

Ophthalmologie 2021 · 118:893–899
<https://doi.org/10.1007/s00347-021-01385-6>
 Angenommen: 25. März 2021
 Online publiziert: 22. April 2021
 © Springer Medizin Verlag GmbH, ein Teil von
 Springer Nature 2021



R. Diener · M. Treder · N. Eter

Klinik für Augenheilkunde, Universitätsklinikum Münster, Münster, Deutschland

Diagnostik von Erkrankungen des Sehnervenkopfes in Zeiten von künstlicher Intelligenz und Big Data

Im Rahmen verschiedener Erkrankungen des Sehnervenkopfes hilft die multimodale Bildgebung, verschiedene Pathologien exakt darzustellen. Dies ermöglicht sowohl eine genaue Diagnostik als auch eine Verlaufsbeurteilung. Die Auswertung dieser Daten mithilfe von künstlicher Intelligenz (KI) eröffnet neue Möglichkeiten in der Augenheilkunde. Zusätzlich kann Big Data helfen, immer mehr anfallende Daten strukturiert auszuwerten.

Big Data

„Big Data“ beschreibt die Analyse von großen Datenmengen. Diese ermöglicht die kostengünstige und ressourcensparende Beantwortung verschiedener klinischer Fragestellungen, um so auch übergeordnete Zusammenhänge aufzeigen zu können [1]. So konnten beispielsweise eine Assoziation zwischen minimierter Sonnenstrahlenexposition und erhöhter Inzidenz eines primären Offenwinkelglaukoms, sowie ein erhöhtes Risiko einer Glaukomerkrankung bei Patienten mit Diabetes mellitus oder vorbestehender arterieller Hypertonie identifiziert werden [2–4]. Basis für diese Auswertungen sind große, strukturierte und digitale Datensammlungen. Dies hat im Bereich der Augenheilkunde dazu geführt, dass verschiedene Register gegründet wurden. Besonders nennenswert sind in diesem Zusammenhang das „Save-Sight“-Register in Australien, das „IRIS“-Register in den USA und das „OREGIS“-Register unter

Schirmherrschaft der Deutschen Ophthalmologischen Gesellschaft (DOG) in Deutschland [5–7].

» „Big Data“ beschreibt die Analyse von großen Datenmengen

Unterstützt wird diese Entwicklung durch eine zunehmende elektronische Dokumentation der Patientenvisiten [8–12]. Gerade in Zeiten einer Pandemie kann sich dies als hilfreich erweisen. Bommakanti et al. entwickelten und implementierten beispielsweise ein Tool, welches das individuelle Risiko eines Fortschreitens einer Augenerkrankung – wie einem Glaukom – durch eine verzögerte Inanspruchnahme der Versorgung und das Morbiditätsrisiko durch eine COVID-19-Exposition berücksichtigt und die Triage anstehender Augenarzttermine erleichtert [13]. Weitere Möglichkeiten von strukturierten großen Datensätzen sind die Anwendung von KI für eine Segmentierung und Klassifikation oder Prädiktion des Krankheitsverlaufs.

Künstliche Intelligenz

KI ist ein Teilbereich der Informatik und beschreibt Algorithmen, die in der Lage sind, „intelligente“ Entscheidungen zu treffen.

Maschinelles Lernen (ML) und Deep Learning (DL) sind Unterbegriffe der KI und beschreiben Algorithmen, welche die Fähigkeiten besitzen, bestimmte Lö-

sungsansätze selbstständig zu „erlernen“ (Abb. 1). ML kann als eine Erweiterung der klassischen Statistik bezeichnet werden. Statistische Modelle sind darauf ausgelegt, Varianzen zu erklären und herauszuarbeiten, mit welcher Wahrscheinlichkeit es sich dabei um Zufall handelt. ML-Modelle haben genauso wie die klassischen statistischen Modelle das Ziel, durch „Training“ anhand von Musterdaten exakte Vorhersagen zu treffen. Im Vergleich zu den klassischen statistischen Modellen ist hier das Ergebnis in der Regel allerdings weniger gut nachvollziehbar.

» Machine Learning ist eine Unterform der künstlichen Intelligenz, welche Deep Learning beinhaltet

Beim DL werden sog. tiefe neuronale Netzwerke verwendet, bei dem Algorithmen orientiert an der Struktur des menschlichen Gehirns aufgebaut sind. In der einfachsten Form hat ein neuronales Netzwerk 3 Elemente: den Input Layer, in dem die Daten dem System zugeführt werden, die Hidden Layers, in denen die Daten weiterverarbeitet werden, und den Output Layer, in dem eine Information (statistische Entscheidung) ausgegeben wird. Diese Algorithmen sind insbesondere für die automatische Bildanalyse geeignet, jedoch sind für den Anwender die Entscheidungsprozesse nicht immer nachvollziehbar und führen somit häu-




Abb. 1 ▲ Künstliche Intelligenz. Machine Learning ist eine Unterform der künstlichen Intelligenz, die wiederum Deep Learning beinhaltet




Abb. 3 ▲ Cup-Disc-Ratio. Die Cup-Disc-Ratio kann durch eine automatisierte Segmentierung von Cup (A) und Disc (B) berechnet werden

fig zu einer sog. „Black Box“ ([14–16]; **Abb. 2**).

