

Identificar e testar técnicas baseadas em Redes Neurais e Lógica Difusa para o Controlo de Semáforos em Tráfego Urbano

Gustavo Filipe Lopes Correia Pinto

Licenciado em Engenharia Mecânica – Ramo Qualidade e Ambiente
pelo Instituto Superior de Engenharia do Porto

Dissertação submetida para satisfação parcial dos
requisitos do grau de mestre
em
Automação, Instrumentação e Controlo

Faculdade de Engenharia da Universidade do Porto
Mestrado em Automação, Instrumentação e Controlo
Rua Dr. Roberto Frias, 4200-465 Porto, Portugal

Novembro de 2007

Dissertação realizada no âmbito do programa do
Mestrado em Automação, Instrumentação e Controlo da
Faculdade de Engenharia da Universidade do Porto

Dissertação realizada sob a supervisão do
Professor Doutor Manuel Romano dos Santos Pinto Barbosa
Professor Auxiliar do Departamento de
Engenharia Mecânica e Gestão Industrial da
Faculdade de Engenharia da Universidade do Porto

“Forecasting is the art of saying what will happen,
and then explaining why it didn’t”

Anonymous

Resumo

Um dos problemas das grandes cidades, nos tempos de hoje, é o controlo do tráfego automóvel. Este problema surgiu não apenas devido ao crescimento do número de automóveis nas cidades e limitações de capacidade dos acessos existentes, mas também devido às limitações das soluções normalmente utilizadas no escalonamento e o controlo feito nos semáforos.

As dificuldades associadas à implementação de soluções mais eficientes no controlo de semáforos estão associadas por um lado ao elevado número de factores que afectam as condições de tráfego. Por outro lado, as decisões tomadas localmente, ao nível de um semáforo, podem condicionar a evolução do tráfego noutros locais ou cruzamentos.

Este tipo de problema pode considerar-se a um nível mais abrangente como envolvendo problemas de optimização e controlo. As limitações das soluções convencionais e o interesse em soluções mais eficientes, juntamente com o aparecimento recente de abordagens alternativas tais como Redes Neurais (*'Artificial Neural Networks – ANN'*) e Lógica Difusa (*'Fuzzy Logic'*), entre outras, tem justificado o desenvolvimento e procura de novas soluções baseadas nesses conceitos.

Algumas das características que tornam estas soluções especialmente adequadas a estes problemas, são a sua natural adequação a problemas não lineares e o seu potencial para tratar problemas de dimensão elevada. Por outro lado a sua aplicação resulta normalmente numa abordagem casuística (*"caso a caso"*) devido à multiplicidade de alternativas na representação do problema e na determinação ou ajuste dos parâmetros envolvidos. Deste modo existe ainda um campo considerável para estudo e desenvolvimento de soluções para os problemas associados em particular ao controlo de tráfego urbano.

O trabalho apresentado nesta Dissertação consiste em identificar estratégias de controlo de semáforos que possam beneficiar destes novos

conceitos. Em particular testaram-se soluções para previsão do fluxo de tráfego nas vias de ligação aos semáforos, com base em Redes Neurais do tipo “*Backpropagation*” e soluções híbridas baseadas em Lógica Difusa e Redes Neurais “*ANFIS*”. Utilizaram-se dados reais de fluxos de tráfego e o programa de computador MatLab® como plataforma de desenvolvimento e implementação das soluções.

Os resultados obtidos permitem verificar da facilidade em obter soluções adequadas tendo em conta tendências ou valores médios das variáveis, mas também na dificuldade em obter soluções para modelar com um grau de eficiência elevado o comportamento discreto associado à evolução do fluxo de tráfego.

Abstract

One of the problems in the big cities nowadays is the control of the traffic. This problem arise not only because of the growth of cars in the cities and the limitations in the existing accesses but also because of the limitations of the solutions usually used in the scheduling and control done at the traffic lights.

The difficulties associated with the implementation of more efficient solutions in the control of the traffic lights are related to the large number of causes that can affect traffic conditions. Furthermore the decisions made locally, at one traffic light, may condition the evolution of the traffic in other places or junctions

This kind of problem may, in a broader perspective, be considered as involving problems of optimization and control. The limitations of the conventional solutions and the need for more efficient ones, along with the recent appearance of alternative approaches such as the Artificial Neural Networks (ANN) and Fuzzy Logic, among others, have contributed to the development and search of new solutions based on these concepts.

Some of the characteristics that make these solutions especially appropriate to these problems are their natural fit to model non linear problems and its potential to deal with problems of greater dimension. On the other side its application usually results in a case to case approach due to the multiplicity of alternatives in the representation of the problem and in the determination or adjustment of the parameters involved. There is thus a considerable field for the study and development of solutions for the problems particularly associated to the control of urban traffic.

The essay here presented aims to identify strategies for the control of the traffic lights that may benefit from these new concepts. In particular, the solutions were tested in the prediction of the traffic flow in the roads leading to the traffic lights, based on the Backpropagation Neural Networks and hybrid solutions using both Fuzzy Logic and Neural Networks (ANFIS). Real traffic flow data was used and the software tool used as a platform for the development and implementation of the solutions was MATLAB®.

The results obtained show that mapping the general behaviour of traffic flows can be easily achieved, but it is difficult to model with high efficiency the behaviour of traffic in short periods of time

Às minhas quatro mulheres:

MÃE **F**RATERNA

AVÓ **E**TERNA

ESPOSA **Ú**NICA

FILHA **P**ALRADORA

Ao terminar mais uma etapa da minha vida, não posso deixar de expressar os meus sinceros agradecimentos a todas as pessoas que de algum modo contribuíram para a concretização deste trabalho, e em especial:

- Ao meu orientador, o professor Manuel Romano Barbosa, pela disponibilidade e forma como orientou cientificamente esta dissertação, quero aqui mostrar a minha eterna gratidão,*
- Ao professor António Ferreira da Silva, pelo apoio e incentivos que me deu e pela amizade demonstrada,*
- Ao professor José Pedro Tavares, pela disponibilidade e informação que permitiram maior facilidade na familiarização com o problema da gestão de tráfego e a obtenção dos dados utilizados,*
- À minha família e a todos os meus amigos, que me deram algo muito especial, a **AMIZADE**,*
- À minha madrinha por ser um anjo,*
- Aos meus “irmãos” de afinidade pela amizade,*
- Aos meus queridos pais por me ensinarem a ser persistente,*
- Ao meu mano...*

Índice

1. Introdução e Objectivos	1
2. Gestão de Tráfego Urbano e Controlo de Semáforos	5
2.1 GESTÃO DE TRÁFEGO	5
2.2 CONTROLO DE SEMÁFOROS	8
2.2.1 <i>Regulação de tráfego com recurso a semáforos</i>	8
2.2.2 <i>Regulação de tráfego centralizada</i>	15
2.2.3 <i>Exemplos de sistemas de regulação</i>	20
3. Estratégias para Gestão de Tráfego	22
3.1 SISTEMAS INTELIGENTES	22
3.2 ENQUADRAMENTO DO TRABALHO DESENVOLVIDO	26
4. Redes Neurais Artificiais e Lógica Difusa	30
4.1 REDES NEURONAIS	30
4.1.1 <i>Componentes</i>	32
4.1.2 <i>Algoritmos de treino do tipo “backpropagation”</i>	37
4.2 LÓGICA DIFUSA	43
4.2.1 <i>ANFIS – Adaptive Neural Fuzzy Inference System</i>	44
4.2.2 <i>Método de Treino</i>	48
5. Problemas Particularmente Tratados	54
5.1 CRUZAMENTO COM TRÊS RAMOS	54
5.2 CRUZAMENTO COM QUATRO RAMOS	57
5.3 ABORDAGENS COM BASE EM REDES NEURONAIS E LÓGICA DIFUSA	58
6. Experiências Realizadas	60
6.1 CRUZAMENTO 3 RAMOS EM Y	60
6.1.1 <i>Experiências com Backpropagation (LM)</i>	63
6.1.2 <i>Lógica Difusa “ANFIS”</i>	66
6.2 CRUZAMENTO 4 RAMOS	67
6.2.1 <i>Backpropagation</i>	69
6.2.2 <i>Lógica Difusa “ANFIS”</i>	69
6.3 ANÁLISE DE RESULTADOS	70
6.3.1 <i>Cruzamento 3 ramos em Y</i>	70
6.3.1.1 <i>Backpropagation</i>	70
6.3.1.2 <i>Lógica Difusa “anfis”</i>	71
6.3.2 <i>Cruzamento 4 ramos</i>	71
6.3.2.1 <i>Backpropagation</i>	71
6.3.2.2 <i>Lógica Difusa “ANFIS”</i>	72
7. Conclusões	73
7.1 TRABALHO DESENVOLVIDO	74
7.2 POSSIBILIDADES FUTURAS	74
Bibliografia	76
Anexos	79
A- DEFINIÇÕES	80
B- MIN E MAX (PREMNMX, POSTMNMX, TRAMNMX):	84
C- DADOS – CRUZAMENTO 3 RAMOS EM Y	86
D – CRUZAMENTO 4 RAMOS	88
E – CRUZAMENTO 4 RAMOS	94

Índice de Figuras

Figura 2. 1 – Ciclo de Fases	13
Figura 2. 2 – Níveis de Regulação	17
Figura 3. 1 – Enquadramento de soluções	27
Figura 4. 1 – Rede Neuronal Artificial	31
Figura 4. 2 – Neurónio Artificial	32
Figura 4. 3 – Neurónio Humano	33
Figura 4. 4 – Configuração da Rede Neuronal	34
Figura 4. 5 – Diagrama em blocos do treino supervisionado	35
Figura 4. 6 – Funções de Activação	38
Figura 4. 7 – Propagação e Retropropagação dos sinais	39
Figura 4. 8 – Raciocínio Difuso	45
Figura 4. 9 – Raciocínio ANFIS com duas entradas e duas regras	45
Figura 4. 10 – Controlador Difuso	49
Figura 4. 11 – Funções de Pertença	50
Figura 4. 12 – Desfusificação	50
Figura 4. 13 – Método do centro de Gravidade	51
Figura 4. 14 – Método das alturas	51
Figura 4. 15 – Método Média dos Máximos	52
Figura 4. 16 – Inferência com múltiplas regras	53
Figura 4. 17 - Variáveis e Termos Linguísticos	53
Figura 5. 1 – Cruzamento com 3 ramos	55
Figura 5. 2 – Cruzamento com 4 ramos	58
Figura 5. 3 – Arquitectura das ferramentas utilizadas	59
Figura 6. 1 – Cruzamento de 3 ramos	60
Figura 6. 2 – Arquitectura do treino/teste com RNAs	63
Figura 6. 3 – Treino e Teste	65
Figura 6. 4 – Arquitectura do treino/teste com LD - ANFIS	66
Figura 6. 5 – Cruzamento de 4 ramos	67

Índice de Tabelas

Tabela 2. 1 – Análise a um cruzamento	13
Tabela 2. 2 – Níveis de serviço	14
Tabela 6. 1 – Resumo das experiências efectuadas	62
Tabela 6. 2 – Treino e teste com vários Nós	64
Tabela 6. 3 – Resumo das experiências efectuadas	69
Tabela 6. 4 – Erros verificados do teste na Rede Neuronal	70
Tabela 6. 5 – Erros verificados do teste na Lógica Difusa	71

Abreviaturas

CD – Controlador Difuso

RNA – Redes Neurais Artificiais

ANFIS – Adaptive Neural Fuzzy Inference System

LD – Lógica Difusa

FIS – Sistema de Conclusão Difuso

AG – Algoritmo Genético

EQM – Erro Quadrático Médio

UTC – Urban Traffic Control

1. Introdução e Objectivos

Um dos problemas das grandes cidades, nos tempos de hoje, é o controlo do tráfego automóvel. Este problema surgiu não apenas devido ao crescimento do número de automóveis nas cidades e limitações de capacidade dos acessos existentes, mas também devido às limitações das soluções normalmente utilizadas no escalonamento e o controlo feito nos semáforos.

A utilização de semáforos nos cruzamentos e vias de circulação é utilizada como forma de coordenar e gerir o acesso a recursos com capacidade limitada (vias de circulação e cruzamentos), por parte dos utilizadores (veículos e peões). Com a sua utilização consegue-se garantir um nível de segurança elevado no acesso, e garantir-se uma repartição adequada dos recursos. Consiste basicamente em estabelecer um ciclo de funcionamento que garante tempos mínimos de acesso a todos os utilizadores, através da coordenação dos sinais luminosos envolvidos.

Apesar das vantagens que introduzem e que os tornam indispensáveis em muitas situações, a sua utilização numa forma mais básica também pode provocar situações de mau aproveitamento dos recursos, como por exemplo quando um sinal vermelho provoca a paragem de um veículo numa via de um cruzamento, mesmo que seja o único veículo presente nesse cruzamento. Um aspecto não menos importante é o de acentuar o carácter descontínuo do fluxo de tráfego, devido às paragens e arranques consequentes do ciclo de funcionamento.

A evolução tecnológica em particular ao nível de sensores, capacidade de processamento e redes de comunicação permitiu abordar a utilização de semáforos de forma a potenciar a sua utilização como forma de gerir o tráfego

de uma forma mais integrada e global em vez de apenas localizada e, por outro permitir uma maior interacção localmente com os utilizadores das vias de circulação (ex. veículos e/ou condutores).

No entanto para se poder tirar partido destas novas capacidades, os problemas associados a uma gestão mais eficiente aumentam também de complexidade exigindo novas abordagens na sua modelação e procura de soluções. A complexidade resulta por um lado do número de factores, ou variáveis a ter em conta para as condições de tráfego. Por outro lado, as decisões tomadas localmente, ao nível de um semáforo, podem condicionar a evolução do tráfego noutros locais ou cruzamentos.

Este tipo de problema pode considerar-se a um nível mais abrangente como envolvendo problemas de optimização e controlo. As limitações das soluções convencionais e o interesse em soluções mais eficientes, juntamente com o desenvolvimento nas últimas décadas de abordagens alternativas tais como Redes Neurais (*'Artificial Neural Networks – ANN'*) e Lógica Difusa (*'Fuzzy Logic'*), entre outras, tem justificado o desenvolvimento e procura de novas soluções baseadas nesses conceitos.

As Redes Neurais baseiam-se na utilização de múltiplos elementos de processamento simples, não lineares, interligados formando uma rede. O ajuste dos parâmetros da rede baseia-se normalmente na utilização, de uma forma iterativa, de um conjunto de dados representativo de ocorrências dos problemas. Estas características permitem em princípio passar para segundo plano uma formulação analítica que traduza a relação entre as diferentes variáveis e a contribuição de cada uma para o problema.

A Lógica Difusa apresenta como característica principal permitir o tratamento de valores das variáveis em classes de decisão, de uma forma que facilita a modelização da tomada de decisões com base em critérios subjectivos, característico do ser humano.

Desta forma estas soluções são naturalmente adequadas a problemas não lineares e com potencial para tratar problemas de dimensão elevada. Por outro lado a sua aplicação resulta normalmente numa abordagem casuística (*'caso a caso'*) devido à multiplicidade de alternativas na representação do problema e

na determinação ou ajuste dos parâmetros envolvidos. Deste modo existe ainda um campo considerável para estudo e desenvolvimento de soluções para os problemas associados, em particular ao controlo de tráfego urbano, o que motivou o interesse por esta área e o desenvolvimento do trabalho apresentado nesta Dissertação.

Os **objectivos principais** do trabalho desenvolvido resultaram em:

- identificar estratégias para controlo de tráfego que possam beneficiar da utilização de conceitos mais recentes, em particular Redes Neurais e Lógica Difusa;
- desenvolver e testar soluções que possam ser incorporadas nas estratégias identificadas.

Com base na análise ao estado actual de desenvolvimento e pesquisa de soluções para este problema, o trabalho concentrou-se num problema particular da previsão de fluxos de tráfego nas vias de ligação aos semáforos, com base em Redes Neurais do tipo “*Backpropagation*” e soluções híbridas baseadas em Lógica Difusa e Redes Neurais “*ANFIS*”. Utilizaram-se dados reais de fluxos de tráfego, relativos a dois tipos de cruzamentos, e o programa de computador MatLab® como plataforma de desenvolvimento e implementação das soluções.

Os resultados obtidos permitem verificar a facilidade em obter soluções adequadas tendo em conta tendências ou valores médios das variáveis, mas também na dificuldade em obter soluções para modelar com um grau de eficiência elevado o comportamento discreto associado à evolução do fluxo de tráfego.

O trabalho efectuado organiza-se nos restantes 7 capítulos, apresentando-se no capítulo seguinte – Cap. 2, uma caracterização mais aprofundada dos problemas associados ao tráfego urbano e a utilização de semáforos, juntamente com as soluções mais utilizadas e as soluções em desenvolvimento.

No capítulo 3 apresenta-se a estratégia para controlo de tráfego, e uma formulação dos problemas a abordar com Redes Neurais e Lógica Difusa. O capítulo seguinte – Cap. 4, apresenta os fundamentos de Redes Neurais e

Lógica Difusa e uma perspectiva da sua utilização como solução para os problemas identificados.

O capítulo 5 apresenta os casos particulares de dois cruzamentos considerados, e a modelação do problema de previsão de variáveis associadas a fluxos de tráfego utilizando Redes Neurais e Lógica Difusa (ANFIS).

No capítulo 6 são descritas as experiências realizadas e analisados os seus resultados.

Por fim no capítulo 7 apresentam-se as conclusões e perspectivas de trabalho futuro.

2. Gestão de Tráfego Urbano e Controlo de Semáforos

Numa perspectiva actual a utilização de semáforos em cruzamentos deve ser encarada como parte de um problema mais global de gestão de tráfego, envolvendo várias zonas de um perímetro urbano. Neste capítulo apresenta-se um enquadramento do problema de controlo de semáforos no problema mais global de gestão de tráfego urbano. Desde uma caracterização dos problemas envolvidos e sua interligação, terminologia e soluções correntes, até às soluções mais avançadas e perspectivas de desenvolvimento.

2.1 Gestão de tráfego

O crescimento do número de automóveis em circulação coloca vários tipos de problemas, em particular em grandes centros urbanos. A tendência para o crescimento do número de veículos em circulação é fácil de justificar devido ao conforto e vantagens associados à sua utilização como meio de transporte, juntamente com a sua disponibilidade que facilita uma utilização quase, ou frequentemente, individual. Contudo também são facilmente constatáveis os problemas de trânsito, em particular nas horas de maior circulação ou “*horas de ponta*” a que muitos de nós estamos habituados. O desperdício de tempo provocado pelos atrasos devidos aos congestionamentos de trânsito, juntamente com a poluição ambiental provocada e os efeitos psicológicos

resultantes da exposição a estas situações têm justificado numerosos esforços no sentido de resolver ou minimizar estes problemas.

Algumas soluções abordam o problema forçando a redução do número de veículos em circulação e criando melhores alternativas com base em transportes públicos. Outras soluções consistem em explorar a possibilidade de aumentar a capacidade das infra-estruturas de circulação, como por exemplo recorrendo ao desnivelamento de passagens ou túneis, novos acessos e alargamento de vias.

Para além destas soluções o recurso a novas tecnologias permite ainda considerar a possibilidade de melhorar a eficiência do sistema através duma melhor gestão do tráfego, mesmo que não implicando alterações às infra-estruturas. Esta abordagem implica a possibilidade de conhecer o comportamento do tráfego, medindo ou observando os parâmetros que o caracterizam, poder actuar sobre ou influenciar o seu comportamento, com base em decisões que se justifiquem tendo em conta medidas de eficiência e objectivos a atingir.

Em relação a medidas de eficiência e objectivos a questão pode colocar-se a vários níveis e relativamente a vários objectivos. Por um lado podemos ter o interesse particular de cada condutor ou veículo, ou outro tipo de utilizador como os “peões”, de um conjunto de veículos que utilizam uma dada via ou cruzamento, de um conjunto de vias e cruzamentos associados a uma zona, ou áreas mais abrangentes como perímetros urbanos. Por outro lado podemos considerar diferentes objectivos a atingir, como por exemplo minimizar tempos de espera, ou de passagem pelas vias de circulação, minimizar gastos de energia, minimizar e resolver situações de congestionamento, aumentar níveis de segurança, etc. Teremos ainda que considerar que vários factores podem influenciar as condições de tráfego, muitos deles imprevisíveis como por exemplo a ocorrência de acidentes. Outros de carácter mais sazonal que se traduzem por fluxos de tráfego maiores a determinadas horas do dia (ou dias, meses), a necessidade de contemplar diferentes tipos de veículos (ex. prioritários, transportes públicos), condições ambientais de circulação (ex.

chuva), condições físicas das infra-estruturas (número de vias, declives, rotundas, cruzamentos, ...).

