

Mariusz FRĄCKIEWICZ, Henryk PALUS, Grzegorz SZOLC
Politechnika Śląska

POPRAWIONY WSKAŹNIK SPSIM DO OCENY JAKOŚCI OBRAZÓW

Streszczenie. Obiektywne miary oceny jakości obrazu (IQA) odgrywają coraz ważniejszą rolę w ocenie jakości obrazów cyfrowych. Oczekuje się, że nowe indeksy IQA będą silnie skorelowane z subiektywnymi ocenami obserwatorów wyrażonymi przez Mean Opinion Score (MOS) lub Difference Mean Opinion Score (DMOS). Jednym z takich ostatnio zaproponowanych indeksów jest indeks SuperPixel-based SIMilarity (SPSIM), który zamiast prostokątnej siatki pikseli wykorzystuje superpiksele. Autorzy niniejszej pracy zaproponowali trzy modyfikacje indeksu SPSIM. W tym celu zmieniono przestrzeń barw wykorzystywaną przez SPSIM oraz zmodyfikowano sposób wyznaczania map podobieństwa przez SPSIM, wykorzystując metody zaczerpnięte z algorytmu obliczania wskaźnika podobieństwa średniego odchylenia (MDSI). Trzecia modyfikacja była połączeniem dwóch pierwszych. Wyniki eksperymentalne uzyskane dla wielu obrazów kolorowych z pięciu baz danych obrazów wykazały zalety proponowanych modyfikacji SPSIM.

AN IMPROVED SPSIM INDEX FOR IMAGE QUALITY ASSESSMENT

Summary. Objective image quality assessment (IQA) measures are playing an increasingly important role in the evaluation of digital image quality. New IQA indices are expected to be strongly correlated with subjective observer evaluations expressed by Mean Opinion Score (MOS) or Difference Mean Opinion Score (DMOS). One such recently proposed index is the SuperPixel-based SIMilarity (SPSIM) index, which uses superpixel patches instead of a rectangular pixel grid. The authors of this paper have proposed three modifications to the SPSIM index. For this purpose, the color space used by SPSIM was changed and the way SPSIM determines similarity maps was modified using methods derived from an algorithm for computing the Mean Deviation Similarity Index (MDSI). The third modification was a combination of the first two. The experimental results obtained for many color images from five image databases demonstrated the advantages of the proposed SPSIM modifications.

1. Wprowadzenie

Metody oceny jakości obrazu IQA (ang. *Image Quality Assessment*) odgrywają istotną rolę w szerokim spektrum operacji przetwarzania obrazów, takich jak filtracja, kompresja i poprawa jakości obrazu. Pozwalają one na obiektywną ocenę jakości percepcyjnej zniekształconego obrazu. Zniekształcone obrazy niekoniecznie powstają

w procesie akwizycji, ale mogą być tworzone przez różne rodzaje przetwarzania obrazu. Wśród metod IQA najbardziej rozwinięte są metody, które porównują przetworzone (zniekształcone) obrazy z obrazami oryginalnymi i są nazywane metodami FR-IQA (ang. *FullReference-IQA*). W ten sposób oceniają one jakość obrazu po wykonaniu operacji jego przetwarzania. Oceny uzyskane dla każdej z miar IQA można porównać z subiektywnymi średnimi ocenami MOS (ang. *Mean Opinion Score*) lub DMOS (ang. *Difference Mean Opinion Score*) uzyskanymi od obserwatorów. Określanie subiektywnych wartości MOS jest jednak czasochłonne i kosztowne. Gdy stosujemy metody FR-IQA, wynikiem porównań będą współczynniki korelacji: im wyższa liczba, tym lepszy pomiar. Podsumowując, celem badań w dziedzinie IQA jest znalezienie środków do obiektywnej, ilościowej oceny jakości obrazu na podstawie subiektywnej oceny dokonanej przez system wzrokowy człowieka HVS (ang. *Human Visual System*).

Wśród miar IQA stosowanych w przetwarzaniu obrazów kolorowych przez długi czas dominowała, ze względu na swoją prostotę, miara o niskiej złożoności, zwana średnim błędem kwadratowym MSE (ang. *Mean Squared Error*). Podobnie popularne było stosowanie innych miar opartych na teorii sygnałów, takich jak średni błąd bezwzględny MAE (ang. *Mean Absolut Error*) czy stosunek sygnału do szumu PSNR (ang. *Peak Signal-to-Noise Ratio*). Z czasem zauważono słaby związek między tymi miarami a ludzką percepcją wzrokową. W pracy [7] pokazano wady miary PSNR na przykładzie obrazu latarni morskiej. Do tego obrazu i jego kopii dodano dodatkowy szum, który znajdował się w dolnej lub górnej części obrazu. W pierwszym przypadku szum był niewidoczny dla obserwatora, w drugim obniżał ocenę jakości obrazu. Tymczasem wartości PSNR dla obu obrazów były takie same. Porównywanie obrazów na zasadzie piksel do piksela nie pozwala na określenie wpływu sąsiedztwa piksela na postrzegany kolor. Ten brak wpływu jest wadą wszystkich wymienionych wyżej miar.

