

CONTROLE ESCALAR DO MOTOTOR DE INDUÇÃO USANDO A TÉCNICA SENSORLESS NEURAL

Tiago H. dos Santos¹, Alessandro Goedel², Sérgio A. Oliveira da Silva², Marcelo Suetake³
Instituto Federal do Paraná (IFPR)¹, Universidade Tecnológica Federal do Paraná (UTFPR-CP)², Universidade Federal de São Carlos (UFSCAR)³
Assis Chateaubriand – PR¹, Cornélio Procópio – PR², São Carlos – SP³
e-mail: tiago.santos@ifpr.edu.br, agoedel@utfpr.edu.br, augus@utfpr.edu.br, mclsuetake@gmail.com

Resumo - Os motores de indução têm grande importância nos mais diversos setores industriais por sua robustez e baixo custo. Assim, quando a carga acoplada ao seu eixo necessitar do controle de velocidade, parte das estratégias de controle e acionamento é baseada na estimativa de velocidade. A proposta deste trabalho consiste em apresentar uma metodologia alternativa às tradicionais para a estimativa de velocidade do motor de indução trifásico. Este é acionado por um inversor de tensão utilizando modulação espacial vetorial na estratégia de controle escalar baseada em redes neurais artificiais. Resultados de simulação e experimentais são apresentados para validar o método proposto com o motor submetido a variações de velocidade e torque de carga, os quais demonstraram ser bem promissores.

Palavras-Chave – Controle Escalar, Estimador de Velocidade, Motor de Indução, Redes Neurais Artificiais.

SCALAR CONTROL OF INDUCTION MOTOR USING THE NEURAL SENSORLESS TECHNIQUE

Abstract – The induction motors have a great importance in many industrial sectors for its robustness and low cost. Thus, when the load coupled to the axis needs speed control, some of the drive and control strategies are based on the estimated axis speed of the motor. The purpose of this work is to present an alternative methodology for speed estimating of three phase induction motor. It is driven by a voltage source inverter using space vector modulation in the scalar control strategy based on artificial neural networks. Simulation and experimental results are presented to validate the performance of the proposed method under motor load torque and speed reference set point variations, which show very promising.

Keywords – Artificial Neural Network, Induction Motor, Scalar Control, Speed Estimator.

Artigo submetido em 24/05/2013. Primeira revisão em 06/11/2013, segunda revisão em 09/02/2014. Aceito para publicação em 10/02/2014 por recomendação do editor Henrique A. C. Braga.

I. INTRODUÇÃO

O Motor de Indução Trifásico (MIT) é usado em muitos setores industriais, sendo o principal elemento de conversão de energia elétrica em mecânica motriz. Suas principais características são baixo custo e robustez [1]-[6].

As aplicações que incluem o MIT podem ser divididas em dois grupos: o primeiro deles é aquele em que o motor é diretamente acoplado à rede elétrica, sem elemento de controle. No segundo, as metodologias de controle escalar ou vetorial são aplicadas. Para ambos os grupos, nas diversas aplicações dos setores produtivos, há a necessidade de conhecer a velocidade no eixo da máquina, seja na forma de medida direta ou estimada.

A velocidade no eixo do motor de indução é comumente medida por meio de *encoders* ópticos, *resolvers* eletromagnéticos ou tacogeradores. Entretanto, o uso destes dispositivos apresentam certas limitações em suas aplicações, tais como o aumento do custo do dispositivo de acionamento, redução da robustez mecânica, baixa imunidade ao ruído, alteração do momento de inércia da máquina, além de exigir cuidados especiais em ambientes hostis [7-12].

Assim, utilizam-se técnicas as quais estimam a velocidade do eixo sem a necessidade da medida direta da variável. Tais técnicas são denominadas *sensorless* [11, 13].

As principais estratégias de controle *sensorless* têm como base os estimadores de malha aberta com monitoramento de corrente e tensão do estator, observadores de estado, sistemas de referência com modelos adaptativos e estimadores baseados em sistemas inteligentes, os quais advêm, principalmente, das Redes Neurais Artificiais (RNA) e lógica fuzzy [7, 10, 14].

A maioria dos estimadores de velocidade tem origem no modelo matemático do motor de indução, onde é necessário o conhecimento preciso dos parâmetros elétricos e mecânicos do motor [8, 10, 15]. Os estimadores de velocidade baseados em Observadores de Estado (OE) necessitam do valor preciso dos parâmetros da máquina para a correta operação do dispositivo *sensorless*, onde tal método requer a resolução de equações diferenciais [16]. A precisão é também prejudicada, pois a modelagem não leva em consideração a saturação eletromagnética, efeito pelicular e variações paramétricas devido aos efeitos da temperatura.

Recentemente, alguns trabalhos têm utilizado as RNAs como um método alternativo de estimação de parâmetros e velocidade de motores de indução trifásicos [17-20].

Um estimador neural tendo como variáveis de saída a velocidade e a resistência rotórica de um MIT, utilizando uma rede ADALINE é apresentado em [17]. Nesta proposta,

a corrente e a tensão do estator da máquina são medidas no eixo de coordenadas estacionária trifásica abc . Após a transformação para o eixo de coordenadas estacionária bifásica $\alpha\beta 0$, esses sinais são utilizados para estimar a corrente, o fluxo e a derivada do fluxo do rotor, sendo essas as variáveis de entrada da RNA. Para a validação do estimador neural de velocidade, este é aplicado em diversas estratégias de controle do MIT, como o controle escalar e o controle vetorial.

Um preditor neural de velocidade de um MIT utilizando uma rede Perceptron de Múltiplas Camadas (PMC) é apresentado em [18]. As entradas desse estimador utilizam os dados de corrente e tensão do estator no eixo de coordenadas síncrona trifásica $dq0$. O conjunto de dados de treinamento e validação da rede PMC são adquiridos com a máquina de 2 pólos, 50Hz, operando em regime permanente e com variação de velocidade entre 500 a 1000 Revoluções Por Minuto (RPM).

A aplicação de uma RNA na estimação do fluxo magnético do entreferro de um MIT pela aquisição da tensão e corrente do estator é apresentada em [19]. No referido artigo, a RNA é treinada para operar com um observador do fluxo magnético do rotor, onde este é usado como referência para correção de um Modelo de Referência de Sistema Adaptativo (MRSA). O erro gerado entre o fluxo do rotor de referência dado pela RNA e o MRSA é processado por um controlador Proporcional-Integral (PI), que por sua vez, tem como saída a ação de controle a velocidade estimada, usada para adaptação do MRSA.

Um observador de velocidade baseado em um MRSA com um observador de corrente do estator nos eixos de referência estacionária com o uso de duas RNAs é apresentado em [20]. O observador neural de velocidade tem como entradas o fluxo magnético do rotor, o qual é obtido por um observador da corrente do MIT, a tensão de alimentação e a corrente do estator estimada com atraso temporal. A corrente estimada pelo observador neural é comparada com a corrente medida do MIT e o erro calculado é utilizado no algoritmo de treinamento *online* das RNAs. A informação contida em um dos pesos sinápticos das RNAs contém a informação da velocidade do rotor, que é também utilizada pelo observador de corrente.

A proposta deste trabalho consiste no desenvolvimento de um estimador neural de velocidade aplicado ao controle escalar do MIT utilizando a tensão e a corrente nos eixos d e q síncronos obtidos por meio de um circuito detecção de fase PLL (*Phase-Locked Loop*). Os dados de treinamento são gerados via simulação computacional dos modelos matemáticos do MIT. Já o seu acionamento é realizado por um inversor de tensão trifásico com modulação vetorial espacial aplicado ao controle escalar. O treinamento da estrutura neural é executado de maneira *off-line*. Com o objetivo de validar a metodologia proposta, resultados de simulação e experimentais são apresentados e comparados com o controle utilizando a medida direta da velocidade.

A organização deste trabalho segue a seguinte ordem: na Seção II são apresentados aspectos da modelagem do motor de indução trifásico e o sistema de acionamento; na Seção III são relatados os princípios envolvidos com as RNAs e os resultados de simulação e experimentais que validam a

proposta do trabalho. Finalmente, na Seção IV, as conclusões são apresentadas.

