



Ferramenta de IA para otimizar o retorno financeiro de instalações de medições de balanço em Transformadores sob a ótica de perdas comerciais

Tema: Recuperação de energia - Perdas não-técnicas

Autores: Marcelo Antonio Ramos Leite, Josue Jonathan Borges de Oliveira, Gabriel Alboretti

Co-Autores: Dicson Soares Rabelo, Jurema Celia Martins Braga, Thiago Cazes

Empresa: LIGHT SERVICOS DE ELETRICIDADE S.A.

Resumo

O projeto proposto utiliza modelos de inteligência artificial com técnicas como Kmeans, Gaussian Mixture Models, Regressão Logística e redes neurais MLP para otimizar a instalação de equipamentos de macromedição de energia em transformadores de distribuição. Esses equipamentos desempenham um papel vital na gestão eficiente da distribuição de energia, pois permitem monitorar o desempenho dos transformadores, além de identificar padrões de consumo, detectar anomalias e registrar com precisão a energia injetada, o que é essencial para analisar as perdas de faturamento.

Por meio de uma modelagem elaborada com base em informações de balanço energético e dados analíticos, o projeto prioriza os transformadores com as maiores estimativas de perdas. Isso é especialmente relevante em áreas onde tanto o poder público quanto a concessionária de energia podem intervir para combater fraudes e irregularidades. Essa abordagem busca maximizar o impacto das intervenções, direcionando os recursos disponíveis para os pontos mais críticos da rede elétrica, que possuem potencial para recuperar energia após regularização da situação de consumidores alimentados pelo transformador em questão.

1. Introdução

De acordo com o relatório de investidores, em 2023, as perdas não técnicas atingiram um valor de 64,5%, representando um significativo prejuízo financeiro para a LIGHT. Este valor é substancialmente maior do que os 40,04% reconhecidos na tarifa, conforme os parâmetros estabelecidos pela ANEEL na Revisão Tarifária (RTP) de março de 2022. Diante desse cenário, é crucial a implementação de ações e projetos direcionados ao combate das perdas não técnicas, especialmente em áreas onde há margem para intervenção por parte da companhia.

O projeto proposto e desenvolvido tem como objetivo abordar o tema por meio do desenvolvimento de modelos de inteligência artificial para priorizar a instalação de equipamentos de macromedição de energia em transformadores de distribuição. Isso foi feito considerando parâmetros que visam identificar áreas com perdas não técnicas que possam ser minimizadas após a atuação de combate em campo. Os equipamentos adquiridos pelo projeto desempenham um papel essencial na gestão eficiente da distribuição de energia, pois permitem o monitoramento do desempenho dos transformadores, juntamente com a identificação de

padrões de consumo, detecção de anomalias e registro preciso da energia injetada, essencial para a análise das perdas de faturamento.

Diante do custo com aquisição, instalação e manutenção desses equipamentos, e considerando a limitação de recursos da distribuidora, que não tem capacidade para equipar todos os seus quase noventa mil transformadores. A pesquisa propôs uma abordagem inovadora para priorizar os transformadores que devem receber a instalação do dispositivo. Utilizando informações de balanço energético juntamente com dados analíticos, foi desenvolvida uma modelagem com o objetivo de construir um ranking que priorize os transformadores com as maiores perdas estimadas em áreas onde o poder público e a concessionária de energia possam atuar no combate a fraude e irregularidades. Essa abordagem procura maximizar o impacto das intervenções, direcionando os recursos disponíveis para os pontos mais críticos da rede elétrica com potencial para incorporação de energia após a normalização de consumidores em situação irregular.

2. Desenvolvimento

Metodologia

Do universo disponível de transformadores, a equipe de pesquisa se concentrou em cerca de cinquenta e sete mil transformadores que atendem à rede aérea de distribuição. A tarefa é complexa, pois é necessário identificar os mais adequados para tal finalidade. No início do projeto, a Light possuía dados de medições provenientes dos equipamentos de macromedição de aproximadamente doze mil transformadores de sua rede de distribuição. Essa informação foi crucial e serviu como ponto de partida para a modelagem do problema e desenvolvimento da pesquisa.

Além das informações dos transformadores com medição, o projeto teve acesso ao modelo de combate a perdas comerciais EnergyWatch, um produto inovador desenvolvido em parceria com a Fu2re e a Light em um projeto de pesquisa e desenvolvimento ANEEL. Esse modelo atua como uma ferramenta de seleção de alvos para combate a perdas não técnicas. A partir das bases de dados do EnergyWatch, foi possível inferir informações relevantes sobre o potencial de retorno de energia de toda a área de distribuição. Seus modelos, além de indicar o potencial de irregularidade de uma determinada unidade consumidora, também apontam ações de recuperação e incorporação de energia após a normalização, uma variável extremamente relevante e necessária para o projeto atual.

