

Rozdział 3

Zagadnienia segmentacji tęczówki na potrzeby systemów biometrycznych

Mirosław Omieljanowicz

Streszczenie: Celem opracowania jest przedstawienie zagadnień związanych z wykorzystaniem obrazu tęczówki oka ludzkiego w biometrii. W przedstawianej pracy opisano, z jakich komponentów składa się system biometryczny oraz jakim przekształceniom podlega obraz tęczówki, aby mógł być wykorzystany do celów identyfikacji czy też autoryzacji ludzi.

Największą uwagę poświęcono procesowi segmentacji tęczówki. W sposób syntetyczny omówiono problemy związane z segmentacją obrazu. Przedstawiono także kilka najczęściej używanych algorytmów segmentacji. Jeden z nich został zaimplementowany w wersji podstawowej (powszechnie stosowanej), a w dalszej części opracowania wskazano i opisano kilka zmodyfikowanych zastosowań wybranego algorytmu. Przygotowane algorytmy zostały następnie poddane ewaluacji pod kątem poprawności segmentacji tęczówki oka.

W opracowaniu opisano metodę testowania oceny efektów działania różnych wersji procesu segmentacji. W dalszej kolejności pokazano badania przeprowadzone zgodnie z wybranymi metodami ewaluacji. Na zakończenie publikacji zaprezentowano uzyskane wyniki, dokonano ich krytycznej oceny i wyciągnięto wnioski dotyczące dalszych kierunków prac.

Słowa kluczowe: Biometria, Tęczówka, Segmentacja

Wprowadzenie

Biometria jest technologią pomiaru i analizy biologicznych cech człowieka, przede wszystkim w celu rozróżniania ludzi. Identyfikacja lub weryfikacja osób jest wykonywana przez pomiar powtarzalnych fizycznych lub behawioralnych cech charakterystycznych. W przeciągu wielu lat prac badawczych zaproponowano wiele technik opartych o różnorodne cechy ludzkie, m. in odcisk palca, geometrię dłoni, wygląd twarzy, kształt ucha, siatkówkę oka, głos, podpis odręczny, zapach ciała, tęczówkę, sposób chodzenia, układ żył na dłoni. Kluczowym elementem definiującym znaczenie danej cechy w rozpoznawaniu człowieka są jej wysoka unikalność, uniwersalność, trwałość

i mierzalność. Do takich cech ewidentnie zalicza się tęczę oka, jednakże niezbyt prosty i łatwy sposób pozyskiwania jej obrazu oraz stosunkowo skomplikowany obliczeniowo proces analizy spowodował, że dopiero w obecnym okresie pojawiają się komercyjne rozwiązania dostępne dla przeciętnego użytkownika [1].

Tęczę oka jest jedną z głównych biometryk stosowanych w zaawansowanych systemach dostępu do budynków i biur oraz będących tematem licznych publikacji naukowych i popularnonaukowych. Główną jej przewagą nad innymi podejściami jest olbrzymi poziom różnorodności wzorów jej wyglądu. Według źródeł literaturowych prawdopodobieństwo, że w procesie porównywania dwóch obrazów od dwóch różnych osób da błędny wynik wynosi jak 1 do 10^{12} [2,3]. Oznacza to, że wystąpienie fałszywej akceptacji jest w praktyce niemożliwe. Poza tym, tęczę należy do najbardziej trwałych cech biometrycznych człowieka, gdyż nie ulega zmianie przez całe życie. Dodatkowo, przy bezpośredniej akwizycji tęczy w czasie rzeczywistym, oszustwo z wykorzystaniem podstawionego wzoru (np. zdjęcia) jest praktycznie niemożliwe. Wymienione wyżej podstawowe cechy charakterystyczne tęczy oka powodują, że w zastosowaniach biometrycznych jest ona bardzo atrakcyjnym elementem.

Wykorzystanie tęczy jako cechy biometrycznej determinuje wiele problemów, których rozwiązanie decyduje o jego skuteczności. O ile ekstrakcja cech (utworzenie wektora cech) z dobrze wydzielonego i znormalizowanego obrazu tęczy nie stanowi istotnego problemu, o tyle w dziedzinie opracowania efektywnej metody wyznaczenia obszaru, na którym znajduje się tęczę, stale trwają prace badawcze i rozwojowe. Jest to jeden z pierwszych i jednocześnie kluczowy etap analizy tęczy oka, zwany segmentacją. Precyzja tego procesu decyduje o poprawności działania całego systemu. Niepoprawne działanie algorytmu segmentacji może prowadzić do powstawania różniących się reprezentacji wzoru tej samej tęczy. Bezpośrednio wpływa to na współczynnik fałszywego odrzucenia i w rezultacie na ocenę efektywności całego systemu [3].

W dalszej części publikacji największą uwagę poświęcono metodom i algorytmom segmentacji tęczy oka na obrazach w bliskiej podczerwieni z powodów wskazanych w pkt. 3.1.3 oraz pkt. 3.2.3. Eksperymentalnie pokazano w jakim stopniu zastosowane metody oraz algorytmy wpływają na skuteczność selekcji tęczy mierzoną za pomocą opracowanej obiektywnej metody testowania i oceny efektów. Do przeprowadzenia badań wykorzystane zostały publicznie dostępne zasoby zawierające zdjęcia oczu, wykonane przy użyciu kamer operujących w bliskiej podczerwieni [4].

3.1. Zagadnienia segmentacji tęczy oka


Segmentacja obrazu tęczy oka należy do ogólnej dziedziny, jakim jest segmentacja obrazu, będącym typowym zagadnieniem z zakresu tzw. widzenia komputerowego. Polega to na wydzieleniu obszarów, które są jednorodne pod względem pewnych

własności, np. linii poziomych, pionowych, krawędzi obszarów o różnych czy też o tym samym kolorze, podobnym wzorze lub poziomie jaskrawości. W efekcie uzyskuje się uproszczenie lub zmianę prezentacji obrazu do formy, którą daje poszukiwany efekt końcowy lub jest przygotowana do dalszej analizy. Segmentacja obrazu jest głównie używana do ustalenia granic obszarów, na których znajdują się wybrane struktury czy obiekty. Inaczej ujmując, proces segmentacji polega na przypisaniu poszczególnych pikseli obrazu do pewnej klasy na podstawie wspólnych cech. Przykładowymi wynikami segmentacji mogą być zbiór konturów (pikseli na granicy dwóch obiektów), maska binarna (obraz z dwoma, zwykle skrajnymi poziomami wartości pikseli). Posegmentowany obraz często znajduje bezpośrednie wykorzystanie praktyczne w takich zastosowaniach, jak: widzenie maszynowe w automatyce, obrazowanie do celów medycznych, nadzór wizyjny, kontroli ruchu drogowego i oczywiście w biometrycznych systemach identyfikacji i autoryzacji ludzi.

Obecnie dostępnych jest bardzo wiele metod segmentacji, często bezpośrednio dostosowanych do ściśle ustalonego celu. Występują także metody uniwersalne. Część z nich wymaga współpracy z człowiekiem, część może działać w sposób nienadzorowany – automatyczny. Generalnie, metody segmentacji można podzielić na obszarowe i krawędziowe. Pierwszy z wymienionych typów opiera się na ustaleniu podobieństw wewnątrz określonego obszaru. W wyniku otrzymywane są zbiory pikseli podzielone na klasy według określonego kryterium. Drugi typ to metody krawędziowe służące ustaleniu granic oddzielających różniące się obszary wydzielając fragmenty składające się z punktów granicznych. Algorytmy stosowane w poszczególnych typach segmentacji są rozwiązaniami specjalizowanymi, tzn. algorytmy ustalające obszary nie pozwolą na wykrycie krawędzi i vice versa algorytmy krawędziowe nie sprawdzą się w identyfikacji obszarów. Przykładami powszechnie stosowanych metod segmentacji są progowanie, rozrost obszaru, różnego typu transformacje [5].

