

Zbigniew Mikrut*, Mariusz Duplaga**

Wykrywanie krwi na obrazach bronchoskopowych za pomocą sieci neuronowych***

1. Wprowadzenie

Obecnie używane bronchoskopy pozwalają na wizualizację w wysokiej jakości kolorze, oferując opcje przekodowania kolorów w trakcie badania, a co najważniejsze – możliwości rejestracji filmów. Powstaje w ten sposób baza badań, która może być przeszukiwana pod kątem wykrywania zadanych patologii. Stworzenie oprogramowania do automatycznego przeszukiwania bazy jest jednym z celów projektu BRONCHOVID [2], a jedną z poszukiwanych patologii jest wykrywanie obszarów krwawień. Wykryte automatycznie i zweryfikowane przez lekarza patologie będą służyć do utworzenia bibliotek wzorców, przeznaczonych do udoskonalania mechanizmów detekcji oraz do celów dydaktycznych.

Najistotniejszą cechą odróżniającą obszary krwawień od innych regionów obrazu jest kolor, dlatego też zdecydowano o wykorzystaniu do segmentacji jedynie informacji o kolorze pojedynczych pikseli. Argumenty przemawiające za tym wyborem przedstawiono w pracy [9], w której posłużono się przykładami, zaczerpniętymi z prac [3, 4, 6, 8]. Wobec braku publikacji związanych z analizą obrazów bronchoskopowych zacytowane przykłady dotyczą wykrywania krwawień na obrazach uzyskanych techniką endoskopii kapsułkowej przewodu pokarmowego (WCE – *Wireless Capsule Endoscopy*). W pracy [9] dokonano także wyboru przestrzeni barw HSV (*Hue Saturation Value*) dla reprezentacji pikseli obrazu na podstawie wyżej cytowanych artykułów oraz pracy [7].

2. Zbiory uczące i testowe


Jednym z podstawowych warunków, jakie należy spełnić, zanim przejdzie się do etapu uczenia sieci neuronowych, jest prawidłowy dobór ciągu uczącego [1, 10, 11]. Główną cechą prawidłowo skonstruowanego zbioru uczącego jest jego reprezentatywność, czyli do-

* Katedra Automatyki, Akademia Górniczo-Hutnicza w Krakowie

** Uniwersytet Jagielloński Collegium Medicum w Krakowie

*** Wykonano w ramach grantu MNiSW, umowa nr R13 011 03


branie jak największej liczby różnorodnych przykładów dla każdej z rozpoznawanych klas. W przypadku obrazów pochodzących z badania bronchoskopowego nie jest to zadanie trywialne. Patologie tego samego rodzaju wyglądają nieco inaczej w zależności od tego, w którym miejscu drzewa oskrzelowego znajduje się głowica. Dodatkowo nowoczesne bronchoskopy automatycznie regulują oświetlenie obserwowanego pola, co powoduje pozorne zmiany kolorystyki. Pierwszym krokiem prowadzącym do prawidłowego wyboru zbioru uczącego jest wizualna ocena obrazów i próba wybrania ramek różniących się od siebie. Z 20 wytypowanych przez lekarza-diagnostę obrazów wybrano 6, które przedstawiono na rysunku 1. Pozostałe ramki zostały przeznaczone do zbioru testowego. Na wszystkich 20 obrazach lekarz zaznaczył obszary krwawień.



Rys. 1. Obrazy wybrane do zbioru uczącego (widoczne zaznaczenia lekarza)

Pomimo precyzyjnego zaznaczenia obszarów krwawień już na pierwszy rzut oka wiadać, że występują w nich różne odcienie. Dodatkowo wewnątrz zaznaczeń znalazły się rejon niebędące krwawieniami. Głównie są to odbłaski (por. ramki 200833 i 212072 na rysunku 1) lub mniej intensywne odcienie barw, spowodowane nierównościami tkanek lub bliskością wlotów drzewa oskrzelowego (dobrymi przykładami są wymienione wyżej obrazy oraz ramka 1928222). Radykalną zmianę kolorystyki spowodowaną regulacją oświetlenia

