

# Künstliche Intelligenz und Maschinelles Lernen

## Artificial intelligence and machine learning

### Autor

Peter Hahn

### Institute

Vulpiusklinik  
Abteilung für Handchirurgie

### Schlüsselwörter

Maschinelles Lernen, Künstliche Intelligenz, Datenanalyse

### Key words

Machine learning, artificial intelligence, data science

eingereicht 18.10.2018

akzeptiert 15.12.2018

### Bibliografie

DOI <https://doi.org/10.1055/a-0826-4789>

Handchir Mikrochir Plast Chir 2019; 51: 62–67

© Georg Thieme Verlag KG Stuttgart · New York

ISSN 0722-1819

### Korrespondenzadresse

Prof. Peter Hahn

Vulpiusklinik

Abteilung für Handchirurgie

Vulpiusstraße 29

74906 Bad Rappenau

Tel.: +49(0)7264-60133

Fax: +49(0)7264-60257

E-Mail: [peter.hahn@vulpiusklinik.de](mailto:peter.hahn@vulpiusklinik.de)

### ZUSAMMENFASSUNG

Maschinelles Lernen (ML), ein Teilbereich der Künstlichen Intelligenz, ist die Fähigkeit von Computer-Algorithmen, Wissen aus Beispielen zu lernen, ohne dafür explizit programmiert zu sein und dieses Wissen dann auf unbekannte Fälle anzuwenden. Die Anwendung von ML in der Medizin wird in den nächsten Jahren exponentiell zunehmen. Ärzte sollten daher über die prinzipiellen Arten von ML sowie den Prozess des ML grundlegende Kenntnisse haben. Denn nur so ist es möglich, ML optimal zu nutzen und die Grenzen und Probleme des Verfahrens zu erkennen.

### ABSTRACT

Machine learning (ML) is the ability of computers to learn from data without being programmed explicitly for that purpose, and to apply the acquired knowledge to unknown cases. The application of ML in medicine will increase exponentially in the years to come. Doctors should have some basic knowledge of ML. Only then will they be able to use ML optimally and to recognise the limits and difficulties of ML.

## Einleitung


Maschinelles Lernen (Machine learning, ML) ist die Fähigkeit von Computer-Algorithmen, Wissen aus Beispielen zu erlernen und dieses Wissen dann auf andere, unbekannte Fälle anzuwenden. Das Programm sucht hierbei nach immanenten Mustern, die in großen Datenmengen vorhanden sein können. Maschinelles Lernen gehört zum Gebiet der Künstlichen Intelligenz (KI), einem Teilgebiet der Informatik. Beide Begriffe erscheinen häufig auch im Zusammenhang mit den Begriffen „Data Science“ oder „Big Data“. Eine klare Abgrenzung ist jedoch nicht möglich.

Erste Ansätze der KI gab es bereits in den sechziger und siebziger Jahren des letzten Jahrhunderts. Die Künstliche Intelligenz (KI) wurde durch das „Dartmouth Summer Research Project on Artificial Intelligence“ akademisch [1]. Die erste Welle der KI brachte jedoch nicht die erhofften Erfolge, so dass die Euphorie schnell wieder verflog. Bedingt durch die stete Zunahme an verfügbaren

Daten einerseits und die exponentiell verbesserte Rechenkapazität moderner Computer, die die notwendigen komplexen Rechenoperationen erst möglich machen, hat die Anwendung von ML in den letzten Jahren einen erneuten Aufschwung erfahren.

So ergibt eine Suche bei Pubmed zum Begriff „machine learning“ für die letzten 5 Jahre fast 30 000 Textstellen.

ML wird die Medizin in den nächsten 10 Jahren grundlegend verändern [2]. Wir Ärzte werden zunehmend bei der Diagnosestellung und Therapiewahl von ML unterstützt werden, wenn auch nicht ersetzt. Die großen digitalen Konzerne wie Apple, Google, Microsoft und andere arbeiten daran, das Thema Gesundheit in den nächsten Jahren mitzubestimmen. Verständlich, da dies weltweit der größte Wachstumsmarkt ist. Die vielen Daten, die sie von den Nutzern erhalten, werden mittels ML bearbeitet und für individuelle oder globale Prognosen benutzt.



► **Abb. 1** Unüberwachtes Lernen (K-mean). In der Abbildung links oben sind die Ausgangsdaten. Diese sind primär unstrukturiert. Man kann die Daten dann durch den Lernprozess in verschiedene Cluster (farbig gekennzeichnet) unterteilen lassen. Die beste Genauigkeit der Zuordnung ergibt sich für 3 Cluster (zweite Reihe links).

