

## Uma nova abordagem utilizando RNA para reconhecimento automático de placas de veículos baseado em pré-processamento de imagens e pós-processamento

Shiguelo Nomura<sup>1</sup>, Keiji Yamanaka<sup>2</sup>, Osamu Katai<sup>1</sup>, and Hiroshi Kawakami<sup>1</sup>

<sup>1</sup>Department of Systems Science, Graduate School of Informatics, Kyoto University, Japan

<sup>2</sup>Faculdade de Engenhariaia Elétrica, Universidade Federal de Uberlândia, Brasil

E-mails: [shiguelo@sys.i.kyoto-u.ac.jp](mailto:shiguelo@sys.i.kyoto-u.ac.jp), [keiji@ufu.br](mailto:keiji@ufu.br), [katai@i.kyoto-u.ac.jp](mailto:katai@i.kyoto-u.ac.jp),

[kawakami@i.kyoto-u.ac.jp](mailto:kawakami@i.kyoto-u.ac.jp)

### Abstract

*This work presents a new system based on artificial neural networks (RNA) techniques to improve the automatic recognition of the number plate from degraded images. The input of the system are images automatically generated by photographic radars installed at the roads in Uberlândia city. The proposed system is composed by a degraded image preprocessing stage and a number plate code recognition stage. New preprocessing methods for image binarization, character segmentation and feature extraction are applied. The RNA model is trained with a set of output patterns that have low similarity between them. This model is used to recognize each character extracted from the number plate. The recognized characters sequence serves as the input data to the postprocessing stage that accepts or rejects that sequence as the result of the number plate recognition. Despite the degraded quality of the input images, experimental results have presented promising results. The output patterns used in the training stage of the RNA model and the proposed postprocessor have significantly increased the recognition rate showing the robustness of the system to process this kind of image.*

### 1. Introdução

O reconhecimento automático de caracteres por computador tem encontrado crescente aceitação por parte de pesquisadores, técnicos e autoridades ligados ao estudo e controle do tráfego de veículos. Uma das linhas que tem sido objeto de pesquisa por diferentes grupos no mundo é a leitura automática de placas de veículos, como forma de detectar transgressores da lei do trânsito, encontrar carros roubados, controlar entrada e saída de veículos para garantir a segurança, cobrar taxa de estacionamento, cobrar pedágios ou efetuar estudos de origem/destino, entre outros [1][2][3].

Várias pesquisas têm sido desenvolvidas sobre este tema [4][5][6]. No entanto, observa-se que os sistemas convencionais de reconhecimento de placas de veículos têm utilizado imagens obtidas de fotos tiradas sob condições ambientais bem controladas. Um exemplo de

imagem que tem sido utilizada nestes sistemas é apresentado na Fig. 1, onde é possível verificar que a mesma é bem definida comparada com as imagens obtidas por radares fotográficos, Fig. 2, e que foram utilizadas nessa pesquisa.



Figura 1 – Exemplo de foto da Westminster International



Figura 2 – Exemplo de fotos disponíveis nessa pesquisa

O grande desafio a ser tratado nessa pesquisa é a utilização desse tipo de imagens reais extraídas de fotos tiradas automaticamente através de radares fotográficos instalados nas vias da cidade de Uberlândia. Na realidade, esses radares são constituídos de câmeras fotográficas comuns sujeitas às condições mais adversas possíveis (intempéries, movimento dos veículos, ângulo de focalização, posição das câmeras, distância entre a câmera e os veículos, período do dia ou da noite), e sem qualquer controle manual durante a obtenção da foto que contém uma imagem de placa. Portanto, são imagens que apresentam problemas de luminosidade, contraste, focalização, variação de resolução, variação de dimensão que demandam um sistema capaz de extrair

o máximo de informações relevantes para o reconhecimento dos códigos representados por essas imagens.

Para enfrentar o desafio mencionado, o sistema proposto tem como componentes básicos os módulos de binarização e de segmentação, o mecanismo de reconhecimento de caracteres, seguido do pós-processamento dos códigos de placas.

