 5) Projektion des Bildes in den 3D-Raum
- 6) Aufbau des 3D-Modells
- 7) Erkennung von relevanten Bereichen im 3D-Modell
- 8) Klassifizierung der erkannten Bereiche und Weiterverarbeitung bzw. Entscheidungsfindung

9.1.5 Chatbots & Assistenten

Mit dem Einsatz von Chatbots können Organisationen ihre Mitarbeiterinnen und Mitarbeiter bzw. Kundinnen und Kunden rund um die Uhr unterstützen und ihnen Wissen bereitstellen. Durch die Integration mit verschiedenen Systemen und Datenquellen erkennen intelligente Bots den Kontext und können – wie ein menschlicher Mitarbeiter – bereits gewisse Annahmen treffen. Da die Kommunikation mit dem virtuellen Assistenten in menschlicher Sprache erfolgt, vereinfacht das die Interaktion und Benutzererfahrung. Anstatt also eine komplexe Benutzeroberfläche mit vielen (und meist irrelevanten) Optionen zu präsentieren, steht bei den Bots das konkrete Anliegen des Users im Fokus. Als Input eignen sich bei Chatbot-Anwendungen sämtliche Kommunikation in schriftlicher bzw. gesprochener Form, auf welche Feedback (z.B. eine Auskunft) gegeben werden soll.



Abbildung 11: Input & Output bei Chatbots & Assistenten

9.2 Empfohlenes Vorgehen bei der Umsetzung eines KI-Projektes

Das Vorgehen bei der Umsetzung von KI-Projekten muss strukturiert erfolgen. Als Besonderheit im Vergleich zu regulären IT-Projekten steht bei KI-Anwendungen die mehrmalige Überprüfung der Machbarkeit im wesentlichen Fokus der Entwicklung, da diese oft je nach Umgebung und den vorhandenen Daten variieren kann. Oft ist es auch nicht möglich, auf Erfahrungswerte zurückzugreifen, da viele KI-Methoden und Algorithmen für den Alltagseinsatz noch unerprobt sind bzw. einen starken Forschungscharakter aufweisen.

Daher empfiehlt sich folgende Vorgehensweise bei der Umsetzung eines KI-Projektes, welche je nach Komplexität angepasst werden kann:

1. Festlegung des Projektumfangs und der Problemstellung, Projektplanung und Erstanalyse der technischen und wirtschaftlichen Machbarkeit.

2. Identifizierung von Datenquellen und deren Umfang bzw. Analyse der Datenqualität. Gegebenenfalls ist eine Synthese von Trainingsdaten erforderlich, falls keine ausreichende Menge an Daten vorhanden ist.
3. Durchführung einer Machbarkeitsstudie (Proof of Concept) um prinzipielle Durchführbarkeit des Vorhabens zu analysieren.
4. Entwicklung eines Prototyps, welcher die benötigte Kernfunktionalität beinhaltet.
5. Entwicklung des Produktivsystems
6. Integration in Systemlandschaft
7. Produktivsetzung

Häufig ist es sinnvoll, nach Abschluss der Schritte 1 bis 4 jeweils zu prüfen, ob eine Fortführung des Projektes basierend auf den bis dahin gewonnenen Erkenntnissen sinnvoll erscheint.

10 Zusammenfassung und Handlungsempfehlungen

Um die in Kapitel 3 definierten strategischen Ziele der KI-Strategie der Stadt Wien zu erreichen, werden folgende Handlungsempfehlungen gegeben:

10.1 Prozess zur Identifikation von zusätzlichen KI-Anwendungsfällen

Zusätzlich zu den im Rahmen der Entwicklung der KI-Strategie identifizierten Anwendungsfällen sollten im Rahmen eines laufenden und noch zu etablierenden Prozesses KI-Anwendungsfälle erarbeitet und implementiert werden. Dazu können sowohl die in Kapitel 9.1 beschriebenen generischen Anwendungsfälle herangezogen werden, als auch komplett neue Ideen eingebracht werden. Insbesondere bei Services für Bürgerinnen und Bürger ist zu prüfen, ob der Einsatz von KI-Methoden zu einer nachhaltigen Verbesserung führen kann.

