



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA ELÉTRICA

HERIVELTON ALVES DE OLIVEIRA

**SISTEMA DE RECONHECIMENTO DE PADRÕES PARA IDENTIFICAÇÃO DE
PORTE DE VEÍCULOS ATRAVÉS DE ANÁLISE DE PERFIL MAGNÉTICO**

FORTALEZA

2011

Herivelton Alves de Oliveira

**SISTEMA DE RECONHECIMENTO DE PADRÕES PARA IDENTIFICAÇÃO DE
PORTE DE VEÍCULOS ATRAVÉS DE ANÁLISE DE PERFIL MAGNÉTICO**

Dissertação submetida à Universidade Federal
do Ceará, como requisito parcial para obtenção
do grau de Mestre em Engenharia Elétrica.

Orientador:

Otacílio da Mota Almeida, Dr.

Co-orientador:

Arthur Plínio de Souza Braga, Dr.

Fortaleza
Setembro de 2011

HERIVELTON ALVES DE OLIVEIRA

**SISTEMA DE RECONHECIMENTO DE PADRÕES PARA
IDENTIFICAÇÃO DE PORTE DE VEÍCULOS ATRAVÉS DE ANÁLISE
DE PERFIL MAGNÉTICO**

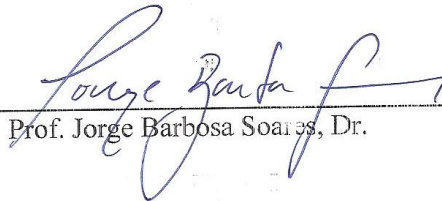
Esta Dissertação foi julgada adequada para a obtenção de título de Mestre em Engenharia Elétrica, Área de Concentração em Eletrônica de Potência e Acionamentos, e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Ceará.


Herivelton Alves Barbosa

Orientador:


Prof. Otacilio da Mota Almeida, Dr.

Banca Examinadora:


Prof. Jorge Barbosa Soares, Dr.


Prof. Sergio Daher, Dr.


Prof. Arthur Plínio de Souza Braga, Dr.

Fortaleza, 08 de setembro de 2011

DEDICATÓRIA

Dedico este trabalho ao meu pai, Aauto Sidoca de Sousa Oliveira (*in memorian*), que sempre me incentivou a estudar e que contribuiu de forma direta para a formação moral que tenho hoje.

AGRADECIMENTOS

Agradeço a Deus por mais esta conquista e por ter me dado a força de vontade para concluir este trabalho.

À minha esposa Marie que teve paciência nos momentos de ausência e pelo apoio nos momentos de dificuldades.

À empresa Fotosensores® que financiou a realização dos estudos, a participação em congressos e a montagem de equipamentos para testes.

Aos colegas da Fotosensores® que de alguma forma contribuíram para a elaboração deste trabalho.

SUMÁRIO

DEDICATÓRIA.....	iv
AGRADECIMENTOS.....	v
SUMÁRIO.....	vi
LISTA DE FIGURAS.....	viii
LISTA DE TABELAS.....	x
LISTA DE SIGLAS E ABREVIATURAS.....	xi
RESUMO.....	xii
ABSTRACT.....	xiii
CAPÍTULO 1 - INTRODUÇÃO.....	1
1.1 JUSTIFICATIVA.....	1
1.2 OBJETIVOS.....	2
1.3 ARTIGOS GERADOS.....	3
1.4 ESTRUTURA DO TRABALHO.....	3
CAPÍTULO 2 - FUNDAMENTOS TEÓRICOS.....	5
2.1 SISTEMAS DE DETECÇÃO DE VEÍCULOS.....	5
2.1.1 LAÇOS INDUTIVOS.....	5
2.1.2 SENSORES PIEZELÉTRICOS.....	11
2.2. CLASSIFICAÇÃO VEICULAR.....	15
2.2.1 CLASSIFICADORES VEICULARES BASEADOS EM LAÇOS INDUTIVOS.....	16
2.2.2 CLASSIFICAÇÃO VEICULAR COM PROCESSAMENTO DE IMAGEM.....	18
2.2.3 CLASSIFICADORES VEICULARES BASEADOS EM LASER.....	19
2.3 SISTEMA CLASSIFICADOR UTILIZADO PELA FOTOSENSORES®.....	20
2.4 REDES NEURAIS ARTIFICIAIS.....	21
2.4.1 REDE PERCEPTRON DE MÚLTIPLAS CAMADAS (<i>MULTILAYER PERCEPTRON – MLP</i>).....	23
2.4.2 O ALGORÍTMO DE LEVENBERG-MARQUARDT.....	24
2.5 CONSIDERAÇÕES FINAIS.....	26
CAPÍTULO 3 - SISTEMA PROPOSTO.....	28
3.1 INTRODUÇÃO.....	28
3.1.1 CARACTERÍSTICAS DO PERFIL MAGNÉTICO UTILIZADAS.....	31

3.1.2 ETAPAS DE DESENVOLVIMENTO	38
3.2 AQUISIÇÃO DE DADOS.....	38
3.3 PROCESSAMENTO DOS DADOS.....	41
3.4 MONTAGEM DO PROTÓTIPO.....	42
3.5 CONSIDERAÇÕES FINAIS	45
CAPÍTULO 4 - DESENVOLVIMENTO DO SISTEMA CLASSIFICADOR	47
4.1. SISTEMA CLASSIFICADOR DESENVOLVIDO	47
4.2 RESULTADOS	53
4.3. COMENTÁRIOS FINAIS	57
CAPÍTULO 5 - CONCLUSÕES E TRABALHOS FUTUROS	58
5.1 CONCLUSÕES.....	58
5.2 RECOMENDAÇÕES PARA TRABALHOS FUTUROS	59
REFERÊNCIAS BIBLIOGRÁFICAS	60
APÊNDICE A - EXEMPLO DE UM CIRCUITO DE DETECÇÃO DE VEÍCULOS POR LAÇO INDUTIVO.....	65
A.1 - O HARDWARE DO IDENTIFICADOR DE VEÍCULOS:.....	65
A.1.1 O CIRCUITO OSCILADOR DE COLPITTS.....	65
A.1.2 O CIRCUITO PLL – <i>PHASE LOCKED LOOP</i>	67

LISTA DE FIGURAS

Figura 1.1 - Sinalização de velocidades distintas por porte.	2
Figura 2.1 - Esquema de montagem do sistema detector por laço indutivo (DLI).....	6
Figura 2.2 - Detecção de presença de veículo com laços indutivos (adaptado de CALIXTO, 2006).....	7
Figura 2.3 - Gráficos de perfil magnético para diferentes tipos de veículos.	7
Figura 2.4 - Sistema com dois laços indutivos por faixa.	8
Figura 2.5 - Esquema com dois laços indutivos destacando o tempo de desacionamento.	9
Figura 2.6 - Esquema com 3 sensores indutivos.	9
Figura 2.7 - Parâmetros de comprimento e largura do laço indutivo (NISHIMOTO, 2006)...	10
Figura 2.8 - Situação em que ocorre <i>splash over</i>	11
Figura 2.9 - Esquema de um sensor piezelétrico com PZT	12
Figura 2.10 - Seção transversal do cabo piezelétrico (SIMONI, 2008).	13
Figura 2.11 - Sensor piezelétrico coaxial.	13
Figura 2.12 - Sistema de pesagem com sensores piezelétricos.	14
Figura 2.13 - Sensor piezelétrico tipo retangular.	14
Figura 2.14 - Sensor piezelétrico retangular instalado.	14
Figura 2.15 - Sistema analógico de detecção por laço indutivo (adaptado de CALIXTO, 2006).....	16
Figura 2.16 - Fixação da câmera para coleta da perspectiva superior do veículo (CALIXTO, 2006).....	19
Figura 2.17- Classificador veicular baseado em laser (adaptado de HARLOW e PENG, 2001 e MAGALHÃES, 2008).	20
Figura 2.18 - Neurônio biológico: os constituintes da célula.	22
Figura 2.19 - Neurônio artificial (HAYKIN, 1999).	23
Figura 2.20 - Topologia Típica de uma Rede MLP de três camadas.	24
Figura 3.1 - Categorias ou classes de veículos adotadas (adaptado de META e CINSDIKICI, 2010).....	28
Figura 3.2 - Esquema do aplicativo SGL da Fotosensores®.....	32
Figura 3.3 - Extração de características do perfil magnético (adaptado de OH <i>et al.</i> , 2002 e RITCHIE <i>et al.</i> , 2005).	33
Figura 3.4 - Imagem e perfil magnético de um veículo pequeno.	1

Figura 3.5 - Imagem e perfil magnético de uma motocicleta.....	1
Figura 3.6 - Imagem e perfil magnético de uma caminhonete.....	1
Figura 3.7 - Imagem e perfil magnético de um veículo tipo van.....	1
Figura 3.8 - Imagem e perfil magnético de caminhão.....	1
Figura 3.9 - Imagem e perfil magnético de um ônibus.....	1
Figura 3.10 - Diagrama de Atividades	38
Figura 3.11 - Equipamento de fiscalização de trânsito em Fortaleza.....	39
Figura 3.12 - Esquema de ligação do sistema de fiscalização eletrônica.....	40
Figura 3.13 - Disposição dos laços indutivos do sistema a utilizado (distância em metros)....	41
Figura 3.14 - Gráficos do perfil magnético antes e depois do deslocamento.....	42
Figura 3.15 - Informações extraídas do perfil magnético.....	42
Figura 3.16 - Equipamento de fiscalização de tráfego.....	43
Figura 3.17 - Visão interna do equipamento.....	43
Figura 3.18 - Tela principal do SGL.....	44
Figura 3.19 - Tela de configuração de funcionalidades.....	45
Figura 4.4 - Tela inicial do FotoPerfil.....	49
Figura 4.5 - Tela de Dados.....	49
Figura 4.6 - Tela de consistência.....	50
Figura 4.7 - Tela de treinamento.....	51
Figura 4.8 - Tela de avaliação da RNA.....	52
Figura 4.9 - Tela de avaliação de resultados do classificador.....	52
Figura A.1 - Indutância e assinatura de identificação da classe do veículo (BARBOSA <i>et al.</i> , 2004).....	66
Figura A.2 - Oscilador de Colpitts (BARBOSA <i>et al.</i> , 2004).....	66
Figura A.3 - Diagrama de conexões do PLL ao oscilador Colpitts (BARBOSA <i>et al.</i> , 2004)	68

LISTA DE TABELAS

Tabela 2.1 - Classificação veicular segundo FHWA.....	15
Tabela 2.2 - Classificação veicular segundo CALIXTO(2006)	17
Tabela 2.3 - Classes de veículos segundo META e CINSDIKICI.....	18
Tabela 2.4 - Categorias de veículos adotadas atualmente pela Fotosensores®.....	21
Tabela 3.1 - Subclassificação quanto à espécie do CTB.....	29
Tabela 3.2 - Frota de veículos no Brasil e em Fortaleza segundo o DENATRAN em Março de 2011.	30
Tabela 3.3 - Quantidade de veículos nas classes propostas.....	31
Tabela 3.4 - Características extraídas de perfis magnéticos (adaptado de OH <i>et al.</i> , 2002, OH, RITCHIE e STEPHEN, 2003, RITCHIE <i>et al.</i> , 2005).....	33
Tabela 3.5 - Entradas da RNA.....	37
Tabela 4.1 - Valores de saída do neurônio da camada de saída	48
Tabela 4.2 - As 5 classes de veículos definidas.....	51
Tabela 4.3 - Resultados simulação da rede com dados de treinamento.	53
Tabela 4.4 - Resultados simulação da rede com dados de teste.	54
Tabela 4.5 - Resultados com classificador desenvolvido em Matlab.....	54
Tabela 4.6 - Resultado da classificação veicular em 4 categorias.....	55
Tabela 4.7 - Resultado da classificação veicular em 5 categorias.....	56

LISTA DE SIGLAS E ABREVIATURAS

RNA – Redes Neurais Artificiais

ITS – *Intelligent Transportation Systems*

CTB – Código de Trânsito Brasileiro

FHWA – *Federal Highway Administration*

ILD – *Inductive Loop Detector*

DLI – Detector por Laço Indutivo

PZT – Titanato Zirconato de Chumbo

PVDF – Fluoreto de Polivinilideno

WIM – *Weigh-in-motion*

SOFM – *Self-Organizing Feature Map*

PCA – *Principal Component Analysis*

UART – *Universal Asynchronous Receiver/Transmitter*

SMTD – Sistema de Monitoramento de Tráfego Digital

MLP – *Multilayer Perceptron*

LGPL – *Lesser General Public License*

Oliveira, H. A. “SISTEMA DE RECONHECIMENTO DE PADRÕES PARA IDENTIFICAÇÃO DE PORTE DE VEÍCULOS ATRAVÉS DE ANÁLISE DE PERFIL MAGNÉTICO.” Universidade Federal do Ceará – UFC, 2011.

RESUMO

Atualmente os órgãos de trânsito utilizam os sistemas de monitoramento de tráfego para redução de acidentes de trânsito e como ferramenta fundamental para a coleta de dados estatísticos para auxiliar no planejamento e gerenciamento dos sistemas viários. Nestes dados são observadas informações como a quantidade de veículos que trafegam em determinado ponto, a velocidade média e a identificação da categoria dos veículos. A identificação da categoria dos veículos que trafegam em uma via permite o controle de acesso a faixas de rolagem destinadas a uma classe de veículos específica. O objetivo desse trabalho é propor uma solução para classificação de veículos através da análise de sinais coletados de sensores indutivos no momento em que o veículo passa sobre os mesmos. O conjunto destes sinais para cada veículo é denominado perfil magnético. Foi utilizado um classificador baseado em Rede Neural Artificial (RNA) para identificar o tipo de veículo de acordo com o padrão do perfil magnético coletado. Na implementação do sistema foi utilizado um *framework* Java que possibilitou a integração da RNA ao aplicativo que opera no equipamento de monitoramento de tráfego. Também foi desenvolvido um aplicativo em Java que permite realizar o treinamento da rede utilizando dados coletados no equipamento e também permite avaliar posteriormente os resultados obtidos pela RNA. Os veículos foram classificados nas seguintes categorias: motos, veículos pequenos, veículos médios, ônibus e caminhões. O sistema desenvolvido foi integrado a um equipamento de fiscalização de tráfego fabricado pela empresa Fotosensores® e apresentou resultados satisfatórios, pois o índice de acerto geral do classificador foi de 97%, além de representar uma melhoria no equipamento que anteriormente realizava a classificação em somente quatro classes de veículos.

Palavras-chaves: Perfil magnético, Rede Neural Artificial, Classificador, Java, Laços Indutivos.

Oliveira, H. A. “A PATTERN RECOGNITION SYSTEM FOR IDENTIFICATION OF VEHICLES BY ANALYSIS OF MAGNETIC PROFILE.” Universidade Federal do Ceará – UFC, 2011.

ABSTRACT

Currently, transit agencies use traffic monitoring systems to reduce traffic accidents and as a fundamental tool for collecting statistical data for planning and management of road systems. These data are observed as the amount of information vehicles that travel at a certain point, the average speed and the identification of the category of vehicles. The identification of the category of vehicles that travels on a path allows you to control access lanes connecting to a specific class of vehicles. The objective of this work is to propose a solution for vehicle classification by analyzing signals collected from inductive sensors at the time the vehicle passes over the sensors. This set of signs for each vehicle is called the magnetic profile. This work used a classifier based on Artificial Neural Network (ANN) to identify the type of vehicle according to the pattern of magnetic profile collected. The implemented system used a Java framework that enabled the integration of ANN to the application that operates in the traffic monitoring equipment. It was developed a Java application that trains the ANN using data collected in the equipment and also allows evaluating further classification results obtained by the ANN. The vehicles were classified into the following categories: motorcycles, small vehicles, medium vehicles, buses and trucks. The developed system has been integrated into a traffic monitoring equipment manufactured by Fotosensores® and gave satisfactory results with an overall success rate above 97%. It represents an improvement in the equipment that carried out the classification.

Keywords: Magnetic Profile, Artificial Neural Network, Classification, Java, Inductive Loops.

CAPÍTULO 1 - INTRODUÇÃO

1.1 JUSTIFICATIVA

Os órgãos de trânsito possuem a necessidade de ter informações estatísticas relacionadas ao fluxo de veículos nas ruas e avenidas da cidade. As informações necessárias vão desde a quantidade de veículos que passa em cada trecho por dia, bem como a classificação dos veículos pelo porte, classificação por faixa de velocidade e até mesmo o número de veículos que cometem infrações todos os dias. Com base nestas informações é possível fazer um planejamento para construção de novas vias de acesso e viadutos, instalação de semáforos e elaboração de estudos técnicos para instalação de sistemas de registro de infração. Também é possível auxiliar na melhoria do tráfego em tempo real, pois as informações podem alimentar sistemas observados por agentes de trânsito com autonomia de intervir em determinados trechos criando rotas alternativas para uma melhor distribuição do fluxo de veículos. Esta melhoria no tráfego também pode ser feita de forma automática, como por exemplo, em semáforos inteligentes que podem ser alimentados com estas informações para determinar os melhores tempos de fase para cada foco luminoso de acordo com fluxo registrado.

Uma forma eficiente de fornecer todas estas informações é a utilização de sistemas eletrônicos de gerenciamento de dados de trânsito. Também conhecidos como ITS (*Intelligent Transportation Systems*), estes sistemas são implantados com outros objetivos como garantir a fluidez do trânsito, automatizar os sistemas de controle, além de educar e punir os motoristas infratores (MIMBELA, KLEIN, 2000; NISHIMOTO, 2006; CALIXTO, 2006; SIMONI, 2008).

Nesta dissertação é apresentada uma solução para classificação de porte veicular utilizando sensores indutivos, os quais são bastante utilizados devido ao baixo custo. O classificador apresentado foi desenvolvido com uma Rede Neural Artificial (RNA) (HAYKIN, 1999) por ser bastante eficiente para esta função.

A solução foi integrada em um equipamento de fiscalização de tráfego que utiliza atualmente um classificador apenas baseado no tamanho do veículo. Este método não permite distinguir ônibus de caminhões por estes veículos apresentarem tamanhos praticamente iguais, além da dificuldade de separar carros de passeio de caminhonetes. O sistema novo vai

permitir o aumento do número de classes e melhorar a precisão. O sistema utilizado atualmente classifica os veículos em motocicleta, veículo pequeno, veículo médio e veículo grande. O sistema desenvolvido permitirá a classificação em motocicleta, veículo pequeno, veículo médio, caminhão e ônibus. A divisão da classe de veículos grandes em ônibus e caminhões possibilita a utilização do sistema em equipamentos de fiscalização de tráfego que registra a imagem de veículos trafegando em faixas de rolagem exclusivas para ônibus.

1.2 OBJETIVOS

O objetivo deste trabalho é desenvolver um sistema para a classificação de veículos que transitam em vias urbanas e rodovias que possa ser integrado nos equipamentos de fiscalização veicular, sem a necessidade de alteração de hardware. A análise dos sinais coletados de sensores indutivos será feita utilizando-se algoritmos de Redes Neurais Artificiais (RNA). A solução proposta pode ser aplicada em sistemas de fiscalização eletrônica em rodovias onde a velocidade máxima regulamentada seja diferente de acordo com o tipo de veículo, como por exemplo, velocidade máxima permitida de 100 km/h para veículo de pequeno e médio porte e 80 km/h para ônibus e caminhões (Figura 1.1), além de permitir o registro de infrações para veículos trafegando em faixas ou vias destinadas exclusivamente a determinados tipos de veículos. Também pode ser aplicada em contadores de veículos fornecendo dados estatísticos do fluxo de veículos em determinadas avenidas, estradas, ruas, etc. A solução está integrada a um equipamento de fiscalização de tráfego fornecido pela empresa Fotosensores®. A empresa atualmente possui uma solução de classificação dos veículos baseada apenas no tamanho dos veículos.



