

Tomasz SZYMCZYK

ROZPOZNAWANIE TEKSTUR Z WYKORZYSTANIEM BAZY MODELI

STRESZCZENIE *Problem rozpoznawania obrazów jest zagadnieniem trudnym i złożonym. Jednym z możliwych sposobów jego realizacji, jest wykorzystanie bazy modeli i porównywanie ich z obrazem badanym pochodzącym z kamery. Możliwe jest rozpoznawanie w oparciu o: kształt, kolor czy też teksturę. W artykule zaprezentowano wykorzystanie zmodyfikowanej metody dopasowania wzorców do rozpoznawania obrazów, pochodzących z rzeczywistej kamery przemysłowej. Przedstawiono także podstawowe wady i ograniczenia klasycznej metody dopasowania wzorców.*

Słowa kluczowe: *rozpoznawanie tekstur, przetwarzanie obrazów, dopasowanie wzorców.*

1. WSTĘP

Współczesne systemy automatyki przemysłowej naszpikowane są elementami sztucznej inteligencji. Systemy te przetwarzają ogromne ilości informacji

dr inż. Tomasz SZYMCZYK
e-mail: t.szymczyk@pollub.pl


Instytut Informatyki,
Wydział Elektrotechniki i Informatyki,
Politechnika Lubelska

PRACE INSTYTUTU ELEKTROTECHNIKI, zeszyt 249, 2011

praktycznie w czasie rzeczywistym i podejmują skomplikowane decyzje. Wiele pozornie prostych zadań przemysłowych wzbogaconych jest o elementy zaczerpnięte z systemów rozpoznawania obrazów. Począwszy od systemów rozpoznawania tekstu (adresu) stosowanych np. w kanadyjskiej poczcie poprzez wykrywanie twarzy czy uśmiechu zaimplementowane we współczesnych aparatach fotograficznych, po systemy detekcji defektów produktu finalnego w przemyśle skończywszy. Wszystkie te systemy wykorzystują szeroko pojęte widzenie komputerowe. W artykule przedstawiono przykład systemu rozpoznawania obrazów wspomagający pracę w sektorze przetwórczym przemysłu spożywczego. Zaprezentowano wyniki badań na rzeczywistych obrazach z kamery przemysłowej. Obrazy te (dziennie i nocne) zawierają typowe zniekształcenia optyczne.

2. ROZPOZNAWANIE OBRAZÓW

Analizując, jakiegokolwiek obraz, należy wziąć pod uwagę wiele czynników takich jak: kształt, kolor, wielkość, oraz ziarnistość (teksturę) badanego obiektu. Jest to szczególnie ważne w przypadku analizowania tekstur. W przypadku obrazów jednorodnych z wyraźnie dominującym kolorem czy też binarnych analizę kształtu można wykonać za pomocą współczynników kształtu [10], którymi mierzy się badany obiekt.



Rys. 1. Dziedziny analizy i rozpoznawania obrazów

Rozpoznawanie obiektów może odbywać się na wiele sposobów. Można rozpoznawać obiekty na podstawie ich kształtu. Często stosuje się wieloetapowe rozpoznawanie np. najpierw ogólny zarys, kształt a następnie szczegółowe rozpoznawanie na podstawie tekstury, koloru itp. Z zależności od konkretnego zadania często łączy się wspomniane powyżej sposoby w jeden tzn. najpierw za pomocą detekcji kształtu podstawowego wyznacza się miejsce detekcji szczegółowej. Ma to na celu przyspieszenie procesu rozpoznawania.

2.1. Rozpoznawanie kształtów

Badany obraz można opisać liczbowo – zmierzyć. Pomiarów przeprowadzamy w celu zredukowania obrazu do zbioru wartości liczbowych opisujących wybrane charakterystyczne jego cechy. Na podstawie przeprowadzonych pomiarów, możemy bezpośrednio wyciągnąć wnioski dotyczące rozpoznawanego obrazu. Wyróżniamy dwie kategorie pomiarów prowadzących do otrzymania parametrów:

1. Lokalnych opisujących pewien element obrazu tj. średnicę obiektu lub jego powierzchnię.
2. Globalnych będących wielkościami względnymi opisującymi cechy grup obiektów lub innych elementów obrazu.

W wyniku dokonania pomiarów na obrazie otrzymuje się zbiór wartości, które poddawane są kolejnym etapom przetwarzania w celu wykrycia ich charakterystycznych cech. Dąży się do wyodrębnienia takich cech obiektów, które pozwolą na jednoznaczną identyfikację obiektów posiadających ten sam kształt. Cechy te powinny być także niewrażliwe na działanie standardowych przekształceń obrazu związanych z procesem jego przetwarzania i analizy. Pomiarów dokonane bezpośrednio na obrazie takie jak: pole powierzchni, długość obwodu czy współrzędne obiektu nie spełniają założenia niezmienności wobec przekształceń skalowania i rotacji.

Metody momentowe służą do opisu własności figur. W procesie charakteryzowania figur przydatne są przede wszystkim momenty pierwszego i drugiego rzędu. W przypadku tekstur momenty pierwszego rzędu określają położenie środka ciężkości, a momenty drugiego rzędu ($p = 0, q = 2$ lub $p = 2, q = 0$) są miarą bezwładności danego obiektu.

Moment rzędu p funkcji ciągłej jednej zmiennej jest zdefiniowany następująco:

$$m_p = \int_X x^p f(x) dx \quad (1)$$

gdzie:

X – zbiór wszystkich punktów x .

Moment rzędu p, q funkcji ciągłej dwu zmiennych jest zdefiniowany następująco:

$$m_{p,q} = \iint_{X Y} x^p y^q f(x, y) dx dy \quad (2)$$

gdzie:

X, Y – zbiór wszystkich punktów odpowiednio x, y .

