

# Correlação entre ENSO e DEC

**Tema:** Gestão Ativos e Manutenção

**Autores:** ALAN MARQUES DA CUNHA

**Co-Autores:** -

**Empresa:** Copel Distribuição S.A.

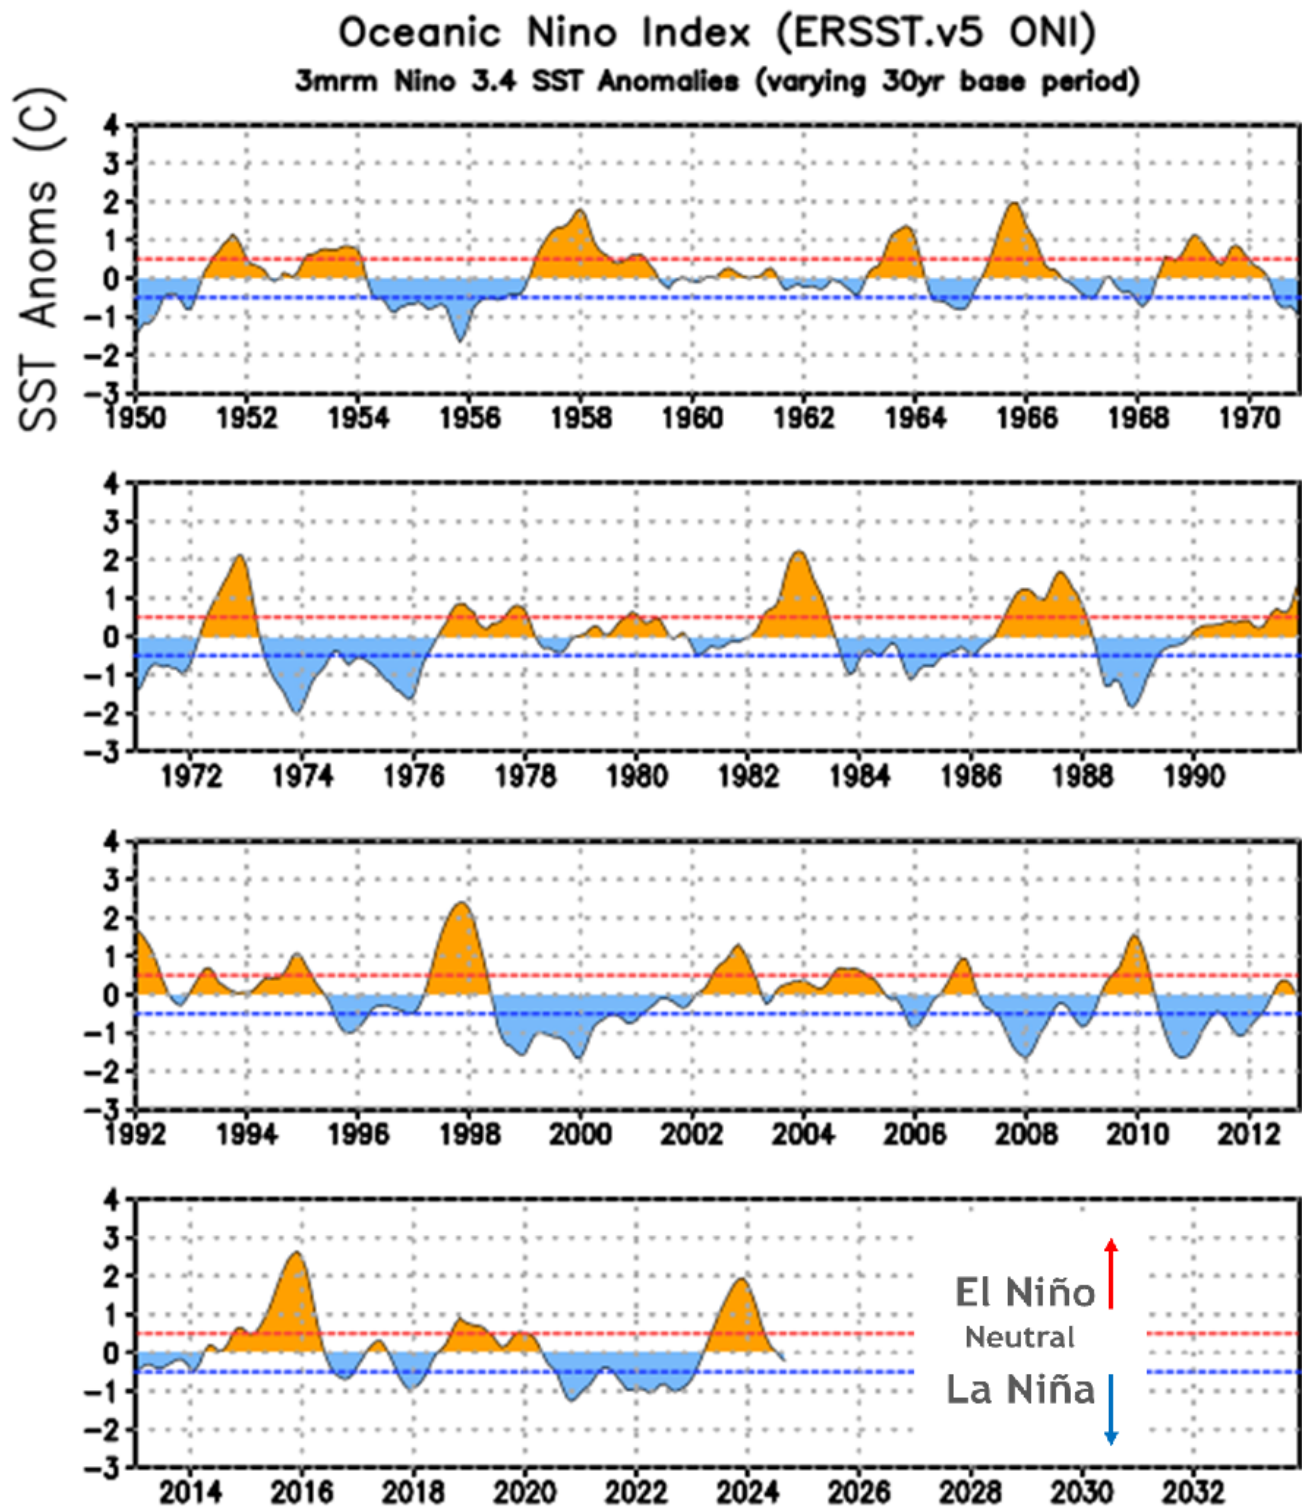
---

## Resumo

O El Niño-Oscilação Sul (ENSO) é um fenômeno climático que provoca variações significativas nos padrões de precipitação e temperatura, afetando diretamente a infraestrutura elétrica. Este artigo examina a correlação entre o ENSO e a Duração Equivalente de Interrupção por Unidade Consumidora (DEC) no Brasil, utilizando dados do Climate Prediction Center (CPC) da NOAA. São discutidos modelos preditivos e estratégias de mitigação, concluindo que a integração de previsões climáticas na gestão da rede elétrica é essencial para reduzir interrupções e aumentar a resiliência operacional.

## 1. Introdução

A continuidade do fornecimento de energia elétrica é fundamental para distribuidoras, sendo o DEC uma métrica chave. O ENSO, caracterizado por anomalias de temperatura no Oceano Pacífico, apresenta duas fases principais: El Niño e La Niña. Essas fases alteram os padrões climáticos globais, incluindo o Brasil, onde podem causar secas ou chuvas intensas, impactando a rede elétrica. Compreender e antecipar os efeitos do ENSO é crucial para garantir a eficiência e qualidade do serviço.



## 2. Desenvolvimento

### Desenvolvimento

#### 1. ENSO e o Índice Oceânico de El Niño (ONI)

O ENSO é monitorado pelo ONI, que avalia as anomalias de temperatura da superfície do mar na região Niño-3.4 (5°N-5°S, 120°W-170°W). Valores do ONI acima de +0,5°C indicam El Niño, enquanto valores abaixo de -0,5°C indicam La Niña. No Brasil, o El Niño tende a causar chuvas intensas no Sul e Sudeste e secas no Norte e Nordeste, enquanto a La Niña apresenta efeitos opostos. Essas variações afetam a rede elétrica, exigindo estratégias adaptativas.

