

CLASSIFICAÇÃO DE VEÍCULOS AUTOMOTIVOS ATRAVÉS DE SENSORES INDUTIVOS E REDES NEURAIS

Lucas Costa Cicarelli, Eduardo Parente Ribeiro, Gideon Villar Leandro

Universidade Federal do Paraná – Departamento de Engenharia Elétrica
lcicarelli@gmail.com, edu@eletrica.ufpr.br, gideon@eletrica.ufpr.br

Resumo – A identificação da categoria de um veículo que trafega em uma via é um importante parâmetro para sistemas de gerenciamento de tráfego. Várias técnicas são empregadas para realizar a tarefa de classificação veicular, sendo que a maioria processa informações provenientes dos sensores indutivos. Neste trabalho, é proposto um sistema de classificação de veículos em oito categorias utilizando-se rede neural. As variáveis de entrada utilizadas para a rede neural foram extraídas a partir dos perfis magnéticos adquiridos. Este estudo apresenta uma análise da seleção dos parâmetros de entrada para a rede neural. Este sistema foi capaz de alcançar índices de acerto na classificação de 90%. Os resultados dos testes mostram a viabilidade técnica de se utilizar o sistema em equipamentos fixo de fiscalização eletrônica, permitindo a diferenciação de categorias muito semelhantes entre si como caminhonetes de camionetas.

Palavras-chave – Classificação de veículos, redes neurais, laços indutivos.

1 Introdução

A classificação de veículos automotores em diferentes categorias apresenta grande utilidade para sistemas inteligentes de tráfego - ITS (Intelligent Traffic Systems). Os ITS contribuem com ferramentas para a gestão do trânsito em diversas aplicações como comunicação, sinalização, organização, gerenciamento, controle e proteção das variáveis (pedestres, veículos, estradas, etc.) envolvidas – sobretudo os agentes humanos. Um sistema capaz de classificar veículos em diferentes categorias contribui com os ITSs em aspectos como:

- Planejamento do sistema viário;
- Estimar a emissão de poluentes nas vias;
- Verificar sazonalidade do tráfego, ou seja, as mudanças de comportamento do mesmo em épocas distintas;
- Localizar e projetar pontos de instalações para as operações de monitoramento e fiscalização;
- Fiscalizar vias que permitam o tráfego de categorias exclusivas;
- Fiscalizar categorias de veículos distintas em faixas de velocidades distintas.

A maior parte dos sistemas de classificação utilizados tem como base o processamento das variáveis obtidas dos sensores indutivos. Eles são amplamente difundidos como elemento sensor em equipamentos fixos de fiscalização eletrônica pelas vantagens apresentadas em termos de custo e confiabilidade [1].

O presente artigo utiliza rede neural para classificação veicular tendo como variáveis de entrada os parâmetros extraídos a partir das respostas produzidas pelos sensores indutivos durante a passagem dos diferentes veículos sobre os mesmos. Foram testadas diferentes combinações de variáveis de entrada para a rede neural. Os resultados dos diferentes casos foram comparados em relação aos índices de classificação correta obtidos.

O algoritmo de classificação do sistema proposto realiza a separação entre caminhonetes, camionetas e vans o que poderia contribuir com o agente de trânsito na diferenciação dos veículos que possuem velocidades máximas regulamentadas, visto que o código de trânsito brasileiro regulamenta diferentes velocidades em vias expressas para caminhões e caminhonetes (80 km/h), ônibus (90 km/h) e veículos de passeio ou motos (110 km/h) (Art. 61, Código de Trânsito Brasileiro, 1997). Segundo o artigo 96 do CTB, Caminhonete (pickup) é todo veículo destinado ao transporte de carga com peso bruto total de até 3,5 mil kg (passageiros e carga em compartimentos separados). Já camioneta é um veículo misto destinado ao transporte de passageiros e carga no mesmo compartimento, também conhecida como SUV, do inglês (Small Utility Vehicle). Alguns exemplos de caminhonete são Chevrolet S-10, Fiat Strada, Ford Ranger. Como exemplos de camioneta tem-se Hyundai Tucson, Land Rover Discovery 3, Renault Scenic.