### 1.1. Módulo de binarização

A função do módulo de binarização [7] é receber as imagens coloridas e convertê-las, primeiramente, para imagens em níveis de cinza e, finalmente, em imagens em preto e branco que se tornam computacionalmente mais fáceis de serem processadas. É importante considerar que, nessa conversão, as informações úteis (por exemplo, o detalhe da curva da letra G para ser diferenciado da letra C) devem ser preservadas. Por outro lado, as informações inúteis (por exemplo, ruídos provenientes de sombra nas placas) devem ser descartadas da melhor forma possível. Resumidamente, esse módulo envolve técnicas de conversão de imagens coloridas para imagens em níveis de cinza representadas pelo modelo YIQ, realce das imagens em níveis de cinza usando o filtro mediano, controle de intensidade ou brilho através de operações com pixels, remoção de ruídos utilizando operações da morfologia matemática [8], e determinação do limiar de binarização pelo método de Otsu [9].

### 1.2. Módulo de segmentação

No módulo de segmentação [7], é recebida a imagem preparada pelo módulo de binarização para que essa imagem possa ser dividida em elementos de caracteres e extraídas suas características. As técnicas mais utilizadas nesse módulo são a construção do histograma vertical, os métodos morfológicos [10] de espessamento, poda e afinamento, e o cálculo do custo de segmentação.

Na extração de características dos caracteres, leva-se em consideração a posição relativa dos mesmos, e essa informação é utilizada no processo posterior de reconhecimento ou recuperação de algum caractere para que o código completo possa ser identificado. Para o reconhecimento de conjuntos de caracteres como os códigos de placas de veículos, o reconhecimento isolado de cada caractere não é suficiente. Essa insuficiência é ainda maior se o objetivo for recuperar, através de um pós-processamento, algum caractere que não foi possível reconhecer por causa da má qualidade da imagem. Para que o objetivo possa ser alcançado é necessário que as informações das posições dos caracteres segmentados e extraídos da imagem também sejam obtidas na fase de extração de características. Daí, também a importância deste módulo no sistema proposto. No caso das imagens de placas utilizadas neste trabalho, algumas informações geométricas e a ocorrência de determinados tipos de caracteres em áreas

específicas são consideradas como referência para a obtenção das posições.

### 1.3. Reconhecimento de caracteres

Um sistema de reconhecimento automático de caracteres a partir de imagens degradadas, como as disponíveis nesse trabalho, deve ser capaz de exibir alguns graus de inteligência. Para uma máquina, essa inteligência estaria relacionada à:

- Capacidade de aprender a partir de exemplos, e de generalizar o conhecimento de maneira que possa ser aplicada em circunstâncias novas e diferentes.
- Habilidade de realizar inferências a partir de informações incompletas.
- Capacidade de extrair informações importantes a partir de detalhes aparentemente irrelevantes.

Para que o sistema proposto neste trabalho possa ter as capacidades listadas acima durante a etapa de reconhecimento dos caracteres, adotou-se as técnicas baseadas em RNA [11]. O modelo escolhido foi o “Multi-Layer Perceptron” (MLP), treinado com o algoritmo “Back Propagation”. A função de ativação utilizada foi a “sigmoid” bipolar. Com o objetivo de se obter o máximo aproveitamento da capacidade das RNA, é introduzido um novo conjunto de vetores de saída para o treinamento do modelo. Esse conjunto recebe a denominação de vetores “pouco similares” (PS), ou seja, vetores em que tomados dois a dois, o ângulo formado entre eles é o maior possível.

Na prática, o reconhecimento serve para atribuir um rótulo a um objeto, baseado na informação fornecida pelo módulo de segmentação. No caso em questão, o reconhecimento de um caractere requer a associação de características para que aquele caractere seja rotulado através de uma letra ou um dígito pelo reconhecedor baseado em RNA.

### 1.4. Interpretação do código

A interpretação envolve a atribuição de um significado ao conjunto de caracteres que foram reconhecidos. Obtendo-se o conjunto de caracteres rotulados, torna-se necessário interpretar, ou seja, atribuir um significado a esse conjunto. Por exemplo, uma cadeia de 3 letras e 4 dígitos pode ser interpretada como sendo a placa de algum veículo.

