

Aplicação Prática de Previsão Ocorrências de Interrupção de Energia baseada em Machine Learning

Tema: Operação

Autores: Rafael Perez Pagan

Co-Autores: Rafael Sampaio De Bonis, João Vítor de Moraes Santos Gomes

Empresa: DDMX

Resumo

A qualidade do serviço de distribuição de energia elétrica impacta diretamente a qualidade de vida dos consumidores. Incidentes que levam à interrupção no fornecimento de energia podem ocorrer, e é importante que uma resposta rápida seja dada pela empresa responsável pelo restabelecimento do serviço. Este trabalho tem como objetivo o desenvolvimento de uma aplicação prática de previsão de ocorrências interrupção de energia utilizando inteligência artificial, visando auxiliar empresas distribuidoras na melhoria da realocação de seus recursos e agilidade de seus serviços emergenciais. Primeiramente, diferentes modelos de previsão foram desenvolvidos e aplicados utilizando dados históricos de ocorrências e climáticos de diferentes regiões do estado do Rio de Janeiro. O modelo com melhores resultados utilizou o método de regressão *Random Forest*, com valores de erro percentual absoluto médio em torno de 13%. O modelo selecionado foi então replicado em uma plataforma *web* para uso dos gestores da distribuidora e passou a integrar o planejamento diário de mobilização de equipes técnicas.

1. Introdução

A energia elétrica possui um papel fundamental na manutenção do bem-estar da população e desenvolvimento econômico dos países. A interrupção do fornecimento, devido a eventos que vão desde o clima (chuvas ou ventos intensos) até acidentes automobilísticos ou catástrofes naturais, deve ser evitada, e caso ocorra, o fornecimento deve ser reestabelecido com rapidez. Além do evidente prejuízo ao consumidor, a própria empresa de distribuição fica sujeita à aplicação de multas e advertências por parte da agência reguladora que, no caso do Brasil, é a ANEEL (Agência Nacional de Energia Elétrica).

A aplicação de técnicas de inteligência artificial (IA) em problemas relacionados à geração e distribuição de energia elétrica está se tornando cada vez mais comum (GURURAJAPATHY, MOKHLIS, & ILLIAS, 2017; MEI & DOOMERNIK, 2017). Essas técnicas visam a classificação e previsão de demanda de carga (RAZA & KHOSRAVI, 2015), a previsão de eventos climáticos (DADKHAH, REZAEI, & CHAVOSHI, 2018), entre outros. Neste trabalho, tais técnicas serão utilizadas para previsão de ocorrências de interrupção de energia. O objetivo deste trabalho, portanto, é apresentar o desenvolvimento de uma aplicação prática de previsão de ocorrências de interrupção de energia utilizando métodos computacionais baseados em IA. Para isso, serão utilizados dados históricos de ocorrências de interrupção do fornecimento de energia em regiões do estado do Rio de Janeiro (RJ), Brasil e dados climáticos das mesmas regiões. Diferentes modelos foram

desenvolvidos e aplicados a fim de selecionar aquele com os melhores resultados para a massa de dados utilizada.

A aplicação prática visa apresentar as previsões de ocorrências de interrupção de energia para cada região da área de concessão. Para isso, desenvolveu-se um *dashboard* com atualização automática cujo objetivo é balizar as decisões de seus gestores na realocação de recursos e equipes técnicas para atender as demandas previstas com antecedência de até 96 horas.

No decorrer deste trabalho serão apresentados o processo de desenvolvimento do modelo de previsão, a aplicação prática e suas diferentes visões assim como a análise dos resultados obtidos e conclusões.

2. Desenvolvimento

Para cumprir o objetivo proposto neste trabalho, o processo de pesquisa e desenvolvimento foi dividido em cinco etapas:

- Etapa 1: Aquisição e pré-processamento de dados;
- Etapa 2: Desenvolvimento e treinamento dos modelos de previsão;
- Etapa 3: Análise dos resultados para seleção do modelo mais adequado;
- Etapa 4: Aplicação prática

Os próximos tópicos apresentarão a metodologia e a fundamentação teórica utilizada durante estas cinco etapas.

