

FERNANDO BARROS RODRIGUES

**USO DE REDES NEURAIS COM ADAPTAÇÃO DE PESOS
POR MODOS DESLIZANTES PARA CONTROLE DE
SISTEMAS E APLICAÇÕES EM MÁQUINAS ELÉTRICAS**

Ilha Solteira
2015



FERNANDO BARROS RODRIGUES

**USO DE REDES NEURAIS COM ADAPTAÇÃO DE PESOS
POR MODOS DESLIZANTES PARA CONTROLE DE
SISTEMAS E APLICAÇÕES EM MÁQUINAS ELÉTRICAS**

Tese apresentada à Faculdade de Engenharia do Câmpus de Ilha Solteira - UNESP como parte dos requisitos para obtenção do título de Doutor em Engenharia Elétrica. Área de Conhecimento: Automação.

Prof. Dr. José Paulo Fernandes Garcia
Orientador

Ilha Solteira
2015

FICHA CATALOGRÁFICA

Elaborada pela Seção Técnica de Aquisição e Tratamento da Informação
Serviço Técnico de Biblioteca e Documentação da UNESP - Ilha Solteira.

R131u Rodrigues, Fernando Barros.
 Uso de redes neurais com adaptação de pesos por modos deslizantes para controle de sistemas e aplicações em máquinas elétricas / Fernando Barros Rodrigues. - Ilha Solteira: [s.n.], 2015
 190 f. : il.

 Tese (doutorado) - Universidade Estadual Paulista. Faculdade de Engenharia de Ilha Solteira. Área de Conhecimento: Elétrica, 2015

 Orientador: José Paulo Fernandes Garcia

 Inclui bibliografia

 1. Rede neural artificial. 2. Rastreamento de sinais. 3. Incertezas casadas e não casadas. 4. Estrutura variável e modos deslizantes. 5. Variações paramétricas. 6. Perturbações externas.



UNIVERSIDADE ESTADUAL PAULISTA
CAMPUS DE ILHA SOLTEIRA
FACULDADE DE ENGENHARIA DE ILHA SOLTEIRA



CERTIFICADO DE APROVAÇÃO

TÍTULO: Uso de redes neurais com adaptação de pesos por modos deslizantes para controle de sistemas e aplicações em máquinas elétricas

AUTOR: FERNANDO BARROS RODRIGUES

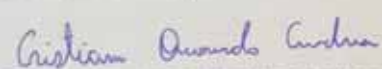
ORIENTADOR: Prof. Dr. JOSE PAULO FERNANDES GARCIA

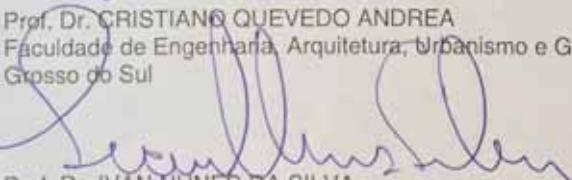
Aprovado como parte das exigências para obtenção do Título de DOUTOR EM ENGENHARIA ELÉTRICA, Área: AUTOMAÇÃO, pela Comissão Examinadora:


Prof. Dr. JOSE PAULO FERNANDES GARCIA
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira


Prof. Dr. MARCELO CARVALHO M TEIXEIRA
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira


Prof. Dr. FALCÕES JOSE MENDES DE SEIXAS
Departamento de Engenharia Elétrica / Faculdade de Engenharia de Ilha Solteira


Prof. Dr. CRISTIANO QUEVEDO ANDREA
Faculdade de Engenharia, Arquitetura, Urbanismo e Geografia / Universidade Federal de Mato Grosso do Sul


Prof. Dr. IVAN NUNES DA SILVA
Departamento de Engenharia Elétrica / Escola de Engenharia de São Carlos-Usp

Data da realização: 29 de janeiro de 2015.

À mulher
Que pelo amor
Concedeu-me a vida.
Com a dor,
Concedeu-me a luz.
À minha mãe...
Elisabeth.

AGRADECIMENTOS

Agradeço primeiramente a Deus, por me conceder sabedoria e oportunidade de realizar este trabalho, fortalecendo-me nos momentos de incertezas e dificuldades.

Ao meu orientador Prof. Dr. José Paulo Fernandes Garcia e à Prof^a. Dra. Lizete Maria Crnkowise Fernandes Garcia quero expressar a minha profunda gratidão, incentivando-me e contribuindo com o meu aprendizado e minha formação.

Aos professores Dr. Jean Marcos de Souza Ribeiro, Dr. Falcondes José Mendes de Seixas, Dr. Marcelo Carvalho Minhoto Texeira, Dr. Edvaldo Assunção, Dr. Rodrigo Cardim, Dr. Francisco Carlos Vieira Malange, Dr. Júlio Borges de Souza e Dr. Dionízio Paschoareli Júnior pelas forças, incentivos e conhecimentos a mim fornecidos para a realização do Doutorado.

A FEIS-UNESP e seus funcionários, que contribuíram direta e indiretamente em minha formação profissional e pessoal, em especial aos técnicos de laboratório Adilson Antônio Palombo e Everaldo Leandro de Moraes.

Aos meus amigos de laboratório André Luiz Alexandre de Paula, Emerson Ravazzi Pires da Silva, Fábio Prudente Durão, Gisele de Carvalho Apolinário, Jefferson Leone e Silva, Luiz Francisco Sanches Buzachero, Manoel Rodrigo Moreira, Saulo Crnkowise Garcia, Uiliam Nelson Lenzion Tomaz Alves e Victor Leonardo Yoshimura pelas sinceridades, ajudas, conselhos, críticas e momentos de descontração.

Aos amigos que tive a oportunidade de conviver em Ilha Solteira, Clarice Sayumi Kuriyama, Eleusa Maria Lima, à memória de Izilda Maria David Hidalgo, e Marcus Vinícius Alves Pereira, e aos amigos que convivo em Presidente Epitácio, Adriana Maria Pereira, Alexandre Ataíde Carniato, Aline Karen Baldo, Ítalo Alves Montorio Júnior, Leonardo Ataíde Carniato, João Victor Fazzan, José Guilherme Magalini Santos Decanini, Márcia Jani Cícero, Marcos do Nascimento, Rosana Abbud e Verônica de Freitas, pelos auxílios, conselhos e momentos de descontração e distração que passamos juntos.

Aos meus pais, Aparecido Rodrigues e Elizabeth Antunes Barros Rodrigues, à minha irmã Eloisa Barros Rodrigues, ao meu cunhado Thomas Rodrigues dos Santos, aos meus sobrinhos Lara Rodrigues dos Santos e Heitor Rodrigues dos Santos e ao meu avô Benedito do Carmo Barros, o qual, sempre me apoiaram e incentivaram nesta caminhada.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo apoio

financeiro e ao Instituto Federal de Educação, Ciência e Tecnologia do Estado de São Paulo (IFSP) pelo incentivo acadêmico.

“Aquele que conquista o mundo
e desconsidera a sua alma
não é digno de ser chamado
de Filho de Deus.”

RESUMO

Neste trabalho investiga-se a capacidade de uma rede neural artificial, com ajustes de pesos em tempo real, executar o controle de sistemas por meio de uma estrutura de rastreamento de sinais em três contextos: inicialmente em uma série de sistemas lineares e não-lineares; em um segundo momento, a rede neural é utilizada no controle de sistemas sujeitos a incertezas paramétricas; e por fim, no controle de máquinas elétricas que podem ou não estar sujeitas a variações paramétricas, incertezas e perturbações lineares e não-lineares. Na primeira aplicação da rede neural artificial verifica-se o desempenho de rastreamento de sistemas lineares de 1^a, 2^a e 3^a ordens controlados em malha fechada por meio de simulações computacionais. Nesse sentido, calcula-se um índice de desempenho utilizando a integral do valor absoluto do erro (IAE - *Integral of the Absolute Magnitude of the Error*). Esse índice indica a proximidade da saída real do sistema com relação ao sinal de referência. Essa estrutura rastreadora de sinais poderá funcionar conjuntamente com controlador clássico Proporcional, Integral e Derivativo (PID). Testes são realizados utilizando controladores com estrutura variável e modos deslizantes, os quais, são estratégias robustas às incertezas paramétricas do tipo casadas, todavia não apresentam o mesmo comportamento no que tange às incertezas do tipo não casadas. Dentro desse contexto, apresenta-se uma estratégia de controle utilizando redes neurais artificiais em conjunto com modos deslizantes para reduzir as influências de quaisquer tipos de incertezas e perturbações. A eficácia da estrutura de controle proposta é verificada por meio de simulações computacionais considerando um modelo de eixo lateral de um avião L-1011 em condições de voo. O controle de máquinas elétricas é realizado inicialmente em motor de corrente contínua e posteriormente em motor de indução trifásico. Por meio de uma estratégia de controle formada por controlador PID auxiliado por rede neural artificial, o controle do motor de corrente contínua é realizado. O desempenho do motor de indução é analisado considerando inicialmente controladores PID e posteriormente controlador com estrutura variável e modos deslizantes, podendo ou não os controladores operarem com rede neural artificial. O motor de indução considerado pode apresentar incertezas e perturbações externas, sejam lineares ou não-lineares, o qual, espera-se que a utilização da rede neural melhore a resposta do motor, eliminando os efeitos degenerativos provindos das incertezas e perturbações.

Palavras-chave: Rede neural artificial. Rastreamento de sinais. Incertezas casadas e não casadas. Estrutura variável e Modos deslizantes. Variações paramétricas. Perturbações externas.

ABSTRACT

This thesis investigates the ability of an Artificial Neural Network (ANN), with real-time adjustable weights, to execute the control systems through a tracking structure for signals in three applications: in a series of linear and non-linear systems; to control systems subject to parametric uncertainties; and to control electrical machines that may be subject to linear and nonlinear disturbances and uncertainties. In the first application of ANN, it is verified the performance of tracking signals in systems of 1st, 2nd and 3rd order through computer simulations results. In this regard, it estimates a performance index using the Integral of the Absolute value of the Error (IAE), which indicates the difference between the system real output and the reference signal value. The proposed structure with the neural network is able to work with classical compensators, the proportional, integral and derivative (PID) controller. Evaluation tests are performed using controllers with variable structure and sliding mode. This strategies presents robustness to a class of parametric uncertainties, called matched parametric uncertainty. However, this technique is not robust related to unmatched uncertainty class. Thus, in this paper a control strategy is proposed based on ANN through sliding mode control technique to minimize the uncertainties and disturbances effects. In order to show the effectiveness of proposed method, simulation results are performed using a lateral axis model of an L-1011 in cruise flight conditions subject to the uncertainties and external disturbances. Initially, it is accomplished of direct current (DC) motors, and after that, the technique is applied to alternating current (AC) motors (three-phase induction). Through the combination of PID controller and ANN, some evaluations tests are performed in DC motors. The performance of induction motor has been addressed considering two control strategies using ANN. The first consists of three PID controllers of the following control variables: speed, torque and flux; at the second stage, it was designed observers and controllers according to variable structure and sliding mode technique applied to the nonlinear mathematical model of three-phase induction motor. The induction motor is subjected to nonlinear and linear uncertainties and external disturbances. Therefore, the observer and controller technique is used through the combination of sliding mode and ANN. A strategy for detection and accommodation of the controller is presented and the simulation results are compared to the control strategy with artificial neural network.

Keywords: Artificial neural network. Signal tracking. Matched and unmatched uncertainty. Variable structure and Sliding mode. Parametric variations. External disturbances.

LISTA DE FIGURAS

Figura 1	Neurônio biológico.	34
Figura 2	Modelo do neurônio de McCulloch-Pitts.	35
Figura 3	Função sinal.	36
Figura 4	Função linear.	36
Figura 5	Lógica rampa.	37
Figura 6	Função logística.	37
Figura 7	Função hiperbólica.	38
Figura 8	Rede Adaline.	39
Figura 9	Neurônio Adaline com duas entradas.	39
Figura 10	Representação geométrica da função lógica “e”.	40
Figura 11	Padrão de entrada de uma função lógica “não ou exclusivo”.	41
Figura 12	Arquitetura neural de rede Madaline para a realização mínima da função lógica “não ou exclusivo”.	42
Figura 13	Representação geométrica da função lógica “não ou exclusivo”.	43
Figura 14	Rede Madaline adaptativa composta por três camadas.	43
Figura 15	Representação de rede Hopfield.	44
Figura 16	Treinamento não-supervisionado.	45
Figura 17	Treinamento supervisionado.	45
Figura 18	Estrutura de um neurônio Adaline contínuo no tempo.	47
Figura 19	Estratégia de controle por RNA com adaptação de pesos via CEV-RNA em sistemas desconhecidos.	53
Figura 20	Sinal de referência para análise de desempenho em sistema de 1 ^a , 2 ^a e 3 ^a ordem.	54
Figura 21	Implementação da estratégia controle por RNA em sistemas desconhecidos.	55

Figura 22	Índices de desempenho para sistemas de 1 ^a ordem: primeiro caso.	56
Figura 23	Índices de desempenho para sistemas de 1 ^a ordem: segundo caso.	57
Figura 24	Sinal de referência e sinal de saída do sistema (25) em malha aberta sem controlador.	58
Figura 25	Sinal de referência e sinal de saída do sistema (25) em malha fechada com controlador via RNA.	59
Figura 26	Índices de desempenho para sistemas de 2 ^a ordem: primeiro caso.	60
Figura 27	Índices de desempenho para sistemas de 2 ^a ordem: segundo caso.	61
Figura 28	Índices de desempenho para sistemas de 2 ^a ordem: terceiro caso.	62
Figura 29	Índices de desempenho para sistemas de 2 ^a ordem: quarto caso.	63
Figura 30	Índices de desempenho para sistemas de 3 ^a ordem: primeiro caso.	64
Figura 31	Índices de desempenho para sistemas de 3 ^a ordem: segundo caso.	65
Figura 32	Índices de desempenho para sistemas de 3 ^a ordem: terceiro caso.	66
Figura 33	Sinal de referência e sinais de saída do sistema (35) em malha fechada sem controlador e com controle via RNA.	66
Figura 34	Sinais de controle do sistema (35) em malha fechada sem controlador e com controle via RNA.	67
Figura 35	Índices de desempenho para sistemas de 3 ^a ordem: quarto caso.	68
Figura 36	Índices de desempenho para sistemas de 3 ^a ordem: quinto caso.	69
Figura 37	Comparação entre o sinal de entrada e sinal de saída de uma RNA.	71
Figura 38	Sinal de referência e sinais de saída do sistema com controlador P e com controle via RNA.	72
Figura 39	Sinais de saída com controlador P e com controle via RNA.	72
Figura 40	Estratégia de controle por RNA com adaptação de pesos via CEV-RNA e controle PID.	73
Figura 41	Simulação computacional da estratégia de controle via RNA e PID.	73
Figura 42	Sinal de referência e sinais de saída com controlador PID e com controle via RNA mais PID: sistema (43).	75

Figura 43	Sinal de controle gerado pelo PID e sinal de controle gerado pela RNA mais PID: sistema (43).	75
Figura 44	Sinal de referência e sinais de saída com controlador PID e com controle via RNA mais PID: sistema (45).	76
Figura 45	Sinal de controle gerado pelo PID e sinal de controle gerado pela RNA mais PID: sistema (45).	77
Figura 46	Sinal de referência e sinais de saída com controlador PID e com controle via RNA mais PID: sistema (46).	77
Figura 47	Sinal de controle gerado pelo PID e sinal de controle gerado pela RNA mais PID: sistema (46).	78
Figura 48	Sinal de referência e sinais de saída com controlador PID e com controle via RNA mais PID: sistema (47).	79
Figura 49	Sinal de controle gerado pelo PID e sinal de controle gerado pela RNA mais PID: sistema (47).	79
Figura 50	Implementação de controle para sistemas lineares e não-lineares por RNA e PID.	80
Figura 51	Sinal de referência para sistema de 3ª ordem com controle PID mais RNA.	81
Figura 52	Sinal de referência e sinais de saída com controlador PID e com controle via RNA mais PID: sistema (49).	82
Figura 53	Sinal de controle gerado pelo PID e sinal de controle gerado pela RNA mais PID: sistema (49).	82
Figura 54	Sinal de referência e sinais de saída com controlador PID e com controle via RNA mais PID: sistema (49) saturado.	83
Figura 55	Sinal de controle gerado pelo PID e sinal de controle gerado pela RNA mais PID: sistema (49) saturado.	84
Figura 56	Sinal de referência e sinais de saída com controlador PID e com controle via RNA mais PID: sistema (51) saturado.	85
Figura 57	Sinal de controle gerado pelo PID e sinal de controle gerado pela RNA mais PID: sistema (51) saturado.	85
Figura 58	Ângulos e partes principais de um avião.	92

Figura 59	Visão frontal de um avião com o ângulo de <i>bank</i> (ϕ_a).	93
Figura 60	Trajetória do avião e ângulo de derrapagem β_a	93
Figura 61	Estrutura de controle via RNA para sistemas lineares e não-lineares já controlados por OEV/MD e CEV/MD.	95
Figura 62	Simulação computacional da estratégia controle via RNA, OEV/MD e CEV/MD. 96	
Figura 63	Simulações realizadas com o modelo matemático de eixo lateral de um avião.	98
Figura 64	Sinais de referência, sinais de saída $y_2(t)$, $y_3(t)$ e $y_4(t)$ e sinais de controle para a primeira simulação: sistema sem incertezas controlado via CEV/MD.	99
Figura 65	Sinais de referência, sinais de saída $y_2(t)$, $y_3(t)$ e $y_4(t)$ e sinais de controle para a segunda simulação: sistema com incerteza não-linear casada controlado via CEV/MD.	100
Figura 66	Sinais de referência, sinais de saída $y_2(t)$, $y_3(t)$ e $y_4(t)$ e sinais de controle para a terceira simulação: sistema com incerteza não-linear casada controlado via CEV/MD e RNA.	100
Figura 67	Sinais de referência e sinais de saída $y_2(t)$, $y_3(t)$ e $y_4(t)$ para a quarta simulação: sistema com incertezas não-lineares casadas e não casadas controlado via CEV/MD.	101
Figura 68	Sinais de controle $u_1(t)$ e $u_2(t)$ para a quarta simulação: sistema com incertezas não-lineares casadas e não casadas controlado via CEV/MD.	102
Figura 69	Sinais de referência e sinais de saída $y_2(t)$, $y_3(t)$ e $y_4(t)$ para a quinta simulação: sistema com incertezas não-lineares casadas e não casadas controlado via CEV/MD e RNA em $y_4(t)$	102
Figura 70	Sinais de controle $u_1(t)$ e $u_2(t)$ para a quinta simulação: sistema com incertezas não-lineares casadas e não casadas controlado via CEV/MD e RNA em $y_4(t)$	103
Figura 71	Sinais de referência e sinais de saída para a sexta simulação: sistema com incertezas não-lineares casadas e não casadas controlado via CEV/MD e RNA em $y_2(t)$, $y_3(t)$ e $y_4(t)$	104

Figura 72	Sinais de controle $u_1(t)$ e $u_2(t)$ para a sexta simulação: sistema com incertezas não-lineares casadas e não casadas controlado via CEV/MD e RNA em $y_2(t)$, $y_3(t)$ e $y_4(t)$	104
Figura 73	Diagrama de um motor de corrente contínua com excitação independente.	107
Figura 74	Simulação computacional da estratégia controle via RNA e PID no Motor de CC.	109
Figura 75	Sinal de referência e torque da carga: motor de CC.	110
Figura 76	Velocidade do motor CC com controle PID-1 e PID-1 com RNA.	111
Figura 77	Tensão do motor CC com controle PID-1 e PID-1 com RNA.	111
Figura 78	Corrente do motor CC com controle PID-1 e PID-1 com RNA.	112
Figura 79	Velocidade do motor CC com controle PID-2 e PID-2 com RNA.	113
Figura 80	Tensão do motor CC com controle PID-2 e PID-2 com RNA.	113
Figura 81	Corrente do motor CC com controle PID-2 e PID-2 com RNA.	114
Figura 82	Velocidade do motor CC com controle PID-3 e PID-3 com RNA.	115
Figura 83	Tensão do motor CC com controle PID-3 e PID-3 com RNA.	115
Figura 84	Corrente do motor CC com controle PID-3 e PID-3 com RNA.	116
Figura 85	Relações angulares dos vetores correntes.	118
Figura 86	Diagrama das malhas de controle via PID utilizando modelo matemático do motor de indução.	122
Figura 87	Diagrama das malhas de controle via PID e RNA utilizando modelo matemático do motor de indução.	122
Figura 88	Conjugado da carga para o MIT com controles PID e RNA: casos 1 e 2.	123
Figura 89	Velocidade e correntes estatísticas do MIT com controle PID: caso 1.	124
Figura 90	Velocidade e correntes estatísticas do MIT com controles PID e RNA: caso 1.	125
Figura 91	Velocidade e correntes estatísticas do MIT com controle PID: caso 2.	126
Figura 92	Velocidade e correntes estatísticas do MIT com controles PID e RNA: caso 2.	126
Figura 93	Conjugado da carga para o MIT com controles PID e RNA: casos de 3 à 6.	127
Figura 94	Velocidade e correntes estatísticas do MIT com controle PID: caso 3.	128

Figura 95	Velocidade e correntes estatóricas do MIT com controles PID e RNA: caso 3.	128
Figura 96	Velocidade e correntes estatóricas do MIT com controle PID: caso 4.	129
Figura 97	Velocidade e correntes estatóricas do MIT com controles PID e RNA: caso 4.	130
Figura 98	Velocidade e correntes estatóricas do MIT com controle PID: caso 5.	131
Figura 99	Velocidade e correntes estatóricas do MIT com controles PID e RNA: caso 5.	131
Figura 100	Velocidade e correntes estatóricas do MIT com controle PID: caso 6.	132
Figura 101	Velocidade e correntes estatóricas do MIT com controles PID e RNA: caso 6.	133
Figura 102	Esquema de detecção e adaptação do controlador.	140
Figura 103	Estratégia de controle via CEV-MIT utilizando modelo matemático do motor de indução.	140
Figura 104	Simulação computacional da estratégia de controle CEV-MIT em MIT.	141
Figura 105	Estratégia de controle CEV/AC-MIT para o modelo matemático do motor de indução utilizando CEV-MIT, detecção e adaptação do controlador.	142
Figura 106	Simulação computacional da estratégia de controle CEV/AC-MIT com adaptação do controlador.	143
Figura 107	Estratégia de controle CEV/RNA-MIT-I utilizando modelo matemático do motor de indução.	144
Figura 108	Simulação computacional da estratégia de controle CEV/RNA-MIT-I em MIT.	145
Figura 109	Estratégia de controle CEV/RNA-MIT-II utilizando modelo matemático do motor de indução.	146
Figura 110	Simulação computacional da estratégia de controle CEV/RNA-MIT-II em MIT.	147
Figura 111	Simulações realizadas no MIT com controle vetorial.	148
Figura 112	Sinal de referência variável e conjugado da carga para MIT com CEV-MIT e RNA: variação paramétrica linear.	150
Figura 113	Velocidade do MIT com CEV-MIT: primeira estratégia de controle (CEV-MIT), sinal de referência variável e variação paramétrica linear.	150

Figura 114	Sinal de referência e corrente I_{mR} com CEV-MIT: primeira estratégia de controle (CEV-MIT), sinal de referência variável e variação paramétrica linear.	151
Figura 115	Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: primeira estratégia de controle (CEV-MIT), sinal de referência variável e variação paramétrica linear.	152
Figura 116	Velocidade do MIT com CEV-MIT: segunda estratégia de controle (CEV/AC-MIT), sinal de referência variável e variação paramétrica linear.	152
Figura 117	Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: segunda estratégia de controle (CEV/AC-MIT), sinal de referência variável e variação paramétrica linear.	153
Figura 118	Seleção do controlador CEV-MIT ativo: segunda estratégia de controle (CEV/AC-MIT), sinal de referência variável e variação paramétrica linear.	154
Figura 119	Velocidade do MIT com CEV-MIT: terceira estratégia de controle (CEV/RNA-MIT-I), sinal de referência variável e variação paramétrica linear.	154
Figura 120	Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: terceira estratégia de controle (CEV/RNA-MIT-I), sinal de referência variável e variação paramétrica linear.	155
Figura 121	Velocidade do MIT com CEV-MIT: primeira estratégia de controle (CEV-MIT), sinal de referência constante e variação paramétrica linear.	156
Figura 122	Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: primeira estratégia de controle (CEV-MIT), sinal de referência constante e variação paramétrica linear.	157
Figura 123	Velocidade do MIT com CEV-MIT: segunda estratégia de controle (CEV/AC-MIT), sinal de referência constante e variação paramétrica linear.	157
Figura 124	Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: segunda estratégia de controle (CEV/AC-MIT), sinal de referência constante e variação paramétrica linear.	158
Figura 125	Seleção do controlador CEV-MIT ativo: segunda estratégia de controle (CEV/AC-MIT), sinal de referência constante e variação paramétrica linear.	159
Figura 126	Velocidade do MIT com CEV-MIT: terceira estratégia de controle (CEV/RNA-MIT-I), sinal de referência constante e variação paramétrica linear.	159
Figura 127	Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: terceira estratégia de controle (CEV/RNA-MIT-I), sinal de referência constante e variação paramétrica linear.	160
Figura 128	Dinâmica da variação paramétrica não-linear considerada no MIT dos 18 aos 57 segundos de simulação.	161

Figura 129	Sinal de referência e conjugado da carga para o motor de indução trifásico com CEV-MIT e RNA: variação paramétrica não-linear.	162
Figura 130	Velocidade do MIT com CEV-MIT: primeira estratégia de controle (CEV-MIT), sinal de referência variável e variação paramétrica não-linear.	163
Figura 131	Sinal de referência e corrente I_{mR} com CEV-MIT: primeira estratégia de controle (CEV-MIT), sinal de referência variável e variação paramétrica não-linear.	163
Figura 132	Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: primeira estratégia de controle (CEV-MIT), sinal de referência variável e variação paramétrica não-linear.	164
Figura 133	Velocidade do MIT com CEV-MIT: segunda estratégia de controle (CEV/AC-MIT), sinal de referência variável e variação paramétrica não-linear.	165
Figura 134	Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: segunda estratégia de controle (CEV/AC-MIT), sinal de referência variável e variação paramétrica não-linear.	165
Figura 135	Seleção do controlador CEV-MIT ativo: segunda estratégia de controle (CEV/AC-MIT), sinal de referência variável e variação paramétrica não-linear.	166
Figura 136	Velocidade do MIT com CEV-MIT: terceira estratégia de controle (CEV/RNA-MIT-I), sinal de referência variável e variação paramétrica não-linear.	167
Figura 137	Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: terceira estratégia de controle (CEV/RNA-MIT-I), sinal de referência variável e variação paramétrica não-linear.	167
Figura 138	Velocidade do MIT com CEV-MIT: primeira estratégia de controle (CEV-MIT), sinal de referência constante e variação paramétrica não-linear.	168
Figura 139	Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: primeira estratégia de controle (CEV-MIT), sinal de referência constante e variação paramétrica não-linear.	169
Figura 140	Velocidade do MIT com CEV-MIT: segunda estratégia de controle (CEV/AC-MIT), sinal de referência constante e variação paramétrica não-linear.	170
Figura 141	Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: segunda estratégia de controle (CEV/AC-MIT), sinal de referência constante e variação paramétrica não-linear.	170
Figura 142	Seleção do controlador CEV-MIT ativo: segunda estratégia de controle (CEV/AC-MIT), sinal de referência constante e variação paramétrica não-linear.	171
Figura 143	Velocidade do MIT com CEV-MIT: terceira estratégia de controle (CEV/RNA-MIT-I), sinal de referência constante e variação paramétrica não-linear.	172

Figura 144	Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: terceira estratégia de controle (CEV/RNA-MIT-I), sinal de referência constante e variação paramétrica não-linear.	172
Figura 145	Velocidade do MIT com CEV-MIT: primeira estratégia de controle (CEV-MIT), incerteza linear e perturbação não-linear.	174
Figura 146	Sinal de referência e corrente I_{mR} com CEV-MIT: primeira estratégia de controle (CEV-MIT), incerteza linear e perturbação não-linear.	175
Figura 147	Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: primeira estratégia de controle (CEV-MIT), incerteza linear e perturbação não-linear.	175
Figura 148	Velocidade do MIT com CEV-MIT: terceira estratégia de controle (CEV/RNA-MIT-I), incerteza linear e perturbação não-linear.	176
Figura 149	Sinal de referência e corrente I_{mR} com CEV-MIT: terceira estratégia de controle (CEV/RNA-MIT-I), incerteza linear e perturbação não-linear.	177
Figura 150	Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: terceira estratégia de controle (CEV/RNA-MIT-I), incerteza linear e perturbação não-linear.	178
Figura 151	Velocidade do MIT com CEV-MIT: quarta estratégia de controle (CEV/RNA-MIT-II), incerteza linear e perturbação não-linear.	178
Figura 152	Sinal de referência e corrente I_{mR} com CEV-MIT: quarta estratégia de controle (CEV/RNA-MIT-II), incerteza linear e perturbação não-linear.	179
Figura 153	Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: quarta estratégia de controle (CEV/RNA-MIT-II), incerteza linear e perturbação não-linear.	180

LISTA DE TABELAS

Tabela 1	Função lógica “e”	40
Tabela 2	Função lógica “não ou exclusivo”	41
Tabela 3	Parâmetros do motor CC	109
Tabela 4	Parâmetros do motor de indução	123

LISTA DE ABREVIACOES E SIGLAS

3D	Três Dimenses
AD	Adaline
Adaline	<i>ADaptive LInear Element</i>
ANN	<i>Artificial Neural Network</i>
BP	<i>Backpropagation</i>
CA	Corrente Alternada
CC	Corrente Contnua
CEV	Controle com Estrutura Varivel
CEV/AC-MIT	Controle com Estrutura Varivel e Modos Deslizantes e Estratgia de Deteco e Adaptao do Controlador aplicado em MIT
CEV/MD	Controle com Estrutura Varivel e Modos Deslizantes
CEV-MIT	Controle com Estrutura Varivel e Modos Deslizantes aplicado em MIT
CEV-RNA	Controlador com Estrutura Varivel e Modos Deslizantes aplicado em RNA
CEV/RNA-MIT-I	Controlador com Estrutura Varivel e Modos Deslizantes e uma Malha com RNA aplicado em MIT
CEV/RNA-MIT-II	Controlador com Estrutura Varivel e Modos Deslizantes e duas Malhas com RNA aplicado em MIT
FT	Funo de Transferncia
IAE	<i>Integral of the Absolute Magnitude of Error</i>
ID	ndice de Desempenho
LMS	<i>Least Mean Square</i>
Madaline	Multi-Adaline
MD	Modo Deslizante
MIT	Motor de Induo Trifsico
OEV/MD	Observador com Estrutura Varivel e Modos Deslizantes
OEV-MIT	Observador com Estrutura Varivel e Modos Deslizantes aplicado em MIT
PID	Proporcional, Integral e Derivativo
RNA	Rede Neural Artificial
SD	Superfcie de Deslizamento
SLIT	Sistema Linear Invariante no Tempo

LISTA DE SÍMBOLOS

Alfabeto Grego

β_a	Ângulo de derrapagem (<i>sideslip angle</i>)
γ_0	Escalar positivo
γ	Ângulo de 120° entre bobinas
δ_a	Deflexão do aileron
δ_C	Constante pequena e positiva
δ_l	Deflexão do leme
δ_L	Ângulo de carga
δ_R	Constante positiva
Δ	Varição desconhecida da constante de tempo do rotor
Δ_A	Incerteza desconhecida e limitada da matriz A de sistemas
Δ_{22}	Ganho de incerteza não-linear
Δ_{52}	Ganho de incerteza não-linear
Δ_{55}	Ganho de incerteza não-linear
ε	Ângulo do rotor
ζ	Ângulo elétrico de $i_S(t)$
η	Constante positiva pequena
λ	Inclinação da curva da função sigmóide
v	Torque da carga normalizado
\tilde{v}	Torque da carga estimado
$\dot{\tilde{v}}$	Derivada do torque da carga estimado
$\xi(t)$	Não-linearidade desconhecida e limitada
ρ	Fase do vetor corrente de magnetização no rotor
ρ_C	Constante positiva
ρ_O	Função escalar
$\sigma(x)$	Superfície de deslizamento
$\sigma(t,x)$	Superfície de deslizamento
$\dot{\sigma}(t,x)$	Derivada da superfície de deslizamento
σ_R	Fator de dispersão do rotor
σ_1	Superfície de deslizamento 1
σ_2	Superfície de deslizamento 2
$\dot{\sigma}_1$	Derivada da superfície de deslizamento 1
$\dot{\sigma}_2$	Derivada da superfície de deslizamento 2
τ	Constante de tempo

τ_a	Constante de tempo elétrica da máquina de CC
τ_m	Constante mecânica da máquina de indução
τ_R	Constante de tempo do rotor
τ_{Rnom}	Constante de tempo nominal do rotor
v	Incertezas variante no tempo e limitada
ϕ_a	Ângulo de <i>bank</i>
ϕ	Fluxo no entreferro no eixo direto do motor de CC
ω	Velocidade angular do rotor
ω_B	velocidade angular nominal do rotor
ω_m	Velocidade mecânica
$\dot{\omega}_m$	Aceleração do motor
ω_{mR}	Velocidade angular do vetor corrente de magnetização do rotor
ω_{ref}	Velocidade angular do rotor de referência
ω_1	Velocidade angular do vetor corrente de estator

Alfabeto Latino

a	Número de caminhos paralelos do motor de CC
$A(t, x)$	Matriz do vetor de estados constante
$B(t, x)$	Matriz do vetor de controle constante
$C(t, x)$	Matriz do vetor de saída constante
c_1	Constante positiva
c_2	Constante positiva
d_k	Saída desejada discreta de um neurônio
E_a	Tensão de armadura
$e(t)$	Erro de aprendizado de um neurônio
$e_y(t)$	Erro entre o sinal de saída da planta e o sinal de referência
e_1	Erro entre o estado 1 da planta e o estado 1 estimado
e_2	Erro entre o estado 2 da planta e o estado 2 estimado
e_3	Erro entre o estado 3 da planta e o estado 3 estimado
e_4	Erro entre o torque da carga e o torque da carga estimado
\dot{e}_1	Derivada do erro entre o estado 1 da planta e o estado 1 estimado
\dot{e}_2	Derivada do erro entre o estado 2 da planta e o estado 2 estimado
\dot{e}_3	Derivada do erro entre o estado 3 da planta e o estado 3 estimado
\dot{e}_4	Derivada do erro entre o torque da carga e o torque da carga estimado
$f(t)$	Função variante no tempo da não-linearidade desconhecida
$f(t, x(t))$	Função desconhecida que representa incertezas do sistema

$f(s)$	Função de ativação de um neurônio
$G(s)$	Planta controlada
i_a	Corrente de armadura do motor de CC
I_B	Corrente nominal do motor
i_f	Corrente de campo do motor de CC
I_f	Corrente de campo constante do motor de CC
i_{mR}	Valor instantâneo da corrente de magnetização do rotor
$i_{mR\ ref}$	Valor instantâneo da corrente de magnetização do rotor de referência
i_{mR}^*	Conjugado do valor instantâneo da corrente de magnetização do rotor
\dot{i}_{mR}	Vetor corrente de magnetização do rotor
\dot{i}_R	Vetor complexo da corrente do rotor
i_S	Valor instantâneo da corrente do estator
\dot{i}_S	Vetor complexo da corrente do estator
i_{sa}	Corrente “a” do estator para um sistema bifásico ortogonal
i_{sb}	Corrente “b” do estator para um sistema bifásico ortogonal
i_{Sd}	Corrente do estator direta
$i_{Sd\ ref}$	Corrente do estator direta de referência
i_{Sq}	Corrente do estator em quadratura
$i_{Sq\ ref}$	Corrente do estator em quadratura de referência
i_{S1}	Corrente do estator na fase 1
i_{S2}	Corrente do estator na fase 2
i_{S3}	Corrente do estator na fase 3
J	Momento de inércia
k	Constante de tempo
K_O	Constante Positiva
k_a	Constante do motor de CC
k_f	Constante do motor de CC
k_m	Constante do motor de CC
k_{mit}	Constante do motor de indução
k_{mitB}	Constante do motor de indução nominal
k_R	Constante positiva para projeto do CEV-RNA
L_a	Indutância de armadura de um motor de CC
L_{aq}	Autoindutância do motor de CC
L_R	Auto-indutância de um enrolamento do rotor
L_S	Auto-indutância de um enrolamento do estator
L_0	Indutância mútua
L_1	Constante
L_2	Constante
m_B	Torque elétrico nominal do motor

m_d	Torque elétrico
$m_d \text{ ref}$	Torque elétrico de referência
m_L	Torque de carga
N_p	Número de padrões de entrada de um neurônio
N_w	Número de pesos de um neurônio
N_y	Número de saídas de um neurônio
p	Número de polos do motor de CC
p_a	Taxa de <i>roll</i>
P_B	Potência nominal
P_1	Constante positiva 1
P_2	Constante positiva 2
r	Taxa de guinada (<i>yaw rate</i>)
$r(t)$	Função decisão
$r^I(t)$	Função resíduo obtida do primeiro controlador
$r^{II}(t)$	Função resíduo obtida do segundo controlador
R_a	Resistência do circuito de armadura
R_R	Resistência do rotor por fase
R_S	Resistência do estator por fase
r_{wo}	Taxa de guinada de <i>washed out</i>
s_k	Saída intermediária e discreta de um neurônio
$S(t)$	Matrix da superfície de deslizamento
t	Tempo
T_e	Torque eletromagnético de uma máquina de CC
t_h	Tempo de entrada em deslizamento
T_L	Conjugado mecânico da carga
u	Vetor do sinal de controle
$u(t)$	Sinal de controle contínuo no tempo
U_B	Tensão Nominal
u_{eq}	Sinal de controle equivalente
u_{eq1}	Sinal de controle equivalente 1
u_{eq2}	Sinal de controle equivalente 2
u_{NL}	Sinal de controle descontínuo
u_{NL1}	Sinal de controle descontínuo 1
u_{NL2}	Sinal de controle descontínuo 2
u_1	Entrada de controle 1
u_2	Entrada de controle 2
V_B	Velocidade Nominal
$V(e(t))$	Função de Lyapunov
V_{ta}	Tensão nos terminais de armadura de um motor de CC

V_x	Constante positiva conhecida
$V_{\dot{x}}$	Constante positiva conhecida
V_y	Constante positiva conhecida
$V_{\dot{y}}$	Constante positiva conhecida
$V(\sigma)$	Função de Lyapunov
$\dot{V}(\sigma)$	Derivada da função de Lyapunov
W	Constante positiva conhecida
\tilde{W}	Constante positiva conhecida
$\tilde{w}_{eq}(t)$	Vetor de pesos adaptativo equivalente
\tilde{w}_k	Vetor de pesos “aumentado” e discreto
w_{nk}	“n” pesos atribuídos aos “n” padrões de entrada
$w(t)$	Vetor de pesos contínuo no tempo
$\tilde{w}(t)$	Vetor de pesos contínuo no tempo “aumentado”
\tilde{W}_0	Constante
w_0	Peso bias
w_{1k}	Peso atribuído ao padrão de entrada 1
x	Vetor de estados
\dot{x}	Derivada do vetor de estados
$x(t)$	Padrão de entrada contínuo no tempo ou estados do sistema
$\tilde{x}(t)$	Padrão de entrada contínuo no tempo “aumentado”
$\tilde{x}^I(t)$	Vetor de estados estimados pelo observador I
$\tilde{x}^{II}(t)$	Vetor de estados estimados pelo observador II
\tilde{x}_k	Vetor de sinais de entrada ou padrão de entrada “aumentado” discreto
x_{nk}	“n” padrões de entrada discretos
x_0	Entrada para o peso bias
x_{1k}	Padrão de entrada 1 discreto
x_1	Estado 1 da planta
x_2	Estado 2 da planta
x_3	Estado 3 da planta
x_{1Ref}	Estado 1 de referência
x_{3Ref}	Estado 3 de referência
\tilde{x}_1	Estado 1 da planta estimado
\tilde{x}_2	Estado 2 da planta estimado
\tilde{x}_3	Estado 3 da planta estimado
$\dot{\tilde{x}}_1$	Derivada do estado 1 da planta estimado
$\dot{\tilde{x}}_2$	Derivada do estado 2 da planta estimado
$\dot{\tilde{x}}_3$	Derivada do estado 3 da planta estimado
x_5	Estado do filtro de <i>washed out</i>
y	Vetor do sinal de saída

$y(t)$	Saída real da planta contínua no tempo
$\tilde{y}^I(t)$	Saída da planta estimada pelo observador I
$\tilde{y}^{II}(t)$	Saída da planta estimada pelo observador II
$y_d(t)$	Saída desejada contínua no tempo
$y'_d(t)$	Saída real do neurônio contínua no tempo
y_k	Saída de um neurônio discreta
Z_a	Número de condutores da armadura do motor de CC
ϵ_k	Erro entre a saída desejada e saída de um neurônio
∂	Derivada parcial

SUMÁRIO

1	INTRODUÇÃO	29
2	REDES NEURAIS ARTIFICIAIS E ALGORITMO DE ADAPTAÇÃO DE PESOS	33
2.1	REDES NEURAIS ARTIFICIAIS	33
2.1.1	Neurônio biológico	33
2.1.2	Neurônio artificial	34
2.1.3	Rede adaline	38
2.1.4	Rede madaline	42
2.1.5	Classificação de redes neurais	44
2.1.6	Treinamento de redes neurais	44
2.1.7	Capacidades de redes neurais	46
2.2	ALGORITMO DE ADAPTAÇÃO DE PESOS EM ADALINES UTILIZANDO CONTROLE COM ESTRUTURA VARIÁVEL E MODOS DESLIZANTES	46
2.2.1	Definições e conceitos básicos	47
2.2.2	Formulação do problema	48
2.2.3	Erro de aprendizado adaptativo nulo em tempo finito	49
2.3	CONCLUSÕES PARCIAIS	51
3	ESTRATÉGIA DE CONTROLE RASTREADORA DE SINAIS EM PLANTAS UTILIZANDO RNA E CEV-RNA	52
3.1	ANÁLISE DA EFICIÊNCIA DE CONTROLE VIA RNA EM SISTEMAS LINEARES	52
3.1.1	Sistemas lineares de 1ª ordem	54
3.1.2	Sistemas lineares de 2ª ordem	58
3.1.3	Sistemas lineares de 3ª ordem	62

3.2	ANÁLISE DA EFICIÊNCIA DE RNA EM SISTEMAS COM CONTROLADOR PID	70
3.2.1	Sistemas lineares de 1ª e 2ª ordem controlados por PID e RNA	71
3.2.2	Sistemas de 3ª ordem controlados por PID e RNA	78
3.3	CONCLUSÕES PARCIAIS	84
4	CONTROLADORES CEV/MD AUXILIADOS POR RNA APLICADOS EM SISTEMAS INCERTOS NÃO-LINEARES	87
4.1	CONTROLADOR E OBSERVADOR COM ESTRUTURA VARIÁVEL E MODOS DESLIZANTES	87
4.1.1	Controlador com estrutura variável e modos deslizantes (CEV/MD)	88
4.1.2	Observador com estrutura variável e modos deslizantes (OEV/MD)	89
4.2	ROBUSTEZ DO CONTROLE COM ESTRUTURA VARIÁVEL E MODOS DESLIZANTES	90
4.2.1	Definições	90
4.2.2	Sensibilidade do sistema durante o modo deslizante: condições de invariância	90
4.3	MODELO DE EIXOS LATERAIS DE UM AVIÃO L-1011	92
4.4	ESTRATÉGIA DE CONTROLE E SIMULAÇÕES REALIZADAS	94
4.5	RESULTADOS OBTIDOS E ANÁLISES	98
4.6	CONCLUSÕES PARCIAIS	105
5	CEV-RNA UTILIZADA PARA CONTROLE DE MOTORES ELÉTRICOS	106
5.1	MOTOR DE CORRENTE CONTÍNUA COM EXCITAÇÃO INDEPENDENTE	106
5.1.1	Equações dinâmicas do motor CC	106
5.1.2	Controle de velocidade de um motor de CC com excitação independente	108
5.2	MOTOR DE INDUÇÃO TRIFÁSICO (MIT)	116
5.2.1	Modelo matemático em coordenadas de campo com corrente de estator imposta	117
5.2.2	Estratégias de controle para MIT via PID e RNA	121

5.2.3	Simulações e resultados	121
5.3	CONCLUSÕES PARCIAIS	132
6	ESTRATÉGIAS DE CONTROLE VETORIAIS DE MIT ROBUSTAS A INCERTEZAS E VARIAÇÕES PARAMÉTRICAS	134
6.1	PROJETO DO CONTROLADOR COM ESTRUTURA VARIÁVEL COM MODOS DESLIZANTES (CEV-MIT)	134
6.1.1	Projeto da superfície de deslizamento (SD)	134
6.1.2	Projeto da lei de controle	136
6.2	PROJETO DO OBSERVADOR COM ESTRUTURA VARIÁVEL E MODOS DESLIZANTES (OEV-MIT)	137
6.3	ESTRATÉGIA DE ADAPTAÇÃO DO CONTROLADOR	138
6.3.1	Resíduos	138
6.3.2	Diagnóstico e adaptação do controlador	139
6.4	ESTRATÉGIAS DE CONTROLE	139
6.5	SIMULAÇÕES E RESULTADOS	147
6.5.1	Simulações e resultados: variação paramétrica linear	149
6.5.2	Simulações e resultados: variação paramétrica não-linear	160
6.5.3	Simulações e resultados: incerteza linear e perturbação não-linear	171
6.6	CONCLUSÕES PARCIAIS	180
7	CONCLUSÕES	183
	REFERÊNCIAS	186

1 INTRODUÇÃO

Controles com estrutura variável e modos deslizantes são estratégias de controle que apresentam características robustas quanto a dinâmicas indesejadas causadas por incertezas paramétricas e distúrbios externos (ZHANG; LIU; ZHU, 2014; YU; KAYNAK, 2009; HUNG; GAO; HUNG, 1993). Em Xu, Guo e Lee (2014) é realizada a implementação de uma estratégia de controle com Modos Deslizantes em um robô móvel equilibrado por duas rodas, capaz de eliminar influências paramétricas do tipo casadas e perturbações externas.

