

LICENCE PLATE RECOGNITION USING FEEDFORWARD NEURAL NETWORKS

Matej Kseneman¹, Dušan Gleich¹

¹Fakulteta za elektrotehniko, računalništvo in informatiko, Maribor, Slovenija

Key words: licence plate recognition, colour segmentation, colour space, feedforward neural networks, OCR engine

Abstract: Licence plate recognition presented in this paper is used to identify vehicles by their licence plate numbers. This technology can be widely used for paying pay-rolls, in opening parking garage door, traffic control /1/, etc. This paper presents an algorithm for licence plate recognition, shown in Fig. 1. The algorithm itself is divided into two parts, the first part extracts licence plate and the optical character recognition is described in the second part of the paper. In the first part of the paper three methods for licence plate recognition are presented. White pixels in an image can be detected using threshold method. Reference photo is shown in Fig. 2; meanwhile the experimental result of threshold method is shown in Fig. 3. The second method is based on 2D correlation, which uses segmentation in order to limit search area. The segmentation technique is performed using (1), but it is computationally very demanding (2). The result of this phase is shown in Fig 4. The method with Euclidian norm (3) uses Freeman chain code with interior pixels, but it is user dependent, because the user has to input one licence plate pixel (the result is shown in Fig. 5). The first method is used as method for licence plate recognition. The dilatation algorithm is used to fill up the whole plate with the same pixels. The dilated picture is shown in Fig 6. The algorithm detects the angle of licence plate, as shown in Fig. 7. Rotated and isolated licence plate is quantised and rescaled using a histogram method. The extracted licence plate is further shown in Fig. 8. The edges cut from detected licence plate and extracted binary images are shown in Figs. 9–10, respectively. A method called peak-to-valley is used to extract each individual character, which sums picture's columns and creates a histogram. By comparing sums to specified threshold, characters are detected. Characters are recognised using feed-forward neural networks. This network has 200 input neurons and 36 output neurons. Learning is accomplished through supervised learning of back-propagation technique. The whole structure of neural network is shown in Fig. 11. The results presented in Table 1 show that the overall efficiency of OCR engine is 96% when the recognition is applied on extracted licence plate

Razpoznavanje registrskih tablic vozila z uporabo feedforward nevronske mreže

Kjučne besede: razpoznavanje registrske tablice, segmentacija barve, barvni prostor, nevronske mreže, OCR sistem

Izvleček: Ideja razpoznavanja registrskih tablic vozila (RTV) je relativno stara. Z razvojem informacijskih tehnologij in zmogljivosti računalniških centralno-procesnih enot je postala implementacija zelo zahtevnih algoritmov zanimiva in uporabna. V tem članku bomo predstavili zmogljiv in robusten algoritem za zaznavo slovenskih RTV in zaznavo njenih znakov z uporabo t.i. feedforward nevronske mreže. V prvem delu članka predstavljamo tri algoritme za izločitev RTV, in sicer s pomočjo pragovne funkcije, 2D korelacije in Evklidske norme. Nad prepoznanoto RTV se opravi kvantizacija in normalizacija za odstranitev šuma v sliki, skaliranje in rotacija na prizetenost velikosti in orientiranosti. V drugem delu članka pa predstavljamo algoritem za prepoznavanje znakov na RTV s pomočjo sistema za prepoznavanje znakov (ang. Optical Character Recognition - OCR). Sistem OCR je sestavljen iz feedforward tipa nevronske mreže. Predlagani algoritem je zmožen prepozнатi 96% izmed vseh testiranih RTV.

1. Uvod

S povečanjem zmogljivosti današnjih centralnih procesorskih enot in uporabi multimedijskih tehnologij v vsakdanjem življenju se prav tako povečuje potreba po avtomatizaciji vsakdanjih procesov. V tem članku bomo predstavili avtomatsko razpoznavanje RTV. Implementacijo predstavljenega algoritma je možno uvesti v plačilo cestnih, odpiranje zapornic garažnih hiš, pri nadzoru prometa, itd. Obstaja mnogo rešitev za avtomatizacijo RTV.

