



Sistema de alerta de condições climáticas severas na distribuição de energia elétrica

Tema: Tecnologias Emergentes

Autores: Mateus Bravim da Silva

Co-Autores: -

Empresa: EDP Espírito Santo Distribuição de Energia S.A.

Resumo

A qualidade da energia elétrica está diretamente relacionada a distúrbios que podem ocorrer tanto nas instalações dos consumidores quanto no sistema das concessionárias. No Brasil, onde a maioria das linhas de distribuição é aérea, eventos climáticos, como tempestades e rajadas de vento, têm um impacto significativo e são uma das principais causas de desligamentos não programados. Essas condições adversas provocam múltiplas interrupções em várias regiões, resultando em prejuízos tanto para as concessionárias quanto para os clientes. Identificar as causas dessas falhas permite adotar uma abordagem mais eficiente, facilitando o posicionamento estratégico das equipes e, conseqüentemente, reduzindo o tempo de resposta para solucionar os problemas.

A base de dados utilizada neste estudo é composta por indicadores de qualidade de energia e dados climáticos históricos e informações sobre a infraestrutura. A pesquisa abrange uma extensa área territorial do estado do Espírito Santo, Brasil, com registros históricos de interrupções entre 2021 e 2023. O estudo foca faltas não programadas e por conta de eventos climáticos. Para a codificação e organização dos dados geográficos, foi adotada a técnica do *Geohash*, que permite uma representação mais eficiente das áreas propensas a interrupções. Essas áreas foram agrupadas em zonas de aproximadamente 4,7 km², totalizando 1222 zonas distintas.

Três índices foram desenvolvidos para avaliar a gravidade das falhas climáticas: o índice de perigo, que mede a gravidade das ocorrências com base nas condições climáticas; o índice de impacto, que considera os indicadores de qualidade de energia; e o índice de alerta, que combina os dois primeiros para uma análise mais abrangente. Os resultados demonstraram um bom desempenho do índice de perigo, com erro médio de -0,1423 e coeficiente de determinação médio de 0,6146, indicando boa aderência. Esses dados foram aplicados à rede de distribuição, permitindo a criação de um índice de alerta eficiente, capaz de oferecer suporte estratégico para a tomada de decisão e a mitigação dos impactos de eventos climáticos extremos.

1. Introdução

A disponibilidade de energia elétrica representa um avanço significativo na qualidade de vida das populações. Quando um sistema de distribuição de energia elétrica é implantado, os benefícios são imediatos, tanto em termos de maior conforto doméstico quanto em relação a melhores oportunidades de emprego

e produção (FARIAS; SELLITTO, 2011). A energia é um produto sujeito a características específicas de qualidade, que são avaliadas por parâmetros bem definidos e monitorados conforme as normas técnicas do setor elétrico. A Agência Nacional de Energia Elétrica (ANEEL) acompanha a qualidade do fornecimento de energia por meio de indicadores como o Duração Equivalente de Interrupção por Unidade Consumidora (DEC), que mede o tempo que um cliente fica sem energia, e a Frequência Equivalente de Interrupção por Unidade Consumidora (FEC), que quantifica o número de interrupções no fornecimento (Agência Nacional de Energia Elétrica, 2016).

As interrupções não programadas no fornecimento de energia podem ser causadas por uma série de fatores, incluindo falhas nos equipamentos, erros humanos, danos maliciosos e condições climáticas adversas. Esses fenômenos, que são aleatórios ou intrínsecos ao sistema elétrico, afetam a qualidade do fornecimento de energia e geram prejuízos tanto para os clientes quanto para as concessionárias (WARD, 2013). Os sistemas de previsão numérica do tempo têm se tornado mais precisos, resultando em melhorias que abrangem desde a redução de perdas econômicas até o apoio a emergências, permitindo a antecipação de eventos climáticos e a redução de riscos para vidas e propriedades (BAUER; THORPE; BRUNET, 2015). A utilização de sistemas de previsão do tempo também contribui para a otimização da gestão de recursos naturais, redução de impactos de desastres naturais e apoio a áreas como a agricultura de precisão, onde a combinação de dados climáticos e sensores locais facilita a tomada de decisões, aumentando a produtividade e evitando custos desnecessários (BENDRE; THOOL; THOOL, 2015). No estudo de Baklanov et al. (2002), a combinação de dados meteorológicos e de cobertura terrestre ajudou na previsão de poluição urbana, facilitando a adoção de medidas para melhorar a qualidade de vida nas cidades.

O *Geohash*, por sua vez, surge como uma alternativa eficiente aos sistemas de coordenadas geográficas tradicionais, como latitude e longitude, representando áreas geográficas por meio de sequências alfanuméricas facilmente processáveis em sistemas de informação geográfica (BALKI ; ŠOŠTARI ; HORVAT, 2012). Suas aplicações incluem, por exemplo, a análise de trajetórias de veículos (SOUSA; BOUKERCHE; LOUREIRO, 2020) e o manejo de grandes volumes de dados espaciais e temporais (ATTA et al., 2016).

O uso de inteligência artificial no setor elétrico tem crescido pela sua capacidade de identificar padrões e detectar falhas nas redes de distribuição e transmissão, permitindo a otimização das proteções e a melhoria da confiabilidade (KONDO, 2015). A análise de dados climáticos juntamente com informações sobre falhas de energia, vegetação e equipamentos nos Estados Unidos tem permitido a implementação de sistemas preditivos para otimizar o posicionamento de equipes em situações críticas (CERRAI et al., 2019).

Este estudo propõe o desenvolvimento de um sistema capaz de inferir o impacto de condições climáticas nos indicadores DEC e FEC, oferecendo uma ferramenta integrada a sistemas de previsão meteorológica. Essa abordagem permite, de forma antecipada, identificar as regiões mais propensas a sofrerem maiores impactos nesses indicadores. Para atingir esse objetivo, são definidos três índices principais: impacto, perigo e alerta. O índice de impacto é baseado na normalização do DEC ou FEC para cada alimentador; o índice de perigo reflete as condições climáticas em uma determinada região; e o índice de alerta combina impacto e perigo, destacando as áreas da rede elétrica mais suscetíveis a interrupções devido a condições adversas. O estudo será realizado em grande parte do estado do Espírito Santo, Brasil, excluindo a região centro-oeste, e analisará a relação entre a localização das falhas e as condições climáticas locais.

