

# Rede Neural Auto-Regressiva Com Entradas Exógenas (NARX) Aplicada ao Controle de Velocidade em Veículos Elétricos

Carlos E. R. B. Fonseca\*, Náthalee C. Almeida<sup>†</sup> e Marcelo A. C. Fernandes<sup>‡</sup>

<sup>\*‡</sup>Departamento de Engenharia da Computação e Automação (DCA)  
Universidade Federal do Rio Grande do Norte (UFRN)  
Natal, Brasil

\*cadubentzen@bct.ect.ufrn.br, ‡mfernandes@dca.ufrn.br

<sup>†</sup>Universidade Federal Rural do Semi-Árido (UFERSA)  
Pau dos Ferros, Brasil

<sup>†</sup>nathalee.almeida@ufersa.edu.br

**Resumo**—Este artigo propõe uma estratégia de controle de velocidade para veículos equipados com motores elétricos de corrente contínua e ímã permanente (PMDC - *Permanent Magnet DC*). Esta estratégia tem como base um controlador não-linear auto-regressivo com entradas exógenas (NARX - *Nonlinear Autoregressive Exogenous*) baseado em Redes Neurais Artificiais (RNA) do Tipo Perceptron de Múltiplas Camadas (MLP - *Multilayer Perceptron*) treinado com algoritmo da retropropagação (BP - *Backpropagation*). O controlador neural atua de forma direta no PMDC, tendo como entrada o erro entre a velocidade atual e a velocidade de referência do veículo, estados passados da saída e finalmente o ângulo de inclinação longitudinal do veículo. Resultados obtidos, a partir de simulações para várias situações de percurso, são apresentados e mostram a eficiência do controlador proposto.

**Palavras-chave**—Controlador Neural, Redes Neurais Artificiais, NARX, Veículos Elétricos.

**Abstract**—This article proposes a velocity control strategy for vehicles equipped with electric motors Permanent Magnet DC (PMDC). This strategy is based on a Nonlinear Autoregressive Exogenous controller (NARX) based on Artificial Neural Networks (ANN) Type Multilayer Perceptron trained with the Backpropagation algorithm. The neural controller works directly in the PMDC and has as input the error between the actual speed and the reference speed of the vehicle, past states of output and finally the pitch angle of the vehicle. All electric vehicle modeling and its controller is displayed. Results obtained with simulations for various situations route are presented and show the effectiveness of the proposed controller.

**Keywords**—Neural Controller, Artificial Neural Networks, NARX, Electric Vehicles.

## I. INTRODUÇÃO

O controle de velocidade de veículos em percurso longitudinal é um tema bastante pesquisado no qual várias técnicas foram propostas nos últimos anos. Pode-se dizer que é uma das bases para o desenvolvimento de veículos autônomos e os chamados carros inteligentes [1]. Dentre as várias técnicas propostas na literatura podem-se destacar as baseadas em inteligência artificial (IA) que utilizam redes neurais artificiais (RNA), sistemas fuzzy e algoritmos genéticos [2], [3], [4],

[5]. Estas técnicas proporcionam um ganho de performance ao sistema de controle quando comparadas as técnicas tradicionais principalmente nos casos em que modelo longitudinal do veículo considera os efeitos não lineares do atrito aerodinâmico e do atrito de rolamento [6], [7].

Técnicas baseadas em IA são amplamente utilizadas no controle de velocidade de veículos a combustão, elétricos e híbridos como apresentado nos trabalhos [8], [9]. Em Veículos Elétricos (VE) as propostas se concentram na utilização de sistemas Fuzzy como os trabalhos apresentados em [10], [11], [12], [13], [4]. No caso de RNA's, estratégias baseadas no modelo não-linear auto-regressivo com entradas exógenas (NARX - *Nonlinear Autoregressive Exogenous*) são também bastante utilizadas. Neste último caso, trabalhos recentes mostram suas vantagens em relação as técnicas não-auto-regressivas [6].

