

КЛАССИФИКАЦИИ СТАДИЙ ДИАБЕТИЧЕСКОЙ РЕТИНОПАТИИ НА ОСНОВЕ АЛГОРИТМОВ МАШИННОГО ОБУЧЕНИЯ И НАБОРА ПРИЗНАКОВ

М.М. Лукашевич¹, Ю.И. Голуб², В.В. Старовойтов²

¹Учреждение образования «Белорусский государственный университет информатики и радиоэлектроники», ул. П. Бровки, 6, 220013, г. Минск, Беларусь,

lukashevich@bsuir.by

²Государственное научное учреждение «Объединенный институт проблем информатики Национальной академии наук Беларуси», ул. Сурганова, 6, 220012, г. Минск,

Беларусь, 6423506@gmail.com, valerystar@mail.ru

Машинное обучение и искусственный интеллект широко используются для диагностики хронических заболеваний, чтобы еще на ранних стадиях можно было провести необходимое профилактическое лечение. Сахарный диабет вызывает повреждение сетчатки глаз. Данное заболевание называется диабетической ретинопатией, которое может быть достаточно точно диагностировано с помощью алгоритмов машинного обучения при анализе изображений сетчатки глаза. Диагностика на ранней стадии имеет решающее значение для предотвращения опасных последствий таких как слепота. В данной работе проведен сравнительный анализ нескольких алгоритмов машинного обучения, а также описан подход к вычислению признаков для решения задачи классификации стадий диабетической ретинопатии. Отдельное внимание уделено этапам анализа исходных данных и предварительной обработки изображений. Выполнены экспериментальные исследования, приведены результаты экспериментов и рекомендации по использованию предложенного подхода.

Ключевые слова: Изображение, диабетическая ретинопатия; машинное обучение; классификация; признаки.

CLASSIFICATION OF DIABETIC RETINOPATHY STAGES BASED ON MACHINE LEARNING ALGORITHMS AND SET OF FEATURES

М.М. Lukashevich^a, Y.I. Golub^b, V.V. Starovoitov^b

^aBelarusian State University of Informatics and Radioelectronics, 6 Brovki Street, Minsk 220013, Belarus

^bUnited Institute of Informatics Problems of the National Academy of Science of Belarus, 6 Surhanava Street, Minsk 220012, Belarus

Corresponding author: lukashevich@bsuir.by

Machine learning and artificial intelligence are widely used to diagnose chronic diseases so that necessary preventive treatment can be given early on. Diabetes mellitus causes damage to the retina. This disease is called diabetic retinopathy, which can be diagnosed quite accurately using machine learning algorithms to analyze retinal images.

Diagnosis at an early stage is crucial to prevent dangerous consequences such as blindness. This paper provides a comparative analysis of several machine learning algorithms and describes an approach to feature computation for the task of classifying the stages of diabetic retinopathy. Particular attention is paid to the stages of initial data analysis and image preprocessing. Experimental studies are performed, the results of experiments and recommendations for the use of the proposed approach are given.

Keywords: Image; diabetic retinopathy; machine learning; classification; features.

Введение

Значительные достижения в области медицинских технологий позволяют реализовать простые и недорогие способы получения и сбора данных, что требует разработки и прикладного применения новых технологий анализа данных (включая большие данные). На сегодняшний день существующие аппаратные средства сбора медицинских данных, включая различные приборы, датчики, которые далеко не всегда позволяют анализировать данные и чаще всего не предоставляют возможность принятия решений. Такая же ситуация существует и в области диагностики и лечения диабетической ретинопатии, которая проявляется как повреждение сетчатки глаз за счет повышенного уровня сахара в крови или сахарного диабета. По оценкам Международной диабетической федерации на 2019 год, 79% из 50 взрослых с диабетом проживают в странах с низким и средним уровнем дохода, а к 2045 году число случаев диабета в мире возрастет до 51 700 миллионов. С экономической точки зрения, диабет повлек за собой не менее 760 млрд долл. расходов на здравоохранение в 2019 году [1].

Фундус-исследование позволяет достаточно легко получить изображение сетчатки глаза человека. Тем не менее автоматизации последующего цифрового анализа такого рода изображений и интерпретация результатов ещё очень слабо развита. Методы машинного обучения позволяют извлекать закономерности из данных, имеют обобщающие способности, что позволяет строить эффективные модели [2, 3]. В области диабетической ретинопатии одним из наиболее важных приложений исследований является раннее прогнозирование и диагностика заболевания, представляющего угрозу для человека и снижающих качество жизни. Поэтому в рамках данного исследования была предложена методология классификации стадий диабетической ретинопатии на основе алгоритмов машинного обучения и набора информативных признаков [3, 4].

