

Tomasz Szymczyk*

Metoda dopasowania wzorców w rozpoznawaniu obrazów – ograniczenia, problemy i modyfikacje metody

1. Wprowadzenie

1.1. Postrzeganie a rozpoznawanie obrazów

Problem rozpoznawania obrazów przez człowieka jest zagadnieniem niezwykle złożonym. W ogromnym uproszczeniu proces rozpoznawania treści wizyjnej można przedstawić następująco. Patrząc na dany obraz nasz wzrok jest tylko trójwymiarowym receptorem obrazu statycznego bądź dynamicznego. Zarejestrowany przez ludzkie oko obraz kierowany jest do mózgu. Tam porównywany jest z szeregiem zapamiętanych i wyuczonych czynników. Wszystko co widzimy, możemy nazwać i określić, jeżeli już tego doświadczyliśmy wcześniej. Rozpoznawanie „nieznanego” to proces znacznie bardziej złożony. Do akwizycji obrazu i „bazy wiedzy” o obrazach należy dodać bardzo rozległą wiedzę, między innymi z dziedzin takich jak: fizyka, kinematyka, chemia, psychologia itd., a także informacje płynące z innych receptorów niż wzrok: słuchu, węchu, dotyku. Widząc płonąca zapalke czy palący się palnik acetylenowy pomimo, że wyglądz płomienia w każdym z tych przypadków różni się, podświadomie wiemy, że dotknięcie jednego czy drugiego gołą ręką wywoła nieprzyjemne następstwa. Ten prozaiczny przykład ilustruje, jak funkcjonuje rozumienie otaczającej nas rzeczywistości. Rozpoznawanie tekstur rządzi się dokładnie takimi samymi prawami. Tekstura, faktura materiału może różnić się od siebie, pomimo iż stanowi jedną całość konkretnego elementu. Tekstura wygenerowana automatycznie z wykorzystaniem matematycznego wzoru znacznie różni się od losowo stworzonej tekstury. Ten drugi rodzaj to naturalne tekstury [4]. Przyroda pozornie tylko powiela pewne elementy, w praktyce są one praktycznie niepowtarzalne [5]. Tekstury takie to fragmenty rafy koralowej, słoje i sęki w drewnie czy usypany kopiec jabłek. Stopień powtarzalności tekstury jest odwrotnie proporcjonalny do poziomu szczegółowości. Im większe wykonamy zbliżenie na teksturę, tym więcej szczegółów zauważymy, ale znacząco zmaleje powtarzalność wzoru (dla takiej

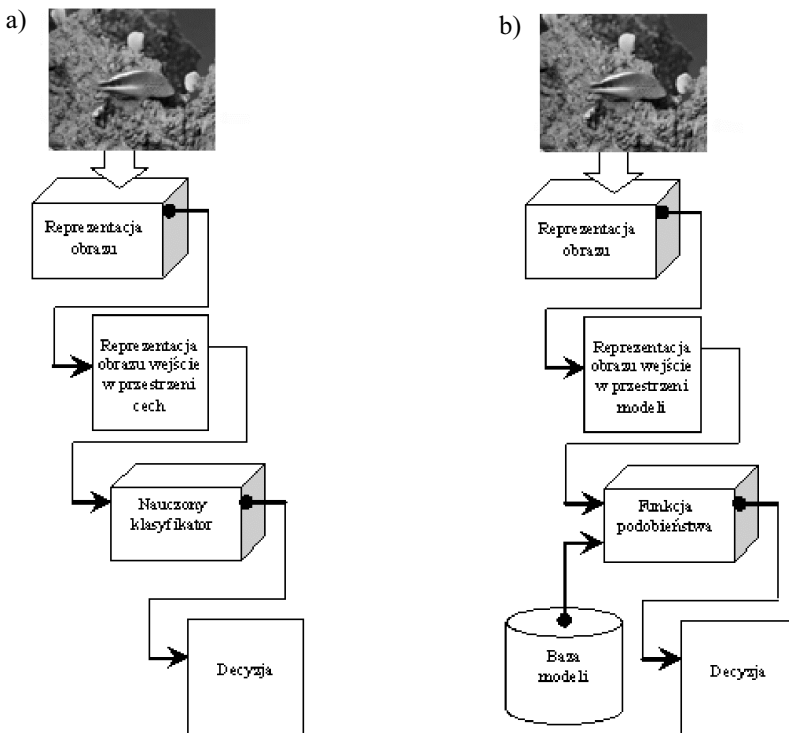
* Wydział Elektrotechniki i Informatyki, Instytut Informatyki, Politechnika Lubelska w Lublinie

