

POLSKA AKADEMIA NAUK

**Instytut Podstawowych
Problemów Techniki**

ROZPRAWA DOKTORSKA

mgr Karol Przystalski

**Detekcja i klasyfikacja barwnikowych zmian skóry na zdjęciach
wielowarstwowych**

Promotor
Prof. dr hab. inż. Maciej Ogorzałek

Warszawa 2014

Podziękowania

Składam serdeczne podziękowania za pomoc oraz wsparcie merytoryczne w trakcie pisania pracy mojemu promotorowi, prof. dr hab. inż. Maciejowi Ogorzałkowi. Szczególnie dziękuję za wykazaną cierpliwość oraz motywację w trudniejszych okresach pisania pracy.

Chciałbym również serdecznie podziękować prof. dr hab. Ewie Grabskiej oraz kolegom i koleżankom z Zakładu Technologii Informatycznych Uniwersytetu Jagiellońskiego, w szczególności dr Katarzynie Grzesiak-Kopeć, dr Piotrowi Oramusowi, dr Grzegorzowi Surówce, dr Leszkowi Bogaczowi, mgr inż. Leszkowi Nowakowi, mgr inż. Marcinowi Pawłowskiemu, mgr Adamowi Górskiemu oraz mgr Grzegorzowi Szońcowi za celne uwagi do treści pracy. Bez ich wsparcia nie byłoby możliwe napisanie niniejszej pracy.

Podziękowania kieruję również do mgr Iwony Grabskiej-Gradzińskiej za wsparcie językowe oraz motywację do pracy nad niniejszą pracą doktorską.

Szczególne podziękowania kieruję do Pani Pauliny Pyki z Face and Body Institute za możliwość skorzystania ze zgromadzonej bazy danych zdjęć wielowarstwowych. Bez tej bazy nie byłoby możliwe przeprowadzenie opisanych w pracy badań.

Podziękowania kieruję również do Ministerstwa Nauki i Szkolnictwa Wyższego za wsparcie finansowe w trakcie realizacji badań. Badania nie byłyby zapewne możliwe, gdyby nie otrzymany grant promotorski N N518 506439.

Mojemu Tacie

Streszczenie

W ciągu ostatnich kilkudziesięciu lat rozwój technologii pozwolił na wprowadzanie coraz nowocześniejszych narzędzi do diagnostyki czerniaka, który jest jednym z najgroźniejszych nowotworów. Z czasem dermatoskopy klasyczne zostały wyparte na rzecz bardziej zaawansowanych urządzeń, takich jak wideodermatoskop oraz SIAscope. Niestety, pomimo coraz lepszych urządzeń, skuteczność diagnostyki lekarzy jest nadal niezadowolająca. Dlatego zaczęto przeprowadzać badania naukowe nad udoskonaleniem procesu diagnostycznego przez wyodrębnienie wcześniej nieznanymi cech znamion barwnikowych oraz zastosowania technik komputerowych, które mogą wspomóc proces diagnostyczny.

Celem pracy jest wykazanie, że fraktalne charakterystyki wielowarstwowych zdjęć znamion mogą być użyteczne w diagnostyce dermatologicznej. Na podstawie zdjęć pozyskanych od krakowskiej kliniki Face and Body Institute numerycznie obliczono wartość wymiaru pudełkowego oraz lakunarność zdjęć znamienia. Otrzymane wyniki porównano z oceną każdej cechy skali Huntera, która stosowana jest powszechnie jako pomoc diagnostyczna przez lekarzy. Przedstawione w pracy badania są pierwszą próbą liczbowej reprezentacji znamion na podstawie zdjęć wielowarstwowych. Zdjęcia wielowarstwowe zostały wprowadzone wraz z pojawieniem się urządzenia SIAscope. Są efektem wykorzystania w procesie fotograficznym oświetlenia o kilku długościach fal światła. Wykorzystanie różnych długości fal światła pozwala na uzyskanie większej ilości informacji odnośnie znamienia.

Wyniki wskazują na użyteczność fraktalnych charakterystyk znamion dla kształtów geometrycznych całości lub segmentów obrazów. Wynika to m.in. z wartości takich miar jakości klasyfikacji jak na przykład pole pod krzywą ROC. Dla cech przy danych testowych obejmujących jedną piątą wielkości zbioru obiektów prawidłowo sklasyfikowano, w zależności od badanej cechy, od blisko 70% nawet do niemal 100% przypadków. Analiza fraktalna daje bardzo dobre wyniki dla cech opartych na zdjęciach obrazujących absorbowanie przez melaninę fal światła ultrafioletowego. Skuteczność wykrywania wynosi od 56% do 95%. Metody fraktalne dają także dobre wyniki dla niektórych cech bazujących na zdjęciach obrazujących absorbowanie fal światła przez kolagen oraz hemoglobinę. Wskazuje to jednoznacznie na możliwość wykorzystania niektórych charakterystyk fraktalnych znamion w procesie diagnostycznym.

Słowa kluczowe: *melanoma, malignant melanoma, czerniak, SIAscope, fraktale, wymiar fraktalny, wymiar pudełkowy, lakunarność, wymiar prześwitów, wymiar perforacji, zdjęcia wielowarstwowe znamion, zdjęcia wielospektralne, maszyna wektorów podpierających, sieci neuronowe, uczenie maszynowe, nowotwór skóry, znamiona skórne*

Abstract

Over the past tens of years the technology improvements made it possible to introduce more advanced diagnostic tools for one of the deadliest cancers which melanoma is. Over time classic dermatoscopes were superseded by more advanced devices like videodermatoscope and SIAscope. Unfortunately, even if better tools are used, doctors' diagnosis success rate is still unsatisfactory low. This was the reason why some research was carried out to improve the diagnostic process by figuring out previously unknown features of pigmented moles that can improve the diagnostic process.

Aim of this study is to demonstrate that fractal characteristics of multilevel lesion images can be useful in dermatological diagnostic. Based on image database obtained from Face and Body Institute Clinic in Krakow, box dimension and lacunarity values of lesion images was calculated. The results were compared to assessment of each feature of Hunter's scale which is commonly used as a diagnostic assesment by doctors. Presented research is the first time attempt when multilevel lesion images was used for a numerical representation of a lesion. Multilevel lesion images were introduced with SIAscope device. Multilevel images are composed in a photographic process with several light wavelengths usage. Using different wavelengths than only visible wavelength light gives more information about the lesion.

The results indicate the usefulness of fractal characteristics lesions of overall geometric shapes or a part of a particular one. It's indicated by such quality measures of the classifier like under the ROC curve. The effectiveness of one-fifth of test data in the database ranges from almost 70% to close to 100%. Fractal analysis gives very good results for features of the images based on the melanin absorbing of ultraviolet light waves. The correctness of the detection ranges from 56% to 95%. Fractal methods also gives good results for some of the features based on images of collagen and hemoglobin absorbing of light waves. Mentioned results clearly indicate that lesion fractal characteristics can be used in diagnostic process.

Keywords: *melanoma, malignant melanoma, SIAscope, fractals, fractal dimension, box dimension, lacunarity, multi-level images, multi-layered images, support vector machine, neural networks, skin cancer, skin lesions*

Spis treści

Wstęp	5
1. Uzasadnienie podjęcia tematu badań – wprowadzenie do analizy znamion barwnikowych	11
1.1. Używane urządzenia diagnostyczne	13
1.2. Liczbowa charakterystyka znamion	16
2. Klasyfikacja obiektów	25
2.1. Wprowadzenie do klasyfikacji obrazów	26
2.2. Wykorzystanie klasyfikatora C-SVM	29
2.3. Wykorzystanie jednokierunkowych sieci neuronowych do klasyfikacji obrazów	31
2.4. Wykorzystanie klasyfikatorów w analizie znamion barwnikowych	32
3. Metody analizy fraktalnej	35
3.1. Wprowadzenie do fraktali	35
3.2. Wymiar pudełkowy	38
3.3. Lakunarność	40
3.4. Zastosowanie metod fraktalnych w analizie znamion barwnikowych	41
4. Metody przetwarzania obrazów	49
4.1. Wstępna obróbka obrazów	49
4.2. Konwersja obrazu RGB do obrazu w odcieniach szarości	50
4.3. Metody binaryzacji	51
5. Analiza wyników	57
5.1. Baza danych	58
5.2. Analiza metod przetwarzania obrazów	60
5.3. Analiza oraz omówienie wyników klasyfikacji cech	65
5.4. Klasyfikacja częściowej oceny znamienia według skali Huntera	77
5.5. Podsumowanie	83
6. Przyszłe badania	85
Bibliografia	87

Wstęp

Sukces w skutecznym leczeniu pacjentów z nowotworami wiąże się przede wszystkim z szybkim zdiagnozowaniem choroby. Dotyczy to zwłaszcza czerniaka, który jest jednym z najgroźniejszych nowotworów [1]. Wczesna diagnoza może oznaczać wyleczenie pacjenta w stu procentach, ponieważ czerniaka można relatywnie łatwo usunąć chirurgicznie. Im później zdiagnozowany nowotwór, tym większe prawdopodobieństwo przerzutów, które doprowadzają do śmierci pacjenta. To, czy po wycięciu czerniaka wystąpią przerzuty, zależy od wielu czynników, między innymi od głębokości naciekania nowotworu w głąb skóry.

Przy analizie znamion bardzo istotna jest ocena lekarza, który bez względu na doświadczenie może podjąć jedną decyzję diagnostyczną, ale postawić dwa rodzaje diagnozy. W przypadku badania znamion barwnikowych decyzja ta jest później porównywana z wynikami badania histopatologicznego potwierdzającego – lub nie – postawioną diagnozę.

Tabela 1: Możliwe decyzje diagnostyczne w stosunku do wyniku badania histopatologicznego

		Wynik badania histopatologicznego	
		złośliwe	niezłośliwe
Diagnoza	złośliwe	Prawdziwie dodatni (<i>ang. true positive</i>)	Fałszywie dodatni, (<i>ang. false positive</i>)
	niezłośliwe	Fałszywie ujemny, (<i>ang. false negative</i>)	Prawdziwie ujemny, (<i>ang. true negative</i>)

Wiersze oznaczają pozytywną lub negatywną diagnozę postawioną przez lekarza. Możliwe diagnozy postawione przez lekarza oraz ich weryfikacje w wyniku badania histopatologicznego przedstawia tabela 1. Kolumny oznaczają charakter złośliwy lub niezłośliwy znamienia. Każda z czterech kombinacji w tabeli 1 składa się z dwóch słów. Pierwsze słowo określa, czy diagnoza jest trafna czy jest błędna. Drugie słowo określa w stosunku do jakiego znamienia została podjęta diagnoza. W Polsce lekarze stosują często angielski zapis skrótów diagnozy i wyniku. Skróty te podane są w nawiasie i oznaczają *true*, *false* oraz *positive*, *negative*. *Positive* określa znamie o charakterze złośliwym, natomiast *negative* określa znamie łagodne. Krzyżując elementy tabeli otrzymujemy wszystkie możliwe kombinacje. Dwie z nich są trafne, a dwie pozostałe nie. Pierwsza mówi o zdiagnozowaniu czerniaka w stosunku do znamienia, które faktycznie jest czerniakiem (*ang. true positive*). Druga możliwość mówi o tym,

że znamię ma charakter łagodny i w badaniu histopatologicznym okazuje się to prawdą (ang. *true negative*). Pozostałe dwie są decyzjami błędnymi, ponieważ lekarz stawia diagnozę czerniaka, a znamię okazuje się łagodne (ang. *false positive*) lub na odwrót (ang. *false negative*). W przypadku *false negative* mamy do czynienia ze znamieniem złośliwym, pomimo tego, że lekarz postawił inną diagnozę. Taka błędna diagnoza jest najbardziej niebezpieczna dla pacjenta. Na podstawie czterech możliwych kombinacji można stworzyć wskaźniki skuteczności lekarzy: swoistość (ang. *specificity*) oraz czułość (ang. *sensitivity*) [2, 3, 4, 5]. Oba wskaźniki obliczane są na podstawie statystyki decyzji, które lekarz podejmuje w trakcie procesu diagnostycznego w stosunku do wyniku badania histopatologicznego.

Swoistość oznacza trafne zdiagnozowanie znamienia, które ma charakter łagodny w stosunku do liczby wszystkich znamion łagodnych, czyli do sumy liczby poprawnie zdiagnozowanych znamion łagodnych oraz liczby znamion błędnie zdiagnozowanych jako złośliwe. Swoistość obliczamy na podstawie wzoru:

$$\text{swoistość} = \frac{TN}{TN + FP} \quad (1)$$

Swoistość oznacza w praktyce skuteczność diagnozowania znamion łagodnych.

Bardziej istotnym wskaźnikiem z punktu widzenia pacjenta jest czułość. Jest to stosunek liczby poprawnie zdiagnozowanych znamion złośliwych do sumy liczby poprawnie zdiagnozowanych znamion złośliwych oraz błędnie zdiagnozowanych znamion łagodnych.

Czułość oblicza się w następujący sposób:

$$\text{czułość} = \frac{TP}{TP + FN} \quad (2)$$

Czułość określa skuteczność wykrywania znamion złośliwych. Menzies w [2] podaje, że dla lekarzy pierwszego kontaktu czułość wynosi jedynie 62% (patrz: tabela 2). W przypadku lekarzy specjalistów wyniki okazują się być nieco lepsze, lecz niezadowalające. Odsetek pacjentów, u których zbyt późno zdiagnozowano czerniaka, jest wciąż wysoki.

Tabela 2: Skuteczność diagnostyki lekarzy

Wiedza medyczna	Czułość	Swoistość
Eksperci	90%	59%
Dermatolodzy	81%	60%
Lekarze po szkoleniu	85%	36%
Lekarze pierwszego kontaktu	62%	63%

Ze względu na niezadowalającą skuteczność lekarzy zaczęto pracować nad metodami oraz oprogramowaniem, którego zadaniem jest wspomaganie lekarzy w diagnostyce. Dotyczy to prawie wszystkich dziedzin medycyny. Jedną z metod wspomagania diagnostyki jest analiza obrazów, którą stosuje się dla zdjęć wykonanych za pomocą standardowego cyfrowego aparatu fotograficznego, jak na przykład w przypadku badań nad tęczówką oka [6, 7, 8, 9], czy obrazów USG, jak na przykład przy badaniach raka piersi czy prostaty [10, 11, 12, 13, 14, 15]. W dermatologii od ponad dziesięciu lat analizuje się zdjęcia wykonane za pomocą wideodermatoskopów [16, 17, 18, 19, 20, 21, 22, 23, 24, 25, 26, 27, 28, 29, 30, 31, 32, 33, 34], czyli urządzeń wykonujących zdjęcia znamion w świetle widzialnym, podobnie jak standardowe aparaty fotograficzne. Relatywnie nowym rozwiązaniem są zdjęcia wykonywane przy oświetleniu źródłami o różnych długościach fal światła. W dalszej części pracy nazywane są one *zdjęciami wielowarstwowymi* (ang. *multilevel images*). Należy tutaj wyjaśnić, że zdjęcia wielowarstwowe to zdjęcia wielospektralne, które pokazują reakcję różnych komórek lub substancji na daną długość fal światła. Dzięki temu uzyskujemy kilka zdjęć, które nazywane są warstwami. Przykładowo, melanina absorbuje światło ultrafioletowe i będzie lepiej widoczna na zdjęciu wykonanym przy wykorzystaniu tego rodzaju oświetlenia. Wykonanie zdjęć przy różnych długościach fal światła pozwala też na sprawdzenie reakcji substancji, które znajdują się w skórze. Dzięki temu zdjęcia dostarczają więcej informacji do analizy. Mimo postępu technologicznego i metodologii analizy, niniejsza praca jest jedną z pierwszych dotyczących badań nad zdjęciami wielowarstwowymi, ponieważ rezultaty diagnostyczne osiągnięte na podstawie zdjęć wykonanych przy oświetleniu falami światła widzialnego wciąż nie przynoszą satysfakcjonujących rezultatów. Pozwala to przypuszczać, że analiza zdjęć wielowarstwowych pozwoli na zwiększenie skuteczności diagnostyki czerniaka.

Teza pracy

W niniejszej pracy stawiana jest teza: **fraktalne charakterystyki wielowarstwowych zdjęć znamion mogą być użyteczne w diagnostyce dermatologicznej i znacząco poprawić skuteczność rozpoznawania nowotworów skóry**. Aby możliwe było udowodnienie stawianej tezy, użyto bazy wielowarstwowych zdjęć znamion udostępnionej w ramach współpracy z firmą Face and Body Institute w Krakowie. Baza zdjęć wielowarstwowych składa się z ponad dziewięciuset przypadków znamion. Niewielki rozmiar bazy wynika z tego, że urządzenie SIAscope jest dostępne dopiero od kilku lat. Dotychczas podjęto próbę analizy zdjęć wielowarstwowych jedynie w przypadku oprogramowania MoleMate. Wspomaga ono operatorów dermatoskopu SIAscope, który jest pierwszym powszechnie dostępnym dermatoskopem wykorzystującym kilka długości fal światła do analizy znamion barwnikowych [35, 36, 37]. MoleMate nie wyodrębnia jednak żadnych cech charakterystycznych w postaci liczbowej. Dotychczas prowadzono badania nad analizą zdjęć stworzonych za pomocą urządzenia SIAscope [38, 39, 40, 41]. Prowadzono również badania nad analizą zdjęć

dermatoskopowych za pomocą metod fraktalnych [42, 43]. W niniejszej pracy po raz pierwszy podjęto próbę liczbowej charakterystyki zdjęć wielowarstwowych za pomocą metod fraktalnych.

Kolejnym krokiem jest wybór algorytmów analizy obrazów, które dotychczas nie były wykorzystywane do analizy zdjęć wielowarstwowych [44]. Do udowodnienia stawianej tezy wykorzystano dwa algorytmy. Pierwszy z nich oblicza wartość lakunarności obrazu (ang. *lacunarity*). Znany jest także w polskiej literaturze pod nazwą wymiaru perforacji lub wymiaru prześwitów. Drugi natomiast oblicza wartość wymiaru pudełkowego (ang. *box dimension*). Wartości uzyskane przy wykorzystaniu obu metod włączono w skład wektora cech dla wspomnianych wcześniej zdjęć wielowarstwowych. Na podstawie tych wartości podjęto próbę wykazania, że charakterystyki fraktalne są istotnymi cechami w diagnostyce czerniaka. Do badania wykorzystano liczbową skalę wykorzystywaną przez lekarzy używających dermatoskopu SIAscope, tzw. skalę Huntera. Badania przeprowadzone na dostępnej bazie znamion pozwalają na wysunięcie wniosków co do zastosowania metod fraktalnych w diagnostyce czerniaka. Metody te wykazują szczególną przydatność przy klasyfikacji takich cech jak wielkość znamienia, nagromadzenie hemoglobiny, naciekanie, pojedyncze naczynia krwionośne, znaczne ubytki kolagenu oraz hemoglobiny. Niestety w niektórych przypadkach charakterystyki fraktalne nie dają zadowalających wyników. Przykładem może być wykrywanie struktury przypominającej zwoje mózgowe, gdzie skuteczność w najlepszym przypadku wynosi jedynie 68%. Dla uproszczenia struktura ta w dalszej części pracy nazywana będzie *zwojami*. Warto tutaj zwrócić uwagę, że czerniak nie jest jedynym nowotworem skóry, a przedstawione w dalszej pracy cechy skal odnoszą się również do innych nowotworów skóry bazujących na znamionach barwnikowych. Czerniak jest jednak uznawany za najgroźniejszy nowotwór skóry [1], a wskaźnik śmiertelności jest co najmniej kilkakrotnie wyższy w porównaniu do innych nowotworów skóry. Dlatego w niniejszej pracy skupiono się na czerniaku.

Średnia skuteczność klasyfikacji niektórych cech jest wyższa niż swoistość oraz czułość określona dla lekarzy. Nie pozwala to na w pełni zautomatyzowaną diagnostykę czerniaka. Dostarcza jednak dodatkowych informacji, które są istotne podczas stawiania diagnozy, co pozwala na usprawnienie diagnostyki oraz na polepszenie wyników lekarzy diagnozujących czerniaka.

Zakres pracy

Treść rozprawy zawarto w pięciu rozdziałach. W rozdziale I na podstawie analizy literatury uzasadniono podjęcie tematu. W rozdziale tym przedstawiono skalę problemu zachorowalności na czerniaka oraz diagnostykę tej choroby. Przedstawiono również metody oraz urządzenia, jakimi posługują się lekarze do oceny znamienia. Istotną częścią są metody wykorzystywane przez lekarzy w procesie diagnostycznym czerniaka, szczególnie skala Huntera. Cechy

znamion, które wchodzą w skład skali Huntera, są punktem odniesienia w ocenie zastosowania metod fraktalnych w procesie diagnostycznym. Wybór skali Huntera wynika z tego, że jako jedyna opiera się na zdjęciach SIAscopowych. Jak wspomniano wcześniej, istotą zdjęć wielowarstwowych jest dostarczenie większej ilości informacji dzięki pięciu zdjęciom znamienia uzyskanym przy oświetleniu za pomocą różnych długości fal światła. Spośród opisanych w rozdziale I zdjęć, w dalszej części pracy wykorzystywane są jedynie cztery zdjęcia: warstwy melaniny, hemoglobiny, kolagenu oraz naciekania.

Diagnostyka czerniaka przedstawiona wcześniej jest przykładem problemu klasyfikacji. Na podstawie uzyskanej pary wartości wymiarów fraktalnych podjęto próbę przypisania znamionom cech skali Huntera. W rozdziale II opisano dwa wybrane klasyfikatory: maszynę wektorów podpierających oraz sieci neuronowe. W badanych przypadkach klasyfikatory mają charakter binarny, ponieważ podejmowane decyzje „zdrowy”/„chory” mają charakter binarny. Dla porównania podjęto próbę sklasyfikowania znamion i porównania rezultatów z oceną według skali Huntera. Istotną częścią przedstawionych metod jest opisany w rozdziale II sposób doboru bazy testowej oraz treningowej. Aby uzyskać jak najlepsze wyniki wykorzystano opisaną metodę krosvalidacji.

Istotą rozdziału III jest przedstawienie metod fraktalnych, które zostały wykorzystane w badaniach. Wyznaczenie charakterystyk fraktalnych znamion w założeniach powinno pozwolić na przypisanie w procesie klasyfikacji (patrz: rozdział II) znamionom cech wchodzących w skład skali Huntera. Jak wspomniano wcześniej, wyznaczenie charakterystyk fraktalnych poszczególnych znamion możliwe jest na podstawie obrazu binarnego zdjęcia warstwy znamienia, której dotyczy dana cecha. W dalszej części rozdziału przedstawiono dwie metody fraktalne: obliczenie wartości wymiaru pudełkowego oraz lakunarności. Obie wartości wyliczane są dla każdego znamienia z osobna dla obrazu binarnego uzyskanego przy wykorzystaniu progu ustalonego za pomocą jednej z przedstawionych w rozdziale IV metod binaryzacji. Dzięki temu wartości wymiaru pudełkowego oraz lakunarności wyznaczone są na podstawie ponad czterdziestu obrazów binarnych, każdy uzyskany za pomocą innej metody binaryzacji. Każda para wartości wymiaru pudełkowego oraz lakunarności jest w dalszej części pracy określana mianem charakterystyki fraktalnej znamienia.

W rozdziale IV opisano metody przetwarzania obrazów. Przedstawione metody są wykorzystywane do konwersji zdjęć każdej z czterech warstw w celu uzyskania obrazu monochromatycznego. Na podstawie obrazu monochromatycznego wyznaczany jest histogram. Znaczną część rozdziału poświęcono metodom binaryzacji obrazów monochromatycznych. Na podstawie histogramu można wyznaczyć próg binaryzacji. Wyznaczone progi pozwalają na oddzielenie struktury znajdującej się na zdjęciu od tła. Na podstawie obrazu binarnego możliwe jest obliczenie wartości wymiarów fraktalnych opisanych w rozdziale III. Wybór

obrazów binarnych do obliczenia wartości wymiaru fraktalnego jest uwarunkowany tym, że metody opisane w pracy powinny działać szybko na urządzeniach mobilnych.

W rozdziale V opisano zastosowanie metod binaryzacji, metod fraktalnych oraz wyniki klasyfikacji cech znamion wynikające z zastosowania wspomnianych metod oraz klasyfikatorów. Istotną częścią rozdziału są wnioski płynące z zastosowania metod binaryzacji. Zastosowanie tylko niektórych metod binaryzacji pozwala na uzyskanie zadowalających wyników klasyfikacji. W kolejnej części rozdziału omówiono wyniki klasyfikacji. Znaczna część poświęcona jest wynikom przypisania znamionom cech skali Huntera. Jednocześnie porównano wyniki klasyfikacji przy zastosowaniu obu przedstawionych w rozdziale II klasyfikatorów. W ostatniej części przedstawiono wnioski potwierdzające stawianą w pracy tezę.

1. Uzasadnienie podjęcia tematu badań – wprowadzenie do analizy znamion barwnikowych

Czerniak dotyka wszystkich ludzi bez względu na wiek, płeć czy kolor skóry. W statystykach widoczne są dwa wskaźniki, na które warto zwrócić szczególną uwagę: wskaźnik zachorowalności oraz wskaźnik śmiertelności pacjentów. Pierwszy z nich wyrażony jest najczęściej jako liczba zdiagnozowanych przypadków na sto tysięcy osób rocznie. Rzadziej podawany jest jako całkowita liczba zachorowań w stosunku do populacji danego kraju. Drugi wskaźnik tj. śmiertelność wśród pacjentów chorych na czerniaka może być podawany w trzech formach: jako liczba przypadków śmiertelnych na sto tysięcy osób rocznie, procentowo jako stosunek śmiertelnych przypadków do wszystkich przypadków wykrycia czerniaka rocznie lub liczbowo w stosunku do populacji danego kraju rocznie. Najczęściej na czerniaka zapadają osoby o jasnych włosach i niebieskich oczach. Dlatego też do krajów, gdzie czerniak stanowi poważne zagrożenie, należą kraje europejskie, Stany Zjednoczone oraz Australia. Osoby o ciemnej karnacji skóry lub czarnej skórze także są narażone na czerniaka, jednak wśród tych osób odsetek pacjentów dotkniętych tym nowotworem jest niewielki i stanowi problem marginalny. Ze względu m.in. na karnację ryzyko zachorowalności na czerniaka określa przynależność do grupy fototypu skóry (patrz: tabela 1.1). Fototypy zostały opisane w [45].

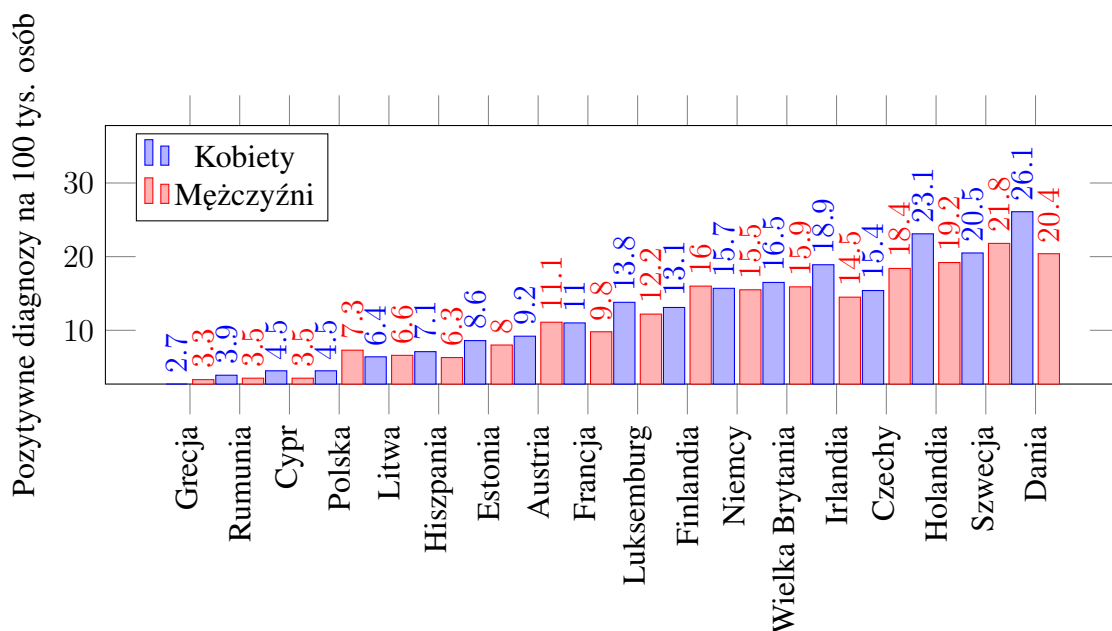
Tabela 1.1: Fototypy skóry człowieka

Typ	Cechy	Reakcja na światło
I	Błada biała skóra, liczne piegry, włosy blond/rude, niebieskie/zielone oczy	Zawsze ulega oparzeniom, trudno się opala
II	Błada skóra, niebieskie/zielone oczy	Łatwo ulega oparzeniom, trudno się opala
III	Ciemniejsza biała skóra	Opala się po początkowym oparzeniu
IV	Jasnobrązowa skóra	Oparzenia minimalne, opala się łatwo
V	Brązowa skóra	Rzadko ulega oparzeniom, mocno się opala
VI	Ciemnobrązowa/czarna skóra	Nie ulega oparzeniom, zawsze się mocno opala

Najbardziej narażone są osoby z fototypem I, najmniej z VI.

