

UNIVERSIDADE FEDERAL DE ALAGOAS
FACULDADE DE ECONOMIA, ADMINISTRAÇÃO E CONTABILIDADE FEAC
CIÊNCIAS ECONÔMICAS

ANDERSON DOS SANTOS DE OLIVEIRA

**ANÁLISE COMPARATIVA DE MODELOS DE PREVISÃO PARA RECEITAS
CORRENTES MENSIS DO ESTADO DE ALAGOAS: ABORDAGENS
ECONOMÉTRICAS E REDES NEURAS**

MACEIÓ

2024

ANDERSON DOS SANTOS DE OLIVEIRA

**ANÁLISE COMPARATIVA DE MODELOS DE PREVISÃO PARA RECEITAS
CORRENTES MENSAS DO ESTADO DE ALAGOAS: ABORDAGENS
ECONOMÉTRICAS E REDES NEURAS**

Trabalho de Conclusão de Curso apresentado ao Curso de Ciências Econômicas da Universidade Federal de Alagoas, como requisito parcial para obtenção do grau de Bacharel em Ciências Econômicas.

Orientador: Dilson José de Sena Pereira

MACEIÓ

2024

Catálogo na Fonte
Universidade Federal de Alagoas
Biblioteca Central
Divisão de Tratamento Técnico

Bibliotecário: Marcelino de Carvalho Freitas Neto – CRB-4 – 1767

- O48a Oliveira, Anderson dos Santos de.
Análise comparativa de modelos de previsão para receitas correntes mensais do estado de Alagoas : abordagens econométricas e redes neurais / Anderson dos Santos de Oliveira. – 2024.
51 f. : il.
- Orientador: Dilson José de Sena Pereira.
Monografia (Trabalho de Conclusão Curso em Ciências Econômicas: bacharelado) – Universidade Federal de Alagoas. Faculdade de Economia, Administração e Contabilidade. Maceió, 2024.
- Bibliografia: f. 49-51.
1. Receitas correntes - Alagoas - Previsão. 2. Auto-Regressivo Integrados de Médias Móveis com Sazonalidade (Modelo econométrico). 3. Redes neurais (Computação). I. Título.

CDU: 336.2(813.5)

ANDERSON DOS SANTOS DE OLIVEIRA

ANÁLISE COMPARATIVA DE MODELOS DE PREVISÃO PARA RECEITAS
CORRENTES MENSAIS DO ESTADO DE ALAGOAS: ABORDAGENS
ECONOMÉTRICAS E REDES NEURAIAS

Trabalho de Conclusão de Curso apresentado
ao Curso de Ciências Econômicas da
Universidade Federal de Alagoas, como
requisito parcial para obtenção do grau de
Bacharel em Ciências Econômicas.

BANCA EXAMINADORA:

Documento assinado digitalmente
 **DILSON JOSE DE SENA PEREIRA**
Data: 18/03/2024 10:49:01-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Dilson José de Sena Pereira
Universidade Federal de Alagoas
Orientador

Documento assinado digitalmente
 **ANDERSON MOREIRA ARISTIDES DOS SANTOS**
Data: 18/03/2024 18:39:44-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Anderson Moreira Aristides dos Santos
Universidade Federal de Alagoas
Examinador

Documento assinado digitalmente
 **FRANCISCO JOSE PEIXOTO ROSARIO**
Data: 18/03/2024 15:15:44-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Francisco José Peixoto Rosário
Universidade Federal de Alagoas
Examinador

Dedico este trabalho aos meus pais.

AGRADECIMENTOS

Dedico este trabalho, em primeiro lugar, ao Deus de Abraão, Isaque e Jacó, que me concedeu força e coragem para superar todos os obstáculos durante esta jornada. Consagre ao Senhor tudo o que você faz, e seus planos serão bem-sucedidos (Provérbios 16:3).

Agradeço imensamente a todos os professores que contribuíram para o meu crescimento pessoal e profissional. Em particular, expresso minha gratidão ao professor Francisco José Peixoto Rosário, cuja orientação e oportunidade de participar de dois projetos PIBIC foram de extrema importância para o meu desenvolvimento acadêmico. Além disso, gostaria de agradecer ao meu orientador, Dilson José de Sena Pereira, pela sua paciência e dedicação durante todo o processo de elaboração deste trabalho. Agradeço também ao Professor Anderson Moreira Aristides dos Santos por ter aceitado participar da banca e pelas valiosas observações.