A busca de estratégias de controle eficientes e robustas cada vez mais se faz necessária, devido à existência de uma variedade considerável de sistemas dinâmicos e de alta complexibilidade, apresentando muitas vezes dinâmicas desconhecidas, erros de modelagem, vários tipos de distúrbios, incertezas e ruídos (TOPALOV; KAYNAK; AYDIN, 2007; WU; WANG; DANG, 2014; YAO; JIAO; MA, 2014; ABBASZADEH; MARQUEZ, 2012).

Muitos autores vêm buscando soluções de controle utilizando sistemas neuro-adaptativos, compensando a existência de distúrbios externos e mudanças paramétricas da planta, que normalmente são imprevisíveis (NIED et al., 2007; TOPALOV et al., 2007; TOPALOV; KAYNAK, 2001), em que Controladores com Estrutura Variável e Modo Deslizante (CEV/MD) estão sendo muito utilizados com redes neurais, lógicas Fuzzy e algoritmo genético (YU; KAYNAK, 2009).

A utilização de lógica Fuzzy junto de CEV/MD tem sido uma solução que alguns pesquisadores têm encontrado para controlar sistemas não-lineares que apresentam incertezas dinâmicas (EFE, 2003; KARAKUZU, 2010). Em Da e Song (2003) é proposto um Controlador com Estrutura Variável (CEV) junto de uma rede neural Fuzzy, com redução da trepidação causada por alguns CEV, devido ao chaveamento de alta velocidade presente no sinal de controle.

Redes neurais artificiais (RNA) são sistemas neuro-adaptativos, tal que, para apresentarem um bom desempenho, normalmente necessitam que um treinamento seja previamente realizado, ajustando seus pesos, de forma a produzirem respostas desejadas, conforme os padrões de entradas (HAYKIN, 1998, 842 p.).

O algoritmo de aprendizado mais utilizado é o *backpropagation* (BP), sendo comumente empregado em ajustes de pesos de forma *offline*, porém uma grande quantidade de algoritmos BP com aprendizado *online*, isto é, aprendizado realizado durante a utilização da rede em sua aplicação, tem sido proposto (NIED et al., 2007; TOPALOV et al., 2007; ZHAO, 1996; YU; EFE; KAYNAK, 2002). Em Jahangir et al. (2012) uma teoria de controle ótimo é utilizada para melhorar a taxa de convergência de algoritmo BP.

RNA que utilizam o BP para treinamento apresentam boas respostas. Na presença de fortes distúrbios externos, passam a ter um desempenho satisfatório face a esses problemas (NIED et al., 2007). Em Efe e Kaynak (2000) testes são realizados com o intuito de se verificar a robustez e a estabilidade de sistemas que utilizam o gradiente descendente como algoritmo de treinamento e o fato de se utilizar o CEV/MD para ajustar os pesos de RNA melhoram o desempenho dos sistemas.

Controle com Estrutura Variável e Modos Deslizantes (CEV/MD) têm sido muito utilizado para ajustes dos pesos de RNA em tempo real. Estas junções têm-se mostrado promissoras, proporcionando um mecanismo de ajuste que garante a estabilidade, com alta taxa de convergência e robustez (HU et al., 2012; YU; KAYNAK, 2009; RODRIGUEZ; ZEGERS; VEGA, 2009; TOPALOV et al., 2007). Em Kaynak, Erbatur e Ertugrul (2001) encontra-se uma revisão bibliográfica das principais contribuições de algoritmos de adaptação de pesos que utilizam controladores com Modo Deslizante (MD) aplicados em metodologias computacionalmente inteligentes, como por exemplo, redes neurais artificiais, além de uma comparação de rendimento com controladores que utilizam lógica Fuzzy, destacando-se também as dificuldades encontradas em implementações práticas com CEV/MD.

Em Sira-Ramírez e Colina-Morles (1995) é apresentada uma teoria de controle com Estrutura Variável e Modos Deslizantes para adaptar os pesos de redes Adaline, com o propósito da rede ser capaz de apenas reproduzir sinais de saídas mensuráveis, não havendo nenhuma ação efetiva na malha direta de controle, de modo a influenciar a resposta de plantas desconhecidas.

Estes mecanismos de ajustes de pesos *online* podem ser empregados tanto em sistemas contínuos no tempo (TOPALOV; KAYNAK; AYDIN, 2007; EFE, 2002; SIRA-RAMÍREZ; COLINA-MORLES; RIVAS-ECHEVERRÍA, 2000; SIRA-RAMÍREZ; COLINA-MORLES, 1995; EFE, 2009), como em sistemas discretos (MAN et al., 2006; TOPALOV; KAYNAK, 2005), além de serem utilizados e adaptados em uma série de sistemas não-lineares e incertos (TOPALOV; KAYNAK, 2004; EFE et al., 2004). Em Ertugrul e Kaynak (2000) e Efe, Kaynak e Yu (2000) são utilizadas redes Adaline com ajustes de pesos por MD, para o controle de manipuladores robóticos. Hu et al. (2012) enfocam o problema do projeto de um controlador com MD adaptativo para um veículo hipersônico, tal que se explora a característica de imunidade a incertezas paramétricas e distúrbios externos no modelo, sem a necessidade de serem casadas ou não.

Aplicações em máquinas elétricas utilizando RNA com algoritmo de adaptação de pesos *online* também são encontradas na literatura. Topalov et al. (2007) realizam experimentos em motor síncrono, apresentando uma abordagem de RNA com adaptação de pesos por CEV, utilizados para controlar a velocidade de um motor elétrico. Em Liu e Zhu (2014) redes Adaline são utilizadas em motores síncronos de ímã permanente para estimar o fluxo concatenado do rotor e não-linearidades que surgem no inversor de frequência com resposta em tensão.

Fu, Xie e Luo (2012) apresentam uma rede neural dinâmica com ajuste de pesos por MD com a finalidade de apenas identificar o modelo do motor de indução, incluindo os aspectos de fenômenos rápidos e lentos que o motor apresenta. Outra aplicação em motores de indução é apresentada em Cirrincione et al. (2013). Neste caso é utilizado um motor de indução linear, tal que, é proposto um observador de velocidade que utiliza um sistema adaptativo com redes Adaline.

A principal contribuição deste trabalho está em testar a rede neural Adaline com ajuste de pesos em tempo real, proposta por Sira-Ramírez e Colina-Morles (1995), sendo alocada de forma a atuar no controle efetivo de uma série de sistemas de 1ª, 2ª e 3ª ordem, lineares e não-lineares, sujeitos a incertezas paramétricas, distúrbios externos e perturbações. Sendo assim, simulações computacionais são realizadas, investigando-se em quais condições a rede apresenta característica em minimizar os erros entre sinais desejados e as saídas das plantas, além de minimizar os efeitos degenerativos provindos de não-linearidades, incertezas, distúrbios e perturbações externas.

No Capítulo 2 é descrita uma teoria sobre RNA, fazendo-se uma analogia com o neurônio biológico. Os conceitos de neurônios Adaline e Madaline são apresentados, classificando os tipos de redes recorrentes e não recorrentes, além dos algoritmos de treinamento supervisionado e não-supervisionado. Neste capítulo detalha-se o algoritmo de ajuste de pesos da RNA em tempo real para rede Adaline, o CEV-RNA, proposto por Sira-Ramírez e Colina-Morles (1995) e utilizado nas simulações realizadas neste trabalho.

No Capítulo 3, conjecturas são realizadas baseadas em resultados obtidos por meio de simulações computacionais em sistemas de 1ª, 2ª e 3ª ordem, utilizando a rede descrita por Sira-Ramírez e Colina-Morles (1995). Para isso, uma estratégia de controle em malha fechada é proposta utilizando a RNA. Esta rede é testada por meio de simulações atuando isoladamente ou em conjunto com controladores proporcional, integral e derivativo (PID) em estratégias de controle rastreadoras de sinais de sistemas lineares e não-lineares.

Baseado nestas análises, no Capítulo 4 é proposta uma estratégia de controle formada por Controlador e Observador, ambos com Estrutura Variável e Modos Deslizantes (CEV/MD e OEV/MD, respectivamente), acrescida da estrutura neural desenvolvida por Sira-Ramírez e Colina-Morles (1995). Com isso, explora-se a capacidade da nova estratégia de controle, em amenizar as influências causadas por incertezas não-lineares do tipo casadas e não casadas, presentes em modelos matemáticos de sistemas.

O modelo matemático linear de um motor de Corrente Contínua (CC) e o modelo não-linear de um Motor de Indução Trifásico (MIT) em coordenadas de campo com corrente de estator imposta são apresentados no Capítulo 5. Simulações são realizadas utilizando uma estratégia de controle proposta, formada por controlador PID auxiliado pela estrutura neural Adaline com ajustes de pesos via CEV-RNA. Os resultados destas simulações são comparados

com os resultados obtidos por meio de simulações utilizando-se apenas o controlador PID.

No Capítulo 6 são apresentados os projetos de um controlador e um observador, ambos segundo a técnica de estrutura variável e modos deslizantes aplicados ao modelo matemático do MIT (CEV-MIT e OEV-MIT, respectivamente), utilizados em quatro estratégias de controle, capazes de manter a velocidade do motor e a corrente de magnetização do rotor buscando suas respectivas referências, mesmo na presença de não-linearidades, incertezas e perturbações. Além das não-linearidades e incertezas presentes no modelo matemático do sistema, é inserida primeiramente uma variação paramétrica linear e num segundo momento uma variação paramétrica não-linear no modelo matemático do motor. Uma perturbação externa também é inserida, desenvolvendo uma dinâmica não-linear nos sinais de controle gerados pela fonte de alimentação do motor.

A primeira estratégia de controle apresentada é formada apenas pelo controlador CEV-MIT e observador OEV-MIT atuando no controle da máquina. No caso da segunda estratégia de controle apresentada, utiliza-se um esquema de detecção e adaptação do controlador, sendo necessário prever as condições operacionais da máquina e assim projetar o controlador e o observador para cada possível situação. A terceira estratégia de controle é proposta, tal que, o CEV-MIT e o OEV-MIT atuam em conjunto com o sistema neuro-adaptativo Adaline com algoritmo de ajuste de pesos em tempo real CEV-RNA, auxiliando o motor a buscar o sinal de referência de velocidade. Uma vantagem na utilização desta estratégia de controle com RNA em relação a estratégia com detecção e adaptação do controlador é não haver a necessidade de prever as possíveis condições de operação do motor. Para a quarta estratégia de controle é proposto o acréscimo de uma segunda estrutura neural, atuando diretamente na busca do sinal de referência para a corrente de magnetização do rotor. Por conseguinte, simulações computacionais são realizadas destacando-se em quais condições de operação do motor as estratégias de controle são eficazes.

As conclusões finais deste trabalho estão no Capítulo 7.

2 REDES NEURAIIS ARTIFICIAIS E ALGORITMO DE ADAPTAÇÃO DE PESOS

Neste capítulo apresenta-se uma revisão sobre as principais características de Redes Neurais Artificiais (RNA). RNA são sistemas inteligentes capazes de aproximar funções, identificar padrões, realizar previsões, dentre outros (HAYKIN, 1998, 842 p.). Deste modo, justifica-se sua aplicação na solução de problemas complexos ausentes de formulações analíticas precisas. Dentro deste contexto, apresentar-se-ão os fundamentos relativos ao neurônio biológico e ao neurônio artificial, além de uma descrição objetiva dos conceitos relacionados às redes utilizadas para o desenvolvimento deste trabalho.

Consecutivamente, uma teoria robusta para adaptação de pesos para RNA é apresentada. A adaptação de pesos é realizada utilizando um controlador com Estrutura Variável e Modos Deslizantes, garantindo em um tempo finito, que a rede passe a apresentar a resposta desejada e assim fique por todo o tempo subsequente. Esta revisão foi extraída do artigo de Sira-Ramírez e Colina-Morles (1995).

2.1 REDES NEURAIIS ARTIFICIAIS

2.1.1 Neurônio biológico

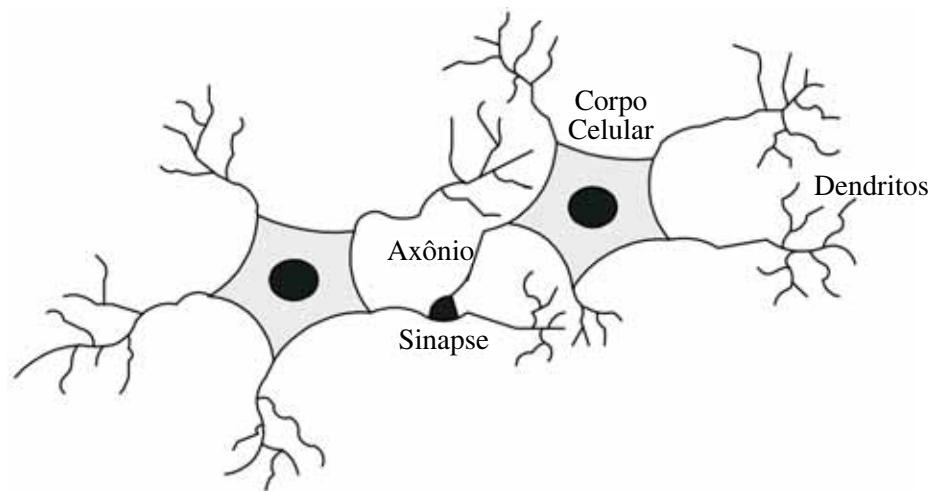
Vários estudiosos vêm ao longo dos anos desenvolvendo modelos matemáticos que apresentam respostas parecidas com os neurônios biológicos presentes em organismos inteligentes, que por meio de treinamentos ou estímulos conseguem adquirir certo conhecimento ou experiência (FILHO; CARVALHO, 1997).

O neurônio biológico é uma estrutura formada basicamente pelos dendritos, axônios e corpo celular (Figura (1)). Os dendritos são responsáveis por captar sinais elétricos de outros neurônios (canais de entrada), e por meio dos axônios, atividades elétricas são enviadas aos demais neurônios (terminal de saída). A parte principal e vital desta estrutura consiste do corpo celular, o qual processa as informações recebidas pelos dendritos e impulsos nervosos são gerados (FILHO; CARVALHO, 1997).

Como visto na Figura (1), a conexão entre neurônios dá-se por meio da sinapse, isto é, a ligação entre o dendrito e o axônio.

Dentro deste contexto, se os sinais recebidos pelos dendritos de um neurônio exceder um valor limiar de ativação (*threshold*), o mesmo disparará um sinal eletroquímico a outro neurônio. Como a sinapse possui uma abertura com um neurotransmissor químico, um sinal, ou

Figura 1 - Neurônio biológico.



Fonte: Lopes (2005).

melhor, um impulso nervoso pode ser transmitido a outro neurônio. A inteligência que pode ser atribuída a um neurônio se dá pela conectividade entre os demais neurônios (HAYKIN, 1998, 842 p.).

2.1.2 Neurônio artificial

Os neurônios artificiais foram criados com o intuito de modelar o funcionamento dos neurônios biológicos, e assim, por meio de técnicas computacionais, simulam o aprendizado do cérebro humano. Estes neurônios, artificiais e biológicos não são iguais, porém apresentam características semelhantes, dentre elas, destacam-se:

- Armazenamento de conhecimentos por meio de treinamento;
- Interligações entre neurônios realizadas por conexões sinápticas, utilizadas para armazenar informações importantes a rede neural que ele faz parte;
- Capacidade de generalização, o que permite que a rede neural artificial forneça, em tempo real, saídas com uma razoável precisão para entradas que não participaram da fase de treinamento (SILVA; SPATTI; FLAUZINO, 2010).

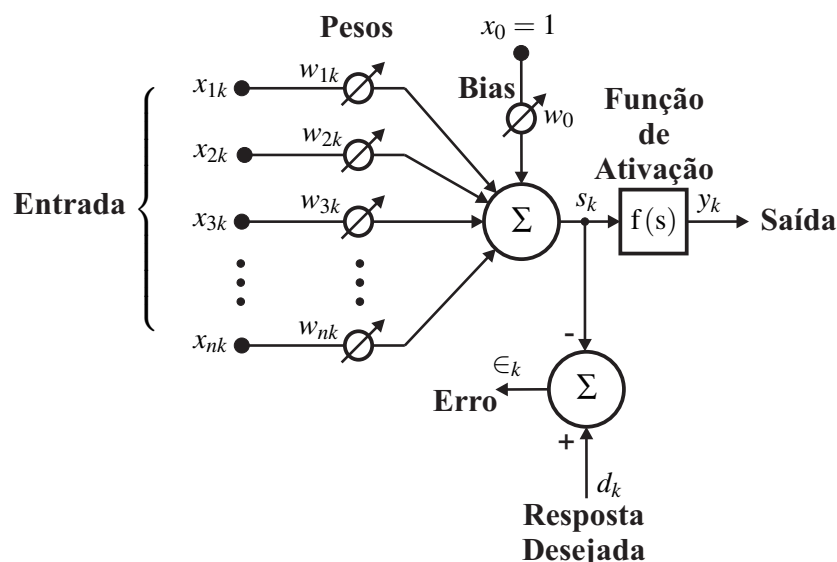
Além das características supracitadas, uma RNA, formada por vários neurônios, destacam-se (SILVA; SPATTI; FLAUZINO, 2010; DECANINI, 2013):

- Representação distribuída do conhecimento, sendo que, o conhecimento é armazenado de forma distribuída em seus pesos, tornando-se mais tolerantes a falhas de neurônios individuais;

- Apresentam robustez e tolerância a falhas, mesmo que as informações a serem analisadas estejam incompletas ou com ruído é possível obter um raciocínio correto;
- Não necessitam de regras explícitas, sendo que, o processo de aprendizagem ocorre por meio de exemplos;
- Determinadas redes são capazes de aprender novos cenários sem perda do conhecimento previamente adquirido, tendo assim, a capacidade de aprendizado continuado;
- Capacidade de paralelismo, produzindo respostas com alto desempenho computacional.
- Facilidade de prototipagem, isto é, na maioria das aplicações, consegue-se implementar redes neurais em *hardware* ou em *software*, uma vez que sua utilização dá-se por meio de operações matemáticas elementares.

Redes neurais apresentam um conjunto de elementos compactos para resolverem os problemas do cotidiano. Sua maioria é formada por sistema adaptativo (WIDROW; LEHR, 1990). McCulloch e Pitts (1943) descrevem um modelo de neurônio artificial, no qual a saída corresponde a uma combinação linear das entradas, conforme apresentado na Figura (2).

Figura 2 - Modelo do neurônio de McCulloch-Pitts.



Fonte: Widrow e Lehr (1990).

Considerando uma implementação digital, a cada constante de tempo k , um vetor de sinais de entrada ou padrão de entrada $\tilde{x}_k = [x_{1k}, x_{2k}, \dots, x_{nk}, x_0]^T$ e uma resposta desejada d_k , serão recebidos por estes elementos. A soma das entradas ponderadas pelo vetor de pesos


$\tilde{w}_k = [w_{1k}, w_{2k}, \dots, w_{nk}, w_0]^T$, produzem uma saída linear intermediária ($s_k = \tilde{x}_k^T \tilde{w}_k$). Os componentes de \tilde{x}_k podem apresentar valores analógicos ou binários e os de \tilde{w}_k são adaptados continuamente, podendo ser positivos ou negativos.

A saída intermediária s_k de um neurônio alimenta uma função de ativação, gerando o sinal de saída do neurônio y_k , que é enviado aos demais neurônios. O erro linear ϵ_k é obtido pela comparação entre a resposta desejada d_k e a saída y_k .

As funções de ativação mais empregadas são:

- **Signal:** $f(s) = \begin{cases} +1, & \text{se } s \geq 0 \\ -1, & \text{se } s < 0 \end{cases}$


Figura 3 - Função signal.



Fonte: o próprio autor.

- **Linear:** $f(s) = s$


Figura 4 - Função linear.



Fonte: o próprio autor.

- *Rampa*


Figura 5 - Lógica rampa.



Fonte: o próprio autor.

- **Logística:** $f(s) = \frac{1}{(1+e^{-\lambda s})}$

Figura 6 - Função logística.




Fonte: o próprio autor.

tal que, λ é a inclinação da curva.

- **Hiperbólica:** $f(s) = \frac{(1-e^{-\lambda s})}{(1+e^{-\lambda s})}$

Figura 7 - Função hiperbólica.



Fonte: o próprio autor.

2.1.3 Rede adaline

O modelo de neurônio artificial Adaline (*ADaptive LInear Element*) foi proposto por Widrow e Hoff em 1959 e posteriormente uma versão formada por vários neurônios Adaline, a rede neural Madaline (Multi-Adaline) (WIDROW; LEHR, 1990).

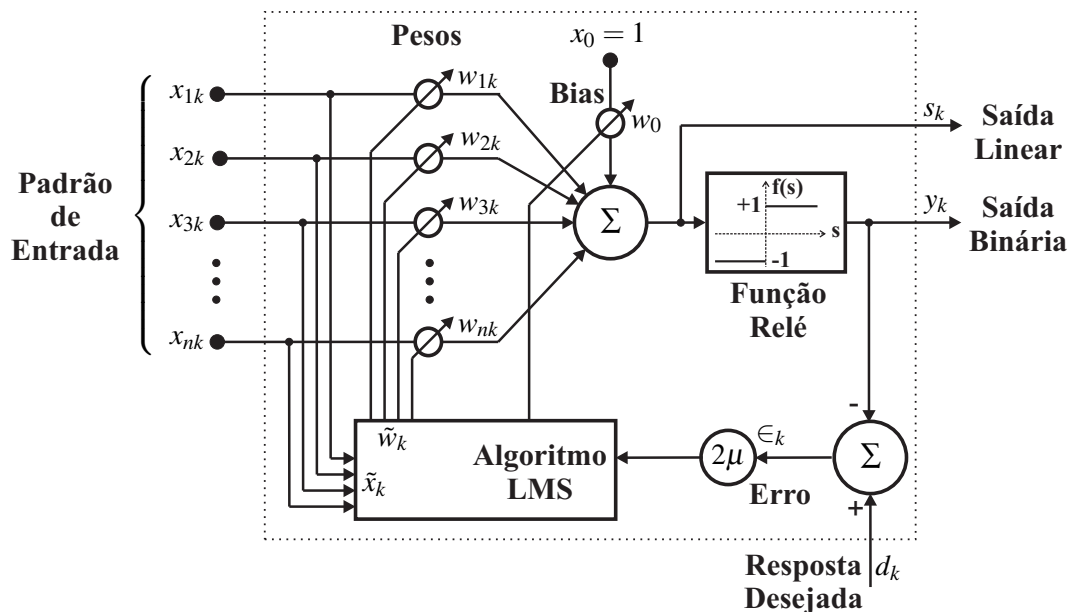
A representação da estrutura de uma rede Adaline é dada na Figura (8). O combinador linear adaptativo junto de uma função de ativação, linear ou não-linear, compõe esta rede.

Para se obter uma resposta desejada da RNA, necessita-se que um treinamento seja previamente realizado, ajustando os pesos de \tilde{w}_k automaticamente. Existem vários algoritmos com essa finalidade, como por exemplo, o *Least Mean Square* (LMS), projetado de forma que minimize a soma dos quadrados dos erros lineares em relação ao conjunto de treinamento (WIDROW; LEHR, 1990), e o *backpropagation*, sendo o algoritmo de retroalimentação mais difundido na comunidade acadêmica (HAGAN; MENHAJ, 1994; NIED et al., 2007).

O treinamento de uma rede Adaline é realizado considerando uma quantidade grande de padrões de entrada. Após sua realização, os pesos estarão ajustados e a rede poderá ser testada. Por conseguinte, aplicam-se padrões de entrada e espera-se que, além da característica de aprendizagem, a rede Adaline faça corretamente a generalização, característica essa imprescindível para a rede, pois nem sempre é possível utilizar todos os padrões de entradas durante o treinamento (WIDROW; LEHR, 1990).

Um neurônio, com n entradas e apenas uma saída y_k , é capaz de resolver apenas tarefas, como por exemplo, implementar uma lógica “e” ou uma lógica “ou”.


Figura 8 - Rede Adaline.



Fonte: Widrow e Lehr (1990).

A Figura (9) apresenta de um neurônio com duas entradas e uma saída, o qual será treinado para fazer a implementação de uma lógica “e” de acordo com o padrão de entrada. Neste exemplo será utilizado uma representação diferente das usuais para os estados lógicos alto e baixo, como sendo $[+1, -1]$ respectivamente, ao invés de $[+1, 0]$ (WIDROW; LEHR, 1990).

Figura 9 - Neurônio Adaline com duas entradas.



Fonte: Widrow e Lehr (1990).

As respostas de uma lógica “e” de acordo com as duas entradas e seus pontos distribuídos geometricamente são mostrados na Tabela (1) e na Figura (10), respectivamente.

O hiperplano de comutação também está representado na Figura (10), espera-se que após o treinamento a rede Adaline consiga fornecer a resposta desejada de acordo com os padrões de entrada, isto é, para o ponto $[-0,9, +0,6]$ (próximo do ponto “d”) a rede deve fornecer a saída $y_k = -1$, realizando a generalização.


A condição limiar crítica ocorre quando a saída linear s_k é igual a zero:

Tabela 1 - Função lógica “e”

Ponto	Entrada		Saída
	x_1	x_2	y_k
a	+1	+1	+1
b	+1	-1	-1
c	-1	-1	-1
d	-1	+1	-1

Fonte: o próprio autor.

Figura 10 - Representação geométrica da função lógica “e”.



Fonte: o próprio autor.

$$s_k = x_1 w_1 + x_2 w_2 + w_0 = 0 \quad , \quad (1)$$

assim,

$$x_2 = -\frac{w_1}{w_2} x_1 - \frac{w_0}{w_2} \quad , \quad (2)$$

sendo que, $-\frac{w_1}{w_2}$ é o coeficiente angular da reta e $-\frac{w_0}{w_2}$ é o deslocamento da reta no eixo de x_2 . Logo, um neurônio Adaline pode ser utilizado para classes de funções linearmente separáveis.

Um exemplo de função linearmente não separável é a lógica “não ou exclusivo”, que é apresentada na Tabela (2).

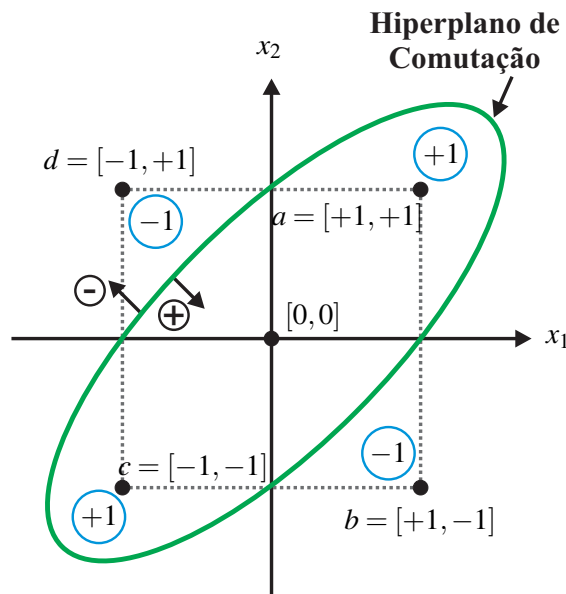
Tabela 2 - Função lógica “não ou exclusivo”

Entrada			Saída
Ponto	x_1	x_2	y_k
a	+1	+1	+1
b	+1	-1	-1
c	-1	-1	+1
d	-1	+1	-1

Fonte: o próprio autor.

Na Figura (11) encontram-se os pontos referentes aos padrões de entrada, por meio de uma simples análise pode-se observar que com apenas um neurônio não é possível separar linearmente estes pontos. Com isto, faz-se necessário o uso de uma rede Madaline.

Figura 11 - Padrão de entrada de uma função lógica “não ou exclusivo”.

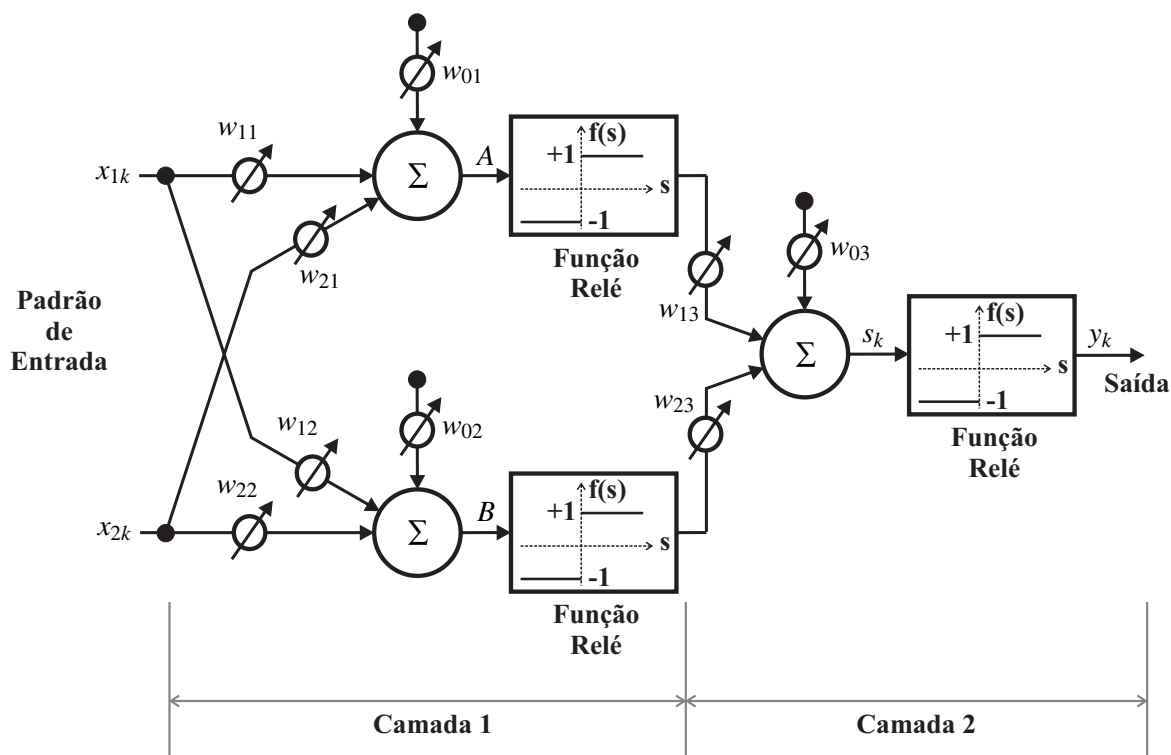


Fonte: o próprio autor.

2.1.4 Rede madaline

Uma das primeiras redes neurais formadas por camadas, com a possibilidade de treinamento e múltiplos elementos adaptativos consiste na estrutura considerada Madaline. Verifica-se, analisando a Figura (12), que a rede Madaline, em um caso simples, é formada pela junção de redes Adaline. Esta rede previamente treinada realiza a função lógica “não ou exclusivo” com êxito.

Figura 12 - Arquitetura neural de rede Madaline para a realização mínima da função lógica “não ou exclusivo”.

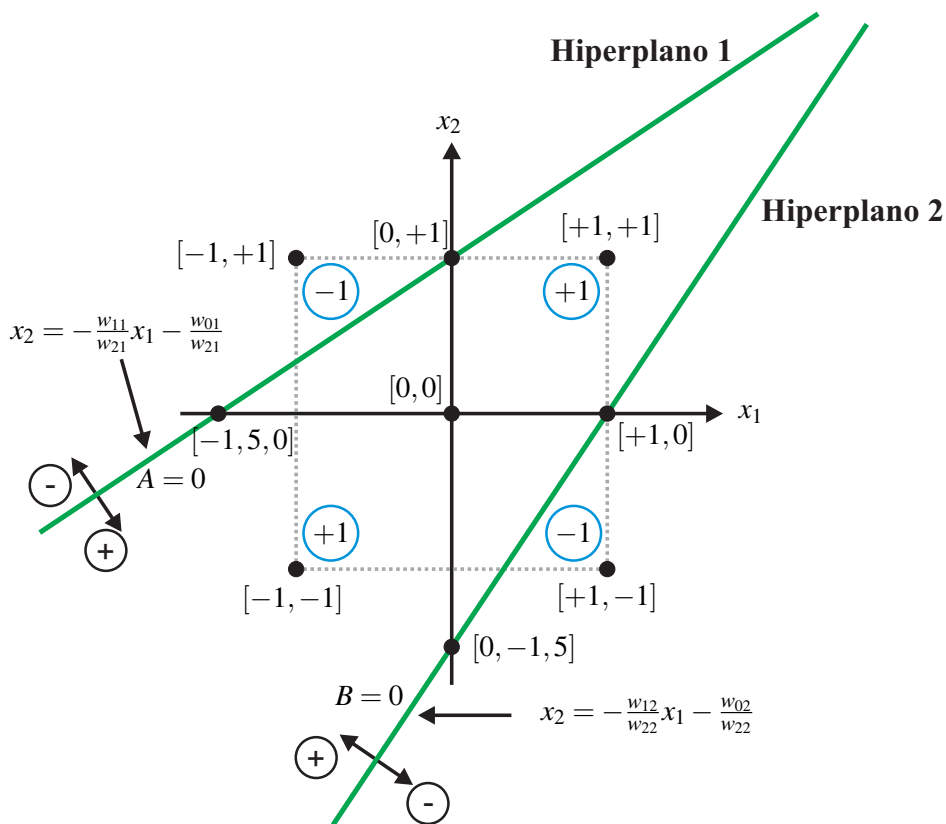


Fonte: Widrow e Lehr (1990).

Duas camadas compõem a RNA mostrada na Figura (12), sendo que, na primeira camada estão presentes dois neurônios e na segunda apenas um. A resposta obtida após o treinamento é apresentada na Figura (13), a qual ilustra a representação da separabilidade geométrica dos padrões de entrada.


Redes Madaline são, usualmente, construída por inúmeras camadas, que se subdividem em camadas de entrada, escondidas e de saída. A camada de entrada e as camadas escondidas são formadas por diversos neurônios, enquanto a de saída apresenta, em geral, um número reduzido. Na Figura (14) é apresentada esta estrutura descrita, sendo as redes Adaline representadas por AD.

Figura 13 - Representação geométrica da função lógica “não ou exclusivo”.



Fonte: o próprio autor.

Figura 14 - Rede Madaline adaptativa composta por três camadas.



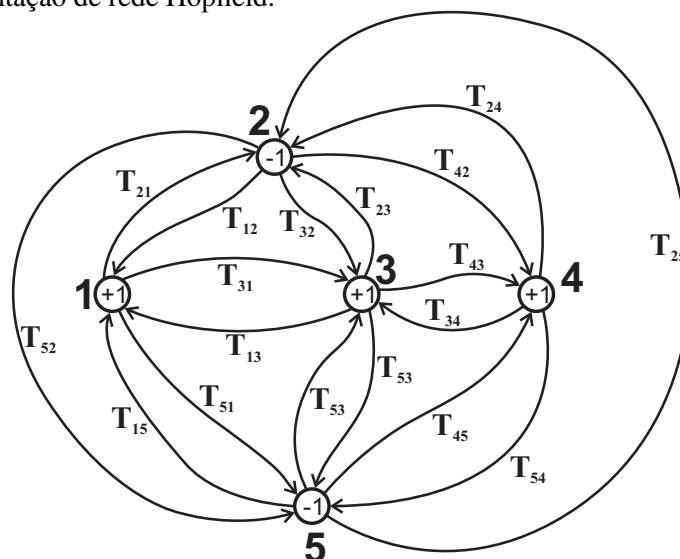
Fonte: Widrow e Lehr (1990) e Silva, Spatti e Flauzino (2010).

2.1.5 Classificação de redes neurais

Redes neurais podem ser classificadas de acordo com a forma de alimentação dos neurônios presentes em uma rede composta por várias camadas (HAYKIN, 1998, 842 p.):

- **Redes Recorrentes:** são formadas por laços de realimentação entre os neurônios da mesma camada em que fazem parte ou laços que realimentam neurônios das camadas anteriores. Um exemplo de rede recorrente é a Hopfield, ilustrada na Figura (15), na qual, tanto os neurônios de entrada e de saída da rede são interligados.

Figura 15 - Representação de rede Hopfield.



Fonte: Mceliece et al. (1987).

- **Redes não-recorrentes (*feedforward*):** não apresentam laços de realimentação, isto é, a saída de um neurônio alimenta apenas os neurônios da camada seguinte, sendo assim, considera-se não-recorrente a rede apresentada na Figura (14).

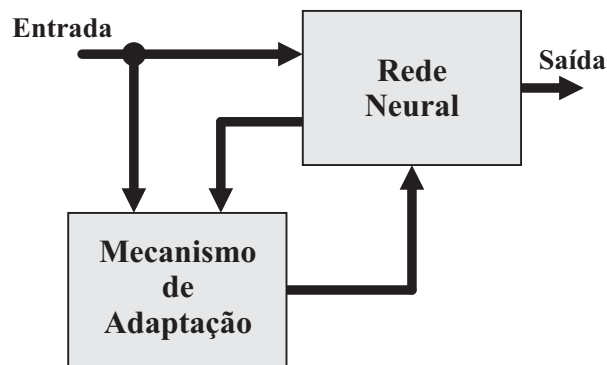
2.1.6 Treinamento de redes neurais

A realização do treinamento é essencial para a tomada de decisões e, conseqüentemente, o fornecimento das respostas desejadas, tendo como base o padrão de entrada. Por conseguinte, o treinamento consiste de um processo iterativo de ajustes dos pesos a partir de dados reais, sendo assim, a rede absorve conhecimento utilizando exemplos.

Pode-se definir algoritmo de treinamento como sendo um conjunto de regras bem definidas para a solução de um problema. Dentre os vários algoritmos existentes, uma característica que se destaca, está nos requisitos que eles necessitam para conseguir realizar o treinamento, isto é, necessitam apenas do padrão de entrada ou então, também de um erro gerado pela saída da rede comparada com a saída desejada. Isto traz as seguintes classificações (HAYKIN, 1998, 842 p.):

- Treinamento não-supervisionado: este treinamento está representado na Figura (16), tal que, o processo de aprendizagem é realizado utilizando exclusivamente os vetores de entrada, não sendo realizada nenhuma comparação com respostas predeterminadas, o que o torna um processo de auto-organização. As redes Hopfield e ART são exemplos de redes que possuem treinamento não-supervisionado.

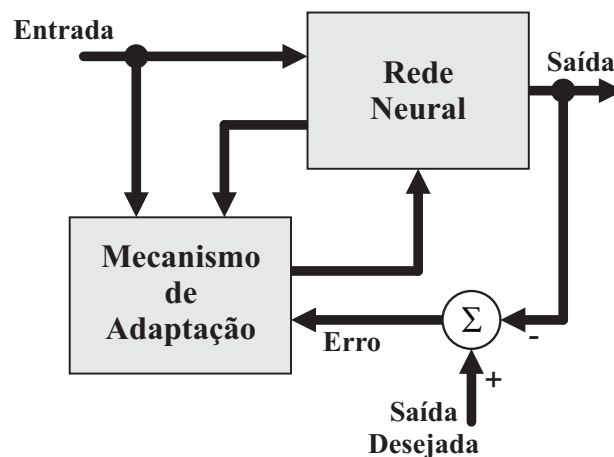
Figura 16 - Treinamento não-supervisionado.



Fonte: HAYKIN (1998, 842 p.).

- Treinamento supervisionado: realiza-se com o auxílio de um tutor ou professor, isto é, utilizando o padrão de entrada e a comparação da saída da rede com saída desejada. Este tipo de treinamento está representado na Figura (17), o qual, a saída obtida é avaliada e comparada com a saída desejada. Caso não seja atendido o critério de convergência predefinido, a rede deverá ajustar os pesos de maneira a buscar uma boa resposta, adquirindo o conhecimento almejado.

Figura 17 - Treinamento supervisionado.



Fonte: HAYKIN (1998, 842 p.).

As redes Madaline e ARTMAP são exemplos de redes que apresentam treinamento supervisionado. O algoritmo de treinamento mais empregado em redes Madaline é o de retropropagação, também conhecido por *backpropagation* (BP).

- Treinamento híbrido: neste treinamento realiza-se uma combinação das duas formas anteriores, ocorrendo uma alternância entre elas.

2.1.7 Capacidades de redes neurais

A capacidade de uma RNA em conseguir adquirir conhecimento sobre determinadas situações ou problemas está diretamente relacionada com a quantidade de neurônios que a compõe. A utilização de uma grande quantidade de neurônios a deixa mais complexa, porém aumenta a abrangência em termos de soluções possíveis.

A escolha da quantidade de neurônios para a composição de uma rede não é algo exato, conseqüentemente não se tem uma fórmula ou regra geral específica para definir este quantitativo. O que existe, são métodos para estimar a quantidade necessária de neurônios, tal que, a rede resolva certo problema (WIDROW; LEHR, 1990; BRAGA; CARVALHO; LUDEMIR, 2007).

Redes neurais com poucos neurônios ou então, devido a um treinamento interrompido prematuramente, não conseguem a resposta desejada. Neste sentido, o aumento da quantidade de neurônios traz benefícios à rede, possibilitando que a mesma seja capaz de realizar um mapeamento não-linear. Contudo, se ocorrer um aumento excessivo deste valor, a rede pode começar a fazer registros de possíveis ruídos que venham a surgir no padrão de entrada, logo a rede passa a apresentar respostas não tão fiéis em relação às esperadas (BRAGA; CARVALHO; LUDEMIR, 2007).

Segundo Widrow e Lehr (1990), uma boa generalização pode ocorrer se o conjunto de treinamento apresentar um grande número de padrões de entrada em relação à capacidade da rede, isto é, se o número de padrões de entrada N_p for consideravelmente maior que a relação entre o número de pesos N_w pelo número de saídas N_y , traduzindo $N_p \gg N_w/N_y$.

2.2 ALGORITMO DE ADAPTAÇÃO DE PESOS EM ADALINES UTILIZANDO CONTROLE COM ESTRUTURA VARIÁVEL E MODOS DESLIZANTES

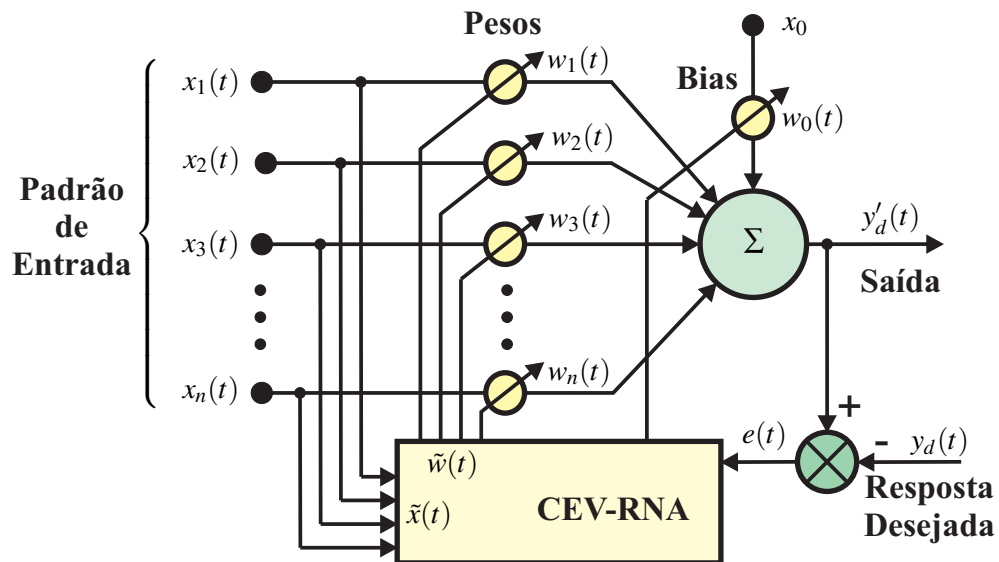
Nesta seção é explorado o projeto de um Controlador com Estrutura Variável e Modos Deslizantes aplicado em RNA (CEV-RNA). Este estudo baseia-se no artigo de Sira-Ramírez e Colina-Morles (1995). O CEV-RNA será utilizado para adaptar os pesos da uma rede Adaline em tempo real. Esta adaptação dos pesos, garante que a rede apresente respostas desejadas, isto é, a capacidade em reproduzir sinais de saídas mensuráveis, de plantas desconhecidas.

2.2.1 Definições e conceitos básicos

O Modo Deslizante (MD) proposto por Sira-Ramírez e Colina-Morles (1995) garante um aprendizado adaptativo robusto em redes Adaline, sendo assim, redes neurais que utilizam combinação linear das entradas para formar a saída, como por exemplo, o modelo proposto por McCulloch e Pitts (1943) e representado na Figura (2). O conjunto de zeros do erro de aprendizagem é considerado como uma superfície de deslizamento no espaço dos parâmetros de aprendizagem e uma trajetória da superfície de deslizamento pode então ser alcançada em tempo finito.

Considera-se agora o modelo de um perceptron da Figura (2), sendo utilizado em uma aplicação contínua no tempo, como representado na Figura (18).

Figura 18 - Estrutura de um neurônio Adaline contínuo no tempo.



Fonte: Sira-Ramírez e Colina-Morles (1995).

O vetor do padrão de entrada, sem a entrada do peso bias, é dado por

$$x(t) = [x_1(t), \dots, x_n(t)]^T,$$

assumindo também que,

$$\begin{aligned} \|x(t)\| &= \sqrt{x_1^2(t) + \dots + x_n^2(t)} \leq V_x, \quad \forall t, \\ \|\dot{x}(t)\| &= \sqrt{\dot{x}_1^2(t) + \dots + \dot{x}_n^2(t)} \leq V_{\dot{x}}, \quad \forall t, \end{aligned} \quad (3)$$

tal que, V_x e $V_{\dot{x}}$ são constantes positivas conhecidas.

O vetor de entrada “aumentado”, que inclui a entrada constante $x_0 > 1$, relativo ao peso bias, $w_0(t)$ fica,

$$\tilde{x}(t) = [x_1(t), \dots, x_n(t), x_0]^T = [x(t), x_0]^T. \quad (4)$$

Nota 1. O produto escalar $\tilde{x}^T(t)\tilde{x}(t) = x_0^2 + x^T(t)x(t) = x_0^2 + \|x(t)\|^2$ é limitado para todo t .

O vetor $w(t) = [w_1(t), \dots, w_n(t)]^T$ representa o conjunto dos pesos variando com o tempo e assume-se que a magnitude do vetor $w(t)$ é limitada, $\|w(t)\| \leq W, \forall t$, para alguma constante W .