W Stanach Zjednoczonych w 2011 roku zanotowano roczny wzrost zachorowalności o 3,1% (wg *American Cancer Society*). Zgodnie z [46] w roku 2011 tylko w Stanach Zjednoczonych zdiagnozowano czerniaka u 76250 pacjentów. Wskaźnik śmiertelności wynosił tutaj w 2008 roku 8420 pacjentów na populację [47].

W Europie problem jest niewiele mniejszy niż w Stanach Zjednoczonych. Przykładowo, w Wielkiej Brytanii w 2008 roku czerniaka zdiagnozowano u około 11800 pacjentów (dane za [48]). W 2008 roku na terenie Wielkiej Brytanii na sto tysięcy osób przypadało średnio szesnaście przypadków zdiagnozowanych czerniaków [48]. Wielka Brytania jest jednak w czołówce zachorowalności na czerniaka w Unii Europejskiej (patrz: rysunek 1.1). Na wykresie widać różnice między krajami południowej i północnej Europy. Związane jest to z dominacją określonych fototypów skóry w populacji. W Unii Europejskiej śmiertelność z powodu czerniaka wynosi 6000 pacjentów na populację rocznie [49].



Rysunek 1.1: Częstość występowania czerniaka w krajach europejskich

W porównaniu z wcześniej wspomnianymi krajami, w Australii problem czerniaka jest na tyle poważny, że instytucje rządowe angażują się w akcje uświadamiające o ryzyku zbyt długiego przebywania na słońcu. Dla rdzennych mieszkańców Australii problem czerniaka jest marginalny, natomiast dla potomków emigrantów istotny. Wynika to głównie z wpływu dziury ozonowej, gdyż promieniowanie UV jest groźne dla ludzi o jasnej karnacji skóry. Warto tutaj dodać, że ekspozycja na promieniowanie UV może być powodem powstania zarówno czerniaka jak i innych nowotworów skóry. Zgodnie z tym co podaje *Australian Institute of Health and Welfare* [50], u dwóch na trzech Australijczyków przed siedemdziesiątym rokiem życia zostanie

zdiagnozowany jeden z nowotworów skóry. Spośród nowo zdiagnozowanych nowotworów w Australii około 80% stanowią nowotwory skóry. Szacuje się, że rocznie diagnozuje się w Australii około 10300 nowych przypadków czerniaka, a z powodu przerzutów związanych z czerniakiem umiera tam rocznie około 1300 pacjentów (za [50]).

Niestety, wskaźniki zachorowalności oraz śmiertelności, pomimo rozwoju technologii, z roku na rok rosną. Wskaźnik zachorowalności zależy od stopnia ekspozycji na czynniki ryzyka. Wzrost wskaźnika śmiertelności wynika przede wszystkim z tego, że pacjenci trafiają na leczenie w zaawansowanym stadium choroby, co założy w dużej mierze od stopnia świadomości pacjentów, którzy zbyt późno zgłaszają się do lekarza. Istotny wpływ na śmiertelność ma również wiedza lekarzy pierwszego kontaktu. Ostatecznie wskaźnik śmiertelności wzrasta również ze względu na jakość metod diagnostycznych.

1.1. Używane urządzenia diagnostyczne

Dermatolodzy w procesie diagnostycznym wykorzystują narzędzia do obserwacji znamion. Im bardziej zaawansowane narzędzia, tym większe prawdopodobieństwo poprawnego wykrycia czerniaka. Najczęściej stosowanym narzędziem do obserwacji znamion są dermatoskopy. Istnieje wiele rodzajów dermatoskopów ([51, 52, 53, 54, 55, 56, 57, 58, 59, 60, 61, 62, 63]), natomiast dermatoskopy można podzielić na kilka głównych typów:

1. dermatoskopy klasyczne,
2. wideodermatoskopy,
3. dermatoskopy mobilne,
4. dermatoskopy wykorzystujące różne długości fal światła.

Dermatoskop klasyczny jest to urządzenie zbudowane na bazie szkła powiększającego wspomaganego źródłem światła. Wśród dermatoskopów klasycznych bardzo popularne są te produkowane przez firmę Heine. Firma ta opatentowała [64] dermatoskop klasyczny w formie jak na zdjęciu 1.2a. Oświetlenie wykorzystywane w tych dermatoskopach generowane jest za pomocą diod LED lub lampy halogenowej. Dodatkowo, w przypadku dermatoskopów klasycznych, wykorzystywany jest najczęściej olejek imersyjny. Celem wykorzystania olejku jest uzyskanie efektu soczewki imersyjnej, która zapobiega załamaniu światła. Pozwala to na polepszenie skuteczności obserwacji obrazu. Wynalezienie dermatoskopu było krokiem milowym w diagnostyce chorób skóry. Pozwoliło na znaczne obniżenie wskaźnika śmiertelności.

Kolejny etap w rozwoju urządzeń do obserwacji znamion barwnikowych stanowią wideodermatoskopy. Są to relatywnie drogie urządzenia, które wraz z dermatoskopem posiadają dołączony komputer stacjonarny oraz często również drukarkę. Przykładowy wideodermatoskop pokazano na rysunku 1.2b. Lekarz dokonuje obserwacji na podstawie

zdjęcia wyświetlonego na monitorze, a nie w sposób bezpośredni, jak to ma miejsce w przypadku dermatoskopów klasycznych. Dodatkowo urządzenia te są dostarczane wraz z oprogramowaniem. Posługiwanie się oprogramowaniem w celu obserwacji znamienia daje ogromne możliwości w porównaniu do dermatoskopów klasycznych. Oprogramowanie pozwala na dokumentowanie badań, zapisywanie zdjęć oraz danych pacjentów. Umożliwia także zapamiętywanie lokalizacji znamion na ciele pacjenta [65, 66]. Dzięki takiej funkcjonalności możliwe jest dokładniejsze zbadanie znamienia i precyzyjniejsza analiza. Pozwala przede wszystkim na obserwację znamienia w czasie, co jest szczególnie istotne podczas badania pod kątem czerniaka. Dodatkowo, obsługa wideodermatoskopu jest prostsza, ponieważ nie wymaga użycia olejku imersyjnego, bowiem fale światła wykorzystane w wideodermatoskopach są spolaryzowane, a to daje podobny efekt jak użycie olejku imersyjnego.

Wideodermatoskopy były ogromnym osiągnięciem, ponieważ pozwalały m.in. na zapisywanie zdjęć znamion. Pomimo jednak wielu innowacyjnych rozwiązań, badania za pomocą tych urządzeń można było wykonać jedynie stacjonarnie. Rozwiązaniem tego problemu było wprowadzenie dermatoskopów mobilnych. Dermatoskopy mobilne ([67, 68, 69, 70]) charakteryzują się przede wszystkim niewielkimi gabarytami. Przykład takiego urządzenia pokazano na rysunku 1.2d. W odróżnieniu od dermatoskopów klasycznych, wykorzystują oświetlenie takie jak w wideodermatoskopach. Dodatkowo dermatoskopy mobilne można podłączyć do standardowego cyfrowego aparatu fotograficznego, co pozwala na wykonanie oraz zapisanie zdjęcia znamienia. Dzięki temu możliwe było osiągnięcie



Rysunek 1.2: Dermatoskopy, źródła: a) <http://www.heine.com/>, b) <http://www.vidix.it/>, c) <http://simsys-molemate.com/>, d) oraz e) <http://www.dermlite.com/cms/>


tej samej funkcjonalności co w przypadku wideodermatoskopów – przy dużo mniejszych rozmiarach. Takie rozwiązanie nie pozwoliło na udoskonalenie procesu diagnostycznego, natomiast pozwoliło na zastosowanie wideodermatoskopów w terenie.

Udoskonalenie procesu diagnostycznego było możliwe dopiero po wprowadzeniu tak zwanych przystawek do dermatoskopów mobilnych. Przystawki pozwalają na podłączenie do dermatoskopu urządzeń łączących fotografię z przetwarzaniem obrazów, takich jak telefony komórkowe. Przykładem połączenia telefonu komórkowego z dermatoskopem jest przystawka HandyScope (<http://www.handyscope.net/>) lub DermLite (<http://www.dermlite.com/cms/en/products/accessories/connection-kit-5.html>). Na rysunku 1.2c pokazano przystawkę do telefonu iPhone 4S. Urządzenia takie jak iPhone mają dostatecznie dobry aparat, aby można było wykorzystać zdjęcia w procesie diagnostycznym. Udoskonalenie procesu diagnostycznego możliwe jest dzięki rozwojowi oprogramowania, którego można użyć na telefonach komórkowych. Wykorzystanie telefonu komórkowego ma jeszcze jedną zaletę, pozwala rozwijać oprogramowanie do dermatoskopów niezależnym dostawcom. Do tej pory powstało kilkanaście aplikacji. Wśród nich są także takie, które pozwalają na znajdowanie cech zdjęć znamienia.

Ostatnim rodzajem dermatoskopów są urządzenia takie jak SIAscope [71]. Jest to urządzenie, którego cechą charakterystyczną jest tworzenie i zapisywanie zdjęć uzyskanych przy oświetleniu skóry światłem o różnych długościach fal. Jak wspomniano we wstępie, zdjęcia wielospektralne nazywane będą w dalszej części pracy zdjęciami wielowarstwowymi, ponieważ pokazują one reakcję skóry na fale światła o innej długości niż fale światła widzialnego, co daje efekt warstw skóry. Na rysunku 1.3 opisano, jak powstają zdjęcia wielowarstwowe.

SIAscope pozwala na wykonanie oraz analizę znamienia na podstawie pięciu typów zdjęć, które wykonywane są za pomocą kilku długości fal światła. Światło ultrafioletowe pozwala na uzyskanie zdjęcia, na którym uwidocznione zostaną skupiska melaniny. Inne substancje takie jak hemoglobina czy kolagen absorbują inne długości fal światła (patrz: rys. 1.4). Ostatnie zdjęcie pokazuje głębokość naciekania, która jest efektem nałożenia kilku zdjęć. SIAscope, dzięki innowacyjnemu podejściu umożliwiającemu pozyskanie większej ilości danych na temat znamienia, pozwala na bardziej precyzyjną diagnozę, co powinno przełożyć się na obniżenie wskaźnika śmiertelności.

Na rysunku 1.4 widoczne są cztery wykresy przedstawiające poziom absorpcji fal światła przez komórki skóry człowieka. Czarnym kolorem oznaczono wykres absorpcji fal światła przez melaninę. Widać wyraźnie, że melanina reaguje na fale światła ultrafioletowego. Kolorem niebieskim oznaczono absorpcję fal światła przez kolagen. Kolagen, podobnie jak melanina reaguje na fale światła ultrafioletowego. Wykresy oznaczone kolorem czerwonym oraz zielonym oznaczają hemoglobinę utlenowaną oraz odtlenowaną. Wyraźnie widoczne są dwa

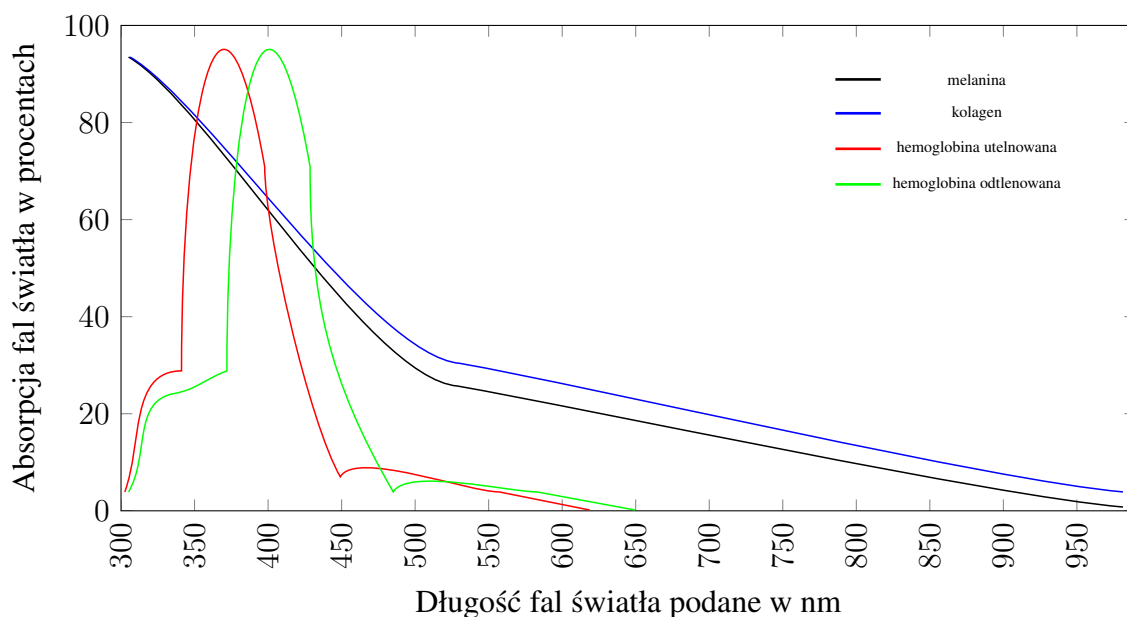


Rysunek 1.3: Uwidocznione odbicie fal światła oraz reakcji kolagenu, melaniny oraz hemoglobiny na fale światła o różnej długości dające efekt warstw

wzniesienia dla fal światła bliskiego ultrafioletu oraz fal światła widzialnego. Istotny jest fakt, że hemoglobina w ogóle nie reagują na fale światła podczerwieni.

1.2. Liczbowa charakterystyka znamion

Lekarze opracowali kilka metod pozwalających na liczbową charakterystykę badanych znamion. Liczbowe charakterystyki nazywane są przez nich skalami, według których mierzy się czy badane znamię ma charakter złośliwy. Skale różnią się sposobem oceny, natomiast opierają się na podobnych wyodrębnionych cechach znamienia. Na podstawie liczbowej charakterystyki podejmowana jest decyzja, czy dane znamię zakwalifikować jako znamię łagodne, podejrzane, czy złośliwe. Z punktu widzenia klasyfikacji obrazów, liczbowa charakterystyka znamion pozwala na zautomatyzowanie co najmniej części procesu diagnostycznego. Dodatkowo, możliwe jest dodanie nowych cech do danej skali, jeżeli cecha taka ma istotny wpływ na poprawę skuteczności diagnostyki. Liczbowe charakterystyki istniały zanim stworzono takie urządzenia jak wideodermatoskopy czy SIAscope. Ich rozwój widoczny jest na przestrzeni ostatnich dwudziestu lat. W dalszej części rozdziału przedstawiono najczęściej stosowane skale.



Rysunek 1.4: Wykres poziomu absorpcji fal światła przez komórki skóry człowieka. Dalsze objaśnienia w tekście

Skala ABCD

W przypadku czerniaka lekarze posługują się najczęściej skalą ABCD. Została ona zaproponowana i opisana w [72]. W wyniku jej zastosowania możliwe jest obliczenie wskaźnika TDS (ang. *Total Dermatoscopy Score*), który określa, czy znamię ma cechy wskazujące na czerniaka, czy nie. Wskaźnik ten można obliczyć za pomocą wzoru:

$$TDS = A * 1,3 + B * 0,1 + C * 0,5 + D * 0,5 \quad (1.1)$$

Zmienne we wzorze określają odpowiednio:

- A (ang. *assymetry*) – asymetria znamienia,
- B (ang. *border*) – równomierny/nierównomierny brzeg znamienia,
- C (ang. *colour*) – liczba występujących kolorów,
- D (ang. *differential structure*) – liczba struktur różnicujących dla czerniaka.

Każda zmienna może przyjąć różne wartości w zależności od badanego znamienia. Przedziały zmienności podano w drugiej kolumnie tabeli 1.2.

Z asymetrią (A) mamy do czynienia w zakresie konturu, koloru oraz struktury. Należy przyznać jeden punkt dla każdej asymetrii, ale nie więcej niż dwa. Brzegi (B) liczy się dzieląc znamię liniami: pionową, poziomą oraz dwiema liniami pod kątem 45° w taki sposób, aby punkt przecięcia linii był środkiem znamienia. Dzięki temu powstanie osiem segmentów.

Tabela 1.2: Skala ABCD

Cecha	Wartości	Mnożnik	Wynik
Asymetria	0-2	1,3	0,0-2,6
Brzeg	0-8	0,1	0,0-0,8
Kolory	1-6	0,5	0,5-3,0
Wzorce	1-5	0,5	0,5-2,5

W każdym segmencie należy sprawdzić, czy brzegi nie są postrzępione. Za każdy brzeg znamienia w segmencie, który nie jest równy/łagodny należy dodać jeden punkt. Kolor (C) jest najłatwiejszy do wykrycia. Należy przyznać jeden punkt za każdy z poniższych kolorów widocznych na obrazie znamienia:


- cielisty (kolor identyczny jak otaczającej skóry),
- czarny,
- ciemnobrązowy,
- jasnobrązowy,
- czerwony,
- niebieski.

Ostatnią składową są struktury różnicujące (D). Istnieje kilka określeń oraz tłumaczeń określających struktury różnicujące. W literaturze spotyka się tłumaczenie tego pojęcia jako wzorce (ang. *patterns*) lub cechy (ang. *features*). Istnieje także tłumaczenie mówiące wprost, że są to cechy charakteryzujące czerniaka. Struktury różnicujące to zbiór cech, które charakteryzują czerniaka. Są one związane z teksturą widoczną na obrazie. Takich cech jest wiele [73], natomiast skala ABCD określa jasno pięć punktowanych cech:

- siatka barwnikowa (ang. *pigment network*),
- przestrzeń niestrukturalna (ang. *structureless areas*),
- kropki (ang. *dots*),
- globulki (ang. *aggregated globules*),
- smugi (ang. *branched streaks*).

Podobnie jak powyżej, dla każdej wykrytej cechy należy przyznać jeden punkt. Poza strukturami wymienionymi powyżej, istnieje wiele innych. Wiele z nich zostało opisanych w [74, 75].

Można łatwo zauważyć, że najmniej istotną zmienną są brzegi znamienia, natomiast najistotniejszą asymetria. Wystarczy, że znamię jest asymetryczne, posiada dwie cechy



Rysunek 1.5: Znamię wykazuje cechy charakterystyczne dla czerniaka takie jak: kilka kolorów, brak symetrii, wielkość powyżej 6 mm – źródło: baza dostarczona przez Face and Body Institute

charakterystyczne dla czerniaka oraz trzy kolory – i już można je uznać za znamię podejrzanę. Wartość wskaźnika TDS poniżej 4,76 sugeruje znamię łagodne. Powyżej wartości 5,45 oznacza wysokie prawdopodobieństwo znamienia o charakterze złośliwym. Znamiona, których wartości TDS znajdują się w przedziale między 4,76 a 5,45, uznawane są za znamiona podejrzaną i zaleca się zabieg chirurgiczny lub obserwację.

Dla przykładu, na rysunku 1.5 pokazane jest znamię, które w skali ABCD uzyskało wartość TDS równą 4,8. Znamię nie jest symetryczne względem osi pionowej oraz poziomej. Ma nieregularny brzeg w co najmniej dwóch miejscach oraz cztery kolory. Na zdjęciu widoczna jest też co najmniej jedna struktura różnicująca.


W literaturze istnieją także modyfikacje skali ABCD. Jedną z nich jest skala, gdzie D (ang. *diameter*) odpowiada za wielkość znamienia. Oznacza to, że D jest tym większe, im większe jest znamię. Warto zwrócić uwagę na to, że charakterystyczną granicą dla czerniaka są znamiona większe niż 6 mm. Istnieje także modyfikacja ABCDE, gdzie do standardowej skali dodana jest kolejna zmienna E (ang. *evolution*) [76]. W przypadku E nie ma możliwości przypisania konkretnej wartości, ponieważ zmienna ta mówi o zmianach znamienia w czasie. Wymaga to od lekarza dysponowania zdjęciami znamienia wykonanymi w odstępie czasowym. To wiąże się z koniecznością posiadania odpowiedniego oprogramowania oraz dermatoskopu. W większości przypadków zmiana znamienia w czasie oznacza znamię podejrzaną i jest ono

często usuwane chirurgicznie.


Skala Huntera

SIAscope jest urządzeniem, które jako pierwsze odniosło komercyjny sukces w diagnostyce czerniaka jako dermatoskop wykorzystujący różne długości fal światła. Do tego urządzenia dołączone zostało oprogramowanie MoleMate. Założenie tego zestawu jest takie, że oprogramowanie powinno pozwalać na obsługę i wstępną diagnostykę znamienia przez osoby nie będące dermatologami. Wykorzystuje ono tak zwaną skalę Huntera [77] do diagnostyki. MoleMate pozwala w sposób półautomatyczny na postawienie wstępnej diagnozy zadając badającemu kilka prostych pytań. Jako odpowiedź oczekuje jedynie stwierdzeń „tak” lub „nie”, co bardzo upraszcza proces diagnostyczny. Dodatkowo do każdego pytania dołączone są przykładowe zdjęcia znamion posiadających cechę, której dotyczy pytanie. Skala ta daje wynik w zakresie od zera do trzynastu punktów, a punkty liczone są za każde pytanie po jednym, za wyjątkiem ostatniego pytania, gdzie można przyznać do sześciu punktów. Pytania na które należy odpowiedzieć to:

- czy na zdjęciu widoczne są jasne kropki? – pytanie dotyczy zdjęcia o rozdzielczości 672x672 pikseli, które ukazuje absorpcję fal światła przez kolagen (patrz: rysunek 1.6a),
- czy na zdjęciu widoczne są *zwoje*? – pytanie dotyczy zdjęcia o rozdzielczości 672x672 pikseli, które ukazuje absorpcję fal światła ultrafioletowego przez melaninę (patrz: rysunek 1.6b),
- czy na zdjęciu widoczne są czerwone obszary (nagromadzenie hemoglobiny)? – pytanie dotyczy zdjęcia o rozdzielczości 672x672 pikseli ukazuje absorpcję fal światła przez hemoglobinę (patrz: rysunek 1.6c),
- czy na zdjęciu widoczne są jaskrawe kolory? – pytanie dotyczy zdjęcia o rozdzielczości 672x672 pikseli, które ukazuje głębokość naciekania w głąb (patrz: rysunek 1.6d),
- czy na zdjęciu widoczne są naczynia krwionośne? – pytanie dotyczy zdjęcia o rozdzielczości 672x672 pikseli, które ukazuje absorpcję fal światła przez hemoglobinę (patrz: rysunek 1.6e),
- czy na zdjęciu widoczne są ubytki hemoglobiny (białe obszary)? – pytanie dotyczy zdjęcia o rozdzielczości 672x672 pikseli, które ukazuje absorpcję fal światła przez hemoglobinę (patrz: rysunek 1.6f),
- czy znamię jest większe niż 6 mm? – pytanie dotyczy zdjęcia o rozdzielczości 1400x1400 pikseli, które ukazuje znamię w świetle widzialnym; maksymalny możliwy rozmiar na zdjęciu to 11 mm,



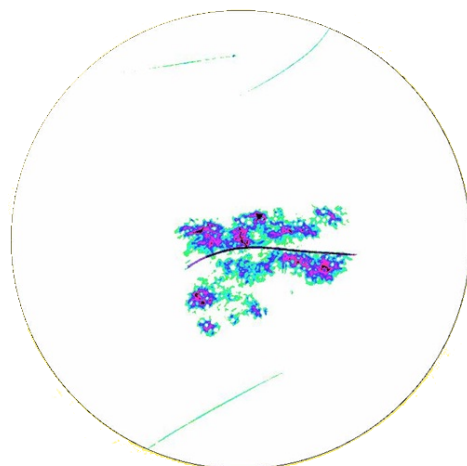
(a) Cecha: jasne kropki na warstwie kolagenu




(b) Cecha: zwoje




(c) Cecha: nagromadzenie hemoglobiny widoczne jako czerwony plamy



(d) Cecha: znaczne naciekanie w głąb



(e) Cecha: widoczne pojedyncze naczynia krwionośne (czerwone nitki)



(f) Cecha: ubytki hemoglobiny (białe plamy)

Rysunek 1.6: Zdjęcia wykazujące pozytywne cechy wg skali Huntera – źródło: baza dostarczona przez Face and Body Institute

Tabela 1.3: Głębokość naciekania wyrażona w stopniach w skali Clarka

Stopień	Głębokość
I	melanoma <i>in situ</i> – zmiany dotyczą jedynie warstwy naskórka (ang. <i>epidermis</i>)
II	zmiany naciekają do wyższej warstwy skóry (ang. <i>dermis</i>)
III	zmiany naciekają do niższej warstwy skóry (ang. <i>dermis</i>)
IV	zmiany sięgają naczyń krwionośnych – warstwy siateczkowatej (ang. <i>reticular dermis</i>)
V	zmiany sięgają warstwy podskórnej

— jaki jest wiek pacjenta?

Ostatnie pytanie, dotyczące wieku, punktowane jest od zera do sześciu w zależności od grupy wiekowej. Statystycznie u osób starszych prawdopodobieństwo wystąpienia czerniaka jest wyższe niż u młodszych.

Na rysunku 1.6 widoczne są zdjęcia, dla których odpowiedzi na kolejne pytania są pozytywne. Dla skali Huntera wynik powyżej sześciu oznacza znamię podejrzaną, a powyżej dziewięciu oznacza, że jest to najprawdopodobniej czerniak. Niniejsza praca opiera się na analizie zdjęć wielowarstwowych, dlatego w dalszej części pracy rozpatrywane są jedynie cechy skali Huntera. Ze względu na brak możliwości analizy wieku pacjenta na podstawie zdjęcia skóry, w dalszej części pracy ocena znamienia według skali Huntera będzie dotyczyć częściowej oceny znamienia. Wynika to z tego, że ocena znamienia nie jest pełna w tym przypadku.

Skala Clarka oraz Breslowa

Obok skali ABCD istnieją również dwie inne skale, które istnieją prawie od samego początku analizy znamion barwnikowych. Skale Clarka oraz Breslowa określają stopnie naciekania zmian w głąb. W skali Breslowa [78] istnieją cztery stopnie naciekania. Stopnie odpowiadają głębokości naciekania wyrażonej w milimetrach. Im wyższy stopień, tym rokowania są gorsze.

Skala Clarka [79] składa się z pięciu stopni i określa stopień naciekania w warstwach skóry. Podobnie jak w przypadku skali Breslowa, im wyższy stopień tym gorsze rokowania (patrz: tabela 1.3).

Inne skale

Przedstawione powyżej liczbowe charakterystyki znamion pomagają dermatologom w podejmowaniu diagnozy. Istnieje wiele innych skal, które pozwalają na polepszenie skuteczności wykrywania czerniaka przez lekarzy. Istnieją skale bardzo uproszczone jak skala 3-punktowa [80] oraz bardziej skomplikowane jak skala CASH [81], skala Chaos-Clue

[82] czy skala TNM (ang. *Tumor, Nodes, Metastasis*) [83]. Skale takie jak 7-punktowa [84] oraz Mensiesia [85], podobnie jak w większości przypadków bazują na wzorcach charakterystycznych dla czerniaka. Każda nowo powstała skala umożliwia osiągnięcie większej skuteczności w porównaniu do poprzedniej. Udowodniono w [86], że wybór skali wykorzystywanej w diagnostyce czerniaka ma istotny wpływ na takie wskaźniki jak swoistość oraz czułość. W niniejszej pracy opracowano cechy fraktalne znamion na bazie zdjęć wielospektralnych, które mogą zostać wykorzystane w diagnostyce znamion barwnikowych. Do tej pory badania w oparciu o analizę fraktalną prowadzono jedynie na zdjęciach dermatoskopowych wykonanych za pomocą fal światła widzialnego [42, 43]. Dodatkowo, w trakcie badań odkryto dwie nowe cechy, które określają zawartość kolagenu. Zostały one opisane w dalszej części pracy.


