

Autoreferat

1. Imię i Nazwisko: **Michał Kruk**

2. Posiadane dyplomy, stopnie naukowe – z podaniem nazwy, miejsca i roku ich uzyskania.

- magister inżynier – kierunek informatyka, Wydział Elektryczny, Politechnika Warszawska, 2004, praca magisterska pod tytułem „**Analiza skupień za pomocą metod neuronowych i statystycznych**”, praca oceniona z wyróżnieniem.
- doktor inżynier nauk technicznych w dyscyplinie elektrotechnika, Wydział Elektryczny, Politechnika Warszawska, 2008, rozprawa doktorska pod tytułem: „**Automatyczny system rozpoznawania komórek na podstawie obrazu mikroskopowego wybranej tkanki ludzkiej dla potrzeb diagnostyki medycznej**”, rozprawa oceniona z wyróżnieniem.

3. Informacje o dotychczasowym zatrudnieniu w jednostkach naukowych/ artystycznych.

- 2008 – obecnie – pracownik naukowo dydaktyczny, kierownik Zakładu Systemów Inteligentnych, aktualnie na stanowisku adiunkta, Katedra Zastosowań Informatyki, Wydział Zastosowań Informatyki i Matematyki, Szkoła Główna Gospodarstwa Wiejskiego w Warszawie

4. Wskazanie osiągnięcia* wynikającego z art. 16 ust. 2 ustawy z dnia 14 marca 2003 r. o stopniach naukowych i tytule naukowym oraz o stopniach i tytule w zakresie sztuki (Dz. U. nr 65, poz. 595 ze zm.):

cykl powiązanych tematycznie 13 publikacji pod tytułem:

Zastosowania metod sztucznej inteligencji we wspomaganiu rozpoznania i diagnostyki obrazów biomedycznych

a) (autor/autorzy, tytuł/tytuły publikacji, nazwa wydawnictwa, rok wydania),

1. **MICHAŁ KRUK**, Stanisław Osowski, Robert Koktysz, „Recognition and Classification of Colon Cells Applying the Ensemble of Classifiers”, Elsevier, **Computers in Biology and Medicine**, 2009, 39.2, pp. 156-165
2. **MICHAŁ KRUK**, Stanisław Osowski, Robert Koktysz, „Segmentacja i parametryzacja struktur histologicznych w obrazach mikroskopowych prostaty dla oceny skali Gleasona”, **Przegląd Elektrotechniczny**, 2010, R. 86, nr 5, pp. 5-9
3. **MICHAŁ KRUK**, Stanisław Osowski, Robert Koktysz, „Extraction and parameterization of the glandular ducts in the image of colon in inflammatory bowel

diseases – results of experiments”, **Przegląd Elektrotechniczny**, 2010, R. 86, nr 1, pp. 23-25

4. **MICHAŁ KRUK**, Stanisław Osowski, Robert Koktysz, „Numerical characterization of the images of prostate cancer for recognition of Gleason scale”, **Przegląd Elektrotechniczny**, 2011, 87.5, pp. 81-83
5. Stanisław Osowski, **MICHAŁ KRUK**, Robert Koktysz, Jarosław Kurek, „Image Processing for Localization and Parameterization of the Glandular Ducts of Colon in Inflammatory Bowel Diseases”, rozdział w monografii: **Computational Modeling and Simulation of Intellect: Current State and Future Perspectives**, IGI Global, 2011, pp. 1-24.
6. Tomasz Leś, **MICHAŁ KRUK**, Stanisław Osowski, „Automatic recognition of industrial tools using artificial intelligence methods”, **Expert Systems with Applications**, 2013, 40.12, pp. 4777-4784
7. **MICHAŁ KRUK**, Bartosz Świdorski, Stanisław Osowski, „Box-counting fractal dimension in application to recognition of hypertension through the retinal image analysis”, **Przegląd Elektrotechniczny**, 2013, R. 89 nr 9, pp. 286-289
8. **MICHAŁ KRUK**, Stanisław Osowski, Tomasz Markiewicz, Wojciech Kozłowski, Robert Koktysz, Janina Słodkowska, Bartosz Świdorski, „Nucleolus detection in the Fuhrman grading system for application in CCRC”, **Biomedizinische Technik/Biomedical Engineering**, 2014, 59.1, pp. 79-86
9. **MICHAŁ KRUK**, Stanisław Osowski, Tomasz Markiewicz, Janina Słodkowska, Robert Koktysz, Wojciech Kozłowski, Bartosz Świdorski, „Computer Approach to the Recognition of Fuhrman Grade of Cells in Clear-Cell Renal Carcinoma”, **Analytical and Quantitative Cytopathology and Histopathology**, 2014, 36.3, pp. 147-160
10. Bartosz Świdorski, Stanisław Osowski, **MICHAŁ KRUK**, Jarosław Kurek, „Texture characterization based on the Kolmogorov-Smirnov distance”, **Expert Systems with Applications**, 2015, 42.1, pp. 503-509
11. **MICHAŁ KRUK**, Ryszard Kozera, Stanisław Osowski, Paweł Trzciniński, Lidia Sas-Paszt, Beata Sumorok, Bolesław Borkowski, „Computerized Classification System for the Identification of Soil Microorganisms”, **Applied Mathematics & Information Sciences**, Jan. 2016, 10.1, pp. 21-31
12. **MICHAŁ KRUK**, Bartosz Świdorski, Stanisław Osowski, Jarosław Kurek, Monika Słowińska, Irena Walecka, „Melanoma recognition using extended set of descriptors and classifiers”, **EURASIP Journal on Image and Video Processing**, 2015(1), 1-10
13. Bartosz Świdorski, Stanisław Osowski, **MICHAŁ KRUK**, Walid Barhoumi, „Aggregation of classifiers ensemble using local discriminatory power and quantiles”, **Expert Systems with Applications**, 2016, 46, pp. 316-323