Diante do exposto, o primeiro passo do projeto foi consolidar diferentes bases de informações e preparar os dados pertinentes ao problema apresentado. Para a construção de um modelo de inteligência artificial, a etapa crucial é a criação de uma base de dados analítica consistente. Um processo de consolidação dos dados foi desenvolvido pela pesquisa, normalizando as informações que, em sua maioria, estavam originalmente distribuídas no nível de unidade consumidora, para que representassem características do transformador que atende ao grupo de clientes vinculados. Esse processo permitiu a vinculação desses atributos aos registros de balanço energético dos transformadores com balanços conhecidos e validados. Os dados adotados pelo modelo foram categorizados em cinco grupos fundamentais: Dados Cadastrais, Faturamento, Notas, Inteligência e Balanço Energético. Os quatro primeiros demandaram uma consolidação específica no nível de transformador, já que os dados originais estavam registrados a níveis de clientes.

- Dados Cadastrais: constituídas de informações relativas às características da instalação do cliente, suas propriedades, localização e estado atual.
- Faturamento: Compreendem dados mensais de todas as faturas associadas a cada cliente.

- Notas: Englobam todas as notas de serviço pertinentes a cada cliente.
- Inteligência: Este grupo resulta da utilização do produto EnergyWatch para seleção de alvos, cujo foco era priorizar a seleção de clientes com alto potencial de fraude. Cada cliente possuía um score associado a um indicativo de fraude, bem como informações sobre as características específicas de fraude que apresentavam e potencial de energia recuperado e energia incrementado após a normalização.
- Balanço Energético: Contêm os dados mensais referentes ao balanço dos transformadores já instalados. O processo de transformação dos dados teve o emprego de duas técnicas descritas a seguir: 1) Para características categóricas, utilizou-se a técnica "one hot encode", gerando um vetor binário dessas características e, posteriormente, somando essas novas características para proporcionar uma sumarização no nível de transformador. 2) No caso de características numéricas, foi adotado um procedimento semelhante, agrupando os valores em faixas equivalentes antes da consolidação utilizando o operador "one hot encode". Neste operador, sendo x_i uma variável categórica com n valores distintos, representados por $1, 2, \dots, n$, o one-hot encoder mapeia x_i em um vetor binário conforme exemplificado na figura 1, onde i corresponde ao valor distinto da categoria em seu vetor de possíveis atribuições. Após essa operação, para cada grupo de dados, foram removidas as características que apresentavam mais de 90% dos dados zerados ou nulos, adotando o algoritmo 'MinMaxScaler'. Este conjunto de técnicas asseguram a qualidade do dado utilizado nos passos seguintes, qualificando melhor os atributos que serão entradas para o modelo de inteligência artificial proposto. Todo esse processo pode ser visualizado de maneira resumida na figura 2.

$$f(x_i) = \begin{cases} [1, 0, \dots, 0] & \text{se } i = 1 \\ [0, 1, \dots, 0] & \text{se } i = 2 \\ \vdots & \\ [0, 0, \dots, 1] & \text{se } i = n \end{cases}$$

Figura 1 – Função "one hot encode"



Figura 2 - Processo de transformação de dados

O problema pesquisado não pode ser reduzido a uma categorização simples, pois demanda uma abordagem mais complexa para identificar os melhores transformadores para a instalação do equipamento, visando o retorno de incorporação de energia após ações de normalização por inspeção de campo. Desta forma, a pesquisa foi estruturada em quatro etapas principais: clusterização, associação, modelos de predição e priorização.

A etapa inicial de clusterização, consiste no agrupamento de todos os transformadores existentes, sejam eles medidos ou não, com base nos quatro primeiros grupos de dados transformados na etapa anterior (Dados Cadastrais, Faturamento, Notas e Inteligência). Para essa clusterização, foram empregadas duas técnicas distintas: 'K-Means' e 'Gaussian Mixture Model' (GMM). Durante a pesquisa e testes, optou-se pela utilização combinada dos dois métodos, permitindo que a clusterização leve em consideração tanto as médias dos centroides no caso do K-Means, quanto as variâncias no caso do GMM, criando um conjunto mais disperso de clusters. Ao final desse processo, obtemos, para todos os transformadores, medidos e não medidos, as classificações dos clusters a que pertencem em cada uma das técnicas aplicadas. A técnica desenvolvida combina as duas saídas e produz um mapa de correlação entre os transformadores medidos e não medidos e pertencentes a um mesmo cluster.

