

UNIVERSIDADE ESTADUAL DE CAMPINAS

FACULDADE DE ENGENHARIA ELÉTRICA

DEPARTAMENTO DE ENGENHARIA DE COMPUTAÇÃO E
AUTOMAÇÃO INDUSTRIAL

**Grupos Neurais e Sistemas Nebulosos: Aplicação à
Navegação Autônoma.**

Autor: João Alberto Fabro

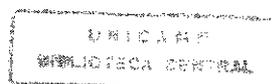
Orientador: Prof. Dr. Fernando Antonio Campos Gomide

Este exemplar corresponde à redação final da tese
defendida por João Alberto Fabro
e aprovada pela Comissão
Julgadora em 27/02/96.

Orientador

Dissertação apresentada à Faculdade
de Engenharia Elétrica da Universidade
Estadual de Campinas-FEE/UNICAMP
como parte dos requisitos exigidos
para a obtenção do título de MESTRE
EM ENGENHARIA ELÉTRICA.

Fevereiro 1996



UNIVERSIDADE	BC
UNIVERSIDADE	UNICAMP
DATA	1996
Nº	8
PREÇO	27612
PREÇO	667196
C	<input type="checkbox"/>
D	<input checked="" type="checkbox"/>
PREÇO	8411,00
DATA	03/05/96
Nº OFD	

CM-00087718-0

FICHA CATALOGRÁFICA ELABORADA PELA
BIBLIOTECA DA ÁREA DE ENGENHARIA - BAE - UNICAMP

F116g Fabro, João Alberto
Grupos neurais e sistemas nebulosos: aplicação à
navegação autônoma / João Alberto Fabro.--Campinas,
SP: [s.n.], 1996.

Orientador: Fernando Antonio Campos Gomide.
Dissertação (mestrado) - Universidade Estadual de
Campinas, Faculdade de Engenharia Elétrica.

1. Redes neurais (Computação). 2. Inteligência
artificial. 3. Conjuntos nebulosos. I. Gomide, Fernando
Antonio Campos. II. Universidade Estadual de Campinas.
Faculdade de Engenharia Elétrica. III. Título.

**Dedico este trabalho à minha família, pelo apoio,
e à Michele, pela compreensão e paciência.**

“It’s clearly useful to have machines doing jobs that are insufficient for the human brain and thus leave human beings the possibility of devoting themselves to more creative labors that will stretch and expand their minds.”

Isaac Asimov, 1920-1992

Resumo

Neste trabalho é apresentada uma arquitetura de controle para navegação de veículos autônomos, usando auto-organização e técnicas de redes neurais e lógica nebulosa. O objetivo é encontrar alvos posicionados em um ambiente desconhecido, sem entretanto colidir com obstáculos. A arquitetura faz uso da teoria dos grupos neurais, de redes neurais e sistemas nebulosos, para o aprendizado de habilidades de navegação. Sensores neurais/nebulosos são utilizados para fornecer informações que possibilitem aos campos adaptativos ativarem ações nebulosas em resposta às características encontradas no ambiente. Ou seja, o sistema de controle desenvolve um comportamento adaptativo através das interações entre o veículo e o ambiente, e de estratégias de aprendizado. Resultados de simulação mostram que o sistema apresenta capacidade de aprender estratégias de navegação que proporcionam um melhor desempenho quando comparadas com esquemas alternativos utilizados para a solução do mesmo problema.

Abstract

In this work a self organizing, neurofuzzy control architecture for a class of autonomous vehicles' navigation is presented. The aim is to find target positions, without colliding with obstacles of an unknown environment. The architecture uses neural networks and fuzzy systems together with the theory of neuronal group selection to learn navigation skills. Neurofuzzy sensor information builds up adaptive fields whose intensity triggers fuzzy control actions in response to the environment characteristics. That is, the control system develops adaptive behavior from the interactions between the vehicle, the environment, and learning strategies. Simulation results show that the control system is able to efficiently learn navigation strategies that perform better when compared with alternative schemes.

Agradecimentos

Meus sinceros agradecimentos a todos que me auxiliaram, de alguma forma, a chegar à conclusão deste trabalho:

- Ao prof . Fernando Gomide, pela confiança e pelo apoio;
- Aos colegas Andrey, Carlos e Edson, pela amizade, confiança e incentivo, e por serem minha segunda família nestes anos aqui em Campinas;
- Ao Maurício, pelas discussões sobre assuntos correlatos ou não à este trabalho;
- Às professoras Carmem Satie Hara e Miriam Halfeld Ferrari Alves, e ao professor Marcos Alexandre Castilho, por acreditarem em mim e me incentivarem a seguir meus sonhos.

Conteúdo

RESUMO:.....	iii
ABSTRACT	iv
AGRADECIMENTOS.....	iv
CONTEÚDO	vi
LISTA DE FIGURAS	viii
1. INTRODUÇÃO.....	1
1.1. SISTEMAS AUTÔNOMOS	1
1.2. FORMULAÇÃO DO PROBLEMA	1
1.3. MOTIVAÇÃO E RELEVÂNCIA	2
1.4. OBJETIVOS	3
1.5. ORGANIZAÇÃO DA TESE	3
2. FUNDAMENTOS TEÓRICOS	4
2.1 INTRODUÇÃO.....	4
2.2 REDES NEURAIS	4
2.2.1. <i>Introdução</i>	4
2.2.2. <i>Aprendizado</i>	6
2.2.3. <i>Classificação das Redes Neurais</i>	7
2.2.4. <i>Redes Multicamadas</i>	9
2.2.5. <i>Redes Concorrentes</i>	10
2.2.5.1. <i>Rede auto-organizável de Kohonen</i>	11
2.3. SISTEMAS NEBULOSOS.....	12
2.3.1. <i>Definições e Operações sobre Conjuntos Nebulosos</i>	13
2.3.2. <i>Produto Cartesiano e Relação entre Conjuntos</i>	16
2.3.3. <i>Relações Nebulosas</i>	17
2.3.4. <i>Conjuntos Nebulosos e Variáveis Linguísticas</i>	17
2.3.5. <i>Proposições Nebulosas</i>	18
2.3.6. <i>Composição de Relações Nebulosas</i>	19
2.3.7. <i>Regra de Inferência Composicional</i>	20
2.3.8. <i>Lógica Nebulosa</i>	20

2.3.9. Controle Nebuloso	21
2.3.10. Inferência Nebulosa	23
2.4. TEORIA DA SELEÇÃO DE GRUPOS NEURAIIS	25
2.5. ABORDAGENS PARA O CONTROLE AUTÔNOMO DE VEÍCULOS	26
2.6. RESUMO	27
3. CONTROLE ADAPTATIVO DE VEÍCULOS AUTÔNOMOS.....	28
3.1. INTRODUÇÃO.....	28
3.2. DEFINIÇÃO DO PROBLEMA	28
3.3. CONTROLE DISTRIBUÍDO ADAPTATIVO	30
3.3.1. Grupos Neurais	30
3.3.2. Aprendizagem e Adaptação.....	31
3.3.3. Condicionamento Clássico.....	32
3.3.4. Implementação.....	33
3.4. ANÁLISE DA ABORDAGEM	34
3.5. RESUMO	35
4. CONTROLE NEURO-NEBULOSO DE VEÍCULOS AUTÔNOMOS.....	36
4.1. INTRODUÇÃO.....	36
4.2. ARQUITETURA DO SISTEMA	36
4.3. SISTEMA DE SENSORES	38
4.3.1. Sensores Nebulosos de Colisão.....	38
4.3.2. Sensores Nebulosos de Alvo.....	39
4.4. VARIÁVEIS LINGÜÍSTICAS OBTIDAS DOS GRUPOS NEURAIIS	40
4.5. REGRAS NEBULOSAS DE CONTROLE	41
4.6. SELEÇÃO PROPORCIONAL DE COMPORTAMENTO	42
4.7. IMPLEMENTAÇÃO	43
4.8. RESUMO	44
5. SIMULAÇÃO E ANÁLISE DE RESULTADOS	45
5.1. INTRODUÇÃO.....	45
5.2. CONTROLE ADAPTATIVO DISTRIBUÍDO	45
5.2. SISTEMA NEURAL COM SENSORES NEBULOSOS	47
5.3. SISTEMA COM SENSORES E CONTROLE NEBULOSO	49
5.4. SISTEMA DE CONTROLE COM SELETOR PROPORCIONAL DE COMPORTAMENTOS	51
5.5. RESULTADOS EM COMPARAÇÃO COM OS OBTIDOS PELA PROPOSTA DE OLIVEIRA	55
5.6. ANÁLISE DOS RESULTADOS	58
5.7. RESUMO.....	58
6. CONCLUSÕES E PERSPECTIVAS FUTURAS.....	59
7. REFERÊNCIAS BIBLIOGRÁFICAS	62

Lista de Figuras

Figura 2.1 - Neurônio natural e modelo simplificado(neurônio artificial).....	5
Figura 2.2 - Função de ativação Degrau.....	5
Figura 2.3 - Função de ativação Sigmóide.....	6
Figura 2.4 - Experimento de Pavlov.....	7
Figura 2.5 - Exemplo de rede neural não-recorrente.....	8
Figura 2.6 - Rede neural recorrente de Hopfield.....	8
Figura 2.7 - Estrutura de uma rede neural do tipo Perceptron.....	9
Figura 2.8 - Uma rede competitiva.....	10
Figura 2.9 - Mapa auto-organizável de Kohonen.....	11
Figura 2.10 - Função de pertinência para o conjunto perto.....	13
Figura 2.11 - Conjunto clássico A e conjunto nebuloso P.....	13
Figura 2.12 - Negação,união e intersecção em conjuntos clássicos e nebulosos.....	15
Figura 2.13 - Conjuntos nebulosos representando altura.....	17
Figura 2.14 - Modificadores lingüísticos muito pequeno (P^2) e não pequeno($\sim P$).....	18
Figura 2.15 - Estrutura básica de um controlador nebuloso.....	22
Figura 2.16 - Exemplo de aplicação de controle nebuloso.....	23
Figura 2.17 - Um exemplo genérico do processo de inferência nebulosa.....	24
Figura 2.18 - Outro exemplo de inferência nebulosa - utilizando regra do produto.....	24
Figura 3.1 - Posicionamento dos sensores de distância e colisão.....	29
Figura 3.2 - Exemplo de um ambiente.....	29
Figura 3.3 - Controlador adaptativo e conexões entre os grupos neurais.....	31
Figura 4.1 - Arquitetura do sistema.....	37
Figura 4.2 - Conjuntos nebulosos associados à cada sensor de colisão.....	38
Figura 4.3 - Conjuntos nebulosos associados à cada sensor de alvo.....	39
Figura 4.4 - Conjuntos nebulosos representando direção do obstáculo mais próximo.....	40
Figura 5.1 - Trajetória do veículo: ambiente simples e posições de alvo fixas.....	45
Figura 5.2 - Trajetória do veículo: ambiente mais complexo e posições de alvo fixas.....	46
Figura 5.3 - Trajetória do veículo: posições de alvos aleatórias - flexas indicam colisões.....	46
Figura 5.4 - Colisões, alcance de alvos e desvios referentes à trajetória da figura 5.3.....	47
Figura 5.5 - Exemplo de trajetória obtida pelo sistema com sensores nebulosos.....	48
Figura 5.6 - Colisões, alcance de alvos e desvios referentes à trajetória da figura 5.5.....	48
Figura 5.7 - Exemplo de trajetória obtida pelo sistema com sensores e controle nebulosos.....	49
Figura 5.8 - Colisões, desvios e alvos alcançados referentes à trajetória da figura 5.7.....	49
Figura 5.9 - Detalhamento da figura 5.8 - número de colisões e alvos alcançados.....	50
Figura 5.10 - Situação em que o sistema não alcança um alvo muito próximo à obstáculo.....	50
Figura 5.11 - Exemplo de trajetória : ambiente simples e alvos fixos.....	51

Figura 5.12 - Exemplo de trajetória : ambiente mais complexo e posições de alvo fixas.....	52
Figura 5.13 - Trajetória do veículo: posições de alvos aleatórias	52
Figura 5.14 - Alcance de alvos e desvios relativos à trajetória da figura 5.13.	53
Figura 5.15 - Trajetória do veículo após mudança de ambiente	53
Figure 5.16 - Alcance de alvos e desvios relativos à trajetória apresentada na figura 5.15.....	54
Figura 5.17 - Trajetória realizada pelo veículo após mudança de ambiente - Sistema original	54
Figura 5.18 - Alcance de alvos, desvios e colisões relativos à trajetória da figura 5.14	55
Figura 5.19 - Simulações obtidas pela proposta de controle apresentada por Oliveira.....	55
Figura 5.20 - Trajetória do veículo em ambiente similar ao da figura 5.19-c	56
Figura 5.21 - Trajetória do veículo - configuração dos obstáculos em forma de U - 1	57
Figura 5.22 - Trajetória do veículo - configuração dos obstáculos em forma de U - 2.....	57

1. Introdução

1.1. Sistemas Autônomos

Sistemas autônomos são sistemas dotados de propriedades que permitem a execução de determinadas tarefas sem a necessidade de interferência externa durante o processo. Uma das principais características do comportamento autônomo decorre da necessidade do sistema de se adaptar, eventualmente se auto-organizar, de forma a contornar situações imprevistas. Exemplo típico ocorre quando o sistema interage com um meio externo dinâmico, isto é, cujos parâmetros são variantes no tempo. Em particular, a navegação autônoma de veículos em ambientes com obstáculos constitui-se uma importante classe de sistemas autônomos, a qual vem sendo estudada devido às inerentes complexidades e relevância tecnológica.

1.2. Formulação do Problema

O problema básico da navegação autônoma de veículos é a determinação de uma trajetória, de modo que o veículo possa navegar em segurança (sem colidir com obstáculos) até alcançar uma ou mais posições pré-estabelecidas no ambiente. A complexidade envolvida relaciona-se com a multiplicidade de posições relativas distintas do veículo, e a necessidade de reconhecimento e tratamento específico de cada situação encontrada. Para estabelecer as decisões de controle apropriadas a cada situação, o sistema de controle deve ser capaz de reconhecer e tratar cada situação específica, ou possuir capacidades de generalização.

As dificuldades intrínsecas do problema de navegação autônoma têm interessado muitos pesquisadores do campo da inteligência artificial, com várias soluções sendo propostas. São duas as principais classes de abordagens para esta classe de problemas: planejamento de trajetórias (abordagens baseadas em modelos) e navegação utilizando informações fornecidas por sensores (abordagens baseadas em sensores).

As abordagens baseadas em modelos utilizam um modelo do ambiente, no qual se encontra o veículo, para definir uma trajetória pela qual possa haver a movimentação em direção ao alvo, evitando obstáculos. Estas metodologias são capazes de encontrar um caminho capaz de levar o veículo de uma posição inicial até o alvo, sem colidir com os obstáculos do ambiente. Entretanto, é necessário, em todos os métodos, um modelo adequado do ambiente no qual o veículo se locomove. A eficácia destes métodos depende, principalmente, da precisão do modelo, para possibilitar a geração de trajetórias que não levem o veículo a colidir. O problema referente à utilização destas técnicas decorre da dificuldade de obter modelos precisos de ambientes com características dinâmicas. Estas técnicas são mais apropriadas para planejamento de trajetórias em ambientes estáticos e controlados.

As abordagens baseadas em sensores utilizam medições realizadas diretamente no ambiente, para determinar o próximo movimento do veículo, com o objetivo de evitar obstáculos, ao mesmo tempo que dirigem o veículo em direção ao alvo. Uma classe de metodologias baseadas em sensores utiliza o conceito de *comportamentos*[Bro86]. Cada comportamento é baseado em leituras de sensores específicos. Exemplos de comportamentos incluem *alcançar alvo* e *desviar obstáculos*. A principal vantagem da navegação baseada em sensores é que o veículo pode navegar em ambientes dinâmicos e desconhecidos, pois as únicas

informações necessárias para a movimentação são obtidas dos próprios sensores. Entretanto, as dificuldades apresentadas no projeto de tais abordagens são grandes devido à imprevisibilidade do ambiente, e às inúmeras situações reais com as quais o sistema poderá se defrontar.

As abordagens baseadas em modelos e baseadas em sensores podem ser combinadas em abordagens híbridas[Ver93]. Uma configuração típica é a utilização de um modelo incompleto do ambiente para um planejamento de trajetória inicial, e técnicas de navegação por sensores para desviar obstáculos que possam ser encontrados no caminho planejado. Entretanto, existem as dificuldades de formulação de modelos, ainda que incompletos, e de fusão entre os comportamentos, que podem por vezes apresentar saídas conflitantes [Pay90].

1.3. Motivação e Relevância

O problema da navegação autônoma tem sido muito estudado, devido à sua complexidade e potencial de aplicação em aplicações reais. Várias abordagens já foram propostas, tendo cada uma suas vantagens e limitações.

As abordagens de planejamento de trajetórias, baseadas em modelos e em técnicas da inteligência artificial(IA) clássica, apresentam sérias limitações. Em primeiro lugar, a necessidade da manutenção de um modelo completo do ambiente no qual se trabalha leva à um problema conhecido como *Frame Problem*: os recursos necessários para manter um modelo completo do ambiente crescem exponencialmente com a complexidade deste ambiente, e com o número de modificações que nele podem ocorrer [Pyl87]. Deste modo, torna-se impossível manter um modelo detalhado de um ambiente complexo e com características dinâmicas, como as que ocorrem no mundo real. A solução deste problema não depende apenas de um aumento das capacidades computacionais envolvidas, pois por mais que se aumente o poder computacional empreendido para a manutenção do modelo, ainda seria impossível manter o modelo completo necessário para o planejamento das trajetórias, e ainda operar sobre este modelo em tempo real. Isto está relacionado com a impossibilidade de manutenção constante do modelo, pois a cada mudança no ambiente real, devem ser escolhidos e modificados pontos do modelo relacionados com esta mudança, e esta escolha não é trivial [Ver93]. Mesmo abordagens híbridas, que necessitam apenas de modelos aproximados do ambiente, recaem neste problema. Um outro problema relacionado é a questão da localidade, ou *situadness*: o sistema deve operar no mundo real, e portanto estar baseado em informações recebidas diretamente do ambiente [Suc87], via sensores, e não sobre um modelo interno do ambiente.

Para contornar estes problemas das abordagens tradicionais da IA, outras foram desenvolvidas, principalmente baseando-se em leituras de sensores em tempo real. Neste caso, as vantagens estão principalmente relacionadas com a não necessidade de manutenção de modelos detalhados do ambiente, e com a possibilidade de resposta em tempo real. Várias propostas foram apresentadas para o tratamento do problema, porém as que se mostraram mais promissoras para a solução de problemas complexos foram as baseadas em lógica nebulosa e redes neurais.

Metodologias baseadas na teoria de conjuntos nebulosos possuem vantagens quanto ao tratamento das várias situações possíveis, sem necessitar de um modelo detalhado do ambiente. Entretanto, a definição e refinamento das regras de controle podem se tornar muito trabalhosas e demoradas[Ver93]. Outro problema é que a construção e o refinamento das bases de regras dependem do conhecimento especialista.

Com o intuito de contornar estas deficiências, foram propostas metodologias baseadas em redes neurais. Estas metodologias possuem a vantagem de não precisar de programação explícita, e sim de um treinamento composto por padrões de comportamento esperados durante a navegação. Entretanto, as metodologias baseadas em redes neurais não apresentam a generalidade necessária para o tratamento de todos os casos que podem ser encontrados em ambientes reais.

Devido a estes fatos, neste trabalho é desenvolvida uma arquitetura composta, utilizando-se de redes neurais e de sistemas nebulosos, visando contornar parte das dificuldades mencionadas previamente. O trabalho é motivado pela necessidade de se desenvolver sistemas de controle de veículos autônomos e de se analisar a viabilidade de uso de redes neurais e sistemas nebulosos em sistemas com aprendizagem. A aplicação de tais sistemas autônomos é especialmente importante em situações como: ambientes hostis à presença humana, realização de tarefas monótonas porém em ambientes com mudanças dinâmicas, sistemas automáticos de manufatura e manuseio, dentre outros.

Este trabalho é baseado no conceito de controle distribuído introduzido por Verschure et. al.[Ver92], o qual, por sua vez, está baseado na teoria dos grupos neurais desenvolvida por Edelman[Ede87]. Esta proposta foi considerada por apresentar os resultados mais promissores em termos de adaptação interativa a ambientes desconhecidos.

1.4. Objetivos

O objetivo deste trabalho é o de utilizar redes neurais, notadamente a teoria dos grupos neurais de Edelman[Ede87], em conjunto com técnicas provenientes da teoria dos conjuntos nebulosos, em particular regras de inferência nebulosa[Zad88], para desenvolver um sistema capaz de controlar a movimentação de um veículo autônomo em um ambiente com topologia desconhecida. Um dos principais objetivos consiste no desenvolvimento de um sistema de controle que opere independentemente das características do ambiente em que se encontrar, possibilitando assim seu uso em condições genéricas, semelhantes às encontradas em ambientes reais. Outro objetivo é a utilização de técnicas de auto-organização, de modo a obter um sistema de controle adaptativo que possa se adequar, durante a interação, às mudanças que ocorram no ambiente, ou a outros ambientes distintos com os quais se defrontar.

1.5. Organização da Tese

Após esta introdução, no capítulo 2 são revistos os conceitos básicos de redes neurais, sistemas nebulosos e grupos neurais, relevantes ao entendimento do trabalho. É apresentada também uma revisão bibliográfica das propostas existentes para a solução do problema da navegação autônoma, baseando-se principalmente nestes conceitos. No capítulo 3 é apresentada a proposta de Verschure et. al.[Ver92], na qual foi baseado o desenvolvimento deste trabalho. No capítulo 4 são apresentadas as extensões e modificações do modelo original, utilizando para isto técnicas da teoria dos conjuntos nebulosos. No capítulo 5 são realizados experimentos e comparações, demonstrando os avanços obtidos com a introdução das modificações. No capítulo 6, apresentamos as conclusões obtidas, e propostas de trabalhos futuros.

2. Fundamentos Teóricos

2.1 Introdução

Neste capítulo são apresentados conceitos necessários para a compreensão das técnicas utilizadas na proposta de controle autônomo desenvolvida nesta dissertação. Serão revistos conceitos de redes neurais, sistemas nebulosos, e teoria de grupos neurais. Será apresentada também uma revisão bibliográfica dos trabalhos na área de controle autônomo, principalmente aqueles que utilizam os conceitos mencionados.

2.2 Redes Neurais

2.2.1. Introdução

Redes neurais artificiais são modelos computacionais construídos a partir do estudo de sistemas neuro-biológicos encontrados nos animais e nos seres humanos. O mais notável e estudado destes sistemas é o próprio cérebro humano, composto por conexões entre suas células básicas, os neurônios. Estes elementos possuem um grande número de vias de entrada (os dendritos), um corpo celular (soma), e uma única via de saída (o axônio), que pode estar conectada a inúmeras outras entradas de diferentes neurônios. Um modelo da estrutura e do funcionamento de um neurônio foi primeiramente apresentado por McCulloch e Pitts[MP43], e deu origem às pesquisas sobre redes neurais artificiais.

A Figura 2.1 mostra um modelo de neurônio artificial, em comparação à um neurônio real. Neste modelo simplificado, proposto por Rosenblatt[Ros59], X é um vetor de valores apresentados na entrada de cada neurônio. Cada conexão de entrada possui um peso w_i associado. Estes pesos modelam uma característica dos neurônios reais, de possuírem conexões que propagam estímulos de maneira variável, podendo ser excitatórias ou inibitórias, em maior ou menor grau. Usualmente, os valores de entrada (x_i) são multiplicados pelos pesos associados a cada entrada (w_i), e os resultados são aplicados à uma função de agregação, tipicamente via a soma dos produtos entre x_i e w_i . O valor obtido é processado por uma função de ativação, que define o valor de saída do neurônio.

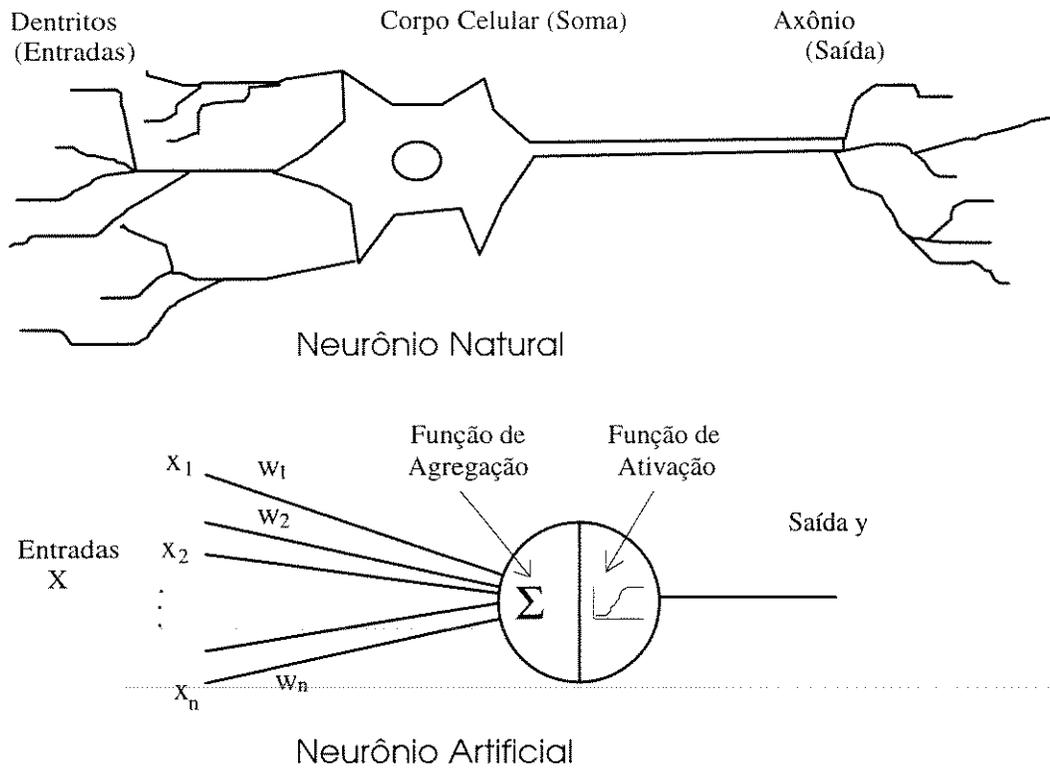


Figura 2.1 - Neurônio natural e modelo simplificado (neurônio artificial)

A função de ativação pode induzir tanto uma saída binária, por exemplo, $y \in \{0,1\}$, como na Figura 2.2, quanto valores contínuos em um intervalo, por exemplo $y \in [0,1]$, como na Figura 2.3.

