

Local Volt-Var Control Applied in an Islanded Microgrid Using Supervised Learning Techniques

Diego D. Domingues , Sérgio J. M. Almeida , and Eduardo A. C. Costa 

Abstract—The electrical sector pursuit of technical and ecological alternatives makes it possible to integrate and cooperatively optimize dispersed energy resources, enhancing the stability, dependability, and resilience of contemporary energy systems. Microgrids and artificial intelligence are two ideas that could be included into contemporary power grids in an effort to lower costs and pollution emissions. This work proposes a new energy control and management strategy based on smart devices in this context. It explores machine-learning techniques for implementing supervised learning algorithms to perform automatic volt-var control adjustments and mitigate voltage fluctuations at the point of common coupling using smart inverters. The techniques explored and compared in this study include multilayer perceptron, SVM, and random forest. The results were consistent, with average accuracies above 90%, indicating the relevance of the analyzed models for this application. Thus, this research seeks to improve power quality in islanded microgrids with high penetration of distributed generation and explore the potential of artificial intelligence in decision-making processes.

Link to graphical and video abstracts, and to code:
<https://latamt.ieeet9.org/index.php/transactions/article/view/9469>

Index Terms—microgrids, power quality, smart inverter, volt-var control, artificial intelligence, machine learning

I. INTRODUÇÃO

INTELIGÊNCIA Artificial (IA) oferece inúmeras vantagens em novos cenários para redes elétricas, como a análise de grandes volumes de dados em tempo real ou com base em modelos previamente treinados, permitindo tomadas de decisão mais rápidas e precisas. Além disso, a IA possibilita a automação de processos complexos, como a previsão de demanda e a otimização da operação do sistema elétrico, o que contribui para maior eficiência e confiabilidade da rede.

A busca por alternativas sustentáveis tem impulsionado o uso de fontes renováveis nas unidades consumidoras, como a geração fotovoltaica, eólica e a partir de biogás. Essa tendência reforça a necessidade de adaptação da infraestrutura elétrica para comportar um novo perfil de geração distribuída, com a expectativa de que tais fontes se tornem predominantes ao longo do tempo [1].

Nesse contexto, destacam-se dois conceitos complementares: as microrredes (MR) e as redes inteligentes (*smart grids* (SG)). As MR são sistemas elétricos localizados que podem

operar conectados ou de forma isolada da rede principal, sendo compostas por cargas, fontes renováveis, sistemas de armazenamento e dispositivos de controle. Já as redes inteligentes representam uma modernização ampla do sistema elétrico, utilizando tecnologias de comunicação e automação para melhorar a operação em larga escala. As MR oferecem uma solução prática para modernizar a infraestrutura elétrica em nível local, possibilitando o monitoramento em tempo real e a coleta de dados operacionais, além da capacidade de operar de forma autônoma [2] [3].

Em complemento, o uso da IA surge como alternativa eficaz para aprimorar os métodos tradicionais. O aprendizado de máquina (*Machine Learning* (ML)), uma das áreas da IA, permite a criação de estratégias de controle adaptativas à dinâmica do sistema, com destaque para as redes neurais artificiais (RNAs), que contribuem para uma maior flexibilidade e resiliência da rede.

Uma alternativa em MR e na geração distribuída (GD) é a utilização de recursos energéticos distribuídos (REDs) para corrigir desvios em indicadores de qualidade de energia que estejam fora dos limites normais. Entre os distúrbios associados à qualidade da energia elétrica (QEE), destaca-se a variação de tensão no ponto de acoplamento comum (PAC), frequentemente observada em sistemas elétricos e intensificada pela inserção de REDs, devido ao desequilíbrio entre geração e consumo [4].

Esse problema pode ser atenuado por meio do controle da tensão no PAC, ajustando a injeção ou absorção de potência reativa. Tal ajuste é chamado de controle Volt-Var (CVV) e é amplamente empregado e discutido na literatura [5] [6] [7] [8]. Contudo, por ser geralmente baseado em curvas fixas definidas localmente, o CVV tradicional pode não responder de forma eficiente à alta variabilidade presente em MR.

Dessa forma, pesquisadores têm desenvolvido soluções inteligentes para otimizar o desempenho de sistemas com elevada penetração de REDs, visando maior eficiência e confiabilidade operacional [9] [10].

A integração da IA é, portanto, uma abordagem promissora para tornar as redes elétricas mais ativas e adaptáveis, sendo capaz de lidar com diversas perturbações que impactam a qualidade e a continuidade do fornecimento de energia.

Sendo assim, este trabalho propõe aplicar e avaliar um modelo de aprendizado supervisionado para fornecer um ajuste inteligente do CVV no PAC, com base nos dados coletados da rede. O objetivo é apresentar uma alternativa viável para controle de tensão local em microrredes operando em modo ilhado, superando as limitações dos métodos convencionais.

The associate editor coordinating the review of this manuscript and approving it for publication was Gladston Moreira (*Corresponding author: Diego Domingues*).

Diego Domingues, S. J. M. Almeida, and E. A. C. Costa are with Catholic University of Pelotas, Pelotas, Rio Grande do Sul, Brazil (e-mail: diego.domingues@sou.ucpel.edu.br, sergio.almeida@ucpel.edu.br, and eduardo.costa@ucpel.edu.br).

Ao dispensar a dependência de comunicação entre dispositivos distribuídos, o modelo é capaz de se adaptar à dinâmica da rede, mesmo em condições de operação isolada. Essa autonomia torna a abordagem particularmente útil em cenários onde há restrição de infraestrutura de comunicação.

Este modelo de controle inteligente oferece uma solução eficiente e robusta para melhorar a QEE em microrredes ilhadas, contribuindo para a otimização do sistema e abrindo novas possibilidades para as redes elétricas inteligentes do futuro.

II. CONTEXTUALIZAÇÃO

Diversos trabalhos de pesquisa têm investigado a aplicação de IA no contexto de microrredes ou na abordagem de algumas perturbações de QEE, que podem surgir em redes modernas com a penetração massiva de GD [11], [12], [13], [14], [15]. Observou-se que a tendência de pesquisas nessas áreas tiveram aumentos significativos nos últimos anos.