Yohimori /2/ je predlagal algoritem, ki primerja povprečne osvetlitve registrske tablice s podanimi pragovi. Porikli /3/ razpoznavajo RTV preko kovariančne matrike in nevronske mreže. Podobno storiti tudi Matas /4/, kateri za povečanje robustnosti pri razpoznavi uporabi invariantne deskriptorje in te rezultate pelje na nevronske mreže.

Prav to delo nas je motiviralo, da smo izvedli algoritem s pomočjo nevronske mreže. V tem članku smo avtomatizirali razpoznavo RTV. Slika 1 prikazuje predlagani algoritem za razpoznavo RTV.



Slika 1. Blok diagram poteka razpoznavane.

Fig. 1. Block diagram of recognition sequence.

Na izvorni sliki algoritem prične z iskanjem bele barve, kjer se nato v sliki belih segmentov išče pravokotnik. Na tem mestu se lahko pojavi nepravilna izbira pravokotnika, kajti slika belih segmentov je polna artefaktov (majhnih segmentov bele barve), ki so posledica leska in drugih stvari bele barve. Problem poskusimo odpraviti z uporabo segmentacije slike, nad katero napravimo 2D konvolucijo oz. korelacijo. Podoben pristop napravimo tudi s tretjo metodo, kjer algoritem za iskanje tablice uporablja Evklidsko normo /5/.

Iskanje pravokotnika se vrši preko dilatacije (odebelitve) belih segmentov, katere smisel je zapolniti črna področja na registrski tablici, na katerih se prvotno nahajajo znaki vključno z grbom. Z izbiro manjšega področja registrske tablice, se algoritem osredotoči na iskanje ravnih linij, preko katerih določi kot rotacijo RTV. Kot rotacije določimo z uporabo Radonove transformacije /6/, s katero se nato celotna slika rotira tako, da se RTV pomakne v horizontalni položaj. Vzrok nagnjenosti gre iskati v krivinah na cestišču in kotom gledanja kamere.

Na manjši sliki ponovno opravimo iskanje pravokotnika, rezultat tega pa je slika registrske tablice v naravni velikosti slike in horizontalnem položaju. Na koncu se izvede še segmentacija znakov, kjer izločimo regije posameznih znakov, z OCR sistemom temelječim na nevronskih mrežah pa izvedemo razpoznavo znakov.

2. Zaznavanje registrske tablice

To poglavje podaja podrobno predstavitev posameznih korakov predlaganega algoritma, in sicer si koraki sledijo v vrstnem redu, kot so predstavljeni na sliki 1.

2.1. Uporaba različnih metod zaznavanja

Iskanje bele barve

Iskanje bele barve izvedemo v barvnem prostoru XYZ /7/, v katerem se prvotne 3 dimenzijske RGB prostora pretvorijo v 2 dimenzijske, tretja komponenta pa predstavlja svetlost. Na ta način lažje podamo meje, v katerih se nahaja bela barva, kar je ključnega pomena pri snovanju algoritma. Algoritem preveri ali je dani slikovni element bele barve ali ne. V primeru, da je, ga označi na izhodni sliki, kar prikazuje slika 3, medtem ko slika 2 prikazuje referenčno sliko.

2D korelacija

Razčlenjevanje slike v segmente s podobnimi lastnostmi imenujemo segmentacija slike. Pogosto predstavlja atribut svetlost barve pri monokromatski sliki, barvne komponente



Slika 2. Referenčna fotografija.
Fig. 2. Reference photography.

pri barvi sliki, lahko pa upoštevamo tudi robove objektov in njihove tekture, skratka možnosti je veliko. Po drugi strani pa nam segmentacija ne daje informacij o klasifikaciji segmentov, prav tako tudi o njihovih medsebojnih relacijah. Segmentacija je odvisna od osvetlitve slike, kar pa vpliva tudi na zaznavanje registrske tablice. Efekt ublažimo z izvedbo normalizacije barvnih komponent z vsoto trojice RGB /8-10/.



Slika 3. Najdeni beli slikovni elementi.
Fig. 3. Extracted white pixels.

