

Robert Ambroziak*,
Marcin Jasiński**

PARAMETRY STATYSTYCZNE PIERWSZEGO RZĘDU W AUTOMATYCZNEJ KLASYFIKACJI NOMINAŁU BANKNOTU

Artykuł przedstawia algorytm statystycznego rozpoznawania tekstury obrazu zaimplementowany w systemie automatycznej klasyfikacji banknotów.

This paper introduces some texture analyze algorithm to have application in automatic system in classification of money.

Wstęp

Automatyczne systemy pracujące z banknotami różnych walut, znalazły powszechne zastosowanie w życiu i pracy ludzi dążących wraz z postępem techniki do realizacji pojęcia „globalnej wioski”. Idea wprowadzenia zamiast systemu monetarnego punktów kredytowych realizowanych wirtualnie, znana z filmów fantastycznych, z powodu trudności technicznych długo nie zagości jeszcze w naszym życiu. Zatem system monetarny oparty na monetach i banknotach powinien zostać w miarę możliwości jak najlepiej zautomatyzowany.

Bankomaty są urządzeniami już dość powszechnie zdomowionymi w naszej rzeczywistości. Ułatwiają znacznie życie, nie trzeba iść do banku, czekać w kolejce, wypełniać różnych formularzy, aby wypłacić pieniądze. Wypłata banknotów dla automatycznego systemu nie stanowi żadnego problemu, banknoty są już posegregowane a jedynie mechaniczny podajnik musi być tak skonstruowany, aby nie wypłacił podwójnych np. sklejonych banknotów. Jednak wpłata pieniędzy w bankomacie, czyli wprowadzenie banknotów do automatycznego systemu stawia przed konstruktorami takich urządzeń wiele wyzwań.

* Katedra Informatyki Stosowanej Politechniki Łódzkiej

** Katedra Informatyki Stosowanej Politechniki Łódzkiej

Maszyna musi odpowiednio podjąć decyzję, jaki banknot tzn. nominal i wartość, został wprowadzony, ale także jak najskuteczniej sprawdzić jego autentyczność.

Innymi skutecznie wykorzystywanymi urządzeniami są maszyny liczące i sortujące banknoty, w bankach czy w innych instytucjach mających do czynienia z dużą ilością gotówki. Praktycznie 95% technik służących do automatycznej detekcji banknotów, związanych jest przetwarzaniem, analizą i rozpoznawaniem obrazów. Techniki pracujące na informacji zawartej w obrazie [5] znalazły z powodzeniem zastosowanie w wielu dziedzinach nauki, w przemyśle, medycynie itp. W artykule przedstawiamy jedną z metod statystycznego wyznaczania parametrów [2] opisujących właściwości tekstury obrazu, a w szczególności obrazów banknotów uzyskanych ze skanera opartego na przetworniku CCD, co znacząco eliminuje zniekształcenia spowodowane zagięciami powierzchni banknotów oraz złym oświetleniem. Istnieje wiele metod i podejść związanych z zagadnieniami analizy i klasyfikacji obrazów. Często są one jednak kosztowne numerycznie i czasochłonne. Przedstawiony w tej publikacji algorytm klasyfikacji obrazu jest dość szybki i nie wymaga dużych zasobów pamięciowych sprzętu, zbyt dużej mocy obliczeniowej, co może pozwolić na zastosowanie tej metody w systemach wbudowanych, jakimi są np. bankomaty, maszyny sortujące. Artykuł zawiera także nasze spostrzeżenia i wyniki badań, które zostały uzyskane z przeprowadzonej przez nas implementacji modelu systemu automatycznej klasyfikacji banknotów różnych walut i nominalów.

Podstawy teoretyczne związane z analizą informacji obrazowej

Na wstępie chcemy wyjaśnić kilka pojęć związanych z przetwarzaniem informacji zawartej w obrazie.

Pojęciem obraz [5] określamy dwuwymiarową funkcję intensywności światła $F(x, y)$, gdzie wartości czyli amplituda F w przestrzennych współrzędnych (x, y) określa intensywność (jasność) obrazu w tym punkcie. Ponieważ światło jest formą energii, to na $F(x, y)$ mają wpływ dwa elementy:

Iluminacja (*ang. illumination*) – czyli wielkość promieniowania świetlnego źródła,

Odbicie (*ang. Reflectance*) – czyli ilość światła odbitego w scenie.

$$F(x, y) = I(x, y) + R(x, y)$$


Gdzie: $0 < I(x, y) < \infty, 0 < R(x, y) < 1$,

Ze względu na specyfikę procesów cyfrowych (komputerowych) funkcja obrazu $F(x, y)$ musi być zdyskretyzowana, czyli poddana procesowi dokonującemu cyfrowy zapis obrazu w formie dwuwymiarowej tablicy zwanej obrazem cyfrowym, gdzie każdy jej element jest określany terminem piksel lub pel.