Definiuje się również momenty centralne, niezależne od współrzędnych obiektu:

$$\mu_{p,q} = \iint_{X Y} (x - \bar{x})^p (y - \bar{y})^q f(x, y) dx dy \quad (3)$$

gdzie:

(\bar{x}, \bar{y}) – współrzędne środka obiektu,

X, Y – zbiór wszystkich punktów odpowiednio x, y ,

f – funkcja przyjmująca wartości z przedziału $[0, 1]$.

Współrzędne środka można obliczyć ze wzoru:

$$\bar{x} = \frac{m_{10}}{m_{00}}, \quad \bar{y} = \frac{m_{01}}{m_{00}} \quad (4)$$

W dwuwymiarowej przestrzeni dyskretnej wzory na momenty p, q i momenty centralne są następujące:

$$m_{p,q} = \sum_X \sum_Y x^p y^q f(x, y) \quad (5)$$

$$\mu_{p,q} = \sum_X \sum_Y (x - \bar{x})^p (y - \bar{y})^q f(x, y) \quad (6)$$

Momenty takie możemy znormalizować dzieląc je przez odpowiednią potęgę μ_{00} . Otrzymuje się niezmiennie względem przesunięcia i skalowania momenty centralne znormalizowane wyrażające się wzorem:

$$\eta_{p,q} = \frac{\mu_{p,q}}{\mu_{00}^\gamma}, \quad \gamma = \frac{p+q}{2} + 1 \quad (7)$$

Za pomocą znormalizowanych momentów można wyznaczyć niezmienniki momentowe Hu [3, 11, 24]:

$$\begin{aligned}
 h_1 &= \eta_{20} + \eta_{02} \\
 h_2 &= (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2 \\
 h_3 &= (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2 \\
 h_4 &= (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2 \\
 h_5 &= (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12}) [(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] + (3\eta_{21} - \eta_{03}) \\
 &\quad (\eta_{21} + \eta_{03}) [3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \\
 h_6 &= (\eta_{20} - \eta_{02}) [(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03}) \\
 h_7 &= (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03}) [3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] - \\
 &\quad (\eta_{30} - 3\eta_{12})(\eta_{21} + \eta_{03}) [3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2]
 \end{aligned} \tag{8}$$

Niezmienniki momentowe są cechami o fundamentalnym znaczeniu przy rozpoznawaniu obiektów płaskich, ponieważ umożliwiają rozpoznanie obiektów przy ich różnej lokalizacji (translacja) w polu widzenia oraz przy różnych powiększeniach obiektu badanego (skalowanie) i różnych kątach obrotu (rotacja). W przypadku „lustrzanego odbicia” obiektu h_7 zmienia znak na przeciwny co również bardzo łatwo wykryć.

2.2. Kody łańcuchowe i rozpoznawanie syntaktyczne

Rozpoznawanie kształtów może odbywać się także z wykorzystaniem łańcuchowego opisu obrysu przedmiotu. Do najczęściej spotykanych należą:

1. Kody łańcuchowe Freemana.
2. Reprezentacja konturu poprzez krzywą α -s.
3. Język opisu obrazów Shawa.
4. Język opisu cech kształtu (Jakubowskiego).


Opisany kształt zamieniony jest na ciąg znaków, który tworzy wzorzec a następnie badany obiekt jest również kodowany w tej samej gramatyce opisu. Następnie porównywane są ciągi znakowe. Wspomniane wyżej metody na ogół tworzą jednoznaczny opis niezależny od obrotu figury oraz od miejsca rozpoczęcia opisu jej kształtu. W przypadku bardziej skomplikowanych kształtów rozpoznawanie z ich pomocą nie daje jednak zadowalających rezultatów.

Wraz z rozwojem technik rozpoznawania obrazu stopniowo, począwszy od lat sześćdziesiątych, pojawiał się problem zbyt dużej wielkości obrazów poddawanych rozpoznaniu, wiążący się ze znacznym zwiększeniem się wymiarów przestrzeni cech używanych do opisu wzorca. W odpowiedzi na te problemy zaczęto wprowadzać nowe – syntaktyczne podejście do rozpoznawania obrazów, w którym zaczęto stosować techniki lingwistyki matematycznej.

Jest to technika stosowana do dnia dzisiejszego, a opiera się na podziale złożonego obrazu na mniejsze podobrazy (ang. *Primitives Picture*), które następnie rozpoznawane są metodami całościowymi przy założeniu ich wzajemnej niezależności. W przypadku zbyt dużej złożoności podobrazów algorytm podziału kontynuowany jest aż do momentu osiągnięcia zadowalającego wyniku, to jest osiągnięcia składowych pierwotnych obrazu. Składowymi pierwotnymi są niepodzielne elementy obrazu, w przypadku których możemy założyć ich istnienie i pewną identyfikację dla danej klasy obrazów. Podejście syntaktyczne [23] opiera się na wyodrębnieniu składowych pierwotnych obrazu i ustaleniu relacji zachodzących pomiędzy nimi. Ze względu na fakt, iż składowe pierwotne obrazu traktujemy jako obiekty niezależne bardzo ważną rolę odgrywa właściwe ustalenie relacji zachodzących pomiędzy podobrazami w celu późniejszego prawidłowego ich złożenia i rozpoznania.

2.3. Rozpoznawanie tekstur

Teksturą określamy przestrzenną organizację elementów obrazu uwarunkowaną statystycznym rozkładem jasności elementów w danym obszarze obrazu [3, 4, 5, 6, 15, 18, 25, 27]. Tekstury możemy podzielić na naturalne i sztuczne. Naturalne są to tekstury, których rozkład jest losowo wymuszony np. przez przyrodę: tekstura trawy, marmuru, słoje drewna, rafa koralowa itd. Jest to tekstura o silnie losowej powtarzalności. Wraz z oddalaniem się od powierzchni tekstury zmniejsza się jej szczegółowość wyraźnie jednak rośnie powtarzalność. Sztuczna tekstura to taka jaką generuje maszyna. Pomimo licznych zabiegów projektantów i programistów charakteryzuje się ona silną powtarzalnością (znikomy element losowości). Tekstury sztuczne znalazły zastosowania w generowaniu pseudo-realistycznych scen np. w architekturze, motoryzacji. Najwięcej ich niewątpliwie pojawia się we współczesnym przemyśle rozrywkowym – grach komputerowych. Różnicę pomiędzy teksturą naturalną, a sztuczną przedstawiono na rysunku 2.



