

Ophthalmologie 2021 · 118:697–706
<https://doi.org/10.1007/s00347-020-01231-1>
 Eingegangen: 20. April 2020
 Überarbeitet: 23. August 2020
 Angenommen: 24. August 2020
 Online publiziert: 24. September 2020
 © Der/die Autor(en) 2020



Achim Langenbacher¹ · Larissa Häfner² · Timo Eppig¹ · Berthold Seitz² ·
 Nóra Szentmáry³ · Elias Flockerzi²

¹ Institut für Experimentelle Ophthalmologie, Universität des Saarlandes, Homburg, Deutschland

² Klinik für Augenheilkunde, Universitätsklinikum des Saarlandes, Homburg, Deutschland

³ Dr. Rolf M. Schwiete Zentrum für Limbusstammzellforschung und kongenitale Aniridie, Universität des Saarlandes, Homburg, Deutschland

Keratokonusdetektion und Ableitung des Ausprägungsgrades aus den Parametern des Corvis[®]ST

Eine Studie, basierend auf Algorithmen des Maschinenlernens

Künstliche Intelligenz hat in den vergangenen Jahren in viele Disziplinen der Medizin, aber auch z. B. in Bereiche der Ingenieurwissenschaften, der Naturwissenschaften oder im Finanzbereich Einzug gehalten [1, 3, 9, 28, 34]. Immer wenn logische Zusammenhänge zwischen Einflussfaktoren und Wirkung nicht mehr klar erkennbar sind oder die Zusammenhänge zu komplex erscheinen, wird heute versucht, mit Verfahren der künstlichen Intelligenz Verbindungen herzustellen. Allen Ansätzen gemein ist, dass die Algorithmen einem Lernprozess unterzogen sind und, auf einer großen Zahl von Datensätzen basierend, Zusammenhänge zwischen Eingangsgrößen herstellen.

Maschinelles Lernen ist ein Unterbegriff der künstlichen Intelligenz und gliedert sich in 2 Bereiche: Beim überwachten Lernen wird Expertenwissen in Form einer manuellen Klassifikation (das sog. „Labeling“ von Datensätzen) hinterlegt. Derartige Algorithmen dienen z. B. dazu, Erkrankungen zu erkennen oder den Schweregrad einer Pathologie zu klassifizieren (klassifizierende Systeme des überwachten Lernens) [3, 11, 28, 36]. Wichtigste Vertreter sind hier Ansätze wie Decision Trees, Support Vector Machines (SVM), Discriminance Analysis, Naive

Bayes oder Nearest Neighbourhood [1, 3, 9].

Alternativ kann die Zielgröße des Algorithmus anstatt einer kategorialen Variablen auch eine metrische Variable sein (z. B. ein Keratokonusindex) [16, 19–21, 26, 27, 32, 37], man spricht dann von einem Regressionsalgorithmus des überwachten Lernens. Wichtigste Vertreter sind hier die Linear Regression (Generalized Linear Models [GLM]), Support Vector Regression (SVR), Ensemble Methods, Regression Trees oder Neural Networks. Neben den überwachten Ansätzen des Maschinenlernens gibt es die Option des nicht überwachten Lernens, bei dem kein Expertenwissen in Form eines „Labeling“ von Datensätzen eingebracht wird, sondern der Algorithmus selbstständig versucht, Muster und Strukturen zu erkennen und Datensätze zu gruppieren (sog. Clustern). Die wichtigsten Ansätze in diesem Zusammenhang sind kMeans oder kMedoids, Hierarchical, Gaussian Mixture, Neural Networks oder Hidden Markov Models.

Beim überwachten Lernen ist neben der großen Anzahl an Datensätzen für den Lernprozess von elementarer Bedeutung, dass die Klassifizierung durch einen Experten (das „Labeling“) sehr sorgfältig durchgeführt wird. Sind Datensätze

fehlerhaft klassifiziert, so wird der Algorithmus Zusammenhänge fehlerhaft ableiten, was am Ende zu falschen Ergebnissen führt. Weiter ist darauf zu achten, dass bei Klassifizierungsverfahren für den Lernprozess von allen Klassen genügend Datensätze zur Verfügung stehen. Die Datensätze werden zunächst z. B. durch Ziehen einer Stichprobe in einen Lerndatensatz und einen Validierungsdatsatz aufgeteilt. Der Lerndatensatz dient dazu, den Algorithmus zu trainieren, wohingegen der Validierungsdatsatz dazu dient, die Güte des Verfahrens im Sinne von (richtig positiven und richtig negativen) Entscheidungen zu prüfen. Nimmt man diese Aufteilung nicht vor und validiert mit dem Datensatz, mit dem das System vorab trainiert wurde, wird die Performance des Algorithmus in der Regel überschätzt. In den vergangenen Jahren haben sich neben dem einfachen „Holdout“ für die Kreuzvalidierung [9] zunehmend Verfahren wie die „K-Fold“-Kreuzvalidierung oder das „Repeated Random Subsampling“ etabliert. Bei der „K-Fold“-Kreuzvalidierung werden die Daten in K Partitionen aufgeteilt und in K Durchläufen jeweils an K-1 Partitionen trainiert und am beim Training ausgesparten Datensatz validiert. Beim „Repeated

Random Subsampling“ wird in mehreren Durchläufen jeweils eine zufällige Stichprobe als Validierungsdatensatz abgetrennt und am verbleibenden Datensatz trainiert, hier besteht allerdings die Gefahr, dass einzelne Daten bei der Stichprobenziehung in keinem der Durchläufe für das Training oder die Validierung herangezogen werden. Bei der „K-Fold“-Kreuzvalidierung wird am Ende jeder Datensatz K-1-mal für das Training und 1-mal für die Validierung herangezogen, trotz höheren Rechenaufwands reduzieren sich hier die Anforderungen an den Umfang des Datensatzes.

Geräteassistiertes Keratokonusscreening basiert heute in der Regel auf Messdaten der Hornhauttopographie, der Hornhauttomographie, der Aberrometrie oder sog. biomechanischen Kenngrößen. Die Hornhauttopographie mit Placidssystemen kann bereits auf eine 30-jährige Tradition zurückblicken, und in den 1990er-Jahren wurden bereits sehr einfach strukturierte Verfahren des Maschinenlernens wie neuronale Netze oder Entscheidungsbäume/Expertensysteme entwickelt (z. B. KPI, KCI, KISA, I-S bei den TMS-Systemen der Firma Tomey), die dem Anwender eine Empfehlung an die Hand geben, ob bei der individuell vorliegenden Messung von einem Keratokonusbefund (oder Keratokonusverdacht) auszugehen ist [4, 13, 37], mit welcher Wahrscheinlichkeit ein Keratokonus vorliegt [12] oder mit welchem Schweregrad die Pathologie vorliegt [6, 7, 19]. Im einfachsten Fall wurden direkt Messgrößen der Topografie abgefragt und über Grenzwerte eine Entscheidung getroffen (z. B. zentraler Brechwert CK >47,2 dpt → Keratokonus).

Für das Corvis®ST wird mit dem Corvis Biomechanical Index CBI eine Kenngröße angeboten [2, 33], die aufgrund der Architektur des Algorithmus eine quasi binäre Entscheidung trifft, ob ein Keratokonus vorliegt oder nicht [8, 15, 26, 30]. Ein Staging, das beispielsweise bei einer Verlaufskontrolle unabdingbar ist, leistet der CBI nicht. Der TKC-Wert der Pentacam beschränkt sich zwar auf die Analyse der Hornhautvorderfläche, er ist jedoch als Staging-Parameter sehr beliebt, da der Wert sehr stark an die klinische Klassifizierung nach dem Amsler-Krumeich-

Schema angelehnt ist, das seit vielen Jahren in der Keratokonusdiagnostik etabliert ist und bei vielen Verlaufsstudien zugrunde gelegt wurde.

In der vorliegenden Arbeit soll anhand von klinischen Daten, die mit dem Corvis®ST-System sowie der Pentacam HR erhoben wurden, skizziert werden, wie aus den DCR-Parametern [2, 33] des Corvis®ST, basierend auf Strategien des überwachten Lernens, ein klassifizierender Algorithmus definiert werden kann, mit dem eine binäre Entscheidung für das Vorliegen eines Keratokonus oder eine Klassifikation des Keratokonus möglich ist. Das „Labeling“ der Datensätze durch einen Experten soll dabei durch das Ergebnis des „Topographic Keratocornus Classification Index“ (TKC) der Pentacam ersetzt werden.