II. MODELAGEM E ACIONAMENTO DO MIT

Uma equação ou um conjunto de equações que compõem um modelo matemático são uma aproximação do sistema físico real [21]. Assim, faz-se necessária a modelagem matemática do elemento em estudo: o motor de indução trifásico. Tal equacionamento propicia a implementação em ambiente computacional do sistema físico, a saber: a máquina elétrica e o seu sistema de acionamento.

Um dos principais passos envolvidos no treinamento de uma rede neural artificial consiste na a obtenção do conjunto de padrões de entrada e saída com o objetivo de propiciar o ajuste dos parâmetros internos da rede. Este procedimento é conhecido como processo de treinamento e deve garantir que a estrutura neural é exposta a sequências de padrões que descrevam de forma satisfatória o comportamento do sistema analisado.

A. Aspectos da Modelagem do MIT

Com o propósito de gerar os padrões de treinamento para estimativa de velocidade do motor de indução, quando em diferentes situações de carga e tensão de alimentação, foram realizadas várias simulações utilizando a ferramenta Matlab/Simulink. O modelo do motor de indução usado nas simulações foi desenvolvido em [22] e [23]. Este modelo leva em consideração vários aspectos envolvidos na dinâmica eletromecânica do motor, permitindo a simulação do comportamento do regime transitório ao regime permanente em diversas configurações de operação.

O modelo apresentado nas referências ONG 1998 [22] e Krause et al. 2002 [23] estabelece a relação entre as variáveis elétricas e mecânicas do motor de indução trifásico simétrico. Assim, é possível simular computacionalmente a dinâmica da máquina em estudo do regime transitório ao regime permanente. Esta modelagem é apresentada em diversos trabalhos na área de máquinas elétricas e acionamentos.

O diagrama em blocos da Figura 1 apresenta as entradas e saídas do modelo proposto, bem como o sistema de acionamento. Os parâmetros da máquina, tais como tensão, parâmetros elétricos do rotor e estator, momento de inércia da carga e do rotor, e conjugado de carga são as entradas do modelo. A corrente elétrica, o conjugado eletromagnético e a velocidade do rotor são as saídas do modelo. Estas variáveis serão usadas no processo de treinamento das redes neurais associado ao acionamento da máquina.




Fig. 1. Diagrama esquemático representando as configurações de entradas-saídas para simular o MIT e acionamento.

A função $f(\omega)$ representa as diversas cargas que podem ser simuladas. Na Tabela I são mostrados os parâmetros usados na simulação do modelo do MIT. Com as simulações foi possível gerar a quantidade necessária de dados para o treinamento da RNA.

TABELA I
Parâmetros do MIT

Linha Standard – IV Polos – 60 Hz – 220/380V	
Potência	1 cv
Corrente Nominal	3,018 A
Resistência de Estator	7,32 Ω
Resistência de Rotor	2,78 Ω
Indutância de Dispersão do Estator	8,95 mH
Indutância de Dispersão do Rotor	5,44 mH
Indutância de Magnetização	0,141 H
Momento de Inércia	2,71.10 ⁻³ kgm ²
Torque Nominal	4,1 Nm

B. Acionamento do MIT

Neste trabalho, o MIT é acionado por um inversor de tensão trifásico, cujo objetivo é aplicar uma tensão de alimentação de forma que ele opere conforme o sinal de referência do sistema de controle escalar.

O circuito de potência do inversor é composto basicamente por três módulos, a saber: o retificador trifásico, o filtro capacitivo do barramento cc e o conversor cc/ca, conforme apresentado na Figura 2. No diagrama apresentado os diodos D1 a D6 compõem o circuito retificador trifásico, C é o capacitor de filtro do barramento cc e as chaves semicondutoras de potência S1 a S6 formam o inversor trifásico.




Fig. 2. Módulos de potência do inversor de tensão trifásico.

As chaves de potência do módulo de saída (S1 a S6) são comandadas através de sinais modulados por largura de pulso (*Pulse Width Modulation* - PWM) gerados pelo algoritmo de modulação. A técnica de modulação utilizada neste trabalho é a modulação por largura de pulsos por vetores espaciais (*Space Vector Pulse Width Modulation* - SVPWM) baseada em [24].

C. Controle escalar do MIT

O controle escalar é um dos métodos mais empregados na indústria devido a sua simplicidade. Entretanto, seu desempenho dinâmico é limitado, mesmo a laço fechado, principalmente quando opera em regiões de baixas velocidades [16]. Trabalhos recentes têm utilizado a estratégia escalar para a verificação de novas propostas de controle e técnicas *sensorless* [3].

A essência do controle escalar consiste em estabelecer a relação tensão/frequência (V/f) constante, de forma a manter o fluxo magnético máximo no entreferro também constante.

Caso a tensão não tenha uma relação apropriada com a frequência, a máquina pode operar na região de saturação ou enfraquecimento de campo [3].

O fluxo produzido pode ser calculado através da relação entre a tensão e a frequência, dada por:

$$\Phi_m \cong \frac{V_p}{f} \cong K_v \quad (1)$$

onde Φ_m é o máximo fluxo do entreferro (Weber), K_v é a constante de proporcionalidade entre a tensão de pico por fase V_p e a frequência da tensão f . A constante K_v calculada em (1) não leva em consideração a ondulação da tensão do barramento cc e as perdas no cobre do estator. Entretanto, em baixas velocidades de operação, essas perdas têm efeito relevante no desempenho do controle, reduzindo o torque eletromagnético da máquina [25]. Para minimizar a queda de tensão na resistência estatórica R_s , uma tensão é adicionada na relação V/f , denominada V_{boost} .

Neste método de controle, a velocidade de escorregamento, a tensão V_{boost} e a referência de velocidade são variáveis, sendo estas calculadas de acordo com as características do MIT e do ponto de operação desejado.

III. ESTIMADORES NEURAL DE VELOCIDADE

A identificação de sistemas através das redes neurais artificiais tem mostrado resultados promissores na área de sistemas de potência. Mais especificamente, o uso de RNA tem oferecido estratégias alternativas ao tratamento de problemas relacionados às máquinas elétricas [8, 18-20, 26, 27, 30]. No presente trabalho, as RNAs foram usadas para estimativa de velocidade no eixo de um motor de indução trifásico acionado por um inversor de tensão com modulação SVPWM com base na medida de tensão e corrente de alimentação da máquina. Esta metodologia é a base da técnica conhecida como *sensorless*.

O uso das técnicas *sensorless* no controle de máquinas elétricas é hoje uma realidade em diversos *drivers* comerciais de aplicações industriais. Isso reduz consideravelmente o custo de implementação dos sistemas de controle, uma vez que os sensores de velocidade com elevada precisão e nível de ruído satisfatório possuem custo elevado. Desse modo, as pesquisas por estimadores de velocidade precisos e estáveis estão em constante processo de evolução e desenvolvimento.

Alguns trabalhos que utilizam a tensão e/ou a corrente do MIT como variável de entrada dos estimadores, os quais utilizam essas variáveis nos eixos de coordenadas síncrona e estacionária, são respectivamente apresentados em [18] e em [17].

A. Tratamento de Dados

As simulações executadas do modelo da máquina, associada ao sistema de acionamento, formam um conjunto de dados, os quais são usados no processo de treinamento e validação.

As tensões sintetizadas pelo inversor de tensão trifásico e as correntes drenadas pela máquina, devido às características do chaveamento do inversor, possuem um elevado nível de ruído. A fim de contornar esse efeito, é utilizado um FPB de segunda ordem ajustado para uma frequência de corte de

600Hz. Esses sinais, agora com características senoidais, precisam ser pré-processados de forma a se extrair as informações que possam ser utilizadas para mapear a velocidade do MIT.

A proposta de tratamento de dados deste trabalho consiste em utilizar os sinais de tensão e corrente nos eixos de coordenadas $dq0$. Para isso, as variáveis de tensão e correntes, primeiramente no eixo de coordenadas estacionárias abc , são transformadas para o eixo de coordenadas estacionária $\alpha\beta0$, sendo as tensões nesse eixo de referência, utilizadas no algoritmo de detecção de fase *Phase-Locked Loop* (PLL). Posteriormente, as tensões bifásicas são transformadas para o eixo de coordenadas síncronas $dq0$. Nesta última transformação de eixos de referência, são utilizados os sinais de sincronismo ($sen\theta$ e $cos\theta$) extraídos do algoritmo PLL, os quais estão sincronizados com a tensão da rede elétrica. No presente trabalho utilizou-se a tensão aplicada no MIT como sinal de referência para o PLL. O diagrama em blocos que representa método de tratamento de dados é mostrado na Figura 3.