2.1 Aquisição e pré-processamento de dados

Para desenvolvimento e validação dos modelos de previsão foram utilizados dados provenientes de duas fontes: 1) dados históricos sobre ocorrências de interrupção de energia, referentes a área de concessão da ENEL¹ no estado do Rio de Janeiro; e 2) histórico de dados climáticos obtidos junto à empresa Climatempo². Nos dois casos, os dados utilizados abrangem o período entre 01/01/2019 e 30/06/2022, e são referentes a três regiões do estado do Rio de Janeiro, Brasil, que possuem características geográficas e climáticas bem distintas: Macaé, Cabo Frio e Niterói.

Com relação ao histórico de ocorrências, foram utilizados dados de: identificação de ocorrências, nível de tensão (BT, MT ou AT), causa, dia e horário do início e fim do evento e localidade. Como o objetivo do modelo é realizar uma previsão diária, os dados históricos de ocorrências foram agrupados em amostras diárias. Seu formato está representado na tabela 1.

Tabela 1 - Formato agregado das ocorrências emergenciais.

Ocorrência Emergencial	
data	Valor que representa a data inicial do período, em data hora completa
localidade	Região da ocorrência (Macaé, Cabo Frio ou Niterói)
BT	Contagem de ocorrências do tipo Baixa Tensão.
MT	Contagem de ocorrências do tipo Média Tensão.
AT	Contagem de ocorrências do tipo Alta Tensão.
calculo_tma	Soma dos tempos de atendimento das ocorrências do dia.
conh_total	Soma da multiplicação da duração e quantidade de clientes afetados totais das ocorrências do dia
clientes_afetados	Soma da quantidade de clientes que foram afetados pelas ocorrências do dia.

Do histórico climático, foram utilizados os dados de: acúmulo de precipitação diária medido em mm, valores máximo, mínimo e médio da intensidade do vento no dia medidos em m/s e valores máximo, mínimo e médio da temperatura para cada dia. O formato dos dados climáticos utilizado está representado na Tabela 2.

Tabela 2 – Formato dados climáticos.

dados_climaticos	
data	Valor que representa a data inicial do período, em data hora completa
localidade	Região dos dados climáticos (Macaé, Cabo Frio ou Niterói)
velocidade_vento	Valor que representa a velocidade do vento, em km/h, no período.
rajada_vento	Valor que representa a velocidade máxima do vento, em km/h, no período.
temperatura	Valor que representa a temperatura média, em graus Celsius, no período.
Temperatura_minima	Valor que representa a temperatura mínima, em graus Celsius, do dia.
Temperatura_maxima	Valor que representa a temperatura máxima, em graus Celsius, do dia.
probabilidade_chuva	Valor que representa a probabilidade, em percentual, de chover no dia.
precipitacao_chuva	Valor que representa o acúmulo de precipitação, em mm, do dia.

Um passo muito importante para o treinamento de uma inteligência artificial é o pré-processamento dos dados. Nele os dados são adaptados para o melhor aproveitamento. O método utilizado nessa pesquisa foi o passo de normalização utilizando a técnica *MaxMinScaler* (KOTSIANTIS; KANELLOPOULOS; PINTELAS, 2006; FRAEDRICH; LARNDER, 1993). Este normalizador divide cada valor pela máxima diferença entre os mínimos e máximos; portanto, é ideal para normalizar dados com diferentes escalas.

2.2 Desenvolvimento e treinamento dos modelos de previsão

Aprendizado de Máquina (Machine Learning (ML)) é um subcampo da inteligência artificial. Baseia-se no desenvolvimento de inteligência capaz de reconhecer erros e padrões, e utilizar desse aprendizado para prever resultados, classificar dados ou agrupá-los. Os modelos de treinamento com aprendizado de máquina podem ser categorizados em dois de principais tipos: supervisionado e o não-supervisionado.

Modelos que utilizam de resultados pré-definidos são nomeados de aprendizado supervisionado, onde são utilizados valores conhecidos da variável alvo para aprender quais devem ser seus resultados para valores desconhecidos. Esses valores servem como rótulos para as previsões, permitindo um ajuste com base na minimização do erro entre esperado e real. Um exemplo de modelo de treinamento supervisionado é a regressão, que tem como objetivo prever o valor de saída de uma variável numérica (dependente) a partir de um conjunto de uma ou mais variáveis independentes. As técnicas de regressão escolhidas para participar dos ensaios desse estudo foram *Linear Regressor*, *MLP Regressor*, *SVR* e *RandomForest Regressor*.

