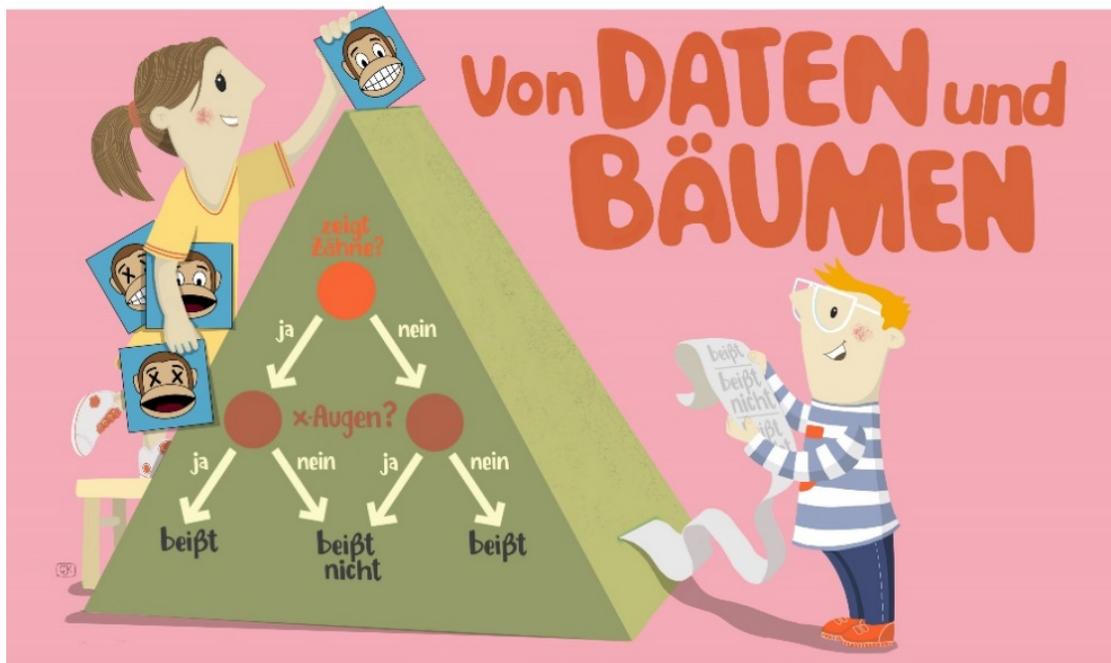


IT2School

Gemeinsam IT entdecken



KI-B4 Von Daten und Bäumen

Daten mit KI selbst auswerten

Eine Entwicklung in Kooperation von:

Inhalt

1	Von Daten und Bäumen	3
2	Warum gibt es das Modul?	4
3	Ziele des Moduls.....	4
4	Die Rolle der Unternehmensvertreterin/des Unternehmensvertreters.....	5
5	Inhalte des Moduls.....	5
1.	Klassifikation	5
2.	Over- und Underfitting	8
3.	Bewertung der Güte eines Modells	9
4.	Bias	11
5.	Orange3.....	12
6	Unterrichtliche Umsetzung.....	14
6.1	Grober Unterrichtsplan	15
6.2	Stundenverlaufsskizzen.....	16
6.2.1	Stunde 1: Datenanalyse und Entscheidungsbaum	16
6.2.2	Stunde 2-3: Datenanalyse mit Orange3	19
6.2.3	Stunde 4-6: Projektarbeit (nur Variante II).....	22
6.2.4	Stunde 7: KI und unsere Gesellschaft.....	24
7	Einbettung in verschiedene Fächer und Themen	25
8	Anschlussthemen.....	25
9	Literatur und Links	26
10	Arbeitsmaterialien	26
11	Glossar.....	27
12	Fragen, Feedback, Anregungen.....	28

1 Von Daten und Bäumen

In diesem Aufbaumodul wenden die Schülerinnen und Schüler KI-Methoden (vorwiegend das Lernen von Entscheidungsbäumen) aktiv auf **Daten** an und analysieren die gesellschaftliche Wirkung von KI-Systemen. Aufbauend auf den niederschweligen Beispielen, die auch im Modul "Schlag den Roboter" genutzt wurden, schlüpfen die Schülerinnen und Schüler in die Rolle eines Data Scientist und erzeugen mithilfe der freien Software Orange3 Modelle, um datenbasiert Entscheidungen abzuleiten oder Vorhersagen zu treffen. Die Schülerinnen und Schüler setzen damit nicht nur KI-Methoden aktiv ein, sondern lernen auch Berufsperspektiven wie die des Data Scientist kennen und diskutieren die gesellschaftliche Wirkung, die aus dem Einsatz ihrer Modelle resultieren würde.

Lernfeld/Cluster:	Mit KI gestalten
Zielgruppe/Klassenstufe:	4. bis 5. Klasse
	6. bis 7. Klasse
	X 8. bis 10. Klasse
	X 11. bis 12. Klasse
Geschätzter Zeitaufwand:	2 bis 8 Unterrichtsstunden, auch als Projekttag umsetzbar
Lernziele:	<p>Nach Abschluss des Teilmoduls können die Schülerinnen und Schüler...</p> <ul style="list-style-type: none"> • Probleme erläutern, in denen KI gewinnbringend eingesetzt werden kann (Welche Probleme werden bereits mit KI gelöst?). • Probleme unter Nutzung von KI-Methoden lösen (Wie kann ich KI nutzen, um Probleme zu lösen?). • Konsequenzen aus dem Einsatz von KI-Methoden diskutieren und bewerten. (Welche Konsequenzen hat der Einsatz von KI-Methoden auf uns und unsere Gesellschaft? Wo liegen die Gefahren von KI?) • Einsatzmöglichkeiten von KI-Methoden als "Werkzeug" bspw. bei der beruflichen Tätigkeit beschreiben (Wie arbeitet ein Data Scientist? Was kann ich mit KI später (beruflich) machen?).
Vorkenntnisse der Schülerinnen und Schüler:	<p>Empfohlen:</p> <ul style="list-style-type: none"> • Basismodul „Schlag den Roboter“
Vorkenntnisse der/des Lehrenden:	<p>Empfohlen:</p> <ul style="list-style-type: none"> • Basismodul „Schlag den Roboter“
Vorkenntnisse der Unternehmensvertreterin/des Unternehmensvertreters:	<p>Empfohlen:</p> <ul style="list-style-type: none"> • Beispiele für KI-Anwendungen aus dem eigenen Unternehmen benennen und erläutern können
Sonstige Voraussetzungen:	<ul style="list-style-type: none"> • Zugang zu Computern mit installierter Software Orange3 (kann ohne Administratorrechte installiert werden)



2 Warum gibt es das Modul?

Viele Anwendungen aus unserem Alltag basieren auf dem maschinellen Lernen, wie etwa Film- oder Musik-Streaming-Dienste. Diese Dienste sammeln Daten der Nutzerinnen und Nutzer, um ihre Vorlieben kennenzulernen, sie zu kategorisieren und um daraus passende Empfehlungen abzuleiten. Die Programme lernen durch die vielen Nutzerdaten, welche Inhalte sie welchen Nutzern vorschlagen können. Auch in anderen Bereichen, wie etwa im Gesundheitssektor zur besseren Erkennung von Krankheiten, wird das maschinelle Lernen eingesetzt. Zentral für maschinelles Lernen ist die Nutzung und Verwertung großer Mengen von Daten. Mit Hilfe von Beispieldaten lernt die Maschine und wird dann mit der Zeit und dem Zugriff auf noch mehr Daten, immer besser in ihren Berechnungen.

In diesem Modul wird der Fokus auf genau diese Daten gelegt, um das Phänomen des maschinellen Lernens zu erläutern. Diese Herangehensweise ermöglicht es auch Lernern ohne Programmiererfahrung, KI-Methoden zu verstehen und anzuwenden und die Hintergründe aktueller Fragestellungen gesellschaftlicher Tragweite selbst zu entdecken. Die Schülerinnen und Schüler haben darüber hinaus die Möglichkeit, realistische Szenarien aus dem Alltag zu diskutieren und einen Eindruck davon zu gewinnen, wie KI ihren eigenen Berufsweg beeinflussen kann. Durch das Verstehen der Funktionsweise, erhalten die Kinder und Jugendlichen einen kritischen Blick auf solche Systeme. Sie können ihr Verhalten und Nutzungsgewohnheiten reflektieren und werden in die Lage versetzt, selbstbestimmte Entscheidungen zu treffen, die nicht allein durch Maschinen gelenkt werden.

Durch den Fokus auf Daten ergeben sich im Rahmen dieses Moduls unterschiedliche Einsatz- bzw. Anknüpfungsmöglichkeiten für eine Vielzahl von Fächern, etwa in den Naturwissenschaften oder im Wirtschaftsunterricht.

3 Ziele des Moduls

Das Modul trägt auf vielfältige Weise zu den drei Dagstuhl-Perspektiven bei:

- Aus technologischer Perspektive lernen Schülerinnen und Schüler in diesem Modul typische Herangehensweisen für die Lösung von KI-Problemen mithilfe von maschinellem Lernen kennen.
- Aus anwendungsbezogener Perspektive erfahren die Schülerinnen und Schüler vielfältige Anwendungen von KI. Außerdem wird thematisiert, wie KI für die eigene berufliche Zukunft zur Auswertung von Daten (auch im Beruf) genutzt werden kann.
- Aus gesellschaftlich-kultureller Perspektive werden Konsequenzen des Einsatzes von KI-Methoden diskutiert und unter ethischen und moralischen Gesichtspunkten bewertet.

4 Die Rolle der Unternehmensvertreterin/des Unternehmensvertreters

In diesem Modul hat die Unternehmensvertreterin bzw. der Unternehmensvertreter mehrere Möglichkeiten aktiv mitzuwirken. Hier einige Anregungen:

- Als Special Guest in der Schule über die Bedeutung von maschinellem Lernen in der Wirtschaft und insbesondere im eigenen Unternehmen berichten
- Schülerinnen und Schülern eine Exkursion in das eigene Unternehmen ermöglichen und zeigen, wie Künstliche Intelligenz in der Praxis eingesetzt wird
- Fragen & Antworten-Runden mit „KI-ExpertInnen“ oder Data Scientists des eigenen Unternehmens organisieren, die berichten, warum sie sich für ein Studium im Bereich Informatik / Data Science entschieden haben
- „Kreativworkshop“ oder „Wettbewerb“ ausrichten, wie das Gelernte im Alltag der Schülerinnen und Schüler eingesetzt werden könnte und nach bestimmten Bewertungskriterien (Kreativität, Umsetzbarkeit, Innovationsgrad...) die entwickelten bzw. eingereichten Ideen bewerten
- Unterstützung von Jugend-forscht-Projekten im Bereich KI, die sich aus dem Unterricht ergeben

5 Inhalte des Moduls

Es lassen sich drei Arten unterscheiden, wie Maschinen „lernen“ können (siehe dafür das Basismodul KI-B3 „Schlag den Roboter“). In diesem Modul soll das überwachte Lernen vertieft werden. Hier werden dem Programm beschriftete Trainingsdaten zur Verfügung gestellt, auf deren Grundlage das Programm lernt, auch weiteren Daten eine Beschriftung zuzuordnen. Die wesentlichen Begriffe und Funktionen werden im Folgenden näher erläutert.

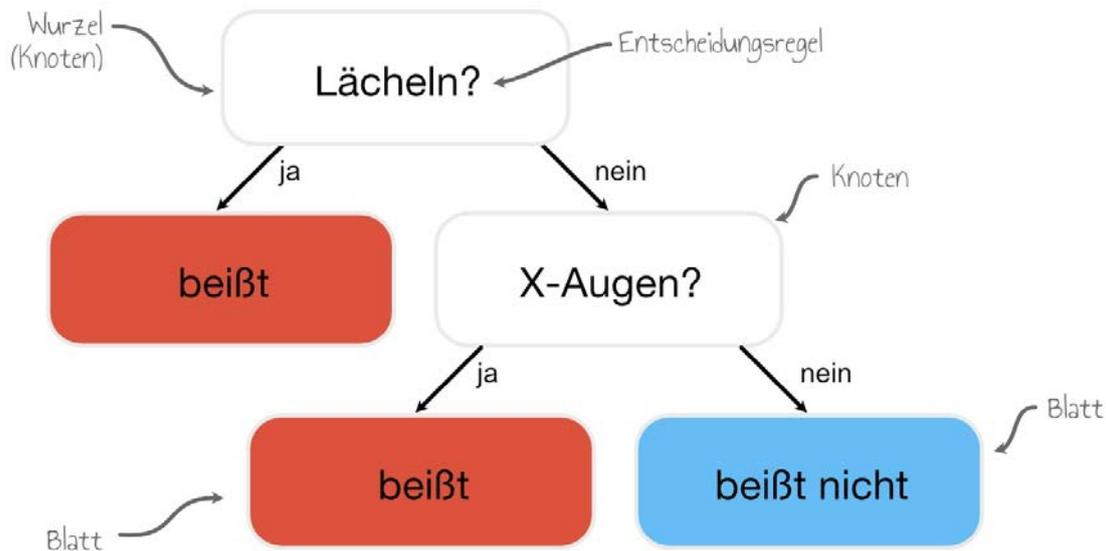
5.1 Klassifikation

Ein häufiger Einsatzzweck von überwachten Lernverfahren sind sogenannte Klassifikationsprobleme. Bei Klassifikationsproblemen lernt das Programm neuen Daten eine Kategorie zuzuordnen. Je nach Anwendungsbereich können dann beispielsweise medizinische Bilder in die Klassen „Tumor“ oder „kein Tumor“ sortiert werden oder bei der Bewertung der Bonität eines Bankkunden in die Klassen „kreditwürdig“ bzw. „nicht kreditwürdig“. Die Funktionsweise solcher Verfahren wird in diesem Modul anhand eines „Äffchen-Spiels“ verdeutlicht, wobei Äffchen aufgrund ihres Aussehens als „beißt“ oder „beißt nicht“ klassifiziert werden. In diesen Beispielen existieren jeweils nur zwei Klassen. In anderen Anwendungsfällen, z.B. bei der Erkennung des Inhalts auf Bildern können viele weitere Klassen zur Anwendung kommen, z.B. Hund, Katze, Maus, Straßenschild, Tisch, ...

Überwachte Lernverfahren erhalten eine Reihe von Trainingsdaten mit entsprechenden Beschriftungen. Sie lernen in der sogenannten Trainingsphase selbständig eine Verbindung zwischen Trainingsdaten und Beschriftung, ein sogenanntes „Modell“. In unserem Beispiel ist dieses Modell ein Entscheidungsbaum. Dieses Modell, wie z.B. der Entscheidungsbaum, kann dann auf beliebige Eingabedaten angewendet werden und die Klassen für Daten vorhersagen.

Klassifikation mittels Entscheidungsbaum

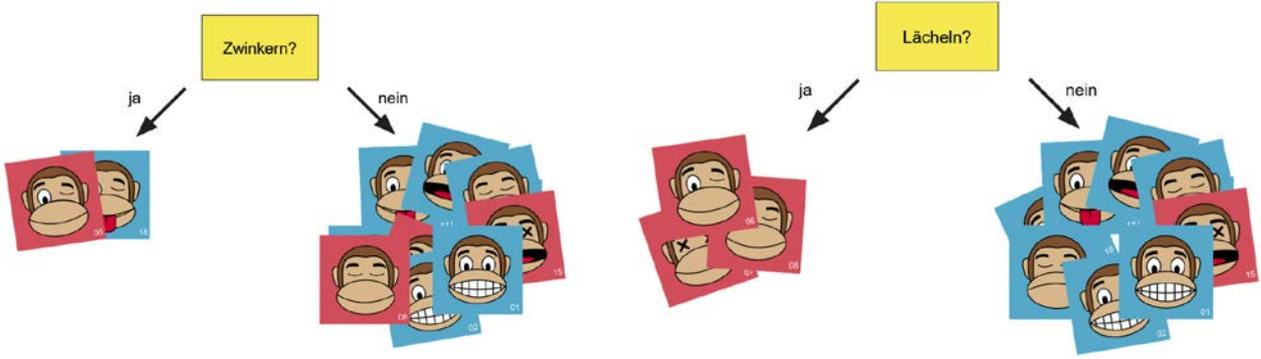
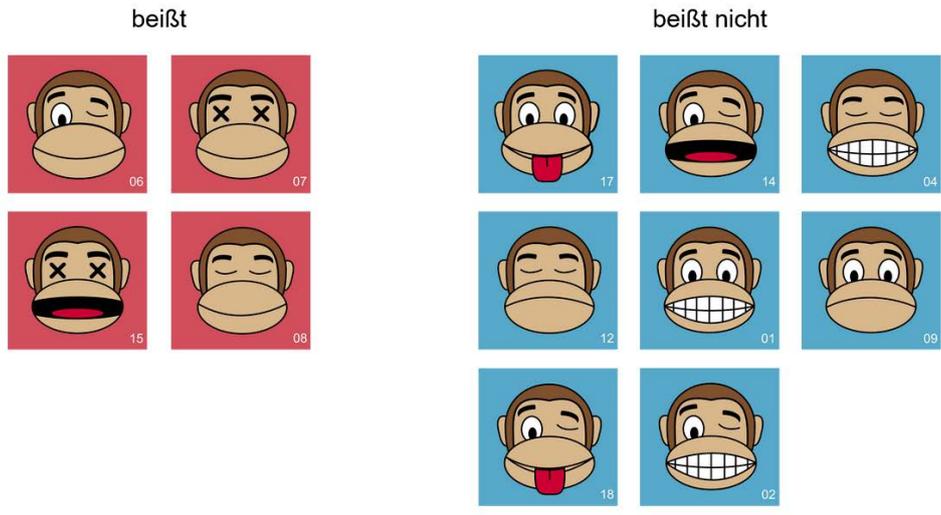
Ein häufig genutztes überwachtes Lernverfahren zur Klassifikation stellt das sogenannte Lernen von Entscheidungsbäumen (Decision tree learning) dar. Mit dem Begriff „Baum“ wird eine Datenstruktur aus der Informatik bezeichnet, mit der sich hierarchische Strukturen abbilden lassen. In einem sog. Entscheidungsbaum sind Entscheidungsregeln dargestellt.



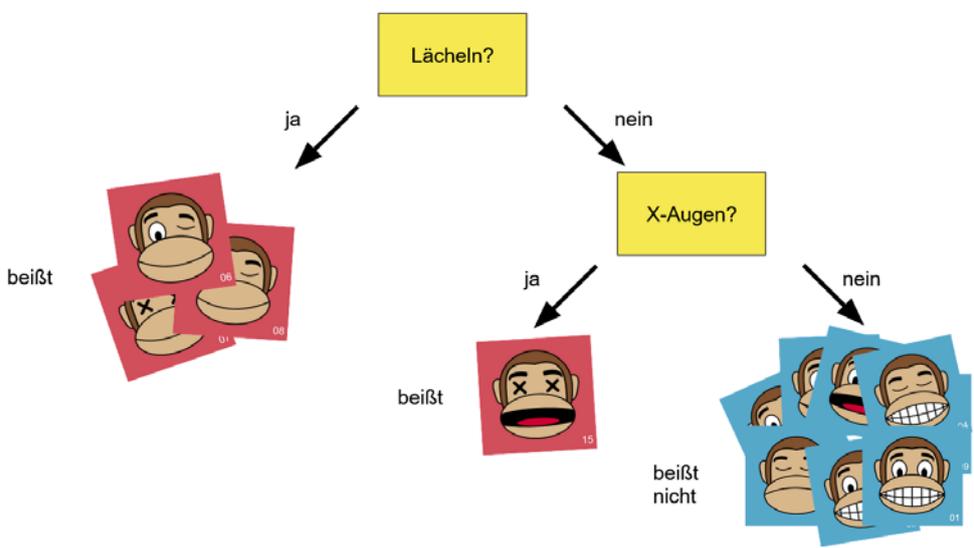
Ein **Knoten** (eine Abzweigung im Baum) repräsentiert eine zu treffende Entscheidung. Jeder Knoten kann je nach möglichen Entscheidungen mehrere Kinder (d.h. untergeordnete Knoten) haben. Der oberste Knoten wird als **Wurzel** bezeichnet. Hat ein Knoten keine Kinder, so sprechen wir von einem **Blatt**. In der Regel ergibt sich aus dem Blatt, an dem ein Datensatz nach Durchlaufen des Baumes endet, welcher Klasse er angehört. Mit Hilfe des Entscheidungsbaums können also Daten klassifiziert werden. Wenn bspw. ein Äffchen durch einen zugehörigen Entscheidungsbaum verarbeitet wird, entscheidet der letzte Knoten, nachdem alle Entscheidungsregeln ausgewertet wurden, über die Klasse, also entweder beißt, oder beißt nicht.

Beim Lernen von Entscheidungsbäumen werden in der Trainingsphase alle Trainingsdaten beginnend bei der Wurzel sukzessive mithilfe von Entscheidungsregeln aufgeteilt. Dabei wird stets die Regel gewählt, die am meisten Information über die zu vergebende Beschriftung liefert¹.