Fig. 3. Diagrama em blocos do processamento de dados.

O algoritmo do PLL utilizado neste trabalho é baseado no sistema pPLL trifásico apresentado em [29]. Esse sistema se fundamenta na teoria da potência ativa instantânea trifásica, onde o sistema pPLL é desenvolvido no sistema de eixos de coordenadas estacionárias bifásicas ($\alpha\beta$). A potência ativa instantânea trifásica, considerando um sistema trifásico a três fios, pode ser representada de duas formas, trifásica ou bifásica, ou seja, nos sistemas de eixos de referências estacionárias abc ou $\alpha\beta$, como segue:

$$p = v_{an}i_a + v_{bn}i_b + v_{cn}i_c = v_{\alpha}i_{\alpha} + v_{\beta}i_{\beta} \quad (2)$$

onde p é a potência ativa instantânea, v_{an}, v_{bn}, v_{cn} e i_a, i_b, i_c são, respectivamente, as tensões e correntes no sistema de eixos estacionários trifásicos (abc) e $v_{\alpha}, v_{\beta}, i_{\alpha}, i_{\beta}$ são, respectivamente, as tensões e as correntes no sistema de eixos estacionário bifásico ($\alpha\beta$).

O esquema pPLL trifásico apresentado na Figura 4, opera de modo a anular a componente média da potência ativa instantânea fictícia p' . Assim, quando o valor médio de p' for zero, o sinal de saída do PLL estará atacadado com a componente fundamental do sinal de entrada, ou seja, o sinal de saída $sen(\theta^* - \pi/2)$ estará em fase com o ângulo de fase da tensão v_{α} . O comportamento dinâmico do pPLL é definido pelo controlador PI, o qual determina a frequência angular ($\omega^* = 2\pi f$), onde f é a frequência da componente fundamental do sinal de entrada. O ângulo θ^* é obtido pela integração da frequência angular ω^* . Portanto, θ^* é usado para calcular as correntes fictícias i'_{α} e i'_{β} (Figura 4). Para cancelar a parcela

contínua da potência p' as correntes fictícias i'_{α} e i'_{β} devem ser ortogonais às tensões v_{α} e v_{β} , respectivamente [28].

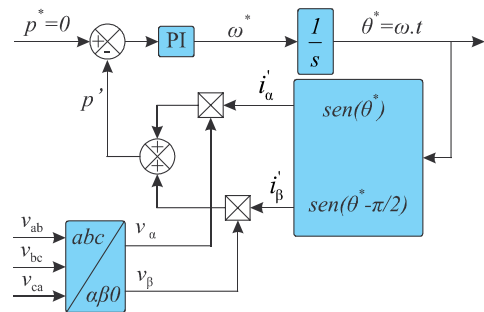


Fig. 4. Diagrama em blocos do sistema p-PLL trifásico.

B. Estrutura Neural do Estimador de Velocidade.

As redes neurais artificiais têm se mostrado eficientes nas mais diversas aplicações de engenharia. Nesse trabalho, uma estrutura neural é aplicada na estimação de velocidade de um motor de indução trifásico quando este é acionado por um inversor de frequência com controle escalar.

Para compor o conjunto de dados de treinamento foram realizadas diversas simulações do modelo matemático do MIT implementado no ambiente Matlab/Simulink e operando na faixa de 1 Hz a 60 Hz. Ainda, para cada ponto de operação de frequência do controle escalar, foram utilizados cinco valores de conjugado resistente de carga, variando de 0,1 N.m a 4,1 N.m com incremento de 1 N.m. Para cada simulação, foram também aplicadas variações desse conjugado de carga após atingido o regime permanente, a fim de que o conjunto de treinamento caracterize a dinâmica da máquina a essa variação, aproximando-a das condições de operação em ambientes industriais.

Na proposta deste trabalho foram testadas algumas configurações de RNAs; a saber: a peceptron múltiplas camadas (PMC) e a rede perceptron com atraso nas entradas do tempo (*Time Delay Neural Network – TDNN*). A melhor resposta dinâmica foi apresentada pela rede TDNN de ordem quatro. A Figura 5 apresenta o conjunto inversor de tensão com controle escalar, processamento de dados e estimador neural de velocidade.

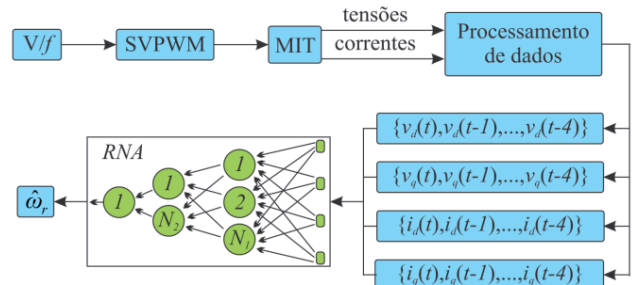


Fig. 5. Estrutura de treinamento e teste do estimador.

Para que o estimador proposto seja generalista com relação ao motor de indução acionado, foi adotada a normalização com os valores máximos de todas as variáveis de entrada e saída. Dessa forma, objetiva-se um desempenho satisfatório do estimador, mesmo para uma máquina cujos

parâmetros são diferentes daqueles usados nas simulações. A Tabela II apresenta os parâmetros estruturais da RNA, onde a convergência do processo de treinamento ocorreu em 312 épocas.

C. Validação Computacional.

A RNA TDNN foi treinada através de dados obtidos nas várias simulações do modelo do MIT acionado por um inversor de tensão trifásico com controle escalar. O diagrama ilustrado na Figura 6 apresenta a estrutura de simulação implementada computacionalmente.

TABELA II
Parâmetros da RNA

Arquitetura da Rede	Perceptron Multicamadas (TDNN)
Tipo de treinamento	Supervisionado
Número de camadas	3
Número de neurônios na 1ª camada escondida	6
Número de neurônios na 2ª camada escondida	21
Algoritmo de treinamento	Levenberg-Marquardt
Taxa de aprendizagem	$5 \cdot 10^{-2}$
Número de épocas	3000
Erro quadrático requerido	$1 \cdot 10^{-2}$
Função de ativação dos neurônios das camadas escondidas	Tangente hiperbólica
Função de ativação do neurônio da camada de saída	Linear

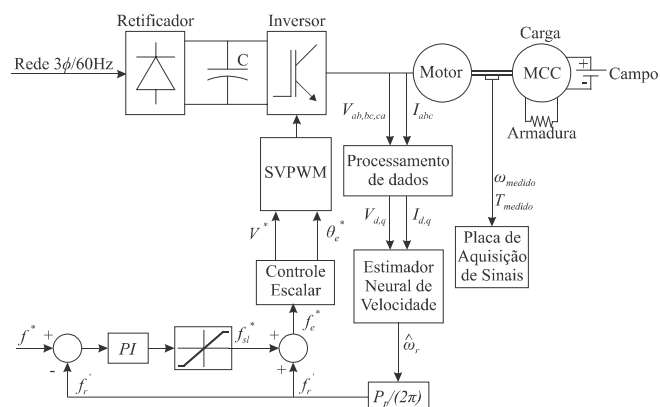


Fig. 6. Diagrama em blocos do controle escalar a laço-fechado com o estimador neural.

A técnica de controle apresentada neste trabalho consiste em determinar o erro entre a frequência (medida ou estimada) com a frequência de referência. Esta medida é a entrada do PI de controle de escorregamento. A saída desse PI é somada a velocidade atual e gera a referência de velocidade síncrona para o controle escalar. Tal estratégia de controle encontra-se em [3,4].

O projeto dos ganhos do controlador PI da malha de velocidade considerou a função de transferência da planta $G(s) = Y(s)/U(s)$, onde $Y(s)$ é a saída da função, que no caso é a velocidade, e a entrada $U(s)$ é a frequência da tensão de alimentação da máquina, conforme apresentado na Figura 7. Para encontrar a função $G(s)$ levou-se em consideração que a dinâmica mecânica predomina em relação à elétrica [3]. Com as curvas de entradas e saídas adquiridas nas simulações, foi realizada a identificação e projeto do controle da planta $G(s)$.