Bildsegmentierung

Die Bildsegmentierung ist der Vorgang des Überprüfens eines jeden einzelnen Bildpunktes, ob dieser einem uns interessierenden Objekt, wie z. B. einer anatomischen Struktur, angehört.

Die Untersuchung des Sehnervenkopfes kann neben der stereoskopischen Funduskopie mithilfe unterschiedlicher Bildgebungsmodalitäten wie der Farbfundusfotografie oder der optischen Kohärenztomographie (OCT) erfolgen. Für eine korrekte Zuordnung von strukturellen Veränderungen zu verschiedenen Sehnervenerkrankungen ist eine genaue Segmentierung der anatomischen Strukturen erforderlich.

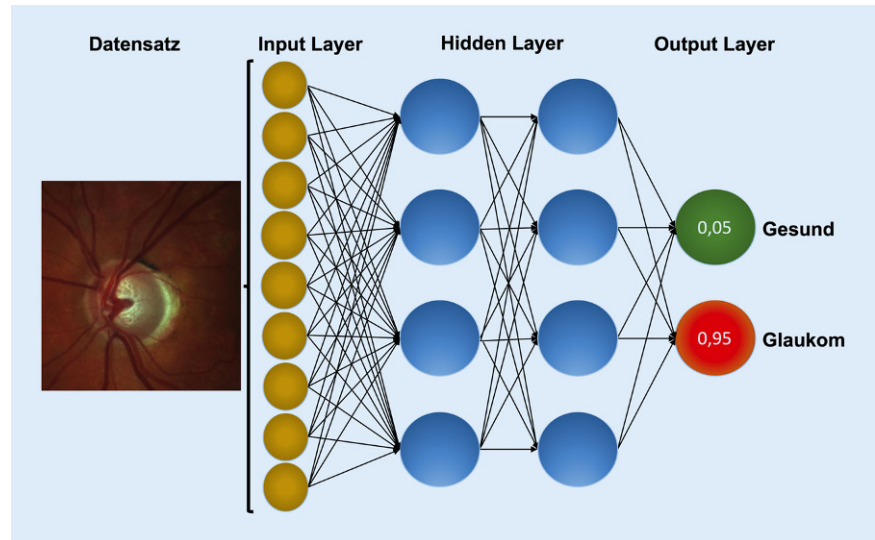


Abb. 2 ▲ Künstliches neuronales Netz. Das Bild eines Sehnervenkopfes wird dem künstlichen neuronalen Netz (KNN) durch die Input Layer zugänglich gemacht. Jedes Pixel entspricht einem Input-Neuron (hier mit weniger Neuronen vereinfacht dargestellt). Nach Verarbeitung der Bildinformationen in den Hidden Layers wird das Bild im Output Layer mit einer Wahrscheinlichkeit von 95 % als Glaukom klassifiziert. (Mod. nach Treder et al. [15])

Eine große Exkavation im Verhältnis zu der Sehnervenscheibe (Cup-Disc-Ratio) kann beispielsweise ein Hinweis für eine glaukomatöse Optikusschädigung sein.

Zwar ist eine große Exkavation nicht direkt pathognomonisch für ein Glaukom, jedoch minimiert eine automatisierte robuste Berechnung der Cup-Disc-Ratio (CDR) die hohe Inter- und Intraobservervariabilität der Beurteilung von Papillen auf Fundusfotos [17].

Mehrere Arbeitsgruppen entwickelten deshalb Modelle, mit denen eine automatische Segmentierung des Sehnervenkopfes in Cup und Disc und somit eine leichte Berechnung der CDR auf Fundusfotos möglich ist ([18]; **Abb. 3**) Trotzdem ist diese aufgrund des Mangels an scharfen Konturen und fehlender Tiefeninformationen innerhalb eines 2-dimensionalen Bildes fehleranfällig. Zhao et al. konnten dieses Problem mit einem 2-stufigen halb-überwachten Ansatz lösen. Mithilfe eines tiefen neuronalen Netzes wurden in einem ersten Schritt auf Fundusfotos vorher nicht definierte Merkmale des Sehnervenkopfes extrahiert (Output). Somit wird eine aufwendige und fehleranfällige manuelle Markierung umgangen, da das System selbstständig nach Merkmalen (engl. „features“) suchte. In einem

zweiten Schritt wurden diese Merkmale wiederum als Input für ein weiteres Regressionsmodell zur Vorhersage der vertikalen CDR verwendet. Das Modell konnte die CDR mit einem mittleren absoluten Fehler von 0,0563 sehr genau vorhersagen und übertraf klassische Modelle, die auf einer manuellen Segmentierung basierten [19].

Im Gegensatz zu Fundusfotos ermöglicht ein OCT-Scan eine 3-dimensionale Darstellung des Sehnervenkopfes und des peripapillären Gewebes. Diese hat zu einem tieferen Verständnis von strukturellen Veränderungen im Bereich des Sehnerven bei verschiedenen Optikusnerkrankungen geführt.

Im Rahmen einer glaukomatösen Optikusneuropathie kommt es beispielsweise zu typischen Veränderungen im Bereich der Papille und der peripapillären retinalen Nervenfaserschicht (RNFL). Bislang segmentieren kommerziell erhältliche Geräte v. a. die RNFL und die auf der Bruch-Membran basierende minimale Randsaumweite (BMO-MRW). Diese Parameter haben sich v. a. bei der Detektion und Verlaufsbeurteilung von Glaukompatienten als sinnvoll erwiesen. Jedoch können bei bis zu 40 % der RNFL-Scans Segmentierungsfehler aufgrund einer schlechten Aufnahmequalität auftreten [20]. Eine manuelle

Korrektur dieser Fehler ist zeitaufwendig und behindert den Arbeitsfluss im klinischen Alltag.

