

Le dossier – IA et segment antérieur

Place de l'IA au sein des outils de détection du kératocône

RÉSUMÉ: Le dépistage du kératocône est principalement basé sur l'analyse des topographies cornéennes. Il existe pourtant une grande variabilité inter- et intra-opérateur dans l'évaluation subjective de ces examens. De ce fait, des tests objectifs de dépistage du kératocône et du kératocône infraclinique ont été développés afin d'aider le praticien à mieux identifier les formes de cette pathologie les moins "évidentes" à l'œil nu. L'augmentation de la puissance de calculs des ordinateurs, la disponibilité d'une quantité importante de données (*big data*) et le développement exponentiel de l'apprentissage profond (*deep learning*) permet à l'IA de jouer un rôle prépondérant dans la détection automatisée du kératocône.



A. SAAD
Hôpital Fondation Rothschild,
Centre Médical Argentine, PARIS.

Le dépistage du kératocône (KC) ainsi que l'évaluation de son évolution sont principalement basés sur l'analyse d'examens paracliniques complémentaires. C'est un enjeu majeur car une détection précoce permet de sensibiliser le patient et sa famille sur les facteurs de risques environnementaux d'évolution de KC, notamment les frottements oculaires [1], et parce qu'un kératocône infraclinique (FFKC) constitue une contre-indication formelle au Lasik, sous peine de précipiter l'aggravation de l'état cornéen [2].

De nombreux travaux ont montré la variabilité inter- et intra-opérateur dans l'analyse des topographies et tomographies cornéennes, un même examen pouvant être classé comme normal ou suspect par deux experts différents et même par le même expert à deux moments espacés dans le temps [3]. De ce fait, des tests objectifs de dépistage du KC et du FFKC ont été développés afin d'aider le praticien à mieux identifier les formes de cette pathologie les moins "évidentes" à l'œil nu. Ces tests, développés par les pionniers en la matière Rabinowitz, Klyce ou Ambrosio, regroupaient des éléments quantitatifs

de la topographie (face antérieure) ou de la tomographie (face antérieure et postérieure) de la cornée afin de simplifier et de rendre plus objective la tâche du praticien [4-6].

IA et algorithmes utilisés dans la détection du kératocône

L'intelligence artificielle (IA) est, par définition, "l'ensemble des théories et des techniques mises en œuvre en vue de réaliser des machines capables de simuler l'intelligence humaine". Cette description est assez large et imprécise, et caractérise l'étendue des domaines impliqués dans l'IA. Cette dernière correspond donc à un ensemble de concepts et de technologies plus qu'à une discipline autonome constituée [7]. L'apprentissage automatique (en anglais *machine learning*) ou apprentissage statistique est un champ d'étude de l'intelligence artificielle qui se fonde sur des approches mathématiques et statistiques pour donner aux ordinateurs la possibilité d'"apprendre" à partir de données, c'est-à-dire d'améliorer leurs performances à résoudre des tâches sans être explicitement programmés pour chacune [8].

I Le dossier – IA et segment antérieur

L'apprentissage automatique comporte la plupart du temps deux étapes. La première consiste à estimer un modèle à partir de données, appelées observations, qui sont disponibles et en nombre fini, lors de la phase de création du système. Dans le cadre de la détection du KC, l'objectif du modèle consiste à reconnaître la présence du KC dans un set de données. La seconde phase correspond à l'évaluation du modèle sur un set vierge n'ayant pas servi à sa conception : de nouvelles données sont soumises (données de topographie et tomographie cornéenne) afin d'obtenir le résultat correspondant à la tâche souhaitée (cornée normale ou pathologique). En pratique, certains systèmes peuvent poursuivre leur apprentissage une fois en production, pour peu qu'ils aient un moyen d'obtenir un retour sur la justesse des résultats produits. C'est à ce moment-là que l'utilisation sémantique "d'intelligence" artificielle est réelle, dans le sens que le programme s'améliore de lui-même, similairement à l'intelligence humaine.