Istnieje wiele modeli opisu obrazu cyfrowego, związanych przede wszystkim z jasnością, kolorem i jego nasyceniem w każdej jednostce logicznej obrazu, jaką jest piksel.

Do celów diagnostycznych, można powiedzieć przemysłowych, stosuje się bardzo często standard HSL (*ang. Hue, Saturation, Lightness*), który odpowiednio rozgranicza jasność oraz kolor i jego nasycenie w obrazie. Wydobycie informacji o kolorze danego punktu obrazu ma zasadnicze znaczenie w klasyfikacji banknotów, które to z założeń projektowych są odpowiednio zróżnicowane, a informacja ilościowa wystąpienia danego zakresu kolorów w obrazie banknotu może dać interesującą informację o jego nominale.

Następnym parametrem charakteryzującym informację zawartą w obrazie jest histogram. Histogram jest funkcją opisującą ilość wystąpień punktów o danej jasności, jest to rozkład jasności obrazu. Możemy modelować histogram w celu poprawy kontrastu i jasności analizowanego obrazu. Rozciąganie histogramu poprawia kontrast obrazu i zapewnia całkowite wykorzystanie jego głębi.



Rys. 1 Przykładowy histogram rozkładu jasności obrazu.

Podstawą obliczeń parametrów statystycznych pierwszego rzędu jest histogram rozkładu jasności w obrazie.

Histogram [1] [3] [5] i jego parametry obliczane są w konkretnym wyznaczonym obszarze zainteresowania ROI (*ang. region of interest*). Do opisu obra-

zu banknotu (późniejszej jego klasyfikacji) wyznaczamy zestaw cech tekstur oparty o statystyczną metodę pierwszego rzędu bazującą na o następujących parametrach:

- Wartość oczekiwana,
- Odchylenie standardowe,
- Skośność histogramu,
- Kurioza.

Wartość oczekiwana jasności określa średnią jasność analizowanego obszaru obrazu i jest opisana wzorem:

$$\mu = \sum_{i=0}^{N-1} iP(i)$$

Gdzie:

N – liczba możliwych jasności i ,

$P(i)$ – prawdopodobieństwo punktu o jasności i ,

Odchylenie standardowe określa zmienność jasności wśród pikseli w rozpatrywanym obszarze analizy i jest określone zależnością:

$$\sigma = \sqrt{\sum_{i=0}^{N-1} (i - \mu)^2 P(i)}$$

Gdzie:

N – liczba możliwych jasności i ,

$P(i)$ – prawdopodobieństwo punktu o jasności i ,

Skośność histogramu jest wielkością opisującą stopień asymetrii rozkładu jasności. Wartość dodatnia skośności oznacza, że w badanym obszarze znajduje się więcej pikseli o jasności większej od wartości oczekiwanej i wartości te są

dalej rozłożone niż piksele o jasności mniejszej od wartości oczekiwanej. Skośność histogramu wyraża się wzorem:

$$S = \left[\sum_{i=0}^{N-1} (i - \mu)^3 P(i) \right] \frac{1}{\sigma^3}$$

Gdzie:

N – liczba możliwych jasności i ,

$P(i)$ – prawdopodobieństwo punktu o jasności i ,

Kurtoza jest parametrem opisującym stopień skupienia rozkładu jasności. Wartość dodatnia wskazuje na duże skupienie histogramu wokół wartości oczekiwanej, większe niż w przypadku rozkładu normalnego. Wartość ujemna mówi o tym, że rozkład jasności jest stosunkowo płaski. Kurtozę można wyznaczyć ze wzoru:

$$K = \left\{ \left[\sum_{i=0}^{N-1} (i - \mu)^4 P(i) \right] \frac{1}{\sigma^4} \right\} - 3$$

Gdzie:

N – liczba możliwych jasności i ,

$P(i)$ – prawdopodobieństwo punktu o jasności i ,

Automatyczna klasyfikacja nominałów banknotów – implementacja i wyniki badań

Implementacji rozważań teoretycznych dokonaliśmy we własnym programie, działającym pod systemem operacyjnym Windows, zrealizowanym w pakiecie programistycznym MS Visual C++ 6.0.

Obraz banknotów może zostać wprowadzony z pliku, lub też skanera płaskiego lub aparatu cyfrowego. Po odpowiednim ze skalowaniu, przetworzeniu wstępnym (tzn. redukcja szumów itp.) wyznaczamy wzorzec oparty o obliczenia statystyczne histogramu dla danego ROI. Doświadczalnie wielkość ROI przyjęliśmy na 15x15 pikseli (wycinek kwadratowy), co okazało się wielkością optymalną dla szeregu banknotów.