można zaobserwować na obrazie 235324 (por. rys. 1). Z tych powodów przed ekstrakcją pikseli do zbioru uczącego należy wyeliminować rejony niebędące krwawieniami. Metodę takiej eliminacji dokładniej opisano w pracy [9], zamieszczonej w tym zeszycie. Opiera się ona na analizie trójwymiarowego (3D) histogramu pikseli należących do zaznaczonego przez lekarza obszaru. Histogram jest tworzony dla przestrzeni barw HSV, znormalizowanej do przedziału $[0, 1]$. Po wyznaczeniu koloru dominującego (maksimum histogramu) osoba korygująca interaktywnie zmienia próg, który odpowiada liczbie pikseli wchodzących w skład poszczególnych elementów histogramu. W ten sposób np. zmniejszając próg, uwzględniamy coraz więcej kolorów pikseli, dla których liczebności w histogramie są powyżej progu. Dynamicznie tworzone są maski, które są wizualnie porównywane z obrazem źródłowym i korygowane przy pomocy odpowiednich zmian progu. Przykład obrazu źródłowego i finalnej wersji maski przedstawiono na rysunku 2. Należy zauważyć, że przy tej metodzie postępowania maska zwykle nie pokrywa całego zaznaczonego obszaru. Dodatkowo zaznaczane są rejony o zbliżonej kolorystyce leżące poza zaznaczeniem.



Rys. 2. Obraz 1854765 – wynik iteracyjnej korekty zaznaczenia (por. [9], s. 1377–1386)

Kolejnym etapem tworzenia zbioru uczącego jest ekstrakcja składowych HSV pojedynczych pikseli. Na obecnym etapie prac rozróżniane mają być obszary krwawień od pozostałych rejonów. Elementy klasy „krew” odpowiadają pikselom znajdującym się w obrębie maski interaktywnego zaznaczenia, przy czym jest sprawdzana unikalność składowych HSV. Przy użyciu negacji maski zaznaczenia dopisywane do zbioru uczącego są piksele pozostałe (klasa „inne”). W tabeli 1 zestawiono liczby unikalnych pikseli obu klas dla każdego z 6 obrazów uczących. Porównanie wartości HSV pikseli obu klas pomiędzy poszczególnymi obrazami zostało przedstawione w pracy [9]. Z analizy odpowiednich tabel wynika, że wybrane obrazy znacząco różnią się między sobą, a więc zbiór uczący powinien być reprezentatywny. Podobne porównanie, przeprowadzone nie bezpośrednio lecz z punktu widzenia nauczonych sieci neuronowych zostanie przedstawione w punkcie 4.

Inną ważną cechą zbioru uczącego jest niesprzecznność danych, czyli uniknięcie sytuacji przedstawionej w prawej części tabeli 1. Po scaleniu sześciu zbiorów okazało się, że

część pikseli należy równocześnie do obu rozpoznawanych klas (por. kolumny 4 i 5, tab. 1). Dylemat ten można rozwiązać dwojako:

- 1) założyć, że powinny zostać wykryte jak największe rejony krwawień, nawet kosztem popełnienia błędu; wtedy należy usunąć zduplikowane reprezentacje z klasy „inne”;
- 2) przyjąć, że bardziej interesująca jest detekcja pikseli, odpowiadających krwawieniom, z wysokim stopniem pewności rozpoznania; w tym przypadku należałoby wyeliminować odpowiednie piksele z klasy „krew”.

W omawianych eksperymentach zdecydowano się na rozwiązanie pierwsze.

Tabela 1

Liczby pikseli w dwóch klasach dla obrazów ze zbioru uczącego

Kod obrazu	Klasa „krew”	Klasa „inne”	W zbiorze uczącym scalonym:	
			„krew” w „inne”	„inne” w „krew”
1854765	172	9269	164	337
1881874	296	6833	283	802
1928222	285	5691	278	309
200833	112	9235	80	1017
212072	385	7812	359	776
235324	574	9788	457	2

3. Sieć neuronowa typu SOM

Z dwóch najpopularniejszych i najbardziej efektywnych sieci neuronowych (*backpropagation* i SOM) [10, 11] do klasyfikacji wybrano SOM (Kohonen *Self Organizing Map*) [5]. Za tym wyborem przemawia prostota samej sieci, dobre możliwości wizualizacji wyników uczenia oraz wysokiej klasy ogólnie dostępne oprogramowanie (*SOM Toolbox for Matlab* [12, 13]). Użycie mocniejszego narzędzia, jakim jest sieć ze wsteczną propagacją błędów, zaplanowano w przypadku niepowodzenia lub w późniejszym etapie prac, kiedy to konieczne stanie się rozpoznawanie reprezentacji należących do kilku klas.