Rys. 2. Przykład tekstury: a) sztucznej, b) naturalnej

Na podstawie [3] teksturę możemy opisać za pomocą przestrzennej funkcji autokorelacji danej wzorem (9), lub parametrów wykorzystujących transformację Fouriera obrazu cyfrowego (11).

W przypadku opisu, z wykorzystaniem przestrzennej funkcji autokorelacji, teksturę można opisać wzorem (9):

$$A(\zeta, \eta, i, j) = \frac{\sum_{m=i-W}^{i+W} \sum_{n=j-W}^{j+W} f(m, n) f(m - \zeta, n - \eta)}{\sum_{m=i-W}^{i+W} \sum_{n=j-W}^{j+W} [f(m, n)]^2} \quad (9)$$

gdzie:

m, n – współrzędne punktu,

W – liczba całkowita,

(i, j) – współrzędne punktu,

$\zeta, \eta = 0, \pm 1, \pm 2, \pm 3, \dots$ – współrzędne przesunięcia.

Funkcja autokorelacji obliczana jest w obszarze o nieparzystych wymiarach $(2W + 1)$ na $(2W + 1)$ dla każdego punktu obrazu o współrzędnych (i, j) i dla $\zeta, \eta = 0, \pm 1, \pm 2, \pm 3, \dots$.

Przy ustalonym przesunięciu (ζ, η) największe wartości funkcji $A(\zeta, \eta, i, j)$ wskazują obszar największej ziarnistości tekstury.

$$T(i, j) = \sum_{\zeta=-h}^{+h} \sum_{\eta=-h}^{+h} \zeta^2 \eta^2 A(\zeta, \eta, i, j) \quad (10)$$

gdzie:

(ζ, η) – współrzędne przesunięcia.

Oznacza to, że rozmiar ziaren tekstury jest proporcjonalny do funkcji autokorelacji.

Innym sposobem opisu tekstury [3], o rozmiarze M na N , jest opis z uwzględnieniem parametrów wykorzystujących transformatę Fouriera obrazu cyfrowego $f(k, l)$ daną wzorem (11).

$$F(u, v) = \frac{1}{MN} \sum_{k=1}^M \sum_{l=1}^N f(k, l) e^{-2\pi i(ku+lv)} \quad (11)$$

gdzie:

(M, N) – rozmiar tekstury,
 $1 \leq u \leq M, 1 \leq v \leq N, (k, l)$ – współrzędne punktu.

W przypadku gdy tekstura opisana jest statystycznymi parametrami jaskrawości elementów obrazu należy określić bezwzględną różnicę poziomów jasności dla dwóch elementów obrazu lub bezwzględną różnicę uśrednionych wartości jasności dla dwóch grup elementów obrazu. Rozpatruje się dwa elementy obrazu o współrzędnych (x, y) oraz $(x + \Delta x, y + \Delta y)$ różnica poziomów jaskrawości zdefiniowana jest następującym wzorem:

$$f_{\delta}(x, y) = |f(x, y) - f(x + \Delta x, y + \Delta y)| \quad (12)$$

gdzie: $\Delta x, \Delta y$ – przesunięcie, a $\delta = \sqrt{\Delta x^2 + \Delta y^2}$ jest odległością pomiędzy rozpatrywanymi elementami obrazu.

Następnie oblicza się gęstość prawdopodobieństwa zdarzenia polegającego na tym, że para wybranych elementów obrazu badanego odległa od siebie o δ i usytuowanych względem siebie pod kątem α posiada jasność odpowiednio (k_1, k_2) .

$$\Delta x = \delta \cos(\alpha), \quad \Delta y = \delta \sin(\alpha) \quad (13)$$

Obliczone w ten sposób gęstości prawdopodobieństw tworzą macierz $P_{\delta, \alpha}(k_1, k_2)$. Dysponując macierzą nią można obliczyć następujące parametry tekstury [3, 5, 6]:

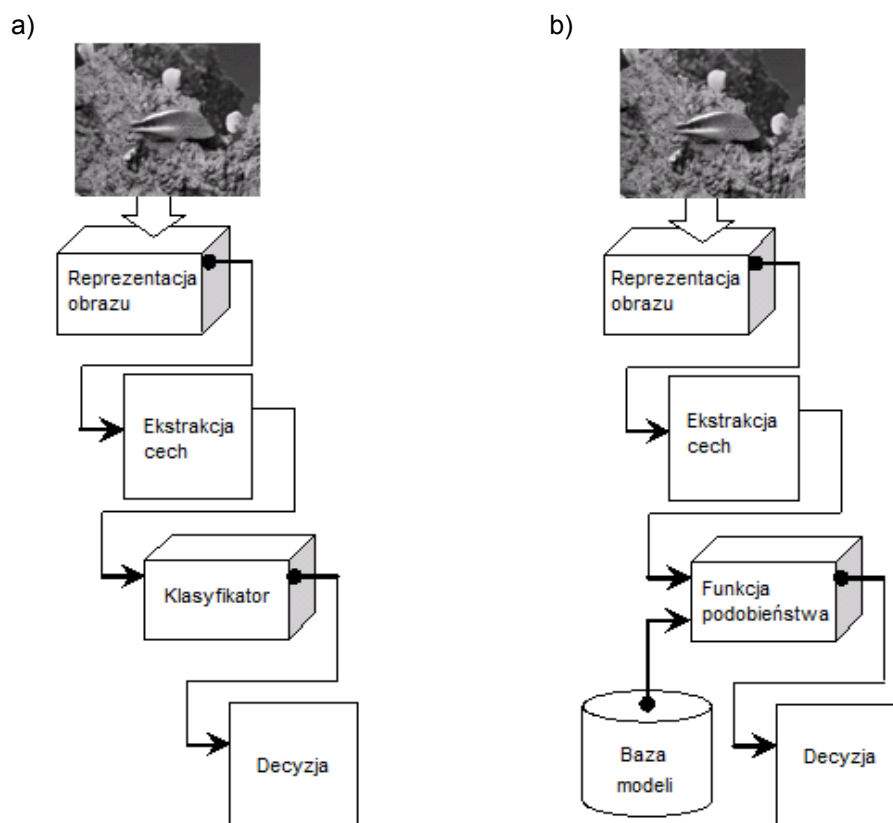
1. Kontrast.
2. Moment drugiego rzędu (miara homogeniczności obrazu).
3. Współczynnik korelacji.
4. Entropia.
5. Wariancja.
6. Moment różnicowy.