b) omówienie celu naukowego/artystycznego ww. pracy/prac i osiągniętych wyników wraz z omówieniem ich ewentualnego wykorzystania.

1. Wstęp

Tematyka mojej pracy badawczej poczynając od rozprawy doktorskiej z roku 2008 dotyczy metod sztucznej inteligencji i eksploracji danych w zastosowaniu do wspomagania rozpoznawania i klasyfikacji obrazów, głównie obrazów biomedycznych. W szczególności skupia się na problematyce mającej ścisły związek z diagnostyką medyczną w ujęciu patomorfologicznym. Tematy mojej pracy badawczej obejmują:

- wspomaganie automatycznej diagnostyki medycznej na podstawie mikroskopowych obrazów biomedycznych dla takich schorzeń jak nieswoiste zapalenia jelit, rak prostaty, rak jasno komórkowy nerki, czerniak, poprzez zastosowanie metod przetwarzania obrazów z użyciem klasyfikatorów, głównie neuronowych,
- wspomaganie diagnostyki zmian zachodzących w obrazie dna oka przy zastosowaniu metod sztucznej inteligencji i teorii chaosu, w szczególności wymiaru fraktalnego,
- opracowanie uniwersalnych metod segmentacji obrazów biomedycznych, mających zastosowanie w analizie różnorodnych obrazów,
- opracowanie specjalizowanych metod generacji, doboru i selekcji diagnostycznych cech numerycznych dla poprawnej klasyfikacji obrazów,
- opracowanie systemu automatycznej klasyfikacji mikroorganizmów żyjących w glebie na podstawie obrazów mikroskopowych.

Uzyskane przeze mnie osiągnięcia opublikowane zostały w czasopismach z bazy JCR i obejmują szeroki zakres problemów występujących w tematyce automatycznego przetwarzania obrazów biomedycznych, selekcji cech diagnostycznych oraz finalnej klasyfikacji tych obrazów. Główny wysiłek badawczy skupiony został na następujących zagadnieniach badawczych:

- opracowanie algorytmów do automatycznej segmentacji komórek obronnych organizmu występujących w obrazach mikroskopowych jelit,
- opracowanie algorytmów do automatycznej segmentacji cew gruczołowych w obrazach mikroskopowych jelit,
- opracowanie ulepszonych metod klasyfikacji wzorców obrazów biomedycznych,
- opracowanie algorytmu segmentacji, cech diagnostycznych oraz zbudowanie klasyfikatora w systemie do automatycznego wspomagania diagnostyki raka prostaty,
- opracowanie metody opisu obrazów dna oka przy zastosowaniu wymiaru fraktalnego,
- opracowanie nowych rozwiązań deskryptorów numerycznych obrazów na podstawie odległości Kolmogorova-Smirnova,
- opracowanie automatycznego systemu do klasyfikacji narzędzi na podstawie ich obrazu dwuwymiarowego,

- opracowanie automatycznego systemu do rozpoznania i klasyfikacji mikroorganizmów występujących w glebie.

Opublikowane wyniki układają się w jednotematyczny cykl 10 prac opublikowanych w czasopismach znajdujących się w bazie JCR i trzech publikacji spoza tej listy (rozdział w międzynarodowej monografii wydanej w USA, artykuł w Przeglądzie Elektrotechnicznym po usunięciu go z listy JCR oraz w pozycji [11] - **Applied Mathematics & Information Sciences** współczynnik IF został zawieszony po przyjęciu do druku), skupiający się na praktycznych zastosowaniach metod przetwarzania obrazów, selekcji cech oraz sztucznej inteligencji użytej w zadaniach klasyfikacji.