Relativamente à capacidade de conhecer e quantificar o comportamento do tráfego e actuar sobre os seus elementos a evolução tecnológica continua a trazer importantes contribuições desde a introdução de semáforos em cruzamentos. Hoje são frequentes exemplos de sistemas de gestão de tráfego [1] em funcionamento que se baseiam na utilização de câmaras de vídeo e sistemas de visão, sistemas baseados em sensores (ex. indutivos) para detectar e subseqüentemente permitir a contagem do número de veículos que passam em determinado ponto, e na utilização de redes de comunicação para transmissão dessa informação permitindo tomadas de decisão de uma forma global e centralizada que normalmente se traduzem em actuar sobre os ciclos de funcionamento dos semáforos. O passo seguinte será a capacidade de interacção directa entre cada veículo e o sistema, por exemplo ao nível dos semáforos para identificação de destinos pretendidos. Apesar destas possibilidades de automatização não devemos esquecer as soluções menos automatizadas e com benefícios comprovados como por exemplo a utilização de canais de rádio com informação específica sobre as condições de trânsito baseada na recolha de dados directamente (ex. veículos; helicópteros) nos locais de circulação. Mais recentemente a utilização do Sistema de Posicionamento Global (*'GPS-Global Positioning System'*) combinado com informações detalhadas para navegação vem alargar estas possibilidades de interacção e coordenação dos veículos e sistema de gestão de tráfego.

Ainda na caracterização geral de sistemas de tráfego é de realçar que mesmo ao nível da interpretação dos dados recolhidos e tomada de decisões a componente “humana” é ainda um elemento essencial em muitos sistemas. Por um lado como forma de garantir a segurança do sistema, por outro pela dificuldade em desenvolver soluções 100% automáticas.

Tendo em conta estas considerações poderemos classificar o problema de optimização em causa como de elevada complexidade pelo número de variáveis envolvidas e pelo carácter dinâmico do sistema. A dimensão do problema e o tipo de variáveis envolvido dificulta uma abordagem baseada

numa formulação analítica e respectivo tratamento matemático. Consequentemente torna natural uma procura de soluções baseadas em regras ou heurísticas, como exemplo Redes Neurais, Lógica Difusa, Algoritmos Genéticos, e muitas outras [2], [3], [4].

Neste enquadramento a utilização de semáforos aparece reforçada como um elemento fundamental de regulação num sistema de Gestão de Tráfego, uma vez que os seus estados de funcionamento podem resultar das decisões tomadas a um nível global e no limite em tempo real.

2.2 Controlo de semáforos

Na sua forma mais elementar o controlo de semáforos consiste em estabelecer um ciclo de funcionamento que garante tempos mínimos de acesso a todos os utilizadores dos recursos, através da coordenação dos sinais luminosos envolvidos. Colocado desta forma o problema parece simples, no entanto basta considerar as diferentes tipologias e características físicas possíveis para cruzamentos, juntamente com variações ao nível dos volumes e tipos de tráfego para justificar a necessidade de utilizar procedimentos e métodos [5] que permitam chegar a soluções adequadas.

2.2.1 Regulação de tráfego com recurso a semáforos

As regras de atribuição de prioridade convencionais dos códigos da estrada, apesar de resolverem os conflitos na utilização de cruzamentos, introduzem perdas significativas, pelo facto de levarem a frequentes paragens e arranques dos veículos. A solução consistiu em reduzir a frequência das paragens dos veículos, introduzindo um mecanismo de atribuição de recursos. Os semáforos mais simples atribuem a utilização do cruzamento a conjuntos de vias, que não entram em conflito, de forma cíclica.

Os semáforos de período fixo melhoram o fluxo automóvel, mas pecam pelo facto de lhes ser impossível adaptarem-se a alterações no volume de tráfego

proveniente de cada uma das vias. Não é possível definir um conjunto de tempos para os estados de um semáforo, que seja óptimo para todas as cargas possíveis das vias que confluem no cruzamento.

A evolução consistiu em criar semáforos, cujos tempos evoluem ciclicamente ao longo de um período fixo (normalmente um dia), de forma a adaptar o semáforo às variações cíclicas da carga de tráfego em cada uma das vias que fluem no cruzamento.

Estes semáforos exigem uma colecção dos dados, tratados estatisticamente, sobre o volume de tráfego nas vias de uma rede viária, de forma a definir um padrão do tráfego, que possa ser utilizado para a programação.

Os cruzamentos semaforizados caracterizam-se pela atribuição de diferentes períodos de tempo, do direito de entrada no cruzamento aos diferentes movimentos de tráfego, sendo evitados os conflitos entre veículos e entre veículos e peões, o que se traduz num aumento da segurança. Trata-se de um tipo de solução flexível que permite atribuir qualquer correlação de prioridades relativas entre os diferentes movimentos do cruzamento, evitando assim movimentos considerados incompatíveis na mesma fase.

Uma fase representa o estado do sinal luminoso durante o qual uma ou várias correntes de tráfego têm direito de avançar, estando as outras impedidas de o fazer. É identificada quando no início pelo menos uma corrente de tráfego ganha o direito de passagem e no seu fim pelo menos uma corrente de tráfego perde esse direito [6].

Um ciclo de fases é uma sequência de fases que termina quando a primeira fase se repete. O tempo de ciclo corresponde ao tempo necessário para completar um ciclo e a unidade de tempo é o segundo. Um ciclo de fases tem incluído um intervalo de tempo em que o vermelho se encontra aceso para todas as fases, é o chamado “Tudo-vermelho”. O tempo em que a intersecção não está a ser utilizada por nenhum dos movimentos é designado como “Tempo perdido”.

Num cruzamento, o volume de tráfego é o número de veículos que circulam num determinado ponto da via durante um intervalo de tempo, assim como, o

fluxo de saturação é o fluxo máximo que pode atravessar uma dada intersecção, sob as condições existentes, admitindo que aquele grupo de pistas dispõe de 100% de tempo de verde, e definido em $\text{veíc./h}_{\text{verde}}$, *veículos por hora de verde*.

O “temível” trânsito é um problema do quotidiano a que nos habituamos de tal forma que raramente se analisa em profundidade. Mas, sendo ele o objecto de estudo, vai ser analisado e descrito de uma forma mais objectiva. Os veículos e os peões são os intervenientes dinâmicos enquanto que as infra-estruturas como a estrada, a auto-estrada, rotundas, entre outros são os estáticos. No anexo A – Definições, encontram-se alguns conceitos utilizados no tema aqui tratado.

As combinações possíveis de situações são de tal forma elevadas que vamos limitar as hipóteses para o estudo apenas ao trânsito urbano. A regulação será apenas os mecanismos baseados em semáforos.

A Norma Portuguesa (JAE P5/90) faz referência aos objectivos da regulação após uma análise às condições operacionais que se verificam nas intersecções e às necessidades funcionais do seu traçado:

- Desencorajar, ou proibir, os movimentos indesejáveis ou errados;
- Definir claramente as trajectórias que os veículos devem seguir;
- Encorajar as velocidades convenientes;
- Separar no espaço os pontos de conflito tanto quanto possível;
- Assegurar que o cruzamento das correntes de tráfego se efectue de uma forma aproximadamente ortogonal e as convergências segundo ângulos muito agudos;
- Facilitar o movimento das correntes de tráfego prioritárias;
- Assegurar a desaceleração e a paragem dos veículos fora das vias utilizadas pelo tráfego directo, que geralmente circula a velocidade elevada.

Os cruzamentos semaforizados são uma tipologia muito utilizada devido à sua grande flexibilidade e adaptabilidade às condições locais e às características do tráfego só comparável ao das rotundas.

O “Manual on Uniform Traffic Control Devices” [7] estipula 8 critérios que devem ser considerados e que justificam a instalação de sinais luminosos em cruzamentos. Esses critérios são os seguintes:

- Volume de veículos em 8 horas;
- Volume de veículos em 4 horas;
- Tráfego na hora de ponta;
- Volume de peões;
- Travessia de peões junto a escolas;
- Sistemas de coordenação de sinais luminosos;
- Sinistralidade;
- Gestão da rede rodoviária.

A instalação de sinais luminosos num determinado cruzamento apenas deve ser considerada se pelo menos um destes critérios de instalação for satisfeito, caso contrário deve-se optar por outras tipologias. No entanto, o cumprimento de um ou mais critérios não significa, por si só, a obrigatoriedade de instalação de sinais luminosos, mas é uma solução a ponderar para a regulação do tráfego no cruzamento em estudo.

Normalmente, é definido um indicador que permite avaliar o desempenho das diferentes tipologias consideradas. A escolha recai no valor médio do atraso por veículo, uma vez que é este o indicador proposto na última edição do “*Transportation Research Board*” [8] para a definição do nível de serviço em cruzamentos.

O objectivo na gestão de tráfego é garantir que a capacidade da rede rodoviária seja utilizada ao máximo. Para o efeito têm de ser combinados três tipos de serviço:

- Coordenação de semáforos, para minimizar os atrasos e controlar as filas de espera dos veículos;
- Controlo de ramais de acesso às vias rápidas e auto-estradas;
- Detecção e gestão de imprevistos.

Segundo o Highway Capacity Manual [9], o nível de serviço é uma medida qualitativa de caracterização das condições de operação de um determinado elemento da estrada. São definidos 6 níveis de serviço (A, B, C, D, E e F)

sendo que o nível de serviço A corresponde às melhores condições de operação (livre circulação) e o nível de serviço F às piores (congestionamento).

Em relação à capacidade, é uma solução que apresenta grandes potencialidades, semelhantes às atingíveis pelas rotundas. No entanto, existe uma maior dificuldade no tráfego de viragem à esquerda, principalmente se o tráfego for significativo, o que exigirá a criação de uma fase especial.

Os prenúncios do aparecimento dos congestionamentos são:

- Aumento dos atrasos;
- Aumento custo da operação (Viagem);
- Aumento da poluição;
- Aumento do stress do condutor;
- Aumenta a probabilidade de ocorrer acidentes.

A capacidade de uma intersecção semaforizada é baseada no conceito de fluxo de saturação. Entende-se, como a capacidade de um determinado movimento, em termos do fluxo máximo admissível desse movimento num intervalo de tempo sob determinadas condições de tráfego, características geométricas e de sinalização.

A Tabela 2. 1 resume a abordagem que é feita numa análise às características de um cruzamento.

Características	Parâmetros
Geométricas	Tipo de área
	Número de pistas
	Largura das pistas
	Inclinação longitudinal
	Existência de pistas exclusivas (VE ou VD)
	Comprimento das pistas de armazenamento
	Existência de estacionamento

Tráfego	Volumes por movimentos (veic./h)
	Factor de ponta horária
	Percentagem de veículos pesados
	Volume de peões em conflito (peões/h)
	Número de autocarros/h com paragem no local
	Actividade de estacionamento (estac./h)
De sinalização	Comprimento do ciclo (seg.)
	Tempo de verde (seg.)
	Actuado/tempo fixo
	Botão para peões
	Tempo mínimo de verde para peões
	Plano de fases

Fonte: Highway Capacity Manual

Tabela 2. 1 – Análise a um cruzamento

Quando é feita uma análise a um cruzamento e não estando disponíveis alguns dos dados da Tabela 2. 1, é possível recorrer a valores parametrizados em Highway Capacity Manual [9].

O tema da regulação de sinais luminosos é estudado para otimizar o fluxo do cruzamento ou zona. É usual definir-se uma sequência de fases representando-o num diagrama como ilustra a Figura 2. 1.




Figura 2. 1 – Ciclo de Fases

O nível de serviço é definido em tempo médio de atraso para um período de 15 minutos. Este tempo de atraso é uma causa do desconforto originado ao condutor, do consumo de combustível excessivo e tempo perdido na viagem.

Na Tabela 2. 2 mostra os seis níveis de serviço.

Nível de serviço	Tempo de atraso (seg./veíc.)
A	$\leq 5,0$
B	5,1 a 15,0
C	15,1 a 25,0
D	25,1 a 40,0
E	41,1 a 60,0
F	$> 60,0$

Fonte: Highway Capacity Manual

Tabela 2. 2 – Níveis de serviço

Nível de Serviço A - Situação em que os atrasos são muito pequenos (menores que 5 segundos por veículo) ocorre quando a progressão é muito favorável e a maioria dos veículos chega durante o verde, nem sequer tendo que parar. Tempos de ciclo curtos contribuem para tempos de atraso curtos.

Nível de Serviço F - Este nível de serviço apresenta tempos de atraso superiores a 1 minuto por veículo o que é considerado inaceitável pela maioria dos condutores.

O atraso sofrido por veículos depende de diversos factores relacionados com o tipo de controlo do cruzamento, a sua geometria e os volumes de tráfego que aí circulam. O atraso sofrido por um veículo corresponde à diferença de tempo entre o tempo real do percurso e o tempo que decorria no caso de ser percorrida em condições livres de qualquer perturbação provocada pela existência do cruzamento. O valor do atraso inclui o tempo de desaceleração do veículo, o da fila de espera, o tempo parado e o de aceleração.

No caso dos cruzamentos com sinais luminosos, existe a necessidade de estabelecer um conjunto de parâmetros para a regulação dos sinais luminosos e conseqüente plano de regulação. Assim, os parâmetros considerados são os seguintes:

- Tempo de verde útil mínimo para cada corrente de tráfego – 6 segundos;
- Tempo máximo para a duração do ciclo – 100 segundos;
- Tempo de interverde – 5 segundos, dos quais 3 segundos de amarelo e 2 segundos de “tudo-vermelho”;
- Incremento no tempo de duração do ciclo – 1 segundo;
- Débito de saturação base – 1800 veíc./h;
- Grau de saturação máximo aceitável – 0,9.

2.2.2 Regulação de tráfego centralizada

O controlo com o recurso aos semáforos pode ser feito numa escala micro ou macro-controlo. Se for um único cruzamento a ser controlado, onde as variáveis só dizem respeito ao próprio, então estamos a falar de um micro-controlo. O macro-controlo é feito a uma dada zona da cidade, sendo possível coordenar um sistema de vários cruzamentos com o intuito de proporcionar um escoamento homogéneo diminuindo o número de paragens e consequentemente os atrasos. Essa coordenação pode ser realizada de duas formas distintas, são elas:

- 1 – Coordenação de cruzamentos semaforizados existentes ao longo de um Itinerário ou eixo, criando as chamadas “ondas verdes”;
- 2 – Tratamento de cruzamentos recorrendo a Sistemas de Controlo de Tráfego do tipo UTC – *Urban Traffic Control*.

Nos sistemas do tipo UTC, existe uma central a partir da qual são lançados os vários planos de regulação que melhor se ajustam às condições de tráfego existentes na zona controlada pelo sistema [1].

O custo de investimento é moderado e o de exploração tem vindo a diminuir em relação às restantes tipologias (cruzamento sem sinais luminosos, rotundas, cruzamento desnivelados).

No que respeita ao espaço viário, são soluções que necessitam de menos espaço do que as rotundas – têm uma capacidade de controlo idêntica. Essa vantagem, perante as rotundas, origina uma maior utilização nos cruzamentos

devido à flexibilidade da configuração e ocupação do solo na adaptação às condições locais.

A metodologia aplicada nos cruzamentos semaforizados tem vantagens, por exemplo, o espaço mínimo necessário em locais com forte ocupação do solo, flexibilidade para responder a diferentes condições de tráfego, ajusta-se às necessidades dos peões com melhor qualidade e tem a possibilidade de coordenação com outros cruzamentos semaforizados – Macro-controlo;

No entanto esta metodologia também apresenta algumas desvantagens, como o aumento do atraso e custo de operação em condições não saturadas, principalmente se a regulação for de tempos fixos (pouco flexível) , o risco de acidente em colisões frente-traseira é maior devido à transição do verde para o vermelho, o que obriga à travagem dos veículos e impossibilitam os veículos de efectuarem manobras de inversão.

Numa cidade desenvolvida, a regulação do tráfego urbano desempenha um papel fundamental uma vez que permite explorar a rede de uma forma dinâmica.

A regulação dos sinais luminosos pode ser efectuada em três níveis, ver Figura 2. 2:

1. Nível local – gestão de um cruzamento isolado:

Consiste na definição do tempo de verde, assim como, o diagrama de fases, sendo fixado os períodos de transição entre fases sucessivas. Neste nível é possível estabelecer dois tipos de regulação, por tempos fixos ou actuados pelo tráfego – micro-regulação.

Na micro-regulação há uma preocupação em ajustar o tempo de verde à procura. Através de sensores, colocados estrategicamente no cruzamento, é comunicado ao controlador a chegada dos veículos. O sistema também pode interagir com os pedidos dos peões.

Se o fluxo de tráfego é previsível ao longo do tempo, então, é aconselhado o controlo através da multi-programação em tempos fixos.

Se os fluxos são instáveis com variações muito acentuadas, então, é preferível recorrer à micro-regulação.

2. Nível intermédio – coordenação dos cruzamentos ao longo de um eixo ou itinerário, podendo ser criada a onda verde;

3. Nível global – coordenação dos cruzamentos de uma zona – macro-regulação. Com o recurso a um centro de controlo constituído por um ou vários computadores centrais que recebem informação em tempo-real e por recursos humanos. Estes dois recursos complementam-se porque apesar de toda a capacidade do sistema implementado ainda não consegue prescindir da componente humana para solucionar os imprevistos.

Não é suficiente uma micro-regulação ser eficaz quando o cruzamento controlado está próximo de outros. É necessário haver uma coordenação entre os mesmos. O ritmo de chegada dos veículos a um cruzamento é influenciado pelas intersecções adjacentes e também vão influenciar os subjacentes. Nestes casos, é imperativo a coordenação dos sinais luminosos a um nível intermédio - privilegiando o percurso mais importante em detrimento dos secundários ou um “controlo por artérias” – onde se considera o mais importante a área a coordenar.

Estes planos podem ter tempos fixos, previamente estudados com base em dados recolhidos ou gerados em tempo real com base em dados obtidos por detectores colocados estrategicamente.

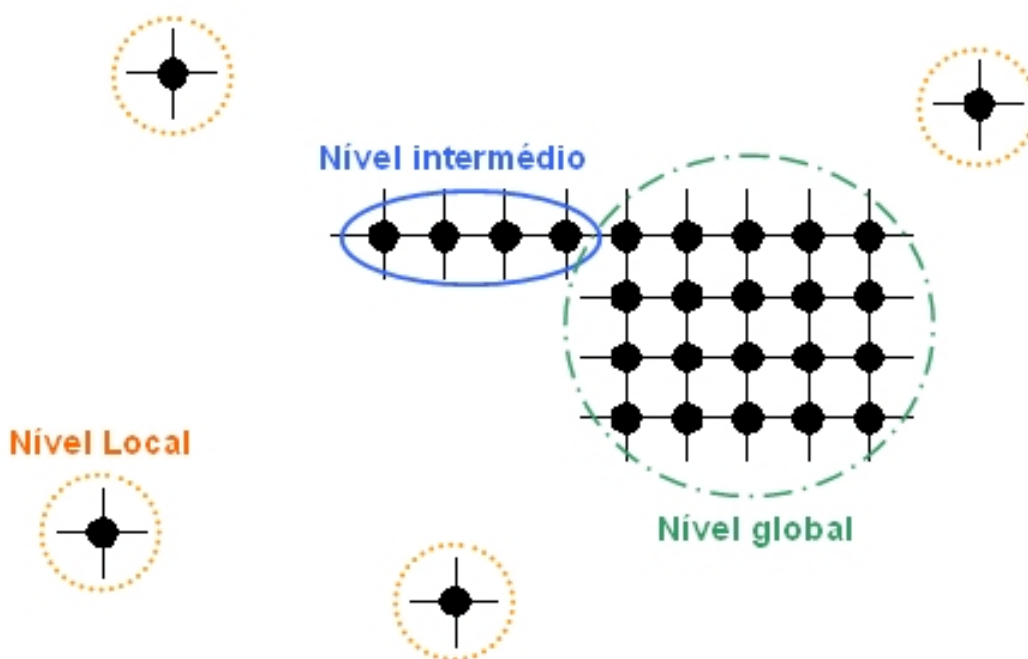


Figura 2. 2 – Níveis de Regulação

O princípio da onda verde é simples de se entender e de fácil aplicação quando se fala em vias de sentido único. Para itinerários de dois sentidos torna-se mais complexo. Devido a este facto, é aconselhado recorrerem a um programa de cálculo, tal como, TRANSYT (TRRL), MAXBAND (FWHA), TALLON (CETUR), entre outros, para ajudar na tarefa de implementação da onda verde [1].

Apesar das políticas de desincentivação ao uso de veículos particulares, do aumento do custo de operação, duma melhor oferta dos transportes colectivos, o que tem vindo a acontecer é um aumento do número de veículos nas cidades e por consequência maiores tempos de espera. Para se fazer frente a esta tendência, é imprescindível haver um controlo eficaz. O controlo por zonas encontra-se bastante expandido nas grandes cidades devido à complexidade das redes e do número de cruzamentos sinalizados.

Os sistemas UTC¹, começaram a ser desenvolvidos e instalados na década de 60. O sistema era constituído por um computador Digital com um disco para armazenamento de dados, com capacidade de processamento dos dados provenientes de subestações, OTU². Este tipo de equipamento era apenas instalado nas grandes cidades, onde a densidade de sinais luminosos justificasse o investimento porque o equipamento era específico e os recursos humanos eram especializados.

A evolução tecnológica originou uma maior eficiência no sistema e uma redução de custos na implementação destes sistemas.

Deste modo o campo de aplicação alarga-se para as cidades menos densas.