3. ROZPOZNAWANIE BAZUJĄCE NA MODELU

Proces rozpoznawania obrazów można podzielić ze względu na sposób wnioskowania, w następujący sposób :

1. Rozpoznawanie oparte na cechach (ang. *feature-based*).
2. Rozpoznawanie oparte na modelu (ang. *model-based*).

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 uprzednie bazy modeli, z którym nastąpi porównanie obrazu badanego.



Rys. 3. Ogólny schemat rozpoznawania obrazów ze względu na sposób wnioskowania:
a) wnioskowanie oparte o cechy, b) wnioskowanie oparte o model

3.1. Metoda Template Matching

Wykorzystanie metody dopasowania wzorców (ang. *template matching*) może być pomocne w rozpoznawaniu i interpretacji obrazu [1, 12, 20]. Metoda

dopasowania szablonów polega na rozpoznawaniu badanej sceny na podstawie porównania ze wzorcem [1, 3, 5, 6]. Wynikiem jest funkcja celu, która znormalizowana i wyrażona w procentach jest funkcją podobieństwa. Klasycznie metodę dopasowania wzorców wykorzystuje się do rozpoznawania kształtów. W artykule zaprezentowano adaptację tej metody do zagadnienia rozpoznawania tekstur.

Wykorzystując metodę template matching (TM) do wyszukania położenia konkretnego szczegółu w obrazie badanym zakłada się istnienie dwóch macierzy [26, 16]. 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 [21]. Bardzo rzadkim przypadkiem jest idealne pasowanie do siebie wzorca i obrazu. Wymagane jest więc zdefiniowanie jakości podobieństwa. Poniżej przedstawiono definicje kilku miar:

$$\max_{[i,j] \in R} |f - g| \quad (14)$$

$$\sum_{[i,j] \in R} |f - g| \quad (15)$$

$$\sum_{[i,j] \in R} |f - g|^2 \quad (16)$$

gdzie:

f, g – macierze reprezentujące obraz i wzorzec.

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 [13]:

$$\sum_{[i,j] \in R} |f - g|^2 = \sum_{[i,j] \in R} f^2 + \sum_{[i,j] \in R} g^2 - 2 \sum_{[i,j] \in R} fg \quad (17)$$

gdzie:

f, g – macierze reprezentujące obraz i wzorzec.

Jeśli przyjmujemy, że f i g są skorelowane wtedy wzór (17) 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,

$$M_{fg}[i, j] = \sum_{k=1}^m \sum_{l=1}^n g[k, l] f[i+k, j+l] \quad (18)$$

gdzie:

- f, g – macierze reprezentujące obraz i wzorzec,
- (k, l) – współrzędne punktu wzorca,
- (i, j) – współrzędne punktu obrazu.

Operacja ta jest zwana korelacją krzyżową między f i g . Celem metody jest znalezienie miejsc zawierających maksima funkcji zdefiniowanej wzorem (18). 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. Miara dopasowania M może wtedy zostać obliczona używając wzorów (19) i (20).

$$C_{fg}[i, j] = \sum_{k=1}^m \sum_{l=1}^n g[k, l] f[i+k, j+l] \quad (19)$$

$$M[i, j] = \frac{C_{fg}[i, j]}{\sqrt{\sum_{k=1}^m \sum_{l=1}^n f^2[i+k, j+l]}} \quad (20)$$

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 [17].

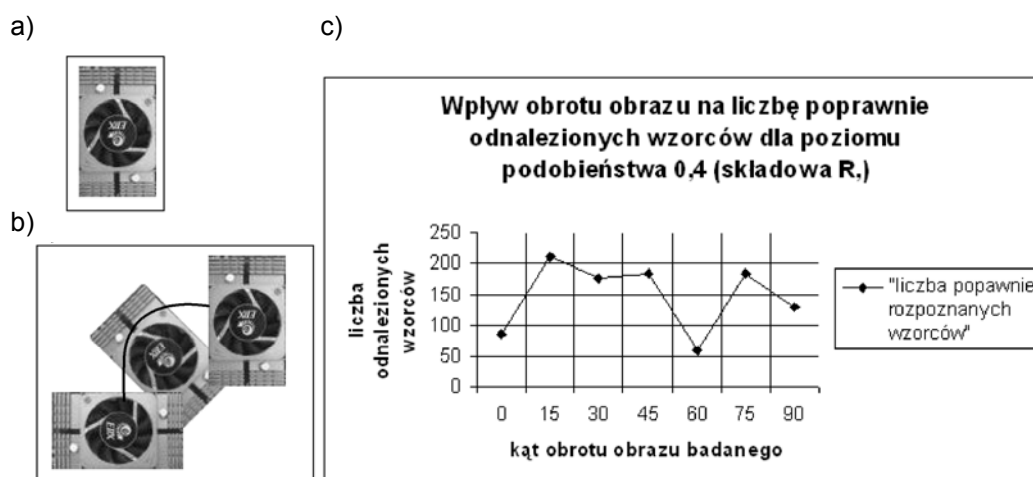
3.2. Ograniczenia metody Template Matching

