

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE GOIÁS
CÂMPUS ITUMBIARA
BACHARELADO EM ENGENHARIA ELÉTRICA**

RAYRA AUGUSTA GONÇALVES RAMOS

**ANÁLISE DE MÉTODOS DE INTELIGÊNCIA ARTIFICIAL NA PREVISÃO DE
DADOS PLUVIOMÉTRICOS**

**ITUMBIARA-GO
2025**



INSTITUTO FEDERAL
Goiás

MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
SISTEMA INTEGRADO DE BIBLIOTECAS

TERMO DE AUTORIZAÇÃO PARA DISPONIBILIZAÇÃO NO REPOSITÓRIO DIGITAL DO IFG - ReDi IFG

Com base no disposto na Lei Federal nº 9.610/98, AUTORIZO o Instituto Federal de Educação, Ciência e Tecnologia de Goiás, a disponibilizar gratuitamente o documento no Repositório Digital (ReDi IFG), sem ressarcimento de direitos autorais, conforme permissão assinada abaixo, em formato digital para fins de leitura, download e impressão, a título de divulgação da produção técnico-científica no IFG.

Identificação da Produção Técnico-Científica

- | | |
|--|---|
| ☐ Tese | ☐ Artigo Científico |
| ☐ Dissertação | ☐ Capítulo de Livro |
| ☐ Monografia – Especialização | ☐ Livro |
| ☒ TCC - Graduação | ☐ Trabalho Apresentado em Evento |
| ☐ Produto Técnico e Educacional - Tipo: _____ | |

Nome Completo do Autor: Rayra Augusta Gonçalves Ramos.

Matrícula: 20182040070123.

Título do Trabalho: Análise de métodos de inteligência artificial na previsão de dados pluviométricos.

Autorização - Marque uma das opções

1. (**X**) Autorizo disponibilizar meu trabalho no Repositório Digital do IFG (acesso aberto);
2. () Autorizo disponibilizar meu trabalho no Repositório Digital do IFG somente após a data ____/____/____ (Embargo);
3. () Não autorizo disponibilizar meu trabalho no Repositório Digital do IFG (acesso restrito).

Ao indicar a opção **2 ou 3**, marque a justificativa:

- () O documento está sujeito a registro de patente.
() O documento pode vir a ser publicado como livro, capítulo de livro ou artigo.
() Outra justificativa: _____

DECLARAÇÃO DE DISTRIBUIÇÃO NÃO-EXCLUSIVA

O/A referido/a autor/a declara que:

- i. o documento é seu trabalho original, detém os direitos autorais da produção técnico-científica e não infringe os direitos de qualquer outra pessoa ou entidade;
- ii. obteve autorização de quaisquer materiais inclusos no documento do qual não detém os direitos de autor/a, para conceder ao Instituto Federal de Educação, Ciência e Tecnologia de Goiás os direitos requeridos e que este material cujos direitos autorais são de terceiros, estão claramente identificados e reconhecidos no texto ou conteúdo do documento entregue;
- iii. cumpriu quaisquer obrigações exigidas por contrato ou acordo, caso o documento entregue seja baseado em trabalho financiado ou apoiado por outra instituição que não o Instituto Federal de Educação, Ciência e Tecnologia de Goiás.

Itumbiara-GO, 24/03/2025.

Local

Data



Documento assinado digitalmente
RAYRA AUGUSTA GONCALVES RAMOS
Data: 24/03/2025 22:14:48-0300
Verifique em <https://validar.iti.gov.br>

Assinatura do Autor e/ou Detentor dos Direitos Autorais

RAYRA AUGUSTA GONÇALVES RAMOS

ANÁLISE DE MÉTODOS DE INTELIGÊNCIA ARTIFICIAL NA PREVISÃO DE DADOS
PLUVIOMÉTRICOS

Trabalho de Conclusão de Curso apresentado ao curso de Bacharelado em Engenharia Elétrica, do Instituto Federal de Educação, Ciência e Tecnologia de Goiás - Campus Itumbiara, como requisito parcial à obtenção do título de Bacharel em Engenharia Elétrica.

Orientador: Prof. Dr. Hugo Xavier Rocha

Dados Internacionais de Catalogação na Publicação (CIP)

R175 Ramos, Rayra Augusta Gonçalves
 Análise de métodos de inteligência artificial na previsão de
 dados pluviométricos. / Rayra Augusta Gonçalves Ramos. --
 Itumbiara, 2025.
 49 p. : il.

 Trabalho de conclusão de curso (Bacharelado em Engenharia
 Elétrica) - Instituto Federal de Educação, Ciência e Tecnologia
 de Goiás, Câmpus Itumbiara, 2025.

 Orientador: Prof. Dr. Hugo Xavier Rocha

 1.Inteligência Artificial. 2. Análise de séries temporais.
 3.Vetores. I. Título. II. Ramos, Rayra Augusta Gonçalves. IV.
 Rocha, Hugo Xavier. Instituto Federal de Educação, Ciência e
 Tecnologia de Goiás.

CDD 621.3

Instituto Federal de Educação, Ciência e Tecnologia de Goiás
Biblioteca Maria Gabriela Pacheco Pardey / Câmpus Itumbiara
Bibliotecário: Marla de Souza Correia CRB-1/3011



INSTITUTO FEDERAL
Goiás

MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE GOIÁS
CÂMPUS ITUMBIARA

Termo de Aprovação

RAYRA AUGUSTA GONÇALVES RAMOS

ANÁLISE DE MÉTODOS DE INTELIGÊNCIA ARTIFICIAL NA PREVISÃO DE DADOS PLUVIOMÉTRICOS

Trabalho de Conclusão de Curso apresentado à Coordenação do Curso de Engenharia Elétrica do Instituto Federal de Educação, Ciência e Tecnologia de Goiás – Campus Itumbiara, como parte dos requisitos para a obtenção do título de Bacharel em Engenharia Elétrica.

Trabalho de Conclusão de Curso defendido e aprovado, em 07 de março de 2025, pela banca examinadora constituída pelos seguintes membros:

BANCA EXAMINADORA

Prof. DSc. Hugo Xavier Rocha - Orientador

Instituto Federal de Goiás, Campus Itumbiara.

(Assinado Eletronicamente).

Prof. DSc. Jucélio Costa de Araújo - Membro interno

Instituto Federal de Goiás, Campus Itumbiara.

(Assinado Eletronicamente).

Prof. DSc. Wellington do Prado - membro interno

Instituto Federal de Goiás, Campus Itumbiara.

(Assinado Eletronicamente).

Itumbiara – GO

2025

Documento assinado eletronicamente por:

- Jucelio Costa de Araujo, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 10/03/2025 11:25:16.
- Wellington do Prado, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 10/03/2025 10:53:18.
- Hugo Xavier Rocha, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 07/03/2025 16:01:02.

Este documento foi emitido pelo SUAP em 07/03/2025. Para comprovar sua autenticidade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifg.edu.br/autenticar-documento/> e forneça os dados abaixo:

Código Verificador: 624957

Código de Autenticação: 6e5be05ab6



Instituto Federal de Educação, Ciência e Tecnologia de Goiás
Avenida Furnas, nº 55, 55, Bairro Village Imperial, ITUMBIARA / GO, CEP 75524-010
(64) 2103-5612 (ramal: 5612)

Primeiramente a Deus por ter me dado força e sabedoria. A minha mãe Maria Aparecida Gonçalves Leite Erle, as minhas irmãs e todos os meus colegas e amigos por todo apoio nessa jornada.

AGRADECIMENTOS

Este momento representa mais do que palavras podem expressar. Durante essa caminhada, enfrentei desafios que pareceram intransponíveis, mas com determinação e apoio, consegui superá-los. Essa trajetória não foi percorrida sozinha, e sou imensamente grata a todos que, de alguma forma, contribuíram para que este sonho se tornasse realidade.

À minha mãe e irmãs, que foram meu alicerce inabalável. Sem vocês, essa conquista não seria possível. Cada incentivo, gesto de carinho e apoio incondicional foram essenciais para que eu chegasse até aqui.

Aos professores, cuja dedicação e orientação foram fundamentais para minha formação. Seu conhecimento e apoio foram indispensáveis no desenvolvimento deste trabalho e no meu crescimento acadêmico.

Às minhas amigas, que estiveram sempre ao meu lado, me ouvindo e me incentivando, mesmo nos momentos mais difíceis. Obrigada por serem meu suporte e me ajudarem a seguir em frente.

Aos colegas e mentores, que compartilharam comigo experiências valiosas e contribuíram para minha jornada acadêmica e profissional. Seu conhecimento e incentivo foram essenciais para meu aprendizado.

Ao grupo acadêmico, ao corpo docente e a todos que, direta ou indiretamente, auxiliaram na minha evolução. As trocas de conhecimento e os desafios enfrentados tornaram essa trajetória enriquecedora.

Aos amigos do curso, Ana Laura Magalhães, Gustavo Rocha, Leticia Torres, Myllena Cunha e Niele Alves, que tornaram essa caminhada mais leve e significativa. Compartilhamos desafios, conquistas e momentos inesquecíveis, tornando essa experiência ainda mais especial.

Por fim, minha gratidão a todos que, de alguma forma, fizeram parte desta jornada, seja por meio de palavras, gestos ou presença nos momentos mais desafiadores. Cada um de vocês contribuiu para a realização deste sonho.

Muito obrigada!

RESUMO

Este estudo investiga a aplicação de métodos de Inteligência Artificial na previsão de dados pluviométricos, com enfoque na análise de séries temporais e suas implicações para o setor energético. Foram avaliados três modelos preditivos: máquinas de vetores de suporte (SVM), Random Forest e ARIMA, comparando sua eficácia na modelagem de padrões climáticos e de consumo energético. A pesquisa utilizou dados históricos de precipitação e consumo elétrico, aplicando técnicas de tratamento, normalização e análise estatística para validar os modelos. Os resultados demonstraram que o SVM apresentou o melhor desempenho, com menor erro preditivo e maior capacidade de adaptação a oscilações sazonais e eventos climáticos extremos, como o fenômeno El Niño. O Random Forest obteve um desempenho intermediário, enquanto o ARIMA mostrou dificuldades em capturar padrões não lineares e variações abruptas nos dados. A análise comparativa reforça a importância de técnicas avançadas para previsão de consumo energético, evidenciando que modelos baseados em aprendizado de máquina são mais eficazes do que abordagens estatísticas tradicionais. Conclui-se que a aplicação de Inteligência Artificial pode aprimorar a gestão energética e auxiliar na formulação de estratégias para mitigação dos impactos de variáveis climáticas sobre a demanda elétrica.

Palavras-chave: Inteligência Artificial; Dados Pluviométricos; Séries Temporais; Máquinas de Vetores de Suporte; Random Forest.

ABSTRACT

This study investigates the application of artificial intelligence methods in forecasting rainfall data, focusing on time series analysis and its implications for the energy sector. Three predictive models were evaluated: support vector machines (SVM), random forest and ARIMA, comparing their effectiveness in modeling climate patterns and energy consumption. The research used historical data on precipitation and electrical consumption, applying processing, normalization and statistical analysis techniques to validate the models. The results demonstrated that the SVM presented the best performance, with lower predictive error and greater ability to adapt to seasonal fluctuations and extreme weather events, such as the El Niño phenomenon. Random forest achieved an intermediate performance, while ARIMA showed difficulties in capturing non-linear patterns and abrupt variations in the data. The comparative analysis reinforces the importance of advanced techniques for predicting energy consumption, showing that models based on machine learning are more effective than traditional statistical approaches. It is concluded that the application of artificial intelligence can improve energy management and assist in the formulation of strategies to mitigate the impacts of climate variables on electrical demand.

Keywords: Artificial Intelligence; Rainfall Data; Time Series; Support Vector Machines; Random Forest.

LISTA DE FIGURAS

Figura 1 - Seleção e Leitura do Arquivo	32
Figura 2 - Transformação dos Dados	33
Figura 3 - Padronização da Variável de Mês.....	33
Figura 4 - Identificação e Substituição de Valores Ausentes	33
Figura 5 - Teste de Normalidade	34
Figura 6 - Escolha do Teste Estatístico	34
Figura 7 - Dados do Treino	35
Figura 8 - Modelo ARIMA	35
Figura 9 - Modelo SVM	35
Figura 10 - Modelo Random Forest	35
Figura 11 - Avaliação de Modelos	36
Figura 12 - Visualização dos Resultados	36

LISTA DE GRÁFICOS

Gráfico 1 - Boxplot da Distribuição Mensal do Consumo de Energia	37
Gráfico 2 - Evolução do Consumo de Energia de 2003 a 2024.....	38
Gráfico 3 - Comparação entre Consumo Habitual e Previsão pelo ARIMA.....	40
Gráfico 4 - Comparação entre Consumo Habitual e Previsão pelo Random Forest	41
Gráfico 5 - Comparação entre Consumo Habitual e Previsão pelo SVM	42
Gráfico 6 - Comparação entre Modelos Preditivos para 2024-2028 Destacando o Impacto do El Niño.....	43

LISTA DE TABELAS

Tabela 1 - Comparação dos Modelos Preditivos (RMSE e MAE).....	39
---	----

LISTA DE ABREVIATURAS E SIGLAS

ABNT – Associação Brasileira de Normas Técnicas

AI – Inteligência Artificial

ANN – Artificial Neural Networks (Redes Neurais Artificiais)

ARIMA – AutoRegressive Integrated Moving Average

CSV – Comma-Separated Values (Valores Separados por Vírgula)

DB – Banco de Dados

El Niño – Oscilação Climática de Aquecimento das Águas do Oceano Pacífico

EPE – Empresa de Pesquisa Energética

IEEE – Institute of Electrical and Electronics Engineers

IoT – Internet das Coisas

LSTM – Long Short-Term Memory (Memória de Longo e Curto Prazo)

MAE – Mean Absolute Error (Erro Absoluto Médio)

MSE – Mean Squared Error (Erro Quadrático Médio)

PET – Programa de Educação Tutorial

RF – Random Forest (Floresta Aleatória)

RMSE – Root Mean Squared Error (Raiz do Erro Quadrático Médio)

SVM – Support Vector Machine (Máquina de Vetores de Suporte)

TS – Time Series (Séries Temporais)

XAI – Explainable AI (Inteligência Artificial Explicável)

SUMÁRIO

1	INTRODUÇÃO	14
1.1	JUSTIFICATIVA.....	14
1.2	OBJETIVOS	15
1.2.1	Objetivo Geral.....	15
1.2.2	Objetivos Específicos.....	15
2	REFERENCIAL TEÓRICO.....	17
2.1	INTELIGÊNCIA ARTIFICIAL	17
2.2	MÉTODOS DE INTELIGÊNCIA ARTIFICIAL USADOS PARA PREVISÕES ...	18
2.3	MODELOS APLICÁVEIS À PREVISÃO DE CONSUMO DE ENERGIA.....	21
2.4	FATORES QUE INFLUENCIAM PREVISÕES RELACIONADAS AO EL NIÑO	24
2.5	DESAFIOS E LIMITAÇÕES NA APLICAÇÃO DA INTELIGÊNCIA ARTIFICIAL	26
3	METODOLOGIA	29
3.1	TIPO DE PESQUISA.....	29
3.2	PROCEDIMENTOS METODOLÓGICOS	29
3.2.1	Coleta de Dados	29
3.2.2	Tratamento e pré-processamento dos Dados.....	30
3.2.3	Modelos de Inteligência Artificial Aplicados	30
3.2.4	Avaliação e Validação dos Modelos	30
4	DESCRIÇÃO E ANÁLISE DO CÓDIGO DESENVOLVIDO EM R.....	32
4.1	IMPORTAÇÃO E TRATAMENTO INICIAL DE DADOS	32
4.1.1	Seleção e Leitura do Arquivo.....	32
4.1.2	Transformação dos Dados.....	33
4.1.3	Padronização da Variável de Mês	33
4.2	TRATAMENTO DE DADOS AUSENTES E NORMALIZAÇÃO	33
4.2.1	Identificação e Substituição de Valores Ausentes	33
4.3	ANÁLISE ESTATÍSTICA	34
4.3.1	Teste de Normalidade (Shapiro-Wilk).....	34
4.3.2	Escolha do Teste Estatístico.....	34
4.4	MODELAGEM PREDITIVA	35
4.4.1	Divisão dos Dados em Treinamento e Teste.....	35
4.4.2	Implementação dos Modelos Preditivos	35
4.5	AVALIAÇÃO DOS MODELOS.....	36
4.6	VISUALIZAÇÃO DOS RESULTADOS.....	36
5	RESULTADOS E DISCURSÕES	37
5.1	ANÁLISE DA DISTRIBUIÇÃO DO CONSUMO DE ENERGIA POR MÊS	37
5.1.1	Padrões Mensais de Consumo.....	37
5.1.2	Identificação de <i>Outliers</i>	38
5.2	EVOLUÇÃO DO CONSUMO DE ENERGIA ELÉTRICA (2003-2024).....	38
5.2.1	Tendências Gerais e Crescimento do Consumo.....	39
5.3	AVALIAÇÃO DOS MODELOS PREDITIVOS.....	39

5.4 COMPARAÇÃO ENTRE MODELOS E CONSUMO HABITUAL	40
5.4.1 Comparação entre ARIMA e Consumo Habitual	40
5.4.2 Comparação entre Random Forest e Consumo Habitual	41
5.4.3 Comparação entre SVM e Consumo Habitual	41
5.5 DISCUSSÃO DOS RESULTADOS.....	42
5.5.1 Desempenho Comparativo dos Modelos	42
5.5.2 Impacto do El Niño na Previsão do Consumo Energético	43
5.5.3 Limitações dos Modelos e Perspectivas Futuras.....	44
6 CONSIDERAÇÕES FINAIS	45
REFERÊNCIAS	47
ANEXOS	50
APÊNDICE	68

1 INTRODUÇÃO

Este estudo investiga a aplicação da Inteligência Artificial (IA) na análise e previsão de séries temporais, com ênfase em sua relevância para cenários climáticos e socioeconômicos. A IA tem se destacado como uma ferramenta eficiente para lidar com grandes volumes de dados, identificar padrões complexos e prever tendências, tornando-se um recurso estratégico em diversos setores. Estudos como os de Scodro e Corso (2023) demonstram a eficácia de modelos preditivos, como AutoRegressive Integrated Moving Average (ARIMA) e Redes Neurais Artificiais (Artificial Neural Networks – ANN), na previsão de preços de alimentos e na compreensão das variações climáticas que impactam diretamente os mercados agrícolas.

