

DesagregaGD: uma ferramenta computacional para desagregação da curva de carga em redes com geração distribuída

Bruno Henrique da Silva Lima ^[1], Rafael Mendonça Rocha Barros ^{[2]*}

^[1] bhs11@discente.ifpe.edu.br, ^[2] rafael.barros@garanhuns.ifpe.edu.br. Departamento de Engenharia Elétrica, Instituto Federal de Pernambuco (IFPE), Garanhuns, PE, Brasil

* autor correspondente

Resumo

A expansão da Micro e Minigeração Distribuída (MMGD) no Brasil impõe o desafio do mascaramento da carga, fenômeno no qual a geração junto ao consumo oculta o comportamento real dos consumidores, alterando o perfil de demanda medido pelas distribuidoras. Após refutar a hipótese inicial de que o fenômeno degradava as previsões de carga do Operador Nacional do Sistema (ONS), a pesquisa foi redirecionada para o objetivo de desenvolver e validar uma ferramenta computacional, denominada DesagregaGD, para estimar a curva de carga real e quantificar o mascaramento. A metodologia baseou-se na geração de dados controlados por meio de simulações de fluxo de potência no software OpenDSS, modelando sistemas-teste do IEEE com e sem geração fotovoltaica. A partir desses dados, a ferramenta foi desenvolvida em JavaScript, aplicando a operação matemática fundamental: Carga Real = Carga Mascarada + Geração Distribuída. A validação foi estruturada em duas etapas para testar a robustez do método. Primeiramente, em sistemas-teste ideais, a ferramenta alcançou um Coeficiente de Determinação (R^2) de 0,9958 e um erro médio percentual de 1,5%. Em seguida, a validação foi estendida a um estudo de caso complexo, utilizando um modelo de alimentador real da Neoenergia com alta penetração de GD. Mesmo neste cenário, a aplicação manteve a alta precisão, atingindo um R^2 de 0,9929 e um erro médio percentual de 0,74%, confirmando sua eficácia em condições práticas. Como principal contribuição, o estudo entrega a aplicação web DesagregaGD, de código aberto, gratuita e com registro de software, oferecendo uma solução validada para o planejamento, a operação e o monitoramento de redes com alta presença de GD, contribuindo para uma gestão mais segura e eficiente do sistema elétrico.

Palavras-chave: ferramenta para computador; fluxo de potência; geração distribuída; mascaramento da carga; OpenDSS.

DesagregaGD: a computational tool for load curve disaggregation in grids with distributed generation

Abstract

The expansion of Micro and Minigeneration Distributed Generation (MMGD) in Brazil imposes the challenge of load masking, a phenomenon in which generation at the point of consumption hides the real behavior of consumers, altering the demand profile measured by utilities. After refuting the initial hypothesis that the phenomenon degraded the load forecasts of the National System Operator (ONS), the research was redirected towards the objective of developing and validating a computational tool, named DesagregaGD, to estimate the real load curve and quantify load masking. The methodology was based on the generation of controlled data through power flow simulations in the OpenDSS software, modeling IEEE test systems with and without photovoltaic generation. From this data, the tool was developed in JavaScript, applying the fundamental mathematical operation: Real Load = Masked Load + Distributed Generation. The validation was structured in two stages to test the method's robustness. First, on ideal test systems, the tool achieved a Coefficient of Determination (R^2) of 0.9958 and a mean percentage error of 1.5%. Next, the validation was extended to a complex case study, using a model of a real Neoenergia feeder with high DG penetration. Even in this scenario, the application maintained high accuracy, reaching an R^2 of 0.9929 and a mean percentage error of 0.74%, confirming its effectiveness in practical conditions. As the main contribution, the study delivers the DesagregaGD web application, which is open-source, free, and has registered software, offering a


validated solution for the planning, operation, and monitoring of grids with a high presence of DG, contributing to a safer and more efficient management of the electrical system.

Keywords: computer tool; distributed generation; load masking; OpenDSS; power flow.

1 Introdução

A transição energética global tem redefinido as bases dos sistemas elétricos de potência, catalisando uma mudança de paradigma na qual consumidores, antes considerados elementos passivos, emergem como agentes ativos. Este movimento é particularmente acentuado no Brasil, onde a Micro e Minigeração Distribuída (MMGD), impulsionada majoritariamente pela fonte solar fotovoltaica, experimenta um crescimento exponencial. Fomentado inicialmente pela Resolução Normativa nº 482/2012 (ANEEL, 2012), este avanço foi consolidado pela Lei nº 14.300/2022, o marco legal do setor (Brasil, 2022), e regulamentado em detalhe pela Resolução Normativa nº 1.000/2021 (ANEEL, 2021). Como resultado, a capacidade instalada saltou de 2,2 GW em 2019 para mais de 26 GW ao final de 2023, conforme apresentado na Figura 1 (EPE, 2025). Este cenário não é uma particularidade brasileira, mas um fenômeno global que impõe novos e complexos desafios operacionais às redes de distribuição.

Figura 1 – Evolução da capacidade instalada de MMGD acumulada no Brasil



Fonte: EPE (2025)

O desafio central que motiva este trabalho reside no fenômeno conhecido como “mascaramento da carga” (*load masking effect*). A geração de energia no mesmo ponto de consumo altera fundamentalmente o perfil de demanda líquida que é efetivamente medido pela concessionária, ocultando o comportamento real dos consumidores. Essa perda de visibilidade é uma consequência direta da crescente geração “atrás do medidor” (*behind-the-meter – BTM*) e compromete a gestão segura e eficiente da rede elétrica (Erdener *et al.*, 2022). A literatura recente demonstra que a alta penetração de geração fotovoltaica causa impactos técnicos severos, como sobretensões, sobrecargas em alimentadores e fluxos de potência reversos, que comprometem diretamente a qualidade e a estabilidade do fornecimento de energia (Razavi *et al.*, 2019; Torres; Negreiros; Tiba, 2019; Uzum *et al.*, 2021). Adicionalmente, o mascaramento degrada a acurácia dos modelos tradicionais de previsão de carga em nível local, que são cruciais para o planejamento da expansão e para a operação otimizada do sistema.

A crescente penetração da Geração Distribuída (GD) fotovoltaica tem gerado o fenômeno do “mascaramento da carga”, que, em cenários de alta injeção de energia, resulta em um fluxo de potência reverso (Majeed; Nwulu, 2022; Torres; Negreiros; Tiba, 2019). Essa condição, para a qual as redes de

distribuição não foram originalmente projetadas, é o gatilho para severos impactos técnicos que comprometem a estabilidade e a eficiência do sistema elétrico (Majeed; Nwulu, 2022; Santos, 2023). Estudos demonstram que o fluxo reverso causa violações nos níveis de tensão com sobretensões que ultrapassam os limites regulatórios (Castilhos; Donadel, 2022; Torres; Negreiros; Tiba, 2019), acelera a degradação de ativos como transformadores de distribuição (Majeed; Nwulu, 2022) e, paradoxalmente, pode aumentar significativamente as perdas elétricas na rede (Castilhos; Donadel, 2022; Torres; Negreiros; Tiba, 2019). Tais problemas, somados a distúrbios como as distorções harmônicas, consolidam-se em uma queda geral na qualidade da energia, afetando todos os consumidores conectados (Santos, 2023).

Diante deste cenário, para superar o desafio do mascaramento da carga, a comunidade científica tem se dedicado ao desenvolvimento de modelos avançados de desagregação, que buscam separar a geração fotovoltaica (PV) do consumo real a partir de dados de medição da carga líquida. Duas abordagens proeminentes ilustram bem esse esforço: uma baseada em um *framework* de aprendizado de máquina adaptativo, que transforma dados brutos em características estatísticas e temporais para treinar modelos de regressão (Saeedi *et al.*, 2021), e outra que emprega uma inovadora abordagem *data-driven* baseada em teoria dos jogos, utilizando uma “biblioteca de exemplares” de perfis de carga e geração para otimizar a separação dos sinais (Bu *et al.*, 2020).

Identifica-se, portanto, uma lacuna relevante: a carência de ferramentas computacionais que sejam, ao mesmo tempo, acessíveis, de baixo custo, de código aberto e que demandem dados de entrada facilmente disponíveis para as equipes de planejamento e operação das distribuidoras. Essa lacuna motivou o objetivo principal deste trabalho: o desenvolvimento e a validação de uma ferramenta computacional, denominada DesagregaGD, que se diferencia por sua simplicidade e aplicabilidade. O propósito da ferramenta é permitir que os diversos agentes do setor elétrico possam estimar a curva de carga real de seus alimentadores a partir de dados de medição da carga líquida e perfis de geração, de modo a identificar, visualizar e quantificar os efeitos do mascaramento da carga.

Para alcançar este objetivo, o artigo está estruturado da seguinte forma: a seção 2 detalha a fundamentação teórica; a seção 3 descreve a metodologia, incluindo o uso do software OpenDSS para geração de dados de validação, uma prática consolidada para estudos de impacto de GD (Costa, 2023); a seção 4 apresenta os resultados, desde a análise inicial até a validação da ferramenta em um estudo de caso real; e, por fim, a seção 5 expõe as conclusões, ressaltando as contribuições do trabalho para o setor elétrico.

2 Referencial teórico

Este capítulo reúne a fundamentação teórica necessária para compreender a problemática do mascaramento da carga e os métodos empregados em sua análise. Inicialmente, apresenta-se o conceito de MMGD e seus desdobramentos técnicos nas redes de distribuição. Em seguida, aprofunda-se a discussão sobre o fenômeno do mascaramento da carga, destacando seus impactos na operação, no planejamento e na confiabilidade do sistema elétrico. Por fim, aborda-se a importância das ferramentas de simulação computacional, com ênfase no fluxo de potência e no uso do software OpenDSS, amplamente consolidado na literatura como suporte para estudos de redes com alta penetração de GD.