Figura 1.1 - Sinalização de velocidades distintas por porte.

Nas rodovias onde não houver sinalização regulamentadora o parágrafo II do inciso primeiro do artigo 61 do Código de Trânsito Brasileiro (CTB, 1997) define as seguintes velocidades máximas permitidas:

1. Cento e dez quilômetros por hora para automóveis, camionetas e motocicletas; (Redação dada pela Lei nº 10.830, de 2003);
2. Noventa quilômetros por hora, para ônibus e microônibus;
3. Oitenta quilômetros por hora, para os demais veículos;

Observa-se que os caminhões não são citados no texto da lei apresentado acima, o que indica que estes fazem parte do conjunto dos demais veículos. Os equipamentos eletrônicos de fiscalização fabricados pela empresa Fotosensores®, empregados atualmente para o controle automático de velocidade em vias, não possuem tecnologia para diferenciar ônibus de caminhões, o que impossibilita a atribuição de velocidades máximas distintas regulamentadas conforme nas três categorias citadas na lei. Com a classificação proposta neste trabalho, o sistema passa a efetuar tal atividade.

1.3 ARTIGOS GERADOS

Os resultados desta pesquisa geraram os seguintes artigos:

- 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. XVIII Congresso Brasileiro de Automática (CBA), 2010, Bonito-MS.
- OLIVEIRA, H. A., BARBOSA, F. R., ALMEIDA, O. M., BRAGA, A. P. S., A Vehicle Classification Based on Inductive Loop Detectors Using Artificial Neural Networks. INDUSCON, 2010, São Paulo - SP.

1.4 ESTRUTURA DO TRABALHO

O trabalho apresentado está organizado em cinco capítulos. Nesse capítulo foram apresentados a justificativa e os objetivos do sistema proposto.

No Capítulo 2 discorre-se sobre as principais tecnologias para coleta de dados e classificação de veículos. Além da solução aqui utilizada (através da análise da resposta magnética gerada pelos veículos), outras podem ser aplicadas, como técnicas baseadas em reconhecimento do padrão de imagem do veículo ou no padrão gerado por sinais de laser.

Ainda nesse capítulo são apresentados os principais estudos que utilizam o sensoriamento magnético para classificação de veículos.

No Capítulo 3 discutem-se os conceitos físicos envolvidos nos métodos empregados para detecção de veículos através de sensores indutivos. É discutido o sistema de aquisição utilizado nesta dissertação e o cenário utilizado para desenvolvimento do sistema classificador.

A construção do sistema, os conceitos de Redes Neurais Artificiais e a extração de parâmetros do perfil magnético dos veículos são apresentados no Capítulo 4. A modelagem da RNA proposta é apresentada, assim como as etapas de desenvolvimento do sistema. Este é testado em diversas condições, e nesse mesmo capítulo os resultados gerados são discutidos.

Finalmente, no Capítulo 5, apresentam-se as conclusões. Sugerem-se melhorias e possíveis trabalhos futuros.

CAPÍTULO 2 - FUNDAMENTOS TEÓRICOS

2.1 SISTEMAS DE DETECÇÃO DE VEÍCULOS

De acordo com o órgão americano de administração de rodovias federais (*Federal Highway Administration*) existem diversas tecnologias de sensores utilizadas para detecção de veículos (FHWA, 1997). Entre as tecnologias mais importantes pode-se citar: os detectores por laço indutivo, infravermelho, cabos piezelétricos, ultra-som, radar, microondas, pneumáticos, laser e vídeo. No Brasil, os equipamentos “fixos” de fiscalização de tráfego – aqueles em instalação permanente na via – utilizam normalmente os sensores piezelétricos e/ou os laços indutivos. Sensores piezelétricos para tráfego, embora sejam confiáveis na detecção especialmente dos eixos dos veículos, têm custo elevado, sendo mais utilizados para aplicações de peso em movimento em postos de fiscalização. Eles são normalmente combinados com laços indutivos, pois somente detectam o veículo quando a sua roda está sobre o sensor. Neste caso, o laço indutivo é instalado como um grande laço preenchendo a região entre os dois sensores piezelétricos e se encarrega de detectar a “presença” do veículo, enquanto cabe aos sensores piezelétricos a contagem de eixos, a determinação da velocidade (SROKA, 2004) e eventualmente o peso em movimento.

A seguir, serão apresentadas as vantagens e desvantagens dos sensores mais utilizados no Brasil.

2.1.1 LAÇOS INDUTIVOS

O sistema de detecção de veículos mais comum no Brasil é o que utiliza laço indutivo (também conhecido como DLI – Detector por laço indutivo), que capta mudanças na indutância de uma bobina instalada no revestimento asfáltico quando um veículo (metálico) passa por sobre ela. Esta bobina é mais conhecida como laço indutivo e é feita com fio de cobre isolado de 1,5 a 2,5 mm de diâmetro que geralmente é disposto de forma retangular fazendo duas ou mais voltas de acordo com a Figura 2.1. A instalação do laço indutivo é feita realizando-se cortes rasos no pavimento onde ele é colocado e em seguida coloca-se um material selante, como asfalto ou cimento, para cobrir os fios. O laço indutivo é conectado a uma placa eletrônica com um circuito oscilador. Esta placa também possui um microcontrolador que monitora a frequência do conjunto formado pelo circuito oscilador e o

laço indutivo e é denominada placa detectora ou placa metrológica. A popularidade deste sistema se deve ao baixo custo em relação a outras tecnologias utilizadas e à sua robustez por utilizar fios enterrados, o que protege contra degradação do material devido a ações do clima, como sol e chuva. Em alguns casos são usados em configuração simples (um único laço) para medição de tráfego e operação de trânsito de forma inteligente. Outras vezes pode ser instalado em dois ou três laços por faixa para realizar o cálculo de velocidade.




Figura 2.1 - Esquema de montagem do sistema detector por laço indutivo (DLI).

Os detectores convencionais por laço indutivo, na sua grande maioria, fornecem apenas saídas digitais indicando a “presença” ou “ausência” de veículo de acordo com a Figura 2.2. O avanço tecnológico ocorrido desde a introdução dos primeiros laços indutivos em 1960 possibilitou mais recentemente que se pudesse adquirir a forma de onda relacionada com a variação da indutância ao longo do tempo, ou seja, a “assinatura” ou “perfil magnético”, do veículo. Isto motivou diversos estudos em busca da extração de informações adicionais dos laços indutivos (PFANNERSTILL, 1989, SUN, RITCHIE, 1999, GAJDA *et al.*, 2001, ABDULHAI, TABIB, SAYED, 2003, MAGALHÃES, 2008.). Sinais gerados por diferentes classes de veículos sobre o laço diferem em forma, amplitude, parâmetros estatísticos, duração, espectro de frequência, etc. Na Figura 2.3 apresenta-se um gráfico com curvas geradas por diferentes tipos de veículos. Pode-se observar que cada tipo de veículo gera uma curva distinta.




Figura 2.2 - Detecção de presença de veículo com laços indutivos (adaptado de CALIXTO, 2006).




Figura 2.3 - Gráficos de perfil magnético para diferentes tipos de veículos.

Pode-se utilizar um único sensor indutivo ou em pares. Os sensores utilizados em pares, também conhecidos como *speed traps*, instalados de acordo com a Figura 2.4, permitem o cálculo da velocidade dos veículos com boa precisão. Equipamentos de monitoramento de velocidade, como as lombadas eletrônicas, usam esta técnica. A velocidade do veículo é calculada a partir da obtenção do tempo decorrido entre os acionamentos do primeiro e do segundo sensor. Como a distância d , na Figura 2.4, entre os dois sensores é fixa e conhecida, a velocidade pode ser obtida através da equação básica da cinemática (2.1).

$$V = \frac{d}{t} \quad (2.1)$$

Sendo:

V = velocidade medida [m/s];

d = distância entre os laços [m];

t = tempo decorrido entre os acionamentos do primeiro e segundo laço [s];




Figura 2.4 - Sistema com dois laços indutivos por faixa.

Outra informação obtida com duplos sensores é o comprimento magnético do veículo. O comprimento é dito magnético, pois com sensores indutivos é possível contabilizar apenas o comprimento das partes magnéticas do veículo, ou seja, das partes metálicas. Extensões de carrocerias de madeira após o término do chassi, por exemplo, não são detectadas. Com o conhecimento da velocidade e do tempo que o sensor permaneceu acionado, calcula-se o comprimento magnético do veículo utilizando a mesma equação do cálculo da velocidade (2.1). O comprimento obtido deve ser subtraído da dimensão do laço na direção longitudinal da pista, pois durante o tempo de acionamento do sensor o veículo percorre uma distância equivalente à soma do seu comprimento e da dimensão do laço na direção longitudinal da pista (ANDREOTTI, 2001). Assim, o comprimento do veículo é dado pela fórmula:

$$X = (V * T_{13}) - h \quad (2.2)$$

Sendo:

X: Comprimento do veículo, [m];

V: Velocidade, [m/s];

$T_{13} = T_3 - T_1$: Tempo de ativação do sensor 1, [s];

h: Comprimento do laço indutivo no sentido do fluxo, [m];

Algumas técnicas de cálculo de velocidade utilizam o tempo entre os desacionamentos, de acordo com a Figura 2.5, para melhorar a confiabilidade da medição. Desta maneira, são realizadas duas medições: uma utilizando o tempo entre os acionamentos e outra utilizando o tempo entre os desacionamentos (NISHIMOTO, 2006; SIMONI, 2008). Outros equipamentos utilizam três laços indutivos para minimizar os erros, realizando três

medições. O esquema desta configuração é apresentado na Figura 2.6. A velocidade é calculada entre o primeiro e o segundo sensor, entre o primeiro e o terceiro e entre o segundo e o terceiro. Caso a diferença entre as três velocidades calculadas seja superior a um limiar pré-determinado, a medição é descartada.




Figura 2.5 - Esquema com dois laços indutivos destacando o tempo de desacionamento.




Figura 2.6 - Esquema com 3 sensores indutivos.

Os sistemas de apenas um sensor são utilizados em semáforos acionados sob demanda, controle de abertura de cancelas em estacionamentos, para realizar a contagem do fluxo, determinar a taxa de ocupação e a velocidade média na via. A velocidade média pode ser estimada com apenas um laço caso se saiba o comprimento médio dos veículos que trafegam por um determinado local de acordo com a Equação 2.3 (NISHIMOTO, 2006; SIMONI, 2008).

$$V_m = \frac{l}{t_{off} - t_{on}} \quad (2.3)$$

Sendo:

l : comprimento efetivo [m];

t_{on} : instante de tempo em que o laço é ativado [s];

t_{off} : instante de tempo em que o laço é desativado [s];

O comprimento efetivo l corresponde à soma do comprimento do veículo, com o comprimento do laço indutivo. O comprimento do laço indutivo é definido como a medida da borda lateral do laço, medido na direção de fluxo da via, como mostra a Figura 2.7 (NISHIMOTO, 2006).




Figura 2.7 - Parâmetros de comprimento e largura do laço indutivo (NISHIMOTO, 2006).

Como o comprimento real dos veículos que passam pelo sensor é desconhecido, um valor médio de l é utilizado para realizar o cálculo. Contudo, a utilização desse valor médio pode resultar em velocidades imprecisas uma vez que o comprimento varia de veículo para veículo (NISHIMOTO, 2006).

A utilização de laços indutivos apresenta os seguintes problemas (NISHIMOTO, 2006):

- Erros de detecção causados por veículos que trafegam na faixa adjacente (*splash over*). Geralmente estes erros ocorrem quando veículos de grande porte, como na Figura 2.8, passam pela faixa lateral à faixa monitorada causando erros de medição;
- Indução causada pelo campo magnético de um laço indutivo próximo (*crosstalk*);
- Baixa sensibilidade para detecção de motocicletas.



Figura 2.8 - Situação em que ocorre *splash over*.

2.1.2 SENSORES PIEZELÉTRICOS

A piezeletricidade é uma propriedade de alguns materiais que geram energia elétrica quando sujeitos a pressão (efeito piezelétrico direto), e que produzem trabalho mecânico quando excitados eletricamente (efeito piezo-elétrico inverso) (SIMONI, 2008). Entre os principais materiais utilizados para fabricação de sensores piezelétricos estão os de cerâmicas de titanato zirconato de chumbo (PZT) e titanato de chumbo modificado com cálcio; os polímeros ferroelétricos (fluoreto de polivinilideno – PVDF), e os compósitos de polímero/cerâmica (PTCa) (MARAT-MENDES, 2000; SIMONI, 2008). A Figura 2.9 apresenta o exemplo de um sensor piezelétrico fabricado com cerâmica de titanato zirconato de chumbo (PZT).

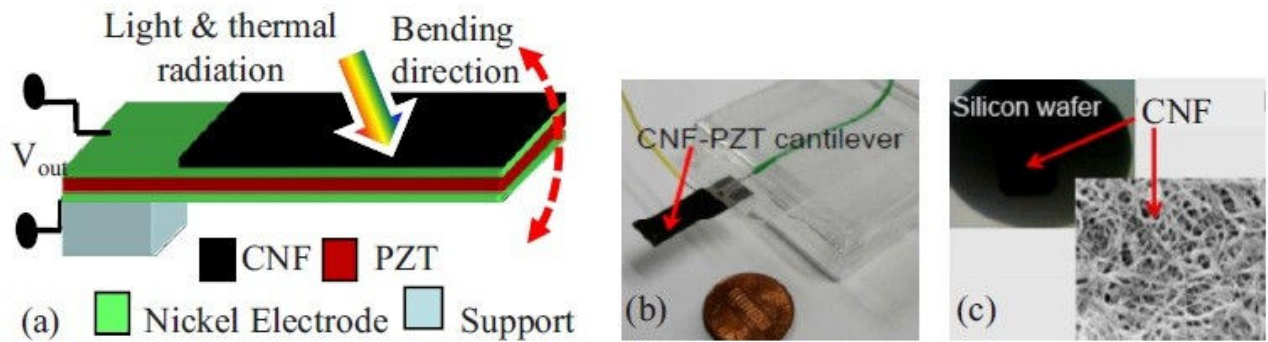


Figura 2.9 - Esquema de um sensor piezolétrico com PZT

Sensores piezolétricos são usados para classificar veículos por número de eixos e espaçamento e para medir o peso e a velocidade do veículo (quando múltiplos sensores são utilizados). Eles são frequentemente usados como parte de sistemas de pesagem em movimento (*weigh-in-motion* – WIM).

Um sensor tubo piezolétrico é construído com um metal, que compõe a estrutura central do sensor, o qual é circundado por material piezolétrico e uma camada mais externa de metal, de acordo com a Figura 2.10. Durante o processo de fabricação, o sensor é sujeito a um campo elétrico radial intenso, campo elétrico esse que tem por finalidade polarizar o material piezolétrico. O campo elétrico é aplicado antes da jaqueta de metal mais externo ser colocada, e esse campo transforma o polímero amorfo numa forma semicristalina, enquanto retêm muitas das propriedades flexíveis do polímero original. Outro tipo de sensor piezolétrico usa um pó a base de mineral como um material piezolétrico que forma o dielétrico entre o fio de cobre no centro do cabo coaxial e o tubo de cobre sólido que serve como condutor mais externo. Durante a fabricação, a temperatura do cabo é aumentada para 400 °C e uma tensão é aplicada entre o condutor mais interno e o externo para polarizar o pó, orientando as cargas elétricas das moléculas do pó. A tensão é mantida uma vez que o cabo é esfriado, estabilizando o campo polarizado (DNIT e NEP-UFSC, 2007).

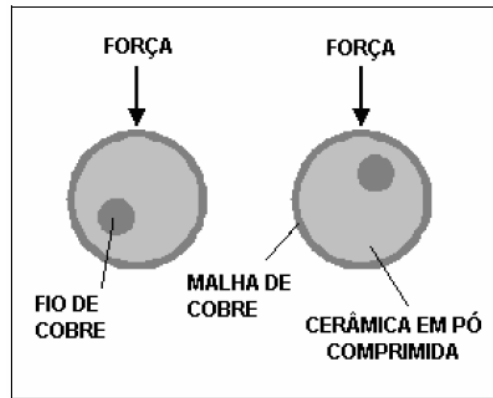


Figura 2.10 - Seção transversal do cabo piezoeletrico (SIMONI, 2008).

O cabo pode ser fornecido com epóxi dentro de um canal de alumínio para garantir que seja adequadamente instalado, como pode ser observado na Figura 2.11.

Este tipo de sensor piezoeletrico é recomendado para WIM, classificação de veículo por número de eixo e espaçamento, medida da carga total do veículo (Figura 2.12), medida da velocidade e aplicações de contagem. Borracha de espuma é colocada ao longo das laterais do sensor durante a instalação quando este tipo de cabo piezo é usado em sistemas WIM. Esta técnica transforma as componentes não verticais em parcelas verticais de esforço, aumentando então a medida de esforço total na vertical e reduzindo consideravelmente a influência do esforço lateral que prejudica o desempenho do sensor para a finalidade WIM (DNIT e NEP-UFSC, 2007).




Figura 2.11 - Sensor piezoeletrico coaxial.



Figura 2.12 - Sistema de pesagem com sensores piezelétricos.

Além do modelo cilíndrico mostrado na Figura 2.10, tem-se o modelo retangular que é apresentado na Figura 2.13. Para instalá-lo na via é utilizado um suporte de acordo com o apresentado na Figura 2.14.




Figura 2.13 - Sensor piezelétrico tipo retangular.




Figura 2.14 - Sensor piezelétrico retangular instalado.

Os sensores piezelétricos são capazes de coletar informações derivadas do pneu passando por sobre o sensor ao produzir um sinal analógico que é proporcional à pressão (esforço) exercida no sensor. Esta propriedade dos sensores piezelétricos permite que eles diferenciem eixos individuais com extrema precisão. Além disso, em termos de custo do sensor instalado, eles são somente mais caros do que o laço indutivo, porém disponibilizam mais informação, possuem capacidade de determinar a classificação do veículo baseado no peso e espaçamento do eixo, e capacidade para determinar e monitorar os pesos dos veículos para sistemas WIM.

Um problema prático comum a estes sensores é a dificuldade de se instalar um cabo longo e rígido no mesmo nível da superfície da pista. O pavimento normalmente possui ondulações, e um trecho do cabo pode estar nivelado com a pista enquanto outro trecho está abaixo da superfície, causando diferenças de sensibilidade. Ondas de choque horizontais, inerentes a todas as estradas, também causam acionamentos indevidos. Um veículo pesado trafegando em uma faixa adjacente onde há um sensor instalado pode causar uma tensão elétrica no cabo maior que a causada por um veículo de passeio (OPITZ e CALL, 1996; SIMONI, 2008).