Algoritem segmentacije deluje na sledeč način: najprej se izvede inicializacija, ki predstavi vse piksele kot neoznačene elemente, nato pa algoritem izbere prvi neoznačeni piksel, preko katerega se s pomočjo enačbe (1) izračuna razdalja pripadnosti 1. segmentu.

$$d_{i,j} = \sqrt{(R_p - R_{i,j})^2 + (G_p - G_{i,j})^2 + (B_p - B_{i,j})^2} \quad (1)$$

kjer je:

- d – razdalja,
- i, j – indeksa simbolično nakazujeta, da gre za matriko, kjer indeks i predstavlja vrstico in indeks j predstavlja stolpec trenutno izbranega slikovnega elementa,
- p – vrednosti barvne komponente slikovnega elementa, s katerim računamo razdaljo in
- R, G, B – barvne komponente.

S 1. segmentom se označijo tudi slikovni elementi, katerih vrednost razdalje je pod vnaprej podano vrednostjo praga, ki eksperimentalno določeno znaša 0.1 (vrednost je manjša od 1 zaradi normalizacije barv). Slika 2 prikazuje referenčno fotografijo, za katero algoritem najde 52 segmentov.

Iz dobljenih segmentov določimo področje RTV preko 2D konvolucije oz. korelacije, kar opisuje enačba (2) /11/.

$$c(n_1, n_2) = \sum_{k_1=-\infty}^{\infty} \sum_{k_2=-\infty}^{\infty} a(k_1, k_2) b(n_1 - k_1, n_2 - k_2), \quad (2)$$

kjer sta: a in b parametra funkcije diskretnega argumenta n_1 in n_2 .

Poudariti je potrebno, da se v enačbi (2) meji vsot spremenita na vrednost, ki zaznamuje širino in višino slike.

Algoritem korelacije se izvede s pravokotno masko, katere dimenzijs so izbrane glede na velikost RTV. Prvotna maska dimenzijs 60×190 je sestavljena tako, da znaša vrednost 1 na področju med 10. in 50. vrstico, kot tudi med 25. in 165. stolpcem, vendar so te vrednosti do prvotne dimenzijs obrobljene z nasprotnimi vrednostmi, torej -1. Algoritem išče RTV na vseh segmentih, a le na enem segmentu ima korelacijska funkcija maksimalno vrednost. Za prikaz rezultata se v sliki uporabi točko z maksimalno vrednostjo, kateri očrtamo pravokotnik velikosti 140×40 , kar prikazuje slika 4.



*Slika 4. Rezultat segmentacije in 2D korelacije.
Fig. 4. Result of segmentation and 2D correlation.*

Evklidska norma

Algoritem temelji na principu iskanja najprej v širino /12/. Zaradi samega koncepta delovanja algoritma potrebujemo dva seznama, in sicer označenih in neoznačenih slikovnih elementov. Evklidsko normo izračunamo preko enačbe (3) /5/.

(3)

Algoritem pri kreiranju polja označenih slikovnih elementov uporablja strategijo iskanja v vseh osmih smereh (gor, dol, levo in desno ter v ostalih 4 glavnih diagonalnih smereh). Ob zagonu algoritma, se le-ta postavi na mesto prvega neoznačenega elementa, ga označi v seznamu označenih slikovnih elementov in izračuna Evklidsko normo. Iz tega mesta pričnemo iskanje v vseh osmih smereh, kjer se v seznam označenih elementov vnesejo le neoznačeni elementi. Prag je nastavljen na 10% vrednosti trenutno obravnavanega slikovnega elementa, kjer se slikovni elementi vnašajo v posebno matriko, v kateri so le slikovni elementi, ki zadovoljujejo vse opisane pogoje. Algoritem se konča, ko v seznamu neoznačenih elementov ne najdemo več novega še neoznačenega elementa.