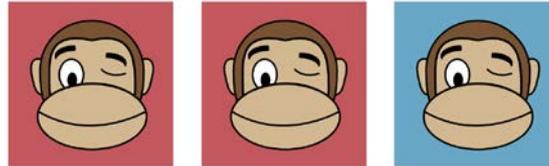
¹ Viele Algorithmen berechnen hierfür den sogenannten Informationsgewinn: https://de.wikipedia.org/wiki/Iterative_Dichotomiser_3



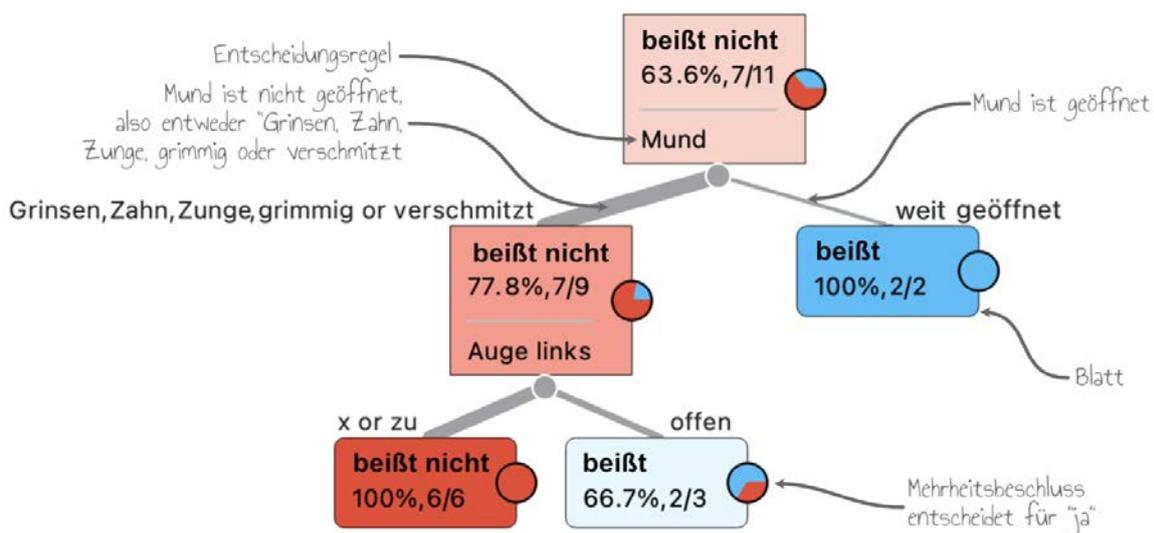
Im obigen Beispiel etwa liefert die Entscheidungsregel „Lächeln?“ deutlich mehr Information über die Beschriftung *beißt* bzw. *beißt nicht* als die Regel „Zwinkern?“. Entsprechend wählt das Lernverfahren selbstständig „Lächeln?“ als erste Entscheidungsregel aus. Dieses Vorgehen wird so lange wiederholt, bis entweder nur Äffchen mit der der gleichen Beschriftung übrig sind oder keine weiteren Merkmale zur Unterscheidung der Äffchen existieren. Der resultierende Baum für dieses Beispiel ist untenstehend abgebildet.



Gerade in realweltlichen Datensätzen und auch in diesem Beispiel, kann der Fall auftreten, dass sich die Daten in einem Knoten nicht weiter unterscheiden lassen. Betrachten wir dazu folgendes weitere Beispiel: Die Äffchen, deren Mund nicht geöffnet und deren linkes Auge geöffnet ist, unterscheiden sich nur noch bezüglich ihrer Beschriftung (beißt/beißt nicht), nicht aber in ihren Merkmalen.



In diesem Falls entscheidet der Mehrheitsbeschluss: Im Beispiel ist die Mehrheit der Äffchen beißend, daher wird die Klasse "beißt" vergeben. In der Software Orange, dem Werkzeug das in diesem Modul genutzt wird, ist das wie folgt visualisiert:



(Binärer) Entscheidungsbaum in Orange3

Von einem sogenannten binären Entscheidungsbaum sprechen wir, wenn jeder Knoten genau zwei oder keine Kinder hat.

5.2 Over- und Underfitting

Ziel des Lernprozesses ist es, ein Modell zu erhalten, das für den Anwendungsfall gute Ergebnisse liefert. Dabei kann es allerdings auch zu Problemen kommen. Beispielsweise kann es passieren, dass sich ein Modell zu stark an die Trainingsdaten anpasst und infolgedessen kaum auf neue Daten generalisieren kann. Dies könnte man auch mit „Auswendiglernen“ vergleichen. Das Programm wurde mit Hilfe der vorgegebenen Daten so trainiert, dass es nur mit den vorhandenen Daten gut funktioniert. Der Algorithmus ist aber nicht mehr in der Lage mit neuen Eingaben umzugehen. Man spricht in diesem Fall von einer Überanpassung (**Overfitting**).

Auf der anderen Seite kann es auch zu einer Unteranpassung (**Underfitting**) kommen, wenn das Modell aus den Trainingsdaten nicht genug über die zugrunde liegende Struktur der Daten lernen kann und deshalb zu stark generalisiert, sodass keine zufriedenstellenden Ergebnisse auf neuen Daten erzielt werden können. Es können aus den vorhandenen Daten einfach keine

sinnvollen Schlüsse gezogen werden, um auf Grundlage dessen neue Daten zu kategorisieren.

Um ein solches Over- bzw. Underfitting vor dem Einsatz in der Praxis aufzudecken, wird das Modell zunächst getestet.

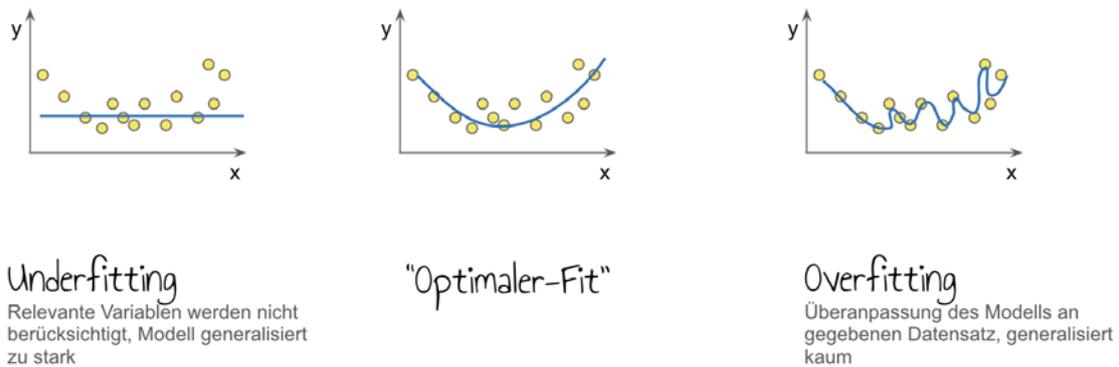


Abb.: Beispiel für Overfitting und Underfitting sowie dem „optimalen Fit“ bei einem einfachen Modell

5.3 Bewertung der Güte eines Modells

Um ein Modell zu testen werden Testdaten verwendet. Auch für diese Testdaten (wie für die Trainingsdaten) ist die Beschriftung, also tatsächliche Klasse der Daten, bekannt. Bei unseren Äffchen wissen wir also, ob sie beißen oder nicht. Um zu bewerten, wie „gut“ das Modell die Testdaten klassifiziert, wird die Güte des Modells bestimmt. Dazu wird das Modell auf die Testdaten angewendet. Anschließend vergleiche wir die vom Modell vorhergesagten mit den eigentlichen Beschriftungen.

Wenn bei einem Klassifikationsproblem nur zwei Klassen zu unterscheiden sind (wie „beißt“ und „beißt nicht“), bietet es sich an, die Ergebnisse dieses Vergleichs als Tabelle (sog. Konfusionsmatrix) darzustellen.

		Predicted		Σ
		ja	nein	
Actual	ja	4	0	4
	nein	1	8	9
Σ		5	8	13

Konfusionsmatrix: Vom Modell vorhergesagte Klassen (Predicted) werden spaltenweise, die tatsächlichen Klassen (Actual) zeilenweise eingetragen.

Anhand dieser Tabelle sind vier wichtige Fälle zu unterscheiden

- **True positive (TP)** (Richtig positiv): Fälle, in denen das Modell **ja** vorhergesagt hat und die tatsächliche Klasse ebenfalls **ja** war (Beispiel: in obiger Konfusionsmatrix: 4). Beispielsweise hat das Modell ein Äffchen als beißend klassifiziert und tatsächlich ist das Äffchen auch beißend.
- **True negative (TN)** (Richtig negativ): Fälle, in denen das Modell **nein** vorhergesagt hat und die tatsächliche Klasse ebenfalls **nein** war (Beispiel: in obiger Konfusionsmatrix: 8). Das Äffchen beißt nicht und wurde auch als „nicht beißend“ klassifiziert.
- **False positive (FP)** (Falsch positiv): Fälle, in denen das Modell **ja** vorhergesagt hat und die tatsächliche Klasse aber **nein** war (Beispiel: in obiger Konfusionsmatrix: 1). Das Modell hat das Äffchen als beißend klassifiziert, allerdings war das Äffchen tatsächlich als nicht beißend kategorisiert.
- **False negative (FN)** (Falsch negativ): Fälle, in denen das Modell **nein** vorhergesagt hat und die tatsächliche Klasse aber **ja** war (Beispiel: in obiger Konfusionsmatrix: 0). In diesem Fall hat das Modell das Äffchen als nicht beißend klassifiziert, allerdings beißt es doch.

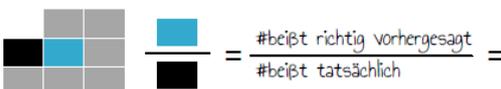
Mithilfe dieser Konfusionsmatrix lassen sich nun verschiedene Metriken zur Bewertung der Güte ganz einfach bestimmen. Zu den bekanntesten Metriken gehören dabei die **Genauigkeit** (accuracy), die **Trefferquote** (recall) und **Präzision** (precision).

Genauigkeit (accuracy): Die Genauigkeit gibt an, wie viele aller Fälle korrekt klassifiziert wurden, also:

$$\text{Genauigkeit} = \frac{TP+TN}{TP+TN+FP+FN}$$

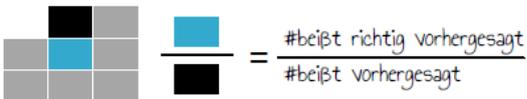

Genauigkeit stellt die allgemeinste Metrik dar und bietet sich beispielsweise dann an, wenn es darum geht, Hunde von Katzen zu unterscheiden, und beide Klassen ungefähr gleich oft in den Trainingsdaten vorkommen.

Trefferquote (recall): Die Trefferquote (oder Sensitivität) wiederum misst, wie viele der tatsächlich positiven Fälle richtig erkannt wurden:

$$\text{Trefferquote} = \frac{TP}{TP + FN}$$


Dies ist beispielsweise hilfreich, wenn hohe Kosten dadurch entstehen, dass kranke Personen (in der Medizinsprache *positiv* getestet) nicht erkannt werden. Vielleicht erinnern Sie sich noch an die Diskussionen bei der Einführung der Corona-Tests. Auch hier ging es um die Sensitivität der Tests.

Präzision (precision): Die Präzision gibt an, wie gut (oder wie präzise) das Modell tatsächlich positive Fälle erkennt:

$$\text{Präzision} = \frac{TP}{TP + FP}$$


Präzision eignet sich dann als Metrik, wenn die Kosten für falsch positive Fälle sehr hoch sind, beispielsweise wenn eine gesunde Person durch eine falsche Vorhersage des Modells eine teure und die Gesundheit beeinträchtigende Chemotherapie erhält.

Je nach Problem kann mal die eine und mal die andere Metrik besser geeignet sein, um die Güte des Modells zu bewerten.

Wenn, beispielsweise mithilfe dieser Metriken, beim Testen festgestellt wurde, dass das KI-Modell keine zufriedenstellenden Ergebnisse liefert, können sowohl die zum Training verwendeten Daten als auch Auswahl und Konfiguration des eingesetzten Verfahrens überarbeitet werden.

5.4 Bias

Von Algorithmen erhoffen wir uns im Allgemeinen faire und objektive Entscheidungen auf der Grundlage von Fakten, die im Gegensatz zu unseren menschlichen Entscheidungen, nicht von Emotionen, Stimmungen oder einseitigen Erfahrungen beeinflusst werden. Dennoch lesen wir, trotz Testphase, in den Medien von rassistischen Chatbots, ungerechtfertigten Verurteilungen durch KI und sexistischen Gesichtserkennungssystemen. Ursächlich dafür ist häufig ein Bias (Verzerrung) in den Daten, die zum Training und zum Testen des Modells eingesetzt wurden. Dabei können verschiedene Arten von Bias auftreten. Von einem historischen Bias sprechen wir beispielsweise dann, wenn sich KI-Systeme bei Einstellungsprozessen von Bewerberinnen und Bewerbern nur auf Einstellungsprozesse in der Vergangenheit beziehen. Von einer Stichprobenverzerrung (Selection Bias) ist beispielsweise die Rede, wenn ein Verfahren zur Gesichtserkennung vor allem mit hellhäutigen Männern trainiert wird und die Ergebnisse für dunkelhäutige Frauen deutlich schlechter ausfallen, diese Personengruppe also weniger gut erkannt wird. Nachdem die Test- und Trainingsdaten aus derselben Datengrundlage stammen und damit gegebenenfalls beide durch einen Bias verzerrt sind, zeigen sich daraus resultierende Probleme nicht in der Testphase sondern erst beim Einsatz in der Praxis und wir lesen in den Medien davon.

Maschinelle Lernverfahren leiten lediglich statistische Zusammenhänge aus Daten ab. So können dementsprechend immer nur **Korrelationen** (statistische Beziehungen) und nie **Kausalitäten** (Ursache-Wirkung-Beziehungen) identifiziert werden. Auch das ist bei der Bewertung des Einsatzes von entsprechenden KI-Systemen zu beachten.

Ein KI-System an sich ist also nicht „diskriminierend“ oder „sexistisch“. Aber wir Menschen sind eben oftmals unfair oder voreingenommen und das zeigt sich auch in den von uns produzierten Daten, die wir für maschinelle Lernverfahren heranziehen (etwa bei Bewerbungsprozessen). Damit übertragen wir unsere menschlichen Vorurteile auf die Technologie. Ein Bias kann aber auch durch Fehler in der Datenerhebung der verwendeten Datensätze (Stichprobenauswahl, soziale Erwünschtheit, ...) entstehen. Bias in den verwendeten Daten aufzudecken, ist in der Praxis nicht so einfach: In diesem Modul arbeiten wir zu Beginn mit sehr kleinen Datensätzen, die wir auch händisch auswerten und überblicken können. In der Praxis hingegen, werden

große Datensätze mit Millionen von Datenpunkten verwendet. Wie immer, wenn Informatiksysteme Entscheidungen mit direktem Einfluss auf unser Leben fällen, müssen sie insbesondere auch im Praxiseinsatz gründlich überprüft werden, um sicherzustellen, dass sie auch wie beabsichtigt funktioniert. Genauso wie bei anderen Werkzeugen, muss abgewogen werden, ob und wie wir sie als Gesellschaft einsetzen wollen.

5.5 Orange3

Datenanalyse mit Orange3

Orange3 ist ein Datenanalysetool, das an der Universität Ljubljana entwickelt wird und für alle gängigen Desktop-Betriebssysteme zum Download zur Verfügung steht (<http://orange.biolab.si/>). In Orange werden Datenanalysen nicht durch textbasierte Programmierung, sondern als Datenflussdiagramm beschrieben (siehe z.B. Arbeitsmaterial KI-B4.2.2). Entsprechend treten keine Syntaxfehler auf und der Fokus im Unterricht kann auf der Analyse und Interpretation der Daten liegen. Orange kann ohne Administratorrechte ausgeführt und via pip, via conda² oder als ausführbare Datei bezogen werden. Der Installationsprozess kann je nach System eine gewisse Zeit dauern. Deswegen sollte die Software vor der Unterrichtsstunde heruntergeladen und ausprobiert werden. Der Fokus in dieser Sequenz liegt auf dem überwachten Verfahren des Lernens von Entscheidungsbäumen, die im Folgenden genauer beschrieben werden. Für Tipps und Hilfestellungen zu den Funktionen von Orange3 sei an dieser Stelle auf die Hilfekarten KI-B4.2.5 verwiesen.

Mit Orange 3 können auch weitere Lernverfahren eingesetzt werden, z.B. Random Forests und k-Nearest-Neighbour. Diese Verfahren werden an dieser Stelle nicht vertieft, Sie finden dazu aber nähere Erläuterung im Zusatzmaterial KI-B4.2.6. Der Einsatz dieser Lernverfahren eignet sich vor allem für Fortgeschrittene im Rahmen tiefergehender Projektphasen. Die Schülerinnen und Schüler haben dann auch die Möglichkeit mit eigenen Daten zu arbeiten.

Datenerfassung und Modellierung

Um Daten in Orange3 verwenden zu können, müssen sie in einem für den Computer verarbeitbaren Format vorliegen. Für die Äffchen aus dem Unplugged-Spiel wählen wir dazu geeignete Merkmale aus den Bildern aus und übertragen die Informationen in eine Tabelle³. Mit diesem Schritt bereiten wir die Daten so auf, dass sie für den Computer verarbeitbar sind. Dabei fokussieren wir uns nur auf die Merkmale, die für den Anwendungsfall relevant sind. Dieses Vorgehen bezeichnet man als Modellierung. In der Tabelle gibt jede Spalte ein Merkmal an, jede Zeile beschreibt einen Datensatz (z.B. Bild von einem Äffchen). Bei der Auswahl der Merkmale der Äffchen (vgl. Abbildung) ergeben sich unterschiedliche Möglichkeiten: Die Augen lassen sich zusammen als Merkmal "Augen" mit Merkmalsausprägungen wie "beide offen" oder "nur ein Auge offen", einzeln wie in der Abbildung oder durch ja/nein-Merkmale wie "beide Augen offen", modellieren. Für überwachtetes Lernen muss außerdem ein Zielmerkmal, d.h. die vorherzusagende Beschriftung, festgelegt werden. In unserem Fall ist das „beißt“ oder „beißt nicht“. Für

² Bei pip und conda handelt es um Paketverwaltungsprogramme für die Programmiersprache Python. Sie müssen die Programme jedoch nicht kennen, um dieses Modul einsetzen zu können.

³ Der Computer könnte in unserem Beispiel auch direkt mit den Bildern arbeiten, wie das etwa bei Bilderkennung bzw. Klassifikation von Bildern der Fall ist. Allerdings liegen viele Daten in tabellarischer Form vor, wie auch in den späteren Beispielen in diesem Modul. Auch dort werden die für den Anwendungsfall relevanten Merkmale aus der „echten Welt“ erfasst und für den Computer verarbeitbar gemacht.

diese Unterrichtssequenz sind alle Daten bereits erfasst, liegen als csv-Datei vor und können direkt verwendet werden.

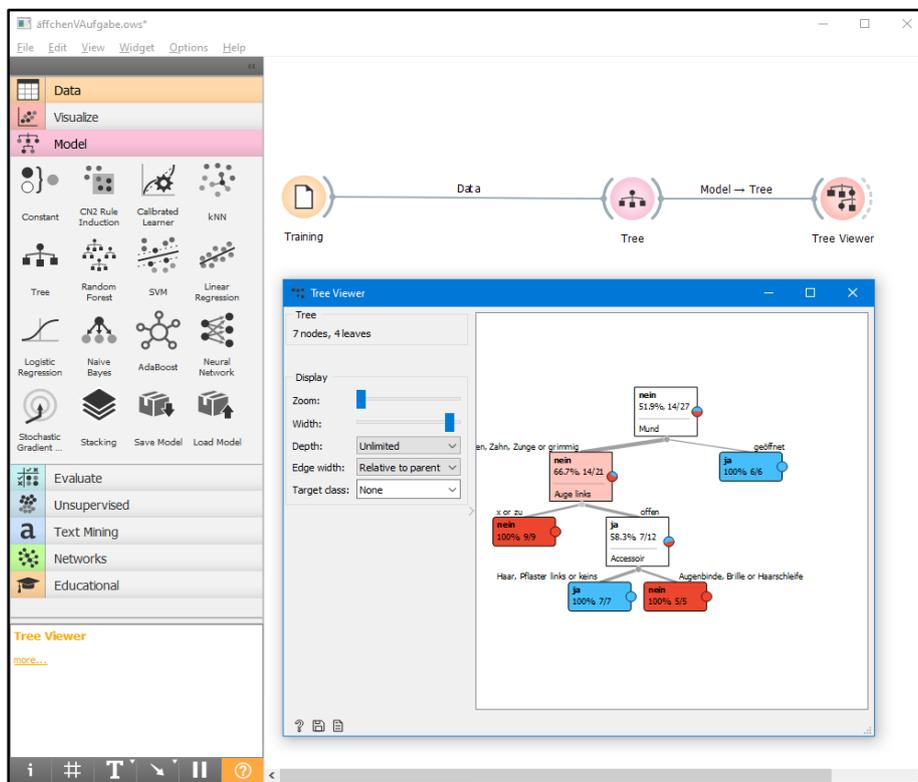
mS#Nummer	D#Auge links	D#Auge rechts	D#Mund	D#Accessoire	cD#Beschriftung
3	x	x	Zahn	keins	beißt nicht
6	offen	zu	Grinsen	keins	beißt
8	zu	zu	Grinsen	keins	beißt nicht
11	x	x	grimmig	keins	beißt nicht

Beispiel Kodierung der Äffchen: Jede Zeile stellt ein Äffchen dar, die verschiedenen Merkmale finden sich in den Spalten (die Zeichen vor # sind spezifisch für Orange3 und geben an, ob das Merkmal diskret (D) oder kontinuierlich (C) ist bzw. ob es sich lediglich um beschreibende Metadaten (m) oder das Zielmerkmal (c) handelt.