2. Klasyfikacja obiektów

Omawiane zagadnienie diagnostyki medycznej jest typowym problemem klasyfikacji. Elementom zbioru $X = \{x_1, x_2, \dots, x_n\}$ przypisuje się elementy zbioru $Y = \{y_1, y_2, \dots, y_n\}$, dla $i = 1, \dots, n$, gdzie n oznacza w tym przypadku liczbę obiektów. Zbiór X nazywany jest zbiorem wektorów cech x_i , natomiast zbiór Y nazywany jest zbiorem klas y_i . Proces pozyskania cech wchodzących w skład wektora cech został opisany w kolejnych dwóch rozdziałach. Zbiór klas w przypadku analizy znamion barwnikowych może przyjąć dwie postacie. W pierwszym przedstawionym w pracy modelu, w którym klasyfikujemy cechy znamion opisanych w poprzednim rozdziale, zbiór etykiet klas jest dwuelementowy. Klasa y_i może w przypadku klasyfikacji binarnej przyjąć wartości *prawda* lub *falsz*, które można przedstawić za pomocą liczb, np. 1 lub -1 . W niniejszej pracy podjęto także próbę sklasyfikowania ocen znamion uzyskanych zgodnie ze skalą Huntera. W tym przypadku zbiór etykiet klas składa się z ośmiu elementów.


Proces budowy klasyfikatora składa się z trzech etapów. Pierwszym etapem jest przygotowanie danych uczących, czyli podzbioru treningowego. Drugi etap to przygotowanie zbioru obiektów, które należy sklasyfikować, czyli podzbioru testowego. Ostatnią częścią jest klasyfikacja oraz obliczenie skuteczności klasyfikacji. Wskaźniki te oblicza się porównując otrzymany wynik z etykietą y_i podzbioru testowego. Ostateczne wyniki przedstawione w rozdziale piątym są średnią ze stu prób klasyfikacji każdej cechy. Dodatkowo, podzbiór treningowy oraz testowy wybierane są w sposób pseudolosowy. Takie podejście pozwala na uzyskanie wiarygodnych wyników.

W dalszej części pracy przedstawione zostaną dwie metody klasyfikujące: sieci neuronowe [87] oraz maszyna wektorów podpierających [88]. Wybór metody maszyny wektorów podpierających wynika z tego, że jest on ogólnie znany jako solidny i dający w większości przypadków bardzo dobre wyniki [89]. Zgodnie z ogólnie przyjętym podejściem, każdy problem klasyfikacji należy rozwiązać za pomocą więcej niż jednego klasyfikatora [90].

Przedstawione w rozdziale klasyfikatory różnią się tym w jaki sposób klasyfikują dane, natomiast proces klasyfikacji jest podobny i składa się ze wspomnianych wcześniej trzech części. W części treningowej klasyfikator na wejściu przyjmuje wektor cech. Na rysunku 2.1 podzbiór treningowy przedstawiony jest jako elementy niebieskie oraz czerwone. Dwa kolory reprezentują w tym przypadku dwie różne etykiety. Przykładowy wektor cech x_1 składa się z cech c_{11} oraz c_{12} . Proces klasyfikacji na podstawie takiego wektora cech przypisuje etykietę



(a) Problem liniowo separowalny



(b) Problem liniowo nieseparowalny

Rysunek 2.1: Ilustracja problemu klasyfikacji danych – niebieskie oraz czerwone elementy posiadają etykietę odpowiednio 1 oraz -1 , natomiast zielonemu elementowi należy przyporządkować jedną z etykiet

dla klasy y_1 . Zielony element jest elementem nowym, któremu jeszcze nie przypisano etykiety. Należy on do podzbioru testowego. Metody takie jak sieci neuronowe czy maszyna wektorów podpierających pozwalają na przypisanie takiemu elementowi etykiety. W przedstawionym przykładzie zielonemu elementowi w procesie klasyfikacji zostanie przypisana etykieta niebieska lub czerwona.

2.1. Wprowadzenie do klasyfikacji obrazów

Jak wspomniano wcześniej, proces klasyfikacji polega na przypisaniu na podstawie wektora cech, elementom ze zbioru obiektów X element y_i ze zbioru klas Y . Wiele przypadków można sklasyfikować liniowo jak na rysunku 2.1a. W przypadku analizy obrazów znamion barwnikowych problem klasyfikacji dotyczy klasyfikacji liniowo nieseparowalnej. Przykładowy przypadek problemu liniowo nieseparowalnego przedstawiono na rysunku 2.1b. W przypadku obu przedstawionych klasyfikatorów istotną część stanowi funkcja dyskryminująca $g(x)$. Aby lepiej przedstawić sposób działania klasyfikatorów posłużymy się metodą minimalno-odległościową.

Dla przykładu przedstawionego na rysunku 2.1a należy obliczyć środki klas m_1 oraz m_2 . W przedstawionym przykładzie wartości te wynoszą odpowiednio:

$$m_1 = \begin{bmatrix} -2,70 \\ -2,91 \end{bmatrix}, \quad m_2 = \begin{bmatrix} 3,95 \\ 3,15 \end{bmatrix}.$$

Można teraz obliczyć równanie powierzchni decyzyjnej. Aby tego dokonać należy podstawić obliczone środki dla obu klas do wzoru równania:

$$g(x) = 2(m_1^T - m_2^T)x_t + m_2^T m_2 - m_1^T m_1. \quad (2.1)$$

Podstawiając m_1 oraz m_2 do wzoru mamy:

$$g(x) = 2 \left(\begin{bmatrix} -2, 70 \\ -2, 91 \end{bmatrix}^T - \begin{bmatrix} 3, 95 \\ 3, 15 \end{bmatrix}^T \right) \cdot \begin{bmatrix} c_{t1} \\ c_{t2} \end{bmatrix} + \begin{bmatrix} 3, 95 \\ 3, 15 \end{bmatrix}^T \cdot \begin{bmatrix} 3, 95 \\ 3, 15 \end{bmatrix} - \begin{bmatrix} -2, 70 \\ -2, 91 \end{bmatrix}^T \cdot \begin{bmatrix} -2, 70 \\ -2, 91 \end{bmatrix} = 0.$$

Co daje ostatecznie równanie powierzchni decyzyjnej postaci:

$$g(x) = -2,5c_{t1} - 0,48c_{t2} + 9,7669 = 0.$$

Powyższe równanie pozwala na wyznaczenie prostej oznaczonej przerywaną szarą linią na rysunku 2.1a.

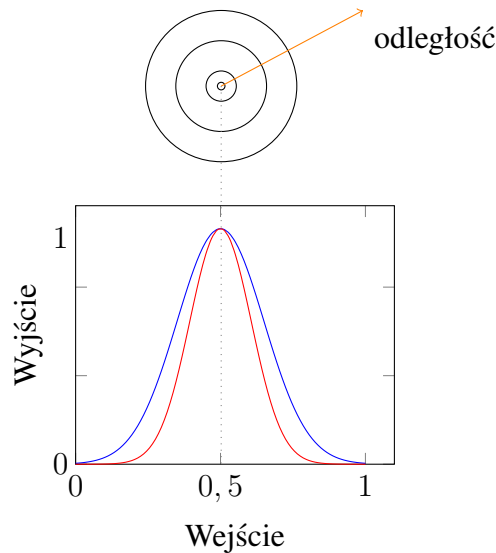
Proces decyzyjny przebiega w przypadku metody minimalno-odległościowej przez wyznaczenie funkcji dyskryminującej każdej z klas. W przypadku zadania dychotomii, czyli takiego gdzie rozważamy podzbiór uczący składający się jedynie z dwóch klas, należy obliczyć dwie postacie funkcji dyskryminującej. Ogólny wzór funkcji dyskryminującej jest postaci:

$$g_i(x) = 2m_i^T x_t - m_i^T m_i, \quad (2.2)$$

dla $i = 1, \dots, k$, gdzie k określa liczbę różnych etykiet. Podstawiając wartości dla każdej z klas otrzymujemy:

$$g_1(x) = 2 \cdot \begin{bmatrix} -2, 70 \\ -2, 91 \end{bmatrix}^T \cdot \begin{bmatrix} c_{t1} \\ c_{t2} \end{bmatrix} - \begin{bmatrix} -2, 70 \\ -2, 91 \end{bmatrix}^T \cdot \begin{bmatrix} -2, 70 \\ -2, 91 \end{bmatrix} = -5,4c_{t1} - 5,82c_{t2} - 15,7581,$$

$$g_2(x) = 2 \cdot \begin{bmatrix} 3, 95 \\ 3, 15 \end{bmatrix}^T \cdot \begin{bmatrix} c_{t1} \\ c_{t2} \end{bmatrix} - \begin{bmatrix} 3, 95 \\ 3, 15 \end{bmatrix}^T \cdot \begin{bmatrix} 3, 95 \\ 3, 15 \end{bmatrix} = 7,9c_{t1} + 6,3c_{t2} - 25,525.$$



Rysunek 2.2: Idea obliczenia wektora wag z wykorzystaniem radialnej funkcji bazowej, dla $\sigma_1 < \sigma_2$, gdzie σ_1 oznaczono kolorem czerwonym oraz σ_2 oznaczono kolorem niebieskim

Należy teraz rozważyć element oznaczony na rysunku 2.1a kolorem zielonym. Po podstawieniu $x_t = (2, 2)$ otrzymujemy wartości funkcji dyskryminującej dla obu klas:


$$g_1(x) = -38,1681,$$

$$g_2(x) = 2,875$$

Wartość $g_2(x)$ jest większa od $g_1(x)$, co pozwala na przypisanie elementowi x_t etykiety 1. Element x_t zostaje sklasyfikowany jako element niebieski (patrz: rysunek 2.1a) w przestrzeni decyzyjnej.

W przypadku analizy obrazów znamion barwnikowych, przedstawiony powyżej przykład prostej klasyfikacji problemu liniowo separowalnego, nie ma zastosowania ze względu na zbyt niską skuteczność takiego podejścia. Analiza cech znamion barwnikowych jest problemem klasyfikacji liniowo nieseparowalnej. W przypadku sieci neuronowych oraz metody maszyny wektorów podpierających istotną częścią, która wpływa na klasyfikację nieliniową, jest funkcja jądra. W badaniach wykorzystano kilka typów funkcji jądra. Najlepsze wyniki osiągnięto za pomocą radialnej funkcji jądra. Na rysunku 2.2 objaśniono ideę radialnej funkcji jądra [91]. Zmienna σ określa szerokość oraz jednocześnie wysokość kapelusza funkcji gaussowskiej. Parametr ten jest nazywany parametrem gładkości (ang. *smoothness*). Przedstawiona na rysunku 2.2 funkcja radialna jest postaci:

$$K(x_i, x, \sigma) = \exp\left(-\frac{\|x_i - x\|^2}{2\sigma^2}\right) = \phi(x_i)^T \phi(x) \quad (2.3)$$



Rysunek 2.3: Ilustracja przeniesienia problemu klasyfikacji liniowo nieseparowalnego w R^2 do przestrzeni R^3 za pomocą funkcji jądra $K : R^d \times R^d \rightarrow R^D$, dla $d < D$, gdzie R^D oznacza przestrzeń wtórną. Wypełnione elementy są w tym przykładzie wektorami podpierającymi

gdzie σ przyjmuje wartość jak opisano na rysunku 2.2. Warto dodać, że istotne jest odpowiednie dobranie wartości σ , która ma istotny wpływ na skuteczność klasyfikacji. Im większa wartość σ tym lepsze dopasowanie do modelu danych. Należy jednak uważać na zbyt dużą wartość zmiennej σ , ponieważ ma istotny wpływ na przeuczenie metody.

2.2. Wykorzystanie klasyfikatora C-SVM

Podstawową metodą wykorzystaną w pracy do klasyfikacji jest metoda maszyny wektorów podpierających (ang. *Support Vector Machine*). Wykazano w poprzednich badaniach [92], [93] oraz [94], że metoda SVM nadaje się do klasyfikacji znamion barwnikowych. Celem klasyfikatora SVM jest wyznaczenie granicy pomiędzy elementami danych klas w przestrzeni decyzyjnej (patrz: rysunek 2.3). Powierzchnia decyzyjna rozgraniczającą dwie klasy nazywa się hiperpłaszczyzną. Hiperpłaszczyznę, dla której marginesy są największe, nazywamy optymalną hiperpłaszczyzną rozdzielającą OSH (ang. *optimal separating hyperplane*) [95]. Im szerszy margines $\frac{2}{\|w\|}$ (przykład jako dwie szare linie ciągłe przedstawione na rysunku 2.3), tym mniejsze ryzyko przeuczenia. Dla uproszczenia rozważmy najpierw przypadek liniowo separowalny. Wyznaczenie OSH możliwe jest za pomocą funkcji rozdzielającej postaci:

$$g(x) = w^T x + w_0, \quad (2.4)$$

gdzie przez w oznaczony został wektor wag. W przypadku problemu liniowo separowalnego wartość wektora wag można wyznaczyć za pomocą wzoru:

$$w = \sum_{i=1}^{N_s} \alpha_i t_i x_i. \quad (2.5)$$

Wartość N_s określa liczbę wektorów podpierających. Wektory podpierające x_i to te, dla których wartość α_i jest większa od 0. W powyższym wzorze t_i określa wartość klasy, czyli w przypadku zadania dychotomii t_i może przyjąć np. wartości 1 lub -1 , w zależności od przynależności do klasy. Mnożniki α_i można obliczyć maksymalizując funkcję celu:

$$L_D(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j t_i t_j x_i^T x_j, \quad (2.6)$$

względem $\alpha = \{\alpha_i\}_{i=1}^N$. Należy także przyjąć ograniczenia:

$$0 \leq \alpha_i \leq C, \quad \sum_{i=1}^N \alpha_i t_i = 0, \quad (2.7)$$

dla $i = 1, \dots, N$. Funkcja celu przyjmuje postać:

$$J(w, w_0, \xi) = \frac{1}{2} w^T \cdot w + C \sum_{i=1}^N \xi_i \quad (2.8)$$

Zmienna ξ_i nazywana jest w literaturze zmienną rozluźniającą lub zmienną osłabiającą (ang. *slack variable*) [95]. Dla każdego obiektu z podzbioru uczącego przypada jedna zmienna rozluźniająca. Określa ona, po której stronie dany obiekt się znajduje. Dla $\xi_i > 1$ element znajduje się po złej stronie. Dla $0 < \xi_i \leq 1$ elementy znajdują się po dobrej stronie hiperpłaszczyzny w obrębie marginesu. Zmienna C w obu powyższych wzorach reprezentuje parametr regularyzacyjny. Im większa wartość C , tym większa złożoność obliczeniowa, ale jednocześnie lepsze dopasowanie.

W przypadku metody C-SVM warto także dodać, że istotną jej częścią jest reguła minimalizacji błędu kwadratowego. Reguła ta pozwala na osiągnięcie odpowiedniego kompromisu między ilością poprawnie i niepoprawnie sklasyfikowanych przypadków.

Dla przypadków liniowo nieseparowalnych należy wprowadzić do przedstawionych wcześniej założeń radialną funkcję jądra. Wektor wag można obliczyć w następujący sposób:

$$w = \sum_{i=1}^{N_s} \alpha_i t_i \phi(x_i) \quad (2.9)$$

Funkcja rozdzielająca przyjmuje postać:

$$g(x) = w^T \phi(x) + w_0 = \sum_{i=1}^{N_s} \alpha_i t_i K(x_i, x) + w_0, \quad (2.10)$$

gdzie w_0 można obliczyć w następujący sposób:

$$w_0 = \frac{1}{N_s} \sum_{j=1}^{N_s} [t_j - \sum_{i=1}^{N_s} t_i \alpha_i K(x_i, x_j)]. \quad (2.11)$$

Należy jeszcze zmaksymalizować funkcję celu:

$$L_D(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j t_i t_j K(x_i, x_j). \quad (2.12)$$

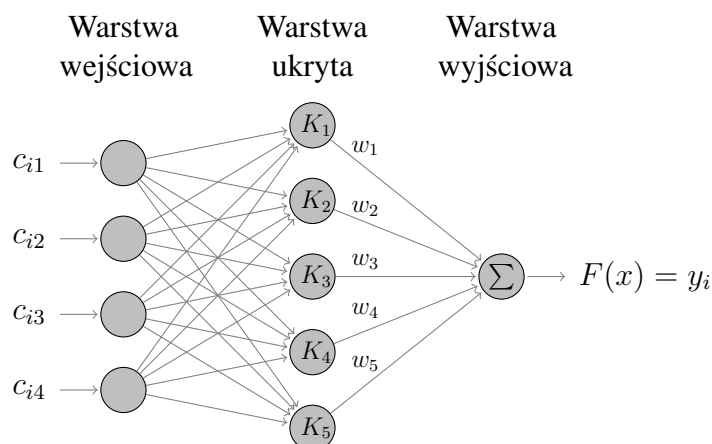
Ograniczenia są takie same jak w przypadku problemu liniowo separowalnego.

2.3. Wykorzystanie jednokierunkowych sieci neuronowych do klasyfikacji obrazów

Z informatycznego punktu widzenia sieci neuronowe [96] można przedstawić jako graf z określonymi węzłami oraz krawędziami. Graf ten jest grafem skierowanym, czyli takim gdzie krawędzie łączące węzły grafu są jednokierunkowe. Istnieją inne typy sieci, na przykład sieci rekurencyjne, gdzie węzły połączone są w obu kierunkach. W niniejszej pracy do klasyfikacji wykorzystano sieci jednokierunkowe z radialną funkcją jądra. Przykładowa sieć neuronowa przedstawiona została na rysunku 2.4.

W przypadku jednokierunkowych sieci neuronowych (ang. *feed forward*) proces uczenia odbywa się w trzech warstwach (patrz: rysunek 2.4). Zmienne c_{ij} to cechy wektora cech, czyli $x_i = (c_{i1}, \dots, c_{ij})$, gdzie j określa liczbę cech w wektorze. Na rysunku 2.4 przedstawiono przykład z czterema cechami. Każda cecha trafia najpierw do neuronów warstwy wejściowej. Warstwa wejściowa ma za zadanie wprowadzenie danych wejściowych do sieci.

Najistotniejszą częścią jest warstwa ukryta. Na rysunku 2.4 pokazano cztery neurony w tej warstwie. Warto zwrócić uwagę na to, że na rysunku przedstawiono jedynie jedną warstwę ukrytą. Istnieją również sieci neuronowe z wieloma warstwami ukrytymi. Na rysunku przedstawiono przykładową liczbę neuronów w warstwie ukrytej. Należy zwrócić uwagę na to, że liczba neuronów warstwy ukrytej powinna być tak dobrana, aby zapobiec efektowi przeuczenia. Problem przeuczenia objawia się tym, że klasyfikator nadmiernie często przypisuje elementom tylko jedną etykietę, przez co skuteczność klasyfikatora spada. Wynika to z tego, że klasyfikator traci zdolność uogólniania na skutego dokładnego dopasowania do



Rysunek 2.4: Ilustracja przedstawiająca zasadę działania sieci neuronowych

danych uczących. Wpływ na to może mieć zbyt duża liczba neuronów. W warstwie ukrytej obliczana jest wartość funkcji jądra $K(x_i, x_j, \sigma)$. Funkcja jądra ma bezpośredni wpływ na ustalenie wartości wagi w_i .

Trzecią warstwą jest warstwa wyjściowa. Na wejściu przyjmuje wartości wag oraz wynik opisanej wcześniej funkcji jądra. Widoczne na rysunku 2.4 wagi w_j obliczane są na etapie uczenia. Na podstawie otrzymanych na wejściu danych obliczana jest wartość funkcji $F(x)$.

$$F(x) = \sum_{j=1}^n w_j K_j(x_i, x, \sigma) \quad (2.13)$$

W dużym uproszczeniu – proces uczenia się sieci neuronowych polega na ustaleniu wartości wag w_i oraz aproksymacji w taki sposób, aby znaleźć funkcję $F(x)$, która przypisze dla danego wektora cech x_i etykietę zgodną z etykietą y_i podzbioru uczącego. W procesie klasyfikacji podzbioru testowego funkcja $F(x)$ powinna zwracać poprawną etykietę dla danego wektora cech. Wyraża ona sumę wszystkich iloczynów wagi każdego neuronu oraz funkcji jądra. Skuteczność klasyfikatora mierzymy przez porównanie wartości $F(x)$ z y_i podzbioru testowego.

2.4. Wykorzystanie klasyfikatorów w analizie znamion barwnikowych

Przedstawione w niniejszym rozdziale metody klasyfikacji danych zostały na podstawie liczbowej reprezentacji zdjęć znamion (opisanej w rozdziałach III oraz IV). Opisany w tym rozdziale wektor cech składa się z cech $x_i = (c_{11}, \dots, c_{ij})$ gdzie j oznacza liczbę cech w wektorze cech. W pracy każda cecha c_{ij} reprezentowana jest przez liczbę wyznaczaną dzięki zastosowaniu metod fraktalnych opisanych w kolejnym rozdziale. Tak jak wspomniano na początku rozdziału, etykiety klas mogą przyjąć w przypadku klasyfikacji binarnej wartości

–1 lub 1. Etykiety w analizie znamion wyznaczane są na podstawie otrzymanych wyników z MoleMate. Aby uzyskać lepsze wyniki, sprawdzono kilka wielkości podzbioru treningowego oraz testowego. Jest to ogólnie przyjęta praktyka [90]. Dane do obu podzbiorów wybrano w sposób pseudolosowy. Wielkości rozpatrywanych podzbiorów treningowych wynoszą odpowiednio 10%, 50%, 60%, 70% oraz 80% całości zbioru obiektów. Podzbiory testowe rozpatrywane są w wielkości odpowiednio 90%, 50%, 40%, 30% oraz 20%. Taki podział podzbiorów treningowego oraz testowego zastosowano dla sieci neuronowych oraz metody maszyny wektorów podpierających. Takie podejście podziału nazywane jest w literaturze metodą π lub metodą rotacyjną [90]. Dodatkowo, istotną częścią klasyfikacji jest uzyskanie najlepszych wyników przy minimalnym błędzie. Istnieją metody statystyczne, które pozwalają na minimalizację błędu, na przykład metoda walidacji krzyżowej (ang. *cross-validation*). Jest to metoda, która pozwala na dobranie takich wartości C oraz σ , dla których wyniki są najlepsze, a błąd najmniejszy.

3. Metody analizy fraktalnej

W rozdziale I opisano jakimi metodami posługują się lekarze w procesie diagnostycznym. Wyznacznikiem tego, czy dane znamię jest czerniakiem, czy nie, jest jego ocena według wybranej skali. Ocena znamienia składa się z sumy ocen poszczególnych cech danej skali. Uwzględnione w skalach cechy znamienia związane są głównie z jego nieregularnością, przede wszystkim co do kształtu oraz tekstury. Prawie wszystkie cechy określają nieregularność na zdjęciach wykonanych za pomocą fal światła widzialnego. Wynika to przede wszystkim z dostępności urządzeń diagnostycznych. Istnieją jednak takie cechy, które są trudne do wychwycenia przez człowieka. Metody fraktalne wydają się być odpowiednim narzędziem do zmierzenia nieregularności, nie tylko znanych już cech znamienia. Dzięki takim metodom fraktalnym jak wymiar pudełkowy możliwe jest opisanie liczbowe struktur geometrycznych. Pozwala to na sklasyfikowanie znamienia i przypisanie mu cech opisanych w rozdziale I.

Opisane w dalszej części rozdziału metody obliczania wartości wymiaru pudełkowego oraz lakunarność pozwolą na uzyskanie dwóch wartości. W dużym uproszczeniu można napisać, że obliczenie wartości wymiaru pudełkowego pozwala na określenie stopnia nieregularności struktur geometrycznych widocznych na obrazie. Wartość lakunarności określa stopień podziurawienia obrazu. Ma to zastosowanie w przypadku cech, które składają się z wielu mniejszych struktur geometrycznych na obrazie. Przykładem może być cecha skali Huntera mówiąca o występowaniu jasnych kropek na obrazie kolagenu. Kolejne cztery podrozdziały szczegółowo opisują algorytmy obliczania wartości wspomnianych wymiarów.

3.1. Wprowadzenie do fraktali

Aby móc wyjaśnić, czym są fraktale, należy najpierw wprowadzić pojęcie wymiaru fraktalnego oraz wymiaru Hausdorffa. Jest to możliwe po wprowadzeniu kilku elementarnych pojęć matematycznych.

Metryką, ilorazem skalarnym lub formą metryczną (patrz: [97], s. 243 lub [98], s. 201) w zbiorze X jest funkcja $d : X \times X \rightarrow \mathbb{R}$, taka ,że dla dowolnych $x, y, z \in X$ spełnione są warunki:

1. $d(x, y) = 0$, wtedy i tylko wtedy, gdy $x = y$,
2. $d(x, y) = d(y, x)$,
3. $d(x, y) + d(y, z) \geq d(x, z)$.

Metryka euklidesowa (patrz: [99], s. 44) jest funkcją $d(x, y)$ w przestrzeni euklidesowej R^n . Dla punktów x i y w przestrzeni R^n metrykę euklidesową definiujemy jako:

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}. \quad (3.1)$$

Przestrzeń metryczna (patrz: [100], s. 25) jest parą (X, ρ) , gdzie X jest zbiorem, a ρ jest odwzorowaniem

$$\rho : X \times X \rightarrow \mathbb{R}, \quad (3.2)$$

zwanym metryką lub odległością.

Dla dwóch zbiorów $A = \{a_1, \dots, a_p\}$ oraz $B = \{b_1, \dots, b_n\}$ istnieje *odległość Hausdorffa* [101] między zbiorami A i B wyrażona jako funkcja $H(A, B)$:

$$H(A, B) = \max(h(A, B), h(B, A)), \quad (3.3)$$

gdzie

$$h(A, B) = \max_{a \in A} \min_{b \in B} |a - b|. \quad (3.4)$$

Miarą (patrz: [99], s. 59) nazywamy funkcję $\mu(E)$ operująca na dowolnym zbiorze X . Dla każdego $E \subseteq X$ przyjmujemy $\mu(E) = \infty$, gdy E jest zbiorem nieskończonym; jeżeli E jest zbiorem skończonym, to za $\mu(E)$ przyjmujemy liczbę elementów zbioru E .

S-wymiarową miarą Hausdorffa (patrz: [102], s. 292) nazywana jest granica $h^s(F)$, czyli $h^s(F) = \lim_{\varepsilon \rightarrow 0} h_\varepsilon^s(F)$. ε oznacza średnicę obiektów w zbiorze F – dowolnym zbiorze w przestrzeni metrycznej X , a $h_\varepsilon^s(F)$ oznacza miarę Hausdorffa dla obiektów o średnicy ε .

Niech F będzie podzbiorem przestrzeni metrycznej. *Wymiar topologiczny* $D_{top}(F)$ (patrz: [103], s. 60, 61) definiuje się w sposób indukcyjny:

1. $D_{top} = -1$ wtedy i tylko wtedy, gdy F jest zbiorem pustym;
2. $D_{top} = n$ wtedy i tylko wtedy, gdy dla każdego $x \in F$ i dla każdego otoczenia U_x punktu x istnieje niepusty otwarty zbiór V , taki że:
 - a) $x \in V \subset U_x$,
 - b) $D_{top}(\delta V \cap F) \leq n - 1$, gdzie $\delta V \cap F$ jest przecięciem zbioru F z brzegiem zbioru V ,
 - c) liczba n jest najmniejszą liczbą naturalną, dla której zachodzi nierówność b).

Na podstawie powyższego można wywnioskować, że dla przypadku przestrzeni jednowymiarowej wartość wymiaru topologicznego wynosi zero. Dla przestrzeni dwuwymiarowej wartość wymiaru topologicznego wynosi jeden.

Wymiar Hausdorffa (patrz: [102], s. 293) definiuje liczbę D_H dla której:

$$h^s(F) = \begin{cases} \infty & \text{dla } s < D_H(F) \\ 0 & \text{dla } s > D_H(F) \end{cases} \quad (3.5)$$

Założeniem jest istnienie zbioru F , który jest podzbiorem n -wymiarowej przestrzeni euklidesowej. Za [104] wymiarem Hausdorffa zbioru F nazywamy liczbę D_H ,

$$D_H(F) = \inf\{s|h^s(F) = 0\} = \sup\{s|h^s(A) = \infty\}. \quad (3.6)$$

Niestety obliczenie kresów: górnego oraz dolnego, jest niemożliwe w sposób numeryczny. Istnieją jednak sposoby na obliczenie przybliżonej wartości wymiaru Hausdorffa, takie jak wymiar samopodobieństw, wymiar pudełkowy czy wymiar pojemnościowy.

