



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

Jaime Osmar Rodrigues Filho

**O Uso de Gêmeos Digitais com Machine Learning no Ciclo do Hidrogênio
Verde: Uma Revisão da literatura**

Blumenau
2024

Jaime Osmar Rodrigues Filho

O Uso de Gêmeos Digitais com Machine Learning no Ciclo do Hidrogênio Verde: Uma Revisão da literatura

Trabalho de Conclusão de Curso de Graduação em Engenharia de Controle e Automação do Centro Tecnológico, de Ciências Exatas e Educação da Universidade Federal de Santa Catarina como requisito para a obtenção do título de Engenheiro de Controle e Automação.
Orientador: Prof. Dr. Tiago Davi Curi Busarello.

Ficha catalográfica gerada por meio de sistema automatizado gerenciado pela BU/UFSC.
Dados inseridos pelo próprio autor.

Rodrigues Filho, Jaime Osmar

O uso de gêmeos digitais com machine learning no ciclo do hidrogênio verde : uma revisão da literatura / Jaime Osmar Rodrigues Filho ; orientador, Tiago Davi Curi Busarello, 2024.

68 p.

Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Santa Catarina, Campus Blumenau, Graduação em Engenharia de Controle e Automação, Blumenau, 2024.

Inclui referências.

1. Engenharia de Controle e Automação. 2. Gêmeo digital. 3. Machine learning. 4. Hidrogênio verde. I. Busarello, Tiago Davi Curi . II. Universidade Federal de Santa Catarina. Graduação em Engenharia de Controle e Automação. III. Título.

Jaime Osmar Rodrigues Filho

O Uso de Gêmeos Digitais com Machine Learning no Ciclo do Hidrogênio

Verde: Uma Revisão da 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, 12 de Dezembro de 2024.

Banca Examinadora:

Prof. Dr. Tiago Davi Curi Busarello
Universidade Federal de Santa Catarina
Orientador

Prof. Dr. Adão Boava
Universidade Federal de Santa Catarina

Prof. Dr. Mauri Ferrandin
Universidade Federal de Santa Catarina

Dedico este trabalho, com todo o carinho e gratidão, aos meus pais, por seu apoio incondicional. Agradeço profundamente aos meus professores da UFSC Blumenau e aos meus colegas de estudos, por toda a amizade, colaboração e motivação compartilhadas ao longo dessa jornada. Cada um de vocês fez parte deste caminho de aprendizado e superação, e sou eternamente grato.

AGRADECIMENTOS

Aos meus pais, com o mais profundo amor e gratidão, deixo aqui minha homenagem especial. Foram eles que estiveram ao meu lado em cada passo, nos momentos mais felizes e nos mais difíceis. Quando a pandemia trouxe incertezas e, posteriormente, quando enfrentei o diagnóstico de um tumor no pâncreas, foram eles que me sustentaram, não só financeiramente, mas emocionalmente, oferecendo um apoio constante e inabalável que me inspirou a seguir em frente. Seu apoio incondicional e suas palavras de incentivo, mesmo nos dias em que pensei em desistir, renovaram minha esperança e me impulsionaram a chegar até aqui. Nada do que eu faça será suficiente para retribuir o amor, a dedicação e a coragem que vocês me transmitiram. Este trabalho e cada conquista nele representada são fruto da força de vocês.

Meu sincero agradecimento ao Érique, meu colega e amigo, com quem compartilhei a convivência nos primeiros anos da universidade e que foi um grande apoio no início desta trajetória. Estendo meus agradecimentos aos colegas do Centro Acadêmico Novo de Engenharia de Controle e Automação, aos amigos da empresa JR. Integre Júnior, que me ajudaram a aprender sobre administração e a vida empresarial, e aos colegas de curso Bruna, Dartagnan, Joana, Daniele, Anderson, entre outros, com quem compartilhei momentos de aprendizado e amizade que levarei para a vida toda.

Agradeço também à empresa Infra Automação Industrial, pela oportunidade de realizar meu estágio obrigatório, onde pude obter uma experiência valiosa na área, contribuindo de maneira significativa para minha formação prática.

Agradeço especialmente ao professor Tiago, que aceitou o desafio de me orientar à distância e em apenas um semestre, demonstrando grande comprometimento com minha formação. Estendo também minha profunda gratidão a todos os professores da UFSC Blumenau, que, com dedicação e excelência, contribuíram de forma significativa para minha trajetória acadêmica. Seu esforço incansável, tanto durante o período de pandemia quanto nas aulas presenciais, foi essencial para o meu aprendizado e desenvolvimento, tornando possível que eu chegasse a esta etapa.

Por fim, agradeço a Deus, por ter me concedido a vida e a oportunidade de superar tantos desafios. Mesmo diante das adversidades da pandemia e após uma cirurgia complexa, em que o tumor foi removido, Sua presença e amparo me deram forças para seguir e completar esta etapa sem maiores complicações de saúde.

“A inovação é a chave para enfrentar as mudanças climáticas e construir um futuro sustentável. Precisamos de tecnologias que reduzam as emissões e nos ajudem a adaptar à nova realidade climática.” (GATES, 2021)

RESUMO

Ao considerarmos que uma parte significativa de todo o hidrogênio produzido no mundo advém de matérias-primas não renováveis, tais como gás natural, carvão e óleo pesado, percebe-se uma demanda mundial pelo hidrogênio “verde” (H₂V), que pode ser obtido a partir de fontes renováveis, como energia solar, eólica e biomassa, opções mais adequadas ao meio ambiente. No Brasil e no mundo, a literatura apresenta estudos que evidenciam a utilização de fontes alternativas renováveis para a produção de H₂V. Este trabalho de conclusão de curso tem como objetivo demonstrar a aplicação da tecnologia de gêmeo digital e de Machine Learning na otimização da produção, armazenamento e conversão de hidrogênio verde em energia elétrica. Metodologicamente, trata-se de um estudo qualitativo, realizado por meio de revisão de literatura. O estudo evidencia que o uso da tecnologia de gêmeo digital e do Machine Learning para a otimização da produção, armazenamento e conversão de hidrogênio verde em energia permite aumentar a produção de H₂V no Brasil, com o objetivo de torná-lo mais disseminado e competitivo, popularizando seu uso para atender às demandas das indústrias e abrir novos mercados.

Palavras-chave: Gêmeo Digital; Machine Learning; Produção, Armazenamento; Conversão; Hidrogênio Verde.

ABSTRACT

Considering that a significant portion of all hydrogen produced worldwide comes from non-renewable raw materials, such as natural gas, coal, and heavy oil, there is a global demand for “green” hydrogen (H₂V), which can be obtained from renewable sources like solar, wind, and biomass energy, options that are more environmentally friendly. In Brazil and worldwide, the literature presents studies that highlight the use of renewable alternative sources for H₂V production. This study aims to demonstrate the application of digital twins and Machine Learning in optimizing the production, storage, and conversion of green hydrogen into energy. Methodologically, it is a qualitative study conducted through a literature review. The study shows that using digital twins and Machine Learning to optimize the production, storage, and conversion of green hydrogen into energy allows for an increased production of H₂V in Brazil, aiming to make it more widespread and competitive, thereby popularizing its use to meet industrial demands and open new markets.

Keywords: Twin Digital; Machine Learning; Production; Storage; Conversion; Green Hydrogen.

LISTA DE FIGURAS

Figura 1 – Paleta de cores do hidrogênio e seus métodos de produção. Fonte: InvestNews (2024b).	20
Figura 2 – Esquema de uma célula de combustível utilizando hidrogênio. Fonte: InfoEscola (2024).	24
Figura 3 – Projetos de hidrogênio verde no Brasil. Fonte: InvestNews (2024b). . .	26
Figura 4 – Processo de produção, armazenamento e uso do hidrogênio verde. Fonte: InvestNews (2024b).	28
Figura 5 – Processo de geração de hidrogênio verde por eletrólise utilizando fontes renováveis. Fonte: (RIBEIRO, 2022).	29
Figura 6 – Infográfico ilustrativo das principais aplicações do hidrogênio verde produzido a partir de fontes renováveis. Fonte: (IBERDROLA, 2024) .	34
Figura 7 – Rede Neural Artificial com uma camada oculta. Fonte: (NASCIMENTO, 2022)	37
Figura 8 – Fases para o desenvolvimento de algoritmos de <i>machine learning</i> . Adaptado de (RAJKOMAR; DEAN; KOHANE, 2019)	38
Figura 9 – Estrutura geral do uso da tecnologia Gêmeo Digital. Fonte: Santos (2023). 40	
Figura 10 – Exemplo de combinação entre sistema físico (à direita) e modelo virtual simulado (à esquerda), incluindo um inversor conectado à rede e controlado por um microcontrolador F28335. Fonte: (BUSARELLO, 2024).	41
Figura 11 – Arquitetura geral do Gêmeo Digital: interação entre sistemas físicos, dados e modelos virtuais. Fonte: adaptado de (SANTOS, 2023).	42
Figura 12 – Modelo de Gêmeo Digital de 8 Dimensões. Fonte: Nascimento (2022). .	43
Figura 13 – Arquitetura de referência de Gêmeo Digital proposta por Rabelo et al. Fonte: Rabelo, Magalhães e Cabral (2023).	44
Figura 14 – Arquitetura de Gêmeo Digital com camadas funcionais. Fonte: Nascimento (2022).	45
Figura 15 – Arquitetura de mapeamento bidirecional entre domínios físico e virtual. Fonte: Zheng, Yang e Cheng (2019).	46
Figura 16 – Fluxo de uma abordagem baseada em aprendizado de máquina para tomada de decisão, destacando a integração entre modelo de aprendizado, base de conhecimento e decisão final. Fonte: Santos (2023)	48

LISTA DE TABELAS

Tabela 1 – Tabela comparativa de tipos de células a combustível. Fonte: Wendt, Götz e Linardi (2000)	23
Tabela 2 – Comparação de tecnologias de eletrólise Fonte: Adaptado de S. Shiva Kumar e Lim (2022) e Tenhumberg e Bükler (2023)	30
Tabela 3 – Vantagens e Desvantagens das Tecnologias de Eletrólise Fonte: Adaptado de S. Shiva Kumar e Lim (2022)	31
Tabela 4 – Comparação entre aprendizado supervisionado, não supervisionado e por reforço. As colunas de aprendizado supervisionado e não supervisionado foram adaptadas de (PAIXÃO <i>et al.</i> , 2022), enquanto a coluna de aprendizado por reforço foi elaborada com base em (SUTTON; BARTO, 2018; RAJKOMAR; DEAN; KOHANE, 2019).	36
Tabela 5 – Simulação tradicional vs. Gêmeo Digital. Fonte: Santos (2023).	47

LISTA DE ABREVIATURAS E SIGLAS

CO_2	Dióxido de carbono
H_2	gás hidrogênio
H_2O	Molécula água
O_2	oxigênio
AIE	Agência Internacional de Energia
AUC	área sob a curva
CO	Monóxido de Carbono
EUA	Estados Unidos da América
FID	Decisão Final de Investimento
GEE	gases de efeito estufa
GNL	Gás natural liquefeito
H2V	Hidrogênio “Verde”
IA	artificial intelligence
IoT	Internet of Things
PLM	Product Lifecycle Management
RNA	rede neural artificial
RTS	real-time simulation
SVM	Máquina de Vetores de Suporte

SUMÁRIO

1	INTRODUÇÃO	14
1.1	ORGANIZAÇÃO DO TEXTO	16
1.1.1	Objetivo Geral	16
1.1.2	Objetivos Específicos	16
2	PERCURSO METODOLÓGICO	18
3	REVISÃO DA LITERATURA	20
3.1	A RELEVÂNCIA DO HIDROGÊNIO VERDE	20
3.1.1	Demandas Atuais	21
3.1.2	O Cenário Atual do Hidrogênio Verde	24
3.1.3	Produção de Hidrogênio Verde	27
3.1.4	O Papel do Hidrogênio no Contexto de Energia Sustentável .	32
3.1.4.1	<i>Aplicações do Hidrogênio</i>	<i>32</i>
3.1.4.2	<i>Produção de Amônia e Metanol a partir do Hidrogênio Verde</i>	<i>33</i>
3.2	IMPORTÂNCIA DO APRENDIZADO DE MÁQUINA E SUAS ABOR- DAGENS	34
3.3	EFEITOS DA UTILIZAÇÃO DE GÊMEOS DIGITAIS E BENEFÍ- CIOS DO APRENDIZADO DE MÁQUINA NO APERFEIÇOAMENTO DE SISTEMAS	40
3.3.1	Vantagens dos Gêmeos Digitais	40
3.3.2	Desafios dos Gêmeos Digitais	41
3.3.3	Arquiteturas de Gêmeos Digitais	42
3.3.4	Aplicações dos Gêmeos Digitais	46
3.3.5	Papel do Aprendizado de Máquina no Aperfeiçoamento de Gêmeos Digitais	47
3.4	A UTILIZAÇÃO DO GÊMEO DIGITAL COM APRENDIZADO DE MÁQUINA PARA A OTIMIZAÇÃO DA PRODUÇÃO, ARMAZENA- MENTO E CONVERSÃO DE HIDROGÊNIO VERDE EM ENERGIA	49
3.4.1	Gêmeo Digital	49
3.4.1.1	<i>Componentes do Gêmeo Digital</i>	<i>49</i>
3.4.2	Integração com <i>Machine Learning</i>	49
3.4.2.1	<i>Otimização da Produção</i>	<i>49</i>
3.4.2.2	<i>Armazenamento Eficiente</i>	<i>49</i>
3.4.2.3	<i>Conversão em Energia</i>	<i>50</i>
3.4.3	Sensores e Controladores	50
3.4.3.1	<i>Sensores</i>	<i>50</i>
3.4.3.1.1	Na Eletrólise	50
3.4.3.1.2	No Armazenamento	50

3.4.3.1.3	Na Conversão em Energia	51
3.4.4	Controladores	51
3.4.5	Considerações de Segurança	51
3.4.6	Possíveis controladores e Sensores para Protótipo	51
3.4.7	Possíveis Controladores e Sensores para Projeto Final	52
3.5	OS BENEFÍCIOS DA UNIÃO DOS GÊMEOS DIGITAIS COM MAR- CHINE LEARNING PARA A FABRICAÇÃO DO HIDROGÊNIO VERDE	53
4	SÍNTESE E TENDÊNCIAS	56
5	CONCLUSÃO	58
	REFERÊNCIAS	60

1 INTRODUÇÃO

O hidrogênio é um combustível limpo, e o hidrogênio verde (H2V), produzido a partir de fontes de energia renovável, representa uma alternativa ecologicamente sustentável aos combustíveis de origem fósseis. O hidrogênio verde se destaca especialmente por seu potencial de descarbonização em setores intensivos em carbono, como o transporte pesado, a produção de fertilizantes e a geração de energia elétrica. Contudo, o alto custo de produção ainda é um desafio significativo para a viabilidade comercial do hidrogênio verde, reduzindo o interesse de alguns setores industriais e de energia elétrica, o que tem levado à suspensão e ao atraso de muitos projetos.

No Brasil, a ampla disponibilidade de recursos naturais, como energia solar, eólica e hídrica, representa uma vantagem comparativa significativa para a produção de hidrogênio verde. Esses recursos renováveis, quando aplicados à eletrólise da água, permitem a geração sustentável de hidrogênio verde a custos potencialmente competitivos. Além disso, a produção descentralizada, viabilizada pelas tecnologias disponíveis, favorece a difusão e o uso do hidrogênio verde em diferentes regiões do país.