A análise de dados ambientais, no entanto, é desafiadora devido a lacunas e inconsistências nos registros, frequentemente causadas por falhas técnicas e limitações operacionais. Métodos que combinam abordagens tradicionais e Redes Neurais Artificiais (ANN), conforme destacado por Ruezzene *et al.* (2021), são fundamentais para preencher essas lacunas e garantir análises climáticas mais precisas, especialmente em regiões com grande variabilidade pluviométrica. Adicionalmente, Barros *et al.* (2023) ressaltam a importância da IA na gestão ambiental, permitindo o monitoramento contínuo de áreas sensíveis e a elaboração de estratégias preventivas. No município de Teresópolis – Rio de Janeiro, o uso de tecnologias avançadas possibilitou intervenções mais assertivas e sustentáveis na administração de recursos naturais.

A aplicação da IA na previsão de consumo de energia elétrica também se destaca, especialmente em cenários influenciados por fenômenos climáticos como o El Niño – Oscilação Climática de Aquecimento das Águas do Oceano Pacífico. A previsão precisa do consumo energético é essencial para o planejamento estratégico do setor elétrico, evitando desperdício e garantindo a eficiência na distribuição. No entanto, a implementação de modelos de IA enfrenta desafios como a necessidade de dados de alta qualidade, a complexidade dos algoritmos e a transparência nos processos decisórios. Superar essas barreiras é essencial para maximizar o potencial dessa tecnologia e sua contribuição para a tomada de decisões estratégicas.

1.1 JUSTIFICATIVA

A crescente dependência de fontes energéticas e os impactos de variáveis climáticas na demanda por eletricidade evidenciam a necessidade de aprimorar modelos de previsão no setor

elétrico. Métodos tradicionais frequentemente apresentam limitações ao lidar com padrões complexos e dados inconsistentes, comprometendo a precisão das projeções.

A IA tem se mostrado uma abordagem promissora nesse cenário, pois permite a modelagem de séries temporais (Time Series – TS) e a identificação de correlações entre fatores climáticos e o consumo de energia. No entanto, a eficácia desses modelos ainda precisa ser avaliada de forma sistemática, especialmente no contexto de eventos climáticos extremos, como o El Niño.

Dessa forma, este estudo justifica-se pela necessidade de investigar e comparar técnicas avançadas de IA aplicadas à previsão energética, visando não apenas a melhoria na qualidade das projeções, mas também o suporte a tomadas de decisão estratégicas no setor.

1.2 OBJETIVOS

1.2.1 Objetivo Geral

Analisar a aplicação de métodos de Inteligência Artificial na previsão de dados pluviométricos, avaliando sua eficácia na modelagem de séries temporais e na identificação de padrões climáticos que influenciam o consumo de energia elétrica.

1.2.2 Objetivos Específicos

- Descrever os principais métodos de IA utilizados para previsões climáticas e energéticas, como Máquinas de Vetores de Suporte (Support Vector Machine – SVM), Modelos de Séries Temporais (ARIMA) e Árvores de Decisão (Random Forest – RF);
- Comparar a precisão e a eficiência dos diferentes modelos de previsão, destacando suas vantagens e limitações na análise de dados pluviométricos;
- Identificar fatores que influenciam a previsibilidade do consumo de energia elétrica, especialmente aqueles relacionados a eventos climáticos extremos, como o fenômeno El Niño;
- Analisar como a aplicação de modelos híbridos (estatísticos e baseados em aprendizado de máquina) pode aprimorar as previsões e reduzir erros em séries temporais complexas;
- Avaliar o impacto da qualidade dos dados na precisão dos modelos, considerando a necessidade de preenchimento de lacunas e tratamento de inconsistências nos registros históricos;

- Sugerir aprimoramentos para a implementação de modelos preditivos no setor energético, visando aumentar a confiabilidade das projeções e auxiliar no planejamento estratégico de recursos.

2 REFERENCIAL TEÓRICO

2.1 INTELIGÊNCIA ARTIFICIAL

A Inteligência Artificial (IA) representa uma das mais importantes inovações tecnológicas do século XXI, com aplicações em diversas áreas que vão desde a educação até a gestão ambiental. Sua capacidade de processar grandes volumes de dados e identificar padrões complexos torna essa tecnologia indispensável para enfrentar desafios contemporâneos. De acordo com Ruezzene *et al.* (2021), a IA tem se mostrado eficaz no preenchimento de falhas em séries temporais de dados climáticos, utilizando técnicas como Redes Neurais Artificiais. Essas abordagens permitem não apenas a recuperação de dados ausentes, mas também a geração de informações que possibilitam análises mais precisas sobre o comportamento climático, essenciais para o planejamento sustentável.

No campo da análise ambiental, a IA desempenha um papel central na identificação de áreas vulneráveis e na elaboração de estratégias de preservação. Barros *et al.* (2023) destacam como a tecnologia tem sido aplicada na avaliação de regiões ambientalmente frágeis, utilizando algoritmos de aprendizado de máquina para monitorar fatores como desmatamento, qualidade da água e erosão do solo. A análise automatizada em tempo real, viabilizada por sensores e imagens de satélite, possibilita a implementação de políticas públicas mais efetivas, reforçando a sustentabilidade e minimizando os impactos ambientais.

Por outro lado, a Inteligência Artificial também desempenha um papel crucial na modelagem e previsão em setores estratégicos, como o agronegócio, devido à sua capacidade de processar grandes volumes de dados e identificar padrões complexos. Scodro e Corso (2023) destacam que a combinação de modelos estatísticos tradicionais, como o ARIMA, com técnicas modernas de Redes Neurais Artificiais resulta em previsões mais precisas de preços de alimentos. Essa integração possibilita a análise de variáveis como índices pluviométricos, sazonalidade e flutuações no mercado global, proporcionando informações estratégicas para os tomadores de decisão. Em cenários de alta volatilidade climática e econômica, a capacidade da IA de incorporar múltiplas fontes de dados em tempo real é indispensável para antecipar tendências e mitigar riscos.

No entanto, a rápida evolução da Inteligência Artificial apresenta desafios éticos e sociais que devem ser cuidadosamente endereçados. Sichman (2021) enfatiza a necessidade de maior transparência nos algoritmos para evitar vieses e injustiças nos processos de tomada de decisão. Ele também alerta para o impacto potencial da automação na concentração de poder

econômico e na exclusão de populações vulneráveis. Por exemplo, a substituição de tarefas humanas por sistemas automatizados pode ampliar desigualdades sociais se não forem implementadas políticas de transição justa. Assim, a reflexão crítica sobre o impacto social da IA é essencial para equilibrar progresso tecnológico com responsabilidade coletiva.

A educação é outro setor amplamente transformado pela inteligência artificial, especialmente no que diz respeito à personalização do ensino. Barbosa e Portes (2023) evidenciam como a IA pode ser utilizada para adaptar conteúdos pedagógicos às necessidades e preferências individuais dos alunos. Ferramentas como tutores virtuais e sistemas de aprendizado adaptativo não apenas tornam o ensino mais eficiente, mas também democratizam o acesso à educação de qualidade. Em um contexto de sociedade em constante transformação, essas tecnologias oferecem oportunidades para superar barreiras tradicionais de acesso e inclusão, promovendo o aprendizado contínuo e alinhado às demandas do século XXI.

Além disso, a Inteligência Artificial tem o potencial de oferecer soluções inovadoras para problemas complexos em diversos setores, incluindo saúde, energia e meio ambiente. Ruezzene *et al.* (2021) destacam que, embora a IA tenha demonstrado eficácia na resolução de desafios técnicos, seu desenvolvimento e aplicação devem ser orientados por princípios de sustentabilidade e ética. Por exemplo, sistemas de IA utilizados em saúde pública devem ser projetados para melhorar a equidade no acesso a serviços essenciais, enquanto tecnologias aplicadas no setor energético precisam considerar o impacto ambiental e a eficiência no uso de recursos naturais.

Para que a Inteligência Artificial alcance seu potencial máximo, é imprescindível um compromisso com a inovação responsável. Isso inclui não apenas a criação de tecnologias avançadas, mas também a adoção de políticas e regulamentações que garantam sua aplicação ética e sustentável. Conforme apontado por Ruezzene *et al.* (2021), a IA pode se consolidar como uma ferramenta indispensável para a construção de um futuro mais inclusivo, mas sua implementação deve ser acompanhada de estratégias que minimizem os riscos e maximizem os benefícios. Dessa forma, a tecnologia pode promover não apenas avanços econômicos, mas também transformações sociais significativas em direção a uma sociedade mais justa e equilibrada.

2.2 MÉTODOS DE INTELIGÊNCIA ARTIFICIAL USADOS PARA PREVISÕES

A aplicação de métodos de Inteligência Artificial (IA) para previsões pluviométricas tem revolucionado o campo da análise climática, oferecendo ferramentas robustas e precisas

para lidar com desafios que envolvem dados complexos e dinâmicos. Esses métodos são essenciais para a compreensão dos padrões de precipitação, permitindo o planejamento e a gestão eficaz de recursos hídricos e agrícolas.

Um dos métodos mais utilizados é o modelo de Redes Neurais Artificiais (RNA), conhecido por sua capacidade de identificar padrões complexos e não lineares em séries temporais. Ruezzene *et al.* (2021) destacam a eficiência das RNAs no preenchimento de falhas em dados pluviométricos. Essa técnica não apenas corrige lacunas em séries temporais, mas também melhora a qualidade das análises subsequentes, tornando-as mais precisas e confiáveis. Em cenários onde os dados são escassos ou apresentam inconsistências, as RNAs se mostram indispensáveis para reconstruir séries temporais contínuas e consistentes.

O modelo Box-Jenkins (BJ) continua a ser amplamente reconhecido como uma ferramenta essencial na análise de séries temporais devido à sua abordagem estatística detalhada e rigorosa. Conforme demonstrado por Salame *et al.* (2019), sua aplicação em dados relacionados à precipitação oferece resultados confiáveis na modelagem de padrões sazonais e cíclicos. Isso se deve à capacidade do BJ de capturar a estrutura subjacente dos dados, mesmo em contextos de alta variabilidade. Além disso, quando combinado com métodos como o Singular Spectrum Analysis (SSA), que suaviza os dados antes da modelagem, sua eficácia é ainda maior. Essa combinação permite que padrões ocultos sejam melhor identificados, proporcionando uma base sólida para a previsão precisa de eventos climáticos extremos, como variações bruscas na precipitação.

O aprendizado profundo, representado por modelos como as redes Long Short-Term Memory (LSTM), trouxe avanços significativos na área de previsão pluviométrica. Esses modelos, projetados para lidar com longas séries de dados temporais, têm a capacidade de capturar dependências complexas entre variáveis, algo que métodos convencionais frequentemente não conseguem identificar. Neto e Nascimento (2024) destacam que o LSTM é particularmente eficaz na previsão de eventos hidrológicos extremos, como enchentes e secas, graças à sua habilidade de processar informações sequenciais de longo prazo. Em regiões como a Amazônia, onde os padrões climáticos são altamente dinâmicos e imprevisíveis, o LSTM tem demonstrado ser uma ferramenta crucial para prever níveis de rios e antecipar impactos de eventos extremos, contribuindo para o planejamento de ações de mitigação.

Os modelos híbridos têm ganhado destaque pela capacidade de unir as forças de abordagens tradicionais e modernas. Um exemplo notável é a integração entre ARIMA, conhecido por sua robustez na análise de séries temporais lineares e, Redes Neurais Artificiais (RNAs), que lidam bem com relações não lineares nos dados. Scodro e Corso (2023)

demonstram que essa combinação não apenas melhora a assertividade das previsões, mas também reduz significativamente os erros, tornando os resultados mais confiáveis. Essa abordagem é especialmente valiosa em contextos onde os padrões de precipitação são fortemente influenciados por fenômenos climáticos, como o El Niño. A capacidade de integrar o rigor analítico do ARIMA com a flexibilidade das RNAs permite uma análise mais completa, abrangendo tanto tendências lineares quanto complexidades não lineares.

Além disso, Ribeiro *et al.* (2024) destacam a importância de incorporar variáveis climáticas locais e globais na construção de modelos preditivos. O uso de abordagens integradas que combinam aprendizado profundo com dados regionais específicos mostrou-se eficiente na previsão de fenômenos pluviométricos e em sua relação com padrões sazonais amplos, como o El Niño e La Niña. Essa integração aumenta a capacidade dos modelos de capturar os efeitos combinados de fatores locais, como relevo e vegetação, e de fenômenos climáticos globais, proporcionando previsões mais detalhadas e úteis para gestores de recursos hídricos.

Por outro lado, Barbosa e Portes (2023) enfatizam que a escolha do modelo apropriado deve levar em consideração não apenas a precisão preditiva, mas também a acessibilidade e a facilidade de implementação. Eles apontam que, em muitos contextos, a combinação de métodos tradicionais, como BJ, com técnicas mais recentes, como redes neurais, pode oferecer um equilíbrio ideal entre custo-benefício e desempenho. Essa abordagem híbrida, além de ser prática, possibilita a adaptação dos modelos a diferentes cenários e a capacidade de responder rapidamente a mudanças nos padrões climáticos.

Em regiões marcadas pela escassez de dados, Ruezzene *et al.* (2021) sugerem que a aplicação de técnicas avançadas para preenchimento de lacunas em séries temporais é fundamental para melhorar a qualidade das previsões. Quando esses dados tratados são integrados a modelos preditivos, como LSTM ou ARIMA-RNA, a confiabilidade dos resultados é substancialmente aprimorada. Essa etapa é crucial para evitar falhas nas previsões e garantir que as decisões tomadas com base nessas análises sejam eficazes.

A aplicação de IA não se limita à previsão de precipitação, mas também inclui o monitoramento e a análise de variáveis climáticas relacionadas, como a vazão de rios e a umidade do solo. Ferramentas como Random Forest e Gradient Boosting são frequentemente utilizadas para identificar variáveis-chave que influenciam os padrões pluviométricos. Essas técnicas baseadas em árvores de decisão oferecem alta interpretabilidade, permitindo que pesquisadores e gestores compreendam melhor os fatores que afetam os resultados.

O papel dos métodos preditivos vai além do processamento de dados. A IA contribui para a formulação de cenários futuros, possibilitando a criação de estratégias proativas para

mitigar os impactos de eventos climáticos extremos. Por exemplo, modelos como o LSTM são capazes de simular diferentes cenários com base em variações históricas, permitindo que autoridades se preparem para desafios climáticos de maneira mais eficaz. A integração dessas ferramentas com dados geoespaciais e históricos oferece uma visão abrangente das dinâmicas climáticas, como demonstrado por Neto e Nascimento (2024) em suas análises na Amazônia.

A escolha do método mais adequado depende do contexto específico da análise e dos objetivos do estudo. Métodos como BJ são ideais para séries temporais estáveis, enquanto as RNAs e o LSTM são mais indicados para cenários com alta complexidade e variação. Além disso, a combinação de métodos, como ARIMA e RNAs, oferece um equilíbrio entre simplicidade e precisão, tornando-os adequados para uma ampla gama de aplicações (Barros Teixeira; Santos, 2023).

Em síntese, os avanços nos métodos de Inteligência Artificial para previsões pluviométricas têm transformado a maneira como analisamos e compreendemos os padrões climáticos. Esses métodos não apenas melhoram a precisão das previsões, mas também oferecem insights valiosos para a gestão de recursos naturais e o planejamento estratégico em diversas áreas. Com a crescente disponibilidade de dados e o desenvolvimento de novas tecnologias, espera-se que essas ferramentas continuem a evoluir, contribuindo para soluções mais eficazes e sustentáveis no enfrentamento das mudanças climáticas (Salame *et al.*, 2019).

2.3 MODELOS APLICÁVEIS À PREVISÃO DE CONSUMO DE ENERGIA

A previsão do consumo de energia elétrica é essencial para o planejamento estratégico de empresas e governos, garantindo eficiência na produção e distribuição dos recursos. Scodro e Corso (2023) destacam que o modelo Autoregressive Integrated Moving Average (ARIMA) tem sido amplamente utilizado para prever padrões de consumo em séries temporais estáveis. Este modelo é eficaz em identificar tendências lineares e padrões sazonais, mas enfrenta limitações em séries com alta variabilidade. Por isso, em muitas aplicações, ele é combinado com técnicas mais avançadas para aumentar a precisão das previsões.

Salame *et al.* (2019) apontam que Redes Neurais Artificiais (RNAs) representam um avanço significativo para lidar com dados não lineares e complexos. Essas redes têm a capacidade de aprender padrões ocultos em séries temporais, sendo particularmente úteis em cenários onde fatores externos, como variações climáticas, impactam o consumo de energia. Os autores destacam ainda que as RNAs podem superar modelos estatísticos tradicionais quando

treinadas com dados de alta qualidade, mostrando um desempenho robusto em diferentes horizontes temporais.

Neto e Nascimento (2024) exploraram o uso de redes do tipo Long Short-Term Memory (LSTM) para previsões de consumo energético em cenários marcados por eventos extremos, como secas e inundações. As LSTM se destacam por sua capacidade de capturar dependências temporais de longo prazo, permitindo análises detalhadas mesmo em séries com grandes flutuações. Essa abordagem tem sido essencial para antecipar o impacto de fatores climáticos no consumo de energia, especialmente em regiões dependentes de fontes renováveis, como hidrelétricas.

Ruezzene *et al.* (2021) enfatizam a importância de garantir a qualidade dos dados antes de aplicar modelos preditivos. Em suas análises, os autores compararam métodos tradicionais e redes neurais para preenchimento de lacunas em séries temporais energéticas, demonstrando que a combinação dessas abordagens pode aumentar significativamente a confiabilidade das previsões. O uso de RNAs para este propósito mostrou-se eficiente na reconstrução de séries históricas, reduzindo erros associados a dados incompletos.

Barros *et al.* (2023) destacam que o aprendizado de máquina, aplicado em modelos híbridos, é uma solução eficiente para lidar com cenários complexos onde variáveis lineares e não lineares coexistem. A combinação de métodos estatísticos com Redes Neurais Artificiais (RNAs) tem sido especialmente útil na previsão de consumo energético em áreas urbanas densamente povoadas, onde padrões de uso são influenciados por fatores sazonais, demográficos e socioeconômicos. Esses modelos híbridos demonstram sua força ao capturar interações dinâmicas entre múltiplas variáveis, oferecendo previsões mais detalhadas e confiáveis. Além disso, os autores sugerem que o uso de aprendizado de máquina integrado a métodos tradicionais pode auxiliar na alocação de recursos e na implementação de políticas energéticas mais eficazes.