Условно можно выделить два подхода при решении данной задачи: использование классических алгоритмов машинного обучения (машины опорных векторов, метод k ближайших соседей, деревья решений и др.) и

реализация глубокого обучения сверточных нейронных сетей (AlexNet, VGGNet и др. архитектуры). Оба подхода имеют свои положительные моменты, но основным ограничением глубокого обучения является то, что необходимо иметь большое число данных, превышающее размер большинства доступных публичных наборов изображений сетчатки глаз. В рамках одного набора все возможные классы должны быть представлены достаточным числом изображений. В связи с этим в работе выбран подход исследования классических алгоритмов машинного обучения и возможности построения эффективных моделей на их основе [5, 6].

1. Методология исследования

Методология проведенного исследования включает в себя подготовку данных, определение набора признаков, создание моделей машинного обучения и выбор наиболее эффективной с точки зрения точности модели. Этап подготовки данных включает в себя сбор изображений сетчатки глаз и предварительную обработку изображений. В исследовании будем использовать публичный набор данных, описание которого приведено ниже. Этап определения набора признаков включает в себя непосредственно само вычисление признаков, стандартные техники по их нормированию, масштабированию и стандартизации. Также предусмотрен этап выбора подмножества информативных признаков. Типовой процесс создания модели машинного обучения обязательно включает этап разбиения данных на обучающую и тестовую выборки. На следующем этапе предлагается реализовать алгоритмы машинного обучения, выполнить их настройку. Модели на основе выбранных алгоритмов обучаются на обучающем наборе данных, а затем применяются к тестовым данным. Выполняется оценка качества работы моделей и выбирается модель/алгоритм, показывающий максимальную точность на тестовых данных. Данная методология была реализована в процессе исследований, посвященных задаче классификации стадий диабетической ретинопатии.

2. Подготовка данных

Выбор и анализ набора данных. В зависимости от типа и степени типичных признаков диабетической ретинопатии (ДР), таких как микроаневризмы, микрокровоизлияния, микроинфаркты, липидные экссудативные очаги, неоваскуляризация и т. д., болезнь классифицируется в несколько этапов: начальная, умеренная, тяжелая и пролиферативная [7]. В данном исследовании использовались изображения сетчатки глаза из набора данных Asia Pacific Tele-Ophthalmology Society 2019 Blindness

Detection (APTOS 2019 BD) [8]. Это большой набор изображений сетчатки, сделанных с помощью фундус-линзы при различных визуальных условиях. 3662 изображения размечены экспертами в соответствии со степенью тяжести диабетической ретинопатии по шкале от 0 до 4. Набор несбалансированный, распределение изображений по классам следующее: 0 – 1805 изображений, 1 – 370 изображений, 2 – 999 изображений, 3 – 193 изображения, 4 – 295 изображений). Многие изображения не в фокусе, переэкспонированы, недоэкспонированы или содержат артефакты. Набор подходит для постановки экспериментов по классификации стадий диабетической ретинопатии. Примеры изображений представлены на рисунке.




Рисунок - Примеры изображений сетчатки глаза

Разбиение данных на обучающую и тестовую выборки является важным этапом. Данные были разделены на обучающую и тестовую выборки (80% и 20% соответственно) с сохранением баланса классов.

Предварительная обработка изображений сетчатки глаз включает в себя следующие операции. На этапе предварительной обработки изображений необходимо выполнять **обрезку фона**, который иногда занимает значительный процент от общей площади изображения и является практически черной и неинформативной областью [9]. На следующем этапе из исходного цветного (RGB) изображения **извлекается зеленый канал** (Green Channel), который наиболее предпочтителен для автоматической диагностики заболеваний сетчатки [10]. Далее все операции выполняются только с Green каналом, как наиболее информативным для данной задачи.

База для экспериментов содержит изображения различного размера и соотношения сторон. Приведение изображений к единому размеру может изменить соотношение высоты и ширины изображений, а также внесет некоторые искажения. Поэтому предлагается выполнять **изменения размера изображений**, где будет зафиксирована его высота, равная 512 пикселям. А размер ширины изображения будет изменяться таким образом, чтобы сохранилось соотношение сторон.

Для **фильтрации шумов**, которые также присутствуют в Green канале изображения далее необходимо выполнить слияние в определенной пропорции исходного одноканального изображения ($src1$) и изображения, полученного путём применения к исходному одноканальному изображению фильтра Гаусса ($src2$) в соответствии с формулой:

$$dst = \alpha \cdot src1 + \beta \cdot src2 + \gamma \quad (1)$$

где dst – изображение после фильтрации шумов, $src1$ – исходное одноканальное изображение, $src2$ – исходное одноканальное изображение, к которому применен фильтр Гаусса, $\alpha = 4, \beta = -4, \gamma = 128$ – коэффициенты слияния. Размер ядра Гаусса равен (0,0), а стандартное отклонение гауссова ядра в направлении X равно 10 [11].