3.1.1. Specyfika obrazu tęczówki oka

Przedstawiana publikacja dotyczy analizy obrazu tęczówki oka. Oznacza to, że powinny być zastosowane specjalistyczne, dopasowane do specyfiki wyglądu oka rozwiązania. Tęczówka to część oka ludzkiego i nigdy nie jest widoczna samodzielnie, lecz jako pewien obszar na ujęciu oka. Tęczówkę z punktu widzenia anatomii tworzy kilka składników. Pierwszym z nich od wewnątrz organizmu człowieka, stanowi silnie ubarwiony nabłonek, nieprzenikliwy dla światła. Kolejnym elementem są mięśnie kontrolujące rozmiar źrenicy. Następny jest, silnie unaczyniony, tzw. zrąb tęczówki, który składa się w włókien kolagenowych. Najbardziej zewnętrzną warstwę stanowi nabłonek przedni. W nim położone są liczne komórki pigmentowe mające wpływ na kolor tęczówki. Jej wygląd obserwowany na zdjęciach jest efektem odbicia światła w jej wielowarstwowej strukturze [8]. Wygląd zewnętrzny ze wskazaniem charakterystycznych elementów przedstawiono na rys 3.1.




RYSUNEK 3.1. Obraz obu oczu z zaznaczonymi charakterystycznymi miejscami

Pokazane na rys. 3.1 zdjęcie oka zostało zrobione z bliska przy użyciu kamery w bliskiej podczerwieni (wyjaśnienie stosowania fal bliskiej podczerwieni, patrz pkt 3.1.3 i pkt 3.2.3). Widoczna na zdjęciu tęczówka ma kształt pierścienia ograniczonego od wewnątrz przez krawędź źrenicy i od zewnątrz przez granicę z twardówką. Wewnątrz obszar można podzielić na dwie strefy. Pierwsza z nich od krawędzi źrenicy to strefa okołożreniczna, zaś druga, otaczająca, to strefa włoskowata. Pomiędzy nimi znajduje się okrągłe zgrubienie nazywane kołnierzem. Wokół kołnierza widoczne są liczne zagłębienia i bruzdy. W pobliżu krawędzi tęczówki występują koncentryczne linie. Są to tzw. zmarszczki, które pogłębiają się przy rozszerzaniu się źrenicy. Opisanie struktury tworzą, charakterystyczną dla tęczówki, teksturę i to ona jest elementem analizowanych w ramach systemów biometrycznych [6].

Obserwacje i analizy medyczne potwierdzają, że wygląd tęczówki jest unikalny dla każdego człowieka i od wieku dwóch lat nie zmienia się przez cały okres życia. Różnice występują nawet pomiędzy lewym i prawym okiem tej samej osoby, a także u bliźniąt jednojajowych. Według nauk medycznych wygląd zewnętrzny (tekstura na zdjęciu rys. 3.1) zależy do warunków, w jakich następował rozwój w fazie płodowej człowieka, a te są praktycznie niepowtarzalne u każdej osoby. Z tego powodu, mimo iż struktura tęczówki jest uwarunkowana genetycznie, to jest wręcz nieprawdopodobne, aby dwoje ludzi miało taki sam obraz/wzór tęczówki oka [8], a jest to najważniejsza cecha z punktu widzenia rozróżniania osób. Dodatkowo szerokość widocznego obrazu tęczówki zależy od rozmiaru średnicy źrenicy, której rozmiar zmienia się praktycznie w sposób ciągły. Obserwacja tych zmian może być użyta do weryfikacji czy analizowany jest obraz „na żywo.” Zabezpiecza to przed podstawieniem sztucznego obrazu oka co oznacza wysokie bezpieczeństwo w relacji do prób oszukiwania [10] systemów autoryzacyjnych.

3.1.2. Ogólna struktura systemu rozpoznawania tęczówki

Każdy system biometryczny, w tym oparty o analizę obrazu tęczówki dokonuje porównania wektora cech bieżąco dostarczonej próbki z wektorami cech zgromadzonymi w bazie i ustala poziom podobieństwa wektora wejściowego ze wszystkimi w bazie poszukując najlepszego dopasowania a następnie decydując o zgodności próbki z wzorcem. Typowy blokowy schemat systemu rozpoznawania tęczówki wraz ze wskazaniem kierunku przepływu informacji został przedstawiony na rys. 2.2.



RYСУNEK 3.2. Schemat blokowy typowego systemu rozpoznawania tęczówki

Wyróżnione są cztery główne moduły realizujące następujące zadania (etapy przetwarzania): pozyskanie (akwizycja) obrazu, segmentacja tęczówki, normalizacja do postaci obrazu prostokątnego, ekstrakcja cech (wyznaczenie wektora cech) i porównanie z zapisami w bazie danych. Jakość wyników każdego z etapów jest bardzo uzależniona od efektów/poprawności działania poprzedniego.

Zadanie akwizycji obrazu polega na pozyskaniu dwuwymiarowego obrazu tęczówki. Obecnie zwykle wykorzystywane są do tego celu kamery CCD. W wielu sytuacjach stosowane jest dodatkowe oświetlenie źródłem podczerwonym w celu

uzyskanie poprawnego, odpowiednio jasnego zdjęcia. Proces akwizycji jest stosunkowo trudny w realizacji i wymaga aktywnego działania osoby poddającej się identyfikacji czy autoryzacji za pomocą obrazu tęczówki oka. W większości przypadków chodzi o odpowiednie otwarcie powiek i centralne ustawienie w okularze. Tak uzyskany obraz jest czasami wstępnie przetwarzany a potem przekazywany do modułu wykonania segmentacji, czyli „wycięcia” ze zdjęcia fragmentu zawierającego wyłącznie tęczówkę.

Blok segmentacji jest najistotniejszym elementem procesu analizy. Jego zadanie to lokalizacja obszaru zajmowanego przez tęczówkę i jego izolacja od pozostałych składników. Są to przede wszystkim źrenica, powieki, rzęsy, twardówka i różnego typu artefakty. Typowo segmentacja wykonywana jest w oparciu o wykrycie wewnętrznego i zewnętrznego konturu tęczówki i ewentualnie niepożądanych fragmentów powiek i rzęs, przysłaniających jej obszar. Ten proces jest krytycznym elementem systemu rozpoznawania tęczówki, a jego niedoskonałości drastycznie zmniejszają jakość (skuteczność) całego systemu biometrycznego.