Od 2004 roku jako metodę IQA stosuje się miarę indeksu podobieństwa strukturalnego SSIM (ang. *Structural Similarity Index Measure*) [15], która odzwierciedla percepcyjną zmianę informacji o strukturze obiektów w scenie. Miara ta wykorzystuje ideę współzależności pikseli, które sąsiadują ze sobą w przestrzeni obrazu. Wartość SSIM w porównywanych obrazach powstaje jako kombinacja trzech podobieństw: luminancji, kontrastu i struktury. Oblicza się ją, uśredniając wyniki uzyskane w oddzielnych oknach lokalnych. W 2011 roku zaproponowano miarę o nazwie GSIM (ang. *Gradient SIMilarity index*) [6], która uwzględnia podobieństwo gradientu w obrazach, które reprezentują krawędzie. Pomysły te stały się punktem wyjścia dla nowych percepcyjnych miar jakości obrazu, a w ciągu ostatniej dekady zaproponowano wiele takich miar IQA. W pracy [18] został zaproponowany indeks jakości nazwany FSIM (ang. *Feature SIMilarity index*). Lokalna jakość ocenianego obrazu jest opisywana za pomocą dwóch niskopoziomowych map cech opartych na zgodności fazowej (PC) i wielkości gradientu (GM). FSIMc, kolorowa wersja FSIM, jest wynikiem uwzględnienia składowych chrominancji I oraz Q. Innym przykładem podejścia gradientowego jest prosty indeks zwany odchyleniem podobieństwa wielkości gradientu GMSD (ang. *Gradient Magnitude Similarity Deviation*) [16]. Mapa podobieństwa wielkości gradientu wyraża lokalną jakość obrazu, a następnie obliczane jest odchylenie standardowe tej mapy i wykorzystywane jako końcowy wskaźnik jakości GMSD. Zhang L. i in. [17] opisali miarę nazwaną Visual VSI (ang. *Saliency-based Index*), która wykorzystuje lokalną mapę jakości zniekształconego obrazu opartą na zmianach istotności poszczególnych regionów obrazu.

Ostatnio Nafchi i in. [8] zaproponowali nowy model IQA o nazwie MDSI (ang. *Mean Deviation Similarity Index*), który wykorzystuje nowe podobieństwo gradientowe do oceny zniekształceń lokalnych oraz podobieństwo chromatyczne do zniekształceń kolorystycznych. Ostateczne obliczenie wyniku MDSI wymaga zastosowania metody łączącej obie mapy podobieństwa; w tym przypadku zastosowano specyficzną strategię łączenia odchyleń. W pracy [2] przedstawiono indeks PSIM (ang. *Perceptual SIMilarity*), który oblicza podobieństwa mikro- i makrostrukturalne, opisywane jak zwykle przez mapy gradientowe. Dodatkowo indeks ten wykorzystuje podobieństwo kolorów i realizuje łączenie oparte na percepcji. Modele IQA opracowane w ostatnim czasie są złożone i uwzględniają coraz większą liczbę właściwości ludzkiego układu wzrokowego. Taki model został opracowany przez Shi C. i Lin Y. i nazwany VCGS (ang. *Visual saliency with Color appearance and Gradient Similarity*) [13]. Indeks ten opiera się na fuzji danych z trzech map podobieństwa zdefiniowanych przez istotność wizualną z wrażeniem koloru, gradientem i chrominancją. Modele IQA w coraz większym stopniu uwzględniają fakt, że ludzie zwracają większą uwagę na ogólną strukturę obrazu niż na lokalne informacje o każdym pikselu.

Wiele metod IQA najpierw przekształca składowe RGB pikseli obrazu w inne przestrzenie barw, które są bardziej związane z postrzeganiem kolorów. Są to zazwyczaj przestrzenie należące do kategorii przestrzeni typu "luminancja-chrominancja", takie jak YUV, YIQ, YCrCb, CIELAB itp. Takie miary opracowano niedawno, np. MDSI. Osiągają one wyższe współczynniki korelacji z MOS podczas testów na publicznie dostępnych bazach obrazów.

Przedstawiona powyżej idea oceny podobieństwa została wykorzystana przez Suna i in. do zaproponowania innego indeksu IQA o nazwie SPSIM (ang. *SuperPixel-based SIMilarity index*) [14]. Idea superpiksela sięga 2003 roku [11]. Grupę pikseli o podobnych cechach (intensywności, kolorze itp.) można zastąpić pojedynczym superpikselem. Superpiksele zapewniają wygodną i zwartą reprezentację obrazów, przydatną w złożonych obliczeniowo zadaniach. Są one znacznie większe niż piksele, dlatego algorytmy działające na obrazach superpikselowych mogą być szybsze. Superpiksele zachowują większość krawędzi obrazu. Istnieje wiele różnych metod rozkładu obrazów na superpiksele, z których największą popularność zdobyła szybka metoda SLIC (ang. *Simple Linear Iterative Clustering*). Zazwyczaj w pomiarach jakości obrazu porównuje się cechy wyodrębnione z pikseli (np. MSE, PSNR) lub prostokątnych okien (np. SSIM: *Structural Similarity Index Measure*). Takie okna zwykle nie mają znaczenia wizualnego, natomiast superpiksele, w przeciwieństwie do sztucznie wygenerowanych plam, mają znaczenie wizualne i są dopasowane do zawartości obrazu.

