

DOI: <https://doi.org/10.17816/DD624022>



Machine-learning and artificial neural network technologies in the classification of postkeratotomy corneal deformity

Ekaterina K. Tsyrenzhapova¹, Olga I. Rozanova¹, Tatiana N. Iureva^{1,2,3}, Andrey A. Ivanov¹, Ivan S. Rozanov⁴

¹ The S. Fyodorov Eye Microsurgery Federal State Institution, Irkutsk, Russia;

² Irkutsk State Medical University, Irkutsk, Russia;

³ Russian Medical Academy of Continuous Professional Education, Irkutsk, Russia;

⁴ LLC Transneft Technology, Irkutsk, Russia

ABSTRACT

BACKGROUND: A thorough analysis of both optical and anatomical properties of the cornea in patients after anterior radial keratotomy is important in choosing the optical power of an intraocular lens in the surgical treatment of cataracts and other types of optical correction. Improving the classification of postkeratotomy corneal deformity is crucial in modern ophthalmology due to its diverse clinical presentation.

AIM: To develop an automated classification system for postkeratotomy corneal deformity using machine learning and artificial neural networks based on the analysis of topographic maps of the cornea.

MATERIALS AND METHODS: Depersonalized data from medical records of 250 patients aged 46–76 (mean, 59.63±5.95) years were analyzed. Moreover, 500 topographic maps of the anterior and posterior surfaces of the cornea were analyzed, and three stages of machine learning for postkeratotomy corneal deformity classification were performed.

RESULTS: Stage I, which involved topography analysis of the anterior and posterior surfaces of the cornea, allowed for the measurement of anterior and posterior corneal elevation in three ring-shaped zones. At stage II, a direct distribution neural network was selected and created during deep machine learning. Eight auxiliary parameters describing the shape of the anterior and posterior surfaces of the cornea were established. In Stage III, classification algorithms for postkeratotomy corneal deformity were developed based on the test-to-training sample ratio, which ranged from 75% to 91%.

CONCLUSION: The proposed artificial neural network classifies of postkeratotomy corneal deformity types with an accuracy of 91%. The potential for further improving the training quality of this artificial neural network has been established. Neural network algorithms can become a useful tool for the automatic classification of postkeratotomy corneal deformity in patients after radial keratotomy.

Keywords: anterior radial keratotomy; artificial intelligence; machine learning; corneal topography.

To cite this article:

Tsyrenzhapova EK, Rozanova OI, Iureva TN, Ivanov AA, Rozanov IS. Machine-learning and artificial neural network technologies in the classification of postkeratotomy corneal deformity. *Digital Diagnostics*. 2024;5(1):64–74. DOI: <https://doi.org/10.17816/DD624022>

Submitted: 29.11.2023

Accepted: 14.02.2024

Published online: 11.03.2024

DOI: <https://doi.org/10.17816/DD624022>

Технологии машинного обучения и искусственной нейронной сети в классификации посткератотомической деформации роговицы

Е.К. Цыренжапова¹, О.И. Розанова¹, Т.Н. Юрьева^{1, 2, 3}, А.А. Иванов¹, И.С. Розанов⁴

¹ Национальный медицинский исследовательский центр «Межотраслевой научно-технический комплекс «Микрохирургия глаза» имени академика С.Н. Фёдорова», Иркутск, Россия;

² Иркутский государственный медицинский университет, Иркутск, Россия;

³ Российская медицинская академия непрерывного профессионального образования, Иркутск, Россия;

⁴ ООО «Транснефть-Технологии», Иркутск, Россия

АННОТАЦИЯ

Обоснование. Тщательный анализ как оптических, так и анатомических свойств роговицы у пациентов после перенесённой передней радиальной кератотомии приобретает особое значение в выборе оптической силы интраокулярной линзы при хирургическом лечении катаракты и других видах оптической коррекции. Вариабельность клинической картины посткератотомической деформации определяет необходимость разработки её классификации и является важной задачей современной офтальмологии.

Цель — разработать автоматизированную систему классификации посткератотомической деформации роговицы с использованием машинного обучения и искусственной нейронной сети на основе анализа численных значений топографических карт роговицы.

Материалы и методы. В качестве материала использовались обезличенные результаты анализа медицинской документации 250 пациентов в возрасте от 46 до 76 лет (средний возраст — 59,63±5,95 года). Проведён анализ 500 карт рельеф-топографии передней и задней поверхностей роговицы и 3 этапа машинного обучения классификации посткератотомической деформации.

Результаты. I этап — анализ рельеф-топографии передней и задней поверхностей роговицы — позволил зафиксировать численные значения элевации передней и задней поверхности роговицы в трёх кольцевидных зонах. На II этапе в ходе глубокого машинного обучения была выбрана и создана нейросеть прямого распространения. Установлены 8 вспомогательных параметров, описывающих форму передней и задней поверхностей роговицы. III этап сопровождался получением алгоритмов классификации посткератотомической деформации роговицы в зависимости от соотношения тестовой и обучающей выборок, которое варьировало от 75 до 91%.