Carrer Torres e Corso (2021) exploraram a aplicação do modelo híbrido ARIMA com RNAs em séries temporais caracterizadas por alta sazonalidade e presença de ruídos, como no consumo de energia. A pesquisa revelou que essa combinação permite não apenas melhorar a precisão das previsões, mas também adaptar os modelos a mudanças abruptas nos padrões de consumo. Essa abordagem é particularmente valiosa em cenários onde o comportamento energético é influenciado por eventos inesperados, como oscilações climáticas ou crises econômicas. Os autores também apontam que o uso de métodos híbridos promove uma melhor gestão de recursos computacionais, possibilitando equilibrar a necessidade de análises detalhadas com a eficiência operacional.

Sichman (2021) aborda os desafios éticos e técnicos relacionados à aplicação de Inteligência Artificial em previsões energéticas, destacando a necessidade de transparência no desenvolvimento de algoritmos. Ele alerta que, embora os modelos baseados em IA possam alcançar alta precisão, a falta de explicabilidade nas decisões pode limitar sua aceitação em setores estratégicos. Sichman também enfatiza a importância de considerar o impacto social dessas tecnologias, especialmente no contexto de comunidades vulneráveis, onde a má implementação de sistemas automatizados pode exacerbar desigualdades. Por isso, a criação de políticas públicas que regulamentem o uso ético da IA é essencial para garantir que os benefícios tecnológicos sejam amplamente distribuídos.

Barbosa e Portes (2023) discutem o papel transformador das redes neurais profundas, como as Long Short-Term Memory (LSTM), na modelagem de séries temporais complexas. Essas técnicas têm se destacado por sua capacidade de capturar padrões sequenciais em dados energéticos, especialmente em cenários onde múltiplos fatores, como temperatura, densidade populacional e flutuações econômicas, impactam o consumo. Os autores também destacam que, embora o potencial dessas tecnologias seja significativo, sua implementação exige infraestrutura computacional robusta e treinamento especializado. Investir nesses recursos é crucial para maximizar a aplicabilidade das redes neurais profundas e garantir sua integração eficaz em estratégias de previsão.

Deste modo, Salame *et al.* (2019) reforçam que o sucesso dos modelos híbridos depende de uma preparação adequada dos dados e de uma compreensão profunda das variáveis envolvidas. Em sua análise comparativa entre Box-Jenkins e Redes Neurais Artificiais, os autores concluíram que a integração desses métodos potencializa a capacidade preditiva, especialmente quando combinados com técnicas de pré-processamento, como o Singular Spectrum Analysis (SSA). Essa abordagem híbrida permite que padrões sazonais sejam isolados de fatores aleatórios, aumentando a confiabilidade das previsões mesmo em cenários marcados por alta variabilidade e incerteza.

Ribeiro *et al.* (2024) destacam que, para maximizar a eficácia dos modelos híbridos, é fundamental considerar variáveis climáticas e ambientais como fatores-chave na previsão de consumo energético. Em seus estudos sobre a relação entre padrões climáticos locais e globais e o consumo de energia, os autores identificaram que a inclusão de dados ambientais aumenta a precisão e a relevância das previsões. Essa abordagem integrada é particularmente útil para o planejamento energético em regiões sensíveis a variações climáticas, como aquelas dependentes de fontes hidrelétricas.

Neto e Nascimento (2024) acrescentam que o uso de modelos baseados em aprendizado profundo, como redes neurais convolucionais (CNN) e LSTM, é essencial para lidar com a complexidade crescente das séries temporais energéticas. Essas redes são capazes de identificar interações sutis entre variáveis ao longo do tempo, permitindo previsões mais acuradas em contextos que a dependência temporal desempenha um papel crucial. No entanto, os autores enfatizam que a implementação dessas técnicas requer a integração de sistemas computacionais avançados e uma análise contínua das mudanças nos padrões de dados.

2.4 FATORES QUE INFLUENCIAM PREVISÕES RELACIONADAS AO EL NIÑO

A previsão de consumo de energia é fundamental para a gestão eficiente de recursos e para garantir o atendimento às demandas crescentes em diversas regiões. Ribeiro *et al.* (2024) destacam a importância de modelos preditivos baseados em fatores climáticos locais e globais. Em sua pesquisa, os autores utilizaram algoritmos como Random Forest para avaliar padrões de consumo relacionados à variação climática, demonstrando que a integração de múltiplas variáveis ambientais resulta em previsões mais precisas e adaptáveis a diferentes cenários. Essa abordagem é especialmente relevante em áreas onde o clima influencia diretamente a disponibilidade de energia.

Santos (2016) enfatiza a influência do fenômeno El Niño sobre o consumo de energia, especialmente em regiões dependentes de fontes hidrelétricas. Sua análise no município de Vitória da Conquista (BA) revelou como alterações na pluviosidade afetam a geração de energia e, consequentemente, o consumo. A inclusão de dados climáticos históricos em modelos estatísticos permite prever variações sazonais com maior precisão, auxiliando no planejamento estratégico do setor energético em períodos de instabilidade climática.

Diniz *et al.* (2020) exploraram o uso do modelo Box-Jenkins (BJ) para prever padrões de consumo energético, destacando sua eficácia em séries temporais de alta variabilidade. A metodologia mostrou-se confiável para identificar tendências sazonais e comportamentos cíclicos, sendo amplamente utilizada no setor elétrico brasileiro. No entanto, os autores apontam que sua construção exige maior rigor técnico, principalmente em séries de dados complexas, o que pode ser mitigado com o uso de técnicas híbridas.

Souza *et al.* (2016) abordam o potencial das Redes Neurais Artificiais (RNAs) como ferramenta preditiva no setor de energia. Essas redes destacam-se por sua capacidade de processar grandes volumes de dados e identificar padrões não-lineares, especialmente em cenários com múltiplas variáveis interligadas. Apesar de demandarem maior capacidade

computacional, as RNAs demonstraram um desempenho superior em relação aos métodos tradicionais, tornando-se uma escolha ideal para aplicações em tempo real e em ambientes dinâmicos.

Massulo Neto e Nascimento (2024) compararam diferentes modelos de inteligência artificial, incluindo Long Short-Term Memory (LSTM), Random Forest e Gradient Boosting, para prever eventos extremos que impactam o consumo de energia no estado do Amazonas. Os resultados indicaram que o LSTM se destacou ao capturar dependências temporais e padrões sequenciais, sendo especialmente eficaz em prever variações no nível dos rios e outras variáveis críticas. Essa capacidade reforça a relevância das redes neurais avançadas na criação de modelos adaptativos e precisos.

Barbosa e Portes (2023) discutem o papel das metodologias ativas e da Inteligência Artificial na otimização de processos analíticos no setor energético. Os autores enfatizam a necessidade de combinar inovação tecnológica com abordagens pedagógicas para capacitar profissionais na utilização de ferramentas avançadas. Essa integração promove maior eficiência no uso de modelos preditivos, resultando em decisões estratégicas mais acertadas e sustentáveis.

Salame *et al.* (2019) realizaram uma análise comparativa entre os modelos Box-Jenkins e Redes Neurais Artificiais na previsão de consumo energético, utilizando dados da bacia Araguaia-Tocantins. Embora ambos os métodos apresentem resultados satisfatórios, as redes neurais destacaram-se em séries temporais de maior complexidade. No entanto, os autores ressaltam que o método Box-Jenkins ainda é amplamente utilizado devido à sua simplicidade e robustez em contextos menos dinâmicos.

Carrer Torres e Corso (2021) investigaram o uso de modelos híbridos para prever a demanda em sistemas de iluminação automotiva, trazendo *insights* relevantes para o setor energético. A integração de ARIMA com RNAs mostrou-se eficaz na redução de erros preditivos, combinando a capacidade dos modelos estatísticos em identificar padrões sazonais com a flexibilidade das redes neurais para tratar variáveis não-lineares. Essa abordagem destaca o potencial de soluções híbridas no contexto energético.

Sichman (2021) discute os avanços e desafios associados à aplicação de Inteligência Artificial na previsão de consumo de energia. Ele aponta que, apesar do entusiasmo gerado pelas novas tecnologias, é crucial considerar questões éticas e sociais no desenvolvimento de modelos preditivos. A transparência nos algoritmos e a inclusão de variáveis contextuais são essenciais para garantir que as soluções tecnológicas beneficiem a sociedade de forma equitativa e sustentável.

Ruezzenne *et al.* (2021) exploram a importância de preencher lacunas em séries temporais antes da aplicação de modelos preditivos. Em seu estudo, métodos baseados em redes neurais mostraram-se altamente eficazes para reconstruir séries históricas e garantir maior consistência nos dados. Essa etapa é indispensável para melhorar a precisão das previsões e reduzir os erros associados a dados incompletos.

2.5 DESAFIOS E LIMITAÇÕES NA APLICAÇÃO DA INTELIGÊNCIA ARTIFICIAL

A Inteligência Artificial (IA) enfrenta diversos desafios relacionados à sua implementação em diferentes setores, principalmente devido à complexidade dos sistemas e à dependência de dados de alta qualidade. Conforme destacado por Sichman (2021), a falta de transparência nos algoritmos é uma das limitações mais críticas, pois dificulta a explicação de como os modelos chegam às suas decisões. Essa característica, frequentemente chamada de “caixa-preta”, é especialmente preocupante em áreas como saúde e justiça, onde a tomada de decisão deve ser totalmente confiável e justificável. Para mitigar esse problema, Sichman sugere que o desenvolvimento de sistemas explicáveis e transparentes seja priorizado, promovendo maior confiança por parte dos usuários.

Outro desafio significativo é a dependência de dados de alta qualidade para o treinamento de modelos de IA. Ribeiro *et al.* (2024) apontam que, em projetos como a previsão da proliferação do *Aedes aegypti*, a precisão dos modelos depende diretamente da coleta e processamento de dados atualizados e representativos. No entanto, regiões com infraestrutura tecnológica limitada podem enfrentar dificuldades para acessar ou produzir esses dados, o que compromete a aplicabilidade da IA. Além disso, a questão da proteção de dados surge como uma preocupação ética, especialmente quando informações sensíveis são usadas para treinar os modelos.

Salame *et al.* (2019) destacam que a escolha do modelo é um fator determinante para o sucesso das aplicações de IA. Em sua análise comparativa entre métodos estatísticos como Box-Jenkins e Redes Neurais Artificiais, os autores identificaram que redes neurais são mais eficazes para lidar com dados complexos e não lineares, mas apresentam maior custo computacional e exigem conhecimento técnico avançado. Essa barreira técnica pode limitar a adoção de métodos mais sofisticados, especialmente em organizações com recursos tecnológicos e humanos reduzidos.

No contexto das mudanças climáticas e previsão de eventos extremos, Neto e Nascimento (2024) discutem as limitações dos modelos de IA ao lidar com a complexidade dos fenômenos naturais. Métodos avançados como Random Forest e Redes Neurais Profundas, embora altamente precisos, dependem de uma integração eficiente de dados globais e locais, o que demanda esforços significativos de coordenação e colaboração interdisciplinar. Além disso, a variabilidade climática introduz incertezas adicionais que desafiam a confiabilidade das previsões.

A desigualdade no acesso à tecnologia é outro ponto crítico. Barbosa e Portes (2023) destacam que a aplicação de IA em setores como educação deve considerar a inclusão digital como uma prioridade. Em muitas regiões, a falta de infraestrutura tecnológica adequada impede que escolas e instituições educacionais utilizem ferramentas baseadas em IA, o que agrava as desigualdades já existentes. Os autores sugerem que iniciativas governamentais e parcerias público-privadas podem ser a solução para promover a inclusão digital e permitir que mais pessoas se beneficiem da tecnologia.

Scodro e Corso (2023) destacam que, em setores como o agronegócio, a integração de modelos estatísticos tradicionais com Redes Neurais Artificiais oferece grande potencial, mas apresenta desafios operacionais. A implementação desses sistemas exige investimentos em infraestrutura tecnológica, capacitação de profissionais e atualizações constantes para lidar com mudanças nas condições climáticas e econômicas. Essa complexidade pode dificultar a adoção da IA por pequenas e médias empresas, que frequentemente não dispõem de recursos suficientes.

A questão da governança também é destacada por Santos e Menezes (2021), que argumentam que a falta de regulamentação clara limita o uso responsável da IA. Sem políticas públicas bem definidas, o uso indiscriminado de algoritmos pode gerar desigualdades e prejudicar setores vulneráveis. Os autores enfatizam que a criação de marcos regulatórios é fundamental para equilibrar o avanço tecnológico com os princípios éticos e sociais, garantindo que a IA seja aplicada de forma justa e inclusiva.

Ruezzene *et al.* (2021) abordam ainda o desafio do preenchimento de lacunas em séries temporais de dados antes da aplicação de modelos preditivos. Eles demonstraram que métodos baseados em redes neurais são eficazes para reconstruir séries históricas e melhorar a qualidade dos dados, mas demandam maior capacidade computacional e expertise técnica. Essa etapa é essencial para evitar erros nas previsões e garantir a confiabilidade dos resultados.

Deste modo, Salame *et al.* (2019) apontam que, apesar dos avanços, a IA ainda enfrenta dificuldades em simular comportamentos humanos de forma precisa e ética. Problemas

relacionados a vieses nos algoritmos e à falta de representatividade nos dados utilizados para treinamento são comuns e podem levar a resultados discriminatórios. A solução, segundo os autores, está na adoção de práticas de desenvolvimento éticas, que considerem a diversidade e promovam a equidade em todas as fases do processo.

3 METODOLOGIA

3.1 TIPO DE PESQUISA

Este estudo caracteriza-se como uma pesquisa aplicada e quantitativa, pois busca utilizar métodos de Inteligência Artificial para previsão de dados pluviométricos e consumo energético, com foco na análise de séries temporais e padrões climáticos. A pesquisa também possui caráter exploratório e descritivo, uma vez que, além de descrever os métodos de Inteligência Artificial aplicados às previsões, busca comparar seu desempenho e eficácia na modelagem preditiva. A fase exploratória consiste no levantamento e estudo dos principais modelos de Inteligência Artificial utilizados para previsão de dados climáticos e energéticos. Já a fase descritiva refere-se à aplicação desses modelos em bases de dados reais, para avaliar sua precisão e capacidade preditiva, especialmente em cenários influenciados pelo fenômeno El Niño.

3.2 PROCEDIMENTOS METODOLÓGICOS

3.2.1 Coleta de Dados

Os dados utilizados no estudo foram obtidos a partir de fontes confiáveis, incluindo órgãos meteorológicos, como o Instituto Nacional de Meteorologia (INMET) e o National Oceanic and Atmospheric Administration (NOAA), que forneceram séries históricas de precipitação, temperatura e umidade relativa do ar. Também foram utilizados dados de instituições do setor energético, como o Operador Nacional do Sistema Elétrico (ONS) e a Agência Nacional de Energia Elétrica (ANEEL), que disponibilizaram informações sobre o consumo energético por região.

Além disso, foram consultados artigos científicos e estudos anteriores que forneceram informações complementares sobre a aplicação de modelos de Inteligência Artificial em previsões climáticas e energéticas. Os dados coletados referem-se a medições mensais de precipitação, temperatura e consumo energético, permitindo a modelagem de séries temporais e a análise de tendências ao longo dos anos. A série temporal analisada abrange um período significativo, garantindo robustez estatística nas previsões.

3.2.2 Tratamento e pré-processamento dos Dados

Antes de serem utilizados na análise na linguagem abordada, os dados foram reorganizados manualmente para garantir maior compatibilidade com a estrutura exigida pelos modelos preditivos. Essa reorganização visou facilitar a manipulação dos dados, evitando inconsistências e garantindo um formato adequado para a aplicação das técnicas de inteligência artificial.

As colunas foram renomeadas e reorganizadas para um formato mais intuitivo e compatível com a sintaxe da linguagem, evitando espaço e caracteres especiais que poderiam dificultar a importação e o processamento dos dados.

Após feito isso, os dados foram aplicados à linguagem R, onde passaram por um processo de limpeza e preparação. Foram tratados os dados ausentes por meio de interpolação estatística para pequenas lacunas e pelo uso de Redes Neurais Artificiais para reconstrução de séries históricas em casos mais complexos. Os dados foram normalizados utilizando escalas ajustadas, garantindo comparabilidade entre variáveis distintas. A detecção de valores atípicos foi realizada pelo método Z-score, prevenindo distorções nos modelos preditivos. Além disso, a base de dados foi dividida em conjuntos de treinamento, representando 80% dos dados, e de teste, com 20%, permitindo a avaliação do desempenho das previsões.

3.2.3 Modelos de Inteligência Artificial Aplicados

Os modelos de Inteligência Artificial empregados na pesquisa incluem o ARIMA, utilizado como referência para modelagem estatística de séries temporais; o SVM, empregado devido à sua capacidade de lidar com dados não lineares e de alta variabilidade; e o Random Forest, que permite a análise da influência de múltiplas variáveis climáticas e energéticas. Além disso, foram testadas abordagens híbridas, como a combinação de ARIMA com Redes Neurais Artificiais (ARIMA-RNA), visando integrar padrões estatísticos lineares com a capacidade de aprendizado profundo das redes neurais.

3.2.4 Avaliação e Validação dos Modelos

A avaliação dos modelos foi realizada com base em métricas estatísticas reconhecidas para séries temporais, como o Erro Quadrático Médio (RMSE), que penaliza grandes discrepâncias entre valores previstos e reais, o Erro Absoluto Médio (MAE), que mede a diferença média entre as previsões e os valores reais, e o Coeficiente de Determinação (R^2), que

indica o quanto o modelo explica a variabilidade dos dados reais. Os resultados foram analisados por meio de gráficos comparativos e tabelas estatísticas, permitindo identificar qual modelo apresentou maior precisão na previsão do consumo de energia elétrica e qual melhor capturou os efeitos do El Niño.

4 DESCRIÇÃO E ANÁLISE DO CÓDIGO DESENVOLVIDO EM R

O código foi desenvolvido em R, devido à sua robustez na análise estatística, manipulação de dados e implementação de algoritmos de aprendizado de máquina. R é amplamente utilizado em aplicações que envolvem séries temporais, modelagem estatística e visualização de dados, sendo, portanto, uma escolha adequada para a previsão do consumo de energia elétrica considerando padrões climáticos e a influência do fenômeno El Niño.

O código desenvolvido foi estruturado para realizar tratamento de dados, análise exploratória, testes estatísticos e modelagem preditiva, utilizando bibliotecas especializadas para cada etapa. Dentre as principais, destacam-se:

- Tidyverse e Readxl para manipulação e importação de dados;
- Forecast para séries temporais;
- e1071 para Máquinas de Vetores de Suporte (SVM);
- Random Forest para modelos baseados em Árvores de Decisão;
- ggplot2 para visualização gráfica.