Um sistema centralizado de controlo de tráfego clássico é composto por:

- uma central que assegura a coordenação de todo o conjunto de sinais luminosos:

- uma rede de comunicações que assegura o sistema de informação entre o posto central e os controladores locais;

¹ UTC – Urban Traffic Control

² OUT – Outstation Transmission Units

- em alguns casos, controladores de zona coordenam um conjunto de sinais luminosos, sem recurso à central.

No posto central é utilizado um painel sinóptico que tem como funcionalidade auxiliar os operadores. A informação fornecida é indispensável para uma boa operação do sistema. Normalmente os equipamentos são monitorizados e também é possível visualizar informações complementares, tais como:

1. nível de manutenção – defeitos de funcionamento dos equipamentos;
2. nível de circulação – débitos, taxas de ocupação, etc.;
3. nível de exploração – n.º do plano em curso.

Os centros de controlo são equipados de consolas para:

1. poder implementar manualmente os planos de regulação;
2. controlar remotamente as câmaras instaladas no terreno;
3. controlar os monitores de televisão.

No que diz respeito ao modo de operação pode-se configurar três situações diferentes:

1. central – o controlador recebe ordens do computador central;
2. local – o comando é gerado pelo próprio controlador;
3. manual – os sinais vão-se sucedendo, segundo o diagrama, através da pressão de um botão.

Para ajudar na medição das variáveis de circulação são instalados no terreno sensores. Eles são sensíveis à grandeza física que se pretende medir – presença e passagem de veículos ou peões, informando através de um sinal ao detector. O detector é um dispositivo electrónico cuja funcionalidade é analisar a informação recebida do sensor e codificá-la para enviar a mensagem ao controlador [1].

Na abordagem aos sensores convém referir os dois tipos distintos:

1. sensores para a micro-regulação;
2. sensores para a macro-regulação.

Os primeiros são colocados próximos dos sinais luminosos em todas ou quase todas as vias. Os segundos dependem do tipo de sistema

implementado, mas geralmente são colocados nas vias principais, nas intercepções críticas e nos locais de geração de tráfego.

As chamadas espiras – sensores indutivos, têm objectivos diferentes consoante a posição onde são colocadas. Essa localização depende muito da geometria do cruzamento.

Para a validação do sistema são utilizadas câmaras de vigilância. Assim é possível a visualização de perturbações que tenham surgido sem se verificar uma situação de fenómeno de saturação. Assim sendo não se justifica a entrada de um plano de regulação específico para o efeito. As câmaras são dispostas de forma a visualizar pelo menos uma parte do cruzamento.

O sistema de câmaras está ligado numa rede de televisão em circuito fechado.

2.2.3 Exemplos de sistemas de regulação

O problema do controlo de tráfego foi evoluindo devido ao crescimento da população, da conjuntura económica e muitas outras causas. Tal como o problema, a solução também foi tendo a sua evolução. Apesar dos sistemas terem sido desenvolvidos em países diferentes, eles têm alguns pontos em comum. Por exemplo, os sistemas têm uma central de controlo, equipada com um computador que está ligado numa rede a outros computadores locais que recebem informação dos detectores. O objectivo é receber informação do tráfego do cruzamento e armazenar. A decisão é feita através da central, com o recurso ao computador ou manualmente por um funcionário com o auxílio de um painel sinóptico ou câmaras de vídeo. Os planos de regulação são calculados em “off-line” e guardados para serem utilizados quando as condições de tráfego assim o “exigirem”, com o intuito de minimizar a tempo de espera ou o número de paragens dos veículos. A preparação dos planos pode ser baseada com recurso a simuladores, por exemplo, o SIDRA. Os sistemas de regulação que se encontram nestes padrões, sem recurso a simuladores, são TraNSyT, *Traffic Network Study Tool*, implementado em Londres, o ETRA em Espanha e o PRODYN, *Programmation Dynamique* de França. O SCAT, *Sydney Co-ordinated Adaptive Traffic* desenvolvido na Áustria, actua na

duração do ciclo, nos tempos de verde e no desfasamento entre intersecções adjacentes. Os micro-computadores têm poder de decisão para controlar o cruzamento onde estão instalados.

O SCOOT, (Split Cycle and Offset Optimization Technique), já tem a capacidade de fazer previsões do tráfego na rede e determina os atrasos e paragens face ao plano de regulação. Também está equipado com um sistema para verificar se há alguma anomalia nos detectores. O SIGA, Sistema Inteligente de Gestão Autónoma, implementado em Portugal tem dois sistemas de controlo distintos. Um para ser utilizado quando a circulação é fluida, então a estratégia tem por base um conjunto de planos de regulação para zonas individuais. O outro é utilizado quando é detectada saturação, são aproveitadas zonas para fazer filas de espera com o intuito de manter fluida a circulação em geral.

Os objectivos na criação deste sistema são, melhorar as condições de escoamento nos períodos de ponta, dar prioridade absoluta aos veículos de emergência, facilitar a circulação dos veículos de transporte público, solucionar o congestionamento da área central e também das artérias mais críticas da rede viária, aumentar a segurança rodoviária.

Os planos de regulação são calculados previamente e aplicados em função aos dados recebidos dos detectores colocados estrategicamente. A transição dos planos é realizada através de uma variação do ciclo de 5 segundos até se alcançar o ciclo desejado.

Relativamente aos transportes públicos, foram criadas pistas exclusivas nas artérias com capacidade de “armazenar” os veículos. A abertura do sinal verde é dado com alguns segundos de antecedência para os veículos públicos arrancarem primeiro.

A avaliação do sistema pode ser feito por dois métodos distintos:

no primeiro, é feita uma comparação entre as variáveis armazenadas antes e depois do sistema de regulação. No segundo, recorre-se a um veículo equipado que permita o registo das distâncias percorridas e respectivos tempos, nas condições normais de tráfego. Com o recurso a um veículo teste também é possível calcular os consumos e as emissões poluentes.

3. Estratégias para Gestão de Tráfego

Apesar da evolução verificada no desenvolvimento de sistemas mais eficientes para a gestão de tráfego ainda existem muitos aspectos ou problemas não totalmente resolvidos. A dimensão e complexidade destes problemas podem associar-se ao elevado número de variáveis em causa, à dificuldade em definir a relação entre essas variáveis e ao carácter dinâmico do sistema. Sendo ainda problemas em aberto justifica-se a consideração das várias ferramentas disponíveis para a sua abordagem desde formulações analíticas, métodos estatísticos ou métodos alternativos, mais recentes que dispensam uma formulação analítica do problema.

Neste capítulo aborda-se a aplicação desses métodos, como redes neuronais, lógica difusa e algoritmos genéticos que permitem ultrapassar algumas das limitações da formulação analítica dos problemas, verificando-se um elevado número de trabalhos desenvolvidos ou em curso.

Nestes trabalhos destacam-se soluções híbridas, combinando a utilização de várias técnicas, para os problemas sendo útil englobá-las numa estratégia para a gestão de tráfego. Permitindo desse modo o enquadramento dos vários problemas e tirar partido das características particulares de cada técnica, não só numa perspectiva localizada do problema mas também a um nível mais global da gestão de tráfego.

3.1 Sistemas Inteligentes

Os sinais luminosos são um elemento imprescindível para o controlo eficaz do tráfego. Este problema pode ser abordado e solucionado de várias formas distintas, como explicado anteriormente. Após uma pesquisa feita na área das

técnicas de IA, como sistemas peritos (*Expert Systems*), Lógica Difusa, Redes Neurais Artificiais e Algoritmos Genéticos, constata-se que já existem muitos trabalhos desenvolvidos.

Pappis and Mandani [10], em 1977, desenvolveram o controlo duma intersecção de tráfego isolada, com os sentidos únicos de Este para Oeste e Norte para Sul com a chegada dos veículos aleatória recorrendo ao controlador de LD. Mais tarde Pedrycz e Gomide [11] e Trabia [12] deram continuidade ao trabalho desenvolvido por Pappis e Mandani. Nakatsuyama [13] recorreu à Lógica Difusa para modelar o controlo de duas intersecções adjacentes com movimento de sentido único, Kelsey and Bisset [14], fazem o controlo do tráfego simulado com intersecções isoladas de Norte/sul e Este/Oeste enquanto que Chiu [15], utilizou a mesma ferramenta para controlar uma rede viária de intersecções múltiplas com ruas de dois sentidos e mais tarde com Chand [16], publicam que num contexto de rede, a LD pode ser usada para calcular o tempo de ciclo, podendo ser aumentada, reduzida ou compensada. Tzes [17], com o sistema de controlo também determina quando é requerida coordenação de junções para aliviar o tráfego em intersecções críticas. Hoyer e Jumar [18], tal como Zhou identificam e reconhecem certos padrões de fluxo de tráfego, permitindo assim definir o tempo dos sinais adaptáveis às situações do tráfego. Niittymäky e Pursula [19], investigaram o Controlo Difuso em semáforos ao nível da intersecção individual.

Com o recurso às RNAs, Pomerleau [20] escreveu sobre Visão e Navegação. Em relação aos sistemas peritos, Niehaus e Stengel [21] trabalharam no sistema perito para condução automatizada num itinerário; Maskarinec [22] cria um sistema perito para evitar acidentes para automóveis autónomos numa via; Richie e Prosser [23] criaram um sistema perito em tempo real para controlo de acidentes na auto-estrada. Aplicações com controladores lógicos difusos existem publicados por Freisleben e Kunkelman [24] uma combinação entre LD e RNAs para controlar veículos autónomos; Von Altrock, Krause e Zimmerman [25] estudaram tecnologias de controlo de LD aplicadas em automóveis com RNAs para controlar os veículos autónomos. Favilla, Machion e Gomide [26] fizeram o controlo do tráfego com recurso a

estratégias adaptáveis dos Sistemas Difusos. Sugeno e Murakami [27] escreveram sobre controlo de estacionamento de automóveis. Chiu e Chand [28] fizeram o controlo adaptativo do semáforo com LD.

Trabalhos mais recentes mostram que soluções baseadas em IA continuam a ser objecto de estudos e trabalhos nesta área.

Em Outubro de 2001 M. Patel e N. Ranganathan [29] propõem um método inteligente de tomadas de decisão de controlo para o tráfego urbano em tempo real onde utilizam as RNAs e a LD como base do sistema. As RNAs tomam decisões com base na aprendizagem de exemplos antecedentes enquanto que os sistemas peritos seguem uma base de conhecimento desenvolvida pelo raciocínio humano para a tomada de decisão. Este sistema tem como base o algoritmo “backpropagation” das RNAs que consegue aprender a adaptar-se dinamicamente ao ambiente e um sistema perito Fuzzy para tomar decisões.

A nível de hardware no cruzamento, são utilizados sensores para contar/detectar os veículos à chegada do cruzamento em estudo. Também têm alguns sensores, colocados estrategicamente, em algumas saídas do cruzamento. Como o sistema de controlo foi ao encontro das expectativas, em algumas saídas não foram colocados sensores uma vez que o sistema prevê a passagem do número de veículos nesse sentido. Este estudo trabalha com dados recolhidos de 15 em 15 min e o seu objectivo é controlar o tempo de verde em tempo-real consoante as necessidades locais. Como resultado, o atraso médio por veículo diminuiu e as filas de espera também foram reduzidas. Neste documento é claro que existem objectivos que não são compatíveis, por exemplo, atraso médio por veículo, a segurança e o ambiente. É difícil encontrar o óptimo dos três, por exemplo, para obter o óptimo em relação ao ambiente e à segurança o atraso médio por veículo é 40% maior. Para encontrar o óptimo entre estes três interesses utilizaram o MOGA³. O MOGA baseia-se nas técnicas de optimização no princípio da evolução natural e é seu objectivo encontrar uma solução que seja óptima para todos os interesses. Neste trabalho é demonstrado que a combinação de várias técnicas da IA vêm potenciar o que cada uma tem de melhor.

³ MOGA – Multi-objective genetic algorithms.

Em Novembro de 2001, Wu Wei e Mingjum Wang [3] apresentaram um método de controlo adaptável baseado na LD com recurso às RNAs para uma intercepção de 4 aproximações isoladas a um cruzamento. Este método tem capacidade para fazer ajustes ao tempo dos sinais com respeito a mudanças observadas. Usando três modelos com níveis diferentes baseados na “Neural-Fuzzy”, pode-se determinar se é necessário modificar a fase actual e seleccionar a sequência da mesma.

É atribuído um grau de urgência a cada veículo que se aproxima do cruzamento cuja caracterização, na LD, é “Pequeno”, “Médio” e “Grande”.

O cruzamento está instrumentado com alguns sensores colocados estrategicamente, cuja informação é combinada com a obtida com recurso à previsão das filas de espera. Assim é possível controlar o cruzamento, com base nas previsões das variáveis de saída, com um escalonamento mais eficaz. Como variáveis conhecidas temos a chegada dos veículos e também uma saída do cruzamento. Como existem três hipóteses de saída do cruzamento, uma é contada pelo sensor, a outra é prevista e a última é calculada pela diferença. Estes cálculos e medições são efectuados em intervalos de 15 min.

Os resultados da simulação mostram que o controlador tem capacidade para ajustar os tempos com respeito às condições de tráfego em tempo real e o tempo de atraso é menor que o utilizado.

Em Setembro de 2002 Leoncio Zaráte Gamarra, Ademar Ferreira e Sérgio Ribeiro Augusto [2] propõem um novo sistema de controlo semaforico para o tráfego de veículos em cruzamentos, utilizando técnicas de aprendizagem por reforço e sintonização de conjuntos Fuzzy. Na arquitectura da rede a base de regras é feita por uma rede neuronal que implementa a inferência Fuzzy. O sistema a controlar, o fluxo de veículos, é tratado como espaços contínuos de estados e acções. Como resultado, reduziram-se as filas de espera.

Em 1993, Jyh-Shing e Roger Jang [23] sugeriram uma arquitectura com a designação de Sistema de Inferência Difuso baseado em Redes Adaptáveis ou simplesmente ANFIS. Foi criado um sistema de conclusão difuso baseado em regras do tipo “se,... então,... “ para modelar os aspectos qualitativos do

conhecimento humano ou processos sem empregar análises quantitativas precisas.

3.2 Enquadramento do Trabalho Desenvolvido

Apesar do controlo do fluxo de tráfego já se encontrar muito desenvolvido, é um facto que ainda continua a haver congestionamento, acidentes, o ambiente continua a ser “agredido” constantemente. De facto, os sistemas existentes já conseguem reagir, em *tempo-real*, às necessidades do tráfego.

Na Figura 3. 1 podemos ver uma forma de interpretar o problema. Devido à sua complexidade, pode ser dividido em três partes. Na primeira, pode ser tratado o reconhecimento do comportamento ou de padrões, onde podem ser utilizadas ferramentas com características apropriadas para esse fim, por exemplo redes neuronais ou Lógica Difusa Adaptativa. É neste primeiro ponto que o trabalho vai ser centralizado. Aqui há uma necessidade em recolher uma amostra representativa do universo, quer seja com um único tipo de variável quer seja com problemas multi-variáveis, não sendo necessário envolver definições empíricas para o conhecimento do problema.

Na segunda parte, pode-se entrar no campo da tomada de decisão. Nesta fase todo o trabalho feito na primeira parte pode e deve ser aproveitado para suportar a tomada de decisão.

Na terceira e última parte é feita a implementação de todo o processo envolvido no controlo de tráfego. Todas estas partes podem, caso se verifique vantajoso, recorrer a técnicas diferentes, criando uma simbiose entre elas para o objectivo ser alcançado.

No entanto, o objectivo deste trabalho é focar e propor uma solução no reconhecimento do comportamento/padrões de tráfego com recurso às redes neuronais artificiais e à lógica difusa adaptativa.

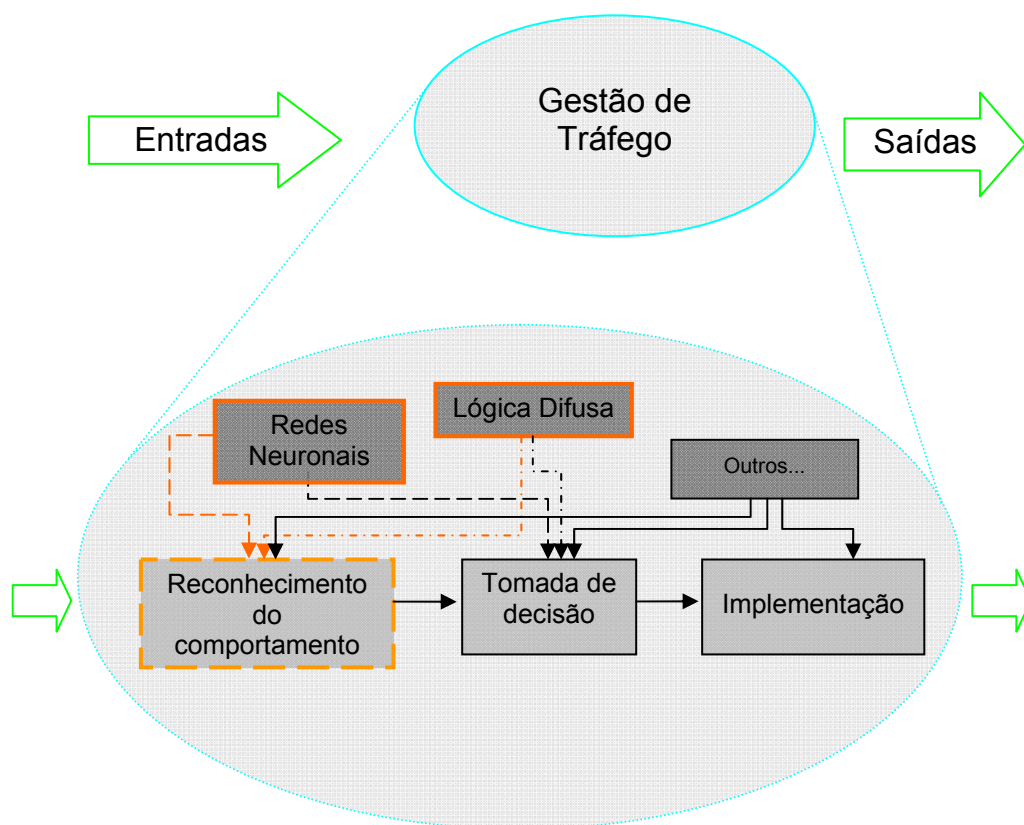


Figura 3. 1 – Enquadramento de soluções

As Redes Neurais Artificiais conseguem modelar o comportamento de um sistema a partir de dados existentes, sendo bastante imunes ao ruído ou a falhas na informação introduzida. Representam modelos conexionistas com uma capacidade de aprendizagem baseado no histórico, dando resposta a novas situações, especialmente em problemas com uma forte componente de ruído, informação incompleta e não linear [30].

Trata-se da procura de padrões e regularidades em conjuntos de dados, eventualmente de natureza complexa e possivelmente soluções não parametrizáveis. Também não necessitam de uma definição explícita de conhecimento do problema e podem ainda incorporar no modelo problemas multi-variável. No entanto, as RNAs não são uma solução universal para todos os problemas [31]. De facto, uma das dificuldades que resulta do uso de Redes Neurais Artificiais reside no tempo dispendido com a procura do melhor tipo de rede ou topologia. Numa primeira fase o treino da rede tem que ser em *off-line* e posteriormente pode ser afinada também *off-line* ou em *on-line*.

A lógica difusa assenta na extensão da lógica booleana, onde apenas intervêm os conceitos de “verdadeiro” ou “falso”. Neste contexto, adquirem importância termos aproximativos de natureza vaga, como “pequeno” ou “grande”. Assim, tende-se a exprimir o raciocínio humano, que não se limita a afirmações rígidas, do tipo “sim” ou “não”, mas admitem igualmente válidas ilações intermédias, do género “talvez” ou “mais ou menos”.

Um modelo de um sistema baseado em ferramentas matemáticas convencionais, por exemplo, equações diferenciais, não é adequado para lidar com sistemas incertos e/ou mal definidos devido à sua complexidade. Um sistema difuso que emprega as regras Lógicas “se... então...” pode modelar os aspectos qualitativos do conhecimento humano e do próprio processo sem fazer análises quantitativas precisas.

De forma mais objectiva, pode-se definir **Lógica Difusa** como sendo uma ferramenta capaz de captar informações vagas, em geral descritas numa linguagem natural e convertê-las para um formato numérico, de fácil manipulação pelos computadores actuais.

Para os modelos mais complexos onde não é imediato arbitrar os parâmetros associados às funções de pertinência, com base na experiência de peritos, é utilizado um processo de aprendizagem incorporado na Lógica Difusa. O nome dado a esse processo é “*Neuro-adaptive*”. Com a técnica de aprendizagem incorporada no sistema difuso – ANFIS⁴ é possível definir os parâmetros para as funções de pertinência de maneira a responder às variações dos valores de entrada/saída.

Através dos dados recolhidos e armazenados do cruzamento, o ANFIS pode prever, com base no histórico, o fluxo de tráfego. O processo de previsão também é feito em “*off-line*” tal como o das RNAs.

Não há dúvida que o poder de resposta em tempo real é uma mais valia para qualquer sistema de controlo de tráfego nos tempos de hoje. Se a estratégia não for aplicada no momento mais adequado, corre o risco de não ser eficaz e perder a confiança dos utilizadores. É então imperativo

⁴ ANFIS – *Adaptive Neural Fuzzy Inference System*

desenvolver técnicas para calcular as condições futuras do tráfego de forma que a acção correcta e oportuna seja implementada [32].