2.2. CLASSIFICAÇÃO VEICULAR

A classificação veicular vem sendo estudada desde a década de 70. Podem-se citar alguns trabalhos recentes envolvendo exclusivamente sinais provenientes de laços indutivos: GAJDA *et al.*, 2001; OH, RITCHIE e STEPHEN, 2003; SROKA, 2004 e CALIXTO, 2006. Existem diversas formas de classificações de veículos relatadas na literatura e adotadas pelos diferentes órgãos de transporte, que variam dependendo do país ou região e da aplicação. Por exemplo, o órgão de transportes norte americano, a FHWA – *Federal Highway Administration* utiliza a classificação em 13 categorias mostrada na Tabela 2.1 (FHWA, 1997, ou RITCHIE *et al.*, 2005, tradução para o português em CALIXTO, 2006).

Tabela 2.1 - Classificação veicular segundo FHWA.

1	Motocicleta
2	Carro de Passeio
3	Outros Veículos de 2 eixos e 4 pneus
4	Ônibus
5	Caminhões de dois eixos e 6 pneus
6	Caminhões de três eixos
7	Caminhões de quatro ou mais eixos
8	Carretas de até quatro eixos

9	Carretas de cinco eixos
10	Carretas de seis ou mais eixos
11	Carretas de mais de um reboque com até cinco eixos
12	Carretas de mais de um reboque com seis eixos
13	Carretas de mais de um reboque com sete eixos ou mais

2.2.1 CLASSIFICADORES VEICULARES BASEADOS EM LAÇOS INDUTIVOS

Os sistemas de sensores indutivos são bastante utilizados e difundidos por apresentarem longa vida útil, robustez e baixo custo se comparados aos sistemas que utilizam sensores infravermelhos, piezelétricos, ultra-som, radar, microondas, pneumáticos, laser ou vídeo. POTTER (2011) relata a evolução e disseminação desse sistema ao longo das décadas. Nessa evolução, eles passaram de simples detectores de presença (Figura 2.2) para importante ferramenta dos sistemas inteligentes de tráfego. A aplicação de detecção digital, ou seja, se existe ou não veículo sobre o sensor, foi substituído pela detecção analógica de uma forma de onda completa (Figura 2.15). Desta forma é possível extrair outras informações, que implicam nas mais variadas aplicações.

O Detector por Laço Indutivo (DLI) é a forma mais comum de detecção utilizada para classificação dos veículos no Brasil por apresentarem as características descritas acima. Quando um veículo passa por um sistema de fiscalização de trânsito baseado em um DLI, a contagem é feita, e a velocidade do veículo é calculada (2.1). Sabendo a velocidade, o controlador calcula o comprimento do veículo (2.2) e determina a sua classe (SUN, RITCHIE e TSAI, 1995). Este método é usado atualmente por muitas empresas nas rodovias brasileiras.




Figura 2.15 - Sistema analógico de detecção por laço indutivo (adaptado de CALIXTO, 2006).

A eficiência de um sistema de classificação veicular é definida como sendo a razão entre o número de veículos classificados corretamente sobre o número de veículos totais para cada classe.

Em 2000, GAJDA e colegas propuseram um modelo que usa os padrões representando a forma de sinais de medição no domínio do tempo com um DLI simples em vez do sistema tradicional. Eles conduziram experimentos em quatro classes de veículos: carros de passeio, camionetes de entrega, caminhões e ônibus. Suas eficiências foram: 94% para automóveis de passeio, 66% para camionetes de entrega, 80% para caminhões, 94% para ônibus, e, finalmente, 83% para todos os veículos (GAJDA *et al.*, 2000).

Também em 2000, SUN e colegas usaram mapas auto-organizáveis (SOFMs - *Self-Organizing Feature Map*) para classificação de veículos. Um SOFM é uma rede neural artificial que forma grupos de neurônios que refletem similaridades no vetor de entrada. As entradas do SOFM são as assinaturas indutivas processadas. O SOFM produz resultados em torno de 80% nas taxas de classificação geral para quatro classes de veículos (SUN, RITCHIE e OH, 2000).

Em 2006, YONG-KUL KI e DOO-KWON BAIK propuseram um sistema de classificação veicular por perfil magnético, com um único sensor magnético, usando redes neurais com o algoritmo de *back-propagation* e obteve uma eficiência geral de 91,5% com acerto de 92% para carros de passeio, 79,4% para vans, 100% para caminhões, 91,6% para ônibus e 100% para motocicletas.

Também em 2006, CALIXTO apresentou um sistema de classificação veicular baseado em sistemas *Fuzzy* classificando os veículos em seis categorias: moto, carro, utilitário, ônibus, caminhão e carreta (Tabela 2.2). Ele utilizou dois sensores indutivos e obteve uma taxa geral de acerto mínimo de 95%.

Tabela 2.2 - Classificação veicular segundo CALIXTO(2006)

1	Carro
2	Moto
3	Ônibus
4	Caminhões
5	Utilitários
6	Carretas
7	Outros veículos

Em 2010, SONER META e MUHAMMED G. CINSDIKICI obtiveram 94,21% de acerto com classificador veicular baseado em um único sensor magnético utilizando a teoria de Análise dos Componentes Principais (PCA - *Principal Component Analysis*) e uma rede neural artificial com algoritmo *Back Propagation*. Neste trabalho, os veículos foram classificados em cinco categorias de acordo com a Tabela 2.3.

Tabela 2.3 - Classes de veículos segundo META e CINSDIKICI.

1	Carros e Jeeps
2	Micro-ônibus e Vans
3	Pickups e Caminhões
4	Ônibus e Ônibus articulados
5	Motocicletas

2.2.2 CLASSIFICAÇÃO VEICULAR COM PROCESSAMENTO DE IMAGEM

Os sistemas de processamento de imagem vêm se difundindo no meio científico e tecnológico como uma importante ferramenta para automatização de processos (MACCARLEY, 1999; GUPTE, PAPANIKOLOPOULOS, 2000; MOHOTTALA, KAGESAWA, IKEUCHI, 2003). Esta tecnologia viabiliza sistemas de reconhecimento de padrões faciais, padrões de assinaturas e outras aplicações (CALIXTO, 2006). No próprio controle de tráfego, são aplicados os sistemas de reconhecimento de caracteres de placas de veículos.

Alguns sistemas para classificação de veículos propõem-se a distinguir categorias pelos padrões coletados por câmeras de vídeo. São efetuadas análises das características das imagens coletadas. MOHOTTALA, KAGESAWA e IKEUCHI (2003) propõem a classificação de categorias de veículos através da análise de imagens geradas por um sistema tridimensional. O sistema faz distinção de quatro classes de veículos: Sedan, Wagon, mini-van e Hatchback. A câmera é fixada de maneira a registrar a imagem superior dos veículos, conforme Figura 2.16 (CALIXTO, 2006). A eficiência obtida com este sistema foi de 83%.

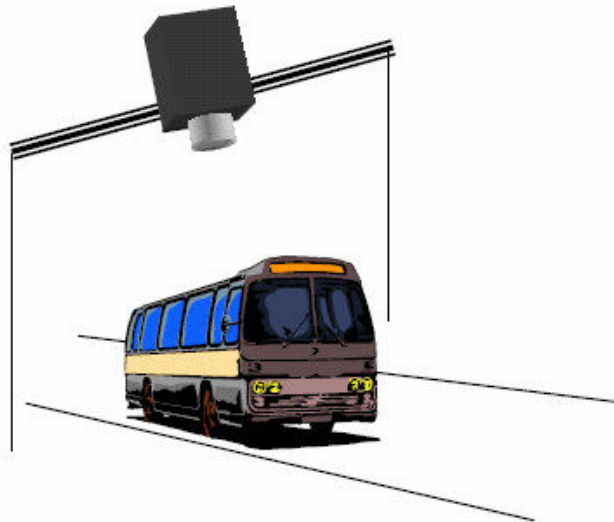


Figura 2.16 - Fixação da câmera para coleta da perspectiva superior do veículo (CALIXTO, 2006).

ZHANG e SIYAL (2000) utilizam a técnica da análise do contorno dos veículos para classificação em quatro categorias por eles definidas: jeep, carro de passeio, caminhões e mini-vans. No experimento obteve-se um índice de acerto de 85% com 17 dos 20 veículos classificados corretamente.

GUPTE e PAPANIKOLOPOULUS (2000) desenvolveram um algoritmo para detecção e classificação de veículos através de sequências de imagens de tráfego gravadas por uma câmera estacionária. O sistema proposto classifica veículos em duas categorias, caminhões e não caminhões. O sistema é composto de seis estágios: segmentação de movimento (para identificação de algumas regiões de movimento), agrupamento das regiões, identificação de parâmetros (para coleta de características como altura e comprimento das regiões), identificação do veículo em uma das regiões de movimentação, julgamento da região (para verificação se é um veículo ou um simples ruído utilizando filtro de Kalman) e classificação dos veículos identificados nas categorias. Os resultados relatados foram de 90% na identificação da presença dos veículos na imagem e 70% de classificação correta para as duas categorias (CALIXTO, 2006).

2.2.3 CLASSIFICADORES VEICULARES BASEADOS EM LASER

Em 2001, HARLOW e PENG apresentaram um sistema de classificação veicular alternativo aos sistemas baseados em processamento de imagem convencional (captura de intensidade luminosa e cor). Um sistema não invasivo de imagem baseado na medida de distância e refletância dos objetos por feixes de LASER, de forma a ficar mais imune às condições ambientais e de iluminação (Figura 2.17). São dois feixes posicionados diretamente

sobre a via de tráfego. A taxa de classificação de veículos alcançada para 14 categorias em 2001 foi acima de 92%. Atualmente, para este sistema, o fabricante relata uma taxa de acerto na detecção de veículos em 99,98% e taxa de acerto na classificação em 95%. O problema deste sistema, assim como o de todos os sistemas que atualmente usam LASER, é seu alto custo. Portanto a pesquisa continua em torno da melhoria de técnicas que visam extrair informações de imagens convencionais, mas que levem a soluções mais baratas (MAGALHÃES, 2008).




Figura 2.17- Classificador veicular baseado em laser (adaptado de HARLOW e PENG, 2001 e MAGALHÃES, 2008).

2.3 SISTEMA CLASSIFICADOR UTILIZADO PELA FOTOSENSORES®

O equipamento de fiscalização de tráfego fabricado pela empresa Fotosensores® possui um sistema de classificação veicular que faz a categorização de acordo com o tamanho do veículo e utiliza dois sensores indutivos por faixa da via. O método utilizado separa veículos em uma das quatro categorias: veículo pequeno, veículo médio, veículos grandes e motocicletas (OLIVEIRA, *et al*, 2010). As regras para classificação funcionam da seguinte forma: Primeiramente o sistema calcula o comprimento de veículo de acordo com a Equação (2.2) que utiliza o tempo de ocupação ou tempo de ativação do primeiro sensor ($T1-T3$), o comprimento do laço indutivo no sentido do fluxo e a velocidade do veículo. A velocidade do veículo é calculada de acordo com a equação (2.1) utilizando a distância padrão entre os dois

sensores (Figura 2.4) e o tempo de deslocamento do veículo entre o primeiro e o segundo sensor (T2-T1) (Figura 2.2). Então, o modelo classifica os veículos em quatro categorias de acordo com o comprimento de veículo (Tabela 2.4).

Tabela 2.4 - Categorias de veículos adotadas atualmente pela Fotosensores®

Categoria	Tamanho
Motocicleta	Menor que 3m
Veículo Pequeno	Entre 3m e 4m
Veículo Médio	Entre 4m e 7m
Veículo Grande	Maior que 7m

A precisão deste método depende da exatidão das variáveis independentes na equação para o comprimento do veículo. As variáveis independentes (velocidade e tempo de ocupação) podem incluir os seguintes erros (KI, BAIK, 2006; OLIVEIRA *et al.*, 2010):

- 1) Erros na Velocidade: O DLI mede a velocidade que será utilizada na classificação dos veículos, mas esta informação pode conter alguns erros devido à velocidade de varredura da unidade de controle, a diferentes sensibilidades para os dois canais, à variação da velocidade dos veículos que passam no local de medição acelerando ou desacelerando, e assim por diante (GAJDA *et al.*, 1997).
- 2) Os erros no tempo de ocupação: Quando uma massa metálica passa através do campo magnético gerado pelo DLI, o distúrbio produz uma redução na indutância do laço, e as propriedades de ressonância do circuito são alteradas. Uma motocicleta, por exemplo, poderia produzir uma mudança de frequência de até 0,08%, enquanto que um automóvel poderia causar uma mudança de até 3% (SUN, RITCHIE e TSAI, 1995). Esta variação é afetada pela distância entre o sensor indutivo e o chassi do veículo (GAJDA *et al.*, 1997). Se a distância é grande, tem um pequeno impacto no campo magnético e induz a um erro na medição do tempo de ocupação. Por exemplo, o tempo de ocupação de um caminhão medido tende a ser inferior ao valor real porque a distância é maior do que os outros veículos. Neste caso pode ocorrer de o sistema classificar um veículo grande como um veículo médio.

2.4 REDES NEURAIIS ARTIFICIAIS

Uma Rede Neural Artificial (RNA) é um modelo computacional que compartilha algumas das propriedades do cérebro: consiste de muitas unidades simples trabalhando em paralelo sem um controle central. As conexões entre unidades possuem pesos numéricos que

podem ser modificados pelo elemento de aprendizado (RUSSELL e NORVIG, 2010). A essas unidades damos o nome de neurônio e suas conexões sinapses.

As RNAs são semelhantes ao cérebro humano em dois aspectos basicamente (HAYKIN, 1999):

- A experiência é a fonte do conhecimento adquirido, e
- O conhecimento adquirido é armazenado nas sinapses.

O neurônio, célula constituinte do cérebro, ilustrado pela Figura 2.18, é composto por um corpo celular chamado Soma onde se encontra seu núcleo e por axônios e dendritos. O axônio, uma fibra nervosa de superfície lisa com poucas ramificações e maior comprimento, é responsável pela transmissão na comunicação com outros neurônios. Os dendritos, que tem aparência de árvores, possuem superfície irregular e muitas ramificações, atuam como receptores nesta comunicação.




Figura 2.18 - Neurônio biológico: os constituintes da célula.

A ligação entre os neurônios é chamada sinapse e é caracterizada por um processo químico no qual são liberadas substâncias transmissoras que se difundem pela junção sináptica entre neurônios, o que causa aumento ou queda no potencial elétrico do neurônio receptor. Resumindo, uma sinapse é a conexão entre neurônios o que implica em excitação ou inibição do neurônio receptor (HAYKIN, 1999).

De forma análoga, um neurônio artificial apresenta as mesmas características. A Figura 2.19 mostra um modelo onde podem ser vistos: sinapses representadas pelas entradas e pesos sinápticos, somatório e função de ativação. Cada sinapse é caracterizada por um estímulo de entrada multiplicado pelo seu peso sináptico correspondente. Depois desta multiplicação, cada sinal de entrada é somado e o resultado é então, aplicado a uma função de ativação que restringe a saída do neurônio a um intervalo de 0 a 1 ou de -1 a $+1$.

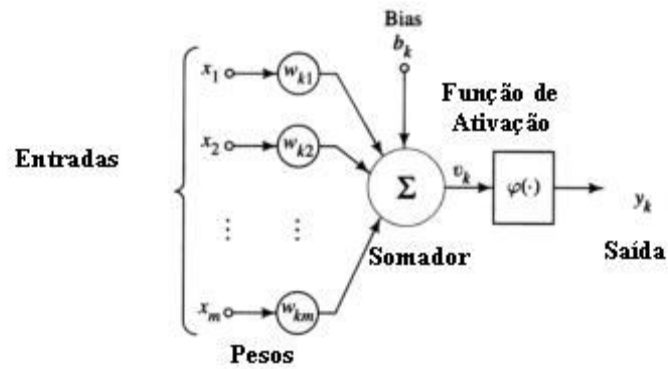


Figura 2.19 - Neurônio artificial (HAYKIN, 1999).

O neurônio artificial pode ser descrito pela equação (HAYKIN, 1999):

$$y_k = \varphi \left(\sum_{i=1}^n x_i W_{ki} \right) \quad (2.1)$$

Onde, y_k é a saída do neurônio; φ é a função de ativação; x_1, x_2, \dots, x_n são os sinais de entrada do neurônio; e $W_{k1}, W_{k2}, \dots, W_{kn}$ são os pesos sinápticos do neurônio em questão (neurônio k).

Portanto, o neurônio artificial imita o funcionamento do neurônio biológico por meio das entradas, representando as sinapses e pela função de ativação que simula o processo químico que libera substâncias químicas que excitarão ou inibirão os próximos neurônios.

2.4.1 REDE PERCEPTRON DE MÚTIPLAS CAMADAS (*MULTILAYER PERCEPTRON – MLP*)

As redes MLP são os modelos de RNA mais utilizados (HAYKIN, 1999). Este tipo de RNA é formado por várias camadas de neurônios, cada uma com função específica. Os neurônios de uma determinada camada se conectam aos neurônios da camada seguinte. Uma rede de três camadas é apresentada na Figura 2.20.




Figura 2.20 - Topologia Típica de uma Rede MLP de três camadas.

Cada neurônio da rede calcula sua função de ativação (Equação 2.1) que é tipicamente a tangente hiperbólica ou a função sigmóide.

Geralmente, a rede MLP é treinada com o algoritmo *back-propagation* (HAYKIN, 1999) tendo como objetivo minimizar o erro médio quadrático da saída da rede, ajustando os pesos e bias. O procedimento de treinamento supervisionado aplicado à rede pode ser considerado como um problema de otimização não-linear, no qual os pesos são atualizados iterativamente para que a função-objetivo definida seja minimizada.

2.4.2 O ALGORÍTMO DE LEVENBERG-MARQUARDT

Enquanto o *back-propagation* padrão utiliza a descida de gradiente como método de aproximação do mínimo da função erro, o algoritmo de Levenberg-Marquardt (LM) utiliza uma aproximação pelo método de Newton (HAYKIN, 1999). Esta aproximação é obtida a partir da modificação do método de Gauss-Newton introduzindo-se o parâmetro μ , conforme a equação:

$$\Delta x = [J^T(x)J(x) + \mu I]^{-1} J^T(x)e(x) \quad (2.2)$$

Sendo que I é a matriz identidade, $e(x)$ é o erro e J é a matriz Jacobiana. A Matriz Jacobiana (denominada em homenagem ao matemático alemão Carl Gustav Jakob Jacobi) é formada pelas derivadas parciais de primeira ordem de uma função vetorial. Se uma função é diferenciável num ponto, a sua derivada é dada em coordenadas pela Jacobiana, mas uma função não precisa ser diferenciável para a existência da Jacobiana; basta que as derivadas parciais existam. O parâmetro μ (Equação 2.2) é multiplicado por um fator (β) toda vez que um passo resultar num aumento na função erro, que se deseja minimizar. Quando um passo

resultar na diminuição da função genérica $V(x)$, μ é dividido pelo fator β . Isto significa dizer que, se houver uma convergência para o mínimo da função, μ é pequeno e o algoritmo se aproxima do método de Newton (passo $1/\mu$); no caso de não haver convergência, o método se aproxima da descida de gradiente. O parâmetro μ funciona como um fator de estabilização do treinamento, ajustando a aproximação de forma a utilizar a rápida convergência do método de Newton e evitando passos muito grandes que possam levar a um erro de convergência (HAYKIN, 1999).