2. Desenvolvimento

O desenvolvimento do sistema proposto inicia-se com a definição e construção dos índices impacto, perigo e alerta, que formam a base para a análise do impacto climático nos indicadores DEC e FEC. A Figura

1 demonstra o cálculo do Índice de Alerta integra dados de impacto elétrico (DEC e FEC) e condições climáticas processadas por um modelo de regressão. A estrutura apresentada permite avaliar, em tempo real ou em previsões futuras, as áreas mais suscetíveis a interrupções na rede elétrica. Essa abordagem também viabiliza a utilização de ferramentas de *Business Intelligence* (BI) para a análise e monitoramento estratégico dos resultados.

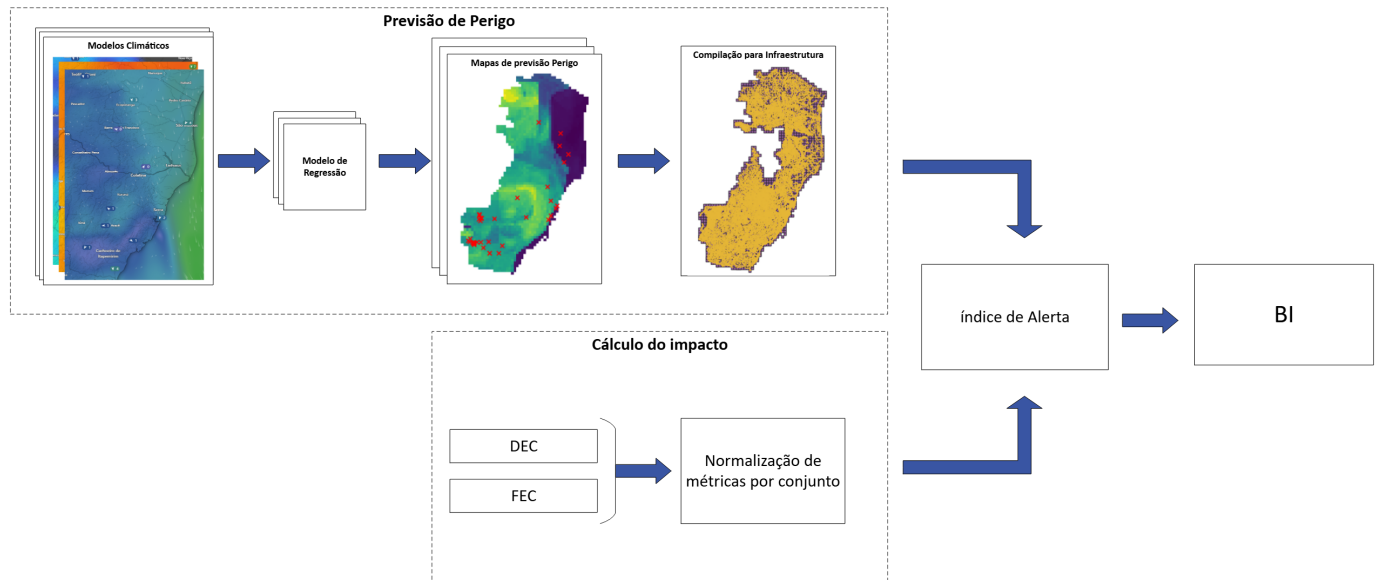


Figura 1: Fluxo de processamento para o cálculo do Índice de Alerta. O diagrama mostra a integração entre os indicadores elétricos (DEC e FEC), dados climáticos para o processamento do perigo, a combinação para a formação do índice de alerta e integração visualização de BI.

O uso de informações georreferenciadas em conjunto com o *Geohash* possibilita a organização espacial eficiente dos dados, permitindo o cruzamento de índices de risco, perigo e alerta com informações sobre equipamentos, redes elétricas, cidades e conjuntos regionais. O *Geohash* utiliza uma sequência alfanumérica hierárquica, onde cada caractere adicional aumenta a precisão geográfica ao subdividir a área representada em regiões menores. Essa estrutura hierárquica é particularmente útil para ajustar a granularidade da análise, permitindo tanto uma visão macro para identificar tendências regionais quanto uma visão detalhada para avaliar áreas específicas da rede elétrica. Com isso, é possível realizar análises otimizadas e direcionar recursos com maior eficácia, especialmente em situações de planejamento ou resposta a eventos extremos.

Na Figura 2, observa-se a aplicação do *Geohash* em dois níveis de granularidade distintos, permitindo uma visão hierárquica das áreas geográficas. Essa abordagem possibilita tanto a análise detalhada de trechos específicos da rede de distribuição elétrica quanto uma visão abrangente de regiões maiores, facilitando o planejamento e a tomada de decisões estratégicas.




Figura 2: Representação da rede de distribuição elétrica (em amarelo) sobreposta a duas grades que demonstram diferentes níveis de *Geohash*. À esquerda, uma subdivisão mais detalhada com o *Geohash* de nível 6; à direita, uma subdivisão mais ampla, indicando áreas maiores com o *Geohash* de nível 5.

O índice de impacto foi desenvolvido para avaliar o efeito relativo de cada alimentador no desempenho geral do sistema elétrico, utilizando os indicadores DEC (Duração Equivalente de Interrupção por Unidade Consumidora) e FEC (Frequência Equivalente de Interrupção por Unidade Consumidora). Esses indicadores, amplamente utilizados para medir a qualidade do fornecimento de energia, servem como base para calcular um peso normalizado, variando de 0 a 1, para cada alimentador.

O cálculo considera o maior valor de impacto entre os alimentadores em um dado período como referência. Assim, cada alimentador tem seu impacto normalizado com base nesse valor máximo, de forma que o alimentador mais crítico, que gera maior impacto no sistema, é atribuído um peso próximo a 1. Alimentadores com desempenho menos problemático têm valores progressivamente menores, tendendo a 0. Essa abordagem permite priorizar ações de manutenção e de forma estratégica, concentrando esforços nos alimentadores que mais influenciam negativamente o desempenho global.