Blok normalizacji przeprowadza geometryczne przekształcenie wysegmentowanego obszaru tęczówki mającego kształt pierścieniowaty do postaci prostokąta, ponieważ wykonanie obliczenia wektora cech na kształcie nieregularnego pierścienia jest bardzo skomplikowane. Znacznie prościej można to wykonać przy użyciu obrazu w typowej formie prostokąta. Operacja przekształcenia kształtu obrazu zwykle jest realizowana poprzez przeniesienie układu współrzędnych polarnych na układ kartezjański. Proces taki nazywany jest czasami „odwijaniem tęczówki” a jego rezultatem jest prostokątny pas, gdzie pionowa współrzędna odpowiada współrzędnej promieniowej, zaś pozioma współrzędnej kątowej. W tej operacji wytwarzany obraz jest sprowadzany do znormalizowanego kształtu o stałej ilości pikseli w pionie i poziomie. Takie podejście pozwala na uniezależnienie się od rozmiarów tęczówki wyodrębnionej w procesie segmentacji. Wymiary wydzielonej tęczówki różnią się bowiem u różnych osób, zmieniają się także w zależności od kąta ujęcia. Dodatkowo zwykle oprócz pożądaných składników wyodrębnionego obrazu zawiera on szereg zakłóceń, np. fragmenty rzęs czy powiek. Ich wyeliminowanie na pierwotnym kształcie (pierścieniowaty) jest trudne. Przejście na format znormalizowany pozwala na zastosowanie wielu ogólnie znanych metod poprawy obrazu. W procesie mapowania pierwotnego kształtu na znormalizowany przenoszone są także wszystkie artefakty i zakłócenia. Na prostokątnym obrazie można je eliminować przy użyciu ogólnie znanych metod i algorytmów, np. poprzez zastosowanie masek, filtrów. Oprócz tego, możliwe jest zastosowanie innych filtrów uwydatniających elementy tęczówki.

Kolejny blok to procedury wyznaczania wektora cech. Możliwe jest zastosowanie różnych podejść, które również wpływają na końcowy rezultat w postaci skuteczności systemu biometrycznego. Większość algorytmów wykorzystuje filtry fal-kowe, które z obrazu wyznaczają informacje o fazie [2,3,10]. W wyniku kwantyzacji fazy powstają wektory cech, które mogą być porównywane algorytmami wyznaczającymi odległości


3.1.3. Zagadnienia segmentacji tęczówki

Ze względu na specyfikę fizycznej budowy tęczówki w rozwiązaniach biometrycznych najczęściej wykorzystuje się obrazy powstałe w ujęciach z zastosowaniem oświetlenia w bliskiej podczerwieni [9]. Cechy fizyczne tęczówki oka powodują, że szczegóły są słabo widoczne w widmie światła widzialnego. Wykorzystanie fal o większej długości, tuż poza zakresem widzialności znacząco lepiej uwypatnia strukturę tęczówki, dając tym więcej informacji potrzebnych wydzielenia odpowiedniego obszaru i budowy unikalnego wektora cech. Przyczyną takiego efektu jest pochłanianie przez melaninę części widma światła widzialnego. Zostało to pokazane na rys. 3.3. Obrazy z pierwszej od lewej kolumny to widok w bliskiej podczerwieni, pozostałe to składowe podstawowe światła widzialnego.


brązowa tęczówka



zielona tęczówka




niebieska tęczówka



RYSUNEK 3.3. Tęczówka oka w bliskiej podczerwieni i świetle widzialnym [7]

Wykorzystanie fal w bliskiej podczerwieni ma jeszcze jedną ważną zaletę. Jest ono niewidoczne dla człowieka i nieszkodliwe w zakresie mocy, która pozwala na uzyskiwanie jasnych, wyraźnych obrazów.

Jednakże, mimo zastosowania oświetlenia dającego wysokiej jakości obrazy, segmentacja tęczówki należy do trudnych, złożonych zagadnień. Wynika, to z faktu obecności na zdjęciach nieusuwalnych w procesie jego tworzenia naturalnych elementów budowy oka, jak już wcześniej wymieniane źrenicę, twardówkę oka oraz powieki i rzęsy. Różnorodność uzyskiwanego obrazu jest na tyle duża, że do jej segmentacji należy użyć wielu metod analizy obrazu, w większości krawędziowych (obszarowe nie sprawdzają się na tak zróżnicowanych obrazach).



RYSUNEK 3.4 Krawędzie na obrazie tęczówki uzyskane z użyciem operatora Sobel'a w osi x i y

Główne problemy, które pojawiają się w procesie segmentacji tęczówki to jej kształt, który odbiega istotnie od powszechnie znanych figur geometrycznych. Wewnętrzna krawędź występuje na granicy ze źrenicą. I to jest najprostszy do wykrycia element, gdyż źrenica jest zasadniczo okrągła i przy dobrej jakości zdjęcia wyraźnie ciemniejsza od pozostałych części oka. Zdecydowanie trudnym zagadnieniem jest ustalenie zewnętrznej krawędzi, gdyż mimo iż pełny obraz oka pokazuje również postać okręgu to wyjątkowo rzadko jest on widoczny w praktyce. Najczęściej jest on przysłonięta powieką/powiekami czy też rzęsami. Powoduje to, że algorytmy służące wykrywaniu krawędzi okręgów dają bardzo niezadowalające rezultaty. Pojawiają się fałszywe nieregularne krawędzie prowadzące do sztucznego obniżenia lub powiększenia obszaru uznanego jako tęczówka. Dodatkowo cały proces utrudniają typowe problemy występujące w analizie obrazów, takie jak: nierównomierne oświetlenie, refleksy świetlne, zbyt niski czy zbyt wysoki kontrast, zbyt jasny lub zbyt ciemny obraz całości. W związku z powyższym w analizie służącej segmentacji tęczówki wykorzystuje się w praktyce wiele algorytmów nakierowanych na wykrywanie krawędzi. Jednakże, doprowadzenie do wybrania odpowiedniego fragmentu wymaga wielu przekształceń, gdyż użycie jednego algorytmu nie daje oczekiwanych rezultatów. Poniżej przedstawiono obraz uzyskany przy wykorzystaniu filtru Sobela, pokazujący wiele nieużytecznych, wręcz przeszkadzających w segmentacji tęczówki krawędzi (rys. 3.4).

3.1.4. Podstawowe metody stosowane w segmentacji tęczówki

Lista dostępnych publikacji dotyczących metod segmentacji tęczówki jest bardzo obszerna. Zdecydowana większość z nich dotyczy metod krawędziowych [15], część zaś korzysta z rozwiązań opartych o metody aktywnych konturów, gdyż pozwalają uwzględnić nieregularną geometrię widocznego na zdjęciach obszaru tęczówki. Wśród najczęściej wykorzystywanych możemy znaleźć: klasyczny już operator całkująco-różniczkujący Daugman'a [2,3,10] oraz równie klasyczna transformacja Hough'a [11] oraz rzadziej spotykane aktywne kontury geodezyjne [12].

Operator całkująco-różniczkujący jest podstawową metodą stosowaną w rozwiązaniach komercyjnych o wysokiej skuteczności i jedną z najpopularniejszych metod segmentacji tęczówki wymienianych w publikacjach. Został on opracowany i opublikowany przez John'a Daugman'a w 1993 roku. Ze swej natury pracuje on jako detektor okrągłych krawędzi i używany jest do ustalania wewnętrznego i zewnętrznego konturu tęczówki na obrazie. W dalszej części procesu wykonywana jest zmiana poszukiwanej krzywej z okręgu na łuk (linie paraboliczne), co pozwala ograniczyć wpływ potencjalnego przesłonięcia przez fragmenty powieki. Operator Daugman'a umożliwia poszukiwanie i wykrycie krawędzi powiek, które może być prowadzone z wykorzystaniem różnych krzywych. Ustalenie położenia powiek daje istotne korzyści poprawiając precyzję wykrycia obszaru tęczówki. Szczegóły tego rozwiązania nie zostały opublikowane i nadal pozostaje duże pole do kolejnych prac.