W niniejszej pracy rozważamy nowe modyfikacje miary SPSIM, które poprawiają współczynniki korelacji z MOS. Niniejsza praca jest zorganizowana w następujący sposób. Po wprowadzeniu, w rozdziale 2 przedstawiamy względnie nową miarę jakości obrazu o nazwie SPSIM. W rozdziale 3 wprowadzono dwie modyfikacje miary SPSIM. W rozdziale 4 przedstawione są wyniki testów eksperymentalnych na różnych bazach obrazów. Praca zakończona jest podsumowaniem w rozdziale 5.

2. Przegląd istniejących rozwiązań

2.1. MDSI

Wiele miar IQA działa w następujący sposób: określa się lokalne zniekształcenia w obrazach, buduje mapy podobieństwa i wdraża strategię łączenia na podstawie średniej, średniej ważonej, odchylenia standardowego itp. Przykładem takiego podejścia do modelowania wskaźnika IQA jest wspomniany w poprzednim rozdziale wskaźnik podobieństwa średniego odchylenia MDSI (ang. *Mean Deviation Similarity Index*). Obliczanie wskaźnika MDSI rozpoczyna się od konwersji składowych przestrzeni barw RGB obrazów wejściowych na składową luminancji:

$$L = 0.2989R + 0.5870G + 0.1140B \quad (1)$$

i dwie składowe chrominancje:

$$\begin{bmatrix} H \\ M \end{bmatrix} = \begin{bmatrix} 0.30 & 0.04 & -0.35 \\ 0.34 & -0.6 & 0.17 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix}. \quad (2)$$

Indeks ten opiera się na obliczaniu podobieństwa gradientów (GS) dla zniekształceń strukturalnych oraz podobieństwa chromatyczności (CS) dla zniekształceń kolorów.

Lokalna mapa podobieństwa strukturalnego jest zwykle wyznaczana na podstawie wartości gradientu. Klasycznie, mapy podobieństwa strukturalnego są wyprowadzane z wartości gradientów obliczanych niezależnie dla obrazu oryginalnego i zniekształconego. W przypadku miary MDSI klasyczne podejście zostało rozszerzone z wykorzystaniem mapy wartości gradientu dla połączonych wartości kanałów luminancji obu obrazów (referencyjnego r i zniekształconego d):

$$f = 0.5(L_r + L_d), \quad (3)$$

Podobieństwo strukturalne wyrażone jest jako:

$$GS_{rf}(x) = \frac{2G_r(x)G_f(x) + C_2}{G_r^2(x) + G_f^2(x) + C_2}, \quad (4)$$

$$GS_{df}(x) = \frac{2G_d(x)G_f(x) + C_2}{G_d^2(x) + G_f^2(x) + C_2}, \quad (5)$$

$$\widehat{GS}(x) = GS(x) + [GS_{df}(x) - GS_{rf}(x)]. \quad (6)$$

Do obliczania wielkości gradientu stosuje się prosty operator Prewitta. Autorzy indeksu MDSI zmodyfikowali również metodę określania lokalnego podobieństwa chromatyczności. Omówione wcześniej miary IQA, które wykorzystywały chrominancję obrazu cyfrowego, takie jak FSIM czy VSI, określały podobieństwo chromatyczności oddzielnie dla dwóch składowych chrominancji. W przypadku MDSI zaproponowano jednoczesne określanie podobieństwa kolorów dla obu składowych chrominancji, korzystając z następującego wzoru:

$$\widehat{CS}(x) = \frac{2(H_r(x)H_d(x) + M_r(x)M_d(x)) + C_3}{H_r^2(x) + H_d^2(x) + M_r(x)^2 + M_d(x)^2 + C_3}, \quad (7)$$



Rys. 1. Mapy podobieństwa MDSI: **(a)** obraz referencyjny, **(b)** obraz zniekształcony, **(c)** mapa podobieństwa dla chromy $\widehat{CS}(x)$, **(d)** mapa podobieństwa dla gradientu $\widehat{GCS}(x)$.

Mapy podobieństwa dla chromy $\widehat{CS}(x)$ i gradientu $\widehat{GCS}(x)$ są łączone średnią ważoną:

$$\widehat{GCS}(x) = \alpha \widehat{GS}(x) + (1 - \alpha) \widehat{CS}(x), \quad (8)$$

Ostatnim krokiem obliczeniowym jest przekształcenie wynikowej mapy \widehat{GCS} w wynik MDSI:

$$MDSI = \left[\frac{1}{N} \sum_{i=1}^N |\widehat{GCS}_i|^{1/4} - \left(\frac{1}{N} \sum_{i=1}^N \widehat{GCS}_i \right)^{1/4} \right]^{1/4}. \quad (9)$$

Sugestie dotyczące wyboru kilku parametrów, których wartości wpływają na efektywność indeksu MDSI, można znaleźć w oryginalnym artykule [8].