No algoritmo de LM, quando a função de desempenho apresenta a forma de uma soma de quadrados, como no caso do treinamento das redes *feed-forward*, então a matriz Hessiana pode ser aproximada conforme a equação a seguir:

$$H(x) = J^T(\bar{w})J(\bar{w}) \quad (2.3)$$

Onde \bar{w} é a representação dos pesos e bias e J é a matriz Jacobiana que contém as primeiras derivadas dos erros da rede com respeito aos pesos e polarização.

O gradiente pode ser obtido mediante a equação:

$$\delta = J^T(\bar{w})\epsilon(\bar{w}) \quad (2.4)$$

Sendo que δ é o gradiente e ϵ é o vetor de erros da rede.

O problema é que a matriz Hessiana, conforme definida na equação (2.3), pode não ter inversa. A modificação de Levenberg-Marquardt propõe uma solução adicionando à matriz Hessiana a parcela μI , onde μ é um escalar, conhecido como tamanho de passo adaptativo e I é a matriz identidade resultando na equação (2.5) para atualização dos pesos e polarização (HAGAN, MENHAJ, 1994; JAZAYERI, ROSEHART e WESTWICK, 2007).

$$\bar{w}_{k+1} = \bar{w}_k - [J^T(\bar{w})J(\bar{w}) + \mu I]^{-1} J^T(\bar{w})\epsilon(\bar{w}) \quad (2.5)$$

Onde k é a época atual de treinamento.

Seguem os passos para o algoritmo de treinamento Levenberg-Marquardt (Haykin, 1999):

Passo 1: São ajustados os parâmetros iniciais do algoritmo de treinamento, como o valor inicial do escalar μ , e suas taxas de decréscimo e acréscimo.

Passo 2: Estabelece-se um critério de parada para o treinamento, podendo ser um valor satisfatório da função de desempenho ou número de épocas de treinamento, ou ainda um valor de gradiente pré-determinado.

Passo 3: É apresentado um par entrada-saída e calcula-se a saída das camadas da rede utilizando a equação 2.1. Calcula-se o erro na última camada e atualiza-se o índice de desempenho (Erro Quadrático Médio - EQM), conforme as equações 2.6 e 2.7:

$$e_j(t) = d_j(t) - y_j(t) \quad (2.6)$$

$$EQM = \frac{1}{2N} \left[\sum_{j=1}^m e_j^2(t) \right] \quad (2.7)$$

Sendo e_j o sinal de erro do neurônio j na camada de saída, ou seja, diferença entre a saída desejada d_j e a saída atual y_j , m é o número de neurônios da camada de saída e t é o número da iteração de treinamento atual.

Passo 4: Cálculo da Matriz Hessiana, gradiente e atualização dos pesos, conforme as equações (2.3) e (2.5).

Passo 5: Recalcula-se a função de desempenho. Se este valor é menor que o obtido no passo 1, então μ é reduzido através da taxa de redução pré-definida e retorna ao passo 3. Caso contrário, μ é incrementado e retorna ao passo 4.

Passo 6: Verifica-se o critério de parada definido no passo 2 e determina-se o encerramento ou não do treinamento.

Devido a essa característica de acelerar a convergência, minimizando rapidamente a função de desempenho, o algoritmo LM é apontado como um dos algoritmos de treinamento mais rápidos (RAO e TRIPATHY, 1980; JAZAYERI, ROSEHART e WESTWICK, 2007).

2.5 CONSIDERAÇÕES FINAIS

Dentre os sistemas de detecção de veículos existentes no mercado, os mais utilizados são os que utilizam laços indutivos e os que utilizam sensores piezelétricos. Os laços indutivos são utilizados devido ao baixo custo em comparação com os outros sensores. Os sensores piezelétricos são indicados na medição de peso em movimento, contagem de eixos de veículos, espaçamento entre eixos e medição de velocidade. Geralmente os sensores piezelétricos são utilizados juntamente com os laços indutivos.

Neste Capítulo foram apresentadas algumas técnicas utilizadas para a classificação de veículos. Dentre estas técnicas, a que utiliza detecção por laços indutivos foi escolhida para o desenvolvimento do sistema proposto neste trabalho por ser utilizado por muitas empresas no Brasil. Foram apresentados alguns trabalhos relacionados à classificação veicular utilizando detectores de laço indutivo desenvolvidos nos últimos anos. Dentre estes se destaca o trabalho desenvolvido por CALIXTO em 2006 que integrou um classificador veicular baseado em lógica Fuzzy a equipamentos de fiscalização de tráfego da empresa Perkons e obteve índice de acerto mínimo de 95%. Ainda neste capítulo também foram apresentados conceitos sobre RNA.

O sistema proposto, que é apresentado no próximo capítulo, também será integrado a um equipamento de fiscalização de tráfego e o classificador foi desenvolvido utilizando RNA.

CAPÍTULO 3 - SISTEMA PROPOSTO

3.1 INTRODUÇÃO

Para o sistema proposto foi utilizado um classificador baseado em RNA para identificar o tipo de veículo de acordo com o padrão do perfil magnético coletado.

No sistema proposto, os veículos são classificados nas seguintes categorias: motocicletas, veículos pequenos, veículos médios, ônibus e caminhões. A categoria de motocicletas é composta por motocicletas e motonetas. Os veículos pequenos são os carros de passeio e as pequenas camionetas. Na categoria de veículos médios temos as camionetes grandes e as vans. Os caminhões de todo o tipo ficam na categoria caminhão. E por fim a categoria de ônibus é composta de micro-ônibus, ônibus e ônibus articulado.






1	Motocicleta	
2	Veículo Pequeno	
3	Veículo Médio	
4	Caminhão	
5	Ônibus	

Figura 3.1 - Categorias ou classes de veículos adotadas (adaptado de META e CINSDIKICI, 2010).

A escolha das categorias apresentadas na Figura 3.1 foi feita de acordo com a análise das características do perfil magnético gerado por cada tipo de veículo de acordo com as semelhanças, levando-se em consideração os trabalhos realizados anteriormente, a

classificação definida pelo Código de Trânsito Brasileiro (Tabela 3.1) e a distribuição estatística de tipos de veículos na cidade de Fortaleza e no Brasil (Tabela 3.2). Também foi levada em consideração na escolha das classes a necessidade de distinguir ônibus de caminhões para aplicações de detecção de veículos trafegando em faixa exclusiva para ônibus.

O Código de Trânsito Brasileiro define em seu artigo 96 uma classificação veicular, que pode ser quanto à tração, quanto à espécie e quanto à categoria (DENATRAN, 1997). Especificamente, quanto à espécie, os veículos são subdivididos ainda em veículos de passageiros (12 classes), de carga (9 classes), misto (3 classes), de competição, de tração (4 classes), especial e de coleção, conforme Tabela 3.1.

Tabela 3.1 - Subclassificação quanto à espécie do CTB

II - Passageiros (a)	II - Carga (b)	II - Misto(c)	II - Tração (e)
1 – Bicicleta	1 – Motoneta	1 – Caminhoneta	1 – Caminhão trator
2 – Ciclomotor	2 – Motocicleta	2 – Utilitário	2 – Trator de rodas
3 – Motoneta	3 – Triciclo	3 – Outros	3 – Trator de esteira
4 – Motocicleta	4 – Quadriciclo		4 – Trator misto
5 – Triciclo	5 – Caminhonete		
6 – Quadriciclo	6 – Caminhão		
7 – Automóvel	7 – Reboque /Semi		
8 – Microônibus	8 – Carroça		
9 – Ônibus	9 – Carro de mão		
10 – Bonde			
11 – Reboque /Semi			
12 – Charrete			

Ainda de acordo com o CTB, no Anexo I – Dos conceitos e Definições, as principais classes de veículos são definidas como:

- Veículo de carga - veículo destinado ao transporte de carga, podendo transportar dois passageiros, exclusive o condutor.
- Veículo de passageiros - veículo destinado ao transporte de pessoas e suas bagagens.
- Veículo misto - veículo automotor destinado ao transporte simultâneo de carga e passageiro.
- Motocicleta - veículo automotor de duas rodas, com ou sem *side-car*, dirigido por condutor em posição montada.
- Automóvel - veículo automotor destinado ao transporte de passageiros, com capacidade para até oito pessoas, exclusive o condutor.

- Camioneta - veículo misto destinado ao transporte de passageiros e carga no mesmo compartimento.
- Caminhonete - veículo destinado ao transporte de carga com peso bruto total de até três mil e quinhentos quilogramas.
- Utilitário - veículo misto caracterizado pela versatilidade do seu uso, inclusive fora de estrada.
- Microônibus - veículo automotor de transporte coletivo com capacidade para até vinte passageiros.
- Ônibus - veículo automotor de transporte coletivo com capacidade para mais de vinte passageiros, ainda que, em virtude de adaptações com vista à maior comodidade destes, transporte um número menor.

Tabela 3.2 - Frota de veículos no Brasil e em Fortaleza segundo o DENATRAN em Março de 2011.

Tipo de Veículo	FROTA DO BRASIL		FROTA DE FORTALEZA	
	Frota	Percentual	Frota	Percentual
AUTOMOVEL	37.795.329	57,17%	432.505	59,30%
BONDE	120	0,00%	0	0,00%
CAMINHAO	2.173.370	3,29%	19.030	2,61%
CAMINHAO TRATOR	423.111	0,64%	2.912	0,40%
CAMINHONETE	4.392.292	6,64%	47.424	6,50%
CAMIONETA	1.901.821	2,88%	24.004	3,29%
CHASSI PLATAFORMA	3.625	0,01%	117	0,02%
CICLOMOTOR	97.887	0,15%	378	0,05%
MICRO-ONIBUS	277.350	0,42%	2.685	0,37%
MOTOCICLETA	14.320.591	21,66%	162.410	22,27%
MOTONETA	2.509.649	3,80%	4.717	0,65%
ONIBUS	460.076	0,70%	5.730	0,79%
QUADRICICLO	153	0,00%	0	0,00%
REBOQUE	801.672	1,21%	11.573	1,59%
SEMI-REBOQUE	624.840	0,95%	4.328	0,59%
SIDE-CAR	8.427	0,01%	248	0,03%
OUTROS	7.998	0,01%	55	0,01%
TRATOR ESTEIRA	164	0,00%	0	0,00%
TRATOR RODAS	22.345	0,03%	122	0,02%
TRICICLO	11.227	0,02%	202	0,03%
UTILITÁRIO	284.030	0,43%	10.850	1,49%
TOTAL	66.116.077	100,00%	729.290	100,00%

A Tabela 3.2 apresenta a frota quantitativa e percentual de veículos da cidade de Fortaleza e do Brasil. Estas informações são referentes ao mês de Março de 2011 e foram fornecidas pelo DENATRAN (<http://www.denatran.gov.br/frota.htm>).

A Tabela 3.3 apresenta a distribuição das frotas de acordo com o agrupamento proposto neste trabalho simplificando a Tabela 3.2. Verificamos que apenas 0,23% dos veículos da frota brasileira e 0,15% dos veículos da frota de Fortaleza não estão nas cinco classes adotadas no trabalho.

Tabela 3.3 - Quantidade de veículos nas classes propostas

Tipo de Veículo	FROTA DO BRASIL		FROTA DE FORTALEZA	
	Frota	Percentual da Frota	Frota	Percentual da Frota
1 – MOTOCICLETA S E MOTONETAS	16.830.240	25,46%	167.127	22,92%
2 - AUTOMÓVEIS E CAMIONETAS	39.697.150	60,04%	456.509	62,60%
3 - CAMINHONETES E UTILITÁRIOS	4.676.322	7,07%	58.274	7,99%
4 - CAMINHÃO, REBOQUE E SEMI-REBOQUE	4.022.993	6,08%	37.843	5,19%
5 - ÔNIBUS E MICRO-ÔNIBUS	737.426	1,12%	8.415	1,15%
6 – OUTROS	151.946	0,23%	1.122	0,15%
TOTAL	66.116.077	100,00%	729.290	100,00%

3.1.1 CARACTERÍSTICAS DO PERFIL MAGNÉTICO UTILIZADAS

Para se identificar as características relevantes do perfil magnético de cada veículo foi modificado o aplicativo de captura de imagens do equipamento de fiscalização de tráfego da empresa Fotosensores® Tecnologia Eletrônica Ltda. Este aplicativo é denominado SGL (Sistema de Gerenciamento Local) que além de armazenar a imagem dos veículos, passou a armazenar também os arquivos com o perfil magnético de cada veículo com a inclusão do módulo do perfil magnético (Figura 3.2). Com este banco de dados de imagens e dados foi possível fazer um estudo observando as características que poderiam ser utilizadas para treinar a RNA.

Também foi feito um levantamento das características utilizadas pelos pesquisadores da área. OH *et al.* em 2002 e OH, RITCHIE e STEPHEN em 2003 relacionam uma série de características usualmente extraídas dos perfis magnéticos obtidos de sensores indutivos convencionais pelos diversos pesquisadores da área. As características relacionadas por estes pesquisadores são resumidas na Figura 3.3 e Tabela 3.4. Algumas delas são extraídas da assinatura bruta (Figura 3.3-A e D), que é a curva gerada sem a normalização, como o tempo

de ocupação O (Tabela 3.4) em segundos (tempo em que o veículo permanece sobre o laço) e a variação máxima de magnitude M , que pode ser dada em contagem de ciclos, frequência em kHz, indutância em nano-Henries (ΔL) ou por unidade ($\Delta L/L$), ou ainda como S_L definido como o distúrbio percentual em relação à indutância de repouso. Outras grandezas são extraídas da assinatura normalizada em ambos os eixos de amplitude e tempo (Figura 3.3-B e E), dividindo-se os valores correspondentes ao eixo das ordenadas y por M e multiplicando-se os valores correspondentes ao eixo de tempo x pela velocidade v (resultando em uma medida de distância em metros), respectivamente.

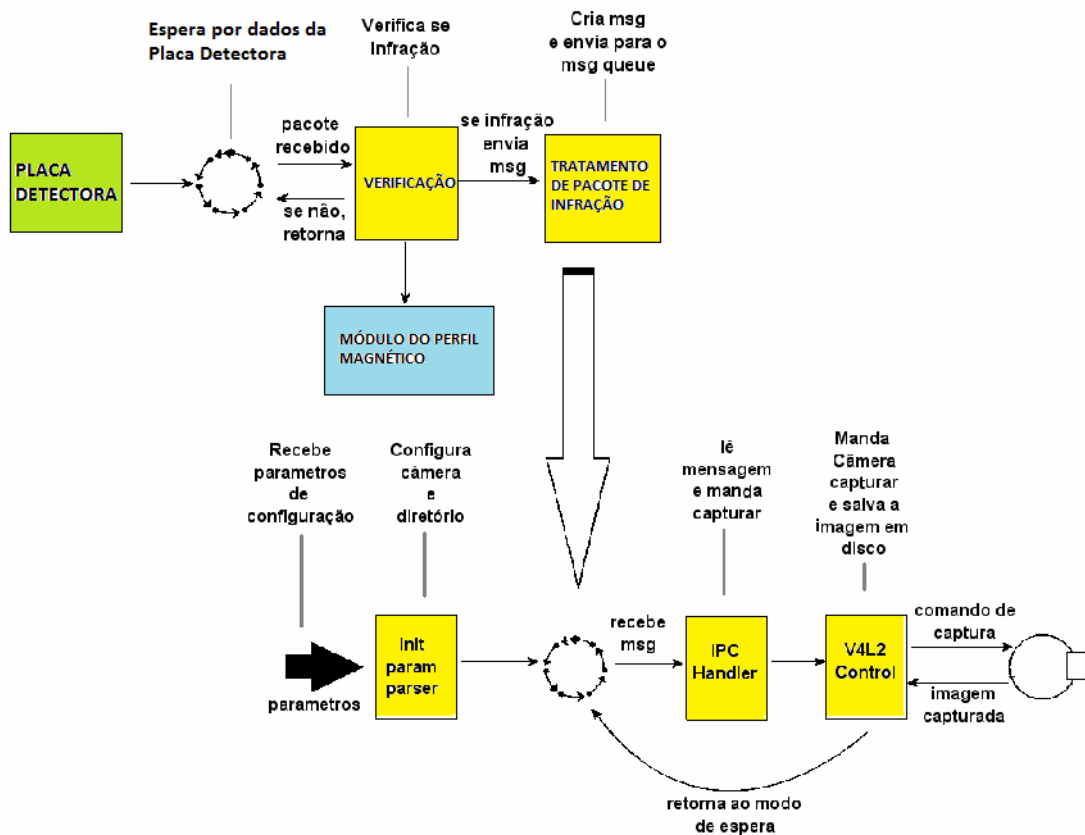


Figura 3.2 - Esquema do aplicativo SGL da Fotosensores®.

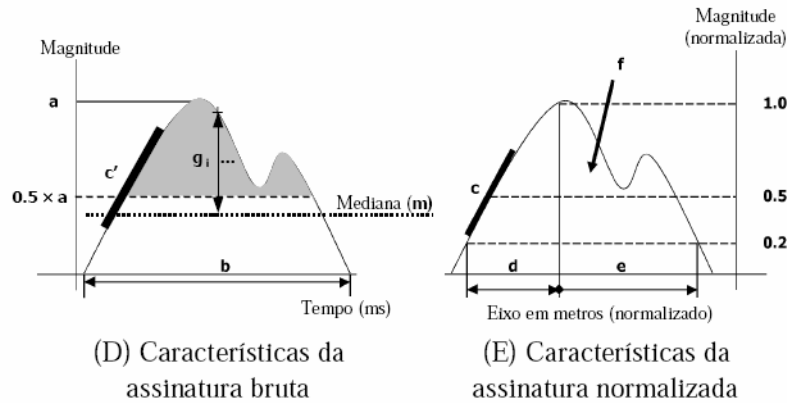



Figura 3.3 - Extração de características do perfil magnético (adaptado de OH *et al.*, 2002 e RITCHIE *et al.*, 2005).

Tabela 3.4 - Características extraídas de perfis magnéticos (adaptado de OH *et al.*, 2002, OH, RITCHIE e STEPHEN, 2003, RITCHIE *et al.*, 2005).

NOTAÇÃO	CARACTERÍSTICA	DESCRIÇÃO	CÁLCULO (Figura 3.3)
GRUPO I: CARACTERÍSTICAS DE TRÁFEGO			
O	TEMPO DE OCUPAÇÃO	Tempo total em que o veículo permanece sobre o laço indutivo (milissegundos)	b
SR	TAXA DE SUBIDA	Inclinação do perfil no ponto de ordenada y igual a 0,5 antes da normalização da abscissa	c'
V	VELOCIDADE	Velocidade instantânea do veículo	Equação 2.1
GRUPO II: CARACTERÍSTICAS DO VEÍCULO			
M	MAGNITUDE MÁXIMA	Valor máximo absoluto da magnitude	a
SP	PARÂMETRO DE FORMA	Grandeza relacionada ao grau de simetria e obliquidade do perfil (adimensional)	d/(d/e)
L	COMPRIMENTO ELETRÔNICO (OU MAGNÉTICO) DO VEÍCULO	Comprimento à partir da ocupação do laço (metros)	d/e
A	ÁREA SOB A CURVA DO PERFIL	Área sobre a curva após normalização	f
DOS	GRAU DE SIMETRIA	Seja m a mediana do perfil. DOS é a soma das distâncias (em y) até m de cada ponto acima da ordenada $y=0,5xa$ ($\Delta L/L$, por exemplo, adimensional)	
NHM	NÚMERO DE AMOSTRAS DE ALTA MAGNITUDE	Número de amostras acima da ordenada $y=0,5$ após a normalização nos eixos x e y (adimensional)	NHM
SRN	TAXA DE SUBIDA NORMALIZADA	Inclinação do perfil no ponto de ordenada y igual a 0,5 após normalização	c

As características mostradas na Tabela 3.4 referem-se aos perfis magnéticos de laços indutivos. Elas estão separadas em dois grupos, o primeiro deles com as grandezas referentes a informações de tráfego. O segundo grupo traz as características do veículo em si.