Assim, este trabalho possui como objetivo apresentar uma nova estratégia de controlador NARX baseado em Redes Neurais Artificiais (RNA) para o controle de velocidade em VE. Diferentemente das propostas apresentadas na literatura, esta proposta consegue utilizar uma rede MLP com uma dimensão reduzida e com o desempenho semelhante a outras propostas apresentadas na literatura devido a inserção da variável de perturbação (inclinação longitudinal) como entrada do controlador neural. Outro ponto importante associado ao trabalho é sua modelagem que faz simulação em um modelo completo do motor PMDC acoplado ao veículo trazendo mais realidade ao modelo teórico, diferentemente dos trabalhos propostos em [8], [9]. Resultados de simulação são apresentados e mostram a eficiência da técnica proposta em vários cenários de percurso.

## II. MODELAGEM DO SISTEMA

A Figura 1 apresenta a arquitetura do sistema associado ao VE modelado, no qual um motor PMDC traciona um veículo elétrico. O motor PMDC, que gera como saída um sinal de torque  $\tau_m(t)$  e uma rotação  $\omega_m(t)$ , é acionado por uma tensão  $v_a(t)$  cujo valor é controlado por acelerador externo. Além do torque,  $\tau_m(t)$ , e uma rotação,  $\omega_m(t)$ , o VE modelado recebe como um sinal de perturbação,  $\theta(t)$ , que representa ângulos de subida e descida de um dado percurso longitudinal. Existe uma redução de 2 vezes entre o motor PMDC e o VE. Os detalhes

relativos a modelagem do PMDC e do veículo elétrico estão apresentados nas sub-seções seguintes.

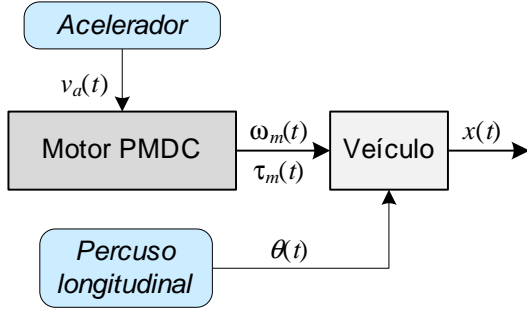


Figura 1. Arquitetura geral do sistema associado ao VE modelado e simulado.

### A. Motor DC

A dinâmica do motor PMDC, ilustrado na Figura 2, é modelada por uma equação que representa a parte elétrica e outra que caracteriza a parte mecânica. A equação diferencial que modela a parte elétrica é dada pela expressão

$$v_a(t) = R_a i_a(t) + L_a \frac{di_a(t)}{dt} + v_i(t), \quad (1)$$

onde  $v_a(t)$ ,  $i_a(t)$ ,  $R_a$  e  $L_a$  são a tensão em volts (V), a corrente em amperes (A), a resistência em  $\Omega$  e a indutância em henry (H) na armadura do motor PMDC, respectivamente, e  $v_i(t)$  é a tensão induzida no terminal do rotor em volts (V). Já a parte mecânica é modelada pela expressão

$$J_m \frac{d\omega_m(t)}{dt} = \tau_m(t) - B_m \omega_m(t) - \tau_c(t), \quad (2)$$

onde  $J_m$  é o momento de inércia do rotor (em Kg.m<sup>2</sup>),  $B_m$  é a constante de viscosidade (em N.m.s),  $\omega_m(t)$  é a rotação do motor (em rad/s),  $\tau_m(t)$  é o torque gerado pelo motor (também chamado de torque magnético) (em N.m) e, finalmente,  $\tau_c(t)$  é o torque necessário para girar a carga (em N.m).




Figura 2. Modelo eletro-mecânico do motor PMDC.

Para motores do tipo PMDC, o torque magnético,  $\tau_m(t)$ , é diretamente proporcional a corrente na armadura,  $i_a(t)$ , ou seja,

$$\tau_m(t) = K_\tau i_a(t), \quad (3)$$

e que a rotação do motor,  $\omega_m(t)$ , é diretamente proporcional a tensão induzida,  $v_i(t)$ , como é expresso por

$$v_i(t) = K_\omega \omega_m(t) \quad (4)$$

onde  $K_\tau$  é a constante de torque (em N.m/A) e  $K_\omega$  é a constante de velocidade (em V/rad/s) do motor PMDC. A tensão máxima suportada pelo PMDC é chamada de  $v_a^{max}$ .

