

# Uczenie maszynowe w detekcji zmian patologicznych na obrazach okulistycznych

*Maciej SZYMKOWSKI\**

*Khalid SAEED\**

*Emil SAEED\*\**

## 1. Wstęp

Aktualnie jedną z najbardziej groźnych chorób dla organizmu ludzkiego jest cukrzyca. Na całym świecie choruje na nią ponad 425 milionów ludzi. Zgodnie z przewidywaniami światowej organizacji zdrowia (WHO) ta liczba ma zostać podwojona do 2050 roku. W wielu przypadkach zmiany cukrzycowe pojawiają się także na obrazach okulistycznych, np. obrazie dna oka czy też optycznej koherentnej tomografii (OCT). Nieleczona cukrzyca może prowadzić do nieodwracalnych zaburzeń widzenia, jak również nawet do całkowitej utraty wzroku. Bardzo często wczesne stadium zmian patologicznych jest niedostrzegalne gołym okiem nawet dla doświadczonego lekarza okulisty, jak również pacjent może nie zgłaszać pogorszenia widzenia. Wykrycie tego rodzaju zmian w ich wczesnej postaci pozwala uniknąć dalszych komplikacji, a także może zapobiec rozwojowi cukrzycy w organizmie.

Zmiany cukrzycowe widoczne na obrazie dna oka, sugerujące najczęściej konieczność wdrożenia leczenia, widoczne są w postaci wysięków twardych, czyli niewielkich odbarwień (najczęściej w kolorze żółto-czerwonym wpadającym w barwę pomarańczową). W literaturze możemy oczywiście znaleźć zróżnicowane algorytmy dotyczące detekcji tych zmian, jednakże zdecydowana większość z nich nie realizuje tejsz operacji z wystarczającą dokładnością oraz przy odpowiednio krótkim czasie przetwarzania.

W ramach niniejszej pracy prezentujemy nasz autorski algorytm, który pozwala na detekcję zmian w obrazie dna oka oraz wstępne rezultaty, które zostały dzięki niemu osiągnięte. Jednym z ważniejszych etapów proponowanego rozwiązania jest klasyfikacja wykrytych punktów jako zmian patologicznych lub zmian nienoszących znamion choroby. Ten element jest realizowany z wykorzystaniem metod uczenia maszynowego. Finalnie dokonujemy kalkulacji skuteczności przygotowanego rozwiązania – jest ona szacowana na podstawie decyzji, jaką zwrócił nasz algorytm w porównaniu do decyzji doświadczonego okulisty, będącego równocześnie członkiem naszego zespołu.

---

\* Politechnika Białostocka

\*\* Uniwersytet Medyczny w Białymstoku

## 2. Aktualny stan wiedzy

W literaturze możemy odnaleźć wiele zróżnicowanych rozwiązań skorelowanych z przetwarzaniem obrazu dna oka. W ogólnym rozrachunku możemy wyróżnić dwie grupy takowych algorytmów. Pierwszą z nich są metodyki oparte o rozpoznawanie człowieka na podstawie siatkówki oka.

Interesujące rozwiązanie zostało zaproponowane w ramach pracy [1]. W tym przypadku autorzy skorzystali z sieci neuronowych w celu detekcji tożsamości człowieka. W pracy nie przedstawiono zbyt wiele detali, brakuje w niej informacji o tym, w jaki sposób nastąpiła konstrukcja sieci neuronowej oraz jakie modele sieci były brane pod uwagę w trakcie wykonywania eksperymentów. Ponadto, w rzeczonym artykule autorzy nie rozważają tego, czy system zadziała w sposób oczekiwany, gdy na siatkówce oka pojawią się jakiegokolwiek zmiany patologiczne.

Rozwiązania bazujące na sztucznej inteligencji albo uczeniu maszynowym są powszechnie stosowane w przypadku rozpoznawania tożsamości człowieka na podstawie siatkówki oka. Dobrym przykładem jest [2]. W pracy tej zastosowano metody uczenia maszynowego do wyodrębnienia układu naczyń krwionośnych siatkówki oka. Autorzy wzięli również pod uwagę możliwość występowania zmian patologicznych w formie wysięków twardych. Inną pracą, która również odnosi się do segmentacji układu naczyń krwionośnych siatkówki oka w celu rozpoznawania człowieka jest [3]. W tym przypadku użyto algorytmu Harrisa do wyodrębnienia interesujących struktur. Autorzy zaproponowali także własną metodę służącą do porównania dwóch kolejnych próbek. Głównym celem prac [1-3] było jednak skupienie się na możliwości rozpoznawania człowieka, a nie detekcji zmian patologicznych.