Fig. 7. Diagrama em blocos do controle escalar a laço-fechado com o estimador neural.

1) *Metodologia de Treino e Validação*: A metodologia proposta neste trabalho está representada na Figura 8, onde o diagrama em blocos mostra a estrutura formada entre a modelagem e a experimentação executadas entre os passos 1 a 9 descritos a seguir.

Na primeira fase ocorre a modelagem do MIT, conforme descrito na Seção II (passo 1). As simulações do MIT, junto ao seu método de acionamento, gera o banco de dados utilizados no treinamento e no teste da estrutura neural proposta (passos 2, 3 e 4). A próxima etapa consiste no treinamento da RNA, conforme descrito na Seção III (passo 5). Após o seu treinamento, a RNA é avaliada através dos dados adquiridos via simulação e armazenados segundo os passos 3 e 4. Este processo é denominado de validação cruzada (*crossvalidation*), sendo esse executado nos passos 6 e 7.

Após a validação com os dados de simulação, a RNA é implementada num sistema embarcado como será apresentado nesta Seção. Uma vez embarcada, são realizados os testes da RNA com dados experimentais conforme os passos 8 e 9. Os resultados obtidos com o estimador neural são comparados com a velocidade medida de forma a validar a RNA (passo 10). Esse processo de validação de uma RNA treinada e validada com dados de simulação e posteriormente sua validação com dados experimentais é denominado bivalidação cruzada, definida por [29].

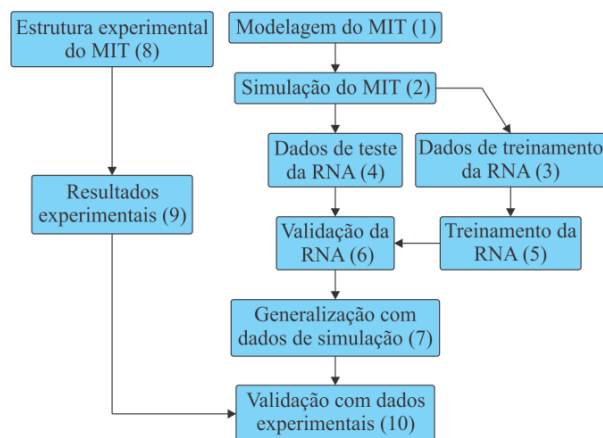


Fig. 8. Diagrama em blocos da metodologia.

2) *Resultados e Generalização das Simulações*: Nesta subseção são abordados os passos 1 a 7 da metodologia apresentada na Figura 8. Para os resultados de simulação considera-se que o MIT possui uma carga com torque linear representada por:

$$T_l = K_t + \alpha \omega_r \quad (3)$$

onde T_l é o torque mecânico da carga (N.m), α é a constante de proporcionalidade torque/velocidade (N.m/rad/s), ω_r é a velocidade angular do rotor e K_t é uma constante de torque mínimo que neste trabalho foi atribuído o valor de 0,1 N.m.

Para as simulações a seguir, foi assumido que a carga possui um momento de inércia de $5,42 \cdot 10^{-3} \text{ kg.m}^2$. Esse valor de momento de inércia tem como objetivo testar a RNA para condições diferentes de carga no MIT, uma vez que para o momento de inércia de carga usado no treinamento foi considerado o valor apresentado na Tabela I.

Foram realizados testes em seis situações conforme apresentado na Tabela III. Essas referências de operação têm como objetivo avaliar o desempenho do estimador em três regiões de operação, ou seja, baixa, média e altas velocidades.

Para os testes de 1 a 3 foi considerada uma única referência de velocidade, sendo verificado o desempenho do sistema de controle quando aplicado uma variação do conjugado resistente de carga do MIT utilizando a RNA comparada com a medida direta da velocidade.

TABELA III

Pontos de Operação da Proposta (Dados de Simulação)				
Número do teste	Frequência de operação (Hz)		Torque de Carga (N.m)	
	Inicial	Final	Inicial	Final
1	6		1,1	1,6
2	21,5		1,1	3,1
3	53		4,4	1,4
4	5	20	0,2	0,4
5	35	50	3,3	4,7
6	52	20	4,4	1,7

A Figura 9 apresenta o resultado obtido para o teste 1. Nesta figura o estimador opera como elemento sensor de velocidade, fornecendo a variável para a realimentação da malha de controle numa região de baixa velocidade.

Embora o nível de ruído apresentado pelo estimador seja elevado para esse ponto de operação, o valor médio é bastante aproximado ao valor medido. Neste trabalho não foi utilizado um filtro na saída do estimador, pois o objetivo era verificar a amplitude de tal oscilação. No primeiro teste a velocidade de referência é de 6 Hz, a qual pode ser considerada baixa para a utilização do controle escalar.

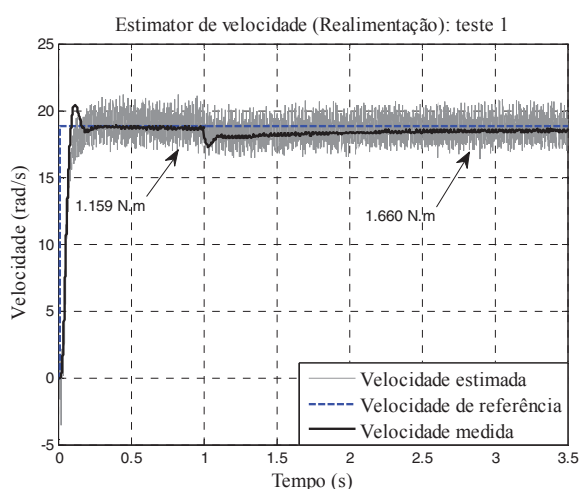


Fig. 9. Estimador de velocidade na realimentação da malha de controle para o teste 1.

No teste 6 a variação da referência seguiu o sentido de redução de velocidade, conforme mostra a Figura 10. O ruído na velocidade estimada apresentada em ambas as figuras se

justifica pela oscilação na corrente que atingiu valores fora do domínio de treinamento da RNA, assim como o apresentado em todos os resultados mostrados. Embora o sistema de controle tenha se mostrado mais oscilatório no transitório de velocidade, após a alteração da referência de velocidade (em 1 segundo), não foi observado instabilidade, pois a baixa frequência de cruzamento do sistema compensado atenua as variações abruptas do erro de velocidade apresentado ao controlador PI. Outra condição que torna o sistema robusto com relação à instabilidade é o fato de que a dinâmica mecânica é lenta quando comparada à dinâmica elétrica.

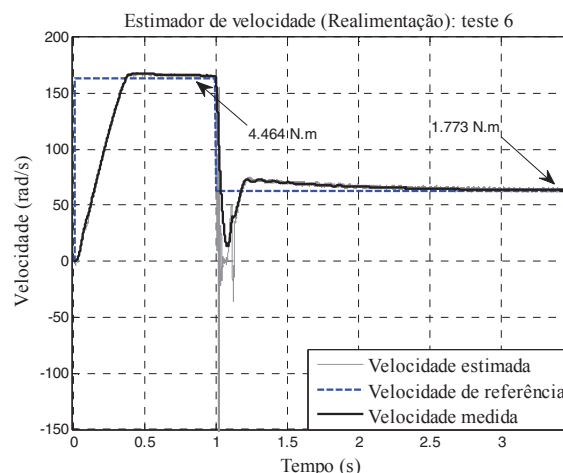


Fig. 10. Estimador de velocidade na realimentação da malha de controle para o teste 6.

A Tabela IV apresenta o Erro Relativo Médio (ERM) para o estimador atuando na realimentação do sistema de controle em cada um dos testes computacionais realizados. Pode-se observar que os testes 1 e 4 apresentaram maior erro de estimação. Esses testes ocorreram com a referência nas baixas velocidades de operação, região essa onde os sinais mensurados possuem elevados níveis de ruídos. Já o elevado erro obtido no teste 6 se deve ao maior tempo necessário para a estabilização da velocidade no primeiro instante de tempo (de 0 a 1 segundo).