- Artykuły [1,3,5] związane są z przetwarzaniem i rozpoznawaniem mikroskopowych obrazów biomedycznych jelit. Prace związane są z diagnostyką takich schorzeń jak choroba Leśniowskiego-Crohna, Colitis Ulcerosa oraz nieswoiste zapalenia jelit. Materiał do badań pozyskany został z Zakładu Patomorfologii Wojskowego Instytutu Medycznego w Warszawie.
- Prace [2,4] poruszają tematykę automatycznej diagnostyki schorzeń nowotworowych gruczołu prostaty. Przedstawiają opracowany algorytm segmentacji struktur histologicznych oraz klasyfikator do oceny skali Gleasona zaawansowania nowotworu. Prace bazują na materiale pozyskanym z Zakładu Patomorfologii Wojskowego Instytutu Medycznego.
- Publikacje [8,9] dotyczą problematyki związanej z automatycznym rozpoznawaniem skali Fuhrmana w diagnostyce raka jasnokomórkowego nerki. Opisują zarówno budowę automatycznego systemu diagnostycznego jak również proponują skuteczną metodę wykrywania jąder w jądrach nowotworu. Prace powstały we współpracy z Zakładem Patomorfologii Wojskowego Instytutu Medycznego. W pracy [9] porównano również zgodność trzech ekspertów ludzkich między sobą jak również z klasyfikatorem neuronowym.
- Prace [1,4,5,6,7,8,9,11,12,13] dotyczą problematyki klasyfikacji, w szczególności metod eksploracji danych użytecznych w diagnostyce medycznej [1,4,5,7,8,9,12], jak również w zagadnieniach przemysłowych [6] i rolniczych [11].
- Artykuł [8] proponuje nową i skuteczną metodę wykrywania jąder w jądrach raka jasnokomórkowego nerki.
- Publikacje [10,12] są poświęcone nowym opracowaniom deskryptorów numerycznych, które znajdują zastosowanie do opisu tekstur. Jak dowiedziono w pracy deskryptor ten zastosowany do zadania klasyfikacji daje lepsze rezultaty niż klasyczne deskryptory Haralicka. Nowe rozwiązania deskryptorów zostały zastosowane do generacji cech diagnostycznych obrazów biomedycznych, wzbogacając zestaw cech.
- W pracy [11] opisano zastosowanie metod eksploracji danych i klasyfikatorów do rozpoznawania różnych gatunków mikroorganizmów występujących w glebie i mających duży wpływ na jej parametry i jakość. Praca opiera się na danych pozyskanych we współpracy z Instytutem Ogródnictwa w Skierniewicach.
- Praca [12] jest rozpoczęciem nowego i ważnego rozdziału w pracy naukowej habilitanta. Poświęcona jest ona diagnostyce nowotworów skóry, w szczególności czerniakowi. Zastosowano w niej skuteczne i użyteczne zastosowanie deskryptorów opracowanych w pracach [10,12] do wspomagania diagnostyki raka skóry (czerniaka).

Uzyskane przeze mnie osiągnięcia badawcze są powiązane z aktywną współpracą z krajowymi ośrodkami naukowymi: Zakładem Patomorfologii Wojskowego Instytutu Medycznego w Warszawie, Wydziałem Elektrycznym Politechniki Warszawskiej, Instytutem Ogrodnictwa w Skierniewicach oraz Centrum Onkologicznym w Warszawie. Na polu współpracy zagranicznej aktywnie współpracuję z National Engineering School of Carthage, University UVT of Tunis oraz Muğla Sıtkı Koçman University.

2. Zastosowanie metod przetwarzania obrazów i sztucznej inteligencji w obrazach mikroskopowych jelit

Tematyka związana z przetwarzaniem obrazów mikroskopowych jelit, która opracowana została w mojej pracy doktorskiej rozszerzona została w pracach [1,3,5], które ukazały się po obronie doktoratu w 2008 roku. Dotyczy ona zastosowania metod przetwarzania obrazów do segmentacji cew gruczołowych oraz komórek obronnych organizmu jak również klasyfikacji tych ostatnich. Z racji złożoności zadania rozdzieliłem je na dwa mniejsze problemy: segmentacja cew gruczołowych i na ich podstawie wspomaganie diagnostyki schorzenia oraz segmentacja komórek obronnych występujących w podścielisku tkanki i ich klasyfikacja oraz zliczanie.