### B. Veículo

O modelo longitudinal do veículo, apresentado na Figura 3, pode ser caracterizado pela expressão

$$M \frac{dx(t)}{dt} = f_t(t) - f_a(t), \quad (5)$$

onde  $M$  é a massa do veículo em Kg,  $x(t)$  é a velocidade linear do veículo em m/s,  $f_t(t)$  é a força de tração do veículo em Newton (N) e  $f_a(t)$  é a força gerada pelos atritos também em N.




Figura 3. Modelo longitudinal de um veículo.

Segundo [14], a força de atrito,  $f_a(t)$ , pode ser expressa como

$$f_a(t) = f_d(t) + f_r(t) + f_g(t) \sin(\theta(t)), \quad (6)$$

onde  $f_d(t)$  é a força de atrito aerodinâmico (em N),  $f_r(t)$  é a força de resistência ao rolamento (em N),  $f_g(t)$  é a força gravitacional (em N) e  $\theta(t)$  é o ângulo de inclinação do plano em que se encontra o veículo.

O atrito aerodinâmico pode ser representado por

$$f_d(t) = \text{sign}(x) \left( \frac{1}{2} \rho C_d A_{fr} x^2(t) \right), \quad (7)$$

onde  $\text{sign}(\cdot)$  é a função sinal,  $\rho$  é a densidade do ar,  $C_d$  é o coeficiente do atrito aerodinâmico e  $A_{fr}$  é a área frontal do veículo (em m<sup>2</sup>). A força de resistência ao rolamento pode ser expressa como

$$f_r(t) = \text{sign}(x) (MgC_0 + MgC_1 x^2(t)), \quad (8)$$

onde  $C_0$  e  $C_1$  são os coeficientes de rolamento e  $g$  é a aceleração da gravidade (m/s<sup>2</sup>). Finalmente, a força gravitacional é dada por

$$f_g(t) = Mg. \quad (9)$$

## III. PERCEPTRON DE MÚLTIPLAS CAMADAS

O perceptron de múltiplas camadas, treinado com o algoritmo *Backpropagation* (BP), é uma técnica amplamente utilizada em aplicações baseadas em redes neurais artificiais, devido à sua habilidade em trabalhar com problemas não-lineares [15]. Na Figura 4 é apresentada uma rede do tipo MLP com três camadas, com  $P$  neurônios na camada de entrada,  $K$  neurônios na camada escondida e  $H$  neurônios na camada de saída.

O  $i$ -ésimo neurônio da camada escondida processa o sinal de acordo com a equação

$$z_i(n) = \varphi \left( \sum_{j=0}^{P-1} w_{ij}^{(1)}(n) u_j(n) \right), \quad (10)$$

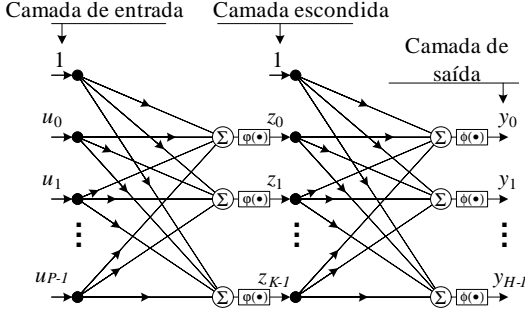


Figura 4. Estrutura de uma RNA do tipo MLP com três camadas.

onde  $z_i(n)$  ( $i = 0, 1, \dots, K-1$ ) é o sinal de saída do  $i$ -ésimo neurônio,  $u_j(n)$  ( $j = 0, 1, \dots, P-1$ ) é o  $j$ -ésimo sinal de entrada,  $w_{ij}^{(1)}$  são os pesos associados com as conexões entre a entrada  $u_j(n)$  e a saída  $z_i(n)$  e, finalmente,  $\varphi(\cdot)$  é a função de ativação da camada escondida. A saída do  $h$ -ésimo neurônio da camada de saída é dada por

$$y_h(n) = \phi \left( \sum_{i=0}^{K-1} w_{hi}^{(2)}(n) z_i(n) \right), \quad (11)$$

onde  $y_h(n)$  ( $h = 0, 1, \dots, H-1$ ) é o sinal de saída do  $h$ -ésimo neurônio,  $w_{hi}^{(2)}$  são os pesos associados com as conexões entre a saída da camada escondida  $z_i(n)$  e a saída da camada de saída  $y_h(n)$  e  $\phi(\cdot)$  é a função de ativação da camada de saída.