Entre essas tecnologias, destaca-se o uso de Gêmeos Digitais (Digital Twin - DT), definidos como “representações virtuais de alta fidelidade de sistemas físicos” que se mantêm sincronizados em tempo real e, em alguns casos, operam com capacidades preditivas, antecipando eventos antes mesmo de sua ocorrência no mundo físico. Essa característica preditiva permite não apenas o acompanhamento preciso, mas também a otimização proativa dos processos de produção e armazenamento de energia elétrica, garantindo maior eficiência e confiabilidade (BAI *et al.*, 2024). O conceito de gêmeo digital remonta aos anos 1970, com a NASA, que usou simulações de alta fidelidade para treinar astronautas na missão Apollo 13; mais tarde, o termo foi formalizado em 2003 e ampliado como uma tecnologia capaz de “espelhar a vida de seu correspondente físico”, integrando dados de sensores e histórico operacional para reproduzir com precisão o desempenho de sistemas complexos (KUPRAT *et al.*, 2024).

Na eletrônica de potência, a aplicação de Gêmeos digitais enfrenta o desafio de equilibrar alta fidelidade e rápida resposta computacional, uma vez que o controle preciso e em tempo real é necessário para otimizar o funcionamento dos sistemas, especialmente em cenários de operação intensiva, como a produção de hidrogênio verde (BAI *et al.*, 2024). Nesse setor, o uso de gêmeos digitais térmicos (thermal digital twins) também se mostra vantajoso, pois permite monitorar em tempo real o comportamento térmico dos sistemas, ajustando parâmetros continuamente para maximizar a eficiência e a longevidade dos equipamentos (KUPRAT *et al.*, 2024).

Com a digitalização crescente dos processos industriais, os gêmeos digitais são uma solução viável ao possibilitar que as indústrias realizem um monitoramento digital detalhado dos produtos, facilitando a detecção precoce de problemas físicos, a previsão de

resultados com maior precisão e a criação de produtos de maior qualidade (PARROTT; WARSHAW, 2017). O conceito de gêmeo digital foi cunhado por John Vickers, da NASA, e Michael Grieves, que lecionava o curso de Gestão de Ciclo de Vida do Produto (*Product Lifecycle Management* - PLM) na Universidade de Michigan em 2003 (GRIEVES; VICKERS, 2017).

Na época, Grieves descrevia a representação virtual de produtos como algo “...relativamente novo e imaturo”, já que a coleta de dados dos produtos físicos era “...limitada, realizada manualmente e em sua maioria registrada em papel”. Grieves e Vickers idealizavam um cenário onde o modelo virtual de um produto poderia servir como base para o Gêmeo Digital, uma representação virtual de um produto físico que retém as informações desse produto (JONES *et al.*, 2020).

Diante disso, é fundamental alimentar continuamente a tecnologia dos gêmeos digitais com dados fidedignos, fiéis à operação real e relevantes para as análises a serem realizadas. Isso assegura que as informações obtidas sejam confiáveis para permitir tomadas de decisão rápidas, assertivas e informadas, com uma visão detalhada do desempenho atual e futuro dos sistemas. Vale destacar que os avanços nas tecnologias de inteligência artificial (*Artificial Intelligence* - IA) e Internet das Coisas (*Internet of Things* - IoT) têm facilitado a obtenção e análise rápida de dados, contribuindo para o desenvolvimento de insights e tendências. Consequentemente, os Gêmeos digitais evoluíram, podendo ser classificados em diferentes níveis de complexidade, desde o nível de componente até o nível de processo.

(BUSARELLO, 2024) destaca que, embora o conceito de gêmeos digitais na engenharia não seja novo, a capacidade de atualizar automaticamente o modelo virtual com modificações do sistema real tem incentivado indústrias e academia a buscar soluções novas e rápidas, sendo a inteligência artificial uma forte candidata para atender a essa necessidade.

Para atender às demandas das atividades cotidianas de análise e otimização dos processos industriais, o gêmeo digital permite o monitoramento em tempo real, possibilitando análises e validações rápidas, com ganhos em agilidade, eficiência e praticidade. Segundo o grupo AVEVA, o gêmeo digital pode reduzir as despesas de uma empresa em até 30%, aumentar a produtividade em até 10% e incrementar a receita em até 2% (AVEVA, 2022).

Conforme (BUSARELLO, 2024), a configuração de um Gêmeo Digital permite:

- Testar novos algoritmos de controle com segurança, sem risco de danos ao sistema físico.
- Realizar múltiplos testes em curtos períodos de tempo.
- Medir parâmetros específicos do protótipo em tempo real e atualizar automaticamente o modelo virtual.

Considerando que o hidrogênio verde se posiciona no cenário internacional como uma das fontes renováveis com maior potencial para substituir o “hidrogênio cinza” e

outros combustíveis fósseis, especialmente em aplicações de transporte de carga pesada, fertilizantes agrícolas e geração de eletricidade, o uso de Gêmeos digitais com aprendizado de máquina (*machine learning*) surge como uma estratégia viável para otimizar a produção, o armazenamento e a conversão do hidrogênio verde em energia elétrica.

1.1 ORGANIZAÇÃO DO TEXTO

O presente trabalho está estruturado em cinco capítulos. O primeiro capítulo corresponde à introdução, apresentando o contexto, a relevância do tema e os objetivos do estudo. O segundo capítulo detalha a metodologia utilizada para a realização da revisão da literatura, descrevendo os critérios de seleção e análise das fontes.

O terceiro capítulo reúne a discussão sobre o hidrogênio verde e a utilização de gêmeos digitais com aprendizado de máquina, abordando como essas tecnologias podem ser integradas para otimizar a produção, armazenamento e conversão de hidrogênio em energia elétrica, destacando também os benefícios ambientais e econômicos dessa aplicação.

O quarto capítulo apresenta uma síntese das contribuições e projeções futuras deste estudo, apontando caminhos promissores para a implementação prática de gêmeos digitais e aprendizado de máquina no contexto industrial, com ênfase na validação experimental e na evolução tecnológica.

Por fim, o quinto capítulo apresenta a conclusão, consolidando os principais pontos discutidos e ressaltando as contribuições deste trabalho ao campo da automação industrial. Também são sugeridos desdobramentos para pesquisas futuras, considerando as oportunidades e os desafios na aplicação prática das tecnologias analisadas.

1.1.1 Objetivo Geral

Demonstrar, por meio de revisão bibliográfica, a viabilidade de elaboração de um gêmeo digital para o sistema de produção de hidrogênio verde, incluindo metodologias de aprendizagem para aprimorar os processos de produção, armazenamento e conversão energética deste recurso.

1.1.2 Objetivos Específicos

1. Realizar uma revisão da literatura sobre o conceito de hidrogênio verde, destacando sua importância na transição energética e os desafios associados à sua produção, armazenamento e conversão em energia elétrica.
2. Investigar a aplicação de gêmeos digitais, com ênfase na integração de tecnologias como sensores, controle avançado e aprendizado de máquina para otimizar processos produtivos.
3. Identificar os benefícios do aprendizado de máquina na modelagem preditiva e na manutenção preditiva de sistemas de produção de hidrogênio verde.

4. Explorar as possibilidades de integração entre gêmeos digitais e aprendizado de máquina para aprimorar a eficiência energética e reduzir os custos associados à produção e ao armazenamento de hidrogênio verde.
5. Analisar as projeções futuras e as potenciais contribuições tecnológicas da combinação de gêmeos digitais e aprendizado de máquina para o avanço da automação industrial e a sustentabilidade ambiental.

2 PERCURSO METODOLÓGICO

Realizar uma pesquisa implica na adoção de uma série de requisitos que envolvem o desenvolvimento de métodos, estratégias, perícia, bom senso e instinto. Esses elementos exigem do pesquisador conhecimento de diferentes naturezas, incluindo o domínio teórico, técnico e metodológico da abordagem que se pretende adotar (GATTI, 2002).

Os estudos de revisão bibliográfica são caracterizados pela análise e uso de documentos científicos, como livros, teses, dissertações e artigos acadêmicos, sem a aplicação direta de dados empíricos. Dessa forma, esse tipo de pesquisa baseia-se em fontes secundárias, ou seja, nas contribuições de diferentes autores sobre um tema específico. Isso distingue a revisão bibliográfica da pesquisa documental, que se concentra em fontes primárias que ainda não passaram por um tratamento científico (SÁ-SILVA; ALMEIDA, C. D. d.; GUINDANI, 2009).

Segundo Okoli (2015),

A revisão sistemática (também chamada de revisão sistemática da literatura) é uma metodologia rigorosa [...]; desde então, foi expandida para as ciências sociais e outros campos de pesquisa, incorporando outras abordagens de síntese, inclusive qualitativas. Uma revisão sistemática não é meramente uma “revisão da literatura” no sentido de uma coleta e discussão da literatura relevante; trata-se de uma metodologia científica rigorosa para responder com autoridade a questões sobre as quais existe uma quantidade considerável de pesquisa, sintetizando os estudos já existentes (OKOLI, 2015, p.03).

Em consonância com esse entendimento, Campbell Collaboration (2024) ressalta que esse tipo de análise tem por objetivo sumarizar as melhores evidências disponíveis sobre uma questão específica, empregando procedimentos transparentes para localizar, avaliar e sintetizar os resultados de pesquisas relevantes na área em estudo.

Os referenciais teóricos demonstram que essa abordagem metodológica se fundamenta na coleta abrangente de textos publicados sobre um determinado tema, com etapas definidas para garantir rigor científico e alta transparência. Trata-se, portanto, de uma pesquisa baseada em fontes secundárias que emprega métodos claros e sistemáticos, reduzindo o risco de vieses na busca, coleta, extração e utilização de dados provenientes de estudos primários. Assim, ela fornece evidências de alta qualidade para embasar o contexto a ser investigado (CAMPOS; CAETANO; LAUS-GOMES, 2023).

Diante do exposto, e no contexto de uma pesquisa qualitativa, este estudo visa evidenciar, por meio de análises previamente realizadas, a aplicação de gêmeos digitais com aprendizado de máquina (*Machine Learning*) para otimizar a produção, o armazenamento e a conversão de hidrogênio verde em energia.

Para embasar o estudo, realizou-se uma busca abrangente em livros e artigos científicos, utilizando palavras-chave como "gêmeos digitais", "aprendizado de máquina" e "hidrogênio verde", bem como seus correspondentes em inglês: "*digital twins*", "*machine learning*" e "*green hydrogen*", com o objetivo de aprofundar os conceitos fundamentais

relacionados a essas áreas. Além disso, foi realizada uma pesquisa em sites de notícias confiáveis para incorporar informações atualizadas sobre o mercado de hidrogênio verde e gêmeos digitais, possibilitando a análise de tendências e avanços recentes no setor. Imagens ilustrativas também foram utilizadas para complementar a análise, promovendo maior clareza visual aos tópicos abordados.

3 REVISÃO DA LITERATURA

3.1 A RELEVÂNCIA DO HIDROGÊNIO VERDE

O hidrogênio se mostra um ator central na transição energética. Ele se destaca como uma fonte de energia flexível e sustentável. O conceito de "cores" atribuído a ele se refere a várias metodologias em sua produção, conforme apresentado na Figura 1.



Figura 1 – Paleta de cores do hidrogênio e seus métodos de produção. Fonte: InvestNews (2024b).

É importante salientar que as cores atribuídas ao hidrogênio têm como única finalidade ilustrar os processos de produção. Na prática, o hidrogênio é um gás incolor, inodoro e amplamente eficiente como portador de energia.

Dentre as diversas formas de produção, o hidrogênio verde se destaca por ser gerado a partir de fontes de energia renováveis, como solar e eólica, sem emissão de gás carbônico (CO_2). Esse tipo de hidrogênio, produzido de maneira neutra em relação ao clima, é apontado por especialistas como uma solução estratégica para a redução das emissões de CO_2 em setores industriais variados.

A produção do hidrogênio verde envolve a separação da molécula de água em hidrogênio e oxigênio, por meio de um processo denominado eletrólise da água, que utiliza eletricidade proveniente de fontes renováveis. Por ser isento de emissões, esse método representa uma alternativa ecologicamente correta e altamente promissora. Além disso, o hidrogênio verde possibilita o armazenamento de energia gerada por fontes renováveis e o transporte dessa energia a longas distâncias, conectando regiões com abundância de

recursos energéticos locais com demanda energética, mesmo a milhares de quilômetros de distância.

É por meio de um processo denominado eletrólise da água que se forma a divisão da molécula de água em hidrogênio e oxigênio. A energia usada neste processo é derivada de fontes renováveis de eletricidade. Isso, portanto, retrata uma técnica limpa que se destaca não apenas como ecologicamente correta, mas também bastante promissora. Nesta linha, o transportador de hidrogênio verde pode armazenar tanta energia quanto a produzida pela geração de energia a partir de fontes de energia renováveis. E também é usado como transportador de energia no transporte de energia por grandes distâncias, ligando regiões ricas em energia às que demandam energia, mesmo que estejam a milhares de quilômetros de distância.

No contexto brasileiro, o hidrogênio verde emerge como uma solução estratégica devido à abundância de recursos naturais renováveis, como a energia solar, eólica e hidroelétrica. O Brasil possui um grande potencial para se tornar um dos líderes globais na produção e exportação deste recurso, especialmente em função de sua matriz energética predominantemente limpa e das extensas áreas disponíveis para instalação de usinas solares e parques eólicos. Regiões como o Nordeste brasileiro, ricas em fontes renováveis, apresentam condições ideais para a geração do hidrogênio verde, além de proximidade com portos estratégicos para exportação.

3.1.1 Demandas Atuais

Com a dinâmica da vida moderna, a demanda por energia tem crescido constantemente. Em 2019, estimativas da Agência Internacional de Energia (AIE) previam que a demanda global de energia aumentaria entre 25% e 30% até 2040. Em uma economia dependente de carvão e petróleo, tal aumento significaria mais emissões de CO_2 , exacerbando as mudanças climáticas (CENTRO DE HIDROGÊNIO VERDE - UNIFEI, 2019).

O processo de descarbonização do planeta, contudo, projeta um mundo mais acessível, eficiente e sustentável para 2050, impulsionado por energias limpas e renováveis, como o hidrogênio verde (SILVEIRA; OLIVEIRA, 2021). Assim, a descarbonização se apresenta como uma das principais metas globais atuais.

Especialistas de diversas áreas do conhecimento afirmam que o hidrogênio verde poderá representar cerca de um quarto do mercado energético mundial até 2050, com potencial para impulsionar a transição energética. Ele é visto como um portador de energia limpa e uma solução ecológica para o planeta (KOVAČ; PARANOS; MARCIUŠ, 2021).

Em torno de 75% do nosso sistema solar é composto por hidrogênio, razão pela qual esse gás tem sido amplamente discutido em termos de transição energética e proteção climática. Espera-se que, num futuro próximo, o hidrogênio (H_2), um gás incolor e inodoro, cumpra um papel relevante nos setores de transporte, indústria, construção e geração de

energia, impactando positivamente a economia (SILVA, 2016).

O hidrogênio, também chamado de gás hidrogênio ou gás ultraleve, é composto por dois átomos de hidrogênio ligados por um elo covalente, sendo o átomo mais leve da tabela periódica. Representado pela fórmula química H_2 , ele é visto por especialistas como uma fonte promissora para o alcance das metas climáticas, especialmente quando combinado com eletricidade de origem "verde".