Como resultado, a relevância e a importância de analisar novos métodos que podem ser empregados para melhorar alguns pontos de interesse em redes elétricas, especialmente em áreas menos estudadas como microrredes, foram notadas.

Nesse sentido, um tópico destacado diz respeito aos *Smart Inverters (SI)* e a possibilidade de utilizar funções extras embarcadas nesses dispositivos para abordar algumas questões de QEE. Por exemplo, o CVV e os aprimoramentos nessas funcionalidades visam melhorar os parâmetros relacionados aos recursos contidos em sistemas distribuídos que fazem parte da GD e MR.

Como parte de um sistema eficiente que requer operações capazes de se adaptar não apenas às funcionalidades locais, mas também de inferir ajustes globais [6], os inversores inteligentes apresentam características comuns que definem essas particularidades de recursos.

Uma dessas abordagens diz respeito aos controles dinâmicos de suporte de tensão, que são vitais para manter a estabilidade e a QEE em redes elétricas modernas. Isso é especialmente verdadeiro em cenários com aumento da GD e integração de fontes renováveis. Funções como fator de potência fixo, Volt-Var e Volt-Watt são utilizadas para ajustar dinamicamente a injeção ou absorção de potência reativa, garantindo que a tensão permaneça dentro dos limites operacionais seguros.

Com os avanços em IA, esses controles podem ser aprimorados para operar de forma mais ativa e autônoma, respondendo com agilidade às variações inesperadas de carga e geração. Além disso, a aplicação da IA torna o sistema elétrico mais resiliente, preparado para enfrentar as condições dinâmicas e imprevisíveis da rede.

Ainda assim, não existe um modelo matemático único que apresente a saída "padrão" para as curvas do CVV. Porém, alguns modelos de curvas já foram implementados e testados para certas dinâmicas que envolvem controle local ou distribuído, a maioria das quais compara a melhor estratégia fixa imposta a cada inversor para produzir os melhores resultados [5] [6] [16].

No entanto, isso não reflete a realidade dos sistemas elétricos, que apresentam dinâmicas complexas baseadas em vários

fatores, como variações de carga e demanda. A oscilação de temperatura e cobertura de nuvens em curvas de irradiância, das quais os sistemas fotovoltaicos dependem para níveis adequados de geração, também contribui para essas dinâmicas.

Essa complexidade se torna ainda mais significativa no contexto de microrredes, pois há menos elementos de controle externos. Isso justifica maior interesse em práticas que utilizem os recursos do sistema para executar essas tarefas e manter os valores de QEE dentro de faixas adequadas, reduzindo estruturas passivas e promovendo estruturas mais supervisionadas e ativas [17].

III. TRABALHOS RELACIONADOS

O impacto da inserção de GD nas redes de distribuição vem ganhando destaque, como em [5], que analisa a alta penetração de GD nesse tipo de rede. Para isso, o autor utiliza o *software OpenDSS* nas simulações e compara três cenários para validar a utilização de inversores inteligentes neste contexto. Os cenários analisados foram sem a inserção de GD, com a inserção de GD, e, por fim utilizando as funções inteligentes do inversor. Os resultados se mostraram satisfatórios de modo geral. Porém, por utilizar valores fixos para os ajustes do CVV, volt-watt e fator de potência em todos os inversores, os resultados ficaram dependentes desta configuração. Além disso, dinâmicas mais realistas em relação às variações de carga e da porcentagem de inserção da GD não foram investigados. O autor sugere que testes também sejam realizados em sistemas isolados, neste caso, microrredes.

Em [6], análogo a [5], também é feito um estudo do comportamento de três controles dos inversores inteligentes, Volt-Var, Volt-Watt e fator de potência constante. Porém, é feita uma análise mais criteriosa dos cenários de estudos, onde aponta-se a influência da variação da penetração de geração fotovoltaica, incidência de radiação solar e carregamento do circuito. Apesar desta análise mais perscrutada, os controles dos inversores são considerados os mesmos para todos os cenários avaliados. Embora tenham sido utilizados valores para as curvas que aproximavam a tensão de valores ótimos, esta condição não seria viável em um circuito diferente do estudado. Ao final, o autor sugere outras variações mais dinâmicas para as análises e que os testes sejam feitos em microrredes em trabalhos futuros.

Propõe-se em [16] um algoritmo para controle de injeção de potência reativa em redes de distribuição radial, com geração distribuída fotovoltaica. O objetivo principal é equilibrar a regulação de tensão e a redução de perdas elétricas, utilizando inversores conectados à rede para controlar a injeção de potência reativa de forma distribuída. Os resultados mostram que o algoritmo proposto obteve menores perdas e melhor perfil de tensão em comparação com outros métodos da literatura, com destaque para cenários de altas penetrações de GD. Embora o trabalho apresente bons resultados, o algoritmo proposto é projetado para condições específicas, por exemplo, rede radial monofásica. Isso não torna possível generalizar a sua utilização para outras abordagens mais complexas, como sistemas trifásicos, outros tipos de GD e ainda outras condições de carga.

Em [7], apresenta-se um estudo de caso detalhado sobre a aplicação da função Volt-Var de inversores solares em uma rede de transmissão de alta tensão na República da Índia, focando em eventos de contingência, como o colapso de tensão e o ilhamento. Simulações verificaram a eficácia de uma planta fotovoltaica de 100 MW no suporte à tensão, mostrando como a injeção de potência reativa pode mitigar quedas de tensão em cenários de contingência. O estudo destaca a eficácia da função Volt-Var, demonstrando que, com essa abordagem, houve uma melhoria significativa na resposta do sistema em comparação a estratégias tradicionais. No entanto, a aplicação é voltada para uma planta solar de grande porte centralizada, sendo menos flexível em comparação com soluções descentralizadas e escaláveis em microrredes. Além de que, o controle proposto não explora métodos mais avançados, como o uso de inteligência artificial para otimização dinâmica, por exemplo.