Podstawy działania sieci SOM są szeroko opisywane i znane [5, 10, 11], nie jest więc celowe powtarzanie ich w niniejszej pracy. Interesujące są natomiast szczegóły implementacji procesu uczenia w użytym *toolboxie* oraz możliwości wpływania na półautomatyczną metodę przeprowadzania eksperymentów.

Celem przyświecającym autorom oprogramowania [12, 13] była możliwość wykorzystania go w sposób całkowicie automatyczny. Pierwszym poziomem ingerencji w wartości domyślne jest wprowadzanie pewnych modyfikacji w sposób „symboliczny”: dobrym przykładem jest (wykorzystana w tej pracy) możliwość wymuszenia zmniejszenia wielkości automatycznie generowanej sieci. Kolejnym poziomem jest bezpośrednia ingerencja

w konkretne parametry. Dla powyższego przykładu jest to zadawanie konkretnej struktury sieci: jej rozmiarów, warunków brzegowych, kształtu sąsiedztwa neuronów, dynamiki zmian rozmiarów sąsiedztwa i współczynników uczenia w czasie itp.

Poniżej zostaną wymienione najważniejsze cechy i parametry zamodelowanej sieci ze wskazaniem wprowadzonych zmian w stosunku do wartości domyślnych.

- 1) Chronologicznie pierwszym i niezbędnym krokiem jest normalizacja danych wejściowych do zakresu $[0, 1]$. Oprogramowanie oferuje kilka metod, jednak w przypadku danych w postaci reprezentacji pikseli normalizacja odbywa się na etapie przekształcania obrazu z przestrzeni kolorów RGB do HSV.
- 2) Struktura sieci jest generowana automatycznie na podstawie analizy zbioru uczącego. Zaakceptowano następujące wielkości domyślne: ogólny kształt warstwy SOM – prostokąt, strukturę połączeń – heksagonalną, gaussowską funkcję sąsiedztwa. Oprogramowanie dobierało wielkość warstwy SOM na podstawie analizy zbioru uczącego, przy czym odbywało się to dla dwóch typów sieci: *normal*, czyli standardowej oraz *small* czyli zmniejszonej.
- 3) Inicjalizacja początkowych wag może być zrealizowana przy użyciu metody nazwanej w pracach [5, 13] „liniową” (metoda domyślna) lub w sposób przypadkowy. W omawianych eksperymentach zastosowano metodę domyślną. Polega ona na wyznaczeniu dwóch wektorów własnych macierzy autokorelacji danych uczących, które posiadają najwyższe wartości własne. Wektory te są propagowane liniowo odpowiednio w kierunkach x i y prostokątnej siatki, tworzącej warstwę SOM.
- 4) Uczenie sieci przebiega w dwóch fazach: zgrubnej i dokładnej. Fazy te charakteryzują się różną szybkością zmian współczynników uczenia i różnym tempem zmian funkcji sąsiedztwa. Nie ingerowano w domyślne wartości tych współczynników. Zmieniono za to sposób uczenia ze standardowego *batch* na sekwencyjny: uczenie przebiega dłużej, lecz jest dokładniejsze. Drugą poważną zmianą było zastąpienie domyślnego trybu uczenia „bez nauczyciela” metodą nadzorowaną (*supervised*). Metoda ta polega na wydłużeniu w fazie uczenia wektora cech o binarny wektor wartości oczekiwanych typu 1-z- N , gdzie N jest liczbą klas. Dodanie (konkatenacja) wektora wartości oczekiwanych powoduje lepsze różnicowanie klas oraz daje możliwość wyznaczenia ich granic po zakończeniu procesu uczenia. Na etapie klasyfikacji ta dodatkowa informacja nie jest uwzględniana.
- 5) Proces klasyfikacji polega na podawaniu na wejście sieci wektorów ze zbioru testowego i wyznaczaniu neuronu-zwycięzcy (BMU – *Best Matching Unit*). Zarówno w czasie uczenia, jak i na etapie klasyfikacji użyto domyślnej metryki – euklidesowej. Często zdarza się, że neuron-zwycięzca odpowiada na wektory należące do różnych klas, dlatego przed etapem klasyfikacji dokonuje się ostatecznego przyporządkowania neuronów do klas (*labeling*). Oprogramowanie oferuje trzy możliwości: dodanie do rozważanego neuronu wszystkich etykiet, dla których dany neuron okazał się zwycięzcą, dodania wszystkich etykiet uzupełnionych liczbą ich wystąpień oraz dodanie jednej etykiety, która wystąpiła najczęściej. Z tych opcji wybrano tę ostatnią (*vote*).