Pri tej metodi je najpomembnejši začetni slikovni element, ki se mora nahajati znotraj področja RTV, saj se z njim nastavi vrednost praga in prične se iskanje ostalih slikovnih

elementov. To je sicer velika slabost, saj s tem izgubimo avtonomnost sistema, a je sam algoritem računsko zelo učinkovit. Problem odpravimo tako, da kombiniramo več metod. Kombinacija metode 2D korelacije in izračuna Evklidske norme dajeta dobre rezultate, saj metoda 2D korelacije vrne centralno točko, kjer je potrebno biti pazljiv, da le-ta ni drugačne barve (npr. črne). Tako je algoritem potrebno nadgraditi, da le-ta sam preveri ali je centralna točka primerna ali ne in v slednjem primeru se premakne do prve primerne točke oz. slikovnega elementa. Rezultat tega algoritma prikazuje slika 5. Kombinacija obeh metod je sila učinkovita, a je računsko izjemno potratna.



*Slika 5. Rezultat uporabe Evklidske norme.
Fig. 5. Result using Euclidian norm.*



*Slika 6. Dilatacija področij bele barve.
Fig. 6. Dilatation of white colour areas.*

2.2. Omejitev področja iskanja registrske tablice

V sliki z zaznano RTV, ki jo dobimo po eni izmed prej naštetih metod algoritem išče pravokotnik. Smiselno je izvesti dilatacijo slike (razširjanje slike) /13/, saj se s tem doseže zapolnitve praznih regij, ki so ostale na mestih znakov in grba. To zelo olajša iskanje pravokotnika, kajti ta korak dodobra zapolni področje registrske tablice. Rezultat

dilatacije slike opravljene nad izhodno sliko metode iskanja bele barve prikazuje slika 6.

2.3. Rotacija tablice

RTV je lahko poljubno orientirana na sliki, zato je potrebno najti kot rotacije, saj preko tega kota algoritem rotira registrsko tablico v horizontalni položaj potreben pri klasifikaciji znakov. Najprej izvedemo pretvorbo iz barvne slike v sliko s sivimi odtenki barve in predpostavimo, da so paralelne linije prisotne v okolini RTV. Na sliki zaznamo robove predmetov, nato izvedemo izračun Radonove transformacije /6/, in sicer v področju med 0° in 179° . Najdenih linij je navadno veliko, zato algoritem uporabi le najdaljše, kar stori s preprostim odštetjem neke konstantne vrednosti, ki v našem primeru znaša 25. Za kot zasuka se izmed vseh najdenih linij izbere maksimalna dolžina, ki navadno predstavlja sprednji ali zadnji odbijač. Slika 7 prikazuje primer vrha najdenih linij.



Slika 7. Vris linij potrebnih pri določitvi kota zasuka.
Fig. 7. Lines drawn needed for angle determination.

Naslednji korak je rotacija slike za najdeni kot. Rotirano sliko pretvorimo v binarno sliko, kjer zopet opravimo dilatacijo slike. Tukaj za razširitev uporabimo elemente oblike karo. Algoritem ponovno izvede iskanje pravokotnika v manjši sliki, kjer kot rezultat dobimo točno področje registrske tablice. Povečano področje najdene registrske tablice je prikazano na sliki 8.



Slika 8. Izločena registrska tablica.
Fig. 8. Extracted licence plate.

Slike 8 se kaj hitro opazi, da se poleg RTV nahaja nekaj dodatnega prostora. Problem odpravimo z določitvijo mejnih točk kontur, za to uporabimo metodo izračuna histograma, ki izračuna vsoto vrstic in stolpcev. Rezultat predstavlja dva stolpična vektorja, kjer eden vsebuje vsoto stolpcev, drugi pa vsoto vrstic. Začetne in končne vrednosti obeh vektorjev so enake nič (gre za binarno sliko) tako, da lahko algoritem izračuna točke, na katerih se nahaja področje registrske tablice, kot je prikazano na sliki 9.



Slika 9. Registrska tablica po obdelavi kontur.
Fig. 9. Licence plate after analysing contours.