O trabalho de [18], propõe um método de controle de tensão em redes de distribuição com ajuste mínimo nas unidades de geração distribuída, utilizando o algoritmo de otimização por enxame de partículas *Particle Swarm Optimization (PSO)*. A ideia é minimizar as violações de tensão e o esforço de controle, como ajustes de *taps* de transformadores e bancos de capacitores, mantendo a máxima injeção de potência ativa das fontes de geração distribuída. Embora eficaz, a abordagem se concentra em uma otimização pontual com a necessidade de ajustes frequentes para lidar com a dinâmica da rede.

A implementação de uma nova metodologia é mostrada em [8], para o controle de tensão e potência reativa utilizando o CVV em sistemas de distribuição inteligentes, coordenando tanto equipamentos convencionais quanto modernos com eletrônica de potência. Utilizando lógica *fuzzy*, o algoritmo simplifica a implementação e garante um desempenho eficiente em tempo real. Aplicada em um sistema teste IEEE de 34 barras com geradores distribuídos, a estratégia demonstrou resultados promissores ao reduzir o número de chaveamentos e manter a tensão dentro de níveis adequados. Porém, por depender de regras predefinidas, não apresenta um bom comportamento em condições operacionais reais.

Em [9], propõe-se a utilização de métodos baseados em AM, como RNAs, árvores de decisão (AD), e *Support Vector Machine (SVM)*, para o controle centralizado de tensão e potência reativa em redes de distribuição modernas.

As magnitudes de tensão nos nós, magnitudes de fluxo de corrente nos circuitos e injeções de potência ativa e reativa nos nós em diferentes pontos da rede foram usadas como dados de entrada para determinar o ajuste ideal de variáveis de controle, como potência ativa e reativa de geradores distribuídos, bancos de capacitores e transformadores com troca de *taps*. Embora eficaz em redes com controle centralizado, essa abordagem pode ser limitada se inserida em cenários dinâmicos e distribuídos, especialmente em redes mais complexas como microrredes, onde o controle local é essencial.

A implementação de um método de identificação de perfis elétricos de recursos energéticos distribuídos em redes de baixa tensão, utilizando técnicas de aprendizado supervisionado, como *kNN*, *Random Forest* e *perceptron* multicamadas, é apresentado em [10]. A proposta aborda a falta de monitoramento em redes de baixa tensão e a necessidade

de maior observabilidade para a gestão ativa dos REDs. O modelo utiliza medições de potência ativa, reativa, corrente e tensão para identificar a presença de veículos elétricos (VE) e sistemas fotovoltaicos (SFV), com precisão de até 93% para SFV e 73% para VE. O trabalho evidencia a viabilidade na utilização de aprendizado supervisionado em redes com alta penetração de REDs.

Em [19], aplicam-se redes neurais profundas *Deep Neural Network (DNN)* para o projeto de otimização das regras de CVV em inversores de redes de distribuição com REDs. O estudo visa enfrentar os desafios das flutuações rápidas de tensão, otimizando as regras conforme o padrão IEEE 1547, que permite a personalização por barra. O método sugere treinar uma *DNN* que emula as dinâmicas Volt-Var, minimizando a distância das tensões ao ponto de equilíbrio.

A Tabela I sumariza um comparativo dos trabalhos relacionados e as diferenças para a proposta desta pesquisa.

TABELA I
RESUMO DE TRABALHOS RELACIONADOS

Referência	Cenário Analisado	Software de Simulação	Inversores Inteligentes e CVV	Técnica de IA
[5]	RD	OpenDSS/MATLAB	Sim	N/A
[6]	RD	OpenDSS/MATLAB	Sim	N/A
[16]	RD	MATLAB	Sim	N/A
[7]	LT	ETAP/MATLAB	Sim	N/A
[18]	RD	OpenDSS/Python	Sim	PSO
[8]	RD	OpenDSS/MATLAB	Sim	Fuzzy
[9]	RD	WEKA	Sim	ANN/DT/SVM
[10]	RD	OpenDSS/Python	Não	kNN/RF/MLP
[19]	RD	MATLAB/Python	Sim	DNN
Este trabalho	MR	OpenDSS/Python	Sim	MLP/SVM/MRF

RD=Redes de Distribuição; LT=Linhas de Transmissão; MR=Microredes; N/A=Não Aplicado

É possível observar uma tendência com relação à exploração de técnicas de IA com a finalidade de otimizar as funções dos inversores inteligentes, visto que ainda são poucas as pesquisas que integram estes elementos, especialmente se tratando de microrredes.

Desta forma, esta pesquisa visa contribuir com esse tópico, permitindo uma maior utilização de estratégias de controle descentralizadas. A ideia principal é mesclar os ganhos relacionados ao AM que pode se adaptar a dinâmica da rede a partir dos dados que coleta dela. Também, a resolução de problemas relacionados a QEE que estão presentes em MR, necessitando de operações confiáveis, automatizadas e menos dependentes de agentes externos.

IV. MODELAGEM DO SISTEMA

O circuito IEEE 13 barras foi utilizado como base e modelado no *software OpenDSS* que destaca-se como uma ferramenta de código aberto amplamente utilizada em estudos voltados para SG, oferecendo simulações precisas de sistemas elétricos de distribuição. Sua capacidade de operar em regime da frequência e integrar elementos como GD, aliada à possibilidade de controle externo via linguagens de programação como *Python*, torna-o altamente flexível para análises dinâmicas.

Com algumas alterações realizadas em sua estrutura para adaptá-lo à dinâmica necessária para a coleta de dados e a implementação da microrrede teste, o circuito desenvolvido possui linhas de distribuição trifásicas aéreas e subterrâneas desequilibradas, ramificações bifásicas e trifásicas e cargas distribuídas [20].

Embora seja um circuito relativamente pequeno, com poucas barras, apresenta uma boa estrutura para a implementação de testes baseados na dinâmica da rede. Ele contém elementos com características típicas de redes de distribuição e de microrredes tradicionais, proporcionando uma melhor aproximação para modelos destinados à análise de QEE.