Os dados do ONI são disponibilizados pelo CPC em médias móveis de três meses; por exemplo, o índice de novembro corresponde à média de setembro, outubro e novembro (SON). Para manter a consistência, adotou-se a média de três períodos para os demais índices utilizados como entradas nos modelos preditivos. Essa abordagem permitiu identificar uma correlação significativa entre as variações do ONI e o DEC Bruto (DEC\_B), que representa o DEC sem expurgos.

Observou-se que a variação absoluta do ONI, calculada como a diferença entre o valor do índice no período M e o valor de sete períodos anteriores, quando superior a 0,5, frequentemente coincide com picos no DEC\_B. Essa relação é ilustrada na figura, onde "delta\_índice" representa a variação absoluta de sete períodos do índice, e "flag" indica quando delta\_índice excede 0,5. O gráfico demonstra que o DEC\_B está mais relacionado à variação do índice do que à fase específica do ENSO (El Niño ou La Niña). Isso sugere que não é possível afirmar categoricamente que períodos de El Niño, caracterizados por temperaturas mais altas e maior precipitação, resultam em aumento do DEC\_B, ou que períodos de La Niña, com condições mais secas, levam a uma redução nas interrupções. O fator determinante parece ser a magnitude da variação do ONI, com mudanças significativas associadas a um maior número de desligamentos. Uma possível explicação é que tempestades mais severas ocorrem quando a variação do ONI (delta\_índice) supera 0,5.

## 2. Impactos do ENSO no DEC

Eventos climáticos extremos associados ao ENSO podem aumentar o DEC de maneira significativa. Por exemplo, durante o El Niño de 2015-2016, tempestades severas no Sul do Brasil resultaram em danos significativos à infraestrutura elétrica, elevando os índices de interrupção. Estudos também evidenciam correlações diretas entre os valores do ONI e picos de DEC em várias regiões do Brasil, especialmente nas áreas onde a infraestrutura é mais vulnerável a variações climáticas intensas.

## 3. Modelagem Preditiva do DEC

Modelos de séries temporais foram fundamentais para analisar e prever o comportamento do DEC diante de variações climáticas associadas ao ENSO:

- **Prophet:** Um modelo eficaz para capturar tendências e sazonalidades anuais e mensais.
- **SARIMAX:** Capaz de incluir variáveis exógenas, como o ONI, para criar previsões mais robustas.
- **LSTM:** Ideal para modelar padrões não lineares e complexos que envolvem múltiplas variáveis.

Com base nos dados históricos de DEC\_B da concessionária desde 2014 e informações do ONI, desenvolveu-se um modelo preditivo para o DEC\_B. Posteriormente, os valores previstos de DEC\_B foram utilizados como variáveis exógenas para obter um modelo de previsão do DEC líquido (com expurgos). Uma análise de backtest validou os resultados, demonstrando coerência e confiabilidade.

