

Classificação de Faltas em Sistemas de Distribuição com Inserção de Geração Distribuída via Autoencoder e Perceptron Multicamadas

Andréia S. Santos¹, Reginaldo J. Silva², Carlos R. Minnussi³

UNESP, Ilha Solteira, SP

Lucas Teles Faria⁴

UNESP, Rosana, SP

A integração massiva de geração distribuída (GD) traz desafios significativos para a operação dos sistemas de distribuição de energia elétrica (SDEEs) [3]. Nos últimos anos, a produção de energia a partir de fontes renováveis cresceu consideravelmente devido aos esforços globais para atender às metas de descarbonização [2]. Entre essas fontes, destacam-se os sistemas fotovoltaicos (PVs), que representam cerca de 84% das instalações de GD no Brasil [1]. Em redes com alta penetração PVs, as variações nos sinais de corrente podem comprometer a atuação dos relés de sobrecorrente, dificultando a detecção e classificação de faltas [4].

Dante da complexidade introduzida pelos sistemas PVs nos SDEEs, especialmente devido à natureza intermitente da geração solar, este estudo propõe a implementação de Autoencoders (AEs) na etapa de pré-processamento para redução da dimensionalidade e extração das principais características dos sinais de correntes. Os AEs são conformados por uma arquitetura de rede neural do tipo *Multilayer Perceptron* (MLP) e são amplamente empregados para aprendizado de representações de dados. Esses modelos realizam transformações não lineares para capturar e organizar informações discriminativas, possibilitando a obtenção de uma codificação direta ou de um mapeamento paramétrico da entrada para uma representação mais significativa [5]. O vetor resultante, denominado espaço latente, concentra as principais informações para alimentar o classificador.

As diversas condições de faltas foram simuladas no sistema teste IEEE-34 barras, modelado no ATP/ATPDraw, considerando diferentes variações, incluindo a quantidade de sistemas PVs (0 PV e 10 PVs), a resistência da falta, o tipo de falta, a barra de localização e o ângulo de inserção. A rede neural MLP foi empregada como classificador. O problema foi formulado como uma classificação multiclasse, abrangendo sete classes correspondentes aos curtos-circuitos (A_g , A_b , A_c , AC_g/AC , AB_g/AB , BC_g/BC e ABC_g/ABC) e uma classe adicional correspondente ao estado operativo normal do sistema [4].

Os resultados são apresentados na Tabela 1. As simulações são feitas a partir de duas abordagens: a janela composta pelos sinais de corrente completos e a janela processada pelo AE, com o objetivo de avaliar sua eficiência. Observa-se que todas as métricas apresentaram um desempenho superior no Cenário 1 com os sinais processados pelo AE em comparação ao uso do sinal completo. A acurácia, por exemplo, teve uma leve melhoria, passando de 97,55% para 98,91%.

No Cenário 2, no qual são conectados 10 sistemas PVs, essa melhora é mais significativa. Todas as métricas foram substancialmente aprimoradas, com incrementos na acurácia, no *recall* macro e

¹andreia.faria@unesp.br

²reginaldo.silva@unesp.br

³carlos.minnussi@unesp.br

⁴lucas.teles@unesp.br

Tabela 1: Resultados para cenário 1 (0 PV) e cenário 2 (10 PVs).

Métricas	Cenário 0 PV		Cenário 10PV	
	Sem AE	Com AE	Sem AE	Com AE
Acurácia	0,9755	0,9891	0,5213	0,9048
<i>Recall</i> macro	0,9748	0,9865	0,1597	0,8742
<i>Recall</i> micro	0,9756	0,9891	0,5213	0,9048
Especificidade Macro	0,9958	0,9978	0,8819	0,9838
Especificidade Micro	0,9965	0,9984	0,9316	0,9864
Precisão Macro	0,9816	0,9960	0,4242	0,8783
Precisão Micro	0,9756	0,9891	0,5213	0,9048
<i>F₁-Score</i> Macro	0,9779	0,9909	0,1481	0,8708
<i>F₁-Score</i> Micro	0,9756	0,9891	0,5213	0,9048
AUC Macro	0,9993	0,9998	0,5464	0,9929
AUC Micro	0,9996	0,9999	0,7782	0,9942

no *F₁-Score* de 38,35%, 71,45% e 72,27%, respectivamente. Esses resultados destacam a eficácia do AE na redução da dimensionalidade dos dados e na melhoria do desempenho do classificador, especialmente em cenários com alta penetração de sistemas PVs.

Além disso, observa-se o impacto dos sistemas PVs no estágio de classificação, provocado principalmente pelas variações nas magnitudes das correntes, o que reforça a importância do pré-processamento para aprimorar a precisão do classificador.

Agradecimentos

Os autores agradecem à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, pelo auxílio financeiro.

Referências

- [1] T. K. Gimenes et al. “Impact of distributed energy resources on power quality: Brazilian scenario analysis”. Em: **Electric Power Systems Research** 211 (2022), pp. 108249. DOI: [10.1016/j.epsr.2022.108249](https://doi.org/10.1016/j.epsr.2022.108249).
- [2] S. R. Ola et al. “A protection scheme for a power system with solar energy penetration”. Em: **Applied Sciences (Switzerland)** 10 (2020), pp. 1516. DOI: [10.3390/app10041516](https://doi.org/10.3390/app10041516).
- [3] S. Razavi et al. “Impact of distributed generation on protection and voltage regulation of distribution systems: A review”. Em: **Renewable and Sustainable Energy Reviews** 105 (2019), pp. 157–167. DOI: [10.1016/j.rser.2019.01.050](https://doi.org/10.1016/j.rser.2019.01.050).
- [4] A. S. Santos et al. “Integrating autoencoders to improve fault classification with PV system insertion”. Em: **Electric Power Systems Research** 242 (2025), pp. 111426. DOI: [10.1016/j.epsr.2025.111426](https://doi.org/10.1016/j.epsr.2025.111426).
- [5] Z. Yang et al. “Autoencoder-based representation learning and its application in intelligent fault diagnosis: A review”. Em: **Measurement** 189 (2022), pp. 110460. DOI: [10.1016/j.measurement.2021.110460](https://doi.org/10.1016/j.measurement.2021.110460).