No sistema proposto, essa etapa é conhecida como pós-processamento e tem interação com uma base de dados. É nessa base que se encontra o conhecimento sobre o domínio do problema, ou seja, o universo das placas válidas. Isso significa que a comunicação com o reconhecedor baseia-se no conhecimento prévio da natureza esperada do resultado. Então, esse conhecimento auxilia em operações de interpretação dos códigos. Experimentalmente, o pós-processador compara as seqüências de caracteres reconhecidos pelas RNA com os códigos válidos armazenados na base de dados. Então, é realizado um processo de interpretação

(aceitação, rejeição ou eliminação) do código de entrada para se determinar a solução mais adequada. Se essa determinação não for possível, uma resposta coerente é apresentada. Outra vantagem de se utilizar o pós-processador é a possibilidade de recuperar um código de placa válida mesmo que algum caractere seja perdido por causa da má qualidade de imagem. Quando a imagem de entrada é bastante degradada ou há uma grande variedade de estilos como no caso de manuscritos japoneses [12], o pós-processador tem sido bastante útil. Para o caso do sistema proposto, em uma cadeia de 3 letras e 4 dígitos em que foram reconhecidos apenas 6 caracteres, permite ao pós-processador recuperar o caractere que não pôde ser reconhecido.

Na Seção a seguir, é apresentado o esquema do sistema proposto, através da Fig. 3, com a descrição de suas etapas. Os resultados experimentais obtidos pelo sistema são discutidos na Seção 3. A Seção 4 é a conclusão do trabalho.

## 2. Esquema do sistema e sua descrição

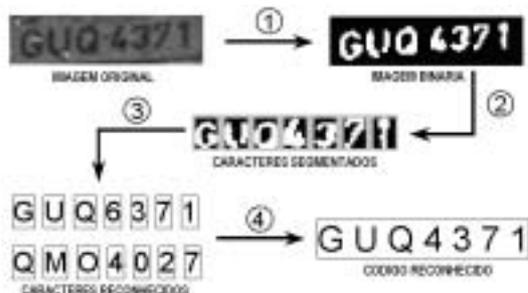


Figura 3 – Esquema do sistema proposto

### 2.1. Etapa 1

As imagens originais, inicialmente coloridas, são transformadas para versões binárias utilizando os métodos adaptativos propostos em [13]. A Fig. 4 apresenta um exemplo de imagem original bastante degradada. A imagem é processada através da aplicação dos métodos adaptativos, e a Fig. 5 contém sua versão binária que servirá como dado de entrada para o próximo passo.



Figura 4 – Imagem original colorida



Figura 5 – Imagem binária

### 2.2. Etapa 2

Como citado anteriormente, devido ao fato das imagens originais serem degradadas, surgem problemas

de fragmentação, sobreposição ou conexão de caracteres nas suas versões binárias. O segundo caractere da esquerda para a direita na imagem da Fig. 5, por exemplo, está com problema de fragmentação. Nesta etapa, foi utilizada a abordagem proposta em [14], que tem como mérito a automatização do processo de segmentação dos caracteres das placas de veículos através da adaptatividade. Essa adaptatividade do sistema permite detectar o estado em que se encontram os caracteres (segmentados naturalmente, fragmentados, sobrepostos ou conectados) e aplicar automaticamente os métodos adequados de segmentação em cada caso.

Após a separação ou segmentação das imagens dos caracteres, cada imagem sofre uma padronização [14]. Essa padronização visa minimizar as mudanças de escala e os problemas de translação entre os padrões a serem extraídos, aumentando a taxa de reconhecimento desses padrões numa placa. Nesta etapa também ocorre o trabalho de extração dos vetores de características e suas respectivas posições na imagem da placa. Os padrões binários da Fig. 5 devidamente segmentados e extraídos, estão representados pelas imagens da Fig. 6. Cada vetor de características de representação bipolar é constituído de 300 elementos e serve de entrada para o modelo de rede neural definido na etapa seguinte.



Figura 6 – Padrões segmentados e extraídos

### 2.3. Etapa 3

Estratégias já consagradas como a fixação de um determinado parâmetro e variação dos demais, foram adotadas para se definir a topologia adequada de RNA. Os experimentos convencionais foram realizados com o objetivo de se obter a maior taxa de reconhecimento dos padrões de entrada representados pelos vetores de características obtidos na etapa anterior. Assim, o modelo utilizado no trabalho possui 300 neurônios na camada de entrada, 200 neurônios na camada intermediária e 48 neurônios na camada de saída.