Patienten und Methoden

Bei 60 Augen von 60 Normalprobanden (30 linke und 30 rechte, mittleres Alter $31,9 \pm 12,0$ Jahre) ohne Anzeichen eines Keratokonus sowie 379 Augen von Patienten mit Keratokonus (179 linke und 200 rechte Augen, mittleres Alter $35,2 \pm 12,5$ Jahre) wurde mit der Pentacam HR (Fa. Oculus, Wetzlar, Deutschland) die Hornhauttomographie gemessen. Direkt im Anschluss wurde mit dem im Funktionsumfang erweiterten Luftdrucktonometer Corvis®ST (Fa. Oculus, Wetzlar, Deutschland) gemessen [10, 26, 29]. Die 60 Normalprobanden rekrutierten sich aus der Belegschaft der Klinik für Augenheilkunde am Universitätsklinikum des Saarlandes, die 379 Augen mit Keratokonus wurden aus dem Homburger Keratokonus Center (HKC) ausgewählt. Bei den Normalprobanden war der TKC-Wert „-“ (hier als 0 gewertet). Unter den Patienten mit Keratokonus waren 100 Befunde mit einem TKC-Wert von 1; 144 mit einem TKC-Wert von 2; 117 mit einem TKC-Wert von 3 und 18 mit einem TKC-Wert von 4 gemäß der Klassifikation der Pentacam auf der Basis der Hornhautvorderflächenbefunde. Für die binäre Klassifikation wurden die Befunde mit TKC=0 zu einem binären TKCbin=0 und die Befunde mit TKC=1, 2, 3 oder 4 zu TKCbin=1 zusammengefasst.

Das Corvis®ST ist ein Luftdrucktonometer, das einen normierten Luftstoß auf die Hornhaut appliziert. Mit einer Hochgeschwindigkeitskamera, die zusammen mit der horizontalen Spaltbeleuchtung (Wellenlänge 455 nm) die Konditionen an eine Scheimpflug-Abbildung erfüllt, wird in kurzer Folge eine Bildsequenz mit 4330 Bildern erfasst und so das dynamische Verhalten der durch den Luftstoß induzierten Eindellung sowie Relaxation der Hornhaut erfasst. Dabei wird für die Messung eine Vielzahl von DCR-Parametern (Dynamic Response Parameter) erfasst. Aus diesen DCR-Parametern werden 6 Größen für die Berechnung des Corvis®ST Biomechanical Index CBI verwendet [33] bzw. fließen in Kombination mit einer Messung der Pentacam in die Berechnung des Topographic Biomechanical Index TBI ein:

- ARTh: [2]: Ambrósio Relational Thickness horizontal, relative Hornhautdickenzunahme vom Zentrum zur Peripherie,
- SP-A1 [2]: Messgröße für die Steifigkeit der Hornhaut, Verhältnis aus Kraft (Druckpuls) zur Verformung der ersten Applanation. SPA1 verringert sich, je höher der Grad des Keratokonus, da die Gesamtsteifigkeit der Hornhaut reduzierter ist,
- DA-Ratio 1 mm [2, 33]: Verhältnis der zentralen Deformation zur peripheren Deformation (1 mm peripher), vergrößert sich mit geringerer Steifigkeit der Hornhaut (mehr „Flattern“ in der Peripherie),
- DA-Ratio 2 mm [2, 33]: Verhältnis der zentralen Deformation zur peripheren Deformation (2 mm peripher), vergrößert sich mit geringerer Steifigkeit der Hornhaut (mehr „Flattern“ in der Peripherie),
- A1 velocity (m/s): Geschwindigkeit der Hornhaut zur ersten Applanation,
- max. Deformation Amplitude (mm): maximale Deformation der Hornhaut in anterior-posteriore Richtung.

Die Kombination der Messdaten beider Messgeräte (Corvis®ST und Pentacam HR) wurde über die gemeinsame Software-Plattform in eine .csv-Datei überführt und für eine weitere Auswertung umformatiert.

Ophthalmologie 2021 · 118:697–706 <https://doi.org/10.1007/s00347-020-01231-1>
© Der/die Autor(en) 2020

A. Langenbacher · L. Häfner · T. Eppig · B. Seitz · N. Szentmáry · E. Flockerzi

Keratokonusedetektion und Ableitung des Ausprägungsgrades aus den Parametern des Corvis®ST. Eine Studie, basierend auf Algorithmen des Maschinlernens

Zusammenfassung

Hintergrund und Zielsetzung. In den vergangenen Jahren wurden zunehmend Systeme der künstlichen Intelligenz in der Medizin etabliert, die Pathologien oder Erkrankungen erkennen oder von komplementären Erkrankungen abgrenzen. Bisher liefert das Corvis®ST (Corneal Visualization Scheimpflug Technology, Oculus, Wetzlar, Deutschland) einen Index-CBI, der quasi binär Keratokonus klassifiziert, aber kein Staging zulässt. Ziel der Studie ist es, anhand von Messgrößen des Corvis®ST ein Vorhersagemodell zu entwerfen, das den Topographic Keratoconus Classification Index (TKC) der Pentacam high resolution (HR, Oculus) nachbildet.

Patienten und Methoden. Es wurden 60 Messungen an Normalprobanden (TKC 0) und 379 Augen mit Keratokonus (TKC 1 bis 4) in die Studie mit einbezogen. Nach der Messung mit der Pentacam HR (Zielgröße TKC) wurde eine Untersuchung mit dem Corvis®ST durchgeführt, aus der 6 Messparameter

extrahiert wurden, die in den Corvis Biomechanical Index CBI eingehen (ARTh, SP-A1, DA-Ratio 1 mm, DA-Ratio 2 mm, A1 velocity, max. Deformation Amplitude). Neben dem TKC als Zielgröße wurde der binarisierte TKC (1: TKC 1 bis 4, 0: TKC 0) modelliert. Als Gütemaß wurde die Genauigkeit des Modells als Anteil der korrekten Klassifizierungen herangezogen. Fehlklassifizierungen wurden in der Modellierung so bestraft, dass die Abweichung des modellierten TKC-Wertes vom gemessenen Wert bewertet wurde.

Ergebnisse. Es wurden 24 verschiedene Modelle des überwachten maschinellen Lernens aus 6 Familien getestet. Für die Modellierung des TKC in Stufen von 0–4 zeigte das Modell, basierend auf einer Support Vector Machine (SVM) mit linearem Kernel, die beste Performance mit einem Anteil an richtigen Klassifizierungen von 65,1 %. Für den binarisierten Wert des TKC zeigte ein Decision Tree mit grober Auflösung die beste

Performance mit einem Anteil an richtigen Klassifizierungen von 95,2 %, direkt gefolgt von der SVM mit linearem oder quadratischem Kernel und dem Nearest Neighborhood Classifier mit kubischem Kernel (jeweils 94,5 %).

Schlussfolgerungen. In der Arbeit soll das Prinzip des überwachten Maschinlernens in der Anwendung auf die modellierte Klassifizierung von Messbefunden gezeigt werden. So wurden Messdaten des Corvis®ST dazu verwendet, die Einteilung in den Schweregrad eines Keratokonus mittels Pentacam (TKC) mit einer ganzen Reihe von Algorithmen des maschinellen Lernens nachzubilden.

Schlüsselwörter

Corvis · Scheimpflug-Hornhauttomographie · Künstliche Intelligenz · Überwachtes Maschinlernen · Keratokonus

Keratoconus detection and classification from parameters of the Corvis®ST. A study based on algorithms of machine learning

Abstract

Background and objective. In the last decades increasingly more systems of artificial intelligence have been established in medicine, which identify diseases or pathologies or discriminate them from complementary diseases. Up to now the Corvis®ST (Corneal Visualization Scheimpflug Technology, Corvis®ST, Oculus, Wetzlar, Germany) yielded a binary index for classifying keratoconus but did not enable staging. The purpose of this study was to develop a prediction model, which mimics the topographic keratoconus classification index (TKC) of the Pentacam high resolution (HR, Oculus) with measurement parameters extracted from the Corvis®ST.

Patients and methods. In this study 60 measurements from normal subjects (TKC 0) and 379 eyes with keratoconus (TKC 1–4) were recruited. After measurement with the Pentacam HR (target parameter TKC) a measurement with the Corvis®ST

device was performed. From this device 6 dynamic response parameters were extracted, which were included in the Corvis biomechanical index (CBI) provided by the Corvis®ST (ARTh, SP-A1, DA ratio 1 mm, DA ratio 2 mm, A1 velocity, max. deformation amplitude). In addition to the TKC as the target, the binarized TKC (1: TKC 1–4, 0: TKC 0) was modelled. The performance of the model was validated with accuracy as an indicator for correct classification made by the algorithm. Misclassifications in the modelling were penalized by the number of stages of deviation between the modelled and measured TKC values.