À Secretaria de Estado de Transporte e Desenvolvimento Urbano (SETRAND), especialmente à Superintendência de Planejamento, Orçamento, Finanças e Contabilidade, pela valiosa oportunidade proporcionada durante meu período de estágio. Gostaria de agradecer em especial à Senhora Ivanilda Barreto, cuja orientação despertou meu interesse pela área do orçamento público.

Agradeço a toda a minha família, que direta ou indiretamente, me deu forças para alcançar esta conquista. Expresso minha eterna gratidão ao meu alicerce, meus pais, Clovis e Adriana, pelo apoio afetivo incondicional, pelas palavras de incentivo e por sempre terem buscado proporcionar o melhor para mim, mesmo diante das dificuldades. Também dedico estas palavras de gratidão aos meus irmãos, Emerson e Nelisson, e ao meu sobrinho Welisson, os quais são essenciais em minha vida.

Agradeço aos meus amigos de graduação, o flamenguista Lucas, e ao amigo palmeirense Luan, pelos momentos de descontração ao longo da minha jornada acadêmica. Também expresso minha gratidão à minha amiga de estágio, Cledenize, por todo o apoio durante essa fase.

Por fim, agradeço a todos que de forma direta ou indireta contribuíram para o desenvolvimento dessa pesquisa.

"Todas as previsões estão erradas, mas algumas são úteis." – George Box.

RESUMO

Nesta pesquisa, conduziu-se uma análise comparativa entre modelos econométricos e de redes neurais para prever as receitas correntes em Alagoas. Utilizando dados do Portal da Transparência, aplicaram-se os modelos SARIMA e a Rede Neural NNAR. Os resultados destacaram a superioridade do NNAR na previsão das receitas correntes e do ICMS, enquanto o SARIMA demonstrou melhor desempenho na previsão das transferências correntes. Esses resultados têm implicações importantes para o planejamento financeiro em Alagoas, enfatizando a utilidade desses modelos na previsão precisa das receitas públicas. No entanto, é fundamental reconhecer as limitações inerentes aos dados disponíveis. Recomenda-se investigações futuras que explorem técnicas adicionais e variáveis para aprimorar a precisão das previsões, contribuindo para uma gestão financeira mais informada no contexto estadual.

Palavras-chave: previsão; receitas correntes; SARIMA; redes neurais; Alagoas.

ABSTRACT

In this research, a comparative analysis was conducted between econometric and neural network models to predict current revenues in Alagoas. Using data from the Transparency Portal, the SARIMA models and the NNAR Neural Network were applied. The results highlighted the superiority of NNAR in forecasting current revenues and ICMS, while SARIMA demonstrated better performance in forecasting current transfers. These results have important implications for financial planning in Alagoas, emphasizing the usefulness of these models in accurately forecasting public revenues. However, it is essential to recognize the limitations inherent in the available data. Future investigations are recommended that explore additional techniques and variables to improve forecast accuracy, contributing to more informed financial management in the state context.

Keywords: forecasting; current revenues; SARIMA; neural networks; Alagoas.

LISTA DE FIGURAS

Figura 1 - Neurônio Artificial.....	21
Figura 2- Média da Composição das Receitas Correntes de 2018 a 2023.....	24
Figura 3 - Origem das Transferências Correntes	25
Figura 4 - Estrutura Tributária.....	25
Figura 5 - Série Temporal Receitas Correntes.....	27
Figura 6 - Série Temporal Transferências Correntes.....	28
Figura 7 - Série Temporal ICMS.....	28
Figura 8 - Box Plot (Receitas Correntes).....	29
Figura 9 - Box Plot Transferências Correntes.	30
Figura 10 - Figura 9 - Box Plot ICMS.....	31
Figura 11 - Box Plot Mensal Receitas Correntes.....	33
Figura 12 - Box Plot Mensal Transferências Correntes.....	34
Figura 13 - Box Plot Mensal ICMS.....	35
Figura 14 - Previsão Receitas Correntes 2023 (12 Passos a Frente)	42
Figura 15 - Previsão Transferências Correntes 2023.....	44
Figura 16- Previsão ICMS 2023 (12 Passos a Frente).....	46