Es ist daher wichtig, dass Ärzte die grundlegenden Prinzipien des ML kennen und auch über Probleme und Grenzen dieser Methode informiert sind.

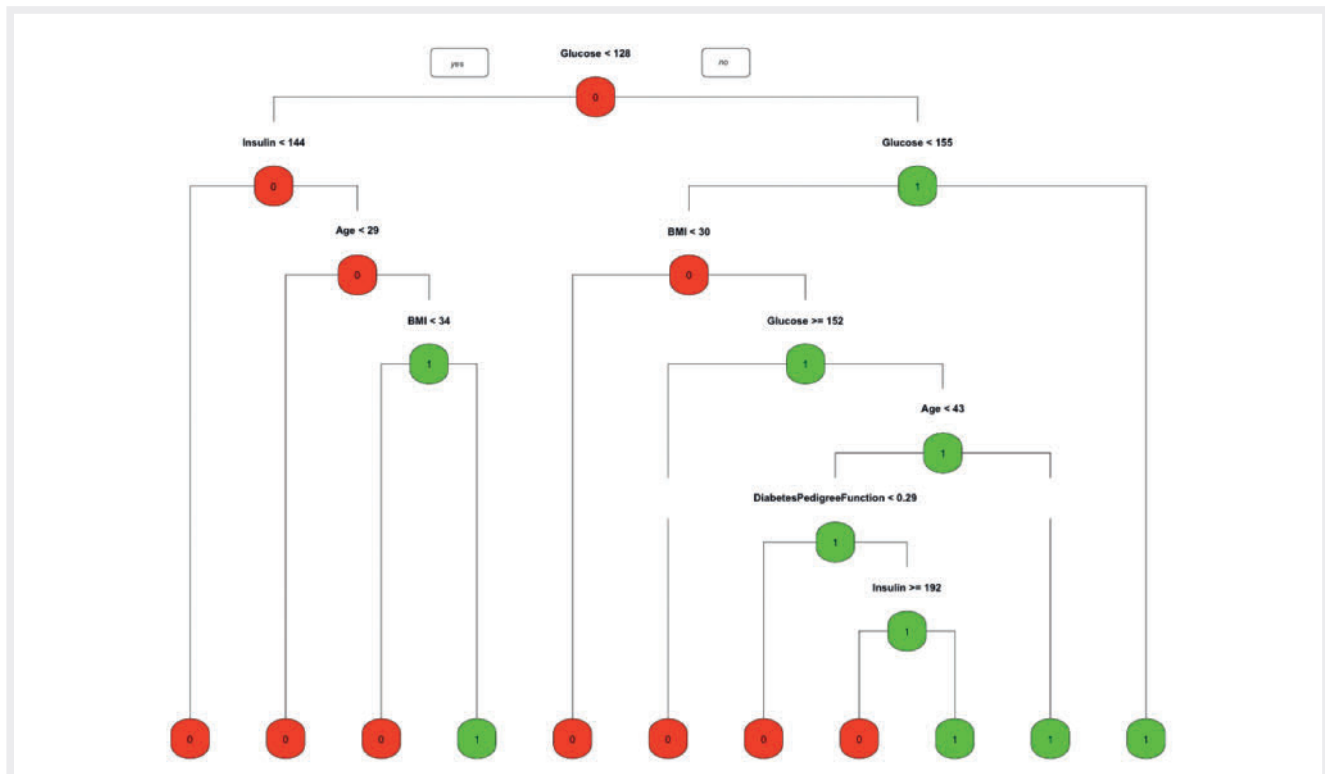
## Was ist maschinelles Lernen?

Maschinelles Lernen ist keine einheitliche Methode oder ein spezielles Computerprogramm, sondern eine Vielzahl verschiedener Algorithmen, die dem Ziel dienen, aus vorhandenen Daten zu lernen und das erlernte Wissen auf neue Fälle anzuwenden. Im Gegensatz zu klassischen Computerprogrammen, die eine feste Abfolge von Befehlen ausführen, um eine definierte Aufgabe zu erledigen, sind die Ergebnisse der ML-Algorithmen abhängig von den vorhandenen Daten. Das Vorgehen des ML ist vergleichbar mit einem jungen Arzt, der seine Kenntnisse im Laufe der Zeit aus einer Vielzahl von Fällen gewinnt. Während der junge Arzt hierfür Monate oder Jahre benötigt, kann der Computer Millionen von Fällen in Minuten „durchsehen“, analysieren und daraus lernen. Aufgrund der riesigen Anzahl analysierter Fälle kann ML Zusammenhänge in den Daten erkennen, die dem Menschen verborgen bleiben. Hinzu kommt, dass wir Menschen nicht mehr als drei Dimensionen wahrnehmen können, während Computer auch mit mehreren tausend Dimensionen arbeiten können. Außerdem haben wir im Gegensatz zum Computer Schwierigkeiten, nicht lineare Zusammenhänge zu erkennen. Da aber die meisten biologischen Phänomene nicht linear sind, fällt uns eine Zuordnung insbesondere bei Vorhandensein mehrere Faktoren schwer oder ist gar unmöglich.

