

Predição Térmica de Válvulas HVDC com ConvLSTM para Suporte a Gêmeo Digital de Subestação

Vinicius Lima Carvalho¹, Jair Neto¹, Gabriel Cyrino¹,
Alexandre Cardoso¹, Edgard Lamounier¹

¹Universidade Federal de Uberlândia (UFU) – Uberlândia, MG – Brazil

{viniciuscarvalho, jair.neto, gabrielcyrino, alexandre, lamounier}@ufu.br

Abstract. *This work investigates a ConvLSTM-based approach for thermal map prediction of HVDC converter valves, aiming to overcome the temporal sparsity of infrared captures (one image every six hours) in a Digital Twin system. The method evolved from an LSTM trained on low-resolution RGB images to a ConvLSTM fed with absolute temperature matrices, achieving a Mean Absolute Error of 0.85 °C on real data from a Brazilian HVDC substation.*

Resumo. *Este trabalho investiga uma abordagem baseada em ConvLSTM para predição de mapas térmicos de válvulas conversoras HVDC, visando superar a esparsidade temporal das capturas termográficas (uma imagem a cada seis horas) em um sistema de Gêmeo Digital. O método evoluiu de uma LSTM treinada com imagens RGB de baixa resolução para uma ConvLSTM alimentada por matrizes de temperatura absoluta, atingindo Erro Médio Absoluto de 0,85 °C em dados reais de uma subestação HVDC brasileira.*

1. Introdução

Subestações de transmissão HVDC (*High Voltage Direct Current*) operam com válvulas de tiristores responsáveis pela conversão de energia em alta tensão e corrente contínua. Falhas térmicas nesses componentes podem causar interrupções sistêmicas de grande escala, com prejuízos econômicos severos para a operadora e impactos diretos no sistema interligado nacional [Alexandre 2025]. Nesse cenário, a migração de modelos de manutenção reativa para preditiva é um requisito operacional. O Gêmeo Digital (DT), réplica virtual sincronizada com o ativo físico via fluxo contínuo de dados, tem se consolidado como ferramenta central nessa transição em sistemas de potência, habilitando monitoramento em tempo real e análises preditivas [Mansour et al. 2023].

O DT foi definido [Grievies 2005] como um modelo composto por produto físico, produto virtual e conexão de dados bidirecional em tempo real. Trabalhos recentes em sistemas de potência demonstram que DTs alimentados por algoritmos de Inteligência Artificial (IA) elevam o nível de maturidade do monitoramento, deixando o estado puramente descritivo e habilitando análises preditivas [Cardoso et al. 2025]. No contexto específico de válvulas HVDC, foi proposto o TransFNN (Transformer + rede neural) para prever sobretemperatura na água de refrigeração, com 91,81% de acurácia em séries temporais escalares [Zhou et al. 2023]. Em um trabalho correlato [Sun et al. 2025], aplicou-se redes neurais gráficas espaço-temporais para predição de capacidade de refrigeração. Em ambos, contudo, a saída é escalar ou agregada, sem reconstrução do campo térmico 2D que uma câmera termográfica fornece.

O presente trabalho aborda um caso real: o Gêmeo Digital de uma subestação HVDC brasileira monitora as válvulas conversoras por meio de câmeras termográficas com cadência de uma captura a cada seis horas. Esse intervalo, fruto de uma decisão de projeto da administradora da subestação, é incompatível com a sincronicidade exigida pelo paradigma do DT, criando lacunas no monitoramento. Para preencher esses intervalos, propõe-se uma abordagem baseada em ConvLSTM (*Convolutional Long Short-Term Memory*) [Shi et al. 2015], arquitetura que substitui as multiplicações matriciais das portas LSTM (*Long Short-Term Memory*) por convoluções 2D, preservando a estrutura espacial dos dados, treinada diretamente sobre matrizes de temperatura absoluta extraídas dos frames termográficos. Este artigo reporta a metodologia adotada, os resultados quantitativos já obtidos e o próximo passo da pesquisa: um ciclo de aprendizado contínuo realimentado pelos próprios erros de predição.

2. Metodologia e Resultados Parciais

Os dados utilizados foram coletados na sala de válvulas da subestação, totalizando 160 matrizes termográficas de um único módulo capturadas em intervalos de seis horas. Cada arquivo corresponde a uma matriz de temperatura absoluta (em °C) com *timestamp* embutido no nome no formato `YYYYMMDD_HHMMSSmmmm`, permitindo o ordenamento temporal preciso da sequência.