Historicamente, o hidrogênio tem sido usado como combustível em carros, dirigíveis e naves espaciais desde o início do século XIX.

Embora disponível em abundância, principalmente em moléculas combinadas com outros elementos, a produção de hidrogênio é cara e energeticamente intensa. Um método comum de produção é a eletrólise, na qual a molécula de água (H_2O) é transformada em gás hidrogênio (H_2) e oxigênio (O_2) por meio de corrente elétrica. Se essa eletricidade for proveniente de fontes renováveis, como energia solar ou eólica, o produto é denominado "hidrogênio verde" (ALMEIDA, A. S. d. e. a., 2019).

Conforme Marc Richter (2023),

Cada quilograma de hidrogênio contém cerca de 2,4 vezes mais energia do que o gás natural. Além disso, a única entrada necessária para liberar essa energia é o oxigênio, e a única saída é a água. Isto significa que, como fonte de energia, o hidrogênio produz zero emissões de gases de efeito estufa (GEE), uma vez que a combustão do hidrogênio gera apenas água, sem liberar GEE (MARC RICHTER, 2023, p. 416).

A reação de combustão do hidrogênio pode ser evidenciada pela Equação 1, onde a energia liberada é de 242 kJ/mol ou 121 kJ/g.



Para ilustrar o processo de geração de energia a partir do hidrogênio, a Figura 2 apresenta um esquema de uma célula de combustível, onde o hidrogênio é utilizado para produzir eletricidade de forma eficiente e limpa. Conforme descrito por Electrocell (2019), as células de combustível são dispositivos eletroquímicos que convertem energia química diretamente em energia elétrica, utilizando, por exemplo, hidrogênio como combustível, com a vantagem de produzir como subproduto apenas água, sem emissões poluentes.

Para a fabricação da energia elétrica a partir do hidrogênio, é utilizada uma membrana eletrolítica, que pode ser composta de diferentes materiais, dependendo do tipo de célula de combustível e das condições de operação. Esses materiais são responsáveis por influenciar a eficiência, a durabilidade e a aplicabilidade da energia gerada. Podemos ver uma breve comparação desses materiais na Tabela 1.

Tipo	Eletrólito (espécie transportada)	Faixa de Temp. (°C)	Vantagens	Desvantagens	Aplicações
Alcalina (AFC)	KOH (OH ⁻)	60–90	Alta eficiência (83% teórica)	Sensível a CO ₂ , gases ultra puros, sem reforma do combustível	Espaçonaves, aplicações militares
Membrana (PEMFC)	Polímero: Nafion® (H ₃ O ⁺)	80–90	Altas densidades de potência e eficiência, operação flexível	Custo da membrana e catalisador, contaminação do catalisador com CO	Veículos automotores, espaçonaves, mobilidade
Ácido fosfórico (PAFC)	H ₃ PO ₃ (H ₃ O ⁺)	160–200	Maior desenvolvimento tecnológico	Controle da porosidade do eletrodo, sensibilidade a CO, eficiência limitada pela corrosão	Unidades estacionárias (100 kW a alguns MW), cogeração eletricidade/calor
Carbonatos fundidos (MCFC)	Carbonatos fundidos (CO ₃ ²⁻)	650–700	Tolerância a CO/CO ₂ , eletrodos à base de Ni	Problemas de materiais, necessidade da reciclagem de CO ₂ , interface trifásica de difícil controle	Unidades estacionárias de algumas centenas de kW, cogeração eletricidade/calor
Cerâmicas (SOFC)	ZrO ₂ (O ²⁻)	800–900	Alta eficiência (cinética favorável), a reforma do combustível pode ser feita na célula	Problemas de materiais, expansão térmica, necessidade de pré-reforma	Unidades estacionárias de 10 a algumas centenas de kW, cogeração eletricidade/calor

Tabela 1 – Tabela comparativa de tipos de células a combustível. Fonte: Wendt, Götz e Linardi (2000)

Célula combustível com Membrana Trocadora de Prótons




Figura 2 – Esquema de uma célula de combustível utilizando hidrogênio. Fonte: InfoEscola (2024).

3.1.2 O Cenário Atual do Hidrogênio Verde

Harvard divulgou, na edição de 9 de outubro de 2024 do "The Wall Street Journal", uma matéria intitulada "Custo de produção do hidrogênio verde é proibitivo", baseada na realidade dos Estados Unidos da América (EUA).

O artigo destaca que, atualmente, os custos de produção, transporte e armazenamento do hidrogênio verde são superiores aos dos combustíveis fósseis e à futura remoção de carbono da atmosfera. Segundo uma pesquisa publicada na revista científica *Joule*, para eliminar uma tonelada de dióxido de carbono, os custos associados ao hidrogênio verde variam entre US\$ 500 e US\$ 1.250. Em comparação, os preços de captura e armazenamento de carbono nos EUA atualmente oscilam entre US\$ 100 e US\$ 1.000 por tonelada, o que torna a extração de CO_2 diretamente da atmosfera uma opção mais viável.

De acordo com The Wall Street Journal (2024),

O relatório foi divulgado uma semana depois de a Agência Internacional de Energia ter publicado sua última revisão global sobre a economia do hidrogênio. O documento observou que a demanda global pelo gás atingiu 97 milhões de toneladas em 2023, representando um aumento de 2,5% em relação a 2022.

A pesquisa também aponta que o Brasil possui grande potencial para a produção de hidrogênio verde, devido à sua abundância de recursos naturais.

No contexto internacional, a demanda por hidrogênio continua a crescer, embora grande parte da produção planejada ainda esteja em estágios iniciais de desenvolvimento. The Wall Street Journal (2024) cita Roxane Shafiee, pesquisadora de pós-doutorado no Centro para o Meio Ambiente da Universidade de Harvard, que ressalta a necessidade de uma expansão anual de 90% entre 2024 e 2030 para que todos os projetos em andamento se concretizem. Esse ritmo de crescimento seria sem precedentes, superando significativamente

as taxas de expansão observadas na energia solar durante seus períodos de maior aceleração.

A pesquisa aponta que o cenário atual apresenta sinais pouco claros quanto à demanda, além de enfrentar obstáculos como dificuldades de financiamento, atrasos em incentivos, incertezas regulatórias, questões de licenciamento e desafios operacionais, os quais dificultam o crescimento do setor. The Wall Street Journal (2024) cita Pierre Etienne Franc, CEO da Hy24, uma gestora de investimentos focada em hidrogênio limpo (derivado de fontes renováveis), que observa que o entusiasmo inicial era elevado, com a expectativa de que o hidrogênio pudesse alcançar, em uma década, o que o gás natural liquefeito (GNL) não conseguiu em 50 anos e o que a energia nuclear não realizou em 70 anos.

Franc ressalta que os Estados Unidos estão atualmente "à frente" no desenvolvimento do hidrogênio azul, destacando diversos projetos de grande escala no país que estão próximos de tomar decisões finais de investimento. O hidrogênio azul, produzido a partir de fontes fósseis como o gás natural, tem suas emissões de dióxido de carbono (CO_2) capturadas e armazenadas para mitigar o impacto ambiental. Esse processo permite a geração de hidrogênio com menor emissão de carbono em comparação ao hidrogênio tradicional. Além disso, o programa fiscal 45Q, nos EUA, oferece créditos tributários que incentivam investimentos em captura e armazenamento de carbono.

O sucesso dos projetos de hidrogênio azul em larga escala nos Estados Unidos da América e a escolha do país de avançar para a fase de decisão final de investimento (FID) são, em grande parte, atribuídos aos créditos fiscais disponíveis. Esse progresso representa uma vitória para os Estados Unidos, pois permite a utilização contínua dos recursos de gás natural existentes e o desenvolvimento de produtos derivados de hidrogênio com baixo carbono, como os obtidos no refino de petróleo, fertilizantes e e-combustíveis. Apostando no mercado a médio e longo prazo, conforme veiculado pela InvestNews (2024a), a Arábia Saudita irá investir no futuro mais de 10 bilhões de dólares em produção de hidrogênio verde, estabelecendo a Energy Solutions Co. em parceria com a Saudi Aramco, visando diversificar a economia além do petróleo.

The Wall Street Journal (2024) menciona ainda Eugene McKenna, vice-presidente sênior de hidrogênio e tecnologias sustentáveis da Johnson Matthey, que afirma que regulamentações claras e maior apoio a projetos de hidrogênio azul podem impulsionar a indústria em outras regiões. Ele ressalta que as empresas buscam investir em projetos que sejam lucrativos para seus acionistas e que só o farão se houver viabilidade comercial.

O mercado de hidrogênio verde está em rápida expansão, com projeções que indicam uma demanda global superior a 200 milhões de toneladas até 2030, impulsionada pelo compromisso de descarbonização de diversos setores industriais e pelo avanço de políticas públicas de incentivo (HOLANDA ARAÚJO; TUPINAMBÁ, 2023; BEZUTTI, 2023). Estima-se que o valor desse mercado possa alcançar US\$ 1,4 trilhão até 2050, superando o mercado de gás natural líquido (BASTOS, 2023). Apesar do elevado potencial, desafios como custos de produção e desenvolvimento de infraestrutura ainda precisam ser superados

para que o hidrogênio verde se consolide como uma alternativa competitiva no mercado global (NELSON SIFFERT, 2023; COMPANY, 2023).

McKenna sugere que projetos de hidrogênio verde têm mais chances de sucesso em países como o Brasil e a Austrália, onde as fontes de energia renováveis são mais abundantes, enquanto o hidrogênio azul pode ser mais viável em países como os EUA e na região norte da Europa.

No Brasil, diversas iniciativas estão sendo lideradas por empresas para a produção de hidrogênio verde. Entre os esforços, destaca-se a parceria da mineradora Vale com a europeia Green Energy Park (GEP), que visa avaliar a instalação de uma unidade de produção de hidrogênio verde para abastecer um complexo industrial. Esse "mega hub" poderá ser uma plataforma aberta para parcerias internacionais, com o objetivo de descarbonizar a cadeia produtiva siderúrgica por meio do uso do HBI (ferro briquetado a quente). Esses esforços refletem a importância do Brasil como um potencial hub de produção e exportação de hidrogênio verde, aproveitando suas vantagens geográficas e recursos renováveis.

Outras empresas, como Shell, EDP, Auren e Casa dos Ventos, também estão desenvolvendo projetos que visam posicionar o Brasil entre os principais produtores globais de hidrogênio verde. Atualmente, estima-se que existam pelo menos 23 iniciativas em andamento no país, com investimentos previstos na ordem de R\$ 188,7 bilhões, conforme apresentado na Figura 3. Com a sanção do marco regulatório do hidrogênio de baixa emissão de carbono, o governo brasileiro tem incentivado a produção desse combustível, que possui grande potencial para contribuir com a descarbonização da matriz energética nacional e internacional.




Figura 3 – Projetos de hidrogênio verde no Brasil. Fonte: InvestNews (2024b).

No que diz respeito aos estados destacados na Figura 3, o Nordeste se sobressai

como a região mais promissora devido à abundância de fontes de energia renovável. Paralelamente, os estados do Sul do Brasil têm avançado significativamente no desenvolvimento de iniciativas relacionadas ao hidrogênio verde, impulsionados pela busca por alternativas energéticas sustentáveis. Em Santa Catarina, a Universidade Federal de Santa Catarina (UFSC) inaugurou, em 2023, a primeira usina de hidrogênio verde do estado, localizada no Laboratório Fotovoltaica, no Sapiens Parque, em Florianópolis, fruto de uma parceria tecnológica entre Brasil e Alemanha (MIRANDA, 2023). O estado também sancionou a Política Estadual do Hidrogênio Verde, que visa fomentar a produção e o uso desse combustível em setores como energia e fertilizantes, contribuindo para a redução de emissões de gases de efeito estufa (PORTAL LITORAL SUL, 2024).

No Rio Grande do Sul, o governo estadual está desenvolvendo um "MasterPlan" para mapear o potencial de produção de hidrogênio verde e consolidar o estado como um hub nacional desse setor. Com projeções de investimentos de até US\$ 10 bilhões nos próximos anos, estima-se a geração de milhares de empregos diretos e indiretos, reforçando a relevância da região no processo de transição energética (CIVIL, 2023).


3.1.3 Produção de Hidrogênio Verde

De acordo com Atilhan *et al.* (2021), a demanda mundial por hidrogênio deve crescer de aproximadamente 70 milhões de toneladas em 2019 para 120 milhões de toneladas em 2024. Diversos recursos podem ser utilizados para a produção de hidrogênio, incluindo fontes fósseis e renováveis (DAWOOD; ANDA; SHAFIULLAH, 2020).

Atualmente, os combustíveis fósseis são os mais consolidados e frequentemente empregados na indústria devido à sua viabilidade econômica. Estes métodos incluem o craqueamento e a reforma de hidrocarbonetos. Em 2016, a produção global de hidrogênio foi de cerca de 85 milhões de toneladas, sendo majoritariamente aplicada em setores como refino de petróleo, metalurgia, produção de fertilizantes, processamento de alimentos e fabricação de semicondutores (EL-EMAM; ÖZCAN, 2019).

O hidrogênio pode ser extraído de fontes naturais, como hidrocarbonetos e compostos químicos, utilizando técnicas variadas. Estas incluem abordagens fotônicas, elétricas, químicas, bioenergéticas, térmicas ou combinações dessas (EL-EMAM; ÖZCAN, 2019).

Embora a maior parte do hidrogênio atual seja obtida de combustíveis fósseis — como gás natural, carvão e petróleo —, ele desempenha papéis essenciais em setores como refinarias, onde é utilizado para processar petróleo bruto, e na produção de compostos químicos, como metanol e amônia (NORONHA *et al.*, 2021). Uma alternativa mais sustentável é o processo de eletrólise, descrito na Equação (2), que separa moléculas de água em hidrogênio e oxigênio por meio de energia elétrica.



O hidrogênio obtido nesse processo passa por etapas de secagem, purificação e

compressão, alcançando pressões entre 10,3 e 413,7 bar antes de ser armazenado em tanques. Apesar de atualmente representar menos de 5% da produção global, a eletrólise é considerada promissora devido à ausência de emissões de carbono e à produção de hidrogênio com alta pureza (HAN *et al.*, 2021).

A Figura 4 apresenta um infográfico que resume as etapas do processo de produção, armazenamento e uso do hidrogênio verde. Já a Figura 5 ilustra o esquema detalhado do processo de geração de hidrogênio verde utilizando fontes renováveis, como energia solar e eólica. Essa abordagem destaca-se por não emitir gases de efeito estufa, alinhando-se às metas globais de descarbonização e sendo considerada uma das alternativas mais promissoras para a produção sustentável de hidrogênio.




Figura 4 – Processo de produção, armazenamento e uso do hidrogênio verde. Fonte: InvestNews (2024b).




Figura 5 – Processo de geração de hidrogênio verde por eletrólise utilizando fontes renováveis. Fonte: (RIBEIRO, 2022).

As Tabelas 2 e 3 apresentam análises comparativas das principais tecnologias de eletrólise utilizadas na produção de hidrogênio. Enquanto a Tabela 2 explora aspectos técnicos como tipos de eletrólitos, faixas de temperatura e eficiência, a Tabela 3 sintetiza as vantagens e desvantagens de cada tecnologia.

