

Controlador Multivariável Neuro-Nebuloso para Navegação de um Veículo Autônomo

Giuliani Paulineli Garbi

giulianigarbi@yahoo.com.br

Victor Orlando Gamarra Rosado

victor@feg.unesp.br

Departamento de Engenharia Mecânica da
Faculdade de Engenharia de Guaratinguetá – UNESP

Francisco José Grandinetti

grandi@unitau.br

Departamento de Engenharia Mecânica da
Universidade de Taubaté - UNITAU

RESUMO

A função principal de um veículo autônomo é realizar tarefas pré-determinadas deslocando-se em ambientes desconhecidos. Portanto, o veículo precisa de um sistema de controle para efeitos de planejamento das suas tarefas e outro para garantir sua segurança no deslocamento. Um dos grandes desafios no projeto de veículos autônomos é o desenvolvimento do processo de tomada de decisão, em tempo real, durante seu deslocamento na realização de suas tarefas e evitando potenciais obstáculos.

Este trabalho propõe a implementação de um controlador com a técnica multivariável neuro-nebuloso aplicado em conjunto à navegação de um veículo autônomo. O controlador integra o sistema que determina as tarefas e o que garante o deslocamento do veículo com segurança. Para comprovar o desempenho do controlador proposto no trabalho é realizada uma comparação com um controlador neuro-nebuloso apresentado na literatura.

A verificação do desempenho do controlador multivariável neuro-nebuloso é obtido por meio de simulações em ambientes com obstáculos nos quais o veículo deve realizar seu deslocamento, ambientes estes formados por diferentes configurações. As simulações ocorrem no software Matlab 6.5, comprovando que no caso de sistemas complexos, por exemplo, os veículos autônomos, a arquitetura do controlador proposto é menos complexa e possui tempo de resposta menor do que o controlador neuro-nebuloso.

PALAVRA-CHAVE: Veículos autônomos, controlador multivariável neuro-nebuloso.

Multivariable Neuro-Fuzzy Controller for an Autonomous Vehicle Navigation

ABSTRACT

The main function of autonomous vehicle is to carry tasks pre-determined going itself in unknown environments. Therefore, the vehicle needs a system both to control a task planning and to guarantee a decision taking development, in real time during the displacement, carrying the tasks and avoiding potential obstacles.

This work proposes a multivariable neuro-fuzzy controller implementation for autonomous vehicle navigation. The controller integrates the systems that determine the tasks and guarantee the displacement with security. To prove the purpose controller performance it is made a comparison with presented neuro-fuzzy controller in literature.

The verification of multivariable neuro-fuzzy controller performance is gotten through simulations in different environments with obstacles. The software MatLab 6.5 simulations, proving that in the case of complex systems, for example an autonomous vehicle, the architecture of propose controller is less complex and with better performance in relation to neuro-fuzzy controller.

KEY WORDS: Autonomous vehicle, multivariable neuro-fuzzy controller.

I. INTRODUÇÃO

Os veículos robóticos surgiram devido à crescente necessidade de exploração de ambientes desconhecidos. Esses veículos estão se tornando cada vez mais autônomos e demandam controladores sofisticados para realizar a navegação ou deslocamento em ambientes complexos (Pradhan, Parhi, Panda, 2006). Como principais aplicações, atualmente, citam-se os veículos de exploração espacial, por exemplo, os robôs que se encontram em Marte e os veículos não tripulados usados em missões especiais (Brooks, 1986).

Este trabalho discute com detalhes o desenvolvimento de um controlador com as técnicas do sistema de inferência adaptativo neuro-nebuloso (ANFIS) implementado na estrutura de multivariáveis para a navegação de um veículo autônomo em ambientes complexos. O sistema do controlador é organizado em vários ANFIS, representando a posição física do veículo, a lógica entre os sensores para evitar colisões e o comando de fusão para combinar as saídas dos subsistemas (Tunstel, 1996) e (Rusu et al, 2003).

Para atingir as expectativas de navegação devem-se considerar os problemas associados aos ambientes do mundo real. A dinâmica do ambiente pode ser parcialmente prevista através do conhecimento aproximado do ambiente e também pela utilização de sensores. Essas informações são processadas por um agente representado pelo controlador (Selekwa, Dunlap, Collins, 2005).

O controlador possui uma arquitetura hierárquica que decompõe o problema do controle da navegação em alguns subsistemas, os quais podem ser controlador independentemente e em paralelo, assim diminuindo o efeito negativo de possuir extensa base de regras que prejudicam o desempenho em tempo real do sistema.

Os subsistemas e seus controladores possuem comportamento reativo (Saffiotti, Konolige, Ruspini, 1995). O conceito de comportamento reativo é caracterizado pela forma especial de descentralização do controle, em que é utilizado um comando de fusão para combinar as saídas dos subsistemas. Esse conceito também é conhecido como estrutura de univalores ou univariáveis amplamente utilizado em veículos autônomos. Entretanto, essa estrutura tende a causar indecisões em ambientes complexos.

A lógica de multivalores ou multivariáveis utilizada com os conceitos da lógica nebulosa ou difusa é uma boa ferramenta de desenvolvimento de controladores para navegação de veículos autônomos em ambientes complexos, pois a capacidade de representação de valores lógicos (verdadeiro ou falso) em uma escala graduada através da combinação dos operadores lógicos.

As redes neurais artificiais são usadas para resolver o problema de aprendizagem do comportamento reativo. A aprendizagem permite ao veículo autônomo adquirir conhecimento pela interação com os ambientes e, conseqüentemente, adaptar seu comportamento, assim resolvendo o problema de conhecimento insuficiente no desenvolvimento da base de regras para o controlador (Arkin, 1998) e (Jang, 1993).

II. VEÍCULO ROBÓTICO AUTÔNOMO

Para implementar o controlador proposto no trabalho é necessário determinar o tipo e a estrutura de um veículo robótico autônomo. Tem-se um veículo na forma retangular com um *drive* diferencial acoplado em duas rodas controladas independentemente. O sistema de controle de navegação requer sensores para verificar a presença de obstáculos e sensores de localização. Os sensores de proximidade são responsáveis por medir a distância em que se encontram os obstáculos, são 7 sensores de infravermelho colocados em torno do veículo, conforme ilustrado na Figura 1. O principal objetivo da navegação é atingir um alvo ou uma localização, o presente veículo é equipado com GPS (Global Positioning System) que verifica a direção do veículo relacionando a posição inicial e a atual (plano X e Y).