O desenvolvimento do modelo passou por três etapas iterativas, cuja síntese é apresentada na Tabela 1. Na primeira etapa, uma LSTM convencional foi treinada com 23 imagens termográficas em escala de cinza, com resolução reduzida (64×64 px) e capturadas de módulos distintos. O resultado evidenciou baixa fidelidade espacial, com a predição reproduzindo apenas o padrão médio da cena. Na segunda etapa, o conjunto foi refinado para imagens do mesmo módulo (20 amostras), em maior resolução com color-map turbo; a melhora visual, porém, não permitiu avaliação quantitativa, pois o espaço RGB distorce a relação com a temperatura.

Na terceira etapa, optou-se por abandonar a alimentação por imagens e treinar o modelo diretamente sobre os valores absolutos de temperatura organizados em matrizes CSV. A arquitetura foi simultaneamente migrada para ConvLSTM, com 160 frames do mesmo módulo, preservando assim a estrutura espacial 2D do campo térmico durante todo o pipeline. Os hiperparâmetros foram definidos por uma busca automatizada via framework Optuna, minimizando o erro médio absoluto (EMA) e estão disponíveis na Tabela 2.

Tabela 1. Evolução das três abordagens testadas.

Entrada	Modelo	Amostras	EMA (°C)
Imagens cinza 64×64	LSTM	23	—
Imagens RGB <i>turbo</i>	LSTM	20	—
Matrizes CSV de temperatura	ConvLSTM	160	0,85

A arquitetura final utiliza células ConvLSTM com *kernel* 5×5 e número de canais ocultos configurável. A entrada é uma sequência de frames consecutivos (matrizes $H \times W$ de temperatura) e a saída é a previsão do frame seguinte. Quando o *timestamp* alvo não corresponde a uma captura real existente, o modelo é iterado de forma auto-regressiva: a

Tabela 2. Hiperparâmetros da ConvLSTM otimizados via Optuna.

Hiperparâmetro	Valor	Descrição
Comprimento da sequência	8	Frames de entrada por amostra
Canais ocultos	16	Dimensão do estado latente
Épocas	25	Iterações sobre o conjunto de treino
Taxa de aprendizado	$5,77 \times 10^{-3}$	Otimizado via Optuna
Tamanho do lote	4	Amostras por passo de gradiente
Tamanho do kernel	5	Filtro convolucional (5×5)

saída de cada passo realimenta o passo seguinte, com número de iterações estimado pelo intervalo mediano entre os frames. Esse mecanismo permite gerar previsões sintéticas em qualquer instante dentro da janela de seis horas entre duas capturas reais, condição necessária para a visualização contínua exigida pelo DT. A Figura 1 compara uma imagem real e uma gerada pelo modelo para o mesmo instante e módulo. O treinamento foi executado em aproximadamente 8 a 10 minutos em uma GPU NVIDIA RTX 4060 Ti, com paralelização via núcleos CUDA. Os dados foram divididos cronologicamente, sem embaralhamento, em 80% para treino e 20% finais para validação, preservando a ordem temporal das sequências.




Figura 1. Exemplo de comparação entre uma imagem real e a prevista para determinado horário

A avaliação foi realizada comparando os frames previstos com os valores de referência pixel a pixel, na escala de temperatura original. A Tabela 3 apresenta as métricas obtidas. O EMA (Erro Médio Absoluto) de 0,85 °C indica que, em média, o erro por pixel é inferior a 1 °C, valor aceitável para o contexto de manutenção preditiva, em que os limiares de alerta de sobretemperatura são tipicamente superiores a 10 °C acima da faixa nominal de operação.

A dificuldade de predição concentra-se em regiões de alto gradiente térmico (tiristores sob carga), comportamento característico de arquiteturas com suavização temporal: o modelo tende a subestimar levemente picos extremos, mas preserva a distribuição espacial do calor. Como os trabalhos correlatos [Zhou et al. 2023, Sun et al. 2025] operam sobre saídas escalares ou agregadas, a métrica aqui reportada é complementar e não diretamente equivalente.

Tabela 3. Métricas de erro da predição ConvLSTM sobre o conjunto de validação (32 amostras).

Métrica	Valor
Erro Médio Absoluto (EMA)	0,85 °C
Percentil 50 (P50)	0,69 °C
Percentil 90 (P90)	1,70 °C
Percentil 95 (P95)	2,06 °C




Figura 2. Distribuição do erro de predição (EMA)

A análise da evolução do erro ao longo da sequência, vista na Figura 2, mostrou tendência estável, sem deterioração progressiva nas predições sucessivas, visto que somente foram observados 16 valores discrepantes em um espaço de 152 frames preditos. Esse comportamento é relevante porque valida a robustez do modelo dentro da janela de seis horas entre duas capturas reais, exatamente o intervalo que o DT precisa preencher para oferecer visualização térmica contínua.

