

Identificação da tendência das emissões de gases do efeito estufa no estado do Amazonas: uma abordagem com suavização exponencial

Trend Identification of Greenhouse Gas Emissions in the Amazonas State: An Approach with Exponential Smoothing

Identificación de la tendencia de las emisiones de gases de efecto invernadero en el estado de Amazonas: un enfoque con suavización exponencial

Francisco Soares Lima Filho

Professor Mestrando, IFAM, Brasil.
fancisco Soares@gmail.com

Viviane Leite Dias de Mattos

Professora Doutora, FURG, Brasil.
vivianeldm.furg@gmail.com

RESUMO

Este artigo foca na importância da compreensão das emissões de dióxido de carbono equivalente (CO₂e) no estado do Amazonas, destacando as potenciais implicações para políticas públicas. Utilizando análise de séries temporais de dados climáticos, o estudo investiga padrões de variabilidade e busca prever mudanças de curto e longo prazo nas emissões de CO₂e. O objetivo é identificar os modelos de suavização exponencial mais adequados para prever a tendência das emissões de CO₂e resultantes de mudanças no uso da terra na Amazônia durante o período de 1990 a 2021. Além disso, o artigo avalia a precisão dos modelos selecionados. Os resultados enfatizam a necessidade crítica de desenvolver modelos eficazes de previsão e estimativa em diversas áreas, destacando sua relevância na informação dos processos de formulação de políticas.

PALAVRAS-CHAVE: Séries temporais. Emissões de CO₂e. suavização exponencial. previsão.

SUMMARY

This article focuses on the significance of comprehending carbon dioxide equivalent (CO₂e) emissions in the state of Amazonas, emphasizing the potential implications for public policies. Leveraging time series analysis of climate data, the study investigates patterns of variability and aims to predict short and long term changes in CO₂e emissions. The objective is to identify the most suitable exponential smoothing models to forecast the trend of CO₂e emissions resulting from forest land use changes in Amazonas State during the period from 1990 to 2021. Additionally, the article evaluates the accuracy of the selected models. The findings emphasize the critical need to develop effective prediction and estimation models across diverse domains, underscoring their relevance in informing policy-making processes.

KEYWORDS: Time series. CO₂e emissions. exponential smoothing. forecast.

RESUMEN

Este artículo se centra en la importancia de comprender las emisiones de dióxido de carbono equivalente (CO₂e) en el estado de Amazonas, destacando las posibles implicaciones para las políticas públicas. Aprovechando el análisis de series temporales de datos climáticos, el estudio investiga patrones de variabilidad y busca prever cambios a corto y largo plazo en las emisiones de CO₂e. El objetivo es identificar los modelos de suavización exponencial más adecuados para pronosticar la tendencia de las emisiones de CO₂e resultantes de cambios en el uso del suelo en el estado de Amazonas durante el período de 1990 a 2021. Además, el artículo evalúa la precisión de los modelos seleccionados. Los hallazgos enfatizan la necesidad crítica de desarrollar modelos efectivos de predicción y estimación en diversas áreas, destacando su relevancia en la información de los procesos de formulación de políticas.

PALABRAS CLAVE: Series temporales. emisiones de CO₂e. suavización exponencial. pronóstico.

1 INTRODUÇÃO

A atividade humana vem mudando a Terra causando transformações imprevisíveis e complexas, caracterizando o fenômeno da mudança climática. A sua ocorrência causa desastres ecológicos e sociais, podendo resultar em colapsos econômicos locais e globais (KARIMI et al., 2022).

O desmatamento e os incêndios florestais são problemas ambientais significativos que afetam a biodiversidade, o clima e as comunidades que dependem da floresta (FEARNSIDE, 2010). No Brasil, a região amazônica é particularmente afetada por esses problemas. O desmatamento e as queimadas são causados por uma combinação de fatores ambientais e antrópicos, como o clima, a agricultura, a pecuária e a extração de madeira (AMIGO, 2020).

A Amazônia é o bioma que mais tem emitido gases do efeito estufa (GEE) decorrentes principalmente do avanço da pecuária sobre as florestas. Em relação às emissões estaduais, o estado do Amazonas emitiu em 2020, por mudança de uso da terra, 109, 1 M t de dióxido de carbono equivalente (CO_2e) que sozinho representa 60, 5% da emissão do setor no Brasil (POTENZA et al., 2021).