Metoda template matching jest metodą wrażliwą na podstawowe operacje afiniczne na obrazie. Należą do nich rotacja i skalowanie. Należy uważnie i rozsądnie budować bazę wzorców. W przypadku rozpoznawania obiektów „małych”

nie stykających się ze sobą (np. litery) wzorcem może być pojedyncza litera (kształt) lub nawet cały wyraz. Jeżeli na obrazie, w którym wyszukujemy kształtu, istnieje podejrzenie, że nie cały obraz szukany jest widoczny należy jako wzorzec zdefiniować najbardziej charakterystyczną część obrazu, jednoznacznie wskazującą na konkretny obiekt. Przykładem może być zliczanie ryb w ławicy – wzorzec w postaci „całej ryby” nie jest najlepszym wyborem, znacznie lepiej byłoby jako wzornik zdefiniować oko lub ogon ryby.

Obrazy o jednolitym tle, z wyraźnie zarysowanym obrysem badanego obrazu, rozpoznaje się najłatwiej. Analiza obrazów binarnych jest prosta i daje dobre rezultaty. Z uwagi na bardzo prostą reprezentację obrazu (w zapisie binarnym) znalazł on zastosowanie do rozpoznawania tekstu czy też prostych obrazów mikroskopowych. Bardzo często metodę TM używa się do zliczenia szukanych obiektów w obrazie (np. zdjęcia komórek).

Rozpoznawanie obrazów monochromatycznych jest znacznie trudniejsze od poprzednich. Powodem tego jest bardziej „rzeczywiste” tło. 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: wzorzec – obraz badany jest wyraźnie większa od korelacji: wzorzec – tło. Na rysunku 4 zaprezentowano wpływ rotacji obrazu badanego na ilość znalezionych dopasowań przy założeniu, że poziom podobieństwa wynosi 40%.



Rys. 4. Wpływ rotacji obiektu szukanego na jakość rozpoznawania:


a) wyszukiwany wzorzec, b) kolorowy obraz badany (24 bity). 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)

Problem w rozpoznawaniu pojawia się wtedy gdy w obrazie badanym pojawia się „bogate” tło. W badaniu obrazów rzeczywistych np. z kamer przemysłowych, bardzo rzadko w obrazie badanym występuje dokładnie identyczny obraz jak szukany wzorzec. Najczęściej jest on przeskalowany, obrócony, zniekształcony, inaczej oświetlony, przysłonięty, z dodatkowym cieniem itp. W takim wypadku bardzo często wartość korelacji pomiędzy zniekształconym obrazem badanym, a wzorcem jest porównywalna lub czasem nawet mniejsza od wartości korelacji z tłem. Dla takich warunków poprawne rozpoznanie jest często niemożliwe. W obrazach o dużej zawartości informacji tj. z „bogatym tłem” należy eliminować tło. W zależności od badanej sceny można to zrobić prostym zestawem filtrów graficznych: rozmycie, a później wyostrenie krawędzi. Usuwa się wysokie częstotliwości z tła (dużą zmienność), które powodują powstawanie ekstremów lokalnych w wartości funkcji korelacji. Następnie wyostrza się krawędzie podkreślając obecność głównego obiektu, który ma być zidentyfikowany. 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.

Obrazy rzeczywiste kolorowe stanowią największe wyzwanie. Obrazy kolorowe można traktować jako połączenie trzech obrazów monochromatycznych powstałych po filtracji składowych R , G i B z obrazu kolorowego zapisanego w formacie RGB. Rozpoznawanie odbywa się wtedy w sposób następujący: z obrazu badanego i wzorca wybiera się jedną składową barwną – tę samą dla obu. Następnie obliczono korelację. Rozpoznawanie na tak postawionych warunkach sprowadza się do rozpoznawania obrazów monochromatycznych. Należy jednak wspomnieć, że może wystąpić silna zależność jakości rozpoznawania (wyszukiwania) od wybranej składowej [22]. Autor zaobserwował to w przypadku badania tekstury rafy koralowej (obrazy podwodne)

4. PRZYKŁAD WYKORZYSTANIA ROZPOZNAWANIA TEKSTUR W PRAKTYCE

W artykule skupiono się na rozpoznawaniu powierzchni (tekstur) w przemysłowym zastosowaniu. System ma za zadanie automatycznie odnaleźć obszar zawierający konkretną teksturę. Wzornik (baza modeli) jest zdefiniowana przez eksperta. System powinien być odporny na zniekształcenia obrazu, zmianę charakteru i sposobu oświetlenia (różne pory dnia oraz zdjęcia nocne). Przykład obrazu z kamery przemysłowej, wzornik i znalezioną powierzchnię przedstawiono na rysunku 5



Rys. 5. Przykład rozpoznawania tekstury w obrazie przemysłowym.


a) rzeczywisty widok z kamery (tryb nocny), b) wzorec zdefiniowany z innego obrazu c) przykład rozpoznanej powierzchni (najtrudniejszy przypadek)