Nos parâmetros actuais e com recurso à IA a gestão do tráfego pode ser feita através de um conjunto de técnicas como ilustra a Figura 3. 1.

Com a previsão de algumas variáveis, vai originar intervenções antecedentes por parte do controlador no sistema. Na realidade, se compararmos com manutenção, estaríamos a falar da manutenção preventiva. Antes de ocorrer o problema, o sistema já o identificou e tem condições de actuar para minimizar a ocorrência.

4. Redes Neurais Artificiais e Lógica Difusa

Tendo optado por testar a aplicação de redes neuronais e lógica difusa aos problemas associados à gestão de tráfego urbano, neste capítulo pretende-se caracterizar e descrever os seus elementos principais, incluindo os procedimentos normalmente seguidos no desenvolvimento de soluções para problemas concretos com base nestas técnicas.

4.1 Redes Neurais

O trabalho em Redes Neurais Artificiais tem sido motivado e desenvolvido pelo reconhecimento de que o cérebro humano processa todas as informações captadas de uma forma muito própria. O cérebro pode ser comparável a um computador altamente complexo, não linear e paralelo. Ele tem a capacidade de estruturar e organizar as suas unidades de processamento, conhecidas por neurónios, de forma a realizar um processamento muito mais rápido do que qualquer outro computador digital hoje existente, para algumas funções particulares como por exemplo reconhecimento de padrões (imagens, texto escrito manualmente). Uma rede neuronal artificial pode considerar-se como inspirada nessa interpretação do funcionamento do cérebro humano. Sendo no entanto bastante diferente quer na dimensão, quer no modelo e funcionamento dos seus elementos.

Uma rede neuronal pode ser implementada utilizando componentes electrónicos ou simulada por programação num computador. Os modelos de

redes neuronais realizam a manipulação de informações através da interação de um grande número de unidades básicas de processamento, às quais se dá o nome de neurónios artificiais, ou mais frequentemente nós; sendo fundamental também a forma e tipo de interligações entre esses elementos.

As RNAs podem apresentar uma ou mais camadas intermédias, ditas também de escondidas⁵, de neurónios.

Do ponto de vista prático, as RNAs têm como vantagem o facto de não necessitarem de conhecimento explícito do problema para tomar decisões; elas baseiam-se unicamente nos exemplos que lhes são fornecidos. As RNAs podem ser utilizadas na solução de uma grande quantidade de problemas encontrados nas mais diversas áreas de aplicação: classificação, diagnóstico, análise de sinais e de imagens, *reconhecimento de padrões*, optimização e controlo. As redes são particularmente eficientes na resolução de problemas em que não se dispõe de uma formulação analítica, nem conhecimento explícito acessível. No limite pode considerar-se uma RNA como uma “caixa de processamento” de entradas e saídas que pode ser treinada com base num conjunto limitado de exemplos, conforme representado na Figura 4. 1.

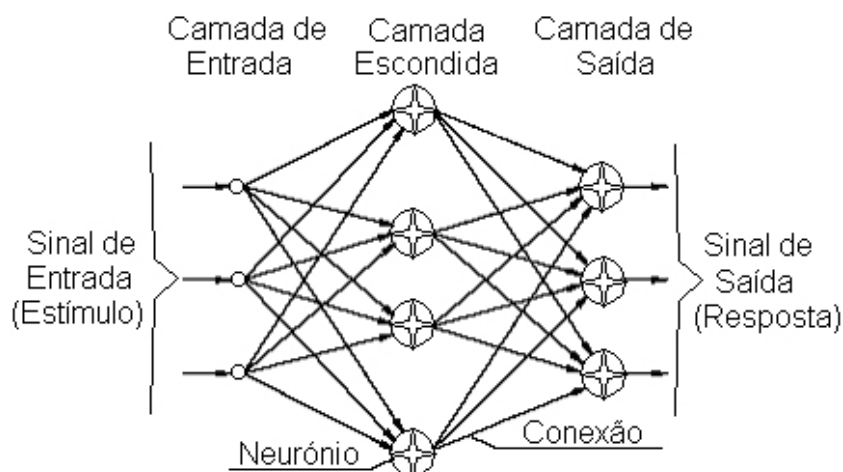


Figura 4. 1 – Rede Neuronal Artificial

⁵ Hidden Layer

4.1.1 Componentes

Em geral podemos considerar que uma rede neuronal é constituída por unidades de processamento ou nós (neurónios) e ligações entre esses nós, definindo a tipologia ou arquitectura da rede. Outro aspecto determinante é o processo ou algoritmo, que define a forma de ajuste os parâmetros da rede de forma a fornecer uma solução para um dado problema. Em geral pode dizer-se que existem várias alternativas em relação à configuração de uma rede neuronal com base nestes elementos, desde a escolha das funções que são implementadas em cada nó, do efeito de cada uma das ligações entre os nós, à tipologia e número de elementos utilizados. Ainda em relação aos algoritmos de treino, ou ajuste dos parâmetros da rede, também existem actualmente várias alternativas.

Um Neurónio Artificial, ou nó, é a unidade fundamental de processamento de uma RNA, o qual recebe uma ou mais entradas, transformando-as em saídas. Segundo TUBB (1993) cada entrada tem um peso associado, que determina sua intensidade. O esquema do neurónio artificial pode ser visualizado na Figura 4. 2, onde a_i são as entradas na rede neuronal, w_{ji} são os pesos das conexões, b_j é o bias, net_j é o valor de activação e y_j é a saída real.

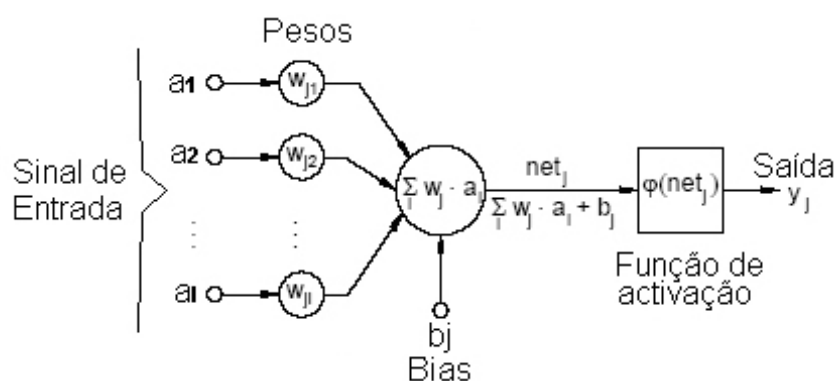



Figura 4. 2 – Neurónio Artificial

Uma representação genérica de um neurónio humano é mostrada na Figura 4. 3., de forma a estabelecer o paralelo entre os dois sistemas. Os dendritos apicais e basais são zonas receptivas, o corpo celular é onde se inicia a codificação da saída, os axónios constituem a linha de transmissão e os terminais sinápticos transmitem o “aprendido” para outro neurónio.

**Figura 4. 3 – Neurónio Humano**

Cada neurónio artificial (nó) possui um estado interno chamado valor de activação, que é modificado sempre que uma nova entrada é recebida. Essas entradas são combinadas e um novo valor de activação é calculado através de uma função. A saída do neurónio é por sua vez calculada aplicando uma função de saída, por vezes também referida como função de activação, ao valor de activação. Esta saída, por sua vez, serve de entrada para o neurónio seguinte e assim sucessivamente.

Uma rede neuronal pode apresentar-se em várias configurações, tais como acção directa ou recorrente como mostra Figura 4. 4. A configuração acção directa (ou “*feedforward*”) caracteriza-se pelos neurónios das camadas inferiores se interligarem somente com os neurónios da camada imediatamente superior. A configuração é chamada recorrente quando um neurónio pode receber entradas de qualquer outra camada da rede. A configuração com

realimentação acontece quando os neurónios da entrada recebem sinais vindos directamente dos neurónios da saída.

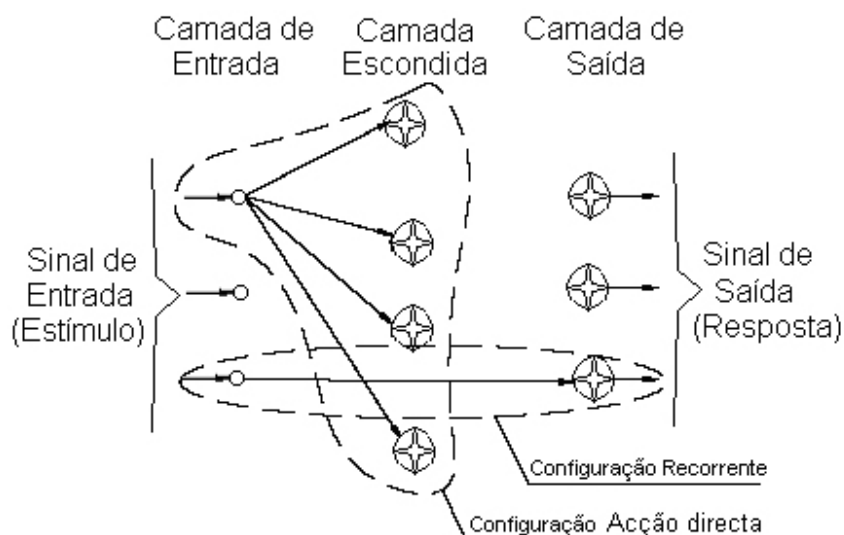


Figura 4. 4 – Configuração da Rede Neuronal

Cada unidade da rede recebe sinais de outras unidades. Essas ligações, ou pesos, determinam o efeito que a saída de uma unidade exerce sobre as outras unidades. Os pesos podem ter um efeito positivo ou negativo, ou seja inibidor na acção da unidade seguinte. Consistindo normalmente a fase de treino da rede num algoritmo que ajusta estes pesos de forma a minimizar uma função de erro. Desta forma o “conhecimento” ou “memória” da rede fica distribuída pelos pesos ou ligações da rede.

A combinação das entradas, normalmente pela soma ponderada das mesmas (Figura 4.2), gera uma entrada total que serve de base para a modificação do estado interno da unidade, o seu valor de activação. A saída de uma unidade é uma função do seu valor de activação.

A característica principal de uma rede neuronal é a sua capacidade de aprender, levando a que normalmente se considerem duas fases no processo de utilização de uma rede: uma fase de treino, e uma de utilização. O treino consiste no ajuste dos parâmetros internos da rede, de maneira que a rede apresente um resultado esperado dada a apresentação de um conjunto de

padrões específicos. Os padrões de treino da rede contêm as informações que se desejam que a rede aprenda. Os parâmetros a ajustar são os pesos das conexões que interligam os neurónios. Os diversos modelos de redes neuronais caracterizam-se pela utilização de diferentes técnicas de treino. O treino genericamente pode ser classificado como supervisionado ou não supervisionado.

O treino é supervisionado (Figura 4. 5) quando o ajuste de parâmetros é feito a partir da apresentação de um conjunto de pares de entradas e saídas padrão. Neste processo uma entrada padrão é apresentada à rede e uma saída é calculada. A diferença existente entre a saída calculada e a saída padrão é o erro produzido, que se deseja minimizar.

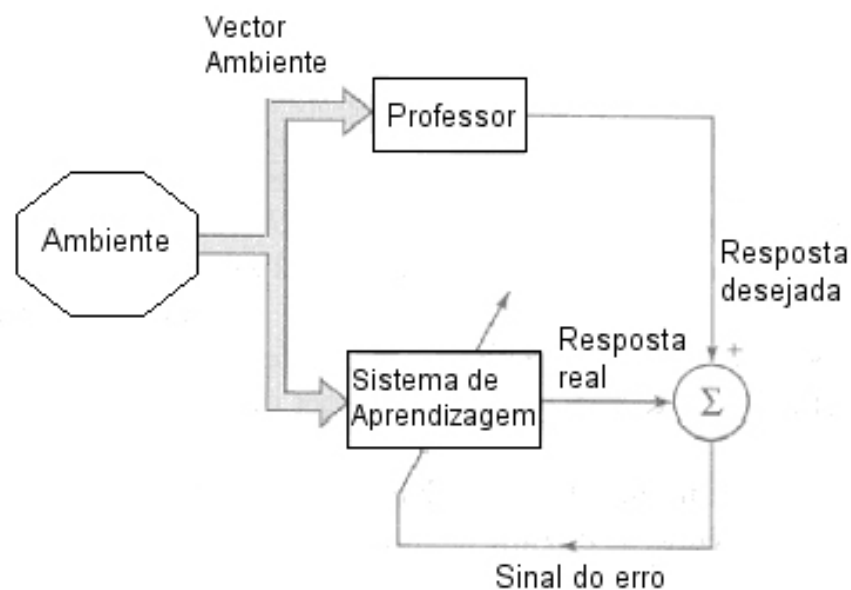


Figura 4. 5 – Diagrama em blocos do treino supervisionado

Neste tipo de aprendizagem são conhecidas à priori as respostas correctas correspondentes a um certo conjunto de dados de entrada. A referir entre outros os seguintes algoritmos de aprendizagem com supervisão:

(a) Regra de aprendizagem de Widrow-Hoff (ou método do gradiente aplicado em redes neuronais lineares);

(b) Aprendizagem por *retropropagação* do erro (“*error backpropagation*”) que constitui uma generalização da anterior regra a redes com camadas intermédias, lineares ou não lineares;

(c) Método do gradiente descendente e seus aperfeiçoamentos. De referir a existência de técnicas destinadas a melhorar a convergência destes métodos tais como a técnica do *momento* e do coeficiente de aprendizagem variável ou adaptativo;

(d) A aprendizagem recorrendo aos métodos de aproximação, Método de Newton como por exemplo o de *Levenberg-Marquardt*;

(e) A aprendizagem recorrendo a técnicas heurísticas, como por exemplo, os algoritmos evolutivos “*evolutionary algorithms*” ou a aprendizagem recorrendo ao processo “*simulated annealing*”.

Normalmente o algoritmo utilizado classifica a rede em que se aplica, sendo as redes mais divulgadas as redes “*backpropagation*”, ou de retropropagação. Estas são de acção directa, com pelo menos uma camada intermédia e utilizam um algoritmo iterativo com base no gradiente descendente para ajuste dos pesos da rede de modo a minimizar o erro quadrático da camada de saída relativamente aos valores desejados.

O treino é “não supervisionado” quando o conjunto de padrões de treino possui somente entradas, ou seja não existe saída padrão, não sendo possível mostrar à rede neuronal um alvo para se alcançar. O processo utiliza a comparação entre sinais para a construção de grupos de similaridade.

A aprendizagem sem supervisão é aplicada em sistemas de memória associativa e essencialmente de reconhecimento de padrões. Nestas redes a aprendizagem é realizada sem se conhecer antecipadamente as respostas consideradas correctas. Podem ser utilizados diferentes algoritmos de aprendizagem sem supervisão, entre outros:

(a) Algoritmos de estimulação pela entrada – em Inglês, “*reinforcement algorithms*” – também designados (no contexto da aprendizagem sem supervisão) por algoritmos de aprendizagem associativa– em Inglês, “*associative learning algorithm*”. A regra de Hebb [33], as regras de Instar e Outstar, constituem alguns exemplos deste tipo de algoritmos;

(b) Algoritmos de aprendizagem competitiva tais como a regra de Kohonen, [34].

Considerando os diferentes algoritmos de treino actualmente disponíveis, podemos considerar que os algoritmos do tipo “*backpropagation*”, desde a sua versão inicial até aos métodos que permitem evoluções na velocidade e generalização obtida através do processo de treino, continuam a ser dos mais utilizados. Tendo por essa razão sido escolhido como o método que iria ser utilizado neste trabalho.

4.1.2 Algoritmos de treino do tipo “*backpropagation*”

O algoritmo de retropropagação, ou “*backpropagation*”, assumiu um papel determinante na evolução e desenvolvimento de redes neuronais artificiais. Foi a possibilidade de utilizar um algoritmo que permite o ajuste, treino, de redes com camadas intermédias que tornou o seu aparecimento [35] determinante para a intensificação dos trabalhos de investigação nesta área. Demonstrou-se que uma rede neuronal com camadas intermédias e um número de nós adequado, pode mapear qualquer função não linear. Multiplicando-se os casos de aplicações de redes neuronais, explorando as suas capacidades de processamento distribuído e não linearidades.

Aplica-se a redes multicamada, de acção directa e baseia-se na utilização do método do gradiente descendente para ajustar o valor dos pesos das ligações entre nós da rede, de forma iterativa. Os nós da rede têm valores de activação em função dos pesos associados a cada entrada (*Equação 4. 1*).

$$net_j = \sum_i w_{ji} \times a_i + b_j$$

a- entradas, b-bias, w- pesos

Equação 4. 1: *valor de activação*

O ajuste dos pesos é definido com base na minimização do erro quadrático médio, entre o valor de saída da rede e o valor desejado (*Equação 4. 2 e Equação 4. 3*). Sendo necessário apenas que as funções de saída dos nós, ou funções de activação, utilizadas sejam diferenciáveis, como por exemplo as

funções logarítmica, tangente hiperbólica e a função linear (Figura 4. 6). Na sua forma original utiliza um coeficiente de aprendizagem, (“*learning rate*”), que determina em cada passo o valor utilizado na variação dos pesos. Posteriormente é considerado também outro coeficiente, ou parâmetro, que tem por objectivo contabilizar as variações no passo anterior do algoritmo, normalmente designado por “momento” ou (“*momentum term*”).

$$erro_j = t_j - y_j$$

t_j – saída desejada; y_j – saída da rede

Equação 4. 2

$$EQM = \frac{1}{2} \sum_j (erro_j)^2$$

Equação 4. 3: Erro Quadrático Médio




Figura 4. 6 – Funções de Activação

A implementação mais simples do backpropagation que aprende as actualizações dos “pesos” e do “*bias*” da rede na direcção na qual a função de desempenho diminui rapidamente – gradiente descendente. Uma iteração deste algoritmo pode ser escrita:

$$x_{k+1} = x_k - \alpha_k g_k$$

Equação 4. 4 – Iteração do algoritmo “*backpropagation*”

Onde:

x_k = vector dos pesos e *bias* actuais;

g_k = gradiente actual

α_k = taxa ou coeficiente de aprendizagem (lr- “*learning rate*”)

Quanto maior for o coeficiente de aprendizagem maior será o passo. Se “*lr*” for muito grande, o algoritmo fica instável. Se for muito pequeno, o algoritmo torna-se lento e leva muito tempo para convergir.

A Figura 4. 7 ilustra o processo de funcionamento de uma rede neuronal com acção directa. Neste tipo de rede neuronal existem dois tipos de sinais: os sinais funcionais e os sinais de erro. O sinal funcional é um sinal de entrada que se propaga para a frente através da rede neuronal e termina na camada de saída como um sinal de saída. O sinal de erro inicia-se no neurónio de saída e propaga-se para trás através da rede neuronal.

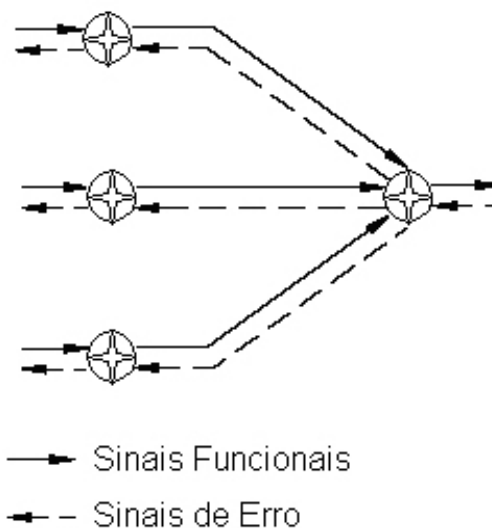


Figura 4. 7 – Propagação e Retropropagação dos sinais

Há duas maneiras diferentes nas quais este algoritmo de gradiente descendente pode ser implementado, tendo em conta a utilização do conjunto dos dados de treino:

- de forma incremental: o gradiente é calculado e os pesos são actualizados depois de cada entrada ser aplicada na rede;
- de forma agrupada ou em (“*batch*”): todas as entradas são aplicadas na rede e só no fim é que os pesos são actualizados.

A consideração do termo (“*momentum*”) no algoritmo (gradiente descendente com *impulso*) torna-se mais rápido que o anterior devido ao

impulso. Age como um filtro passa-baixo, o impulso permite à rede ignorar o aparecimento de pequenas características localizadas. O “impulso” pode ser adicionado à aprendizagem “backpropagation” fazendo mudanças de peso igual à soma da fracção da última mudança de peso e a nova mudança sugerida pela regra “backpropagation”. A magnitude do efeito que permite a última mudança de peso é medida por uma constante “mc” que pode variar entre 0 e 1. Quando a constante de impulso é “zero”, a mudança de peso é baseada somente no gradiente. Quando a constante de impulso é “um”, a nova mudança de peso é fixa para igualar a última mudança e o gradiente é simplesmente ignorado. Os gradientes são computados pela soma dos gradientes calculados em cada treino e os “pesos” e o “bias” são actualizados só depois de treinados todos os exemplos apresentados. Se a nova função de desempenho numa determinada iteração excede a função de desempenho da iteração prévia com uma diferença superior à razão predefinida (tipicamente 1,04) os pesos e o bias novos são descartados e o “mc” coeficiente de impulso é fixo para zerar. A função “traingdm” é invocada usando os mesmos passos da função “traingd”, com a excepção dos parâmetros de aprendizagem “mc”, “lr” e “Max_perf.inc” (incremento máximo da performance) que devem ser definidos [40].

