

WYKORZYSTANIE SZTUCZNYCH SIECI NEURONOWYCH DO WYKRYWANIA I ROZPOZNAWANIA TABLIC REJESTRACYJNYCH NA ZDJĘCIACH POJAZDÓW

Maciej HUZAREK¹, Tomasz A. RUTKOWSKI²

Politechnika Gdańska, Wydział Elektrotechniki i Automatyki

1. tel.: 58 347 1742 e-mail: maciej.huzarek@gmail.com

2. tel.: 58 347 1206 e-mail: tomasz.adam.rutkowski@pg.gda.pl

Streszczenie: W artykule przedstawiono koncepcję algorytmu wykrywania i rozpoznawania tablic rejestracyjnych (AWiRTR) na obrazach cyfrowych pojazdów. Detekcja i lokalizacja tablic rejestracyjnych oraz wyodrębnienie z obrazu tablicy rejestracyjnej poszczególnych znaków odbywa się z wykorzystaniem podstawowych technik przetwarzania obrazu (przekształcenia morfologiczne, wykrywanie krawędzi) jak i podstawowych danych statystycznych obiektów wykrytych w obrazie (np. stosunek szerokość do wysokość obiektu). Natomiast za rozpoznawanie poszczególnych znaków odpowiedzialna jest wielowarstwowa, jednokierunkowa sztuczna sieć neuronowa. Przedstawiony algorytm został zaimplementowany i zweryfikowany w środowisku Matlab/Simulink. Pomimo wykorzystania w algorytmie AWiRTR dobrze znanych z literatury metod lokalizacji, segmentacji i rozpoznawania wzorców, otrzymane w trakcie weryfikacji algorytmu wyniki wskazują jego efektywność na poziomie 96,26%. Jest ona porównywalna do efektywności innych algorytmów AWiRTR opisywanych w literaturze.

Słowa kluczowe: przetwarzanie obrazu, lokalizacja obiektów, rozpoznawanie wzorców, sieci neuronowe.

1. WPROWADZENIE

Systemy automatycznego wykrywania i rozpoznawania tablic rejestracyjnych AWiRTR (ang. Automatic License Plate Recognition, ALPR) pełnią obecnie ważną rolę w systemach monitorowania i nadzorowania ruchu pojazdów. Wynika to m.in. z potrzeby identyfikowania pojazdów znajdujących się na drodze np. w celu zapewnienia ich płynnego przejazdu przez nadzorowany odcinek drogi, kontroli dostępu, czy naliczania opłat parkingowych na kontrolowanym obszarze. Pierwsze komercyjne urządzenia tego typu pojawiły się w latach 90 XX wieku [1]. Obecnie nadal prowadzone są badania nad poszukiwaniem efektywnych metod przetwarzania w czasie rzeczywistym cyfrowych obrazów pojazdów, wykonywanych nie tylko w sytuacjach statycznych ale i dynamicznych, w zróżnicowanych warunkach oświetlenia, pod różnymi kątami nachylenia, w różnych dystansach od pojazdu czy różnego typu zabrudzeniami na tablicach rejestracyjnych pojazdów.

Typowy algorytm AWiRTR [1,2,3,4,5] charakteryzuje się następującym schematem działania: wykrycie i lokalizacja tablicy rejestracyjnej na obrazie cyfrowym pojazdu, wyodrębnienie znaków znajdujących się na tablicy rejestracyjnej pojazdu, oraz rozpoznanie znaków z tablicy

rejestracyjnej. W literaturze, do realizacji zadania lokalizacji tablicy, spotyka się przykłady zastosowania wielu technik, które często łączy się ze sobą w celu zwiększenia ich efektywności, są to m.in.: wykrywanie krawędzi [1, 3], metody morfologiczne [1, 4], kwantyzacja wektorowa [2], wykorzystanie profili jasności (histogramów) [5], czy sztucznych sieci neuronowych [2]. Proces segmentacji, wyodrębniania poszczególnych znaków z obrazu tablicy jest typowo realizowany z wykorzystaniem przekształceń morfologicznych [2], metod rzutu profili jasności [5] lub analizie obszarów spójności połączonej z analizą danych statystycznych obiektów wykrytych w obrazie [4] ze stałymi [3, 4] lub adaptowalnymi [5] progami decyzyjnymi. Natomiast zadanie rozpoznawania pojedynczych znaków lub łącznie wszystkich znaków, wykonywane jest typowo z wykorzystaniem: metody korelacji cech [4, 6], metody ukrytych modeli Markowa [6] czy metody wektorów nośnych lub sztucznych sieci neuronowych [2, 6, 7].