Essas informações são incluídas para demonstrar a diversidade de métodos existentes para a produção de hidrogênio via eletrólise, bem como os desafios e oportunidades associados a cada abordagem. Essa análise permite identificar quais tecnologias são mais adequadas para diferentes cenários e aplicações industriais, contribuindo para a escolha estratégica na busca por soluções eficientes e sustentáveis para a produção de hidrogênio.

Característica	Alcalina (AEC)	AEM	PEM	Óxido Sólido (SOEC)
Eletrólito	KOH/NaOH (5M)	1M KOH/NaOH	Polímero sólido (PFSA)	Zircônia estabilizada com ítria (YSZ)
Separador	Asbesto/ Zircon/ Ni	Fumatech	Nafion	YSZ
Cátodo	Aço inox perfurado com níquel	Níquel	Óxido de irídio	Ni/YSZ
Ânodo	Aço inox perfurado com níquel	Níquel/NiFeCo	Platina-carbono	Perovskitas (LSCF, LSM)
Temperatura Operacional (°C)	70-90	40-60	50-80	700-850
Pressão	<30 bar	<35 bar	<70 bar	1 bar
Eficiência	50-78%	57-59%	50-83%	89%
Vida útil (horas)	60.000	>30.000	50.000-80.000	20.000
Status de Desenvolvimento	Madura	Pesquisa e Desenvolvimento	Comercial	Pesquisa e Desenvolvimento
Custo de Capital	500-1000 USD/kW	-	700-1400 USD/kW	-

Tabela 2 – Comparação de tecnologias de eletrólise Fonte: Adaptado de S. Shiva Kumar e Lim (2022) e Tenhumberg e Büker (2023)

Tecnologia	Vantagens	Desvantagens
Alcalina (AEC)	Tecnologia madura e comercialmente disponível; custos de capital mais baixos	Eficiência energética relativamente menor; necessita de separadores para evitar a mistura de gases
AEM	Design compacto; não requer catalisadores de metais nobres	Necessita de mais pesquisa e desenvolvimento para melhorar a estabilidade e eficiência
PEM	Alta eficiência; resposta rápida a variações de carga; design compacto	Uso de catalisadores de metais nobres aumenta o custo; sensível a impurezas na água
Óxido Sólido (SOEC)	Alta eficiência devido ao aproveitamento de calor; possibilidade de integração com fontes de calor residual	Altas temperaturas requerem materiais resistentes; menor flexibilidade operacional

Tabela 3 – Vantagens e Desvantagens das Tecnologias de Eletrólise Fonte: Adaptado de S. Shiva Kumar e Lim (2022)

A expressão "power-to-gas" (Energia para o Gás - P2G) refere-se à geração de um gás combustível a partir da eletrólise da água (H_2O) utilizando energia elétrica. Com essa tecnologia, o gás hidrogênio (H_2), também chamado de gás natural sintético, é produzido e pode ser armazenado na rede de gás natural. Espera-se que os custos de produção de hidrogênio via eletrólise diminuam em cerca de 70% na próxima década, facilitando a adoção em larga escala da produção de hidrogênio verde.

A gaseificação da biomassa é considerada uma das alternativas mais viáveis e sustentáveis para a produção de hidrogênio, com potencial de ser neutra em carbono (SAIDI; GOHARI; RAMEZANI, 2020). Como a biomassa é uma fonte renovável que absorve CO_2 da atmosfera durante seu crescimento, sua pegada líquida de carbono é significativamente menor em comparação com a dos combustíveis fósseis. No entanto, a viabilidade econômica da produção de hidrogênio a partir da biomassa depende da disponibilidade e do custo da matéria-prima.

As propriedades físico-químicas, a distribuição e a concentração de hidrogênio na biomassa são fatores essenciais para a seleção de materiais de fornecimento. Devido à grande diversidade na composição estrutural e na forma das matérias-primas de biomassa, é importante considerar essas características ao associar a matéria-prima com a tecnologia de conversão adequada (SRIVASTAVA *et al.*, 2020).

Nos processos de reforma, o hidrogênio é gerado como subproduto na indústria química. O processo de reforma catalítica, derivado do latim "reformare", é utilizado em refinarias para converter alcanos e cicloalcanos derivados da nafta (gasolina bruta) em compostos aromáticos e alcanos ramificados, com o objetivo de aumentar o índice de octanas. O gás H_2 é um subproduto significativo desse processo. O gás natural, composto principalmente por metano e contendo outros hidrocarbonetos e CO_2 , é a principal matéria-

prima para a reforma do metano a vapor (OSMAN, 2020).

A reação do gás natural com o vapor ocorre em duas etapas, a temperaturas elevadas. Primeiramente, há a reação do monóxido de carbono com o hidrogênio gerado, junto com o gás natural não reagido. Em seguida, adiciona-se mais vapor para reagir com o monóxido de carbono em uma reação de deslocamento água-gás, permitindo a recuperação adicional de hidrogênio e a conversão de CO em CO_2 . A eficiência total desse processo é de cerca de 75% (PINSKY *et al.*, 2020). No entanto, ele emite uma quantidade significativa de dióxido de carbono, o que pode ser mitigado pela implementação de tecnologias de captura e armazenamento de carbono, que separam os gases de combustão do fluxo de produto.

3.1.4 O Papel do Hidrogênio no Contexto de Energia Sustentável

O hidrogênio desempenha um papel crucial em setores onde a eletrificação direta não é viável no curto prazo, como o transporte aéreo, o transporte de mercadorias pesadas e o transporte marítimo. Nesse contexto, a tecnologia Energia para Gás surge como uma solução eficiente em termos de economia de energia e sustentabilidade, especialmente quando aproveita o excedente de eletricidade gerada por fontes renováveis, como energia solar e eólica. Esse gás pode ser utilizado diretamente como um portador de energia ou convertido em metano, gás de síntese, combustíveis líquidos, eletricidade e produtos químicos como amônia e metanol (THEMA; BAUER; STERNER, 2019).

3.1.4.1 Aplicações do Hidrogênio

A seguir, são apresentados alguns usos importantes do hidrogênio:

Aplicações estacionárias

Células de combustível podem atuar como pequenas usinas combinadas de calor e energia, estações móveis de energia para sistemas de comunicação ou como geradores de emergência. Além disso, minicélulas de combustível podem substituir baterias em dispositivos eletrônicos, como laptops. O hidrogênio verde também é capaz de aquecer fornos industriais em setores como vidro, cimento e aço, promovendo descarbonização nesses processos.

Hidrogênio como combustível – aplicações móveis

Quando queimado, o hidrogênio não gera emissões, produzindo apenas vapor d'água. Isso o torna um substituto ideal para combustíveis fósseis nos setores de transporte e indústria. Na forma comprimida, o hidrogênio apresenta alta densidade energética, sendo adequado para transporte em longas distâncias, tanto em terra quanto no mar. Ele pode ser

utilizado diretamente em motores de combustão ou convertido em eletricidade por meio de células de combustível. Exemplos de aplicações incluem carros, ônibus, caminhões, bondes, locomotivas, navios e aeronaves movidos a hidrogênio, evidenciando o vasto potencial dessa fonte de energia limpa. Além disso, o hidrogênio pode ser utilizado como matéria-prima para combustíveis sintéticos, contribuindo para um transporte menos impactante ao meio ambiente.

Hidrogênio como armazenamento de energia

Com o aumento do uso de energia renovável, torna-se essencial gerenciar as flutuações na sua disponibilidade. O hidrogênio é uma molécula que pode ser transportada e armazenada globalmente, independentemente do local ou do momento em que a energia renovável é gerada. Contudo, devido ao seu baixo ponto de fusão e ebulição, o hidrogênio só se torna líquido sob alta pressão, o que limita seu transporte. Para superar esse desafio, pesquisas estão sendo realizadas para ligar o hidrogênio a líquidos orgânicos, facilitando seu transporte. Esses líquidos resultam da combinação de silanos e álcoois.

3.1.4.2 *Produção de Amônia e Metanol a partir do Hidrogênio Verde*

A amônia é uma das substâncias químicas mais produzidas globalmente e se destaca como um meio eficiente de armazenamento de energia. Quando o hidrogênio utilizado na sua produção é obtido a partir de eletricidade renovável, resulta na chamada amônia verde, que apresenta uma densidade energética maior que o hidrogênio, facilitando seu transporte e armazenamento. O Brasil, devido ao seu potencial em fontes renováveis, pode se tornar um grande exportador de amônia verde, criando uma nova classe de biocombustíveis renováveis.

O setor naval, responsável por cerca de 3 a 4% das emissões globais de CO_2 , pode se beneficiar do uso de amônia verde como combustível carbono neutro. Além disso, o dióxido de carbono (CO_2) pode ser convertido em metanol por meio de reação com hidrogênio. O metanol, por sua vez, é utilizado como base para diversos produtos químicos do cotidiano e apresenta excelente capacidade de armazenamento e transporte, assim como a amônia.

O hidrogênio verde desempenha um papel estratégico na transição energética e na descarbonização de setores industriais e de transporte, conforme destacado ao longo deste capítulo. A Figura 6 ilustra de forma gráfica as principais aplicações do hidrogênio verde, enfatizando seu papel como fonte de energia limpa em indústrias químicas, transporte e agricultura. Dessa forma, a combinação do texto com a figura proporciona uma visão mais ampla e detalhada das possibilidades oferecidas pelo hidrogênio verde para a sustentabilidade energética.




Figura 6 – Infográfico ilustrativo das principais aplicações do hidrogênio verde produzido a partir de fontes renováveis. Fonte: (IBERDROLA, 2024)

3.2 IMPORTÂNCIA DO APRENDIZADO DE MÁQUINA E SUAS ABORDAGENS

O aprendizado de máquina é uma área da ciência da computação que integra técnicas matemáticas e estatísticas com algoritmos computacionais. Essa abordagem, fundamentada no conceito de inteligência artificial (IA), é aplicada em contextos onde se busca identificar padrões em conjuntos de variáveis para prever resultados específicos de interesse.

Historicamente, muitos sistemas computacionais na área médica baseavam-se em algoritmos que seguiam regras predefinidas, conhecidos como “sistemas especialistas”. Nesses casos, o desenvolvedor codificava o conhecimento médico em regras já estabelecidas. Em contrapartida, as técnicas de aprendizado de máquina são capazes de lidar com um grande número de variáveis, explorando combinações que permitem prever resultados com maior precisão, frequentemente utilizando grandes volumes de dados, conhecidos como *big data*.

No contexto de *big data*, Doug Laney introduziu, em 2001, o modelo das “3 Vs” para descrever suas principais características: volume significativo, alta velocidade e variedade extensa de informações. Esses atributos demandam novas técnicas de processamento capazes de facilitar descobertas e otimizar processos. O termo *big data* refere-se tanto

a conjuntos de dados tão extensos que ferramentas tradicionais de gerenciamento não conseguem armazenar ou processar de maneira eficiente, quanto às tecnologias desenvolvidas para suportar esse gerenciamento, incluindo infraestruturas de armazenamento e ferramentas especializadas.

O desenvolvimento de um algoritmo de aprendizado de máquina abrange três etapas principais: pré-processamento, treinamento e avaliação do modelo. Na fase inicial, realiza-se a organização do banco de dados, a definição da pergunta de pesquisa e a divisão dos dados em conjuntos de treinamento e teste. O treinamento pode ser supervisionado, quando se utiliza uma amostra de dados com classificações previamente conhecidas, ou não supervisionado, onde o aprendizado ocorre sem classificações preexistentes. Adicionalmente, existe o aprendizado por reforço, no qual o modelo aprende por meio de interações com o ambiente, recebendo feedback em forma de recompensas ou penalidades, com o objetivo de otimizar uma estratégia que maximize a recompensa cumulativa ao longo do tempo (SUTTON; BARTO, 2018). Na etapa de avaliação, o modelo é testado com os dados separados para essa finalidade, gerando os resultados finais. Assim, os algoritmos de aprendizado de máquina aprendem por meio de observações repetidas, estabelecendo padrões que permitem rotular dados e criar modelos que generalizam informações, possibilitando a aplicação a novos dados ainda não analisados (RAJKOMAR; DEAN; KOHANE, 2019).

A principal distinção entre aprendizado supervisionado, não supervisionado e por reforço reside na abordagem utilizada para o treinamento do algoritmo. No aprendizado não supervisionado, o modelo de aprendizado de máquina identifica características dos dados e cria representações sem acesso prévio aos rótulos de cada item. Isso possibilita a descoberta heurística de padrões nos dados, o que pode revelar relações ainda não consideradas (KOHONEN; HONKELA, 2007; SATHYA; ABRAHAM, 2013). Por outro lado, no aprendizado supervisionado, o modelo utiliza dados previamente rotulados, comparando os resultados gerados com os rótulos conhecidos em um processo iterativo, visando minimizar erros. Já no aprendizado por reforço, o algoritmo é projetado para tomar decisões em um ambiente dinâmico, ajustando suas ações com base no feedback recebido a partir de recompensas, o que o torna ideal para problemas que envolvem tomadas de decisões sequenciais, como em jogos, controle de robôs e otimização de processos (SUTTON; BARTO, 2018).

A Tabela 4, adaptada de (PAIXÃO *et al.*, 2022), sintetiza as principais características de cada abordagem de aprendizado, destacando suas vantagens, desvantagens e aplicabilidade prática. A coluna adicional referente ao aprendizado por reforço foi elaborada com base em (SUTTON; BARTO, 2018; RAJKOMAR; DEAN; KOHANE, 2019).

Várias técnicas de aprendizado de máquina têm sido amplamente utilizadas em sistemas de diagnóstico assistido por computador, incluindo rede neural artificial (RNA), regressão logística, árvores de decisão, florestas aleatórias, redes bayesianas, Aprendizagem profunda (*deep learning*) e máquinas de vetor de suporte (*Support Vector Machines* -

	Aprendizado supervisionado	Aprendizado não supervisionado	Aprendizado por reforço
Definição	Algoritmos que aprendem relações entre atributos de entrada e de saída a partir de conjuntos de exemplos rotulados.	Algoritmos que buscam encontrar padrões em agrupamentos de dados com características semelhantes, em busca de categorias e desfechos ainda não identificados ou informados.	Algoritmos que aprendem por meio de interação com o ambiente, recebendo recompensas ou penalidades para otimizar decisões sequenciais.
Vantagens	Análise de múltiplos parâmetros. Solução rápida e automática para questões de grande escala e elevada acurácia.	Menor interferência humana na análise dos dados. Excelente para fontes de dados multimodais ou multidimensionais. Permite identificação de novos desfechos.	Aprendizado contínuo e adaptável a ambientes dinâmicos. Ideal para tomadas de decisão em tempo real.
Desvantagens	Necessidade dos dados serem rotulados, o que para grandes volumes de dados pode ser impraticável. Tendência ao sobreajuste (<i>overfitting</i>) dos dados.	Custo elevado e técnicas complexas. Necessita grande quantidade de dados para elaboração do algoritmo. Interpretação dos resultados pode ser desafiadora.	Requer muitas interações com o ambiente. Treinamento pode ser demorado e computacionalmente caro.
Principais tarefas	Regressão, classificação, modelos prognósticos e análise de sobrevivência.	Redução da dimensionalidade do problema e agrupamento (<i>clustering</i>).	Controle de robôs, otimização de processos e jogos.
Exemplos de algoritmos	Regressão logística, árvores de decisão, máquinas de vetor de suporte (<i>SVM</i>) e redes neurais artificiais.	Análise de componentes principais, agrupamento hierárquico, <i>autoencoders</i> e análise linear de discriminantes.	Q-Learning, Deep Q-Network (DQN), SARSA.