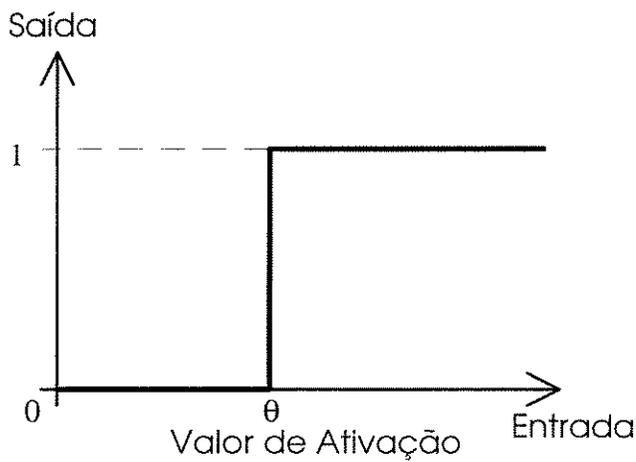


Figura 2.2 - Função de ativação Degrau

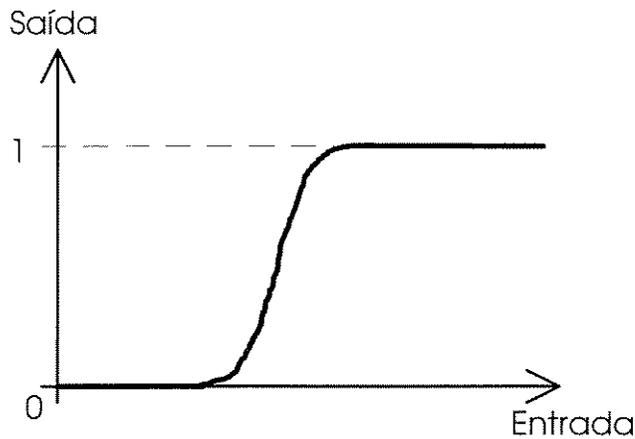


Figura 2.3 - Função de ativação Sigmóide

2.2.2. Aprendizado

Uma das principais características das redes neurais artificiais é sua capacidade de aprender. O conhecimento contido na rede está representado na sua estrutura e nos pesos sinápticos das conexões entre os neurônios. Deste modo, ao se modificar os pesos, pode-se atualizar o conhecimento contido, induzindo a adaptação do sistema. Este processo de modificação dos pesos das conexões é denominado treinamento, e as primeiras idéias a esse respeito foram sugeridas em 1949 por Donald Hebb [Heb49].

Hebb propôs o conceito de aprendizado por correlação (*correlation learning*), também conhecido por aprendizado Hebbiano, onde os pesos das conexões são ajustados de acordo com os níveis de ativação dos neurônios conectados:

$$\Delta W_{ij} = \alpha a_i a_j \quad (2.1)$$

onde α representa a taxa de aprendizado, a_i o nível de ativação do neurônio i de uma camada, e a_j o nível de ativação do neurônio j da camada seguinte, e W_{ij} denota o peso da conexão do neurônio i para o neurônio j .

Um exemplo que ilustra a idéia básica de Hebb considera os experimentos de Pavlov [Pav27] com treinamento condicionado. Na Figura 2.4 são apresentados três neurônios, A, B e C, dispostos em duas camadas, representando os neurônios cerebrais de um cão. O neurônio A é estimulado por entradas sensoriais de visão, enquanto o neurônio B é estimulado por entradas sensoriais de som. Ambos estão conectados ao neurônio C, responsável pela ação de salivação, que é acionada quando suas entradas, moduladas pelos pesos de conexão S_{ac} e S_{bc} , apresentam valores excitatórios suficientes. Isto é, suponha inicialmente que, quando A é ativado, C automaticamente também se ativa; e que quando A não está ativo, C também não está ativo, independente da ativação de B. Supondo agora que é apresentada a visão de alimento (A ativo), o que provoca a ativação de C (e conseqüente salivação), e que simultaneamente B é ativado por um estímulo sonoro característico, por exemplo o soar de um sino. De acordo com Hebb, a conexão S_{bc} será reforçada, pois os dois neurônios por ela conectados estão ativados. Repetindo este experimento sucessivamente, a influência de B sobre a ativação de C crescerá continuamente, chegando, após determinado período, a ser suficiente para ativar C independentemente da ativação de A. Isto significa que apenas o soar do sino provoca a salivação, mesmo antes da apresentação do alimento. Tal experimento, realizado

com animais, mostra ser correta a proposta sugerida por Hebb para o treinamento por correlação em redes neurais.

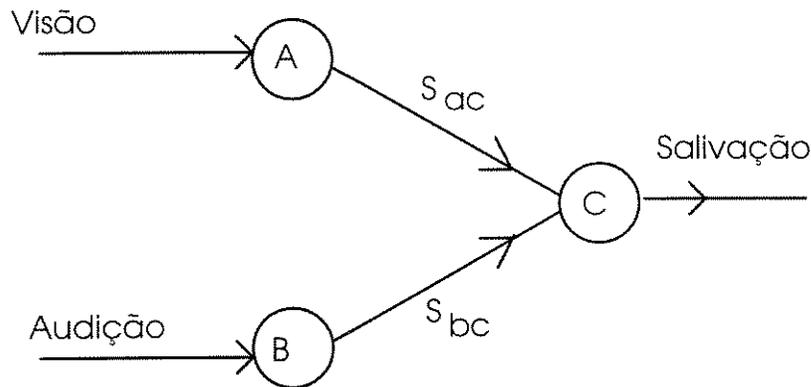


Figura 2.4 - Experimento de Pavlov

2.2.3. Classificação das Redes Neurais

Redes neurais artificiais podem ser classificadas quanto ao tipo de treinamento utilizado, e quanto à topologia das conexões entre os neurônios. Os métodos de treinamento para redes neurais podem ser agrupados em duas classes: treinamento supervisionado e não-supervisionado. No treinamento supervisionado, pares de padrões de entrada/saída relacionados são apresentados à rede, que então utiliza um algoritmo de modificação dos pesos das conexões para *aprender* o mapeamento desejado entre estes padrões. Um exemplo de rede com treinamento supervisionado é a rede do tipo Perceptron[Ros59]. No caso do treinamento não-supervisionado, os padrões são apresentados à rede, a qual procura criar classes a partir das similaridades encontradas nos padrões, a fim de classificá-los automaticamente. Um exemplo de rede com treinamento não-supervisionado é a rede de Kohonen[Koh84].

De acordo com a topologia das conexões entre os neurônios, as redes neurais artificiais podem ser ainda divididas em redes recorrentes e não-recorrentes. Redes não-recorrentes não possuem conexões de realimentação, sendo que o sentido das conexões sempre parte da camada de entrada, passando por eventuais camadas intermediárias, e se dirigindo para a saída da rede. Por não existir realimentação, não existem problemas como o de estabilidade, pois a rede é sempre estável, e qualquer entrada provocará uma saída também estável. A Figura 2.5 mostra um exemplo de rede não-recorrente.

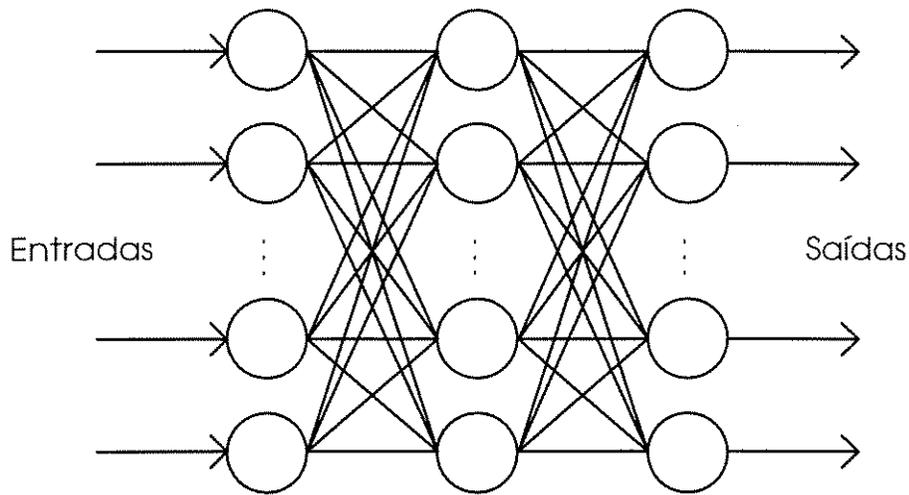


Figura 2.5 - Exemplo de rede neural não-recorrente

Redes recorrentes, por outro lado, possuem realimentação entre os neurônios, levando à necessidade de um processo de estabilização para obter-se o resultado. Um exemplo, apresentado na Figura 2.6, é a rede de Hopfield [Hop82].

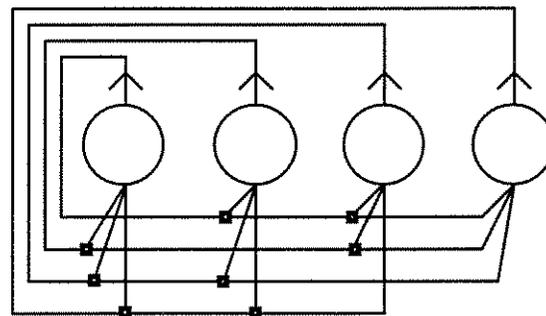


Figura 2.6 - Rede neural recorrente de Hopfield

Dentre as vantagens das redes neurais, quando comparadas à sistemas computacionais tradicionais, está o processamento massivo de informações, onde cada elemento de processamento, ou neurônio artificial, pode ter associado um processador físico independente, levando a um alto grau de paralelismo. Outra característica é a capacidade de aprendizado através de mudanças nos pesos das conexões entre os neurônios. Estas características são importantes na solução de problemas encontrados na vida real. A capacidade de adaptação e aprendizado é vital em áreas como reconhecimento de voz, controle, e em problemas que requerem interação com ambientes dinâmicos. Devido à sua inerente característica distribuída, redes neurais são também robustas quanto à ocorrência de falhas nas unidades de processamento.

É apresentada a seguir a descrição de algumas redes representativas das classes definidas.

2.2.4. Redes Multicamadas

Uma das estrutura composta por neurônios artificiais mais utilizadas é a rede denominada *multicamadas*. Esta rede pode ser treinada para reconhecer padrões ou aproximar funções. Utilizando treinamento supervisionado, basta apresentar o padrão a ser reconhecido nas entradas da rede e alterar os pesos proporcionalmente ao erro encontrado entre as saídas desejadas e as apresentadas na saída. Por meio desta alteração nos pesos, a rede pode aprender o mapeamento correto, e efetuar o reconhecimento. Na Figura 2.7 é apresentada uma estrutura típica de uma rede neural *feedforward* do tipo multicamadas.

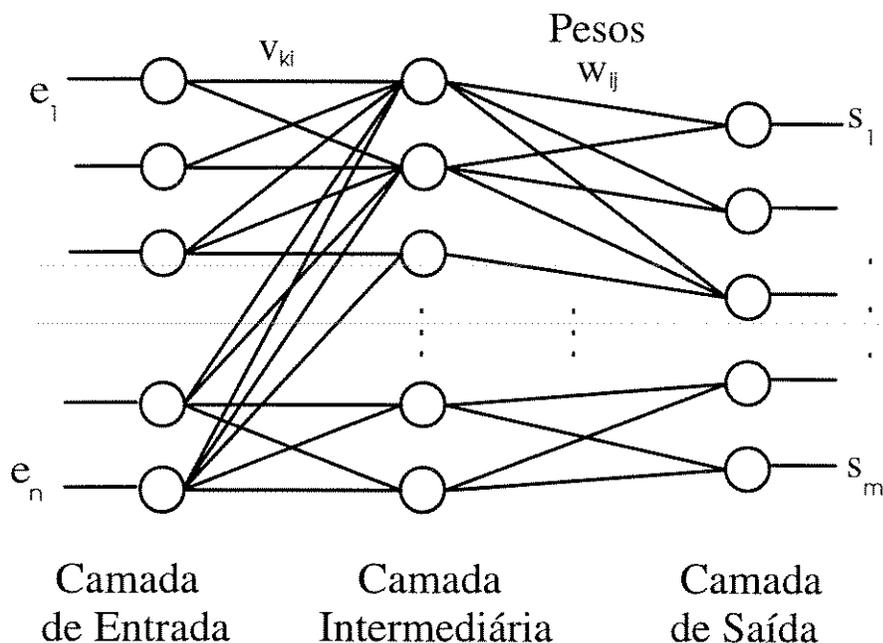


Figura 2.7: Estrutura de uma rede neural do tipo multicamadas

No treinamento desta classe de rede, uma possibilidade de regra de aprendizado deriva da proposta de Hebb, denominada regra delta, ou de Widrow-Hoff[Wid60].

$$\Delta W_{ij} = \alpha(a_i^* - a_i)a_j \tag{2.2}$$

sendo a_i^* a ativação esperada do neurônio i da camada de saída, a_i a ativação obtida pela propagação da rede, a_j a ativação do neurônio j da camada intermediária, e α a taxa de aprendizagem.

Em 1986, Rumelhart[Rum86] apresentou um algoritmo de treinamento para o Perceptron com mais de uma camada intermediária (multicamadas), denominado *backpropagation*, que utiliza uma regra de aprendizado denominada *regra delta generalizada* para realizar uma busca no espaço de pesos via método do gradiente. Foi demonstrado que este tipo de algoritmo de treinamento pode aproximar, com precisão arbitrária, qualquer função com um número finito de descontinuidades [Hor89].

O algoritmo de treinamento opera em duas fases: na primeira, o padrão de entrada é propagado da entrada para a saída, ponderado pelos dos pesos de cada camada de conexões da rede. O resultado obtido na camada de saída é então comparado ao resultado esperado, e o erro é retro-propagado, alterando os pesos através da regra delta generalizada.

O principal inconveniente deste algoritmo é a velocidade de convergência, característica da busca pelo gradiente. Várias propostas já foram apresentadas para a melhora deste método treinamento, desde mecanismos de aceleração[Sil90], até propostas de implementação paralela[Gho89]. Um novo algoritmo, baseado no método de busca pelo gradiente conjugado[Hes52], foi recentemente desenvolvido[Mol93], procurando atenuar este problema.

2.2.5. Redes Concorrentes

Redes auto-organizáveis são as que não necessitam de treinamento supervisionado. Este tipo de rede, por exemplo, classifica padrões apresentados em sua entrada a partir das similaridades encontradas entre estes padrões, criando automaticamente classes que agregam padrões similares. Um exemplo são as redes competitivas[Rum85], utilizadas para classificação de dados em agrupamentos (*clusters*) com características semelhantes. Estas redes são ditas competitivas pois, a cada apresentação de um padrão de entrada, os neurônios competem pela classificação, e o neurônio mais ativo inibe os outros. O neurônio vencedor representa a classe a qual pertence o padrão de entrada, e os pesos das conexões são então modificados de acordo com a classificação. Na Figura 2.8 é apresentado um exemplo de rede competitiva.

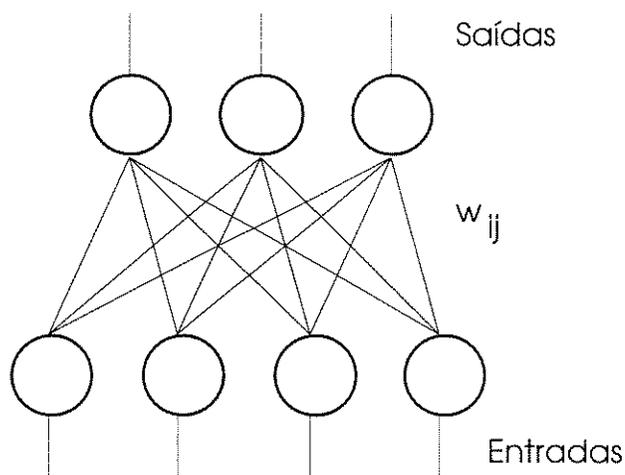


Figura 2.8 - Uma rede competitiva.

Nesta rede, os pesos w_{ij} são inicializados, por exemplo, com valores randômicos. Após, os padrões a serem classificados são apresentados nas entradas x_i , e as saídas a_i de cada neurônio são calculadas, por exemplo, como:

$$a_i = \sum_j w_{ij} \cdot x_j \quad (2.3)$$

Para cada padrão apresentado, o neurônio com o maior valor de saída a é o vencedor, e suas conexões são reforçadas. Este esquema de operação é denominado *winner-take-all*, pois apenas um neurônio é o vencedor em uma iteração. Deste modo, após várias iterações sobre o conjunto de padrões a serem classificados, a rede se auto-organiza, de modo que cada neurônio de saída se torna representativo de uma classe de padrões de entrada.

2.2.5.1. Rede auto-organizável de Kohonen

A estratégia utilizada pelas redes competitivas é a inibição lateral dos outros neurônios, de modo que apenas um saia vitorioso. Tal estratégia é inspirada em estudos sobre o funcionamento do córtex cerebral humano, e leva à classificação de padrões não muito diferentes em neurônios contíguos (preservando a topologia dos padrões de entrada). Baseado nestas idéias, Kohonen[Koh82] propôs uma extensão às redes competitivas, o denominado *mapa de características* de Kohonen. Na Figura 2.9 é apresentada uma rede de Kohonen típica. Existe apenas uma camada de neurônios, em forma de grade, na qual as conexões são restritas aos neurônios na vizinhança imediata. Cada sinal de entrada é conectado a todos os neurônios, cada um representando uma saída, e correspondendo à uma determinada classe. O algoritmo de auto-organização atua como um classificador de características dos padrões de entrada, descobrindo as regularidades, dividindo-os em classes de elementos similares. As conexões entre os neurônios na vizinhança são inibitórias, fazendo que um neurônio ativo iniba a ativação de todos os que o circundam. Na Figura 2.9, o neurônio marcado com um X está ativo, inibindo todos os neurônios em uma vizinhança, que aparece preenchida.

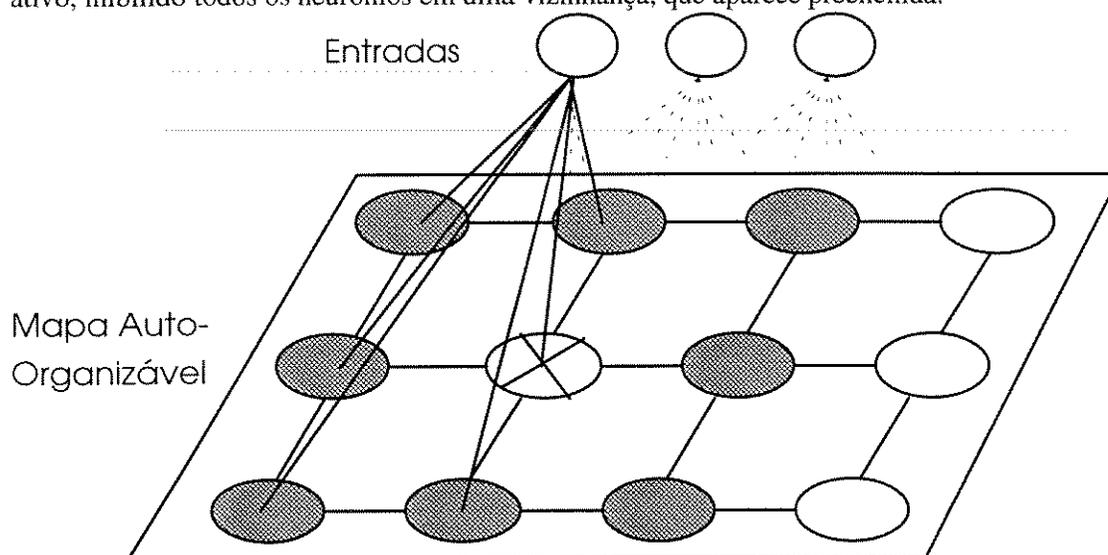


Figura 2.9 - Mapa Auto-Organizável de Kohonen

Do mesmo modo que nas redes competitivas, a cada padrão de entrada apresentado, o neurônio vencedor é definido, e as conexões são atualizadas. Neste caso, entretanto, todas as conexões da rede são atualizadas, de acordo com:

$$w_i(t+1) = w_i(t) + \gamma h(i,k)(x(t) - w_i(t)) \quad (2.4)$$

sendo γ a taxa de aprendizagem, e $h(i,k)$ uma função da distância entre o neurônio i sendo atualizado e o neurônio vencedor k para um determinado padrão. Uma função comumente utilizada é a gaussiana, que em uma dimensão pode ser expressa, por exemplo para duas dimensões:

$$h(i,k) = e^{-\sqrt{(i_x - k_x)^2 + (i_y - k_y)^2}} \quad (2.5)$$

onde (i_x, i_y) e (k_x, k_y) são as coordenadas das posições dos neurônios na rede.

Uma das características principais da rede de Kohonen é a auto-organização, pois os padrões são classificados pela rede em um processo não supervisionado. Entre as principais aplicações desta rede, encontram-se as de processamento de imagens e de fala[Koh84].

2.3. Sistemas Nebulosos

Observando que muitos conceitos no mundo real não podem ser bem representados usando limites claramente definidos, Lofti A. Zadeh desenvolveu a teoria dos conjuntos nebulosos (Fuzzy Sets[Zad65]). Esta teoria generaliza a teoria clássica dos conjuntos para permitir que objetos possuam *graus de pertinência* à determinados conjuntos, possibilitando assim a representação de conceitos vagos e imprecisos, porém mantendo a precisão matemática no tratamento. O *grau de pertinência* de um elemento de um universo à um determinado conjunto é representado por um número real no intervalo $[0,1]$, que representa o quão verdadeira é a afirmação de que *este elemento pertence a este conjunto*. Um grau de pertinência de 1 equivale ao clássico símbolo de pertinência \in , e um grau de pertinência de 0 equivale ao clássico símbolo \notin . Entretanto, graus intermediários também podem ser tratados com idêntica facilidade.

Um conjunto nebuloso é caracterizado por meio de uma função, denominada *função de pertinência*, que relaciona os elementos de um universo de discurso X aos seus respectivos graus de pertinência $\mu_F(x)$ ao conjunto nebuloso F , que pode ser descrito como um conjunto de pares ordenados

$$F = \{ (x, \mu_F(x)), x \in X \} \quad (2.6)$$

Na Figura 2.8 é apresentada uma função de pertinência para o conjunto nebuloso *perto*, em relação a medidas de distância genéricas. Nesta função, distâncias entre 0 e 20 unidades possuem valor de pertinência $\mu(x)=1.0$, significando que estas distâncias possuem total compatibilidade com o conceito de *perto*. Distâncias maiores de 20 e menores de 250 unidades apresentam valores de pertinência decrescentes, representando afinidades cada vez menores com o conceito *perto*. Distâncias acima de 250 unidades possuem grau de pertinência $\mu(x)=0.0$, isto é, não são consideradas como tendo qualquer compatibilidade com o conceito representado. Os conceitos da teoria dos conjuntos nebulosos aproximam-se muito dos utilizados na linguagem e no raciocínio humano.

Os conjuntos nebulosos são uma maneira de representar a imprecisão e a incerteza encontrados normalmente em problemas reais, aos quais os conjuntos tradicionais não podem representar adequadamente. O poder de representação dos conjuntos nebulosos encontra-se na capacidade de representar conceitos vagos e imprecisos, os quais seres humanos tratam com grande habilidade. A maioria dos problemas encontrados na vida real pode ser resolvida com base em informações imprecisas, incompletas e vagas que estão disponíveis no momento, e mesmo assim as pessoas conseguem resolver estes problemas satisfatoriamente. Isto é devido ao processo de raciocínio aproximado a partir destas informações, de modo a obter um resultado também aproximado, porém satisfatório para o problema em questão.

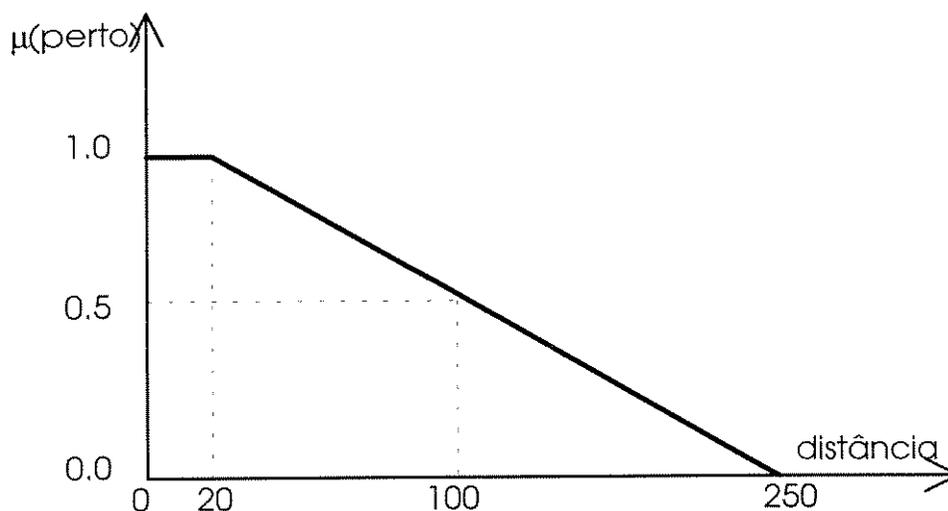


Figura 2.10 - Função de pertinência para o conjunto *perto*.

2.3.1. Definições e Operações sobre Conjuntos Nebulosos

Do mesmo modo que a teoria clássica dos conjuntos permite que se efetuem operações de complemento, intersecção e união, assim também as permitem os conjuntos nebulosos. Entretanto, com o advento do conceito de função de pertinência, deve-se rever as operações básicas sobre estes conjuntos. Considerando os conjuntos nebulosos P e Q em um universo X, define-se:

Conjunto vazio: $P = \emptyset$ se e somente se $\forall x \in X, \mu_P(x) = 0$

Conjuntos iguais: $P = Q$ se e somente se $\forall x \in X, \mu_P(x) = \mu_Q(x)$

P subconjunto de Q: $P \subseteq Q$ se $\forall x \in X, \mu_P(x) \leq \mu_Q(x)$

As funções de pertinência generalizam o conceito de conjuntos, mas podem também ser empregadas para a representação de conjuntos clássicos, como no exemplo abaixo. Utilizaremos como universo de discurso $X = \{0,1,2, \dots, 10\}$, i.e., o conjunto dos números inteiros não negativos entre 0 e 10. A função de pertinência que caracteriza o conjunto clássico $A = \{x \mid 0 \leq x \leq 3, x \in X\}$ é a dos números menores ou iguais a 3. Observa-se a divisão brusca entre os elementos pertencentes ao conjuntos (0,1,2 e 3), com valor de pertinência 1.0, e valores não pertencentes (4,5,...10), com valor de pertinência 0.0. Para realizar comparações, apresentamos também um conjunto nebuloso P, que denota o conceito de número *pequeno*. Observa-se claramente a suavidade na diferenciação entre elementos pertencentes e não pertencentes a este conjunto nebuloso.

