

KI B³ - Künstliche Intelligenz in die berufliche Bildung bringen

Geprüfte Berufsspezialistin/
Geprüfter Berufsspezialist
für Künstliche Intelligenz und
Maschinelles Lernen (IHK)

Rahmenplan mit Lernzielen

Inhalt

Vorwort	3
Taxonomie der Lernziele (Anwendungstaxonomie)	4
Konzeption mit Stundenempfehlung	5
1. Implementierung und Anwendungsmöglichkeiten von datenbasierten KI-Modellen	6
1.1. Grundbegriffe von KI und maschinellem Lernen.....	6
1.2. Umgang mit Daten	7
1.3. Datenanalyse & Maschinelles Lernen	9
1.4. Chancen & Herausforderungen der KI	16
1.5. Praktisches Projekt	18
1.6. Grundkenntnisse Programmierung und KI-Systementwicklung	18
2. Mitgestalten und Umsetzen von (Veränderungs-)Prozessen und Projekten	20
2.1. Prozessmanagement	20
2.2. Zukunftsorientiertes Arbeiten in Projekten	20
3. Rechtliche Grundlagen	20
3.1. Rechtliche Grundlagen	20
4. Abwägung und Beurteilung ökonomischer Aspekte	21
4.1. Abwägungsmethoden	21
4.2. ökonomische Aspekte	21
5. Zukunftskompetenzen.....	22
5.1. Metakompetenzen	22
5.2. Zukunftskompetenzen / interaktive Kompetenzen	22
5.3. Agiles Arbeiten	23

Vorwort

Der vorliegende Rahmenplan wurde mit großer Sorgfalt und unter Einbeziehung verschiedener Perspektiven und Expertisen im Rahmen des InnoVET-Projekts KI B³ erstellt. Es ist jedoch wichtig zu betonen, dass dieser Plan als Orientierungshilfe und Vorschlag zu verstehen ist und keine rechtliche Verbindlichkeit besitzt.

Dieser Rahmenplan dient als

- Orientierungshilfe und Impulsgeber
- Basis für weitere Diskussionen und Planungen
- Flexibles Instrument zur Anpassung an individuelle Bedürfnisse und Gegebenheiten

Rechtlicher Hinweis

An dieser Stelle ist der Hinweis wichtig, dass der Rahmenplan keine gesetzliche Vorgabe darstellt. Es handelt sich um kein rechtsverbindliches Dokument. D.h. Abweichungen und Anpassungen sind möglich und in vielen Fällen sogar erwünscht. Die im Rahmenplan vorgestellten Inhalte und zeitliche Einteilungen dienen als Orientierungshilfe und als Basis für eigenen Überlegungen.

Taxonomie der Lernziele (Anwendungstaxonomie)

Die Lernziele beschreiben die angestrebten Lernergebnisse innerhalb der Sachgebiete. Den Lernzielen wurden zur Konkretisierung Lerninhalte zugeordnet. Lernziele, Lerninhalte und Taxonomiestufen helfen dem Lernenden, den Dozenten und Prüfern bei der Umsetzung der Qualifizierung.

Durch die Tätigkeitswörter wird das Lernziel hinsichtlich seiner Anforderungen erkennbar gemacht.

Bei dem vorliegenden Rahmenplan handelt es sich weder um eine Ablaufplanung für den Lehrgang noch um methodische Vorgaben für den Dozenten. Mit der Taxonomie werden die Lernziele geordnet und die Richtung des Lernens verdeutlicht.

Dem Rahmenplan wurden folgende Taxonomiestufen mit entsprechenden Tätigkeitswörtern zu Grunde gelegt

Taxonomie der Lernziele (Anwendungstaxonomie) gem. DIHK		
Taxonomiestufe	Definition	Zuordnung
Wissen	Beschreibt den Erwerb von Kenntnissen (Daten, Fakten, Sachverhalte), die notwendig sind, um Zusammenhänge zu verstehen.	WISSEN
		kennen
		überblicken
Verstehen	Beschreibt das Erkennen und Verinnerlichen von Zusammenhängen, um komplexe Aufgabenstellungen und Problemfälle einer Lösung zuführen zu können.	VERSTEHEN
		analysieren
		begründen
		beurteilen
		bewerten
		einordnen
		erfassen
		festlegen
		feststellen
		überprüfen
		unterscheiden
		vergleichen
		verstehen
zuordnen		
Anwenden	Beschreibt die aus dem Verstehen der Zusammenhänge resultierende Fähigkeit zu sach- und fachgerechtem Handeln.	ANWENDEN
		anwenden
		auswählen
		beachten
		beherrschen
		berücksichtigen
		beschaffen
		darstellen
		durchführen
		einleiten
		einsetzen
		entwickeln
erarbeiten		

		erläutern
		ermitteln
		erstellen
		fördern
		gewährleisten
		mitwirken
		sicherstellen
		überwachen
		umsetzen
		unterstützen
		veranlassen

Konzeption mit Stundenempfehlung

Themengebiet	Stunden
1. Implementierung und Anwendungsmöglichkeiten von datenbasierten KI-Modellen	300 Std.
2. Mitgestalten und Umsetzen von (Veränderungs-) Prozessen und Projekten	32 Std.
3. Rechtliche Grundlagen	40 Std.
4. Abwägung und Beurteilung ökonomischer Aspekte	36 Std.
5. Zukunftskompetenzen	32 Std.
Gesamtstunden	440 Std.