10.2 Implementation von konkreten KI-Anwendungsfällen

Auf Basis der in Kapitel 9.1 beschriebenen generischen Anwendungsfälle werden Vorschläge zur Umsetzung von konkreten KI-Anwendungsfällen ausgearbeitet. Es wird empfohlen, initial 2-3 dieser Anwendungsfälle einer Machbarkeitsstudie zu unterziehen und im Falle eines positiven Ergebnisses die Entwicklung und Implementierung des Produktivsystems zu veranlassen. Bei der Implementierung wird besonderes Augenmerk auf die Marktreife der KI-Technologien, die Sicherheit, die Verfügbarkeit, die Stabilität und die Funktionalität von KI-Systemen gelegt.

10.3 Aufbau von KI-Kompetenzen in der Stadtverwaltung

Innerhalb der Stadt Wien sollten fundiertes Wissen und Kompetenzen hinsichtlich Künstlicher Intelligenz langfristig innerhalb der Organisation geschaffen werden, um folgende Aufgaben erfüllen zu können:

- Laufende Identifikation von KI-Anwendungsfällen innerhalb der Fachbereiche der Magistratsabteilungen und deren Unternehmungen.
- Schaffung von Akzeptanz und Vertrauen in KI-Technologie durch laufende Kommunikation, Schulungen und Workshops mit Mitarbeiterinnen und Mitarbeiter.
- Steuerung und laufende Verbesserung von bereits implementierten KI-Anwendungsfällen.
- Internes Projektmanagement und Steuerung externer Dienstleister im Zuge der Entwicklung und Implementierung eines KI-Anwendungsfalles.
- Querverbindung zur bestehenden Data-Excellence Strategie.
- Durchführung von Machbarkeitsstudien und Entwicklung eigener Prototypen zur Erprobung.

Zur Erfüllung dieser Aufgaben sind jeweils folgende Kompetenzprofile geeignet:

10.3.1 Kompetenzprofile KI / Machine Learning

KI/ML ForscherIn	Stellt die Basistechnologie zur Verfügung. Kann neueste verfügbare Technologien und Verfahren kombinieren, weiterentwickeln und gänzlich neue Methoden entwickeln. Arbeitet in der Grundlagenforschung, um neue Methoden und Einsatzgebiete zu erschließen, oder in der angewandten Forschung, um bereits bestehende Technologien an neue Anwendungsgebiete anzupassen.
KI/ML IngenieurIn	Verwendet neueste verfügbare Basistechnologien, kombiniert diese und erstellt daraus Machine Learning- und KI-Anwendungen. Setzt die Auswahl, Vorverarbeitung, Verarbeitung und Nachverarbeitung der Daten um. Plant, implementiert und führt Qualitätssicherung durch. Implementiert Workflows von der Evaluierung bis zum Produktiveinsatz.
KI/ML Helfer	Führt manuelle oder semi-automatische Erstellung von Trainingsdaten durch. Hat einfaches Basiswissen über KI/ML und Datenorganisation. Kann einfache Aufgaben der Qualitätssicherung durchführen und Monitoring-Aufgaben durchführen.
KI/ML ManagerIn	Kann eine KI/ML-Organisation aufbauen, managen und die Finanzierung organisieren. Kann die technologischen Möglichkeiten von KI/ML einschätzen und die notwendigen rechtlichen und geschäftlichen Rahmenbedingungen für erfolgreiche KI/ML Projekte sicherstellen.

10.3.2 Kompetenzprofile Data Science / Data Engineer

Data Scientist	Verfügt über umfangreiches Wissen über sowohl klassische Machine Learning Methoden als auch über den aktuellen Forschungsstand. Ist in der Lage, eigenständig auf Basis neuester verfügbarer Technologien und Verfahren Prototypen umzusetzen und kann KI-Produktsysteme technisch detailliert spezifizieren.
AnalystIn	Hat einen detaillierten Überblick über unterschiedliche praxiserprobte Machine Learning Verfahren und setzt diese modular über Tools oder Bibliotheken ein. Verfügt über ausreichend Domänenwissen um Fragestellungen selbstständig zu beantworten und Ergebnisse zu interpretieren.

DomänenexpertIn	Hat genaues Wissen über die Bedeutung der Daten aus einer Wertschöpfungskette. Verfügt zusätzlich über Übersichtswissen zu KI und Machine Learning. Bildet die Schnittstelle zwischen den Entwicklern von Machine Learning Anwendungen und deren Anwendern.
Data Engineer	Zeichnet sich verantwortlich für die Datenbereitstellung und verfügt über detailliertes Wissen über Datenbanksysteme, Data Lakes und Data Pipelines. Konzipiert Datenschemen und stellt Datenqualität und Performance sicher. Hat Basiswissen über KI/ML.
DevOps Engineer	Betreut die KI und Datensysteme und stellt deren Hochverfügbarkeit sicher. Plant und implementiert Updates und Migrationen und sorgt für die Sicherheit und Zugriffsmechanismen der Systeme.