3. Определение набора признаков

Вычисление признаков. В качестве признаков для принятия решения (классификации) были выбраны следующие 5 групп признаков: признаки Харалика (Haralick Features) [12, 13]; локальные бинарные признаки (Local Binary Patterns) [14]; гистограммные признаки; пороговые статистики смежности (Threshold Adjacency Statistics); моменты Ху. Для всех признаков выполнялась **стандартизация** путем удаления среднего значения и масштабирования до единичной дисперсии.

Выбор признаков является одним из наиболее важных процессов на этапе определения набора признаков. В работе был использован метод одномерного отбора признаков (Univariate Feature Selection), который работает путем выбора лучших признаков на основе одномерных статистических тестов. Выбор характеристик выполнялся в соответствии с процентилем самых высоких оценок (75%) [15].

4. Создание моделей машинного обучения на базе алгоритмов

Одна из целей данной работы - провести сравнительное исследование для оценки наиболее эффективного алгоритма классификации стадий диабетической ретинопатии у пациента. Было рассмотрено 4 группы популярных методов классификации для прогнозирования заболевания: линейные алгоритмы, нелинейные алгоритмы, алгоритмы на основе нейронных сетей и ансамблевые алгоритмы, всего 13 алгоритмов. В процессе построения моделей использоваться метод кросс-валидации или перекрестной проверки (k-fold cross-validation) со значением $k = 10$. Данный подход позволяет выполнить настройку гиперпараметров модели [16].

5. Оценка результатов, выбор лучшей модели

Описанные выше методология исследования и ее этапы были реализованы на языке программирования Python с использованием библиотеки машинного обучения scikit-learn [17], библиотеки компьютерного зрения OpenCV [18] и библиотеки компьютерного зрения и обработки изображений Mahotas [19]. Для оценки построенных моделей использовались стандартные метрики задач машинного обучения: общая точность предсказания модели по всем классам (accuracy), точность модели при определении положительных результатов (precision), полнота (recall) и F-мера (f1-score) [20]. Результаты экспериментов представлены в таблице. Приводятся название алгоритма, средняя оценка точности (accuracy) и среднее квадратичное отклонение (standard deviation) при 10-кратной перекрёстной проверки на обучающем наборе, а также точности (accuracy) модели на тестовом наборе.

Таблица. Результаты экспериментов

Алгоритм	Обучающий набор		Тестовый набор
	accuracy	standard deviation	accuracy
Логистическая регрессия (Logistic Regression)	0.766	0.023	0.776
Линейный дискриминантный анализ (Linear Discriminant Analysis, LDA)	0.758	0.024	0.769
Метод k-ближайших соседей (K-Neighbors Classifier, KNN)	0.729	0.022	0.749
Деревья принятия решений (Decision Tree Classifier, CART)	0.668	0.034	0.714
Наивный классификатор Байеса (Naive Bayes Classifier, NB)	0.533	0.026	0.542
Линейный метод опорных векторов (Linear Support Vector Classification, LSVC)	0.761	0.021	0.769
Метод опорных векторов (C-Support Vector Classification, SVC)	0.751	0.023	0.776
Многослойный перцептрон (Multilayer Perceptrons, MLP)	0.756	0.017	0.780
Bagging (Bagging Classifier, BG)	0.750	0.026	0.802
Случайный лес (Random Forest Classifier, RF)	0.751	0.021	0.793
Экстра-деревья (Extra Trees Classifier, ET)	0.755	0.028	0.790
AdaBoost (AdaBoost Classifier, AB)	0.717	0.022	0.748
Градиентный boosting (Gradient Boosting Classifier, GB)	0.749	0.019	0.797

Результаты экспериментов показывают, что наиболее высокую эффективность показывают ансамблевые алгоритмы. Модель на основе Bagging алгоритма показала на тестовом наборе лучшие результаты по точности (ассигасу). Данные результаты позволяют сформулировать некоторые выводы и рекомендации для решения задачи классификации стадий диабетической ретинопатии. Изображения сетчатки глаза человека требуют предварительной обработки для эффективной реализации последующих стадий вычисления признаков и принятия решений. При построении моделей машинного обучения для решения задачи классификации стадий диабетической ретинопатии целесообразно использовать ансамблевые методы. Дальнейшие исследования следует продолжить в области разработки алгоритмов вычисления информативных признаков.

Заключение

В работе авторами описана и реализована методология классификации стадий диабетической ретинопатии на основе классических алгоритмов машинного обучения. Приведено описание этапа предварительной обработки изображений, вычисления и отбора информативных признаков, а также этап принятия решения на основе 13 алгоритмов машинного обучения. Тестирование выполнено на публичном наборе данных, приведены результаты экспериментов.

Работа частично выполнена в рамках проектов БРФФИ Ф20РА-014 и Ф21ПАКГ-001.