Algorytm AWiRTR prezentowany w artykule nie jest nową koncepcją, bazuje na typowej i znanej z literatury strukturze oraz metodach, które stosuje się w tego typu algorytmach [1, 2, 3, 4, 5, 6, 7]. W celu wykrywania i rozpoznawania prostokątnych tablic rejestracyjnych wykorzystano w nim następujące rozwiązania: mechanizm wykrywania krawędzi [1, 3], przekształcenia morfologiczne obrazu [1, 4], analizę spójności i dane statystyczne obiektów występujących na obrazie [1, 2, 5], oraz sztuczną sieć neuronową jako uniwersalny klasyfikator [2, 6, 7, 8]. Algorytm został zaimplementowany i zweryfikowany w środowisku szybkiego prototypowania Matlab/Simulink [9, 10] z wykorzystaniem funkcji przyborników: Image Processing Toolbox [9] oraz Neural Network Toolbox [9].

W związku z ochroną danych właścicieli aut, prezentowane w artykule obrazy cyfrowe tablic rejestracyjnych pojazdów zostały częściowo zamazane.

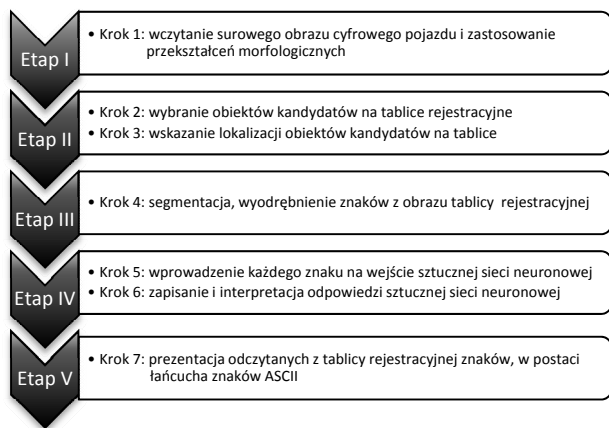
2. STRUKTURA ALGORYTMU AWiRTR

Strukturę algorytmu AWiRTR przedstawiono na rysunku 1. Można w niej wyodrębnić pięć głównych etapów, które obejmują proces przetwarzania obrazu od wczytania jego surowej wersji cyfrowej do prezentacji wyniku, w postaci łańcucha znaków ASCII zawierającego rozpoznane na tablicy rejestracyjnej znaki.

Kolejne etapy algorytmu odpowiadają za:

- etap I: wczytanie i obróbkę obrazu cyfrowego pojazdu,
- etap II: wykrycie i lokalizację tablicy na obrazie pojazdu,
- etap III: segmentację znaków tablicy rejestracyjnej,
- etap IV: rozpoznawanie i klasyfikację znaków z tablicy,
- etap V: prezentację wyniku.

W ramach przedstawionych etapów zdefiniowano siedem kolejnych kroków (rys. 1). W każdym z nich, dane opisujące przetwarzany obraz cyfrowy posiadają inny zestaw cech charakterystycznych.



Rys. 1. Etapy i kroki prezentowanego algorytmu AWiRTR

2.1. Etap I: wczytanie i obróbka obrazu pojazdu

Etap I związany jest z wczytaniem oraz wstępną obróbką surowego obrazu cyfrowego pojazdu (krok 1 na rysunku 1). Na początku zostaje wczytany obraz cyfrowy pojazdu o rozdzielczości co mniejszej 2 megapikseli i jest on konwertowany do rozmiaru 500x752 pikseli. Rozdzielczość i rozmiar obrazu cyfrowego zostały dobrane eksperymentalnie w trakcie etapu weryfikacji i testów algorytmu AWiRTR, z uwzględnieniem czasu obliczeń numerycznych oraz efektywności działania jego poszczególnych etapów (liczba błędnych decyzji mniejsza od 10%). Aby uniknąć nadmiernego wpływu oświetlenia oraz szumów na obrazie, przestrzeń barw modelu kolorów RGB zostaje zamieniona na przestrzeń barw modelu YCBCR [8]. Po tej operacji obraz cyfrowy jest poddawane szeregowi przekształceń morfologicznych umożliwiających:

- wykrycie krawędzi obiektów (nie zawsze wykryte krawędzie poszczególnych obiektów łączą się w figury zamknięte),
- łączenie małych szczegółów na dużym obszarze w większe obiekty (pozwala uzyskać obiekty o połączonych krawędziach),
- operacje wypełniania pustych przestrzeni, tzw. dziur, (zbiór pikseli tła znajdujących się wewnątrz połączonych krawędzi obiektu),
- usunięcie z obrazu obiektów nieistotnych detali.

Podstawowym celem tych przekształceń jest wyróżnienie na obrazie obiektów o kształtach przypominających kształt tablicy rejestracyjnej. Przykładowy wynik ich działania na surowym obrazie cyfrowym został przedstawiony na rysunku 2. Wyróżnione na biało obszary (rys.2), oznaczają obszary w których może znajdować się tablica rejestracyjna.

2.2. Etap II: wykrywanie i lokalizacja tablicy na obrazie

Celem Etapu II algorytmu AWiRTR jest identyfikacja tablicy rejestracyjnej spośród wszystkich wyróżnionych w trakcie Etapu I obszarów, a następnie wskazanie jej



Rys. 2. Wynik działania przekształceń Etapu I algorytmu AWiRTR, krok 1: przykładowy „surowy” obraz cyfrowy początkowy (lewy) i obraz cyfrowy po przekształceniach (prawy)

lokalizacji na analizowanym obrazie (kroki 2 i 3 na rysunku 1).

Rozpatrywany na tym etapie obraz cyfrowy jest poddawany analizie obszarów spójności, umożliwiającej identyfikację i indeksację wszystkich wykrytych obiektów. Jej dopełnieniem jest zebranie danych statystycznych, związanych z każdym wykrytym w obrazie obiektem tj. jego rozmiarem, położeniem, informacją o kształcie itp. Na podstawie tego typu danych zdefiniowano wskaźniki, które umożliwiają klasyfikację rozważanych obiektów do grupy kandydatów na tablice rejestracyjne. Do zestawu głównych wskaźników, mających największe znaczenie na tym etapie działania algorytmu zalicza się:

- stosunek szerokości do wysokości obrazu obiektu kandydata na tablicę rejestracyjną, który przyjmuje się że powinien być większy od 3,2 i mniejszy od 6,2 (dla tablicy rzeczywistej jest on równy 4.56),
- obwód kandydata, który przyjmuje się że powinien być większy od 350 pikseli,
- stosunek ilości białych pikseli w obiekcie (obraz nieprzekształcony) do pola powierzchni kandydata, który przyjmuje się że powinien być większy od 0,6,
- czy wybrany kandydat nie jest elementem składowym innego obiektu kandydata,
- oraz czy w obiekcie kandydacie znajduje się od 4 do 8 innych obiektów (które mogą być znakami).

Wartości graniczne (progi decyzyjne) poszczególnych wskaźników dobrano eksperymentalnie analizując efektywność procesu wykrywania i lokalizacji tablic z wykorzystaniem zestawu obrazów cyfrowych pojazdów wykonanych pod różnymi kątami ($\pm 45^\circ$) oraz w różnych odległościach od systemu akwizycji obrazu (od 1 m do 9 m). Założono przy tym, że liczba popełnianych błędów na tym etapie powinna być mniejsza od 10%.

Na rysunku 3 strzałką wskazano lokalizację obiektu, który na podstawie przedstawionych wyżej wskaźników został zidentyfikowany na obrazie cyfrowym pojazdu jako tablica rejestracyjna (rys. 3 - prawy).