Foram implementados cinco cenários teste para realizar as simulações, a fim de reproduzir um ambiente computacional mais próximo das condições normais de operação de uma microrrede em modo isolado.

O objetivo era capturar dados de tensão em um dos pontos de acoplamento, por meio da inserção de um inversor fotovoltaico. A barra escolhida para isso foi a 680, pois é a mais distante dos elementos de controle da microrrede, localizados na barra 632.

Para classificar os valores de saída das tensões foi considerado a faixa utilizada na Tabela II.

TABELA II
LIMITES DAS FAIXAS DE VARIAÇÃO DE TENSÃO DE LEITURA - ADAPTADO DE [21]

Tensão Nominal superior a 2.3 kV e inferior a 69 kV	
Tensão de Atendimento	Faixa de Variação da Tensão de Leitura (TL)
Adequada	$0.93 \text{ p.u.} \leq TL \leq 1.05 \text{ p.u.}$
Precária	$0.90 \text{ p.u.} \leq TL < 0.93 \text{ p.u.}$
Crítica	$TL < 0.90 \text{ p.u.}$ ou $TL > 1.05 \text{ p.u.}$

Com essas medições, é possível monitorar o surgimento de distúrbios de QEE, sua gravidade e frequência de recorrência, para que esses dados possam ser usados como base para a tomada de decisão [22].

Foram realizados ajustes para implementar os cenários de referência nos REDs, especificamente na penetração de GD, que, sob determinadas condições de saturação, fez com que as tensões de referência oscilassem para faixas de controle, indicando condições anormais.

Oscilações dinâmicas foram introduzidas nas cargas do circuito para simular variações nos consumos residencial, comercial e industrial, proporcionando um comportamento mais realista ao sistema. Para isso, as curvas de carga originais foram modificadas com a inserção de padrões característicos de sistemas fotovoltaicos, considerando diferentes níveis de irradiação em dias nublados e ensolarados. Além disso, um sistema fotovoltaico foi adicionado à Barra 670. A Tabela III demonstra um quadro resumo com as principais características dos dispositivos implementados.

Nestas condições foram realizadas as simulações e adquiridos os resultados para servir de *dataset* no restante das análises e implementações. Nas simulações realizadas, utilizando o modo *Daily* do *OpenDSS*, foi considerado um período de

TABELA III
TABELA RESUMO DISPOSITIVOS DA MR TESTE

Descrição	Sistemas fotovoltaicos			Geradores			Sistema de armazenamento
	FV1	FV2	FV3	Ger 1	Ger 2	Ger 3	BESS
Tensão de linha nominal (kV)	0.48	0.48	0.48	4.16	0.48	4.16	4.16
Barra	675	680	670	671	684	646	632
Potência nominal (kVA)	1800	4000	2500	1875	250	625	350
Fator de potência	1	1	1	0.8	0.8	0.8	1

monitoramento da barra de sete dias, com um intervalo de integração de 10 minutos. Assim, totalizou-se 168 horas de análise e, com isso, foi possível registrar um total de 1008 leituras válidas em cada cenário.

A Fig. 1 mostra a configuração do circuito da microrrede teste implementada.

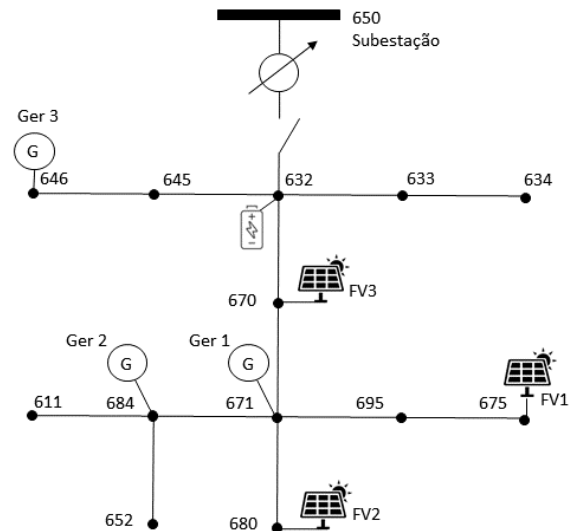


Fig. 1. Diagrama unifilar da microrrede de teste implementada.

V. METODOLOGIA

Com o objetivo de implementar um *dataset* com rótulos para treinar e validar os modelos de *ML*, foram realizados testes e configurações afim de obter um melhor cenário e dados concretos para este fim. A Fig. 2 ilustra as duas etapas fundamentais do processo metodológico utilizado para avaliar as curvas CVV e rotular as saídas do conjunto de dados, destacando o encadeamento de decisões adotado em cada etapa.

A sequência da implementação foi de criar rótulos para cada uma das condições de variação de tensão. Assim, foi analisado o comportamento de algumas das curvas de CVV padronizadas e utilizadas ao redor do mundo. Seis dessas curvas padronizadas são citadas em [23].