LISTA DE QUADROS

Quadro 1 – Receitas Correntes.....	23
Quadro 2 - Lista de Variáveis.....	26

LISTA DE TABELAS

Tabela 1- Dados do Box Plot das Receitas Correntes	30
Tabela 2 - Dados do Box Plot das Transferências Correntes.	31
Tabela 3 – Dados do Box Plot Mensal Receitas Correntes.	33
Tabela 4 – Dados do Box Plot Mensal Transferências Correntes	34
Tabela 5 - Dados do Box Plot Mensal ICMS	35
Tabela 6 - Valores Previstos 12 passos à frente (Receitas Correntes 2023).....	43
Tabela 7 - Medidas de Acurácia Previsão Receitas Correntes	44
Tabela 8 - Valores Previstos 12 passos à frente (Transferências Correntes 2023).....	44
Tabela 9 - Medidas de Acurácia Previsão Transferências Correntes	46
Tabela 10 -Valores Previstos 12 passos à frente (ICMS 2023)	46
Tabela 11 - Medidas de Acurácia Previsão (ICMS 2023).....	47

LISTA DE ABREVIATURAS E SIGLAS

AIC	Critérios de Informação de Akaike
ARIMA	Auto-Regressivo Integrado de Médias Móveis
BIC	Critérios de Informação de Schwarz
FAC	Função de Autocorrelação
FACP	Função de Autocorrelação Parcial
ICMS	Imposto Sobre Circulação de Mercadorias e Serviços
IPCA	Índice Nacional de Preços ao Consumidor Amplo
IPTU	Imposto Sobre a Propriedade Predial e Territorial Urbana
ISS	Imposto Sobre Serviços
ITBI	Imposto sobre a Transmissão de Bens Imóveis
LDO	Lei de Diretrizes Orçamentárias
LOA	Lei Orçamentária Anual
LRF	Lei De Responsabilidade Fiscal
MAE	Média Absoluta dos Erros
MAPE	Média Absoluta Percentual dos Erros
NNAR	Autorregressão de Redes Neurais Artificiais
PPA	Plano Plurianual
RMSE	Raiz do Erro Médio Quadrático
RNAs	Redes Neurais Artificiais
SARIMA	Auto-Regressivos Integrados de Médias Móveis com Sazonalidade
VAR	Vetores Auto-Regressivos

SUMÁRIO

1	INTRODUÇÃO.....	13
1.1	Objetivos.....	14
2	REVISÃO DA LITERATURA.....	15
2.1	Importância da previsão para a eficiência orçamentária.....	15
2.2	Modelos econométricos na previsão de receitas.....	17
2.3	Redes neurais na previsão.....	20
3	DESCRIÇÃO E ANÁLISE DA BASE DE DADOS.....	23
3.1	Composição das Receitas Correntes.....	23
3.2	Variáveis Seleccionadas.....	25
3.3	Séries Históricas.....	26
3.4	Estatísticas Descritivas.....	29
4	METODOLOGIA.....	37
4.1	Modelo Integrado Autorregressivo Médias Móveis Sazonal (SARIMA)..	38
4.2	Modelos de Autorregressão de Redes Neurais Artificiais (NNAR).....	40
5	RESULTADOS E DISCUSSÕES.....	42
5.1	Previsão Receitas Correntes.....	42
5.2	Previsão Transferências Correntes.....	44
5.3	Previsão ICMS.....	46
6	CONCLUSÃO.....	48
	REFERÊNCIAS.....	49

1 INTRODUÇÃO

No âmbito do orçamento público, aprimorar as técnicas de previsão da receita corrente mensal torna-se essencial para promover uma melhoria na capacidade orçamentária do estado. A pertinência deste estudo destaca-se por se posicionar como uma pesquisa em técnicas de previsão voltadas às séries históricas do Estado de Alagoas. Diante desse contexto, a abordagem comparativa entre modelos econométricos de séries temporais, como ARIMA, e redes neurais artificiais, emerge como uma possibilidade para aprimorar as projeções das receitas correntes estaduais. A implementação desses métodos proporcionará uma avaliação mais robusta e eficaz, considerando a complexidade intrínseca da dinâmica econômica alagoana.