Definição 2.1. O vetor peso “aumentado” é definido pela inclusão do peso bias:

$$\begin{aligned} \tilde{w}(t) &= [w_1(t), \dots, w_n(t), w_0(t)]^T, \\ &= [w(t), w_0(t)]^T. \end{aligned} \quad (5)$$

Analogamente, $\tilde{w}(t)$ é assumido limitado para cada t , isto é,

$$\|\tilde{w}(t)\| = \sqrt{w_1^2(t) + \dots + w_n^2(t) + w_0^2(t)} \leq \tilde{W}, \forall t, \quad (6)$$

para alguma constante \tilde{W} .

Seja $y_d(t)$ a saída desejada variando com t . Assume-se que

$$\begin{aligned} \|y_d(t)\| &\leq V_y, \forall t, \\ \|\dot{y}_d(t)\| &\leq V_{\dot{y}}, \forall t. \end{aligned} \quad (7)$$

O sinal de saída $y'_d(t)$ é um escalar definido como:

$$\begin{aligned} y'_d(t) &= \sum_{i=1}^n w_i(t)x_i(t) + w_0(t)x_0, \\ &= w^T(t)x(t) + w_0(t)x_0 = \tilde{w}^T(t)\tilde{x}(t). \end{aligned} \quad (8)$$

Com isso, define-se o erro de aprendizado $e(t)$ como o escalar

$$e(t) = y'_d(t) - y_d(t). \quad (9)$$

2.2.2 Formulação do problema

Usando a teoria de controladores com estrutura variável e modos deslizantes, considera-se o valor nulo do erro de aprendizagem $e(t)$ como sendo uma superfície de deslizamento variando no tempo (SIRA-RAMÍREZ; COLINA-MORLES, 1995),

$$S(e(t)) = e(t) = 0. \quad (10)$$

A condição apresentada na Equação (10) garante que a saída do perceptron, $y'_d(t)$ coincide com o sinal de saída desejado, $y_d(t)$, para todo tempo $t > t_h$, tal que t_h é o tempo de entrada em deslizamento.

Definição 2.2. Um movimento deslizante é dito existir numa superfície de deslizamento se $S(e(t)) = e(t) = 0$, depois de um tempo t_h , se a condição $S(t)\dot{S}(t) = e(t)\dot{e}(t) < 0$ é satisfeita para todo t em algum intervalo semi-aberto não trivial da forma $[t, t_h) \subset (-\infty, t_h)$ (SIRA-RAMÍREZ; COLINA-MORLES, 1995).

Sendo assim, deseja-se projetar uma lei adaptativa para o vetor “aumentado” da variável dos pesos $\tilde{w}(t)$, tal que a condição do modo deslizante da Definição (2.2) seja estabelecida.

2.2.3 Erro de aprendizado adaptativo nulo em tempo finito

Seja $\text{sign } e(t)$, a função sinal, definida por

$$\text{sign } e(t) = \begin{cases} 1 & \text{para } e(t) > 0 \\ 0 & \text{para } e(t) = 0 \\ -1 & \text{para } e(t) < 0 \end{cases}, \quad (11)$$

tem-se o seguinte teorema:

Teorema 1. Se a lei de adaptação para o vetor peso “aumentado” $\tilde{w}(t)$ é escolhida como,

$$\begin{aligned} \dot{\tilde{w}}(t) &= - \left(\frac{\tilde{x}(t)}{\tilde{x}^T(t)\tilde{x}(t)} \right) k_R \text{sign } e(t), \\ &= - \left(\frac{\begin{bmatrix} x(t) \\ x_0 \end{bmatrix}}{x_0^2 + x^T(t)x(t)} \right) k_R \text{sign } e(t), \end{aligned} \quad (12)$$

sendo que, k_R é uma constante suficientemente grande satisfazendo,

$$k_R > \tilde{W}V_{\tilde{x}} + V_{\tilde{y}}, \quad (13)$$

então, dado a condição inicial arbitrária $e(0)$, o erro de aprendizagem $e(t)$ converge para zero no tempo finito t_h estimado por

$$t_h \leq \frac{|e(0)|}{k_R - \tilde{W}V_{\dot{x}} - V_{\dot{y}}}, \quad (14)$$

e um movimento deslizando é mantido em $e = 0$ para todo $t > t_h$ (SIRA-RAMÍREZ; COLINA-MORLES, 1995).

Demonstração. A prova do teorema (1) está em Sira-Ramírez e Colina-Morles (1995). \square

Nota 2. Nota-se que a lei de adaptação dinâmica proposta para o vetor dos pesos em (12) resulta em uma evolução regulada e contínua do vetor de pesos variáveis $\tilde{w}(t)$. A estratégia descontínua (12) representa a solução para mínimos quadrados, com respeito a $\dot{\tilde{w}}(t)$ da seguinte equação variante no tempo,

$$\dot{\tilde{w}}^T(t) \tilde{x}(t) = -k_R \text{sign} [y'_d(t) - y_d(t)], \quad (15)$$

que produz a seguinte dinâmica para o sinal de saída do perceptron $y'_d(t)$,

$$\dot{y}'_d(t) = \tilde{w}^T(t) \dot{\tilde{x}}(t) - k_R \text{sign} [y'_d(t) - y_d(t)], \quad (16)$$

tal que, o sinal $\tilde{w}^T(t) \dot{\tilde{x}}(t)$ atua como um sinal de perturbação limitado.

Com o intuito de se obter um melhor projeto para a estratégia de adaptação de pesos dada em (12), obtendo-se menor valor para k_R , considera-se que $\dot{\tilde{x}}(t)$ é mensurável. Sendo assim, segue o seguinte teorema.

Teorema 2. Se a lei de adaptação para o vetor peso aumentado $\tilde{w}(t)$ é escolhido como,

$$\dot{\tilde{w}}(t) = - \left(\frac{\tilde{x}(t) \dot{\tilde{x}}^T(t)}{\tilde{x}^T(t) \tilde{x}(t)} \right) \tilde{w}(t) - \left(\frac{\tilde{x}(t)}{\tilde{x}^T(t) \tilde{x}(t)} \right) k_R \text{sign} e(t), \quad (17)$$

com k_R sendo uma constante positiva satisfazendo $k_R > V_{\dot{y}}$, então dada uma condição inicial arbitrária $e(0)$, o erro de aprendizagem $e(t)$ converge para zero no tempo finito t_h satisfazendo,

$$t_h \leq \frac{|e(0)|}{k_R - V_{\dot{y}}}, \quad (18)$$

e um movimento deslizando é mantido em $e = 0$ para todo $t > t_h$ (SIRA-RAMÍREZ; COLINA-MORLES, 1995).

Demonstração. A prova do teorema (2) está em Sira-Ramírez e Colina-Morles (1995). \square

Nota 3. Como antes, a lei de adaptação da dinâmica proposta para o vetor dos pesos em (17) resulta em uma evolução contínua dos pesos. Tal lei representa uma solução por mínimo quadrado, com respeito a $\dot{\tilde{w}}(t)$ da seguinte equação linear variante no tempo.

$$\begin{aligned} \dot{y}'_d(t) &= \dot{\tilde{w}}^T(t) \tilde{x}(t) + \tilde{w}^T(t) \dot{\tilde{x}}(t), \\ &= -k_R \text{sign} [y'_d(t) - y_d(t)] . \end{aligned} \tag{19}$$

2.3 CONCLUSÕES PARCIAIS

Neste capítulo apresentaram-se os fundamentos relacionados às redes neurais artificiais, os quais elucidam o seu emprego em problemas de alta complexidade. Trata-se de uma ferramenta robusta devida a sua capacidade de generalização, alto nível de confiabilidade e rapidez de diagnóstico.

Dentro desta perspectiva, foi apresentada uma teoria de adaptação de pesos em redes Adaline, utilizando um controlador com Estrutura Variável e Modos Deslizantes. Essa estratégia garante que o deslizamento ocorra em um tempo finito e após isto, a rede passa a gerar sinais de saída muito próximos dos desejados.

3 ESTRATÉGIA DE CONTROLE RASTREADORA DE SINAIS EM PLANTAS UTILIZANDO RNA E CEV-RNA

O algoritmo de pesos de redes Adaline proposto por Sira-Ramírez e Colina-Morles (1995) foi utilizado em seu trabalho com a finalidade de apenas identificar saídas mensuráveis de plantas desconhecidas, não havendo nenhuma interferência na estratégia de controle. Sendo assim, Sira-Ramírez e Colina-Morles (1995) realizaram testes, analisando o desempenho da rede neural em reproduzir sinais de saída de plantas desconhecidas, verificando assim, o desempenho da RNA com CEV-RNA.

Neste trabalho, a RNA com ajuste de pesos via CEV-RNA é alocada de forma a atuar no controle de diversos sistemas, ora sendo utilizada apenas a RNA com o CEV-RNA na malha direta de controle, ora a RNA com o CEV-RNA auxiliando um controlador já existente.

RNA com adaptação de pesos via CEV-RNA mostra-se uma solução promissora no controle de sistemas. Uma dificuldade, porém, em utilizar esse tipo de solução, está na obtenção de provas, de forma a garantir, em quais tipos de sistemas a rede realmente é capaz controlar, calculando sinais de controle com valores aceitáveis, isto é, valores não elevados, caso contrário, demandaria uma grande quantidade de energia e esforços, dificultando aplicações reais.

Sendo assim, neste capítulo analisa-se a eficiência dessa ferramenta, sendo utilizada como controlador em malha fechada, rastreando sinais desejados. Resultados de simulações computacionais realizadas em uma série de sistemas, principalmente lineares, de 1^a, 2^a e 3^a ordem são apresentados. Também são analisados resultados de simulações, as quais, apresentam duas malhas de controle, uma formada por um controlador Proporcional, Integral e Derivativo (PID) e a outra malha de controle, formada por uma RNA com adaptação de pesos via CEV-RNA.

3.1 ANÁLISE DA EFICIÊNCIA DE CONTROLE VIA RNA EM SISTEMAS LINEARES

Neste item, uma grande gama de testes e simulações são realizados considerando a estrutura neural proposta por Sira-Ramírez e Colina-Morles (1995), alocada de forma a se ter um sistema em malha fechada como representado na Figura (19).

Todos os resultados das simulações computacionais realizadas nesta tese são obtidas por meio do *software* MATLAB/SIMULINK®.

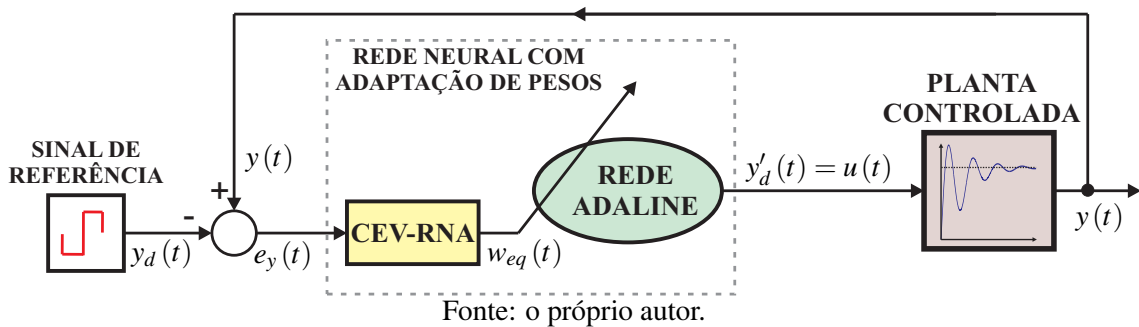
A lei de adaptação dos pesos da rede Adaline, considerada nestas simulações, é a apresentada na Equação (17).

No intuito de amenizar os problemas causados pela trepidação na superfície de deslizamento, $k_R \text{sign } e(t)$ é substituído por $k_R \frac{e(t)}{|e(t)| + \delta_R}$, sendo assim, a lei de adaptação de pesos equivalente fica

$$\dot{w}_{eq}(t) = - \left(\frac{\tilde{x}(t) \dot{\tilde{x}}^T(t)}{\tilde{x}^T(t) \tilde{x}(t)} \right) \tilde{w}(t) - \left(\frac{\tilde{x}(t)}{\tilde{x}^T(t) \tilde{x}(t)} \right) k_R \frac{e(t)}{|e(t)| + \delta_R}, \quad (20)$$

tal que, δ_R é uma constante positiva de projeto com valores reduzidos (SIRA-RAMÍREZ; COLINA-MORLES, 1995).

Figura 19 - Estratégia de controle por RNA com adaptação de pesos via CEV-RNA em sistemas desconhecidos.



A saída $y(t)$ da planta a ser controlada é comparada com o sinal de referência $y_d(t)$, que por sua vez alimenta a estrutura neural. A RNA está inserida na malha direta, de forma que sua saída $y'_d(t)$ passa a ser o sinal de controle $u(t)$ entregue a planta. Sendo assim, o objetivo de controle é fazer com que a planta siga o sinal de referência, minimizando o erro $e_y(t)$.

A rede neural é estimulada pelo vetor do padrão de entrada, que pode ser formado por um filtro passa-baixas, dado pelas seguintes equações (SIRA-RAMÍREZ; COLINA-MORLES, 1995),

$$\dot{x}_1(t) = 0,$$

$$\dot{x}_2(t) = x_3(t),$$

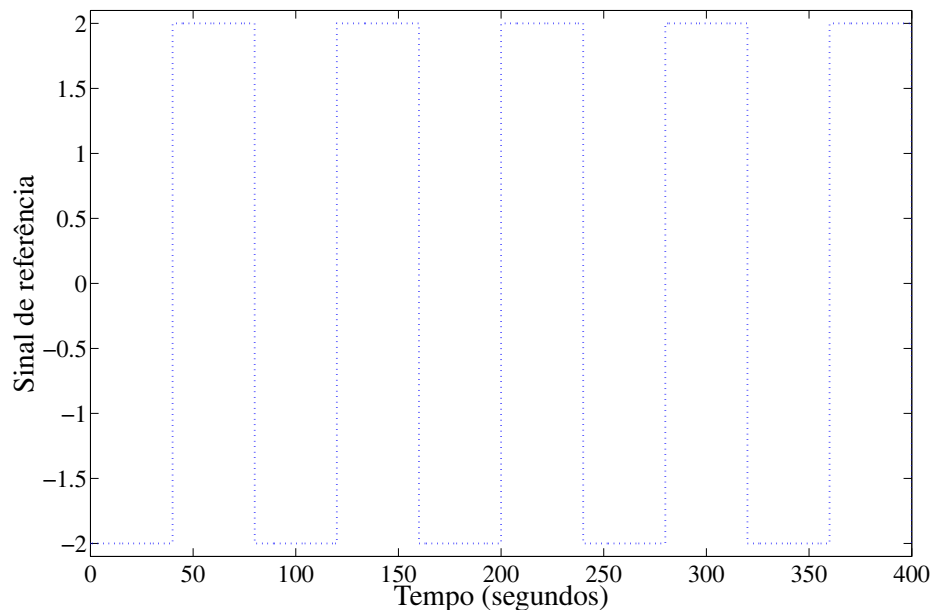
$$\dot{x}_3(t) = x_4(t),$$

$$\dot{x}_4(t) = -x_2(t) - 3x_3(t) - 3x_4(t) - u(t).$$

Os sistemas desconhecidos pela rede, aqui considerados, são Lineares e Invariantes no Tempo (SLIT) de 1ª, 2ª e 3ª ordem. O sinal de referência utilizado nas simulações é o sinal de onda quadrada dado na Figura (20).

Cada simulação é realizada por um período de 400 segundos desde que, o sistema não atinja um Índice de Desempenho (ID) máximo (definido em (21)) igual a 400. Caso isso ocorra,

Figura 20 - Sinal de referência para análise de desempenho em sistema de 1ª, 2ª e 3ª ordem.



Fonte: o próprio autor.

a simulação é automaticamente abortada e segue-se para a próxima simulação. O ID é calculado pelo método da integral do valor absoluto do erro (IAE - *Integral of the Absolute magnitude of the Error*) dado por,

$$ID = \int |y(t) - y_d(t)| dt . \quad (21)$$

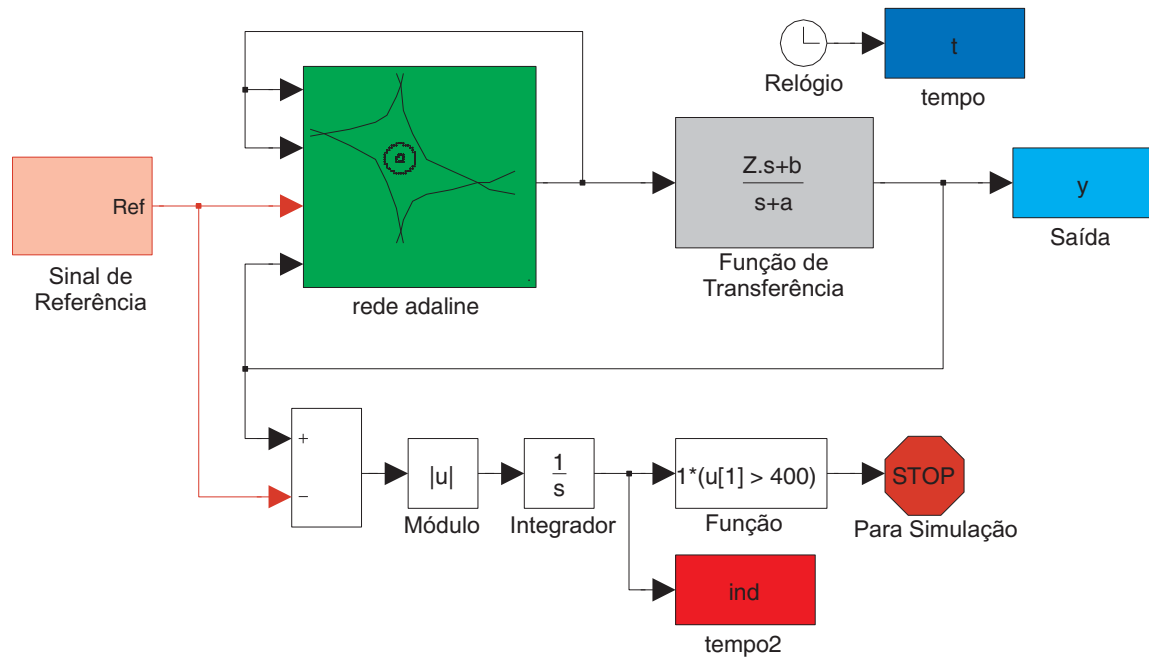
A implementação da estrutura de controle no *software* MATLAB/SIMULINK[®] está representada na Figura (21).

Os ID são gerados partindo de um sistema principal e comparado com outros sistemas derivados dele, fazendo-se pequenas alterações dos polos e zeros. Considerando o sistema descrito na Figura (21), vários valores numéricos podem ser atribuídos às constantes Z , a e b , alterando-se o sistema. Os polos e zeros são trocados numa faixa de valores positivos e negativos, sendo assim, vários ID são obtidos, um para cada sistema. Os ID gerados dos sistemas derivados do principal são plotados em gráficos em três dimensões (3D), de modo a se verificar em quais tipos de sistemas a estrutura neural é capaz de atuar de forma eficaz como controlador.

3.1.1 Sistemas lineares de 1ª ordem

O primeiro sistema implementado e submetido a testes é de 1ª ordem e sua Função de Transferência (FT) é dada pela seguinte equação,

Figura 21 - Implementação da estratégia controle por RNA em sistemas desconhecidos.



Fonte: o próprio autor.

$$G(s) = \frac{Zs + b}{s + a} . \quad (22)$$

Para este sistema principal dois casos foram considerados:

- No primeiro, a constante Z ficou igual a zero, sendo assim, o sistema, neste caso, passa a ter a seguinte FT,

$$G(s) = \frac{b}{s + a} . \quad (23)$$

Nas simulações realizadas neste caso, considera-se que os sistemas dados por (23) são gerados por meio da mudança das constantes a e b com um passo de 0,3 em 0,3, para cada uma delas. Estes passos foram escolhidos de modo a obter-se vários ID, melhorando a resolução do gráfico gerado. Foi imposto os seguintes limites para as constantes,

$$-0,8 \leq a \leq 1,0 \quad \text{e} \quad -0,8 \leq b \leq 1,0.$$


Sendo assim, vários sistemas com polos e zeros diferentes são obtidos e submetidos a simulações computacionais. Os resultados dos ID calculados para cada sistema são apresentados em um único gráfico.

Os dados do controlador CEV-RNA (Equação (20)) utilizado nestas simulações para adap-

tação dos pesos da RNA são, $k_R = 10$ e $\delta_R = 0,5$.

Na Figura (22), tem-se os resultados dos ID das simulações realizadas considerando o primeiro caso, com os subsistemas gerados a partir da Equação (23), implementados como na estrutura da Figura (19).

Figura 22 - Índices de desempenho para sistemas de 1ª ordem: primeiro caso.



Fonte: o próprio autor.

A interpretação dos gráficos é a seguinte: Quando os valores do ID são pequenos, significa que a rede é capaz de estabilizar o sistema com eficácia, indicando que a saída do sistema segue o sinal de referência; quando os valores do ID chegam próximos de 400, as simulações são abortadas, indicando que a rede é ineficiente, tal que, em alguns casos, existem grandes discrepâncias entre os sinais comparados, e em outros casos, a RNA não provê estabilidade ao sistema em malha fechada.

Pelos resultados, verifica-se que quando a e b apresentam valores positivos, a rede desempenha um controle eficaz dos sistemas, uma vez que, os polos e zeros dos sistemas são negativos. No entanto, quando os sistemas passam a apresentar um polo positivo, a RNA com CEV-RNA não é capaz de desempenhar um bom controle sobre os sistemas.

- No segundo caso para o sistema de primeira ordem (22), atribui-se Z igual a um, sendo assim, a FT principal passa para

$$G(s) = \frac{s+b}{s+a}, \quad \text{com } a \neq b. \quad (24)$$

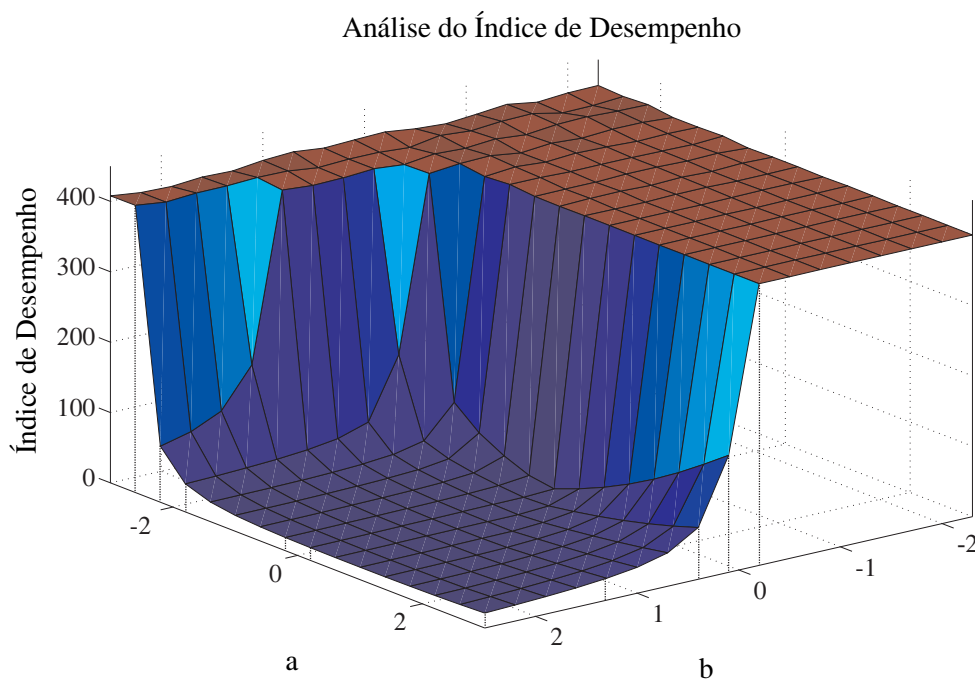
Nas simulações realizadas, as constantes a e b sofrem variações entre

$$-3,0 \leq a \leq 3,0 \quad \text{e} \quad -2,3 \leq b \leq 2,5,$$

mantendo os ganhos do controlador, k_R e δ_R , iguais os do primeiro caso.

Os resultados para o segundo caso são apresentados na Figura (23) que, por sinal, são parecidos com os do primeiro caso. Contudo, a rede conseguiu boa estabilização de alguns sistemas que apresentam valores de a negativos, isto é, sistemas que contêm valores de polos positivos, desde que, os zeros sejam negativos.

Figura 23 - Índices de desempenho para sistemas de 1ª ordem: segundo caso.



Fonte: o próprio autor.

Pelos resultados apresentados até agora, verifica-se que a rede se mostra mais eficaz quando aplicada em sistemas estáveis em malha aberta, todavia, sua utilização em sistemas naturalmente instáveis, poucos sistemas são estabilizados, tal que, a maioria não apresenta resultados satisfatórios.

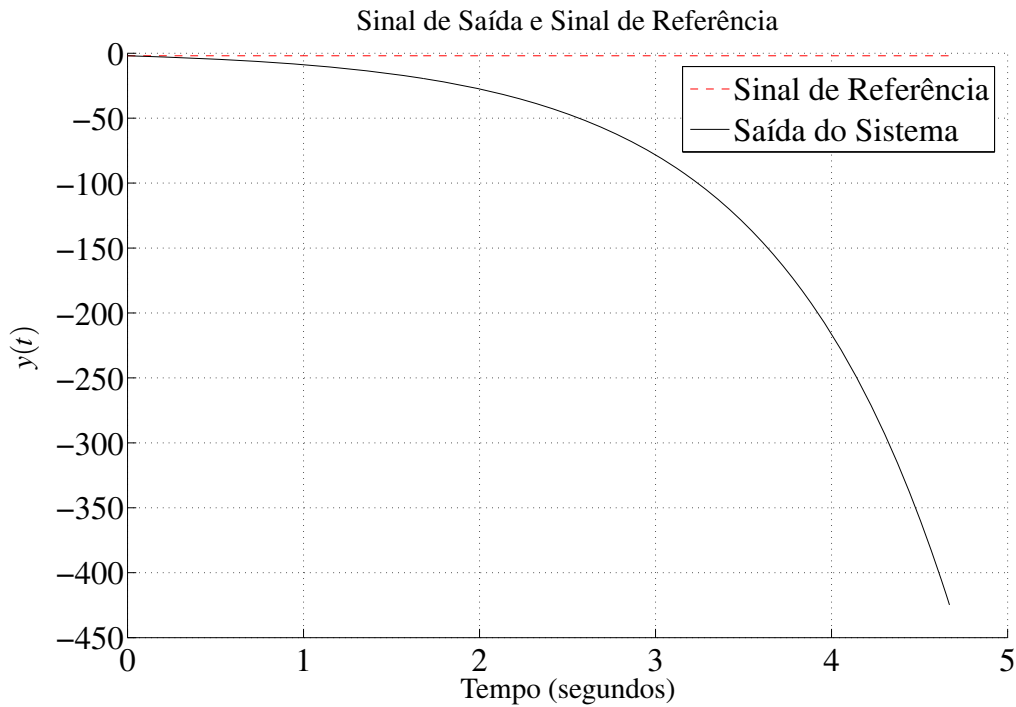
Duas simulação com resultado no tempo são realizadas considerando um sistema de fase não mínima, ora sem malha de realimentação, ora com realimentação e sinal de controle ajustado pela RNA. O sistema naturalmente instável é obtido a partir do sistema da Equação (24), atribuindo os seguintes valores, $a = -1$ e $b = 1$, passando a ser,

$$G(s) = \frac{s+1}{s-1}, \quad (25)$$

sendo assim, o sistema apresenta um polo positivo e um zero negativo em malha aberta.

O resultado da simulação considerando o sistema da Equação (25) em malha aberta sem controlador e sinal de referência representado na Figura (20) é dado na Figura (24).

Figura 24 - Sinal de referência e sinal de saída do sistema (25) em malha aberta sem controlador.



Fonte: o próprio autor.

Como esperado, o sistema em malha aberta é instável e a simulação é abortada, uma vez que o sistema apresenta forte divergência em relação ao sinal de referência.

Na Figura (25) é apresentado o resultado da simulação do sistema (25) considerando o esquema descrito na Figura (19). Neste caso, o fato de realimentar o sistema e ajuste do sinal de controle pela RNA fazem o sistema seguir com certa precisão o sinal desejado, indicando um bom desempenho da estratégia de controle, o que resulta em um ID pequeno.


3.1.2 Sistemas lineares de 2ª ordem

As próximas simulações são baseadas em um sistema de 2ª ordem, dado por

$$G(s) = \frac{Zs + C}{s^2 + as + b}. \quad (26)$$

A estrutura de controle utilizada nos sistemas de 2ª ordem é a mesma apresentada na Figura

Figura 25 - Sinal de referência e sinal de saída do sistema (25) em malha fechada com controlador via RNA.



(19) e durante as simulações são consideradas as mesmas condições de operação que os sistemas de 1ª ordem são submetidos.

Para este sistema, quatro casos principais de mudanças de polos e zeros são realizados:

- O primeiro caso é implementado com os parâmetros constantes $Z = 1$, $b = 1$, variando-se apenas C e a , com os limites

$$-1,0 \leq C \leq 1,0 \quad \text{e} \quad -3,0 \leq a \leq 3,0.$$


Sendo assim, a FT do sistema dado pela Equação (26) passa a ser

$$G(s) = \frac{s + C}{s^2 + as + 1}. \quad (27)$$

As simulações com os sistemas dados por (27) são realizadas com os seguintes parâmetros do controlador, $k_R = 10$ e $\delta_R = 0,5$.

Na Figura (26) são mostrados os resultados obtidos nas simulações. Assim, como nos sistemas de 1ª ordem, verifica-se que com valores positivos para as constantes C e a , a rede tem facilidade em controlá-los, já que são naturalmente estáveis. Fato que não ocorre em sistemas de fase não mínima, isto é, sistemas com polos ou zeros positivos.

Figura 26 - Índices de desempenho para sistemas de 2ª ordem: primeiro caso.



- No segundo caso, as constantes foram escolhidas como $Z = 1$, $a = 1$ e

$$-1,0 \leq C \leq 1,0 \quad \text{e} \quad -3,0 \leq b \leq 3,0.$$

Com isso, o sistema principal fica

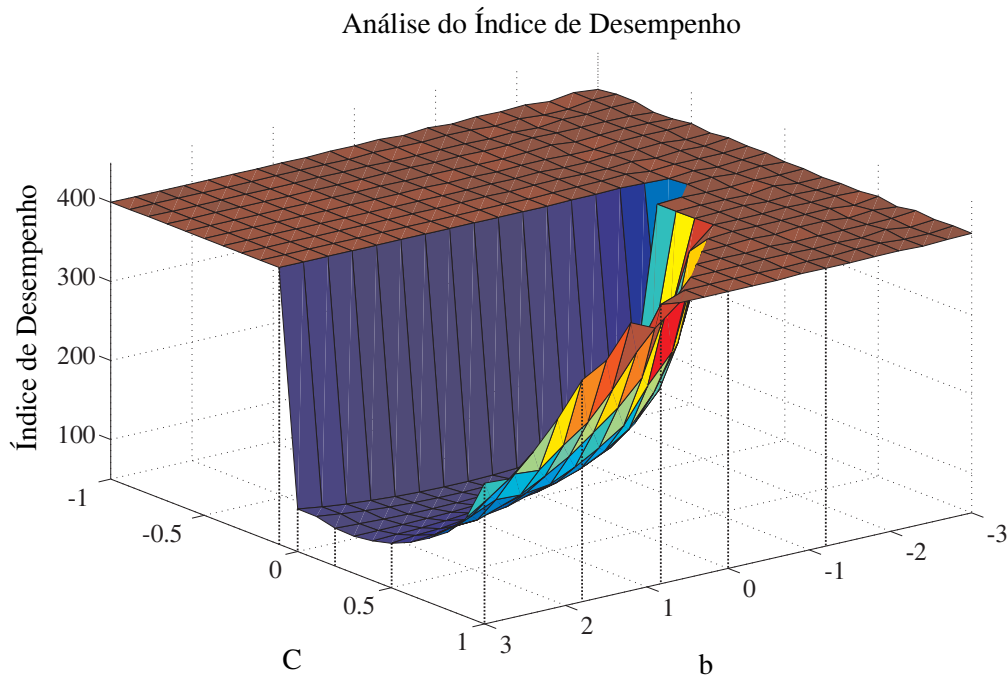
$$G(s) = \frac{s + C}{s^2 + s + b}. \quad (28)$$

Os ganhos do controlador são os mesmos do primeiro caso, $k_R = 10$ e $\delta_R = 0,5$. Os resultados para este segundo caso são apresentados na Figura (27). Os ID são parecidos com os do primeiro caso, sendo que a rede estabiliza sistemas contendo polos e zeros negativos com certa precisão. No entanto, a RNA começa a apresentar bons desempenhos em alguns sistemas com fase não mínima, formados por apenas polos positivos, nunca em sistemas com zeros positivos. Característica interessante e também observada nos dois casos analisados para os sistemas de 1ª ordem, tal que a rede não consegue fazer sistemas com zeros positivos rastrear sinais de referência corretamente.

- Já no terceiro caso, os parâmetros constantes do sistema (26) foram $Z = 0$, $C = 1$ e

$$-3,0 \leq a \leq 3,0 \quad \text{e} \quad -3,0 \leq b \leq 3,0.$$

Figura 27 - Índices de desempenho para sistemas de 2ª ordem: segundo caso.



Com estas alterações o sistema fica

$$G(s) = \frac{1}{s^2 + as + b}. \quad (29)$$

Os resultados para este caso são apresentados na Figura (28), sendo que os parâmetros do controlador foram $k_R = 1$ e $\delta_R = 0,5$. Verifica-se que, com esta estrutura de controle, os sistemas de fase mínima, isto é, sistemas com polos e zeros negativos, obtiveram as melhores respostas em relação ao sinal de referência.

- No último caso, escolheram-se as constantes do sistema (26), por $Z = 1$, $C = 0$ e

$$-0,8 \leq a \leq 1,0 \quad \text{e} \quad -3,0 \leq b \leq 3,0.$$


Assim, o sistema principal passa a ser

$$G(s) = \frac{s}{s^2 + as + b}, \quad (30)$$

tal que, comparando com o sistema principal do caso anterior, Equação (29), verifica-se que a substituição da constante $Z = 0$ para $Z = 1$ altera os zeros do sistema.

Os dados do CEV-RNA foram $k_R = 10$ e $\delta_R = 0,5$ e os resultados apresentados na Fi-

Figura 28 - Índices de desempenho para sistemas de 2ª ordem: terceiro caso.



gura (29). Analisando estes resultados em relação aos do caso anterior, verifica-se que o fato de acrescentar zeros negativos, melhora a resposta dos sistemas controlados. Bons resultados podem ser notados até em alguns sistemas que apresentam polos positivos, mostrando que a RNA é eficaz em controlar algumas classes de sistemas de fase não mínima, característica não observada nos subsistemas do caso anterior.

3.1.3 Sistemas lineares de 3ª ordem

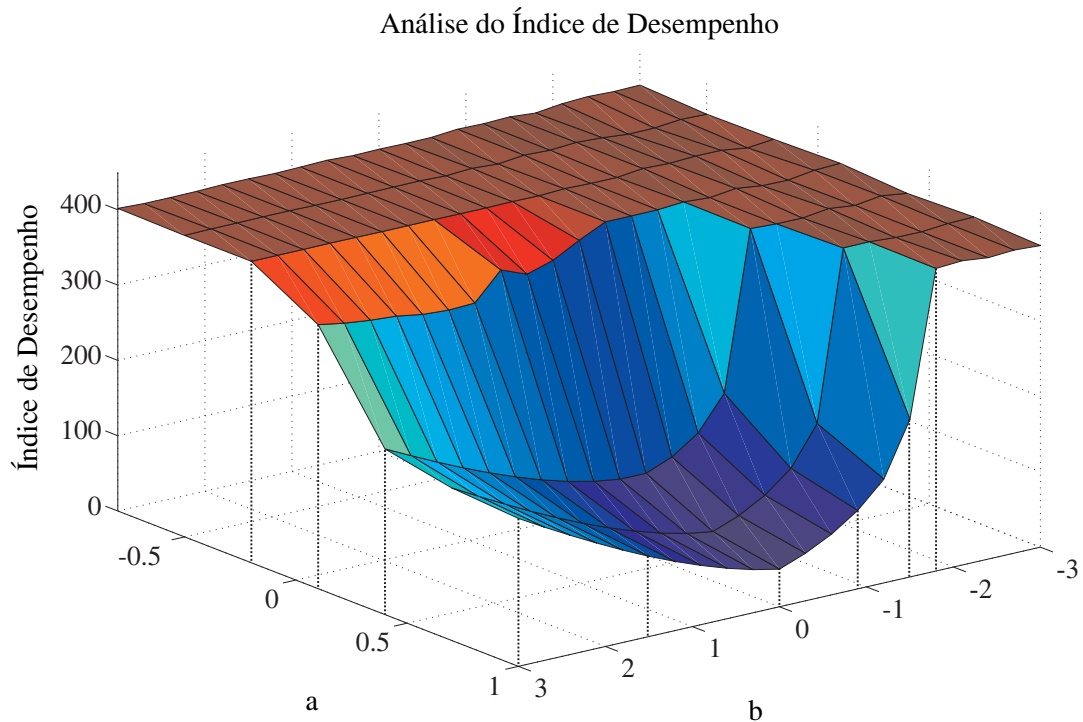
Nesta etapa, as análises dos ID de sistemas controlados via RNA são para sistemas de 3ª ordem.

Os vários subsistemas submetidos a testes de desempenho derivam-se do seguinte sistema

$$G(s) = \frac{(s + z_1)(s + z_2) + C}{(s + p_1)(s + p_2)(s + p_3)}. \quad (31)$$

As simulações são realizadas considerando a estratégia de controle e as condições operacionais dos casos anteriores. Inicialmente três casos são testados, sendo que, em cada caso, fixam-se zeros em posições diferentes e apenas os polos foram descolados passo a passo. Sendo assim:

Figura 29 - Índices de desempenho para sistemas de 2ª ordem: quarto caso.



• No primeiro caso implementado para o sistema de 3ª ordem, Equação (31), escolhem-se as constantes da planta como, $z_1 = z_2 = -s$, $C = 1$, $p_3 = 1$ e

$$-3,0 \leq p_2 \leq 3,0 \quad \text{e} \quad -3,0 \leq p_1 \leq 3,0.$$

Por meio destas considerações, o sistema passa a ser


$$G(s) = \frac{1}{(s+p_1)(s+p_2)(s+1)}. \quad (32)$$

Os parâmetros do controlador são ajustados segundo, $k_R = 7$ e $\delta_R = 0,5$. Os resultados das simulações estão na Figura (30), na qual pode-se verificar que para sistemas sem zeros a RNA mostra-se ineficiente e a maioria dos sistemas apresentam valores elevados de ID, indicando que poucos seguiram corretamente o sinal desejado.

• O segundo caso é realizado para a Equação (31), com as constantes escolhidas por $z_1 = 1$, $z_2 = -s$, $C = 0$, $p_3 = 4$ e

$$-3,0 \leq p_2 \leq 3,0 \quad \text{e} \quad -3,0 \leq p_1 \leq 3,0.$$

Figura 30 - Índices de desempenho para sistemas de 3ª ordem: primeiro caso.



Fonte: o próprio autor.

Assim, o sistema principal é dado por

$$G(s) = \frac{(s+1)}{(s+p_1)(s+p_2)(s+4)}. \quad (33)$$

Os resultados dos ID são apresentados na Figura (31) com os parâmetros do controlador $k_R = 20$ e $\delta_R = 0,5$. Pode ser visto que devido ao acréscimo de um zero negativo nos subsistemas, aumenta a quantidade de plantas de fase não mínima que a rede é eficiente em controlar, mantendo-as sob o sinal de referência com certa precisão.


• Para o terceiro caso, os parâmetros constantes são escolhidos segundo $z_1 = 1$, $z_2 = 5$, $C = 0$, $p_3 = 4$ e,

$$-3,0 \leq p_2 \leq 3,0 \quad \text{e} \quad -3,0 \leq p_1 \leq 3,0.$$

Com estes valores, a FT do sistema principal torna-se

$$G(s) = \frac{(s+1)(s+5)}{(s+p_1)(s+p_2)(s+4)}. \quad (34)$$

Figura 31 - Índices de desempenho para sistemas de 3ª ordem: segundo caso.



Os resultados para sistemas de 3ª ordem do terceiro caso são apresentados na Figura (32). Os parâmetros do controlador utilizado para adaptar os pesos da rede Adaline são escolhidos como $k_R = 7$ e $\delta_R = 0,5$. Pode ser visto que, para os sistemas apresentando zeros e polos negativos, a RNA consegue manter suas respostas próximas do sinal desejado. Em alguns casos em que os polos estão próximos de zero, e até mesmo positivos, a rede consegue estabilizá-los, apresentando valores de ID reduzidos, porém, nunca estabiliza sistemas que apresentam zeros positivos.


Antes de avançar para novos casos utilizando sistemas de 3ª ordem, dois gráficos são apresentados contendo resultados de simulação com resposta no tempo, para um dos vários sistemas testados no terceiro caso, tal que, $p_1 = 3$ e $p_2 = 1$, sendo assim, o sistema (34) fica

$$G(s) = \frac{(s+1)(s+5)}{(s+3)(s+1)(s+4)}. \quad (35)$$

Na Figura (33) tem-se os resultados referentes ao sinal de referência e os sinais de saída do sistema obtidos por meio de duas simulações. A primeira simulação é realizada considerando o sistema em malha fechada sem o controle da rede, com apenas ganho unitário. Na segunda simulação, o sistema é controlado pela RNA via CEV-RNA.


Pelos resultados, verifica-se que o sistema sendo controlado pela estratégia neural apre-

Figura 32 - Índices de desempenho para sistemas de 3ª ordem: terceiro caso.



Fonte: o próprio autor.

Figura 33 - Sinal de referência e sinais de saída do sistema (35) em malha fechada sem controlador e com controle via RNA.




Fonte: o próprio autor.

senda bom desempenho, rastreando o sinal de referência, sendo que, pequenos *overshoots* são encontrados durante as trocas de posição do sinal desejado. No caso em que há apenas a malha de realimentação com ganho unitário, a planta é estável, porém, o sinal de saída da planta não busca o sinal de referência, o que apresentaria um ID elevado, se comparado com a simulação contendo a RNA.

Na Figura (34) pode-se verificar os sinais de controle que alimentam o sistema, respectivamente em cada simulação. O sinal de controle para a simulação do sistema sendo controlado com a rede, apresenta valores numéricos mais elevados quando comparados com o sinal de controle para a simulação sem controlador. Todavia, os valores numéricos não são exagerados, sendo assim, um sinal de controle aceitável.

Figura 34 - Sinais de controle do sistema (35) em malha fechada sem controlador e com controle via RNA.



Fonte: o próprio autor.

Pelos resultados temporais das duas simulações, pode ser visto que para um sistema estável, o qual não segue o sinal desejado, a RNA é capaz e melhorar seu desempenho, fazendo-o seguir com certa precisão o sinal de referência.

Após a apresentação desses resultados, três novos casos de análises de ID são realizados partido do sistema de 3ª ordem (31), considerando as mesmas condições dos casos anteriores:

- O quarto caso é realizado considerando as seguintes constantes, $z_1 = 1$, $C = 0$, $p_2 = 5$, $p_3 = 6$ e

$$-0,8 \leq z_2 \leq 1,0 \quad \text{e} \quad -3,0 \leq p_1 \leq 3,0,$$


alterando o sistema principal para

$$G(s) = \frac{(s+1)(s+z_2)}{(s+p_1)(s+5)(s+6)}. \quad (36)$$

Neste caso, tem-se vários sistemas com diferentes valores de zeros e polos, o que não ocorreu nos três primeiros casos, em que, o zeros tinham valores fixos e a mudança ocorria apenas nos polos.

Os parâmetros do controlador para este caso são $k_R = 7$ e $\delta_R = 0,5$. Os ID destas simulações estão presentes na Figura (35) e verifica-se que a rede consegue controlar vários sistemas de fase mínima, apresentando bons resultados. Quando as constantes z_2 e p_1 estão próximas de valores negativos, a rede não é capaz de prover um controle eficiente a estes sistemas.

Figura 35 - Índices de desempenho para sistemas de 3ª ordem: quarto caso.



Fonte: o próprio autor.

• O caso 5 é obtido modificando o sistema principal dado em (31) com as seguintes constantes, $z_1 = 0$, $z_2 = -s$, $C = 0$, $p_3 = 6$, e,

$$-3,0 \leq p_2 \leq 3,0 \quad \text{e} \quad -3,0 \leq p_1 \leq 3,0,$$


ficando

$$G(s) = \frac{s}{(s+p_1)(s+p_2)(s+6)} \quad (37)$$

Na Figura (36) encontram-se os resultados dos ID para este quinto caso, sendo os dados do controlador $k_R = 90$ e $\delta_R = 0,5$.

Figura 36 - Índices de desempenho para sistemas de 3ª ordem: quinto caso.

Análise do Índice de Desempenho



Fonte: o próprio autor.

Neste caso, com sistemas apresentando zeros fixos, mais uma vez os sistemas de fase mínima apresentam boas respostas face ao sinal de referência em que foram submetidos. Em alguns sistemas, com os polos próximos de zero ou até mesmo positivos, apresentam respostas satisfatórias, não chegando ao limite estipulado para o ID.

- Para o último caso analisado, considera-se que, $z_1 = 0$, $z_2 = 0$, $C = 0$, $p_3 = 6$, e

$$-3,0 \leq p_2 \leq 3,0 \quad \text{e} \quad -3,0 \leq p_1 \leq 3,0.$$

Com isso, FT do sistema (31) fica

$$G(s) = \frac{(s)^2}{(s+p_1)(s+p_2)(s+6)} \quad (38)$$

Para este caso simulado, consideraram-se os ganhos do controlador, $k_R = 90$ e $\delta_R = 0,5$,

sendo que não foi possível encontrar estabilidade em nenhum dos subsistemas obtidos a partir do sistema (38). Este caso mostra a fragilidade deste método de controle em sistemas com zeros no semiplano positivo ou próximos dele.

3.2 ANÁLISE DA EFICIÊNCIA DE RNA EM SISTEMAS COM CONTROLADOR PID

Nesta seção analisa-se o comportamento de sistemas controlados via PID acrescidos da estrutura neural Adaline com adaptação de pesos CEV-RNA proposta por Sira-Ramírez e Colina-Morles (1995). Esta junção de controladores PID com RNA é aplicada tanto em sistemas lineares como em sistemas não-lineares.