4. Wyniki

Sieci SOM opisane w punkcie 3 zastosowano do klasyfikacji pikseli obrazów bronchoskopowych. Sieci uczono rozpoznawania dwóch klas, umownie nazwanych „krew” oraz „inne”. Tabela 2 przedstawia wyniki klasyfikacji w odniesieniu do zbiorów uczących. Sieci były uczone sześcioma zbiorami uczącymi z osobna a następnie te same zbiory były klasyfikowane. Miało to na celu przeprowadzenie oceny efektywności samych sieci oraz stopnia podobieństwa wybranych sześciu obrazów. Sieci generowano i uczono w wersjach standardowej (*normal*) i zmniejszonej (*small*). Różnice w rozmiarach automatycznie utworzonych sieci są znaczne. Pokazano je w kolumnie 8 tabeli 2. W pierwszej kolumnie znajdują się nazwy (kody) obrazów, którymi uczono sieci. Te same kody znajdują się w pierwszym wierszu. Oznaczają one obrazy podlegające rozpoznawaniu. Tak więc – przykładowo – w drugim wierszu tabeli 2 zestawiono wyniki rozpoznawania obrazów sieciami SOM o rozmiarach 48×14 oraz 24×7, nauczonych pikselami obrazu o kodzie 1854765. Procentowe rozpoznania zestawione w tabeli 2 są stosunkiem liczby pikseli klasy „krew” rozpoznanych w zaznaczeniu interaktywnym do całkowitej liczby pikseli w tym zaznaczeniu.

Tabela 2

Wyniki uczenia i rozpoznawania zbiorów uczących (w %). W poszczególnych polach górne liczby odpowiadają sieci SOM typu *normal*, dolne – sieci SOM typu *small*. Nagłówek „obraz OK” odpowiada obrazowi, na którym nie stwierdzono krwawienia

Kod obrazu	1854765	1881874	1928222	200833	212072	235324	Rozmiar sieci	Obraz OK (329505)
1854765	64,51 96,55	71,06 91,14	48,75 64,02	68,48 99,79	76,39 92,28	0,00 0,00	48×14 24×7	77 pix 0,17% 71 pix 0,16%
1881874	76,26 74,56	82,59 89,53	53,34 61,92	93,24 100,00	78,52 79,11	0,00 0,00	46×13 21×7	5 pix 0,01% 5 pix 0,01%
1928222	80,51 90,88	66,31 75,33	83,91 95,24	95,29 99,07	83,40 90,56	0,00 0,00	48×11 27×5	19 pix 0,04% 148 pix 0,33%
200833	10,56 30,21	10,16 22,41	13,63 21,24	61,94 95,71	34,49 49,41	0,00 0,00	48×14 24×7	0 pix 0,00% 0 pix 0,00%
212072	81,23 93,29	57,29 64,61	53,32 62,98	86,40 87,40	85,90 93,60	0,00 0,00	48×13 22×7	220 pix 0,49% 476 pix 1,05%
235324	0,00 0,00	4,42 8,53	0,00 0,00	0,83 0,93	0,15 0,15	86,23 90,95	54×13 25×7	1070 pix 2,37% 1233 pix 2,72%
Zbiór scalony	96,42 95,35	93,06 96,04	91,66 88,69	100,00 100,00	95,87 94,51	92,26 89,96	56×19 26×10	1145 pix 2,53% 1296 pix 2,87%

