



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO DE CIÊNCIAS EXATAS E EDUCAÇÃO
DEPARTAMENTO DE ENG. DE CONTROLE, AUTOMAÇÃO E COMPUTAÇÃO
CURSO ENGENHARIA DE CONTROLE E AUTOMAÇÃO

Lucas Barreto Viana

Gêmeos Digitais no Contexto de Sistemas de Eletrônica de Potência

Uma Revisão de Literatura

Blumenau

2025

Lucas Barreto Viana

Gêmeos Digitais no Contexto de Sistemas de Eletrônica de Potência

Uma Revisão de Literatura

Trabalho de Conclusão de Curso submetido ao curso de Engenharia de Controle e Automação do Centro Tecnológico de Ciências Exatas e Educação da Universidade Federal de Santa Catarina como requisito parcial para a obtenção do título de Bacharel em Engenharia de Controle e Automação

Orientador(a): Prof. Tiago Davi Curi Busarello

Blumenau

2025

Ficha catalográfica para trabalhos acadêmicos

Viana, Lucas Barreto

Gêmeos Digitais no Contexto de Sistemas de Eletrônica de Potência : Uma Revisão de Literatura / Lucas Barreto Viana ; orientador, Tiago Davi Curi Busarello, 2025.
66 p.

Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Santa Catarina, Campus Blumenau, Graduação em Engenharia de Controle e Automação, Blumenau, 2025.

Inclui referências.

1. Engenharia de Controle e Automação. 2. Gêmeos Digitais. 3. Eletrônica de potência. 4. Sistemas de eletrônica de potência. I. Busarello, Tiago Davi Curi. II. Universidade Federal de Santa Catarina. Graduação em Engenharia de Controle e Automação. III. Título.

Lucas Barreto Viana

Gêmeos Digitais no Contexto de Sistemas de Eletrônica de Potência
Uma Revisão de Literatura

Este Trabalho de Conclusão de Curso foi julgado adequado para obtenção do título de “Engenheiro de Controle e Automação” e aprovado em sua forma final pelo Curso de Graduação em Engenharia de Controle e Automação.

Blumenau, 18 de dezembro de 2025.

Banca examinadora

Insira neste espaço
a assinatura

Prof. Dr. Tiago Davi Curi Busarello
Orientador

Insira neste espaço
a assinatura

Prof. Dra. Janaina Gonçalves Guimarães
Universidade Federal de Santa Catarina

Insira neste espaço
a assinatura

Prof. Dr. Adão Boava
Universidade Federal de Santa Catarina

Blumenau, 2025.

Dedico este trabalho a minha Anna, minha namorada, que me viu nos piores dias tentando organizar minhas ideias e mudando os rumos da pesquisa. Enquanto eu não via o caminho, ela se manteve minha guia e esperança.

AGRADECIMENTOS

Os agradecimentos que possuo são diversos, tanto para amigos que acreditaram em mim, quanto aos professores que viam futuro em mim, até a minha família que me proporcionou tudo. Então começarei com o primeiro apoio.

Agradeço a minha mãe, Tereza, por doar seu tempo em minha educação e criação, por sempre ter me instigado a me desafiar e conhecer mais, mesmo quando eu me sentia pequeno demais para isso. Agradeço por ela ter se mantido firme mesmo nos momentos que eu queria desistir dos estudos, das vezes que não estudava para as provas do ensino fundamental e médio, sempre puxando minha orelha para conseguir um futuro com um diploma em mãos, mesmo quando eu insistia em não querer. Acima de tudo isso, eu agradeço pelas noites mal dormidas ao cuidar de seus filhos doentes, pelo carinho que me fez crescer como pessoa, pelos ensinamentos de sempre me manter original e não me deixar abalar pelas dificuldades, por ser a rocha que edificou quem eu sou.

Agradeço ao meu pai, Petrócio, por doar seu tempo junto a nós para garantir o sustento da família, trazendo uma vida farta aos seus filhos e esposa, mesmo quando chegava exausto em casa seu sorriso surgia ao nos ver. Parecia que, independentemente do cansaço que lhe consumia, sua alma encontrava forças em nós, e uma alegria genuína nascia dentro do senhor. Agradeço pelos momentos que encontrava para passar conosco, criar conexões mesmo distante, se fazer presente no tempo que havia e ainda há, ainda me lembro das nossas idas ao parque, o senhor dava voltas a pé junto aos pedestres enquanto eu me deslocava com minha bicicleta, sempre lhe procurando com os olhos onde nos cruzaríamos novamente. Acima disso tudo, eu agradeço que nunca cedeu a dor da distância com um sorriso, hoje eu sei que dói, compreendo ao ver o tempo passar e a saudade de esperá-lo a porta de casa depois de uma semana exaustiva e sentir a animação com a sua chegada.

Agradeço ao meu irmão, André, que mesmo não o compreendendo bem, cheio de conflitos, eu o agradeço por me mostrar que o amor fraternal é confuso, mas existe mesmo nos piores momentos. Agradeço por, mesmo após tantos conflitos, ainda acharmos o caminho para o companheirismo. Sei que não somos próximos e sei que isso é culpa minha por diversos motivos, então aqui eu também venho lhe pedir perdão por não ter sido o irmão ideal, alguém que realmente olhasse para ti e quisesse lhe compreender. Peço perdão por lhe incomodar e irritar em diversos

momentos da vida e sei que muitos deles você já perdoou, e por isso eu lhe agradeço. Mas isso é uma sessão de agradecimentos e não de pedidos de perdão. Então eu lhe agradeço por se preocupar comigo quando passei dificuldades na escola, por se lembrar de mim mesmo após brigas. Basicamente, para deixar de ser meloso, obrigado por ser meu irmão.

Agradeço aos meus parentes, de sangue ou do coração, por sempre acreditarem em mim, me verem como eu jamais veria. Sempre trouxeram alegria ao meu lado, carinho comigo e um amor tão poderoso que jamais cessou até hoje. Sei que não apareço muito nos grupos e nas mídias sociais para devolver esse amor, mas nunca fui o melhor nesse quesito, então sempre que rezo os coloco em minhas orações. Sempre que estes momentos vêm, eu faço o que posso para lhes enaltecer. Agradeço imensamente por estar sempre com vocês, de perto ou longe.

Agradeço aos meus amigos Goldi, Santi, Luckays, Guilherme, RC, Verenguer, Bert, Igor, entre todos os outros do nosso querido grupo “Verenguer LTDA”, sei que alguém vai ficar irritado por não ter sido mencionado, mas não me culpem, são muitos para agradecer um-a-um e pelos motivos específicos. Então, eu os agradeço pelos momentos divertidos, pelos xingamentos, pelas chamadas, pelas conversas com ou sem os neurônios e por me ajudarem nos meus momentos difíceis, trazendo alegria mesmo quando eu me sentia só. Sei que não sou a pessoa mais fácil de se lidar todos os dias, mas agradeço a amizade verdadeira que temos, com algumas durando mais de cinco anos. Espero que muitos mais venham aí.

Agradeço a comunidade do Café Literário, em principal a *staff* do nosso querido Café. Me ajudaram a amadurecer minha arte, a dar voz a ela e me ouviram reclamar das minhas obras incessantemente. Além disso, agradeço ao Café por me apresentar a minha companheira de alma que receberá um parágrafo ainda hoje, eu prometo.

Agradeço aos meus amigos da faculdade, Valdir e Nicoletti por estarem enlouquecendo comigo nos piores momentos, pelas risadas no Restaurante Universitário, pelas noites mal dormidas em estudo constante, pelos madrugadões, pizzas, momentos diversos que aproveitamos fora da vida acadêmica. Acima disso, agradeço pelos desafios que superamos juntos, pelo crescimento curricular uno e pelo sofrimento compartilhado e nunca guardado. Espero que a gente consiga superar mais esta etapa, juntos ou separados, a gente ainda vai conseguir.

Aqui eu agradeço a quem eu dedico este trabalho, Anna, minha namorada. Eu só tenho a agradecer por esses três anos, quase quatro, que estamos juntos, por você estar comigo em todas as crises possíveis da faculdade, desde pensar em desistir, não aguentar mais de noites viradas para estudos, fazer trabalhos, surtando por ter esquecido detalhes ou simplesmente estar saturado das coisas. E, mesmo me vendo no meu pior momento, você não desistiu de mim, me agarrou e me deu todas as forças para continuar, caminhar, me arrastar pelos desafios, me amando em cada segundo, me aconselhando, ajudando, me guardando. Eu agradeço diariamente a Deus por estar ao teu lado, vendo seu sorriso com as bobagens que falo e faço, as dancinhas sinceras depois de provar algo que cozinhei, as conquistas que multiplicamos, as risadas que sincronizamos, a vida que dividimos e planejamos para nunca mais se apartar.

Anna, este trabalho é dedicado a ti do fundo do meu coração, pois sem você eu jamais terminaria isso, sem seu apoio, seu amor, dedicação e noites que ficou ao meu lado, enquanto me via afogado no cansaço e frustração, olhando para páginas de artigos e tentando escrever algo que não fazia sentido para mim. Hoje, com o trabalho finalizado e com esses agradecimentos, eu vejo que isso tudo só me fez perceber o quanto eu sou abençoado por ter você. Obrigado, espero que não tenha sido tão chato enquanto confeccionava o TCC.

Agradeço aos meus professores, desde o maternal até os do ensino superior, sem vocês eu não saberia interpretar o que são agradecimentos ou confeccionar um artigo. Agradeço a mim por ter vivido por tantos anos sem sequelas graves e com tantos amigos, parentes e família para me apoiar nos meus problemas e a comemorar nas minhas conquistas. Agradeço ao meu orientador, professor Tiago Davi Curi Bussarello, a banca de avaliadores, professor Adão Boava e professora Janaina Gonçalves Guimarães por terem disponibilizado seu tempo me avaliando e pelas aulas que me auxiliaram a progredir até aqui. E agradeço a Deus por todas as oportunidades que me foram dadas, pelos amigos, família, parentes, conhecidos e desconhecidos que me trouxeram até aqui.

Aos que esqueci de mencionar, peço perdão, tentei colocar todos que pude, mas sempre fui péssimo de memória.

“Eu não sabia, eu não tinha percebido
Eu sempre achei que era vivo
Parafuso e fluido em lugar de articulação
Até achava que aqui batia um coração
Nada é orgânico, é tudo programado.”
—Pitty, *Admirável Chip Novo*

RESUMO

Este trabalho apresenta uma revisão bibliográfica sobre a aplicação de Gêmeos Digitais (Digital Twins – DTs) em sistemas de eletrônica de potência, com foco em publicações recentes (2024–2025) indexadas na base IEEE Xplore. O estudo aborda os conceitos fundamentais dos DTs, suas estruturas, tecnologias habilitadoras e métodos de modelagem (física, baseada em dados e híbrida). Além disso, são analisadas categorias de identificação de parâmetros, incluindo métodos metaheurísticos, baseados em filtros, aprendizado de máquina e probabilísticos. A revisão inclui a análise comparativa de artigos selecionados, destacando aplicações em conversores Buck, inversores 3L-ANPC, sistemas fotovoltaicos conectados à rede e monitoramento térmico. Os resultados evidenciam o potencial dos DTs para monitoramento em tempo real, diagnóstico de falhas, manutenção preditiva e otimização de sistemas críticos, apontando também lacunas como sensibilidade a parâmetros não modelados, alto custo computacional e necessidade de padronização. Conclui-se que os DTs representam uma tecnologia em ascensão, capaz de aumentar a confiabilidade, eficiência e autonomia dos sistemas de eletrônica de potência.

Palavras-chave: Gêmeos Digitais; Eletrônica de potência; Sistemas eletrônicos com gêmeos digitais; Gêmeos digitais na eletrônica de potência; Revisão bibliográfica.

ABSTRACT

This work presents a literature review on the application of Digital Twins (DTs) in power electronics systems, focusing on recent publications (2024–2025) indexed in the IEEE Xplore database. The study covers the fundamental concepts of DTs, their structures, enabling Technologies, and modeling approaches (physical, data-driven, and hybrid). Additionally, parameter identification methods are analyzed, including metaheuristic, filter-based, machine learning, and probabilistic techniques. The review includes a comparative analysis of selected articles, highlighting applications in Buck converters, 3L-ANPC inverters, grid-connected photovoltaic systems, and thermal monitoring. The results demonstrate the potential of DTs for real-time monitoring, fault diagnosis, predictive maintenance, and optimization of critical systems, while also pointing out gaps such as sensitivity to unmodeled parameters, high computational cost, and lack of standardization. It is concluded that DTs represent an emerging technology capable of enhancing the reliability, efficiency, and autonomy of power electronics systems.

Keywords: Digital Twins; Power Electronics; Parameter Identification; Hybrid Modeling; Literature Review.

LISTA DE FIGURAS

Figura 1- Exemplo de configuração de um sistema físico (a direita) juntamente ao seu gêmeo digital (a esquerda), com ambos possuindo o mesmo controlador (F28335). Fonte: Bussarello (2024).....	25
Figura 2 – Fluxograma de funcionamento de um DT de um conversor Buck com identificação por PSO. Fonte: Wu <i>et al.</i> (2025)	29
Figura 3 – Modelo genérico do funcionamento de uma rede neural. Fonte: Kamal <i>et al.</i> , 2024	33
Figura 4 – Esquema de funcionamento de um DT probabilístico em funcionamento. Fonte: Bai <i>et al.</i> (2024)	39
Figura 5 – Topologia ideal (a esquerda) e real (direita) de um dos níveis de um inversor 3L-ANPC. Fonte: Song <i>et al.</i> (2024).....	41
Figura 6 – Topologia do sistema fotovoltaico <i>grid-connected</i> . Fonte: Kumar e Kumar (2025).	43
Figura 7 – Topologia nos dois estados de chaveamento de um conversor Buck. Fonte: Liu, Yang e Liu (2025).....	44
Figura 8 – Topologia do conversor Buck com sensores. Fonte: Nazif <i>et al.</i> (2025).....	46
Figura 9 – Funcionamento do gêmeo digital proposto por Liu, Qing e Chen (2024). Fonte: Liu, Qing e Chen (2024).....	49
Figura 10 – Modelo de arquitetura híbrida proposto por Torchio <i>et al.</i> (2025). Fonte: Torchio <i>et al.</i> (2025).....	50
Figura 11 – Fluxograma do funcionamento de ambas as partes do gêmeo digital proposto por Roy e Sarwat (2025), a esquerda o modelo baseado em ML e a direita o modelo físico orientado por aprendizagem de máquina. Fonte: Roy e Sarwat (2025).....	52

LISTA DE TABELAS

Tabela 1– Comparativo entre os artigos com modelagem física. Fonte: O autor (2025).....	47
Tabela 2 – Comparativo entre os artigos com modelagem híbrida. Fonte: O autor (2025).....	53

LISTA DE ABREVIATURAS E SIGLAS

3L-ANPC	Three-Level Active Neutral-Point Clamped
AOA	Arithmetic Optimization Algorithm
ANN	Artificial Neural Network
BO	Bayesian Optimization
CAFe	Comunidade Acadêmica Federada
CPS	Cyber-Physical System
DEKF	Dual Extended Kalman Filter
DNN	Deep Neural Network
DT	Digital Twin
E2FD-HO	Electromagnetic Field and Electrostatic Discharge Hybrid Optimization
EKF	Extended Kalman Filter
ESR	Equivalent Series Resistance
FFNN	Feed-Forward Neural Network
FPGA	Field-Programmable Gate Array
GA	Genetic Algorithm
GRU	Gated Recurrent Unit
GWO	Grey Wolf Optimizer
IA	Inteligência Artificial
IGBT	Insulated-Gate Bipolar Transistor
IMPC	Integral Model Predictive Control
IoT	Internet of Things
IPM	Interior Point Method
KF	Kalman Filter
LSTM	Long Short-Term Memory
MEF	Método dos Elementos Finitos
ML	Machine Learning
MPPT	Maximum Power Point Tracking
NARX-ANN	Nonlinear AutoRegressive with eXogenous inputs Artificial Neural
Network	
NTC	Negative Temperature Coefficient
P&O	Perturb and Observe
PCE	Polynomial Chaos Expansion

PID	Proportional-Integral-Derivative
PIML	Physics-Informed Machine Learning
PINN	Physics-Informed Neural Network
PSO	Particle Swarm Optimization
RF	Random Forest
RLS	Recursive Least Squares
ROM	Reduction Order Model
DA	Dragonfly Algorithm
HIL	Hardware-in-the-Loop

SUMÁRIO

1	INTRODUÇÃO	17
2	METODOLOGIA	20
3	REVISÃO DE LITERATURA	21
3.1	CONCEITO E ESTRUTURA DOS GÊMEOS DIGITAIS	21
3.2	TECNOLOGIAS HABILITADORAS.....	22
3.3	MODELAGEM E APLICAÇÕES NA ELETRÔNICA DE POTÊNCIA.....	23
3.4	IDENTIFICAÇÃO DE PARÂMETROS	26
3.4.1	Métodos Metaheurísticos	26
3.4.2	Métodos Baseados em Filtros e Estimação	30
3.4.3	Métodos Baseados em Aprendizado de Máquina	31
3.4.4	Métodos Probabilísticos	36
3.5	ARTIGOS SELECIONADOS.....	40
3.5.1	Modelagem física	41
3.5.2	Modelagem híbrida	48
4	SÍNTESE E TENDENCIAS FUTURAS	57
5	CONCLUSÃO	59
	REFERÊNCIAS	61

1 INTRODUÇÃO

Com o constante avanço tecnológico e a crescente demanda por eficiência, previsão e confiabilidade nos processos industriais, a engenharia vem enfrentando o desafio de desenvolver sistemas capazes de operar de maneira autônoma, sustentável e econômica. Com isso, as constantes buscas por soluções que consigam conciliar um alto desempenho, uma redução de custos e um impacto ambiental minimizado impulsionam o surgimento de novas abordagens tecnológicas, sendo os gêmeos digitais (*Digital Twins* – DT's) uma das que vem se destacando recentemente.