Antes de iniciar estas análises, duas considerações são realizadas para o sistema descrito pela FT,

$$G(s) = \frac{(s-1)}{(s+1)(s+2)}, \quad (39)$$

aplicada à estrutura de controle dada na Figura (19).

Em um caso hipotético, a estrutura da rede neural é tida como se fosse um ganho $P(t)$, que, por simplicidade é analisado como um ganho proporcional P constante. Então, em malha fechada, tem-se

$$G_{MF}(s) = \frac{P(s-1)}{s^2 + (3+P)s + (2-P)}. \quad (40)$$

Segundo análise de controle clássico, basta $0 < P < 2$ para estabilizar o sistema, no entanto, haveria um erro estacionário em relação ao sinal de referência. Todavia, ao submeter este sistema a uma simulação computacional, utilizando a RNA normalmente como nos casos anteriores, verifica-se que a rede não é capaz de estabilizar o sistema. Mostra-se, assim, que a RNA não se comporta como uma constante direta na malha de controle.


A segunda consideração é em relação à dinâmica da rede e pode ser obtida por meio dos resultados apresentados na Figura (37), na qual, compara-se o sinal que alimenta a estrutura neural e a resposta que a rede apresenta. Assim, a rede é considerada dinâmica, uma vez que há defasagem entre o sinal de entrada com o sinal de saída.

Substituindo a FT do sistema (39) por

$$G(s) = \frac{(s+3)}{(s+1)(s+2)}, \quad (41)$$

a RNA passa a ser capaz de estabilizar o sistema, fazendo-o seguir corretamente a referência desejada, o que só seria possível se, no lugar da RNA, tivesse um ganho P muito elevado, o que forçaria o sinal de controle.

Figura 37 - Comparação entre o sinal de entrada e sinal de saída de uma RNA.



Fonte: o próprio autor.

Por meio de simulações, com resultados no tempo, demonstra-se esta situação supracitada. Os parâmetros do controlador CEV-RNA para este caso são ajustados por $k_R = 10$ e $\delta_R = 0,5$. Sendo assim, na Figura (38) encontram-se os resultados do sinal de referência, junto dos sinais de saída do sistema controlado via RNA e do sistema controlado via ganho proporcional P , alocado no lugar da RNA, fazendo parte da malha direta de controle.


O sinal de referência, para este caso específico, é uma onda quadrada, com período de 40 segundos, contendo a mesma amplitude do sinal utilizado nas simulações anteriores.

O controle utilizando apenas o ganho proporcional P só consegue fazer o sistema apresentar uma resposta a altura do sistema sendo controlado via RNA, por meio de um ganho $P = 100$. Este valor de ganho P mostra-se boa solução para o controle do sistema, todavia, ao analisar os sinais de controle para as duas simulações, dados na Figura (39), verifica-se que com o controle proporcional, o sinal de controle atinge valores elevados em certos momentos, o que não ocorre quando o controle é realizado via RNA.


3.2.1 Sistemas lineares de 1ª e 2ª ordem controlados por PID e RNA

Após estas análises, testa-se o desempenho da associação de RNA na malha direta de controle em sistemas lineares já controlados via PID. Sendo assim, uma nova estrutura de controle em malha fechada é proposta na Figura (40).

Nesta nova estratégia, tem-se duas malhas de controle, a primeira malha é formada pelo controlador PID convencional e a segunda malha, formada pela RNA. Por meio da comparação

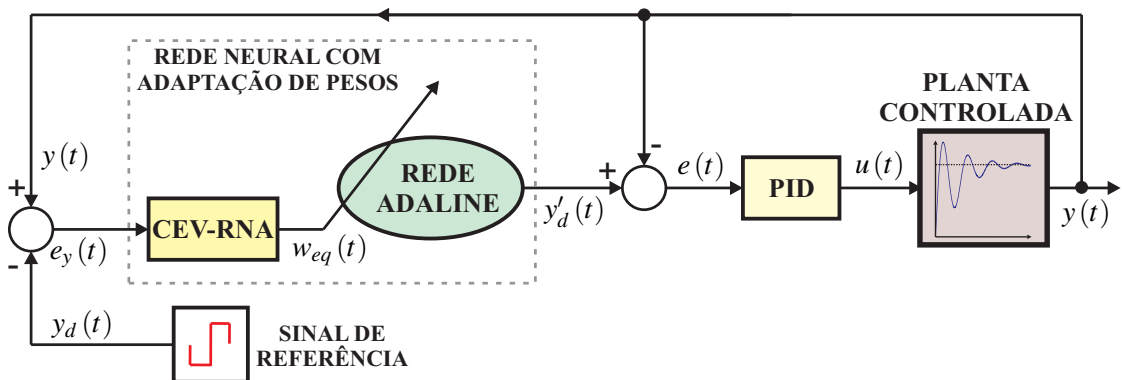
Figura 38 - Sinal de referência e sinais de saída do sistema com controlador P e com controle via RNA.

Fonte: o próprio autor.

Figura 39 - Sinais de saída com controlador P e com controle via RNA.

Fonte: o próprio autor.

Figura 40 - Estratégia de controle por RNA com adaptação de pesos via CEV-RNA e controle PID.

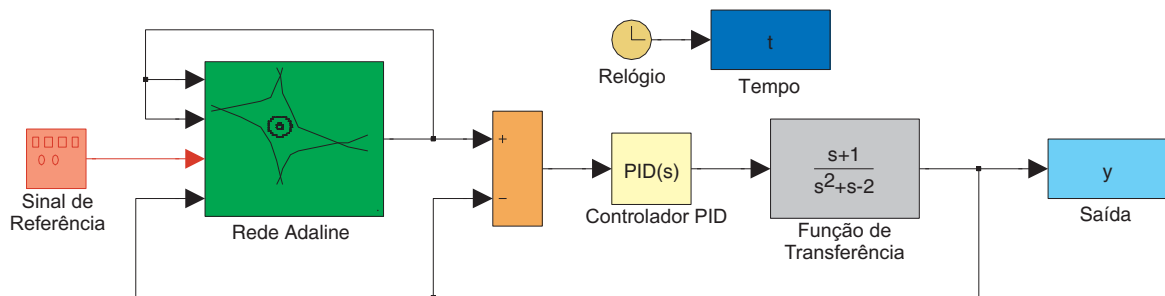


Fonte: o próprio autor.

do sinal de referência $y_d(t)$ com a saída da planta $y(t)$, tem-se o sinal de erro $e_y(t)$, que alimenta a RNA e assim, o novo sinal de referência $y'_d(t)$ é calculado. A comparação entre a saída da planta $y(t)$ e o sinal de referência $y'_d(t)$ fornece o erro $e(t)$, que alimenta o controlador PID.

A simulação computacional da estratégia de controle é dada na Figura (41), sendo possível verificar as duas malhas de controle propostas, gerando o sinal de controle para a planta.

Figura 41 - Simulação computacional da estratégia de controle via RNA e PID.



Fonte: o próprio autor.

Esta estratégia de controle é aplicada a quatro sistemas lineares, sendo dois de 1ª ordem e dois de 2ª ordem. Espera-se que nas simulações os sistemas sigam o mesmo sinal de referência utilizado nos casos anteriores, o sinal de onda quadrada dado na Figura (20).

Com isso, considera-se o sistema, $G(s) = \frac{(s-1)}{(s+1)(s+2)}$, que em malha fechada, sem a presença da malha de controle da RNA, é estável com apenas um controlador PID, dado por,

$$G_{MF}(s) = \frac{P(s-1)}{s^2 + (3+P)s + (P-2)}, \quad \text{com } 0 < 2 < P. \quad (42)$$

O fato de acrescentar a malha de controle com a RNA, como na Figura (40), faz com que o sistema se torne instável. Isto demonstra que, em casos em que existem zeros positivos, a rede

não é capaz de contribuir positivamente no controle de sistemas, mesmo com o auxílio de um controlador previamente projetado.

Por outro lado, para um sistema apresentando apenas zeros negativos como no sistema,

$$G(s) = \frac{(s+1)}{(s-1)(s+2)}, \quad (43)$$

e em malha fechada com apenas o controlador PID, tem-se

$$G(s) = \frac{P(s+1)}{s^2 + (1+P)s + (P-2)}, \quad \text{com } P > 2, \quad (44)$$

o acréscimo da RNA melhora o desempenho da planta.

Uma simulação é realizada utilizando a estrutura de controle (40) e, comparada com uma simulação utilizando apenas a malha de controle formada pelo controlador PID. Os parâmetros do controlador PID são $P = 10$, $I = 0$ e $D = 0$, sendo assim, utiliza-se somente o parâmetro de proporcionalidade. Já para o CEV-RNA, que adapta os pesos da RNA, os parâmetros são projetados segundo, $k_R = 10$ e $\delta_R = 0,5$.

A saída da planta controlada e o sinal de referência estão na Figura (42); os sinais de controle, na Figura (43). Analisando os resultados da saída do sistema, verifica-se que o controlador PID mantém a planta estável, contudo, não apresenta um bom desempenho ao seguir o sinal desejado. Todavia, com o acréscimo da malha de controle contendo a RNA, o problema da busca do sinal de referência é solucionado, melhorando consideravelmente a resposta do sistema.

Pontos positivos também são encontrados no sinal de controle aplicado no sistema com o acréscimo da estrutura neural, pois passam a apresentar valores reduzidos em relação ao sinal de controle com apenas o controlador PID, exigindo menos energia, além do sistema apresentar a resposta esperada.


O segundo sistema linear submetido a simulações considerando a estratégia de controle proposta em (40) é dado por

$$G(s) = \frac{1}{s-3}. \quad (45)$$

Este sistema é naturalmente instável e facilmente estabilizado com apenas a malha de controle com o PID.


Simulações testando o desempenho desta planta com apenas o controle PID e com o controlador PID mais RNA são realizadas e os resultados apresentados nas Figuras (44) e (45). Os controladores são ajustados com os seguintes parâmetros: $k_R = 10$, $\delta_R = 0,05$, $P = 10$, $I = 1$ e $D = 0$.

Figura 42 - Sinal de referência e sinais de saída com controlador PID e com controle via RNA mais PID: sistema (43).



Fonte: o próprio autor.


Figura 43 - Sinal de controle gerado pelo PID e sinal de controle gerado pela RNA mais PID: sistema (43).



Fonte: o próprio autor.

Na Figura (44), encontram-se o sinal de referência e os sinais de saída para cada estrutura de controle, respectivamente. A saída da planta, com apenas o controle PID, não segue o sinal de referência, enquanto que o mesmo controlador PID acrescido da malha de controle com a RNA mantém a saída da planta muito próxima do sinal desejado. É claro que um ajuste mais fino nos ganhos do controlador PID melhoraria o desempenho do sistema, contudo, optou-se em deixar um controlador não tão preciso, para assim, verificar se a rede era capaz de corrigir este problema.

Figura 44 - Sinal de referência e sinais de saída com controlador PID e com controle via RNA mais PID: sistema (45).



Fonte: o próprio autor.

Os sinais de controle são dados na Figura (45) e mais uma vez o acréscimo da RNA reduz o sinal de controle entregue à planta.


A FT da terceira planta linear é dada por,

$$G(s) = \frac{1}{s + 1/3} . \quad (46)$$

Assim como nos casos anteriores, duas simulações foram comparadas, uma contendo apenas a malha de controle com o PID e outra com a malha da RNA acrescentada (Figura (40)) e os parâmetros dos controladores são: $k_R = 10$, $\delta_R = 0,05$, $P = 10$, $I = 1$ e $D = 0$.


O sinal de saída da planta para as duas simulações e o sinal de referência são mostrados na Figura (46) e os sinais de controle na Figura (47). Mais uma vez, o fato de acrescentar a rede na estratégia de controle, mostra-se eficaz, uma vez que melhora a resposta da planta e o sinal de controle.

Figura 45 - Sinal de controle gerado pelo PID e sinal de controle gerado pela RNA mais PID: sistema (45).




Fonte: o próprio autor.

Figura 46 - Sinal de referência e sinais de saída com controlador PID e com controle via RNA mais PID: sistema (46).



Fonte: o próprio autor.

Figura 47 - Sinal de controle gerado pelo PID e sinal de controle gerado pela RNA mais PID: sistema (46).



Fonte: o próprio autor.

O sistema de 2ª ordem utilizado na estratégia de controle (40), é dado por

$$G(s) = \frac{1}{s^2 + 3s + 3} \quad (47)$$


Os resultados estão nas Figuras (48) e (49), nas quais os dados dos controladores CEV-RNA e PID são $k_R = 1$, $\delta_R = 0,5$, $P = 10$, $I = 1$ e $D = 0$.

O acréscimo da rede neural melhora a resposta do sistema, deixando o sinal de saída mais próximo do sinal de referência, além de amenizar os picos no sinal de controle calculados pelo PID.

3.2.2 Sistemas de 3ª ordem controlados por PID e RNA


Após as simulações computacionais realizadas em sistemas lineares de primeira e segunda ordem, testes são realizados em sistemas de terceira ordem, que podem apresentar ou não incertezas não-lineares. Todavia, a estrutura de controle proposta na Figura (40) é substituída por uma nova estrutura, Figura (50), em que, abre margem a uma gama grande de sistemas incertos, podendo ser lineares ou não-lineares.

Figura 48 - Sinal de referência e sinais de saída com controlador PID e com controle via RNA mais PID: sistema (47).



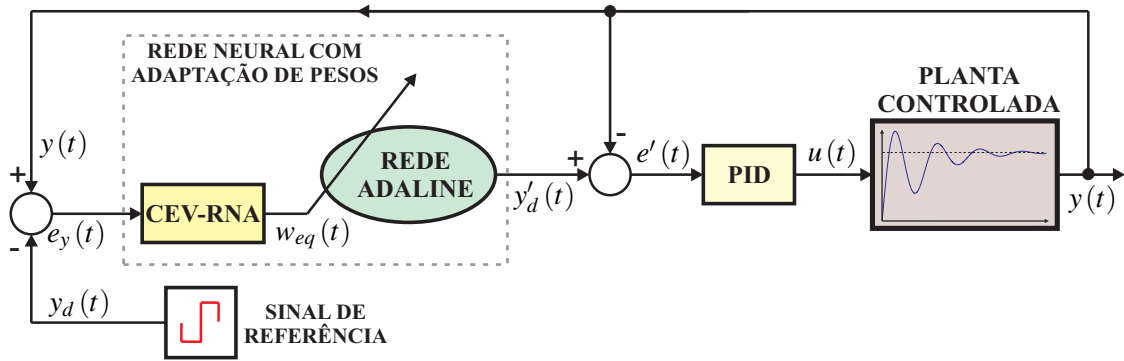
Fonte: o próprio autor.

Figura 49 - Sinal de controle gerado pelo PID e sinal de controle gerado pela RNA mais PID: sistema (47).



Fonte: o próprio autor.

Figura 50 - Implementação de controle para sistemas lineares e não-lineares por RNA e PID.



Fonte: o próprio autor.

Considera-se o sistema descrito no espaço de estados

$$\begin{aligned}\dot{x}(t) &= Ax(t) + Bu(t) + f(t), \\ y(t) &= Cx(t),\end{aligned}\quad (48)$$

tal que o vetor de estados $x(t) \in \mathbb{R}^n$, o vetor controle $u(t) \in \mathbb{R}^m$, o vetor de saída $y(t) \in \mathbb{R}^p$ e o modelo de não-linearidades no sistema $f(t) \in \mathbb{R}^n$, com $A \in \mathbb{R}^{n \times n}$, $B \in \mathbb{R}^{n \times m}$ e $C \in \mathbb{R}^{p \times n}$.

O primeiro sistema simulado é de terceira ordem e apresenta as seguintes matrizes constantes em malha aberta

$$A = \begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ -1 & -4 & 10 \end{bmatrix}, \quad B = \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix}, \quad C = [0 \ 0 \ 1] \quad e \quad f(t) = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}. \quad (49)$$

Os autovalores da matriz A são $[9,5712 \ -0,1735 \ 0,6023]$ e, assim, o sistema é instável em malha aberta, pois apresenta dois autovalores com parte real positiva.

Todavia, ao submeter o sistema (49) em malha fechada, com apenas um ganho proporcional unitário na malha direta de controle, as matrizes ficam


$$A_{MF} = \begin{bmatrix} -11 & -1 & -4 \\ 0 & 0 & 1 \\ -1 & 0 & 0 \end{bmatrix}, \quad B_{MF} = \begin{bmatrix} 1 \\ 0 \\ 0 \end{bmatrix} \quad e \quad C_{MF} = [1 \ 0 \ 0], \quad (50)$$

e os autovalores $[-10,6326 \ -0,1837 + 0,2456i \ -0,1837 - 0,2456i]$ da matriz A todos com parte real negativa, passando a ser um sistema estável, condição ideal para a RNA atuar de

forma eficaz no desempenho do sistema, como supracitado.

As simulações com a estratégia de controle proposta na Figura (50) para o sistema (48) e matrizes (49) são realizadas utilizando-se o sinal de referência apresentado na Figura (51).

Figura 51 - Sinal de referência para sistema de 3ª ordem com controle PID mais RNA.



Fonte: o próprio autor.

Neste primeiro caso, duas simulações são realizadas: na primeira, utiliza-se apenas a malha de controle do controlador PID, com os seguintes ganhos, $P = 1$, $I = 0$ e $D = 0$ sendo assim, uma malha de controle com ganho proporcional igual a um, enquanto que, na segunda simulação, considera-se a estratégia de controle completa, como apresentado na Figura (50). Os dados do controlador CEV-RNA são $k = 900$ e $\delta_R = 0,05$.


Os resultados do sinal de saída para estas duas simulações e o sinal de referência estão na Figura (52). O sinal de saída do sistema sendo controlado com o PID é estável, porém não segue o sinal de referência. Entretanto, quando a malha de controle da RNA está presente, o sistema passa a ser capaz de seguir o sinal desejado corretamente, apresentando pequenos *overshoots* durante trocas bruscas de posições.

Na Figura (53) os sinais de controle são comparados, verificando-se um problema no sinal de controle para o caso da rede neural. O sistema segue a referência imposta, porém o sinal de controle tende a infinito, inviabilizando esta aplicação.

Sendo assim, as simulações são novamente realizadas, considerando-se um limitador no sinal de controle. Este limitador satura o sinal de controle em no máximo 500 e no mínimo -500 , colocando, assim, não-linearidades no sistema que é linear.


Os resultados dos sinais de saída para este segundo caso estão na Figura (54), na qual verifica-se que o sistema não segue o sinal de referência, quando controlado pelo PID e na simulação com a estratégia de controle proposta, o sistema segue o sinal desejado, passando a

Figura 52 - Sinal de referência e sinais de saída com controlador PID e com controle via RNA mais PID: sistema (49).



Fonte: o próprio autor.


Figura 53 - Sinal de controle gerado pelo PID e sinal de controle gerado pela RNA mais PID: sistema (49).



Fonte: o próprio autor.

apresentar pequenas trepidações em certos instantes que não ocorriam no caso anterior. A justificativa para estas trepidações é dada por meio de uma análise do sinal de controle, apresentado na Figura (55). Verifica-se que as oscilações na saída da planta ocorrem exatamente quando o sinal de controle atinge os limites máximos permitidos. Contudo, mesmo atingindo os valores máximos, a rede é capaz de se ajustar e manter o sistema em operação, característica essa muito importante, encontrada em RNA.

Figura 54 - Sinal de referência e sinais de saída com controlador PID e com controle via RNA mais PID: sistema (49) saturado.



Fonte: o próprio autor.


A estratégia de controle formada pela RNA obteve bom desempenho em controlar o sistema, uma vez que o sistema naturalmente instável é estabilizado por um controlador qualquer, no caso, um controlador PID com apenas ganho proporcional unitário.

Um terceiro caso, com simulações considerando o acréscimo de não-linearidades no sistema (49), são realizadas nas condições de operação do segundo caso. Sendo assim, espera-se que a rede mantenha a resposta da planta sobre o sinal de referência apresentado na Figura (51). O novo sistema apresenta-se como

$$A = \begin{bmatrix} 0 & v_{x2} & 0 \\ 0 & 0 & 1 \\ -1 & -4 & 10 \end{bmatrix}, \quad B = \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix}, \quad C = [0 \ 0 \ 1] \quad e \quad f(t) = \begin{bmatrix} 0 \\ 0 \\ v_u \end{bmatrix}, \quad (51)$$

no qual as incertezas são $v_{x2} = 0,5\text{sen}(2\pi 0,1t)$ e $v_u = 40\text{sen}(2\pi 0,025t)$.

Figura 55 - Sinal de controle gerado pelo PID e sinal de controle gerado pela RNA mais PID: sistema (49) saturado.



Fonte: o próprio autor.

Os resultados do sinal de saída são apresentados na Figura (56), sendo que a saída da planta controlada por apenas o controlador PID, sofre as influências causadas pelas incertezas não-lineares consideradas. Na simulação com o sistema controlado pela estratégia de controle proposta, o sistema segue o sinal de referência corretamente, amenizando os efeitos degenerativos causados pelas incertezas não-lineares.


Os sinais de controle para essas simulações estão na Figura (57), sendo que o sinal de controle foi adaptado pela rede, dentro dos limites impostos pelos saturadores. Nos instantes em que o sinal de controle atinge os limites considerados, a saída da planta apresenta pequenas distorções e novamente a rede consegue manter o sistema em funcionamento.

Sendo assim, a estratégia de controle mostra-se uma solução eficaz, auxiliando sistemas que apresentam um desempenho ruim, porém estável, a buscarem sinais desejados.

3.3 CONCLUSÕES PARCIAIS


Neste capítulo analisou-se por meio de simulações computacionais o desempenho de redes neurais artificiais Adaline com adaptação de pesos em tempo real no controle de sistemas lineares em malha fechada. Conclui-se que a rede não atua de forma eficaz em sistemas de fase não mínima, isto é, sistemas que apresentam zeros positivos em malha aberta. A rede mostrou-se eficiente, melhorando a resposta de sistemas estáveis em malha aberta e até mesmo

Figura 56 - Sinal de referência e sinais de saída com controlador PID e com controle via RNA mais PID: sistema (51) saturado.



Fonte: o próprio autor.

Figura 57 - Sinal de controle gerado pelo PID e sinal de controle gerado pela RNA mais PID: sistema (51) saturado.



Fonte: o próprio autor.

em algumas classes de sistemas instáveis com polos positivos, desde que com zeros negativos, rastreando de maneira eficaz o sinal de referência.

Resultados também foram obtidos em sistemas controlados por uma nova estratégia de controle, formada por controlador PID e pela RNA com CEV-RNA. Pelos resultados, verificou-se que mesmo em sistemas de fase não mínima, sendo estabilizados pelo controlador PID, que em malha fechada continuavam a apresentar zeros com parte real positiva, o acréscimo da rede, se tornou ineficiente e incapaz de controlar a planta. Agora, em sistemas de fase mínima que estão sendo controlados por um controlador qualquer, como por exemplo, um controlador PID sem um ajuste adequado dos pesos, a rede conseguiu melhorar consideravelmente a resposta da planta, fazendo-a seguir o sinal de referência, o que não ocorria com apenas o controlador PID.

As comparações entre os sinais de controle gerados nas simulação utilizando apenas o controlador PID, com os sinais de controle gerados considerando o acréscimo da malha de controle via RNA, trouxeram informações importantes quanto à utilização da RNA, tal que, o fato de acrescentar a malha de controle via RNA, diminui os sinais de controle, além deles não mais apresentarem os picos momentâneos com valores elevados que ocorriam nos sinais de controle com apenas o controlador PID.

Outro ponto favorável está no fato da rede conseguir eliminar os efeitos degenerativos causados por incertezas não-lineares presentes em sistemas. Robustez esta, o qual muitos controladores não conseguem lidar. CEV/MD são controladores que apresentam robustez a uma classe de incertezas, e no caso apresentado, a RNA com CEV-RNA, conseguiu eliminar todas as incertezas que foram impostas. Esta característica será melhor discutida no próximo capítulo.

4 CONTROLADORES CEV/MD AUXILIADOS POR RNA APLICADOS EM SISTEMAS INCERTOS NÃO-LINEARES

Neste capítulo é proposta uma estratégia de controle formada por Controlador e Observador, ambos com Estrutura Variável e Modos Deslizantes (CEV/MD e OEV/MD, respectivamente), acrescida da estrutura neural desenvolvida por Sira-Ramírez e Colina-Morles (1995). Com isso, explora-se a capacidade da nova estratégia de controle, em amenizar as influências causadas por incertezas não-lineares do tipo casadas e não casadas, presentes em modelos matemáticos de sistemas.

Estratégias de controle que utilizam a técnica de Estrutura Variável e Modos Deslizantes apresentam características robustas a uma classe de incertezas paramétricas. Sendo assim, são descritos os tipos de incertezas presentes em sistemas, os quais, estas estratégias de controle apresentam certa imunidade, isto é, os tipos de incertezas que não influenciam o desempenho de sistemas devido a atuação do CEV/MD e do OEV/MD. Esta característica, muito explorada neste tipo de controlador, não pode ser encontrada em controladores convencionais, como por exemplo, o controlador PID.

Para a utilização do CEV/MD e do OEV/MD, é proposta uma nova estrutura de controle. Esta estrutura é composta por apenas uma malha de controle, com a possibilidade de utilização de várias redes Adaline, uma para cada saída da planta controlada. Por meio de simulações computacionais, este esquema de controle proposto é testado em um modelo de eixo lateral de um avião em condições de voo.

4.1 CONTROLADOR E OBSERVADOR COM ESTRUTURA VARIÁVEL E MODOS DESLIZANTES

Neste item apresenta-se os conceitos de um Controlador e um Observador, ambos com Estrutura Variável e Modos Deslizantes contínuo no tempo, aplicados em plantas lineares e não-lineares incertas, baseados em DeCarlo, Zak e Matthews (1988) e Spurgeon e Edwards (1998).

Considera-se o sistema incerto descrito abaixo,

$$\begin{aligned}\dot{x}(t) &= Ax(t) + Bu(t) + Df(t), \\ y(t) &= Cx(t),\end{aligned}\tag{52}$$

sendo que, o vetor de estados $x(t) \in \mathbb{R}^n$, o vetor controle $u(t) \in \mathbb{R}^m$, o vetor de saída $y(t) \in \mathbb{R}^p$ e

o modelo de não-linearidades desconhecido, porém limitado, no sistema $Df(t) = \xi(t) \in \mathbb{R}^{n \times 1}$, com as matrizes $A \in \mathbb{R}^{n \times n}$, $B \in \mathbb{R}^{n \times m}$, $C \in \mathbb{R}^{p \times n}$, $D \in \mathbb{R}^{n \times m}$ e $f(t) \in \mathbb{R}^{m \times 1}$.

4.1.1 Controlador com estrutura variável e modos deslizantes (CEV/MD)

Controle com Estrutura Variável e Modos Deslizantes (CEV/MD) é um controle de realimentação chaveado de alta velocidade, tal que esse chaveamento é utilizado para conduzir e manter, por todo tempo subsequente, a trajetória dos estados de uma planta sobre uma superfície especificada e escolhida no espaço de estados ou sobre a intersecção de todas as superfícies. Essa superfície escolhida é chamada de Superfície de Deslizamento (SD) ou superfície de chaveamento (DECARLO; ZAK; MATTHEWS, 1988).

O Modo Deslizante (MD) ocorre quando a trajetória dos estados da planta atinge a SD e nela permanece por todo tempo subsequente fazendo assim com que o sistema sofra menor influência de distúrbios externos, alterações paramétricas e incertezas casadas. A lei de controle CEV/MD fornece então um meio robusto e eficaz de controlar plantas lineares e não-lineares (DECARLO; ZAK; MATTHEWS, 1988).

Para o projeto do CEV/MD considera-se o sistema incerto (52) e o controlador com a seguinte estrutura

$$u(t) = u_{eq}(t) + u_{NL}(t). \quad (53)$$

A superfície de deslizamento é

$$\{x(t) / \sigma(x(t)) = Sx(t) = 0\},$$

tal que S é a matriz da superfície de deslizamento, sendo $S \in \mathbb{R}^{m \times n}$ e $S = \frac{\partial \sigma}{\partial x}$.

Diferenciando $\sigma(x) = 0$ em relação ao tempo, tem-se

$$\left[\frac{\partial \sigma}{\partial x} \right] \dot{x} = 0. \quad (54)$$

Substituindo a equação (52) em (54), com alguns passos matemáticos tem-se o vetor de controle $u_{eq}(t)$,

$$u_{eq}(t) = -[SB]^{-1}SAx(t). \quad (55)$$

O controle chaveado $u_{NL}(t)$ escolhido é dado por,

$$u_{NL} = -\rho_C \frac{\sigma(x)}{\|\sigma(x)\| + \delta_C}, \quad \text{com } \rho_C > 0. \quad (56)$$

Este controlador contínuo no tempo está bem detalhado em DeCarlo, Zak e Matthews (1988), Utkin (1978) e Garcia e Bennaton (2002).

4.1.2 Observador com estrutura variável e modos deslizantes (OEV/MD)

O Observador com Estrutura Variável e Modos Deslizantes (OEV/MD) é agora descrito. Este estimador de estados é apresentado em sua forma canônica (SPURGEON; EDWARDS, 1998).

Suponha-se que exista uma mudança de coordenadas linear T_0 tal que o sistema (52) possa ser escrito como

$$\begin{cases} \dot{x}_1(t) = A_{11}x_1(t) + A_{12}y(t) + B_1u(t), \\ \dot{y}(t) = A_{21}x_1(t) + A_{22}y(t) + B_2u(t) + D_2f(t), \end{cases} \quad (57)$$

sendo que $x_1 \in \mathbb{R}^{n-p}$, $y \in \mathbb{R}^p$, $D_2 \in \mathbb{R}^{q \times q}$ é não singular e a matriz A_{11} tem autovalores estáveis.

Considere o observador com modos deslizantes da forma

$$\begin{cases} \dot{\hat{x}}_1(t) = A_{11}\hat{x}_1(t) + A_{12}\hat{y}(t) + B_1u(t) - A_{12}e_y(t), \\ \dot{\hat{y}}(t) = A_{21}\hat{x}_1(t) + A_{22}\hat{y}(t) + B_2u(t) - (A_{22} - A_{22}^s)e_y(t) + v, \end{cases} \quad (58)$$

tal que A_{22}^s é uma matriz de projeto estável e $e_y(t) = \hat{y}(t) - y(t)$. Seja $P_2 \in \mathbb{R}^{p \times p}$ uma matriz de Lyapunov, simétrica e positiva definida para A_{22}^s , então o vetor descontínuo v é definido por

$$v = \begin{cases} -\rho_O(t, y, u) \|D_2\| \frac{P_2 e_y}{\|P_2 e_y\|}, & \text{se } e_y \neq 0, \\ 0, & \text{se } e_y = 0, \end{cases} \quad (59)$$

tal que, a função escalar $\rho_O : \mathbb{R}_+ \times \mathbb{R}^p \times \mathbb{R}^m \rightarrow \mathbb{R}_+$ satisfaz,

$$\rho_O(t, y, u) \geq r_1 \|u\| + \alpha(t, y) + \gamma_0, \quad (60)$$

e γ_0 é um escalar positivo.

Este observador está bem apresentado em Spurgeon e Edwards (1998), Garcia (2002) e Rodrigues (2009), o qual encontram-se mais detalhes sobre como projetá-lo.

4.2 ROBUSTEZ DO CONTROLE COM ESTRUTURA VARIÁVEL E MODOS DESLIZANTES

Este item é baseado em Drazenovic (1969) e dá o embasamento matemático necessário à classificação dos tipos de incertezas encontradas em sistemas lineares ou não-lineares, que podem ser do tipo casadas e do tipo não casadas.

4.2.1 Definições

A resposta de um CEV/MD consiste em três fases:

- Aquela em que o sistema ainda não alcançou o modo deslizante (modo de alcance);
- O instante em que o sistema atinge o modo deslizante;
- E o momento em que o sistema entra em regime de estado permanente.

As análises em relação a robustez e sensibilidade deverão abordar estas três etapas.

As questões de sensibilidade e robustez foram assim esclarecidas em Spurgeon e Edwards (1998):

Definição 4.1. *Um sistema é dito sensível às variações dos parâmetros, se uma medida Φ é diferente de zero. No caso especial em que $\Phi = 0$, o sistema é dito ser zero-sensível. Se Φ é pequena, o sistema é dito insensível.*

Definição 4.2. *Um sistema é dito robusto se a propriedade de interesse do sistema permanece em uma região limitada em face de uma classe de perturbações limitadas.*

4.2.2 Sensibilidade do sistema durante o modo deslizante: condições de invariância

Considere o sistema do tipo

$$\dot{x} = (A + \Delta A)x(t) + Bu(t) + Df(t), \quad (61)$$

tal que ΔA e $Df(t)$ são desconhecidos mas limitados.

Neste sistema pode-se projetar uma lei de controle tal que seja garantida a condição de atratividade e o sistema pode ser insensível às incertezas pelas seguintes condições,

- **Condições de invariância:**

Drazenovic (1969) elaborou as condições nas quais o sistema é zero-sensível, chamada aqui, genericamente, de condições de invariância.

Seja o sistema sujeito às incertezas e perturbações descritas na Equação (61), cuja superfície de chaveamento é dada por

$$\sigma(x, t) = Sx(t) .$$

No deslizamento, então, considerando $\sigma(x, t) = 0$ e $\dot{\sigma}(x, t) = 0$, chega-se a

$$\begin{aligned} \dot{\sigma}(x, t) = & \left[I_n - B(SB)^{-1}S \right] [Ax(t) + \\ & + \Delta Ax(t) + Df(t)], \end{aligned} \quad (62)$$

$$\text{e } Sx(t) = 0. \quad (63)$$

Para que o sistema no modo deslizante seja zero-sensível a $f(t)$ e ΔA , as seguintes condições devem ser satisfeitas,

$$\begin{aligned} \left[I_n - B(SB)^{-1}S \right] Df(t) = 0 & \Rightarrow \\ \Rightarrow Df(t) = B(SB)^{-1}SDf(t), \end{aligned} \quad (64)$$

$$\begin{aligned} \left[I_n - B(SB)^{-1}S \right] \Delta Ax(t) = 0 & \Rightarrow \\ \Rightarrow \Delta Ax(t) = B(SB)^{-1}S\Delta Ax(t). \end{aligned} \quad (65)$$

Então,

- Para que (64) seja satisfeita, $Df(t) = Bm$, sendo $m = (SB^{-1})SDf(t)$, é necessário que

$$\text{rank} \begin{bmatrix} B & D \end{bmatrix} = \text{rank}[B], \quad (66)$$

ou seja, que todas as colunas de D sejam combinações lineares das colunas de B .

- De (65), $\Delta Ax(t) = B(SB)^{-1}S\Delta Ax(t)$, sujeito a $Sx(t) = 0$, então considere que as colunas da matriz T sejam a base vetorial do subespaço $R^{(n-m)}$. Neste caso, $x(t) = Tx^r(t)$, sendo que, $x^r(t) \in R^{(n-m)}$. Então a equação (65) toma a forma

$$\Delta A T x^r(t) = B(SB)^{-1}S\Delta A T x^r(t). \quad (67)$$

A equação acima é satisfeita se

$$\text{rank} \begin{bmatrix} B & \Delta A T \end{bmatrix} = \text{rank} [B]. \quad (68)$$


Com isso, (66) e (68) mostram em que condições o sistema é zero-sensível às variações dos parâmetros (incertezas do tipo casadas), caso contrário, estas variações paramétricas influenciarão o desempenho do sistema quando em deslizamento (incertezas do tipo não casadas). Deve-se observar que as condições de invariância analisadas acima devem-se somente à física do sistema.

4.3 MODELO DE EIXOS LATERAIS DE UM AVIÃO L-1011

O sistema utilizado nas simulações é um modelo matemático de eixo lateral de um avião L-1011 em condições de voo. Este sistema foi descrito originalmente por Edwards e Spurgeon (1994).

As Figuras (58), (59) e (60) representam um modelo de avião. Na Figura (58) têm-se os ângulos e as partes principais de um avião, na Figura (59), tem-se uma visão frontal de um avião com a definição do ângulo de *bank* e na Figura (60) tem-se um avião com o seu eixo longitudinal deslocado do eixo da trajetória, formando assim, o ângulo de derrapagem.

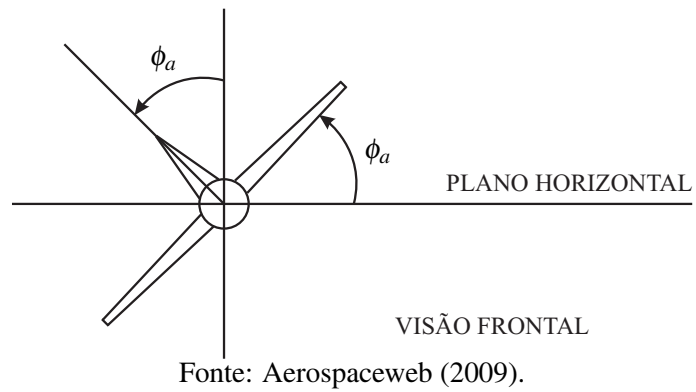

Figura 58 - Ângulos e partes principais de um avião.



Fonte: Aerospaceweb (2009).

O sistema incerto é dado por,

$$\begin{aligned} \dot{x}(t) &= Ax(t) + Bu(t) + \xi(t), \\ y(t) &= Cx(t), \end{aligned} \quad (69)$$

Figura 59 - Visão frontal de um avião com o ângulo de *bank* (ϕ_a).Figura 60 - Trajetória do avião e ângulo de derrapagem β_a .

com $x(t) \in \mathbb{R}^5$, $u(t) \in \mathbb{R}^2$, $y(t) \in \mathbb{R}^4$ e $\xi(t) \in \mathbb{R}^{5 \times 1}$.

O vetor de estados é representado por $x^T = [\phi_a, r, p_a, \beta_a, x_5]$, tal que ϕ_a , r , p_a , β_a e x_5 são o ângulo de *bank* (rad), a taxa de guinada (*yaw rate*) (rad/s), a taxa de *roll* (rad/s), o ângulo de derrapagem (*sideslip angle*) (rad/s) e o estado do filtro de *washed out*, respectivamente. O vetor de controle é representado por $u^T = [\delta_l, \delta_a]$, sendo que δ_l e δ_a são a deflexão do leme (rad) e a deflexão do aileron (rad), respectivamente. O vetor de saída é representado por $y^T = [r_{wo}, p_a, \beta_a, \phi_a]$, tal que, r_{wo} , p_a , β_a e ϕ_a são a taxa de guinada de *washed out*, a taxa de *roll* (rad/s), o ângulo de derrapagem (*sideslip angle*) (rad/s) e o ângulo de *bank* (rad), respectivamente (DHAHRI et al., 2007).

As matrizes A , B e C , contendo incertezas do tipo casadas e não casadas, utilizadas nas simulações são dadas por

$$A = \begin{bmatrix} 0 & 0 & 1 & 0 & 0 \\ 0 & -0,154 + \Delta_{22}\text{sen}(2\pi 0,5t) & -0,0042 & 1,54 & 0 \\ 0 & 0,249 & -1 & -5,2 & 0 \\ 0,0386 & -0,996 & -0,0003 & -0,117 & 0 \\ 0 & 0,5 + \Delta_{52}\text{sen}(2\pi 0,5t) & 0 & 0 & -0,5 + \Delta_{55}\text{sen}(2\pi 0,5t) \end{bmatrix},$$

$$B = \begin{bmatrix} 0 & 0 \\ -0,744 & -0,032 \\ 0,337 & -1,12 \\ 0,02 & 0 \\ 0 & 0 \end{bmatrix},$$

$$C = \begin{bmatrix} 0 & 1 & 0 & 0 & -1 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 1 & 0 & 0 & 0 & 0 \end{bmatrix},$$

sendo que, as incertezas não-lineares correspondem aos ganhos Δ_{22} , Δ_{52} e Δ_{55} .

4.4 ESTRATÉGIA DE CONTROLE E SIMULAÇÕES REALIZADAS

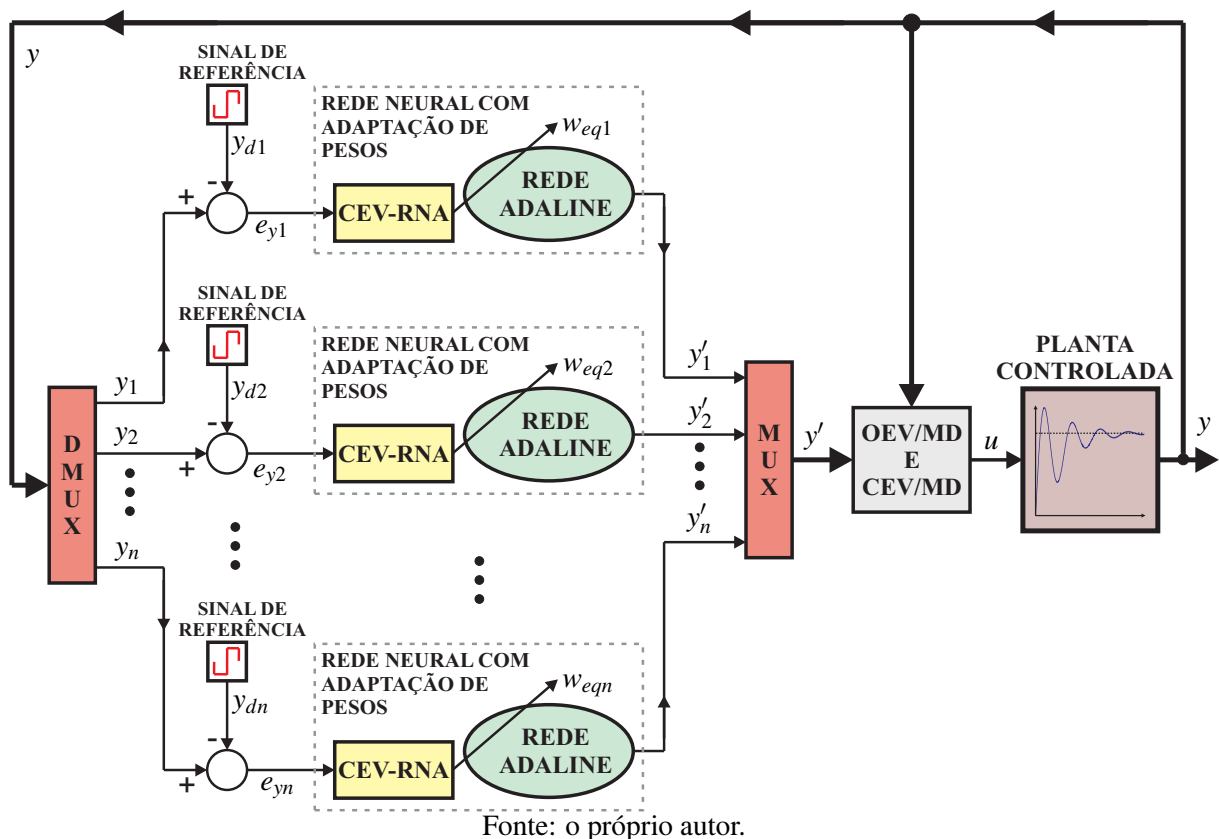
Para as simulações do modelo de eixo lateral de um avião, uma nova estrutura de controle é proposta. A nova estratégia de controle capaz de reduzir os efeitos degenerativos causado por quaisquer tipos de incertezas e distúrbios é esquematizada na Figura (61).

Considerando que o sinal de saída $y(t)$ da planta controlada é formado por “ n ” componentes,

$y(t)^T = [y_1(t) \ y_2(t) \ \dots \ y_n(t)]$, um demultiplexador (DMUX) foi utilizado, obtendo-se acessos a todas as saídas da planta. O processo inverso também foi realizado, só que para o novo vetor de sinais de saída gerado pela rede neural, o $y'(t)^T = [y'_1(t) \ y'_2(t) \ \dots \ y'_n(t)]$, em que, utiliza-se um multiplexador (MUX).

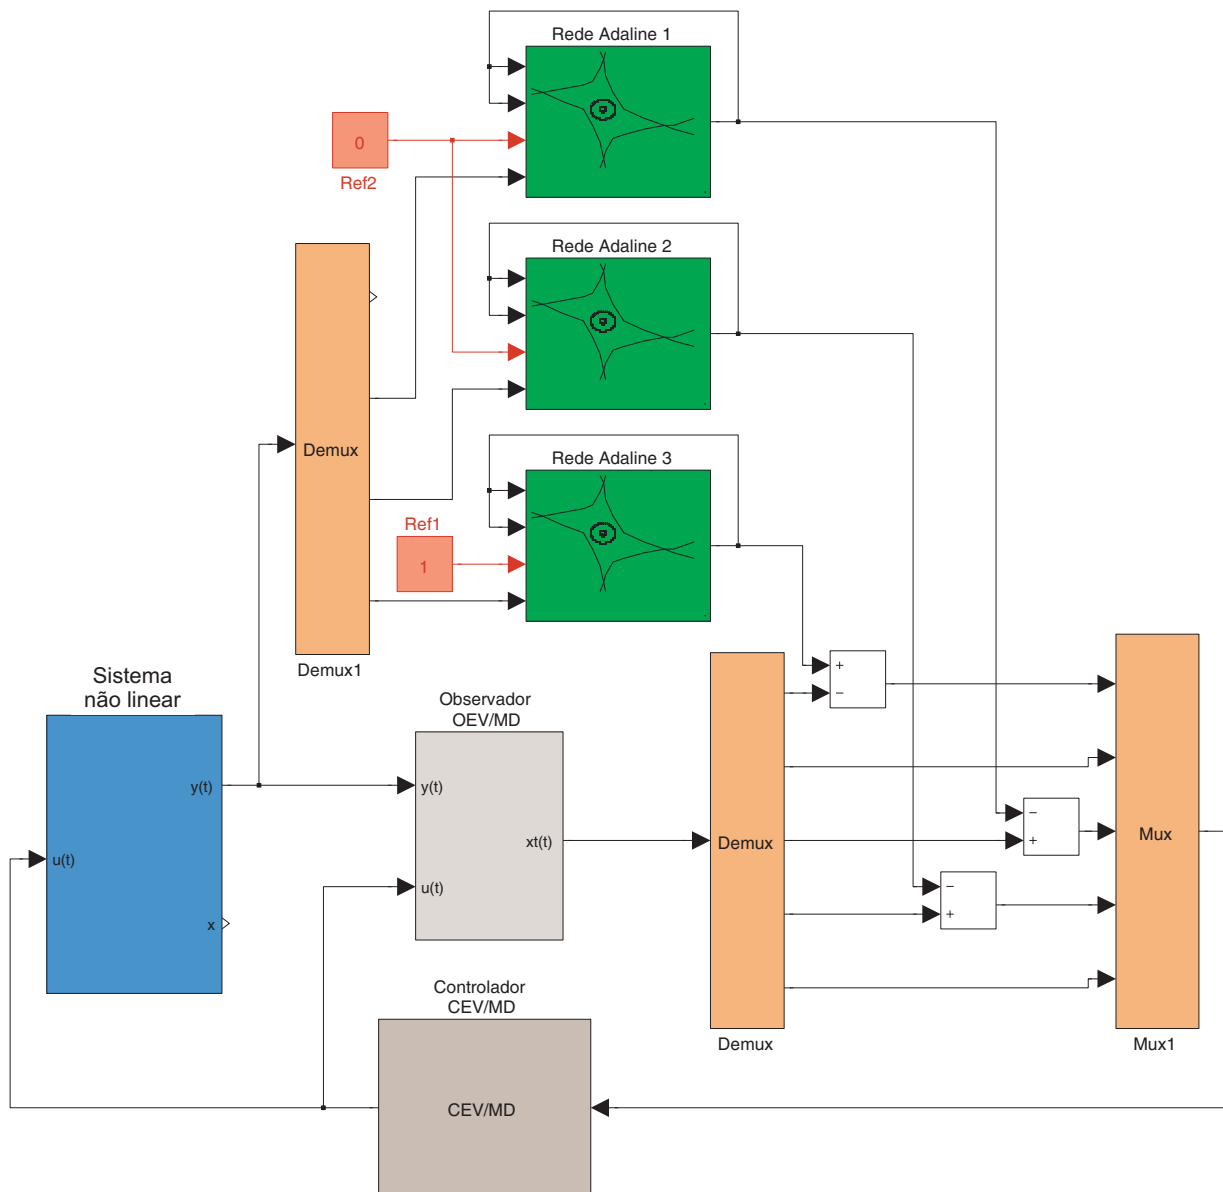
Esta nova estrutura de controle é formada por duas malhas de controle, tal que cada um dos “ n ” erros $e_y(t)$, obtidos entre os sinais de referência $y_d(t)$ e as saídas da planta $y(t)$, respectivamente, alimentam RNA específicas, formando assim, o novo vetor de saída $y'(t)$. Com isso, compara-se o novo sinal de saída $y'(t)$ com o estimado pelo OEV/MD, compondo o vetor de estados necessário para o CEV/MD controlar da planta. Sendo assim, existe um banco de “ n ” RNA, uma para cada saída da planta que apresenta sinal de referência, ajustando cada uma destas saídas, antes do observador e do controlador (OEV/MD e CEV/MD) gerarem o sinal de controle entregue à planta.