As emissões mundiais de GEE somavam cerca de 51 e 58 bilhões de toneladas (Gt) de CO_2e em 2021, segundo o relatório *Emissions Gap Report* publicado pela UNEP. Neste período o Brasil contribuiu com 2, 42 Gt CO_2e , representando cerca de um percentual entre 3, 5 e 4, 5% das emissões globais anuais. Embora exista necessidade de reduzi-la, esta participação já chegou a representar 6% em 2003 (SEEG, 2023).

O estudo das mudanças climáticas globais sobre cada região do país é imprescindível para o planejamento estratégico e para a tomada de decisões por parte do poder público e da sociedade (COPERTINO et al., 2017). A tomada de decisão baseada em conhecimento científico é fundamental para preservar a natureza e garantir o bem-estar das pessoas.

A modelagem de séries temporais, por exemplo, pode fornecer informações relacionadas às tendências de emissão de CO_2e , dando subsídios para elaboração de políticas públicas de maneira responsável. Segundo Morettin e Tolo (2018), a maioria dos métodos de previsão baseia-se na ideia de que as observações passadas contêm informações sobre padrões de comportamento da série temporal. A análise de séries temporais permite encontrar modelos que descrevem de forma adequada um processo de geração de dados, que seja capaz de prever o comportamento futuro de uma determinada variável para um determinado horizonte de previsão (VERÍSSIMO et al., 2013).

Os modelos de Suavização Exponencial já produziram excelentes resultados na modelagem de séries temporais em vários contextos (ALAM; ALARJANI, 2021; THABANI; HAPANYENGWI; MUTONGI, 2019; NYONI; BONGA, 2019). Eles são úteis para ajustar dados de séries temporais, refletindo a tendência ao longo do tempo. No entanto, nem sempre são a melhor opção para todas as séries temporais. É recomendado explorar vários métodos de modelagem e previsão para escolher aquele que melhor se adapta aos dados e às necessidades específicas (RAGSDALE, 2021).

Certamente a previsão das emissões de CO_2e é uma área de pesquisa importante em face das mudanças climáticas globais e dos esforços para reduzir as emissões de GEE. Esta pesquisa visa identificar os modelos de suavização exponencial mais adequados para prever a tendência das emissões de CO_2e resultantes da produção de energia do estado do Amazonas.

O artigo está organizado em cinco seções. Na Seção 1., apresenta-se a motivação e o objetivo da pesquisa, enquanto na Seção 2. é realizada uma revisão da literatura. A Seção 3. detalha a metodologia utilizada, e na Seção 4. são apresentados e discutidos os resultados encontrados. A Seção 5. aborda as conclusões, limitações deste estudo e sugestões de trabalhos futuros.

2 REVISÃO DA LITERATURA

Desde a década de 1950, o método de suavização exponencial tem sido amplamente utilizado como uma estrutura de modelagem que incorpora modelos estocásticos, probabilidades e intervalos de previsão. No entanto, os procedimentos de seleção de modelos para suavização exponencial foram desenvolvidos apenas recentemente, com contribuições significativas de *Ord et al. (1997)* e *Hyndman et al. (2002)*. Esses estudos, juntamente com outros trabalhos relevantes, estabeleceram uma classe de modelos de espaço de estado que serve como base para todos os métodos de suavização exponencial (HYNDMAN; ATHANASOPOULOS, 2021).

Segundo Makridakis, Wheelwright e Hyndman (2021), os métodos de suavização exponencial, em sua maioria são recursivos — percorrendo os dados conhecidos, período a período, em vez de usar todos os dados anteriores no ajuste. A estratégia de modelagem de séries temporais envolvem dividir a série em conjuntos de inicialização e de teste, escolher um método de previsão, estimar os componentes do modelo, avaliar o desempenho no conjunto de teste, analisar a adequação e aplicabilidade do método.