O perigo é uma condição ou situação com potencial para causar danos ou consequências indesejadas, sendo a fonte do dano, enquanto o risco é a probabilidade de um evento adverso ocorrer. Historicamente, o conceito de perigo tem sido fundamental para a proteção contra ameaças naturais e causadas pelo homem. No setor de energia elétrica, os perigos podem ser causados por falhas em equipamentos, vandalismo e desastres naturais. Identificar esses perigos permite adotar medidas preventivas, como manutenção regular e preparação para desastres.

Neste estudo, foram utilizados dados de reanálise climática que têm como origem a combinação de observações de satélite, estações meteorológicas, boias oceânicas e outros tipos de dados com modelos numéricos de alta resolução para gerar um conjunto de dados coerentes e consistentes, recriando assim os comportamentos passados. Sendo assim, foram utilizados os dados climáticos do Centro Europeu de Previsões Meteorológicas de Médio Prazo Reanálise do clima ERA5, os quais possuem uma resolução espacial de 0,25 graus (aproximadamente 31 km) em uma frequência horária (HERSBACH et al., 2020). Devido à discrepância entre a resolução do conjunto de dados climáticos e a resolução do *Geohash* escolhido, foi essencial empregar técnicas de interpolação espacial linear (LI;HEAP, 2008). Essas técnicas foram aplicadas para ajustar os dados de acordo com cada *Geohash*, tomando como base suas coordenadas

centrais. Dessa forma, tornou-se possível obter os registros das condições climáticas históricas para cada *Geohash* específico dentro de uma região determinada.

Para avaliar a incidência de faltas, foi utilizado um modelo baseado em eventos não planejados ocorridos entre 2022 e 2023, com dados extraídos do Sistema de Gerenciamento de Interrupções (OMS). O OMS é uma fonte abrangente de informações, fornecendo detalhes sobre as causas das interrupções, os equipamentos impactados e os clientes afetados. Além disso, o sistema registra o tempo de resposta e resolução de cada falha, bem como sua localização geográfica.

De forma semelhante à abordagem adotada para análise de reanálise climática, os dados foram compilados utilizando *Geohash* em uma escala uniforme. Nesse processo, as coordenadas dos eventos foram convertidas para geocódigos, permitindo uma análise espacial consistente e estruturada.

A criação de um índice de perigo, baseado em dados climáticos, permite avaliar o impacto das condições meteorológicas adversas sobre a rede elétrica, contribuindo para aumentar a resiliência e reduzir riscos operacionais. Para alcançar esse objetivo, o método XGBoost foi escolhido devido à sua ampla utilização em problemas de aprendizado supervisionado, sua capacidade de lidar com grandes volumes de dados e a robustez em capturar relações complexas entre variáveis.

A escolha dessas variáveis teve como objetivo capturar os principais fatores que afetam a rede elétrica em condições adversas, sem adicionar complexidade desnecessária ao modelo. As variáveis selecionadas incluem rajadas de vento, precipitação e índices de instabilidade atmosférica, como o **CAPE** (*Convective Available Potential Energy*), entre outros fatores descritos na Tabela 1.

A **rajada de vento** foi incluída como uma variável de entrada devido ao fato de que ventos fortes representam um dos maiores riscos para a infraestrutura elétrica. Esses ventos podem derrubar cabos, danificar equipamentos e provocar interrupções significativas no fornecimento de energia.

A **precipitação**, por sua vez, foi escolhida por sua influência significativa na estabilidade do solo e da vegetação. Chuvas intensas podem provocar quedas de árvores, erosão e deslizamentos de terra, que, por sua vez, podem causar danos à infraestrutura elétrica. Além disso, a precipitação é frequentemente associada a tempestades que intensificam o risco de falhas na rede.

O **CAPE** foi incluído como um indicador da instabilidade atmosférica, pois reflete a quantidade de energia disponível para o desenvolvimento de tempestades severas. Níveis elevados de CAPE estão frequentemente correlacionados com condições que favorecem eventos climáticos extremos, como ventos fortes, raios e granizo.

Outras variáveis, como temperatura a 2 metros (**t2m**) e ponto de orvalho a 2 metros (**d2m**), foram incorporadas para complementar a análise das condições atmosféricas, fornecendo um panorama mais completo sobre o ambiente climático. Essas variáveis permitem identificar interações importantes, como a formação de nevoeiros ou a intensificação de tempestades.

Tabela 1: Variáveis utilizadas para compor o índice de perigo.

<i>Variável</i>	<i>Descrição</i>	<i>Unidade</i>
t2m	Temperatura a 2 metros	K
vw	Velocidade do vento	m/s
d2m	Ponto de orvalho a 2 metros	K
cape	Energia potencial convectiva disponível	J/kg
e	Evaporação	m
i10fg	Velocidade de rajada de vento a 10m	m/s
tcc	Total cobertura de nuvens	%
tp	Total de precipitação	mm/h

Todos os dados foram treinados com informações provenientes de reanálises climáticas. Para viabilizar essa abordagem, os dados foram adaptados de forma a harmonizar as variáveis disponíveis entre diferentes modelos climáticos, mesmo que esses modelos apresentem algumas variáveis distintas. Essa padronização permite integrar as informações de diferentes fontes, tornando possível prever condições futuras com base nos padrões históricos observados nas reanálises.

Além disso, o uso de múltiplos modelos climáticos fornece uma perspectiva mais abrangente e robusta das condições futuras. Essa abordagem contribui para uma compreensão mais detalhada e precisa do comportamento da rede elétrica diante de condições climáticas adversas, possibilitando identificar com maior eficácia as zonas de perigo elevado. Como resultado, operadores e planejadores podem adotar medidas preventivas e direcionar recursos de forma mais eficiente, aumentando a resiliência do sistema e reduzindo os riscos associados a eventos extremos.