Mit dem DL-Modell, das von Mariotoni et al. vorgeschlagen wurde, ließ sich die RNFL in OCT-Bildern mit schlechter Aufnahmequalität besser messen, als mit der Software des Herstellers [21]. Neben der RNFL und BMO-MRW zeigen sich bei Fortschreiten eines Glaukoms jedoch auch Änderungen anderer anatomischer Strukturen, die auf dem OCT-Scan der Papille sichtbar sind. Zwar konnten Thompson et al. auf OCT-Scans mithilfe eines DL-Modells ohne Segmentierung der RNFL besser ein Glaukom diagnostizieren als mit der Nervenfaserschichtdickenmessung [22], welche eine segmentierungsunabhängige Klassifikation von gesunden Patienten und Patienten mit einem Glaukom ermöglicht. Dies limitiert im Umkehrschluss jedoch auch die klinische Anwendung des Algorithmus allein auf die genannten Patientengruppen.

Im Gegensatz dazu sind Bildsegmentierungsalgorithmen wie der von Devala et al. universell bei allen Erkrankungen des Sehnervenkopfes anwendbar, da sie nicht speziell auf die automatische Identifikation einer bestimmten Erkrankung, sondern allein auf eine optimierte Segmentierung einer Bildgebungsmodalität trainiert sind. Die genannte Arbeitsgruppe konnte mithilfe eines mehrschichtigen neuronalen Netzwerkes die RNFL, das prälaminaire Gewebe, das retinale Pigmentepithel, die Aderhaut, die Lamina cribrosa und die peripapilläre Sklera automatisiert zuordnen und markieren [23]. Die automatische Segmentierung konnte robust sowohl in gesunden als auch in für Segmentierungsfehler anfälligen glaukomatös veränderten Sehnervenköpfen durchgeführt werden [24]. In einem weiteren Ansatz konnte die gleiche Arbeitsgruppe einen DL-Algorithmus entwickeln, der die Qualität von OCT-B-Scans unterschiedlicher Geräte so harmonisierte, dass in einem weiteren Schritt eine gerätespezifische Segmentierung der Strukturen möglich war [25]. Dies macht eine einfache Implementierung der Segmentierung von OCT-Scans im klinischen Alltag auf unterschiedlichen Geräten möglich und erleichtert die Diagnostik und Verlaufsbe-

Ophthalmologe 2021 · 118:893–899 <https://doi.org/10.1007/s00347-021-01385-6>
© Springer Medizin Verlag GmbH, ein Teil von Springer Nature 2021

R. Diener · M. Treder · N. Eter

Diagnostik von Erkrankungen des Sehnervenkopfes in Zeiten von künstlicher Intelligenz und Big Data

Zusammenfassung

Hintergrund. Der Einsatz von künstlicher Intelligenz (KI) ist unter anderem in der automatischen Bildsegmentierung, -analyse und Klassifikation interessant und bereits für verschiedene Bereiche der Augenheilkunde beschrieben.

Fragestellung. Diese Arbeit soll einen Überblick über aktuelle Ansätze und Fortschritte bei der Anwendung von Big Data und KI bei verschiedenen Erkrankungen des Sehnervenkopfes geben.

Material und Methode. Es wurde eine PubMed-Recherche durchgeführt. Gesucht wurde nach Studien, die klinische Fragestellungen mithilfe von Big-Data-Ansätzen beantworteten oder klassische Methoden des maschinellen Lernens bei der Analyse von multimodaler Bildgebung des Sehnervenkopfes verwendeten.

Ergebnisse. Big Data kann bei Volkskrankheiten wie dem Glaukom helfen, klinische

Fragestellungen zu beantworten. KI findet sowohl bei der Segmentierung von multimodaler Bildgebung des Sehnervenkopfes als auch bei der Klassifikation von Erkrankungen wie dem Glaukom oder der Stauungspapille auf diesen Bilddaten Anwendung.

Schlussfolgerung. Mithilfe von Big Data und KI können Zusammenhänge besser erkannt und die Diagnostik und Verlaufsbeurteilung von Erkrankungen des Sehnervenkopfes erleichtert oder automatisiert werden. Eine Voraussetzung für die klinische Anwendung ist in Europa die CE-Kennzeichnung als ein Medizinprodukt und in den USA die Zulassung durch die Food and Drug Administration.

Schlüsselwörter

Maschinelles Lernen · Fundusfotos · Glaukom · Optische Kohärenztomographie · Deep Learning

Diagnostics of diseases of the optic nerve head in times of artificial intelligence and big data

Abstract

Background. The use of artificial intelligence (AI) interesting for automated image segmentation, analysis and classification, among others and has already been described for various fields of ophthalmology.

Objective. This manuscript provides an overview of current approaches and advances in the application of big data and AI in various diseases of the optic nerve head.

Material and methods. A PubMed search was performed. Studies were searched for that answered clinical questions using big data approaches or classical machine learning methods in the analysis of multimodal imaging of the optic nerve head.