Drugim często stosowanym w literaturze podejściem jest wykorzystanie transformacji Hough'a należącej do klasyki algorytmów analizy obrazów i służącej do znajdowania w obrazie geometrycznych kształtów takich jak proste czy okręgi. Korzystając z bazowej wersji transformaty opracowano wiele jej modyfikacji w zastosowaniach do segmentacji tęczówki [13]. Przed jej użyciem koniecznym jest przeprowadzenie procesu wykrywania krawędzi przeprowadzonego w wielu kierunkach. Na tak uzyskanym obrazie (mapa możliwie wszystkich krawędzi) użyta zostaje transformata Hough'a dająca w efekcie wskazanie okręgów otaczających tęczówkę. Możliwe jest także wykorzystanie tej transformacji Hough'a w celu wykrycia powiek. Ciekawe rozwiązanie pokazano w pracy [14], gdzie wykorzystano dwa oddzielne obrazy, krawędzi poziomych do ustalenia położenia powiek, krawędzi pionowych do ustalenia zewnętrznej granicy tęczówki, jednocześnie obniżając czas przetwarzania (oddzielne obrazy z mniejszą ilością obiektów są przekształcane szybciej niż jeden z dużą ilością szczegółów) i poprawiając precyzję segmentacji. Użycie transformacji Hough'a do wydzielenia tęczówki charakteryzuje się dwoma istotnymi i trudnymi do uniknięcia komplikacjami. Chodzi o dobór progu algorytmów wykrywania krawędzi oraz progu oceny ilości punktów w przestrzeni Hough'a. Mają one kluczowy wpływ na jakość segmentacji i praktycznie niemożliwe jest ustalenie ich w sposób automatyczny. Dodatkowo transformacja Hough'a wymaga znaczących mocy obliczeniowych, co na pewno ogranicza jej zastosowanie w systemach pracujących w czasie rzeczywistym.

Aktualnie w dziedzinie segmentacji tęczówki oka bardzo obiecującym rozwiązaniem jest zastosowanie metody aktywnych konturów [12]. Opisane wyżej klasyczne podejścia zakładają, że krawędzie tęczówki mają kształt okręgu, co jest zgodne z anatomicznym obrazem. Jednakże, jak wskazano wyżej na zdjęciach ludzkiego oka (praktycznie w każdym przypadku) jest obserwowane przysłonięcie przez powieki ew. rzęsy. Implikuje to, że przy segmentacji konieczne jest wykrywanie krzywych niebędących częścią okręgu. W standardowym podejściu wymagane jest wtedy przeprowadzenie wielokrotnego wykrywania krawędzi w różnych kierunkach. W tym kontekście interesującą alternatywą są metody aktywnych konturów, które pozwalają na śledzenie i ustalanie nieregularnych krawędzi. Do segmentacji tęczówki zwykle jest stosowana ich odmiana geodezyjne aktywne kontury [12]. Proces ustalenia interesującego obszaru jest podzielony na dwa następujące po sobie generalne etapy – wydzielenie źrenicy i wydzielenie tęczówki. Segmentacja tęczówki jest uwarunkowana ustaleniem jej wewnętrznej krawędzi, co wskazuje, że w pierwszym etapie musi zostać wydzielona źrenica. Zastosowanie aktywnych konturów wymaga zainicjowania procesu segmentacji tęczówki okręgiem leżącym wewnątrz jej, dlatego w pierwszej kolejności wykonywana jest segmentacja źrenicy. Zostało to wykonywane stosunkowo prostym postępowaniem polegającym, w uproszczeniu, na ustaleniu minimalnej wartości piksela w obrazie (źrenica jest zwykle najciemniejszym elementem) i dokonanie binaryzacji obrazu z progiem wyższym o 25 od minimalnej wartości piksela. W efekcie otrzymuje się obraz zbinaryzowany zawierający tło i kształty odpowiadające źrenicy i innych elementów takich jak, np. rzęsy. Najmniejsze z elementów są usuwane filtrem medianowym a spośród pozostałych ustala się obszary możliwe do zakwalifikowania jako okręgi i wybiera największy jako obszar źrenicy. W następnym etapie wykorzystuje się algorytm aktywnych konturów geodezyjnych.

Metoda aktywnych konturów geodezyjnych bazuje na relacji pomiędzy aktywnymi konturami i obliczaniem linii geodezyjnych. Wyściowym aktywnym konturem jest wyznaczona wcześniej linia wewnętrznej krawędzi tęczówki. Droga ewolucji tej krzywej osiągana jest dość dokładna (względem wcześniej opisanych metod) segmentacja tęczówki. Jednakże, mimo dużej dokładności zastosowanie tej metody w praktyce wiąże się z kilkoma istotnymi problemami. Analogicznie do rozwiązań stosujących transformatę Hough'a bardzo ważny jest dobór parametrów (źle dobrane parametry skutkują słabej jakości segmentacją) i znacząca złożoność obliczeniowa na pewno ograniczająca jej wykorzystanie w praktyce.

Przedstawiona w pkt. 2 skondensowana analiza metod segmentacji tęczówki wskazała, że mimo upływu czasu najbardziej klasyczne rozwiązanie jakim jest zastosowanie operatora całkująco-różniczkującego Daugman'a ma przeważającą ilość zalet w stosunku do jej wad przede wszystkim, jeżeli ma się na celu praktyczne zastosowania. Decydują o tym takie cechy jak złożoność obliczeniowa pozwalająca na wykorzystanie jej w samodzielnie pracujących systemach wbudowanych i duże możliwości modyfikacji dające szansę na własne opracowania. W związku z powyższym

w dalszej części opisywanych w tej publikacji prac wykonano wdrożenie operatora całkująco-różniczkującego dokonując kilku zmian i uzupełniając szeregiem dodatkowych metod a także oceniono w sposób uporządkowany ich wyniki.

3.2. Badanie wariantów rozwiązań bazujących na algorytmie Daugman'a

3.2.1. Wykorzystane oprogramowanie

Zgodnie z rozważaniami przedstawionymi w poprzedniej części niniejszego opracowania do przeprowadzenia analizy różnych wariantów metod segmentacji tęczówki wybrano realizację opartą o algorytm Daugman'a. Jego idea i dostępne opisy pozwalają na wprowadzenie szeregu rozwiązań umożliwiających elastyczne zmiany „wokół” tego algorytmu oraz przeprowadzenie oceny ich wpływu na wysegmentowany obraz. Znajduje to potwierdzenie w ilości publikacji na jego temat, a także szeregu komercyjnych implementacji. W celu przeprowadzenia badań i eksperymentów wykorzystano oprogramowanie przygotowane w ramach pracy magisterskiej [18] na Wydziale Informatyki Politechniki Białostockiej. Zostało ona zaimplementowane w języku C++ z zachowaniem dużej modularności i konfigurowalności, co umożliwia użycie wielu wariantów rozwiązań i dość prostą modyfikację parametrów przetwarzania. Konstrukcja aplikacji przygotowana została z podziałem całego procesu na 5 podstawowych etapów, przy czym w każdym z nich umożliwiono łatwe wprowadzanie modyfikacji wybranych elementów. Etap 1 to przetwarzanie wstępne. W jego ramach możliwe jest zastosowanie algorytmów usuwania zakłóceń i poprawy kontrastu. Najważniejsze z nich to usuwanie zakłóceń poprzez zastosowanie jednego z filtrów (filtr Gaussa parametrze σ , filtr medianowy, filtr bilateralny), poprawa kontrastu (wyrównywanie histogramu lub adaptacyjne wyrównywanie histogramu z limitem kontrastu algorytmem CLAHE) czy też usuwanie refleksów świetlnych (metoda interpolacji obrazu tzw. *inpainting*). Drugi etap to wykrywanie krawędzi źrenicy (wewnętrznej krawędzi tęczówki). Zastosowany został tu operator całkująco-różniczkujący przystosowany do pracy na obrazach wykonanych w bliskiej podczerwieni. Możliwe jest też ustawianie poziomu głównego parametru jakim jest zakres promienia r wewnętrznego okręgu oraz postęp jego zmian (jest to jednocześnie krok operacji różniczkowania). Etap trzeci to wykrywanie zewnętrznej krawędzi tęczówki, również z wykorzystaniem operatora całkująco-różniczkującego, ale nie dla okręgów, lecz dla dwóch łuków lewej i prawej strony. Etap czwarty to wykrywanie górnej i dolnej powieki. Tu ponownie zastosowano operator całkująco-różniczkujący dostosowany do wykrywania łuku. Etap piąty to wykrycie rzęs i innych artefaktów oraz minimalizacja ich (usunięcie) wpływu na wynik segmentacji. na powierzchni tęczówki poprzez zastosowanie własnego algorytmu z podwójnym progowaniem.