1. Implementierung und Anwendungsmöglichkeiten von datenbasierten KI-Modellen

1.1. Grundbegriffe von KI und maschinellem Lernen

	Bestandteile der Qualifikationsinhalte	Anwendungstaxonomie	Hinweise zur Vermittlung
1.1.1	Einführung	verstehen	Die Lernenden lernen eine typische Anwendung des Maschinellen Lernens kennen: die Prognose von Verkaufszahlen. Sie können mögliche Strategien wiedergeben, wie diese Prognose zustande kommen kann.
1.1.2	Spiel	anwenden	
1.1.3	Regression	beschreiben, verstehen, unterscheiden	Die Lernenden können den Begriff Regression beschreiben. Sie verstehen die Bedeutung von prädiktiven Faktoren in diesem Zusammenhang und können den Unterschied zwischen kausalen und nicht kausalen Faktoren erklären. Sie können zwischen Regression und Klassifikation unterscheiden.
1.1.4	Daten und Wissen	begründen, analysieren	Die Lernenden können die Bedeutung von Daten als Grundlage für (abstrakte) KI-Modelle erläutern. Sie können Beispiele für Daten in diesem Rahmen analysieren.
1.1.5	Maschinelles Lernen	verstehen	Die Lernenden kennen Entscheidungsbäume als einfache KI-Modelle und können erklären, wie man sie mit Hilfe von Daten Schritt für Schritt erstellen kann.
1.1.6	KI-Modelle	verstehen	Die Lernenden verstehen, dass Modelle helfen können, Daten besser zu verstehen. Sie können das Erstellen von Vorhersagen durch Anwendung von Modellen auf neue Daten beschreiben.
1.1.7	Arbeitsblatt Entscheidungsbaum	anwenden	Die Lernenden können ihr Wissen über die schrittweise Erstellung von Entscheidungsbäumen mithilfe von vorgegebenen Daten bei der manuellen Erstellung eines Klassifikationsbaums umsetzen.
1.1.8	Trainingsdaten	verstehen, begründen, unterscheiden	Die Lernenden verstehen, welche Informationen in Trainingsdaten vorhanden sein müssen. Sie können mögliche Szenarien, aus denen Trainingsdaten stammen können, beschreiben. Die Lernenden können Begriffe im Zusammenhang mit Trainingsdaten (Annotation von Daten, überwachtes und nicht überwachtes Lernen, Clustering als ein Beispiel von nicht überwachtem Lernen, Reinforcement Learning oder

Verstärkendes Lernen, Agenten für die lernende Komponente vor allem beim Reinforcement Learning) beschreiben.

1.1.9	Algorithmen	verstehen	Die Lernenden verstehen, was ein Algorithmus ist. Sie können die Schritte einfacher Algorithmen in Worten beschreiben. Die Lernenden können einfache Algorithmen auf abstrakter Ebene verstehen, erklären und modifizieren. Sie können erläutern, dass man Algorithmen auch durch Flussdiagramme oder Pseudo-Code beschreiben kann. Sie können beschreiben, wie die Erstellung von Entscheidungsbäumen beim Maschinellen Lernen durch einen festen Algorithmus vorgegeben werden kann.
1.1.10	Beispielanwendungen	kennen, begründen	Die Lernenden können Beispiele für verschiedene Anwendungen von maschinellem Lernen benennen und erläutern. Sie können erörtern, welche Daten für das Training entsprechender Modelle hilfreich sind.
1.1.11	Praxisprojekt Teachable Machine	anwenden	Die Lernenden können mithilfe einer intuitiven Anwendung, wie z.B. Googles Teachable Machine, ein einfaches KI-Modell erstellen und anwenden.

1.2. Umgang mit Daten

	Bestandteile der Qualifikationsinhalte	Anwendungstaxonomie	Hinweise zur Vermittlung
1.2.1	Daten in Tabellen darstellen	anwenden	Die Lernenden verstehen Tabellen als Repräsentation von Daten. Sie können ein Tool (z.B. Python, bei Vorgabe des Codes – ohne Programmierkenntnisse) anwenden, um Daten hinsichtlich einfacher Kriterien zu filtern (z. B. nach Datum) und aus Daten einfache statistische Eigenschaften bestimmen (z. B. Anzahl der Zeilen, Bereich der vorkommenden Werte).
1.2.2	Daten in Tabellen analysieren	anwenden	Die Lernenden verstehen den Sinn von logischen Operationen beim gezielten Zugriff auf bestimmte Untermengen von Daten. Sie können das Problem von fehlenden Werten erläutern. Die Lernenden verstehen, wie mithilfe eines Tools (z.B. Python, bei Vorgabe des Codes – ohne Programmierkenntnisse) weitere einfache statistische Eigenschaften von (Untermengen von) Daten ermittelt werden