Заключение. Разработана искусственная нейронная сеть, успешно решающая задачу классификации типов посткератотомической деформации роговицы с точностью 91%. Установлен потенциал для дальнейшего улучшения качества обучения данной нейронной сети. Применение алгоритмов искусственной нейронной сети может стать полезным инструментом автоматической классификации посткератотомической деформации роговицы у пациентов, перенёвших ранее радиальную кератотомию.

Ключевые слова: передняя радиальная кератотомия; искусственный интеллект; машинное обучение; рельеф-топография роговицы.

Как цитировать:

Цыренжапова Е.К., Розанова О.И., Юрьева Т.Н., Иванов А.А., Розанов И.С. Технологии машинного обучения и искусственной нейронной сети в классификации посткератотомической деформации роговицы // Digital Diagnostics. 2024. Т. 5, № 1. С. 64–74. DOI: <https://doi.org/10.17816/DD624022>

DOI: <https://doi.org/10.17816/DD624022>

机器学习和人工神经网络技术在角膜切开术后角膜畸形分类中的应用

Ekaterina K. Tsyrenzhapova¹, Olga I. Rozanova¹, Tatiana N. Iureva^{1, 2, 3}, Andrey A. Ivanov¹, Ivan S. Rozanov⁴

¹ The S. Fyodorov Eye Microsurgery Federal State Institution, Irkutsk, Russia;

² Irkutsk State Medical University, Irkutsk, Russia;

³ Russian Medical Academy of Continuous Professional Education, Irkutsk, Russia;

⁴ LLC Transneft Technology, Irkutsk, Russia

摘要

论证。 对前放射状角膜切开术后患者角膜的光学和解剖特性进行仔细分析。这对于选择用于白内障手术和其他类型光学矫正的眼内镜片的光学倍率具有特殊意义。角膜切开术后畸形临床表现的多变性决定了有必要对其进行分类，这也是现代眼科学的一项重要任务。

目的。 本研究旨在利用机器学习和人工神经网络开发角膜切开术后角膜畸形自动分类系统。该分类系统的开发基于对角膜图形数值的分析。

材料与方法。 以250名患者的匿名病历分析结果为材料。患者年龄在46至76岁之间（平均年龄为59.63±5.95岁）。对500张角膜前后表面的图形，对角膜切开术后畸形分类进行了3个阶段的机器学习。

结果。 第一阶段是分析角膜前后表面的图形。通过分析记录了角膜前后表面在三个环形区域的隆起数值。在第二阶段，通过深度机器学习选择并建立了一个前馈神经网络，确定了八个辅助参数。这些参数描述了角膜前后表面的形态。在第三阶段根据测试样本和训练样本的比例，获得了角膜切开术后角膜畸形的分类算法，该比例为75%至91%。

结论。 开发了一个人工神经网络。成功解决了角膜切开术后角膜畸形类型的分类问题，准确率高达91%。该神经网络的训练质量还有进一步提高的潜力。人工神经网络算法的应用可以成为对曾接受过放射状角膜切开术的患者进行角膜切开术后角膜畸形自动分类的有用工具。

关键词： 前放射状角膜切开术；人工智能；机器学习；角膜图形。

引用本文：

Tsyrenzhapova EK, Rozanova OI, Iureva TN, Ivanov AA, Rozanov IS. 机器学习和人工神经网络技术在角膜切开术后角膜畸形分类中的应用. *Digital Diagnostics*. 2024;5(1):64–74. DOI: <https://doi.org/10.17816/DD624022>

收到: 29.11.2023

接受: 14.02.2024

发布日期: 11.03.2024

论证

眼科疾病诊断中眼科检查范围的扩大大增加了保健负担,尤其是眼科诊所的负担。与此同时,深度机器学习和人工神经网络等技术可以使分析结果的过程自动化,提高病理检测的准确性和速度,并使医生活动中的决策过程自动化。在眼科疾病的诊断中,机器学习模型在眼底图像、晶状体混浊、青光眼时的视神经变化以及眼压测量数据的评估中体现得最为明显。此外,机器学习和人工智能还被广泛用作诊断角膜病变的方法。在角膜病理学研究中,圆锥角膜的诊断备受关注[1-6]。卷积神经网络(convolutional neural networks)尤其擅长模式识别和图像分类任务,这使得这些算法成为自动分析彩色编码Scheimpflug相机图像的合理选择[7]。V.A.Dos Santos等人开发并训练了用于角膜光学相干断层扫描图像分类的CorneaNet神经网络(奥地利)[8]。台湾科学家B.I.Kuo等人对角膜地形图结果进行了回顾性评估,从而开发出一种用于角膜病诊断的深度机器学习算法[9]。S.Shi等人的研究表明了,利用机器学习结合Scheimpflug相机图像和超分辨率光学相干断层扫描,在亚临床圆锥角膜和正常角膜的鉴别诊断中表现优异[10]。最近的几项研究表明了,卷积神经网络技术在角膜内皮图像分类算法中自动检测Fuchs内皮营养不良症的有效性[11]。