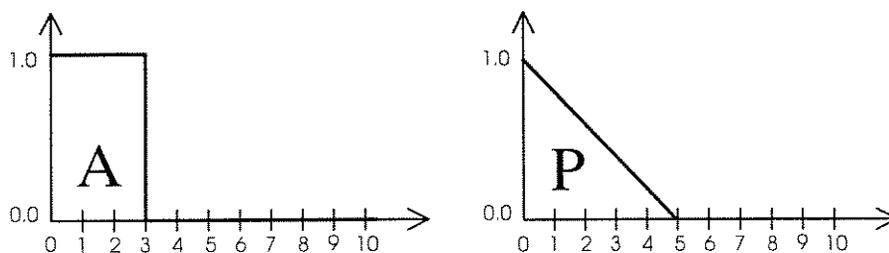


Figura 2.11 - Conjunto clássico A e conjunto nebuloso P

As operações básicas de complemento, união e intersecção de conjuntos clássicos e nebulosos são discutidas a seguir:

A operação de complemento sobre o conjunto clássico A realiza uma inversão da função de pertinência, resultando no conjunto $\sim A = \{x \mid 4 \leq x \leq 10\}$. A mesma operação pode ser realizada sobre o conjunto nebuloso P , aplicando a cada ponto a regra $\mu(\sim P) = (1 - \mu(P))$. Assim obteremos o conjunto $\sim P$, que pode ser descrito como o conjunto dos números *não pequenos*, ou *grandes*. Podemos definir então a operação de complemento como:

$$\sim A = \{(x, \mu_A(x)) \mid \mu_{\sim A} = 1 - \mu_A(x)\} \quad (2.7)$$

Para o caso da união, considere um conjunto $B = \{x \mid 2 < x < 5, x \in X\}$. A união dos conjuntos A e B resulta no conjunto $C = \{x \mid 1 < x < 5\}$. Esta operação pode ser vista como o *máximo* dentre as funções de pertinência de A e B , tomado ponto a ponto.

$$A \cup B = \{(x, \mu_{A \cup B}(x)) \mid \mu(x) = \max(\mu_A(x), \mu_B(x))\} \quad (2.8)$$

Do mesmo modo, a intersecção entre A e B resulta no conjunto $D = \{x \mid 2 < x < 3\}$, e pode ser vista como o *mínimo* sobre as funções de pertinência de A e B .

$$A \cap B = \{(x, \mu_{A \cap B}(x)) \mid \mu(x) = \min(\mu_A(x), \mu_B(x))\} \quad (2.9)$$

Para ilustrar é apresentada na Figura 2.12 a aplicação da união e da intersecção clássica e nebulosa, sobre os conjuntos clássicos A e B , e sobre os conjuntos nebulosos P e $\sim P$. Um ponto muito importante a ser notado é que o princípio do meio-excluído, $A \cap \sim A = \emptyset$, fundamental para a lógica clássica (e base para os paradoxos nela encontrados) não é mais válido. No caso dos conjuntos nebulosos, $P \cap \sim P$ pode ser diferente de \emptyset , como está apresentado na figura.

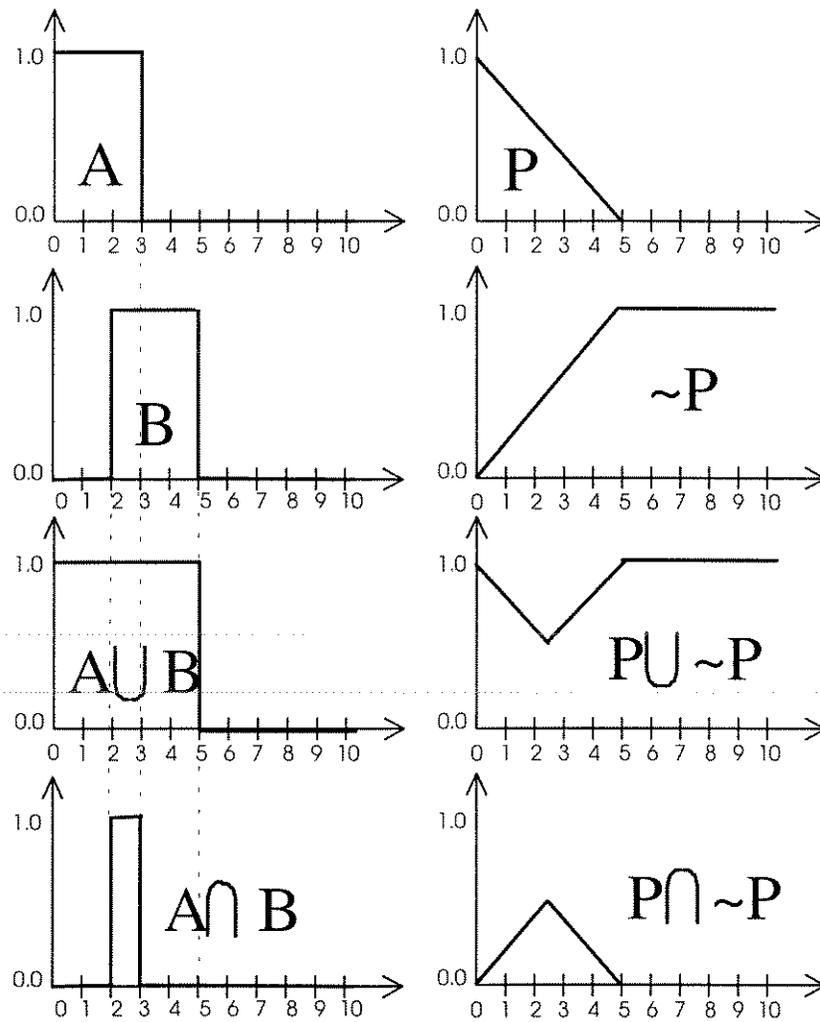


Figura 2.12 - Exemplos de Negação, União e Intersecção em conjuntos clássicos e nebulosos

As operações que podem ser aplicadas aos conjuntos nebulosos não limitam-se somente ao máximo e mínimo, mas formam uma família de normas, denominadas normas triangulares (normas T) e Co-normas triangulares (co-normas T, também conhecidas como normas S). Uma norma triangular (norma-T) é uma função $\tau: [0,1] \times [0,1] \rightarrow [0,1]$ tal que, $\forall x, y, z, w \in [0,1]$ com as seguintes propriedades:

- i. $x \tau w \leq y \tau z$, se $x \leq y, w \leq z$ (Monotonicidade)
- ii. $x \tau y = y \tau x$ (Associatividade)
- iii. $(x \tau y) \tau z = x \tau (y \tau z)$ (Comutatividade)
- iv. $x \tau 0 = 0; x \tau 1 = x$ (Contorno)

Uma co-norma triangular (ou norma-S) é uma função $\sigma: [0,1] \times [0,1] \rightarrow [0,1]$ satisfazendo as propriedades i) a iii) acima, e ainda:

- iv. $x \sigma 0 = x; x \sigma 1 = 1$ (Contorno)

Entre as normas triangulares incluem-se o próprio operador mínimo, o produto algébrico, o produto limitado e o produto drástico, definidos abaixo:

- intersecção ou mínimo: $x \wedge y = \min(x,y)$
- produto algébrico: $x \cdot y = xy$
- produto limitado: $x \otimes y = \max(0, x+y-1)$
- produto drástico: $x \cap y = \begin{cases} x & \text{se } y=1 \\ y & \text{se } x=1 \\ 0 & \text{se } x,y < 1 \end{cases}$

Entre as co-normas triangulares, incluem-se o operador máximo, soma algébrica, soma limitada e soma drástica, definidas a seguir:

- união ou máximo: $x \vee y = \max(x,y)$
- soma algébrica: $x \hat{+} y = x + y - xy$
- soma limitada: $x \oplus y = \min(1, x + y)$
- soma drástica: $x \cup y = \begin{cases} x & \text{se } y=0 \\ y & \text{se } x=0 \\ 1 & \text{se } x,y > 0 \end{cases}$

2.3.2. Produto Cartesiano e Relação entre Conjuntos

O produto cartesiano entre conjuntos clássicos X e Y , é representado por $X \times Y$ e definido como:

$$X \times Y = \{(x, y) \mid x \in X \text{ e } y \in Y\}.$$

Esta definição pode ser generalizada para uma família de conjuntos clássicos X_1, X_2, \dots, X_n e denotada por $X_1 \times X_2 \times \dots \times X_n$. Elementos do produto cartesiano são n-tuplas do tipo (x_1, x_2, \dots, x_n) , de modo que $x_1 \in X_1, x_2 \in X_2, \dots, \text{ e } x_n \in X_n$.

Uma relação entre conjuntos clássicos X_1, X_2, \dots, X_n , é um subconjunto do produto cartesiano por eles formado. Este subconjunto representa as n-tuplas que *pertencem* à relação. Utilizando a notação de funções de pertinência, poder-se-ia dizer que as n-tuplas deste subconjunto possuem pertinência 1 à essa relação, enquanto que todas as outras possíveis n-tuplas possuem pertinência 0. Deste modo, torna-se possível estender o conceito de relação entre conjuntos para os sistemas nebulosos.

2.3.3. Relações Nebulosas

Uma relação nebulosa R entre dois conjunto clássico X e Y é um subconjunto nebuloso do produto cartesiano $X \times Y$, definido pela função de pertinência $\mu_R(x,y)$ e expressa por:

$$R = \{ \mu_R(x,y) / (x,y), x \in X, y \in Y \}$$

Uma relação nebulosa expressa o *grau de correspondência* entre os elementos dos conjuntos clássicos X e Y , expresso como valores no intervalo $[0,1]$, representando o nível de afinidade do par à relação. Um exemplo é a relação nebulosa de *proximidade* entre diferentes cidades, como na tabela abaixo:

Relação Proximidade	São Paulo	Campinas	Rio de Janeiro
Rio de Janeiro	0.5	0.6	1.0
Curitiba	0.6	0.4	0.3
Jundiaí	0.9	0.95	0.5

Tabela 2.1 - Um exemplo de uma relação nebulosa

2.3.4. Conjuntos Nebulosos e Variáveis Linguísticas

Os conjuntos nebulosos representam uma informação imprecisa de maneira direta, através de graus de pertinência $\mu(x)$ de cada elemento x de um conjunto nebuloso. Um exemplo clássico é o tratamento humano à referências de altura: em lugar de usar números precisos, as pessoas utilizam um grupo de conjuntos nebulosos representativos. Neste caso, estes conjuntos poderiam ser simplesmente *Baixo*, *Médio* e *Alto*, e poderiam ser representados como a seguir:

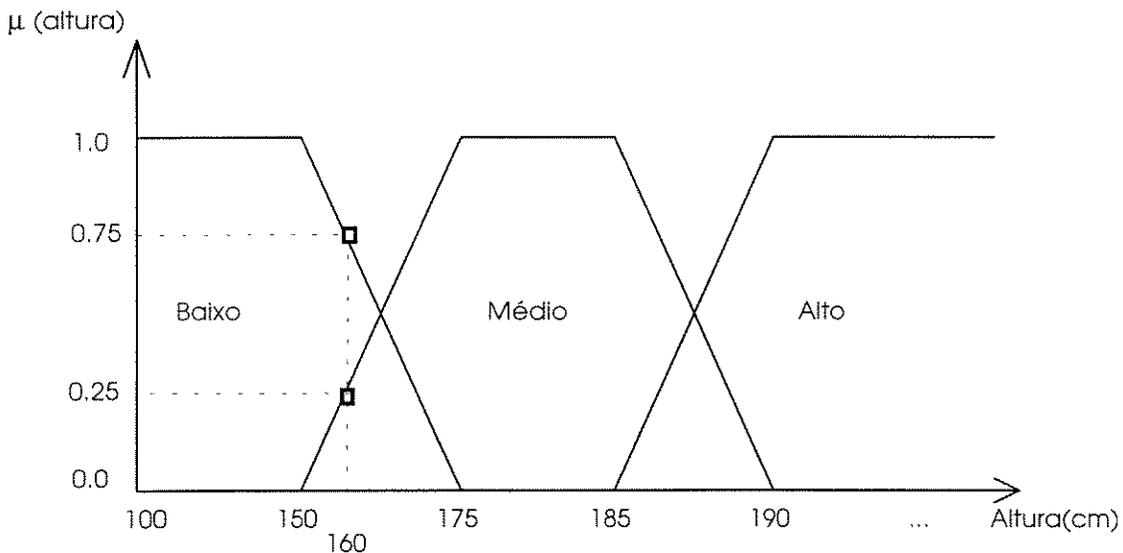


Figura 2.13 - Conjuntos Nebulosos representando altura.

Deste modo, pessoas podem ser classificadas de acordo com a altura, em um (ou mais) dos conjuntos nebulosos representativos deste conceito. Qualquer pessoa com menos de 150 centímetros, ou um metro e meio, teria grau de pertinência $\mu(x)=1.0$ ao conjunto nebuloso *Baixo*, isto é, se enquadraria totalmente no conceito de estatura baixa. Note também que os limites entre os conjuntos se sobrepõem, podendo assim um mesmo indivíduo, de um metro e

sessenta (160 centímetros), por exemplo, se classificar tanto como *Baixo* quanto como *Médio*, mas com diferentes graus de pertinência. Uma representação precisa pode ser feita utilizando a notação valor/conjunto, sendo este elemento com 160 centímetros de altura caracterizado como $0.75/Baixo + 0.25/Médio$. Cabe observar que a distribuição dos conjuntos sobre o universo de discurso pode ser arbitrário, que as funções podem tomar quaisquer formato (trapezoidal, como no exemplo, mas também triangular ou gaussiana), e que pode ou não haver sobreposição de conjuntos. Toda esta generalidade proporciona uma alta capacidade de representação e de adequação ao problema a ser tratado.

Um conceito relacionado com conjuntos nebulosos é o de variável linguística. Entende-se por variável um identificador que pode assumir um dentre vários valores. Deste modo, uma variável linguística pode assumir um valor linguístico dentre vários em um conjunto de termos linguísticos. No exemplo da Figura 2.13, a variável poderia ser denominada *altura*, e assumir um dos seguintes valores: baixo, médio ou alto, elementos do conjunto $T = \{baixo, médio, alto\}$.

Formalmente, uma variável linguística é caracterizada pela quintupla $\{ X, T(X), U, G, M \}$, onde X é o nome do conjunto de termos (*altura*, no exemplo), U o universo de discurso, G uma gramática para gerar os termos $T(X)$, e M o significado dos termos linguísticos, representado através de conjuntos nebulosos.

Variáveis linguísticas podem também conter modificadores (também linguísticos) que alteram seu valor. Exemplos de modificadores válidos são: *muito*, *pouco*, *não muito*, *mais* ou *menos*. Existem também conectivos que podem ser aplicados à estas variáveis, *e* e *ou*. Assim, um valor válido para a variável linguística *altura* seria *não muito alto e não muito baixo*. Os modificadores linguísticos podem ser definidos matematicamente, como no exemplo dos conjuntos *baixo* e *muito baixo*, onde o modificador *muito* é caracterizado por elevar cada ponto da função de pertinência à segunda potência. Os conectivos *and(e)* e *or(ou)* são equivalentes às operações de união e intersecção de conjuntos, respectivamente, podendo dar origem a conjuntos complexamente definidos, porém representados lingüisticamente de maneira simples. Na Figura 2.14 é apresentado um exemplo da aplicação dos modificadores linguísticos *muito* e *não* ao conjunto nebulosos pequeno (P).

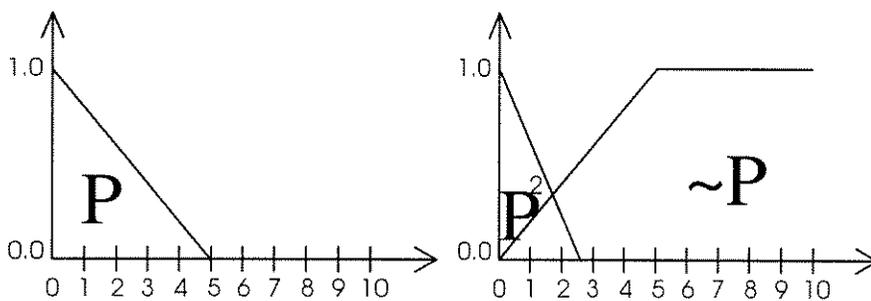


Figura 2.14 - Modificadores linguísticos *muito pequeno* (P^2) e *não pequeno* ($\sim P$)

2.3.5. Proposições Nebulosas

Seja uma frase da forma (X é A), onde X é o nome de uma variável linguística e A um subconjunto nebuloso definido no universo de discurso X . Esta frase é denominada proposição nebulosa. Proposições nebulosas podem ser combinadas utilizando-se operadores lógicos E e OU, ou de implicação da forma SE...ENTÃO. As proposições nebulosas resultantes podem ser descritas em termos de relações nebulosas, como a seguir.

Sejam X e Y variáveis linguísticas com universos de discurso X e Y , respectivamente. Sejam A e B conjuntos nebulosos definidos respectivamente em X e Y . As proposições nebulosas (X é A) e (Y é B) podem ser conectadas pelo operador OU, como abaixo, gerando a proposição nebulosa binária, através de uma relação nebulosa R em $X \times Y$:

$$(X \text{ é } A) \text{ ou } (Y \text{ é } B) \text{ ---> } ((X, Y) \text{ é } R_{A \text{ ou } B})$$

A relação nebulosa $R_{A \text{ ou } B}$ é determinada por uma norma-S:

$$R_{A \text{ ou } B} = \{ \mu_{R_{A \text{ ou } B}}(x, y) = \mu_A(x) \sigma \mu_B(y), x \in X, y \in Y \}$$

De modo análogo, a relação $R_{A \text{ e } B}$ é determinada por uma norma-T.

A implicação lógica SE ... ENTÃO é também conhecida como declaração condicional nebulosa, regra nebulosa ou implicação nebulosa. Este operador descreve a dependência do valor de uma variável nebulosa em relação ao valor de outra. Implicações são da forma:

$$\text{SE } (X \text{ é } A) \text{ ENTÃO } (Y \text{ é } B) \dots$$

que pode ser representado por:

$$((x, y) \text{ é } R_{A \rightarrow B})$$

A relação nebulosa de implicação $R_{A \rightarrow B}$ pode ser obtida através das funções de pertinência individuais $\mu(x)$ e $\mu(y)$ de diversas maneiras, como definido a seguir:

- (1) Mamdani (1974) : $\mu_{R_{A \rightarrow B}}(x, y) = \mu_A(x) \wedge \mu_B(y)$
- (2) Larsen (1981) : $\mu_{R_{A \rightarrow B}}(x, y) = \mu_A(x) \cdot \mu_B(y)$
- (3) Implicação Nebulosa aritmética de Zadeh: $\mu_{R_{A \rightarrow B}}(x, y) = 1 \wedge (1 - \mu_A(x) + \mu_B(y))$
- (4) Implicação Nebulosa MaxMin de Zadeh: $\mu_{R_{A \rightarrow B}}(x, y) = (\mu_A(x) \wedge \mu_B(y)) \vee (1 - \mu_A(x))$

sendo as mais utilizadas, em aplicações de controle, as propostas por Mamdani [Mam74] e Larsen[Lar80]. Para realizar a combinação de N declarações nebulosas do tipo SE ... ENTÃO, utiliza-se o conectivo OU, usualmente implementado pelo operador max (\vee) [Lem84]:

$$\mu_R(x, y) = \vee_j (\mu_{A_j}(x) \wedge \mu_{B_j}(y)), j=1, 2, \dots, N$$

2.3.6. Composição de Relações Nebulosas

A composição C entre duas relações $P(X, Y)$ e $Q(Y, Z)$, denotada por:

$$C(X, Z) = P(X, Y) \circ Q(Y, Z)$$

é definida como o subconjunto $C(X, Z)$ de $X \times Z$, tal que $(x, z) \in C$ se e somente se existe ao menos um $y \in Y$ tal que $(x, y) \in P$ e $(y, z) \in Q$.

Do mesmo modo que as operações básicas possuem uma variedade de generalizações para os conjuntos nebulosos, a operação de composição de relações nebulosas pode tomar

diversas formas. A mais comum destas formas é a *composição max-min*, definida [Zad65] como:

$$\mu_{P \circ Q}(x,z) = \max_{y \in Y} \min[\mu_P(x,y), \mu_Q(y,z)]$$

para todo $x \in X$ e $z \in Z$. Entretanto, pode-se utilizar qualquer norma-T em substituição ao operador mínimo, como o produto algébrico[Kau75], produto limitado ou o produto drástico[Miz81].

2.3.7. Regra de Inferência Composicional

Considere-se duas proposições nebulosas:

$$\begin{array}{ll} \text{SE } (X \text{ é } A) \text{ ENTÃO } (Y \text{ é } B) & : \quad ((X,Y) \text{ é } R^1) \\ \text{SE } (Y \text{ é } B) \text{ ENTÃO } (Z \text{ é } C) & : \quad ((Y,Z) \text{ é } R^2) \end{array}$$

Estas duas proposições podem ser compostas de forma a resultar em:

$$\text{SE } (X \text{ é } A) \text{ ENTÃO } (Z \text{ é } C) \quad : \quad ((X,Z) \text{ é } R^{12})$$

Como já apresentado, $R^{12} = R^1 \circ R^2$ é determinada pela composição sup- τ . Por exemplo, esta pode ser definida por uma regra do tipo max-min:

$$\mu_{R^1 \circ R^2}(x,z) = \max_{y \in Y} \min[\mu_{R^1}(x,y), \mu_{R^2}(y,z)]$$

ou por uma regra do tipo max-produto:

$$\mu_{R^1 \circ R^2}(x,z) = \max_{y \in Y} (\mu_{R^1}(x,y) \cdot \mu_{R^2}(y,z))$$

2.3.8. Lógica Nebulosa

Baseada na teoria dos conjuntos nebulosos, a lógica nebulosa proporciona os mecanismos para realizar inferências lógicas baseadas em informações imprecisas. Analogamente a teoria dos conjuntos, a lógica nebulosa é uma generalização da lógica tradicional. Utilizando os respectivos conceitos de negação, união e intersecção nebulosas, é possível realizar todos os processos de inferência já conhecidos na lógica tradicional com conjuntos nebulosos. A principal regra de inferência da lógica clássica é o *modus ponens*. Segundo esta regra, a partir do conhecimento de um fato ($X \text{ é } A'$) e da existência de uma regra do tipo "se ($X \text{ é } A$) então ($Y \text{ é } B$)", pode-se inferir ($Y \text{ é } B'$). Esta regra básica foi generalizada para a utilização com a lógica nebulosa, dando origem ao *modus ponens generalizado*. Nesta nova regra, os conjuntos envolvidos, A e B, são conjuntos nebulosos, e conclusões podem ser obtidas sempre que o antecedente é parcialmente satisfeito, da seguinte forma:

$$(x \text{ é } A') : A' = \{ (\mu_{A'}(x), x), x \in X \}$$

$$\text{se } (X \text{ é } A) \text{ então } (Y \text{ é } B) : (X, Y) \text{ é } R$$

Dadas estas duas proposições nebulosas, pela regra da composição pode-se inferir:

$$(Y \text{ é } B')$$

Por exemplo, utilizando-se a regra de inferência max-min, teremos que:

$$B' = A' \circ R : B'(y) = \bigvee_x (\mu_{A'}(x) \wedge \mu_R(x, y))$$

2.3.9. Controle Nebuloso

A lógica nebulosa pode ser utilizada para a implementação de controladores nebulosos, aplicados aos mais variados tipos de processos [Lee90]. A utilização de regras nebulosas e variáveis linguísticas confere ao sistema de controle várias vantagens, incluindo:

- simplificação do modelo do processo;
- melhor tratamento das imprecisões inerentes aos sensores utilizados;
- facilidade na especificação das regras de controle, em linguagem próxima à natural;
- satisfação de múltiplos objetivos de controle;
- facilidade de incorporação do conhecimento de especialistas humanos;

Entretanto, quando tanto as leituras de sensores quanto os sinais esperados pelos atuadores do sistema de controle não são nebulosos, são necessários elementos adicionais entre o controlador nebuloso e o processo a ser controlado. Estes elementos são denominados fuzificador e defuzificador, e estão posicionados na entrada e saída do sistema de controle, respectivamente. Estes elementos são responsáveis por transformar as medidas obtidas dos sensores em conjuntos nebulosos (fuzificador), e em transformar os conjuntos nebulosos obtidos na saída do controlador em valores não nebulosos de controle para o processo (defuzificador).

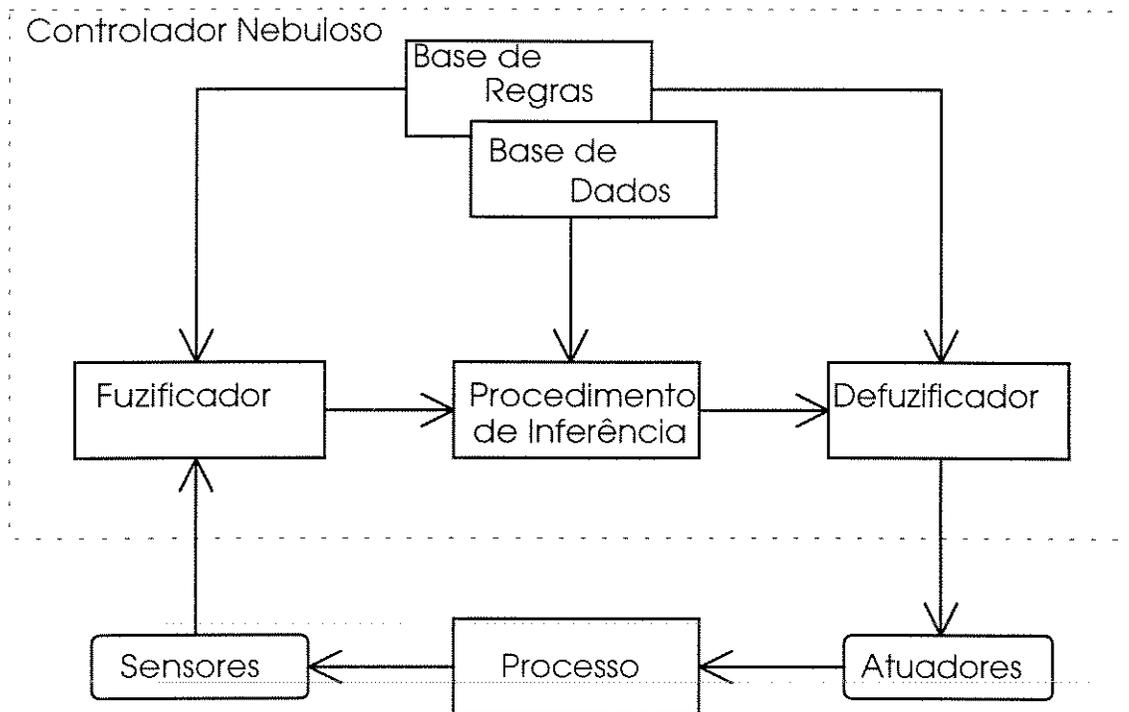


Figura 2.15 - Estrutura básica de um controlador nebuloso

Como exemplo, é apresentado o problema de controle de direção de um veículo, apresentado na Figura 2.16. As leituras realizadas pelos sensores são a distância para a esquina (x_1), o ângulo entre a direção seguida pelo carro (x_3), e as distâncias laterais até as paredes (x_2 e x_4). Com base nas respostas (imprecisas) dos sensores, o sistema de controle deve ser capaz de fazer o carro contornar a curva, e continuar seu caminho. O primeiro passo é realizado pelo fuzificador, que recebe as leituras dos sensores e as transforma em conjuntos nebulosos a serem tratados pelo procedimento de inferência. A fuzificação consiste da transformação das leituras em conjuntos nebulosos que representem tanto o valor lido, como a falta de precisão deste valor. A técnica de fuzificação mais utilizada consiste da atribuição de uma função de pertinência triangular ou gaussiana ao valor lido, centrando esta função no exato valor passado pelo sensor. Os conjuntos nebulosos gerados são então armazenados na base de dados, e utilizados para realizar as inferências nebulosas. Esta base de dados contém também a definição dos conjuntos nebulosos que caracterizam os valores que poderão ser assumidos pelas variáveis linguísticas utilizadas pelo controlador. Na Figura 2.16 são apresentados exemplos das funções de pertinência das variáveis x_1 e x_3 . O cerne do controlador nebuloso é a base de regras, a qual armazena regras linguísticas que definem o comportamento do sistema. As regras são da forma “se (x_1 é A) e (x_2 é B) e (x_3 é C) e (x_4 é D) então (y é E)”, sendo x_1, x_2, \dots, x_4 e y variáveis linguísticas, e A, B, C, D e E valores que estas variáveis podem assumir. Um exemplo válido de regra, a qual deve ser explicitada por um especialista no processo controlado, é:

- se (x_1 (distância até a esquina) é grande) e (x_3 (ângulo com a parede) é frente) e (x_2 e x_4 (distâncias laterais) não são grandes) então (y (atuação no volante do carro) é frente).