samej ilości obrazu). Pomimo ogromnego skomplikowania procesu rozpoznawania obrazów, bardzo wiele dziedzin życia zaadaptowało już systemy wspomagające tę czynność. Należy tutaj wspomnieć nie tylko przemysł, który powszechnie wykorzystuje defektoskopię, wspomaganie automatycznego zliczania drobnych elementów, ale także coraz odważniejsze zastosowania w medycynie [7]. Rozpoznawanie i analiza obrazów otacza nas wsząd: inteligentne sterowanie światłami na drodze, automatyczne odczytywanie kodów kreskowych czy adresu z korespondencji.

1.2. Rozpoznawanie obrazów

Proces rozpoznawania obrazów można podzielić ze względu na sposób wnioskowania. Wyróżnia się następujące podejścia:

- Rozpoznawanie oparte na cechach (*feature-based*); ogólny schemat przedstawiono na rysunku 1a.
- Rozpoznawanie oparte na modelu (*model-based*); ogólny schemat przedstawiono na rysunku 1b.



Rys. 1. Ogólny schemat rozpoznawania obrazów ze względu na sposób wnioskowania:
a) wnioskowanie oparte na cechach; b) wnioskowanie oparte na modelu

W podejściu pierwszym tworzona jest reprezentacja obrazu dostosowana do potrzeb i możliwości klasyfikatora. Analiza zawartości obrazu odbywa się w przestrzeni cech. W podejściu drugim konieczne jest utworzenie „repozytorium obiektów” (baza modeli), z którym nastąpi porównanie obrazu badanego. Wykorzystanie metody dopasowania wzorców (*template matching*) może być pomocne w rozpoznawaniu i interpretacji obrazu [1]. Metoda dopasowania szablonów polega na rozpoznawaniu badanej sceny na podstawie porównania ze wzorcem [6] Wynikiem jest funkcja celu, którą należy później poddać odpowiedniej interpretacji. Tę właśnie koncepcję autor rozwinie w tym artykule. Baza wiedzy może zawierać albo obrazy – plik graficzny albo jednoznaczną reprezentację obrazu – deskryptor.

1.3. Baza wzorców

W celu rozpoznawania obrazu bazującego na modelu należy w pierwszej kolejności stworzyć bazę modeli. Repozytorium wiedzy powinno zawierać wszystkie możliwe obrazy z jakimi będzie miał do czynienia system badający. Obrazy wzorcowe należy pogrupować według konkretnych cech badanego obiektu, a następnie zgrupować w odpowiednie klasy. W czasie trwania procesu rozpoznawania w pierwszej kolejności będą wybierane klasy obrazów, a następnie z pomocą metody dopasowania wzorców konkretne obrazy. Takie podejście ma za zadanie zmniejszyć liczbę porównań obraz badany – wzorec. Wadą i poważnym ograniczeniem przedstawionej koncepcji jest fakt, że nie można zastosować jej do rozpoznawania dowolnych obrazów. Baza wiedzy musiałaby zawierać ogromne ilości obrazów. Pomimo pogrupowania obrazów w klasy i uprzedniej preselekcji w obrębie klas, proces porównania byłby niesłychanie długi (porównanie obrazu badanego z każdym z wręcz nieskończonej ilości wzorców). Koncepcja rozpoznawania bazująca na modelu wymusza niejako stosowanie jej do skończonej liczby rozwiązań. W artykule zaprezentowano przykład systemu automatycznej detekcji konkretnej tekstury i przedstawiono proces tworzenia bazy wiedzy właśnie dla takiego systemu.