			können (z.B. Mittelwert, Maximum, Minimum).
1.2.3	Daten vorbereiten	anwenden	Die Lernenden können die Begriffe Instanz/Datensatz und Features/Attribute beschreiben. Sie verstehen, wie mithilfe von Tools (z.B. Python, bei Vorgabe des Codes – ohne Programmierkenntnisse) gezielt Daten in Tabellen verändert werden können. Sie können Spalten mit neuen Features einfügen. Sie verstehen, wie Tabellen mithilfe von Schlüsseln zusammengeführt werden können. Sie kennen und verstehen die Begriffe Inner Join und Outer Join in diesem Zusammenhang. Sie kennen Histogramme zur Visualisierung von Daten und können sie interpretieren. Sie kennen Boxplots als weitere Möglichkeit zur Visualisierung von Daten. Sie können Ausreißer in Boxplots identifizieren. Sie verstehen die Begriffe Median, Quartil und Interquartilsabstand, Quantil, sowie den Begriff Antenne oder Whiskers.
1.2.4	Datensicherheit	überblicken, begründen	Die Lernenden kennen technische und organisatorische Maßnahmen zum Schutz von Daten generell und können diese nennen und erläutern. Sie können die Begriffe Vertraulichkeit, Integrität und Verfügbarkeit in diesem Zusammenhang erklären.
		erläutern	Die Lernenden kennen die Bedeutung von sicheren Passwörtern für die Datensicherheit. Sie erkennen die Gefahr von Phishing-Mails und können verdächtige Eigenschaften von Phishing-Mails beschreiben.
1.2.5	Verschlüsselung	verstehen, anwenden	Die Lernenden können mit einfachen Chiffrierverfahren Nachrichten verschlüsseln und entschlüsseln. Sie verstehen, wie schwach verschlüsselte Nachrichten mithilfe von Statistik entziffert werden können. Sie kennen den Unterschied zwischen symmetrischen und asymmetrischen Verschlüsselungsverfahren und können ihn beschreiben.
1.2.6	Standardisierung	verstehen, anwenden	Die Lernenden verstehen die Bedeutung der Standardisierung von Daten für maschinelle Lernverfahren und können Daten (z. B. mithilfe von Python-Bibliotheken) standardisieren.
1.2.7	Tensoren in Python	verstehen, anwenden	Die Lernenden kennen das Konzept von Tensoren zur Repräsentation von Daten in

neuronalen Netzen. Sie können (z. B. mithilfe von Python-Bibliotheken) Tensoren manipulieren (z. B. um Dimensionen erweitern oder die Form des Tensors verändern).

1.3. Datenanalyse & Maschinelles Lernen

	Bestandteile der Qualifikationsinhalte	Anwendungstaxonomie	Hinweise zur Vermittlung
1.3.1	Das Koordinatensystem	verstehen	Die Lernenden verstehen die Darstellung von Datenpunkte in einem zweidimensionalen Koordinatensystem.
1.3.2	Funktionen	verstehen	Die Lernenden kennen Funktionen als eindeutige Zuordnungen von einer Definitionsmenge in eine Wertemenge. Sie verstehen die Darstellung von einfachen Funktionen in einem Koordinatensystem.
1.3.3	lineare Funktionen: Steigung	analysieren	Die Lernenden kennen lineare Funktionen (umgangssprachlich als lineare Funktionen bezeichnete Funktionen). Sie kennen den Parameter Steigung und können ihn interpretieren. Sie können die Steigung an der Funktionsgleichung und an der grafischen Darstellung der Funktion ablesen.
1.3.4	lineare Funktionen: y-Achsenabschnitt	analysieren	Sie kennen den Parameter y-Achsenabschnitt und können ihn interpretieren. Sie können den y-Achsenabschnitt an der Funktionsgleichung und mithilfe der grafischen Darstellung der Funktion bestimmen.
1.3.5	Scatterplots	analysieren	Die Lernenden können Scatterplots/ Streudiagramme zur Darstellung von Daten interpretieren und verstehen deren Bedeutung zur Erkennung von Mustern in Daten.
		anwenden	Sie können für ausgewählte Eigenschaften von Daten Streudiagramme mithilfe eines Tools (z.B. Python, bei Vorgabe des Codes – ohne Programmierkenntnisse) erzeugen. Sie können Aussagen über Beziehungen zwischen Eigenschaften von Daten anhand von Scatterplots analysieren.
1.3.6	Mittelwert/ Standardabweichung	analysieren	Die Lernenden kennen Mittelwert und Standardabweichung als statistische Größen und können diese interpretieren. Sie können Mittelwert und Standardabweichung manuell berechnen.

		anwenden	Die Lernenden können die Berechnung von Mittelwert und Standardabweichung in der Praxis mithilfe von Tools (z.B. Python, bei Vorgabe des Codes – ohne Programmierkenntnisse) durchführen.
1.3.7	Korrelation	anwenden	Die Lernenden verstehen das Konzept Korrelation und den Korrelationskoeffizienten als Maß für den linearen Zusammenhang zwischen zwei Faktoren. Sie können den Korrelationskoeffizienten interpretieren und erläutern, wie er berechnet wird.
		begründen	Die Lernenden können z.B. anhand von Scheinkorrelationen erläutern, dass Korrelation nicht Kausalität bedeutet.
1.3.8	Einführung lineare Regression	verstehen, anwenden	Die Lernenden können einfache lineare Regressionsmodelle als Zusammenhang zwischen einer abhängigen/erklärten und einer unabhängigen/erklärenden Variable beschreiben. Sie verstehen die Regressionslinie als Darstellung des Regressionsmodells. Sie können ein einfaches lineares Regressionsmodell für Prognosen anwenden. Sie kennen den Determinationskoeffizienten als Maß für die Güte von Regressionsmodellen. Sie verstehen, dass die Regressionslinie mithilfe der Varianz berechnet werden kann (müssen diese aber nicht selbst berechnen können).
		anwenden	Die Lernenden verstehen, wie man mithilfe von Tools (z.B. Python) in der Praxis ein lineares Regressionsmodell anpassen, bewerten und auf neue Daten anwenden kann.
1.3.9	Multiple lineare Regression	anwenden verstehen	Die Lernenden kennen die multiple lineare Regression als Erweiterung der einfachen linearen Regression auf mehrere erklärende Variablen. Sie können die Parameter eines multiplen linearen Regressionsmodells interpretieren. Sie können den Unterschied zwischen Variablen, die als messbare Größen gegeben sind, und nominalen (kategorialen) Variablen beschreiben. Sie verstehen, dass nominale Variablen mithilfe von Dummy-Kodierung ebenfalls als Faktoren bei der linearen Regression verwendet werden können. Sie können die Parameter eines multiplen linearen Regressionsmodells für die Berechnung einfacher Prognosen anwenden.