2.1 Micro e minigeração distribuída no cenário brasileiro

A GD refere-se à produção de energia elétrica realizada junto ou próxima ao ponto de consumo, conectada diretamente à rede de distribuição da concessionária local. No Brasil, a modalidade ganhou forte impulso a partir da Resolução Normativa (REN) nº 482/2012 da Agência Nacional de Energia Elétrica (ANEEL), que estabeleceu as condições para o acesso de Microgeração (potência instalada menor ou igual a 75 kW) e Minigeração (potência superior a 75 kW e menor ou igual a 5 MW) à rede (ANEEL, 2012).

O principal mecanismo de incentivo criado por essa regulação foi o Sistema de Compensação de Energia Elétrica, que permite ao consumidor-gerador injetar o excedente de energia na rede e receber créditos em energia (kWh) para abater do seu consumo futuro ou de outro estabelecimento de sua titularidade. A evolução desse marco regulatório culminou na Lei nº 14.300/2022, que trouxe maior

segurança jurídica e novas diretrizes para a remuneração dos ativos da rede de distribuição, mas manteve a estrutura fundamental que permitiu a expansão massiva da GD no país (Brasil, 2022).

2.2 O mascaramento da carga e seus impactos técnicos na rede elétrica

O fenômeno do mascaramento da carga (*load masking* ou *load hiding*) surge da crescente penetração da MMGD, sobretudo de fonte solar fotovoltaica. Em uma unidade consumidora com geração própria, parte ou toda a energia produzida é consumida localmente no instante da geração, configurando o autoconsumo. Esse processo, embora benéfico para o consumidor, oculta da distribuidora o perfil real de consumo, uma vez que apenas a energia injetada ou retirada da rede é registrada pelos medidores bidirecionais, no regime de medição líquida (*net metering*) (Chen; Haji; Ardakanian, 2021; Erdener *et al.*, 2022). Assim, a parcela autoconsumida permanece “atrás do medidor” e torna-se invisível para os operadores do sistema, caracterizando o mascaramento da carga.


Esse efeito implica uma mudança estrutural no fluxo de energia elétrica: redes tradicionalmente radiais e unidirecionais passam a operar de forma bidirecional, com consumidores atuando também como produtores, os chamados prosumidores (Marcon, 2021; Pereira, 2022). Como a geração distribuída é, em grande parte, não supervisionada pelas distribuidoras, há perda de visibilidade e controle sobre o comportamento dinâmico da demanda.

Do ponto de vista da concessionária, o mascaramento da carga altera o perfil de demanda líquida medido no ponto de acoplamento comum (PCC), seja na unidade consumidora ou na saída da subestação. A demanda líquida ($D_{líquida}$), que é a carga que a concessionária efetivamente “enxerga” e precisa suprir, é o resultado da diferença entre a demanda bruta real dos consumidores (D_{real}) e a geração distribuída local (G_{GD}), conforme a Equação 1 (Chen; Haji; Ardakanian, 2021; Erdener *et al.*, 2022):

$$D_{líquida}(t) = D_{real}(t) - G_{GD}(t) \quad (1)$$

Este fenômeno cria um novo perfil de demanda com maior variabilidade e rampas mais acentuadas. A representação clássica deste efeito é a “Curva Pato” (*Duck Curve*), apresentada na Figura 2, termo que foi popularizado pelo Operador do Sistema Independente da Califórnia (CAISO, 2016). Embora o conceito original tenha mais de uma década, sua relevância apenas aumentou, com estudos recentes analisando sua intensificação e os desafios operacionais associados, como a necessidade de recursos de geração flexíveis para compensar a rápida queda da geração solar no final da tarde. Além do desafio operacional, o mascaramento da carga compromete a precisão dos modelos de previsão de demanda em nível local, que são fundamentais para o planejamento e a gestão de ativos da distribuição. A superação desse desafio de visibilidade tem motivado o desenvolvimento de diversas técnicas de desagregação de carga, muitas baseadas em modelos estatísticos e de aprendizado de máquina.

Figura 2 – “Curva Pato” (*Duck Curve*)



Fonte: CAISO (2016)

Como a Figura 2 evidencia, a “barriga do pato” representa a carga líquida drasticamente reduzida nos horários de pico solar, enquanto o “pescoço” representa a rampa extremamente acentuada no final da tarde, quando a geração solar decai rapidamente e a demanda noturna começa a aumentar. No caso da Califórnia, essa rampa chegou a exigir a retomada de 13 GW de carga em apenas três horas (Pereira, 2022). Este comportamento representa um grande desafio para a operação do sistema, exigindo recursos de geração flexíveis para acompanhar as rápidas variações de carga e podendo levar a um despacho de geração subótimo.

Do ponto de vista técnico, os impactos mais relevantes do mascaramento incluem:

- **Previsão de carga comprometida:** os modelos estatísticos tradicionais, baseados em séries históricas, deixam de refletir a carga real, pois a geração solar aparece como uma “carga negativa”. Isso degrada a precisão de projeções locais e prejudica o planejamento da expansão da rede (Chen; Haji; Ardakanian, 2021; Erdener *et al.*, 2022).
- **Alteração do perfil de tensão:** em situações de fluxo reverso de potência (*Reverse Power Flow* – RPF), quando a geração local excede a carga, a energia flui em direção à subestação, elevando os níveis de tensão e podendo ultrapassar os limites regulatórios, com consequências para equipamentos e inversores conectados (Razavi *et al.*, 2019; Uzum *et al.*, 2021).
- **Perdas elétricas:** estudos apontam que a relação entre penetração da MMGD e perdas é não linear. Inicialmente, a geração próxima ao consumo reduz perdas por efeito Joule; contudo, acima de um nível ótimo, o aumento do RPF faz as perdas crescerem novamente, podendo superar as de um sistema sem GD (Salimon *et al.*, 2023).
- **Qualidade da energia:** a conexão em massa de inversores introduz harmônicos e supra-harmônicos, além de flutuações rápidas e lentas de tensão, afetando cargas sensíveis e reduzindo a vida útil de equipamentos (Smith *et al.*, 2017; Uzum *et al.*, 2021).
- **Confiabilidade dos sistemas de proteção:** a inserção da GD altera a seletividade e a coordenação das proteções. Entre os principais problemas estão: aumento do nível de curto-circuito, atuação indevida de dispositivos de proteção (operações simpáticas), cegueira da proteção (*protection blinding*), além do risco deilhamento não intencional, que compromete a segurança de equipes e consumidores (Razavi *et al.*, 2019).

Esses efeitos demonstram que o mascaramento da carga não é apenas um problema de visibilidade de dados, mas um fenômeno que impacta diretamente o planejamento, a operação e a proteção das redes de distribuição. A mitigação de seus impactos exige soluções inovadoras, como controle de potência reativa por inversores inteligentes, sistemas de armazenamento de energia e algoritmos de desagregação que permitam recuperar o perfil real de demanda.

2.3 Estudos e abordagens para a desagregação da geração fotovoltaica atrás do medidor

A crescente necessidade de “enxergar” a geração fotovoltaica (FV) instalada “atrás do medidor” impulsionou uma vasta pesquisa focada no desenvolvimento de métodos de desagregação. Esses métodos buscam separar a geração FV da demanda nativa a partir de um único sinal de medição: a demanda líquida, que é o que os medidores inteligentes convencionais registram (Bu *et al.*, 2020). A literatura sobre o tema pode ser categorizada em duas abordagens principais: métodos baseados em modelos físicos e métodos orientados a dados.

Os métodos baseados em modelos físicos utilizam modelos paramétricos que descrevem o comportamento de um sistema FV para estimar sua geração. Essa abordagem requer um conjunto detalhado de informações, incluindo dados meteorológicos (como irradiância e temperatura), a localização geográfica precisa da instalação e as características físicas dos painéis, como eficiência, inclinação e orientação (azimute) (Bu *et al.*, 2020).

A principal desvantagem dessa abordagem reside na dificuldade de obter parâmetros precisos e confiáveis. Muitas vezes, as informações sobre as instalações de MMGD não estão disponíveis ou são incertas, um problema agravado pela existência de instalações não autorizadas, que não são formalmente registradas junto à distribuidora (Bu *et al.*, 2020). Além disso, esses modelos são

vulneráveis a superestimar grosseiramente a geração em casos de falhas parciais ou totais do sistema FV, pois o modelo físico não tem como saber que o sistema está fora de operação (Bu *et al.*, 2020).

Com a ampla implantação da infraestrutura de medição avançada (AMI), as distribuidoras passaram a ter acesso a um grande volume de dados de medidores inteligentes, o que viabilizou o desenvolvimento de métodos de desagregação orientados a dados (Bu *et al.*, 2020). Essas técnicas utilizam algoritmos de aprendizado de máquina e métodos estatísticos para identificar padrões e correlações nos dados e, a partir deles, estimar a geração FV.

A literatura científica recente tem explorado intensamente o desafio da desagregação da carga, comumente recorrendo a abordagens de alta complexidade. Métodos baseados em aprendizado de máquina (*machine learning*) e Monitoramento de Carga Não Intrusivo (NILM), por exemplo, utilizam algoritmos sofisticados para estimar a geração fotovoltaica a partir de dados agregados (Chen; Haji; Ardakanian, 2021).

Um exemplo notável é o *framework* de aprendizado de máquina adaptativo proposto por Saeedi *et al.* (2021), que transforma dados brutos de medição em características estatísticas e temporais para treinar modelos de regressão, alcançando alta precisão. Contudo, essa abordagem depende da disponibilidade de medições diretas da geração em alguns pontos da rede para servir como *ground truth* durante o treinamento dos modelos. De forma similar, a abordagem de Bu *et al.* (2020) emprega uma sofisticada metodologia baseada em teoria dos jogos, que utiliza uma “biblioteca de exemplares” com perfis típicos de carga e geração para otimizar a separação dos sinais. A eficácia desse método, no entanto, está condicionada à existência de dados de consumidores “totalmente observáveis” – aqueles com medição apartada de consumo e geração – para a construção dessa biblioteca.