2. Praktyczne rozpoznawanie wykorzystujące metodę dopasowania wzorców

2.1. Opis metody TM

Wykorzystując metodę *template matching* do wyszukania położenia konkretnego szczegółu w obrazie badanym zakłada się istnienie dwóch macierzy [2, 9]. Pierwsza z nich to macierz wzorca $g[i, j]$, która powstaje poprzez zapisanie obrazu wzorca w postaci cyfrowej. Druga macierz $f[i, j]$ to cyfrowe odwzorowanie obrazu badanego. Wyszukanie odbywa się przez porównywanie wartości intensywności w szablonie z odpowiednimi wartościami w obrazie [6]. Bardzo rzadkim przypadkiem jest idealne pasowanie do siebie wzorca

i obrazu. Wymagane jest więc zdefiniowanie jakości podobieństwa. Poniżej przedstawiono definicje kilku miar:

$$\max_{[i, j] \in R} |f - g| \quad (1)$$

$$\sum_{[i, j] \in R} |f - g| \quad (2)$$

$$\sum_{[i, j] \in R} |f - g|^2 \quad (3)$$

gdzie R – region szablonu (wzorca).

Najpopularniejszą miarą jest miara sumy kwadratów błędów. W przypadku dopasowywania szablonów, ta miara może zostać obliczona pośrednio i w celu obniżenia kosztów metody można przekształcić ją następująco [1]

$$\sum_{[i, j] \in R} |f - g|^2 = \sum_{[i, j] \in R} f^2 + \sum_{[i, j] \in R} g^2 - 2 \sum_{[i, j] \in R} fg \quad (4)$$

Jeśli przyjmujemy, że f i g są skorelowane, wtedy wzór (4) jest miarą dopasowania. Należy teraz obliczyć miary dopasowania w każdym punkcie obrazu badanego. Metoda taka wymaga liniowego przesuwania wzorca po głównym obrazie i obliczenia miary dopasowania w każdym punkcie. W ten sposób dla szablonu o rozmiarze m na n obliczamy

$$M_{fg}[i, j] = \sum_{k=1}^m \sum_{l=1}^n g[k, l] f[i+k, j+l] \quad (5)$$

gdzie k i l – przesunięcia szablonu na obrazie.

Ta operacja jest zwana korelacją krzyżową między f i g .

Celem metody jest znalezienie miejsc zawierających maksima funkcji zdefiniowanej wzorem (5). Należy także założyć istnienie pewnej wartości będącej wartością progową. Miejsca dobrego dopasowania będą to takie obszary, w których występują wartości większe od progu tolerancji (poziom podobieństwa).

W przypadku zastosowania obliczenia funkcji M do obrazów, wartości szablonu g są stałe, ale wartości f będą się zmieniały. Wartość M zależy wtedy od wartości f i nie zawsze daje poprawny wynik dopasowania w różnych miejscach. Ten problem należy rozwiązać poprzez obliczenie znormalizowanej korelacji krzyżowej. Miarę dopasowania M można wtedy obliczyć, używając wzorów (6) i (7).

$$C_{fg}[i, j] = \sum_{k=1}^m \sum_{l=1}^n g[k, l] f[i+k, j+l] \quad (6)$$

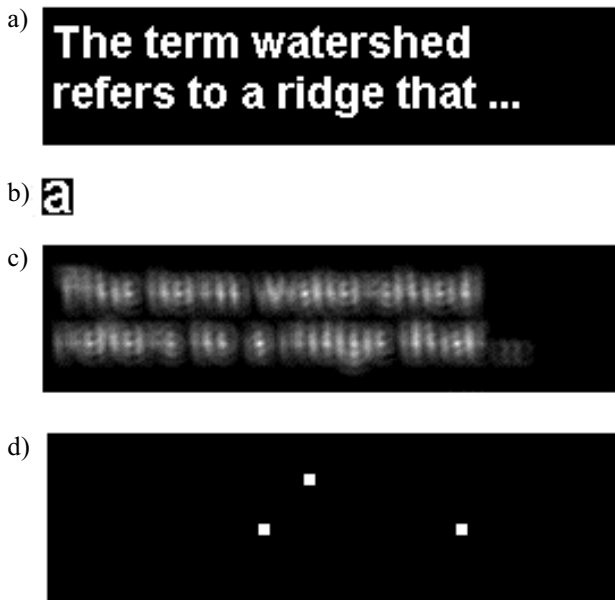
$$M[i, j] = \frac{C_{fg}[i, j]}{\sqrt{\sum_{k=1}^m \sum_{l=1}^n f^2[i+k, j+l]}} \quad (7)$$

Wykazano, że M daje maksymalną wartość w punkcie o współrzędnych i, j dla każdego $g = cf$. Należy wspomnieć, że powyższe obliczenia upraszczają się znacznie dla obrazów binarnych [3].