Teksturę można opisać matematycznie tzn. policzyć jej energię, homogeniczność, inercję. Można dokonać analizy barwnej, statystyczny rozkład intensywności, ASM (ang. *Angular Second Moment*) można dokonać wyznaczenia współczynników dla np. deskryptorów tekstury zdefiniowanego w MPEG-7 [14, 15, 28]. Dysponując takim matematycznym opisem lub jednym z deskryptorów tekstury, można próbować z powodzeniem wyszukiwać w obrazie konkretnej tekstury – jako matematyczne porównanie przetworzonych cech. Autor dla danego problemu proponuje jednak inne rozwiązanie. Polega ona na porównywaniu obszaru roboczego z wybranym wzorcem. Porównywanie odbywa się z wykorzystaniem metody dopasowania wzorców [1, 12, 26] z wykorzystaniem szybkiej transformaty Fouriera (ang. *Fast Fourier Transform*) [21, 26]. Obliczana jest szybka transformata Fouriera dla obrazu i wzorca W w kolejnym kroku liczony jest splot obrazów dwóch transformat. W ostatnim etapie obliczana jest transformata odwrotna. Finalnie powstały obraz traktowany jest jako funkcja celu – im wyższe wartości, tym lepsze dopasowanie wzorca do obrazu. Tak zdefiniowana metoda, jednak dla badanego zagadnienia, nie dawała poprawnych rezultatów. Znajdowano obszary, w których nie występuje wzorec. W celu poprawy wyników przetestowano szereg przekształceń graficznych i wyniku czego wybrano proste graficzne przekształcenie znacząco poprawiające wyniki. Obraz badany i wzorec poddano przekształceniu z wykorzystaniem gradientu morfologicznego. W zagadnieniu badano zmianę wartości elementu strukturalnego SE równego odpowiednio: 3, 5 i 7. Rozwiązanie takie wydaje się być znacznie łatwiejsze w implementacji (zdecydowanie mniejsza złożoność matematyczna), i szybsze (mniej operacji matematycznych wykonanych na obrazie) w stosunku do innych sposobów analizy tekstury. Brak konieczności implementacji złożonych operacji matematycznych umożliwia przeniesienie części obliczeniowej na „słabsze” procesory wykorzystywane np. w urządzeniach mobilnych. Dodatkową trudność w problemowym rozpoznawaniu stanowi fakt, że tekstura charakteryzująca obszar roboczy jest

teksturą naturalną [9]. Oznacza to że jej „powtarzalności” i rozkład jest całkowicie losowy. Wysokość z której pozyskiwane są zdjęcia jest wystarczająca do pokazania całego obszaru tekstury. Traci się na szczegółowości (która wbrew pozorom nie jest wymagana) ale zyskuje na powtarzalności tekstury.

4.1. Metodyka oceny rozpoznanych powierzchni

Problem rozpoznawania tekstury można utożsamić ze znalezieniem pewnego obszaru zawierającego taką grupę cech jaka, została zdefiniowana w zadaniu. W praktyce sprowadza się to do odnalezienia obszaru, w którym znajduje się wyszukiwana tekstura, której próbka znajduje się w bazie wzorców. Proces poprawności rozpoznawania zdefiniowano następująco: każdy obraz zawiera obszar, w którym znajduje się szukany zbiór cech – tekstura. Dla każdego badanego obrazu zdefiniowano dwa zakresy występowania poprawnego obszaru (rys. 6).



Rys. 6. Przykłady zdefiniowanych przez eksperta obszarów występowania tekstury. Kolorem ciemno-szarym zaznaczono cały zakres występowania tekstury. Kolorem jasno-szarym obwiedziono wyraźnie widoczną teksturę (w bieżącym oświetleniu)

Do dalszych badań autor wybrał jako wzorzec poprawności obszary otoczone linią ciemno-szarą. Kryterium to jest bardziej rygorystyczne. Nawet ekspert

(człowiek) ma problemy ze zdefiniowaniem wyraźnie różnej (od wzorca) tekstury. Linia ciemno-szara, na ogół pokrywająca się z dokładnym obszarem burty – wyznacza domniemaną powierzchnię, w której znajduje się badana tekstura. Nieodpowiednie oświetlenie wypacza w sposób widoczny charakter tekstury. Autor zdefiniował dwa wskaźniki:

1. Liczbę poprawnie rozpoznanych pikseli (tekstury) w obrębie obszaru wyznaczonego przez ciemno-szarą linię.
2. Liczbę rozpoznanych pikseli (tekstury) poza obszarem wyznaczonego przez ciemno-szarą linię (błędne rozpoznanie).

Bazę wzorców stworzono wybierając z obrazu dziennego losowe, kwadratowe wycinki o boku 64-rech pikseli. Tak stworzone sześć wzorców posłużyło do dalszego badania jakości rozpoznawania tekstury na innych obrazach.




Rys. 7. Przykładowe wzorce o rozmiarze 64x64 piksele losowo wybrane z dziennego obrazu

4.2. Otrzymane wyniki

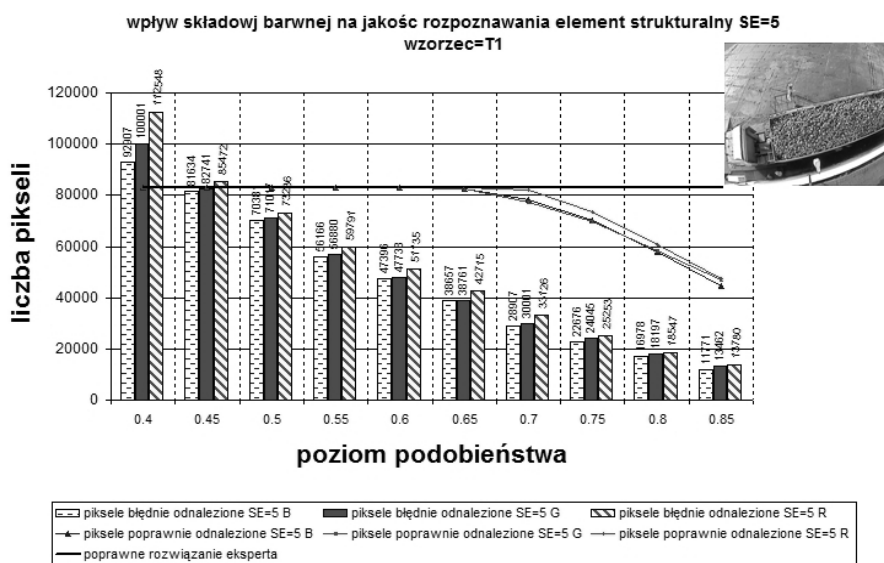
Na wstępie porównano wyniki uzyskane za pomocą klasycznej [1, 21] metody dopasowania wzorców (metoda 1), oraz metody autora (metoda 2), w której obraz badany i wzorec przed porównaniem z wykorzystaniem metody TM poddano przekształceniu graficznemu. Przekształcenie polega na zastosowaniu gradientu morfologicznego o elemencie strukturalnym $SE = 3$. Metoda 3 (również autora) to przekształcenie za pomocą gradientu morfologicznego o $SE = 3$ tylko obrazu a wzorec nie został poddany przekształceniu morfologicznemu. Wyniki