TABELA IV
Parâmetros da RNA

Número do teste	ERM (%) do estimador na realimentação
1	3,51
2	1,17
3	0,67
4	3,00
5	0,70
6	4,21

As simulações apresentadas nesta subseção mostram a habilidade das RNAs em estimar a velocidade do motor de indução trifásico desde o transitório até o regime permanente, inclusive nas regiões de baixas velocidades de operação.

D. A Bancada Experimental.

Neste trabalho a experimentação prática visa confrontar os resultados obtidos via simulação, de um modelo matemático com a dinâmica do sistema físico.

Validar experimentalmente os sistemas avaliados primeiramente via simulação computacional é uma constante nos projetos de pesquisas atuais [29]. Nesse propósito, essa seção é dedicada à descrição dos principais componentes do laboratório de ensaios envolvidos no processo de aquisição de dados experimentais.

A bancada de ensaios é composta basicamente pela máquina de corrente contínua, que está acoplada ao MIT intermediado pelo torquímetro girante. Um tacogerador é acoplado à máquina de corrente contínua. A Figura 11 apresenta a bancada de ensaios. Ainda, nessa figura, são mostrados os conjuntos de condicionamentos dos sinais: *i*) de corrente e de tensão da máquina de corrente contínua, *ii*) condicionamento de sinais do torquímetro e *iii*) a placa de aquisição de dados. A máquina de corrente contínua está configurada para operar como Gerador de Corrente Contínua (GCC), cujo objetivo é impor conjugado resistente ao MIT. A tensão gerada na armadura do GCC é aplicada à carga resistiva. Dessa forma, foi possível variar o conjugado resistivo imposto pelo GCC ao MIT atuando na tensão de alimentação da bobina de campo através de uma fonte de corrente contínua.




Fig. 11. Estrutura geral do laboratório de ensaios de máquinas elétricas.

Os pulsos de comando das chaves de potência são gerados pelo módulo de controle do inversor de tensão. Este é composto por duas placas de condicionamento de sinais de corrente e de tensão, as quais recebem os sinais dos respectivos sensores Hall e adequam o sinal para as entradas do conversor A/D. Devido ao nível de tensão de saída do tacogerador faz-se necessário o uso de uma placa de condicionamento do sinal do dispositivo para a placa de aquisição de sinais e para o conversor A/D do *Digital Signal Processor* (DSP).

Apresenta-se também uma placa de condicionamento de sinais composto por um FPB de primeira ordem com frequência de corte de 1 kHz, responsável por reconstruir o sinal da velocidade estimada calculada pelo DSP que é apresentada em uma saída PWM com frequência de 24 kHz e uma placa de comando para o DSP contendo botão para acionamento do motor bem como dois potenciômetros para ajuste de velocidade e taxa de aceleração do MIT.

O DSP utilizado é o DSP TMS320F28335 da *Texas Instrument* associado ao kit de desenvolvimento eZDSP-TMS320F28335 fabricado pela empresa *Spectrum Digital*.

A placa de aquisição de dados utilizada nesse trabalho, a NI USB-6221 na *National Instruments*, tem como função adquirir os sinais do tacogerador, dos sensores Hall de corrente e tensão de alimentação do MIT, da velocidade estimada como saída do DSP, do torque mecânico e da velocidade de referência. Os dados adquiridos são formatados para representação gráfica e cálculo de desempenho do estimador e do controle de velocidade.

Dispostos todos esses elementos em laboratório e aferido o seu funcionamento, é iniciado o processo de testes para validação experimental da metodologia proposta neste trabalho.

E. Validação Experimental.

Nesta seção são apresentados os resultados obtidos com o controle realimentado com a velocidade estimada. Além disso, conforme será apresentado, a metodologia proposta é analisada em dois casos diferenciados. No primeiro caso (Caso 1) a validação experimental utiliza a estrutura apresentada nos resultados de simulação. Já no segundo caso (Caso 2), após a avaliação da resposta dinâmica da metodologia apresentada no primeiro caso, é proposta e validada uma nova alternativa, a qual considera a tensão no barramento cc.

1) *Caso 1*: Foram realizados cinco testes nas diversas condições apresentadas na Tabela V, onde para cada teste foram observados diferentes frequências de operação (F) em regime permanente. Para todos os testes realizados a variação da referência do ponto de operação tem uma taxa de aceleração de 50 rad/s^2 .

TABELA V
Pontos de Operação (Dados Experimentais – Caso 1)

Número do teste	Frequência de operação (Hz)			Torque de carga (N.m)		
	F. 1	F. 2	F. 3	F. 1	F. 2	F. 3
1	41,3	15,5	-	3,925	1,450	-
2	10,4	30,0	-	1,050	2,870	-
3		40,2		0,800	3,590	1,010
4		8,42		0,493	1,243	0,510
5	9,04	44,7	21,1	1,036	4,645	2,132

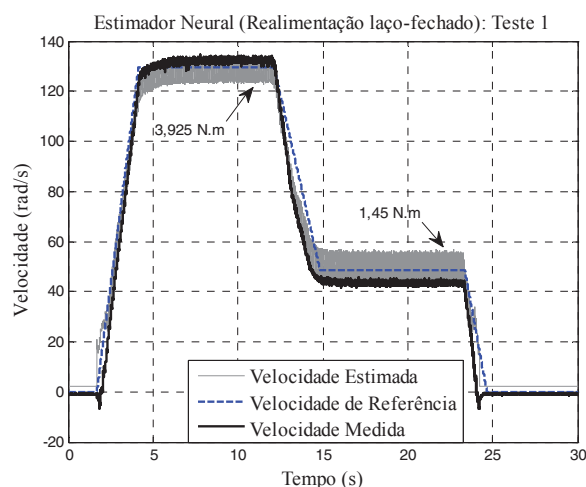


Fig. 12. Estimador de velocidade na realimentação do controle a laço-fechado – teste experimental 1.

As Figuras 12 e 13 mostram a resposta do estimador neural de velocidade quando o MIT é acionado a laço-fechado por meio da velocidade estimada pela RNA. Foram realizados os testes com variação de velocidade de referência e de conjugado de carga. O teste 1 mostra que para uma variação de 41,3 Hz para 15,5 Hz o controle manteve-se estável como o apresentado na Figura 10.

A Figura 13 apresenta o desempenho do sistema utilizando três frequências de operações diferentes, no caso, 9,04 Hz, 44,7 Hz e 21,1 Hz.

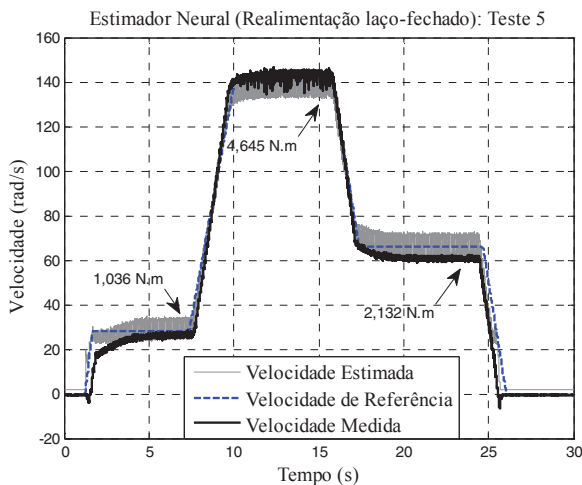


Fig. 13. Estimador de velocidade na realimentação do controle a laço-fechado – teste experimental 5.

A Tabela VI apresenta o ERM de velocidade do controle quando realimentado pela medida direta e estimada de velocidade dos resultados apresentados. O cálculo do ERM para as duas situações é calculado entre a velocidade medida em relação à referência sempre considerando o sistema em regime permanente. Deve ser ressaltado que nos testes 3 e 4 tem-se m frequência de operação e três valores de conjugado de carga impostos à máquina.