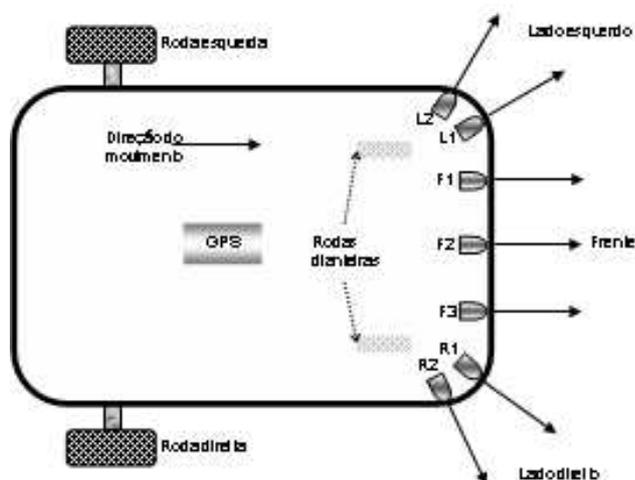


Figura 1 – Posição dos sensores do veículo autônomo.

III. SISTEMA DE CONTROLE MULTIVARIÁVEIS NEURO-NEBULOSO

Esta sessão descreve o desenvolvimento do sistema de inferência adaptativo neuro-nebuloso (ANFIS). A arquitetura multivariável é um sistema de controle formado por subsistemas que retornam preferências graduadas para o comando de fusão, formando assim uma saída única do controlador. A ação do controlador é obter a velocidade para o veículo. Na prática são dois sistemas de controle, um para cada motor independente, pois, o sistema de inferência adaptativo neuro-nebuloso utiliza o sistema de inferência da lógica nebulosa de Takagi/Sugeno que permite apenas uma saída. A organização hierárquica dos subsistemas aplicados na ação de controle do veículo autônomo é ilustrada na Figura 2.

O sistema de controle é formado por quatro subsistemas ANFIS: Colisão dianteira; Colisão lado direito; Direção do movimento, e um multivariável ANFIS com a finalidade de realizar o comando de fusão para obter a velocidade para o veículo durante a navegação, desviando dos obstáculos e procurando seu objetivo ou alvo.

O sistema de inferência adaptativo neuro-nebuloso é uma rede de trabalho com estrutura similar às redes neurais artificiais, o qual é formado por mapas com funções de entrada, saídas e parâmetros de associação, os parâmetros são utilizados para interpretar os mapas dos dados de entrada e saída, possibilitando o processo de aprendizagem.

A computação desses parâmetros é facilitada pela utilização de um vetor gradiente, o qual determina como deve trabalhar o sistema de inferência nebuloso, modelando os dados de entrada e saída. O conjunto de regras do sistema de inferência de cada subsistema é obtido por um processo de validação. Para o treinamento da rede, inicialmente é utilizado um vetor gradiente com as dados do mapa de entrada e saída. Uma vez gerados os parâmetros pelos métodos de validação, rotinas de otimizações são aplicadas para ajustar os parâmetros através dos métodos de *backpropagation* e *least square estimation*.

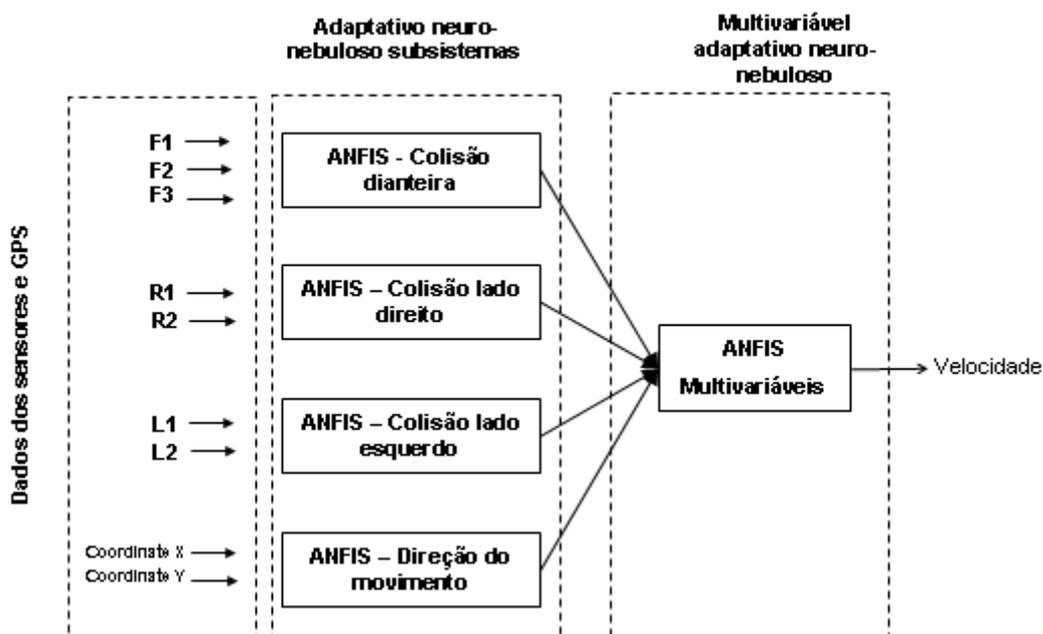


Figura 2 – Arquitetura do controlador multivariáveis neuro-nebuloso para o veículo autônomo.

O conjunto de funções nebulosas referentes à velocidade possui três grupos: Stop Speed (SS), Medium Speed (MS) e High Speed (HS). Para representar o conjunto de funções nebulosas para a velocidade é utilizada a forma de onda do tipo Gaussiana, dentre os tipos de onda testados, esse tipo é o mais simples e não compromete o desempenho do controlador, onde $\mu \in (0, 1)$. O conjunto é ilustrado na Figura 3.

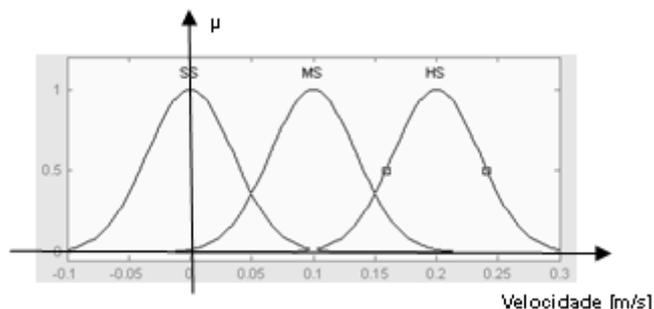


Figura 3 – Representação do conjunto de funções nebulosas para a velocidade do veículo.

3.1 ANFIS COLISÃO DIANTEIRA

Para representar o desenvolvimento dos subsistemas ANFIS do controlador, é apresentada de controle para a velocidade do motor direito porque a estrutura, o conjunto de funções, as regras nebulosas, o conjunto de dados de treinamento (vetor gradiente) e a checagem dos parâmetros de treinamento são similares para o controle de velocidade do motor esquerdo.

O ANFIS colisão dianteira possui estrutura com três entradas, os sensores F1; F2; F3, e uma saída representada pela velocidade graduada do motor direito. A estrutura é ilustrada na Figura 4.