Rys. 3. Wynik działania wykrywania i lokalizacji tablicy na obrazie cyfrowym - Etap II algorytmu AWiRTR, kroki 2 i 3: przykładowy surowy obraz początkowy (lewy) oraz po przekształceniach (prawy), ze wskazaną lokalizacją tablicy rejestracyjnej

2.3. Etap III: segmentacja znaków tablicy rejestracyjnej

Po zakończeniu Etapu II następuje wykonanie operacji wyodrębnienia każdego ze znaków znajdujących się na tablicy rejestracyjnej (krok 4 na rysunku 1).

W pierwszej kolejności zostaje wczytany fragment surowego obrazu cyfrowego, który został już wcześniej zidentyfikowany jako tablica rejestracyjna (rys. 3). Obraz ten poddaje się kolejno przekształceniu z przestrzeni RGB na obraz w odcieniach szarości, oraz analizie spójności. Następnie, na podstawie zdefiniowanych w tym celu wskaźników zostają wybrane tylko takie obiekty które posiadają cechy znaków (rys. 4). Przy wyodrębnianiu poszczególnych znaków, jako istotne wskaźniki wykorzystano m.in.:

- stosunek wysokości do szerokości obiektu kandydata na znak, który przyjmuje się że powinien być większy od 1,4 i mniejszy od 3,
- liczba obiektów znajdujących się wokół kandydata, która powinna być w granicach od 1 do 2,
- odpowiednie położenie środka masy ciężkości kandydata (wzdłuż poziomej osi tablicy),
- oraz procent wypełnionej powierzchni przez obraz kandydata po przekształceniach do 80%.

Wartości graniczne poszczególnych wskaźników dobrano również eksperymentalnie analizując efektywność procesu wyodrębniania znaków z obrazu cyfrowego tablicy rejestracyjnej, który był prezentowany jako wynik Etapu II algorytmu. Założono przy tym, że liczba popełnianych błędów na tym etapie powinna być mniejsza od 10 %.

Dodatkowo, ze wszystkich obiektów sklasyfikowanych jako obrazy znaków, odrzucane są obszary wewnętrzne, które są następnie wypełniane. Przykład takiej operacji dla znaku/litery „R” przedstawiono na rysunku 5.

Wyselekcjonowane i przetworzone obrazy znaków zostają przygotowane do ich klasyfikacji (rozpoznania) przez sztuczną sieć neuronową w Etapie IV algorytmu. Każdy znak w postaci binarnej jest postrzegany jako macierz, której elementami są wyłącznie zera i jedynki. Wszystkie znaki są następnie skalowane do standardowego rozmiaru o wysokości 44 pikseli i szerokości 33 pikseli. Następnie macierze poszczególnych znaków są konwertowane na odpowiednie wektory (o liczbie wierszy



Rys. 4. Wynik działania segmentacji znaków na obrazie cyfrowym tablicy rejestracyjnej z Etapu III algorytmu AWiRTR, kroki 4: wczytany obraz RGB tablicy rejestracyjnej (górną część) oraz obraz po przekształceniach i korekcji pochyleń (dolną część)



Rys. 5. Zestawienie operacji na znakach, kolejno od lewej: wykryte krawędzie znaku, znak po odrzuceniu wnętrza i znak po wypełnieniu

równej $44 \times 33 = 1320$), które w kolejnym etapie algorytmu podawane są na wejścia sztucznej sieci neuronowej.

Na etapie weryfikacji i testów Etapu IV algorytmu AWiRTR (punkt 2.4) zaobserwowano pozytywny wpływ wspomnianego przekształcenia, odrzucenia i wypełnienia obszaru wewnętrznego znaków (rys. 5), na efektywność procesu ich rozpoznawania. Przykładowo, w przypadku znaków „E”, „R” i „B” efektywność rozpoznawania wzrosła średnio o kilkanaście procent bez negatywnego wpływu na efektywności rozpoznawania pozostałych znaków. Wiąże się to z odpowiednim zróżnicowaniem cech geometrycznych układu pikseli danego znaku prezentowanego na wejściu przyjętej struktury sztucznej sieci neuronowej. Wynika stąd również przyjęty standardowy rozmiar znaków (44×33 piksele), który również dobrano w ramach tych samych testów.

