

Received November 22, 2023; accepted February 28, 2024; Date of publication April 09, 2024. 
The review of this paper was arranged by Associate Editor Allan Cupertino  and Editor-in-Chief Telles Brunelli Lazzarin .

Digital Object Identifier <http://doi.org/10.18618/REP.2024.1.0035>

Comparação de Estratégias de Controle Preditivo e Direto de Torque para Motores de Indução

Rafael Figueiredo ¹, Igor Oliani ¹, Angelo S. Lunardi ¹, Alfeu J. Sguarezi Filho ¹, Daniel Albiero ², Marcello Mezaroba ³

¹Universidade Federal do ABC, Fundação Universidade Federal do ABC, Santo André – SP, Brasil.

²Universidade Estadual de Campinas, Faculdade de Engenharia Agrícola da Unicamp, Campinas – SP, Brasil.

³Universidade do Estado de Santa Catarina, Departamento de Engenharia Elétrica, Joinville – SC, Brasil.

e-mail: rafael.figueiredo@ufabc.edu.br, igor.oliani@ufabc.edu.br, angelo.lunardi@ufabc.edu.br, alfeu.sguarezi@ufabc.edu.br, dalbiero@unicamp.br, marcello.mezaroba@udesc.br

RESUMO As mudanças climáticas e a tendência de eletrificação causada pelo uso de energias renováveis incentiva a pesquisa em eletrificação de sistemas e direciona parte do interesse a tecnologias de acionamentos elétricos. Dentre os motores usados em acionamentos modernos, os motores de indução trifásicos mostram-se competitivos dado o seu baixo custo, elevada robustez e maturidade tecnológica. Este artigo explora métodos de controle direto de torque e fluxo, com destaque para controles preditivos, promissores por sua resposta dinâmica rápida e flexibilidade com não linearidades. São analisados resultados experimentais do DTC, PTC, PTC-DSVM e MPTC na mesma bancada. Os resultados demonstram por meio das respostas dinâmica, em regime e THD as diferenças entre estratégias e mostram que a frequência fixa do MPTC não se relaciona diretamente à melhor qualidade de energia no acionamento. O custo computacional também é medido para complemento das análises.

PALAVRAS-CHAVE Controle Direto de Torque, Controle Preditivo Baseado em Modelo, Controle Preditivo Modulado, Controle Preditivo de Torque, Motor de Indução.

Predictive and Direct Torque Control Strategies Comparison for Induction Motors

ABSTRACT Climate change and the expansion of renewable energy encourage research on system electrification, and part of this attention is directed to motor drive technology. Among the electrical machines used in modern drives, three-phase induction motors are competitive due to their low cost, high robustness, and technological maturity. This article explores direct torque and flux control methods, with an emphasis on model-based predictive controls, which are promising due to their fast dynamic response and flexibility with non-linearities. The DTC, PTC, PTC-DSVM, and MPTC are analyzed on the same experimental bench. Results of dynamic response, steady state and THD show the differences between strategies and that the fixed frequency of MPTC does not directly translate to an improvement of energy quality. The computational burden is also measured for a deeper comparison.

KEYWORDS Direct Torque Control, Induction Motor, Model Predictive Control, Predictive Torque Control, Modulated Predictive Control.

I. INTRODUÇÃO

As recorrentes consequências da mudança climática fazem governos e a sociedade acelerarem o uso de energia renovável e, devido as características das fontes renováveis (localização, sazonalidade, variabilidade) há um incentivo a eletrificação de sistemas, como transporte [1], e a busca por melhoria de eficiência energética em sistemas já eletrificados [2].

Os motores elétricos são os maiores consumidores de energia atualmente conectados à rede elétrica por ser uma forma eficiente de transformar energia elétrica em trabalho [3]. Isto leva a um contínuo aumento na pesquisa voltado a eficiência energética e desempenho de máquinas elétricas e sistemas de acionamento [2].

Dentre os sistemas de acionamento de alto desempenho e eficiência, os motores mais comuns são os motores síncronos de ímã permanente (MSIP), motores de relutância síncrona (assistido ou não por ímãs) (MRS) e os motores de indução (MI) [4].

O MI tem seu processo de produção amplamente conhecido e documentado, sendo o motor mais barato, em geral, e com elevada robustez já que não tem risco de sofrer desmagnetização por sobrecorrente e temperatura [3]. Além disso, ao utilizar rotores de cobre pode alcançar eficiência e densidade de torque a par com as máquinas síncronas [5]. Em [4] e [6] os autores fazem um estudo comparativo e abordam formas de se melhorar eficiência dos MIs.

A. Estratégias de Controle de MIs

Os sistemas de acionamento de MIs modernos usam modelos vetoriais para realizar controle desacoplado de fluxo magnético e torque. As estratégias mais difundidas são o controle direto de torque do inglês, *Direct Torque Control* – DTC, onde o modelo utilizado usa as equações de torque e fluxo para o controle, e o controle orientado por campo (do inglês, *Field Oriented Control* – FOC), que pode utilizar tensões ou correntes para controlar o torque e fluxo indiretamente.

O DTC, proposto por [7] em 1986, é o método clássico que utiliza controladores de histerese para controlar o fluxo e torque e não utiliza modulador; usa uma Tabela de chaveamento para controlar o inversor de saída. Essa combinação faz que o controle de torque tenha uma resposta dinâmica rápida, enquanto apresenta uma frequência de chaveamento variável.

Entre as recentes estratégias de controle, o controle preditivo (do inglês, *Predictive Torque Control*) – PTC, proposto por [8], baseia-se na teoria do controle preditivo baseado em modelo (do inglês, *Model Predictive Control*) – MPC para modernizar o controle direto de torque, tornando a resposta dinâmica mais rápida e também permite adicionar restrições e não linearidades complexas, o que não é possível no DTC ou FOC [9], como por exemplo limite de corrente, penalização de esforço e penalização de frequência de chaveamento [9].

Nesta estratégia o modelo do motor é discretizado para controlar o torque e fluxo a partir de uma função de custo que minimiza o erro de controle [10]. O PTC utiliza um modelo por estados finitos (do inglês, *Finite Control Set-FCS*) do próprio inversor, que permite a aplicação de 7 vetores de tensão distintos nos terminais da máquina, o que elimina a necessidade de modulador e gera uma saída de frequência variável.

O PTC, entretanto, apresenta um alto *ripple* de torque e fluxo em regime permanente, que aparecem devido a falta de modulação do sinal de saída. Este *ripple* pode ser compensado aumentando a frequência de amostragem do controlador [11], porém isto aumenta rapidamente o custo computacional tornando inviável o cálculo em tempo real das predições.