Outra aplicação para utilização do perfil magnético é a re-identificação veicular que consiste na verificação de passagem por um segundo ponto após o veículo já ter trafegado sobre um primeiro ponto. O perfil magnético para re-identificação de seqüências de veículos foi inicialmente discutido por Bohnke e Pfannerstill [2], que aplicaram um sistema de identificação de sete classes de veículos usando duplos sensores indutivos e uma rede neural tipo mapa de Kohonem. Foi proposto por Andreotti [3], um sistema de classificação em sete categorias utilizando técnicas de clusterização. Foram utilizados 248 perfis magnéticos sendo 166 para treinamento e 82 para validação. O sistema alcançou precisão de 97,5%. Magalhães [4] propôs um sistema de classificação de veículos a partir da extração do perfil magnético dos veículos utilizando técnicas de estimação em frequência em alta resolução pela Decomposição Harmônica de Pisarenko – PHD e sua combinação com processamento de imagens obtidas de câmeras de vídeo.

Oh et al. (2002)[5] obtiveram resultados de classificação de 82,6% utilizando rede neural, com 4 parâmetro de entrada, classificando veículos em 7 categorias, sendo 4 de veículos comerciais. O sistema de classificação proposto por Sun (2003) [6] e adaptado por Ritchie et al.[7] utilizou árvore de decisão heurística com base em 4 parâmetros extraídos do perfil magnético tendo sido obtidos índice de classificação de 85% e 89,3% respectivamente.

O sistema proposto por Calixto [1] utilizou de lógica nebulosa para classificar veículos em 6 categorias, com taxa de acerto superior a 85% para todas as categorias. Em trabalho realizado por Oliveira et. al [8] foi proposto um sistema de classificação de veículos de acordo com o comprimento, utilizando rede neural, obtendo taxa de reconhecimento de 92,43% em um equipamento instalado em campo. Em [9] é descrito o desenvolvimento de um sistema inteligente para detecção contagem, medição de velocidade e identificação (classificação) de veículos. O projeto utilizou técnicas de processamento de sinais, como transformada rápida de Fourier (FFT). A FFT foi usada para análise e interpretação dos sinais gerados pelos laços de indução.

O presente artigo se divide em 4 seções. Na seção 2, é apresentada a definição do domínio do problema, a aquisição e preparação dos dados para a classificação e o projeto da rede. Os resultados são apresentados na seção 3 e as conclusões na seção 4.

2 Metodologia

A. Definições

Equipamentos de medição de velocidade classificados pelo Código de Trânsito Brasileiro (CTB, 97) como fixos, realizam medições com base em dados extraídos a partir de laços indutivos. Tais sensores, quando excitados eletricamente respondem às variações de campo magnético do meio. Quando um objeto metálico se aproxima do campo magnético produzido pelo sensor, pequenas correntes são induzidas na superfície metálica do objeto. Tais correntes geram um campo magnético próprio oposto ao campo gerado pelo sensor, conforme a lei de Lenz, fazendo com que a indutância do sensor diminua. A indutância também pode sofrer aumento quando objetos com composição elevada de metais ferrosos se aproximam do sensor incrementando a densidade de fluxo do campo magnético. A medição da indutância pelo sistema detector de velocidade, ao longo do tempo, gera uma curva conhecida como perfil magnético ou assinatura magnética [1].

Quando um veículo transita sobre os sensores indutivos, é gerado um perfil magnético dependente de sua velocidade, dimensões e distribuição de massa metálica que o compõe ao longo de seu comprimento [10]. O funcionamento do sistema de fiscalização consiste, basicamente, em detectar a passagem do veículo, fazer o cálculo e a conferência da velocidade e, se verificada a infração, capturá-lo através do sistema de vídeo. O sistema de detecção de veículos presente no equipamento DEV (Detector Eletrônico de Velocidade) é um sistema embarcado, constituído de filtros de hardware e software, amplificadores de sinal, sendo baseado em arquitetura DSP (*Digital Signal Processor*).

A Figura 1 apresenta o diagrama em blocos do sistema detector utilizado para obtenção da resposta do sensor na forma de perfil magnético. Inicialmente, o sinal do laço indutivo passa por um filtro passa-faixa que elimina as frequências capturadas fora do espectro de trabalho do sistema detector. Em seguida, o sinal passa por um transformador que isola o laço instalado no asfalto da eletrônica da placa detectora, elevando o sinal através da relação de 16:1 das bobinas. O sinal é então amplificado eletronicamente e passa por um estágio corta-faixa que elimina a frequência de 60 Hz. O sinal finalmente é digitalizado no conversor analógico-digital de 12 bits, que resulta no perfil magnético apresentado.




Figura 1 - Diagrama do Sistema Detector [10].