Wymiar samopodobieństw (patrz: [102], s. 278) jest jednym z najprostszych sposobów uzyskania przybliżonej wartości wymiaru Hausdorffa. Wymiar samopodobieństw można zdefiniować wzorem:

$$D_s = \frac{\log N(F)}{\log \frac{1}{\varepsilon}}, \quad (3.7)$$

gdzie ε oznacza średnicę obiektów pokrywających obiekt, a $N(F)$ minimalną liczbę obiektów pokrywających wymaganych do pokrycia struktury geometrycznej. Wynika to z zależności:

$$N_\varepsilon(F) = \left(\frac{1}{\varepsilon}\right)^{-D_s}. \quad (3.8)$$

Zakładamy, że dla figur pokrywających o wielkości ε istnieje liczba $N_\varepsilon(F)$, która wyraża minimalną liczbę figur potrzebnych do pokrycia struktury F . Wtedy dla małych wartości ε zachodzi w przybliżeniu proporcjonalność:

$$N_\varepsilon(F) \sim \left(\frac{1}{\varepsilon}\right)^d \quad (3.9)$$


Liczba d określa wymiar obiektu. Wartość wymiaru jest tym dokładniejsza, im ε jest mniejsze.

Wymiar pojemnościowy (patrz: [103], s. 54) pozwala na obliczenie wartości wymiaru fraktalnego dla małych ε :

$$D_{poj.} = \lim_{\varepsilon \rightarrow 0} \frac{\log N_\varepsilon(F)}{\log \left(\frac{1}{\varepsilon}\right)} \quad (3.10)$$

W literaturze wymiar pojemnościowy nazywany jest też *wymiarem Kołmogorowa*.

Pojęcie fraktala odnosi się przede wszystkim do obiektów geometrycznych (przykłady: [105, 106, 107]). Zostało wprowadzone przez Benoita Mandelbrota na początku XX wieku [108]. Zdefiniował on fraktale jako obiekty, które posiadają trzy cechy:



Rysunek 3.1: Idea obliczania wartości wymiaru pudełkowego przez zliczanie pudełek o różnych długości krawędzi

- określone są zależnością rekurencyjną,
- są obiektami samopodobnymi,
- wymiar nie jest liczbą całkowitą.

Na potrzeby tej pracy *fraktalem* (za [103], s. 61) nazywamy zbiór, którego wymiar topologiczny jest różny (mniejszy) od wymiaru Hausdorffa. Numeryczne obliczenie wspomnianego powyżej wymiaru Hausdorffa nie jest możliwe, stąd konieczność obliczenia jego przybliżonej wartości wymiaru Hausdorffa. Jedną z popularnych metod obliczenia wartości przybliżonej jest obliczenie wartości wymiaru pudełkowego.

3.2. Wymiar pudełkowy

Jak wspomniano we wprowadzeniu do rozdziału, obliczenie wartości wymiaru pudełkowego (patrz: [102], s. 287) pozwala na określenie nieregularności struktury geometrycznej znajdującej się na obrazie. Wymiar pudełkowy w literaturze spotykany jest także pod nazwą *wymiaru Minkowskiego* [109] lub *wymiaru Minkowskiego-Bouliganda*. Wspomniany wcześniej wymiar Kołmogorowa [109] jest szczególnym przypadkiem wymiaru pudełkowego. Wartość wymiaru pudełkowego obrazu obliczana jest na podstawie obserwacji pokrycia struktury geometrycznej w stosunku do długości krawędzi tak zwanych pudełek. Rysunek 3.1 przedstawia przykład pokrycia tego samego znamienia za pomocą pudełek o różnej długości krawędzi pudełek ε . Istotą wykorzystania wielu wielkości pudełek jest uzyskanie wartości wymiaru fraktalnego danej figury minimalizując błąd statystyczny. Im mniejsze pudełka, tym wynik z założenia powinien być dokładniejszy, liczba pudełek większa, a czas obliczenia dłuższy. Relację wielkości pudełek do minimalnej liczby figur (np. sześciątów) potrzebnych do pokrycia obiektu przedstawia rysunek 3.2.

Aby móc obliczyć wartość wymiaru pudełkowego należy obliczyć najpierw wartości wymiaru dla każdej długości krawędzi pudełka. Wartość tą oblicza się w taki sam sposób jak wymiar samopodobieństw:

$$D_c = \frac{\log N(F)}{\log \frac{1}{\varepsilon}} \quad (3.11)$$

Wartością wymiaru pudełkowego jest nachylenie linii prostej uzyskanej na podstawie wartości dla poszczególnych długości krawędzi pudełka. Nachylenie prostej przedstawione jest na rysunku 3.2. Jak widać na wykresie 3.2, linia nie przechodzi idealnie przez wszystkie punkty. Jest wyznaczana na podstawie regresji liniowej:

$$D_p = \frac{n \sum \log \varepsilon \log N(F) - \sum \log \varepsilon \sum \log N(F)}{n \sum (\log \varepsilon)^2 - (\sum \log \varepsilon)^2} \quad (3.12)$$

We wzorze n odpowiada za liczbę niebieskich punktów – liczbę wykorzystanych długości krawędzi pudełek. Dla prostej wyznaczonej jak na rysunku 3.2 możliwe jest obliczenie takich statystyk, jak błąd standardowy oraz korelacje. Błąd standardowy można obliczyć na podstawie wzoru:

$$SE = \sqrt{\frac{\sum \log N(F)^2 - b \sum \log N(F) - D_p \sum \log \varepsilon \log N(F)}{n - 2}} \quad (3.13)$$


$$b = \frac{\sum \log N(F) - D_p \log \varepsilon \log N(F)}{n} \quad (3.14)$$

Błąd standardowy określa, jak bardzo wiarygodna jest obliczona wartość. Im mniejszy, tym większa dokładność wyniku. W przeprowadzonych badaniach średni błąd jest na poziomie około 3%. Jest to bardzo mały błąd, a co za tym idzie, wyniki są wiarygodne. Warto jednak zwrócić uwagę na to, że im dłuższe krawędzie pudełka, tym błąd jest większy. Z tego powodu zrezygnowano z pudełek o dłuższych krawędziach niż $\frac{1}{128}$. Na podstawie błędu statystycznego można wyciągnąć wniosek co do zasadności użycia tej metody. Obliczenie wartości wymiaru pudełkowego pozwala na wybranie tej wartości wymiaru, dla której błąd statystyczny jest najmniejszy przez dobór pudełek o różnych długościach krawędzi.


Drugim wskaźnikiem świadczącym o jakości otrzymanych wyników jest korelacja wartości do otrzymanej linii. Można ją obliczyć za pomocą wzoru:

$$r^2 = \left(\frac{(n \sum \log \varepsilon \log N(F) - \sum \log \varepsilon \sum \log N(F))}{\sqrt{(n \sum S^2 - (\sum \log \varepsilon)^2)(n \sum \log N(F)^2 - (\sum \log N(F))^2)}} \right)^2 \quad (3.15)$$

O dobrym dopasowaniu świadczy wartość r^2 bliska 1. Wartość poniżej 0,7 świadczy o słabym dopasowaniu, a co za tym idzie, o niskiej jakości otrzymanych wyników. Wartości pomiędzy 0,7 a 0,9 świadczą o silnej korelacji, natomiast o wysokiej jakości otrzymanych wyników może świadczyć wartość korelacji powyżej 0,9. W badaniach korelacja w najgorszym przypadku



(a) Relacja długości krawędzi pudełek do liczby pudełek wymaganych do pokrycia obiektu



(b) Funkcja postaci $y = ax + b$ oznaczona zielonym kolorem oraz poszczególne wartości cząstkowe dla różnych długości krawędzi pudełka

Rysunek 3.2: Ilustracja obliczania wartości wymiaru pudełkowego na przykładzie analizy obrazu binarnego przedstawiającego cechę jasnych kropek

jest na poziomie 0,95, natomiast dla większości przypadków wartość korelacji wynosi powyżej 0,98.

3.3. Lakunarność

Lakunarność (ang. *lacunarity*) w dużym uproszczeniu mierzy podziurawienie obrazu [110]. Przez podziurawienie należy rozumieć jasniejszy obszar na obrazie otoczony ciemniejszymi obszarami wokół. Podobnie jak w przypadku obliczania wymiaru pudełkowego, obraz także dzielony jest na tak zwane pudełka. Wartość lakunarności składa się z cząstowych wartości lakunarności. W dużym uproszczeniu można określić lakunarność jako kwadrat współczynnika zmienności (ang. *coefficient of variation*), który wyrażony jest za pomocą wzoru:

$$\lambda_\varepsilon = CV_\varepsilon^2 = \frac{\sigma_\varepsilon}{\mu_\varepsilon} \quad (3.16)$$

We wzorze CV oznacza współczynnik zmienności. Zmienna σ_ε określa odchylenie standardowe dla pudełek o długości krawędzi ε . Druga zmienna μ_ε określa średnią liczbę pikseli w pudełku. W przypadku obrazów binarnych będzie to średnia liczba pikseli o wartości jeden (czarnych

pikseli). Wartość obu zmiennych (σ, μ) określana jest w trakcie obliczania wartości wymiaru pudełkowego. Celem jest skrócenie czasu wykonywania obliczeń.

Jak wspomniano wcześniej, istotą obliczania wartości wymiaru pudełkowego jest obliczenie wartości wymiaru cząstkowego dla wielu długości krawędzi pudełka. W przypadku lakunarności także liczona jest wartość cząstkowa lakunarności dla każdej długości krawędzi pudełka (λ_ε). Wartość lakunarności jest średnią arytmetyczną z obliczonych wcześniej cząstkowych wartości. Wartość lakunarności można więc policzyć według wzoru:

$$\bar{\Lambda} = \sum_{i=1}^N \frac{\lambda_i}{N}, \quad (3.17)$$


dla $i = 1, \dots, N$, gdzie liczbą długości krawędzi pudełek.

3.4. Zastosowanie metod fraktalnych w analizie znamion barwnikowych

Jak wspomniano we wstępie, metody fraktalne można zastosować do zmierzenia nieregularności struktur geometrycznych. W dotychczasowych pracach prowadzono pracę nad analizą zdjęć za pomocą metod fraktalnych [111]. Udowodniono także, że jest to możliwe w kontekście analizy znamion barwnikowych [112]. Warto także wspomnieć o ograniczeniach wynikających z analizy znamion na podstawie zdjęć. W przypadku zdjęć wielowarstwowych mamy do czynienia ze zdjęciami o rozdzielczości 672x672 pikseli. Wynika z tego, że maksymalna długość krawędzi wynosi jedynie 672 piksele, a minimalna długość 1 piksel.

Opisane w rozdziale I cechy skali Huntera, podobnie jak pozostałych skal, bazują na strukturach charakterystycznych dla czerniaka. Lakunarność ze względu na to, że mierzy podziurawienie obrazu ma zastosowanie w przypadku cech przedstawionych na rysunku 3.3. Na rysunku 3.3 przedstawiono przykładowe struktury dla takich cech jak jasne kropki, *zwoje* oraz widoczne naczynia. Jednocześnie dla celów porównawczych przedstawiono przykłady obrazów zbinaryzowanych zdjęć, na których nie zaobserwowano wspomnianych cech. W przypadku analizy zdjęć znamion obliczanie wartości wymiaru pudełkowego ma potencjalnie zastosowanie dla takich cech jak wielkość znamienia, ubytki i nagromadzenie kolagenu, a także głębokość naciekania. Na rysunkach 3.4 oraz 3.5 przedstawiono przykładowe struktury, które wykazują daną cechę bądź nie.

Na podstawie przedstawionych obrazów możliwe jest obliczenie wartości wymiaru pudełkowego oraz lakunarności. I tak, dla cechy jasnych kropek widoczne są istotne różnice w wartościach wspomnianych wymiarów. Dla struktury nie wykazującej kropek (patrz: rysunek 3.3b) wartość wymiaru pudełkowego wynosi 1,1508, a wartość lakunarności 1,5382. Dla porównania wartość wymiaru pudełkowego dla struktury przedstawionej na rysunku 3.3a wynosi 0,4095. Wartość lakunarności dla tej struktury wynosi 0,7074. Różnice pomiędzy




(a) Obraz zbinaryzowany zdjęcia warstwy kolagenu na którym widoczne są jasne kropki




(b) Obraz zbinaryzowany zdjęcia warstwy kolagenu na którym brak widocznych jasnych kropek




(c) Obraz zbinaryzowany zdjęcia warstwy melaniny na którym widoczne są *zwoje*



(d) Obraz zbinaryzowany zdjęcia warstwy melaniny na którym brak widocznych *zwojów*




(e) Obraz zbinaryzowany zdjęcia warstwy hemoglobiny na którym widoczne są naczynia krwionośne




(f) Obraz zbinaryzowany zdjęcia warstwy hemoglobiny na którym brak widocznych naczyń krwionośnych


Rysunek 3.3: Obrazy zbinaryzowane przedstawiające przykładowe struktury takich cech jak jasne kropki (a), *zwojów* (b) oraz naczyń krwionośnych (c)




(a) Obraz zbinaryzowany zdjęcia warstwy hemoglobiny na którym widoczne są ubytki hemoglobiny



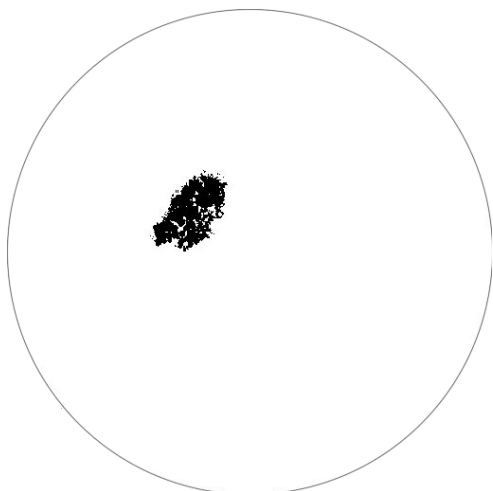
(b) Obraz zbinaryzowany zdjęcia warstwy hemoglobiny na którym brak widocznych ubytków hemoglobiny




(c) Obraz zbinaryzowany zdjęcia warstwy melaniny dużego znamienia



(d) Obraz zbinaryzowany zdjęcia warstwy melaniny małego znamienia




(e) Obraz zbinaryzowany zdjęcia warstwy hemoglobiny na którym widoczne jest znaczne nagromadzenie hemoglobiny



(f) Obraz zbinaryzowany zdjęcia warstwy hemoglobiny na którym brak widocznego nagromadzenia hemoglobiny

Rysunek 3.4: Obrazy zbinaryzowane przedstawiające przykładowe struktury takich cech jak ubytki hemoglobiny (a), dużego znamienia (b) oraz nagromadzenia hemoglobiny (c)



(a) Obraz zbinaryzowany zdjęcia warstwy naciekania na którym widoczne jest znaczne naciekanie w głąb

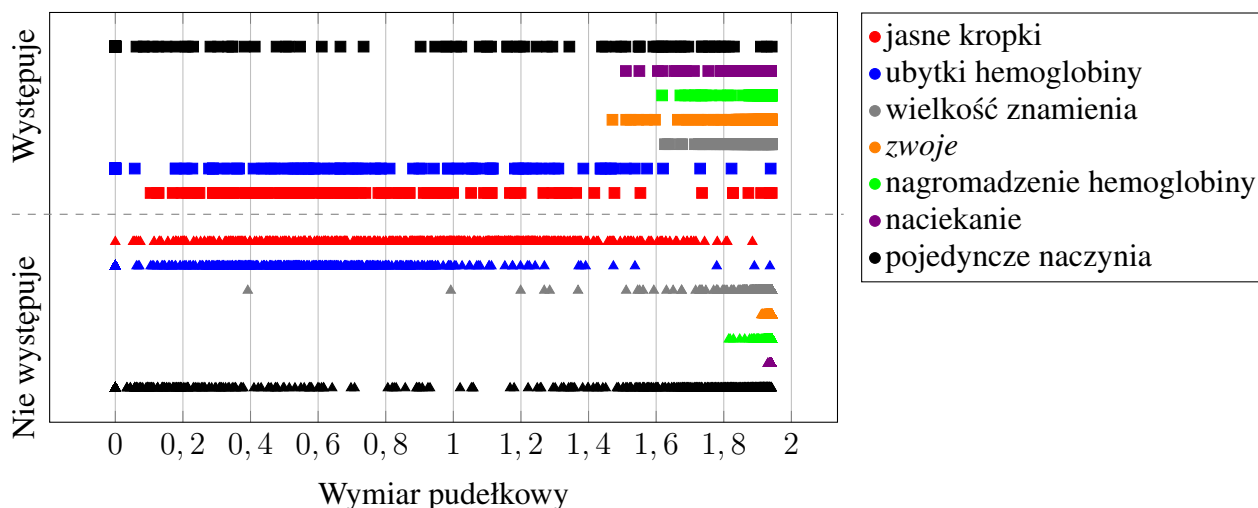
(b) Obraz zbinaryzowany zdjęcia warstwy naciekania na którym brak widocznego znacznego naciekania w głąb

Rysunek 3.5: Obrazy zbinaryzowane przedstawiające przykładowe struktury cechy naciekania

obiema strukturami są znaczące. Ze względu na to, że w wielu przypadkach kropki występują jako bardzo małe obiekty, takie jak przedstawiono na rysunku 3.3a. Widoczne kropki znajdują się wewnątrz niebieskiego obszaru/okręgu.

W przypadku *zwojów* różnice nie są aż tak znaczące jak w przypadku jasnych kropek. Niemniej jednak, różnice pozwalają na rozróżnienie w większości przypadków znamion wykazujących cechę *zwojów* od tych, które tej cechy nie wykazują. Dla struktury przedstawionej na rysunku 3.3c obliczono wartości wymiaru pudełkowego oraz lakunarności, które wynoszą odpowiednio 1,8158 oraz 0,25. Dla przykładowej struktury nie wykazującej cechy *zwojów* (patrz: rysunek 3.3d) wartości te wynoszą odpowiednio 1,9271 oraz 0,1252. Istotną rolę w przypadku tej cechy odgrywa wartość lakunarności, która mierzy podziurwienie struktury. *Zwoje* charakteryzują się przede wszystkim dziurami lub przestrzeniami pomiędzy elementami struktury.

Trudność w wykrywaniu naczyń jest taka, że naczynia mogą występować jako pojedyncze naczynia lub w postaci wielu naczyń formujących kształt na wzór siatki. Przedstawiona na rysunku 3.3e struktura zawiera wiele naczyń oraz dodatkowo widoczne jest nagromadzenie hemoglobiny. Jedna cecha nie wyklucza drugiej, więc mogą występować jednocześnie na jednym obrazie. Jest to dodatkowe utrudnienie w wykrywaniu tej cechy. Dla porównania przedstawiono strukturę, która jest obrazem binarnym zdjęcia warstwy hemoglobiny na którym widoczna jest cecha nagromadzenia hemoglobiny (patrz: 3.3f). Dla obu przypadków wartości wymiarów wynoszą odpowiednio 1,6369 i 0,7462 dla struktury przedstawionej na rysunku 3.3e oraz 1,7847 i 0,4012 dla struktury przedstawionej na rysunku 3.3f.

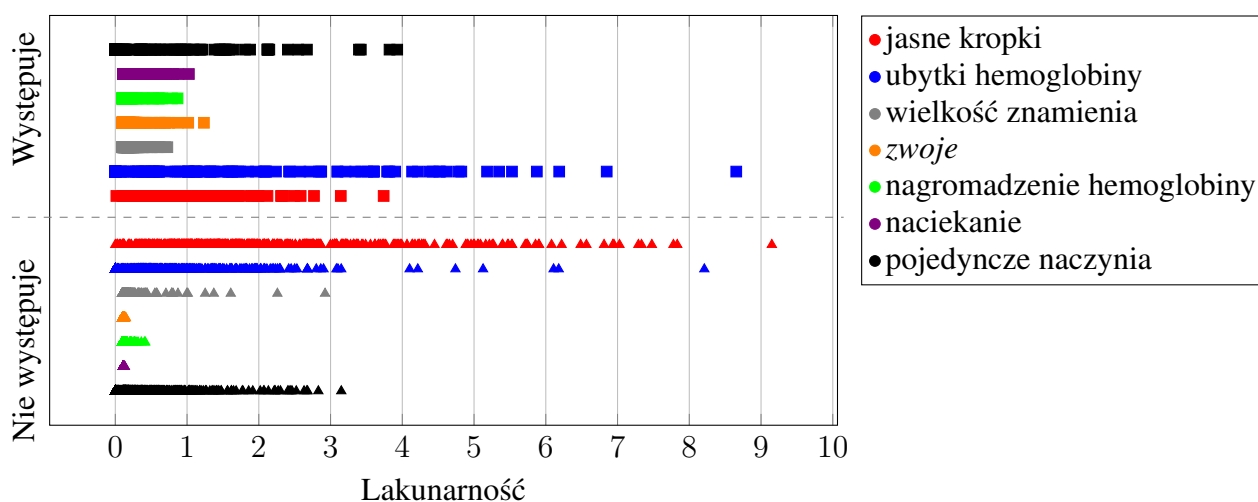


Rysunek 3.6: Rozkład wartości wymiaru pudełkowego cech skali Huntera na podstawie struktur na obrazach zbinaryzowanych metodą Doyle [113] (patrz: rozdział IV)

Przedstawione na rysunkach 3.4a oraz 3.4b struktury są zbinaryzowanymi obrazami warstwy hemoglobiny. Na pierwszym z nich widać strukturę ubytków hemoglobiny, natomiast druga struktura przedstawia obraz zbinaryzowany zdjęcia na którym takiej cechy nie wykryto. Cecha ubytków hemoglobiny wydaje się być prostą cechą do wykrycia za pomocą metod fraktalnych. Wskazują na to wartości policzonych wymiarów. Dla struktury przedstawionej na rysunku 3.4a wartości wynoszą 1,2993 oraz 2,8702. W przypadku struktury przedstawionej na rysunku 3.4b wartości te wynoszą 0,4194 oraz 0,417. Widać istotną różnicę pomiędzy obiema strukturami.

Jak wspomniano wcześniej, duże znamiona to takie, których odległość od najbardziej odległych punktów znamienia wynosi nie mniej niż 6 mm. W przypadku zdjęć warstwy melaniny wykonanych za pomocą urządzenia SIAScope, maksymalna wielkość wynosi 11 mm. Różnice między obiema strukturami przedstawionymi na rysunkach 3.4c oraz 3.4d są oczywiste. Niemniej jednak, różnice pomiędzy wartościami wymiarów obu struktur nie są aż tak znaczące. Dla struktury 3.4c obliczono wartości, które wynoszą 1,8833 oraz 0,2172. Dla struktury przedstawionej na rysunku 3.4d wartości wynoszą 1,9271 oraz 0,1252. Różnice nie są więc aż tak znaczące jak w przypadku cechy jasnych kropek.

Cecha nagromadzenia hemoglobiny może przyjmować różne postacie. Na obrazach zbinaryzowanych może przyjąć formę niewielkiego obiektu bez znaczącego podziurawienia (patrz: rysunek 3.4e) lub znacznie większego obiektu jak struktura przedstawiona na rysunku 3.3f. W wielu przypadkach istotnym czynnikiem decydującym o klasyfikacji jest wartość lakunarności. Dla struktury przedstawionej na rysunku 3.4e wynosi 2,8702. Dla przykładowej struktury, która jest obrazem zbinaryzowanym zdjęcia znamienia nie wykazującego cechy ubytków (patrz: rysunek 3.4f) wartość lakunarności wynosi 0,417. Dla obu struktur wartość



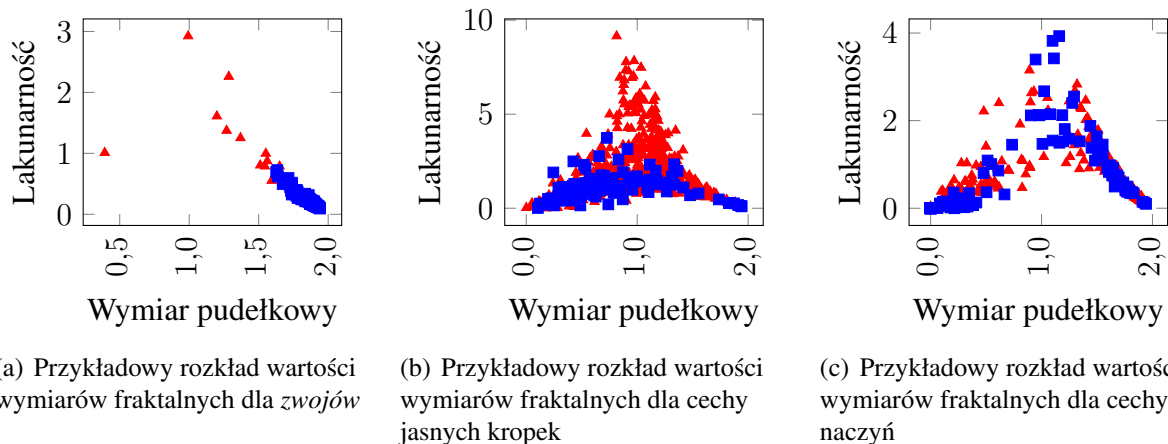
Rysunek 3.7: Rozkład wartości lakunarności cech skali Huntera na podstawie struktur na obrazach zbinaryzowanych metodą Doyle [113] (patrz: rozdział IV)

wymiaru pudełkowego wynosi odpowiednio 1,2993 dla struktury przedstawionej na rysunku 3.4e oraz 0,4194 dla struktury przedstawionej na rysunku 3.4f.

Cecha naciekania jest bardzo prosta do wykrycia. Struktury przedstawione na rysunku 3.5a oraz 3.5b odpowiadają strukturze, która wykazuje daną cechę oraz jej nie wykazuje. Wartości wymiaru pudełkowego są w tym przypadku oczywiste. Podobnie z wartościami lakunarności, które wynoszą odpowiednio 0,2964 dla struktury przedstawionej na rysunku 3.5a oraz 0,1103 dla struktury przedstawionej na rysunku 3.5b.

Na rysunkach 3.6 oraz 3.7 przedstawiono przykładowe rozkłady wartości wymiaru pudełkowego oraz lakunarności dla wszystkich cech skali Huntera. Wartości wymiarów uzyskano na podstawie obrazu binarnego, który jest wynikiem zastosowania opisanej w kolejnym rozdziale metody binaryzacji Doyle [113]. Przedstawiono jedynie rozkłady dla jednej metody binaryzacji ze względu na zachowanie przejrzystości pracy. Na rysunku 3.6 wartości wymiarów pudełkowy dla każdej cechy oznaczono innym kolorem. W niektórych przypadkach możliwe jest rozgraniczenie w łatwy sposób elementów, które wykazują daną cechę od takich, której tej cechy nie wykazują. Dotyczy to cechy naciekania oznaczonej kolorem fioletowym oraz *zwojów* oznaczonych kolorem pomarańczowym. Niestety w pozostałych przypadkach jest to dość trudne. Istotny wpływ ma zastosowana metoda binaryzacji. Dlatego w pracy przeanalizowano ponad czterdzieści metod, co pozwala na dobranie odpowiedniej metody binaryzacji w stosunku do badanej cechy.

Na rysunku 3.7 przedstawiono rozkład wartości lakunarności. W rozkładzie wartości lakunarności można rozgraniczyć część przypadków, które nie wykazują cechy jasnych kropek (oznaczone kolorem czerwonym). Można także rozróżnić niektóre przypadki cechy ubytków hemoglobiny (oznaczone kolorem niebieskim).



Rysunek 3.8: Przykładowe relacje wartości lakunarności do wartości wymiaru pudełkowego. Kolorem niebieskim oznaczono przypadki pozytywne. Wartości wymiarów fraktalnych obliczono z wykorzystaniem metody binaryzacji zaproponowanej w [114] (patrz: rozdział IV)

W niektórych przypadkach rozróżnienie przypadków możliwe jest jedynie gdy analizie poddane zostaną obie wartości wymiarów. Aby zachować przejrzystość pracy przedstawiono jedynie kilka przypadków relacji wartości wymiarów fraktalnych uzyskanych z wykorzystaniem jednej metody wyznaczania progów (patrz: rozdział IV). Na przedstawionych rysunkach 3.8 widać, że w niektórych przypadkach znamiona, które wykazują daną cechę skupione są wokół jednego punktu. Jest to dobrze widoczne na rysunku 3.8a, gdzie przypadki pozytywne skupione są w prawym dolnym rogu rozkładu. Na rysunku 3.8b widać, że wartości lakunarności dla jasnych kropek przyjmują niskie wartości. Istnieją jednak takie przypadki, dla których trudno jest rozdzielić elementy pozytywne od negatywnych (patrz: rys. 3.8c). Wartości wymiarów fraktalnych zależą od obrazu zbinaryzowanego. Metody pozyskania struktury na obrazie binarnym przedstawiono w kolejnym rozdziale.