Outros pesquisadores, como Sossan *et al.* (2018), desenvolveram abordagens não supervisionadas que não requerem medições diretas da geração FV para treinamento. Esses métodos utilizam o conhecimento estrutural do sistema e medições ambientais, como a irradiância, para desagregar os sinais (Saeedi *et al.*, 2021).

Tais pré-requisitos, comuns a muitas técnicas avançadas, representam barreiras significativas para a aplicação em larga escala pelas concessionárias, que frequentemente não dispõem de medições tão granulares ou de um vasto histórico de dados para calibração de modelos complexos (Qu *et al.*, 2025).

A combinação de dados de múltiplas fontes, como medidores inteligentes, SCADA, e sensores meteorológicos, dentro de um *framework* de aprendizado de máquina, tem se mostrado uma abordagem poderosa e flexível para aumentar a visibilidade da geração BTM e, consequentemente, a segurança e eficiência da operação da rede de distribuição (Saeedi *et al.*, 2021).

2.4 Simulação de fluxo de potência com OpenDSS

A análise de fluxo de potência é uma das ferramentas mais importantes no estudo de sistemas elétricos, pois permite determinar a distribuição de tensões, correntes e fluxos de potência em condições normais de operação. Com o avanço da geração distribuída, especialmente a solar fotovoltaica, tornou-se fundamental utilizar simuladores capazes de representar redes de distribuição desbalanceadas, com múltiplos pontos de geração e perfis temporais de carga.

Nesse contexto, destaca-se o *Open Distribution System Simulator* (OpenDSS), um software de código aberto desenvolvido pelo Electric Power Research Institute (EPRI), amplamente adotado em estudos de redes de distribuição devido à sua flexibilidade e capacidade de modelagem (Gao *et al.*, 2017; Guerra; Martínez-Velasco, 2018). O OpenDSS suporta a simulação em regime quase-estático no domínio do tempo, permitindo incorporar variações horárias de carga e geração, o que o torna adequado para avaliar impactos associados à penetração da GD, como rampas de potência e mascaramento da carga.

Entre suas principais vantagens, destacam-se:

- Versatilidade de aplicação, uma vez que pode ser utilizado para estudos de fluxo de potência, curto-circuito, confiabilidade, qualidade da energia e análises probabilísticas (Hariri; Newaz; Faruque, 2017; Guerra; Martínez-Velasco, 2018).

- Integração com outras plataformas como MATLAB e Python, facilitando a aplicação de metodologias avançadas, como simulações probabilísticas e métodos de Monte Carlo (Tello-Maita; Marulanda; Pavas, 2019).
- Capacidade de operação em tempo real (RT-HIL), por meio de integração com hardware externo, permitindo validação experimental e desenvolvimento de estratégias de automação da distribuição (Montenegro; Hernandez; Ramos, 2012).


Na literatura recente, o OpenDSS vem sendo consolidado como uma ferramenta de referência em pesquisas de GD e redes inteligentes. Tello-Maita, Marulanda e Pavas (2019) empregaram o software para realizar estudos probabilísticos de fluxo de potência em sistemas de distribuição com alta penetração fotovoltaica, enquanto Montenegro, Hernandez e Ramos (2012) destacaram seu uso integrado a plataformas de simulação em tempo real. Revisões sistemáticas reforçam sua relevância e ampla aceitação pela comunidade científica (Hariri; Newaz; Faruque 2017; Guerra; Martínez-Velasco, 2018).

Assim, a adoção do OpenDSS neste trabalho é justificada não apenas por sua robustez na modelagem de sistemas de distribuição com geração distribuída, mas também pelo reconhecimento consolidado de sua aplicabilidade em estudos de fluxo de potência e análise de impactos técnicos em redes elétricas modernas, permitindo a geração de dados controlados para o desenvolvimento e a validação da ferramenta DesagregaGD.

3 Metodologia

A presente pesquisa foi conduzida por meio de uma abordagem quantitativa e aplicada, desenvolvida em etapas sequenciais e interdependentes. A estrutura metodológica foi desenhada para, inicialmente, explorar uma hipótese sobre os impactos da GD em escala macro e, subsequentemente, direcionar o foco para o desenvolvimento e a validação de uma solução tecnológica para um problema prático em nível de rede de distribuição. O fluxo de trabalho, ilustrado na Figura 3, foi dividido em quatro fases principais, que são detalhadas a seguir.

Figura 3 – Fluxograma da metodologia utilizada



Fonte: elaborada pelos autores

3.1 Fase 1: análise exploratória da previsão de carga do ONS

A fase inicial do projeto consistiu em uma análise exploratória para verificar a hipótese de que a crescente inserção da MMGD no Sistema Interligado Nacional (SIN) estaria correlacionada a um aumento nos erros de previsão de carga do Operador Nacional do Sistema Elétrico. Para esta etapa, foram coletados dados públicos das notas técnicas do ONS, compreendendo o período de 2019 a 2024. Após o tratamento dos dados, foram calculadas métricas estatísticas de desempenho para avaliar a assertividade das previsões. As métricas selecionadas, como o Coeficiente de Determinação (R^2), a Raiz do Erro Quadrático Médio (RMSE) e o Erro Percentual Absoluto Médio (MAPE), são amplamente utilizadas na literatura para quantificar a aderência de modelos de previsão e estimação no setor elétrico. Adicionalmente, utilizou-se o Coeficiente de Correlação de Spearman para avaliar a relação monotônica entre a capacidade instalada de MMGD e a evolução dos erros.

3.2 Fase 2: simulação e geração de dados para o estudo do mascaramento

A segunda etapa da metodologia consistiu na realização de simulações computacionais utilizando o software OpenDSS. Essa fase teve como finalidade gerar dados sintéticos para validação

da ferramenta proposta, permitindo a análise controlada dos efeitos da inserção da geração distribuída fotovoltaica no perfil de carga líquida.

O uso de sistemas-teste padronizados, como o IEEE 13 barras, é prática consolidada na literatura, pois fornece um ambiente validado para avaliar o desempenho de metodologias em diferentes cenários de penetração de geração distribuída (Kersting, 2001). Esses sistemas possibilitam a reprodução de condições operacionais realistas, como desbalanceamento de fases, conexões monofásicas e variação de carregamento.

O OpenDSS, desenvolvido pelo Electric Power Research Institute (EPRI), foi projetado especificamente para a análise de redes de distribuição. Sua flexibilidade em simular fluxos de potência trifásicos desbalanceados, estudos no domínio do tempo e integração com linguagens de programação externas (como Python e MATLAB) o consolidaram como ferramenta de referência para estudos de impacto de fontes renováveis em redes de baixa e média tensão (Dugan; McDermott; Ball, 2001).

No contexto brasileiro, diferentes trabalhos empregaram o OpenDSS para avaliar os impactos técnicos da penetração fotovoltaica em alimentadores reais, demonstrando sua eficácia em reproduzir cenários de sobrecarga de transformadores, fluxo reverso de potência e variações de tensão (Costa, 2023; Oliveira; Oliveira; Silva, 2021). Tais estudos reforçam a adequação da ferramenta para analisar o fenômeno do mascaramento da carga e validar soluções computacionais voltadas às distribuidoras.

3.3 Fase 3: desenvolvimento da ferramenta computacional DesagregaGD

Esta fase concentrou-se no desenvolvimento do principal produto tecnológico do trabalho: a aplicação web DesagregaGD. A ferramenta foi concebida para ser uma solução de baixo custo, acessível e intuitiva. Para seu desenvolvimento, foram empregadas tecnologias web padrão: HTML para a estruturação da interface do usuário, CSS para a estilização visual e JavaScript para toda a lógica de programação. A biblioteca Chart.js foi integrada para a geração de gráficos interativos e customizáveis, essenciais para a visualização dos resultados.

A literatura recente apresenta diversas abordagens para o problema da desagregação da carga. Técnicas de *Non-Intrusive Load Monitoring* (NILM) e algoritmos de aprendizado de máquina têm sido amplamente empregados, utilizando redes neurais artificiais, *Hidden Markov Models* e métodos híbridos físico-estatísticos para identificar padrões de consumo e estimar a geração fotovoltaica a partir de dados agregados (Bu *et al.*, 2020; Chen; Haji; Ardakanian, 2021). Embora apresentem bons resultados, essas metodologias frequentemente requerem grandes volumes de dados históricos, medições em alta granularidade ou infraestrutura avançada de medição, o que representa barreiras para sua aplicação em larga escala por concessionárias (Qu *et al.*, 2025).

Diante dessas limitações, optou-se por uma abordagem mais simples e prática, fundamentada no uso de perfis típicos de geração fotovoltaica e dados de carga líquida já disponíveis pelas distribuidoras. Essa escolha se justifica pela busca de uma solução replicável e escalável, capaz de ser aplicada mesmo em contextos onde não há infraestrutura avançada de medição, garantindo maior aderência à realidade brasileira. Abordagens similares já têm sido exploradas em estudos que enfatizam a importância de ferramentas de código aberto e metodologias simplificadas para aumentar a aplicabilidade em diferentes sistemas (Gao *et al.*, 2024; Martins; Castelo Branco; Hallack, 2022).

A implementação da ferramenta também priorizou a transparência metodológica e a reprodutibilidade científica, alinhando-se ao movimento de utilização de softwares livres e metodologias abertas no setor elétrico. Com isso, a DesagregaGD se diferencia por oferecer uma solução prática e confiável, sem abrir mão da fundamentação teórica necessária para lidar com o mascaramento da carga.

O núcleo da ferramenta é o seu algoritmo de desagregação, implementado em JavaScript. O algoritmo executa os seguintes passos:

1. **Entrada de dados:** A interface permite que o usuário forneça os dados de entrada necessários: um arquivo .csv contendo a curva de carga mascarada (medida), um arquivo .csv com a curva de geração ou irradiância solar, a potência total instalada de GD (em kW), a eficiência média dos sistemas fotovoltaicos e o percentual de distribuição dessa potência entre as três fases da rede.