2.2. Rozpoznawanie obrazów binarnych

Rozpoznawanie obrazów binarnych jest najprostszym problemem w rozpoznawaniu obrazów. Degradacja obrazu kolorowego do bitowych wartości znacznie przyspiesza i ułatwia działanie metody TM. W rzeczywistości niesie jednak za sobą tak daleko idące zmiany w obrazie badanym, taką utratę cennych informacji, że stosuje się ją w bardzo ograniczonym zakresie (badania biologiczne na komórkach czy rozpoznawanie tekstu).

Na rysunku 2 przedstawiono etapy rozpoznawania tekstu.

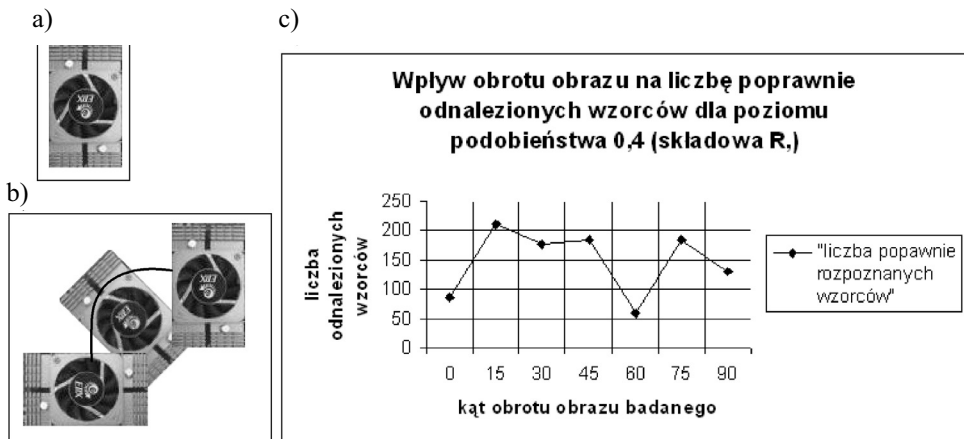


Rys. 2. Przebieg rozpoznawania (odnajdowania) wzorca dla obrazów binarnych: a) obraz badany; b) wyszukiwany wzorec; c) graficzny obraz funkcji dopasowania (korelacji); d) odnalezione położenia wyszukiwanego wzorca – widok po progowaniu

Rozpoznawanie tekstu drukowanego jako kształtu binarnego jest stosunkowo prostym działaniem i daje zadowalające rezultaty.


2.3. Rozpoznawanie obrazów monochromatycznych

Metoda *template matching* jest metodą wrażliwą na podstawowe operacje afiniczne na obrazie. Należą do nich rotacja i skalowanie. Obrazy o jednolitym tle z wyraźnie zarysowanym obrysem badanego obrazu rozpoznaje się najłatwiej. Nawet w przypadku obrotów badanego obiektu wartość funkcji celu będąca wynikiem korelacji obraz badany – wzorzec jest wyraźnie większa od korelacji obraz badany – tło. Na rysunku 3 zaprezentowano wpływ rotacji obrazu badanego na ilość znalezionych dopasowań przy założeniu, że poziom podobieństwa wynosi 40%. Duże wartości (ilości) odnalezionych wzorców na obrazie wynikowym układają się w specyficzną „chmurę” rozwiązań oscylujących wokół dokładnego rozwiązania.



Rys. 3. Wyszukiwany wzorzec (a), kolorowy obraz badany (24 bity) (b), sztucznie stworzony obraz zawierający obiekt badany pod różnymi kątami (c). Charakterystyka przedstawiająca wpływ obrotu obrazu na liczbę poprawnie odnalezionych wzorców dla poziomu podobieństwa 0,4. W badaniu uwzględniono składową czerwoną (R)