Auch wenn es keine einheitlichen ML-Algorithmen gibt, so können doch mehrere prinzipielle Arten von Lernprozessen unterschieden werden.

## Überwachtes Lernen (supervised learning)

Hierbei werden dem Algorithmus während des Lernvorgangs die zu lernenden Klassen (diskret) oder Werte (kontinuierlich) mit den Daten präsentiert. Das Programm kann also jedem Datensatz einen Ergebniswert zuordnen. Die einfachste Form ist das Erlernen von zwei Klassen (gesund oder krank, hell oder dunkel, Auto oder Fahrrad usw.), aber auch Mehrklassenmodelle (gesund, verdächtig, krank; Auto, Fahrrad, Motorrad, Fußgänger) sind denkbar. Während des Lernvorgangs lernt der Computer die Charakteristika der Klassen und kann das „Wissen“ dann auf neue Fälle anwenden. Beispiele aus der Medizin sind die Erkennung der diabetischen Retinopathie auf Bildern vom Augenhintergrund [3] oder die Vorhersage der Sterblichkeit bei Koronarstenose [4]. Überwachtes Lernen wird häufig zur Vorhersage von Verläufen eingesetzt. Es soll die Frage beantwortet werden, ob eine spezielle Befundkonstellation zu einem Ereignis (Krankheit, Tod etc.) in der Zukunft führt. Statt Klassen (gesund, krank) können aber auch kontinuierliche numerische Werte als Lern- und Vorhersagewert dienen. Beispiel ist die Vorhersage der Luftverschmutzung in bestimmten Gebieten als Prädiktor für Atemwegserkrankungen.



► **Abb. 2** Entscheidungsbaum für den Lernprozess des Pima Indians Diabetes Dataset. Mit einfachen Ja/Nein-Entscheidungen wird eine Genauigkeit von ca. 80 % erreicht.

## Unüberwachtes Lernen (unsupervised learning)

Beim unüberwachten Lernen gibt es keine Klassen oder Zahlen, die vorhergesagt werden müssen. Hier ist es Aufgabe des Programms, Muster innerhalb der Daten selbstständig zu erkennen (► **Abb. 1**). Die identifizierten Muster (Cluster) werden dann häufig in einem zweiten Schritt als Klassen für überwachtes Lernen verwendet. Anwendungsgebiete sind häufig die Suche nach unbekanntem Zusammenhängen. So kann z. B. die Suche nach Mustern in der Immunpathologie oder Genetik zu Erkenntnissen zu unbekanntem Zusammenhängen und neuen Forschungsansätzen führen [5].

## Andere Verfahren

Neben den beiden oben genannten Ansätzen, gibt es weitere Verfahren, die letztlich Modifikationen der beiden Verfahren sind, wie z. B. teilüberwachtes Lernen und bestärkendes Lernen. Speziell für Daten, bei denen eine der Klassen in sehr geringer Anzahl vorkommt, braucht man spezielle Verfahren, um diese Ausnahmen zu erkennen (anomaly detection). Diese Methode wird u. a. in der Genanalyse benutzt.

## Vorbereitung und Durchführung

Beim überwachten Lernen wird aus den vorhandenen Daten (Merkmalen, features, predictors) auf das vorherzusagende Ereignis (target, outcome) geschlossen. ► **Abb. 2** zeigt den Entscheidungsbaum nach ML anhand des „PIMA Indians Diabetes Dataset“ [6]. Das Programm gestattet anhand von wenigen Daten und Parametern (Blutzuckerwert unter/über 128 mg/ml bzw. unter/über 155 mg/ml; Alter unter/über 29 Jahre bzw. unter/über 43 Jahre; Body Mass

Index (BMI) unter/über 30 bzw. unter/über 34; etc.), die schlicht mit „ja“ oder „nein“ zu beantworten sind, vorherzusagen, ob ein Diabetes mellitus vorhanden ist oder nicht (ja = 1, nein = 0) (► **Abb. 2**).