Ao delinear esses aspectos, o presente estudo posiciona-se como uma contribuição significativa para o avanço do conhecimento em previsão econômica regional. A análise comparativa proposta não apenas atende às demandas práticas da gestão pública em Alagoas, mas também oferece um arcabouço teórico robusto para pesquisas futuras. Por meio da articulação entre teoria e aplicação prática, espera-se que este trabalho amplie a compreensão sobre a eficácia de diferentes abordagens na previsão das receitas correntes em um contexto regional único e desafiador.

Do ponto de vista social, a importância desse estudo reside na possibilidade de contribuir para a previsão das receitas de Alagoas. Os resultados obtidos podem contribuir para uma alocação mais eficiente de recursos, beneficiando diretamente a população. A implementação de modelos de previsão mais precisos pode resultar em políticas públicas mais eficazes, promovendo o desenvolvimento socioeconômico e melhorando a qualidade de vida dos cidadãos.

1.1 Objetivos

Geral:

Verificar a capacidade preditiva dos modelos SARIMA e redes neurais na previsão das receitas correntes mensais em Alagoas.

Específicos:

- Realizar uma análise detalhada das estatísticas descritivas das séries temporais das receitas correntes mensais em Alagoas, incluindo medidas de tendência central, dispersão e padrões sazonais.
- Verificar a capacidade dos modelos econométricos (SARIMA) em prever a receita corrente mensal em Alagoas, considerando métricas de precisão, como Média Absoluta dos Erros (MAE), Média Absoluta Percentual dos Erros (MAPE) e Raiz do Erro Médio Quadrático (RMSE).
- Avaliar o desempenho de redes neurais (NNAR) na previsão da receita corrente mensal em Alagoas, considerando métricas de precisão, como Média Absoluta dos Erros (MAE), Média Absoluta Percentual dos Erros (MAPE) e Raiz do Erro Médio Quadrático (RMSE).
- Identificar e destacar o modelo que demonstra o melhor desempenho na previsão das receitas correntes em Alagoas, com base nas métricas analisadas.

2 REVISÃO DA LITERATURA

Essa revisão de literatura está dividida em três tópicos, no primeiro tópico (2.1) examina-se a importância da previsão, fornecendo uma base teórica para compreender o papel crítico dessa prática na gestão pública. Em seguida, no tópico (2.2), são explorados os modelos econométricos na previsão, com ênfase em sua aplicação específica no contexto das receitas correntes. O tópico (2.3) direciona o foco para as redes neurais na previsão.

2.1 Importância da previsão para a eficiência orçamentária

A gestão pública, em todas as suas instâncias federal, estadual e municipal, enfrenta a necessidade imperativa de estabelecer mecanismos eficientes¹ de planejamento e organização para gerir suas finanças. Conforme estipulado pela legislação federal, especificamente a Lei Nº 4.320 de 1964, é obrigatório realizar projeções das receitas esperadas e monitorar de perto os gastos, assegurando a conformidade e eficácia na execução das atividades financeiras por parte dos administradores públicos.

Paralelamente, a Lei de Responsabilidade Fiscal (LRF), Lei Complementar nº 101 de maio de 2000, complementa esse quadro normativo ao estabelecer diretrizes para o tratamento das finanças públicas. Essas normativas incluem medidas disciplinares relacionadas à transparência, responsabilidade e integração na gestão fiscal, contribuindo para uma administração financeira eficaz e transparente. O conjunto dessas ferramentas é vital para orientar o governo na conformidade com suas diretrizes orçamentárias, evitando práticas que possam comprometer a integridade financeira e as responsabilidades fiscais.

No contexto constitucional, o Art. 165 da constituição federal confere ao Poder Executivo, em instâncias Federal, Estadual e Municipal, a incumbência de elaborar o Plano Plurianual (PPA), a Lei de Diretrizes Orçamentárias (LDO) e a Lei Orçamentária Anual (LOA). A receita orçamentária no setor público apresenta os seguintes estágios: previsão,

¹ Eficiência: Trata-se de fazer as coisas da maneira mais econômica, minimizando desperdícios e maximizando a produtividade.

lançamento, arrecadações e recolhimento. A previsão faz parte do planejamento, sendo a etapa na qual se estima a arrecadação das receitas orçamentárias constante na LOA.

Dentro do contexto orçamentário brasileiro, as atuais regras fiscais podem resultar em desafios significativos quando confrontadas com um cenário econômico adverso ou uma possível superestimação de receitas. Comprometer-se com despesas que a entidade não possui capacidade de suportar coloca o poder executivo em uma encruzilhada difícil, obrigando-o a escolher entre violar as metas do resultado primário ou implementar cortes nas despesas. Ambas as opções têm implicações prejudiciais para o gestor público, sublinhando, assim, a importância crucial das previsões de receitas (BAPTISTA, 2019).