1.3.10	Klassifikationsbäume	verstehen, analysieren	Die Lernenden verstehen, dass man bei der Erstellung von Klassifikationsbäumen möglichst nicht-diverse Klassen an den Blättern anstrebt. Sie verstehen, dass man die Diversität mit Maßen wie z.B. dem Gini-Index messen kann. Sie können Klassifikationsbäume interpretieren und auf neue Daten anwenden.
		anwenden	Die Lernenden können in der Praxis mithilfe von Tools (z.B. Python, bei Vorgabe des Codes – ohne Programmierkenntnisse) Klassifikationsbäume auf der Basis von Trainingsdaten erstellen.
1.3.11	Entropie	verstehen	Die Lernenden kennen die Entropie als weiteres Maß für Unordnung (Diversität) und können erläutern, wie man sie beim Training von Entscheidungsbäumen einsetzen kann.
1.3.12	Training von Klassifikationsbäumen	verstehen, begründen	Die Lernenden können in einfachen Worten den Algorithmus zur Erstellung von Klassifikationsbäumen beschreiben. Sie können Overfitting als Problem beim Training von Entscheidungsbäumen erläutern.
		anwenden	Die Lernenden verstehen, wie Tools (z.B. Python, bei Vorgabe des Codes – ohne Programmierkenntnisse) den Algorithmus zur Erstellung von Klassifikationsbäumen umsetzen.
		kennen	Die Lernenden kennen Parameter gegen Overfitting beim Training von Entscheidungsbäumen.
1.3.13	Evaluationsmaße	verstehen, analysieren	Die Lernenden kennen die Accuracy, Precision und Recall als Maße für die Performanz von Klassifikationsmodellen. Sie können erklären, was diese Maße erfassen und beschreiben, wie man sie berechnet. Sie können die Performanz von KI-Modellen mithilfe dieser Maße analysieren. Sie kennen die Konfusionsmatrix zur Darstellung von Klassifikationsergebnissen und können diese analysieren. Sie kennen den F-Score als Maß, das Precision und Recall zusammenfasst. Die Lernenden kennen RMSE als Evaluationsmaß für die Performanz von Regressionsmodellen und verstehen, wie es berechnet wird.
		anwenden	Die Lernenden können Evaluationsergebnisse in der Praxis mithilfe von Tools (z.B. Python,

			bei Vorgabe des Codes – ohne Programmierkenntnisse) berechnen.
1.3.14	Training und Test	verstehen, begründen	Die Lernenden können die Bedeutung einer strikten Aufteilung in Trainings- und Testdaten für die Evaluation von Modellen erläutern. Sie verstehen die Bedeutung von Testdaten für das Erkennen von Overfitting. Sie können Overfitting durch Vergleich der Performanz auf den Trainingsdaten vs. der Performanz auf den Testdaten bestimmen. Sie verstehen die Bedeutung der Repräsentativität der Trainings- und Testdaten. Sie kennen typische Mengen-verhältnisse bzgl. der Menge der Testdaten zur Menge der Trainingsdaten.
		anwenden	Die Lernenden können mithilfe von Tools (z.B. Python, bei Vorgabe des Codes – ohne Programmierkenntnisse) Parameter zur Vermeidung von Overfitting beim Training von Entscheidungsbäumen anwenden.
1.3.15	Cross-Validierung	verstehen, begründen	Die Lernenden können das Konzept der n-fachen Cross-Validierung erläutern.
		anwenden	Die Lernenden verstehen, dass man die n-fache Cross-Validierung mithilfe von Tools (z.B. Python) automatisieren kann und haben sie an praktischen Beispielen ausprobiert.
1.3.16	Distanzfunktionen	verstehen	Die Lernenden können den Begriff Distanzfunktion und insbesondere die Euklidische Distanz erläutern. Sie verstehen, dass die Skalierung der Werte in den verschiedenen Dimensionen die Distanz beeinflusst. Sie kennen Standardisierung als Mittel, den Beitrag aller Dimensionen gleich zu halten. Sie kennen z-scores als Ergebnis der Standardisierung und können diese interpretieren.
		anwenden	Die Lernenden verstehen, wie die Berechnung der Distanz in der Praxis mithilfe von Tools (z.B. Python) funktioniert. Sie kennen die Distanzmatrix als Ergebnis der Berechnung der Distanzen zwischen vielen Datenpunkten.
1.3.17	Instanzbasiertes Lernen	verstehen	Die Lernenden kennen das Konzept instanzbasiertes Lernen als Variante des Maschinellen Lernens, bei der kein Training im engeren