3.2.2. Metoda oceny jakości segmentacji tęczęwki

Segmentacja tęczęwki jest krytycznym składnikiem biometrycznego systemu rozpoznawania czy też autentykacji ludzi. Mimo to skuteczność wykonania tego procesu nie da się łatwo ocenić poprzez badanie efektów działania całego systemu. Przyczyna jest oczywista – wynik końcowy zależy także od jakości działania jego pozostałych modułów składowych. Skupienie uwagi na efektach segmentacji i wykonanie ich oceny wymaga zastosowania specyficznego podejścia. Najbardziej oczywistym rozwiązaniem jest wizualna ewaluacja wykonana przez ludzi, ekspertów dziedzinowych. Takie podejście ma jednak istotne wady. Przede wszystkim jest oceną subiektywną. Poza tym, sprawdzi się przy ewaluacji stosunkowo niewielkiej liczby obrazów. W sytuacji dużej ilości wyników staje się czasochłonna i z upływem czasu rośnie ryzyko popełnienia ludzkiego błędu. Te fakty oznaczają, że konieczne jest zastosowanie metody oceny wyrażonej w wartościach liczbowych możliwych do ustalenia metodami obliczeniowymi zaimplementowanymi w postaci programów komputerowych, które gwarantują obiektywizm ewaluacji.

Generalnie obiektywne metody ewaluacji segmentacji obrazów bazują na wyznaczeniu różnicy wyników w stosunku do przygotowanych wzorców. W przypadku segmentacji obrazów polega to na zastosowaniu obrazu porównawczego przygotowanego jednorazowo ręcznie przez eksperta. Po przeprowadzeniu przetwarzania obliczana jest miara pokrycia otrzymanego wyniku z obrazem porównawczym. Porównanie jest wykonywane na podstawie obliczonych wartości miar, takich jak odległość lub poziom podobieństwa. Są one powszechnie stosowane ze względu na szybkość, powtarzalność i łatwość wyznaczenia.

Algorytmy segmentacji tęczęwki zasadniczo dokonują podziału pikseli obrazu na dwie klasy – należących do tęczęwki i stanowiących tło. Pozwala to na traktowanie tych algorytmów jako klasyfikatorów binarnych [17] i na zastosowanie sposobów ewaluacji stworzonych dla tego typu rozwiązań. Stanowi to znaczne ułatwienie, gdyż dostępnych jest wiele sprawdzonych miar stworzonych do oceny klasyfikacji binarnej. W takiej sytuacji typowo definiuje się zbiór pozytywny pikseli należący do obiektu (tu do obszaru tęczęwki) oraz zbiór negatywny pikseli nienależących do obiektu (tu poza obszarem tęczęwki). Poprzez porównanie przynależności pikseli w obrazie wynikowym z przynależnością w obrazie porównawczym możemy wyliczyć cztery charakterystyczne wielkości [16]. Są to wielkości:

- TP – (ang. *true positive*) – liczba pikseli prawidłowo określonych jako należące do obszaru tęczęwki
- TN – (ang. *true negative*) – liczba pikseli prawidłowo określonych jako nienależące do obszaru tęczęwki
- FP – (ang. *false positive*) – liczba pikseli błędnie określonych jako należące do tęczęwki – tzw. błąd pierwszego rodzaju
- FN – (ang. *false negative*) – liczba pikseli błędnie określonych jako nienależące do obszaru tęczęwki – tzw. błąd drugiego rodzaju

Na podstawie w/w czterech wielkości wyznacza się typowe miary stosowane w ocenie jakości przetwarzania obrazów. Są nimi precyzja (P), czułość (R od ang. recall) i miara F1 [16].

Precyzja jest wyznaczana wg. formuły (1) i wskazuje jaka część pikseli uznana jako należąca do tęczy, została prawidłowo wybrana. Czułość obliczana wg. wzoru (2) wskazuje, jaka część wszystkich pikseli należących do tęczy, została prawidłowo wyznaczona.

$$P = \frac{TP}{TP + FP} \quad (1)$$

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

W/w wielkości dają ocenę wyniku w postaci dwóch wielkości, ale czasami komplikują przeprowadzenie jednoznacznego porównania (np. nie jest jasne, który z aspektów jest istotniejszy w danym zastosowaniu). Bezpośrednie porównanie jest możliwe przy użyciu pojedynczych wielkości. Taką możliwość stwarza trzecia z wymienionych powyżej wielkości. Jest to miara oznaczana jako F1, którą wyznacza się na podstawie formuły (3). Wielkość F1 nazywana jest czasami współczynnikiem Sørensen-Dice'a i stanowi syntetyczną ocenę, będąc średnią harmoniczną precyzji i czułości a jej maksymalna wartość odpowiadająca idealnej segmentacji wynosi 1.

$$F1 = \frac{2PR}{P + R} = \frac{2TP}{2TP + FP + FN} \quad (3)$$

Miary opisane powyżej dotyczą oceny pojedynczego obrazu wynikowego. W praktyce oczekujemy, że opracowane algorytmy będą stosowane do przetworzenia dużej ilości obrazów co oznacza, że przytoczone wskaźniki odnoszące się do pojedynczego obrazu nie są odpowiednio miarodajne. Do całościowej oceny algorytmów konieczne jest wykonanie ewaluacji dla zestawu obrazów pokrywającego dużą ilość przypadków spotykanych w praktyce. W takiej sytuacji należy zastosować podejście statystyczne. Wówczas możliwe jest porównywanie i ocena jakości dla dużych zbiorów danych. Typowymi wskaźnikami oceny statystycznej są wartość oczekiwana (zwykle oznaczana symbolem μ) oraz odchylenie standardowe (zwykle oznaczana symbolem σ). W przypadku ewaluacji jakości działania, rozważanej w tej publikacji segmentacji tęczy ważną informacją jest określenie ilości przypadków, które w znaczący sposób różnią się do wartości oczekiwanej. Zwykle mają one niewielki wpływ na wartość oczekiwaną, jednak mogą wskazać pojedyncze/kilkukrotne przypadki, gdy metoda wyraźnie zawodzi, co daje możliwość „wyłapania” takich sytuacji i przeprowadzenia ew. udoskonaleń algorytmów. W statystyce są one określane jako obserwacje odstające a ich pomiar zwykle polega na wskazaniu ilości takich sytuacji. Typowo należą do nich przypadki, w których obliczona miara różni się od wartości oczekiwanej o więcej niż 3 odchylenia standardowe. W dalszej części publikacji liczba obserwacji odstających będzie oznaczana przez o . Przyjęto także, że jakość segmentacji będzie

oceniana miarą $F1$ poprzez jej wartość oczekiwaną (oznaczenie $\mu F1$), odchylenie standardowe (oznaczenie $\sigma F1$) oraz ilość przypadków odstających (oznaczenie $oF1$). Przy tak przyjętej ocenie najlepsze wyniki to, te które mają najwyższą wartość oczekiwaną, przy małym odchyleniu standardowym i stosunkowo (do liczebności zbioru) małej ilości obserwacji odstających. We wszystkich opisanych niżej eksperymentach zastosowano miarę $F1$ z wyznaczaniem wartości $\mu F1$, $\sigma F1$ oraz $oF1$.