Observando o banco de dados de imagens e perfis magnéticos, conseguiu-se identificar algumas características do gráfico comum para determinados tipos de veículos.

Das características citadas na literatura, utilizamos a magnitude máxima e o tempo de ocupação. Outras características que utilizadas no trabalho foram: a área do gráfico, o tempo de deslocamento do veículo de um sensor para o outro e o número de máximos locais do gráfico do perfil magnético.

A área do gráfico é importante porque fornece uma idéia da forma, uma vez que, dependendo da distribuição dos valores, podemos ter valores de área diferente com a mesma amplitude máxima. Utilizamos esta informação dos dois sensores porque posteriormente será possível fazer uma comparação dos dois valores para identificar casos de medições incorretas possibilitando a exclusão destes eventos.

O tempo de deslocamento foi utilizado, substituindo o valor da velocidade que usualmente é utilizado por outros pesquisadores, porque ele é inversamente proporcional à velocidade de acordo com a Equação 2.1.

O número de máximos locais foi utilizado porque se verificou que em determinados tipos de classes de veículo esta informação foi muito importante para que a RNA tivesse êxito na classificação. Nos veículos de pequeno porte e motocicleta o número de máximos locais é geralmente um, enquanto que nos ônibus e caminhões verificam-se valores entre 4 e 12.

A Figura 3.4 apresenta a imagem de um veículo de passeio e o gráfico do perfil magnético do mesmo. Este veículo é o que apresenta os maiores valores de pico do perfil magnético porque são veículos baixos, com distância da massa metálica para os sensores mais próximos que outros veículos de maior porte. Também se observou que o número de máximos locais fica entre um e dois porque possuem massas metálicas distribuídas de forma homogênea. Outro veículo que apresentou características muito parecidas foram as camionetas de pequeno porte.

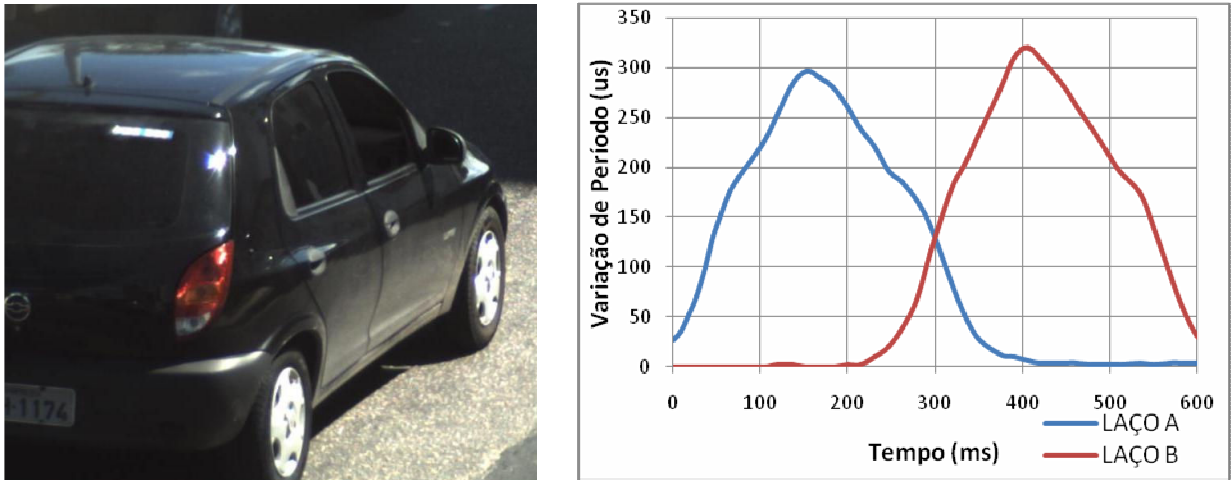


Figura 3.4 - Imagem e perfil magnético de um veículo pequeno.

As motocicletas apresentam características bem distintas de todos os veículos (Figura 3.5). As áreas e os valores de pico são bem menores que todos os outros veículos. Outra informação marcante neste veículo é o tempo de ocupação que também é menor que os veículos de passeio.

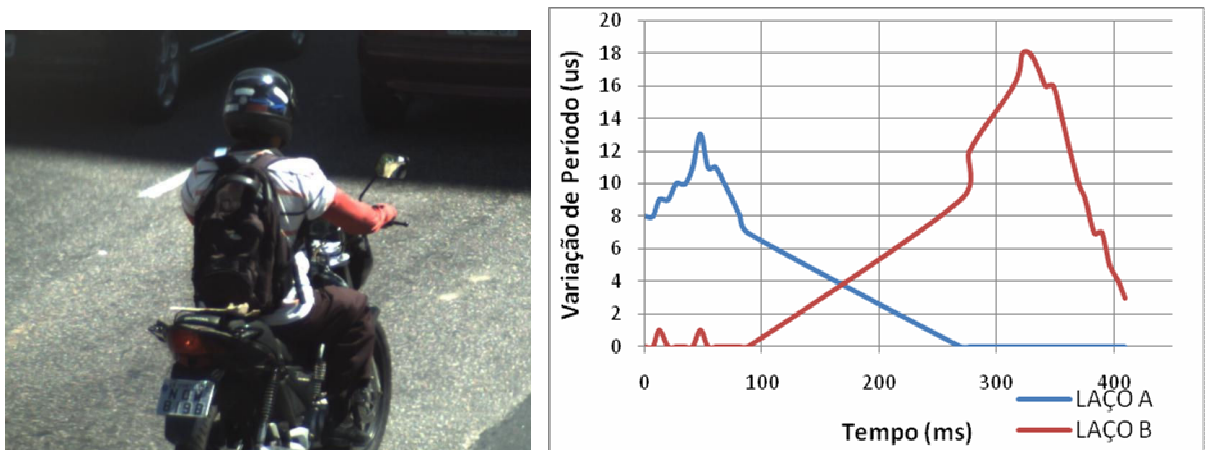


Figura 3.5 - Imagem e perfil magnético de uma motocicleta.

Os veículos do tipo van, camioneta e caminhonete possuem características parecidas com os veículos de passeio, porém possuem geralmente de 2 a 4 máximos locais além de apresentarem o tempo de ocupação um pouco maior. A Figura 3.6 e a Figura 3.7 apresentam respectivamente a imagem com o perfil magnético de uma caminhonete e a imagem com o perfil magnético de uma van. Verificamos que em ambos os casos os gráficos apresentam 3 máximos locais.

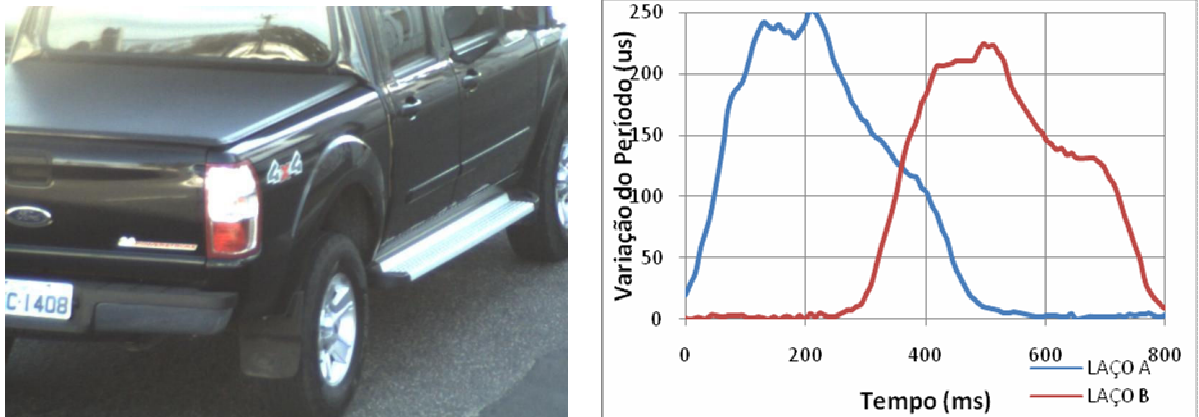


Figura 3.6 - Imagem e perfil magnético de uma caminhonete.

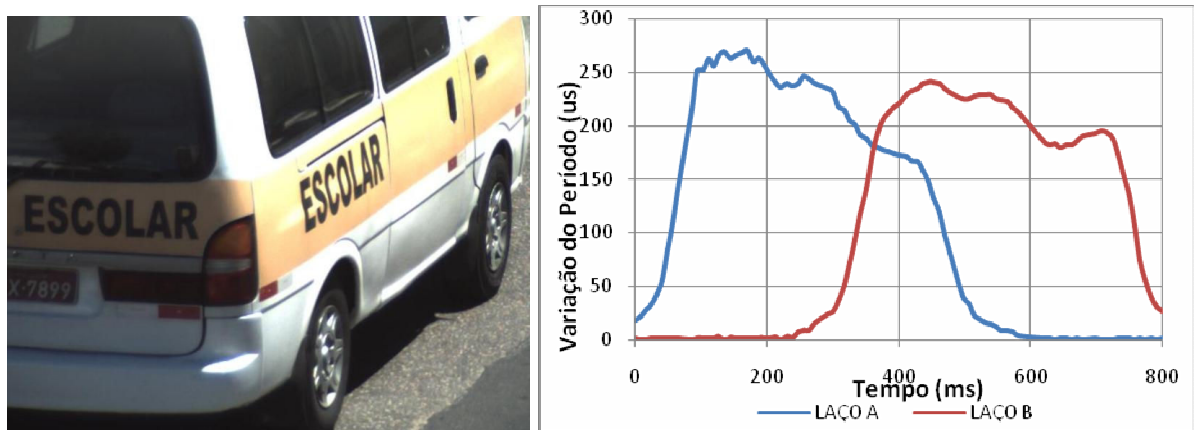


Figura 3.7 - Imagem e perfil magnético de um veículo tipo van.

Podemos observar nas Figura 3.8 e na Figura 3.9 que os caminhões e os ônibus apresentam uma quantidade de máximos locais bem maiores que os outros veículos. Outra característica destes tipos de veículos é o tempo de ocupação que também é maior. O que distingue um caminhão de um ônibus é que geralmente a área do perfil magnético do ônibus é maior porque a sua massa metálica é maior e a distribuição é homogênea.

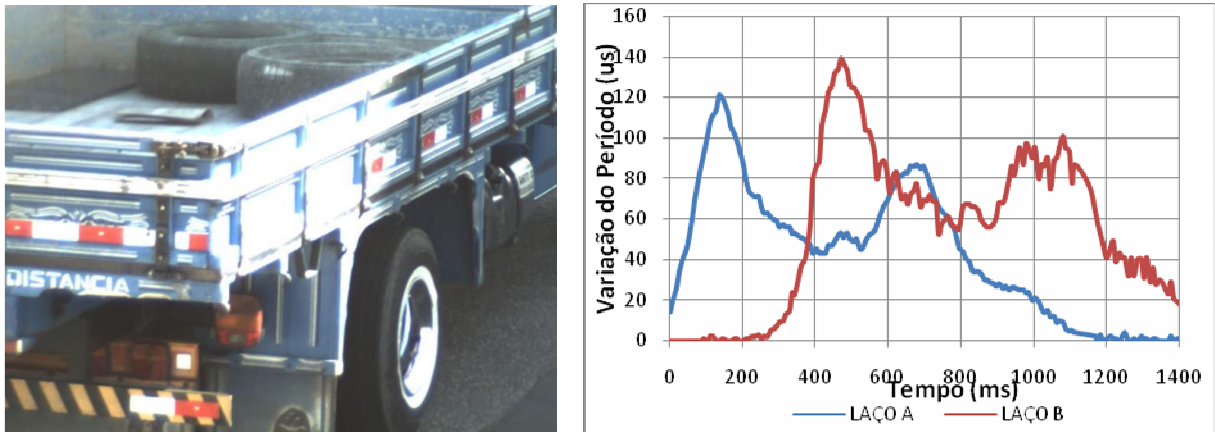


Figura 3.8 - Imagem e perfil magnético de caminhão.

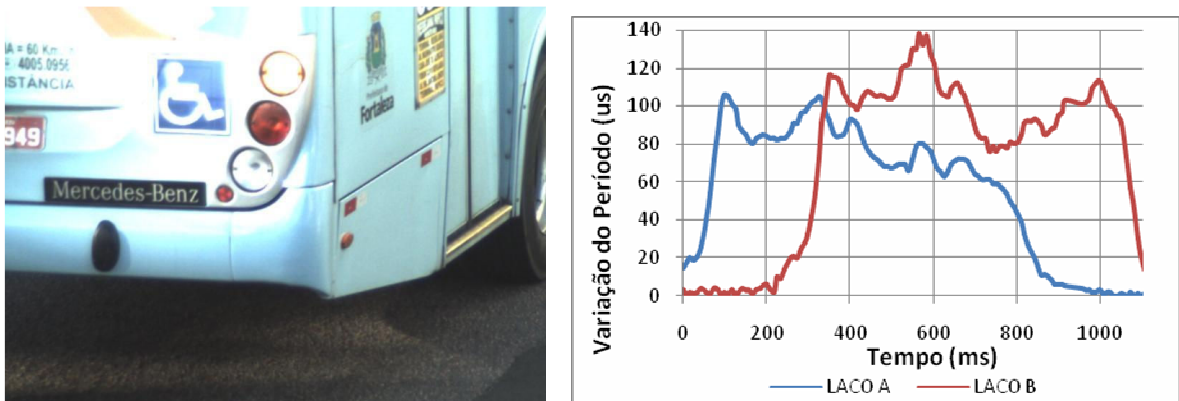


Figura 3.9 - Imagem e perfil magnético de um ônibus.

A tabela a seguir apresenta as características que foram utilizadas como entrada da RNA desenvolvida como classificador.

Tabela 3.5 - Entradas da RNA

Ítem	Descrição	Código
1	Área do perfil magnético no laço A	Aa
2	Área do perfil magnético no laço B	Ab
3	Valor máximo do perfil no laço A	Ma
4	Valor máximo do perfil no laço B	Mb
5	Tempo de ocupação no laço A	Ta
6	Tempo de ocupação no laço B	Tb
7	Tempo de deslocamento do laço A para o B	Td
8	Número de máximos locais no laço A	Na

3.1.2 ETAPAS DE DESENVOLVIMENTO

Para facilitar a compreensão de forma clara da solução proposta, dividiu-se a mesma em processos distintos sequenciais, de acordo com a Figura 3.10, que são: aquisição, consistência, treinamento, operação e avaliação.



Figura 3.10 - Diagrama de Atividades.

A etapa de aquisição consiste no armazenamento de um banco de dados de imagens e perfis magnéticos no equipamento de fiscalização de tráfego.

Na etapa de consistência os valores de saída ideal da rede são atribuídos de acordo com a verificação da imagem registrada e armazenada na etapa de aquisição. Nesta etapa também são selecionados os dados que serão utilizados para treinar a RNA.

Após a consistência, o treinamento da RNA já pode ser iniciado.

Após o treinamento é iniciada a operação do sistema com RNA funcionando e realizando a classificação dos veículos.

A etapa de avaliação consiste no levantamento estatístico de quantos veículos foram classificados corretamente.

3.2 AQUISIÇÃO DE DADOS

Para o desenvolvimento deste trabalho, foi utilizada a estrutura e o suporte da empresa Fotosensores® Tecnologia Eletrônica Ltda, fabricante de equipamentos de fiscalização de tráfego. Foi utilizado o parque de equipamentos instalados e operados pela empresa na cidade de Fortaleza (Figura 3.11). Esses equipamentos foram utilizados para levantamento de dados, testes e simulações.



Figura 3.11 - Equipamento de fiscalização de trânsito em Fortaleza.

Os equipamentos eletrônicos de medição de velocidade classificados como fixos pelo Código de Trânsito Brasileiro (DENATRAN, 1997) realizam, em sua grande maioria, a aquisição de dados através de sensores indutivos.

O equipamento de fiscalização eletrônica utilizado é dotado de uma placa detectora ou metrológica que possui quatro circuitos osciladores. Cada circuito é conectado a um sensor indutivo instalado no revestimento asfáltico da via. Cada faixa de rolagem da via é monitorada por dois sensores. Esta placa possui um microcontrolador que faz a leitura do período do sinal gerado neste circuito oscilador a cada instante de tempo e armazena em uma memória. Quando um veículo passa pelos dois sensores ocorre uma variação da frequência de oscilação que é detectada pelo microcontrolador na entrada do veículo em cada sensor. Quando a variação atinge um determinado valor de limiar (Figura 3.15) os dados começam a ser enviados, em tempo real, via UART (*Universal Asynchronous Receiver/Transmitter*) para um sistema computacional que possui uma câmera de vídeo CCD (Figura 3.12). O envio é encerrado quando é atingido novamente o valor de limiar. Neste momento a placa detectora envia um pacote de informações via serial contendo a data, o horário, o tipo de infração detectada, a velocidade medida e a faixa que o veículo passou. A imagem do veículo é registrada e associada aos dados recebidos.

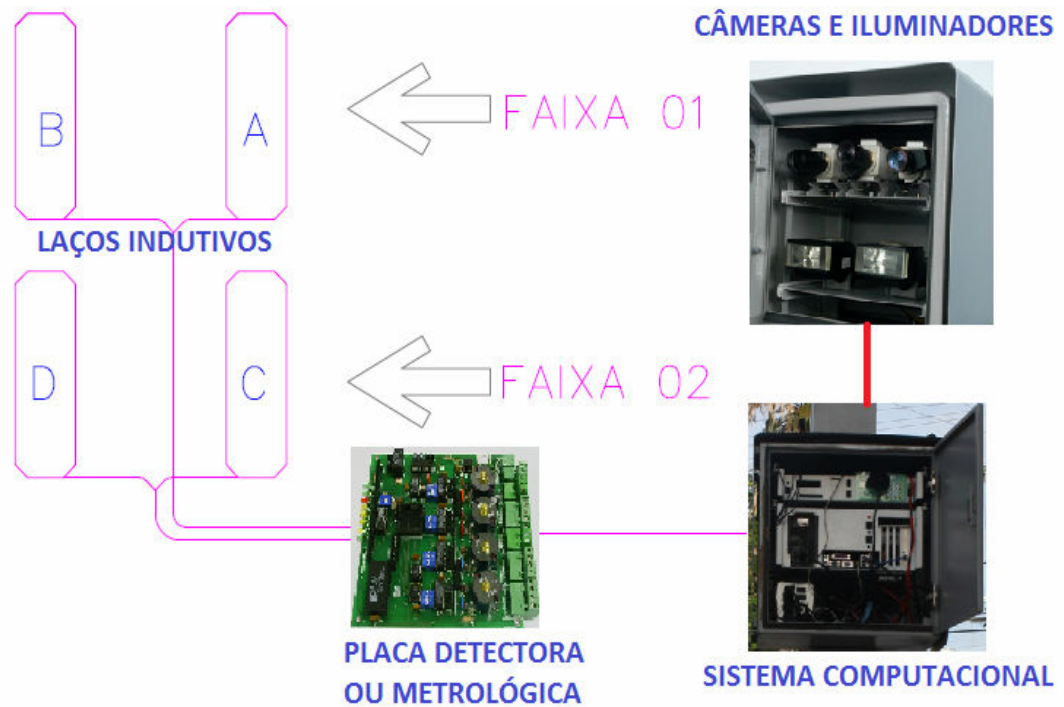


Figura 3.12 - Esquema de ligação do sistema de fiscalização eletrônica.