与此同时,以前接受过前放射状角膜切开术的老年性白内障和近视患者也在不断增加。值得注意的是,前放射状角膜切开术是首个大规模屈光手术,为世界上大量患者解决了近视矫正的重要问题。众所周知,前放射状角膜切开术的屈光效应是基于角膜中心区构造的改变而引起的角膜处光功率的变化,而角膜中心区构造的改变是由于在眼内压作用下,放射状定量切口部位角膜生物力学特性的局部减弱而引起的。在开发阶段前放射状角膜切开术应使两个角膜表面均匀变平,并保持角膜曲率半径的比例。然而,角膜畸形的特征受眼睛初始参数(角膜的生物力学特性、近视程度、眼压水平)、手术因素(切口的数量、深度和长度、手术质量)、再生过程和瘢痕的个体特征、手术时患者的年龄、患者的生活方式、衰老过程等的影响。这就是为什么在前放射状角膜切开术后的远期,角膜会发生明显的畸形变化,这在计划进行白内障手术并植入眼内镜片时尤为重要。

白内障患者的角膜曾接受过手术改造,如果术前对角膜光学特性的分析出现错误,可能会导致白内障手术后出现屈光不正和视力质量低下等致命后果。因此,对前放射状角膜切开术后患者的角膜地形图进行全面分析,制定角膜切开术后角膜畸形的分类标准,并创建自动分类系统,可以为白内障手术的个性化治疗奠定基础,并提高此类患者眼内镜片光学倍率计算的准确性。

目的

基于对角膜地形图数值的分析,利用机器学习和人工神经网络开发角膜切开术后角膜畸形自动分类系统。

材料和方法

本研究以2020-2023年期间去俄罗斯联邦卫生部联邦国家自治机构伊尔库茨克分部国立《S.N.Fedorov“眼显微外科学”跨部门科技联合体》医学研究中心的250名46至76岁(平均年龄为 59.63 ± 5.95)患者的匿名病历结果为分析材料。除了标准的眼科检查外,所有患者都在Pentacam HR设备(Oculus,德国)上接受了角膜地形图检查。作为角膜光学特性的特征,记录了38个角膜前后表面高度参数和12个反映角膜厚度、屈光力、散光值和非球面度的参数。研究分三个阶段进行。

第一阶段:分析角膜前后表面的地形图

数据集包括500张地形图(Pentacam 4 maps refractive显示屏)中角膜前后表面各19个数字高度值。高度数据记录在三个环形区域:中心区、旁中心区的4个点以及位于直径6mm圆线上的周边区的14个点。研究从位于90度的一个点开始,然后顺时针方向转动。角膜高度图上地形图点的位置示意图见图1。

第二阶段:深度学习机构和可视化

对以开发机构的训练和测试过程是在一台个人电脑上进行的,其软件和硬件如下:Windows 10操作系统、AMD Ryzen™ 7 2700E处理器、16GB RAM。