6 Unterrichtliche Umsetzung

Im Rahmen des Moduls KI-B3 „Schlag den Roboter“ haben die Schülerinnen und Schüler durch verschiedene Unplugged-Aktivitäten die grundlegenden Funktionsweisen verschiedener KI-Methoden untersucht sowie Beispiele kennengelernt und hinterfragt. Darauf aufbauend modellieren sie nun das bereits in der Unplugged-Variante erkundete Beispiel des Gute-Äffchen-Böse-Äffchen-Spiels mithilfe von Orange3 (siehe Abb.). Anschließend erfolgt eine Übertragung der gelernten Konzepte auf reale Datensätze, die die Schülerinnen und Schüler mithilfe von KI-Methoden auswerten. So erfahren sie wie Daten, die auch als Öl des 21. Jahrhunderts bezeichnet werden, erst die Grundlage für die jüngeren Entwicklungen künstlicher Intelligenz bilden⁴. Zum Einsatz kommen überwachte Lernverfahren. Aufbauend auf dieser Anwendung von KI-Methoden werden anschließend die gesellschaftliche Dimension betrachtet sowie drängende Fragen von KI-Verfahren diskutiert und bewertet. Das Modul ist dabei so gestaltet, dass es sowohl im Anschluss an das Modul „Schlag den Roboter“ als auch unabhängig davon im Unterricht eingesetzt werden kann.



Das Gute-Äffchen-Böse-Äffchen-Spiel in Orange3

⁴ In diesem Zusammenhang wird häufig der Begriff „Big Data“ verwendet.

6.1 Grober Unterrichtsplan

Variante I:

Diese Variante ist empfehlenswert, wenn weniger Unterrichtsstunden zur Verfügung stehen oder für die Lerngruppe eine einfachere Variante angemessen ist. Das Modul wird dann in einer verkürzten Version ohne Projektphase durchgeführt:

Unterrichtsszenarien	Kurze Zusammenfassung
Datenanalyse und Entscheidungsbaum (1 UZE)	Die Schülerinnen und Schüler ... erstellen händisch den Entscheidungsbaum und die Konfusionsmatrix für ein einfaches Beispiel.
Datenanalyse mit Orange3 (2 UZE)	Die Schülerinnen und Schüler ... nutzen das Werkzeug Orange3, um gegebene Daten zu analysieren. Hinweis: die Software Orange3 sollte vorher heruntergeladen werden.
KI und unsere Gesellschaft (1 UZE)	Die Schülerinnen und Schüler ... diskutieren und bewerten Konsequenzen aus dem Einsatz von KI-Methoden. ... erläutern den Unterschied von Korrelation und Kausalität. ... erläutern, warum Verzerrungen in Daten die Ergebnisse von KI-Systemen beeinflussen.

Variante II: In der ausführlichen Variante werden die erworbenen Kompetenzen zur Datenanalyse in Orange 3 vor der abschließenden Betrachtung gesellschaftlicher Auswirkungen in einer Projektphase vertieft. Diese schließt sich damit an die Doppelstunde zur Datenanalyse in Orange3 an.

Unterrichtsszenarien	Kurze Zusammenfassung
Projektarbeit (2-3 UZE)	Die Schülerinnen und Schüler ... lösen Probleme unter Nutzung von KI-Methoden. ... erläutern, warum bei Ergebnissen von ML-Verfahren KI-bedingt Fehler enthalten sein können. ... beschreiben Einsatzmöglichkeiten von KI-Methoden als „Werkzeug“ in beruflichen Tätigkeiten.

Vertiefungsmöglichkeiten: Die im Modul erlernten Kompetenzen im Umgang und zur Auswertung von Daten mithilfe von KI können auch auf weitere, insbesondere auch fachspezifische Fragestellungen angewandt werden. Dazu besteht auch die Möglichkeit, selbst Daten zu erheben. So könnten bspw. im naturwissenschaftlichen Unterricht Daten aus Experimenten gewonnen und anschließend, etwa in der Projektphase dieses Moduls, ausgewertet werden. Darüber hinaus bietet das Werkzeug Orange3 neben den im Modul eingeführten Verfahren weitere Möglichkeiten zur Auswertung und Visualisierung von Daten, die im Unterricht eingesetzt werden können.

6.2 Stundenverlaufsskizzen

Abkürzungen/Legende

AB = Arbeitsblatt/Arbeitsblätter; L = Lehrkraft; MuM = Mitschülerinnen und Mitschüler; SuS = Schülerinnen und Schüler;
UV = Unternehmensvertreterin/Unternehmensvertreter

6.2.1 Stunde 1: Datenanalyse und Entscheidungsbaum

In der ersten Einheit dieser Sequenz lernen die Schülerinnen und Schüler den Begriff des Entscheidungsbaums und der Konfusionsmatrix sowie Metriken zur Beurteilung der Güte eines Modells kennen, indem sie Äffchen nach ihrem Beißverhalten beim Füttern klassifizieren.

Zeit	Phase	Sozialform/ Lehrerimpuls	Inhalt/Unterrichtsgeschehen	Material
5	Einstieg	Lehrer-Schüler-Gespräch	Zu Beginn der Stunde wird die Geschichte über die Firma Target auf dem Beamer aufgelegt und diese gemeinsam besprochen. Beispielsweise mit folgenden Diskussionsfragen: - Welche Informationen hatte die Firma Target über ihre Kunden? - Welche Folgen können solche Vorhersagemodelle für die Betroffenen haben? - Kennt ihr auch andere Bereiche, in denen Daten über Euch gesammelt werden, um euch passende Angebote zu machen? Beispiel Spotify oder Netflix - Lebensweltbezug	Foliensatz KI-B4.1
30	Erarbeitung	Einzel- oder Partnerarbeit	<ul style="list-style-type: none"> • Differenzierung I (leichter, Spiel noch nicht gespielt): Sie haben das Unplugged-Spiel mit ihrer Klasse noch nicht gespielt, dann nutzen Sie KI-B4.1.2a und im späteren Verlauf weiterhin die a-Varianten des Materials. • Differenzierung II (schwerer, Spiel noch nicht gespielt): Sie haben das Spiel noch nicht gespielt, wollen aber die komplexere Version durchführen. Nehmen Sie in diesem Fall die Äffchen aus KI-B4.1.2a als Beispiel her, anhand dessen sie die Spielregeln im Klassengespräch einführen, und führen sie anschließend KI-B4.1.2b durch. Im weiteren Verlauf des Moduls nutzen sie stets die b-Variante des Materials. 	Differenzierung I: KI-B4.2.1 a) Differenzierung II und III: KI-B4.2.1 b) Kontrollblatt KI-B4.2.2

			<ul style="list-style-type: none"> • Differenzierung III (schwerer, Spiel bereits gespielt): Sie haben das Modul „Schlag den Roboter“ bereits unterrichtet und das Gute-Äffchen-Böse-Äffchen-Spiel bereits gespielt. Nutzen Sie in diesem Fall KI-B4.1.2b und auch im späteren Verlauf weiterhin die b-Variante des Materials. 	
10	Diskussion	Lehrer-Schüler-Gespräch	Vergleich der Lösungen und Lehrer-Schüler-Gespräch zu den verschiedenen Metriken zur Beurteilung der Güte von Modellen.	

Stunde 1: Datenanalyse und Entscheidungsbaum

In der ersten Stunde lernen die Schülerinnen und Schüler den Begriff des Entscheidungsbaums und der Konfusionsmatrix sowie Metriken zur Beurteilung der Güte eines Modells kennen, indem sie die Aktivität 1 aus dem Modul KI-B3 „Schlag den Roboter“ erneut durchführen.

Präsentieren Sie zu Beginn der Stunde eine Zeitungsmeldung (siehe KI-B4.1.1) mit einer Geschichte über einen Einzelhändler, die sich in den USA zugetragen haben soll (z.B. über den Beamer).

Geben Sie den Schülerinnen und Schülern folgende Fragestellungen als Impuls mit:

- Welche Informationen hatte die Firma Target über ihre Kunden?
(Antwortmöglichkeiten: Welche Produkte wann gekauft wurden, Häufigkeit der Einkäufe, Tageszeiten, Menge gekaufter Produkte)
- Welche Folgen können solche Vorhersagemodelle für die Betroffenen haben?
(Antwortmöglichkeiten: Passgenaue Produktempfehlungen, Eindringen in die Privatsphäre, unangenehmes Gefühl beobachtet zu werden, Stigmatisierung, ...)
- Habt ihr Erfahrungen mit anderen Bereichen, in denen Daten gesammelt werden, um Euch passende Angebote zu liefern? (Antwortmöglichkeiten: Spotify, Netflix, Amazon Prime, Online-Shopping)

Diskutieren Sie mit Ihren Schülerinnen und Schülern über den Artikel. Leiten Sie dann dazu über, dass die Schülerinnen und Schüler in dieser Unterrichtssequenz selbst die Möglichkeit haben, solche Vorhersagemodelle zu erstellen.

Um solche Modelle nun auch selbst zu erstellen, wird zunächst die Unplugged-Aktivität zu überwachtem Lernen, das „Gute-Äffchen-böse-Äffchen“-Spiel aus Modul KI-B3 „Schlag den Roboter“ herangezogen. Bei der Erstellung der Regeln bzw. des Entscheidungsbaums auf dem zugehörigen Arbeitsblatt gibt es keine „eine Musterlösung“, auch wenn in den Begleitmaterialien eine mögliche „gute“ Lösung zur Orientierung angegeben ist. Auch diese Lösung ermöglicht aber keine vollständig korrekte Klassifikation der Testdaten, die beim maschinellen Lernen im Allgemeinen nicht erreicht werden kann. Die Schülerinnen und Schüler sollen bewusst mit ihren eigenen – und möglicherweise suboptimalen – Modellen das restliche Arbeitsblatt bearbeiten.

Vergleichen Sie anschließend die Lösungen mit den Schülerinnen und Schülern und sprechen Sie über die verschiedenen Metriken zur Beurteilung der Güte eines Modells im Lehrer-Schüler-Gespräch. Diese Metriken lassen sich zukünftig verwenden, um die Güte eines vom Computer automatisch erstellten Modells zu bestimmen.

6.2.2 Stunde 2-3: Datenanalyse mit Orange3

In der zweiten Einheit dieser Sequenz lernen die Schülerinnen und Schüler das Werkzeug Orange3 kennen und nutzen es zur Analyse von gegebenen Daten. Hinweis: Wenn die Software Orange 3 noch nicht auf den Schulrechnern heruntergeladen wurde, sollte dies vor der Stunde erledigt werden.

Zeit	Phase	Sozialform/ Lehrerimpuls	Inhalt/Unterrichtsgeschehen	Material
15	Einstieg	Einzel- oder Partnerarbeit	Die Schülerinnen und Schüler kodieren 3 gegebene Äffchen, sodass ein Computer diese verarbeiten könnte.	optional: Tabelle KI-B4.2.1
60	Erarbeitung & Vertiefung	Einzel- oder Partnerarbeit	Die Schülerinnen und Schüler nutzen Orange3, um Arbeitsblatt KI-B4.3.1 zu bearbeiten. Differenzierung I: Sie haben in Stunde 1 das Material a gewählt, dann wählen Sie auch hier KI-B4.2.2a. Differenzierung II+III: Sie haben in Stunde 1 das Material b gewählt, dann wählen Sie auch hier KI-B4.2.2b.	Differenzierung I: KI-B4.2.2a Differenzierung II und III: KI-B4.2.2b Datensatz KI-B4.2.3 optional: Hilfekarten KI-B4.3.5
15	Besprechung	Lehrer-Schüler-Gespräch	Besprechung des Arbeitsblatts und ggf. Vergleich der Güte der verschiedenen Modelle. Thematisierung von Over- und Underfitting.	

Stunde 2 und 3: Datenanalyse mit Orange3

In der zweiten Einheit dieser Sequenz lernen die Schülerinnen und Schüler das Werkzeug Orange3 kennen und nutzen es zur Analyse von gegebenen Daten, um im Anschluss das Projekt durchführen zu können. Damit wenden die Schülerinnen und Schüler ein ähnliches Vorgehen wie die Data Scientists der Firma Target an.

Vermutlich ist Ihren Schülerinnen und Schülern klar, dass Computer mit strukturierten Daten und weniger mit Münzen oder Karten arbeiten. Dies dient auch als Fragestellung für den Beginn der Lerneinheit: Wie lässt sich dieses Verfahren nun durch einen Computer ausführen?

Dazu sollen die Schülerinnen und Schüler drei gegebene Äffchen geeignet modellieren, sodass ein Computer diese verarbeiten könnte. Dazu werden die Äffchen 1, 33 und 14 gezeigt. Optional kann bereits eine Tabelle vorgegeben werden (siehe KI-B4.2.1).

Es ergeben sich unterschiedliche Möglichkeiten zur Modellierung, etwa binär (Merkmal vorhanden/nicht vorhanden), oder aber über die verschiedenen Merkmalsausprägungen (bspw. Mund: offen/geschlossen/Zunge rausstrecken/ Zähne fletschen).

	Mund weit offen
	nein
	ja
	ja

binär

	Mund
	Zähne
	weit geöffnet
	weit geöffnet

nicht binär

Anschließend soll nun das Äffchenspiel in Orange3 gelöst werden. Findet die KI einen besseren Entscheidungsbaum? Dazu starten die Schülerinnen und Schüler Orange3 und bearbeiten Arbeitsblatt KI-B4.2.2 mit dem Datensatz KI-B4.2.3.

Wählen Sie dabei Variante KI-B4.2.2a, falls Sie

- ... in der erste Unterrichtsstunde Variante KI-B4.1.2a des Arbeitsblattes gewählt haben oder eine kürzere Variante bevorzugen.

Ansonsten wählen sie Sie KI-B4.2.2b.

Mögliche Differenzierung: Als mögliche Differenzierung können weitere Modelle (Random Forest und KNN) eingeführt werden. Dazu können die beigelegten Folien (KI-B4.2.4) verwendet werden. Anschließend sollten die Schülerinnen und Schüler ggf. noch einmal die Möglichkeit erhalten, die alternativen Modelle in Orange3 auszuprobieren.

Im Lehrer-Schüler-Gespräch wird nun das Arbeitsblatt besprochen und ggf. die Güte der verschiedenen Modelle verglichen. Außerdem können anhand von Aufgabe 3 die Begriffe Over- und Underfitting thematisiert werden.



6.2.3 Stunde 4-6: Projektarbeit (nur Variante II)

Während der (bis zu) dreistündigen Projektarbeitsphase arbeiten die Schülerinnen und Schüler an ihrem Arbeitsauftrag und erstellen ein Poster zur Präsentation ihrer Ergebnisse. Optional kann während des Projekts den Gruppen der Link zu einem Interview mit Data Scientist gegeben werden.

Zeit	Phase	Sozialform/ Lehrerimpuls	Inhalt/Unterrichtsgeschehen	Material
10	Wahl Projektthema	Lehrer-Schüler-Gespräch	Vorstellung und Wahl der Projektthemen	Themenübersicht KI-B4.3.1
50-95min	Durchführung des Projekts	Projektphase	<p>Die Schülerinnen und Schüler bearbeiten das gewählte Projektthema in Gruppen und halten ihre Ergebnisse auf einem Plakat fest. Optional kann während des Projekts den Gruppen der Link zu einem Interview mit Data Scientist gegeben werden, die sich auf dem YouTube Kanal der Wissensfabrik finden:</p> <ul style="list-style-type: none"> • Was macht eigentlich eine Data Scientist? Interview mit Elena Bruna https://youtu.be/EbURtR4NUj4 • Was macht eigentlich ein KI-Entwickler? Interview mit Dennis Hügele https://youtu.be/_sZnDZf7LgM 	KI-B4.3.3 Arbeitsanweisung Projekt KI-B4.2.5 Hilfekarten für Orange3 ggf. KI-B4.3.4 Datensatz für das Projekt student data 1 x Plakat je Gruppe zur Darstellung der Ergebnisse (nicht in Klassensatz enthalten).
30	Präsentation	Schülerpräsentation und moderierte Frageunde	Präsentation und Diskussion der Ergebnisse (z.B. 5 x 4er Gruppe à 5 Minuten).	Von Schülerinnen und Schülern erstellte Präsentationen / Poster

Stunde 4 bis 6: Projektarbeit (nur Variante II)

Während der dreistündigen Projektarbeitsphase arbeiten die Schülerinnen und Schüler weitestgehend selbstständig. Stellen Sie der Klasse zunächst die verschiedenen Themen und damit verbundenen Fragestellungen für die Projektarbeit vor (vgl. KI-B4.3.1), bilden Sie Gruppen und lassen Sie die Gruppen dann jeweils ein Thema wählen.

Anschließend erhalten sie den Arbeitsauftrag.

Arbeitsauftrag (findet sich auch in den Begleitmaterialien)

Als Data Scientist ist es eure Aufgabe, Probleme durch Erstellen eines Klassifikationsmodells zu lösen. Dazu steht euch ein Datensatz zur Verfügung, der den Ausgangspunkt für euer KI-Modell darstellt.

Folgt dazu folgenden Schritten:

1. Erstellt ein neues Orange3-Projekt.
 - Wenn euer Datensatz bereits in Orange3 enthalten ist, zieht das Datasets-Widget auf die Leinwand und wählt den entsprechenden Datensatz mit einem Doppelklick aus.
 - Wenn euer Datensatz nicht in Orange3 enthalten ist, öffnet ihn wie den Äffchendatensatz mithilfe des File-Widgets.
2. Verschafft euch anschließend einen Überblick über den Datensatz mithilfe des Data Table-Widgets! Notiert, welche Informationen in den Spalten gespeichert sind. Was sind die möglichen Klassen? Welche Merkmale stehen euch zur Verfügung?
3. Teilt die Daten mithilfe des Data Sampler-Widget in Trainings- und Testdaten auf.
4. Trainiert mehrere Modelle, indem ihr unterschiedliche Merkmale für das Training auswählt und verschiedene Parameter des Trainingsprozesses festlegt.
5. Testet und bewertet eure Modelle mithilfe einer geeigneten Metrik.
6. Überlegt euch, welche Personengruppen wie von eurem Modell profitieren und welche Personengruppen wie von eurem Modell benachteiligt werden könnten.
7. Gestaltet ein Poster, das euren Datensatz, euer Ziel und eure Ergebnisse knapp und präzise zusammenfasst. Was findet ihr an eurer Auswertung überraschend?

Den Schülerinnen und Schülern stehen Hilfekarten zu den verschiedenen im Rahmen des Projekts relevanten Möglichkeiten innerhalb von Orange3. Die Schülerinnen und Schüler können zum Festhalten und Präsentieren ein Poster erstellen.

Zusätzlich besteht während des Projekts die Möglichkeit, den Gruppen einzeln ein aufgezeichnetes Interview mit zwei Data Scientists zu zeigen und so mögliche Berufs- und Karriereoptionen deutlich zu machen.

Abschließend präsentieren die Schülerinnen und Schüler ihre Ergebnisse. Bitten Sie sie dazu ihr Plakat an einer Stelle im Klassenzimmer aufzuhängen. Anschließend präsentieren die Gruppen der Reihe nach ihre Ergebnisse und die Klasse wandert mit. Dabei sollte jeweils dieselbe Zeit, die für die Präsentation verwendet wurde, auch für die anschließende Diskussion der Ergebnisse aufgewendet werden (z.B. 5 x 4er Gruppe à 5 Minuten mit 2,5 Präsentation und 2,5 Minuten Diskussion). Lassen Sie die Schülerinnen und Schüler dabei die Aufgaben des Menschen beim Erstellen von Modellen im Kontext des maschinellen Lernens (Konfigurieren des Verfahrens, Festlegen der Parameter, Güte der resultierenden Modelle kritisch einschätzen) reflektieren und benennen.

6.2.4 Stunde 7: KI und unsere Gesellschaft

In der letzten Einheit diskutieren die Schülerinnen und Schüler über die ethische Perspektive beim Einsatz von KI-Modellen.