Tabela 4 – Comparação entre aprendizado supervisionado, não supervisionado e por reforço. As colunas de aprendizado supervisionado e não supervisionado foram adaptadas de (PAIXÃO *et al.*, 2022), enquanto a coluna de aprendizado por reforço foi elaborada com base em (SUTTON; BARTO, 2018; RAJKOMAR; DEAN; KOHANE, 2019).

SVM), entre outras (PODGORELEC *et al.*, 2002; SMITH *et al.*, 2019). Algumas dessas abordagens aplicam modelos matemáticos tradicionais para aprender e organizar dados, enquanto outras empregam representações mais abstratas, conhecidas como modelos matemáticos complexos (BARRETO; SOUZA, 2006).

Nesse contexto, a interpretação dos métodos utilizados para gerar resultados de previsão, detecção ou classificação pode ser limitada. Por conta dessa complexidade, muitos desses modelos de aprendizado de máquina são frequentemente referidos como "caixas-pretas", devido à dificuldade de compreender como suas decisões são tomadas.

Uma RNA é um modelo computacional e matemático projetado para simular o funcionamento do cérebro humano. Ela é composta por várias camadas interconectadas, incluindo uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. Essa estrutura é inspirada nas conexões sinápticas entre os neurônios biológicos ((BARRETO; SOUZA, 2006; BIANCHI, 2008; RAJKOMAR; DEAN; KOHANE, 2019).

A rede neural artificial tem sido amplamente empregada em tarefas complexas, como a classificação de dados, reconhecimento de padrões e previsões em diferentes domínios, devido à sua capacidade de aprendizado não linear e de modelagem de dados complexos. conforme pode-se visualizar na Figura 7




Figura 7 – Rede Neural Artificial com uma camada oculta. Fonte: (NASCIMENTO, 2022)

Uma rede neural artificial (RNA) "aprende" por meio das conexões entre suas camadas (entrada, oculta e saída) e dos pesos associados a cada uma delas. Nesse processo, os dados de entrada são apresentados à camada de entrada e transmitidos de uma camada para outra. O processamento matemático ocorre durante essa transmissão, enquanto os pesos das conexões são ajustados com base no erro identificado na camada de saída — isto




Figura 8 – Fases para o desenvolvimento de algoritmos de *machine learning*. Adaptado de (RAJKOMAR; DEAN; KOHANE, 2019)

é, a diferença entre o resultado esperado e o resultado efetivamente obtido. Esse ciclo se repete até que o erro seja minimizado ou até que um número pré-estabelecido de iterações seja alcançado (BARRETO; SOUZA, 2006; AL-SHAYEA, 2011; BENGIO; COURVILLE; VINCENT, 2013).

A aprendizagem profunda se distingue das técnicas tradicionais de aprendizado de máquina por utilizar modelos computacionais mais complexos, que incluem múltiplas camadas de processamento baseadas em redes neurais artificiais. Conforme ilustra a Figura 8 embora a aprendizagem profunda opere de maneira semelhante às RNA, ele incorpora um número maior de camadas, resultando em um número significativamente maior de conexões sinápticas. Cada camada gera uma representação dos dados recebidos da camada anterior, permitindo o aprendizado de características hierárquicas. Além disso, os algoritmos de aprendizagem profunda podem ser aplicados tanto de forma supervisionada quanto não supervisionada (MIOTTO *et al.*, 2018; BENGIO, 2009).

No contexto de *big data*, os *autoencoders* surgem como uma classe específica de redes neurais projetadas para reduzir a dimensionalidade dos dados. Esses algoritmos empregam modelos matemáticos de elevado nível de abstração para criar um novo conjunto de dados que preserva as características mais relevantes dos dados originais. A principal diferença entre uma rede neural tradicional e um *autoencoder* é que este último utiliza dados não

rotulados durante sua fase de treinamento (RAGHAVENDRA *et al.*, 2019).

Outro algoritmo amplamente utilizado é a árvore de decisão, que é especialmente eficaz em conjuntos de dados relativamente pequenos. Este método é baseado em uma sequência de perguntas do tipo "sim/não", as quais classificam os dados em diferentes categorias. O modelo estatístico gerado pela árvore de decisão pode ser usado tanto para classificação quanto para predição. Cada pergunta gera possíveis respostas que se ramificam em novas opções, repetindo o processo até alcançar um resultado final. Entre as principais vantagens do algoritmo de árvore de decisão estão sua simplicidade e facilidade de interpretação (PODGORELEC *et al.*, 2002; GOODMAN *et al.*, 2016).

As florestas aleatórias são uma extensão das árvores de decisão e são amplamente utilizadas para resolver problemas de classificação e regressão. Este método combina diversas árvores de decisão, cada uma treinada de forma independente, resultando em um modelo robusto. Entre suas principais características destacam-se: uma teoria simples, rapidez na análise dos dados, robustez diante de ruídos excessivos e a capacidade de compensar automaticamente amostras tendenciosas (PANG *et al.*, 2004).

A Máquina de Vetores de Suporte (*Support Vector Machine* - SVM) é um método de aprendizado supervisionado amplamente utilizado em bioinformática. Este algoritmo baseia-se na minimização de erros e utiliza conceitos da teoria estatística do aprendizado e da otimização. Além de ser eficaz na classificação binária, o SVM também pode ser aplicado à regressão de dados contínuos, conhecida como regressão do vetor de suporte. Na bioinformática, Chen e Kurgan (2007) desenvolveram o PFRES, um método baseado em SVM para reconhecimento de dobras proteicas, demonstrando a eficácia do SVM na classificação de estruturas proteicas complexas. Já Krittanawong (2020) destacaram que os SVM apresentaram alta precisão na predição de acidentes vasculares cerebrais, com uma área sob a curva (AUC) de 0,92, indicando desempenho robusto. Esses estudos reforçam a versatilidade e eficiência dos SVM em diversas aplicações de alta dimensionalidade, equilibrando complexidade e erro (CHEN; KURGAN, 2007; KRITTANAWONG, 2020).

As redes bayesianas são outra técnica que é frequentemente aplicada na medicina. Elas utilizam métodos estatísticos baseados na teoria bayesiana para representar crenças subjetivas de especialistas em uma estrutura probabilística, possibilitando a inferência de relações causais e a tomada de decisão sob incerteza.

Cada um desses algoritmos adota técnicas distintas para aprender a partir de observações e realizar o mapeamento entre conjuntos de preditores e resultados esperados. O objetivo final é generalizar as informações para que novas entradas, não previamente analisadas pelo modelo, possam ser processadas com precisão (SATHYA; ABRAHAM, 2013).

3.3 EFEITOS DA UTILIZAÇÃO DE GÊMEOS DIGITAIS E BENEFÍCIOS DO APRENDIZADO DE MÁQUINA NO APERFEIÇOAMENTO DE SISTEMAS

Os gêmeos digitais (*digital twins*) são representações virtuais dinâmicas de sistemas físicos, criadas a partir da integração de dados em tempo real coletados por sensores ou tecnologias de *Big Data*. Esses dados são processados por ferramentas avançadas, como inteligência artificial (IA), computação em nuvem (*Cloud Computing*) e aprendizado de máquina (*Machine Learning*). Dessa forma, os gêmeos digitais possuem a capacidade de "sentir", ao coletar informações em tempo real por sensores ou *Big Data*; "analisar" e "pensar", processando os dados com inteligência artificial e aprendizado de máquina; e "agir", propondo otimizações e resolvendo incidentes com base nas previsões geradas.

A Figura 9 apresenta a arquitetura geral da tecnologia de gêmeos digitais.




Figura 9 – Estrutura geral do uso da tecnologia Gêmeo Digital. Fonte: Santos (2023).

3.3.1 Vantagens dos Gêmeos Digitais

Desde sua concepção, os gêmeos digitais consolidaram-se como uma das tecnologias mais promissoras no contexto da Indústria 4.0. Em 2018, a consultoria Gartner classificou-os entre as dez principais tecnologias emergentes, corroborando a visão de outras organizações, como a Deloitte (2017) e KPMG International (2017), que enfatizaram sua capacidade de transformar processos industriais em relatórios dedicados à integração de sistemas digitais.

Entre as principais vantagens dessa tecnologia, destacam-se a previsão de falhas operacionais e a automação na resolução de incidentes. Por meio da manutenção preditiva,

os gêmeos digitais analisam dados em tempo real, promovendo maior eficiência e redução de custos operacionais. Estudos da consultoria IDC indicam que empresas que implementaram gêmeos digitais em 2018 observaram melhorias de até 30% em processos essenciais, além de ganhos substanciais em tempo e qualidade nas operações.

Adicionalmente, a implementação de gêmeos digitais apoia a inovação, permitindo simulações detalhadas e cenários de teste, essenciais para o desenvolvimento de novos produtos e processos. Esses modelos também contribuem significativamente para a sustentabilidade ao reduzir desperdícios de recursos e energia, alinhando-se às demandas globais por operações mais responsáveis e ambientalmente conscientes.

A Figura 10 ilustra a integração entre sistemas físicos e seus modelos digitais.




Figura 10 – Exemplo de combinação entre sistema físico (à direita) e modelo virtual simulado (à esquerda), incluindo um inversor conectado à rede e controlado por um microcontrolador F28335. Fonte: (BUSARELLO, 2024).

Na eletrônica de potência, por exemplo, os gêmeos digitais desempenham um papel crucial ao permitir o monitoramento de parâmetros críticos em tempo real. Isso inclui prever falhas decorrentes do envelhecimento térmico e ajustar comportamentos operacionais para melhorar a eficiência energética e a longevidade dos dispositivos (KUPRAT *et al.*, 2024).

3.3.2 Desafios dos Gêmeos Digitais

Apesar das inúmeras vantagens, a implementação de gêmeos digitais apresenta desafios significativos. Um dos maiores obstáculos está na integração contínua entre os sistemas físico e digital, especialmente quando mudanças rápidas no sistema físico exigem

adaptações no modelo virtual em tempo real. Essa sincronização demanda tecnologias avançadas, como *real-time simulation* (RTS), Internet das Coisas (IoT) e aprendizado de máquina, além de infraestrutura robusta e investimentos elevados (BAI *et al.*, 2024).

Outro desafio é o ajuste automático de modelos virtuais, que muitas vezes enfrenta incertezas operacionais, especialmente em sistemas altamente complexos. Métodos como filtros de Kalman estendidos e algoritmos de otimização, como o enxame de partículas, têm sido utilizados para minimizar essas incertezas, embora ainda sejam necessários avanços para alcançar maior confiabilidade e eficiência.

Por fim, questões relacionadas à segurança e privacidade dos dados também se destacam como barreiras à adoção em larga escala, exigindo abordagens cada vez mais inovadoras para proteger as informações sensíveis envolvidas na operação dos gêmeos digitais.

3.3.3 Arquiteturas de Gêmeos Digitais

Os gêmeos digitais podem ser construídos com diferentes arquiteturas, dependendo das aplicações específicas e dos requisitos do sistema. Essas arquiteturas geralmente incorporam componentes físicos e virtuais integrados por sistemas de comunicação robustos, possibilitando a sincronização bidirecional entre os domínios físico e digital. A Figura 11A apresenta um exemplo genérico dessas interações, destacando o fluxo de dados entre sistemas físicos (SF), sistemas de sincronização (SS), sistemas de dados (SD) e sistemas virtuais (SV).




Figura 11 – Arquitetura geral do Gêmeo Digital: interação entre sistemas físicos, dados e modelos virtuais. Fonte: adaptado de (SANTOS, 2023).

A seguir, são apresentados modelos de arquitetura destinados à implementação de gêmeos digitais.

- **Modelo de 8 Dimensões:** Desenvolvido por Stark, Freseman e Lindow (2019), esse modelo organiza o gêmeo digital em dimensões relacionadas ao contexto do produto (como integração e ciclo de vida) e ao comportamento (incluindo capacidades de simulação e interação). Ele serve como referência para definir o escopo e as funcionalidades do sistema. A Figura 12 ilustra essa abordagem.

Contexto e Ambiente				Comportamento e Capacidade			
Ciclo de Vida do Produto	Amplitude de Integração	Modo de Conexão	Frequência de Atualização	Inteligência do Sistema Ciber-Físico	Capacidade de Simulação	Riqueza do Modelo Digital	Interação Humana
1- Início da Vida (BoL)	1- Produto/Máquina	1- Unidirecional	1- Cada Semana	1- Ação Humana	1- Estático	1- Geometria, Cinemática	1- Dispositivos Inteligentes
2- Meio da Vida (MoL)	2- Sistema de Produção/Próximo da Produção		2- Cada Dia	2- Automatizado	2- Dinâmico		2- VR/AR
	3- Ambiente de Produção	2- Bidirecional	3- Cada Hora	3- Parcialmente Autônomo	3- Ad-Hoc	2- Controle do Comportamento	
3- Fim da Vida (EoL)	4- Mundo (Interação de todos os objetos)	3- Automático	4- Tempo Real	4- Autônomo	4- Perspectiva do Futuro	3- Comportamento Físico	3- Híbrido

Figura 12 – Modelo de Gêmeo Digital de 8 Dimensões. Fonte: Nascimento (2022).

- **Modelo de Rabelo et al.:** Esta arquitetura, proposta por Rabelo, Magalhães e Cabral (2023), foi desenvolvida para atender aos desafios de integração de Sistemas Ciberfísicos (SCFs) em ambientes industriais reais. Ela adota uma abordagem modular que considera os requisitos de interoperabilidade, armazenamento de dados, digitalização de modelos e visualização gráfica. Baseia-se no modelo ISA-95, que organiza os processos em níveis, e propõe a encapsulação de sistemas industriais legados para transformá-los em provedores de serviços na arquitetura geral. A Figura 13 apresenta a estrutura proposta.




Figura 13 – Arquitetura de referência de Gêmeo Digital proposta por Rabelo et al. Fonte: Rabelo, Magalhães e Cabral (2023).

- **Camadas Funcionais:** Bevilacqua et al. (2020) propuseram uma arquitetura composta por quatro camadas principais: o espaço físico do processo industrial, o sistema de comunicação, o gêmeo digital propriamente dito e o espaço do usuário. Cada camada desempenha funções específicas, desde a coleta de dados físicos até a simulação e interação com usuários finais. A Figura 14 apresenta os componentes dessa arquitetura.




Figura 14 – Arquitetura de Gêmeo Digital com camadas funcionais. Fonte: Nascimento (2022).

- **Arquitetura de Mapeamento Bidirecional:** Conforme Zheng, Yang e Cheng (2019), esta arquitetura conecta o espaço físico e virtual por meio de uma camada de processamento de informações que permite a sincronização e o mapeamento de dados em tempo real. A Figura 15 destaca os módulos que compõem essa estrutura.

Esses modelos de arquitetura destacam a flexibilidade e a adaptabilidade dos gêmeos digitais, permitindo que sejam ajustados a diferentes setores e desafios operacionais.




Figura 15 – Arquitetura de mapeamento bidirecional entre domínios físico e virtual. Fonte: Zheng, Yang e Cheng (2019).