As ocorrências foram agrupadas em regiões específicas e normalizadas entre 0 e 1 para definir a variável a ser prevista. Nessa abordagem, ocorrências isoladas recebem valores baixos, enquanto um grande número de eventos tende a um valor próximo de 1. Essa normalização foi realizada de forma regionalizada, preservando as características específicas de cada área. Por exemplo, regiões rurais, que geralmente apresentam um menor número de ocorrências em comparação com regiões urbanas, mantêm sua proporcionalidade, garantindo que o índice de perigo reflita as particularidades locais. Assim, obteve-se o índice de perigo que o modelo se propõe a prever.

Com a variável de saída devidamente definida, foi realizado um pré-processamento nos dados históricos para lidar com informações conflitantes na base. Durante esse processo, um algoritmo de *clustering* foi aplicado, agrupando os dados em diferentes categorias para analisar padrões específicos do índice de perigo estimado. Regiões identificadas como climaticamente tranquilas foram revisadas e, em casos onde houve um número elevado de ocorrências anômalas, essas amostras foram removidas. Esse procedimento visou reduzir a incidência de erros e inconsistências na base de dados, aprimorando a qualidade do treinamento do modelo.

Após o pré-processamento, os dados foram submetidos a uma normalização adicional e preparados para o treinamento utilizando validação cruzada do tipo k-fold. Esse método dividiu os dados em subconjuntos de treinamento e validação, permitindo uma avaliação mais robusta do modelo. Para medir o desempenho do modelo, foram empregadas as seguintes métricas de regressão:

- **Erro Quadrático Médio (MSE):** Mede a magnitude média dos erros, enfatizando maiores desvios.
-

Erro Absoluto Médio (MAE): Captura a média dos desvios absolutos entre os valores previstos e os reais.

- **Coeficiente de Determinação (R^2):** Avalia a proporção da variância explicada pelo modelo, indicando a qualidade do ajuste.

Com base nas métricas mencionadas, o modelo apresentou um desempenho consistente. O Erro Absoluto Médio (MAE) teve uma média de -0,1705, indicando que as previsões, em média, apresentaram desvios relativamente pequenos em relação aos valores reais. O Coeficiente de Determinação (R^2) obteve um valor médio de 0,6146, demonstrando que cerca de 61,46% da variância dos dados foi explicada pelo modelo, refletindo um bom ajuste. Já o Erro Quadrático Médio (MSE) foi de -0,0480, evidenciando precisão nas previsões com penalização maior para desvios mais significativos. Por fim, o Erro Absoluto Mediano (Median AE) apresentou um valor de -0,1423, reforçando a estabilidade nos desvios previstos. Esses resultados demonstram a capacidade do modelo de capturar padrões nos dados de forma eficaz e robusta.

A figura 3 ilustra a evolução espacial e temporal do índice de perigo gerado por um modelo de inteligência artificial. Os mapas apresentam previsões horárias desse índice em uma escala de 0 a 1, conforme indicado pela barra de cores ao lado de cada painel, onde valores mais altos (em vermelho) correspondem a um maior perigo e valores mais baixos (em azul) indicam menor risco. Cada painel está identificado com o horário correspondente à previsão.

Os marcadores em forma de "X" representam a localização das ocorrências registradas durante cada intervalo de tempo. Observa-se que a previsão identificou com precisão a região sul do estado como a área com maior incidência de eventos, alinhando-se com os registros reais. No entanto, às 20 horas, o sistema indicou o término do evento, enquanto as marcações demonstraram que as ocorrências continuaram a ser registradas após esse horário. Essa discrepância revela que, como os dados de entrada provêm de previsões geradas por modelos climáticos como GFS, ECMWF, GEM e ICON, eles estão sujeitos a falhas, o que pode levar a previsões incorretas. Isso reflete diretamente na saída do perigo, reforçando a importância de adotar múltiplas fontes de previsão para proporcionar uma visão mais abrangente do cenário futuro.

