

**UNIVERSIDADE FEDERAL DE PERNAMBUCO**  
**CENTRO DE TECNOLOGIA E GEOCIÊNCIAS**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA**

**APLICAÇÃO DE REDES NEURAIS**  
**ARTIFICIAIS NO CONTROLE EFICIENTE**  
**DO MOTOR DE INDUÇÃO TRIFÁSICO**

**ARINEU FELIX DOS SANTOS**

**Dissertação** submetida ao Programa de Pós-Graduação em Engenharia Elétrica da  
Universidade Federal de Pernambuco como parte dos requisitos para obtenção do grau de  
**Mestre em Engenharia Elétrica**

**ORIENTADOR: FRANCISCO DE ASSIS DOS SANTOS NEVES, D.SC.**

Recife, Julho de 2008.

**S237a**

**Santos, Arineu Felix dos.**

Aplicação de redes neurais artificiais no controle eficiente do motor de indução trifásico / Arineu Felix dos Santos.- Recife: O Autor, 2008. xix, 114 folhas, il : figs., gráfs., tabs.

Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG. Programa de Pós-Graduação em Engenharia Elétrica, 2008.

Inclui bibliografia e apêndice.

1. Engenharia elétrica. 2. Conservação de energia. 3. Eficiência.. 4. Motor de indução. 5. Saturação magnética. 6. Redes neurais artificiais. I. Título.

**UFPE**

**621.3**

**CDD (22. ed.)**

**BCTG/2008-136**



**Universidade Federal de Pernambuco**

***Pós-Graduação em Engenharia Elétrica***

PARECER DA COMISSÃO EXAMINADORA DE DEFESA DE  
DISSERTAÇÃO DO MESTRADO ACADÊMICO DE

**ARINEU FÉLIX DOS SANTOS**

TÍTULO

**“APLICAÇÃO DE REDES NEURAIAS ARTIFICIAIS NO CONTROLE  
EFICIENTE DO MOTOR DE INDUÇÃO TRIFÁSICO”**

A comissão examinadora composta pelos professores: RONALDO RIBEIRO BARBOSA DE AQUINO, DEESP/UFPE, MARCELO CABRAL CAVALCANTI, DEESP/UFPE, e BENJAMIM RODRIGUES DE MENEZES, DEE/UFMG sob a presidência do primeiro, consideram o candidato **ARINEU FÉLIX DOS SANTOS APROVADO.**

Recife, 07 de julho de 2008.

**EDUARDO FONTANA**  
Coordenador do PPGE

**RONALDO RIBEIRO BARBOSA DE AQUINO**  
Membro Titular Interno

**BENJAMIM RODRIGUES DE MENEZES**  
Membro Titular Externo

**MARCELO CABRAL CAVALCANTI**  
Membro Titular Interno

*"À Cachinho,  
Aos meus pais."*

# AGRADECIMENTOS

À Deus, pela sua presença constante em minha vida.

À Adine, por sempre me apoiar e incentivar, por sua presença, amor e dedicação em todos os momentos da minha vida.

Aos meus pais, Manoel, Lourdes, Zito e Cristina, aos meus irmãos Adjailson (*in memoriam*), Andrea e Adriana, pelo apoio, amor e carinho ao longo da minha caminhada. Gostaria que vocês soubessem que, mesmo não demonstrando, eu os amo profundamente.

Ao professor Francisco, pela orientação, paciência e confiança em mim depositada, além da amizade construída ao longo deste mestrado.

Aos que fazem o GEPAE (Grupo de Eletrônica de Potência e Acionamentos Elétricos), em especial, aos amigos Fabrício, Gustavo e Kléber pela convivência fraterna, disponibilidade, explicações e sugestões técnicas e pelos momentos de descontração.

Ao professor Ronaldo pela presença, ajuda, e por sempre acreditar na realização deste trabalho.

Aos amigos Josinaldo e Otoni, pelas contribuições dadas ao longo destes 2 anos.

A todos os professores, funcionários e amigos que contribuíram de forma direta ou indireta para a realização deste trabalho.

A CAPES pelo apoio financeiro.

ARINEU FELIX DOS SANTOS

*Universidade Federal de Pernambuco*

*07 de Julho de 2008*

*Sempre que você se propõe a fazer algo, você consegue. O importante é nunca dizer não, não importa o tamanho da dificuldade que existe no caminho. O homem sempre pode superar seus limites.*

**Cristopher Tronco**

Resumo da Dissertação apresentada à UFPE como parte dos requisitos necessários para a obtenção do grau de Mestre em Engenharia Elétrica

## **APLICAÇÃO DE REDES NEURAS ARTIFICIAIS NO CONTROLE EFICIENTE DO MOTOR DE INDUÇÃO TRIFÁSICO**

**Arineu Felix dos Santos**

Julho/2008

**Orientador:** Francisco de Assis dos Santos Neves, D.Sc.

**Área de Concentração:** Processamento de Energia

**Palavras-chaves:** Conservação de Energia, Eficiência, Motor de Indução, Saturação Magnética, Redes Neurais Artificiais

**Número de páginas:** 114

O motor de indução trifásico, embora seja uma máquina intrinsecamente eficiente, pode, através de acionamento inadequado, levar a um consumo excessivo de energia, quer seja devido ao grande número de motores instalados, quer seja devido à freqüente aplicação ineficiente dos mesmos. Esta dissertação apresenta a implementação de uma técnica de controle sob orientação pelo campo que utiliza redes neurais artificiais como ferramenta auxiliar na busca de uma maior eficiência de um motor de indução trifásico com rotor em gaiola. Para esse fim, as redes neurais atuam na predição do fluxo de rotor de referência, para uma dada condição operacional, o qual é utilizado no controle direto de fluxo e conjugado, resultando, assim, na redução das perdas na máquina. As equações do modelo eletromagnético da máquina de indução, com inclusão da saturação magnética do ferro do núcleo, em um referencial arbitrário, bem como o estimador de fluxo de rotor são descritos. Simulações digitais são utilizadas para criação do banco de dados, treinamento e escolha das melhores arquiteturas das redes neurais, além do estudo do comportamento do sistema acionado para diversas condições de velocidade e de carga. Por fim, são apresentados os resultados experimentais e avaliado o desempenho das redes neurais e sua influência sobre o consumo de energia pelo motor de indução.

Abstract of Dissertation presented to UFPE as a partial fulfillment of the requirements for the degree of Master in Electrical Engineering

**APPLICATION OF ARTIFICIAL NEURAL NETWORK  
IN THE EFFICIENT CONTROL THREE-PHASE  
INDUCTION MOTOR**

**Arineu Felix dos Santos**

July/2008

**Supervisor:** Francisco de Assis dos Santos Neves, D.Sc.

**Area of Concentration:** Energy processing

**Keywords:** Energy Conservation, Efficiency, Induction Motor, Magnetic Saturation, Neural Network

**Number of pages:** 114

Although the induction motor is an intrinsically efficient machine, it may greatly contribute for energy conservation, due to the great number of installed motors, or due to inadequate choice of the best motor for a specific application.

This dissertation presents an implementation of a field oriented control technique, which uses artificial neural networks for improving the efficiency of an squirrel cage induction motor drive. For that end, the neural networks determine the rotor reference flux, for a given operational condition. This reference flux is used in the direct field oriented control, resulting in the reduction of the machine losses.

The equations of the electromagnetic model of the induction machine in an arbitrary reference frame, including the effects of magnetic saturation, as well as the rotor flux linkage estimators are described.

Digital simulations are used to create the database, training and also selecting the best neural network architectures. Besides, the system's behavior for different speeds and loads is verified through simulations. Finally, experimental results are presented and the neural networks performance and their influence on the induction motor energy consumption are evaluated.

# CONTEÚDO

<b>LISTA DE FIGURAS</b>	<b>xii</b>
<b>LISTA DE TABELAS</b>	<b>xvi</b>
<b>LISTA DE NOMENCLATURAS E SÍMBOLOS</b>	<b>xviii</b>
<b>1 ASPECTOS GERAIS</b>	<b>1</b>
<b>1.1 Introdução</b> . . . . .	1
<b>1.2 Distribuição das Perdas em um Motor de Indução Trifásico</b> . . . . .	3
1.2.1 Perdas nos Núcleos . . . . .	3
1.2.2 Perdas Mecânicas . . . . .	3
1.2.3 Perdas no Circuito Elétrico do Estator e do Rotor . . . . .	4
1.2.4 Perdas Suplementares . . . . .	4
<b>1.3 Conservação de Energia</b> . . . . .	5
1.3.1 Fase de Projeto . . . . .	7
1.3.2 Técnicas de Controle . . . . .	7
<b>1.4 Objetivos</b> . . . . .	9
<b>1.5 Organização do Texto</b> . . . . .	9
<b>2 MODELAGEM DO SISTEMA</b>	<b>11</b>
<b>2.1 O Modelo Vetorial</b> . . . . .	11
<b>2.2 A Saturação Magnética</b> . . . . .	15
<b>2.3 Estimador de Fluxo de Rotor</b> . . . . .	19
2.3.1 Estimador 1 . . . . .	20
2.3.2 Estimador 2 . . . . .	21

<b>2.4</b>	<b>Estratégia de Controle Vetorial do Motor de Indução</b>	<b>23</b>
2.4.1	Controle Orientado Segundo o Fluxo de Rotor	24
<b>2.5</b>	<b>Resultados de Simulação</b>	<b>28</b>
2.5.1	Partida e Aplicação de Carga	30
2.5.2	Partida e Reversão de Velocidade	32
2.5.3	Partida e Variação do Fluxo de Referência	35
<b>3</b>	<b>ASPECTOS GERAIS SOBRE REDES NEURAIS ARTIFICIAIS</b>	<b>38</b>
<b>3.1</b>	<b>Introdução</b>	<b>38</b>
<b>3.2</b>	<b>Neurônios Biológicos</b>	<b>39</b>
<b>3.3</b>	<b>Neurônios Artificiais</b>	<b>40</b>
<b>3.4</b>	<b>Aprendizagem</b>	<b>45</b>
<b>3.5</b>	<b>Redes MLP</b>	<b>48</b>
3.5.1	Algoritmo de Retropropagação	48
<b>3.6</b>	<b>A Técnica Implementada</b>	<b>52</b>
<b>4</b>	<b>TREINAMENTO, ESCOLHA E DESEMPENHO DAS REDES MLP UTILIZADAS</b>	<b>55</b>
<b>4.1</b>	<b>Escolha das Variáveis de Entrada</b>	<b>55</b>
<b>4.2</b>	<b>Criação das Redes</b>	<b>56</b>
4.2.1	Obtenção, Tratamento e Separação dos Dados	56
4.2.2	Processo de Treinamento e Escolha da Melhor Arquitetura	59
4.2.3	Método de Validação Cruzada	62
<b>4.3</b>	<b>Resultados do Treinamento das Redes</b>	<b>63</b>
4.3.1	Resultados do Treinamento da Rede 1	63
4.3.2	Resultados do Treinamento da Rede 2	65
4.3.3	Resultados do Treinamento da Rede 3	66
4.3.4	Resultados do Treinamento da Rede 4	68
4.3.5	Resultados do Treinamento da Rede 5	69
4.3.6	Resultados do Treinamento da Rede 6	71
4.3.7	Resultados do Treinamento da Rede 7	72
4.3.8	Resultados do Treinamento da Rede 8	74

4.3.9	Resultados do Treinamento da Rede 9 . . . . .	75
4.3.10	Resultados do Treinamento da Rede 10 . . . . .	76
<b>5</b>	<b>SIMULAÇÕES E RESULTADOS EXPERIMENTAIS</b>	<b>81</b>
<b>5.1</b>	<b>Descrição dos Testes . . . . .</b>	<b>82</b>
5.1.1	Partida e Variação de Velocidade, com o Motor Operando em Vazio .	82
5.1.2	Partida e Variação de Carga . . . . .	82
5.1.3	Partida e Aplicação de Carga . . . . .	82
<b>5.2</b>	<b>Resultados de Simulação . . . . .</b>	<b>83</b>
5.2.1	Partida e Variação de Velocidade . . . . .	83
5.2.2	Partida e Variação de Carga . . . . .	85
<b>5.3</b>	<b>Estrutura Básica do Sistema de Acionamento . . . . .</b>	<b>88</b>
<b>5.4</b>	<b>Resultados Experimentais . . . . .</b>	<b>90</b>
5.4.1	Partida e Variação de Velocidade . . . . .	91
5.4.2	Partida e Aplicação de Carga . . . . .	94
<b>6</b>	<b>CONCLUSÃO</b>	<b>104</b>
<b>6.1</b>	<b>Trabalhos Futuros . . . . .</b>	<b>105</b>
<b>Apêndice A DADOS E PARÂMETROS DOS COMPONENTES DO SISTEMA DE</b>		
<b>ACIONAMENTO</b>		<b>107</b>
<b>A.1</b>	<b>Máquina de Indução . . . . .</b>	<b>107</b>
<b>A.2</b>	<b>Máquina de Corrente Contínua . . . . .</b>	<b>107</b>
<b>A.3</b>	<b>Chaves Estáticas do Conversor CA/CC/CA . . . . .</b>	<b>108</b>
<b>A.4</b>	<b>Componentes Passivos do Conversor CA/CC/CA . . . . .</b>	<b>108</b>
<b>REFERÊNCIAS BIBLIOGRÁFICAS</b>		<b>109</b>

# LISTA DE FIGURAS

1.1	Utilização da energia elétrica: (a) no país e (b) na indústria. . . . .	1
1.2	Tipos de motores elétricos. . . . .	2
1.3	Distribuição dos MIT vendidos por faixa de potência. . . . .	3
1.4	Perdas em um motor de indução trifásico. . . . .	4
1.5	Distribuição percentual das perdas em função da carga em um MIT de 15 cv. . . . .	5
1.6	Distribuição percentual das perdas em função da potência do motor. . . . .	5
1.7	Curva de rendimento de um motor de indução trifásico. . . . .	6
2.1	Sistema de coordenadas dq girante a uma velocidade arbitrária. . . . .	12
2.2	Circuito equivalente em coordenadas dq da máquina de indução em referencial arbitrário. . . . .	15
2.3	Alinhamento dos domínios magnéticos. . . . .	16
2.4	Curva característica de circuito aberto típica e linha de entreferro. . . . .	16
2.5	Curva característica de circuito aberto experimental. . . . .	17
2.6	Diagrama de blocos do estimador 1 com inclusão da saturação magnética. . . . .	21
2.7	Diagrama de blocos do estimador 2 com inclusão da saturação magnética. . . . .	22
2.8	Diagrama esquemático do sistema de acionamento implementado. . . . .	25
2.9	Controle vetorial orientado segundo o fluxo de rotor. . . . .	25
2.10	Resultados de simulação. Evolução do fluxo, da velocidade e do conjugado. Partida e aplicação de carga: (a) Estimador 1; (b) Estimador 2. . . . .	30
2.11	Resultados de simulação. Evolução das componentes de corrente de eixos direto e em quadratura. Partida e aplicação de carga: (a) Estimador 1; (b) Estimador 2. . . . .	31
2.12	Resultados de simulação. Evolução da indutância e da corrente de magnetização. Partida e aplicação de carga: (a) Estimador 1; (b) Estimador 2. . . . .	31

2.13	Resultados de simulação. Trajetória do vetor fluxo de rotor. Partida e aplicação de carga - Estimador 1. . . . .	32
2.14	Resultados de simulação. Evolução do fluxo, da velocidade e do conjugado. Partida e reversão de velocidade: (a) Estimador 1; (b) Estimador 2. . . . .	33
2.15	Resultados de simulação. Evolução das componentes de corrente de eixos direto e em quadratura. Partida e reversão de velocidade: (a) Estimador 1; (b) Estimador 2. . . . .	33
2.16	Resultados de simulação. Plano de fase - Conjugado x Velocidade. Partida e reversão de velocidade: (a) Estimador 1; (b) Estimador 2. . . . .	34
2.17	Resultados de simulação. Evolução da indutância e da corrente de magnetização. Partida e reversão de velocidade: (a) Estimador 1; (b) Estimador 2. . . . .	34
2.18	Resultados de simulação. Trajetória do vetor fluxo de rotor. Partida e reversão de velocidade - Estimador 1. . . . .	35
2.19	Resultados de simulação. Evolução do fluxo, da velocidade e do conjugado. Partida e variação do fluxo de referência: (a) Estimador 1; (b) Estimador 2. . . . .	35
2.20	Resultados de simulação. Evolução das componentes de corrente de eixos direto e em quadratura. Partida e variação do fluxo de referência: (a) Estimador 1; (b) Estimador 2. . . . .	36
2.21	Resultados de simulação. Evolução da indutância e da corrente de magnetização. Partida e variação do fluxo de referência: (a) Estimador 1; (b) Estimador 2. . . . .	36
2.22	Resultados de simulação. Trajetória do vetor fluxo de rotor. Partida e variação do fluxo de referência - Estimador 1. . . . .	37
3.1	Partes do neurônio biológico. . . . .	40
3.2	Partes do neurônio artificial. . . . .	41
3.3	Transformação afim produzida pela presença de um bias. . . . .	43
3.4	Funções de ativação: (a) Sinal, (b) Linear por partes, (c) Sigmoidal, (d) Gaussiana. . . . .	43
3.5	Rede de Múltiplas Camadas. . . . .	44
3.6	Aprendizado supervisionado. . . . .	46
3.7	Aprendizado não-supervisionado. . . . .	46
3.8	Fluxo de processamento do algoritmo backpropagation. . . . .	49
3.9	Potência de entrada x fluxo de rotor: (a) $\omega_r = 0,25p.u.$ ; (b) $T_c = 0,25p.u.$ . . . . .	52

3.10	Controle convencional x Controle neural. . . . .	53
4.1	Superfície representativa do banco de dados. . . . .	57
4.2	Potências de entrada - Rede 1. . . . .	64
4.3	Potências de entrada - Rede 2. . . . .	65
4.4	Potências de entrada - Rede 3. . . . .	67
4.5	Potências de entrada - Rede 4. . . . .	69
4.6	Potências de entrada - Rede 5. . . . .	70
4.7	Potências de entrada - Rede 6. . . . .	72
4.8	Potências de entrada - Rede 7. . . . .	73
4.9	Potências de entrada - Rede 8. . . . .	75
4.10	Potências de entrada - Rede 9. . . . .	76
4.11	Potências de entrada - Rede 10. . . . .	77
4.12	Superfície gerada através das redes neurais. . . . .	80
5.1	Resultados de simulação. Variação de velocidade. Máquina em vazio. Evolução do fluxo e da velocidade: (a) sem rede neural; (b) com rede neural.	83
5.2	Resultados de simulação. Variação de velocidade. Máquina em vazio. Evolução do conjugado: (a) sem rede neural; (b) com rede neural. . . . .	84
5.3	Resultados de simulação. Variação de velocidade. Máquina em vazio. Trajetória do vetor fluxo de rotor: (a) sem rede neural; (b) com rede neural.	84
5.4	Resultados de simulação. Variação de velocidade. Máquina em vazio. Evolução das componentes de corrente de eixos direto e em quadratura: (a) sem rede neural; (b) com rede neural. . . . .	85
5.5	Resultados de simulação. Partida e aplicação de carga. Evolução do fluxo e da velocidade: (a) sem rede neural; (b) com rede neural. . . . .	86
5.6	Resultados de simulação. Partida e aplicação de carga. Evolução do conjugado: (a) sem rede neural; (b) com rede neural. . . . .	87
5.7	Resultados de simulação. Partida e aplicação de carga. Trajetória do vetor fluxo de rotor:(a) sem rede neural; (b) com rede neural. . . . .	87
5.8	Resultados de simulação. Partida e aplicação de carga. Evolução das componentes de corrente de eixos direto e em quadratura: (a) sem rede neural; (b) com rede neural. . . . .	88
5.9	Estrutura básica do sistema de acionamento. . . . .	89

5.10	Resultados experimentais. Aplicação e variação de velocidade. Máquina em vazio. Evolução do fluxo e da velocidade: (a) sem rede neural; (b) com rede neural. . . . .	91
5.11	Resultados experimentais. Aplicação e variação de velocidade. Máquina em vazio. Evolução do conjugado e da potência de entrada: (a) sem rede neural; (b) com rede neural. . . . .	92
5.12	Resultados experimentais. Aplicação e variação de velocidade. Máquina em vazio. Evolução das componentes de corrente de eixos direto e em quadratura: (a) sem rede neural; (b) com rede neural. . . . .	93
5.13	Resultados experimentais. Aplicação e retirada de carga. Evolução do fluxo e da velocidade. $\omega_{r*} = 204 \text{ rad.ele/s}$ : (a) sem rede neural; (b) com rede neural. . . . .	94
5.14	Resultados experimentais. Aplicação e retirada de carga. Evolução das componentes de corrente de eixos direto e em quadratura. $\omega_{r*} = 204 \text{ rad.ele/s}$ : (a) sem rede neural; (b) com rede neural. . . . .	95
5.15	Resultados experimentais. Aplicação e retirada de carga. Evolução do conjugado e da potência de entrada. $\omega_{r*} = 204 \text{ rad.ele/s}$ : (a) sem rede neural; (b) com rede neural. . . . .	96
5.16	Resultados experimentais. Aplicação e retirada de carga. Evolução do fluxo e da velocidade. $\omega_{r*} = 238 \text{ rad.ele/s}$ : (a) sem rede neural; (b) com rede neural. . . . .	97
5.17	Resultados experimentais. Aplicação e retirada de carga. Evolução das componentes de corrente de eixos direto e em quadratura. $\omega_{r*} = 238 \text{ rad.ele/s}$ : (a) sem rede neural; (b) com rede neural. . . . .	98
5.18	Resultados experimentais. Aplicação e retirada de carga. Evolução do conjugado e da potência de entrada. $\omega_{r*} = 238 \text{ rad.ele/s}$ : (a) sem rede neural; (b) com rede neural. . . . .	98
5.19	Resultados experimentais. Aplicação e retirada de carga. Evolução do fluxo e da velocidade. $\omega_{r*} = 272 \text{ rad.ele/s}$ : (a) sem rede neural; (b) com rede neural. . . . .	99
5.20	Resultados experimentais. Aplicação e retirada de carga. Evolução das componentes de corrente de eixos direto e em quadratura. $\omega_{r*} = 272 \text{ rad.ele/s}$ : (a) sem rede neural; (b) com rede neural. . . . .	100
5.21	Resultados experimentais. Aplicação e retirada de carga. Evolução do conjugado e da potência de entrada. $\omega_{r*} = 272 \text{ rad.ele/s}$ : (a) sem rede neural; (b) com rede neural. . . . .	100

# LISTA DE TABELAS

2.1	Ganhos de simulação dos controladores PI . . . . .	29
4.1	Limites do banco de dados . . . . .	56
4.2	Rede neural artificial versus faixa operacional . . . . .	58
4.3	Variações das arquiteturas das redes neurais artificiais . . . . .	61
4.4	Formação dos conjuntos de treinamento, validação e teste . . . . .	62
4.5	Arquitetura da Rede 1 . . . . .	63
4.6	Resultado do treinamento da melhor rede - Ensaio 1 . . . . .	63
4.7	Rede 1 - Conjugado de carga = 0 p.u. . . . .	64
4.8	Arquitetura da Rede 2 . . . . .	65
4.9	Resultado do treinamento da melhor rede - Ensaio 2 . . . . .	65
4.10	Rede 2 - Conjugado de carga = 0,1 p.u. . . . .	66
4.11	Rede 2 - Conjugado de carga = 0,2 p.u. . . . .	66
4.12	Arquitetura da Rede 3 . . . . .	67
4.13	Resultado do treinamento da melhor rede - Ensaio 3 . . . . .	67
4.14	Rede 3 - Conjugado de carga = 0,3 p.u. . . . .	68
4.15	Arquitetura da Rede 4 . . . . .	68
4.16	Resultado do treinamento da melhor rede - Ensaio 4 . . . . .	68
4.17	Arquitetura da Rede 5 . . . . .	69
4.18	Resultado do treinamento da melhor rede - Ensaio 5 . . . . .	69
4.19	Rede 5 - Conjugado de carga = 0,4 p.u. . . . .	70
4.20	Rede 5 - Conjugado de carga = 0,5 p.u. . . . .	71
4.21	Arquitetura da Rede 6 . . . . .	71
4.22	Resultado do treinamento da melhor rede - Ensaio 6 . . . . .	71

4.23	Arquitetura da Rede 7 . . . . .	72
4.24	Resultado do treinamento da melhor rede - Ensaio 7 . . . . .	72
4.25	Rede 7 - Conjugado de carga = 0,6 p.u. . . . .	73
4.26	Rede 7 - Conjugado de carga = 0,7 p.u. . . . .	74
4.27	Arquitetura da Rede 8 . . . . .	74
4.28	Resultado do treinamento da melhor rede - Ensaio 8 . . . . .	74
4.29	Arquitetura da Rede 9 . . . . .	75
4.30	Resultado do treinamento da melhor rede - Ensaio 9 . . . . .	75
4.31	Rede 9 - Conjugado de carga = 0,8 p.u. . . . .	76
4.32	Arquitetura da Rede 10 . . . . .	77
4.33	Resultado do treinamento da melhor rede - Ensaio 10 . . . . .	77
4.34	Rede 10 - Conjugado de carga = 0,9 p.u. . . . .	78
4.35	Rede 10 - Conjugado de carga = 1 p.u. . . . .	78
4.36	Resumo das arquiteturas das redes . . . . .	79
5.1	Ganhos experimentais dos controladores PI . . . . .	90
5.2	Potências de entradas experimentais da máquina operando em vazio . . . . .	93
5.3	Resultados Experimentais: $\omega_r^* = 204$ rad.ele/s . . . . .	97
5.4	Resultados Experimentais: $\omega_r^* = 238$ rad.ele/s . . . . .	99
5.5	Resultados Experimentais: $\omega_r^* = 272$ rad.ele/s . . . . .	101
5.6	Resultados Experimentais: $\omega_r^* = 306$ rad.ele/s . . . . .	102
5.7	Resultados Experimentais: $\omega_r^* = 340$ rad.ele/s . . . . .	102

# Lista de Nomenclaturas e Símbolos

$\eta$	rendimento
$\Im$	parte imaginária
$\lambda_{md}$	fluxo de magnetização em eixo direto [Wb]
$\lambda_{mq}$	fluxo de magnetização em eixo de quadratura [Wb]
$\lambda_{rd}$	fluxo de rotor em eixo direto [Wb]
$\lambda_{rq}$	fluxo de rotor em eixo de quadratura [Wb]
$\lambda_{sd}$	fluxo de estator em eixo direto [Wb]
$\lambda_{sq}$	fluxo de estator em eixo de quadratura [Wb]
$\nu_k$	potencial de ativação do neurônio k
$\omega_e$	velocidade angular do sistema de coordenadas $dq$ [rad/s]
$\omega_{fr}$	velocidade angular do vetor fluxo de rotor [rad/s]
$\omega_r$	velocidade angular do rotor [rad/s]
$\omega_s$	velocidade angular síncrona [rad/s]
$\vec{\lambda}_m$	vetor espacial fluxo de magnetização [Wb]
$\vec{\lambda}_r$	vetor espacial fluxo de rotor [Wb]
$\vec{\lambda}_s$	vetor espacial fluxo de estator [Wb]
$\vec{i}_m$	vetor espacial corrente de magnetização [A]
$\vec{i}_r$	vetor espacial corrente de rotor [A]
$\vec{i}_s$	vetor espacial corrente de estator [A]
$\vec{v}_r$	vetor espacial tensão de rotor [V]
$\vec{v}_s$	vetor espacial tensão de estator [V]
$\sigma$	coeficiente de dispersão da máquina

$\tau_r$	constante de tempo do rotor
$\tau_s$	constante de tempo do estator
$\theta_e$	posição angular do sistema de coordenadas $dq$ [rad]
$\varphi(\cdot)$	função de ativação
$AD$	Analógico - Digital
$CA$	Corrente Alternada
$CC$	Corrente Contínua
$DA$	Digital - Analógico
$i_{md}$	corrente de magnetização em eixo direto [A]
$i_{mq}$	corrente de magnetização em eixo de quadratura [A]
$i_{rd}$	corrente de rotor em eixo direto [A]
$i_{rq}$	corrente de rotor em eixo de quadratura [A]
$i_{sd}$	corrente de estator em eixo direto [A]
$i_{sq}$	corrente de estator em eixo de quadratura [A]
$J$	momento de inércia [ $Kg.m^2$ ]
$K_i$	ganho integral
$K_p$	ganho proporcional
$L_m$	indutância de magnetização [H]
$L_r$	indutância própria de rotor [H]
$L_s$	indutância própria de estator [H]
$L_{lr}$	indutância de dispersão de rotor [H]
$L_{ls}$	indutância de dispersão de estator [H]
$MIT$	Motor de Indução Trifásico
$P$	número de pólos
$P_{CR}$	valor médio da potência de entrada em regime permanente com RNA
$P_E$	potência elétrica de entrada nos terminais da máquina
$P_M$	potência mecânica de saída no eixo da máquina
$P_{SR}$	valor médio da potência de entrada em regime permanente sem RNA

$PWM$	Modulação por Largura de Pulso - <i>Pulse-Width Modulation</i>
$R_r$	resistência de rotor
$R_s$	resistência de estator
$RNA$	Rede Neural Artificial
$S_j$	função de chaveamento da chave $S_j$ do inversor
$T_c$	conjugado de carga [N.m]
$T_e$	conjugado eletromagnético [N.m]
$v_{rd}$	tensão de rotor em eixo direto [V]
$v_{rq}$	tensão de rotor em eixo de quadratura [V]
$v_{sd}$	tensão de estator em eixo direto [V]
$v_{sq}$	tensão de estator em eixo de quadratura [V]
$x$	qualquer grandeza trifásica elétrica ou magnética da máquina
[H]	matriz Hessiana
[J]	matriz Jacobiana
$b_k$	bias do neurônio k
E	medida do erro total
MAPE	Erro Médio Percentual - <i>Mean Absolute Percentage Error</i>
MLP	Redes de Múltiplas Camadas - <i>MultiLayer Perceptron</i>
MSE	Erro Médio Quadrático - <i>Mean Square Error</i>
RBF	Funções de Bases Radiais - <i>Radial Basis Function</i>
$u_k$	sinal de saída do somador do neurônio k
$w_{kj}$	peso que conecta o terminal de entrada j ao neurônio k
$y_{ck}$	saída calculada do neurônio k
$y_{dk}$	saída desejada do neurônio k
$y_k$	sinal de saída do neurônio k



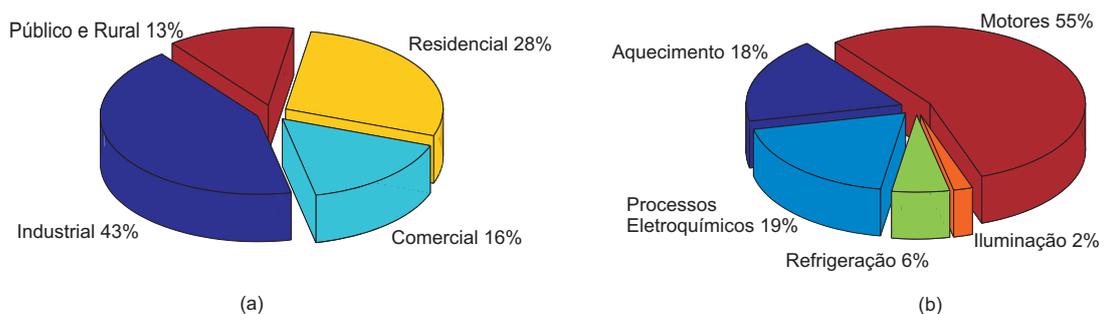
# 1

## ASPECTOS GERAIS

### 1.1 Introdução

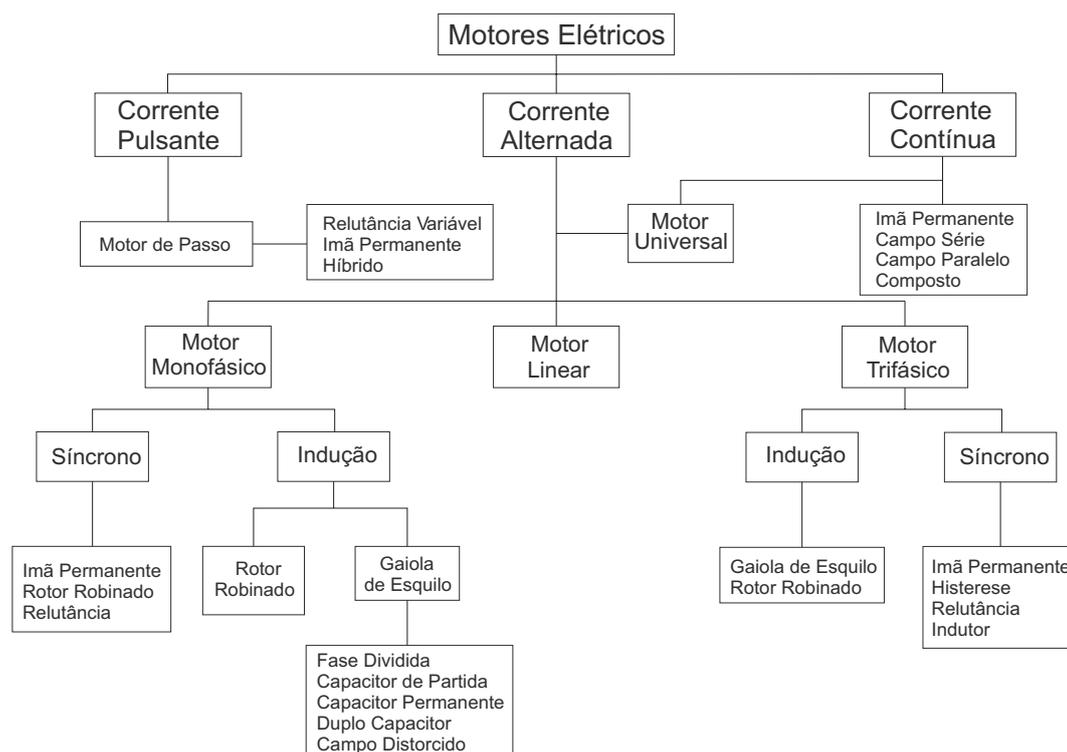
Ao longo da história, o homem procurou meios de saciar suas necessidades de forma a utilizar o menor esforço possível. Dentre as principais descobertas, a da eletricidade e a do motor elétrico garantiram a substituição de grande parte de seu trabalho braçal pela força motriz proporcionada pelos motores elétricos [1].

Hoje, o homem se serve do motor elétrico no seu dia-a-dia, tanto diretamente em aparelhos domésticos como liquidificadores, geladeiras etc. quanto indiretamente, através de produtos industrializados como remédios, vestuários, alimentos etc. Na Fig. 1.1 é mostrada a distribuição do consumo de energia elétrica nos principais setores do País e como esta energia é usada dentro do setor industrial [2].



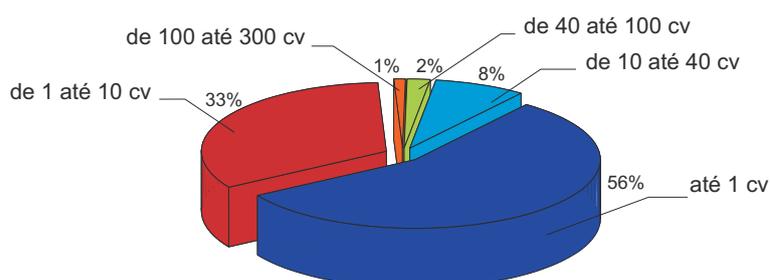
**Figura 1.1:** Utilização da energia elétrica: (a) no país e (b) na indústria.

O motor elétrico é um equipamento destinado a transformar energia elétrica em energia mecânica. Ele é o mais usado entre todos os tipos de motores, pois combina as vantagens da energia elétrica com a de sua construção simples, além de possuir as mais variadas formas e tamanhos, de acordo com o fim a que se destina. Geralmente sua classificação é feita segundo a sua tensão de alimentação como mostrado na Fig. 1.2 [1].



**Figura 1.2:** Tipos de motores elétricos.

Dentre as diversas classes de motores elétricos existentes, os de indução são os mais utilizados, devido à sua simplicidade, robustez e baixo custo. Estima-se que, no Brasil, nas últimas duas décadas (1985-2005), foram vendidos cerca de dois milhões e quinhentos mil motores de indução trifásicos (MIT) [2]. A distribuição percentual destes motores por faixa de potência é ilustrada na Fig. 1.3 [2].