Results. A total of 24 different models of supervised machine learning from 6 different families were tested. For modelling of the TKC stages 0–4, the algorithm based on a support vector machine (SVM) with linear kernel showed the best performance with an

accuracy of 65.1% correct classifications. For modelling of binarized TKC, a decision tree with a coarse resolution showed a superior performance with an accuracy of 95.2% correct classifications followed by the SVM with linear or quadratic kernel and a nearest neighborhood classifier with cubic kernel (94.5% each).

Conclusion. This study aimed to show the principle of supervised machine learning applied to a set-up for the modelled classification of keratoconus staging. Preprocessed measurement data extracted from the Corvis®ST device were used to mimic the TKC provided by the Pentacam device with a series of different algorithms of machine learning.

Keywords

Corvis · Scheimpflug corneal tomography · Artificial intelligence · Supervised machine learning · Keratoconus

Tab. 1 Strafpunkte im Klassifizierungsalgorithmus, die für eine Fehlklassifikation bei der Vorhersage vergeben wurden. Stimmt die Vorhersage des Maschinenlernalgorithmus mit dem gemessenen TKC-Wert überein (Hauptdiagonale, Text in Kursiv), so werden keine Strafpunkte vergeben. Je stärker die Abweichung desto höher ist das Strafmaß

		Mit dem Maschinenlernalgorithmus vorhergesagter Wert des TKC				
		TKC 0	TKC 1	TKC 2	TKC 3	TKC 4
Mit der Pentacam gemessener TKC	TKC 0	<i>0</i>	1	2	3	4
	TKC 1	1	<i>0</i>	1	2	3
	TKC 2	2	1	<i>0</i>	1	2
	TKC 3	3	2	1	<i>0</i>	1
	TKC 4	4	3	2	1	<i>0</i>

Die Weiterverarbeitung der 439 Datensätze erfolgte in der Interpretersprache MATLAB (MathWorks, Natick, USA, Version 2019b). Der Datensatz wurde über eine Zufallsstichprobe in 5 etwa gleich große Gruppen aufgeteilt (K-Fold-Kreuzvalidierung). Dann wurde für 5 Durchläufe jeweils 1 Gruppe als Validierungsdatensatz interpretiert und der Algorithmus auf der Basis der 4 anderen Gruppen trainiert, bis jede der 5 Gruppen einmal als Validierungsdatensatz verwendet wurde.

Die Datensätze wurden mit folgenden Strategien (Familien an Algorithmen) des Maschinlernens untersucht:

– Decision Trees

Entscheidungsbäume dienen der automatischen Klassifikation auf der Basis einer geordneten gerichteten (hierarchische Struktur) Sequenz an Entscheidungen [9]. Die Baumstruktur beginnt stets mit einem Wurzelknoten (erste Entscheidung beim Durchlaufen) sowie einer beliebigen Anzahl innerer Knoten, bei denen jeweils wieder eine Entscheidung nötig ist. In den meisten Fällen sind die Entscheidungen an jeder Verzweigung binär (erlauben nur 2 Optionen). Diese Familie von Algorithmen lässt sich sehr anschaulich grafisch darstellen bzw. in einer Software implementieren. Man unterscheidet die unterschiedlichen Auflösungsstufen dieser Familie an Algorithmen nach der maximalen Anzahl von Verzweigungen (Entscheidungen).

In dieser Arbeit wurden 3 verschiedenen Auflösungsstufen vorgesehen: grobe/mittlere/feine Auflösung ent-

spricht einer Beschränkung auf 20/40/100 Entscheidungen.

– Discriminance Analysis

Die Diskriminanzanalyse dient der automatischen Einteilung bzw. Klassifikation in 2 oder mehrere Gruppen auf der Basis von Merkmalen [10, 20]. Die hier verwendeten 6 Merkmale (Parameter des Corvis) treten bei jedem Probanden oder Patienten in einer spezifischen Ausprägung auf. Die Strategie der Diskriminanzanalyse ist es nun, in einem 6-dimensionalen Merkmalsraum Ebenen zu definieren, durch die die gelabelten Fälle sich optimal trennen lassen im Sinne einer quadratischen Distanz des Merkmalsvektors zur Trennfläche. Bei der linearen Diskriminanzanalyse wird davon ausgegangen, dass die zu unterscheidenden Gruppen gleiche Kovarianzmatrizen aufweisen. Bei der nichtlinearen (z. B. quadratischen) Diskriminanzanalyse wird mit einer nichtlinearen (z. B. quadratischen) Diskriminanzfunktion gearbeitet, die Kovarianzmatrizen der verschiedenen Gruppen sind daher nicht mehr gleich.

In dieser Arbeit wurden die lineare und die quadratische Diskriminanzanalyse verwendet.

– Naive Bayes Classifiers

Ein Bayes-Klassifikator (benannt nach dem Mathematiker Thomas Bayes) ordnet einer Corvis-Messung eines Patienten/Probanden einer Klasse zu in der Art, dass die „Kosten“, (also das Strafmaß) am geringsten sind. In unserem Fall wird wiederum ein 6-dimensionaler Raum aufgespannt, und jede Koordinate in diesem Raum wird einer Klasse

zugeordnet [20]. Der Rechenaufwand für den Bayes-Algorithmus ist vergleichsweise hoch, so verwendet man oft eine vereinfachte Form (Naive Bayes). Die Vereinfachung wird durch die Entflechtung der „Merkmale und Attribute“ geschaffen, in vielen Fällen führt dieser vereinfachte Ansatz bereits zu einer guten Trennung zwischen den Klassen. Unterschieden wird hier in der Annahme der Dichteverteilungen der einzelnen Merkmale.

In der vorliegenden Arbeit wurde der Naive-Bayes-Algorithmus mit 2 unterschiedlichen Dichteverteilungen implementiert, einmal auf der Annahme einer Normalverteilung (Gaussian Naive-Bayes) und einmal auf der Kernel Naive-Bayes auf der Basis einer Kernel-Gewichtungsfunktion (als Vertreter einer flexiblen nichtparametrischen Wahrscheinlichkeitsdichteverteilung).

– SVM

Eine Support Vector Machine kann sowohl für Regressionsnetzwerke wie auch für klassifizierende Netzwerke eingesetzt werden [3]. Im vorliegenden Fall wird wiederum ein 6-dimensionaler Merkmalsraum aufgespannt. Der Ansatz einer SVM ist es, eine Hyperebene (als Trennebene) zu definieren, umgeben von einem möglichst breiten Korridor, sodass der Fläche benachbarten Fällen zuverlässig Klassen zugeordnet werden können. Der Abstand der einzelnen Fälle entlang des Normalenvektors zur Hyperebene muss demnach möglichst groß sein. Die Charakteristik ist nun, dass ausschließlich die Fälle (Corbis-Messungen) für die Definition der Hyperebene herangezogen werden, die in der unmittelbaren Nachbarschaft der Trennebene liegen (sog. Stützstellen oder „support vectors“), alle weiter von der Trennebene entfernten Fälle werden dabei ignoriert. SVM bieten eine besonders elegante und effiziente Form der Berücksichtigung unterschiedlicher Kernelfunktionen, die als verallgemeinertes Skalarprodukt von Vektoren angesehen werden können. Etabliert sind beim maschinellen

Tab. 2 Mittelwert und Standardabweichung der 6 DCR-Parameter des Corvis®ST, die für die Erstellung der verschiedenen Maschinenlernalgorithmen zur Nachbildung des TKC (und des binarisierten TKC) der Pentacam verwendet wurden. Der *p*-Wert (Mann-Whitney-U-Test) vergleicht die Gruppe der Normalprobanden (TKC = 0) mit der Gruppe der Patienten mit Keratokonus (TKC = 1 ... 4)

Anzahl <i>n</i> = 439	ARTh	SP-A1	DA-Ratio 1 mm	DA-Ratio 2 mm	A1 velocity	Max. Deformation Amplitude
TKC 0	536 ± 162	116 ± 18	1,52 ± 0,06	3,89 ± 0,43	0,13 ± 0,02	1,05 ± 0,11
TKC 1–4	242 ± 128	66 ± 22	1,69 ± 0,10	5,56 ± 1,52	0,17 ± 0,03	1,20 ± 0,16
Gesamt	282 ± 167	73 ± 27	1,66 ± 0,11	5,33 ± 1,53	0,16 ± 0,03	0,18 ± 0,16
<i>p</i> -Wert	<0,001	<0,001	<0,001	<0,001	<0,001	<0,001