B. Seleção da Base de Dados

Para garantir uma grande quantidade de perfis magnéticos, a fim de agregar dados suficientes, permitindo uma boa análise estatística, o processo de coleta foi automatizado em conjunto com a imagem do veículo correspondente. A captura pelas câmeras dos equipamentos foi regulada para garantir a visualização completa do veículo, permitindo a compreensão correta da categoria equivalente. Os dados foram coletados a partir de um equipamento do tipo DEV, fabricante Perkons S/A, localizado na BR-277, próximo a represa da Vossoroca. De forma a obter uma quantidade homogênea de veículos das diferentes classes e agregar possíveis veículos ao banco de dados que não circulam neste equipamento, foram coletadas amostras de ônibus, vans e motos em outros equipamentos instalados em Curitiba e Campo Grande.

O banco de dados gerado foi distribuído em classes, conforme análise da imagem gerada para cada veículo atribuiu-se uma classe equivalente. A base de dados foi constituída por 3906 veículos, sendo 592 carros, 488 motos, 495 ônibus, 640 caminhões, 520 carretas, 407 vans, 436 caminhonetes e 328 camionetas.

C. Extração de Características

A extração de características do perfil magnético permite agrupar os veículos em diferentes categorias, sendo que os modelos de cada categoria apresentam perfis magnéticos semelhantes. O sistema proposto neste trabalho classifica veículos em oito categorias: carro, moto, ônibus, caminhão, carreta, caminhonete, camioneta e van.

Uma vez que se sabe a velocidade de cada veículo, tendo sido esta calculada através de dois sensores indutivos instalados em distância fixa, pode-se eliminar a dependência deste parâmetro, normalizando-se o perfil ao longo do tempo. As diferenças construtivas dos laços indutivos, bem como dos parâmetros de ajuste e offset, são corrigidas, normalizando a amplitude dos sinais magnéticos obtidos.

A Figura 2 mostra a curva de perfil magnético normalizadas no eixo horizontal (comprimento) e vertical (amplitude) para um veículo do tipo caminhão. Para a classificação utilizaram-se somente as curvas geradas a partir de um dos laços, uma vez que a informação provida a partir do segundo laço é praticamente a mesma que a do primeiro, não sendo necessária para a análise do problema.




Figura 2 - Características do Perfil Magnético Normalizado.

Foram extraídas 10 características dos perfis magnéticos normalizados, para serem utilizadas como entrada para o sistema de classificação. As características foram escolhidas de forma a tornar as classes facilmente diferenciáveis e foram tomadas com base na literatura revisada ([1], [5], [6], [7] e [11]). São apresentadas a seguir a notação, descrição e cálculo de cada uma das características.

L – Comprimento magnético do veículo - Comprimento a partir da ocupação do laço (metros) - $b+c$.

X_M – Valor médio - Somatória das amostras de perfil magnético dividido pelo número de pontos do perfil (adimensional) -

$$X_M = \frac{\sum_{i=1}^n x_i}{n}$$

sendo X_M o valor médio, x_i o valor do perfil magnético no ponto “i” e n o número de pontos do perfil magnético

N_p – Número de picos (inversões) - O número de picos é o total de inflexões na curva de perfil magnético, ou seja, quantas vezes a derivada primeira passa de valor negativo para positivo ou vice-versa (adimensional). - Algoritmo que analisa quantas vezes a derivada muda de sinal.

\bar{X}_i – Valor médio de picos - Essa medida é obtida através dos valores médios dos pontos de inversão (adimensional). -

$$\bar{X}_i = \frac{\sum_{j=1}^{n_i} X_j}{n_i}$$

onde \bar{X}_i é o valor médio das inversões do perfil magnético, X_j o valor do perfil magnético na inversão j e n_i é o número de inversões ocorridas no perfil magnético.

Var – Variância normalizada - A variância é uma medida da variabilidade dos dados em torno da média.

$$Var = \sqrt{\frac{\sum_{i=1}^n (X_i - X_M)^2}{n - 1}}$$

É definida como o desvio quadrático médio em relação ao valor médio (adimensional) - A variância Var é obtida a partir de X_i (valor do perfil magnético normalizado em amplitude e comprimento no ponto i), X_M (valor médio do perfil magnético normalizado em amplitude e comprimento) e n (número de pontos do perfil magnético).

SR_N – Taxa de subida normalizada (“Slew Rate”) - Inclinação do perfil no ponto de ordenada $y=A/2$. $[(\Delta L/L)/m = m^{-1}]$ - d

DOS – Grau de simetria (“Degree of Symetry”) - Seja m a mediana do perfil, DOS é a soma das distâncias (em y) até m de cada ponto acima da ordenada $y = A/2$ ($[\Delta L/L]$, adimensional) – $\sum \langle e_i, m \rangle$

m – Mediana - É definida como o valor que divide os dados ordenados ao meio, i.e. metade dos dados têm valores maiores do que a mediana, a outra metade tem valores menores do que a mediana.