			Sinn stattfindet. Sie kennen Nächste-Nachbarn-Klassifikation und -Regression als Vertreter dieser Variante und können sie in eigenen Worten erklären. Sie verstehen den Einsatz von Distanzfunktionen in diesem Zusammenhang.
		anwenden	Die Lernenden verstehen die Anwendung von Nächste-Nachbarn-Klassifikation und -Regression in der Praxis mithilfe von Tools (z.B. Python). Sie verstehen, warum Dimensionen, die nicht zur Vorhersage beitragen, beim instanzbasierten Lernen problematisch sein können.
		anwenden	Die Lernenden verstehen den Einfluss des Parameters der Anzahl der nächsten Nachbarn bei der Nächste-Nachbarn-Regression.
1.3.18	Neuronen	kennen, verstehen	Die Lernenden kennen Neuronen als Bestandteil von Neuronalen Netzen und können sie in eigenen Worten beschreiben. Sie kennen und verstehen die Begriffe Gewichte, Bias und Logit. Sie verstehen den Effekt der Aktivierungsfunktion auf den Logit zur Modellierung von nichtlinearen Zusammenhängen. Sie können die Sigmoid-Funktion als typische Aktivierungsfunktion nennen. Sie verstehen, wie Neuronen Schicht für Schicht zu neuronalen Netzen kombiniert werden können. Sie kennen den Begriff Hidden Layers/Verborgene Schichten und können ihn erklären. Sie kennen den Begriff tiefe neuronale Netzwerke und können ihn erklären.
1.3.19	Aktivierungsfunktionen	verstehen	Die Lernenden wissen, dass es neuere Alternativen zur Sigmoid-Aktivierung gibt. Sie verstehen, dass diese das Training effizienter machen können. Sie kennen die Softmax-Funktion als Aktivierungsfunktion der obersten Schicht bei Klassifikationsproblemen. Sie verstehen, dass die Softmax-Funktion Klassenwahrscheinlichkeiten als Ergebnis liefert. Sie verstehen, dass Netzwerke für Klassifikationsprobleme pro Klasse ein Ausgangsneuron haben.
1.3.20	Parameter in Neuronalen Netzen	verstehen	Die Lernenden können beschreiben, dass die Gewichte jeder Schicht in einer Gewichtematrix zusammengefasst werden können und dass dadurch die Berechnung der Logits durch Multiplikation mit einer Matrix erfolgt.

			Die Lernenden kennen und verstehen den Begriff Forward Pass und können ihn in einfachen Worten erklären. Die Lernenden verstehen, dass die Gewichte die lernbaren Parameter des Netzwerks darstellen.
1.3.21	Training von neuronalen Netzen	verstehen	Die Lernenden verstehen, dass die lernbaren Parameter beim Training mithilfe der Gradienten der Verlustfunktion automatisch angepasst werden. Sie können den Algorithmus zum Training von neuronalen Netzen in einfachen Worten beschreiben.
1.3.22	Hyperparameter beim Training von neuronalen Netzen	verstehen	Die Lernenden kennen den Begriff Lernrate und können ihn in einfachen Worten erklären. Sie kennen die Begriffe Epoche und Batchgröße/Batch Size und können sie erklären. Sie verstehen das Konzept des Early Stopping und können es erklären. Sie können Grafiken mit der Entwicklung des Verlusts und der Accuracy beim Training analysieren. Sie kennen den Unterschied zwischen Validierungsdaten und Testdaten.
1.3.23	Verlustfunktion	verstehen	Die Lernenden können beschreiben, dass die Verlustfunktion die Entwicklung des Fehlers bei Veränderung der lernbaren Parameter erfasst.
1.3.24	Netzwerkarchitekturen RNN	verstehen	Die Lernenden verstehen die Architektur von Feed Forward Neural Networks/FNNs sowie von Rekurrenten Neuronalen Netzen/RNNs und können sie in eigenen Worten beschreiben. Sie verstehen den Einsatz von RNNs für sequentielle Daten. Sie verstehen, dass RNNs beim Training ausgerollt werden. Sie verstehen, dass dadurch beim Training sehr tiefe Netzwerke entstehen können.
1.3.25	Netzwerkarchitekturen LSTM	verstehen	Die Lernenden können beschreiben, dass Long Short Term Memory (LSTM)-Netze eine Art Gedächtnis modellieren. Sie verstehen, dass beim Training gelernt wird, was im Gedächtnis behalten werden soll. Sie können erläutern, dass die Verbindungen in LSTM-Netzen komplexer sind als in FNNs.
1.3.26	Netzwerkarchitekturen Encoder-Decoder	verstehen	Die Lernenden verstehen, was ein Sequence-to-sequence-Problem ist. Sie können beschreiben, dass Encoder-Decoder-Architekturen geeignet für solche Probleme sind. Sie verstehen, dass Encoder und Decoder zwei Netzwerke sind, die