2. **Processamento:** O algoritmo primeiramente normaliza e interpola a curva de geração para um perfil diário detalhado. Em seguida, calcula a curva de geração de GD em kW, escalonando o perfil normalizado pela potência instalada e eficiência informadas.
3. **Cálculo da carga real:** A curva de carga real é estimada por meio da aplicação da operação matemática fundamental, ponto a ponto para cada intervalo de tempo e para cada uma das fases, conforme a Equação 2.

$$Carga_{real}(t) = Carga_{mascarada}(t) + Geração_{GD}(t) \quad (2)$$

4. **Saída de resultados:** A ferramenta apresenta os resultados em múltiplos formatos, incluindo métricas de análise (como energia total gerada e mascarada), gráficos interativos que comparam as curvas de carga (real e mascarada) e botões que permitem ao usuário exportar todos os dados processados para novos arquivos .csv, garantindo a interoperabilidade com outros softwares.

É importante ressaltar que a DesagregaGD opera a partir da curva de carga agregada do alimentador, geralmente medida na saída da subestação. A ferramenta não se propõe a construir curvas de carga por setor de consumo (ex: residencial, comercial), mas sim a desagregar o sinal total já medido pela concessionária. Embora a interface permita ao usuário uma distribuição percentual da GD pelas três fases, a abordagem principal trata a potência de forma agregada, sendo este um ponto de partida para análises mais complexas.

3.4 Fase 4: validação, implementação e registro

A última etapa da metodologia correspondeu à validação da ferramenta DesagregaGD, realizada por meio da comparação entre as curvas de carga estimadas e os valores de referência obtidos a partir das simulações computacionais e do estudo de caso real. O objetivo foi avaliar a capacidade da ferramenta em reproduzir adequadamente o perfil de demanda real, mitigando os efeitos do mascaramento da carga.

Para essa validação, foram utilizadas métricas amplamente reconhecidas na literatura para avaliação de modelos de previsão e estimação em sistemas elétricos:

- **Coefficiente de Determinação (R^2):** quantifica a proporção da variabilidade dos dados observados explicada pelo modelo, sendo um dos indicadores mais utilizados em estudos de desempenho preditivo (Chai; Draxler, 2014). Valores mais próximos de 1 indicam um ajuste perfeito do modelo aos dados observados.
- **Raiz do Erro Quadrático Médio (RMSE):** mede o desvio médio quadrático entre valores previstos e observados, sendo sensível a erros de maior magnitude, característica relevante em estudos de previsão de carga (Hong; Fan, 2016).
- **Erro Percentual Absoluto Médio (MAPE):** expressa o erro médio em termos percentuais, permitindo uma avaliação relativa da acurácia, bastante utilizada em aplicações energéticas e de séries temporais (Hyndman; Koehler, 2006).
- **Coefficiente de Correlação de Spearman:** utilizado para avaliar a dependência monotônica entre duas variáveis, sendo adequado para verificar a relação entre a expansão da MMGD e os erros de previsão (Spearman, 1904). Este coeficiente varia de -1 (associação negativa perfeita) a +1 (associação positiva perfeita), onde 0 indica ausência de correlação monotônica.

A combinação dessas métricas garante uma avaliação abrangente da ferramenta, contemplando tanto a aderência estatística quanto a robustez em diferentes cenários de análise. Essa abordagem segue práticas consolidadas em estudos de previsão de carga e validação de modelos em sistemas de energia (Weron, 2014; Stratman *et al.*, 2022).

O processo de validação foi estruturado em duas etapas complementares para testar tanto a precisão matemática quanto a aplicabilidade prática do algoritmo.

- a. **Validação em sistemas-teste:** Primeiramente, o algoritmo foi verificado utilizando os dados controlados gerados na Fase 2 a partir do sistema-teste IEEE 13 barras. A curva de carga mascarada simulada foi inserida como entrada na DesagregaGD, e a curva real estimada pela ferramenta foi comparada com a curva real conhecida da simulação. Esta etapa serviu para verificar a correção matemática e a precisão do algoritmo em um ambiente idealizado.
- b. **Validação em estudo de caso real:** Para comprovar a robustez da ferramenta em um cenário complexo, uma segunda validação foi realizada utilizando o modelo de um alimentador real da Neoenergia Pernambuco, com alta penetração de GD. O modelo utilizado foi desenvolvido e previamente tratado a partir de dados da Base de Dados Geográfica da Distribuição (BDGD), conforme detalhado por Silva e Barros (2025). A aderência entre a curva estimada e a curva real simulada para este caso foi quantificada por meio do Coeficiente de Determinação (R^2) e do Erro Percentual (MAPE), métricas padrões para validação de modelos.

Com a validação concluída, a ferramenta computacional foi implementada e disponibilizada de forma pública e gratuita no repositório do Grupo de Estudos em Sistemas Elétricos (GSEL) do IFPE, Campus Garanhuns (IFPE, 2025). Por fim, para formalizar a autoria e assegurar os direitos de propriedade intelectual, foi realizado o registro do software junto ao Instituto Nacional da Propriedade Industrial (INPI), sob o N° BR512025003011-8.

4 Resultados e discussões

Esta seção apresenta os resultados obtidos ao longo das quatro fases da pesquisa. A análise é apresentada de forma sequencial, iniciando com os achados da investigação exploratória sobre a previsão de carga, seguida pela caracterização do mascaramento via simulação, a apresentação da ferramenta desenvolvida e, por fim, a validação de sua acurácia.

4.1 Análise da previsão de carga do sistema interligado nacional

A investigação inicial buscou validar a hipótese de que o crescimento da MMGD estaria degradando a qualidade das previsões de carga do ONS. Foram analisados os dados de previsão e de carga verificada para o SIN entre os anos de 2019 e 2024. A Tabela 1 consolida as métricas de erro calculadas, enquanto a Tabela 2 apresenta os coeficientes de correlação de Spearman entre a capacidade instalada de MMGD e as referidas métricas.

Tabela 1 – Erros entre previsão de carga e carga verificada

ANO	Capacidade instalada de MMGD (MW)	Carga prevista (MWh)	Carga verificada (MWh)	Raiz do Erro Quadrático Médio (RMSE)	Erro Percentual Absoluto Médio (MAPE)	Coeficiente de Determinação (R^2)
2019	2.314	68.922	64.611	4.738,94	7,05	0,78
2020	5.309	70.830	63.420	8.206,42	12,15	0,52
2021	10.048	69.095	68.539	1.565,34	1,71	0,65
2022	18.356	70.758	68.823	2.394,03	2,97	0,76
2023	26.627	71.760	73.705	4.265,45	4,54	0,16
2024	36.169	78.923	78.460	1.334,18	1,23	0,83

Fonte: dados da pesquisa

Tabela 2 – Coeficientes de Spearman

Descrição da Correlação	Valor
Coeficiente de Spearman entre capacidade instalada de MMGD e RMSE	-0,710
Coeficiente de Spearman entre capacidade instalada de MMGD e MAPE	-0,710
Coeficiente de Spearman entre capacidade instalada de MMGD e R^2	0,085

As Tabelas 1 e 2 evidenciam que não há perda de qualidade na previsão de carga do SIN em função do aumento da MMGD. Os resultados demonstram que, mesmo com o expressivo crescimento da capacidade instalada de geração distribuída fotovoltaica ao longo do período analisado – atingindo 36.169 MW em 2024 –, os indicadores de acurácia das previsões mantiveram-se consistentes e até aprimorados. O ano de 2024, que apresentou a maior capacidade de MMGD, registrou os melhores indicadores de todo o intervalo: o menor RMSE (1.334,18), o menor MAPE (1,23%) e o maior Coeficiente de Determinação ($R^2 = 0,83$). Esses resultados indicam que as metodologias de previsão utilizadas pelo ONS são robustas o suficiente para absorver as variações impostas pela penetração da GD, sem prejuízo significativo à acurácia em escala nacional.

Contudo, sob a ótica do sistema de distribuição, o cenário se apresenta de maneira distinta. Embora a análise em nível sistêmico não aponte degradação das previsões globais de carga, o avanço da GD implica no mascaramento da demanda real nos alimentadores de média e baixa tensão, ocultando o comportamento efetivo das cargas conectadas à rede. Esse mascaramento pode levar à interpretação equivocada de retração no consumo ou de redução na taxa de crescimento da demanda, quando, na realidade, parte significativa da energia está sendo suprida localmente pela geração fotovoltaica. Assim, enquanto os modelos de previsão do ONS mantêm desempenho satisfatório em escala macro, as distorções provocadas pela GD emergem em escala granular, impactando diretamente as concessionárias de distribuição.

Dessa forma, os resultados reforçam que, embora a expansão da MMGD não tenha degradado a qualidade das previsões de carga do SIN, os efeitos de mascaramento em nível local permanecem relevantes. O foco do presente trabalho, portanto, foi redirecionado para o desenvolvimento de uma metodologia voltada à desagregação e compreensão da carga em nível de alimentador, onde o fenômeno de mascaramento se manifesta de maneira concreta e influencia o planejamento, a operação e a confiabilidade do sistema de distribuição.