Zeit	Phase	Sozialform/ Lehrerimpuls	Inhalt/Unterrichtsgeschehen	Material
25	Erarbeitung & Vertiefung	Partnerarbeit	Die Schülerinnen und Schüler bearbeiten in Partnerarbeit die vorgegebenen Szenarien und diskutieren über die Leitfragen. Alternativ können die Aufgaben mit Hilfe der Jigsaw-Methode bearbeitet werden.	KI-B4.4
10	Sicherung	Lehrer-Schüler-Gespräch	1-2 Gruppen stellen ihre Ergebnisse vor.	
10	Fazit und Ausblick	Lehrer-Schüler-Gespräch	Anschließend wird der Einsatz von KI im Plenum diskutiert. Leitfragen sind <ul style="list-style-type: none">• Auf Basis des Gelernten: Wofür sollte KI eingesetzt werden -- und wofür nicht?• Welche Regeln sollten für einen fairen Einsatz von KI-Systemen gelten?	

Stunde 7: KI und unsere Gesellschaft

In der letzten Einheit diskutieren Sie mit ihrer Klasse die ethische Perspektive beim Einsatz von KI-Modellen. Dazu erhalten die Schülerinnen und Schüler das Arbeitsmaterial KI-B4.4 mit drei Szenarien über unzuverlässige, diskriminierende bzw. fehlerhafte KI-Systeme. Diese werden zunächst in Partnerarbeit und anschließend im Plenum diskutiert. Durch den gesellschaftlich relevanten Bezug kann dieses Thema in unterschiedliche Fächer eingebettet werden.

7 Einbettung in verschiedene Fächer und Themen

Im Zuge der digitalen Transformation spielen Daten und Datenanalyse in allen Schulfächern und deren Bezugswissenschaften eine herausragende Rolle. So werden Datenanalysen und Künstliche Intelligenz oft als viertes Standbein der Wissenschaft bezeichnet. Jeder Wissenschaftler bzw. jede Wissenschaftlerin benötigt entsprechende Kompetenzen im Umgang und der Analyse von Daten. Und auch für den Schulunterricht werden entsprechende Vorgehensweisen zunehmend Inhalt und bieten weiterhin enormes Potential für einen handlungsorientierten und fachübergreifenden Unterricht. Ob bei der Durchführung von Experimenten im Physikunterricht, der Beantwortung von Fragen im Chemie- oder Biologieunterricht, der Auswertung von Geodaten im Geographieunterricht, der Analyse von Textdokumenten im Fach Deutsch oder der Diskussion ethischer, gesellschaftlicher und moralischer Konsequenzen im Ethik- oder Religionsunterricht: Überall finden die in diesem Modul eingeführten Verfahren zunehmende Bedeutung und können fachübergreifend zur Beantwortung fachspezifischer Fragestellungen eingesetzt werden.

8 Anschluss Themen

Als Anschluss Themen im Zusammenhang mit IT2School bieten sich folgende Bausteine an:

KI-A2: Mein persönlicher Assistent

Während in diesem Modul die datenbasierte Sicht eingenommen wurde, können die Schülerinnen und Schüler im Modul „Mein persönlicher Assistent“ selbst einen (einfachen) digitalen Sprachassistenten entwickeln. Dieses Modul ergänzt die hier eingenommene Sichtweise und zeigt, dass KI auch als kreatives Werkzeug für persönliche Projekte verwendet werden kann.



9 Literatur und Links

- **AI Unplugged:** <https://aiunplugged.org>
- **Werkzeug Orange3:** <https://orangedatamining.com> (kann ohne Administratorrechte genutzt werden)
- **Quellen für weitere Datensätze:** <https://datasetsearch.research.google.com/>, <https://archive.ics.uci.edu/ml/datasets/>
- **Unterrichtsreihe „Data Mining im Unterricht“:** <https://dataliteracy.education/unterrichtsmaterial/>

10 Arbeitsmaterialien

Das Modul besteht aus folgenden Materialien. Zu allen Arbeitsblättern gibt es auch Musterlösungen.

Nr.	Titel	Beschreibung
😊 KI-B4.1.1	Einstiegsimpuls	Einstiegsimpuls Zeitungsmeldung „Target“
😊 KI-B4.1.2	Entscheidungsbäume	Arbeitsblatt zur Einführung von Entscheidungsbäumen anhand der Äffchen in Variante a und b.
😊 KI-B4.1.3	Kontrollblatt	Kontrolle der Klassifizierung der Äffchen um anschließend die Metriken berechnen zu können
😊 KI-B4.2.1	Vorlage Tabelle	Tabellarische Vorlage zur Kodierung der Äffchen
😊 KI-B4.2.2	Orange3	Arbeitsblatt zur Einführung in die Nutzung von Orange3 zur Datenanalyse in Variante a und b.
😊 KI-B4.2.3	Datensatz Äffchen	Datensatz zur Bearbeitung des Arbeitsblattes
😊 KI-B4.2.4	Foliensatz Random Forest / KNN	Foliensatz zur optionalen Erläuterung weiterer Verfahren zur Datenanalyse
😊 KI-B4.2.5	Hilfen Orange3	Hilfekarten zu den verschiedenen für die Projektarbeit relevanten Funktionen von Orange3 (kann auch digital zur Verfügung gestellt werden)
😊 KI-B4.2.6	Erläuterung Random Forest / KNN	Fachlicher Hintergrund zu Random Forest bzw. KNN als optionalen weiteren Verfahren, die verwendet werden können.
😊 KI-B4.3.1	Übersicht Datensätze	Eine Übersicht über mögliche Datensätze für die Projektarbeitsphase
😊 KI-B4.3.2	Interviews Data Scientist	Interviews mit Unternehmensvertreter*innen: Was macht eigentlich ein Data Scientist? Interview 1: https://youtu.be/EbURtR4NUj4 Interview 2: https://youtu.be/_sZnDZf7LgM

😊 KI-B4.3.3	Arbeitsauftrag	Arbeitsauftrag für die Projektarbeit
😊 KI-B4.3.4	Datensatz student data	Datensatz für ein Projekt aus der Projektarbeit
😊 KI-B4.4	Arbeitsblatt Bias	Arbeitsblatt mit drei Szenarien zu Bias bei KI-Modellen

Legende

- 😊 Material für Schülerinnen und Schüler
- 😊 Material für Lehrkräfte sowie Unternehmensvertreterinnen und Unternehmensvertreter
- 😊 Zusatzmaterial

11 Glossar

Begriff	Erläuterung
Maschinelles Lernen	Beim <u>maschinellen Lernen (ML)</u> leiten Computer Zusammenhänge aus Daten bzw. Erfahrungen ab. Das Gelernte wird in einem Modell gespeichert.
Überwachtes Lernen	Bei überwachtem Lernen wird aus beschrifteten Daten eine Zuordnung von Daten zu Beschriftung gelernt, die dann auf weitere, unbeschriftete Daten angewendet werden kann.
Trainingsdaten	Trainingsdaten sind Daten, die zur Erstellung eines mit überwachtem Lernen trainierten Modells herangezogen werden.
Testdaten	Testdaten werden genutzt, um zu beurteilen (zu „testen“), ob ein Modell zufriedenstellende Ergebnisse liefert. Sie sollten nicht Teil des Trainingsprozesses sein.
Entscheidungsbaum	Entscheidungsbäume stellen Entscheidungsregeln in einem geordneten und gerichteten Baum bestehend aus mehreren hierarchisch angeordneten Entscheidungen dar. Sie können im Fall von überwachtem Lernen auch automatisch aus Daten gelernt werden.
Konfusionsmatrix	Die Konfusionsmatrix ist eine Tabelle, in der die richtigen und falschen Vorhersagen eines Modells übersichtlich dargestellt werden.

12 Fragen, Feedback, Anregungen

Sie haben das Modul ausprobiert und nun Fragen, Anregungen oder Feedback für uns? Darüber freuen wir uns, denn mit Ihren Erfahrungen können wir Schritt für Schritt einen FAQ (Frequently Asked Questions) für die neuen KI-Module aufbauen oder die Module weiter entwickeln.

Bitte füllen Sie folgende Umfrage über SurveyMonkey aus: <https://bit.ly/3DQnqj8> über den folgenden QR-Code kommen Sie ebenfalls zur SurveyMonkey-Umfrage:



Sie können sich auch gerne unter bildung@wissensfabrik.de melden.

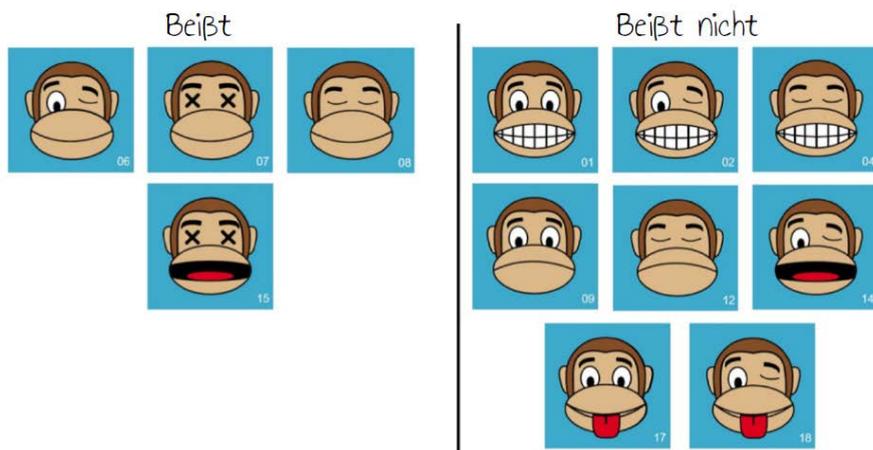


Aufgabenblatt: Klassifikation mit Entscheidungsbäumen

Als Tierpflegerin bzw. Tierpfleger sind wir für die Fütterung der Äffchen zuständig. Dabei müssen wir aufpassen: Manche Äffchen beißen. Von den Äffchen im Zoo wissen wir bereits, ob sie beißen. Allerdings werden bald neue Tiere zur Gruppe stoßen. Wir müssen uns daher überlegen, wie wir herausfinden können, welche neuen Äffchen beißen und welche nicht – ohne ihren Zähnen zu nahe zu kommen.

Trainingsdaten

Von den Äffchen, die bereits im Zoo leben, können wir lernen. Sie sind unsere Trainingsdaten. Mit Hilfe dieser Trainingsdaten können wir Regeln entwickeln, um beißende und nicht beißende Äffchen unterscheiden zu können. Regeln können bspw. von folgender Form sein: Wenn der Affe die Zunge zeigt, dann beißt er. Entwickle basierend auf den folgenden Äffchen selbst solche Regeln!

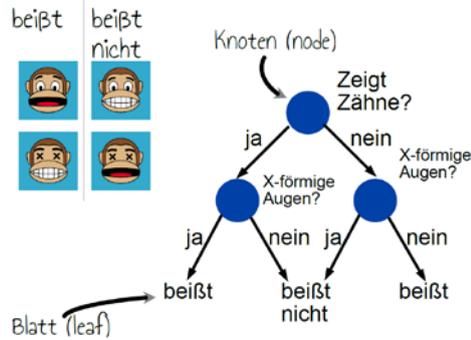


Regeln

Entscheidungsbaum

Eine besondere Art solche Regeln darzustellen sind Entscheidungsbaeume. Ein Entscheidungsbaum stellt Regeln hierarchisch dar und wird von oben nach unten gelesen.

Vollziehe das folgende Beispiel nach und notiere deine Regeln von Seite 1 ebenfalls als Entscheidungsbaum im Feld rechts.



Entscheidungsbaum

Testdaten

Ein Entscheidungsbaum ist ein Modell, das nun auf weitere Daten angewendet werden kann. Unser Modell können wir nun mit weiteren Tieren testen, von denen wir bereits wissen, ob sie beißen oder nicht. Diese Tiere sind also unsere **Testdaten**.

1. Entscheide mithilfe deines Entscheidungsbaumes, ob die folgenden Äffchen beißen (B) oder nicht beißen (NB) und trage deine Vorhersage in die freien Felder ein!
2. Vergleiche deine Lösung mit der Auflösung, die du von deiner Lehrkraft bekommst, und markiere, ob deine Vorhersage richtig oder falsch war!

Konfusionsmatrix

Jetzt hast du die Testdaten klassifiziert und ihre tatsächliche Zuordnung ist bekannt. Die Ergebnisse trägt du summarisch in die folgende Tabelle (die **Konfusionsmatrix**) ein.

1. Fülle die Felder der Konfusionsmatrix!

Beispiel: Das Feld links oben gibt an, für wie viele Äffchen du richtig die Kategorie beißt vorhergesagt hast (z.B. 2)!

	Vorhergesagt: Äffchen beißt	Vorhergesagt: Äffchen beißt nicht
Tatsächlich: Äffchen beißt		
Tatsächlich: Äffchen beißt nicht		

2. Berechne das folgende Verhältnis und gib das Ergebnis als Prozentsatz an!

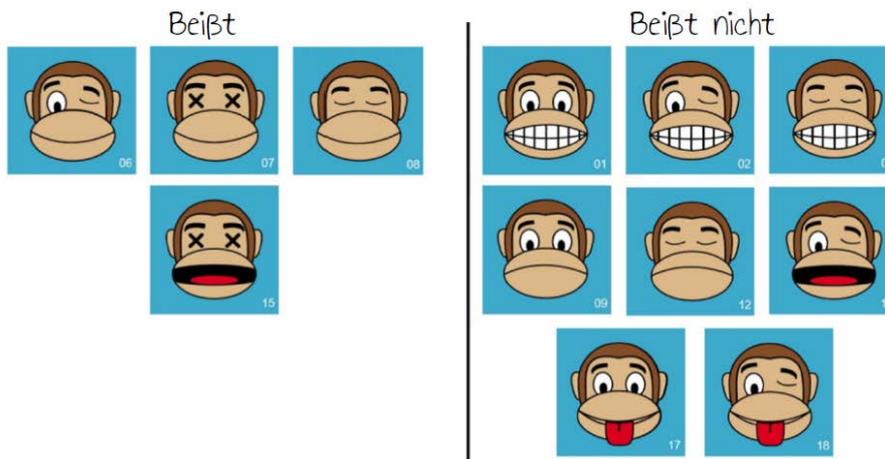
Eine Entwicklung in Kooperation von der Didaktik der Informatik der FU Berlin (computingeducation.de) und der Wissensfabrik – Unternehmen für Deutschland e.V. Dieses Material stellt ein Derivat von AI Unplugged dar (CC-BY-NC, Seegeer & Lindner)

Aufgabenblatt: Klassifikation mit Entscheidungsbäumen

Als Tierpflegerin bzw. Tierpfleger sind wir für die Fütterung der Äffchen zuständig. Dabei müssen wir aufpassen: Manche Äffchen beißen. Von den Äffchen im Zoo wissen wir bereits, ob sie beißen. Allerdings werden bald neue Tiere zur Gruppe stoßen. Wir müssen uns daher überlegen, wie wir herausfinden können, welche neuen Äffchen beißen und welche nicht – ohne ihren Zähnen zu nahe zu kommen.

Trainingsdaten

Von den Äffchen, die bereits im Zoo leben, können wir lernen. Sie sind unsere Trainingsdaten. Mit Hilfe dieser Trainingsdaten können wir Regeln entwickeln, um beißende und nicht beißende Äffchen unterscheiden zu können. Regeln können bspw. von folgender Form sein: Wenn der Affe die Zunge zeigt, dann beißt er. Entwickle basierend auf den folgenden Äffchen selbst solche Regeln!



Regeln

Individuell

Z.B. „Hat ein Äffchen einen lächelnden Mund, so beißt es.“

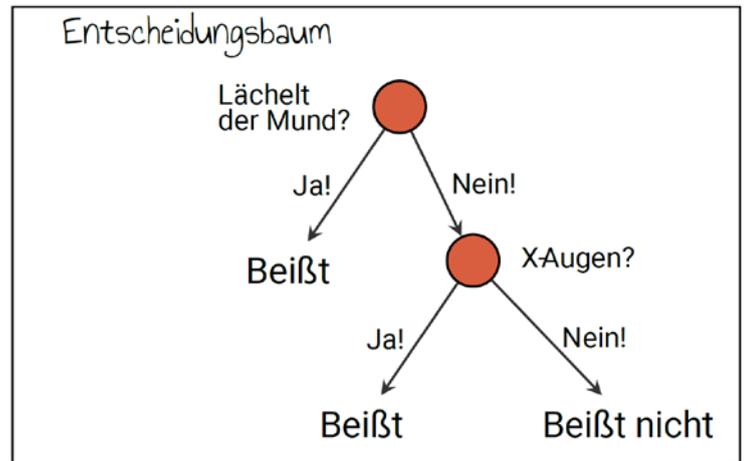
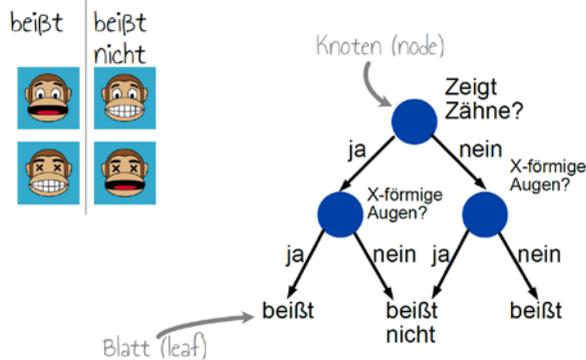
Lächelt er nicht und hat X-Augen, so beißt es.

In allen anderen Fällen beißt es nicht.

Entscheidungsbaum

Eine besondere Art solche Regeln darzustellen sind Entscheidungsbäume. Ein Entscheidungsbaum stellt Regeln hierarchisch dar und wird von oben nach unten gelesen.

Vollziehe das folgende Beispiel nach und notiere deine Regeln von Seite 1 ebenfalls als Entscheidungsbaum im Feld rechts.



Testdaten

Ein Entscheidungsbaum ist ein Modell, das nun auf weitere Daten angewendet werden kann. Unser Modell können wir nun mit weiteren Tieren testen, von denen wir bereits wissen, ob sie beißen oder nicht. Diese Tiere sind also unsere **Testdaten**.

1. Entscheide mithilfe deines Entscheidungsbaumes, ob die folgenden Äffchen beißen (B) oder nicht beißen (NB) und trage deine Vorhersage in die freien Felder ein!
2. Vergleiche deine Lösung mit der Auflösung, die du von deiner Lehrkraft bekommst, und markiere, ob deine Vorhersage richtig oder falsch war!

Konfusionsmatrix

Jetzt hast du die Testdaten klassifiziert und ihre tatsächliche Zuordnung ist bekannt. Die Ergebnisse trägst du summarisch in die folgende Tabelle (die Konfusionsmatrix) ein.

1. Fülle die Felder der Konfusionsmatrix!

Beispiel: Das Feld links oben gibt an, für wie viele Äffchen du richtig die Kategorie beißt vorhergesagt hast (z.B. 2)!

	Vorhergesagt: Äffchen beißt	Vorhergesagt: Äffchen beißt nicht
Tatsächlich: Äffchen beißt	2	1
Tatsächlich: Äffchen beißt nicht	1	2

2. Berechne das folgende Verhältnis und gib das Ergebnis als Prozentsatz an!

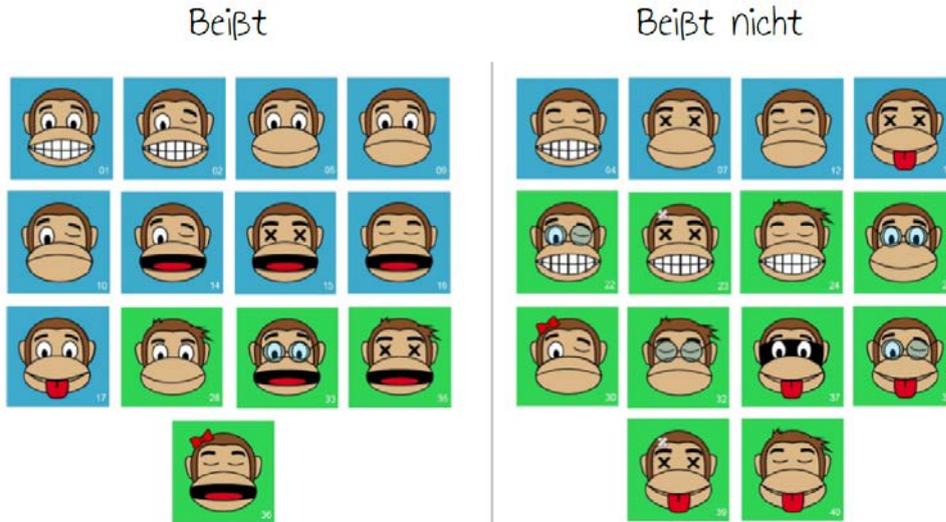


Aufgabenblatt: Klassifikation mit Entscheidungsbäumen

Als Tierpflegerin bzw. Tierpfleger sind wir für die Fütterung der Affen zuständig. Dabei müssen wir aufpassen: Manche Affen beißen. Von den Affen im Zoo wissen wir bereits, ob sie beißen. Allerdings werden bald neue Tiere zur Gruppe hinzukommen. Wir müssen uns daher überlegen, wie wir herausfinden können, welche neuen Affen beißen und welche nicht – am besten ohne ihren Zähnen zu nahe zu kommen.