			gemeinsam trainiert werden. Sie können erläutern, dass für manche Probleme die Performanz von Encoder-Decoder-Netzwerken durch Attention Scores verbessert werden kann.
1.3.27	Netzwerkarchitekturen CNN	verstehen	Die Lernenden kennen die Architektur von Convolutional Neural Networks, insbesondere das Konzept von 1D- und 2D-Filterkernen und die Bedeutung der Parameter "Stride" und Kernlänge bzw. -größe. Sie verstehen den Effekt von MaxPooling-Schichten nach Konvolutionsschichten. Sie kennen Feature Maps als Output von Konvolutionsschichten.
1.3.28	Clustering	verstehen	Die Lernenden verstehen die Bedeutung von Clusterverfahren zur Entdeckung von Strukturen in Daten. Sie verstehen, wie der kMeans-Algorithmus funktioniert sowie den Zusammenhang zwischen Nähe und Ähnlichkeit. Sie erfassen die Bedeutung der Skalierung und den Einfluss der verwendeten Dimensionen auf das Ergebnis. Sie können zwischen partitionierenden und hierarchischen Clusterverfahren unterscheiden. Sie kennen Dendrogramme zur Darstellung der Ergebnisse bei hierarchischen Verfahren und können sie interpretieren. Sie kennen die Principal Components Analyse als Methode zur Dimensionreduktion bei der Clusteranalyse. Sie verstehen die Interpretation der Koeffizienten bei der PCA. Sie verstehen den Einsatz von PCA zur Visualisierung von mehrdimensionalen Daten. Sie können zwischen extrinsischen und intrinsischen Evaluierungsverfahren für die Clusteranalyse unterscheiden. Sie kennen die Silhouette und den Silhouettenplot als Beispiel eines extrinsischen Evaluierungsmaßes und den Rand Index und die Purity als Beispiele für intrinsische Evaluierungsmaße.
		anwenden	Die Lernenden können (z.B. mithilfe von Python-Bibliotheken) eine einfache Clusteranalyse selbst durchführen, mit und ohne Dimensionalitätsreduktion durch PCA, und eine Silhouettenanalyse der Ergebnisse durchführen.
1.3.29	Overfitting/Robustheit	verstehen	Die Lernenden verstehen das Problem von Overfitting und können Fälle von Overfitting

erkennen. Sie kennen Early Stopping, Dropout, L2-Regularisierung und Batch Normalisierung als Techniken, um Overfitting bei neuronalen Netzen zu reduzieren. Sie kennen Data Augmentation sowie die Verwendung von Ensembles als Methoden, um robustere Modelle zu erhalten. Sie kennen Kovariatenverschiebung und Konzeptverschiebung als typische Probleme bei der Anwendung von Modellen nach Abschluss der Testphase. Sie kennen in diesem Zusammenhang die Bedeutung einer laufenden Evaluierung auch in der Anwendungsphase. Sie kennen Transfer Learning und Fine Tuning als Methoden, um der Kovariaten- bzw. der Konzeptverschiebung bei neuronalen Netzen entgegenzuwirken. Sie kennen Adversarial Examples als Problem bei der Anwendung von Neuronalen Netzen.

anwenden

Die Lernenden können beim Training von neuronalen Netzen Methoden zur Vermeidung von Overfitting einsetzen, z.B. mithilfe von Python-Bibliotheken.

1.4. Chancen & Herausforderungen der KI

	Bestandteile der Qualifikationsinhalte	Anwendungstaxonomie	Hinweise zur Vermittlung
1.4.1	Datenschutz	begründen, berücksichtigen	Die Lernenden haben sich mit Datenschutz aus Verbrauchersicht auseinandergesetzt. Sie können das Sammeln von personenbezogenen Daten kritisch diskutieren. Sie wissen, dass Daten in den meisten Fällen nur mit Einwilligung der Verbraucher*innen erhoben werden dürfen. Sie kennen die von der DSGVO vorgegebene Rechte auf Auskunft, Widerspruch, Berichtigung, Löschung gegenüber Unternehmen. Sie wissen, dass Unternehmen bei Verletzung des Datenschutzes mit harten Strafen belegt werden können. Die Lernenden können Beispiele von sensiblen Daten nennen, und erläutern, dass für diese noch strengere Regelungen gelten. Die Lernenden kennen den Begriff "Verzeichnis von Verfahrenstätigkeiten"; sie wissen, wer es im Unternehmen führen muss und können erklären, warum es benötigt wird.

	begründen, berücksichtigen	Die Lernenden kennen weitere Rechte der Verbraucher im Zusammenhang mit personenbezogenen Daten. Sie kennen und können die Pflichten der Unternehmen in diesem Zusammenhang beschreiben: Datenminimierung, Speicherbegrenzung, Zweckbindung, sowie die Verpflichtung, Daten sachlich richtig und aktuell zu halten. Sie können die Bedeutung der Datensicherheit im Rahmen des Datenschutzes erklären.	
	begründen, berücksichtigen	Die Lernenden kennen den Begriff Datenschutz und können ihn erklären. Sie kennen den Begriff "besondere personenbezogene Daten" und können ihn erklären. Sie können erläutern, dass die Verarbeitung von personenbezogenen Daten im Normalfall nur mit Einwilligung erlaubt ist und wissen, dass diese Einwilligung bestimmten Anforderungen entsprechen muss. Sie können beschreiben, dass es neben den Basisanforderungen (wie Datenminimierung, Speicherbegrenzung, etc.) auch formale Anforderungen gibt, die gesetzlich geregelt sind. Sie kennen die arbeitsrechtlichen und strafrechtlichen Folgen von Datenschutzverstößen. Sie verstehen den Begriff "technische und organisatorische Maßnahmen" und können ihn erklären (siehe auch Thema Datensicherheit). Sie kennen das Konzept der Pseudonymisierung zum Schutz von personenbezogenen Daten. Sie kennen die Aufgaben der/des Datenschutzbeauftragten und können diese in einfachen Worten beschreiben. Sie können für den Datenschutz kritische Situationen am Arbeitsplatz beschreiben und erklären, wie man sie vermeiden kann.	
	beurteilen	Die Lernenden können Beispiele von Datenschutzverstößen kritisch bewerten.	
	bewerten	Die Lernenden können die Vermarktung von personenbezogenen Daten kritisch bewerten.	
1.4.2	Algorithmischer Bias	kennen, erläutern	Die Lernenden können den Effekt von unausgewogenen/unfairen Trainingsdaten beim maschinellen Lernen beschreiben.
		verstehen, analysieren kennen	Die Lernenden kennen den Begriff algorithmischer Bias/ alg. Voreingenommenheit und können ihn erklären. Sie verstehen, dass algorithmischer Bias zu Diskriminierung führen