2.1 Segmentacja cew gruczołowych

Ważnym czynnikiem diagnostycznym jest ocena parametrów cew gruczołowych na zdjęciu mikroskopowym. Cewy zdrowe mają podłużne eliptyczne kształty, bez śladów pączkowania. Przy stanach zapalnych następuje niszczenie cew przez własny układ odpornościowy organizmu, a ich kształt ulega istotnej zmianie: kształt eliptyczny ulega wyraźnemu podziałowi na wiele odrębnych części ułożonych przypadkowo względem siebie i nietworzących charakterystycznego kształtu cewy.

W pracy [5] opisano stworzoną przeze mnie metodę segmentacji cew gruczołowych oraz zaprezentowano autorski algorytm pomiaru odległości pomiędzy nimi. Zaproponowałem również zestaw cech numerycznych, na podstawie których dokonać można rozpoznania obrazu i zaklasyfikować go do jednej z 3 klas: pacjent zdrowy, stan zapalny lekki oraz ciężki. Cechy te posłużyły do uczenia i testowania maszyny wektorów podtrzymujących (SVM) spełniającej rolę klasyfikatora. Osiągnąłem zadowalający z punktu widzenia praktyki medycznej poziom dokładności, który przedstawia macierz rozbieżności klas przedstawiona w Tabeli 1.

Tabela 1. Wyniki klasyfikacji stanów zapalnych jelita na podstawie zdjęcia mikroskopowego wycinka tkanki

Klasa	Stan zdrowy	Stan zapalny lekki	Stan zapalny ciężki
Zdrowy	94.1%	2.63%	3.27%
Stan zapalny lekki	3.35%	92.26%	4.19%
Stan zapalny ciężki	0	2.63%	97.37%

Zaproponowane przeze mnie elementy nowatorskie rozwiązań, których wynik został przetestowany na rzeczywistych danych pochodzących od pacjentów Wojskowego Instytutu Medycznego, można ująć w następujących punktach:


- stworzenie skutecznego algorytmu segmentującego cewy gruczołowe w obrazie,
- opracowanie autorskiej metody pomiaru odległości między cewami w obrazie; opracowana przeze mnie metoda okazała się na tyle uniwersalna, że znalazła również zastosowanie w pracach [2,4] poświęconych analizie obrazów mikroskopowych nowotworów prostaty,
- opracowanie i ewaluacja numerycznych deskryptorów pozwalających na osiągnięcie dobrych wyników klasyfikacji akceptowalnych w praktyce,
- przetestowanie wielu klasyfikatorów (MLP, KNN, RBF, SVM), wybranie najlepszego, którym okazał się być SVM oraz opracowanie parametrów diagnostycznych pozwalających uzyskać najlepsze wyniki klasyfikacji.

2.2 Segmentacja i klasyfikacja komórek obronnych w podścielisku tkanki

Ilość komórek obronnych w podścielisku tkanki świadczy o nasileniu schorzenia. Ważnym czynnikiem diagnozującym jest pojawienie się granulocytów, zwłaszcza obojętnochłonnych. Pomocny w badaniu jest także stosunek odpowiedniego typu komórek do innego - na przykład liczba limfocytów do liczby plazmocytów. Oprócz liczby komórek miara nasilenia stanu zapalnego jelita jest także miejsce ich występowania - czy są to tylko okolice powierzchni czy też cała błona śluzowa aż do mięśnia. Stąd też wykonywane są dwa zdjęcia z każdego preparatu – pierwsze z powierzchni błony śluzowej, drugie z jej głębi. Skład, procentowa zawartość i stosunek liczby poszczególnych rodzajów komórek jest ważnym kryterium oceny schorzenia dla lekarza patomorfologa. Prace [1,3,5] poświęcone są właśnie temu zagadnieniu – automatycznej segmentacji i klasyfikacji komórek występujących w podścielisku tkanki. Prace bazują na zdjęciach mikroskopowych pochodzących od pacjentów Wojskowego Instytutu Medycznego w Warszawie.


Do najważniejszych i nowatorskich osiągnięć mojego autorstwa zaprezentowanych w wyżej wymienionych artykułach zaliczyć można:

- Opracowanie algorytmu dokonującego segmentacji komórek. Opracowany przez mnie algorytm dokonuje poprawnej segmentacji komórek w większości obrazów. Bazuje na metodach morfologii matematycznej, algorytmie k-średnich grupowania oraz metodzie działów wodnych. Argumentem wejściowym dla algorytmu jest rzeczywisty obraz mikroskopowy tkanki natomiast na wyjściu zwracane są wysegmentowane komórki. Zaprezentowano to na Rysunku 1.