Trainingsdaten

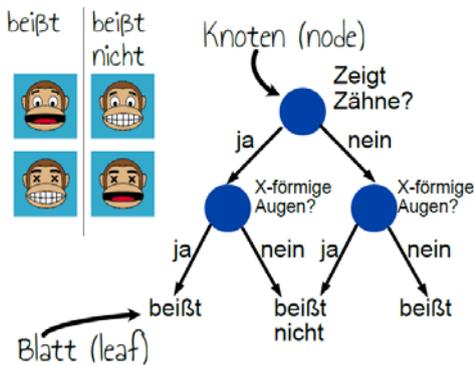
Von den Affen, die bereits im Zoo leben, können wir lernen. Sie sind unsere Trainingsdaten mit deren Hilfe der Entscheidungsbaum gelernt wird.



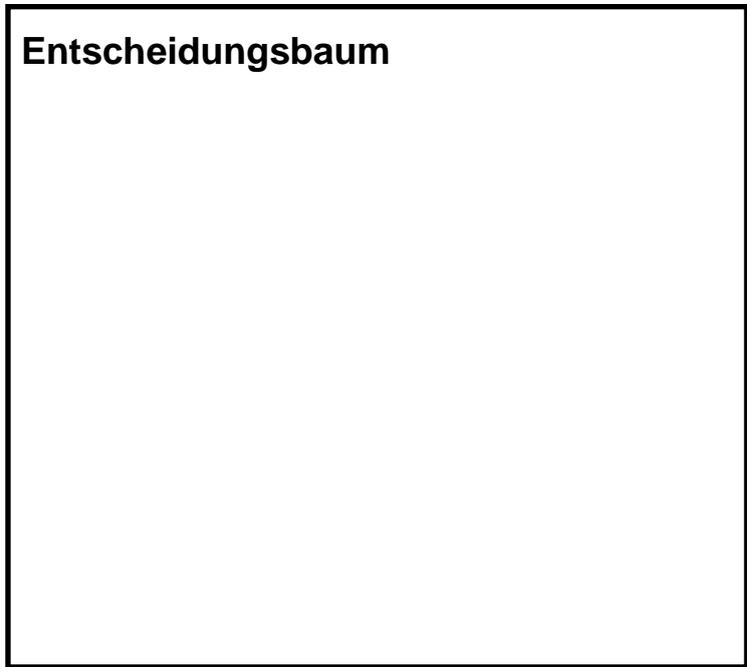
Entscheidungsbaum

Ein Entscheidungsbaum stellt Regeln hierarchisch dar und wird von oben nach unten gelesen.

Vollziehe das Beispiel nach und erstelle einen Entscheidungsbaum für die gegebenen Affen.



Entscheidungsbaum



Testdaten

Ein Entscheidungsbaum ist ein Modell, das nun auf weitere Daten angewendet werden kann. Unser Modell können wir nun mit weiteren Tieren testen, von denen wir bereits wissen, ob sie beißen oder nicht. Diese Tiere sind also unsere Testdaten.

- Entscheide mithilfe deines Entscheidungsbaumes, ob die folgenden Affen beißen (B) oder nicht beißen (NB) und trage deine Vorhersage in die freien Felder ein!
- Vergleiche deine Lösung mit der Auflösung und markiere, ob deine Vorhersage richtig oder falsch war!

<input style="width: 100%; height: 20px;" type="text"/>	Deine Vorhersage: Beißt oder beißt nicht?					
<input checked="" type="checkbox"/> <input checked="" type="checkbox"/>						
<input style="width: 100%; height: 20px;" type="text"/>	Deine Vorhersage: Beißt oder beißt nicht?					
<input checked="" type="checkbox"/> <input checked="" type="checkbox"/>						

Konfusionsmatrix

Jetzt hast du die Testdaten klassifiziert und ihre tatsächliche Zuordnung ist bekannt. Die Ergebnisse trägst du summarisch in die folgende Tabelle (die Konfusionsmatrix) ein.

- Fülle die Felder der Konfusionsmatrix!
Beispiel: Das Feld links oben gibt an, für wie viele Äffchen du richtig die Kategorie beißt vorhergesagt hast (z.B. 2)!

	Vorhergesagt: Äffchen beißt	Vorhergesagt: Äffchen beißt nicht
Tatsächlich: Äffchen beißt		
Tatsächlich: Äffchen beißt nicht		

- Berechne die folgenden Verhältnisse und gib das Ergebnis als Prozentsatz an!

$$\frac{\text{#korrekt vorhergesagt}}{\text{#insgesamt vorhergesagt}} = \frac{3}{5} = \text{[]} \text{ ---}$$

$$\frac{\text{#beißt richtig vorhergesagt}}{\text{#beißt tatsächlich}} = \frac{2}{3} = \text{[]} \text{ ---}$$

$$\frac{\text{#beißt richtig vorhergesagt}}{\text{#beißt vorhergesagt}} = \frac{2}{3} = \text{[]} \text{ ---}$$

Deine Ergebnisse

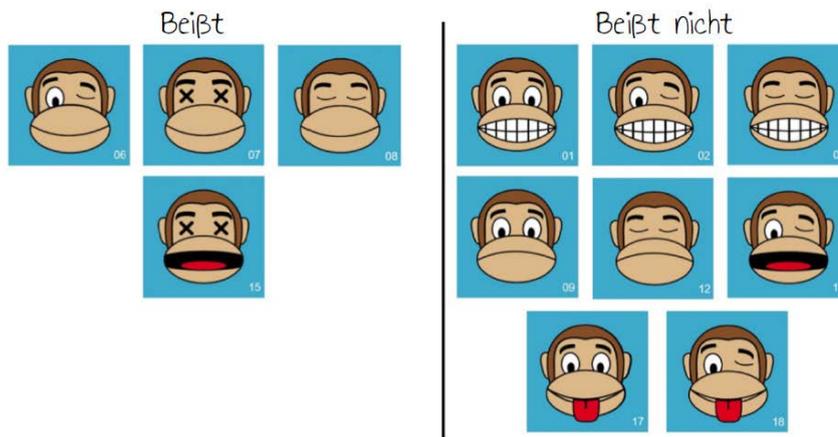
Hier benennen wir gemeinsam dieses Verhältnis, das wir auch eine Metrik nennen.

Aufgabenblatt: Klassifikation mit Entscheidungsbäumen

Als Tierpflegerin bzw. Tierpfleger sind wir für die Fütterung der Affen zuständig. Dabei müssen wir aufpassen: Manche Affen beißen. Von den Affen im Zoo wissen wir bereits, ob sie beißen. Allerdings werden bald neue Tiere zur Gruppe hinzukommen. Wir müssen uns daher überlegen, wie wir herausfinden können, welche neuen Affen beißen und welche nicht am besten ohne ihren Zähnen zu nahe zu kommen.

Trainingsdaten

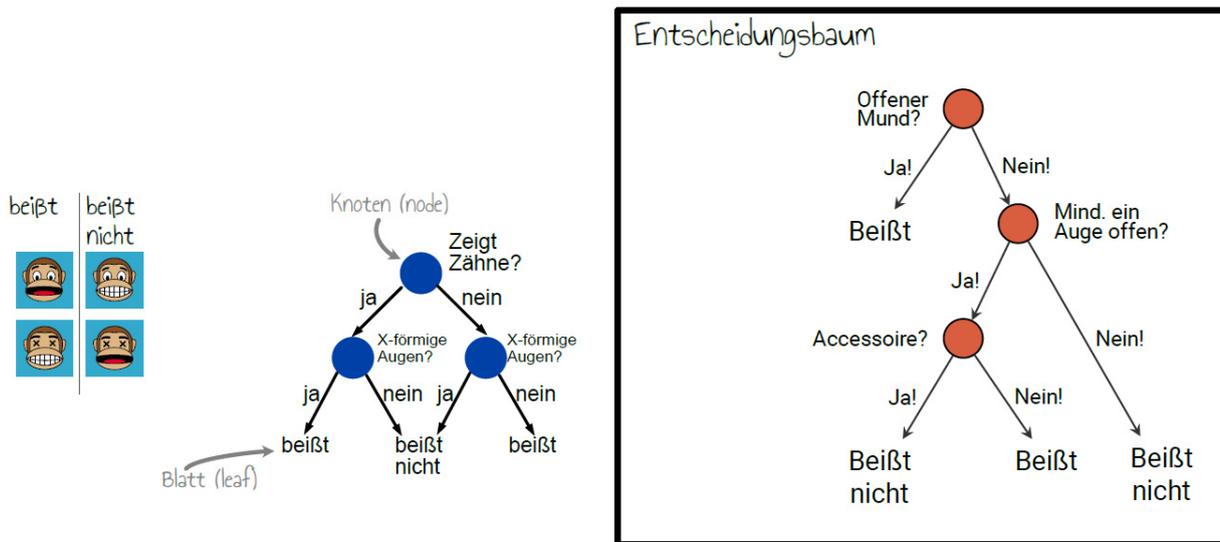
Von den Affen, die bereits im Zoo leben, können wir lernen. Sie sind unsere **Trainingsdaten**, mit deren Hilfe der **Entscheidungsbaum** erstellt wird.



Entscheidungsbaum

Ein Entscheidungsbaum stellt Regeln hierarchisch dar und wird von oben nach unten gelesen.

Vollziehe das Beispiel nach und erstelle einen Entscheidungsbaum für die gegebenen Affen.



Testdaten

Ein Entscheidungsbaum ist ein Modell, das nun auf weitere Daten angewendet werden kann. Unser Modell können wir nun mit weiteren Tieren testen, von denen wir bereits wissen, ob sie beißen oder nicht. Diese Tiere sind also unsere **Testdaten**.



1. Entscheide mithilfe deines Entscheidungsbaumes, ob die folgenden Affen beißen (B) oder nicht beißen (NB) und trage deine Vorhersage in die freien Felder ein!
2. Vergleiche deine Lösung mit der Auflösung und markiere, ob deine Vorhersage richtig oder falsch war!

						Deine Vorhersage: Beißt oder beißt nicht?
BN	B	BN	BN	B	B	
✓ X	✓ X	✓ X	✓ X	✓ X	✓ X	War deine Vorhersage richtig oder falsch?
						Deine Vorhersage: Beißt oder beißt nicht?
BN	BN	BN	BN	BN	B	
✓ X	✓ X	✓ X	✓ X	✓ X	✓ X	War deine Vorhersage richtig oder falsch?

Konfusionsmatrix

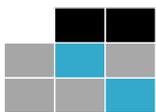
Jetzt hast du die Testdaten klassifiziert und ihre tatsächliche Zuordnung ist bekannt. Die Ergebnisse trägst du summarisch in die folgende Tabelle (die Konfusionsmatrix) ein.

1. Fülle die Felder der Konfusionsmatrix!

Beispiel: Das Feld links oben gibt an, für wie viele Äffchen du richtig die Kategorie beißt vorhergesagt hast (z.B. 2)!

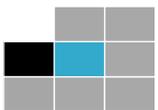
	Vorhergesagt: Äffchen beißt	Vorhergesagt: Äffchen beißt nicht
Tatsächlich: Äffchen beißt	3	1
Tatsächlich: Äffchen beißt nicht	2	6

2. Berechne die folgenden Verhältnisse und gib das Ergebnis als Prozentsatz an!



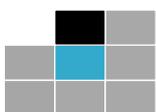
$$\frac{\text{#korrekt vorhergesagt}}{\text{#insgesamt vorhergesagt}} = \frac{3}{4} = 75\%$$

Genauigkeit (accuracy)



$$\frac{\text{#beißt richtig vorhergesagt}}{\text{#beißt tatsächlich}} = \frac{1}{2} = 50\%$$

Trefferquote (recall)



$$\frac{\text{#beißt richtig vorhergesagt}}{\text{#beißt vorhergesagt}} = \frac{2}{3} = 66\%$$

Präzision (precision)

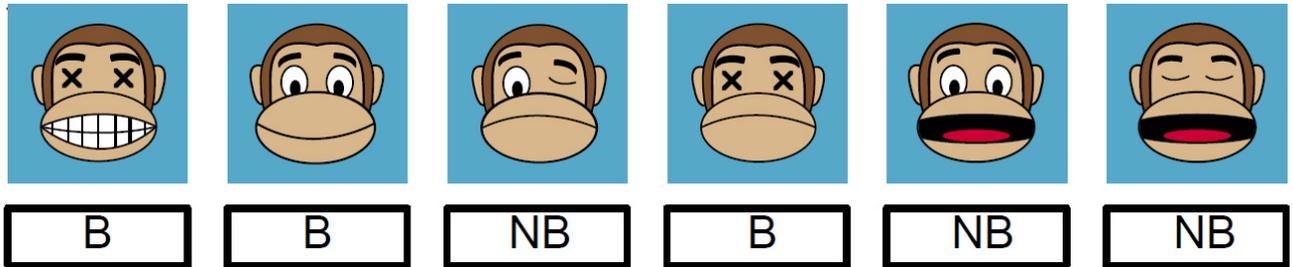
Deine Ergebnisse

Hier benennen wir gemeinsam diese Metrik.



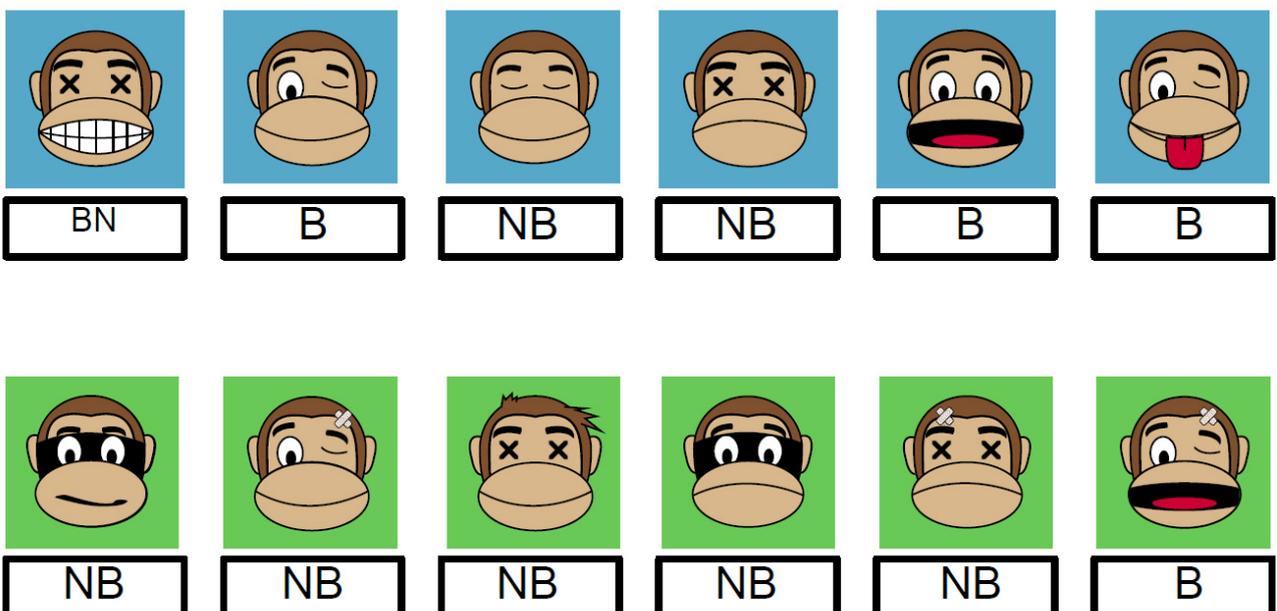
Vergleichslösung: Klassifikation mit Entscheidungsbäumen (Variante a)

Das aus den Trainingsdaten gewonnene Modell lässt sich mithilfe der Testdaten testen. Im Folgenden findest du die eigentliche Beschriftung für die Äffchen in den Testdaten. Vergleiche die Auflösung mit deinen Beschriftungen und markiere, ob deine Vorhersage richtig oder falsch war.



Vergleichslösung: Klassifikation mit Entscheidungsbäumen (Variante b)

Das aus den Trainingsdaten gewonnene Modell lässt sich mithilfe der **Testdaten** testen. Im Folgenden findest du die eigentliche Beschriftung für die Äffchen in den Testdaten. Vergleiche die Auflösung mit deinen Beschriftungen und markiere, ob deine Vorhersage richtig oder falsch war.



Kodierung der Merkmale der Äffchen

Um die Äffchen mithilfe des Computers klassifizieren zu können, wird eine geeignete Kodierung benötigt.

Erstelle eine geeignete Kodierung für die drei gegebenen Äffchen. Suche dir dazu Merkmale aus, die die Äffchen eindeutig beschreiben und gib deren Ausprägungen für die drei Äffchen an.

Merkmale

Merkmalsausprägungen für Äffchen 1

Merkmalsausprägungen für Äffchen 1f

Merkmalsausprägungen für Äffchen 33

Aufgabenblatt: Entscheidungsbäume in Orange3

Im Folgenden wirst du in die Rolle eines Data Scientist schlüpfen, der mithilfe der zur Verfügung gestellten Daten der Äffchen aus dem Zoo ein KI-Modell zur Vorhersage von deren Beißverhalten trainiert. Ein Data Scientist arbeitet mit verschiedensten Daten und zieht mithilfe von wissenschaftlichen Analysen und entsprechender Programme Schlüsse aus diesen Daten. Das Modell, das wir heute lernen lassen, ist ein Entscheidungsbaum.

Öffne das Programm Orange3 auf deinem PC und lege ein neues Projekt an.

Aufgabe 1:

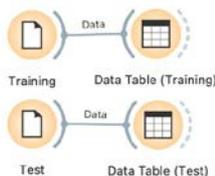
a) Von deiner Lehrkraft erhältst du zwei csv-Dateien, die die Trainings- (`affen-trainingsdaten.csv`) und Testdaten (`affen-testdaten.csv`) des Äffchenspiels beinhalten.

Öffne beide Dateien in Orange3, indem du das *File-Widget* aus dem Bereich *Data* auf die Leinwand ziehst.

Mit einem Doppelklick gelangst du in die Einstellungen. Dort kannst du die Datei auswählen (). Schließe das Fenster wieder. Für jeden Datensatz benötigst du ein eigenes *File-Widget*: eins für die Trainingsdaten und eins für die Testdaten. Benenne die Widgets, indem du mit einem Rechtsklick das Kontextmenü öffnest und *Rename* auswählst (siehe auch Hilfskarte S.1)

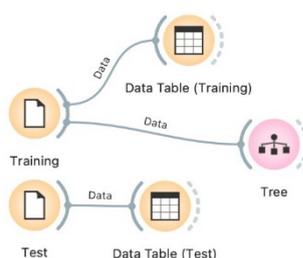


b) Noch kannst du die Daten aber nicht ansehen. Dafür wird ein weiteres Widget benötigt. Ziehe das *Data Table-Widget* aus dem Bereich *Data* auf die Leinwand. Verbinde dann den Ausgang der *File-Widgets* mit einem *Data Table-Widget*. Mit einem Doppelklick auf das Widget kannst du dir die Daten ansehen (siehe auch Hilfskarte S. 2). Beschreibe wie die Merkmale der Äffchen modelliert sind!



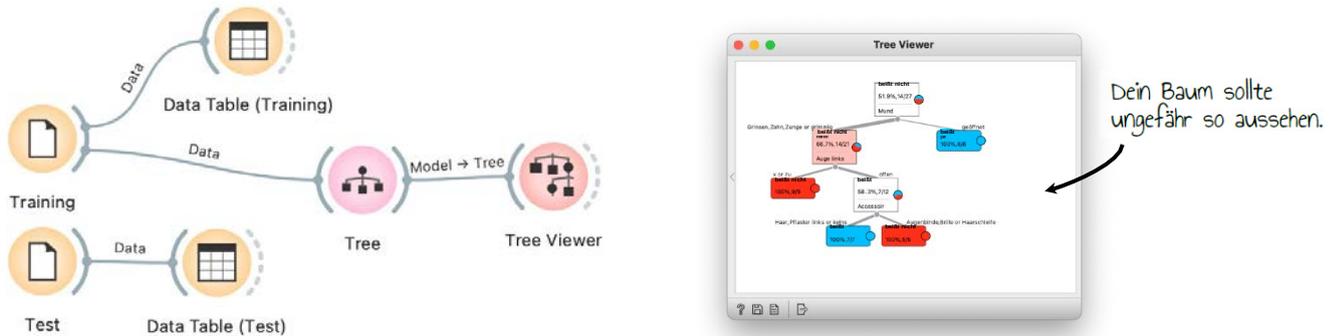
c) Jetzt hast du endlich die Daten, um einen **Entscheidungsbaum** lernen zu lassen. Ziehe dazu ein *Tree-Widget* aus dem Bereich *Model* auf die Leinwand. Verbinde die Trainingsdaten mit dem *Tree-Widget*.