2.2. SPSIM

W przeciwieństwie do innych miar jakości, w metodzie Superpixel-based SIMilarity (SPSIM) ekstrakcja cech jest oparta na segmentacji superpikselowej. W wyniku grupowania pikseli powstaje mozaika o znacznie mniejszej liczbie tzw. superpikseli, co pozwala na szybsze dalsze przetwarzanie. Ważną zaletą segmentacji z wykorzystaniem superpikseli w porównaniu z innymi algorytmami nadsegmentacji jest możliwość określenia a priori liczby generowanych superpikseli. Ponadto segmentacja z użyciem superpikseli pozwala lepiej wyodrębnić z obrazu ważne percepcyjnie regiony.

Wśród algorytmów generujących superpiksele można wyróżnić m.in. algorytmy oparte na grafach, gradientowe, klasteryzacyjne, wododziałowe itp. Wiele z tych metod jest przewidzianych do segmentacji obrazu z parametrami prowadzącymi do nadsegmentacji. Kształt i rozmiar superpikseli może być różny w zależności od zastosowanego algorytmu. Każdy piksel znajduje się w jednym, i tylko jednym, superpikselu. Algorytmy generowania superpikseli kontrolują liczbę i właściwości superpikseli, takie jak zwartość czy minimalny rozmiar. Jednym z najpopularniejszych i najszybszych algorytmów segmentacji superpikselowej jest algorytm SLIC (ang. *Simple Linear Iterative Clustering*) oparty na metodzie k-means. Charakteryzuje się on tym, że wyjściowe superpiksele mają podobny kształt i rozmiar. Do jego niewątpliwych zalet należy fakt, że segmentacja wymaga jedynie określenia pożądanej liczby superpikseli w obrazie wyjściowym. Dlatego też algorytm SLIC jest wykorzystywany w opisywanym w niniejszej pracy indeksie jakości SPSIM. Superpiksele są generowane tylko na obrazie referencyjnym, a następnie są stosowane zarówno do obrazu referencyjnego, jak i zniekształconego.

Algorytm obliczania indeksu SPSIM opiera się na podobieństwie luminancji superpiksela, podobieństwie chrominancji superpiksela i podobieństwie gradientu piksela.

Wartości map podobieństwa są obliczane w przestrzeni barw YUV zamiast przestrzeni barw RGB, gdzie Y to składowa luminancji, a U i V to składowe chrominancji. Jeśli użyjemy symbolu s_i dla superpiksela zawierającego piksel i , to możemy zapisać następujące wzory na luminancję L_i i podobieństwo luminancji $M_L(i)$:

$$L_i = \frac{1}{|s_i|} \sum_{j \in s_i} Y(j), \quad M_L(i) = \frac{2L_r(i)L_d(i) + T_1}{L_r^2(i) + L_d^2(i) + T_1}, \quad (10)$$

gdzie $Y(j)$ jest luminancją piksela j , a $L_r(i)$ i $L_d(i)$ są średnimi luminancjami superpiksela s_i w obrazach referencyjnym i zniekształconym. T_1 jest zmienną dodatnią, aby uniknąć niestabilności równania. Podobne wzory można skonstruować zarówno dla składowej chrominancji U , jak i V :

$$U_i = \frac{1}{|s_i|} \sum_{j \in s_i} U(j), \quad M_U(i) = \frac{2U_r(i)U_d(i) + T_1}{U_r^2(i) + U_d^2(i) + T_1}, \quad (11)$$

$$V_i = \frac{1}{|s_i|} \sum_{j \in s_i} V(j), \quad M_V(i) = \frac{2V_r(i)V_d(i) + T_1}{V_r^2(i) + V_d^2(i) + T_1}. \quad (12)$$

Następnie można wyznaczyć podobieństwo chrominancji M_C w następujący sposób:

$$M_C(i) = M_U(i)M_V(i). \quad (13)$$

Wzór podobny do powyższego opisuje gradient podobieństwa M_G :

$$M_G(i) = \frac{2G_r(i)G_d(i) + T_2}{G_r^2(i) + G_d^2(i) + T_2}, \quad (14)$$

gdzie wielkość gradientu G składa się z dwóch składowych wyznaczonych za pomocą prostego operatora Prewitta, a T_1 , T_2 są stałymi dobranymi przez autorów. Dalsze szczegóły wyznaczania T_1 i T_2 opisane są w [14]. Wzór na wyznaczenie podobieństwa superpiksela i w obu obrazach można zapisać jako:

$$M(i) = M_G(i) [M_L(i)]^\alpha e^{\beta(M_C(i)-1)}, \quad (15)$$


gdzie α and β definiują wagi dla składowych luminancyjnych i chrominancyjnych. Ostatecznie indeks SPSIM jest sumą ważoną $M(i)$ i wag, które są obliczane przy użyciu złożoności tekstury TC , opisanej jako odchylenie standardowe std i kurtoza $Kurt$ superpiksela:

$$TC_r(i) = \frac{std(S_r(i))}{Kurt[S_r(i)] + 3}, \quad TC_d(i) = \frac{std(S_d(i))}{Kurt[S_d(i)] + 3}, \quad (16)$$


$$w(i) = \exp(0.05 \cdot \text{abs}(TC_d(i) - TC_r(i))), \quad (17)$$

$$SPSIM = \frac{\sum_{i=1}^N M(i)w(i)}{\sum_{i=1}^N w(i)}, \quad (18)$$

gdzie: $S_r(i)$, $S_d(i)$ są superpikselami w obrazach referencyjnym i zniekształconym zawierającymi i – ty piksel.