skonfrontowano także z metodą rozpoznawania wykorzystującą histogram dwuwymiarowy (metoda 4). Pomimo, że dopasowanie obrazów w oparciu o informację wzajemną (ang. *Mutual Information*) jest często spotykana w zagadnieniach widzenia komputerowego i sprawdza się np. w zagadnieniach medycznych, dla zadania problemu nie dała poprawnych rezultatów. W przypadku małego progu tolerancji odnajdowała za dużo błędnych rozwiązań a w przypadku dużego progu równego 0,95 znalazła dokładnie jeden obszar odpowiadający wzorcowi. Wyniki przedstawiono na rysunku 8.



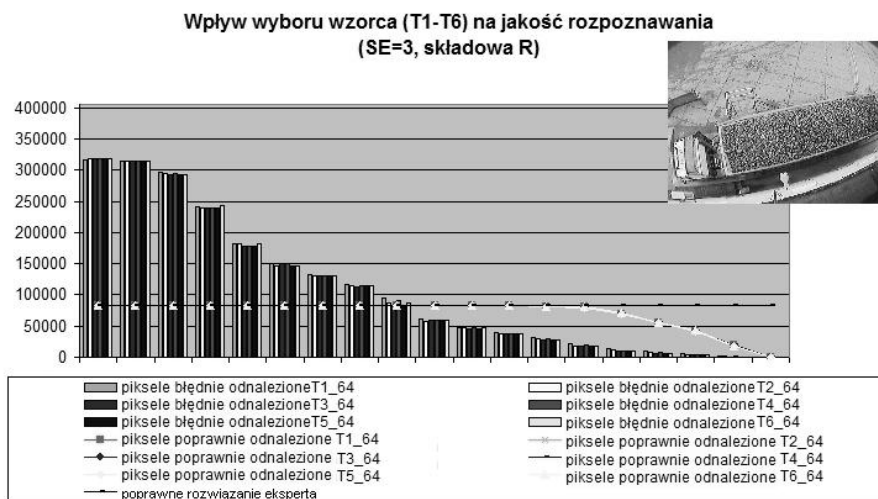
Rys. 8. porównanie wyników działania czterech metod badawczych

Prezentowana metoda wykazuje pomijalny wpływ wyboru składowej barwnej na jakość rozpoznawania. Przedstawiono to na rysunku 9.




Rys. 9. Wpływ wyboru składowej barwnej na jakość rozpoznawania. Pomiary przeprowadzono dla wzorca T1 i SE = 5

W zadaniu wykorzystuje się bazę wzorców. W celu umożliwienia rozpoznawania w oparciu o wzorce, „baza wiedzy” musi zawierać skończoną liczbę wzorców. W najlepszym wypadku byłoby, gdyby w celu poprawnego działania systemu można było wykorzystać jeden wzorzec, stosować go do wszystkich badanych zdjęć. Przebadano więc wpływ różnych wzorców na poziom rozpoznawania, a wyniki w postaci wykresu przedstawiono na rysunku 10.



Rys. 10. Wpływ losowości wyboru wzorca (T1-T6) na jakość rozpoznawania w obrazie testowym dla składowej czerwonej i $SE = 3$

W artykule zaprezentowano także wpływ rozmiaru wzorca na jakość rozpoznawania. Wyniki uzyskane w badaniu obrazu nocnego przedstawiono na rysunku 11. Należy wspomnieć, że ten obraz, z uwagi na ekspozycję świetlną, był jednym z najtrudniejszych obrazów poddanych procesowi rozpoznawania.



Rys. 11. Wpływ wyboru rozmiaru wzorca na jakość rozpoznawania na przykładzie zdjęcia nocnego. Pomiary przeprowadzono dla składowej R i $SE = 5$

5. WNIOSKI

Wykorzystując metodę zaproponowaną przez autora uzyskano pozytywne rezultaty rozpoznawania tekstury. Należy zwrócić uwagę, że wyniki uzyskane tą metodą wykazują pomijalną zależność od wybranej składowej barwnej oraz od wybranego wzorca. Za pomocą raz zdefiniowanego wzorca, pochodzącego z konkretnego obrazu można rozpoznawać teksturę na innych obrazach, nawet takich, w których występuje inna ziarnistość tekstury oraz są to obrazy wykonane w nocy i zawierające duże zniekształcenia. Obrazy charakteryzujące się silnymi zakrzywieniami pola obrazu, aberracją chromatyczną, są silnie zaszumione, a ekspozycja oświetlenia jest praktycznie inna na każdym z nich (cienie i refleksy świetlne). W przebadanych obrazach nocnych jakość rozpoznawania jest gorsza niż w przypadku obrazów dziennych, jednakże nadal poprawna.