Uma estratégia para mitigar o *ripple* é o uso de um modulador discreto por vetores espaciais (do inglês, *Discrete Space Vector Modulation* – DSVM) [11] [12] [13]. O tempo de amostragem do controlador é dividido em n partes iguais – normalmente em três ou duas, como visto em [14] – para a formação de vetores tensão virtuais durante um tempo de amostragem. A cada tempo de amostragem a função de custo é calculada considerando o vetor virtual e em seguida o inversor é chaveado n vezes por tempo de amostragem.

Outra possibilidade para mitigar o *ripple* em regime permanente e em baixas cargas é utilizar um modulador em conjunto ao controlador preditivo [15] [16] [17]. Assim, a estratégia se torna um *Continuous Control Set* (ou M2PC, *Modulated Model Predictive Control*) ou MPTC (*Modulated Predictive Torque Control*) quando utilizado com o PTC [18].

Em geral, estas estratégias encontram o setor no plano complexo dos vetores tensão onde existe menor erro e calculam o *duty cycle* de cada vetor para sintetizar a tensão desejada através de um padrão de chaveamento SVM (*Space Vector Modulation*) [15] [19]. Desta forma o inversor consegue gerar a tensão necessária para controle com boa modulação e diminuindo o *ripple* em regime permanente e baixa carga. Contudo, esta estratégia tem alguns problemas em relação ao modelo preditivo de busca exaustiva: aproveitamento do barramento CC é limitado [19], pode ocorrer o cálculo impreciso dos *duty cycles* em caso de sobremodulação [12] [19] ou sub otimizações com a presença de mais termos na função de custo (como limite de corrente ou penalização de esforço) [17].

B. Estrutura e Contribuição do Trabalho

Este artigo compara as estratégias de controle direto de torque para motores de indução: DTC, PTC, PTC-DSVM e MPTC, com enfoque nos preditivos e no resultados do MPTC, solução de frequência fixa que argumenta melhora em *ripples* de controle e THD.

As estratégias são comparadas em bancada, implementando os controles no mesmo *DSP*, sensores, tratamento de sinais, máquina e carga, mostrando um comparativo mais realista que o obtido em simulações ou testes em *Hardware in Loop* (HIL).

São analisados resultados de resposta dinâmica e de regime permanente para torque, fluxo e velocidade, mostrando comparações mais abrangentes e diretas comparado com a literatura, onde não há uma comparação direta do incluindo o MPTC [20] [21].

II. MODELAGEM DOS SISTEMAS

Esta seção mostra a modelagem dinâmica do motor de indução e a modelagem elétrica do inversor fonte de tensão trifásico (do inglês, *Voltage Source Inverter* – VSI).

A. Motor de Indução

O modelo dinâmico do motor de indução adotado neste artigo usa uma representação em vetores espaciais no referencial estacionário [8]. A representação neste referencial, em relação ao referencial dq alinhado ao fluxo pode ajudar na robustez, já que erros de parâmetros do modelo não incidem sobre a orientação de campo [22] [23].

$$\vec{v}_{\alpha\beta,s} = R_s \vec{i}_{\alpha\beta,s} + \frac{d\vec{\psi}_{\alpha\beta,s}}{dt} \quad (1)$$

$$\vec{v}_{\alpha\beta,r} = R_r \vec{i}_{\alpha\beta,r} + \frac{d\vec{\psi}_{\alpha\beta,r}}{dt} = 0 \quad (2)$$

$$\vec{\psi}_{\alpha\beta,s} = L_s \vec{i}_{\alpha\beta,s} + L_m \vec{i}_{\alpha\beta,r} \quad (3)$$

$$\vec{\psi}_{\alpha\beta,r} = L_m \vec{i}_{\alpha\beta,s} + L_r \vec{i}_{\alpha\beta,r} \quad (4)$$

$$T_e = \frac{3}{2} p \{ \vec{\psi}_{\alpha\beta,s}^* \times \vec{i}_{\alpha\beta,s} \}. \quad (5)$$

L_s e L_r são as indutâncias próprias do estator e do rotor, L_m é a indutância mútua. As resistências do estator e rotor são R_s e R_r . A tensão do estator é denominada $\vec{v}_{\alpha\beta s}$ e a corrente do estator é $\vec{i}_{\alpha\beta s}$. O fluxo do estator é representado por $\vec{\psi}_{\alpha\beta s}$ e o fluxo do rotor por $\vec{\psi}_{\alpha\beta r}$. T_e e p representam o torque eletromagnético e número de par de polos da máquina. O asterisco é usado para representar o complexo conjugado de um vetor.

B. Inversor Trifásico

O motor de indução é alimentado por um VSI de dois níveis (Figura 1). Este tipo de inversor tem seis chaves controladas (IGBTs ou MOSFETs) e oito possíveis estados de chaveamento: seis ativos, com diferentes tensões de saída, e dois nulos, com tensão igual a zero.

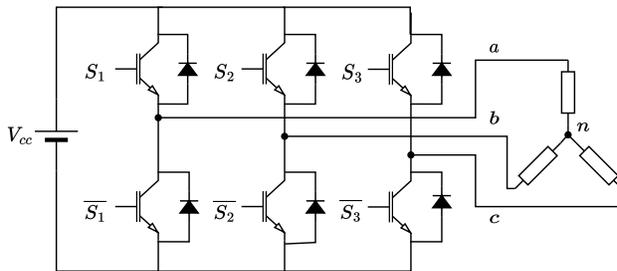


FIGURA 1. Topologia do Inversor Fonte de Tensão de dois níveis.

A Tabela 1 mostra as tensões de chaveamento para cada estado do VSI no referencial $\alpha\beta$. S_1 , S_2 e S_3 são os estados das chaves eletrônicas para cada vetor tensão descrito.

TABELA 1. Estados de Chaveamento e Tensões do VSI

| Vetor | S_1 | S_2 | S_3 | $\vec{v}_{\alpha\beta,s}^x$ |
|-----------------------------|-------|-------|-------|--|
| $\vec{v}_{\alpha\beta,s}^0$ | 0 | 0 | 0 | $0 V_{cc}$ |
| $\vec{v}_{\alpha\beta,s}^1$ | 1 | 0 | 0 | $\frac{2}{3} V_{cc}$ |
| $\vec{v}_{\alpha\beta,s}^2$ | 1 | 1 | 0 | $(\frac{1}{3} + j\frac{\sqrt{3}}{3})V_{cc}$ |
| $\vec{v}_{\alpha\beta,s}^3$ | 0 | 1 | 0 | $(-\frac{1}{3} + j\frac{\sqrt{3}}{3})V_{cc}$ |
| $\vec{v}_{\alpha\beta,s}^4$ | 0 | 1 | 1 | $-\frac{2}{3} V_{cc}$ |
| $\vec{v}_{\alpha\beta,s}^5$ | 0 | 0 | 1 | $(-\frac{1}{3} - j\frac{\sqrt{3}}{3})V_{cc}$ |
| $\vec{v}_{\alpha\beta,s}^6$ | 1 | 0 | 1 | $(\frac{1}{3} - j\frac{\sqrt{3}}{3})V_{cc}$ |
| $\vec{v}_{\alpha\beta,s}^7$ | 1 | 1 | 1 | $0 V_{cc}$ |

III. MODELAGEM DOS CONTROLADORES

Esta seção é destinada à modelagem dos controladores diretos de torque: DTC, PTC, PTC-DSVM e MPTC.