**Figura 1.3:** Distribuição dos MIT vendidos por faixa de potência.

## 1.2 Distribuição das Perdas em um Motor de Indução Trifásico

Como em qualquer outro equipamento conversor de energia, uma parte da energia fornecida ao motor elétrico estará disponível para realização de trabalho útil e outra se destinará a suprir as perdas internas inerentes ao processo de conversão. Tais perdas podem ser agrupadas da seguinte forma:

### 1.2.1 Perdas nos Núcleos

Também chamadas de perdas no ferro, são perdas que ocorrem nos pacotes magnéticos do estator e do rotor, constituídas pelas perdas por histerese e Foucault (correntes parasitas). A perda por histerese resulta da constante reorientação do campo magnético sobre o pacote de lâminas de aço-silício (material mais utilizado). Já as perdas por Foucault são devidas às correntes induzidas no interior do material magnético, que circulando, produzem perdas na forma de calor. Estas perdas dependem da frequência e da densidade máxima de fluxo. No caso particular das perdas por corrente parasitas, elas dependem também da espessura e do isolamento das lâminas do pacote magnético [1] [3].

### 1.2.2 Perdas Mecânicas

São as perdas devidas ao atrito nos mancais ou nos rolamentos da máquina, somadas às perdas por ventilação, devidas à resistência do ar e à movimentação do rotor. Em geral, quando o motor está operando em carga nominal, elas são a menor parcela da perda total.

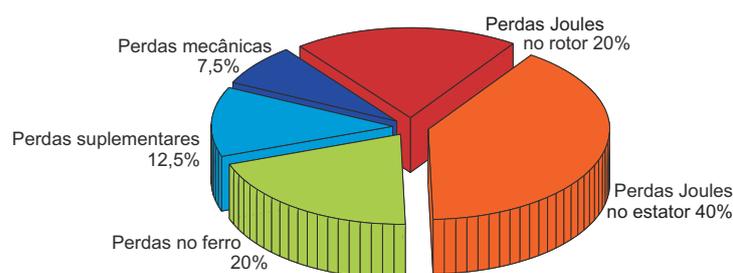
### 1.2.3 Perdas no Circuito Elétrico do Estator e do Rotor

São as perdas por efeito Joule resultantes da passagem da corrente elétrica pelos enrolamentos de estator e rotor. As perdas que ocorrem na gaiola do rotor dependem da carga, do material do condutor da gaiola, da seção reta e do comprimento das barras e são aproximadamente proporcionais ao escorregamento de operação [1].

### 1.2.4 Perdas Suplementares

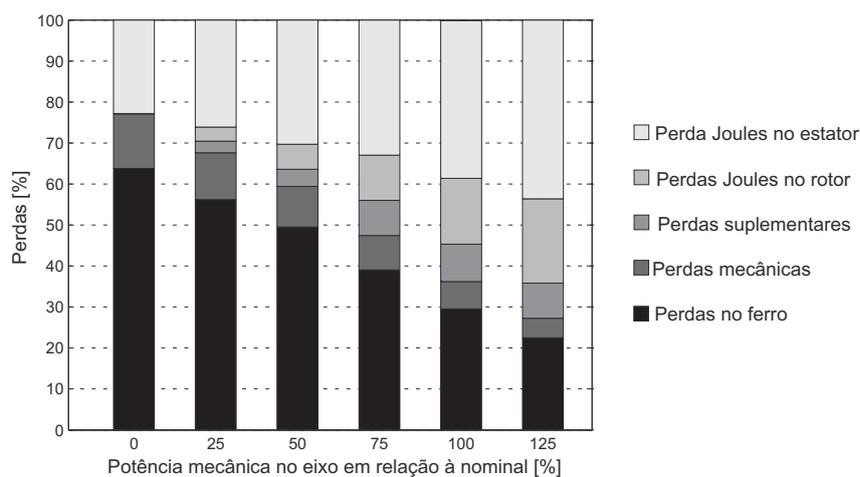
São as perdas resultantes da diferença entre a perda total do motor e os três tipos de perdas citados acima. Elas levam em conta vários fenômenos, tais como a distribuição não uniforme da corrente nos enrolamentos, o efeito da saturação e as imperfeições na densidade de campo magnético (devido às ranhuras do estator e do rotor) e ocasionam perdas ôhmicas nas barras das gaiolas, associadas aos harmônicos de corrente [1]. As perdas suplementares crescem proporcionalmente com o quadrado da corrente de carga.

Todas estas perdas variam de acordo com as condições operacionais do motor. Na Fig.1.4[3] é apresentada a relação de proporção e distribuição média das perdas em um motor operando em condições nominais.

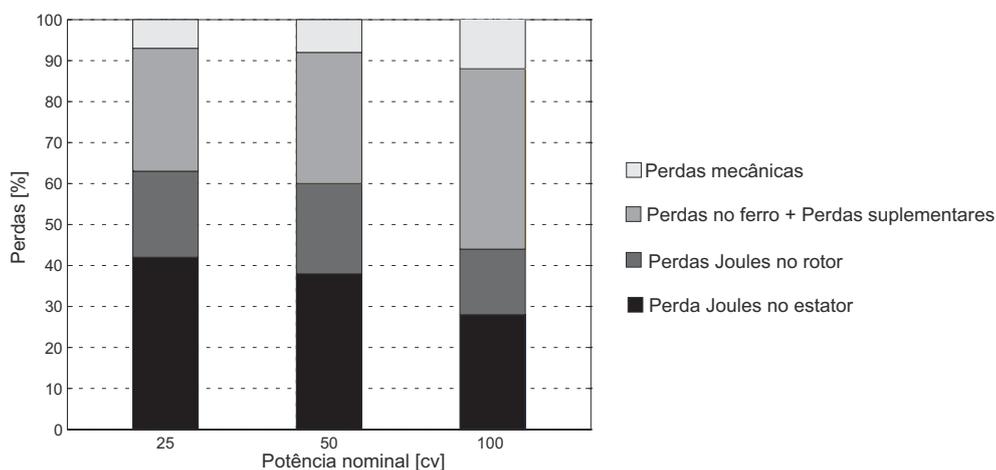


**Figura 1.4:** Perdas em um motor de indução trifásico.

No caso em que o motor está operando fora de suas condições nominais, a distribuição das perdas varia significativamente. Na Fig. 1.5 [2] é mostrada a variação típica das perdas de um MIT de 15 cv (cavalo-vapor) em função da potência mecânica fornecida em seu eixo. Além das condições operacionais, a potência do motor influencia nas perdas como ilustrado na Fig. 1.6 [2] a qual mostra a evolução das perdas em função da potência do motor.



**Figura 1.5:** Distribuição percentual das perdas em função da carga em um MIT de 15 cv.



**Figura 1.6:** Distribuição percentual das perdas em função da potência do motor.

### 1.3 Conservação de Energia

Como foi dito anteriormente, a potência útil disponível no eixo do motor é menor que a potência elétrica absorvida da rede. A relação entre elas é chamada rendimento e é dada por:

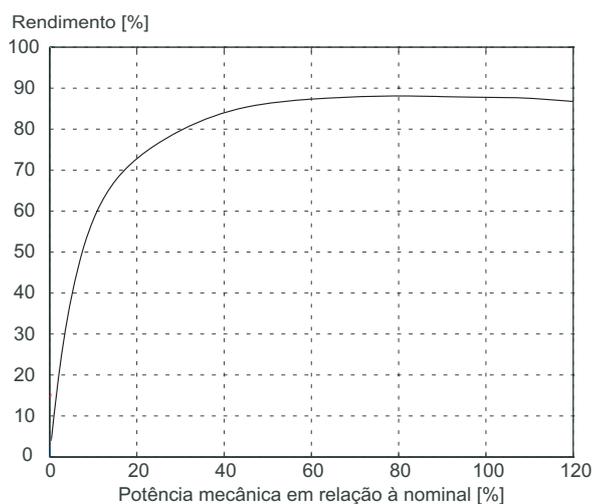
$$\eta = \frac{P_M}{P_E} \quad (1.1)$$

em que:

- $\eta$  - rendimento;

- $P_M$  - potência mecânica de saída no eixo da máquina;
- $P_E$  - potência elétrica de entrada nos terminais da máquina.

Embora o MIT seja uma máquina intrinsecamente eficiente como mostrado na Fig.1.7[1], este se constitui como um grande potencial de conservação de energia, quer seja devido ao grande número de motores instalados, Fig.1.3[1], quer seja devido à aplicação ineficiente dos mesmos.



**Figura 1.7:** Curva de rendimento de um motor de indução trifásico.

Observando a Fig. 1.7, percebe-se que um motor acionando uma carga muito inferior à sua capacidade nominal, motor sobredimensionado, resulta em baixo rendimento, o que contribui para o desperdício de energia.

Com a crescente preocupação com o fornecimento e o custo da energia, vem uma preocupação correspondente com a eficiência do seu uso.

Para se obter um melhor rendimento de um dado motor, pode-se seguir por duas vertentes:

- A busca por uma melhor eficiência durante a fase de projeto e/ou aquisição do motor;
- A busca por técnicas de controle que visam a melhor eficiência de um dado motor;

### 1.3.1 Fase de Projeto

Para uma melhor eficiência do MIT é necessário tanto um projeto cuidadoso do motor elétrico como uma análise adequada da aplicação para a qual se destina.

O projeto do motor, com ênfase no estudo de suas perdas, é importante pelas seguintes razões [1]:

- As perdas determinam o rendimento do motor e influenciam o seu custo de funcionamento;
- As perdas determinam o aquecimento do motor e, conseqüentemente, a potência de saída nominal que pode ser obtida sem deterioração indevida do isolamento;
- As componentes de quedas de tensão e corrente associadas às perdas devem ser levadas em consideração apropriadamente em um modelo do motor.

Por outro lado, o motor deve adaptar-se de forma adequada à finalidade a que se destina, tanto em termos de tamanho como de desempenho. Este critério nem sempre é atendido devido a limitações de ordem prática. A principal delas é que as máquinas estão geralmente disponíveis apenas em certos tamanhos padronizados, limitando assim a capacidade de se fazer um ajuste fino com uma dada aplicação em particular. Outro fato diz respeito à dificuldade de se caracterizar as cargas de operação e à necessidade, por parte dos projetistas, de garantir o atendimento da carga.

### 1.3.2 Técnicas de Controle

Como se sabe, para uma dada condição de velocidade e torque, as perdas em uma máquina de indução podem ser minimizadas ajustando apropriadamente o nível de fluxo do entreferro [4] [5]. Isto se deve ao fato que as perdas no ferro do núcleo em uma máquina são uma função direta do fluxo. Em decorrência disto, uma variação no fluxo muda a corrente exigida para atender a um certo conjugado de carga e, conseqüentemente, o equilíbrio entre as perdas de estator e rotor.

O desafio para os engenheiros, porém, é poder prever o valor do fluxo apropriado em quaisquer pontos operacionais de conjugado e velocidade que minimize as perdas na máquina, conseqüentemente, maximizando a sua eficiência.

Muitos pesquisadores têm explorado este princípio e vários métodos têm sido propostos com o intuito de obter um controle favorável do fluxo de entreferro, especialmente para máquinas que operam em cargas leves. Estes métodos podem ser agrupados em três classes distintas.

A primeira classe, chamada "controlador modelo de perdas", baseia-se na medição da velocidade e correntes de estator da máquina, que são as variáveis de um modelo com perdas, para estimação do melhor fluxo de entreferro [6],[7]. O problema principal desta abordagem diz respeito a obtenção dos valores exatos dos parâmetros do modelo com perdas da máquina, freqüentemente desconhecidos para os usuários e que podem variar devido a mudanças nas condições operacionais, o que o torna não praticável.

Outra classe, denominada "controlador por procura"[8], [4], [9], mede a potência de entrada da máquina em intervalos de tempos regulares e ajusta o nível de fluxo para o qual resulte o mínimo valor de potência para uma dada condição operacional. Esta classe, em particular, não demanda um conhecimento dos parâmetros da máquina e o procedimento de procura é de fácil implementação. Não obstante, a precisão das medidas pode ser pobre devido à elevada sensibilidade a ruídos e perturbações. Além disso, a técnica pode ser lenta em localizar o ponto favorável. Também, em sistemas reais, o método pode não encontrar o ponto ideal e causar oscilações no fluxo de entreferro resultando em perturbações indesejáveis no conjugado eletromagnético.

A terceira classe, chamada "olhar a tabela", [10] [11], também fornece o nível de fluxo favorável para diferentes pontos de operação. Esta técnica consiste na construção de uma tabela que estabelece um valor de fluxo para uma dada condição operacional, supondo que este seja constante. Tal suposição pode sempre ser aceitável desde que o valor de fluxo favorável não varie devido à saturação magnética e a temperatura. Tal tabela, porém, exige muita memória e um elevado tempo computacional.

Nas últimas décadas, com o avanço das pesquisas com inteligência artificial, principalmente na área de Redes Neurais Artificiais; Lógica Fuzzy; Sistemas Neuro-Fuzzy, forneceram ferramentas atrativas e de boa aplicabilidade em problemas que envolvem relações não-lineares complexas, como no caso das equações do modelo das máquinas elétricas incluindo os efeitos da saturação.

No que se refere a Redes Neurais Artificiais (RNA), diversos estudos têm sido realizados, utilizando-se redes neurais artificiais como parte constituinte de sistemas de controle, atuando na predição de parâmetros e grandezas elétricas ou magnéticas [12] [13].

## **1.4 Objetivos**

Dentre os principais objetivos desse trabalho, pode-se enumerar:

1. A melhoria da eficiência do MIT ao longo de sua faixa de operação, principalmente acionando leves cargas;
2. A modelagem da máquina de indução e do estimador de fluxo considerando o efeito da saturação magnética do ferro;
3. A aplicação de redes neurais artificiais (RNA) na seleção do fluxo de rotor de referência do controle vetorial do MIT, visando uma melhor eficiência do sistema a ser controlado.

## **1.5 Organização do Texto**

Este trabalho está dividido em seis capítulos, onde o primeiro capítulo consta de uma introdução sobre motores elétricos e suas principais perdas, técnicas de conservação de energia e os objetivos pretendidos nesta dissertação.

No segundo capítulo é realizada a modelagem da máquina de indução e do estimador de fluxo de rotor, considerando o efeito da saturação magnética do ferro. É descrito o método de controle e simulações da modelagem adotada são apresentadas.

No terceiro capítulo é apresentada uma breve descrição das redes neurais artificiais, abordando seus conceitos principais, arquiteturas e algoritmos de aprendizagem. Nesse capítulo também é descrita a técnica a ser implementada na busca de uma melhor eficiência do sistema.

No quarto capítulo são descritas as etapas de obtenção da base de dados, processamento, treinamento e escolha da melhor arquitetura da rede e os resultados do desempenho de cada rede atuando isoladamente.

Já no capítulo cinco, são mostrados os resultados de simulação e experimentais da máquina, utilizando o conjunto de redes para diferentes condições de carga e velocidade.

O capítulo seis apresenta as principais conclusões e contribuições, além de sugerir temas para continuidade deste trabalho. O texto se encerra com a apresentação das referências bibliográficas e apêndice.

# 2 | MODELAGEM DO SISTEMA

Este capítulo descreve o modelo eletromagnético da máquina de indução, com inclusão da saturação magnética do ferro do núcleo, em um referencial arbitrário, bem como os estimadores de fluxo de rotor utilizados.

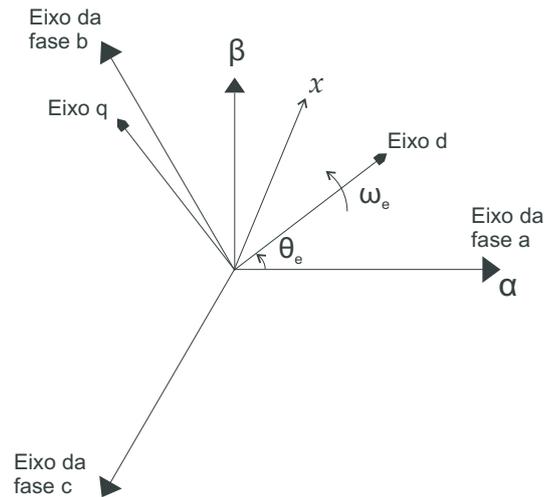
O *estimador 1*, proposto neste trabalho, adota o referencial fixo no rotor. Já o *estimador 2* que utiliza o referencial fixo no vetor fluxo de rotor serve como parâmetro de comparação do estimador proposto.

A técnica de controle vetorial utilizada é o controle orientado segundo o fluxo de rotor. Simulações do controle vetorial do motor de indução com saturação são realizadas e uma análise do desempenho dos estimadores de fluxo é feita.

## 2.1 O Modelo Vetorial

O modelo vetorial baseia-se na representação das variáveis elétricas e magnéticas da máquina de indução trifásica em componentes  $dq$  ortogonais de vetores espaciais. Uma terceira componente (componente de seqüência zero) seria necessária para representar as grandezas trifásicas em um caso geral. Porém, supondo que a máquina possui perfeita simetria elétrica, magnética e de geometria de construção, que é alimentada por uma fonte de tensão equilibrada e que tem o estator conectado em triângulo ou em estrela não aterrada,

as componentes de seqüência zero são nulas e podem ser desconsideradas. A partir da representação vetorial é possível o controle desacoplado ou quase desacoplado entre fluxo e conjugado, resultando assim em precisão, rapidez de resposta e eficiência do acionamento onde o motor está inserido [14]. Neste trabalho, o referencial  $dq$  foi definido como mostrado na Fig. 2.1, considerando a inexistência da componente de seqüência zero.



**Figura 2.1:** Sistema de coordenadas  $dq$  girante a uma velocidade arbitrária.

Na Fig. 2.1,  $x$  é usado para representar qualquer grandeza trifásica elétrica ou magnética da máquina, ou seja, tensão, corrente ou fluxo,  $\theta_e$  é o ângulo entre o *eixo d* e o *eixo magnético da fase a do estator* e  $\omega_e = d\theta_e/dt$  é a velocidade relativa com que o referencial  $dq$  gira em relação ao estator. No caso particular em que o referencial  $dq$  é fixo no estator, com o *eixo d* alinhado com o *eixo magnético da fase a do estator*, denomina-se o referencial de  $\alpha\beta$ .

A conversão  $abc \rightarrow dq$  entre os sistemas de coordenadas é realizada através da seguinte matriz:

$$\begin{bmatrix} x_d \\ x_q \end{bmatrix} = \frac{2}{3} \begin{bmatrix} \cos(\theta_e) & \cos(\theta_e - 120^\circ) & \cos(\theta_e + 120^\circ) \\ \sin(\theta_e) & \sin(\theta_e - 120^\circ) & \sin(\theta_e + 120^\circ) \end{bmatrix} \cdot \begin{bmatrix} x_a \\ x_b \\ x_c \end{bmatrix} \quad (2.1)$$

enquanto a transformação inversa  $dq \rightarrow abc$  é dada por:

$$\begin{bmatrix} x_a \\ x_b \\ x_c \end{bmatrix} = \begin{bmatrix} \cos(\theta_e) & \sin(\theta_e) \\ \cos(\theta_e - 120^\circ) & \sin(\theta_e - 120^\circ) \\ \cos(\theta_e + 120^\circ) & \sin(\theta_e + 120^\circ) \end{bmatrix} \cdot \begin{bmatrix} x_d \\ x_q \end{bmatrix} \quad (2.2)$$

Quando a velocidade relativa entre os eixos é nula ( $\omega_e = 0$ ), tem-se um referencial fixo no estator. Quando a velocidade do referencial for igual à síncrona ( $\omega_e = \omega_s$ ), tem-se o referencial fixo no campo girante (referencial síncrono) e quando a velocidade do sistema de coordenadas é igual à do rotor ( $\omega_e = \omega_r$ ), tem-se o referencial fixo no rotor.

As equações usualmente empregadas do modelo da máquina de indução, desconsiderando-se a saturação, em um referencial girante à velocidade arbitrária  $\omega_e$ , são escritas na forma:

$$\vec{v}_s = R_s \vec{i}_s + \frac{d\vec{\lambda}_s}{dt} + j\omega_e \vec{\lambda}_s \quad (2.3)$$

$$\vec{v}_r = \vec{0} = R_r \vec{i}_r + \frac{d\vec{\lambda}_r}{dt} + j(\omega_e - \omega_r) \vec{\lambda}_r \quad (2.4)$$

$$\vec{i}_m = \vec{i}_s + \vec{i}_r \quad (2.5)$$

$$\vec{\lambda}_s = L_s \vec{i}_s + L_m \vec{i}_r \quad (2.6)$$

$$\vec{\lambda}_r = L_r \vec{i}_r + L_m \vec{i}_s \quad (2.7)$$

$$\vec{\lambda}_m = L_m \vec{i}_m \quad (2.8)$$

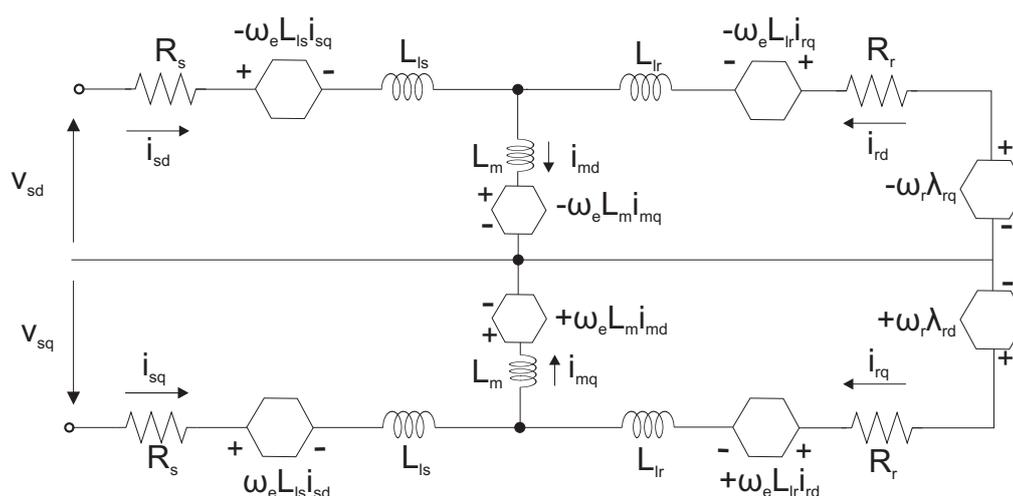
$$\frac{2}{P} J_m \frac{d\omega_r}{dt} = T_e - T_c \quad (2.9)$$

$$T_e = \frac{3P}{2} \Im \{ \vec{\lambda}_r \vec{i}_r^* \} \quad (2.10)$$

em que:

- $\vec{v}_s$  - vetor espacial tensão de estator
- $\vec{v}_r$  - vetor espacial tensão de rotor
- $\vec{i}_s$  - vetor espacial corrente de estator
- $\vec{i}_r$  - vetor espacial corrente de rotor
- $\vec{i}_m$  - vetor espacial corrente de magnetização
- $\vec{\lambda}_s$  - vetor espacial fluxo de estator
- $\vec{\lambda}_r$  - vetor espacial fluxo de rotor
- $\vec{\lambda}_m$  - vetor espacial fluxo de magnetização
- $R_s$  - resistência de estator
- $R_r$  - resistência de rotor
- $L_s$  - indutância própria de estator
- $L_r$  - indutância própria de rotor
- $L_m$  - indutância de magnetização
- $P$  - número de pólos
- $T_e$  - conjugado eletromagnético
- $T_c$  - conjugado de carga
- $J_m$  - momento de inércia
- $\Im$  - parte imaginária

Na Fig. 2.2, é ilustrado o circuito equivalente em coordenadas  $dq$  da máquina de indução descrito pelas equações acima mencionadas.

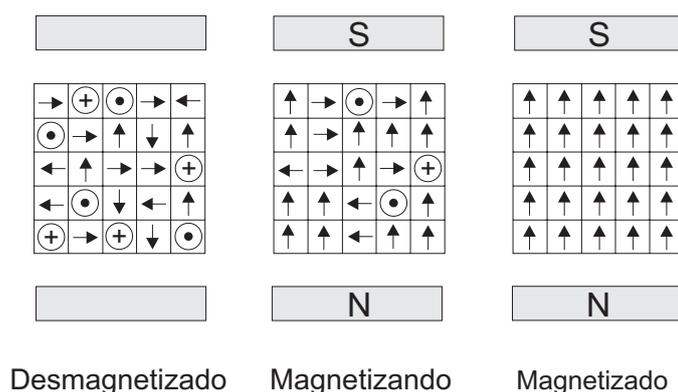


**Figura 2.2:** Circuito equivalente em coordenadas dq da máquina de indução em referencial arbitrário.

## 2.2 A Saturação Magnética

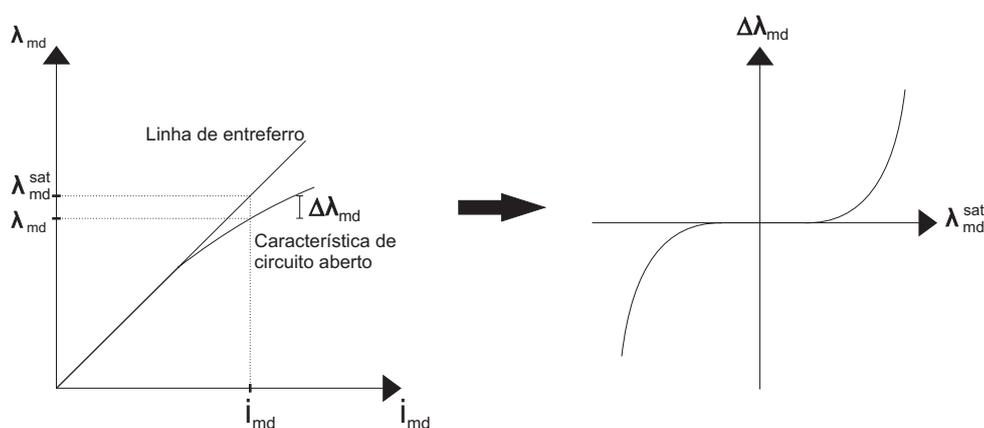
A habilidade de certos materiais de adquirir um alto e permanente momento magnético, é de grande importância para a engenharia elétrica. Dentre os materiais magnéticos, notadamente o ferro, o níquel, o cobalto e algumas de suas ligas e compostos são os mais comuns. Com seu uso, é possível obter densidades de fluxo magnético com níveis relativamente baixos de força magnetizante além de poderem ser usados para delimitar e direcionar os campos magnéticos, dentro de caminhos bem definidos.

Nas máquinas elétricas, os materiais magnéticos são empregados para dar forma aos campos de modo que o conjugado desejado seja produzido e as características nos terminais da máquina sejam obtidas [15]. Quando um material magnético é submetido a uma força magnetizante externa, os domínios, isto é, as regiões nas quais os momentos magnéticos de todos os átomos estão em paralelo formando um momento magnético resultante, tendem a se alinhar na direção do campo aplicado, Fig. 2.3. Como resultado, ocorre um valor de densidade de fluxo muito mais elevado do que aquele que existiria devido apenas à força magnetizante inicialmente aplicada. À medida que a força magnetizante aumenta, esse comportamento continua até que todos os momentos magnéticos estejam alinhados com o campo aplicado. A partir de então, os momentos não podem mais contribuir para o aumento da densidade do fluxo, e diz-se que o material magnético está *saturado* [15].



**Figura 2.3:** Alinhamento dos domínios magnéticos.

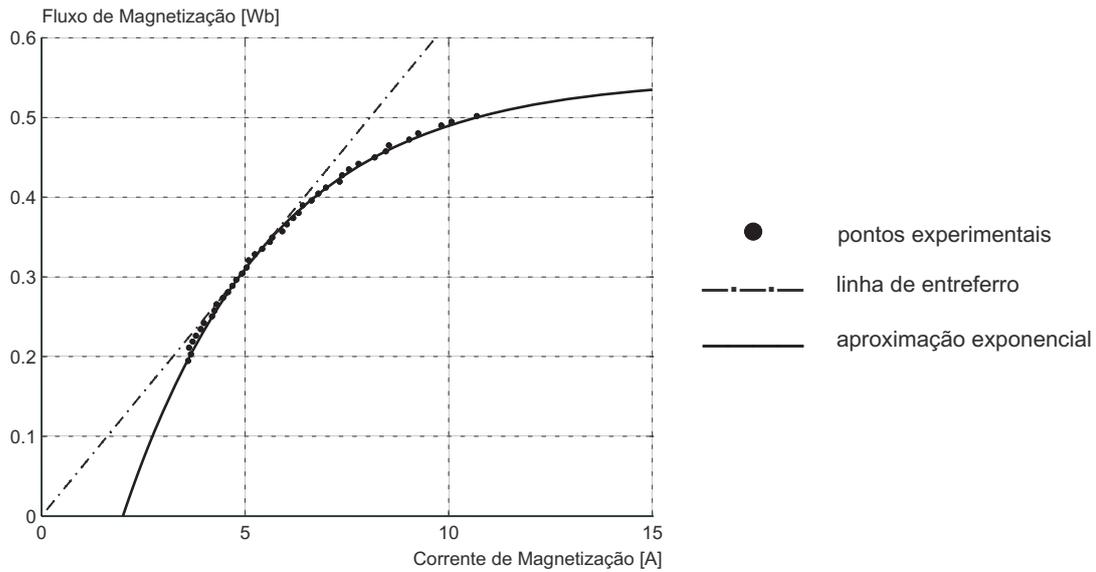
Na Fig. 2.4 é mostrada a curva característica de circuito aberto típica de um MIT. Nela, os efeitos da saturação magnética podem ser vistos claramente. Quando a corrente de magnetização é aumentada desde zero, a característica de circuito aberto é aproximadamente linear. Essa parte da curva (e sua extensão para valores elevados de correntes de campo) é conhecida como *linha de entreferro*. Com correntes de campo crescentes, a curva característica inclina-se para baixo à medida que a saturação do material magnético vai aumentando [15].



**Figura 2.4:** Curva característica de circuito aberto típica e linha de entreferro.

O efeito da saturação magnética no motor de indução, embora seja muito bem compreendido, representa uma propriedade indesejável do ferro do núcleo. Modelos da máquina de indução com inclusão da saturação magnética do ferro podem ser encontrados em [16], [17], [18] onde demonstra-se que a saturação magnética pode ser modelada por uma indutância mútua variável não-linear.

Neste trabalho, o efeito da saturação é considerado, nos algoritmos de simulação, a partir da constante atualização do valor da indutância de magnetização. Para tanto, obteve-se a curva característica em vazio da máquina a ser utilizada ao longo deste texto. Na Fig. 2.5 são mostrados os pontos obtidos experimentalmente, a aproximação exponencial destes pontos e a linha de entreferro adotada.



**Figura 2.5:** Curva característica de circuito aberto experimental.

A equação (2.11), relaciona a corrente de magnetização ( $i_m$ ) com o valor do fluxo de magnetização ( $\lambda_m$ ) correspondente, para a região não linear da curva de magnetização.

$$\lambda_m = 0,55 \left[ 1 - 1,7376 \exp\left(-\frac{i_m}{3,62}\right) \right] \quad (2.11)$$

ou expressando-se  $i_m(\lambda_m)$ :

$$i_m = 2 - 3,62 \ln\left(1 - \frac{\lambda_m}{0,55}\right) \quad (2.12)$$

A saturação do ferro afeta ambas componentes de fluxo, dispersão e mútuo, sendo que o fluxo mútuo é o mais afetado. Os caminhos do fluxo de dispersão dos enrolamentos da máquina são muito complicados se comparados aos caminhos do fluxo mútuo. Deste modo, contabilizar os efeitos da saturação magnética do ferro sobre o fluxo disperso não é uma tarefa muito fácil. Para uma máquina com um entreferro uniforme, pode-se assumir que

os efeitos da saturação magnética sobre as componentes  $d$  e  $q$  são os mesmos, de forma que a característica de saturação, mostrada na Fig. 2.4, pode ser usada para ambas as componentes, embora a localização da saturação possa realmente afetar as componentes  $dq$  não uniformemente [19].

Assim sendo, partir das equações (2.8) e (2.12) a indutância de magnetização variável fica assim estabelecida:

$$L_m = \begin{cases} 0,062, & \text{se } \lambda_m \leq 0,31 \\ \frac{\lambda_m}{2-3,62 \ln(1-\frac{\lambda_m}{0,55})}, & \text{caso contrário} \end{cases} \quad (2.13)$$

Todos os algoritmos de simulação do MIT foram realizados em *Matlab*<sup>®</sup> [20]. Para isso, as equações do modelo eletromagnético, (2.3) a (2.7), foram reescritas na forma de equação de estado e discretizadas através da função *c2d* do Matlab.

Das equações (2.6) e (2.7) pode-se expressar as correntes de estator e de rotor como função dos fluxos de estator e rotor:

$$\vec{i}_s = \frac{1}{\sigma L_s} \vec{\lambda}_s - \frac{L_m}{\sigma L_s L_r} \vec{\lambda}_r \quad (2.14)$$

$$\vec{i}_r = \frac{1}{\sigma L_r} \vec{\lambda}_r - \frac{L_m}{\sigma L_s L_r} \vec{\lambda}_s \quad (2.15)$$

em que " $\sigma$ " é o coeficiente de dispersão da máquina dado por:

$$\sigma = 1 - \frac{L_m^2}{L_s L_r} \quad (2.16)$$

Substituindo (2.14) em (2.3) e (2.15) em (2.4) tem-se:

$$\dot{\vec{\lambda}}_s = - \left( \frac{1}{\sigma \tau_s} + j\omega_e \right) \vec{\lambda}_s + \frac{L_m}{\sigma \tau_s L_r} \vec{\lambda}_r + \vec{v}_s \quad (2.17)$$

$$\dot{\vec{\lambda}}_r = - \left[ \frac{1}{\sigma \tau_r} + j(\omega_e - \omega_r) \right] \vec{\lambda}_r + \frac{L_m}{\sigma \tau_r L_s} \vec{\lambda}_s \quad (2.18)$$

em que " $\tau_s$ " e " $\tau_r$ " são as constantes de tempo de estator e rotor, respectivamente:

$$\tau_s = \frac{L_s}{R_s} \quad (2.19)$$

$$\tau_r = \frac{L_r}{R_r} \quad (2.20)$$

Expressando-se (2.17) e (2.18), na forma matricial, em termos das componentes de eixos direto e em quadratura, chega-se à seguinte equação de estado:

$$\begin{bmatrix} \dot{\lambda}_{sd} \\ \dot{\lambda}_{sq} \\ \dot{\lambda}_{rd} \\ \dot{\lambda}_{rq} \end{bmatrix} = \begin{bmatrix} -\frac{1}{\sigma\tau_s} & \omega_e & \frac{L_m}{L_r} \frac{1}{\sigma\tau_s} & 0 \\ -\omega_e & -\frac{1}{\sigma\tau_s} & 0 & \frac{L_m}{L_r} \frac{1}{\sigma\tau_s} \\ \frac{L_m}{L_s} \frac{1}{\sigma\tau_r} & 0 & -\frac{1}{\sigma\tau_r} & (\omega_e - \omega_r) \\ 0 & \frac{L_m}{L_s} \frac{1}{\sigma\tau_r} & -(\omega_e - \omega_r) & -\frac{1}{\sigma\tau_r} \end{bmatrix} \begin{bmatrix} \lambda_{sd} \\ \lambda_{sq} \\ \lambda_{rd} \\ \lambda_{rq} \end{bmatrix} + \begin{bmatrix} 1 & 0 \\ 0 & 1 \\ 0 & 0 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} v_{sd} \\ v_{sq} \end{bmatrix} \quad (2.21)$$

ou, em referencial fixo no estator ( $\omega_e = 0$ ), tem-se

$$\begin{bmatrix} \dot{\lambda}_{s\alpha} \\ \dot{\lambda}_{s\beta} \\ \dot{\lambda}_{r\alpha} \\ \dot{\lambda}_{r\beta} \end{bmatrix} = \begin{bmatrix} -\frac{1}{\sigma\tau_s} & 0 & \frac{L_m}{L_r} \frac{1}{\sigma\tau_s} & 0 \\ 0 & -\frac{1}{\sigma\tau_s} & 0 & \frac{L_m}{L_r} \frac{1}{\sigma\tau_s} \\ \frac{L_m}{L_s} \frac{1}{\sigma\tau_r} & 0 & -\frac{1}{\sigma\tau_r} & -\omega_r \\ 0 & \frac{L_m}{L_s} \frac{1}{\sigma\tau_r} & \omega_r & -\frac{1}{\sigma\tau_r} \end{bmatrix} \begin{bmatrix} \lambda_{s\alpha} \\ \lambda_{s\beta} \\ \lambda_{r\alpha} \\ \lambda_{r\beta} \end{bmatrix} + \begin{bmatrix} 1 & 0 \\ 0 & 1 \\ 0 & 0 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} v_{s\alpha} \\ v_{s\beta} \end{bmatrix} \quad (2.22)$$

### 2.3 Estimador de Fluxo de Rotor

Dentre as diferentes formas de obtenção do fluxo magnético do MIT, pode-se citar a medição direta por sensores de efeito Hall e a estimação por meio de estimadores ou observadores de estado. Cada uma destas formas apresenta vantagens e desvantagens com relação à implementação, robustez, rapidez e exatidão [21]. Neste trabalho, optou-se pela utilização de estimadores, principalmente por estes demandarem um esforço computacional relativamente baixo frente aos observadores de estado e por necessitarem apenas da medição

de grandezas elétricas (correntes e tensões) e da velocidade, o que reduz o seu custo frente à medição direta através de sensores.