3.2.3. Przygotowanie danych testowych

Opisywane wyżej metody przetwarzania i oprogramowanie testujące zostały nakierowane na przekształcanie obrazów oka wykonanych w bliskiej podczerwieni. Główną przesłanką do użycia takich obrazów był fakt publicznej dostępności znaczącej ilości próbek. Utworzenie własnej bazy obrazów oka w liczebności przekraczającej 100 to zadanie praktycznie wymagające bardzo długiego okresu ich gromadzenia a dodatkowo obwarowane istotnymi ograniczeniami prawnymi zawartymi w ustawach dotyczących ochrony danych osobowych. Wykorzystanie publicznie dostępnych zbiorów usuwa w/w problemy a jednocześnie daje możliwości stosunkowo prostego porównania własnych wyników z uzyskiwanymi przez innych wykorzystujących te same zestawy próbek. Wybrana została baza *CASIA Iris Image Database* [4], którą zbudowała Chinese Academy of Sciences – Institute of Automation, właśnie do celów związanych z systemami biometrycznymi. Zestaw obrazów w wersji 4 (*CASIA-IrisV4*) posiada 6 różnych zbiorów. Ze względu na to, że przygotowane metody i ich implementacja przygotowane zostały do badania skuteczności usuwania wpływu pewnych typowych jak i najtrudniejszych rodzajów zakłóceń, wyselekcjonowano 3 z nich w taki sposób, aby były w nich obrazy zawierające interesujące zniekształcenia. Wybrane zbiory to:

- *CASIA-Iris-Thousand* – ilość osób 1000, ilość obrazów ok 20000, główne cechy – okulary na części próbek, refleksy świetlne pojawiające się na źrenicy i okularach, widoczny szeroki obszar wokół gałki ocznej łącznie z brwiami.
- *CASIA-Iris-Lamp* – ilość osób 411, ilość obrazów ok 16000, główne cechy – zmienny rozmiar źrenicy, nierównomierne oświetlenie.
- *CASIA-Iris-Interval* – ilość osób 249, ilość obrazów ok 2600, główne cechy – punktowe refleksy świetlne w obszarze źrenicy, obrazy prześwietlone, obrazy ze słabym kontrastem.

Zgodnie z opisem sposobu oceny jakości do jej przeprowadzenia konieczne są obrazy porównawcze przygotowane przez człowieka. Ze względu na czasochłonność ręcznego przeprowadzenia segmentacji z każdego ze zbiorów wybrano losowo po 200 próbek. Tak utworzone zestawy zdjęć nazwano: zbiór Z1 – zawiera próbki z *CASIA-Iris-Thousand*, zbiór Z2 – próbki z *CASIA-Iris-Lamp*, zbiór Z3 – próbki z *CASIA-Iris-Interval*. W sumie przygotowano 600 zdjęć porównawczych. Format ich opisu wykonano tak, aby był zgodny z opisem wyniku uzyskiwanym z aplikacji segmentującej. Dzięki temu możliwe było automatyczne porównywanie z obliczaniem wskaźników statystycznych.

3.3. Wybrane eksperymenty i wnioski

Jak opisano w podpunkcie 3.1 przygotowane do prowadzenia badań oprogramowanie posiada bardzo szeroki zakres wyboru zastosowanych metod i konfigurowania ich parametrów. Jest ich na tyle dużo, że realizacja wszystkich możliwych wariantów przetwarzania, ich opis i analiza wyników temat na oddzielne obszerne opracowanie. W przedstawionej publikacji zostały krótko opisane trzy wybrane próby, które dobrze wskazują na możliwości zastosowanego oprogramowania.

3.3.1. Wpływ parametru filtru Gaussa i kroku różniczkowania w operatorze całkująco-różniczkującym

Pierwszy z opisywanych eksperymentów dotyczy wpływu filtracji wstępnej obrazu za pomocą filtru Gaussa (oznaczenie parametru σG) i doboru kroku różniczkowania w operatorze Dougman'a (oznaczenie parametru Δr). Filtr Gaussa należący do kategorii uśredniających likwiduje wysokoczęstotliwościowy szum, jednak w efekcie otrzymujemy wygładzony obraz utrudniając tym wykrywanie krawędzi. Z kolei wielkość parametru Δr decyduje o skuteczności wykrycia krawędzi, przy czym niskie wartości sprawdzają się w przy „ostrzych” obrazach, zaś duże przy obrazach wygładzonych. Zaplanowany eksperyment służy obserwacji efektów segmentacji przy różnych kombinacjach wartości współczynnika filtru Gaussa σG i kroku zmian promienia okręgu Δr w operacji różniczkowania operatora całkująco-różniczkującego. Testy zostały przeprowadzone na 3 zbiorach wskazanych powyżej. Parametr Δr zmieniano w zakresie 2–24 z krokiem 2, zaś σG w zakresie 0–10 z krokiem 0,5. Uporządkowane względem wartości $\mu F1$ wyniki (10 najlepszych) zostały pokazane w kolejnych tabelach 3.1, 3.2 i 3.3 odpowiednio dla zbiorów Z1, Z2 i Z3.

TABELA 3.1. Wynik dla zbioru Z1 względem parametrów Δr i σG

Lp.	Δr	σG	$\mu F1$	$\sigma F1$	$oF1$
1	10	6,5	0,804	0,314	27
2	10	8	0,801	0,311	28
3	10	7	0,800	0,315	29
4	10	6	0,800	0,320	29
5	10	7,5	0,799	0,314	29
6	10	8,5	0,797	0,309	28
7	10	9	0,792	0,310	28
8	10	5,5	0,792	0,328	31
9	16	7	0,786	0,299	26
10	16	7,5	0,785	0,298	26

TABELA 3.2. Wynik dla zbioru Z2 względem parametrów Δr i σG

Lp.	Δr	σG	$\mu F1$	$\sigma F1$	$oF1$
1	12	7,5	0,874	0,149	15
2	12	7	0,874	0,154	16
3	8	7	0,870	0,180	18
4	12	5	0,868	0,183	17
5	12	5,5	0,868	0,176	17
6	12	6,5	0,868	0,163	17
7	8	6	0,868	0,197	18
8	8	7,5	0,866	0,189	16
9	12	6	0,865	0,177	18
10	12	4,5	0,863	0,197	17

TABELA 3.3. Wynik dla zbioru Z3 – parametry Δr i σG

Lp.	Δr	σG	$\mu F1$	$\sigma F1$	$oF1$
1	20	6,5	0,882	0,134	7
2	22	5,5	0,880	0,119	10
3	22	6,5	0,880	0,119	10
4	22	6	0,879	0,120	10
5	20	7	0,879	0,139	8
6	20	7,5	0,876	0,136	10
7	22	7	0,875	0,125	11
8	20	8	0,874	0,137	11
9	22	7,5	0,873	0,132	12
10	22	8	0,871	0,127	14

We wszystkich przedstawionych tabelach wartość oczekiwana miary jest dość wysoka (powyżej 0,78) co oznacza, że segmentacja zlokalizowała tęczę prawidłowo. Wyraźnie najslabsze wyniki widoczne są w tabeli 3.1 i dotyczą one zbioru Z1. Ewaluacja ręczna – przegląd wzrokowy plików zbioru Z1 wskazał, że najbardziej prawdopodobną przyczyną była duża ilość mocnych refleksów świetlnych.