NHM – Número de amostras de alta amplitude (“Number of High Magnitude”) - Número de amostras acima da ordenada y de valor igual a $A/2$ (adimensional).

SP – Parâmetro de forma (“Shape Parameter”) - Grandeza relacionada ao grau de simetria e obliquidade do perfil (adimensional). – $b/(b+c)$

A variação de indutância no laço indutivo é inversamente proporcional a distância entre a plataforma do veículo e o sensor. Desse modo, os ônibus e caminhões, por exemplo, produzem uma variação de indutância menor que um veículo de passageiro ou uma van. As curvas de perfis magnéticos apresentam características similares referentes a cada categoria de veículos. O perfil magnético de um veículo de passeio tem o formato de uma parábola. Ônibus e caminhões apresentam formatos com maiores ondulações. O perfil de uma van se assemelha a de um veículo de passeio, porém é mais largo na base da parábola. O formato da curva depende do chassi, comprimento do veículo e configuração de eixos [12].

O tempo de ocupação é o intervalo que o veículo permanece sobre o sensor indutivo e varia de acordo com a categoria do veículo. O tempo de ocupação de um automóvel é menor que o de um ônibus ou caminhão, na mesma velocidade, sendo diretamente proporcional ao comprimento do veículo. Foi levantada a distribuição estatística para o banco de dados de veículos pré-classificado para cada parâmetro descrito anteriormente.