As principais funções utilizadas na rede MLP são a sigmóide, que possui sua saída limitada entre 0 e 1, e tangente hiperbólica, que é limitada entre  $-1$  e  $1$ . O algoritmo BP para uma RNA com duas camadas escondidas (ver Figura 4) pode ser expresso por

$$w_{hi}^{(2)}(n+1) = w_{hi}^{(2)}(n) + \eta \delta_h^{(2)}(n) z_i(n) + \alpha w_{hi}^{(2)}(n-1) \quad (12)$$

onde

$$\delta_h^{(2)}(n) = \dot{\phi}(y_h(n)) e_h(n) \quad (13)$$

e

$$w_{ij}^{(1)}(n+1) = w_{ij}^{(1)}(n) + \eta \delta_i^{(1)}(n) u_j(n) + \alpha w_{ij}^{(1)}(n-1) \quad (14)$$

onde

$$\delta_i^{(1)}(n) = \dot{\varphi}(z_i(n)) \sum_{h=0}^{H-1} w_{hi}^{(1)}(n) \delta_h^{(1)}(n) \quad (15)$$

no qual,  $\dot{\phi}(\cdot)$  e  $\dot{\varphi}(\cdot)$  são as derivadas das funções de ativação da camada de saída e da camada escondida, respectivamente,  $\eta$  é o passo de treinamento,  $\alpha$  é o momento e  $e_h(n)$  é o erro do  $h$ -ésimo neurônio de saída que é expresso por

$$e_h(n) = \hat{y}_h(n) - y_h(n) \quad (16)$$

onde  $\hat{y}_h(n)$  é o valor de referência (informação de treinamento) do  $h$ -ésimo neurônio de saída no  $n$ -ésimo instante de tempo.

#### IV. ESTRATÉGIA DE CONTROLE

A Figura 5 detalha, em diagrama de blocos, a estratégia de controle associada a planta na qual, através de uma RNA do tipo MLP-BP, a tensão na armadura do motor elétrico,  $v_a(t)$ , é ajustada em tempo real para que a velocidade do VE,  $x(t)$ , siga uma velocidade de referência predefinida,  $x_r(t)$ . O controlador neural proposto, utiliza uma estratégia direta cujas entradas, do sistema são caracterizadas pelo erro,  $e(n)$ , amostras atrasadas da saída,  $v_a(n-1)$  e  $v_a(n-2)$ , e uma estimativa da inclinação do veículo,  $\beta(n)$ , medida por um sensor de inclinação. Os sinais de entrada do controlador são discretizados a uma taxa de  $t_s$  segundos e o sinal de saída,  $v_a(n)$ , aciona um driver gerando o sinal  $v_a(t)$ . O controlador neural proposto é treinado em tempo real a cada  $n$ -ésima amostra e utiliza uma função de ativação linear na saída e uma função de ativação do tipo sigmóide na camada escondida.

Diante das considerações feitas, as Equações 10 e 11 podem ser reescritas de forma a caracterizarem o sinal de saída do controlador neural,  $v_a(n)$ , como

$$v_a(n) = w_0^{(2)}(n) + \sum_{i=1}^{K-1} w_i^{(2)}(n) z_i(n) \quad (17)$$

onde

$$z_i(n) = \varphi \left( w_{i,0}^{(1)}(n) + \sum_{j=1}^D w_{ij}^{(1)}(n) v_a(n-j) + e(n) w_{i,D+1}^{(1)}(n) + \beta(n) w_{i,D+2}^{(1)}(n) \right) \quad (18)$$

no qual,  $\varphi(\cdot)$  representa a função sigmóide e  $D$  representa o número de sinais recorrentes associados a saída  $v_a(n)$ . Para o controlador proposto neste artigo tem-se  $K = 4$  e  $D = 2$ . Assim, com base na Figura 4 a MLP utilizada no controlador possui  $P = 4$  neurônios na camada de entrada,  $K = 4$  neurônios na camada escondida e  $H = 1$  neurônio na camada de saída.