A. DTC – Direct Torque Control

No DTC proposto por [7] (Figura 2), o torque eletromagnético e a magnitude do fluxo do estator são controlados através da seleção direta da melhor estratégia de chaveamento do inversor entre os 8 vetores possíveis (Tabela 1).

São desconsideradas a queda de tensão no enrolamento do estator e a dinâmica do fluxo para um tempo de amostragem T_s pequeno o suficiente.

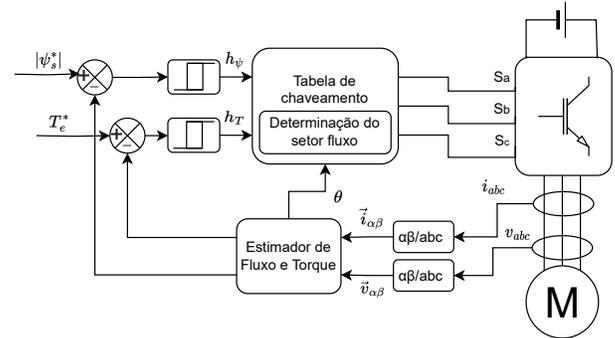


FIGURA 2. Diagrama de Blocos do DTC.

O estado de chaveamento é escolhido a partir de uma Tabela de chaveamento pré definida, que tem como entrada os sinais de comando para aumentar ou diminuir o torque h_T e fluxo h_ψ – vindos de controladores por histerese [7] – e a posição do fluxo do estator $\vec{\psi}_{\alpha\beta,s}$ no plano $\alpha\beta$ denotada pelo símbolo θ .

O torque é estimado usando (5). O vetor fluxo do estator é estimado com o modelo do integrador (6), derivado de (3):

$$\vec{\psi}_{\alpha\beta s} = \int (\vec{v}_{\alpha\beta s} - R_s \vec{i}_{\alpha\beta s}) dt. \quad (6)$$

B. PTC – Predictive Torque Control

O PTC, descrito por [8] (Figura 3), usa o modelo do motor e do inversor para prever os valores futuros de fluxo e torque. Juntando as referências de controle com os valores das predições em uma função de custo é possível otimizar a escolha de chaveamento do inversor para atingir a resposta desejada do sistema.

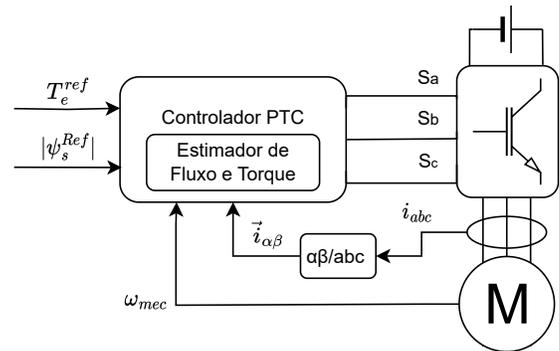


FIGURA 3. Diagrama de blocos do PTC.

Para realizar as predições, o modelo do motor é discretizado utilizando o método de Euler para os instantes $[k]$ e $[k+1]$. Isso traz vantagens na aplicação em sistemas digitais, já que o método de controle é naturalmente discretizado [8].

Dentro da rotina do algoritmo de controle, o primeiro passo é a estimação do fluxo do estator e rotor. O estimador

utilizado é o mesmo que foi utilizado no DTC (6), mas sob a forma discretizada em (7). O fluxo do rotor em (8) é obtido através da combinação de (3) com (4) em suas formas discretizadas.

$$\vec{\psi}_{\alpha\beta,s}[k] = \vec{\psi}_{\alpha\beta,s}[k-1] + T_s(\vec{v}_{\alpha\beta,s}[k-1] - R_s\vec{i}_{\alpha\beta,s}[k]) \quad (7)$$

$$\vec{\psi}_{\alpha\beta,r}[k] = \frac{L_r}{L_m}\vec{\psi}_{\alpha\beta,s}[k] + \vec{i}_{\alpha\beta,s}[k]\left(L_m - \frac{L_r L_s}{L_m}\right). \quad (8)$$

Em seguida é realizada a predição do fluxo em (9), assim como da corrente do estator em (10), utilizada para realizar a predição de torque (11) no instante $[k+1]$. Por fim, o torque eletromagnético é calculado em (11).

$$\vec{\psi}_{\alpha\beta,s}[k+1] = \vec{\psi}_s[k] + T_s(\vec{v}_{\alpha\beta,s}^p[k] - R_s\vec{i}_{\alpha\beta,s}[k]) \quad (9)$$

$$\vec{i}_{\alpha\beta,s}^p[k+1] = \left(1 + \frac{T_s}{\tau_\sigma}\right)\vec{i}_{\alpha\beta,s}[k] +$$

$$\frac{T_s}{\tau_\sigma + T_s} \left\{ \frac{1}{R_\sigma} \left[\left(\frac{k_r}{\tau_r} - k_r j \omega_{mec} \right) \psi_{\alpha\beta r}[k] + \vec{v}_{\alpha\beta,s}^p[k] \right] \right\}$$

$$T_e[k+1] = \frac{3}{2} p I_m \left\{ \vec{\psi}_{\alpha\beta,s}^p[k+1] \vec{i}_{\alpha\beta,s}^p[k+1] \right\}. \quad (11)$$

Nestas equações de predição, $\vec{v}_{\alpha\beta,s}^p[k]$ representa os vetores de tensão que podem ser aplicados na máquina a partir do VSI (Tabela 1), o que possibilita 7 diferentes predições de fluxo e torque. A escolha do melhor estado de chaveamento é feita a partir da minimização da função de custo (12). λ_f é um coeficiente utilizado para ponderar a contribuição de cada porção da função de custo [9].

$$g^i = |T_e^{ref} - T[k+1]| + \lambda_f \left| |\vec{\psi}_{\alpha\beta,s}^{ref}| - |\vec{\psi}_s[k+1]| \right|. \quad (12)$$

C. DSVM – Discrete Space Vector Modulation

O DSVM consiste na divisão do tempo de amostragem do controlador preditivo em n partes iguais para a criação de um vetor tensão virtual (13) utilizado nas equações de predição. Com isso é possível melhorar o desempenho do controlador sem o aumento exponencial do custo computacional [11].