O método de suavização exponencial simples (SES) é usado para fazer previsões de dados que não mostram uma tendência clara e nem um padrão sazonal. Sua formulação está apresentada na primeira linha do corpo da Tabela 1, para erros aditivos e multiplicativos, onde o valor estimado no t-ésimo período y_t é uma função linear do nível no período anterior l_{t-1} , representando a parte previsível de y_t , e do erro ε_t , a parte imprevisível de y_t , e α é o parâmetro de suavização do nível que varia entre 0 e 1. Esse método é amplamente utilizado para realizar previsões simples e rápidas (HYNDMAN; ATHANASOPOULOS, 2021).

Tabela 1 - Método de suavização exponencial

Tendência	Com erro aditivo (A)	Com erro multiplicativo (M)
N	$y_t = l_{t-1} + \varepsilon_t$ $l_t = l_{t-1} + \alpha\varepsilon_t$	$y_t = l_{t-1}(1 + \varepsilon_t)$ $l_t = l_{t-1}(1 + \alpha\varepsilon_t)$
A	$y_t = l_{t-1} + b_{t-1} + \varepsilon_t$ $l_t = l_{t-1} + b_{t-1} + \alpha\varepsilon_t$ $b_t = b_{t-1} + \beta\varepsilon_t$	$y_t = (l_{t-1} + b_{t-1})(1 + \varepsilon_t)$ $lt = (lt - 1 + bt - 1)(1 + \alpha\varepsilon_t)$ $b_t = b_{t-1} + \beta(l_{t-1} + b_{t-1})\varepsilon_t$
A_d	$y_t = l_{t-1} + \phi b_{t-1} + \varepsilon_t$ $l_t = l_{t-1} + \phi b_{t-1} + \alpha\varepsilon_t$ $b_t = \phi b_{t-1} + \beta\varepsilon_t$	$y_t = (l_{t-1} + \phi b_{t-1})(1 + \varepsilon_t)$ $l_t = (l_{t-1} + \phi b_{t-1})(1 + \alpha\varepsilon_t)$ $b_t = \phi b_{t-1} + \beta(l_{t-1} + \phi b_{t-1})\varepsilon_t$

Fonte: Adaptado de Hyndman e Athanasopoulos (2023). Sem tendência (N), tendência aditiva (A), tendência aditiva amortecida (A_d), valor estimado (y_t), nível estimado (l_t), tendência estimada (b_t), erro (ε_t), parâmetro de suavização para o nível (α), parâmetro de suavização para a tendência (β), parâmetros de amortecimento (ϕ)

Holt (1957) estendeu a SES para permitir a previsão de dados em séries com tendência,

propondo o método linear de Holt. As suas equações são apresentadas na segunda linha da Tabela 1, considerando erros aditivos e multiplicativos, sendo, em relação ao anterior, acrescentados os parâmetros associados à tendência, β e b_t . Nestas equações α e β também devem variar entre 0 e 1.

Contudo, esse método apresenta a desvantagem de superestimar as previsões, principalmente em longo prazo. Para resolver esta desvantagem, Gardner e McKenzie (1985) propuseram uma modificação para permitir o "amortecimento" da tendência. As equações que o representam estão na terceira linha da Tabela 1. Em conjunto com os parâmetros α e β , elas incluem um parâmetro de amortecimento da tendência $0 \leq \phi \leq 1$. Se $\phi = 1$, o método é idêntico ao método linear de Holt. Para valores entre 0 e 1, ϕ amortece a tendência para que ela se aproxime de uma constante em algum momento no futuro. De fato, as previsões convergem para $\ell_t + \phi b_t / (1 - \phi)$ quando $h \rightarrow \infty$ para qualquer valor $0 \leq \phi \leq 1$. Isso significa que as previsões de curto prazo são tendenciosas, enquanto as previsões de longo prazo são constantes (HYNDMAN; ATHANASOPOULOS, 2021).

Além destes modelos aditivos, existem os modelos multiplicativos, que podem ser obtidos pelas mesmas equações apresentadas na Tabela 1 com a substituição da operação adição entre ℓ_t e b_t pela operação produto.

Várias aplicações destes métodos podem ser encontradas na literatura. Uma pesquisa bibliográfica foi realizada na *Web of Science*, buscando aplicações deste método publicadas na última década. Os principais termos utilizados na busca incluíram "GHG", "CO2emissions", "time series", "forecast" e "exponential smoothing", com diferentes combinações. Os trabalhos apresentados a seguir, foram selecionados em função da relevância de seu conteúdo e da metodologia utilizada.