Para a etapa de treinamento, foi utilizado o algoritmo BP treinado de forma iterativa (em tempo real) a cada  $n$  éxima amostra do sinal de referência. Com base na Equação 16, o sinal de erro é expresso por

$$e(n) = x_r(n) - x(n). \quad (19)$$

Este sinal também é utilizado para o cálculo do gradiente da camada de saída da RNA de acordo com a Equação 13.

#### V. SIMULAÇÕES E RESULTADOS

Com o objetivo de validar a proposta, foram feitas simulações utilizando um modelo desenvolvido do sistema motor PMDC e veículo (de acordo com as equações apresentadas na seção II) no ambiente Matlab/Simulink. Os valores associados aos parâmetros do motor PMDC e do veículo estão apresentados na tabela I [16].

Utilizando os parâmetros apresentados na Tabela I, foram simuladas três situações de percurso ( $SP_1$ ,  $SP_2$  e  $SP_3$ ) cujos resultados estão apresentados nas Figuras 6, 7 e 9. Em  $SP_1$  o VE desloca-se em um percurso com inclinação constante

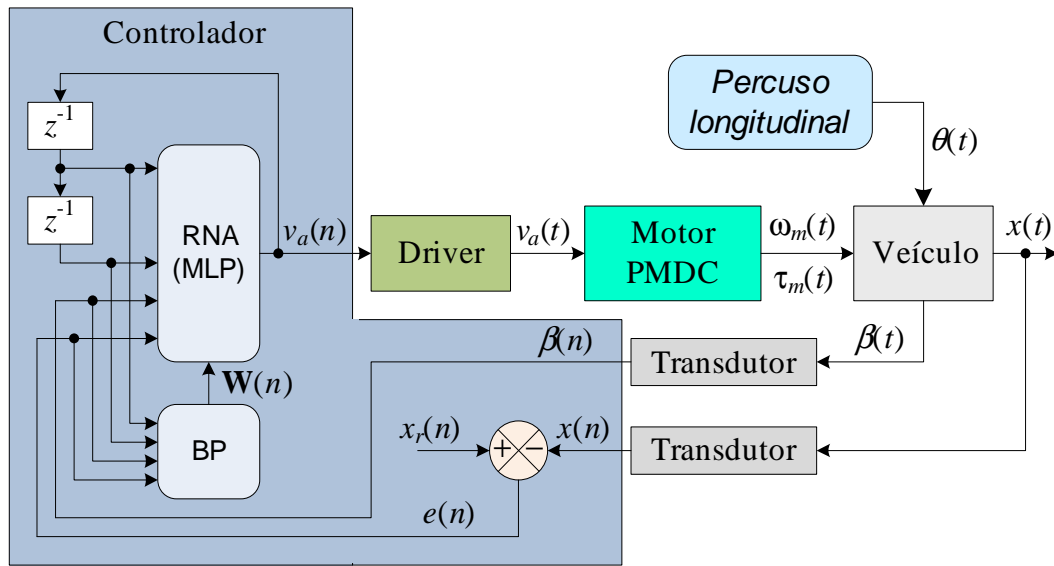


Figura 5. Diagrama de blocos ilustrando a estratégia de controle utilizada.

Tabela I. PARÂMETROS DO VEÍCULO E DO MOTOR PMDC UTILIZADOS NAS SIMULAÇÕES.