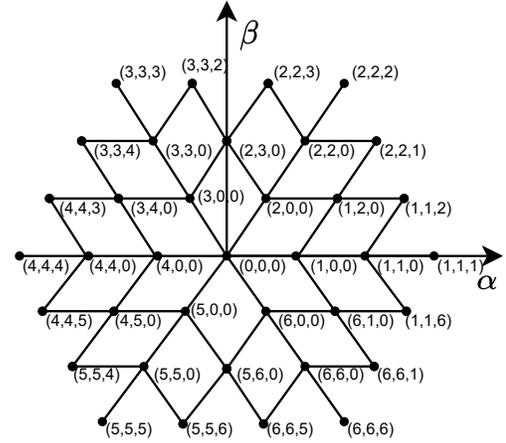
$$\vec{v}_s^{(i,j,\dots,k)} = \frac{v_i + v_j \dots + v_k}{n}. \quad (13)$$

Fazendo $n = 3$, são gerados, teoricamente, 8^3 vetores. Porém, excluindo-se as sobreposições, como por exemplo, os vetores (1,0,0), (0,1,0) e (0,0,1) que produzem virtualmente a mesma tensão no intervalo de amostragem, são aplicáveis 37 vetores.

Comparando ao PTC em uma mesma frequência de amostragem, a aplicação de 3 vetores traz benefícios claros na qualidade de energia [24], porém o custo computacional quintuplica, uma vez que de 7 possibilidade de predição salta-se para 37. Em [11] discute-se a vantagem de diminuir a frequência de amostragem a $1/3$ e obter os mesmos resultados do PTC.

Existem métodos para diminuir o conjunto de vetores possíveis utilizando tabelas de busca [11], mas alguns métodos podem levar a sub otimização do controle [25].

FIGURA 4. Visualização dos vetores virtuais de tensão do DSVM com $n = 3$.



D. MPTC – Modulated Predictive Torque Control

Diferentemente do DSVM, no qual o tempo de amostragem é dividido em partes iguais, no MPTC o controlador encontra o setor do hexágono no plano complexo no qual se encontra o vetor ótimo [18] [19]. O vetor ótimo é decomposto em dois vetores adjacentes que definem o seu setor mais um vetor nulo. Assim, cada um desses três elementos é aplicado pelo inversor através de ciclos de trabalho previamente calculados [15].

O primeiro passo é encontrar os valores g^i da função de custo (12) para cada um dos possíveis i vetores (Tabela 1), utilizando o mesmo estimador de fluxo e as mesmas equações do PTC. Para os cálculos que utilizam a tensão do estator $[k-1]$, a tensão média é calculada a partir dos *duty cycles* calculados no tempo de amostragem anterior.

Em seguida, é calculada uma nova função de custo (14), calculada para os seis setores do hexágono. Esta função leva em consideração a função de custo (12) e os respectivos *duty cycles* para cada par de vetores consecutivos.

$$g^j = d_1 \cdot g_1 + d_2 \cdot g_2. \quad (14)$$

g_1 e g_2 são as funções de custo de vetores consecutivos e d_1 e d_2 são os respectivos *duty cycles*, calculados com o sistema de equações (15). O sistema também utiliza g_0 , custo do vetor nulo.

$$\begin{cases} d_0 = \frac{g_1 \cdot g_2}{g_1 \cdot g_2 + g_1 \cdot g_0 + g_0 \cdot g_2} \\ d_1 = \frac{g_0 \cdot g_2}{g_1 \cdot g_2 + g_1 \cdot g_0 + g_0 \cdot g_2} \\ d_2 = \frac{g_1 \cdot g_0}{g_1 \cdot g_2 + g_1 \cdot g_0 + g_0 \cdot g_2} \end{cases} \quad (15)$$

A partir de (14) é escolhido o par de vetores e *duty cycles* que minimizam a função de custo. Em seguida a tensão calculada é sintetizada a partir de uma estratégia de chaveamento como o SVM [16] ou utilizando os periféricos PWM dos DSPs. A segunda opção requer menos processamento do

dispositivo, já que o controle dos *duty cycles* é feito pelos periféricos.

Esta estratégia traz resultados na atenuação dos *ripples*, mas não aproveita bem o barramento CC [19], também podem ocorrer sub-otimizações [12], cálculo de *duty cycles* negativos ou maiores que 1, o que exige estratégias mais complexas de sobremodulação [19] [26].

E. Compensação de Atraso

A modelagem dos métodos preditivos assumem que não há atraso nos cálculos, ou seja, que as medições e o chaveamento é realizado no instante $[k]$. Em aplicações práticas o cálculo pode demorar uma porção significativa do tempo de amostragem, terminando os cálculos em 60% do período de amostragem por exemplo, levando a sub-otimização [9].

Para resolver este problema as predições são realizadas um tempo de amostragem a frente para que os cálculos do instante $[k]$ já tenham sido feitos quando ocorre a interrupção do controlador: em $[k]$, é utilizado o modelo e o estado de chaveamento do inversor para fazer uma predição das variáveis em $[k + 1]$. Em $[k + 1]$ são realizadas as predições considerando a Tabela de chaveamento e a função custo.

Esta estratégia é chamada de compensação de atraso [27] e é uma estratégia de implementação do controle preditivo [24] que exibe melhoria em aplicações práticas [14].

IV. RESULTADOS EXPERIMENTAIS

Os controladores foram testados em bancada, composta por um motor de indução de 1,1kW, uma placa de desenvolvimento LAUNCHXL-F28379D, um inversor trifásico de bancada de 600V/20kW, um freio eletromagnético e um VARIAC para ajustar a tensão do barramento CC em 400V em todos os testes. A Tabela 2 mostra os parâmetros do motor utilizado nos testes.

TABELA 2. Parâmetros do Motor de Indução

| Parâmetro | Valor | Unidade |
|------------------------|-------|----------|
| Potência nominal | 1.1 | kW |
| Velocidade nominal | 1700 | rpm |
| Torque Nominal | 6.18 | N·m |
| Fluxo nominal | 0.8 | Wb |
| Frequência Nominal | 60 | Hz |
| Número de Polos | 4 | - |
| Resistência do Estator | 7,1 | Ω |
| Resistência do Rotor | 3,98 | Ω |
| Indutância do Estator | 545 | mH |
| Indutância do Rotor | 545 | mH |
| Indutância Mútua | 526 | mH |

A montagem experimental é exibida na Figura 5. Os circuitos de condicionamento de sinais e sensores de corrente foram montados no LEPS (Laboratório de Eletrônica de Potência e *Smart Grids* da UFABC).