4.2 Caracterização do mascaramento da carga via simulação

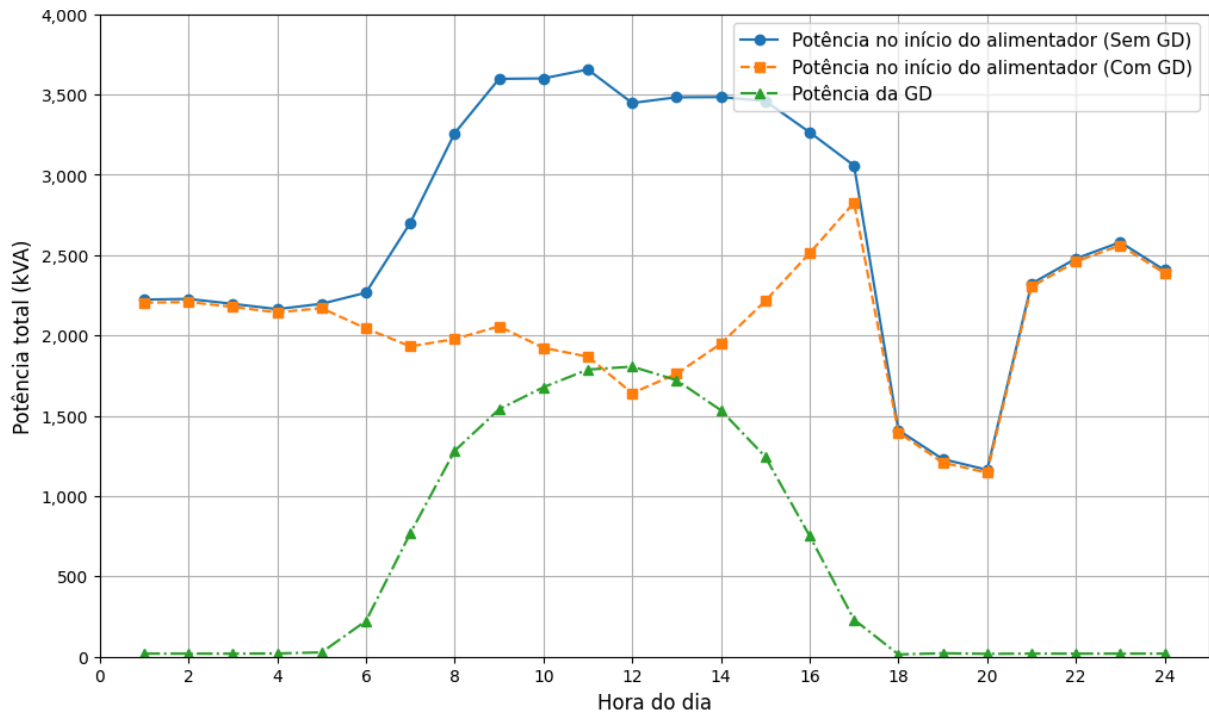
Para caracterizar o impacto da Geração Distribuída em nível local, foram conduzidas simulações de fluxo de potência na plataforma OpenDSS. A Figura 4 exibe os resultados consolidados de uma simulação diária no sistema-teste IEEE 13 barras, apresentando três curvas de potência distintas.

A curva “Carga Real” (azul) representa a demanda do sistema sem a presença de GD, obtida no cenário de base. A curva “Geração Fotovoltaica” (verde) demonstra o perfil de geração dos painéis solares ao longo do dia, com pico de produção ao meio-dia. Por fim, a curva “Carga Mascarada” (laranja) representa a potência líquida que seria medida na subestação, ou seja, a demanda real já abatida pela geração solar local.

Para garantir a fidedignidade e a reprodutibilidade dos dados desta simulação, os sistemas fotovoltaicos no modelo IEEE 13 barras não foram modelados com uma eficiência média fixa. Em vez disso, foi utilizada uma abordagem dinâmica detalhada, baseada nos seguintes componentes:


- Uma curva de eficiência vs. irradiância, apresentada na Figura 5, que define a eficiência do sistema entre 86% e 97%, sendo mais alta em níveis de maior irradiância.
- Uma curva de potência vs. temperatura, exibida na Figura 6, que aplica um *derating* (redução) na potência de saída à medida que a temperatura da célula aumenta, partindo do ponto de referência de 100% de potência a 25 °C.
- Um perfil diário de temperatura da célula, detalhado na Figura 7, que representa a variação térmica esperada ao longo do dia e alimenta a curva de *derating*.

Figura 4 – Comparação das curvas de potência com e sem geração distribuída




Fonte: elaborada pelos autores

Figura 5 – Curva de eficiência vs. irradiância utilizada na simulação OpenDSS para o sistema de IEE 13 barras




Fonte: elaborada pelos autores

Figura 6 – Curva de potência vs. temperatura utilizada na simulação OpenDSS para o sistema de IEE 13 barras



Fonte: elaborada pelos autores

Figura 7 – Curva diária de temperatura da célula utilizada na simulação OpenDSS para o sistema de IEE 13 barras



Fonte: elaborada pelos autores

Para garantir a transparência metodológica e a contextualização dos resultados, é fundamental esclarecer a composição da curva “Carga Real” (azul). Esta curva não é um perfil de carga único e simplificado. Ela é o resultado agregado medido no início do alimentador, resultante da soma das 15 cargas individuais definidas no sistema-teste.

Para garantir um cenário heterogêneo e realista, 10 perfis de carga (*loadshapes*) distintos de média tensão para dia útil foram aplicados a essas cargas, conforme a Figura 8. Estes perfis foram modelados a partir dos dados da campanha de medições reais da Neoenergia Pernambuco, disponibilizados na Consulta Pública ANEEL 003/2021. Portanto, a curva “Carga Real (Sem GD)” representa a soma complexa desses 10 perfis de carga distintos, operando de forma desbalanceada. A


curva “Geração Fotovoltaica” (verde) é o resultado do modelo PV detalhado, e a curva “Carga Mascarada” (laranja) é o resultado líquido da interação entre essa demanda heterogênea e a GD. Na Tabela 3, são apresentadas as configurações das cargas utilizadas para o caso base.

Tabela 3 – Cargas simuladas para o Sistema IEEE 13 barras

Identificação da carga	Barra	Fases	Conexão	Modelo	Perfil	kV	kW	kVAr
671	671.1.2.3	3φ	Δ	1	MT1_DU	4,16	1155	660
634a	634.1	1φ	Y	1	MT2_DU	0,28	160	110
634b	634.2	1φ	Y	1	MT3_DU	0,28	120	90
634c	634.3	1φ	Y	1	MT4_DU	0,28	120	90
645	645.2	1φ	Y	1	MT5_DU	2,4	170	125
646	646.2.3	2φ	Δ	2	MT6_DU	4,16	230	132
692	692.3.1	2φ	Δ	5	MT7_DU	4,16	170	151
675a	675.1	1φ	Y	1	MT8_DU	2,4	485	190
675b	675.2	1φ	Y	1	MT9_DU	2,4	68	60
675c	675.3	1φ	Y	1	MT10_DU	2,4	290	212
611	611.3	1φ	Y	5	MT1_DU	2,4	170	80
652	652.1	1φ	Y	2	MT2_DU	2,4	128	86
670a	670.1	1φ	Y	1	MT3_DU	2,4	17	10
670b	670.2	1φ	Y	1	MT4_DU	2,4	66	38
670c	670.3	1φ	Y	1	MT5_DU	2,4	117	68

Fonte: elaborada pelos autores

Figura 8 – Perfis de carga de média tensão (dia útil) utilizados na simulação



Fonte: elaborada pelos autores

Assim, os resultados obtidos confirmam a pertinência do uso do OpenDSS como ambiente de validação da ferramenta proposta, uma vez que possibilita avaliar cenários operacionais diversos e quantificar de forma detalhada os impactos técnicos da MMGD.

4.3 A ferramenta DesagregaGD como solução proposta

A partir do entendimento do fenômeno, o foco da pesquisa se concentrou no desenvolvimento do principal produto tecnológico deste trabalho: a ferramenta web DesagregaGD. Seu objetivo central é restaurar a visibilidade da curva de carga real, a partir de dados de carga líquida e perfis de geração fotovoltaica, possibilitando compreender de forma mais precisa o comportamento dos consumidores. A Figura 9 apresenta a tela inicial da aplicação, destacando a simplicidade da interface para a entrada de dados.

Figura 9 – Interface principal da ferramenta DesagregaGD

DesagregaGD
Ferramenta para Determinação da Carga Elétrica Real em Alimentadores com Penetração de Geração Distribuída

Aplicação Sobre Exemplos

Configurações e Uploads

Curva de Irradiância Solar (.csv):
Escolher arquivo Nenhum arquivo escolhido
Forneça ao menos 1 ponto. Se mais de 1, serão interpolados para 144 pontos em 24h.

Potência Instalada da GD (kW):
Ex: 50

Eficiência média dos sistemas fotovoltaicos (0 a 1):
0.2

Curva de potência no início do alimentador:
Escolher arquivo Nenhum arquivo escolhido
Formato esperado: Colunas para hora, S1(kVA), S2(kVA), S3(kVA).

Distribuição da GD pelas Fases (%): Total: 0.00%


Fase 1 (S1): Ex: 33.33 **Fase 2 (S2):** Ex: 33.33 **Fase 3 (S3):** Ex: 33.34

Processar Dados e Gerar Gráficos

Fonte: elaborada pelos autores

Após o processamento dos dados de entrada, a ferramenta fornece um conjunto rico de saídas, incluindo métricas de análise e uma série de gráficos interativos. A Figura 10 exibe um dos principais resultados visuais da ferramenta: a comparação das curvas de carga real e mascarada por fase, juntamente com a geração horária estimada.

Figura 10 – Gráfico de saída da ferramenta com comparação por fase



Fonte: elaborada pelos autores

Portanto, a DesagregaGD se consolida como uma alternativa cientificamente fundamentada, replicável e escalável. Ao demonstrar que é possível atingir alta precisão com uma metodologia mais direta, a ferramenta oferece uma solução prática e de grande valor para as equipes de planejamento e operação das distribuidoras, permitindo-lhes recalibrar modelos de previsão, otimizar ajustes de tensão e realizar uma gestão de ativos mais assertiva, contribuindo para a manutenção da confiabilidade do sistema elétrico em um cenário de alta penetração de GD.