La plupart des algorithmes d'IA utilisés dans la détection du KC sont qualifiés d'apprentissage supervisé, c'est-à-dire que les données sont étiquetées : la réponse à la tâche est connue pour ces données. Les principaux algorithmes d'apprentissage automatique supervisé utilisés pour la détection du kératocône sont les suivants :

>>> Les machines à vecteurs de support (SVM)

Cette méthode permet de traiter des problèmes de discrimination non linéaire et de reformuler le problème de classement comme un problème d'optimisation quadratique. L'idée clé est la notion de marge maximale qui représente la distance entre la frontière de séparation et les échantillons les plus proches. Ces derniers sont appelés vecteurs de support. Dans les SVM, la frontière de séparation est choisie comme celle qui maximise la marge [9].

>>> Les réseaux de neurones

Ce système (variante de l'apprentissage profond ou *deep learning*) est à l'origine schématiquement inspiré du fonctionnement des neurones biologiques et s'est rapproché par la suite des méthodes statistiques. Les réseaux de neurones sont généralement optimisés par des méthodes d'apprentissage de type probabiliste. Contrairement à d'autres types d'algorithmes, les réseaux de neurones ne peuvent pas être programmés directement pour effectuer une tâche. À la manière du cerveau en développement d'un enfant, la seule instruction qu'ils ont est d'apprendre.

On distingue trois méthodes d'apprentissage distinctes. Dans le cas de l'apprentissage supervisé, l'algorithme s'entraîne sur un ensemble de données étiquetées et se modifie jusqu'à être capable de traiter le *dataset* afin d'obtenir le résultat souhaité. Dans le cas de l'apprentissage non supervisé, les données ne sont pas étiquetées, le réseau de neurones analyse l'ensemble de données et tente de les classer. Dans le cas de l'apprentissage renforcé, le réseau de neurones est renforcé pour les résultats positifs et sanctionné pour les résultats négatifs. C'est ce qui lui permet d'apprendre au fil du temps, de la même manière qu'un humain apprend progressivement de ses erreurs [8].

>>> La méthode des k plus proches voisins

Dans cette méthode, on dispose d'une base de données d'apprentissage constituée de N couples "entrée-sortie". Pour estimer la sortie associée à une nouvelle entrée x, la méthode des k plus proches voisins consiste à prendre en compte (de façon identique) les k échantillons d'apprentissage dont l'entrée est la plus proche de la nouvelle entrée x, selon une distance à définir. Puisque cet algorithme est basé sur la distance, la normalisation peut améliorer sa précision.

>>> Les arbres de décision

Un arbre de décision est un outil d'aide à la décision représentant un ensemble de choix sous la forme graphique d'un arbre. Les différentes décisions possibles sont situées aux extrémités des branches (les "feuilles" de l'arbre) et sont atteintes en fonction de décisions prises à chaque étape.

>>> L'analyse discriminante linéaire

L'analyse discriminante linéaire fait partie des techniques d'analyse discriminante prédictive. Il s'agit d'expliquer et de prédire l'appartenance d'un individu à une classe (groupe) prédéfinie à partir de ses caractéristiques mesurées à l'aide de variables prédictives. Ici, prédire l'appartenance d'une cornée à un groupe de KC ou de cornées normales à partir des caractéristiques topographiques et tomographiques.

Évolution des études utilisant l'IA pour la détection du kératocône

Les principales études ayant utilisé l'IA pour la détection du kératocône, du kératocône suspect (présentant des anomalies mineures topographiques) et du kératocône fruste (aspect normal à la topographie mais présentant un kératocône évident à l'œil controlatéral) sont présentées dans le *tableau I*.

Ces nombreux travaux montrent bien que l'utilisation de l'IA dans la détection du kératocône date des années 1990 et permettait, en utilisant des indices numériques descriptifs des topographies cornéennes, une précision tout à fait acceptable dans la classification des kératocônes [4, 5, 10, 11]. Il est cependant impossible de comparer ces différentes études, réalisées à des époques différentes, avec des moyens différents et des "standards" de diagnostic du kératocône distincts. L'objectif à l'époque était de diagnostiquer un kératocône.