3.3.4 Aplicações dos Gêmeos Digitais

Os gêmeos digitais possuem uma vasta gama de aplicações na Indústria 4.0 e em áreas correlatas. Por meio da criação de réplicas digitais de produtos, sistemas produtivos e ambientes de operação, empresas podem prever com precisão eventos futuros no mundo físico. Engenheiros utilizam essa tecnologia para corrigir falhas e desenvolver versões mais confiáveis de produtos, baseando-se no histórico detalhado de modelos anteriores.

- **Sistemas de Potência e Eletrônica:** Monitoramento de parâmetros térmicos e elétricos em dispositivos, como inversores e módulos de potência, com ajustes em tempo real para reduzir estresse termomecânico e aumentar a eficiência energética (SANTOS, 2023). Esses sistemas também são usados para projetar e validar estratégias de controle antes da implementação no ambiente físico (NASCIMENTO, 2022).

- **Manutenção Preditiva em Indústrias:** Redução do tempo de inatividade de máquinas ao prever falhas com base em dados históricos e em tempo real (NASCIMENTO, 2022).
- **Gerenciamento de Recursos Hídricos:** Monitoramento de plantas hidráulicas, ajustando operações para prevenir danos e otimizar o consumo energético (NASCIMENTO, 2022).
- **Apoio ao Desenvolvimento de Produtos:** Testes virtuais de múltiplos cenários e validação de decisões de engenharia, reduzindo custos e acelerando o desenvolvimento (RABELO; MAGALHÃES; CABRAL, 2023).

A Tabela 5 compara as características de simulações tradicionais e a tecnologia de gêmeos digitais, destacando as vantagens desta última.

Característica	Simulação tradicional	Simulação como Gêmeo Digital
Coleta de dados	Manual	Automática
Atualização do modelo	Manual	Automática e periódica
Percepção de tempo	Análises pontuais	Análises em tempo real
Escopo de atuação	Limitado	Amplo e flexível
Objetivos principais	Análises específicas	Apoio à tomada de decisões
Complexidade	Necessita de especialistas	Modelos amigáveis
Integração física	Não aplicável	Total ou parcial
Autonomia	Não autônoma	Autônoma ou semiautônoma

Tabela 5 – Simulação tradicional vs. Gêmeo Digital. Fonte: Santos (2023).

3.3.5 Papel do Aprendizado de Máquina no Aperfeiçoamento de Gêmeos Digitais

O aprendizado de máquina potencializa as capacidades dos gêmeos digitais, permitindo sua adaptação a condições operacionais complexas e oferecendo soluções automatizadas para desafios específicos da indústria. Ao processar grandes volumes de dados em tempo real, o aprendizado de máquina identifica padrões e gera insights acionáveis, superando as limitações dos métodos tradicionais de análise (SANTOS, 2023).

Por exemplo, Santos (2023) propõem uma abordagem que integra algoritmos de aprendizado supervisionado, como o *K-Nearest Neighbors* (K-NN), com cartas de controle para monitorar a consistência de modelos de gêmeos digitais. Essa combinação permite identificar discrepâncias entre o modelo virtual e o sistema físico, assegurando a precisão contínua do gêmeo digital.

A Figura 16 apresenta o fluxo de uma abordagem baseada em aprendizado de máquina para tomada de decisão, evidenciando a interação entre o algoritmo de aprendizado, a base de conhecimento e o mecanismo de decisão para garantir resultados confiáveis.




Figura 16 – Fluxo de uma abordagem baseada em aprendizado de máquina para tomada de decisão, destacando a integração entre modelo de aprendizado, base de conhecimento e decisão final. Fonte: Santos (2023)

Adicionalmente, algoritmos avançados, como redes neurais artificiais, têm sido aplicados para:

- **Deteção de anomalias em tempo real:** Monitoramento contínuo de dados para identificar variações inesperadas nos sistemas físicos, como alterações de pressão ou falhas mecânicas (NASCIMENTO, 2022).
- **Ajuste dinâmico de parâmetros:** Aprendizado contínuo com base em novas condições operacionais, ajustando automaticamente configurações do sistema físico (SANTOS, 2023).
- **Análise híbrida:** Integração de aprendizado de máquina com técnicas estatísticas, como cartas de controle, para melhorar a confiabilidade do sistema (NASCIMENTO, 2022).

Essas aplicações demonstram que o aprendizado de máquina não apenas potencializa as capacidades analíticas dos gêmeos digitais, mas também transforma sua abordagem de reativa para proativa, antecipando problemas e propondo soluções antes mesmo que eles impactem os sistemas operacionais.

3.4 A UTILIZAÇÃO DO GÊMEO DIGITAL COM APRENDIZADO DE MÁQUINA PARA A OTIMIZAÇÃO DA PRODUÇÃO, ARMAZENAMENTO E CONVERSÃO DE HIDROGÊNIO VERDE EM ENERGIA

3.4.1 Gêmeo Digital

No contexto da produção de hidrogênio, o gêmeo digital pode representar todos os componentes do processo, desde a eletrólise até o armazenamento e a conversão em energia elétrica.

3.4.1.1 Componentes do Gêmeo Digital

Os principais componentes do gêmeo digital incluem:

- **Sensores:** Coletam dados em tempo real sobre variáveis como temperatura, pressão, fluxo e qualidade do hidrogênio.
- **Modelos Computacionais:** Simulam o comportamento do sistema com base nos dados coletados, permitindo análises preditivas.
- **Interface de Visualização:** Facilita a interação dos operadores com o gêmeo digital, auxiliando na tomada de decisões.

3.4.2 Integração com *Machine Learning*

O *machine learning*, uma subárea da inteligência artificial, utiliza algoritmos para identificar padrões e realizar previsões com base em dados históricos. A integração do *machine learning* com o gêmeo digital traz benefícios nas etapas de produção, armazenamento e conversão em energia.

3.4.2.1 Otimização da Produção

- **Análise Preditiva:** Modelos de aprendizado de máquina podem prever a demanda de hidrogênio, ajustando automaticamente as configurações do eletrolisador, como corrente elétrica e temperatura, para maximizar a eficiência.
- **Deteção de Anomalias:** Algoritmos identificam padrões operacionais normais e alertam sobre desvios, permitindo intervenções rápidas antes que os problemas se agravem.

3.4.2.2 Armazenamento Eficiente

- **Gestão de Estoque:** O gêmeo digital simula diferentes cenários de armazenamento, enquanto o *machine learning* analisa dados históricos para prever a demanda futura, otimizando o uso do espaço e reduzindo custos operacionais.

- **Segurança:** Algoritmos preveem possíveis falhas ou vazamentos, utilizando dados de sensores para melhorar a segurança dos sistemas de armazenamento.

3.4.2.3 Conversão em Energia

- **Eficiência da Célula de Combustível:** O gêmeo digital monitora o desempenho da célula de combustível em tempo real, enquanto algoritmos ajustam os parâmetros operacionais para maximizar a eficiência energética.
- **Previsão de Manutenção:** Dados históricos permitem prever a necessidade de manutenção das células de combustível, evitando paradas inesperadas e aumentando a disponibilidade do sistema.

3.4.3 Sensores e Controladores

Os sensores desempenham um papel essencial no monitoramento e controle dos processos de eletrólise, armazenamento e conversão de hidrogênio. Já os controladores automatizam os processos, garantindo eficiência e segurança.

3.4.3.1 Sensores

3.4.3.1.1 Na Eletrólise

- **Sensor de Fluxo de Água:** Monitora a entrada de água, essencial para o funcionamento adequado do eletrolisador.
- **Sensor de Pressão:** Garante que a pressão interna esteja dentro dos limites operacionais, evitando falhas.
- **Sensor de Temperatura:** Controla o calor gerado durante a eletrólise, prevenindo superaquecimento.
- **Sensor de Corrente Elétrica:** Mede o consumo de energia, permitindo ajustes na operação para reduzir custos.
- **Sensores de Gás (H_2 e O_2):** Avaliam a concentração e a pureza dos gases produzidos.

3.4.3.1.2 No Armazenamento

- **Sensor de Pressão de Hidrogênio:** Monitora a pressão nos tanques, evitando explosões.
- **Sensor de Vazamento:** Detecta vazamentos de hidrogênio, garantindo a segurança.
- **Sensor de Nível:** Mede a quantidade de gás armazenado, assegurando a capacidade operacional segura dos tanques.

3.4.3.1.3 Na Conversão em Energia

- **Sensor de Fluxo de Hidrogênio:** Monitora o consumo de hidrogênio nas células de combustível.
- **Sensores de Tensão e Corrente:** Avaliam a geração de energia, permitindo ajustes para maximizar a eficiência.
- **Sensor de Umidade:** Mantém os níveis ideais de umidade nas células de combustível, prevenindo falhas.

3.4.4 Controladores

- **Controlador de Potência:** Regula a energia fornecida ao eletrolisador, garantindo sua operação na faixa ideal.
- **PLC (Controlador Lógico Programável):** Integra dados dos sensores e automatiza o controle do processo.
- **Sistema SCADA:** Permite supervisão e controle remoto, facilitando a gestão em tempo real dos processos.

3.4.5 Considerações de Segurança

A segurança é uma prioridade em sistemas que lidam com hidrogênio. As principais medidas incluem:

- **Redundância em Sensores Críticos:** Sensores de pressão e vazamento devem ser redundantes para garantir a segurança operacional.
- **Protocolos de Segurança:** Normas como SIL (*Safety Integrity Level* - Nível de Integridade de Segurança) asseguram que os sistemas atendam a padrões rigorosos.
- **Testes Regulares:** A validação contínua de sensores e atuadores mantém a precisão e eficiência do sistema.

3.4.6 Possíveis controladores e Sensores para Protótipo

A prototipagem de sistemas baseados em hidrogênio verde é geralmente feita tendo em mente a acessibilidade e a facilidade de programação e, portanto, Arduino e ESP32 são preferidos. Esses microcontroladores encontram amplas aplicações em projetos de automação devido ao seu baixo custo, versatilidade e disponibilidade de uma ampla gama de bibliotecas para a fácil integração de diferentes sensores.

No caso do Arduino, ele poderia ajudar, respectivamente, com sensores básicos para monitorar níveis de pressão no eletrolisador, como sensores de pressão (MPX5700AP) e sensores de temperatura baseados em termistor (por exemplo, NTC10k), juntamente

com sensores simples de fluxo de água (por exemplo, YF-S201). Além de ser adequado para essas mesmas aplicações, o ESP32 possui conectividade Wi-Fi e Bluetooth, o que permite comunicação em tempo real com plataformas de monitoramento e controle remoto. Por exemplo, no ESP32 podem ser integrados sensores como aqueles para detecção de hidrogênio (MQ-8) e sensores elétricos de corrente (ACS712) medindo a energia consumida pelo sistema.

3.4.7 Possíveis Controladores e Sensores para Projeto Final

Em projetos finais de maior escala, voltados para aplicações industriais, os controladores utilizados devem ser mais robustos e capazes de lidar com um grande volume de dados em tempo real, além de operar de forma confiável em ambientes desafiadores. Nesse contexto, PLCs (Controladores Lógicos Programáveis) de marcas consolidadas, como Siemens (linha S7) e Rockwell Automation (Allen-Bradley), são ideais para integrar sensores industriais de alta precisão. Esses PLCs suportam protocolos como Profibus, Profinet e EtherNet/IP, permitindo a conexão com sensores de pressão piezoelétricos (ex.: ESI Pressure Sensors), sensores de vazamento por ultrassom (como o Ultrasonic Gas Leak Detector) e sensores de temperatura PT1000. Esses dispositivos fornecem dados confiáveis, mesmo em ambientes com condições extremas de temperatura ou pressão, sendo amplamente utilizados em sistemas industriais.

Além desses, os PLCs da Typhoon HIL representam uma solução avançada para sistemas que requerem validação de modelos por meio de simulação em tempo real (*Hardware-in-the-Loop*). Esses controladores são ideais para projetos onde a análise de desempenho e segurança em condições reais é essencial antes da implementação definitiva. A compatibilidade com protocolos como Modbus e OPC UA, combinada com a capacidade de integração direta com ferramentas de simulação, permite sua aplicação em processos complexos. Eles podem ser integrados a sensores de alta precisão, como espectrômetros de massa para análise de gases (H_2 e O_2), sensores ultrassônicos de nível (VegaPuls 64) e sensores de corrente LEM DHAB, garantindo monitoramento detalhado e otimização do processo.

Para sistemas que requerem maior flexibilidade e conectividade, controladores industriais baseados em Raspberry Pi configurados com sistemas operacionais em tempo real (RTOS) também podem ser utilizados. Esses controladores são particularmente vantajosos em ambientes que necessitam de alta conectividade e automação personalizada, complementando a robustez dos PLCs tradicionais em projetos de grande escala.

A integração de sensores, controladores e tecnologias avançadas, como o gêmeo digital e o *machine learning*, é fundamental para a eficiência, segurança e sustentabilidade dos sistemas de hidrogênio verde. Essa abordagem promove não apenas a otimização dos processos, mas também contribui significativamente para uma transição energética mais limpa e sustentável.

3.5 OS BENEFÍCIOS DA UNIÃO DOS GÊMEOS DIGITAIS COM MACHINE LEARNING PARA A FABRICAÇÃO DO HIDROGÊNIO VERDE

A integração de tecnologias avançadas, como gêmeos digitais e aprendizado de máquina, oferece oportunidades significativas para aprimorar o processo de produção de hidrogênio verde. Essa abordagem não apenas aumenta a eficiência e a segurança, mas também contribui para a sustentabilidade ambiental.

Na produção de hidrogênio, um gêmeo digital pode modelar todo o processo, desde a eletrólise até o armazenamento e a conversão em energia (TAO *et al.*, 2018). Essa tecnologia possibilita uma visualização clara do funcionamento do sistema, permitindo ajustes dinâmicos com base em dados obtidos por sensores.

O aprendizado de máquina, uma subárea da inteligência artificial, utiliza algoritmos para analisar grandes volumes de dados, identificando padrões e propondo ajustes específicos (BISHOP, 2006). Essa capacidade de aprendizagem a partir de dados históricos e em tempo real é particularmente valiosa na fabricação do hidrogênio verde, onde a eficiência operacional e a segurança são cruciais. Segundo (BISHOP, 2006), a integração dessas tecnologias foca na otimização da eficiência operacional e na implementação de manutenção preditiva.

A união de gêmeos digitais com aprendizado de máquina permite melhorar a eficiência dos processos de produção de hidrogênio. Os modelos de aprendizado de máquina podem prever a demanda de hidrogênio e ajustar automaticamente as configurações do eletrolisador, como a corrente elétrica e a pressão, garantindo a operação em condições ideais (KUMAR, A. *et al.*, 2020). Isso resulta em um aumento significativo na produção de hidrogênio e na redução do consumo de energia.

No que se refere à manutenção preditiva, a capacidade de monitorar e analisar dados em tempo real possibilita a implementação de estratégias eficazes. O aprendizado de máquina pode identificar padrões que precedem falhas técnicas, permitindo que as equipes de manutenção intervenham antes que problemas maiores ocorram. Essa abordagem não apenas reduz o tempo de inatividade, mas também diminui os custos operacionais associados à manutenção reativa (HUANG *et al.*, 2018).

Em termos de aprimoramento da segurança, a integração de gêmeos digitais com aprendizado de máquina reforça a confiabilidade dos sistemas de produção de hidrogênio. Os algoritmos podem monitorar dados de sensores em busca de anomalias, como variações de pressão ou temperatura, que podem indicar riscos potenciais, como vazamentos ou falhas nos equipamentos. Ao detectar esses problemas precocemente, as operações podem ser ajustadas ou interrompidas para evitar acidentes (HUANG *et al.*, 2018).