TABELA VI
ERM do Controle de Velocidade em Regime Permanente (Caso 1)

Número do teste	ERM (%) com estimador neural		
	F. 1	F. 2	F. 3
1	2,311	10,801	-
2	9,393	1,017	-
3	5,020	0,465	4,173
4	7,155	9,299	7,140
5	7,397	2,061	8,440

A principal dificuldade observada durante os testes experimentais ocorre em relação à variação da tensão no barramento cc do inversor, o que resulta na alteração da tensão de alimentação do MIT. A variação da tensão é dependente da carga do MIT, da capacitância do filtro do barramento cc e também da tensão da rede elétrica. Quanto maior a carga aplicada no eixo do MIT, maior é a corrente drenada pelo mesmo, o que resulta em uma maior ondulação da tensão do barramento cc, diminuindo assim sua tensão média. Observa-se que para uma frequência de operação fixa, em regime permanente, a variação do conjugado de carga do MIT ocasiona variação da velocidade estimada, mesmo com

o controle atuando de forma a manter a velocidade em torno da referência.

2) *Caso 2*: Com o intuito de melhorar o desempenho do estimador de velocidade, já observada a relevância do comportamento da tensão do barramento cc, é proposta uma nova estratégia para o estimador neural. A tensão do barramento cc passa a compor o conjunto de variáveis de entrada da RNA. No entanto, a utilização dessa nova variável implicaria no aumento de custo de implementação, pois um sensor adicional com o respectivo condicionamento de sinais seria necessário.

Para contornar a necessidade de um sensor adicional, propõe-se neste trabalho a estimativa da tensão do barramento cc a partir da tensão de barramento ideal (311 V), subtraída de uma parcela equivalente à queda de tensão em uma impedância do barramento (\hat{X}_{cc}), sendo esta proporcional à corrente drenada. Dessa forma, a interferência da variação da tensão do barramento pode ser estimada com as variáveis já mensuradas.

Com a adição dessa nova entrada na rede, o processamento de dados representado na Figura 3 foi alterado, como mostra a Figura 14. A corrente i é calculada como o módulo das componentes i_α e i_β . Já a impedância \hat{X}_{cc} foi estimada pela variação da tensão média do barramento cc em função da corrente i . Ao final de diversos ensaios experimentais realizados, obteve-se o valor equivalente a 1,02 Ω para \hat{X}_{cc} .

Diferentemente das demais entradas da RNA, somente a tensão estimada do barramento atual é utilizada, ou seja, a utilização das amostras atrasadas não é necessária devido à baixa frequência da ondulação da tensão do barramento cc. Assim, para otimizar o tempo de processamento e o espaço na memória de dados, somente a amostra atual da variável é usada.

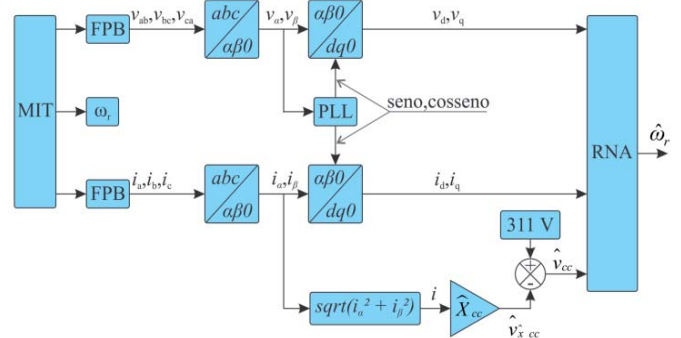


Fig. 14. Diagrama em blocos do processamento de dados modificado.

A estrutura geral do estimador, antes apresentada na Figura 5, foi reformulada e está apresentada na Figura 15.

A RNA foi novamente treinada utilizando a mesma estrutura anterior, adicionada à nova variável de entrada. Após isso, foi então constituído um novo conjunto de ensaios computacionais e experimentais para a validação da proposta. Seguindo a mesma metodologia de testes utilizada anteriormente, foram realizados mais dez ensaios respeitando os mesmos critérios.

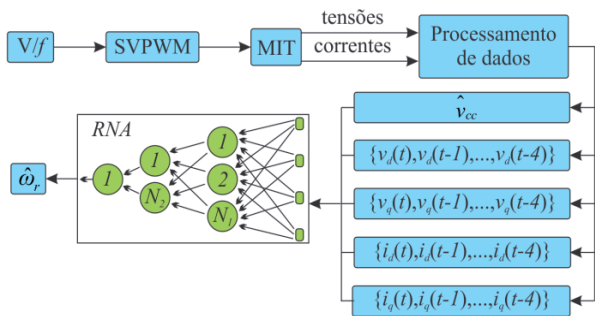


Fig. 15. Diagrama estrutural do estimador modificado.

Primeiramente, cinco testes (6 ao 10) foram realizados com o controle escalar a laço-fechado utilizando a medida direta de velocidade. Posteriormente, a velocidade usada é utilizada na realimentação do sistema de controle (testes 11 a 15). A Tabela VII apresenta os parâmetros dos testes realizados.

TABELA VII

Pontos de Operação (Dados Experimentais - Caso 2)

Número do teste	Frequência de operação (Hz)			Torque de carga (N.m)		
	F. 1	F. 2	F. 3	F. 1	F. 2	F. 3
6	46,4	25,01	-	4,153	2,375	-
7	20,0	45,82	-	1,982	4,163	-
8		29,71		2,409	4,333	2,416
9		5,81		0,429	1,020	0,419
10	5,81	45,2	22,1	0,718	4,404	2,315
11	46,02	19,47	-	4,094	1,919	-
12	19,68	44,27	-	1,918	3,874	-
13		29,04		0,521	3,050	0,526
14		6,55		0,428	1,237	0,666
15	5,71	43,13	21,62	0,776	4,577	2,497

Nesta fase de testes a proposta é comparada com a metodologia tradicional de controle da máquina; ou seja, através da realimentação de velocidade com tacogerador [3]. O resultado obtido para a variação da velocidade de referência apresentado é relativo à mudança de frequência de ajuste 46,4 Hz para 25,01 Hz e é mostrado na Figura 16.

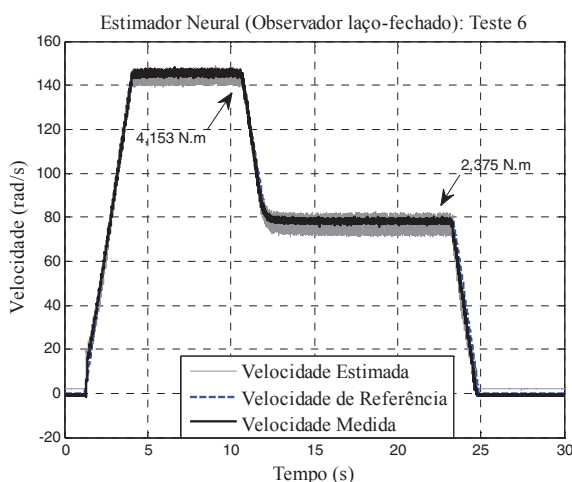


Fig. 16. Estimador de velocidade como observador no controle a laço-fechado – teste experimental 6.

A seguir são apresentados os resultados obtidos utilizando a nova abordagem de variáveis de entrada da RNA, tendo agora, a velocidade estimada como variável de realimentação

do sistema de controle. As Figuras 17 a 18 apresentam a resposta do estimador neural de velocidades quando o MIT é acionado a laço-fechado através da velocidade estimada pela RNA.

Seguindo os mesmos procedimentos realizados nos testes de 6 a 10, foram realizados primeiramente os testes de variação da velocidade de referência. O teste 11 mostra que, através da Figura 17, para uma variação de 46,02 Hz para 19,47 Hz, o controle manteve-se estável para a variação de 4,094 N.m para 1,919 N.m. A Figura 18 apresenta os resultados obtidos para três frequências de operação diferentes, no caso: 5,71 Hz, 43,13 Hz e 21,62 Hz. Ainda na Figura 18, a sobrecarga foi considerada (4,577 N.m) para a máquina operando na F. 2 do teste em questão executado.