Rys. 1. Przykład działania algorytmu segmentującego

- Opracowanie i selekcja cech diagnostycznych najlepiej opisujących poszczególne rodzaje komórek i pozwalających na uzyskanie najlepszych wyników ich rozpoznania.
- Opracowanie integratora klasyfikatorów do klasyfikacji poszczególnych typów komórek. Każdy z klasyfikatorów wyznacza niezależnie przynależność do danej klasy, obarczoną zwykle pewnym błędem. Rozkład statystyczny tego błędu jest różny dla każdego klasyfikatora. System integrujący ma za zadanie takie połączenie wyników klasyfikacji, które zapewni najmniejszy błąd finalny. Opracowałem i przetestowałem różne pojedyncze klasyfikatory oraz różne systemy integracji wyników działania poszczególnych elementów zespołu, w tym: uśrednianie, uśrednianie ważone oraz zastosowanie dekompozycji PCA. Wyniki integracji poprzez dekompozycję PCA pokazały przewagę zespołu klasyfikatorów nad najlepszym pojedynczym klasyfikatorem indywidualnym. Przykład wyników przedstawia Rysunek 2.



Rys. 2. Wyniki integracji klasyfikatorów

3. Diagnostyka schorzeń nowotworowych gruczołu prostaty

Drugim nurtem moich badań było zastosowanie praktyczne metod przetwarzania obrazu i sztucznej inteligencji w diagnostyce raka stercza. Po 80 roku życia nowotwór spotykany jest prawie u każdego mężczyzny (!) – co pokazuje jak ogromna jest ilość danych do przetworzenia przez lekarzy patomorfologów i stąd moje zainteresowanie tą tematyką. Do oceny stopnia zaawansowania raka prostaty stosuje się powszechnie skalę Gleasona. W skali tej mikroskopowemu obrazowi tkanki prostaty przypisuje się liczby od 1 (postać mało zaawansowana, rokowanie dobre) do 5 (postać zaawansowana, rokowanie bardzo złe). Oceny skali dokonuje się na podstawie morfologii cewek występujących w obrazie mikroskopowym tkanki.

W pracy [2] największy nacisk został położony na opracowanie skutecznej metody segmentacji cew w obrazach, które są kluczowym elementem przy ocenie skali Gleasona. Opracowałem skuteczny algorytm wyodrębniania tych struktur histologicznych, który bazuje na metodach morfologii matematycznej.

W publikacjach [2,4] zaproponowałem zestaw cech diagnostycznych do opisu numerycznego wyodrębnionych cew. Jedną z proponowanych przeze mnie cech była odległość między cewami do wyliczenia której użyłem opracowanego wcześniej i opisanego w pracy [5] algorytmu. Cechy te następnie poddałem ewaluacji poprzez wyznaczenie miary Fishera, aby stwierdzić ich przydatność w zadaniu klasyfikacji.

W pracy [4] opracowałem model klasyfikatora SVM, którego zadaniem było określenie skali Gleasona na podstawie podanych na wejściu deskryptorów numerycznych. Po dokonaniu ewaluacji cech wykazałem, że najlepsze wyniki daje ograniczony do 11 (z 17)


cech wektor wejściowy składający. Obniżyło to błąd dokładności klasyfikacji z 15,6% do 3% co odpowiada standardom praktycznej diagnostyki medycznej.

4. Diagnostyka raka jasnokomórkowego nerki

Kolejnym kierunkiem moich badań w dziedzinie praktycznych zastosowań metod sztucznej inteligencji do analizy obrazów biomedycznych były problemy automatycznej diagnostyki raka jasnokomórkowego nerki. Poświęcone temu zagadnieniu są artykuły [8,9].

Do określenia stopnia zaawansowania raka jasnokomórkowego nerki stosuje się skalę Fuhrmana, od jednego do czterech. Skala 1 oznacza nowotwór najmniej zaawansowany, dobrze rokujący, 4 oznacza zaawansowane stadium o złym rokowaniu. Metody określające wartości w skali Fuhrmana bazują na wykrywaniu jąderek w jądrach komórek nowotworów. Im bardziej zaawansowany nowotwór tym jąderko jest większe, posiadające bardziej nieregularny kształt oraz zmienioną strukturę chromatyny. Stąd bardzo istotnym czynnikiem diagnostycznym jest wykrywanie jąderek w jądrach raka jasnokomórkowego nerki.

W pracy [8] opisałem stworzoną przeze mnie skuteczną metodę wykrywania jąderek. Bazuje ona na podobieństwie funkcji paraboloidalnej do funkcji jasności obrazu jąderka. Zobrazowano to na rys. 3.



Rys. 3. Wykres funkcji paraboloidalnej (góra) oraz przykładowe jądro z jąderkiem i ich znormalizowany i odwrócony wykres jasności (dół)

Zaproponowane przeze mnie rozwiązanie problemu wykrywania i segmentacji jąderek polega na przejściu paraboloidalnej funkcji okna przez poszczególne piksele obrazu jądra i określenie podobieństwa między tą funkcją, a fragmentem obrazu, który pokrywa. Proces ten odbywa się iteracyjnie – po każdej iteracji zwiększane jest okno, aż do połowy wielkości obrazu jądra.