No estudo realizado por Kale e Pohekar (2014), a previsão da demanda de eletricidade foi abordada buscando fornecer soluções sustentáveis no setor de energia. Utilizando uma ferramenta de software amplamente utilizada para prever a demanda e o fornecimento de energia (LEAP), eles aplicaram o método de suavização exponencial linear de Holt para prever a demanda de eletricidade em Maharashtra, Índia, até 2030. Três cenários foram gerados, considerando diferentes aspectos, como energia, impacto ambiental e custo, fornecendo, segundo os autores, insights valiosos para políticas energéticas e ambientais.

Yörük et al. (2023) propuseram um modelo de otimização mista adaptado para o planejamento estratégico de eletricidade na Turquia. Além da minimização de custos, o modelo também incorporou políticas estratégicas, como a redução de emissões de CO_2 . Os pesquisadores utilizaram métodos de previsão, incluindo ARIMA (Modelos Autoregressivos Integrados de Médias Móveis) e Suavização Exponencial, para prever com precisão a demanda de eletricidade. Os resultados destacaram um aumento significativo no uso de fontes de energia renováveis e uma redução na dependência de combustíveis fósseis na geração de energia.

No estudo de Alamri e Khan (2023), a previsão de emissões de CO_2 na Arábia Saudita foi investigada. Diferentes técnicas de modelagem estatística e de aprendizado de máquina foram implementadas e avaliadas, incluindo suavização exponencial e ARIMA. O modelo de análise de expansão de base neural para séries temporais interpretáveis (N-BEATS) demonstrou um melhor desempenho na previsão de emissões de CO_2 . O estudo também ofereceu recomendações e estratégias para mitigar as mudanças climáticas por meio da redução de emissões de CO_2 .

Esses estudos apresentam uma ampla gama de abordagens e modelos aplicados na área de suavização exponencial e previsão de séries temporais. Os resultados obtidos demonstraram a eficiência desses modelos, contribuindo para o avanço do conhecimento nessa área e oferecendo informações para melhorar o desempenho da previsão em diferentes contextos.

3 METODOLOGIA

O escopo deste estudo é restrito ao estado do Amazonas, localizado na Região Norte do Brasil, o qual se destaca como o maior em extensão territorial, abrangendo 18.3% (1.559 mil km²) do território brasileiro (IBGE, 2022). De acordo com os dados coletados no Censo 2022, realizado pelo Instituto Brasileiro de Geografia e Estatística (IBGE), possui população de aproximadamente 3.941.175 pessoas, o que representa cerca de 1,9% do total da população do Brasil. Essas informações constituem elementos fundamentais para o enquadramento deste estudo em um contexto científico.

Os dados e a análise foram realizados a partir de observações anuais das emissões de CO_2e neste estado, no período de 1990 a 2021. Nesta análise foram consideradas apenas as emissões oriundas da categoria de energia (emissões pela queima de combustíveis e emissões fugitivas), disponibilizadas pelo Sistema de Estimativas de Emissões e Remoções de Gases de Efeito Estufa (SEEG) do Observatório do Clima (SEEG, 2023).

Para compreender o comportamento das emissões de CO_2e , foi feita uma análise exploratória dos dados. Posteriormente, a série foi dividida em um período de treinamento ou ajuste (1990-2015) e outro de teste (2016-2021). Considerando o período de ajuste, a série temporal foi modelada com os métodos de Suavização Exponencial com tendência aditiva e erro aditivo (AA), Suavização Exponencial com tendência aditiva e erro multiplicativo (MA), Suavização Exponencial com tendência multiplicativa e erro multiplicativo (MM), Suavização Exponencial com tendência aditiva amortecida e erro aditivo (AA_d), Suavização Exponencial com tendência aditiva amortecida e erro multiplicativo (MA_d) e Suavização Exponencial com tendência multiplicativa amortecida e erro multiplicativo (MM_d).