As grandezas estimadas e medidas pelo controlador (torque, fluxo, correntes e velocidade) são sintetizadas

através de PWM-DACs (conversores analógico digitais) da placa do DSP, salvas com osciloscópio e exibidas utilizando a biblioteca de código aberto *Matplotlib*.

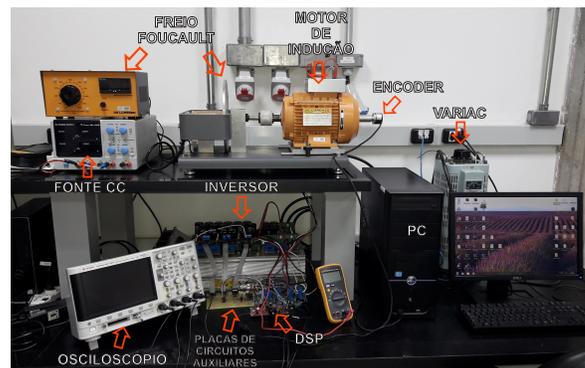


FIGURA 5. Bancada Experimental.

As frequências de amostragem foram ajustadas em 20 khz, com exceção do PTC-DSVM, que foi amostrado em 6,66 kHz, pois o DSVM aplica três vetores de tensão no período de amostragem. Isso torna o número de possíveis chaveamentos iguais ao DTC e PTC e permite uma melhor comparação entre as estratégias.

A. Controle de Torque e Fluxo

A fim de comparar o desempenho dos controles descritos, foi realizado um teste de consecutivos degraus de torque e fluxo. Os degraus de torque ocorrem a cada 250ms, variando de -3 a 3 Nm e a cada segundo há um degrau de fluxo, que varia de 0,4 Wb a 0,7 Wb. O freio foi ajustado para 100% de carga para evitar que o eixo acelere além da capacidade do barramento CC. A Figura 6 mostra os resultados das quatro estratégias sobrepostas no gráfico.

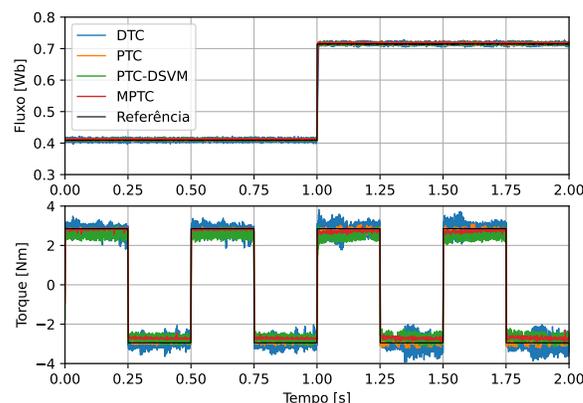


FIGURA 6. Degrau de Torque e Fluxo.

Os resultados mostram um bom desempenho de todos os controladores, seguindo as referências de fluxo e torque corretamente com baixo erro de regime. A Tabela 3 mostra os Erros Absolutos Percentuais Médios (MAPE – *Mean*

Absolute Percentual Error) e ripples de torque e fluxo para cada estratégia.

Para evidenciar as diferenças dos controladores, a Figura 7 mostra em detalhe (janela de 20ms) o momento de um degrau de torque e fluxo. É possível observar o ripple e tempo de subida das variáveis, exibidos na Tabela 3, considerando 90% do valor da referência.

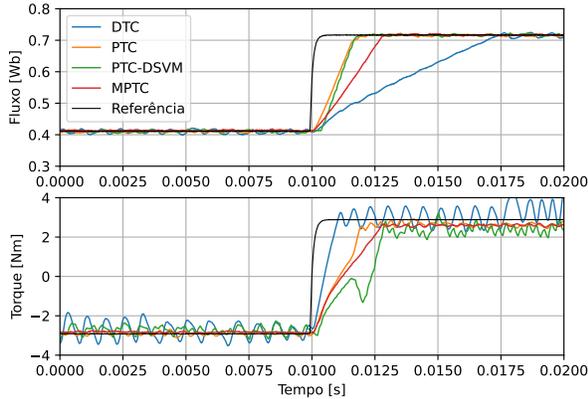


FIGURA 7. Detalhe do degrau de torque e fluxo.

O DTC age mais rapidamente sobre o torque enquanto os métodos preditivos priorizam a resposta do fluxo, resultado do fator λ_f na função de custo. É possível notar um pequeno erro de regime dos métodos preditivos, entretanto segundo dados da Tabela 3, o menor ripple ainda contém erros relativos menores para os métodos preditivos. Também é perceptível uma anomalia na resposta de torque para o PTC-DSVM, possivelmente causado pela baixa frequência de amostragem e simplicidade do estimador [28].

TABELA 3. Resultado do Controle de Velocidade

| | DTC | PTC | PTC-DSVM | MPTC |
|----------------------|--------|--------|----------|--------|
| Fluxo | | | | |
| MAPE [%] | 0,89 | 0,34 | 0,67 | 0,82 |
| Ripple [Wb] | 0,0092 | 0,0037 | 0,0057 | 0,0047 |
| t_s [ms] | 5,5 | 1,3 | 1,4 | 2,2 |
| Torque | | | | |
| MAPE [%] | 7,79 | 4,41 | 11,33 | 6,25 |
| Ripple a 0,7 Wb [Nm] | 0,56 | 0,21 | 0,37 | 0,12 |
| Ripple a 0,4 Wb [Nm] | 0,47 | 0,11 | 0,25 | 0,057 |
| t_s Torque [ms] | 1,0 | 2,3 | 2,9 | 2,8 |

B. Controle de Velocidade

Foi implementado um controle de velocidade com PI, utilizando ganhos $k_p = 0,03$ e $k_i = 0,5$ em todos os controladores, configurados por tentativa e erro. O ajuste foi manual para ter o melhor desempenho sem distorcer excessivamente as correntes de fase. A intenção deste teste não é o controle de velocidade e sim a análise do de erro

de regime e THD das malhas internas de controle. Por este motivo, foi adicionada uma saturação para proteger a máquina e o sistema mecânico, já que o sistema elétrico é capaz de fornecer um torque muito superior ao nominal da máquina.