Ważną częścią, która wiąże się z procesem obliczania wartości wymiaru pudełkowego oraz lakunarności jest wyznaczenie błędu oraz korelacji. Tak jak wspomniano wcześniej, im błąd jest mniejszy oraz jednocześnie korelacja wyższa, tym bardziej wiarygodne są uzyskane wyniki. Wspomniano również, że wartości wymiarów zależą od wykorzystanej metody binaryzacji. Obliczenie wartości błędu oraz korelacji jest istotne jedynie dla tych wartości wymiarów, dla których zastosowanie danej metody binaryzacji daje najlepsze wyniki klasyfikacji. O zastosowaniu metod binaryzacji oraz wynikach klasyfikacji traktują kolejne dwa rozdziały. Otrzymane wyniki błędów standardowych dla każdej cechy zostały przedstawione w tabeli 3.1. Na podstawie przedstawionych wyników widać, że największym błędem obarczone są wyniki dla cechy jasnych kropek oraz ubytków hemoglobiny. Najmniejszy błąd występuje dla cechy naciekania oraz nagromadzenia hemoglobiny. Korelacja dla wszystkich przypadków jest wyższa od 95%. Najmniej skorelowane wyniki przedstawione są dla cechy

Cecha	Błąd standardowy	Korelacja
Jasne kropki	0,1113	0,9806
<i>Zwoje</i>	0,0358	0,9997
Nagromadzenie hemoglobiny	0,0250	0,9999
Naciekanie	0,0254	0,9999
Naczynia	0,0533	0,9663
Ubytki hemoglobiny	0,0957	0,9742
Wielkość znamienia	0,0274	0,9998

Tabela 3.1: Średni błąd standardowy oraz korelacja dla obliczonych wartości wymiaru pudełkowego oraz lakunarności. Wartości te zostały obliczone na podstawie obrazu zbinaryzowanego za pomocą jednej z metod binaryzacji (patrz: rozdział IV i V)

naczyń oraz ubytków hemoglobiny. Z przedstawionych wyników można wywnioskować, że otrzymane wyniki wartości wspomnianych wymiarów są wiarygodne.


4. Metody przetwarzania obrazów

W poprzednim rozdziale przedstawione zostały metody fraktalne, których celem jest wyznaczenie wartości wymiaru fraktalnego obrazu. Wartości te określają strukturę geometryczną znajdującą się na obrazie i są wykorzystywane do stworzenia wektora cech (patrz: rozdział II). Istotą dobrej klasyfikacji w przypadku analizy obrazu jest między innymi odpowiednie przygotowanie obrazów. Analizie poddane są obrazy znamion pod kątem wcześniej wymienionych cech (patrz: rozdział I). W celu uzyskania wiarygodnej wartości wymiaru fraktalnego należy zastosować kilka metod przetwarzania obrazów w celu wyciągnięcia istotnych informacji zawartych w obrazie.

Obrazy w bazie danych przedstawione są za pomocą modelu RGB. Model RGB nie pozwala na dalszą analizę ze względu na zbyt dużą złożoność przedstawionych danych na obrazie. Należy najpierw przekonwertować obrazy RGB do obrazów monochromatycznych. Obraz monochromatyczny należy rozumieć jako obraz jednokolorowy, czyli taki, który do reprezentacji wykorzystuje wyłącznie odcienie jednego koloru. W dalszej części pracy jako obraz monochromatyczny należy rozumieć obraz w odcieniach szarości. W rozdziale opisane zostały dwie metody przetwarzania obrazów: metoda redukcji kolorów oraz binaryzacji obrazów. W części dotyczącej binaryzacji przedstawiono wstępne wyniki analizy metod binaryzacji. Istotą analizy wielu metod binaryzacji jest wybór najlepszej metody do analizy zdjęć wielowarstwowych. Warto zwrócić uwagę na to, że obliczenie wartości wymiaru fraktalnego na podstawie obrazu binarnego jest znacznie szybsze niż w przypadku obrazu monochromatycznego. Jest to istotne, ponieważ przedstawione w pracy metody mogą zostać wykorzystane na urządzeniach mobilnych.

4.1. Wstępna obróbka obrazów

Zdjęcia znajdujące się w bazie wykonane są za pomocą urządzenia SIAscope. Ich rozdzielczość różni się w zależności od tak zwanej warstwy. Zdjęcia wykonane za pomocą fal światła widzialnego mają rozdzielczość 1400x1400 pikseli. Pozostałe warstwy mają rozdzielczość 672x672 pikseli. Opisana w poprzednim rozdziale metoda opiera się na wykorzystaniu kilku długości krawędzi pudełka zaczynając od najmniejszej (1 piksel) oraz kolejnych potęg dwójki. Maksymalną długością krawędzi jest 512 pikseli, aczkolwiek ze




Rysunek 4.1: Różnice między reprezentacją obrazów za pomocą modelu RGB oraz YUV

względu na duży błąd przy tej wielkości krawędzi, maksymalna długość krawędzi wynosi jedynie 128 pikseli.

Jak widać na rysunku 1.6, większość cech to mniejsze lub większe ciemne struktury na jasnym tle. W trzech przypadkach cecha charakteryzuje się jasnymi strukturami na ciemnym tle. Dotyczy to takich cech jak jasne kropki, ubytki kolagenu oraz ubytki hemoglobiny. Dla tych cech należy zmodyfikować zdjęcia zanim zostaną poddane analizie fraktalnej. Tło takich obrazów należy przyciemnić. W ten sposób wyostrowione zostaną jaśniejsze części zdjęcia. Przykładowy wynik w postaci histogramu widoczny jest w dalszej części rozdziału (patrz: rysunek 4.2).

4.2. Konwersja obrazu RGB do obrazu w odcieniach szarości

Najczęstszym modelem wykorzystywanym w przechowywaniu obrazów jest model RGB. Składa się z trzech macierzy dwuwymiarowych $N \times M$. Każda macierz reprezentuje jedną z wartości składowych: R (kolor czerwony), G (kolor zielony) oraz B (kolor niebieski). Wartości poszczególnych elementów macierzy mogą przyjąć wartości od 0 do 255. Kolor piksela ustalany jest na podstawie sumy wartości elementów macierzy R, G i B dla tej samej pozycji. Obliczenie wartości opisanych wcześniej wymiarów fraktalnych wymaga przekształcenia obrazu z RGB do obrazu zbinaryzowanego. Proces przekształcenia obrazu z RGB do formy obrazu zbinaryzowanego wymaga najpierw konwersji obrazu z RGB do obrazu monochromatycznego. Proces redukcji kolorów polega na przekształceniu trzech macierzy



Rysunek 4.2: Histogram obrazu monochromatycznego warstwy kolagenu

dwuwymiarowych do jednej macierzy dwuwymiarowej. Elementy takiej macierzy mogą przyjąć wartości od 0 do 255. Wartości te odzwierciedlają odcień szarości. Istnieje wiele metod konwertujących obraz RGB do obrazu w odcieniach szarości. Najprostszym rozwiązaniem jest uśrednienie wartości dla każdego piksela $\frac{R+G+B}{3}$. Inną metodą jest wydzielenie tylko jednej macierzy obrazu RGB. Wartości wybranej macierzy reprezentują wartości obrazu monochromatycznego. Metodą wybraną do konwersji wykorzystaną w przedstawionych w niniejszej pracy badaniach, jest metoda, która wykorzystuje model YUV. Wybór modelu YUV wynika z tego, że najlepiej oddaje sposób postrzegania kolorów przez człowieka. Przestrzeń YUV składa się z trzech składowych, luminancji Y oraz dwóch chrominancji U oraz V. Odcień szarości każdego piksela obliczany jest jako $R * 0,299 + G * 0,587 + B * 0,144$. W przedstawionym później procesie binaryzacji do stworzenia histogramu wykorzystana została jedynie warstwa luminancji Y.

4.3. Metody binaryzacji

Binaryzacja zdjęcia jest prostą operacją, której celem jest stworzenie obrazu binarnego na podstawie obrazu monochromatycznego. Na podstawie obrazu monochromatycznego można stworzyć histogram, czyli rozkład odcieni szarości. Przykład histogramu dla cechy jasnych kropek przedstawiony jest na rysunku 4.2. W przypadku cechy jasnych kropek interesujące są jaśniejsze kolory, czyli te piksele, które znajdują się na prawo od niebieskiej linii. Zielono-niebieska przeważająca część obrazu znajduje się nieznacznie na lewo od niebieskiej linii (przykładowego progu).

Istotą procesu binaryzacji jest wyznaczenie progu. Próg określa przedziały odcieni szarości (patrz: histogram), przyjmujących wartość 1 i 0. Dla przykładu, ustawienie progu na poziomie 100 oznacza, że piksele, których wartość na obrazie monochromatycznym zawiera

się w przedziale od 0 do 100, będą na obrazie zbinaryzowanym widoczne jako czarne piksele. Pozostałe pozostaną białe. Możliwa jest też konwencja, która przypisuje kolor biały dla wartości 1 oraz czarny dla 0. Nie ma to jednak wpływu na obliczenia, o ile poprawnie zostanie przyjęty kolor tła. Należy także dodać, że wartości progów wyznacza się w przedziale od 0 do 255 lub w przedziale przeskalowanym od 0 do 1.


W przypadku analizy znamion barwnikowych poprawna binaryzacja wymaga wyznaczenia progów dla każdej cechy z osobna. Wyznaczanie progów binaryzacji nie jest łatwe, ponieważ trudno określić, które wartości pozwolą na osiągnięcie najlepszych wyników. Zważając na dużą liczbę dostępnych algorytmów do wyznaczenia progów, podjęto próbę analizy metod przedstawionych w [115]. Przystawiono tam najbardziej obszerny z dostępnych publikacji przekrój metod binaryzacji. Autorzy porównują ponad czterdzieści metod binaryzacji podzielonych według sześciu typów. Każdy typ charakteryzuje się innym podejściem do problemu wyznaczania progów. Według [115] metody binaryzacji można podzielić na takie, które przy wyznaczaniu progów opierają się na:

- kształcie histogramu (ang. *histogram shape-based thresholding*) – [116, 117, 118, 119, 120],
- klasteryzacji obrazu (ang. *cluster-based thresholding*) – [121, 122, 123, 124, 125, 126],
- entropii obrazu (ang. *entropy-based thresholding*) – [114, 127, 128, 129, 130, 131, 132, 133],
- lokalnych statystykach dla poszczególnych pikseli (ang. *local adaptive thresholding*) – [134, 135, 136, 137, 138, 139, 140, 141, 142],
- podobieństwie obrazu monochromatycznego do obrazu zbinaryzowanego według wybranej skali porównawczej (ang. *attribute similarity thresholding*) – [143, 144, 145, 146, 147],
- rozkładzie odcieni szarości w przestrzeni (ang. *spatial thresholding*) – [132, 148, 149, 150].

Aby nieco przybliżyć sposób wyznaczania progów przez metody binaryzacji, przedstawione zostaną metody po jednej z każdego typu. W tym celu należy wprowadzić statystyki, które wykorzystywane są w prawie wszystkich metodach binaryzacji. Każdy odcień reprezentowany jest przez liczbę wystąpień y_i , gdzie $i = 0, \dots, 255$. Niektóre metody binaryzacji bazujące na metodach statystycznych wykorzystują do wyznaczenia progów sumy nazywane momentami. Momenty $A(n, m)$, $B(n, m)$ oraz $C(n, m)$ obliczane są jak poniżej:

$$A(n, m) = \sum_{i=n}^m y_i, B(n, m) = \sum_{i=n}^m i y_i, D(n, m) = \sum_{i=n}^m i^2 y_i, \quad (4.1)$$

gdzie n oznacza początek, a m koniec przedziału odcieni szarości, dla których mają zostać policzone momenty. Przykładowo moment $A(0, 255)$ obliczy sumę dla wszystkich odcieni szarości.



Rysunek 4.3: Przykładowy rozkład średnich wartości progów oraz odchylenia standardowego progów analizowanych metod binaryzacji dla obrazów warstwy melaniny

W metodzie [114] podobnie jak w [121] obraz zostaje podzielony na tło oraz obiekt znajdujący się na obrazie. Podobnie jak w przypadku metody zaproponowanej w [121] celem jest wyekstrahowanie obiektu znajdującego się na obrazie. W metodzie zaproponowanej w [114] obiekt uzyskujemy obliczając entropię:

$$E_j = \sum_{i=0}^j y_i \log y_i \text{ dla } j = 0, \dots, 255, \quad (4.2)$$

w taki sposób, aby zmaksymalizować wartość funkcji:

$$F(j) = \frac{E_j}{A(0, j)} - \log A(0, j) + \frac{E_n - E_j}{A(0, m) - A(0, j)} - \log A(0, m) - A(0, j). \quad (4.3)$$

Za próg należy przyjąć wartość j , dla którego funkcja osiągnie maksimum.

Jedną z prostszych metod jest metoda przedstawiona w [122]. Zakłada, że dla danego progów t można wyznaczyć wartości odpowiednio w_b oraz σ_b^2 dla tła i w_f oraz σ_f^2 dla obiektu. Zmienne w_f oraz w_b są sumą liczby pikseli od odpowiednio dla $i = 0, \dots, t$ dla tła oraz $i = t+1, \dots, 255$ dla obiektu. Sumy te są dzielone przez liczbę wszystkich pikseli. Następnym etapem jest obliczenie wartości średniej, która wymagana jest do obliczenia współczynnika zmienności dla tła (σ_b^2) oraz obiektu (σ_f^2). Celem jest znalezienie takiego t , dla którego wartość σ_w^2 jest najmniejsza:

$$\sigma_w^2 = w_b \sigma_b^2 + w_f \sigma_f^2 \quad (4.4)$$

Metoda zaproponowana w [120] bazuje na metodzie przedstawionej w [122]. Różnica polega na tym, że w przypadku [120] założeniem jest ograniczenie poszukiwania optymalnego progu do zbioru, który wyznaczony jest za pomocą modelu autoregresyjnego.

Metoda zaproponowana w [134] określa przynależność każdego piksela z osobna do tła bądź do obiektu. Przynależność określana jest w sposób jak poniżej:

$$p_i = \begin{cases} 0 & : p_i > m(i, j) + k * \sigma(i, j) - C \\ 1 & : p_i < m(i, j) + k * \sigma(i, j) - C \end{cases}, \quad (4.5)$$

gdzie $m(i, j)$ określa wartość średnią oraz odchylenie standardowe dla otoczenia piksela. Otoczenie zdefiniowane jest z góry i według autorów powinno wynosić 15x15 pikseli. Zmiennym k oraz C także przypisana jest z góry założona wartość.

Metoda zaproponowana w [144] bazuje na idei zbiorów rozmytych ($f : A \rightarrow \mathfrak{R}$), gdzie celem jest znalezienie takiego t , dla którego zminimalizowana jest funkcja:

$$E(X) = \frac{1}{MN \ln 2} \sum_{g=1}^{254} S(\mu_x^g) y_i, \quad (4.6)$$

gdzie w naszym przypadku M oraz N wynoszą 672, a S oznacza funkcję Shannona. Funkcja przynależności zdefiniowana jest następująco:

$$\mu_x(x_{mn}) = \begin{cases} \frac{1}{1 + \frac{|x_{mn} - \mu_0|}{C}} \text{ dla } x_{mn} \leq t \\ \frac{1}{1 + \frac{|x_{mn} - \mu_1|}{C}} \text{ dla } x_{mn} > t \end{cases}, \quad (4.7)$$

gdzie C jest stałą taką, że: $\frac{1}{2} \leq \mu_x(x_{mn}) \leq 1$. Zmienna x_{mn} określa odcień szarości piksela na obrazie o współrzędnych m oraz n . Zmienne μ_0 oraz μ_1 zdefiniowane są jak poniżej:


$$\mu_0 = \text{int} \left(\frac{B(0, t)}{A(0, t)} \right), \quad (4.8)$$

$$\mu_1 = \text{int} \left(\frac{B(t + 1, 255)}{A(t + 1, 255)} \right). \quad (4.9)$$

Metoda zaproponowana w [148] definiuje zmienną p_{ij} :

$$p_{ij} = \frac{f_{ij}}{N^2}, \quad (4.10)$$

która określa prawdopodobieństwo dla odcienia i oraz j , gdzie $i, j = 1, \dots, m$. W przypadku rozpatrywanych obrazów $m = 255$. Zmienna f_{ij} określa częstotliwość wystąpienia pikseli



Rysunek 4.4: Przestrzeń dwuwymiarowa tworzona w metodzie zaproponowanej w [148].
Źródło: [148]

odcienia i . Do wyznaczenia progów wykorzystano dwuwymiarowy histogram jak na rysunku 4.4.

Istotą metody jest dobranie takich progów s oraz t dla których zmaksymalizowana zostanie wartość funkcji:

$$\psi(s, t) = \ln[P_{st}(1 - P_{st})] + \frac{H_{st}}{P_{st}} + \frac{H_{mm} - H_{st}}{(1 - P_{st})}, \quad (4.11)$$

gdzie

$$P_{st} = - \sum_{i=1}^s \sum_{j=1}^t p_{ij}, \quad (4.12)$$

oraz

$$H_{st} = - \sum_{i=1}^s \sum_{j=1}^t p_{ij} \ln(p_{ij}), \quad H_{mm} = - \sum_{i=1}^m \sum_{j=1}^m p_{ij} \ln(p_{ij}). \quad (4.13)$$

Autorzy [115] porównali skuteczność przedstawionych metod w binaryzacji obrazów tekstur oraz pisma. Zaproponowane metody mierzące skuteczność poprawnej binaryzacji nie mają niestety zastosowania w przypadku analizy znamion barwnikowych. Wynika to z tego, że nie ma możliwości bezpośredniego porównania uzyskanego obrazu z wzorcem. Skuteczność metod w przypadku analizy obrazów znamion można ustalić jedynie na podstawie skuteczności klasyfikacji cech (patrz: wyniki skuteczności klasyfikacji w rozdziale V). W przypadku niektórych metod można od razu zauważyć ich słabą skuteczność. Dotyczy to tych metod, których wartość wyznaczonego progów jest mniejsza od pierwszego odcienia i dla którego liczba wystąpień jest niezerowa. Analogicznie dla wartości progów większego od ostatniego odcienia i dla którego liczba wystąpień jest niezerowa. Można to sprawdzić obliczając średni próg dla wszystkich zdjęć dla danej cechy. Rozkład średnich wartości progów w stosunku do odchylenia

standardowego wyznaczonych progów metod dla każdej cechy przedstawiono na rysunku 4.3. Warto dodać, że dla niektórych metod wyznaczenie średniego progu jest niemożliwe. Dotyczy to przede wszystkim metod bazujących na lokalnych statystykach pikseli. Wyniki zastosowania metod binaryzacji w procesie klasyfikacji cech znamion przedstawiono w rozdziale piątym. Różnią się one od wyników przedstawionych w [115].

5. Analiza wyników

W poprzednich rozdziałach przedstawiono elementy składające się na proces oceny cech znamion barwnikowych na podstawie zdjęć wielowarstwowych. Niniejszy rozdział został podzielony na kilka części. Pierwsza część dotyczy analizy metod przetwarzania obrazów (patrz: rozdział IV). Zastosowanie wielu metod binaryzacji do obliczenia wartości wymiarów fraktalnych obrazów (patrz: rozdział III) pozwoliło wykazać, że niektóre metody można wykorzystać w procesie analizy znamion barwnikowych.

Najistotniejszą częścią są opisane w kolejnym podrozdziale wyniki klasyfikacji. Za pomocą wspomnianych w rozdziale II klasyfikatorów uzyskano wyniki, które świadczą o słuszności postawionej w pracy tezy. Wyniki różnią się w zależności od użytego klasyfikatora oraz badanej cechy. Skuteczność klasyfikacji mierzona jest za pomocą trzech miar. Pierwsza z nich mówi o ogólnej skuteczności klasyfikacji, czyli stosunku liczby poprawnie sklasyfikowanych przypadków danej cechy do liczby elementów w podzbiorze testowym. Na skuteczność klasyfikatora składają się również takie miary jak skuteczność klasyfikowania znamion, które wykazują daną cechę, w dalszej części pracy nazywana czułością klasyfikatora. Trzecią miarą jest swoistość klasyfikatora, która opisuje, w jakim stopniu poprawnie zaklasyfikowano znamię jako takie, które nie wykazuje danej cechy.

W dalszej części rozdziału przedstawiono wyniki klasyfikacji oceny znamion zgodnie ze skalą Huntera. Problem klasyfikacji znamion według jakiegokolwiek dermatologicznej skali ocen jest problemem bardziej złożonym od klasyfikacji cech. Wynika to z tego, że w przypadku klasyfikacji znamion według ocen skali Huntera, y_i może przyjąć jedną z siedmiu etykiet. W przypadku klasyfikacji poszczególnych cech klasyfikacja ma charakter binarny (dwie etykiety). Wybór klasyfikatora SVM w przypadku ocen skali Huntera wynika z faktu, że daje on lepsze wyniki w przypadku klasyfikacji cech w porównaniu do sieci neuronowych.

W ostatniej części opisano wnioski wynikające z przedstawionych w rozdziale wyników. Przedstawione wnioski dotyczą osiągniętych rezultatów oraz zastosowania metod binaryzacji oraz metod fraktalnych w kontekście wykorzystania ich w analizie znamion barwnikowych. Na tej podstawie stwierdzono słuszność stawianej tezy.

5.1. Baza danych

Pozyskanie bazy danych zdjęć znamion barwnikowych jest niezwykle trudne. W Polsce w publicznych placówkach medycznych, ze względu na obowiązujące prawo o ochronie danych osobowych, zdjęcia pacjentów nie mogą zostać udostępnione. Udało się nawiązać współpracę z Face and Body Institute w Krakowie. Placówka ta dysponuje jednym z najnowocześniejszych urządzeń do diagnostyki o nazwie SIAscope (patrz: rozdział I). W ciągu dwóch lat badań udało się zgromadzić bazę zdjęć dla ponad dziewięciuset sześćdziesięciu znamion. Przez dwa lata udało się zdiagnozować jedynie dwanaście przypadków czerniaka, które zostały potwierdzone badaniem histopatologicznym. Aby możliwe było przeprowadzenie analizy zdjęć należało najpierw z bazy ponad dziewięciuset sześćdziesięciu zdjęć odrzucić te, które się nie nadawały do dalszej analizy. Na tym etapie odrzucono wszystkie zdjęcia, które były bardzo złej jakości, np. były zbyt ciemne lub zbyt jasne. Jest to wynik błędnego użycia urządzenia, którego końcówka powinna podczas badania przylegać całkowicie do skóry. Przyleganie zapobiega dodatkowemu naświetlaniu przez zewnętrzne źródła światła. Jako kryterium odrzucenia przyjęto jasne/ciemne plamy na obrzeżach zdjęcia.

Po wstępnym przefiltrowaniu bazy należy jeszcze odrzucić te zdjęcia, które są dobrej jakości, natomiast ze względu na zawartość nie nadają się do analizy. Istotny problem stanowią zdjęcia z dużą ilością włosów. Niestety, stanowią one znaczną część bazy. Jako kryterium odrzucenia zdjęć przyjęto widoczne włosy na zdjęciach przedstawiających absorpcję światła ultrafioletowego przez melaninę. Włosy te widać jako podłużne nitki zajmujące znaczną część obrazu. Istnieją algorytmy, które pozwalają na usunięcie włosów [151], niemniej jednak algorytmy te działają poprawnie jedynie ze zdjęciami, które uzyskane zostały przy wykorzystaniu fal światła widzialnego.

Aby maksymalnie wykorzystać pozyskane zdjęcia odrzucono jedynie te zdjęcia, których wykorzystanie mogłoby w oczywisty sposób wypaczyć wyniki. Wskutek tego baza zdjęć jednej warstwy zawiera więcej zdjęć od bazy innej warstwy. Badania dotyczą warstwy kolagenu, hemoglobiny, melaniny oraz głębokości naciekania. Najczęstszym powodem odfiltrowania zdjęć, jak wspomniano wcześniej, jest złe naświetlenie znamienia. W tym przypadku odrzucane są zdjęcia wszystkich warstw. W przypadku włosów na zdjęciu wiele zależy od ich ilości. Duża ilość dyskwalifikuje najczęściej zdjęcia wszystkich warstw, aczkolwiek mniejsza ilość włosów nie ma istotnego wpływu na zdjęcie warstwy hemoglobiny. Po odfiltrowaniu wszystkich zdjęć, które zawierały szumy, otrzymano bazę jak w tabeli 5.1. Warto tutaj dodać, że nie odrzucono ani jednego przypadku, którego ocena w skali Huntera była większa niż 1. Istotne jest także to, że proces odrzucania zdjęć miał miejsce przed jakimikolwiek innymi czynnościami związanymi ze zdjęciami, np. etap przetwarzania obrazów. Na podstawie przedstawionych danych w tabeli 5.1 widać, że niektóre cechy występują częściej od innych. Najczęściej występuje cecha naciekania, co jest oczywiste w przypadku

Tabela 5.1: Baza zdjęć znamion z podziałem na cechy

Cecha	Liczba znamion, dla których cecha występuje	Liczba znamion, dla których cecha nie występuje
Jasne kropki	106	523
<i>Zwoje</i>	139	475
Nagromadzenie hemoglobiny	116	574
Głębokość melaniny	503	389
Naczynia krwionośne	97	593
Ubytki hemoglobiny	114	576
Wielkość	211	403
Ubytki kolagenu	347	282
Nadmiar kolagenu	19	610

znamion barwnikowych. Podobnie z ubytkami kolagenu, których jest więcej niż znamion nie wykazujących tej cechy. Cecha ubytków kolagenu jest cechą wprowadzoną na potrzeby pracy. W trakcie prowadzenia badań zaobserwowano, że ilość kolagenu wspomaga detekcję innych cech. Ubytki kolagenu bardzo rzadko występują razem z cechą jasnych kropek. Wprowadzenie tej cechy w przypadku wysokiej skuteczności w wykrywaniu pozwoli na wykrycie znamion, które z dużym prawdopodobieństwem nie wykazują cechy jasnych kropek. Cel wprowadzenia nowej cechy jaką jest nadmiaru kolagenu jest taki sam jak w przypadku ubytku kolagenu. Nadmiar kolagenu nie występuje razem z ubytkiem. Warto tutaj zwrócić uwagę na to, że obie cechy nie są wykorzystywane w żadnej znanej skali.

Cechy oparte na zdjęciach hemoglobiny występują stosunkowo często, ponieważ średnio co siódme znamię przejawia chociaż jedną z tych cech. Niewiele częściej występuje cecha jasnych kropek. *Zwoje* występują jeszcze częściej, natomiast zgodnie z tym co zostało opisane w aplikacji MoleMate, jest to cecha, która może albo świadczyć o czerniaku albo o zrogowaceniu skóry, czyli chorobie o zupełnie innym charakterze niż czerniak.

Typy znamion

Znaczna część bazy zawiera znamiona o charakterze łagodnym. Znamiona łagodne to przede wszystkim znamiona dysplastyczne, czyli znamiona barwnikowe, które nie wykazują złośliwości. Istnieją również inne typy znamion łagodnych. Przykładowo, często występujące

w bazie zrogowacenie łojotokowe ma w większości przypadków charakter łagodny. Na rysunku 5.1a przedstawiono przykład znamienia łagodnego. Na rysunku widać, że znamiona łagodne charakteryzują się przede wszystkim tym, że bez względu na zastosowaną metodę binaryzacji, nie można jednocześnie wyodrębnić struktury na obrazach większości warstw (patrz: rys. 5.1c). Dla porównania z innymi rodzajami znamion przedstawiono również przykładowe wartości wymiarów pudełkowych oraz lakunarności dla dwóch cech opartych na zdjęciach melaniny. Warto dodać, że przedstawiony obraz na rysunku 5.1b jest wynikiem zastosowania metody wprowadzonej przez Shanbhaga [129]. Wybór tej metody jest uwarunkowany tym, że w większości przypadków metoda ta pozwala, w porównaniu do zastosowania innych metod, na uzyskanie najlepszych wyników skuteczności klasyfikacji. Na rysunku 5.1d przedstawiono rozkład wartości wymiaru pudełkowego oraz lakunarności dla dwóch cech.

Przykład znamienia podejrzanego przedstawiono na rysunku 5.2. Przez podejrzanego należy rozumieć znamię, które może zostać zdiagnozowane w badaniu histopatologicznym jako znamię złośliwe lub jest wysokie prawdopodobieństwo, że takie znamię może stać się złośliwe w najbliższej przyszłości. Widoczne są znaczące różnice w porównaniu do przykładowego znamienia łagodnego (patrz: rys. 5.1). W przypadku znamion łagodnych na obrazach niektórych warstw nie ma widocznych znaczących różnic w strukturze. Innymi słowy, obrazy warstw znamion łagodnych są często jednorodne. Wynika z tego fakt, że w wielu przypadkach nie jest możliwe rozgraniczenie struktury od tła na obrazie. Na rysunku 5.2 przedstawiającym warstwy znamienia podejrzanego, widoczne są wyodrębnione struktury w przypadku każdej warstwy. Podobnie jak w przypadku znamienia łagodnego, wartości wymiarów fraktalnych mogą być różne w zależności od zastosowanej metody binaryzacji dla cech bazujących na tych samych warstwach. Rozkład wartości wymiarów fraktalnych dla metody Shanbhag został przedstawiony na rysunku 5.2f.