Drugą grupą rozwiązań, która jest skorelowana z siatkówką oka, są metody obejmujące detekcję zmian patologicznych. Dominującym trendem w badaniach jest stosowanie metod sztucznej inteligencji i uczenia maszynowego do zautomatyzowanej detekcji zmian (najczęściej wysiękowych) na obrazach kolorowych dna oka. Koronnymi przykładami takich solucji mogą być [4-7]. Najbardziej popularną metodą są sztuczne sieci neuronowe [4, 5]. Algorytmy [4, 5] różnią się między sobą przede wszystkim zaimplementowanym modelem sieci oraz sposobem, w jaki wyekstrahowano niezbędne dane oraz utworzono wektor cech. W literaturze równie popularne są metody oparte o uczenie maszynowe [6, 7]. Ich główną wadą (podobnie jak w przypadku algorytmów opartych o sztuczną inteligencję) jest konieczność posiadania bardzo dużej bazy próbek, na mocy której następuje uczenie. Najczęściej proces przygotowania sieci do klasyfikacji trwa bardzo długo. W przypadku rozwiązań opartych o przetwarzanie obrazu możemy stwierdzić, że są one znacznie prostsze, jak również, że posiadają mniejszą złożoność obliczeniową.

### 3. Proponowane rozwiązanie

Głównym celem naszego algorytmu jest rozróżnienie obszarów posiadających zmiany patologiczne od fragmentów siatkówki, które są zdrowe. Nasze badania zostały przeprowadzone w oparciu o doświadczenia, jakie nabyliśmy w ramach poprzednich eksperymentów [8,9]. Proponowane rozwiązanie przedstawiamy w formie pseudokodu w ramach algorytmu 1. Proponowana metoda została zaimplementowana z wykorzystaniem języka programowania Java oraz matematycznego frameworku opracowanego przez autorów.

Algorytm 1. Pseudokod zaproponowanego rozwiązania

```
algorithm retina {  
    image = wczytaj_obraz(ścieżka)  
    image.filtruj_obraz(Filtr.MEDIANOWY)  
    image.konwertuj_do_skali_szarości(Kanał.ZIELONY)  
    image.wyznacz_regiony()  
    image.zbadaj_wyznaczone_regiony()  
}
```

Pierwszym krokiem zaproponowanego rozwiązania było wczytanie obrazu. Wykonano to, wykorzystując metodę `open` z klasy `ImageIO`. Przykładowy obraz przedstawiający zdrową siatkówkę oka przedstawiamy na rysunku 1, natomiast rysunek 2 przedstawia dno oka ze zmianami patologicznymi w formie wysięków twardych.



RYS. 1. Zdjęcie przedstawiające zdrową siatkówkę oka

FIG. 1. Healthy retina sample

ŹRÓDŁO: opracowanie własne.

SOURCE: own elaboration.



RYS. 2. Zdjęcie przedstawiające siatkówkę oka z wysiękami twardymi

FIG. 2. Retina sample with hard exudates

ŹRÓDŁO: opracowanie własne.


SOURCE: own elaboration.

Po wczytaniu obrazu kolejnym krokiem było usunięcie zbędnych zniekształceń, które powstają podczas procesu akwizycji danych. W tym przypadku autorzy wykonali szereg eksperymentów w celu znalezienia narzędzia, które pozwoliłoby nam na pozyskanie jak najdokładniejszego oczyszczenia obrazu. Porównywalne wyniki zostały osiągnięte przy użyciu filtra rozmywającego (przy masce 5x5) oraz filtra medianowego (z wykorzystaniem maski 3x3). Autorzy zdecydowali, że wykorzystane zostanie drugie z rzeczonych rozwiązań, ze względu na jego prostotę oraz niską złożoność obliczeniową.

Kolejnym etapem proponowanego rozwiązania była konwersja próbki do skali szarości. Podobnie jak w przypadku algorytmu układu żył w palcu, opublikowanego w [10], podjęliśmy próby dotyczące zróżnicowanych form przejścia do skali szarości. W trakcie eksperymentów zbadaliśmy konwersję z użyciem kanałów czerwonego, zielonego, niebieskiego, a także wartości uśrednionej z tych trzech elementów. Nasze badania potwierdziły tezy opublikowane w ramach prac [11, 12]. Mianowicie zaobserwowaliśmy, że najdokładniejsze odwzorowanie siatkówki oka jest obserwowalne w przypadku konwersji z użyciem kanału zielonego. W tym przypadku mamy na myśli fakt, że układ żył jest doskonale widoczny, jak również, że znacząca część dodatkowych zniekształceń została w sposób zautomatyzowany usunięta.