LITERATURA

1. Brunelli R.: Template matching techniques In computer Vision. Theory and practice, John Wiley & Sons, Ltd, 2009, ISBN: 978-0-470-51706-2.
2. Canny J.: A Computational Approach to Edge Detection, IEEE Transactions on Pattern Analysis and Machine Intelligence, tom. PAMI-8, No. 6, 1986, str. 679-698.
3. Choraś R. S.: Komputerowa Wizja Metody interpretacji i identyfikacji obiektów, EXIT Warszawa, 2005
4. Chen C. H., Pau L. F., Wang P. S. P. (eds.): The Handbook of Pattern Recognition and Computer Vision (2nd Edition), World Scientific Publishing Co., 1998
5. Chen T., Wu Q.H, Rahmani-Torkman R., Hughes J.: Apseudo top-hat mathematical morphological approach to edge detection in dark regions. Pattern Recognition 2002, tom 35(1) 2002, str. 199-210.
6. Cootes T.F, Edwards G.J., Taylor C.J.: Active appearance models, IEEE Trans, PAMI 2001, tom 23(6), str. 681-685.
7. Cieslak M., Heilpern S.: Rozpoznawanie obrazów, PWN Warszawa 1988.
8. Cieslak M., Heilpern S., Ostasiewicz W., Smoluk A.: Zbiory Rozmyte, Rozpoznawanie obrazów, Teoria katastrof, wybór tekstów, PWN Warszawa 1988.
9. Cyganek.B.: Komputerowe przetwarzanie obrazów trójwymiarowych, AOW Exit Warszawa, 2002.
10. Doros M.: Przetwarzanie obrazów, WSISiZ Warszawa, 2003.
11. Haralick R., Sternberg S., Zhuang X.: Image analysis Rusing mathematical morfology, IEEE Trans, PAMI 1987, tom 9(4), str. 532-550.
12. Kato Y., Hirano T., Nakamura O.: Fast template matching algorithm for contour image based on its chain code description applied for human face identification, www.sciencedirect.com Pattern Recognition 40, 2007.
13. Mai L. C.: Introduction to computer vision and image processing, Department of Pattern Recognition and Knowledge Engineering Institute of Information Technology, Hanoi, Vietnam eeexplore.ieee.org/jel5/10500/33260/01572091.pdf?arnumber=1572091.

14. Manjunath B.S., OhmVinod J. R. , Vasudevan V., Yamada A.: Color and texture descriptors, www-itec.uni-klu.ac.at/~harald/mm02/MPEG7-2.pdf
15. Mosorov V., Kaczorowski D.: Nowa metoda detekcji defektów tekstury, *Automatyka* 20.06, tom 10, zeszyt 3.
16. Myler H. R., Weeks A. R., Jr.: *The Pocket Handbook Of Image Processing Algorithms In C*, Prentice Hall 1993.
17. Nixon M. S., Aguado S.A.: *Feature Extraction and Image Processing*, First Edition, Newnes, 2005.
18. Pratt W. K.: *Digital image processing*; 2001 John Wiley & Sons, Inc.
19. Ramanan D., Forsyth D.A, Barnard K.: Building models of animals from video, *IEEE Transactions on Pattern Analysis and Machine Intelligence* 2006, Volume 28 , Issue 8, ISSN: 0162-8828.
20. Russ J. C.: *The image processing handbook*, CRC PRESS, 2005.
21. Seul M., O`Gorman L.: *Practical algorithms for image analysis*, Cambridge University Press, 2000.
22. Szymczyk T.: Metoda dopasowania wzorców w rozpoznawaniu obrazów-ograniczenia, problemy i modyfikacje metody , *Automatyka* tom 12, zeszyt 2, UWND 2008, str. 449-462.
23. Tadeusiewicz R., Flasiński M.: *Rozpoznawanie obrazów*, PWN Warszawa, 1991.
24. Teh C.C, Chin R.T.: On image analysis by the methods of moments. *IEEE Trans PAMI* 1988, tom 10, str. 496-513.
25. Umeda A., Sugimura J., Yamamoto Y.: Characterization of wear particles and their relations with sliding conditions, *Wear* 216, str. 220-228,1998.
26. Zieliński T. P.: *Cyfrowe przetwarzanie sygnałów Od teorii do zastosowań*, WKŁ Warszawa, 2005.
27. Zhou G., Leu M., Blackmore D.: Fractal geometry modeling with applications in surface characterisation and wear prediction. *Int. Journ. of Machine Tools and Manufact.* Tom 35, No. 2, 1995, str. 203-209.
28. Yamada A., Pickering M, Jeannin S., Cieplinski L.: Ohm J. R., Kim M. ,MPEG-7 visual part of experimentation model version 10.0, ISO/IEC JTC1/SC29/WG11/N4063, 2001.

Rękopis dostarczono dnia 19.10.2010 r.

TEXTURES RECOGNITION USING MODEL DATABASE

Tomasz SZYMCZYK

ABSTRACT *The problem of the image recognizing is difficult and complex question. The using the base of models and comparing their to image from camera is one of possible ways of his realization. Image recognizing is possible in support about shape, colour or texture also. In article modified method template matching to recognizing images from real industrial camera was presented. Moreover basic disadvantages and limitations of simple template matching method was shown in the paper.*

Dr inż. Tomasz SZYMCZYK – absolwent Politechniki Lubelskiej Wydziału Elektrotechniki i Informatyki. W roku 2009 uzyskał tytuł doktora nauk technicznych broniąc rozprawę doktorską pt: „Nowa metoda rozpoznawania cech w obrazie przemysłowym bazująca na modelowej identyfikacji tekstury”. Obecnie zatrudniony na stanowisku adiunkta w Instytucie Informatyki WEil PL. Zainteresowania naukowe: przetwarzanie i rozpoznawanie obrazów, projektowanie systemów informatycznych, bazy danych, ochrona informacji.