Results. Big data can help to answer clinical questions in common diseases such as glaucoma. The AI is applied for

the segmentation of multimodal imaging of the optic nerve head as well as for the classification of diseases, such as glaucoma or optic disc edema on this imaging data.

Conclusion. With the help of big data and AI, relationships can be recognized more easily and the diagnostics and course assessment of diseases of the optic nerve head can be facilitated or automated. A prerequisite for clinical application is a CE marking as a medical device in Europe and approval by the Food and Drug Administration in the USA.

Keywords

Machine learning · Fundus photography · Glaucoma · Optical coherence tomography · Deep learning

urteilung von Erkrankungen des Sehnervenkopfes wie dem Glaukom.

Glaukomatöse Optikusneuropathie

Da eine glaukomatöse Optikusneuropathie im Frühstadium asymptomatisch verläuft, ist das Glaukom für ein Scree-

ning von großen Patientenkohorten geeignet.

Jedoch liefert aktuell noch kein einzelnes Untersuchungsverfahren allein ausreichend valide Daten, um ein Glaukom sicher zu diagnostizieren. Für ein kosteneffektives Glaukomscreening wäre ein einzelner Test mit gleichzeitig hoher Sensitivität und Spezifität wünschenswert [26]. Da die digitale Farbfundusfotografie weit verbreitet und kostengünstig ist, scheint eine automatisierte, KI-gestützte Bilddatenanalyse zur Detektion von glaukomatösen Optikuschädigungen auf dieser Bildgebungsmodalität sehr attraktiv [27].

» Für ein kosteneffektives Glaukomscreening wäre ein einzelner Test wünschenswert

Die Klassifikation von glaukomatösen Optikusneuropathien auf Farbfundusfotos ist schon mit einer hohen Genauigkeit möglich. Li et al. konnten mithilfe von 48.116 Fundusfotos einen DL-Algorithmus mit einer Fläche unter der Kurve (AUC) von 0,986 zur Detektion von glaukomatösen Optikusneuropathien generieren [28]. Phene et al. konnten mit ihrem DL-Algorithmus, trainiert auf 86.618 Fundusfotos, sogar 2 Glaukomspezialisten bei der Klassifikation einer glaukomatösen Optikusatrophie übertreffen [29]. Für den Augenarzt ist die Logik hinter der Entscheidung des Algorithmus aufgrund der „Black Box“ von Algorithmen v. a. bei tiefen neuronalen Netzwerken jedoch nicht nachvollziehbar.

Dies konnte die Arbeitsgruppe um Phene et al. mithilfe einer logistischen Regression jedoch umgehen und zeigen, dass sowohl für den Glaukomspezialisten als auch für den Algorithmus die gleichen Merkmale (CDR > 0,7, Papillenrandkerbe, Nervenfaserverdefekt, Gefäßverlauf) am ausschlaggebendsten für die Klassifikation waren [29].

Obwohl die Fundusfotografie der optimale Kandidat für ein Glaukomscreening zu sein scheint, können mit OCT-Scans zusätzliche Informationen wie die peripapilläre RNFL oder BMO-

MRW über den Sehnervenkopf gewonnen werden.

Medeiros et al. konnten zeigen, dass es möglich ist, einen Algorithmus darauf zu trainieren, automatisiert die Dicke der RNFL allein auf Fundusfotos zu quantifizieren [30]. Sie trainierten ein tiefes neuronales Netzwerk mit Fundusfotos und den korrespondierenden SD („spectral domain“)-OCT-Scans von 2312 Sehnerven. Das DL-System konnte auf einem Testdatensatz, bestehend aus 6292 Papillenfotos, die mittlere Dicke der RNFL mit einer absoluten Abweichung von $82,5 \pm 16,8 \mu\text{m}$ vorhersagen. Dieses Modell übertraf sogar Augenärzte in der Klassifikation von Bildern von Sehnervenköpfen mit und ohne einen Gesichtsfelddefekt [31]. Die gleiche Arbeitsgruppe konnte ähnlich vielversprechende Ergebnisse mit der Vorhersage der mittleren BMO-MRW allein auf Fundusfotos erzielen [32].

Neben der Quantifizierung von RNFL und BMO-MRW auf Farbfundusfotos könnten andere KI-Ansätze zu einem tieferen Verständnis der Auswirkung von strukturellen Veränderungen des Sehnerven auf seine Funktion führen. Christopher et al. konnten mithilfe eines DL-Modells Gesichtsfelddefekte nur anhand von OCT-Scans des Sehnervenkopfes vorhersagen [33]. Dieser Ansatz könnte im klinischen Alltag helfen, die Häufigkeit der zeitaufwendigen Gesichtsfelduntersuchung bei Glaukompatienten effektiver zu gestalten und gezielter anzuwenden. Mariottoni et al. konnten eine KI-basierte Zuordnung von strukturellen OCT-RNFL-Schäden zu Gesichtsfelddefekten bei einem Glaukom entwickeln. Dies ermöglicht ein tieferes Verständnis des Zusammenhanges von Struktur und Funktion und kann im klinischen Alltag bei der Beurteilung von RNFL-Defekten helfen [34].