Nach der Datenerfassung liegen die Daten in der Regel nicht in einer Form vor, in der sie direkt vom ML verarbeitet werden können. Deswegen sind verschiedene Schritte der Vorverarbeitung nötig. Deren Aufwand übersteigt in der Regel den Aufwand des eigentlichen Lernprozesses.

Die meisten ML-Algorithmen können nur mit Zahlen arbeiten, so dass sowohl Text als auch kategorische Variablen wie z. B. Geschlecht, Familienstand u. a. in Zahlen umgewandelt werden müssen. Das Geschlecht wird dann mit 0 = männlich, 1 = weiblich und 2 = unbekannt kodiert. Texte werden analysiert und die im Text vorkommenden Worte nach Häufigkeit in einem Wörterbuch sortiert. Die Nummern der Einträge im Wörterbuch werden dann zur weiteren Analyse verwendet.

Welche Merkmale das Ergebnis mitbestimmen oder es evtl. sogar verfälschen, ist primär nicht bekannt. Daher stellt die Analyse und Bearbeitung der Merkmale (feature-engineering) einen wesentlichen Teil der Vorbereitung dar. Häufig müssen durch Modifikation oder Hinzufügen neue Merkmale geschaffen werden, die das Ergebnis verbessern. Die Einteilung des Patientenalters in Klassen (20–29, 30–39 etc.) kann z. B. als neues Merkmal die Präzision des ML erhöhen.

Weitere wichtige Methoden sind die Suche nach fehlenden Werten und nach Fehleingaben, das Zusammenfassen von Werten durch Addition sowie Varianzanalysen zum Angleich der statistischen Verteilung durch verschiedene mathematische Verfahren. Die Kunst einer guten Analyse, die eine hohe Genauigkeit erreicht,

liegt häufig in diesen Schritten. Andererseits besteht hier auch ein gewisses Gefahrenmoment. Die Veränderungen an den Originaldaten erhöhen die Genauigkeit der Analyse, erschweren aber eine Interpretation der Ergebnisse. Im Beispiel müssen alle Patienten mit unrealistischen Werten entfernt werden, z. B. Patienten mit einem Blutzuckerwert oder einem BMI von 0. Die Entfernung der unrealistischen Werte erhöht die Genauigkeit von 85 % auf 87 %. Nach der Vorverarbeitung folgt der eigentliche Lernprozess.

## Algorithmen

Es gibt inzwischen mehr als hundert ML-Algorithmen. Eine prinzipielle Betrachtung einiger häufiger Algorithmen reicht jedoch aus, um die grundlegenden Stärken und Schwächen des ML zu verstehen.

Alle Verfahren arbeiten im Prinzip so, dass ein Modell aus den Gesamtdaten errechnet wird. Mit dem Modell werden dann Vorhersagen für die einzelnen Datensätze gemacht und mit dem bekannten Ergebnis abgeglichen. Danach nimmt man einzelne Datensätze und wendet das erstellte Modell darauf an. Die so erhaltenen Vorhersagen vergleicht man mit dem bekannten Ergebnis aus den Gesamtdaten. Dann werden die Parameter des Modells, nicht die Daten, modifiziert und das Modell erneut berechnet. Dieser Prozess wird so lange wiederholt, bis die Differenz zwischen der Modell-Vorhersage für einzelne Datensätze und dem bekannten Ergebnis aus den Gesamtdaten möglichst gering ist. Für das Beispiel des PIMA Indians Diabetes Dataset bedeutet dies, dass man die Grenzwerte für den Blutzuckerwert, das Alter, den BMI etc. solange hin- und herschiebt, bis in 85 % und mehr bei Anwendung des errechneten Modells auf einzelne Datensätze die Vorhersage (Diabetes mellitus vorhanden oder nicht) mit dem bekannten Ergebnis des Einzelfalls übereinstimmt.

## Regression

Die Regression ist die einfachste Form der ML-Algorithmen für die Vorhersage kontinuierlicher Daten. Einfache oder multivariate Regression wird derzeit in vielen wissenschaftlichen Arbeiten für die Analyse von Auswirkungen verschiedener Variablen auf ein Ergebnis benutzt [7]. In den meisten Fällen handelt es sich jedoch um eine explorative Analyse der Daten und nicht um die Vorhersage unbekannter Ereignisse. Für letzteren Anwendungsbereich besteht ein wesentliches Problem in der Tatsache, dass eine Extrapolation über den Datenbereich des Trainings hinaus mit großen Fehlern behaftet sein kann. Dies bedeutet, dass z. B. bei der Regression über das Alter mit Trainingsdaten, die zwischen 20 und 65 Jahren liegen, eine Vorhersage für Patienten darunter oder darüber nicht valide ist.