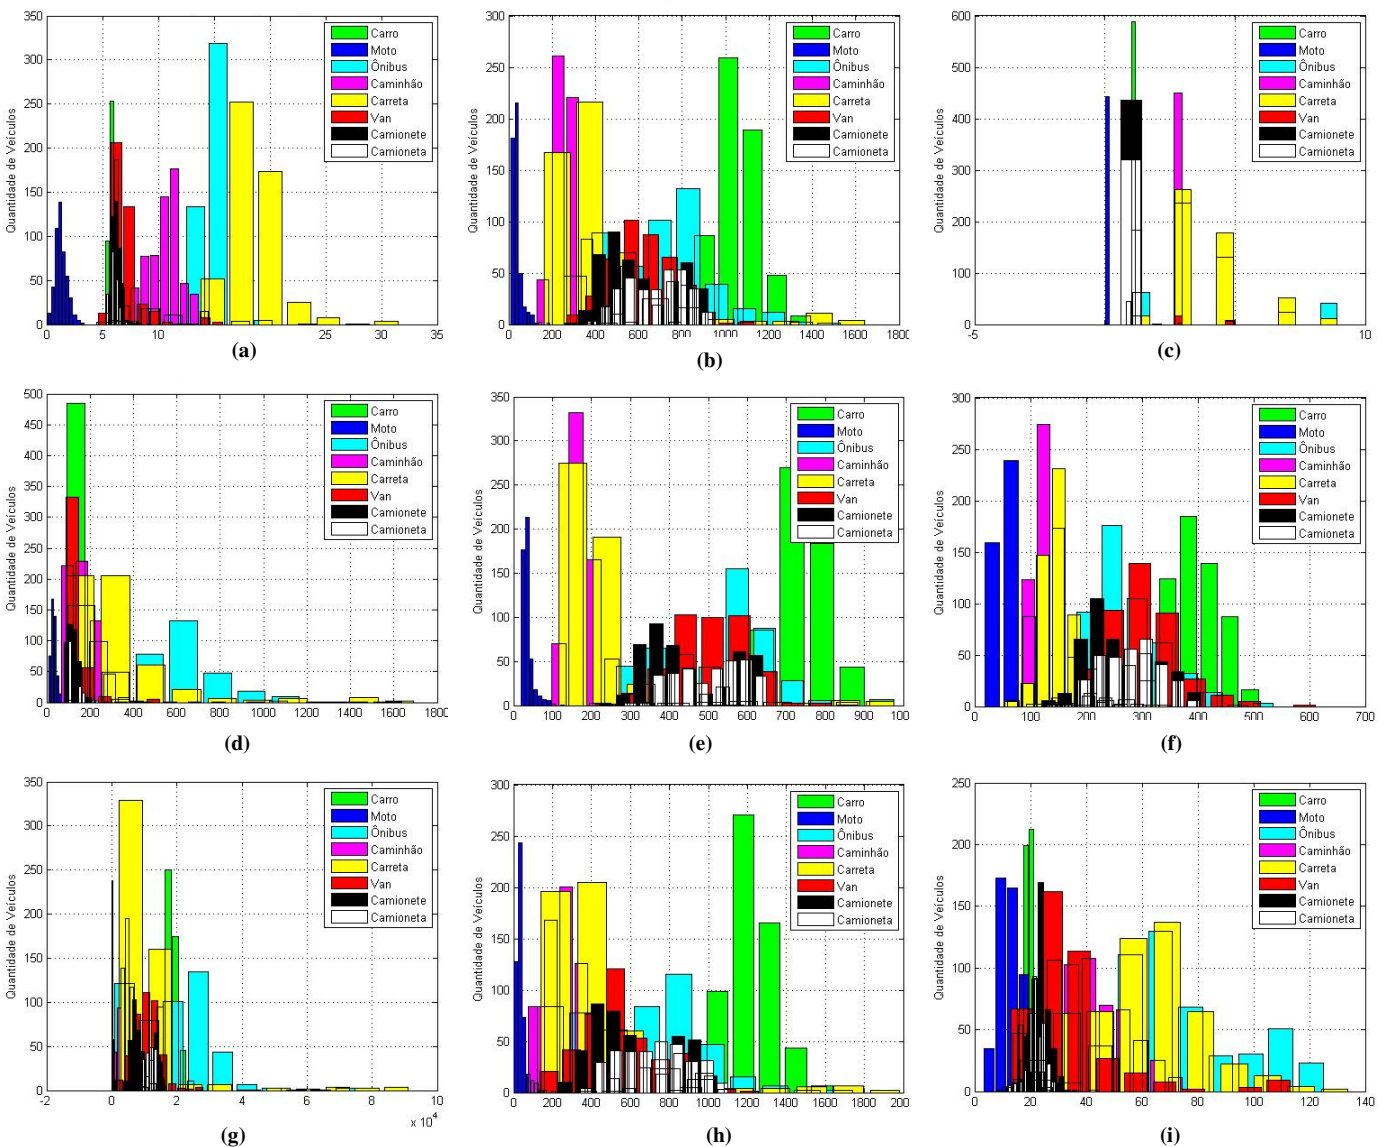


Figura 3 – Distribuição estatísticas para os diversos parâmetros extraídos dos perfis magnéticos para as 8 categorias. Comprimento Magnético (a), Valor Médio (b), Número de Picos (c), Valor médio de Picos (d), Variância (e), Taxa de Subida Normalizada (f), Grau de Simetria (g), Mediana (h) e Número de Amostras de AltaAmplitude (i).

O parâmetro comprimento magnético permite a diferenciação das categorias moto, caminhão e carreta. Porém, a diferenciação de camionetas, vans e utilitários torna-se impossibilitada e as categorias apresentam sobreposição em relação ao grupo de caminhões. Existe também uma pequena superposição entre os grupos de veículos de carretas e ônibus. Para o parâmetro valor médio evidencia-se a diferenciação da categoria moto. As variações mais acentuadas ocorrem para as categorias de carros e ônibus e os menores valores para carretas e caminhões. Já camionetas, caminhonetes e vans apresentam valores intermediários. Nota-se um grande número de inversões nos perfis magnéticos de carretas e ônibus, sendo estas as categorias que apresentam maiores valores médios de picos. Este parâmetro permite pequena separação entre ônibus e caminhões/carretas. Os histogramas de variância permitem verificar a separação da categoria carro das demais. Ônibus, caminhonetes, camionetas e vans apresentam valores intermediários, caminhões e carretas apresentam os menores valores. O grau de simetria e o parâmetro de forma permitem a importante separação entre camionetas (maiores valores) de caminhonetes (menores valores). As categorias ônibus e carreta apresentam os maiores valores de grau de simetria. Já a taxa de subida normalizada permite a separação entre carros e caminhonetes/camionetas/vans, permitindo também a diferenciação entre carretas e ônibus. Os maiores valores de taxa de subida são apresentados pelos carros e os menores pelas motos. Observando o histograma para a mediana, nota-se que as caminhonetes e camionetas apresentam valores superiores deste parâmetro em relação a vans. A mediana permite a diferenciação entre ônibus e vans. O número de amostras de alta amplitude (NHM) possibilita uma importante separação das vans em relação a caminhonetes e camionetas.

D. Arquitetura da Rede Neural e Treinamento

O sistema classificador é constituído por uma rede neural Multi-Layer Perceptron (MLP) com função de ativação tangente hiperbólica (tanh) para os neurônios da camada oculta, treinada por algoritmo de retropropagação de erro (BNN – Back-Propagation Neural Network). As entradas utilizadas para a rede neural foram constituídas pelas características extraídas do perfil de cada veículo, descritos na seção C. A saída é constituída por 8 neurônios, sendo um para cada classe de veículos a categorizar.