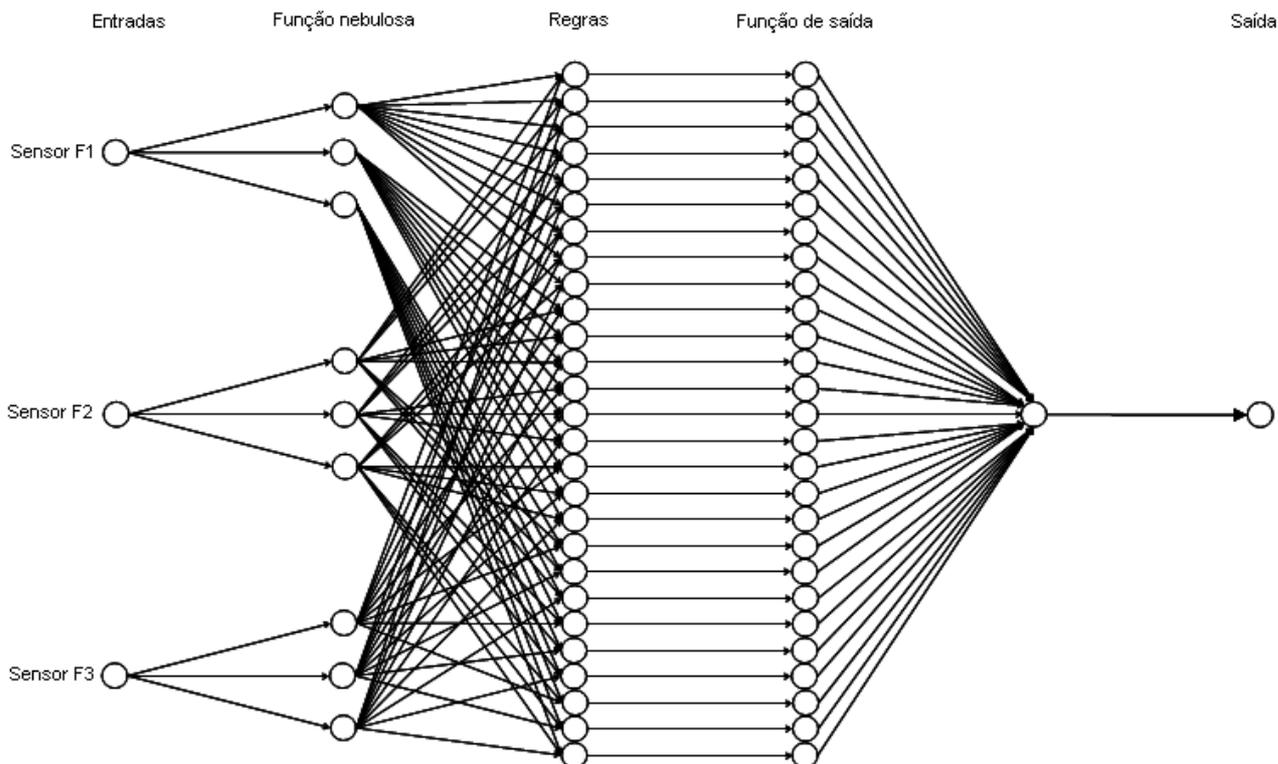


Figura 4 – Estrutura ANFIS colisão dianteira para velocidade do motor direito.

O conjunto de dados para o treinamento do ANFIS colisão dianteira é formado por um vetor gradiente com 47 pontos de dados com quatro informações: distância dos sensores F1; F2; F3 e a velocidade do motor direito. Na realidade são dois vetores, sendo um vetor treinamento de como o sistema deve operar e outro vetor checagem com valores variando de 5% do primeiro vetor.

Para gerar os parâmetros de associação e assim obter o conjunto de regras utilizadas no mecanismo de inferência, é feito o treinamento da rede utilizando os dois vetores por meio de 50 combinações entre os métodos *backpropagation* e *least square estimation*. O resultado do erro do treinamento é ilustrado na Figura 5.

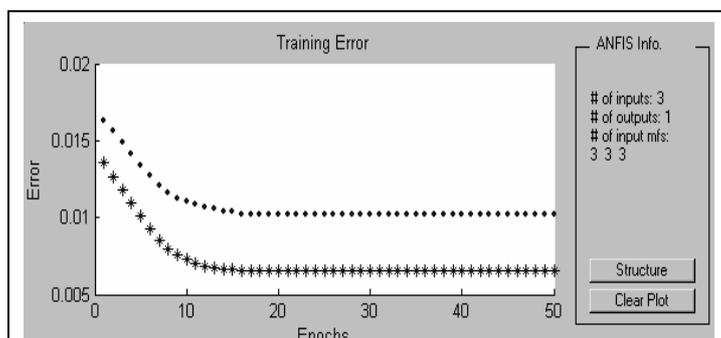


Figura 5 – Erro do treinamento do ANFIS colisão dianteira para velocidade do motor direito.

3.2 ANFIS COLISÃO LADO DIREITO E ESQUERDO

O ANFIS colisão lado direito e esquerdo possui a mesma estrutura, sendo duas entradas: R1; R2, L1; L2, e uma saída representada pela velocidade graduada do motor direito. A estrutura é ilustrada na Figura 6.

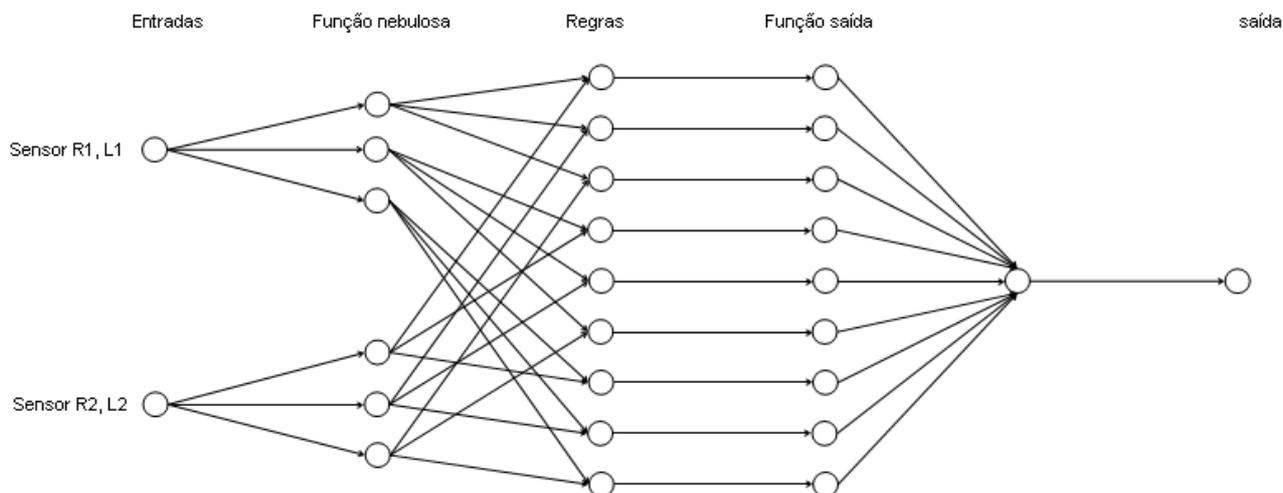


Figura 6 – Estrutura ANFIS colisão lado direito e esquerdo para velocidade do motor direito.