A técnica de regressão linear ajusta uma reta através dos dados de dispersão, ajustando com um modelo linear com coeficiente angular w , a reta é desenhada fazendo o produto escalar de w e x (conjunto de dados), para assim minimizar a soma residual dos quadrados entre os valores observados do conjunto de dados e os valores previstos pela aproximação linear. É a técnica de regressão mais simples e também o mais comum de ser usado (SOUZA; JUNQUEIRA, 2005).

A MLP Regressor (Multi-layer Perceptron) é uma técnica de regressão que utiliza o treino de uma função $f(.)$: $R_m \rightarrow R_o$ gerado de um algoritmo de aprendizado supervisionado MLP que usa como base o conjunto de dados de treinamento, tamanho de dados na entrada (m) e o número de dados da saída (o). Setando algumas características $X = \{x_1, x, \dots\}$ e um alvo y , o algoritmo aprende uma função não-linear aproximada pelos dados de classificação ou regressão (MURTAGH, 1991).

A técnica SVR (Support Vector Regressor) é uma técnica de regressão baseada nos modelos de máquina de vetor de suporte. O funcionamento desta técnica se baseia no modelo de μ SVR que utiliza dos parâmetros C (parâmetro de regularização) e μ (margem de erro aceitável) para o cálculo da minimização de erro e o parâmetro kernel para mapear a transformação da dimensão dos dados de entrada, permitindo assim a geração de funções cujo comportamento não seja necessariamente linear (SMOLA; SCHÖLKOPF, 2004). No Random Forest, cada árvore de decisão é feita a partir de uma amostra extraída com substituição do conjunto de treinamento, a construção da árvore é feita dividindo cada nó com a melhor divisão encontrada em um subconjunto aleatório de tamanho determinado. O objetivo é diminuir a variância do estimador florestal. As árvores de decisões individuais, normalmente exibem um alto valor de variância e tendem se ajustar (SEGAL, 2004; RODRIGUEZ-GALIANO et al., 2015).

Para realizar um comparativo dos resultados obtidos por cada um dos métodos utilizados durante o treinamento, todos eles passaram por uma mesma rotina capaz de produzir um relatório no final da execução com os tempos de treinamento, tempo de teste, e medidas de erros adotadas. Essa rotina foi escrita em

Python no Google Colab, utilizando as bibliotecas *Scikit Learn*, *Pandas* e *Numpy*.

Durante os testes, a lista *listaPreProcessamento* foi configurada com um valor vazio, para utilizar os dados sem processamento e um valor contendo a classe *MinMaxScaler* do *sklearn*; a lista *listaRegressores* foi configurada contendo, em cada posição, as classes *LinearRegressor*, *SVR*, *MLPRegressor* e *RandomForestRegressor* já instanciadas; e a função *treinaCV* (r, d) recebe um regressor r e um conjunto de dados d para

realizar o treinamento do modelo utilizando validação cruzada (KRSTAJIC et al., 2014; FUSHIKI, 2011). Como o treinamento dos regressores foi feito utilizando um algoritmo de validação cruzada de *5-fold*, o cálculo das medidas adotadas é contabilizado com a média aritmética dos valores obtidos de cada partição do banco.

2.3 Análise dos resultados para seleção do modelo mais adequado

Para fins de análise de resultados, as métricas de erros são essenciais para verificar se o treinamento conseguiu de forma satisfatória reproduzir, e consequentemente prever no caso da regressão, os resultados da análise. Há muitos tipos de métricas de erros, e uso dessas métricas depende da característica de cada problema. Como o modelo da pesquisa é de regressão supervisionada, e o intuito é prever resultados, as métricas selecionadas foram R2 Score e MAPE.

O coeficiente de determinação, também conhecido como R2 Score, representa a variância das variáveis independentes no modelo treinado e as variáveis dos dados de treinamento. Essa métrica fornece uma indicação da qualidade do ajuste, assim sendo, uma medida do quão bem as amostras ainda não vistas serão previstas pelo modelo treinado, por meio da variância explicada. (CHICCO; WARRENS; JURMAN, 2021).