Für die Klassifikation gibt es die logistische Regression. Diese ist sehr stabil, benötigt aber für exakte Vorhersagen sehr große Datenmengen [8].

## Support-vector machines

Diese häufig benutzten Algorithmen sind sehr stabil und geeignet für verschiedene Anwendungen. Das Prinzip besteht darin, dass der Algorithmus versucht, eine Trennebene zwischen die Daten der einzelnen Klassen so zu legen, dass diese möglichst gut voneinander abgegrenzt sind. Daten mit zwei Merkmalen werden durch Linien getrennt (► **Abb. 3**), Daten mit drei Merkmalen durch Ebenen im Raum, höher-dimensionale Daten durch sogenannte Hyperplanes.

Das sind n-1-dimensionale Ebenen im n-dimensionalen Raum. Die Optimierung der Steuerung der Myoelektrik der oberen Extremität kann z. B. mit dieser Methode erreicht werden [9].

## Baum-orientierte Verfahren

In den letzten Jahren haben sich diese Verfahren in diversen Modifikationen (z. B. XGBoost) als sehr verlässlich herausgestellt. Diese Algorithmen ordnen die Merkmale in Entscheidungsbäumen an. ► **Abb. 2** zeigt einen möglichen Entscheidungsbaum für das Beispiel der Diabetes Daten.

Einfache baum-orientierte Verfahren wie in der Abbildung erlauben eine gute Interpretation der Entscheidungsbäume. Komplexere Verfahren, bei denen die Bäume einer Bewertung und Umverteilung unterzogen werden (XGBoost), sind kaum interpretierbar.

## Neuronale Netze und Deep Learning

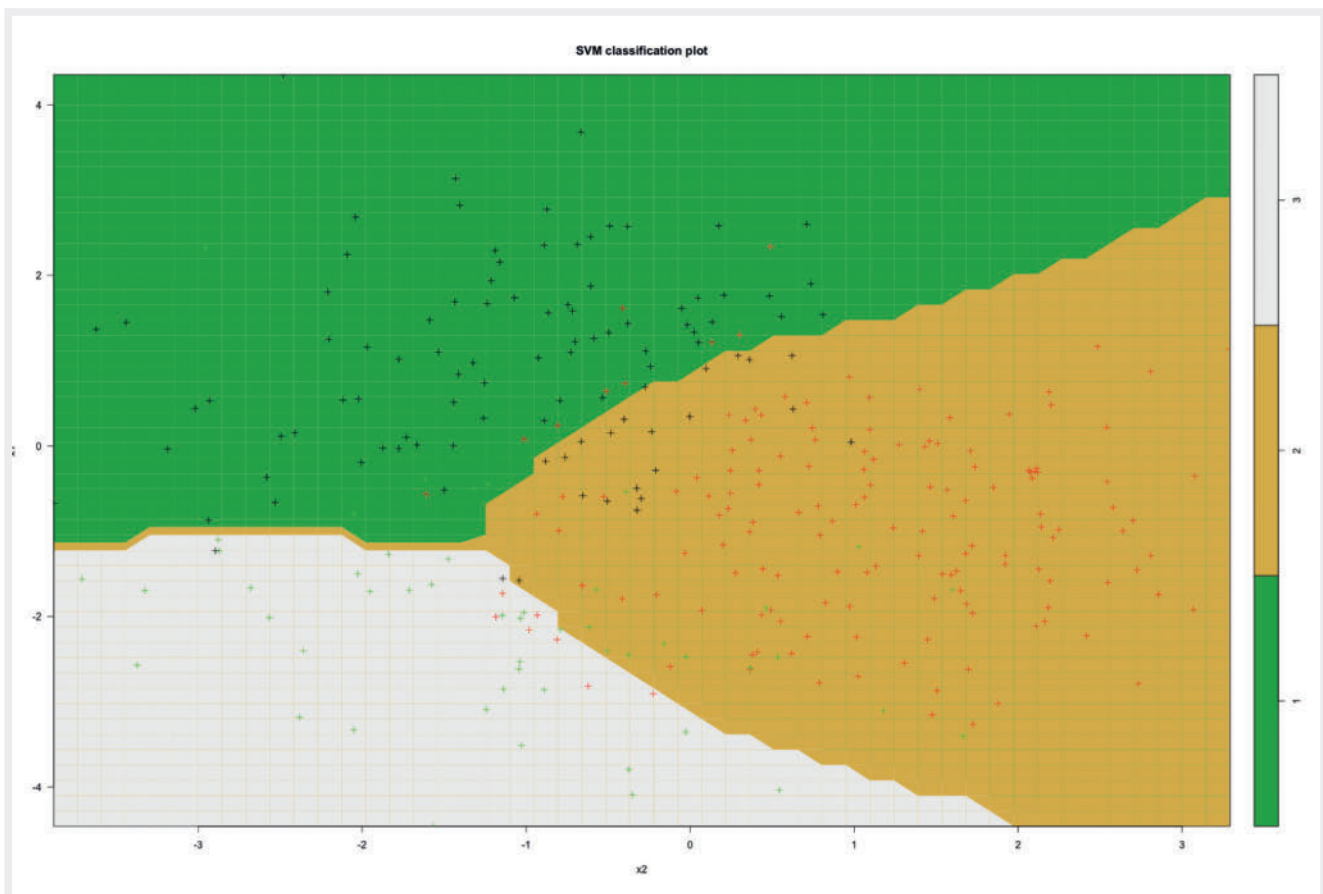
Neuronale Netze versuchen die Struktur des menschlichen Gehirns nachzubilden. Sie arbeiten mit mindestens einer Schicht Eingabe-Neuronen, einer verdeckten Schicht und einer Schicht Ausgabe-Neuronen. In komplexen Fällen können auch mehrere verdeckte Schichten notwendig sein. Neuronale Netze sind sehr rechenintensiv. Durch die Steigerung der Rechenleistung moderner Computer haben sie in den letzten Jahren, speziell für die Bilderkennung, wieder an Bedeutung gewonnen. Weiterentwicklungen wie das sogenannte „deep learning“ sind neuronale Netze mit sehr vielen Zwischenschichten. AlphaGO, das Programm, das den weltbesten Go-Spieler mehrfach geschlagen hat, arbeitet mit deep learning. Auch die Ergebnisse der neuronalen Netze sind nicht interpretierbar.