W pracy wykazałem, że optymalną wartością podobieństwa (wartością progową) powyżej której można stwierdzić, że jąderko w obrazie istnieje jest wartość 0.5. Wyniki przedstawia Tabela 2.

Tabela 2. Wyniki wykrywania jąderek dla zmieniającego się progu wartości podobieństwa

Wartość podobieństwa	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9	1	Liczba rzeczywistych wskazań przez eksperta
Jąderko	1618	1618	1614	1602	1598	1398	1242	1090	960	848	1618
Bez jąderka	0	128	366	682	878	880	902	932	956	970	970
Błąd	37.48	32.53	23.49	11.75	4.33	11.98	17.16	21.87	25.97	29.75	-

W pracy [9] przedstawiłem zastosowanie sieci SVM do klasyfikacji zaawansowania raka jasnokomórkowego nerki na podstawie zdjęć mikroskopowych wycinka tkanki. Do moich głównych osiągnięć o których mowa w pracy mógłbym zaliczyć:

- Stworzenie skutecznej metody segmentacji jąder w obrazach. Opracowana metoda bazuje na gradiencie oraz algorytmie działów wodnych.
- Opracowanie i selekcja deskryptorów numerycznych, które stanowią bazę do trenowania i testowania klasyfikatora.
- Opracowanie automatycznego systemu diagnostycznego do określenia skali Fuhrmana na podstawie obrazu nerki.

W pracy [9] dokonałem również badania zgodności ekspertów ludzkich (lekarzy patomorfologów) między sobą oraz ze stworzonym systemem do diagnostyki skali Fuhrmana. Dla 100 różnych obrazów, pochodzących od 100 pacjentów lekarze i automatyczny system dokonali niezależnej diagnozy. Wyniki pozwoliły na określenie współczynnika kappa Cohena, który opisuje zgodność między dwiema klasyfikacjami. Wyniki zaprezentowano w Tabeli 3. Wartość powyżej 0.4 jest uważana za satysfakcjonującą.

Tabela 3. Wartości kappa Cohena diagnozy skali Fuhrmana


	System	Ekspert 1	Ekspert 2	Ekspert 3
System	-	0,4246	0,5049	0,4230
Ekspert 1	0,4246	-	0,3660	0,2499
Ekspert 2	0,5049	0,3660	-	0,2476
Ekspert 3	0,4230	0,2499	0,2476	-

5. Zastosowanie metod sztucznej inteligencji i eksploracji danych w zadaniach klasyfikacji obrazów

Kolejnym nurtem moich badań było zastosowanie praktyczne metod sztucznej inteligencji i eksploracji danych w problemach klasyfikacji obrazów. Zaliczyć można do nich zastosowanie tych metod w inżynierii biomedycznej, rolnictwie oraz przemyśle. Główny nacisk w tych pracach położyłem na metody opracowania cech diagnostycznych, wybór ich optymalnego zestawu oraz dobór odpowiedniego klasyfikatora jak też wybór odpowiednich dla niego parametrów.

Jedną z nich jest zastosowanie transformaty PCA do redukcji wymiaru wektora wejściowego dla klasyfikatora różnych klas przy różnym zestawie cech diagnostycznych. Rozwiązanie to w zastosowaniu do diagnostyki medycznej na podstawie mikroskopowego obrazu wycinka tkanki ludzkiej zostało opublikowane w pracach [1,4].

W pracy [1] opisałem stworzony przez siebie integrator pięciu różnych klasyfikatorów, który skuteczniej klasyfikował komórki obronne organizmu niż każdy pojedynczy model wchodzący w skład integratora. Model integratora stworzonego przeze mnie i opisanego w pracy [1] przedstawiono na rys. 4.



Rys. 4. Opracowany model integratora klasyfikatorów

W pracach [1,5,11] zastosowałem różne metody selekcji cech numerycznych. Do metod tych należały: miara Fishera, rzadka regresja logistyczna (Sparse Logistic Regression - SLR), korelacyjna selekcja cech (Correlation Feature Selection - CFS), przyrost informacji (Information Gain - IG), metoda wzajemnej informacji (Mutual Gain - MG), niezależność

statystyczna (Statistical Independence - SI) oraz metoda FCBF (Fast Correlation Based Filter). Wykazałem, że zastosowanie selekcji cech ma duży wpływ na poprawę wyników klasyfikacji. W pracy [11] dokonałem szczegółowej analizy porównawczej różnych metod selekcji cech i ich wpływu na jakość klasyfikacji mikroorganizmów żyjących w glebie dla takich klasyfikatorów jak: SVM (Support Vector Machine), RBF (Radial Basis Function), MLP (MultiLayer Perceptron), RF (Random Forest), KNN (K Nearest Neighbors). W Tabeli 4 przedstawiono wyniki analizy.