Stauungspapille

Eine der größten Herausforderungen bei der Anwendung von KI ist es, robuste Ansätze auch für Erkrankungen mit geringer Inzidenz zu entwickeln. Teilweise ist bei diesen eine ausreichend große Anzahl an Patienten nur mit Datenbanken oder großen multizentrischen Studien zu

erzielen. Trotzdem kann gerade die Abgrenzung einer Erkrankung mit hoher Inzidenz wie dem Glaukom zu anderen selteneren Sehnervenerkrankungen schwierig und zugleich klinisch hochrelevant sein. Dieser Fragestellung widmeten sich Yang et al. und konnten mit einem DL-Modell zwischen glaukomatöser und nichtglaukomatöser Optikusneuropathie auf 3815 Farbfundusfotos mit einer Sensitivität von 93 % und einer Spezifität von 81 % unterscheiden [35].

» Große Datensätze bei Erkrankungen mit niedriger Inzidenz zu generieren ist eine Herausforderung

Vergleichsweise einfach ist für einen erfahrenen Augenarzt die Detektion einer Stauungspapille. Die direkte Ophthalmoskopie wird aber nur noch vereinzelt von Internisten oder Neurologen beherrscht. Jedoch zeigt sich bei 2,6 % aller Patienten mit neurologischen Symptomen eine Stauungspapille (STP), die Hinweis auf einen erhöhten Hirndruck sein kann [36]. Wird diese übersehen und bleibt eine intrakranielle Hypertension unbehandelt, kann dies zu einem irreversiblen Nervenfaserverdefekt mit konsekutiver Funktionsminderung führen. Aus diesem Grund wird in verschiedenen Kliniken und Notaufnahmen mithilfe der digitalen Fundusfotografie ein Bild des Sehnervenkopfes erstellt [37]. Dieses Bild wiederum muss durch einen Augenarzt vor Ort oder per Telemedizin in einem anderen Zentrum beurteilt werden [37]. Hier wäre ein robuster KI-Ansatz zur automatischen Detektion von Papillenödem sehr hilfreich, jedoch sind große Datensätze bei Erkrankungen mit niedriger Inzidenz ein limitierender Faktor. Echeagaray et al. konnten mithilfe eines ML-Algorithmus automatisiert auf Farbfundusfotos den Grad des Papillenödems nach Frisén [38] mit einer gleichen Genauigkeit wie ein erfahrener Neuroophthalmologe klassifizieren [39]. Akbar et al. konnten automatisiert mit einer Genauigkeit von 92,9 % eine Stauungspapille von gesunden Sehnervenköpfen auf Farbfundusfotos abgrenzen [40], ähnliche Ergeb-

nisse wurde von Fatima et al. erzielt [41]. Die verwendeten Datensätze waren mit einer Anzahl von jeweils unter 300 Fundusfotos in beiden Fällen nur gering. Auch ist die Unterscheidung zwischen gesund und krank zwar vielversprechend, entspricht jedoch nicht der Realität, in der mehr als 2 Alternativen vorhanden sind. So ist es klinisch teilweise schwierig, zwischen Papillenödem und Pseudopapillenödem – beispielsweise bei hyperopen Augen – zu unterscheiden. Mit einem ML-Modell konnten Ahn et al. zwischen geschwollenen Sehnervenköpfen aufgrund unterschiedlicher Optikusneuropathien, Pseudopapillenödem und gesunden Sehnervenköpfen unterscheiden [42]. Zusätzlich umgingen die genannten Autoren das Problem eines kleinen Datensatzes. Zum einen konnte mithilfe von Augmentierung der vorhandenen Daten die Diversität des Datensatzes erhöht werden, ohne tatsächlich neue Daten zu generieren. Dies minimiert das Risiko einer Überanpassung (engl. „overfitting“), was bedeutet, dass der Algorithmus nicht auf externe Daten anwendbar

ist, da er zwischen gesund und krank anhand von Merkmalen unterscheidet, die nur in dem vorhandenen Datensatz, aber nicht auf einem weiteren externen Datensatz vorhanden sind. Zum anderen wurde ein vortrainiertes tiefes neuronales Netzwerk verwendet. Dadurch wurden trotz der geringeren Datenmengen gute Ergebnisse erzielt.

Einen deutlich größeren Datensatz konnten Milea et al. [43] in einer multizentrischen Studie generieren. Die Arbeitsgruppe trainierte einen DL-Algorithmus auf 14.341 Fundusfotos, von denen 2148 Papillen ein Papillenödem aufgrund einer intrakraniellen Hypertension hatten. Der Algorithmus konnte auf einem externen Datensatz von 1505 Farbfundusfotos mit einer AUC von jeweils 0,99 zwischen gesunden Sehnervenköpfen und Stauungspapillen sowie zwischen Stauungspapillen und anderen Pathologien des Sehnervenkopfes unterscheiden. Die Studie aus dem *New England Journal of Medicine* zeigt, dass auch bei Erkrankungen mit geringer Inzidenz mithilfe von multi-

zentrischen Datensätzen robuste Algorithmen generiert werden können. Der Algorithmus der BONSAI-Arbeitsgruppe könnte bei Implementierung einen großen Einfluss auf die tägliche Routine in Notaufnahmen haben und maßgeblich die Versorgung von Patienten mit intrakranieller Hypertension durch eine schnellere Diagnostik und Therapie verbessern.