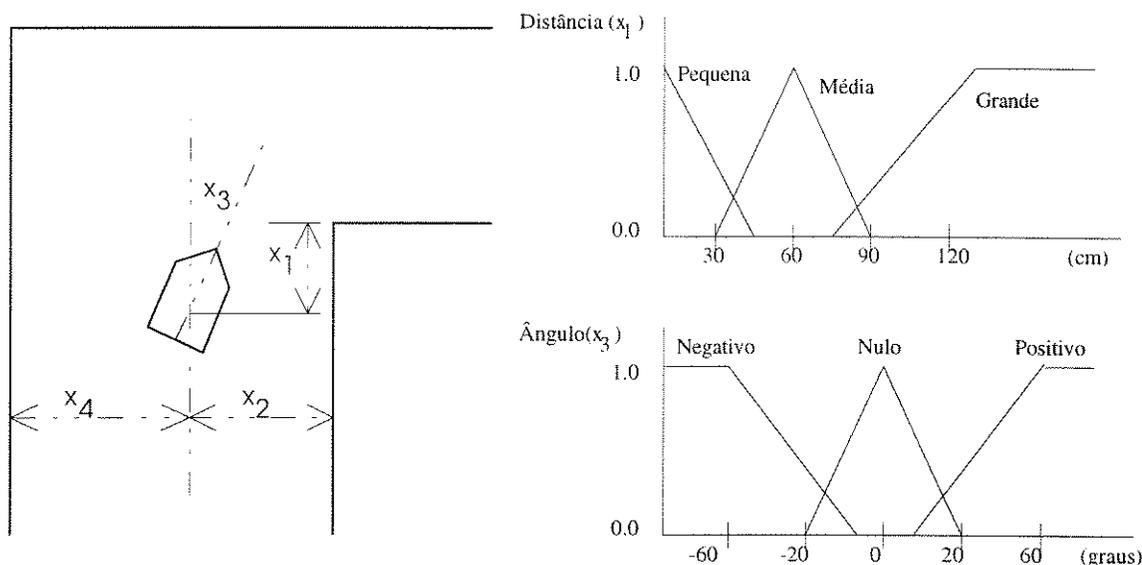


Figura 2.16 - Exemplo de aplicação de controle nebuloso

2.3.10. Inferência Nebulosa

O processo de inferência ocorre através da determinação do valor de cada conseqüente das regras nebulosas, a partir dos graus de compatibilidade entre as proposições derivadas das medidas com as respectivas proposições presentes nos antecedentes das regras. Cada medida dos sensores a e b, após fuzificada (gerando os conjuntos nebulosos A' e B'), é comparada com os antecedentes de todas as regras nebulosas. Esta comparação é realizada aplicando-se o operador de intersecção (\min) entre os conjuntos representativos da leitura do sensor (A' e B') e do antecedente de cada regra ($A1$ e $A2$). Este processo resulta no nível de satisfação que cada leitura de sensor apresenta para cada regra. Após este cálculo, para todas as entradas, é realizada a inferência, isto é, a propagação dos valores verdade através das regras nebulosas, gerando conjuntos nebulosos representativos dos conseqüentes de cada regra. Para isto é utilizada a regra da composição de relações. A contribuição de cada regra é levada em consideração via, por exemplo, a união (\max) entre os conjuntos nebulosos resultantes das regras ($C1$ e $C2$). Neste ponto, já se possuem as respostas para o controlador, mas na forma de um conjunto nebuloso ($C1 \cup C2$). Para que se possa aplicar tal resposta ao processo, através dos atuadores, é necessária uma defuzificação do resultado. Existem vários métodos de defuzificação, sendo os mais usados o do valor máximo e o do centro de área.

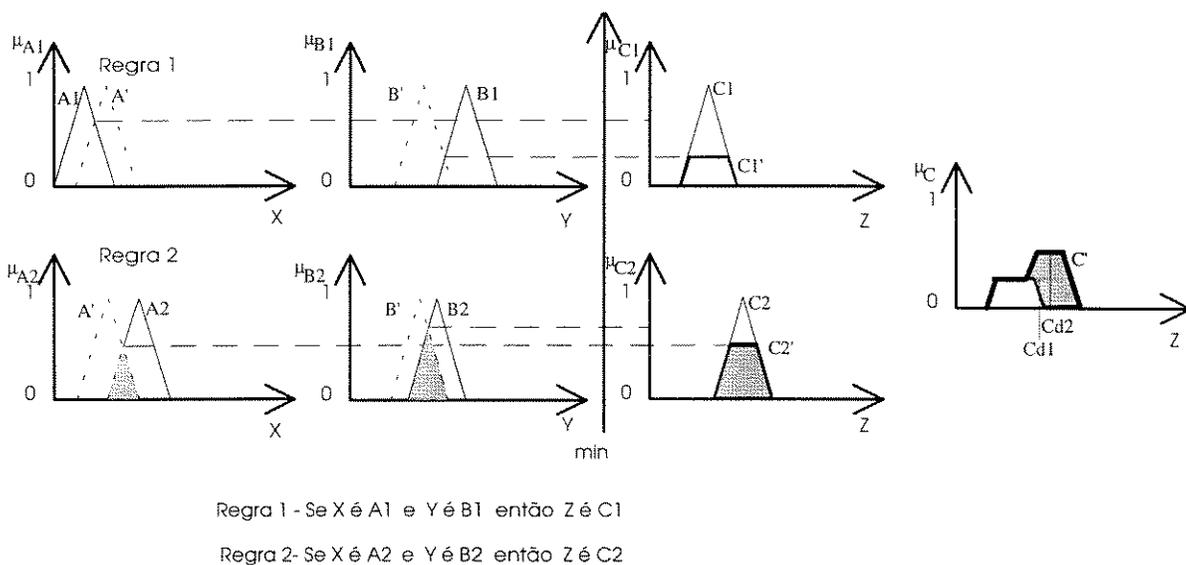


Figura 2.17 - Um exemplo do processo de inferência nebulosa.

Na Figura 2.17 são apresentados exemplos de inferência nebulosa, com duas regras operando sobre os mesmos conjuntos de entrada. Os conjuntos A' e B' representam leituras de sensores, já fuzzificadas. Estes conjuntos são comparados com os antecedentes nebulosos das regras 1 e 2, e é realizada a interseção entre os conjuntos. Os conjuntos C1' e C2' são formados a partir do menor valor de pertinência encontrado, propagado para os conjuntos C1 e C2. O conjunto $C' = C1' \cup C2'$ é o resultado da inferência nebulosa das regras 1 e 2, e em geral necessita ser defuzificado para fornecer um sinal de controle para o sistema controlado. Nesta figura são também apresentados os dois pontos mais comuns utilizados pela defuzificação, correspondendo ao cálculo do centro de área (Cd1), ou à média dos máximos (Cd2).

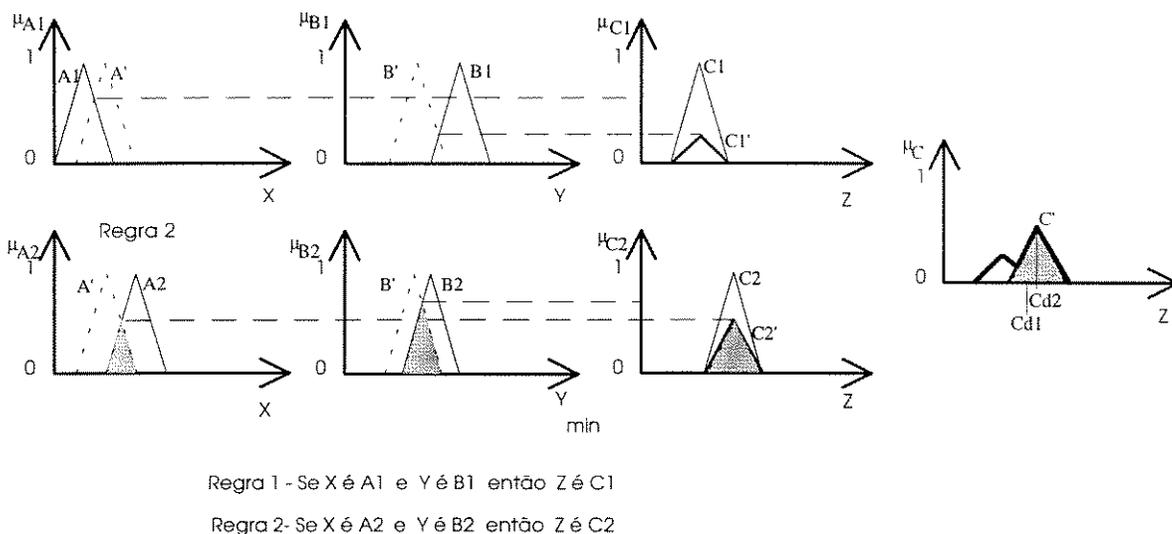


Figura 2.18 - Outro exemplo de inferência nebulosa - utilizando regra do produto.

A Figura 2.18 apresenta o mesmo mecanismo de inferência, mas utilizando o operador max-produto de Larsen na composição das relações.

2.4. Teoria da Seleção de Grupos Neurais

A teoria da seleção de grupos neurais (*neuronal group selection*) foi apresentada por Gerald Edelman [Ede87] como uma teoria sobre o funcionamento do cérebro e do comportamento. Esta teoria foi baseada principalmente nos estudos de Edelman a respeito do sistema imunológico humano, pelos quais ele recebeu um prêmio Nobel. As noções fundamentais são baseadas nas hipóteses de evolução e desenvolvimento seletivo, apresentadas por Darwin [Dar66]. Esta teoria propõe uma nova visão, conexionista, baseada em interação de elementos simples, os neurônios, para o desenvolvimento de reações complexas quando em interação com o ambiente.

Os principais elementos da teoria de Edelman são a seleção por desenvolvimento (*developmental selection*), a seleção por experiências (*experimental selection*), e os mapeamentos reentrantes (*reentrant mappings*). A primeira idéia (*developmental selection*) dita que as arquiteturas neurais de um cérebro em desenvolvimento são determinadas através de seleção de grupos de células neurais, que é determinada pelos mecanismos de crescimento, divisão, adesão e morte destas células. Este processo de desenvolvimento depende de processos regulados pela genética do indivíduo, e leva a formação de repertórios primários (*primary repertoires*), ou grupos neurais primários, que consistem em grupos de neurônios interconectados. A criação destes grupos, por depender de influências dinâmicas do ambiente, apresentam grande diversidade entre indivíduos. Esta diversidade proporciona uma base para seleção, além de apresentar um fundamento para o processo de adaptação. Este processo, entretanto, é o responsável pelas capacidades básicas de sobrevivência de todos os indivíduos da espécie, provendo funções básicas, como reconhecimento de alimento e movimentação, e outras funções automáticas, como respiração e batimento cardíaco. Em determinadas espécies estas capacidades, definidas geneticamente, proporcionam aos indivíduos recém-nascidos até a capacidade de locomoção independente, como por exemplo em animais que, logo após o nascimento, devem acompanhar o rebanho, sob pena de serem abandonados.

No próximo estágio de desenvolvimento, as conexões sinápticas entre os elementos de cada grupo são reforçadas ou enfraquecidas, devido à seleção por experiência. Este processo depende dos sinais provindos do ambiente, e dos mecanismos de mudança nas conexões [Pav27]. Nesta fase, são formados os repertórios secundários (*secondary repertoires*) de modo a expressar uma maior adaptação às características do ambiente. Repertórios primários e secundários são relacionados à formação de mapas de percepção sobre o mundo no qual o agente se encontra. Tal percepção consiste de uma categorização dos sinais e dos processos com os quais o agente deve operar. Tal categorização deve ser o mais fiel possível ao mundo do qual ela é extraída, e para isto Edelman considera que só é possível de ser atingida através de um acoplamento constante com o mundo no qual se está interagindo.

O terceiro mecanismo crucial é o de mapeamentos reentrantes entre os grupos neurais. Os repertórios de tais grupos devem estar conectados, de modo a possibilitar interações coordenadas. Devido à estas interações entre grupos de diferentes (ou complementares) funções, são formados mapeamentos globais (*global mappings*), que possibilitam a realização de funções mais complexas de classificação que os repertórios separadamente. Os mapeamentos globais possibilitam categorizações nas quais tanto a percepção do mundo como as ações nele realizadas estão fortemente relacionadas. O processo de reentrância entre os grupos neurais evolui e se modifica constantemente, e reflete a continuidade dos processos dinâmicos que ocorrem no mundo real, possibilitando a criação de expectativas a respeito dos eventos e sinais obtidos deste mundo.

Com base nestas definições, é possível desenvolver agentes autônomos capazes de realizar categorização, evoluírem através de aprendizado por interação, e apresentarem comportamentos inteligentes, independente da necessidade de treinamento prévio ou especificação de regras. Esta proposta apresenta uma alternativa às abordagens tradicionais, tanto da inteligência artificial clássica, como das propostas de redes neurais comumente utilizadas nos mais diversos sistemas.

Devido às bases desta proposta estarem fortemente relacionadas à processos biológicos apenas recentemente descobertos, existe uma expectativa na possibilidade de sua utilização em problemas de difícil tratamento, induzindo novos paradigmas para a solução de problemas [Ver93].

2.5. Abordagens para o Controle Autônomo de Veículos

Conforme mencionado anteriormente, o planejamento de trajetórias (baseado em modelos completos do ambiente), é uma proposta de solução do problema de navegação de veículo autônomos. Lozan-Pérez[Loz79], por exemplo, apresentou um método de cálculo de trajetórias utilizando um método de configuração de espaços em ambientes que podem ser modelados por polígonos. Vários outros métodos para planejamento global de trajetória foram propostos, sendo o mais conhecido o método STRIPS[Fik72], o qual usa técnicas de manipulação de conhecimento sobre o ambiente para modelá-lo, e busca no espaço de estados gerado para encontrar uma trajetória segura. Estes métodos conseguem resolver o problema do planejamento de trajetórias em ambientes totalmente conhecidos. Entretanto, quando se trata de ambientes desconhecidos, ou ambientes com características dinâmicas, estes métodos não podem ser utilizados. Para superar estas dificuldades, são necessários métodos que utilizem informações adquiridas diretamente do ambiente, em tempo real, através de sensores. Baseado nas medições provenientes dos sensores, o veículo deve ser capaz de realizar um planejamento local da trajetória e tomar a ação de controle adequada.

Borenstein e Koren [Bor89] desenvolveram o método do *campo de força virtual* para a solução deste problema. Este método utiliza leituras provenientes de sensores ultrasônicos para determinar localmente a direção a seguir, usando campos de força virtuais para evitar obstáculos. Entretanto, dificuldades são encontradas com os coeficientes de força quando em ambientes que não podem ser representados por um modelo matemático preciso [Bor91].

Brooks[Bro86], por outro lado, propôs uma abordagem baseada em comportamentos, denominada *subsumption architecture*. Este método é baseado na pré-especificação de comportamentos através de módulos de realização de tarefas. Cada módulo é responsável por um comportamento específico, como *desviar obstáculos*, *alcançar alvo*, ou *contornar obstáculo*, e da interação entre estes comportamentos simples se obtém um sistema de controle complexo. Esta experiência apresentou sucesso na navegação em ambientes desconhecidos, mas depende das estruturas de conhecimento pré-definidas e programadas em cada módulo. Estes métodos apresentam, entretanto, grande dificuldade no controle em ambientes com muitos obstáculos e, por exemplo, com alvos aleatoriamente posicionados, que não podem ser descritos por modelos matemáticos, devido à complexidade da interação que daí advém.

Várias outras abordagens foram recentemente propostas, principalmente usando conjuntos nebulosos e redes neurais. A abordagem usando sistemas nebulosos tem a vantagem de poder tratar incertezas e imprecisão usando bases de conhecimento simples[Ish91]. O conhecimento é representado na forma de regras nebulosas, devendo modelar as ações a serem tomadas a partir de leituras de sensores. Entretanto, mesmo após a definição e refinamento das regras, é geralmente difícil tratar todos as possíveis situações através de regras específicas.

Uma alternativa, recentemente apresentada por Beom e Cho[Beo92], utiliza bases de regras nebulosas para os diferentes comportamentos e, através de funções de avaliação de desempenho, o sistema realiza aprendizado por reforço para sintonizar as regras nebulosas para o ambiente específico em que se encontra. Tal sistema necessita de uma pré-especificação das regras, de modo genérico, e de períodos de aprendizado inicial antes de entrar em operação.

Para evitar estes inconvenientes, foram também desenvolvidas metodologias de controle baseadas nas técnicas de redes neurais. A principal vantagem das redes neurais é que não é necessária programação explícita de conhecimento. Deste modo, utilizando por exemplo uma rede multicamadas e treinamento *backpropagation*, e um conjunto de padrões de treinamento [Koz91], é possível treinar um veículo para navegar em vários ambientes [Sek90]. Entretanto existem inúmeras situações específicas a serem tratadas, quando em ambientes complexos, gerando dificuldades no treinamento.

Visando combinar o melhor das tecnologias de planejamento de trajetórias, navegação baseada em sensores, lógica nebulosa e redes neurais, Beom e Cho [Beo95] desenvolveram recentemente um sistema de controle que utiliza o seguinte mecanismo: uma rede neural recebendo entradas provenientes de sensores é treinada para reconhecer a situação em que o veículo se encontra; a seguir uma base de regras nebulosas criada especialmente para aquela situação é utilizada para definir a movimentação. Ainda assim, a definição e refinamento das regras são realizadas manualmente, e dependem do conhecimento de um especialista. Outra alternativa foi também recentemente apresentada por Oliveira[Oli95], utilizando algoritmos genéticos para a otimização dos parâmetros de uma rede neuro-nebulosa, de modo a obter um sistema de navegação melhor adequado ao ambiente no qual está inserido. Um inconveniente desta metodologia é a necessidade de um longo período inicial de adequação ao ambiente, devido ao custo computacional da utilização dos algoritmos genéticos.

Uma metodologia baseada nas técnicas de redes neurais, apresentada por Verschure [Ver92], denominada *controle adaptativo distribuído*, apresenta novas alternativas de adaptação à ambientes desconhecidos. Esta arquitetura de controle pode aprender a navegar um veículo a partir de sua interação com o ambiente, sem a necessidade de programação ou treinamento prévios. Neste caso, o sistema produz um comportamento emergente durante o processo de aprendizagem. Os principais problemas são relacionados ao desempenho em difíceis situações reais encontradas na navegação.

A proposta desenvolvida neste trabalho é uma arquitetura de controle auto-organizável, utilizando técnicas de sistemas nebulosos, e baseada no modelo de Verschure[Ver92] para o controle de navegação de um veículo autônomo em ambientes desconhecidos. O conceito de sensores neurais-nebulosos [Gom92] e um conjunto básico de ações motoras [Ede87] são usados para construir uma arquitetura de controle capaz de aprender e incrementar seu desempenho a partir de interações com o ambiente.

2.6. Resumo

Neste capítulo foram apresentados os conceitos básicos que fundamentam este trabalho. O problema de navegação autônoma foi colocado, enfatizando as principais dificuldades encontradas na sua solução, e exemplos de várias abordagens já desenvolvidas. Foi também apresentada uma breve revisão das técnicas utilizadas na solução do problema, incluindo aquelas baseadas em redes neurais e sistemas nebulosos. O capítulo seguinte descreve a proposta de Verschure et. al., na qual este trabalho foi baseado, por ser esta considerada uma das mais promissoras abordagens para a solução do problema de navegação de veículos autônomos em ambientes desconhecidos.

3. Controle Adaptativo de Veículos Autônomos

3.1. Introdução

O controle de veículos autônomos é uma área onde, tradicionalmente, são utilizadas técnicas de inteligência artificial, devido à complexidade envolvida, à necessidade de planejamento, e à interação com o mundo. Entretanto, devido à estas características, os modelos baseados nos métodos da inteligência artificial tradicional só podem tratar problemas reduzidos, pois as necessidades de processamento requeridas impossibilitam o tratamento de situações complexas, como já foi discutido na seção 1.3.

Devido à necessidade de resposta em tempo real, o processamento associado aos métodos tradicionais torna-se muito lento ao tratar problemas complexos, impossibilitando, em geral, o tempo de resposta necessário. Outro ponto de interesse é o fato de que o ambiente nem sempre é completamente conhecido, sendo necessário dotar o sistema de controle de mecanismos de adaptação face às mudanças que podem ser encontradas, e às novas situações que podem ocorrer.

Com base nestes fatos, foi proposta por Verschure et. al. uma nova metodologia de controle, denominada Controle Adaptativo Distribuído[Ver92]. Esta metodologia baseia-se na teoria dos grupos neurais de Edelman[Ede87] para obter um sistema de controle que se adapte em função do ambiente, o qual é continuamente observado através de sensores. Este sistema pode, então, aprender uma forma de navegar em um ambiente, sem a necessidade prévia de programação ou treinamento.

As principais vantagens desta metodologia são: a capacidade de adaptação, característica das redes neurais, e a operação paralela de todos os elementos constituintes do sistema de controle, viabilizando sua utilização em controle.

3.2. Definição do Problema

O problema considerado é, essencialmente, o de controlar a movimentação de um veículo autônomo em um ambiente composto por obstáculos, paredes, e posições para as quais o veículo deve se movimentar (alvos). O veículo deve interagir com o ambiente, evitando colidir com obstáculos e alcançando os alvos.

A interação do veículo com o ambiente é feita através de conjuntos de sensores: de colisão, de distância até os obstáculos, e de posição do alvo, respectivamente. Os sensores de colisão e de distância são distribuídos por posições na frente do veículo, da seguinte maneira:

- os sensores de distância e colisão estão espaçados desde a posição -90° até $+90^{\circ}$, como apresentado na Figura 3.1;
- nas posições mais extremas, estes sensores estão mais espaçados, enquanto que na região central próxima ao 0° , os sensores estão mais perto um do outro, permitindo uma maior precisão na direção na qual o veículo normalmente se move, isto é, para frente;

- os sensores de alvo são 2, posicionados a -90° e $+90^{\circ}$, e apresentam resposta proporcional à distância do sensor ao alvo; a partir destes dados, o sistema de controle pode inferir a posição relativa do alvo, mais à direita ou mais à esquerda do veículo;
- os sensores de distância apresentam resposta proporcional à distância do sensor ao obstáculo mais próximo, apresentando uma resposta exponencial que atinge o máximo à uma determinada distância pré-especificada;
- os sensores de colisão apresentam resposta binária, sendo ativados somente quando o veículo colide com um obstáculo ou com uma parede;

A seguir é apresentado um diagrama esquemático do posicionamento dos sensores:

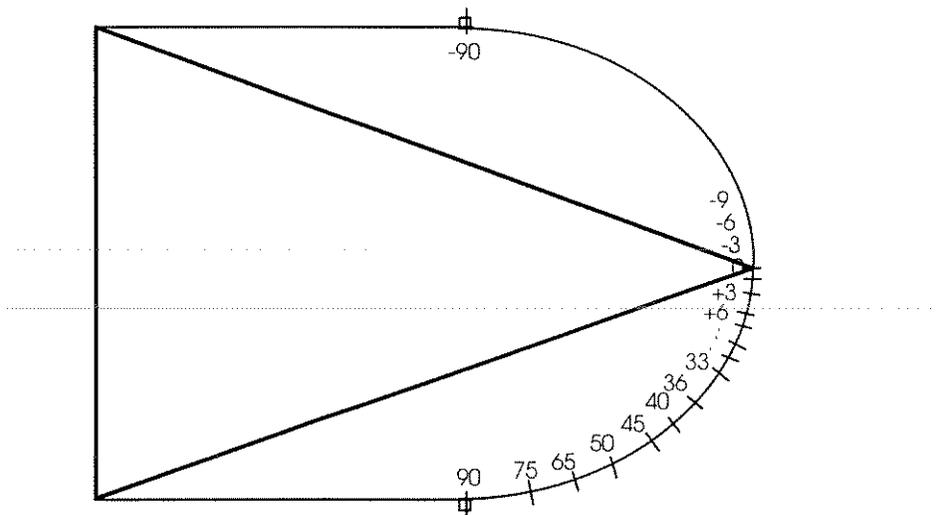


Figura 3.1 - Posicionamento dos sensores de distância e colisão

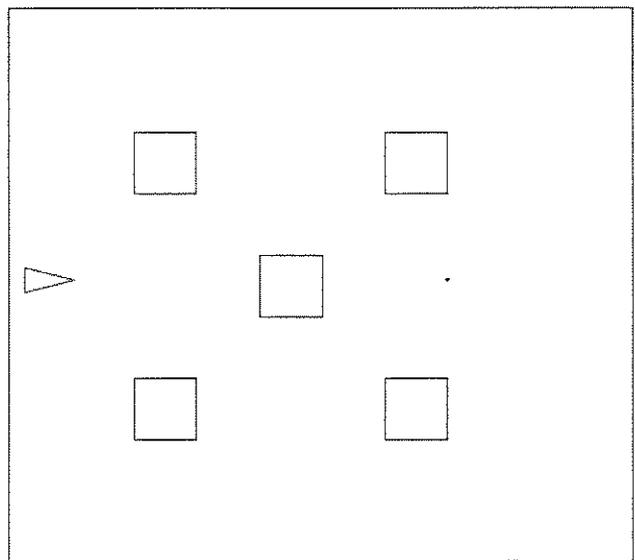


Figura 3.2 - Exemplo de um ambiente

O veículo deve, continuamente, procurar atingir o alvo, desviando dos obstáculos que porventura estejam no caminho. As capacidades de movimentação do veículo são: andar um passo para frente, virar à direita ou à esquerda um determinado grau (fixo), e dar marcha-a-ré (para os casos em que houver colisão). O ambiente é considerado fechado, possuindo obstáculos, e com alvos definidos por pontos, como mostrado na Figura 3.2.