kann. Die Lernenden können Ursachen für algorithmischen Bias nennen.

1.4.3	Erklärbarkeit	verstehen	Die Lernenden verstehen, dass die Parameter einfacher Lernverfahren interpretierbar sind. Sie können beschreiben, dass Entscheidungen der Modelle dadurch erklärbar/nachvollziehbar sind. Sie verstehen, dass die Interpretation der einzelnen Parameter bei neuronalen Netzen aufgrund der Menge nicht möglich ist.
		verstehen	Die Lernenden kennen die Visualisierung von Filterkernen und Feature Maps in CNNs als Beispiel zur Erklärung der Parameter bzw. der im Netzwerk entstehenden Repräsentationen und können diese an einem einfachen Beispiel selbst durchführen.

1.5. Praktisches Projekt

	Bestandteile der Qualifikationsinhalte	Anwendungstaxonomie	Hinweise zur Vermittlung
1.5.1	Praktisches Projekt	anwenden	Die Lernenden können das Gelernte in einem eigenen praktischen Projekt anwenden.

1.6. Grundkenntnisse Programmierung und KI-Systementwicklung

	Bestandteile der Qualifikationsinhalte	Anwendungstaxonomie	Hinweise zur Vermittlung
1.6.1	Grundzüge der Programmierung z.B. mit Python	beherrschen	Die Lernenden kennen folgende Konzepte und können sie in einfachen Programmierprojekten selbst umsetzen: Datenverwaltung mit Variablen, Ein- und Ausgabe bei Programmen, Datentypen inkl. Zeichenketten, Rechenoperationen und logische Operatoren, Fallunterscheidungen, Schleifen, Zufallszahlen, Modularisierung durch Funktionen, Datenstrukturen.
1.6.2	Datenanalyse und Modelltraining z.B. mit Python	durchführen	Die Lernenden können einfache Programmierprojekte zu Datenanalyse und Modelltraining selbst umsetzen. Insbesondere können sie, z.B. mithilfe von Python-Bibliotheken: Daten in Trainings-, Test- und Validierungsdaten aufteilen, Daten standardisieren, einfache neuronale Netze (z.B. FNNs)

			trainieren, 1D-CNNs zur Analyse von Zeitreihen trainieren, 2D-CNNs zur Bilderkennung trainieren, Techniken zur Vermeidung von Overfitting einsetzen, Modelle evaluieren, bestehende Modelle durch Transfer Learning für neue Aufgaben einsetzen.
1.6.3	Einführung in die Software-Systementwicklung	zuordnen	Die Lernenden kennen die verschiedenen Aktivitäten, die bei der Software-Systementwicklung relevant sind und können sie in den Software-Entwicklungslebenszyklus einordnen.
1.6.4	Software-Anforderungen	analysieren	Die Lernenden verstehen den Prozess der Anforderungsanalyse bei Software-Systemen. Sie können konkrete Anwendungsfälle und Problemdomänen analysieren und funktionale und nichtfunktionale Anforderungen erheben. Die Lernenden verstehen die speziellen Anforderungen von KI-Systemen und können einschätzen, wann eine KI-Lösung sinnvoll ist.
1.6.5	Software-Architektur & -Design	verstehen	Die Lernenden verstehen den Begriff Software-Architektur und können. Sie können simple Architekturdiagramme verstehen und Systeme im Grobentwurf planen. Die Lernenden kennen gängige KI-Komponenten und verstehen, wie diese in die Software-Architektur eingebunden werden können. Sie verstehen die grundlegenden Unterschiede zwischen verschiedenen Deployment-Konfigurationen bei KI-Systemen.
1.6.6	Software-Qualität	überprüfen	Die Lernenden verstehen die Bedeutung des Begriffes Qualität bei Software-Systemen und kennen die wichtigsten Qualitätsattribute nach ISO25010. Sie können bestehende Software-Systeme nach Qualitätskriterien beurteilen und verstehen, wie den Entwurf von Software-Systemen beeinflussen. Sie verstehen, welche zusätzlichen Qualitätsattribute bei KI-Systemen relevant sind.
1.6.7	Software-Testing	verstehen	Die Lernenden können verstehen, wie Testvorgänge in Software-Systemen ablaufen. Sie können Sie wichtige Begriffe im Testen verstehen. Sie verstehen, welche besonderen Unterschiede beim Testen in KI-basierten Systemen relevant sind.