Tem-se percebido nessa etapa que além de uma escolha adequada dos padrões de entrada e da quantidade de neurônios na camada escondida, há uma relevante contribuição da escolha adequada da representação dos padrões de saída para o aumento da taxa de reconhecimento pelas RNA. Conforme os experimentos descritos a seguir, os vetores PS definidos na Seção 1 são os mais indicados para treinar a rede com os dados de entrada disponíveis para essa pesquisa. Um conjunto de validação constituído por 71 placas foi separado para realizar esses experimentos. Vários treinamentos e testes foram realizados visando a definição de um vetor de saída mais adequado que resulte na maior taxa de reconhecimento para os dados disponíveis. A seguir, são apresentados os resultados de

reconhecimento sobre o conjunto de validação para cada tipo de representação dos padrões de saída.

### 2.3.1. Utilizando vetores de saída convencionais

#### Vetor com 10 elementos

$$V_i = [-1, -1, \dots, 1, \dots, -1]$$

Onde o elemento 1 na posição  $i$  corresponde ao dígito  $i$  do vetor  $V$  para esse dígito. A exceção ocorre para o dígito 0, cujo elemento positivo se encontra na posição 10.

#### Vetor com 48 elementos

Analogamente ao caso anterior, o elemento positivo de cada vetor está na posição correspondente ao valor do dígito, com exceção do dígito 0. A quantidade 48 foi definida para a comparação com o novo tipo de representação (os vetores PS) dos padrões de saída.

Adotando-se o vetor de representação bipolar com 10 elementos cada, para o caso dos dígitos, onde cada posição acesa refere-se a um dígito, a máxima taxa de reconhecimento conseguida foi de 76,8 %. O aumento do número de elementos de 10 para 48 em cada vetor resultou no aumento de 7,4 % na taxa de reconhecimento, chegando a 239 dígitos reconhecidos do total de 284.

### 2.3.2. Utilizando vetores PS

Os vetores PS são construídos de modo que o coeficiente de similaridade calculado entre 2 vetores seja o menor possível. O coeficiente de similaridade [12] entre um vetor e todos os vetores restantes (9, no caso desse experimento) é calculado através da Eq. (1).

$$sim(V_i, V_j) = \frac{V_i \cdot V_j}{|V_i| \cdot |V_j|} \quad (1)$$

Onde  $i=1, \dots, N$ ;  $j=1, \dots, N$  para  $i \neq j$ ;  $N$  é o número de vetores.

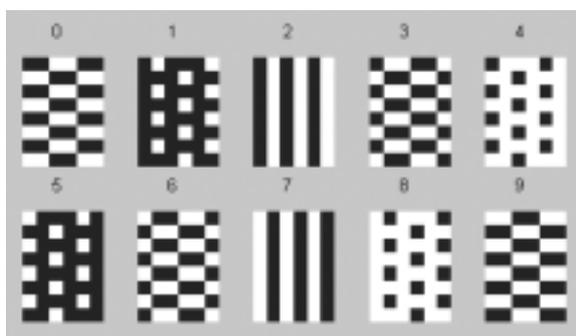


Figura 7 – Exemplo de vetores PS

A Fig. 7 ilustra os vetores PS para os dígitos (utilizados nesse trabalho), quando representados por meio de matrizes 8x6 e plotados graficamente.

O máximo valor, dentre os 45 coeficientes de similaridade calculados para os vetores convencionais, foi de 0,9167, enquanto que, para os vetores PS, esse

máximo valor caiu para 0,5. Um novo treinamento da rede neural foi realizado, desta vez para os vetores PS. Para esse treinamento, tomou-se o mesmo conjunto inicial de pesos e o mesmo conjunto de padrões de entrada utilizados para treinar a rede neural com os padrões de saída convencionais. Testando a nova rede para a amostra de 71 placas, verificou-se que foram reconhecidos 249 caracteres, ou seja, houve um aumento de cerca de 3,5 % na taxa de reconhecimento.

Seguindo-se o mesmo raciocínio, construiu-se mais 26 novos vetores PS para as 26 letras do alfabeto e com o máximo valor de 0,5 dentre os 325 coeficientes de similaridade calculados.