4.1 IMPORTAÇÃO E TRATAMENTO INICIAL DE DADOS

4.1.1 Seleção e Leitura do Arquivo

Após a importação, os nomes das colunas são verificados e, caso necessário, renomeados para evitar erros durante o processamento dos dados.

Figura 1 - Seleção e Leitura do Arquivo

```
file_path <- file.choose()
print(paste("Arquivo selecionado:", file_path))

dados <- read_excel(file_path, sheet = "TOTAL")

dados <- dados %>%
  rename(ANO_DE_REFERENCIA = "ANO DE REFERÊNCIA", REGIAO_GEOGRAFICA = "REGIÃO GEOGRÁFICA")
```

Fonte: Elaborado pela autora.

4.1.2 Transformação dos Dados

Os dados são convertidos para formato longo, permitindo a organização da base de maneira estruturada para análises e previsões mais eficientes.

Figura 2 - Transformação dos Dados

```
dados_long <- dados %>%
  pivot_longer(cols = -c(ANO_DE_REFERENCIA, REGIAO_GEOGRAFICA),
    names_to = "Mês", values_to = "Consumo_Mwh")
```

Fonte: Elaborado pela autora.

4.1.3 Padronização da Variável de Mês

Os meses são transformados em variáveis categóricas ordenadas, garantindo que gráficos e análises respeitem a sequência cronológica correta.

Figura 3 - Padronização da Variável de Mês

```
meses_ordenados <- c("JANEIRO", "FEVEREIRO", "MARÇO", "ABRIL", "MAIO", "JUNHO",
  "JULHO", "AGOSTO", "SETEMBRO", "OUTUBRO", "NOVEMBRO", "DEZEMBRO")
dados_long$Mês <- factor(dados_long$Mês, levels = meses_ordenados, ordered = TRUE)
```

Fonte: Elaborado pela autora.

4.2 TRATAMENTO DE DADOS AUSENTES E NORMALIZAÇÃO

4.2.1 Identificação e Substituição de Valores Ausentes

O código verifica a existência de valores faltantes (NAs) e, caso existam, os substitui pela média da variável correspondente para evitar distorções nos modelos preditivos.

Figura 4 - Identificação e Substituição de Valores Ausentes

```
print("Valores ausentes antes da correção:")
print(colSums(is.na(dados_long)))

dados_long$Consumo_Mwh[is.na(dados_long$Consumo_Mwh)] <- mean(dados_long$Consumo_Mwh, na.rm = TRUE)
print(colSums(is.na(dados_long)))
```

Fonte: Elaborado pela autora.

4.3 ANÁLISE ESTATÍSTICA

4.3.1 Teste de Normalidade (Shapiro-Wilk)

Para determinar se os dados seguem uma distribuição normal, é aplicado o Teste de Shapiro-Wilk.

Figura 5 - Teste de Normalidade

```
shapiro_test <- shapiro.test(dados_long$Consumo_MWh)
print(shapiro_test)
```

Fonte: Elaborado pela autora.

4.3.2 Escolha do Teste Estatístico

Se os dados forem normais, aplica-se o “Teste t Pareado” para comparar o consumo de energia entre duas regiões. Por outro lado, se os dados não forem normais, são aplicados testes não paramétricos, como Kruskal-Wallis (para múltiplos grupos) ou Wilcoxon (para duas regiões específicas).

Figura 6 - Escolha do Teste Estatístico

```
if (shapiro_test$p.value > 0.05) {
  print("Os dados seguem distribuição normal. Aplicando Teste t Pareado...")

  dados_t_test <- dados_long %>%
    filter(REGIAO_GEOGRAFICA %in% c("Sudeste", "Nordeste")) %>%
    spread(REGIAO_GEOGRAFICA, Consumo_MWh)

  if (all(c("Sudeste", "Nordeste") %in% colnames(dados_t_test))) {
    resultado_t <- t.test(dados_t_test$Sudeste, dados_t_test$Nordeste, paired = TRUE)
    print(resultado_t)
  } else {
    print("Erro: Dados insuficientes para Teste t Pareado.")
  }
} else {
  print("Os dados NÃO seguem distribuição normal.")

  if (length(unique(dados_long$REGIAO_GEOGRAFICA)) > 2) {
    print("Mais de dois grupos detectados. Aplicando Teste de Kruskal-Wallis...")
    kruskal_test <- kruskal.test(Consumo_MWh ~ REGIAO_GEOGRAFICA, data = dados_long)
    print(kruskal_test)
  } else {
    print("Aplicando Teste de Wilcoxon para duas regiões específicas...")
    resultado_wilcox <- wilcox.test(Consumo_MWh ~ REGIAO_GEOGRAFICA, data = dados_long)
    print(resultado_wilcox)
  }
}
```

Fonte: Elaborado pela autora.

4.4 MODELAGEM PREDITIVA

4.4.1 Divisão dos Dados em Treinamento e Teste

Os dados são divididos em 80% para treinamento e 20% para teste para garantir a validação dos modelos preditivos.

Figura 7 - Dados do Treino

```
set.seed(123)
dados_treino <- dados_long %>% filter(ANO_DE_REFERENCIA < 2020)
dados_teste <- dados_long %>% filter(ANO_DE_REFERENCIA >= 2020)
```

Fonte: Elaborado pela autora.

4.4.2 Implementação dos Modelos Preditivos

- Modelo ARIMA (Séries Temporais)

Figura 8 - Modelo ARIMA

```
serie_temporal <- ts(dados_treino$Consumo_Mwh, start = min(dados_treino$ANO_DE_REFERENCIA), frequency = 12)
modelo_arima <- auto.arima(serie_temporal)
previsao_arima <- forecast(modelo_arima, h=nrow(dados_teste))
```

Fonte: Elaborado pela autora.

- Modelo SVM (Máquinas de Vetores de Suporte)

Figura 9 - Modelo SVM

```
serie_temporal <- ts(dados_treino$Consumo_Mwh, start = min(dados_treino$ANO_DE_REFERENCIA), frequency = 12)
modelo_arima <- auto.arima(serie_temporal)
previsao_arima <- forecast(modelo_arima, h=nrow(dados_teste))
```

Fonte: Elaborado pela autora.

- Modelo Random Forest (Árvores de Decisão)

Figura 10 - Modelo Random Forest

```
modelo_rf <- randomForest(Consumo_Mwh ~ ., data = dados_treino, ntree = 100)
previsao_rf <- predict(modelo_rf, newdata = dados_teste)
```

Fonte: Elaborado pela autora.

4.5 AVALIAÇÃO DOS MODELOS

Os modelos são avaliados por meio das métricas de erro:

Figura 11 - Avaliação de Modelos

```
erros <- tibble(
  Modelo = c("ARIMA", "SVM", "Random Forest"),
  RMSE = c(rmse(dados_teste$Consumo_Mwh, previsao_arima),
           rmse(dados_teste$Consumo_Mwh, previsao_svm),
           rmse(dados_teste$Consumo_Mwh, previsao_rf)),
  MAE = c(mae(dados_teste$Consumo_Mwh, previsao_arima),
           mae(dados_teste$Consumo_Mwh, previsao_svm),
           mae(dados_teste$Consumo_Mwh, previsao_rf))
)
print(erros)
```

Fonte: Elaborado pela autora.

4.6 VISUALIZAÇÃO DOS RESULTADOS

O código inclui gráficos comparando consumo real e previsto, além de destacar o impacto do El Niño na demanda energética.

Figura 12 - Visualização dos Resultados

```
ggplot(dados_long, aes(x = ANO_DE_REFERENCIA, y = Consumo_Mwh, color = REGIAO_GEOGRAFICA)) +
  geom_line() +
  geom_point() +
  labs(title = "Evolução do Consumo de Energia Elétrica (2003-2024)", x = "Ano", y = "Consumo (Mwh)") +
  theme_minimal()

# Verificar se as colunas existem no dataframe
print(colnames(dados_futuros))
```

Fonte: Elaborado pela autora.


5 RESULTADOS E DISCURSÕES

Os resultados obtidos nesta pesquisa são apresentados nesta seção, abordando a análise da distribuição do consumo de energia elétrica ao longo do tempo, a avaliação dos modelos preditivos empregados e a identificação do impacto do fenômeno El Niño no consumo energético. A interpretação dos dados foi realizada com base em métricas estatísticas, gráficos comparativos e discussões sobre a aplicabilidade dos modelos na previsão da demanda elétrica.

5.1 ANÁLISE DA DISTRIBUIÇÃO DO CONSUMO DE ENERGIA POR MÊS

O Gráfico 1 apresenta a distribuição do consumo de energia elétrica ao longo dos meses do ano, utilizando um gráfico de Boxplot. Esse tipo de visualização permite identificar a dispersão dos dados, a mediana, os quartis e possíveis outliers, fornecendo uma visão clara das oscilações mensais do consumo.

Gráfico 1 - Boxplot da Distribuição Mensal do Consumo de Energia



Fonte: Elaborado pela autora.

5.1.1 Padrões Mensais de Consumo

Observa-se que o consumo de energia apresenta variações mensais ao longo do ano, embora mantenha uma distribuição relativamente estável entre os meses. Os meses de janeiro e dezembro apresentam maior dispersão, sugerindo uma demanda energética mais volátil,


possivelmente influenciada por fatores sazonais, como períodos de férias e festividades de fim de ano. Por outro lado, junho e julho, apresentam menor variação, indicando uma demanda mais estável, possivelmente devido a padrões climáticos e operacionais das regiões analisadas.

5.1.2 Identificação de Outliers

Os pontos fora dos limites das caixas representam outliers, ou seja, valores que se desviam significativamente do padrão habitual de consumo. Esses valores extremos podem estar associados a eventos climáticos severos, variações na atividade econômica, períodos de racionamento ou aumento repentino da demanda. O impacto do fenômeno El Niño também pode justificar oscilações anômalas, uma vez que pode alterar temperaturas e padrões climáticos, influenciando a necessidade de uso de aquecimento ou refrigeração.

5.2 EVOLUÇÃO DO CONSUMO DE ENERGIA ELÉTRICA (2003-2024)¹

A evolução do consumo energético ao longo do tempo é representada na Gráfico 2, que apresenta um gráfico de séries temporais, evidenciando a tendência de crescimento e oscilações ao longo dos anos.



Fonte: Elaborado pela autora.

¹ Os dados foram retirados do site Empresa de Pesquisa Energética. Apesar de os dados estarem atualizados referente a 2024, foram utilizados os dados entre os anos 2004 e 2023 devido ao início da presente pesquisa. Cf. Empresa de Pesquisa Energética. Disponível em: <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/consumo-de-energia-eletrica>. Acesso em: 26 fev. 2024.

5.2.1 Tendências Gerais e Crescimento do Consumo

Os dados indicam um crescimento constante no consumo de energia elétrica ao longo do período analisado. Regiões com maior atividade industrial e populacional, como Sudeste e Sudeste/Centro-Oeste, apresentam os maiores volumes de consumo, refletindo a concentração de indústrias, serviços e centros urbanos com alta demanda elétrica.

5.3 AVALIAÇÃO DOS MODELOS PREDITIVOS

Para prever o consumo de energia nos anos futuros (2024-2028), foram utilizados três modelos: ARIMA, SVM e Random Forest. A eficácia desses modelos foi avaliada por meio de duas métricas estatísticas amplamente utilizadas:

- Root Mean Squared Error (RMSE): Mede o erro médio da previsão em relação aos valores reais, dando maior peso a erros maiores. Quanto menor o RMSE, mais preciso é o modelo.
- Mean Absolute Error (MAE): Representa a média dos erros absolutos, ou seja, mede o quão distante, em média, as previsões estão dos valores reais. Assim como o RMSE, valores menores de MAE indicam previsões mais acuradas.

A Tabela 1 apresenta os valores dessas métricas para cada modelo, permitindo uma comparação quantitativa do desempenho preditivo.

Tabela 1 - Comparação dos Modelos Preditivos (RMSE e MAE)

Modelo	RMSE	MAE
ARIMA	7.433.029	4.982.406
SVM	1.439.115	947.640
Random Forest	1.797.224	1.248.416

Fonte: Elaborado pela autora.

Os valores de RMSE e MAE apropriados para modelagem de consumo energético podem variar dependendo do contexto e do conjunto de dados analisado. No entanto, diversos estudos indicam que modelos preditivos devem apresentar RMSE significativamente inferior à média do consumo energético para serem considerados eficazes.

Segundo Hyndman e Athanasopoulos (2018), um modelo preditivo é considerado eficiente quando seu RMSE é menor do que 10-15% da média da série temporal. No caso deste estudo, a média de consumo energético está na ordem de dezenas de milhões de MWh, tornando valores de RMSE abaixo de 2.000.000 apropriados para modelagem preditiva aceitável.

Estudos como os de Zhang *et al.* (2020) e Chen & Liu (2021) sobre previsão de consumo elétrico sugerem que modelos baseados em aprendizado de máquina (como SVM e Random Forest) tendem a superar modelos estatísticos tradicionais (como ARIMA), especialmente em séries temporais com alta variabilidade. Esses estudos reforçam a observação de que modelos baseados em aprendizado de máquina são mais eficientes para prever padrões não lineares e oscilações abruptas, o que explica o melhor desempenho do SVM neste estudo.


5.4 COMPARAÇÃO ENTRE MODELOS E CONSUMO HABITUAL

Os modelos preditivos foram comparados ao consumo normal, que representa a média histórica de cada região e mês. Essa análise é essencial para identificar qual modelo melhor reflete as tendências reais do consumo energético e como cada abordagem responde às variações climáticas e estruturais.

5.4.1 Comparação entre ARIMA e Consumo Habitual

O gráfico a seguir (Gráfico 3) apresenta a comparação entre o consumo habitual e a previsão gerada pelo modelo ARIMA. Observa-se que este modelo tende a suavizar oscilações abruptas, baseando-se fortemente em padrões históricos.

Gráfico 3 - Comparação entre Consumo Habitual e Previsão pelo ARIMA




Fonte: Elaborado pela autora.

O modelo ARIMA projetou um crescimento contínuo do consumo para algumas regiões, como Sudeste e Sul, enquanto para outras, como Nordeste e Norte, o consumo apresentou tendência de estabilidade ou crescimento leve.

5.4.2 Comparação entre Random Forest e Consumo Habitual

O Gráfico 4 apresenta a previsão do modelo Random Forest, comparada ao consumo habitual. Diferente do ARIMA, esse modelo consegue capturar variações mais dinâmicas no consumo, sendo mais sensível a fatores externos, como eventos climáticos e mudanças econômicas.




Fonte: Elaborado pela autora.

O Random Forest capturou flutuações mais evidentes no consumo, identificando padrões não lineares que o ARIMA não conseguiu modelar com precisão.

5.4.3 Comparação entre SVM e Consumo Habitual

O Gráfico a seguir apresenta a comparação entre o consumo habitual e a previsão gerada pelo modelo SVM, que demonstrou maior eficiência em termos de erro preditivo. Esse modelo mostrou uma capacidade superior de ajuste às variações do consumo, principalmente em regiões afetadas por oscilações climáticas.

Gráfico 5 - Comparação entre Consumo Habitual e Previsão pelo SVM



Fonte: Elaborado pela autora.

Observa-se que, nos períodos de impacto do fenômeno El Niño, indicados por triângulos preenchidos, algumas regiões apresentam uma redução no consumo previsto em relação ao consumo habitual. Isso sugere que eventos climáticos podem influenciar significativamente a demanda energética. Além disso, o modelo SVM identificou padrões complexos no consumo, mostrando-se mais eficiente na previsão de períodos de alta demanda e variações abruptas.


5.5 DISCUSSÃO DOS RESULTADOS

Os resultados da modelagem preditiva indicam que o Support Vector Machine (SVM) apresentou o melhor desempenho, seguido pelo Random Forest, enquanto o ARIMA teve os piores resultados. Essa conclusão se baseia nas métricas estatísticas RMSE e MAE, nas quais o SVM obteve os menores valores, demonstrando maior precisão.

5.5.1 Desempenho Comparativo dos Modelos

O SVM mostrou-se mais eficaz porque lida bem com padrões não lineares e complexos, comuns no consumo energético, que pode ser influenciado por fatores sazonais e climáticos.

Gráfico 6 - Comparação entre Modelos Preditivos para 2024-2028 Destacando o Impacto do El Niño



Fonte: Elaborado pela autora.

Como observado no Gráfico 6, o modelo ajustou-se melhor às variações sazonais e aos períodos de alta demanda, capturando oscilações abruptas de forma mais precisa. O Random Forest, apesar de um desempenho intermediário, teve dificuldades em prever tendências de longo prazo e eventos atípicos, como o impacto do El Niño, devido à sua estrutura baseada em médias ponderadas. Por outro lado, o ARIMA teve o pior desempenho, pois sua abordagem linear não capturou adequadamente as oscilações não periódicas do consumo energético. Esse modelo mostrou limitações especialmente na previsão de mudanças bruscas e efeitos prolongados de eventos climáticos.

5.5.2 Impacto do El Niño na Previsão do Consumo Energético

O El Niño influencia diretamente o consumo energético ao aumentar a demanda por climatização (ar-condicionado, ventilação) e reduzir a geração hidrelétrica, alterando o equilíbrio entre oferta e demanda de energia. Entre os modelos avaliados:

- SVM capturou melhor essas oscilações, ajustando-se às variações históricas causadas pelo fenômeno.
- Random Forest apresentou um desempenho moderado, reconhecendo mudanças sazonais, mas sem captar completamente os picos de consumo.
- ARIMA, devido à sua estrutura linear, teve dificuldade em identificar os impactos do El Niño, subestimando aumentos repentinos no consumo.

Isso reforça a necessidade de utilizar modelos que incorporem variáveis climáticas de forma mais dinâmica para previsões mais confiáveis.

5.5.3 Limitações dos Modelos e Perspectivas Futuras

Embora o SVM tenha sido o modelo mais preciso, ele requer alto custo computacional e ajustes criteriosos de hiperparâmetros. O Random Forest mostrou robustez, mas sua capacidade de prever tendências de longo prazo pode ser aprimorada. Já o ARIMA, por ser um modelo linear, demonstrou limitações na previsão de padrões não periódicos, podendo ser melhorado ao integrar abordagens híbridas, como redes neurais combinadas com métodos estatísticos.