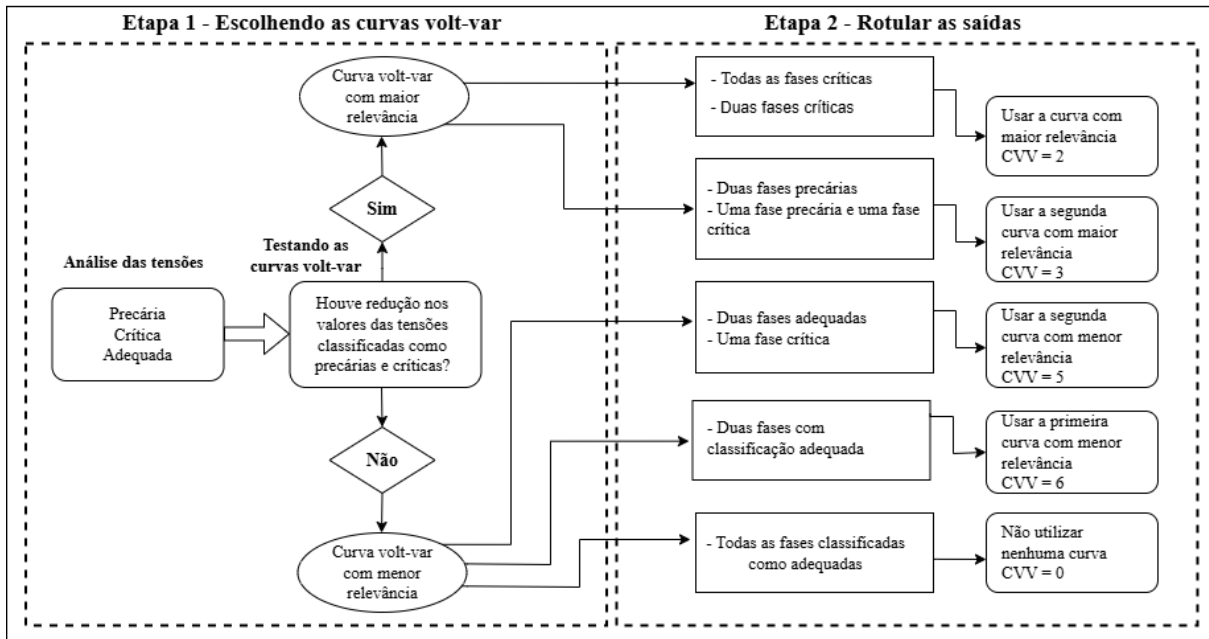


Fig. 2. Fluxograma de análise e rotulagem dos dados.

Nesta pesquisa cada uma das curvas analisadas foi numerada de 1 a 6. Essa numeração irá servir de base para o restante das simulações e resultados. Os valores de ajuste em cada uma delas são mostrados na Tabela IV.

TABELA IV
AJUSTES DAS CURVAS VOLT-VAR PADRONIZADAS.
ADAPTADO DE [24]

	CVV Califórnia (1)	CVV IEEEA (2)	CVV IEEEB (3)	CVV Austrália (4)	CVV Europa (5)	CVV Hawaii (6)
V1 (p.u)	0.92	0.9	0.92	0.91	0.95	0.97
Q1	+30%	+44%	+44%	+30%	+43.60%	+44%
V2 (p.u)	0.967	1	0.98	0.966	0.97	0.97
Q2	0	0	0	0	0	0
V3 (p.u)	1.033	1	1.02	1.038	1.031	1.03
Q3	0	0	0	0	0	0
V4 (p.u)	1.07	1.1	1.08	1.1	1.05	1.06
Q4	-30%	-25%	-44%	-30%	-43.60%	-44%

Todas as curvas foram analisadas no cenário 01 (três sistemas fotovoltaicos presentes) que apresentou a pior condição para as tensões fora da faixa considerada como adequada.

A análise também considerou a quantidade de melhoria representada em cada uma das três fases analisadas. A Tabela V mostra uma comparação da quantidade de pontos de tensão em cada uma das classificações antes (a) e depois (b) da inserção do CVV para a curva com maior representação de melhoria no cenário analisado que, foi a curva denominada de 2 (IEEEA).

Este teste comparativo foi feito para todas as curvas e, observou-se que quatro delas apresentavam melhores resultados de forma mais abrangente, sendo estas curvas escolhidas

TABELA V
COMPARAÇÃO DO NÚMERO DE PONTOS ANTES E DEPOIS DO CVV

	Sem CVV			Com CVV			
	Fase A	Fase B	Fase C	Fase A	Fase B	Fase C	
Adequada	712	922	882	Adequada	824	1008	983
Crítica	185	86	70	Crítica	105	0	0
Precária	111	0	56	Precária	79	0	25
	1008	1008	1008	1008	1008	1008	1008
	(a)			(b)			

como as saídas possíveis para rotular o *dataset* a ser utilizado posteriormente na implementação do modelo de ML.

Para inserir um rótulo em cada saída da tabela de análise, foi considerada uma abordagem sistemática baseada em critérios específicos, como frequência e gravidade das ocorrências.

A lógica usada considerou os seguintes critérios: A classificação "Crítica" tem a maior ponderação. "Precária" tem a menor ponderação média e "Adequada" tem a menor ponderação. A Tabela VI apresenta a forma final com a representação das possibilidades para cada saída com base nas combinações possíveis em cada entrada.

Além disso, para garantir um *dataset* equilibrado e sem repetições dos dados de entrada, optou-se em utilizar valores dos cinco cenários simulados. Assim, para cada combinação foram utilizados dados de entrada até formar um valor fixo para cada possibilidade de curva.

O *dataframe* final utilizado na sequência das simulações apresenta um total de 1400 dados, contendo seis entradas representando os módulos e o ângulos das tensões em cada fase no ponto analisado. Uma saída contém valores categóricos que representam as curvas para cada combinação de entrada

TABELA VI
CLASSIFICAÇÃO DE SAÍDAS COM BASE EM COMBINAÇÕES
DE ENTRADA

Classificação das fases			
Fase A	Fase B	Fase C	Tipo de curva
Adequada	Adequada	Adequada	0
Adequada	Crítica	Adequada	5
Precária	Adequada	Adequada	6
Adequada	Adequada	Precária	6
Crítica	Adequada	Adequada	5
Crítica	Crítica	Adequada	2
Crítica	Adequada	Crítica	2
Crítica	Adequada	Precária	3
Precária	Adequada	Precária	3
Crítica	Crítica	Crítica	2
Precária	Adequada	Crítica	3

possível naquele instante de tempo.

VI. CLASSIFICADORES INTELIGENTES

Nesta pesquisa foram utilizados três modelos de *ML* para verificar a métrica de classificação que seria mais adequada para o estudo proposto. O objetivo principal é avaliar a possibilidade de integrar inteligência artificial aos métodos de controle local para ajuste de tensão dinâmica no ponto de acoplamento comum analisado, barra 680.

Desta forma, as microrredes que operam de forma isolada, teriam mais uma possibilidade para o ajuste das tensões próximo às cargas e essa operação seria feita de forma autônoma.