Definido o tipo dos vetores de saída, procedeu-se o treinamento das redes neurais. Como as imagens originais se encontram bastante degradadas, a utilização de uma única rede neural para reconhecer os 10 dígitos e as 26 letras não tem proporcionado resultados satisfatórios. A estratégia adotada foi treinar uma rede para cada caractere, totalizando 36 redes chamadas “especialistas”. Assim, cada rede pôde ser treinada para uma gama maior de variações no padrão de um caractere. A Fig. 8 é uma amostra dos padrões de treinamento da rede especialista para o dígito 8.



Figura 8 – Padrões de entrada para o dígito 8

### 2.3.3. Fase de reconhecimento propriamente dito

Valendo-se das informações de localização dos caracteres (3 primeiras letras e 4 últimos dígitos) a estratégia utilizada foi de reconhecer cada caractere considerando a posição do vetor de características obtida na Etapa 2. Em outras palavras, para os 3 primeiros vetores foram utilizadas as redes especialistas para reconhecer letras e para os 4 últimos foram utilizadas as redes especialistas para reconhecer dígitos. Uma primeira seqüência de caracteres reconhecidos é obtida tomando-se o caractere cujo erro é mínimo e uma segunda seqüência é obtida tomando-se o segundo menor erro.

Dessa fase de reconhecimento é apresentada a primeira seqüência como sendo a “placa reconhecida

pelas RNA” (PR) e a segunda seqüência como “placa candidata pelas RNA” (PC). Além disso, é apresentado o vetor de erros para a PC. A Fig. 9 ilustra os resultados pelas RNA para a placa da Fig. 4.



Figura 9 – Resultados para a placa da Fig. 4

Esses dados são utilizados pela etapa seguinte para determinar os candidatos de placas válidas mediante consulta na base de dados.

#### 2.4. Etapa 4

Nesta etapa, é implementado o pós-processador para reconhecer o código da placa referente às seqüências de vetores candidatos obtidos na etapa anterior. Conforme o mecanismo apresentado na Fig. 10, o pós-processador é constituído de uma base de conhecimento. Essa base é constituída de códigos de placas válidas que servem de informação para o processo de validação da seqüência de caracteres reconhecidos. Através desse processo de validação, as seqüências são utilizadas como referência para se encontrar os candidatos de placas válidas na base de dados. O critério utilizado para aceitar uma placa da base de dados como candidata é o número de coincidências de cada caractere dessa placa com o correspondente caractere da PR ou PC. Esse critério é denominado “critério do número de coincidências” (CNC). Se este número for superior a um limite (estabelecido como sendo 5 neste trabalho), a placa da base é armazenada como candidata. Na Fig. 10 é visualizada a única placa candidata encontrada na base de dados para o caso da placa da Fig. 4. O número de coincidências calculado pelo CNC vale 7.

O pós-processador baseia-se no fato de que o número determinado é maior que o limite estabelecido para considerar essa placa candidata como reconhecida. Conseqüentemente, o dígito 6 da PR é substituído pelo dígito 4, para que a placa correta, de código GUQ4371, seja reconhecida. No outro exemplo, dois códigos candidatos foram encontrados na base de dados para as seqüências reconhecidas pelas RNA. Neste caso, é realizado um tratamento mais pormenorizado para que um dos candidatos da base de dados seja escolhido como a placa reconhecida. Esse tratamento constitui a tarefa principal do pós-processador que será descrito a seguir.

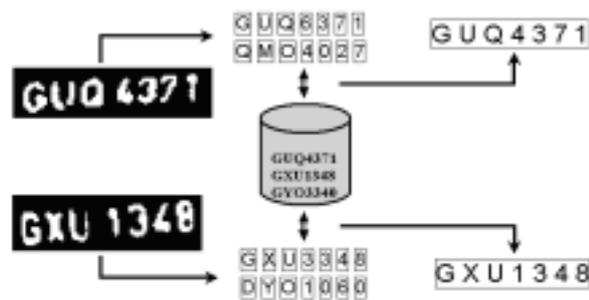


Figura 10 – Mecanismo de pós-processamento para reconhecimento do código de uma placa