O conjunto de dados para o treinamento do ANFIS colisão lado direito é formado por um vetor gradiente com 26 pontos de dados com três informações: distância dos sensores R1; R2 e a velocidade do motor direito. Na realidade são dois vetores, sendo um vetor treinamento de como o sistema deve operar e outro vetor checagem com valores variando de 5% do primeiro vetor.

Para gerar os parâmetros de associação e assim obter o conjunto de regras utilizadas no mecanismo de inferência, é feito o treinamento da rede, utilizando-se os dois vetores por meio de 50 combinações entre os métodos *backpropagation* e *least square estimation*. O resultado do erro do treinamento é ilustrado na Figura 7.

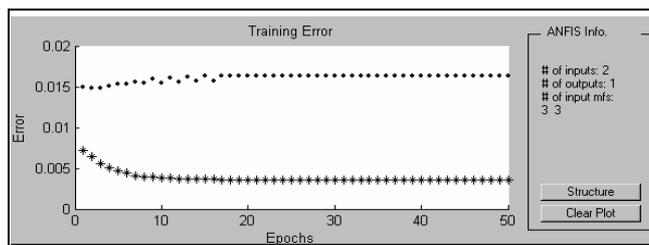


Figura 7 – Erro do treinamento do ANFIS colisão lado direito para velocidade do motor direito.

3.3 ANFIS DIREÇÃO DO MOVIMENTO

O ANFIS direção do movimento possui uma estrutura com duas entradas: as coordenadas X (abscissa) e Y (ordenada), e uma saída representada pela velocidade graduada do motor direito. A estrutura é ilustrada na Figura 8.

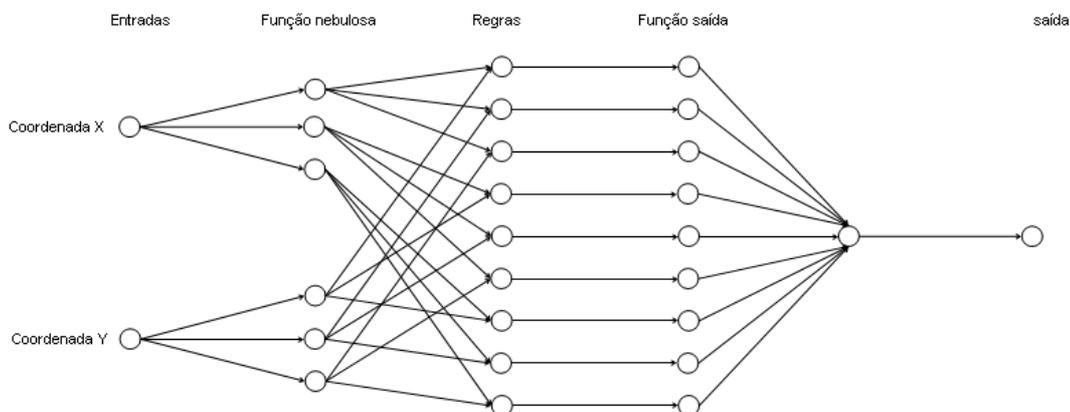


Figura 8 – Estrutura ANFIS direção do movimento para velocidade do motor direito.

O conjunto de dados para o treinamento do ANFIS direção do movimento é formado por um vetor gradiente com 47 pontos de dados com três informações: coordenadas X e Y e a velocidade do motor direito. Na realidade são dois vetores, sendo um vetor treinamento de como o sistema deve operar e outro vetor checagem com valores variando de 5% do primeiro vetor.

Para gerar os parâmetros de associação e assim obter o conjunto de regras utilizadas no mecanismo de inferência, é feito o treinamento da rede utilizando-se os dois vetores por meio de 50 combinações entre os métodos *backpropagation* e *least square estimation*. O resultado do erro do treinamento é ilustrado na Figura 9.

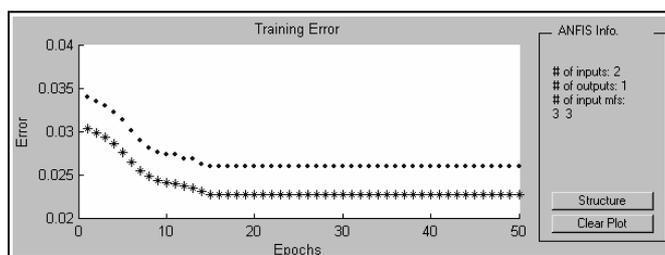


Figura 9 – Erro do treinamento do ANFIS direção do movimento para velocidade do motor direito.

3.4 ANFIS MULTIVARIÁVEIS

O ANFIS multivariáveis determina a velocidade do veículo durante a navegação ou deslocamento, desviando-se dos obstáculos e buscando seu objetivo. Possui uma estrutura com quatro entradas: as saídas dos ANFIS colisão dianteira, colisão lado direito, colisão lado esquerdo e direção do movimento, e como saída a velocidade do veículo autônomo.

A forma geral para obter o conjunto de regras para quatro entradas e uma saída por Takagi/Sugeno é:

$$\begin{aligned}
 & \text{IF } x \text{ is } A_a \text{ AND } y \text{ is } B_b \text{ AND } z \text{ is } C_c \text{ AND } w \text{ is } D_d \\
 & \text{THEN} \\
 & F_L = p_L x + q_L y + r_L z + s_L w + t_L; \\
 & \text{for } a=1, \dots, F; b=1, \dots, G; c=1, \dots, H; d=1, \dots, I; \\
 & L=1, \dots, R; R = F \times G \times H \times I
 \end{aligned} \tag{1}$$

Em que x, y, z e w são as variáveis, F_L é a saída para L -ésima regra, F, G, H e I são o tamanho do conjunto de função nebulosa A, B, C e D e R é o tamanho da base de regras. Para o ANFIS multivariáveis, tem-se $R = 81$ como o número do conjunto de regras. A estrutura é ilustrada na Figura 10.