4.4 Validação do algoritmo e implementação

A etapa final do projeto concentrou-se na validação quantitativa da confiabilidade do algoritmo da DesagregaGD. Para isso, a curva de carga mascarada, gerada a partir da simulação do sistema-teste IEEE 13 barras no OpenDSS (Figura 4, curva laranja), foi utilizada como dado de entrada na ferramenta. A curva de carga real, estimada pela aplicação, foi então diretamente comparada com a curva de carga real original, conhecida da simulação (Figura 4, curva azul), que serviu como “verdade fundamental” (*ground truth*).

A análise comparativa revelou uma excelente aderência entre os resultados. A ferramenta alcançou um Coeficiente de Determinação (R^2) de 0,9958 e o maior erro médio percentual observado entre a curva real e a estimada foi de apenas 1,5%. Este desvio mínimo, atribuído a pequenas aproximações computacionais inerentes ao processo, confirma a alta precisão e confiabilidade do algoritmo de desagregação.

Esses resultados são particularmente relevantes quando contextualizados com as abordagens mais complexas da literatura. O trabalho de Bu *et al.* (2020), por exemplo, que utiliza uma abordagem *data-driven* baseada em teoria dos jogos, reporta um Erro Percentual Absoluto Médio (MAPE) para a desagregação da geração fotovoltaica que varia, em sua maioria, entre 4% e 8% para diferentes alimentadores. De forma semelhante, o *framework* de aprendizado de máquina adaptativo de Saeedi *et al.* (2021) alcança um valor de R^2 de até 0,94 em cenários de validação cruzada com divisão de dados de 90% para treinamento e 10% para teste, com um RMSE de 4%.

A discussão que emerge deste resultado (R^2 de 0,9958) foca na validação matemática da ferramenta. Ela comprova que o algoritmo executa a operação de desagregação da Equação 2, com altíssima precisão em um ambiente de simulação controlado, mesmo partindo de uma carga agregada complexa (composta por 10 perfis distintos).

É importante contextualizar esta comparação com os métodos da literatura, como os de Bu *et al.* (2020) (MAPE de 4% a 8%) e Saeedi *et al.* (2021) (R^2 de 0,94). Esses trabalhos utilizam dados de medidores reais e algoritmos de *machine learning* para estimar a geração em um cenário com incertezas, o que representa um desafio fundamentalmente diferente. A principal vantagem da DesagregaGD não reside em ser superior a esses métodos de ponta, mas sim em sua simplicidade, baixo custo e aplicabilidade prática. A ferramenta demonstra que, para concessionárias que já possuem uma estimativa razoável do perfil de geração (como a curva da Figura 8), é possível reconstruir a carga

real com notável acurácia (como validado no estudo de caso da Seção 4.5), contornando a necessidade de algoritmos de *machine learning* complexos e dados de treinamento extensivos.

Com a validação concluída e a eficácia comprovada, a ferramenta foi implementada em um repositório público e o software foi devidamente registrado no INPI, concluindo com êxito todos os objetivos propostos para esta pesquisa.

4.5 Estudo de caso: validação da ferramenta em um sistema real

É importante ressaltar que a abordagem da DesagregaGD possui limitações inerentes à sua metodologia agregada. A ferramenta não modela a topologia da rede (influência da distância) nem os perfis de carga individuais.

Isso ocorre porque:

- Os perfis das cargas já estão “embutidos” no resultado, uma vez que a metodologia se baseia na curva de carga total medida no início do alimentador (carga mascarada).
- A influência da distância (que afeta o nível de perdas da rede) não é contemplada, pois o modelo não é topológico. Contudo, pode-se afirmar que esta influência na variação da desagregação é pequena, e as perdas totais já estão contidas na medição de entrada.

Adicionalmente, a precisão da estimativa está condicionada à qualidade dos dados de entrada. Conforme já observado, a ferramenta depende de um perfil de irradiância solar representativo, podendo apresentar desvios em dias de condições climáticas atípicas. Da mesma forma, o método assume uma eficiência média para o conjunto de sistemas fotovoltaicos, não capturando a variabilidade individual entre as instalações. Adicionalmente, a precisão da estimativa está condicionada à qualidade dos dados de entrada. Conforme já observado, a ferramenta depende de um perfil de irradiância solar representativo, podendo apresentar desvios em dias de condições climáticas atípicas. Da mesma forma, o método assume uma eficiência média para o conjunto de sistemas fotovoltaicos, não capturando a variabilidade individual entre as instalações.

Para comprovar a robustez e a aplicabilidade prática da DesagregaGD, foi realizado um estudo de caso validando a ferramenta com o modelo de um alimentador real da Neoenergia Pernambuco. O alimentador pertence a subestação Garanhuns, localizada no município de mesmo nome, e opera em nível de 13,8 kV na rede primária, 380 V na rede secundária, possui 15 consumidores de média tensão, 12.628 consumidores de baixa tensão, e 156 unidades com MMGD. Conforme detalhado na metodologia, este sistema representa um cenário desafiador, com alta penetração de Geração Distribuída. A topologia da rede é apresentada na Figura 11.

É fundamental destacar que o modelo utilizado foi desenvolvido a partir de dados da Base de Dados Geográfica da Distribuição (BDGD), que exigiram um tratamento prévio para corrigir múltiplas inconsistências que inviabilizavam simulações de fluxo de carga, conforme detalhado por Silva e Barros (2025). A utilização do modelo já corrigido por eles foi um passo crucial para garantir a confiabilidade desta validação.


Para a execução do teste, a curva de geração agregada foi modelada com base em um perfil médio de irradiância solar diário típico obtido com dados da Base de Dados Geográfica da Distribuidora (BDGD), exibido na Figura 12. Este perfil foi escalonado na ferramenta utilizando uma potência de pico de 870 kWp, valor determinado a partir da soma da geração de todos os sistemas fotovoltaicos no próprio modelo da rede (considerando perdas por temperatura e eficiência), garantindo a representação fiel do sistema.

Figura 11 – Topologia do alimentador da Neoenergia Pernambuco utilizado no estudo de caso



Fonte: Silva e Barros (2025)

Figura 12 – Curva de irradiância diária utilizada para modelar a geração distribuída no estudo de caso

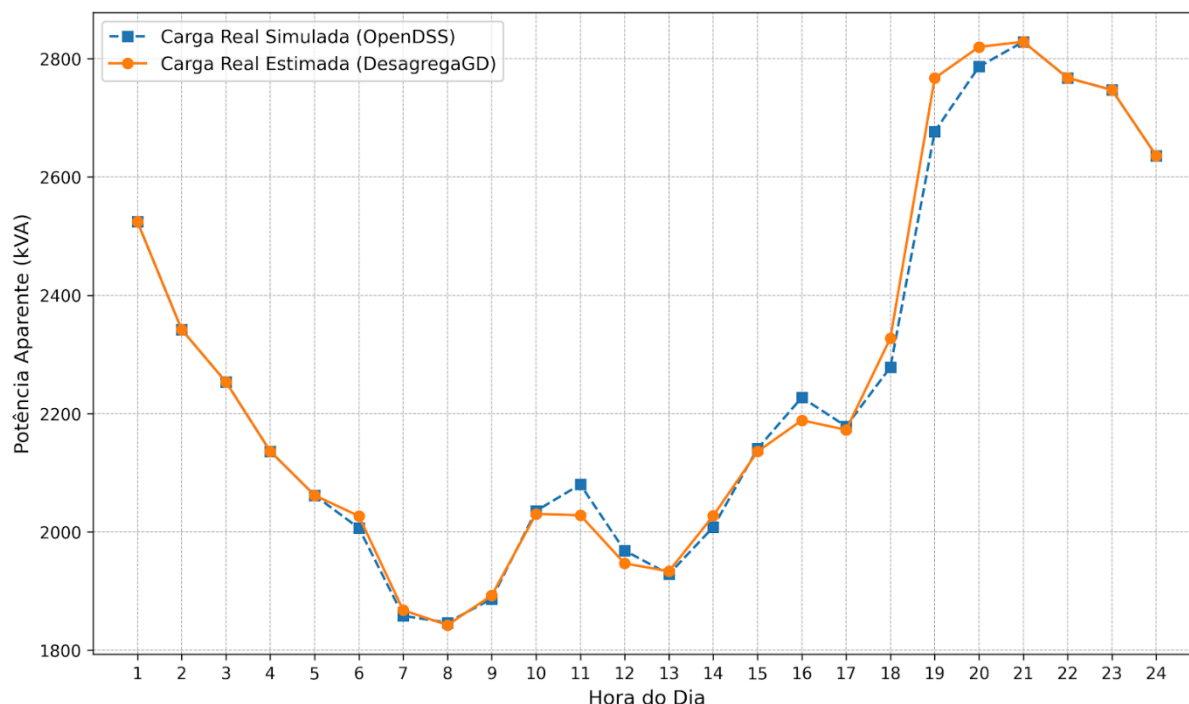


Fonte: elaborada pelos autores

Para a execução deste teste de validação, a ferramenta DesagregaGD foi alimentada com a curva de carga mascarada obtida na simulação do OpenDSS (considerando a presença das MMGDs). A curva de geração foi modelada a partir do perfil de irradiância de 24 pontos cedido pela BDGD, escalonado por uma potência instalada de 870 kW, distribuída igualmente entre as três fases. A eficiência foi configurada como 100%, pois o valor da potência de pico já representa a geração líquida,

com as perdas por temperatura e eficiência dos sistemas individuais já descontadas a partir do modelo base. Na Figura 13 é apresentado o resultado final da validação, sobrepondo a curva de carga real do alimentador (obtida via simulação no OpenDSS) e a curva estimada pela ferramenta DesagregaGD.

Figura 13 – Validação com o alimentador real: carga real simulada (OpenDSS) vs. carga real estimada (DesagregaGD)



Fonte: elaborada pelos autores

Observa-se que o erro nas proximidades das 6 h e das 20 h está diretamente relacionado às perdas do sistema, já que há uma rampa de carga considerável durante esse período. A curva estimada pela ferramenta DesagregaGD não realiza a separação entre carga e perdas técnicas, tratando ambas como parte da demanda total, enquanto a curva obtida no OpenDSS considera exclusivamente a carga. Essa diferença conceitual explica as pequenas discrepâncias nos períodos de transição entre noite e dia, quando as condições de geração e carregamento variam rapidamente. Ressalta-se que tal comportamento está dentro das limitações conhecidas da ferramenta e não compromete a representatividade geral dos resultados, que demonstram forte aderência global entre as curvas simulada e estimada.