Rys. 2. Mapy podobieństwa SPSIM (100 superpikseli): (a) obraz referencyjny, (b) obraz zniekształcony, (c) mapa podobieństwa dla luminancji, (d) mapa podobieństwa dla chrominancji, (e) mapa podobieństwa dla gradientu.



Rys. 3. Mapy podobieństwa SPSIM (400 superpikseli): (a) obraz referencyjny, (b) obraz zniekształcony, (c) mapa podobieństwa dla luminancji, (d) mapa podobieństwa dla chrominancji, (e) mapa podobieństwa dla gradientu.

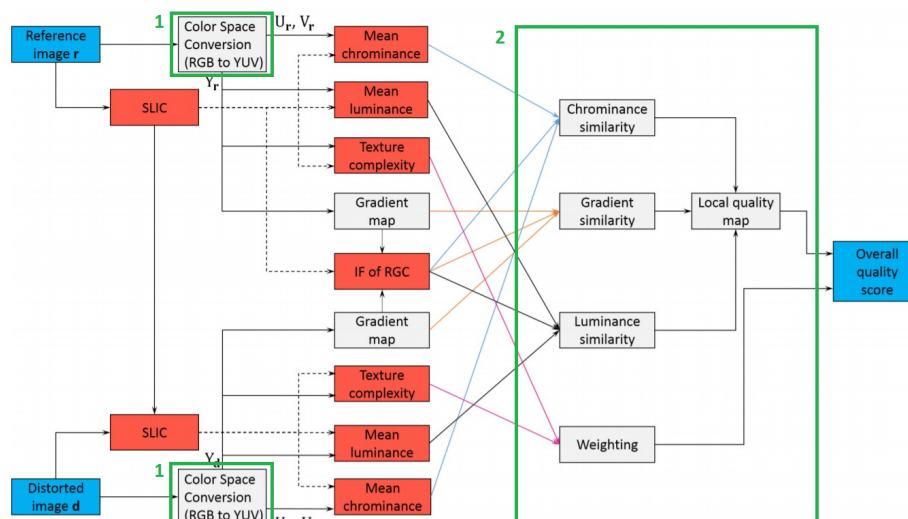
Na rysunkach 2 i 3 przedstawiono lokalne mapy podobieństwa dla dwóch rozdzielczości superpikselowych: 100 i 400. Na obrazach widać, że w przypadku większej liczby superpikseli lokalne mapy podobieństwa są bardziej szczegółowe. Jednak dalsze zwiększanie liczby superpikseli powoduje znaczne wydłużenie czasu obliczeń indeksu SPSIM.

Dobre wyniki uzyskane przy użyciu wskaźnika SPSIM pokazują, że superpiksele odpowiednio odzwierciedlają działanie ludzkiego systemu wzrokowego i nadają się do przetwarzania obrazów.

3. Proponowane modyfikacje SPSIM

W 2013 roku [3] zaproponowano modyfikację wskaźnika SSIM, obejmującą analizę utraty kolorów w oparciu o przestrzeń barw reprezentującą informację o kolorze lepiej niż klasyczna przestrzeń RGB. Przeprowadzono badania mające na celu określenie, która przestrzeń barw najlepiej reprezentuje zmiany chromatyczne w obrazie. Dokonano porównania wyników uzyskanych przez modyfikację indeksu przy użyciu przestrzeni barw YCbCr, HSI, YIQ, YUV i CIELab. Spośród analizowanych przestrzeni barw najlepszą zbieżność z oceną subiektywną wykazano dla miary jakości opartej na przestrzeni YCbCr.

Składowa Y reprezentuje luminancję obrazu, natomiast składowe C_b i C_r reprezentują chrominancję. Wysoka zbieżność kolorowej wersji indeksu SSIM wykorzystującej przestrzeń barw YCbCr z subiektywną oceną pozwala przypuszczać, że zastosowanie tej przestrzeni barw do innych indeksów IQA powinno również poprawić skuteczność predykcyjną oceny jakości obrazu. Dlatego też możliwa jest zmiana algorytmu



Rys. 4. Schemat blokowy wskaźnika SPSIM z zaznaczonymi propozycjami modyfikacji (zielone pola)

indeksu SPSIM poprzez zastąpienie wykorzystywanej w nim przestrzeni YUV przestrzenią YCbCr, przy zachowaniu pozostałych kroków algorytmu bez zmian.