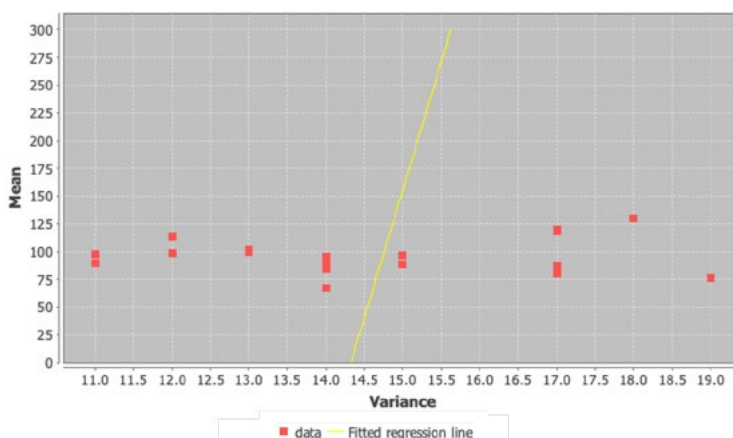
Następną procedurą użytą w ramach proponowanej solucji był algorytm skorelowany z wyznaczeniem regionów podejrzanych o bycie zmianami patologicznymi. W tym przypadku autorzy zastosowali obliczenie wartości średniej oraz wariancji. Na podstawie tych dwóch wartości (oraz dodatkowo wyznaczonych eksperymentalnie wartości progowych) podejmowana była decyzja, czy dany region może być podejrzewany

o występowanie zmian patologicznych. W trakcie badań autorzy zweryfikowali, jakiej wielkości regiony przynoszą najlepsze rezultaty. W tym przypadku okazało się, że najdokładniejszy wynik był osiągnięty przy podziale na sektory o wielkości 250x250 pikseli. Wynik osiągnięty po przeprowadzeniu tegoż etapu przedstawia rysunek 3.



RYS. 3. Siatkówka oka wraz z obszarami podejrzanymi o występowanie zmian patologicznych  
FIG. 3. Retina with areas suspected to contain pathological changes

ŹRÓDŁO: opracowanie własne.  
SOURCE: own elaboration.



RYS. 4. Przykładowa linia regresji służąca do oddzielenia obszarów zdrowych i chorych  
FIG. 4. Sample regression line for separation healthy areas from the ones with pathological changes

ŹRÓDŁO: opracowanie własne.  
SOURCE: own elaboration.

Ostatnim krokiem proponowanej solucji było dokładniejsze zbadanie wyznaczonych regionów. Mianowicie miało to na celu sprawdzenie, czy powinniśmy sklasyfikować region jako zdrowy czy też jako posiadający zmiany chorobowe. Operacja ta była wykonywana z wykorzystaniem metody regresji liniowej – każdy z regionów został bowiem zaprezentowany w przestrzeni dwuwymiarowej. Na jednej z osi odłożono wartość wariancji, natomiast na drugiej odchylenie standardowe. W ten sposób wyznaczono linię regresji – wartości, które znalazły się po stronie prawej uznawaliśmy za zmiany patologiczne, natomiast te po stronie lewej były klasyfikowane jako obszary zdrowe. Przykładowy wynik takiego działania został przedstawiony na rysunku 4.

## 4. Przeprowadzone badania

Eksperymenty, które zostały wykonane w trakcie prac nad niniejszym algorytmem możemy podzielić na trzy główne grupy. Pierwszą z nich była selekcja poszczególnych algorytmów w celu jak najdokładniejszego przygotowania obrazu do wyodrębnienia poszczególnych obszarów oraz detekcji zmian patologicznych. W tym przypadku autorzy zbadali zróżnicowane metody – m.in. filtracji, binaryzacji czy szkieletyzacji. Jednakże w poszczególnych przypadkach (jak np. po zastosowaniu metody binaryzacji) obserwowaliśmy znaczące pogorszenie osiąganych wyników. Było to nierzadko spowodowane problemem z zamazywaniem różnic pomiędzy obszarami zdrowymi a chorymi. Najlepsze wyniki (tzn. pozwalające na osiągnięcie największej dokładności) zostały osiągnięte na podstawie algorytmu opisanego w ramach trzeciej sekcji niniejszego dokumentu.