5 Conclusões

Este trabalho se propôs a investigar os impactos da Geração Distribuída no sistema elétrico, culminando no desenvolvimento e validação da DesagregaGD, uma solução prática para o desafio do mascaramento da carga. A pesquisa partiu de uma análise em escala macro, que não confirmou a hipótese de que a expansão da MMGD estaria degradando a acurácia das previsões de carga do Operador Nacional do Sistema Elétrico. Este resultado inicial direcionou o foco da investigação para o nível da rede de distribuição, onde o fenômeno se manifesta de forma mais crítica e com impactos operacionais diretos para as concessionárias.

A principal contribuição científica do estudo é a entrega de uma ferramenta computacional que se posiciona de forma única frente às abordagens existentes na literatura, validada por uma performance de alta precisão, alcançando um Coeficiente de Determinação (R^2) de 0,9929 e um erro médio percentual de 0,74%, em um estudo de caso com um alimentador real. A originalidade da DesagregaGD reside na combinação estratégica de três fatores:

- **Simplicidade e acessibilidade:** Em contraste com modelos complexos de *machine learning* ou Desagregação de Carga Não Intrusiva (NILM), frequentemente citados na literatura, a ferramenta utiliza uma abordagem matemática fundamental. Implementada em uma plataforma web de código aberto, ela elimina barreiras de custo, conhecimento técnico avançado e poder computacional, tornando a análise acessível a um público mais amplo de engenheiros, planejadores, estudantes e demais interessados no tema.
- **Alta acurácia com baixa exigência de dados:** O estudo demonstra que é possível reconstruir a curva de carga real com um erro médio percentual de apenas 0,74%, utilizando dados agregados de carga e perfis de geração, que já são amplamente disponíveis para as distribuidoras. Este achado é particularmente relevante, pois contorna a necessidade de medições granulares em tempo real ou de um longo histórico de dados para o treinamento de modelos, que representam os maiores obstáculos para a implementação de outras soluções.
- **Validação em cenário prático brasileiro:** A eficácia da ferramenta foi comprovada não apenas em um sistema-teste ideal do IEEE, mas na aplicação a um modelo detalhado de um alimentador real da Neoenergia Pernambuco. Essa validação em um cenário complexo, com dados do mundo real, garante a relevância e a aplicabilidade prática da solução para os desafios enfrentados pelo setor elétrico nacional.

Ao oferecer uma metodologia acessível para quantificar o mascaramento da carga, a DesagregaGD se consolida como uma ferramenta valiosa de suporte à decisão para concessionárias de energia, agências reguladoras e pesquisadores. A capacidade de restaurar a visibilidade sobre o comportamento real dos consumidores contribui diretamente para um planejamento mais eficiente, uma operação mais segura e uma gestão de ativos mais assertiva. Na prática, um engenheiro de planejamento pode utilizar a DesagregaGD para recalibrar modelos de previsão de alimentadores com alta penetração de GD, otimizar ajustes em reguladores de tensão ou postergar investimentos em expansão da rede com base na demanda real, e não na mascarada. Para a continuidade da pesquisa, recomenda-se a expansão do método para incluir outras fontes de geração intermitentes, como a eólica, e a integração de módulos de previsão de carga em nível local, consolidando a ferramenta como uma solução ainda mais completa para os desafios da transição energética.

Agradecimentos

Os autores gostariam de expressar seus sinceros agradecimentos ao Instituto Federal de Pernambuco (IFPE), Campus Garanhuns, por todo o suporte institucional e pela concessão de bolsa no âmbito do Programa Institucional de Bolsas de Iniciação Científica (PIBIC). Agradecem também ao pesquisador Felipe Martins da Silva, pela disponibilização de dados utilizados na validação da ferramenta desenvolvida, descritos na seção 4.5 do trabalho.

Financiamento

Esta pesquisa foi financiada por meio do Programa Institucional de Bolsas de Iniciação Científica (PIBIC) do IFPE Campus Garanhuns.

Conflito de interesses

Os autores declaram não haver conflito de interesses.

Contribuições ao artigo

LIMA, B. H. S.: Coleta, análise e/ou interpretação dos dados; redação inicial ou revisão substantiva do manuscrito. **BARROS, R. M. R.:** concepção ou delineamento do estudo/pesquisa; revisão crítica com contribuição intelectual relevante; supervisão geral do projeto ou coordenação técnica. Todos os autores participaram da escrita, discussão, leitura e aprovação da versão final do artigo.

Referências

ANEEL – AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. **Resolução Normativa nº 482, de 17 de abril de 2012**. Estabelece as condições gerais para o acesso de microgeração e minigeração distribuída aos sistemas de distribuição de energia elétrica, o sistema de compensação de energia elétrica, e dá outras providências. Brasília, DF: ANEEL, 2012. Disponível em: <https://www2.aneel.gov.br/cedoc/ren2012482.pdf>. Acesso em: 30 out. 2025.

ANEEL – AGÊNCIA NACIONAL DE ENERGIA ELÉTRICA. **Resolução Normativa nº 1.000, de 7 de dezembro de 2021**. Estabelece as Regras de Prestação do Serviço Público de Distribuição de Energia Elétrica; revoga as Resoluções Normativas nº 414, de 9 de setembro de 2010; nº 470, de 13 de dezembro de 2011; e nº 901, de 8 de dezembro de 2020 e dá outras providências. Brasília, DF: ANEEL, 2021. Disponível em: <https://www2.aneel.gov.br/cedoc/ren20211000.pdf>. Acesso em: 30 out. 2025.

BRASIL. **Lei nº 14.300, de 6 de janeiro de 2022**. Institui o marco legal da microgeração e minigeração distribuída, o Sistema de Compensação de Energia Elétrica (SCEE) e o Programa de Energia Renovável Social (PERS); altera as Leis nºs 10.848, de 15 de março de 2004, e 9.427, de 26 de dezembro de 1996; e dá outras providências. Brasília, DF: Presidência da República, 2022. Disponível em: https://www.planalto.gov.br/ccivil_03/_ato2019-2022/2022/lei/114300.htm. Acesso em: 30 out. 2025.

BU, F.; DEHGHANPOUR, K.; YUAN, Y.; WANG, Z.; ZHANG, Y. A Data-Driven Game-Theoretic Approach for Behind-the-Meter PV Generation Disaggregation. **IEEE Transactions on Power Systems**, v. 35, n. 4, p. 3133-3144, jul. 2020. DOI: <https://doi.org/10.1109/TPWRS.2020.2966732>.

CAISO – CALIFORNIA ISO. **What the duck curve tells us about managing a green grid**. Folsom, CA: CAISO, 2016. Disponível em: https://www.caiso.com/Documents/FlexibleResourcesHelpRenewables_FastFacts.pdf. Acesso em: 22 ago. 2025.

CASTILHOS, L. P.; DONADEL, C. B. Impactos de Geradores Fotovoltaicos Distribuídos em uma Rede de Distribuição de Energia Elétrica de Baixa Tensão. **The Journal of Engineering and Exact Sciences**, v. 8, n. 6, 14685, 2022. DOI: <https://doi.org/10.18540/jcecvl8iss6pp14685-01i>.

CHAI, T.; DRAXLER, R. R. Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature. **Geoscientific Model Development**, v. 7, n. 3, p. 1247-1250, 2014. DOI: <https://doi.org/10.5194/gmd-7-1247-2014>.

CHEN, X.; HAJI, M. M.; ARDAKANIAN, O. A Data-Efficient Approach to Behind-the-Meter Solar Generation Disaggregation. **arXiv preprint arXiv:2105.08122**, 2021. DOI: <https://doi.org/10.48550/arXiv.2105.08122>.

COSTA, G. H. **Estudo dos impactos da penetração da geração distribuída fotovoltaica de uma rede de distribuição utilizando o software OpenDSS**. 2023. 39 f. Trabalho de Conclusão de Curso (Graduação em Engenharia Elétrica) – Universidade Federal do Ceará, Fortaleza, 2023. Disponível em: <http://repositorio.ufc.br/handle/riufc/73904>. Acesso em: 30 out. 2025.

DUGAN, R. C.; MCDERMOTT, T. E.; BALL, G. J. Planning for distributed generation. **IEEE Industry Applications Magazine**, v. 7, n. 2, p. 80-88, mar./abr. 2001. DOI: <https://doi.org/10.1109/2943.911193>.

EPE – EMPRESA DE PESQUISA ENERGÉTICA. **Painel de Dados de Micro e Minigeração Distribuída (PDGD)**. Rio de Janeiro: EPE, [2025]. Disponível em: <https://dashboard.epe.gov.br/apps/pdgd>. Acesso em: 30 out. 2025.

ERDENER, B. C.; FENG, C.; DOUBLEDAY, K.; FLORITA, A.; HODGE, B.-M. A review of behind-the-meter solar forecasting. **Renewable and Sustainable Energy Reviews**, v. 160, 112224, maio 2022. DOI: <https://doi.org/10.1016/j.rser.2022.112224>.

GAO, D. W.; MULJADI, E.; TIAN, T.; MILLER, M. **Software Comparison for Renewable Energy Deployment in a Distribution System**. Golden, CO: National Renewable Energy Laboratory (NREL), 2017. DOI: <https://doi.org/10.2172/1345057>.

GAO, X.; ZHANG, J.; SUN, H.; LIANG, Y.; WEI, L.; YAN, C.; XIE, Y. A review of voltage control studies on low voltage distribution networks containing high penetration distributed photovoltaics. **Energies**, v. 17, n. 3, 3058, 2024. DOI: <https://doi.org/10.3390/en17133058>.