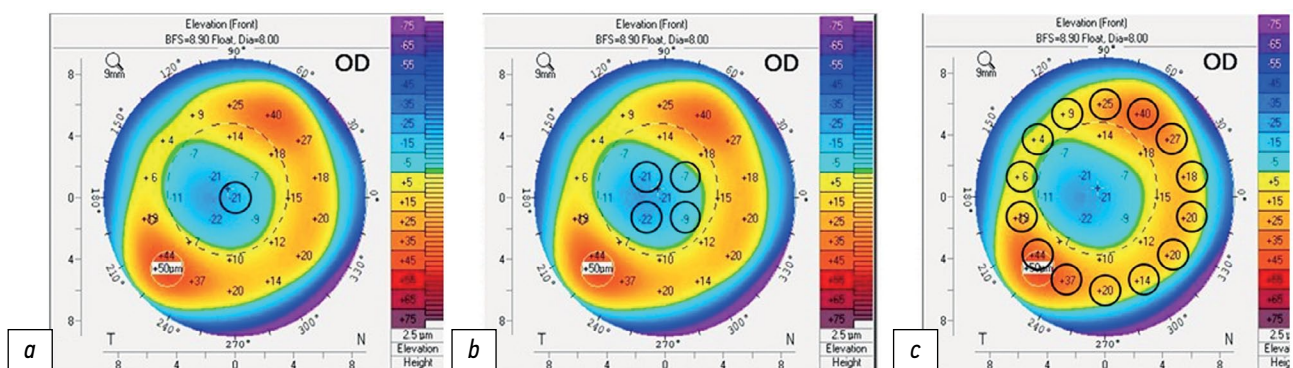


图1. 角膜表面的控制点: a——角膜中心; b——旁中心区; c——周边区,直径为6mm。

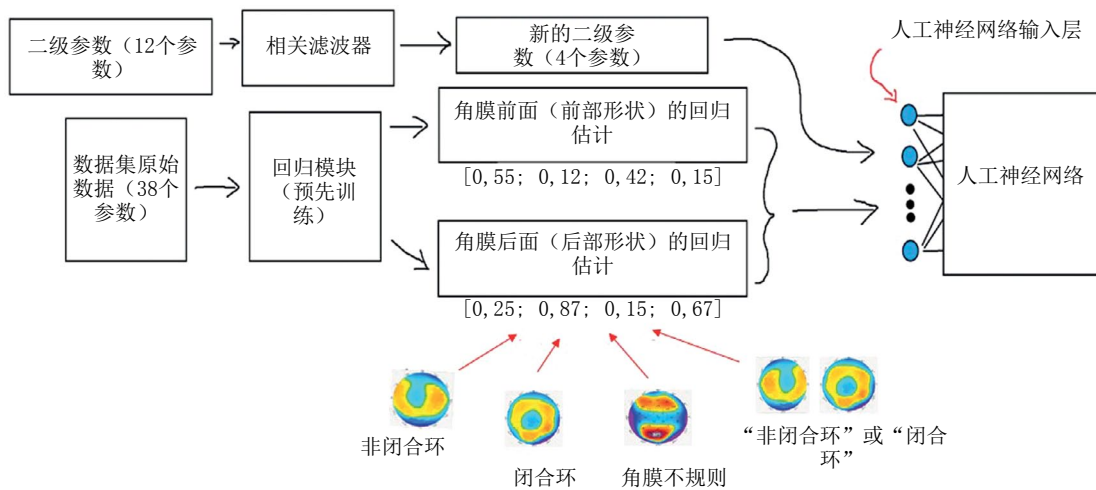


图2. 处理数据集的过程。

需要注意的是，图形处理器并未用于模型训练，所有必要的计算均在中央处理器上进行。编程时使用了带有Anaconda发行版的Python 3.10语言，特别是tf.keras 2.12.0库。在TensorFlow框架2.0版本中使用了Keras API规范实施。

数据集包含一个关键参数，即“类型”，用于描述患者角膜前后表面高度。根据地形图确定了角膜切开后角膜畸形的类型。根据角膜前后表面高度模式，共确定了6种类型（表1）[14]。

在这一阶段的工作中，对数据集进行了优化：使用相关性和回归分析对所有参数的性质进行了研究，并根据研究结果排除了低信息量特征（图2）。参数“类型”仅用于测试神经网络的训练情况，不作为输入参数使用。

第三阶段：创建神经网络

神经网络包含三个层：输入层、隐藏层和输出层：对于执行分类任务的神经网络来说，这个层数已经足够了。输入层神经元数 $M=12$ （参数），输出神经元数为6（类别）。隐藏层的神经元数量按公式 $M = \frac{2}{3} \times N + K$ 计算，其中 N 为输入神经元数量， K 为输出神经元数量。

本研究的任务是创建一个可与输入特征表配合使用的人工神经网络。人工神经网络的示意图见图3。

结果

在开发神经网络的过程中，我们创建了一个简单的控制界面，可通过测试样本对训练进行自动检查（图4）。该界面被用于配置和选择最佳训练Epoch数。后来，在创建了必要的模块后，繁琐的界面让位于更简约的控制台输出。这一过程加快了训练速度，降低了复杂性，提高了模型的准确性。

为了更客观地感知神经网络训练的效率，可以分批进行模型训练，并比较每个训练周期（每个Epoch）的平均指标。在对数据集进行优化以及在进行相关

性和回归分析后剔除不重要参数前后神经网络平均训练指标的依赖关系图见图5。结果发现了，在对数据集进行同质变量清理和回归估计分析后，训练过程明显加快。如果没有准备阶段，同样的过程需要更长的时间，但最终版本的算法也无法达到高精度和稳定的训练效果。

由此产生的原型神经网络并不总是能够识别畸形的类型，尽管在这个过程中，它们逐渐被训练得能够更有效地完成分类任务（图6）。

此外，还可以观察到第4和第5角膜切开后角膜畸形类型经常出现错误（见图6）。鉴于这些类别在所使用的数据集中最为罕见，这可能是类别不平衡问题的一种表现形式。尽管在训练的第200个Epoch时，类别之间的差异和类别定义的错误实际上已经消失，但在训练过程中发现错误的往往是第4和第5种类型。这可能是由于每个新的人工神经网络都是从神经元的随机初始状态开始训练的，但大多数误差往往分布在第4和第5种类型之间的总体趋势依然存在（图7）。

平均而言，在第200个训练Epoch时，最终迭代的人工神经网络显示了91%的正确答案（12个中有11个）。然而，测试样本的规模并不是很大，随着测试


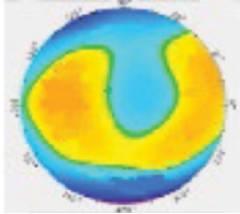
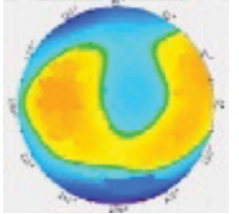
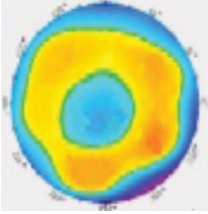
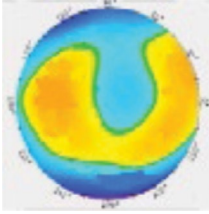
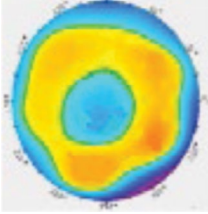
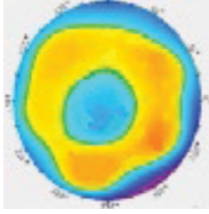
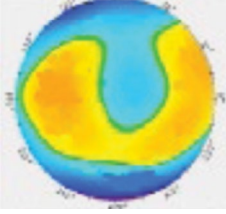
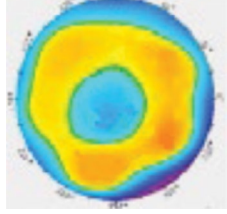
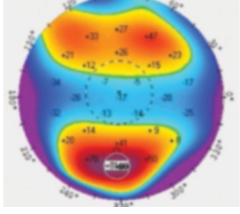
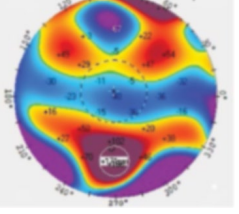
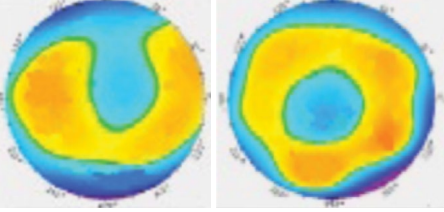
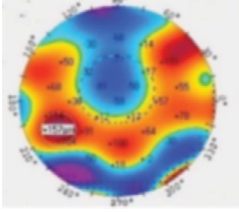