Dois estimadores considerando o efeito da saturação magnética e o modelo em corrente são comparados. O *estimador 1* proposto neste trabalho é empregado utilizando-se o referencial fixo no rotor, enquanto que no *estimador 2* é adotado o referencial fixo no vetor fluxo de rotor.

### 2.3.1 Estimador 1

A partir das medições de corrente e velocidade, o vetor fluxo de rotor pode ser estimado através da equação (2.4). Para maior comodidade esta equação é repetida a seguir:

$$\vec{0} = R_r \vec{i}_r + \dot{\vec{\lambda}}_r + j(\omega_e - \omega_r) \vec{\lambda}_r \quad (2.23)$$

Isolando o termo  $\dot{\vec{i}}_r$  de (2.7) e substituindo-o em (2.23) tem-se:

$$\vec{0} = R_r \left[ \frac{1}{L_r} (\vec{\lambda}_r - L_m \vec{i}_s) \right] + \dot{\vec{\lambda}}_r + j(\omega_e - \omega_r) \vec{\lambda}_r \quad (2.24)$$

A estimativa da derivada do fluxo de rotor em um referencial arbitrário é obtida da equação (2.24), escrita na forma:

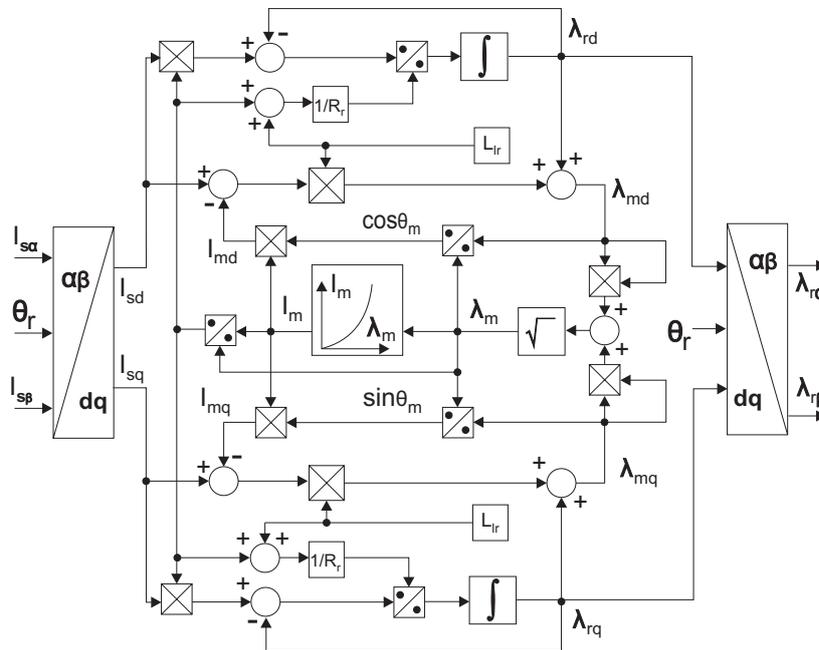
$$\dot{\vec{\lambda}}_r = \left[ -\frac{1}{\tau_r} - j(\omega_e - \omega_r) \right] \vec{\lambda}_r + \frac{L_m}{\tau_r} \dot{\vec{i}}_s \quad (2.25)$$

ou, em termos das componentes de eixos direto e em quadratura:

$$\begin{bmatrix} \dot{\lambda}_{rd} \\ \dot{\lambda}_{rq} \end{bmatrix} = \begin{bmatrix} -\frac{1}{\tau_r} & (\omega_e - \omega_r) \\ -(\omega_e - \omega_r) & -\frac{1}{\tau_r} \end{bmatrix} \cdot \begin{bmatrix} \lambda_{rd} \\ \lambda_{rq} \end{bmatrix} + \frac{L_m}{\tau_r} \begin{bmatrix} \dot{i}_{sd} \\ \dot{i}_{sq} \end{bmatrix} \quad (2.26)$$

O estimador de fluxo descrito acima é denominado *modelo em corrente*. Este modelo é estável para todas as faixas de velocidade, embora tenha resposta oscilatória em altas velocidades.

O diagrama de blocos do *estimador 1*, em referencial fixo no rotor ( $\omega_e = \omega_r$ ) e considerando o efeito da saturação magnética do ferro (Fig. 2.5) é ilustrado na Fig. 2.6.



**Figura 2.6:** Diagrama de blocos do estimador 1 com inclusão da saturação magnética.

### 2.3.2 Estimador 2

Este estimador é baseado na modelagem do fluxo de rotor com inclusão da saturação magnética descrita em [22]. Em referencial arbitrário as componentes do vetor fluxo de magnetização  $\vec{\lambda}_m$  podem ser expressas pelas equações (2.27) e (2.28) quando as equações de tensão do rotor do MIT são descritas como em (2.29) e (2.30):

$$\lambda_{md} = L_m(i_{sd} + i_{rd}) = \lambda_{rd} - L_{lr}i_{rd} = \lambda_{rd} + L_{lr}(i_{sd} - i_{md}) \quad (2.27)$$

$$\lambda_{mq} = L_m(i_{sq} + i_{rq}) = \lambda_{rq} - L_{lr}i_{rq} = \lambda_{rq} + L_{lr}(i_{sq} - i_{mq}) \quad (2.28)$$

$$0 = R_r i_{rd} + \frac{d\lambda_{rd}}{dt} - (\omega_e - \omega_r)\lambda_{rq} \quad (2.29)$$

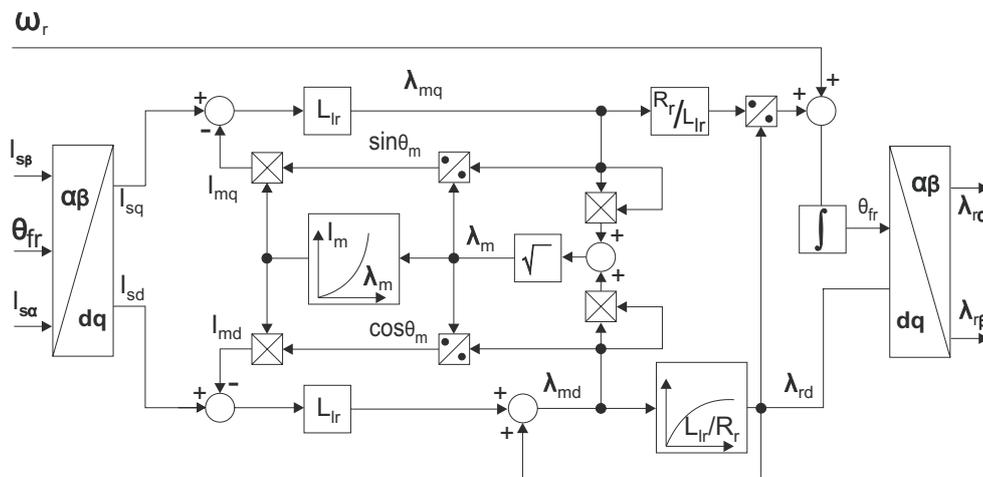
$$0 = R_r i_{rq} + \frac{d\lambda_{rq}}{dt} + (\omega_e - \omega_r)\lambda_{rd} \quad (2.30)$$

Introduzindo o referencial orientado segundo o vetor fluxo de rotor tem-se  $\lambda_{rq} = 0$ ,  $\frac{d\lambda_{rq}}{dt} = 0$ ,  $\omega_e = \omega_{fr}$ , em que  $\omega_{fr}$  é a velocidade do vetor fluxo de rotor. A partir dessas modificações, as equações (2.31) e (2.32) são obtidas das equações (2.27), (2.29) e (2.28), (2.30), respectivamente:

$$\frac{L_{lr}}{R_r} \frac{d\lambda_{rd}}{dt} + \lambda_{rd} = \lambda_{md} \quad (2.31)$$

$$\omega_{fr} - \omega_r = -R_r \frac{i_{rq}}{\lambda_{rd}} = \frac{R_r}{L_{lr}} \frac{\lambda_{mq}}{\lambda_{rd}} \quad (2.32)$$

Na Fig. 2.7 é mostrado o diagrama de blocos do estimador de fluxo baseado nas equações (2.27), (2.28), (2.31) e (2.32) e na curva de magnetização da Fig. 2.5.



**Figura 2.7:** Diagrama de blocos do estimador 2 com inclusão da saturação magnética.

A princípio, os dois estimadores mostrados são equivalentes, tendo em vista que são baseados nas mesmas equações. No entanto, a implementação de um estimador usando referenciais distintos pode influenciar nos erros de estimação [23] [24] e, por esta razão, as respostas dos dois estimadores serão comparadas adiante. O estimador 1 assemelha-se ao estimador pelo modelo em corrente usualmente empregado quando do acionamento sem considerar a saturação, enquanto o estimador 2 contém um calculador de escorregamento

similar ao usado no método indireto de controle em referencial orientado pelo fluxo de rotor. A precisão deste estimador depende do conhecimento dos parâmetros do MIT que aparecem no modelo. Como já foi incluído as variações de  $L_m$  através da curva de magnetização não-linear (Fig. 2.5), a única parte sensível é  $R_r$ . Embora as correções do valor de  $R_r$  durante a operação serem possíveis, estas não são implementadas neste trabalho.

## 2.4 Estratégia de Controle Vetorial do Motor de Indução

As técnicas de controle, assim como o modelo vetorial, baseiam-se na representação das grandezas elétricas em componentes ortogonais: as componentes de eixo direto são normalmente responsáveis pela produção de fluxo, enquanto que as componentes de eixo em quadratura são responsáveis pela produção de conjugado. Desta forma essas técnicas buscam o controle desacoplado ou quase-desacoplado entre fluxo e conjugado [14].

A orientação pelo campo é uma técnica de controle vetorial na qual os eixos ortogonais sobre os quais se realiza a decomposição das variáveis são posicionados de modo que o *eixo d* é alinhado na direção de um dos vetores enlace de fluxo, dando origem assim às suas diversas denominações:

- Orientação pelo Fluxo de Rotor;
- Orientação pelo Fluxo de Estator;
- Orientação pelo Fluxo Mútuo.

Essas técnicas de orientação pelo campo, podem ser implementadas de duas maneiras: direta ou indireta. Nos métodos diretos, o controle é realizado através da realimentação do vetor fluxo, sendo este obtido através de medição direta ou através de algoritmos de estimação. Os métodos diretos que se baseiam na medição direta do fluxo possuem como principal vantagem a sua independência em relação aos parâmetros da máquina, embora sejam de implementação mais difícil, tenham custo mais elevado e reduzida robustez, tendo em vista a necessidade de instalação de sensores [14].

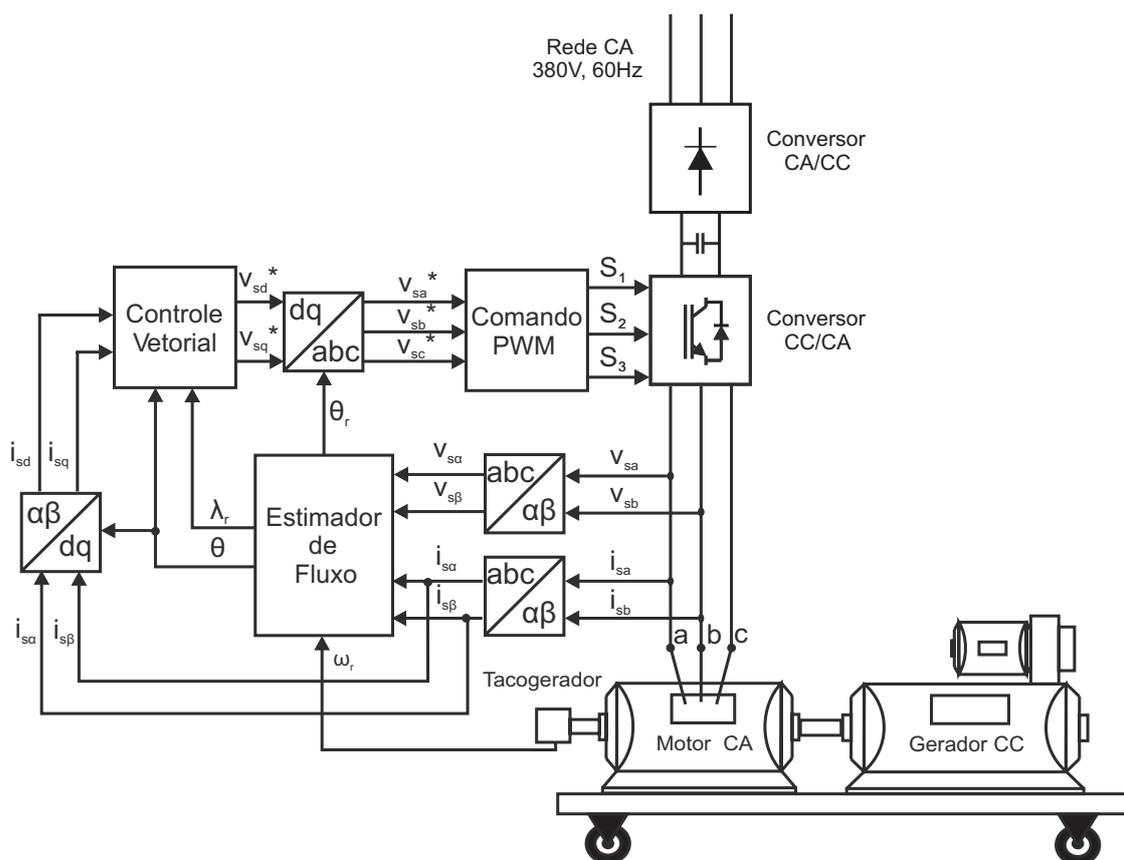
Nos métodos indiretos, o controle é realizado em malha aberta através da monitoração de variáveis (posição angular do rotor e correntes de estator). Os métodos indiretos, embora sejam de simples implementação, dependem de parâmetros da máquina que podem variar fortemente com a temperatura, saturação magnética, etc [14]. Nos métodos diretos baseados em observadores de fluxo (em malha fechada), o vetor fluxo é também obtido com base no modelo da máquina e na medição de grandezas elétricas e, às vezes, na posição ou velocidade rotórica. Sendo assim, esses métodos dependem do conhecimento dos parâmetros do modelo. No entanto, podem ser projetados observadores robustos, em que os parâmetros, ao variar dentro de certos limites, não produzirão erros de estimação superiores a certos valores aceitáveis [25] [26] [27] [28].

As técnicas de controle por orientação pelo campo para alimentação em corrente foram generalizadas através do denominado *Controlador Universal Orientado pelo Campo* [29]. Posteriormente, essas técnicas também foram generalizadas para alimentação em tensão [14].

Na próxima subseção é descrito o método de controle implementado neste trabalho: controle direto por orientação segundo o fluxo de rotor. A implementação utiliza os estimadores de fluxos descritos na seção anterior para obtenção do vetor fluxo de rotor.

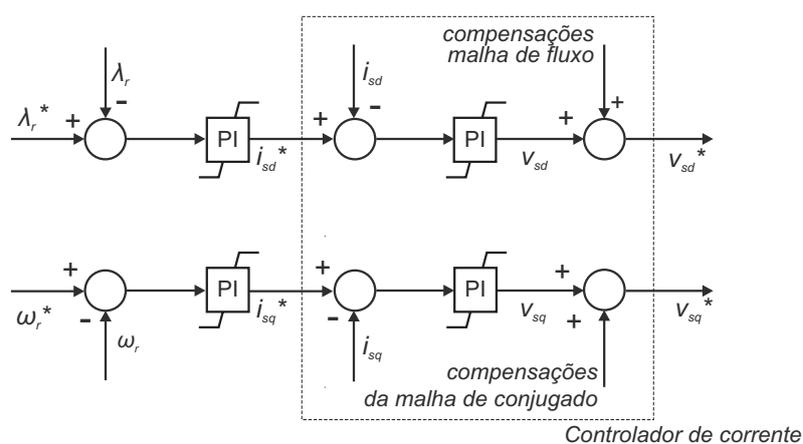
#### 2.4.1 Controle Orientado Segundo o Fluxo de Rotor

O sistema de acionamento utilizado neste trabalho é ilustrado na forma de diagrama de blocos na Fig. 2.8. A descrição mais detalhada deste sistema será apresentada no Capítulo 5.



**Figura 2.8:** Diagrama esquemático do sistema de acionamento implementado.

O bloco referente ao controle vetorial da Fig. 2.8, controle orientado pelo fluxo de rotor, foi implementado como mostrado na Fig. 2.9.



**Figura 2.9:** Controle vetorial orientado segundo o fluxo de rotor.

De acordo com a Fig. 2.9, a malha de controle de fluxo começa com o fluxo de rotor de referência,  $\lambda_r^*$ , sendo comparado com o valor estimado. O sinal de erro passa então por

um controlador do tipo PI, que fornece como saída o valor de referência da corrente de eixo direto  $i_{sd}^*$ .

Na malha de controle de velocidade, a velocidade angular de referência,  $\omega_r^*$ , é comparada com o valor medido, o sinal gerado passa por controlador PI que fornece, de forma semelhante à malha de fluxo, o valor de referência da corrente de eixo em quadratura  $i_{sq}^*$ .

As referências de corrente  $i_{sd}^*$  e  $i_{sq}^*$  obtidas passam então por controladores de corrente, que fornecem nas suas saídas os valores de  $v_{sd}^*$  e  $v_{sq}^*$  a serem utilizadas pelo algoritmo de PWM. As equações dinâmicas correlacionando correntes e tensões de estator são descritas a seguir.

Das equações (2.6) e (2.7), pode-se expressar o fluxo de estator como uma função do fluxo de rotor e da corrente de estator:

$$\vec{\lambda}_s = \sigma L_s \vec{i}_s + \frac{L_m}{L_r} \vec{\lambda}_r \quad (2.33)$$

Substituindo-se (2.33) em (2.3) tem-se:

$$\vec{v}_s = \left( R_s + j\omega_e \sigma L_s \right) \vec{i}_s + \sigma L_s \dot{\vec{i}}_s + \frac{L_m}{L_r} \dot{\vec{\lambda}}_r + j\omega_e \frac{L_m}{L_r} \vec{\lambda}_r \quad (2.34)$$

Para eliminar o termo em derivada do fluxo de rotor na equação (2.34) primeiramente substitui-se (2.7) em (2.4) eliminando-se o termo  $\dot{\vec{i}}_r$ . Desta forma, após algumas manipulações algébricas obtém-se:

$$\dot{\vec{\lambda}}_r = -\frac{1}{\tau_r} \left( \vec{\lambda}_r - L_m \vec{i}_s \right) - j(\omega_e - \omega_r) \vec{\lambda}_r \quad (2.35)$$

Substituindo-se (2.35) em (2.34) elimina-se  $\dot{\vec{\lambda}}_r$ :

$$\vec{v}_s = \left( R_s + \frac{1}{\tau_r} \frac{L_m^2}{L_r} + j\omega_e \sigma L_s \right) \vec{i}_s + \sigma L_s \dot{\vec{i}}_s + \left( j\omega_r - \frac{1}{\tau_r} \right) \frac{L_m}{L_r} \vec{\lambda}_r \quad (2.36)$$

Expressando (2.36) em termos das componentes ortogonais, obtém-se:

$$v_{sd} = \left( R_s + \frac{1}{\tau_r} \frac{L_m^2}{L_r} \right) i_{sd} - \omega_e \sigma L_s i_{sq} + \sigma L_s \dot{i}_{sd} - \frac{L_m}{L_r} \left( \frac{1}{\tau_r} \lambda_{rd} + \lambda_{rq} \right) \quad (2.37)$$

$$v_{sq} = \left( R_s + \frac{1}{\tau_r} \frac{L_m^2}{L_r} \right) i_{sq} + \omega_e \sigma L_s i_{sd} + \sigma L_s \dot{i}_{sq} + \frac{L_m}{L_r} \left( \omega_r \lambda_{rd} - \frac{1}{\tau_r} \lambda_{rq} \right) \quad (2.38)$$

Assim, as equações de estado das correntes de eixo direto e de eixo em quadratura, em referencial orientado pelo fluxo de rotor ( $\lambda_{rq} = 0$ ) tornam-se:

$$\dot{i}_{sd} = -\frac{R_s}{\sigma L_s} \left( 1 + \frac{R_r}{R_s} \frac{L_m^2}{L_r^2} \right) i_{sd} + \frac{1}{\sigma L_s} \left( v_{sd} + \omega_e \sigma L_s i_{sq} + \frac{1}{\tau_r} \frac{L_m}{L_r} \lambda_{rd} \right) \quad (2.39)$$

$$\dot{i}_{sq} = -\frac{R_s}{\sigma L_s} \left( 1 + \frac{R_r}{R_s} \frac{L_m^2}{L_r^2} \right) i_{sq} + \frac{1}{\sigma L_s} \left( v_{sq} - \omega_e \sigma L_s i_{sd} - \omega_r \frac{L_m}{L_r} \lambda_{rd} \right) \quad (2.40)$$

As grandezas  $i_{sd}$ ,  $i_{sq}$ ,  $\omega_r$  e  $\lambda_{rd}$  entre parênteses no segundo termo do segundo membro das equações acima podem ser tratados como perturbações conhecidas, ou seja, essas perturbações podem ser compensadas. Assim qualquer uma das duas equações acima pode ser escrita como segue:

$$\dot{x} = ax + bu + c = ax + u' \quad (2.41)$$

em que  $u'$  é a entrada da planta já considerando a compensação das perturbações:

$$u' = bu + c \quad (2.42)$$

ou

$$u = \frac{u' - c}{b} \quad (2.43)$$

Comparando (2.41) e (2.39) obtém-se:

$$\frac{v'_{sd}}{\sigma L_s} = \frac{1}{\sigma L_s} \left( \omega_e \sigma L_s i_{sq} + \frac{1}{\tau_r} \frac{L_m}{L_r} \lambda_{rd} + v_{sd}^* \right) \quad (2.44)$$

Finalmente, isolando o termo  $v_{sd}^*$  o qual é a tensão de referência de eixo direto na saída do controlador de corrente tem-se:

$$v_{sd}^* = v'_{sd} - \omega_e \sigma L_s i_{sq} - \frac{1}{\tau_r} \frac{L_m}{L_r} \lambda_{rd} \quad (2.45)$$

De forma semelhante, utilizando (2.38), (2.41) e (2.40) obtém-se:

$$v_{sq}^* = v'_{sq} + \omega_e \sigma L_s i_{sd} + \omega_r \frac{L_m}{L_r} \lambda_{rd} \quad (2.46)$$

em que  $v_{sq}^*$  é a tensão de referência de eixo em quadratura na saída do controlador de corrente.

Neste trabalho, adotou-se como algoritmo de sintetização das tensões de alimentação do MIT, a técnica de PWM regular trifásico simétrico [30]. Maiores detalhes e a dedução das equações desta técnica podem ser encontrados na referência.

## 2.5 Resultados de Simulação

Nesta seção são apresentados os resultados relativos ao controlador por orientação pelo fluxo de rotor, *estimador 1* e *estimador 2*, obtidos na simulação do modelo da máquina com inclusão do efeito da saturação magnética. As simulações realizadas permitem, a visualização do fluxo, do conjugado e da corrente de magnetização (variáveis não acessíveis na implementação prática). A máquina de indução é submetida a três diferentes casos de transitórios:

- Caso 1: Partida e aplicação de carga;
- Caso 2: Partida e reversão de velocidade;
- Caso 3: Partida e variação do fluxo de referência.

Para simulação da máquina, foi desenvolvido um programa no *Matlab*<sup>®</sup> [20]. Os seguintes parâmetros foram adotados nas simulações:

- Tempo de simulação = 5 s;
- Passo de simulação = 10  $\mu$  s;
- Frequência de amostragem do algoritmo de controle = 4,0 kHz;
- Frequência de chaveamento = 4,0 kHz;
- Tensão do barramento cc = 640 V;
- Tensão de entrada da rede = 311,127 V de pico (fase-neutro);

Os ganhos utilizados nos controladores PI, Tabela 2.1, foram determinados com base nas condições de projeto e posteriormente ajustados em simulação. Saturações foram impostas as variáveis de controle para manter a operação do sistema em condições seguras.

**Tabela 2.1:** *Ganhos de simulação dos controladores PI*

Malha	Kp	Ki
de fluxo	700	8000
de velocidade	200	8000
de corrente	50	8000

Os valores de saturação dos controladores utilizados foram:

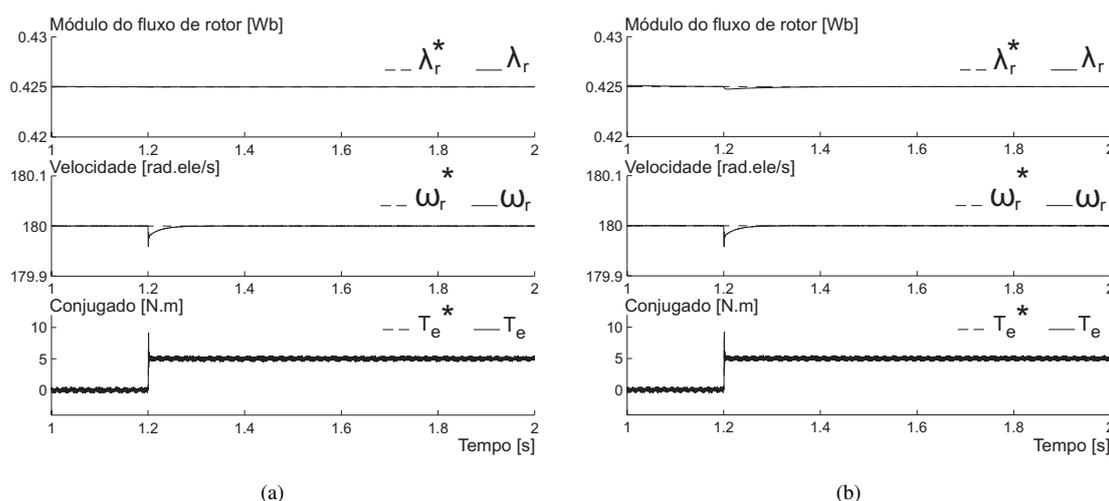
- Corrente máxima de estator : 40 A de pico;
- Corrente máxima de eixo direto : 28 A de pico;
- Tensão do barramento cc = 640 V;
- Tensão de entrada da rede = 311 V de pico (fase-terra);
- Tensão máxima de eixo direto = 222 V.

### 2.5.1 Partida e Aplicação de Carga

Nesta simulação, partiu-se a máquina em vazio com fluxo e velocidade de referência fixados em  $0,425\text{Wb}$  e  $180\text{rad.ele/s}$ , respectivamente. Posteriormente, aplicou-se um conjugado de carga de  $5\text{Nm}$ .

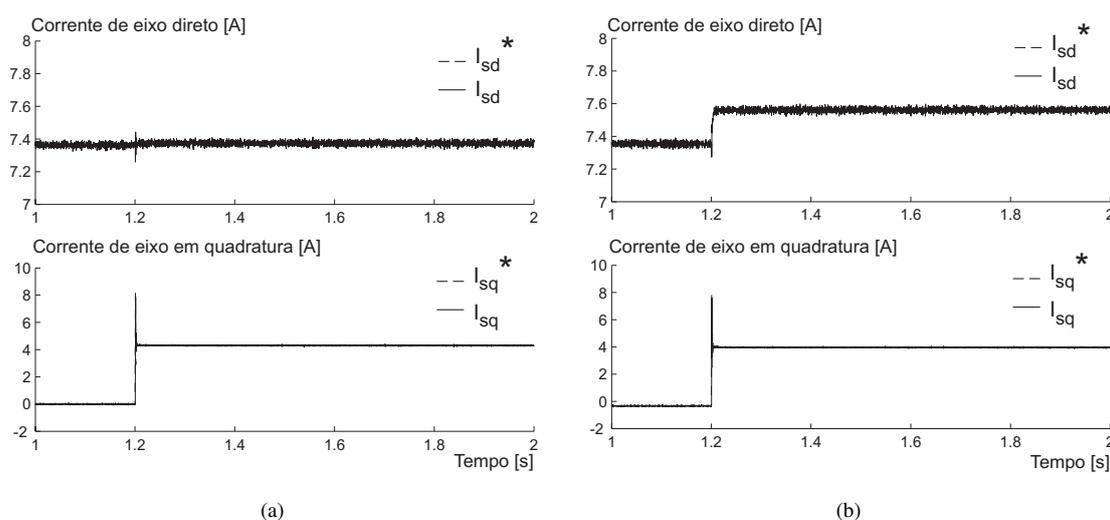
As Figs. 2.10 a 2.13, mostram o comportamento dos *estimadores 1* e *2* durante o transitório de partida e aplicação de carga.

Os comportamentos do fluxo, da velocidade e do conjugado são mostrados na Fig. 2.10. Na partida, os fluxos estimados convergem para o valor de referência assim como posteriormente a velocidade. Durante a aplicação de carga, não há variações visíveis no fluxo estimado, o que confere a qualidade da estimação de fluxo de ambos os estimadores.



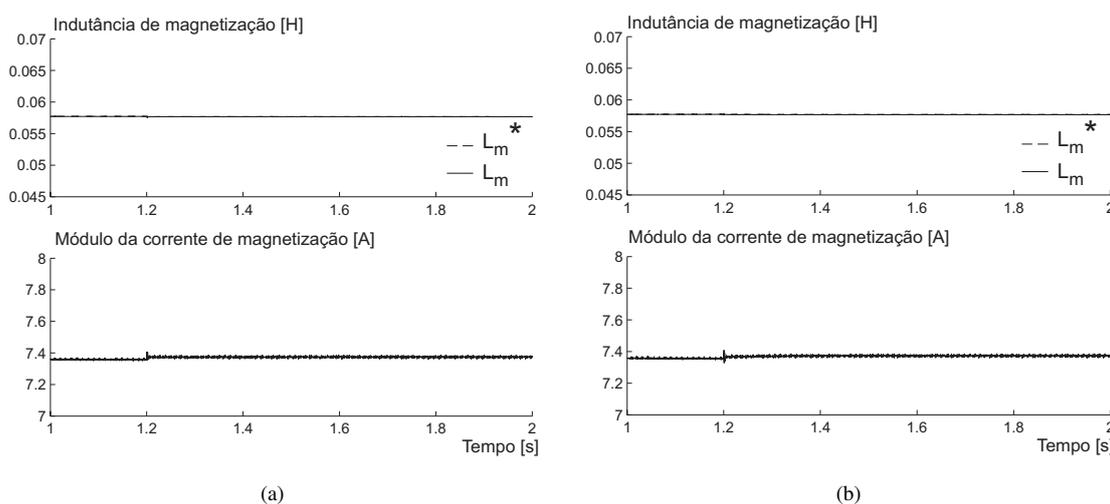
**Figura 2.10:** Resultados de simulação. Evolução do fluxo, da velocidade e do conjugado. Partida e aplicação de carga: (a) Estimador 1; (b) Estimador 2.

Na Fig. 2.11, é mostrado o comportamento da malha de controle de corrente. Como pode ser observado, as correntes de eixo direto e em quadratura acompanham os seus respectivos valores de referência rapidamente, mostrando assim o bom desempenho do controle de corrente.



**Figura 2.11:** Resultados de simulação. Evolução das componentes de corrente de eixos direto e em quadratura. Partida e aplicação de carga: (a) Estimador 1; (b) Estimador 2.

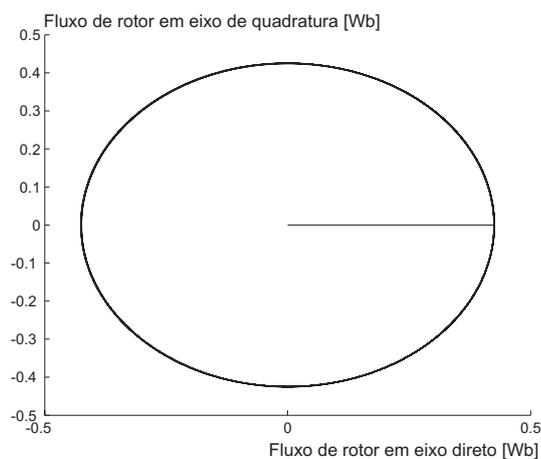
Os comportamentos da indutância de magnetização e do módulo da corrente de magnetização são mostrados na Fig. 2.12. O efeito da saturação magnética do ferro pode ser observado acompanhando-se as variações da corrente e da indutância de magnetização. Percebe-se ainda, que o valor estimado acompanha o valor real da indutância de magnetização.



**Figura 2.12:** Resultados de simulação. Evolução da indutância e da corrente de magnetização. Partida e aplicação de carga: (a) Estimador 1; (b) Estimador 2.

Na Fig. 2.13 é mostrada a trajetória do vetor fluxo de rotor proveniente do *estimador 1*. O fluxo de rotor, depois de estabelecido, segue uma trajetória circular, mesmo durante a

aplicação de carga, ratificando o bom desacoplamento entre as malhas de fluxo e conjugado.

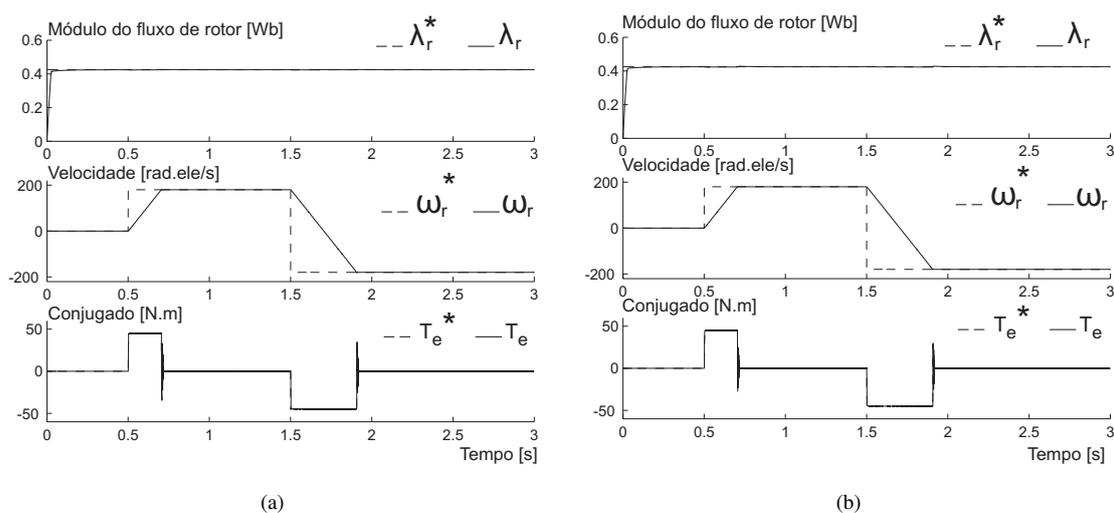


**Figura 2.13:** Resultados de simulação. Trajetória do vetor fluxo de rotor. Partida e aplicação de carga - Estimador 1.

### 2.5.2 Partida e Reversão de Velocidade

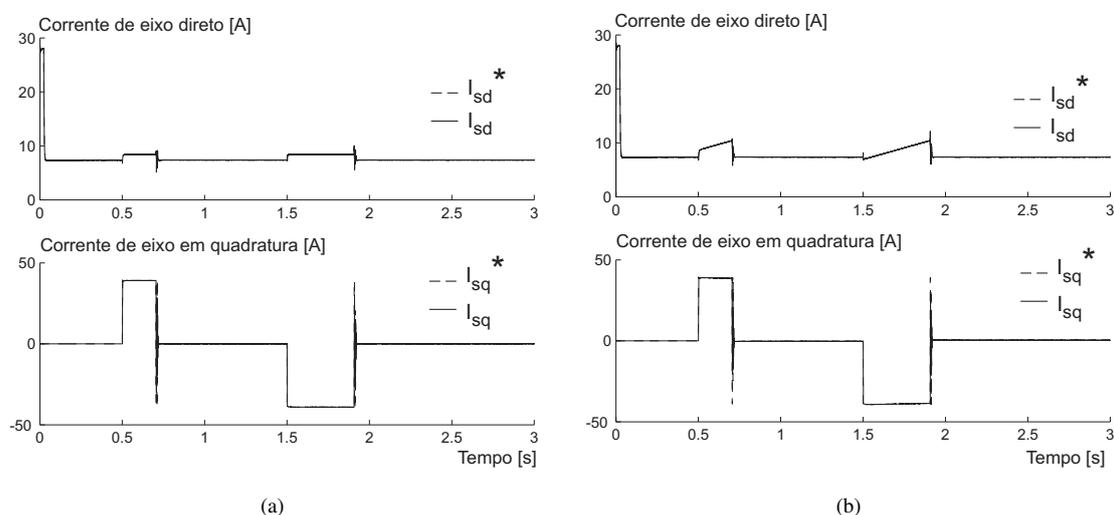
Nesta simulação, partiu-se a máquina com os valores de referência de fluxo e conjugado estabelecidos anteriormente e em seguida solicitou-se a reversão de velocidade. As Figs. 2.14 - 2.17, mostram o comportamento dos *estimadores 1 e 2* durante o transitório de partida e reversão de velocidade.