O erro médio percentual absoluto (*Mean Absolute Percentage Error* - MAPE), também conhecido como Desvio Percentual Médio Absoluto (MAPD), é uma das métricas de avaliação de erros utilizadas nesse estudo. Essa métrica tem a função de ser sensível aos erros relativos gerados, diferentes das outras métricas que são calculadas de forma global, o MAPE não se altera em escala global da variável destino. A métrica não ignora valores de baixa magnitude, assim como o Erro Médio Absoluto (MAE) no resultado, isso porque é calculado o percentual relativo do erro em relação ao resultado real.

Graças à configuração estruturada no algoritmo de ensaios, é possível observar os resultados obtidos por cada regressor de forma separada. O retorno da função *treinaCV(r,d)* apresenta os resultados de R2 Score, MAPE e tempo de treinamento para cada localidade e método de regressão. Os resultados podem ser observados na tabela 3.

Tabela 3 – Resultados dos métodos de regressão

SUCURSAL	TÉCNICA	TEMPO DE TREINAMENTO	R2	MAPE
CABO FRIO	<i>LinearRegression</i>	0,0448 [s]	-0,1339	32,83%
	<i>MLPRegressor</i>	2,8041 [s]	-0,1242	31,22%
	<i>RandomForestRegressor</i>	7,2257 [s]	0,7495	13,09%
	<i>SVR</i>	0,0497 [s]	-0,1685	29,05%
MACAÉ	<i>LinearRegression</i>	0,0435 [s]	-0,4946	41,46%
	<i>MLPRegressor</i>	2,2268 [s]	-0,1907	35,68%
	<i>RandomForestRegressor</i>	7,0849 [s]	0,6503	13,99%
	<i>SVR</i>	0,0473 [s]	-0,1212	30,76%
NITERÓI	<i>LinearRegression</i>	0,0439 [s]	0,0744	28,91%
	<i>MLPRegressor</i>	2,3119 [s]	-0,2156	33,14%
	<i>RandomForestRegressor</i>	7,3191 [s]	0,7494	13,20%
	<i>SVR</i>	0,0476 [s]	-0,2137	31,64%

O melhor método, como pode-se observar na Tabelas 3, foi o *RandomForestRegressor*, com a média do R^2 em torno de 0,72 e do MAPE em 13,4%. Este método se mostrou ser o com melhor R^2 , porém também foi o com maior tempo de treinamento, levando centenas de vezes mais tempo que os métodos *SVR* e *LinearRegression*. No entanto, mesmo com essa diferença de tempo, o caso que mais levou tempo para treinar com os dados utilizados no estudo levou em torno de 10 segundos, o que é um tempo de execução aceitável para a aplicação desejada.

Os gráficos apresentados nas figuras 1, 2 e 3, ilustram os resultados para um período de dados previstos utilizando o modelo *RandomForestRegressor*. Pode-se observar a comparação entre a quantidade real de ocorrências para cada dia e a quantidade prevista pelo modelo.




Figura 1 – Gráfico comparativo previsão vs real para Cabo Frio




Figura 2 – Gráfico comparativo previsão vs real para Niterói




Figura 3 – Gráfico comparativo previsão vs real para Macaé

2.4 Aplicação prática

Para a aplicação prática do modelo optou-se por implementá-lo no sistema GEOnline. O GEOnline é um sistema de auxílio à tomada de decisão desenvolvido pela empresa DDMX³ através da plataforma DDMX

Intellergy para a operação emergencial da Enel. A plataforma *DDMX Intellergy* é uma ferramenta que permite:

- Receber e coletar dados de múltiplas fontes, em tempo real;
- Construir, implementar e adequar regras de operações;
- Disparar alertas em tempo real através do cruzamento de dados e da aplicação de algoritmos inteligentes;
- Visualizar os dados através de grids, mapas e dashboards com os principais indicadores gerenciais e operacionais, em tempo real e em visão histórica;
- Agendamento de extratores e *jobs* para execução de cálculos de novos indicadores ou integração com outros sistemas.

A plataforma possui os dados em tempo real de ocorrências de interrupção de energia obtidos através de uma integração com o OMS (*outage management system*) da Enel Rio e possui dados climáticos obtidos com a API Climatempo. Desta forma, o desenvolvimento do modelo e da aplicação prática utilizam as mesmas bases de informação, que diminui a probabilidade de não replicabilidade entre os dois ambientes. A equipe de desenvolvimento da DDMX incluiu um novo serviço à plataforma capaz de gerar modelos de previsão com uso da técnica *RandomForestRegressor*. A figura 4 apresenta um fluxo de funcionamento deste serviço.