O treinamento e simulação foram feitos no MATLAB 7 utilizando o Neural Network Toolbox. Três tipos de algoritmos de treinamento foram testados: Levenberg-Marquardt, *Automated Regularization* (trainbr) e de Parada Antecipada (*Early Stopping*) sendo o critério de parada o número máximo de 100 épocas de treinamento ou o erro quadrático médio não superior a 1×10^{-10} . Foram testadas diversas configurações de rede, sempre com uma camada oculta, variando-se os neurônios da camada de entrada para cada teste. O número de neurônios da camada oculta variou de acordo com os parâmetros de entrada, tendo sido utilizado sempre o valor inteiro mais próximo da média entre o número de entradas e saídas [12].

Devido ao fato de a inicialização dos pesos (*bias*) da rede neural ser feito com valores aleatórios, o treinamento e validação da rede era repetido, até se obter a taxa de acerto mínima de 70%, para o conjunto de validação, para cada caso de teste.

O total de veículos foi dividido em 3 conjuntos (35% para treinamento, 15% para validação e 50% para teste) mantendo-se a proporção para o total de veículos de cada classe. As entradas de dados para treinamento e validação estavam agrupadas por classes em um arquivo contendo todos os padrões da classe 1 seguidos pelos padrões da classe 2 e assim sucessivamente. Como os algoritmos utilizados pelo MATLAB atualizam os parâmetros após a apresentação de cada padrão, não é recomendada a apresentação de padrões de uma mesma classe. Por isso, o conjunto de treinamento teve de ser "embaralhado".

Cada configuração da rede neural utilizou um tipo de conjunto de neurônios de entrada, tendo sido testadas as seguintes combinações

- Caso 1: Todos os parâmetros da Tabela 1. Neste caso foram utilizados 9 neurônios na camada oculta.
- Caso 2: Os microônibus foram agrupados na mesma classe que as vans. Neste caso foram utilizados 9 neurônios na camada oculta.
- Caso 3: Mesmos parâmetros do perfil utilizados para classificação em 4 categorias por Calixto (comprimento magnético, valor médio e número de picos [1]. Neste caso foram utilizados 5 neurônios na camada oculta.
- Caso 4: Parâmetros do perfil utilizados para classificação em 6 categorias por Calixto (comprimento magnético, valor médio, número de picos, valor médio de picos e variância) [1]. Neste caso foram utilizados 6 neurônios na camada oculta.
- Caso 5: parâmetros do perfil utilizados em [5], [6], [7] e [11]. Neste caso foram utilizados 6 neurônios na camada oculta.
- Caso 6: Ao analisar o histograma da Figura 3, verificou-se que o valor médio de picos e o grau de simetria não contribuem significativamente para a separação entre categorias de veículos, podendo inclusive gerar erros no sistema classificador. Portanto tais parâmetros foram desconsiderados para este último caso de teste, em que se utilizou 8 parâmetros para os neurônios de entrada. Neste caso foram utilizados 8 neurônios na camada oculta.

3 Resultados

Para cada configuração de rede neural foram realizados os seguintes procedimentos:

- Treinamento utilizando o conjunto de treinamento
- Validação utilizando o conjunto de validação
- Simulação da rede com o conjunto de dados de teste
- Verificação do resultado obtido contra o esperado

Os resultados dos testes para cada um dos casos simulados são mostrados na Tabela 1, sendo destacados os maiores índices de acerto para cada caso de teste, e indicado o algoritmo de treinamento da rede neural que acarretou em um maior índice de classificação (número de veículos classificados corretamente pelo total de veículos testados).

Tabela 1 – Índices de acertos na classificação para cada categoria.

Caso Teste	Algoritmo de Treinamento	Carro	Moto	Ônibus	Caminhão	Carreta	Van	Caminhonete	Camioneta	Total
1	Bayes Regulation (BR)	98%	99%	90%	95%	93%	74%	78%	65%	88%
2	Early Stopping (ES)	98%	99%	90%	96%	97%	47%	86%	77%	89%
3	Levenberg Marquardt (LM)	97%	100,00%	78%	92%	94%	31%	55%	70%	80%
4	Bayes Regulation (BR)	98%	100,00%	87%	94%	94%	62%	78,18%	65%	87%
5	Bayes Regulation (BR)	97%	100%	94%	91%	90%	65%	65%	69%	86%
6	Early Stopping (ES)	98%	100%	95%	95%	95%	64%	80%	80%	90%

Observando-se a Tabela 1, verifica-se que o maior índice de classificação geral e para cada categoria foi a rede neural utilizando 8 parâmetros, superando inclusive a rede que utilizou todos os 10 parâmetros, o que comprova que a eliminação de 2 parâmetros (grau de simetria e valor médio de picos) permitiu um aumento de acertos de classificação para as categorias ônibus, caminhonete e camioneta e uma diminuição dos acertos para as vans.