Klicke doppelt auf das Widget und stelle sicher, dass ein **binärer** Entscheidungsbaum gelernt wird und der Haken bei **Induce binary tree** gesetzt ist (siehe auch Hilfskarte S.3)



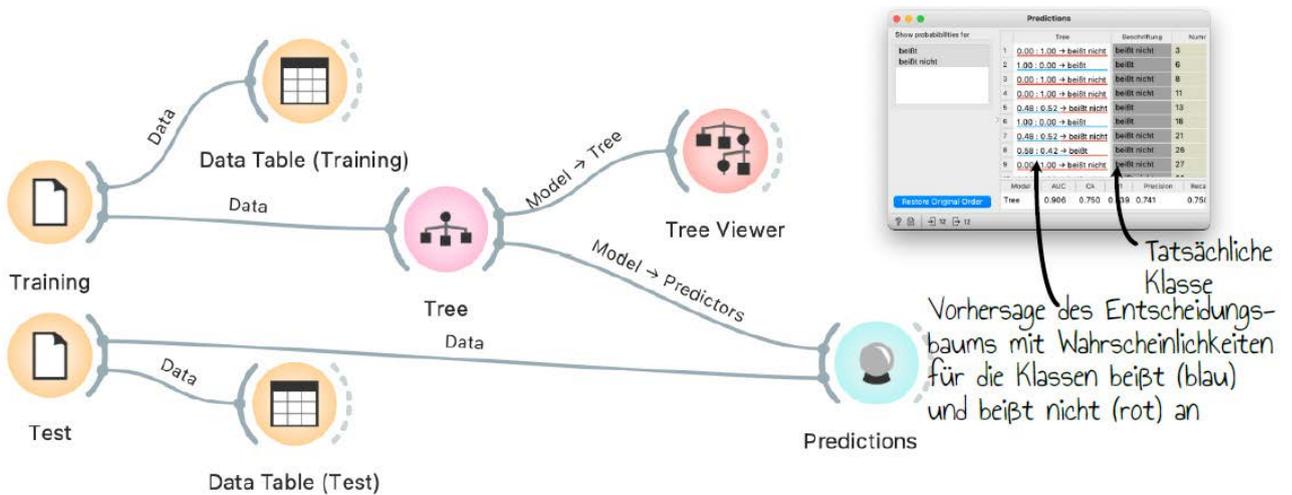
d) Mit dem *Tree-Widget* kannst du den Baum aber noch nicht ansehen, sondern nur Einstellungen fürs Training festlegen.

Um den gelernten Baum anzuzeigen, ziehe ein *Tree Viewer-Widget* aus dem Bereich *Visualize* auf die Leinwand und verbinde es mit dem *Tree-Widget*. Mit einem Doppelklick kannst du dir den Baum ansehen (siehe auch Hilfskarte S.4)



e) Im Folgenden gilt es, den gelernten Entscheidungsbaum zu testen. Dazu stehen Testdaten bereit, auf die du nun den Baum anwendest.

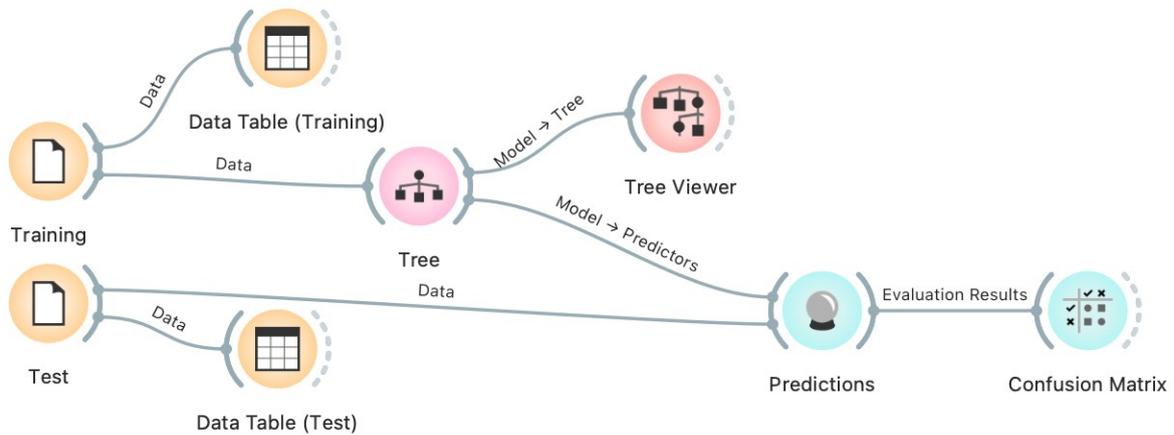
Ziehe dazu ein *Predictions-Widget* aus dem Bereich *Evaluate* auf die Leinwand, dass das zur Verfügung gestellte Modell auf die zur Verfügung gestellten Daten anwendet. Du hast bereits beides: Verbinde das Widget mit den Testdaten und dem Entscheidungsbaum. Ein Doppelklick zeigt an, wie das Modell die Daten klassifiziert hat (siehe auch Hilfskarte S.5).



f) Zum Schluss untersuchst du, wie gut das vom Computer erstellte Modell ist. Bei dieser Einschätzung hilft dir die Konfusionsmatrix.

Ziehe das *Confusion Matrix-Widget* aus dem Bereich *Evaluate* auf die Leinwand (Hilfskarte S. 6) und verbinde es mit dem *Predictions-Widget*. Ein Doppelklick auf das *Confusion Matrix-Widget* zeigt die Konfusionsmatrix an.

Berechne die Genauigkeit deiner Vorhersage mit gemäß der Formel aus der letzten Stunde. Die Felder der hier angezeigten Konfusionsmatrix entsprechen auch den Feldern aus deinem Arbeitsmaterial von letzter Stunde.



Aufgabe 2:

Jetzt kannst du das Vorgehen des Computers mit deinem eigenen, manuellen Vorgehen vergleichen.

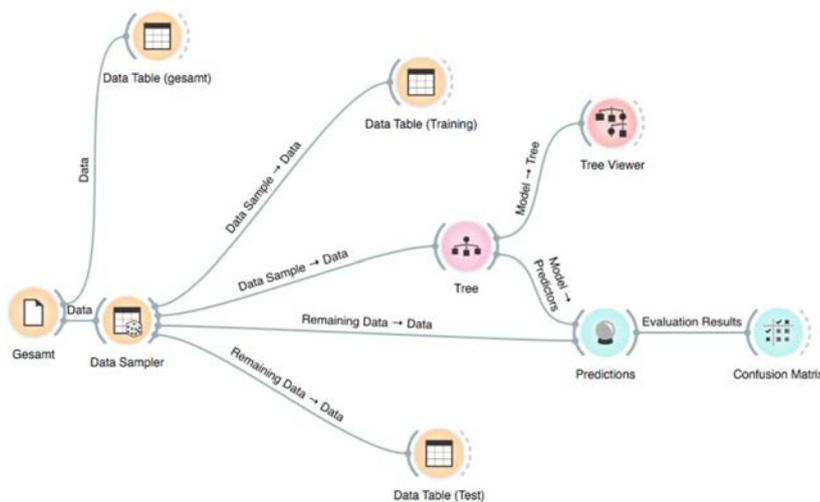
- Im Spiel aus der letzten Stunde haben wir zunächst Regeln von im Zoo lebenden Äffchen abgeleitet (Trainingsphase) und anschließend das resultierende Modell mit weiteren Äffchen getestet (Testphase). Welche Widgets übernehmen nun diese Aufgaben (Trainings - und Testphase)?
- Bewerte, aufbauend auf deinem Ergebnis in Aufgabe 1f), inwiefern das Modell des Computers für den tatsächlichen Einsatz im Zoo geeignet ist.

Aufgabe 3 (nur wenn Projektwoche anschließend wird)

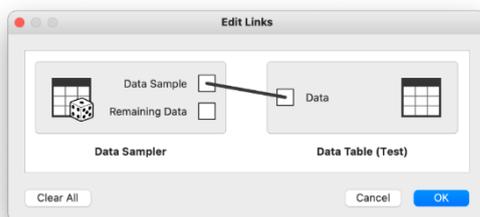
Zum Schluss lernst du, wie sich Test- und Trainingsdaten automatisch aus dem gesamten Datensatz generieren lassen. So wird nicht nur eine zufällige Aufteilung sichergestellt, sondern es spart auch Zeit.

Das Widget *Data Sampler* würfelt die Daten dafür zufällig aus (siehe auch Hilfekarte S. 7)

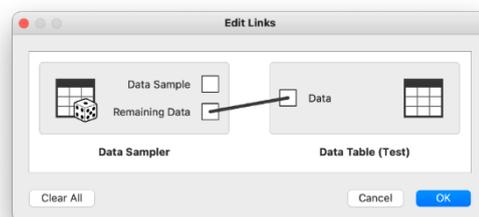
Erstelle ein neues Orange-Project für das Äffchenspiel. Als Eingabe steht dabei nur eine Datei (*affen-gesamt.csv*) mit allen Äffchen zur Verfügung. Benenne das *File-Widget* und die *Data Table-Widgets*, wie unten dargestellt. Achte darauf, diesmal nur ein *File-Widget* und das *Data Sampler-Widget* zu verwenden.



Hinweis: Wenn du das Data-Sampler-Widget mit dem nächsten Widget verbindest, steht über dieser Verbindung entweder *Data Sample* (Trainingsdaten) oder *Remaining Data* (Testdaten). Um zwischen den beiden zu wechseln, klicke doppelt auf die Verbindung. Die schwarze Linie im sich öffnenden Menü zeigt an, welche Ausgaben des linken Widgets welchen Eingaben des rechten Widgets zugeordnet werden. Die schwarze Linie im Menü kannst du durch einen Doppelklick entfernen und durch Klicken und Ziehen hinzufügen.



Beispiel: *Data Sample* wird als Eingabe für *Data* verwendet.



Beispiel: *Remaining Data* wird als Eingabe für *Data* verwendet.

Variiere den Anteil des Trainingsdatensatzes am gesamten Datensatz, indem du den Regler *Fixed proportion of data* verschiebst. Würfle anschließend den Trainingsdatensatz erneut aus, indem du auf die Schaltfläche *Sample Data* klickst.

Beobachte dabei die Veränderungen in der Konfusionsmatrix und der Baumdarstellung. Notiere deine Beobachtung!

Musterlösung zu Aufgabenblatt: Entscheidungsbäume in Orange3

Aufgabe 1b:

Die Merkmale der Äffchen sind wie folgt modelliert:

- Mund (mit Ausprägungen wie Zahn, Grinsen oder grimmig)
- Auge links (mit den Ausprägungen offen, zu und x)
- Auge rechts (mit den Ausprägungen offen, zu und x)
- Accessoire (mit Ausprägungen wie keins oder Augenbinde)
- beißt (mit den Ausprägungen ja und nein)

Als Zusatzinformation ist jeweils außerdem die Nummer des Äffchens angegeben.

Aufgabe 2a:

Trainingsphase: *Tree-Widget*; Testphase: *Predictions-Widget* und *Confusion Matrix-Widget*

Aufgabe 2b:

Individuell. Maßgeblich ist die Genauigkeit des Modells. Ob diese für den Anwendungsfall ausreicht, muss durch die Schülerin bzw. den Schüler individuell bewertet werden.

Entscheidend dafür ist, wie schwerwiegend ein Fehler des Modells für den Tierpfleger bzw. die Tierpflegerin wäre.

Aufgabe 3:

Wenn der Anteil der Trainings- und Testdaten variiert wird, verändern sich der Entscheidungsbaum und die Konfusionsmatrix.

Aufgabenblatt: Entscheidungsbäume in Orange3

Im Folgenden wirst du in die Rolle eines Data Scientist schlüpfen, der mithilfe der zur Verfügung gestellten Daten der Äffchen aus dem Zoo ein KI-Modell zur Vorhersage von deren Beißverhalten trainiert. Ein Data Scientist arbeitet mit verschiedensten Daten und zieht mit Hilfe von wissenschaftlichen Analysen und entsprechender Programme Schlüsse aus diesen Daten. Das Modell, das wir heute lernen lassen, ist ein Entscheidungsbaum.

Öffne das Programm Orange3 auf deinem PC und lege ein neues Projekt an.

Aufgabe 1:

a) Von deiner Lehrkraft erhältst du zwei csv-Dateien, die die Trainings- (`affen-trainingsdaten.csv`) und Testdaten (`affen-testdaten.csv`) des Äffchenspiels beinhalten.

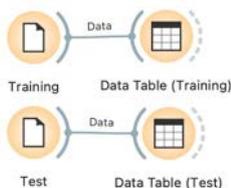
Öffne beide Dateien in Orange3, indem du das *File-Widget* aus dem Bereich *Data* auf die Leinwand ziehst. Mit einem Doppelklick gelangst du in die Einstellungen. Dort kannst du die Datei auswählen (). Schließe das Fenster wieder. Für jeden Datensatz benötigst du ein eigenes File-Widget: eins für die Trainingsdaten und eins für die Testdaten. Benenne die Widgets, indem du mit einem Rechtsklick das Kontextmenü öffnest und *Rename* auswählst (siehe auch Hilfskarte S.1).



b) Noch kannst du die Daten aber nicht ansehen. Dafür wird ein weiteres Widget benötigt.

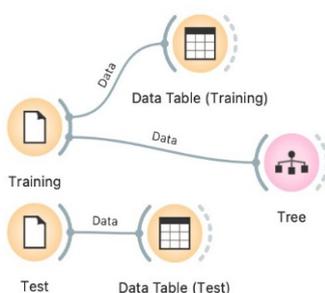
Ziehe das *Data Table*-Widget aus dem Bereich *Data* auf die Leinwand. Verbinde dann den Ausgang der *File*-Widgets mit einem *Data Table*-Widget. Mit einem Doppelklick auf das Widget kannst du dir die Daten ansehen (siehe auch Hilfskarte S. 2).

Beschreibe wie die Merkmale der Äffchen modelliert sind!



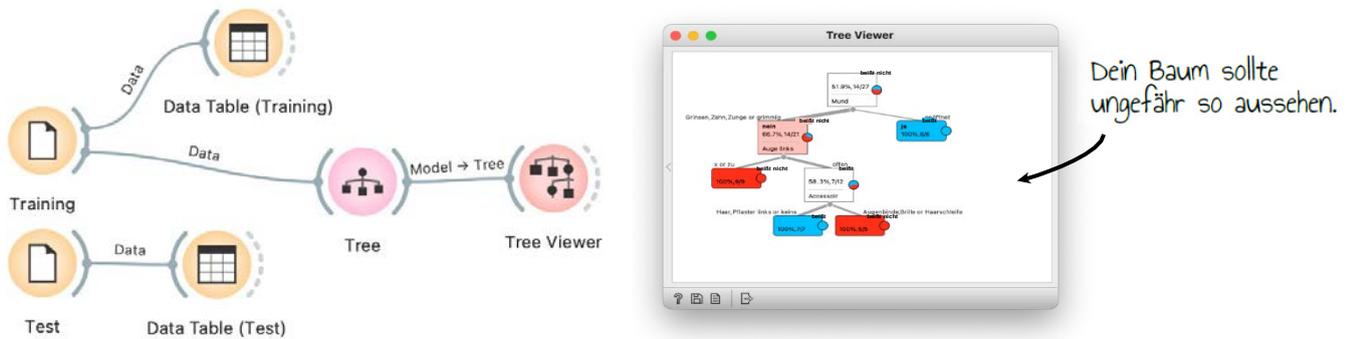
c) Jetzt hast du endlich die Daten, um einen **Entscheidungsbaum** lernen zu lassen. Ziehe dazu ein *Tree*-Widget aus dem Bereich *Model* auf die Leinwand. Verbinde die Trainingsdaten mit dem *Tree*-Widget.

Klicke doppelt auf das Widget und stelle sicher, dass ein **binärer** Entscheidungsbaum gelernt wird und der Haken bei Induce binary tree gesetzt ist (siehe auch Hilfskarte S.3).



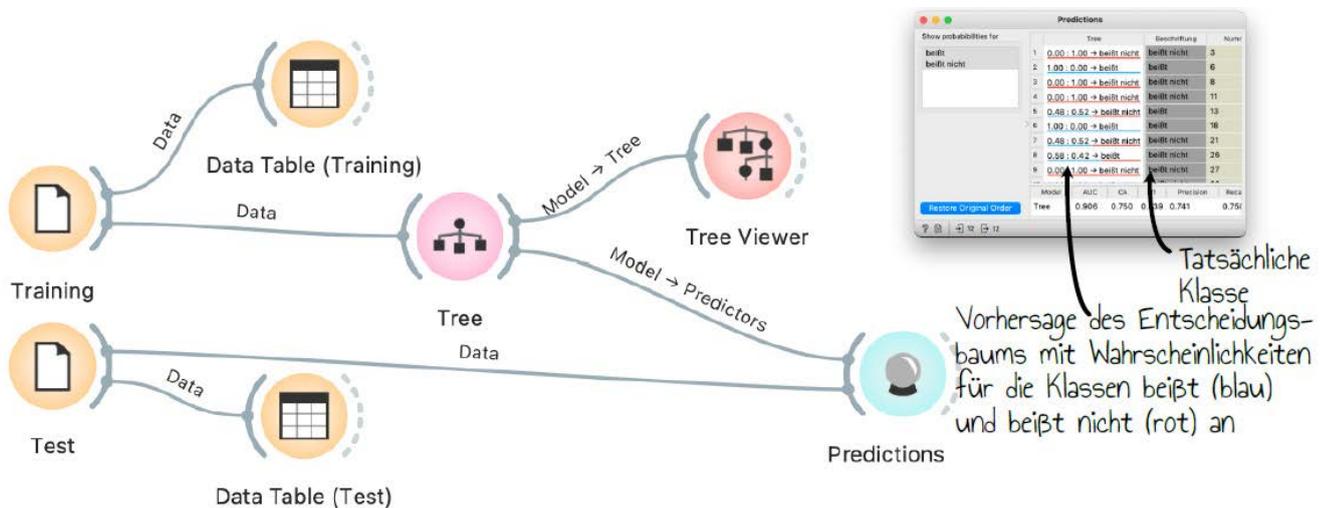
d) Mit dem *Tree-Widget* kannst du den Baum aber noch nicht ansehen, sondern nur Einstellungen fürs Training festlegen.

Um den gelernten Baum anzuzeigen, ziehe ein *Tree Viewer*-Widget aus dem Bereich *Visualize* auf die Leinwand und verbinde es mit dem *Tree-Widget*. Mit einem Doppelklick kannst du dir den Baum ansehen (siehe auch Hilfskarte S.4)



e) Im Folgenden gilt es, den gelernten Entscheidungsbaum zu testen. Dazu stehen Testdaten bereit, auf die du nun den Baum anwendest.

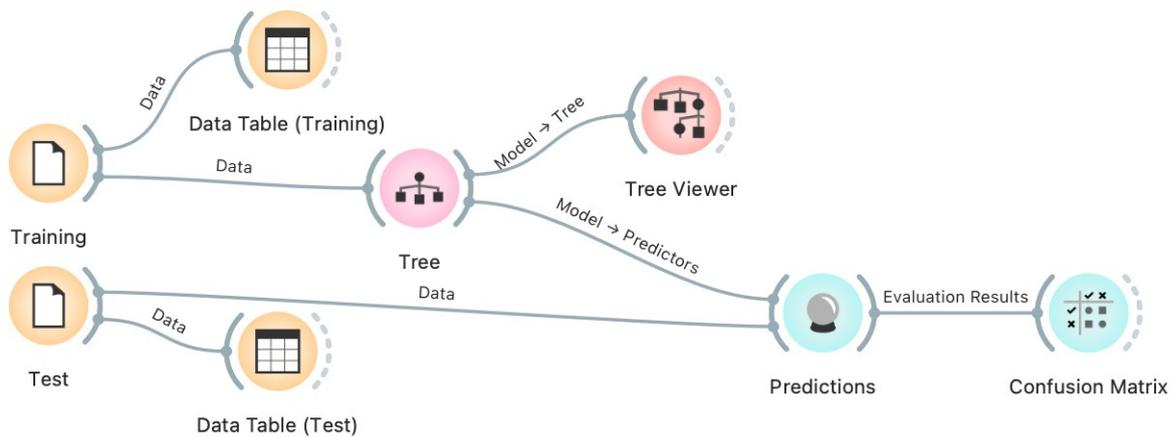
Ziehe dazu ein *Predictions*-Widget aus dem Bereich *Evaluate* auf die Leinwand, dass das zur Verfügung gestellte Modell auf die zur Verfügung gestellten Daten anwendet. Du hast bereits beides: Verbinde das Widget mit den Testdaten und dem Entscheidungsbaum. Ein Doppelklick zeigt an, wie das Modell die Daten klassifiziert hat (siehe auch Hilfskarte S.5).



f) Schluss untersuchst du, wie gut das vom Computer erstellte Modell ist. Bei dieser Einschätzung hilft dir die *Konfusionsmatrix*.