Rys. 2 Przykładowe wyznaczanie parametrów fragmentu tekstury obrazu

Tak jak to widać na Rys. 2, aby skonstruować wzorec do późniejszej klasyfikacji należy odnaleźć w obrazie banknotu obszary o jednolitej strukturze charakterystycznej dla danego banknotu, a następnie dodać je do zbioru cech opisujących wzorec.

Dla zilustrowania poprawnego wyznaczenia obszarów tekstur na zamieszczonym Rys. 3, umieszczone są czarne kwadraty obrysowujące fragmenty o jednolitej strukturze, która zostanie podczas klasyfikacji poddana analizie i porównaniu z badanym obrazem.




Rys. 3 Rozkład próbek obrazu służących do konstrukcji wzorca



Rys. 4 Przykładowe wartości parametrów w wybranych ROI.

Klasyfikacja banknotów

W obrębie danej tekstury banknotu wartości tych cech będą do siebie zbliżone. Dla różnych jasności oświetlenia fotografowanego banknotu wartość oczekiwana będzie się zmieniała, ale pozostałe parametry pozostaną bez zmian. Klasyfikacja czytanego obrazu (banknotu) polega na porównaniu zdefiniowanych wcześniej zbiorów cech banknotów wzorcowych wyznaczonych na podstawie próbek tekstur z aktualnie analizowanym, a nie całości obrazu wzorcowego i badanego. Używany algorytm przyporządkowywania badanego obiektu jest zmodyfikowaną wersją klasyfikatora minimalno-odległościowego k-NN[4]. Klasyfikacja odbywa się w cztero-wymiarowej przestrzeni cech (wartość oczekiwana, wariancja, skośność, kurtosis). Wartość każdej z cech w próbce obrazu jest reprezentowana przez współrzędną punktu umieszczonego w czterowymiarowej przestrzeni. Dla każdego wzorca jest obliczana odległość punktu danej próbki wzorca od punktu wyznaczonego na podstawie analizy badanego banknotu. Czynność ta jest powtarzana dla każdej grupy czterech cech w zdefiniowanym zbiorze próbek i sumowana. Czym mniejsza odległość tym różnica pomiędzy badanym obiektem a obiektem wzorcowym jest mniejsza. Decyzja o przyporządkowaniu analizowanego banknotu do określonego wzorca jest podejmowana na podstawie sumarycznej odległości punktów opisujących rozbieżność wartości cech w próbkach. Analizowany obraz zostaje zaklasyfikowany do wzorca, którego sumaryczna odległość jest najmniejsza.



Rys. 5 Okno definicji zestawu wzorców oraz wynik porównania tego samego nominału banknotu

Na Rys. 5 widać porównanie tego samego nominału banknotu dla dwóch różnych egzemplarzy. Jak widać błędy nie są zbyt duże, jedynie skośność czy też kurtosis wykazują większy błąd klasyfikacji, co spowodowane jest zapewne zabrudzeniami i uszkodzeniami mechanicznymi banknotów.

Opisany sposób znacznie skraca czas analizy i klasyfikacji, gdyż cyfrowe dane opisujące zestaw cech dla jednego wzorca zajmują od 1 KB do 10 KB, natomiast w przypadku zdjęcia banknotu jest to aż 1 MB, w związku, z czym ilość danych podlegających analizie jest od 100 do 1000 razy mniejsza. Taka metoda klasyfikacji w dużo lepiej nadaje się do implementacji w systemach wbudowanych, choćby ze względu na wymaganą ilość pamięci do przechowywania wzorców.

Źródła

1. R. M. Haralick, K. Shanmugam, I. Einstein, *Textural Features for Image Classification*; IEEE Transaction on Systems, Man and Cybernetics, Vol. SMC-3, No 6, November 1973, pp 610-621.
2. H. Kassyk-Rokicka, *Mierniki statystyczne*; Państwowe Wydawnictwo Ekonomiczne, Warszawa 1986.
3. A. Materka, *Elementy cyfrowego przetwarzania i analizy obrazów*; Państwowe Wydawnictwo Naukowe, Warszawa-Lódź 1991.
4. R. Tadeusiewicz, M. Flasiński, *Rozpoznawanie obrazów*; Państwowe Wydawnictwo Naukowe, Warszawa 1991.
5. R. Tadeusiewicz, *Systemy wizyjne robotów przemysłowych*; Wydawnictwa Naukowo-Techniczne, Warszawa 1992.