A Tabela 2 apresenta os resultados totais e quantificados da classificação, sendo que nas linhas está registrada a quantidade de veículos referente à categoria (coluna) de acordo com a imagem observada e nas colunas está registrada a classificação que o sistema atribuiu.

Tabela 2 – Classificação de veículos para o caso de teste 6.

CATEGORIA REAL	CLASSIFICAÇÃO PELA REDE NEURAL								Total Real
	Carro	Moto	Ônibus	Caminhão	Carreta	Van	Caminhonete	Camioneta	
Carro	293	2	0	0	0	0	3	0	298
Moto	0	250	0	1	0	0	0	0	251
Ônibus	4	1	235	4	2	2	0	0	248
Caminhão	0	1	0	307	5	2	7	0	322
Carreta	0	0	5	5	248	0	0	2	260
Van	5	0	25	1	0	132	10	32	205
Caminhonete	0	0	0	2	0	4	175	38	219
Camioneta	2	0	0	0	0	10	21	128	161
Total Classificação	304	254	265	320	255	150	216	200	1964

A partir da análise da Tabela 2, evidencia-se que:

- Apenas 5 caminhões foram classificados como carretas e apenas 5 carretas foram classificados como caminhões.
- Apenas 4 ônibus foram confundidos com caminhões
- As categorias carro, moto, ônibus, caminhões e carretas puderam ser separadas umas das outras com grande confiabilidade.
- Apenas 2 camionetas e 5 vans foram confundidas com veículos de passeio e apenas 3 carros foram classificados como caminhonete. O sistema foi capaz de separar com eficiência a categoria carro da categoria de utilitários (vans, caminhonetes e camionetas).

- A utilização de apenas 3 parâmetros de entrada apresenta bons resultados para classificação em 6 categorias, entretanto é insuficiente para separar as classes de veículos de caminhonetes, camionetas e vans. Acrescentando os parâmetros de valor médio de picos e variância, é possível obter melhores índices para as categorias de vans e caminhonetes.
- Os parâmetros utilizados em [5], [6], [7] e [11] se mostraram menos eficientes para classificar caminhões e carretas que aqueles utilizados por Calixto [1], em compensação apresentaram maiores índices de classificação para as categorias de van e camioneta.
- O agrupamento de vans e microônibus na mesma categoria (Caso de Teste 2) acarretou uma melhora significativa na classificação de caminhonetes e camionetas, entretanto um maior número de vans foi classificado como ônibus, o que ocasionou o decréscimo no índice de classificação.

Entre as categorias de vans, camionetas e caminhonetes ocorreram os maiores erros na classificação, conforme já era previsto, devido ao fato de os perfis magnéticos entre estes tipos de veículos apresentarem muitas semelhanças. Ainda assim, os índices de acertos de classificação para estas categorias são superiores aos respectivos índices obtidos por Sun [6] (71% para o total de veículos, sendo que caminhonetes e camionetas estavam agrupadas em uma mesma categoria e as vans em outra categoria. Um índice de 75% de acerto foi obtido por Oh e Ritchie (2007) [11] para classificação de caminhonetes, camionetas e carros e de 58,3% para vans. Neste último, foram utilizados para testes apenas 12 veículos de cada categoria. o sistema foi implementado através de uma rede neural probabilística com esquema de decisão bayesiano. As variáveis de entrada foram comprimento magnético, amplitude, desvio padrão, parâmetro de forma e grau de simetria. Já em outro trabalho de Ritchie [7] foram obtidos índices de classificação de 96,24% para carros, 61,58% para caminhonetes (total de 133 no teste), 51,34% para vans (total de 638) e 47,63% para camionetas (apenas 42 no teste). Foram utilizadas as mesmas variáveis de entrada do trabalho de Oh e Ritchie (2007) [11], entretanto o sistema foi implementado através de árvore de decisão heurística.