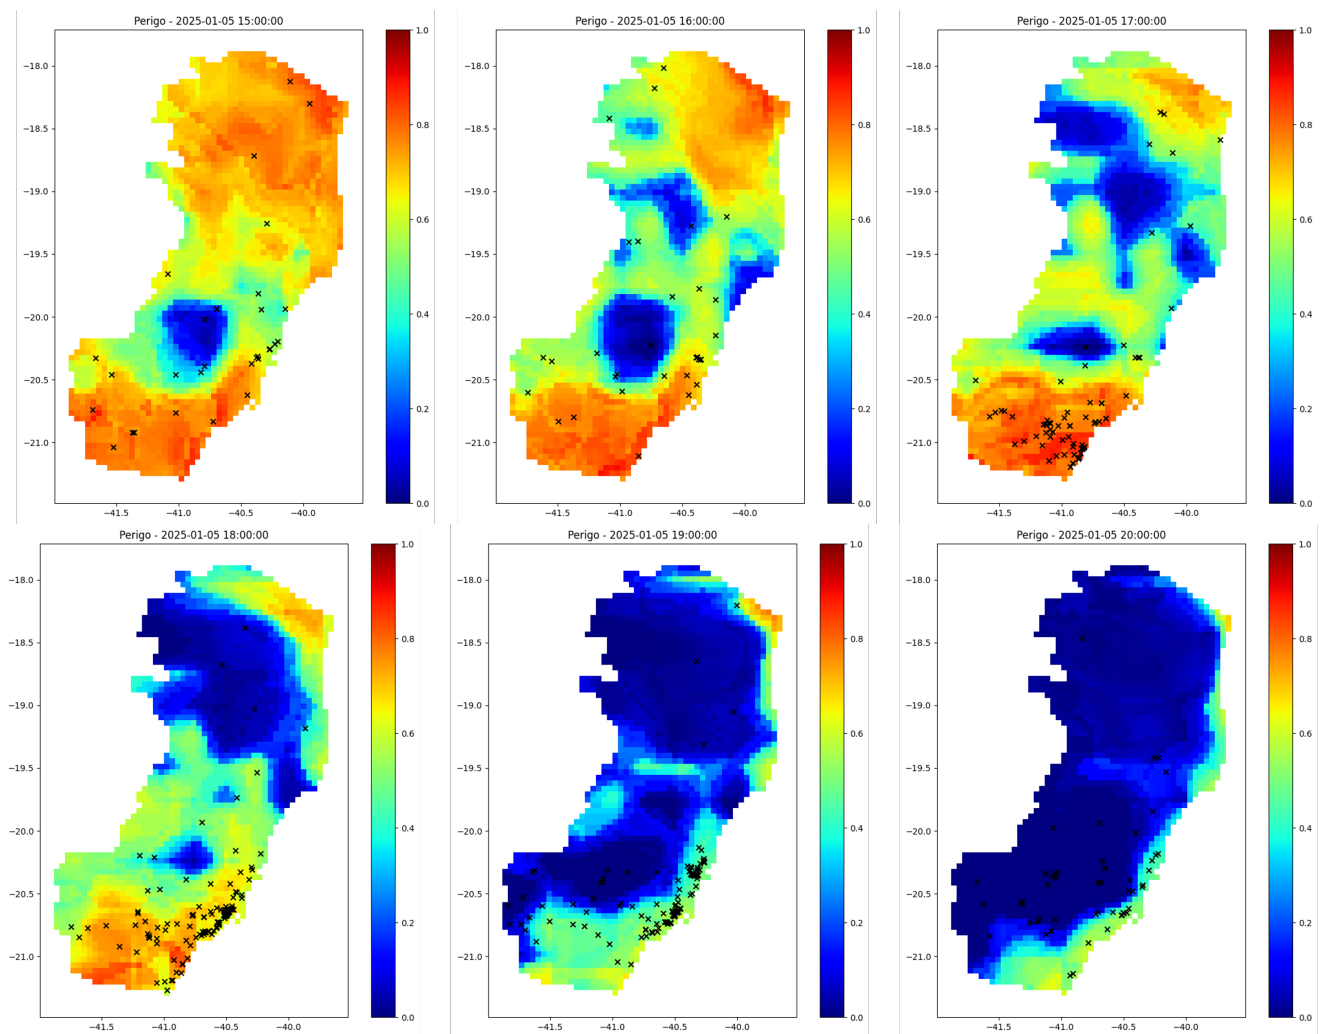


Figura 3 : Valor previsto pelo modelo para o estado nos dias no evento do dia 05/01/2024 das 15:00 as 20:00 com base no modelo de previsão GFS.

O uso do Índice de Perigo em conjunto com o *Geohash* permite a representação de informações geoespacialmente distribuídas, facilitando a análise regional. No entanto, essa abordagem não captura completamente as especificidades da rede elétrica, que é composta por diferentes elementos, como alimentadores e subestações, que frequentemente se estendem por múltiplos *Geoshashes*. Para superar essa limitação, é necessário integrar as informações geográficas com os dados estruturais da rede elétrica, realizando a avaliação no nível do alimentador. O cálculo do Índice de Perigo para cada alimentador é feito pela soma ponderada das áreas geográficas que o compõem, levando em conta o comprimento das linhas em cada *Geohash*, conforme descrito na Equação (1).

$$W_{PER}(g, t) = \sum_{g \in G_{PER}} \left(\frac{\ell(g)}{\ell_{total}} \cdot W(g, t) \right) \quad (1)$$

Onde:

- W_{PER} é o **Índice de Perigo** associado ao alimentador;
- G_{PER} é o conjunto de **Geohashes** que compõem o alimentador;
- $\ell(g)$ é o comprimento das linhas da rede presentes no **Geohash** g ;
- ℓ_{total} é o comprimento total das linhas do alimentador;
- $W(g, t)$ é o **Índice de Perigo** calculado para o **Geohash** g .

O índice de alerta foi criado com a finalidade de unir os índices de risco e de perigo relacionado à falta de energia, permitindo assim a elaboração de um mapa dinâmico ao longo do tempo que evidencie as áreas mais impactadas. Essa combinação fornece uma visão completa dos locais e períodos com maior vulnerabilidade, tornando possível a implementação de ações preventivas e corretivas mais eficazes, além de melhorar a distribuição dos recursos disponíveis.

Para realizar essa combinação, foi empregada a t-norma de Aukasiewski (tL), uma ferramenta matemática que se destaca pela sua habilidade em integrar índices de maneira coerente e lógica. Essa metodologia é aplicada para cada *Geohash* g em um determinado tempo t , resultando em um índice agregado $W(g, t)$. A definição deste índice está descrita na Equação (2), onde $R(g)$ se refere ao índice de risco vinculado a um *Geohash* específico g , enquanto $P(t, g)$ representa o índice de perigo calculado para o tempo t e a região g em questão.

Uma das principais características da t-norma de Aukasiewski é a sua capacidade de manter o valor de alerta em zero nos casos em que não há risco. Em regiões onde o risco é ausente ($R(g) = 0$), o indicador de alerta permanece nulo ($W(g, t) = 0$), mesmo se o índice de perigo atingir seus níveis máximos. Além disso, em locais com risco considerado baixo, a influência do perigo sobre o índice $W(g, t)$ é contida, nunca ultrapassando o valor do risco $R(g)$ mesmo quando $P(t, g)$ atinge seu pico. Essa particularidade torna o índice $W(g, t)$ especialmente valioso para identificar áreas com maior propensão a falhas elétricas, fornecendo uma reflexão precisa sobre a criticidade de cada local. Dessa forma, essa abordagem facilita a detecção e realce de áreas com maior vulnerabilidade, o que é crucial para implementar ações eficazes na mitigação de situações adversas.

$$W_{ALERT}(g, t) = \max\{0, R(g) - [P(t, g) + I(t, g)]\} \quad (2)$$

Onde:

- $W_{ALERT}(g, t)$: é o **Índice de Alerta** calculado para o **Geohash** g no instante t ;
- $R(g)$: é o valor de **Risco base** associado ao **Geohash** g ;
- $P(t, g)$: é o valor do **Índice de Perigo** no tempo t e no **Geohash** g ;
- $I(t, g)$: é o valor do **Índice de Impacto** associado ao **Geohash** g no tempo t ;
- O operador $\max\{0, \cdot\}$ assegura que o índice de alerta seja limitado a valores não negativos.