GUERRA, G.; MARTÍNEZ-VELASCO, J. A. A review of tools, models and techniques for long-term assessment of distribution systems using OpenDSS and parallel computing. **AIMS Energy**, v. 6, n. 5, p. 764-800, 2018. DOI: <https://doi.org/10.3934/energy.2018.5.764>.

HARIRI, A.; NEWAZ, A.; FARUQUE, M. O. Open-source python-OpenDSS interface for hybrid simulation of PV impact studies. **IET Generation, Transmission & Distribution**, v. 11, n. 12, p. 3125-3133, 2017. DOI: <https://doi.org/10.1049/iet-gtd.2016.1572>.

HONG, T.; FAN, S. Probabilistic electric load forecasting: A tutorial review. **International Journal of Forecasting**, v. 32, n. 3, p. 914-938, 2016. DOI: <https://doi.org/10.1016/j.ijforecast.2015.11.011>.

HYNDMAN, R. J.; KOEHLER, A. B. Another look at measures of forecast accuracy. **International Journal of Forecasting**, v. 22, n. 4, p. 679-688, 2006. DOI: <https://doi.org/10.1016/j.ijforecast.2006.03.001>.

IFPE – INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE PERNAMBUCO. **Repositório do Grupo de Pesquisa em Sistemas Elétricos do IFPE Campus Garanhuns**. Garanhuns: IFPE, 2025. Disponível em: <https://github.com/gsel-ifpe>. Acesso em: 16 ago. 2025.

KERSTING, W. H. Radial distribution test feeders. In: IEEE POWER ENGINEERING SOCIETY WINTER MEETING, 2001, Columbus. **Proceedings** [...]. Columbus, OH: IEEE, 2001. v. 2, p. 908-912. DOI: <https://doi.org/10.1109/PESW.2001.916993>.

MAJEED, I. B.; NWULU, N. I. Impact of Reverse Power Flow on Distributed Transformers in a Solar-Photovoltaic-Integrated Low-Voltage Network. **Energies**, v. 15, n. 23, 9238, 2022. DOI: <https://doi.org/10.3390/en15239238>.

MARCON, A. C. K. L. **Desagregação de carga e geração em unidades consumidoras com micro e minigeração solar fotovoltaica conectadas à rede**. 2021. Trabalho de Conclusão de Curso (Bacharelado em Engenharia de Energia) – Escola de Engenharia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2021. Disponível em: <https://lume.ufrgs.br/bitstream/handle/10183/224394/001128128.pdf>. Acesso em: 30 out. 2025.

MARTINS, V. A.; CASTELO BRANCO, D. A.; HALLACK, M. C. M. Economic Effects of Micro- and Mini-Distributed Photovoltaic Generation for the Brazilian Distribution System. **Energies**, v. 15, n. 3, 737, 2022. DOI: <https://doi.org/10.3390/en15030737>.

MONTENEGRO, D.; HERNANDEZ, M.; RAMOS, G. A. Real Time OpenDSS framework for Distribution Systems Simulation and Analysis. In: IEEE/PES TRANSMISSION AND DISTRIBUTION: LATIN AMERICA CONFERENCE AND EXPOSITION (T&D-LA), 6., 2012,

Montevideo. **Proceedings** [...]. Montevideo: IEEE, 2012. DOI: <https://doi.org/10.1109/TDC-LA.2012.6319069>.

OLIVEIRA, E. M. C. S.; OLIVEIRA, M. E.; SILVA, L. G. W. Impacts of Photovoltaic Systems on a Brazilian Distribution Feeder using OpenDSS. **Renewable Energy and Power Quality Journal**, v. 19, n. 3, p. 310-315, set. 2021. DOI: <https://doi.org/10.24084/repqj19.283>.

PEREIRA, J. M. A. **Impactos para a operação do sistema elétrico após a inserção massiva de micro e minigeração distribuída**. 2022. Trabalho de Conclusão de Curso (Especialização em Fontes Renováveis: Geração, Operação e Integração) – Universidade Federal de Minas Gerais, Belo Horizonte, 2022. Disponível em: <https://repositorio.ufmg.br/items/1f531b1e-8557-43bd-9659-a591ab3b731a>. Acesso em: 30 out. 2025.

QU, Z.; GE, X.; LU, J.; WANG, F. Unsupervised disaggregation of aggregated net load considering behind-the-meter PV based on virtual PV sample construction. **Applied Energy**, v. 381, 125007, mar. 2025. DOI: <https://doi.org/10.1016/j.apenergy.2024.125007>.

RAZAVI, S.-E.; RAHIMI, E.; JAVADI, M. S.; NEZHAD, A. E.; LOTFI, M.; SHAFIE-KHAH, M.; CATALÃO, J. P. S. Impact of Distributed Generation on Protection and Voltage Regulation of Distribution Systems: A Review. **Renewable and Sustainable Energy Reviews**, v. 105, p. 157-167, maio 2019. DOI: <https://doi.org/10.1016/j.rser.2019.01.050>.

SAEEDI, R.; SADANANDAN, S. K.; SRIVASTAVA, A. K.; DAVIES, K. L.; GEBREMEDHIN, A. H. An Adaptive Machine Learning Framework for Behind-the-Meter Load/PV Disaggregation. **IEEE Transactions on Industrial Informatics**, v. 17, n. 10, p. 7060-7069, out. 2021. DOI: <https://doi.org/10.1109/TII.2021.3060898>.

SALIMON, S. A.; ADEPOJU, G. A.; ADEBAYO, I. G.; HOWLADER, H. O. R.; AYANLADE, S. O.; ADEWUYI, O. B. Impact of Distributed Generators Penetration Level on the Power Loss and Voltage Profile of Radial Distribution Networks. **Energies**, v. 16, n. 4, 1943, fev. 2023. DOI: <https://doi.org/10.3390/en16041943>.

SANTOS, T. L. **Análise dos impactos da geração distribuída por painéis solares fotovoltaicos no sistema de baixa tensão: uma avaliação dos efeitos no gerenciamento da rede elétrica**. 2023. 35 f. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Civil) – Instituto Federal de Educação, Ciência e Tecnologia da Paraíba, Cajazeiras, 2023. Disponível em: <https://repositorio.ifpb.edu.br/jspui/handle/177683/3413>. Acesso em: 30 out. 2025.

SILVA, F.; BARROS, R. Diagnóstico e Correção da BDGD Ordinária para Execução de Fluxo de Carga em um Alimentador da Neoenergia Pernambuco. In: SEMINÁRIO NACIONAL DE DISTRIBUIÇÃO DE ENERGIA ELÉTRICA (SENDI), 25., 2025, Belo Horizonte. **Anais** [...]. Belo Horizonte: ABRADÉE, 2025. Disponível em: <https://sendi.org.br/trabalhostecnicos/DIARIA27/9232%20-%20FELIPE%20SILVA.zip>. Acesso em: 30 out. 2025.

SMITH, J.; RÖNNBERG, S.; BOLLEN, M.; MEYER, J.; BLANCO, A.; KOO, K.-L.; MUSHAMALIRWA, D. Power quality aspects of solar power: results from CIGRE JWG C4/C6.29. In: INTERNATIONAL CONFERENCE & EXHIBITION ON ELECTRICITY DISTRIBUTION (CIRED), 2017, Glasgow. **Proceedings** [...]. Glasgow: IET, 2017. n. 1. DOI: <https://doi.org/10.1049/oap-cired.2017.0351>.

SOSSAN, F.; NESPOLI, L.; MEDICI, V.; PAOLONE, M. Unsupervised Disaggregation of Photovoltaic Production From Composite Power Flow Measurements of Heterogeneous Prosumers.

IEEE Transactions on Industrial Informatics, v. 14, n. 9, p. 3904-3913, set. 2018. DOI: <https://doi.org/10.1109/TII.2018.2791932>.

SPEARMAN, C. The proof and measurement of association between two things. **American Journal of Psychology**, v. 15, n. 1, p. 72-101, 1904. Disponível em: <https://www.jstor.org/stable/pdf/1412159.pdf>. Acesso em: 30 out. 2025.

STRATMAN, A.; HONG, T.; YI, M.; ZHAO, D. Net Load Forecasting with Disaggregated Behind-the-Meter PV Generation. *In: IEEE INDUSTRY APPLICATIONS SOCIETY ANNUAL MEETING (IAS)*, 2022, Detroit. **Proceedings** [...]. Detroit: IEEE, 2022. DOI: <https://doi.org/10.1109/IAS54023.2022.9940025>.

TELLO-MAITA, J.; MARULANDA, A.; PAVAS, A. Simulation of Modern Distribution Systems Using Matlab and OpenDSS. *In: FISE-IEEE/CIGRE CONFERENCE – LIVING THE ENERGY TRANSITION*, 2019, Medellín. **Proceedings** [...]. Medellín: IEEE, 2019. DOI: <https://doi.org/10.1109/FISECIGRE48012.2019.8984949>.

TORRES, I. C.; NEGREIROS, G. F.; TIBA, C. Theoretical and Experimental Study to Determine Voltage Violation, Reverse Electric Current and Losses in Prosumers Connected to Low-Voltage Power Grid. **Energies**, v. 12, n. 23, 4568, 2019. DOI: <https://doi.org/10.3390/en12234568>.

UZUM, B.; ONEN, A.; HASANIEN, H. M.; MUYEEN, S. M. Rooftop Solar PV Penetration Impacts on Distribution Network and Further Growth Factors – A Comprehensive Review. **Electronics**, v. 10, n. 1, 55, 2021. DOI: <https://doi.org/10.3390/electronics10010055>.

WERON, R. Electricity price forecasting: A review of the state-of-the-art with a look into the future. **International Journal of Forecasting**, v. 30, n. 4, p. 1030-1081, 2014. DOI: <https://doi.org/10.1016/j.ijforecast.2014.08.008>.