Além disso, a otimização dos processos de fabricação não apenas melhora a eficiência, mas também contribui para a sustentabilidade ambiental. A redução do consumo de energia e a minimização de desperdícios são benefícios diretos da integração de gêmeos digitais e aprendizado de máquina. Isso resulta em uma produção de hidrogênio

verde mais econômica e ambientalmente amigável, alinhando-se com as metas globais de sustentabilidade (MOUSSA *et al.*, 2020).

Por fim, a flexibilidade e a escalabilidade oferecidas pelos gêmeos digitais permitem que as operações de produção se adaptem rapidamente às mudanças na demanda ou nas condições do mercado. A integração com aprendizado de máquina facilita a análise de grandes volumes de dados, o que é essencial para escalar a produção de hidrogênio verde em resposta à crescente demanda global por soluções de energia limpa (KHAN *et al.*, 2021).

Dessa forma, a integração de gêmeos digitais com aprendizado de máquina representa um avanço significativo na fabricação de hidrogênio verde. Essa união não apenas melhora a eficiência e a segurança dos processos, mas também contribui para a sustentabilidade e a viabilidade econômica da produção de hidrogênio como uma fonte de energia renovável. À medida que as tecnologias avançam, espera-se que essa abordagem se torne um padrão na indústria, impulsionando a transição para uma economia de baixo carbono.

Tudo isso seria de grande ajuda para melhorar a eficácia da produção de hidrogênio verde e não apenas a segurança, mas também a segurança ambiental.

Para a produção de hidrogênio, todo o processo de eletrólise para armazenamento de energia e conversão pode ser modelado usando um gêmeo digital. Ele permite uma representação explícita de como um determinado sistema opera, permitindo modificações "dinâmicas" baseadas em sensores.

A inteligência artificial abrange vários campos, um dos quais é o subcampo aprendizado de máquina, que envolve o uso de algoritmos para analisar padrões em grandes volumes de dados e recomendar cursos de ação apropriados (BISHOP, 2006). Essa capacidade de aprender com dados históricos e em tempo real é fundamental na fabricação de hidrogênio verde devido à eficiência operacional e à segurança que são tudo. A integração dessas tecnologias tem como (BISHOP, 2006) uma concentração na otimização da eficiência operacional e na implementação da manutenção preditiva.

Portanto, gêmeos digitais combinados com aprendizado de máquina contribuiriam muito para otimizar o processo de produção de hidrogênio. Os modelos de aprendizado de máquina preveem a necessidade de hidrogênio e podem ajustar automaticamente a condição do eletrolisador, ou seja, a corrente elétrica, pressão, etc., para uma operação suave, conforme recomendado por Kumar et al. (KUMAR, A. *et al.*, 2020). Isso leva a um aumento substancial na produção de hidrogênio e reduz o consumo de energia.

A estratégia eficiente é a intervenção oportuna do pessoal de manutenção e retificação da falha antes que ela leve a problemas maiores. Eles podem identificar padrões de falhas técnicas pouco antes de sua ocorrência devido aos recursos de aprendizado de máquina e aconselhar as equipes de manutenção a intervir logo antes que tais problemas surjam. Em vez de reduzir o tempo de inatividade, ele reduz os custos operacionais que continuam aumentando com estratégias de manutenção reativas.

A confiabilidade dos sistemas de produção de hidrogênio seria ainda mais aprimorada quando a segurança fosse aprimorada na integração do aprendizado de máquina com gêmeos digitais. Um algoritmo poderia observar os dados do sensor, como por exemplo pressão ou temperatura, e suas variações como indicadores de possíveis riscos, como vazamento ou falha do equipamento. Caso tais irregularidades sejam encontradas, ações oportunas podem ser tomadas, ou seja, a operação pode ser interrompida para evitar um acidente (HUANG *et al.*, 2018).

Assim, a otimização de processos não só melhora a eficiência da operação, mas também tem uma palavra a dizer na sustentabilidade ambiental, uma vez que usar gêmeos digitais e aprendizado de máquina diretamente pode reduzir o consumo de energia e a geração de resíduos, tornando a produção de hidrogênio verde mais econômica e amigável ao meio ambiente. Isso está em linha com as metas globais de sustentabilidade (MOUSSA *et al.*, 2020).

A flexibilidade e a escalabilidade associadas aos gêmeos digitais permitem que a operação de produção responda e se adapte rapidamente a quaisquer mudanças na demanda ou nas condições de mercado. Ela permite o fornecimento de escala com aprendizado de máquina auxiliando na análise de dados enormes que será um requisito essencial na escala da produção de hidrogênio verde em resposta à crescente demanda por soluções de energia limpa globalmente (KHAN *et al.*, 2021).

Assim, a fusão de gêmeos digitais de aprendizado de máquina conota um avanço na fabricação de hidrogênio verde. A fusão não só melhora a segurança e a eficiência do processo, mas também empresta uma estratégia sustentável e economicamente viável para a produção de hidrogênio como uma fonte renovável de energia. A tecnologia futura tornará este método uma escolha automática para mudar para formas econômicas de baixo carbono.

4 SÍNTESE E TENDÊNCIAS

O potencial de um gêmeo digital alimentado por dados e integrado com aprendizado de máquina em qualquer estágio da cadeia de produção de hidrogênio verde é transformador. A importância está na possibilidade de modelar, prever e otimizar processos complexos, incluindo tanto a produção de hidrogênio por eletrólise quanto etapas de armazenamento e conversão de energia.

O futuro contará sobre validação experimental em uma configuração de laboratório real. Tanto dessa perspectiva quanto os dados são capturados em tempo real por sensores para usar gêmeos digitais para desenvolver representações virtuais aprofundadas de sistemas de produção. Monitorar variáveis críticas de pressão, temperatura e fluxo dessa maneira para ajustes dinâmicos de parâmetros operacionais será uma garantia de eficiência energética e sustentabilidade.

Outras etapas exigiriam a aplicação de diferentes metodologias de aprendizado de máquina, ou seja, redes neurais e algoritmos preditivos para a identificação de padrões com base em dados obtidos por meio do monitoramento e ajustes automatizados em processos de produção. Com isso, estudos avançados de controle, como observadores de estado, juntamente com controle preditivo, podem ser aplicados para melhorar o desempenho de sistemas de eletrólise com mais estabilidade nas operações e redução de custos.

Uma oportunidade atraente é usar sensores especializados e desenvolver modelos preditivos para implementar manutenção preditiva em um nível granular, o que permite a antecipação de falhas para estender a vida útil de peças críticas. Pode garantir mais confiabilidade e segurança. A outra são os avanços alcançados no domínio do "digital thread" de acordo com Deloitte (2017) que retrata a integração real de dados durante todo o ciclo de vida do produto, do design ao uso, com vistas a criar um fluxo contínuo de informações para melhor eficiência.

A integração dos avanços discutidos anteriormente com as informações no cenário global do hidrogênio verde também é necessário para compreender os desenvolvimentos futuros. A demanda global esmagadoramente crescente por hidrogênio, conforme descrito no relatório da Agência Internacional de Energia, e investimentos massivos, por exemplo, pela Arábia Saudita e pelo Brasil, pintam um quadro favorável para a expansão de tecnologias que produzem hidrogênio verde de mais de uma maneira. Esses investimentos complementam a demanda por soluções em eficiência e direção — como a necessidade de produção econômica e ambientalmente sustentável, que pode ser habilitada por meios como gêmeos digitais e aprendizado de máquina neste aspecto específico da cadeia de valor.

Por outro lado, um dos pontos positivos decorrentes disso é o fator ambiental. Como ele usa aprendizado de máquina, ele pode reduzir o uso de energia no processo de eletrólise e também os resíduos que ele produz. Além disso, como os sistemas podem ser

monitorados em tempo real, será possível fazer ajustes muito precisos, bem como reduzir as emissões, o que torna a geração de hidrogênio verde muito mais próxima das metas de descarbonização que foram definidas globalmente. Esta é, portanto, uma resposta direta ao chamado ambiental e de sustentabilidade, garantindo que haja uma transição para uma economia de baixo carbono.

Na tendência futura, o desenvolvimento de um gêmeo digital com aprendizado de máquina apoiaria o desenvolvimento de uma economia de baixo carbono. Quando novas implementações de práticas industriais surgirem para a integração de inteligência artificial e a Internet das Coisas, a escalabilidade e a flexibilidade na produção de hidrogênio verde serão promissoras. Este trabalho pode ser a base para futuros esforços experimentais e desenvolvimentos tecnológicos nesta área.

5 CONCLUSÃO

Por meio de revisão da literatura, este trabalho discute o potencial de transformação do acoplamento de gêmeos digitais com aprendizado de máquina na cadeia de produção de hidrogênio verde. Esta tecnologia é relevante porque pode executar, emular e otimizar processos complicados relacionados à extração e uso de energia do hidrogênio. Ela abrange estágios da eletrólise até a conversão e armazenamento de hidrogênio em energia.

O hidrogênio é frequentemente chamado de "combustível do futuro", pois é abundante e disponível em todo o planeta. Como um elemento de emissão zero, é abundante em uma molécula de água e, portanto, produzido com fontes renováveis de energia. Armazenamento de energia eficaz para diferentes aplicações.

Dadas as exigências da descarbonização da economia global, o planejamento de importância para o hidrogênio no futuro próximo é muito significativo. Dada a urgência vital de ter transições energéticas bem-sucedidas e mitigação das mudanças climáticas, os combustíveis fósseis exigem substituições, sendo o primeiro a escolha mais promissora. O hidrogênio é o transportador mais promissor para essa energia, dada sua produção por meio da eletrólise da água com eletricidade somente de fontes renováveis, como o sol e o vento, com escopo de emissão zero. A divisão de moléculas de água para portadores de energia abre espaço para a produção limpa e sustentável de combustível energético, abrindo espaço para a sustentabilidade nas cadeias de fornecimento de energia.

A produção sustentável de hidrogênio tem a capacidade de reduzir massivamente as emissões de CO_2 , particularmente nos setores como a indústria e de transporte onde a eficiência energética mais a aplicação direta de eletricidade renovável são inadequadas. É por isso que o hidrogênio é um dos mais importantes transportadores de energia para o futuro.

Além de suas vantagens comparativas, pois possui amplos recursos naturais renováveis para produzir hidrogênio verde, um dos maiores desafios é levantar os recursos financeiros necessários para colocá-lo em prática. No entanto, com planos diretores adequados e incentivos adequados do setor público, como o plano de incentivo de R\$ 18,3 bilhões aprovado pelo Senado em setembro de 2024, esses obstáculos podem ser superados e a tecnologia pode ser levada adiante no cenário nacional.

É exposto na literatura que países onde a participação de fontes de energia renováveis na matriz energética é considerável tendem a ter vantagens de custo na produção de hidrogênio verde. Além disso, países que têm infraestruturas de gasodutos muito avançadas podem reutilizar suas redes mais antigas para gás natural para ampliar a distribuição de hidrogênio. Ou seja, países que podem misturar capacidades muito altas de geração de energia solar e eólica com infraestruturas de gasodutos bem estabelecidas estão estrategicamente posicionados para montar uma cadeia de economia de hidrogênio.

Finalmente, a tecnologia de gêmeos digitais com aprendizado de máquina pode

desempenhar um m papel no avanço da sustentabilidade industrial. Sendo uma tecnologia disruptiva, ela impulsiona não apenas a eficiência na área industrial como também pode auxiliar na área energética, e utilizando na produção armazenamento e transformação do hidrogênio em energia faz ser possível que também reduz a emissão de gases poluentes, tendo um efeito muito direto no trabalho relacionado à mitigação dos efeitos das mudanças climáticas.

REFERÊNCIAS

ALMEIDA, A. S. de et al. Hidrogênio, o combustível do futuro. **Diversitas Journal**, v. 4, n. 2, p. 356–366, jun. 2019.

ATILHAN, Selma; PARK, Sunhwa; EL-HALWAGI, Mahmoud M; ATILHAN, Mert; MOORE, Margaux; NIELSEN, Rasmus B. Green hydrogen as an alternative fuel for the shipping industry. **Current Opinion in Chemical Engineering**, v. 31, p. 100668, 2021. ISSN 2211-3398.

AVEVA. **Engineering a trusted digital twin**. Cambridge, UK: AVEVA Group plc e its subsidiaries, 2022.

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**, IEEE, v. 12, n. 3, p. 50–57, set. 2024.

BARRETO, GA; SOUZA, LG. Adaptive Filtering with the Self-Organizing Map: A Performance Comparison. **Neural Networks**, v. 19, n. 6-7, p. 785–798, 2006.

BASTOS, Fernanda. **Mercado de hidrogênio verde deve chegar à marca de 1,4 trilhão de dólares até 2050**. 2023. Disponível em: <https://exame.com/esg/mercado-de-hidrogenio-verde-deve-chegar-a-marca-de-14-trilhao-de-dolares-ate-2050>. Acesso em: 19 dez. 2024.

BENGIO, Y. **Learning Deep Architectures for AI**. Pittsburgh: Mach Learn, 2009.

BENGIO, Y; COURVILLE, A; VINCENT, P. Representation Learning: A Review and New Perspectives. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 35, n. 8, p. 1798–1828, 2013.

BEZUTTI, Natália. **Demanda por hidrogênio verde em 2050 deve ser até cinco vezes maior que a atual, aponta BCG**. 2023. Disponível em: <https://megawhat.energy/hidrogenio/demanda-por-hidrogenio-verde-em-2050-deve-ser-ate-cinco-vezes-maior-que-atual-aponta-bcg>. Acesso em: 19 dez. 2024.

BIANCHI, RE. **Extração de Conhecimento Simbólico em Técnicas de Aprendizado de Máquina Caixa-Preta por Similaridade de Rankings**. 2008. Dissertation – Universidade de São Paulo, São Paulo.

BISHOP, C. M. **Pattern Recognition and Machine Learning**. [S.l.]: Springer, 2006.

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. out. 2024. Disponível em: <https://www.linkedin.com/feed/update/urn:li:activity:7239639220309372929/>. Acesso em: 28 out. 2024.

CAMPBELL COLLABORATION. **Home page**. Londres: Campbell Collaboration, 2024. Disponível em: <https://www.campbellcollaboration.org>. Acesso em: 28 out. 2024.

CAMPOS, Alessandra; CAETANO, Luís Miguel; LAUS-GOMES, Victor. Revisão sistemática de literatura em educação: características, estrutura e possibilidades às pesquisas qualitativas. **Linguagens, Educação e Sociedade**, v. 27, p. 2526–8449, jun. 2023.

CENTRO DE HIDROGÊNIO VERDE - UNIFEI. **O Hidrogênio Verde (H2V)**. Acesso em: 1 nov. 2024. 2019. Disponível em: <https://ch2v.unifei.edu.br/o-hidrogenio-verde-h2v/>. Acesso em: 1 nov. 2024.

CHEN, Ke; KURGAN, Lukasz. PFRES: protein fold recognition using support vector machine. **Bioinformatics**, Oxford University Press, v. 23, n. 21, p. 2843–2849, 2007.