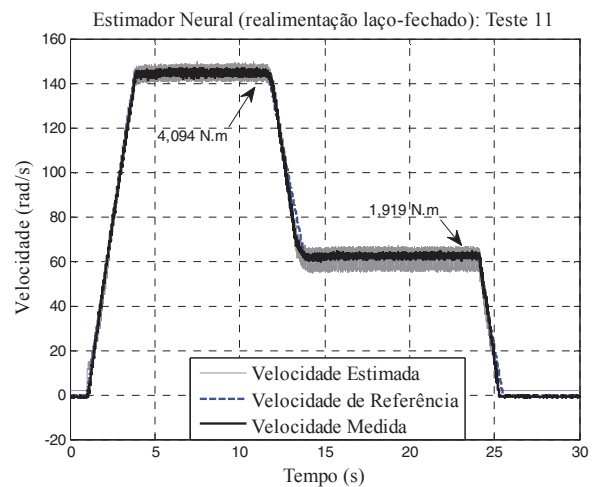


Fig. 17. Estimador de velocidade na realimentação do controle a laço-fechado – teste experimental 11.

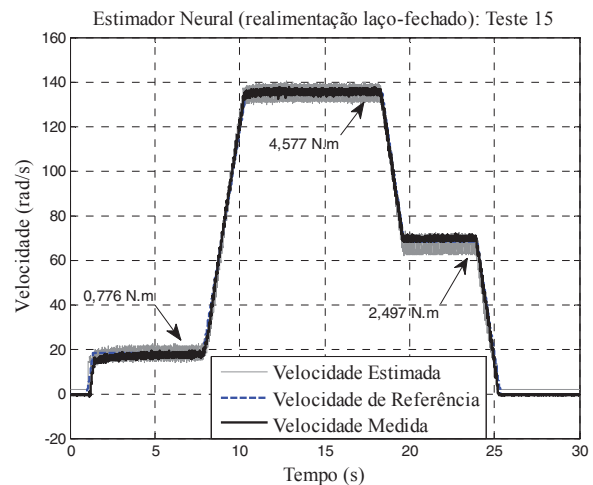


Fig. 18. Estimador de velocidade na realimentação do controle a laço-fechado – teste experimental 15.

As respostas apresentadas no Caso 2, onde a utilização da tensão estimada do barramento cc foi introduzida como entrada do estimador neural, demonstram uma diminuição significativa do ERM. A Tabela VIII apresenta o ERM de velocidade do controle quando realimentado pela medida direta e estimada de velocidade dos resultados apresentados no Caso 2.

TABELA VIII
ERM do Controle de Velocidade em Regime Permanente
(Caso 2)

Número do teste	ERM (%) com tacogerador			ERM (%) com estimador neural		
	F. 1	F. 2	F. 3	F. 1	F. 2	F. 3
6	0,268	0,513	-	-	-	-
7	0,762	0,321	-	-	-	-
8	0,313	0,374	0,340	-	-	-
9	2,333	2,420	2,391	-	-	-
10	0,268	0,509	0,759	-	-	-
11	-	-	-	0,247	1,866	-
12	-	-	-	1,842	0,549	-
13	-	-	-	1,608	0,505	1,857
14	-	-	-	2,326	1,401	2,197
15	-	-	-	2,667	0,244	2,656

Observa-se que os erros apresentados nos testes 11 e 15 (Figuras 17 e 18) possuem valores significativos. Isto ocorreu pois os resultados foram obtidos considerando tanto o regime transitório quanto o permanente. Quando foi considerado apenas o estado estacionário estes apresentaram menor influência, resultando em um ERM compatível com a realimentação direta de velocidade por meio do tacogerador.

Os resultados mostram uma melhora no desempenho do estimador nas condições avaliadas, ou seja, variação de velocidade e de conjugado de carga. Nota-se também que o erro existente entre a velocidade estimada e a medida é tolerável, viabilizando a utilização do estimador em aplicações de supervisão de velocidade em *driver* de acionamento ou mesmo em sistemas de controle do MIT. O estudo comparativo que os autores realizaram foi considerando o erro em relação a medida direta da variável para o mesmo controlador PI.

O estimador de velocidade proposto é comparado com a medida direta da velocidade no eixo quando ambos são aplicados a mesma estratégia de controle PI. O erro máximo com o estimador no Caso 2 foi de 2,667% e com a medida direta foi de 2,42%. Na referência [3] foi apresentada uma tabela comparativa de erro em relação a três estratégias de controle escalar com realimentação direta de velocidade. A Tabela II do referido trabalho reflete o comparativo entre estratégias de controle aplicado a estratégia V/f com realimentação direta da velocidade e a estratégia PI apresentou um erro de 4,18%.

IV. CONCLUSÕES

Este trabalho propôs uma metodologia alternativa para estimar a velocidade do motor de indução acionado por um inversor de tensão com controle escalar a laço-fechado utilizando modulação SVPWM, baseado em uma rede neural artificial TDNN com treinamento supervisionado *off-line*. A metodologia proposta estima a velocidade desde o transitório ao regime permanente, compreendendo toda a faixa de operação do controle escalar.

Num primeiro momento, a proposta foi validada conforme os resultados de simulação apresentados para condições de variação de torque de carga com o motor em regime permanente e variação de velocidade de referência, objetivando demonstrar a robustez da metodologia. Os testes do estimador neural de velocidade foram realizados. Neste

contexto, os resultados de simulação apresentaram reduzido erro relativo médio em todos os pontos de operação de 0,67% a 4,21% atuando na realimentação do sistema de controle.

A proposta foi também avaliada em bancada experimental com emulação de carga linear no eixo da máquina. No Caso 1, o estimador neural é testado nas mesmas condições apresentadas via simulação. O ERM apresentado ficou compreendido entre 1,017% e 10,801% com o controle a laço-fechado quando comparado à medida direta de velocidade. No entanto, observou-se que a variação da tensão do barramento cc, a qual é dependente da potência drenada pelo inversor, prejudicou o desempenho do controle com o estimador neural.

Uma vez detectado a dependência do estimador em relação a tensão do barramento cc, foi proposta uma segunda metodologia de estimação dessa variável, onde esta passou a compor o conjunto de dados de entrada para a RNA. Foram realizadas mais 375 simulações visando formar um novo conjunto de treinamento. Após o re-treinamento da mesma arquitetura de RNA do Caso 1, o novo estimador foi implementado e testado em bancada experimental no Caso 2. Nesta situação o estimador neural foi avaliado com o método tradicional de controle; ou seja, com a realimentação da velocidade através de um tacogerador. Nessas condições o ERM apresentado ficou compreendido entre 0,268% a 2,420%. Quando a tensão estimada do barramento cc participou da operação da RNA, o desempenho teve uma melhora significativa, validando assim a proposta em aplicações de monitoramento de controle de motores de indução trifásicos. Assim, quando o estimador neural atuou no laço de realimentação o erro de velocidade no eixo em relação ao *set-point* variou entre 0,247% a 2,677%. Estes resultados são muito próximos daqueles com realimentação direta da velocidade através de um sensor de velocidade. Entretanto, a faixa de erro obtida, por estimador ou realimentação da velocidade, pode ser elevada para determinados tipos de plantas que exigem controle muito preciso de velocidade. Neste caso, outras estratégias de controle devem ser abordadas.

AGRADECIMENTOS

Os autores agradecem ao CNPq pelo apoio financeiro do CNPq (Processos 474290/2008-5, 473576/2011-2, 552269/2011-5), Fundação Araucária (Processo 06/56093-3) e CAPES.

REFERÊNCIAS

- [1] F. Immovilli, C. Bianchini, M. Cocconcelli, A. Bellini, R. Rubini, "Bearing Fault Model for Induction Motor with Externally Induced Vibration" *IEEE Transactions on Industrial Electronics*, Volume: vol. 60, no. 8, pp. 3408-3418, 2012.
- [2] R. Trabelsia, A. Khedherb, M. F. Mimounic, F. M'sahlic, "Backstepping control for an induction motor using an adaptive sliding rotor-flux observer", *Electric Power Systems Research*, vol. 93, pp. 1-15, 2012.