I Le dossier – IA et segment antérieur

Auteur Année Journal	Topographe Données N inclus	Algorithme d'IA	Résultats
Maeda [10] 1994 IOVS	TMS-1 8 indices 200 topographies	Analyse discriminante Arbre décisionnel	KC vs autres Sensibilité : 89 % Spécificité : 99 %
Maeda [5] 1995 IOVS	TMS-1 11 indices 200 topographies	Réseau de neurones	Précision : 80 %
Smolek [11] 1997 IOVS	TMS-1 10 indices 300 topographies	Réseau de neurones	Précision : 100 %
Accardo [12] 2002 JBI	EyeSys 10 indices 396 topographies	Réseau de neurones	KC débutant vs N Sensibilité : 94,1 % Spécificité : 97,6 %
Souza [13] 2010 Clinics	Orbscan II 11 indices 318 topographies	SVM et réseau de neurones	N vs KC AUROC : 0,99 Sensibilité : 100 %
Saad [14] 2010 IOVS	Orbscan II 51 indices 143 topographies	Analyse discriminante	N vs FFKC Sensibilité : 93 % Spécificité : 92 %
Saad [15] 2012 IOVS	OPD Scan Zernike coeff 143 topographies	Analyse discriminante	N vs FFKC AUROC : 0,98
Smadja [16] 2013 AJO	Galilei 55 indices 372 topographies	Arbre décisionnel	N vs FFKC Sensibilité : 93,6 % Spécificité : 97,2 %
Silverman [17] 2014 IOVS	Artemis-1 Cartes épithéliales et pachymétriques 204	Réseau de neurones Analyse discriminante	N vs KC Sensibilité : 98,9 % Spécificité : 99,5 %
Hidalgo [18] 2016 Cornea	Pentacam 22 indices 860 topographies	SVM	N vs FFKC Sensibilité : 79,1 % Spécificité : 97,9 %
Kovacs [19] 2016 JCRS	Pentacam 135 topographies	Réseau de neurones	N vs FFKC Sensibilité : 90 % Spécificité : 90 %
Lopes [20] 2018 AJO	Pentacam 3 693 topographies	Réseau de neurones SVM Analyse discriminante	N vs FFKC Sensibilité : 85,2 % Spécificité : 96,6 %
Yousefi [21] 2018 Plos	Casia OCT 3 156	Apprentissage non supervisé	N vs KC Sensibilité : 97,7 % Spécificité : 94,1 %
Ke Cao [22] 2020 TVST	Pentacam 11 indices 89 topographies	Random Forest Arbres décisionnels Régression logistique SVM Analyse discriminante Méthodes des k	N vs KCS Sensibilité : 94 % Spécificité : 90 %
Kamiya [23] 2019 BMJ	Casia SS-1000 Analyse d'image 543	Réseau de neurones convolutif (analyse des images)	N vs KC Sensibilité : 100 % Spécificité : 98,4 %

Tableau I : Principales études ayant utilisé l'IA pour la détection du kératocône.

Auteur Année Journal	Topographe Données N inclus	Algorithme d'IA	Résultats
Bo-I Kuo [24] 2020 TVST	TMS-4 Analyse d'image 354 topographies	Réseau de neurones convolutif (analyse des images)	N vs KC Sensibilité : 94,4 % Spécificité : 97,2 %
Abdelmotaal [25] 2020 TVST	Pentacam Analyse d'image 3 218 images	Réseau de neurones convolutif (analyse des images)	N vs KC Sensibilité : 95 % Spécificité : 100 %
Yie Xie [26] 2020 JAMA	Pentacam Analyse d'image 6 465 images	Réseau de neurones convolutif (analyse des images)	N vs KC Sensibilité : 97,8 % Spécificité : 99,2 %
Zeboulon [27] 2020 AJO	Orbscan Raw data 3 000 topographies	Réseau de neurones convolutif (analyse des données brutes)	N vs KC Sensibilité : 100 % Spécificité : 99 %
Zeboulon [28] 2020 Scientific Reports	Orbscan Raw data 13 705	Apprentissage non supervisé - <i>clustering</i>	N vs KC Sensibilité : 81 % Spécificité : 100 %
Hosni Mahmoud [29] 2021 Sensors	Casia OCT photos de face et de profil	Construction d'images 3D à partir de photos 2D Réseau de neurones	N vs KC Sensibilité : 98,45 % Spécificité : 96 %