Tab. 3 Korrelation der 6 DCR-Parameter des Corvis®ST, aus denen der TKC (sowie der binarisierte TKC) der Pentacam nachgebildet werden soll (*n* = 439). In der oberen rechten Hälfte der Matrix ist Spearman's *p* dargestellt, in der unteren linken Hälfte Kendall's *τ*. Die Werte korrelieren sehr stark miteinander. Aufgrund der starken Korrelation der Parameter untereinander ist der Informationsgehalt der hier dargestellten Werte begrenzt

<i>τ</i>	<i>p</i>					
	ARTh	SP-A1	DA-Ratio 1 mm	DA-Ratio 2 mm	A1 velocity	Max. Deformation Amplitude
ARTh	1	0,765	-0,785	-0,773	-0,583	-0,502
SP-A1	0,579	1	-0,792	-0,841	-0,761	-0,772
DA-Ratio 1 mm	-0,598	-0,605	1	0,933	0,675	0,678
DA-Ratio 2 mm	-0,590	-0,665	0,789	1	0,786	0,725
A1 velocity	-0,416	-0,570	0,491	0,598	1	0,798
Max. Deformation Amplitude	-0,432	-0,583	0,490	0,540	0,612	1

Lernen lineare oder polynomiale Kernel oder Gauß-Kernel, die auch als radiale Basisfunktionen (RBF) zu verstehen sind.

In der vorliegenden Arbeit wurden für die Support Vector Machine ein vereinfachter linearer Kernel, ein polynomialer Kernel in Form eines quadratischen und kubischen Ansatzes sowie ein Gauß-Kernel mit 3 verschiedenen Auflösungsstufen implementiert. Die Auflösungsstufe bezieht sich auf die Skalierung des Kernels.

- Nearest Neighborhood Classifiers**
 Dieser Nächste-Nachbarn-Klassifikator [1] basiert auf einem nichtparametrischen Verfahren zur Schätzung der Wahrscheinlichkeitsdichteverteilungen. Geht man im vorliegenden Fall wieder von einem 6-dimensionalen Merkmalsraum aus, so erfolgt die Klassifikation durch eine Mehrheitsentscheidung der bereits klassifizierten benachbarten Messungen im Merkmalsraum. Zu jedem Fall werden *k* nächste Nachbarn bewertet, wobei *k* die Auflösungsstufe beschreibt und in der Regel, um ein Unentschieden in der Mehrheitsfindung auszuschließen, eine ungerade Zahl ist. Wird *k* zu hoch gewählt, so besteht die Gefahr, dass Messungen

in die Klassifikation mit einbezogen werden, die im Merkmalsraum weit weg liegen und einer anderen Klasse angehören, wird *k* zu klein gewählt, so besteht die Gefahr, dass Rauschen in den Trainingsdaten die Entscheidung beeinflusst. Die Algorithmen sind in der Regel sehr effizient zu implementieren.

In der vorliegenden Arbeit wurde für den Nearest-Neighborhood-Klassifikator mit einer euklidischen Norm als Abstandsmaß mit *k* = 3/5/11 (grobe/mittlere/feine Auflösungsstufe) gearbeitet, mit einer Cosinus-Distanz (anguläre Distanz), mit einer kubischen Metrik sowie einer Metrik mit gewichteten Abständen. Die Details zu den verschiedenen Metriken sind in [1] aufgeführt.

- Ensemble Learning**
 Ensembleverfahren werden beim maschinellen Lernen eingesetzt, um mit einer endlichen Menge an unterschiedlichen Lernalgorithmen anstatt eines einzelnen Algorithmus zu arbeiten [11, 20]. Bagging kombiniert mehrere komplementäre Vorhersagen von Klassifikationsmodellen, wobei die Ergebnisse der einzelnen Modelle gleich gewertet werden. Beim Boosting werden schwache Klassifikatoren verwendet, um in

der Zusammenarbeit der Verfahren einen starken Klassifikator zu erhalten. Sehr oft werden hier als Familien von Klassifikatoren Decision Trees (Boosted Tree, Bagged Tree, Random Undersampling Boosted Tree), Diskriminanzanalyseverfahren (Discriminance Analysis), Nearest-Neighborhood-Verfahren in einem Ensemble zusammengefasst.

In der vorliegenden Arbeit wurden für die Ensemble-Ansätze ein Boosted Tree bzw. ein Random Undersampling Boosted Tree, ein Bagged Tree, eine Subspace Discriminance Analysis sowie ein Subspace-*k*-Nearest-Neighborhood-Klassifikator implementiert.

Das Strafmaß für eine Fehlklassifizierung wurde so gewählt, dass auf der Hauptdiagonalen keine Strafpunkte und auf der 1., 2. und 3. Nebendiagonalen jeweils mit 1, 2 oder 3 Strafpunkten gewichtet wurde, sodass eine Abweichung des geschätzten vom beobachteten TKC-Wert linear mit dem Maß der Abweichung bestraft wird. Die **Tab. 1** zeigt die Strafpunkte, die für eine Fehlklassifikation des Algorithmus vergeben wurden.

Für die Bewertung der einzelnen Ansätze bei der Abbildung des TKC-Index bzw. des binären TKCbin-Index wurde

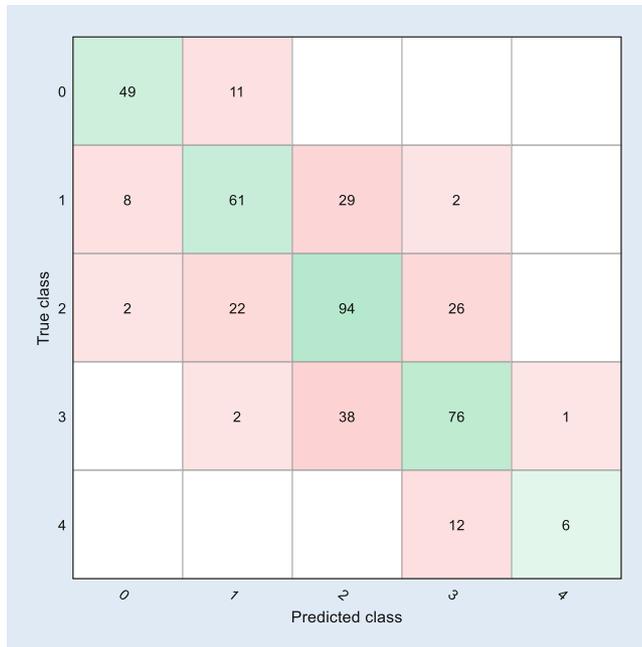


Abb. 1 ▲ Konfusionsmatrix für die Support Vector Machine (SVM) mit linearem Kernel für die Schätzung des TKC ($n=439$). Auf der Hauptdiagonalen sind die richtig getroffenen Entscheidungen abzulesen, auf den beiden ersten Nebendiagonalen die Fälle, bei denen das Modell den TKC um 1 Stufe falsch geschätzt hat etc.

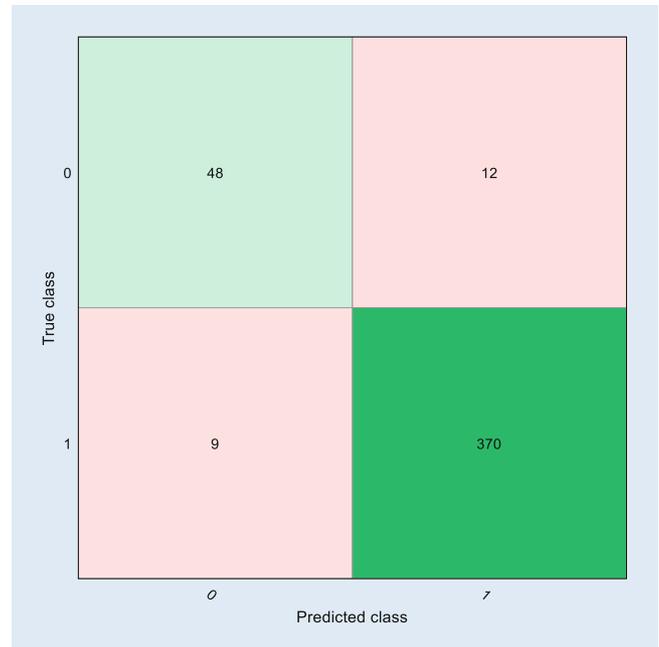


Abb. 2 ▲ Konfusionsmatrix für den Decision Tree mit grober Auflösungsstufe für die Schätzung des binarisierten TKC (TKCbin, $n=439$). Links oben/rechts unten wurden die richtig Positiven/richtig Negativen eingetragen, rechts oben/links unten die falsch Positiven/falsch Negativen. Die Genauigkeit (Accuracy) liegt bei 95,2%, die Sensitivität bei 97,4% und die Spezifität bei 80,0%

die Konfusionsmatrix berechnet. Als Gütekriterien für die Bewertung der einzelnen Ansätze wurde aus der Konfusionsmatrix die Genauigkeit (Accuracy) als Anteil der im Validierungsdatensatz richtig entschieden Klassifizierungen ermittelt.