6 CONSIDERAÇÕES FINAIS

A presente pesquisa analisou e comparou a aplicação de diferentes modelos preditivos na previsão do consumo de energia elétrica, considerando a influência do fenômeno El Niño. A implementação dos modelos SVM, Random Forest e ARIMA permitiu avaliar suas respectivas eficácias na modelagem de séries temporais e na previsão de padrões de demanda energética. Os resultados demonstraram que o SVM apresentou o melhor desempenho, devido à sua capacidade de capturar padrões não lineares e oscilações abruptas, tornando-o mais adequado para previsões energéticas em cenários dinâmicos. O Random Forest também se mostrou eficiente, mas sua abordagem baseada em múltiplas árvores de decisão suavizou as previsões, reduzindo sua sensibilidade a variações extremas. Já o ARIMA, por ser um modelo estatístico tradicional, teve dificuldades em prever tendências não lineares e respondeu de forma limitada às oscilações causadas por eventos climáticos, resultando no desempenho mais fraco entre os modelos analisados.

Os resultados ressaltam a importância de abordagens preditivas robustas no planejamento energético, especialmente diante de fatores externos como mudanças climáticas e sazonalidades do consumo. A capacidade de prever com maior precisão o comportamento da demanda elétrica possibilita um gerenciamento mais eficiente da distribuição de energia, reduzindo desperdícios, otimizando recursos e contribuindo para a estabilidade do sistema elétrico. A aplicação de modelos baseados em aprendizado de máquina pode fornecer suporte estratégico para concessionárias e tomadores de decisão, permitindo ajustes na oferta conforme as variações de consumo previstas. Além disso, essa abordagem favorece a mitigação de impactos causados por eventos climáticos extremos, garantindo maior resiliência ao setor energético.

Diante dos desafios identificados, pesquisas futuras podem aprofundar a investigação sobre modelos híbridos, que combinem a precisão dos métodos estatísticos com a flexibilidade dos algoritmos de aprendizado de máquina. A incorporação de variáveis climáticas adicionais, como umidade relativa do ar, pressão atmosférica e velocidade do vento, pode melhorar ainda mais a acurácia das previsões, proporcionando uma visão mais ampla dos fatores que influenciam o consumo energético. Além disso, a aplicação de redes neurais profundas, como Long Short-Term Memory (LSTM), pode permitir um melhor entendimento de padrões a longo prazo em séries temporais, tornando as previsões ainda mais confiáveis.

Outra direção promissora para estudos futuros é a utilização de técnicas de Explainable AI (XAI), um conjunto de métodos desenvolvidos para aumentar a transparência dos modelos de aprendizado de máquina, tornando suas previsões mais interpretáveis e compreensíveis para usuários e tomadores de decisão. No contexto da previsão de consumo energético, a XAI poderia ajudar a explicar quais variáveis climáticas ou padrões históricos influenciam mais fortemente as previsões, permitindo ajustes mais precisos e confiáveis na gestão do setor elétrico. Ao melhorar a interpretabilidade dos modelos, essas técnicas podem aumentar a confiança de gestores e operadores no uso de algoritmos de aprendizado de máquina, facilitando sua adoção em cenários reais de planejamento energético.

Dessa forma, este estudo reforça a importância da Inteligência Artificial como ferramenta essencial para a previsão do consumo de energia elétrica, destacando que modelos avançados, como o SVM e o Random Forest, têm um papel fundamental na melhoria da eficiência energética. A adoção dessas tecnologias é crucial para enfrentar desafios relacionados à variabilidade da demanda e às mudanças climáticas, garantindo um planejamento energético mais preciso e sustentável. A evolução contínua dos modelos preditivos contribuirá para a modernização do setor elétrico, proporcionando maior segurança no fornecimento de energia e promovendo a adoção de práticas mais eficientes na gestão dos recursos energéticos.

REFERÊNCIAS

- BARBOSA, Lucia Martins; PORTES, Luiza Alves Ferreira. A inteligência artificial. **Revista Tecnologia Educacional [on line]**, Rio de Janeiro, n. 236, p. 16-27, 2023. Disponível em: chrome-extension://efaidnbmnnnibpcajpcglclefindmkaj/https://abt-br.org.br/wp-content/uploads/2023/03/RTE_236.pdf. Acesso em: 06 dez. 2024.
- BARROS TEIXEIRA, Lucas; SANTOS, Marilde Terezinha Prado. Abordagem com dados de distribuição pluviométrica na cidade de São Carlos-SP. **Anais do Encontro Anual de Tecnologia da Informação**, v. 12, n. 1, p. 12-12, 2023. Disponível em: <http://anais.eati.info:8080/index.php/2019/article/view/305>. Acesso em: 30 nov. 2024.
- BARROS, Atila *et al.* Inteligência Artificial como ferramenta de apoio a análise de dados para avaliação de áreas ambientalmente frágeis no município de Teresópolis, Rio de Janeiro. **Revista Tópicos**, v. 1, n. 4, p. 1-17, 2023. Disponível em: <https://revistatopicos.com.br/artigos/inteligencia-artificial-como-ferramenta-de-apoio-a-analise-de-dados-para-avaliacao-de-areas-ambientalmente-frageis-no-municipio-de-teresopolis-rio-de-janeiro>. Acesso em: 15 dez. 2024.
- BOX, G. E. P.; JENKINS, G. M. **Time series analysis: forecasting and control**. Holden-Day, 1970.
- BREIMAN, L. Random forests. **Machine Learning**, v. 45, n. 1, p. 5-32, 2001. Disponível em: <https://link.springer.com/article/10.1023/A:1010933404324>. Acesso em: 30 nov. 2024.
- BURGES, C. J. A tutorial on support vector machines for pattern recognition. **Data Mining and Knowledge Discovery**, v. 2, n. 2, p. 121-167, 1998. Disponível em: <https://www.di.ens.fr/~mallat/papiers/svmtutorial.pdf>. Acesso em: 25 nov. 2024.
- CARRER TORRES, José Luiz; LUÍS CORSO, Leandro. Aplicação de modelos de previsão e Inteligência Artificial para avaliar demanda no segmento de sistemas de iluminação automotivo. **Tecno-Lógica**, v. 25, n. 2, 2021. Disponível em: <https://online.unisc.br/seer/index.php/tecnologica/article/view/16425>. Acesso em: 10 ago. 2024.
- CHEN, W.; LIU, Z. Comparison of Machine Learning Algorithms for Energy Consumption Forecasting. **Energy Reports**, v. 7, p. 5171-5180, 2021. Disponível em: https://link.springer.com/chapter/10.1007/978-3-031-80817-3_5. Acesso em: 04 dez. 2024.
- DINIZ, Renata Richelle Santos *et al.* Índice de anomalia de chuvas da Microrregião do Cariri Ocidental Paraibano. **Revista Brasileira de Geografia Física**, v. 13, n. 6, p. 2628-2640, 2020. Disponível em: <https://periodicos.ufpe.br/revistas/index.php/rbgfe/article/view/244009>. Acesso em: 05 dez. 2024.
- EMPRESA DE PESQUISA ENERGÉTICA. Disponível em: <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/consumo-de-energia-eletrica>. Acesso em: 27 nov. 2024.
- FAN, S.; HYNDMAN, R. Short-term Load Forecasting Based on a Semi-Parametric Additive Model. **IEEE Transactions on Power Systems**, v. 27, n. 1, p. 134-141, 2012. Disponível em: <https://robjhyndman.com/papers/2010STLF-FinalR1.pdf>. Acesso em: 15 nov. 2024.

HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: Principles and Practice** (2nd ed.). OTexts, 2018. Disponível em: <https://otexts.com/fpp2/>. Acesso em: 06 dez. 2024.

NETO, Gilberto Massulo; NASCIMENTO, Emerson Leão Brito. Mudanças climáticas: Inteligência Artificial na previsão de eventos hidrológicos extremos no estado do Amazonas. **Cuadernos de Educación y Desarrollo**, v. 16, n. 13, p. e6849-e6849, 2024. Disponível em: <https://ojs.cuadernoseducacion.com/ojs/index.php/ced/article/view/6849>. Acesso em: 27 nov. 2024.

RIBEIRO, Eduardo *et al.* Modelo preditivo para a proliferação do *Aedes aegypti* em Itajaí (Santa Catarina): Uma abordagem integrando fatores climáticos locais e globais. **Estrabão**, v. 5, p. 81-91, 2024. Disponível em: <https://revista.estrabao.press/index.php/estrabao/article/view/207>. Acesso em: 05 jan. 2025.

RUEZZENE, Camila Bermond *et al.* Preenchimento de falhas em dados de precipitação através de métodos tradicionais e por inteligência artificial. **Revista Brasileira de Climatologia**, v. 29, p. 177-204, 2021. Disponível em: <https://ojs.ufgd.edu.br/index.php/rbclima/article/view/15184>. Acesso em: 15 dez. 2024.

SALAME, Camil Wadih *et al.* Um estudo comparativo dos modelos Box-Jenkins e Redes Neurais Artificiais na previsão de vazões e precipitações pluviométricas da bacia Araguaia, Tocantins, Brasil. **Revista Brasileira de Ciências Ambientais (RBCIAMB)**, n. 52, p. 28-43, 2019. Disponível em: https://www.rbciamb.com.br/Publicacoes_RBCIAMB/article/view/585. Acesso em: 27 nov. 2024.

SANTOS, João Marcos Amorim; MENEZES, Moisés Lima. Análise e previsão de precipitação pluviométrica sob a abordagem massa. **Pesquisa Operacional para o Desenvolvimento**, v. 14, p. 1-16, 2021. Disponível em: <https://podesenvolvimento.org.br/podesenvolvimento/article/view/696>. Acesso em: 27 nov. 2024.

SANTOS, Tiago Pereira. A influência do fenômeno el niño sobre a pluviosidade do município de Vitória da Conquista–Ba. **Revista Geoaraguaia**, v. 6, n. 2, 2016. Disponível em: <https://periodicoscientificos.ufmt.br/ojs/index.php/geo/article/view/4901>. Acesso em: 05 jan. 2025.

SCODRO, Leonardo; CORSO, Leandro Luís. Previsão de preço de alimentos utilizando o método ARIMA e inteligência artificial. **Revista Produção Online**, v. 23, n. 1, p. 4869-4869, 2023. Disponível em: <https://www.producaoonline.org.br/rpo/article/view/4869>. Acesso em: 15 dez. 2024.

SICHMAN, Jaime Simão. Inteligência Artificial e sociedade: avanços e riscos. **Estudos Avançados**, v. 35, p. 37-50, 2021. Disponível em: <https://www.scielo.br/j/ea/a/c4sqqrthGMS3ngdBhGWtKhh/?format=html>. Acesso em: 06 dez. 2024.

SMYL, S. A Hybrid Method for Hierarchical Time Series Forecasting. **International Journal of Forecasting**, v. 36, n. 1, p. 75-92, 2020. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0169207019301153>. Acesso em: 04 dez. 2024.

SOUZA, Luan Vinícius et al. Análise dos efeitos do el niño no município de Aimorés (MG). **Anais do Seminário Científico do UNIFACIG**, n. 2, 2016. Disponível em: <https://pensaracademico.unifacig.edu.br/index.php/semiariocientifico/article/view/135>. Acesso em: 05 jan. 2025.

VAPNIK, V. **The nature of statistical learning theory**. Springer, 1995.

ZHANG, G.; EDDY PATUWO, B.; HU, M. Y. Forecasting with artificial neural networks: The state of the art. **International Journal of Forecasting**, v. 14, n. 1, 1998, p. 35-62. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0169207097000447>. Acesso em: 20 nov. 2024.

ANEXOS

Linguagem R

```
# 1. Selecionar o arquivo de dados manualmente
library(tidyverse)
library(forecast)
library(e1071)
library(randomForest)
library(ggpubr)
library(readxl)
library(zoo)
library(ggplot2)
library(tidyverse)
library(readxl)

# Solicitar ao usuário que escolha o arquivo
file_path <- file.choose()
print(paste("Arquivo selecionado:", file_path))

# 2. Carregar os dados do arquivo Excel corretamente
dados <- read_excel(file_path, sheet = "TOTAL")

# 3. Verificar os nomes das colunas
print("Nomes das colunas:")
print(colnames(dados))

# 4. Renomear colunas para evitar erros, se necessário
dados <- dados %>%
  rename(ANO_DE_REFERENCIA = "ANO DE REFERÊNCIA",
         REGIAO_GEOGRAFICA = "REGIÃO GEOGRÁFICA")
```

```
# 5. Carregar os dados do arquivo Excel corretamente
dados <- read_excel(file_path, sheet = "TOTAL")

# 6. Verificar os nomes das colunas
print("Nomes das colunas:")
print(colnames(dados))

# 7. Renomear colunas para evitar erros, se necessário
dados <- dados %>%
  rename(ANO_DE_REFERENCIA = "ANO DE REFERÊNCIA",
         REGIAO_GEOGRAFICA = "REGIÃO GEOGRÁFICA")

# 8. Transformar os dados para formato longo
dados_long <- dados %>%
  pivot_longer(cols = -c(ANO_DE_REFERENCIA, REGIAO_GEOGRAFICA),
               names_to = "Mês", values_to = "Consumo_MWh")

# 9. Converter os nomes dos meses para fator ordenado
meses_ordenados <- c("JANEIRO", "FEVEREIRO", "MARÇO", "ABRIL",
                     "MAIO", "JUNHO",
                     "JULHO", "AGOSTO", "SETEMBRO", "OUTUBRO",
                     "NOVEMBRO", "DEZEMBRO")

dados_long$Mês <- factor(dados_long$Mês, levels = meses_ordenados,
                        ordered = TRUE)

# 10. TRATAR VALORES AUSENTES (NAs)
print("Valores ausentes antes da correção:")
print(colSums(is.na(dados_long)))
```

```

# Método escolhido: Preencher NAs com a média
dados_long$Consumo_MWh[is.na(dados_long$Consumo_MWh)] <-
mean(dados_long$Consumo_MWh, na.rm = TRUE)

# Verificar novamente
print("Valores ausentes depois da correção:")
print(colSums(is.na(dados_long)))

# 11. Teste de Normalidade (Shapiro-Wilk)
shapiro_test <- shapiro.test(dados_long$Consumo_MWh)
print(shapiro_test)

# 12. Escolher o Teste Estatístico adequado
if (shapiro_test$p.value > 0.05) {
  print("Os dados seguem distribuição normal. Aplicando Teste t Pareado...")

  # Escolher apenas duas regiões para rodar o Teste t Pareado
  dados_t_test <- dados_long %>%
    filter(REGIAO_GEOGRAFICA %in% c("Sudeste", "Nordeste")) %>%
    spread(REGIAO_GEOGRAFICA, Consumo_MWh)

  if (all(c("Sudeste", "Nordeste") %in% colnames(dados_t_test))) {
    resultado_t <- t.test(dados_t_test$Sudeste, dados_t_test$Nordeste, paired =
TRUE)
    print(resultado_t)
  } else {
    print("Erro: Dados insuficientes para Teste t Pareado.")
  }

} else {

```

```

print("Os dados NÃO seguem distribuição normal.")

if (length(unique(dados_long$REGIAO_GEOGRAFICA)) > 2) {
  print("Mais de dois grupos detectados. Aplicando Teste de Kruskal-Wallis...")
  kruskal_test <- kruskal.test(Consumo_MWh ~ REGIAO_GEOGRAFICA, data
= dados_long)
  print(kruskal_test)
} else {
  print("Aplicando Teste de Wilcoxon para duas regiões específicas...")
  resultado_wilcox <- wilcox.test(Consumo_MWh ~ REGIAO_GEOGRAFICA,
data = dados_long)
  print(resultado_wilcox)
}
}

# 13. Criar Modelos Preditivos

# Separar dados para treinamento (80%) e teste (20%)
set.seed(123)
dados_treino <- dados_long %>% filter(ANO_DE_REFERENCIA < 2020)
dados_teste <- dados_long %>% filter(ANO_DE_REFERENCIA >= 2020)

# TRATAR NAs ANTES DO TREINAMENTO
print("Valores ausentes no conjunto de treino antes da correção:")
print(colSums(is.na(dados_treino)))

dados_treino$Consumo_MWh[is.na(dados_treino$Consumo_MWh)] <-
mean(dados_treino$Consumo_MWh, na.rm = TRUE)
dados_treino <- na.omit(dados_treino)

```

```
print("Valores ausentes no conjunto de treino depois da correção:")
print(colSums(is.na(dados_treino)))

# Modelo ARIMA para Séries Temporais
serie_temporal <- ts(dados_treino$Consumo_MWh, start =
min(dados_treino$ANO_DE_REFERENCIA), frequency = 12)
modelo_arima <- auto.arima(serie_temporal)
previsao_arima <- forecast(modelo_arima, h=nrow(dados_teste))

# Modelo SVM (Máquinas de Vetores de Suporte)
modelo_svm <- svm(Consumo_MWh ~ ., data = dados_treino, kernel = "radial")
previsao_svm <- predict(modelo_svm, newdata = dados_teste)

# Modelo Random Forest (Árvores de Decisão)
modelo_rf <- randomForest(Consumo_MWh ~ ., data = dados_treino, ntree =
100)
previsao_rf <- predict(modelo_rf, newdata = dados_teste)

# 14. Avaliação dos Modelos (RMSE e MAE)
# Verificar o tamanho das previsões
print(length(dados_teste$Consumo_MWh))
print(length(previsao_arima$mean))
print(length(previsao_svm))
print(length(previsao_rf))

# Ajustar o tamanho das previsões se necessário
previsao_arima <-
previsao_arima$mean[1:length(dados_teste$Consumo_MWh)]
previsao_svm <- previsao_svm[1:length(dados_teste$Consumo_MWh)]
previsao_rf <- previsao_rf[1:length(dados_teste$Consumo_MWh)]
```

```

# Funções de Erro
rmse <- function(real, previsto) sqrt(mean((real - previsto)^2, na.rm = TRUE))
mae <- function(real, previsto) mean(abs(real - previsto), na.rm = TRUE)

# Calcular os erros dos modelos
erros <- tibble(
  Modelo = c("ARIMA", "SVM", "Random Forest"),
  RMSE = c(rmse(dados_teste$Consumo_MWh, previsao_arima),
           rmse(dados_teste$Consumo_MWh, previsao_svm),
           rmse(dados_teste$Consumo_MWh, previsao_rf)),
  MAE = c(mae(dados_teste$Consumo_MWh, previsao_arima),
           mae(dados_teste$Consumo_MWh, previsao_svm),
           mae(dados_teste$Consumo_MWh, previsao_rf))
)

print(erros)

# 15. Gráfico de Consumo ao longo dos anos por Região
ggplot(dados_long, aes(x = ANO_DE_REFERENCIA, y = Consumo_MWh,
color = REGIAO_GEOGRAFICA)) +
  geom_line() +
  geom_point() +
  labs(title = "Evolução do Consumo de Energia Elétrica (2003-2023)", x =
"Ano", y = "Consumo (MWh)") +
  theme_minimal()

# Verificar se as colunas existem no dataframe
print(colnames(dados_futuros))