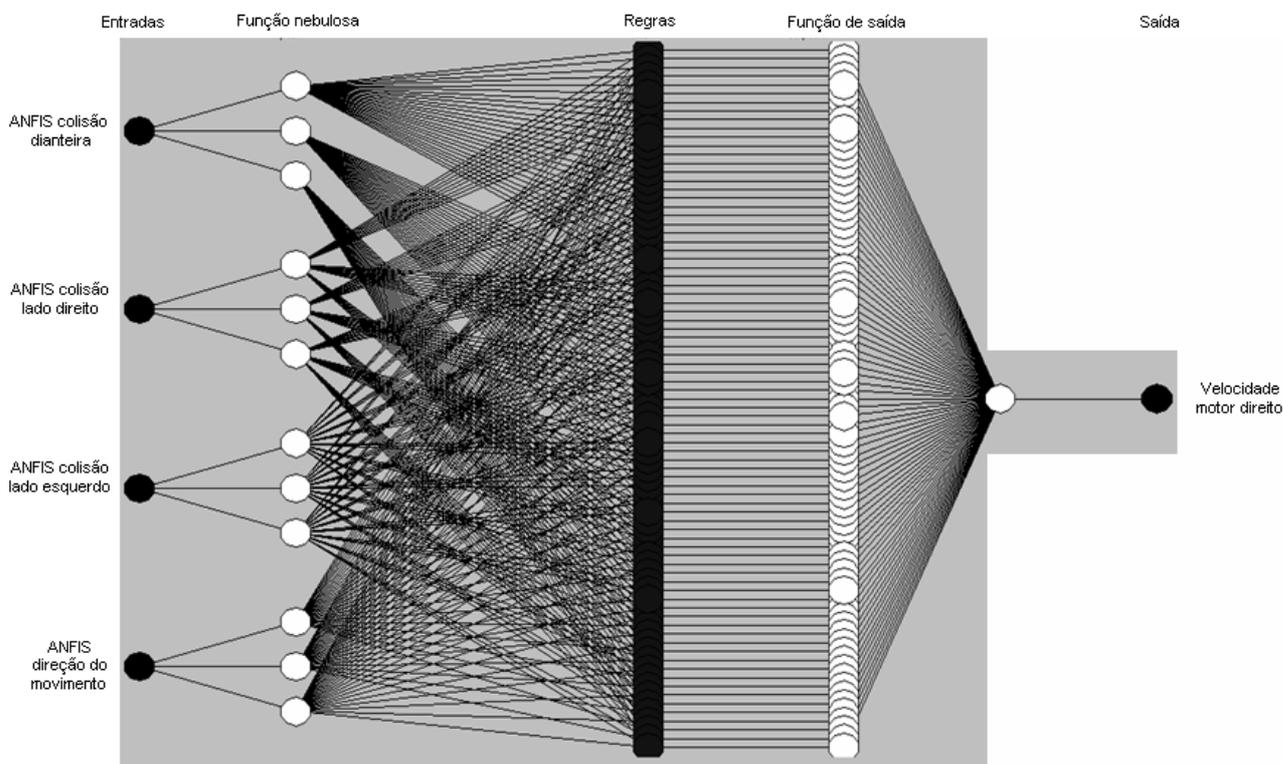


Figura 10 – Estrutura ANFIS multivariáveis para velocidade do motor direito.

O conjunto de funções nebulosas para as entradas relacionadas à velocidade do motor direito é representado pela Figura 11, sendo *Stop Speed* (SS), *Medium Speed* (MS) e *High Speed* (HS). Em que *toward behavior*, *side right behavior*, *side left behavior* e *heading direction behavior* são, respectivamente, os subsistemas ANFIS colisão dianteira, ANFIS colisão lado direito, ANFIS colisão lado esquerdo e ANFIS direção do movimento.

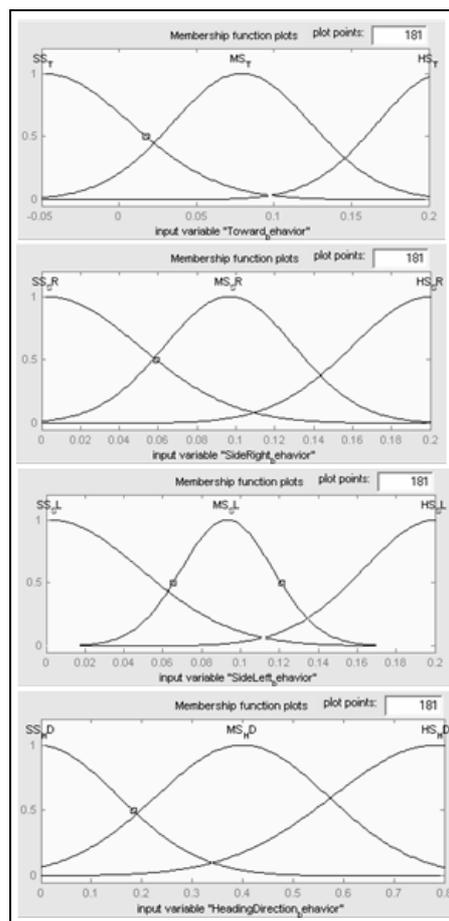


Figura 11 – Estrutura ANFIS multivariáveis para velocidade do motor direito.

O conjunto de dados para o treinamento do ANFIS multivariáveis é formado por um vetor gradiente com 112 pontos de dados com cinco informações: ANFIS colisão dianteira, colisão lado direito, colisão lado esquerdo, direção do movimento e a velocidade do motor direito. Na realidade são dois vetores, sendo um vetor treinamento de como o sistema deve operar e outro vetor checagem com valores variando de 5% do primeiro vetor.

Para gerar os parâmetros de associação e assim obter o conjunto de regras utilizadas no mecanismo de inferência, é feito o treinamento da rede utilizando os dois vetores por meio de 50 combinações entre os métodos *backpropagation* e *least square estimation*. O resultado do erro do treinamento é ilustrado na Figura 12.

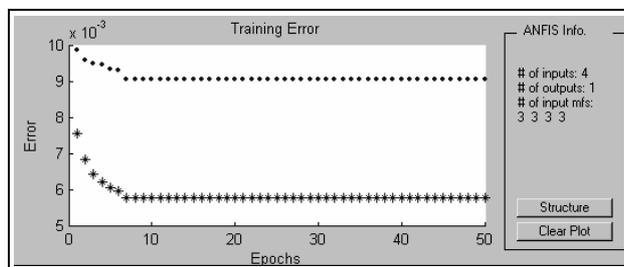


Figura 12 – Erro do treinamento do ANFIS multivariáveis para velocidade do motor direito.

IV. COMPARAÇÃO ENTRE O CONTROLADOR PROPOSTO E O NEURO-NEBULOSO

Para o controlador multivariável neuro-nebuloso proposto neste trabalho, o mecanismo de inferência e o conjunto de regras são divididos entre os subsistemas: ANFIS colisão dianteira com 27 regras, colisão lado direito com 9 regras, colisão esquerdo com 9 regras, direção do movimento com 9 regras e o multivariável com 81 regras. Com isso melhora-se o tempo de processamento à tomada de decisão do controlador. Também se ressalta que o conjunto de regras é obtido pelo processo de treinamento pelo vetor gradiente.

Para o controlador apenas neuro-nebuloso o mecanismo de inferência e o conjunto de regras são centralizados no próprio controlador. Com isso, o controlador possui um conjunto com 19683 regras, assim aumentando o tempo de processamento do controlador e prejudicando o desempenho do sistema. A Figura 13 ilustra a arquitetura para o controlador neuro-nebuloso e a Figura 14 ilustra a complexidade do sistema de inferência para este tipo de controle.