Inną propozycją poprawy oceny jakości obrazu za pomocą indeksu SPSIM jest wykorzystanie zalet opisanej wcześniej miary jakości MDSI. Zarówno w przypadku miary SPSIM, jak i MDSI, do wyznaczania ich wartości wykorzystuje się lokalne podobieństwo chrominancji i struktury obrazu. Obie te składowe różnią się dla każdego z indeksów. W przypadku indeksu SPSIM podobieństwo chrominancji dla każdego z dwóch kanałów jest obliczane osobno, natomiast w przypadku indeksu MDSI podobieństwo chrominancji jest obliczane jednocześnie. Podobnie, w przypadku podobieństwa strukturalnego, indeks MDSI dodatkowo uwzględnia mapę wartości gradientu dla połączonych kanałów luminancji, podczas gdy mapa lokalnych podobieństw strukturalnych w SPSIM jest obliczana dla każdego obrazu osobno. Dlatego druga propozycja modyfikacji indeksu SPSIM polega na wyznaczeniu lokalnych map podobieństwa chrominancji i struktury obrazu w oparciu o podejście znane z indeksu MDSI. W ramach tego podejścia zastosowano połączenie dwóch metod: SPSIM i MDSI.

Obie zaproponowane powyżej modyfikacje algorytmu SPSIM zostały osobno zaimplementowane i porównane z innymi miarami jakości. Implementacja nowej przestrzeni barw była dosyć prosta (dwa pola oznaczone na rysunku 4 jako 1) i sprowadzała się do prostej zamiany wzorów przekształcających z RGB na proponowaną przestrzeń barw.

Implementacja drugiej modyfikacji wymagała wykorzystania elementów kodu MDSI opisującego budowę map podobieństwa chrominancji i map podobieństwa strukturalnego (pole 2 na rysunku 4). Szczegóły implementacji można znaleźć w pracy poświęconej MDSI [8]. Ponadto, zaimplementowano również rozwiązanie łączące obie proponowane modyfikacje SPSIM. Podsumowując, rozważymy trzy modyfikacje SPSIM: pierwszą ograniczającą się do zmiany przestrzeni barw i oznaczoną dalej jako SPSIM(YCbCr), drugą działającą w przestrzeni barw YUV, ale wykorzystującą elementy MDSI i oznaczoną jako SPSIM (MDSI) oraz trzecią łączącą dwie poprzednie modyfikacje SPSIM i oznaczoną jako SPSIM (YCbCr_MDSI). Skuteczność powstałych w ten

Tabela 1

Porównanie obrazowych baz danych wykorzystywanych w ocenie obrazów IQA

Database Name	No. of Original Images	No. of Distortion Types	Ratings per Image	Environment	No. of Distorted Images
LIVE	29	5	23	lab	779
TID2008	25	17	33	lab	1700
CSIQ	30	6	5~7	lab	866
TID2013	25	24	9	lab	3000
KADID-10k	81	25	30	crowdsourcing	10125

sposób modyfikacji SPSIM jest przedstawiona w następnym rozdziale.

4. Eksperymenty obliczeniowe

Eksperymenty obliczeniowe przeprowadzono na pięciu obrazowych bazach danych: LIVE (2006) [12], TID2008 [10], CSIQ (2010) [4], TID2013 [9], i KADID-10k [5]. W tabeli 1 przedstawiono podstawowe informacje o wybranych bazach obrazów. Nowością dla bazy KADID-10k było wykorzystanie *crowdsourcingu* do subiektywnej oceny jakości obrazu.

Tabele 2 i 3 zawierają wartości współczynników korelacji Pearsona oraz błędy RMSE dla badanych miar IQA. W każdej kolumnie tabeli trzy najlepsze wyniki są zaznaczone pogrubioną czcionką. Dwie prawe kolumny zawierają średnie arytmetyczne i średnie ważone wartości w odniesieniu do liczby obrazów w każdej bazie danych. Biorąc pod uwagę średnie ważone obliczonych współczynników korelacji i błędów RMSE, można zauważyć, że modyfikacje indeksu SPSIM dają bardzo dobre wyniki. Dla indeksu SPSIM i jego trzech modyfikacji przyjęto liczbę superpikseli równą 400.

Dobre wyniki uzyskane dla SPSIM i jego modyfikacji dotyczą głównie obrazów z baz TID2008 i TID2013. Współczynniki korelacji obliczone dla baz CSIQ i LIVE nie są tak jednoznaczne. Duża liczba obrazów zawartych w bazach TID pozwala na wiarygodne przeniesienie tych dobrych wyników w postaci średnich ważonych.

Pomiary wydajności analizowanych nowych miar jakości przeprowadzono na komputerze PC z procesorem Intel Core i5-7200U 2,5 GHz i 12 GB pamięci RAM. Skrypty obliczeniowe wykonano przy użyciu platformy Matlab R2019b. Dla każdego obrazu ze zbioru TID2013 zmierzono czas obliczeniowy każdego indeksu jakości. Wydajność indeksu była mierzona jako średni czas oceny jakości obrazu. W tabeli 4 przedstawiono średnie czasy obliczeń dla wybranych miar IQA. Modyfikacje SPSIM spowodowały jedynie kilkuprocentowy wzrost czasu obliczeń w porównaniu z oryginalnym SPSIM.