Figura 11 – Saída do pós-processador para uma placa

Cada placa da base de dados é analisada conforme o CNC. Se o número de coincidências for maior que o limite (5, nesse trabalho), a placa da base de dados é armazenada como “placa candidata do BD” (PBD). Quando nenhuma PBD é encontrada, o resultado é a “rejeição” do padrão de entrada. Na Fig. 11, foram encontradas 2 PBD: “GXU1348” e “GYO3340”. Ambas possuem 7 (número máximo de coincidências) caracteres coincidindo com PR e PC. Por isso, as 2 PBD permaneceram como novas placas candidatas (NPC). Uma PBD teria sido eliminada se o seu número de coincidências fosse menor que o das demais. O próximo passo é filtrar as NPC utilizando o vetor de erros para PC obtido na Etapa 3. Assim, cada nova placa candidata é comparada com PR e obtém-se os valores no vetor de erros correspondentes àqueles caracteres que não coincidem. Em seguida, esses valores são somados e a placa reconhecida será a que tiver a menor soma. No caso da Fig. 11, para a primeira NPC apenas o caractere da posição 4 não coincidiu. Enquanto que para a segunda NPC os caracteres das posições 2, 3 e 7 não coincidiram. Conseqüentemente, a soma dos erros para a primeira NPC foi menor e então seu código foi utilizado como placa reconhecida.

### 3. Resultados experimentais

O sistema proposto foi testado tomando-se uma amostra de imagens de placas, devidamente processadas pelos módulos de pré-processamento de imagens descritos nas Seções 2.1 e 2.2, para se obter os vetores de características dos dados.

Os dados foram divididos da seguinte forma:

#### a) Conjunto de treinamento

Os dados deste conjunto foram tomados de imagens de placas que não pertencem ao conjunto de teste descrito a seguir. Esses dados foram utilizados como padrões de entrada para treinar cada rede neural especialista. Um exemplo desses padrões pode ser verificado na Fig. 8.

#### b) Conjunto de teste

Este conjunto é constituído de 943 imagens de placas e é subdividido em 4 grupos para realizar os testes de reconhecimento pelo sistema proposto. A Tabela 1 apresenta a distribuição dos dados em grupos.

Tabela 1 – Distribuição das imagens em grupos

Grupo	Quantidade
I	458
II	302
III	112
IV	71

Utilizando-se esses dados como entrada, foram aplicadas as RNA treinadas conforme a descrição feita na Seção 2.3. Os resultados de reconhecimento dos caracteres obtidos dessa aplicação são apresentados na Tabela 2.

Tabela 2 – Taxa de reconhecimento dos caracteres

Grupo	Total caracteres	Caracteres reconhecidos	Taxa reconhecimento
I	3206	2540	79.2%
II	2114	1670	79.0%
III	784	689	87.9%
IV	497	420	84.5%

O pós-processador descrito na Seção 2.4 foi testado utilizando-se as seqüências de caracteres reconhecidos pelas RNA e as bases de dados de placas válidas referentes aos 4 grupos. A Tabela 3 contém a lista dos resultados desse teste e mostra também as taxas de reconhecimento dos códigos das placas somente pelas RNA. Analisando-se os resultados listados, observa-se que houve um considerável aumento da taxa de reconhecimento dos códigos das placas, quando o pós-processador foi introduzido. Além disso, percebe-se que as taxas de acertos, rejeições ou erros dependem muito pouco da quantidade de placas num determinado grupo. Verifica-se ainda que o desempenho da rede neural tem

contribuído para o aumento da taxa de reconhecimento, ao comparar as taxas da coluna de acertos da Tabela 3 com as taxas de reconhecimento da Tabela 2 (por exemplo, 87,9% de taxa de reconhecimento de caracteres pelas RNA corresponde a 97,3% de reconhecimento dos códigos pelo pós-processador).

Tabela 3 – Resultados de reconhecimento dos códigos

G	Reconhecidas pelas RNA		Resultados do pós-processamento					
			Acertos		Rejeições		Erros	
I	42	9.2%	368	80.3%	81	17.7%	9	2.0%
II	52	17.2%	255	84.4%	47	15.6%	0	0.0%
III	44	39.3%	109	97.3%	2	1.8%	1	0.9%
IV	15	21.1%	61	85.9%	10	14.1%	0	0.0%

A Fig. 12 apresenta alguns exemplos de imagens de placas que o sistema proposto tem rejeitado, ou seja, o limite pelo CNC não tem sido satisfeito para esses dados. Ao lado de cada imagem original se encontra a imagem binária pré-processada conforme descrito na Seção 2.1.