Schlussfolgerung und Ausblick

Die strukturierte Sammlung und Auswertung von Daten mithilfe von Big-Data-Analysen sowie die Verwendung maschinellen Lernens auf digitalisierten Daten hat zu einer Vielzahl an interessanten Anwendungen geführt. Mit diesen können Zusammenhänge besser erkannt und die Diagnostik und Verlaufsbeurteilung von Erkrankungen des Sehnervenkopfes erleichtert oder automatisiert werden. Eine Voraussetzung für die klinische Anwendung ist in Europa die CE-Kennzeichnung als ein Medizinprodukt und in den USA die Zulassung durch die

Hier steht eine Anzeige.

Food and Drug Administration (FDA). In den nächsten Jahren wird sich zeigen, ob eine Implementierung dieser Algorithmen in den Alltag umgesetzt werden kann.

Die Anwendung von künstlicher Intelligenz in der Augenheilkunde ist jedoch längst keine Zukunftsmusik mehr. Zuletzt konnte ein auf KI basierender Algorithmus zur Früherkennung einer diabetischen Retinopathie auf Fundusfotos eine Zulassung in Europa (2019) und in den USA (2018) erhalten [44].

Fazit für die Praxis

- Um eine automatisierte Klassifikation von Erkrankungen mit hoher und mit geringer Inzidenz zu ermöglichen, ist die strukturelle Erfassung von Bilddaten in Registern oder in multizentrischen Studien notwendig.
- KI(künstliche Intelligenz)-basierte Algorithmen können durch eine verbesserte Segmentierung von Fundusfotos und OCT(optische Kohärenztomographie)-Scans des Sehnervenkopfes die Diagnostik und Verlaufsbeurteilung von Sehnerven-erkrankungen optimieren.
- KI-basierte Algorithmen können auf Farbfundusfotos besser ein Glaukom erkennen als ein Augenarzt und bieten deshalb einen interessanten Ansatz für ein Glaukomscreening von großen Datenmengen.
- KI-basierte Algorithmen könnten den Ablauf in Notaufnahmen durch eine automatisierte Diagnostik von Papillenödem auf Farbfundusfotos optimieren.

Korrespondenzadresse



Dr. med. R. Diener
Klinik für Augenheilkunde,
Universitätsklinikum Münster
Domagkstr. 15, 48149 Münster,
Deutschland
raphael.diener@
ukmuenster.de

Einhaltung ethischer Richtlinien

Interessenkonflikt. R. Diener, M. Treder und N. Eter geben an, dass kein Interessenkonflikt besteht.

Für diesen Beitrag wurden von den Autoren keine Studien an Menschen oder Tieren durchgeführt. Für die aufgeführten Studien gelten die jeweils dort angegebenen ethischen Richtlinien.