O melhor ajuste foi identificado por um critério de informação, sendo o modelo mais parcimonioso identificado por Critério de Informação de Akaike (AIC), Critério de Informação de Akaike Corrigido (AICc) e o Critério de Informação Bayesiano (BIC) (AKHTER; HASSAN; ABBAS, 2020). Para avaliar a qualidade do ajuste utilizam-se três testes estatísticos que foram aplicados aos resíduos: o teste de Ljung-Box para verificar a autocorrelação nos resíduos, o teste ARCH para detectar a presença de heterocedasticidade condicional nos resíduos e o teste de Jarque-Bera para avaliar se os dados seguem uma distribuição normal (PROFILLIDIS; BOTZORIS, 2019). O modelo com melhor capacidade preditiva foi identificado pelas métricas de erro: Erro Médio Absoluto (MAE), Raiz do Erro Médio Quadrático (RMSE), Erro Percentual Médio Absoluto (MAPE) (ZHAO; LI; QU, 2022).

Os procedimentos foram executados no software R (R Core Team, 2022), em sua maioria com funções do pacote *forecast* (HYNDMAN; ATHANASOPOULOS, 2021). Para as análises de inferência, foram considerados os níveis de significância 0,01 e 0,05, e as estimações por intervalo com nível de confiança de 0,95.

4 RESULTADOS E DISCUSSÕES

A Figura 1 mostra que a série temporal apresenta uma tendência crescente ao longo do tempo, com um aumento geral nas emissões de CO_2e . A série possui flutuações ao longo do tempo, mas ainda mantém a direção geral de crescimento. Isso sugere que podem existir influências externas ou fatores variáveis que impactam as emissões desse gás no estado. No final do período, há uma estabilização ou desaceleração no crescimento das emissões de CO_2e oriundas da produção de energia. Uma avaliação realizada por meio de um *Boxplot* não identifica valor discrepante, Figura 2.


Figure 1: Emissões de CO_2e no estado do Amazonas para categoria energia, 1990-2021



Fonte: Elaboração própria, adaptado do SEEG.

Com base nas medidas descritivas dos dados, apresentadas na Tabela 2, observa-se uma distribuição das emissões relativamente equilibrada em torno de um valor central, pois a média (6185951t) e a mediana (6788602t) estão relativamente próximas uma da outra.

Figure 2: Emissões de CO_2e no estado do Amazonas para categoria energia, 1990-2021



Fonte: Elaboração própria, adaptado do SEEG.

O desvio padrão (2595071t) assume valor moderado em relação à média, e indica que as emissões de CO_2e da categoria de energia têm uma dispersão moderada em torno da média. O primeiro quartil (4295020t) e o terceiro quartil (8701040t) indicam que 25% e 75% das observações, respectivamente, estão abaixo desses valores. O valor de assimetria (-0,2686) é negativo e baixo, indicando que a distribuição é levemente assimétrica, ou seja, com uma cauda longa à esquerda. Isso sugere que existem valores baixos das emissões que podem estar puxando a distribuição para a esquerda. Já a curtose (-1,709) indica que a série possui uma

distribuição mais achatada com caudas pesadas, sugerindo uma maior presença de valores extremos em relação à distribuição normal.

Tabela 1 – Medidas descritivas da série temporal produção de energia

Medidas	Min.	1º Qu.	Mediana	Média	3º Qu.	Max.	Desvio padrão	Curtose
CO2e(t)	1.658.841	3.493.068	5.246.602	5.757.890	7.938.359	10.053.720	2.583.743	1,709

Fonte: Elaboração própria

A Tabela 3 apresenta os coeficientes dos modelos obtidos pelo Método de Suavização Exponencial. No modelo ETS(AA), observa-se que $\alpha(0.4650)$ indica que mudanças recentes têm impacto na estimativa do nível atual da série temporal. O coeficiente $\beta(1.00 \times 10^{-4})$ sugere que a tendência histórica tem uma influência moderada nas previsões futuras, equilibrando a importância das observações recentes. Com um $\varphi(1.281.777,0731)$ bem alto, indica uma forte dependência das observações passadas na série temporal.