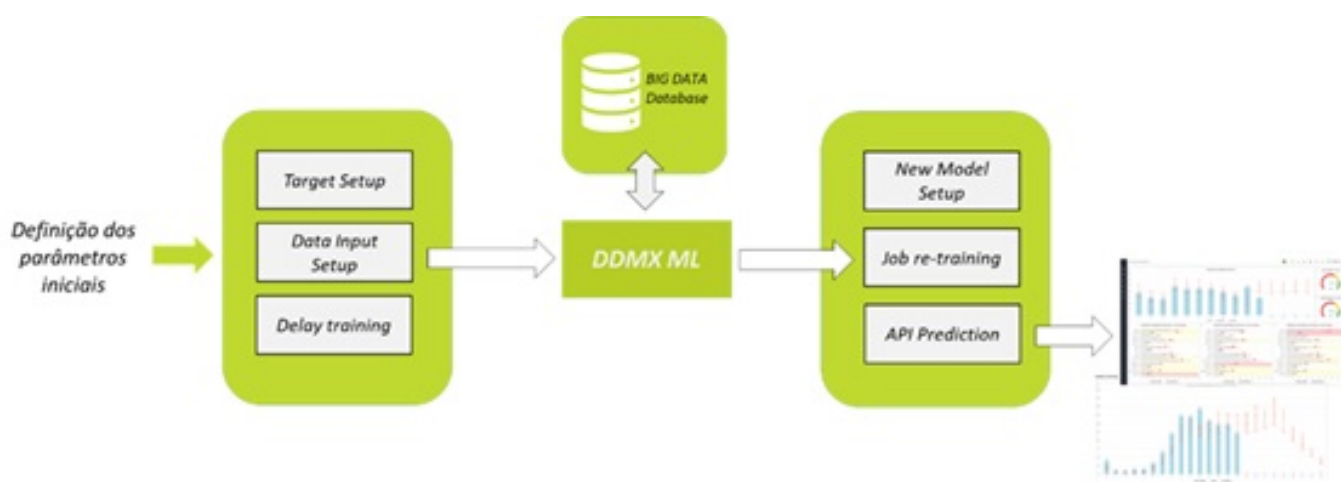


Figura 4 – Funcionamento do gerador de modelos na plataforma *DDMX Intellergy*

Com o uso deste serviço, possibilitou-se a criação de um modelo de previsão dentro da plataforma configurando o mesmo alvo de previsão (número de ocorrências de interrupção de energia), os dados de entrada (localização das tabelas de ocorrências e dados climáticos dentro da base de dados) e a periodicidade de treinamento (diário). O serviço então armazena o novo modelo e disponibiliza um serviço web (API) para consulta da previsão atualizada por outros serviços da plataforma.

Para visualizar as previsões e acompanhar a sua assertividade, propôs-se a construção de um *dashboard* para consulta das previsões dentro do GEOnline. A aplicação de visualizações de informação interativas pode auxiliar um especialista a explorar os dados por diferentes perspectivas e compreender partes de uma realidade que são de seu interesse. A figura 5 apresenta o dashboard desenvolvido.