Os DT's representam uma das mais promissoras e interessantes inovações da Indústria 4.0, já que oferecendo uma ponte entre o mundo físico e digital. Isso ocorre, pois eles consistem em modelos virtuais dinâmicos e sincronizados de sistemas reais, capazes de reproduzir seu comportamento em tempo real a partir de dados coletados por sensores, sistemas de controle e algoritmos de aprendizado (Tao *et al.*, 2019). Tal interação contínua entre os ambientes físico e virtual permite a prevenção de falhas, otimização dos parâmetros de operação e simulação em cenários complexos, reduzindo significativamente os custos de manutenção, as falhas e o tempo de desenvolvimento de novas soluções tecnológicas (Lu *et al.*, 2021; Minerva; Lee; Crespi, 2020; Qi; Tao, 2018).

Os DT's possuem grande relevância quando aplicados à eletrônica de potência, visto que essa área, responsável pela conversão e controle eficiente de energia elétrica, é essencial para setores como geração renovável, transporte elétrico, automação e redes inteligentes. Dispositivos como conversores, inversores e retificadores acabam sujeitos a diversas degradações, como aquelas que ocorrem pelo tempo de uso, degradações térmicas, eletromagnéticas e elétricas, o que compromete a confiabilidade dos sistemas, a economia e, considerando as degradações pelo tempo, diminuem o tempo de vida do sistema. Logo, nesse contexto, os gêmeos digitais surgem como ferramentas estratégicas para acompanhar o comportamento desses dispositivos, permitindo diagnóstico de falhas, prognóstico de degradação, otimização e análises em tempo real.

Nos estudos recentes de Wu *et al.* (2025) é reforçado o potencial dessas abordagens. Já que os autores apresentam uma visão abrangente do estado da arte, e trazem diversos estudos referentes aos DT's e suas aplicações, além de os descrever como entidades multi-físicas bidirecionais capazes de acompanhar o ciclo

completo de um sistema de potência, desde o projeto até a operação e a manutenção. Além disso, Bai *et al.* (2024) complementam tais afirmações ao destacarem que os DT's, na eletrônica de potência, possuem quatro propriedades fundamentais, sendo elas a interpretabilidade (capacidade do DT de explicar o comportamento do sistema físico com base em modelos de alta fidelidade), traçabilidade (capacidade do DT de sincronização com o sistema físico em tempo real, refletindo seu estado atual), previsibilidade (capacidade do DT de prever comportamentos futuros do sistema físico com base no modelo e em dados históricos do físico) e cooperatividade (capacidade do DT de auxiliar o sistema físico fornecendo suporte em tempo real na tomada de decisões), diferenciando-os, assim, de simulações comuns.

Liu, Qing e Chen (2024), por exemplo, trouxeram o desenvolvimento de modelos de DT's para a identificação multiparamétrica de um conversor Buck DC-DC, utilizando algoritmos de otimização como *Particle Swarm Optimization* (PSO) para validação dos métodos de cálculo, permitindo, assim, uma maior precisão na calibração de parâmetros elétricos e térmicos. Song *et al.* (2024) também se utilizaram do PSO para otimização e verificação da modelagem e identificação multiparamétrica, porém, desta vez, de um inversor *three-phase three-level active-NPC* (3L-ANPC), que conseguiram uma identificação dos parâmetros com erros menores que 5%, trazendo confiabilidade ao método.

Além da identificação e calibração, os gêmeos digitais também são visados pelas suas aplicações referentes a manutenções preditivas e saúde dos equipamentos. Roy e Sarwat (2025), por exemplo, desenvolveram um modelo híbrido físico-informado (*Physics-Informed Machine Learning* – PIML) capaz de prever a degradação de inversores ponte-H sob ruído e variação de carga, o que demonstrando um forte auxílio da inteligência artificial (IA) na contribuição dos DT's na melhoria contínua e fuga de desafios.

Mesmo com essas soluções para uma melhoria contínua dos gêmeos digitais, ainda há problemas levantados por Qi e Tao (2018) e por Tao *et al.* (2019), como ruídos nos sensores usados para análise, a falta de registros ou bancos de dados para treino das IA's nele utilizadas. Também há um problema de latência na indústria que pode causar atraso na atualização dos DT's em tempo real, o que já está sendo analisada ao pensarmos em tecnologias futuras, como o uso do 6G na indústria, como apontam Lu *et al.* (2021). Além disso, há outra questão que é ausência de padronização e interoperabilidade entre diferentes plataformas e modelos.

Diante desse cenário, este trabalho propõe uma revisão bibliográfica sobre o uso de gêmeos digitais aplicados à eletrônica de potência, abordando suas estruturas conceituais, modelos de implementação, aplicações práticas e desafios tecnológicos. O estudo concentra-se em publicações recentes (2024–2025) disponíveis na base *IEEE Xplore*, de modo a refletir o estado mais atual da pesquisa científica nessa área.

Assim, o objetivo geral desta monografia é analisar o estado da arte dos gêmeos digitais na eletrônica de potência, identificando tendências, lacunas e perspectivas para o desenvolvimento de sistemas mais confiáveis, eficientes e autônomos.

E como objetivos específicos define-se:

- Selecionar publicações científicas recentes (2024–2025) sobre gêmeos digitais aplicados à eletrônica de potência, disponíveis na base de dados *IEEE Xplore Digital Library*.
- Classificar os estudos selecionados em categorias temáticas de análise, considerando seus enfoques em modelagem e diagnóstico.
- Analisar criticamente as contribuições, metodologias e resultados apresentados nos artigos selecionados, identificando tendências tecnológicas e abordagens emergentes no uso de gêmeos digitais na área.
- Identificar lacunas e apontar perspectivas futuras para o desenvolvimento de sistemas de potência baseados em gêmeos digitais, com ênfase em confiabilidade, eficiência e autonomia operacional.

Com isso, a monografia se dividiu com o capítulo 1 apresentando a contextualização do tema, justificativa e objetivos da pesquisa, o capítulo 2 descrevendo a metodologia empregada na busca e seleção dos artigos, o capítulo 3 apresenta a revisão de literatura, se aprofundando mais nos gêmeos digitais, suas modelagens, métodos de identificação de parâmetros e suas aplicações nos sistemas de eletrônica de potência, o capítulo 4 consiste na análise dos artigos estudados e tendências futuras dos gêmeos digitais na eletrônica de potência, por fim, o capítulo 5 traz a conclusão do trabalho.

2 METODOLOGIA

Esta pesquisa se caracteriza como um estudo de natureza bibliográfica, voltado a análise de artigos recentes sobre a aplicação de gêmeos digitais em sistemas de eletrônica de potência. Visto isso, a busca foi realizada na plataforma *IEEE Xplore Digital Library*, utilizando o sistema de autenticação *CAFe*, concedido pela plataforma *Periódicos CAPES*.

Para busca dos artigos, foi utilizado o seguinte conjunto de descritores: ("*Digital Twin*" OR "*Digital Twins*") e ("*Power Electronic*" OR "*Power Electronic Systems*"). Além disso, para delimitar o escopo temporal, foram considerados apenas estudos publicados em 2024 e 2025, resultando em 75 publicações nesta primeira seleção.

Em seguida, foram aplicados filtros adicionais, um para selecionar apenas artigos publicados em *Journals* e outro para artigos publicados em *Magazines*. Com isso o escopo foi reduzido para 27 artigos publicados, sendo 24 deles de *Journals* e 3 de *Magazines*.

Os artigos foram selecionados conforme a relevância temática, priorizando aqueles que abordavam diretamente a aplicação de gêmeos digitais na eletrônica de potência ou em sistemas de potência. Desse modo, a etapa de seleção consistiu na leitura atenta dos resumos e conclusões dos 27 artigos encontrados. Em função do tempo, foram selecionadas 10 publicações para análise, tais artigos foram selecionados por seu foco direto em sistemas da eletrônica de potência, suas contribuições com a área e os gêmeos digitais e seus resultados encontrados. Esses textos foram lidos integralmente e analisados com o objetivo de identificar as contribuições, tendências e limitações observadas nos estudos selecionados, assim como compreender como cada categoria tem avançado no desenvolvimento e aplicação dos gêmeos digitais.

3 REVISÃO DE LITERATURA

3.1 CONCEITO E ESTRUTURA DOS GÊMEOS DIGITAIS

O conceito de *Digital Twin* surgiu no início dos anos 2000, quando Michael Grieves o apresentou como uma forma de representar digitalmente produtos durante todo o seu ciclo de vida. Desde então, o termo evoluiu de uma simples modelagem tridimensional para um sistema cibernético-físico dinâmico, capaz de refletir e prever o comportamento de sistemas físicos em tempo real (Wu *et al.*, 2025).

Na eletrônica de potência esse conceito é particularmente relevante, já que conversores, inversores e retificadores operam sob condições variáveis de carga e temperatura, o que leva a uma alta demanda por precisão e confiabilidade dos componentes. Bai *et al.* (2024) trazem uma ampliação da definição quando descrevem DT's como sistemas autossustentáveis, sincronizados e interativos, fazendo uma correspondência contínua entre o estado físico e o modelo digital, com isso são possíveis melhores prognósticos, previsibilidade e cooperatividade para uma melhor análise dos sistemas digitalizados.

Mihai *et al.* (2022) reforçam que o DT não é igual as simulações tradicionais, já que eles combinam dados em tempo real, inteligência artificial (IA), aprendizado de máquina (*Machine Learning* – ML), Internet das Coisas (*Internet of Things* — IoT), realidade aumentada e computação distribuída. Esse ecossistema integrado permite, não apenas observar o comportamento do sistema, mas também prever falhas e otimizar seu desempenho operacional, configurando uma ferramenta essencial para sistemas complexos, como os de eletrônica de potência.

Com isso, Tao *et al.* (2019) trazem que os gêmeos digitais constituem uma das tecnologias centrais da Indústria 4.0, já que permitem a integração entre o espaço físico e o digital a partir de sensores, redes de comunicação e sistemas de dados que criam uma sincronização bidirecional entre o ambiente real e o simulado, o que gera a possibilidade de monitorar, diagnosticar, controlar e otimizar processos.

A estrutura dos gêmeos digitais, segundo os pesquisadores Minerva *et al.* (2020) é que um DT é composto pelo espaço físico, onde se apresenta o sistema real e suas variáveis mensuráveis, espaço digital, onde se encontra o modelo digital que reproduz as características e dinâmicas do sistema real, e o canal de comunicação

bidirecional, que sincroniza os dados e estados de maneira contínua entre o físico e o digital.

Esses três elementos formam um ciclo fechado de feedback, no qual qualquer alteração que ocorra no domínio físico é refletida no modelo digital e vice-versa. Dentro de aplicações na eletrônica de potência, essa estrutura permite o monitoramento, controle, identificação de anomalias e correção de parâmetros sem interrupção do sistema físico, tudo isso em tempo real, conforme mostrado por Lei *et al.* (2023).

Em complemento, Groshev *et al.* (2021) traz os DT's como o verdadeiro “núcleo inteligente” de um sistema ciber-físico (*Cyber-Physical System* — CPS), onde a camada digital processa os grandes volumes de dados ao se utilizar de IA ou ML, enquanto na camada física são feitas medições contínuas via sensores para captura dos parâmetros. Os autores apontam que tal integração é fundamental para alcançar uma tomada de decisão autônoma e otimização adaptativa do sistema, princípios que favorecem seu uso dentro da eletrônica de potência.

3.2 TECNOLOGIAS HABILITADORAS

Atualmente os gêmeos digitais são possíveis e mais bem integrados por um conjunto de tecnologias interligadas, sendo elas a IoT, que garante a conectividade entre sensores e atuadores distribuídos. A computação em nuvem, a qual fornece infraestrutura necessária para armazenamento e que, em conjunto com a inteligência artificial e ML — que interpretam dados e otimizam a resposta do modelo digital —, permitem a integração dos DT's em tempo real. A *big data* e análise avançada, que possibilitam o tratamento de grandes volumes de dados industriais, e a rede 5G (e futuramente 6G), já que permitem a comunicação em baixa latência, principal questão na indústria, além de alta confiabilidade entre o sistema físico e virtual (Lu *et al.*, 2021; Minerva, Lee, Crespi; 2020; Qi; Tao, 2018).

Tao e Qi (2018) destacam que a convergência entre *Big Data* e *Digital Twin* cria um ciclo contínuo de aprendizado e retroalimentação, em que dados do mundo físico alimentam o modelo digital e que, como Lu *et al.* (2021) trazem, a rede 6G permitirá uma melhor comunicação com a IA e o banco de dados, trazendo consigo melhores *insights* sobre o sistema representado pelo DT, além de elevar o nível de modelagem e diagnósticos em tempo real. Com isso, tal integração se mostra ideal

para a eletrônica de potência, visto que pequenas variações térmicas, elétricas ou magnéticas podem impactar na saúde e funcionamento dos componentes que compõem o sistema.

3.3 MODELAGEM E APLICAÇÕES NA ELETRÔNICA DE POTÊNCIA

Entende-se que a modelagem de qualquer gêmeo digital é a sua base e, de acordo com Mihai *et al.* (2022), ela pode ser elencada em três categorias: a categoria baseada em física, no qual a topologia do sistema é inteiramente traduzida a partir de leis e equações fundamentais, se portando como uma abordagem mais inflexível e robusta dentro de seu escopo, já que se houverem parâmetros parasitas não modelados, eles podem dificultar a identificação dos demais, mas dentro da topologia idealmente modelada os erros se mostram mínimos.

A baseada em dados, na qual se utiliza de IA e/ou ML treinadas com bancos de dados do funcionamento dos componentes nos sistemas analisados, assim a modelagem é montada totalmente baseada nesses dados. Este método de modelagem se destaca pela sua flexibilidade ao possibilitar a modelagem de diversos sistemas presentes em seu banco de dados, contudo, caso haja problemas nos dados isso afetará diretamente na modelagem do sistema, além de problemas clássicos de IA's que se especializam demais no banco de dados de treinamento e acabam não atingindo os resultados esperados no uso real ou na verificação da IA.

E os híbridos que utilizam ambas as técnicas, em geral, boa parte da topologia do sistema é descrita via cálculos físicos, já a abordagem com dados serve para preencher possíveis lacunas que não foram calculadas inicialmente, como erros dos sensores, divergências mínimas entre fabricantes ou erros de acoplamento inesperados.

Dentro da eletrônica de potência as abordagens mais comuns tem sido as híbridas, já que elas se mostram mais confiáveis, versáteis e úteis neste contexto que precisa de sistemas mais precisos e preditivos que os demais. Um exemplo seria Shi *et al.* (2022) que aplicaram o PSO para ajustar parâmetros de um inversor trifásico a partir de dados experimentais, ou pode-se utilizar os já citados Song *et al.* (2024) que se utilizaram da mesma estratégia de ML a base de PSO para a identificação dos parâmetros do DT.

Então, para a eletrônica de potência, a capacidade de DT's híbridos na sincronia e capacidade de mimetizar o sistema real se mostram ótimas para o controle e observação de seus sistemas, e com as tecnologias anteriormente citadas — como IoT e 5G — garantem sua precisão e estabilidade ao receber ou enviar dados necessários para controle, ou atualização dos sistemas (virtual ou físico) como é demonstrado pelo estudo de Lei *et al.* (2023) que demonstram a capacidade dos gêmeos digitais de detectar falhas no controlador físico de um conversor DC-DC, além de substituí-lo virtualmente e em tempo real, mantendo o sistema em contínuo funcionamento.

Os estudos de Mulinka *et al.* (2022) já trazem um modelo de DT otimizado por *Bayesian Learning* para diagnosticar de falhas em inversores conectados à rede, o que alcançou uma maior precisão e menor tempo de resposta se comparado aos métodos tradicionais.