3. Conclusão e Trabalhos Futuros

Os resultados parciais obtidos indicam que a ConvLSTM treinada sobre matrizes de temperatura absoluta é uma estratégia viável para preencher as lacunas temporais entre capturas termográficas em válvulas HVDC, preservando a fidelidade espacial do mapa térmico. A evolução de LSTM sobre imagens RGB para ConvLSTM sobre matrizes de temperatura reforça que o formato de entrada é determinante para a qualidade da predição, e que a migração para valores absolutos elimina o ruído da quantização do espaço de cor.

Por se tratar de um trabalho em andamento, os próximos passos da pesquisa concentram-se em duas frentes:

- **Aprendizado contínuo com retroalimentação.** A principal direção em desenvolvimento é a construção de um ciclo fechado em que, a cada nova captura termográfica real recebida, o sistema computa o erro entre a predição sintética previamente gerada para aquela *timestamp* e o valor de referência agora disponível. Esse erro alimenta uma rotina de retropropagação que ajusta os pesos da ConvLSTM de forma incremental, sem necessidade de reiniciar o treinamento do

zero. A expectativa é que a acurácia evolua ao longo do tempo e que o modelo se adapte automaticamente a variações sazonais e a mudanças no regime de carga da subestação;

- **Incorporação de variáveis operacionais.** Os parâmetros elétricos do sistema supervisão (corrente, tensão, temperatura ambiente e do líquido de arrefecimento), atualmente não utilizados como entrada do modelo, apresentam correlação direta com a distribuição de calor nos tiristores. Sua inclusão como variáveis exógenas tende a melhorar a predição em regimes transitórios e de alta carga, em que apenas a inércia temporal dos frames anteriores é insuficiente.

Agradecimentos

Os autores agradecem à Agência Nacional de Energia Elétrica (ANEEL) e à AXIA Energia pelo apoio ao projeto de P&D da ANEEL “Uso de Realidade Virtual e Aumentada aplicadas as fases de Engenharia, Manutenção e Controle do Sistema HVDC da AXIA Energia Norte” (PD-003729983/2025). Os autores também agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio ao projeto intitulado “Realidade Virtual e Aumentada associada a Gêmeos Digitais na Operação e Manutenção de Ativos do Setor Elétrico” (Processo nº 308355/2025-3), no âmbito da Chamada CNPq nº 18/2024 – Bolsa de Produtividade em Desenvolvimento Tecnológico e Extensão Inovadora (DT).

Referências

- Alexandre, A. M. (2025). Análise da confiabilidade de sistemas elétricos em ambientes industriais: Estudo de caso. Repositório UFU.
- Cardoso, A., Alexandre, A. M., Lamounier, E., and Lima, G. F. M. (2025). Towards a digital twin architecture: Enabling technologies and applications in power systems. In *Anais das Jornadas Iberoamericanas de Interação Humano-Computadora*, pages 1–10, Zacatecas, MX.
- Grieves, M. W. (2005). Product lifecycle management: The new paradigm for enterprises. *International Journal of Product Development*.
- Mansour, D.-E. A., Numair, M., Zalhaf, A. S., Ramadan, R., Darwish, M. M. F., Huang, Q., Hussien, M. G., and Abdel-Rahim, O. (2023). Applications of IoT and digital twin in electrical power systems: A comprehensive survey. *IET Generation, Transmission & Distribution*, 17(20):4457–4479.
- Shi, X., Chen, Z., Wang, H., Yeung, D.-Y., Wong, W.-K., and Woo, W.-c. (2015). Convolutional LSTM network: A machine learning approach for precipitation nowcasting. In *Advances in Neural Information Processing Systems (NeurIPS)*, pages 802–810.
- Sun, H., Li, S., Huang, J., Li, H., Jing, G., Tao, Y., and Tian, X. (2025). Dynamic spatial-temporal graph neural network for cooling capacity prediction in HVDC systems. *Energies*, 18(2):313.
- Zhou, S., Qin, L., Sun, H., Peng, B., Ruan, J., Wang, J., Tang, X., Wang, X., and Liu, K. (2023). TransFNN: A novel overtemperature prediction method for HVDC converter valves based on an improved transformer and the F-NN algorithm. *Sensors*, 23(7):3562.