Zur Einordnung unserer Ergebnisse wurden zudem der CBI des Corvis sowie der Gesamtindex BAD-D des Belin-Ambrósio-Keratokonusmoduls (Pentacam) mit erfasst. Für die Darstellung der Konfusionsmatrix für den TKCbin und den CBI/BAD-D wurde beim BAD-D ein Trennwert von 1,6 und beim CBI ein Trennwert von 0,5 [33] herangezogen.

Ergebnisse

Der Altersvergleich zwischen Probanden (TKC=0) und Patienten mit Keratokonus (TKC=1 bis TKC=4) wies keinen signifikanten Unterschied auf ($p=0,027$). In **Tab. 2** sind die Ergebnisse der deskriptiven Auswertung (Mittelwert \pm Standardabweichung) der 6 DCR-Parameter des Corvis[®]ST dargestellt, die hier als Einflussgrößen für

die Ableitung eines Schätzmodells für den TKC dienen sollen. Die Auswertung erfolgte separat für die Gruppe der Normalprobanden (mit TKC=0), die Gruppe mit Keratokonus (TKC=1...4) sowie für das Gesamtkollektiv. Im Vergleich der Gruppe der Normalprobanden mit der Gruppe der Augen mit Keratokonus weisen alle 6 ausgewerteten Parameter einen signifikanten Unterschied auf (jeweils $p < 0,001$, Mann-Whitney-U-Test).

Wie aus **Tab. 3** hervorgeht, sind die 6 Parameter ARTh, SP-A1, DA-Ratio 1 mm, DA-Ratio 2 mm, A1 velocity und max. Deformation Amplitude untereinander stark korreliert (Spearman's $|\rho| \geq 0,576$). Das bedeutet für unseren Ansatz, dass die Größen voneinander abhängen und damit der Informationsgehalt dieser Größen begrenzt ist.

Die **Tab. 4** stellt die Ergebnisse der 4 Ansätze des Maschinenlernens mit der besten Performance, angewandt auf die 439 Datensätze zur Nachbildung des TKC, dar. Die 24 Algorithmen aus 6 verschiedenen Familien wurden eingesetzt, um den TKC-Wert der Penta-

cam nachzubilden, der Werte zwischen 0 (in der Pentacam als „-“ geführt) und 4 annehmen kann. Es zeigt sich, dass bei der Nachbildung des TKC der SVM-Algorithmus mit linearem Kernel die besten Ergebnisse hinsichtlich der Genauigkeit liefert (65,1% richtige Entscheidungen), gefolgt von der Diskriminanzanalyse mit linearem Kernel und dem SVM-Algorithmus mit Gauß-Kernel in der mittleren Auflösungsstufe sowie der SVM mit quadratischem Kernel. Exemplarisch wurde hier die SVM mit linearem Kernel als der Ansatz mit der besten Genauigkeit dargestellt. Die **Abb. 1** zeigt die Konfusionsmatrix mit dem Anteil der richtigen Entscheidungen auf der Hauptdiagonalen. Auf den beiden ersten Nebendiagonalen wird der TKC-Wert der Pentacam jeweils um 1 falsch geschätzt, auf den 2. Nebendiagonalen jeweils um 2 TKC-Stufen daneben etc.

Weiter wurde der binarisierte Wert TKCbin modelliert, der Werte von 0 (in der Pentacam „-“) oder 1 (TKC=1 bis TKC=4) annimmt (**Tab. 5**). Für die Entscheidung, ob ein Keratokonus

Tab. 4 Hier sind die 4 Algorithmen des Maschinenlernens dargestellt, die, basierend auf dem vorliegenden Datensatz von 439 Augen, hinsichtlich ihrer Genauigkeit für die Nachbildung des TKC der Pentacam die höchste Genauigkeit erreichten. (Der Algorithmus mit der höchsten Güte ist in kursiv markiert.) Linear/quadratisch/Gauß beziehen sich auf den verwendeten Kernel des Algorithmus, mittel bezeichnet die Auflösungsstufe des Algorithmus. Als Gütemaße wurden die Genauigkeit der Entscheidung ($(\text{richtig Positive} + \text{richtig Negative})/\text{Gesamtanzahl}$) und die kumulierte Anzahl der Strafpunkte (Summe der mit den jeweiligen Strafpunkten gewichteten Entscheidungen) dargestellt

Algorithmusfamilie	Algorithmus	Topographic Keratoconus Classification TKC 0–4 (n = 439)	
		Genauigkeit in %	Kumulierte Strafpunkte
Support Vector Machine	Linear	65,1	159
	Quadratisch	62,4	178
	Gauß mittel	62,6	174
Discriminace Analysis	Linear	64,0	162

Tab. 5 Hier sind die 4 Algorithmen des Maschinenlernens dargestellt, die, basierend auf dem vorliegenden Datensatz von 439 Augen, die hinsichtlich ihrer Genauigkeit für die Nachbildung des binarisierten TKC der Pentacam (TKCbin) die höchste Genauigkeit erreichten. Linear/quadratisch/kubisch bezieht sich auf den verwendeten Kernel des Algorithmus, beim Decision Tree wurden in der groben Auflösungsstufe maximal 20 binäre Entscheidungen (für mittel/fein 40/100 Entscheidungen) zugelassen. Als Gütemaße wurden die Genauigkeit der Entscheidung ($(\text{richtig Positive} + \text{richtig Negative})/\text{Gesamtanzahl}$) und die kumulierte Anzahl der Strafpunkte dargestellt. Da bei der Klassifikation nach TKCbin die falsch positiven und falsch negativen Entscheidungen jeweils mit 1 Strafpunkt belegt wurden, entspricht die Anzahl der Strafpunkte hier der Anzahl der Fehlentscheidungen

Algorithmusfamilie	Algorithmus	Topographic Keratoconus Classification TKC 0–4 (n = 439)	
		Genauigkeit in %	Kumulierte Strafpunkte
Decision Tree	Grob	95,2	21
Support Vector Machine	Linear	94,5	24
	Quadratisch	94,5	24
Nearest Neighborhood Classifier	Kubisch	94,5	24

Tab. 6 Konfusionsmatrix für den binarisierten TKC-Index TKCbin vs. CBI und BAD-D-Gesamtindex. Als Trennwert zwischen Normalbefund und Keratokonus wurden die in der Literatur beschriebenen Werte CBI = 0,5 [33] und BAD-D = 1,6 herangezogen. Der CBI/BAD-D bildet in 381/431 Fällen den TKCbin korrekt nach. Das entspricht einer Accuracy von 86,8%/98,2%. Aus der Konfusionsmatrix kann man die Sensitivität von 85,0%/98,9% und die Spezifität von 98,3%/93,3% ablesen. Die Vergleichstabelle für den in dieser Arbeit vorgestellten Algorithmus des Maschinenlernens findet sich in **Abb. 2**

	Corvis Biomechanical Index CBI		Belin-Ambrósio Gesamtindex BAD-D	
TKCbin	0	1	0	1
0	59	1	56	4
1	57	322	4	375

vorliegt oder nicht (TKCbin), ergab die Modellierung mit dem Entscheidungsbaum in der groben Auflösungsstufe (mit maximal 20 zulässigen binären Entscheidungen) eine Genauigkeit von 95,2% (Sensitivität 97,4%, Spezifität 80%), gefolgt vom SVM-Algorithmus mit linearem oder quadratischem Kernel und

dem Nearest Neighbourhood Classifier mit kubischem Kernel (jeweils 94,5%). Exemplarisch wurde hier aufgrund der besten Performance der Decision Tree mit grober Auflösungsstufe dargestellt. Die **Abb. 2** zeigt die Konfusionsmatrix mit dem Anteil der richtig positiven und

negativen sowie falsch positiven und negativen Entscheidungen.