3.3.2. Zastosowanie algorytmu usuwania refleksów i ograniczenia obszaru poszukiwań

Analiza wyników uzyskanych w eksperymencie opisanym w punkcie 3.3.1 wskazała, że najgorsze wyniki wynikały z obecności na zdjęciach refleksów świetlnych położonych na obrazie okularów poza przestrzenią, na której widoczna była tęczówka. Zainspirowało to do przeprowadzenia analizy z włączeniem do procesu przetwarzania algorytmu usuwającego refleksy oraz dodatkowo wprowadzenia ograniczenia obszaru poszukiwania położenia środka okręgu wyznaczającego wewnętrzną granicę tęczówki.

Zastosowany do ustalenia obszaru poszukiwań algorytm jest dość prosty i korzysta z parametru będącego progiem wartości piksela odniesionego do średniej jasności obrazu (oznaczony jako wpj – względny próg jasności). Z kolei do usunięcia refleksów świetlnych zastosowano metodę *inpainting*'u [17], przy czym pierwszą operacją było usunięcie refleksów na oryginalnym obrazie. Zmieniała ona jednocześnie średnią wartość jasności (usunięte najjaśniejsze punkty) co miało wpływ na bezwzględne wartości progu wpj , co dodatkowo uzasadniało połączenie wybranych metod w jednym eksperymencie. Eksperyment został przeprowadzony przy zmiennych wartościach progu wpj w zakresie 0,05–1 z krokiem co 0,05. Analogicznie jak w punkcie 3.3.1, poniżej przedstawiono wyniki (10 najlepszych) uzyskane dla wszystkich zbiorów wskazanych w tej publikacji.

TABELA 3.4. Wyniki testu – filtr antyrefleksu i ograniczenie obszaru poszukiwań, zbiór Z1

Lp.	wpj	$\mu F1$	$\sigma F1$	$oF1$
1	0,25	0,913	0,116	6
2	0,2	0,909	0,132	7
3	0,3	0,908	0,132	7
4	0,15	0,907	0,134	8
5	0,35	0,903	0,147	8
6	0,4	0,903	0,147	8
7	0,45	0,903	0,147	8
8	0,5	0,903	0,147	8
9	0,55	0,903	0,147	8
10	0,6	0,900	0,153	9

TABELA 3.5. Wyniki testu – filtr antyrefleksu i ograniczenie obszaru poszukiwań, zbiór Z2

Lp.	wpi	$\mu F1$	$\sigma F1$	$\sigma F1$
1	0,2	0,898	0,082	16
2	0,35	0,895	0,096	15
3	0,3	0,895	0,096	15
4	0,25	0,894	0,101	13
5	0,4	0,890	0,115	13
6	0,45	0,890	0,115	13
7	0,55	0,885	0,131	14
8	0,6	0,885	0,131	14
9	0,65	0,885	0,131	14
10	0,7	0,885	0,131	14

TABELA 3.6. Wyniki testu – filtr antyrefleksu i ograniczenie obszaru poszukiwań, zbiór Z3

Lp.	wpi	$\mu F1$	$\sigma F1$	$\sigma F1$
1	0,4	0,903	0,064	11
2	0,45	0,903	0,064	11
3	0,5	0,903	0,064	11
4	0,55	0,903	0,064	11
5	0,6	0,903	0,064	11
6	0,65	0,903	0,064	11
7	0,7	0,903	0,064	11
8	0,75	0,903	0,064	11
9	0,8	0,903	0,064	11
10	0,85	0,903	0,064	11

Jak widać w prezentowanych tabelach wyniki mierzone wartością oczekiwaną uległy poprawie we wszystkich zbiorach. Dodatkowo odchylenie standardowe zmniejszyło się bardzo wyraźnie. Świadczy to o bardzo dużym wpływie punktowych jasnych zakłóceń na skuteczność segmentacji. W każdym rozpatrywanym przypadku (także gdy na obrazie nie było refleksów świetlnych) zastosowanie algorytmu *inpainting*'u poprawiało wynik. Należy stąd wyciągnąć wniosek, że w zadaniach segmentacji tęczówki powinien on być stosowany z definicji. Szczegółnej poprawie uległy wartości standardowego odchylenia. Wskazuje to na pozytywne efekty także w zakresie powtarzalności. Jednakże, w niektórych przypadkach uległa zwiększeniu liczba obserwacji odstających. Można to uznać jako skutek zawężenia odchylenia standardowego, ale w niektórych zastosowaniach, gdy unikanie pojawienia się istotnie słabych wyników jest kluczowe

może stanowić wadę. Generalnie należy stwierdzić, że uzyskano znaczącą poprawę i użyty zestaw przekształceń i algorytmów może stanowić punkt wyjścia do budowy wysokoskutecznego systemu biometrycznego wykorzystującego tęczówkę.

3.3.3. Wykorzystanie algorytmu poprawy kontrastu

Mechanizmy dokonujące podziału obrazu na interesujące elementy zawsze opierają się na ustaleniu różnic i granic pomiędzy nimi. Potrzebują one odpowiednio przygotowanego zdjęcia. Jednym z najważniejszych czynników pozwalający rozróżniać zawartość obrazu, także dla człowieka, jest odpowiedni kontrast. Wydaje się, że dotyczy to także przypadku segmentacji (wydzielenia) tęczówki. Należy jednak uwzględnić fakt, że zmiany kontrastu wpływają na poziom jasności a precyzyjniej na rozkład jasności pomiędzy poszczególnymi obszarami obrazu. Już wstępne eksperymenty pokazały, że zastosowanie klasycznego podejścia jakim jest wyrównanie histogramu nie przynosi oczekiwanych rezultatów w postaci lepszego wykrywania położenia tęczówki. W tej metodzie dzieje się tak przede wszystkim z powodu powiększenia widoczności nie tylko samego obiektu, ale i elementów pobocznych takich jak rzęsy, krawędzie powiek czy inne podobne w charakterze zakłócenia. Wynika to z sedna zasady działania algorytmu wyrównania histogramu, który to operuje jednorodnie na całym obrazie.

Z wymienionych wyżej powodów zdecydowano się na wykonanie całego zbioru testów przy wykorzystaniu adaptacyjnego wyrównania kontrastu algorytmem CLAHE. Tak jak w poprzednich eksperymentach wykorzystano zbiory Z1, Z2 i Z3 i dokonano oceny wyników przy zastosowaniu miary F1. Zastosowano parametr limitu wartości kontrastu (oznaczenie lk – limit kontrastu) zmieniany w zakresie 0,25–10,0 z krokiem 0,25. Ponownie tak jak w poprzednich badaniach najlepszych 10 wyników przedstawiono w tabelach 3.7, 3.8, 3.9.