Bussarello (2024) traz um exemplo prático em seu LinkedIn e uma rápida análise de como o gêmeo digital a sua disposição o auxilia em testes de algoritmos de controle sem o risco de danificar o sistema real, fazer diversos testes em curtos períodos e a identificação dos parâmetros do sistema real e atualizar automaticamente os parâmetros no gêmeo digital. Na Figura 1 ele mostra o *setup* do gêmeo digital, no qual ele se utiliza de um Typhoon HIL em tempo real (presente à esquerda da imagem) para mimetizar o sistema físico de um filtro LCL e um inversor *grid-connected* (presente à direita da imagem), ambos conectados a controladores F28335.




Figura 1- Exemplo de configuração de um sistema físico (a direita) juntamente ao seu gêmeo digital (a esquerda), com ambos possuindo o mesmo controlador (F28335). Fonte: Bussarello (2024)

A apresentação das duas pesquisas e o *post* do LinkedIn reforçam o papel dos DT's na eletrônica de potência e sua importância nesta área, além de representar uma notória evolução para a indústria e pesquisa na área, também é observável que os gêmeos digitais permitem o desenvolvimento de estratégias de controle adaptativo que respondem dinamicamente a mudanças nas condições de operação. Não à toa, o modelo proposto por Di Nezio *et al.* (2023) evidencia ainda mais a capacidade dos gêmeos digitais em ajustar parâmetros em tempo real com alta confiabilidade, tornando-os essenciais para a manutenção preditiva de conversores AC/DC e DC/DC. Além de possuírem a capacidade de análises paramétricas profundas, como demonstrado no trabalho de Song *et al.* (2025) que trazem um DT capaz de fazer análises preditivas de um sistema complexo com um inversor de três níveis, possibilitando manutenções preditivas de maneira não invasiva ao sistema. Já o *post* de Busarello (2024) demonstra a confiabilidade que os gêmeos digitais trazem para diversos testes sobre o sistema e o mantendo longe de possíveis problemas que ocorram ao longo dos testes, sejam em questão de configurações com correntes e tensões diferentes ou desgaste por uso exaustivo dos componentes do sistema.

3.4 IDENTIFICAÇÃO DE PARÂMETROS

Após a modelagem do sistema analisado, é necessário o uso de algoritmos ou métodos de identificação desses parâmetros. Tais algoritmos são, em geral, um conjunto de métodos computacionais e matemáticos usados para estimar ou ajustar os parâmetros do modelo digital de forma a ele refletir o máximo de fidelidade ao comportamento do sistema físico real, sendo em tempo real ou não.

A partir do artigo de Wu *et al.* (2025) é possível elencar as seguintes categorias: metaheurísticos, baseados em filtros e estimação, baseados em aprendizado de máquina e probabilísticos. Essas categorias são discutidas a seguir.

3.4.1 Métodos Metaheurísticos

Os métodos metaheurísticos representam uma categoria de algoritmos de otimização que se distinguem por sua abordagem inspirada em fenômenos naturais e processos biológicos. Estes são classificados devido sua natureza de busca estocástica global que não requer informações sobre gradientes ou derivadas da função objetivo. Isto é, estes algoritmos operam com uma população de soluções candidatas que evoluem coletivamente através do espaço de parâmetros, utilizando mecanismos de colaboração e competição inspirados em comportamentos presentes na natureza (Ozcan; Mohan, 1999).

A característica principal destes métodos é sua capacidade de escapar de ótimos locais através de estratégias de exploração ampla do espaço de busca, seguida por fase de exploração intensiva nas regiões mais promissoras. No contexto de gêmeos digitais para sistemas da eletrônica de potência, esses métodos são valorizados por sua capacidade de lidar com funções objetivo não diferenciáveis e problemas com múltiplos ótimos locais, como ocorre frequentemente na identificação de parâmetros degradados em componentes de conversores de potência (Bai *et al.*, 2024; Wu *et al.*, 2025).

O PSO é um exemplo desta categoria, funcionando através de sua metáfora de enxame, onde partículas ajustam suas trajetórias baseadas tanto em sua experiência individual quanto no conhecimento coletivo do grupo (Kennedy; Eberhart, 1995). Já o *Genetic Algorithm* (GA), outro exemplo deste tipo de método, opera

através de operadores de seleção, *crossover* e mutação que simulam processos evolutivos. Outro exemplo é o *Arithmetic Optimization Algorithm* (AOA) que utiliza operadores matemáticos fundamentais para guiar a busca, enquanto o *Bayesian Optimization* (BO) já modela a função objetivo como um processo gaussiano para dirigir eficientemente a exploração (Abualigah *et al.*, 2021; Holland, 1975; Pelikan; Godberg; Tsutsui, 2003). O fator que unifica estes métodos é sua independência de informações analíticas detalhadas sobre o sistema, visto que eles tratam a função objetivo como uma "caixa preta", tornando-os especialmente adequados para problemas complexos onde relações paramétricas exatas são desconhecidas ou difíceis de modelar analiticamente (Bai *et al.* 2024).

Focando o método PSO, este é um algoritmo de otimização baseado em população que se inspira no comportamento coletivo de organismos biológicos como, por exemplo, bandos de pássaros ou cardumes de peixes. Este método foi desenvolvido inicialmente por Kennedy e Eberhart (1995) tem sido amplamente aplicado em problemas de otimização contínua, especialmente em contextos em que os modelos matemáticos são complexos, não-lineares ou possuem múltiplos ótimos locais. Na área de gêmeos digitais para eletrônica de potência, ele se destaca como uma ferramenta eficaz para a identificação de parâmetros de sistemas físicos, permitindo que o modelo digital mantenha alta fidelidade em relação ao seu correspondente físico ao longo do tempo.

Assim, o princípio fundamental do PSO reside na metáfora social de um conjunto de partículas (soluções candidatas) exploram colaborativamente o espaço de busca para encontrar a solução ótima. Cada partícula no enxame representa uma possível combinação de parâmetros do sistema modelado, como a indutância (L), capacitância (C), resistência (R) ou resistência dos semicondutores no estado permissivo (R_ON) em conversores de potência. Essas partículas não apenas possuem conhecimento individual sobre sua melhor posição histórica, mas também compartilham informações sobre a melhor posição encontrada por todo o enxame, criando assim um mecanismo de inteligência coletiva que guia a busca pela solução ótima (Kennedy; Eberhart, 1995; Ozcan; Mohan, 1999).

Do ponto de vista matemático, o comportamento do PSO é governado por duas equações principais que atualizam a velocidade e posição de cada partícula em cada iteração. Para uma partícula "i" em uma dimensão "D" do espaço de parâmetros, a velocidade é atualizada combinando três componentes: um termo de inércia que

preserva parte do movimento anterior, um componente cognitivo que atrai a partícula em direção à sua melhor posição pessoal histórica, e um componente social que atrai em direção à melhor posição encontrada por todo o enxame. A posição da partícula é então atualizada simplesmente adicionando a velocidade calculada à sua posição atual. Esta simplicidade conceitual e matemática é uma das grandes vantagens do PSO, tornando-o relativamente fácil de implementar e adaptar a diferentes problemas (Kennedy; Eberhart, 1995; Kennedy; Eberhart, 1997).

Na aplicação específica à identificação de parâmetros para gêmeos digitais em sistemas da eletrônica de potência, o PSO é utilizado visando minimizar a diferença entre as respostas do sistema físico e do modelo digital. A função objetivo típica mede o erro quadrático entre os sinais de saída do sistema real (medidos por sensores) e os sinais simulados pelo gêmeo digital (Bai *et al.* 2024). Por exemplo, em um conversor Buck, podem-se comparar as formas de onda de tensão de saída ou corrente no indutor ou tensão do capacitor, ajustando iterativamente os parâmetros L, C e R do modelo até que a correspondência seja satisfatória. Este processo permite a criação inicial de um modelo preciso e, também, o acompanhamento contínuo de parâmetros que possam degradar-se com o tempo, como, por exemplo, a capacitância que diminui devido ao envelhecimento ou a resistência ON que aumenta com a degradação do semiconductor.

Visto isso, a implementação prática do PSO para gêmeos digitais segue um fluxo sistemático que começa com a inicialização do enxame, onde são definidos os limites físicos de cada parâmetro a ser identificado. Em seguida, as partículas são distribuídas aleatoriamente dentro deste espaço de busca, e a função objetivo é avaliada para cada uma delas. O algoritmo então entra em um ciclo iterativo onde as melhores posições pessoais e global são atualizadas, e as partículas se movem através do espaço de parâmetros de acordo com as equações de velocidade e posição. Este processo continua até que um critério de parada seja atingido, seja ele um número máximo de iterações, um valor mínimo aceitável para a função objetivo, ou a convergência do enxame (quando as partículas param de se mover significativamente) (Wu *et al.*, 2025). A Figura 2 traz um fluxograma do funcionamento do algoritmo PSO na identificação de parâmetros críticos de um gêmeo digital de um conversor Buck.

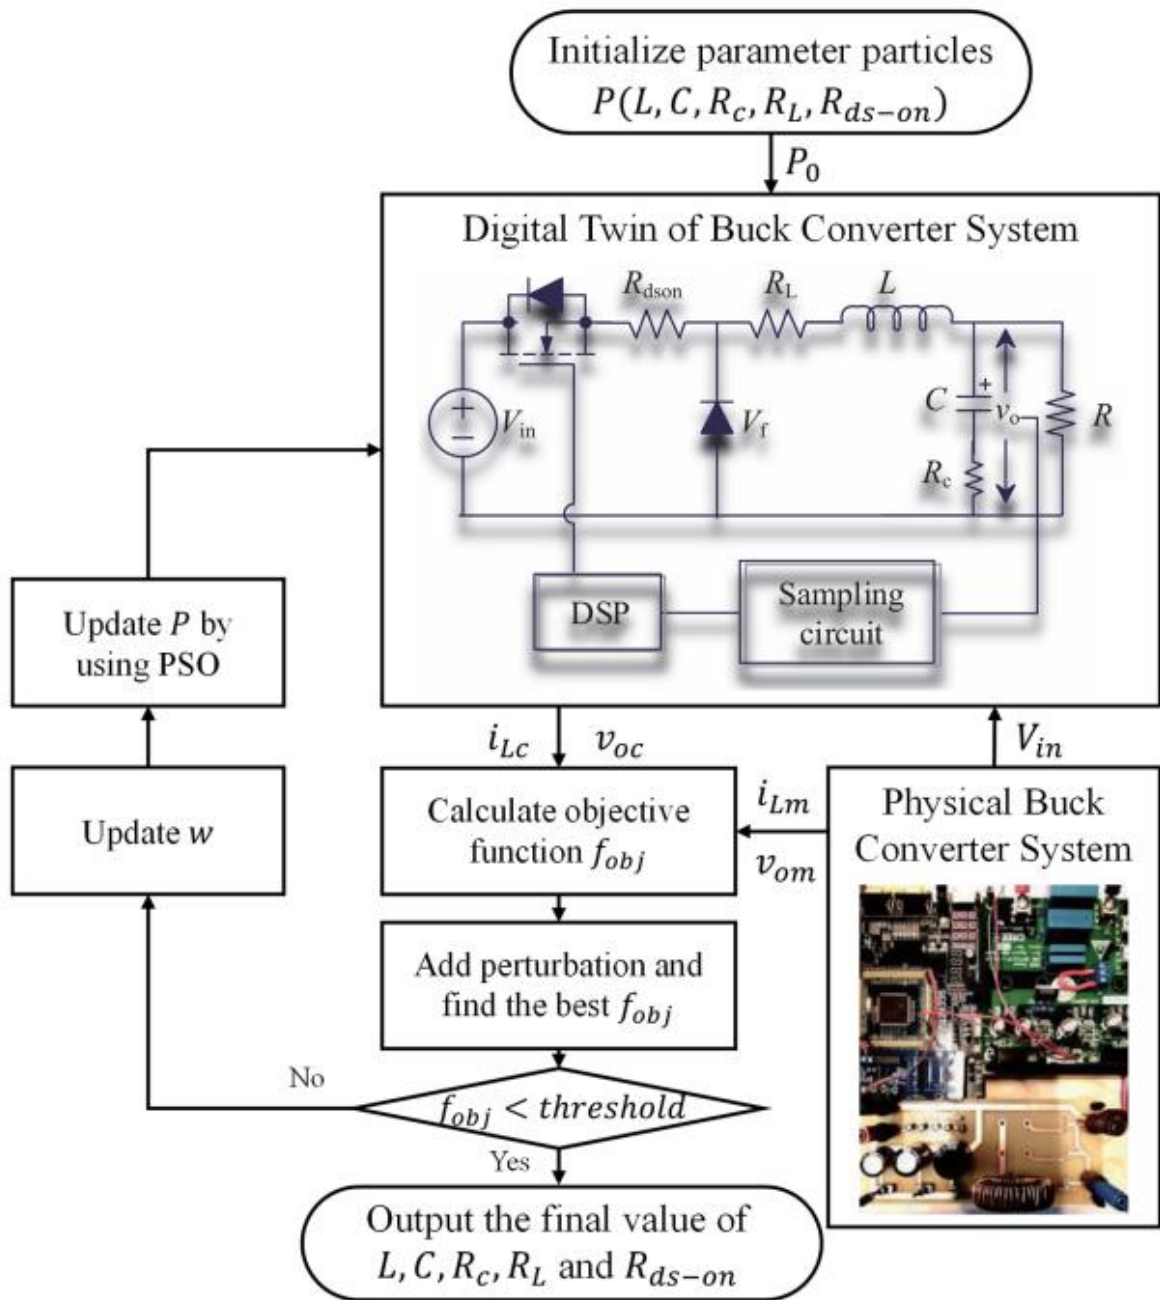


Figura 2 – Fluxograma de funcionamento de um DT de um conversor Buck com identificação por PSO. Fonte: Wu *et. al.* (2025)

Nesse contexto, o PSO apresenta múltiplas vantagens, entre elas: sua natureza baseada em população o torna menos suscetível a ficar preso em ótimos locais do que métodos de busca individual; não requer o cálculo de gradientes, o que é particularmente útil para sistemas não diferenciáveis ou quando a função objetivo é ruidosa (como ocorre com dados reais de sensores); e é intrinsecamente paralelizável, pois as avaliações da função objetivo para diferentes partículas pode ser realizadas simultaneamente. Além disso, o PSO demonstra robustez em face de incertezas e

variações paramétricas, uma característica valiosa quando se lida com sistemas reais que apresentam tolerâncias de fabricação e degradação ao longo do tempo (Wu *et al.*, 2025).

Nos trabalhos de Wu *et al.* (2025) e Bai *et al.* (2024), o PSO é mencionado como um dos métodos mais utilizados para a identificação de parâmetros em gêmeos digitais de eletrônica de potência. Além disso, o artigo de Wu *et al.* (2025) destaca o PSO por sua simplicidade de implementação, rápida convergência e boa precisão.

A escolha dos parâmetros do próprio algoritmo PSO (como o fator de inércia, coeficientes cognitivo e social, e tamanho do enxame) influencia significativamente em seu desempenho. Os valores típicos para problemas de identificação de parâmetros em eletrônica de potência incluem enxames de 20 a 50 partículas, fator de inércia entre 0,4 e 0,9 (frequentemente decrescente ao longo das iterações para transicionar de exploração para exploração), e coeficientes cognitivo e social próximos a 2,0. O número de iterações necessárias varia com a complexidade do problema, mas fica geralmente entre 50 e 200 para convergência satisfatória (Freitas; Lopes; Morgado-Dias, 2020).

Em resumo, este método oferece uma abordagem poderosa e flexível para a identificação de parâmetros em gêmeos digitais de sistemas de eletrônica de potência. Observa-se que a capacidade de lidar com espaços de busca multidimensionais, a robustez frente a não-linearidades e incertezas, e a eficácia comprovada em aplicações práticas o tornam uma ferramenta valiosa para manter a fidelidade entre modelos digitais e sistemas físicos ao longo de todo o seu ciclo de vida - desde o projeto inicial até a operação contínua e manutenção preditiva.

3.4.2 Métodos Baseados em Filtros e Estimação

Os métodos baseados em filtros constituem uma categoria diferente que se caracteriza por sua abordagem recursiva e baseada em modelos dinâmicos explícitos. Essa categoria precisa de um modelo matemático formal das dinâmicas do sistema, que é utilizado para prever estados futuros e então corrigir essas previsões com medições reais. Estes algoritmos são essencialmente estimadores sequenciais que processam dados à medida que chegam, atualizando continuamente suas estimativas de parâmetros. Uma característica distintiva crucial é seu tratamento explícito de incertezas através da modelagem formal de ruídos de processo e medição,

tipicamente assumidos como distribuídos de maneira gaussiana. Esta modelagem probabilística do ruído permite que estes métodos não apenas forneçam estimativas pontuais de parâmetros, mas também quantifiquem a incerteza associada a essas estimativas através de matrizes de covariância (Wu *et al.*, 2025).