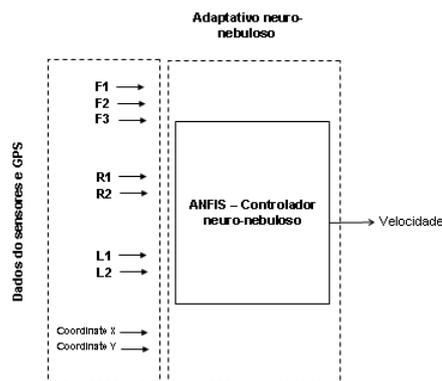


Figura 13 – Arquitetura do controlador neuro-nebuloso.

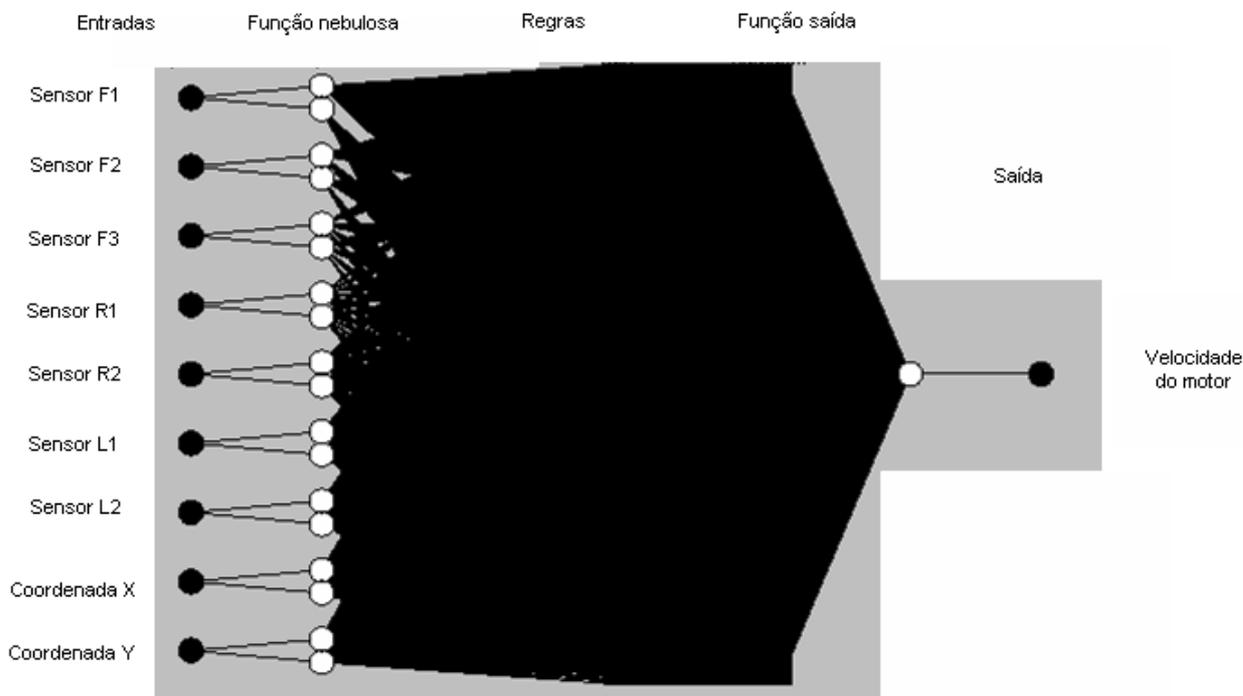


Figura 14 – Estrutura ANFIS para o controlador apenas neuro-nebuloso.

V. IMPLEMENTAÇÃO DO CONTROLADOR MULTIVARIÁVEL NEURO-NEBULOSO

Esta sessão apresenta a simulação e o desempenho do controlador proposto por meio do *software* Matlab 6.5, a simulação é realizada em três diferentes cenários. A Figura 15 ilustra o sistema do controlador. Em que *avoidance collision toward behavior*, *avoidance collision side right behavior*, *avoidance collision side left behavior* e *heading direction behavior*, *multi-valued behavior to right speed motor*, *multi-valued behavior to left speed motor*, *right motor speed* e *left motor speed* são respectivamente os subsistemas ANFIS colisão dianteira, colisão lado direito, colisão lado esquerdo, direção do movimento, multivariável para motor direito, multivariável para o motor esquerdo, velocidade do motor direito e velocidade do motor esquerdo.

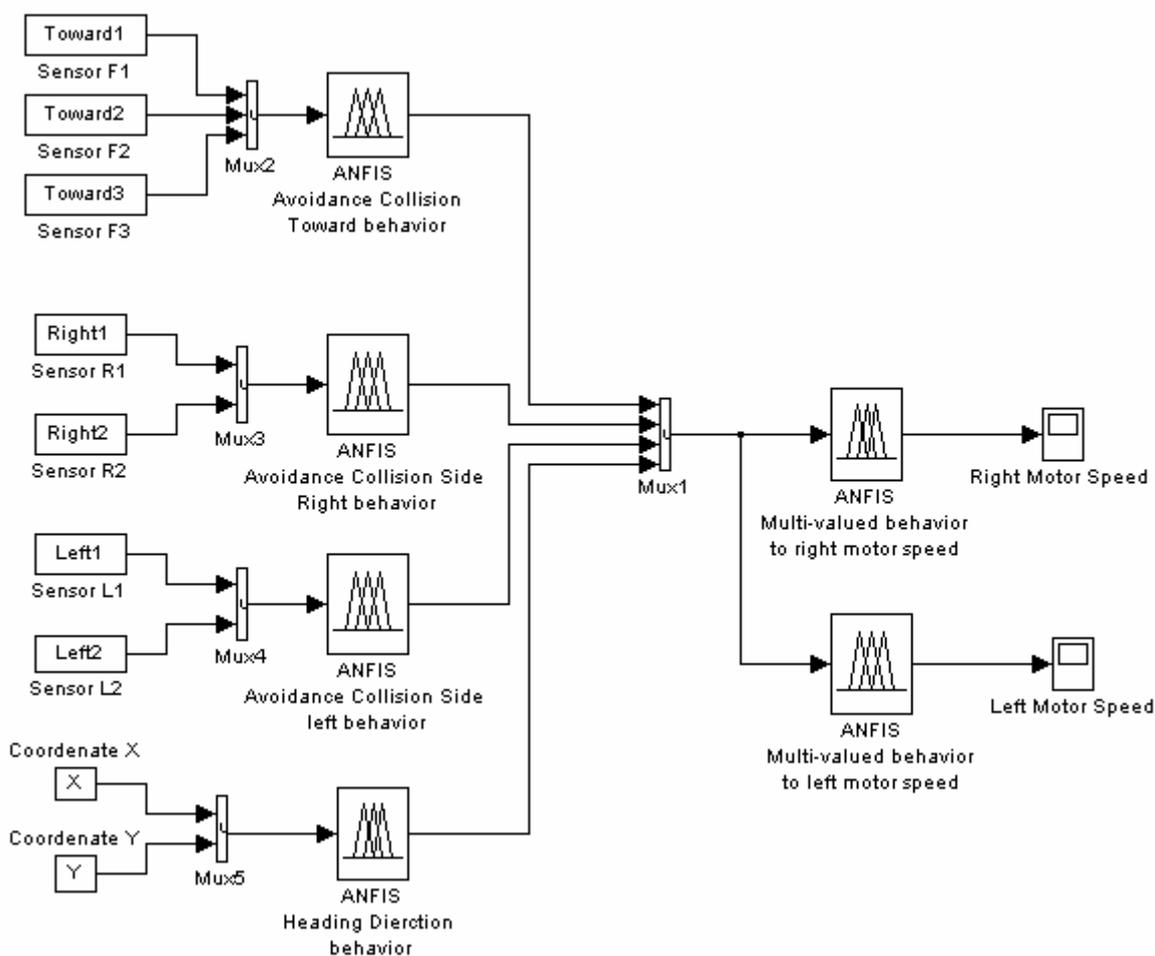


Figura 15 – Sistema para o controlador proposto.