Uma das limitações na sua utilização é o número de iterações e o tempo necessário para treinar a rede. Depende do número de nós e do número de casos utilizados. Esta limitação levou a que se tenham desenvolvido alterações ao algoritmo original, por exemplo com base na utilização de métodos que recorrem ao cálculo da segunda derivada ou a uma sua aproximação, como por exemplo o método de “Levenberg-Marquardt”. Normalmente levam a convergências mais rápidas, dependendo da dimensão da rede.

Outra das limitações do algoritmo “backpropagation” relaciona-se com a possibilidade de convergir para mínimos locais, e na capacidade de generalização obtida após o treino. Tendo-se também desenvolvido algumas metodologias de treino que pretendem diminuir esses efeitos, como por exemplo variar o coeficiente de aprendizagem durante a fase de treino.

Nas experiências desenvolvidas efectuaram-se alguns treinos e testes iniciais de modo a testar várias alternativas. Tendo-se verificado que nas várias experiências não havia grandes diferenças relativamente ao erro final, optou-se pelo métodos mais rápido (duas ordens de grandeza: 10-2000) no processo de convergência, que foi o Levenberg-Marquardt. Neste caso não é muito crítico a diferença de tempo mas se o sistema evoluir a diferença de tempo de resposta do sistema começa a ser cada vez maior.

O algoritmo Levenberg-Marquardt, sendo um método *Quasi-Newton*, foi concebido para considerar uma aproximação de segunda ordem sem calcular a matriz de Hessian. Quando a função de desempenho tem a forma da soma dos quadrados então a matriz de Hessian pode ser aproximada como:

$$H = J^T \times J$$

Equação 4. 5 – aproximação à matriz de Hessian

e o gradiente pode ser calculado como:

$$g = J^T \times e$$

Equação 4. 6 – Gradiente

Onde J é a matriz Jacobiana que contém a primeira derivada dos erros da rede em relação aos pesos e o “e” é o vector dos erros da rede. A matriz Jacobiana pode ser calculada através da algoritmo original “*backpropagation*”.

O algoritmo de LM usa uma aproximação à matriz de Hessian:

$$x_{k+1} = x_k [J^T J + \mu I]^{-1} J^T \times e$$

Equação 4. 7 – Algoritmo LM

Quando o parâmetro μ se aproxima de zero, o método aproxima-se do método de Gauss-Newton, isto é, exactamente o método de Newton. Quando μ é elevado o método aproxima-se do método gradiente descendente.

O algoritmo que vai ser utilizado neste trabalho é o de retropropagação.

A configuração da rede neuronal para o algoritmo de retropropagação é do tipo acção directa⁶. Ela consiste num conjunto de unidades sensoriais que constituem a camada de entrada, uma ou mais camadas ocultas e uma camada de saída de nós computacionais.

A representação, ou codificação do problema a ser tratado numa rede neuronal está directamente associada à especificação dos elementos, ou nós de entrada e dos elementos de saída. O número de elementos nas camadas de entrada e de saída é determinado pelos objectivos de utilização da rede que definem as variáveis de entrada/saída e pela codificação dessas variáveis. Em princípio não há restrições nesta codificação, permitindo combinações de diferentes tipos de variáveis, tanto na entrada como na saída.

Nessa codificação é comum normalizarem-se os valores no intervalo [-1 1] ou [0 1], com o objectivo de melhorar a eficiência da rede [36].

Sendo o processo de treino baseado em dados ou exemplos de comportamento do sistema é importante garantir que eles são representativos do universo de dados possível. Por outro lado a separação dos dados disponíveis em conjuntos de treino e teste condiciona o processo de treino e validação da solução. Os conjuntos de teste não são apresentados à rede durante a fase de treino. A separação depende do problema em causa, sendo comum usarem-se 15-20% do total de dados para o conjunto de teste.

Outro aspecto determinante no processo de treino da rede prende-se com a capacidade de definir quando é que o treino deve parar de modo a não comprometer a possibilidade de generalização da rede, uma vez que prolongando o número de iterações de treino a rede terá tendência para melhorar a sua eficiência nos casos de treino (*“overfitting”*) mas piorar nos casos de teste. Existem alguns procedimentos que tentam minimizar este problema [36]. Um deles consiste em testar durante o processo de treino a eficiência da rede num conjunto de dados de treino/validação, de modo a poder parar o processo em função do erro nesses dados e não no de treino.

Sendo uma das características das redes neuronais começar o processo de treino a partir de um estado dos seus parâmetros definido de modo aleatório, o

⁶ feedforward

processo de convergência pode ser muito dependente desse ponto inicial. Deve-se portanto repetir, para a mesma rede, várias vezes o mesmo procedimento de modo a identificar essas situações.

4.2 Lógica Difusa

Neste capítulo, vai ser feita referência à classe de redes difusas adaptativas que são funcionalmente equivalentes ao sistema de conclusão difusa⁷. A arquitetura proposta refere-se ao ANFIS⁸ sistema de conclusão difuso baseado nas redes adaptativas. Também vai ser mencionada a decomposição dos parâmetros, tais como as regras de aprendizagem “Híbridas” das redes adaptativas.

Os controladores difusos (CD) são encontrados em várias aplicações, nomeadamente não só na indústria como também em electrodomésticos. Para sistemas complexos mal definidos que não são controlados facilmente por outros métodos de controlo convencionais, os CD constituem uma possível alternativa desde que possam obter informação qualitativa do conhecimento humano.

No entanto, o rigor das técnicas de aquisição do conhecimento e a disponibilidade de domínio humano (peritos) são imprescindíveis.

Lógica Difusa é uma ferramenta capaz de captar informações vagas, em geral descritas numa linguagem natural, por exemplo, “*quente*”, “*muito frio*” “*talvez*” e convertê-las para um formato de fácil manipulação pelos computadores.

Fazendo uma Comparação com as tecnologias tradicionais, o CD apresenta diversas vantagens, nomeadamente, no uso de variáveis linguísticas deixa mais perto do pensamento humano, com base na experiência de peritos, a eficácia do controlo de processos com comportamento complexo, não linear.

⁷ Fuzzy inference systems (FIS)

⁸ Adaptive Networks based Fuzzy Inference Systems

O sistema de conclusão difuso é um método que funciona da seguinte maneira:

- as características de entrada são incorporadas nas funções de pertinência;
- as entradas das funções de pertinência em regras;
- as regras para um conjunto de características de saída;
- as características de saída para as saídas das funções de pertinência;
- as saídas das funções de pertinência para um valor de saída;
- e finalmente, a decisão associada à saída.

Existem alguns modelos onde não se podem, apenas, olhar e descrever as funções de pertinência. Em vez de se escolherem arbitrariamente os parâmetros associados às funções de pertinência, estes podem ser escolhidos de maneira a responder às variações dos valores de entrada/saída. A este processo é dado o nome de “neuro-adaptive” técnica de aprendizagem incorporada no sistema difuso – ANFIS.

4.2.1 ANFIS – Adaptive Neural Fuzzy Inference System

Em geral, as formas das funções de pertinência dependem dos parâmetros que podem ser ajustados para mudar a forma dessas mesmas funções.

Os parâmetros que podem ser ajustados automaticamente dependem dos dados a modelar.

O modelo de validação com o conjunto de dados “*Checking*” e “*testing*” serve para validar e verificar o modelo em estudo.

São utilizados os dados de validação para verificar e controlar a performance do modelo.

Os dois parâmetros do ANFIS, do método de optimização, para o treino FIS, são:

- Híbrido – por defeito, é uma junção de mínimos quadrados e o “*backpropagation*”.
- “*backpropagation*”.

A tolerância do erro é usada como critério para terminar o treino. O treino irá parar depois do erro do treino se encontrar dentro da tolerância. Para uma melhor compreensão vão ser dados dois exemplos simples.

Exemplo prático: [Fonte: Manual do Matlab]

Um sistema de conclusão difuso tem duas entradas “x” e “y” e uma saída “z”. Supondo que tem duas regras “SE... ENTÃO” do tipo Takagi e Sugeno.

Regra 1: Se x é A1 e y é B1, então $f_1 = p_1x + q_1y + r_1$,

Equação 4. 8

Regra 2: Se x é A2 e y é B2, então $f_2 = p_2x + q_2y + r_2$.

Equação 4. 9




Figura 4. 8 – Raciocínio Difuso

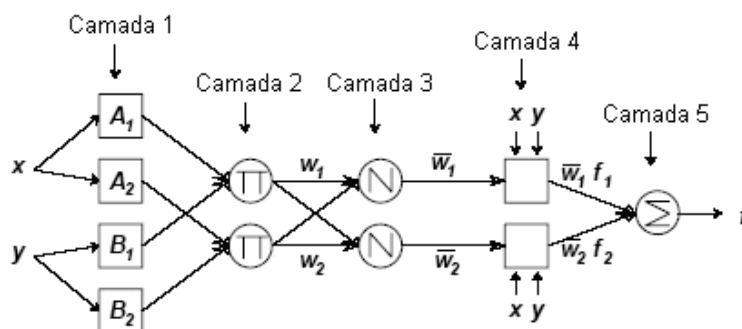


Figura 4. 9 – Raciocínio ANFIS com duas entradas e duas regras

A Figura 4. 8 ilustra o raciocínio difuso e a Figura 4. 9 mostra a arquitectura utilizada no ANFIS.

As funções dos nós na mesma camada são da mesma família como está explicado a seguir:

Na camada 1:

todos os nós “i”, nesta camada, é um quadrado com uma função do nó.

$$O_i^1 = \mu \times A_i(x)$$

Equação 4. 10

Onde (x) é a entrada no nó i e A_i é a etiqueta linguística (pequena, média, etc) associado com a função do nó. Por outras palavras, O_i^1 é a função de pertença de A_i e especifica o grau para o qual o x satisfaz o quantificado A_i .

Geralmente, é escolhido $\mu A_i(x)$ para ser bem moldado com o máximo igual a 1 e o mínimo igual a 0, tal que:

$$\mu A_i(x) = \frac{1}{1 + \left[\left(\frac{x - c_i}{a_i} \right)^2 \right] b_i}$$

Equação 4. 11

Ou

$$\mu A_i(x) = \exp \left\{ - \left[\left(\frac{x - c_i}{a_i} \right)^2 \right] b_i \right\}$$

Equação 4. 12

Onde $\{a_i, b_i, c_i\}$ são o conjunto de parâmetros. Como estes valores mudam, as funções de pertença também variam adequadamente exibindo várias formas das etiquetas linguísticas. Habitualmente as funções de pertença têm a forma de trapézio ou triangular, no entanto também existem outras formas que vão ser abordadas posteriormente neste capítulo.

Camada 2:

Todos os nós desta camada são circulares de etiqueta Π . É feito o produto, dos sinais recebidos e de seguida são enviados, por exemplo

$$w_i = \mu A_i(x) \times \mu B_i(y), \quad i = 1, 2$$

Equação 4. 13

Cada nó de saída representa o peso de uma regra.

Camada 3:

Todos os nós desta camada são circulares de etiqueta N. O nó i calcula a relação do peso da regra i com a soma dos pesos de todas as regras:

$$\bar{w}_i = \frac{w_i}{w_1 + w_2}, i = 1, 2$$

Equação 4. 14

As saídas desta camada chamam-se “firing strengths” normalizados.

Camada 4:

Todos os nós i desta camada são um quadrado com a seguinte função:

$$O_i^4 = \bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i)$$

Equação 4. 15

Onde \bar{w}_i é a saída da camada 3 e $\{p_i, q_i, r_i\}$ são o conjunto de parâmetros.

Os parâmetros desta camada referem-se aos parâmetros consequentes.

Camada 5:

O único nó da camada 5 é circular com etiqueta Σ que computa a saída final como a adição de todas as entradas, i.e.,

$$O_1^5 = \text{saída global} = \sum_i w_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i}$$

Equação 4. 16

A aproximação híbrida é muito mais rápida que a de gradiente descendente, mas também exige maior performance por parte do processador do computador.

Em princípio, se o tamanho do conjunto de dados de entrada-saída disponível for bastante grande, então a afinação das funções de pertinência é aplicável (ou até mesmo necessário). No entanto, é possível que um conjunto de dados não seja representativo do universo para utilizar o ANFIS.

A Lógica Difusa ou Lógica Nebulosa, também pode ser definida, como a lógica que suporta os modos de raciocínio que são aproximados.

O raciocínio exacto corresponde a um caso limite do raciocínio aproximado, sendo interpretado como um processo de composição nebulosa.

4.2.2 Método de Treino

O controlador difuso é constituído por 4 módulos, como se pode ver Figura 4. 10:

a) Fusificador: responsável pela conversão (real) – difusa de modo a torná-la compatível com a representação interna do controlador difuso. Caso o universo de discurso não se encontre normalizado este módulo realiza a requerida transformação de escalas;

b) Base de conhecimento: base de dados + base de regras

b.₁ Base de dados – disponibiliza a informação necessária ao funcionamento dos módulos de fusificação e desfusificação, sob a forma de funções de pertinência e de factores de escala;

b.₂ Base de regras – representa a estratégia de um operador humano, preferencialmente experiente;

c) Motor de Inferência: responsável pelo cálculo do valor difuso global da saída do controlador a partir das entradas individuais das regras disparadas;

d) Módulo de Desfusificação: realiza a operação de conversão da saída difusa do controlador num valor crespo (real).

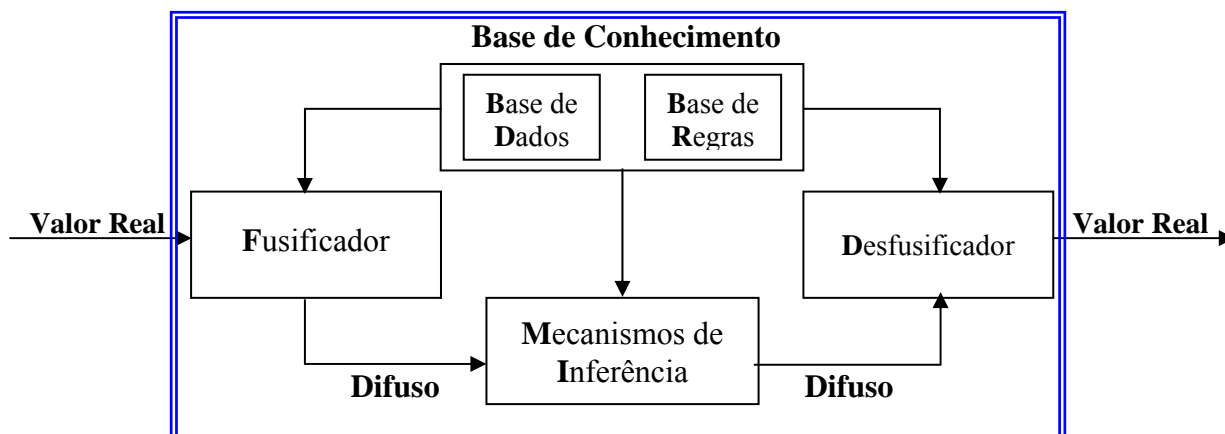


Figura 4. 10 – Controlador Difuso

Para exemplo, podemos fazer referência às leituras de sensores e aos sinais esperados pelos actuadores do sistema de controlo que não são nebulosos e por isso, são necessários elementos adicionais entre o controlador nebuloso e o processo a ser controlado. Estes elementos são os mencionados anteriormente: Fusificador e Desfusificador.

Para executar a fusificação é necessário dominar algumas noções básicas dos sistemas difusos, para posteriormente realizar o primeiro passo do processamento difuso.

A descrição de uma ou várias variáveis faz-se por intermédio de expressões linguísticas que caracterizam todas as situações possíveis por exemplo, “alto”, “médio”, “baixo”, “quente”, “frio”, “morno”, etc.

Uma etiqueta linguística representa-se matematicamente por um conjunto difuso, formado por vários valores lógicos referentes à possibilidade de ocorrência. Os valores de um conjunto difuso encontram-se compreendidos num intervalo de 0 a 1.

O número de etiquetas linguísticas é 5^{+2} , normalmente um número ímpar compreendido entre 3 e 7. O limite inferior decorre do facto da generalidade dos conceitos na linguagem natural (humana) considerar 2 extremos e um meio-termo, enquanto que o limite superior advém das capacidades de memória de curto-prazo dos seres humanos (até 7 símbolos).

Na (Figura 4. 11) pode-se ver o tipo de funções de pertença mais utilizados, do tipo triangular, trapezoidal ou radial.

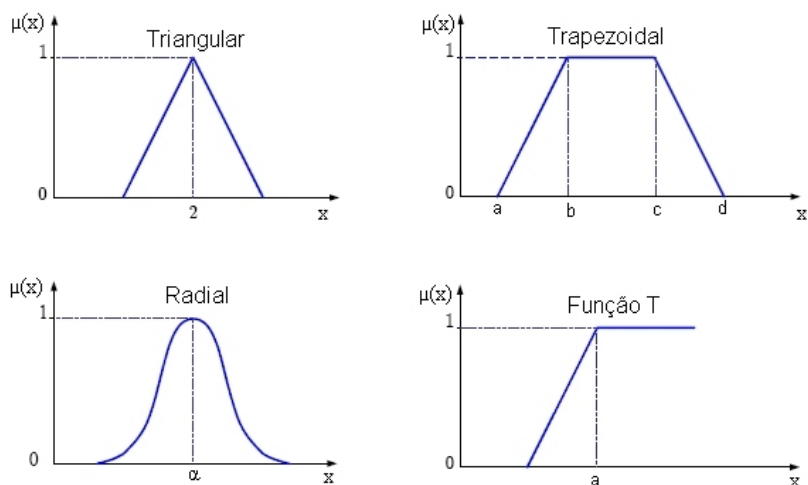


Figura 4. 11 – Funções de Pertença

O processo de defusificação realiza a conversão de conjuntos difusos em valores reais. Nesta fase final do processamento começa-se pela extracção difusa, escolhendo o valor da variável linguística de saída do sistema, com o recurso ao método do centro de gravidade, (utilizado neste trabalho). O problema resume-se à definição de uma metodologia adequada.




Figura 4. 12 – Defusificação

Métodos de defusificação mais comuns:

- i) Centro de Gravidade;
- ii) Altura;
- iii) Média dos Máximos.

i) Centro de Gravidade:

Esta operação é computacionalmente complexa, o que origina frequentemente ciclos de inferência algo lentos.

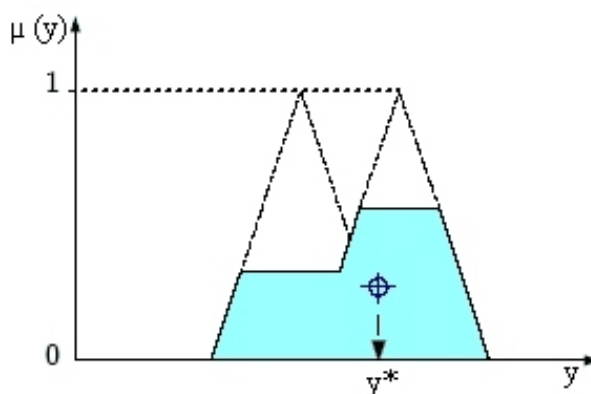


Figura 4. 13 – Método do centro de Gravidade

Para o cálculo do centro de gravidade (y^*), é utilizado o algoritmo:

$$y^* = \frac{\int y \times \mu(y) dy}{\int \mu(y) dy}$$

Equação 4. 17

ii) Altura:

Este método é computacionalmente leve e de implementação extremamente simples.




Figura 4. 14 – Método das alturas

Para o cálculo do método das alturas (y^*), é utilizado o algoritmo:

$$y^* = \frac{\sum_k c_k \times f_k}{\sum_k f_k}$$

Equação 4. 18

iii) Média dos Máximos

É um método computacionalmente leve e de implementação simples.




Figura 4. 15 – Método Média dos Máximos

Para o cálculo do método da média dos máximos (y^*), é utilizado o algoritmo:

$$y^* = \frac{1}{2} \times \left[\inf_{y \in Y} \left(y \in Y : \mu_Y(y) = \tilde{\mu}_Y \right) + \sup_{y \in Y} \left(y \in Y : \mu_Y(y) = \tilde{\mu}_Y \right) \right]$$

Equação 4. 19




Figura 4. 16 – Inferência com múltiplas regras

A função de pertença “membership function” estabelece uma relação entre os conjuntos difusos, associados a cada termo linguístico “Baixo”, “Médio”, “Alto” e o universo de discurso. Esta relação pode ter expressão analítica ou ser representada gráficamente pelas funções de pertença de cada conjunto difuso dependentes da variável linguística. Habitualmente a função de pertença simboliza-se por μ e para identificar a variável respectiva escreve-se o seu símbolo como argumento, isto é, utiliza-se a notação $\mu(x)$.