图3. 最后一次迭代的人工神经网络示意图。

表1. 取决于角膜前后表面高度模式的角膜切开术后角膜畸形分类类型

畸形类型	角膜前表面高度模式	角膜后表面高度模式
1	非闭合环* 	非闭合环* 
2	闭合环* 	非闭合环* 
3	闭合环* 	闭合环* 
4	非闭合环* 	闭合环* 
5	不规则 	不规则 
6	“非闭合环”或“闭合环” 	不规则, 出现明显的后表面高度位移 (大于80μm) 

*高度不超过80μm

```

31/31 [=====] - 0s 1ms/step - loss: 0.1250 - accuracy: 0.9542
Epoch 200/200
31/31 [=====] - 0s 1ms/step - loss: 0.1844 - accuracy: 0.9477
+++test+++
1/1 [=====] - 0s 126ms/step - loss: 0.5918 - accuracy: 0.9167
1/1 [=====] - 0s 46ms/step
++++predict n++
[[0.      0.8538249  0.14576246  0.      0.00000004  0.00041263
  0.      ]]
1

++++predict all++
1/1 [=====] - 0s 18ms/step
[112233425566]<--- 模型答案
[112233445566]<--- 正确答案
正确答案数: 11 /12

```

图4. 控制台程序的神经网络操作界面（神经网络的错误答案和其校正用红色标出）。

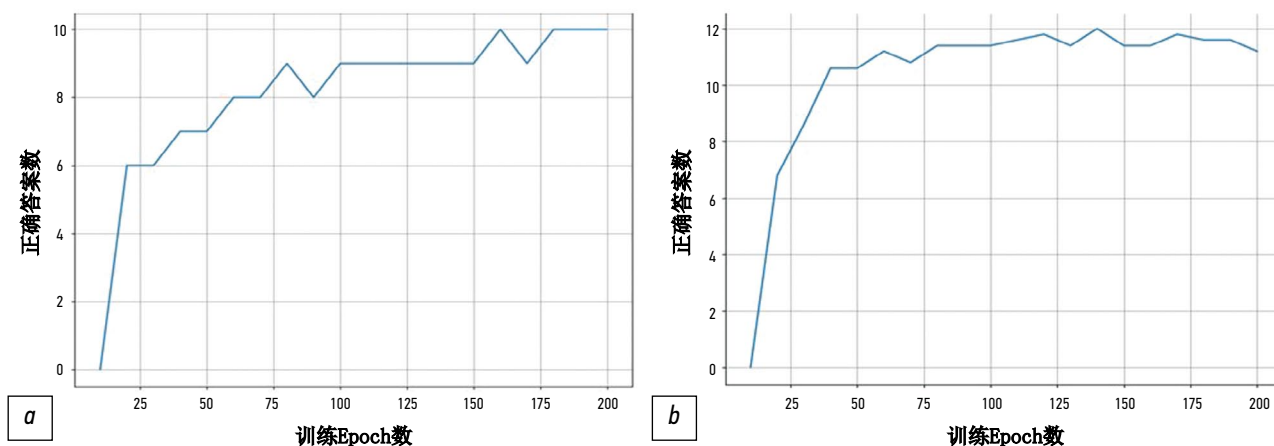


图5. 学习率与Epoch的关系图：a——优化前；b——优化后。

```

1/1 [=====] - 0s 49ms/step
[122333420126]<--- 模型答案
[112233445566]<--- 正确答案
正确答案数: 6 /12
1/1 [=====] - 0s 20ms/step - loss: 2.6415 - accuracy: 0.5000
模型 sequential_82 训练Epoch: 160
1/1 [=====] - 0s 46ms/step
[212333421126]<--- 模型答案
[112233445566]<--- 正确答案
正确答案数: 6 /12
1/1 [=====] - 0s 21ms/step - loss: 6.7181 - accuracy: 0.5833
模型 sequential_83 训练Epoch: 170
1/1 [=====] - 0s 48ms/step
[112233321136]<--- 模型答案
[112233445566]<--- 正确答案
正确答案数: 7 /12
1/1 [=====] - 0s 21ms/step - loss: 3.3654 - accuracy: 0.8333
模型 sequential_84 训练Epoch: 180
1/1 [=====] - 0s 47ms/step
[112233441516]<--- 模型答案
[112233445566]<--- 正确答案
正确答案数: 10 /12