Библиографические ссылки

1. IDF Diabetes Atlas 9th 475 Edition 2019 [Электронный ресурс]. URL: <https://www.idf.org/aboutdiabetes/what-is-diabetes/facts-figures.html> (дата обращения: 05.09.2022).
2. Kumar R.K., Arunabhaskar K.A. A Hybrid Machine Learning Strategy Assisted Diabetic Retinopathy Detection based on Retinal Images // International Conference on Innovative Computing, Intelligent Communication and Smart Electrical Systems (ICSES). 2021; 1-6. DOI: 10.1109/ICSES52305.2021.9633875.
3. Dagliati A., Marini S., Sacchi Lx., et al. Machine Learning Methods to Predict Diabetes Complications // J Diabetes Sci Technol. 2018. № 12(2). P. 295–302. DOI:10.1177/1932296817706375.
4. Kavakiotis I., Tsave O., Salifoglou A., Maglaveras N., Vlahavas I., Chouvarda I. Machine Learning and Data Mining Methods in Diabetes Research // Computational and Structural Biotechnology Journal. 2017. № 15. P. 104–116. DOI: <https://doi.org/10.1016/j.csbj.2016.12.005>.
5. Stolte S, Fang R. A survey on medical image analysis in diabetic retinopathy // Med Image Anal. 2020. № 64. P. 101742. DOI:10.1016/j.media.2020.101742.

6. Shekar S., Satpute N., Gupta A. Review on diabetic retinopathy with deep learning methods // *Journal of Medical Imaging*. 2021. № 8(6). P. 060901.
7. Sim D'.A., Keane P.A., Rajendram R., et al. Patterns of peripheral retinal and central macula ischemia in diabetic retinopathy as evaluated by ultra-widefield fluorescein angiography // *Am J Ophthalmol*. 2014. № 158(1). P. 144–153. DOI:10.1016/j.ajo.2014.03.009.
8. APTOS 2019 Blindness Detection [Электронный ресурс]. URL: <https://www.kaggle.com/competitions/aptos2019-blindness-detection/data> (дата обращения: 05.09.2022).
9. Starovoitov V.V., Golub Y.I., Lukashevich M.M. A Universal Retinal Image Template for Automated Screening of Diabetic Retinopathy // *Pattern Recognit. Image Anal*. 2022. № 32. P. 322–331. <https://doi.org/10.1134/S1054661822020195>.
10. Amin J., Sharif M., Yasmin M. A Review on Recent Developments for Detection of Diabetic Retinopathy // *Scientifica (Cairo)*. 2016. P. 6838976. DOI:10.1155/2016/6838976.
11. Maison Maison, T. Maya Lestari, A. Luthfi. Retinal Blood Vessel Segmentation using Gaussian Filter // *Journal of Physics Conference Series*. 2019. № 1376(1). P. 012023. DOI: [10.1088/1742-6596/1376/1/012023](https://doi.org/10.1088/1742-6596/1376/1/012023).
12. Texture Feature Analysis in Fundus Image in Screening Diabetic Retinopathy | *Annals of the Romanian Society for Cell Biology* [Электронный ресурс]. URL: <https://www.annalsofrscb.ro/index.php/journal/article/view/1656> (дата обращения: 05.09.2022).
13. Haralick Robert M. et al. Textural Features for Image Classification // *IEEE Trans. Syst. Man Cybern*. 1973. № 3. P. 610–621.
14. Ojala T., Pietikäinen M., Harwood D. Performance evaluation of texture measures with classification based on Kullback discrimination of distributions // *Proceedings of the 12th IAPR International Conference on Pattern Recognition (ICPR 1994)*. 1994. № 1. P. 582–585.
15. Guyon I., Elisseeff A. An introduction to variable and feature selection // *Journal of machine learning research*. 2003. № 3. P. 1157–1182.
16. Krstajic D., Buturovic L.J., Leah, D.E. Cross-validation pitfalls when selecting and assessing regression and classification models // *J Cheminform*. 2014. № 6. P. 10. DOI: <https://doi.org/10.1186/1758-2946-6-10>.
17. scikit-learn: machine learning in Python — scikit-learn 1.1.2 documentation [Электронный ресурс]. URL: <https://scikit-learn.org/stable/> (дата обращения: 05.09.2022).
18. OpenCV [Электронный ресурс]. URL: <https://opencv.org/> (дата обращения: 05.09.2022).
19. Mahotas: Computer Vision in Python — mahotas 1.4.3+git documentation [Электронный ресурс]. URL: <https://mahotas.readthedocs.io/en/latest/> (дата обращения: 05.09.2022).
20. Géron A. *Hands-on machine learning with Scikit-Learn, Keras and TensorFlow: concepts, tools, and techniques to build intelligent systems* (2nd ed.). O'Reilly Media Inc.: 2019. 856 p.