W tabeli 2 zaznaczono główną przekątną pogrubionymi liniami. Dla idealnych klasyfikatorów wartości na głównej przekątnej powinny wynosić 100%. W przypadku uczenia sieci małymi zbiorami widać, że lepsze wyniki osiągnięto dla sieci o rozmiarach zmniejszo-

nych względem sieci „domyślnej”. Bardzo małe wartości w kolumnie 7 i w wierszu 7 świadczą o całkowitej odmienności obrazu o kodzie 235324 od pozostałych obrazów (por. także rys. 1). O podobieństwie pozostałych obrazów należy wnioskować nie tylko na podstawie procentowych rozpoznań, ale także z porównania wzajemnych wyników klasyfikacji, czyli wyników położonych symetrycznie względem przekątnej. Znalaziono tylko dwie pary obrazów w przybliżeniu spełniających te kryteria podobieństwa. Odpowiadające im pola pokolorowano w tabeli 2. Fakt ten świadczy o prawidłowym wyborze obrazów przeznaczonych do uczenia sieci.

Dane z 6 obrazów wybranych do uczenia scalono, a dane zweryfikowano (por. pkt 2). Powstałym w ten sposób zbiorem uczono sieci. Wyniki klasyfikacji zbiorów uczących zestawiono w ostatnim wierszu tabeli 2. Procentowe rozpoznania są na dobrym poziomie. Zmniejszyły się także różnice w rozpoznaniach pomiędzy sieciami SOM o różnych rozmiarach.

Tabelę 2 uzupełniają wyniki rozpoznawania przeprowadzone na obrazie nie zawierającym krwawień (ostatnia kolumna, zatytułowana „Obraz OK”). Bardzo niskie wartości (podane zarówno w pikselach jak i w procentach) potwierdzają dobrą jakość klasyfikatorów.

W tabeli 3 zestawiono wyniki klasyfikacji 14 obrazów testowych, uzyskane za pomocą sieci SOM nauczonych zbiorem scalonym z 6 zbiorów uczących. Wyniki są zróżnicowane, od około 25% (4 obrazy) przez rozpoznania średnie (około 50–70% – 5 obrazów) do wysokich. Podobnie jak w przypadku rozpoznawania cząstkowych zbiorów uczących (por. tab. 2) wyniki osiągane przez oba typy sieci są do siebie zbliżone.

Tabela 3

Wyniki rozpoznawania 14 obrazów testowych (w %). Pierwszy wiersz zawiera kody obrazów, drugi wyniki dla sieci SOM *normal*, trzeci – wyniki dla sieci SOM *small*

1854673	1855089	1856063	1865615z	1881376	1928345	1928479	201195z	2099185	212003	234884	236216	236744z	238860
25,00	83,23	20,42	68,92	44,94	21,38	59,25	98,18	54,46	37,43	29,65	73,67	98,55	94,17
28,76	89,20	25,64	74,53	42,32	19,67	66,82	98,60	50,18	61,05	31,60	70,07	90,91	83,91


W tabeli 3 wyróżniono cztery pola, odpowiadające następującym obrazom:

- 1928345 – obraz, dla którego rozpoznanie było najniższe,
- 1928479 – obraz o średnim rozpoznaniu,
- 201195z – obraz o najwyższym rozpoznaniu,
- 212003 – obraz o największej różnicy rozpoznań dla sieci o dwóch rozmiarach.

Na rysunku 3 pokazano wybrane obrazy oraz graficznie przedstawiono wyniki rozpoznawania obszarów krwawień, uzyskane za pomocą sieci typu *normal* i typu *small*. Znaczenie kolorów zostało zdefiniowane w podpisie pod rysunkiem 3. Wizualna analiza

potwierdza duże podobieństwo wyników uzyskanych dla obu rodzajów sieci. Ma to miejsce nawet w przypadku obrazu 212003, dla którego różnica wyników jest największa.