```

图6. 神经网络的渐进式训练以及随后按控制点对模型的验证。




图7. 确定角膜切开后角膜畸形类型的误差比。

样本的增加, 训练部分也在减少, 其中第4和第5种类型由于数据量较少而受到的影响尤为严重。从每个给定类别中减少2条记录的样本会导致平均积分率在第200个Epoch时降至75%。

讨论

本研究强调了使用神经网络对前放射状角膜切开后经手术修改的角膜轮廓进行诊断分类的潜力。200个训练Epoch后获得的数据显示, 在测试样本和训练样本的不同比例下, 结果令人满意, 达到75–91%的范围。与此同时, 如果出现第4和第5类分类错误, 则需要增加数据集。分类准确度在一定程度上与前面介绍的构建人工神经网络的计算准确度相关。

例如, M.C. Arbelaez等人(2012年)研究了支持向量机在圆锥角膜患者角膜地形图数据分类中的有效性。他们的研究取得了很高的灵敏度和特异度, 分别为92.0%和97.7%。研究强调了, 与仅分析角膜前表面相比, 加入角膜厚度及其前后表面的数据将显著提高亚临床圆锥角膜的检测率[15]。我们还可以提及R.Hidalgo等人(2016年)的研究, 与单参数分析(0.922对0.809)相比, 使用支持向量机对角膜地形图数据进行的多参数分析显示出更高的准确性(ROC曲线下方的面积值更高)。总体分类的平均灵敏度和特异度分别为89.0%和95.2%, ROC曲线下面积为0.922[16]。

结果表明了, 通过适当调整学习过程、准备输入数据、使用较大的训练样本和选择最佳机构, 可以在角膜切开后角膜畸形分类问题上获得非常高且稳定的指标。此外, 消除类不平衡问题也很重要, 这对人工神经网络的训练质量有积极影响。虽然所使用的交叉熵误差估计方法大大减少了这一问题, 但我们不能排除一个事实: 第4和第5种类型作为最少的类型, 所受的影响最大, 包含的误差也最多。

通过对记录进行独立聚类来研究数据集中的现有类别看起来很有前景。这将允许消除原划分的主观因素。

还应指出的是, 本研究展示的是利用输入特征表构建人工神经网络的结果。不过, 所获得的数据是进一步构建直接使用角膜地形图的人工神经网络的基础。

结论

在分析角膜地形图数值的基础上, 开发了一个人工神经网络, 成功解决了角膜切开后角膜畸形类型分类问题, 准确性高达91%。该角膜切开后角膜畸形的训练质量还有进一步提高的潜力。应用人工智能算法可以成为对角膜切开后角膜畸形患者进行自动分类的有用工具, 从而提供及时、高质量的诊断, 并确定进一步的患者管理策略。

ADDITIONAL INFORMATION

Funding source. This study was not supported by any external sources of funding.

Competing interests. The authors declare that they have no competing interests.

Authors' contribution. All authors made a substantial contribution to the conception of the work, acquisition, analysis, interpretation of data for the work, drafting and revising the work, final approval of the version to be published and agree to be accountable for all aspects of the work. O.I. Rozanova — development of the concept and design of the study, writing the text of the article and editing, development of methodology, head of the study; E.K. Tsyrenzhapova — conducting research, writing the text of the article and editing, literature review, preparation and collection of data, preparation of the draft of the article, conducting research, final preparation of the article for publication, statistical data processing and their interpretation; I.S. Rozanov — computer accompaniment of the study; T.N. Iurieva — conducting research, final preparation of the article for publication, statistical data processing and interpretation; A.A. Ivanov — conducting research, literature review, preparation and collection of data, preparation of a draft article.