Do dodatkowych testów indeksu SPSIM z różnymi liczbami superpikseli (od 100 do 4000) wykorzystano bazę danych IQA KADID-10k (Konstanz Artificially Distorted Image quality Database). KADID-10k zawiera ponad 10 000 obrazów wraz z subiektywnymi ocenami ich jakości (MOS). Uzyskane wyniki przedstawiono w tabeli 5. Najlepsze wyniki dla danej liczby superpikseli są wyróżnione pogrubioną czcionką. W każdym przypadku najlepsze wyniki uzyskano dla modyfikacji SPSIM opartej na połączeniu zmiany przestrzeni barw na YCbCr i zastosowania map podobieństwa używanych w MDSI. Zwiększenie liczby superpikseli poprawia wartości wszystkich czterech indeksów. Dodatkowo dla pary obrazów przedstawionych na Rys. 2 i 3 sprawdzono wpływ liczby superpikseli na czas obliczeń dla indeksu SPSIM (YCbCr). Zmiana liczby superpikseli ze 100 do 4000 spowodowała wydłużenie czasu obliczeń (6,14 razy). Wy-

Tabela 2

Porównanie współczynników korelacji liniowej Pearsona (PLCC) dla wybranych wskaźników IQA.

	CSIQ	LIVE	TID2008	TID2013	\overline{PLCC}	\overline{PLCC}_w
PSNR	0.7857	0.8682	0.5405	0.6788	0.7183	0.6796
SSIM	0.8579	0.9212	0.6803	0.7459	0.8013	0.7651
FSIMc	0.9191	0.9613	0.8762	0.8769	0.9084	0.8928
GMSD	0.9541	0.9603	0.8788	0.8590	0.9131	0.8897
VSI	0.9279	0.9482	0.8762	0.9000	0.9131	0.9033
MDSI	0.9531	0.9659	0.9160	0.9085	0.9359	0.9236
PSIM	0.9642	0.9584	0.9077	0.9080	0.9346	0.9218
VCGS	0.9301	0.9509	0.8776	0.9000	0.9147	0.9044
SPSIM	0.9335	0.9576	0.8927	0.9090	0.9232	0.9139
SPSIM (YCbCr)	0.9346	0.9564	0.8946	0.9099	0.9238	0.9148
SPSIM (MDSI)	0.9327	0.9592	0.9049	0.9165	0.9283	0.9208
SPSIM (YCbCr_MDSI)	0.9334	0.9583	0.9051	0.9173	0.9285	0.9213

Tabela 3

Porównanie wartości RMSE dla wybranych wskaźników jakości IQA.

	CSIQ	LIVE	TID2008	TID2013	\overline{RMSE}	\overline{RMSE}_w
PSNR	0.1624	13.5582	1.1290	0.9103	3.9400	2.4196
SSIM	0.1349	10.6320	0.9836	0.8256	3.1440	1.9776
FSIMc	0.1034	7.5296	0.6468	0.5959	2.2189	1.3936
GMSD	0.0786	7.6214	0.6404	0.6346	2.2437	1.5080
VSI	0.0979	8.6817	0.6466	0.5404	2.4916	1.4181
MDSI	0.0795	7.0790	0.5383	0.5181	2.0537	1.4792
PSIM	0.0696	7.7942	0.5632	0.5193	2.2366	1.2470
VCGS	0.0964	8.4557	0.6433	0.5404	2.4339	1.3855
SPSIM	0.0942	7.8711	0.6047	0.5167	2.2717	1.3629
SPSIM (YCbCr)	0.0934	7.9766	0.5996	0.5143	2.2960	1.3959
SPSIM (MDSI)	0.0947	7.7210	0.5712	0.4958	2.2207	1.3483
SPSIM (YCbCr_MDSI)	0.0942	7.8048	0.5705	0.4935	2.2407	1.3573

bór liczby superpikseli musi być kompromisem między czasem obliczeń a wartościami indeksu wyrażającymi poziom korelacji z punktacją MOS. Pozostałe eksperymenty obliczeniowe przeprowadzane w ramach niniejszej pracy oraz uzyskane wyniki zostały przedstawione w artykule [1].

5. Podsumowanie

W artykule wykazano, że proste modyfikacje SPSIM (zmiana przestrzeni barw, różne sposoby definiowania map podobieństwa inspirowane indeksem MDSI) prowadzą

Czas obliczeń dla nowych miar jakości.

IQA index	\overline{time} (ms)
MDSI	2.14
PSIM	5.33
VCGS	47.68
SPSIM	16.07
SPSIM (YCbCr)	16.80
SPSIM (MDSI)	15.86
SPSIM (YCbCr_MDSI)	17.44

Tabela 4

Tabela 5

Wpływ liczby superpikseli na wartości: SROCC, KROCC, PLCC i RMSE.