Naslednji korak je filtriranje slike, s katerim se poudarjo znaki registrske tablice. Ta korak je ključnega pomembnega pri kasnejši razpoznavi znakov. Sliko najprej pretvorimo v sliko sivih odtenkov, nato izvedemo kvantizacijo in izenačevanje z izračunom histograma slike. Eksperimentalno nastavimo parametra oz. limiti, ki navzdol omejitva vrednosti na 0, navzgor pa na 1 (gre za normalizirano sivinsko sliko). Za vse ostale vrednosti, ki se nahajajo zunanjih teh mej, izračunamo optimalen prag. V primeru, kadar je histogram slike pretežno bimodalni, t.j. ima dva ločena vrhova, vrednost praga nastavimo na minimalno vrednost med vrhovoma. Težje je to v primerih, ko se vrhova prekriva. Optimalen prag dejansko minimizira napako interpretacije ozadja kot objekta na sliki. Ta metoda je poenostavitev mnogo kompleksnejše statistične metode, vendar daje zelo dobre rezultate tudi pri majhnem številu iteracij. Primer kvantizacije in izenačevanja prikazuje slika 10.



Slika 10. Kvantizacija in izenačevanje.
Fig. 10. Quantization and equalization.

3. Razpoznavanje znakov na RTV

Sledče poglavje podaja postopke, ki smo jih uporabili za razpoznavanje znakov registrskega tablica. Vsi omenjeni algoritmi se navezujejo na stanje, ko smo že uspešno razpoznali registrsko tablico in jo le-ta predstavljena kot npr. Slika 10.

3.1. Razčlenitev znakov

Binarno sliko RTV razčlenimo z uporabo metode izračuna histograma, in sicer vsote stolpcev slike (ang. Peak-to-valley). Pri razčlenjevanju slike sta algoritem v pomoč dva statistična parametra, in sicer sta to minimalna širina in minimalna površina regije. Ta dva parametra sta potrebna, saj z njuno pomočjo lahko algoritem izloči nepotrebne znake, ki se pojavi na registrski tablici, kot so grbi in pomicljaji. Razčlenjevanje poteka od leve proti desni, kjer izračunamo vsote stolpcev slike in jih primerjamo s podanimi parametromi. V primeru, da najden znak s končno vsoto stolpcev ustreza pogojema, potem algoritem vrne začetno in končno mejo znaka ter nadaljuje iskanje na desni strani meje oz. za tem znakom.

Nad pravkar dobljenimi mejami znakov, v katerih se nahajajo znaki registrske tablice, izvedemo dilatacijo, ki zmanjša šum v sliki, ki je posledica predvsem slabe kakovosti slike. Metoda tudi poveča razmik med znaki, kar napravi lažjo

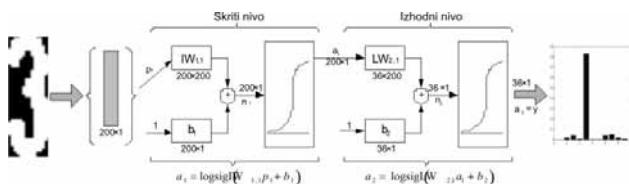
separacijo med znaki in ozadjem. Slednje je ključnega pomena pri razpoznavi z OCR sistemom.

Vsakemu najdenemu znaku prilagodimo konture, kar izvedemo s podobnimi postopki, ki so že bili opisani tako v horizontalni, kot tudi vertikalni smeri. Znak je potrebno skalirati na izbrano dimenzijo 20×10 slikovnih elementov, saj znaša število vhodnih nevronov ravno 200. To predstavlja zelo pomemben korak, saj so v učni množici nevronske mreže shranjeni znaki točno takšnih dimenzijs. Razpoznavna RTV z uporabo nevronske mreže je sicer izjemno robustna, a kljub temu je ključnega pomena pridobitev dobrih kontur. Jalove konture direktno vplivajo na uspešnost OCR sistema pri razpoznavi znakov.

3.2. Nevronska mreža in razpoznavanje znakov

Nevronske mreže sestavljajo elementarni elementi t.i. nevroni, kateri delujejo paralelno. Ti elementi so le poenostavljena izpeljanka biološkega nevrolaškega sistema. Podobno kot je to v naravi biološkega delovanja, se tudi tukaj determinira sposobnost reševanja problema s številom povezav med nevroni. Učenje nevronske mreže torej vpliva na povezave med nevroni tako, da se postavijo določeni pragovi (povezavam med nevroni se dodajo uteži), kateri vplivajo na nadaljnje odvijanje reševanja problema.