Os principais modelos de *ML* foram *Perceptron* Multicamadas, *SVM* e *Random Forest*, e os parâmetros utilizados em cada um deles são detalhados na sequência desta seção.

Para o algoritmo *MLP*, algumas configurações e topologias foram testadas durante as implementações e assim foi gerado o modelo MLP-01, que apresenta poucos parâmetros de ajuste e bons resultados em suas simulações. O modelo MLP-01 utilizou uma arquitetura com 12 neurônios na camada oculta, função de ativação *tanh*, função de perda *cross-entropy*, *max_iter* = 5000, *early_stopping* = *False*, *random_state* = *None* e validação cruzada com 5 dobras.

Por ser um modelo de *ML* versátil e eficiente, amplamente aplicado em problemas de classificação e regressão [25], o *SVM* também foi testado para avaliar seu desempenho nas condições apresentadas nesta pesquisa. Alguns parâmetros foram variados até que o modelo que apresentou os melhores resultados fosse encontrado, chamado SVM-01.

Para o modelo SVM-01, foi utilizado o *kernel RBF* com $C = 10$ e $\gamma = 0.1$, mantendo os mesmos pré-processamentos dos modelos anteriores. Outros tipos de *kernel*, como polinomial e *sigmoid*, foram testados, porém com desempenho inferior.

Por fim, foi testado o *Random Forest*, uma técnica de aprendizado baseada em árvores de decisão, que são altamente flexíveis e conseguem capturar relações complexas entre dados. O modelo testado nesta pesquisa foi denominado RF-01.

O modelo RF-01, baseado em floresta aleatória, foi configurado com $n_estimators = 500$, $max_depth = 15$, $min_samples_leaf = 5$ e *random_state* = *None*, com validação cruzada em 5 dobras.

Em todas as implementações, o banco de dados foi normalizado e balanceado, utilizando a técnica de normalização *StandardScaler* e a função *SMOTE* para o balanceamento. Os conjuntos de treinamento e teste foram divididos em 70% e 30% respectivamente e por fim, foram realizadas simulações variando o número de iterações em 100 e 300 vezes para reduzir a variabilidade estatística, além de inúmeras variações experimentais de parâmetros para assim calcular métricas de validação do modelo.

Todos os modelos foram desenvolvidos em *Python* utilizando a biblioteca *Scikit-learn* na implementação e para avaliar o desempenho e robustez de cada simulação, foram utilizadas quatro métricas: acurácia, desvio médio padrão, *F1-Score* e matriz de confusão. Os resultados serão apresentados na próxima seção.

VII. RESULTADOS E DISCUSSÃO

Nesta seção, são apresentados os resultados dos modelos de *ML* testados, com uma análise detalhada do seu desempenho em relação às métricas de avaliação.

A análise dos resultados visa destacar os modelos mais adequados para o problema em questão, bem como discutir os desafios encontrados e as implicações para sua aplicação prática em microrredes.

Inicialmente, a Tabela VII apresenta os valores das principais métricas avaliadas, como acurácia, desvio padrão e *F1-score*, permitindo uma visão clara da eficácia de cada modelo.

TABELA VII
RESUMO DOS RESULTADOS DAS MÉTRICAS DE AVALIAÇÃO
DOS MODELOS DE *ML*

	MLP-01		SVM-01		RF-01	
Nº de simulações	100	300	100	300	100	300
Acurácia média	93.40%	93.49%	90.64%	90.73%	99.07%	99.15%
Desvio médio padrão	1.55%	1.49%	1.30%	1.41%	0.51%	0.54%
F1-score médio	93.11%	93.58%	90.86%	90.95%	99.07%	99.15%
Média de épocas para convergência	2305	2294	-	-	-	-

Em seguida, as matrizes de confusão são exploradas individualmente, com o apoio de figuras, para compreender os padrões de classificação e identificar possíveis limitações de cada abordagem.

A. Análise dos Resultados

A partir dos resultados apresentados na Tabela VII é possível fazer uma breve discussão sobre o desempenho dos três modelos de *ML* implementados nesta pesquisa.

O modelo MLP-01 apresentou um bom desempenho, com acurácia média de 93.49% nas 300 simulações e *F1-score* de 93.58%. No entanto, destaca-se o maior número médio de épocas para convergência, indicando que o *MLP* exigiu mais iterações para atingir sua estabilidade. Apesar disso, o desempenho é significativo, especialmente quando comparado ao *SVM*.

Matriz de Confusão Média - MLP-01

Real \ Previsão	0	2	3	5	6
0	81	0	0	1	1
2	0	101	1	1	0
3	0	2	95	2	14
5	0	2	1	70	1
6	0	0	5	0	35

Fig. 3. Matriz de confusão modelo MLP-01.

Matriz de Confusão Média - SVM-01

Real \ Previsão	0	2	3	5	6
0	79	0	0	1	2
2	0	98	3	1	0
3	0	2	98	1	12
5	1	1	1	67	3
6	0	0	4	0	36

Fig. 4. Matriz de confusão modelo SVM-01.

Matriz de Confusão Média - RF-01

Real \ Previsão	0	2	3	5	6
0	82	0	0	0	1
2	0	102	1	0	0
3	0	0	114	0	0
5	0	0	0	74	0
6	0	0	0	0	40

Fig. 5. Matriz de confusão modelo RF-01.

No modelo SVM-01, pode-se observar um menor desempenho entre as análises, com acurácia média de 90.73% e *F1-score* médio de 90.95% nas 300 simulações. Embora o desvio padrão do SVM seja relativamente baixo, a performance inferior indica que o modelo pode não ser tão adequado para os dados testados em relação aos outros métodos avaliados.

Por fim, o modelo RF-01 demonstrou o melhor desempenho

geral, com acurácia média e *F1-score* médio superiores a 99% em todas as simulações, e o menor desvio padrão, indicando consistência elevada.

Em relação às matrizes de confusão, os resultados são essenciais para entender detalhadamente como os modelos lidam com as diferentes classes, especialmente em termos de falsos positivos (FP) e falsos negativos (FN).