Sytuacja diametralnie zmienia się, gdy w obrazie badanym pojawia się tło. Bardzo często wartość korelacji pomiędzy przekształconym (zniekształconym) obrazem badanym a wzorcem jest mniejsza od wartości korelacji z tłem. Takie rozpoznanie spisane jest na niepowodzenie. W obrazach o dużej zawartości informacji z „bogatym tłem” należy za wszelką cenę eliminować tło. W zależności od badanej sceny można to zrobić prostym zestawem filtrów graficznych: rozmycie, a później wyostrenie krawędzi. Usuwamy wysokie częstotliwości z tła (dużą zmienność), które powodują powstawanie ekstremów lokalnych w wartości funkcji korelacji. Następnie wyostrając krawędzie, podkreślamy obecność głównego obiektu, który chcemy zidentyfikować. W uzasadnionych przypadkach należy wyszukać krawędzie i usunąć pozostałe informacje o obrazie, czyli przekształcić go do postaci binarnej. Należy dokładnie takiemu samemu przekształceniu poddać zarówno obraz badany, jak i wzorzec. Przykład takiego działania przedstawiono na rysunku 4.



Rys. 4. Przebieg rozpoznawania (odnajdowania) wzorca dla obrazów monochromatycznych. Przypadek, w którym obraz badany przekształcono do postaci binarnej i w takiej formie został on poddany procesowi dopasowania: a) obraz badany po wyrównaniu histogramu i odpowiadający mu obraz binarny; b) wyszukiwany wzorec i jego binarny odpowiednik; c) graficzny obraz funkcji dopasowania (korelacji) ekstrema lokalne i wyraźnie widoczne ekstrema globalne będące dokładną lokalizacją szukanego obrazu; opracowanie własne (wynik działania metody)

2.4. Rozpoznawanie obrazów kolorowych RGB

Obrazy kolorowe potraktowano jako superpozycję trzech obrazów monochromatycznych. Rozpoznawanie odbywało się w sposób następujący: z obrazu badanego i wzorca wybierano jedną składową barwną – tę samą dla obu. Następnie obliczano korelację. Rozpoznawanie na tak postawionych warunkach nie różniło się znacząco od rozpoznawania obrazów monochromatycznych. Zaobserwowano silny wpływ składowej barwnej na otrzymane wyniki. Wyjątkowo silną zależność otrzymano przy badaniu obrazów morskich (rys. 5).



Rys. 5. Wynik rozpoznawania w kolorowym obrazie RGB. Wyróżnionym kolorem zaznaczono miejsca odnalezienia tekstury rafy koralowej: a) obraz badany (600×600 pikseli, 24 bity kolor); b) wzorec (30×30 pikseli, 24 bity kolor) (widok powiększony); c) wynik rozpoznawania dla składowej czerwonej (R), wyróżniona kolorem jasnoszarym; d) wynik rozpoznawania dla składowej zielonej (G), wyróżniona kolorem jasnoszarym; e) wynik rozpoznawania dla składowej niebieskiej (B), wyróżniona kolorem jasnoszarym


Wyszukiwanie tekstury rafy koralowej dla składowej czerwonej i zielonej (R i G) dało zadowalające i podobne wyniki. Składowa niebieska (B), która w minimalnym stopniu występuje w teksturze rafy koralowej została zgodnie z oczekiwaniami odnaleziona w toni wodnej. Wyniki przedstawiono na rysunku 5. Niemożliwe było więc połączenie wyników wyszukiwania wykonanych dla trzech składowych.

3. Problem badawczy

3.1. Modyfikacja działania metody *template matching*

Zadanie badawcze polegało na odnalezieniu obszaru roboczego wewnątrz burty naczepy. Należało wyznaczyć obszar występowania płodów rolnych – czyli obszar o określonej teksturze (rys. 6).


W celu poprawy działania metody wyszukiwania zaproponowano wykorzystanie gradientu morfologicznego. Usuwa on znaczną część informacji z obrazu, ale działa znacznie „łagodniej” od procesu binaryzacji (rys. 6).




Rys. 6. Kolorowy obraz z kamery przemysłowej wykonany w rozdzielczości: 704×576×24 bity:
 a) obraz oryginalny; b) fragment obrazu przekształcony do postaci binarnej;
 c) fragment obrazu przekształcony z wykorzystaniem gradientu morfologicznego

Operacja gradientu morfologicznego polega na wykonaniu sekwencji następujących operacji. Jako pierwsza wykonywana jest operacja dylatacji elementem strukturalnym SE na obrazie wejściowym. Operacja dylatacji może być rozumiana jest jako filtr maksymalny,

a następnie na obrazie wejściowym wykonywana jest operacja erozji (filtr minimalny) z udziałem tego samego elementu strukturalnego. Kolejnym etapem jest odjęcie od siebie uzyskanych obrazów. W literaturze można spotkać także inny opis działania gradientu morfologicznego [8], którego przebieg przedstawiono na rysunku 8. Wykorzystano w nim element strukturalny pokazany na rysunku 7b.