Vhodno skalirano slike velikosti 20×10 pretvorimo v stolpični vektor, ki nosi informacijo o znaku. Tako se skladata dimenzijs in število vhodnih nevronov, ki znaša 200. Podrobni prikaz za števko 3 prikazuje slika 11, kjer je potrebno poudariti, da je tukaj razpoznavna izvedena le za numerični del znakov /14/.



Slika 11. Arhitektura nevronske mreže.

Fig. 11. Neural network architecture.

Pri klasifikaciji znakov uporabljamo feedforward (predkrmljeno) nevronske mreže, in sicer gre za dvonivojsko log-sigmoid/log-sigmoid nevronske mreže. Vseh možnih znakov je 36, izmed katerih je 26 črk in 10 števk, zato je smiselno uvesti 36 izhodnih nevronov. Izvod iz nevronske mreže predstavlja vektor dimenzijs 36×1 , v katerem so na vsakem mestu podane verjetnosti, ki opisujejo podobnost vhodnega znaka z znaki v učni množici. Identifikacijo iskanega znaka določimo z maksimalno verjetnostjo. Nevronska mreža je sposobna identificirati znake na popačenih slikah, v katerih je prisoten šum. Zajem slik v naravi pogosto privede do šumne slike, saj so v naravi prisotni različni vremenski pogoji, na šumnost slike pa vpliva tudi šumnost CCD tipala oz. njegovega CMOS ekvivalenta. Eksperimentalno je določeno, da se pri razpoznavi znakov najmanj napak

pojavlja pri šumu s srednjo vrednostjo enako 0 in standardno deviacijo 0.2 ali manj.

Robustno nevronske mreže, ki bi bila kar najmanj občutljiva na vhodni šum, najprej učimo na idealnih primerih, v katerih ni prisotnega šuma. Vse te idealne primere umetno vnesemo šum in nevronske mreže ponovno učimo na šumnih primerih. Učenje nevronske mreže traja vse dokler ni dosežena vrednost kvadratične vsote napake 10^{-5} ali se učenje zaključi po maksimalno 5000 epohah. Ker se ob takšnem postopku pojavi problemi pri klasifikaciji idealnih primerov, je potrebno nevronske mreže ponovno učiti na idealnih primerih. Učenje nevronske mreže uporablja taktiko vračanja v primeru napake (ang. Backpropagation), ki poteka tako z adaptivnim učenjem kot tudi z momenti.

Zadnjih nekaj let so se na področju razpoznavne znakov zelo razširile metode z uporabo nevronske mreže, katere v določenih primerih pravilno interpretirajo vhodne signale, medtem ko ostale metode odpovedo. Problematika uporabljenih metoda nevronske mreže pri OCR sistemu postane očitna, saj je za uspešno razpoznavo potrebna čim večja učna množica. V tej učni množici se mora nahajati čim več različnih primerov istega znaka, ki naj bo idealen, šumen, rotiran, itd. Posledica nepravilnih interpretacij znakov je predvsem majhno število znakov v učni množici, saj je bilo vseh skupaj komaj 360 (za vsak znak po 10 različnih primerov). Izboljšanje delovanja OCR sistema je pričakovati z razširitvijo učne množice.

4. Razpoznavanje znakov na RTV

Testiranje algoritma je potekalo na 50-ih naključno izbranih fotografijah avtomobilov s slovenskimi in evropskimi registrskimi tablicami. Tabela 1 podaja eksperimentalne rezultate, ki so razdeljeni na dva dela. V prvem delu primerjamo 3 metode razpoznavne registrske tablice in njihovo učinkovitost, medtem ko v drugem delu merimo učinkovitost razpoznavne znakov. Poudariti je potrebno dejstvo, da je metoda Evklidske norme že imela najden slikovni element iz področja registrske tablice. Iz Tabele 1 izhaja tudi dejstvo, da je sistem klasifikacije znakov izjemno robusten, a kljub vsemu učinkovit.

Tabela 1. Učinkovitost različnih metod.