A previsão das receitas desempenha um papel crucial na formulação do orçamento público, oferecendo a oportunidade de moldar e fundamentar escolhas relacionadas à política fiscal. À medida que as projeções de arrecadação influenciam decisões sobre investimentos, despesas públicas e ajustes, torna-se evidente a importância de realizar essas projeções de maneira meticulosa e precisa.

De acordo com Giambiagi, Alem e Pinto (2021), a qualidade dessa previsão é determinante para a elaboração de orçamentos realistas, evitando desequilíbrios financeiros e permitindo uma gestão mais eficiente dos recursos públicos. A imprecisão na previsão, conforme apontado pelos autores, pode levar a ajustes orçamentários emergenciais, impactando diretamente programas essenciais e a estabilidade macroeconômica.

Nascimento e Boente (2022) conduziram uma pesquisa com o objetivo de investigar os fatores que possam influenciar os erros na previsão orçamentária da receita no setor público, utilizando dados dos municípios brasileiros no período de 2015 a 2018. Com base na teoria econômica das expectativas adaptativas, que sugere que os agentes econômicos formulam expectativas para o futuro com base em eventos passados, os resultados indicaram que erros em previsões anteriores exercem um impacto negativo nas previsões atuais da receita orçamentária, demonstrando persistência e tendência. Esse fenômeno pode resultar, por exemplo, na superestimação da receita, prejudicando a execução das despesas e contribuindo para o aumento do déficit público, além de gerar despesas inscritas em restos a pagar.

Ainda segundo Nascimento e Boente (2022), as conclusões sugerem que a implicação desses resultados aponta, principalmente, para a necessidade de os municípios concentrarem

esforços em fatores internos ao lidar com o erro de previsão, priorizando aprimoramentos nos modelos de previsão, antes de considerar preocupações relacionadas a variáveis externas.

Conforme destacado por Santos e Alves (2011), a otimização do processo de planejamento e execução das receitas e despesas municipais e estaduais desempenha um papel crucial no fortalecimento da capacidade de quitação de dívidas, na busca pelo equilíbrio do superávit primário e no incremento das receitas tributárias. Nesse sentido, a elaboração de previsões orçamentárias precisas emerge como um facilitador para as atividades relacionadas ao planejamento, avaliação, controle e prestação de contas no âmbito do setor público (DA SILVA ZONATTO; HEIN, 2013).

A precisão da previsão orçamentária é fundamental para viabilizar o planejamento eficaz das atividades no âmbito público, assegurando recursos para a manutenção das operações básicas e a realização de obras e investimentos governamentais.

Quando a previsão não atende adequadamente, torna-se necessário realizar ajustes, indicando a urgência de uma reavaliação dos planos previamente estabelecidos. Isso pode comprometer as atividades de planejamento, avaliação, controle e responsabilização no tocante à arrecadação e alocação dos recursos públicos, podendo, inclusive, impactar a manutenção dos serviços.

2.2 Modelos econométricos na previsão de receitas

Nesta seção será feita a contextualização teórica dos métodos econométricos empregados na projeção de receitas em diferentes contextos econômicos. Essas contribuições serão utilizadas como referência para fundamentar o desenvolvimento metodológico da análise a ser conduzida.

A Econometria de acordo com Gujarati e Porter (2011), pode ser compreendida, em termos gerais, como uma "medição econômica". Essa disciplina representa a aplicação de métodos estatísticos e matemáticos aos dados econômicos, visando proporcionar respaldo empírico aos modelos concebidos pela economia.

Além disso, ela se configura como uma análise quantitativa dos fenômenos econômicos, fundamentada nas teorias e observações, fazendo uso de métodos de inferência.

Essa abordagem permite uma compreensão mais profunda e embasada dos aspectos econômicos, contribuindo para a robustez e validade das conclusões alcançadas.

Dentro da literatura, os modelos econométricos de séries temporais são frequentemente utilizados na previsão das receitas correntes. No contexto das séries temporais, destaca-se que este campo se configura como um capítulo distintivo dentro da econometria.