Foi realizada a inversão de velocidade, de $-110rad/s$ a $110rad/s$, com freio eletromagnético configurado para 70% de carga. A saída do PI é saturada em 8 Nm, pouco acima do torque nominal da máquina, e o fluxo é controlado em 0,5 Wb.

A Figura 8 mostra o resultado deste ensaio. Os tempos de subida, erros relativos percentuais médios e ripple são exibidos na Tabela 4.

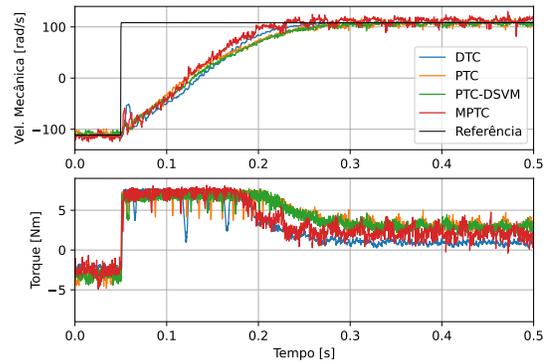


FIGURA 8. Degrau de velocidade com carga nominal.

TABELA 4. Resultado do Controle de Velocidade

| | DTC | PTC | PTC-DSVM | MPTC |
|----------------|------|------|----------|------|
| t_s [ms] | 230 | 232 | 231 | 230 |
| MAPE [%] | 1,05 | 2,53 | 2,28 | 5,39 |
| Ripple [rad/s] | 2,3 | 6,7 | 5,5 | 10,9 |

Com a velocidade constante foi feita uma medida de corrente diretamente da placa de condicionamento de sensores para cálculo da FFT do sinal e medida do THD. A medida foi feita diretamente no sensor para evitar distorções causadas pela amostragem e síntese pelo DAC-PWM. A Figura 9 mostra a captura das correntes da fase A – para demonstração da forma da onda – e a FFT do sinal. Para o MPTC é possível notar um pequeno pico em 20 kHz, frequência de chaveamento do modulador, entretanto a distorção de frequência mais baixa é predominante e similar à outras estratégias.

A Tabela 5 mostra os THDs obtidos para os sinais de corrente. Os resultados mostram melhor desempenho do PTC, seguido pelo PTC-DSVM, DTC e MPTC.

TABELA 5. Resultado do Controle de Velocidade

| | DTC | PTC | PTC-DSVM | MPTC |
|---------|------|-----|----------|------|
| THD [%] | 15,4 | 7,8 | 13,1 | 17,3 |

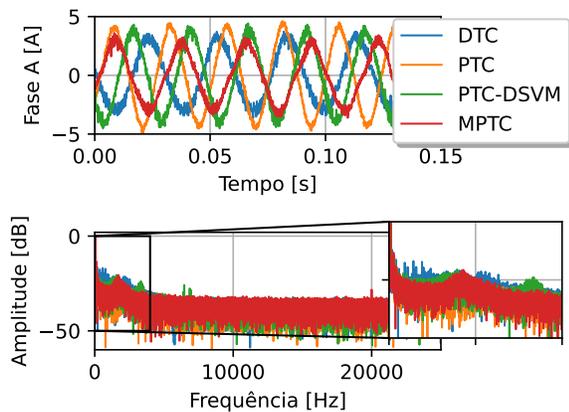


FIGURA 9. Correntes de fase e FFT das correntes (zoom de 0 Hz a 4kHz).

Os resultados condizem com a literatura, com o PTC obtendo melhor desempenho ao DTC e com o DSVM sendo uma solução para otimizar o custo computacional com pouca perda na qualidade de energia. Já o MPTC teve um pior índice de qualidade de energia comparado ao DTC em momentos de alta carga e velocidade próxima ao limite do barramento (evidenciado pelo alto *ripple* de torque na Figura 8). Isso pode ser causado pela não otimização em momentos de sobremodulação, como citado na literatura [19].

C. Custo Computacional

Também foi analisado o custo computacional de cada controlador a partir do tempo de cálculo dos controladores, incluindo a compensação de atraso dos preditivos. A medição foi realizada utilizando uma porta GPIO do DSP como uma *flag* indicando o processo de cálculo do controlador. A Figura 10 mostra o tempo de duração das interrupções e o tempo livre do controlador.

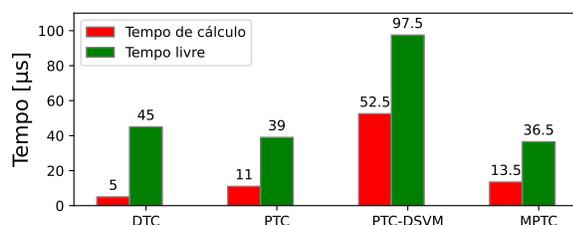


FIGURA 10. Tempo de cálculo e tempo livre do núcleo.

O DTC é o controlador mais rápido, como esperado pela estrutura de Tabela de busca e controladores por histerese da estratégia. É seguido pelo PTC e pelo MPTC, mostrando que o cálculo dos *duty cycles* não impacta no custo computacional do controlador. É importante notar o resultado do PTC-DSVM, que mesmo sendo o método mais caro computacionalmente devido à busca exaustiva de 37 vetores,

o fato de ter uma frequência de amostragem menor deixa mais tempo livre para o processador realizar outras tarefas.

V. CONCLUSÕES

Os dados mostram resultados satisfatórios para todos controladores, sendo todos aptos a realizar controle de alto desempenho de motores de indução. Entretanto, a melhor estratégia é o PTC, sendo mais versátil e com melhor resultado de distorção e *ripple* de torque. A frequência fixa do MPTC não trás claras melhorias, ao menos em sua implementação clássica.

A frequência de amostragem mais baixa do PTC-DSVM tende a dificultar a correta estimação de variáveis no modelo causando perda de desempenho. Ainda assim, as métricas para o controle de fluxo, torque e o THD atestam um melhor desempenho que o DTC, podendo ser utilizada em microcontroladores de baixo poder computacional.

AGRADECIMENTOS

Ao LEPS – UFABC e seus participantes pelo apoio e suporte, além da Fundação de Desenvolvimento da Pesquisa – Fundep Rota 2030/Linha V (processo: 27192.03.01/2020.13-00), ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPQ) (405757/2018-2 e 407867/2022-8) e FAPESP (2022/00323-3 e 2021/10421-0) pelo apoio financeiro.