## K-means Cluster (unüberwachtes Lernen)

Dieses unüberwachte Verfahren versucht innerhalb der Daten Cluster zusammenhängender Daten zu finden. Diese Daten sollten um den Mittelpunkt des entsprechenden Clusters liegen und die Summe der Abstände zum Mittelpunkt sollte minimal sein (► **Abb. 1**). Die so erlernten Cluster können dann z. B. als Klassen für überwachtes Lernen verwendet werden.

## Stärken und Schwächen

Auf die mangelnde Interpretation der Modelle bei den einzelnen ML-Algorithmen wurde bereits hingewiesen. Einige weitere Punkte sind aber für den „Nutzer“ von ML noch von Interesse. Viele Programme geben als Ergebnis der Klassifikation keine Ja/Nein-Ergebnisse aus, sondern ermitteln die Wahrscheinlichkeit für positiv = 1 oder negativ = 0 als dezimalen Wert. Mittels eines Wertes (threshold) wird dann festgelegt, ab welcher Grenze das Ergebnis positiv sein soll. Dieser Grenzwert muss nicht zwangsläufig bei 0,5 liegen. Einerseits muss man sich dessen bewusst sein und die „Entscheidung“ des Algorithmus nicht als absoluten Wert wahrnehmen. Andererseits hat dies den Vorteil, dass bei einer Verschiebung des Grenzwerts z. B. unter 0,5 mehr Fälle als positiv eingestuft werden, die Anzahl der negativen Fälle aber abnimmt. Dies hat den Vorteil, dass über den Grenzwert gesteuert werden kann, ob man eine höhere Sensitivität (mehr Kranke werden erkannt) oder eine höhere Spezifität (Gesunde werden als Gesunde identifiziert) haben will. Diese Entscheidung kann je nach Anwendungsfall unterschiedlich ausfallen.



► **Abb. 3** Lernprozess für einen Datensatz mit 3 Klassen. Die vom Programm errechneten Areale für die Klassen entsprechen den Hintergrundfarben, die Kreuze den Fällen der entsprechenden Klassen. Klasse1: grüner Hintergrund, schwarze Kreuze. Klasse2: gelber Hintergrund, rote Kreuze. Klasse 3: weißer Hintergrund, grüne Kreuze. Die meisten Fälle werden korrekt zugeordnet, einzelne Fälle liegen jedoch im falschen Areal und sind damit nicht korrekt klassifiziert.