O Filtro de Kalman (KF) é um exemplo desta categoria, sendo projetado para sistemas lineares com ruído gaussiano. Sua extensão, o *Extended Kalman Filter* (EKF), amplia a aplicabilidade para sistemas não lineares através de linearizações locais. Já o *Dual Extended Kalman Filter* (DEKF) avança ao estimar simultaneamente estados e parâmetros através de dois filtros acoplados. O *Recursive Least Squares* (RLS) oferece uma abordagem alternativa baseada em minimização recursiva de erros quadráticos (Bai *et al.*, 2024; Wu *et al.*, 2025).

Estes métodos se distinguem dos metaheurísticos por sua dependência de um modelo dinâmico bem definido e sua estrutura recursiva que os torna naturalmente adequados para implementação em tempo real. Em aplicações de gêmeos digitais, eles são importantes para monitoramento contínuo de parâmetros que variam lentamente com o tempo, como a degradação progressiva de componentes.

3.4.3 Métodos Baseados em Aprendizado de Máquina

Os métodos baseados em aprendizado de máquina são caracterizados pela descoberta automática de relações entre variáveis diretamente pelos dados, sem a necessidade de modelos físicos explícitos, em outras palavras, estes métodos aprendem a partir de dados empíricos do sistema analisado, levando a uma redução da necessidade de leis físicas, permitindo uma maior flexibilidade para encontrar padrões e correlações entre as entradas e saídas do sistema (Wu *et al.*, 2025). Além disso, esta característica de modelagem flexível permite capturar relações não lineares que seriam difíceis de expressar analiticamente. Estes métodos também possuem uma dependência aos conjuntos de dados, necessitando que eles sejam abrangentes para o treinamento, e possuem seu desempenho ligado à qualidade, quantidade e representatividade desses dados (Wu *et al.*, 2025).

As Redes Neurais Artificiais (*Artificial Neural Network* — ANN) representam a arquitetura fundamental desta categoria, com sua capacidade de aproximar funções não lineares arbitrárias através de composição de transformações simples. As redes

Nonlinear AutoRegressive with eXogenous inputs Artificial Neural Network (NARX-ANN) estendem esta capacidade para domínios dinâmicos através da incorporação de memória de estados passados. As *Deep Neural Networks* (DNN) aprofundam esta abordagem através de arquiteturas com múltiplas camadas que permitem a aprendizagem de características hierárquicas. Já as redes *Long Short-Term Memory* (LSTM) e *Gated Recurrent Unit* (GRU) se especializam em dados sequenciais através de mecanismos de memória de longo prazo (Wu *et al.*, 2025).

O que distingue estes métodos das outras categorias é a sua independência de modelos físicos, já que eles os aprendem diretamente dos padrões nos dados, tornando-os interessantes em problemas onde os mecanismos subjacentes são mal compreendidos ou complexos em demasiado. Em aplicações de gêmeos digitais eles se mostram eficazes para diagnóstico de falhas complexas, previsão de comportamentos em condições operacionais diversas e para análise de parâmetros não modelados ou de difícil modelagem (Bai *et al.* 2024; Wu *et al.*, 2025).

Trazendo um maior foco para a arquitetura ANN, ela se destaca por ser uma arquitetura base para a expansão das demais, por possuir uma abordagem computacional inspirada pela estrutura neuronal biológica, trazendo consigo a possibilidade de aprender com a experiência, tal qual os neurônios fazem. Tal característica permite uma captura de diversos padrões diretamente dos dados fornecidos para treinamento (Haykin, 1999; Hertz; Krogh; Palmer, 2018).

No contexto dos gêmeos digitais para eletrônica de potência, as ANNs atuam como tradutores universais entre o comportamento observado e os parâmetros internos invisíveis. Quando um conversor Buck apresenta uma certa resposta temporal à mudança de carga, uma ANN bem treinada consegue inferir padrões dessa resposta e apresentar quanto foi o impacto e em quais componentes houve esse impacto, tudo isso a partir do banco de dados na qual ela se baseou (Torchio *et al.*, 2024; Wu *et al.*, 2025).

A estrutura de uma ANN é composta por um conjunto de camadas de processamento compostas por: uma camada de entrada que recebe os dados brutos (tensões, correntes, temperaturas, entre outros), uma ou mais camadas ocultas que fazem as transformações dos dados e compreensão ou aprendizagem do comportamento, e uma camada de saída que fornece as respostas desejadas (parâmetros identificados, previsões, classificações) (Kamal *et al.*, 2024).

Cada neurônio em uma camada recebe as entradas e as pondera por "pesos" (que representam a importância de cada entrada), tudo é somado, passado um ajuste fino e o resultado passado por uma função de ativação. Essa função de ativação, como sigmoide, tanh ou ReLU, que transformam a soma linear em algo não linear, permitem com que a rede aprenda padrões complexos (Badarinath; Chierichetti; Kakhki, 2021). Tal estrutura pode ser observada na Figura 3, que não traz uma estrutura de uma ANN, mas sim de uma DNN, contudo suas estruturas são próximas o suficiente para auxiliar na visualização de seu funcionamento.




Figura 3 – Modelo genérico do funcionamento de uma rede neural. Fonte: Kamal *et al.*, 2024

O treinamento de uma ANN é um processo de aprendizado por tentativa e erro sofisticado. Inicialmente, os pesos são definidos aleatoriamente, no qual a rede entrega valores sem uma base. A cada exemplo de treinamento, ela compara sua previsão com a resposta correta, calcula o erro, e então alastra esse erro através da rede, ajustando levemente cada peso na direção que reduziria o erro. Esse processo,

chamado *back-propagation*, repete-se milhares ou milhões de vezes até que a rede aprenda o mapeamento correto (Ferrario *et al.*, 2017).

A força dessa arquitetura reside em sua capacidade de aprender relações complexas diretamente dos dados sem necessidade de um modelo físico explícito. Em muitos sistemas de eletrônica de potência, as relações entre parâmetros degradados e respostas do sistema são altamente não lineares, acopladas e difíceis de modelar analiticamente, porém ela consegue aprender essas relações através dos dados, resolvendo-os com maior eficácia (Wu *et al.*, 2025).

Outra vantagem crucial é a capacidade de generalização, já que uma ANN com um banco de dados abrangente e representativo, além dela ser bem treinada, permite a memorização e compreensão do comportamento do sistema, permitindo o reconhecimento de padrões de dados similares aos analisados em situações fora dos dados analisados durante o treinamento. O que, dentro do contexto de gêmeos digitais, permite análises de situações mais variadas, sem a necessidade de constante de recalibração, igual aos métodos baseados em modelos físicos, a depender dos erros “invisíveis” dos componentes (Hertz; Krogh; Palmer, 2018; Torchio *et al.*, 2024).

Para sistemas de potência, onde o tempo importa profundamente, certas variantes de ANNs se destacam. As NARX-ANN, que incorporam memória explicitamente, permitindo que a rede leve em conta não apenas as entradas atuais, mas também entradas e saídas passadas. O que permite capturar dinâmicas como a resposta transitória de um conversor ou a evolução térmica lenta de um módulo de potência (Wang, 2003).

Construir uma ANN eficaz para um gêmeo digital segue um passo-a-passo rigoroso, já que necessita de uma alta quantidade de dados do sistema físico operando em várias condições: normal, com diferentes cargas, em diferentes temperaturas, e idealmente com falhas conhecidas induzidas. Esses dados são pré-processados: normalizados, filtrados, e, talvez, transformados para extrair características relevantes (como componentes de Fourier para análise harmônica) (Torchio *et al.*, 2024).

A arquitetura da rede é então projetada se pensando na quantidade de camadas, quantos neurônios por camadas serão necessários e a função de ativação. Uma rede muito simples pode não capturar a complexidade do sistema; uma muito complexa pode “memorizar” os dados de treinamento sem realmente aprender a generalizar. O que implica em testar a rede neural para saber se a arquitetura utilizada

cumpriu com as necessidades do projeto inicial (Ferrario *et al.*, 2017; Torchio *et al.*, 2024).

O treinamento propriamente dito divide os dados em três conjuntos: treinamento (para aprender), validação (para ajustar hiperparâmetros) e teste (para avaliar o desempenho final). A depender da complexidade e do volume de dados, o treinamento pode levar de horas a dias.

O artigo de Lu *et al.* (2023), por exemplo, traz uma ANN sendo usada para identificação não invasiva de parâmetros em um conversor Boost. No qual a rede aprende a mapear as formas de onda, medidas da corrente do indutor e tensão de saída para os valores dos componentes internos, sem necessidade de interromper a operação ou adicionar circuitos de medição especiais.

Dentre as vantagens que essa arquitetura possui, temos a capacidade de modelar relações extremamente complexas, robustez a ruídos (quando bem treinadas e com uma boa biblioteca de dados), capacidade de processar múltiplas variáveis simultaneamente, e velocidade de inferência uma vez treinadas.

Mas os desafios são significativos, como a necessidade de grandes volumes de dados de treinamento que pode ser proibitiva, especialmente para falhas raras. O risco de *overfitting* — aprender os dados de treinamento tão bem que a rede se especializa demais, perdendo em generalização — e a necessidade de técnicas como regularização, *dropout* e validação cruzada (Jayasinghe *et al.*, 2024). Além disso, como Bai *et al.* (2024) traz, as ANN são como caixas pretas, já que é custoso saber exatamente como elas chegaram naqueles resultados, o que pode ser uma problemática em aplicações críticas onde a explicabilidade é importante.

Os métodos baseados em dados também são sensíveis à qualidade dos dados, pois dados incompletos, enviesados ou mal rotulados levam a modelos com os mesmos problemas (Jayasinghe *et al.*, 2024). Levando todas essas questões em consideração, talvez a melhor solução seja uma combinação entre o uso da física integrada as ANN's. Essa abordagem híbrida traz o melhor dos dois mundos ao possuir a precisão dos dados e a generalização da física (Wu *et al.*, 2025).

Em resumo, essa arquitetura representa uma ferramenta interessante e versátil para identificação de parâmetros em gêmeos digitais de sistemas de eletrônica de potência. Através de sua capacidade de aprender padrões complexos diretamente dos dados, ela permite descobrir relações sutis entre comportamentos observados e parâmetros internos, muitas vezes revelando conexões que escapariam das

abordagens tradicionais. Porém, as ANN's não são uma solução absoluta, já que requerem dados, cuidado no projeto e entendimento de suas limitações. Mas quando aplicadas adequadamente, oferecem uma maneira única de manter os gêmeos digitais sintonizados com a realidade cada vez mais complexa dos sistemas físicos.

3.4.4 Métodos Probabilísticos

Os métodos probabilísticos formam uma categoria que se diferencia pelo foco explícito na quantificação, propagação e gestão de incertezas nos processos de identificação de parâmetros. O que os caracteriza é a representação de parâmetros não como valores determinísticos, mas como distribuições de probabilidade que encapsulam o conhecimento atual sobre seus valores possíveis (Thelen *et al.*, 2023; Wu *et al.*, 2025). Esta representação probabilística permite uma avaliação mais rica e realista, reconhecendo que incertezas são inerentes a sistemas reais devido a tolerâncias de fabricação, variações operacionais e limitações de medição. A ideia central destes métodos é que, em vez de buscar um único valor "verdadeiro" para cada parâmetro, deve-se manter e atualizar crenças probabilísticas que refletem tanto o conhecimento prévio quanto a evidência proporcionada pelos dados observados (Bai *et al.*, 2024).

A *Polynomial Chaos Expansion* (PCE) exemplifica esta categoria ao representar variáveis aleatórias através de séries de polinômios ortogonais, permitindo uma propagação eficiente de incertezas por meio de modelos complexos (Bai *et al.*, 2024). As abordagens bayesianas representam outra vertente importante, utilizando o teorema de Bayes para atualizar distribuições a priori em distribuições a posteriori a partir de novos dados (Chen *et al.*, 2021; Wu *et al.*, 2025). Também há os métodos de Monte Carlo que, embora computacionalmente mais intensivos, oferecem uma abordagem flexível por amostragem estocástica (Bai *et al.*, 2024). O que unifica estes métodos é seu foco na quantificação de incertezas, já que eles fornecem estimativas de parâmetros, medidas da confiança nessas estimativas e intervalos de credibilidade ou momentos estatísticos. Em gêmeos digitais, esta capacidade é usada para avaliação de riscos, análise de confiabilidade e tomada de decisão sob incerteza.

Focando-se no método PCE, ele traz uma metodologia probabilística para representação e propagação de incertezas em sistemas de engenharia complexos. Fundamentado na *Homogeneous Chaos* desenvolvida originalmente por Norbert

Wiener por volta de 1930, o PCE evoluiu de suas raízes na física matemática para tornar-se uma ferramenta na análise de incertezas para sistemas de engenharia moderna, encontrando aplicação relevante nos gêmeos digitais para eletrônica de potência (Xiu; Karniadakis, 2002; Xiu, 2010; Wiener; 1938).

O conceito deles reside na representação de variáveis aleatórias e processos estocásticos através de expansões em séries de polinômios ortogonais. Esta representação baseia-se no princípio fundamental de que qualquer variável aleatória com variância finita pode ser expressa como uma combinação linear infinita de polinômios ortogonais em variáveis aleatórias gaussianas padrão (Wiener, 1938). Na prática, esta série infinita é truncada para uma soma finita, criando uma aproximação espectral que captura as características estatísticas essenciais da variável aleatória original (Xiu; Karniadakis, 2002; Xiu, 2010). Além disso, essa abordagem, em geral, exibe uma rápida convergência para uma ampla classe de distribuições de probabilidade, o que a torna bem eficiente comparada a métodos de amostragem direta como Monte Carlo (Milton *et al.*, 2020).

A implementação prática do PCE começa com a representação dos parâmetros incertos do sistema, como variáveis aleatórias com distribuições de probabilidade conhecidas (Su; Strunz, 2010). Para cada parâmetro incerto é selecionado uma família de polinômios ortogonais apropriada, como polinômios de Hermite para variáveis Gaussianas, polinômios de Legendre para variáveis uniformes, ou polinômios de Laguerre para variáveis exponenciais (Wiener, 1938; Xiu, 2010). Esta correspondência entre distribuição de probabilidade e família polinomial não é arbitrária, mas fundamentada na teoria da medida e na ortogonalidade com respeito à função peso que corresponde à função densidade de probabilidade da variável aleatória (Xiu; Karniadakis, 2002; Xiu, 2010). A escolha apropriada garante boas propriedades de convergência e estabilidade numérica.

O principal da metodologia envolve a expansão da variável aleatória de interesse Y (geralmente uma quantidade de saída do sistema) em termos das variáveis aleatórias de entrada ξ através da expressão:

$$Y(\xi) = \sum_{\alpha \in \mathcal{A}} c_{\alpha} \Psi_{\alpha}(\xi) \quad (1)$$

No qual Ψ_{α} representa os polinômios multidimensionais, c_{α} são os coeficientes espectrais a determinar, e α são multi-índices que identificam os termos

da expansão. O conjunto A define o truncamento da expansão, com estratégias comuns incluindo expansão total de grau máximo p (onde $\sum \alpha_i \leq p$) ou expansões baseadas em índices esparsos que aproveitam a estrutura de dependência do sistema (Milton *et al.*, 2020).

A determinação dos coeficientes c_α constitui a etapa computacional central do PCE, com duas abordagens principais emergindo na prática. A abordagem intrusiva, ou baseada em Galerkin, projeta as equações governantes do sistema sobre o espaço gerado pelos polinômios de caos, resultando em um sistema aumentado de equações determinísticas para os coeficientes (Xiu; Karniadakis, 2002; Xiu, 2010). Embora mais precisa, esta abordagem requer modificações significativas dos códigos de simulação existentes. Já a abordagem não intrusiva, baseada em amostragem ou regressão, trata o modelo computacional como uma “caixa preta” e estima os coeficientes através da solução de um problema de regressão linear usando amostras da resposta do sistema. No contexto de gêmeos digitais em sistemas embarcados, a abordagem não intrusiva é preferida devido à sua compatibilidade com plataformas de hardware reconfigurável (FPGA) e códigos de simulação existentes (Bai *et al.*, 2024).

Se voltando aos gêmeos digitais na eletrônica de potência, o PCE assume um papel no desenvolvimento de gêmeos digitais que se utilizam de abordagens probabilísticas, no caso, os modelos digitais que não apenas replicam o comportamento médio esperado do sistema físico, mas também quantificam e propagam as incertezas associadas aos parâmetros do sistema. Por exemplo o trabalho apresentado por Bai *et al.* (2024), no qual há um conversor Buck digital e seus parâmetros como indutância, capacitância e resistência podem ser representados como variáveis aleatórias com distribuições que refletem tolerâncias de fabricação, variações ambientais ou degradação ao longo do tempo. Além disso, o PCE permite calcular, de maneira analítica, a resposta média, variância e momentos estatísticos superiores através dos coeficientes c_α do conversor, os intervalos de confiança para tensões e correntes de saída, probabilidades de violação de limites operacionais, e sensibilidades das saídas em relação às incertezas paramétricas.