O ETS(MA) possui um $\alpha(0,2438)$ relativamente baixo indica menor sensibilidade a variações recentes. O $\beta(1,00 \times 10^{-4})$ sugere uma influência moderada da tendência histórica nas previsões futuras. O $\varphi(1.340.427,5530)$ é alto, indicando uma dependência observações passadas na série temporal. Já para o ETS(MM) $\alpha(0,6017)$ é alto, sugerindo que mudanças recentes têm um impacto no nível atual. O coeficiente $\beta(0,151)$ indica influência moderada da tendência histórica nas previsões futuras. O coeficiente $\varphi(1.406.325,6423)$ indica uma dependência das observações passadas.

Table 3: Coeficientes dos modelos estimados pelo Método de Suavização Exponencial, 1990-2015

Modelo	α	β	φ	ℓ	b
AA	0,4650	1,00e-04		1.281.777,07	333.738,73
AA_d	0,4016	1,00e-04	0,9735	1.219.450,30	396.985,03
MA	0,2438	1,00e-04		1.340.427,55	333.738,80
MA_d	0,3650	1,02e-04	0,9800	1.310.909,26	360.127,01
MM	0,6017	1,51e-01		1.406.325,64	1,16
MM_d	0,5174	1,00e-04	0,9117	1.406.325,89	1,23

Fonte: Elaboração própria. Parâmetro de suavização para o nível (α), parâmetro de suavização para a tendência (β), parâmetros de amortecimento da tendência (φ), estimativa inicial de nível (ℓ) e estimativa inicial de tendência (b)

O modelo ETS(AA_d) indica uma tendência acentuada em suavizar a componente de nível e tendência. O coeficiente autorregressivo (φ) sugere uma dependência nas observações passadas, contribuindo para a modelagem da série temporal. O modelo ETS(MA_d) apresenta uma abordagem semelhante ao ETS(AA_d), com ênfase na suavização das componentes de nível e tendência. A presença do coeficiente b indica uma consideração explícita da componente sazonal diária na modelagem. O modelo ETS(MM_d) destaca a importância da suavização nas componentes de nível e tendência, com ênfase especial na componente sazonal mensal (b). O coeficiente autorregressivo (φ) sugere uma dependência nas observações passadas para a modelagem adequada.

Com base nas métricas de critério de informação apresentadas na Tabela 4, os modelos com os melhores ajustes são o ETS(MA) e o ETS(MA_d). Ambos possuem os menores valores para AIC, com ETS(MA) sendo o melhor também em AICc e BIC, apresentando o melhor desempenho

nos critérios de informação.

Ao analisar os resultados dos testes estatísticos para os resíduos, observa-se que os valores-p encontrados nos testes de Ljung-Box e nos testes ARCH são maiores do que 0,05, indicando ausência de evidências significativas de autocorrelação nos resíduos (Ljung-Box) e de heterocedasticidade condicional (ARCH). Além disso, os valores-p para os testes de Jarque-Bera também são maiores do que 0,05, sugerindo que os resíduos podem ser considerados como tendo uma distribuição normal. Esses resultados fortalecem a adequação dos modelos ETS(MA) e ETS(MA_d) para a modelagem da série temporal.

Table 4: Resultados dos critérios de informação e dos testes de autocorrelação, heterocedasticidade e normalidade dos resíduos dos modelos, 1990-2015

Modelo	AIC	AICc	BIC	Ljung-Box	JB	ARCH
MA	817,68	819,50	824,16	0,5218	0,9275	0,6610
MA _d	819,37	822,22	827,14	0,5972	0,8341	0,4983
MM _d	820,62	823,47	828,39	0,4843	0,8408	0,4656
MM	825,93	827,75	832,41	0,3212	0,7768	0,2106
AA _d	827,35	830,21	835,12	0,8714	0,3312	0,0262
AA	827,47	829,29	833,95	0,8965	0,0801	0,0087

Fonte: Elaboração própria. Critério de informação de Akaike (AIC), Akaike corrigido (AICc), Bayesiano (BIC) e Jarque Bera (JB). *Valor de p para cada um dos testes.

A Tabela 5 mostra as métricas de erro, comparando as métricas dos modelos mais parcimoniosos, observamos que o ETS(MA_d) apresenta desempenho superior em todas as medidas avaliadas em relação ao ETS(MA). O RSME do ETS(MA_d) é significativamente menor, indicando uma menor dispersão entre as previsões e os valores reais. Da mesma forma, o MAE, sugerindo uma capacidade de previsão mais precisa e consistente em comparação ao ETS(MA). Esses resultados indicam que o ETS(MA_d) tem uma melhor capacidade de predição, fornecendo estimativas mais próximas dos valores reais.