3.3. Controle Distribuído Adaptativo

O controle adaptativo está baseado na teoria do estímulo condicionado clássico, apresentado por Verschure e Colen[Ver91], e nos estudos de Edelman e Pavlov. Segundo esta teoria, os seres podem aprender com base em sua própria interação com o ambiente, modificando seu comportamento para adequá-lo ao ambiente encontrado. No caso da navegação autônoma, o objetivo do sistema é aprender a chegar ao alvo, a partir de qualquer posição que se encontre, sem colidir com os obstáculos intermediários. Inicialmente, o sistema de controle não possui informação nenhuma sobre o ambiente, nem sobre como e onde desviar dos obstáculos, nem que tipo de obstáculos serão encontrados. Deste modo, o aprendizado é realizado no decorrer da interação com o ambiente, e é não supervisionado, sendo fornecida somente uma lei de aprendizagem, a qual dita que: em caso de colisão, o veículo deve modificar seus parâmetros internos de modo a evitar que colisões voltem a ocorrer novamente ; e em caso de alcance de alvos, o veículo deve reforçar os parâmetros, de modo que outros alvos em situação semelhante sejam também alcançados; como isto é feito é explicado a seguir.

3.3.1. Grupos Neurais

O sistema de controle é composto por vários grupos neurais [Ede87], correspondendo no caso a conjuntos de neurônios conectados aos sensores. Existem três grupos, cada grupo conectado a um conjunto de sensores do mesmo tipo, sendo que cada neurônio recebe entrada de um único sensor (tais grupos são denominados Colisão, Alvo e Distância, dependendo dos sensores que estão sendo utilizados, como na Figura 3.3). Os grupos Colisão e Alvo recebem, em adição, entradas provenientes das saídas do grupo Distância, moduladas por uma matriz de pesos entre cada saída do grupo Distância e cada entrada dos neurônios destes dois grupos. Desta forma, ao modificar estes pesos, é possível alterar o comportamento do controlador, e, conseqüentemente, o comportamento do veículo.

Os grupos neurais utilizados neste sistema de controle podem ser classificados como redes neurais não-recorrentes, por não possuírem conexões de realimentação entre neurônios de um mesmo grupo. Quanto a aprendizagem, os grupos neurais de Colisão e Alvo utilizam treinamento não-supervisionado, do tipo Hebbiano, pois é o tipo de treinamento que melhor se adequa à teoria do condicionamento clássico e de aprendizado por experiência. Uma explicação mais detalhada é encontrada na seção 3.3.2.

Há ainda um outro grupo, responsável pelo comando motor. Este grupo mapeia as saídas dos grupos Alvo e Colisão em ações motoras responsáveis pela movimentação do veículo, através de uma rede neural previamente treinada (treinamento supervisionado). Este grupo é implementado através de uma rede do tipo Perceptron multicamadas, recebendo entrada de cada saída dos neurônios dos grupos Colisão e Alvo ($39+2=41$ entradas), possuindo 20 neurônios na camada intermediária, e apresentando 4 neurônios de saída, correspondendo às ações de controle de movimentação previamente citadas.

Da interação entre estes quatro grupos, os quais, por sua vez, interagem com o ambiente através dos respectivos sensores e atuadores, se forma o comportamento do controlador e do sistema como um todo. Devido às constantes modificações que são efetuadas nos pesos inter-grupos, o sistema está em constante adaptação, procurando sempre se adequar ao ambiente e às situações nele encontradas.

A seguir, na Figura 3.3, é apresentado um diagrama esquemático do controlador adaptativo e as respectivas conexões entre os grupos neurais.

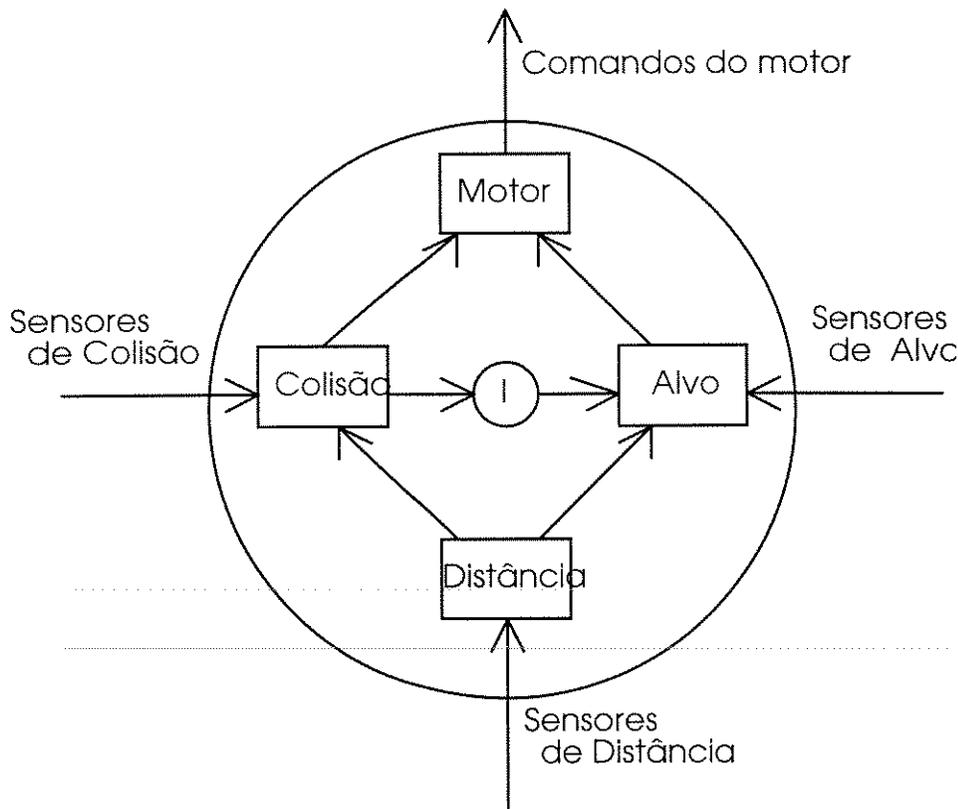


Figura 3.3- Controlador adaptativo e conexões entre os grupos neurais

O círculo central, marcado com a letra "I", é um módulo inibidor, que atua inibindo as saídas do grupo de Alvo sempre que houver uma saída ativa no grupo Colisão. Isto é necessário para, caso um obstáculo se encontre muito próximo, fazer com que seja mais relevante evitar colisões que chegar ao alvo. Assim, o controlador guia o veículo num procedimento de contorno de obstáculo, até que este esteja fora do caminho para o alcance do alvo.

Inicialmente, o comportamento do sistema não está definido. Conseqüentemente, o veículo não apresenta um comportamento adequado, avançando na direção do alvo até colidir com algum obstáculo. O veículo então retrocede, vira para algum lado (colisões pela direita tendem a fazer o veículo virar para a esquerda, e vice-versa), e novamente tenta ir em direção ao alvo. Após sucessivas colisões, os pesos vão sendo progressivamente modificados, fazendo com que o controlador atue com mais eficiência, girando antes de colidir, até o momento em que não ocorrem mais colisões. Nestas circunstâncias, considera-se que o sistema adaptou-se ao ambiente. Uma modificação do ambiente, ou inclusão/modificação de obstáculos, também modifica o comportamento do controlador, provocando eventuais colisões. Contudo, após algum tempo interagindo com o ambiente, o sistema se re-adapta, atingindo os alvos e evitando colisões com os obstáculos.

3.3.2. Aprendizagem e Adaptação

O sistema, ao contrário de sistemas clássicos de inteligência artificial, não possui uma representação interna explícita do ambiente em que está operando. Ao contrário, a fonte de informação a respeito do ambiente é fornecida pelos sensores. Com base exclusivamente nesta informação, e nenhuma pressuposição sobre a topologia do ambiente e os obstáculos nele

posicionados, é necessário que o sistema aprenda uma estratégia que o leve a realizar a tarefa definida.

No caso do grupo de colisões, as modificações nos pesos sinápticos (segundo a regra de Hebb) ocorrem somente quando um neurônio ligado à um sensor de colisão é ativado. No início da interação, os neurônios do grupo de colisão só se ativam quando realmente ocorre uma colisão. Os pesos são então modificados, de forma que outra colisão nesta mesma posição não aconteça novamente. Após um período de adaptação, os próprios pesos provocam a ativação do neurônio do grupo de colisão, antes que a mesma ocorra, prevendo deste modo a colisão, tomando uma ação (comando motor) para evitá-la.

Quando o veículo atinge um alvo especificado, os pesos relacionados aos respectivos neurônios são modificados, numa tentativa de reforçar o comportamento responsável pelo alcance do alvo. Deste modo, regras simples e locais de modificação de pesos de conexões levam, quando tomadas em conjunto, e após um período adequado de adaptação a um ambiente específico, à um comportamento global inteligente, pois os objetivos de movimentar, atingir alvos e evitar colisões são alcançados satisfatoriamente. Conseqüentemente, o sistema faz emergir o comportamento responsável pela navegação autônoma.

3.3.3. Condicionamento Clássico

O modelo de Controle Adaptativo Distribuído proposto por Verschure é baseado no estudo do condicionamento clássico em animais, estudado por Pavlov[Pav27]. Este estudo foi realizado para compreender o comportamento adotado por animais em sua interação com determinados estímulos, caracterizando deste modo um processo de aprendizagem dos mesmos.

O mecanismo de condicionamento pode ser visto como uma forma que um organismo possui de, baseado em experiências de interação com o ambiente, fazer previsões sobre os estímulos que serão encontrados.

O condicionamento clássico pressupõe que um organismo é capaz de perceber um determinado conjunto de estímulos do ambiente, os quais automaticamente provocarão resposta do seu próprio sistema nervoso. Um exemplo clássico é o do cão que, ao sentir a presença de alimento através de sensores de olfato e/ou visão (um estímulo), começa a salivar (reflexo automático). Esta relação estímulo-reflexo pode ser vista como definida geneticamente, pois implica diretamente na sobrevivência do animal se ele é capaz de reconhecer o seu alimento, sem que seja preciso treiná-lo para tal.

A teoria do condicionamento clássico define que o organismo pode desenvolver outras associações, que não as definidas geneticamente, para provocar reações que melhor o adequem ao seu ambiente, como no caso da associação do soar de uma sineta ao reflexo de salivação.

Uma outra propriedade conhecida sobre o condicionamento é que "um organismo somente aprende quando os eventos ocorridos violam suas expectativas"[Res72]. Somente eventos não usuais, do ponto de vista do organismo em relação à sua interação com o ambiente, é que podem ser considerados como relevantes em um processo de condicionamento.

Esta teoria, embora simples, mostra-se adequada à proposta de controle adaptativo distribuído, por ser baseada no aprendizado via interação com o ambiente, realizando um mapeamento das respostas obtidas nos sensores com um comportamento apresentado pelo sistema de controle.

3.3.4. Implementação

Os experimentos realizados no controle do veículo foram feitos em um ambiente de simulação implementado especialmente para esta função. Neste ambiente foram desenvolvidos simulações para um conjunto de obstáculos, um alvo a ser atingido, e os sensores necessários, sendo estes de distância, de colisão e de localização do alvo. A movimentação do veículo é definida da seguinte maneira:

- as capacidades de movimentação do veículo resumem-se em: andar para frente, realizar rotação à esquerda ou à direita, e dar marcha-a-ré;
- a ação *default* é avançar em velocidade constante, exceto no caso de colisão com algum obstáculo, quando então deve-se parar, realizar um retrocesso seguido de rotação, e então continuar a movimentação;
- por simular um sistema de movimento por eixos com rodas, o veículo somente realiza rotação para qualquer lado em conjunto com um movimento para frente ou para trás;
- o ângulo de rotação do eixo, a cada passo, é constante e é igual a 90° , tanto para a esquerda quanto para a direita;

A cada passo de simulação, os sensores posicionados em volta do veículo fornecem as entradas para os respectivos grupos neurais. O estado s_j relativo ao neurônio j do grupo neural conectado aos sensores de distância é dado por:

$$s_j = \frac{1}{e^{x(r_j - d_{\max})}} \quad (3.1)$$

sendo r_j a resposta do sensor de distância j , x um fator para controle da curvatura da função exponencial, e d_{\max} a distância (mínima) a partir da qual o sensor apresenta saída máxima (completamente ativada). Esta função é chamada *função de transdução* por traduzir eventos físicos relacionados pelo sensor no estado de um grupo neural. Esta função é utilizada para representar uma medida de *tempo para contato* [Lee76] com um obstáculo, i.e., quanto falta para a colisão com um obstáculo em se continuando o movimento nesta direção. A função exponencial é utilizada para prevenir que o valor de s_j cresça infinitamente para distâncias muito pequenas. Nas simulações apresentadas x possui valor 0.1 e d_{\max} valor 15.

Para os grupos neurais de colisão e alvo, a saída de cada neurônio (s_j) é um padrão binário, 0 ou 1, dependendo se o valor dado pela seguinte fórmula ultrapassar ou não um determinado valor limite (0.5 nas simulações):

$$h_i^\lambda = c_i^\lambda + \sum_{j=1}^N K_{ij}^\lambda s_j \quad (3.2)$$

O parâmetro λ denota o grupo neural, podendo ser C (colisão) ou A (alvo). c_i^λ denota a entrada proveniente do próprio sensor. N é o número de neurônios do grupo neural de distâncias, enquanto o somatório encarrega-se de levar em consideração as saídas do grupo neural de distâncias, ponderadas pelos pesos (K_{ij}^λ) associados às conexões entre os neurônios dos dois grupos neurais. Estes pesos são modificados segundo a seguinte lei, proposta por Verschure:

$$\Delta K_{ij}^\lambda = \frac{1}{N} \left[\eta^\lambda s_i^\lambda s_j - \epsilon s^{-\lambda} K_{ij}^\lambda \right] \quad (3.3)$$

onde η^λ denota a taxa de aprendizagem das conexões entre os grupos neurais de colisão e alvo e o de distância ($\eta = 0.2$ nas simulações). ϵ denota a taxa de decaimento ($\epsilon = 0.8$), e $s^{-\lambda}$ a ativação média de todo o grupo λ . Este último parâmetro faz com que o “esquecimento” do sistema seja proporcional à atividade do grupo neural. Assim, somente ocorrerá um decréscimo nos pesos das conexões no caso em que houver atividade no grupo neural. Isto é importante pois, caso contrário, seria impossível obter um estado estável dos pesos, pois mesmo que não ocorressem eventos (colisões, por exemplo) os pesos diminuiriam continuamente até chegarem novamente a zero, estado em que não há nenhum conhecimento sobre o ambiente. Esta característica permite ao sistema adquirir conhecimento somente quando ocorre um evento não esperado, como uma colisão. Por outro lado, enquanto o sistema consegue desviar-se com sucesso dos obstáculos, o conhecimento previamente adquirido deve ser mantido.

O elemento inibitório entre os grupos neurais de colisão e alvo possui uma ativação contínua, dada por:

$$a(t+1) = \alpha a(t) + \frac{1}{M^-} \sum_{i=1}^{M^-} s_i(t) \quad (3.4)$$

onde α denota a taxa de decaimento ($\alpha = 0.1$), M^- o número de elementos no grupo neural de colisões, e s_i o nível de ativação do elemento i deste grupo. A saída do elemento inibidor é binária, dependendo se o valor atual ultrapassa ou não um limiar (0.15). Se a ativação do grupo de colisões for grande o suficiente, o grupo de alvo é inibido, parando de atuar no controle da movimentação. Isto é necessário para que o grupo de colisão possa desviar os obstáculos encontrados mais facilmente, sem precisar sempre seguir em direção ao alvo até colidir.

3.4. Análise da Abordagem

Esta abordagem para o problema do controle autônomo de veículos auto-guiados apresenta muitos pontos interessantes, quando comparada a outras propostas mais tradicionais. Primeiramente, a utilização de elementos neurais que distribuem a tarefa de controle permite uma implementação paralela com respostas em tempo real. Outro item a destacar é a capacidade de adaptação durante o processo de interação com o ambiente. Isto provê o sistema de controle com uma capacidade de atuação nos mais diferentes ambientes, sem a necessidade de treinamento prévio. Um terceiro ponto relevante desta proposta é a capacidade de gerar comportamentos emergentes, provindos da própria experiência obtida durante a interação com o ambiente.

Entretanto, devido à relativa simplicidade dos sensores e mecanismos utilizados, o sistema de controle não consegue obter resultados satisfatórios quando em situações muito genéricas ou complexas de interação. Devido à isto, nossa proposta procura aumentar os potenciais de adaptação e generalização deste sistema, utilizando para tal as técnicas de sistemas nebulosos, pelos seguintes motivos:

- sistemas nebulosos capturam e tratam com facilidade incertezas encontradas com frequência em ambientes e sensores reais;
- o controle nebuloso provê a capacidade de ações de controle mais suaves, em lugar dos padrões fixos utilizados na proposta atual, nos comandos do grupo motor;
- a flexibilidade apresentada pelos sistemas nebulosos podem contribuir para melhorar o tratamento das informações provindas dos sensores, aumentando deste modo a robustez do sistema de controle como um todo;

3.5. Resumo

Neste capítulo foi detalhada a proposta original de controle adaptativo distribuído de Verschure et. al.[Ver92]. Foram discutidos os conceitos relacionados à esta proposta, bem como sua implementação. Foi realizada também uma discussão de suas características. Em vista disto, este trabalho propõe, no próximo capítulo, modificações baseadas nas técnicas de sistemas nebulosos, com o objetivo de incrementar o desempenho do sistema de controle, aumentando sua flexibilidade, sua generalidade, e sua capacidade de operação em ambientes complexos.

4. Controle Neuro-Nebuloso de Veículos Autônomos

4.1. Introdução

Este capítulo considera uma extensão do modelo de controle adaptativo proposto por Verschure et. al., utilizando para isto técnicas e abordagens baseadas na teoria de sistemas nebulosos. Objetiva-se com isto o incremento das capacidades de navegação e adaptação a ambientes desconhecidos, preservando as características principais de auto-adaptação e obtenção de comportamentos emergentes. Para tal, são introduzidas modificações no modelo original de Verschure, consistindo na substituição dos sensores de alvo e colisão por *sensores nebulosos*, além da introdução de um mecanismo de controle de movimentação baseado em lógica nebulosa. É introduzido também um mecanismo de fusão dos comportamentos de *desvio de obstáculos e localização de alvos*, visando obter um melhor compromisso em situações onde estes dois comportamentos estão em conflito.

4.2 Arquitetura do Sistema

O diagrama da arquitetura do sistema de controle neuro-nebuloso proposto é mostrado na Figura 4.1. As modificações introduzidas, as quais se basearam nas observações sobre o comportamento do sistema apresentado no capítulo anterior, estão resumidas a seguir:

- Os sensores de colisão e alvo originalmente utilizados no modelo de Verschure apresentam resposta binária, fornecendo pouca informação sobre a situação em que o veículo se encontra no ambiente. Esta informação resume-se na “posição de colisão”, no caso dos sensores de colisão, e na “direção do alvo”(direita/esquerda), no caso dos sensores de alvo. Com a introdução dos sensores nebulosos de colisão e alvo, a situação do veículo fica melhor caracterizada devido ao efeito granular da informação fornecida.
- A característica binária dos sensores de colisão leva o sistema original a, necessariamente, realizar um retrocesso para desviar dos obstáculos. A impossibilidade de um monitoramento contínuo do posicionamento quanto aos obstáculos obriga o sistema a, sempre que defrontar um obstáculo, realizar um retrocesso para só então efetuar a ação de desvio. A utilização de sensores nebulosos torna possível a monitoração e previsão de colisões, bem como a realização de ações de desvio na proporção necessária à situação corrente.
- A utilização de uma rede neural do tipo *feed-forward* codificando ações de controle motor rígidas e com ângulos fixos (90° à direita, 90° à esquerda, ré), impõe uma limitação na capacidade e flexibilidade de movimentação, características que são essenciais para a operação em ambientes complexos.
- Um problema adicional encontrado no modelo original é a sua dificuldade em coordenar as tarefas distintas de evitar colisões e alcançar alvos, principalmente em situações em que o alvo se encontra próximo ao obstáculo. O tratamento sugerido por Verschure consiste em apenas fornecer uma prioridade para o comportamento de *desvio de obstáculos*, impossibilitando deste modo o alcance de alvos em posições muito próximas ao contorno do ambiente ou aos próprios obstáculos. Com a introdução de um esquema de seleção proporcional de comportamento o sistema

de controle modificado estabelece compromissos entre as tarefas, quando em situações de conflito, a partir do grau de ativação dos grupos neurais associados.

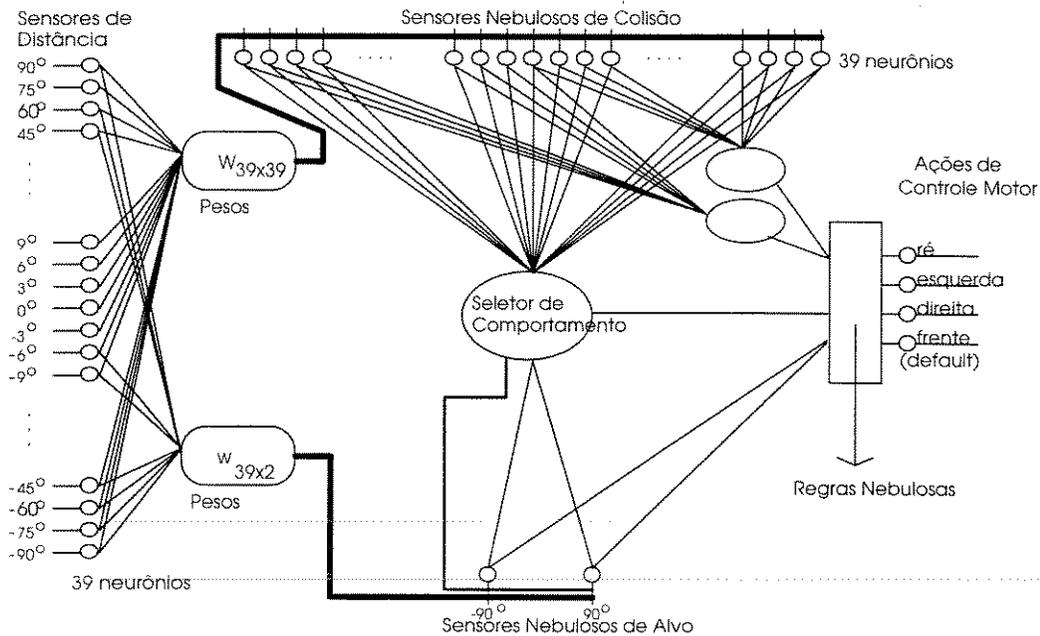


Figura 4.1 - Arquitetura do Sistema

Analogamente ao caso anterior, a interação do veículo com o ambiente é realizada através de sensores de distância a obstáculos, e de sensores de colisão e direção do alvo, os dois últimos nebulosos[Fab96a]. Os sensores estão posicionados conforme já explicitado na seção 3.2. Do mesmo modo, continuam existindo apenas 2 sensores de alvo, 39 sensores de colisão e 39 de distância. A seção seguinte (seção 4.3) detalha o funcionamento dos sensores nebulosos.

O módulo inibidor, utilizado na proposta de Verschure para inibir a saída do grupo neural de alvo, no caso de proximidade de algum obstáculo, foi substituído por outro, denominado *Seletor Proporcional de Comportamento*[Fab96b], responsável pela composição (fusão) das saídas dos dois grupos (de Colisão e de Alvo), no caso de proximidade simultânea de alvo e obstáculo. A seção 4.6 apresenta o funcionamento deste seletor.

O grupo de controle motor substitui a rede neural utilizada na proposta de Verschure por uma base de regras nebulosas de controle. Estas regras obtêm dados referentes às variáveis dos seus antecedentes tanto dos sensores nebulosos, quanto a partir de um processo de *fuzificação* das saídas dos grupos neurais. A utilização de regras nebulosas possibilita que os comandos motores do veículo sejam *contínuos*, substituindo os comandos rígidos anteriormente utilizados (vire à direita 9°, vire à esquerda 9°) por comandos linguísticos com maior conteúdo semântico (ex.: vire muito à esquerda, vire um pouco à direita). Estes comandos motores linguísticos são *defuzificados* para a determinação da rotação do veículo. As regras de controle nebuloso utilizadas, bem como uma explicação detalhada de seu funcionamento, são apresentados na seção 4.5.

4.3. Sistema de Sensores

4.3.1. Sensores Nebulosos de Colisão

Normalmente, sensores de colisão são *sensores de contato*, apresentando saída binária: inativo enquanto não colidiu, e ativo quando é detectada uma colisão. Neste trabalho utilizam-se sensores baseados na teoria dos conjuntos nebulosos[Gom92][Fou94]. Os sensores de colisão nebulosos substituem a saída binária dos sensores de contato por um valor que representa uma medida de *tempo para colidir*[Lee76]. Deste modo, cada sensor nebuloso fornece um *grau de colisão*, dependendo da proximidade do obstáculo. As saídas dos sensores são usadas pelo sistema de controle para atualizar os pesos entre os grupos neurais de colisão e distância, e pelas regras de controle para acionar ações de acordo com a situação.