Istotnie różne obrazy w porównaniu do obrazów znamienia podejrzanego przedstawiono na rysunku 5.3. Przedstawione struktury znamienia złośliwego składają się z mniejszych rozrzuconych obiektów. Wynika to z tego, że znamiona złośliwe charakteryzują się nieregularnościami na każdym poziomie. Różnice między znamieniem złośliwym a łagodnym czy podejrzanym widoczne są również na rozkładzie wartości wymiarów przedstawionych na rysunkach 5.1d, 5.2f oraz 5.3f.

5.2. Analiza metod przetwarzania obrazów


W rozdziale czwartym opisano wykorzystane w badaniach metody przetwarzania obrazów. Szczególną uwagę poświęcono metodom wyznaczania progów w procesie binaryzacji. Powodem takiej sytuacji jest to, że metody te istotnie wpływają na skuteczność klasyfikacji, czego dowodzą przedstawione w dalszej części wyniki. Ze względu na częsty brak formalnej




(a) Znamię łagodne – zdjęcie wykonane za pomocą światła widzialnego



(b) Znamię łagodne – przykładowy obraz zbinaryzowany warstwy melaniny



(c) Znamię łagodne – obraz zbinaryzowany na podstawie obrazów warstw hemoglobiny, kolagenu oraz naciekania w głąb



(d) Wartości wymiarów pudełkowego oraz lakunarności dla przedstawionych obrazów zbinaryzowanych. Kolorem czarnym oznaczono wartości wartości wymiarów dla cechy wielkości, a kolorem niebieskim wartości wymiarów dla cechy *zwojów*

Rysunek 5.1: Przykład znamienia łagodnego wraz ze zbinaryzowanymi obrazami poszczególnych warstw oraz rozkładem wartości wymiarów fraktalnych cech

nazwy danej metody, przyjęto (podobnie jak w [115]) jako jej nazwę nazwisko pierwszego jej autora. Istnieją metody, które zostały wprowadzone przez te same osoby. W takim przypadku do nazwy metody dodano liczbę porządkową.


Na podstawie badań wykazano, że niektóre metody nie nadają się do analizy znamion barwnikowych w przypadku analizy zdjęć wielowarstwowych. Zastosowanie niektórych metod pozwala na osiągnięcie zadowalającej skuteczności klasyfikacji. Inne pozwalają na osiągnięcie skuteczności klasyfikacji na poziomie podobnym jakie osiągnęłyby klasyfikując



(a) Znamię podejrzane – zdjęcie wykonane za pomocą światła widzialnego




(b) Znamię podejrzane – przykładowy obraz zbinaryzowany warstwy melaniny



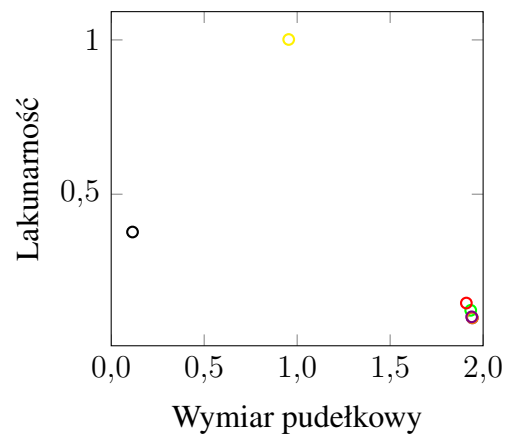
(c) Znamię podejrzane – przykładowy obraz zbinaryzowany warstwy głębokości naciekania



(d) Znamię podejrzane – przykładowy obraz zbinaryzowany warstwy hemoglobiny



(e) Znamię podejrzane – przykładowy obraz zbinaryzowany warstwy kolagenu




(f) Wartości wymiarów pudełkowego oraz lakunarności dla przedstawionych obrazów zbinaryzowanych warstw znamienia o potencjalnie złośliwym charakterze


Rysunek 5.2: Przykład znamienia o potencjalnie złośliwym charakterze wraz ze zbinaryzowanymi obrazami poszczególnych warstw oraz rozkładem wartości wymiarów fraktalnych cech




(a) Znamię złośliwe – zdjęcie wykonane za pomocą światła widzialnego



(b) Znamię złośliwe – przykładowy obraz zbinaryzowany warstwy melaniny



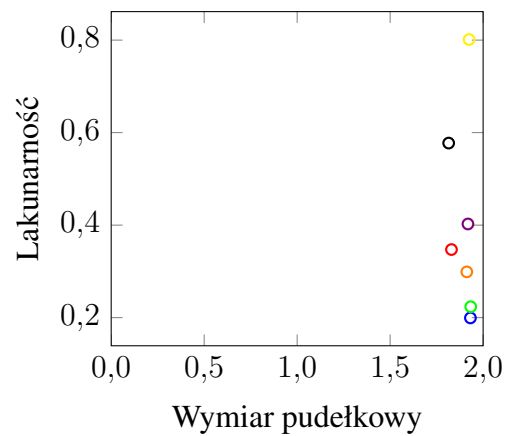
(c) Znamię złośliwe – przykładowy obraz zbinaryzowany warstwy głębokości naciekania



(d) Znamię złośliwe – przykładowy obraz zbinaryzowany warstwy hemoglobiny



(e) Znamię złośliwe – przykładowy obraz zbinaryzowany warstwy kolagenu



(f) Wartości wymiarów pudełkowego oraz lakunarności dla przedstawionych obrazów zbinaryzowanych przykładowego

Rysunek 5.3: Przykład znamienia o wysoce prawdopodobnym złośliwym charakterze wraz ze zbinaryzowanymi obrazami poszczególnych warstw oraz rozkładem wartości wymiarów fraktalnych cech

znamiona w sposób losowy, czyli na poziomie około 50%. Istnieją jednak takie metody, przy wykorzystaniu których skuteczność klasyfikacji wynosi poniżej 50%. Przez skuteczność należy tutaj rozumieć średnią skuteczność całkowitej klasyfikacji, czułość oraz swoistość klasyfikatora dla danej cechy. Warto tutaj zwrócić uwagę na to, że próba zwiększenia czułości przez odwrócenie/zanegowanie wyników klasyfikacji spowoduje zmniejszenie swoistości. Podobnie w przypadku próby zwiększenia swoistości. Istnieją metody które nie nadają się do analizy znamion barwnikowych. Należą do nich przede wszystkim metody z grupy metod bazujących na lokalnych statystykach pikseli, rozkładzie odcieni w przestrzeni oraz bazujące na kształcie histogramu. Wykazano również, że najlepsze wyniki klasyfikacji można osiągnąć wykorzystując metody z grupy metod bazujących na entropii oraz klastrowaniu obrazu. Metody wprowadzone przez Li [130], Prewitt [152] oraz Zacka [153] pozwalają na skuteczną klasyfikację tylko dla cechy naciekania. W przypadku tej cechy zastosowanie powyższych metod pozwala na osiągnięcie czułości klasyfikatora na poziomie od 50% do 90%. Metoda Tsai [143] wydaje się mieć zastosowanie jedynie w przypadku klasyfikacji dwóch cech naciekania oraz nadmiaru kolagenu, ponieważ pozwala na uzyskanie wyników średnio powyżej 75%. Wykorzystując tę metodę cechy takie jak ubytki kolagenu oraz wielkość znamienia można sklasyfikować ze skutecznością na poziomie 50%. Metoda Yen wprowadzona w [128] ma zastosowanie w przypadku klasyfikacji cechy ubytków hemoglobiny pozwalając na uzyskanie skuteczności na poziomie 65%. Pierwszą metodę zaproponowaną przez Prewitt [152] można wykorzystać w przypadku klasyfikacji cech nagromadzenia hemoglobiny oraz wielkości znamienia, dla których średnia skuteczność wynosi średnio około 65%. Metody zaproponowane przez Kapura w [114] pozwalają na uzyskanie średnich wyników klasyfikacji na poziomie 80% dla cechy ubytków hemoglobiny oraz na poziomie 90% dla cechy naciekania. Dodatkowo druga metoda wprowadzona przez Kapura [114] może zostać wykorzystana do klasyfikacji cechy wielkości znamienia. Dla pozostałych cech zastosowanie obu metod nie pozwala na uzyskanie dobrych wyników klasyfikacji. Metoda binaryzacji (Doyle) zaproponowana w [154] pozwala na uzyskanie bardzo dobrych wyników w przypadku cech wielkości znamienia oraz ubytków kolagenu. Dodatkowo pozwala na uzyskanie średnich wyników skuteczności wyższej niż 50% dla cechy nagromadzenia hemoglobiny. Metoda Glasbey [113] pozwala na uzyskanie skuteczności na poziomie około 75% jedynie dla cechy nagromadzonej hemoglobiny. Pozwala także uzyskać skuteczność klasyfikacji na poziomie 40% dla cechy wielkości znamienia oraz niemal 80% dla cechy naciekania. W pozostałych przypadkach zastosowanie tej metody wydaje się być bezzasadne. Metoda Shanbhag zaproponowana w [129] jest jedyną metodą ze wszystkich analizowanych w pracy, która ma zastosowanie w przypadku analizy *zwojów*. Wyniki czułości klasyfikatora, choć średnio na poziomie jedynie około 65%, są znacznie lepsze od wyników, do uzyskania których wykorzystano pozostałe metody binaryzacji. Cecha widocznych naczyń jest wykrywana

skutecznie jedynie w przypadku wykorzystania metody zaproponowanej w [129]. Średnia czułość wynosi w przypadku tej cechy oraz metody na poziomie 60%. Dodatkowo, metoda ta ma zastosowanie w przypadku wykrywania takich cech jak naciekanie, kropki oraz ubytki kolagenu. We wszystkich trzech przypadkach metoda ta pozwala na uzyskanie najlepszych wyników klasyfikacji w porównaniu do wyników uzyskanych przy wykorzystaniu pozostałych metod.

5.3. Analiza oraz omówienie wyników klasyfikacji cech

Niniejszy podrozdział podzielony jest na dwie części. Najpierw przedstawiono wyniki klasyfikacji cech za pomocą wspomnianych w rozdziale II klasyfikatorów. Następnie omówione zostaną szczegółowo wyniki klasyfikacji każdej cechy.

Wyniki klasyfikacji podzielono według klasyfikatorów. Przedstawione zostały w dwóch tabelach 5.2 oraz 5.4. Lista cech skali Huntera opisana w rozdziale I rozszerzona jest o wspomniane wcześniej dwie dodatkowe cechy. W poprzednim podrozdziale opisano wykorzystanie metod binaryzacji w procesie klasyfikacji. Jedynie niektóre pozwalają na uzyskanie zadowalającego poziomu skuteczności. W dalszej części pracy przedstawiono wyniki uzyskane za pomocą jednej metody dla każdej cechy. Przedstawiona metoda pozwala na uzyskanie najlepszych wyników dla danej cechy, w porównaniu do wyników uzyskanych przy wykorzystaniu pozostałych metod. Celem takiego podejścia jest zachowanie przejrzystości pracy. W tabelach przedstawiono także różne typy skuteczności klasyfikatora. Skuteczność ogólna klasyfikatora oznaczona została kolorem niebieskim. Skuteczność ogólna określa skuteczność klasyfikatora bez podziału na znamiona wykazujące daną cechę lub nie. Innymi słowy, skuteczność ogólna mierzona jest jako liczba skutecznie sklasyfikowanych przypadków w porównaniu do liczby przypadków podzbioru testowego. Czułość klasyfikatora określa skuteczność klasyfikatora w stosunku do znamion, które wykazują daną cechę. Odnosi się więc do liczby przypadków znamion, które wykazują daną cechę w podzbiorze testowym. W przedstawionych tabelach została oznaczona kolorem zielonym. Analogicznie w przypadku swoistości klasyfikatora, która została oznaczona kolorem czerwonym.

Faktem jest, że dla takich cech jak kropki, nadmiar kolagenu czy naczynia, skuteczność klasyfikacji za pomocą sieci neuronowych nie została uwzględniona w tabeli 5.4, ponieważ skuteczność tej metody jest niezwykle niska. Średnia skuteczność we wspomnianych przypadkach nie przekraczała w najlepszym przypadku 50%. Wykorzystanie sieci neuronowych do klasyfikacji wydaje się być uzasadnione jedynie w przypadku klasyfikacji wielkości znamienia, gdzie dla danych uczących wynoszących 10% całości bazy można osiągnąć wysoką skuteczność na poziomie 97,5%. W pozostałych przypadkach ogólna skuteczność uzyskana za pomocą metody sieci neuronowych jest średnio niższa w porównaniu

do metody maszyny wektorów podpierających. Metoda SVM daje w większości przypadków ogólną skuteczność powyżej 90%. Zależy to często od stosunku podzbioru trenującego do podzbioru testowego. W kilku przypadkach widoczny jest efekt przeuczenia. Występuje on wtedy, gdy uzyskana skuteczność jest większa dla mniejszego podzbioru trenującego w porównaniu do uzyskanej skuteczności dla większego podzbioru trenującego. W przypadku zastosowania metody SVM dotyczy to jedynie cechy nadmiaru kolagenu. Ten problem występuje częściej, gdy metodą zastosowaną do klasyfikacji są sieci neuronowe. Dotyczy to takich cech jak *zwoje*, głębokość naciekania oraz wielkość znamienia.

Ogólna skuteczność dla wszystkich przypadków jest wysoce zadowalająca. Z punktu widzenia analizy znamion barwnikowych, bardziej istotna jest jednak skuteczność klasyfikacji znamion, które wykazują daną cechę. Wynika to z faktu, że wraz ze wzrostem liczby wykazywanych cech, wzrasta prawdopodobieństwo czerniaka (według skali Huntera). W tabeli 5.2 przedstawiona czułość klasyfikatora w porównaniu do ogólnej skuteczności jest w wielu przypadkach znacznie gorsza. Zwłaszcza dotyczy to podzbioru trenującego wynoszącego 10% zbioru obiektów (patrz: pierwsza kolumna w tabelach skuteczności klasyfikacji). Dotyczy to w przypadku metody SVM takich cech jak kropki, naczynia oraz ubytki hemoglobiny. Sieci neuronowe wykazują słabą skuteczność w przypadku takich cech jak ubytki hemoglobiny oraz *zwojów*. Podobnie jak w przypadku ogólnej skuteczności, także w przypadku czułości klasyfikatora występuje problem przeuczenia. Dotyczy to w przypadku SVM takich cech jak nadmiar kolagenu, głębokości naciekania oraz wielkości znamienia. W przypadku sieci neuronowych problem ten występuje jedynie w przypadku głębokości naciekania oraz wielkości znamienia. Porównując wyniki uzyskane za pomocą sieci neuronowych oraz maszyny wektorów podpierających można wyciągnąć wniosek, że zastosowanie sieci neuronowych w tym przypadku daje przeważnie gorsze wyniki. Sieci neuronowe znajdują zastosowanie w przypadku klasyfikacji takich cech jak ubytki kolagenu, nagromadzenia hemoglobiny oraz głębokości naciekania. Porównywalne do sieci neuronowych wyniki SVM można uzyskać w przypadku wielkości znamienia.

Ze wszystkich cech najtrudniejszą do wykrycia jest cecha *zwojów*. Najlepsze rezultaty daje klasyfikacja wielkości znamienia oraz naciekania. Wyniki powyżej 90% można uznać za wysoce zadowalające – dotyczą czterech cech. Można uznać za dobry każdy wynik klasyfikacji, który jest wyższy od 80% – dotyczy kolejnych trzech cech.

Swoistość klasyfikatora z punktu widzenia pacjenta jest równie istotna co czułość klasyfikatora. Wyniki przedstawione w tabelach 5.2 oraz 5.4 pozwalają na wyciągnięcie kilku wniosków. Wykrywanie znamion, które nie wykazują danej cechy, okazuje się dawać lepsze rezultaty w porównaniu do wykrywania znamion, które daną cechę wykazują. Dla wszystkich cech możliwe jest uzyskanie skuteczności na poziomie powyżej 80%. Dodatkowo swoistość klasyfikatora aż dla sześciu cech wynosi powyżej 90%. Sieci neuronowe dają w

każdym przypadku znacznie słabsze rezultaty w porównaniu do SVM. Problem przeuczenia występuje w przypadku swoistości klasyfikatora jedynie dla cechy *zwojów* w przypadku SVM oraz głębokości naciekania w przypadku sieci neuronowych.

Jasne kropki

Cecha jasnych kropek widoczna jest na rysunku 5.4a jako wiele niewielkich obszarów rozrzuconych po znacznym obszarze obrazu. Dla porównania przedstawiono na rysunku 5.4b przykład bez kropek. W przypadku struktury przedstawionej na rysunku 5.4b widać, że na obrazie istnieje jedna większa struktura. Przedstawione na rysunku 5.4c wyniki pokazują, że jedynie czułość klasyfikatora jest na zadowalającym poziomie dopiero przy podzbiorze treningowym wielkości 80% zbioru obiektów. Krzywa ROC przedstawiona na rysunku 5.4d świadczy jednak o dobrej skuteczności klasyfikatora.

Zwoje

Różnica między znamionami, które wykazują *zwoje*, a takimi, które ich nie wykazują, przedstawiono na rysunkach 5.5a oraz 5.5b. Znamiona nie wykazujące wspomnianej struktury są skupione, mają przeważnie łagodne brzegi. Dodatkowo, znamiona wykazujące strukturę są najczęściej znamionami dużymi z prześwitami. Skuteczność klasyfikacji takich znamion jest niska w porównaniu do pozostałych cech. Widać to dobrze na rysunku 5.5c. Pomimo porównywalnie niskiej czułości klasyfikatora, dobór klasyfikatora należy ocenić pozytywnie. Świadczy o tym krzywa ROC, która została przedstawiona na rysunku 5.5d.

Nagromadzenie hemoglobiny

Nagromadzenie hemoglobiny objawiają się jako większe struktury z pustymi obszarami wewnątrz. Przykład takiej struktury przedstawiono na rysunku 5.6a. Struktury podobne do przedstawionej na rysunku 5.6b lub w postaci niewielkich obiektów rozrzuconych na obrazie, świadczą o tym, że znamię nie wykazuje cechy nagromadzenia hemoglobiny. Skuteczność klasyfikacji jest zadowalająca, z niewielkimi różnicami przy doborze wielkości podzbioru testowego (patrz: rysunek 5.6c oraz 5.6d).

Głębokość naciekania

W odrożnieniu od *zwojów* cecha naciekania jest prosta do wykrycia. Świadczą o tym przedstawione wyniki (patrz: rysunek 5.7c). Najczęściej występuje na obrazie zbinaryzowanym w postaci mniejszych lub większych plam. Na rysunku 5.7a przedstawiono przykład niewielkiego naciekania. Istnieją także przypadki, gdzie naciekanie jest tak niewielkie, że niemal niewidoczne. Wtedy przyjmuje się, że znamię takie tej cechy nie wykazuje. Przykład bez żadnego naciekania widoczny jest na rysunku 5.7b. O skuteczności doboru klasyfikatora świadczy przedstawiona na rysunku 5.7d krzywa ROC.

Tabela 5.2: Skuteczność klasyfikacji zdjęć za pomocą maszyny wektorów podpierających. Kolorem niebieskim oznaczono skuteczność ogólną, kolorem czerwonym swoistość klasyfikatora, a kolorem zielonym czułość klasyfikatora


Cecha – metoda binaryzacji	Skuteczność klasyfikacji				
	10/90	50/50	60/40	70/30	80/20
	78,6%	85,5%	89,7%	92,0%	93,4%
Jasne kropki – Shanbhag [129]	33,5%	56,7%	69,0%	78,1%	83,8%
	86,1%	91,4%	93,7%	94,4%	95,1%
	78,9%	81,3%	81,7%	82,2%	82,2%
Zwoje – Shanbhag [129]	56,1%	64,4%	66,2%	67,0%	68,2%
	83,0%	83,8%	84,1%	84,6%	84,4%
	88,4%	91,2%	92,3%	92,3%	92,7%
Nagromadzenie hemoglobiny – Glasbey [113]	66,4%	75,9%	80,2%	79,9%	81,2%
	92,8%	94,2%	94,5%	94,6%	94,8%
	92,2%	93,7%	94,2%	94,1%	94,5%
Głębokość naciekania – Kapur I [114]	95,2%	95,5%	95,6%	95,5%	95,3%
	89,1%	91,6%	92,4%	92,4%	93,4%
	81,1%	87,2%	90,3%	91,8%	92,6%
Widoczne naczynia – Shanbhag [129]	27,3%	57,2%	76,6%	85,7%	90,0%
	87,4%	90,3%	91,6%	92,3%	92,8%
	80,0%	86,8%	90,1%	92,1%	92,6%
Ubytki hemoglobiny – Kapur II [114]	32,6%	64,5%	83,2%	92,0%	94,7%
	85,7%	89,9%	90,9%	92,1%	92,3%
	82,3%	83,3%	83,8%	83,9%	84,1%
Wielkość – Kapur II [114]	93,1%	94,0%	95,5%	95,4%	95,6%
	79,8%	80,6%	80,9%	81,1%	81,2%
	76,8%	85,6%	87,4%	89,1%	89,7%
Ubytki kolagenu – Shanbhag [129]	80,7%	88,0%	88,9%	90,5%	91,6%
	73,4%	82,9%	85,8%	87,3%	87,4%
	97,0%	97,7%	97,9%	98,0%	97,9%
Nadmiar kolagenu – Glasbey [113]	59,6%	75,2%	77,5%	79,4%	78,5%
	97,8%	98,0%	98,3%	98,4%	98,4%

Tabela 5.4: Skuteczność klasyfikacji zdjęć za pomocą sieci neuronowych. Kolorem niebieskim oznaczono skuteczność ogólną, kolorem czerwonym swoistość klasyfikatora, a kolorem zielonym czułość klasyfikatora


Cecha – metoda binaryzacji	Skuteczność klasyfikacji				
	10/90	50/50	60/40	70/30	80/20
<i>Zwoje</i> – Shanbhag [129]	78,0%	78,0%	78,4%	78,5%	78,3%
	33,8%	33,8%	53,3%	56,3%	53,4%
	78,7%	78,7%	78,9%	78,9%	78,7%
Nagromadzenie hemoglobiny – Glasbey [113]	85,9%	85,9%	85,9%	87,3%	87,4%
	80,5%	80,5%	80,5%	84,6%	84,7%
	86,3%	86,3%	86,3%	87,5%	87,6%
Głębokość naciekania – Kapur I [114]	83,0%	83,0%	85,5%	86,6%	86,5%
	96,6%	96,6%	96,4%	96,4%	96,4%
	74,0%	74,0%	77,2%	78,8%	78,7%
Ubytki hemoglobiny – Kapur II [114]	83,0%	85,4%	85,7%	85,9%	85,9%
	49,1%	67,4%	71,4%	73,8%	74,4%
	49,1%	67,4%	71,4%	73,8%	74,5%
Wielkość – Kapur II [114]	97,5%	79,5%	79,5%	81,1%	81,0%
	95,4%	95,4%	95,4%	95,2%	94,3%
	76,9%	76,9%	76,9%	78,3%	78,4%
Ubytki kolagenu – Shanbhag [129]	75,9%	79,5%	80,1%	80,6%	80,9%
	85,5%	91,3%	92,4%	92,5%	92,7%
	68,8%	71,4%	71,6%	72,3%	72,6%

Naczynia


Hemoglobina na obrazie w kształcie naczyń krwionośnych może przyjąć dwie formy. Jedna z nich została przedstawiona na rysunku 5.8a. Struktura ta przyjmuje formę jednego lub więcej obiektów w kształcie nitek. Druga forma została przedstawiona w rozdziale III na rysunku 3.3e. W tym przypadku struktura posiada postrzępione brzegi. Dla porównania przedstawiono przykład znamienia, które nie wykazuje cechy naczyń. Struktura na obrazie binarnym 5.8b przyjmuje kształt wielu niewielkich obiektów rozrzuconych na obrazie. Bliżej takiej strukturze do




(a) Obraz zbinaryzowany znamienia wykazującego jasne kropki



(b) Obraz zbinaryzowany znamienia nie wykazującego cechy jasnych kropek



(c) Skuteczność klasyfikacji – ogólna skuteczność klasyfikatora oznaczona została kolorem niebieskim, czułość klasyfikatora kolorem zielonym, swoistość klasyfikatora kolorem czerwonym



(d) Przykładowa krzywa ROC klasyfikacji cechy jasnych kropek

Rysunek 5.4: Przykładowe zbinaryzowane obrazy znamion, wyniki klasyfikacji oraz przykładowa krzywa ROC dla cechy jasnych kropek. Na obrazach przedstawiony jest obraz zbinaryzowany znamienia wykazujący cechę jasnych kropek (a) oraz nie wykazujący tej cechy (b). Na kolejnych dwóch przedstawione są wyniki klasyfikacji za pomocą metody SVM cechy jasnych kropek na wykresie (c) oraz skuteczność klasyfikatora wyrażona za pomocą krzywej ROC (d)


obrazu przedstawiającego cechę *zwojów* niż do obrazu ze strukturą naczyń. Oczywiście jedynie hipotetycznie, ponieważ cechy te występują na różnych warstwach. Skuteczność klasyfikacji cechy naczyń jest jedynie zadowalająca w przypadku podzbioru testowego stanowiącej 80% zbioru obiektów (patrz: rysunek 5.8c, 5.8d).



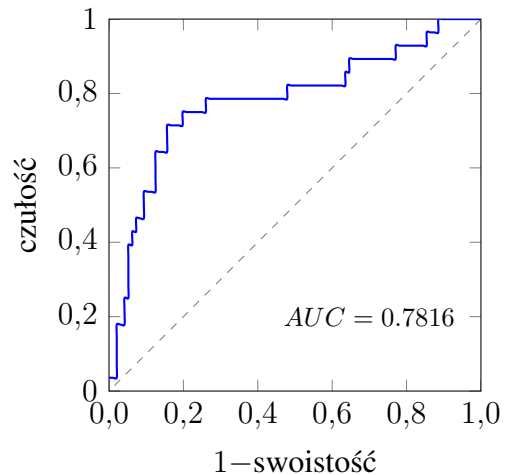
(a) Obraz zbinaryzowany znamienia wykazującego cechę *zwojów*



(b) Obraz zbinaryzowany znamienia nie wykazującego cechy *zwojów*



(c) Skuteczność klasyfikacji – ogólna skuteczność klasyfikatora oznaczona została kolorem niebieskim, czułość klasyfikatora kolorem zielonym, swoistość klasyfikatora kolorem czerwonym




(d) Przykładowa krzywa ROC klasyfikacji cechy *zwojów*


Rysunek 5.5: Przykładowe zbinaryzowane obrazy znamion, wyniki klasyfikacji oraz przykładowa krzywa ROC dla *zwojów*. Na obrazach przedstawiony jest obraz zbinaryzowany znamienia wykazujący cechę *zwojów* (a) oraz nie wykazujący tej cechy (b). Na kolejnych dwóch przedstawione są wyniki klasyfikacji za pomocą metody SVM *zwojów* na wykresie (c) oraz skuteczność klasyfikatora wyrażona za pomocą krzywej ROC (d)

Ubytki hemoglobiny


Ubytki hemoglobiny widoczne są jako małe lub duże struktury ze znacznie postrzępionym brzegiem. Przykład takiej struktury przedstawiono na rysunku 5.9a. Dla porównania, na rysunku 5.9b przedstawiono strukturę znamienia, które nie wykazuje cechy ubytków hemoglobiny. Jak widać na rysunku, struktura ta to niewielkie obiekty rozrzucone na obrazie. Innym przykładem jest struktura przedstawiona na rysunku 5.8a. W tym przypadku struktura




(a) Obraz zbinaryzowany znamienia wykazującego cechę nagromadzenia hemoglobiny



(b) Obraz zbinaryzowany znamienia nie wykazującego cechy nagromadzenia hemoglobiny




(c) Skuteczność klasyfikacji – ogólna skuteczność klasyfikatora oznaczona została kolorem niebieskim, czułość klasyfikatora kolorem zielonym, swoistość klasyfikatora kolorem czerwonym




(d) Przykładowa krzywa ROC klasyfikacji cechy nagromadzenia hemoglobiny

Rysunek 5.6: Przykładowe zbinaryzowane obrazy znamion, wyniki klasyfikacji oraz przykładowa krzywa ROC dla cechy nagromadzenia hemoglobiny. Na obrazach przedstawiony jest obraz zbinaryzowany znamienia wykazujący cechę nagromadzenia hemoglobiny (a) oraz nie wykazujący tej cechy (b). Na kolejnych dwóch przedstawione są wyniki klasyfikacji za pomocą metody SVM cechy nagromadzenia hemoglobiny na wykresie (c) oraz skuteczność klasyfikatora wyrażona za pomocą krzywej ROC (d)


jest niewielka. Skuteczność klasyfikacji jest zadowalający już przy wielkości podzbioru testowego stanowiącej 60% zbioru obiektów (patrz: 5.9c). Skuteczność klasyfikatora jest również zadowalająca, o czym świadczy rysunek 5.9d.