A associação, segunda etapa do processo, busca conectar os transformadores não medidos aos medidos. Dentro de cada agrupamento criado na etapa anterior, contendo tanto transformadores medidos quanto não medidos. São calculadas distâncias e proporcionalidades entre cada par (medido - não medido) de transformadores. Isso resulta na identificação do "transformador pai" mais próximo para cada transformador não medido, permitindo a estimativa proporcional dos valores de perdas. A conclusão desta etapa permite avaliar como um transformador que tem seu balanço medido se correlaciona com os transformadores sem medição, analisando suas características mais gerais possíveis para correlacionar as perdas de energia. Uma exemplificação do conjunto das duas primeiras etapas pode ser visualizada na figura 3, onde foi adotado a representação de apenas duas variáveis para ilustrar o cenário desejado.




Figura 3 – Representação 2D da associação de transformadores

Com o cálculo da estimativa de perdas para os transformadores não medidos em mãos, a terceira etapa, denominada de modelos de predição, permite a criação de modelos de aprendizado de máquina para priorizar os melhores transformadores para instalação do equipamento de medição. Considerando a natureza temporal das perdas no balanço energético, foram utilizados dois modelos de inteligência artificial, sendo um modelo de regressão logística e uma rede neural MLP. Ambos os modelos foram empregados para capturar as características específicas e a temporalidade dos dados. A regressão logística, um modelo estatístico usado para modelar a probabilidade de uma variável categórica dependente assumir um determinado valor, foi explorada para maximizar transformadores medidos que tenham percentuais positivos de incremento de energia após execuções de campo como notas de corte, religação, inspeção, normalização e regularização de clandestinos. Essa variável é extremamente importante, pois condiciona a saída do modelo às regiões onde as ações da concessionária refletem em incremento de energia faturada. O segundo modelo, uma rede neural MLP, avalia todo o conjunto de características de todos os transformadores, com e sem medição, para validar o grau de aderência da estimativa de perdas realizada com base no método de clusterização. Essa rede neural serve como balizadora das estimativas de perdas. Ao final deste processo, as saídas desses modelos são combinadas para fornecer um score de indicação do transformador não medido, permitindo uma seleção mais precisa e eficiente dos transformadores para a instalação de macromedição.

A última etapa, chamada de priorização, utiliza os modelos executados na etapa anterior e as consolidações da primeira etapa. Alguns filtros de negócio são aplicados para otimizar a seleção dos transformadores para a instalação do equipamento. Por exemplo, há preferência por transformadores não subterrâneos e localizados em áreas seguras para a equipe de campo. Um exemplo de filtragem do projeto emprega raios dinâmicos com informações de unidades classificadas como Área de Severos Riscos Operacionais (ASRO), juntamente com dados de órgãos públicos, como a plataforma Fogo Cruzado, que indica regiões com alta incidência de eventos criminais. Essas informações são usadas para classificar os transformadores em áreas de risco, aumentando a segurança das equipes ao evitar regiões com maior risco operacional.

Ao final do processo construído, os transformadores são priorizados não apenas com base na estimativa de perdas e potencial de recuperação de energia, mas também levando em consideração a segurança operacional e a viabilidade prática da instalação. A metodologia empregada resulta na geração de um indicador quantitativo denominado "Score", variando de 0 a 1. Esse "Score" desempenha um papel crucial na determinação da prioridade de instalação. À medida que o valor se aproxima de 1, a prioridade aumenta proporcionalmente, podendo estar diretamente relacionada às perdas associadas ao transformador em questão. Essa abordagem foi desenvolvida em processos automatizados, com uma ferramenta web sendo alimentada e projetando as saídas do processo para que a área de negócios utilize os dados. Isso simplifica o processo de escolha e permite uma alocação eficiente de recursos, priorizando os transformadores cujas instalações dos medidores terão um impacto mais significativo na mitigação das perdas não técnicas. Dessa forma, evita-se o direcionamento da instalação desses equipamentos com base em decisões empíricas dos colaboradores de campo, promovendo uma tomada de decisão mais fundamentada e estratégicas.

Resultados

A pesquisa mediu os resultados em duas fases. A primeira abordagem foi verificar a eficácia do modelo de previsão de perdas dos transformadores com base nos dados analíticos consolidados e apontados pelo modelo. Nesta etapa, nossa equipe processou os modelos e indicou a instalação de vinte equipamentos, com o objetivo de monitorar se a perda observada no equipamento estava compatível com a predição do modelo. Durante a fase de indicação dos locais para instalação, a equipe de campo identificou alguns problemas com as seleções realizadas pelo time técnico. Houve a necessidade de buscar novos locais, principalmente por motivos de segurança da equipe e dificuldades no combate às perdas. A área de concessão da Light tem áreas de severa restrição operacional dinâmicas que não estão totalmente mapeadas, e alguns casos precisaram ser revistos.