Tabela 4. Dokładność klasyfikacji 12 gatunków mikroorganizmów dla wszystkich proponowanych cech oraz wybranych przy użyciu różnych metod selekcji

Klasyfikator	Wszystkie cechy	FCBF	SLR	CFS	FD	SBMLR	IG	MI	SI
SVM	89.80	98.19	92,17	97,34	96,43	93,45	92,79	91,28	91,87
RBF	87.30	94,78	91,23	93,26	91,42	91,39	90,93	91,04	90,22
MLP	83.80	92,97	87,74	92,97	89,12	85,38	86,37	86,29	85,11
RF	89.57	98,41	92,17	97,78	95,31	94,56	93,14	92,41	92,11
kNN	86.58	95,24	90,53	94,67	92,17	88,74	87,35	86,98	87,09

W pracy [7] zaproponowałem skuteczną metodę klasyfikacji obrazów dna oka w diagnostyce nadciśnienia tętniczego. W artykule zaprezentowałem zastosowanie wymiaru pudełkowego do rozpoznania zmian ciśnieniowych poprzez automatyczną analizę obrazu dna oka. Zaproponowana została metoda szybkiego rozpoznania stanu chorobowego rozróżniająca trzy klasy: stan zdrowy, początkowy stan choroby i stan zaawansowany choroby. Przedstawione zostały rezultaty rozpoznania dotyczące 125 przypadków. Zaprezentowana metoda okazała się efektywna do wstępnej klasyfikacji obrazów, ze względu na fakt, że posługuje się tylko jedną wartością (fraktalnym wymiarem pudełkowym), a więc jest szybka i daje poprawne wyniki: 112 poprawnie sklasyfikowanych stanów na 125 (błąd na poziomie 10,4%) oraz błąd na poziomie 7,2% w przypadku podziału na jedynie dwie klasy: zdrowy i chory.


Prace [1,4,5,6,7,9,11,12,13] przedstawiają użycie klasyfikatorów SVM [1,4,5,6,7,9,11,12,13], Random Forest [11], MLP [1,11], RBF [1,11], KNN [1,11] lub metod ich integracji [1,13]. Spośród nich artykuły [1,4,5,9,11,12] bazują na danych rzeczywistych pozyskanych z różnych ośrodków naukowych: mikroskopowe obrazy tkanek z Zakładu Patomorfologii Wojskowego Instytutu Medycznego [1,4,5,9], Centrum Onkologii [12] oraz mikroskopowe obrazy mikroorganizmów żyjących w glebie z Instytutu Ogródnictwa w Skierniewicach [11].

6. Stworzenie deskryptora numerycznego mającego zastosowanie w opisie tekstur

Innym nurtem mojej pracy badawczej było opracowanie skutecznego deskryptora numerycznego do opisu tekstur. Stosowanie istniejących już od dłuższego czasu, popularnych deskryptorów Haralicka, bazujących na macierzy współjawnień (co-occurrence matrix) nie zawsze dawało w pracy badawczej poprawne rezultaty, stąd moje zainteresowanie stworzeniem metody konkurencyjnej. W pracach [10, 12] przedstawiono nowatorskie podejście do generowania numerycznych deskryptorów obrazów tekstur. Bazuje ono na

statystycznej odległości Kołmogorova-Smirnova zastosowanej do jasności pikseli w koncentrycznych pierścieniach utworzonych dla wszystkich możliwych pozycji centralnego piksela w obrazie. Zamiast stosowania statystyki KS do całego obrazu, obraz został podzielony na wiele koncentrycznych promieni i zastosowano statystykę wszystkich kombinacji pierścieni położonych w różnych podobszarach obrazu. Dzięki temu zaproponowano numeryczną charakterystykę obrazu, która lepiej pasuje do znajdowania różnic między poszczególnymi obszarami obrazu należącymi do różnych klas. Podejście to stosuje regresję liniową do krzywej reprezentowanej przez odległość KS pomiędzy jasnością pikseli kolejnych pierścieni a różnymi poziomami geometrycznych różnic między okręgami. Nachylenie krzywej regresji jest traktowane jako deskryptor.

Stworzony deskryptor do opisu obrazów przedstawiających różne rodzaje gruntów został zastosowany do separacji klas i porównany ze standardowymi cechami numerycznymi Haralicka. Wykazano jego przewagę nad deskryptorami Haralicka dla większości klas, co przedstawiono na rys 5. Porównanie zostało przeprowadzone dla 12 różnych klas gruntów z 4 podstawowymi cechami Haralicka: kontrastem (kontrast), korelacją (correlation), energią (energy) oraz jednorodnością (homogeneity).