O modelo MLP-01 apresentou poucos erros nas previsões, com destaque para a curva de número 3 que foi 14 vezes indicada erroneamente como sendo a curva número 6. Mesmo assim, o modelo apresentou poucas limitações em relação a consistência das análises.

O modelo SVM-01 teve o pior desempenho, com muitos erros de previsão em boa parte do conjunto de análise, indicando maiores dificuldades em separar as classes, especialmente em casos onde as classes são desbalanceadas ou possuem sobreposição, conforme refletido em seu menor *F1-score* em relação aos outros modelos.

Já o modelo RF-01 apresentou excelente equilíbrio entre as previsões, indicando que as classificações incorretas são mínimas. Isso implica que o modelo é capaz de identificar com precisão todas as classes e se adequar bem ao cenário simulado.

Em resumo, o modelo RF-01 se destaca como a melhor escolha para o problema abordado, devido à sua alta acurácia, robustez e consistência mostrados na análise dos resultados gerais, sendo capaz de desempenhar bons resultados frente ao conjunto de dados testados.

VIII. CONSIDERAÇÕES FINAIS

A integração de fontes renováveis e recursos distribuídos nas redes elétricas exige soluções inovadoras para assegurar estabilidade e qualidade no fornecimento. Nesse cenário, as microrredes representam uma alternativa eficaz, especialmente em operação ilhada com inversores inteligentes. O uso do *OpenDSS*, ferramenta amplamente empregada na simulação de sistemas de distribuição, permite modelar microrredes de forma detalhada e simular diferentes cenários operacionais, considerando variações de carga, penetração de geração distribuída e o comportamento dos inversores.

Os resultados dos modelos de *machine learning* testados demonstram um potencial significativo para a aplicação em microrredes. Apesar da acurácia superior a 99% obtida em simulação, é importante considerar que, em ambientes reais, flutuações de carga, variabilidade da geração renovável e limitações operacionais dos inversores podem comprometer a resposta do controle, mesmo diante de pequenos erros de previsão. Isso reforça a necessidade de validar a robustez do modelo frente a diferentes condições operacionais.

Ajustes automatizados destacam o potencial das tecnologias para processar grandes volumes de dados e modernizar sistemas. A integração entre modelagem computacional e aplicação prática assegura a eficiência e estabilidade das microrredes. Futuros estudos incluirão circuitos maiores e novos modelos de *ML*, como aprendizado por reforço e métodos não supervisionados, para um controle de tensão mais inteligente e adaptável.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.