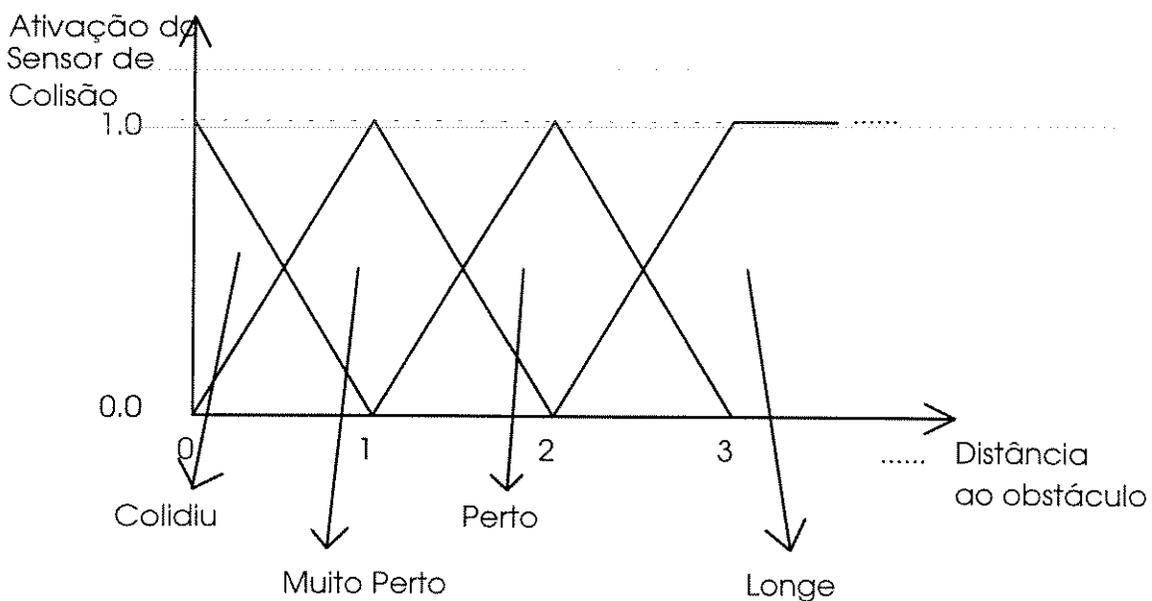


Figura 4.2 - Conjuntos Nebulosos Associados à cada Sensor de Colisão

Quanto ao sistema de controle, as entradas provenientes destes sensores (posicionados sobre o veículo) servem de entrada para o grupo neural de detecção de colisão. Isto é realizado através de um processo de *defuzificação* que, a partir dos conjuntos nebulosos gerados por cada sensor, calcula um valor no intervalo [0,1] correspondente à uma medida de possibilidade de colisão. Valores próximos de 1.0 indicam que existe uma alta chance de haver uma colisão. A função que faz a *defuzificação* é definida de forma a fornecer resultado 0.0 no caso do sensor apresentar como resposta o conjunto nebuloso *Longe*, e resposta 1.0 no caso da resposta ser o conjunto nebuloso *Colidiu*.

```

Procedimento Defuzifica_Leituras_dos_Sensores_de_Colisão
Início
  Para cada sensor faça:
    - Realize leitura do sensor nebuloso
    - Calcule nível defuzificado de ativação do sensor:
       $S_n = (\mu_{Longe} * 0.0) + (\mu_{Perto} * 0.5) + (\mu_{MuitoPerto} * 0.7) + (\mu_{Colidiu} * 1.0)$ 
    FimPara
Fim
    
```

Algoritmo 4.1 - Defuzificação das leituras dos sensores de colisão

As respostas dos sensores nebulosos são também utilizadas pelo mecanismo de controle motor. Neste caso, os conjuntos nebulosos não são *defuzificados*, e sim passados como antecedentes para as regras de controle responsáveis pelo desvio de obstáculos. Este mecanismo é detalhado na seção 4.4.

4.3.2. Sensores Nebulosos de Alvo

Consideram-se somente dois sensores de alvo, posicionados a -90° e $+90^\circ$ da frente do veículo. A saída destes sensores fornece uma estimativa da distância até o alvo. Destas duas medidas, o sistema de controle pode inferir o lado para o qual virar a fim de dirigir-se ao alvo. Assim, se o alvo está à esquerda, mas está longe, então o veículo pode virar apenas um pouco nesta direção. Por outro lado, se o alvo está muito próximo, então a ação de controle deve ser mais acentuada, e o veículo deve virar mais rapidamente para alcançar o alvo. As leituras destes sensores também são defuzificadas e utilizadas como entradas para o grupo neural de alvo, seguindo um algoritmo equivalente ao apresentado na seção anterior.

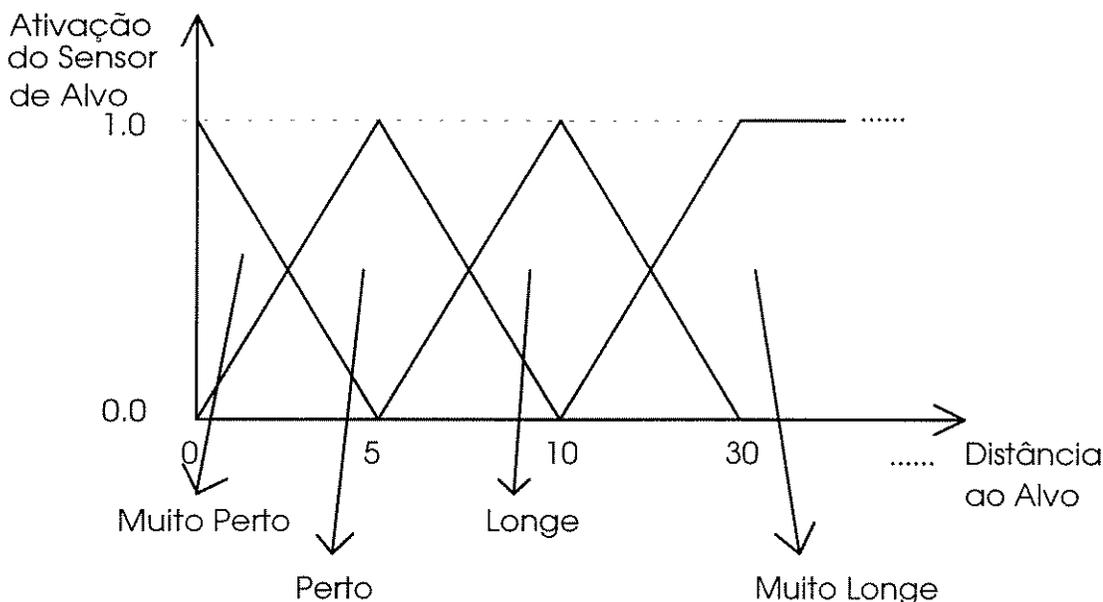


Figura 4.3 - Conjuntos Nebulosos Associados à cada Sensor de Alvo

4.4. Variáveis Linguísticas Obtidas dos Grupos Neurais

Para as regras nebulosas de controle, são necessárias informações sobre a distância ao alvo, a direção do alvo, a distância ao obstáculo mais próximo, e também a direção deste obstáculo. As distâncias são fornecidas através das leituras dos sensores nebulosos. As direções, entretanto, devem ser obtidas a partir da visão que o veículo possui do ambiente, para a obtenção do controle adaptativo através do aprendizado nos grupos neurais. Deste modo, para determinar a direção do alvo e do obstáculo mais próximo, é necessário um processo de *fuzificação* das saídas dos grupos neurais de detecção de alvo e de obstáculo, respectivamente. Isto se realiza através de uma comparação entre os níveis de ativação de todos os neurônios do grupo: o nível mais alto representa a posição do obstáculo mais próximo. É também necessário *fuzificar* a posição ao redor da qual se encontram os neurônios mais ativos, representando assim a possibilidade de uma colisão iminente em toda esta vizinhança. Os conjuntos utilizados para esta situação são apresentados na Figura 4.4. Para obstáculos à esquerda, os conjuntos são análogos, mas com os ângulos negativos.

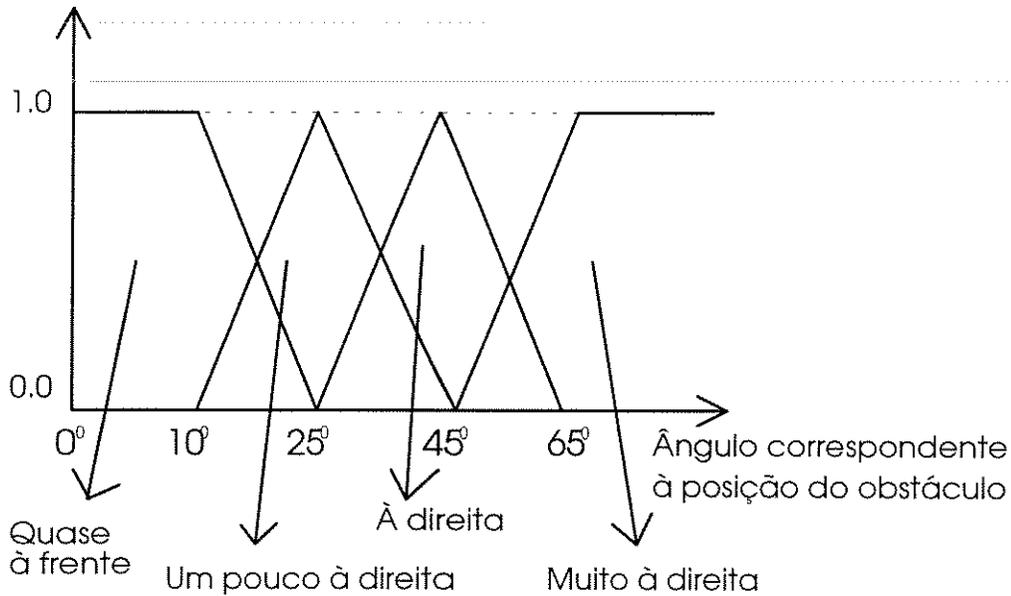


Figura 4.4 - Conjuntos Nebulosos representando direção do obstáculo mais próximo.

A seguir é apresentado o mecanismo de controle motor por regras nebulosas, o qual utiliza estas informações.

4.5. Regras de Controle Nebulosas

A arquitetura original proposta por Verschure utiliza uma rede neural pré-treinada para relacionar as saídas dos grupos de alvo e colisão com ações de controle rígidas e diretas (Ex: vire à direita 90°, vá em frente, de a ré). Neste trabalho as ações básicas de controle são especificadas por um conjunto de regras de controle nebulosas. As regras nebulosas são ativadas de acordo com informações provenientes dos sensores nebulosos, e com as saídas dos grupos neurais. Os sensores nebulosos de colisão e alvo fornecem informações sobre o ambiente. Do grupo neural de colisões, o sistema obtém informação sobre a *posição do obstáculo*. Esta informação é obtida encontrando o neurônio mais ativo. Os neurônios são associados com posições de obstáculos, descritos pelos seguintes conjuntos nebulosos: *quase a frente, um pouco, normal e muito*, seguidos pelo lado onde o obstáculo se encontra, *esquerda ou direita*. Com esta informação, as regras de controle tornam-se muito simples. Por exemplo:

Se o obstáculo está *muito à direita*, então vire *um pouco à esquerda*.

Regras nebulosas de controle adicionais são usadas para evitar colisões, como no seguinte exemplo; onde *sensor de colisão* e *posição do obstáculo* são variáveis nebulosas:

Se o sensor de colisão está no nível *colidiu* e o obstáculo está *à direita*, então *de a ré e vire à esquerda*.

Se o sensor de colisão está *perto* e o obstáculo está *à muito à direita*, então vire *um pouco à esquerda*.

Posição do obstáculo → Sensor de colisão ↓	Quase à frente, à direita	Um pouco à direita	À direita	Muito à direita
Colidiu	ré, muito à esquerda	ré, muito à esquerda	ré, à esquerda	ré, um pouco à esquerda
Muito Perto	ré, muito à esquerda	ré, muito à esquerda	ré, à esquerda	ré, um pouco à esquerda
Perto	muito à esquerda	muito à esquerda	à esquerda	um pouco à esquerda
Longe	siga em frente	siga em frente	siga em frente	siga em frente

Tabela 4.1 - Regras nebulosas de desvio de obstáculos



As regras para alcance de alvos são do tipo mostrado pelo seguinte exemplo, onde *direção do alvo* e *distância para o alvo* são variáveis nebulosas:

Se o alvo está à *direita*, e a distância para o alvo é *perto*, então vire *muito à direita*.

Direção do Alvo → Distância ao Alvo ↓	Quase à frente, à direita	Um pouco à direita	À direita	Muito à direita
Muito Perto	um pouco à direita	à direita	à direita	muito à direita
Perto	à direita	à direita	muito à direita	muito à direita
Longe	um pouco à direita	um pouco à direita	à direita	à direita
Muito Longe	um pouco à direita	um pouco à direita	um pouco à direita	um pouco à direita

Tabela 4.2 - Regras Nebulosas de alcance de alvos

Observe que as regras de alcance de alvo e desvio de obstáculos podem ser conflitantes; por isto é necessária a presença do seletor de comportamento proporcional.

4.6. Seleção Proporcional de Comportamento

Para assegurar o desempenho global do sistema em encontrar alvos e desviar de obstáculos, mesmo quando os alvos se encontram próximos a obstáculos, foi introduzido um *seletor proporcional de comportamento*. Este seletor realiza suas decisões baseado em medidas de *ativação* dos grupos neurais de alvo e colisão, sendo as regras de controle proporcionalmente compostas para decidir a ação final a ser tomada. As fórmulas para calcular os níveis de ativação são:

- Ativação do Grupo de Colisões (α_c):

$$\alpha_c = \frac{1}{m_c} \sum_{n=1}^{m_n} s_n \quad (4.1)$$

onde m_c é o número de neurônios do grupo de colisões ($m_c=39$) e s_n são os níveis de ativação dos neurônios.

- Ativação do Grupo de Alvos (α_a):

$$\alpha_a = \mu \frac{1}{\sum_{n=1}^{m_n} dist_n} \quad (4.2)$$

onde *dist* é uma função que avalia a distância entre cada sensor e o alvo. O fator μ é utilizado para compatibilizar os níveis de ativação, e m_a é o número de neurônios do grupo de alvos ($m_a=2$). Neste trabalho, considerou-se $\mu = 10$.

Procedimento Seletor_Proportional_de_Comportamento
 Início

- Calcular ativação do grupo de colisões - α_c -Fórmula 4.1
- Calcular ativação do grupo de alvos - α_a -Fórmula 4.2
 ($dist_n$ = defuzificação da leitura do sensor nebuloso)
- Calcular resposta motora defuzificada m_c (em graus)
 obtida a partir do processo de inferência nebulosa
 sobre as regras da Tabela 4.1 - Grupo de colisões
- Definir resposta motora defuzificada m_a (em graus)
 obtida a partir da Tabela 4.2 - Grupo de alvos
- Calcular ação de controle proporcional (em graus)
 através da seguinte fórmula:

$$A = \alpha_c / (\alpha_c + \alpha_a) * m_c + \alpha_a / (\alpha_c + \alpha_a) * m_a$$
- Retornar ação de controle A a ser tomado pelo veículo

Fim.

Algoritmo 4.2 - Funcionamento do seletor proporcional de comportamento

4.7. Implementação

Na implementação do sistema de controle foi utilizado o ambiente de simulação descrito no capítulo 3. As capacidades de movimentação do veículo foram redefinidas da seguinte maneira:

- o veículo é capaz de realizar rotação à esquerda ou à direita, de um ângulo no intervalo entre $[-20^\circ, +20^\circ]$, de acordo com o determinado pelas regras de controle motor. Esta ação é *defuzificada*, utilizando o método do centro de área, e o resultado é o ângulo de rotação efetivamente aplicado ao veículo;
- a ação *default* é avançar em velocidade constante, definida pelo sistema de controle; no caso de colisão com algum obstáculo, deve-se parar, realizar um retrocesso seguido de rotação, e continuar a movimentação;

A cada passo de simulação, os sensores posicionados sobre o veículo fornecem as entradas para os respectivos grupos neurais e para a base de regras de controle motor.

O estado s_j relativo ao neurônio j do grupo neural conectado aos sensores de distância é dado por:

$$s_j = \frac{1}{e^{x(r_j - d_{\max})}} \quad (4.3)$$

Esta função, chamada *função de transdução*, corresponde à saída de cada neurônio do grupo de distância. No caso das simulações apresentadas neste trabalho, d_{\max} possui valor 15, e x valor 0.1.

Para os grupos neurais de colisão e alvo, a ativação(saída) de cada neurônio s_j é um valor contínuo no intervalo $[0,1]$, calculado através da seguinte fórmula:

$$h_i^\lambda = c_i^\lambda + \sum_{j=1}^N K_{ij}^\lambda s_j \quad (4.4)$$

O parâmetro λ denota o grupo neural, podendo ser C (colisão) ou A (alvo). c_i^λ denota a entrada proveniente do próprio sensor, já *defuzificada*, com valor no intervalo $[0,1]$, como apresentado no algoritmo 4.1. N é o número de neurônios do grupo neural de distâncias (39 neste caso), enquanto o somatório encarrega-se de levar em consideração as saídas do grupo neural de distâncias, ponderadas pelos pesos (K_{ij}^λ) associados às conexões entre os neurônios dos dois grupos neurais. Estes pesos são modificados segundo a seguinte lei:

$$\Delta K_{ij}^\lambda = \frac{1}{N} \left[\eta^\lambda s_i^\lambda s_j - \epsilon s^{-\lambda} K_{ij}^\lambda \right] \quad (4.5)$$

onde η^λ denota a taxa de aprendizagem das conexões entre os grupos neurais de colisão e alvo e o de distância ($\eta^\lambda = 0.2$ nas simulações). ϵ denota a taxa de decaimento ($\epsilon = 0.8$), e $s^{-\lambda}$ a ativação média de todo o grupo. Estas fórmulas são as mesmas utilizadas no modelo de Verschure, exceto que são considerados valores contínuos em $[0,1]$ para as ativações dos neurônios.

4.8. Resumo

Neste capítulo foram apresentadas as modificações introduzidas no modelo original de Verschure, com o intuito de incrementar as capacidades do controle adaptativo distribuído. Estas características foram baseadas na teoria de sistemas nebulosos, principalmente as idéias de sensores nebulosos e lógica nebulosa. Foi também apresentado um método de fusão das respostas dos grupos neurais, de modo a tratar difíceis situações, tipicamente onde alvos a serem alcançados se encontram muito próximos a obstáculos.

5. Simulação e Análise de Resultados

5.1. Introdução

Neste capítulo são apresentados os resultados das simulações realizadas, afim de se demonstrar a efetividade da metodologia, quando comparada com outras existentes, principalmente com o modelo de controle adaptativo distribuído no qual este trabalho foi baseado. Para realizar as comparações de desempenho, inicialmente são apresentados os resultados obtidos em simulações realizadas com o sistema proposto por Verschure et al.. Em seguida as modificações introduzidas durante várias etapas deste trabalho são apresentadas, e, finalmente, com o sistema proposto completo. Uma comparação com uma metodologia alternativa é também considerada.

5.2. Controle Adaptativo Distribuído

Este sistema de controle, discutido no capítulo 3, apresenta vantagens sobre metodologias alternativas[Bro86][Ish91], principalmente com relação à sua adaptabilidade ao ambiente em que se encontra, apesar da simplicidade de sua organização em grupos neurais. Entretanto o sistema apresenta limitações quando utilizado em situações complexas, excedendo seu poder de generalização e aprendizado.

Na Figura 5.1 é apresentado o resultado da navegação em um ambiente simples, com apenas um obstáculo. O sistema consegue generalizar o conhecimento adquirido, atingindo, após um período inicial de adaptação, um desempenho satisfatório (alcança os alvos, contornando o obstáculo central). O sistema colide inicialmente, até desenvolver o comportamento de contorno de obstáculo.

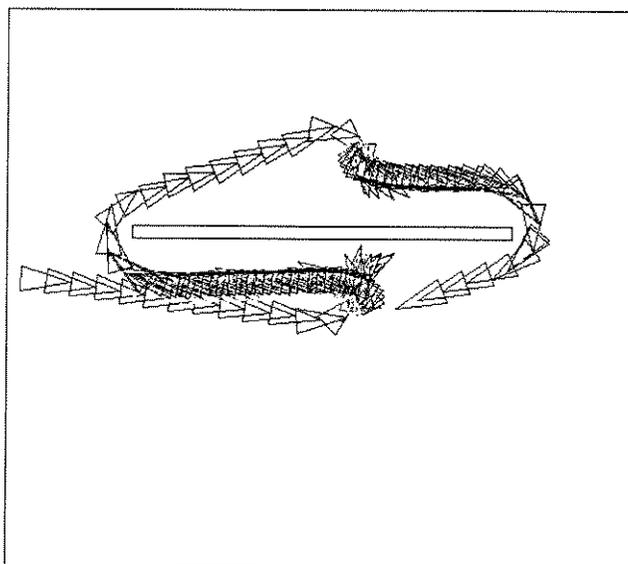


Figura 5.1 - Trajetória do veículo: ambiente simples e posições de alvo fixas

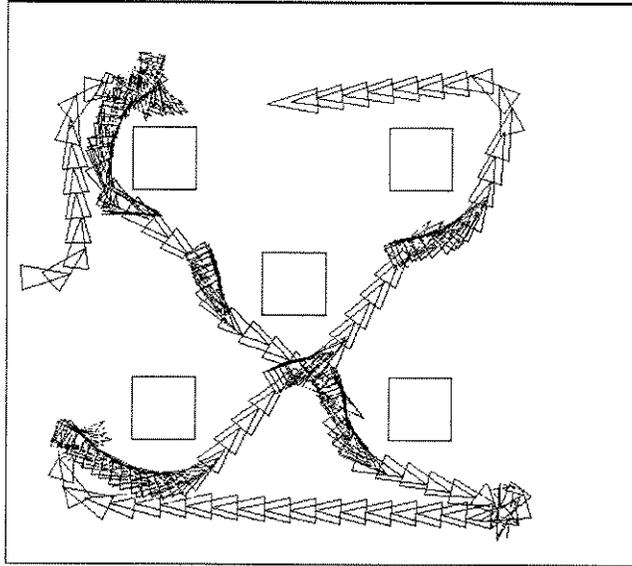


Figura 5.2 -Trajetória do veículo: ambiente mais complexo e posições de alvo fixas

No caso mostrado na Figura 5.2, as posições dos obstáculos configuram um ambiente mais complexo. Entretanto, devido ao fato de os alvos serem apresentados em posições fixas (os quatro cantos do ambiente), ainda é possível ao sistema de controle, após um período de adaptação mais prolongado, obter sucesso em evitar colisões.

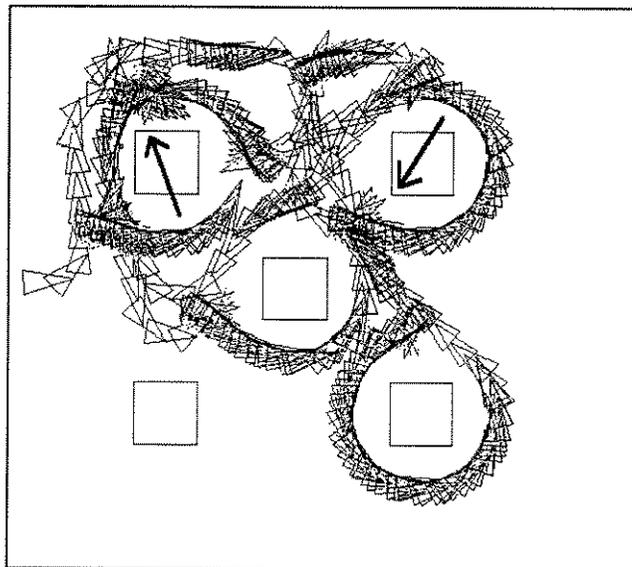


Figura 5.3 - Trajetória do veículo: posições de alvos aleatórias - Flechas indicam colisões

Entretanto, no caso mostrado Figura 5.3, as posições de alvo são geradas aleatoriamente cada vez que um alvo é alcançado, ou após um período pré-determinado (300 passos). A complexidade envolvida nesta situação aumenta, eventualmente levando a situações onde o alvo fica muito próximo a obstáculos, e a necessidade do tratamento de um número muito maior de situações onde é necessário o desvio de obstáculos. Neste tipo de situação, o sistema de controle não realiza uma adaptação satisfatória, continuando a colidir indefinidamente durante todo o período de simulação. Na Figura 5.4 é apresentada a evolução das colisões, dos desvios provocados pelo grupo neural de colisões, e dos alvos alcançados.

Observa-se que, após um período inicial de adaptação, no qual o veículo colide várias vezes, os desvios passam a ser realizados principalmente pelo grupo neural de colisões, a partir das informações procedentes dos sensores de distância. Entretanto, mesmo após o período inicial de adaptação, continuam a ocorrer colisões continuamente. O sistema não consegue generalizar todas as situações com que se defronta, voltando a colidir seguidamente.

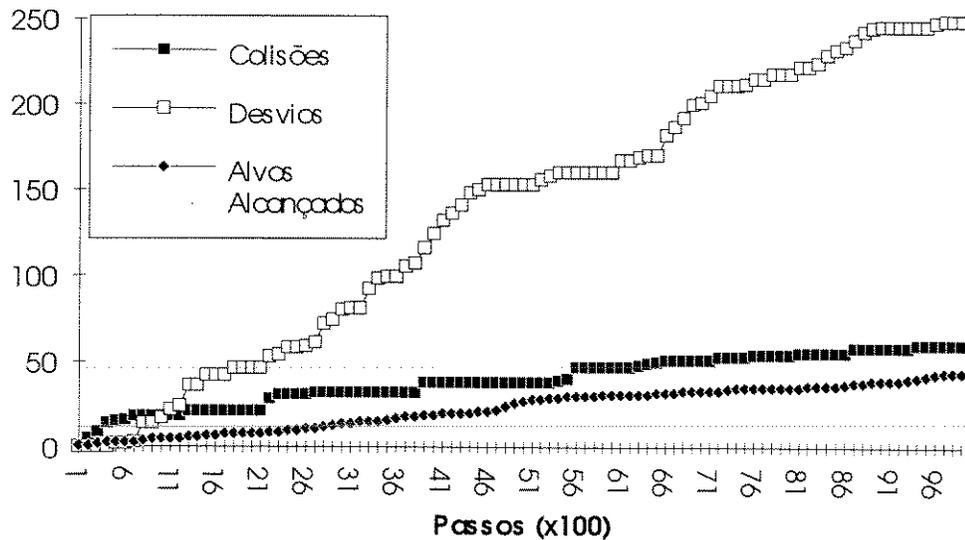


Figura 5.4 - Colisões, alcance de alvos e desvios referentes à trajetória da Figura 5.3

5.2. Sistema Neural com Sensores Nebulosos

A primeira tentativa para se obter um melhor desempenho do sistema de controle consistiu em substituir os sensores de colisão originais, com resposta binária, por sensores nebulosos com resposta contínua, como os descritos no capítulo anterior. As saídas dos sensores são conjuntos nebulosos, que são *defuzificados* pelo método do centro de área, e convertidos em sinais para a entrada dos neurônios do grupo de colisão. Tal conversão é realizada no sentido de fornecer como entrada aos neurônios um valor que represente o grau de possibilidade da ocorrência de uma colisão. Tal modificação possibilitou uma mudança adicional no sistema de controle motor: com ativações contínuas dos sensores de colisão, tornou-se possível realizar ações de desvio de obstáculos apenas por uma mudança de trajetória, e não mais necessariamente por um retrocesso seguido de rotação, como no caso da proposta original de Verschure. A vantagem desta alternativa é a possibilidade de se desviar obstáculos sem primeiro parar e dar a ré no veículo. A necessidade de ré reduz-se aos casos onde não se obteve sucesso no desvio antecipado, e a colisão realmente ocorre. As Figuras 5.5 e 5.6 apresentam os resultados obtidos com estas modificações.