Figura 61 - Estrutura de controle via RNA para sistemas lineares e não-lineares já controlados por OEV/MD e CEV/MD.



A simulação computacional da estratégia de controle esquematizada na Figura (61) é apresentada na Figura (62), o qual, é possível verificar a comparação entre as saídas da planta ajustas pelas RNA com as saídas estimadas pelo observador. Três RNA foram utilizadas na simulação, sendo uma rede para cada saída da planta que apresenta sinal de referência.

Figura 62 - Simulação computacional da estratégia controle via RNA, OEV/MD e CEV/MD.



Fonte: o próprio autor.

A utilização da RNA Adaline com ajuste de pesos via CEV-RNA compoendo a segunda malha de controle auxilia o CEV/MD e o OEV/MD a estabilizar sistemas, melhorando suas respostas devido à redução da influência de perturbações externas e incertezas do tipo casadas e não casadas.

Simulações computacionais são realizadas utilizando a estrutura neural proposta por Sira-Ramírez e Colina-Morles (1995) auxiliando o CEV/MD e o OEV/MD no controle do modelo de eixo lateral de um avião, conforme a estratégia proposta na Figura (61).

As simulações para o sistema (69) são realizadas considerando uma posição constante do avião, deixando apenas a saída $y_1(t)$ sem sinal de referência, sendo imposto apenas os sinais desejados $y_{d2}(t) = 0$, $y_{d3}(t) = 0$ e $y_{d4}(t) = 1$. Com isso, três simulações são realizadas, explorando-se os efeitos causados por incertezas paramétricas no sistema controlado:

- A primeira simulação é realizada considerando o sistema (69) sem incertezas paramétricas sendo controlado apenas pelo CEV/MD e OEV/MD, conseqüentemente, os ganhos constantes das incertezas são $\Delta_{22} = \Delta_{52} = \Delta_{55} = 0$. Com isso, a segunda malha de controle contendo a RNA com CEV-RNA não é utilizada.

- A segunda simulação trata da análise do sistema apresentando incerteza do tipo casada e não-linear no elemento 22 da matriz A e controle realizado apenas pelo CEV/MD e o OEV/MD. Com isso, os ganhos constantes da matriz ficam, $\Delta_{22} = 0,3$ e $\Delta_{52} = \Delta_{55} = 0$.

- No caso da terceira simulação, são consideradas as mesmas condições de incertezas do caso anterior, acrescentando-se uma estrutura neural Adaline com CEV-RNA em cada uma das saídas da planta que apresentam sinal de referência, $y_2(t)$, $y_3(t)$ e $y_4(t)$.

- A quarta simulação, trata da análise de desempenho do sistema (69) apresentando incertezas não-lineares em todos os respectivos elementos da matriz A , considerando apenas o CEV/MD e o OEV/MD presente na malha de controle. Sendo assim, $\Delta_{22} = \Delta_{52} = 0,3$ e $\Delta_{55} = 3,0$.

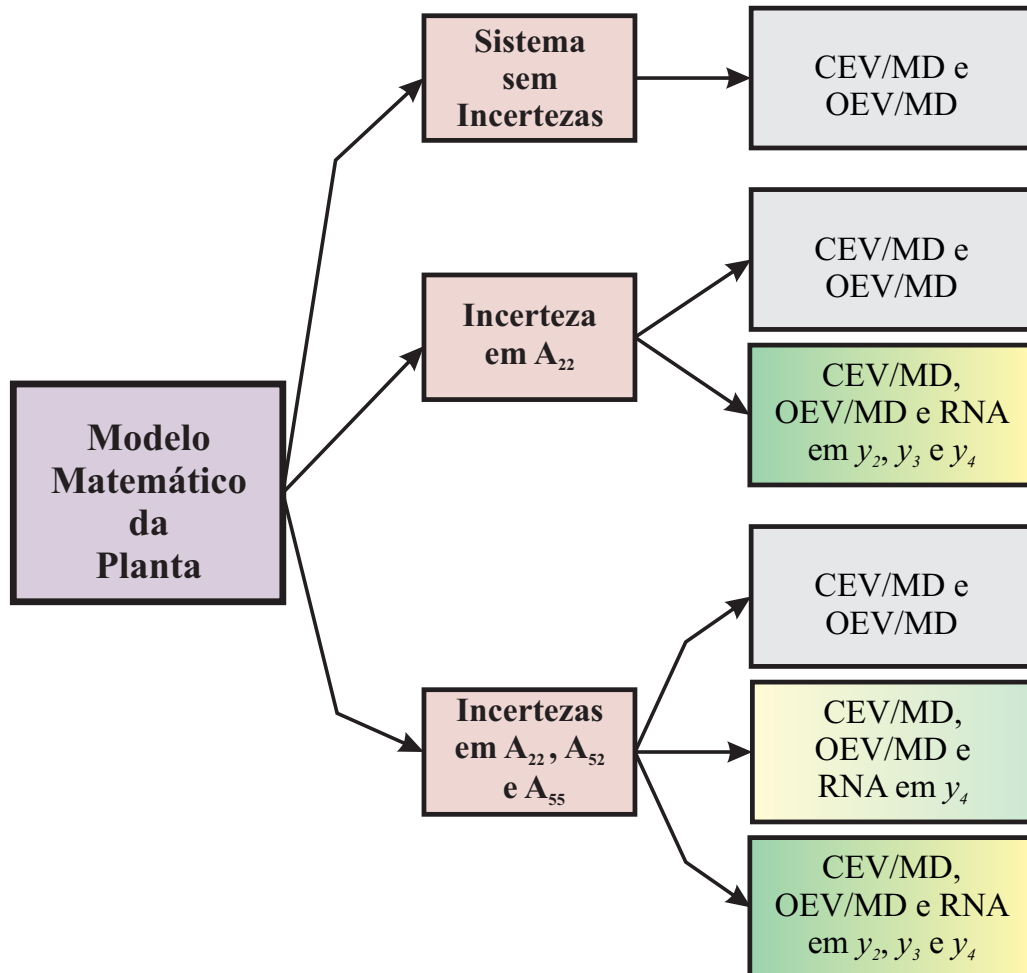
- Na quinta simulação é considerada a presença de todas as incertezas presentes na matriz A , como no caso anterior. Todavia, a RNA é acrescida na malha de controle apenas na saída $y_4(t)$, modificando a estratégia de controle proposta na Figura (61), a qual indica a utilização da estrutura neural em todas as saídas da planta.

- Na última simulação realizada, o sistema novamente é controlado pelo CEV/MD, com as mesmas condições dos dois casos anteriores, incertezas do tipo casadas e não casadas contendo os ganhos $\Delta_{22} = \Delta_{52} = 0,3$ e $\Delta_{55} = 3,0$. Contudo, as RNA com os CEV-RNA são acrescidos na malha de controle, como proposto na Figura (61). Apenas a saída $y_1(t)$ da planta não foi ajustada pela RNA, já que não apresenta sinal de referência.

No diagrama da Figura (63) apresentam-se esquematicamente as seis simulações realizadas

com o modelo matemático de eixo lateral de um avião, modificando-se os tipos de incertezas/perturbações e as estratégias de controle.

Figura 63 - Simulações realizadas com o modelo matemático de eixo lateral de um avião.



Fonte: o próprio autor.

Os valores dos ganhos do CEV-RNA, do CEV/MD e do OEV/MD utilizados em todas as simulações foram $k_R = 3$, $\delta_R = 0,01$, $\rho_C = 15$, $\delta_C = 0,05$ e $\rho_0 = 10$.

4.5 RESULTADOS OBTIDOS E ANÁLISES

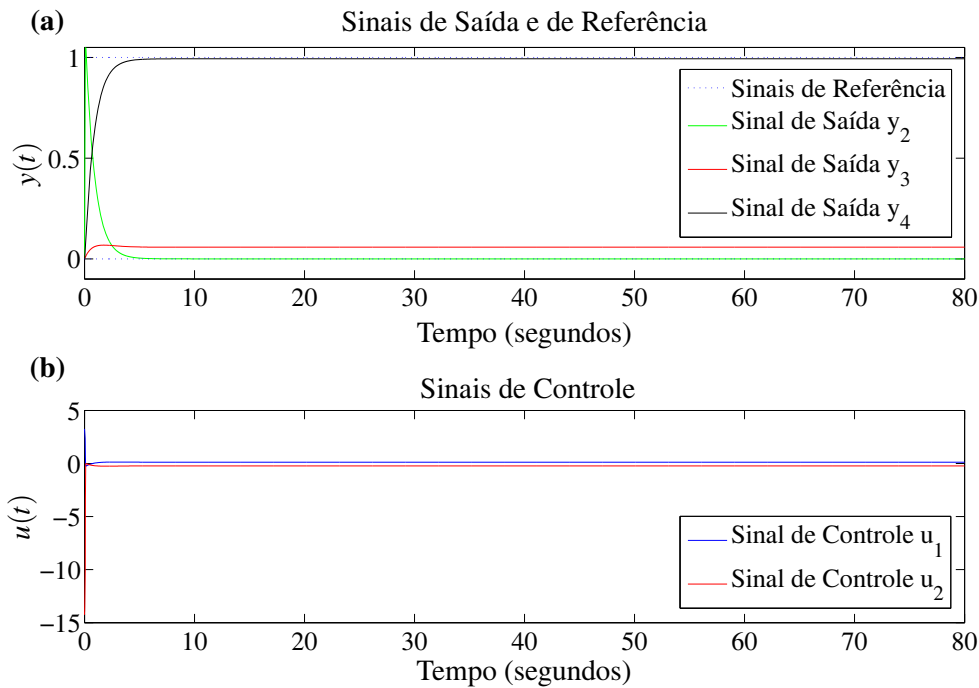
Os resultados das simulações são agora apresentados. Na Figura (64) estão os resultados da primeira simulação.

Os sinais de referência $y_d(t) = 0$ e $y_d(t) = 1$ e os resultados dos sinais de saída $y_2(t)$, $y_3(t)$ e $y_4(t)$ para esta primeira simulação estão na Figura (64a). Pode-se verificar que o sistema é estável com o CEV/MD e as saídas da planta buscam os sinais de referência almejados, sendo que apenas a saída $y_3(t)$ apresenta erro de regime permanente um pouco mais elevado, se comparado

com as outras saídas.

Na Figura (64b) encontram-se os sinais de controle. Em regime permanente, estes sinais são constantes, apresentando valores numéricos próximos de zero.

Figura 64 - Sinais de referência, sinais de saída $y_2(t)$, $y_3(t)$ e $y_4(t)$ e sinais de controle para a primeira simulação: sistema sem incertezas controlado via CEV/MD.



Fonte: o próprio autor.

Na Figura (65) encontram-se os resultados referentes à segunda simulação. Aqui, as incertezas paramétricas não-lineares estão presentes no elemento 22 na matriz A do sistema, utilizando-se apenas o CEV/MD e o OEV/MD.

Os sinais de saída da planta controlada e seus respectivos sinais de referência estão na Figura (65a). Verifica-se que os resultados são muito próximos com os resultados da simulação anterior, em que o sistema não apresenta incerteza no elemento 22. Isto representa boa atuação do controlador e do observador quando o sistema apresenta incertezas do tipo casadas.

Os sinais de controle estão na Figura (65b) e, assim como no caso anterior, permaneceram próximos de zero, exigindo poucos esforços dos atuadores.

Os resultados para a terceira simulação encontram-se na Figura (66). Nesse caso, pode ser visto que o acréscimo da RNA melhora o desempenho do sistema, no qual, os problemas de erro de regime permanente foram minimizados (Figura (66a)), além de reduzir ainda mais os sinais de controle (Figura (66b)).

Figura 65 - Sinais de referência, sinais de saída $y_2(t)$, $y_3(t)$ e $y_4(t)$ e sinais de controle para a segunda simulação: sistema com incerteza não-linear casada controlado via CEV/MD.






Figura 66 - Sinais de referência, sinais de saída $y_2(t)$, $y_3(t)$ e $y_4(t)$ e sinais de controle para a terceira simulação: sistema com incerteza não-linear casada controlado via CEV/MD e RNA.



Os resultados referentes à quarta simulação, em que o sistema apresenta incertezas paramétricas não-lineares nos elementos na matriz A , estão nas Figuras (67) e (68). Os sinais de referência, $y_d(t) = 0$ e $y_d(t) = 1$, e as saídas $y_2(t)$, $y_3(t)$ e $y_4(t)$ são dadas na Figura (67) e os sinais de controle estão na Figura (68). Assim como nos casos anteriores, o controlador mantém o sistema estável, contudo, há uma demanda maior dos sinais de controle, além de as saídas do sistema não permanecerem sobre o sinal de referência, sofrendo fortes influências das incertezas consideradas. Resultado esperado, já que esta estratégia de controle não é apropriada ao tipo de incertezas que a planta é submetida.

Figura 67 - Sinais de referência e sinais de saída $y_2(t)$, $y_3(t)$ e $y_4(t)$ para a quarta simulação: sistema com incertezas não-lineares casadas e não casadas controlado via CEV/MD.




Fonte: o próprio autor.

Os sinais de saída da planta e os sinais de controle para a quinta simulação estão nas Figuras (69) e (70), respectivamente. Nesse caso, são consideradas as mesmas condições do caso anterior, sendo acrescentado a RNA na malha de controle apenas na saída $y_4(t)$.

Como pode ser visto na Figura (69), o fato de acrescentar a RNA na saída $y_4(t)$, melhora a resposta da planta, de modo que as saídas $y_2(t)$ e $y_4(t)$ do sistema passaram a seguir corretamente o sinal desejado após um período inicial, o qual se dá pelo tempo t_h necessário para o CEV-RNA entrar em deslizamento.


Os sinais de controle $u_1(t)$ e $u_2(t)$ presentes na Figura (70) são parecidos com os sinais de controle do caso anterior, os quais também não apresentam valores numéricos elevados, contudo, reduzem as oscilações encontradas em $y_2(t)$ e $y_4(t)$ no quarto caso.

Figura 68 - Sinais de controle $u_1(t)$ e $u_2(t)$ para a quarta simulação: sistema com incertezas não-lineares casadas e não casadas controlado via CEV/MD.




Fonte: o próprio autor.

Figura 69 - Sinais de referência e sinais de saída $y_2(t)$, $y_3(t)$ e $y_4(t)$ para a quinta simulação: sistema com incertezas não-lineares casadas e não casadas controlado via CEV/MD e RNA em $y_4(t)$.



Fonte: o próprio autor.

Figura 70 - Sinais de controle $u_1(t)$ e $u_2(t)$ para a quinta simulação: sistema com incertezas não-lineares casadas e não casadas controlado via CEV/MD e RNA em $y_4(t)$.



Fonte: o próprio autor.

Os resultados da sexta simulação estão nas Figura (71) e (72), tal que, os sinais de saída $y_2(t)$, $y_3(t)$ e $y_4(t)$ e seus respectivos sinais de referência estão na Figura (71).

Comparando estes resultados com os das simulações do quarto e do quinto caso, verifica-se que o acréscimo da RNA na malha direta de controle das saídas $y_2(t)$, $y_3(t)$ e $y_4(t)$ melhora consideravelmente o desempenho da planta controlada. As saídas do sistema ficam muito próximas dos sinais de referência, com reduções significativas das influências degenerativas causadas pelas incertezas casadas e não-casadas consideradas no modelo matemático da planta. Além disso, os sinais de controle mostrados na Figura (72) apresentam-se com seus valores numéricos reduzidos.

Por meio destes resultados obtidos, pode ser visto que a estratégia de controle proposta trouxe grandes melhorias tanto na resposta da planta controlada como nos sinais de controle, demonstrando-se assim, sua eficácia em controlar sistemas incertos.

Figura 71 - Sinais de referência e sinais de saída para a sexta simulação: sistema com incertezas não-lineares casadas e não casadas controlado via CEV/MD e RNA em $y_2(t)$, $y_3(t)$ e $y_4(t)$.





Figura 72 - Sinais de controle $u_1(t)$ e $u_2(t)$ para a sexta simulação: sistema com incertezas não-lineares casadas e não casadas controlado via CEV/MD e RNA em $y_2(t)$, $y_3(t)$ e $y_4(t)$.



4.6 CONCLUSÕES PARCIAIS

Explorou-se neste capítulo a capacidade de redes Adaline em reduzir os efeitos degenerativos causados por incertezas paramétricas não-lineares presentes em modelos matemáticos. Os pesos da rede Adaline são adaptados, em tempo real, por um controlador com estrutura variável e modos deslizantes (CEV-RNA). Uma nova estratégia de controle foi proposta, sendo que as várias estruturas neurais foram alocadas, de modo a formar outra malha de controle, auxiliando no controle de plantas sujeitas a incertezas/perturbações, as quais, já apresentavam controlador e observador com estrutura variável e modos deslizantes (CEV/MD e OEV/MD).

Por meio de simulações computacionais, um modelo de eixos laterais de um avião L-1011 foi submetido a testes. Pelos resultados obtidos, verificou-se que o sistema sendo controlado apenas com o CEV/MD e o OEV/MD, apresentou dificuldades em rastrear os sinais de referência, principalmente na presença de incertezas não-lineares do tipo casadas e não casadas no modelo matemático da planta, o que impôs fortes oscilações na dinâmica do sistema. Concluiu-se que, acrescentando-se a estrutura neural na malha de controle, melhorou-se consideravelmente o desempenho do sistema, sendo que as saídas da planta rastream com precisão os sinais de referência desejados, reduzindo as oscilações encontradas nos sinais de saída da planta, além dos sinais de controle apresentarem valores numéricos também reduzidos, quando comparados com os obtidos na simulação sem a estrutura neural. Os bons resultados obtidos nas simulações utilizando a nova estratégia de controle comprovam a eficácia do método proposto.

5 CEV-RNA UTILIZADA PARA CONTROLE DE MOTORES ELÉTRICOS

Este capítulo trata do controle de máquinas elétricas rotativas utilizando controladores PID e RNA com ajuste de peso via CEV-RNA. Estes controladores são submetidos a testes em motor de Corrente Contínua (CC) e em Motor de Indução Trifásico (MIT).

Sendo assim, é descrito o modelo linear de um motor de CC (FITZGERALD; KINGSLEY JUNIOR; KUSKO, 1975), o qual é aplicado em diversas simulações. O controle do motor de CC é realizado comparando os resultados de desempenho do sinal de saída em seguir o sinal de referência quando apenas o controlador PID está presente na malha de controle, com simulações realizadas considerando uma segunda malha de controle, contendo a estrutura neural artificial com ajuste de pesos via CEV-RNA proposto no esquema da Figura (50).

Um modelo matemático de MIT não-linear, em Coordenadas de Campo com Corrente de Estator Imposta (LEONHARD, 2001) também é apresentado. O controle do motor de indução é realizado por meio de uma estratégia de controle contendo três malhas de controle, apresentando um controlador PID em cada malha de controle (LEONHARD, 2001). As simulações considerando apenas o controle PID são comparadas com simulações em que é considerado o acréscimo de uma quarta malha de controle contendo RNA com ajuste de pesos via CEV-RNA.

5.1 MOTOR DE CORRENTE CONTÍNUA COM EXCITAÇÃO INDEPENDENTE


Os motores de CC são frequentemente utilizados em aplicações que requerem controle preciso da velocidade e conjugado de saída em uma ampla faixa de valores. Nesta seção é descrito um modelo matemático de um motor CC com excitação independente, o qual é considerado excitação de campo constante. Essa consideração faz com que a velocidade do motor seja ajustada apenas pela variação da tensão aplicada aos terminais da armadura. A análise envolve então, os transitórios elétricos no circuito de armadura e a dinâmica da carga mecânica movida pelo motor.

5.1.1 Equações dinâmicas do motor CC

A representação elétrica de um motor de CC com excitação independente é dado na Figura (73) (FITZGERALD; KINGSLEY JUNIOR; KUSKO, 1975).

O torque eletromagnético de uma máquina CC é

Figura 73 - Diagrama de um motor de corrente contínua com excitação independente.



Fonte: Fitzgerald, Kingsley Junior e Kusko (1975).

$$T_e = k_a \phi i_a, \quad (70)$$

sendo, ϕ é o fluxo no entreferro no eixo direto, i_a é a corrente de armadura e a constante,

$$k_a = \frac{pZ_a}{2\pi a},$$

com o número de polos p , o número de condutores da armadura Z_a e o número de caminhos paralelos a .

A tensão gerada na armadura de uma máquina CC pode ser dada por

$$E_a = k_a \phi \omega_m, \quad (71)$$

sendo que, ω_m é a velocidade mecânica da máquina.

Se o circuito magnético é linear (isto é, se não há saturação), então

$$T_e = k_f i_f i_a, \quad (72)$$

$$E_a = k_f i_f \omega_m, \quad (73)$$

tal que, i_f é a corrente de campo e k_f uma constante.

Considerando I_f como sendo a corrente de campo constante, as equações do conjugado eletromagnético e da tensão ficam

$$T_e = k_m i_a, \quad (74)$$

$$E_a = k_m \omega_m, \quad (75)$$

sendo, a constante $k_m = k_f I_f$.

A tensão nos terminais da máquina é dada por

$$V_{ta} = E_a + L_{aq} \dot{i}_a + R_a i_a, \quad (76)$$

tal que, L_{aq} é a autoindutância e R_a é a resistência do circuito de armadura.

Como a Equação da constante de tempo elétrica da máquina é

$$\tau_a = \frac{L_a}{R_a},$$

a Equação (76) pode ser reescrita por

$$\tau_a \dot{i}_a = \frac{V_{ta} - E_a}{R_a} - i_a. \quad (77)$$

Para um motor, a equação dinâmica do sistema mecânico é,

$$T_e = k_f i_f i_a = J \dot{\omega}_m + T_L, \quad (78)$$

sendo que, J é o momento de inércia, $\dot{\omega}_m$ é a aceleração do motor e T_L é o conjugado mecânico da carga.

Pela Equação (74),

$$\dot{\omega}_m = \frac{T_e}{J} - \frac{T_L}{J} = \frac{k_m i_a}{J} - \frac{T_L}{J}. \quad (79)$$

Sendo assim, as Equações (77) e (79) compõem o modelo dinâmico da máquina CC.

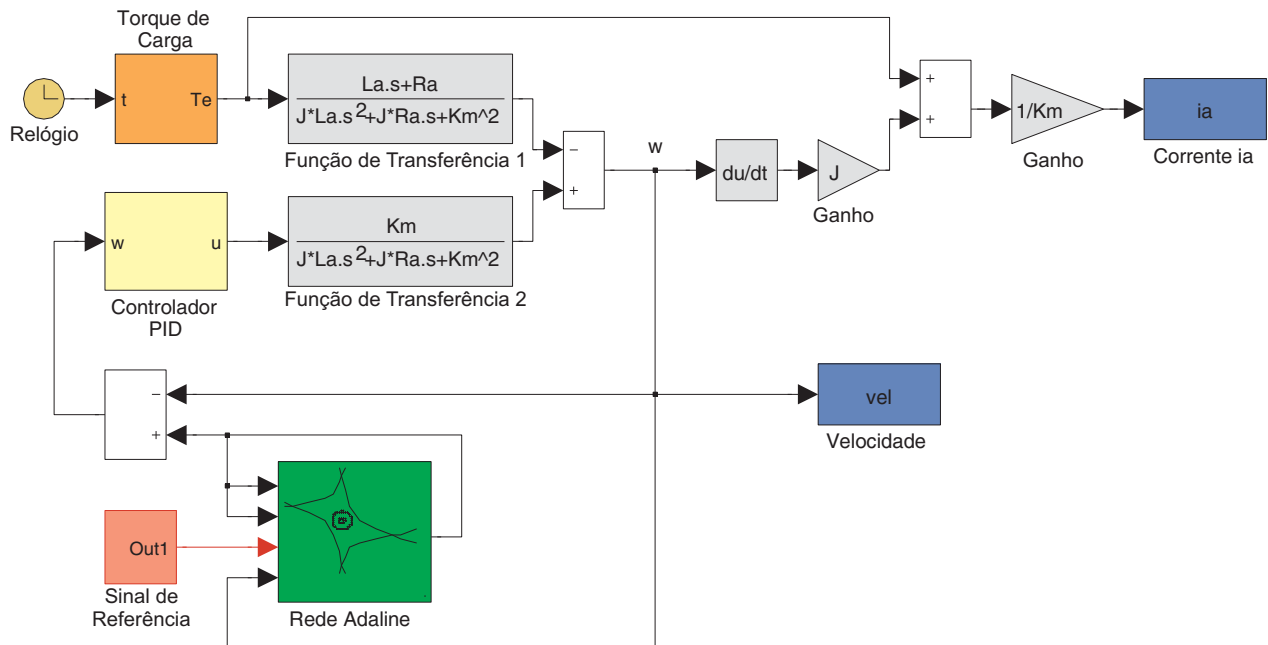
5.1.2 Controle de velocidade de um motor de CC com excitação independente

Para o controle de velocidade do motor de CC é utilizado o Esquema da Figura (50). Nesse esquema utiliza-se um controlador PID na primeira malha de controle e a segunda malha é formada pela estrutura neural Adaline, na qual a simulação computacional dessa estratégia de controle nas equações matemáticas no motor de CC está esquematizada na Figura (74).

Os parâmetros do motor estão descritos na Tabela (3). Na Figura (75a) tem-se o sinal de referência para velocidade do motor CC e na Figura (75b), o torque da carga considerado.

As simulações para o motor CC são realizadas em três casos, modificando-se o projeto dos controladores PID.

Figura 74 - Simulação computacional da estratégia controle via RNA e PID no Motor de CC.




Fonte: o próprio autor.

Tabela 3 - Parâmetros do motor CC

Parâmetros e Símbolos	Valores
Potência Nominal (P_B)	10 HP
Velocidade Nominal (ω_B)	500 rpm
Tensão Nominal (U_B)	240 V
Resistência de Armadura (R_a)	7,56 Ω
Indutância da Armadura (L_a)	0,055 H
Momento de Inércia (J)	0,068 kgm ²
Constante da Máquina (k_m)	4,23 Vs/rad

Fonte: Fitzgerald, Kingsley Junior e Kusko (1975).

Figura 75 - Sinal de referência e torque da carga: motor de CC.




Fonte: o próprio autor.

- No primeiro caso, compara-se o desempenho do motor CC apresentando controle via PID sem RNA, com a estratégia de controle que considera o controlador PID e RNA. O controlador PID projetado para as simulações do primeiro caso é o PID-1, apresentando os seguintes parâmetros: $P = 10$, $I = 3$ e $D = 0$. Os ganhos do controlador CEV-RNA são, $k_R = 25$ e $\delta_R = 0,1$.

Na Figura (76) é apresentada a comparação dos resultados de velocidade para as duas estratégias de controle. A velocidade da máquina quando controlada pelo PID-1 acrescida da rede neural mostra-se muito próxima do sinal de referência, enquanto que a resposta da máquina, quando apenas controlada pelo PID-1, não permanece sobre a referência.


A comparação das tensões que alimentam os terminais da máquina estão na Figura (77) e a comparação das correntes de armadura estão na Figura (78). Observa-se que os *overshoots* encontrados nos sinais de tensão e corrente da simulação com controle via PID-1 são eliminados na simulação com a estratégia de controle que utiliza a RNA.

Figura 76 - Velocidade do motor CC com controle PID-1 e PID-1 com RNA.




Fonte: o próprio autor.

Figura 77 - Tensão do motor CC com controle PID-1 e PID-1 com RNA.



Fonte: o próprio autor.

Figura 78 - Corrente do motor CC com controle PID-1 e PID-1 com RNA.




Fonte: o próprio autor.

- O segundo caso é realizado nas mesmas condições do caso anterior, alterando-se apenas os ganhos do controlador PID, sendo assim, o controlador PID, agora chamado de PID-2, é projetado com os seguintes ganhos, $P = 10$, $I = 10$ e $D = 0,01$, o qual passa a apresentar um pequeno ganho derivativo.


A resposta da velocidade do motor para as duas simulações com o projeto do controlador PID-2 estão na Figura (79). Pode ser visto que o ajuste dos ganhos do controlador melhora a resposta do motor quando o controle é realizado por apenas o PID-2. Todavia, por meio de uma análise do sinal de tensão (Figura (80a)) e do sinal de corrente (Figura (81)), verifica-se que esta resposta é alcançada, devido o grande aumento dos níveis de tensões, e conseqüentemente, a corrente de armadura, nos momentos de trocas abruptas de velocidade. O acréscimo da RNA com o CEV-RNA melhora os sinais de tensão e corrente, eliminando os *overshoots*, Figura (80b) e Figura (81), além da resposta de velocidade da máquina ficar mais próxima do sinal de referência.

Figura 79 - Velocidade do motor CC com controle PID-2 e PID-2 com RNA.




Fonte: o próprio autor.

Figura 80 - Tensão do motor CC com controle PID-2 e PID-2 com RNA.



Fonte: o próprio autor.

Figura 81 - Corrente do motor CC com controle PID-2 e PID-2 com RNA.




Fonte: o próprio autor.

• No último caso, os ganhos do novo controlador PID-3 passam para $P = 1$, $I = 0$ e $D = 0$. Com isso, não se utilizam os ganhos integral e derivativo do controlador PID, sendo apenas um sistema em malha fechada com ganho unitário. Os ganhos do CEV-RNA para este caso são $k_R = 100$ e $\delta_R = 0, 1$.

Na Figura (82), os resultados da velocidade para o terceiro caso são apresentados. Verifica-se que o controle em malha fechada com ganho unitário é suficiente para estabilizar a planta, contudo, a velocidade do motor não segue o sinal de referência. Esta condição de operação e controle é favorável para o acréscimo da RNA. Comparando os resultados, o motor passa a seguir o sinal de velocidade desejado.


As tensões e as correntes estão na Figura (83) e na Figura (84), respectivamente. Pode ser visto que em ambas as estratégias de controle, as tensões não apresentam valores elevados, porém, as correntes apresentam pequenos picos, quando o controle é apenas realizado pelo controlador PID-3.

Figura 82 - Velocidade do motor CC com controle PID-3 e PID-3 com RNA.



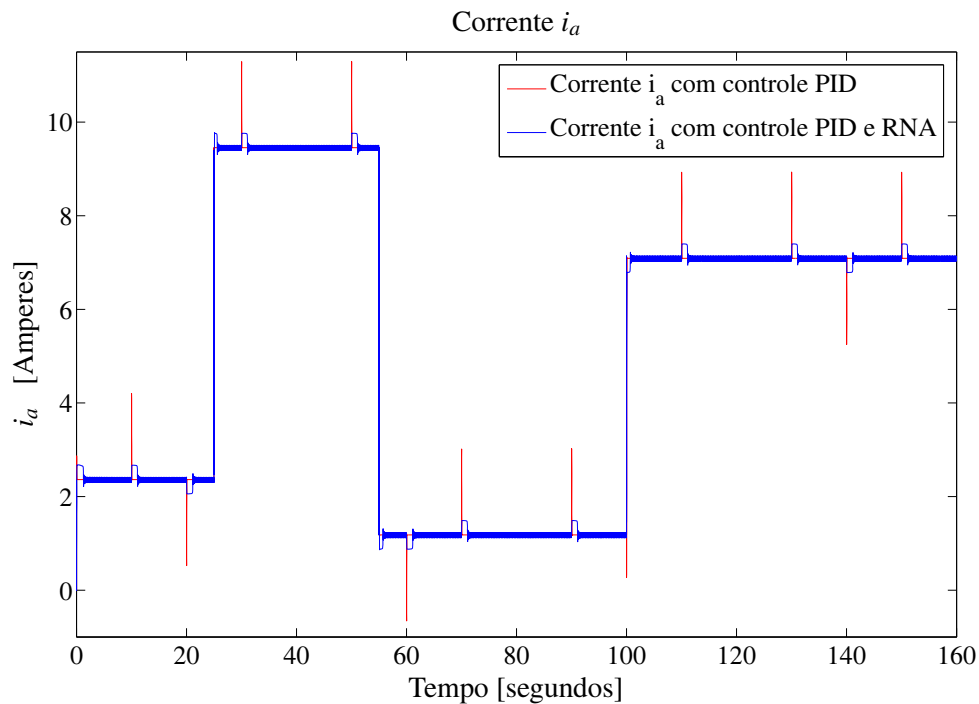
Fonte: o próprio autor.

Figura 83 - Tensão do motor CC com controle PID-3 e PID-3 com RNA.



Fonte: o próprio autor.

Figura 84 - Corrente do motor CC com controle PID-3 e PID-3 com RNA.



Fonte: o próprio autor.

5.2 MOTOR DE INDUÇÃO TRIFÁSICO (MIT)

Máquinas assíncronas ou de indução são o tipo mais utilizado em aplicações industriais. Sua principal vantagem é a eliminação de todos os contatos elétricos deslizantes, resultando em uma construção extremamente simples, segura e fisicamente robusta, o que proporciona a realização de sua manutenção em períodos maiores e a menor custo (SILVA; GARCIA; TEIXEIRA, 1998).

O circuito equivalente geralmente deduzido da operação em regime permanente com tensões senoidais demonstra ser inadequado quando se trata de transitórios ou quando o motor é alimentado por um conversor estático. Isso traz a necessidade de se realizar o estudo dinâmico da máquina síncrona.

Métodos de controle eficientes para máquinas de indução são muito pesquisados, especialmente utilizando modelo dinâmico em coordenadas de campo (LEONHARD, 2001), as quais permitem projetos de técnicas de controle semelhantes às empregadas em máquinas de corrente contínua.

Assim, este capítulo trata sobre a modelagem dinâmica de máquinas assíncronas, com dedução de suas equações diferenciais em coordenadas de campo (LEONHARD, 2001; SILVA, 1998).

O modelo matemático do MIT é empregado em simulações computacionais, nas quais, a dinâmica do motor é influenciada por incertezas. Duas estratégias de controle são utilizadas, uma com apenas controladores PID e outra, com controladores PID e RNA, comparando-se o desempenho do motor em malha fechada.

5.2.1 Modelo matemático em coordenadas de campo com corrente de estator imposta

Um modelo de máquina assíncrona em coordenadas de campo é agora apresentado (LEONHARD, 2001). Este modelo consiste na transformação de coordenadas das variáveis da máquina para um sistema de coordenadas definido por uma variável que representa o fluxo magnético no rotor. Dessa forma, pode-se obter um modelo semelhante ao da máquina de CC, tal que todas as variáveis permanecem estáticas.

A expressão para o torque elétrico é

$$m_d = \frac{2}{3} L_0 \text{Im} \left[\dot{i}_S (\dot{i}_R e^{j\varepsilon})^* \right], \quad (80)$$

tal que L_0 é a indutância mútua, \dot{i}_S o vetor corrente do estator, \dot{i}_R o vetor corrente do rotor e ε é o ângulo do rotor. O torque elétrico foi obtido descrevendo a interação entre as correntes do rotor e a onda de fluxo resultante das correntes do estator. Como as correntes do rotor não podem ser medidas em máquinas com rotor gaiola de esquilo, é apropriado substituir $\dot{i}_R e^{j\varepsilon}$ por uma grandeza equivalente que poderia ser medida ou estimada baseada no estator. Uma escolha adequada, como será mostrado, é o vetor corrente de magnetização do rotor representando o fluxo no rotor definido nas coordenadas do estator,

$$\dot{i}_{mR}(t) = \dot{i}_S(t) + (1 + \sigma_R) \dot{i}_R e^{j\varepsilon} = \dot{i}_{mR} e^{j\rho(t)}, \quad (81)$$

sendo que, σ_R é o fator de dispersão do rotor e ρ é a fase do vetor corrente de magnetização no rotor.

Eliminando a corrente do rotor na equação (80), tem-se a seguinte equação

$$m_d = \frac{2}{3} \frac{L_0}{1 + \sigma_R} \text{Im} \left[\dot{i}_S (\dot{i}_{mR} - \dot{i}_S)^* \right],$$

a qual pode ser simplificada como

$$m_d = \frac{2}{3} \frac{L_0}{1 + \sigma_R} \text{Im} \left[\dot{i}_S \dot{i}_{mR}^* \right]. \quad (82)$$

Inserindo o vetor corrente de magnetização conforme equação (81), tem-se

$$m_d = \frac{2}{3} \frac{L_0}{1 + \sigma_R} \dot{i}_{mR} \text{Im} \left[\dot{i}_S e^{-j\rho} \right], \quad (83)$$


sendo que $i_S e^{-j\rho} = i_S e^{j\delta} = i_{Sd} + j i_{Sq}$ representa o vetor corrente do estator visto de uma referência móvel, definido pelo vetor corrente de magnetização i_{mR} . A relação angular dos vetores correntes é representada na Figura (85). O vetor corrente do estator em coordenadas de campo consiste de duas componentes ortogonais,

$$i_{Sd} = \text{Re} [i_S e^{-j\rho}] = i_S \cos \delta_L, \quad (84)$$

$$i_{Sq} = \text{Im} [i_S e^{-j\rho}] = i_S \text{sen} \delta_L,$$

sendo que, i_{Sd} é a corrente do estator direta na direção do vetor corrente de magnetização e i_{Sq} é a corrente do estator em quadratura, perpendicular ao vetor corrente de magnetização.

Figura 85 - Relações angulares dos vetores correntes.



Introduzindo a componente de corrente em quadratura na equação (83), tem-se uma expressão simples

$$m_d(t) = k_{mit} i_{mR} i_{Sq}, \quad k_{mit} = \frac{2}{3} \frac{L_0}{1 + \sigma_R}, \quad (85)$$

a qual, mostra uma das vantagens do vetor corrente do estator em coordenadas de campo, também chamado Orientação por Campo (LEONHARD, 2001).

A equação (85) assemelha-se à expressão para o torque elétrico de uma máquina CC, tal que i_{mR} corresponde ao fluxo principal e i_{Sq} a corrente de armadura. Portanto, i_{Sd} e i_{Sq} são as duas grandezas de entrada independentes controlando o torque do motor, δ_L representa o ângulo de carga que se anula na ausência de carga.

Para obter o modelo completo da máquina assíncrona em coordenadas de campo com cor-

rente de estator imposta, considera-se a seguinte equação de tensão do rotor,

$$R_R \dot{i}_R + L_R \frac{di_R}{dt} + L_0 \frac{d}{dt} (i_S e^{j\varepsilon}) = 0, \quad (86)$$

sendo que L_R é a indutância do rotor, inserindo \dot{i}_{mR} , tem-se a seguinte equação

$$R_R \dot{i}_R + L_0 \frac{d}{dt} \underbrace{[(1 + \sigma_R) \dot{i}_R + i_S e^{-j\varepsilon}]}_{i_{mR} e^{-j\varepsilon}} = 0,$$

que resulta em

$$\tau_R \frac{di_{mR}}{dt} + (1 - j\omega\tau_R) i_{mR} = i_S, \quad (87)$$

sendo que τ_R é a constante de tempo do rotor e $\frac{d\varepsilon}{dt} = \omega$ é a velocidade angular.

Da Figura (85) deduz-se a velocidade angular instantânea dos vetores corrente de magnetização e corrente do estator

$$\frac{d\rho}{dt} = \omega_{mR}(t), \quad (88)$$

$$\frac{d\zeta}{dt} = \omega_1(t) = \omega_{mR} + \frac{d\delta_L}{dt}.$$

Multiplicando a equação (87) por $e^{-j\rho}$ e expandindo a expressão do lado esquerdo, tem-se

$$\tau_R \frac{di_{mR}}{dt} + j\omega_{mR} \tau_R i_{mR} + (1 - j\omega\tau_R) i_{mR} = i_S e^{-j\rho},$$

que pode ser dividida em partes reais e imaginárias

$$\tau_R \frac{di_{mR}}{dt} + i_{mR} = i_{sd}, \quad (89)$$

$$\frac{1}{\omega_B} \frac{d\rho}{dt} = \frac{\omega}{\omega_B} + \frac{i_{Sq}}{\omega_B \tau_R i_{mR}} = \frac{\omega}{\omega_B} + \frac{\omega_2}{\omega_B}. \quad (90)$$

As equações (85), (89) e (90), juntamente com as equações mecânicas

$$J \frac{d\omega}{dt} = m_d(t) - m_L(t), \quad (91)$$

$$J \frac{d\omega}{dt} = \frac{2}{3} L_0 \text{Im} \left[i_S (\dot{i}_R e^{j\varepsilon})^* \right] - m_d(\varepsilon, \omega, t),$$

$$\frac{d\varepsilon}{dt} = \omega, \quad (92)$$

sendo, J é o momento de inércia da máquina e m_L é o torque de carga externa aplicado à máquina, constituem um modelo do motor de indução em coordenadas de campo.

As duas correntes de entrada orientadas por campo são produzidas transformando as correntes do estator com base no ângulo de fluxo ρ . Isto é realizado primeiramente convertendo as três correntes do estator para um sistema bifásico ortogonal,

$$\underline{i}_S(t) = i_{S1} + i_{S2}e^{j\gamma} + i_{S3}e^{j2\gamma} = i_{Sa} + ji_{Sb} . \quad (93)$$

Considerando a condição para correntes trifásicas simétricas, $i_{S1} + i_{S2} + i_{S3} = 0$, isto resulta em

$$\begin{aligned} i_{Sa}(t) &= \frac{3}{2}i_{S1}(t), \\ i_{Sb}(t) &= \frac{\sqrt{3}}{2}[i_{S2}(t) - i_{S3}(t)]. \end{aligned} \quad (94)$$

Essas correntes alternadas (CA) são então, pela transformação em coordenadas de campo, convertidas a grandezas CC,

$$\begin{aligned} \underline{i}_S(t)e^{-j\rho} &= (i_{Sa} + ji_{Sb})(\cos\rho - jsen\rho), \\ \underline{i}_S(t)e^{-j\rho} &= i_{Sd} + ji_{Sq}. \end{aligned} \quad (95)$$

Disto tem-se

$$\begin{aligned} i_{Sd}(t) &= i_{Sa}\cos\rho + i_{Sb}sen\rho, \\ i_{Sq}(t) &= i_{Sb}\cos\rho - i_{Sa}sen\rho. \end{aligned} \quad (96)$$

O ângulo do fluxo ρ é obtido pela integração da equação (90), ou seja, é uma variável interna. A transformação de coordenada essencialmente constitui uma demodulação.

Reescrevendo as equações (89) e (90) e substituindo a equação (85) na equação (91) tem-se

$$\frac{di_{mR}}{dt} = -\frac{1}{\tau_R}i_{mR} + \frac{1}{\tau_R}i_{Sd}, \quad (97)$$

$$\frac{d\rho}{dt} = \omega + \frac{i_{Sq}}{\tau_R i_{mR}}, \quad (98)$$

$$\frac{d\omega}{dt} = \frac{1}{J} \frac{2}{3} \frac{L_0}{(1 + \sigma_R)} i_{mR} i_{Sq} - \frac{1}{J} m_L. \quad (99)$$

Usando os valores base da corrente, velocidade angular e torque mecânico (I_B , ω_B e m_B , respectivamente), o sistema das equações (97), (98) e (99) pode ser normalizado como,

$$\frac{dx_1}{dt} = -\frac{1}{\tau_R}x_1 + \frac{1}{\tau_R}u_1, \quad (100)$$

$$\frac{dx_2}{dt} = \omega_B x_3 + \frac{1}{\tau_R} \frac{u_2}{x_1}, \quad (101)$$

$$\frac{dx_3}{dt} = \frac{k_{mitB}}{\tau_m} x_1 u_2 - \frac{1}{\tau_m} v, \quad (102)$$

sendo que, $u_1 = \frac{i_{sd}}{I_B}$ e $u_2 = \frac{i_{sq}}{I_B}$ são as entradas de controle normalizadas, $x_1 = \frac{i_{mR}}{I_B}$ é a amplitude do vetor corrente de magnetização no rotor normalizado, $x_2 = \rho$ é a fase do vetor corrente de magnetização do rotor, $x_3 = \frac{\omega}{\omega_B} > 0$ é a velocidade angular normalizada, $k_{mitB} = \frac{2}{3} \frac{L_0 I_B^2}{(1+\sigma_R)m_B}$ é constante, $\tau_m = \frac{J\omega_B}{m_B}$ é a constante mecânica da máquina de indução e $v = \frac{mL}{m_B}$ é o torque da carga normalizado.