```

```
# Se a coluna 'Consumo_SVM' não existir, veja se o modelo gerou previsões
corretamente
```

```
if (!"Consumo_SVM" %in% colnames(dados_futuros)) {
  print("A coluna 'Consumo_SVM' não foi encontrada! Verificando previsão...")
}
```

```
# Gerar novamente a previsão SVM
```

```
dados_futuros$Consumo_SVM <- predict(modelo_svm, newdata =
dados_futuros)
```

```
# Exibir a estrutura corrigida
```

```
print(head(dados_futuros))
```

```
}
```

```
# 16. Comparação do Consumo Habitual vs. Consumo Previsto pelo Modelo
SVM
```

```
# Criar um dataframe para armazenar as previsões futuras
```

```
anos_futuros <- seq(max(dados_long$ANO_DE_REFERENCIA) + 1,
max(dados_long$ANO_DE_REFERENCIA) + 5)
```

```
dados_futuros <- data.frame(ANO_DE_REFERENCIA = rep(anos_futuros, each
= length(unique(dados_long$REGIAO_GEOGRAFICA))),
```

```
REGIAO_GEOGRAFICA =
rep(unique(dados_long$REGIAO_GEOGRAFICA), times =
length(anos_futuros)))
```

```
# Adicionar a variável 'Mês' ao dataframe de previsão
```

```
dados_futuros <- dados_futuros %>%
```

```
mutate(Mês = factor(rep(meses_ordenados, length.out =
nrow(dados_futuros)),
```

```
levels = meses_ordenados, ordered = TRUE))
```

```

# Prever com o modelo SVM

dados_futuros$Consumo_SVM <- predict(modelo_svm, newdata =
dados_futuros)

# Criar um cenário de consumo normal baseado na média histórica
consumo_normal <- dados_long %>%
  group_by(REGIAO_GEOGRAFICA, Mês) %>%
  summarise(Consumo_Normal = mean(Consumo_MWh, na.rm = TRUE),
.groups = 'drop')

dados_futuros <- left_join(dados_futuros, consumo_normal, by =
c("REGIAO_GEOGRAFICA", "Mês"))

# Identificar períodos de El Niño onde a previsão SVM diverge
significativamente do consumo habitual
dados_futuros <- dados_futuros %>%
  mutate(Efeito_El_Nino = ifelse(abs(Consumo_SVM - Consumo_Normal) /
Consumo_Normal > 0.1, "El Niño", "Normal"))

# Exibir comparativo de consumo habitual vs. consumo previsto
print("Comparação entre Consumo Habitual e Consumo Previsto pelo Modelo
SVM:")

print(dados_futuros)

# Gráfico Comparativo destacando o efeito El Niño

ggplot(dados_futuros, aes(x = ANO_DE_REFERENCIA, color =
REGIAO_GEOGRAFICA)) +
  geom_line(aes(y = Consumo_Normal, linetype = "Consumo Habitual"), size =
1) +
  geom_line(aes(y = Consumo_SVM, linetype = "Previsão SVM"), size = 1,
linetype = "dashed") +

```

```

geom_point(aes(y = Consumo_SVM, shape = Efeito_El_Nino), size = 3) +
scale_shape_manual(values = c("El Niño" = 17, "Habitual" = NA)) +
labs(title = "Comparação entre Consumo Habitual e Previsão pelo Modelo
SVM",
      subtitle = "Destaque para os períodos de impacto do El Niño",
      x = "Ano",
      y = "Consumo Previsto (MWh)",
      color = "Região Geográfica",
      linetype = "Modelo",
      shape = "Efeito El Niño") +
theme_minimal()

```

17. Distribuição do Consumo de Energia por Mês

```

# Criar o gráfico de boxplot
ggplot(dados_long, aes(x = Mês, y = Consumo_MWh, fill = Mês)) +
  geom_boxplot(outlier.colour = "black", outlier.shape = 16, outlier.size = 2,
alpha = 0.6) +
  labs(title = "Distribuição do Consumo de Energia por Mês",
        x = "Mês",
        y = "Consumo (MWh)") +
  theme_minimal() +
  theme(axis.text.x = element_text(angle = 45, hjust = 1))

```

18. Comparação do Consumo Habitual vs. Consumo Previsto pelo Modelo de Séries Temporais

```

# Criar um dataframe para armazenar as previsões futuras

```

```

anos_futuros <- seq(max(dados_long$ANO_DE_REFERENCIA) + 1,
max(dados_long$ANO_DE_REFERENCIA) + 5)

dados_futuros <- data.frame(ANO_DE_REFERENCIA = rep(anos_futuros, each
= length(unique(dados_long$REGIAO_GEOGRAFICA))),
                           REGIAO_GEOGRAFICA =
rep(unique(dados_long$REGIAO_GEOGRAFICA), times =
length(anos_futuros)))

# Adicionar a variável 'Mês' ao dataframe de previsão
dados_futuros <- dados_futuros %>%
  mutate(Mês = factor(rep(meses_ordenados, length.out =
nrow(dados_futuros)),
                      levels = meses_ordenados, ordered = TRUE))

# Prever com o modelo de Séries Temporais ARIMA
for (regiao in unique(dados_long$REGIAO_GEOGRAFICA)) {
  serie_temporal <-
ts(dados_long$Consumo_MWh[dados_long$REGIAO_GEOGRAFICA ==
regiao],
    start = min(dados_long$ANO_DE_REFERENCIA), frequency =
12)
  modelo_arima <- auto.arima(serie_temporal)
  previsao_arima_futuro <- forecast(modelo_arima, h=length(anos_futuros))
  dados_futuros$Consumo_ARIMA[dados_futuros$REGIAO_GEOGRAFICA ==
regiao] <- previsao_arima_futuro$mean
}

# Criar um cenário de consumo normal baseado na média histórica
consumo_normal <- dados_long %>%
  group_by(REGIAO_GEOGRAFICA, Mês) %>%
  summarise(Consumo_Normal = mean(Consumo_MWh, na.rm = TRUE),
            .groups = 'drop')

```

```

dados_futuros <- left_join(dados_futuros, consumo_normal, by =
c("REGIAO_GEOGRAFICA", "Mês"))

# Identificar períodos de El Niño onde a previsão ARIMA diverge
significativamente do consumo normal

dados_futuros <- dados_futuros %>%
  mutate(Efeito_El_Nino = ifelse(abs(Consumo_ARIMA - Consumo_Normal) /
Consumo_Normal > 0.1, "El Niño", "Habitual"))

# Exibir comparativo de consumo habitual vs. consumo previsto

print("Comparação entre Consumo Habitual e Consumo Previsto pelo Modelo
de Séries Temporais:")

print(dados_futuros)

# Gráfico Comparativo destacando o efeito El Niño

ggplot(dados_futuros, aes(x = ANO_DE_REFERENCIA, color =
REGIAO_GEOGRAFICA)) +
  geom_line(aes(y = Consumo_Normal, linetype = "Consumo Habitual"), size =
1) +
  geom_line(aes(y = Consumo_ARIMA, linetype = "Previsão ARIMA"), size = 1,
linetype = "dashed") +
  geom_point(aes(y = Consumo_ARIMA, shape = Efeito_El_Nino), size = 3) +
  scale_shape_manual(values = c("El Niño" = 17, "Habitual" = NA)) +
  labs(title = "Comparação entre Consumo Habitual e Previsão pelo Modelo de
Séries Temporais",
       subtitle = "Destaque para os períodos de impacto do El Niño",
       x = "Ano",
       y = "Consumo Previsto (MWh)",
       color = "Região Geográfica",
       linetype = "Modelo",
       shape = "Efeito El Niño") +
  theme_minimal()

```

19. Comparação do Consumo Normal vs. Consumo Previsto pelo Modelo Random Forest

Criar um dataframe para armazenar as previsões futuras

```
anos_futuros <- seq(max(dados_long$ANO_DE_REFERENCIA) + 1,
max(dados_long$ANO_DE_REFERENCIA) + 5)

dados_futuros <- data.frame(ANO_DE_REFERENCIA = rep(anos_futuros, each
= length(unique(dados_long$REGIAO_GEOGRAFICA))),
                           REGIAO_GEOGRAFICA =
rep(unique(dados_long$REGIAO_GEOGRAFICA), times =
length(anos_futuros)))
```

Adicionar a variável 'Mês' ao dataframe de previsão

```
dados_futuros <- dados_futuros %>%
  mutate(Mês = factor(rep(meses_ordenados, length.out =
nrow(dados_futuros)),
                      levels = meses_ordenados, ordered = TRUE))
```

Prever com o modelo Random Forest

```
dados_futuros$Consumo_RandomForest <- predict(modelo_rf, newdata =
dados_futuros)
```

Criar um cenário de consumo habitual baseado na média histórica

```
consumo_normal <- dados_long %>%
  group_by(REGIAO_GEOGRAFICA, Mês) %>%
  summarise(Consumo_Normal = mean(Consumo_MWh, na.rm = TRUE),
            .groups = 'drop')

dados_futuros <- left_join(dados_futuros, consumo_normal, by =
c("REGIAO_GEOGRAFICA", "Mês"))
```

```

# Identificar períodos de El Niño onde a previsão Random Forest diverge
significativamente do consumo habitual

dados_futuros <- dados_futuros %>%

  mutate(Efeito_El_Nino = ifelse(abs(Consumo_RandomForest -
Consumo_Normal) / Consumo_Normal > 0.1, "El Niño", "Normal"))

# Exibir comparativo de consumo habitual vs. consumo previsto

print("Comparação entre Consumo Habitual e Consumo Previsto pelo Modelo
Random Forest:")

print(dados_futuros)

# Gráfico Comparativo destacando o efeito El Niño

ggplot(dados_futuros, aes(x = ANO_DE_REFERENCIA, color =
REGIAO_GEOGRAFICA)) +

  geom_line(aes(y = Consumo_Normal, linetype = "Consumo Habitual"), size =
1) +

  geom_line(aes(y = Consumo_RandomForest, linetype = "Previsão Random
Forest"), size = 1, linetype = "dashed") +

  geom_point(aes(y = Consumo_RandomForest, shape = Efeito_El_Nino), size
= 3) +

  scale_shape_manual(values = c("El Niño" = 17, "Habitual" = NA)) +

  labs(title = "Comparação entre Consumo Habitual e Previsão pelo Modelo
Random Forest",

       subtitle = "Destaque para os períodos de impacto do El Niño",

       x = "Ano",

       y = "Consumo Previsto (MWh)",

       color = "Região Geográfica",

       linetype = "Modelo",

       shape = "Efeito El Niño") +

  theme_minimal()

```

20. Comparação entre Modelos Preditivos para os Próximos 5 Anos,
Destacando o Efeito El Niño

Criar um dataframe para armazenar as previsões futuras

```
anos_futuros <- seq(2024, 2028)
```

```
dados_futuros <- data.frame(ANO_DE_REFERENCIA = anos_futuros)
```

Criar o dataframe consumo_geral somando o consumo total por ano

```
consumo_geral <- dados_long %>%
```

```
  group_by(ANO_DE_REFERENCIA) %>%
```

```
  summarise(Consumo_Total = sum(Consumo_MWh, na.rm = TRUE))
```

Definir a frequência da série temporal

```
data_frequency <-
```

```
ifelse(n_distinct(diff(consumo_geral$ANO_DE_REFERENCIA)) > 1, 1, 12)
```

Identificar anos com impacto do El Niño

```
anos_impacto <- c(2025, 2027) # Exemplo de anos que podem ter impacto  
significativo
```

Prever com o modelo de Séries Temporais (ARIMA)

```
serie_temporal <- ts(consumo_geral$Consumo_Total, start =  
min(consumo_geral$ANO_DE_REFERENCIA), frequency = data_frequency)
```

```
modelo_arima <- auto.arima(serie_temporal, stepwise = FALSE, approximation  
= FALSE)
```

```
previsao_arima <- forecast(modelo_arima, h=length(anos_futuros))
```

```
dados_futuros$Consumo_Arima <- previsao_arima$mean
```

Prever com o modelo de Máquinas de Vetores de Suporte (SVM)

```
modelo_svm <- svm(Consumo_Total ~ ANO_DE_REFERENCIA, data =  
consumo_geral, kernel = "radial")
```

```

dados_futuros$Consumo_SVM <- predict(modelo_svm, newdata =
dados_futuros)

# Prever com o modelo Baseado em Árvores de Decisão (Random Forest)
modelo_rf <- randomForest(Consumo_Total ~ ANO_DE_REFERENCIA, data =
consumo_geral, ntree = 100)
dados_futuros$Consumo_DecisionTree <- predict(modelo_rf, newdata =
dados_futuros)

# Exibir previsões comparando apenas os modelos preditivos, destacando anos
de impacto do El Niño

ggplot(dados_futuros, aes(x = ANO_DE_REFERENCIA)) +
  geom_line(aes(y = Consumo_Arima, color = "Previsão ARIMA"), size = 1,
linetype = "dashed") +
  geom_line(aes(y = Consumo_SVM, color = "Previsão SVM"), size = 1, linetype
= "dotted") +
  geom_line(aes(y = Consumo_DecisionTree, color = "Previsão Decision
Trees"), size = 1, linetype = "dotdash") +
  geom_point(data = dados_futuros %>% filter(ANO_DE_REFERENCIA %in%
anos_impacto),
  aes(x = ANO_DE_REFERENCIA, y = Consumo_Arima, color =
"Impacto ARIMA"), shape = 17, size = 3) +
  geom_point(data = dados_futuros %>% filter(ANO_DE_REFERENCIA %in%
anos_impacto),
  aes(x = ANO_DE_REFERENCIA, y = Consumo_SVM, color = "Impacto
SVM"), shape = 17, size = 3) +
  geom_point(data = dados_futuros %>% filter(ANO_DE_REFERENCIA %in%
anos_impacto),
  aes(x = ANO_DE_REFERENCIA, y = Consumo_DecisionTree, color =
"Impacto Decision Trees"), shape = 17, size = 3) +
  labs(title = "Comparação entre Modelos Preditivos para 2024-2028
Destacando o Impacto do El Niño",
  x = "Ano",
  y = "Consumo Total (MWh)",

```

```

    color = "Legenda") +
  theme_minimal()

```

21. Comparação entre Modelos Preditivos para os Próximos 5 Anos, Destacando o Efeito El Niño e Consumo Normal

Criar um dataframe para armazenar as previsões futuras

```
anos_futuros <- seq(2024, 2028)
```

```
dados_futuros <- data.frame(ANO_DE_REFERENCIA = anos_futuros)
```

Criar o dataframe consumo_geral somando o consumo total por ano

```
consumo_geral <- dados_long %>%
```

```
  group_by(ANO_DE_REFERENCIA) %>%
```

```
  summarise(Consumo_Total = sum(Consumo_MWh, na.rm = TRUE))
```

Definir a frequência da série temporal

```
data_frequency <-
```

```
ifelse(n_distinct(diff(consumo_geral$ANO_DE_REFERENCIA)) > 1, 1, 12)
```

Identificar anos com impacto do El Niño

```
anos_impacto <- c(2025, 2027) # Exemplo de anos que podem ter impacto significativo
```

Calcular o consumo normal utilizando Suavização Exponencial Simples (SES) para capturar tendências

```
modelo_ses <- ses(ts(consumo_geral$Consumo_Total, start =
```

```
min(consumo_geral$ANO_DE_REFERENCIA), frequency = data_frequency), h = length(anos_futuros))
```

```
dados_futuros$Consumo_Normal <- modelo_ses$mean
```

```

# Prever com o modelo de Séries Temporais (ARIMA)

serie_temporal <- ts(consumo_geral$Consumo_Total, start =
min(consumo_geral$ANO_DE_REFERENCIA), frequency = data_frequency)

modelo_arima <- auto.arima(serie_temporal, stepwise = FALSE, approximation
= FALSE)

previsao_arima <- forecast(modelo_arima, h=length(anos_futuros))

dados_futuros$Consumo_Arima <- previsao_arima$mean


# Prever com o modelo de Máquinas de Vetores de Suporte (SVM)

modelo_svm <- svm(Consumo_Total ~ ANO_DE_REFERENCIA, data =
consumo_geral, kernel = "radial")

dados_futuros$Consumo_SVM <- predict(modelo_svm, newdata =
dados_futuros)


# Prever com o modelo Baseado em Árvores de Decisão (Random Forest)

modelo_rf <- randomForest(Consumo_Total ~ ANO_DE_REFERENCIA, data =
consumo_geral, ntree = 100)

dados_futuros$Consumo_DecisionTree <- predict(modelo_rf, newdata =
dados_futuros)


# Exibir previsões comparando apenas os modelos preditivos, destacando anos
de impacto do El Niño e adicionando Consumo Habitual

ggplot(dados_futuros, aes(x = ANO_DE_REFERENCIA)) +
  geom_line(aes(y = Consumo_Normal, color = "Consumo Habitual"), size = 1)
+
  geom_line(aes(y = Consumo_Arima, color = "Previsão ARIMA"), size = 1,
linetype = "dashed") +
  geom_line(aes(y = Consumo_SVM, color = "Previsão SVM"), size = 1, linetype
= "dotted") +
  geom_line(aes(y = Consumo_DecisionTree, color = "Previsão Decision
Trees"), size = 1, linetype = "dotdash") +
  geom_point(data = dados_futuros %>% filter(ANO_DE_REFERENCIA %in%
anos_impacto),

```

```

aes(x = ANO_DE_REFERENCIA, y = Consumo_Arima, color =
"Impacto ARIMA"), shape = 17, size = 3) +

geom_point(data = dados_futuros %>% filter(ANO_DE_REFERENCIA %in%
anos_impacto),

aes(x = ANO_DE_REFERENCIA, y = Consumo_SVM, color = "Impacto
SVM"), shape = 17, size = 3) +

geom_point(data = dados_futuros %>% filter(ANO_DE_REFERENCIA %in%
anos_impacto),

aes(x = ANO_DE_REFERENCIA, y = Consumo_DecisionTree, color =
"Impacto Decision Trees"), shape = 17, size = 3) +

labs(title = "Comparação entre Modelos Preditivos para 2024-2028
Destacando o Impacto do El Niño e Consumo Habitual",

x = "Ano",

y = "Consumo Total (MWh)",

color = "Legenda") +

theme_minimal()

```

APÊNDICE

Os dados utilizados neste estudo foram obtidos no site da Empresa de Pesquisa Energética (EPE),² órgão vinculado ao Ministério de Minas e Energia do Brasil, responsável pela coleta e divulgação de estatísticas sobre o setor energético nacional. A base de dados contempla informações detalhadas sobre o consumo de energia elétrica no Brasil, permitindo a análise de tendências históricas e a modelagem preditiva do consumo futuro.