Ziehe das *Confusion Matrix*-Widget aus dem Bereich *Evaluate* auf die Leinwand (Hilfskarte S. 6) und verbinde es mit dem *Predictions*-Widget. Ein Doppelklick auf das *Confusion Matrix*-Widget zeigt die Konfusionsmatrix an.

Berechne Genauigkeit, Trefferquote und Präzision deiner Vorhersage gemäß der Formel aus der letzten Stunde. Die Felder der hier angezeigten Konfusionsmatrix entsprechen auch den Feldern aus deinem Arbeitsmaterial von letzter Stunde.



Aufgabe 2:

Jetzt kannst du das Vorgehen des Computers mit deinem eigenen, manuellen Vorgehen vergleichen.

- Im Spiel aus der letzten Stunde haben wir zunächst Regeln von im Zoo lebenden Äffchen abgeleitet (Trainingsphase) und anschließend das resultierende Modell mit weiteren Äffchen getestet (Testphase). Welche Widgets übernehmen nun diese Aufgaben (Trainings - und Testphase)?
- Vergleiche den erzeugten Entscheidungsbaum (Doppelklick auf Tree Viewer) mit deiner händisch gefundenen Lösung von letzter Stunde. Beschreibe, ob und worin sich die Entscheidungsbäume unterscheiden.
- Vergleiche die Konfusionsmatrix und die Metriken deiner händisch gefundenen Lösung mit der des Entscheidungsbaums aus Orange 3 (Doppelklick auf Confusion Matrix). Bewerte den erzeugte Entscheidungsbaum im Vergleich zu deiner händisch erzeugten Lösung.

Aufgabe 3:

Für diese Aufgabe kannst du die Ergebnisse von Aufgabe 1 nutzen. Untersuche die Vorhersagequalität für zwei Baumvarianten:

- i) binärer Baum (Induce binary tree) ii) Baum ohne Einschränkungen (Induce binary tree)

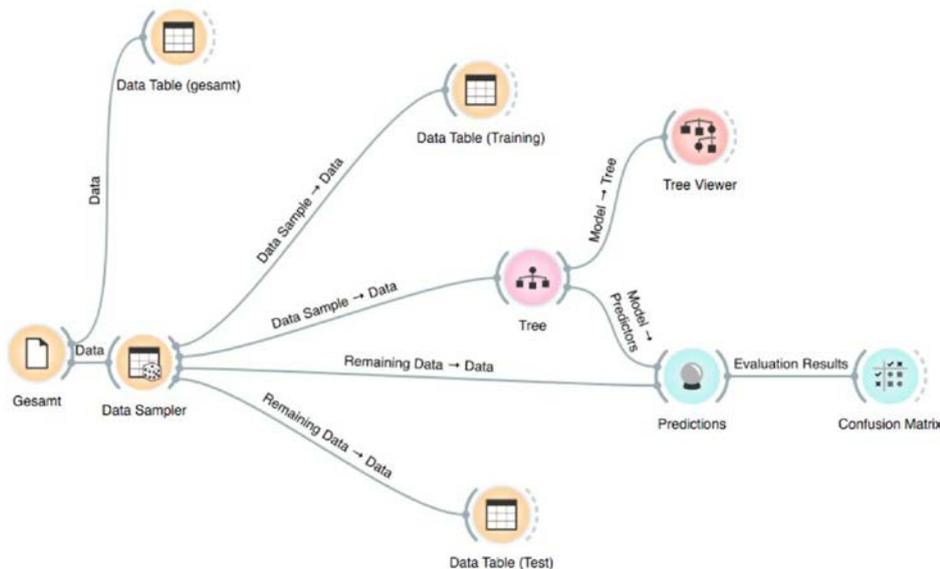
- Vergleiche die beiden erzeugten Entscheidungsbäume. Beschreibe, worin sich die Entscheidungsbäume unterscheiden.
- Vergleiche die beiden zugehörigen Konfusionsmatrizen (Doppelklick auf Confusion Matrix). Bist du über das Ergebnis überrascht? Wenn ja, warum?
- Stelle eine Vermutung auf, warum auch Entscheidungsbäume mit weniger Entscheidungsregeln die Vorhersage verbessern könnten!

Aufgabe 4:

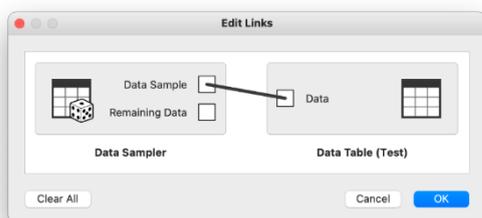
Zum Schluss lernst du, wie sich Test- und Trainingsdaten automatisch aus dem gesamten Datensatz generieren lassen. So wird nicht nur eine zufällige Aufteilung sichergestellt, sondern es spart auch Zeit.

Das Widget *Data Sampler* würfelt die Daten dafür zufällig aus (siehe auch Hilfekarte S.7)

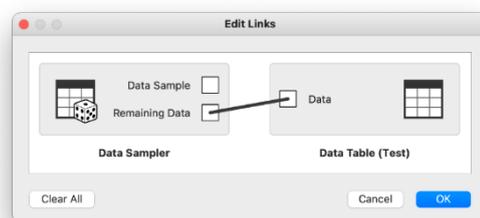
Erstelle ein neues Orange-Projekt für das Äffchenspiel. Als Eingabe steht dabei nur eine Datei (*affen-gesamt.csv*) mit allen Äffchen zur Verfügung. Benenne das *File-Widget* und die *Data Table*-Widgets, wie unten dargestellt. Achte darauf, diesmal nur ein *File-Widget* und das *Data Sampler*-Widget zu verwenden.



Hinweis: Wenn du das Data-Sampler-Widget mit dem nächsten Widget verbindest, steht über dieser Verbindung entweder Data Sample (Trainingsdaten) oder Remaining Data (Testdaten). Um zwischen den beiden zu wechseln, klicke doppelt auf die Verbindung. Die schwarze Linie im sich öffnenden Menü zeigt an, welche Ausgaben des linken Widgets welchen Eingaben des rechten Widgets zugeordnet werden. Die schwarze Linie im Menü kannst du durch einen Doppelklick entfernen und durch Klicken und Ziehen hinzufügen.



Beispiel: *Data Sample* wird als Eingabe für *Data* verwendet.



Beispiel: *Remaining Data* wird als Eingabe für *Data* verwendet.

Variiere den Anteil des Trainingsdatensatzes am gesamten Datensatz, indem du den Regler Fixed proportion of data verschiebst. Würfle anschließend den Trainingsdatensatz erneut aus, indem du auf die Schaltfläche  klickst.

Beobachte dabei die Veränderungen in der Konfusionsmatrix und der Baumdarstellung. Notiere deine Beobachtung!

Musterlösung zu Aufgabenblatt: Entscheidungsbäume in Orange3

Aufgabe 1b:

Die Merkmale der Äffchen sind wie folgt modelliert:
 -Mund (mit Ausprägungen wie Zahn, Grinsen oder grimmig)
 -Auge links (mit den Ausprägungen offen, zu und x)
 -Auge rechts (mit den Ausprägungen offen, zu und x)
 -Accessoire (mit Ausprägungen wie keins oder Augenbinde)
 -beißt (mit den Ausprägungen ja und nein)

Als Zusatzinformation ist jeweils außerdem die Nummer des Äffchens angegeben.

Aufgabe 2a:

Trainingsphase: *Tree-Widget*; Testphase: *Predictions-Widget* und *Confusion Matrix-Widget*

Aufgabe 2b:

Individuell. Unterschiede könnten sich bspw. hinsichtlich der Anzahl der richtig und falsch klassifizierten Äffchen ergeben. Auch bei der Tiefe des Baums, dem Verzweigungsgrad oder den Merkmalen der jeweils falsch klassifizierten Äffchen können sich Unterschiede ergeben.

Aufgabe 2c:

Individuell. Metriken helfen schnell dabei einen Überblick über die Modelle zu bekommen und das bessere Modell für die Aufgabe auszuwählen. Auch das computergenerierte Modell wird nicht alle Äffchen richtig klassifizieren.

Aufgabe 3a:

Der Baum ohne Einschränkungen hat einen höheren Verzweigungsgrad als der binäre Baum und verfügt über mehr Entscheidungsregeln, die die Trainingsdaten noch spezifischer aufteilen.

Aufgabe 3b:

Der nicht-binäre Baum klassifiziert deutlich mehr Testdaten falsch bzw. hat eine deutlich geringere Genauigkeit. Das ist zunächst überraschend, da man aufgrund der zusätzlichen Möglichkeiten, die Zuordnung zwischen Ein- und Ausgabe zu lernen, davon ausgehen könnte, dass dadurch ein genaueres Modell möglich ist.

Aufgabe 3c:

Wie in Aufgabe 3b gesehen kann ein Modell, das über mehr Möglichkeiten verfügt, die Beziehung zwischen Ein- und Ausgabe zu modellieren, zu schlechteren Ergebnissen führen. Dies liegt daran, dass während des Trainingsprozesses eine Überanpassung an die Spezifika der Trainingsdaten erfolgt – der Algorithmus lernt die Trainingsdaten gewissermaßen „auswendig“. Das resultierende Modell kann nicht mehr ausreichend auf die Testdaten verallgemeinern. Obwohl es erstmal nicht intuitiv erscheint, sind daher einfache Modelle in vielen Fällen erfolgreicher in der Vorhersage als deutlich komplexer erscheinende Modelle.

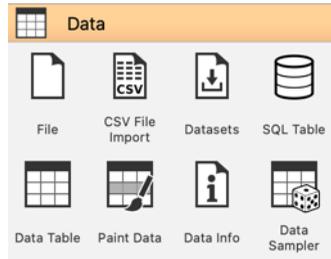
Aufgabe 4:

Wenn der Anteil der Trainings- und Testdaten variiert wird, verändern sich der Entscheidungsbaum und die Konfusionsmatrix.



HILFE: FILE Einlesen von Daten

Um Daten einzulesen, gibt es das Widget *File* im Abschnitt *Data*.



Das Konfigurationsmenü erreicht man mit einem Doppelklick auf das Widget. Dort muss die Datei ausgewählt werden ().



Nach dem Laden können die Merkmale mit ihren Datentypen, Rollen und möglichen Ausprägungen überprüft werden.

Type:

 **Categorical:** Es gibt nur endlich viele Merkmalsausprägungen (z.B. Auge links)

 **Text:** Zeichenketten (z.B. Name)

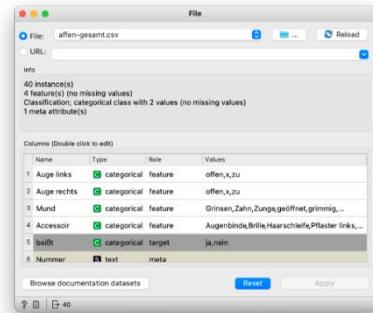
 **Numeric:** Zahlenwerte (z.B. Alter)

Role:

Feature: Zu untersuchende Merkmale, um Zielklasse zu bestimmen (z.B. „Auge links“ oder „Mund“)

Target: Zu bestimmende Klasse (z.B. „beißt“ mit den Ausprägungen „ja/nein“)

Meta: Zusatzinformationen, die für Untersuchung nicht wichtig sind (z.B. Äffchennummer)



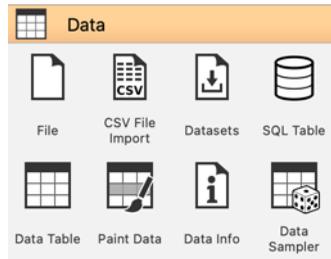
Mit einem Rechtsklick auf das Widget kann dieses umbenannt werden (Rename).





HILFE: DATA TABLE Ausgabe einer Tabelle

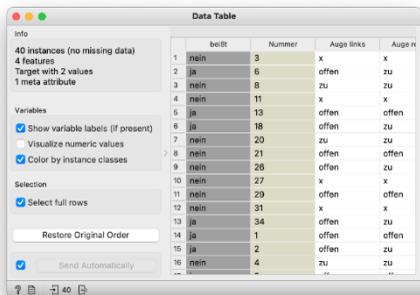
Um sich den Inhalt einer Tabelle anzusehen, gibt es das Widget *Data Table* im Abschnitt *Data*.



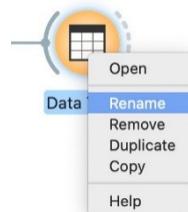
Du musst eine Datenquelle an das neue *Widget* anschließen. Die Quelle ist das *File-Widget*. Die Verbindung wird mit klicken und ziehen von der Quelle (File) zur Senke (Data Table) hergestellt.



Mit einem Doppelklick auf das *Widget* kann die Tabelle betrachtet werden.



Mit einem Rechtsklick auf das *Widget* kann dieses umbenannt werden (Rename).

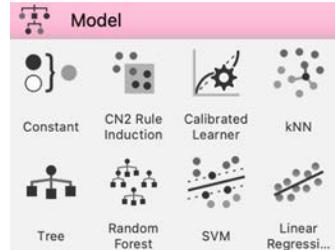




HILFE: TREE

Entscheidungsbaum

Für das Erzeugen von Entscheidungs-bäumen, die Entscheidungen in Form hierarchischer Regeln abbilden, gibt es das Widget *Tree* im Abschnitt *Model*.

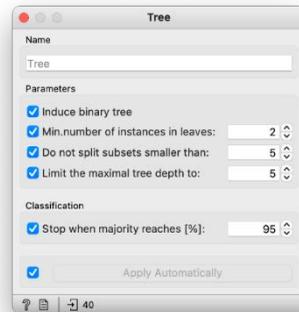


Du musst eine Datenquelle an das neue Widget anschließen. Die Quelle ist unser *File*-Widget mit den Trainingsdaten. Die Verbindung geschieht mit klicken und ziehen von der Quelle (File) zur Senke (Tree).

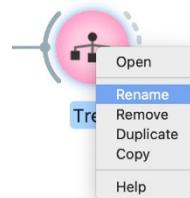


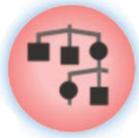
Mit einem Doppelklick auf das Widget können Eigenschaften des zu erzeugenden Baums festgelegt werden.

Im Beispiel rechts wurde festgelegt, dass der zu erzeugende Entscheidungsbaum ein binärer Baum sein soll (Induce binary tree), d.h. jeder Knoten verfügt über maximal zwei nachfolgende Knoten.



Mit einem Rechtsklick auf das Widget kann dieses umbenannt werden (Rename).





HILFE: TREE VIEWER Entscheidungsbaum anzeigen

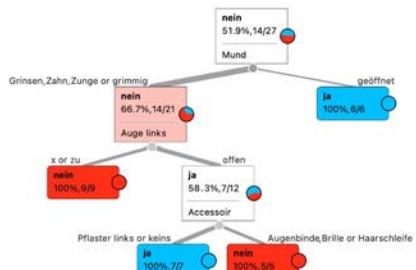
Zur Darstellung eines Entscheidungsbaums gibt es das Widget *Tree Viewer* im Abschnitt *Visualize*.



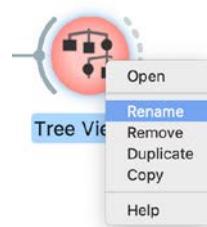
Du musst einen Entscheidungsbaum als Quelle an das neue Widget anschließen. Die Quelle ist ein *Tree*-Widget. Die Verbindung wird mit klicken und ziehen von der Quelle (Tree) zur Senke (Tree Viewer) hergestellt.



Mit einem Doppelklick auf das Widget kann man den Entscheidungsbaum betrachten. Beachte dabei auch die Details, wie Einfärbung der Knoten und Linienstärke der Kanten. In den Knoten sind auch die Anzahl an Exemplaren (engl. instance) vermerkt, für die der Knoten steht. So vertritt der Wurzelknoten hier 27 Affen.



Mit einem Rechtsklick auf das Widget kann dieses umbenannt werden (Rename).

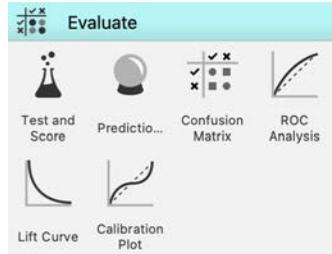




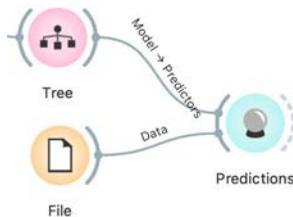
HILFE: PREDICTIONS

Auswertung: Vorhersage

Zur Nutzung eines Entscheidungsbaums für Vorhersagen (also das Anwenden auf Datensätze) gibt es das Widget *Predictions* im Abschnitt *Evaluate*.



Du musst eine Datenquelle und ein Modell an das neue Widget anschließen. Die Datenquelle ist ein *File-Widget*, das Modell unser Baum. Die Verbindung geschieht mit klicken und ziehen von der Quelle (File sowie Tree) zur Senke (Predictions).



Tree	beißt	Nummer	Auge links	Auge rechts	Mund	Accessoir
1 <u>0.00 : 1.00 → nein</u>	nein	3	x	x	Zahn	keins
2 <u>1.00 : 0.00 → ja</u>	ja	6	offen	zu	Grinsen	keins
3 <u>0.00 : 1.00 → nein</u>	nein	8	zu	zu	Grinsen	keins

Mit einem Doppelklick kann die Prognose direkt mit den Daten verglichen werden. Für eine bessere Übersicht kann die Trennung zwischen der Baumvorhersage, links, und den Daten, rechts, mit der Maus verschoben werden (so wie oben geschehen).

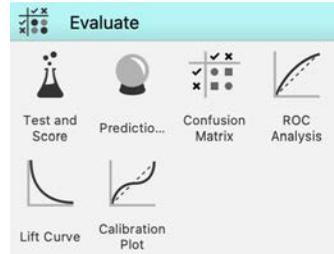
Hier kann man beispielsweise sehen, dass die Äffchen 3, 6 und 8 richtig vorhergesagt wurden. Äffchen 3 und 8 beißen nicht (nein) und Äffchen 6 beißt (ja).



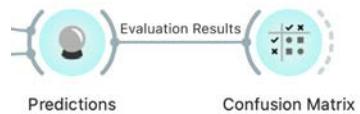
HILFE: CONFUSION MATRIX

Auswertung: Konfusionsmatrix

Zur Darstellung einer Konfusionsmatrix gibt es das Widget *Confusion Matrix* im Abschnitt *Evaluate*.



Du musst die Vorhersage als Quelle an das neue Widget anschließen. Die Quelle ist ein *Predictions*-Widget. Die Verbindung geschieht mit klicken und ziehen von der Quelle (Predictions) zur Senke (Confusion Matrix).



		Predicted		Σ
		ja	nein	
Actual	ja	4	0	4
	nein	1	8	9
Σ		5	8	13

Mit einem Doppelklick auf das Widget kann die Konfusionsmatrix betrachtet werden.

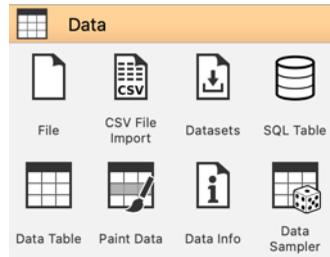




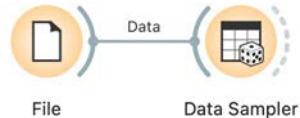
HILFE: DATA SAMPLER

Datensatz zufällig aufteilen

Um einen großen Datensatz in zwei Teile zu zerlegen, gibt es das Widget *Data Sampler* im Abschnitt *Data*. Dies ist hilfreich, um einen Datensatz in Trainings- und Testdaten aufzuteilen.



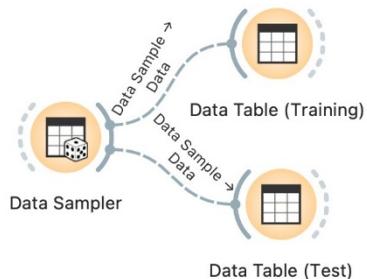
Du musst eine Datenquelle an das neue Widget anschließen. Die Quelle ist ein *File*-Widget. Die Verbindung wird mit klicken und ziehen von der Quelle (*File*) zur Senke (*Data Sampler*) hergestellt.



Der *Data Sampler* erzeugt nun zwei neue Quellen (die je zwei Teile des Datensatzes enthalten):

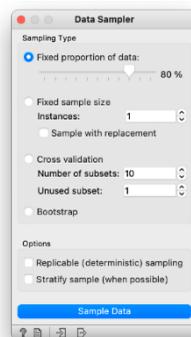
- *Data Sample*
- *Remaining Data*

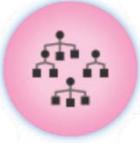
Verbindest du diese Quellen mit anderen Widgets, so musst du nachträglich kontrollieren, ob Orange die richtige Quelle gewählt hat.



Mit einem Doppelklick auf das Widget *Data Sampler* kann der Anteil der Trainingsdatensätze (*Data Sample*) an den gesamten Datensätzen festgelegt werden (z.B. 80%).