Convém fazer a normalização do universo de discurso da variável linguística, aplicando a esta variável um factor de escala. A normalização das variáveis linguísticas no controlo difuso origina um universo de discurso [-1,1], porque o erro de controlo pode ser positivo ou negativo em torno do erro nulo.

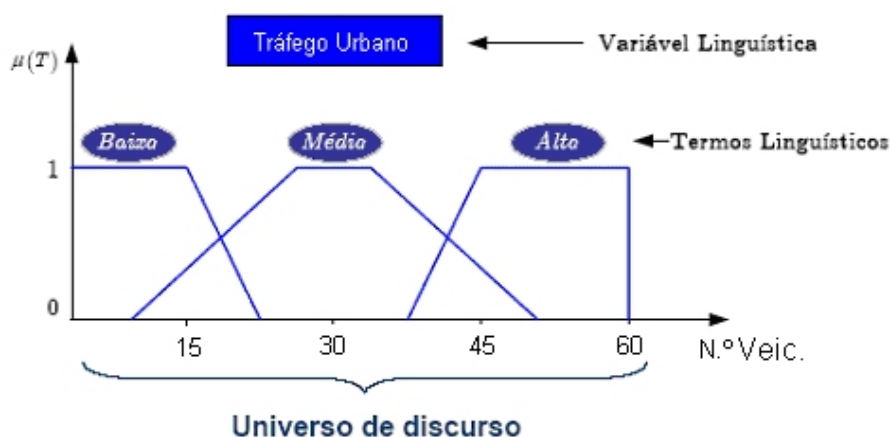


Figura 4. 17 - Variáveis e Termos Linguísticos

5. Problemas Tratados

Neste capítulo apresentam-se os dois cruzamentos que foram considerados para testar a utilização das técnicas escolhidas, redes neuronais do tipo “*backpropagation*” e lógica difusa adaptativa “*ANFIS*“. Apresentam-se também os dados disponíveis, bem como a abordagem escolhida para a modelização do problema nas ferramentas escolhidas.

Os cruzamentos escolhidos correspondem a localizações distintas, em relação às características de tráfego e também apresentam configurações diferentes. O primeiro é um cruzamento com 3 ramos em Y com valores recolhidos em intervalos de 15 minutos a partir das 8 até às 22 horas. O segundo é um cruzamento prioritário com 4 ramos com valores recolhidos em intervalos de 5 minutos durante um mês.


5.1 Cruzamento com três ramos

Este cruzamento foi abordado inicialmente porque foram disponibilizados dados reais [anexo C] que permitiam gerar informação para testar as estratégias escolhidas.

Consiste de um cruzamento com 3 ramos em Y (*Figura 5. 1*) existente numa zona de ligação entre duas vias rápidas. As suas características geométricas podem caracterizar-se como:

- tendo 2 pistas a Norte, 2 a Oeste e 2 a Sul.;
- inclinação longitudinal de 0°;

- existência de pistas exclusivas:
 - a Norte, uma pista para viragem à esquerda e outra à direita;
 - a oeste, uma pista para viragem à esquerda e outra em frente;
 - a sul, uma pista para viragem à direita e outra em frente;comprimento ilimitado das pistas de armazenamento
- não existência de estacionamento:




Os dados reais representam contagens de 15 em 15 minutos, obtidas num dia em particular, dos fluxos em cada um dos movimentos. Tendo também sido disponibilizado os dados correspondentes a um estudo feito para estabelecer um plano de regulação de semáforos a aplicar nesse cruzamento. Desta forma foi possível utilizar dados reais de fluxos de tráfego e dados gerados de comportamento de fluxos de tráfego com base num plano de regulação de semáforos.

Estes dados permitem constituir um conjunto de treino e teste num total de 60 padrões, associados a variáveis de fluxo de tráfego ou tempos de espera. Tendo servido de base às primeiras experiências realizadas.

Os parâmetros considerados no plano de regulação definido são os seguintes:

- Tempo de verde útil mínimo para cada corrente de tráfego – 7 segundos;
- Tempo máximo para a duração do ciclo – 100 segundos;
- Tempo de interverde – 5 segundos, dos quais 3 segundos de amarelo e 2 segundos de “tudo-vermelho”;
- Incremento no tempo de duração do ciclo – 1 segundo;
- Grau de saturação máximo aceitável – 0,9.
- Botão para peões:
 - Não existe;
- Tempo mínimo de verde para peões:
 - 0 segundos;
- Plano de fases:



- Débitos de saturação:
 - Pista com sentido em frente – 1800 veículos/hora;
 - Pista com viragem à esquerda – 1700 veículos/hora;
 - Pista com viragem à direita – 1600 veículos/hora;
- Atraso médio por veículo:
 - Ver anexos
- Percentagem de veículos pesados:
 - Foi feita uma conversão para veículos ligeiros;
- Volume de peões em conflito (peões/hora):

- Não existem passagem de peões;
- Número de autocarros/hora com paragem local:
- Não existem autocarros com paragem local;
- Actividade de estacionamento (manobras de estacionamento/hora):
- Não existem estacionamentos;

5.2 Cruzamento com quatro ramos

O volume de dados disponíveis para o cruzamento de 3 ramos, correspondendo apenas a recolhas de um dia, e em intervalos de 15 em 15 minutos, serviu os objectivos como primeira abordagem ao problema. No entanto a utilização de um maior volume de dados, juntamente com outro tipo de cruzamentos era importante para a validação das soluções testadas. Por essa razão foi considerado um cruzamento com quatro ramos (Figura 5. 2) inserido numa zona urbana.

Os dados disponíveis para este caso [anexo D] correspondem a contagens de 5 em 5 minutos ao longo de um mês, permitindo um volume de dados substancialmente maior do que no primeiro caso. No total temos um conjunto de dados superior a 8600 casos. Para além do volume total temos ainda a possibilidade de considerar os dados agrupados por dias ou semanas. Os dados continuam a ser dados reais.

As características geométricas são as seguintes:

- Tipo de Área: Urbana;
- Número de pistas: quatro




Figura 5. 2 – Cruzamento com 4 ramos

5.3 Abordagens com base em redes neuronais e lógica difusa

A abordagem inicial consistiu em testar a possibilidade de treinar uma rede neuronal para prever o comportamento de variáveis associadas ao tráfego num cruzamento. Essa informação seria útil para um tratamento subsequente do plano de regulação dos semáforos, numa perspectiva de curto prazo, ou seja micro-regulação. Poderá também ser útil para reduzir o número de sensores necessários para determinar por exemplo o fluxo de tráfego numa via.

A ideia base consiste em tirar partido de redes neuronais e lógica difusa adaptativa para modelar o comportamento do tráfego. Neste caso em particular pretendia-se considerar as variáveis directamente associadas a um cruzamento, como por exemplo fluxo de tráfego nas vias de acesso e saída, ou tempos de espera. Estas técnicas permitiam considerar simultaneamente mais

do que uma variável, ou valores dessa variável em diferentes instantes de tempo. Em relação à informação fornecida optou-se sempre por considerar apenas uma saída da rede.

Numa primeira abordagem foram feitas várias combinações envolvendo as variáveis de fluxos e tempos de espera. Essas combinações distinguiram-se por:

- incluírem apenas um tipo de variável, em diferentes instantes de tempo (tipicamente 3) e correspondentes a uma via;
- incluírem apenas um tipo de variável, em diferentes instantes de tempo, mas referentes a outras vias;
- incluírem mais do que um tipo de variável, em diferentes instantes de tempo, numa só via, ou em mais do que uma via.



Figura 5. 3 – Arquitectura das ferramentas utilizadas

Esta abordagem baseou-se na utilização dos dados do primeiro cruzamento.

Numa segunda abordagem tentou-se tirar partido do maior volume de dados disponíveis no segundo cruzamento, concentrando-se apenas na variável fluxo de tráfego.

No capítulo seguinte são apresentadas as experiências efectuadas.

6. Experiências Realizadas

As experiências realizadas consistiram em utilizar redes neurais do tipo backpropagation e lógica difusa adaptativa tendo como suporte de desenvolvimento o software Matlab®. Neste capítulo apresentamos as soluções testadas para os dois casos abordados (cap. 5): um cruzamento de três ramos em Y e outro de quatro ramos.

6.1 Cruzamento 3 ramos em Y

O primeiro cruzamento estudado é designado como *Cruzamento de três ramos em Y* pela sua estrutura. Na Figura 6. 1 pode ser vista a sua estrutura bem como o número de vias e respectivos sentidos.




Figura 6. 1 – Cruzamento de 3 ramos

Os dados utilizados no treino e no teste da rede neuronal foram recolhidos no cruzamento em estudo, desde as 6 até às 22 horas durante um único dia, com intervalos de 15 minutos, os restantes foram calculados através dos dados recolhidos [anexo C].

A tabela 6.1 apresenta uma síntese das alternativas testadas. Cada alternativa surgiu na sequência da estratégia definida (5.3) e em consequência dos testes realizados para testar cada uma delas. A tabela contém 7 alternativas, indicando para cada uma delas o número de entradas (coluna 2), o tipo de variável associada a cada entrada (coluna 3), o número de saídas (coluna 4), e o tipo de variável na saída (coluna 5). Para além disso apresenta uma linha para cada alternativa com a caracterização dos dados de treino e teste utilizados. Em todas as alternativas apresentadas os dados foram normalizados.

Hip.	Entrada	Entradas	Saída	Saídas
1 ^a	3	Fluxo Tráfego T	1	Fluxo Tráfego T+1
		Fluxo Tráfego T-1		
		Fluxo Tráfego T-2		
80% dos dados são para treino e 20% para teste. Os dados são relativos a um dia das 8:00 às 22:00 [15/15 min]				
2 ^a	6	Fluxo Tráfego T	1	Atraso médio Pista 1 T+1
		Atraso médio Pista 1 T		
		Atraso médio Pista 2 T		
		Atraso médio Pista 3+4 T		
		Atraso médio Pista 5 T		
		Atraso médio Pista 6 T		
80% dos dados são para treino e 20% para teste. Os dados são relativos a um dia das 8:00 às 22:00 [15/15 min]				

3 ^a	6	Fluxo Tráfego T	1	Fluxo Tráfego T+1
		Atraso médio Pista 1 T		
		Atraso médio Pista 2 T		
		Atraso médio Pista 3+4 T		
		Atraso médio Pista 5 T		
		Atraso médio Pista 6 T		
80% dos dados são para treino e 20% para teste. Os dados são relativos a um dia das 8:00 às 22:00 [15/15 min]				
4 ^a	5	Fluxo Tráfego T	1	Fluxo Tráfego T+1
		Fluxo Tráfego T-1		
		Fluxo Tráfego T-2		
		Fluxo Tráfego T-3		
		Fluxo Tráfego T-4		
80% dos dados são para treino e 20% para teste. Os dados são relativos a um dia das 8:00 às 22:00 [15/15 min]				
5 ^a	3	Fluxo Tráfego T	1	Fluxo Tráfego T+1
		Fluxo Tráfego ΔT [T-(T-1)]		
		Fluxo Tráfego T-2		
80% dos dados são para treino e 20% para teste. Os dados são relativos a um dia das 8:00 às 22:00 [15/15 min]				
6 ^a	4	Fluxo Tráfego T	1	Atraso médio Pista 1 T+1
		Fluxo Tráfego ΔT [T-(T-1)]		
		Fluxo Tráfego T-2		
		Atraso médio Pista 1 T		
80% dos dados são para treino e 20% para teste. Os dados são relativos a um dia das 8:00 às 22:00 [15/15 min]				
7 ^a	4	Fluxo Tráfego T	1	Atraso médio Pista 1 T+1
		Atraso médio Pista 1 T		
		Atraso médio Pista 1 T-1		
		Atraso médio Pista 1 T-2		
80% dos dados são para treino e 20% para teste. Os dados são relativos a um dia das 8:00 às 22:00 [15/15 min]				

Tabela 6. 1 – Resumo das experiências efectuadas

Seguidamente apresenta-se o processo de treino para cada uma destas configurações, primeiro utilizando uma rede backpropagation com algoritmo Levenberg-Marquardt, e depois uma solução utilizando *ANFIS*.

6.1.1 Experiências com Backpropagation (LM)

A arquitectura, ilustrada na Figura 6. 2, vai servir como ponto de partida para uma abordagem ao problema referente ao treino com recurso às RNA.




Figura 6. 2 – Arquitectura do treino/teste com RNAs

O ajuste dos parâmetros da rede, número de camadas intermédias e número de nós, e o ajuste dos pesos das ligações através do processo de treino foi semelhante em todas as hipóteses enunciadas na secção anterior (6.1).

Após a entrada das variáveis na rede, é feito um pré-processamento de dados para converter os valores iniciais em valores compreendidos entre $[-1;1]$. O objectivo desta conversão é uniformizar os dados de entrada.

A aprendizagem baseia-se no método de Levenberg-Marquardt. Apesar de terem sido testados outros algoritmos, como o backpropagation original e a versão que incluía um termo de *“momento”*, que no entanto se revelaram mais lentos e sem diferenças significativas na eficiência das redes.

O procedimento para definir o número de elementos, ou nós intermédios de cada rede baseou-se na expectativa de que uma rede com um número cada vez maior de nós intermédios terá um desempenho consistentemente melhor nos dados de treino, mas por outro lado também consistentemente pior nos

dados de teste. Ou seja perderá capacidade de generalização. Assim testaram-se redes com um número mínimo de 2 elementos e máximos de 24 e 48, cujos resultados permitiram confirmar essa expectativa e apontar para valores intermédios – ver Tabela 6. 2. Com o aumento dos nós verificou-se uma diminuição do erro de treino e conseqüentemente um aumento no erro de teste.

Nos	Treino				
	Max	Min	Erro Médio	MSE Normalizado	MSE
2	31,14473	-31,8003	4,187961	0,02764588	31,95863
24	31,35028	-31,6993	4,114413	0,02639861	30,5168
48	29,3579	-30,163	4,001996	0,0251449	29,0675

Nos	Teste				
	Max	Min	Erro Médio	MSE Normalizado	MSE
2	23,35293	-27,9544	0,63335	0,03403	31,6627
24	32,74753	-28,0377	0,734102	0,03755614	34,9366
48	36,26235	-32,6301	0,77686	0,03844534	35,76378

Tabela 6. 2 – Treino e teste com vários Nós

As funções de activação testadas incluíram a linear na camada de saída, e funções sigmoidais logarítmica e tangente hiperbólica nas camadas inferiores. Não verificando diferenças significativas optou-se por utilizar sempre a tangente hiperbólica.

Em relação ao número de iterações realizadas durante o processo de treino, foi utilizado um processo que consiste em testar durante o processo de treino a eficiência da rede num conjunto de dados de treino/validação, de modo a poder parar o processo em função do erro nesses dados e não necessariamente no de treino.

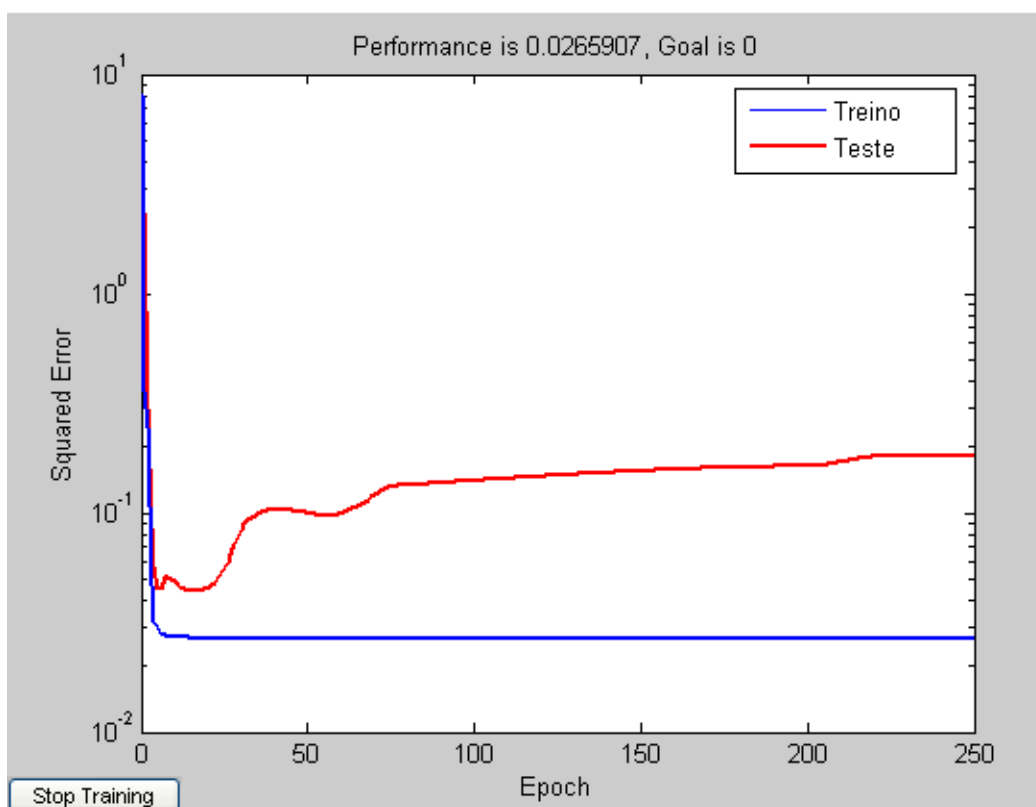


Figura 6. 3 – Treino e Teste

Relativamente aos dados utilizados dividiram-se em conjuntos de treino e teste numa relação aproximada (80/20%) e de forma a evitar repetição de dados e homogeneidade dos conjuntos.

Os resultados obtidos da rede foram sujeitos a um pós-processamento com o objectivo de reconverter para o intervalo de valores antecedentes ao pré-processamento.

Por último, é introduzido na rede treinada um novo conjunto de dados, nunca antes visto pela rede, para fazer um teste verificando, assim, a performance alcançada. Para poder avaliar a resposta referente a cada teste, foi feito uma análise comparativa entre a saída desejada e a previsão dada pelo sistema.

Os resultados obtidos sintetizam-se na Tabela 6. 4. As medidas de eficiência consideradas para além do erro quadrático médio utilizado no treino da rede, inclui esse valor após desnormalização, e valores extremos máximo e

mínimos. Nalguns casos efectuou-se uma análise de correlação entre os valores dados pela rede e os valores desejados.

6.1.2 Lógica Difusa “ANFIS”

Os dados que serviram de base para estudar o cruzamento com recurso às Redes Neurais foram utilizados com a Lógica Difusa Adaptativa, *ANFIS*. A arquitectura utilizada para a aplicação do ANFIS está ilustrada na Figura 6. 4.

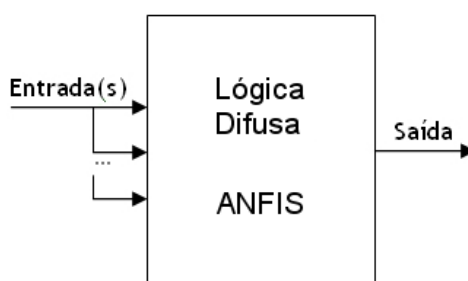


Figura 6. 4 – Arquitectura do treino/teste com LD - ANFIS

Este processo teve início quando os dados de entrada foram submetidos à fusificação, procedimento esse integrante do sistema difuso. Os dados são os mesmos utilizados na RNA, portanto, a verificação da repetibilidade já tinha sido feita.

Após a selecção dos dados é necessário gerar o sistema de conclusão difuso – selecção do número e tipo das respectivas funções de pertença. Também deve ser definido o erro admissível para parar o treino quando este é atingido, ou então, definir o número de iterações máximo do treino.

O método de optimização escolhido foi o híbrido em detrimento do backpropagation – ver capítulo 4.

De uma forma idêntica ao treino da RNA, na selecção dos dados é feita uma divisão, no qual 60 a 70% dos dados são de treino e 15 a 20% são para teste e validação. Quando é feito o treino são usados os dados seleccionados para treino e em simultâneo faz a validação. Por último, foi feito um teste e comparada a resposta dada com o desejado.

Os resultados obtidos sintetizam-se na Tabela 6. 5. As medidas de eficiência consideradas são as mesmas utilizadas pelo método anterior.

6.2 Cruzamento 4 ramos

O cruzamento de quatro ramos estudado tem a sua configuração ilustrada na Figura 6. 5.

Os dados utilizados no treino e no teste da rede neuronal foram recolhidos no cruzamento em estudo, durante 24 horas no mês de Maio, com intervalos de 5 minutos (no anexo D – encontram-se dados de dois dias). Comparando este cruzamento com o primeiro, o número de dados é substancialmente maior. Deve ser feita uma referência em relação aos dados recolhidos neste segundo cruzamento. Por algum motivo e esporadicamente, a contadora não guardava o valor do fluxo automóvel, ficando com zero nesses 5 minutos. A diferença de dados para treino, validação e teste é significativo ao ponto de melhorar os resultados da previsão.




Figura 6. 5 – Cruzamento de 4 ramos

A Tabela 6. 3 tem um resumo das hipóteses abordadas no 2º cruzamento tal como no primeiro cruzamento.