Tableau I : Principales études ayant utilisé l'IA pour la détection du kératocône (suite).

Avec l'apparition des premiers cas d'ectasie post-Lasik, il est devenu de plus en plus important de détecter les formes précoces de KC afin de contre-indiquer une chirurgie photoablatrice par Lasik [2]. Les études des années 2000 se sont attelées à cette tâche (détection des FFKC) avec des résultats probants, en utilisant différents algorithmes d'IA [3, 6, 12-19].

L'augmentation de la puissance de calculs des ordinateurs, la disponibilité d'une quantité importante de données (*big data*) et le développement exponentiel de l'apprentissage profond a récemment permis l'utilisation des réseaux de neurones convolutifs pour l'analyse des données topographiques brutes (*raw data*) et même l'analyse des images topographiques avec des résultats très précis [22, 24-29]. Au vu de ces résultats, il ne fait nul doute que l'IA va continuer à jouer un rôle de plus en plus important dans l'amélioration de nos outils diagnostiques et plus précisément dans la détection des FFKC. La constitution d'une base de données importante (*big data*) et "propre" d'un groupe de

FFKC reste sans doute la seule limitation actuelle à la détection précise de ces cornées par l'analyse d'image. Ce sera sûrement chose faite d'ici quelques années.

BIBLIOGRAPHIE

- MAZHARIAN A, PANTHIER C, COURTIN R *et al*. Incorrect sleeping position and eye rubbing in patients with unilateral or highly asymmetric keratoconus: a case-control study. *Graefes Arch Clin Exp Ophthalmol*, 2020;258:2431-2439.
- SEILER T, QUURKE AW. Iatrogenic keratectasia after LASIK in a case of forme fruste keratoconus. *J Cataract Refract Surg*, 1998;24:1007-1009.
- RAMOS IC, CORREA R, GUERRA FP *et al*. Variability of subjective classifications of corneal topography maps from LASIK candidates. *J Refract Surg*, 2013;29:770-775.
- RABINOWITZ YS, RASHEED K, YANG H *et al*. Accuracy of ultrasonic pachymetry and videokeratography in detecting keratoconus. *J Cataract Refract Surg*, 1998;24:196-201.
- MAEDA N, KLYCE SD, SMOLEK MK. Comparison of methods for detecting keratoconus using videokeratography. *Arch Ophthalmol*, 1995;113:870-874.
- AMBROSIO R JR, ALONZO RS, LUZ A *et al*. Corneal-thickness spatial profile and corneal-volume distribution: tomographic indices to detect keratoconus. *J Cataract Refract Surg*, 2006;32:1851-1859.
- BENET D, PELLICER-VALERO OJ. Artificial Intelligence: the unstoppable revolution in ophthalmology. *Surv Ophthalmol*, 2021 [online ahead of print].
- BALYEN L, PETO T. Promising artificial intelligence-machine learning-deep learning algorithms in ophthalmology. *Asia Pac J Ophthalmol*, 2019;8:264-272.
- KARASUYAMA M, TAKEUCHI I. Nonlinear regularization path for quadratic loss support vector machines. *IEEE Trans Neural Netw*, 2011;22:1613-1625.
- MAEDA N, KLYCE SD, SMOLEK MK *et al*. Automated keratoconus screening with corneal topography analysis. *Invest Ophthalmol Vis Sci*, 1994;35:2749-2757.
- SMOLEK MK, KLYCE SD. Current keratoconus detection methods compared with a neural network approach. *Invest Ophthalmol Vis Sci*, 1997;38:2290-2299.
- ACCARDO PA, PENSIERO S. Neural network-based system for early keratoconus detection from corneal topography. *J Biomed Inform*, 2002;35:151-159.
- SOUZA MB, MEDEIROS FW, SOUZA DB *et al*. Evaluation of machine learning classifiers in keratoconus detection from orbscan II examinations. *Clinics*, 2010;65:1223-1228.