Podczas analizy rysunku 3 w pierwszej kolejności należy zwrócić uwagę na kolor czerwony, oznaczający zgodność wykrycia pikseli odpowiadających klasie „krew” z interaktywnym zaznaczeniem. Rozłożenie pikseli w tych obszarach świadczy o tym, że należy podejść z pewną rezerwą do wyników procentowych, przedstawionych w tabelach 2 i 3. Bardziej istotne jest, czy wykryte piksele tworzą zwarte obszary, czy też są rozproszone. W tym drugim przypadku ważne są także odległości pomiędzy pojedynczymi pikselami lub małymi grupami pikseli, ponieważ za pomocą odpowiedniej operacji morfologicznej można dokonać ich scalenia. Na etapie dalszej analizy prawdopodobnie zostaną ustalone progi dla powierzchni wykrytych obszarów oraz progi dla opisujących je współczynników kształtu.



Rys. 3. Wyniki rozpoznawania klasy „krew” sieciami SOM: *normal* i *small*.

Kolor czerwony – wykrycie w obrębie obszaru zaznaczonego interaktywnie, kolor niebieski – wykrycie poza tym obszarem, kolor biały – obszar zaznaczenia interaktywnego, na którym nie wykryto krwi (cały obszar interaktywnie zaznaczony = czerwony+biały).

Kolor czarny oznacza obszar poza zaznaczeniem, na którym nie wykryto krwawienia

Kolorem niebieskim oznaczono obszary, na których wykryto krwawienia, a które nie zostały wskazane podczas interaktywnego zaznaczania. Częściowo obszary te pokrywają się z zaznaczeniami lekarza (por. trzecią kolumnę rys. 3). Jednak w większości przypadków leżą one poza obydwooma zaznaczeniami, wskazując na duże podobieństwo kolorystyczne do obszarów krwawień ze zbiorów uczących. Dla tych obszarów decyzję o akceptacji lub odrzuceniu musi podjąć lekarz. W kilku przypadkach można wskazać ewidentne błędy. Są one widoczne na obrazach w drugiej i czwartej kolumnie na rysunku 3: jako krwawienia sieć wskazała wloty drzewka oskrzelowego. Prawdopodobnie zostało to spowodowane wpływem obrazu uczącego o kodzie 235324, kolorystycznie odmiennego od pozostałych (por. rys. 1).

5. Podsumowanie i wnioski

W ramach prezentowanych badań pokazano przebieg i wyniki eksperymentów dotyczących wykorzystania sieci neuronowych typu SOM do klasyfikacji pikseli na obrazach bronchoskopowych. Cechą, na podstawie której dokonano klasyfikacji, były składowe HSV koloru. Obrazy przeznaczone do uczenia sieci wybrano na podstawie oceny wizualnej. Dla każdego obrazu utworzono zbiór uczący na podstawie zmodyfikowanego zaznaczenia obszaru krwawienia. Zbiory te scalono, przy czym zadbano o wyeliminowanie powstałych sprzeczności. Określono podstawowe parametry sieci SOM w wersji nadzorowanej i przeprowadzono uczenie w dwóch wariantach: dla sieci większych i mniejszych.

Po zakończeniu procesu uczenia zbiorami cząstkowymi dokonano analizy wzajemnego podobieństwa zbiorów uczących. Stwierdzono występowanie różnic pomiędzy prawie wszystkimi zbiorami. Jeden z nich okazał się bardzo odmienny od innych, mimo to został włączony do scalonego zbioru. Dzięki temu wzrosły prawidłowe rozpoznania obszarów krwawień na podobnych obrazach testowych. Skutkiem ubocznym było kilka nieprawidłowych klasyfikacji wlotów drzewka oskrzelowego jako krwawień.

Wyniki rozpoznawania, a w szczególności wykryte nieprawidłowości, stanowią dobry punkt wyjścia do rozważań nad metodologią klasyfikacji. W przyszłości można rozważyć kilka wariantów niżej wymienionych.