Hip.	Entrada	Entradas	Saída	Saídas
1ª	3	Fluxo Tráfego T	1	Fluxo Tráfego T+1
		Fluxo Tráfego ΔT [T-(T-1)]		
		Fluxo Tráfego T-2		
80% dos dados são para treino e 20% para teste. Os dados são relativos ao dia 1 [15/15 min]				
2ª	3	Fluxo Tráfego T	1	Fluxo Tráfego T+1
		Fluxo Tráfego ΔT [T-(T-1)]		
		Fluxo Tráfego T-2		
os dados correspondentes a 7 dias são para treino e do dia seguinte para teste. [5/5 min]				
3ª	3	Fluxo Tráfego T	1	Fluxo Tráfego T+1
		Fluxo Tráfego ΔT [T-(T-1)]		
		Fluxo Tráfego T-2		
os dados correspondentes a 3 semanas são para treino e uma semana para teste. [5/5 min]				
4ª	3	Fluxo Tráfego T	1	Fluxo Tráfego T+1
		Fluxo Tráfego ΔT [T-(T-1)]		
		Fluxo Tráfego T-2		
os dados correspondentes a 24 dias são para treino e os 7 dias seguintes para teste. [5/5 min]				
5ª	3	Fluxo Tráfego T	1	Fluxo Tráfego T+1
		Fluxo Tráfego T-1		
		Fluxo Tráfego T-2		
os dados correspondentes a 80% dos 31 dias são para treino e os restantes 20% para teste. [5/5 min]				
6ª	3	Fluxo Tráfego T	1	Fluxo Tráfego T+1

		Fluxo Tráfego T-1		
		Fluxo Tráfego T-2		
<p>Foi feita uma média móvel dos 3 valores antecedentes. O objectivo é atenuar a variação. Os dados correspondentes a 80% dos 31 dias são para treino e os restantes 20% para teste. [5/5 min]</p>				
7 ^a	3	Fluxo Tráfego T	1	Fluxo Tráfego T+1
		Fluxo Tráfego T-1		
		Fluxo Tráfego T-2		
<p>Foi feita uma média móvel ponderada dos 3 valores antecedentes. 0,5 para o valor actual; 0,3 para o valor antecedente e 0,2 para o mais afastado no tempo. O objectivo é atenuar a variação. Os dados correspondentes a 80% dos 31 dias são para treino e os restantes 20% para teste. [5/5 min]</p>				

Tabela 6. 3 – Resumo das experiências efectuadas

6.2.1 Backpropagation

A arquitectura, ilustrada na Figura 6. 2, corresponde à abordagem feita ao problema referente ao treino com recurso às RNA, tal como no primeiro cruzamento. O algoritmo utilizado e todos os cuidados necessários para a realização do treino, teste e validação são repetidos neste cruzamento. O objectivo é manter todas as condições na realização para assim ser feito uma comparação de resultados.

6.2.2 Lógica Difusa “ANFIS”

Os dados dos treinos efectuados com o recurso às RNAs são repetidos e estudados com o recurso ao ANFIS. A arquitectura utilizada é a mesma para a aplicação do ANFIS que está ilustrada na Figura 6. 4. Tal como no treino da rede neuronal, foram mantidas todas as condições do cruzamento anterior para ser feita uma comparação justa de resultados.

6.3 Análise de resultados

Apesar de alguns resultados serem satisfatórios, ficou a dúvida se com um maior número de dados os resultados seriam melhores. Após esta verificação passou-se para uma análise a outro cruzamento com um maior número de dados sobre o fluxo de tráfego. No primeiro problema havia 60 padrões para treino e no segundo passou-se para mais de 7000.

De seguida os resultados são dados em formato de tabela.

Em anexo E encontram-se os gráficos do teste referentes à hipótese estudada e com melhores resultados. Pode-se verificar que o sistema faz uma aproximação e uma previsão muito boas para o fluxo do tráfego automóvel. Este resultado é referente ao valor do teste feito com o valor médio dos dados armazenados.

6.3.1 Cruzamento 3 ramos em Y

6.3.1.1 Backpropagation

Hipótese	Erro Máximo	Erro Mínimo	Erro Quadrático Médio Normalizado
1 ^a	12,45852487 [fluxo]	-1,201372053 [fluxo]	0,2801
2 ^a	17,40603949 [atraso médio]	-16,87832949 [atraso médio]	0,63954133
3 ^a	16,68126944 [fluxo]	-6,453517912 [fluxo]	0,507809029
4 ^a	18,5356432 [fluxo]	-5,96087277 [fluxo]	0,455016451
5 ^a	19,3929 [fluxo]	-0,9664 [fluxo]	0,7828
6 ^a	52,04636794 [atraso médio]	-12,00935417 [atraso médio]	6,429624476
7 ^a	19,70875419 [atraso médio]	-10,65782504 [atraso médio]	0,818718572

Tabela 6. 4 – Erros verificados do teste na Rede Neuronal

6.3.1.2 Lógica Difusa “anfis”

Hipótese	Erro Máximo	Erro Mínimo	Erro Quadrático Médio
1 ^a	58,0077 [fluxo]	-54,4305 [fluxo]	-----
2 ^a	23,3437 [atraso médio]	-22,6502 [atraso médio]	-----
3 ^a	6,2295 [fluxo]	-19,070 [fluxo]	0,54517
4 ^a	55,041 [fluxo]	28,4916 [fluxo]	-----
5 ^a	26,4121 [fluxo]	-57,380 [fluxo]	-----
6 ^a	9,3551 [atraso médio]	-28,293 [atraso médio]	-----
7 ^a	11,6465 [atraso médio]	-8,3301 [atraso médio]	0,031244

Tabela 6. 5 – Erros verificados do teste na Lógica Difusa

6.3.2 Cruzamento 4 ramos

6.3.2.1 Backpropagation

Hipótese	Erro Máximo [fluxo]	Erro Mínimo [fluxo]	Erro Quadrático Médio
1 ^a	45,0201	-11,81072	-----
2 ^a	21,8781	-24,2021	0,365567
3 ^a	22,0884	-24,2022	----
4 ^a	22,5304	-27,9521	----
5 ^a	22,1574	-29,2013	----
6 ^a	12,09295	-11,9226	0,013943
7 ^a	16	-12	0,337681

Tabela 6. 6 – Erros verificados do teste na Rede Neuronal

6.3.2.2 Lógica Difusa “ANFIS”

Hipótese	Erro Máximo [fluxo]	Erro Mínimo [fluxo]	Erro Quadrático Médio
1 ^a	9,3024	-10,014	0,0121
2 ^a	22,3237	-24,386	0,1060
3 ^a	19	-19,451	0,0838
4 ^a	21,0205	-26,083	0,0584
5 ^a	22	-36,018	0,0324
6 ^a	22	-27,071	0,0489
7 ^a	23,678	-27	0,0491
8 ^a	28,331	-25,3325	0,0596
9 ^a	23,678	-14,6223	0,0385

Tabela 6. 7 – Erros verificados do teste na Lógica Difusa

7. Conclusões

7.1 Trabalho desenvolvido

O trabalho apresentado nesta Dissertação pretendia identificar estratégias de controlo de semáforos com o recurso às Redes Neurais Artificiais e à Lógica Difusa. Após uma análise inicial e caracterização dos aspectos associadas à gestão de tráfego urbano, decidiu-se concentrar os trabalhos apenas num problema em particular de previsão de variáveis de tráfego. Tendo no entanto presente um enquadramento global dessa situação particular.

Em particular testaram-se soluções para previsão do fluxo de tráfego nas vias de ligação aos semáforos, com base em redes neuronais do tipo “*Backpropagation*” e soluções híbridas baseadas em Lógica Difusa e Redes Neurais (“ANFIS”). Para verificar a utilidade destas ferramentas, utilizaram-se dados reais de fluxos de tráfego em dois cruzamentos diferentes.

Os resultados obtidos permitem verificar que é possível obter soluções adequadas tendo em conta tendências ou valores médios das variáveis. Também se verificou que existe uma grande dificuldade em obter soluções para modelar com um grau de eficiência elevado o comportamento discreto associado à evolução do fluxo de tráfego. Em particular em alguns casos extremos pontuais.

7.2 Possibilidades futuras

- Um dos aspectos que precisa de ser confirmado é avaliar se a qualidade da previsão obtida com os métodos testados tem utilidade na tomada de decisão ou controlo dos semáforos a um nível local ou a um nível mais global.

- Para ser feito um controlo global pode-se utilizar as RNAs ou ANFIS para preverem o fluxo em alguns pontos críticos em detrimento de sensores ou dispositivos de contagem. Assim, evitam-se gastos na colocação e na manutenção desses elementos.

- Prever o fluxo do tráfego automóvel nas entradas do cruzamento e ajudar o controlador (com a informação da previsão.) – Micro-controlo

- Integrar num sistema de controlo do tráfego a previsão de chegada dos veículos a um ou vários cruzamentos para o sistema antecipar correcções no controlo.

Bibliografia

-
- [1] J. P. Tavares, "Sistemas Centralizados de Controlo de Tráfego Urbano - Sua Avaliação: Aplicação do Caso na Cidade do Porto," in *Dissertação de Mestrado em Transportes, IST, Lisboa, Portugal*, 1994.
- [2] Leoncio Zárate, Ademar Ferreira, and S. R. Augusto, "Um novo sistema de controle neuro-fuzzy para trafego de veículos." São Paulo, Brasil. 2002.
- [3] W. Wei and M. Wang, "Traffic Signal Control Using Fuzzy And Neural Network," in *Department of Road and Traffic Engineering, Changsha Communications University*.
- [4] M. Patel and N. Ranganathan, "IDUTC: An Intelligent Decision-Making System for Urban Traffic-Control Applications," 2001.
- [5] J. M. G. Macedo, "Seleccção da tipologia de cruzamentos em função da procura," Faculdade de Engenharia da Universidade do Porto.
- [6] A. H. P. Costa, "Cruzamentos regulados por sinais luminosos," in *Engenharia Cívil*. Porto: Faculdade de Engenharia da Universidade do Porto, 1987.
- [7] *Manual on Uniform Traffic Control Devices*. Washington: U.S. Department of Transportation, 2003.
- [8] *Transportation Research Board*. Washington, D.C.: Speacial Report 209, 1985.
- [9] *Highway Capacity Manual*, 2000.
- [10] C. Pappis and E. Mamdani, "A fuzzy logic controller for a traffic junction.," *IEEE Trans. Systems Man Cybernet*, SMC-7 (10):707-717, 1977.
- [11] w. Pedrycz and F. Gomide, "An introduction to fuzzy sets-analysis and design, MIT Press, Cambridge, MA.," 1998.
- [12] Trabia and Kaseko, "A two-stage fuzzy logic controller for a traffic signals, Transportation Research Part C7: 353-367," 1999.
- [13] Nakatsuyama, M. Nagahashi, and Nishizuka, "Fuzzy Logic phase contoller for a traffic junctions in the one-way arterial raod," *Proceedings of the IFAC Ninth Triennial World Congress, Pergamon Press, Oxford, 2865-2870*, 1984.
- [14] Kelsey and Bisset, "Simulation of traffic flow and control using fuzzy conventional methods," *In: Jamshidi, Fuzzy Logic and control: software and hardware applications. Prentice-Hall, Englewood Cliffs, NJ, 262-278*, 1993.
- [15] Chiu, "Adaptive traffic signal control using fuzzy logic," *Proceedings of the IEEE Intelligent vehicles Symposium, 98-107*, 1992.
- [16] Chiu and Chang, "Adaptive traffic Signal Control Using Fuzzy Logic," *Proceedings of the IEEE International Conference on Fuzzy Systems, 1371-1376*, 1993.
- [17] Tzes, McShade, and Kim, "Expert Fuzzy Logic Traffic Signal Control for Transportation Engineers 65th Annual Meeting, Denver USA 154-158," 1995.
- [18] R. Hoyer and U. Jumar, "Fuzzy Control of Traffic Lights," *IEEE International Conference on Fuzzy, 1526-1531*, 194.

-
- [19] J. Niittymaki and M. Pursula, "Signal Control using fuzzy logic. Fuzzy sets and Systems, 116: 11-22," 2000.
- [20] D. A. Pomerleau, "Vision and Navigation: The CMU Navlab," *Boston, MA: Kluwer*, 1990.
- [21] A. Niehaus and R. F. Steged, "An expert system for automated highway driving," *IEEE Control Syst. Mag.*, Vol 11, pp. 53-61, 1991.
- [22] M. Maskarinec, "An expert system accident avoidance system for an autonomous highway vehicle," in *Proc. 6th IASTED Int. Symp.*, vol C4, pp.20-23, 1989.
- [23] S. G. Ritchie and N. A. Prosser, "Real-time expert system approach to freeway incident management," *Transportation Res. Rec.* 1320, pp.7-16, 1993.
- [24] B. Freisleben and T. Kunkelman, "Combining fuzzy logic and neural networks to control an autonomous vehicle," in *Proc. IEEE Int. Conf. Fuzzy Systems*, Vol 1, pp. 321-326, 1993.
- [25] V. Altrock, B. Krause, and H. J. Zimmerman, "Advanced fuzzy logic control an autonomous vehicle," in *Proc. IEEE Int. Conf. Fuzzy Systems*, Vol 1, pp. 835-842, 1992.
- [26] J. Favilla, A. Machion, and F. Gomide, "Fuzzy traffic control: Adaptive strategies," In *Proc. IEEE Int. Conf. Fuzzy Systems*, Vol 1, pp. 506-511, 1993.
- [27] M. Sugeno and K. Murakami, "Fuzzy parking control of model car," *Proc. 23rd IEEE Conf. Decision and Control*, vol 2, 1984.
- [28] S. Chiu and S. Chand, "Adaptive traffic signal control using fuzzy logic," in *Proc. Int. Conf. Fuzzy Syst.*, vol 2, pp.1371-1376, 1993.
- [29] M. I. Patel and N. Ranganathan, "An Intelligent System Architecture for Urban Traffic Control Applications," 1996.
- [30] L. Prechelt, "A Set of Neural Network Benchmark Problems and Benchmarking Rules," Fakultat fur Informatik Universitat Karlsruhe Germany 1994.
- [31] S. Russell and P. Norving, "Artificial Intelligence: A Modern Approach," in *Prentice-Hall*. New Jersey USA, 1995.
- [32] H. Chen, S. Grant-Muller, L. Mussone, and F. Montgomery, "A Study of Hibrid Neural Network Approaches and the Effects of Missing Data onTraffic Forecasting," 2001.
- [33] D. Hebb, *The Organization of Behaviour*. New York: JohnWiley, 1949.
- [34] T. Kohonen, *Self-Organization and Associative Memory*: Springer, 1987.
- [35] D. E. Rumelhart, J. L., and M. a. t. PDP, *Parallel Distributed processing Explorations in the Microstructure of cognition*.
- [36] E. Azoff, *Neural Network Time Series Forecasting of Financial Markets*. New York, USA: John Wiley & Sons, 1995.
- [37] T. Khanna, *Foundations of Neural Networks*, 1990.
- [38] c. M. Bishop, *Neural Network for pattern recognition*, 1995.
- [39] I. Aleksander and H. Morton, *An Introditionto Neural Computing*
- [40] *Manual Matlab The language of Technical Computing*.

Anexos

A- Definições

- Ciclo – Sequência total de indicações de um semáforo (suposta repetitiva);
- Tempo de ciclo – Tempo necessário para completar um ciclo, medido em segundos e definido como T;
- Fase – Parte do ciclo destinada a uma qualquer combinação de movimentos que recebem permissão para avançar. Uma fase pode acomodar um movimento protegido ou permitido. (Um movimento permitido é aquele que tem lugar em conflito com um fluxo de veículos ou peões, os movimentos protegidos são aqueles que se executam sem esses conflitos);
- Intervalo – Período de tempo em que todos os sinais se mantêm constantes;
- Tudo-vermelho – Intervalo em que o vermelho se encontra aceso para todas as fases
- Tempo perdido – Tempo em que a intersecção não está a ser utilizada por nenhum dos movimentos, L;
- Tempo de mudança – Soma dos tempos de ‘amarelo’ e ‘tudo vermelho’ que ocorrem entre fases e que existem para permitir a limpeza do cruzamento, medido em segundos e definido pela letra Y;
- Tempo de verde – tempo em que, durante uma dada fase, a luz verde aparece. Medido em segundos e identificado como G_i (para a fase i);
- Tempo de verde efectivo – Tempo, durante uma fase, que é efectivamente utilizado para permitir os movimentos, é geralmente igual ao tempo de verde mais o intervalo de mudança menos o tempo perdido para a fase i, medido em segundos e designado por g_i (para a fase i);
- Rácio de verde – Relação entre o tempo verde efectivo e o tempo de ciclo g_i/T (p/ a fase i)

-
- Vermelho efectivo – Tempo, durante um ciclo, em que um movimento (ou conjunto de movimentos) não tem permissão para avançar. É medido em segundos e identificado por ri (para a fase i);
 - Volume de Tráfego – Um volume de tráfego pode ser definido como o número de veículos que circulam num determinado ponto da via durante um intervalo de tempo.
 - Volumes diários e sua utilização – é frequente utilizar-se como intervalo de tempo para a definição dos volumes o dia. São usados geralmente como base para o planeamento de novas estradas e observação das tendências de crescimento de tráfego. Entre estes volumes diários destacam-se dois:
 - Tráfego médio diário anual (TMDA) – média dos volumes de tráfego medidos num determinado local nas 24 horas do dia e ao longo de 365 dias por ano, ou seja, é o número total de veículos que atravessou uma dada secção, dividido por 365;
 - Tráfego médio diário (TMD) – média dos volumes de tráfego medidos num determinado local nas 24 horas do dia mas ao longo de um período inferior a um ano. Enquanto o TMDA é para um ano inteiro um TMD pode ser medido para seis meses, uma estação, um mês, uma semana ou até para dois dias. Um TMD é válido apenas para o período de tempo em que é medido.
 - Volumes horários e sua utilização – Apesar dos volumes de tráfego diários serem importantes para o planeamento não são os únicos a ser utilizados no projecto de novas vias e também em termos operacionais.
 - Velocidade – é definida como a distância percorrida numa unidade de tempo. Num dado fluxo de tráfego, cada veículo viaja a uma determinada velocidade o que implica que não haverá uma só velocidade homogénea mas sim uma distribuição de velocidades individuais de cada veículo. Dessa distribuição discreta de velocidades recorre-se então à média para caracterizar o fluxo como um todo:

-
- Velocidade Média No Tempo – definida como a velocidade média de todos os veículos que atravessam um ponto da via em determinado período;
 - Velocidade Média No Espaço – definida como a velocidade média de todos os veículos que ocupam uma secção da via em determinado período.
 - Filas de espera – 3 elementos fundamentais para a caracterização:
 - Mecanismo de chegadas - a forma como os clientes chegam ao sistema. É caracterizado por uma cadência de chegadas (λ) e por uma distribuição (normalmente é uma distribuição Poisson)
 - Mecanismo de serviço - é descrito pela taxa de serviço (μ), a distribuição, o número de postos de serviço.
 - Disciplina de fila - é constituído pelas regras de escolha do próximo cliente a ser servido (FIFO - first in first out, LIFO - last in first out)
 - Fluxo de Saturação – é definido como o fluxo máximo que pode atravessar uma dada intersecção, sob as condições existentes, admitindo que aquele grupo de pistas dispõe de 100% de tempo de verde, identificando-se como s e definido em veíc./hverde (veículos por hora de verde).
 - Trânsito – é um problema do quotidiano a que nos habituamos de tal forma que raramente o analisamos em profundidade. Mas, sendo ele o objecto de estudo, vamos analisa-lo e descreve-lo de uma forma mais objectiva.
 - Intervenientes dinâmicos - os veículos e os peões.
 - Intervenientes estáticos - as infra-estruturas:
 - Estrada;
 - Auto-estrada;
 - Rotundas.

- Sinalização vertical e horizontal: sistemas de regulação de trânsito que alteram de alguma forma a movimentação dos veículos.
- As combinações possíveis de situações são de tal forma elevado que vamos limitar as hipóteses para o estudo apenas ao trânsito urbano. A regulação será apenas os mecanismos baseados em semáforos.
- Também é necessário caracterizar o trânsito do ponto de vista de quem estuda o fenómeno. Os pontos habitualmente usados são:
 - Velocidades médias de deslocação;
 - Paragens por veículo;
 - Tempos médios de espera por veículos;
 - Escoamento de veículos por hora;
 - Veículos por quilómetros percorridos;
 - Comprimento médio das filas de espera.
- Gestão de trânsito - é um problema complexo do ponto de vista de análise e sua resolução.
- Problemas de escala:
 - número de intervenientes;
 - tamanho;
 - complexidade.

B- Min e Max (premnmx, postmnmx, tramnmx):

Antes de treinar é útil escalar as entradas e os objectivos para que eles se encontrem dentro de uma gama especificada. A função “premnmx” pode ser usada para escalar as entradas e os objectivos para que eles variem no intervalo de [-1, 1]. O código seguinte ilustra o uso desta função.