A Figura 4 ilustra essa aplicação, mostrando um esquema de gêmeo digital probabilístico embutido em controlador (FPGA) para um conversor Buck, onde o PCE é utilizado para construir o modelo estocástico do conversor e formular as equações de análise nodal estocásticas. Nesta implementação, os resultados da simulação

probabilística são utilizados para calcular limites estatísticos que permitem monitorar anormalidades através da comparação entre medições do sistema físico e as faixas de variação esperadas pelo modelo probabilístico (Bai *et al.*, 2024). Esta capacidade de detecção baseada em probabilidades é interessante para identificação preditiva de degradação de componentes. Por exemplo, quando a capacitância de um capacitor específico começa a sair da faixa de tolerância nominal, o comportamento dinâmico do conversor apresentará transições de tensão que excedem os limites probabilísticos estabelecidos pelo PCE.

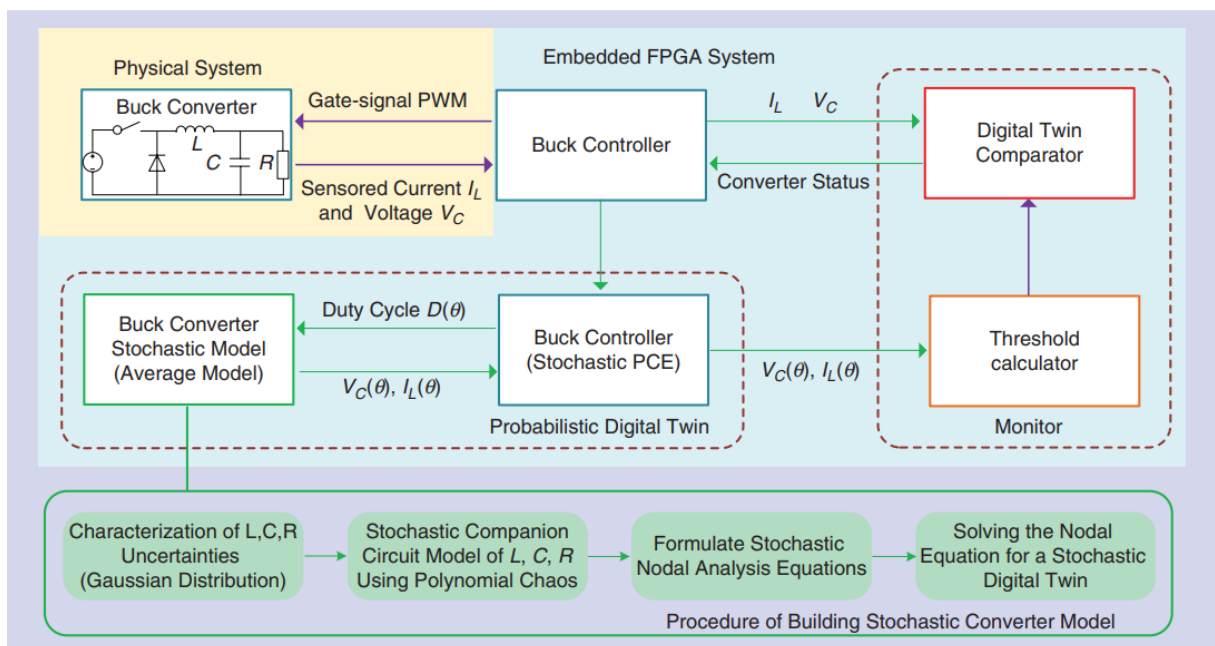


Figura 4 – Esquema de funcionamento de um DT probabilístico em funcionamento.
Fonte: Bai *et al.* (2024)

As vantagens computacionais do PCE o tornam chamativos para implementação em sistemas embarcados com recursos limitados, como os encontrados em aplicações de eletrônica de potência. Uma vez determinados os coeficientes da expansão, a avaliação da resposta do sistema para diferentes realizações das variáveis aleatórias é reduzida a operações polinomiais relativamente simples, dispensando execuções repetidas do modelo físico completo (Milton *et al.*, 2020; Su; Strunz, 2010). Esta eficiência computacional é complementada pela capacidade do PCE de fornecer diretamente os momentos estatísticos da resposta através de fórmulas analíticas simples envolvendo os coeficientes da expansão, bem como por permitir análises de sensibilidade global eficientes através dos índices de

Sobol, que quantificam a contribuição relativa de cada parâmetro incerto para a variância total da resposta.

Contudo, o PCE, assim como os demais métodos, não é perfeito. Uma de suas lacunas é a complexidade computacional que o PCE tradicional cresce exponencialmente com a quantidade de dimensões do sistema, embora técnicas de expansão esparsa e métodos de compressão sensíveis diminuam este problema. Outra é a seleção adequada da base polinomial e da estratégia de truncamento requer conhecimento especializado, e a qualidade dos resultados depende criticamente da precisão na estimativa dos coeficientes. Além disso, para sistemas com não-linearidades pronunciadas ou descontinuidades, a convergência desse método pode ser mais lenta, necessitando de estratégias adaptativas ou abordagens híbridas (Milton *et al.*, 2020; Xiu, 2010).

No contexto dos gêmeos digitais, percebe-se uma tendência crescente para combinar PCE com técnicas de aprendizado de máquina, fornecendo estrutura probabilística fundamental, enquanto métodos baseados em dados refinam e adaptam os modelos em tempo real. Da mesma forma, a combinação com métodos de redução de modelos permite a aplicação em sistemas de grande porte mantendo a viabilidade computacional (Bai *et al.*, 2024; Milton *et al.*, 2020).

Basicamente, o PCE se mostra uma abordagem de análise de incertezas para sistemas de engenharia, oferecendo uma boa estrutura matemática e computacionalmente eficiente para a quantificação e propagação de incertezas e sua aplicação em gêmeos digitais para eletrônica de potência se mostra valorosa na criação de modelos digitais capazes de replicar o comportamento esperado, encapsular e propagar as incertezas presentes nos sistemas físicos, permitindo um monitoramento mais robusto, diagnóstico mais preciso e tomada de decisão mais fundamentada em condições de incerteza.

3.5 ARTIGOS SELECIONADOS

Como comentado anteriormente, é possível dividir os tipos de modelagem em três: as físicas, as baseadas em dados e as híbridas. Dentre os artigos selecionados, nenhum se mostrou ser apenas baseado em dados, logo as propostas que foram apresentadas variaram entre a abordagem de modelagem física e abordagem de modelagem híbrida.

3.5.1 Modelagem física

Dentre os artigos analisados, é possível classificar os estudos de Kumar e Kumar (2025), Liu, Yang e Liu (2025), Nazif *et al.* (2025) e Song *et al.* (2024) como modelagem física, eles se classificam assim, pois eles modelam os sistemas reais puramente em equações matemáticas, não se utilizando de ML ou IA para modelar ou identificar possíveis lacunas futuras na modelagem, permitindo que os gêmeos digitais modelados dessa maneira possam se conectar num primeiro momento ao sistema real, capturar seus dados e prever ou analisar de maneira *offline* os parâmetros e a saúde dos componentes, como é feito no trabalho de Song *et al.* (2024).

E mesmo com esses quatro artigos trazendo modelagem física, ainda há diferença entre eles, pois ela mudará a depender do sistema a ser modelado e de sua complexidade, trazendo uma certa dificuldade para comparar a eficiência dos artigos uns com os outros pelas suas diferenças em sistemas. Contudo, ainda é possível observar certas implicações que fizeram os autores escolherem seus métodos, além das mudanças.

Song *et al.* (2024), por exemplo, fizeram um gêmeo digital voltado para inversores do tipo 3L-ANPC, para isso foi necessário identificar a topologia do sistema real antes de tudo, como é mostrado na Figura 5.

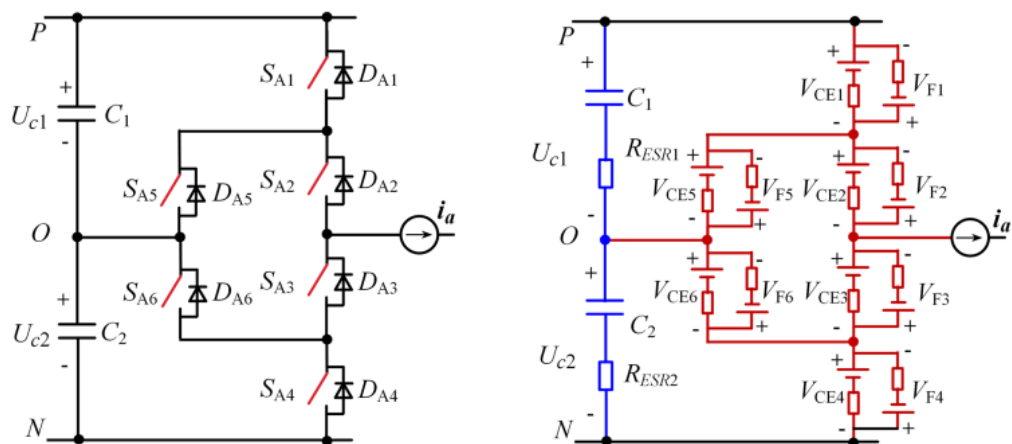


Figura 5 – Topologia ideal (a esquerda) e real (direita) de um dos níveis de um inversor 3L-ANPC. Fonte: Song *et al.* (2024)

A esquerda há a topologia ideal de funcionamento do sistema, já a direita há a topologia real usada como base para a modelagem. Após isso, o sistema foi derivado de maneira matemática se baseando em leis físicas, trazendo consigo parâmetros essenciais para análise da saúde de componentes, como a tensão de saturação de IGBT's e a resistência em série equivalente de capacitores. Com todo o modelo contínuo feito foi discretizado via Runge-kutta de quarta ordem, isso por ser mais estável e altamente preciso para cenários mais complexos, e implementado computacionalmente a modelagem do sistema analisado.

Após isso, Song *et al.* (2024) se utilizaram de um algoritmo de PSO melhorado para a identificação dos parâmetros a partir dos dados de operações reais. Para isso foi necessário definir bem os erros de cada categoria dos parâmetros do DT e do sistema físico, além de fazer uma identificação em cascata se baseando no tempo de degradação de cada componente, primeiro são calculados aqueles com degradação mais lenta (o que fará os resultados serem mais constantes por mais tempo), logo os primeiros a serem identificados são os indutores e a resistência de carga, depois os capacitores e por último os interruptores de potência. Por fim, esses valores são constantemente lidos e comparados, levando a um fator de inércia adaptativa, o que traz maior confiabilidade com o passar do tempo pelo refinamento na identificação e o equilíbrio dos valores.

Já Kumar e Kumar (2025) e Liu, Yang e Liu (2025) se baseiam na modelagem por espaço de estados. Contudo, o projeto dos pesquisadores Kumar e Kumar (2025) trazem maior complexidade, já que eles buscam o desenvolvimento de um sistema completo para conversores *grid-connected* de dois estágios, apresentado na Figura 6.

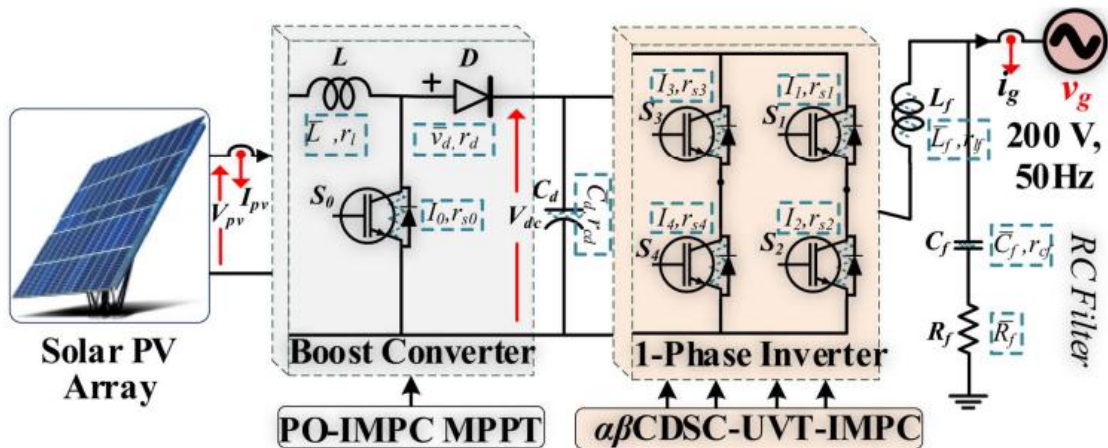


Figura 6 – Topologia do sistema fotovoltaico *grid-connected*. Fonte: Kumar e Kumar (2025).

Isso implica uma modelagem considerando todo o sistema, ou seja, a modelagem do conversor Boost ligado a célula fotovoltaica e o inversor monofásico ligado à rede elétrica. Em cada um desses estágios são derivadas equações de espaço de estados que descrevem a dinâmica dos componentes em seus estados de chaveamento. Com isso também se consegue capturar e analisar variáveis críticas dos componentes, incluindo resistências parasitas. Com o modelo contínuo feito, se utiliza do método de Tustin para ser discretizado. Além disso, Kumar e Kumar (2025) também implementam algoritmos de controle, como o IMPC (*Integral Model Predictive Control*) em conjunto com o P&O (*Perturb and Observe*) com ação integral para rastreamento preciso do ponto de máxima potência que o conversor Boost. Já para o inversor foi utilizada a estratégia $\alpha\beta$ CDSC-UVT-IMPC já que permite um sincronismo estável com a rede, além de estabelecer qualidade de energia.

Agora, dentro da identificação de parâmetros, Kumar e Kumar (2025) se utilizam de um algoritmo híbrido, o E2FD-HO (*Electromagnetic Field and Electrostatic Discharge Hybrid Optimization*), já que permite a estimação de parâmetros desconhecidos ou que variam com o passar da degradação do sistema. Tal algoritmo se utiliza da combinação de mecanismos de atração baseado em cargas — o que promove uma exploração do estado de busca — com um movimento de partículas orientada por forças eletromagnéticas, derivadas da lei de Coulomb, para refinar a busca de parâmetros. Para isso, é necessário iniciar com uma função objetivo que meça a diferença entre o sistema real e o DT para as variáveis-chave — como a

corrente do painel fotovoltaico, tensão do barramento DC e corrente injetada na rede. Isso permite que a cada interação as posições das partículas sejam atualizadas baseadas em suas cargas e nas forças exercidas pelas demais partículas, até convergirem para uma solução que minimize o erro global do sistema. Isso permite uma grande robustez na identificação de parâmetros e manutenção preditiva.

Já Liu, Yang e Liu (2025) trazem uma modelagem mais “simples” por focarem num único componente, que seria um conversor Buck, mostrado em seus estados de MOSFET ligado (a esquerda) e desligado (a direita) na Figura 7. Necessitando de menos etapas que os de Kumar e Kumar (2025) para estabelecer quais parâmetros serão identificados, porém, permitindo o uso maior de poder computacional para a identificação precisa de parâmetros parasitários mais complexos de se medir, como as resistências do MOSFET, do indutor e do capacitor. Além disso, eles conseguem modelar circuitos de amostragem, como divisores de tensão e filtros passivos. O artigo se utiliza do método de Runge-Kutta de quarta ordem para discretização e solução numérica. Liu, Yang e Liu (2025) também implementam um controlador PID não conectado ao DT, mas possível de ser manipulado por terceiros a partir de novos parâmetros recomendados diretamente pelo gêmeo digital, permitindo uma rápida mudança no sistema sem a necessidade de uma nova análise dos componentes.




Figura 7 – Topologia nos dois estados de chaveamento de um conversor Buck.
Fonte: Liu, Yang e Liu (2025)

Já na identificação de parâmetros, que é um ponto bem explorado pelos autores, reside um método um tanto inovador de dois estágios que combinam algoritmos metaheurísticos com análise física do comportamento do circuito. Primeiramente os autores Liu, Yang e Liu (2025) trouxeram um comparativo entre três algoritmos de otimização, sendo ele PSO, GWO (*Grey Wolf Optimizer*) e DA (*Dragonfly Algorithm*), eles foram utilizados para a identificação dos principais parâmetros do sistema, como indutância, capacitância e resistência dos

componentes. Após os testes, PSO apresentou o melhor desempenho dentre os algoritmos analisados no escopo do artigo, contudo ainda houveram erros significativos na estimação da resistência do MOSFET e da resistência do indutor, isso ocorreu por eles terem efeitos similares na forma da onda de saída do sistema. Por isso as estimações foram feitas com método híbrido. No primeiro estágio o PSO fará a estimação da indutância, capacitância e resistência do capacitor, enquanto um segundo estágio é aplicado se utilizando das leis de Kirchhoff durante os estágios de chaveamento para ser possível calcular as resistências faltantes, se aproveitando dos valores de indutância obtidos no estágio anterior. Com essa abordagem iterativa se cria um ciclo no qual estimações mais precisas de indutância levam a cálculos mais precisos das correntes parasitas do indutor e do MOSFET.