Figura 4 - Instalação Equipamento do Projeto

Ao final da primeira rodada de instalação dos equipamentos (a foto de um equipamento sendo instalado pode ser vista na figura 4), obtivemos um resultado de energia injetada pelos 20 equipamentos instalados de 760.837,92 kWh. Observamos, para estes equipamentos, uma perda de 85,88% em energia medida e uma perda de 84,88% em energia faturada. Esses resultados demonstram a precisão do modelo na predição das perdas e destacam a importância de ajustes contínuos no processo de seleção de locais para instalação, visando sempre a segurança da equipe e a eficiência operacional.

Com os resultados desta etapa validando os modelos desenvolvidos e a abordagem da técnica, a equipe de pesquisa avançou para a construção de uma ferramenta com inter-face para a área de negócios interagir com os modelos desenvolvidos no projeto e permitir o acompanhamento das ações. Além disso, foi realizado um novo experimento de varredura de todos os consumidores de um transformador com macromedição para identificar a natureza das perdas. Com o apoio da área de combate a perdas, foi instituída uma ação conjunta de campo com uma equipe destacada especificamente para percorrer todos os clientes vinculados ao transformador que apresentava as maiores perdas em energia medida e faturada.

Os resultados de campo apontaram que o transformador estava com 46,88% de clientes clandestinos ligados à rede da concessionária e 53,33% dos clientes ativos apresentaram situação de fraude ou irregularidade. Após as ações de campo, a equipe de pesquisa monitorou o desempenho da ação para avaliação do Kw Faturado das unidades consumidoras com ações de fraudes ou irregularidades encontradas. Para este grupo de clientes, identificou-se um aumento de 29% no consumo medido em relação à média de consumo dos 3 meses anteriores e um aumento de 37% do consumo medido em relação ao mês anterior à fraude. A atividade conjunta comprovou que o objetivo do método em abordar a instalação de equipamentos em regiões com perdas e com possibilidade de atuação do combate e consequente incorporação de energia mostrou-se eficaz e viável com as técnicas e processos constituídos, sendo uma ferramenta que agrega valor para a empresa.

Ainda no escopo da pesquisa, a área de negócios indicou um total de 62 transformadores para instalação dos equipamentos, sendo instalados um total de 40 com recursos do projeto.

3. Conclusão

O projeto teve como objetivo a construção de uma metodologia que priorize e apoie a equipe de negócios no direcionamento da instalação de equipamentos de macromedição para apoiar ações de combate às perdas não técnicas. A pesquisa e os resultados mostraram-se valiosos para a área de negócios, pois aproximam as equipes de engenharia e as equipes de campo, tornando-se um fator de apoio e monitoramento dos resultados. O projeto se encerra entregando um portal que integra as informações técnicas e atualiza os modelos de inteligência artificial desenvolvidos, criando um processo que pode ser adotado pela empresa em suas ações de campo. Isso cria um impacto nas ações de combate às perdas não técnicas e gera um retorno direto e indireto para a companhia. Esse portal não só auxilia na tomada de decisões mais eficazes, mas também facilita a coordenação entre as equipes envolvidas, promovendo uma abordagem mais integrada e eficiente para enfrentar os desafios relacionados às perdas de energia.

4. Referências bibliográficas

[1]Central de Resultados LIGHT, Apresentação Resultados, (2024, maio). [Online].

D i s p o n í v e l :
h t t p s : / / a p i . m z i q . c o m / m z f i l e m a n a g -
er/v2/d/50b51302-4c48-4351-b296-bfcbe65fd70a/08ff5ad9-7458-6fbf-6b05-2bccbcf98b20?origin=1

[2]Gabriel Alboretti, Marcelo Leite, Rafael Marques, Rodrigo Nascimento, Thiago Cazes, Sistema de combates a perdas comerciais EnergyWatch, 2020

- [3]D. A. Valdes, I. O. Ayaquica, C. Guillen and J. R. Vazquez, "Gaussian Mixture Models Implementation to Enhance Spectral Clustering," in IEEE Latin America Transactions, vol. 14, no. 3, pp. 1416-1426, March 2016, doi: 10.1109/TLA.2016.7459629.
- [4]Q. Qiu, Q. Zhang and K. Guo, "Grey Kmeans algorithm and its application to the analysis of regional competitive ability," 2014 IEEE 7th Joint International Information Technology and Artificial Intelligence Conference, Chongqing, China, 2014, pp. 249-253,
- [5]A. Meffe¹, P. H. Baumann¹, A. U. Antunes¹, C. C. B. de Oliveira¹, T. B. Cazes², D. M. Duarte², A. M. da Silva², A. F. Rocha³ e G. W. S. Gusmão⁴ Cálculo e Previsão de Perdas Técnicas e Não Técnicas por Regional, Subestação e Alimentador, Considerando Efeitos das Manobras e do Plano de Expansão, Agosto 2017 disponível em <https://www.researchgate.net/publication/319206182>