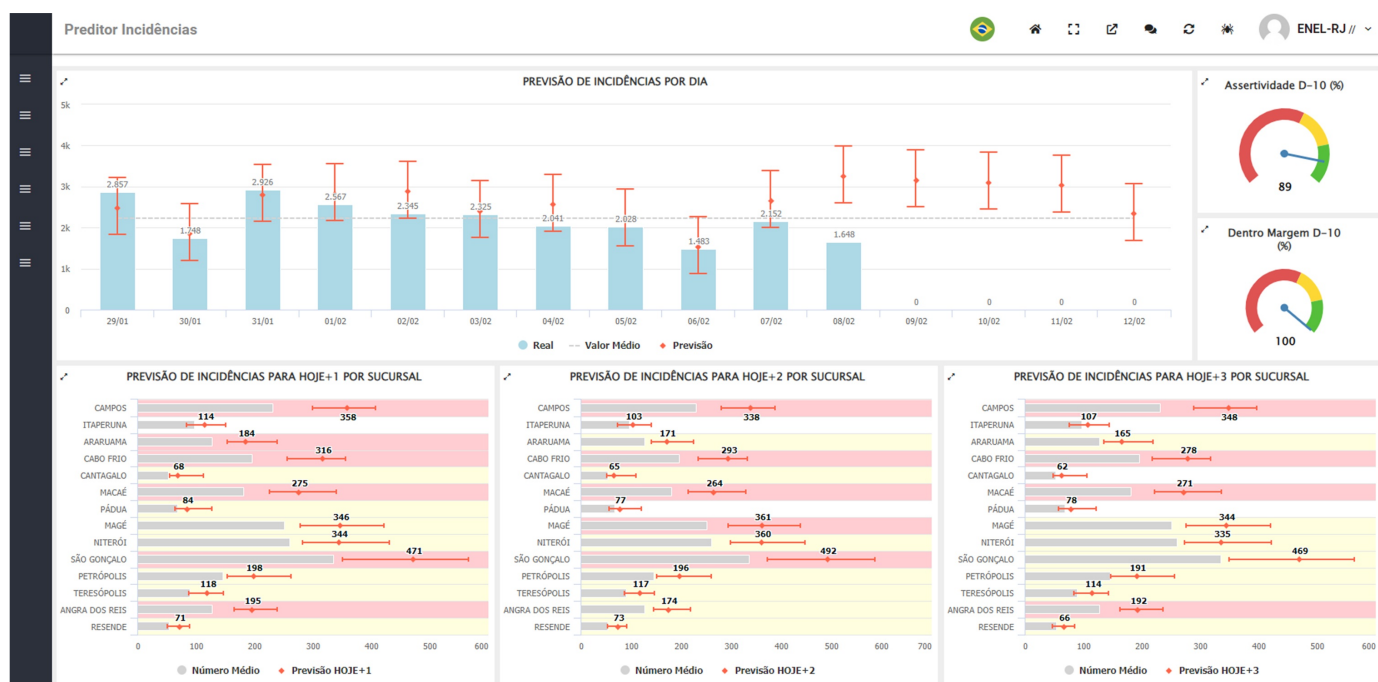


Figura 5 – Dashboard Preditor de Ocorrências GEOnline

A ferramenta permite visualizar a comparação entre a quantidade de ocorrências de interrupção prevista pelo modelo e a quantidade real para os últimos dez dias. A previsão estende-se para os próximos quatro dias (96 horas). Foi incluído também dois indicadores de performance do modelo. Um deles foi denominado “assertividade” medido através da diferença entre 100% e o MAPE, o outro foi denominado “dentro margem”, que indica o número de dias em que o número real de ocorrências esteve dentro da margem de erro da previsão.

Também foram incluídos três gráficos com as previsões por localidade para os próximos três dias. Destacando-se em amarelo aquelas localidades cuja previsão está pelo menos 20% acima do seu número médio de ocorrências diário e em vermelho aquelas localidades cuja previsão está pelo menos 40% acima do seu número médio de ocorrências diário.

O usuário também pode interagir com a ferramenta, filtrando apenas uma localidade e observando os resultados dos indicadores apenas para a localidade escolhida, conforme figura 6. Outra interação permitida é visualizar o comportamento previsto para os diferentes períodos do dia. A figura 7 apresenta um exemplo em que o usuário seleciona uma data e visualiza o comportamento previsto de aumento e diminuição de ocorrências durante o dia selecionado. Nota-se que há a curva típica com o valor médio de ocorrências para cada horário e o valor previsto na mesma visão. Para dias passados, essa mesma visualização permite fazer um comparativo da assertividade da previsão com o número real de cada horário, exemplificado na figura 8.