A série temporal analisada compreende o período de 2004 a 2023, abrangendo ciclos econômicos e variações no consumo energético ao longo dos anos. Esse intervalo foi escolhido devido à sua disponibilidade no início desta pesquisa e à necessidade de uma base de dados suficientemente extensa para garantir previsões estatisticamente confiáveis. Embora informações referentes ao ano de 2024 já estivessem disponíveis, optou-se por não as incluir para manter a coerência da base histórica utilizada na pesquisa.

Para a modelagem preditiva, utilizou-se exclusivamente o histórico de consumo de energia elétrica, considerando a variável “Consumo Total de Energia (MWh)”, a qual representa a quantidade total de eletricidade consumida mensalmente no Brasil. Esses dados foram fundamentais para o treinamento e avaliação dos modelos de previsão implementados neste estudo. Segue a tabela formulada através dos dados extraídos do site.

² Cf. EMPRESA DE PESQUISA ENERGÉTICA. Disponível em: <https://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/consumo-de-energia-eletrica>. Acesso em: 27 nov. 2024.

ANO DE REFERÊNCIA	REGIÃO GEOGRÁFICA	JANEIRO	FEVEREIRO	MARÇO	ABRIL	MAIO	JUNHO	JULHO	AGOSTO	SETEMBRO	OUTUBRO	NOVEMBRO	DEZEMBRO
2023	Norte	3.179.191	2.963.028	3.328.358	3.214.011	3.392.976	3.374.046	3.424.461	3.598.417	3.685.256	3.708.598	3.622.795	3.548.012
2023	Nordeste	7.649.099	7.491.621	7.855.653	7.849.403	7.919.798	7.696.280	7.452.017	7.717.962	8.053.795	8.181.552	8.495.447	8.475.584
2023	Sudeste	20.422.809	20.584.858	22.140.643	21.551.007	20.490.741	20.385.883	20.046.684	20.721.847	21.131.102	22.058.031	22.241.366	22.845.977
2023	Sul	8.316.139	8.622.232	8.957.674	8.637.518	7.874.384	7.704.283	7.712.281	7.793.263	7.815.574	8.035.205	8.032.454	8.356.239
2023	Centro-Oeste	3.246.899	3.236.306	3.431.350	3.469.085	3.506.915	3.363.226	3.262.082	3.524.129	3.721.163	3.936.944	4.014.761	3.944.219
2023	Sistemas Isolados	237.204	224.614	250.366	247.859	250.320	232.274	230.379	254.623	269.878	272.843	267.375	251.926
2023	Norte	3.571.001	3.364.943	3.756.769	3.658.729	3.880.006	3.845.737	3.943.641	4.073.194	4.120.425	4.215.751	4.121.646	4.101.521
2023	Nordeste	6.659.377	6.523.348	6.789.724	6.792.133	6.790.259	6.603.136	6.324.981	6.564.407	6.904.764	6.964.856	7.280.393	7.234.279
2023	Sudeste/C.Oeste	24.030.416	24.162.909	25.959.145	25.384.785	24.389.844	24.138.288	23.686.243	24.670.131	25.296.248	26.431.675	26.704.955	27.226.067
2023	Sul	8.316.139	8.622.232	8.957.674	8.637.518	7.874.384	7.704.283	7.712.281	7.793.263	7.815.574	8.035.205	8.032.454	8.356.239
2022	Norte	3.033.708	2.774.943	3.003.596	2.935.306	3.100.011	3.120.578	3.254.761	3.419.567	3.380.310	3.421.210	3.344.484	3.309.421
2022	Nordeste	7.269.935	6.998.206	7.459.577	7.240.388	7.269.432	7.021.728	7.104.761	7.297.981	7.422.700	7.644.765	7.770.458	7.692.127
2022	Sudeste	20.474.247	20.328.123	22.068.130	21.718.100	20.788.847	19.924.575	19.948.621	20.409.125	20.410.074	20.496.295	20.581.356	20.763.406
2022	Sul	8.500.828	8.547.848	8.768.560	7.909.914	7.536.736	7.594.186	7.629.543	7.645.256	7.536.752	7.417.894	7.584.502	8.011.391
2022	Centro-Oeste	3.254.144	3.201.552	3.372.490	3.407.133	3.354.987	3.277.801	3.294.887	3.400.608	3.527.730	3.505.864	3.505.813	3.453.736
2022	Sistemas Isolados	235.892	229.193	239.586	233.429	233.329	228.368	235.000	257.739	259.051	267.114	256.722	243.198
2022	Norte	3.105.646	2.838.039	3.073.501	2.998.603	3.215.176	3.272.582	3.433.865	3.652.620	3.647.860	3.720.511	3.695.918	3.700.136
2022	Nordeste	6.607.898	6.381.377	6.791.966	6.591.470	6.545.708	6.289.142	6.319.253	6.414.405	6.500.121	6.674.237	6.779.200	6.658.218
2022	Sudeste/C.Oeste	24.082.598	23.854.215	25.798.740	25.477.424	24.519.064	23.554.589	23.614.913	24.202.518	24.333.783	24.406.272	24.470.272	24.617.138
2022	Sul	8.500.828	8.547.848	8.768.560	7.909.914	7.536.736	7.594.186	7.629.543	7.645.256	7.536.752	7.417.894	7.584.502	8.011.391
2021	Norte	2.873.241	2.756.767	2.891.451	2.986.818	3.053.069	3.043.949	3.034.193	3.144.878	3.172.368	3.201.778	3.161.073	3.159.175
2021	Nordeste	7.419.803	7.043.661	7.244.997	7.205.498	6.974.430	6.994.342	6.994.258	7.110.502	7.190.596	7.540.206	7.484.406	7.714.748
2021	Sudeste	21.497.695	20.562.263	21.988.991	21.061.907	19.953.595	19.751.841	19.528.232	19.800.844	20.664.260	20.795.884	20.237.021	20.723.920
2021	Sul	8.117.258	7.972.092	8.257.890	8.114.934	7.579.902	7.330.463	7.472.284	7.611.805	7.349.094	7.447.106	7.611.454	7.896.309
2021	Centro-Oeste	3.185.331	3.172.280	3.278.122	3.288.285	3.223.643	3.308.328	3.161.535	3.239.988	3.576.234	3.611.676	3.375.322	3.421.799
2021	Sistemas Isolados	237.650	229.734	230.447	250.318	241.255	230.634	227.645	240.727	262.271	261.891	255.819	249.263
2021	Norte	2.969.159	2.836.646	2.973.993	3.037.187	3.121.817	3.140.880	3.186.793	3.265.815	3.277.932	3.305.404	3.283.431	3.291.787
2021	Nordeste	6.777.095	6.429.620	6.628.741	6.580.056	6.338.504	6.331.917	6.296.865	6.398.043	6.451.708	6.790.720	6.749.533	6.975.130
2021	Sudeste/C.Oeste	24.992.166	24.038.971	25.570.380	24.674.947	23.503.160	23.395.029	23.006.915	23.391.625	24.611.547	24.791.530	23.969.038	24.503.463
2021	Sul	8.117.258	7.972.092	8.257.890	8.114.934	7.579.902	7.330.463	7.472.284	7.611.805	7.349.094	7.447.106	7.611.454	7.896.309
2020	Norte	2.894.526	2.836.047	2.815.284	2.629.850	2.656.714	2.708.916	2.898.335	3.035.361	3.085.360	3.160.122	3.007.704	2.991.752
2020	Nordeste	7.122.375	6.808.203	6.929.932	6.362.705	6.356.709	6.234.574	6.529.700	6.521.734	6.823.175	7.365.126	7.009.816	7.105.679
2020	Sudeste	20.157.502	19.994.440	20.221.091	18.064.680	17.378.115	17.315.901	18.381.116	19.324.707	19.785.077	21.224.407	20.377.363	20.807.481
2020	Sul	7.980.476	8.120.196	7.950.414	7.081.307	6.672.170	6.566.360	6.979.431	7.110.004	7.263.503	7.519.421	7.616.851	7.842.894
2020	Centro-Oeste	3.174.327	3.205.252	3.221.899	3.125.511	3.060.527	2.943.299	3.080.717	3.250.420	3.395.254	3.654.538	3.418.960	3.413.597
2020	Sistemas Isolados	244.792	242.321	258.421	243.519	226.173	226.718	239.861	248.232	264.520	271.478	265.767	265.633
2020	Norte	2.938.356	2.838.344	2.826.208	2.672.450	2.730.799	2.826.972	2.991.221	3.103.326	3.125.072	3.237.951	3.085.089	3.031.145
2020	Nordeste	6.518.270	6.226.032	6.336.125	5.766.810	5.748.623	5.594.620	5.877.721	5.860.123	6.144.747	6.637.922	6.308.776	6.415.198
2020	Sudeste/C.Oeste	23.647.312	23.537.245	23.767.453	21.499.967	20.746.470	20.554.380	21.781.065	22.920.541	23.554.528	25.256.842	24.154.212	24.606.533
2020	Sul	7.980.476	8.120.196	7.950.414	7.081.307	6.672.170	6.566.360	6.979.431	7.110.004	7.263.503	7.519.421	7.616.851	7.842.894
2019	Norte	2.563.184	2.421.379	2.600.591	2.567.809	2.688.743	2.719.684	2.820.493	2.881.216	2.938.026	2.965.331	2.925.432	2.994.753
2019	Nordeste	6.965.521	6.820.975	7.049.578	6.773.402	7.055.062	6.624.438	6.672.154	6.545.284	6.633.387	7.138.364	7.323.640	7.536.744
2019	Sudeste	20.965.938	20.584.521	20.626.330	19.827.659	20.187.003	18.980.780	18.699.588	18.900.145	19.292.022	20.170.884	20.623.039	19.593.151
2019	Sul	8.000.635	8.131.096	7.767.428	7.470.886	7.374.881	7.058.334	7.081.185	7.169.974	7.031.953	7.346.734	7.520.830	7.467.002
2019	Centro-Oeste	3.151.911	3.206.029	3.104.065	3.083.639	3.174.962	3.057.549	3.072.499	3.144.928	3.366.802	3.446.465	3.399.533	3.210.248
2019	Sistemas Isolados	235.374	223.485	244.515	253.060	243.778	227.972	238.645	234.551	248.732	264.261	251.565	248.470
2019	Norte	2.601.234	2.473.879	2.634.746	2.576.790	2.739.375	2.803.120	2.883.806	2.970.444	2.986.743	3.033.103	3.022.024	3.103.353
2019	Nordeste	6.382.005	6.247.356	6.466.787	6.199.701	6.441.791	6.001.112	6.040.693	5.897.532	5.971.396	6.471.428	6.644.637	6.840.622
2019	Sudeste/C.Oeste	24.427.941	24.088.184	24.034.515	23.222.958	23.680.825	22.350.247	22.101.589	22.369.044	23.023.366	23.952.252	24.353.417	23.142.450
2019	Sul	8.000.635	8.131.096	7.767.428	7.470.886	7.374.881	7.058.334	7.081.185	7.169.974	7.031.953	7.346.734	7.520.830	7.467.002
2018	Norte	2.812.898	2.650.539	2.868.574	2.679.314	2.666.895	2.583.924	2.658.452	2.688.994	2.689.093	2.828.459	2.723.638	2.585.260
2018	Nordeste	6.715.170	6.352.263	6.581.659	6.665.546	6.655.929	6.596.568	6.520.394	6.687.898	6.636.681	7.053.458	7.184.242	6.848.865
2018	Sudeste	20.078.364	19.689.600	20.852.953	20.732.786	19.736.424	19.179.160	19.272.779	19.378.187	19.599.718	20.110.169	20.154.429	20.021.515
2018	Sul	7.526.624	7.571.527	7.771.959	7.527.392	7.190.267	6.900.873	7.049.956	7.141.588	6.955.336	7.087.255	7.173.508	7.276.983
2018	Centro-Oeste	2.921.618	2.905.102	3.031.726	3.089.967	3.013.784	2.942.775	3.006.576	3.152.209	3.158.158	3.314.445	3.171.851	3.142.225
2018	Sistemas Isolados	231.785	230.774	238.314	244.509	235.248	231.225	231.825	249.042	245.815	272.863	265.657	235.615
2018	Norte	2.852.964	2.651.457	2.892.971	2.696.785	2.692.115	2.654.733	2.717.587	2.740.023	2.752.253	2.854.447	2.771.254	2.662.331
2018	Nordeste	6.148.176	5.830.843	6.020.333	6.103.823	6.084.050	6.008.233	5.922.473	6.065.236	6.015.347	6.404.249	6.537.616	6.240.489
2018	Sudeste/C.Oeste	23.295.126	22.884.429	24.183.293	24.122.497	23.061.619	22.408.235	22.586.316	22.852.986	23.070.236	23.774.972	23.659.633	23.459.430
2018	Sul	7.526.624	7.571.527	7.771.959	7.527.392	7.190.267	6.900.873	7.049.956	7.141.588	6.955.336	7.087.255	7.173.508	7.276.983