O processo de coleta dos perfis magnéticos foi automatizado e agregado ao sistema de medição de velocidade, possibilitando relacionar cada um destes perfis à imagem capturada do veículo. Desta forma, pôde-se gerar um banco de dados de perfis magnéticos com as respectivas fotografias dos veículos para análise.

A geração do banco de dados foi realizada através da implantação desse sistema de aquisição em um equipamento de fiscalização eletrônica de velocidade.

Para a implantação do sistema de aquisição não foi necessária a alteração do hardware do equipamento. O sistema computacional do equipamento de fiscalização utilizado é dotado de um processador Atlon X2 da AMD, duas memórias DDR2 de 1GB, um HD de 160GB e uma placa mãe Gigabyte. A placa detectora ou metrológica utilizada no sistema é a placa SMTDP fabricada pela Fotosensores®. Esta placa realiza o monitoramento de duas faixas de rolagem utilizando quatro sensores indutivos. Os sensores indutivos utilizados são confeccionados com cabos de 2,5 mm e cada laço indutivo é formado por seis voltas deste cabo. O sistema de captura é dotado de três câmeras de vídeo com resolução de imagem de 640x480 e dois iluminadores infravermelhos.

Os laços indutivos utilizados possuem 1,0 m de largura, com comprimento variando de acordo a largura da faixa de rolagem. Os laços indutivos estão dispostos de forma que a distância entre a borda de cada laço esteja a 3,5 m da mesma borda do laço vizinho, assim a

distância entre o primeiro e o último laço é de 2,5 m, e a distância total ocupada pelos dois laços de fora a fora é de 4,5 m. A Figura 3.13 ilustra a disposição dos laços na via.




Figura 3.13 - Disposição dos laços indutivos do sistema a utilizado (distância em metros).

3.3 PROCESSAMENTO DOS DADOS

Para o desenvolvimento do sistema de classificação baseado em uma RNA MLP foi feito um tratamento dos dados fornecidos pela placa detectora. Os dados de perfil magnético referentes a cada veículo correspondem aos valores de variação do período nos dois sensores correspondentes à faixa em que o veículo está passando em determinadas amostras de tempo.

Estes dados recebidos são processados para que seja feita a extração das informações necessárias para alimentar a entrada da rede RNA. Este processo é feito em três etapas pelo próprio software do equipamento de fiscalização de trânsito: deslocamento do eixo temporal, normalização e extração das informações.

O deslocamento do eixo consiste em deslocar o início da curva do laço A para a posição 0 no eixo do tempo de acordo com o que podemos observar na Figura 3.14.




Figura 3.14 - Gráficos do perfil magnético antes e depois do deslocamento

Como foi citado anteriormente, o conjunto de informações utilizadas como entradas na rede desenvolvida foram: os valores máximos de variação em cada um dos sensores (M_a e M_b), a área sob a curva das variações dos períodos dos sinais gerados pelos osciladores nos dois sensores durante a passagem do veículo (A_a e A_b), o tempo de ocupação do veículo em cada um dos sensores (T_a e T_b), o tempo de deslocamento (T_d) e o número de máximos locais da curva do primeiro sensor (N_a) (Figura 3.15).

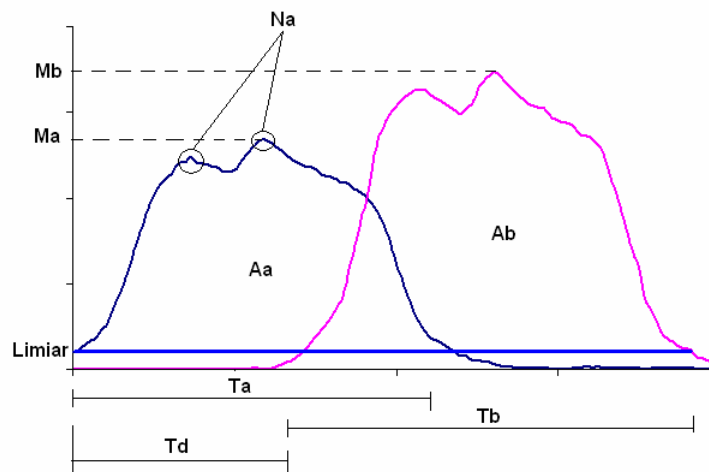


Figura 3.15 - Informações extraídas do perfil magnético.

3.4 MONTAGEM DO PROTÓTIPO

Para testes e simulações do sistema de classificação inicialmente, o mesmo foi integrado a um equipamento de fiscalização de tráfego fabricado pela empresa Fotosensores® instalado na cidade de Fortaleza (Figura 3.16).



Figura 3.16 - Equipamento de fiscalização de tráfego.



Figura 3.17 - Visão interna do equipamento.

O equipamento de fiscalização de tráfego utilizado é denominado SMTD – Sistema de Monitoramento de Tráfego Digital e utiliza o sistema operacional Linux. O aplicativo utilizado para fazer o registro das imagens dos veículos infratores é denominado SGL – Sistema de Gerenciamento Local. Nele também é possível fazer todas as configurações do equipamento. O classificador baseado em perfil magnético foi integrado a este software. Na Figura 3.18 é possível identificar um gráfico de perfil magnético sendo plotado em tempo real no momento em que o veículo está passando. Este equipamento encontra-se instalado na Avenida Rogaciano Leite, número 1040, na cidade de Fortaleza.

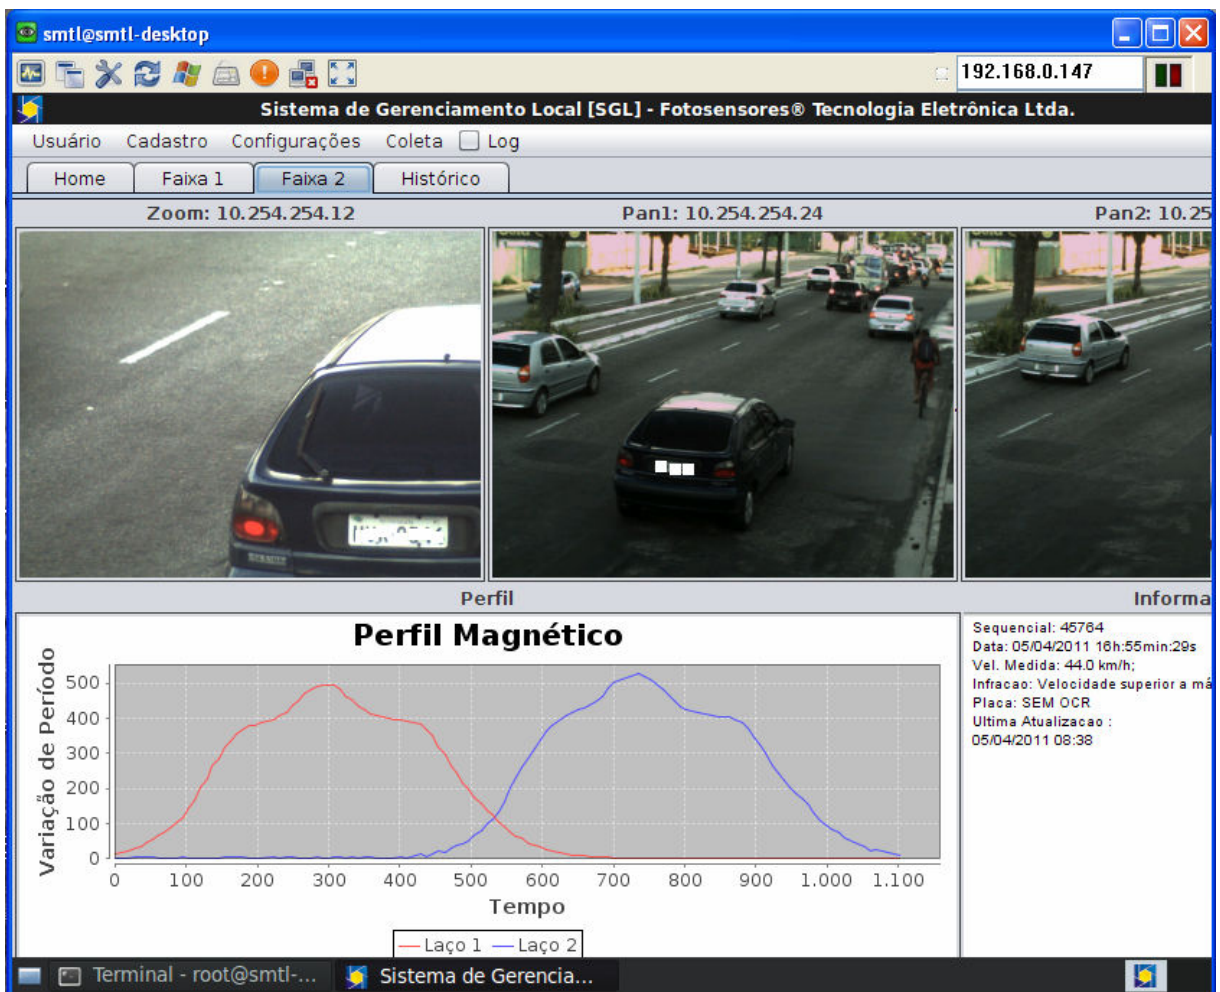


Figura 3.18 - Tela principal do SGL.

Inicialmente este aplicativo deve ser utilizado para a captura de amostras de perfil magnético de todos os tipos de veículo para serem utilizados no treinamento da RNA. Este aplicativo pode operar em dois modos com relação ao classificador. Ele pode funcionar com o classificador habilitado ou com a coleta de perfil magnético habilitada. Para que ele funcione como coletor, basta marcar a opção “Habilitar coleta RNA” na tela “Regra de funcionalidades” conforme Figura 3.19.

Com esta funcionalidade habilitada o SGL salvará os dados de perfil magnético na pasta /opt/FotoCaptura/perfil. As imagens são sempre salvas na pasta

/opt/FotoCaptura/imagens_infra. Dentro da pasta perfil são guardados os arquivos evento.CSV com os dados processados de cada perfil magnético. Estes dados correspondem aos valores de entrada da RNA. Também é armazenado o arquivo máximos.CSV que será utilizado na normalização dos dados de entrada da Rede.




Figura 3.19 - Tela de configuração de funcionalidades.

3.5 CONSIDERAÇÕES FINAIS

Neste Capítulo foi apresentado o sistema proposto, explicando a escolha do número de classes e as características do perfil magnético utilizadas como entrada da RNA. Foram apresentados detalhes do hardware do sistema de aquisição de dados e do processamento dos dados do perfil magnético de cada veículo com o objetivo de extrair as informações necessárias para alimentar a RNA. O equipamento de fiscalização de tráfego fabricado pela Fotosensores® teve seu software adaptado para realizar a coleta dos dados de perfil magnético.

No próximo Capítulo serão apresentados os detalhes do sistema desenvolvido em Matlab e posteriormente implementado com a plataforma de desenvolvimento de software Java. Os resultados obtidos serão apresentados e comentados.

CAPÍTULO 4 - DESENVOLVIMENTO DO SISTEMA CLASSIFICADOR

4.1. SISTEMA CLASSIFICADOR DESENVOLVIDO

A implementação da RNA funcionando como um classificador foi feito inicialmente utilizando-se a ferramenta computacional Matlab. Nesta etapa, os dados de perfil magnético de todos os veículos foram armazenados pelo equipamento de fiscalização de tráfego e coletados posteriormente. Em seguida, os dados obtidos foram tratados para se extrair as informações de entrada da RNA.

Para realizar a classificação utilizou-se uma rede RNA MLP (Perceptron de Múltiplas Camadas) (Subseção 2.4.1 e 2.4.2) com uma camada escondida com oito neurônios. Estes neurônios possuem função de ativação do tipo sigmóide logística, conforme a Equação 4.1. A camada de entrada da rede possui oito entradas (Tabela 3.5) para receber os valores máximos de variação em cada sensor, os somatórios dos períodos em cada sensor, os tempos de permanência sobre os sensores, o tempo de deslocamento do veículo entre um sensor e outro e o número de máximos locais na curva gerada pelo primeiro laço. A rede possui um único neurônio na camada de saída, também com função de ativação do tipo sigmóide logística. Os valores iniciais de pesos são iguais a zero e o valores iniciais de bias iguais a 1. Os valores de saída do neurônio da camada de saída serão de acordo com a Tabela 4.1. O fato de utilizarmos apenas um neurônio na camada de saída facilitou posteriormente a alteração do sistema para classificação em 5 categorias.

$$\Phi(v) = \frac{1}{1 + \exp(-\alpha v)} \quad (4.1)$$

O treinamento da rede foi feito baseado no algoritmo de Levenberg-Marquardt (Subseção 2.4.2). Utilizando um μ inicial de 0,3, com taxa de incremento de 10 e taxa de decremento de 0,9.

Como estratégia de parada, o número máximo de épocas para desenvolvimento do treinamento foi parametrizado em 1000 iterações. O alvo de redução da função custo, nesse caso Erro Quadrático Médio, foi parametrizado em 10^{-6} . Outra forma de parar o treinamento era que o cálculo do gradiente da função custo ficasse abaixo do mínimo de 10^{-10} .

Esta primeira rede implementada realizou a classificação dos veículos em quatro classes: motocicletas, veículos de pequeno porte, veículos de médio porte e veículos de grande porte.

Tabela 4.1 - Valores de saída do neurônio da camada de saída.

Classe	Saída da Rede	Código
Motocicleta	0,25	T
Veículo Pequeno (Carros de passeio)	0,50	P
Veículo Médio (Vans e Utilitários)	0,75	M
Veículo Grande (Ônibus e Caminhão)	1,00	G

A avaliação desta rede foi feita através de testes com dados gerados no equipamento de fiscalização de acordo com o descrito no capítulo anterior.

A etapa seguinte consistiu no desenvolvimento de um aplicativo denominado FotoPerfil (Figura 4.1) em Java que tem a finalidade de auxiliar na visualização dos dados e imagens coletados, além de auxiliar na seleção das informações válidas, tratamento e validação dos dados obtidos e treinamento da RNA. Logo a seguir é apresentada a tela inicial deste aplicativo. Para o desenvolvimento da RNA foi utilizada o framework ENCOG.

ENCOG é um framework de redes neurais e inteligência artificial disponível para Java, .Net e Silverlight. O ENCOG contém classes para criar uma ampla variedade de RNAs, como classes para normalizar e processar dados para essas RNAs. Com ele é possível implementar e treinar a rede neural com diversas técnicas de treinamento, como Back Propagation, Resilient Propagation, Levenberg–Marquardt, entre outros (HEATON, 2010). Também é possível utilizar Multithread, que é uma forma de um processo dividir a si mesmo em duas ou mais tarefas que podem ser executadas concorrentemente, para obter um melhor desempenho durante o treinamento em máquinas multiprocessadas. Seu código fonte está disponível sob licença LGPL (Lesser General Public License) para qualquer pessoa utilizar, estudar, modificar e distribuir de acordo com os termos da licença.



Figura 4.1 - Tela inicial do FotoPerfil.

Os dados de perfil magnético e as imagens coletadas no equipamento de fiscalização de tráfego SMTD devem ser transferidos para a pasta do aplicativo FotoPerfil;

Em seguida deve-se escolher a opção Obter Dados no menu de Configurações. A tela a seguir será exibida (Figura 4.2).



Figura 4.2 - Tela de Dados.

Deve ser escolhida a opção Consistência na tela principal do FotoCaptura (Figura 4.1) e em seguida devem-se copiar os fluxos e imagens das pastas copiadas do equipamento de fiscalização de tráfego. Após a conclusão da cópia dos dados podemos abrir a tela de consistência.

A tela de consistência (Figura 4.3) é utilizada para a validação dos dados de perfil magnético obtidos pelo equipamento SMTD. É possível visualizar para cada veículo os seus dados de perfil magnético original e normalizado, a imagem registrada, o gráfico do perfil magnético, os dados de entrada da rede e o valor de saída ideal. Cada veículo deve ser avaliado por um especialista que conheça as classes de veículos e deve-se atribuir o valor de saída ideal. Os valores de saída que podem ser atribuídos são: 1 para motocicleta, 2 para carro de passeio, 3 para veículo de médio porte, 4 para caminhão e 5 para ônibus. Após atribuir o valor de saída ideal é necessário acionar o botão de salvar. Os valores associados acima serão todos divididos por cinco pelo software para que possam ficar equivalentes aos valores de saída da RNA de acordo com Tabela 4.2.

Nesta etapa também se deve excluir dados que estejam com alguma inconsistência. Também se deve deixar as quantidades de cada classe aproximadamente a mesma quantidade para cada classe. Estes dados serão utilizados para o treinamento da Rede RNA.

Figura 4.3 - Tela de consistência.

Após a preparação dos dados na Tela de Consistência devemos realizar o treinamento da RNA na tela específica para esta função (Figura 4.4). No final do treinamento será criado o arquivo FotoPerfil.eg. Este arquivo contém os parâmetros de treinamento da rede e deve ser colocado na pasta /opt/FotoCaptura/Perfil/treinamento no equipamento de SMTD. Logo em seguida o classificador pode ser colocado em operação.

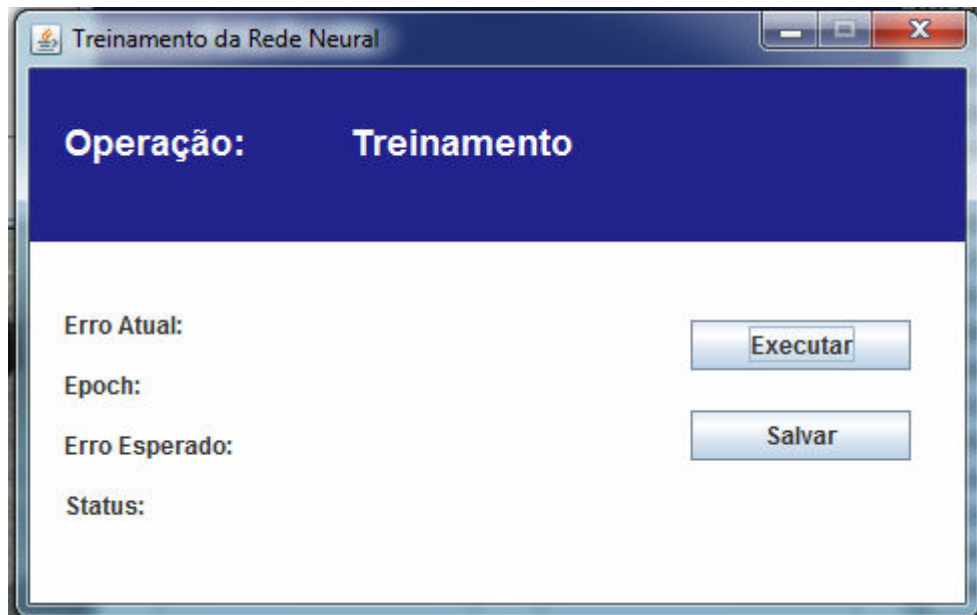


Figura 4.4 - Tela de treinamento.