Literatur

1. Clark A, Ng J, Morlet N, Semmens J (2016) Big data and ophthalmic research. *Surv Ophthalmol* 61(4):443–465
2. Ellis JD, Evans JM, Ruta DA, Baines PS, Leese G, MacDonald TM et al (2000) Glaucoma incidence in an unselected cohort of diabetic patients: is diabetes mellitus a risk factor for glaucoma? *Br J Ophthalmol* 84(11):1218–1224
3. Kuang TM, Xirasagar S, Kao YW, Shia BC, Lin HC (2020) Association of systemic hypertension with primary open-angle glaucoma: a population-based case-control study. *Am J Ophthalmol* 218:99–104
4. Teikari J, O'Donnell J, Nurminen M, Raivio I (1991) Acute closed angle glaucoma and sunshine. *J Epidemiol Community Health* 45(4):291–293
5. Gillies M, Walton R, Liong J, Arnold J, McAllister I, Morlet N et al (2014) Efficient capture of high-quality data on outcomes of treatment for macular diseases: the fight retinal blindness! Project. *Retina* 34(1):188–195
6. Parke I D, Lum F, Rich W (2017) The IRIS® registry: purpose and perspectives. *Ophthalmologie* 114(1):1–6
7. van Dijk K, Ham L, Tse WH, Liarakos VS, Quilendrino R, Yeh RY et al (2013) Near complete visual recovery and refractive stability in modern corneal transplantation: descemet membrane endothelial keratoplasty (DMEK). *Cont Lens Anterior Eye* 36(1):13–21
8. Alnawaiseh M, Alten F, Huelsken G, Rentmeister G, Lange M, Claes T et al (2015) Implementierung einer elektronischen Patientenakte an einer deutschen Augenklinik der Maximalversorgung. *Ophthalmologie* 112(4):337–345
9. Kortüm K, Müller M, Babenko A, Kampik A, Kreuzer T (2015) Entwicklung eines augenärztlichen klinischen Informationssystems für bettenführende Augenkliniken. *Ophthalmologie* 112(12):995–1001
10. Kuchenbecker J, Behrens-Baumann W (2004) Einsatz einer elektronischen Patientenakte (EPA) an der Universitätsaugenklinik Magdeburg. *Ophthalmologie* 101(12):1214–1219
11. Spira-Eppig C, Eppig T, Bischof M, Schießel G, Milioti G, Käsmann-Kellner B et al (2018) Per aspera ad astra: Einführung einer elektronischen Patientenakte an einer Universitätsaugenklinik: Erfahrungen mit „FIDUS“ in der Klinik für Augenheilkunde am Universitätsklinikum des Saarlandes UKS. *Ophthalmologie* 115(10):868–877
12. Kortüm K, Kern C, Meyer G, Priglinger S, Hirneiß C (2017) Rahmenbedingungen zur Sammlung von „Real-Life“-Daten am Beispiel der Augenklinik der Universität München. *Klin Monbl Augenheilkd* 234(12):1477–1482
13. Bommakanti NK, Zhou Y, Ehrlich JR, Elam AR, John D, Kamat SS et al (2020) Application of the sight outcomes research collaborative ophthalmology data repository for triaging patients with glaucoma and clinic appointments during pandemics such as COVID-19. *Jama Ophthalmol* 138(9):974–980
14. Schmidt-Erfurth U, Sadeghipour A, Gerendas B, Waldstein S, Bogunović H (2018) Artificial intelligence in retina. *Prog Retin Eye Res* 67:1–29
15. Treder M, Eter N (2018) „Deep Learning“ und neuronale Netzwerke in der Augenheilkunde. *Ophthalmologie* 115(9):714–721
16. Treder M, Diener R, Eter N (2020) Künstliche Intelligenz zum Management von Makulaödemen. *Ophthalmologie* 117(10):989–992
17. Varma R, Steinmann WC, Scott IU (1992) Expert agreement in evaluating the optic disc for glaucoma. *Ophthalmology* 99(2):215–221
18. Gao J, Jiang Y, Zhang H, Wang F (2020) Joint disc and cup segmentation based on recurrent fully convolutional network. *PLoS ONE* 15(9):e238983
19. Zhao R, Chen X, Liu X, Chen Z, Guo F, Li S (2020) Direct cup-to-disc ratio estimation for glaucoma screening via semi-supervised learning. *IEEE J Biomed Health Inform* 24(4):1104–1113
20. Mansberger SL, Menda SA, Fortune BA, Gardiner SK, Demirel S (2017) Automated segmentation errors when using optical coherence tomography to measure retinal nerve fiber layer thickness in glaucoma. *Am J Ophthalmol* 174:1–8
21. Mariottoni EB, Jammal AA, Urata CN, Berchuck SI, Thompson AC, Estrela T et al (2020) Quantification of retinal nerve fibre layer thickness on optical coherence tomography with a deep learning segmentation-free approach. *Sci Rep* 10(1):402
22. Thompson AC, Jammal AA, Berchuck SI, Mariottoni EB, Medeiros FA (2020) Assessment of a segmentation-free deep learning algorithm for diagnosing glaucoma from optical coherence tomography scans. *Jama Ophthalmol* 138(4):333–339
23. Devalla SK, Chin KS, Mari JM, Tun TA, Strouthidis NG, Aung T et al (2018) A deep learning approach to digitally stain optical coherence tomography images of the optic nerve head. *Invest Ophthalmol Vis Sci* 59(1):63–74
24. Liu Y, Simavli H, Que CJ, Rizzo JL, Tsikata E, Maurer R et al (2015) Patient characteristics associated with artifacts in spectralis optical coherence tomography imaging of the retinal nerve fiber layer in glaucoma. *Am J Ophthalmol* 159(3):565–576.e2
25. Devalla SK, Pham TH, Panda SK, Zhang L, Subramanian G, Swaminathan A et al (2020) Towards label-free 3D segmentation of optical coherence tomography images of the optic nerve head using deep learning. *Biomed Opt Express* 11(11):6356–6378
26. Moyer VA (2013) Screening for glaucoma: U.S. preventive services task force recommendation statement. *Ann Intern Med* 159(7):484–489
27. Muramatsu C, Hayashi Y, Sawada A, Hatanaka Y, Hara T, Yamamoto T et al (2010) Detection of retinal nerve fiber layer defects on retinal fundus images for early diagnosis of glaucoma. *J Biomed Opt* 15(1):16021
28. Li Z, He Y, Keel S, Meng W, Chang RT, He M (2018) Efficacy of a deep learning system for detecting glaucomatous optic neuropathy based on color fundus photographs. *Ophthalmology* 125(8):1199–1206
29. Phene S, Dunn RC, Hammel N, Liu Y, Krause J, Kitade N et al (2019) Deep learning and glaucoma specialists: the relative importance of optic disc features to predict glaucoma referral in fundus photographs. *Ophthalmology* 126(12):1627–1639