CONTRIBUIÇÕES DOS AUTORES

Conceitualização, Curadoria de dados, Análise de dados, Pesquisa, Metodologia, Desenvolvimento, implementação e teste de software, Design da apresentação de dados, Redação do manuscrito original, Redação - revisão e edição: FIGUEIREDO, R.; Curadoria de dados, Análise de dados, Metodologia, Desenvolvimento, implementação e teste de software, Redação - revisão e edição: OLIANI, I.; Curadoria de dados, Metodologia, Desenvolvimento, implementação e teste de software, Validação de dados e experimentos, Redação - revisão e edição: LUNARDI, L.A.; Conceitualização, Curadoria de dados, Recebimento de financiamento, Metodologia, Administração do projeto, Disponibilização de ferramentas, Supervisão, Validação de dados e experimentos, Redação - revisão e edição: SGUAREZI FILHO, A.J.; Conceitualização, Recebimento de financiamento, Administração do projeto, Disponibilização de ferramentas: ALBIERO, D.; MEZARROBA, M.

PLÁGIO E SIMILARIDADE

O artigo foi submetido para verificação de similaridade no sistema Crossref Similarity Check (iThenticate).

REFERÊNCIAS

- [1] F. Un-Noor, S. Padmanaban, L. Mihet-Popa, M. N. Mollah, E. Hossain, "A Comprehensive Study of Key Electric Vehicle (EV) Components, Technologies, Challenges, Impacts, and Future Direction of Development", *Energies*, vol. 10, no. 8, Ago. 2017, doi:10.3390/en10081217.

- [2] A. T. de Almeida, F. J. T. E. Ferreira, G. Baoming, “Beyond Induction Motors—Technology Trends to Move Up Efficiency”, *IEEE Transactions on Industry Applications*, vol. 50, no. 3, pp. 2103–2114, Nov. 2014, doi:10.1109/TIA.2013.2288425.
- [3] A. E. Fitzgerald, C. Kingsley, S. D. Umans, *Máquinas Elétricas de Fitzgerald e Kingsley*, 7 ed., AMGH, Porto Alegre, 2014.
- [4] S. Jia, P. Zhang, D. Liang, M. Dai, J. Liu, “Design and Comparison of Three Different Types of IE4 Efficiency Machines”, in *22nd International Conference on Electrical Machines and Systems (ICEMS)*, pp. 1–4, 2019, doi:10.1109/ICEMS.2019.8921786.
- [5] C. H. T. Lee, W. Hua, T. Long, C. Jiang, L. V. Iyer, “A Critical Review of Emerging Technologies for Electric and Hybrid Vehicles”, *IEEE Open Journal of Vehicular Technology*, vol. 2, pp. 471–485, Dez. 2021, doi:10.1109/OJVT.2021.3138894.
- [6] D. Mohanraj, J. Gopalakrishnan, B. Chokkalingam, L. Mihet-Popa, “Critical Aspects of Electric Motor Drive Controllers and Mitigation of Torque Ripple—Review”, *IEEE Access*, vol. 10, pp. 73635–73674, Jun. 2022, doi:10.1109/ACCESS.2022.3187515.
- [7] I. Takahashi, T. Noguchi, “A New Quick-Response and High-Efficiency Control Strategy of an Induction Motor”, *IEEE Transactions on Industry Applications*, vol. IA-22, no. 5, pp. 820–827, Set. 1986, doi:10.1109/TIA.1986.4504799.
- [8] J. Rodriguez, P. Cortes, *Predictive control of power converters and electrical drives*, vol. 40, John Wiley & Sons, New York, 2012.
- [9] P. Karamanakos, T. Geyer, “Guidelines for the Design of Finite Control Set Model Predictive Controllers”, *IEEE Transactions on Power Electronics*, vol. 35, no. 7, pp. 7434–7450, Nov. 2020, doi:10.1109/TPEL.2019.2954357.
- [10] A. J. S. Filho, *Model Predictive Control for Doubly-Fed Induction Generators and Three-Phase Power Converters*, Elsevier, Cambridge, MA, 2022, doi:10.1016/B978-0-32-390964-8.00002-6.
- [11] M. Amiri, J. Milimonfared, D. A. Khaburi, “Predictive Torque Control Implementation for Induction Motors Based on Discrete Space Vector Modulation”, *IEEE Transactions on Industrial Electronics*, vol. 65, no. 9, pp. 6881–6889, Jan. 2018, doi:10.1109/TIE.2018.2795589.
- [12] I. Osman, D. Xiao, M. F. Rahman, M. Norambuena, J. Rodriguez, “Discrete Space Vector Modulation Based Model Predictive Flux Control With Reduced Switching Frequency for IM Drive”, *IEEE Transactions on Energy Conversion*, vol. 36, no. 2, pp. 1357–1367, Out. 2021, doi:10.1109/TEC.2020.3033356.
- [13] W. Zhang, Y. Yang, M. Fan, L. He, A. Ji, Y. Xiao, H. Wen, X. Zhang, T. Yang, S. Mekhilef, J. Rodriguez, “An Improved Model Predictive Torque Control for PMSM Drives Based on Discrete Space Vector Modulation”, *IEEE Transactions on Power Electronics*, vol. 38, no. 6, pp. 7535–7545, Mar. 2023, doi:10.1109/TPEL.2023.3257399.
- [14] A. Bhaumik, S. Das, “Virtual voltage vector based predictive current control of speed sensorless induction motor drives”, *ISA Transactions*, vol. 133, pp. 495–504, Fev. 2023, doi:https://doi.org/10.1016/j.isatra.2022.07.007.
- [15] M. Rivera, F. Morales, C. Baier, J. Muñoz, L. Tarisciotti, P. Zanchetta, P. Wheeler, “A modulated model predictive control scheme for a two-level voltage source inverter”, in *IEEE International Conference on Industrial Technology (ICIT)*, pp. 2224–2229, 2015, doi:10.1109/ICIT.2015.7125425.
- [16] L. Tarisciotti, P. Zanchetta, A. Watson, J. C. Clare, M. Degano, S. Bifaretti, “Modulated Model Predictive Control for a Three-Phase Active Rectifier”, *IEEE Transactions on Industry Applications*, vol. 51, no. 2, pp. 1610–1620, Jul. 2015, doi:10.1109/TIA.2014.2339397.
- [17] B. V. Comarella, D. Carletti, I. Yahyaoui, L. F. Encarnação, “Theoretical and Experimental Comparative Analysis of Finite Control Set Model Predictive Control Strategies”, *Electronics*, vol. 12, no. 6, Mar. 2023, doi:10.3390/electronics12061482.
- [18] V. Yaramasu, A. Dekka, J. Rodriguez, “Modulated Model Predictive Torque and Current Control of Squirrel Cage Induction Generator-Based Wind Power Generation System”, in *IEEE 21st Workshop on Control and Modeling for Power Electronics (COMPEL)*, pp. 1–7, 2020, doi:10.1109/COMPEL49091.2020.9265656.
- [19] F. Yu, K. Li, Z. Zhu, X. Liu, “An Over-Modulated Model Predictive Current Control for Permanent Magnet Synchronous Motors”, *IEEE Access*, vol. 10, pp. 40391–40401, Abr. 2022, doi:10.1109/ACCESS.2022.3166511.
- [20] H. Aberkane, D. Sakri, D. Rahem, “Comparative study of different variants of direct torque control applied to induction motor”, in *9th International Renewable Energy Congress (IREC)*, pp. 1–6, 2018, doi:10.1109/IREC.2018.8362484.
- [21] K. A. Tibamoso, N. A. Oñate, “Model predictive control on induction machine for electric traction”, in *Chilean Conference on Electrical, Electronics Engineering, Information and Communication Technologies (CHILECON)*, pp. 1–5, 2017, doi:10.1109/CHILECON.2017.8229626.
- [22] I. Oliani, T. Baldim Dos Santos, R. B. F. Figueiredo, D. Albiero, A. Pelizari, A. Joãozinho Sguarezi Filho, “Robust Finite Control Set Current Control for Induction Motor Using Deadbeat Approach in Synchronous Reference Frame”, *Eletrônica de Potência*, vol. 28, no. 1, pp. 28–35, Mar. 2023, doi:10.18618/REP.2023.1.0041.
- [23] R. Figueiredo, A. Lunardi, A. J. Sguarezi, A. Pelizari, “Controle preditivo robusto com conjunto finito de estados para máquinas de indução”, *Eletrônica de Potência*, vol. 27, no. 3, pp. 208–215, Ago. 2022, doi:10.18618/REP.2022.3.0027.
- [24] M. F. Elmorshedy, W. Xu, F. F. M. El-Sousy, M. R. Islam, A. A. Ahmed, “Recent Achievements in Model Predictive Control Techniques for Industrial Motor: A Comprehensive State-of-the-Art”, *IEEE Access*, vol. 9, pp. 58170–58191, Abr. 2021, doi:10.1109/ACCESS.2021.3073020.
- [25] I. Osman, D. Xiao, K. S. Alam, S. M. S. I. Shakib, M. P. Akter, M. F. Rahman, “Discrete Space Vector Modulation-Based Model Predictive Torque Control With No Suboptimization”, *IEEE Transactions on Industrial Electronics*, vol. 67, no. 10, pp. 8164–8174, Out. 2020, doi:10.1109/TIE.2019.2946559.
- [26] W. Tian, Q. Yang, X. Gao, P. Karamanakos, X. Yin, R. Kennel, M. L. Heldwein, “Fast Indirect Model Predictive Control for Variable Speed Drives”, *IEEE Transactions on Power Electronics*, vol. 38, no. 11, pp. 14475–14491, Ago. 2023, doi:10.1109/TPEL.2023.3307773.
- [27] P. Cortes, J. Rodriguez, C. Silva, A. Flores, “Delay Compensation in Model Predictive Current Control of a Three-Phase Inverter”, *IEEE Transactions on Industrial Electronics*, vol. 59, no. 2, pp. 1323–1325, Mai. 2012, doi:10.1109/TIE.2011.2157284.
- [28] T. Santos, I. Oliani, R. Figueiredo, A. Pelizari, A. J. Sguarezi Filho, “Avaliação do Impacto da Robustez na Estimação de Fluxo Magnético para os Controles Preditivos de Torque e Corrente”, in *IX Simpósio Brasileiro de Sistemas Elétricos (SBSE)*, 2022, doi:10.20906/sbse.v2i1.2890.