Rys. 7. Elementy strukturalne o promieniu jednostkowym: a) element SE oparty na siatce heksagonalnej; b) element SE oparty na siatce kwadratowej



Rys. 8. Kolejne etapy przekształcenia obrazu L gradientem morfologicznym SE o rozmiarze 3: a) obraz wejściowy – L; b) dylatacja obrazu L elementem strukturalnym SE 3×3 – D(L, SE); c) obraz wynikowy D(L, SE) – L – różnica obrazu po dylacji i obrazu wejściowego


Dla przypadku dyskretnego działanie gradientu morfologicznego zdefiniowane jest poniższym wzorem

$$\text{grad}(L, SE) = \frac{1}{2} [(L \oplus SE) - (L \ominus SE)] = \frac{1}{2} \left(\max_{SE} (L) - \min_{SE} (L) \right) \quad (8)$$

Jak wykazały badania, w przypadku badania tekstury gradient bardzo silnie uwydatnia jej strukturę. Rozpoznawanie odbywa się w obrębie zarówno jednej składowej barwnej, jak i poprzednio identycznemu przekształceniu gradientowemu podlega para obraz-wzorec. Seria badań empirycznych potwierdziła fakt małej wrażliwości wpływu składowych R, G, B na finalną jakość rozpoznawania. Przedstawiono to na rysunku 10. Niewielkie różnice

jakie zaobserwowano wynikają z dużej aberracji chromatycznej zarejestrowanego obrazu. Obrazem badanym był obraz z kamery przemysłowej przedstawiony na rysunku 6.


Wybrano losowo sześć tekstur o przypadkowym wymiarze 64×64 piksele i stworzono z nich „bazę wiedzy”. Należy przypomnieć, że obszar roboczy to tekstura o całkowicie losowej zmienności i ziarnistości (rys. 9). Następnie bazując na tych wzorcach, wyszukiwano obszar roboczy w różnych przykładowych obrazach. Obrazy różniły się między innymi kształtem naczepy, liczbą obszarów roboczych (naczepa z przyczepą), a także niewielką różnicą w jasności (zachmurzony dzień).



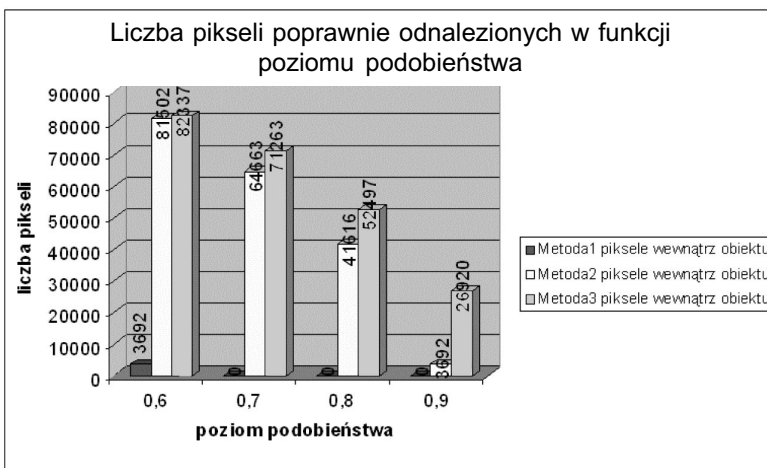
Rys. 9. Tworzenie bazy wzorców

Zaprezentowano wyniki działania trzech metod. Metoda pierwsza wykorzystuje niezmodyfikowaną metodę TM (*template matching*). W metodzie drugiej obraz badany i wzorzec przed porównaniem z wykorzystaniem metody TM poddano przekształceniu graficznemu. Przekształcenie polega na zastosowaniu gradientu morfologicznego o elemencie strukturalnym $SE = 3$. W metodzie trzeciej poddano przekształceniu za pomocą gradientu morfologicznego o $SE = 3$ tylko obraz. Oczywiście jest rzeczą, że istnieje jeszcze kolejna wariacja tej metody polegająca na filtracji gradientowej tylko wzorca. Metoda ta jednak nie dała żadnych pozytywnych rezultatów dla poprawnego odnajdowania wzorca i nie została umieszczona w tej publikacji. Zaprezentowane na rysunkach 10 i 11 wyniki dotyczyły badania obrazu z rysunku 9 i wzorca T1 (rys. 9). Najlepsze rezultaty otrzymano dla poziomu podobieństwa pomiędzy wzorcem a obrazem dla wartości z zakresu od 0,6 do 0,9. Wartości