A integração do mapa de alertas com plataformas de BI e o uso de *Geohashes* tornam a solução ainda mais robusta e eficiente. Essa abordagem aprimora o monitoramento e a gestão da rede elétrica, fortalecendo sua resiliência frente a condições adversas e minimizando os impactos de interrupções no fornecimento de energia. A figura 4 retrata a aplicação da solução em um sistema de BI, onde é possível observar a condição atual da rede.

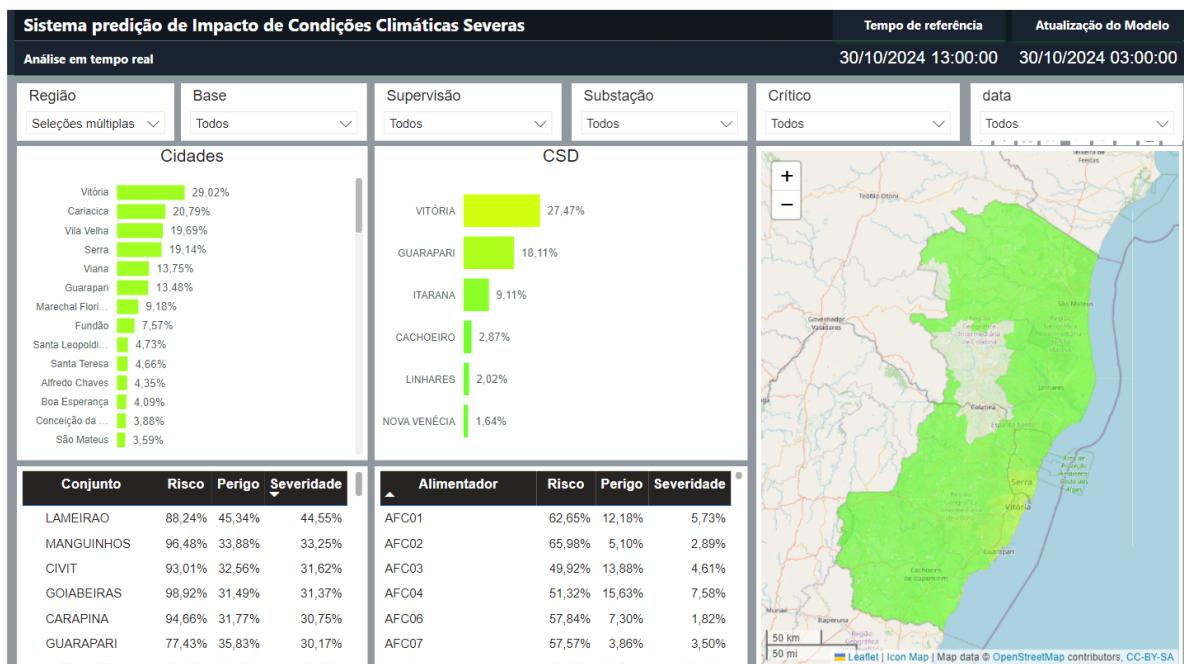


Figura 4 : Sistema de BI para monitoramento de condições climáticas extremas

Uma das principais vantagens desse sistema é a capacidade de integrar dados de previsões meteorológicas para calcular índices de perigo em momentos futuros. Isso viabiliza a geração de alertas antecipados sobre as condições da rede elétrica, facilitando o planejamento de ações preventivas, como a mobilização de equipes para áreas vulneráveis e a alocação estratégica de recursos em regiões de maior risco devido a condições climáticas severas.

Com informações de modelos de previsão, é possível determinar as condições futuras de cada elemento da rede de distribuição e obter uma visão antecipada do impacto de eventos climáticos. Essa integração

permite observar, de forma simplificada, os impactos projetados, além de identificar as estruturas mais suscetíveis a esses eventos para cada modelo.

A abordagem integrada dos modelos oferece uma avaliação mais precisa dos impactos, considerando diferentes resoluções temporais, como previsões horárias ou a cada 3 horas, o que assegura maior flexibilidade e detalhamento na análise dos efeitos sobre a rede de distribuição.

A Figura 5 apresenta a tabela utilizada na aplicação de BI para monitorar essas informações. As colunas exibem o período estimado e os modelos de previsão, enquanto as linhas representam os conjuntos críticos, detalhados até o nível de subestações e alimentadores. Os valores na tabela refletem as projeções de perigo, oferecendo uma visão clara e estruturada dos possíveis efeitos climáticos, facilitando o planejamento e a tomada de decisão.