10.4 Standardisierung

Wer die Standards setzt, bestimmt den Markt. Gemeinsame Normen und Standards sorgen für den Abbau technischer Hemmnisse, unterstützen die Öffnung von Märkten und erhöhen damit die Wettbewerbsfähigkeit der Wirtschaft. Gemeinsame Standards können die Nutzerfreundlichkeit von Anwendungen erhöhen und Interoperabilität ermöglichen. Deshalb ist eine angemessene Stoßkraft Europas in internationalen Standardisierungsprozessen sicherzustellen. Hierzu wird die Stadt Wien mit Expertinnen und Experten aus Wissenschaft und Wirtschaft folgende Handlungsoptionen prüfen:

- Start einer Initiative, um Wiener und europäische Interessen in internationalen Standardisierungsgremien stärker gemeinsam zu vertreten.
- Stärkeres Engagement für die Entwicklung offener und internationaler Standards.
- Einbeziehung der Gruppe „Sofortmaßnahmen der Stadt Wien“.

Die Vernetzung und der Ausbau der Kompetenzzentren mit anderen europäischen Key-Playern werden unverzüglich umgesetzt. Darüber hinaus wird die Einrichtung von thematischen Kompetenzzentren in Angriff genommen. Die Stadt Wien wird im Rahmen laufender Programme und des Haushaltes 2019 die einschlägigen Maßnahmen im Sinne dieser Eckpunkte umsetzen.

10.5 KI-Framework

Immer wenn eine neue KI-Anwendung geplant, beauftragt oder umgesetzt wird, ist zu prüfen, ob für die Umsetzung erforderliche KI-Kern- bzw. Schlüsseltechnologien bereits innerhalb der Stadt Wien vorhanden

sind und ob diese in die geplante Lösung integriert werden können, selbst wenn z.B. eine zugekaufte Lösung bereits ihre eigenen Kerntechnologien mitbringt.

Darüber hinaus empfiehlt es sich, auf bestehende Angebote im Bereich MLaaS zurückzugreifen bzw. die Möglichkeit dazu vor Projektbeginn zu evaluieren, um in der Entwicklung einer KI-Lösung möglicherweise Zeit und Ressourcen zu sparen.

10.6 Bereitstellung einer Prototyping-Umgebung für Entwicklerinnen und Entwickler

Eine Prototyping-Umgebung bezeichnet einen isolierten Bereich zum Testen von Software (bzw. Modellen), innerhalb dessen jede Maßnahme keine Auswirkung auf die äußere Umgebung hat. Einerseits kann so kein Schaden angerichtet werden, andererseits wird es jedoch ermöglicht, die Wirkungen der Software aufzuzeichnen und daraus zu lernen. Die Zurverfügungstellung einer Prototyping-Umgebung für interne Entwicklerinnen und Entwickler der Stadt Wien würde es somit ermöglichen, neue KI-Anwendungsfälle auf deren Funktionsweise bzw. Tauglichkeit zu testen, ohne bestehende Systeme damit zu beeinflussen.

10.7 Sicherstellung von menschenzentrierter KI

Bei KI-Systemen muss Transparenz, Nachvollziehbarkeit und Überprüfbarkeit gewährleistet sein, sodass effektiver Schutz gegen Verzerrungen, Diskriminierungen, Manipulationen oder sonstige missbräuchliche Nutzungen insbesondere beim Einsatz von Prognose- und Entscheidungssystemen möglich ist. Dies bedeutet auch, dass die Entscheidungshoheit nicht einem Computersystem überlassen wird, sondern in der Verantwortung des Menschen liegt.