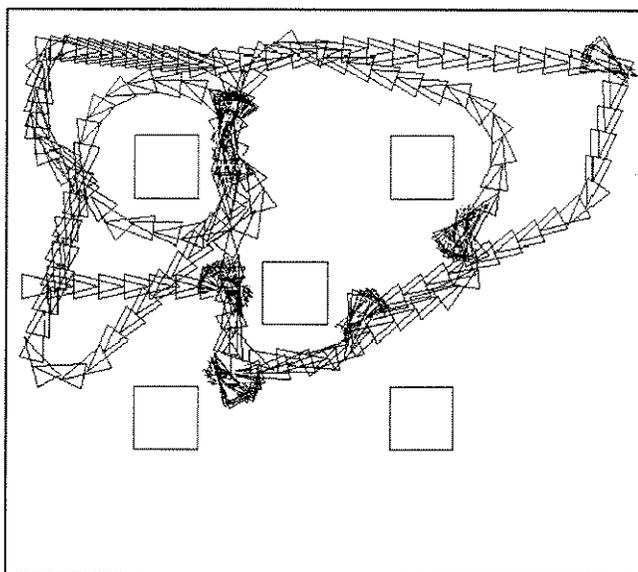


Figura 5.5 - Exemplo de trajetória obtida pelo sistema com sensores nebulosos

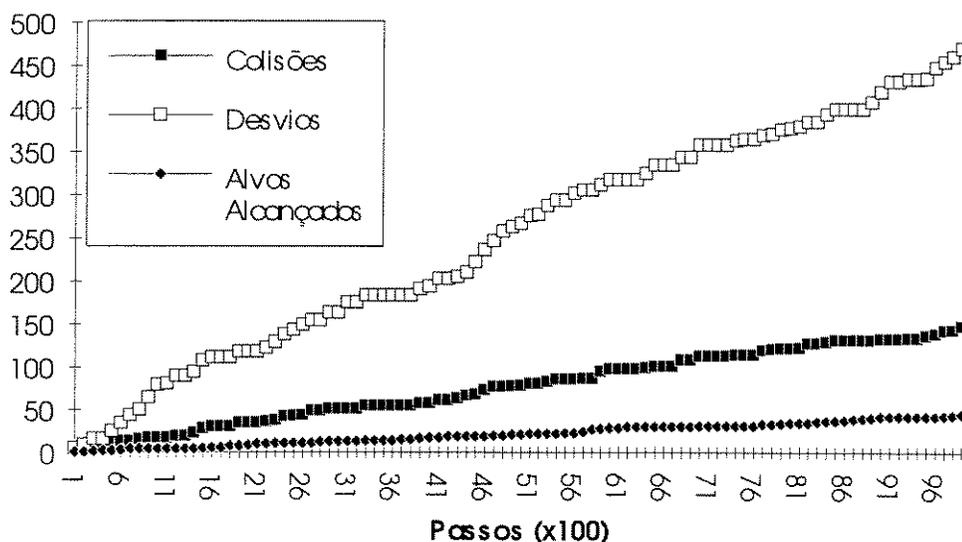


Figura 5.6 - Colisões, alcance de alvos e desvios referentes à trajetória da Figura 5.5

Não se observa melhorias significativas no desempenho do sistema de controle, exceto o fato de que o número de retrocessos diminuiu consideravelmente. Entretanto, o número de colisões aumentou, levando à conclusão de que o mecanismo de desvio sem retrocesso implantado não se mostrou efetivo enquanto as ações de controle se mantiveram rígidas (i.e. girar 9° à esquerda ou à direita). Devido ao fato dos sensores de colisão apresentarem resposta significativa somente quando muito próximo ao obstáculo (ver seção 4.5), não há a possibilidade de se evitar colisões apenas com estas ações de controle.

5.3. Sistema com Sensores e Controle Nebuloso

Com o objetivo de obter maior desempenho no desvio de obstáculos, e evitar os inconvenientes das ações rígidas de controle até então utilizadas, considerou-se a substituição da rede neural pré-treinada da proposta de Verschure por um sistema de controle nebuloso. As vantagens deste modelo são a maior flexibilidade das ações de controle (que podem variar continuamente em todo o universo de ações possíveis). As regras de controle utilizadas foram descritas na seção 4.5. Além disto, foram também introduzidos os sensores nebulosos de alvo, proporcionando informações adicionais sobre o posicionamento relativo do alvo (direção e distância aproximadas do alvo). Com estas modificações, o sistema passou a apresentar características como as mostradas nas Figuras 5.7 e 5.8.

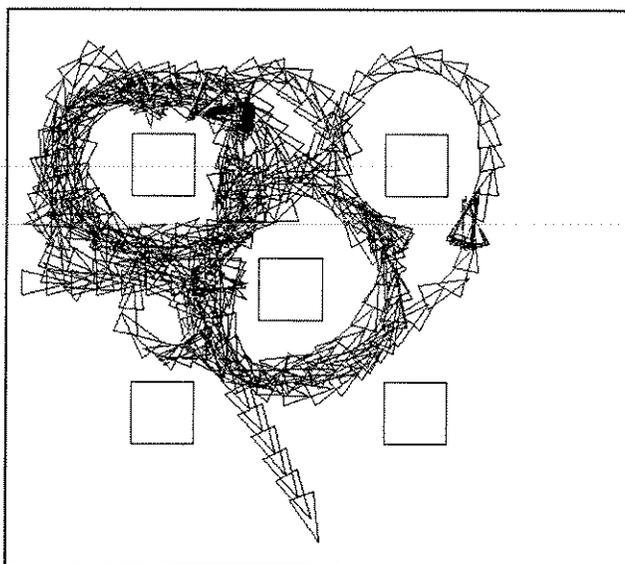


Figura 5.7 - Exemplo de trajetória obtida pelo sistema com sensores e controle nebulosos

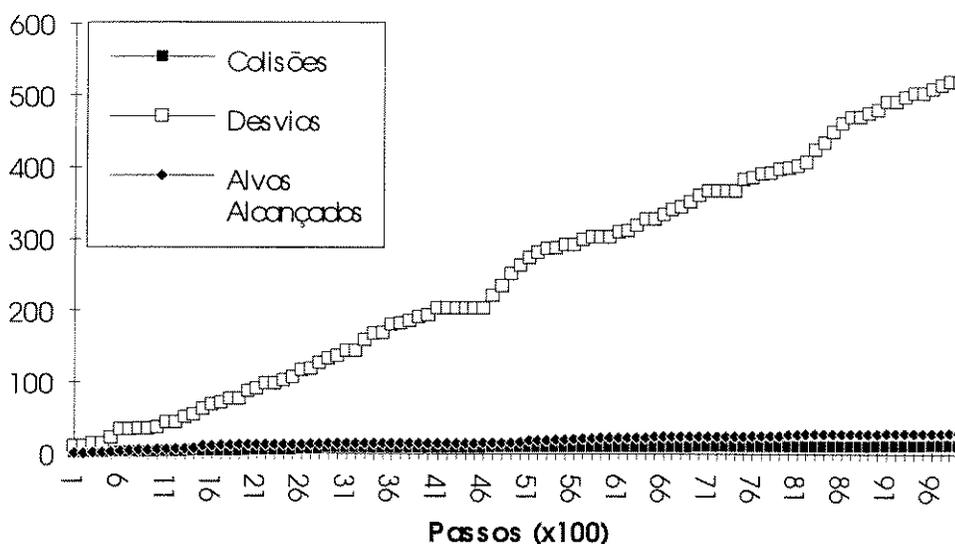


Figura 5.8 - Colisões, desvios e alvos alcançados referentes à trajetória da Figura 5.7

A Figura 5.9 detalha o número de colisões e de alvos alcançados pelo novo sistema. Observa-se o aumento da capacidade do sistema de realizar os desvios de obstáculos, representado pelo aumento significativo dos desvios antecipados (controlados pelos sensores de distância e interações entre os grupos de Distância e Colisão), além da diminuição do número de colisões ocorridas durante as simulações. Durante a simulação, o número de colisões esteve na média de 30 colisões em 10000 passos, o que representa um grande avanço em relação ao sistema anterior. O número de alvos alcançados pelo sistema, entretanto, manteve-se constante, não sendo afetado pela inclusão dos sensores nebulosos e das regras de controle nebulosas. Uma consideração para explicar tal comportamento é a forma pela qual o sistema manipula a preferência pelo desvio de obstáculos, através do módulo inibidor. Esta forma leva a situações como a da Figura 5.10, onde o sistema não consegue alcançar um alvo posicionado próximo ao obstáculo.

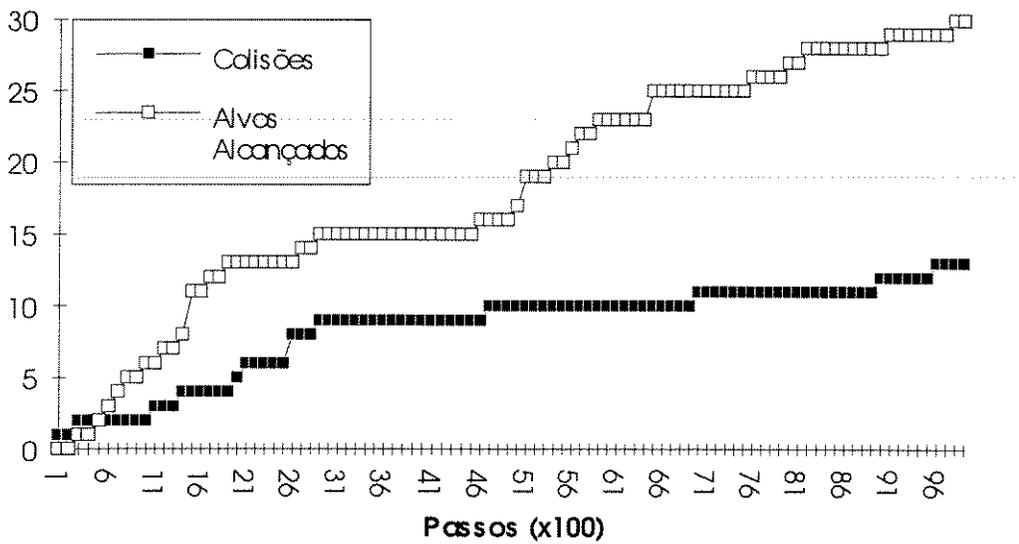


Figura 5.9 - Detalhamento da Figura 5.8 - número de colisões e alvos alcançados

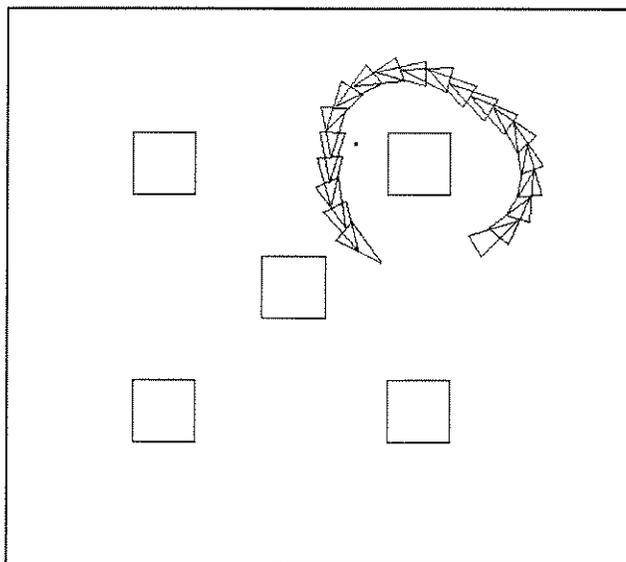


Figura 5.10 - Situação em que o sistema não alcança um alvo muito próximo à obstáculo

Para evitar estas situações, o módulo inibidor foi substituído por outro denominado Seletor Proporcional de Comportamento, o qual compõe os sinais provenientes dos grupos de Colisão e de Alvo para acionar o sistema nebuloso de controle motor.

5.4. Sistema de Controle com Seletor Proporcional de Comportamentos

O sistema proposto final, com os sensores nebulosos de alvos e obstáculos, o módulo de controle motor implementado via lógica nebulosa, e o seletor proporcional de comportamento, é analisado nesta seção. Na Figura 5.11, o sistema realiza com sucesso a navegação em um ambiente simples, com alvos posicionados em locais fixos. Não ocorreu nenhuma colisão durante esta simulação, e o sistema apresentou um comportamento de desvio de obstáculos satisfatório. Na Figura 5.12, em um ambiente mais complexo, porém ainda com alvos fixos, o sistema também consegue realizar a navegação sem colisões. Na simulação mostrada na Figura 5.13, o posicionamento dos alvos é aleatório. O sistema também apresenta resultados satisfatórios, pois o número de colisões ocorridas durante toda a simulação é nulo. Inicialmente, os sensores nebulosos, em conjunto com as regras de controle motor, obtém informações suficientes para evitar colisões. Com a evolução da interação com o ambiente, o sistema de controle se adapta, conseguindo antecipar e evitar colisões ao mesmo tempo em que se dirige para os alvos.

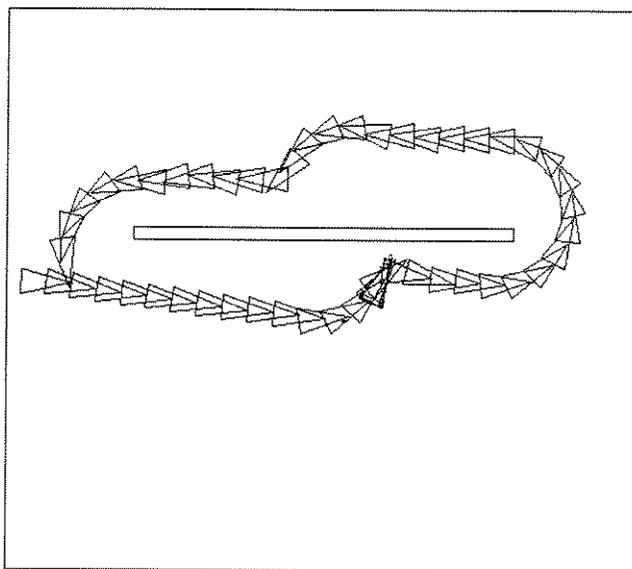


Figura 5.11 - Exemplo de trajetória : ambiente simples e alvos fixos

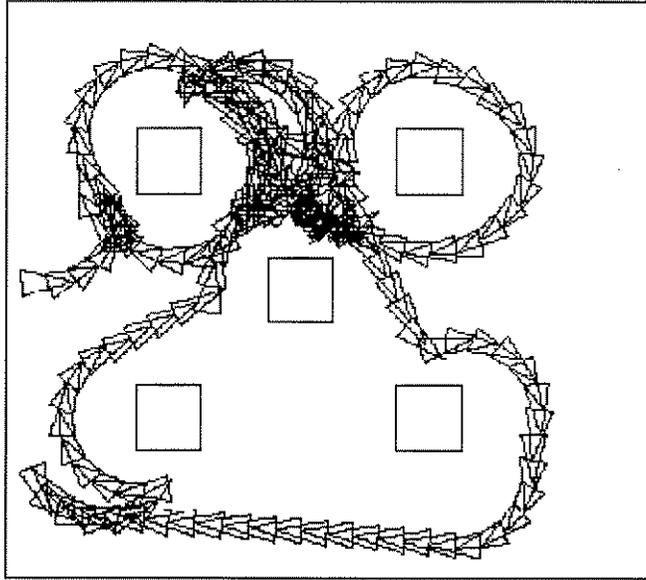


Figura 5.12 - Exemplo de trajetória : ambiente mais complexo e posições de alvo fixas

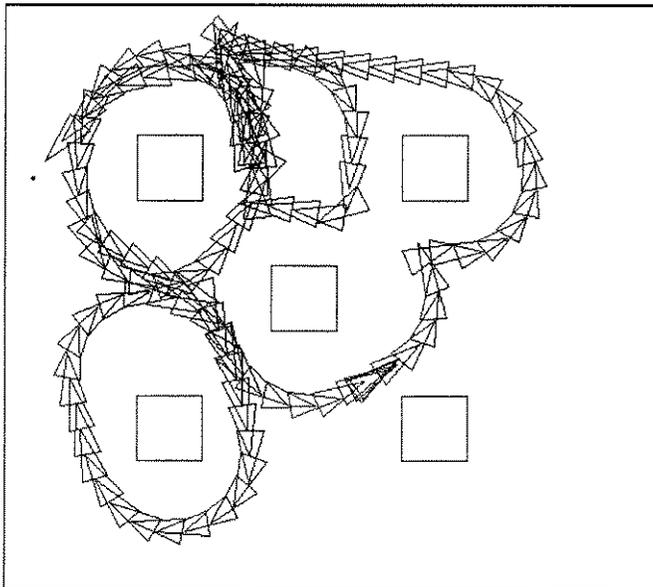


Figura 5.13 - Trajetória do veículo: posições de alvos aleatórias

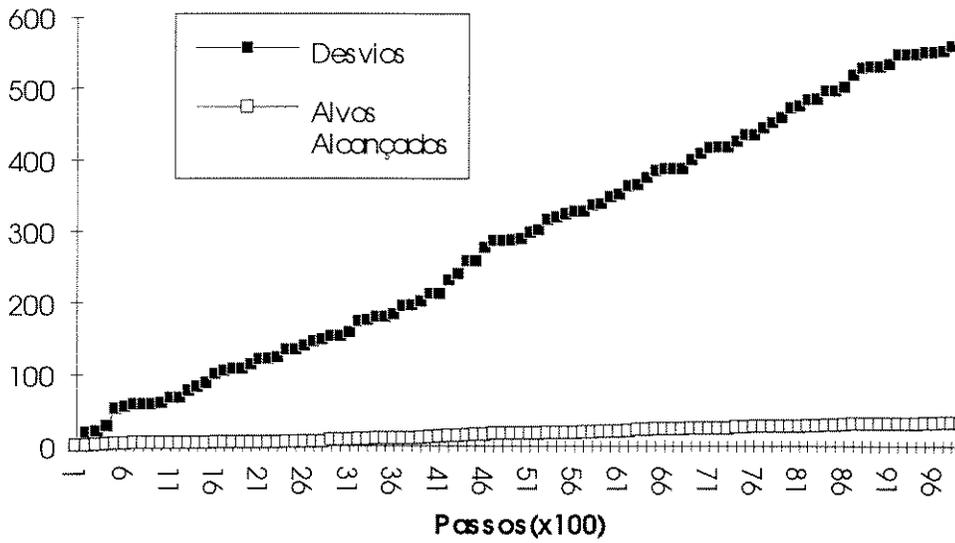


Figura 5.14 - Alcance de alvos e desvios relativos à trajetória da Figura 5.13.

Após realizada a simulação correspondente à Figura 5.13, o veículo foi colocado em um outro ambiente diferente, como o apresentado na Figura 5.15. O objetivo é o de testar as capacidades de adaptação do sistema face a novas situações encontradas no novo ambiente. Os alvos continuaram sendo apresentados aleatoriamente. O sistema foi capaz de navegar neste novo ambiente via adaptação, sem que tenha ocorrido nenhuma colisão. Na Figura 5.16, é apresentado o desempenho nesta nova situação, em termos de desvios e alvos alcançados.

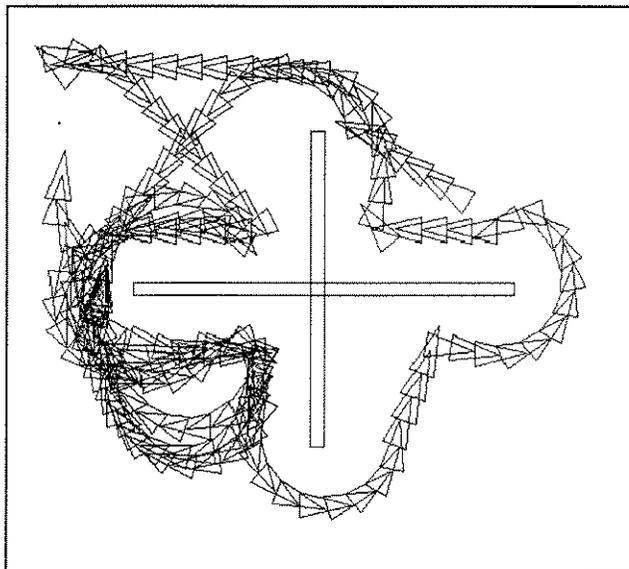


Figura 5.15 - Trajetória do veículo após mudança de ambiente.

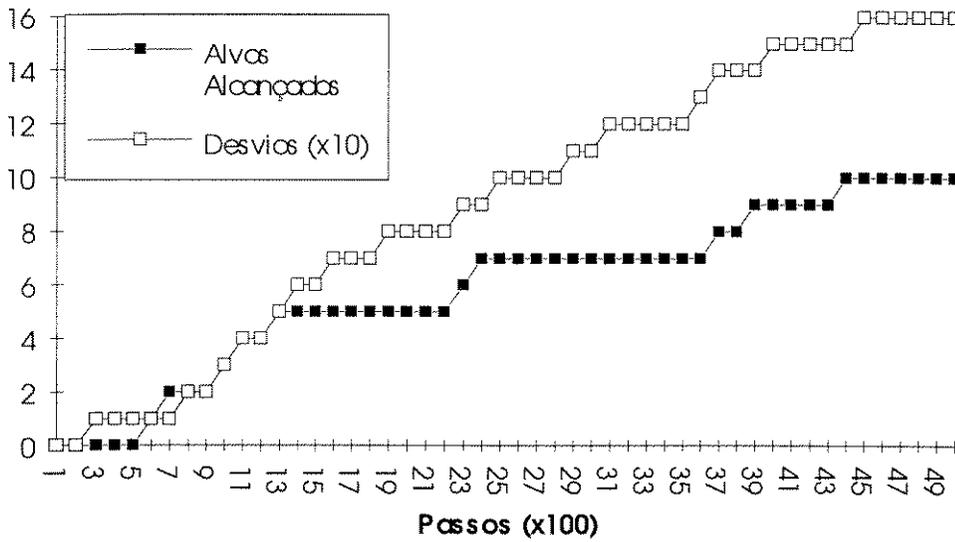


Figure 5.16 - Alcance de alvos e desvios relativos à trajetória apresentada na Figura 5.15

A mesma simulação foi realizada utilizando o sistema de controle original proposto por Verschure. Um exemplo de trajetória obtida está apresentado na Figura 5.17. Flechas indicam posições onde voltaram a ocorrer colisões, durante o processo de re-adaptação. Na Figura 5.18, são apresentados os resultados obtidos, em relação à colisões, desvios e alvos alcançados. Destas simulações pode-se observar que o sistema de controle proposto neste trabalho possui maior capacidade de generalização, quando comparado à proposta original de Verschure.

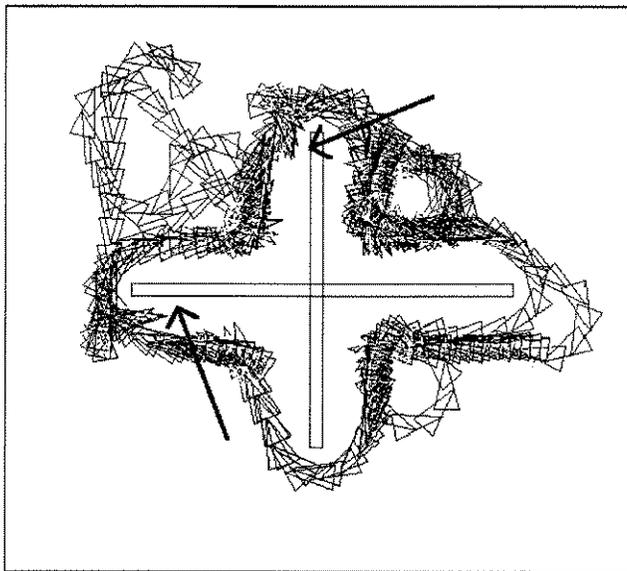


Figura 5.17 - Trajetória realizada pelo veículo após mudança de ambiente - Sistema de controle original de Verschure

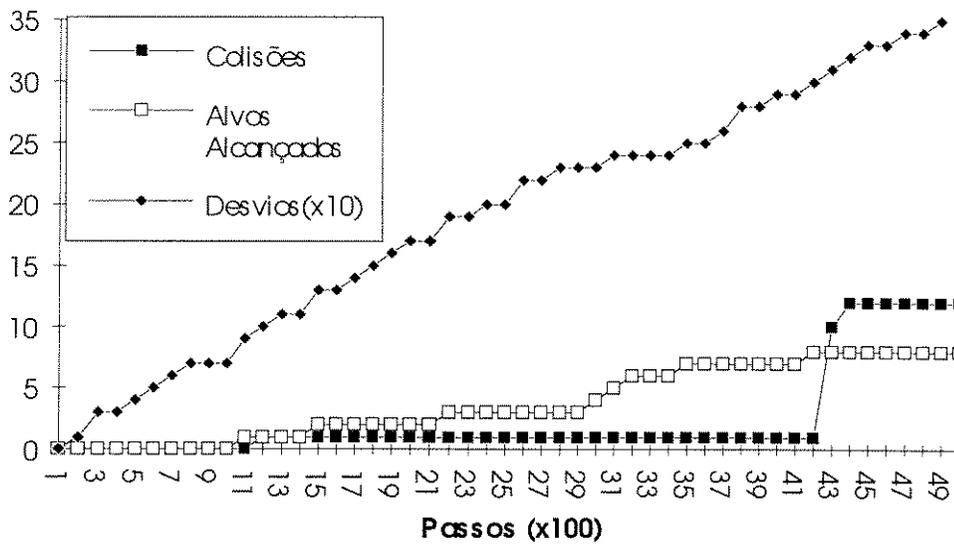


Figura 5.18 - Alcance de alvos, desvios e colisões relativos à trajetória da Figura 5.17

5.5. Resultados obtidos em comparação com a proposta de Oliveira

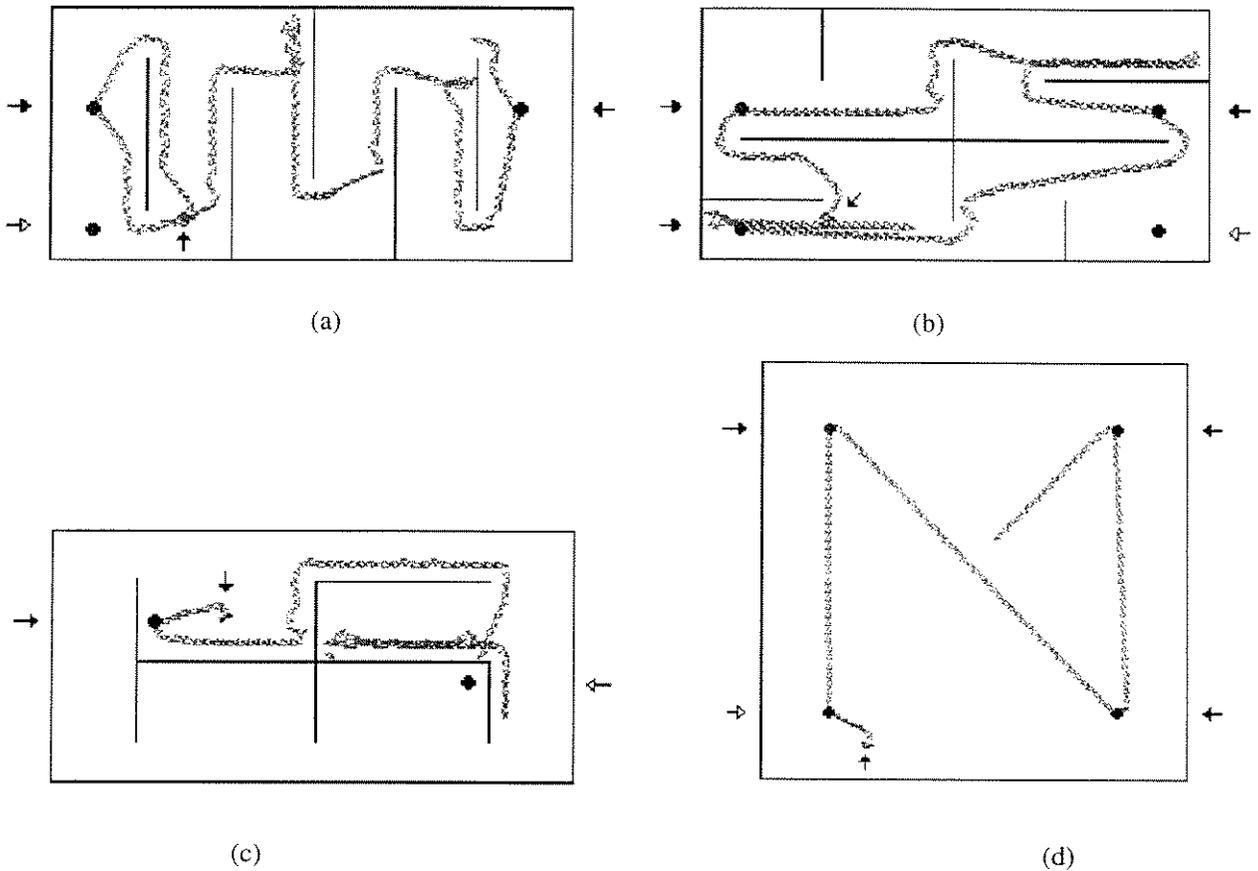


Figura 5.19 - Simulações obtidas pela proposta de sistema de controle apresentada por Oliveira
 Na Figura 5.19 são apresentadas trajetórias obtidas pelo sistema proposto por

Oliveira[Oli95]. Tal sistema é também baseado em sensores, utilizando uma rede neuro-fuzzy, proposta por Figueiredo[Fig94], e algoritmos genéticos[Alm92] como forma de aprendizado. Os resultados obtidos são satisfatórios, e o sistema de controle final obtido consegue realizar a tarefa de navegação em ambientes diversos, sem colisões. Uma diferença fundamental entre o sistema proposto por Oliveira e o desenvolvido neste trabalho é o mecanismo de aprendizado: enquanto num o treinamento é realizado a priori, por um mecanismo de otimização (algoritmos genéticos) de parâmetros da rede neuro-nebulosa, no caso aqui desenvolvido a adaptação se realiza durante o processo de interação, estando sempre se adaptando à novas situações e novos ambientes que possam surgir.