Hora_UTC-3	18/01	18/01 07:00		18/01 08:00		18/01 09:00		18/01 10:00		18/01 11:00		18/01 12:00		18/01 13:00		18/01 14:00	
Conjunto	ICON	GFS	ICON	GFS	ICON	GFS	ICON	GFS	ICON	GFS	ICON	GFS	ICON	GFS	ICON	GFS	ICON
GUARAPARI	0.00%	0.00%	0.00%	0.05%	0.02%	0.11%	5.51%	0.41%	13.96%	11.49%	25.11%	31.47%	29.81%	33.22%	31.00%	33.98%	33.1%
IBES	0.00%	0.00%	0.00%	0.00%	0.00%	0.01%	0.19%	0.00%	1.32%	1.54%	1.60%	0.50%	3.53%	1.68%	6.41%	1.67%	8.2%
ITAPEMIRIM	0.26%	0.22%	0.57%	0.93%	4.68%	2.40%	17.26%	11.63%	33.34%	37.38%	49.36%	57.93%	53.13%	62.74%	47.52%	63.26%	40.7%
ITAPOÁ	0.00%	0.00%	0.00%	0.00%	0.05%	0.01%	0.07%	0.00%	0.51%	2.06%	0.88%	1.73%	1.33%	4.33%	5.35%	3.83%	8.5%
ITARANA	0.00%	0.15%	0.00%	0.65%	0.00%	1.19%	0.00%	1.40%	0.00%	3.04%	0.04%	4.30%	0.79%	9.55%	1.04%	18.48%	2.1%
IÚNA	0.00%	0.00%	0.00%	0.00%	0.04%	0.03%	0.35%	0.04%	1.04%	0.63%	2.13%	43.77%	3.96%	56.25%	6.20%	63.48%	7.5%
JAGUARE	0.15%	1.17%	0.39%	2.33%	0.32%	0.24%	0.35%	0.16%	0.07%	0.00%	0.06%	0.01%	0.00%	0.00%	0.04%	0.00%	0.4%
JOAO NEIVA	0.01%	2.80%	0.06%	3.04%	0.18%	2.66%	0.63%	0.67%	2.34%	0.13%	0.72%	0.08%	0.00%	0.00%	0.04%	0.00%	0.6%
LAMEIRAO	0.09%	0.00%	0.06%	0.00%	0.01%	0.00%	0.40%	0.01%	2.59%	2.55%	4.61%	10.73%	4.96%	6.69%	8.20%	6.69%	7.7%
LINHARES	0.52%	2.86%	0.56%	3.14%	0.27%	2.04%	1.02%	0.91%	0.51%	0.26%	0.02%	0.20%	0.04%	0.22%	0.13%	0.10%	0.5%
MANGUINHOS	0.02%	1.46%	0.03%	0.57%	0.07%	1.81%	0.08%	0.60%	0.08%	0.08%	0.04%	0.99%	1.53%	1.93%	1.37%	2.83%	4.7%
MARECHAL FLORIANO	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	1.81%	0.01%	3.78%	1.63%	4.08%	16.34%	8.28%	46.99%	12.69%	61.94%	14.5%
MARMORE	0.01%	0.06%	0.06%	0.76%	2.09%	7.06%	30.95%	16.88%	17.41%	55.11%	30.01%	65.97%	47.38%	70.29%	47.11%	73.90%	56.0%
MIMOSO DO SUL	0.12%	0.07%	0.44%	0.93%	5.47%	8.79%	28.09%	16.71%	36.16%	38.67%	48.88%	62.58%	56.39%	67.89%	69.53%	71.10%	65.5%
NOVA VENEZIA	0.03%	0.95%	0.03%	0.92%	0.02%	1.03%	0.05%	0.10%	0.01%	0.01%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.0%
PARATI	0.07%	0.00%	0.05%	0.00%	0.04%	0.27%	1.46%	0.03%	5.99%	5.10%	16.58%	27.48%	23.80%	36.30%	18.29%	41.00%	10.5%
PEDRO CANARIO	0.08%	2.14%	0.22%	1.08%	0.20%	0.73%	0.04%	0.07%	0.03%	0.00%	0.03%	0.00%	0.03%	0.07%	0.05%	0.86%	0.0%
PINHEIROS	0.00%	0.01%	0.00%	0.01%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.00%	0.0%
PIUMA	0.00%	0.00%	0.00%	0.63%	0.14%	1.05%	19.29%	2.40%	35.45%	41.77%	71.02%	67.87%	74.72%	75.83%	45.61%	74.26%	54.3%
PRAIA	0.00%	0.00%	0.00%	0.00%	0.04%	0.01%	0.14%	0.00%	0.56%	1.23%	1.26%	1.19%	1.43%	0.98%	2.63%	1.35%	4.8%
SANTA MARIA DE JETIBA	0.00%	0.09%	0.00%	0.35%	0.00%	0.13%	0.35%	0.02%	0.65%	1.38%	1.45%	5.01%	2.76%	14.44%	1.81%	26.29%	2.7%
SAO MATEUS	0.14%	1.93%	0.29%	1.33%	0.29%	0.85%	0.20%	0.81%	0.04%	0.00%	0.03%	0.14%	0.12%	0.20%	0.16%	0.73%	0.0%
SERRA SEDE	0.00%	0.49%	0.00%	0.56%	0.06%	1.50%	0.85%	0.04%	0.42%	0.73%	0.70%	0.40%	1.40%	0.15%	1.49%	0.28%	8.5%
VENDA NOVA	0.00%	0.00%	0.00%	0.00%	0.00%	0.07%	0.06%	0.54%	2.69%	1.48%	29.97%	2.91%	55.29%	4.12%	63.25%	7.4%	
VILA RICA	0.12%	0.03%	0.27%	0.96%	3.67%	9.98%	32.10%	27.05%	19.53%	59.95%	40.39%	66.49%	53.08%	69.27%	47.53%	73.52%	57.5%

Figura 5 : Sistema de BI para monitoramento de condições climáticas extremas

3. Conclusão

Este estudo investiga a utilização de diversas fontes de dados para antecipar falhas no fornecimento de energia elétrica, com o objetivo de prever padrões de interrupção com base no histórico de incidentes passados. Ao integrar informações de modelos de previsão numérica, é possível obter uma visão sobre a condição da rede em momentos futuros.

Essa abordagem é crucial para aprimorar a gestão e a resiliência do sistema elétrico, pois antecipar e entender possíveis cenários de falha é fundamental para a implementação de medidas proativas. A análise do histórico de falhas, juntamente com o uso de modelos de previsão numérica, oferece uma oportunidade valiosa para prever interrupções.

Assim, este trabalho representa um avanço na busca por estratégias mais eficazes no setor elétrico, com o potencial de reduzir os impactos das falhas de energia e garantir uma operação mais segura e eficiente.

Para o desenvolvimento deste projeto, foram definidos e analisados três índices relacionados à ocorrência de falhas na rede elétrica, visando avaliar o impacto de condições climáticas extremas.

A aplicação do índice de impacto possibilitou para avaliar o efeito relativo de cada alimentador no desempenho geral do sistema elétrico proporciona uma ferramenta eficaz para a priorização de ações de manutenção. Ao utilizar os indicadores DEC e FEC como base para calcular um peso normalizado para cada alimentador, o modelo permite identificar e concentrar esforços nos alimentadores com maior impacto no sistema. A abordagem, que considera o valor máximo de impacto como referência para a normalização, facilita a alocação estratégica de recursos, garantindo que as intervenções sejam direcionadas de forma eficiente para os pontos críticos da rede elétrica.