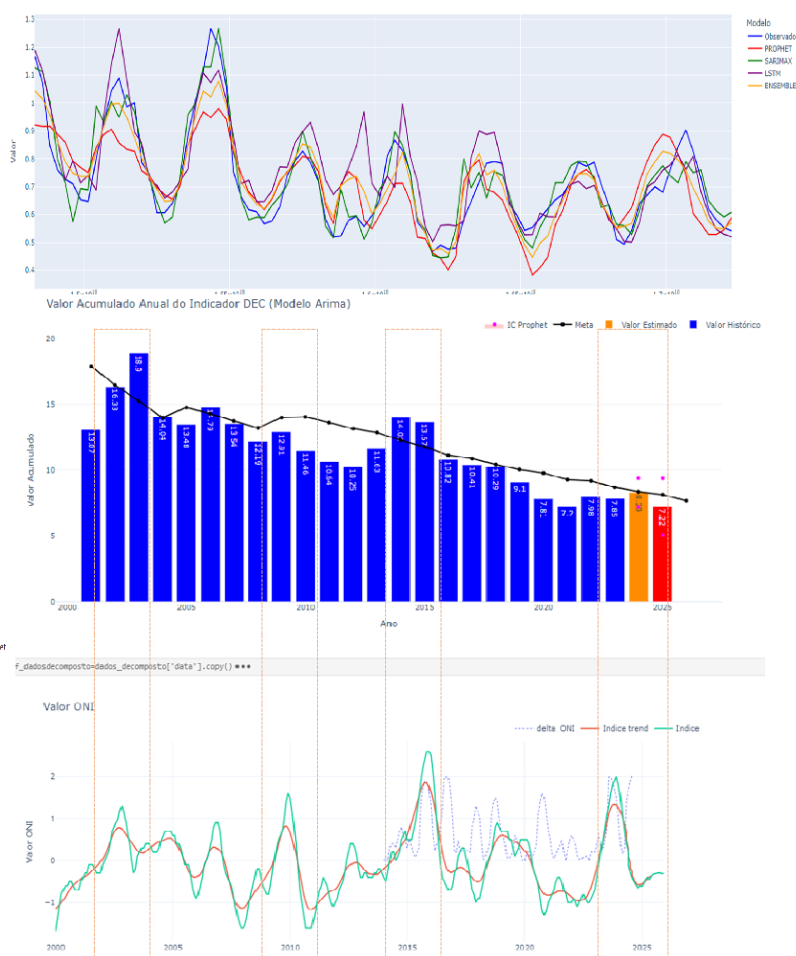
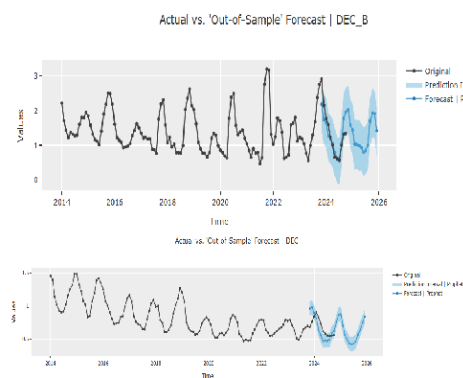
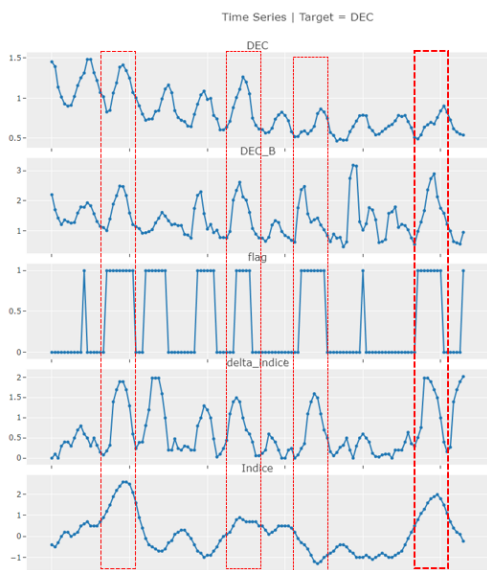
A média de três períodos do indicador DEC foi convertida para valores mensais, acumulados anualmente para estimar o DEC do ano corrente e dos anos subsequentes. Os intervalos de confiança do modelo Prophet foram incorporados como uma "banda" de incerteza, oferecendo maior segurança nas estimativas. O modelo foi considerado promissor, servindo como suporte para o planejamento de ações de manutenção e investimento.

## 4. Implicações para a Gestão da Rede Elétrica

A modelagem preditiva trouxe insights significativos para a gestão da rede elétrica:

- **Estratégias de Manutenção:** A previsão de eventos climáticos adversos permitiu planejar ações preventivas, como poda de árvores e manutenção em áreas de maior risco.
- **Investimentos em Infraestrutura:** Regiões mais impactadas por eventos climáticos extremos podem ter sua infraestrutura reforçada, reduzindo os impactos no DEC.
- **Gestão de Recursos:** Com os modelos preditivos, é possível alocar recursos de forma mais eficiente e desenvolver estratégias mais eficazes para mitigar os riscos climáticos.

Além disso, o modelo permitiu medir a eficácia das ações da distribuidora. Por exemplo, se o DEC observado foi menor do que o estimado pelo modelo, isso pode indicar uma gestão eficiente. Por outro lado, valores maiores que o previsto podem sinalizar insuficiência nas ações implementadas, como manutenção ou investimentos.