Ao contrário dos modelos econométricos, o foco primordial do estudo de séries temporais reside na realização de previsões. Não há uma preocupação em estabelecer os mecanismos causais; o objetivo é puramente alcançar previsões precisas ao máximo possível (DE ANGELO et al., 2011).

De acordo com Sousa (2012), uma série temporal consiste em observações sequenciais de uma variável ao longo do tempo, sendo classificada como discreta se finita ou infinita enumerável e contínua se infinita e não numerável. As séries podem ser determinísticas, com valores futuros estabelecidos por uma relação funcional matemática, ou estocásticas, quando os valores são probabilísticos, envolvendo uma variável aleatória.

A análise busca identificar padrões para previsões, sendo abordada economicamente por meio de modelos de regressão de equação única, regressão com equações simultâneas, modelos auto-regressivos integrados de média móvel e auto-regressão vetorial.

Segundo Gujarati e Porter (2011), os trabalhos empíricos baseados nos dados de séries temporais supõe que a série subjacente sejam estacionárias. Essa característica viabiliza inferências estatísticas nos parâmetros estimados. A não-estacionariedade representa uma violação de pressuposto, podendo resultar em resultados espúrios (SOUSA, 2012).

Alguns autores aplicaram diversos métodos, como Alisamento Exponencial, modelo auto-regressivo integrado de médias móveis (ARIMA), modelo de vetores auto-regressivos (VAR) e o modelo auto-regressivos integrados de médias móveis com sazonalidade (SARIMA), na previsão de receitas em diferentes contextos econômicos.

Coelho Neto (2014) aplicou modelos ARIMA e VAR para realização de previsão das principais rubricas de gastos e receitas da prefeitura de Maracanaú de acordo com os resultados apresentados, percebeu-se a superioridade dos modelos ARIMA em relação aos modelos VAR para as variáveis Receita Tributária, Despesa em Educação, Despesa em Saúde

e Despesas Correntes, já a proposta vetorial obteve maior aderência na modelagem e previsão das Receitas Correntes da prefeitura.

Pessoa, Coronel e Lima (2013) focaram na previsão do Imposto Sobre Circulação de Mercadorias e Serviços (ICMS) do Estado de Minas Gerais comparando modelos ARIMA E ARFIMA, os resultados indicaram a melhor eficácia do modelo ARIMA. Scheffer, Souza e Zanini (2014), aplicaram Box-Jenkins para prever a arrecadação do ICMS no Rio Grande do Sul, identificando SARIMA como o modelo mais adequado. Clemente (2011) também focou na previsão do ICMS voltado para as séries históricas do estado do Paraná utilizando a metodologia de Box - Jenkins, os resultados indicaram a melhor eficácia do modelo SARIMA. Santos (2003) aplicou técnicas como Alisamento Exponencial e Modelos ARIMA para prever o Imposto de Renda, superando modelos anteriores.

Caldart (2006) propôs previsões para o Imposto sobre Serviços (ISS) do município de Caxias do Sul, usando o modelo ARIMA, destacando a boa capacidade do modelo estimado para realizar previsões de curto prazo.

Claudio Cordeiro Teti (2009) aplicaram Modelos Box e Jenkins para prever receitas oriundas do ICMS do Estado de Pernambuco, o autor conclui que o modelo de previsão utilizando séries temporais, em função de sua capacidade preditiva, pode se transformar em um valioso instrumento para auxiliar na elevação da receita tributária no Estado de Pernambuco.

Fabris e Gonçalves (2012) aplicaram Modelos Box e Jenkins para prever receitas de impostos em Criciúma, destacando a eficácia do ARIMA para ICMS. Benelli (2013) aprimorou a previsão da Receita Federal com modelos VAR, obtendo resultados eficientes.

Almeida (2017) construiu modelos estatísticos para prever a arrecadação do ICMS em Minas Gerais, utilizando Alisamento Exponencial e SARIMA. Destacou a baixa previsão devido à crise econômica em 2016 e 2017.

No contexto geral, observa-se uma lacuna na literatura em relação à estimativa da receita corrente de alagoas usando modelos econométricos. vários autores têm apresentados estudos a respeito de técnicas econométricas para previsão da receita, dentre os modelos econométricos comumente empregados na previsão de receitas, destaca-se os modelos de séries temporais, como ARIMA, que têm sido essenciais na identificação de tendências temporais nas receitas, sendo particularmente úteis em cenários econômicos dinâmicos.