Motor PMDC		Veículo	
$R_a$	0,1 $\Omega$	$M$	1500 Kg
$L_a$	0,01 H	$\rho$	1,18
$B_m$	0,08 $\frac{N \cdot m}{rad/s^2}$	$C_d$	0,51
$J_m$	0,7 $Kg \cdot m^2$	$A_{fr}$	2,4 $m^2$
$K_t$	1,06 $\frac{N \cdot m}{A}$	$C_0$	0,015
$V_a^{max}$	220 V	$C_1$	0
		$g$	9,81 $m^2/s$

( $\theta(t) = 5$  graus) durante 600 segundos, no qual a alimentação do PMDC (a aceleração do veículo) varia de acordo com a curva apresentada na Figura 6. Já em  $SP_2$ , (ver Figura 7) o veículo mantém a velocidade de referência,  $x_r(t)$ , fixa em 50 km/h durante 600 segundos porém a inclinação do percurso,  $\theta(t)$ , varia de acordo com o perfil apresentado na Figura 8. A situação  $SP_3$  faz uma combinação dos percursos  $SP_1$  e  $SP_2$  e seus resultados estão apresentados na Figura 9. A Tabela II apresenta os parâmetros de treinamento  $\eta$  e  $\alpha$  (ver Equações 12 e 14) da MLP em cada uma das três situações de percurso.

Tabela II. PARÂMETROS DE TREINAMENTO DA MLP UTILIZADOS NAS SIMULAÇÕES.

Situação de percurso	$\eta$	$\alpha$
$SP_1$	0,005	0,00001
$SP_2$	0,002	0,00001
$SP_3$	0,005	0,00001

Com base nos resultados associados a  $SP_1$  verifica-se que a velocidade do VE,  $x(t)$ , acompanhou muito bem a referência,  $x_r(t)$ , (Figura 6), durante todo o percurso (erro médio menor que 1% entre  $x_r(t)$  e  $x(t)$ ). A Figura 7 também ilustra a velocidade do VE para o caso da  $SP_2$ . Os resultados para esta situação mostram uma maior variação, em relação aos valores de referência ( $x_r(t) = 50$  km/h), quando comparados com as simulações na  $SP_1$ . Todavia, é importante destacar que as variações foram rápidas com um tempo de 20 segundos para o pior caso. Finalmente, para  $SP_3$ , os resultados (ver

Figura 9) ficaram dentro do esperado no qual, observa-se que o controlador neural consegue seguir de forma eficiente o sinal referência  $x_r(t)$ .

## VI. CONCLUSÕES

Este trabalho apresentou uma estratégia de controle, baseada em redes neurais, para o controle de velocidade em veículos elétricos associados a motores PMDC. Este projeto desenvolveu um controlador neural com base em um controlador não-linear auto-regressivo com entradas exógenas (NARX - *Nonlinear Autoregressive Exogenous*). O controlador proposto atua de forma direta no PMDC, tendo como entrada o erro entre a velocidade atual e a velocidade de referência do veículo, estados passados da saída e finalmente o ângulo de inclinação longitudinal do veículo. Diferentemente das propostas apresentadas na literatura, esta proposta consegue utilizar uma rede MLP com uma dimensão reduzida ( $P = 4$  neurônios na camada de entrada,  $K = 4$  neurônios na camada escondida e  $H = 1$  neurônio na camada de saída) e com o desempenho semelhante a outras propostas apresentadas na literatura devido a inserção da variável de perturbação (inclinação longitudinal) como entrada do controlador neural. Os resultados levam a acreditar que o sistema de controle proposto funciona de forma satisfatória, sendo assim bastante promissor para aplicações práticas.

## REFERÊNCIAS

- [1] H. CHEN, X. GONG, Y.-F. HU, Q.-F. LIU, B.-Z. GAO, and H.-Y. GUO, "Automotive control: the state of the art and perspective," *Acta Automatica Sinica*, vol. 39, no. 4, pp. 322 – 346, 2013.
- [2] S. Aryza, A. N. Abdalla, Z. Khalidin, and Z. Lubis, "Adaptive speed estimation of induction motor based on neural network inverse control," *Procedia Engineering*, vol. 15, no. 0, pp. 4188 – 4193, 2011, {CEIS} 2011.
- [3] J. Cao, B. Cao, W. Chen, P. Xu, and X. Wu, "Neural network control of electric vehicle based on position-sensorless brushless dc motor," in *Robotics and Biomimetics, 2007. ROBIO 2007. IEEE International Conference on*, Dec 2007, pp. 1900–1905.




Figura 6. Resultados associados a situação de percurso  $SP_1$ . VE desloca-se em um percurso sem inclinação ( $\theta(t) = 0$ ) durante 600 segundos.