Ein bekanntes Problem des ML ist das sogenannte „overfitting“. Dieses bedeutet, dass sich das Programm so lange optimiert, bis es die Trainingsdaten zu 100 % zuordnen kann. Dies führt dann aber dazu, dass neue Daten nicht korrekt klassifiziert werden, da das Programm zwar die Trainingsdaten perfekt gelernt hat, aber nicht über die zu betrachtende Population generalisieren kann. Dieses Problem sollte durch geeignete Maßnahmen beim Training vermieden werden. Dazu wird der Lernprozess nicht direkt mit den Trainingsdaten validiert, sondern mit einem speziellen Datensatz, der nicht für das Training verwendet wurde. Der Nutzer sollte dieses Problem dennoch kennen, da eine vermeintliche hohe Genauigkeit zu schlechten Ergebnissen in der Realität führen kann.

Ein prinzipieller Fehler der statistischen Betrachtungsweise gilt auch für das ML. Korrelation ist nicht Ursächlichkeit. Speziell beim ML finden die Programme viele Zusammenhänge zwischen Merkmalen und dem Ergebnis. Die meisten Algorithmen können den Einfluss der einzelnen Merkmale auf das Ergebnis prozentual darstellen. Dies darf aber nicht zur Annahme führen, dass dieses Merkmal ursächlich für das Ergebnis ist.

Letztendlich ist die Genauigkeit der erlernten Prognosen immer von der Qualität der ursprünglichen Daten abhängig. Wenn diese Daten schlecht sind, wird ML sie nicht verbessern. Mit guten Daten

in ausreichender Menge lassen sich aber gute Vorhersagen entwickeln.

Qualitativ ausreichende Daten in digitaler Form liegen derzeit bereits überall dort vor, wo viel digitalisiert wird, z. B. in der Radiologie, in der Pathologie und in der Genetik. Aber auch die Intensivmedizin mit einer hohen Anzahl an digitalen Parametern bietet sich für ML an.

### ML in Hand- und plastischer Chirurgie

Wenn eine breitere Öffentlichkeit über die Möglichkeiten und Grenzen des ML informiert ist, wird dies verschiedene Effekte haben. Mit dem zunehmenden Bewusstsein wird es auch einen Anstieg an sinnvollen Anwendungen geben. Nicht nur in Deutschland gibt es eine Vielzahl von Datenbanken mit interessanten Daten, z. B. das TraumaRegister der DGU, das Endoprothesenregister (ERPD), das Herzschrittmacher-Register u. a. Die dort vorhandenen Daten können als Grundlage für die Analyse mit ML dienen, wenn Fragestellungen nicht mit „klassischen“ statistischen Methoden bearbeitet werden können.

ML wird zunächst die mit der Handchirurgie und Plastischen Chirurgie assoziierten Disziplinen betreffen, hier speziell alle Disziplinen, die mit Bildern arbeiten; Radiologie und Pathologie. Deep

learning erreicht eine Genauigkeit von 83 % bei der Frakturanalyse auf Röntgenbildern von Hand, Hand- und Sprunggelenk [10].

Aber auch andere Anwendungen sind möglich, wie die automatisierte Überwachung der Lappenperfusion [11] oder die Vorhersage der Heilungsdauer bei Verbrennungen [12]. Die Steuerung von myoelektrischen Prothesen wird zunehmend durch ML verfeinert [9]. Mittels ML lassen sich aus der Druckverteilung der Hand mit Druckmessplatten [13] mehr Rückschlüsse ziehen als mit konventionellen Methoden [14]. Die automatische Texterkennung und Analyse NLP (natural language processing) wird wesentliche Anwendungen in der Zukunft ermöglichen. So kann z. B. die automatisierte Fallkodierung [15] die tägliche Arbeit erleichtern und präzisieren.

Die zunehmende Kenntnis des ML wird die häufig noch vorhandene Angst vor dieser Methode reduzieren und gleichzeitig eine kritische Betrachtung der Ergebnisse im Kontext des Arztberufes und der modernen Medizin ermöglichen. Bei der Analyse des Nutzens des ML muss man sich immer die Frage stellen, welchen Gewinn der Einsatz von ML im speziellen Umfeld bringt. So erlaubt die automatische Klassifikation von Bildern des Cervix uteri in medizinisch schlecht versorgten Gebieten eine Verbesserung der medizinischen Versorgung, die mit normalen Mitteln nicht zu erreichen wäre [16]. Die oben erwähnte Genauigkeit von 83 % in der Frakturanalyse [10] kann in nicht spezialisierten Zentren schon deutlich über der Genauigkeit der örtlichen Kollegen liegen.