Für den in **Abb. 2** herausgegriffenen Ansatz des Decision Tree mit grober Auflösungsstufe wird in **Abb. 3** exemplarisch der Entscheidungsbaum grafisch dargestellt. Von den maximal 20 zugelassenen binären Entscheidungen (in der groben Auflösungsstufe) wurden nur 11 benötigt für die Konstruktion des Baumes. An jeder Gabelung wird eine der 6 Einflussgrößen abgefragt, und je nachdem, ob der aktuelle Wert eines Datensatzes größer oder kleiner als der Schwellwert ist, wird der linke oder rechte Ast weiterverfolgt. Nach der letzten binären Entscheidung kann direkt das Ergebnis der Schätzung entweder für 1 (Keratokonius, beschrieben durch einen TKC = 1 bis 4) oder 0 (kein Keratokonus, beschrieben durch TKC = 0 bzw. „-“) abgelesen werden.

Die **Tab. 6** zeigt die Konfusionsmatrix des binarisierten TKC (TKCbin) vs. Corvis Biomechanical Index CBI und Gesamtindex des Belin-Ambrósio Moduls der Pentacam BAD-D. Die Accuracy des CBI ist dabei im Vergleich zu dem hier vorgestellten Index des Maschinenlernens mit 86,8% deutlich geringer, die des BAD-D mit 98,9% deutlich höher. Die entsprechende Konfusionsmatrix des Algorithmus des Maschinenlernens, der auf dem vorliegenden Datensatz die beste Performance erreicht hat, ist in **Abb. 2** dargestellt.

Diskussion

Neben einer ganzen Reihe an anderen Disziplinen wie der Technik, dem Finanzwesen und den Naturwissenschaften hat die künstliche Intelligenz in den vergangenen Jahren ihren Einzug in der Medizin gehalten [11]. In der Ophthalmologie wird beispielsweise die künstliche Intelligenz verwendet, um Pathologien der Netzhaut zu erkennen und zu klassifizieren, aber auch seit vielen Jahren für die Erkennung und Quantifizierung ektatischer Erkrankungen wie dem Keratokonus, dem Keratoglobus oder der pelluziden marginalen Degeneration. Schon wenige Jahre nach der Einführung der computergestützten Hornhauttopographie als Weiterent-

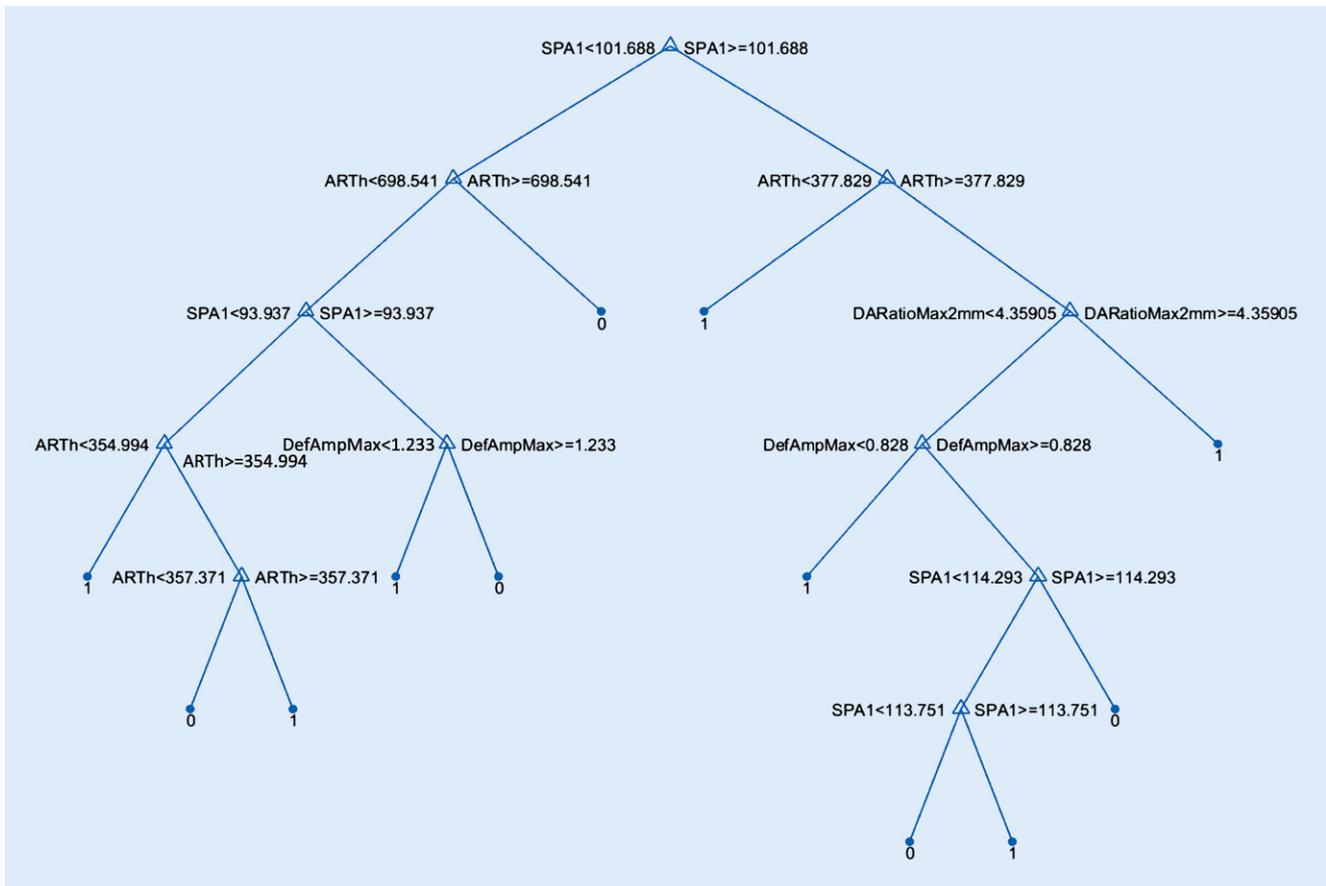


Abb. 3 ▲ Exemplarische Darstellung des Entscheidungsbaums mit grober Auflösung (Decision Tree grob) aus **Abb. 2** mit einer Genauigkeit von 95,2 % für die Modellierung des binarisierten TKC (TKCbin). Bei der Entwicklung des Entscheidungsbaums wurden maximal 20 binäre Entscheidungen zugelassen, nach 11 Entscheidungen wurde keine weitere Verbesserung erreicht. Beim Durchlaufen der Baumstruktur von oben nach unten wird an jeder Gabelung binär einer der 6 Parameter abgefragt und damit entschieden, ob der linke oder rechte Weg gewählt wird. Nach der letzten Entscheidung kann direkt abgelesen werden, ob das Modell den Datensatz als Keratokonus oder Normalbefund (auf der Basis des TKC) identifiziert

wicklung des Videokeratops wurden die ersten Screening-Indizes für das TMS-1 der Firma Computed Anatomy entwickelt, die als Vorfahren dessen angesehen werden können, was heute mit modernen Verfahren möglich ist. In den 90er-Jahren wurden in aller Regel Entscheidungsbäume und einfach neuronale Netze verwendet [12–14, 22–24, 31], heute steht eine umfangreiche Anzahl ganzer Familien von Algorithmen zur Verfügung [20, 21, 25, 27, 32, 35–37].

Entscheidend dafür, welche Verfahren angewandt werden, ist zum einen die Datenbasis selbst, ob z. B. direkt Bilddaten oder Messdaten ausgewertet werden sollen oder ob zum anderen aus Messdaten bereits vorverarbeitete Daten (wie im vorliegenden Fall) herangezogen werden sollen. Werden z. B. Bilddaten als Basis benutzt, so muss zunächst eine deutliche

Datenreduktion oder Merkmalsextraktion erfolgen. Weiter muss bei Bilddaten oft erst die translatorische und rotatorische Varianz eliminiert werden und die Größe der relevanten Struktur normiert werden [9]. Aber auch im vorliegenden Fall sieht man anhand der starken Korrelation der Parameter (vgl. **Tab. 3**), dass bereits bei der geringen Anzahl an Parametern, die für die Modellierung verwendet werden, ein erheblicher Anteil an Redundanz im System vorliegt. Möglicherweise lässt sich das Modell, basierend auf der Korrelation der Einflussfaktoren, weiter vereinfachen (beispielsweise durch eine Hauptachsentransformation und Eliminieren nichtsignifikanter Eigenwerte). Weiter muss geprüft werden, ob bei Ansätzen des Maschinlernens ein Ansatz aus dem überwachten Lernen zum Einsatz kommen soll

oder ein Clustern der Daten beabsichtigt ist, bei dem der Algorithmus selbstständig eine Aufteilung der Daten nach Merkmalen vornimmt. Beim überwachten Lernen wird Expertenwissen benötigt [4–7, 26, 34], also beispielsweise eine Klassifizierung durch einen oder mehrere Experten („Labeling“). Gerade die Einbringung des Expertenwissens macht Verfahren der künstlichen Intelligenz anfällig für Fehlentscheidungen, da Experten im Grenzfall nicht immer kohärente Entscheidungen fällen. Werden mehrere Experten um eine Klassifizierung gebeten, werden klare Fälle meist kohärent bewertet, bei Grenzfällen können Entscheidungen aber abweichen [4–6, 17, 18]. Bei Regressionsverfahren soll am Ende nicht eine Klassifizierung von Datensätzen vorgenommen werden, sondern eine Zahl (z. B. ein Schweregrad einer Er-

krankung) stehen. Wichtig ist stets, dass die Daten, mit denen ein Algorithmus trainiert wird, den gesamten Bereich der Möglichkeiten abdeckt, sonst können in Grenzfällen Entscheidungen vom Algorithmus nicht oder nur fehlerhaft getroffen werden. Weiter ist Voraussetzung für eine Bewertung eines Modells, dass die Daten, die für das Trainieren des Modells verwendet werden, disjunkt zu denen sind, die später für die Validierung eingesetzt werden. Wird das nicht beachtet, so wird die Performance des Modells überbewertet.