2.4. Etap IV: rozpoznawanie i klasyfikacja znaków z tablicy rejestracyjnej


Wykorzystanie sztucznej sieci neuronowych w zadaniu rozpoznawania znaków implikuje konieczność przygotowania odpowiednich wzorców znaków, które będzie można wykorzystać na etapie jej uczenia i weryfikacji. Pozyskanie różnorodnych wzorców tablic rejestracyjnych nie jest procesem trywialnym. W związku z tym, odpowiednio zakłócone wzorce znaków zostały wygenerowane komputerowo z wykorzystaniem czcionki ARKLAS stosowanej w produkcji tablic rejestracyjnych [11]. Operacja ta miała na celu wzbogacenie posiadanej bazy 120 rzeczywistych zdjęć pojazdów. Każdy z przygotowanych wzorców znaków został przekształcony do postaci przedstawionej na rysunku 5. W ten sposób przygotowano 100 próbek każdego, spośród 36 znaków (litery od A do Z i cyfry od 0 do 9).

Rozpoznawanie i klasyfikacja znaków z tablicy rejestracyjnej, w ramach prezentowanego algorytmu AWiRTR, realizowana jest przez jednokierunkową, wielowarstwową sztuczną sieć neuronową z sigmoidalnymi funkcjami aktywacji (rys. 6).

W ramach testów prowadzących do określenia struktury sieci neuronowej, kierowano się kryteriami, takimi jak: czas uczenia – zakładano, że powinien być krótszy niż 15 minut; oraz efektywność utworzonej sieci neuronowej, mierzona liczbą popełnianych błędów – zakładano, że powinna być mniejsza od 10%.

Na etapach uczenia i weryfikacji działania sztucznej sieci neuronowej, posłużono się dwoma różnymi zbiorami wzorców

Działanie klasyfiaktora (rys. 6) polega na prezentowaniu sieci neuronowej wektora o rozmiarze 1320×1 , który opisuje cechy geometrycznego układu pikseli danego znaku. Jako wynik sieć neuronowa na wyjściu generuje 36 wartości z zakresu $\langle 0,1 \rangle$, interpretowanych jako wektor wyjściowy (rozmiar 36×1). Pozycja największej wartości w wektorze wyjściowym, identyfikuje odpowiednio rozpoznany znak (pierwsze 26 pozycji to litery od A do Z, a kolejne to liczby od 0 do 9).



Rys. 6. Struktura i przykład działania sztucznej sieci neuronowej

2.5. Etap V: prezentacja wyniku

Na ostatnim etapie działania algorytmu AWiRTR następuje prezentacja wyniku (krok 7 na rysunku 1) w postaci łańcucha znaków ASCII zawierającego odczytane z obrazu tablicy rejestracyjnej znaki. Wynik w tej postaci można wykorzystać w innych systemach komputerowych (np. różnego rodzaju rejestrach).

3. WERYFIKACJA ALGORYTMU AWiRTR

Efektywność, jakość przedstawionego algorytmu AWiRTR oszacowano poprzez określenie efektywności jego trzech najważniejszych etapów: lokalizacji tablicy rejestracyjnej (Etap II), wyizolowania poszczególnych znaków z obrazu tablicy rejestracyjnej (Etap III), oraz rozpoznania znaków odnalezionych na tablicy rejestracyjnej (Etap IV). Wykorzystano w tym celu zbiór 120 zebranych obrazów cyfrowych rzeczywistych pojazdów, z którego wybrano losowo 50 obrazów i następnie poddano je analizie przez opisany algorytm AWiRTR. Szczegółowe wyniki testów zestawiono w tabeli 1.