### Eigene Kenntnisse sammeln

Es ist im Rahmen dieser Arbeit nur möglich, einige grundlegende Prinzipien des ML zu beleuchten. Wer daran interessiert ist, sich weiter mit dem Thema zu beschäftigen und ggfs. auch selber in die Programmierung einzusteigen, dem seien die sehr guten Online-Kursangebote auf den verschiedenen Plattformen wie Coursera, Khan Academy, EdX oder das reichhaltige Kursangebot der Online-Plattformen speziell der amerikanischen Universitäten (MIT, Harvard, Stanford) empfohlen. Einen guten Einstieg für Anfänger ohne mathematische Vorkenntnisse bietet der Kurs „Chromebook Data Science“ [17].

### Interessenkonflikt

Der Autor gibt an, dass kein Interessenkonflikt besteht.

### Literatur

- [1] McCarthy J, Minsky ML, Rochester N et al. A proposal for the Dartmouth summer research project on artificial intelligence. *AI Mag [Internet]* 2006; 27: 12–14. Available from: <http://www.aaai.org/ojs/index.php/aimagazine/article/view/1904%5Cnhttp://www.mendeley.com/catalog/proposal-dartmouth-summer-research-project-artificial-intelligence-august-31-1955/%5Cnhttp://www-formal.stanford.edu/jmc/history/dartmouth/dartmouth.html>
- [2] Darcy AM, Louie AK, Roberts LW. Machine learning and the profession of medicine. *JAMA* 2016; 315: 551–552

- [3] Gulshan V, Peng L, Coram M et al. Development and Validation of a Deep Learning Algorithm for Detection of Diabetic Retinopathy in Retinal Fundus Photographs. *JAMA* 2016; 304: 649–656
- [4] Motwani M, Dey D, Berman DS et al. Machine learning for prediction of all-cause mortality in patients with suspected coronary artery disease : a 5-year multicentre prospective registry analysis. *Eur Heart J* 2017; 38: 500–507
- [5] Lötsch J, Thrun M, Lerch F et al. Machine-Learned Data Structures of Lipid Marker Serum Concentrations in Multiple Sclerosis Patients Differ from Those in Healthy Subjects. *Int J Mol Sci* 2017; 18: 1217
- [6] <https://www.kaggle.com/uciml/pima-indians-diabetes-database>
- [7] Osinga R, Baust D, Bodmer ES et al. Subjektive und objektive Langzeitanalyse nach Mammareduktionsplastik in 159 Fällen: Patientinnen urteilen anders als Plastische Chirurgen. *Handchir Mikrochir Plast Chir* 2017; 49: 399–404
- [8] Zimmermann RM, Parayvi E, Zimmermann NB, et al. Complications after hand surgery in patients with a raised International Normalized Ratio. *J Hand Surg* 2017; 42: 742–746
- [9] Oskoei MA, Hu H. Support Vector Machine-Based Classification Scheme for Myoelectric Control Applied to Upper Limb. *IEEE Transactions on Biomedical Eng* 2005; 55: 1956–1965
- [10] Olczak J, Fahlberg N, Maki A et al. Artificial intelligence for analyzing orthopedic trauma radiographs, *Acta Orthopaedica* 2017; 88: 581–586
- [11] Kiranantawat K, Sitpahul N, Taeprasartsit P et al. The first Smartphone application for microsurgery monitoring: SilpaRamanitor. *Plast Reconstr Surg* 2014; 134: 130–139
- [12] Yeong EK, Hsiao TC, Chiang HK et al. Prediction of burn healing time using artificial neural networks and reflectance spectrometer. *Burns* 2005; 31: 415–420
- [13] Hahn P, Cenik E, Prommersberger KJ et al. Machine learning as a tool for predicting insincere effort in power grips. *bioRxiv* 2016 doi: <http://dx.doi.org/10.1101/068494>
- [14] Mühlendorfer-Fodor M, Reger A, Pillukat T et al. Auswirkungen der Versteifung des Zeigefinger- bzw. Mittelfingerendgelenkes auf Hand- und Fingerkraft sowie auf die Druckverteilung. *Handchir Mikrochir Plast Chir* 2018; 50: 174–183
- [15] <http://www.minds-medical.de>
- [16] William W, Basaza-Ejiri AH, Obungoloch J et al. A Review of Applications of Image Analysis and Machine Learning Techniques in Automated Diagnosis and Classification of Cervical Cancer from Pap-smear Images. *IST-Africa Week Conference (IST-Africa)*, Gaborone, 2018, 11
- [17] <https://leanpub.com/universities/set/jhu/chromebook-data-science>