Nazif *et al.* (2025), por outro lado, expandem a modelagem em sua pesquisa ao modelarem o conversor Buck juntamente aos possíveis erros que os sensores do sistema possuem. Para isso, após todo o processo de analisar a topologia do sistema real em cálculos físicos coerentes, eles discretizam os parâmetros do sistema utilizando Euler implícito, essa escolha ocorre tanto para aumentar o poder computacional ao se utilizar de um método mais simples, quanto por sua estabilidade numérica para sistemas stiff, além do erro do algoritmo já ser incorporado aos parâmetros do sistema digital. E, como dito antes, o uso do Euler Implícito permite o maior uso de poder computacional em outras demandas do trabalho, como nos dez parâmetros analisados pelos autores, sendo eles quatro parâmetros do conversor — a resistência parasita do indutor e do MOSFET, a capacitância e a indutância — e de seis outros parâmetros que vem dos três sensores apresentados na topologia da Figura 8.




Figura 8 – Topologia do conversor Buck com sensores. Fonte: Nazif *et al.* (2025)

Já na identificação dos parâmetros, Nazif *et al.* (2025) fazem uma análise entre IPM (*Interior Point Method*) e PSO para selecionar o melhor método para o problema explorado e objetivo selecionado. Neste caso, IPM se mostrou um método superior para os autores por sua velocidade de convergência e precisão ser maior em comparação ao PSO. Para a identificação dos parâmetros foram utilizadas cinquenta amostras por ciclo de fechamento em regime permanente, após isso, uma função custo pondera os erros quadráticos da corrente do indutor e a tensão do capacitor, calculando, a partir disso os parâmetros do sistema são estimados.

Na Tabela 1 é feito um compilado das características mais importantes dos três artigos que se utilizam de uma abordagem física em sua modelagem, nela serão comparadas certas características chaves para sua aplicabilidade geral, funcionamento, complexidade e custo de aplicação.

Cr�terios\Autores	Song et al. (2024)	Kumar e Kumar (2025)	Liu, Yang e Liu (2025)	Nazif et al. (2025)
Objetivo do artigo	Monitoramento multiparam�trico n�o invasivo	Monitoramento de condi�o para sistemas fotovoltaicos <i>grid-connected</i>	Identifica�o de par�metros	Identifica�o de par�metros com erros de sensores
Topologia analisada	Inversor do tipo 3L-ANPC	Sistema fotovoltaico <i>grid-connected</i>	Conversor Buck	Conversor Buck com sensores
Abordagem na modelagem	F�sico-anal�tico	F�sica	F�sica	F�sico-anal�tico
M�todo de identifica�o	PSO melhorado	E2FD-HO	PSO em dois est�gios	IPM
Par�metros modelados	12 a 16 (por fase)	15 a 20	10 a 12	10 (4 do conversor, 6 dos sensores)
Erro de identifica�o	Abaixo de 5% (em condi�es ideais)	Abaixo de 1,5% (em condi�es ideais)	Abaixo de 2,33% (em condi�es ideais)	Abaixo de 10% com sensores com at� 1% de erro
Aplicabilidade industrial	Moderada para baixa dependendo dos tipos de sensores	Moderada para baixa a depender dos tipos de sensores	Moderada	Alta
Depend�ncia de dados inicial	Alta para calibra�o inicial	Alta para calibra�o inicial	Alta para calibra�o inicial	Alta na calibra�o inicial
Depend�ncia de dados cont�nua	Muito baixa ap�s calibra�o	Baixa para moderada ap�s calibra�o	Moderada ap�s calibra�o (Recalibragem constante)	Moderada ap�s calibra�o (Recalibragem constante)
Controlador embutido	Sem controlador embutido	PO-IPMC MPPT (Conversor) $\alpha\beta$ CDSC-UVT-IMPC (Inversor)	PID poss�vel de ser atualizado por terceiros	Sem controlador embutido
Principal lacuna	Falta de testes em ambiente n�o controlado	Alta complexidade pelo uso de espa�o de estados	Aumento da complexidade com PSO de dois est�gios	Falta an�lise do custo computacional do sistema

Tabela 1– Comparativo entre os artigos com modelagem f sica. Fonte: O autor (2025)

3.5.2 Modelagem híbrida

Agora, trazendo para modelagens híbridas, podemos classificar os trabalhos de Liu, Qing e Chen (2024), Torchio *et al.* (2025) e Roy e Sarwat (2025) nessa categoria. Isso se deve, pois eles utilizam dos cálculos físicos nas suas equações de modelagem, porém eles também modelam possíveis lacunas se utilizando de dados aprendidos por ML ou IA modificando os cálculos de maneira a compensar essas lacunas e trazer uma maior robustez ao processo, contudo havendo a necessidade de constantemente serem alimentados com os dados para funcionar corretamente.

Liu, Qing e Chen (2024) se utilizaram de uma topologia física já conhecida do conversor Buck e a implementam no ambiente do MATLAB/Simulink, preservando as relações matemáticas dos componentes em sua estrutura fundamental. Contudo, ele não se utiliza de leis físicas ou cálculos matemáticos, mas sim em dados para a identificação dos parâmetros. A topologia é apenas uma carcaça que o algoritmo de identificação utilizará para chegar nos dados.

Logo, na identificação dos parâmetros Liu, Qing e Chen (2024) trazem uma camada de PSO que, assim como os demais que se utilizam do mesmo algoritmo, encontra o melhor conjunto dos parâmetros de indutância, capacitância e resistências parasitas, contudo, tais parâmetros são selecionados a partir de comparações entre a forma de onda gerada pelo DT com a forma de onda da saída do sistema real. Para alcançar tal objetivo, os pesquisadores trazem de inovador é uma metodologia que se utiliza de um mapeamento biunívoco que seleciona de 4 a 8 pontos de amostragem estratégicos distribuídos em um único ciclo de chaveamento e se utiliza de uma função objetivo que pondera os erros de tensão e corrente. Assim como Liu, Yang e Liu (2025), Liu, Qing e Chen (2024) também precisaram resolver o acoplamento natural que ocorre entre a resistência parasita do indutor e a do MOSFET, para esse problema os autores desenvolveram uma estratégia de desacoplamento ao considerarem as correntes parasitas como um conjunto e, logo após, trazerem múltiplos pontos de operação para separar os valores, garantindo uma identificação dos parâmetros que melhor se encaixe na forma de onda analisada, mesmo que sejam necessários mais dados para tal identificação. Todo o sistema descrito pode ser observado na Figura 9, onde eles trazem a esquerda o sistema físico e suas saídas de corrente e tensão, e a direita mostra o gêmeo digital de um ciclo, trazendo sua camada de modelagem e de identificação de parâmetros.

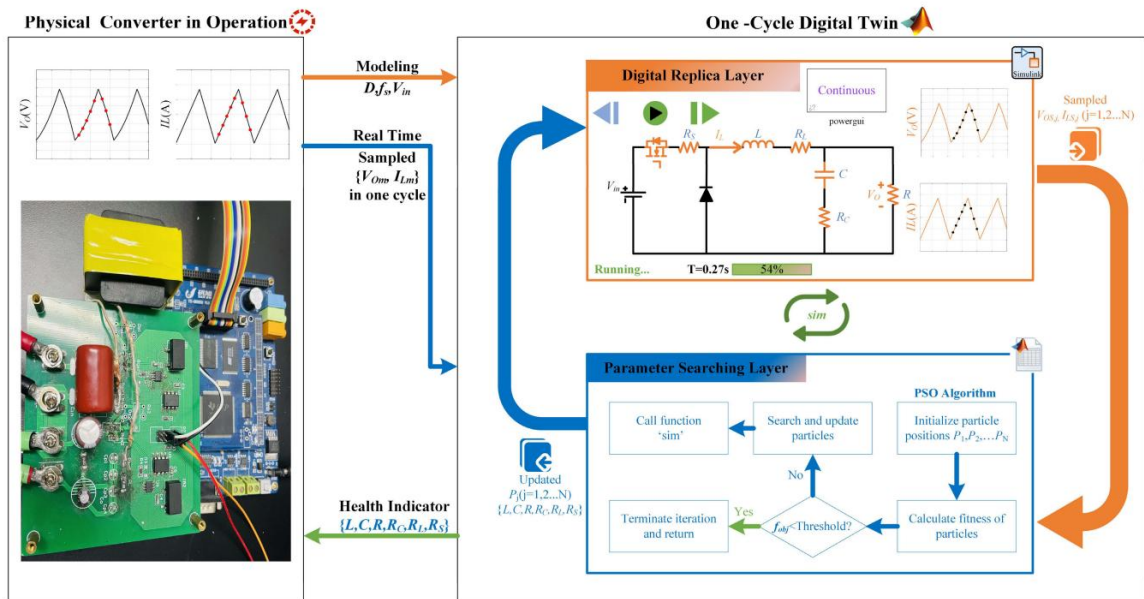


Figura 9 – Funcionamento do gêmeo digital proposto por Liu, Qing e Chen (2024).
Fonte: Liu, Qing e Chen (2024)

Torchio *et al.* (2025) já trazem um DT mais focado para atingir o ponto ideal de temperatura dos componentes, além de ter um foco e forte avanço na sua construção híbrida. Isso ocorre, pois o foco do trabalho deles é no monitoramento térmico em um sistema térmico industrial, o que os obrigou a fazer uma modelagem com fundamentação física se atendendo aos domínios elétricos, térmicos e fluidodinâmicos de maneira acoplada. Dentro do domínio elétrico foi desenvolvido um modelo de perdas baseado em *datasheets* (fichas técnicas) e medições experimentais, identificando tanto as perdas por indução quanto pelas de chaveamento, tudo isso através de ajustes polinomiais que incorporam a dependência térmica. Agora dentro do domínio térmico foi utilizada a equação de advecção-difusão que foi discretizada pelo Método dos Elementos Finitos (MEF), dando um modelo de alta fidelidade com, aproximadamente, cem mil graus de liberdade, contudo isso gerou um gargalo de tempo muito alto para aplicações em tempo real, então também foi necessário aplicar técnicas de Redução de Ordem do Modelo (ROM) baseadas em *moment matching*. Após a aplicação do ROM, o sistema reduziu para vinte graus de liberdade, trazendo erros de temperatura inferiores a 2,5°C. Já dentro do domínio fluidodinâmico, os autores acabam por trazer uma simplificação pela dificuldade da análise em tempo real deste domínio. Por isso eles adotam uma abordagem de fazer os efeitos do fluido de resfriamento como parâmetros pré-computados dentro do modelo térmico,

conseguindo trazer a implementação em tempo real sem comprometer muito a precisão do DT.

Já na identificação de parâmetros, Torchio *et al.* (2025) trazem uma abordagem bem diferente das demais. Pois os autores enfrentaram um desafio prático referente a origem dos componentes semicondutores que vinham de diferentes fornecedores, o que pode levar a fortes variabilidades no comportamento térmico. Para contornar essa situação, os autores propuseram uma integração do modelo físico reduzido (a parte modelada) com duas redes neurais *Feed-Foward* (*Feed-Foward Neural Network* – FFNN), como é possível ver na Figura 10, elas foram alimentadas por um banco de dados gerado experimentalmente com os diferentes IGBTs usados em diversas situações — como mudanças de potência, corrente, frequência, entre outras — o que gerou material suficiente para alimentá-las. A primeira FFNN atua na correção das entradas do modelo térmico, ajustando os cálculos estimados a partir das leituras dos sensores NTC (*Negative Temperature Coefficient*) em tempo real. Já a segunda FFNN atua na correção das saídas do modelo térmico, ela compensa as discrepâncias entre o comportamento previsto pelo sistema e o observado, resultantes de possíveis incertezas nos parâmetros materiais, aproximações da redução de ordem e possíveis variações entre os fabricantes.

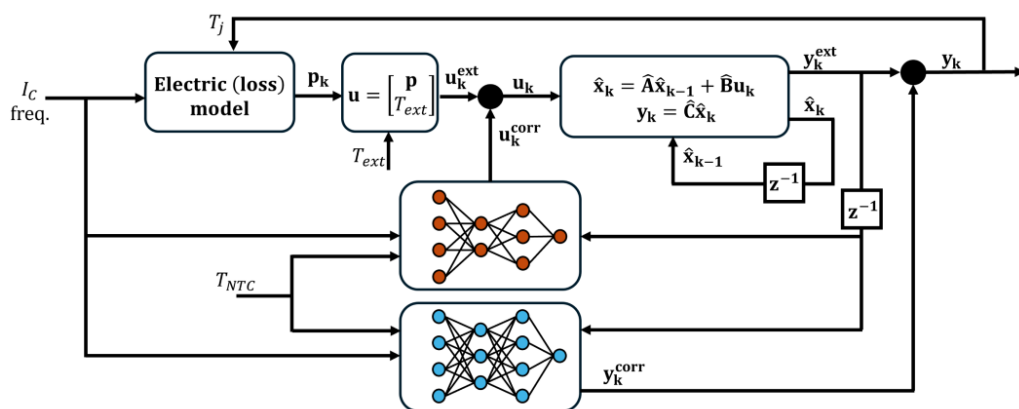


Figura 10 – Modelo de arquitetura híbrida proposto por Torchio *et al.* (2025). Fonte: Torchio *et al.* (2025)

Os autores Roy e Sarwat (2025) já trazem uma proposta de DT voltada para um inversor de ponte H que seja imune a ruídos. Para isso, eles também trouxeram uma abordagem híbrida em sua modelagem. Para a modelagem os autores constroem um modelo de chaveamento digital do inversor real no ambiente virtual do

MATLAB/Simulink, eles validam tal modelo a partir de dados experimentais coletados do protótipo real do inversor, após isso os dados são otimizados via PSO. Este modelo serve, inicialmente, para gerar um conjunto de dados com degradação sintética no qual os parâmetros do sistema (como indutância e capacitância) e as resistências parasitas do sistema sejam variados progressivamente dentro de certos limites que preservem a qualidade da energia na saída do sistema.

Com os dados gerados, agora é possível alimentar as ML's presentes nos dois estágios do sistema de identificação de parâmetros. No primeiro estágio foi utilizado o modelo *Random Forest* (RF) na ML para ser treinado com os dados sintéticos, com isso é estabelecido uma linha base de alta precisão na estimação das resistências parasitas nas condições ideais, alcançando, assim, excelentes métricas, com o parâmetro R^2 bem próximo de 100% e um erro quadrático muito baixo. Já no segundo estágio, focado na estimação da ESR (*Equivalent Series Resistance*) do capacitor, como é possível ver na Figura 11, os autores trouxeram uma PINN (*Physics-Informed Neural Network*) que faz a integração explícita de equações físicas da degradação eletroquímica dos capacitores em sua função de perda, além disso, a PINN junta três questões fundamentais, que são a perda de dados, a perda física e a perda derivativa, tudo isso para melhorar a aderência nas medições, melhorar a consistência com as leis de degradação conhecidas e trazer suavidade temporal das previsões. A ideia é que a rede PINN seja capaz de funcionar mesmo quando os dados de treinamento sejam escassos ou contaminados por ruídos complexos de diversas fontes, sejam com *ripple* de alimentação, transientes de chaves, entre outros.