Considera-se que o parâmetro τ_R é incerto e tem a seguinte variação,

$$\frac{1}{\tau_R} = \frac{1}{\tau_{Rnom}} + \Delta,$$

tal que, $\frac{1}{\tau_{Rnom}}$ é o valor nominal e Δ é a variação desconhecida.

5.2.2 Estratégias de controle para MIT via PID e RNA

O controle vetorial do MIT é realizado por meio de simulações computacionais utilizando controladores PID e comparadas com simulações utilizando uma nova estratégia de controle. A nova estratégia considera o acréscimo da malha controle de contendo a estrutura neural com o CEV-RNA.

O controle PID é formado por três malhas de realimentação, sendo projetado um controlador PID para cada malha de controle. Essas malhas estão representadas no diagrama de blocos da Figura (86). A primeira malha de controle PID é para o controle de velocidade, na segunda malha, realiza-se o controle de torque e o controle do fluxo está na terceira malha de controle (LEONHARD, 2001).

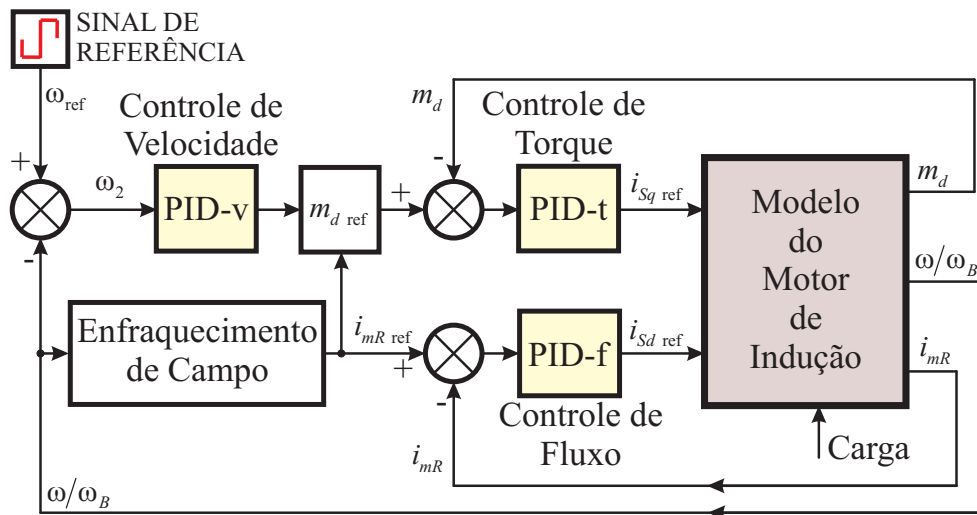
A estratégia de controle proposta é representada do diagrama de blocos da Figura (87), no qual, verifica-se o acréscimo da quarta malha de controle, com a RNA e o CEV-RNA gerando o novo sinal de referência y'_d para a velocidade do motor. Este sinal ajustado pela rede neural auxilia o controle já existente a buscar o sinal de referência para o motor.

5.2.3 Simulações e resultados

O modelo do motor de indução representado nas equações (100), (101) e (102) é submetido a testes de desempenho nas duas estratégias de controle.

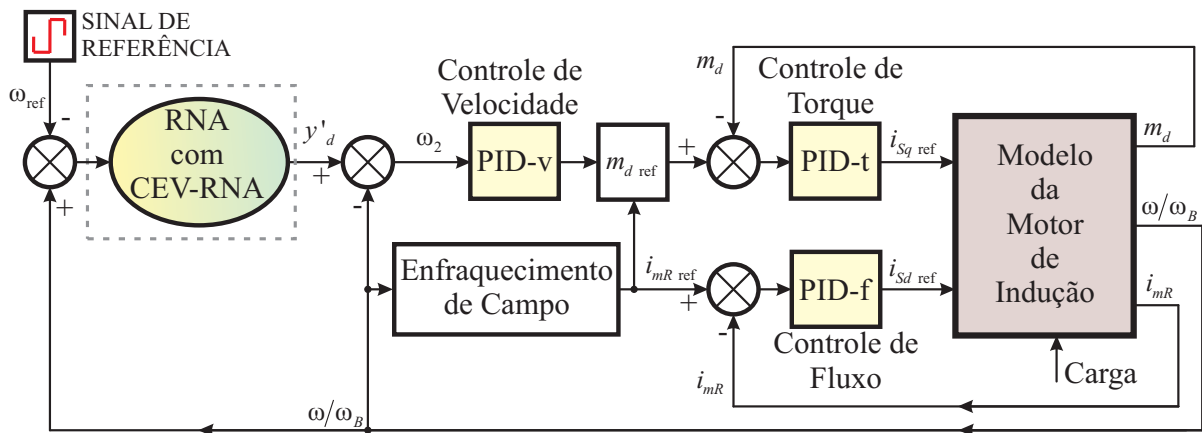
Os parâmetros do MIT estão na Tabela (4) e os resultados das simulações, assim como os sinais de referência e controle são representados em valores por unidade (p.u.).

Figura 86 - Diagrama das malhas de controle via PID utilizando modelo matemático do motor de indução.



Fonte: Leonhard (2001).

Figura 87 - Diagrama das malhas de controle via PID e RNA utilizando modelo matemático do motor de indução.



Fonte: o próprio autor.

Tabela 4 - Parâmetros do motor de indução

Parâmetros e Símbolos	Valores
Tensão Nominal (U_B)	220 V
Corrente Nominal (I_B)	4,2 A
Velocidade Nominal (V_B)	1500 rpm
Torque (m_B)	3,274 Nm
Resistência do Estator (R_S)	1,09 Ω
Resistência do Rotor (R_R)	1,14 Ω
Indutância do Estator (L_S)	100 mH
Indutância do Rotor (L_R)	100 mH
Indutância Mútua (L_0)	92 mH
Momento de Inércia (J)	$3,2 \times 10^{-4} \text{ Kg m}^2$
Fator de Dispersão do Rotor (σ_R)	0,08
Constante de Tempo do Rotor (τ_{Rnom})	87,7 ms

Fonte: Silva (1998).


O parâmetro não-linear incerto $\frac{1}{\tau_R}$ escolhido é uma função variável no tempo dado por

$$\frac{1}{\tau_R} = \frac{1}{\tau_{Rnom}} [1 + 0,1 \text{sen}(10t)].$$

As análises de desempenho do motor são realizadas em seis casos, alterando-se as estratégias de controle (Figura (86) e Figura (87)), e as condições de operação do motor.

O conjugado da carga considerada nos dois primeiros casos simulados estão na Figura (88).

Figura 88 - Conjugado da carga para o MIT com controles PID e RNA: casos 1 e 2.




Fonte: o próprio autor.

• O primeiro caso é realizado considerando o modelo do motor de indução submetido a duas simulações: a primeira com os controladores PID e a segunda com os controladores PID mais a RNA. Os ganhos dos controladores PID e CEV-RNA ajustados para estas simulações são, PID-v: $P = 3$, $I = 15$ e $D = 0,08$, PID-t: $P = 1$, $I = 1$ e $D = 0$, PID-f: $P = 5$, $I = 15$ e $D = 0$, e RNA: $k_R = 10$ e $\delta_R = 0,01$.

O sinal de referência e a velocidade do motor para a simulação utilizando o controle via PID estão na Figura (89a). As correntes estatóricas i_{s1} , i_{s2} e i_{s3} estão na Figura (89b). O projeto destes controladores PID são capazes de manter o motor estável, desde que pequenas cargas sejam colocadas no eixo do motor. O aumento do torque da carga aos 13 segundos de simulação, desestabiliza o sistema, sendo necessário abortar a simulação.


Figura 89 - Velocidade e correntes estatóricas do MIT com controle PID: caso 1.



Fonte: o próprio autor.

Os resultados da velocidade do motor e das correntes estatóricas considerando o acréscimo da estrutura neural estão na Figura (90). O acréscimo da malha de controle com a RNA melhora consideravelmente a resposta do motor, mantendo a velocidade muito próxima da desejada, além do motor permanecer estável em todo o período de simulação. As melhorias alcançadas no controle da velocidade do motor não afetam os níveis das correntes estatóricas, os quais, permaneceram dentro dos limites nominais da máquinas. Características importantes encontradas neste tipo de estratégia de controle.

Figura 90 - Velocidade e correntes estatóricas do MIT com controles PID e RNA: caso 1.



• O segundo caso é realizado considerando as mesmas condições do caso anterior, no qual apenas o ganho derivativo do controlador PID-v é ajustado. Com isso, os valores dos ganhos dos controladores ficam, PID-v: $P = 3$, $I = 15$ e $D = 0$, PID-t: $P = 1$, $I = 1$ e $D = 0$, PID-f: $P = 5$, $I = 15$ e $D = 0$, e RNA: $k_R = 10$ e $\delta_R = 0,01$.

Na Figura (91) os resultados da simulação com apenas o controle PID são apresentados, sendo que na Figura (91a) encontram-se o sinal de referência e a velocidade real do motor e na Figura (91b) estão as correntes i_{s1} , i_{s2} e i_{s3} . Nesse caso, os controladores PID conseguem controlar a máquina, mantendo-a estável em todo o período de simulação, porém, não apresenta muita precisão em relação ao sinal de referência para a velocidade. Essas diferenças na velocidade do motor podem ser vistas durante as mudanças bruscas no sinal de referência e nos momentos de entrada de carga no eixo do motor.

As correntes estatóricas i_{s1} , i_{s2} e i_{s3} permanecem dentro dos limites nominais da máquina, mesmo nos momentos transitórios críticos, isto é, nos momentos de reduções e aumentos bruscos de velocidade e aumentos de carga no eixo do motor.

O acréscimo da malha de controle com a rede neural mais uma vez melhora o desempenho do motor. Os resultados para esta simulação estão na Figura (92). Na Figura (92a) a velocidade do motor segue com melhor precisão o sinal de referência em relação a simulação sem a RNA. Nos períodos de mudanças repentinas de carga e velocidade surgem pequenas oscilações.

Figura 91 - Velocidade e correntes estatóricas do MIT com controle PID: caso 2.






Figura 92 - Velocidade e correntes estatóricas do MIT com controles PID e RNA: caso 2.



O ajuste mais preciso da velocidade do motor não acarretou em correntes mais elevadas, como pode ser visto na Figura (92b), mostrando-se assim uma boa solução de controle para o motor nestas condições operacionais.

Para as simulações dos próximos quatro casos, o torque da carga considerado no eixo do motor é alterado segundo a Figura (93). Os ganhos dos controladores também são mantidos iguais nas simulações desses últimos casos (PID-v: $P = 3$, $I = 15$ e $D = 0$, PID-t: $P = 1$, $I = 1$ e $D = 0$, PID-f: $P = 5$, $I = 15$ e $D = 0$, e RNA: $k_R = 10$ e $\delta_R = 0,01$), sendo apenas alterado o sinal de referência da velocidade ω_{ref} .

Figura 93 - Conjugado da carga para o MIT com controles PID e RNA: casos de 3 à 6.



Fonte: o próprio autor.

Para as simulações dos casos 3 e 4 considera-se um sinal de referência com velocidades medianas, sendo ora em apenas um sentido de giro, ora com reversão na rotação do motor.

- Nas simulações do terceiro caso, considera-se o sinal de referência de velocidades mantendo o motor em apenas um sentido de giro, chegando a velocidades de até 0,6 p.u..

A resposta da velocidade do motor e as correntes i_{s1} , i_{s2} e i_{s3} , utilizando apenas os controladores PID, estão na Figura (94), na qual o motor segue o sinal de referência, apresentando pequenas mudanças de velocidade, principalmente com a entrada da carga. Todavia as correntes estáticas permanecem sempre abaixo do limite nominal da máquina.

A simulação considerando a estratégia de controle da Figura (87) é novamente realizada. Contudo, pelos resultados mostrados na Figura (95) não podem ser vistas melhorias na resposta apresentada. A resposta da velocidade do motor torna-se um pouco diferente, porém, apresentando oscilações durante as trocas bruscas de velocidade e entrada de carga.

Figura 94 - Velocidade e correntes estatóricas do MIT com controle PID: caso 3.

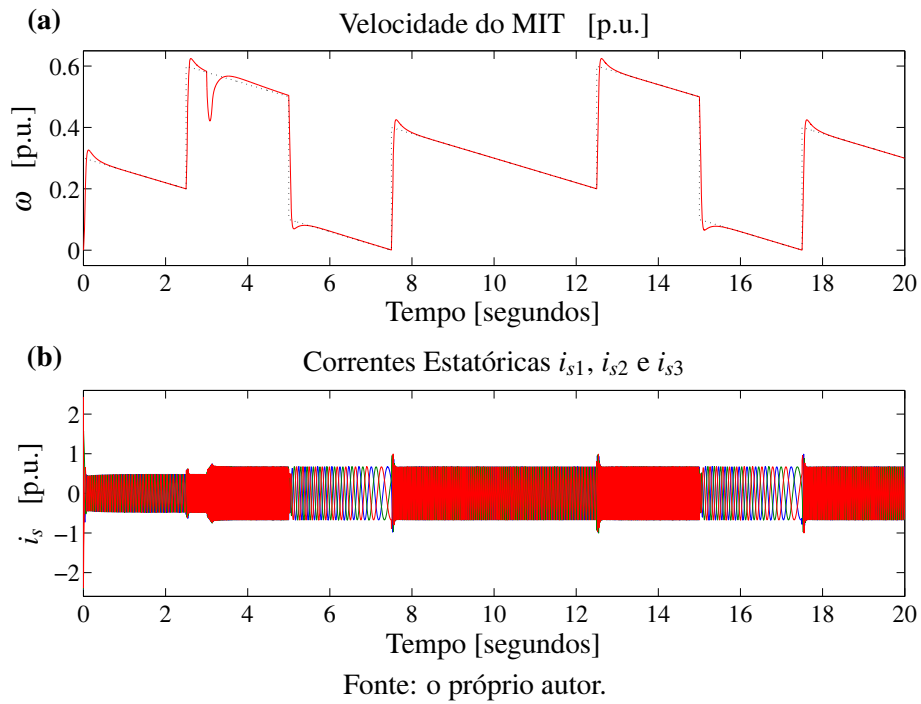



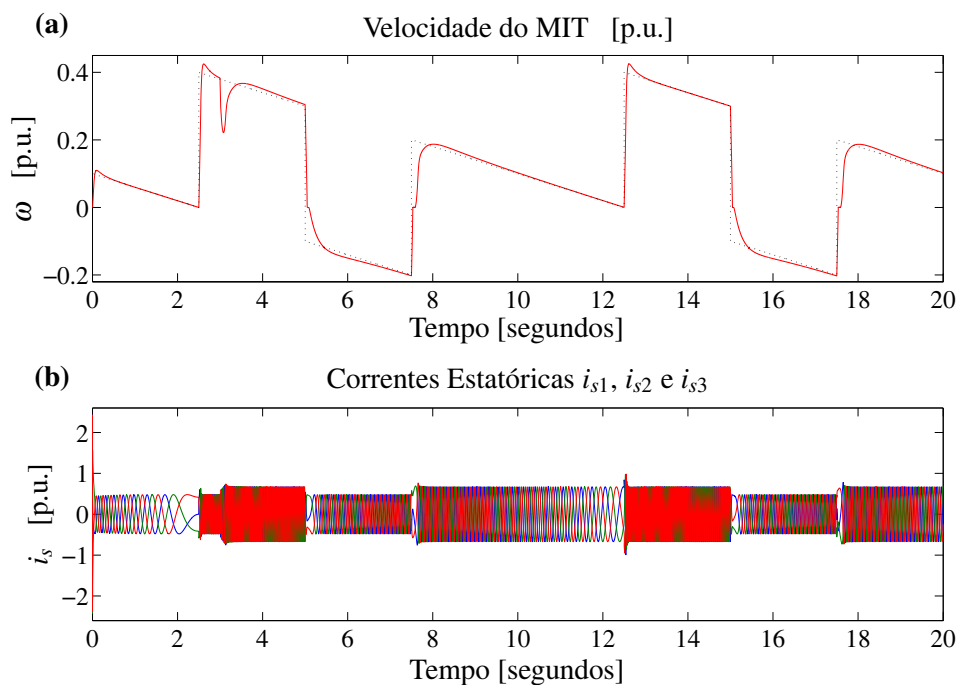
Figura 95 - Velocidade e correntes estatóricas do MIT com controles PID e RNA: caso 3.



- O quarto caso é realizado considerando o sinal de referência apresentando a mesma variação da amplitude pico a pico da velocidade, porém, com reversão no sentido de giro.

Os resultados da simulação desconsiderando a malha da RNA são dados na Figura (96). O sinal de referência e a velocidade do motor estão na Figura (96a) e as correntes na Figura (96b). Assim como nos casos anteriores, o motor não busca com perfeição o sinal de referência nos momentos críticos com variações repentinas de velocidade e carga, e as correntes i_{s1} , i_{s2} e i_{s3} , permanecem dentro dos limites paramétricos da máquina. Em alguns períodos de simulação, o motor reverte o sentido de giro, tal que, naturalmente ocorre uma inversão da sequência de fases entre as três correntes estatóricas.

Figura 96 - Velocidade e correntes estatóricas do MIT com controle PID: caso 4.




Fonte: o próprio autor.

Na Figura (97) os resultados da simulação considerando o acréscimo da estrutura neural são apresentados. Verifica-se que, assim como no terceiro caso, não houve vantagens em se utilizar esta estratégia de controle em relação a simulação com apenas os controladores PID, uma vez que a velocidade do motor sofre pequenas variações indesejadas nos momentos críticos da simulação. Esta análise de desempenho torna-se importante pois verifica-se que, quando uma estratégia de controle consegue atuar eficientemente no desempenho de sistemas, o acréscimo da estrutura neural não traz melhorias consideráveis.

- No quinto caso considera-se o motor trabalhando com velocidades reduzidas e reversão no sentido de giro. Estas condições são impostas, uma vez que o modelo matemático do motor é não-linear e incerto, verificando-se a eficiência da estratégia de controle frente à mudanças

Figura 97 - Velocidade e correntes estatóricas do MIT com controles PID e RNA: caso 4.



Fonte: o próprio autor.

nas dinâmicas das não-linearidades e incertezas paramétricas. Os resultados da simulação com apenas os controladores PID estão na Figura (98). Pode ser visto que em baixas velocidades, a resposta do motor tem uma dinâmica ruim, apresentando lentidão em buscar o sinal de referência.

Pela Figura (99), pode ser visto que o acréscimo da estrutura neural melhora a resposta da máquina. O motor passa a buscar com mais rapidez o sinal de referência, apresentando pequenas oscilações em momentos críticos, mantendo as correntes estatóricas dentro dos limites nominais da máquina.

Nestas condições, em que uma estratégia de controle mantém um sistema estável, porém, com uma resposta ruim, a rede neural consegue agregar uma dinâmica mais rápida ao sistema, fazendo-o permanecer por mais tempo sobre o sinal de referência.

- O sexto caso é realizado considerando um sinal de referência constante em todo o período de simulação, sendo possível verificar a diferença na dinâmica da resposta da máquina.

Na Figura (100) encontram-se o sinal de referência, a velocidade real do motor e as correntes do estator, obtidas na simulação com controle puramente PID. Verifica-se que os controladores conseguem manter o motor estável sobre o sinal de referência, apresentando discrepâncias apenas com a entrada da carga no eixo do motor, o qual, o motor apresenta uma dinâmica lenta ao buscar o sinal desejado.

Figura 98 - Velocidade e correntes estatóricas do MIT com controle PID: caso 5.




Figura 99 - Velocidade e correntes estatóricas do MIT com controles PID e RNA: caso 5.





Figura 100 - Velocidade e correntes estatóricas do MIT com controle PID: caso 6.



Fonte: o próprio autor.

A alteração da dinâmica do motor pode ser vista na Figura (101), na qual a malha de controle com a RNA está presente na estratégia de controle. Verifica-se que no instante em que a carga entra no eixo do motor, ele desacelera, porém, busca rapidamente o sinal de referência desejado. Com referência às correntes do estator, destaca-se também, que os sinais não se elevam bruscamente, permanecendo dentro dos limites nominais da máquina.

5.3 CONCLUSÕES PARCIAIS


Foi apresentado neste capítulo o modelo matemático linear de um motor de CC e um modelo não-linear de motor de indução em coordenadas de campo com corrente de estator imposta.

Simulações computacionais foram realizadas nos dois motores, alterando-se os projetos dos controladores, cargas presentes no eixo do motor e sinais de referência.

As simulações foram realizadas comparando o desempenho dos motores alterando as estratégias de controle. Em ambos os motores, utilizou-se primeiramente uma estratégia de controle formada por controladores PID e posteriormente, a RNA com o CEV-RNA foi acrescentado em outra malha de controle.

Pelos resultados, verifica-se que o fato de acrescentar a estrutura neural Adaline, os motores, na maioria dos casos, passaram a apresentar respostas melhores, uma vez que, nos casos em que os controladores PID apresentavam um bom projeto e, conseqüentemente, o motor uma

Figura 101 - Velocidade e correntes estatóricas do MIT com controles PID e RNA: caso 6.



Fonte: o próprio autor.

boa resposta, a estrutura neural não apresentou grandes vantagens sobre o controle via PID. Isto pode ser visto nas simulações do terceiro e quarto caso do motor de indução.

A utilização da RNA trouxe outros pontos importantes, como por exemplo, rapidez na dinâmica do sistema, além de manter o sistema por mais tempo sobre o sinal de referência com sinais de controle dentro dos parâmetros nominais do motor e, no caso do motor de CC, os picos que ocorriam principalmente nas tensões aplicadas nos terminais da máquina, sofreram fortes reduções.

6 ESTRATÉGIAS DE CONTROLE VETORIAIS DE MIT ROBUSTAS A INCERTEZAS E VARIAÇÕES PARAMÉTRICAS

Neste capítulo, a estrutura neural Adaline com adaptação de pesos em tempo real é utilizada no auxílio de controlador e observador aplicados no modelo matemático do motor de indução não-linear sujeito a incertezas e perturbações, apresentando inicialmente uma dinâmica linear e posteriormente não-linear.

O controlador e o observador são projetados segundo a estratégia de Estrutura Variável e Modos Deslizantes, CEV-MIT e OEV-MIT, respectivamente, aplicados ao modelo matemático do motor de indução trifásico não-linear descrito no Capítulo (5), pelas equações normalizadas (100), (101) e (102) (SILVA; GARCIA; TEIXEIRA, 1998).

O observador de estados é utilizado tanto para estimar os estados da planta, como em um esquema de detecção e adaptação do controlador, o qual, sua resposta é essencial para gerar resíduos e assim, indicar a condição de operação do sistema.

Os resultados das simulações considerando o esquema de detecção e adaptação do controlador via observador são comparados com resultados obtidos em simulações utilizando duas novas estratégias de controle para acomodação de incertezas/perturbações formada por RNA e CEV-RNA.

6.1 PROJETO DO CONTROLADOR COM ESTRUTURA VARIÁVEL COM MODOS DESLIZANTES (CEV-MIT)

O projeto de um CEV-MIT aplicado no modelo matemático descrito pelas equações (100), (101) e (102) é apresentado. O objetivo de controle é estabilizar a velocidade angular do motor e o módulo do vetor corrente de magnetização da máquina assíncrona em respectivos sinais de referência (SILVA; GARCIA; TEIXEIRA, 1998).

6.1.1 Projeto da superfície de deslizamento (SD)

Para o projeto da Superfície de Deslizamento (SD) é utilizado o Método de Controle Equivalente (DECARLO; ZAK; MATTHEWS, 1988), que consiste na determinação do movimento do sistema sobre a superfície $\sigma(t, x) = 0$.

No Deslizamento, considerando o Modo Deslizante (MD) ideal, $\sigma(t, x) = \dot{\sigma}(t, x) = 0$. As-

sim,

$$\dot{\sigma}(t, x) = \frac{\partial \sigma}{\partial x} \dot{x} + \frac{\partial \sigma}{\partial t} = 0. \quad (103)$$

Considerando a dinâmica do sistema dada pela equação

$$\dot{x} = A(t, x)x(t) + B(t, x)u(t) + Dv(t), \quad (104)$$

e substituindo (103) em (104), o controle equivalente u_{eq} fica

$$u_{eq} = - \left[\frac{\partial \sigma}{\partial x} B(t, x) \right]^{-1} \left[\frac{\partial \sigma}{\partial x} A(t, x)x + \frac{\partial \sigma}{\partial x} Dv + \frac{\partial \sigma}{\partial t} \right]. \quad (105)$$

A dinâmica em MD é dada por

$$\dot{x} = \left[I - B(t, x) \left[\frac{\partial \sigma}{\partial x} B(t, x) \right]^{-1} \frac{\partial \sigma}{\partial x} \right] A(t, x)x - B(t, x) \left[\frac{\partial \sigma}{\partial x} B(t, x) \right]^{-1} \frac{\partial \sigma}{\partial t}, \quad (106)$$

com $\sigma(t, x) = 0$.

A equação (106) representa o comportamento dinâmico do sistema dado em (103) na SD, assim pode-se escolher o comportamento desejado e determinar a SD. Como o objetivo de controle está ligado às variáveis x_1 e x_3 , são utilizadas somente as equações (100) e (102) já que ambas não dependem de x_2 .

Deste modo, escolhe-se as variáveis x_1 e x_3 com o seguinte comportamento,

$$\dot{x}_1 = -c_1(x_1 - x_{1Ref}), \quad (107)$$

$$\dot{x}_3 = -c_2(x_3 - x_{3Ref}), \quad (108)$$

sendo que c_1 e c_2 são constantes positivas, x_{1Ref} e x_{3Ref} são as entradas de referência “por unidade” (p.u.).

Assim, usando as equações (105) e (106), uma superfície de deslizamento adequada pode ser escolhida da seguinte forma,

$$\sigma_1(t, x) = x_1 + c_1 \int_0^t (x_1 - x_{1Ref}) d\tau, \quad (109)$$

$$\sigma_2(t, x) = x_3 + c_2 \int_0^t (x_3 - x_{3Ref}) d\tau. \quad (110)$$

6.1.2 Projeto da lei de controle

O objetivo desta fase é encontrar uma lei de controle descontínua que garanta a existência do MD. O método direto de Lyapunov é usado para análise da estabilidade da SD (DECARLO; ZAK; MATTHEWS, 1988; DRAZENOVIC, 1969; CHUNG et al., 1994). A lei de controle escolhida é formada por uma parte contínua e outra descontínua,

$$u = u_{eq} + u_{NL} ,$$

sendo que u_{eq} é o controle equivalente visto do projeto da SD e u_{NL} é o controle descontínuo (chaveado), para $x_1 \neq 0$.

Uma escolha para o motor de u_{eq} e u_{NL} é dada por,

$$u_{eq1} = x_1 - \tau_R c_1 (x_1 - x_{1Ref}) , \quad (111)$$

$$u_{eq2} = \frac{1}{k_{mitB} x_1} [v - \tau_m c_2 (x_3 - x_{3Ref})] ,$$

$$u_{NL1} = -\tau_R P_1 \frac{\sigma_1}{|\sigma_1| + \eta} , \quad (112)$$

$$u_{NL2} = -\frac{\tau_m}{k_{mitB} x_1} P_2 \frac{\sigma_2}{|\sigma_2| + \eta} .$$

A condição de existência do MD é satisfeita escolhendo a seguinte função de Lyapunov,

$$V(\sigma) = \frac{1}{2} \sigma^T \sigma = \frac{1}{2} (\sigma_1^2 + \sigma_2^2) > 0 , \quad (113)$$

e a derivada no tempo

$$\dot{V}(\sigma) = \frac{1}{2} \sigma^T \dot{\sigma} = \sigma_1 \dot{\sigma}_1 + \sigma_2 \dot{\sigma}_2 < 0 . \quad (114)$$

Para satisfazer a equação acima, de (100), (101), (102), (111) e (112), obtêm-se

$$\sigma_1 \dot{\sigma}_1 = -\sigma_1 P_1 \frac{\sigma_1}{|\sigma_1| + \eta} = -P_1 \frac{\sigma_1^2}{|\sigma_1| + \eta} < 0 , \quad (115)$$

$$\sigma_2 \dot{\sigma}_2 = -\sigma_2 P_2 \frac{\sigma_2}{|\sigma_2| + \eta} = -P_2 \frac{\sigma_2^2}{|\sigma_2| + \eta} < 0 . \quad (116)$$

Isto é verdade para as constantes de projeto $P_1 > 0$ e $P_2 > 0$. Assim, as equações (111) e (112) descrevem a lei de controle satisfazendo a condição de existência do MD.

6.2 PROJETO DO OBSERVADOR COM ESTRUTURA VARIÁVEL E MODOS DESLIZANTES (OEV-MIT)

Nesta tese, apenas a saída da planta (x_3) é considerada disponível, sendo assim, um observador se faz necessário. O OEV-MIT é descrito pelas seguintes equações (SILVA; GARCIA; TEIXEIRA, 1998)

$$\dot{\tilde{x}}_1 = -\frac{1}{\tau_{Rnom}}(\tilde{x}_1 - u_1), \quad (117)$$

$$\dot{\tilde{x}}_2 = \omega_B \tilde{x}_3 + \frac{1}{\tau_{Rnom}} \frac{u_2}{\tilde{x}_1}, \quad (118)$$

$$\dot{\tilde{x}}_3 = \frac{1}{\tau_m} (k_{mit_B} \tilde{x}_1 u_2 - \tilde{v}) + L_1 \text{sgn}(x_3 - \tilde{x}_3), \quad (119)$$

$$\dot{\tilde{v}} = L_2 \text{sgn}(x_3 - \tilde{x}_3), \quad (120)$$

sendo que \tilde{x}_1 , \tilde{x}_2 e \tilde{x}_3 são os valores estimados das variáveis de estado e \tilde{v} é o valor estimado da perturbação de carga.

Definindo os erros, $e_1 = x_1 - \tilde{x}_1$, $e_2 = x_2 - \tilde{x}_2$, $e_3 = x_3 - \tilde{x}_3$ e $e_4 = v - \tilde{v}$, tem-se

$$\dot{e}_1 = -\frac{1}{\tau_{Rnom}} e_1 - \Delta(x_1 - u_1), \quad (121)$$

$$\dot{e}_2 = \omega_B e_3 + \frac{1}{\tau_{Rnom}} \left(\frac{1}{x_1} - \frac{1}{\tilde{x}_1} \right) + \Delta \frac{1}{x_1}, \quad (122)$$

$$\dot{e}_3 = \frac{1}{\tau_m} (k_{mit_B} u_2 e_1 - e_4) - L_1 \text{sgn}(e_3), \quad (123)$$

$$\dot{e}_4 = -L_2 \text{sgn}(e_3). \quad (124)$$

Considerando $\Delta = 0$, da equação (121), $e_1 = 0$ no espaço de estados. Agora, na SD $e_3 = 0$, então $\dot{e}_3 = 0$ e também considerando $e_1 = 0$ segue que

$$\frac{1}{\tau_m} e_4 = -L_1 \text{sgn}(e_3).$$

Tomando $L_2 = -K_O L_1$, sendo que K_O é positivo, então,

$$\dot{e}_2 = 0 \quad \text{e} \quad \dot{e}_4 = -\frac{K_O}{\tau_m} e_4,$$

e então os valores no espaço de estados de e_4 são zero. Portanto, $e_1 = e_4 = 0$ e $e_2 = e_{20}$ no espaço de estados, tal que, $e_{20} \in \mathfrak{R}$.

A condição de existência do MD é

$$\frac{1}{2} \frac{d}{dt} (e_3^2) = e_3 \dot{e}_3 = e_3 \left[\frac{1}{\tau_m} (k_{mit_B} e_1 u_2 - e_4) - L_1 \text{sgn}(e_3) \right] < 0.$$

$$\text{Assim, } L_1 > \max \left| \frac{1}{\tau_m} (k_{mit_B} u_2 e_1 - e_4) \right|.$$

6.3 ESTRATÉGIA DE ADAPTAÇÃO DO CONTROLADOR

Uma estratégia para diagnóstico das condições de operações de sistemas e acomodação do controlador é agora apresentada (GARCIA et al., 2009; RODRIGUES, 2009; RODRIGUES et al., 2010). Nessa estratégia, é necessário o projeto de uma série de controladores e observadores, um para cada condição de operação do sistema, sendo assim, existe a necessidade de prever quais tipos de incertezas e variações paramétricas podem ocorrer na planta.

O esquema aqui apresentado deve ser capaz de detectar a ocorrência de alterações dos parâmetros nominais da máquina e/ou incertezas que possam surgir no sistema e acomodar os controladores, obtendo-se assim, o melhor desempenho da planta. Essa estratégia é utilizada em duas condições de operação para o motor de indução: na primeira, o motor opera em condições normais, apresentando valores incertos, porém, próximos aos seus valores nominais; na segunda, o sistema opera com valores substancialmente diferentes dos nominais, caracterizando um sistema incerto.

No caso em que o sistema opera em condições normais são utilizados um Controlador e um Observador, ambos com Estrutura Variável e Modos Deslizantes (CEV-MIT-I e OEV-MIT-I, respectivamente), cujos projetos são realizados considerando os valores dos parâmetros nominais da máquina. No caso em que o motor apresenta variação paramétrica, utiliza-se um Controlador com Estrutura Variável e Modos Deslizantes (CEV-MIT-II) e um Observador com Estrutura Variável e Modos Deslizantes (OEV-MIT-II), cujos projetos levam em consideração a possibilidade de ocorrência desta modificação dos parâmetros nominais. Diversos casos podem ser considerados e, portanto, diversos controladores e observadores podem ser previstos.

6.3.1 Resíduos

Considera-se o sistema incerto dado por

$$\begin{aligned} \dot{x}(t) &= Ax(t) + Bu(t) + f(t, x(t)) , \\ y(t) &= Cx(t) . \end{aligned}$$

A saída real da planta $y(t) \in \mathfrak{R}^p$ disponível é comparada com as saídas dos dois observadores para gerar o resíduo: na estrutura do primeiro (OEV-MIT-I) supõe-se que o sistema controlado está com valores nominais, fornecendo a saída $\tilde{y}^I(t) \in \mathfrak{R}^p$ e os estados $\tilde{x}^I(t) \in \mathfrak{R}^n$; no outro observador (OEV-MIT-II) é assumido que o motor está com valores diferentes do nominal, fornecendo a saída $\tilde{y}^{II}(t) \in \mathfrak{R}^p$ e os estados $\tilde{x}^{II}(t) \in \mathfrak{R}^n$. Aqui, a função de resíduo é definida como

$$r^I(t) = \|\bar{y}^I(t) - y(t)\|,$$

e

$$r^{II}(t) = \|\bar{y}^{II}(t) - y(t)\|.$$

6.3.2 Diagnóstico e adaptação do controlador

A diferença entre as funções de resíduos $r(t) = r^I(t) - r^{II}(t)$ é definida como função de decisão e o diagnóstico da variação paramétrica pode ser formulado como

$$\text{i) Se } r^I(t) < r^{II}(t), \quad (125)$$

então o sistema real está operando com valores nominais, sob condições normais.

$$\text{ii) Se } r^I(t) > r^{II}(t), \quad (126)$$

então o sistema real está operando com valores diferentes do nominal, sob condição fortemente incerta.

A função de decisão adapta os controladores para a condição de normal ou incerta segundo,

$$\begin{cases} \text{se } r(t) < 0, \text{ então CEV-MIT-I é ativado.} \\ \text{se } r(t) > 0, \text{ então CEV-MIT-II é ativado.} \end{cases} \quad (127)$$

A Figura (102) ilustra o esquema proposto, tal que a saída da planta é utilizada pelos observadores. As saídas dos observadores são comparadas com a saída real da planta, constituindo-se os resíduos que determinam, por comparação, qual controlador estará controlando a planta.

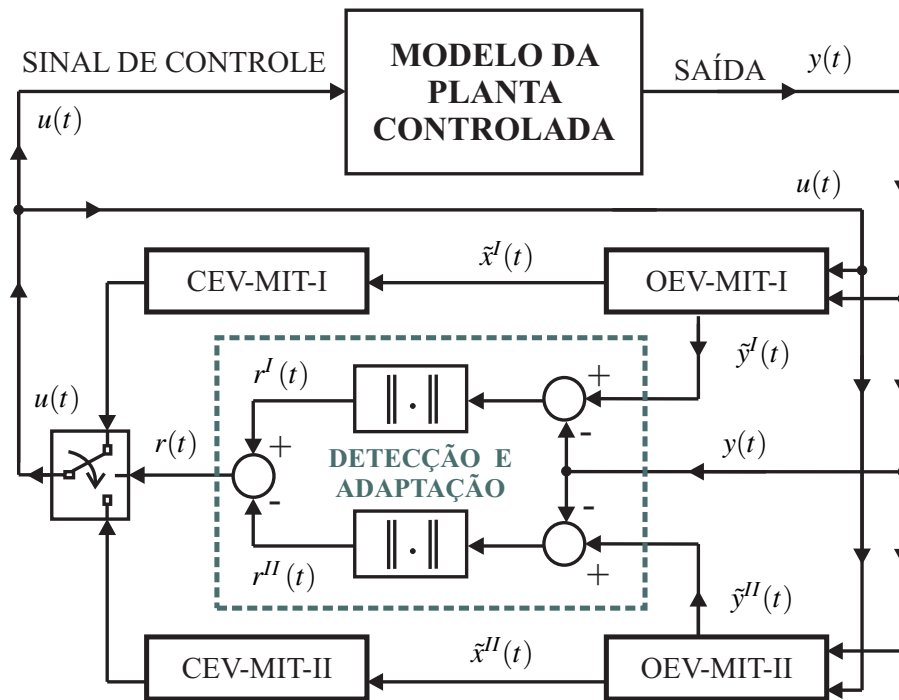
Neste esquema de detecção de anomalias na planta e adaptação do controlador, nunca dois controladores e, conseqüentemente, dois observadores estarão ativos, controlando o sistema.

6.4 ESTRATÉGIAS DE CONTROLE

O motor de indução é submetido a simulações considerando quatro estratégias de controle diferentes utilizando o CEV-MIT e o OEV-MIT, com ou sem detecção de variação paramétrica e adaptação do controlador, ou então com RNA. Nestas simulações considera-se sinais de referência para a velocidade do motor e para a corrente de magnetização do rotor I_{mR} e, acesso apenas a saída do sistema, no caso, a velocidade do motor.

Na Figura (103), é apresentada a primeira estratégia de controle, na qual, por meio do diagrama de blocos, representa-se a malha de controle utilizando apenas o Controlador e o Observador com Estrutura Variável e Modos de Deslizantes (CEV-MIT e OEV-MIT). Nessa estratégia

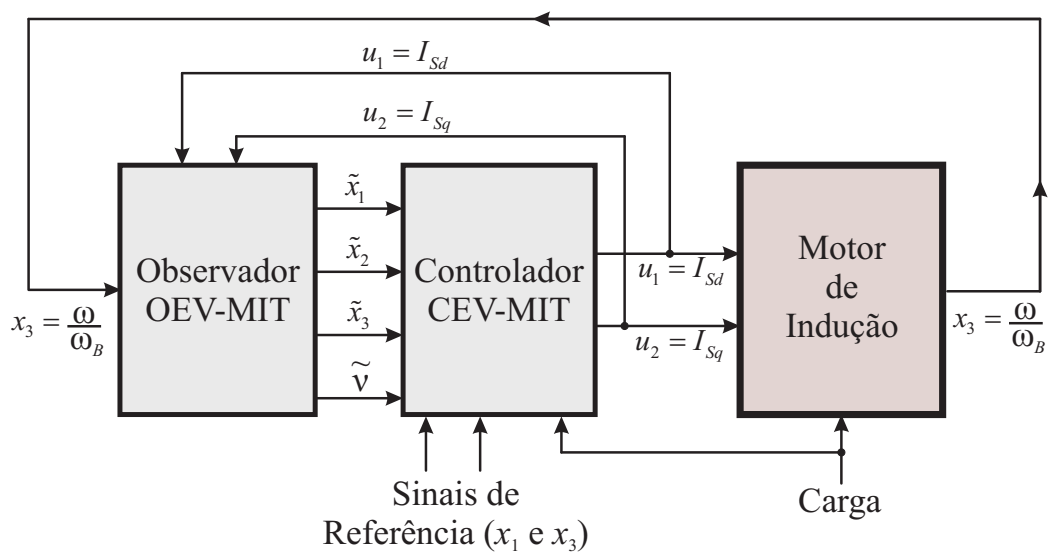
Figura 102 - Esquema de detecção e adaptação do controlador.



Fonte: Rodrigues et al. (2010).

de controle, o observador é utilizado para estimar todos os estados da planta, necessários para o controlador calcular os sinais de controle u_1 e u_2 .

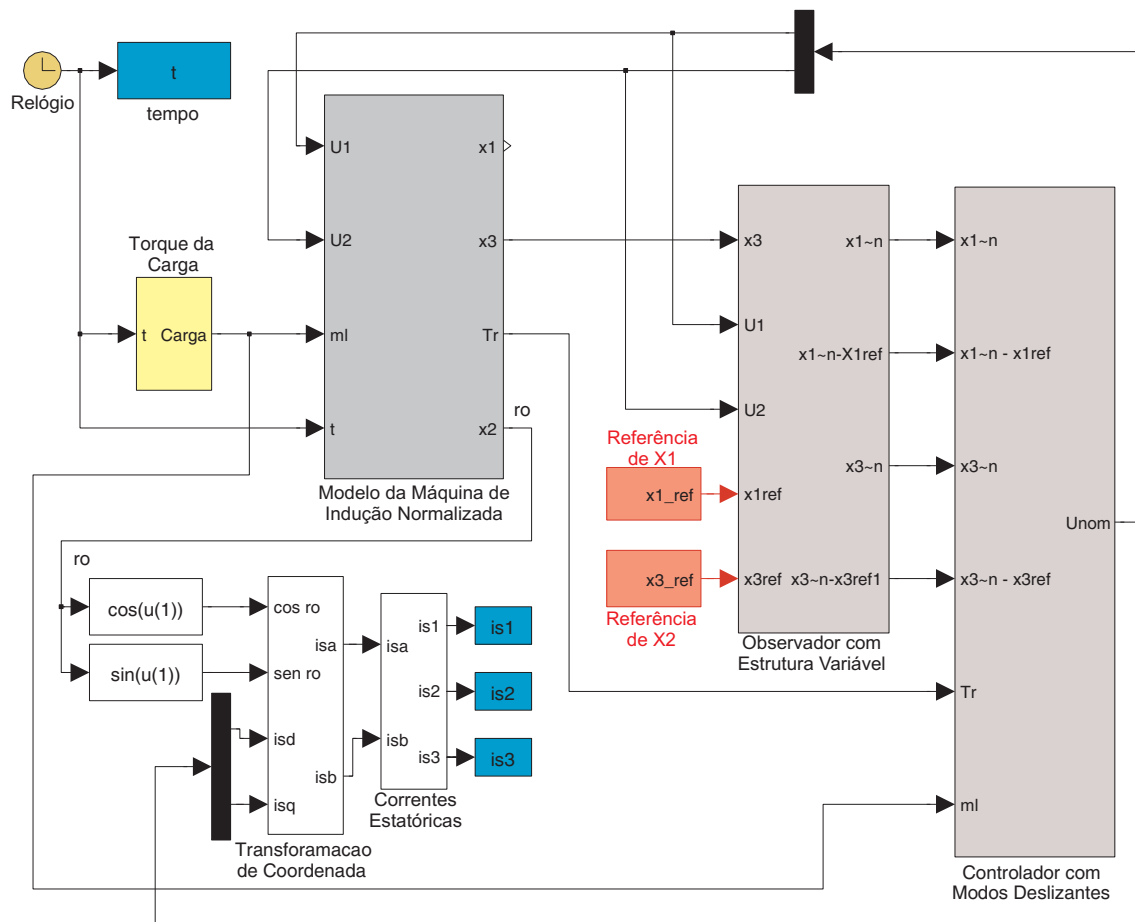
Figura 103 - Estratégia de controle via CEV-MIT utilizando modelo matemático do motor de indução.



Fonte: Silva, Garcia e Teixeira (1998).

A simulação computacional desta estratégia de controle no *software* MATLAB/SIMULINK[®] está na Figura (104). Por meio desta, verifica-se que a saída da planta e os sinais de controle alimentam o observador de estados, o qual gera todos os estados da máquina, imprescindíveis ao CEV/MD. Os sinais de referência para x_1 e x_3 são comparados com os valores calculados pelo observador e também disponibilizados ao controlador.

Figura 104 - Simulação computacional da estratégia de controle CEV-MIT em MIT.

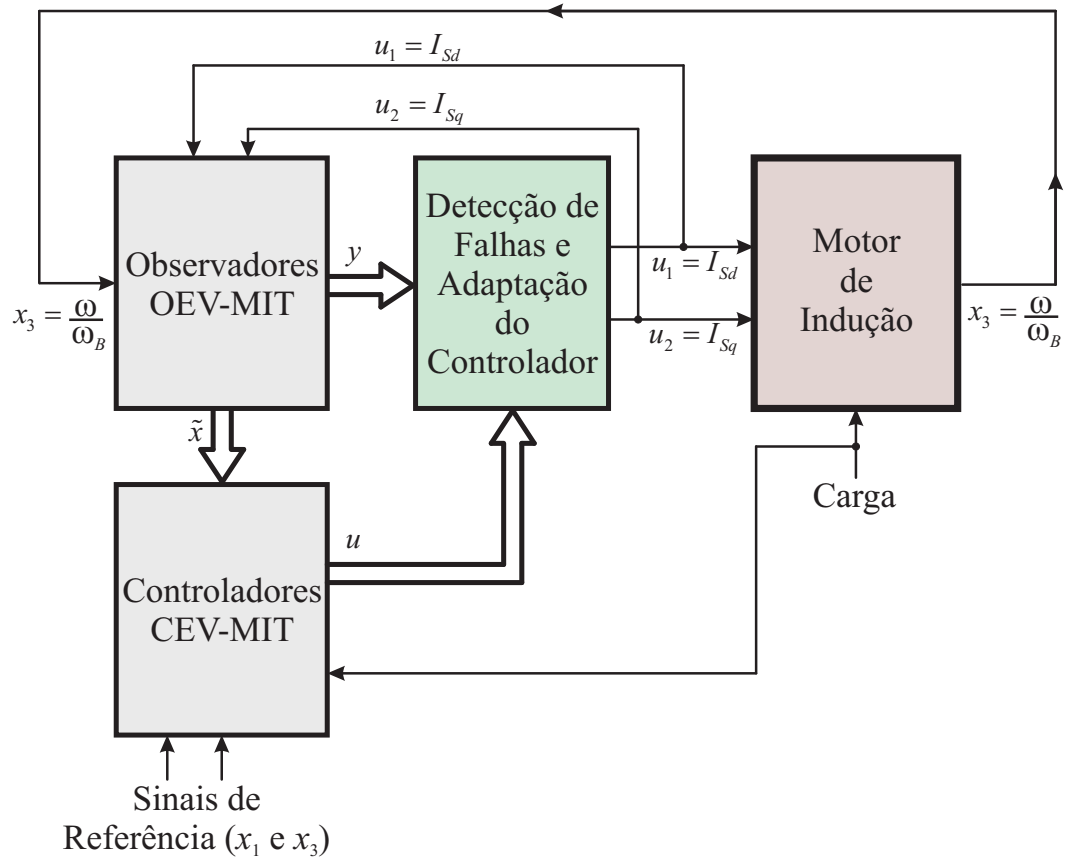


Fonte: o próprio autor.