2017	Norte	2.768.205	2.552.629	2.795.464	2.721.049	2.934.453	2.891.844	2.882.108	3.041.036	2.992.579	3.047.409	2.965.901	2.917.594
2017	Nordeste	6.706.105	6.341.434	6.789.018	6.561.331	6.672.438	6.591.858	6.381.978	6.503.729	6.504.408	6.870.831	6.905.448	6.902.678
2017	Sudeste	19.686.157	19.583.907	20.172.691	19.877.597	18.885.259	18.859.514	18.492.332	18.501.817	19.349.466	19.442.583	19.915.401	19.748.006
2017	Sul	7.307.446	7.520.746	7.845.156	7.275.840	6.691.196	6.804.976	6.751.139	6.880.099	6.981.238	6.878.050	6.932.668	7.128.628
2017	Centro-Oeste	2.901.250	2.837.672	2.943.265	2.994.615	2.971.340	2.966.073	2.872.706	2.939.048	3.181.236	3.097.398	3.107.470	2.909.220
2017	Sistemas Isolados	234.746	219.581	235.207	227.399	236.395	234.445	229.246	251.033	254.237	259.045	262.710	249.416
2017	Norte	2.784.587	2.571.580	2.805.848	2.747.525	2.929.563	2.911.329	2.912.557	3.057.710	3.026.709	3.096.417	3.011.669	2.987.088
2017	Nordeste	6.170.646	5.830.848	6.249.547	6.023.097	6.127.562	6.031.791	5.823.454	5.903.147	5.878.477	6.226.788	6.269.809	6.273.976
2017	Sudeste/C.Oeste	22.871.738	22.693.633	23.409.836	23.156.571	22.169.970	22.131.724	21.663.867	21.773.740	22.868.266	22.875.971	23.350.032	22.967.018
2017	Sul	7.307.446	7.520.746	7.845.156	7.275.840	6.691.196	6.804.976	6.751.139	6.880.099	6.981.238	6.878.050	6.932.668	7.128.628
2016	Norte	2.734.717	2.708.799	2.863.718	2.727.271	2.862.447	2.818.826	2.900.857	2.932.615	2.919.161	2.946.530	2.953.991	2.896.559
2016	Nordeste	6.534.573	6.277.837	6.792.209	6.608.879	6.721.518	6.596.045	6.463.676	6.518.965	6.623.804	6.681.298	6.818.249	6.864.369
2016	Sudeste	19.314.001	19.495.060	19.611.354	20.520.225	19.303.127	18.651.589	18.388.987	18.711.602	19.239.375	19.147.568	19.361.478	19.268.369
2016	Sul	6.978.391	7.406.978	7.259.988	7.326.166	6.859.487	6.644.136	6.665.440	6.609.797	6.587.724	6.452.385	6.690.298	6.944.869
2016	Centro-Oeste	2.839.219	2.838.664	2.917.647	3.086.879	2.902.094	2.839.814	2.836.281	2.920.955	2.974.997	2.970.061	2.930.233	2.806.629
2016	Sistemas Isolados	242.029	243.642	252.453	242.473	231.265	234.959	230.566	260.542	252.657	252.358	253.797	242.865
2016	Norte	2.738.088	2.710.419	2.862.575	2.749.857	2.907.970	2.866.943	2.945.013	2.930.266	2.987.174	2.976.023	3.004.283	2.947.041
2016	Nordeste	6.005.098	5.746.231	6.239.582	6.050.518	6.155.240	6.031.101	5.901.487	5.949.572	6.007.452	6.094.407	6.207.681	6.273.573
2016	Sudeste/C.Oeste	22.437.295	22.620.068	22.830.317	23.900.406	22.494.711	21.773.271	21.512.735	21.943.757	22.510.054	22.422.669	22.598.190	22.372.447
2016	Sul	6.978.391	7.406.978	7.259.988	7.326.166	6.859.487	6.644.136	6.665.440	6.609.797	6.587.724	6.452.385	6.690.298	6.944.869
2015	Norte	2.720.658	2.565.453	2.709.350	2.646.878	2.718.412	2.693.038	2.833.640	2.891.977	2.964.444	3.050.012	2.958.108	2.962.634
2015	Nordeste	6.905.457	6.689.282	6.841.732	6.671.253	6.653.756	6.435.715	6.215.489	6.333.882	6.385.463	6.634.596	6.654.706	6.792.624
2015	Sudeste	20.943.263	20.869.827	20.150.053	20.215.138	19.296.452	18.752.591	18.532.921	19.084.994	18.919.408	19.814.546	19.836.832	19.359.382
2015	Sul	7.330.738	7.665.269	7.278.854	7.236.052	6.683.610	6.567.886	6.446.540	6.648.544	6.494.009	6.561.339	6.636.696	6.604.791
2015	Centro-Oeste	2.857.851	2.929.435	2.778.975	2.827.350	2.850.132	2.814.436	2.787.852	2.899.288	3.078.326	3.216.173	3.138.514	2.950.529
2015	Sistemas Isolados	328.634	304.534	318.361	317.739	312.272	228.746	233.863	244.334	258.600	283.114	263.477	252.893
2015	Norte	2.791.082	2.641.733	2.794.295	2.621.255	2.645.231	2.705.048	2.837.312	2.907.368	2.956.987	3.026.397	2.954.707	2.972.897
2015	Nordeste	6.222.269	6.040.031	6.154.033	6.088.618	6.133.183	5.902.293	5.687.260	5.771.891	5.811.515	6.052.106	6.082.628	6.215.136
2015	Sudeste/C.Oeste	24.085.244	24.067.699	23.213.421	23.333.007	22.428.066	21.859.692	21.611.468	22.286.548	22.320.539	23.353.710	23.287.348	22.624.243
2015	Sul	7.330.738	7.665.269	7.278.854	7.236.052	6.683.610	6.567.886	6.446.540	6.648.544	6.494.009	6.561.339	6.636.696	6.604.791
2014	Norte	2.600.972	2.476.973	2.612.667	2.601.327	2.707.327	2.643.397	2.821.879	2.657.952	2.836.892	2.825.876	2.762.256	2.816.133
2014	Nordeste	6.886.428	6.620.899	6.857.552	6.683.649	6.683.419	6.378.158	6.554.674	6.652.720	6.721.395	6.929.491	6.919.617	6.859.202
2014	Sudeste	20.704.340	21.763.013	20.782.600	20.451.575	20.068.194	19.293.127	19.111.350	19.438.306	19.529.007	20.304.956	20.968.110	20.098.588
2014	Sul	7.333.087	8.019.594	7.281.924	7.007.480	6.794.930	6.627.215	6.639.960	6.872.774	6.787.415	6.922.704	7.264.836	7.266.585
2014	Centro-Oeste	2.754.932	2.773.008	2.734.686	2.847.823	2.846.629	2.784.576	2.738.946	2.928.942	3.020.267	3.117.414	3.035.907	2.797.799
2014	Sistemas Isolados	308.956	283.510	292.087	299.226	305.901	302.528	305.209	313.142	340.352	344.356	339.035	335.079
2014	Norte	2.853.260	2.697.765	2.857.495	2.753.788	2.779.906	2.709.597	2.901.748	2.771.867	2.876.693	2.883.384	2.833.011	2.868.330
2014	Nordeste	6.038.656	5.844.373	6.042.578	5.943.838	6.018.103	5.721.917	5.888.798	5.928.875	6.018.843	6.209.140	6.208.638	6.168.145
2014	Sudeste/C.Oeste	23.745.800	24.808.245	23.795.345	23.587.522	23.201.659	22.365.216	22.131.094	22.664.036	22.871.673	23.740.857	24.305.206	23.200.168
2014	Sul	7.333.087	8.019.594	7.281.924	7.007.480	6.794.930	6.627.215	6.639.960	6.872.774	6.787.415	6.922.704	7.264.836	7.266.585
2013	Norte	2.392.453	2.266.206	2.378.192	2.461.104	2.454.164	2.449.533	2.562.520	2.559.396	2.571.187	2.720.586	2.641.606	2.738.735
2013	Nordeste	6.659.728	6.452.494	6.705.944	6.852.552	6.660.227	6.384.530	6.534.919	6.580.762	6.536.720	6.832.552	6.759.701	6.733.760
2013	Sudeste	20.089.886	19.775.484	19.907.218	20.097.448	19.911.821	19.652.655	19.331.509	19.838.087	20.027.335	20.325.563	20.765.973	20.381.824
2013	Sul	6.617.103	6.952.735	6.833.953	6.572.123	6.613.672	6.498.366	6.544.154	6.797.218	6.572.961	6.654.874	6.849.526	6.885.986
2013	Centro-Oeste	2.607.640	2.558.733	2.616.885	2.670.436	2.704.978	2.642.614	2.724.843	2.837.813	2.816.521	2.855.429	2.903.484	2.816.073
2013	Sistemas Isolados	651.988	627.052	638.423	675.977	672.806	688.200	287.311	289.566	303.953	317.941	318.537	311.346
2013	Norte	2.432.546	2.282.245	2.438.608	2.442.681	2.441.501	2.410.278	2.940.174	2.973.453	2.876.875	2.992.731	2.892.566	2.961.111
2013	Nordeste	5.712.701	5.562.227	5.752.104	5.926.994	5.721.609	5.465.976	5.581.384	5.608.228	5.632.880	5.936.067	5.898.490	5.881.281
2013	Sudeste/C.Oeste	22.952.472	22.581.393	22.779.104	23.035.888	22.895.274	22.564.878	22.344.922	22.944.811	23.138.055	23.487.391	23.961.171	23.516.654
2013	Sul	6.617.103	6.952.735	6.833.953	6.572.123	6.613.672	6.498.366	6.544.154	6.797.218	6.572.961	6.654.874	6.849.526	6.885.986
2012	Norte	2.368.905	2.321.772	2.439.658	2.361.905	2.430.160	2.382.274	2.397.648	2.490.521	2.455.692	2.505.782	2.484.062	2.410.373
2012	Nordeste	6.297.828	6.010.436	6.407.753	6.271.553	6.436.375	6.135.291	6.111.808	6.323.564	6.288.243	6.427.697	6.421.108	6.478.746
2012	Sudeste	18.915.418	19.339.928	20.230.842	20.295.686	19.244.538	19.343.073	18.762.191	19.393.131	19.904.342	19.837.975	20.485.581	19.506.176
2012	Sul	6.353.277	6.812.782	7.026.116	6.534.981	6.141.747	6.180.121	6.188.904	6.391.481	6.340.229	6.251.818	6.543.892	6.725.279
2012	Centro-Oeste	2.369.739	2.415.613	2.518.741	2.531.744	2.557.371	2.487.634	2.456.596	2.580.906	2.673.190	2.772.742	2.708.942	2.644.510
2012	Sistemas Isolados	605.432	642.267	625.665	618.898	626.248	640.553	639.555	682.030	669.984	697.099	715.760	659.099
2012	Norte	2.519.336	2.388.287	2.528.737	2.464.743	2.564.902	2.462.680	2.453.561	2.510.949	2.486.488	2.521.284	2.427.264	2.442.993
2012	Nordeste	5.308.865	5.073.264	5.426.930	5.297.261	5.414.017	5.150.028	5.164.193	5.335.634	5.303.269	5.436.662	5.467.115	5.519.204
2012	Sudeste/C.Oeste	21.518.257	21.983.931	23.015.662	23.079.986	22.063.277	22.095.011	21.470.934	22.259.509	22.861.726	22.889.151	23.489.554	22.418.509
2012	Sul	6.353.277	6.812.782	7.026.116	6.534.981	6.141.747	6.180.121	6.188.904	6.391.481	6.340.229	6.251.818	6.543.892	6.725.279

2011	Norte	2.215.755	2.063.282	2.235.928	2.218.663	2.262.894	2.323.604	2.351.516	2.406.843	2.419.447	2.476.119	2.369.154	2.415.932
2011	Nordeste	5.988.600	5.502.639	6.026.836	5.966.554	5.899.310	5.809.043	5.936.622	6.092.998	6.093.026	6.216.199	6.137.780	6.244.198
2011	Sudeste	19.247.694	19.218.269	19.390.849	19.369.031	18.908.980	18.737.534	18.731.628	19.249.143	19.753.623	19.385.128	19.378.704	19.297.800
2011	Sul	6.285.133	6.504.407	6.435.946	6.183.233	6.147.984	6.011.171	6.081.811	6.177.576	6.133.865	6.118.714	6.045.746	6.344.201
2011	Centro-Oeste	2.136.562	2.156.320	2.261.131	2.310.837	2.346.819	2.278.222	2.315.716	2.409.253	2.565.228	2.547.610	2.437.006	2.439.818
2011	Sistemas Isolados	563.105	539.379	558.760	562.467	568.405	592.238	594.421	632.883	656.582	663.908	633.767	623.402
2011	Norte	2.427.336	2.212.703	2.446.369	2.425.865	2.497.282	2.520.006	2.561.563	2.594.923	2.556.386	2.606.289	2.494.162	2.553.827
2011	Nordeste	4.994.351	4.605.569	5.057.211	4.981.970	4.879.960	4.794.000	4.902.561	5.033.190	5.057.216	5.173.442	5.128.550	5.238.788
2011	Sudeste/C.Oeste	21.603.819	21.582.859	21.852.404	21.894.783	21.472.356	21.242.159	21.276.937	21.897.241	22.561.140	22.181.417	22.066.165	21.981.731
2011	Sul	6.285.133	6.504.407	6.435.946	6.183.233	6.147.984	6.011.171	6.081.811	6.177.576	6.133.865	6.118.714	6.045.746	6.344.201
2010	Norte	2.065.345	1.976.810	2.107.323	2.146.015	2.175.440	2.198.244	2.195.788	2.228.538	2.279.912	2.325.698	2.262.057	2.260.546
2010	Nordeste	5.739.946	5.589.432	6.118.961	5.884.040	5.959.632	5.905.720	5.844.282	5.833.193	5.896.294	6.123.244	6.136.436	6.165.765
2010	Sudeste	17.684.138	18.113.423	18.521.916	18.825.122	18.240.192	18.212.704	17.936.477	18.656.632	18.980.234	18.818.098	18.709.507	19.306.259
2010	Sul	5.798.706	5.979.347	6.199.985	5.982.263	5.730.901	5.652.619	5.706.940	5.755.499	5.711.563	5.628.306	5.758.556	6.029.231
2010	Centro-Oeste	2.072.325	2.070.746	2.168.697	2.188.420	2.190.813	2.200.172	2.165.862	2.239.532	2.314.269	2.293.579	2.211.426	2.194.639
2010	Sistemas Isolados	530.185	522.360	519.974	569.974	555.372	572.783	549.102	583.301	609.370	617.640	607.895	583.777
2010	Norte	2.304.691	2.153.625	2.347.780	2.309.802	2.373.574	2.369.141	2.407.663	2.452.133	2.439.170	2.485.835	2.419.808	2.455.639
2010	Nordeste	4.776.266	4.706.249	5.165.046	4.940.166	4.997.391	4.958.753	4.872.636	4.825.434	4.909.409	5.106.765	5.144.191	5.169.293
2010	Sudeste/C.Oeste	19.950.612	20.368.177	20.884.097	21.223.655	20.639.740	20.616.163	20.313.008	21.097.027	21.512.760	21.350.379	21.147.532	21.718.500
2010	Sul	5.798.706	5.979.347	6.199.985	5.982.263	5.730.901	5.652.619	5.706.940	5.755.499	5.711.563	5.628.306	5.758.556	6.029.231
2009	Norte	1.981.913	1.804.162	1.882.490	1.919.027	1.923.559	1.993.823	2.023.693	2.074.891	2.089.534	2.135.822	2.132.369	2.121.716
2009	Nordeste	5.340.331	5.098.685	5.391.003	5.307.847	5.189.806	5.122.496	5.257.360	5.501.276	5.581.245	5.779.775	5.705.872	5.968.068
2009	Sudeste	16.124.348	16.190.533	16.931.565	17.027.530	16.500.151	16.330.119	16.655.879	17.158.443	17.516.988	17.858.520	18.058.927	18.201.962
2009	Sul	5.279.472	5.465.140	5.742.612	5.671.556	5.266.440	5.261.043	5.315.045	5.392.188	5.362.624	5.440.950	5.591.816	5.739.383
2009	Centro-Oeste	1.940.598	1.936.623	2.030.080	2.116.833	2.065.497	2.007.689	2.073.014	2.135.408	2.166.275	2.204.466	2.127.836	2.092.066
2009	Sistemas Isolados	660.399	641.064	642.350	662.345	678.973	681.152	678.137	739.357	760.014	783.998	578.759	568.805
2009	Norte	2.258.573	1.979.238	2.109.772	2.106.575	2.150.750	2.182.941	2.254.448	2.279.943	2.271.616	2.310.492	2.287.224	2.292.493
2009	Nordeste	4.411.351	4.290.763	4.528.036	4.464.527	4.290.163	4.259.862	4.354.335	4.563.834	4.646.286	4.828.396	4.770.153	5.031.179
2009	Sudeste/C.Oeste	18.056.867	18.118.938	18.954.980	19.137.790	18.559.127	18.330.172	18.723.026	19.286.884	19.676.126	20.055.697	20.388.868	20.491.335
2009	Sul	5.279.472	5.465.140	5.742.612	5.671.556	5.266.440	5.261.043	5.315.045	5.392.188	5.362.624	5.440.950	5.591.816	5.739.383
2008	Norte	1.890.320	1.836.296	1.900.506	1.888.899	1.933.034	1.980.943	1.998.546	2.066.807	2.112.487	2.151.182	2.081.744	2.032.318
2008	Nordeste	5.505.389	5.284.770	5.365.906	5.266.621	5.436.907	5.241.035	5.334.190	5.400.231	5.461.714	5.685.044	5.585.549	5.535.839
2008	Sudeste	17.157.633	17.088.727	17.293.931	17.284.914	17.577.262	17.180.445	17.451.996	17.983.892	17.869.017	18.231.987	18.164.111	16.659.849
2008	Sul	5.491.078	5.689.547	5.723.834	5.604.344	5.382.338	5.368.281	5.419.027	5.520.183	5.412.749	5.481.462	5.441.085	5.366.031
2008	Centro-Oeste	1.811.526	1.831.601	1.834.538	1.907.778	1.970.422	1.972.284	1.946.593	2.042.416	2.108.120	2.124.102	2.137.678	1.965.241
2008	Sistemas Isolados	643.748	632.555	643.022	652.059	674.466	677.641	675.002	731.190	754.347	740.672	754.472	704.255
2008	Norte	2.176.344	2.062.095	2.169.060	2.116.218	2.173.036	2.211.338	2.273.269	2.297.754	2.310.179	2.385.308	2.278.183	2.270.448
2008	Nordeste	4.589.009	4.439.813	4.467.010	4.400.292	4.535.807	4.346.576	4.398.138	4.451.699	4.524.420	4.722.599	4.646.554	4.604.250
2008	Sudeste/C.Oeste	18.955.767	18.906.931	19.115.789	19.179.743	19.534.316	19.139.152	19.384.916	20.012.703	19.962.392	20.343.736	20.289.873	18.614.294
2008	Sul	5.491.078	5.689.547	5.723.834	5.604.344	5.382.338	5.368.281	5.419.027	5.520.183	5.412.749	5.481.462	5.441.085	5.366.031
2007	Norte	1.833.708	1.752.986	1.820.537	1.832.867	1.889.427	1.899.318	1.912.792	1.950.708	1.964.607	2.006.525	1.995.582	1.991.017
2007	Nordeste	5.184.828	4.883.152	4.985.447	5.117.947	5.132.742	5.079.581	5.131.886	5.212.952	5.148.024	5.440.994	5.502.715	5.546.780
2007	Sudeste	16.699.870	16.615.359	17.288.542	17.761.372	17.290.528	16.890.489	16.589.542	16.970.732	17.585.510	17.488.650	17.983.265	17.621.312
2007	Sul	5.203.429	5.351.937	5.424.059	5.404.659	5.219.841	5.114.607	5.056.898	5.194.645	5.157.841	5.240.394	5.294.910	5.333.163
2007	Centro-Oeste	1.777.869	1.721.235	1.794.315	1.913.899	1.850.379	1.782.765	1.809.181	1.852.096	1.879.754	1.959.172	1.878.019	1.812.654
2007	Sistemas Isolados	610.999	613.674	613.844	632.726	637.929	649.524	640.495	659.124	690.497	692.060	703.637	682.025
2007	Norte	2.129.379	1.965.130	2.091.436	2.088.417	2.172.209	2.138.391	2.187.175	2.234.128	2.180.370	2.260.957	2.221.822	2.252.062
2007	Nordeste	4.293.362	4.072.821	4.116.069	4.245.411	4.227.316	4.203.769	4.229.714	4.283.116	4.255.922	4.508.399	4.586.600	4.616.989
2007	Sudeste/C.Oeste	18.462.535	18.321.107	19.067.492	19.659.531	19.125.622	18.660.469	18.386.017	18.810.120	19.451.106	19.433.925	19.847.522	19.420.687
2007	Sul	5.203.429	5.351.937	5.424.059	5.404.659	5.219.841	5.114.607	5.056.898	5.194.645	5.157.841	5.240.394	5.294.910	5.333.163
2006	Norte	1.727.932	1.646.352	1.741.060	1.733.653	1.753.959	1.761.920	1.812.929	1.851.943	1.886.314	1.899.959	1.871.574	1.864.370
2006	Nordeste	4.913.182	4.704.041	4.976.022	4.856.338	4.793.832	4.769.522	4.760.160	4.939.400	4.950.953	5.141.501	5.132.731	5.122.710
2006	Sudeste	15.695.620	16.178.818	16.273.217	16.494.218	15.885.835	15.969.883	15.981.707	16.352.070	16.434.266	16.453.398	16.722.623	16.689.648
2006	Sul	4.927.600	5.187.222	5.211.509	5.062.543	4.807.141	4.879.786	4.847.373	4.957.961	4.841.502	4.852.385	5.043.949	5.074.875
2006	Centro-Oeste	1.616.577	1.667.054	1.696.020	1.741.200	1.684.272	1.687.687	1.711.640	1.784.863	1.803.594	1.796.283	1.760.244	1.742.376
2006	Sistemas Isolados	573.678	572.318	573.765	593.409	583.257	597.955	622.176	630.911	673.536	659.545	661.747	644.481
2006	Norte	1.983.975	1.845.538	1.997.492	1.979.413	2.002.934	2.006.597	2.057.709	2.119.573	2.099.683	2.156.880	2.097.589	2.133.465
2006	Nordeste	4.096.943	3.946.336	4.159.995	4.031.775	3.975.978	3.941.536	3.907.604	4.055.591	4.079.746	4.240.865	4.260.667	4.224.038
2006	Sudeste/C.Oeste	17.298.716	17.832.072	17.955.066	18.220.813	17.555.728	17.642.923	17.678.948	18.122.200	18.222.163	18.233.851	18.467.169	18.417.119
2006	Sul	4.927.600	5.187.222	5.211.509	5.062.543	4.807.141	4.879.786	4.847.373	4.957.961	4.841.502	4.852.385	5.043.949	5.074.875
2005	Norte	1.687.539	1.619.124	1.669.598	1.651.887	1.689.409	1.692.288	1.718.918	1.725.457	1.752.161	1.796.178	1.787.687	1.774.268
2005	Nordeste	4.775.176	4.526.038	4.692.201	4.675.415	4.738.601	4.575.215	4.643.778	4.739.651	4.763.781	4.849.539	4.919.391	5.005.464
2005	Sudeste	15.518.488	15.157.055	15.516.648	16.304.408	15.581.963	15.633.867	15.509.118	15.838.517	16.391.989	16.074.849	16.089.443	16.116.894
2005	Sul	4.809.416	4.966.586	5.069.873	4.997.008	4.799.821	4.760.324	4.724.562	4.743.659	4.654.131	4.668.762	4.748.342	4.948.743
2005	Centro-Oeste	1.584.818	1.569.678	1.650.311	1.726.784	1.672.357	1.664.488	1.725.940	1.717.071	1.773.066	1.755.984	1.742.754	1.659.777
2005													