poniżej 60% uznano za przypadkowe i mało użyteczne w przemysłowych systemach rozpoznawania. Na rysunku 10 zaprezentowano błędne wyniki odnajdowania obszaru roboczego – poza burta, stanowiącą obszar poszukiwany.




Rys. 10. Zestawienie wyników wyszukiwania tekstury dla trzech metod. Piksele błędnie rozpoznane



Rys. 11. Zestawienie wyników wyszukiwania tekstury dla trzech metod. Piksele poprawnie rozpoznane

Po analizie rysunku 10 i 11 wyraźnie zauważalna jest przewaga metody 2 i metody 3 nad zwykłą metodą dopasowania wzorców (metoda 1).

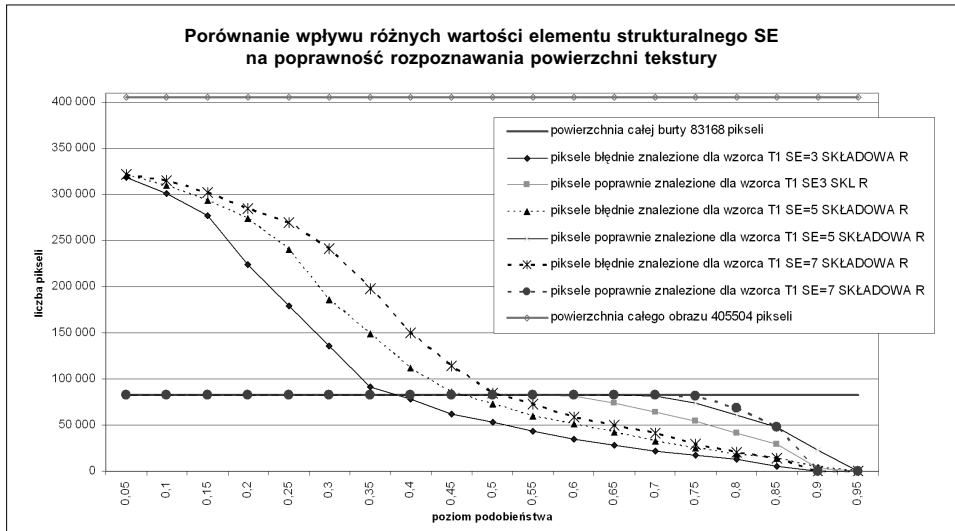


Rys. 12. Wpływ wyboru składowej barwnej na poprawność rozpoznania

Na rysunku 12 przedstawiono za pomocą wykresu liniowego poprawne rozpoznanie obiektu. Praktycznie do wartości podobieństwa 0,55 dla dowolnej składowej została zidentyfikowana poprawnie cała powierzchnia zawierająca badaną teksturę. Wyraźnie widać, że wraz ze wzrostem poziomu podobieństwa maleje poprawność rozpoznania. Czarna pozioma linia to wartość poprawnego rozwiązania zdefiniowana przez eksperta. Charakterystyka uwidacznia wyraźnie małą wrażliwość zaproponowanej metody na wybór składowej barwnej. Za pomocą wykresu kolumnowego przedstawiono błąd metody wykorzystującej gradient morfologiczny. Jako błąd zdefiniowano liczbę pikseli obszaru odnalezionego poza obszarem poprawnym wyznaczonym przez eksperta. Zgodnie z oczekiwaniem błąd maleje wraz ze wzrostem poziomu podobieństwa. W celu oceny poprawności działania metody należy zestawić błędy i poprawne rozpoznanie z konkretnym zastosowaniem. Dla ogromnej większości zastosowań zmodyfikowana metoda będzie z nadmiarem spełniała swoją rolę.

Wielkość elementu strukturalnego (SE), który wykorzystuje gradient morfologiczny w celu przekształcenia obrazu wpływa na „rozmycie” obrazu. Większy rozmiar powoduje mniejszą „ostrość” obrazu, mniej szczegółów. Na rysunku 13 zaprezentowano jego wpływ na jakość rozpoznawania.