A segunda estratégia de controle, CEV/AC-MIT, encontra-se na Figura (105). Nessa estratégia, tem-se o acréscimo do esquema de detecção e adaptação do controlador. Sendo assim, são utilizados dois controladores (CEV-MIT-I e CEV-MIT-II) e dois observadores (OEV-MIT-I e OEV-MIT-II), que passam a controlar o sistema de acordo com a condição de operação do sistema, com ou sem perturbação não destrutiva.

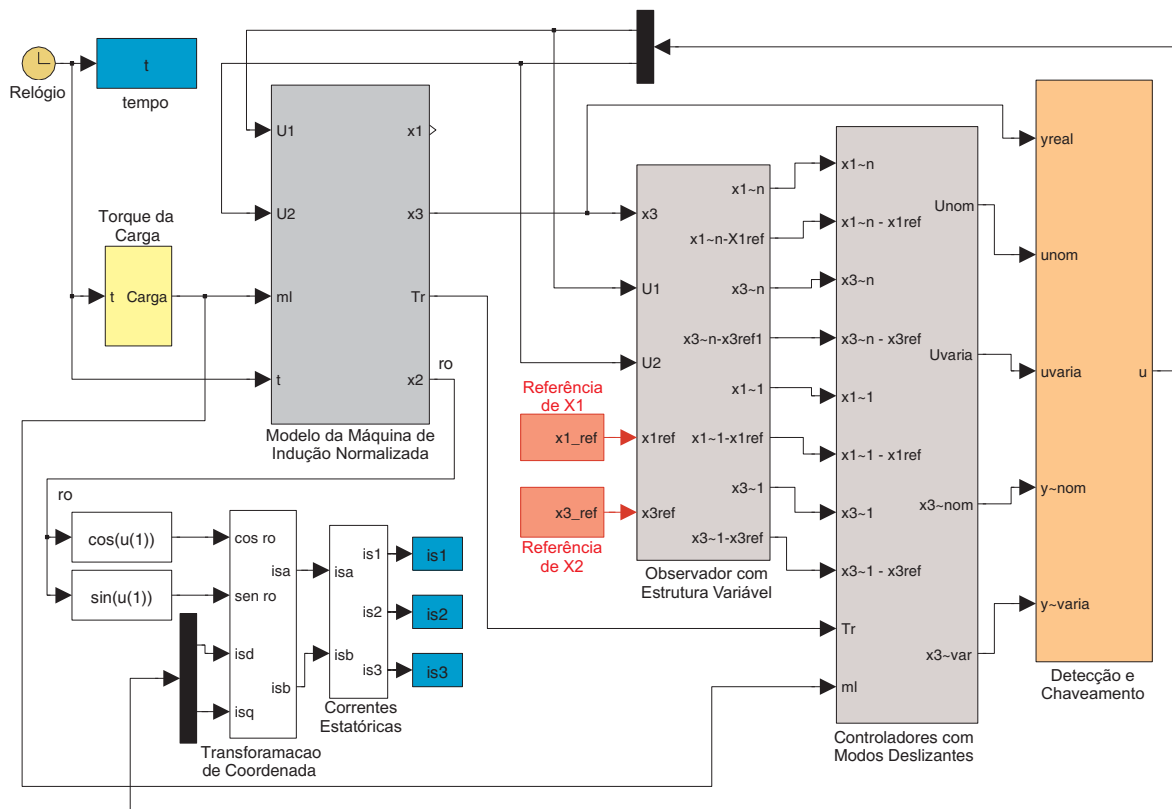
Na Figura (106) tem-se o diagrama de blocos da simulação computacional realizada em que os dois observadores alimentam seus respectivos controladores, responsáveis por calcular os sinais de controle que são escolhidos pelo esquema de detecção para controlar a planta.

Figura 105 - Estratégia de controle CEV/AC-MIT para o modelo matemático do motor de indução utilizando CEV-MIT, detecção e adaptação do controlador.



Fonte: o próprio autor.

Figura 106 - Simulação computacional da estratégia de controle CEV/AC-MIT com adaptação do controlador.

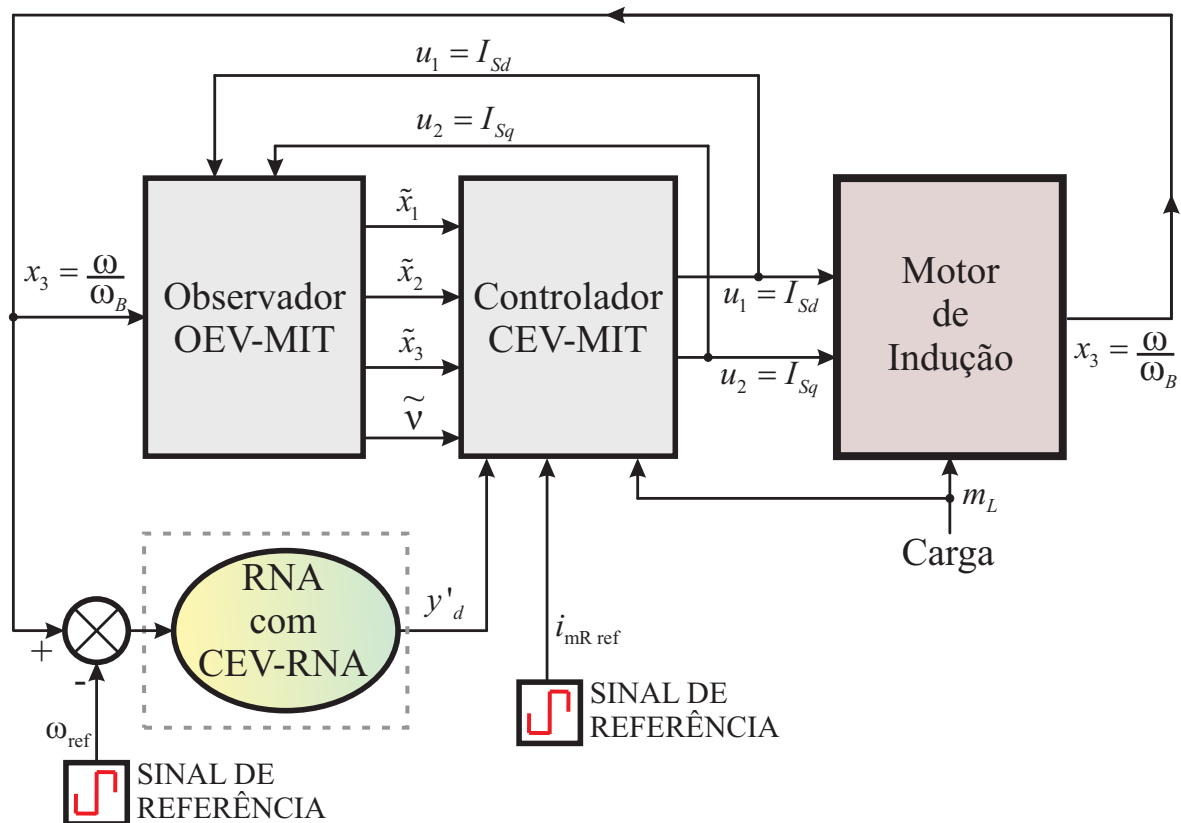


Fonte: o próprio autor.

A terceira estratégia de controle é proposta e esquematizada na Figura (107). A estratégia de controle é formada por duas malhas de controle: a primeira, composta por um controlador e um observador, ambos com estrutura variável e modos deslizantes (CEV-MIT e OEV-MIT, respectivamente); a segunda malha de controle é formada pela RNA Adaline com algoritmo de ajuste de pesos em tempo real via CEV-RNA.

A saída da planta (x_3) é utilizada tanto pelo OEV-MIT, responsável em gerar todos os estados da planta, imprescindíveis ao CEV-MIT, como também, para gerar o sinal de erro entre x_3 e o sinal de referência de velocidade ω_{ref} , utilizado pela RNA, responsável por adaptar o novo sinal de referência y'_d , utilizado pelo CEV-MIT.

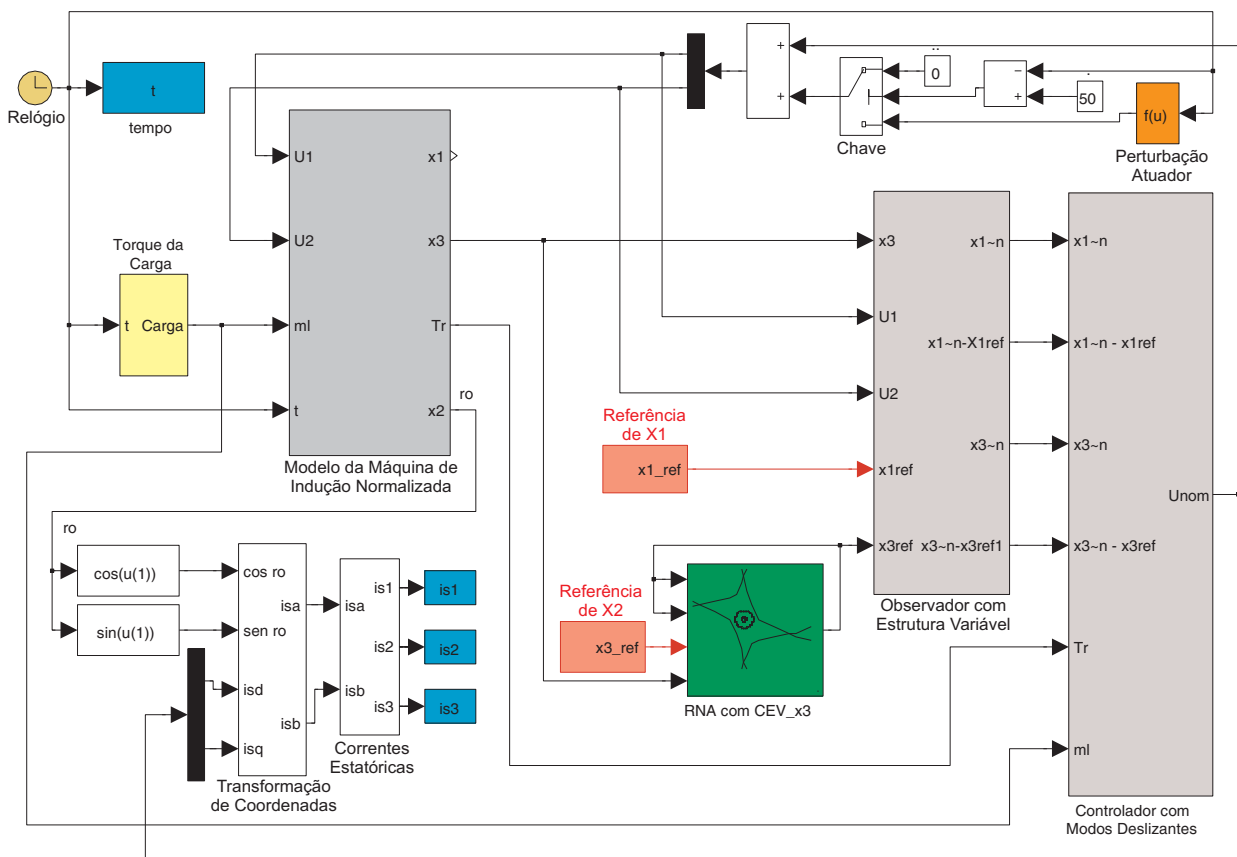
Figura 107 - Estratégia de controle CEV/RNA-MIT-I utilizando modelo matemático do motor de indução.



Fonte: o próprio autor.

O diagrama de blocos da simulação computacional realizada no MATLAB/SIMULINK® da terceira estratégia de controle para o MIT é dado na Figura (108). Nessa Figura é possível verificar as duas malhas de controle, além da inserção de uma perturbação no sinal de controle entregue a planta aqui considerada.

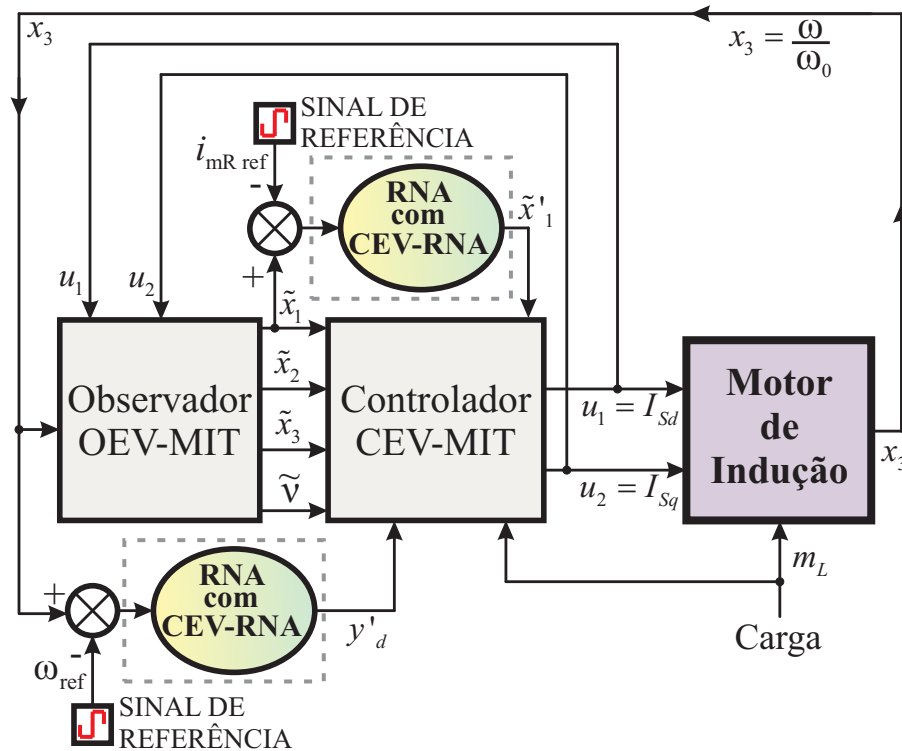
Figura 108 - Simulação computacional da estratégia de controle CEV/RNA-MIT-I em MIT.



Fonte: o próprio autor.

A quarta estratégia de controle vetorial do MIT, CEV/RNA-MIT-II, robusto a incertezas e variações paramétricas é proposta. A estrutura de controle está esquematizada na Figura (109), a qual é formada por três malhas de controle: a primeira, composta por um controlador e um observador, ambos com estrutura variável e modos deslizantes (CEV-MIT e OEV-MIT, respectivamente); a segunda malha de controle é formada pela RNA Adaline com algoritmo de ajuste de pesos em tempo real via CEV-RNA auxiliando o CEV-MIT a manter a velocidade do motor no sinal de referência e a terceira malha, formada por outra RNA, é inserida de forma a contribuir no rastreamento do sinal desejado para i_{mR} .

Figura 109 - Estratégia de controle CEV/RNA-MIT-II utilizando modelo matemático do motor de indução.



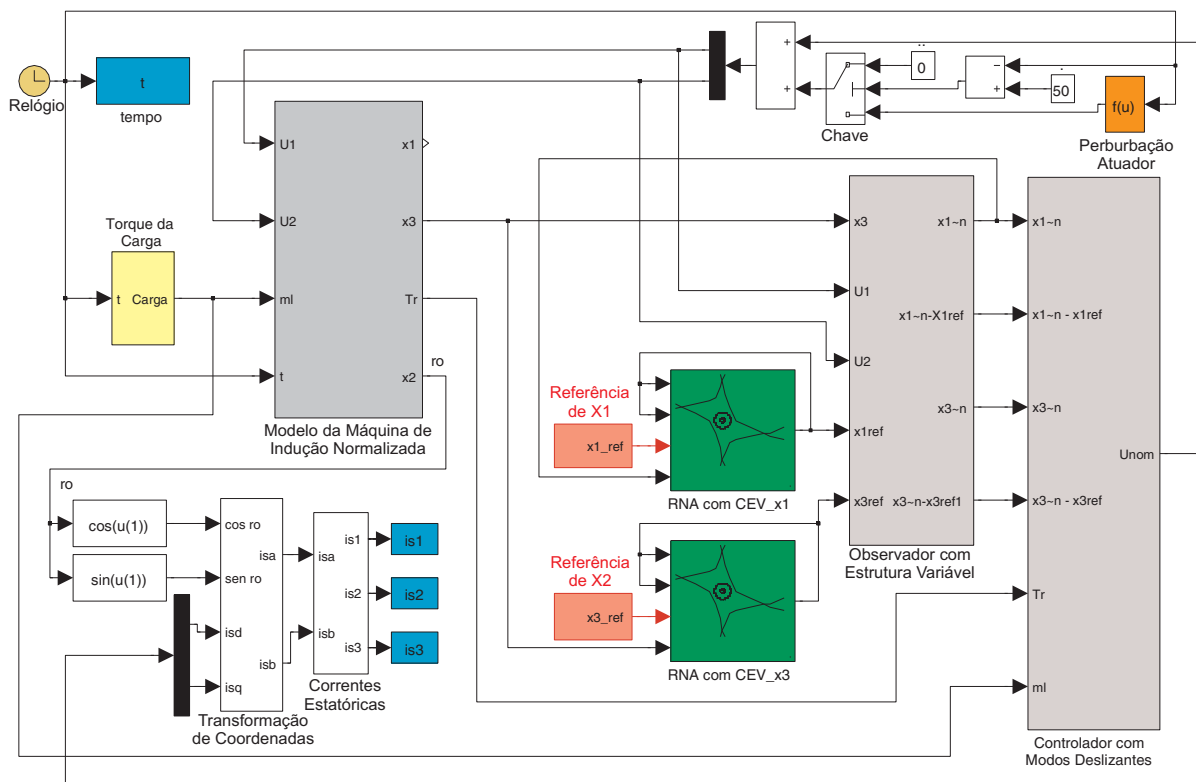
Fonte: o próprio autor.

As incertezas paramétricas degradam o desempenho do CEV-MIT em manter tanto a velocidade do motor como a corrente de magnetização do rotor da máquina em suas respectivas referências. Sendo assim, uma malha de controle com RNA é utilizada para gerar o novo sinal de referência \tilde{x}'_1 para i_{mR} , de modo a minimizar o erro entre i_{mR} e o seu respectivo sinal desejado i_{mRRef} .

A saída da planta (x_3) é utilizada tanto pelo OEV-MIT, responsável em gerar todos os estados estimados da planta, imprescindíveis ao CEV-MIT, como também, para gerar o sinal de erro entre x_3 e o sinal de referência de velocidade ω_{ref} , utilizado pela RNA, responsável por adaptar o novo sinal de referência y'_d , utilizado pelo CEV-MIT.

Na Figura (110) é apresentada a simulação computacional contendo a estratégia de controle descrita na Figura (109), proposta para o motor de indução trifásico. Pode ser visto o acréscimo da terceira malha de controle, contribuindo no rastreamento do sinal de referência imposto para i_{mR} .

Figura 110 - Simulação computacional da estratégia de controle CEV/RNA-MIT-II em MIT.



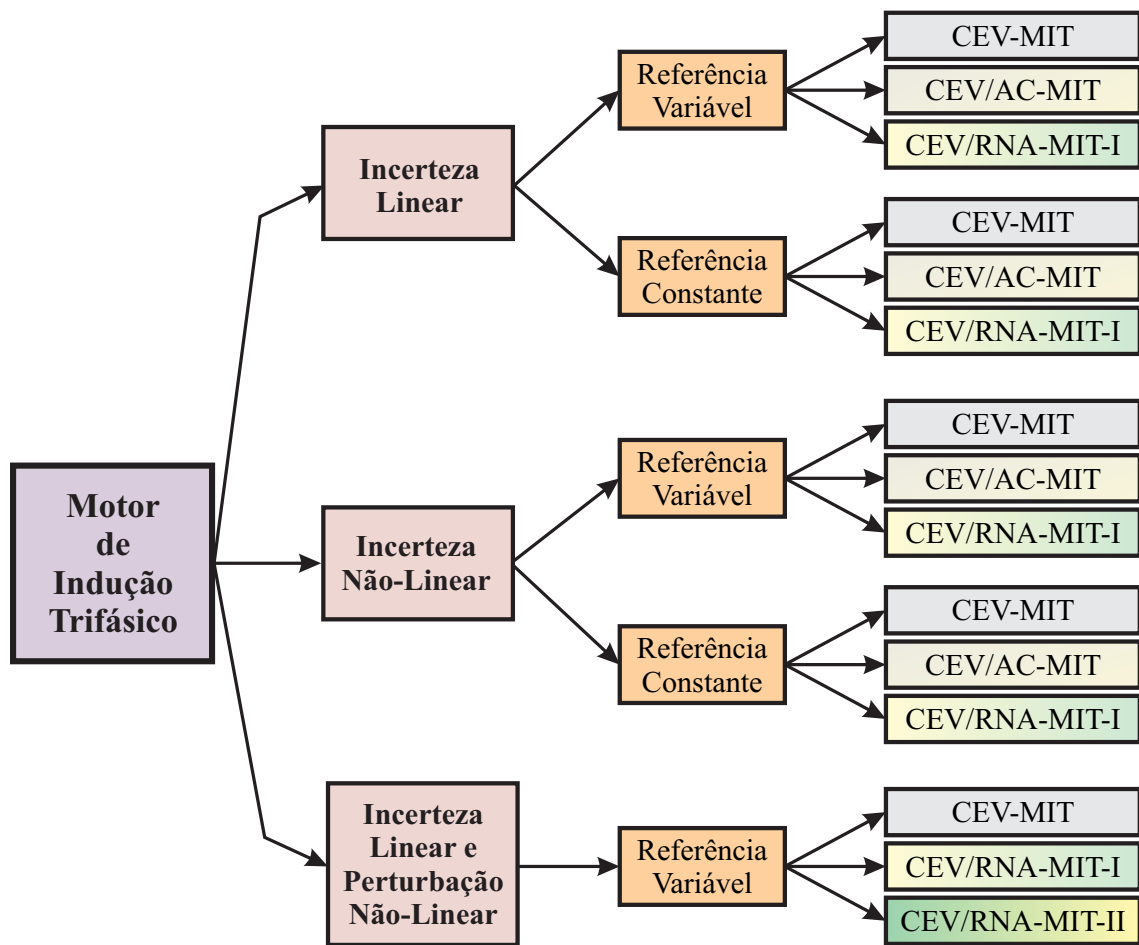
Fonte: o próprio autor.

6.5 SIMULAÇÕES E RESULTADOS

As simulações computacionais utilizando as quatro estratégias de controle, representadas nas Figuras (103), (105), (107) e (109), aplicadas no modelo matemático do MIT não-linear, definido pelas equações (100), (101) e (102) são apresentadas.

Três casos são considerados e descritos no diagrama da Figura (111): primeiramente considera-se o motor sofrendo uma variação paramétrica linear; em um segundo momento, a variação paramétrica apresenta dinâmica não-linear e, por fim, o sistema apresenta variação paramétrica linear e uma perturbação não-linear na fonte que alimenta o motor (atuador). Partindo dessas três condições de incertezas/perturbações, os sinais de referência para a velocidade e as estratégias de controle são alterados, obtendo-se quinze simulações diferentes para o motor, o qual, analisa-se o desempenho do motor sendo controlado pelas quatro estratégias de controle em condições operacionais diferentes.

Figura 111 - Simulações realizadas no MIT com controle vetorial.



Fonte: o próprio autor.

6.5.1 Simulações e resultados: variação paramétrica linear

As simulações computacionais, considerando uma variação paramétrica linear no MIT e seus respectivos resultados são agora apresentados.

A variação está presente no intervalo de 18 a 57 segundos de simulação, sendo imposta uma redução do valor numérico da indutância mútua de $92mH$ para $35mH$. Nos demais intervalos de simulação, o sistema opera normalmente, apresentando apenas pequenas incertezas e não-linearidades. A alteração desta indutância afeta o valor da constante k_{mit_B} da Equação (102). Assim, para visualizar o efeito que causa esta incerteza no desempenho dos controladores, as simulações são realizadas como a seguir:

$$\text{- para } 0s \leq t < 18s ; \quad 57s \leq t \leq 80s \quad \Rightarrow \quad L_{0REAL} = L_{0NOM} = 92mH ;$$

$$\text{- para } 18s \leq t < 57s \quad \Rightarrow \quad L_{0REAL} = L_{0NOM} - \Delta_L(t) = 35mH.$$

Os resultados das simulações, assim como, os sinais de referência e controle estão representados por unidade (p.u.).

Os parâmetros nominais do MIT são os mesmos apresentados na Tabela (4) e os valores numéricos das constantes do controlador CEV-RNA são ajustados por $k_R = 150$ e $\delta_R = 0,5$. Os valores numéricos das constantes do CEV-MIT, equações (111) e (112), são escolhidos por $c_1 = c_2 = 40$, $P_1 = P_2 = 1$ e $\eta = 0,01$. Os parâmetros do observador, dados pelas equações (117), (118), (119) e (120), são ajustados segundo $L_1 = 47$ e $K_O = 10$. Vale ressaltar que em todas as simulações o parâmetro incerto $\frac{1}{\tau_R}$ está sempre presente e escolhe-se a seguinte função variável no tempo e não-linear,

$$\frac{1}{\tau_R} = \frac{1}{\tau_{Rnom}} [1 + 0.1sen(10t)].$$

Em todas as simulações o sinal de referência para o I_{mR} é igual a um. As três primeiras simulações são realizadas considerando as mesmas condições operacionais, alterando-se apenas a estratégia de controle. O sinal de referência para a velocidade e torque de carga presente no eixo da máquina são os dados na Figura (112a) e na Figura (112b), respectivamente.

- Os resultados da simulação com a primeira estratégia de controle, CEV-MIT, e variação linear da indutância mútua estão nas Figuras (113), (114) e (115).

Na Figura (113), mostra-se o sinal de referência e a velocidade do motor. Pode ser visto que, nos primeiros segundos de simulação, a estratégia de controle é capaz de controlar o motor, fazendo-o seguir o sinal de referência. Todavia, com a alteração paramétrica, o motor não segue o sinal de referência de velocidade, passando a ser influenciado pelas dinâmicas degenerativas devido as condições consideradas.

Figura 112 - Sinal de referência variável e conjugado da carga para MIT com CEV-MIT e RNA: variação paramétrica linear.






Figura 113 - Velocidade do MIT com CEV-MIT: primeira estratégia de controle (CEV-MIT), sinal de referência variável e variação paramétrica linear.



O sinal de referência e a corrente de magnetização do rotor I_{mR} estão na Figura (114), na qual, a corrente permanece sobre o sinal desejado em todo o período de simulação.

Figura 114 - Sinal de referência e corrente I_{mR} com CEV-MIT: primeira estratégia de controle (CEV-MIT), sinal de referência variável e variação paramétrica linear.




A corrente I_{mR} em todas as próximas simulações com o MIT e alteração paramétrica linear permanecem sempre no sinal de referência, sendo assim, omitir-se-ão seus resultados.

As correntes estatóricas estão apresentadas na Figura (115). Na Figura (115a) as correntes são descritas em todo o período de simulação e na Figura (115b) estão no intervalo de 4 a 6 segundos de simulação, sendo possível verificar o formato dos sinais de correntes entregues à máquina. As correntes estatóricas permanecem dentro dos limites nominais da máquina, não ultrapassando inclusive a marca de 0,5 p.u..

- Os resultados da simulação considerando a segunda estratégia de controle, a qual, utiliza controlador e observador com estrutura variável e modos deslizantes e esquema de adaptação do controlador (CEV/AC-MIT), são apresentados nas Figuras (116), (117), (118).


O sinal de referência e a velocidade do motor estão na Figura (116). Nesse caso, a velocidade do motor segue o sinal de referência em todo o período de simulação, mesmo em condição incerta do parâmetro L_0 , entre os 18 e 57 segundos de simulação.

Figura 115 - Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: primeira estratégia de controle (CEV-MIT), sinal de referência variável e variação paramétrica linear.



Fonte: o próprio autor.

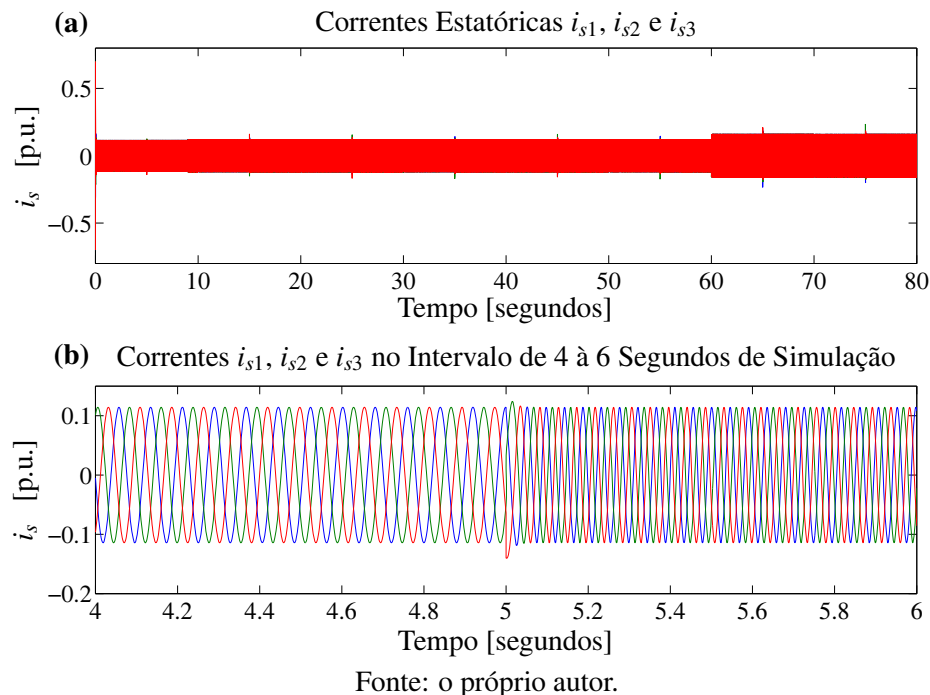
Figura 116 - Velocidade do MIT com CEV-MIT: segunda estratégia de controle (CEV/AC-MIT), sinal de referência variável e variação paramétrica linear.



Fonte: o próprio autor.

As correntes estatóricas estão na Figura (117). As correntes permanecem abaixo dos limites da máquina e sofrem pequenas elevações nas entradas da carga. Devido à muitos períodos das correntes estatóricas, as mesmas são apresentadas na Figura (117b) no intervalo de 4 a 6 segundos de simulação.

Figura 117 - Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: segunda estratégia de controle (CEV/AC-MIT), sinal de referência variável e variação paramétrica linear.




Na Figura 118 tem-se o gráfico da seleção do controlador ativo, com a posição um (1) representando o CEV-MIT-I ativo e a posição dois (2), o CEV-MIT-II ativo. Pode-se notar que os controladores são chaveados de forma adequada, permanecendo a maior parte do tempo ativo o respectivo controlador, projetado segundo as situações operacionais impostas para o motor.

- Nas Figuras (119) e (120) encontram-se os resultados da velocidade do motor e correntes estatóricas, respectivamente, para a simulação utilizando a terceira estratégia de controle, no qual o CEV-MIT é auxiliado pela RNA na busca do sinal de referência da velocidade do motor (CEV/RNA-MIT-I).

Pelo resultado apresentado na Figura (119) verifica-se que a velocidade do motor segue o sinal de referência, mesmo na presença da variação paramétrica entre os 18 e 57 segundos de simulação, o que não ocorre quando a primeira estratégia de controle é utilizada.


Na Figura (120), tem-se os resultados das correntes estatóricas, tal que, novamente permanecem dentro dos limites nominais da máquina.

Figura 118 - Seleção do controlador CEV-MIT ativo: segunda estratégia de controle (CEV/AC-MIT), sinal de referência variável e variação paramétrica linear.




Fonte: o próprio autor.

Figura 119 - Velocidade do MIT com CEV-MIT: terceira estratégia de controle (CEV/RNA-MIT-I), sinal de referência variável e variação paramétrica linear.



Fonte: o próprio autor.

Figura 120 - Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: terceira estratégia de controle (CEV/RNA-MIT-I), sinal de referência variável e variação paramétrica linear.



Fonte: o próprio autor.


Comparando os resultados obtidos nestas três simulações, verifica-se que o controle do MIT apresentando não-linearidades é possível pelo CEV-MIT, porém com a entrada de uma forte variação paramétrica em L_0 , o CEV-MIT não consegue manter o motor no sinal de referência da velocidade. Problema este solucionado de duas formas: por meio da utilização da estratégia de controle com detecção e adaptação do controlado (CEV/AC-MIT), Figura (105), e pela utilização da estratégia com a RNA, proposta neste trabalho (CEV/RNA-MIT-I), Figura (107).

As três simulações anteriores são novamente realizadas, considerando um sinal de referência com valor constante de 0,6 p.u. em todo o período de simulação.

- A primeira simulação com o sinal de referência constante e variação paramétrica linear é realizada utilizando a estratégia de controle que apresenta apenas o CEV-MIT e o OEV-MIT (Figura (103)). Assim como nos casos anteriores, a variação está presente no intervalo de 18 a 57 segundos de simulação.

O resultado da velocidade da máquina e o seu respectivo sinal de referência estão na Figura (121). Nos primeiros segundos de simulação, em que a incerteza linear não está presente na planta, o CEV-MIT consegue controlar com precisão o motor, todavia, com a alteração paramétrica, o sinal de referência é perdido. Quando o sistema volta a operar em condições normais, a resposta da velocidade do motor melhora, porém, não mais com a mesma precisão obtida anteriormente.

Figura 121 - Velocidade do MIT com CEV-MIT: primeira estratégia de controle (CEV-MIT), sinal de referência constante e variação paramétrica linear.



Fonte: o próprio autor.


As correntes estatóricas estão na Figura (122). Assim como nos casos anteriores, as correntes mantêm-se com valores numéricos reduzidos. Na Figura (122b), devido à alta frequência, tem-se a representação das correntes do estator no intervalo de 17 a 19 segundos de simulação, sendo possível verificar o comportamento dos três sinais de corrente.

- O resultados utilizando a segunda estratégia de controle (CEV/AC-MIT), Figura (105), são apresentados nas Figuras (123), (124) e (125).

O sinal de referência e a velocidade do motor estão na Figura (123). A velocidade do motor segue o sinal de referência em todo o período de simulação, mesmo na presença da alteração paramétrica linear imposta. Neste caso, a estratégia de adaptação do controlador atua eficazmente, apresentando pequenas oscilações na velocidade do motor durante o período de simulação.


Os sinais de corrente i_{s1} , i_{s2} e i_{s3} estão presentes na Figura (124), apresentando mais uma vez valores reduzidos, abaixo dos 0,5 p.u..

Figura 122 - Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: primeira estratégia de controle (CEV-MIT), sinal de referência constante e variação paramétrica linear.




Fonte: o próprio autor.

Figura 123 - Velocidade do MIT com CEV-MIT: segunda estratégia de controle (CEV/AC-MIT), sinal de referência constante e variação paramétrica linear.



Fonte: o próprio autor.

Figura 124 - Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: segunda estratégia de controle (CEV/AC-MIT), sinal de referência constante e variação paramétrica linear.




Fonte: o próprio autor.

Na Figura (125), tem-se a resposta da condição de operação do sistema, obtida pelo esquema de adaptação do controlado. Quando o sinal apresenta valor igual a um (1), o esquema de adaptação indica que o sistema trabalha em condições normais, sendo assim, o controlador CEV-MIT-I está ativo. Quando o sinal apresenta valor numérico igual a dois (2), o esquema detecta a presença da variação paramétrica na planta controlada, com isso, o controlador CEV-MIT-II é o que está controlando a planta. Pelos resultados, verifica-se que o esquema de adaptação do controlador indica, a maior parte do tempo, a verdadeira condição de operação do motor, ativando o devido controlador.

- Os resultados considerando a terceira estratégia de controle formada pelo CEV-MIT, OEV-MIT e a RNA (Figura (107)), com sinal de referência para a velocidade constante e variação paramétrica linear são apresentados.


A velocidade do motor e o sinal de referência estão na Figura (126). A velocidade do motor segue o sinal de referência em todo o período de simulação, o qual, a estratégia de controle com RNA mostra-se capaz de controlar o motor em condições altamente incertas e condições normais. A rede neural Adaline consegue se ajustar, mantendo o motor sobre o sinal de referência, não havendo a necessidade de uma parada imediata do motor para se analisar o ocorrido na máquina. Outro ponto importante está no fato de não ser necessário o chaveamento para outro controlador, que deveria ser previamente projetado, para controlar o motor na condição de operação com variação paramétrica conhecida.

Figura 125 - Seleção do controlador CEV-MIT ativo: segunda estratégia de controle (CEV/AC-MIT), sinal de referência constante e variação paramétrica linear.



Fonte: o próprio autor.


Figura 126 - Velocidade do MIT com CEV-MIT: terceira estratégia de controle (CEV/RNA-MIT-I), sinal de referência constante e variação paramétrica linear.



Fonte: o próprio autor.

As correntes estatóricas mantiveram-se dentro dos limites nominais da máquina assíncrona, como mostrado na Figura (127), mesmo com a mudança do parâmetro nominal na planta.

Figura 127 - Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: terceira estratégia de controle (CEV/RNA-MIT-I), sinal de referência constante e variação paramétrica linear.



Fonte: o próprio autor.

Pelos resultados obtidos considerando variação paramétrica linear e sinal de referência constante, o CEV-MIT mostra-se ineficiente para controlar o motor sob condição imposta. Dessa forma, as estratégias de controle utilizando o esquema adaptação do controlador (CEV/AC-MIT) e, a estratégia proposta, composta pela RNA e CEV-RNA auxiliando o OEV-MIT e o CEV-MIT (CEV/RNA-MIT-I), mostram-se necessárias e eficientes para este tipo de incerteza exemplificada.

6.5.2 Simulações e resultados: variação paramétrica não-linear

Após as análises de desempenho da máquina assíncrona apresentando variação paramétrica linear, considera-se que a variação apresenta dinâmica não-linear e limitada.


A incerteza/variação não-linear considerada está presente na Equação (102), na qual, a constante $\frac{k_{mitB}}{\tau_m}$ sofre a seguinte variação em relação ao tempo,

$$\frac{k_{mitB}}{\tau_m} = \frac{k_{mitB}}{\tau_m} + 10 \sin(0,1\pi t). \quad (128)$$

A dinâmica não-linear da variação paramétrica em $\frac{k_{mitB}}{\tau_m}$ ocorre no mesmo intervalo de

tempo da variação linear, entre os 18 e os 57 segundos de simulação, como representado na Figura (128).

Figura 128 - Dinâmica da variação paramétrica não-linear considerada no MIT dos 18 aos 57 segundos de simulação.



Fonte: o próprio autor.

Vale ressaltar que o modelo matemático do motor utilizado é altamente não-linear (equações (100), (101) e (102)), considerando o parâmetro incerto


$$\frac{1}{\tau_R} = \frac{1}{\tau_{Rnom}} [1 + 0.1 \text{sen}(10t)].$$

Assim como no caso de variação paramétrica linear, simulações considerando as três primeiras estratégias de controle aplicadas ao MIT são realizadas, primeiramente, com um sinal de referência variável para a velocidade mecânica do rotor e, em um segundo momento, sinal de referência com valor numérico constante.

Nas simulações são utilizados os mesmos parâmetros do MIT e os mesmos ganhos dos controladores projetados no caso de alteração paramétrica linear.

O sinal de referência para o I_{mR} é mantido sempre constante e igual a um. O sinal de referência variável e o torque da carga estão dados na Figura (129a) e na Figura (129b), respectivamente.

Figura 129 - Sinal de referência e conjugado da carga para o motor de indução trifásico com CEV-MIT e RNA: variação paramétrica não-linear.



Fonte: o próprio autor.

• A primeira simulação com o sistema apresentando variação paramétrica não-linear é realizada considerando a primeira estratégia de controle (CEV-MIT) dada na Figura (103), na qual utiliza-se apenas o CEV-MIT e o OEV-MIT.


Os resultados da velocidade do motor, da corrente de magnetização do rotor e das correntes estáticas para esta simulação estão nas Figuras (130), (131) e (132), respectivamente.

Nos primeiros segundos de simulação, o CEV-MIT estabiliza o sistema, mantendo a velocidade do motor sobre o sinal desejado. Com a entrada da variação não-linear da constante L_0 , a velocidade do motor não busca o sinal de referência, demonstrando que esta estratégia de controle não é apropriada em controlar sistemas com as condições de operação impostas.

Na Figura (131) tem-se a corrente I_{mR} e o sinal de referência. Como visto, em todo o período de simulação, a corrente permanece sob o sinal de referência. Devido esta característica, as respostas da corrente I_{mR} são omitidas nas próximas simulações.


As correntes estáticas i_{s1} , i_{s2} e i_{s3} estão mostradas na Figura (132). Na Figura (132a) verifica-se que mesmo em condição anormal, as correntes se mantêm dentro dos limites nominais da máquina. Na Figura (132b) as correntes são mostradas no intervalo de 4 a 6 segundos de simulação, passando a ser possível verificar a dinâmica dos três sinais de corrente.

Figura 130 - Velocidade do MIT com CEV-MIT: primeira estratégia de controle (CEV-MIT), sinal de referência variável e variação paramétrica não-linear.




Fonte: o próprio autor.

Figura 131 - Sinal de referência e corrente i_{mR} com CEV-MIT: primeira estratégia de controle (CEV-MIT), sinal de referência variável e variação paramétrica não-linear.



Fonte: o próprio autor.

Figura 132 - Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: primeira estratégia de controle (CEV-MIT), sinal de referência variável e variação paramétrica não-linear.



Fonte: o próprio autor.

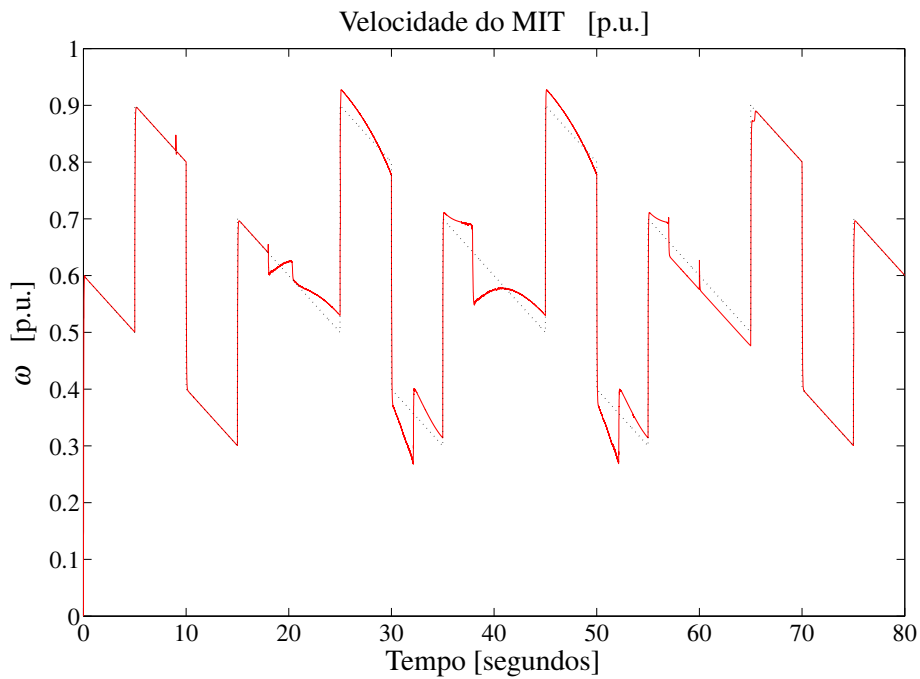
- Para a segunda simulação, considera-se a segunda estratégia, formada pelo CEV-MIT, OEV-MIT e o esquema de adaptação do controlador (CEV/AC-MIT), representada na Figura (105).

O sinal de referência e a velocidade do motor para esta simulação são mostrados na Figura (133). Assim como na simulação anterior, em que o sistema é controlado pela primeira estratégia de controle, a resposta da velocidade do motor não segue o sinal de referência durante a presença da alteração paramétrica não-linear.

Comparando este resultado com os resultados obtidos na simulação com variação paramétrica linear (Figura (116) e Figura (123)), observa-se que a estratégia de controle com detecção e adaptação do controlador é eficaz na presença de apenas variações conhecidas, lineares e constantes. Todavia, na presença de mudança paramétrica não-lineares variável no tempo torna-se inapropriada, existindo assim, a necessidade de buscar uma solução mais condizente para estas condições de operação da planta controlada.


As correntes estatóricas estão representadas na Figura (134), na qual, não ultrapassam os limites da máquina. Devido à números elevados de períodos das correntes estatóricas, as correntes são apresentadas na Figura (134b) no intervalo de 4 a 6 segundos de simulação, sendo possível analisar os sinais de correntes entregues a máquina.

Figura 133 - Velocidade do MIT com CEV-MIT: segunda estratégia de controle (CEV/AC-MIT), sinal de referência variável e variação paramétrica não-linear.



Fonte: o próprio autor.


Figura 134 - Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: segunda estratégia de controle (CEV/AC-MIT), sinal de referência variável e variação paramétrica não-linear.



Fonte: o próprio autor.

Na Figura (135) tem-se o gráfico da seleção do controlador ativo, sendo que quando encontra-se na posição um, indica que para o esquema adaptação do controlador, o sistema opera em condições normais, mantendo o CEV-MIT-I ativo. Na posição dois, o CEV-MIT-II é ativo, uma vez que o esquema de detecção e adaptação do controlador identifica o sistema operando em condição anormal. Pode-se notar que na presença da variação paramétrica, o esquema de adaptação do controlador alterna constantemente entre os controladores, não encontrando uma posição, ou melhor, um controlador adequado para esta condição de operação.