Na Figura 5.20 é apresentada a trajetória obtida pelo sistema proposto no mesmo ambiente da Figura 5.19-c. Este ambiente foi escolhido por ser um exemplo onde a proposta de Oliveira encontrou dificuldades.

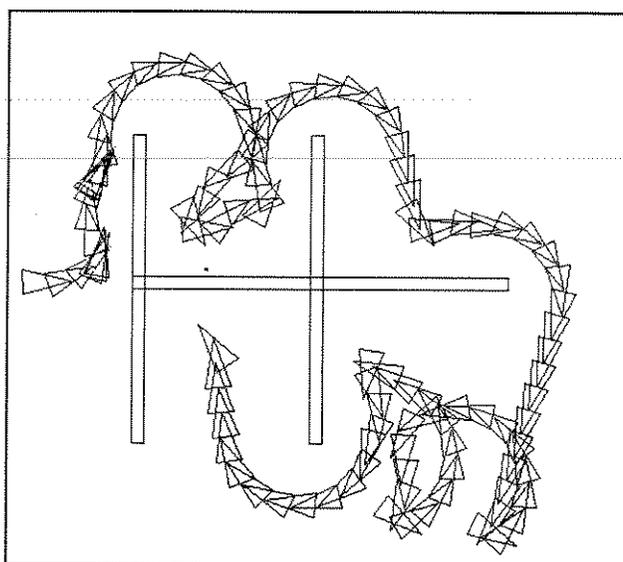


Figura 5.20 - Trajetória do veículo em ambiente similar ao da Figura 5.19-c

O problema encontrado ocorre devido à configuração de obstáculos em forma de U, de onde o veículo não consegue sair. O mesmo problema foi encontrado no sistema aqui proposto, como apresentado na Figura 5.21.

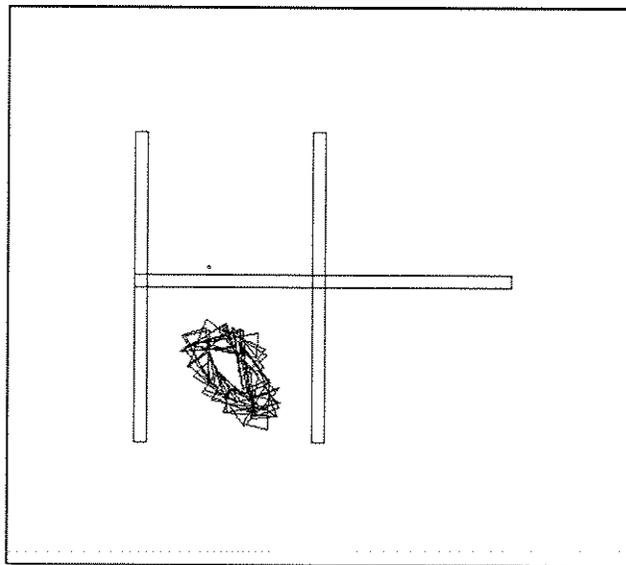


Figura 5.21 - Trajetória do veículo - Configuração dos obstáculos em forma de U - 1

Na Figura 5.22, entretanto, é apresentada uma outra configuração de posicionamento de alvo, no qual o veículo consegue sair da configuração em U dos obstáculos. Isto demonstra a maior generalidade do sistema aqui proposto, quando comparado com a proposta de Oliveira.

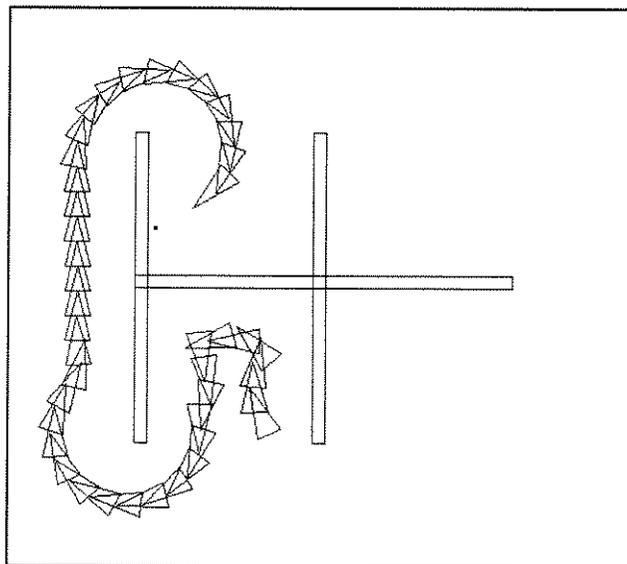


Figura 5.22 - Trajetória do veículo - Configuração dos obstáculos em forma de U - 2

5.6. Análise dos Resultados

As comparações efetuadas neste capítulo demonstram a efetividade do sistema de controle proposto, quando defrontado com situações complexas de interação com diversos ambientes. Em comparações com o sistema original proposto por Verschure, apresenta um maior nível de flexibilidade na navegação, e melhor desempenho quando envolvido com interações complexas com ambientes desconhecidos. O sistema proposto apresenta desempenho comparável também à proposta de Oliveira, com as vantagens de possuir capacidade de adaptação durante a interação com cada ambiente, além de apresentar maior generalidade quando envolvido com difíceis configurações de obstáculos (como os obstáculos em U, nos quais o sistema proposto por Oliveira não consegue navegar com sucesso).

5.7. Resumo

Neste capítulo foram apresentados os resultados computacionais obtidos pelo sistema proposto, bem como os passos realizados para chegar à configuração final do sistema. Foram apresentadas comparações de desempenho em relação ao sistema de Verschure et. al.[Ver92], no qual esta proposta foi baseada. São ainda apresentadas comparações com outro sistema de controle alternativo, proposto por Oliveira[Oli95], que também utiliza técnicas neurais e nebulosas. No capítulo seguinte serão realizadas considerações finais sobre os resultados obtidos neste trabalho, bem como apresentadas propostas de evolução e desenvolvimentos futuros.

6. Conclusões e Perspectivas Futuras

Neste trabalho uma abordagem para o controle autônomo de veículos foi proposta, fundamentando-se na teoria de grupos neurais, na aprendizagem condicionada e na teoria de sistemas nebulosos. A abordagem foi desenvolvida com o objetivo de obter um sistema de controle baseado em sensores, com capacidades de operação autônoma em ambientes desconhecidos, sem necessidade de programação prévia de comportamento, ou treinamento neural específico. As técnicas de sistemas nebulosos introduzidas contribuíram para definir os sensores nebulosos e o controle motor baseado em regras nebulosas, provendo maior flexibilidade principalmente quanto ao desvio de obstáculos. Estas técnicas permitiram também, em conjunto com o seletor/fusor de comportamento introduzido, uma maior eficiência no alcance a alvos posicionados em situações críticas, isto é, muito próximos à obstáculos. Os métodos de aprendizagem utilizados pelos grupos neurais permitem uma adaptação contínua do sistema de controle, garantindo que o veículo desenvolva um comportamento adequado em decorrência das características específicas do ambiente com o qual ele interage.

Em comparação com o sistema apresentado por Verschure et. al.[Ver92] a proposta aqui desenvolvida apresentou resultados superiores, mesmo quando envolvida em complexas interações com o ambiente. A flexibilidade introduzida pelos sensores nebulosos e pelas regras nebulosas de controle motor permite uma navegação eficiente, não incorrendo nas falhas do sistema de Verschure, isto é:

- necessidade de uma quantidade inicial de colisões, enquanto se processa a adaptação e o surgimento do comportamento de desvio de obstáculos;
- incapacidade de generalização durante a interação com o ambiente, levando a constantes colisões em ambientes complexos;
- necessidade de procedimentos de retrocesso (ré), sempre que é ativada uma ação de desvio de obstáculo;
- incapacidade de alcance de alvos posicionados em locais de difícil acesso, como alvos muito próximos a obstáculos ou paredes, por exemplo.

Os sensores nebulosos de colisão introduzidos permitem ao sistema de controle uma detecção eficaz de colisões, antes que as mesmas ocorram, possibilitando ao mecanismo de controle motor a tomada de decisões necessárias de modo a evitá-las. As ações de desvio são implementadas com mecanismos mais flexíveis, utilizando comandos de desvio simples, sem necessidade de retrocesso, permitindo um desvio antecipado de obstáculos, exceto em casos extremos, como quando o veículo se encontra *muito próximo* a algum obstáculo.

As capacidades de adaptação, provenientes da interação entre os grupos neurais, foram mantidas, e as de generalização foram expandidas através do uso dos sensores nebulosos. O seletor de comportamento proporciona maior capacidade de alcance de alvos em situações críticas, permitindo ao sistema de controle alcançar posições de alvos mesmo muito próximas a obstáculos ou aos limites do ambiente.

Uma dificuldade encontrada no desenvolvimento do sistema de controle foi a definição de parâmetros utilizados. Estas definições foram realizadas através de tentativas, problema comum à muitas outras aplicações[Alm92]. O sistema apresentou sensibilidade à mudanças de parâmetros como taxa de aprendizagem(α), e fator de proporcionalidade entre as ativações dos grupos neurais(μ), sendo necessário um processo de seleção destes parâmetros por tentativa para a obtenção de resultados satisfatórios. A introdução das regras nebulosas de controle motor obrigaram também uma definição e posterior refinamento dos conjuntos nebulosos utilizados. A simplicidade da base de regras utilizada, entretanto, permitiu o refinamento destes conjuntos nebulosos sem dificuldades.

Um outro problema, decorrente da necessidade de compatibilizar dois comportamentos conflitantes, alcançar alvos e desviar obstáculos, é a ocorrência de colisões isoladas, durante o processo de interação, principalmente em situações de alvos muito próximos à obstáculos, onde a interação dos dois comportamentos é mais intensa. Mudanças em parâmetros do sistema de controle podem ser efetuadas para anular estas colisões, levando entretanto à uma perda de performance no que diz respeito ao alcance de alvos próximos à obstáculos. Existem estudos mais aprofundados sobre a solução do problema de fusão de comportamentos, como os apresentados por [Pay90] e, mais recentemente, [Yen95].

Com relação à abordagem apresentada por Oliveira[Oli95], podemos observar pelas comparações do capítulo anterior a obtenção de comportamentos semelhantes nos ambientes comparados, concluindo que nossa proposta é capaz de obter sucesso em vários ambientes complexos selecionados, não obtendo sucesso apenas em certas circunstâncias em ambientes com obstáculos do tipo U. Cabe ressaltar as diferentes características dos controladores comparados, pois Oliveira utiliza algoritmos de otimização dos parâmetros de seu controlador neuro-nebuloso (algoritmos genéticos), o que demanda um aprendizado prévio via evolução, não necessário nesta proposta, que apresenta adaptação contínua a cada ambiente com o qual interage.

Um ponto de discussão a ser observado é a definição do número e posição dos sensores utilizados. A informação obtida por estes sensores é de fundamental importância para o desempenho do sistema de controle. Um pequeno número de sensores de alvo apresentou resultados satisfatórios para o sistema de navegação, de modo a definir a direção do alvo a ser alcançado pelo veículo. Entretanto, a quantidade de sensores de colisão e distância à obstáculos tem grande influência no comportamento do sistema de controle. Um número muito pequeno de sensores leva à uma falta de informação sobre as posições dos obstáculos, levando o sistema a colidir em situações extremas (Ex.: colisões com obstáculos pontiagudos). Um aumento do número de sensores leva à uma maior qualidade das informações, constituindo entretanto uma carga de processamento. A definição do número de sensores (e, conseqüentemente, do número de neurônios nos grupos neurais) é de fundamental importância para o desempenho e a capacidade de generalização obtida pelo sistema de controle. A determinação do melhor número de neurônios a serem utilizados em uma determinada aplicação é um problema sobre o qual já houve bastante discussão, com relação às redes neurais mais tradicionais, mas não há estudos definitivos sobre este assunto com relação às aplicações que utilizam grupos neurais.

Quanto à utilização de regras nebulosas para o controle motor do veículo, observa-se que a teoria dos grupos neurais prevê a existência de elementos pré-especificados geneticamente nos seres, por serem de vital importância para a sobrevivência dos mesmos. Deste modo, o controle motor por regras nebulosas veio substituir a rede neural previamente treinada, como observada na proposta de Verschure et.al., na pré-especificação das capacidades de movimentação do veículo. Um outro motivo que levou à utilização de regras

nebulosas é a possibilidade de considerarem informações imprecisas, muito adequada em situações onde há interação com o mundo real.

Como oportunidade de trabalhos futuros, observa-se a implementação da metodologia de controle apresentada em um ambiente real, de modo a poder testar as propriedades de robustez do sistema de controle em situações concretas, e não apenas em simulações. Uma análise mais aprofundada das características de tolerância à imprecisões e falhas dos sensores pode também ser desenvolvida, em conjunto com os testes em ambientes reais. Estes testes não foram realizados por estarem fora do escopo deste trabalho.

Outra proposta é a de incluir no sistema de controle aqui proposto a implementação de uma rede neural nebulosa como a de Oliveira [Oli95]. A inclusão desta rede em lugar das regras de controle nebulosas possibilitaria uma adição quanto às capacidades de aprendizado do sistema, a nível de controle motor. Um estudo mais aprofundado seria necessário para fundir as características de adaptação dos grupos neurais e as características de aprendizado das redes neuro nebulosas. Uma outra possibilidade seria a de estabelecer níveis hierárquicos de controle, introduzindo um nível superior de decisão, responsável pelo planejamento global das trajetórias a serem executadas. Isto poderia ser implementado utilizando um algoritmo de construção de mapas do ambiente a partir de informações dos sensores (*map-building*) [Leo92], em conjunto com um método de cálculo de trajetórias globais. Isto resultaria num sistema de controle híbrido [Pay90] e hierárquico, com uma estratégia de navegação global gerada em um nível, e o desvio de obstáculos que porventura se encontrem no caminho em outro, mais baixo, implementado através do sistema de controle proposto neste trabalho.

7. Referências Bibliográficas

- [Alm92] Almassy, N. and Verschure, P.F.M.J., *Optimizing self-organizing control architectures with genetic algorithms: the interaction between natural selection and ontogenesis*, R. Männer and B. Manderick (editors), Proceedings of the Second Conference on Parallel Problem Solving from Nature, pp. 451-460, Amsterdam, Holland: Elsevier, 1992.
- [Beo92] Beom, H.R. and Cho, H.S., *A sensor based obstacle avoidance controller for a mobile robot using fuzzy logic and neural network*, in Proc. Int. Conf. Intelligent Robots and Systems, Raleigh, NC, July 7-10, pp.1470-1475, 1992.
- [Beo95] Beom, H.R. and Cho, H.S., *A sensor-based navigation for a mobile robot using fuzzy logic and reinforcement learning*, IEEE Trans. Sys. Man Cyber., vol. 25, no. 3, Mar., 1995.
- [Bor89] Borenstein, J. and Koren, Y., *Real-time obstacle avoidance for fast mobile robot*, IEEE Trans. Sys. Man Cyber., vol 19, no. 5, pp. 1179-1187, Sept./Oct., 1989.
- [Bor91] Borenstein, J. and Koren, Y., *Potential field method and their inherent limitations for mobile robot navigation*, in Proc. IEEE Int. Conf. Robotics and Automation, Sacramento, CA., Apr. 9-11, pp. 818-823, 1991.
- [Bro86] Brooks, R.A., *A robust layered control system for a mobile robot*, IEEE Journal Robotics Automat., vol. RA-2, no. 1, pp. 14-23, Mar., 1986.
- [Dar66] Darwin, C., *On the Origin of the Species*, Collie, New York, 1966.
- [Ede87] Edelman, G.M., *Neural Darwinism: The Theory of Neuronal Group Selection*, Basic Books, New York, 1987.
- [Fab95] Fabro, J.A. and F. Gomide, *A SelfOrganizing NeuroFuzzy Control of Autonomous Vehicles*, nos Anais do II Simpósio Brasileiro de Redes Neurais, Out. 18-20, pp. 70-75, São Carlos, SP, Brasil, 1995.
- [Fab96a] Fabro, J.A. and F. Gomide, *A Self-Organizing NeuroFuzzy Control of Complex Systems*, Journal of Applied Mathematics and Computer Science, Special Issue on Computational Intelligence, 1996, a ser publicado.
- [Fab96b] Fabro, J.A. and F. Gomide, *A Self-Organizing NeuroFuzzy Control of Autonomous Vehicles*, Proceedings of the IFAC-World Congress, San Francisco, Jul-30 to Aug-05, 1996, a ser publicado.
- [Fig94] Figueiredo, M, Gomide, F. and Pedrycz, W. *A fuzzy neural network, Structure and learning* In Proceedings of IFSA-94, São Paulo, Brazil, 1994.
- [Fik72] Fikes, R.E., Hart, P.E. and Nilson, N.J., *Learning and executing generalized robot plans*, Artificial Intelligence 3, pp. 251-288, 1972.
- [Fou94] Foulloy, L. and Galichet, S., *Fuzzy sensors for fuzzy control*, Int. J. of Uncertainty, Fuzziness and Knowledge-Based Systems, vol. 2, no. 1, pp. 55-66, 1994.
- [Gho89] Ghosh, J. and Hwang, K., *Mapping neural networks onto message-passing multicomputers*, Journal of Parallel and Distributed Computing, vol. 6, no. 2, pp. 291-330, April 1989.
- [Gom92] Gomide, F. and Rocha, A., *Neurofuzzy components based on threshold*, in Preprints of IFAC Symposium on Intelligent Components and Instruments for Control Applications, pp. 425-430, 1992.
- [Heb49] Hebb, D. O., *The Organization of Behavior*, John Wiley & Sons, New York, 1949.
- [Hes52] Hestenes, M.R., and Stiefel, E., *Methods of conjugate gradients for solving linear systems*, Nat. Bureau Standards J. Res., 49 pp. 409-436, 1952.

- [Hor89] Hornik, K., Stinchcombe, M., and White, H., *Multilayer feed-forward networks are universal approximators*, Neural Networks, 2:359-366, 1989.
- [Hop82] Hopfield, J.J., *Neural networks and physical systems with emergent collective computational abilities*, Proc. National Academy of Sciences, 79, 2554-2558, 1982.
- [Ish91] Ishikawa, S., *A method of indoor mobile robot navigation by fuzzy control*, in Proc. Int. Conf. Intelligent Robots and Systems, Osaka, Japan, Nov. 3-5, pp. 1013-1018, 1991.
- [Kau75] Kaufmann, A., *Introduction to the theory of fuzzy subsets*, Academic Press, New York, 1975.
- [Koh82] Kohonen, T., *Self-organized formation of topologically correct feature maps*, Biological Cybernetics 43, pp. 59-69, 1982
- [Koh84] Kohonen, T., Makisara, M. and Saramaki, T., *Phonotopic maps - insightful representations of phonological for speech recognition*, in Proceedings of the 7th IEEE International Conference on Pattern Recognition, August, 1984.
- [Koz91] Kozakiewicz, C. and Ejiri, M., *Neural network approach to path planning for two dimensional robot motion*, in Proc. Int. Conf. Intelligent Robots and Systems (Osaka, Japan, Nov. 3-5), pp. 818-823, 1991.
- [Lar80] Larsen, P.M., *Industrial applications of fuzzy logic controller*, Int. J. Man. Mach. Studies, vol. 12, no. 1, pp. 3-10, 1980.
- [Lee76] Lee, D.N., *A theory of visual control of braking based on information about time to collision*, Perception 5, pp. 437-459, 1976.
- [Lee90] Lee, C.C., *Fuzzy Logic in control systems: Fuzzy logic controller - Part I and II*, IEEE Trans. Sys. Man. Cyber., vol. 20, no. 2, pp. 404-435, March 1990.
- [Lem84] Lembessis, E., *Dynamic learning behavior of a rule-based self-organizing controller*, Ph. D. Thesis, University of London, 1984.
- [Leo92] Leonard, J.L. Durrant-Whyte, H. F. and Cox, I.J., *Dynamic Map Building for an Autonomous Mobile Robot*, The International Journal of Robotics Research, vol. 11, no. 4, pp. 286-298, August 1992.
- [Loz79] Lozan-Pérez, T., and Wesley, M.A., *An algorithm for planning collision-free paths among the polyhedral obstacles*, Communications of the ACM, vol 22, no. 10, pp. 560-570, October 1979.
- [Mam74] Mamdani, E.H., *Application of fuzzy algorithms for control of simple dynamic plant*, Proc. of the IEE Control and Science, vol. 121, pp. 298-316, 1974.
- [Mo193] Moller, M.F., *A scaled conjugate gradient algorithm for fast supervised learning*, Neural Networks, vol. 6, no. 4, pp. 525-533, 1993.
- [Miz81] Mizumoto, M., *Note on the arithmetic rule by Zadeh for fuzzy conditional inference*, Cyber. Syst., vol 12, pp. 247-306, 1981.
- [MP43] McCulloch, W. S., and Pitts, W., *A Logical calculus of the ideas imminent in nervous activity*, Bulletin of Mathematical Biophysics, vol 5, pp. 115-133, 1943.
- [Oli95] Oliveira, M.A., Figueiredo, M., Gomide, F. and Romero, L., *Neurofuzzy navigation control and neuronal group selection*, in Proc. IFSA-95, São Paulo, 1995.
- [Pav27] Pavlov, I. P., *Conditioned Reflexes*, London: Oxford Univ. Press, 1927.
- [Pay90] Payton, D. W., Roseblat, J. K., and Keirse, D. M., *Plan guided reaction*, IEEE Trans. Sys. Man. Cyber., vol. 20, no. 6, pp.1370-1382, Nov. 1990.
- [Py187] Pylyshyn, Z., *The robots dilemma*, Ablex, Norwood, New Jersey, 1987.
- [Res72] Rescorla, R.A., and Wagner, A.R., *A theory of Pavlovian conditioning: Variations in the effectiveness of reinforcement and nonreinforcement*, in Black and Prokasky Editors, Classical Conditioning 2, Current Theory and Research, ACC, New York, pp. 66-99, 1972.
- [Ros59] Roseblatt, R., *Principles of Neurodynamics*, New York, Spartan Books, 1959.
- [Rum85] Rumelhart, D.E., and Zipster, D., *Feature discovery by competitive learning*, Cognitive Science 9, pp. 75-112, 1985.

- [Rum86] Rumelhart, D.E., and McClelland, J.L., *Parallel Distributed Processing: Explorations of the microstructure of cognition*, vols. 1 and 2, The MIT Press, 1986.
- [Sek90] Sekiguchi, M., Nagata, S. and Asakawa, K., *Mobile robot control by a structured hierarchical neural network*, IEEE Control Systems Mag., vol. 10, no. 3, pp. 69-76, April 1990.
- [Sil90] Silva, F.M. and Almeida, L.B., *Speeding up backpropagation*, in Advanced Neural Computers, R. Eckmiller, ed., North-Holland, pp. 151-160, 1990.
- [Suc87] Suchman, L.A., *Plans and situated actions*, Cambridge Univ. Press, Cambridge, Mass., 1987
- [Ver91] Verschure, P. F. M. J., and Colen, A. C. C., *Adaptive Fields: distributed representations of classically conditioned associations*, Network - Computation in Neural System 2, pp. 189-206, 1991.
- [Ver92] Verschure, P. F. M. J., Pfeifer, R., and Kröse, B. J. A., *Distributed adaptive control: The self-organization of structured behavior*, Robots and Autonom. Agents, n.9, pp. 181-196, 1992.
- [Ver93] Verschure, P. F. M. J., *Formal Minds and Biological Brains- AI and Edelman's Theory of Neuronal Group Selection*, IEEE Expert, pp. 66-75, October 1993.
- [Wid60] Widrow, B. and Hoff, M.E., *Adaptive switching circuits*, 1960 IRE WESCON Conv. Record, Part 4, August 1960.
- [Yen95] Yen, J. and Pfluger, N., *A fuzzy logic based extension to Payton and Roseblatt's command fusion method for mobile robot navigation*, IEEE Trans. Sys. Man. Cyber., vol. 25, no. 6, June 1995.
- [Zad65] Zadeh, L.A., *Fuzzy Sets*, Information and control, vol. 8, no. 3, pp. 338-353, June 1965.
- [Zad88] Zadeh, L.A., *Fuzzy Logic*, Computer, pp. 83-93, April 1988.