Os comportamentos do fluxo, da velocidade e do conjugado da máquina são mostrados na Fig. 2.14. Durante a reversão de velocidade, não há variação perceptível do fluxo estimado, o que ratifica o bom desempenho dinâmico do controle.



**Figura 2.14:** Resultados de simulação. Evolução do fluxo, da velocidade e do conjugado. Partida e reversão de velocidade: (a) Estimador 1; (b) Estimador 2.

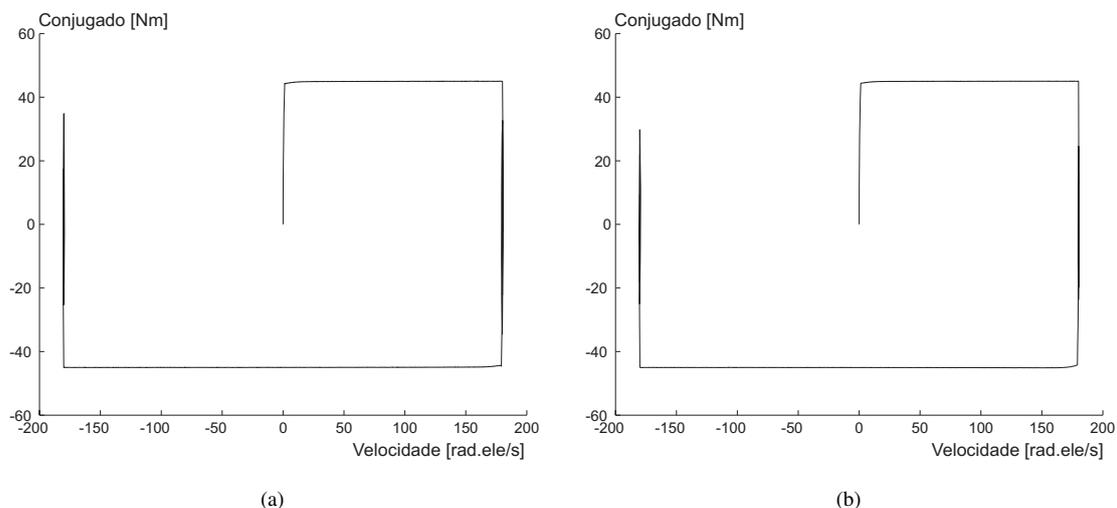
Na Fig. 2.15, são ilustradas as componentes de corrente das malhas de controle. Como era esperado, as correntes de eixo direto e em quadratura também acompanham os seus respectivos valores de referência.



**Figura 2.15:** Resultados de simulação. Evolução das componentes de corrente de eixos direto e em quadratura. Partida e reversão de velocidade: (a) Estimador 1; (b) Estimador 2.

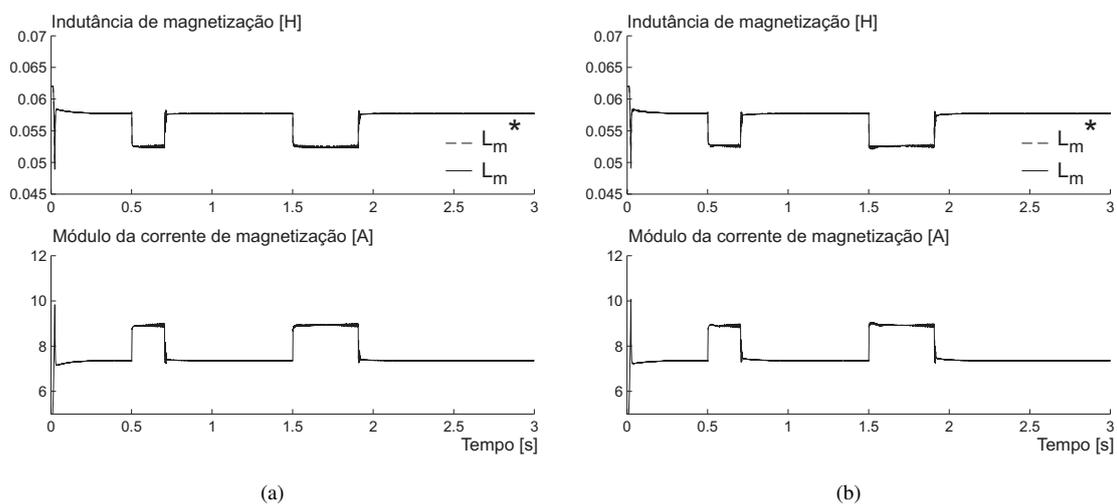
A curva conjugado versus velocidade é mostrada na Fig. 2.16. A trajetória do conjugado aproxima-se bem da característica desejada descrita em [14], ou seja, a trajetória, partindo da origem, percorre os lados de um retângulo por meio de segmentos retilíneos. Fica visualizado

então, o bom desempenho dinâmico da malha de conjugado.

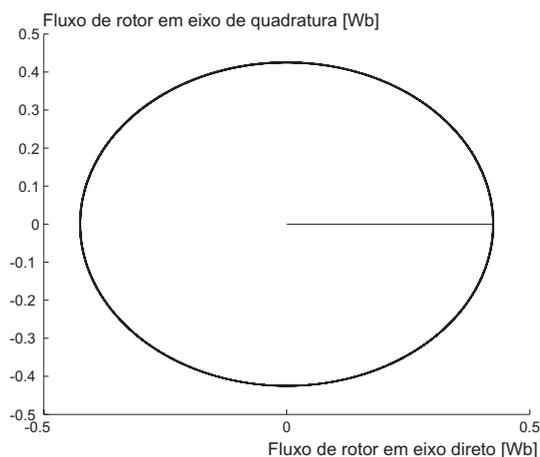


**Figura 2.16:** Resultados de simulação. Plano de fase - Conjugado x Velocidade. Partida e reversão de velocidade: (a) Estimador 1; (b) Estimador 2.

Os comportamentos da indutância de magnetização e do módulo da corrente de magnetização, para a simulação de partida e reversão de velocidade são mostrados na Fig.2.17. Já a trajetória do vetor fluxo de rotor é ilustrada na Fig. 2.18.



**Figura 2.17:** Resultados de simulação. Evolução da indutância e da corrente de magnetização. Partida e reversão de velocidade: (a) Estimador 1; (b) Estimador 2.

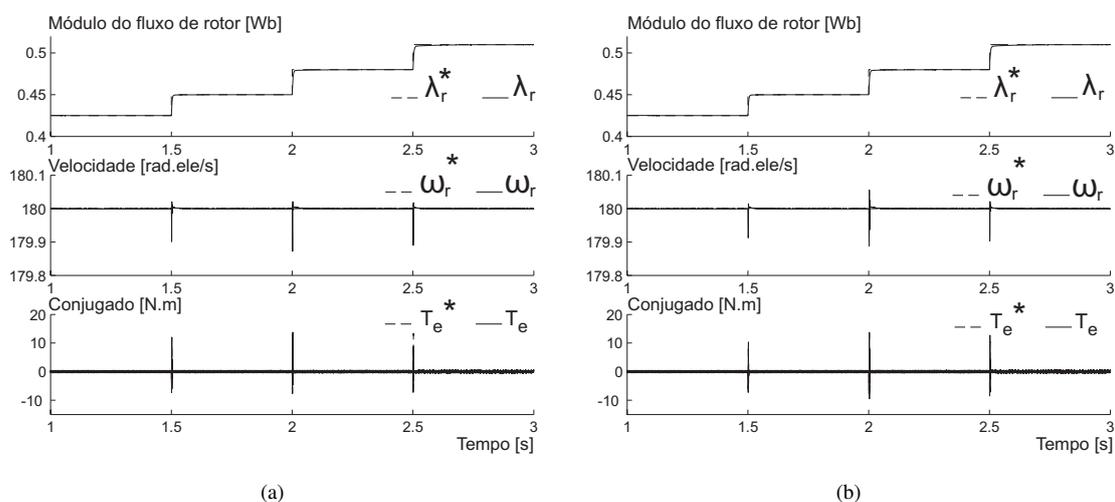


**Figura 2.18:** Resultados de simulação. Trajetória do vetor fluxo de rotor. Partida e reversão de velocidade - Estimador 1.

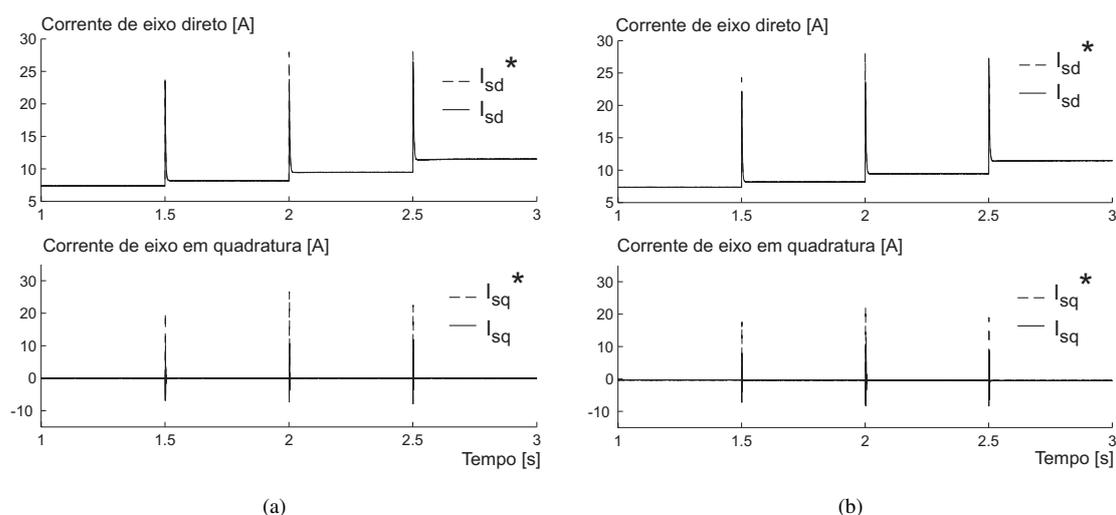
### 2.5.3 Partida e Variação do Fluxo de Referência

Para uma melhor visualização do desempenho do controle e dos estimadores, nas regiões em que a máquina opera com forte saturação, partiu-se a máquina em vazio com fluxo nominal (0,45 *Wb*) e em seguida aumentou-se o valor do fluxo de referência para 0,45, 0,48 e 0,51 *Wb*. As Figs. 2.19 - 2.22, mostram o comportamento dos *estimadores 1* e *2* durante este transitório.

Os comportamentos do fluxo, da velocidade e do conjugado da máquina são mostrados na Fig. 2.19 enquanto as correntes da malha de controle são ilustradas na Fig. 2.20.

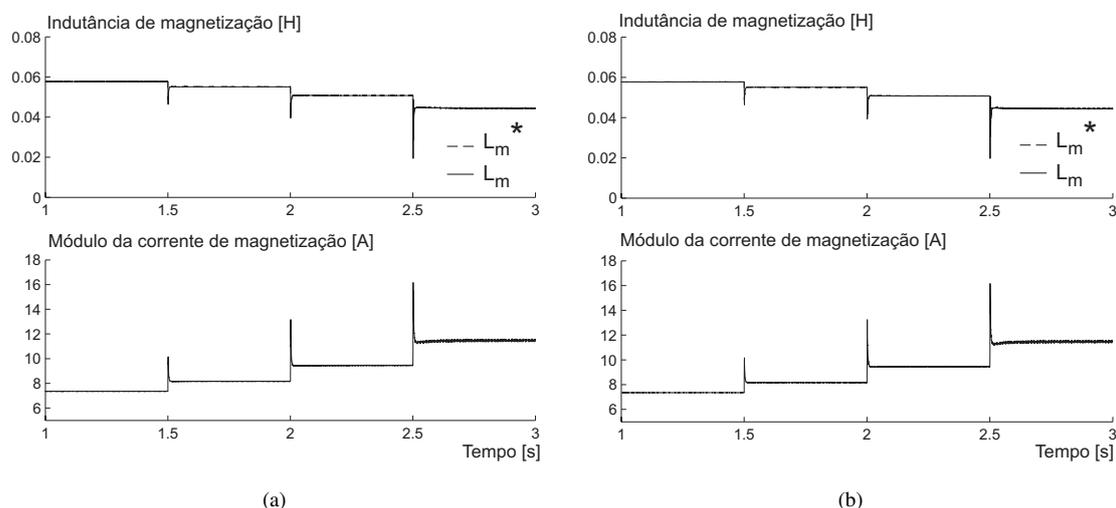


**Figura 2.19:** Resultados de simulação. Evolução do fluxo, da velocidade e do conjugado. Partida e variação do fluxo de referência: (a) Estimador 1; (b) Estimador 2.



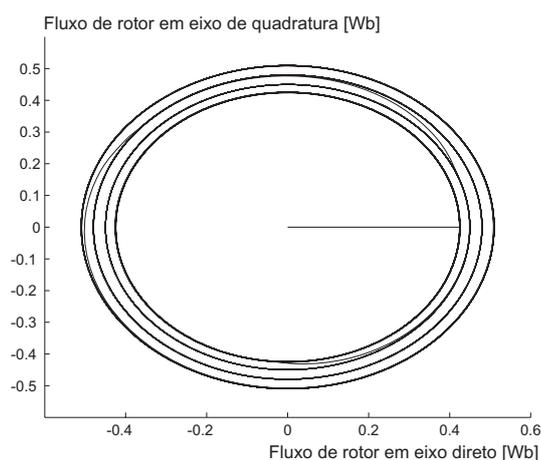
**Figura 2.20:** Resultados de simulação. Evolução das componentes de corrente de eixos direto e em quadratura. Partida e variação do fluxo de referência: (a) Estimador 1; (b) Estimador 2.

Na Fig. 2.21, percebe-se o elevado aumento da corrente de magnetização decorrente da pequena variação do fluxo de referência. O valor da indutância de magnetização vai diminuindo como consequência da menor inclinação da curva de magnetização (Fig. 2.5) nos respectivos pontos de operação.



**Figura 2.21:** Resultados de simulação. Evolução da indutância e da corrente de magnetização. Partida e variação do fluxo de referência: (a) Estimador 1; (b) Estimador 2.

A trajetória do vetor fluxo de rotor, para os diferentes valores do fluxo de referência é ilustrada na Fig. 2.22.



**Figura 2.22:** Resultados de simulação. Trajetória do vetor fluxo de rotor. Partida e variação do fluxo de referência - Estimador 1.

Como base nas simulações realizadas, ficou demonstrado que:

- Os estimadores de fluxos conseguiram acompanhar a dinâmica do fluxo real, o que garante a qualidade da estimação, mesmo considerando os efeitos da saturação magnética;
- Os dois estimadores apresentaram comportamentos semelhantes. Para validação da técnica estudada neste trabalho utilizou-se o *estimador 1*;
- O controle vetorial apresentou um bom desempenho durante os transitórios de partida e reversão de velocidade, partida e aplicação de carga e partida e variação de fluxo;
- Devido as saturações impostas à máquina, o limite máximo de fluxo permitido é de  $0,51Wb$  o qual corresponde a um acréscimo de 20% sobre o seu valor nominal.

# 3

## ASPECTOS GERAIS SOBRE REDES NEURAIS ARTIFICIAIS

### 3.1 Introdução

A partir do momento em que as máquinas começaram a evoluir, um grande desejo do homem tem sido a criação de uma máquina que possa operar independentemente do controle humano. Uma máquina cuja independência seja desenvolvida de acordo com seu próprio aprendizado e que tenha a capacidade de interagir com ambientes desconhecidos por ela. O sistema nervoso humano, tendo o cérebro como centro, é uma fonte de motivação para o desenvolvimento destas máquinas.

As Redes Neurais Artificiais (RNA) são sistemas computacionais com processamento paralelo e distribuído que apresentam a capacidade de aprender e armazenar conhecimento experimental. Estes sistemas computacionais apresentam características semelhantes às observadas no cérebro humano, dentre as quais pode-se destacar:

- Conhecimento é adquirido ou "aprendido" pela rede neural, como no cérebro humano, através de um processo de aprendizado;
- Pesos existentes nas conexões entre neurônios artificiais, análogos às sinapses em neurônios biológicos, são responsáveis por armazenar o conhecimento aprendido;
- Apresentam como o cérebro humano, a capacidade de generalização baseada no conhecimento aprendido. Isto significa que uma rede neural consegue produzir saídas

adequadas para entradas não observadas no seu processo de treinamento.

Os estudos referentes às RNA envolvem diversas áreas de conhecimento, como ciência da computação, neurofisiologia, matemática, dentre outras, com o objetivo de reproduzir as funções das redes neurais biológicas, visando implementar seu comportamento básico e sua dinâmica, e, desta forma, desenvolver sistemas capazes de imitar ou entender aspectos do pensamento humano.

Atualmente as RNA são aplicadas na resolução de uma grande quantidade de problemas com sucesso. Dentre as principais áreas de aplicação de RNA pode-se citar sistemas de controle, reconhecimento de padrões e aproximações de funções.

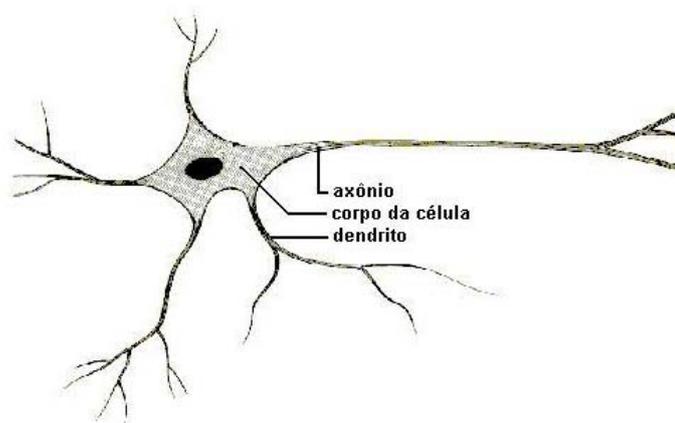
Este capítulo aborda as principais características das RNA. A topologia MLP (*MultiLayer Perceptron*) é discutida de forma mais detalhada, pois será usada como ferramenta auxiliar no controle vetorial do MIT.

## 3.2 Neurônios Biológicos

O cérebro humano contém aproximadamente 10 bilhões de neurônios, suas células fundamentais [31]. O neurônio biológico é constituído basicamente de três partes:

- Os dendritos, que têm por função receber os estímulos transmitidos pelos outros neurônios;
- O corpo do neurônio, que é responsável por coletar e combinar as informações vindas dos outros neurônios;
- E, finalmente, o axônio, que é responsável por transmitir os estímulos para outras células.

Na Fig. 3.1 são ilustradas, de forma simplificada, as partes de um neurônio biológico.

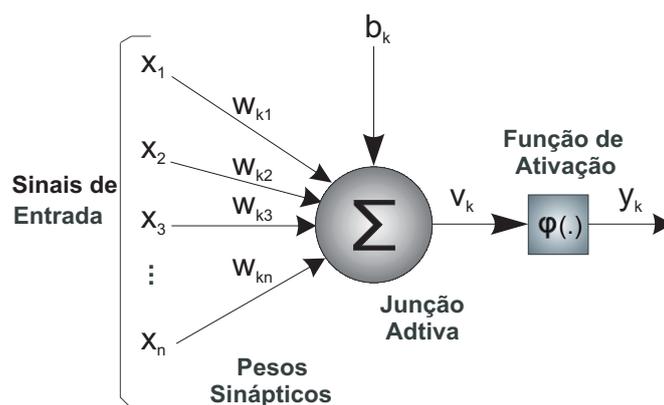


**Figura 3.1:** Partes do neurônio biológico.

Todas as funções e movimentos do organismo estão relacionados ao funcionamento destas pequenas células. Cada um destes neurônios processa e se comunica com os outros continuamente e em paralelo através de sinapses, e juntos formam uma grande rede, chamada rede neural biológica. As sinapses transmitem estímulos através de diferentes concentrações de  $Na^+$  (Sódio) e  $K^+$  (Potássio), e o resultado disto pode ser estendido por todo o corpo humano. Esta rede proporciona uma grande capacidade de processamento e armazenamento de informação.

### 3.3 Neurônios Artificiais

As primeiras informações mencionadas sobre RNA datam de 1943, com o desenvolvimento do primeiro modelo artificial de um neurônio biológico proposto por Walter Pitts e Warren McCulloch [32]. Nesse trabalho, os autores introduziram a idéia de redes neurais como máquinas computacionais. Posteriormente, Frank Rosenblatt [33] demonstrou, com seu novo modelo chamado *perceptron*, que se fossem acrescentadas de pesos ajustáveis, as RNA poderiam ser treinadas para classificar certos tipos de padrões. O diagrama de blocos da Fig.3.2 mostra o modelo de um neurônio artificial, no qual podemos identificar cinco elementos básicos e suas semelhanças com o neurônio biológico:



**Figura 3.2:** *Partes do neurônio artificial.*

- Um conjunto de entradas, que representam os dendritos, cujas ligações com o corpo celular artificial são realizadas através de conexões sinápticas, as quais estão associadas cada qual a seu correspondente peso. Especificamente, um sinal  $x_j$  na entrada da sinapse  $j$  conectada ao neurônio  $k$  é multiplicada pelo peso sináptico  $w_{kj}$ . O primeiro índice se refere ao neurônio em questão e o segundo ao terminal de entrada da sinapse à qual o peso se refere;
- Uma função soma, o corpo do neurônio, responsável pela combinação aditiva das entradas ponderadas pelos respectivos pesos sinápticos;
- Uma função de ativação, limiar de disparo do neurônio biológico, para restringir a amplitude da saída de um neurônio;
- Um bias (ou termo de polarização) aplicado externamente, representado na Fig. 3.2 por  $b_k$ , cuja função é aumentar ou diminuir a entrada líquida da função de ativação, dependendo dele ser positivo ou negativo respectivamente;
- Um terminal de saída  $y_k$ , representando o axônio, que fornece o valor do sinal de saída do neurônio  $k$ .

A função básica do neurônio artificial é então realizar o somatório, ponderado por pesos sinápticos, dos elementos do vetor de entrada e aplicar este resultado como entrada de uma função de ativação.

Em termos matemáticos, pode-se descrever um neurônio  $k$  através das seguintes equações:

$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (3.1)$$

e

$$y_k = \varphi(u_k + b_k) \quad (3.2)$$

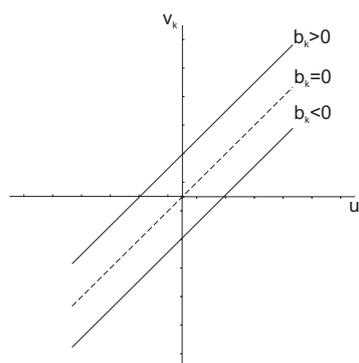
em que:

- $x_1, x_2, \dots, x_m$  são os sinais de entrada;
- $w_{k1}, w_{k2}, \dots, w_{km}$  são os pesos sinápticos do neurônio  $k$ ;
- $u_k$  é a saída do somador do neurônio  $k$ ;
- $b_k$  é o bias do neurônio  $k$ ;
- $\varphi(\cdot)$  é a função de ativação;
- $y_k$  é o sinal de saída do neurônio  $k$ .

O uso do bias  $b_k$  tem o efeito de aplicar uma transformação afim à saída do somador  $u_k$  do modelo da Fig. 3.2 como mostrado por:

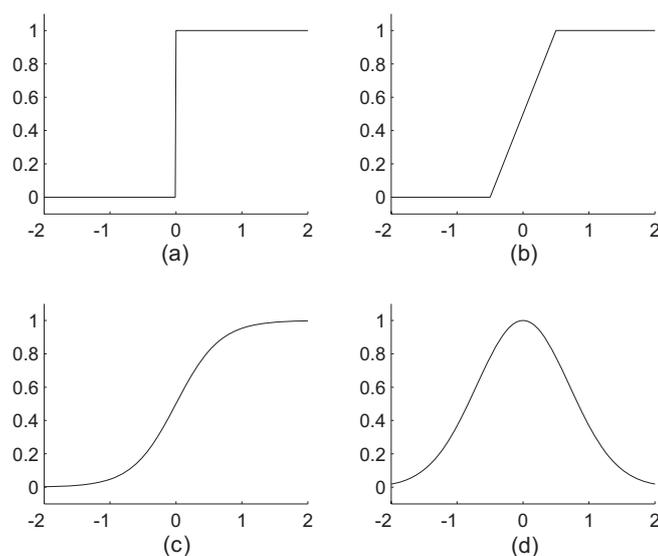
$$v_k = u_k + b_k \quad (3.3)$$

Em particular, dependendo do bias  $b_k$  ser positivo ou negativo, a relação entre o potencial de ativação  $v_k$  do neurônio  $k$  e a saída do somador  $u_k$  é modificada na forma ilustrada na Fig.3.3.



**Figura 3.3:** Transformação afim produzida pela presença de um bias.

A partir do modelo proposto por McCulloch e Pitts, foram derivados vários outros modelos que permitem a produção de uma saída qualquer, não necessariamente zero ou um, e com diferentes funções de ativação [31]. Na Fig. 3.4 estão ilustradas quatro classes de funções de ativação que são usualmente utilizadas:

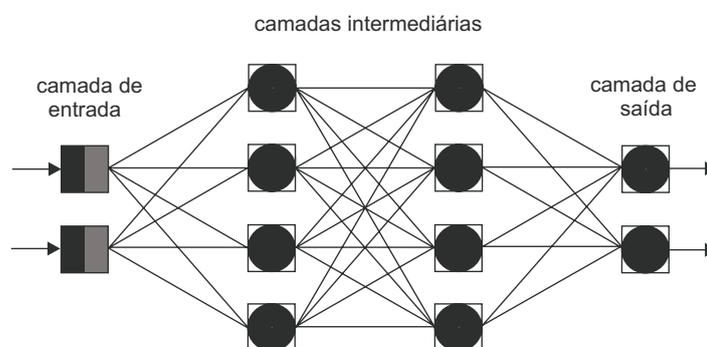


**Figura 3.4:** Funções de ativação: (a) Sinal, (b) Linear por partes, (c) Sigmoideal, (d) Gaussiana.

Quando os limites da função sigmoideal estão compreendidos entre  $[-1,1]$  esta recebe o nome de tangente hiperbólica, se estes estiverem entre  $[0,1]$  ela é chamada sigmoide logística.

Os neurônios podem ser dispostos em uma ou mais camadas e interligados através das sinapses, geralmente unidirecionais. Na maioria desses modelos estas conexões estão associadas a pesos ajustáveis. No entanto, existem RNA com pesos fixos ou sem pesos.

Na Fig. 3.5 é ilustrada uma rede neural possuindo duas entradas, duas camadas intermediárias, também chamadas de camadas ocultas, cada uma contendo quatro neurônios, e uma camada de saída com dois neurônios.



**Figura 3.5:** Rede de Múltiplas Camadas.

Inicialmente a solução de tarefas utilizando redes sem camadas intermediárias estava restrita a problemas *linearmente separáveis*, ou seja, a problemas cuja solução pode ser obtida pela separação de duas regiões por meio de uma reta (ou um hiperplano para o caso n-dimensional).

A possibilidade de dispor os neurônios em diferentes camadas intermediárias, permitiu a solução de problemas não linearmente separáveis. Resultados obtidos de pesquisas mostram que uma camada intermediária é suficiente para aproximar qualquer função contínua [34, 35] e duas camadas intermediárias são suficientes para aproximar qualquer função matemática [36].

As funções de ativação dos nós (neurônios) da camada de saída podem ser diferentes das funções de ativação dos nós das camadas intermediárias. O mesmo se estende para os nós individuais, onde cada nó pode apresentar uma função de ativação diferente.

Os elementos da arquitetura de uma RNA, ou seja, o número de camadas da rede, o número de neurônios em cada camada, a função de ativação de cada neurônio, assim como o tipo de conexão entre os neurônios constituem parâmetros importantes na sua concepção.

### 3.4 Aprendizagem

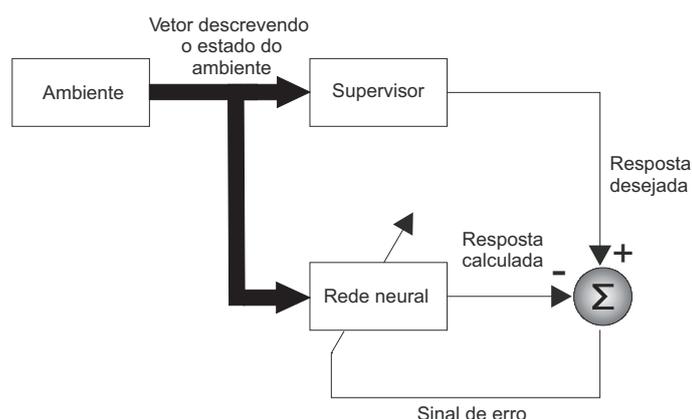
Antes de uma RNA estar apta para ser utilizada na solução de um problema, precisa inicialmente passar por um processo de aprendizagem. Nesta etapa, através de um processo iterativo, os pesos das conexões entre os neurônios são ajustados, e assim, a rede vai criando sua representação própria do problema, através da extração de informações relevantes de padrões que são apresentados a ela. No fim do processo, o conhecimento adquirido do ambiente fica armazenado em suas conexões.

Os procedimentos empregados para adaptar os parâmetros de uma rede é chamado *algoritmo de aprendizado*. Diversos métodos para treinamento (aprendizagem) de redes foram desenvolvidos, cada qual com suas vantagens e desvantagens, podendo ser agrupados em duas categorias principais: aprendizado supervisionado e aprendizado não-supervisionado.

No aprendizado supervisionado, Fig. 3.6, as entradas e saídas desejadas para a rede são fornecidas por um supervisor externo cujo objetivo é ajustar os parâmetros de forma a encontrar uma ligação entre os pares de entrada e saída fornecidos. A cada padrão de entrada submetido à rede compara-se a resposta desejada com a resposta calculada, ajustando-se os pesos das conexões para minimizar o erro [31].

A desvantagem do aprendizado supervisionado é que, na ausência do supervisor, a rede não conseguirá aprender novas estratégias para situações não-cobertas pelos exemplos apresentados a rede durante o treinamento.

Dentre os algoritmos para aprendizado supervisionado mais utilizados estão a regra delta e sua generalização para redes de múltiplas camadas (MLP), o algoritmo backpropagation [37].



**Figura 3.6:** *Aprendizado supervisionado.*

No aprendizado não-supervisionado, Fig. 3.7, não há um supervisor para acompanhar o processo de aprendizado. Para estes algoritmos, somente os padrões de entradas estão disponíveis para a rede. Neste método, a rede desenvolve sua representação do problema a partir do momento em que se estabelece alguma regularidade estatística da entrada de dados [31]. A partir de então, a rede passa a criar novas classes ou grupos automaticamente.

A desvantagem do aprendizado não-supervisionado é que este só se torna possível quando existe redundância nos dados de entrada, ou seja, se existem relações características entre os padrões de entrada. Dentre os principais métodos desta técnica, destaca-se a regra de Hebb [38].



**Figura 3.7:** *Aprendizado não-supervisionado.*

Dependendo do problema a ser abordado, é possível selecionar o tipo de rede neural que melhor se adapta às suas características. As redes Perceptron e Adaline são restritas à solução de problemas linearmente separáveis.

Redes MLP são mais indicadas para solução de problemas complexos. A possibilidade de incluir mais de uma camada intermediária aliada ao fato da separação dos padrões de entrada ser realizada através de hiperplanos permite a construção de aproximadores globais para mapeamento entrada-saída. Essas características, garantem às redes MLP uma maior

capacidade de generalização para regiões onde não há dados de treinamento.

As redes de funções de bases radiais (RBF) são redes que geralmente possuem uma única camada interna a qual utiliza como função de ativação de seus neurônios funções de base radiais. Estas redes separam padrões de entrada através de hiperelipsóides os quais constroem aproximadores locais para mapeamento entrada-saída. As RBF apresentam melhor desempenho em problemas bem definidos.

Já as redes auto-organizativas são modelos que utilizam o paradigma de aprendizado não-supervisionado. Estas redes são potencialmente utilizadas em problemas de reconhecimento de padrões e categorização de dados em que as classes não são conhecidas inicialmente.

Como será visto no Capítulo 4, o problema de redução das perdas em um motor de indução se assemelha a uma relação de mapeamento entrada-saída o que possibilita duas opções de topologias: as redes MLP e RBF.

Tendo em mente a busca por uma rede de fácil implementação prática, os seguintes aspectos foram observados na escolha da topologia:

1. A entrada da função de ativação dos neurônios das redes RBF ser calculado a partir da distância euclidiana entre os vetores de entrada e de pesos, ao contrário das redes MLP em que a entrada de ativação é calculada a partir do produto interno desses vetores, despense um maior número de operações por neurônio;
2. O número de neurônios na camada oculta das redes RBF é geralmente igual ou muito próximo do número de padrões utilizados durante o seu treinamento o que torna o seu desempenho limitado por questão de memória;
3. Por serem aproximadores globais, as redes MLP apresentam maior poder de generalização frente as redes RBF (aproximadores locais).

Com base nos aspectos acima mencionados, optou-se pela utilização das redes MLP, embora o seu treinamento seja mais lento que o das redes RBF.

### 3.5 Redes MLP

As redes MLP são constituídas de uma camada de entrada, uma ou mais camadas intermediárias (ocultas) e uma camada de saída. Como mencionado anteriormente, estas redes permitem a solução de problemas não linearmente separáveis cuja precisão e implementação da função objetivo dependem do número de camadas, assim como da quantidade de neurônios utilizados em cada camada intermediária.

Em muitos casos, a utilização de duas ou mais camadas intermediárias pode facilitar a aprendizagem, porém deve ser observado que o erro medido durante o processo de treinamento, ao ser propagado para a camada anterior, vai tornando-se cada vez menos útil e preciso.

#### 3.5.1 Algoritmo de Retropropagação

O algoritmo de retropropagação do erro (*error backpropagation*), foi apresentado por Rumelhart, Hilton e Williams [37] em 1986 e é utilizado no aprendizado das redes MLP. Tal como a regra delta [39], ele aplica o gradiente descendente para minimizar a função de custo  $E$  dada pela equação

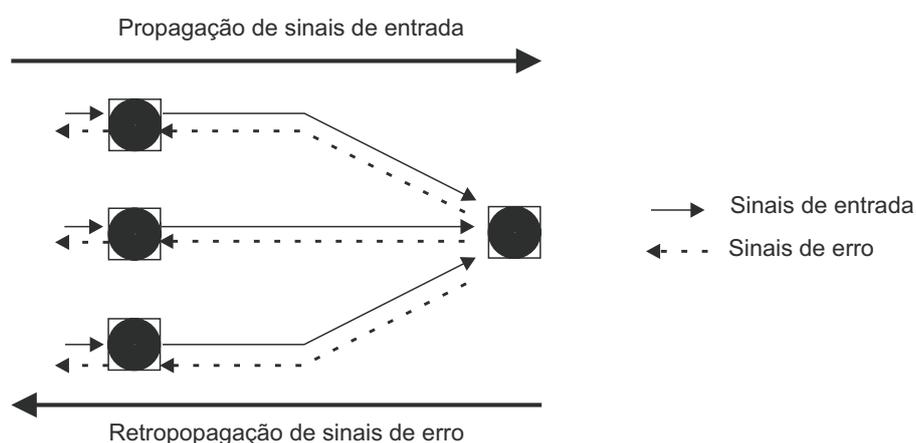
$$E = \frac{1}{2} \sum_{l=1}^q \sum_{i=1}^k (y_{di}^q - y_{ci}^q)^2 \quad (3.4)$$

em que:

- $E$ , função de custo ou medida do erro total
- $y_{di}^q$ , é a  $i$ -ésima saída desejada;
- $y_{ci}^q$ , é a  $i$ -ésima saída calculada;
- $k$ , número de neurônios da camada de saída;
- $q$ , é o número de padrões.

Dois tipos de sinais são observados nesta rede durante o treinamento [40], os sinais de entrada e os sinais de erro, os quais dão origem a duas fases distintas no processo de aprendizado mostrado na Fig. 3.8:

- A fase para frente ou propagação (forward) onde um padrão de entrada é fornecido à camada de entrada, propaga-se neurônio por neurônio para frente através da rede e produz um sinal na camada de saída;
- A fase para trás ou retropropagação (backward) onde os erros originados pela diferença entre a saída desejada e a saída calculada pela rede se propagam para trás, atualizando-se os pesos de cada neurônio.