I Le dossier – IA et segment antérieur

14. SAAD A, GATINEL D. Topographic and tomographic properties of forme fruste keratoconus corneas. *Invest Ophthalmol Vis Sci*, 2010;51:5546-5555.
15. SAAD A, GATINEL D. Evaluation of total and corneal wavefront high order aberrations for the detection of forme fruste keratoconus. *Invest Ophthalmol Vis Sci*, 2012;53:2978-2992.
16. SMADJA D, TOUBOUL D, COHEN A *et al*. Detection of subclinical keratoconus using an automated decision tree classification. *Am J Ophthalmol*, 2013;156:237-246 e1.
17. SILVERMAN RH, URS R, ROYCHOUHDURY A *et al*. Epithelial remodeling as basis for machine-based identification of keratoconus. *Invest Ophthalmol Vis Sci*, 2014;55:1580-1587.
18. RUIZ HIDALGO I, ROZEMA JJ, SAAD A *et al*. Validation of an objective keratoconus detection system implemented in a Scheimpflug tomographer and comparison with other methods. *Cornea*, 2017;36:689-695.
19. KOVACS I, MIHALTZ K, KRANITZ K *et al*. Accuracy of machine learning classifiers using bilateral data from a Scheimpflug camera for identifying eyes with preclinical signs of keratoconus. *J Cataract Refract Surg*, 2016;42:275-283.
20. LOPES BT, RAMOS IC, SALOMAO MQ *et al*. Enhanced tomographic assessment to detect corneal ectasia based on artificial intelligence. *Am J Ophthalmol*, 2018;195:223-232.
21. YOUSEFI S, YOUSEFI E, TAKAHASHI H *et al*. Keratoconus severity identification using unsupervised machine learning. *PLoS One*, 2018;13:e0205998.
22. CAO K, VERSPOOR K, SAHEBJADA S *et al*. Evaluating the performance of various machine learning algorithms to detect subclinical keratoconus. *Transl Vis Sci Technol*, 2020;9:24.
23. KAMIYA K, AYATSUKA Y, KATO Y *et al*. Keratoconus detection using *deep learning* of colour-coded maps with anterior segment optical coherence tomography: a diagnostic accuracy study. *BMJ Open*, 2019;9:e031313.
24. KUO BI, CHANG WY, LIAO TS *et al*. Keratoconus screening based on *deep learning* approach of corneal topography. *Transl Vis Sci Technol*, 2020;9:53.
25. ABDELMOTAALH, MOSTAFAMM, MOSTAFANR *et al*. Classification of color-coded Scheimpflug camera corneal tomography images using deep learning. *Transl Vis Sci Technol*, 2020;9:30.
26. XIE Y, ZHAO L, YANG X *et al*. Screening candidates for refractive surgery with corneal tomographic-based deep learning. *JAMA Ophthalmol*, 2020;138:519-526.
27. ZÉBOULON P, DEBELLEMANIÈRE G, BOUVET M *et al*. Corneal topography raw data classification using a convolutional neural network. *Am J Ophthalmol*, 2020;219:33-39.
28. ZÉBOULON P, DEBELLEMANIÈRE G, GATINEL D. Unsupervised learning for large-scale corneal topography clustering. *Sci Rep*, 2020;10:16973.
29. MAHMOUD HAH, MENGASH HA. Automated keratoconus detection by 3D corneal images reconstruction. *Sensors*, 2021;21:2326.

L'auteur a déclaré ne pas avoir de conflits d'intérêts concernant les données publiées dans cet article.