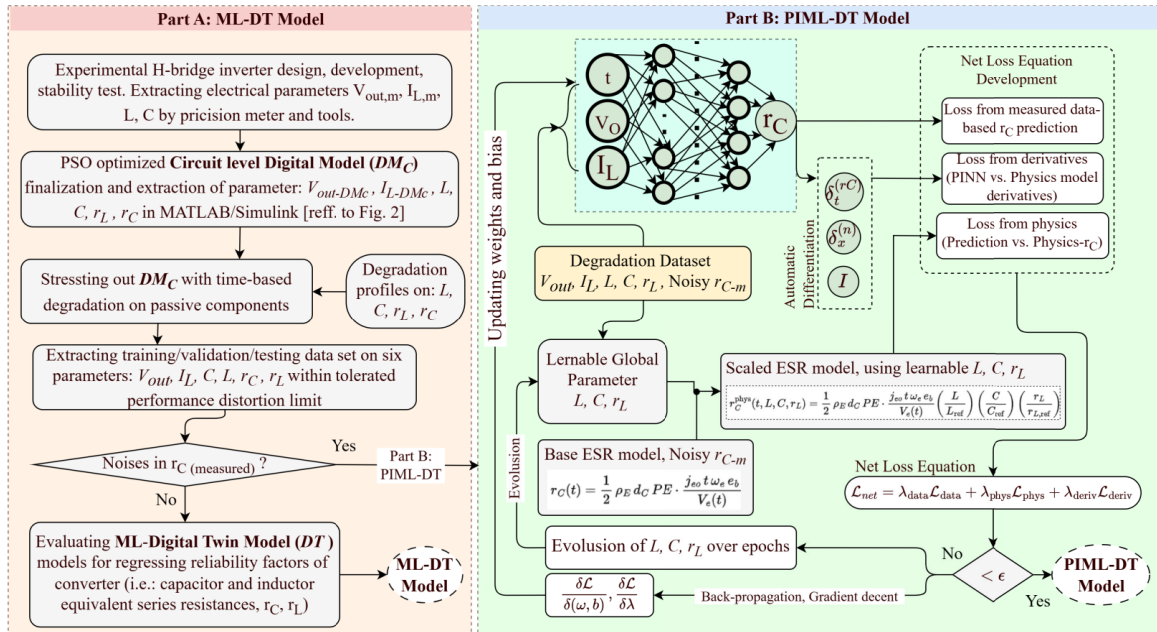


Figura 11 – Fluxograma do funcionamento de ambas as partes do gêmeo digital proposto por Roy e Sarwat (2025), a esquerda o modelo baseado em ML e a direita o modelo físico orientado por aprendizagem de máquina. Fonte: Roy e Sarwat (2025)

Na Tabela 2 é feito um compilado das características mais importantes dos três artigos que se utilizam de uma abordagem híbrida em sua modelagem, nela serão comparadas certas características chaves para sua aplicabilidade geral, funcionamento, complexidade e custo de aplicação

Cr�terios\Autores	Liu, Qing e Chen (2024)	Torchio et al. (2025)	Roy e Sarwat (2025)
Objetivo do artigo	Criar um m�todo simples e r�pido de identifica�o multiparam�trica com apenas um ciclo de chaveamento	Monitoramento t�rmico em tempo real	Estimativa de degrada�o de componentes com dados ruidosos
Topologia do sistema	Conversor Buck	Sistema t�rmico industrial	Inversor do tipo Ponte H
Abordagem na modelagem	H�brida (F�sica estruturalmente + PSO)	H�brida (F�sica + IA)	H�brida (F�sica + IA)
M�todo de identifica�o	PSO	ROM + FFNN	PSO + RF + PINN
Par�metros modelados	6	20 + par�metros FFNN	7 a 10 + par�metros PINN
Erro de identifica�o	Abaixo de 5% para resist�ncias parasitas Pr�ximo de 1% para os demais	Abaixo de 2,5�C	RMSE: 0,0053 para resist�ncia parasita do capacitor R ² : 0,6918
Aplicabilidade industrial	Baixa	Alta	Moderada, podendo variar pelo sistema embarcado
Depend�ncia de dados inicial	Muito alta	Muito alta	Muito alta
Depend�ncia de dados posterior	Alta	Baixa	Moderada
Controlador embutido	Sem controlador embutido	Sem controlador embutido	Sem controlador embutido
Principal lacuna	Poss�vel sensibilidade a ru�dos transit�rios pelo uso dos dados de apenas um ciclo de comuta�o	Falta de an�lises em falhas catastr�ficas, j� que se foca na degrada�o t�rmica gradual	Custo computacional alto pelo modelo PINN proposto, podendo n�o ser vi�vel em microcontroladores comuns

Tabela 2 – Comparativo entre os artigos com modelagem h brida. Fonte: O autor (2025).

O artigo de Hei, Mattavelli e Briz (2025) trazem um conjunto de dez artigos voltados para gêmeos digitais de alta confiabilidade em sistemas de eletrônica de potência, fazendo uma apresentação e contextualização de cada um. Eles explicam como os DT's se mostram eficazes e viáveis na melhoria e estabilidade em aplicações críticas como as de energias renováveis (como placas fotovoltaicas), sistemas industriais e veículos elétricos.

Já Bai *et al.* (2024) trazem consigo um amplo estudo sobre gêmeos digitais e seu conceito, trazendo as tecnologias que possibilitaram a melhoria e o uso dos DT's dentro da eletrônica de potência, exemplos práticos com abordagens de diferentes DT's, como um gêmeo digital probabilístico embarcado em FPGA de um conversor Buck e outro focado na análise térmica de um conversor Buck se utilizando de PSO na identificação de parâmetros. Os pesquisadores também abordam certas lacunas, como a garantia de uma alta fidelidade e, ao mesmo tempo, ter uma boa velocidade computacional para simulações em tempo real, já que altas fidelidades, para sistemas complexos, exigem um alto poder computacional (o que traz uma diminuição da velocidade caso não haja espaço para o sistema embarcado necessário), outra dificuldade apresentada é a captura dos acoplamentos eletrotérmicos em tempo real, entre outras lacunas. Contudo, o artigo traz uma certa animação com o futuro ao dizer que os gêmeos digitais poderão se tornar mais que apenas um assistente no sistema, mas sim consultores e, até mesmo, projetistas autônomos do sistema, colocando que com os avanços dos estudos sobre gêmeos digitais, IA e computação em nuvem haverá mais dados para a projeção híbrida ou totalmente baseada em dados dos DT's e ainda manter o alto desempenho, robustez e confiabilidade.

Por fim, Wu *et al.* (2025) trazem uma revisão bibliográfica de mais de 100 artigos sobre gêmeos digitais em aplicações na eletrônica de potência. Os autores trazem uma classificação em quatro categorias de gêmeos digitais, os de modelo mecanicista — baseados em leis físicas e equações de estado —, modelo de simulação — utilizam ferramentas como MATLAB/Simulink — modelo multifísicos — integram domínios acoplados como elétricos, térmicos e mecânicos — e o modelo baseado em dados — se utilizam de técnicas de IA e ML. Os autores também trazem o ciclo de vida completo dos sistemas, os fragmentando em três fases, o projeto — no qual os DT's auxiliam na otimização de topologias e verificação digital —, o controle — que foca em otimização adaptativa e previsão de variáveis —, e a manutenção — que abrange o monitoramento de condição, diagnóstico de falhas e previsão da vida

útil dos componentes. Com essas classificações, os autores trazem uma análise comparativa e detalhada que evidencia quais são as vantagens e desvantagens das diferentes abordagens de modelagem, trazendo seus custos computacionais, escalabilidade e cenários de aplicações mais adequados. Wu *et al.* (2025) trazem lacunas em seu artigo, como a dificuldade da integração e gestão de diferentes dados necessários para a criação de um DT completo; o aumento na complexidade dos sistemas de eletrônica de potência, o que aumenta o poder computacional necessário para a análise dos dados; a vulnerabilidade dos dados por conta da troca contínua de informações entre o modelo virtual e real (se a comunicação ocorrer via redes *wi-fi*); a necessidade de padronização e maturidade dos DT's ainda ser baixa; e o aumento na eficiência de implementações em tecnologias *edge-cloud*.

Com resultados positivos vindos dos sete artigos, é possível perceber que alguns desses trabalhos não se projetam pensando nos ruídos ou erros gerados pelos sensores utilizados, como os trabalhos de Song *et al.* (2025), Kumar e Kumar (2025), Liu, Yang e Liu (2025) e Liu, Qing e Chen (2024). Eles possuem um foco muito maior na análise dos dados e identificação deles. Liu, Yang e Liu (2025) ainda trazem testes mostrando que seu modelo suporta ruídos aplicados artificialmente, demonstrando a robustez do método deles, contudo o foco do artigo não é voltado para ambientes industriais com sensores pouco calibrados ou com alto ruído. No entanto, todos os quatro artigos se destacam em ambientes controlados, trazendo alta precisão e capacidade preditiva, além de um erro de similaridade menos que 5% em todos. Além disso, Kumar e Kumar (2025) e Liu, Yang e Liu (2025) trazem consigo um monitoramento em tempo real do sistema proposto, Kumar e Kumar (2025) trazem um sistema de controle e proteção do sistema ao invés de monitoramento, que é o caso de Liu, Yang e Liu (2025). Contudo, isso eleva ainda mais o poder computacional necessário, o que obriga os autores a usarem um FPGA para processar todo o DT com a sua modelagem complexa e totalmente física. Já os demais demonstram serem melhores para análises diagnósticas periódicas, para manutenções preditivas e/ou otimização dos recursos computacionais usados, no entanto, necessitam de um maior poder computacional para funcionar e alto tempo de processamento.

Agora trabalhos como os de Nazif *et al.* (2025), Torchio *et al.* (2025) e Roy e Sarwat (2025) já trazem uma maior preocupação em ambientes mais realistas ou não ideais, trazendo consigo uma modelagem já preocupada com os dispositivos mais utilizados em indústrias. Torchio *et al.* (2025) trazem algo até além do esperado ao

criarem um banco de dados utilizando diferentes marcas de IGBT's numa maneira de ter uma maior análise de possíveis erros ou ruídos nele presentes para, assim, haver um controle da temperatura do sistema o mais precisa possível, já que qualquer erro poderia causar uma perda significativa nos dispositivos presentes. Além deles serem o único dos três artigos “realistas” que busca uma análise em tempo real, o que torna ainda maior a necessidade de robustez em milésimos de segundo, para alcançarem isso e ainda trazerem um baixo custo computacional, os autores reduziram ao máximo as variáveis do sistema e se utilizaram de redes neurais já treinadas.

Com isso, a principal lacuna observável em todos os artigos analisados foi uma sensibilidade a parâmetros não modelados. Isso ocorre, pois os artigos assumem que sua modelagem abrangeu todos ou a maioria dos parâmetros de alta importância e acabam por não pensar numa estratégia de mitigação caso haja um parâmetro “parasita” em seu meio. Mas tal lacuna produz um maior efeito em ambientes industriais ou em ambientes mais realistas, o que traz um peso maior para os artigos de Nazif *et al.* (2025), Torchio *et al.* (2025) e Roy e Sarwat (2025).

4 SÍNTESE E TENDENCIAS FUTURAS

Os gêmeos digitais se mostram uma tecnologia muito interessante ao se portarem como uma ferramenta de predição e controle para sistemas críticos na eletrônica de potência. Eles se mostram capazes de fazer análises avançadas sobre os componentes do sistema, porém, a depender de sua complexidade, eles necessitam de alto poder computacional e tempo para fazerem a análise necessária do sistema. Entretanto, os trabalhos analisados demonstraram técnicas capazes de contornar o alto poder e tempo necessário com técnicas inovadoras para a modelagem e identificação dos parâmetros.

Além disso, ainda há lacunas presentes, como o alto poder computacional necessário para análise de sistemas complexos, como o caso do trabalho de Song *et al.* (2025). Eles também podem apresentar um alto tempo de processamento que apenas alguns trabalhos trouxeram esse tempo para que fosse analisado por outros. Há o problema de vulnerabilidade na comunicação dos sensores com os gêmeos que, caso feita via *wi-fi*, podem sofrer ataques de terceiros maliciosos para a deturpação dos dados ou tentativa de conectar na rede privada da indústria, roubando dados importantes e privados. Também há a vulnerabilidade em parâmetros não modelados pelos DT's, o que pode ocasionar em divergências nas leituras dos parâmetros modelados e causar instabilidade nos resultados ou na manutenção do sistema real.

Porém, artigos como os de Wu *et al.* (2025) e Bai *et al.* (2024) trazem consigo uma análise aprofundada sobre DT's e demonstram um forte avanço dessas tecnologias ao serem acompanhadas de suas tecnologias habilitadoras, como IoT, IA e computação em nuvem, que também vem apresentando um avanço constante em suas estruturas, trazendo colunas para preencher as lacunas dos gêmeos digitais ao ponto de eles poderem projetar autonomamente os sistemas que estão mimetizando, além de se autoevoluírem para compreender o que são parâmetros de componentes, correntes parasitas, ruídos e erros na calibração de sensores. Também diminuindo a latência de comunicação entre o sistema analisado e o DT para aumentar o tempo de resposta de controladores atualizados em tempo real. Contudo, mesmo com os avanços, Wu *et al.* (2025) ainda trazem o fato da tecnologia ainda necessitar de maturidade e uma melhor padronização, algo que virá com a constante exploração da inovadora tecnologia.

Por fim, gêmeos digitais são uma tecnologia que trará uma maior confiabilidade aos sistemas da eletrônica de potência, diminuindo perdas por degradação dos componentes a longo prazo, controle voltado para a temperatura ideal dos componentes, melhoria para sistemas domésticos, como de células fotovoltaicas, além de prever quando será a próxima manutenção de peças específicas do sistema sem a necessidade de procedimentos invasivos ou manutenções desnecessárias.

5 CONCLUSÃO

A partir de uma revisão bibliográfica de artigos presentes na biblioteca de arquivos IEEE *Xplore Digital Library* nos anos de 2024 e 2025 sobre gêmeos digitais em sistemas da eletrônica de potência, este trabalho pôde apresentar o grande potencial tecnológico dos gêmeos digitais. Isso se deve pela capacidade de predição, análise, controle e otimização das mais simples topologias até as mais complexas. Além de trazer consigo uma versatilidade de configurações dentro de sua modelagem, método de identificação de parâmetros e objetivo final desejado.

Com a constante necessidade de sistemas mais seguros e confiáveis, o uso dos gêmeos digitais se mostrou uma alternativa mais que interessante, principalmente para analisar sistemas críticos em tempo real e ser seu controlador adaptativo, permitindo prever quando será necessária a próxima manutenção e em qual ou quais componentes ela será necessária, separar quais são e o quanto os parâmetros parasitas influenciam no sistema, e possibilitar uma análise precisa para o desenvolvimento de um controlador ou ter um controlador embutido que atualize seus parâmetros automaticamente.

A partir de classificações propostas por Wu *et al.* (2025) e conceitos amplificados por Bai *et al.* (2024), esta revisão também contribuiu ao classificar os artigos a partir de suas abordagens na modelagem da topologia do sistema real ou de suas metodologias de identificação de parâmetros, sendo as classificações por modelagem a física, por dados e híbrida. Já para a metodologia de identificação de parâmetros, observou-se as classificações por métodos metaheurísticos; métodos baseados em filtros e estimação; métodos baseados em aprendizado de máquina; e métodos probabilísticos. Tais classificações auxiliam na formulação de qual será a melhor configuração e estratégia abordada para o sistema real analisado e o objetivo final que o gêmeo digital deverá realizar.

Além disso, a partir das análises dos artigos, foi possível perceber fortes tendências dos DT a depender dos seus objetivos e topologias analisadas. Contudo, a maioria busca a identificação robusta de sistemas críticos para algo, sendo este algo variado entre predições na saúde dos componentes para compreensão do ciclo de vida deles ou manutenções planejadas com exatidão, controle preciso do sistema e seus componentes, um conjunto de ambos ou uma configuração que torne todo este processo mais rápido, mantendo a robustez e confiabilidade ou a aumentando.

Também foram encontradas lacunas perceptíveis em métodos usados e nos trabalhos analisados, como a falta de testes de ruídos para alguns, problemas de generalização, alto poder computacional necessário, entre outras questões. Contudo, os gêmeos digitais ainda se mostraram uma potência em ascensão constante, principalmente dentro da eletrônica de potência, já que eles permitem a análise em tempo real dos sistemas que mimetizam, possibilitando auxiliar em processos críticos (como o caso de sistemas fotovoltaicos). Além disso, também possibilitam testes sem afetar o sistema real, mas sabendo quais efeitos causarão neles a partir da reação de seu gêmeo digital.

Para possíveis melhorias em trabalhos futuros se mostra interessante o aumento do escopo dos artigos selecionados, buscando artigos de gêmeos digitais que tragam uma modelagem totalmente baseada em dados, além de aumentar as bibliotecas digitais utilizadas, trazendo pesquisas presentes não só o *IEEE Xplore Digital Library*, como também o Portal de Periódicos da CAPES ou a revista Elsevier.

Também, para uma melhor análise, fazer testes empíricos de DT's para comparar resultados com os encontrados nos trabalhos analisados, ou analisar melhores configurações de gêmeos digitais de diferentes topologias. Isso também permitiria analisar de maneira mais aprofundada quais são as vantagens e desvantagens de cada método de identificação ou de modelagem, enriquecendo os dados do trabalho.