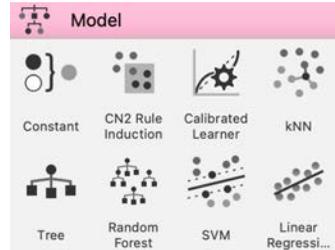
Zusätzlich kann auch ein erneutes Auswürfeln des Trainingsdatensatzes gestartet werden (*Sample Data*).



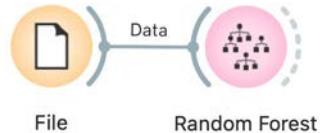


HILFE: RANDOM FOREST Random Forest

Random Forest Modelle enthalten mehrere Entscheidungsbäume und stimmen im Mehrheitsverfahren ab. Für Random Forests gibt es das Widget Random Forest im Abschnitt Model.



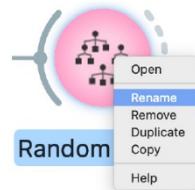
Du musst eine Datenquelle an das neue Widget anschließen. Die Quelle ist ein *File*-Widget mit den Trainingsdaten. Die Verbindung wird mit klicken und ziehen von der Quelle (File) zur Senke (Random Forest) hergestellt.

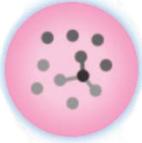


Mit einem Doppelklick auf das Widget können Eigenschaften des zu erzeugenden *Random Forest* festgelegt werden. Im Beispiel rechts wurde festgelegt, dass dieser aus 10 Bäumen bestehen soll.



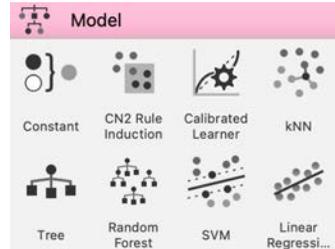
Mit einem Rechtsklick auf das Widget kann dieses umbenannt werden (Rename).



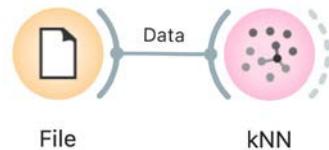


HILFE: KNN K-Nächste-Nachbarn

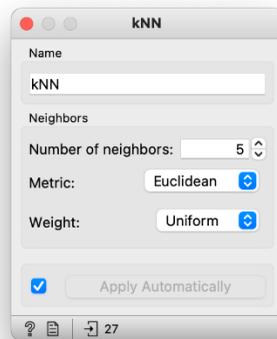
Das k-Nächste-Nachbarn-Modell entscheidet auf Basis der Zielmerkmale der Datenpunkte mit den ähnlichsten Merkmalsausprägungen (die nächsten Nachbarn). Für ein k-Nächste-Nachbarn-Modell gibt es das Widget *kNN* im Abschnitt *Model*.



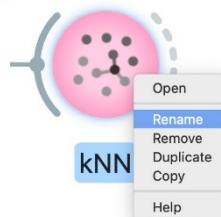
Du musst eine Datenquelle an das neue Widget anschließen. Die Quelle ist ein File-Widget mit den Trainingsdaten. Die Verbindung wird mit klicken und ziehen von der Quelle (File) zur Senke (kNN) hergestellt.



Mit einem Doppelklick auf das Widget können Eigenschaften des zu erzeugenden kNN-Modells festgelegt werden. Im Beispiel rechts wurde festgelegt, dass zur Klassifikation stets die $k=5$ nächsten Nachbarn berücksichtigt werden sollen.



Mit einem Rechtsklick auf das Widget kann dieses umbenannt werden (Rename).

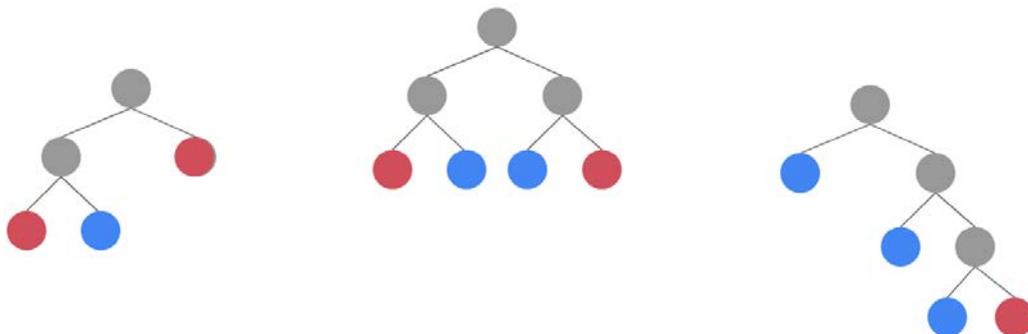


Erläuterung KNN bzw. Random Forest:

Random Forest	Random-Forest ist ein Verfahren für überwachtes Lernen, bei dem mehrere Entscheidungsbäume generiert und Entscheidungen nach dem Mehrheitsprinzip getroffen werden.
k-Nächste-Nachbarn	k-Nächste-Nachbarn ist ein Verfahren für überwachtes Lernen, bei dem die Zugehörigkeit zu einer Klasse bestimmt wird, indem die nächsten k Nachbarn eines Datenpunktes betrachtet werden und die Klassenzugehörigkeit nach dem Mehrheitsprinzip entschieden wird.

Optional: Klassifikation mittels Random Forest-Methode

Variiert man das Lernen von Entscheidungsbäumen, können je nach zur Entscheidung herangezogenen Merkmalen verschiedene Entscheidungsbäume resultieren. Anstelle eines einzelnen Entscheidungsbaumes kann es hilfreich sein, die Entscheidung mehrerer Entscheidungsbäume zu kombinieren, um die Klassifikation zu verbessern. Häufig wird eine Art von Zufall bei der Erstellung der Bäume gewählt, weshalb man dann bei diesem „Wald von Entscheidungsbäumen“ von einem Random Forest¹ spricht.



Optional: Klassifikation mittels k-Nearest-Neighbour

Die verschiedenen Merkmale der Daten lassen sich als Vektoren interpretieren, bei dem jede Dimension ein Merkmal darstellt. Bei der k-Nearest-Neighbour-Klassifikation (oder k-Nächste-Nachbarn-Klassifikation) wird die Klasse eines Datensatzes bestimmt, indem seine nächsten k Nachbarn in diesem Raum betrachtet werden und die Klassenzugehörigkeit nach dem Mehrheitsprinzip entschieden wird: Gehört die Mehrheit der k nächsten Nachbarn der Klasse A an, erhält auch der zu klassifizierende Datenpunkt die Klasse A. Das Lernen beschränkt sich in diesem Fall auf ein Abspeichern der Trainingsbeispiele.

¹ Englisch für: Zufälliger Wald

Datensätze für Projekt

Datensatz	Beschreibung
Attrition - Train (in Orange3 enthalten)	<p>In diesem Datensatz lassen sich Faktoren, die zur Fluktuation von Arbeitnehmern führen, entdecken und Fragen wie nach dem Einfluss der Entfernung zum Arbeitsort oder dem durchschnittlichen Monatseinkommen untersuchen. Es handelt sich dabei um einen fiktiven Datensatz, der von IBM erstellt wurde. Aufgabe ist es, ein Modell zu trainieren, das abwanderungswillige Mitarbeiter erkennt.</p> <p>Ziel: Abwanderungswillige Mitarbeiter vorhersagen</p>
Bank Marketing (in Orange3 enthalten)	<p>Diese Daten entstammen den Direktmarketing-Kampagnen (Telefonanrufe) einer portugiesischen Bank. Aufgabe ist es, auf Basis dieser Daten vorherzusagen, ob ein Kunde eine Festgeldanlage tätigen möchte. Dazu stehen Kundenprofile zur Verfügung (bspw. mit Alter, Berufstyp oder Informationen über frühere Kredite).</p> <p>Ziel: Potenzielle Kunden für Festgeldanlagen vorhersagen</p>
Breast Cancer (in Orange3 enthalten)	<p>Dieser Datensatz enthält Diagnoseinformationen über Brustkrebs. Aufgabe ist es, auf Basis von (bis zu) 9 Merkmalen vorherzusagen, ob Brustkrebs vorliegt.</p> <p>Ziel: Brustkrebs vorhersagen</p>
Adult (in Orange3 enthalten)	<p>Dieser Datensatz enthält Ergebnisse der amerikanischen Volkszählung von 1994. Aufgabe ist es, ein Modell zu trainieren, das entscheiden kann, ob eine Person mehr als 50 Tausend Dollar pro Jahr verdient.</p> <p>Ziel: Vorhersagen, wer mehr als 50.000\$ pro Jahr verdient</p>
Student Performance Data Set	<p>Dieser Datensatz enthält Leistungen von Schülerinnen und Schülern zweier portugiesischer Schulen. Aufgabe ist es, basierend auf demografischen, sozialen und schulischen Merkmalen vorherzusagen, ob der/die Schüler/in den Kurs bestehen wird</p> <p><i>Dateien finden sich im Begleitmaterial.</i></p> <p>Ziel: Bestehen vorhersagen</p>

Arbeitsauftrag: Projekt

Als Data Scientist ist es eure Aufgabe, Probleme durch Erstellen eines Klassifikationsmodells zu lösen. Dazu steht euch ein Datensatz zur Verfügung, der den Ausgangspunkt für euer KI-Modell darstellt.

Folgt dazu folgenden Schritten:

1. Erstellt ein neues Orange3-Projekt.



- Wenn euer Datensatz bereits in Orange3 enthalten ist, zieht das *Datasets*-Widget auf die Leinwand und wählt den entsprechenden Datensatz mit einem Doppelklick aus.

Datasets



- Wenn euer Datensatz nicht in Orange3 enthalten ist, öffnet ihn wie den Öffchendatensatz mithilfe des *File*-Widgets.

File

2. Verschafft euch anschließend einen Überblick über den Datensatz mithilfe des *Data Table*-Widgets. Notiert, welche Informationen in den Spalten gespeichert sind. Was sind die möglichen Klassen? Welche Merkmale stehen euch zur Verfügung?
3. Teilt die Daten mithilfe des *Data Sampler*-Widget in Trainings- und Testdaten auf.
4. Trainiert mehrere Modelle, indem ihr unterschiedliche Merkmale für das Training auswählt und verschiedene Parameter des Trainingsprozesses festlegt.
5. Testet und bewertet eure Modelle mithilfe einer geeigneten Metrik.
6. Überlegt euch, welche Personengruppen wie von eurem Modell profitieren und welche Personengruppen wie von eurem Modell benachteiligt werden könnten.
7. Gestaltet ein Poster, das euren Datensatz, euer Ziel und eure Ergebnisse knapp und präzise zusammenfasst. Was findet ihr an eurer Auswertung überraschend?

KI in den Nachrichten

Lese dir die folgenden Szenarien aufmerksam durch.

Szenario 1: Bewerberauswahl mit KI

Ein Unternehmen sucht neue Mitarbeiter und Mitarbeiterinnen. Dazu soll möglichst wenig Zeit investiert werden. Dennoch sollte die Auswahl nahezu perfekt laufen. Daher trainieren sie ein maschinelles Modell. Als Trainingsdaten werden die Einstellungen der letzten 10 Jahre genutzt. Die eingestellten Mitarbeiterinnen und Mitarbeiter werden u.a. mit Anschrift, Alter, Informationen aus dem Lebenslauf, Geschlecht und Foto erfasst.

Das KI-System sollte somit lernen, welche Eigenschaften das Unternehmen bei seinen Mitarbeiterinnen und Mitarbeitern bevorzugt und damit anschließend selbst die Bewerberauswahl vornehmen.

Das Unternehmen setzte das entstandene Modell für einige Zeit ein. Dabei bemerkte das Management, dass, obwohl viele Bewerber Frauen waren, sie dennoch eher selten vom KI-System eingestellt wurden und häufig direkt eine Ablehnung erfuhren. Weil das in der IT-Branche tätige Unternehmen in der Vergangenheit vorwiegend Männer eingestellt hatte, lernte das Modell, dass Bewerbungen von Frauen schlechter zu bewerten seien. Dies war auch dann der Fall, wenn die Bewerbung keinerlei Angabe des Geschlechts enthielt, da diese Information auch indirekt bspw. über Interessen erschlossen werden konnte.

Szenario 2: Gesichtserkennungssysteme

Die Amerikanerin Joy Buolamwini, Wissenschaftlerin am MIT in Boston, untersuchte 2017 in einem Forschungsprojekt die damals aktuelle Gesichtserkennungssoftware großer Anbieter wie Microsoft, IBM oder Face++. Dabei stellte sie fest, dass die Software der Hersteller zwar insgesamt eine sehr hohe Genauigkeit bei der Erkennung des Geschlechts von über 90% aufwies, aber deutlich schlechter darin sind, das Geschlecht einer dunkelhäutigen Frau zu bestimmen. So wiesen die Systeme dann bspw. nur noch eine Genauigkeit von 65,3% (IBM), 65,5 % (Face++) und 79,3% auf.

Der Softwareentwickler Jacky Alciné entdeckte im Jahr 2015 in seiner Foto-Sammlung ein Album mit dem Titel „Gorillas“, das Googles Gesichtserkennungsalgorithmus automatisch für ihn erstellt hatte. Darin ein Foto von ihm und einer ebenfalls schwarzen Freundin. Zwei Jahre später hatte Google es immer noch nicht geschafft, das Problem zu beheben und behalf sich stattdessen damit, Primaten aus dem Lexikon der Suchbegriffe zu tilgen: eine Verlegenheitslösung. Aber das ist nur ein Beispiel dafür, wie Menschen im Alltag von schlecht funktionierenden Systemen diskriminiert werden. Gesichtserkennung wird inzwischen nicht nur verwendet, um Fotos zu sortieren. Auch die Polizei setzt sie bei der Strafverfolgung ein, auf einigen Flughäfen beschleunigt sie die Passkontrolle (Derivat von netzpolitik.org, BY-NC-SA).

Szenario 3: Notenvergabe in Großbritannien

Wegen der Corona-Pandemie und den Schulausfällen konnten in Großbritannien Prüfungen zum Abitur und zur mittleren Reife nicht abgelegt werden. Zuerst plante das Bildungsministerium, dass die Lehrkräfte die Noten auf Grundlage früherer Bewertungen vergaben. Das führte dazu, dass die Noten im Durchschnitt besser waren als in den Vorjahren. Deswegen ließ das Bildungsministerium die Noten noch einmal mit einem Algorithmus korrigieren, der die Durchschnittsnoten der jeweiligen Schulen der Vorjahre mit einbezog. Die Folge: In 280.000 Fällen wurden Schülerinnen und Schüler schlechter bewertet, das sind fast 40 Prozent aller Schulabschlüsse des Jahres. Bei den Protesten machten die Schülerinnen und Schüler auf Schildern darauf aufmerksam, dass sie den Algorithmus als diskriminierend wahrnehmen. So war auf Plakaten zu lesen, dass Lehrerinnen und Lehrer und nicht die Postleitzahlen über Noten entscheiden sollten. Die Maßnahme wurde mit Schildern wie „Classroom not Class War“ als sozial ungerecht bezeichnet. Hintergrund ist, dass Schülerinnen und Schüler aus privaten, privilegierten und guten Schulen nicht von der Abwertung betroffen sein könnten, während „Problemschulen“ zur Abwertung führen können – ungeachtet der individuellen Schulleistungen der Einzelnen. (Derivat von netzpolitik.org, BY-NC-SA).

Diskutiere mit deinem Nachbarn folgende Fragestellungen:

- Welches Problem wird in den jeweiligen Szenarien beschrieben?
- Welche Ursache(n) könnten die problematischen Entscheidungen der KI-Systeme in den beschriebenen Szenarien haben? / Erläutere unter Einbeziehung der verwendeten Daten, warum es zu diesen Problemen kommen könnte?
- Basierend auf deinen Erfahrungen mit dem Training von Modellen: Wie könnte man diese Probleme lösen?
- Welche Regeln sollten für einen fairen Einsatz von KI-Systemen gelten?

Mögliche Antworten zur Diskussionsaufgabe

Welches Problem wird in den jeweiligen Szenarien beschrieben?

In manchen Situationen weichen die Vorhersagen von KI-Verfahren von der Erwartung ab bzw. benachteiligen Individuen oder bestimmte Personengruppen.

- **Szenario 1** beschreibt dieses Phänomen bei der Bewerberauswahl. Frauen erhalten deutlich seltener ein Jobangebot der angesprochenen Firma als Männer.
- **Szenario 2** beschreibt, dass kommerzielle Gesichtserkennungssysteme zwar bei weißen Personen sehr gut funktionieren, gerade schwarze Frauen jedoch nur schlecht erkannt werden.
- **Szenario 3** beschreibt den Fall, dass die Abschlussnoten der Schülerinnen und Schüler, die über Studienplätze und Ausbildungschancen entscheiden, deutlich von den Bewertungen durch die Lehrkräfte abweichen und dabei eigentlich nicht relevante Merkmale wie der Schulbezirk eine Rolle spielen.

Welche Ursache(n) könnten die problematischen Entscheidungen der KI-Systeme in den beschriebenen Szenarien haben? / Erläutere unter Einbeziehung der verwendeten Daten, warum es zu diesen Problemen kommen konnte.

Ursache für diese Entscheidungen sind oftmals Datensätze, die gewisse Verzerrungen (Bias) aufweisen.

- **Szenario 1:** So wurden für das Bewerberscreening vor allem die historischen Daten von Bewerberinnen und Bewerbern herangezogen. Wurden in der Vergangenheit aber vor allem männliche Bewerber eingestellt, wird diese Entscheidung durch das Modell verfestigt, da es gelernt hat, dass Bewerbungen von Frauen schlechter seien (Historischer Bias).
- **Szenario 2:** Die Bilddatenbanken, die für das Training der Gesichtserkennungssoftware verwendet wurden, weisen vermutlich einen deutlich höheren Anteil an Bildern von weißen Männern als von schwarzen Frauen auf. Die Ursache ist in diesem Fall also in der Auswahl der Daten zu suchen, die von der realen Verteilung der Nutzer abweicht (Selection Bias).
- **Szenario 3:** Im dritten Fall wurden Merkmale berücksichtigt und ein Zusammenhang zwischen dem Schulbezirk und der Abschlussnote hergestellt. Auch wenn ein solcher Zusammenhang prinzipiell bestehen kann (Korrelation), resultiert aus der Zugehörigkeit zu einem Schulbezirk noch lange nicht die Schulnote (keine Kausalität). Der Unterschied zwischen Korrelation und Kausalität wird auch im folgenden Cartoon verdeutlicht.



Korrelation vs. Kausalität (CC-BY-SA Haubert, Seegerer, Albrecht)

Die Verwendung verzerrter Daten (Daten, die die Realität nur bedingt widerspiegeln), kann dabei sowohl absichtlich als auch unabsichtlich bzw. unbewusst erfolgen.

Basierend auf deinen Erfahrungen mit dem Training von Modellen: Wie könnte man diese Probleme lösen?

Es gibt verschiedene Möglichkeiten, diese Probleme zu adressieren oder gar zu lösen. Ein Hauptaugenmerk sollte auf einer geeigneten Auswahl der Trainings- aber auch der Testdaten liegen. Je besser Trainingsdaten die Realität wiedergeben, desto zuverlässiger sollte das Modell in der Praxis funktionieren. Weiterhin denkbar wäre, das System in weiteren möglichst vielfältigen Situationen und mit unterschiedlichen Daten zu testen. Außerdem sollte den Ergebnissen des Modells nicht blind getraut, sondern die Ergebnisse kritisch hinterfragt werden.

Konkret für die verschiedenen Szenarien wäre Folgendes denkbar:

- **Szenario 1:** Weglassen persönlicher Informationen, die nicht für die Einstellung relevant sind (wie Alter, Foto oder Geschlecht). Alternativ können Manche Merkmale der eingestellten Personen austauschen/variieren (bspw. Hobbies zufällig ersetzen, um so für ein "Rauschen" zu sorgen); nicht ausschließlich auf die Entscheidung des Modells verlassen, sondern manuell prüfen.
- **Szenario 2:** Mehr Trainingsdaten von schwarzen Frauen verwenden; Abgleich der Personengruppe der Nutzerinnen und Nutzer mit der Personengruppe, die auf den Trainingsbildern abgebildet ist.
- **Szenario 3:** Lehrkräfte in die Entscheidung einbinden; nicht persönliche Merkmale wie den Schulbezirk entfernen und nur persönliche Merkmale berücksichtigen.

Wichtig: Die konkreten Ideen stellen nur eine Auswahl der vorhandenen Möglichkeiten dar! Die Schülerinnen und Schüler können noch viele weitere sinnvolle Ideen entwickeln.

Welche Regeln sollten für einen fairen Einsatz von KI-Systemen gelten?

Hier sind eine Vielzahl an Möglichkeiten denkbar. So könnte man Regeln vorschlagen, die Ergebnisse nicht automatisch zu akzeptieren, sondern stets einen menschlichen Entscheider zurate zu ziehen, wenn das System für Entscheidungen mit großer Tragweite herangezogen wird. Außerdem könnte man Regeln zu den verwendeten Datensätzen vorschlagen, sodass ein ausgeglichener Datensatz Voraussetzung für das Modell würde.