5.1 CENÁRIO 1

Com alguns obstáculos entre a posição inicial do veículo autônomo, coordenadas (0, 0) e a posição desejada, coordenadas (4.7 e 3.5). O veículo se desloca em direção à posição desejada desviando e contornando os obstáculos. A Figura 16 ilustra o cenário 1 e a Figura 17 ilustra o desempenho de cada motor independentemente. Em que *right motor speed* e *left motor speed* são respectivamente velocidade do motor direito e velocidade do motor esquerdo.

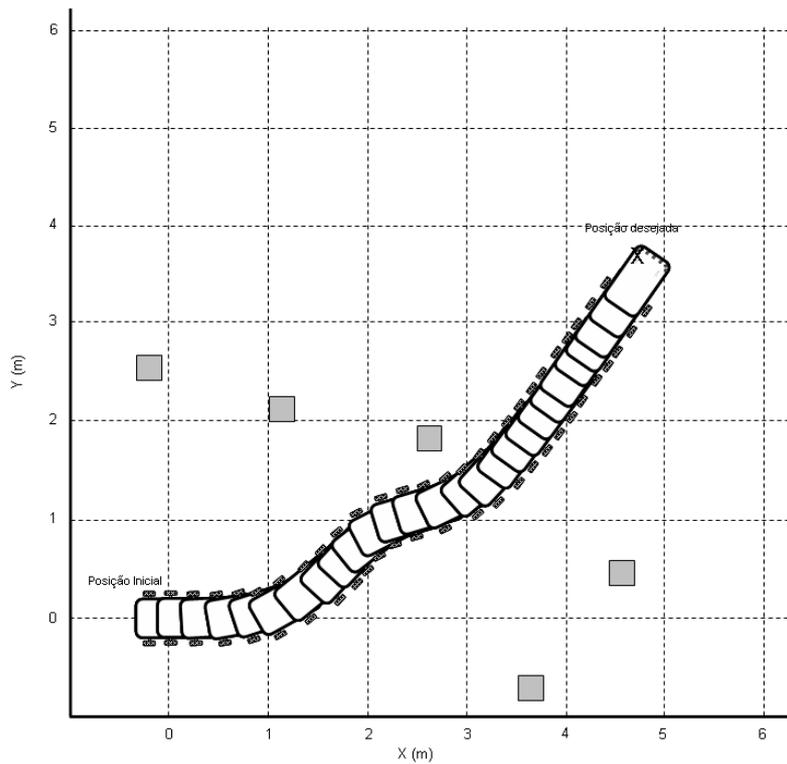


Figura 16 – Cenário 1.

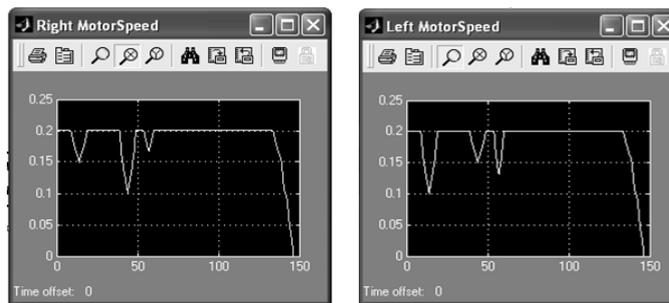


Figura 17 – Velocidade dos motores para o cenário 1.

5.2 CENÁRIO 2

Com muitos obstáculos entre a posição inicial do veículo autônomo, coordenadas (0, 0) e a posição desejada, coordenadas (4.1 e 5.1). O veículo se desloca em direção a posição desejada, desviando e contornando os obstáculos. A Figura 18 ilustra o cenário 2 e a Figura 19 ilustra o desempenho de cada motor independentemente. Em que *right motor speed* e *left motor speed* são, respectivamente, velocidade do motor direito e velocidade do motor esquerdo.

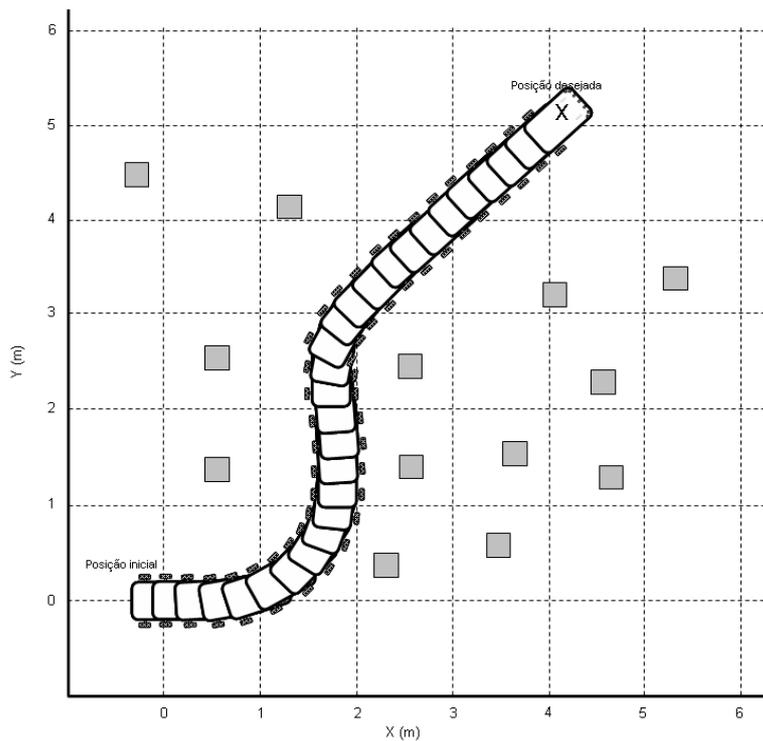


Figura 18 – Cenário 2.