$p = R \times Q$ – matriz de entrada

$t = S \times Q$ – matriz objectiva

$[pn, minp, maxp, tn, mint, maxt] = \text{premnmx}(p,t)$;

$\text{net} = \text{train}(\text{net}, pn, tn)$;

O algoritmo utilizado para o pré-processamento é:

$$pn = 2 \times \frac{p - \text{minp}}{\text{maxp} - \text{minp}} - 1;$$

As entradas originais da rede e os objectivos são determinados nas matrizes “p” e “t”. As entradas normalizadas e os objectivos, “pn” e “tn” que são devolvidos estão compreendidos no intervalo [-1,1]. Os vectores “minp” e “maxp” contêm o mínimo e o máximo das entradas originais, os vectores “mint” e “maxt” contêm o mínimo e máximo dos objectivos originais. Depois da rede treinada, estes vectores deveriam ser usados para transformar qualquer entrada futura que é aplicada à rede. Eles tornam-se uma parte da rede efectivamente, bem como os pesos da rede e suas condições.

Se o “premnmx” é usado para escalar as entradas e os objectivos, então a saída da rede será treinada para fornecer a saída compreendida entre [-1,1]. Se quiser converter estas saídas atrás nas mesmas unidades que eram usadas para os objectivos originais, então devesse usar o “postmnmx”. No código seguinte, nós simulamos a rede que foi treinada no código prévio, e então converte a rede produzida atrás nas unidades originais.

$an = \text{sim}(\text{net}, pn)$;

$a = \text{postmnmx}(an, mint, maxt)$;

O algoritmo utilizado para o pós-processamento, após o treino da rede, é:

$$p = 0,5(pn + 1) \times (\text{maxp} - \text{minp}) + \text{minp}$$

A saída da rede corresponderá aos objectivos normalizados “tn”. A saída da rede “desnormalizada” está na mesma unidade do objectivo original “t”.

Se o “premnmx” é usado para pré-processar os dados de treino, então sempre que a rede treinada é usada com entradas novas eles deveriam ser processados no mesmo contexto, com o mínimo e máximo que foram computados para o conjunto de treino. Isto pode ser realizado com o “tramnmx”. No código seguinte, nós aplicamos um conjunto novo de entradas na rede que já treinamos.

```
pnewn = tramnmx(pnew, minp, maxp) ;
```

```
anewn = sim(net, pnewn) ;
```

```
anew = postmnmx(anewn, mint, maxt) ;
```

O algoritmo utilizado para a introdução de dados novos com o mesmo máximo e mínimo do treino da rede, é:

$$pn = 2 \times \frac{p - \text{minp}}{\text{maxp} - \text{minp}} - 1 ;$$

C- Dados – Cruzamento 3 ramos em Y

Período	Movimentos (u.v.l./15 min)						Atraso médio por veículo (seg)					
	1	2	3	4	5	6	1	2	3+4	5	6	
06:00 às 06:15	10	27	20	28	5	2	22	3	8	21	20	
06:15 às 06:30	13	29	27	33	17	5	24	3	8	25	21	
06:30 às 06:45	17	25	53	33	15	5	28	2	9	27	24	
06:45 às 07:00	14	41	33	28	9	11	24	3	8	22	23	
07:00 às 07:15	23	44	29	49	7	3	30	3	9	23	22	
07:15 às 07:30	39	51	57	83	23	11	34	2	13	39	31	
07:30 às 07:45	43	60	41	49	25	14	23	3	14	31	25	
07:45 às 08:00	53	78	53	72	40	23	32	4	18	35	27	
08:00 às 08:15	30	68	53	32	33	15	23	4	13	22	18	
08:15 às 08:30	52	91	64	51	57	23	33	5	21	32	22	
08:30 às 08:45	38	90	37	66	27	14	25	3	14	28	22	
08:45 às 09:00	55	73	57	79	47	23	37	4	21	39	28	
9:00 às 9:15	36	86	39	72	38	25	29	4	15	28	24	
9:15 às 9:30	36	66	53	68	42	20	32	4	16	30	23	
9:30 às 9:45	20	71	30	48	46	22	26	6	14	21	18	
9:45 às 10:00	29	61	54	53	51	19	31	5	16	25	19	
10:00 às 10:15	29	69	42	46	62	15	29	6	17	21	15	
10:15 às 10:30	16	73	65	62	46	21	32	5	14	30	24	
10:30 às 10:45	13	84	52	48	39	22	25	5	13	25	21	
10:45 às 11:00	11	91	59	54	32	28	25	4	12	28	28	
11:00 às 11:15	19	89	63	53	36	19	30	4	13	28	24	
11:15 às 11:30	22	61	39	38	63	36	30	7	17	20	17	
11:30 às 11:45	17	67	38	49	49	20	26	6	15	22	18	
11:45 às 12:00	16	62	44	31	43	46	24	6	15	19	20	
12:00 às 12:15	14	75	56	31	52	33	25	6	15	22	19	
12:15 às 12:30	12	62	51	67	52	54	30	5	16	26	28	
12:30 às 12:45	22	85	22	35	40	67	32	9	16	16	20	
12:45 às 13:00	25	69	41	43	45	29	30	5	14	22	19	
13:00 às 13:15	39	65	49	63	37	33	28	4	15	29	29	
13:15 às 13:30	40	70	47	65	35	29	28	3	15	29	28	
13:30 às 13:45	26	73	48	82	34	28	39	4	12	32	30	
13:45 às 14:00	51	59	53	88	36	25	35	3	18	39	32	
14:00 às 14:15	22	47	43	62	33	34	30	4	13	25	27	
14:15 às 14:30	22	59	50	62	47	24	33	5	14	27	22	
14:30 às 14:45	21	55	62	59	49	34	35	5	15	28	25	
14:45 às 15:00	26	77	56	78	46	32	37	4	15	31	26	
15:00 às 15:15	21	60	62	63	53	28	36	5	15	29	24	
15:15 às 15:30	22	104	35	55	49	23	31	6	14	24	20	
15:30 às 15:45	16	98	34	68	63	29	31	7	17	25	20	
15:45 às 16:00	21	64	64	58	59	45	37	6	16	28	26	
16:00 às 16:15	23	44	53	65	57	35	39	5	16	28	23	
16:15 às 16:30	24	51	59	53	46	31	35	4	14	27	24	
16:30 às 16:45	20	78	50	57	59	36	33	6	16	26	22	
16:45 às 17:00	19	89	47	50	51	29	29	6	15	24	20	
17:00 às 17:15	23	134	59	62	59	39	41	7	16	29	25	
17:15 às 17:30	15	106	46	56	48	46	28	6	15	25	25	
17:30 às 17:45	19	83	38	46	51	41	27	6	15	21	20	

17:45 à 18:00	14	95	40	65	63	38	30	7	17	25	21
18:00 à 18:15	9	103	40	49	58	45	26	7	15	24	22
18:15 à 18:30	9	120	39	45	52	46	27	7	13	27	26
18:30 à 18:45	14	86	43	54	49	46	27	6	15	24	24
18:45 à 19:00	9	50	30	97	55	37	30	5	16	31	26
19:00 à 19:15	2	49	16	74	56	44	23	6	16	23	21
19:15 à 19:30	6	67	33	33	51	16	21	7	15	18	15
19:30 à 19:45	8	59	18	32	39	18	19	6	13	17	15
19:45 à 20:00	2	52	5	48	31	14	18	5	12	18	16
20:00 à 20:15	7	42	15	24	34	18	18	6	14	15	14
20:15 à 20:30	4	35	21	31	30	14	18	4	12	17	16
20:30 à 20:45	6	41	10	16	28	17	17	5	12	15	14
20:45 à 21:00	3	42	18	26	20	5	16	4	11	17	15
21:00 à 21:15	7	46	8	12	15	6	21	3	7	23	21
21:15 à 21:30	4	35	9	7	18	7	16	4	10	16	14
21:30 à 21:45	5	41	19	22	10	11	20	3	8	21	22
21:45 à 22:00	1	27	4	6	11	6	18	3	7	20	19

D – Cruzamento 4 ramos

<i>Minute</i>	<i>CT12 5Minutes Z:2 01/05/06</i>	<i>Minute</i>	<i>CT12 5Minutes Z:2 02/05/06</i>
0:05	13	0:05	13
0:10	20	0:10	10
0:15	12	0:15	10
0:20	16	0:20	9
0:25	14	0:25	10
0:30	15	0:30	10
0:35	12	0:35	10
0:40	13	0:40	10
0:45	14	0:45	10
0:50	13	0:50	6
0:55	15	0:55	9
1:00	13	1:00	4
1:05	10	1:05	12
1:10	14	1:10	7
1:15	9	1:15	8
1:20	12	1:20	1
1:25	8	1:25	9
1:30	10	1:30	2
1:35	5	1:35	4
1:40	7	1:40	7
1:45	5	1:45	2
1:50	4	1:50	5
1:55	4	1:55	6
2:00	7	2:00	6
2:05	15	2:05	3
2:10	8	2:10	3
2:15	5	2:15	3
2:20	6	2:20	7
2:25	6	2:25	3
2:30	6	2:30	1
2:35	3	2:35	4
2:40	3	2:40	1
2:45	10	2:45	3
2:50	4	2:50	4
2:55	6	2:55	3
3:00	9	3:00	4
3:05	7	3:05	2
3:10	3	3:10	3
3:15	4	3:15	3
3:20	3	3:20	2
3:25	2	3:25	3
3:30	3	3:30	2
3:35	5	3:35	3
3:40	4	3:40	1
3:45	3	3:45	2
3:50	4	3:50	1
3:55	6	4:00	4
4:00	1	4:05	4

4:05	1	4:10	1
4:10	1	4:15	2
4:15	8	4:20	1
4:20	1	4:25	2
4:25	2	4:30	2
4:30	1	4:35	4
4:35	3	4:40	2
4:40	5	5:00	4
4:45	3	5:10	1
4:50	4	5:15	1
4:55	1	5:20	2
5:00	2	5:25	3
5:05	3	5:30	4
5:10	1	5:40	2
5:15	4	5:45	2
5:25	3	5:50	2
5:30	4	5:55	4
5:35	2	6:00	6
5:40	1	6:05	11
5:45	2	6:10	5
5:50	2	6:15	3
5:55	3	6:20	7
6:00	7	6:25	4
6:05	4	6:30	3
6:10	6	6:35	11
6:15	2	6:40	7
6:20	2	6:45	10
6:25	4	6:50	11
6:35	2	6:55	13
6:40	7	7:00	10
6:45	3	7:05	16
6:50	5	7:10	17
6:55	3	7:15	12
7:00	5	7:20	12
7:05	2	7:25	18
7:10	5	7:30	22
7:15	6	7:35	28
7:20	4	7:40	28
7:25	5	7:45	32
7:30	5	7:50	32
7:35	5	7:55	35
7:40	4	8:00	43
7:45	5	8:05	34
7:50	13	8:10	47
7:55	7	8:15	36
8:00	7	8:20	45
8:05	10	8:25	42
8:10	5	8:30	50
8:15	6	8:35	43
8:20	10	8:40	62
8:25	9	8:45	55
8:30	12	8:50	50

8:35	4	8:55	51
8:40	10	9:00	48
8:45	7	9:05	35
8:50	6	9:10	37
8:55	14	9:15	36
9:00	10	9:20	55
9:05	11	9:25	43
9:10	15	9:30	47
9:15	11	9:35	49
9:20	12	9:40	47
9:25	15	9:45	49
9:30	8	9:50	56
9:35	14	9:55	44
9:40	13	10:00	35
9:45	23	10:05	47
9:50	18	10:10	38
9:55	9	10:15	39
10:00	3	10:20	40
10:05	7	10:25	48
10:10	16	10:30	39
10:15	10	10:35	32
10:20	9	10:40	36
10:25	11	10:45	46
10:30	7	10:50	44
10:35	23	10:55	29
10:40	28	11:00	35
10:45	17	11:05	34
10:50	16	11:10	40
10:55	18	11:15	31
11:00	17	11:20	37
11:05	22	11:25	37
11:10	20	11:30	40
11:15	20	11:35	43
11:20	28	11:40	52
11:25	23	11:45	40
11:30	19	11:50	30
11:35	46	11:55	33
11:40	45	12:00	30
11:45	45	12:05	27
11:50	36	12:10	40
11:55	31	12:15	31
12:00	14	12:20	40
12:05	15	12:25	44
12:10	20	12:30	34
12:15	16	12:35	30
12:20	14	12:40	28
12:25	11	12:45	27
12:30	14	12:50	23
12:35	20	12:55	29
12:40	14	13:00	24
12:45	15	13:05	38
12:50	15	13:10	31

12:55	13	13:15	27
13:00	18	13:20	30
13:05	17	13:25	19
13:10	12	13:30	24
13:15	7	13:35	21
13:20	15	13:40	27
13:25	5	13:45	33
13:30	10	13:50	33
13:35	17	13:55	40
13:40	12	14:00	39
13:45	19	14:05	45
13:50	11	14:10	39
13:55	17	14:15	34
14:00	18	14:20	43
14:05	21	14:25	35
14:10	17	14:30	38
14:15	20	14:35	43
14:20	13	14:40	44
14:25	19	14:45	34
14:30	24	14:50	36
14:35	29	14:55	47
14:40	19	15:00	40
14:45	32	15:05	38
14:50	30	15:10	45
14:55	29	15:15	53
15:00	31	15:20	34
15:05	28	15:25	36
15:10	32	15:30	41
15:15	30	15:35	35
15:20	30	15:40	38
15:25	26	15:45	38
15:30	38	15:50	39
15:35	27	15:55	38
15:40	37	16:00	37
15:45	35	16:05	40
15:50	46	16:10	46
15:55	36	16:15	37
16:00	23	16:20	42
16:05	28	16:25	29
16:10	28	16:30	41
16:15	37	16:35	34
16:20	34	16:40	33
16:25	25	16:45	32
16:30	25	16:50	30
16:35	20	16:55	36
16:40	22	17:00	33
16:45	14	17:05	26
16:50	29	17:10	38
16:55	27	17:15	40
17:00	28	17:20	24
17:05	25	17:25	28
17:10	37	17:30	33

17:15	30	17:35	29
17:20	21	17:40	36
17:25	15	17:45	36
17:30	17	17:50	24
17:35	22	17:55	30
17:40	25	18:00	29
17:45	21	18:05	32
17:50	22	18:10	22
17:55	20	18:15	32
18:00	23	18:20	19
18:05	27	18:25	31
18:10	24	18:30	29
18:15	21	18:35	32
18:20	13	18:40	26
18:25	21	18:45	27
18:30	20	18:50	28
18:35	19	18:55	28
18:40	16	19:00	30
18:45	19	19:05	24
18:50	16	19:10	17
18:55	22	19:15	27
19:00	12	19:20	31
19:05	26	19:25	30
19:10	22	19:30	21
19:15	19	19:35	33
19:20	25	19:40	24
19:25	18	19:45	1
19:30	23	19:50	16
19:35	15	19:55	25
19:40	11	20:00	26
19:45	15	20:05	16
19:50	26	20:10	17
19:55	22	20:15	23
20:00	9	20:20	19
20:05	13	20:25	14
20:10	11	20:30	21
20:15	21	20:35	21
20:20	10	20:40	18
20:25	9	20:45	24
20:30	11	20:50	22
20:35	20	20:55	25
20:40	18	21:00	21
20:45	15	21:05	13
20:50	15	21:10	16
20:55	17	21:15	21
21:00	9	21:20	18
21:05	18	21:25	20
21:10	20	21:30	31
21:15	20	21:35	25
21:20	14	21:40	21
21:25	22	21:45	28
21:30	19	21:50	17

21:35	21	21:55	23
21:40	19	22:00	10
21:45	15	22:05	19
21:50	18	22:10	16
21:55	23	22:15	19
22:00	21	22:20	25
22:05	21	22:25	19
22:10	18	22:30	19
22:15	17	22:35	20
22:20	12	22:40	21
22:25	15	22:45	21
22:30	18	22:50	11
22:35	16	22:55	16
22:40	14	23:00	19
22:45	21	23:05	15
22:50	9	23:10	21
22:55	16	23:15	15
23:00	16	23:20	17
23:05	19	23:25	18
23:10	12	23:30	17
23:15	12	23:35	15
23:20	17	23:40	15
23:25	17	23:45	13
23:30	18	23:50	9
23:35	16	23:55	18
23:40	13	24:00:00	14
23:45	6		
23:50	13		
23:55	12		
24:00:00	10		

E – Cruzamento 4 ramos


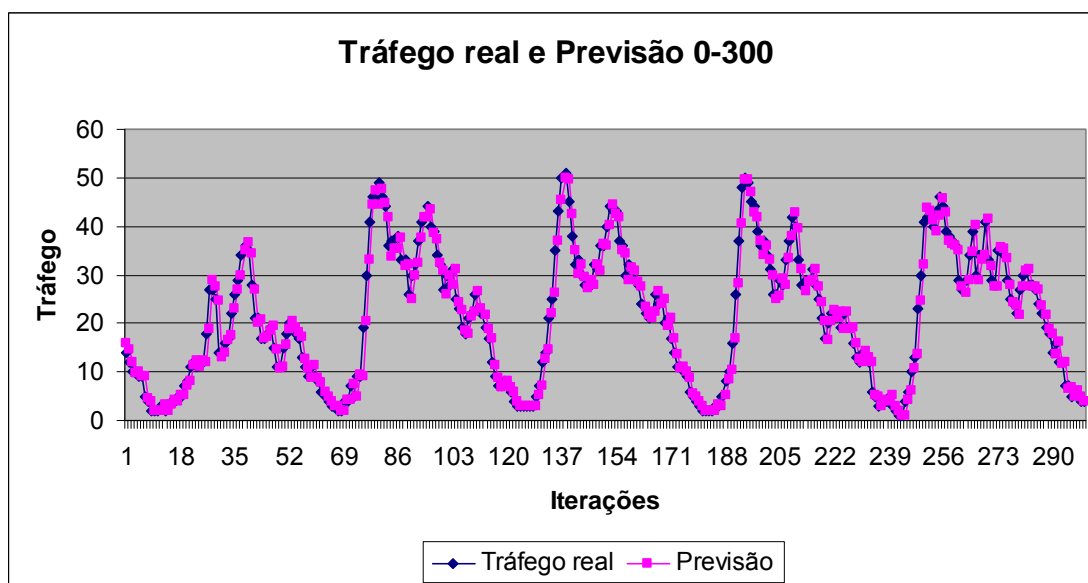
Gráficos RNAs:



Os excertos dos gráficos a baixo mostram a previsão após o treino e respectivo teste.

Erro max: 12,0930

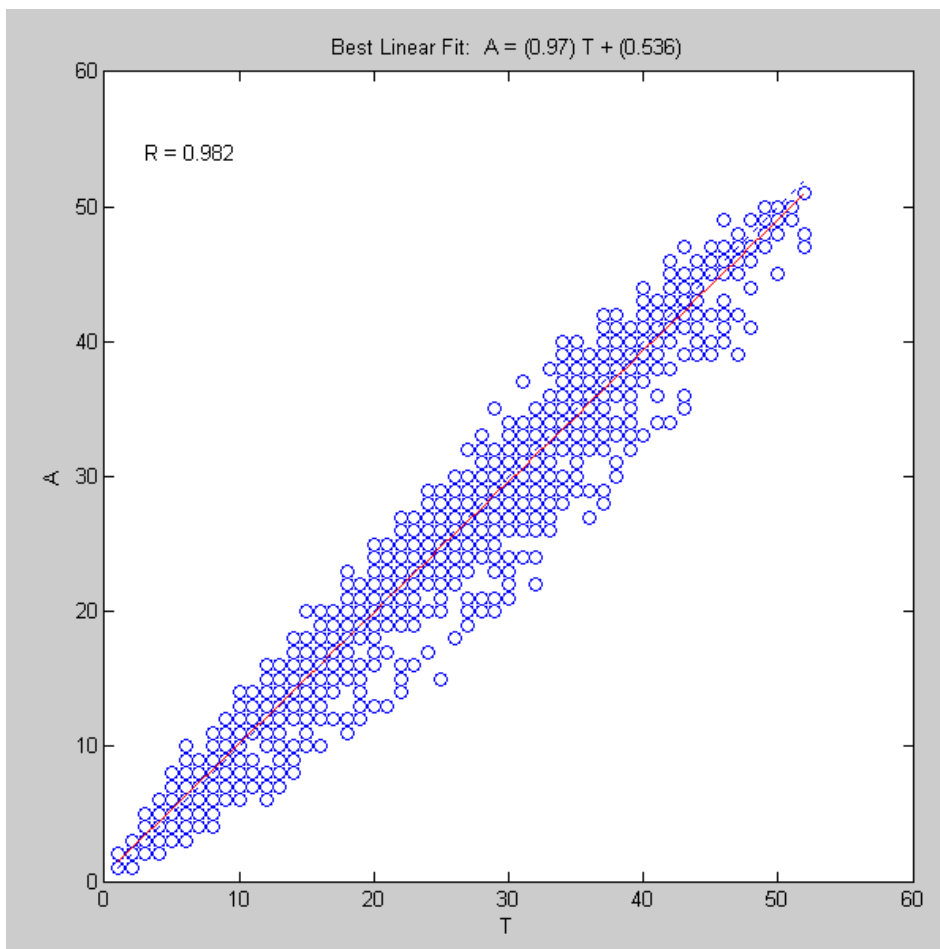
Erro min: -11,9226

MSE = 0,01394










Tem um coeficiente de correlação de 0,982.



Gráficos Lógica Difusa: 7ª Hipótese

Erro Max absoluto = 23,678 MSE = 0,0489





Tem um coeficiente de correlação de 0,902