- Zrealizować uczenie za pomocą zbiorów powstałych z pojedynczych lub bardzo podobnych do siebie obrazów. Wtedy na etapie rozpoznawania trzeba ocenić podobieństwo klasyfikowanego obrazu do poszczególnych obrazów uczących i przełączyć się na odpowiedni klasyfikator lub na klasyfikator ogólny (powstały na bazie zbioru scalonego).
- Oceniać podobieństwo obrazów przeznaczonych do uczenia sieci i próbować korygować kolory (lub inne parametry) obrazów bardzo odmiennych.
- Obrazy odmiennie dołączać do zbioru uczącego (pamiętając o korygowaniu sprzeczności w danych) i ponownie uczyć sieć.

Podsumowując, należy podkreślić, że osiągnięto dobre wyniki klasyfikacji. Dotyczy to zarówno sieci SOM o większych, jak i o mniejszych rozmiarach. Analiza wizualna wyników

wskazuje na konieczność zastosowania *postprocessingu* wobec wykrytych obszarów. Oprócz operacji morfologicznych skutkujących scalaniem małych obiektów należy zastosować bardziej zaawansowane metody: progowanie pól poszczególnych obiektów, analizę ich kształtu oraz wzięcie pod uwagę położenia wykrytych rejonów względem innych elementów sceny.

Literatura

- [1] Demuth H., Beale M., Hagan M., *Neural Network Toolbox 5 User's Guide*. The MathWorks, Inc., Natick, MA, 1992–2007.
- [2] Duplaga M., Leszczuk M., Przelaskowski A., Janowski L., Zieliński T., *BRONCHOVID – zintegrowany system wspomagający diagnostykę bronchoskopową*. Przegląd Lekarski, t. 64, wyd. spec.: Inżynieria medyczna, 2007, 42–48.
- [3] Giritharan B., Yuan X., Liu J., Buckles B., Oh J.H., Tang S.J., *Bleeding Detection from Capsule Endoscopy Videos*. 30th Annual International IEEE EMBS Conference, Vancouver, British Columbia, Canada, August 20–24, 2008.
- [4] Jung Y.S., Kim Y.H., Lee D.H., Kim J.H., *Active Blood Detection in a High Resolution Capsule Endoscopy using Color Spectrum Transformation*. Proc. International Conference on BioMedical Engineering and Informatics BMEI 2008, May 28–30, Sanya, Hainan, China, 859–862.
- [5] Kohonen T., *Self-Organizing Maps*. Springer Series in Information Sciences, vol. 30. Springer, Berlin, Heidelberg, 1995.
- [6] Lau P.Y., Correia P.L., *Detection of bleeding patterns in WCE video using multiple features*. Proceedings of the 29th Annual International Conference of the IEEE EMBS Cité Internationale, Lyon, France, August 23–26, 2007.
- [7] Lee H.C., *Introduction to Color Imaging Science*. Cambridge University Press, Cambridge, 2005.
- [8] Li B., Meng M.Q.-H., *Computer Aided Detection of Bleeding in Capsule Endoscopy Images*. IEEE Canadian Conference on Electrical and Computer Engineering, Niagara Falls, 2008.
- [9] Mikrut Z., Duplaga M., *Generowanie danych z obrazów bronchoskopowych w celu późniejszej klasyfikacji*. Automatyka (półrocznik AGH), t. 13, z. 3, 2009.
- [10] Mikrut Z., Tadeusiewicz R., *Sieci neuronowe w przetwarzaniu i rozpoznawaniu obrazów*. [w:] Biocybernetyka i inżynieria biomedyczna 2000, t. 6, Sieci neuronowe, AOW EXIT, Warszawa, 2000, 459–493.
- [11] Tadeusiewicz R., *Sieci neuronowe*. Akademicka Oficyna Wydawnicza RM, Warszawa, 1993.
- [12] Vesanto J., Himberg J., Alhoniemi E., Parhankangas J., *Self-organizing map in Matlab: the SOM Toolbox*. [w:] Proceedings of the Matlab DSP Conference 1999, 35–40, Espoo, Finland, November 1999.
- [13] Vesanto J., Himberg J., Alhoniemi E., Parhankangas J., *SOM Toolbox for Matlab 5*. Report A57, Helsinki University of Technology, April 2000.