**Figura 3.8:** Fluxo de processamento do algoritmo backpropagation.

Com o intuito de gerar soluções mais eficientes e eficazes, diversas heurísticas e variações do Backpropagation foram propostas: Backpropagation com momentum [37], Quick Propagation (QPROP ou Quickprop) [41], Resilient Propagation [42], Levenberg-Marquadt [43][44] e Treinamento por Modos Deslizantes [45] são alguns exemplos de variações.

#### Algoritmo Levenberg-Marquardt

Enquanto o backpropagation padrão utiliza o gradiente descendente como método de aproximação do mínimo da função erro, o algoritmo de Levenberg-Marquardt utiliza uma

aproximação pelo método de Newton, possibilitando minimizar uma função em relação a um determinado vetor de parâmetros.

Dentre as diversas variações do algoritmo Backpropagation, o algoritmo de Levenberg-Marquardt é a técnica mais rápida de treinamento de redes com múltiplas camadas, desde que a rede possua uma quantidade moderada de pesos sinápticos a fim de tornar o problema com solução.

O algoritmo de Levenberg-Marquardt [43][44], assim como no método de otimização de Newton, faz uso de derivadas de segunda ordem, com uma ligeira modificação no cálculo da matriz Hessiana. Esta, ao invés de ser baseada no cálculo das derivadas de segunda ordem do erro quadrático em relação aos pesos, é calculada a partir do produto da matriz Jacobiana, que contém as primeiras derivadas dos erros em função dos pesos sinápticos.

Seja a seguinte função que se deseja minimizar com respeito ao vetor de parâmetros  $x$ , dada pela expressão:

$$V(x) = \frac{1}{2} \sum_{j=1}^N E_j^2(x) \quad (3.5)$$

em que,

$$x = \left[ W_{11}^1 \quad W_{12}^1 \quad \dots \quad W_{S_1 R_1}^1 \quad W_{11}^2 \quad \dots \quad W_{S_2 R_2}^2 \quad \dots \quad W_{11}^M \quad \dots \quad W_{S_M R_M}^M \right] \quad (3.6)$$

e  $W_{SR}^i$  é o elemento  $SR$  da  $i$ -ésima matriz de pesos de uma rede contendo  $M$  camadas. Nesta matriz de pesos também estão incluídos os termos de polarização. O índice  $N$  do somatório (3.5) é igual a  $N = Q \cdot M$ , onde  $Q$  é o número total de padrões que serão utilizados no treinamento e  $E$  é o sinal de erro na saída do neurônio  $k$  como definido em (3.4).

Para minimizar essa função, com relação ao vetor  $x$ , tem-se que:

$$\Delta x = -\nabla^2 V(x)^{-1} \cdot \nabla V(x) \quad (3.7)$$

em que,  $\nabla^2 V(x)$  e  $\nabla V(x)$  são a Hessiana e o gradiente da função  $V(x)$ , respectivamente. A matriz  $\nabla V(x)$  é então calculada da seguinte forma:

$$[J] = \begin{bmatrix} \frac{\partial e_1(x)}{\partial x_1} & \frac{\partial e_1(x)}{\partial x_2} & \cdots & \frac{\partial e_1(x)}{\partial x_N} \\ \frac{\partial e_2(x)}{\partial x_1} & \frac{\partial e_2(x)}{\partial x_2} & \cdots & \frac{\partial e_2(x)}{\partial x_N} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial e_Q(x)}{\partial x_1} & \frac{\partial e_Q(x)}{\partial x_2} & \cdots & \frac{\partial e_Q(x)}{\partial x_N} \end{bmatrix} \quad (3.8)$$

Como em uma rede neural o desempenho de treinamento é expresso em função da soma dos erros quadráticos a matriz Hessiana pode ser expressa como:

$$[H] = [J]^T [J] \quad (3.9)$$

O método de Newton atualiza os pesos da seguinte forma:

$$x_{k+1} = x_k - [H]^{-1} q_k \quad (3.10)$$

em que

$$q_k = 2[J]^T e(x) \quad (3.11)$$

O método de Levenberg-Marquardt introduz uma pequena modificação no método de Newton e (3.10) é alterada, tornando-se:

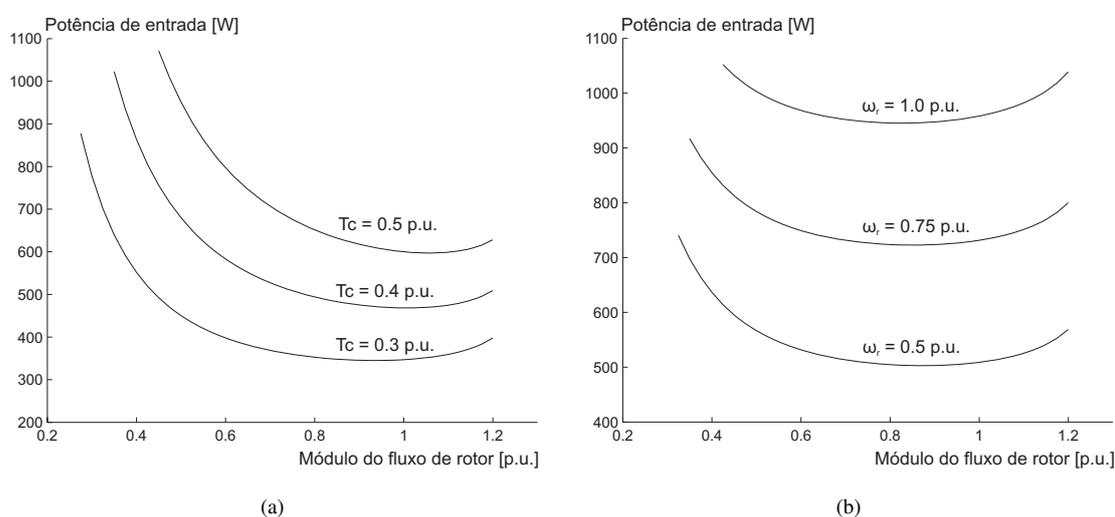
$$\Delta x = -[[J]^T \cdot [J] + \mu \cdot I]^{-1} \cdot [J]^T \cdot e(x) \quad (3.12)$$

O parâmetro  $\mu$  é multiplicado por um fator ( $\rho$ ) toda vez que um passo resultar em um aumento na função erro, que se deseja minimizar. Quando um passo resultar na diminuição da função genérica  $V(x)$ ,  $\mu$  é dividido pelo fator ( $\rho$ ). Isto significa dizer que, se houver uma convergência para o mínimo da função,  $\mu$  é pequeno e o algoritmo se aproxima do método de Newton (passo  $1/\mu$ ); no caso de não haver convergência, o algoritmo torna-se um método de gradiente descendente. O parâmetro  $\mu$  funciona como um fator de estabilização do treinamento, ajustando a aproximação de forma a utilizar a rápida convergência do método de Newton e evitando passos muito grandes que possam levar a um erro de convergência.

### 3.6 A Técnica Implementada

Como foi dito no Capítulo 1, para uma dada condição de velocidade e torque, as perdas em uma máquina de indução podem ser minimizadas ajustando apropriadamente o nível de fluxo do entreferro [4],[5]. Isto se deve ao fato de que as perdas no ferro do núcleo em uma máquina são uma função direta do fluxo. Por conseqüência, uma variação no fluxo muda a corrente exigida por um dado torque e conseqüentemente o equilíbrio entre as perdas no cobre e no ferro de estator e rotor.

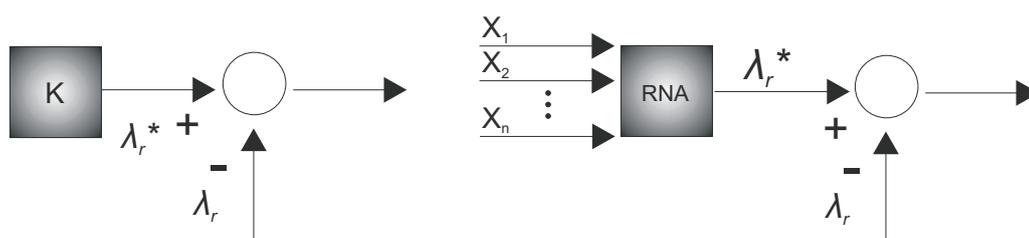
Na Fig. 3.9, é mostrada a potência dissipada em função da variação do fluxo.



**Figura 3.9:** Potência de entrada x fluxo de rotor: (a)  $\omega_r = 0,25$ p.u.; (b)  $T_c = 0,25$ p.u..

A técnica a ser estudada, consiste da substituição do fluxo de referência fixo do controle tradicional orientado segundo o fluxo de rotor por um fluxo de referência variável estabelecido pela RNA como mostrado na Fig. 3.10.

A partir das variáveis de entrada fornecidas, a rede faz a predição do fluxo de referência que resulte nas menores perdas totais da máquina.



**Figura 3.10:** *Controle convencional x Controle neural.*

O número de neurônios nas camadas de entrada e saída de uma rede neural está diretamente relacionado às características que melhor representem o problema a ser resolvido. Na literatura, encontram-se disponíveis diversos trabalhos nos quais diferentes grandezas são utilizadas.

Em [46] e [47] é realizada a modelagem do MIT desprezando os efeitos da saturação magnética, e uma rede neural com dois neurônios na camada de entrada (velocidade do rotor e conjugado de carga) é utilizada na predição da corrente de estator de eixo direto. Em [48] o efeito da resistência do ferro do núcleo é considerado e uma rede similar a anterior é aplicada.

Uma rede neural tendo como entradas as tensões e correntes de estator do MIT [12] é utilizada na determinação da tensão de referência na qual resulte em uma maior eficiência para uma dada carga aplicada ao eixo.

Uma modelagem considerando a variação da indutância de magnetização é realizada em [49], e uma rede com dois neurônios na camada de entrada (velocidade do rotor e conjugado eletromagnético estimado) e um na saída (fluxo de rotor) é estudada.

As variações térmicas e magnéticas são consideradas em [50] e uma rede tendo como entradas o conjugado eletromagnético estimado, a velocidade e a resistência de rotor do MIT é utilizada na determinação do fluxo de rotor. Em [13] o efeito da indutância mútua é adicionado e uma rede com quatro neurônios na camada de entrada é utilizada.

Como a modelagem do motor de indução e do estimador de fluxo já contemplam o efeito da saturação magnética e as variações da resistência de rotor são desconsideradas, adotou-se como parâmetros de entrada da rede neural a velocidade de referência e o conjugado

eletromagnético estimado e como parâmetro de saída o fluxo de rotor de referência.

No próximo capítulo serão descritos o processo de formação, tratamento e separação dos dados, a metodologia adotada para escolha das melhores arquiteturas, bem como os resultados de treinamento e desempenho das RNA.

# 4

## TREINAMENTO, ESCOLHA E DESEMPENHO DAS REDES MLP UTILIZADAS

Este capítulo descreve o processo de criação do banco de dados representativo da operação mais eficiente do MIT, os métodos envolvidos na escolha das arquiteturas das redes neurais, bem como os resultados de simulação do desempenho das RNA obtidas.

### 4.1 Escolha das Variáveis de Entrada

Para uma RNA realizar de forma satisfatória seu trabalho, suas entradas devem conter informações que descrevam as principais características do problema a ser resolvido. A quantidade de informação (número de entradas), é uma questão a ser observada pelo especialista, e deve atender a dois critérios principais:

1. Se o número de informações for pequeno em relação à complexidade do problema, a rede dificilmente conseguirá resultados satisfatórios;
2. Se o número de informações for muito grande, a rede poderá ser muito complexa (grande número de conexões), o que pode torná-la instável.

Diversos trabalhos, dentre os quais pode-se mencionar [46] -[13], citam as variáveis de controle (velocidade e conjugado eletromagnético de referência, tensões e correntes de alimentação, variações da resistência de rotor e indutância de magnetização) como

importantes entradas para o problema abordado neste texto, pois possuem grande correlação com o controle vetorial e conseqüentemente com o consumo de energia do motor.

Nesta dissertação, adotou-se como entradas da rede a velocidade de referência e o conjugado eletromagnético estimado e o fluxo de rotor de referência como saída, tendo em vista o fato da modelagem da máquina e do estimador de fluxo incluírem o efeito da saturação magnética do ferro.

## 4.2 Criação das Redes

Os procedimentos adotados para representação das informações e escolha da arquitetura das redes neurais são os métodos recomendados pelo relatório do *Proben* [51]:

- Obtenção, tratamento e separação dos dados;
- Processo de treinamento e escolha da melhor arquitetura;
- Utilização do método de validação cruzada para determinação da melhor inicialização.

### 4.2.1 Obtenção, Tratamento e Separação dos Dados

Para obter dados representativos da condição de maior eficiência, simulou-se o modelo da máquina de indução, descrito no Capítulo 2, para diversas condições de velocidade e carga. Na Tabela 4.1 é mostrada a faixa de variação das grandezas utilizadas para formação do banco de dados. Os valores de base adotados na representação em p.u. são  $\omega_{r_{base}} = 340 \text{ rad.ele/s}$ ,  $T_{ele_{base}} = 20 \text{ Nm}$  e  $\lambda_{r_{base}} = 0,425 \text{ Wb}$ .

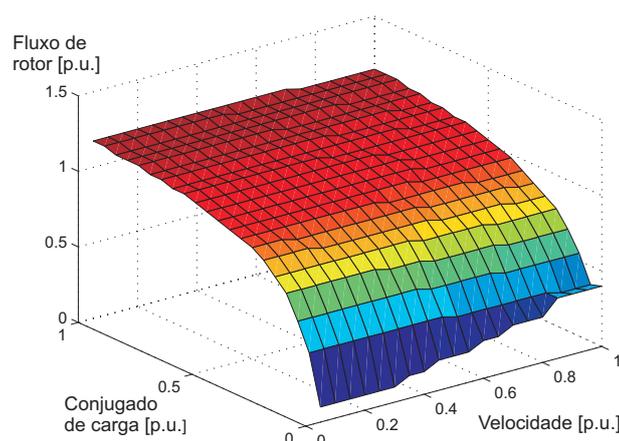
**Tabela 4.1:** Limites do banco de dados

Variável	Intervalo [p.u.]	Incremento [p.u.]
<i>Velocidade</i>	0,05 a 1	0,05
<i>Conjugado</i>	0 a 1	0,05
<i>Fluxo</i>	0,1 a 1,2	0,025

Fixada uma condição operacional (velocidade e conjugado de referência) e um dado

valor de fluxo de referência, mede-se, em regime permanente, a potência de entrada correspondente. O fluxo de referência ideal para uma dada condição operacional é aquele no qual resulte a menor potência de entrada.

Ao final do processo de formação do banco de dados, obteve-se um conjunto formado por 420 pontos. Os valores de fluxo de referência obtidos estão distribuídos no intervalo de  $[0,1;1,175]$ . Na Fig. 4.1 é mostrada a superfície correspondente aos pontos obtidos.



**Figura 4.1:** Superfície representativa do banco de dados.

Como o tempo entre cada amostragem do sistema de controle de velocidade real é de  $250\mu s$  e a saída da rede deve possuir um certo grau de precisão para um bom funcionamento do controle, optou-se por dividir a região operacional do MIT em 10 faixas com base no conjugado de carga aplicado ao seu eixo. Com a divisão por nível de conjugado espera-se obter redes com estruturas menores e, por conseqüência, um menor tempo computacional será necessário para realização dos cálculos envolvidos.

Desta forma 10 redes neurais foram obtidas, onde cada rede, é responsável por sua respectiva faixa de conjugado como mostrado na Tabela 4.2.

Para evitar que o neurônio funcione na sua região de saturação (valores de saída próximos dos limites superior e inferior das funções de ativação), ou que os valores de entrada com magnitude diferentes interfiram no processo de aprendizado da rede, o banco de dados é normalizado, ou seja, seus elementos são distribuídos em uma faixa específica de valores, através da equação (4.1):

**Tabela 4.2:** Rede neural artificial versus faixa operacional

<b>RNA</b>	<b>Conjugado de carga [p.u.]</b>
1	0 a 0,1
2	0,1 a 0,2
3	0,2 a 0,3
4	0,3 a 0,4
5	0,4 a 0,5
6	0,5 a 0,6
7	0,6 a 0,7
8	0,7 a 0,8
9	0,8 a 0,9
10	0,9 a 1,0

$$x_{nij} = \frac{L_{inf}(max(x_j) - x_{ij}) - L_{sup}(min(x_j) - x_{ij})}{max(x_j) - min(x_j)} \quad (4.1)$$

onde  $max(x_j)$  e  $min(x_j)$  correspondem ao valores máximo e mínimo do fluxo de referência e os termos  $L_{sup}$  e  $L_{inf}$  aos limites superior e inferior do intervalo de normalização, respectivamente.

Como a faixa dos valores de entrada (velocidade e conjugado) está compreendida entre [0,1] estes não necessitam ser normalizados. Já a saída, fluxo de rotor de referência, variando no intervalo [0,1;1,175] foi normalizada adotando-se 0,2 e 0,8 como limites superior e inferior do intervalo de normalização, respectivamente. As equações (4.2) e (4.3) são então utilizadas para normalizar e desnormalizar os valores de saída da rede neural:

$$x_{nij} = \frac{0,155 + 0,6x_{ij}}{1,075} \quad (4.2)$$

$$x_{ij} = \frac{-0,155 + 1,075x_{nij}}{0,6} \quad (4.3)$$

Como se dispõe do valor de saída desejado para cada condição operacional, utilizou-se, como algoritmo de aprendizagem, o *algoritmo supervisionado* e, como algoritmo de

treinamento, o de *Levenberg-Marquardt*, por apresentar, dentre todas as variações do algoritmo *backpropagation*, o menor tempo de treinamento.

As redes neurais são criadas a partir da técnica *treinar-e-testar*, que consiste em dividir o banco de dados em três grupos mutuamente exclusivos [51]:

- O *conjunto de treinamento* utilizado no ajuste dos pesos;
- O *conjunto de validação* utilizado como um pseudoteste para avaliar a capacidade de generalização da rede durante o processo de aprendizagem;
- O *conjunto de teste* usado exclusivamente para medir a taxa de erro do sistema e o seu valor corresponde a uma medida do desempenho real do sistema.

O banco de dados foi assim dividido em conjunto de treinamento, conjunto de validação e conjunto de teste, obedecendo as seguintes proporções:

- Conjunto de treinamento - 70% dos dados;
- Conjunto de validação - 20% dos dados;
- Conjunto de teste - 10% dos dados;

Ao longo do processo de treinamento, cada dado do conjunto de treinamento, um par entrada-saída, é apresentado à rede uma única vez por ciclo de treinamento. O número de épocas, ou seja, o número máximo de vezes em que todo o conjunto de treinamento é apresentado à rede foi fixado em 1000 épocas.

A fim de evitar um treinamento tendencioso da rede neural devido a uma má distribuição dos dados de cada conjunto, estes são previamente embaralhados.

#### 4.2.2 Processo de Treinamento e Escolha da Melhor Arquitetura

Todas as redes utilizadas neste trabalho possuem a arquitetura MLP, e são treinadas utilizando o *Matlab*<sup>®</sup> [20] tendo como método de aprendizagem o algoritmo de *Levenberg-Marquardt* [43]. Todas as redes criadas possuem três ou quatro camadas sendo, uma camada

de entrada, uma ou duas camadas ocultas e uma camada de saída. Os neurônios das camadas ocultas variam entre dois e oito e possuem como funções de ativação a tangente hiperbólica ou a sigmóide logística. Como os valores de saída são sempre positivos utilizou-se como função de ativação da camada de saída a sigmóide logística.

O treinamento termina se o número máximo de épocas for atingido, se o Erro Médio Quadrático - MSE ("*Mean Square Error*") do conjunto de treinamento for igual a zero ou se o critério de *Early Stop* for atingido, sendo esses dois últimos critérios explicados a seguir. O MSE é determinado através de

$$MSE = 100 \frac{y_{cmax} - y_{cmin}}{M \cdot N} \sum_{i=1}^N \sum_{j=1}^M (y_{cij} - y_{dij})^2 \quad (4.4)$$

em que,  $y_{cmax}$  e  $y_{cmin}$  são os valores de máximos e mínimos de saída,  $N$  é o número de neurônios da camada de saída,  $M$  é o número de padrões do conjunto de base considerado,  $y_{cij}$  e  $y_{dij}$  são a saída calculada e a saída desejada para cada neurônio, respectivamente.

O erro do conjunto de validação geralmente diminui durante a fase inicial do treinamento. Entretanto, quando a rede começa a decorar os dados de treinamento, o erro do conjunto de validação começa a aumentar. O critério de *Early Stop* tem o objetivo de aumentar a capacidade de generalização das redes, interrompendo o treinamento quando o erro do conjunto de validação aumenta durante um número específico de épocas.

#### **Número de Camadas Ocultas e de Neurônios em cada Camada**

Como foi mencionado no Capítulo 3 uma camada intermediária é suficiente para aproximar qualquer função contínua [34, 35] enquanto que duas camadas intermediárias são suficientes para aproximar qualquer função matemática [36].

Com relação ao número de neurônios nas camadas ocultas, este é definido empiricamente e depende de diversos fatores, como: números de exemplos de treinamento, complexidade da função a ser aprendida, quantidade de ruído presente nos exemplos.

Existem problemas que necessitam apenas de um neurônio na entrada e outro na saída, e outros que podem precisar de milhares de neurônios na camada intermediária. Dentre os

métodos mais utilizados para determinação do número de neurônios estão [31]:

- Adotar o número de neurônios em função do número de entradas e saídas. Deve ser observado, no entanto, que este método não pode ser utilizado de forma genérica;
- Utilizar um número de conexões dez vezes menor que o número de padrões de treinamento.

Uma limitação do número de conexões empregadas, reduz a incidência de *overfitting*, ou seja, evita que a rede memorize os padrões de treinamento, em vez de extrair as características que permitirão o seu poder de generalização. Por outro lado, pode ocorrer *underfitting*, ou seja, a rede não converge durante o seu treinamento e/ou apresenta uma baixa capacidade de generalização.

Desta forma, realizou-se diversas variações na estrutura da rede, como mostrado na Tabela 4.3.

**Tabela 4.3:** *Variações das arquiteturas das redes neurais artificiais*

<b>Nº de camadas ocultas</b>	<b>Nº de neurônios</b>	<b>Funções de ativação</b>
1	2 a 8	<i>tansig</i> e <i>logsig</i>
2	2 a 6	<i>tansig</i> – <i>tansig</i>
		<i>tansig</i> – <i>logsig</i>
		<i>logsig</i> – <i>logsig</i>

Para cada tipo de arquitetura, foram criadas vinte redes. O critério de desempenho adotado para escolha da melhor estrutura da rede (número de camadas ocultas, quantidade de neurônios e as funções de transferências de cada camada) é dado pela menor média aritmética do MSE do conjunto de validação, das vinte redes criadas, durante o treinamento. Realizando-se a escolha da arquitetura desta forma reduz-se a influência da inicialização dos pesos sobre o MSE do conjunto de treinamento.

### 4.2.3 Método de Validação Cruzada

O método de validação cruzada, também chamado *k-fold cross-validation*, consiste em dividir o banco de dados em  $k$  repartições aleatórias, mutuamente exclusivas, para treinar, validar e testar o sistema. Em cada iteração, uma partição diferente é utilizada para testar e as outras  $k - 1$  partições são utilizadas para validar e treinar. Neste trabalho, utiliza-se sempre  $k = 10$ .

Foram realizados dez experimentos, onde, para cada experimento, uma partição diferente é utilizada para testar o sistema e das outras nove, duas partições são escolhidas para formar o conjunto de validação e as demais para formar o conjunto de treinamento. Para cada experimento criaram-se vinte redes, das quais escolheu-se a rede de menor erro médio percentual - MAPE (4.5) no conjunto de teste.

$$MAPE = 100 \frac{1}{N} \sum_{i=1}^N \frac{|y_c - y_d|}{y_d} \quad (4.5)$$

onde  $N$  é o número de padrões do conjunto de base considerado,  $y_c$  e  $y_d$  são a saída calculada e a saída desejada para cada neurônio, respectivamente.

Na Tabela 4.4, são descritas as partições que formam cada conjunto, bem como identificadas as redes que utilizaram os respectivos conjuntos.

**Tabela 4.4:** Formação dos conjuntos de treinamento, validação e teste

Experimento	Rede	Conjuntos de Treinamento	Conjuntos de Validação	Conjuntos de Teste
1	1 a 20	4, 5, 6, 7, 8, 9, 10	2, 3	1
2	21 a 40	5, 6, 7, 8, 9, 10, 1	3, 4	2
3	41 a 60	6, 7, 8, 9, 10, 1, 2	4, 5	3
4	61 a 80	7, 8, 9, 10, 1, 2, 3	5, 6	4
5	81 a 100	8, 9, 10, 1, 2, 3, 4	6, 7	5
6	101 a 120	9, 10, 1, 2, 3, 4, 5	7, 8	6
7	121 a 140	10, 1, 2, 3, 4, 5, 6	8, 9	7
8	141 a 160	1, 2, 3, 4, 5, 6, 7	9, 10	8
9	161 a 180	2, 3, 4, 5, 6, 7, 8	10, 1	9
10	181 a 200	3, 4, 5, 6, 7, 8, 9	1, 2	10

### 4.3 Resultados do Treinamento das Redes

Nesta seção, são apresentadas as arquiteturas das 10 redes neurais obtidas seguindo o processo descrito anteriormente e o desempenho de cada rede dentro da sua respectiva faixa de atuação.

Tendo em vista que cada rede foi treinada através de pontos de um intervalo fechado, em nove situações têm-se duas redes atuando sobre o mesmo valor de conjugado. Desta forma, escolheu-se dentre as duas, a rede que resultasse na maior eficiência.

#### 4.3.1 Resultados do Treinamento da Rede 1

Na Tabela 4.5 é apresentada a arquitetura da *Rede 1*.

**Tabela 4.5:** *Arquitetura da Rede 1*

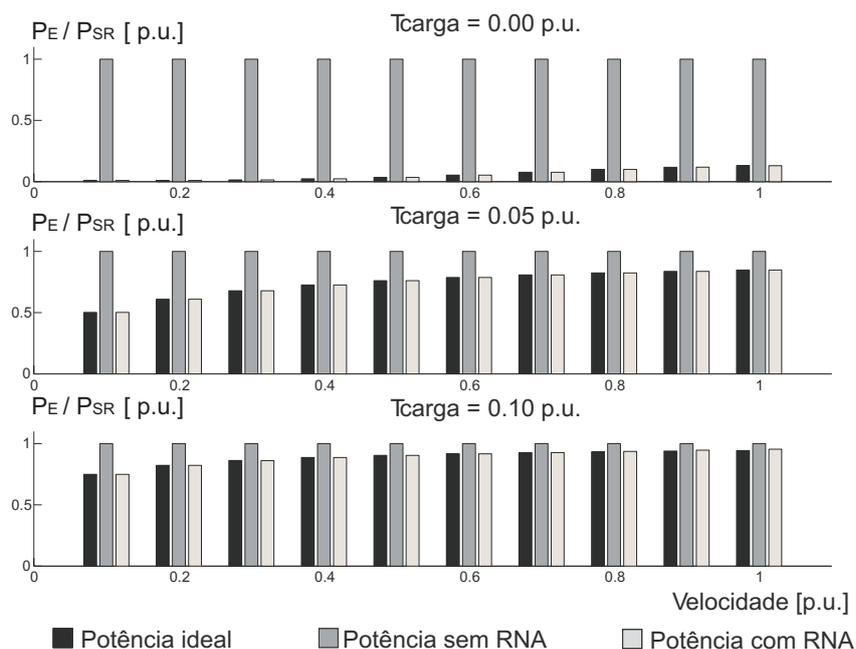
Número de neurônios	Distribuição dos neurônios	Distribuição das funções de transferências
9	2 – 3 – 3 – 1	<i>tansig – tansig – logsig</i>

Definida a arquitetura, escolheu-se a rede com menor MAPE através do método de validação cruzada. Na Tabela 4.6 é apresentado o resultado da *Rede 1*.

**Tabela 4.6:** *Resultado do treinamento da melhor rede - Ensaio 1*

Ensaio 1 - Tcarga = [0 a 0,1] p.u.					
Neurônios	Épocas	MSE % de Treinamento	MSE % de Validação	MSE % de Teste	MAPE de Teste
9	25	0,0051	0,0011	0,0056	2,0514

Na Fig. 4.2, são ilustradas as potências de entrada do MIT operando com o fluxo ideal (nível de fluxo correspondente a menor potência de entrada), o fluxo nominal e com a *Rede 1* atuando dentro de sua faixa de conjugado para diversas velocidades de referência.



**Figura 4.2:** Potências de entrada - Rede 1.

As potências de entrada e a eficiência obtida com a *Rede 1*, com a máquina operando em vazio, são mostradas na Tabela 4.7, em que  $P_{SR}$  corresponde a potência média de entrada em regime permanente do motor de indução utilizando o controle tradicional (sem RNA) com fluxo de referência fixado no valor nominal e  $P_{CR}$  corresponde a potência média de entrada em regime permanente do motor de indução utilizando o controle com RNA.

**Tabela 4.7:** Rede 1 - Conjugado de carga = 0 p.u.

$\omega_r^*[\text{rad.ele/s}]$	$P_{SR}[\text{W}]$	$P_{CR}[\text{W}]$	Redução de Potência %
34,0000	43,1349	0,4295	99,0043
68,0000	43,2257	0,3930	99,0908
102,0000	43,3769	0,6208	98,5688
136,0000	43,5887	1,0179	97,6648
170,0000	43,8612	1,5348	96,5008
204,0000	44,1945	2,3223	94,7453
238,0000	44,5888	3,3948	92,3864
272,0000	45,0441	4,4865	90,0398
306,0000	45,5607	5,3623	88,2304
340,0000	46,1389	5,9823	87,0342

### 4.3.2 Resultados do Treinamento da Rede 2

Nas Tabelas 4.8 e 4.9 são apresentados a arquitetura e o resultado do treinamento da *Rede2*, respectivamente.

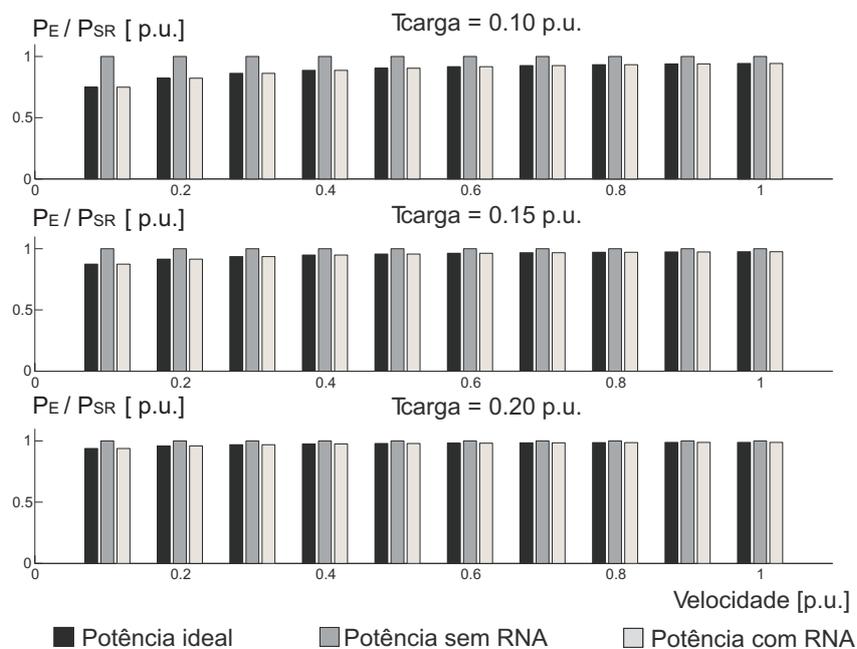
**Tabela 4.8:** Arquitetura da Rede 2

Número de neurônios	Distribuição dos neurônios	Distribuição das funções de transferências
9	2 – 4 – 2 – 1	<i>tansig</i> – <i>tansig</i> – <i>logsig</i>

**Tabela 4.9:** Resultado do treinamento da melhor rede - Ensaio 2

Ensaio 2 - Tcarga = [0,1 a 0,2] p.u.					
Neurônios	Épocas	MSE % de Treinamento	MSE % de Validação	MSE % de Teste	MAPE de Teste
9	72	0,0008	0,0056	0,0008	0,4018

Na Fig. 4.3, são ilustradas as potências de entrada do MIT operando com o fluxo ideal, o fluxo nominal e com a *Rede 2*.



**Figura 4.3:** Potências de entrada - Rede 2.

A eficiência obtida com a *Rede 2* para  $T_c = 0,1 p.u.$ , são mostrados na Tabela 4.10. Já na

Tabela 4.11 as mesmas grandezas são obtidas para  $T_c = 0,2 p.u.$

**Tabela 4.10:** Rede 2 - Conjugado de carga = 0,1 p.u.

$\omega_r$ *[rad.ele/s]	$P_{SR}$ [W]	$P_{CR}$ [W]	Redução de Potência %
34,0000	82,2933	61,6634	25,0687
68,0000	116,3899	95,7006	17,7759
102,0000	150,5475	129,7643	13,8051
136,0000	184,7663	163,8605	11,3147
170,0000	219,0464	198,0002	9,6081
204,0000	253,3878	232,1955	8,3636
238,0000	287,7907	266,4480	7,4160
272,0000	322,2552	300,7366	6,6775
306,0000	356,7817	335,0117	6,1018
340,0000	391,3701	369,1903	5,6672

**Tabela 4.11:** Rede 2 - Conjugado de carga = 0,2 p.u.

$\omega_r$ *[rad.ele/s]	$P_{SR}$ [W]	$P_{CR}$ [W]	Redução de Potência %
34,0000	131,7595	123,6937	6,1216
68,0000	199,8639	191,7541	4,0577
102,0000	268,0311	259,8660	3,0463
136,0000	336,2611	328,0248	2,4494
170,0000	404,5541	396,2378	2,0556
204,0000	472,9101	464,5324	1,7715
238,0000	541,3293	532,9605	1,5459
272,0000	609,8119	601,5426	1,3560
306,0000	678,3581	670,0713	1,2216
340,0000	746,9679	738,4022	1,1467

### 4.3.3 Resultados do Treinamento da Rede 3

A arquitetura da Rede 3 é apresentada na Tabela 4.12. Já na Tabela 4.13 é apresentado o resultado do treinamento da Rede 3.

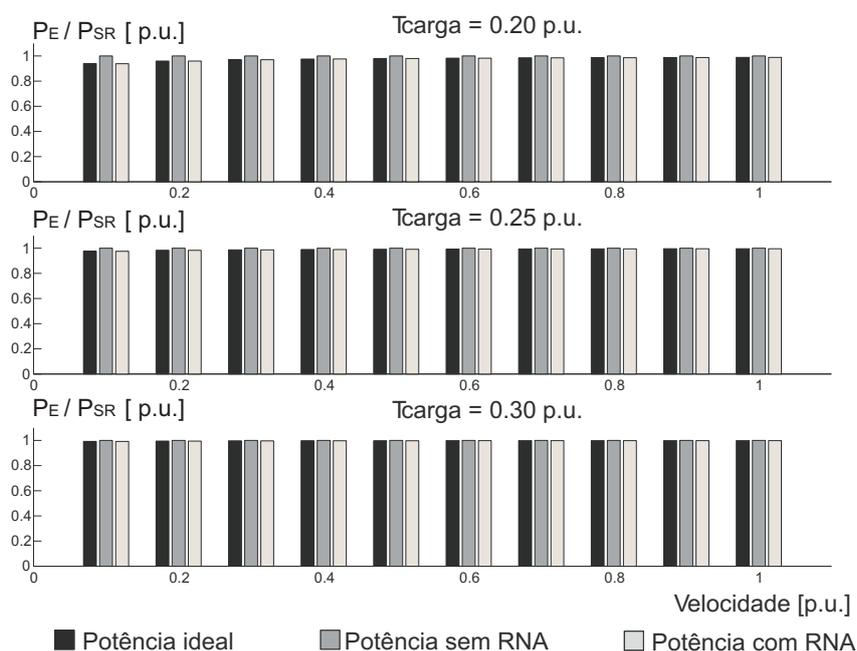
**Tabela 4.12:** Arquitetura da Rede 3

Número de neurônios	Distribuição dos neurônios	Distribuição das funções de transferências
9	2 – 4 – 2 – 1	<i>tansig – tansig – logsig</i>

**Tabela 4.13:** Resultado do treinamento da melhor rede - Ensaio 3

Ensaio 3 - Tcarga = [0,2 a 0,3] p.u.					
Neurônios	Épocas	MSE % de Treinamento	MSE % de Validação	MSE % de Teste	MAPE de Teste
9	84	0,0033	0,0080	0,0085	1,301

As potências de entrada do MIT operando com o fluxo ideal, o fluxo nominal e com a Rede 3 estão ilustrados na Fig. 4.4.