TABELA 3.7. Wyniki testu zbior Z1 – adaptacyjne wyrównywanie histogramu

Lp.	lk	$\mu F1$	$\sigma F1$	$\sigma F1$
1	0,25	0,952	0,077	3
2	5,75	0,950	0,051	7
3	0,5	0,950	0,080	4
4	1	0,948	0,085	5
5	2,75	0,948	0,085	5
6	2	0,948	0,085	5
7	1,5	0,948	0,086	5
8	0,75	0,947	0,085	5
9	2,25	0,947	0,085	5
10	2,5	0,947	0,085	5

TABELA 3.8. Wyniki testu zbior Z2 – adaptacyjne wyrównywanie histogramu

Lp.	lk	$\mu F1$	$\sigma F1$	$oF1$
1	0,25	0,946	0,057	7
2	1,25	0,942	0,072	11
3	0,5	0,941	0,082	7
4	1	0,941	0,073	11
5	1,75	0,941	0,074	9
6	1,5	0,941	0,074	9
7	2,5	0,940	0,083	7
8	2,25	0,939	0,085	7
9	0,75	0,939	0,087	7
10	2,75	0,938	0,087	7

TABELA 3.9. Wyniki testu zbior Z3 – adaptacyjne wyrównywanie histogramu

Lp.	lk	$\mu F1$	$\sigma F1$	$oF1$
1	0,25	0,946	0,057	7
2	1,25	0,942	0,072	11
3	0,5	0,941	0,082	7
4	1	0,941	0,073	11
5	1,75	0,941	0,074	9
6	1,5	0,941	0,074	9
7	2,5	0,940	0,083	7
8	2,25	0,939	0,085	7
9	0,75	0,939	0,087	7
10	2,75	0,938	0,087	7

W przedstawionych wyżej, tabela 3.7, 3.8, 3.9, wynikach zaobserwowano (jak spodziewano się) poprawę jakości segmentacji tęczy (wzrost wartości $\mu F1$ i spadek liczby $oF1$). Jednakże należy zwrócić uwagę, że najlepsze wyniki dla każdego z trzech zbiorów osiągnięto przy minimalnym zwiększeniu kontrastu. Istotne powiększanie kontrastowości obrazu prowadziło do pogorszenia rezultatów, co potwierdziła obserwacja wzrokowa, gdyż przy większym kontraście uwidaczniane mocniej były elementy zakłócające, np. rzęsy, krawędzie powiek, tak jak miało to miejsce przy zwykłym (nieadaptacyjnym) wyrównaniu histogramu. Wykonane na tym etapie badania kilkakrotnie wskazały, że duży wpływ na jakość segmentacji tęczy ma obecność na zdjęciach elementów powiek i rzęs i w opracowanych rozwiązaniach przygotowano dodatkowe operacje służące ograniczeniu tego wpływu.

Podsumowanie

Celem przedstawionych w punkcie 4 eksperymentów było wykazanie wpływu różnych sposobów przetwarzania obrazów oczu na skuteczność segmentacji tęczówki. Jako sposób określenia jakości została wykorzystana często używana do oceny efektów przetwarzania obrazów miara F1 [16]. Przekształcaniu zostały poddane 3 zbiory testowe zdjęć pochodzących z publicznej bazy o liczebności 200 próbek każdy, a do porównań i wyciągania wniosków użyto wartości statystycznych miary F1, takich jak wartość oczekiwana i odchylenie standardowe oraz ilość obserwacji odstających. Testy były przeprowadzone za pomocą specjalnie przygotowanego oprogramowania umożliwiającego wykorzystanie wielu nastawionych na wydzielanie obszaru tęczówki metod przekształcania wraz z możliwością modyfikacji ich parametrów. Aplikacja była także wyspecjalizowana do oceny jakości segmentacji tęczówki rozumianej jako pewien etap przetwarzania w systemie biometrycznym. Zaprezentowane eksperymenty stanowią jedynie małą próbkę możliwości, wielo-wariantowości oprogramowania a jednocześnie pokazują możliwości uzyskiwania poprawy wyników poprzez wprowadzenie nowych nieskomplikowanych algorytmów, modyfikacji znanych rozwiązań oraz dobór wartości ich parametrów. Już przytoczone tylko 3 eksperymenty pozwalają na ustalenie jakie metody wnoszą istotną poprawę jakości segmentacji tęczówki. Należy do nich wprowadzenie w ciąg przekształceń, algorytmu usuwania refleksów świetlnych i poprawa kontrastu metodą adaptacyjnego wyrównania CLAHE. Zastosowane w aplikacji rozwiązania i specjalnie opracowane modyfikacje znanych metod dają duże możliwości badań nad osiągnięciem wysokich współczynników jakości segmentacji tęczówki. Inne, nie pokazane w tej publikacji eksperymenty z metodami wykrywania powiek, rzęs i innych artefaktów wskazują na potencjał całości opracowanych rozwiązań do odszukania zestawu algorytmów i wartości ich parametrów, dających wyniki segmentacji o jakości pozwalającej na zbudowanie całego, wysoce skutecznego pełnego systemu biometrycznego opartego na wykorzystaniu tęczówki jako unikalnej cechy człowieka.

*Publikacja zrealizowana w ramach pracy zespołowej WZ/WI-IIT/4/2020 pt.
„Biometria i przetwarzanie sygnałów”*

Bibliografia

- [1] Strona firmowa <https://payeye.com> [dostęp styczeń 2021]
- [2] Daugman J.D., *High confidence visual recognition of persons by a test of statistical independence*, IEEE Transactions on Pattern Analysis and Machine Intelligence, 1993, vol. 15, no. 11
- [3] Daugman J.D., *How iris recognition works*, IEEE Transactions on Circuits and Systems for Video Technology, 2004, vol. 14, no. 1
- [4] CASIA Iris Image DataBase version 4, <http://biometrics.idealtest.org/findTotalDbByMode.do?mode=Iris>, [dostęp listopad 2020]
- [5] Gonzales R., Woods R., *Digital Images Processing*, Pearson/Prentice Hall, 2008

- [6] Wildes R.P., *Iris Recognition: An Emerging Biometric Technology*, Proceedings of the IEEE, 1997, vol. 85, no. 9
- [7] Jain A.K., Ross A.A., *Introduction to Biometrics*, Springer, 2011
- [8] Adler, F. H., *Physiology of the Eye*, fifth ed., St. Louis, Mosby, 1970
- [9] Ślot K., *Wybrane zagadnienia biometrii*, WKiŁ, Warszawa, 2008
- [10] Daugman J.D., *New Methods in Iris Recognition*, IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics), 2007, vol. 37, no. 5
- [11] Hough P.V.C. *Method and means for recognizing complex patterns*, U.S. Patent 3,069,654, Dec. 18, 1962
- [12] Goldenberg R., Kimmel R., Rivlin E., Rudzsky M., *Fast geodesic active contours*, IEEE Transactions on Image Processing, 2001, vol. 10, no. 10
- [13] Wildes R.P., Asmuth J.C., Green G.L., Hsu S.C., Kolczynski R.J., Matey J.R., McBride S.E., *A system for automated iris recognition*, Proceedings of 1994 IEEE Workshop on Applications of Computer Vision, 1994, pp 121–128
- [14] Kong W.K., Zhang D., *Accurate iris segmentation based on novel reflection and eyelash detection model*, Proceedings of 2001 International Symposium on Intelligent Multimedia, Video and Speech Processing, Hong Kong 2001, pp 263–266
- [15] Malina W., Śmiatacz M., *Cyfrowe przetwarzanie obrazów*, Akademicka Oficyna Wydawnicza EXIT, Warszawa, 2008
- [16] Powers D. M. W., *Evaluation: From Precision, Recall and F-Measure to ROC, Informedness, Markedness & Correlation*, Journal of Machine Learning Technologies, 2011, vol. 2, no. 1, pp. 37–63
- [17] Bertalmío, M., Sapiro, G., Caselles, V., Ballester, C., *Image Inpainting*, Proceedings of SIGGRAPH 2000, New Orleans, USA, 2000. pp. 417–424. doi:10.1145/344779.344972
- [18] Wejroch T., *Segmentacja tęczówki oka na obrazach w bliskiej podczerwieni*, Białystok 2018.