Figura 135 - Seleção do controlador CEV-MIT ativo: segunda estratégia de controle (CEV/AC-MIT), sinal de referência variável e variação paramétrica não-linear.




Fonte: o próprio autor.

- Os resultados da simulação utilizando a terceira estratégia de controle (CEV/RNA-MIT-I) com falha não-linear são apresentados. Nas Figuras (136) e (137) encontram-se os resultados da velocidade do motor e correntes estatóricas, respectivamente.

Pelo resultado apresentado na Figura (136), verifica-se que a velocidade do motor passa a seguir o sinal de referência mesmo na presença da variação paramétrica não-linear. A incerteza considerada altera o valor numérico da constante $\frac{k_{mitB}}{\tau_m}$, no intervalo de 18 a 57 segundos de simulação. Com este resultado, o CEV-RNA mostra-se capaz de ajustar os pesos da RNA, auxiliando o CEV-MIT e o OEV-MIT a controlarem o motor durante todo o período de simulação incerto.


As correntes estatóricas i_{s1} , i_{s2} e i_{s3} , estão representadas na Figura (137) e, mais uma vez, permanecem dentro dos limites nominais da máquina, não existindo a necessidade de um esforço extra em manter a saída da planta no sinal de referência.

Figura 136 - Velocidade do MIT com CEV-MIT: terceira estratégia de controle (CEV/RNA-MIT-I), sinal de referência variável e variação paramétrica não-linear.



Fonte: o próprio autor.

Figura 137 - Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: terceira estratégia de controle (CEV/RNA-MIT-I), sinal de referência variável e variação paramétrica não-linear.



Fonte: o próprio autor.


Por meio destas simulações, verifica-se que para um sistema operando em condição de variação paramétrica desconhecida não-linear, a estrutura neural é capaz de auxiliar de forma eficaz, um controlador já existente, a controlar o sistema. A estratégia de adaptação do controlador é ineficiente na presença de alterações paramétricas não-lineares, além do que, com a RNA, não é necessário prever que tipo de incerteza/perturbação ocorrerá na planta, e consequentemente o projeto do controlador respectivo.

Simulações computacionais considerando um sinal de referência de velocidade constante também são realizadas com variação paramétrica não-linear. O sinal de referência apresenta um valor de 0,6 p.u. e as condições de operação e o projeto dos controladores são os mesmos dos casos anteriores.

- Os resultados da primeira simulação considerando sinal de referência constante e variação paramétrica não-linear são apresentados nas Figuras (138) e (139), nas quais é utilizada a primeira estratégia de controle (CEV-MIT) descrita no diagrama da Figura (103).

A variação paramétrica não-linear é imposta no intervalo entre 18 e 57 segundos de simulação e pela resposta da velocidade da máquina, Figura (138), verifica-se que com a entrada da falha, a estratégia de controle não é capaz de manter a velocidade do motor seguindo o sinal de referência, sofrendo influências degenerativas causadas pela alteração paramétrica não-linear.

Figura 138 - Velocidade do MIT com CEV-MIT: primeira estratégia de controle (CEV-MIT), sinal de referência constante e variação paramétrica não-linear.




Fonte: o próprio autor.

As correntes estatóricas estão na Figura (139). Assim como nos casos anteriores, as correntes mantêm-se com valores numéricos reduzidos. Na Figura (122b), devido à alta frequência,

tem-se a representação das correntes do estator no intervalo de 17 a 19 segundos de simulação, sendo possível verificar o comportamento dos três sinais de corrente.

Figura 139 - Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: primeira estratégia de controle (CEV-MIT), sinal de referência constante e variação paramétrica não-linear.




- A segunda simulação com variação paramétrica não-linear e sinal de referência constante é realizada por meio da segunda estratégia de controle (CEV/AC-MIT) dada na Figura (105). Os resultados para esta simulação computacional estão nas Figuras (140), (141) e (142).

Pelo resultado da saída da planta, Figura (140), a estratégia de controle com detecção e adaptação do controlador mostra-se, como esperado, ineficiente em controlar a planta sob condição incerta. Devido a dinâmica não-linear da variação paramétrica, os controladores previamente projetados não são adequados em controlar a planta, ocasionando a oscilação da velocidade do motor sobre o sinal desejado.

As correntes i_{s1} , i_{s2} e i_{s3} do estator, dadas na Figura (141), permanecem novamente com valores reduzidos, sempre dentro dos limites nominais da máquina.


A resposta do esquema de detecção e adaptação do controlador é apresentado na Figura (142). Pode ser visto que com o sistema operando normalmente, o devido controlador é selecionado e atua na planta, mantendo a resposta da velocidade na referência. Com o sistema apresentando a variação paramétrica, o esquema de adaptação do controlador busca o melhor controlador para a condição de operação, porém não consegue manter em um controlador específico, devido a dinâmica não-linear da variação paramétrica considerada para L_0 .

Figura 140 - Velocidade do MIT com CEV-MIT: segunda estratégia de controle (CEV/AC-MIT), sinal de referência constante e variação paramétrica não-linear.




Fonte: o próprio autor.

Figura 141 - Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: segunda estratégia de controle (CEV/AC-MIT), sinal de referência constante e variação paramétrica não-linear.



Fonte: o próprio autor.

Figura 142 - Seleção do controlador CEV-MIT ativo: segunda estratégia de controle (CEV/AC-MIT), sinal de referência constante e variação paramétrica não-linear.



Fonte: o próprio autor.

- Os resultados da simulação considerando o terceiro esquema de controle (CEV/RNA-MIT-I), com variação paramétrica não-linear e sinal de referência constante, são agora apresentados. A velocidade do motor, presente na Figura (143), segue com precisão o sinal de referência imposto, demonstrando a eficácia da estratégia de controle. O controlador CEV-MIT auxiliado pela rede neural consegue ajustar corretamente a velocidade do motor, mantendo-o em perfeito funcionamento, eliminando os efeitos degenerativos causados pelo tipo de incerteza considerada.


As correntes estatóricas apresentadas na Figura (144) mantêm-se dentro dos limites nominais da máquina.

6.5.3 Simulações e resultados: incerteza linear e perturbação não-linear

Simulações são realizadas considerando duas incertezas/perturbações paramétricas não destrutivas, uma no motor e outra na fonte que alimenta o motor (atuador).


No motor considera-se que a indutância mútua L_0 é um parâmetro incerto, sendo que nos projetos do CEV-MIT e do OEV-MIT o valor considerado como nominal é $L_{0_{NOM}} = 92\text{mH}$. No entanto, a indutância sofre alteração do seu valor numérico como na subseção (6.5.1), na qual o seu valor numérico decai para 35mH no intervalo dos 18 aos 57 segundos de simulação.

Figura 143 - Velocidade do MIT com CEV-MIT: terceira estratégia de controle (CEV/RNA-MIT-I), sinal de referência constante e variação paramétrica não-linear.



Fonte: o próprio autor.

Figura 144 - Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: terceira estratégia de controle (CEV/RNA-MIT-I), sinal de referência constante e variação paramétrica não-linear.



Fonte: o próprio autor.

A perturbação considerada presente no atuador produz uma variação senoidal indesejável nos sinais de controle i_{sd} e i_{sq} a partir dos 40 segundos do período de simulação do motor, tal que,

$$i_{sd} = i_{sd_{CEV}} + \underbrace{[0,3 + 0,1\text{sen}(10t)]}_{\Delta_u(t)} ;$$

$$i_{sq} = i_{sq_{CEV}} + \underbrace{[0,3 + 0,1\text{sen}(10t)]}_{\Delta_u(t)} ,$$

sendo que $i_{sd_{CEV}}$ e $i_{sq_{CEV}}$ são os sinais de controle que deveriam efetivamente atuar no MIT. Assim, tem-se que:

$$0s \leq t < 40s \quad \Rightarrow \quad I_{sd} = I_{sd_{CEV}} \quad \text{e} \quad I_{sq} = I_{sq_{CEV}} ;$$

$$40s \leq t \leq 80s \quad \Rightarrow \quad I_{sd} = I_{sd_{CEV}} + \Delta_u(t) \quad \text{e} \quad I_{sq} = I_{sq_{CEV}} + \Delta_u(t) .$$

Três simulações são realizadas modificando-se a estratégia de controle. Na primeira simulação, o sistema é controlado pela estratégia de controle sem RNA, na qual apenas a malha de controle formada pelo OEV-MIT e o CEV-MIT é utilizada (estratégia de controle CEV-MIT). Assim, os sinais de erro necessários para o CEV-MIT computar os sinais de controle são obtidos através da comparação entre o sinal de referência de velocidade diretamente com a saída x_3 do motor e da comparação entre i_{mRRef} e \tilde{x}_1 , da saída do observador.

Na segunda simulação têm-se as mesmas condições operacionais da primeira simulação, porém o MIT é controlado pela estratégia de controle proposta CEV/RNA-MIT-I, descrita na Figura (107). Nesse caso, a RNA é inserida de modo a modificar o sinal de referência para a velocidade do motor, ω_{ref} , obtendo-se o novo sinal de referência y'_d .

No caso da terceira simulação, utiliza-se a quarta estratégia de controle (CEV/RNA-MIT-II), descrita na Figura (109). Com esta estratégia de controle, a RNA passa a contribuir no controle da corrente de magnetização do rotor (I_{mR}), além de sua contribuição na velocidade do motor.


Os valores numéricos das constantes do controlador, do observador e dos CEV-RNA são iguais a dos casos anteriores, considerando também o mesmo valor incerto para $1/\tau_R$.

A carga mecânica é adicionada no eixo da máquina aos 9 segundos, com um valor de 0,1 p.u., e a partir dos 60 segundos de simulação, passa para 0,3 p.u..

- Os resultados da simulação considerando a primeira estrutura de controle formada pelo CEV-MIT e pelo OEV-MIT são apresentados.

Na Figura (145) mostra-se o sinal de referência e a velocidade real do motor. Pode-se observar que o motor segue a referência com mínimo erro até o instante 18 segundos, de forma que o controle CEV-MIT foi eficaz para rejeitar a incerteza $\Delta(t)$ referente ao parâmetro τ_R . A partir deste instante, porém, ao atuar a incerteza $\Delta_L(t)$ referente ao parâmetro L_0 , ocorre um desvio (constante) da velocidade do motor em relação à sua referência, demonstrando assim que o CEV-MIT, não foi eficaz para rejeitar a influência desta incerteza. Finalmente, a partir do instante 40 segundos, quando a perturbação $\Delta_u(t)$ referente a falha ocorrida no atuador passa a estar presente, é nítida a influência oscilatória que exerce sobre o comportamento do motor, de forma que também o CEV-MIT não foi eficiente para rejeitar esta contingência.

Figura 145 - Velocidade do MIT com CEV-MIT: primeira estratégia de controle (CEV-MIT), incerteza linear e perturbação não-linear.




Fonte: o próprio autor.

Na Figura (146) o resultado da corrente de magnetização do rotor e sua respectiva referência são apresentados. Verifica-se que somente aos 40 segundos, isto é, no momento em que a falha do atuador está presente, a corrente deixa de seguir a referência. Nessa variável, o controlador CEV-MIT apenas não rejeitou a contingência ocorrida no atuador.



Na Figura (147) o torque da carga inserida no eixo da máquina e as correntes trifásicas impostas pelos controladores e atuadores são mostradas. Pode-se perceber que elas não ultrapassam os seus valores nominais, no entanto não foram eficientes no sentido de rejeição às perturbações e incertezas apresentadas. Com o propósito de ilustração, nesta mesma Figura mostra-se também o comportamento das correntes impostas entre os instantes 39 e 41 segundos, observando-se a variação senoidal das amplitudes das correntes devido às falhas ocorridas nos atuadores.

Figura 146 - Sinal de referência e corrente I_{mR} com CEV-MIT: primeira estratégia de controle (CEV-MIT), incerteza linear e perturbação não-linear.



Fonte: o próprio autor.

Figura 147 - Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: primeira estratégia de controle (CEV-MIT), incerteza linear e perturbação não-linear.




Fonte: o próprio autor.

Estes resultados são importantes no intuito de analisar a deterioração provocada pelas incertezas e perturbações nas dinâmicas do motor com a estratégia de controle CEV-MIT, além de propiciar uma comparação e análise da eficiência das estratégias de controle propostas, CEV/RNA-MIT-I e CEV/RNA-MIT-II, como mostrado a seguir. Uma simulação utilizando a estratégia de controle composta pelo esquema de adaptação do controlador (CEV/AC-MIT) não foi realizada, uma vez que a perturbação inserida no atuador, não pode ser prevista durante o projeto do CEV-MIT e do OEV-MIT.

- Como a estratégia de controle formada apenas pelos CEV-MIT e OEV-MIT não trouxe boa resposta ao motor, o mesmo é submetido a uma nova simulação, considerando a terceira estratégia de controle, CEV/RNA-MIT-I, descrita na Figura (107).

O resultado da velocidade do motor é dado na Figura (148). Diferentemente dos resultados obtidos na simulação utilizando o controlador CEV-MIT, a velocidade do motor rastreia seu respectivo sinal de referência com precisão e rapidez. Nos instantes de mudanças bruscas de velocidade de referência do motor, sobressinais são encontrados sem comprometer o bom desempenho dos resultados.


Figura 148 - Velocidade do MIT com CEV-MIT: terceira estratégia de controle (CEV/RNA-MIT-I), incerteza linear e perturbação não-linear.



Fonte: o próprio autor.

A resposta obtida na corrente de magnetização do rotor está na Figura (149), na qual a perturbação inserida na fonte geradora dos sinais de controle continua a induzir uma dinâmica indesejada em I_{mR} , dificultando a busca de seu respectivo sinal de referência.

Figura 149 - Sinal de referência e corrente I_{mR} com CEV-MIT: terceira estratégia de controle (CEV/RNA-MIT-I), incerteza linear e perturbação não-linear.



Fonte: o próprio autor.

As correntes estáticas que alimentam o estator e o torque da carga inserida no eixo da máquina estão representadas na Figura (150). Os três sinais de correntes permanecem abaixo de um p.u. sofrendo pequenas alterações em seu valor com a entrada da carga mecânica e das incertezas/perturbações. Nesta mesma Figura as correntes são representadas no intervalo de 39 aos 41 segundos de simulação, o que permite melhor análise do comportamento dos sinais de corrente.

A inserção da malha de controle formada por uma RNA, ajustando o sinal de referência para velocidade do motor, melhora a resposta da velocidade da máquina, porém, a corrente de magnetização do rotor permanece sofrendo uma dinâmica indesejada devido às condições impostas. Uma solução encontrada para amenizar este problema está na utilização de outra malha de controle, composta por RNA auxiliando o controle de I_{mR} a ajustar o respectivo sinal de referência em relação a resposta de I_{mR} calculada pelo observador de estados OEV-MIT.

- Os resultados obtidos na simulação realizada no MIT sujeito a incertezas e perturbações sendo controlada pela quarta estratégia de controle, CEV/RNA-MIT-II, são apresentados.

Os resultados referentes à velocidade da máquina estão na Figura (151). Assim como no caso anterior, velocidade do motor rastreia seu respectivo sinal de referência, indicando o bom funcionamento da estratégia de controle frente as perturbações e incertezas consideradas.

Figura 150 - Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: terceira estratégia de controle (CEV/RNA-MIT-I), incerteza linear e perturbação não-linear.

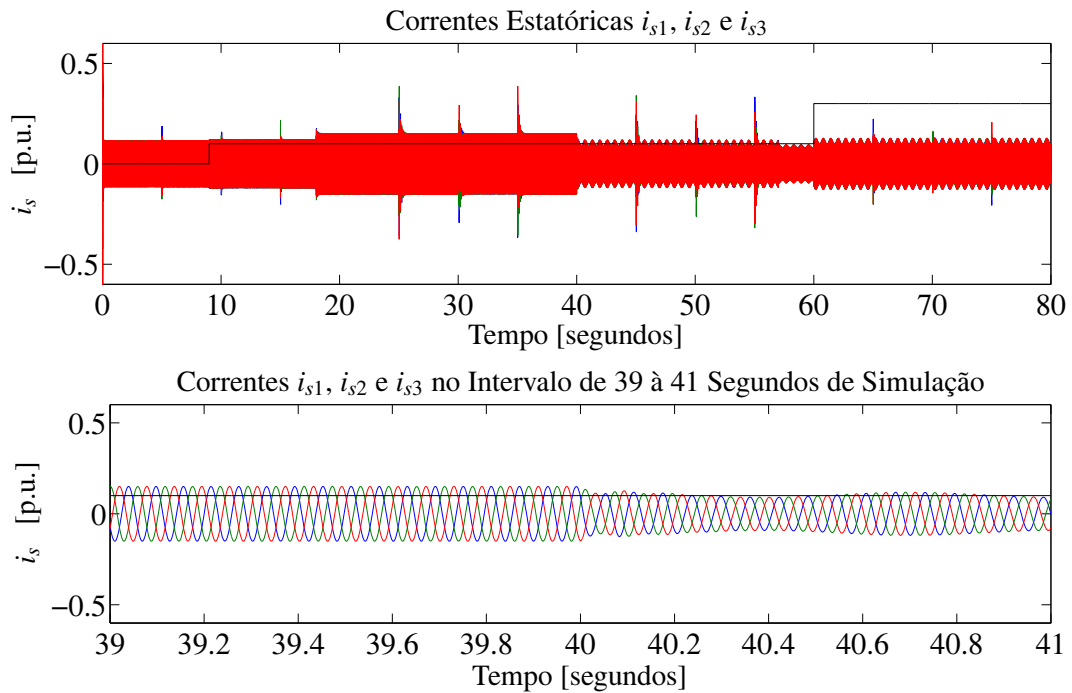




Figura 151 - Velocidade do MIT com CEV-MIT: quarta estratégia de controle (CEV/RNA-MIT-II), incerteza linear e perturbação não-linear.



Os resultados referentes à corrente de magnetização do rotor e seu respectivo sinal de referência são mostrados na Figura (152). Também nesta variável, as incertezas e falhas ocorridas não exerceram influência degenerativa na corrente, de forma que os controladores CEV/RNA-MIT-II, mostram-se eficientes na rejeição destas contingências.


Figura 152 - Sinal de referência e corrente i_{mR} com CEV-MIT: quarta estratégia de controle (CEV/RNA-MIT-II), incerteza linear e perturbação não-linear.



Finalmente, o torque da carga e as correntes do estator, i_{s1} , i_{s2} e i_{s3} são mostradas na Figura (153). Pode-se perceber que elas não ultrapassam os seus valores nominais. Diferentemente do caso anterior, elas foram eficientes no sentido de rejeição às perturbações e incertezas apresentadas. Com o propósito de ilustração, nesta mesma figura mostra-se também o comportamento das correntes impostas entre os instantes 39 e 41 segundos, o qual, também neste caso, se pode observar a variação senoidal das amplitudes das correntes devido às falhas ocorridas nos atuadores, as quais não ofereceram influências degenerativas nos comportamentos do motor devido à estratégia CEV/RNA-MIT-II proposta.

Comparando os resultados das duas simulações, verifica-se que a utilização da estratégia de controle vetorial proposta (CEV/RNA-MIT-II) é capaz de controlar o motor em condições de incertezas paramétricas e perturbações nos atuadores (fontes geradoras dos sinais de controle provenientes dos algoritmos de controle), mantendo a velocidade do motor e a corrente de magnetização do rotor rastreando seus respectivos sinais de referência, sem exigir valores excessivos das correntes. Vale ressaltar que estas simulações são exemplos de como a estrutura de controle proposta é eficiente em controlar máquinas sujeitas a variações e incertezas paramétricas, além de perturbações ocorridas nos atuadores.

Figura 153 - Correntes i_{s1} , i_{s2} e i_{s3} com CEV-MIT: quarta estratégia de controle (CEV/RNA-MIT-II), incerteza linear e perturbação não-linear.



6.6 CONCLUSÕES PARCIAIS

Neste capítulo, foi apresentado o projeto de um controlador e um observador com estrutura variável e modos deslizantes, aplicados no modelo matemático do MIT não-linear descrito no Capítulo (5).

Apresentou-se também um esquema de detecção e adaptação do controlador que, por meio de resíduos gerados pela comparação entre o sinal de saída real da planta e a saída de observadores projetados segundo as condições de operações consideradas para a planta, ativa-se o melhor controlador projetado para a condição de operação.

Quatro estratégias de controle aplicadas a um motor de indução trifásico foram submetidas a teste e seus resultados comparados: a primeira estratégia de controle apresentada é formada por controlador e observador com estrutura variável e modos deslizantes (estratégia CEV-MIT); a segunda estratégia apresentada aqui é formada por CEV-MIT, OEV-MIT e detecção e adaptação do controlador (estratégia CEV/AC-MIT); a terceira estratégia foi proposta e formada pelos CEV-MIT e OEV-MIT, além do acréscimo de uma segunda malha de controle, contendo uma RNA (estratégia CEV/RNA-MIT-I); e a quarta estratégia de controle, também proposta neste trabalho, composta pelos mesmos CEV-MIT, OEV-MIT e RNA na velocidade do motor, apresentando, porém, uma terceira malha de controle com outra RNA ajustando o sinal de referência

para a corrente de magnetização do rotor (estratégia CEV/RNA-MIT-II).

Três incertezas/perturbações foram consideradas, a primeira perturbação apresenta uma dinâmica linear, tal que, a indutância mútua da máquina sofre uma redução. A segunda incerteza é não-linear, de modo que a constante da máquina $\frac{k_{mitB}}{\tau_m}$ sofre uma variação em um período determinado, e a perturbação não-linear ocorre na fonte geradora dos sinais de controle da máquina.

Simulações computacionais foram realizadas comparando a eficiência das quatro estratégias de controle com o sistema apresentando condições operacionais diferentes, segundo as incertezas/perturbações consideradas neste trabalho.

Pelos resultados obtidos nas simulações com incerteza linear, o motor operando em condições normais, com seus valores paramétricos próximos dos nominais, o CEV-MIT e o OEV-MIT conseguiram efetuar um bom controle da planta. Todavia, operando na presença da perturbação, o motor não se manteve sobre o sinal de referência, sofrendo os efeitos degenerativos causados pela incerteza considerada. Todavia, com o motor sendo controlado tanto pela estratégia de controle contendo o esquema de detecção e adaptação do controlador (CEV/AC-MIT), como pela estratégia de controle contendo uma estrutura neural (CEV/RNA-MIT-I), mantiveram a resposta da máquina buscando normalmente o sinal de referência durante todo o período de simulação. Por meio desses resultados, as duas estratégias de controle mostraram-se eficazes em controlar o sistema nas condições de operação impostas.

Analisando os resultados obtidos nas simulações considerando a atuação da incerteza não-linear, conclui-se que em condições normais, o CEV-MIT e OEV-MIT com ou sem o esquema de detecção (estratégias CEV-MIT e CEV/AC-MIT), atuam eficazmente no controle da máquina, contudo, com a entrada da falha na planta, as duas estratégias de controle não conseguem manter a velocidade do motor seguindo o sinal de referência. Nesse caso, o esquema de detecção e adaptação do controlador, mostrou-se inadequado em controlar o sistema. Por meio dos resultados alcançados nas simulações utilizando apenas uma estrutura neural (CEV/RNA-MIT-I), verificou-se que o controle ocorreu eficientemente durante todo o período de simulação. A velocidade do motor foi mantida no sinal desejado, sem a necessidade de um esforço maior dos sinais de controle. A estratégia de controle com a estrutura neural, mostrou-se uma boa solução ao problema encontrado, mantendo o motor operando corretamente.

Pelas simulações realizadas no MIT apresentando incerteza linear e perturbação não-linear, quando o controle da máquina é realizado pela estratégia de controle CEV-MIT, verificam-se as dinâmicas degenerativas presentes na velocidade do motor e na corrente de magnetização do rotor. A utilização da estratégia de controle CEV/RNA-MIT-I, o qual, acrescenta-se a segunda malha de controle com uma RNA, melhoras são encontradas no desempenho da velocidade do motor, fazendo-o buscar com precisão o sinal de referência, porém a corrente de magnetização do rotor mantém-se oscilando sobre o seu respectivo sinal de referência. A solução para este problema foi obtida com a utilização da estratégia de controle CEV/RNA-MIT-II, tal que, é

acrescido a terceira malha de controle, formada pela segunda RNA, atuando diretamente no controle da corrente. As análises dos resultados das simulações computacionais comprovaram a eficácia da nova estratégia de controle (CEV/RNA-MIT-II), apresentando característica robusta às incertezas paramétricas inseridas no motor e perturbações na fonte geradora dos sinais de controle do motor.

7 CONCLUSÕES

Neste trabalho exploraram-se as características de uma rede neural artificial Adaline com ajuste de pesos em tempo real via controlador com estrutura variável e modos deslizantes em controlar sistemas lineares e não-lineares e amenizar efeitos degenerativos provindos de incertezas paramétricas e falha estrutural não destrutiva.

Por meio de simulações computacionais testou-se *a priori* o desempenho da RNA em controlar uma série de sistemas lineares em malha fechada em uma estrutura de rastreamento de sinais. Conclui-se que a rede não atua de forma eficaz em sistemas que apresentam zeros positivos quando em malha aberta, isto é, sistema de fase não mínima. A rede mostrou-se eficiente, melhorando a resposta de sistemas estáveis em malha aberta e até mesmo em algumas classes de sistemas instáveis com polos positivos, desde que com zeros negativos, rastreando de maneira eficaz o sinal de referência.

Uma nova estratégia de controle, formada por controlador PID e pela RNA com CEV-RNA, foi proposta. Simulações foram realizadas em sistemas lineares e não-lineares de terceira ordem, comprovando-se a eficácia da rede neural no sentido de melhorar a resposta de sistemas estáveis, eliminando influências degenerativas na dinâmica dos sistemas, provindas de incertezas e não-linearidades, tal que, projetos de controles convencionais não conseguem atuar de forma eficaz nestas condições.

Explorou-se, também, a capacidade de redes Adaline em reduzir os efeitos degenerativos causados por incertezas paramétricas não-lineares presentes em modelos matemáticos. Uma nova estratégia de controle foi proposta, sendo que a estrutura neural foi acrescida em uma segunda malha de controle, na qual o sistema apresentava controlador e observador com estrutura variável e modos deslizantes (CEV/MD e OEV/MD). Por meio de simulações computacionais, um modelo de eixos laterais de um avião L-1011 foi submetido a testes. Pelos resultados obtidos, verificou-se que o sistema sendo controlado apenas com o CEV/MD e o OEV/MD, apresentou dificuldades em rastrear os sinais de referência, principalmente na presença de incertezas não-lineares do tipo casadas e não casadas no modelo matemático da planta, o que impôs fortes oscilações na dinâmica do sistema. Conclui-se que o acréscimo da estrutura neural na malha de controle melhorou consideravelmente o desempenho do sistema, sendo que as saídas da planta rastream com precisão os sinais de referência desejados, reduzindo as oscilações encontradas nos sinais de saída da planta, além dos sinais de controle apresentarem valores numéricos também reduzidos, quando comparados com os obtidos na simulação sem a estrutura neural.

Simulações computacionais também foram realizadas em máquinas elétricas rotativas. Sendo

assim, foi apresentado o modelo matemático de um motor de Corrente Contínua linear e o modelo matemático de um Motor de Indução Trifásico em coordenadas de campo com corrente de estator imposta não-linear. O controle destas máquinas foi realizado por duas estratégias de controle propostas, formadas por controladores PID e RNA com CEV-RNA. Os resultados utilizando estas estratégias de controle foram comparados com simulações utilizando-se os controladores PID. Pelos resultados obtidos nas simulações, foi verificado que em sistemas que apresentam um controle capaz de manter o sistema estável, porém, sem precisão ao buscar os sinais de referência, o acréscimo da malha de controle composta pela RNA, melhora consideravelmente a resposta dos sistemas, além de reduzir os sinais de controle calculados pelos controladores.

O projeto de um Controlador e um Observador com Estrutura Variável e Modos Deslizantes (CEV-MIT e OEV-MIT) aplicados a um modelo matemático do Motor de Indução foram apresentados. O CEV-MIT e OEV-MIT foram utilizados no controle do motor de indução que estava sujeito a variações paramétricas e perturbações linear e não-linear. Sendo assim, uma estratégia de detecção e adaptação do controlador foi apresentada. Essa estratégia de detecção e adaptação do controlador trabalha com um banco de controladores e observadores, previamente projetados segundo as possíveis condições de operação do motor.

Pelos resultados, verificou-se que o CEV-MIT e o OEV-MIT são capazes de controlar o sistema, contudo, na presença de perturbações externas e variações paramétricas da planta, o motor não segue o sinal de referência. Comparando esses resultados com os obtidos nas simulações que utilizavam o esquema de detecção e adaptação do controlador, CEV/AC-MIT, o motor passa a seguir os sinais de referência em todo o período de simulação apenas quando a variação paramétrica considerada apresentava dinâmica linear e, conseqüentemente, o respectivo controlador e o observador estavam a maior parte do tempo controlando o sistema. Na presença de perturbação externa ou então incertezas não-lineares o esquema de detecção não foi eficaz, pois não conseguiu encontrar o melhor controlador para calcular os sinais de controle e, conseqüentemente, a velocidade do motor oscilou sobre o sinal de referência.

Duas estratégias de controle compostas por CEV-MIT e o OEV-MIT atuando em conjunto com rede neural artificial Adaline foram propostas. A primeira estratégia de controle (CEV/RNA-MIT-I) é formada por uma malha de controle composta pelo CEV-MIT, OEV-MIT e uma segunda malha de controle com uma RNA atuando na busca do sinal de referência para a velocidade do motor. Na segunda estratégia de controle (CEV/RNA-MIT-II) foi considerado o acréscimo de uma terceira malha de controle, contendo outra RNA, auxiliando o CEV-MIT a controlar a corrente de magnetização do rotor.

Simulações computacionais foram realizadas nestas duas estratégias de controle propostas, considerando o modelo não-linear do motor de indução sujeito a incertezas/perturbações linear e não-linear. A análise dos resultados de simulações computacionais comprovou a eficácia

das novas estratégias de controle, apresentando características robustas diante das incertezas paramétricas e perturbações. Essas estratégias mantiveram a saída da planta sobre o sinal de referência em todo o período de simulação. Apenas na presença da perturbação não-linear na fonte geradora dos sinais de controle, o CEV/RNA-MIT-I não conseguiu amenizar a dinâmica indesejada presente na corrente de magnetização do rotor, porém com a utilização do CEV/RNA-MIT-II, tanto a velocidade do motor como a corrente de magnetização do rotor seguiram seus respectivos sinais de referência. Uma vantagem desta estratégia de controle robusta frente às incertezas e perturbações externas é que não é necessário conhecer os tipos de incertezas/perturbações que podem ocorrer no sistema, não sendo necessário projetar um controlador para cada condição de operação do sistema, além de não haver um chaveamento entre os controladores, como realizado na estratégia de controle com adaptação do controlador.

Neste trabalho, tipos específicos de incertezas e perturbações foram considerados apenas para comprovar a robustez da estratégia proposta. Esta robustez aplica-se a outros tipos de perturbações externas, incertezas e variações paramétricas da planta.

Os bons resultados obtidos nas simulações utilizando a RNA no auxílio de estratégia de controle comprovam a eficácia do método proposto no controle de sistemas lineares e não-lineares, incertos e sujeitos a perturbações.

- Trabalhos Futuros:

- Análise matemática da robustez da estratégia de controle proposta;
- Simulações computacionais em novos sistemas sujeitos a outros tipos de incertezas e perturbações externas;
- Implementação prática em kits didáticos.

REFERÊNCIAS

- ABBASZADEH, M.; MARQUEZ, H. J. Nonlinear robust H_∞ filtering for a class of uncertain systems via convex optimization. *Journal of Control Theory and Applications*, Guangzhou, v. 10, n. 2, p. 152–158, 2012.
- AEROSPACEWEB. (Org.). *Bank angle and G's: provo: engineers and scientists in the aerospace field*, 2009. [S.l.: s.n., 200-]. Disponível em: <<http://www.aerospaceweb.org/question/performance/q0146.shtml>>. Acesso em: 3 abr. 2009.
- BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDEMIR, T. B. *Redes neurais artificiais: teoria e aplicações*. 2. ed. [S.l.]: LTC, 2007.
- CHUNG, S. K.; LEE, J. H.; KO, J. S.; YOUN, M. J. A robust speed control of brushless direct drive motor using integral variable structure control with sliding mode observer. *Conf. Rec. IEEE IAS*, Taejon, v. 1, p. 393–400, 1994.
- CIRRINCIONE, M.; ACCETTA, A.; PUCCI, M.; VITALE, G. Mras speed observer for high-performance linear induction motor drives based on linear neural networks. *IEEE Transactions On Power Electronics*, Boston, v. 28, n. 1, p. 123–139, 2013.
- DA, F.; SONG, W. Fuzzy neural networks for direct adaptive control. *IEEE Transactions on Industrial Electronics*, Aquila, v. 50, n. 3, p. 507–513, 2003.
- DECANINI, J. G. M. S. D. *Deteção, classificação e localização de faltas de curto-circuito em sistemas de distribuição de energia elétrica usando sistemas inteligentes*. 2012. 124 f. Tese (Doutorado) — Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2013. Disponível em: <http://www.feis.unesp.br/Home/departamentos/engenhariaeletrica/pos-graduacao/089-tese_joseguilherme.pdf>. Acesso em: 15 nov. 2013.
- DECARLO, R. A.; ZAK, S. H.; MATTHEWS, G. P. Variable structure control of nonlinear and multivariable systems: a tutorial. *Institute of Electrical and Electronics Engineers*, New York, v. 76, n. 3, p. 212–232, 1988.
- DHAHRI, S.; HMIDA, F. B.; SELLAMI, A.; GOSSA, M. LMI-based sliding-mode observer design method for reconstruction of actuator and sensor faults. *International Journal on Sciences and Techniques of Automatic Control*, Tunisia, v. 1, n. 1, p. 91–107, 2007.
- DRAZENOVIC, B. The invariance conditions in variable structure systems. *Automatica*, Oxford, v. 5, p. 287–295, 1969.
- EDWARDS, C.; SPURGEON, S. K. On the development of discontinuous observers. *International Journal of Control*, London, v. 59, n. 5, p. 1211–1229, 1994.

- EFE, M. O. A novel error critic for variable structure control with an ADALINE. *Transactions of the Institute of Measurement and Control*, London, v. 24, n. 5, p. 403–415, 2002.
- EFE, M. O. Fuzzy variable structure control of a class of nonlinear sampled-data systems. *Journal of Dynamical and Control Systems*, New York, v. 9, n. 2, p. 233–256, 2003.
- EFE, M. O. Adaline based robust control in robotics: A riemann-liouville fractional differintegration based learning scheme. *Soft Computing*, Berlin, v. 13, n. 1, p. 23–29, 2009.
- EFE, M. O.; KAYNAK, O. Stabilizing and robustifying the learning mechanisms of artificial neural networks in control engineering applications. *International Journal of Intelligent Systems*, San Francisco, v. 15, n. 5, p. 365–388, 2000.
- EFE, M. O.; KAYNAK, O.; YU, X. Sliding mode control of a three degrees of freedom anthropoid robot by driving the controller parameters to an equivalent regime. *Journal of Dynamic Systems, Measurement and Control, Transactions of the ASME*, Austin, v. 122, n. 4, p. 632–640, 2000.
- EFE, M. O.; ÜNSAL, C.; KAYNAK, O.; YU, X. Variable structure control of a class of uncertain systems. *Automatica*, Oxford, v. 40, n. 1, p. 59–64, 2004.
- ERTUGRUL, M.; KAYNAK, O. Neuro sliding mode control of robotic manipulators. *Mechatronics*, New York, v. 10, p. 239–263, 2000.
- FILHO, E. F. M.; CARVALHO, A. C. P. L. F. Evolutionary design of mlp neural network architectures. In: SIMPÓSIO BRASILEIRO DE REDES NEURAIAS, 4, 1997, Goiânia. *Simpósio...* Goiânia: Universidade Federal de Goiás, 1997. p. 58-65.
- FITZGERALD, A. E.; KINGSLEY JUNIOR, C.; KUSKO, A. *Máquinas elétricas: conversão eletromecânica da energia, processos, dispositivos e sistemas*. [S.l.: s.n.], 1975.
- FU, Z. J.; XIE, W. F.; LUO, W. D. Induction motor identification using dynamic two-time scales neural networks with sliding mode learning. In: IEEE CANADIAN CONFERENCE ON ELECTRICAL AND COMPUTER ENGINEERING: VISION FOR A GREENER FUTURE, 25, 2012, Montreal, *Conference...* Montreal: Fairmont The Queen Elizabeth Hotel, 2012. p. 1-6.
- GARCIA, J. P. F.; GARCIA, L. M. C. F.; RODRIGUES, F. B.; APOLINÁRIO, G. C. Sliding mode for detection and accommodation of input-delay fault in uncertain system. SIMPÓSIO BRASILEIRO DE AUTOMAÇÃO INTELIGENTE, 9., 2009, Brasília. *Simpósio...* Brasília: Universidade de Brasília, 2009.
- GARCIA, L. M. C. F. *Controle com estrutura variável e modos deslizantes em sistemas incertos com atraso no controle*. 2002. 92f. Tese (Doutorado) — Escola Politécnica, Universidade de São Paulo, São Paulo, 2002.
- GARCIA, L. M. C. F.; BENNATON, J. F. Sliding mode control for uncertain input-delay systems with only plant output access. In: PROCEEDING OF THE INTERNATIONAL WORKSHOP ON VARIABLE STRUCTURE SYSTEMS, 7., 2002, Sarajevo. *Proceedings...* Sarajevo: [s.n.], 2002. p. 175–184.

- HAGAN, M. T.; MENHAJ, M. B. Training feedforward networks with the marquardt algorithm. *IEEE Transactions on Neural Network*, Beijing, v. 5, n. 6, p. 989–993, 1994.
- HAYKIN, S. *Neural networks: a comprehensive foundation*. 2nd. ed. New Jersey: Prentice-Hall, 1998, 842 p.
- HU, X.; WU, L.; HU, C.; GAO, H. Adaptive sliding mode tracking control for a flexible air-breathing hypersonic vehicle. *Journal of the Franklin Institute*, New York, v. 349, n. 2, p. 559–577, 2012.
- HUNG, J. Y.; GAO, W.; HUNG, J. C. Variable structure control: a survey. *IEEE Transactions on Industrial Electronics*, Aquila, v. 40, n. 1, p. 2–22, 1993.
- JAHANGIR, M.; GOLSHAN, M.; KHOSRAVI, S.; AFKHAMI, H. Design of a fast convergent backpropagation algorithm based on optimal control theory. *Nonlinear Dynamics*, Berlin, v. 70, n. 2, p. 1051–1059, 2012.
- KARAKUZU, C. Parameter tuning of fuzzy sliding mode controller using particle swarm optimization. *International Journal of Innovative Computing, Information and Control*, Fukuoka, v. 6, n. 10, p. 4755–4770, 2010.
- KAYNAK, O.; ERBATUR, K.; ERTUGRUL, M. The fusion of computationally intelligent methodologies and sliding-mode control - a survey. *IEEE Transactions on Industrial Electronics*, Aquila, v. 48, n. 1, p. 4–17, 2001.
- LEONHARD, W. *Control of electrical drives*. [S.l.]: Springer, 2001. 460 p.
- LIU, K.; ZHU, Z. Q. Online estimation of the rotor flux linkage and voltage-source inverter nonlinearity in permanent magnet synchronous machine drives. *IEEE Transactions on Power Electronics*, London, v. 29, n. 1, p. 418–427, 2014.
- LOPES, M. L. M. *Desenvolvimento de redes neurais para previsão de cargas elétricas de sistemas de energia elétrica*. 2005. 149 f. Tese (Doutorado) — Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2005. Disponível em: <http://www.feis.unesp.br/Home/departamentos/engenhariaeletrica/pos-graduacao/018-tese_mara_lucia_martins_lopes.pdf>. Acesso em: 15 nov. 2013.
- MAN, Z.; WU, H. R.; LIU, S.; YU, X. A new adaptive backpropagation algorithm based on lyapunov stability theory for neural networks. *IEEE Transactions on Neural Networks*, Beijing, v. 17, n. 6, p. 1580–1591, 2006.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, Berlin, n. 9, p. 127–147, 1943.
- MCELIECE, R. J.; POSNER, E. C.; RODEMICH, E. R.; VENKATESH, S. S. The capacity of the hopfield associative memory. *IEEE Transactions on Information Theory*, Toronto, TI-33, n. 4, p. 461–482, 1987.
- NIED, A.; Seleme Jr., S. I.; PARMA, G. G.; MENEZES, B. R. On-line neural training algorithm with sliding mode control and adaptive learning rate. *Neurocomputing*, New York, v. 70, p. 2687–2691, 2007.

- RODRIGUES, F. B. *Multicontroladores para melhoria da robustez e acomodação de falhas em sistemas*. 2009. 85 f. Dissertação (Mestrado) — Faculdade de Engenharia, Universidade Estadual Paulista - UNESP, Ilha Solteira, 2009. Disponível em: <http://www.feis.unesp.br/Home/departamentos/engenhariaeletrica/pos-graduacao/239-dissertacao_fernando_barros.pdf>. Acesso em: 15 jan. 2014.
- RODRIGUES, F. B.; GARCIA, J. P. F.; GARCIA, L. M. C. F.; APOLINÁRIO, G. C. Detecção e acomodação de falhas aplicado a um motor de indução com controle de estrutura variável. In: CONGRESSO BRASILEIRO DE AUTOMÁTICA, 18., 2010, Bonito. *Congresso...* Bonito: Centro de Convenções de Bonito, 2010. p. 2316-2323.
- RODRIGUEZ, R. G.; ZEGERS, P.; VEGA, V. P. Bounded-time system identification under neuro-sliding training. In: PROCEEDINGS OF INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS, 2009, Atlanta. *Conference...* Atlanta: Westin Peach Tree Hotel, 2009. p. 932-937.
- SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. *Redes neurais artificiais para engenharia e ciências aplicadas - curso prático*. São Paulo: Artliber, 2010. 399 p.
- SILVA, S. G. *Controle robusto de máquinas assíncronas usando estrutura variável e modo deslizante*. 1998. 89 f. Dissertação (Mestrado) — Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 1998.
- SILVA, S. G.; GARCIA, J. P. F.; TEIXEIRA, M. C. M. Variable structure controller and observer applied to induction machine. In: INTERNATIONAL WORKSHOP ON ADVANCED MOTION CONTROL, 1998, Coimbra. *Workshop...* Coimbra: Coimbra University, 1998.
- SIRA-RAMÍREZ, H.; COLINA-MORLES, E. A sliding mode strategy for adaptive learning in adalines. *IEEE Transactions on Circuits and Systems-I: Fundamental Theory and Applications*, Chennai, v. 42, n. 12, p. 1001–1012, 1995.
- SIRA-RAMÍREZ, H.; COLINA-MORLES, E.; RIVAS-ECHEVERRÍA, F. Sliding mode-based adaptive learning in dynamical-filter-weights neurons. *International Journal of Control*, London, v. 73, n. 8, p. 678–685, 2000.
- SPURGEON, S. K.; EDWARDS, C. *Sliding mode control: theory and applications*. Padstow: Taylor & Francis, 1998.
- TOPALOV, A. V.; CASCELLA, G. L.; GIORDANO, V.; CUPERTINO, F.; KAYNAK, O. Sliding mode neuro-adaptive control of electric drives. *IEEE Transactions on Industrial Electronics*, Aquila, v. 54, n. 1, p. 671–679, 2007.
- TOPALOV, A. V.; KAYNAK, O. Online learning in adaptive neurocontrol schemes with a sliding mode algorithm. *IEEE Transactions on Systems, Man, and Cybernetics, Part B: Cybernetics*, Bethesda, v. 31, n. 3, p. 445–450, 2001.
- TOPALOV, A. V.; KAYNAK, O. Neural network modeling and control of cement mills using a variable structure systems theory based on-line learning mechanism. *Journal of Process Control*, New York, v. 14, n. 5, p. 581–589, 2004.

- TOPALOV, A. V.; KAYNAK, O. Robust neural identification of robotic manipulators using discrete time adaptive sliding mode learning. In: IFAC WORLD CONGRESS, 16., 2005, Praga, *Congress...* Praga: Institute of Information Theory and Automation, v. 16, 2005. p. 276-276.
- TOPALOV, A. V.; KAYNAK, O.; AYDIN, G. Neuro-adaptive sliding-mode tracking control of robot manipulators. *International Journal of Adaptive Control and Signal Processing*, San Francisco, v. 21, p. 674–691, 2007.
- UTKIN, V. I. *Sliding modes and their applications in variable structure systems*. Moscow: Mir-Publishers, 1978. 257 p.
- WIDROW, B.; LEHR, M. 30 years of adaptive neural networks: Perceptron, madaline, and backpropagation. *Proceedings of the IEEE*, Raleigh, v. 78, n. 9, p. 1415–1442, 1990.
- WU, X.; WANG, Y.; DANG, X. Robust adaptive sliding-mode control of condenser-cleaning mobile manipulator using fuzzy wavelet neural network. *Fuzzy Sets and Systems*, New York, v. 235, n. 1, p. 62–82, 2014.
- XU, J. X.; GUO, Z. Q.; LEE, T. H. Design and implementation of integral sliding-mode control on an underactuated two-wheeled mobile robot. *IEEE Transactions on Industrial Electronics*, Aquila, v. 61, n. 7, p. 3671–3681, 2014.
- YAO, J.; JIAO, Z.; MA, D. Adaptive robust control of dc motors with extended state observer. *IEEE Transactions on Industrial Electronics*, Aquila, v. 61, n. 7, p. 3630–3637, 2014.
- YU, X.; EFE, M.; KAYNAK, O. A general backpropagation algorithm for feedforward neural networks learning. *IEEE Transactions on Neural Networks*, Beijing, v. 13, n. 1, p. 251–254, 2002.
- YU, X.; KAYNAK, O. Sliding-mode control with soft computing: a survey. *IEEE Transactions on Industrial Electronics*, Aquila, v. 56, n. 9, p. 3275–3285, 2009.
- ZHANG, X.; LIU, X.; ZHU, Q. Adaptive chatter free sliding mode control for a class of uncertain chaotic systems. *Applied Mathematics and Computation*, Berlin, v. 232, n. 7, p. 431–435, 2014.
- ZHAO, Y. On-line neural network learning algorithm with exponential convergence rate. *Electronics Letters*, Stevenage, v. 32, n. 15, p. 1381–1382, 1996.