**Figura 4.4:** Potências de entrada - Rede 3.

A eficiência obtida com a Rede 3 para  $T_c = 0,3 p.u.$ , é mostrada na Tabela 4.14.

**Tabela 4.14:** Rede 3 - Conjugado de carga = 0,3 p.u.

$\omega_r$ *[rad.ele/s]	$P_{SR}$ [W]	$P_{CR}$ [W]	Redução de Potência %
34,0000	191,5363	189,9668	0,8194
68,0000	293,6508	292,0567	0,5429
102,0000	395,8309	394,3066	0,3851
136,0000	498,0767	496,6457	0,2873
170,0000	600,3883	599,0229	0,2274
204,0000	702,7658	701,4216	0,1913
238,0000	805,2092	803,8462	0,1693
272,0000	907,7189	906,3080	0,1554
306,0000	1010,2950	1008,8182	0,1462
340,0000	1112,9377	1111,3873	0,1393

#### 4.3.4 Resultados do Treinamento da Rede 4

Nas Tabelas 4.15 e 4.16 são apresentados a arquitetura e o resultado do treinamento da Rede 4, respectivamente.

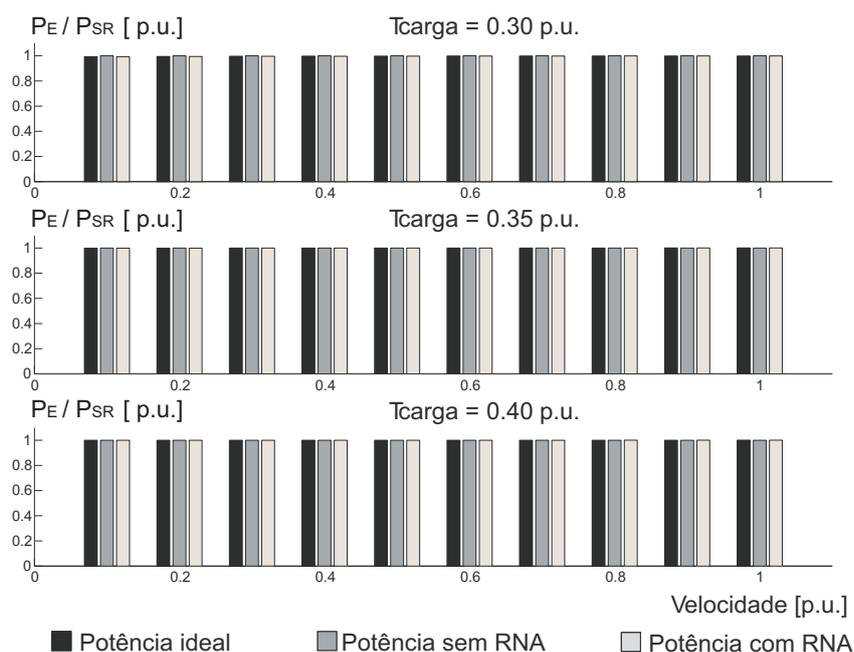
**Tabela 4.15:** Arquitetura da Rede 4

Número de neurônios	Distribuição dos neurônios	Distribuição das funções de transferências
10	2 – 3 – 4 – 1	<i>tansig</i> – <i>logsig</i> – <i>logsig</i>

**Tabela 4.16:** Resultado do treinamento da melhor rede - Ensaio 4

Ensaio 4 - Tcarga = [0,3 a 0,4] p.u.					
Neurônios	Épocas	MSE % de Treinamento	MSE % de Validação	MSE % de Teste	MAPE de Teste
10	63	0,0104	0,0105	0,0105	0,1739

Na Fig. 4.5, são ilustradas as potências de entrada do MIT operando com o fluxo ideal, o fluxo nominal e a Rede 4.



**Figura 4.5:** Potências de entrada - Rede 4.

#### 4.3.5 Resultados do Treinamento da Rede 5

A arquitetura da *Rede 5* é apresentada na Tabela 4.17. Já na Tabela 4.18 é apresentado o resultado do treinamento da *Rede 5*.

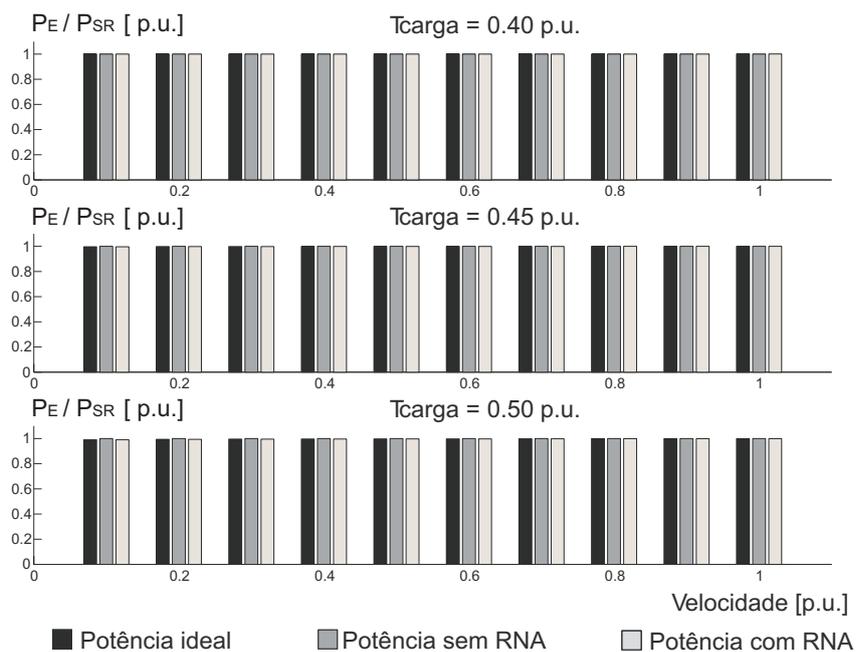
**Tabela 4.17:** Arquitetura da Rede 5

Número de neurônios	Distribuição dos neurônios	Distribuição das funções de transferências
10	2 – 1 – 6 – 1	<i>tansig</i> – <i>tansig</i> – <i>logsig</i>

**Tabela 4.18:** Resultado do treinamento da melhor rede - Ensaio 5

Ensaio 5 - Tcarga = [0,4 a 0,5] p.u.					
Neurônios	Épocas	MSE % de Treinamento	MSE % de Validação	MSE % de Teste	MAPE de Teste
10	64	0,000632	0,000191	0,000356	0,0179

As potências de entrada do MIT operando com o fluxo ideal, o fluxo nominal e com a *Rede 5* estão ilustradas na Fig. 4.6.



**Figura 4.6:** Potências de entrada - Rede 5.

Na Tabela 4.19 é mostrada a eficiência obtida com a Rede 5 para  $T_c = 0,4 p.u.$  Na Tabela 4.20 é descrito o desempenho da Rede 5 para  $T_c = 0,5 p.u.$

**Tabela 4.19:** Rede 5 - Conjugado de carga = 0,4 p.u.

$\omega_r$ * [rad.ele/s]	$P_{SR}$ [W]	$P_{CR}$ [W]	Redução de Potência %
34,0000	261,6282	261,6146	0,0051
68,0000	397,7554	397,7630	0,0019
102,0000	533,9521	533,9876	0,0066
136,0000	670,2185	670,2906	0,0108
170,0000	806,5546	806,6742	0,0148
204,0000	942,9606	943,1413	0,0192
238,0000	1079,4366	1079,6453	0,0239
272,0000	1215,9828	1216,3404	0,0294
306,0000	1352,5993	1353,0814	0,0356
340,0000	1489,2864	1489,9236	0,0428

**Tabela 4.20:** Rede 5 - Conjugado de carga = 0,5 p.u.

$\omega_r$ * [rad.ele/s]	$P_{SR}$ [W]	$P_{CR}$ [W]	Redução de Potência %
34,0000	342,0418	338,8528	0,9323
68,0000	512,1844	509,0077	0,6202
102,0000	682,4017	679,2459	0,4624
136,0000	852,6937	849,5670	0,3667
170,0000	1023,0607	1019,9712	0,3019
204,0000	1193,5026	1190,4565	0,2552
238,0000	1364,0196	1361,0267	0,2194
272,0000	1534,6119	1532,6169	0,1300
306,0000	1705,2797	1703,2722	0,1177
340,0000	1876,0232	1874,0704	0,1041

#### 4.3.6 Resultados do Treinamento da Rede 6

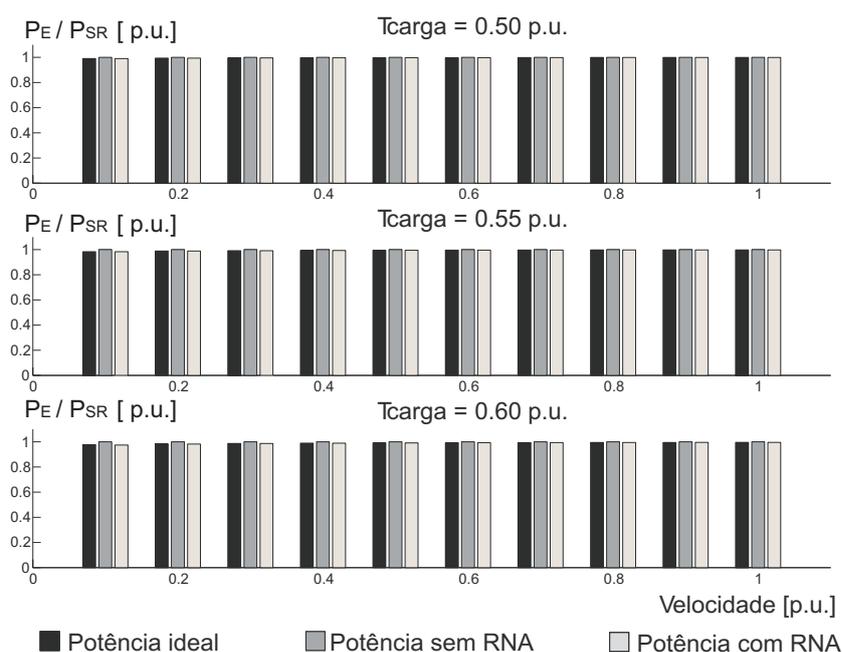
Nas Tabelas 4.21 e 4.22 são apresentados a arquitetura e o resultado do treinamento da Rede 6, respectivamente.

**Tabela 4.21:** Arquitetura da Rede 6

Número de neurônios	Distribuição dos neurônios	Distribuição das funções de transferências
8	2 – 3 – 2 – 1	<i>tansig – logsig – logsig</i>

**Tabela 4.22:** Resultado do treinamento da melhor rede - Ensaio 6

Ensaio 6 - Tcarga = [0,5 a 0,6] p.u.					
Neurônios	Épocas	MSE % de Treinamento	MSE % de Validação	MSE % de Teste	MAPE de Teste
8	83	0,0005	0,00010	0,0002	0,1399



**Figura 4.7:** Potências de entrada - Rede 6.

#### 4.3.7 Resultados do Treinamento da Rede 7

A arquitetura da *Rede 7* é apresentada na Tabela 4.23. Já na Tabela 4.24 é apresentado o resultado do treinamento da *Rede 7*.

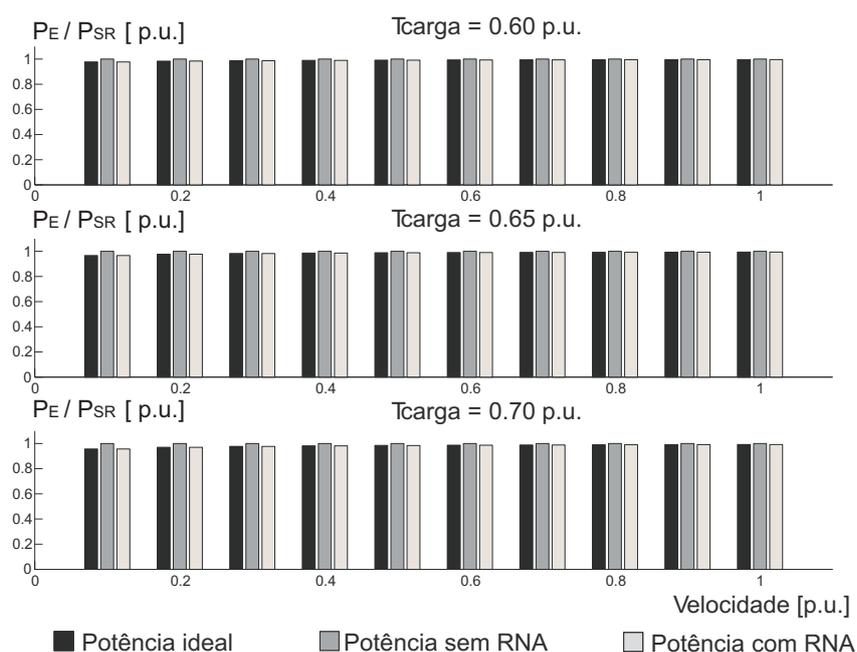
**Tabela 4.23:** Arquitetura da Rede 7

Número de neurônios	Distribuição dos neurônios	Distribuição das funções de transferências
10	2 – 2 – 5 – 1	<i>tansig – logsig – logsig</i>

**Tabela 4.24:** Resultado do treinamento da melhor rede - Ensaio 7

Ensaio 7 - Tcarga = [0,6 a 0,7] p.u.					
Neurônios	Épocas	MSE % de Treinamento	MSE % de Validação	MSE % de Teste	MAPE de Teste
10	21	0,000542	0,00545	0,00129	0,2138

Na Fig. 4.8, são ilustradas as potências de entrada do MIT operando com o fluxo ideal, o fluxo nominal e a *Rede 7*.



**Figura 4.8:** Potências de entrada - Rede 7.

A eficiência obtida com a Rede 7 para  $T_c = 0,6 p.u.$  é mostrada na Tabela 4.25. Já na Tabela 4.26 a mesma grandeza é obtida para  $T_c = 0,7 p.u.$

**Tabela 4.25:** Rede 7 - Conjugado de carga = 0,6 p.u.

$\omega_r$ [rad.ele/s]	$P_{SR}$ [W]	$P_{CR}$ [W]	Redução de Potência %
34,0000	432,7850	422,8041	2,3062
68,0000	636,9462	626,8098	1,5914
102,0000	841,1883	830,1874	1,3078
136,0000	1045,5115	1034,5826	1,0453
170,0000	1249,9158	1239,0590	0,8686
204,0000	1454,4012	1443,6353	0,7402
238,0000	1658,9681	1648,3131	0,6422
272,0000	1863,6165	1853,0909	0,5648
306,0000	2068,3466	2057,9687	0,5017
340,0000	2273,1587	2262,9461	0,4493

**Tabela 4.26:** Rede 7 - Conjugado de carga = 0,7 p.u.

$\omega_r$ * [rad.ele/s]	$P_{SR}$ [W]	$P_{CR}$ [W]	Redução de Potência %
34,0000	533,8684	510,6821	4,3431
68,0000	772,0516	748,8981	2,9989
102,0000	1010,3231	987,2246	2,2862
136,0000	1248,6829	1225,6617	1,8436
170,0000	1487,1314	1464,0959	1,5489
204,0000	1725,6684	1702,8645	1,3215
238,0000	1964,2942	1942,4614	1,1115
272,0000	2203,0089	2181,3530	0,9830
306,0000	2441,8129	2420,2942	0,8813
340,0000	2680,7061	2659,3889	0,7952

#### 4.3.8 Resultados do Treinamento da Rede 8

Nas Tabelas 4.27 e 4.28 são apresentados a arquitetura e o resultado do treinamento da Rede 8, respectivamente.

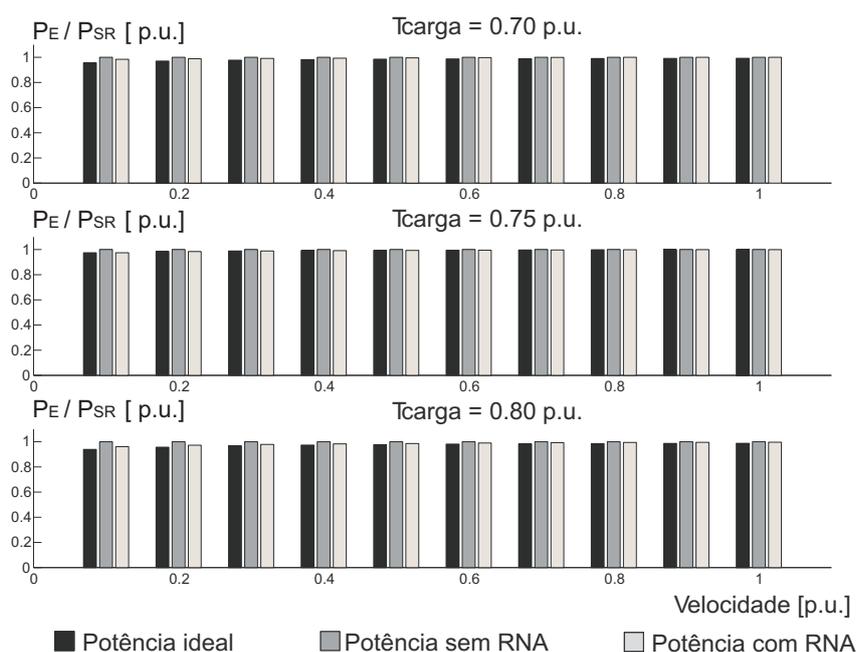
**Tabela 4.27:** Arquitetura da Rede 8

Número de neurônios	Distribuição dos neurônios	Distribuição das funções de transferências
8	2 – 3 – 2 – 1	<i>tansig – logsig – logsig</i>

**Tabela 4.28:** Resultado do treinamento da melhor rede - Ensaio 8

Ensaio 8 - Tcarga = [0,8 a 0,9] p.u.					
Neurônios	Épocas	MSE % de Treinamento	MSE % de Validação	MSE % de Teste	MAPE de Teste
8	37	0,5242	0,5272	0,5001	0,2674

Na Fig. 4.9, são ilustradas as potências de entrada do MIT operando com o fluxo ideal, o fluxo nominal e com a Rede 8.



**Figura 4.9:** Potências de entrada - Rede 8.

#### 4.3.9 Resultados do Treinamento da Rede 9

A arquitetura da *Rede 9* é apresentada na Tabela 4.29. Já na Tabela 4.30 é apresentado o resultado do treinamento da *Rede 9*.

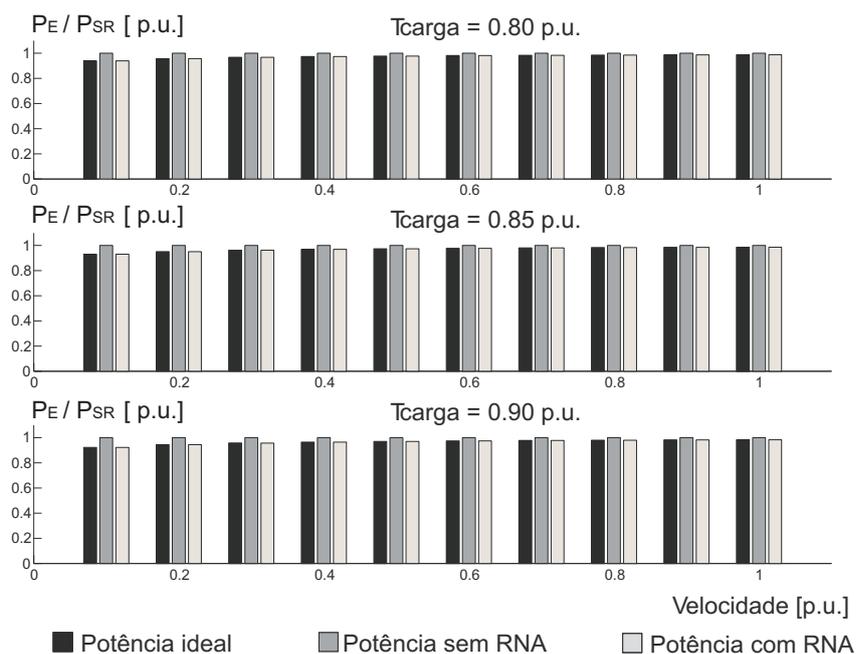
**Tabela 4.29:** Arquitetura da Rede 9

Número de neurônios	Distribuição dos neurônios	Distribuição das funções de transferências
11	2 - 4 - 4 - 1	<i>tansig - logsig - logsig</i>

**Tabela 4.30:** Resultado do treinamento da melhor rede - Ensaio 9

Ensaio 9 - Tcarga = [0,8 a 0,9] p.u.					
Neurônios	Épocas	MSE % de Treinamento	MSE % de Validação	MSE % de Teste	MAPE de Teste
9	61	0,1189	0,1175	0,1210	1,205

As potências de entrada do MIT operando com o fluxo ideal, o fluxo nominal e com a *Rede 9* estão ilustrados na Fig. 4.10.



**Figura 4.10:** Potências de entrada - Rede 9.

**Tabela 4.31:** Rede 9 - Conjugado de carga = 0,8 p.u.

$\omega_r$ [rad.ele/s]	$P_{SR}$ [W]	$P_{CR}$ [W]	Redução de Potência %
34,0000	645,3044	605,9120	6,1045
68,0000	917,5132	878,1609	4,2890
102,0000	1189,8189	1150,5343	3,3017
136,0000	1462,2215	1423,0325	2,6801
170,0000	1734,7212	1695,6556	2,2519
204,0000	2007,3180	1969,2519	1,8964
238,0000	2280,0122	2242,0784	1,6638
272,0000	2552,8039	2515,0233	1,4799
306,0000	2825,6932	2788,0871	1,3309
340,0000	3098,6805	3061,2701	1,2073

#### 4.3.10 Resultados do Treinamento da Rede 10

Nas Tabelas 4.32 e 4.33 são apresentados a arquitetura e o resultado do treinamento da Rede 10, respectivamente.

Tabela 4.32: Arquitetura da Rede 10

Número de neurônios	Distribuição dos neurônios	Distribuição das funções de transferências
9	2 – 3 – 3 – 1	<i>tansig – logsig – logsig</i>

Tabela 4.33: Resultado do treinamento da melhor rede - Ensaio 10

Ensaio 10 - Tcarga = [0,9 a 1,0] p.u.					
Neurônios	Épocas	MSE % de Treinamento	MSE % de Validação	MSE % de Teste	MAPE de Teste
8	53	0,1094	0,1100	0,0011	0,801

Na Fig. 4.11, são ilustradas as potências de entrada do MIT operando com o fluxo ideal, o fluxo nominal e com a Rede 10 atuando dentro de sua faixa de conjugado.

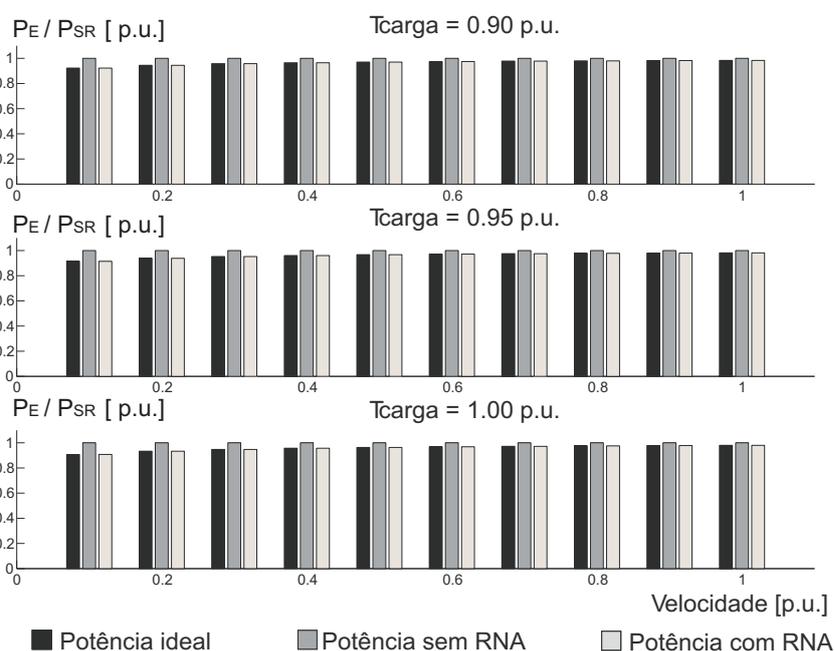


Figura 4.11: Potências de entrada - Rede 10.

A potência de entrada e a eficiência obtida com a Rede 10 para  $T_c = 0,9p.u.$ , são mostradas na Tabela 4.34. Já na Tabela 4.35 as mesmas grandezas são obtidas para  $T_c = 1,0p.u.$

**Tabela 4.34:** Rede 10 - Conjugado de carga = 0,9 p.u.

$\omega_r$ *[rad.ele/s]	$P_{SR}$ [W]	$P_{CR}$ [W]	Redução de Potência %
34,0000	767,1079	707,8745	7,7217
68,0000	1073,3463	1014,1473	5,5154
102,0000	1379,6913	1321,1939	4,2399
136,0000	1686,1429	1627,0898	3,5023
170,0000	1992,7013	1933,7600	2,9579
204,0000	2299,3666	2240,5632	2,5574
238,0000	2606,1388	2547,4995	2,2500
272,0000	2913,0182	2854,5692	2,0065
306,0000	3220,0051	3161,7727	1,8085
340,0000	3527,0996	3469,1104	1,6441

**Tabela 4.35:** Rede 10 - Conjugado de carga = 1 p.u.

$\omega_r$ *[rad.ele/s]	$P_{SR}$ [W]	$P_{CR}$ [W]	Redução de Potência %
34,0000	899,2966	815,6447	9,3019
68,0000	1239,5689	1155,9584	6,7451
102,0000	1579,9586	1496,4216	5,2873
136,0000	1920,4658	1837,0348	4,3443
170,0000	2261,0905	2177,7979	3,6837
204,0000	2601,8330	2518,7113	3,1947
238,0000	2942,6934	2859,7752	2,8178
272,0000	3283,6718	3202,9883	2,4571
306,0000	3624,7684	3544,2800	2,2205
340,0000	3965,9837	3885,7149	2,0239

Na Tabela 4.36 é apresentado um resumo das arquiteturas das 10 redes encontradas, com os respectivos intervalos de atuação.

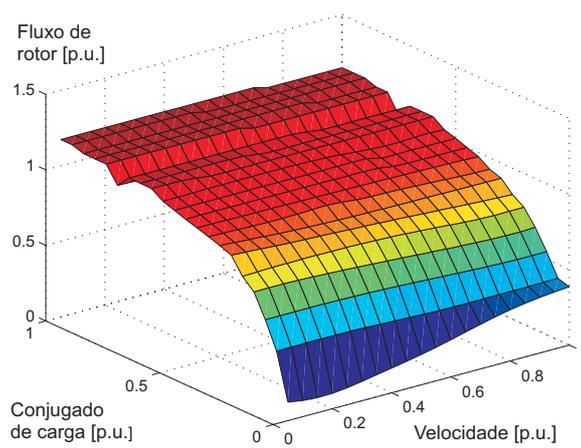
**Tabela 4.36:** *Resumo das arquiteturas das redes*

Rede	Intervalo de carga p.u.	Neurônios	Estrutura	Funções de Transferências
1	[0; 0, 1)	9	2 – 3 – 3 – 1	<i>tansig – tansig – logsig</i>
2	[0, 1; 0, 2]	9	2 – 4 – 2 – 1	<i>tansig – tansig – logsig</i>
3	(0, 2; 0, 3]	9	2 – 4 – 2 – 1	<i>tansig – tansig – logsig</i>
4	(0, 3; 0, 4)	10	2 – 3 – 4 – 1	<i>tansig – logsig – logsig</i>
5	[0, 4; 0, 5]	10	2 – 1 – 6 – 1	<i>tansig – tansig – logsig</i>
6	(0, 5; 0, 6)	8	2 – 3 – 2 – 1	<i>tansig – logsig – logsig</i>
7	[0, 6; 0, 7]	10	2 – 2 – 5 – 1	<i>tansig – logsig – logsig</i>
8	(0, 7; 0, 8)	8	2 – 3 – 2 – 1	<i>tansig – logsig – logsig</i>
9	[0, 8; 0, 9)	11	2 – 4 – 4 – 1	<i>tansig – logsig – logsig</i>
10	[0, 9; 1, 0]	9	2 – 3 – 3 – 1	<i>tansig – logsig – logsig</i>

Ao longo das Figs. 4.2-4.11, observa-se três fases distintas:

1. Com carga leve (0 a 30 % da carga nominal), é possível reduzir o nível de fluxo abaixo de seu valor nominal e conseguir reduções significativas na potência de entrada;
2. Quando o motor aciona cargas de 40 a 50 % da carga nominal, o fluxo necessário, é próximo do valor nominal e não há redução de potência;
3. Para os outros valores de carga, por ter considerado o efeito saturação magnética, eleva-se o fluxo de referência acima do seu valor nominal. Desta forma, consegue-se um pequeno aumento da eficiência do motor.

A superfície gerada a partir da representação do problema de redução das perdas no MIT, sob a visão das redes neurais está ilustrada na Fig. 4.12.



**Figura 4.12:** Superfície gerada através das redes neurais.

# 5

## SIMULAÇÕES E RESULTADOS EXPERIMENTAIS

Este capítulo apresenta as simulações realizadas e os resultados experimentais da estrutura do controle vetorial do motor de indução com inclusão das redes neurais obtidas no Capítulo 4. Os seguintes testes são aplicados ao motor de indução:

- Partida e variação de velocidade, com o motor operando em vazio;
- Partida e variação de carga;
- Aplicação e retirada de carga.

Com base nos resultados obtidos, será realizada uma análise qualitativa dos efeitos do uso da rede neural que define o valor do fluxo de referência sobre o desempenho do controle do motor de indução, avaliando as dinâmicas de velocidade, fluxo, conjugado, correntes, como também sobre a redução do consumo de energia elétrica em comparação com o controle convencional, operando com fluxo de rotor de referência fixado em  $0,425Wb$  (valor nominal).

## 5.1 Descrição dos Testes

### 5.1.1 Partida e Variação de Velocidade, com o Motor Operando em Vazio

Neste teste, foi realizada a partida no motor de indução através de um degrau de 0,1 p.u. (34 rad.ele/s) de velocidade. Após atingido o regime permanente, as redes neurais foram inseridas e a velocidade de referência foi incrementada em degraus de 0,1 p.u. até atingir o valor de 340 rad.ele/s. Este ensaio foi realizado tanto em simulação quanto experimentalmente.

### 5.1.2 Partida e Variação de Carga

O teste de partida e variação de carga, foi realizado após a máquina atingir o regime permanente ( $\omega_r * 170$  rad.mec/s), operando em vazio. Após as redes neurais serem inseridas, a carga de 0,1 p.u. (2 Nm) foi aplicada. Em seguida os valores de carga foram crescendo em degraus 0,1 p.u. até a máquina ficar submetida a carga nominal (20 Nm). Em seguida, a máquina retorna a condição em vazio. Tendo em vista a dificuldade de implementação experimental deste teste, face às limitações de hardware, bem como para a aplicação de valores de carga mecânica tão variados, apenas resultados de simulação foram obtidos.

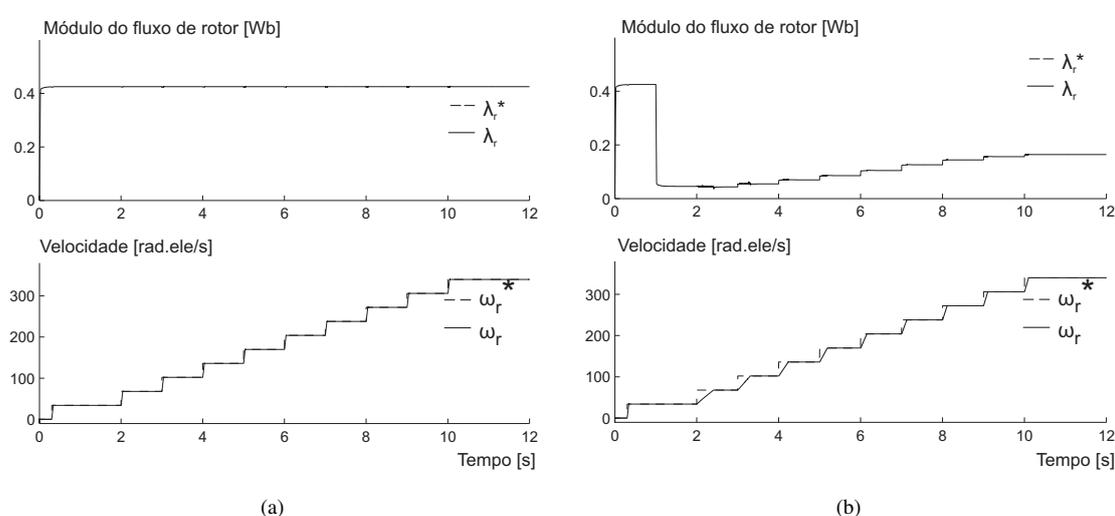
### 5.1.3 Partida e Aplicação de Carga

A fim de verificar experimentalmente o desempenho do sistema proposto quando da variação de conjugado mecânico, o presente ensaio foi realizado em laboratório. Após a máquina atingir o regime permanente, operando em vazio, um degrau de carga foi aplicado e retirado em intervalos de 3s, aproximadamente.

## 5.2 Resultados de Simulação

### 5.2.1 Partida e Variação de Velocidade

Nas Figs 5.1 a 5.4 são mostradas as respostas de velocidade, conjugado, fluxo e correntes para o teste de partida e variação de velocidade. Observa-se que os controles responderam conforme o esperado, ou seja, as grandezas seguem os valores de referências sem discrepâncias apreciáveis.

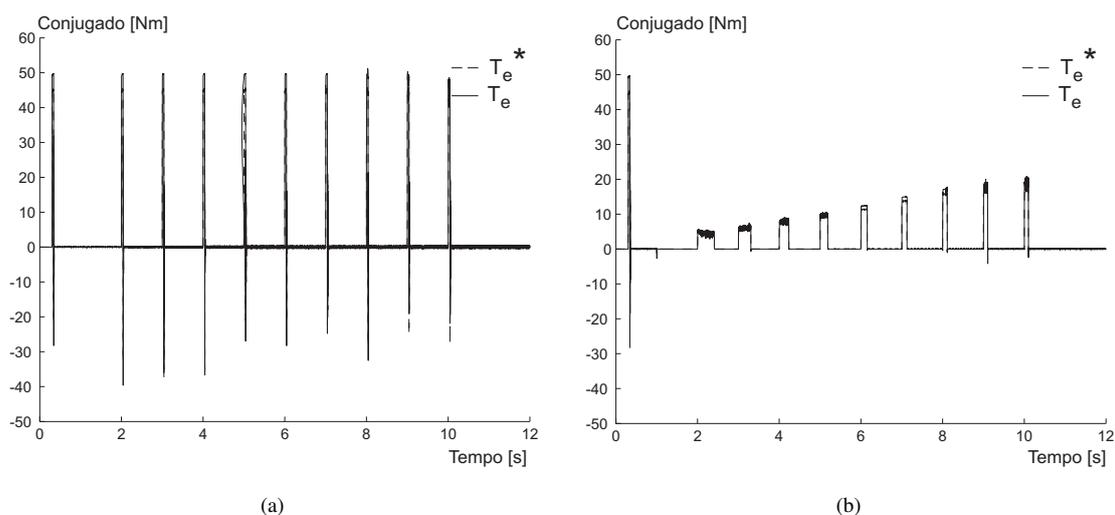


**Figura 5.1:** Resultados de simulação. Variação de velocidade. Máquina em vazio. Evolução do fluxo e da velocidade: (a) sem rede neural; (b) com rede neural.

Na Fig. 5.1 verifica-se que a rede neural impõe um valor de fluxo baixo já que o motor está em vazio, como pode ser observado pelo gráfico do fluxo. O fluxo estimado acompanha o valor de referência sem oscilações consideráveis, mesmo quando da variação de conjugado, indicando um bom desacoplamento entre as malhas de fluxo e conjugado.