CIVIL, Ascom Casa. **Plano Master mapeará potencial para hidrogênio verde no Rio Grande do Sul**. 2023. Disponível em: <https://www.estado.rs.gov.br/plano-master-mapeara-potencial-para-hidrogenio-verde-no-rio-grande-do-sul>. Acesso em: 19 dez. 2024.

COMPANY, McKinsey. **A oportunidade bilionária do hidrogênio verde para o Brasil**. 2023. Disponível em: <https://www.mckinsey.com/br/our-insights/all-insights/a-oportunidade-bilionaria-do-hidrogenio-verde-para-o-brasil>. Acesso em: 19 dez. 2024.

DAWOOD, Furat; ANDA, Martin; SHAFIULLAH, G.M. Hydrogen production for energy: An overview. **International Journal of Hydrogen Energy**, v. 45, n. 7, p. 3847–3869, 2020. ISSN 0360-3199.

DELOITTE. Industry 4.0 and the digital twin: Manufacturing meets its match. **Deloitte Insights**, 2017. Acesso em: 2024-11-25.

ELECTROCELL. **O que é Célula a Combustível**. 2019. Disponível em: https://web.archive.org/web/20190909135703/http://www.electrocell.com.br:80/oqueeacc_pt.htm. Acesso em: 29 nov. 2024.

EL-EMAM, Rami S.; ÖZCAN, Hasan. Comprehensive review on the techno-economics of sustainable large-scale clean hydrogen production. **Journal of Cleaner Production**, v. 220, p. 593–609, 2019. ISSN 0959-6526.

GATES, Bill. **The innovations we need to avoid a climate disaster**. [S.l.: s.n.], mar. 2021. TED Talk. Acesso em: 2024-11-28. Disponível em: https://www.ted.com/talks/bill_gates_the_innovations_we_need_to_avoid_a_climate_disaster.

GATTI, B. A. **A construção da pesquisa em educação no Brasil**. Brasília: Plano, 2002.

GOODMAN, KE; LESSLER, J; COSGROVE, SE; HARRIS, AD; LAUTENBACH, E; HAN, JH et al. A Clinical Decision Tree to Predict Whether a Bacteremic Patient Is Infected with an Extended-Spectrum -Lactamase-Producing Organism. **Clinical Infectious Diseases**, v. 63, n. 7, p. 896–903, 2016.

GRIEVES, Michael W.; VICKERS, John H. Digital Twin: Mitigating Unpredictable, Undesirable Emergent Behavior in Complex Systems. *In*: TRANSDISCIPLINARY Perspectives on Complex Systems: New Findings and Approaches. Cham: Springer International Publishing, 2017. P. 85–113.

HAN, Won-Bi *et al.* Directly sputtered nickel electrodes for alkaline water electrolysis. **Electrochimica Acta**, v. 386, p. 138458, 2021. ISSN 0013-4686.

HOLANDA ARAÚJO, Júlio César; TUPINAMBÁ, Soraya Vanini. **Cenários, Desafios e Oportunidades para o Hidrogênio Verde no Brasil e no Mundo**. 2023. Disponível em: https://br.boell.org/sites/default/files/2023-06/hidrogenio_cenarios_desafios_oportunidades_boll-26.2023.pdf. Acesso em: 19 dez. 2024.

HUANG, W. *et al.* Data-driven predictive maintenance for manufacturing: A review. **Journal of Manufacturing Systems**, v. 46, p. 123–135, 2018.

- IBERDROLA. **Eletrolisador | Fator-chave na produção de hidrogênio verde.** [S.l.: s.n.], 2024. <https://www.iberdrola.com/sustentabilidade/eletrolisador>. Acesso em: 25 nov. 2024.
- INFOESCOLA. **Célula de combustível.** Acesso em: 25 nov. 2024. 2024. Disponível em: <https://www.infoescola.com/eletroquimica/celula-de-combustivel/>.
- INVESTNEWS. **Arábia Saudita vai investir US\$ 10 bilhões em nova empresa de hidrogênio verde.** 2024. Disponível em: <https://investnews.com.br/negocios/arabia-saudita-vai-investir-us-10-bilhoes-em-nova-empresa-de-hidrogenio-verde/>. Acesso em: 30 nov. 2024.
- INVESTNEWS. **Entre tons de verde: Empresas mergulham na corrida do hidrogênio.** 2024. Disponível em: <https://investnews.com.br/negocios/entre-tons-de-verde-empresas-mergulham-na-corrida-do-hidrogenio/>. Acesso em: 30 nov. 2024.
- JONES, David; SNIDER, Chris; NASSEHI, Aydin; YON, Jason; HICKS, Ben. Characterising the Digital Twin: A systematic literature review. **CIRP Journal of Manufacturing Science and Technology**, v. 29, p. 36–52, 2020. ISSN 1755-5817.
- KHAN, M. J. *et al.* Integration of digital twin and machine learning for industrial applications: A review. **Computers in Industry**, v. 129, p. 103426, 2021.
- KOHONEN, T; HONKELA, T. Kohonen Network. **Scholarpedia**, v. 2, n. 1, p. 1568, 2007.
- KOVAČ, Ankica; PARANOS, Matej; MARCIUŠ, Doria. Hydrogen in energy transition: A review. **International Journal of Hydrogen Energy**, v. 46, n. 16, p. 10016–10035, 2021. Hydrogen and Fuel Cells. ISSN 0360-3199.
- KPMG INTERNATIONAL. **Beyond the Hype: Separating Ambition from Reality in IoT.** [S.l.], mai. 2017. Disponível em: <https://assets.kpmg.com/content/dam/kpmg/xx/pdf/2017/05/beyond-the-hype.pdf>. Acesso em: 1 dez. 2024.
- KRITTANAWONG, Chayakrit et al. Machine learning prediction in cardiovascular diseases: Meta-analysis. **European PMC**, 2020.

KUMAR, A. *et al.* Machine learning applications for hydrogen production: A review. **Renewable and Sustainable Energy Reviews**, v. 119, p. 109553, 2020.

KUMAR, S. Shiva; LIM, Hankwon. An overview of water electrolysis technologies for green hydrogen production. **Energy Reports**, 2022.

KUPRAT, Johannes; DEBBADI, Karthik; SCHAUMBURG, Joscha; LISERRE, Marco; LANGWASSER, Marius. Thermal Digital Twin of Power Electronics Modules for Online Thermal Parameter Identification. **IEEE Journal of Emerging and Selected Topics in Power Electronics**, IEEE, v. 12, n. 1, p. 1020–1025, fev. 2024.

MARC RICHTER, Daniela Lara e. Hidrogênio verde: a fonte de energia do futuro. **Novos Cadernos NAEA**, v. 26, n. 1, 2023. ISSN 2179-7536.

MIOTTO, R; WANG, F; WANG, S; JIANG, X; DUDLEY, JT. Deep Learning for Healthcare: Review, Opportunities and Challenges. **Briefings in Bioinformatics**, v. 19, n. 6, p. 1236–1246, 2018.

MIRANDA, Amanda. **UFSC inaugura primeira usina de hidrogênio verde de SC**. 2023. Disponível em: <https://noticias.ufsc.br/2023/08/ufsc-inaugura-primeira-usina-de-hidrogenio-verde-de-sc>. Acesso em: 19 dez. 2024.

MOUSSA, A. *et al.* Sustainable hydrogen production by water electrolysis: A review. **Renewable Energy**, v. 146, p. 1789–1807, 2020.

NASCIMENTO, Caio Mangueira do. **Gêmeo Digital de um Sistema de Bombeamento de Água**. Jul. 2022. Dissertação (Mestrado) – Universidade Federal da Paraíba, João Pessoa. Orientador: Dr. Euler Cássio Tavares Macêdo; Coorientador: Dr. Ademar Virgolino da Silva Netto.

NELSON SIFFERT, Katia Rocha. **Hidrogênio verde: oportunidades e desafios para o Brasil**. 2023. Disponível em: https://repositorio.ipea.gov.br/bitstream/11058/12636/1/Radar_74_Art2_Hidrogenio_verde.pdf. Acesso em: 19 dez. 2024.

NORONHA, M. E. S. *et al.* Hidrogênio e energia eólica: uma revisão sistemática. *In*: ANAIS do Congresso de Administração Sociedade e Inovação. Rio de Janeiro: CASI, 2021. P. 1–18. Apresentado no 14º Congresso de Administração Sociedade e Inovação, 2021, Rio de Janeiro.

OKOLI, C. Critical Realist Considerations for Literature Reviews. **SSRN Electronic Journal**, Rochester, NY, p. 3, dez. 2015.

OSMAN, Ahmed. Catalytic hydrogen production from methane partial oxidation: mechanism and kinetic study mini-review. **Chemical Engineering & Technology**, v. 43, p. 641–648, jan. 2020.

PAIXÃO, Gabriela Miana de Matos; SANTOS, Bruno Campos; ARAUJO, Rodrigo Martins; RIBEIRO, Manoel Horta; MORAES, Jermana Lopes; RIBEIRO, Antônio L. Machine Learning na Medicina: Revisão e Aplicabilidade. **Arquivos Brasileiros de Cardiologia**, v. 118, n. 1, p. 95–102, 2022.

PANG, B; ZHANG, D; LI, N; WANG, K. Computerized Tongue Diagnosis Based on Bayesian Networks. **IEEE Transactions on Biomedical Engineering**, v. 51, n. 10, p. 1803–1810, 2004.

PARROTT, A.; WARSHAW, L. **Indústria 4.0 e o gêmeo digital: a manufatura encontra seu par**. Nova Iorque: Deloitte University Press, 2017.

PINSKY, Roxanne; SABHARWALL, Piyush; HARTVIGSEN, Jeremy; O'BRIEN, James. Comparative review of hydrogen production technologies for nuclear hybrid energy systems. **Progress in Nuclear Energy**, v. 123, p. 103317, 2020. ISSN 0149-1970.

PODGORELEC, V; KOKOL, P; STIGLIC, B; ROZMAN, I. Decision Trees: An Overview and Their Use in Medicine. **Journal of Medical Systems**, v. 26, n. 5, p. 445–463, 2002.

PORTAL LITORAL SUL, Redação da. **Santa Catarina sanciona Política Estadual do Hidrogênio Verde**. 2024. Disponível em: <https://portallitoralsul.com.br/hidrogenio-verde-sc-tem-lei-de-incentivo-para-incentivar-producao-do-combustivel-do-futuro>. Acesso em: 19 dez. 2024.

RABELO, Ricardo J.; MAGALHÃES, Luciano C.; CABRAL, Felipe G. Uma Proposta de Arquitetura de Referência de Gêmeo Digital para Sistemas Ciberfísicos em um cenário de Indústria 4.0. **Anais do Programa de Pós-Graduação em Engenharia de Automação e Sistemas, UFSC**, Florianópolis, SC, Brasil, 2023.

RAGHAVENDRA, U; GUDIGAR, A; BHANDARY, SV; RAO, TN; CIACCIO, EJ; ACHARYA, UR. A Two Layer Sparse Autoencoder for Glaucoma Identification with Fundus Images. **Journal of Medical Systems**, v. 43, n. 9, p. 299, 2019.

RAJKOMAR, A; DEAN, J; KOHANE, I. Machine Learning in Medicine. **New England Journal of Medicine**, v. 380, n. 14, p. 1347–1359, 2019.

RAJKOMAR, Alvin; DEAN, Jeff; KOHANE, Isaac. Machine learning in medicine. **New England Journal of Medicine**, v. 380, n. 14, p. 1347–1358, 2019.

RIBEIRO, Isaac. **O que é hidrogênio verde? ES pode produzir combustível do futuro.** Acesso em: 18 nov. 2024. A Gazeta. ago 2022. Disponível em: <https://www.agazeta.com.br/es/economia/o-que-e-hidrogenio-verde-es-pode-produzir-combustivel-do-futuro-0822>.

SÁ-SILVA, Jackson Ronie; ALMEIDA, Cristóvão Domingos de; GUINDANI, Joel Felipe. Pesquisa documental: pistas teóricas e metodológicas. **Revista Brasileira de História & Ciências Sociais**, São Leopoldo, RS, v. 1, n. 1, jul. 2009.

SAIDI, M.; GOHARI, M. H.; RAMEZANI, A. T. Hydrogen production from waste gasification followed by membrane filtration: a review. **Environmental Chemistry Letters**, v. 18, p. 1529–1556, 2020.

SANTOS, Carlos Henrique dos. **Monitoramento de Modelos de Simulação Utilizados como Gêmeos Digitais: Uma Abordagem Baseada em Aprendizado de Máquina e Carta de Controle.** Jun. 2023. Tese (Doutorado) – Universidade Federal de Itajubá, Itajubá, Brasil. Orientador: Prof. Dr. José Arnaldo Barra Montevechi, Coorientador: Prof. Dr. José Antonio de Queiroz.

SATHYA, R; ABRAHAM, A. Comparison of Supervised and Unsupervised Learning Algorithms for Pattern Classification. **International Journal of Artificial Intelligence**, v. 2, n. 2, p. 34–38, 2013.

AL-SHAYEA, QK. Artificial Neural Networks in Medical Diagnosis. **International Journal of Computer Science Issues**, v. 8, n. 2, p. 150–154, 2011.

SILVA, I. A. Hidrogênio: Combustível do Futuro. **Ensaio e Ciência: ciências biológicas, agrárias e da saúde**, v. 20, n. 2, p. 122–126, 2016.

SILVEIRA, C. S.; OLIVEIRA, L. Análise do mercado de carbono no Brasil: histórico e desenvolvimento. **Novos Cadernos NAEA**, Belém, v. 24, n. 3, p. 11–31, 2021.

SMITH, SW; WALSH, B; GRAUER, K; WANG, K; RAPIN, J; LI, J et al. A Deep Neural Network Learning Algorithm Outperforms a Conventional Algorithm for Emergency Department Electrocardiogram Interpretation. **Journal of Electrocardiology**, v. 52, p. 88–95, 2019.

SRIVASTAVA, R. K. *et al.* Biofuels, biodiesel and biohydrogen production using bioprocesses. A review. **Environmental Chemistry Letters**, v. 18, n. 4, p. 1049–1072, 2020.

SUTTON, Richard S.; BARTO, Andrew G. **Reinforcement Learning: An Introduction**. [S.l.]: MIT Press, 2018.

TAO, F. *et al.* Digital twin and its applications in manufacturing industry. **Journal of Manufacturing Systems**, v. 48, p. 1–20, 2018.

TENHUMBERG, N.; BÜKER, K. Ecological and Economic Evaluation of Hydrogen Production by Different Water Electrolysis Technologies. **International Journal of Hydrogen Energy**, 2023.

THE WALL STREET JOURNAL. Custo de produção do hidrogênio verde é proibitivo, diz estudo de Harvard. **The Wall Street Journal**, out. 2024. Matéria de Yusuf Khan. Disponível em: <https://investnews.com.br/ws/custo-da-producao-de-hidrogenio-verde-e-proibitivo-diz-estudo-de-harvard/>. Último acesso em: 28 out. 2024.

THEMA, M.; BAUER, F.; STERNER, M. Power-to-Gas: Electrolysis and methanation status review. **Renewable and Sustainable Energy Reviews**, v. 112, p. 775–787, 2019. ISSN 1364-0321.

WENDT, Hartmut; GÖTZ, Michael; LINARDI, Marcelo. TECNOLOGIA DE CÉLULAS A COMBUSTÍVEL. **Química Nova**, Instituto de Pesquisas Energéticas e Nucleares, v. 23, n. 4, p. 538–546, 2000.