Dazu ist eine zentrale Verantwortung der Entwicklerinnen und Entwickler bzw. der Anwenderinnen und Anwender von KI-Systemen erforderlich, welche zu Beginn sorgfältig prüfen müssen, ob die verfügbaren Daten für den jeweiligen Analysezweck geeignet sind. Gleichzeitig muss nachvollziehbar und verständlich kommuniziert werden, wie ein KI-System arbeitet, warum es in einer gewissen Situation eine Empfehlung gibt oder eine Entscheidung trifft und welche Daten gegebenenfalls generiert werden. Dazu ist es auch besonders wichtig zu erkennen, ob in den Ausgangsdaten bereits Vorurteile stecken, um so selbsterfüllende Prophezeiungen zu vermeiden. Die Durchsetzung von KI-Systemen wird längerfristig nur dann gewährleistet sein, wenn in der Öffentlichkeit eine breite Akzeptanz gewährleistet ist und die Nutzerinnen und Nutzer das Gefühl haben, sich auf die Technologie verlassen zu können.

Eine sehr umfassende Methode, um Erklärbarkeit zu schaffen, ist LIME (Local Interpretable Model-agnostic Explanations). LIME findet Erklärungen, die lokal mit einfachen, interpretierbaren Modellen gefunden werden und macht so ein annäherungsweise Verständnis von komplexen Machine Learning-Modellen möglich.

LIME basiert auf drei Prinzipien:

- Erklärungen werden lokal und für jede Instanz unabhängig gefunden.
- Ein einfaches Modell wird lokal an Vorhersagen des komplexen Modells angepasst.
- Erklärungen werden anhand der ursprünglichen Variablen gegeben, auch wenn die tatsächliche Klassifikation auf Abstraktionen der Originalvariablen beruht, wie in einem Convolutional Neural Network (CNN).

Dies bedeutet, dass die Entscheidungen direkt nachvollziehbar sind und zum Beispiel die Pixel in einem Bild markiert werden können, die für die Klassifikation entscheidend waren. Bei klassischen tabellarischen Daten kann in Erfahrung gebracht werden, welche der Features am stärksten und in welcher Form zur Klassifikation beigetragen haben, bzw. wird ersichtlich, welche Wörter in einem Text für die Vorhersage des Modells am wichtigsten waren.

11 Literaturverzeichnis

(16. 11 2018). Von Ryte Wiki: https://de.ryte.com/wiki/Natural_Language_Processing abgerufen

Alexander, S., Haisermann, A., Schabicki, T., & Frank, S. (März 2018). Robotic Process Automation (RPA) im Rechnungswesen und Controlling - welche Chance ergeben sich? *Controlling - Zeitschrift für erfolgsorientierte Unternehmenssteuerung*, S. 11-19.

Andrews, W., & Herschel, G. (2017). *Develop Your Artificial Intelligence Strategy Expecting These Three Trends to Shape Its Future*. Stamford: Gartner.

Bankhofer, U., & Vogel, J. (2008). *Datenanalyse und Statistik*. Wiesbaden: Gabler.

Bern, E., & Whit, A. (2017). *A Framework for Applying AI in the Enterprise*. Stamford: Gartner, Inc.

Bitkom. (2017). *Künstliche Intelligenz: Wirtschaftliche Bedeutung, gesellschaftliche Herausforderungen, menschliche Verantwortung*. Berlin: Bundesverband Informationswirtschaft, Telekommunikation und neue Medien e. V.

Bonaccorso, G. (2018). *Machine Learning Algorithms: Popular algorithms for data science and machine learning*. Birmingham: Packt Publishing.

Cearley, D., Burke, B., Searle, S., & Walker, M. (2017). *Top 10 Strategic Technology Trends for 2018*. Stamford: Gartner.

CPS.HUB NRW. (2018). *Künstliche Intelligenz und Maschinelles Lernen - Chancen, Potenziale und Herausforderungen in Nordrhein-Westfalen*. Wuppertal: CPS.HUB NRW.

Dickow, M., & Jacob, D. (April 2018). *Das globale Ringen um die Zukunft der künstlichen Intelligenz*. Berlin: Stiftung Wissenschaft und Politik.

Djeffal, C. (2018). *Künstliche Intelligenz: Beitrag zum Handbuch Digitalisierung in Staat und Verwaltung*. Berlin: Alexander von Humboldt Institut für Internet und Gesellschaft.

Döbel, I., Dr. Leis, M., Vogelsang, M., Neustroev, D., Dr. Petzka, H., Riemer, A., . . . Dr. Weiz, J. (2010). *Maschinelles Lernen - Eine Analyse zu Kompetenzen, Forschung und Anwendung*. München: Fraunhofer-Gesellschaft.

Dörn, S. (2018). *Programmieren für Ingenieure und Naturwissenschaftler*. Berlin: Springer-Verlag.

Ertl, W. (2016). *Grundkurs Künstliche Intelligenz: Eine praxisorientierte Einführung*. Berlin: Springer-Verlag.