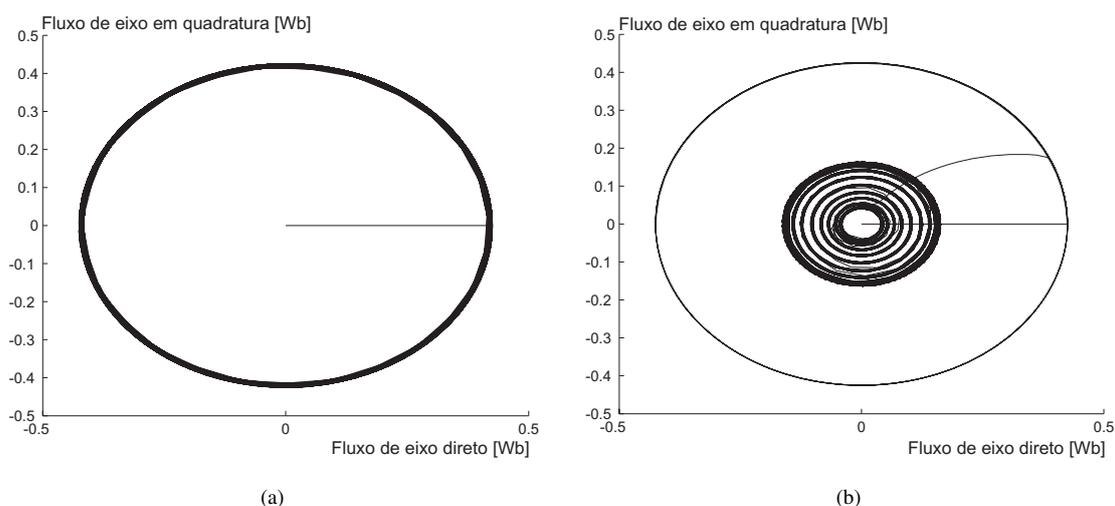
Observa-se que o controle com a rede neural, Fig. 5.1(b), com um fluxo mais baixo, a capacidade de produção de conjugado diminui e como consequência a velocidade sobe mais devagar como ilustrado no gráfico de velocidade.

Conclui-se então que o controle com a rede neural que deve reduzir o consumo de energia elétrica não causa redução considerável na qualidade de um sistema de acionamento que tenha como objetivo principal a realização do controle da velocidade ou da posição.



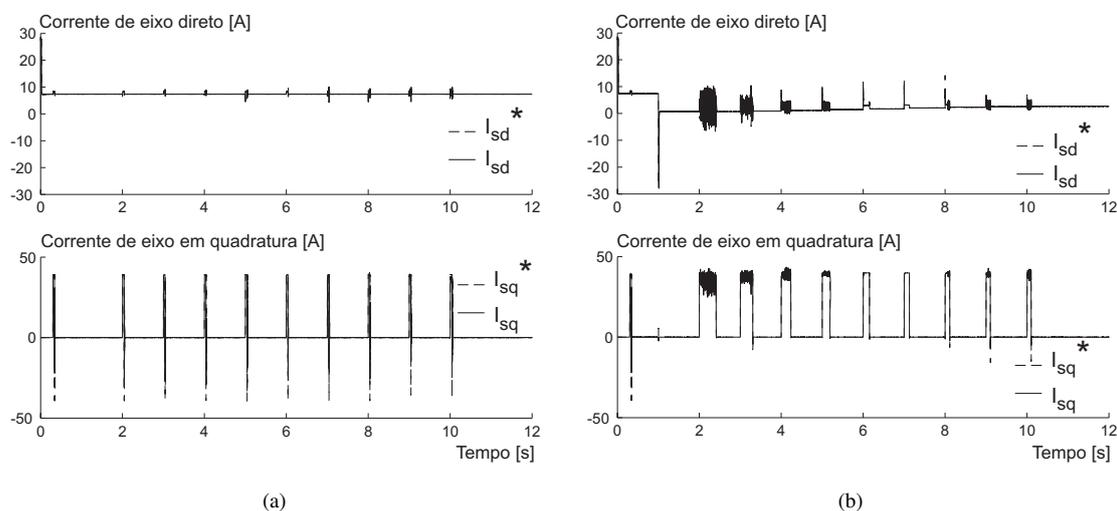
**Figura 5.2:** Resultados de simulação. Variação de velocidade. Máquina em vazio. Evolução do conjugado: (a) sem rede neural; (b) com rede neural.

Na Fig. 5.2 é ilustrado o comportamento do conjugado durante o transitório de variação de velocidade. Como o fluxo de referência imposto pela rede é baixo, a capacidade de produção de conjugado diminui e, mesmo com a corrente de eixo em quadratura no valor de saturação, o conjugado não atinge o mesmo valor que atingiria quando do controle sem a RNA. Com isso, a resposta de conjugado do controle com rede neural que deveria ser muito rápida, como pode ser visto no controle sem rede Fig. 5.2(a), é mais lenta e melhora a medida que o fluxo de referência aumenta como observado na Fig. 5.2(b).



**Figura 5.3:** Resultados de simulação. Variação de velocidade. Máquina em vazio. Trajetória do vetor fluxo de rotor: (a) sem rede neural; (b) com rede neural.

Na Fig. 5.3(b) é possível observar as trajetórias circulares do vetor fluxo de rotor do controle com rede neural. Esse comportamento, demonstra o desacoplamento entre as malhas de fluxo e conjugado, comprovando o bom desempenho do controle.

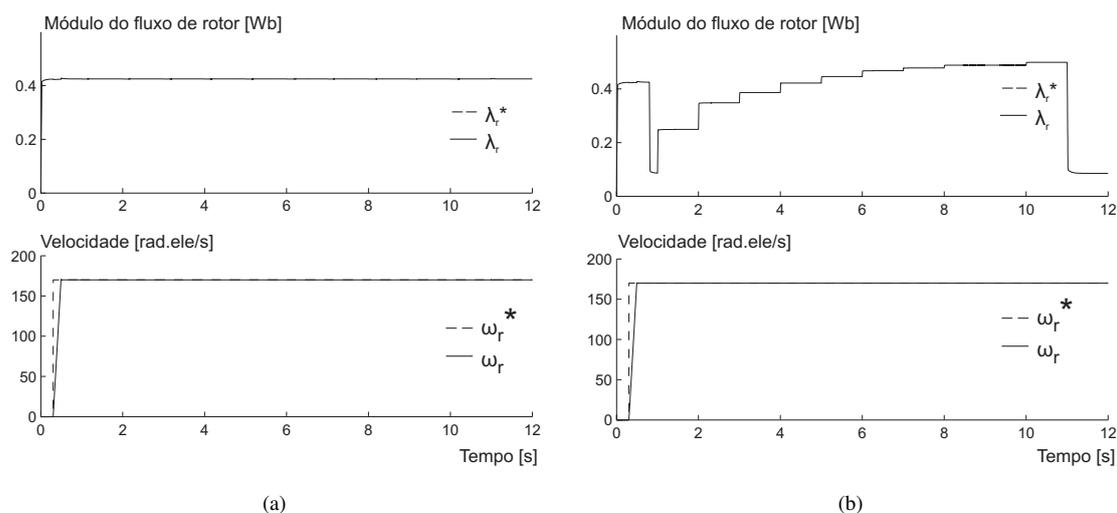


**Figura 5.4:** Resultados de simulação. Variação de velocidade. Máquina em vazio. Evolução das componentes de corrente de eixos direto e em quadratura: (a) sem rede neural; (b) com rede neural.

As correntes de eixo direto e em quadratura são ilustradas na Fig. 5.4. As perturbações de  $I_{sd}$  no controle com rede neural, Fig. 5.4(b), são maiores e mais longas devido a constante mudança no valor do fluxo de referência. Já os picos da corrente de eixo em quadratura são decorrentes dos picos de conjugado necessários para atender as variações da velocidade de referência. Estes valores ficam limitados no valor da saturação. A duração do pico de corrente está relacionado a amplitude do valor do conjugado cuja capacidade de produção está ligada ao nível de magnetização da máquina.

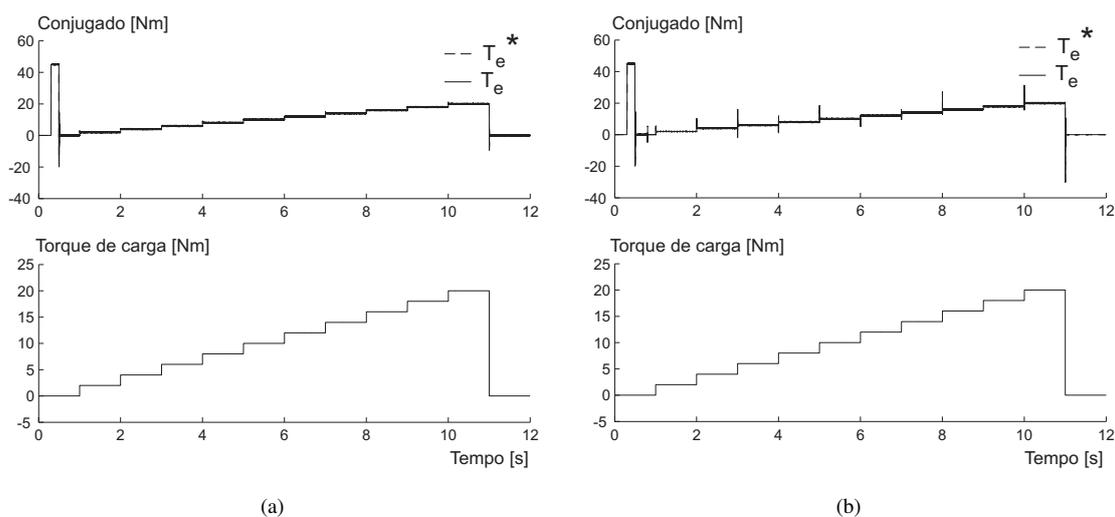
## 5.2.2 Partida e Variação de Carga

As respostas de velocidade, conjugado, fluxo e correntes para o teste de partida e variação de carga estão ilustradas nas Figs 5.5-5.8. Observa-se, assim como no teste de partida e variação de velocidade, que as grandezas seguem os valores de referência sem variações apreciáveis.



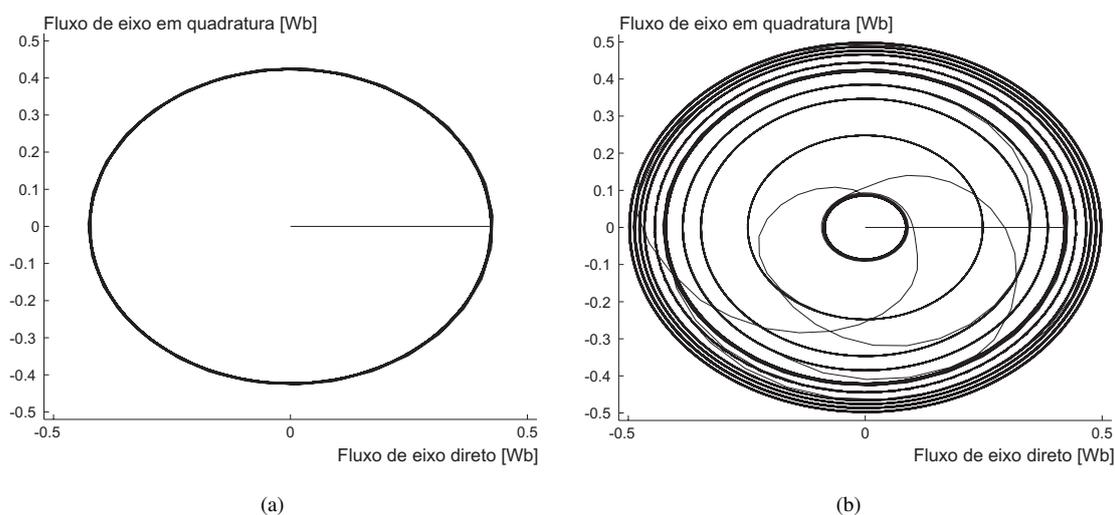
**Figura 5.5:** Resultados de simulação. Partida e aplicação de carga. Evolução do fluxo e da velocidade: (a) sem rede neural; (b) com rede neural.

Na Fig. 5.5 fica evidenciada uma forte dependência entre o conjugado de carga e o valor do fluxo de referência (ótimo para redução de perdas). As perdas estão relacionadas tanto com  $I_{sd}$  quanto com  $I_{sq}$ . Ao aumentar o valor de  $I_{sd}$  ocorre o aumento nas perdas  $R_s I_{sd}^2$  e também nas perdas no ferro, decorrentes do aumento do fluxo. Por outro lado, aumentando o fluxo, a componente de corrente  $I_{sq}$  necessária para vencer o conjugado de carga reduz-se e, portanto, reduz-se a componente de perdas devida a  $R_s I_{sq}^2$ . A função da rede neural é exatamente atuar na predição do fluxo para o qual as perdas são mínimas. Verifica-se, pelo gráfico do fluxo (Fig. 5.5(b)) que, em velocidade constante e para baixos valores de conjugado, os valores ótimos de fluxo são inferiores ao nominal. Esta situação inverte-se para valores de carga elevados, quando vale a pena a operação da máquina sob condição de saturação.



**Figura 5.6:** Resultados de simulação. Partida e aplicação de carga. Evolução do conjugado: (a) sem rede neural; (b) com rede neural.

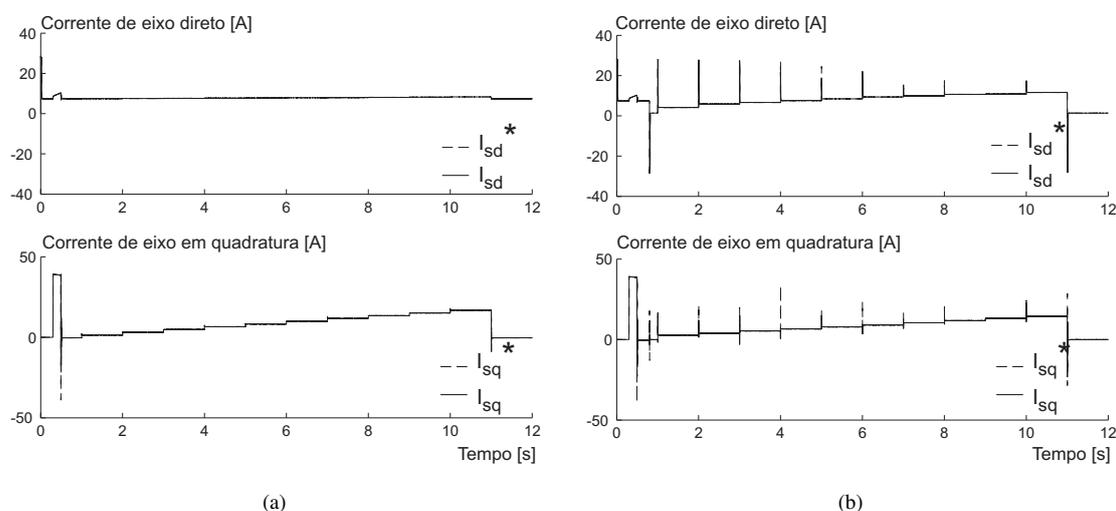
O comportamento do conjugado durante o transitório de partida e variação de carga está ilustrado na Fig. 5.6. Como o fluxo de referência imposto pela rede é mais elevado quando comparado àquele necessário a operar a máquina em vazio, a resposta de conjugado do controle com rede neural é semelhante ao controle convencional. Observa-se na Fig.5.6(b) que o conjugado estimado acompanha a referência.



**Figura 5.7:** Resultados de simulação. Partida e aplicação de carga. Trajetória do vetor fluxo de rotor:(a) sem rede neural; (b) com rede neural.

Na Figura 5.7 fica demonstrado o desacoplamento (ou quase) das malhas de fluxo e

conjugado, tendo em vista as trajetórias circulares desenvolvidas pelo vetor fluxo de rotor.



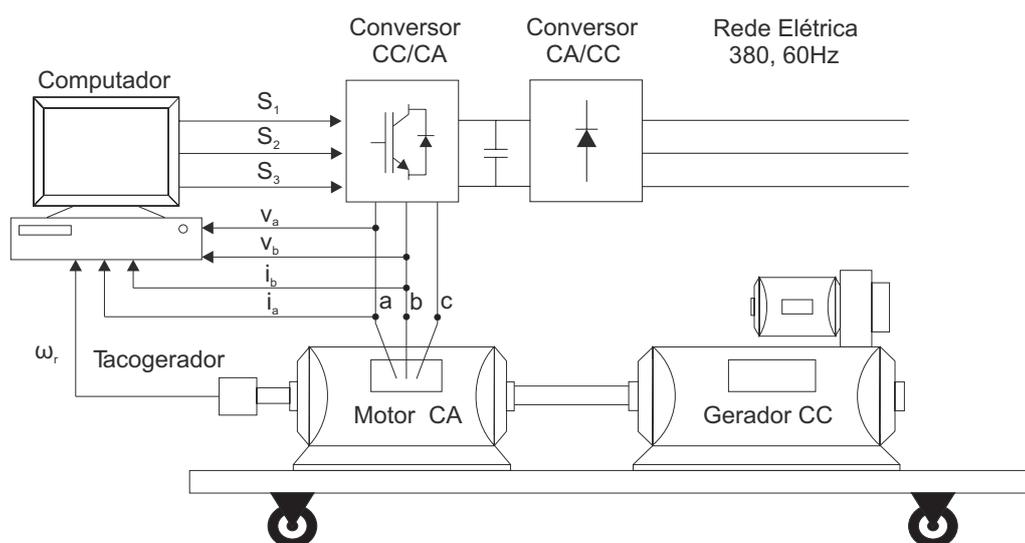
**Figura 5.8:** Resultados de simulação. Partida e aplicação de carga. Evolução das componentes de corrente de eixos direto e em quadratura: (a) sem rede neural; (b) com rede neural.

Na Fig. 5.8 estão ilustrados o comportamento das correntes de eixo direto e em quadratura. Os picos na corrente de eixo direto no controle com rede neural ocorrem, como mencionado anteriormente, devido a constante variação do fluxo de referência imposto pela rede neural.

### 5.3 Estrutura Básica do Sistema de Acionamento

O sistema de acionamento é mostrado na Fig. 5.9. Esse sistema é composto de cinco partes principais: um motor de indução a ser controlado, uma máquina de corrente contínua para impor conjugado de carga ao eixo do motor, um conversor de frequência, uma interface de aquisição de sinais e um microcomputador.

A máquina a ser controlada é um motor de indução com rotor tipo gaiola de esquilo. A carga é aplicada ao eixo do motor de indução por meio de uma máquina de corrente contínua de mesma potência acoplada mecanicamente ao seu eixo. A máquina de corrente contínua opera no modo gerador com campo fixo e os degraus de carga são simulados através da inserção de resistores em seu circuito de armadura. Dados de placa e parâmetros mecânicos e elétricos destas máquinas são descritos no apêndice. Esses mesmos dados foram empregados



**Figura 5.9:** Estrutura básica do sistema de acionamento.

para a realização das simulações apresentadas na seção anterior.

A alimentação do motor de indução é feita através de um conversor CA/CC/CA constituído de uma ponte trifásica de diodos, um banco de capacitores no elo CC o qual possibilita trabalhar com tensões de até 900V e uma ponte trifásica a IGBT's com correntes máximas de 50 A e frequência de chaveamento de 20 kHz.

Para executar os algoritmos de estimação do fluxo de rotor, do controle vetorial e de comando das chaves do conversor CA/CC/CA se faz necessário a aquisição em tempo real das variáveis do sistema de acionamento. Para isso, utiliza-se circuitos de medição e condicionamento de sinais que estão associados a uma interface de aquisições de sinais (AD-DA) da marca *Advantech* modelo *PCL818* que realiza a comunicação com um computador. Os sinais medidos são as tensões da *fase a*, da *fase b* e do barramento CC; as correntes das *fases a* e *b* obtidas através de sensores de efeito hall e a velocidade do eixo do rotor através de um tacogerador.

O microcomputador é um Pentium-S 133 MHz com 16 MB de RAM equipado com uma interface de aquisição de sinais (AD-DA) e uma interface de geração de sinais PWM conectadas através do barramento ISA. O computador interpreta a leitura dos sinais medidos, executa o algoritmo de controle e envia os sinais de comando das chaves do conversor.

O software de controle é implementado através da linguagem C. O algoritmo de controle

é acionado através de interrupções, a intervalos de amostragem de  $250 \mu\text{s}$ . A frequência de chaveamento do algoritmo de PWM regular trifásico [30] é de 20 kHz.

## 5.4 Resultados Experimentais

Devido à imprecisão no processo de estimação dos parâmetros do conjunto motor de indução-máquina CC utilizando o conversor CA/CC/CA, a estimação de fluxo e conseqüentemente a de conjugado não obtiveram a exatidão necessária para a criação de um banco de dados reais confiável para o treinamento das redes a serem utilizadas no experimento.

Diante das limitações encontradas, optou-se por utilizar no experimento, o conjunto de redes encontradas com os dados de simulação, para as quais foram empregados os valores dos parâmetros reais, e desta forma validar a técnica estudada.

Como o objetivo deste trabalho é o aumento da eficiência do motor ao longo de sua faixa operacional não foi realizado um ajuste minucioso dos ganhos dos controladores, o que compromete um pouco a dinâmica do controle.

Os ganhos utilizados nos controladores PI, Tabela 5.1, foram determinados com base nas condições de projeto e posteriormente ajustados na prática. Saturações foram impostas tanto aos controladores, quanto a saída de cada rede, de modo que, a fim de garantir a operação segura do sistema, não fossem atingidos os valores máximos suportáveis indicados pelos fabricantes dos diversos componentes.

**Tabela 5.1:** *Ganhos experimentais dos controladores PI*

Malha	Kp	Ki
de fluxo	200	10000
de velocidade	1	2
de corrente	15	20000

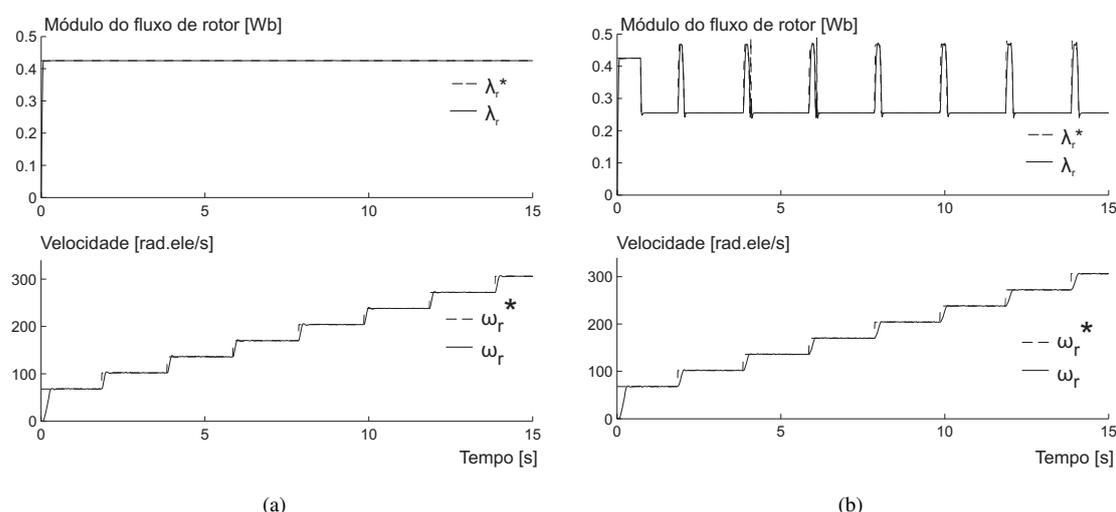
Os valores de saturação dos controladores utilizados foram:

- Corrente máxima de estator : 15 A de pico;

- Corrente máxima de eixo direto : 12 A de pico;
- Tensão máxima de estator : 311 V de pico;
- Tensão máxima de eixo direto : 100 V de pico;
- Conjugado eletromagnético máximo: 15 Nm.

#### 5.4.1 Partida e Variação de Velocidade

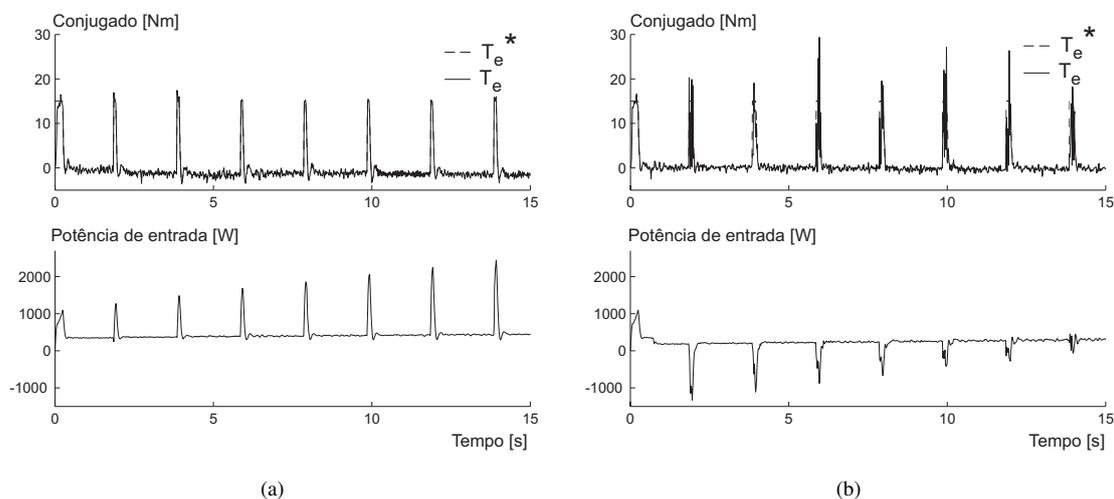
Nas Figs. 5.10 a 5.12 são mostrados as respostas experimentais de velocidade, conjugado, fluxo e correntes para o teste de partida e variação de velocidade.



**Figura 5.10:** Resultados experimentais. Aplicação e variação de velocidade. Máquina em vazio. Evolução do fluxo e da velocidade: (a) sem rede neural; (b) com rede neural.

Na Fig. 5.10(b), verifica-se, assim como nas simulações, que a rede neural impõe um valor de fluxo abaixo do valor nominal já que o motor está em vazio. Observa-se a ocorrência de picos no momento dos transitórios de velocidade. Isto ocorre, devido a variação do conjugado eletromagnético, necessário para impor a velocidade de referência. A velocidade medida, acompanha o valor de referência sem oscilações perceptíveis. Além do mais, verifica-se que o fluxo estimado acompanha o valor de referência sem oscilações consideráveis, mesmo durante a variação de conjugado, indicando um bom desacoplamento entre as malhas de fluxo e conjugado.

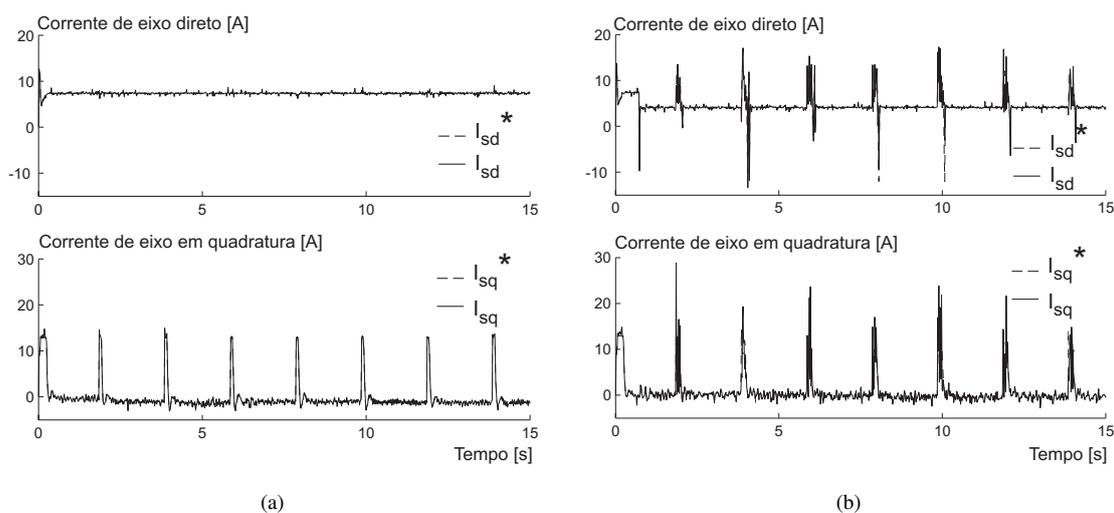
A resposta de velocidade, assim como nas simulações, também é um pouco mais lenta devido a redução da capacidade de produção de conjugado como pode ser observado no gráfico de velocidade da Fig. 5.10(b).



**Figura 5.11:** Resultados experimentais. Aplicação e variação de velocidade. Máquina em vazio. Evolução do conjugado e da potência de entrada: (a) sem rede neural; (b) com rede neural.

Na Fig. 5.11, o comportamento do conjugado eletromagnético é semelhante àqueles verificados em simulação. Além disso, é visível a redução da potência de entrada tanto nos transitórios como em regime permanente do controle com rede neural, Fig. 5.11(b), frente ao controle convencional ilustrado na Fig. 5.11(a).

O comportamento das componentes de corrente de eixos direto e em quadratura é mostrado na Fig. 5.12. Há uma redução da corrente de eixo direto decorrente da diminuição do fluxo de referência do rotor, e a existência de picos são decorrentes da variação do fluxo durante o transitório de velocidade.



**Figura 5.12:** Resultados experimentais. Aplicação e variação de velocidade. Máquina em vazio. Evolução das componentes de corrente de eixos direto e em quadratura: (a) sem rede neural; (b) com rede neural.

A potência de entrada do controle sem rede neural ( $P_{SR}$ ) e com rede neural ( $P_{CR}$ ), para cada velocidade de referência, e a redução percentual de potência de entrada obtida estão descritos na Tabela 5.2.

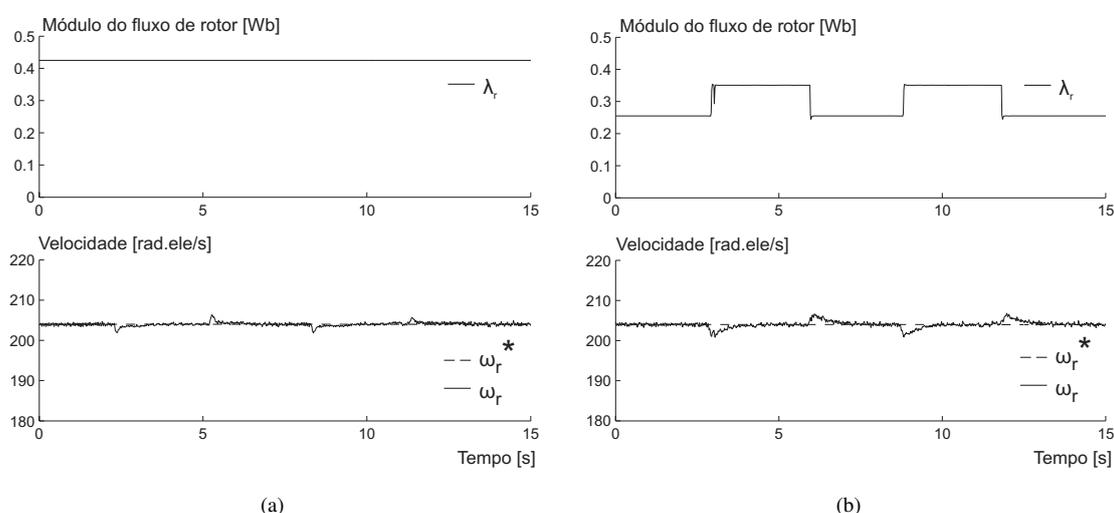
**Tabela 5.2:** Potências de entradas experimentais da máquina operando em vazio

$\omega_r$ [rad.ele/s]	$P_{SR}$ [W]	$P_{CR}$ [W]	Redução de Potência %
34,0000	335,0130	124,2832	<b>62,9020</b>
68,0000	354,7379	156,0212	<b>56,0179</b>
102,0000	372,4988	178,1349	<b>52,1784</b>
136,0000	375,9838	188,0748	<b>49,9780</b>
170,0000	392,9030	204,9831	<b>47,8286</b>
204,0000	402,7912	214,4312	<b>46,7637</b>
238,0000	409,3746	235,7592	<b>42,4099</b>
272,0000	414,2416	259,9184	<b>37,2544</b>
306,0000	419,1219	285,9092	<b>31,7838</b>
340,0000	423,3273	318,5470	<b>24,7516</b>

Na Tabela 5.2 fica evidenciado a redução significativa do consumo de energia ao longo de toda a faixa de velocidade quando o motor está em vazio. Desta forma além do bom desempenho do controle com rede neural o objetivo de reduzir as perdas é alcançado .

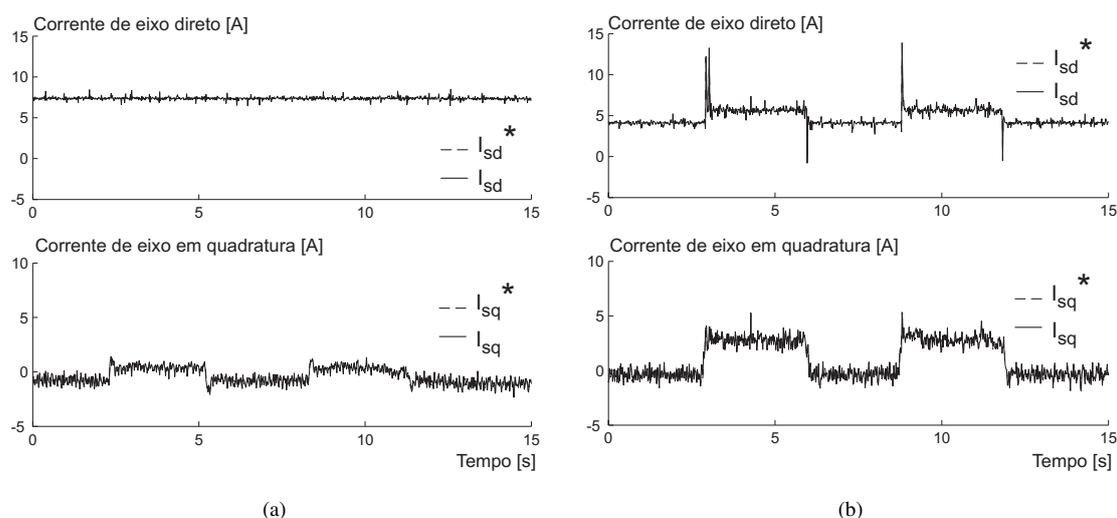
### 5.4.2 Partida e Aplicação de Carga

As respostas de velocidade, conjugado, fluxo e correntes para o teste de partida e retirada de carga para a máquina operando com  $\omega_{r,*} = 204 \text{ rad.ele/s}$  estão ilustrados nas Figs 5.13-5.15. Observa-se, maiores oscilações na velocidade do controle com rede neural, 5.13(b). Isso é justificado devido à necessidade de elevar o fluxo de referência. Como priorizou-se à malha de fluxo frente a de de conjugado, um maior tempo é necessário para que a velocidade volte ao seu valor de referência.



**Figura 5.13:** Resultados experimentais. Aplicação e retirada de carga. Evolução do fluxo e da velocidade.  $\omega_{r,*} = 204 \text{ rad.ele/s}$ : (a) sem rede neural; (b) com rede neural.

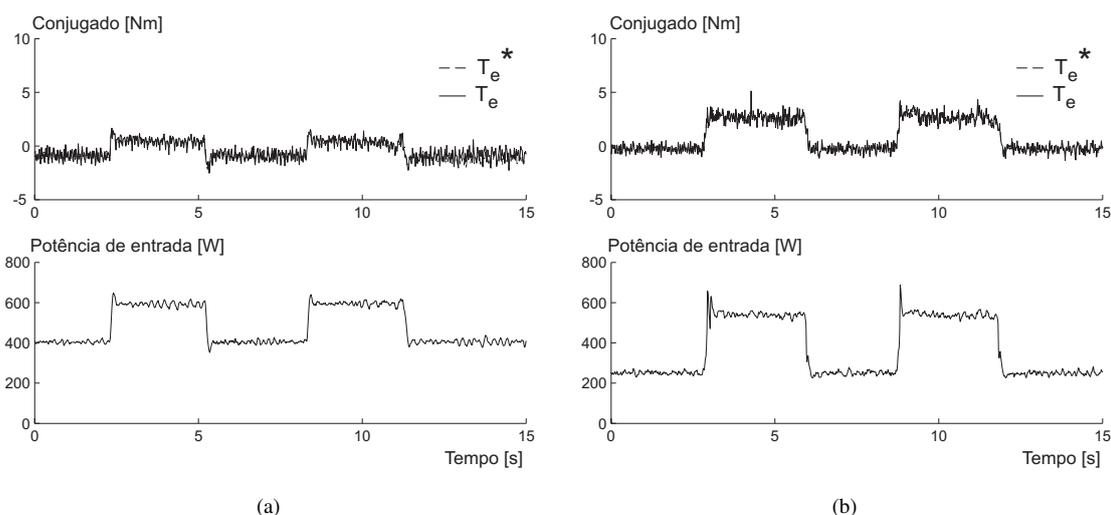
O comportamento das correntes de eixos direto e em quadratura está ilustrado na Fig.5.14. A corrente  $I_{sd}$  do controle com rede neural é menor quando comparada ao controle convencional durante o período de regime. Nos momentos transitórios percebe-se a ocorrência de picos devidos a variação do fluxo de referência. A corrente de eixo em quadratura possui valores diferentes devido a má estimação do conjugado eletromagnético.