O sistema de classificação proposto por Oh et al.(2002) [5] também utiliza uma rede neural com retropropagação de erro, utilizando como parâmetros de entrada a máxima amplitude do perfil, o comprimento magnético, o parâmetro de forma e a área sob a curva do perfil. Os veículos foram classificados em 7 categorias tendo alcançado índice de classificação geral de 82,6%. O percentual de acertos na classificação para as categorias foram respectivamente: carros e minivans, 88,6%; camionetas, 74,3%; van e microônibus, 75%; caminhonetes, 75,7%; caminhão 85,4%; carreta, 100%; ônibus, 100%, sendo que para esta última classe apenas 10 veículos foram utilizados no teste.

Os índices de classificação para carros, motos, ônibus, caminhões e carretas ficaram muito próximos aos valores obtidos por Calixto [1] para as mesmas categorias.

4 Conclusões

Neste trabalho foi apresentado um sistema para classificação de veículos em oito categorias baseado em rede neural cujas variáveis de entrada foram extraídas a partir dos perfis magnéticos dos veículos. Os testes foram realizados utilizando diferentes combinações de variáveis de entrada para a rede neural, variando desde 3 até 10 parâmetros.

A rede neural com retropropagação de erro com 8 neurônios na camada oculta e oito parâmetros de entrada selecionados a partir da capacidade de diferenciação entre classes, alcançou os resultados na classificação geral de 90%. Os índices de classificação para carros, motos, ônibus, caminhões, carretas, vans, caminhonetes, e camionetas foram de 98%, 100%, 95%, 95%, 95%, 64%, 80% e 80%, respectivamente. Com exceção das classes de utilitários (vans, camionetas e caminhonetes), os demais tipos de veículos apresentaram alta taxa de classificação por apresentarem características extraídas do perfil magnético bastante distinguíveis.

5 Referências

- [1] Calixto, S. A. ,“Classificação de Veículos Através de Sistemas Fuzzy”. **Dissertação apresentado a UTFPR**, março, 2006
- [2] Bohnke, P., Pfannerstill, E. A system for the automatic detection of traffic situations. **ITE Journal**, vol. 56, 1986.
- [3] Andreotti, M.,“Sensoriamento Indutivo para Veículos Automotores”. **Dissertação apresentado a UTFPR**, abril, 2001.
- [4] Magalhães, H. A., “Análise em Alta Resolução de Perfis Magnéticos de Sensores a Laço Indutivo e Metodologia de Fusão com Características de Imagem para Classificação de Veículos. **Tese apresentada a UFMG**, maio, 2008.
- [5] Oh, S., Ritchie, Stephen G., Oh, C., “Real Time Traffic Measurement from Single Loop Inductive Signatures”, **81st Annual Meeting of the Transportation Research Board**, Washington, D. C., January, 2002.
- [6] Sun, C. “An Investigation in the Use of Inductive Loop Signatures for Vehicle Classification” **California PATH Research Report UCB-ITS-PRR-2000-4**. Institute of Transportation Studies, University of California, Irvine, CA, USA, March, 2000.
- [7] Ritchie, Stephen G., Park, S., Oh, Jeng, Shing-Ting, Tok, A. “Field Investigation of Advanced Vehicle Reidentification Techniques and Detector Technologies – Phase 2”, **California PATH Research Report UCB-ITS-PRR-2005-8**, Institute of Transportation Studies, University of California, Irvine, CA, USA, March, 2005.
- [8] Oliveira H.A, Barbosa, F.R, Almeida, O.M., Braga, A.P.S. “Reconhecimento de Porte de Veículos com Análise de Perfil Magnético com Sensores Indutivos Instalados na Via de Trânsito Utilizando Redes Neurais Artificiais”. **XIII Congresso Brasileiro de Automática**, pp. 3568-3574, Setembro 2010.

- [9] Barbosa, H.M. et al (2004). “Sistema de Identificação de Veículos por Meio de Laços de Indução: Um projeto Integrado de Ensino e Desenvolvimento Tecnológico”. Anais eletrônicos do **XVIII Congresso Nacional de Pesquisa e Ensino em Transportes**, ANPET.
- [10] Nishimoto, R. E. ,“Novas Geometrias de Laços Indutivos”. **Dissertação apresentado a UTFPR**, dezembro, 2006.
- [11] Oh, C., Ritchie, Stephen G, Jeng, Shin-Ting. “Anonymous Vehicle Reidentification Using Heterogeneous Detection Systems”, **IEEE Transactions on Intelligent Transportation System**, 8(3):460- 9, September, 2007.
- [12] Ki, Y. K., Baik, D. K. “Vehicle-Classification Algorithm for Single-Loop Detectors Using Neural Networks”, **IEEE Transactions on Vehicular Technology**, Vol. 55, No. 6, Novembro, 2006