A rede treinada pode ser testada antes de ser colocada no equipamento. Para tanto, basta carregar alguns dados coletados em campo para teste e escolher a opção testes na tela principal do programa (Figura 4.1). A tela mostrada na Figura 4.5 será apresentada mostrando o resultado do teste. Também é possível visualizar os dados de entrada de cada veículo, bem como o valor de saída ideal e o valor de saída da rede para comparação. Os valores de saída da RNA devem assumir valores próximos aos apresentados na Tabela 4.2.

Tabela 4.2 - As 5 classes de veículos definidas.

Classe	Saída da Rede	Código
Motocicleta	0,2	T
Veículo Pequeno	0,4	P
Veículo Médio	0,6	M
Caminhão	0,8	C
Ônibus	1,0	O

Operação: Avaliar Dados

Ma	Mb	Aa	Ab	Ta	Tb	Td	Na	Saida	Ideal	Modelo
171	227	5717	6768	392	462	333	1	0,61	0,60	M
**131	**197	**5827	**7664	**500	**616	**332	**2	**0,71	**0,60	**C
113	144	4256	4966	475	556	334	1	0,66	0,60	M
319	425	8905	12312	380	452	345	1	0,49	0,40	P
357	500	9404	11076	341	423	324	1	0,45	0,40	P
217	227	8306	8146	501	600	368	2	0,64	0,60	M
230	203	6922	6106	409	516	305	1	0,58	0,60	M
277	285	10362	9491	443	506	342	4	0,62	0,60	M
226	221	8020	7580	466	581	340	3	0,65	0,60	M
272	254	7905	6766	406	484	328	2	0,56	0,60	M
228	229	8099	7650	480	534	334	3	0,64	0,60	M

425 itens

Acertos: 94,35% 401 itens

Erros: 5,65% 24 itens

Figura 4.5 - Tela de avaliação da RNA.

A avaliação dos resultados obtidos com o classificador pode ser feita com a tela a seguir (Figura 4.6). Basta fazer uma cópia dos arquivos obtidos no equipamento SMTD durante a operação do classificador. Pode ser feita uma comparação dos resultados obtidos pelo classificador que já existia no equipamento com o novo classificador baseado em Perfil Magnético e RNA. O sistema também salva um arquivo txt com os resultados do classificador desenvolvido e os resultados do sistema de classificação existente no equipamento. Com isso é possível comparar os resultados dos dois sistemas e criar matrizes comparando os resultados para cada tipo de veículo.

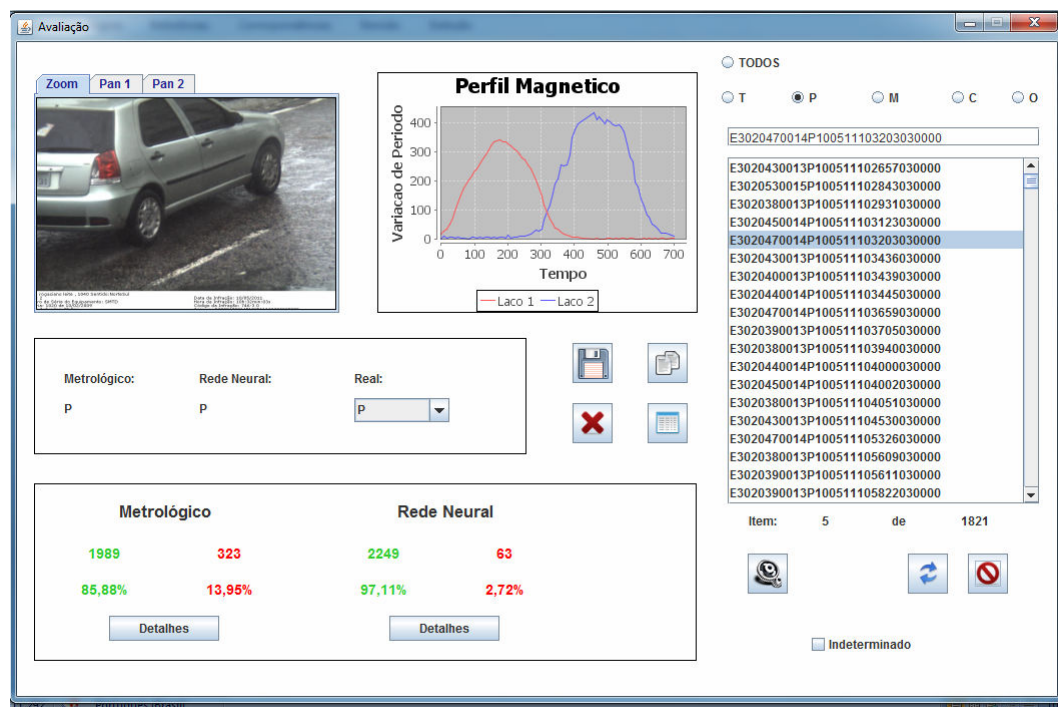


Figura 4.6 - Tela de avaliação de resultados do classificador.

Acionando o botão “Detalhes” que fica abaixo dos resultados apresentados pela Rede Neural Artificial é possível visualizar todas as imagens dos veículos que a rede classificou de forma errada. Esta funcionalidade permite uma melhor análise dos erros cometidos pela RNA, possibilitando inclusive que estes eventos sejam inseridos em um novo treinamento da rede para tentar reduzir os erros.

4.2 RESULTADOS

Para o desenvolvimento do primeiro classificador que utilizou o Matlab foi utilizado um conjunto de 286 dados de perfil magnético, sendo 71 gerados por motocicleta, 86 gerados por veículos pequenos, 66 por veículos médios e 63 gerados por veículos grandes.

Para efeito estatístico, o ato de treinar e testar a rede, verificando sua taxa de acerto, foi repetido 20 vezes. A Rede Neural foi então treinada com 60% dos dados, sendo os 40% restantes separados para verificação da generalização da rede neural através de teste da rede já treinada. Os dados foram normalizados para o treinamento, dividindo-se cada valor de entrada pelo valor máximo do atributo.

Seguem os resultados para os dados de treinamento e de teste.

Tabela 4.3 - Resultados simulação da rede com dados de treinamento.

Número de repetições	Taxa Acerto Mínimo	Taxa Acerto Médio	Taxa Acerto Máximo
20 vezes	100%	100%	100%

A taxa de acerto no treinamento sempre foi de 100% nas 20 vezes em que se repetiu o procedimento de treinar a RNA com os dados selecionados para o treinamento. Para cada procedimento de testes os dados eram embaralhados para a separação dos dados de treinamento.

Tabela 4.4 - Resultados simulação da rede com dados de teste.

Número de repetições	Taxa Acerto Mínimo	Taxa Acerto Médio	Taxa Acerto Máximo
20 vezes	86,08%	92,43%	96,52%

Para realização dos testes foram utilizados 115 dados do total de dados coletados. Obtivemos uma taxa de acerto médio de 92,43%. As taxas de acerto médio para cada classe de veículos foram: 100% para motocicletas e veículos grandes, 94% para veículos pequenos e 84% para veículos médios.

Para efeito de análise é apresentada a Tabela 4.5 com os resultados obtidos em uma das iterações do processo de treinamento e teste da rede. Nesta iteração a taxa de acerto para veículos grandes e motocicletas foi de 100%. Enquanto que a taxa de acerto para veículos pequenos e veículos médios foi de 94,12% e 87,5%, respectivamente. Também é possível identificar quais os tipos de veículo que apresentam maior dificuldade de classificação correta pela rede. Pode-se observar que 2 veículos pequenos foram identificados como veículos médios e 1 veículo médio foi identificado como veículo pequeno. Isto ocorre porque existem camionetes com tamanho muito próximo ao tamanho de um carro de passeio, bem como existem carros do tipo sedan que possuem o tamanho de algumas caminhonetes médias. Outro erro comum é a identificação de veículos médios como veículos grandes porque a forma de onda do perfil magnético de um veículo tipo van é muito parecida com a de um ônibus. Nesta iteração isso ocorreu 2 vezes.

Tabela 4.5 - Resultados com classificador desenvolvido em Matlab.

Classificação/Real	Moto	Veículo Pequeno	Veículo Médio	Veículo Grande	Total Real	Taxa de acerto
Moto	31	0	0	0	31	100,00%
Veículo Pequeno	0	32	2	0	34	94,12%
Veículo Médio	0	1	21	2	24	87,50%
Veículo Grande	0	0	0	26	26	100,00%
Total	31	33	23	28	115	95,65%

Após a validação do algoritmo com o Matlab em laboratório com dados coletados em campo, foi desenvolvido o sistema em Java para fazer a classificação dos veículos em tempo real já no equipamento de fiscalização de tráfego.

O treinamento da rede foi realizado com um total de 630 perfis magnéticos coletados, sendo 150 motocicletas, 205 veículos pequenos, 147 veículos médios e 116 veículos de grande porte. Após o treinamento o sistema de classificação foi posto em operação no equipamento de testes durante um dia e em seguida coletamos os resultados. O teste foi realizado com um total de 326 veículos. Na Tabela 4.6, apresentada a seguir, podemos identificar claramente o índice de acerto para cada classe de veículo, bem como identificar onde o sistema mais errou.

Tabela 4.6 - Resultado da classificação veicular em 4 categorias.

Classificação/Real	Moto	Veículo Pequeno	Veículo Médio	Veículo Grande	Total Real	TAXA DE ACERTO
Moto	27	0	0	0	27	100,00%
Veículo Peq.	3	214	17	0	234	91,45%
Veículo Med.	0	0	47	1	48	97,92%
Veículo Grande	0	0	2	15	17	88,24%
Total (Rede)	30	214	66	16	326	92,94%

O sistema acertou todos os veículos do tipo motocicleta, obteve 91,45% de acerto para veículos de pequeno porte, 97,92% para veículos de médio porte e 88,24% para veículos grandes. Verificamos que dos 326 veículos registrados apenas 23 foram classificados de forma errada, sendo que 17 destes eram veículos pequenos que foram classificados como veículos de médio porte. No geral foram 92,94% de acerto. Foi observado que o índice de acerto geral ficou próximo à média obtida nos testes em laboratório com o algoritmo implementado com o Matlab. O índice de acerto de veículos grandes sofreu uma redução com relação aos resultados obtidos no laboratório passando de 100% para 88,24%. Isto se deve ao fato de no campo existirem mais ruídos e porque no local de testes, em alguns casos, os veículos passam entre faixas, diminuindo assim o efeito do veículo sobre o laço indutivo e alterando a amplitude máxima do perfil magnético registrado.

O próximo passo no desenvolvimento do sistema foi a divisão da categoria de veículos grandes em duas: caminhões e ônibus. Com isso, o sistema passou a classificar em cinco classes: motocicletas, veículos pequenos, veículos médios, caminhões e ônibus. Também foram obtidos bons resultados com esta nova configuração.

Desta vez, para treinar a RNA foram utilizados um total de 672 perfis magnéticos coletados, sendo 135 motocicletas, 202 veículos pequenos, 148 veículos médios, 103

caminhões e 84 ônibus. Após o treinamento, o sistema de classificação foi posto em operação no equipamento de testes durante dois dias e em seguida foram coletados os resultados. Na Tabela 4.7 observam-se os resultados obtidos.

Tabela 4.7 - Resultado da classificação veicular em 5 categorias.

Classificação/Real	Moto	Veículo Pequeno	Veículo Médio	Caminhão	Ônibus	Total Real	TAXA DE ACERTO
Moto	171	0	0	0	0	171	100,00%
Veículo Pequeno	0	1783	37	0	0	1820	97,97%
Veículo Médio	0	6	254	11	0	271	93,73%
Caminhão	0	0	1	14	1	16	87,50%
Ônibus	0	0	0	6	31	37	83,78%
Total (Rede)	171	1789	292	31	32	2315	97,32%

Desta vez o resultado geral foi de 97,32% de acerto. Foram registrados 2315 veículos e apenas 62 (2,68%) foram identificados de forma errada. Mais uma vez o índice de acerto com motocicletas foi de 100%. Já o índice de acerto para veículos pequenos foi de 97,97%. Para veículos de médio porte obteve-se uma eficiência de 93,73%. Para caminhões e ônibus obtiveram-se respectivamente índices de acerto de 87,50% e 83,78%. Dos 62 veículos classificados de forma errada, mais uma vez a maioria era de veículos pequenos classificados como veículos médios. Desta vez foi um total de 37 casos. Também ocorreram 11 erros de identificação de veículos médios que foram classificados como caminhão. Isto ocorre devido à forma de onda do perfil magnético de alguns tipos de caminhões de pequeno porte ser muito parecido com o perfil magnético gerado por caminhonetes. Outro erro importante observado foi a classificação de ônibus como caminhão. Isto ocorre porque, como já foi mencionado anteriormente, alguns veículos passam entre as faixas de rolagem e quando os ônibus capturados estão nesta situação, apresentam o gráfico do perfil magnético semelhante ao de alguns modelos de caminhão.

Foi feito também um levantamento estatístico para verificar o índice de acerto obtido pelo método utilizado atualmente pela Fotosensores®. Observou-se que dos 2315 veículos registrados, 1989 (85,92%) foram classificados corretamente de acordo com o tamanho e 326 (14,08%) foram classificados de forma errada. Lembrando que este método não diferencia caminhões e ônibus, classificando em quatro classes. Para efeito de cálculo, os ônibus e caminhões foram considerados como veículos de grande porte.

4.3. COMENTÁRIOS FINAIS

Neste capítulo foi apresentada a evolução do trabalho que se iniciou com o desenvolvimento da RNA no Matlab, realizando a classificação em quatro categorias, passou para o desenvolvimento do classificador em um software feito em Java, ainda com quatro categorias e finalmente foi apresentado o classificador com cinco categorias.

Foi feita uma análise do resultado obtido com a versão final do classificador, além de realizar uma comparação dos resultados com o método utilizado atualmente pela Fotosensores®.

A versão final do classificador apresentou um resultado geral de 97,32% de acerto para 2315 veículos e apenas 62 (2,68%) foram identificados de forma errada. O índice de acerto com motocicletas foi de 100%. Já o índice de acerto para veículos pequenos foi de 97,97%. Para veículos de médio porte obteve-se uma eficiência de 93,73%. Para caminhões e ônibus obtiveram-se respectivamente índices de acerto de 87,50% e 83,78%.

CAPÍTULO 5 - CONCLUSÕES E TRABALHOS FUTUROS

5.1 CONCLUSÕES

O sistema desenvolvido pode ser utilizado para diversas finalidades no gerenciamento e controle de tráfego das grandes cidades e rodovias. Ele permite a detecção de infração de veículos onde a velocidade máxima permitida varia de acordo com o porte do veículo, pode ser usado no cálculo da velocidade e comprimento do veículo. Outra aplicação interessante está no controle de acesso a estacionamentos pagos onde existem preços diferenciados para cada porte de veículo, pois cria uma automação do processo de cobrança.

O sistema foi concebido para ser embarcado em um hardware com limitações de processamento e de memória. Portanto é um sistema otimizado e que mesmo sendo integrado em um equipamento de fiscalização de tráfego não deve reduzir o desempenho do mesmo.

A classificação foi feita inicialmente em quatro categorias: motocicletas, veículos pequenos, veículos médios e veículos grandes. Após a validação do sistema através de simulações no Matlab com dados coletados em equipamentos de fiscalização, foi desenvolvido um sistema baseado na linguagem de programação Java usando o framework ENCOG que foi integrado ao sistema de fiscalização, realizando assim a classificação em tempo real. Este sistema passou a classificar os veículos em cinco categorias porque a categoria de veículos grandes foi dividida em duas: ônibus e caminhões.

Os resultados obtidos foram um índice de acerto superior a 83% para todos os veículos. O índice de acerto geral na classificação dos veículos ficou superior a 97%.

A estrutura da RNA desenvolvida para o sistema permite que o mesmo possa ser alterado facilmente para aumentar o número de categorias de veículos.

Para a implantação da solução no parque de equipamentos instalados e operados pela empresa Fotosensores® não é necessário a alteração da estrutura de hardware dos equipamentos, basta fazer uma atualização de software.

Com a implantação desta solução os equipamentos de fiscalização deixam de classificar os veículos apenas pelo tamanho. O sistema novo permite o aumento do número de classes e melhora a precisão da diferenciação de veículos de pequeno porte com os veículos

de médio porte. O sistema utilizado atualmente classifica os veículos em motocicleta, veículo pequeno, veículo médio e veículo grande. O sistema desenvolvido permite a classificação em motocicleta, veículo pequeno, veículo médio, caminhão e ônibus. Com isso o equipamento pode ser utilizado para registrar infrações de veículos trafegando em faixas de rolagem exclusivas para ônibus.

5.2 RECOMENDAÇÕES PARA TRABALHOS FUTUROS

Para os próximos trabalhos propomos a integração deste sistema com outros sistemas de detecção de veículo, como por exemplo, com sensores piezelétricos onde seria possível utilizar a quantidade de eixos dos veículos como mais uma entrada da RNA. Também seria possível utilizar as distâncias entre eixos e pode-se associar a intensidade da pressão exercida pelos pneus para dimensionar o peso dos veículos.

Outro trabalho a ser desenvolvido é embarcar o sistema em uma placa baseada em um processador ARM ou similar. Este trabalho provavelmente será desenvolvido com placas de desenvolvimento ARM baseadas em sistemas operacionais Linux como, por exemplo, a placa *Beagle Board* que suporta as seguintes distribuições do Linux: Angstron, Android e Ubuntu. A *BeagleBoard* é um computador em uma única placa de baixo consumo e de baixo custo produzida pela Texas Instrument em parceria com a Digi-Key. A BeagleBoard foi projetado com código fonte aberto para desenvolvimento, e como uma forma de demonstrar o funcionamento do microprocessador OMAP3530 da Texas Instrument. A placa pode ser utilizada em faculdades de todo o mundo para ensinar hardware de código aberto e recursos de software open source.

O Sistema de detecção por laço indutivo também pode ser melhorado com o desenvolvimento de um sistema utilizando um processador ARM com um DSP possibilitando, desta forma, a criação de algoritmos de filtragem de ruídos e tratamento de erros. Com este sistema o cálculo da velocidade pode ser realizado com uma precisão maior.

REFERÊNCIAS BIBLIOGRÁFICAS

ABDULHAI, B., TABIB, SEYED, M. “Spatio-temporal inductance-pattern recognition for vehicle re-identification”, *Transportation Research Part C*, 11:223-39, 2003.

ANDREOTTI, M. T. Sensoriamento indutivo para veículos automotores. 112 f. Dissertação (Mestrado em Engenharia Elétrica e Informática Industrial) - Centro Federal de Educação Tecnológica do Paraná (CEFET-PR), Curitiba, 2001.