- [3] M. Suetake, I. N. Silva, A. Goedel, "Embedded dsp-based compact fuzzy system and its application for induction-motor v/f speed control". *IEEE Transactions on Industrial Electronics*, vol. 58, n° 3, pp. 750-760, mar 2011.
- [4] B. K. Bose, *Modern Power Electronics and AC Drives*, Prentice Hall, 2002.
- [5] M. A. Vogelsberger, S. Grubic, T. G. Habetler, T. M. Wolbank, "Using PWM-Induced Transient Excitation and Advanced Signal Processing for Zero-Speed Sensorless Control of AC Machines", *IEEE Transactions on Industrial Electronics*, vol. 57, no. 1, pp. 365-374, 2010.
- [6] L. M. R. Baccarinia, J. P. B. Tavares, B. R. de Menezes, W. M. Caminhas, "Sliding mode observer for on-line broken rotor bar detection", *Electric Power Systems Research*, vol. 80, pp. 1089-1095, 2010.
- [7] P. VAS, *Sensorless Vector and Direct Torque Control*. Oxford: Oxford University Press, 1998.
- [8] C.-H. Tsai, M.-F. Yeh, "Application of CMAC neural network to the control of induction motor drives", *Applied Soft Computing*, vol. 9, pp. 1187-1196, 2009.
- [9] M. A. Vogelsberger, S. Grubic, T. G. Habetler, T. M. Wolbank, "Using PWM-Induced Transient Excitation and Advanced Signal Processing for Zero-Speed Sensorless Control of AC Machines", *IEEE Transactions on Industrial Electronics*, vol. 57, no. 1, pp. 365-374, 2010.
- [10] M. Jouili, K. Jarrayb, Y. Koubaaa, M. Boussake, "Luenberger state observer for speed sensorless ISFOC induction motor drives", *Electric Power Systems Research*, vol. 89 pp. 139-147, 2012.
- [11] S. Kumar, J. Prakash, P. Kanagasabapathy, "A critical evaluation and experimental verification of Extended Kalman Filter, Unscented Kalman Filter and Neural State Filter for state estimation of three phase induction motor", *Applied Soft Computing*, vol. 11, pp. 3199-3208, 2011.
- [12] J. Guzinski, H. Abu-Rub, "Speed Sensorless Induction Motor Drive With Predictive Current Controller", *IEEE Transactions on Industrial Electronics*, vol. 60, no. 2, pp. 699-709, 2012.
- [13] P. Vaclavek, P. Blaha, I. Herman, "AC Drives Observability Analysis", *IEEE Transactions on Industrial Electronics*, vol. 60, no. 8, pp. 3047-3059, 2013.
- [14] W.-M. Lin; T.-J. Su; R.-C. Wu, "Parameter Identification of Induction Machine With a Starting No-Load Low-Voltage Test", *IEEE Transactions on Industrial Electronics*, vol. 59, pp. 352-360, 2012.
- [15] V. Vasic, S. Vukosavic, E. Levi, "A stator resistance estimation scheme for speed sensorless rotor flux oriented induction motor drives". *IEEE Transactions on Energy Conversion*, vol. 18, no. 4, pp. 476-483, dec. 2003.
- [16] B. K. Bose, *Modern Power Electronics and AC Drives*. New Jersey, Prentice-Hall, 2001.
- [17] I. Mustafa, F. Mustafa, A. Ahmed, "A speed estimation unit for induction motors based on adaptive linear combiner". *Elsevier Energy and Management*, vol 50, no. 7, pp. 1664-1670, Jul. 2009.
- [18] O. Yoksel, D. Mehmet, "Speed estimation of vector controlled squirrel cage asynchronous motor with artificial neural networks". *Elsevier Energy and Management*, vol. 52, no. 1, pp. 675-686, Jan. 2011.
- [19] S. M. Gadoue, D. Giaouris, J. W. Finch, "Sensorless control of induction motor drives at very low and zero speeds using neural network flux observers". *IEEE Transactions on Industrial Electronics*, vol. 56, no. 8, pp. 3029-3039, Aug. 2009.
- [20] S. M. Gadoue, D. Giaouris, J. W. Finch, "An experimental assessment of a stator current MRAS based on neural networks for sensorless control of induction machines". *IEEE Symposium on Sensorless Control for Electrical Drives (SLED)*. Austin Court, Birmingham, UK, pp. 102-106, 2011.
- [21] C. Garcia, *Modelagem e Simulação*. São Paulo, SP: Edusp, 1997.
- [22] C.-M. Ong, *Dynamic Simulation of Electric Machinery: Using Matlab/Simulink*. Upper Sanddle River, NJ: Prentice-Hall, 1998.
- [23] P. C. Krause, O. Wasynczuk, S. D. Sudhoff, *Analysis of Electric Machinery and Drive Systems*. Picataway, NJ: Academic Press, 2002.
- [24] H. V. D. Broeck, H.-C. Skudelny, G. Stanke, "Analysis and realization of a pulsewidth modulator based on voltage space vectors". *IEEE Transactions on Industry Applications*, vol. 24, no. 1, pp. 142-150, jan/feb 1988.
- [25] R. Krishnan, *Electric Motor Drives: Modeling, Analysis and Control*. Upper Sanddle River, NJ: Prentice-Hall, 2001.
- [26] L. Guo, L. Parsa, "Model Reference Adaptive Control of Five-Phase IPM Motors Based on Neural Network", *IEEE Transactions on Industrial Electronics*, vol. 59, no. 3, pp. 1500-1508, 2012.
- [27] C.-K. Lin, "Radial basis function neural network-based adaptive critic control of induction motors", *Applied Soft Computing*, pp. 3066-3074, 2011.
- [28] S. A. O. Silva, P. F. Donoso-Garcia, P. C. Cortizo, and P. F. Seixas, "A three-phase line-interactive UPS system implementation with series-parallel active power-line conditioning capabilities," *IEEE Transactions on Industry Applications*, vol. 38, no. 6, pp. 1581-1590, Nov/Dec. 2002.
- [29] A. Goedel, *Speed estimaton in three phase induction motors*. Doctorate Thesis (in Portuguese), Universidade de São Paulo, São Carlos, SP, 2007.

DADOS BIOGRÁFICOS

Tiago Henrique dos Santos, nascido em 16/06/1984 em Cambé-PR, é tecnólogo em automação industrial (2008) pela Universidade Tecnológica Federal do Paraná (UTFPR-CP); mestre engenharia elétrica (2012) pela Universidade Tecnológica Federal do Paraná (UTFPR-CP).

Atualmente é professor do Departamento de Controle e Processos Industriais do Instituto Federal do Paraná (IFPR).

Suas áreas de interesse são: acionamento de máquinas elétricas, sistemas inteligentes e eletrônica de potência.

Alessandro Goedel, nascido em 12/02/1972 em Arroio do Meio-RS, é engenheiro eletricitista (1996) pela Universidade Federal do Rio Grande do Sul (UFRGS-DEE); mestre em engenharia industrial (2003) pela Universidade Estadual Paulista (UNESP-FEB) e doutor em engenharia elétrica (2007) pela Escola de Engenharia de São Carlos (EESC) da Universidade de São Paulo (USP).

Atualmente é professor do Departamento de Engenharia Elétrica da Universidade Tecnológica Federal do Paraná (UTFPR-CP).

Suas áreas de interesse são: acionamento de máquinas, sistemas inteligentes e ensino de Engenharia Elétrica. É membro da SBA e do IEEE.

Sérgio Augusto Oliveira da Silva, nascido em 07/07/1964 em Joaquim Távora-PR, é engenheiro eletricitista (1987) e mestre em engenharia elétrica (1989) pela Universidade Federal de Santa Catarina (UFSC); e doutor em engenharia elétrica (2001) pela Universidade Federal de Minas Gerais.

Atualmente é professor do Departamento de Engenharia Elétrica da Universidade Tecnológica Federal do Paraná, Campus Cornélio Procopio (UTFPR-CP).

Suas áreas de interesse são: filtros ativos de potência, sistemas de energia ininterrupta (UPS), sistemas de controle empregando DSP, qualidade da energia elétrica e ensino de Engenharia Elétrica. É membro da SOBRAEP e do IEEE.

Marcelo Suetake, nascido em 22/12/1981 em Rinópolis-SP, é engenheiro eletricitista (2005) pela Universidade Estadual Paulista (UNESP-BAURU); mestre (2008) e doutor (2012) em engenharia elétrica pela Escola de Engenharia de São Carlos (EESC) da Universidade de São Paulo (USP).

Atualmente é professor do curso de Engenharia Elétrica da Universidade Federal de São Carlos (UFSCar).

Suas áreas de interesse são: acionamento e controle de máquinas elétricas, sistemas inteligentes e conversão da energia elétrica.