Fraunhofer-Gesellschaft. (2018). *Maschinelles Lernen - Kompetenzen, Anwendungen und Forschungsbedarf*. München.

- Frochte, J. (2018). *Maschinelles Lernen: Grundlagen und Algorithmen in Python*. München: Carl Hanser Verlag.
- Gentsch, P. (2017). *Künstliche Intelligenz für Sales, Marketing und Service; Mit AI und Bots zu einem Algorithmic Business - Konzepte, Technologien und Best Practices*. Berlin: Springer-Verlag.
- Hager, T. (04 2018). Künstliche Intelligenz – Mehr Sicherheit oder neue Sicherheitsrisiken? *Organisator*, S. 40.
- Hecker, Dr., D., Döbel, I., Petersen, U., Rauschert, A., Schmitz, V., & Voss, Dr., A. (2017). *Zukunftsmarkt Künstliche Intelligenz: Potenziale und Anwendungen*. München: Fraunhofer-Allianz Big Data.
- Kropp, M. D., & Töbel, L. (2017). *Machine Learning*. Troisdorf: Sigs Datacom.
- Müller, A. C., & Guido, S. (2017). *Einführung in Machine Learning mit Python: Praxiswissen Data Science*. Sebastopol: O'Reilly.
- Neumaier, O. (1994). Was hat "Künstliche Intelligenz" mit Ethik zu tun? *Conceptus XXVII*, S. 41-76.
- Ott, T. (2 2018). Anomalie-Erkennung mit Machine Learning. *BI-Spektrum*, S. 26-30.
- Otto, P., & Gräf, E. (2018). *Künstliche Intelligenz - Häufig gestellte Fragen*. Berlin: Konrad-Adenauer Stiftung e. V.
- Reder, B. (2018). *Studie Machine Learning / Deep Learning 2018*. München: IDG Business Media GmbH.
- Seiter, M. (2017). *Business Analytics: Effektive Nutzung fortschrittlicher Algorithmen in der Unternehmenssteuerung*. München: Vahlen-Verlag.
- Tiedemann, M. (15. Jänner 2018). Warum Künstliche Intelligenz dem Internet of Things zum Durchbruch verhelfen wird. *Digitale Welt*. Von <https://digitaleweltmagazin.de/en/2018/01/15/ki-bringt-iot-durchbruch/abgerufen>
- Zeigermann, O., & Nguyen, C. (2018). *Machine Learning kurz & gut*. Sebastopol: O'Reilly.

12 Abbildungsverzeichnis

Abbildung 1: CRISP-DM Prozess	17
Abbildung 2: KI-Framework (Bern & Whit, 2017)	28
Abbildung 3: Input & Output bei Auswertung von unstrukturierten Daten in Textform	31
Abbildung 4: Beispielhaftes Ablaufdiagramm zur Auswertung von unstrukturierten Daten in Textform	31
Abbildung 5: Input & Output bei Zeitreihenanalyse	32
Abbildung 6: Beispielhaftes Ablaufdiagramm zur Zeitreihenanalyse	32
Abbildung 7: Input & Output bei Anomalie-Erkennung.....	33
Abbildung 8: Beispielhaftes Ablaufdiagramm zur Anomalie-Erkennung	34
Abbildung 9: Input & Output bei Computer Vision	35
Abbildung 10: Beispielhaftes Ablaufdiagramm zu Computer Vision (Fotogrammetrie).....	35
Abbildung 11: Input & Output bei Chatbots & Assistenten	36

13 Abkürzungsverzeichnis

Abkürzung	Bedeutung
CC	Cognitive Computing
CNN	Convolutional Neural Network
CRF	Conditional Random Field
CRISP-DM	Cross-Industry Standard Process for Data Mining
DL	Deep Learning
ERP	Enterprise Resource Planning
FCNN	Fully Connected Neural Network
IKT	Informations- und Kommunikationstechnologie
IoT	Internet of Things
KI	Künstliche Intelligenz
KNN	Künstliche(s) Neuronales Netz(e)
LIME	Local Interpretable Model-agnostic Explanations
LSTM	Long Short-Term Memory
ML	Maschinelles Lernen
MLaaS	Machine Learning as a Service
NLP	Natural Language Processing
OCR	Optical Character Recognition
RDA	Robotic Desktop Automation
RF	Random Forest
RPA	Robotic Process Automation