30. Medeiros FA, Jammal AA, Thompson AC (2019) From machine to machine: an OCT-trained deep learning algorithm for objective quantification of glaucomatous damage in fundus photographs. *Ophthalmology* 126(4):513–521
31. Jammal AA, Thompson AC, Mariotoni EB, Berchuck SI, Urata CN, Estrela T et al (2020) Human versus machine: comparing a deep learning algorithm to human gradings for detecting glaucoma on Fundus photographs. *Am J Ophthalmol* 211:123–131
32. Thompson AC, Jammal AA, Medeiros FA (2019) A deep learning algorithm to quantify neuroretinal rim loss from optic disc photographs. *Am J Ophthalmol* 201:9–18
33. Christopher M, Bowd C, Belghith A, Goldbaum MH, Weinreb RN, Fazio MA et al (2020) Deep learning approaches predict glaucomatous visual field damage from OCT optic nerve head en face images and retinal nerve fiber layer thickness maps. *Ophthalmology* 127(3):346–356
34. Mariotoni EB, Datta S, Dov D, Jammal AA, Berchuck SI, Tavares IM et al (2020) Artificial intelligence mapping of structure to function in glaucoma. *Transl Vis Sci Technol* 9(2):19
35. Yang HK, Kim YJ, Sung JY, Kim DH, Kim KG, Hwang JM (2020) Efficacy for differentiating nonglaucomatous versus glaucomatous optic neuropathy using deep learning systems. *Am J Ophthalmol* 216:140–146
36. Sachdeva V, Vasseneix C, Hage R, Bidot S, Clough LC, Wright DW et al (2018) Optic nerve head edema among patients presenting to the emergency department. *Neurology* 90(5):e373–e9
37. Biousse V, Bruce BB, Newman NJ (2018) Ophthalmoscopy in the 21st century: the 2017 H. Houston Merritt lecture. *Neurology* 90(4):167–175
38. Frisén L (1982) Swelling of the optic nerve head: a staging scheme. *J Neurol Neurosurg Psychiatry* 45(1):13–18
39. Echegaray S, Zamora G, Yu H, Luo W, Soliz P, Kardon R (2011) Automated analysis of optic nerve images for detection and staging of papilledema. *Invest Ophthalmol Vis Sci* 52(10):7470–7478
40. Akbar S, Akram MU, Sharif M, Tariq A, Yasin UU (2017) Decision support system for detection of papilledema through fundus retinal images. *J Med Syst* 41(4):66
41. Fatima KN, Hassan T, Akram MU, Akhtar M, Butt WH (2017) Fully automated diagnosis of papilledema through robust extraction of vascular patterns and ocular pathology from fundus photographs. *Biomed Opt Express* 8(2):1005–1024
42. Ahn JM, Kim S, Ahn KS, Cho SH, Kim US (2019) Accuracy of machine learning for differentiation between optic neuropathies and pseudopapilledema. *BMC Ophthalmol* 19(1):178
43. Milea D, Najjar RP, Zhuho J, Ting D, Vasseneix C, Xu X et al (2020) Artificial intelligence to detect papilledema from ocular fundus photographs. *N Engl J Med* 382(18):1687–1695
44. De Fauw J, Ledsam JR, Romera-Paredes B, Nikolov S, Tomasev N, Blackwell S et al (2018) Clinically applicable deep learning for diagnosis and referral in retinal disease. *Nat Med* 24(9):1342–1350

Andrew G. Lee, Alexandra J. Sinclair, Ama Sadaka, Shauna Berry, Susan P. Mollan (Eds.)
Neuro-Ophthalmology
 Global Trends in Diagnosis, Treatment and Management

Cham: Springer Nature Switzerland AG 2019, 1. Auflage, 215 S., 43 Abb., (ISBN: 978-3-319-98454-4), 149,79 EUR



Ziel der Herausgebenden dieses Buches war es, ausgesuchte und aktuell wichtige Themen der Neuroophthalmologie zu diskutieren, gleichzeitig aber auch die Sicht auf geographische Unterschiede in Krankheitsbildern, diagnostischem Vorgehen und Therapieerfahrungen zu ermöglichen. Die sechs Herausgebenden, Andrew G. Lee (Houston, TX, USA), Alexandra J. Sinclair (Birmingham, UK), Ama Sadaka (Houston, TX, USA), Shauna Berry (Houston, TX, USA) und Susan P. Mollan (Birmingham, UK) konnten weitere 31 Autor*innen hinzu gewinnen. Die Mehrzahl der Beiträge hat ihren Ursprung in Nordamerika, aber auch Autor*innen aus Großbritannien, der Schweiz, Israel, Singapur und Australien sind vertreten.

Auf 215 Seiten werden folgende Themenbereiche behandelt: Die Vielfalt der Neuritis nervi optici einschließlich der Neuromyelitis optica, die nichtentzündliche AION, die Riesenzell-Arteriitis, Neuro-Bildgebung bei Augenmuskelparesen, Behandlung der idiopathischen intrakraniellen Hypertension, die Therapie des Zentralarterienverschlusses, pharmakologische Pupillendiagnostik, Bildgebung beim Horner-Syndrom, traumatische Optikus-Neuropathie, Work up for Optic Atrophy und die Behandlung der Leberschen hereditären Optikus-Neuropathie.

Als Beispiel für das didaktische Konzept dieses Buches sei das Kapitel 2 „Optic Neuritis as the Presenting Feature of Neuromyelitis Optica (NMO): Diagnosis and Management“ gewählt: Auf einen kurzgefassten Fallreport

folgen die Sicht auf die Historie der Erkrankung, die Epidemiologie, Symptome und Untersuchung, zusätzliche Tests, Kontroversen zur Testung auf AQP4-Antikörper, Differenzialdiagnose der NMO-ON, diagnostische Kriterien, die für eine NMO sprechen, die Behandlung der NMO, und als Abschluss wird zu einer global gestellten Frage kontrovers Stellung bezogen: „Global Perspective: Should All Refractory Optic Neuritis Be Treated with a Combination of Intravenous Steroids and Plasmapheresis?“

Fazit: Diese Publikation, die sich ausgewählten Themen der Neuro-Ophthalmologie von international unterschiedlichen Sichtweisen aus widmet und diese dann diskutiert, ließe sich als „Neuro-Ophthalmology globally sophisticated“ bezeichnen und ist somit als Ergänzung zu einem klassisch strukturierten Lehrbuch der Neuroophthalmologie zu verstehen.

Dr. Udo Hennighausen
Augenarzt, Anerkennung Geriatrie
Jürgen-Töpfer-Straße 10
22763 Hamburg
E-Mail: Udo.Hennighausen@web.de