**Figura 5.14:** Resultados experimentais. Aplicação e retirada de carga. Evolução das componentes de corrente de eixos direto e em quadratura.  $\omega_r^* = 204 \text{ rad.ele/s}$ : (a) sem rede neural; (b) com rede neural.

Na Fig. 5.15, verifica-se que para a mesma condição de carga aplicada no eixo, os conjugados estimados possuem valores ligeiramente diferentes. Isto ocorre devido a imprecisão dos parâmetros, que causa diferentes erros de fluxo e conjugado estimados para diferentes pontos de operação. No entanto, vale salientar que as potências de entrada foram calculadas diretamente das tensões e correntes de entrada adquiridas, de modo que as reduções de potência observadas não sofrem influência da exatidão com que os parâmetros mecânicos e elétricos do motor são conhecidos.

Nota-se ainda que a redução da potência proporcionada pelo controle com rede neural para a operação sob carga é menor, tendo em vista que, nessa situação, o fluxo ótimo, determinado pela rede neural, é mais próximo do fluxo nominal.



**Figura 5.15:** Resultados experimentais. Aplicação e retirada de carga. Evolução do conjugado e da potência de entrada.  $\omega_r^* = 204 \text{ rad.ele/s}$ : (a) sem rede neural; (b) com rede neural.

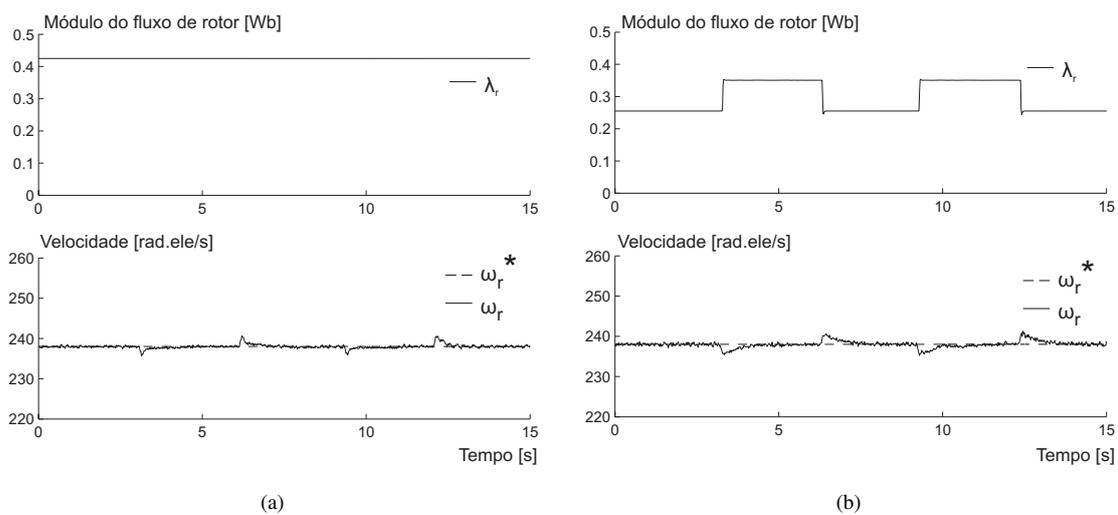
Na Tabela 5.3 estão descritas as potências de entrada para diferentes cargas e a redução no consumo de energia obtido para o motor de indução operando a  $\omega_r^* = 204 \text{ rad.ele/s}$  é evidenciado. Observa-se que quanto maior a carga aplicada, menor é a redução do consumo de energia, tendo em vista que os valores de fluxos ideais aproximam-se do valor do fluxo nominal e o consumo torna-se equivalente ao controle convencional. Em alguns casos, o valor do fluxo de referência fornecido pela rede é maior ou menor que o fluxo ideal, o que é passível de acontecer tendo em vista que o banco de dados utilizados no treinamento na abrange todas as condições operacionais passíveis de acontecer. Nestes casos, o consumo de energia pode ser maior ou menor quando comparado ao do controle convencional.

**Tabela 5.3:** Resultados Experimentais:  $\omega_{r,*} = 204 \text{ rad.ele/s}$ 

$\omega_{r,*}[\text{rad.ele/s}]$	$P_{SR}[\text{W}]$	$P_{CR}[\text{W}]$	Redução de Potência %
204,0000	424,9494	275,0927	<b>35,2646</b>
	440,1128	296,4376	<b>32,6451</b>
	443,7930	302,4744	<b>31,8434</b>
	464,8745	338,9893	<b>27,0794</b>
	505,7869	413,6033	<b>18,2258</b>
	603,4409	566,4078	<b>6,1370</b>
	621,3478	602,9537	<b>2,9604</b>
	644,3315	638,8945	<b>0,8438</b>
	691,3230	705,1184	-1,9955
	820,0768	860,1025	-4,8807

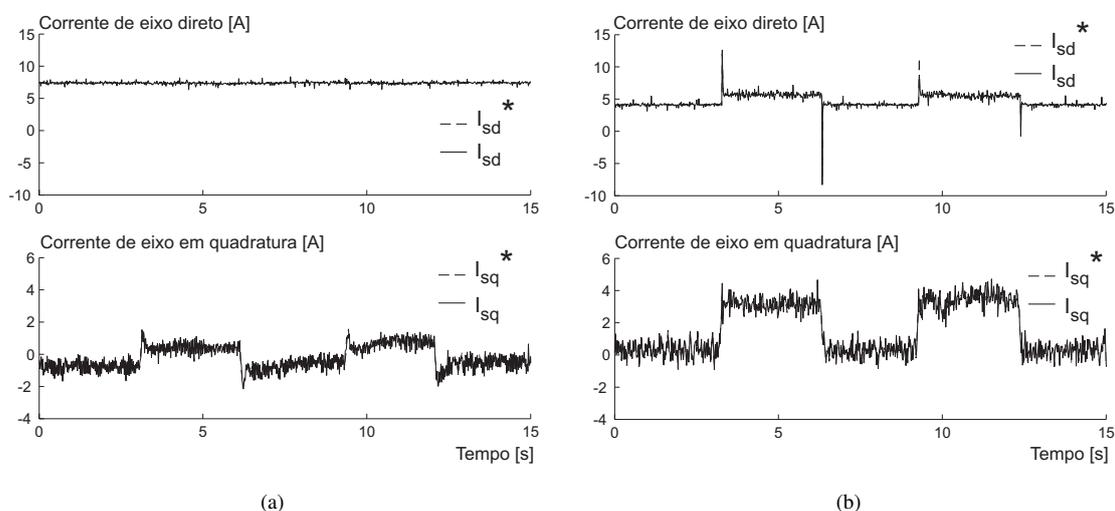
Os resultados para a máquina operando com  $\omega_{r,*} = 238 \text{ rad.ele/s}$  estão ilustrados nas Figs.5.16-5.18.

Na Fig. 5.16(b) observa-se que o fluxo necessário para atender a carga é abaixo do fluxo nominal. Com isso, a resposta de velocidade do controle com rede é um pouco mais lenta que o controle sem rede. Entretanto, o valor de velocidade acompanha a referência sem oscilações apreciáveis.

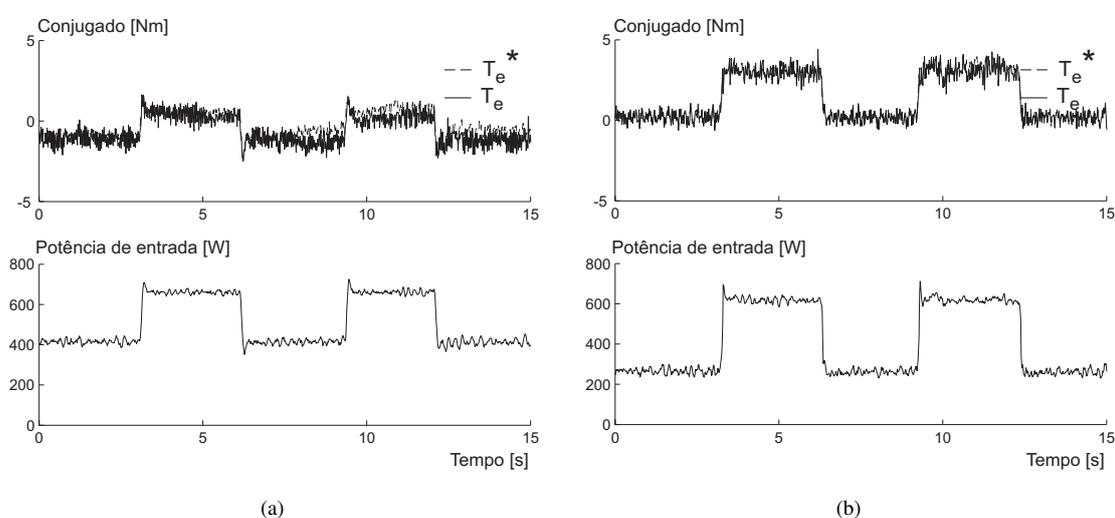


**Figura 5.16:** Resultados experimentais. Aplicação e retirada de carga. Evolução do fluxo e da velocidade.  $\omega_{r,*} = 238 \text{ rad.ele/s}$ : (a) sem rede neural; (b) com rede neural.

Nas Figs. 5.17 e 5.18, as grandezas possuem comportamentos similares ao descritos anteriormente.



**Figura 5.17:** Resultados experimentais. Aplicação e retirada de carga. Evolução das componentes de corrente de eixos direto e em quadratura.  $\omega_r^* = 238 \text{ rad.ele/s}$ : (a) sem rede neural; (b) com rede neural.



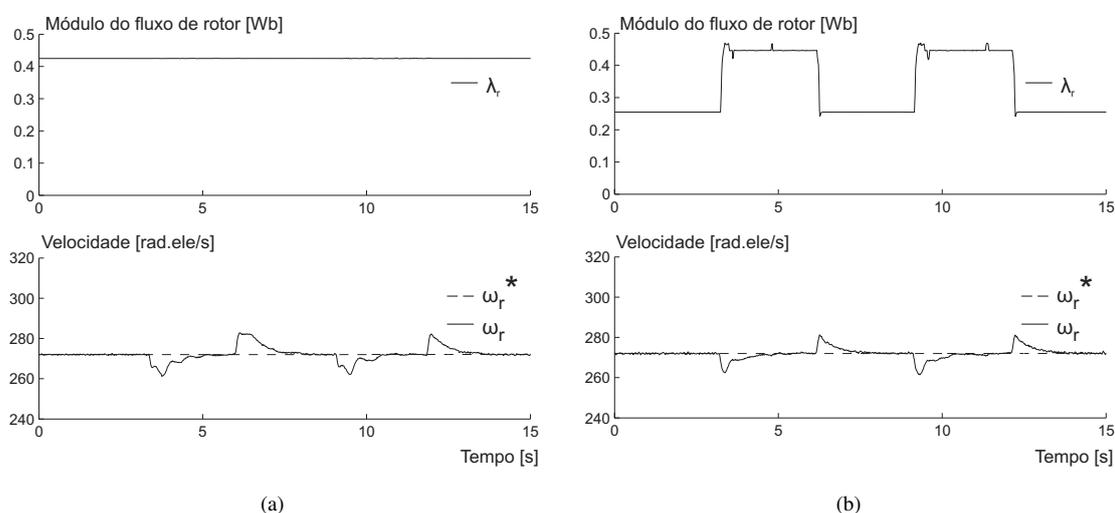
**Figura 5.18:** Resultados experimentais. Aplicação e retirada de carga. Evolução do conjugado e da potência de entrada.  $\omega_r^* = 238 \text{ rad.ele/s}$ : (a) sem rede neural; (b) com rede neural.

As potências de entrada para outras cargas com  $\omega_r^* = 238 \text{ rad.ele/s}$  estão mostradas na Tabela 5.4. Novamente, consegue-se uma redução no consumo de energia para algumas cargas e em outras o consumo é maior devido a um valor não adequado do fluxo de referência fornecido pela rede neural.

**Tabela 5.4:** Resultados Experimentais:  $\omega_r^* = 238 \text{ rad.ele/s}$ 

$\omega_r^*[\text{rad.ele/s}]$	$P_{SR}[\text{W}]$	$P_{CR}[\text{W}]$	Redução de Potência %
238,0000	449,3610	320,7646	<b>28,6176</b>
	465,7994	351,7744	<b>24,4794</b>
	468,8496	355,3583	<b>24,2063</b>
	499,3592	402,5458	<b>19,3875</b>
	562,2723	498,8462	<b>11,2803</b>
	691,0354	700,5444	-1,3761
	723,8130	751,5098	-3,8265
	757,0548	788,9437	-4,2122
	826,7961	879,5714	-6,3831
	1059,4768	1060,4146	-0,0885

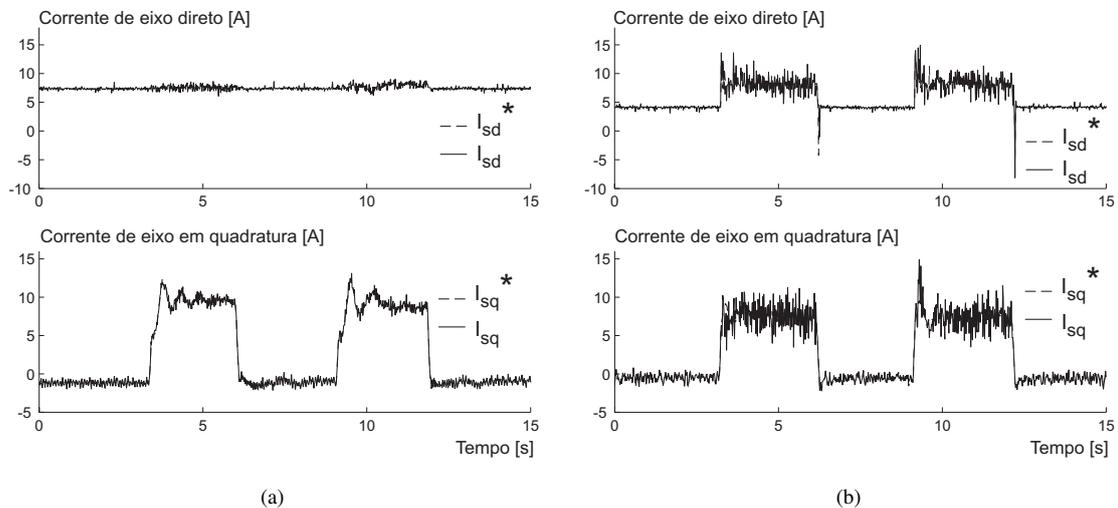
As respostas de velocidade, conjugado, fluxo e correntes para o teste de partida com aplicação e retirada de carga para a máquina operando com  $\omega_r^* = 272 \text{ rad.ele/s}$  estão ilustrados nas Figs 5.19-5.21.



**Figura 5.19:** Resultados experimentais. Aplicação e retirada de carga. Evolução do fluxo e da velocidade.  $\omega_r^* = 272 \text{ rad.ele/s}$ : (a) sem rede neural; (b) com rede neural.

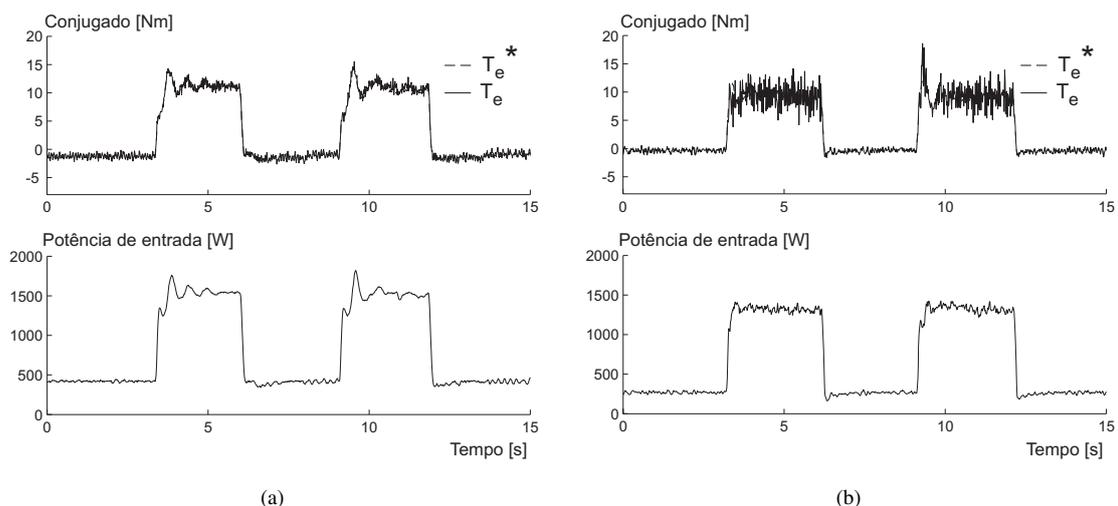
Na Fig. 5.19(b) observa-se que o fluxo de referência ideal, durante a aplicação de carga, é maior que o valor nominal. Nesta condição, o motor está operando na região de saturação magnética, e neste caso o desempenho dinâmico do controle de velocidade é melhor do que

o controle sem o uso da rede neural, tendo em vista que, para os mesmos valores de saturação de  $I_{sq}$ , valores superiores de conjugado são obtidos.



**Figura 5.20:** Resultados experimentais. Aplicação e retirada de carga. Evolução das componentes de corrente de eixos direto e em quadratura.  $\omega_r^* = 272 \text{ rad.ele/s}$ : (a) sem rede neural; (b) com rede neural.

O comportamento das componentes de corrente de eixos direto e em quadratura estão ilustrados na Fig. 5.20. Observa-se que a corrente  $I_{sq}$  do controle sem rede neural apresenta oscilações maiores que o controle com rede neural.



**Figura 5.21:** Resultados experimentais. Aplicação e retirada de carga. Evolução do conjugado e da potência de entrada.  $\omega_r^* = 272 \text{ rad.ele/s}$ : (a) sem rede neural; (b) com rede neural.

Na Fig. 5.21, observa-se nitidamente a redução potência do controle com rede neural

frente ao controle convencional, tanto em vazio quanto com carga. Este comportamento ressalta a importância de ter considerado o efeito da saturação magnética do ferro da máquina e desta forma trabalhar com valores de fluxo acima do valor nominal.

Na Tabela 5.5 são mostradas as potências de entrada para diferentes cargas e a economia obtida para  $\omega_r^* = 272 \text{ rad.ele/s}$ .

**Tabela 5.5:** Resultados Experimentais:  $\omega_r^* = 272 \text{ rad.ele/s}$

$\omega_r^*[\text{rad.ele/s}]$	$P_{SR}[\text{W}]$	$P_{CR}[\text{W}]$	Redução de Potência %
272,0000	479,1414	365,1314	<b>23,7946</b>
	498,2382	402,2270	<b>19,2701</b>
	507,8761	408,8983	<b>19,4886</b>
	545,0132	466,6384	<b>14,3803</b>
	636,7167	583,2245	<b>8,4013</b>
	824,4775	831,7987	-0,8880
	877,7757	884,9593	-0,8184
	930,6873	942,6043	-1,2805
	1086,7428	1043,5501	<b>3,9745</b>

As potências de entrada para outras cargas com  $\omega_r^* = 306 \text{ rad.ele/s}$  estão mostradas na Tabela 5.6. Já na Tabela 5.7, as potências de entrada para diferentes cargas aplicadas com a máquina operando a  $\omega_r^* = 340 \text{ rad.ele/s}$  são mostradas.

**Tabela 5.6:** Resultados Experimentais:  $\omega_{r,*} = 306 \text{ rad.ele/s}$ 

$\omega_{r,*}[\text{rad.ele/s}]$	$P_{SR}[\text{W}]$	$P_{CR}[\text{W}]$	Redução de Potência %
306,0000	483,2101	444,3257	<b>8,0471</b>
	493,5749	439,7509	<b>10,9049</b>
	508,5993	486,2558	<b>4,3931</b>
	544,4008	507,2403	<b>6,8259</b>
	657,3413	654,9796	<b>0,3593</b>
	866,6791	946,0555	-9,1587
	939,3146	1021,4971	-8,7492
	1006,7066	1080,4343	-7,3237
	1187,9428	1190,2038	-0,1903
	1541,1503	1503,0743	<b>2,4706</b>

**Tabela 5.7:** Resultados Experimentais:  $\omega_{r,*} = 340 \text{ rad.ele/s}$ 

$\omega_{r,*}[\text{rad.ele/s}]$	$P_{SR}[\text{W}]$	$P_{CR}[\text{W}]$	Redução de Potência %
340,0000	509,6341	450,7782	<b>11,5487</b>
	522,5788	501,9160	<b>3,9540</b>
	547,9640	457,3642	<b>16,5339</b>
	594,9297	584,4787	<b>1,7567</b>
	723,8965	767,4697	-6,0193
	1016,0405	1127,1005	-10,9307
	1127,1997	1187,3145	-5,3331
	1232,6695	1275,0651	-3,4393
	1448,3227	1421,4186	<b>1,8576</b>
	1886,7789	1754,8654	<b>6,9915</b>

Com base nos valores mostrados nas Tabelas acima, fica evidenciado três casos distintos:

1. Cargas leves necessitam de valores de fluxos de referência abaixo do valor de fluxo nominal. Nestes casos, no controle com rede neural, a redução no consumo de energia é bastante significativo;
2. Para cargas que necessitam de valores de fluxos de referência próximos do valor nominal, o consumo de energia utilizando o controle com rede neural é semelhante

ao controle convencional;

3. Para cargas elevadas, o controle com redes neurais apresenta um melhor desempenho pelo fato de levar em consideração o efeito da saturação magnética do ferro da máquina.

# 6 CONCLUSÃO

Este trabalho apresenta uma aplicação de redes neurais artificiais como parte integrante do controle de velocidade que busca maximizar a eficiência do acionamento de um motor de indução trifásico com rotor em gaiola. Para esse fim, um conjunto de redes foi utilizado na escolha do fluxo de rotor de referência para uma dada condição de carga e velocidade. Uma bancada experimental composta por um conversor CA/CC/CA com retificador a diodos e inversor tipo fonte de tensão a IGBT's, um microcomputador, um gerador CC, um banco de resistências e um "hardware" compatível, foi empregada para validar o estudo.

A implementação experimental foi precedida de um estudo, através da modelagem e simulação da máquina de indução incluindo os efeitos da saturação magnética. Tal estudo serviu também como ferramenta para modelagem de estimadores de fluxo que levassem em conta a saturação e formação de um banco de dados que foi utilizado posteriormente para treinamento das redes neurais. Além disso, ajustou-se os ganhos dos controladores PI das malhas de controle envolvidas.

Devido a limitações de ordem computacional, tendo em vista a implementação em tempo real, o problema da determinação do nível ótimo de fluxo foi particionado, de modo que dez redes foram criadas e treinadas, sendo cada uma responsável por uma determinada faixa de conjugado.

A modelagem da saturação magnética do ferro permitiu a determinação de valores de

fluxos, em locais fora da região de linearidade da curva de saturação, que resultassem em menores perdas na máquina, região esta pouco utilizada na prática comercial. Além disso, tal modelagem permitiu uma melhor precisão do fluxo estimado.

O *estimador 1*, proposto neste trabalho, apresentou uma boa performance quando comparado a outros modelos de estimadores com inclusão da saturação magnética existentes na literatura.

O fato da máquina operar com o nível mínimo de fluxo necessário para uma dada condição de velocidade e carga requer um certo grau de precisão da resposta da rede da neural, não permitindo, desta forma, valores de fluxos de referência muito divergentes daqueles contidos nos dados de treinamento, sob o risco de perda da eficiência do controle.

O bom desempenho das redes de múltiplas camadas tanto no que diz respeito ao aprendizado, quanto à sua capacidade de generalização, ficou demonstrado nos resultados de simulação e experimentais.

Apesar das limitações decorrentes da má estimação do conjugado, aliada ao fato de ter utilizado as RNA obtidas em simulações, os resultados experimentais demonstraram que a utilização da técnica estuda garante uma melhor eficiência no acionamento de motores de indução trifásico não só em regiões de cargas muito abaixo de seus valores nominais, onde estes apresentam baixos rendimentos, quanto em regiões próximas de seus valores nominais, onde estes são tipicamente eficientes.

Quando comparado ao controle tradicional, o controle com RNA apresenta um desempenho dinâmico inferior no que se refere a rapidez de resposta. Desta forma, o uso do controle com rede neural, possui boa aplicabilidade em sistemas que tenham como objetivo principal a economia de energia e não a rapidez de resposta do sistema de controle.

## 6.1 Trabalhos Futuros

Tendo em vista aperfeiçoar o trabalho desenvolvido, algumas propostas de trabalhos futuros são apresentadas a seguir:

- Estudo de modelos com perdas de MIT mais completos;
- Comparação entre as técnicas de estimação de parâmetros existentes;
- Análise da influência de outras entradas no desempenho da RNA;
- O emprego de outras topologias de redes neurais artificiais.



# DADOS E PARÂMETROS DOS COMPONENTES DO SISTEMA DE ACIONAMENTO

## A.1 Máquina de Indução

Potência:  $5hp$ ;

Tensão:  $220/380/440V$ ;

Corrente:  $14,1/8,16/7,05A$ ;

Velocidade:  $1715rpm$ ;

Rendimento:  $84,8\%$ ;

Fator de Potência:  $0,81$ ;

Momento de Inércia:  $0,1017kgm^2$ ;

Resistências:  $R_s = 0,53\Omega$ ,  $R_r = 0,7549\Omega$ ;

Indutâncias:  $L_{ls} = L_{lr} = 5,6mH$ ,  $L_m = 62mH$  (não saturada);

## A.2 Máquina de Corrente Contínua

Potência:  $3,68kW$ ;

Tensão de Armadura:  $250V$ ;

Corrente de Armadura:  $19A$ ;

Excitação: *especial*;

Tensão de Excitação: 250V;

Corrente de Excitação: 0,71A;

Velocidade: 20 a 1800rpm ;

### **A.3 Chaves Estáticas do Conversor CA/CC/CA**

Fabricante: Semikron;

Modelo: SKHI-22 ;

### **A.4 Componentes Passivos do Conversor CA/CC/CA**

Capacitores do elo CC: 2200 $\mu$ F.

## REFERÊNCIAS BIBLIOGRÁFICAS

- [1] E. R. Locatelli, *Motor Elétrico*. PUC-Rio, dezembro 2004.
- [2] ELETROBRAS/PROCEL, *Conservação de Energia: Eficiência Energética de Instalações e Equipamentos*, 3rd ed. Itajubá: EFEI, 2006, vários autores.
- [3] ———, *Conservação de Energia: Eficiência Energética de Instalações e Equipamentos*, 3rd ed. Itajubá: EFEI, 2001, vários autores.
- [4] A. Kusko and D. Galler, “Control means for minimization of losses in ac and dc motor drives,” *IEEE Transactions on Industry Applications*, vol. IA-19, no. 4, pp. 561–570, July 1983.
- [5] F. J. Nola, “Power factor control systems for ac induction motor,” U.S. Patent 4 052 648, October, 1977.
- [6] I. Kioskeridis and N. Margaris, “Loss minimization in induction motor adjustable-speed drives,” *IEEE Transactions on Industrial Electronics*, vol. 43, no. 1, pp. 226–231, Feb 1996.
- [7] ———, “Loss minimization in scalar-controlled induction motor drives with search controllers,” *IEEE Transactions on Power Electronics*, vol. 11, no. 2, pp. 213–220, Mar 1996.
- [8] D. S. Kirschen, D. W. Novotny, and W. Suwanwisoot, “Minimizing induction motor losses by excitation control in variable frequency drives,” *IEEE Transactions on Industry Applications*, vol. IA-20, no. 5, pp. 1244–1250, Sept. 1984.

- [9] D. S. Krischen, D. W. Novotny, and T. A. Lipo, "Optimal efficiency control of induction motor drive," *IEEE Trans. Ind. Appl.*, vol. IA-20, no. 5, March 1987.
- [10] H. G. Kim, S. K. Sul, and M. H. Park, "Optimal efficiency drive of a current source inverter fed induction motor by flux control," *IEEE Transactions on Industry Applications*, vol. IA-20, no. 6, pp. 1453–1459, Nov. 1984.
- [11] S. Sul and M. Park, "A novel technique for optimal efficiency control of a current-source inverter-fed induction motor," *IEEE Transactions on Power Electronics*, vol. 3, no. 2, pp. 192–199, Apr 1988.
- [12] K. Sundareswaran and S. Palani, "Artificial neural network based voltage controller for energy efficient induction motor drive," *IEEE Region 10 International Conference on Global Connectivity in Energy, Computer, Communication and Control, TENCON '98*, vol. 2, pp. 410–413, 1998.
- [13] G. Mino-Aguilar, J. M. Moreno-Eguilaz, B. Pryymak, and J. Peracaula, "A neural network based optimal rotor flux estimator for efficiency optimization an induction motor drive," *ISIE'06*, vol. 3, pp. 2528–2534, July 2006.
- [14] R. S. Silva, "Sistemas elétricos de alto desempenho a velocidade variável: Estratégias de controle e aplicações," Ph.D. dissertation, UFMG, DEE, Março 1995, tese para Concurso de Professor Titular.
- [15] A. E. Fitzgerald, C. Kingsley, and S. D. Umans, *Máquinas Elétricas com Introdução à Eletrônica de Potência*, 6th ed. Bookman, 2006.
- [16] J. Ojo, A. Consoli, and T. Lipo, "An improved model of saturated induction machines," *IEEE Transactions on Industry Applications*, vol. 26, no. 2, pp. 212–221, Mar/Apr 1990.
- [17] J. Moreira and T. Lipo, "Modeling of saturated ac machines including air gap flux harmonic components," *IEEE Transactions on Industry Applications*, vol. 28, no. 2, pp. 343–349, Mar/Apr 1992.

- [18] P. Ljusev, G. Stumberger, and D. Dolinar, "Rotor flux linkage oriented control of induction motor with included magnetic saturation," *IEE Proceedings - Electric Power Applications*, vol. 152, no. 1, pp. 112–118, Jan. 2005.
- [19] C.-M. Ong, *Dynamic Simulation of Electric Machinery*. Prentice Hall PTR, 1998.
- [20] *Getting Started with MATLAB*, R2006b ed., The MathWorks, Inc., 2006.
- [21] W. Leonhard, *Control of Electrical Drives*, 3rd ed. Springer-Verlag, 2001.
- [22] E. Levi, S. Vukosavic, and V. Vuckovic, "Saturation compensation schemes for vector controlled induction motor drives," *Prosc. PESC*, no. 1, pp. 591–598, Jun 1990.
- [23] P. Jansen, R. Lorenz, and D. Novotny, "Observer-based direct field orientation: analysis and comparison of alternative methods," *IEEE Transactions on Industry Applications*, vol. 30, no. 4, pp. 945–953, Jul/Aug 1994.
- [24] P. Jansen and R. Lorenz, "A physically insightful approach to the design and accuracy assessment of flux observers for field oriented induction machine drives," *IEEE Transactions on Industry Applications*, vol. 30, no. 1, pp. 101–110, Jan/Feb 1994.
- [25] Y. Hori, V. Cotter, and Y. A. Kaya, "A novel induction machine flux observer and its application to a high performance ac drive system," in *Proceedings of 10th World Congress on Automatic Control -IFAC*, vol. 3, Munich, Alemanha, 1987, pp. 355–360.
- [26] G. Verghese and S. Sanders, "Observers for flux estimation in induction machines," *Industrial Electronics, IEEE Transactions on*, vol. 35, no. 1, pp. 85–94, Feb 1988.
- [27] P. Jansen and R. Lorenz, "Accuracy limitations of velocity and flux estimation in direct field oriented induction machines," *Fifth European Conference on Power Electronics and Applications, 1993.*, pp. 312–318 vol.4, Sep 1993.
- [28] P. Jansen, C. Thompson, and R. Lorenz, "Observer-based direct field orientation for both zero and very high speed operation [of asynchronous machines]," *Conference Record of the Power Conversion Conference, 1993. Yokohama 1993.*, pp. 432–437, Apr 1993.

- [29] R. De Doncker and D. Novotny, "The universal field oriented controller," *IEEE Transactions on Industry Applications*, vol. 30, no. 1, pp. 92–100, Jan/Feb 1994.
- [30] P. F. Seixas, "Commande numérique d'une machine synchrone autopilotée," These de Docteur, Toulouse, INPT, 1988.
- [31] A. P. Braga, T. B. Ludemir, and A. C. P. L. Carvalho, *Redes Neurais Artificiais: Teoria e Aplicações*. LTC, 2000.
- [32] W. S. McCulloch and W. Pitts, "A logical calculus of the ideas immanent in nervous activity," *Bulletin of Mathematical Biophysics*, vol. 5, no. 4, pp. 115–133, Dec 1943.
- [33] F. Rosenblatt, "The perception: a probabilistic model for information storage and organization in the brain," *Psychological Review*, vol. 65, no. 6, pp. 386–408, Nov 1958.
- [34] G. Cybenko, "Continuous valued neural networks with two hidden layers are sufficient," Department of Computer Science, Tufts University, Medford, MA, USA, Tech. Rep., 1988.
- [35] J. Hertz, A. Krogh, and R. G. Palmer, *Introduction to the theory of neural computation*. Boston, MA, USA: Addison-Wesley Longman Publishing Co., Inc., 1991.
- [36] C. Cybenko, "Approximation by superpositions of a sigmoid function," *Mathematics of Control Signals Systems*, vol. 2, pp. 303–314, 1989.
- [37] D. E. Rumelhart, G. E. Hinton, and R. J. Williams, "Learning representations by back-propagating errors," *Nature*, no. 323, pp. 533–536, Oct 1986.
- [38] D. O. Hebb, *The organization of behavior*, Wiley, 1949.
- [39] B. Widrow and M. E. Hoff, "Adaptive switching circuits," Institute of Radio Engineers, Western Electronic Show and Convention, Tech. Rep., 1960.
- [40] D. B. Parker, "Optimal algorithms for adaptive networks: second order back propagation, second order direct propagation, and second order hebbian learning," in *IEEE First Int. Conf. Neural Networks*, San Diego CA, 1987, pp. 593–600.

- [41] M. Fairhurst, "Fundamentals of neural networks. architectures, algorithms and applications," Prentice/Hall International, Tech. Rep., 1988.
- [42] M. Riedmiller, "Rprop - description and implementation details," University of Karlsruhe, Tech. Rep., 1994.
- [43] K. Levenberg, "A method for the solution of certain problems in least squares," *Quart. Appl. Math.*, vol. 2, pp. 164–168, 1944.
- [44] D. Marquardt, "An algorithm for least-squares estimation of nonlinear parameters," *SIAM Journal on Applied Mathematics*, vol. 11, no. 2, pp. 431–441, 1963.
- [45] G. G. Parma, "Treinamento de redes neurais artificiais baseado em sistemas de estrutura variável com aplicações em acionamentos elétricos," Ph.D. dissertation, Universidade Federal de Minas Gerais, junho 2000.
- [46] K. Hasan, L. Zhang, and B. Singh, "Neural network control of induction motor drives for energy efficiency and high dynamic performance," *23rd International Conference on Industrial Electronics, Control and Instrumentation, 1997. IECON 97.*, vol. 2, pp. 488–493, Nov 1997.
- [47] L. Zhang and K. Hasan, "Neural network aided energy efficiency control for a field-orientation induction machine drive," *Ninth International Conference on (Conf. Publ. No. 468) Electrical Machines and Drives, 1999.*, pp. 356–360, 1999.
- [48] E. Abdin, G. Ghoneem, H. Diab, and S. Deraz, "Efficiency optimization of a vector controlled induction motor drive using an artificial neural network," *The 29th Annual Conference of the IEEE Industrial Electronics Society, 2003. IECON '03.*, vol. 3, pp. 2543–2548, Nov. 2003.
- [49] B. Pryymak, J. Moreno-Eguilaz, and J. Peracaula, "Neural network based efficiency optimization of an induction motor drive with vector control," *IECON 02 [28th Annual Conference of the Industrial Electronics Society, IEEE 2002 ]*, vol. 1, pp. 146–151, Nov. 2002.

- [50] B. Prymak, J. M. Moreno-Eguilaz, and J. Peracaula, “Neural network flux optimization using a model of losses in induction motor drives,” *Mathematics and Computers in Simulation*, vol. 71, no. 4-6, pp. 290–298, Jun 2006.
- [51] L. Prechelt, “Proben1 - a set of neural network benchmark problems and benchmarking rules,” Universit at Karlsruhe, Germany, Tech. Rep., Sep 1994.