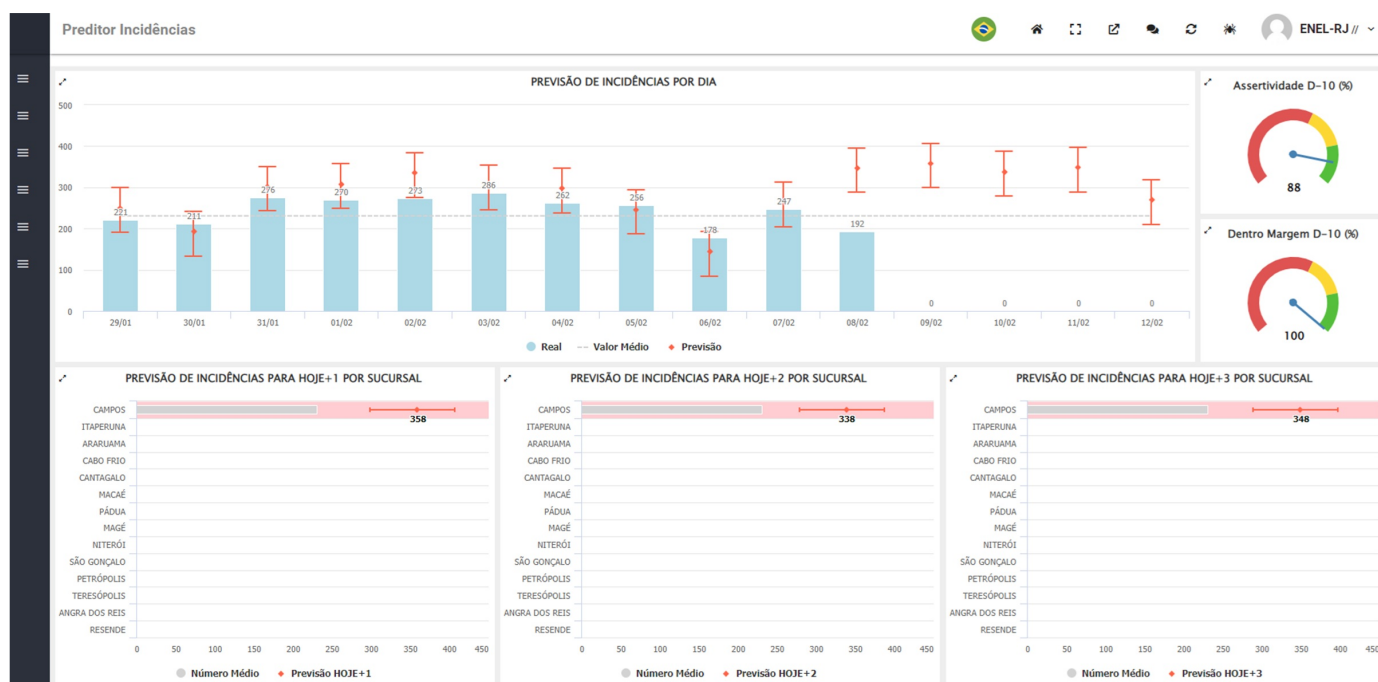


Figura 6 – Dashboard Preditor de Ocorrências GEOnline com filtro




Figura 7 – Dashboard Preditor de Ocorrências GEOnline quebra por hora




Figura 8 – Dashboard Preditor de Ocorrências GEOnline quebra por hora real vs previsto

Após a apresentação da nova funcionalidade aos gestores da distribuidora, decidiu-se que a ferramenta atendia os critérios necessários para uso. Um treinamento foi efetuado e a ferramenta disponibilizada para usuários de níveis de acesso pré-definidos. As previsões contidas no novo painel passaram a integrar parte do conjunto de dados utilizados no planejamento diário de mobilização de equipes técnicas e recursos, conforme objetivo inicial.

3. Conclusão

Localidades diferentes com um mesmo comportamento climático podem ter diferentes impactos na demanda de serviços emergenciais de recomposição de energia. Técnicas de IA permitem dimensionar estes impactos especificamente para cada localidade. Este trabalho teve como objetivo apresentar o desenvolvimento de uma aplicação prática de previsão de ocorrências de interrupção de energia utilizando métodos de IA com dados históricos das ocorrências e climáticos.

Diferentes modelos de regressão foram desenvolvidos e aplicados a fim de selecionar aquele com os melhores resultados para a massa de dados utilizada. A técnica *Random Forest Regressor* foi selecionada por ter os resultados mais satisfatórios, com a média do R2 em torno de 0,72 e do MAPE em 13,4%.

Os resultados satisfatórios e a plataforma fornecida pela empresa DDMX permitiram a construção de uma aplicação prática capaz de disponibilizar as previsões de maneira amigável aos gestores da distribuidora. A nova ferramenta se mostrou capaz de atender o objetivo proposto e passou a integrar o planejamento diário de mobilização de equipes técnicas.