REFERÊNCIAS

- [1] J. P. M. Abuabud and P. H. A. Barra, "Estudo sistemático sobre microrredes e redes elétricas inteligentes," *Brazilian Journal of Development*, vol. 6, no. 9, pp. 65711–65727, 2020. DOI: 10.34117/bjd.v6n9-122.
- [2] N. Hatzigiorgiou, H. Asano, R. Irvani, and C. Marnay, "An overview of ongoing research, development, and demonstration projects," *IEEE Power & Energy Magazine*, vol. 5, no. 4, pp. 79–94, 2007. DOI: 10.1109/MPAE.2007.376583.
- [3] R. M. Soares and M. E. de Oliveira, "Microrredes: o conceito através da história, incentivos eo mercado brasileiro," *Simpósio Brasileiro de Sistemas Elétricos-SBSE*, vol. 2, no. 1, 2022. DOI: 10.20906/sbse.v2i1.2988.
- [4] E. B. d. Oliveira, R. M. Martins, G. Marchesan, J. Parizzi, and C. Lazaro, "Análise de utilização de controle volt-var em sistemas com grande penetração de geração fotovoltaica," in *15th Seminar on Power Electronics and Control (SEPOC 2023)*, Brasil, 2023. DOI: 10.53316/sepoc2023.035.
- [5] L. C. R. Junior, "Inversores inteligentes em sistemas fotovoltaicos para controle integrado de funções utilizando o opendss," Master's thesis, Universidade Federal de Itajubá (UNIFEI), 2018. Disponível em: <https://repositorio.unifei.edu.br/xmlui/handle/123456789/1757>.
- [6] L. P. Carlette, "Análise do impacto de inversores inteligentes aplicados a redes de baixa tensão." Disponível em: <https://pantheon.ufrj.br/handle/11422/9796>, 2019.
- [7] S. Sreekumar, D. S. Kumar, and J. Savier, "A case study on self healing of smart grid with islanding and inverter volt-var function," *IEEE Transactions on Industry Applications*, vol. 56, no. 5, pp. 5408–5416, 2020. DOI: 10.1109/TIA.2020.3011664.
- [8] A. P. C. de Mello, D. P. Bernadon, L. L. Pfitscher, and W. S. Hokama, "Controle volt/var coordenado para operação de sistemas de distribuição inteligentes," in *Congresso Brasileiro de Automática - CBA*, vol. 1, 2019. DOI: doi.org/10.20906/CBA2022/44.
- [9] H. A. Florez, G. P. López, E. M. Carreño-Franco, J. M. López-Lezama, and N. Muñoz-Galeano, "Application of intelligent systems in volt-var centralized control in modern distribution systems of electrical energy," *Electronics*, vol. 11, no. 3, p. 446, 2022. DOI: 10.3390/electronics11030446.
- [10] A. F. M. Jaramillo, J. Lopez-Lorente, D. M. Laverty, P. V. Brogan, S. H. H. Velasquez, J. Martinez-Del-Rincón, and A. M. Foley, "Distributed energy resources electric profile identification in low voltage networks using supervised machine learning techniques," *IEEE Access*, vol. 11, pp. 19469–19486, 2023. DOI: 10.1109/ACCESS.2023.3247977.
- [11] S. Suganthi, A. Vinayagam, V. Veerasamy, A. Deepa, M. Abouhawwash, and M. Thirumeni, "Detection and classification of multiple power quality disturbances in microgrid network using probabilistic based intelligent classifier," *Sustainable Energy Technologies and Assessments*, vol. 47, p. 101470, 2021. DOI: 10.1016/j.seta.2021.101470.
- [12] L. Zjavka, "Power quality daily predictions in smart off-grids using differential, deep and statistics machine learning models processing nwp-data," *Energy Strategy Reviews*, vol. 47, p. 101076, 2023. DOI: 10.1016/j.esr.2023.101076.
- [13] P. I. d. N. Barbalho, V. Lacerda, R. Fernandes, and D. V. Coury, "Deep reinforcement learning-based secondary control for microgrids in islanded mode," *Electric Power Systems Research*, vol. 212, p. 108315, 2022. DOI: 10.1016/j.epr.2022.108315.
- [14] L. de Carvalho Guerra, "Estratégia de gerenciamento de energia de microrrede baseada em algoritmo de otimização global," Master's thesis, Centro Universitário SENAI CIMATEC, Salvador, BA, 2023. Disponível em: <http://repositoriosenaiba.fieb.org.br/handle/fieb/1846>.
- [15] L. G. R. Bernardino, "Estimador seletivo do conteúdo harmônico de tensão e corrente baseado em rede neural profunda," Master's thesis, Universidade Federal de São Carlos, São Carlos, SP, 2022. Disponível em: <https://repositorio.ufscar.br/handle/ufscar/15941>.
- [16] G. Lopes Filho, R. A. P. Franco, F. H. T. Vieira, and C. A. G. Medeiros, "Algoritmo de controle de potência reativa para adequação de valores de tensão e redução de perdas em sistemas de distribuição," *Eletrônica de Potência*, vol. 26, no. 3, pp. 290–301, 2021. DOI: 10.18618/REP.2021.3.0014.
- [17] G. P. L. Sepúlveda, *Aplicação de inteligência computacional na resolução de problemas de sistemas elétricos de potência*. PhD thesis, Universidade Estadual Paulista (Unesp), 2017. Disponível em: <https://repositorio.unesp.br/handle/11449/151837>.
- [18] T. F. Santos and V. H. Ferreira, "Voltage control in microgrids with minimum adjustment in distributed generation units," in *2018 Simposio Brasileiro de Sistemas Elétricos (SBSE)*, pp. 1–6, 2018. DOI: 10.1109/SBSE.2018.8395876.
- [19] S. Gupta, V. Kekatos, and S. Chatzivassileiadis, "Optimal design of volt/var control rules of inverters using deep learning," *IEEE Transactions on Smart Grid*, vol. 15, no. 5, pp. 4731–4743, 2024. DOI: 10.1109/TSG.2024.3381984.
- [20] R. C. Marques, "Detecção de desequilíbrio de tensão em microrredes utilizando redes neurais perceptron," Master's thesis, Universidade Estadual Paulista (UNESP), 2022. Disponível em: <https://repositorio.unesp.br/handle/11449/234109>.
- [21] ANEEL, "Regras e procedimentos de distribuição (prodist)." Acessível online: <https://www.gov.br/aneel/pt-br/centrais-de-contenudos/procedimentos-regulatorios/prodist>, 2022. Acesso em: 15-08-2024.
- [22] F. de Carvalho Castro, "Distorção harmônica de corrente produzida por inversores fotovoltaicos conectados à rede," Master's thesis, Universidade Federal de Goiás (UFG), 2019. Disponível em: <http://repositorio.bc.ufg.br/tede/handle/tede/10152>.
- [23] R. M. Martins, "Impacto do controle de tensão e potência reativa (volt-var) em sistemas de distribuição com alta penetração de geração distribuída fotovoltaica," Master's thesis, Universidade Federal de Santa Maria (UFSM), 2023. Disponível em: <https://repositorio.ufsm.br/handle/1/28696>.
- [24] D. Van Zandt, "Mitigation methods to increase feeder hosting capacity 3002013382; epr report," *Electric Power Research Institute (EPRI): Palo Alto, CA, USA*, 2018.
- [25] A. Géron, *Mãos à Obra: Aprendizado de Máquina com Scikit-Learn & TensorFlow*. Alta Books, 2019.



Diego D. Domingues MSc. in Electronic and Computer Engineering at UCPel (2024), Pelotas, Brazil. Bachelor's degree in Electrical Engineering from UCPel (2018) and Technician in Electrotechnics from Instituto Federal Sul-Riograndense – IFSul (2009). He has experience in the areas of Electrical and Industrial Installations, Information Technology, Telecommunications Systems, Protection and Control of Power Systems, Automation and Renewable Energy Sources. His research interests are in Machine Learning, IoT, Microgrids, Power Systems,

Electrical and Electronic Circuits.



Sérgio J. M. Almeida (M'11) received the B.E.E. degree from the Federal University of Pernambuco (UFPE), Pernambuco, Brazil, in 1988, the M.Sc. degree in electrical engineering from Federal University of Paraíba (UFPB), Paraíba, Brazil, in 1991, and the Ph.D. degree in electrical engineering from the Federal University of Santa Catarina (UFSC), Florianópolis, Brazil, in 2004. He was a Postdoctoral in the Department of Electrical and Electronic Engineering at the Federal University of Santa Catarina, Brazil, from 2009 to 2010. Currently, he is a Professor of

electrical engineering and computer science of the Catholic University of Pelotas, Pelotas, Brazil. His research interests are in digital signal processing, including statistical signal processing, adaptive algorithm, hyperspectral image processing, and dedicated hardware for signal processing.



Eduardo A. C. Costa received the five-year engineering degree in Electrical Engineering from the University of Pernambuco, Recife, Brazil, in 1988, the M.Sc. degree in electrical engineering from the Federal University of Paraíba, Campina Grande, Paraíba, Brazil, in 1991, and the Ph.D. degree in computer science from the Universidade Federal do Rio Grande do Sul, Porto Alegre, Brazil, in 2002. Part of his doctoral work was developed at the Instituto de Engenharia de Sistemas Computadores (INESC-ID), Lisbon, Portugal. He is currently a Full

Professor at the Universidade Católica de Pelotas (UCPel), Pelotas, Brazil. He is co-founder and coordinator of the Graduate Program on Electronic Engineering and Computing at UCPel. His research interests are VLSI architectures and low-power design.