(a) Obraz zbinaryzowany znamienia wykazującego cechę naciekania



(b) Obraz zbinaryzowany znamienia nie wykazującego naciekania



(c) Skuteczność klasyfikacji – ogólna skuteczność klasyfikatora oznaczona została kolorem niebieskim, czułość klasyfikatora kolorem zielonym, swoistość klasyfikatora kolorem czerwonym



(d) Przykładowa krzywa ROC klasyfikacji cechy głębokości naciekania


Rysunek 5.7: Przykładowe zbinaryzowane obrazy znamion, wyniki klasyfikacji oraz przykładowa krzywa ROC dla cechy naciekania. Na obrazach przedstawiony jest obraz zbinaryzowany znamienia wykazujący cechę naciekania (a) oraz nie wykazujący tej cechy (b). Na kolejnych dwóch przedstawione są wyniki klasyfikacji za pomocą metody SVM cechy naciekania na wykresie (c) oraz skuteczność klasyfikatora wyrażona za pomocą krzywej ROC (d)

Wielkość znamienia


Duże znamiona widoczne są jako duże struktury, często o łagodnych brzegach jak na rysunku 5.10a. Mogą także występować w postaci postrzępionej jak w przypadku 5.5a. Przykład znamienia małego widoczny jest na rysunku 5.5b. Istnieją przypadki znamion, które są duże, ale przyjmują postać wielu niewielkich plam rozłożonych na całym obszarze zdjęcia.




(a) Obraz zbinaryzowany znamienia wykazującego cechę naczyń



(b) Obraz zbinaryzowany znamienia nie wykazującego cechy naczyń



(c) Skuteczność klasyfikacji – ogólna skuteczność klasyfikatora oznaczona została kolorem niebieskim, czułość klasyfikatora kolorem zielonym, swoistość klasyfikatora kolorem czerwonym




(d) Przykładowa krzywa ROC klasyfikacji cechy naczyń

Rysunek 5.8: Przykładowe zbinaryzowane obrazy znamion, wyniki klasyfikacji oraz przykładowa krzywa ROC dla cechy naczyń. Na obrazach przedstawiony jest obraz zbinaryzowany znamienia wykazujący cechę naczyń (a) oraz nie wykazujący tej cechy (b). Na kolejnych dwóch przedstawione są wyniki klasyfikacji za pomocą metody SVM cechy naczyń na wykresie (c) oraz skuteczność klasyfikatora wyrażona za pomocą krzywej ROC (d)


Wykrywanie dużych znamion jest proste. Świadczą o tym wyniki przedstawione na rysunku 5.10c oraz 5.10d.

Ubytki kolagenu


Ubytki kolagenu charakteryzują się na obrazie warstwy kolagenu jako obiekty skupione w jednym miejscu. Przykład takiej struktury przedstawiono na rysunku 5.11a. Dla porównania



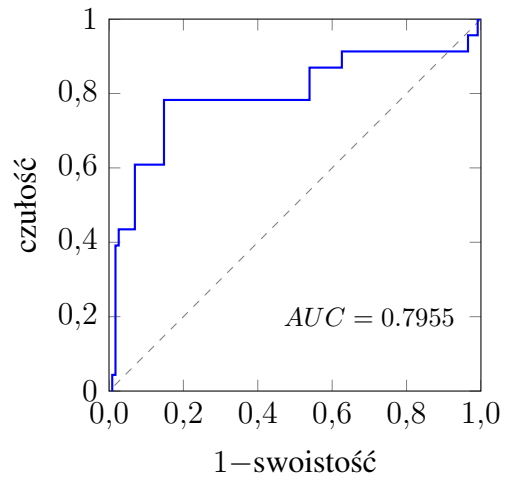
(a) Obraz zbinaryzowany znamienia wykazującego cechę ubytków hemoglobiny



(b) Obraz zbinaryzowany znamienia nie wykazującego cechy ubytków hemoglobiny




(c) Skuteczność klasyfikacji – ogólna skuteczność klasyfikatora oznaczona została kolorem niebieskim, czułość klasyfikatora kolorem zielonym, swoistość klasyfikatora kolorem czerwonym




(d) Przykładowa krzywa ROC klasyfikacji cechy ubytków hemoglobiny

Rysunek 5.9: Przykładowe zbinaryzowane obrazy znamion, wyniki klasyfikacji oraz przykładowa krzywa ROC dla cechy ubytków hemoglobiny. Na obrazach przedstawiony jest obraz zbinaryzowany znamienia wykazujący cechę ubytków hemoglobiny (a) oraz nie wykazujący tej cechy (b). Na kolejnych dwóch przedstawione są wyniki klasyfikacji za pomocą metody SVM cechy ubytków hemoglobiny na wykresie (c) oraz skuteczność klasyfikatora wyrażona za pomocą krzywej ROC (d)


przedstawiono obraz, gdzie cecha ubytków kolagenu nie występuje (patrz: rysunek 5.11b). W przypadku cechy ubytków wyniki wszystkich typów skuteczności są zbliżone (patrz: rysunek 5.11c). Krzywa ROC świadczy o tym, że zastosowany klasyfikator jest dobrym wyborem (patrz: rysunek 5.11d).




(a) Obraz zbinaryzowany dużego znamienia



(b) Obraz zbinaryzowany małego znamienia



(c) Skuteczność klasyfikacji – ogólna skuteczność klasyfikatora oznaczona została kolorem niebieskim, czułość klasyfikatora kolorem zielonym, swoistość klasyfikatora kolorem czerwonym




(d) Przykładowa krzywa ROC klasyfikacji cechy wielkości znamienia


Rysunek 5.10: Przykładowe zbinaryzowane obrazy znamion, wyniki klasyfikacji oraz przykładowa krzywa ROC dla dużego znamienia. Na obrazach przedstawiony jest obraz zbinaryzowany dużego znamienia (a) oraz małego znamienia (b). Na kolejnych dwóch przedstawione są wyniki klasyfikacji za pomocą metody SVM na wykresie (c) oraz skuteczność klasyfikatora wyrażona za pomocą krzywej ROC (d)

Nadmiar kolagenu


Nadmiar kolagenu, podobnie jak w przypadku ubytków kolagenu, charakteryzuje się strukturą skupioną wokół jednego punktu (patrz: rysunek 5.12a). W odróżnieniu od ubytków, znamiona, które nie wykazują nadmiaru kolagenu przyjmują formę struktury wielu podobnych obiektów rozrzuconych na obrazie (patrz: rysunek 5.12b). Czułość klasyfikatora dla cechy nadmiaru kolagenu okazuje się być średnio gorsza niż w przypadku cechy jasnych kropek (patrz: rysunek 5.12c oraz 5.12d).




(a) Obraz zbinaryzowany znamienia wykazującego cechę znacznych ubytków kolagenu



(b) Obraz zbinaryzowany znamienia nie wykazującego cechy ubytków kolagenu



(c) Skuteczność klasyfikacji – ogólna skuteczność klasyfikatora oznaczona została kolorem niebieskim, czułość klasyfikatora kolorem zielonym, swiostosc klasyfikatora kolorem czerwonym




(d) Przykładowa krzywa ROC klasyfikacji cechy ubytków kolagenu


Rysunek 5.11: Przykładowe zbinaryzowane obrazy znamion, wyniki klasyfikacji oraz przykładowa krzywa ROC dla cechy ubytków kolagenu. Na obrazach przedstawiony jest obraz zbinaryzowany znamienia wykazujący cechę ubytków (a) oraz nie wykazujący tej cechy (b). Na kolejnych dwóch przedstawione są wyniki klasyfikacji za pomocą metody SVM cechy ubytków na wykresie (c) oraz skuteczność klasyfikatora wyrażona za pomocą krzywej ROC (d)

5.4. Klasyfikacja częściowej oceny znamienia według skali Huntera


Ta część pracy poświęcona jest analizie wykorzystania metod fraktalnych do klasyfikacji częściowych ocen znamion barwnikowych według skali Huntera. Wektor cech został zbudowany z wartości wymiaru pudełkowego oraz lakunarności zdjęcia każdej cechy. Wartości




(a) Obraz zbinaryzowany znamienia wykazującego cechę nadmiaru kolagenu



(b) Obraz zbinaryzowany znamienia nie wykazującego cechy nadmiaru kolagenu



(c) Skuteczność klasyfikacji – ogólna skuteczność klasyfikatora oznaczona została kolorem niebieskim, czułość klasyfikatora kolorem zielonym, swoistość klasyfikatora kolorem czerwonym



(d) Przykładowa krzywa ROC klasyfikacji cechy nadmiaru kolagenu

Rysunek 5.12: Przykładowe zbinaryzowane obrazy znamion, wyniki klasyfikacji oraz przykładowa krzywa ROC dla cechy nadmiaru kolagenu. Na obrazach przedstawiony jest obraz zbinaryzowany znamienia wykazujący cechę nadmiaru (a) oraz nie wykazujący tej cechy (b). Na kolejnych dwóch przedstawione są wyniki klasyfikacji za pomocą metody SVM cechy nadmiaru na wykresie (c) oraz skuteczność klasyfikatora wyrażona za pomocą krzywej ROC (d)

te zostały dobrane na podstawie przedstawionej wcześniej analizy metod binaryzacji. Dzięki temu powstał wektor cech składający się z czternastu wartości oraz etykiety od zera do pięciu. Baza danych nie zawiera znamion, dla których częściowa ocena jest równa sześć lub siedem. Dotyczy to również bazy przed odfiltrowaniem. Wynika to z tego, że przypadki takie

Tabela 5.6: Baza znamion podzielona według częściowej oceny skali Huntera

Wynik częściowy skali Huntera	0	1	2	3	4	5
Liczba przypadków	65	144	106	64	25	12

zdarzają się niezwykle rzadko i świadczą o zaawansowanym stadium choroby. Dodatkowo, do zdiagnozowania czerniaka nie jest wymagane wykrycie wszystkich cech.

Na podstawie przeprowadzonej metodą F-Score [155] analizy fraktalnej charakterystyki cech wynika, że niektóre charakterystyki fraktalne cech mają większy wpływ na wynik w procesie klasyfikacji od innych. Największy wpływ na klasyfikację mają wartości wymiaru pudełkowego oraz lakunarności wielkości znamienia, następnie wartości wymiaru pudełkowego oraz lakunarności określające naciekanie. Istotne są także wartości lakunarności oraz wymiaru pudełkowego nagromadzenia hemoglobiny. Ostatnim mającym wpływ parametrem jest wartość wymiaru pudełkowego ubytku hemoglobiny. Najmniej istotnym parametrem jest wartość lakunarności *zwojów*.

Podjęto próbę klasyfikacji ocen znamion (patrz: tabela 5.6) na podstawie wektora cech składającego się z siedmiu wartości. Drogą selekcji metodą F-Score wykazano, że tylko siedem wartości ma istotny wpływ na wynik klasyfikacji. Podobnie jak w przypadku klasyfikacji cech, wykorzystano dwie metody klasyfikacji. Klasyfikację podjęto w stosunkach podzbioru trenującego do testowanego w takich samych proporcjach jak w przypadku klasyfikacji cech. Jediną istotną różnicą w porównaniu do klasyfikacji cech jest brak zastosowania sieci neuronowych w klasyfikacji częściowej oceny znamienia. Sieci neuronowe w każdym przypadku nie pozwalają na osiągnięcie skuteczności powyżej 50%. Ogólna klasyfikacja znamion przedstawiona została w tabeli 5.7. Przedstawione wyniki są średnią ze stu prób.

W porównaniu do klasyfikacji cech wyniki klasyfikacji ocen znamion są istotnie gorsze. Warto jednak zwrócić uwagę, że w przypadku klasyfikacji ocen znamion mamy do czynienia z klasyfikacją sześciu klas. Jest to istotnie trudniejszy problem klasyfikacyjny w porównaniu do klasyfikacji binarnej. Wyniki skuteczności na poziomie około 65% oraz 69% można uznać za zadowalające.

W tabelach 5.8, 5.9, 5.10, 5.11 oraz 5.12 przedstawiono skuteczność klasyfikacji poszczególnych znamion według uzyskanej oceny. Wyniki przedstawiono jako średnią liczbę wyboru danej oceny. W pierwszym wierszu przedstawiono etykiety ocen, których oczekiwano, a w kolumnach przedstawiono etykiety ocen, które zostały wybrane przez klasyfikator. Dzięki takiemu podejściu widać jak bardzo pomylił się klasyfikator w ocenie. Warto zwrócić uwagę,

Tabela 5.7: Wyniki klasyfikacji ocen znamion według skali Huntera za pomocą metody maszyny wektorów podpierających

	Skuteczność klasyfikacji				
	10/90	50/50	60/40	70/30	80/20
Częściowa ocena według skali Huntera	36,0%	57,6%	62,3%	65,7%	69,2%

Tabela 5.8: Wyniki klasyfikacji ocen znamienia według skali Huntera dla stosunku 10/90 podzbioru treningowego do podzbioru testowego

Etykieta	Sklasyfikowana jako					
	Ocena 0	Ocena 1	Ocena 2	Ocena 3	Ocena 4	Ocena 5
Ocena 0	41,6%	32,6%	16,7%	6,9%	2,2%	0,0%
Ocena 1	16,7%	49,6%	24,8%	6,7%	2,2%	0,0%
Ocena 2	10,7%	46,5%	34,7%	4,8%	3,0%	0,3%
Ocena 3	8,8%	44,5%	29,9%	15,4%	1,3%	0,1%
Ocena 4	1,7%	51,4%	30,0%	4,3%	12,6%	0,0%
Ocena 5	0,0%	52,7%	32,7%	0,0%	0,0%	14,6%

że wraz ze zmianą stosunku wielkości podzbioru testowego do podzbioru uczącego, zmienia się również liczba klasyfikowanych przypadków.

W przypadku stosunku 10/90 podzbioru testowego do uczącego, widać, że klasyfikator myli się często. Najlepiej klasyfikowane są przypadki o etykiecie 1. Skuteczność sięga niemal 50%. Klasyfikator poprawnie klasyfikuje ponad 40% przypadków o etykiecie 0. Dla przypadków o etykiecie 2 poprawnie klasyfikowanych jest ponad 30% przypadków. W przypadku pozostałych etykiet wyniki są bardzo słabe, ponieważ poprawnie sklasyfikowane przypadki stanowią średnio jedynie około 15%. Widać wyraźnie, że najczęściej klasyfikator mylił się przypisując obiektom etykietę 0, 1 lub 2.

Dla stosunku 50/50 podzbioru testowego do uczącego wyniki skuteczności są lepsze niż w porównaniu do wyników przedstawionych w tabeli 5.8. Podobnie jak w przypadku stosunku 10/90 podzbioru testowego do uczącego, klasyfikator najczęściej mylił się przypisując obiektom etykietę 1. Wyraźnie widać ogólny wzrost skuteczności klasyfikacji dla wszystkich przypadków średnio o 20%. Przypadki o etykiecie 2 oraz 3 są klasyfikowane poprawnie z niemal 50%

Tabela 5.9: Wyniki klasyfikacji ocen znamienia według skali Huntera dla stosunku 50/50 podzbioru treningowego do podzbioru testowego

Etykieta	Sklasyfikowana jako					
	Ocena 0	Ocena 1	Ocena 2	Ocena 3	Ocena 4	Ocena 5
Ocena 0	61,6%	21,5%	10,6%	5,5%	0,0%	0,8%
Ocena 1	9,9%	69,5%	14,7%	5,3%	0,5%	0,1%
Ocena 2	5,1%	32,3%	51,7%	8,1%	2,2%	0,6%
Ocena 3	5,6%	30,9%	12,8%	49,1%	1,3%	0,3%
Ocena 4	0,7%	14,0%	16,9%	10,0%	37,7%	0,0%
Ocena 5	0,0%	50,0%	10,0%	5,0%	0,0%	35,0%

Tabela 5.10: Wyniki klasyfikacji ocen znamienia według skali Huntera dla stosunku 60/40 podzbioru treningowego do podzbioru testowego

Etykieta	Sklasyfikowana jako					
	Ocena 0	Ocena 1	Ocena 2	Ocena 3	Ocena 4	Ocena 5
Ocena 0	66,1%	22,3%	7,7%	3,9%	0,0%	0,0%
Ocena 1	7,8%	76,9%	9,1%	4,4%	1,6%	0,2%
Ocena 2	6,4%	29,0%	56,5%	6,5%	1,6%	0,0%
Ocena 3	6,5%	32,7%	9,6%	47,4%	3,1%	0,7%
Ocena 4	0,0%	48,0%	10,0%	4,0%	38,0%	0,0%
Ocena 5	0,0%	36,0%	10,0%	2,0%	0,0	52,0%

skutecznością. Przypadki o etykiecie 1 mają nadal najlepszą skuteczność i są prawidłowo klasyfikowane w prawie 70% przypadków. Przypadki o etykiecie 5 klasyfikowane są poprawnie w 35% przypadków. Warto tutaj zwrócić uwagę, że przypadki o etykiecie 5 najczęściej są mylone z obiektami o etykiecie 1. Dla przypadków o etykiecie 3 jest podobnie. Są one nieprawidłowo klasyfikowane jako obiekty o etykiecie 1 w ponad 30% przypadków.

Na podstawie przedstawionych wyników w tabeli 5.10 można wyciągnąć kilka wniosków. Jedynie przypadki o etykiecie 4 nie są prawidłowo klasyfikowane w conajmniej 40% przypadków. Wzrost poprawnie sklasyfikowanych przypadków jest znacznie mniejszy niż

Tabela 5.11: Wyniki klasyfikacji ocen znamienia według skali Huntera dla stosunku 70/30 podzbioru treningowego do podzbioru testowego

Etykieta	Sklasyfikowana jako					
	Ocena 0	Ocena 1	Ocena 2	Ocena 3	Ocena 4	Ocena 5
Ocena 0	74,0%	15,5%	5,5%	5,0%	0,0%	0,0%
Ocena 1	12,0%	75,3%	8,9%	3,3%	0,5%	0,0%
Ocena 2	5,0%	26,8%	60,6%	4,4%	3,2%	0,0%
Ocena 3	4,2%	24,2%	12,6%	57,9%	1,1%	0,0%
Ocena 4	0,0%	40,0%	16,2%	3,8%	40,0%	0,0%
Ocena 5	2,5%	32,5%	10,0%	5,0%	0,0%	50,0%

dla stosunku podzbioru testowego do uczącego w proporcji 50/50. Obiekty o etykiecie 1 sklasyfikowane są prawidłowo w ponad 75% przypadków. Widać również, że dopiero przy proporcjach podzbioru uczącego do testowego 60/40 obiekty o etykiecie 5 są poprawnie sklasyfikowane w ponad 50% przypadków. Jest to oczywiście bardzo istotne z punktu widzenia pacjenta.

Wyniki przedstawione w tabeli 5.11 przedstawiają skuteczność klasyfikacji dla proporcji 70/30 podzbioru uczącego do testowego. Z przedstawionych wyników wynika to, że jedynie dla obiektów o etykiecie 0 oraz 3 widać wyraźny wzrost prawidłowo sklasyfikowanych przypadków. W pozostałych przypadkach wzrost jest nieznaczny, a w przypadku obiektów o etykiecie 1 oraz 5 można zauważyć nieznaczny spadek. Warto również zwrócić uwagę na to, że nie odnotowano obiektów, które mylnie sklasyfikowano jako obiekty o etykiecie 5.

W porównaniu do danych przedstawionych w tabelach 5.8, 5.9, 5.10 oraz 5.11, wyniki przedstawione w tabeli 5.12 okazują się być najlepsze. Wynika to przede wszystkim z tego, że proces uczenia klasyfikatora oparty został na największym w porównaniu do pozostałych podzbiórze uczącym. Dla obiektów o etykiecie 1, 2 oraz 5 skuteczność wynosi co najmniej 75%. Jest to bardzo dobry wynik, zwłaszcza obiektów o etykiecie 5. W pozostałych przypadkach skuteczność wynosi około 60%. Najgorzej sklasyfikowane są obiekty o etykiecie 4, gdzie skuteczność wynosi jedynie 58%. Klasyfikator myli się najczęściej przypisując obiektem etykietę 1. Dotyczy to średnio około 22% przypadków. Klasyfikator najrzadziej myli się przypisując mylnie obiektom etykiety 5.

Tabela 5.12: Wyniki klasyfikacji ocen znamienia według skali Huntera dla stosunku 80/20 podzbioru treningowego do podzbioru testowego

Etykieta	Sklasyfikowana jako					
	Ocena 0	Ocena 1	Ocena 2	Ocena 3	Ocena 4	Ocena 5
Ocena 0	75,4%	15,4%	7,7%	1,5%	0,0%	0,0%
Ocena 1	6,9%	77,9%	9,7%	4,8%	0,4%	0,3%
Ocena 2	7,6%	21,9%	60,5%	5,2%	4,3%	0,5%
Ocena 3	6,1%	23,1%	8,5%	61,5%	0,0%	0,8%
Ocena 4	4,0%	24,0%	12,0%	0,8%	58,0%	0,0%
Ocena 5	0,0%	25,0%	0,0%	0,0%	0,0%	75,0%

5.5. Podsumowanie

Na podstawie wyników przedstawionych w poprzednich podrozdziałach można wyciągnąć kilka wniosków. Większość z nich została już opisana w poprzednich podrozdziałach. **Na ich podstawie można postawić tezę, że metody fraktalne mają zastosowanie w procesie diagnostycznym czerniaka w przypadku zdjęć wielospektralnych.** Wskazują na to osiągnięte wyniki zarówno klasyfikacji cech jak i ocen znamion. Skuteczność wykrywania cech na poziomie większym od 80% jest wysoce zadowalająca. Wskazuje jednocześnie na możliwość zautomatyzowania wykrywania niektórych cech, które charakteryzują czerniaka. Automatyzacja natomiast niesie istotną pomoc lekarzom w procesie diagnostycznym. Przedstawiona klasyfikacja znamion nie pozwala jednak na stworzenie w pełni zautomatyzowanego systemu. Wynika to z kilku powodów. Po pierwsze, badany zbiór obiektów nie zawiera dostatecznie wielu przypadków czerniaka. Z tym wiąże się mała liczba przypadków, którym przyznano pięć, sześć oraz siedem punktów. Jest to istotna część, która wymaga dalszych prac w przyszłości wraz z powiększeniem bazy zdjęć. Po drugie, przedstawione metody należy przed wprowadzeniem do zastosowań komercyjnych najpierw sprawdzić na zasadzie badań klinicznych. Istotne jest, aby móc zweryfikować podejście do analizy znamion w praktyce. W kolejnym rozdziale przedstawiono możliwości wykorzystania przedstawionych metod w rozwiązaniach komercyjnych.

Przedstawione w niniejszym rozdziale wyniki pozwalają także wyciągnąć wnioski co do zastosowania metod wyznaczania progu w procesie binaryzacji obrazów. Wykorzystano jedynie ponad czterdzieści metod, co pozwala przypuszczać, że istnieją metody, których nie

wykorzystano w pracy, a które jednocześnie pozwolą na uzyskanie jeszcze lepszych wyników klasyfikacji niż te, które przedstawiono w pracy.

Próba wykrywania cech znamion barwnikowych w sposób automatyczny nie jest niczym nowym, ponieważ prowadzone były już badania nad automatyzacją wykrywania cech [156, 157, 158, 159, 160, 161, 162]. W pracy przedstawiono wyniki, które świadczą o tym, że wykrywanie takich cech jest możliwe ze skutecznością na zadowalającym poziomie. Pozwala to przypuszczać, że wykorzystanie metod fraktalnych jest możliwe w przypadku wykrywania cech, które są częścią innych skal. Dotyczy to także zdjęć standardowych znamion uzyskanych za pomocą fal światła widzialnego.


6. Przyszłe badania

W poprzednim rozdziale opisano wyniki analizy fraktalnej zdjęć wielowarstwowych. Wynika z nich jasno, że cechy oparte na analizie fraktalnej mają istotny wpływ na diagnostykę znamion barwnikowych. Wykazanie przydatności cech fraktalnych było możliwe dzięki wykorzystaniu środków z grantu promotorskiego N518 506439. Kolejnym etapem będzie wykazanie przydatności tych cech w codziennej pracy dermatologów. Aby to umożliwić, napisana została aplikacja. Aplikacja ta będzie dostępna na AppStore. Dedykowana jest dla dermatoskopów, które można połączyć wraz z przystawką do urządzeń mobilnych takich jak iPhone. Przykładowe ekrany aplikacji przedstawiono na rysunkach 6.1a–c. Aplikacja składa się z dwóch części: serwerowej oraz mobilnej. Część serwerowa wykonuje przedstawione w pracy obliczenia na zdjęciach. Wyniki zostają następnie przesłane do aplikacji mobilnej. Dzięki przechowywaniu zdjęć na serwerze możliwa będzie analiza zdjęć pod kątem innych cech niż te, które zostały przeanalizowane w niniejszej pracy. Jak wspomniano w rozdziale I, cech charakteryzujących czerniaka jest kilkadziesiąt, a w niniejszej pracy poddano analizie jedynie siedem cech. Dodatkową, oczywistą korzyścią wynikającą z gromadzenia zdjęć, jest stale powiększająca się baza.




Rysunek 6.1: Zrzuty ekranu aplikacji Mole Diagnostic


Na rysunku 6.1c widoczny jest ekran dodawania nowego znamienia. Lekarz może wstępnie ocenić znamię według wybranej skali. Dane te są również przechowywane w bazie danych na



(a) Widok z przodu



(b) Widok z dołu



(c) Widok z prawej strony



(d) Widok z lewej strony



(e) Widok od spodu

Rysunek 6.2: Nowoczesne urządzenie diagnostyczne, które ma wykorzystywać opisane w pracy metody wspierające diagnostykę

serwerze. Ma to za zadanie późniejszą weryfikację. Dodatkowo, znamię można zlokalizować na ciele pacjenta (patrz: rysunek 6.1b). Znane są przypadki częstszego występowania czerniaka u mężczyzn oraz u kobiet w niektórych partiach ciała, stanowi to istotną informację w celu dalszych badań. Wynika to z tego, że czerniak przejawia odmienne cechy w niektórych miejscach, jak na przykład na rękach czy stopach. Aplikacja ma zasięg globalny, więc dodatkowym problemem badawczym do rozwiązania będzie problem analizy znamion w przypadku różnych karnacji oraz kolorów skóry.

Obecnie prowadzone są prace nad znalezieniem inwestora do stworzenia osobnego urządzenia bazującego na platformie Android (patrz: rysunek 6.2). Urządzenie w zamierzeniu powinno być dermatoskopem mobilnym posiadającym jednocześnie wyświetlacz oraz funkcje znane z urządzeń mobilnych, jak na przykład iPhone. Celem stworzenia takiego urządzenia jest wprowadzenie urządzenia diagnostycznego, które w odróżnieniu od obecnie używanych, mogłoby samodzielnie wspomagać proces diagnostyczny. Jednocześnie prowadzone są prace nad złożeniem wniosku patentowego chroniącego urządzenie przed kopiowaniem.

Poza stworzeniem urządzenia prowadzone są także prace nad przeniesieniem zastosowanych metod na standardowe zdjęcia znamion. Wynika to z tego, że wiele skal bazuje na standardowych zdjęciach dermatoskopowych. Badania takie pozwolą przypuszczalnie na znalezienie zależności zachodzących między zdjęciami uzyskanymi za pomocą fal światła widzialnego, a zdjęciami wielowarstwowymi.