Figura 12 – Imagens difíceis de reconhecer

### 4. Conclusão

Neste trabalho, foi apresentada uma proposta de um novo sistema de reconhecimento automático de placas de veículos baseado em RNA e pós-processador. A rede neural tem desempenhado seu importante papel de ser tolerante às variações de tamanho, posicionamento, e forma dos caracteres destinados ao reconhecimento. A utilização de novos padrões de saída (vetores PS) para treinamento da rede neural possibilitou um aumento significativo na taxa de reconhecimento de cada caractere de uma placa. Também o pós-processamento baseado na interação efetiva com uma base de conhecimento de códigos de placas válidas, aumentou consideravelmente a taxa de reconhecimento das imagens degradadas de placas. Da análise dos resultados preliminares obtidos, pode-se concluir que o sistema proposto tem conseguido uma alta performance mesmo que as imagens sejam bastante degradadas. Assim, pode dispensar a necessidade de instalação de equipamentos sofisticados para aquisição de imagens com melhores

qualidades, o que demandaria altos custos de instalação e manutenção. Os resultados são bastante promissores para contribuição numa implementação futura de um sistema real de reconhecimento automático de placas de veículos.

## Referências

- [1] T. Sirithinaphong, K. Chamnongthai, "The Recognition of Car License Plate for Automatic Parking System", Fifth International Symposium on Signal Processing and its Applications, Brisbane, Australia, Aug. 1999.
- [2] K. Miyamoto, K. Nagano, M. Tamagawa, I. Fujita, and, M. Yamamoto, "Vehicle Licence-Plate Recognition by Image Analysis", IECON, 1991.
- [3] E. R. Lee, P. K. Kim, and H. J. Kim, "Automatic Recognition of a Car License Plate Using Color Image Processing", Proceedings of IEEE International Conference on Image Processing, p301-305, Nov. 13-16 1994.
- [4] J. A. G. Nijhuis et al., "Car License Plate Recognition With Neural Networks and Fuzzy Logic", Proceedings of the IEEE International Conference on NN, vol. 5, pp. 2232-2236, 1995.
- [5] P. Comelli, P. Ferragina, M. N. Granieri, and F. Stabile, "Optical Recognition of Motor Vehicle License Plates", IEEE Trans. On Vehicular Tehcnology, vol. 44, nº 4, pp. 790-799, Nov. 1995.
- [6] R. Parisi, E. D. Claudio, G. Lucarelli, and G. Orlandi, "Car Plate Recognition by Neural Networks and Image Processing", Proceedings of the IEEE International Symposium on Circuits and Systems, Monterey, USA, May 31-June 3, 1998.
- [7] S. Nomura, "Novos Métodos de Binarização de Imagens e Segmentação de Caracteres Aplicados a um Sistema de Reconhecimento Automático de Placas de Veículos", Dissertação de Mestrado, Uberlândia, FEELT-UFU, 117 p., 2002.
- [8] J. Serra, "Image Analysis and Mathematical Morphology", Academic Press, London, 1982.
- [9] N. Otsu, "A threshold selection method from gray-level histograms", IEEE Trans. Syst., Man, Cybern., SMC-9, Jan. 1979, 62-66.
- [10] R. C. Gonzalez, R. E. Woods, "Digital Image Processing", Addison-Wesley Publishing Company, Reading, Massachusetts, 1993.
- [11] L. Fausett, "Fundamentals of Neural Networks – Architectures, Algorithms, and Applications", Prentice Hall, New Jersey, 1997.
- [12] K. Yamanaka, S. Kuroyanagi, and A. Iwata, "A Character-Based Postprocessing System for Handwritten Japanese Address Recognition", IEICE Trans. Inf. & Syst., vol.E82-D, no.2, pp.468-474, 1999.
- [13] S. Nomura, K. Yamanaka, and O. Katai, "New Adaptive Methods Applied to Printed Word Image Binarization", Proceedings of the Fourth IASTED International Conference Signal and Image Processing, pp. 288-293, Kaua'i, Hawaii, USA, Aug. 12-14, 2002.
- [14] S. Nomura, K. Yamanaka, "New Adaptive Approach Based on Mathematical Morphology Applied to Character Segmentation and Code Extraction from Number Plate Images", Proceedings of the 6th World Multi-Conference on Systemics, Cybernetics and Informatics SCI 2002, vol. , pp. , Orlando, Florida, USA, Jul. 14-18, 2002.