Rys. 5. Rozkład średnich różnic między wartościami współczynnika dokładności (Accuracy Ratio – AR) deskryptora KS i 4 cech Haralicka: (a) kontrast (con), (b) korelacja (cor), (c) energia (en) i (d) jednorodność (hom) dla 12 rozpoznawanych klas.

7. Wnioski końcowe

Badania przeprowadzone przeze mnie koncentrują się na zastosowaniu metod sztucznej inteligencji, sieci neuronowych i innych algorytmów eksploracji danych do różnych zadań klasyfikacji, w szczególności praktycznych aspektów ich zastosowania w inżynierii biomedycznej. Cechą wspólną łączącą wszystkie zaprezentowane tu rozwiązania jest zastosowanie podobnych narzędzi i metod sztucznej inteligencji, eksploracji danych oraz cyfrowego przetwarzania obrazów.

Większość przedstawionych przeze mnie zagadnień związanych jest z problemami praktycznymi. Eksperymenty numeryczne zostały przeprowadzone na podstawie rzeczywistych danych z dziedziny patomorfologii (mikroskopowe zdjęcia wycinków różnych tkanek pochodziły od rzeczywistych pacjentów) lub biologii (mikroorganizmy glebowe pozyskane z naturalnego środowiska). We wszystkich tych dziedzinach wprowadziłem kilka nowych pomysłów i rozwiązań, które zostały zaakceptowane przez recenzentów w wielu międzynarodowych czasopismach z bazy JCR.

W chwili obecnej głównym nurtem mojej pracy naukowej jest analiza i klasyfikacja obrazów dermatoskopowych znamion skórnych, w szczególności czerniaka. Owocem tej pracy jest ukazanie się wysokopunktowanych artykułów z bazy JCR [12,13]. W pracy tej uczestniczę w dużym zespole naukowym, w którego skład wchodzi naukowcy z SGGW, Uniwersytetu Jagiellońskiego, Politechniki Warszawskiej oraz Centrum Onkologii-Instytut im. Marii Skłodowskiej-Curie. Owocem naszych prac ma być nowoczesny system diagnostyczny, który miałby zastosowanie we wczesnej diagnostyce nowotworów skóry dla lekarzy pierwszego kontaktu. Specyfikacja zakłada implementację na urządzenia mobilne.

Projekt ten zyskał również aprobatę połączonego zespołu recenzentów z NCN i NCBiR i uzyskał finansowanie z projektu TANGO jako wniosek numer TANGO1/266877/NCBR/2015 pod nazwą DermaViewer. Habilitant jest głównym wykonawcą oraz autorem pomysłu projektu. Jest również kierownikiem projektu ze strony SGGW. Oprogramowanie DermaViewer'a zostanie stworzone w oparciu o algorytmy przetwarzania obrazów oraz sztucznej inteligencji i dodatkowo zasilone o kolejne 2000 zdjęć wideodermoskopowych pochodzących z bazy danych pacjentów Kliniki Dermatologii CSK MSW. Zdjęcia przedstawiać będą łagodne zmiany barwnikowe (znamiona barwnikowe, brodawki łojotokowe), czerniaki lub inne nowotworowe zmiany skóry (raki podstawnokomórkowe i kolczystokomórkowe). Zdjęcia kwalifikujące się do analiz charakteryzować się będą następującymi cechami: będą wykonane przy użyciu wideodermatoskopu Fotofinder Systems GmbH, w powiększeniach 20 – krotnych, o rozdzielczości 300 DPI, prawidłowej jakości pod względem jasności i kontrastu. Wszystkie zdjęcia nowotworów skóry będą miały swoje odzwierciedlenie w rozpoznaniu histopatologicznym (a więc będą zweryfikowane). Zdjęcia zostaną zakwalifikowane do określonych grup diagnostycznych: czerniaków, raków skóry, znamion barwnikowych i brodawek łojotokowych. Dodatkowo przekazanych będzie 500 zdjęć makroskopowych zmian skórnych (znamion barwnikowych, czerniaków, raków skóry, brodawek łojotokowych). Nie włączymy do badania zdjęć zmian zlokalizowanych w zakresie aparatu paznokciowego, skóry owłosionej i błon śluzowych. Zdjęcia te poza oczywistą przydatnością w tworzeniu oprogramowania stanowić podstawę dalszych badań nad skutecznymi metodami segmentacji oraz klasyfikacji czerniaka. Dane kliniczne dotyczące chorych przekazane będą w postaci anonimowej po uzyskaniu Zgodny Komisji bioetycznej.