BARBOSA, H.; BRAGA, C.; JOTA, F.; MAGALHÃES, D.; GOUVÊA, R.; DOURADO, D.; CARVALHO, J.; EULETÉRIO, J.; MENDES, V. “Sistema de identificação de veículos por meio de laços de indução: um projeto integrado de ensino e desenvolvimento tecnológico”, *XVIII ANPET – Congresso de Pesquisa e Ensino em Transportes*, Florianópolis, SC, Brasil, 2004.

BOYLESTAD, R. L. e NASHELSKY, L. Dispositivos Eletrônicos e Teoria de Circuitos. 8ª Ed., Pearson Education, 2004.

CALIXTO, S. A. Classificação de Veículos Através de Sistemas Fuzzy. 86 f. Dissertação (Mestrado em Engenharia Elétrica e Informática Industrial)– Gerência de Pesquisa e Pós-Graduação, Universidade Tecnológica Federal do Paraná, Curitiba, 2006.

DENATRAN, Código de Trânsito Brasileiro – CTB. Lei n. 9.503, de 23 de Setembro de 1997. Disponível em: <http://www.denatran.gov.br/ctb.htm>. Acesso em 10 jul. 2011.

DNIT; NEP-UFSC, Identificação de Sistemas de Pesagem em Movimento - Fase 2: Pré-avaliação dos Equipamentos Disponíveis para Utilização nas Pesagens, Relatório, Novembro de 2007. Disponível em:

<http://www.dnit.gov.br/rodovias/operacoes-rodoviaras/convenios-com-a-ufsc/tt-102-2007-produto-complementar-12.pdf>. Acesso em 10 jul. 2011.

FHWA, “Field test of monitoring of urban vehicle operations using non-intrusive technologies”, Minnesota Department of Transportation – US FHWA, USA, May, 1997

GAJDA, J.; SROKA, R.; STENCEL, M.; WAJDA, A.; ZEQLIN, T. “A vehicle classification based on inductive loop detectors,” in *Proc. 18th IEEE Conf. IMTC*, May 2001, vol. 1, pp. 460–464.

GAJDA, J.; SROKA, R.; STENCEL, M.; WAJDA, A.; ZEQLIN, T. “An Eastern European example of the identification of moving vehicle parameters using the tried and trusted method of weigh in motion,” *Traffic Technol. Int.*, pp. 87–90, Aug./Sep. 2000.

GAJDA, J.; SROKA, R.; STENCEL, M.; ZEQLIN, T., “Measurement of road traffic parameters using an inductive single-loop detector,” in *Proc. 9th IMEKO Symp.*, Glasgow, U.K., Sep. 1997.

GUPTE, S., PAPANIKOLOPOULOS, N. Algorithms for vehicle classification. Final Report n° MN/RC – 2000-27, 1999-2000. University of Minnesota, July 2000.

HAYKIN, S. *Neural Networks: A comprehensive foundation*, Prentice Hall, ISBN 0-13-908385-5. p.396, 1999.

HAGAN, M. T.; MENHAJ, M. B. Training Feed-Forward Networks with the Marquardt Algorithm; *IEEE Transactions on Neural Networks*, vol. 5, no. 6, pp. 989-993, 1994.

HARLOW, C.; PENG, S., “Automatic vehicle classification system with range sensors”, *Transportation Research Part C*, 9:231-47, 2001.

HEATON, J., *An Introduction to Encog Neural Networks for Java*, 2010, <http://www.codeproject.com/KB/recipes/encogintroxorjava.aspx>, acessado em 29/07/2011.

JAZAYERI, P.; ROSEHART, W.; WESTWICK, D. T.; A Multistage Algorithm for Identification of Nonlinear Aggregate Power System Loads; IEEE Transactions on Power Systems, vol. 22, no. 3, pp. 1072-1079, 2007.

MACCARLEY, A. Advanced image sensing methods for traffic surveillance and detection. California Path Research Report, UCB-ITS-PRR-99-11, Berkeley, Março, 1999.

MAGALHÃES, H. A. Análise em Alta Resolução de Perfis Magnéticos de Sensores a Laço Indutivo para Classificação de Veículos Automotores. 216 f. Tese (Doutorado em Engenharia) - Programa de Pós-Graduação em Engenharia Elétrica da Escola de Engenharia da Universidade Federal de Minas Gerais, Belo Horizonte, 2008

MARAT-MENDES, R. M. M. Desenvolvimento de um transdutor piezoelétrico para medição da aceleração angular. Dissertação de mestrado apresentada à Universidade Nova de Lisboa, 2000.

META, S.; CINSDIKICI, M. G. “Vehicle Classification Algorithm based on Component Analysis for Single Loop Inductive Detector”, IEEE Transactions on Vehicular Technology, vol. 59, no. 6, pp. 2795 – 2805, 2010

MIMBELA, L. E., KLEIN L. A Summary of vehicle detection and surveillance technologies used in intelligent transportation systems. Submitted to Federal Highway Administrations (FHWA) Intelligent Transportations Systems Joint Program Office, November, 2000.

MOHOTTALA, S., KAGESAWA, M., IKEUCHI, K. Vehicle class recognition using 3D CG models. Proceedings of 2003 ITS World Congress, November 2003.

NISHIMOTO, R. E., Novas Geometrias de Laços Indutivos. 120 f. Dissertação (Mestrado em Engenharia Elétrica e Informática Industrial)–Gerência de Pesquisa e Pós-Graduação, Universidade Tecnológica Federal do Paraná, Curitiba, 2006.

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.

OH, C.; RITCHIE, STEPHEN G., “Anonymous Vehicle Tracking for Real-Time Traffic Surveillance and Performance on Signalized Arterials” – Report UCI-ITS-TS-WP-03-14, 82nd Annual Meeting of the Transportation Research Board, TRB 2003 Annual Meeting CD-ROM Paper 03-4347, Washington, D. C., January, 2003.

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. XVIII Congresso Brasileiro de Automática (CBA), Bonito-MS, 2010.

OPITZ, R. CALL, J., “A piezo polymer solution for low cost traffic sensors”, Diverse industrial presentations, January, 1996.

PFANNERSTILL, E., “Automatic Monitoring of Traffic Conditions by Re-identification of Vehicles”, Proceedings – IEE Conference on Road Traffic Monitoring, Report 299, pp. 172-5, 1989.

POTTER, T., The evolution of inductive loop detector technology, Reno A&E, <http://www.renoae.com/Documentation/MISC/Advances%20in%20Loop%20Detector%20Technology.pdf> acessado em 29/07/2011.

RAO, N. D.; TRIPATHY, S. C. Power System Static State Estimation By the Levenberg-Marquardt Algorithm. IEEE Transactions on Power Apparatus and Systems, vol. PAS-99, no. 2, pp. 695-702, 1980.

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.

RUSSELL, S., NORVIG, P. *Artificial Intelligence: A Modern Approach*. 3. ed. Prentice Hall, ISBN-10: 0136042597. p.1152, 2010

SIMONI, L., *Contagem de eixos de veículos com sensores indutivos* Dissertação (Mestrado) – Programa de Pós-graduação em Engenharia Elétrica e Informática Industrial, Universidade Tecnológica do Paraná, Curitiba, 2008.

SROKA, R., “Data fusion methods based on fuzzy measures in vehicle classification process” in *Instrumentation and Measurement Technology Conference*, Vol.3, pp. 2234 - 2239, 2004.

SUN, C.; RITCHIE, S. G.; TSAI, K., “Algorithm development for derivation of section-related measures of traffic system performance using inductive loop detectors,” in *Transportation Research Record 1483*. Washington, DC: TRB, National Research Council, 1995, pp. 171–180.

SUN, C., RITCHIE, S. G. “Individual Vehicle Speed Estimation Using Single Loop Inductive Waveforms”, *Journal of Transportation Engineering*, pp. 531-8, 1999.

SUN, C., RITCHIE S. G., OH S. Inductive classifying artificial network for vehicle type categorization. California Path Research Report, UCB-ITS-WP-00-26, Berkeley, Dezembro, 2000.

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, November, 2006.

ZHANG, C., SIYAL, M. Y. A new segmentation technique for classification of moving vehicles. *Vehicular Technology Conference Proceedings*, Tokyo, IEEE 51st, pg 323-326 vol.1, 2000.

APÊNDICE A - EXEMPLO DE UM CIRCUITO DE DETECÇÃO DE VEÍCULOS POR LAÇO INDUTIVO

A.1 - O HARDWARE DO IDENTIFICADOR DE VEÍCULOS:

O hardware de um sistema identificador de veículos por laços indutivos é constituído, basicamente, por dois laços indutivos instalados sob o asfalto e o circuito eletrônico que detecta a variação do campo magnético produzido pelos laços. O laço, quando energizado, funciona como um indutor, criando um campo magnético ao seu redor. Com a passagem de veículos sobre ele, ocorre uma alteração no campo magnético, devido às correntes de Foucault, que aparecem nas partes metálicas dos veículos (BARBOSA *et al.*, 2004). O circuito eletrônico que realiza a detecção pode ser dividido em dois módulos: circuito oscilador de Colpitts e circuito PLL.

A.1.1 O CIRCUITO OSCILADOR DE COLPITTS

O circuito oscilador de Colpitts (BOYLESTAD e NASHELKY, 2004) tem como objetivo medir as variações produzidas pela passagem de veículos sobre o laço, transformando essas variações no campo magnético do laço em tensão elétrica. Neste circuito, o laço corresponde ao elemento indutivo, sendo a frequência de oscilação determinada pelos elementos capacitivos e indutivos do circuito (RLC). Os elementos capacitivos têm um valor fixo, porém o laço de corrente tem sua indutância variada em função do meio magnético ao seu redor. Assim, a frequência do oscilador irá depender da variação do campo magnético do laço. A frequência de oscilação característica está, geralmente, entre 10 kHz e 200 kHz. A frequência de oscilação é então convertida em um sinal analógico, conforme detalhado a seguir. Quando um veículo passa sobre o laço, por ter uma grande massa metálica, provoca uma alteração nas características do circuito RLC, já que a permeabilidade magnética do metal é maior que a do ar, diminuindo o valor da indutância e, conseqüentemente, aumentando o valor da frequência de oscilação. Sendo assim, o detector provê dois tipos de sinais, um de valor mais elevado (com a indutância padrão) e, portanto, sem veículo sobre o laço, e outro de valor menor quando a indutância sofre redução, revelando a presença de um veículo (Figura A.1) (BARBOSA *et al.*, 2004).




Figura A.3 - Indutância e assinatura de identificação da classe do veículo (BARBOSA *et al.*, 2004).

O circuito deste oscilador, como é encontrado em (BOYLESTAD e NASHELSKY, 2004), é apresentado na Figura A.2.

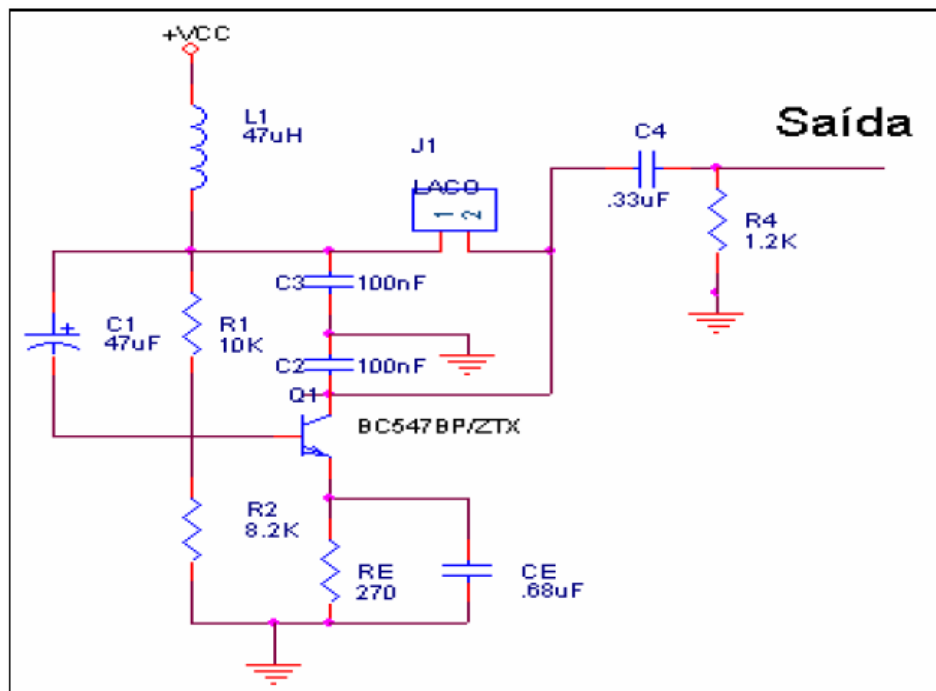


Figura A. 4 - Oscilador de Colpitts (BARBOSA *et al.*, 2004).

O laço indutivo é ligado aos terminais 1 e 2 do conector J1 do circuito oscilador (Figura A.2) cuja saída é conectada à entrada de um “detector de fase” especial, conhecido pela sigla PLL (do Inglês, “*Phase Locked Loop*”).

A frequência de oscilação (como dito, definida pelos valores dos capacitores C1 e C2 e da indutância do laço, L) é dada por:

$$f = \frac{1}{2\pi\sqrt{LC_{eq}}} \quad (\text{A.1})$$

Sendo C_{eq} a capacitância equivalente:

$$C_{eq} = \frac{C_1 C_2}{C_1 + C_2} \quad (\text{A.2})$$

A determinação do melhor valor da frequência de oscilação deve ser cuidadosa. Quando esta frequência é muito baixa, a sensibilidade do circuito a variações de indutância ocorridas no laço (pela passagem dos veículos) é muito pequena, o que ocasiona a perda de muitos detalhes da curva característica dos mesmos. Ensaios feitos por Barbosa e colegas em 2004 mostraram que a faixa ideal de frequências está entre 40 kHz e 200 kHz.

A.1.2 O CIRCUITO PLL – *PHASE LOCKED LOOP*

O sinal senoidal gerado pelo oscilador Colpitts sofre variações quando da passagem de veículos sobre o laço indutivo. Essas variações na frequência do oscilador provocam como consequência variações na fase do sinal senoidal, variações estas que podem ser medidas, com precisão e alta sensibilidade, por um “detector de fase” tipo PLL. O circuito integrado NE565 pode desempenhar a função do *Phase Locked Loop* (PLL). Este possui um oscilador interno que entra em fase com a frequência do sinal de entrada, ou seja, entra em fase com o sinal senoidal proveniente do oscilador. O NE565 possui três sinais de saída: um com forma de onda triangular, um com forma de onda quadrada (ambos na mesma frequência, e iguais à do sinal de entrada) e uma tensão contínua cujo valor depende da frequência do sinal de entrada. Detalhes das interconexões para integração do PLL à saída do Oscilador de Colpitts são mostrados na Figura A.3 (BARBOSA *et al.*, 2004).

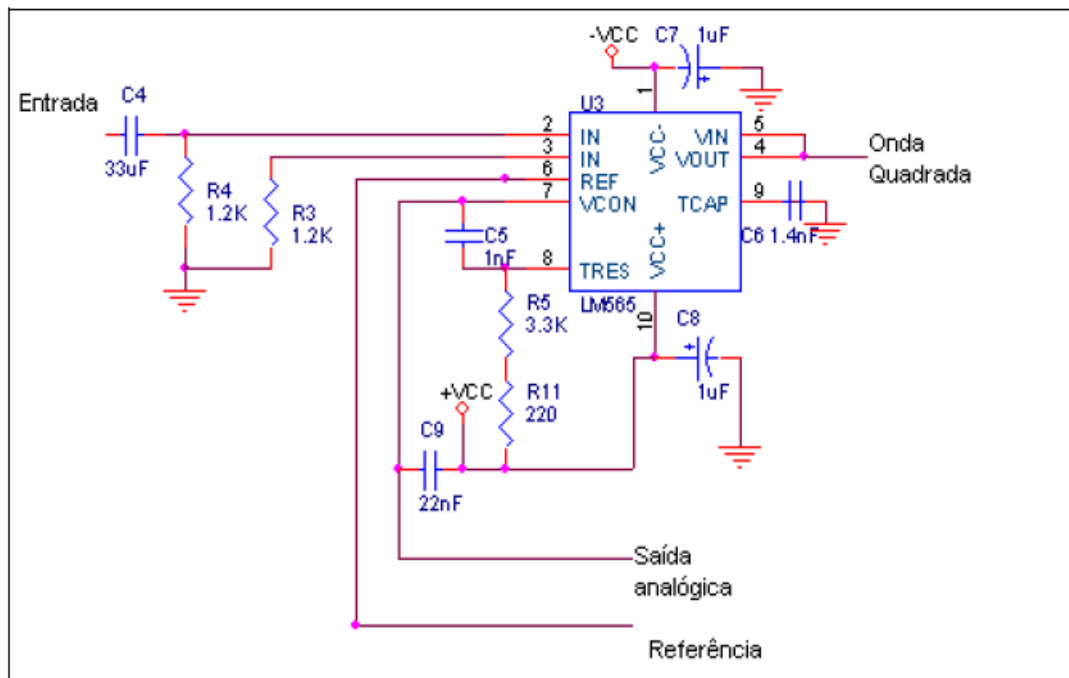


Figura A. 3 - Diagrama de conexões do PLL ao oscilador Colpitts (BARBOSA *et al.*, 2004).

O capacitor C4 e a resistência R4 (Figura A.3) formam um filtro passa-alta para o sinal proveniente do oscilador, eliminando assim seu valor DC, deixando passar apenas a oscilação em torno da referência de tensão. O valor da resistência R3 deve ser igual ao de R4, para que o PLL receba corretamente a referência de tensão a ser utilizada. O capacitor C9 tem a função de filtrar o sinal da saída analógica, conforme será detalhado mais adiante. Os pinos 4 e 5 do NE565 são interligados entre si para fornecer o sinal de saída em forma de onda quadrada. O sinal com forma de onda triangular é observado no pino 9, antes do capacitor C6. Os valores das resistências R5 e R11 e do capacitor C6 determinam a frequência central de oscilação (BARBOSA *et al.*, 2004).

Nos cálculos dos valores das resistências e capacitores do PLL, dois aspectos devem merecer consideração especial: a frequência de corte do filtro e a frequência central de oscilação (BARBOSA *et al.*, 2004).

Um terceiro ponto a ser considerado (na escolha dos parâmetros do PLL) é a faixa de frequências (em torno da frequência central) em que o PLL consegue manter-se em fase com o sinal de entrada, a chamada frequência de captura (f_c). Caso este valor seja menor do que a faixa de variação possível da frequência do oscilador, novo ajuste dos parâmetros deve ser feito (BARBOSA *et al.*, 2004).

A frequência central do PLL corresponde à frequência que faz com que a tensão na saída analógica (do PLL) seja igual à referência (zero volt). O ajuste deste parâmetro é de

fundamental importância, já que é ele que define o valor da tensão na saída, em função da frequência da entrada (que no caso é a frequência do oscilador Colpitts do qual, como visto, o laço faz parte) (BARBOSA *et al.*, 2004).

O sinal de interesse do PLL é a saída analógica que, depois de convertida para a forma digital, é utilizada para transmitir a informação de variação da frequência do oscilador. A variação da frequência também pode ser verificada através do sinal de saída de onda quadrada. Para realizar a leitura destes sinais é utilizado um microcontrolador que também deve transmitir estas informações para um computador via USB.