Table 1. Overall efficiency of various used methods.

	Bela barva	2D korelacija	Evklidska norma
Pravilna razpoznanja tablica	72%	54%	90%
Stopnja klasifikacije znakov			96%

5. Sklep

Uporaba predstavljenega algoritma pri zaznavanju registrskih tablic z uporabo feedforward nevronske mreže se izkaže kot zanesljiva rešitev. Največjo učinkovitost doseže metoda, ki temelji na izračunu Evklidske norme, vendar je pri tej metodi potreben vnos enega slikovnega elementa

znotraj področja registrske tablice, kar napravi celotni algoritmom neavtonomen. Najnižjo učinkovitost izkazuje metoda 2D korelacije, ki pa je povrhу še izjemno računalniško potratna oz. komplikirana. Torej je v celotno integracijo algoritma smiselno vpeljati razpoznavo registrske tablice po metodi iskanja bele barve v XYZ barvнем prostoru.

Ko algoritmom pravilno razpozna registrsko tablico, postane klasifikacija znakov prisotnih v registrski tablici dokaj visoka, saj procentualno znaša kar 96%. Stanje bi se še izboljšalo z razširitvijo učne množica, katera bi vključevala več primerov posameznega znaka.

Nadaljnje delo bo zajemalo implementacijo predlaganega postopka razpozname registrskih tablic z uporabo feedforward nevronskega mrež na avtonomnem digitalnem signalnem procesorju, ki bo deloval v realnih pogojih. Ti pogoji zajemajo spremembe vremenskih razmer, razpoznavanje tudi v nočnih razmerah in pri različnih hitrostih premikanja objektov. Kot temeljni cilj bo postavljeno delovanje v strogem sprotnem času.

Literatura

- /1/ License Plate Recognition, URL:
<http://www.licenseplaterecognition.com/>
- /2/ S. Yohimori, Y. Mitsukura, M. Fukumi, N. Akamatsu, N. Pedrycz, License plate detection system by using threshold function and improved template matching method, 27-30 June 2004.
- /3/ F. Porikli, T. Kocak, Robust License Plate Detection Using Covariance Descriptor in a Neural Network Framework, IEEE International Conference on Advanced Video and Signal Based Surveillance, pp. 107, November 2006.
- /4/ J. Matas, K. Zimmermann, Unconstrained licence plate and text localization and recognition, Intelligent Transportation Systems, 13-15 Sept. 2005.
- /5/ J. Dattorro, Convex Optimization & Euclidean Distance Geometry, Meboo Publishing, 2005.
- /6/ Bracewell, Ronald, Two-Dimensional Imaging, Englewood Cliffs, NJ, Prentice Hall, 1995.
- /7/ CIE XYZ, URL:
http://en.wikipedia.org/wiki/CIE_1931_color_space
- /8/ William K. Pratt, Digital Image Processing 3rd Edition, Wiley-Interscience Publication, 2001.
- /9/ R.C. Gonzales, R. E. Woods, S. L. Eddins, Digital Image Processing using MATLAB, Pearson Prentice Hall, 2004.
- /10/ I. Kramberger, Z. Kačič, Enota za zajemanje stereo slike za delovanje v realnem času s strojno izvedenim digitalnim filtrom, Inf. MDEM, Vol. 33(3), pp. 178-188, 2003.
- /11/ Matlab Help, URL: <http://www.mathworks.com/access/helpdesk/help/techdoc/index.html?access/helpdesk/help/techdoc/ref/conv2.html>;
- /12/ R. Svečko, skripta: Inteligentni sistemi.
- /13/ Haralick, R.M. and L. G. Shapiro, Computer and Robot Vision, Vol. I, Addison-Wesley, 1992, pp. 158-205.
- /14/ B. Kröse, P. Smagt, An introduction to neural networks, November 1996.

Matej Kseneman¹, Dušan Gleich¹

*¹Fakulteta za elektrotehniko, računalništvo in informatiko, Smetanova ulica 17, 2000 Maribor
E-pošta: matej.kseneman@gmail.com*

Prispelo: 31.01.2011

Sprejeto: 23.08.2011