## Modelos Preditivos Utilizados na Análise do DEC

A análise e previsão de séries temporais, como o DEC (Duração Equivalente de Interrupção por Unidade Consumidora), requerem a aplicação de modelos preditivos que sejam capazes de lidar com padrões sazonais, variáveis exógenas e tendências complexas. Na presente análise, foram utilizados três principais modelos preditivos: **Prophet**, **SARIMAX** e **LSTM**. Cada modelo possui características distintas que permitem a construção de previsões robustas e adaptadas às necessidades da distribuidora.

### 1. Prophet

Desenvolvido pelo Facebook, o Prophet é um modelo de séries temporais que se destaca pela sua simplicidade de uso e capacidade de lidar com sazonalidades e tendências de longo prazo. Ele foi projetado para ser intuitivo, permitindo que usuários sem conhecimento aprofundado de estatística ou machine learning possam aplicá-lo de forma eficaz.

#### **Características principais:**

- **Sazonalidade ajustável:** Possui componentes específicos para capturar sazonalidades anuais, mensais e semanais.
- **Tendências não lineares:** Permite modelar tendências de crescimento ou declínio que mudam ao longo do tempo.
- **Manejo de feriados e eventos especiais:** Integra automaticamente efeitos de datas específicas, como eventos climáticos extremos ou feriados, que podem impactar o DEC.

#### **Aplicação no DEC:**

Na análise do DEC, o Prophet foi utilizado para modelar a série histórica considerando variáveis climáticas, como o Índice Oceânico de El Niño (ONI). O modelo foi capaz de identificar picos sazonais relacionados a eventos extremos e fornecer previsões ajustadas para os próximos 18 meses. A simplicidade de ajuste do Prophet foi uma vantagem significativa para incorporar rapidamente novas variáveis exógenas.

#### **Limitações:**

Embora eficaz para tendências e sazonalidades simples, o Prophet pode apresentar limitações em situações com alta complexidade não linear, como interações entre múltiplas variáveis exógenas.

### **2. SARIMAX (Seasonal AutoRegressive Integrated Moving Average with eXogenous variables)**

O SARIMAX é uma extensão dos modelos ARIMA tradicionais, permitindo a inclusão de variáveis exógenas e a modelagem de sazonalidade. Ele é amplamente utilizado em previsão de séries temporais devido à sua capacidade de capturar relações dinâmicas entre a variável-alvo e fatores externos.

#### **Características principais:**

- **Integração de variáveis exógenas:** Permite incluir fatores como ONI, precipitação e temperatura, que impactam diretamente o DEC.
- **Sazonalidade explícita:** Captura padrões sazonais repetitivos, como aumento no DEC em períodos de chuvas intensas.
- **Resíduos estacionários:** Reduz tendências e sazonalidades para focar em padrões residuais.

#### **Aplicação no DEC:**

O SARIMAX foi utilizado para incorporar diretamente as variações do ONI como variável exógena, permitindo prever o DEC bruto e líquido. Esse modelo foi particularmente útil para identificar a correlação entre mudanças abruptas no ONI (delta\_índice) e picos no DEC bruto. Além disso, o SARIMAX demonstrou robustez na previsão de curto prazo, sendo utilizado para planejar ações imediatas de manutenção e investimento.

#### **Limitações:**

O SARIMAX requer um processo rigoroso de validação para assegurar a estacionaridade dos dados e pode ser sensível a parâmetros mal ajustados, como ordens do modelo (p, d, q).

### **3. LSTM (Long Short-Term Memory)**

As redes neurais recorrentes do tipo LSTM são projetadas para lidar com padrões não lineares e dependências de longo prazo em séries temporais. Diferentemente dos modelos estatísticos, o LSTM utiliza aprendizado profundo para extrair características ocultas e padrões complexos dos dados.

#### **Características principais:**

- **Memória de longo prazo:** Retém informações ao longo de vários passos de tempo, permitindo identificar padrões duradouros.
- **Flexibilidade não linear:** Modela interações complexas entre variáveis, como ONI, DEC bruto e condições climáticas.
- **Automatização:** Não exige pré-processamento extensivo, pois o modelo aprende as características diretamente dos dados.