O Índice de Perigo foi desenvolvido utilizando informações climáticas, com base em dados como precipitação e rajadas de vento e índices de instabilidade. Essas variáveis foram integradas por meio de um modelo de regressão que resulta em um indicador capaz de refletir as condições de maior vulnerabilidade da rede elétrica a eventos climáticos adversos.

Os resultados obtidos indicaram que o Índice de Perigo apresentou um desempenho satisfatório, com as métricas avaliadas revelando um R^2 médio de 0,614. No entanto, observou-se que, em algumas situações, os dados utilizados para o treinamento não refletiram integralmente as condições esperadas na saída do modelo, o que dificultou tanto o processo de treinamento quanto a análise dos resultados.

Embora a adoção do modelo de perigo tenha evidenciado erros de previsão em certos momentos, esses erros são compreensíveis, considerando que as informações utilizadas são baseadas em dados de previsão do tempo, os quais, apesar de terem se tornado mais precisos com o tempo, ainda estão sujeitos a limitações e falhas. A integração de múltiplos modelos contribui parcialmente para mitigar esse problema, pois oferece diferentes perspectivas e amplia as possibilidades de análise, facilitando uma avaliação mais abrangente e robusta dos eventos climáticos futuros.

O desenvolvimento do índice de alerta integrado aos mapas dinâmicos no tempo representa um avanço significativo na gestão das redes elétricas. Esta abordagem permite identificar as regiões e períodos mais vulneráveis a falhas, otimizando a alocação de recursos e a implementação de medidas preventivas e corretivas. Com base na t-norma de Aukasiewski, o índice combina de forma lógica e consistente os índices de risco e perigo, preservando a integridade das informações e priorizando as áreas de maior criticidade. A utilização do *Geohash* como estrutura de base foi essencial para garantir a integração espacial dos índices de risco e perigo. Sua flexibilidade em representar diferentes níveis de granularidade facilita a adaptação a distintos requisitos operacionais e computacionais. Essa hierarquia espacial possibilitou a preservação de detalhes regionais críticos no índice de risco, ao mesmo tempo em que reduziu a carga computacional ao agregar informações climáticas no índice de perigo, garantindo análises precisas e escaláveis.

A aplicação do índice de alerta na rede elétrica revelou a necessidade de associar as informações geográficas aos elementos estruturais da rede, como alimentadores e subestações. O cálculo ponderado do índice, levando em consideração o comprimento das linhas da rede, mostrou-se mais eficiente e representativo do que médias simples, evitando superestimações ou subestimações do risco. Dessa forma, a abordagem permite uma avaliação mais detalhada e confiável das condições reais da rede elétrica.

Por fim, a integração do índice de alerta em uma plataforma de BI consolidou sua aplicabilidade prática. A combinação de dados em tempo real, previsões climáticas e informações históricas resultou em um sistema robusto para o monitoramento e gestão da rede elétrica. Esse sistema não apenas aprimora a resiliência frente a condições adversas, mas também minimiza os impactos das interrupções, contribuindo para um fornecimento de energia mais seguro e eficiente.

A solução implementada apresenta uma abordagem robusta para auxiliar a operação durante eventos climáticos, permitindo o monitoramento contínuo e a antecipação na mobilização de equipes para áreas

mais propensas a eventos extremos. Essa estratégia contribui para a redução dos impactos nos indicadores de energia por meio do índice de impacto, aprimorando o atendimento em momentos críticos.

4. Referências bibliográficas

- ANEEL. Elétrica no sistema elétrico nacional, "módulo 8-qualidade de energia elétrica. Agência Nacional de Energia Elétrica (ANEEL), 2016.
- ATTA, Shahbaz et al. Spatial-crowd: A big data framework for efficient data visualization. In: IEEE. 2016 IEEE International Conference on Big Data (Big Data). [S.I.], 2016. p. 2130–2138
- BALKI , Zoran; ŠOŠTARI , Damir; HORVAT, Goran. Geohash and uuid identifier for multi-agent systems. In: SPRINGER. Agent and Multi-Agent Systems. Technologies and Applications: 6th KES International Conference, KES-AMSTA 2012, Dubrovnik, Croatia, June 25-27, 2012. Proceedings 6. [S.I.], 2012. p. 290–298.
- BAUER, Peter; THORPE, Alan; BRUNET, Gilbert. The quiet revolution of numerical weather prediction. Nature, Nature Publishing Group UK London, v. 525, n. 7567, p. 47–55, 2015.
- BENDRE, MR; THOOL, RC; THOOL, VR. Big data in precision agriculture: Weather forecasting for future farming. In: IEEE. 2015 1st international conference on next generation computing technologies (NGCT). [S.I.], 2015. p. 744–750.
- CERRAI, Diego et al. Predicting storm outages through new representations of weather and vegetation. IEEE Access, IEEE, v. 7, p. 29639–29654, 2019.
- FARIAS, Leonel Marques; SELLITTO, Miguel Afonso. Uso da energia ao longo da história: evolução e perspectivas futuras. Revista Liberato, v. 12, n. 17, p. 07–16, 2011.
- HERSBACH, Hans et al. The era5 global reanalysis. Quarterly Journal of the Royal Meteorological Society, Wiley Online Library, v. 146, n. 730, p. 1999–2049, 2020.
- IEMA, Instituto Estadual de Meio Ambiente e Recursos Hídricos do Estado do Espírito Santo. Mapeamento ES 2012-2015. 2015. .
- KONDO, Daniela Vinci. Alocação de religadores automatizados em sistemas de distribuição. Tese (Doutorado) — Universidade de São Paulo, 2015.
- LI, Jin; HEAP, Andrew D. A review of spatial interpolation methods for environmental scientists. Geoscience Australia Canberra, 2008.
- SOUSA, Roniel S De; BOUKERCHE, Azzedine; LOUREIRO, Antonio AF. Vehicle trajectory similarity: models, methods, and applications. ACM Computing Surveys (CSUR), ACM New York, NY, USA, v. 53, n. 5, p. 1–32, 2020.
- WARD, David M. The effect of weather on grid systems and the reliability of electricity supply. Climatic Change, Springer, v. 121, n. 1, p. 103–113, 2013.