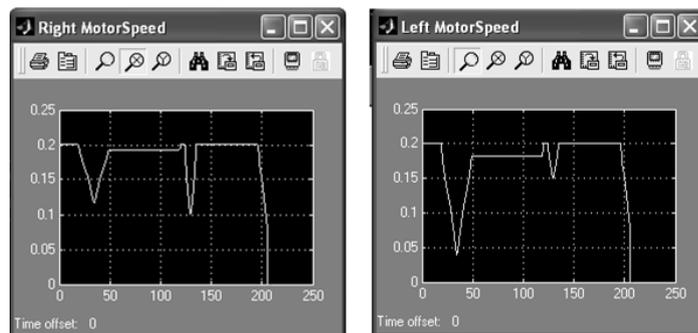


Figura 19 – Velocidade dos motores para o cenário 2.

5.3 CENÁRIO 3

Representando um ambiente complexo, esta situação demonstra a habilidade de navegação do controlador proposto em deslocar-se entre a posição inicial do veículo autônomo, coordenadas (0, 0), e a posição desejada, coordenadas (1.3 e 4.3). O veículo se desloca em direção à posição desejada, desviando e contornando os obstáculos. A Figura 20 ilustra o cenário 3 e a Figura 21 ilustra o desempenho de cada motor independentemente. Em que *right motor speed* e *left motor speed* são, respectivamente, velocidade do motor direito e velocidade do motor esquerdo.

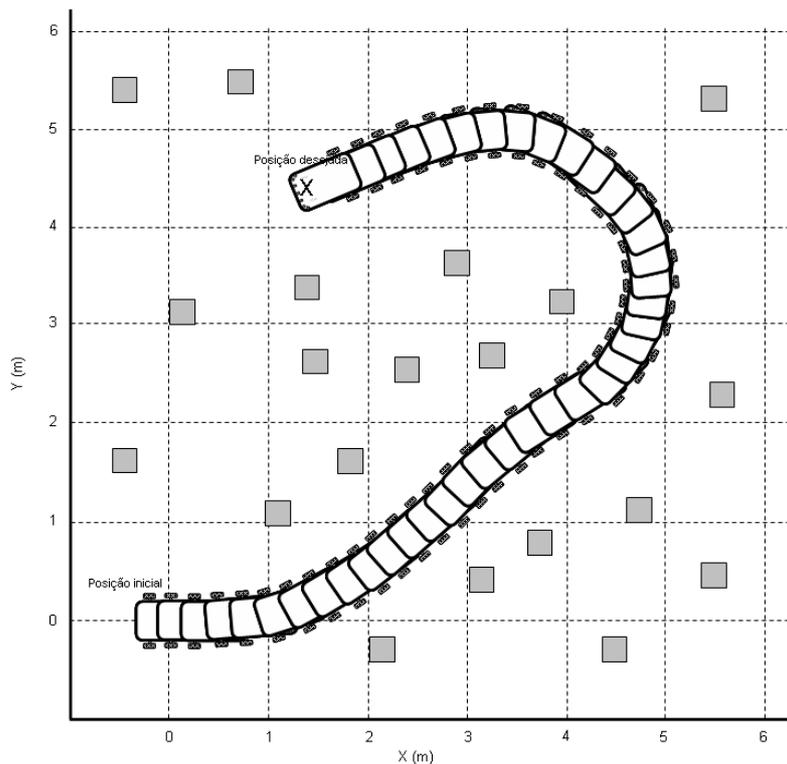


Figura 20 – Cenário 3.

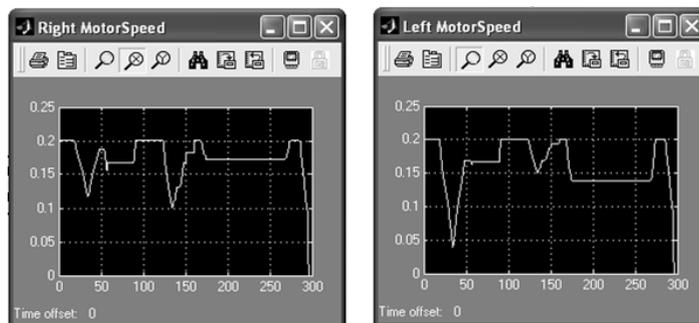


Figura 21 – Velocidade dos motores para o cenário 3.

VI. CONCLUSÃO

A simulação do sistema de controle comprova a habilidade do veículo em deslocar-se até uma posição desejada desviando de obstáculos em ambientes complexos. O sucesso deve ser atribuído à arquitetura hierárquica do controlador multivariável neuro-nebuloso, em que a aprendizagem permite que o controlador adquira conhecimento pela interação com os ambientes e, conseqüentemente, adaptando seu comportamento e resolvendo o problema de insuficiência de conhecimento para o desenvolvimento do conjunto de regras para o sistema de inferência, assim o desempenho do sistema não é prejudicado por extensos tempos de processamento no processo de tomada de decisão do controlador.

VII. REFERÊNCIAS

SELEKWA, M. F., DUNLAP, D. D., COLLINS, E. G., Implementation of multi-valued fuzzy behavior control for robot navigation in cluttered. *In Proceedings of IEEE International Conference on Robotics and Automation*, Barcelona, Spain, pp. 3699–3706, April, 2005.

RUSU, P., PETRIU, E. M., WHALEN, T. E., CORNELL A., SPOELDER H. J. W., Behavior-based neuro-fuzzy controller for mobile robot navigation. *IEEE Trans. Instrum. Measur.*, vol. 52, no. 4, pp. 1335–1340, Aug, 2003.

A. SAFFIOTTI, K. KONOLIGE and H. RUSPINI, A multivalued logic approach to integrating planning and control. *Artificial Intelligence*, vol. 76, pp. 481–526, 1995.

ARKIN R. C., *Behavior-Based Robotics*, Cambridge Massachusetts: MIT Press, 1998.

FIGUEIREDO, M., GOMILE, F., Design of fuzzy system using neuro-fuzzy net-works. *IEEE Trans. Neural Networks*, vol. 10, pp. 815–827, Aug, 1999.

JANG, J. S. R., ANFIS; Adaptive-network-based fuzzy inference system. *IEEE Trans. Syst., Man., Cybern.*, vol. 23, pp. 665–685, June, 1993.

BROOKS, R., A robust layered control system for mobile robot. *IEEE J. Robot. Automat.* vol. 2, pp. 14–23, Feb, 1986.

TUNSTEL, E. W., Mobile robot autonomy via hierarchical fuzzy behavior control. *In Proceedings of the 6th International Symposium on Robotics and Manufacturing*, Montpellier, France, pp. 837–842, May, 1996.

SELEKWA, M. F., COLLINS, E. G., A centralized fuzzy behavior control for robot navigation. *In Proceedings of IEEE International Symposium on Intelligent control*, Houston, Texas, pp. 602–607, October, 2003.

S. K. PRADHAN, D. R. PARHI and A. K. PANDA, Navigation of multiple mobile robots using rule-based-neuro-fuzzy technique. *In Proceedings of International Journal of Computational Intelligence*, vol. 3, no. 2, pp. 142–151, 2006.