In der vorliegenden Arbeit soll gezeigt werden, wie man grundsätzlich an die Aufgabenstellung herangeht, aus den vorverarbeiteten Messdaten eines Systems (hier das Corvis®ST der Firma Oculus) ein Modell zu entwickeln, das möglichst gut die Klassifizierung eines anderen Messsystems (hier die Pentacam HR der Firma Oculus) in Form des Topographic Keratoconus Classification Index (TKC) in Stufen von 0 = kein Keratokonus bis 4 = schwerer Keratokonus nachbildet. Ziel ist es, anhand der Parameter des Corvis®ST einen modellierten Parameter abzuleiten, der in möglichst vielen Fällen kohärent zum TKC-Wert ist. Die hier getesteten Modelle werden auf der Basis des (nicht sehr umfangreichen) Datensatzes der Aufgabenstellung nur zum Teil gerecht. Eines der 24 getesteten Verfahren ist in der Lage, gut 65 % richtige Entscheidungen zu treffen. Toleriert man eine Abweichung des modellierten TKC-Wertes von der Ausgabe der Pentacam um 1 Stufe, so werden am Ende nur 6 von 439 Fällen mit einer Abweichung im TKC von mehr als 1 klassifiziert (s. **Abb. 1**, jeweils 2. Nebendiagonalen). Gibt man sich mit einer Binarisierung im Sinne einer Entscheidung Keratokonus oder kein Keratokonus auf der Basis des TKC zufrieden, so werden über 95 % richtige Entscheidungen getroffen. Hier reicht ein einfacher Entscheidungsbaum mit einer groben Auflösung aus, wie er in **Abb. 3** gezeigt ist. Vergleicht man die Kohärenz der Entscheidungen, die man erhält, wenn man mit dem CBI einen Trennwert von 0,5 annimmt [33] oder mit dem BAD-D einen Trennwert von 1,6, so ergibt sich damit eine Accuracy

von 86,8 % für den CBI bzw. 98,9 % für den BAD-D. Dass Klassifizierungen, die auf denselben Messdaten basieren, grundsätzlich einfacher kohärente Ergebnisse bei einer Klassifizierung erzielen können, liegt auf der Hand (BAD-D vs. TKC, beide basierend auf den Daten der Pentacam). Entsprechend schneiden der CBI sowie der hier vorgestellte Decision Tree schlechter ab. Vergleicht man den CBI mit dem Decision Tree in der groben Auflösungsstufe, so zeigt der CBI eine höhere Spezifität, jedoch eine geringere Accuracy, also eine geringere Anzahl der mit dem TKCbin übereinstimmenden Entscheidungen (381 vs. 418). Über die Anpassung der Entscheidungsschwelle kann ggf. der CBI hinsichtlich der Accuracy noch weiter optimiert werden. Allerdings kann diese Aussage nur auf dem vorliegenden Datensatz getroffen werden.

Bei der vorliegenden Studie wurde mit einer symmetrischen Matrix für das Strafmaß gearbeitet. Das bedeutet, dass eine Unterschätzung des TKC-Wertes genauso behandelt wird wie eine Überschätzung, in unserem Fall wird jede Stufe der Abweichung mit 1 Punkt geahndet (**Tab. 1**). So wird am Ende die Konfusionsmatrix in etwa diagonal-symmetrisch (s. **Abb. 1**). Möchte man dagegen ein Modell entwickeln, das z. B. eine hohe Sensitivität hat (damit möglichst kein pathologischer Befund übersehen wird, was natürlich auf Kosten der Spezifität geht), so kann gezielt mit einer asymmetrischen Matrix für das Strafmaß gearbeitet werden.

Zusammenfassend soll diese Studie das prinzipielle Vorgehen zeigen, wie bei einem Ansatz des überwachten maschinellen Lernens eine Klassifizierung (der Goldstandard für das System) durch ein Modell so nachgebildet wird, dass eine möglichst gute Übereinstimmung der vorhergesagten Klasse mit der als „Expertenwissen“ in den Algorithmus eingespeisten Klassifizierung erreicht wird. Das Ergebnis kann anschließend z. B. mit der Konfusionsmatrix bewertet werden, aus der die Rate der richtig klassifizierten Fälle (Genauigkeit, Accuracy) abgelesen werden kann. Das Vorgehen wurde anhand eines Datensatzes von Normalprobanden und Patienten mit Kera-

tokonus aus dem Homburger Keratokonus Center (HKC) gezeigt, bei denen anhand von vorverarbeiteten Messgrößen des Corvis®ST der TKC-Wert der Pentacam nachgebildet werden sollte.

Korrespondenzadresse

Prof. Dr. Achim Langenbucher
Institut für Experimentelle Ophthalmologie,
Universität des Saarlandes
Kirrberger Str., Gebäude 22, 66421 Homburg,
Deutschland
achim.langenbucher@uks.eu

Funding. Open Access funding provided by Projekt DEAL.

Einhaltung ethischer Richtlinien

Interessenkonflikt. A. Langenbucher, L. Häfner, T. Eppig, B. Seitz, N. Szentmáry und E. Flockerzi bestätigen, dass keine finanziellen Interessen an den im Manuskript beschriebenen Methoden oder den Ergebnissen vorliegen.

Alle beschriebenen Untersuchungen am Menschen oder an menschlichem Gewebe wurden mit Zustimmung der zuständigen Ethikkommission, im Einklang mit nationalem Recht sowie gemäß der Deklaration von Helsinki von 1975 (in der aktuellen, überarbeiteten Fassung) durchgeführt. Von allen beteiligten Patienten liegt eine Einverständniserklärung vor.

Open Access. Dieser Artikel wird unter der Creative Commons Namensnennung 4.0 International Lizenz veröffentlicht, welche die Nutzung, Vervielfältigung, Bearbeitung, Verbreitung und Wiedergabe in jeglichem Medium und Format erlaubt, sofern Sie den/die ursprünglichen Autor(en) und die Quelle ordnungsgemäß nennen, einen Link zur Creative Commons Lizenz beifügen und angeben, ob Änderungen vorgenommen wurden.

Die in diesem Artikel enthaltenen Bilder und sonstiges Drittmaterial unterliegen ebenfalls der genannten Creative Commons Lizenz, sofern sich aus der Abbildungslegende nichts anderes ergibt. Sofern das betreffende Material nicht unter der genannten Creative Commons Lizenz steht und die betreffende Handlung nicht nach gesetzlichen Vorschriften erlaubt ist, ist für die oben aufgeführten Weiterverwendungen des Materials die Einwilligung des jeweiligen Rechteinhabers einzuholen.

Weitere Details zur Lizenz entnehmen Sie bitte der Lizenzinformation auf <http://creativecommons.org/licenses/by/4.0/deed.de>.