Otrzymane wyniki wskazują efektywność na poziomie 98 % w zadaniu wykrywania i lokalizacji tablicy rejestracyjnej na obrazach cyfrowych pojazdów. Natomiast, efektywność wyodrębniania poszczególnych znaków z obrazu tablicy rejestracyjnej oraz rozpoznawanie poszczególnych znaków z tablicy rejestracyjnej oszacowano, odpowiednio na poziomach: 95,69 % i 95,11 %. Średnia efektywność algorytmu AWiRTR, obejmującą te trzy etapy szacuje się na poziomie 96,26 %. Mimo iż metody wykorzystane do realizacji poszczególnych etapów algorytmu należą do podstawowych oraz dobrze znanych z literatury, to uzyskana efektywność jest porównywalna do efektywności innych algorytmów AWiRTR [1,2,3,4,5]. Poprzez odpowiednią parametryzację wykorzystanych w algorytmie metod, udało się również zrealizować stawiane przed nim wymagania związane z efektywnością poszczególnych etapów określoną na poziomie 90 %.

Tabela 1. Efektywność etapów algorytmu AWiRTR

l.p.	Etap algorytmu AWiRTR	Wyniki poprawne / liczba testów	% poprawnych operacji
1	Etap II	49/50	98 %
2	Etap III	333/348	95,69 %
3	Etap IV	331/348	95,11 %

4. WNIOSKI KOŃCOWE

Przedstawiony w artykule algorytm AWiRTR charakteryzuje się wysoką efektywnością, co potwierdzają wyniki przedstawione w tabeli 1. Dalszą poprawę efektywności algorytmu AWiRTR można uzyskać np. poprzez: poprawę jakości wykonywanych zdjęć, rozszerzenie informacji wejściowej do sieci neuronowej o cechy charakterystyczne rozróżnianych wzorców, wykorzystanie zdjęć wykonanych w technologii podczerwieni, czy adaptację progów decyzyjnych wskaźników wykorzystywanych na etapach II i III algorytmu.

5. BIBLIOGRAFIA

1. Smith S.W.: The Scientist and Engineer's Guide to Digital Signal Processing, Second Edition, California, 1999.
2. Porikli F., Kocak T.: Robust License Plate Detection Using Covariance Descriptor in a Neural Network Framework, IEEE, 2006.
3. Tarabek P.: Fast license plate detection based on edge density and integral edge image, IEEE, 2011.
4. Kasaei S.: Extraction and recognition of the vehicle license plate for passing under outside environment, IEEE, 2011.
5. Wenjing J., Xiangjian H., Qiang W.: Segmenting Characters from License Plate Images with Little Prior Knowledge, IEEE, 2010.
6. Kwiatkowski W.: Metody automatycznego rozpoznawania wzorców, BELStudio, Warszawa, 2007.
7. Osowski S.: Sieci neuronowe do przetwarzania informacji, Oficyna Wydawnicza PW, Warszawa, 2000.
8. Swędrowski L., Duzinkiewicz K., Grochowski M., Rutkowski T.: Use of Neural Networks in Diagnostics of Rolling-Element Bearing of the Induction Motor, Key Engineering Materials, vol. 558, 2014.
9. Pakiet oprogramowania Matlab/Simulink, <http://www.mathworks.com>, (dostęp 11.2015).
10. Huzarek M.: Wykrywanie i rozpoznawanie obiektów dynamicznych przy wykorzystaniu sztucznych sieci neuronowych, Politechnika Gdańska, Gdańsk, 2012.
11. Czcionka ARKLAS, <http://polskietablice.prv.pl>, (dostęp 11.2015).

DETECTION AND RECOGNITION OF REGISTRATION PLATES ON PICTURES OF VEHICLES USING ARTIFICIAL NEURAL NETWORK

A license plate detection and recognition system has basically three modules for: localization of the plate region using the digital image of the car, extraction of the characters from digital image of the license plate, and recognition of the characters using a suitable identification method. In this paper, an algorithm is designed that can localize of the plate and extract of the characters from digital image of the license plate with the basics image processing techniques (morphological transformations, edge detection) and with the statistical data (e.g. width height ratio) of the objects identified in the analyzed digital image. It is done at the second and third stage of the presented algorithm, respectively. Finally, at the fourth stage of the presented algorithm, the character recognition is done by multilayer, one directional artificial neural network. Algorithm was implemented and verified in the Matlab/Simulink environment. Experimental results demonstrate promising efficiency of the proposed algorithm: 98% in the task of license plate localization, 95,69% in the task of characters extraction, and 95,11% in the task of characters recognition.

Keywords: image processing, objects localization, pattern recognition, neural networks.