Table 5: Capacidade preditiva dos modelos mais parcimoniosos para emissões de CO2e

Modelo	RMSE	MAE	MAPE(%)
MA _d	7.232.463,62	7.225.793,70	323,12
MA	8.292.891,36	8.283.730,58	368,58

Fonte: Elaboração própria. Erro Médio Absoluto (MAE), Erro Percentual Médio Absoluto (MAPE), Raiz do Erro Médio Quadrático (RMSE)

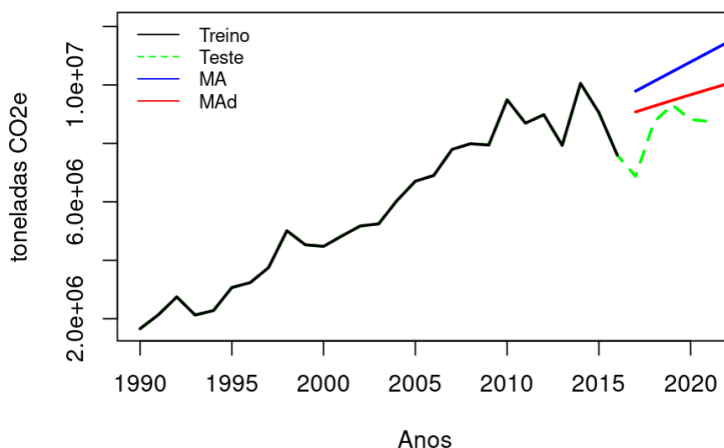
O gráfico da Figura 2 mostra os valores observados e as previsões com intervalos de confiança obtidos a partir dos modelos de Suavização Exponencial com tendência aditiva amortecida e erro multiplicativo (MA_d) e com tendência aditiva e erro multiplicativo (MA).

As previsões acompanham uma tendência semelhante aos valores observados, capturando as variações e a direção geral dos dados. Embora sujeitas a erros, os modelos apresentam um desempenho razoável na previsão.

Em resumo, conforme as métricas utilizadas, o ETS(MA_d) é o mais adequado para realizar previsões. Este achado confirma a ideia de que, quando a variabilidade aumenta com o

tempo, o modelo multiplicativo apresenta melhor desempenho em relação ao aditivo. Além disso, embora não seja o mais parcimonioso, seus resíduos podem ser considerados IID (independentes e identicamente distribuídos), o que agrega confiabilidade aos resultados encontrados.

Figure 2: Emissões de CO2 e no estado do Amazonas, oriundas da categoria energia, 1990-2021.



Fonte: Elaboração própria. Suavização exponencial com tendência aditiva amortecida e erro multiplicativo (MAAd) e com tendência aditiva e erro multiplicativo (MA)

Para $\alpha = 0,365$, $\beta = 1,02e-04$, $\varphi = 0,98$, $\ell = 1.310.909,26$ e $b = 360.127,0131$ temos o seguinte modelo expresso pelas Equações 1, 2 e 3:

$$y_t = (\ell_{t-1} + 0,98 \times b_{t-1})(1 + \varepsilon_t) \quad (1)$$

$$\ell_t = (\ell_{t-1} + 0,98 \times b_{t-1})(1 + 0,365 \times \varepsilon_t) \quad (2)$$

$$b_t = 0,98 \times b_{t-1} + 1,02e - 04 \times (\ell_{t-1} + 0,98 \times b_{t-1})\varepsilon_t \quad (3)$$

5 CONCLUSÃO

As emissões do CO_2e aumentaram significativamente no período observado no estado do Amazonas. No entanto, enormes disparidades são encontradas na série histórica, tanto em termos de valores absolutos de emissões de CO_2e quanto em termos de seu ritmo de crescimento no período 1990 – 2021.

Os resultados encontrados mostram que estes modelos de suavização exponencial, apesar de sua simplicidade, podem ser utilizados com sucesso em situações propícias, sendo aconselháveis para previsões de curto prazo e para séries que não apresentem mudanças abruptas em seu padrão de comportamento.