### Aplicação no DEC:

O LSTM foi empregado para prever tanto o DEC bruto quanto o DEC líquido, capturando padrões complexos de interação entre variáveis exógenas e a série temporal histórica. O modelo se mostrou eficaz para prever desvios extremos, como aqueles associados a mudanças abruptas no ONI, proporcionando maior precisão na identificação de eventos críticos.

### Limitações:

O treinamento do LSTM exige maior volume de dados e tempo computacional em comparação com modelos como Prophet e SARIMAX. Além disso, há maior dificuldade em interpretar os resultados devido à sua natureza de "caixa preta".

### Comparação dos Modelos

Modelo	Sazonalidade	Complexidade	Não Linear	Integração de Variáveis Exógenas	Interpretação
Prophet	Alta	Baixa	Média	Alta	SARIMAX
SARIMAX	Alta	Média	Alta	Média	LSTM
LSTM	Média	Alta	Alta	Baixa	

Os três modelos desempenharam papéis complementares na previsão do DEC, permitindo uma abordagem híbrida que combina simplicidade, robustez e capacidade de capturar padrões complexos. O uso do Prophet e SARIMAX facilitou a análise sazonal e de curto prazo, enquanto o LSTM forneceu insights adicionais sobre padrões não lineares e eventos extremos. A integração desses modelos, aliada a dados históricos de ONI e DEC, resultou em previsões mais confiáveis, essenciais para o planejamento estratégico das distribuidoras.

### Utilidade dos Modelos Preditivos para a Gestão da Distribuidora

Os modelos preditivos desenvolvidos na análise do DEC (Duração Equivalente de Interrupção por Unidade Consumidora) oferecem benefícios estratégicos e operacionais significativos para a gestão de uma distribuidora de energia elétrica. Ao integrar dados climáticos (como o Índice Oceânico de El Niño - ONI), dados históricos do DEC e modelos de séries temporais como Prophet, SARIMAX e LSTM, as distribuidoras podem transformar dados complexos em insights acionáveis, permitindo uma gestão mais eficiente e proativa.

#### 1. Planejamento Operacional

Os modelos preditivos fornecem estimativas confiáveis do DEC para períodos futuros, ajudando a distribuidora a antecipar períodos críticos e planejar ações preventivas. Por exemplo:

- **Manutenção preventiva e preditiva:** As previsões de DEC permitem identificar períodos de maior risco de interrupções, priorizando manutenções em áreas críticas e intensificando o controle de vegetação.
- **Gestão de recursos:** Com base nos picos previstos de DEC, a distribuidora pode alocar equipes, equipamentos e materiais de forma mais eficiente, otimizando custos operacionais.

#### 2. Apoio ao Investimento em Infraestrutura

Os modelos também permitem identificar regiões vulneráveis a eventos climáticos extremos e prever o impacto desses eventos no DEC, facilitando decisões de investimento em infraestrutura:

- **Automação de chaves:** As previsões ajudam a priorizar investimentos em sistemas de automação em áreas com maior incidência de interrupções, reduzindo o tempo médio de recuperação.
-

**Fortalecimento da rede:** Baseando-se nos resultados do modelo, a distribuidora pode reforçar a infraestrutura em áreas mais suscetíveis a variações climáticas, aumentando a resiliência da rede elétrica.

### 3. Monitoramento da Eficiência das Ações

Os modelos preditivos podem servir como referência para avaliar a eficiência das ações implementadas pela distribuidora. Por exemplo:

- **Comparação com previsões:** Se o DEC real observado é inferior ao previsto pelo modelo, isso indica que as ações de manutenção ou investimento foram eficazes. Por outro lado, se o DEC excede o valor previsto, é possível concluir que as ações foram insuficientes, permitindo ajustes no planejamento futuro.
- **Identificação de desvios climáticos:** A relação entre as variações do ONI e o DEC bruto (DEC\_B) permite desvincular impactos causados por condições climáticas de resultados diretamente atribuíveis à gestão da distribuidora.