Figura 7. Resultados associados a situação de percurso  $SP_2$ . VE com  $x_r(t)$ , fixa em 50 km/h durante 600 s e  $\theta(t)$  variando em acordo com a Figura 8.




Figura 8. Variação do  $\theta(t)$  associado ao percurso  $SP_2$ .




Figura 9. Resultados associados a situação de percurso  $SP_3$ . Combinação dos percursos  $SP_1$  e  $SP_2$ .

- [4] R. Abdullah, A. Hussain, K. Warwick, and A. Zayed, "Autonomous intelligent cruise control using a novel multiple-controller framework incorporating fuzzy-logic-based switching and tuning," *Neurocomputing*, vol. 71, no. 13-15, pp. 2727 – 2741, 2008, artificial Neural Networks (ICANN 2006) Engineering of Intelligent Systems (ICEIS 2006).
- [5] E. Onieva, J. Godoy, J. Villagra, V. Milanes, and J. Perez, "On-line learning of a fuzzy controller for a precise vehicle cruise control system," *Expert Systems with Applications*, vol. 40, no. 4, pp. 1046 – 1053, 2013.
- [6] A. Haddoun, M. Benbouzid, D. Diallo, R. Abdessemed, J. Ghouili, and K. Srairi, "Modeling, analysis, and neural network control of an ev electrical differential," *Industrial Electronics, IEEE Transactions on*, vol. 55, no. 6, pp. 2286–2294, June 2008.
- [7] K. E. Majdoub, F. Giri, H. Ouadi, L. Dugard, and F. Chaoui, "Vehicle longitudinal motion modeling for nonlinear control," *Control Engineering Practice*, vol. 20, no. 1, pp. 69 – 81, 2012, special Section: IFAC Conference on Analysis and Design of Hybrid Systems (ADHS'09) in Zaragoza, Spain, 16th-18th September, 2009.
- [8] B. Singh, P. Jain, A. Mittal, and J. Gupta, "Neural network based dtc im drive for electric vehicle propulsion system," in *Electric and Hybrid Vehicles, 2006. ICEHV '06. IEEE Conference on*, Dec 2006, pp. 1–6.
- [9] W. Dazhi, Y. Jie, Y. Qing, W. Dongsheng, and J. Hui, "Estimation and control of hybrid electric vehicle using artificial neural networks," in *Industrial Electronics and Applications, 2007. ICIEA 2007. 2nd IEEE Conference on*, May 2007, pp. 35–40.
- [10] F. Syed, M. Kuang, J. Czubay, M. Smith, and H. Ying, "Fuzzy control to improve high-voltage battery power and engine speed control in a hybrid electric vehicle," in *Fuzzy Information Processing Society, 2005. NAFIPS 2005. Annual Meeting of the North American*, June 2005, pp. 343 – 348.
- [11] F. Syed, M. Kuang, M. Smith, S. Okubo, and H. Ying, "Fuzzy gain-scheduling proportional-integral control for improving engine power and speed behavior in a hybrid electric vehicle," *Vehicular Technology, IEEE Transactions on*, vol. 58, no. 1, pp. 69–84, Jan 2009.
- [12] I. Souza-De-Assis, R. Oliveira, and M. Fernandes, "Speed fuzzy control applied to autonomous electric vehicles," *WSEAS Transactions on Systems and Control*, vol. 9, no. 67, pp. 640–651, 2014.
- [13] M. Fernandes, "Simulation model and road tests comparative results of a small urban electric vehicle," in *III CBSF - Third Brazilian Congress on Fuzzy Systems*, 2014, pp. 836–841.
- [14] H. B. Pacejka, *Tire and Vehicle Dynamics*. Oxford: Society of Automotive Engineers and Butterworth-Heinemann, 2002.
- [15] S. Haykin, *Neural Networks: A Comprehensive Foundation (2nd Edition)*, 2nd ed. Prentice Hall, Jul. 1998.
- [16] J. Trovao, P. Pereirinha, and H. Jorge, "Simulation model and road tests comparative results of a small urban electric vehicle," in *Industrial Electronics, 2009. IECON '09. 35th Annual Conference of IEEE*, 2009, pp. 836–841.