Para previsões de longo prazo, esses modelos não apresentaram bom desempenho, porque, de maneira geral, as séries temporais, por sofrerem influência de outras variáveis, apresentam a tendência de alteração de seu padrão de comportamento. Nesse caso, pode-se recorrer a alternativas, por exemplo, aos modelos de Box-Jenkins.

REFERÊNCIAS

AKHTER, M. F.; HASSAN, D.; ABBAS, S. Predictive ARIMA model for coronal index solar cyclic data. Astronomy and

Computing, v. 32, p. 100403, 2020.

ALAM, T.; ALARJANI, A. **A comparative study of CO₂emission forecasting in the gulf countries using autoregressive integrated moving average, artificial neural network, and Holt-Winters exponential smoothing models.** Adv. Meteorol., v. 2021, p. 1–9, 2021.

ALAMRI, S.; KHAN, S. **Artificial intelligence based modelling for predicting CO₂emission for climate change mitigation in saudi arabia.** Int. J. Adv. Comput. Sci. Appl., v. 14, n. 4, 2023.

AMIGO, I. **When will the amazon hit a tipping point?** Nature, v. 578, n. 7796, p. 505–507, 2020.

COPERTINO, M. S. et al. Zonas costeiras. In: Carlos A. Nobre e José A. Marengo (Ed.). **Mudanças climáticas em rede: um olhar interdisciplinar.** São José dos Campos, SP: INCT, 2017. p. 307–366.

FEARNSIDE, P. M. **Consequências do desmatamento da Amazônia.** Scientific American Brasil Especial Biodiversidade, v. 3, p. 54–59, 2010.

HYNDMAN; ATHANASOPOULOS, R. G. **Forecasting: Principles and Practice.** Monash University, Australia: OTexts, 2021.

IBGE. Instituto Brasileiro de Geografia e Estatística. 2022. (<https://www.ibge.gov.br/cidades-e-estados/am.html>). Accessed: 2022-11-12.

KALE, R. V.; POHEKAR, S. D. **Electricity demand and supply scenarios for maharashtra (india) for 2030: An application of long range energy alternatives planning.** Energy Policy, v. 72, p. 1–13, 2014.

KARIMI, V. et al. **Beyond climate change: Impacts, adaptation strategies, and influencing factors.** In: Climate Change. Cham: Springer International Publishing, 2022. p. 49–70.

MORETTIN, P. A.; TOLOI, C. C. **Análise de séries temporais.** São Paulo: Editora Blucher, 2018.

NYONI, T.; BONGA, W. G. **Prediction of CO₂emissions in india using ARIMA models.** 2019.

POTENZA, R. F. et al. **Calculadora de emissões por pessoa no Brasil.** Nota metodológica Novembro 2021. (<https://seeg-br.s3.amazonaws.com/Notas\%20Metodologicas/Calculadora/OCCalculadora ALTA v2.pdf>). Accessed: 2023-1-11.

R Core Team. R: **The R Project for Statistical Computing.** 2022.

RAGSDALE, C. **Spreadsheet modeling and decision analysis: A practical introduction to business analytics.** 9. ed. Florence, AL, USA: South-Western College Publishing, 2021.

SEEG. Emissions Map — SEEG - System Gas Emissions Estimation. 2023.

THABANI, N.; HAPANYENGWI, H. O.; MUTONGI, C. **Modeling and forecasting carbon dioxide emissions in China using autoregressive integrated moving average (ARIMA) models.** EPRA International Journal of Multidisciplinary Research (IJMR), v. 5, p. 215–224, abr. 2019.

VERÍSSIMO, A. J. et al. **Métodos estatísticos de suavização exponencial Holt-Winters para previsão de demanda em uma empresa do setor metal mecânico.** Rev. Gest. Ind., v. 8, n. 4, 2013.

YÖRÜK, G. et al. **Strategic electricity production planning of turkey via mixed integer programming based on time series forecasting.** Mathematics, v. 11, n. 8, p. 1865, 2023.

ZHAO, L.; LI, Z.; QU, L. **Forecasting of beijing PM_{2.5} with a hybrid ARIMA model based on integrated AIC and improved GS fixed-order methods and seasonal decomposition.** Heliyon, v. 8, p. e12239, 2022.