Portanto, é possível dizer que a ferramenta desenvolvida neste trabalho pode auxiliar de maneira importante companhias de distribuição de energia. De forma a embasar decisões estratégicas a respeito da alocação de equipes de manutenção próximas a áreas com maior chance de ocorrência de incidentes de queda de energia, favorecendo o reestabelecimento mais rápido do abastecimento, aumentando a satisfação dos

clientes e gerando economia para a companhia ao diminuir os fatores para aplicação de multas pela agência reguladora.

Vale ressaltar que, além dos fatores históricos e climáticos utilizados neste trabalho, muitos outros aspectos de natureza imprevisível podem influenciar na ocorrência de incidentes de interrupção de energia, como acidentes automobilísticos, animais na rede, falhas em equipamentos e, até mesmo, vandalismo. Portanto, o modelo desenvolvido se apresenta como um indicativo do comportamento futuro do sistema e o erro na previsão é intrínseco ao método utilizado.

Como trabalho futuros, está prevista a integração de novas variáveis de entrada para treinamento, como a inclusão de avarias em equipamentos, necessidade de podas e idade da rede elétrica, a fim de tornar o modelo cada vez mais preciso. Também se espera utilizar a mesma técnica para previsão de outros indicadores, como número de desarmes e indicadores de qualidade DEC/FEC.

4. Referências bibliográficas

- CHICCO, D.; WARRENS, M. J.; JURMAN, G. The coefficient of determination r-squared is More informative than smape, mae, mape, mse and rmse in regression analysis evaluation. *PeerJ Computer Science*, PeerJ Inc., v. 7, p. e623, 2021.
- FRAEDRICH, K.; LARNDER, C. Scaling regimes of composite rainfall time series. *Tellus A: Dynamic Meteorology and Oceanography*, Taylor & Francis, v. 45, n. 4, p. 289–298, 1993.
- FUSHIKI, T. Estimation of prediction error by using k-fold cross-validation. *Statistics and Computing*, Springer, v. 21, n. 2, p. 137–146, 2011.
- GURURAJAPATHY, S.; MOKHLIS, H.; ILLIAS, H. A. Fault location and detection techniques in power distribution systems with distributed generation: A review. *Renewable and sustainable energy reviews*, Elsevier, v. 74, p. 949–958, 2017.
- KOTSIANTIS, S. B.; KANELLOPOULOS, D.; PINTELAS, P. E. Data preprocessing for supervised learning. *International journal of computer science*, Citeseer, v. 1, n. 2, p. 111–117, 2006.
- KRSTAJIC, D. et al. Cross-validation pitfalls when selecting and assessing regression and classification models. *Journal of cheminformatics*, BioMed Central, v. 6, n. 1, p. 1–15, 2014.
- MEI, A. van der; DOOMERNIK, J.-P. Artificial intelligence potential in power distribution system planning. *CIREN-Open Access Proceedings Journal*, IET, v. 2017, n. 1, p. 2115–2117, 2017.
- MURTAGH, F. Multilayer perceptrons for classification and regression. *Neurocomputing*, Elsevier, v. 2, n. 5-6, p. 183–197, 1991.
- RAZA, M. Q.; KHOSRAVI, A. A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 50, p. 1352–1372, 2015.
- RODRIGUEZ-GALIANO, V. et al. Machine learning predictive models for mineral prospectivity: An evaluation of neural networks, random forest, regression trees and support vector machines. *Ore Geology Reviews*, Elsevier, v. 71, p. 804–818, 2015.
- SEGAL, M. R. Machine learning benchmarks and random forest regression. 2004.
- SMOLA, A. J.; SCHÖLKOPF, B. A tutorial on support vector regression. *Statistics and computing*, Springer, v. 14, n. 3, p. 199–222, 2004.
- SOUZA, S. V. de; JUNQUEIRA, R. G. A procedure to assess linearity by ordinary least squares method. *Analytica Chimica Acta*, Elsevier, v. 552, n. 1-2, p. 25–35, 2005.

DADKHAH, M.; REZAEE, M.; CHAVOSHI, A. Short-term poweroutput forecasting of hourly operation in power plant based on climatefactors and effects of wind direction and wind speed, Energy, vol. 148,pp. 775–788, 2018