### 4. Tomada de Decisão Baseada em Dados

A integração de modelos preditivos no processo decisório fortalece a abordagem baseada em dados, permitindo:

- **Previsão de riscos climáticos:** Com os dados do ONI e suas variações (delta\_índice), a distribuidora pode prever períodos de maior risco de tempestades severas e planejar ações de mitigação.
- **Definição de metas realistas:** As previsões permitem estabelecer metas para o DEC que considerem tanto o impacto das condições climáticas quanto os efeitos das ações operacionais.

### 5. Gestão de Riscos e Conformidade Regulatória

As distribuidoras de energia operam sob rigorosos critérios regulatórios que incluem metas de continuidade do fornecimento (como DEC e FEC). Os modelos preditivos ajudam a:

- **Mitigar penalidades:** Antecipar picos de DEC permite planejar ações corretivas para evitar ultrapassagens nas metas regulatórias, reduzindo o risco de multas.
- **Subsidiar negociações regulatórias:** A análise preditiva pode ser usada para demonstrar a influência de fatores externos, como eventos climáticos extremos, sobre o desempenho da distribuidora, contribuindo para ajustes de metas regulatórias.

### 6. Suporte ao Planejamento Estratégico

Os modelos também têm implicações estratégicas de longo prazo:

- **Gestão de crises climáticas:** Com a intensificação dos impactos das mudanças climáticas, os modelos ajudam a distribuidora a desenvolver planos de resiliência para eventos futuros.
- **Otimização de investimentos:** A projeção de longo prazo do DEC bruto e líquido orienta o direcionamento de investimentos para projetos que maximizem a continuidade do fornecimento e minimizem custos regulatórios.

### 7. Melhoria Contínua e Inovação

Os modelos preditivos não apenas auxiliam na gestão operacional, mas também estimulam a inovação e a melhoria contínua:

- **Aprimoramento do modelo:** À medida que novos dados climáticos e operacionais são incorporados, os modelos tornam-se mais precisos e úteis.
-

**Indicadores de desempenho operacional (KPIs):** A modelagem preditiva pode ser usada para criar novos indicadores de desempenho, permitindo à distribuidora monitorar sua eficiência com maior precisão.

### 3. Conclusão

Os resultados deste estudo mostram que o ENSO, monitorado pelo ONI, está diretamente relacionado ao DEC, mas não de forma linear. A análise destacou que a variação do índice ONI é o principal determinante para os picos de DEC\_B, mais relevante do que as fases específicas de El Niño ou La Niña. Essa descoberta reforça a importância de monitorar e prever variações significativas no ONI para mitigar interrupções de energia.

A integração de modelos preditivos e dados climáticos no planejamento operacional das distribuidoras de energia pode otimizar ações de manutenção, priorizar investimentos e aumentar a eficiência operacional. Além disso, os modelos preditivos oferecem uma ferramenta robusta para medir a eficácia das ações, contribuindo para uma gestão mais transparente e eficaz dos recursos.

Esse estudo também evidencia que o planejamento integrado e o uso de dados históricos são cruciais para enfrentar os desafios impostos pelas mudanças climáticas, garantindo a resiliência da rede elétrica e a satisfação dos consumidores.

### 4. Referências bibliográficas

#### Referências

1. Climate Prediction Center. "ENSO Diagnostic Discussion." NOAA, 14 Nov. 2024. Link
2. Climate Prediction Center. "Global ENSO Temperature and Precipitation Linear Regressions." NOAA, 2010. Link
3. Climate Prediction Center. "ENSO: Recent Evolution, Current Status and Predictions." NOAA, 2024. Link
4. Taylor, S. J., & Letham, B. (2018). "Forecasting at Scale." *The American Statistician*, 72(1), 37-45. (Modelo Prophet) Link
5. Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and Practice*. (SARIMAX e outros métodos de séries temporais). Link
6. Hochreiter, S., & Schmidhuber, J. (1997). "Long Short-Term Memory." *Neural Computation*, 9(8), 1735–1780. (Modelo LSTM) Link
7. PyCaret. "PyCaret: An Open Source, Low-Code Machine Learning Library." Link
8. Zhang, G. P. (2003). "Time series forecasting using a hybrid ARIMA and neural network model." *Neurocomputing*, 50, 159–175. (Abordagem híbrida para séries temporais). Link