REFERENCES

1. Issarti I, Consejo A, Jiménez-García M, et al. Computer aided diagnosis for suspect keratoconus detection. *Comput Biol Med.* 2019;109:33–42. doi: 10.1016/j.compbiomed.2019.04.024
2. Chen X, Zhao J, Iselin KC, et al. Keratoconus detection of changes using deep learning of colour-coded maps. *BMJ Open Ophthalmol.* 2021;6(1):e000824. doi: 10.1136/bmjophth-2021-000824
3. Feng R, Xu Z, Zheng X, et al. KerNet: A novel deep learning approach for keratoconus and sub-clinical keratoconus detection based on raw data of the pentacam HR system. *IEEE J Biomed Health Inform.* 2021;25(10):3898–3910. doi: 10.1109/JBHI.2021.3079430
4. Gatinel D. Screening for subclinical keratoconus and prevention of corneal ectasia with SCORE analyzer software. In: Febraro J-L, Khan HN, Koch DD, editors. *Surgical correction of astigmatism.* Cham: Springer International Publishing; 2018. doi: 10.1007/978-3-319-56565-1_9
5. 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(6):689–695. doi: 10.1097/ICO.0000000000001194
6. Malyugin BE, Sakhnov SN, Axenova LE, Myasnikova VV. Application of artificial intelligence in diagnostics and surgery of keratoconus: a systematic overview. *Fyodorov Journal of Ophthalmic Surgery.* 2022;(1):77–96. EDN: PPQRWZ doi: 10.25276/0235-4160-2022-1-77-96
7. Abdelmotaal H, Mostafa MM, Mostafa ANR, et al. Classification of Color-Coded Scheimpflug Camera Corneal Tomography Images Using Deep Learning. *Transl Vis Sci Technol.* 2020;9(13):30. doi: 10.1167/tvst.9.13.30
8. Dos Santos VA, Schmetterer L, Stegmann H, et al. CorneaNet: fast segmentation of cornea OCT scans of healthy and keratoconic eyes using deep learning. *Biomed Opt Express.* 2019;10(2):622–641. doi:10.1364/BOE.10.000622
9. Kuo BI, Chang WY, Liao TS, et al. Keratoconus Screening Based on Deep Learning Approach of Corneal Topography. *Transl Vis Sci Technol.* 2020;9(2):53. doi:10.1167/tvst.9.2.53
10. Shi C, Wang M, Zhu T, et al. Machine learning helps improve diagnostic ability of subclinical keratoconus using Scheimpflug and OCT imaging modalities. *Eye Vis (Lond).* 2020;7:48. doi: 10.1186/s40662-020-00213-3
11. Shukhaev SV, Mordovtseva EA, Pustozero EA, Kudlakhmedov SS Application of convolutional neural networks to define Fuchs endothelial dystrophy. *Fyodorov Journal of Ophthalmic Surgery.* 2022;(S4):70–76. EDN: WEZTKV doi: 10.25276/0235-4160-2022-4S-70-76
12. Obaid HS, Dheyab SA, Sabry SS. The impact of data pre-processing techniques and dimensionality reduction on the accuracy of machine learning. *2019 9th Annu. Inf. Technol. Electromechanical Eng. Microelectron. Conf. IEMECON.* 2019:279–283. doi: 10.1109/IEMECONX.2019.8877011
13. Valdés-Mas MA, Martín-Guerrero JD, Rupérez MJ, et al. A new approach based on Machine Learning for predicting corneal curvature (K1) and astigmatism in patients with keratoconus after intracorneal ring implantation. *Comput Methods Programs Biomed.* 2014;116:39–47. doi: 10.1016/j.cmpb.2014.04.003
14. Patent RUS № RU 2793142 C1/ 29.03.2023. Rozanova OI, Tsyrenzhapova EK, Iureva TN, et al. A method of evaluating the relief of the anterior and posterior corneal surface. (In Russ).
15. Arbelaez MC, Versaci F, Vestri G, et al. Use of a Support Vector Machine for Keratoconus and Subclinical Keratoconus Detection by Topographic and Tomographic Data. *Ophthalmology.* 2012;119(11):2231–2238. doi: 10.1016/j.ophtha.2012.06.005
16. Ruiz Hidalgo I, Rodriguez P, Rozema JJ, et al. Evaluation of a Machine-Learning Classifier for Keratoconus Detection Based on Scheimpflug Tomography. *Cornea.* 2016;35(6):827–832. doi: 10.1097/ico.0000000000000834

СПИСОК ЛИТЕРАТУРЫ

1. Issarti I., Consejo A., Jiménez-García M., et al. Computer aided diagnosis for suspect keratoconus detection // *Comput Biol Med.* 2019. Vol. 109. P. 33–42. doi: 10.1016/j.compbiomed.2019.04.024
2. Chen X., Zhao J., Iselin K.C., et al. Keratoconus detection of changes using deep learning of colour-coded maps // *BMJ Open Ophthalmol.* 2021. Vol. 6, N 1. P. e000824. doi: 10.1136/bmjophth-2021-000824
3. Feng R., Xu Z., Zheng X., et al. KerNet: A novel deep learning approach for keratoconus and sub-clinical keratoconus detection based on raw data of the pentacam HR system // *IEEE J Biomed Health Inform.* 2021. Vol. 25, N 10. P. 3898–3910. doi: 10.1109/JBHI.2021.3079430
4. Gatinel D. Screening for subclinical keratoconus and prevention of corneal ectasia with SCORE analyzer software. In: Febraro J.-L., Khan H.N., Koch D.D., editors. *Surgical correction of astigmatism.* Cham: Springer International Publishing, 2018. doi: 10.1007/978-3-319-56565-1_9
5. Ruiz Hidalgo I., Rozema J.J., Saad A., et al. Validation of an objective keratoconus detection system implemented in a scheimpflug tomographer and comparison with other methods // *Cornea.* 2017. Vol. 36, N 6. P. 689–695. doi: 10.1097/ICO.0000000000001194
6. Малугин Б.Э., Сахнов С.Н., Аксенова Л.Е., Мясникова В.В. Применение искусственного интеллекта в диагностике и хирургии кератоконуса: систематический обзор // *Офтальмохирургия.* 2022. № 1. С. 77–96. EDN: PPQRWZ doi: 10.25276/0235-4160-2022-1-77-96
7. Abdelmotaal H., Mostafa M.M., Mostafa A.N.R., et al. Classification of Color-Coded Scheimpflug Camera Corneal Tomography Images Using Deep Learning // *Transl Vis Sci Technol.* 2020. Vol. 9, N 13. P. 30. doi: 10.1167/tvst.9.13.30
8. Dos Santos V.A., Schmetterer L., Stegmann H., et al. CorneaNet: fast segmentation of cornea OCT scans of healthy and keratoconic eyes using deep learning // *Biomed Opt Express.* 2019. Vol. 10, N 2. P. 622–641. doi:10.1364/BOE.10.000622
9. Kuo B.I., Chang W.Y., Liao T.S., et al. Keratoconus Screening Based on Deep Learning Approach of Corneal Topography // *Transl Vis Sci Technol.* 2020. Vol. 9, N 2. P. 53. doi: 10.1167/tvst.9.2.53
10. Shi C., Wang M., Zhu T., et al. Machine learning helps improve diagnostic ability of subclinical keratoconus using Scheimpflug and OCT imaging modalities // *Eye Vis (Lond).* 2020. Vol. 7. P. 48. doi: 10.1186/s40662-020-00213-3