2. Mitgestalten und Umsetzen von (Veränderungs-)Prozessen und Projekten

2.1. Prozessmanagement

	Bestandteile der Qualifikationsinhalte	Anwendungstaxonomie	Hinweise zur Vermittlung
2.1.1	(KI relevante) Prozesse zur Zielerreichung	erfassen festlegen	Risikomatrix erstellen, ABC- und Pareto-Analyse
2.1.2	Prozessüberwachung, -prüfung, -bewertung	kennen unterscheiden	ABC-Analyse, Pareto-Analyse, Tabellenauswertung (inkl. Visualisierung)

2.2. Zukunftsorientiertes Arbeiten in Projekten

	Bestandteile der Qualifikationsinhalte	Anwendungstaxonomie	Hinweise zur Vermittlung
2.2.1	Projektergebnisse	darstellen	Projektergebnisse aufbereiten und präsentieren
2.2.2	Zwischen- und Abschlussberichte	erstellen	unter Berücksichtigung technischer, organisatorischer und betriebswirtschaftlicher Zusammenhänge sowie Nachhaltigkeitsaspekte
2.2.3	agile Projektmethoden	kennen anwenden	Kenntnisse von verschiedenen Rollen, Aufgaben und Verantwortungsbereichen (innerhalb der Methoden) auch mit Blick auf Zusammenarbeit auf Distanz

3. Rechtliche Grundlagen

3.1. Rechtliche Grundlagen

	Bestandteile der Qualifikationsinhalte	Anwendungstaxonomie	Hinweise zur Vermittlung
3.1.1	Unternehmensrechtsformen	kennen zuordnen	
3.1.2	Vertragsarten	kennen zuordnen	
3.1.3	Datenschutz	kennen beachten	
3.1.4	Datensicherheit	kennen beachten	

3.1.5	Urheber- und Patentrecht	kennen	relevante Rechtsgrundlagen
3.1.6	Steuerarten & Steuerberechnung	kennen	In Bezug auf relevante Steuerarten bei Auswahl von Vertragsarten und Abschluss von Verträgen

4. Abwägung und Beurteilung ökonomischer Aspekte

4.1. Abwägungsmethoden

	Bestandteile der Qualifikationsinhalte	Anwendungs-taxonomie	Hinweise zur Vermittlung
4.1.1	Kosten-Nutzen-Analyse	kennen auswählen	Einsatzmöglichkeiten und Grenzen, Verfahren und Arten der Kosten-Nutzen-Analyse, Einflussfaktoren und Entscheidungs-parameter Kalkulation und Investitions-rechnung unter Beachtung von Aspekten der Nachhaltigkeit Erfassen von Kosten (Zuordnung von monetären und nicht monetären Kostenaspekten evtl. via Case Study)
		einordnen durchführen anwenden	Aufbereitung und Interpretation von Analyseergebnissen inkl. Transferaufgaben (Schwerpunkt: sich ändernde Rahmenbedingungen) Business-Plan-Erstellung

4.2. ökonomische Aspekte

	Bestandteile der Qualifikationsinhalte	Anwendungs-taxonomie	Hinweise zur Vermittlung
4.2.1	Grundzüge des Controllings	kennen anwenden	Branchenspezifika kennen und in Abwägungsprozesse eingliedern, Kosten-Leistungs-Rechnung erstellen
4.2.2	Grundlagen der Finanzierung und Finanzierungsarten	kennen	Kreditfinanzierung, Leasing, Eigenfinanzierung etc.

5. Zukunftskompetenzen

5.1. Metakompetenzen

	Bestandteile der Qualifikationsinhalte	Anwendungstaxonomie	Hinweise zur Vermittlung
5.1.1	Selbstorganisation	überblicken beherrschen einsetzen	Systementwicklung zur effizienten Gestaltung von Abläufen im Beruf und Privatleben. (Sie bildet die Grundlage für eine strukturelle Ordnung, welche auf bevorstehende Herausforderungen angepasst ist. Selbstorganisation ist also ein Mittel, um Teams und Organisationen erfolgreicher zu gestalten. In der Betriebswirtschaft und Organisationsberatung wird der Begriff auch teilweise als Gegenteil zur Hierarchie verwendet – also der Organisation des Einzelnen.)
5.1.2	Selbstreflexion	anwenden	3 Reflexionsebenen positiv beeinflussende Faktoren zur Selbstreflexion

5.2. Zukunftskompetenzen / interaktive Kompetenzen

	Bestandteile der Qualifikationsinhalte	Anwendungstaxonomie	Hinweise zur Vermittlung
5.2.1	Kommunikationskompetenz	verstehen beherrschen fördern	Definition von Kommunikation Rhetorik üben Fachtermini übersetzen, Kommunikationstraining
5.2.2	Problemlösekompetenz und -methoden	umsetzen anwenden	Problemlösekompetenz entwickeln lösungsorientierte Methoden anwenden
5.2.3	Zeitmanagement	anwenden	Zeitmanagementmethoden überblicken, Möglichkeiten der Themenplanung kennen

5.3. Agiles Arbeiten

	Bestandteile der Qualifikationsinhalte	Anwendungstaxonomie	Hinweise zur Vermittlung
5.3.1	Agile Arbeitsmethoden	kennen anwenden	selbstorganisiertes Arbeiten, Rollen innerhalb eines agiles Teams, Meetingformate und -konzepte, Methoden zur Entscheidungsfindung
5.3.2	Interkulturelle und interdisziplinäre Zusammenarbeit	kennen verstehen	Bedingungen guter interkultureller und interdisziplinärer Zusammenarbeit