REFERÊNCIAS

- ABUALIGAH, Laith; DIABAT, Ali; MIRJALILI, Seyedali; ELAZIZ, Mohamed Abd; GANDOMI, Amir H.. The Arithmetic Optimization Algorithm. **Computer Methods In Applied Mechanics And Engineering**, [S.L.], v. 376, p. 1-38, 2021. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0045782520307945>. Acesso em: 7 dez. 2025.
- BAI, Hao; KUPRAT, Johannes; OSÓRIO, Caio; LIU, Chen; LISERRE, Marco; GAO, Fei. Digital Twins for Modern Power Electronics: an investigation into the enabling technologies and applications. **IEEE Electrification Magazine**, [S.L.], v. 12, n. 3, p. 50-67, 2024. Disponível em: <https://ieeexplore.ieee.org/document/10666932>. Acesso em: 10 nov. 2025.
- BADARINATH, Poojitha Vurtur; CHIERICHETTI, Maria; KAKHKI, Fatemeh Davoudi. A Machine Learning Approach as a Surrogate for a Finite Element Analysis: status of research and application to one dimensional systems. **Sensors**, [S.L.], v. 21, n. 5, p. 1-18, fev. 2021. Disponível em: <https://www.mdpi.com/1424-8220/21/5/1654>. Acesso em: 7 dez. 2025.
- BUSARELLO, Tiago Davi. Digital Twins in Power Electronics: A LinkedIn Post Describing Lab Setup and Research. Publicação no LinkedIn sobre o uso de Digital Twins em eletrônica de potência. 2024. Disponível em: <https://www.linkedin.com/feed/update/urn:li:activity:7239639220309372929/>. Acesso em: 01 dez. 2025.
- CHEN, Shaowei; WANG, Shengyue; WEN, Pengfei; ZHAO, Shuai. Digital Twin for Degradation Parameters Identification of DC-DC Converters Based on Bayesian Optimization. **2021 IEEE - International Conference On Prognostics And Health Management (Icphm)**, [S.L.], p. 1-9, 2021. Disponível em: <https://ieeexplore.ieee.org/document/9486446>. Acesso em: 7 dez. 2025.
- DI NEZIO, Giulia; DIZ, Sergio de López; BENEDETTO, Marco di; LIDOZZI, Alessandro; PEÑA, Emilio José Bueno; SOLERO, Luca. Parameters Estimation of a 3-Phase AC-DC Converter based on the Digital Twin Method. **2023 IEEE Energy Conversion Congress And Exposition (Ecce)**, [S.L.], p. 2937-2944, 2023. Disponível em: <https://ieeexplore.ieee.org/document/10362069>. Acesso em: 10 nov. 2025.
- FERRARIO, E.; PEDRONI, N.; ZIO, E.; LOPEZ-CABALLERO, F.. Bootstrapped Artificial Neural Networks for the seismic analysis of structural systems. **Structural Safety**, [S.L.], v. 67, p. 70-84, 2017. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0167473017300796?via%3Dihub>. Acesso em: 7 dez. 2025.
- FREITAS, Diogo; LOPES, Luiz Guerreiro; MORGADO-DIAS, Fernando. Particle Swarm Optimisation: a historical review up to the current developments. **Entropy**, [S.L.], v. 22, n. 3, p. 362, 2020. Disponível em: <https://www.mdpi.com/1099-4300/22/3/362>. Acesso em: 7 dez. 2025.

GROSHEV, Milan; GUIMARÃES, Carlos; MARTÍN-PÉREZ, Jorge; LAOLIVA, Antonio de. Toward Intelligent Cyber-Physical Systems: digital twin meets artificial intelligence. **IEEE Communications Magazine**, [S.L.], v. 59, n. 8, p. 14-20, 2021. Disponível em: <https://ieeexplore.ieee.org/document/9530501>. Acesso em: 10 nov. 2025.

HAYKIN, Simon. **Neural Networks: A Comprehensive Foundation**. 2. ed. Upper Saddle River: Prentice Hall, 1999.

HERTZ, John A.; KROGH, Anders S.; PALMER, Richard G. **Introduction to the Theory of Neural Computation**. Boca Raton: CRC Press, London, 2018.

HE, Jiangbiao; MATTAVELLI, Paolo; BRIZ, Fernando. Guest Editorial Special Issue on Digital Twin Driven High-Reliability Power Electronic Systems. **IEEE Journal Of Emerging And Selected Topics In Power Electronics**, [S.L.], v. 13, n. 3, p. 2709-2711, 2025. Disponível em: <https://ieeexplore.ieee.org/document/11062365>. Acesso em: 10 nov. 2025.

HOLLAND, J. H. **Adaptation in Natural and Artificial Systems**. Ann Arbor: University of Michigan Press, 1975. Reimpressão: MIT Press, 1992.

HORNIK, Kurt. Approximation capabilities of multilayer feedforward networks. **Neural Networks**, [S.L.], v. 4, n. 2, p. 251-257, 1991. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/089360809190009T>. Acesso em: 7 dez. 2025.

JAYASINGHE, S.C.; MAHMOODIAN, M.; SIDIQ, A.; NANAYAKKARA, T.M.; ALAVI, A.; MAZAHARI, Sam; SHAHRIVAR, F.; SUN, Z.; SETUNGE, S.. Innovative digital twin with artificial neural networks for real-time monitoring of structural response: a port structure case study. **Ocean Engineering**, [S.L.], v. 312, p. 1-15, 2024. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0029801824025253?via%3Dihub>. Acesso em: 7 dez. 2025.

KAMAL, Naheel Faisal; SHARIDA, Ali; BAYHAN, Sertac; ALNUWEIRI, Hussein; ABU-RUB, Haitham. Low-cost Digital Twin Design for Power Electronics using Deep Neural Networks. **2024 4Th International Conference On Smart Grid And Renewable Energy (Sgre)**, [S.L.], p. 1-6, j2024. Disponível em: <https://ieeexplore.ieee.org/document/10428716>. Acesso em: 7 dez. 2025.

KENNEDY, J.; EBERHART, R.. Particle swarm optimization. **Proceedings Of Icn'95 - International Conference On Neural Networks**, [S.L.], v. 4, p. 1942-1948, 1995. Disponível em: <https://ieeexplore.ieee.org/document/488968>. Acesso em: 7 dez. 2025.

KENNEDY, J.; EBERHART, R.C.. A discrete binary version of the particle swarm algorithm. **1997 IEEE International Conference On Systems, Man, And Cybernetics. Computational Cybernetics And Simulation**, [S.L.], v. 5, p. 4104-

4108, 1997. Disponível em: <https://ieeexplore.ieee.org/document/637339>. Acesso em: 7 dez. 2025.

KUMAR, Arun; KUMAR, Nishant. State-Space Driven Digital Twin for Condition Monitoring and Predictive Health Assessment in Grid-Integrated Power Converter System. **IEEE Transactions On Industrial Cyber-Physical Systems**, [S.L.], v. 3, p. 464-471, 2025. Disponível em: <https://ieeexplore.ieee.org/abstract/document/11072486>. Acesso em: 10 nov. 2025.

KURKOVÁ, Věra. Kolmogorov's theorem and multilayer neural networks. **Neural Networks**, [S.L.], v. 5, n. 3, p. 501-506, 1992. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/0893608092900128>. Acesso em: 7 dez. 2025.

LEI, Zhongcheng; ZHOU, Hong; DAI, Xiaoran; HU, Wenshan; LIU, Guo-Ping. Digital twin based monitoring and control for DC-DC converters. **Nature Communications**, [S.L.], v. 14, n. 1, p. 1-11, 2023. Disponível em: <https://www.nature.com/articles/s41467-023-41248-z#citeas>. Acesso em: 10 nov. 2025.

LIU, Yisi; QING, Xinlin; CHEN, Guipeng. One-Cycle Digital Twin-Based Multiparameter Identification of Power Electronic Converters With Simple Implementation and High Accuracy. **IEEE Transactions On Instrumentation And Measurement**, [S.L.], v. 73, p. 1-11, 2024. Disponível em: <https://ieeexplore.ieee.org/document/10712655>. Acesso em: 10 nov. 2025.

LIU, Yi-Hua; YANG, Zong-Zhen; LIU, Min-Chen. Digital Twin-Based Online Health Monitoring of Power Electronics Systems With Self-Evolving Compensators and Improved Parameter Identification Capability. **IEEE Journal Of Emerging And Selected Topics In Power Electronics**, [S.L.], v. 13, n. 3, p. 2725-2737, 2025. Disponível em: <https://ieeexplore.ieee.org/document/10750018>. Acesso em: 10 nov. 2025.

LU, Yunlong; HUANG, Xiaohong; ZHANG, Ke; MAHARJAN, Sabita; ZHANG, Yan. Low-Latency Federated Learning and Blockchain for Edge Association in Digital Twin Empowered 6G Networks. **IEEE Transactions On Industrial Informatics**, [S.L.], v. 17, n. 7, p. 5098-5107, 2021. Disponível em: <https://ieeexplore.ieee.org/document/9170905>. Acesso em: 10 nov. 2025.

LU, Yizhou; ZHANG, Mengfan; NORDSTRÖM, Lars; XU, Qianwen. An Online Digital Twin based Health Monitoring Method for Boost Converter using Neural Network. **2023 IEEE Energy Conversion Congress And Exposition (Ecce)**, [S.L.], p. 3701-3706, 2023. Disponível em: <https://ieeexplore.ieee.org/document/10362778>. Acesso em: 7 dez. 2025.

MIHAI, Stefan; YAQOOB, Mahnoor; HUNG, Dang V.; DAVIS, William; TOWAKEL, Praveer; RAZA, Mohsin; KARAMANOGLU, Mehmet; BARN, Balbir; SHETVE, Dattaprasad; PRASAD, Raja V. Digital Twins: a survey on enabling technologies, challenges, trends and future prospects. **IEEE Communications Surveys &**

Tutorials, [S.L.], v. 24, n. 4, p. 2255-2291, 2022. Disponível em: <https://ieeexplore.ieee.org/document/9899718>. Acesso em: 10 nov. 2025.

MILTON, Matthew; LAO, Castulo de; GINN, Herbert L.; BENIGNI, Andrea. Controller-Embeddable Probabilistic Real-Time Digital Twins for Power Electronic Converter Diagnostics. **IEEE Transactions On Power Electronics**, [S.L.], v. 35, n. 9, p. 9850-9864, 2020. Disponível em: <https://ieeexplore.ieee.org/document/8984243>. Acesso em: 7 dez. 2025.

MINERVA, Roberto; LEE, Gyu Myoung; CRESPI, Noel. Digital Twin in the IoT Context: a survey on technical features, scenarios, and architectural models. **Proceedings Of The IEEE**, [S.L.], v. 108, n. 10, p. 1785-1824, 2020. Disponível em: <https://ieeexplore.ieee.org/document/9120192>. Acesso em: 10 nov. 2025.

MULINKA, Pavol; SAHOO, Subham; KALALAS, Charalampos; NARDELLI, Pedro H. J.. Optimizing a Digital Twin for Fault Diagnosis in Grid Connected Inverters - A Bayesian Approach. **2022 IEEE Energy Conversion Congress And Exposition (Ecce)**, [S.L.], p. 1-6, 2022. Disponível em: <https://ieeexplore.ieee.org/document/9947986>. Acesso em: 10 nov. 2025.

NAZIF, Parsa Behzad; SAEED, Mariam; AHMAD, Saad; GUERRERO, Juan Manuel; MENDEZ, Aitor Rodríguez; ARAICO, Guillermo Carlos Ozaita; LARRAZABAL, Igor; BRIZ, Fernando. Parameter Identification for DC-DC Buck Converter Digital Twin Considering Sensor Errors. **IEEE Journal Of Emerging And Selected Topics In Power Electronics**, [S.L.], v. 13, n. 4, p. 5111-5123, 2025. Disponível em: <https://ieeexplore.ieee.org/document/10967518>. Acesso em: 10 nov. 2025.

OZCAN, E.; MOHAN, C. K. Particle swarm optimization: surfing the waves. In: *Proceedings of the IEEE Congress on Evolutionary Computation (CEC)*, Washington, WA, USA, 6–9, 1999. p. 1939–1944. Disponível em: <https://ieeexplore.ieee.org/document/785510>. Acesso em: 7 dez. 2025.

PELIKAN, Martin; GOLDBERG, David E.; TSUTSUI, Shigeyoshi. **Hierarchical Bayesian optimization algorithm: toward a new generation of evolutionary algorithms**. In: **SICE ANNUAL CONFERENCE**, 4–6 ago. 2003, Fukui, Japão. *Anais...* Fukui: SICE, 2003. p. 547–552. Disponível em: <https://ieeexplore-ieee.org.ez46.periodicos.capes.gov.br/document/1323811> Acesso em: 7 dez. 2025.

QI, Qinglin; TAO, Fei. Digital Twin and Big Data Towards Smart Manufacturing and Industry 4.0: 360 degree comparison. **IEEE Access**, [S.L.], v. 6, p. 3585-3593, 2018. Disponível em: <https://ieeexplore.ieee.org/document/8258937>. Acesso em: 10 nov. 2025.

ROY, Sukanta; SARWAT, Arif. A Noise Immune Physics Informed Data-Driven Digital Twin for Inverter Component Degradation Estimation. **IEEE Access**, [S.L.], v. 13, p. 167165-167177, 2025. Disponível em: <https://ieeexplore.ieee.org/abstract/document/11175140>. Acesso em: 10 nov. 2025.

SHI, Hang; XIAO, Lan; WU, Qunfang; WANG, Wanquan. Digital Twin Approach for IGBT Parameters Identification of a Three-Phase DC-AC Inverter. **2022 IEEE**

Transportation Electrification Conference And Expo, Asia-Pacific (Itec Asia-Pacific), [S.L.], p. 1-4, 2022. Disponível em: <https://ieeexplore.ieee.org/document/9942105>. Acesso em: 10 nov. 2025.

SONG, Wensheng; ZHANG, Zhiwei; ZHANG, Sihui; MA, Chenwei; LI, Jiayao. Digital Twin Modeling and Multiparameter Monitoring Schemes of Three-Level ANPC Inverters. **IEEE Transactions On Power Electronics**, [S.L.], v. 39, n. 12, p. 16596-16608, 2024. Disponível em: <https://ieeexplore.ieee.org/document/10607946>. Acesso em: 10 nov. 2025.

SU, Qianli; STRUNZ, Kai. Stochastic Polynomial-Chaos-Based Average Modeling of Power Electronic Systems. **IEEE Transactions On Power Electronics**, [S.L.], v. 26, n. 4, p. 1167-1171, 2011. Disponível em: <https://ieeexplore-ieee-org.ez22.periodicos.capes.gov.br/document/5567167>. Acesso em: 7 dez. 2025.

TAO, Fei; ZHANG, He; LIU, Ang; NEE, A. Y. C. Digital Twin in Industry: state-of-the-art. **IEEE Transactions On Industrial Informatics**, [S.L.], v. 15, n. 4, p. 2405-2415, 2019. Disponível em: <https://ieeexplore.ieee.org/document/8477101>. Acesso em: 10 nov. 2025.

THELEN, Adam; ZHANG, Xiaoge; FINK, Olga; LU, Yan; GHOSH, Sayan; YOUN, Byeng D.; TODD, Michael D.; MAHADEVAN, Sankaran; HU, Chao; HU, Zhen. Correction: a comprehensive review of digital twin: part 2. **Structural And Multidisciplinary Optimization**, [S.L.], v. 66, n. 1, 2023. Disponível em: <https://link.springer.com/article/10.1007/s00158-022-03410-x>. Acesso em: 7 dez. 2025.

TORCHIO, R.; CONTE, F.; SCARPA, M.; FILIPPINI, M.; PASE, F.; TOSO, F.; NASAB, P. Shahriari; MARSON, E.; VIROLI, A.; POSA, P. Digital Twins in Power Electronics: a comprehensive approach to enhance virtual thermal sensing. **IEEE Transactions On Power Electronics**, [S.L.], v. 40, n. 5, p. 6977-6987, 2025. Disponível em: <https://ieeexplore.ieee.org/document/10845810>. Acesso em: 10 nov. 2025.

XIU, Dongbin. **Numerical Methods for Stochastic Computations: A Spectral Method Approach**. Princeton, NJ: Princeton University Press, 2010. 144 p.

XIU, Dongbin; KARNIADAKIS, George em. The Wiener--Askey Polynomial Chaos for Stochastic Differential Equations. **Siam Journal On Scientific Computing**, [S.L.], v. 24, n. 2, p. 619-644, 2002. Disponível em: <https://epubs.siam.org/doi/abs/10.1137/S1064827501387826>. Acesso em: 7 dez. 2025.

WANG, S.-C. Artificial Neural Network. In: WANG, S.-C. **Interdisciplinary Computing in Java Programming**. Boston: Kluwer Academic Publishers, 2003. p. 81–102. Disponível em: https://link.springer.com/chapter/10.1007/978-1-4615-0377-4_5. Acesso em: 7 dez. 2025.

WIENER, Norbert. The Homogeneous Chaos. **American Journal Of Mathematics**, [S.L.], v. 60, n. 4, p. 897, 1938. Disponível em: <https://www.jstor.org/stable/2371268>. Acesso em: 7 dez. 2025.

WU, Chenhao; CUI, Zhexin; XIA, Qian; YUE, Jiguang; LYU, Feng. An Overview of Digital Twin Technology for Power Electronics: state-of-the-art and future trends. **IEEE Transactions On Power Electronics**, [S.L.], v. 40, n. 9, p. 13337-13362, 2025. Disponível em: <https://ieeexplore.ieee.org/document/11005593>. Acesso em: 10 nov. 2025.