Druga grupa naszych badań dotyczyła bezpośrednio sposobu konstrukcji poszczególnych regionów. Początkowo testowaliśmy zróżnicowane kształty, poczynając od kwadratu, przechodząc przez trójkąty i prostokąty, a kończąc na okręgach. W trakcie realizowanych badań wykazaliśmy, że najdokładniejszy wynik został osiągnięty przy zastosowaniu obszarów kwadratowych. Pozostałe rozwiązania nie prowadziły do osiągnięcia aż tak dokładnych wyników, jak w przypadku rzeźonego wyboru. Kolejnym elementem związanym z obszarami była ich wielkość. Jak już zostało zaznaczone w ramach pracy, najlepsze (tzn. najdokładniejsze) wyniki uzyskano w przypadku szerokości i wysokości poszczególnych elementów równej 250px.

Ostatnim etapem badań było zweryfikowanie poziomu skuteczności proponowanego rozwiązania. W tym przypadku nie opracowaliśmy żadnej zautomatyzowanej metody, ale bazowaliśmy na decyzji naszego algorytmu, którą to porównywaliśmy do decyzji doświadczonego lekarza okulisty, będącego członkiem naszego zespołu. Na tej podstawie udało nam się ustalić, że przy próbie 150 zdjęć (na którą składało się 75 zdjęć zdrowych siatkówek oraz analogiczna ilość zdjęć ukazujących zmiany patologiczne) proponowany przez nas algorytm osiągnął skuteczność na poziomie 93,4%. W większości przypadków błędnie sklasyfikowanych obserwowaliśmy sytuację, w której zdjęcie zdrowe było rozpoznawane jako próbka prezentująca zmiany

patologiczne. Zgodnie z informacjami, jakie otrzymaliśmy od lekarza okulisty, jest to sytuacja znacznie bezpieczniejsza aniżeli przypadek, w którym próbka „chora” byłaby klasyfikowana jako „zdrowa”. Znacznie lepiej jest bowiem, aby pacjent zbadał swój wzrok (w sposób dokładny i dogłębny) aniżeli zaniechał takich badań pomimo występujących (choć nie wykrytych w sposób prawidłowy) przesłanek.

## 5. Podsumowanie

Zrealizowane eksperymenty pokazały dobitnie, że nawet zastosowanie prostych metod statystycznych oraz podstawowych rozwiązań uczenia maszynowego może zagwarantować detekcję i klasyfikację zmian patologicznych na dosyć wysokim poziomie. Proponowany przez nas algorytm został także przetestowany na dwóch różnych urządzeniach (które to różniły się całkowicie konfiguracją i klasą posiadanych komponentów). Na podstawie tegoż eksperymentu jesteśmy w stanie także powiedzieć, że nasza solucja może być używana nawet na komputerach o niskiej jakości konfiguracji. Stanowi to zatem niewątpliwą zaletę naszego rozwiązania.

Ekspertyzy w ramach naszych badań były przeprowadzone na bazie próbek wynoszącej 150 elementów, przy czym 75 z nich reprezentowało zdrowe dno oka, a kolejnych 75 było skorelowanych z siatkówką oka ze zmianami patologicznymi. Nasz algorytm pomylił się jedynie przy 10 z nich. Spośród tejże grupy 9 próbek pochodziło ze zbioru ze zmianami patologicznymi (i zostało sklasyfikowanych jako zdrowe).

Aktualnie autorzy rozpoczęli procedurę zwiększania ilości próbek w bazie oraz udoskonalania zaproponowanego rozwiązania. Ponadto kolejnym krokiem, który zostanie wykonany będzie implementacja i przetestowanie innych, bardziej złożonych algorytmów uczenia maszynowego oraz sztucznej inteligencji. Autorzy będą również dążyć do upublicznienia swojej bazy danych tak, aby inni naukowcy również mogli przeprowadzać na niej swoje eksperymenty.

## Literatura

1. Sadikoglu F, Uzelatinbulat S. Biometric retina identification based on neural network. *Procedia Computer Science*. 2016; 102: 26-33.
2. Mazzaferri J, Larrivee B, Cakir B, Sapieha P, Costantino S. A machine learning approach for automated assessment of retinal vasculature in the oxygen induced retinopathy model. *Scientific Reports*. 2018; DOI: 10.1038/s41598-018-22251-7.
3. Dehghani A, Ghassabi ZR, Moghaddam HA, Moin MS. Human recognition based on retinal images and using new similarity function. *EURASIP Journal on Image and Video Processing*. 2013; 58; DOI: 10.1186/1687-5281-2013-58.