	SROCC	KROCC	PLCC	RMSE
No. of SP: 100				
SPSIM	0.8672	0.6782	0.8675	0.5386
SPSIM (YCbCr)	0.8674	0.6788	0.8675	0.5385
SPSIM (MDSI)	0.8705	0.6827	0.8696	0.5346
SPSIM (YCbCr_MDSI)	0.8709	0.6836	0.8698	0.5342
No. of SP: 4000				
SPSIM	0.8759	0.6908	0.8751	0.5239
SPSIM (YCbCr)	0.8769	0.6923	0.8760	0.5222
SPSIM (MDSI)	0.8797	0.6959	0.8778	0.5186
SPSIM (YCbCr_MDSI)	0.8807	0.6974	0.8787	0.5168

do poprawy korelacji z oceną MOS. O ile zmiana przestrzeni barw nieznacznie poprawia te korelacje, o tyle inny sposób definiowania map podobieństwa poprawia je bardziej. Kombinacja obu modyfikacji oznaczona jako SPSIM (YCbCr_MDSI) daje najlepsze wyniki. Wartości uzyskane przez zmodyfikowane indeksy jakości SPSIM wskazują, że istnieje możliwość ich poprawy w ramach przyszytych badań nad metodami FR-IQA.

Podziękowania

Praca powstała przy wsparciu finansowym Ministerstwa Edukacji i Nauki dla Politechniki Śląskiej w ramach grantów badawczych: 02/010/BK-19/0143 oraz 02/070/BK_22/0035.

LITERATURA

1. Frackiewicz, M., Szolc, G., and Palus, H. An improved SPSIM index for image quality assessment. *Symmetry* 13, 3 (2021), 518.
2. Gu, K., Li, L., Lu, H., Min, X., and Lin, W. A fast reliable image quality predictor by fusing micro- and macro-structures. *IEEE Transactions on Industrial Electronics* 64, 5 (2017), 3903–3912.
3. Jadhav, M., Dandawate, Y., and Pisharoty, N. Performance evaluation of structural similarity index metric in different color spaces for HVS based assessment of quality of colour images. *International Journal of Engineering and Technology* 5, 2 (2013), 1555–1562.
4. Larson, E., and Chandler, D. Most apparent distortion: full-reference image quality assessment and the role of strategy. *Journal of Electronic Imaging* 19, 1 (2010), 011006.
5. Lin, H., Hosu, V., and Saupe, D. Kadid-10k: A large-scale artificially distorted iqa database. In *2019 Eleventh International Conference on Quality of Multimedia Experience (QoMEX) (2019)*, IEEE, pp. 1–3.
6. Liu, A., Lin, W., and Narwaria, M. Image quality assessment based on gradient similarity. *IEEE Transactions on Image Processing* 21, 4 (2011), 1500–1512.

7. Nadenau, M., Winkler, S., Alleysson, D., and Kunt, M. Human vision models for perceptually optimized image processing—a review. *Proceedings of the IEEE* 32 (2000), 1–15.
8. Nafchi, H. Z., Shahkolaei, A., Hedjam, R., and Cheriet, M. Mean deviation similarity index: Efficient and reliable full-reference image quality evaluator. *IEEE Access* 4 (2016), 5579–5590.
9. Ponomarenko, N., Jin, L., Ieremeiev, O., and Lukin, V. e. a. Image database TID2013: Peculiarities, results and perspectives. *Signal Processing: Image Communication* 30 (2015), 57–77.
10. Ponomarenko, N., Lukin, V., Zelensky, A., Egiazarian, K., Carli, M., and Battisti, F. TID2008- a database for evaluation of full-reference visual quality assessment metrics. *Advances of Modern Radioelectronics* 10, 4 (2009), 30–45.
11. Ren, X., and Malik, J. Learning a classification model for segmentation. In *Proc. IEEE Int. conf. on Comp.Vis.* (2003), vol. 1, IEEE, pp. 10–17.
12. Sheikh, H., Sabir, M., and Bovik, A. A statistical evaluation of recent full reference image quality assessment algorithms. *IEEE Transactions on Image Processing* 15, 11 (2006), 3440–3451.
13. Shi, C., and Lin, Y. Full reference image quality assessment based on visual salience with color appearance and gradient similarity. *IEEE Access* 8 (2020), 97310–97320.
14. Sun, W., Liao, Q., Xue, J.-H., and Zhou, F. SPSIM: A superpixel-based similarity index for full-reference image quality assessment. *IEEE Transactions on Image Processing* 27, 9 (2018), 4232–4244.
15. Wang, Z., Bovik, A., Sheikh, H., and Simoncelli, E. Image quality assessment: from error visibility to structural similarity. *IEEE Transactions on Image Processing* 13, 4 (2004), 600–612.
16. Xue, W., Zhang, L., Mou, X., and Bovik, A. C. Gradient magnitude similarity deviation: A highly efficient perceptual image quality index. *IEEE Transactions on Image Processing* 23, 2 (2013), 684–695.
17. Zhang, L., Shen, Y., and Li, H. VSI: A visual saliency-induced index for perceptual image quality assessment. *IEEE Transactions on Image Processing* 23, 10 (2014), 4270–4281.
18. Zhang, L., Zhang, L., Mou, X., and Zhang, D. FSIM: A feature similarity index for image quality assessment. *IEEE Transactions on Image Processing* 20, 8 (2011), 2378–2386.