Bibliografia

- [1] Cancer facts and figures 2014. <http://www.cancer.org/acs/groups/content/@research/documents/webcontent/acspc-042151.pdf>, 2014.
- [2] S. W. Menzies. Automated epiluminescence microscopy: Human vs machine in the diagnosis of melanoma. *Archives of Dermatology*, 135:1538–1540, 1999.
- [3] L. Lusted. Signal detectability and medical decision-making. *Science*, 171:1217–1219, 1971.
- [4] C. Metz. Basic principles of roc analysis. *Seminar in Nuclear Medicine*, 8:283–298, 1978.
- [5] N. Obuchowski. Receiver operating characteristic curves and their use in radiology. *Radiology*, 229:3–8, 2003.
- [6] T. Trebaol, M. Savvides. Fractal encoding of low resolution iris imagery for improved matching. *Applied Imagery Pattern Recognition Workshop*, 37:1–4, 2008.
- [7] A. A. B. Shirazi, L. Nasser. A novel algorithm to classify iris image based on differential of fractal dimension by using neural network. *International Conference on Advanced Computer Theory and Engineering ICACTE'08*, wolumen 1, strony 181–185, Phuket, Tajlandia, 2008.
- [8] D. Haiyan, L. Hong. Texture analysis and characteristic identification about plaque tissues of ivus. *International Conference on Computational and Information Sciences ICCIS'10*, wolumen 1, strony 873–876, Chengdu, Sichuan, Chiny, 2010.
- [9] M. S. Sunder, A. Ross. Iris image retrieval based on macro-features. *International Conference on Pattern Recognition ICPR'10*, wolumen 1, strony 1318–1321, Sztambuł, Turcja, 2010.
- [10] F. L. Lizzi, E. J. Feleppa. Image processing and pre-processing for medical ultrasound. *Proceedings of the 29th Applied Imagery Pattern Recognition Workshop*, wolumen 1, strony 187–192, Waszyngton, USA, 2000.
- [11] C.-H. Lee, P. W. Huang. Classification for pathological prostate images based on fractal analysis. *Congress on Image and Signal Processing*, wolumen 3, strony 113–117, 2008.
- [12] G. Jayalalitha, R. Uthayakumar. Recognition of cervical cancer based on fractal dimension. *International Conference on Advances in Recent Technologies in Communication and Computing ARTCom'09*, wolumen 1, strony 532–536, Kottayam, Kerala, Indie, 2009.

- [13] D. Alexandra, C. Coculescu, J. L. Stanica, i in. Using fractal techniques to reduce haziness in medical imaging. wolumen 1, strony 92–95, 2009.
- [14] S. Don, K. Revathy. Classifying mammogram images using fractal features. *International Conference on Computational Intelligence and Multimedia Applications*, wolumen 2, strony 537–543, Sivakasi, Tamil Nadu, Indie, 2007.
- [15] K. Bojar, M. Nieniewski. New features for classification of cancerous masses in mammograms based on morphological dilation. *Proceedings 5th International Conference on Visual Information Engineering*, wolumen 1, strony 111–116, Xian, Chiny, 2008.
- [16] M. E. Celebi, Y. A. Aslandogan, P. R. Bergstresser. Unsupervised border detection of skin lesion images. *Proceedings of the International Conference on Information Technology: Coding and Computing*, wolumen 2, strony 123–128, Las Vegas, NV, USA, 2005.
- [17] G. Sethumadhavan, S. Sankaran. Border detection and cancer propagation on spectral bands of malignant melanoma using six sigma threshold. *Eighth IEEE/ACIS International Conference on Computer and Information Science ICIS'09*, wolumen 1, strony 586–592, Shanghai, Chiny, 2009.
- [18] V. B. Pires, C. A. Z. Barcelos. Edge detection of skin lesions using anisotropic diffusion. *Seventh International Conference on Intelligent Systems Design and Applications ISDA'07*, wolumen 1, strony 363–370, Rio de Janeiro, Brazylia, 2007.
- [19] T. K. Lee, E. Claridge. Predictive power of irregular border shapes for malignant melanomas. *Skin Research and Technology*, 11:1–8, 2005.
- [20] E. Bullitt, I. Jung, K. Muller, i in. Determining malignancy of brain tumors by analysis of vessel shape. *Lecture Notes in Computer Science*, 3217:645–653, 2004.
- [21] B. S. Arribisala, E. Claridge. A border irregularity measure using a modified conditional entropy method as a malignant melanoma predictor. *Lecture Notes in Computer Science*, 3656:914–921, 2005.
- [22] M. E. Celebi, H. A. Kingravi, B. Uddin, i in. Border detection in dermoscopy images using statistical region merging. *Skin Research and Technology*, 14:347–353, 2008.
- [23] G. Di Leo, A. Paolillo, P. Sommella, i in. Automatic diagnosis of melanoma: a software system based on the 7-point check-list. *Proceedings of the 43rd Hawaii International Conference on System Sciences HICSS'10*, wolumen 1, strony 1–10, Poipu, Kauai, Hawaje, USA, 2010.
- [24] M. G. Rippon, K. Springett, R. Walmsley, i in. Ultrasound assessment of skin and wound tissue: comparison with histology. *Skin Research and Technology*, 4:147–150, 1998.
- [25] H. Tak La, A. Al-Jumaily. Automatically early detection of skin cancer: Study based on neural network classification. *International Conference of Soft Computing and Pattern Recognition*, wolumen 1, strony 1–6, Malacca, Malezja, 2009.

- [26] J. P. Grzymala-Busse, J. W. Grzymala-Busse, Z. S. Hippe. Melanoma prediction using data mining system lers. *Proceedings of the 25th Annual International Computer Software and Applications Conference*, wolumen 1, strony 615–620, Los Alamitos, CA, USA, 2002.
- [27] J. W. Grzymala-Busse, Z. S. Hippe. Data mining methods supporting diagnosis of melanoma. *18th IEEE Symposium on Computer-Based Medical Systems*, wolumen 1, strony 371–373, Dublin, 2005.
- [28] A. Chiem, A. Al-Jumaily, R. N. Khushaba. A novel hybrid system for skin lesion detection, intelligent sensors. *Intelligent Sensors, Sensor Networks and Information ISSNIP'07*, wolumen 1, strony 567–572, Melbourne, Australia, 2007.
- [29] A. G. Manousaki, A. G. Manios, E. I. Tsompanaki, i in. A simple digital image processing system to aid in melanoma diagnosis in an everyday melanocytic skin lesion unit. a preliminary report. *International Journal of Dermatology*, 45:402–410, 2006.
- [30] A. Parolin, E. Herzer, C. R. Jung. Semi-automated diagnosis of melanoma through the analysis of dermatological images. *23rd SIBGRAPI – Conference on Graphics, Patterns and Images CGPI'10*, wolumen 1, strony 71–78, Gramado, Rio Grande do Sul, Brazylia, 2010.
- [31] A. Sboner, P. Bauer, G. Zumiani, i in. Clinical validation of an automated system for supporting the early diagnosis of melanoma. *Skin Research and Technology*, 10:184–192, 2004.
- [32] D. L. Hudson, M. E. Cohen. Software solutions for biomedical decision making. *International Conference on Software Engineering Advances ICSEA'07*, wolumen 1, strona 63, Cap Esterel, Francja, 2007.
- [33] H. Kwasnicka, M. Paradowski. Melanocytic lesion images segmentation enforcing by spatial relations based declarative knowledge. *Proceedings of the 5th International Conference on Intelligent Systems Design and Applications ISDA'05*, wolumen 1, strony 286–291, Wrocław, 2005.
- [34] H. Mirzaalian, G. Hamarneh, T. K. Lee. A graph-based approach to skin mole matching incorporating template-normalized coordinates. *International Conference on Future Computer and Communication CVPR'09*, wolumen 1, strony 2152–2159, Miami, FL, USA, 2009.
- [35] S. Cotton, E. Claridge. Developing a predictive model of human skin coloring. *Proceedings of SPIE, Medical Imaging*, 2708:814–825, 1996.
- [36] S. Cotton, E. Claridge, P. Hall. Non-invasive skin imaging. *Information Processing in Medical Imaging*, 1230:501–506, 1997.
- [37] S. Cotton. *A non-invasive imaging for assisting in the diagnosis of malignant melanoma*. Praca doktorska, Birmingham University, UK, 1998.

- [38] S. Tomatis, M. Carrara, A. Bono, et al. Automated melanoma detection with a novel multispectral imaging system: results of a prospective study. *Physics in Medicine and Biology*, 50:1675–1687, 2005.
- [39] M. Rajab. *Neural network edge detection and skin lesions image segmentation methods: analysis and evaluation*. Praca doktorska, Nottingham University, UK, 2003.
- [40] M. Carrara, A. Bono, C. Bartoli, et al. Multispectral imaging and artificial neural network: mimicking the management decision of the clinician facing pigmented skin lesions. *Physics in Medicine and Biology*, 52:2599–2613, 2007.
- [41] E. Wilson, J. Emery, A. Kinmonth, et al. The cost-effectiveness of a novel dermoscope diagnostic aid for the management of pigmented skin lesions in primary care: a decision-analytic model. *Value in Health*, 16:356–366, 2013.
- [42] G. Jayalalitha, R. Uthayakumar. Estimating the skin cancer using fractals. *International Conference on Computational Intelligence and Multimedia Applications*, wolumen 1, strony 307–312, Sivakasi, Tamil Nadu, Indie, 2007.
- [43] V. Behraves, S. Farshchi. Skin cancer detection algorithm, a novel fractal based approach. *International Journal on Computational Sciences and Applications*, 2:1–7, 2012.
- [44] M. Moncrieff, S. Cotton, E. Claridge, P. Hall. Spectrophotometric intracutaneous analysis: a new technique for imaging pigmented skin lesions. *British Journal of Dermatology*, 146:448–457, 2002.
- [45] T. B. Fitzpatrick. The validity and practicality of sun-reactive skin types I through VI. *Archives of Dermatology*, 124:869–871, 1988.
- [46] Cancer facts and figures 2012. <http://www.cancer.net/patient/Cancer+Types/Melanoma?sectionTitle=Statistics>, 2012.
- [47] A. Jemal, R. Siegel, E. Ward, et al. Cancer statistics. *Cancer Journal for Clinicians*, 58:71–96, 2008.
- [48] Office for National Statistics. Registrations of cancer diagnosed in 2008. <http://www.ons.gov.uk/ons/rel/vsob1/cancer-statistics-registrations-england-series-mb1-no-39-2008/cancer-statistics-registrations-series-mb1.pdf>, 2008.
- [49] J. Ferlay, P. Autier, M. Boniol, et al. Estimates of the cancer incidence and mortality in Europe 2006. *Annals of Oncology*, 18:581–592, 2007.
- [50] Cancer Council. Australia. Cancer in Australia, an overview 2008. <http://www.cancer.org.au/cancersmartlifestyle/SunSmart/Skincancerfactsandfigures.htm>.
- [51] S. Brenner, I. Pomerantz, Y. Oz, et al. Method and a system for imaging and analysis for mole evolution tracking. Patent US2011/0040192 A1, 2011.
- [52] R. Meyer. Device for close-up photography of surfaces. Patent US5825502 A, 1998.
- [53] D. Perkins. Measuring adapter for viewing instrument. Patent US6010450 A, 1998.

- [54] P. Mueller, H. Glaum, R. Hempfling. Illuminated optical enlargement device. Patent US6384988 B1, 2002.
- [55] R. Alfano, Y. Budansky, J. Luo. Spectral polarizing tomographic dermatoscope. Patent US6587711 B1, 2003.
- [56] V. Skladnev, A. Gutenev, S. Menzies, i in. System and method for examining, recording and analyzing dermatological conditions. Patent US6993167 B1, 2006.
- [57] D. Gutkowicz-Krusin, J. Gulfo. Quantitative analysis of skin characteristics. Patent US7894651 B2, 2011.
- [58] M. R. Cane, S. D. Cotton, M. A. Schumann, i in. Epithelial diagnostic aid. Patent US2004/0092802 A1, 2004.
- [59] V. N. Skladnev, S. Menzies, A. Batrac, i in. Boundary finding in dermatological examination. Patent US2004/0264749 A1, 2004.
- [60] V. N. Skladnev, A. Gutenev, S. Menzies, i in. Diagnostic feature extraction in dermatological examination. Patent US2004/0267102 A1, 2004.
- [61] W. Stoecker, R. Moss, J. Stanley, i in. Automatic detection of critical dermoscopy features for malignant melanoma diagnosis. Patent US2006/0269111 A1, 2006.
- [62] S. J. Preece, S. D. Cotton. Method and apparatus for detecting the presence of dermal melanin in epithelial tissue. Patent US2007/0161910 A1, 2007.
- [63] T. Gizewski. Derma diagnostic and automated data analysis system. Patent US2008/0161661 A1, 2008.
- [64] H. A. Heine, H. Scholsser, D. Schade, i in. Dermatoscope. Patent US2004/0062056 A1, 2004.
- [65] L. Kelly, M. Gannon, M. Gerling, i in. Generating and managing medical documentation sets. Patent US2009/0094061 A1, 2009.
- [66] L. Kelly, M. Gannon, M. Gerling, i in. Generating and managing medical documentation sets. Patent US2009/0248443 A1, 2009.
- [67] N. A. Mullani. Dermoscopy epiluminescence device employing cross and parallel polarization. Patent US2004/0174525 A1, 2004.
- [68] N. A. Mullani. Dermoscopy epiluminescence device employing cross and parallel polarization. Patent US2006/0132774 A1, 2006.
- [69] N. A. Mullani. Dermoscopy epiluminescence device employing multiple color illumination sources. Patent US2004/0201846 A1, 2004.
- [70] N. A. Mullani. Dermoscopy epiluminescence device employing multiple color illumination sources. Patent US2006/0139640 A1, 2006.
- [71] S. Cotton, R. Morse, M. Chellingworth. Method and apparatus for measuring collagen thickness. Patent US2007/0161910 A1, 2009.

- [72] F. Nachbar, W. Stolz, T. Merkle, i in. The abcd rule of dermatoscopy: High prospective value in the diagnosis of doubtful melanocytic skin lesions. *Journal of the American Academy of Dermatology*, 30:551–559, 1994.
- [73] R. Johr, H. P. Soyer, G. Argenziano, i in. *Dermoscopy. The Essentials*. Elsevier, 2004.
- [74] H. P. Soyer, G. Argenziano, R. Hofmann-Wellenhof, i in. *Color atlas of melanocytic lesions of the skin*. Springer, 2010.
- [75] W. Stolz, O. Falco, P. Bliiek, i in. *Color atlas of dermatoscopy, 2nd enlarged and completely revised edition*. Berlin: Blackwell publishing, 2002.
- [76] D. S. Rigel, R. J. Friedman, A. W. Kopf, i in. Abcde—an evolving concept in the early detection of melanoma. *Archives of Dermatology*, 141:1032–1034, 2005.
- [77] J. D. Emery, J. Hunter, P. N. Hall, i in. Accuracy of siascopy for pigmented skin lesions encountered in primary care: development and validation of a new diagnostic algorithm. *BMC Dermatology*, 10:1–9, 2010.
- [78] A. Breslow. Thickness, cross-sectional areas and depth of invasion in the prognosis of cutaneous melanoma. *Annals of Surgery*, 172:902–908, 1970.
- [79] W. H. Clark, L. From, E. A. Bernardino, i in. Histogenesis and biologic behavior of primary human malignant melanomas of the skin. *Cancer Research*, 29:705–726, 1969.
- [80] P. Soyer, G. Argenziano, I. Zalaudek. Three-point checklist of dermatoscopy. *Dermatology*, 208:27–31, 2004.
- [81] J. Henning, S. Dusza, S. Wang, i in. The cash (color, architecture, symmetry, and homogeneity) algorithm for dermatoscopy. *Archives of Dermatology*, 56:45—52, 2007.
- [82] H. Kittler, E. Riedl, C. Rosendahl, i in. Dermatoscopy of unpigmented lesions of the skin: a new classification of vessel morphology based on pattern analysis. *Dermopathology: Practical and Conceptual*, 14:3–7, 2008.
- [83] P. Denoix. Enquete permanente dans les centres anticancereux. *Bulletin de l'Institut national d'hygiene*, 1:70, 1946.
- [84] G. Argenziano, C. Catricalà, M. Ardigo, i in. Seven-point checklist of dermatoscopy revisited. *The British Journal of Dermatology*, 4:785–90, 2011.
- [85] S. W. Menzies, C. Ingvar, K. A. Crotty, i in. Frequency and morphologic characteristics of invasive melanomas lacking specific surface microscopic features. *Archives of Dermatology*, 132:1178–1182, 1996.
- [86] C. Dolianitis, J. Kelly, R. Wolfe, i in. Comparative performance of 4 dermoscopic algorithms by nonexperts for the diagnosis of melanocytic lesions. *Archives of Dermatology*, 141:1008–1014, 2005.
- [87] F. Ercal, A. Chawla, W. Stoecker, i in. Neural network diagnosis of malignant melanoma from color images. *IEEE Transactions on Biomedical Engineering*, 41:837–845, 1994.

- [88] C. Burges. A tutorial on support vector machines for pattern recognition. *Data Mining Knowledge Discovery*, 2:121–167, 1998.
- [89] X. Wu, V. Kumar, J. Quinlan, i in. Top 10 algorithms in data mining. *Knowledge and Information Systems*, 14:1–37, 2008.
- [90] L. Kuncheva. *Combining pattern classifiers. Methods and algorithms*. Wiley, 2004.
- [91] J. Park, I. Sandberg. Pattern classification using neural networks. *Neural Computation*, 5:305–316, 1993.
- [92] W. Piątkowska, J. Martyna, L. Nowak, i in. A decision support system based on the semantic analysis of melanoma images using multi-elitist pso and svm. *Proceedings of the 7th International Conference on Machine Learning and Data Mining in Pattern Recognition MLDM'11*, wolumen 1, strony 362–374, Newark, NJ, USA, 2011.
- [93] K. Przystalski, L. Nowak, M. J. Ogorzałek, i in. Semantic analysis of skin lesions using radial basis function neural networks. *Human-System Interactions 2010*, wolumen 1, strony 128–132, Kraków, 2010.
- [94] K. Przystalski, L. Nowak, M. J. Ogorzałek, i in. Decision support system for skin cancer diagnosis. *The Ninth International Symposium on Operations Research and Its Applications ISORA'10*, wolumen 1, strony 406–413, Rzeszów, 2010.
- [95] K. Stapor. *Automatyczna klasyfikacja obiektów*. Exit, 2005.
- [96] R. Lippman. Pattern classification using neural networks. *IEEE Transactions on Biomedical Engineering*, 27:47–64, 1989.
- [97] L. Newelski. *Algebra liniowa II*. Skrypt Uniwersytetu Wrocławskiego, 2005.
- [98] A. Herdegen. *Algebra Liniowa i Geometria*. Discepto, 2010.
- [99] R. M. Olejnik. *Matematyczna teoria miary a metodologiczne analizy procedur pomiarowych*. OBI, 2011.
- [100] J. Povstenko. *Wprowadzenie do metod numerycznych*. Exit, 2005.
- [101] D. Huttenlocher, G. Klanderman, W. Rucklidge. Comparing images using the hausdorff distance. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 15:85–863, 1993.
- [102] H.-O. Peitgen, H. Huergens, D. Saupe. *Granice Chaosu. Fraktale*. PWN, 2002.
- [103] J. Kudrewicz. *Fraktale i chaos*. WNT, 2007.
- [104] F. Hausdorff. Dimension und äußeres maß. *Mathematische Annalen*, 79:157–179, 1918.
- [105] H. von Koch. Sur une courbe continue sans tangente, obtenue par une construction geometrique elementaire. *Arkiv for Matematik*, 1:681–704, 1904.
- [106] W. Sierpiński. Sur une courbe cantorienne qui contient une image biunivoquet et continue detoute courbe donnee. *Academie Paris*, 162:629–632, 1916.
- [107] G. Cantor. De la puissance des ensembles parfait de points. *Acta Mathematica*, 4:381–392, 1884.

- [108] B. Mandelbrot. *The Fractal Geometry of Nature*. W. H. Freeman and Comp., 1982.
- [109] S. Kotowski, W. Kosiński, Z. Michałowicz, i in. Fractal dimension of trajectory as invariant of genetic algorithms. *Artificial Intelligence and Soft Computing*, 5097:414–425, 2008.
- [110] A. Echelard, J. L. Véhel, I. Taralova. Application of fractal tools for the classification of microscopical images of milk fat. *GRETSI'05 Symposium on Signal and Image Processing*, wolumen 1, strony 1–4, Louvain-la-Neuve, Belgia, 2005.
- [111] J. Wu, C. Jiang, L. Yao. Medical image retrieval based on fractal dimension. *The 9th International Conference for Young Computer Scientists*, wolumen 1, strony 2959–2961, Zhang Jia Jie, Hunan, Chiny, 2008.
- [112] S. Gilmore, R. Hofmann-Wellenhof, H. P. Soyer J. Muir. Lacunarity analysis: A promising method for the automated assessment of melanocytic naevi and melanoma. *PLoS ONE*, 4:1–10, 2009.
- [113] C. Glasbey. An analysis of histogram-based thresholding algorithms. *Graphical Models and Image Processing*, 55:532–537, 1993.
- [114] J. Kapur, P. Sahoo, A. Wong. A new method for gray-level picture thresholding using the entropy of the histogram. *Computer Vision, Graphics, and Image Processing*, 29:273–285, 1985.
- [115] M. Sezgin, Bulent Sankur. Survey over image thresholding techniques and quantitative performance evaluation. *Journal of Electronic Imaging*, 13:146–165, 2004.
- [116] A. Rosenfeld, P. De la Torre. Histogram concavity analysis as an aid in threshold selection. *IEEE Systems, Man, and Cybernetics Society*, strony 231–235, 1983.
- [117] M. I. Sezan. A peak detection algorithm and its application to histogram-based image data reduction. *Graphical Models Image Processing*, 29:47–59, 1985.
- [118] J. C. Olivo. Automatic threshold selection using the wavelet transform. *Graphical Models Image Processing*, 56:205–218, 1994.
- [119] N. Ramesh, J. H. Yoo, I. K. Sethi. Thresholding based on histogram approximation. *IEEE Proceedings - Vision Image Signal Process*, 142:271–279, 1995.
- [120] R. Guo, S. M. Pandit. Automatic threshold selection based on histogram modes and a discriminant criterion. *Machine Vision and Applications*, 10:331–338, 1998.
- [121] T. Ridler, S. Calvard. Picture thresholding using an interactive selection method. *IEEE Transactions on Systems, Man and Cybernetics*, 8:630–632, 1978.
- [122] N. Otsu. A threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics*, 9:62–66, 1979.
- [123] J. Kittler, J. Illingworth. Minimum error thresholding. *Pattern Recognition*, 19:41–47, 1986.

- [124] C. V. Jawahar, P. K. Biswas, A. K. Ray. Investigations on fuzzy thresholding based on fuzzy clustering. *Pattern Recognition*, 30:1605–1613, 1997.
- [125] D. E. Lloyd. Automatic target classification using moment invariant of image shapes. *Technical Report, RAE IDN AW126, Farnborough, UK*, 1985.
- [126] M. K. Yanni, E. Horne. A new approach to dynamic thresholding. *EUSIPCO'94: 9th European Conf. Sig. Process*, wolumen 1, strony 34–44, Edinburgh, Szkocja, 1994.
- [127] J. Kapur, P. Sahoo. A new method for gray-level picture thresholding using the entropy of the histogram. *Graphical Models and Image Processing*, 29:273–285, 1985.
- [128] J. Yen, F. Chang, S. Chang. A new criterion for automatic multilevel thresholding. *IEEE Transactions on Image Processing*, 4:370–378, 1995.
- [129] A. Shanbhag. Utilization of information measure as a means of image thresholding. *Graphical Models and Image Processing*, 56:414–419, 1994.
- [130] C. Li, C. Lee. Minimum cross entropy thresholding. *Pattern Recognition*, 26:617–625, 1993.
- [131] H. D. Cheng, Y. H. Chen, Y. Sun. A novel fuzzy entropy approach to image enhancement and thresholding. *Signal Processing*, 75:277–301, 1999.
- [132] N. R. Pal. On minimum cross-entropy thresholding. *Pattern Recognition*, 29:575–580, 1996.
- [133] A. D. Brink, N. E. Pendock. Minimum cross entropy threshold selection. *Pattern Recognition*, 29:179–188, 1996.
- [134] W. Niblack. An introduction to image processing. *Prentice-Hall, Englewood Cliffs, NJ*, strony 115–116, 1986.
- [135] J. Sauvola, M. Pietaksinen. Adaptive document image binarization. *Pattern Recognition*, 33:225–236, 2000.
- [136] J. M. White, G. D. Rohrer. Image thresholding for optical character recognition and other applications requiring character image extraction. *IBM Journal of Research and Development*, 27:400–411, 1983.
- [137] W. Oh, B. Lindquist. Image thresholding by indicator kriging. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 21:590–602, 1999.
- [138] J. Bernsen. Dynamic thresholding of gray level images. *ICPR'86: Proceedings International Conference Pattern Recognition*, wolumen 1, strony 1251–1255, Paryż, 1986.
- [139] Y. Yasuda and M. Dubois, T. S. Huang. Data compression for check processing machines. *Proceedings of IEEE*, 68:874–885, 1980.
- [140] S. D. Yanowitz, A. M. Bruckstein. A new method for image segmentation. *Computer Graphics and Image Processing*, 46:82–95, 1989.

- [141] P. W. Palumbo, P. Swaminathan, S. N. Srihari. Document image binarization: Evaluation of algorithms. *Proceedings of SPIE*, 697:278–286, 1986.
- [142] M. Kamel, A. Zhao. Extraction of binary character/graphics images from grayscale document images. *Graphical Models Image Processing*, 55:203–217, 1993.
- [143] W. Tsai. Moment-preserving thresholding: A new approach. *Computer Vision, Graphics, and Image Processing*, 29:377–393, 1985.
- [144] L. Huang, M. Jang. Image thresholding by minimizing the measure of fuzziness. *Pattern Recognition*, 28:41–51, 1995.
- [145] A. Pikaz, A. Averbuch. Digital image thresholding based on topological stable state. *Pattern Recognition*, 29:829–843, 1996.
- [146] C. K. Leung, F. K. Lam. Maximum a posteriori spatial probability segmentation. *IEEE Proceedings - Vision, Image and Signal Process*, 144:161–167, 1997.
- [147] L. Hertz, R. W. Schafer. Multilevel thresholding using edge matching. *Computer Vision, Graphics and Image Processing*, 44:279–195, 1988.
- [148] A. S. Abutaleb. Automatic thresholding of gray-level pictures using two-dimensional entropy. *Computer Vision, Graphics and Image Processing*, 47:22–32, 1989.
- [149] A. Beghdadi, A. L. Negrate, P. V. De Lesegno. Entropic thresholding using a block source model. *Graphical Models Image Processing*, 57:197–205, 1995.
- [150] H. D. Cheng, Y. H. Chen. Fuzzy partition of two-dimensional histogram and its application to thresholding. *Pattern Recognition*, 32:825–843, 1999.
- [151] M. Fiorese, E. Peserico, A. Silletti. Virtualshave: automated hair removal from digital dermatoscopic image. *Conference Procce IEEE Engineering in Medicine and Biology Society CPIEMBS'11*, wolumen 1, strony 5145–5148, Boston, MA, USA, 2011.
- [152] M. Mendelsohn, J. Prewitt. The analysis fo cell images. *Annals of the New York Academy of Science*, 128:1035–1053, 1966.
- [153] G. Zack, W. Rogers, S. Latt. Automatic measurement of sister chromatid exchange frequency. *Journal of Histochemistry and Cytochemistry*, 25:741–753, 1977.
- [154] W. Doyle. Operation useful for similarity-invariant pattern recognition. *Journal of ACM*, 9:259–267, 1962.
- [155] Y. Chen, C. Lin. Combining svms with various feature selection strategies. *Studies in Fuzziness and Soft Computing*, 207:315–324, 2006.
- [156] K. M. Clawson, P. J. Morrow, B. W. Scotney, i in. Computerised skin lesion surface analysis for pigment asymmetry quantification. *International Machine Vision and Image Processing Conference*, wolumen 1, strony 75–82, Maynooth, Irlandia, 2007.
- [157] K. Clawson, P. Morrow, B. Scotney, i in. Analysis of pigmented skin lesion border irregularity using the harmonic wavelet transform. *13th International Machine Vision and Image Processing Conference*, wolumen 1, strony 18–23, Dublin, 2009.

- [158] P. Rubergni, G. Cevenini, M. Burroni, i in. Automated diagnosis of pigmented skin lesions, international journal of cancer. *Sensor Networks and Information*, 101:576–580, 2002.
- [159] P. Vannoorenbergge, O. Colot, D. De Brucq. Dempster-shafer’s theory as an aid to color information processing application to melanoma detection in dermatology. *Proceedings 10th International Conference on Image Analysis and Processing*, wolumen 1, strony 774–779, Waszyngton, USA, 1999.
- [160] R. Garnavi, M. Aldeen, J. Bailey. Classification of melanoma lesions using wavelet-based texture analysis. *Digital Image Computing: Techniques and Applications*, 1:75–81, 2010.
- [161] K. Ramlakhan, Y. Shang. A mobile automated skin lesion classification system. *23rd IEEE International Conference on Tools with Artificial Intelligence*, wolumen 1, strony 138–141, Boca Raton, FL, USA, 2011.
- [162] U. Wollina, M. Burroni, R. Torricelli, i in. Digital dermoscopy in clinical practice: a three-centre analysis. *Skin Research and Technology Journal*, 13:133–142, 2007.