4. Anitha GJ, Maria KG. *Detecting Hard Exudates in Retinal Fundus Images Using Convolutional Neural Network*, Proceedings of International Conference on Current Trends towards Converging Technologies (ICCTCT), 2018; DOI: 10.1109/icctct.2018.8551079.
5. Bharkad S. *Morphological and Neural Network Based Approach for Detection of Exudates in Fundus Images*, 2<sup>nd</sup> International Conference on Computing Methodologies and Communication (ICCMC), 2018; DOI: 10.1109/ICCMC.2018.8487517.
6. Avula B, Chakraborty C. *Detection of Hard Exudates in Retinal Fundus Images Using Deep Learning*, 2018 7<sup>th</sup> International Conference on Informatics, Electronics and Vision (ICIEV) and 2018 2<sup>nd</sup> International Conference on Imaging, Vision and Pattern Recognition (icIVPR), Proceedings, 2018; DOI: 10.1109/ICIEV.2018.8641016.
7. Long S, Huang X, Chen Z, Pardhan S, Zgeng D. Automatic Detection of Hard Exudates in Color Retinal Images Using Dynamic Threshold and SVM Classification: Algorithm Development and Evaluation, *BioMed Research International*. 2019; 6a: 1-13.
8. Saeed E, Szymkowski M, Saeed K, Mariak Z. An Approach to Automatic Hard Exudate Detection in Retina Color Images by Telemedicine System Based on d-Eye Sensor and Image Processing Algorithms. *MDPI Sensors*. 2019; vol. 19, no. 3; DOI:10.3390/s19030695.
9. Szymkowski M, Saeed E, Saeed K, Mariak Z. *A simple algorithm for hard exudate detection in diabetic retinopathy using spectral-domain Optical Coherence Tomography*, Springer Lecture Notes in Computer Science, Proceedings of 36<sup>th</sup> International Conference on Computer Graphics, CGI 2019, Calgary, Canada, June 17-20; 179-189.
10. Szymkowski M, Saeed K. *Finger Veins Feature Extraction Algorithm Based on Image Processing Methods*. In: Saeed K, Homenda W, Eds. *17<sup>th</sup> International Conference, CISIM 2018*, Olomouc, Czech Republic, September 27-29, 2018, Springer Lecture Notes in Computer Science (LNCS) Proceedings, pp. 80-91.
11. Zhang J, Cui Y, Jiang W, Wang L. *Blood Vessels Segmentation of Retinal Images Based on Neural Network*. 2015 ICIIG 8<sup>th</sup> International Conference on Image and Graphics, Tianjin, China, Proceedings; 11-17.
12. Xu L, Luo S. A Novel Method for Blood Vessel Detection from Retinal Images. *Biomedical Engineering Online*. 2010; vol. 9, no. 14.

Praca była wspierana poprzez grant S/WI/3/2018 przyznany przez Politechnikę Białostocką i sfinansowany ze środków Ministerstwa Nauki i Szkolnictwa Wyższego w Polsce.



## Streszczenie

Współcześnie jedną z najbardziej groźnych chorób jest cukrzyca. W kontekście okulistyki jej wystąpienie może prowadzić do częściowej bądź całkowitej utraty wzroku. Lekarze są w stanie zaobserwować ją odpowiednio wcześniej w formie drobnych plamek na obrazie siatkówki oka. Jednakże należy podkreślić, że często zmiany w początkowym stadium mogą być niewidoczne gołym okiem. W ramach niniejszej pracy zaproponowany został algorytm do detekcji wysięków twardych na obrazach siatkówki oka z zastosowaniem metod uczenia maszynowego. Rozwiązanie to pozwoli lekarzom na wcześniejszą detekcję groźnych zmian chorobowych.

**Słowa kluczowe:** uczenie maszynowe, siatkówka oka, obrazy kolorowe siatkówki oka, zmiany patologiczne, przetwarzanie obrazów

## Summary

### Machine Learning in the detection of pathological changes in ophthalmic images

Nowadays diabetes is one of the most dangerous illnesses. If we are thinking about our sight, untreated diabetes can lead to partial or complete vision loss. Ophthalmologists can observe early changes in retina color image in the form of small spots. However, sometimes these spots are too small to observe them by eye. In this article we propose novel algorithm for detection of hard exudates in retina color images with machine learning methods. This solution will allow ophthalmologists early detection of dangerous pathological changes.

**Keywords:** Machine Learning, retina, retina color images, pathological changes, image processing