Literatur

1. Alfeilat AHA, Hassanat ABA, Lasassmeh O, Tarawneh AS, Alhasanat MB, Salman HSE, Prasath VBS (2019) Effects of distance measure choice on K-nearest neighbour classifier performance: A review. *Big Data* 7(4):221–248

2. Ambrósio R Jr, Lopes BT, Faria-Correia F, Salomão MQ, Bühren J, Roberts CJ, Elsheikh A, Vinciguerra R, Vinciguerra P (2017) Integration of Scheimpflug-based corneal tomography and biomechanical assessments for enhancing ectasia detection. *J Refract Surg* 33(7):434–443
3. Bechtel S (2008) Maschinelles Lernen in der Medizin – Anwendung von Support Vector Machines in der Ganganalyse. Diplomarbeit Fachbereich Mathematik. Universität des Saarlandes, Oldenbourg Wissenschaftsverlag GmbH
4. Goebels S, Eppig T, Seitz B, Langenbucher A (2013) Detection of early forms of keratoconus—current screening methods. *Klin Monbl Augenheilkd* 230(10):998–1004
5. Goebels S, Eppig T, Wagenpfeil S, Cayless A, Seitz B, Langenbucher A (2017) Complementary Keratoconus indices based on topographical interpretation of biomechanical waveform parameters: a supplement to established Keratoconus indices. *Comput Math Methods Med* 2017:5293573. <https://doi.org/10.1155/2017/5293573>
6. Goebels S, Eppig T, Wagenpfeil S, Cayless A, Seitz B, Langenbucher A (2015) Staging of keratoconus indices regarding tomography, topography, and biomechanical measurements. *Am J Ophthalmol* 159(4):733–738
7. Goebels S, Seitz B, Langenbucher A (2013) Diagnostics and stage-oriented therapy of keratoconus: introduction to the Homburg keratoconus center (HKC). *Ophthalmologie* 110(9):808–809
8. Herber R, Ramm L, Spoerl E, Raikup F, Pillunat LE, Terai N (2019) Assessment of corneal biomechanical parameters in healthy and keratoconic eyes using dynamic bidirectional applanation device and dynamic Scheimpflug analyzer. *J Cataract Refract Surg* 45(6):778–788
9. Herrmann J (1997) Maschinelles Lernen und Wissensbasierte Systeme. Springer, Heidelberg. ISBN 978-3-540-61302-2
10. Karimi A, Meimani N, Razaghi R, Rahmati SM, Jadidi K, Rostami M (2018) Biomechanics of the healthy and keratoconic corneas: a combination of the clinical data, finite element analysis, and artificial neural network. *Curr Pharm Des* 24(37):4474–4483
11. Kleesiek J, Murray JM, Kaissis G, Braren R (2020) Künstliche Intelligenz und maschinelles Lernen in der onkologischen Bildgebung. *Onkologie* 26:60–65
12. Klyce SD, Smolek MK, Maeda N (2000) Keratoconus detection with the KISA% method—another view. *J Cataract Refract Surg* 26(4):472–474
13. Klyce SD (2009) Chasing the suspect: keratoconus. *Br J Ophthalmol* 93(7):845–847
14. Klyce SD (2018) The future of Keratoconus screening with artificial intelligence. *Ophthalmology* 125(12):1872–1873. <https://doi.org/10.1016/j.ophtha.2018.08.019>
15. Koh S, Inoue R, Ambrósio R Jr, Maeda N, Miki A, Nishida K (2020) Correlation between corneal biomechanical indices and the severity of Keratoconus. *Cornea* 39(2):215–221
16. Kovács I, Miháltz K, Kránitz K, Juhász É, Takács Á, Dienes L, Gergely R, Nagy ZZ (2016) Accuracy of machine learning classifiers using bilateral data from a Scheimpflug camera for identifying eyes with preclinical signs of keratoconus. *J Cataract Refract Surg* 42(2):275–283
17. Langenbucher A, Gusek-Schneider GC, Kus MM, Huber D, Seitz B (1999) Keratoconus screening with wave-front parameters based on topography height data. *Klin Monbl Augenheilkd* 214(4):217–223
18. Langenbucher A, Nguyen NX, Seitz B (2001) Modeling corneal topography with a subdivision scheme in keratoconus. *Ophthalmologie* 98(1):54–59
19. Lavric A, KeratoDetect VP (2019) Keratoconus detection algorithm using convolutional neural networks. *Comput Intell Neurosci*. <https://doi.org/10.1155/2019/8162567>
20. Lin SR, Ladas JG, Bahadur GG, Al-Hashimi S, Pineda R (2019) A review of machine learning techniques for keratoconus detection and refractive surgery screening. *Semin Ophthalmol* 34(4):317–326
21. Lopes BT, Ramos IC, Salomão MQ, Guerra FP, Schallhorn SC, Schallhorn JM, Vinciguerra R, Vinciguerra P, Price FW Jr, Price MO, Reinstein DZ, Archer TJ, Belin MW, Machado AP, Ambrósio R Jr. (2018) Enhanced tomographic assessment to detect corneal ectasia based on Artificial Intelligence. *Am J Ophthalmol* 195:223–232
22. Maeda N, Klyce SD, Smolek MK, Thompson HW (1994) Automated keratoconus screening with corneal topography analysis. *Invest Ophthalmol Vis Sci* 35(6):2749–2757
23. Maeda N, Klyce SD, Smolek MK (1995) Comparison of methods for detecting keratoconus using videokeratography. *Arch Ophthalmol* 113(7):870–874
24. Maeda N, Klyce SD, Smolek MK (1995) Neural network classification of corneal topography. Preliminary demonstration. *Invest Ophthalmol Vis Sci* 36(7):1327–1335 (Erratum in: *Invest Ophthalmol Vis Sci* 1995 Sep;36(10):1947–8)
25. Randleman JB, Dupps WJ Jr, Santhiago MR, Rabinowitz YS, Koch DD, Stulting RD, Klyce SD (2015) Screening for Keratoconus and related Ectatic corneal disorders. *Cornea* 34(8):e20–e22. <https://doi.org/10.1097/ICO.0000000000000500>
26. Reisdorf S (2019) Artificial intelligence for the development of screening parameters in the field of corneal biomechanics. *Klin Monbl Augenheilkd* 236(12):1423–1427
27. Ruiz Hidalgo I, Rodriguez P, Rozema JJ, Ní Dhubghaill S, Zakaria N, Tassignon MJ, Koppen C (2016) Evaluation of a machine-learning classifier for Keratoconus detection based on Scheimpflug tomography. *Cornea* 35(6):827–832
28. Rüping S, Sander J (2019) Big Data im Gesundheitswesen. In: Haring R (Hrsg) *Gesundheit digital: Perspektiven zur Digitalisierung im Gesundheitswesen*. Springer, Heidelberg. ISBN 978-3-662-57610-6
29. Salomão MQ, Hofling-Lima AL, Gomes Esporcatte LP, Lopes B, Vinciguerra R, Vinciguerra P, Bühren J, Sena N Jr, Luz Hilgert GS, Ambrósio R Jr. (2020) The role of corneal biomechanics for the evaluation of ectasia patients. *Int J Environ Res Public Health* 17(6):E2113. <https://doi.org/10.3390/ijerph17062113>
30. Sedaghat MR, Momeni-Moghaddam H, Ambrósio R Jr, Heidari HR, Maddah N, Danesh Z, Sabzi F (2018) Diagnostic ability of corneal shape and biomechanical parameters for detecting Frank Keratoconus. *Cornea* 37(8):1025–1034
31. Smolek MK, Klyce SD (1997) Current keratoconus detection methods compared with a neural network approach. *Invest Ophthalmol Vis Sci* 38(11):2290–2299
32. Tan A, Yu M, Chen X, Hu L (2019) Application of deep learning in early diagnosis assistant system of Keratoconus. *Zhongguo Yi Liao Qi Xie Za Zhi* 43(2):83–85. <https://doi.org/10.3969/j.issn.1671-7104.2019.02.002>
33. Vinciguerra R, Ambrósio R Jr, Elsheikh A, Roberts CJ, Lopes B, Morenghi E, Azzolini C, Vinciguerra P (2016) Detection of Keratoconus with a new biomechanical index. *J Refract Surg* 32(12):803–810
34. Welsch A, Eitle V, Buxmann P (2018) Maschinelles Lernen. *HMD* 55:366–382. <https://doi.org/10.1365/s40702-018-0404-z>
35. Xie Y, Zhao L, Yang X, Wu X, Yang Y, Huang X, Liu F, Xu J, Lin L, Lin H, Feng Q, Lin H, Liu Q (2020) Screening candidates for refractive surgery with corneal tomographic-based Deep Learning. *JAMA Ophthalmol*. <https://doi.org/10.1001/jamaophthalmol.2020.0507>
36. Yousefi S, Yousefi E, Takahashi H, Hayashi T, Tam-po H, Inoda S, Arai Y, Asbell P (2018) Keratoconus severity identification using unsupervised machine learning. *Plos One* 13(11):e205998. <https://doi.org/10.1371/journal.pone.0205998>
37. Zou HH, Xu JH, Zhang L, Ji SF, Wang Y (2019) Assistant diagnose for subclinical keratoconus by artificial intelligence. *Zhonghua Yan Ke Za Zhi* 55(12):911–915