DADOS BIOGRÁFICOS

Rafael Figueiredo natural de São Paulo, 1994. Doutorando em Energia, Mestre em Eng. Elétrica (2022), Engenheiro de Automação, Instrumentação e Robótica (2022) e Bacharel em Ciência e Tecnologia (2018), pela UFABC. Técnico em Eletrônica pelo IFSP (2012), com experiência profissional na área de manutenção, projeto e laboratório, como técnico e como engenheiro. Faz parte do LEPS (Laboratório de Eletrônica de Potência e Smart Grids da UFABC), além de cursar Bacharelado em Ciência da Computação.

Igor Oliani Bacharel em Ciência e Tecnologia pela Universidade Federal do ABC (2019) onde atualmente está cursando Engenharia de Energia e participando do programa de mestrado em engenharia elétrica. Sua linha de pesquisa é focada em sistemas elétricos e eletrônica de potência aplicada a acionamentos de motores elétricos e veículos elétricos.

Angelo S. Lunardi Doutor em Engenharia Elétrica pela Universidade de São Paulo (USP) em 2022, Mestre em Engenharia Elétrica pela Universidade Federal do ABC (UFABC) e. 2017 e graduado em Engenharia Eletrônica em 2015 pelo Instituto Mauá de Tecnologia, onde durante o curso realizou trabalho científico como iniciação científica em 2013 com foco em simulação computacional e controle multivariável. Atualmente bolsista FUCAMP pós-doutorado com pesquisa em Micro-redes pela Universidade Estadual de Campinas (UNICAMP).

Alfeu J. Sguarezi Filho recebeu seu mestrado e seu Doutorado em Eng. Elétrica pela Universidade de Campinas no Brasil, respectivamente em 2007

e 2010. É professor da Universidade Federal do ABC – UFABC, em Santo André, Brasil, lecionando nas áreas de Máquinas Elétricas, Eletrônica de Potência e Acionamentos Elétricos. É membro Sênior do IEEE.

Daniel Albiero é formado pela Faculdade de Engenharia Agrônômica da Unicamp (2001), Graduação incompleta em Física na Unicamp (1996), mestrado (2005) e doutorado (2009) em Engenharia Agrônômica na Unicamp. Atualmente é Professor de Projeto de Máquinas Agrícolas e Robótica na Faculdade de Engenharia Agrícola (FEAGRI), Universidade Estadual de Campinas (UNICAMP), Coordenador de Extensão da FEAGRI/UNICAMP.

Marcello Mezaroba Engenheiro Eletricista, Mestre e Doutor em Engenharia Elétrica em 1996, 1998 e 2001 respectivamente, pela Universidade Federal de Santa Catarina. É Professor Titular no Departamento de Engenharia Elétrica da Universidade Estadual de Santa Catarina (DEE/UDESC) onde atua na Graduação e Pós-Graduação desde 2002. Sócios fundadores da Empresa SUPPLIER. É membro do Institute of Electrical and Electronics Engineers (IEEE) e da Sociedade Brasileira de Eletrônica de Potência (SOBRAEP), para a qual foi eleito duas vezes para o Conselho Deliberativo. Atuou como Presidente da SOBRAEP eleito para o biênio 2020-2021.