Wnioski płynące z rysunku 13 są następujące: wielkość elementu strukturalnego wpływa na jakość rozpoznawania na zasadzie zmniejszenia dokładności (wraz ze wzrostem rozmiaru SE). Fakt ten można pozytywnie wykorzystać dobierając rozważnie rozmiar do specyfiki tekstury wykorzystanej w konkretnym przemysłowym zastosowaniu.



Rys. 13. Wpływ rozmiaru elementu strukturalnego SE na jakość rozpoznawania

4. Podsumowanie

Metoda *template matching* to metoda wrażliwa na zakłócenia. Do najtrudniejszych wyzwań należą rotacja i skalowanie obiektów badanych. Problem skalowania częściowo zmniejsza się jeżeli rozpoznawanie odbywa się jako rozpoznawanie tekstury, a nie całego obiektu. Analizie nie podlega wtedy kształt obiektu, który zmienia się znacząco wraz z tym przekształceniem. Problem związany z rotacją obiektu dla tekstury naturalnej o dużym zróżnicowaniu praktycznie przestaje istnieć. Tekstura jest na tyle „zmienna”, że obrót nie powoduje już dodatkowych problemów dla obliczeń. Zaproponowane przez autora modyfikacje: metoda 2 i metoda 3 znacząco poprawiły działanie automatycznego systemu detekcji tekstury. Wykazano możliwość zastosowania rozwiązania w inteligentnej automatyce przemysłowej. Dodatkowe przekształcenia zwiększyły czas obliczeń z około 4,4 (metoda 1) do 5,2 sekundy (metoda 2, 3). Czas ten zdefiniowano jako całkowity czas jaki upływa od akwizycji obrazu (wczytanie z pliku) poprzez przekształcenia i rozpoznanie do zapisu obrazu wynikowego z zaznaczonym zakresem wyszukany do pliku. Zaobserwowano niewielki wpływ wyboru dowolnego ze wzorców na finalne rozpoznanie co znacząco może zmniejszyć rozmiar bazy wzorców. Najlepsze wyniki rozpoznawania powierzchni otrzymano dla poziomu podobieństwa równego 0,7 i wielkości elementu strukturalnego SE=3. Zdefiniowane kryterium powierzchniowe (w zakresie poziomu podobieństwa 0,6÷0,7) dla poprawnie odnalezionej liczby pikseli wyrażonej w procentach waha się od 98% do 78%, przy jednoczesnym niskim odsetku błędnie znalezionych: od 9,8% do 6,2%. Ten zakres należy rozważać przy wdrażaniu do pracy koncepcyjnego systemu. Wszystkich symulacji dokonano w programie Matlab na rzeczywistych obrazach przemysłowych.

Literatura

- [1] Chi Mai L., *Introduction to computer vision and image processing*. (eeexplore.ieee.org/iel5/10500/33260/01572091.pdf?arnumber=1572091).
- [2] Myler H.R., Weeks A.R., Jr., *The Pocket Handbook Of Image Processing Algorithms In C*. Prentice Hall, 1993.
- [3] Nixon M.S., Aguado A., *Feature Extraction and Image Processing*. British Library, 2005.
- [4] Parker J.R., *Algorithms for image processing and computer vision*. Wiley Computer Publishing, 2006.
- [5] Ramanan D., Forsyth D.A., Barnard K., *Building Models of animals from video*. PAMI(28), No. 8, 2006.
- [6] Seul M., O’Gorman L., *Practical Algorithms For Image Analysis*. Cambridge University Press, 2000.
- [7] Tadeusiewicz R., Ogiela M., *Nowe możliwości klasyfikacji oraz inteligentnego wyszukiwania informacji w koncepcji automatycznego rozumienia obrazów*. Systemy informatyczne zastosowania i wdrożenia, t. 3, 5–36, Warszawa-Szczyrk, WNT 2003.
- [8] Wróbel Z., Kopyrowski R., *Praktyka przetwarzania obrazów w programie Matlab*. Warszawa, EXIT 2004.
- [9] Zieliński T.P., *Cyfrowe przetwarzanie sygnałów Od teorii do zastosowań*. Warszawa, WKŁ 2005.