- 11.** Шухаев С.В., Мордовцева Е.А., Пустозеров Е.А., Кудлахмедов Ш.Ш. Применение сверточных нейронных сетей для определения эндотелиальной дистрофии Фукса // Офтальмохирургия. 2022. № S4. С. 70–76. EDN: WEZTKV doi: 10.25276/0235-4160-2022-4S-70-76
- 12.** Obaid H.S., Dheyab S.A., Sabry S.S. The impact of data pre-processing techniques and dimensionality reduction on the accuracy of machine learning // 2019 9th Annu. Inf. Technol. Electromechanical Eng. Microelectron. Conf. IEMECON. 2019. P. 279–283. doi: 10.1109/IEMECONX.2019.8877011
- 13.** Valdés-Mas M.A., Martín-Guerrero J.D., Rupérez M.J., et al. A new approach based on Machine Learning for predicting corneal curvature (K1) and astigmatism in patients with keratoconus

- after intracorneal ring implantation // Comput Methods Programs Biomed. 2014. Vol. 116. P. 39–47. doi: 10.1016/j.cmpb.2014.04.003
- 14.** Патент РФ на изобретение № RU 2793142 C1/ 29.03.2023. Розанова О.И., Цыренжапова Е.К., Юрьева Т.Н., и др. Способ оценки рельефа передней и задней поверхности роговицы.
- 15.** Arbelaez M.C., Versaci F., Vestri G., et al. Use of a Support Vector Machine for Keratoconus and Subclinical Keratoconus Detection by Topographic and Tomographic Data // Ophthalmology. 2012. Vol. 119, N 11. P. 2231–2238. doi: 10.1016/j.opthta.2012.06.005
- 16.** Ruiz Hidalgo I., Rodriguez P., Rozema J.J., et al. Evaluation of a Machine-Learning Classifier for Keratoconus Detection Based on Scheimpflug Tomography // Cornea. 2016. Vol. 35, N 6. P. 827–832. doi: 10.1097/ico.0000000000000834

AUTHORS' INFO

* **Ekaterina K. Tsyrenzhapova**, MD;
address: 337 Lermontov street, 664033, Irkutsk, Russia;
ORCID: 0000-0002-6804-8268;
eLibrary SPIN: 1158-5233;
e-mail: katyakel@mail.ru

Olga I. Rozanova, MD, Dr. Sci. (Medicine);
ORCID: 0000-0003-3139-2409;
eLibrary SPIN: 6557-9123;
e-mail: olgrozanova@gmail.com

Tatiana N. Iureva, MD, Dr. Sci. (Medicine), Professor;
ORCID: 0000-0003-0547-7521;
eLibrary SPIN: 8457-5851;
e-mail: tnyurieva@mail.ru

Andrey A. Ivanov, MD;
ORCID: 0009-0001-4235-9252;
e-mail: ivanov.andrei.med@yandex.ru

Ivan S. Rozanov;
ORCID: 0009-0001-7202-0428;
e-mail: nauka@mntk.irkutsk.ru

ОБ АВТОРАХ

* **Цыренжапова Екатерина Кирилловна**;
адрес: Россия, 664033, г. Иркутск, ул. Лермонтова, 337;
ORCID: 0000-0002-6804-8268;
eLibrary SPIN: 1158-5233;
e-mail: katyakel@mail.ru

Розанова Ольга Ивановна, д-р мед. наук;
ORCID: 0000-0003-3139-2409;
eLibrary SPIN: 6557-9123;
e-mail: olgrozanova@gmail.com

Юрьева Татьяна Николаевна, д-р мед. наук, профессор;
ORCID: 0000-0003-0547-7521;
eLibrary SPIN: 8457-5851;
e-mail: tnyurieva@mail.ru

Иванов Андрей Александрович;
ORCID: 0009-0001-4235-9252;
e-mail: ivanov.andrei.med@yandex.ru

Розанов Иван Сергеевич;
ORCID: 0009-0001-7202-0428;
e-mail: nauka@mntk.irkutsk.ru

* Автор, ответственный за переписку / Corresponding author