Esta revisão de literatura destaca os métodos utilizados em cada estudo, fornecendo uma visão abrangente das abordagens adotadas na literatura revisada. Na seção seguinte, será explorada as redes neurais.

2.3 Redes neurais na previsão

Os computadores embora sejam considerados uma invenção moderna, os estudos que buscavam reproduzir o comportamento Inteligente do Homem remontam à época vitoriana (PORTUGAL; FERNANDES, 1996). As Redes Neurais Artificiais (RNAs) é uma tentativa de simulação matemática do princípio básico do funcionamento dos componentes mais elementares do sistema nervoso humano.

A inspiração biológica parte do desenvolvimento e a evolução dos seres vivos que levaram à especialização dos tecidos e à criação de sistemas de coordenação, sendo o sistema nervoso um dos principais nessa coordenação. O tecido nervoso é formado por neurônios, células especializadas que respondem a estímulos, processam informações e transmitem sinais.

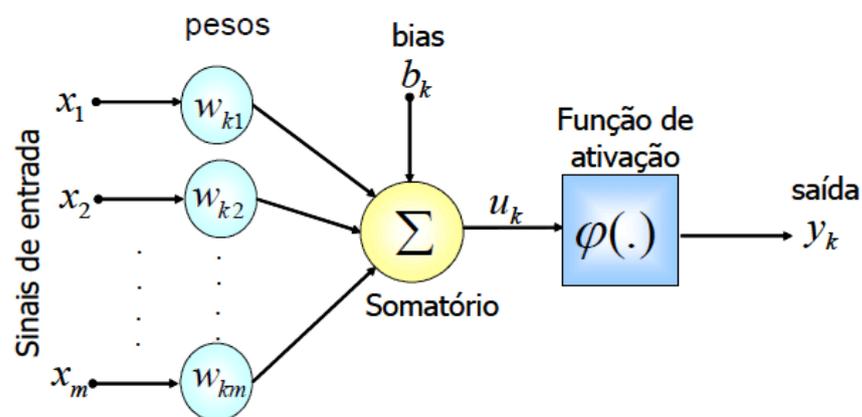
Paralelamente, a inteligência artificial também evoluiu inspirada na estrutura do cérebro, simulando o comportamento humano através de unidades de processamento chamadas neurônios artificiais, os quais, similarmente aos neurônios biológicos, recebem, processam e transmitem informações. Os neurônios artificiais são fundamentais nos sistemas de aprendizado de máquina, onde sua estrutura se assemelha aos neurônios biológicos.

A estrutura de um neurônio artificial pode ser descrita como na Figura 1, assim como os dendritos de um neurônio biológico, um neurônio artificial recebe várias entradas de dados (X_1, X_2, \dots, X_m), cada entrada é associada a um peso, que determina sua influência no cálculo final. Os pesos sinápticos ($W_{K1}, W_{K2}, \dots, W_{Km}$) representam a força ou a importância de cada entrada. Eles multiplicam o valor da entrada correspondente. Após a multiplicação das entradas pelos seus respectivos pesos, os resultados são somados pelo produtor escalar (Σ), para obter uma saída única depois da adição, este sinal é processado através da função que representa o limite ou função de ativação $\varphi(\cdot)$.

Essa função determina como o neurônio dispara com base na soma ponderada das

entradas. Conforme Ferreira et al. (2016), ela introduz não-linearidades na rede neural, permitindo a modelagem de relações complexas, qual produz um sinal de saída y_k o resultado da função de ativação é a saída do neurônio, que pode servir como entrada para outros neurônios na rede neural, na figura 1, o neurônio pode ser considerado como uma representação simplificada dos neurônios biológicos.

Figura 1 - Neurônio Artificial



Fonte: SOARES, Pablo; SILVA, José Patrocínio. 2011

Assim como as células nervosas do corpo humano, os neurônios artificiais buscam integrar e processar informações para aprender e executar tarefas. Os avanços na área da inteligência artificial permitem não apenas imitar, mas também otimizar a aprendizagem desses neurônios sintéticos para alcançar desempenho e eficiência semelhantes ou superiores aos dos sistemas biológicos.

A disseminação da utilização de RNAs em previsões ganhou destaque a partir da introdução do algoritmo de erro back - propagation para o treinamento de redes de múltiplas camadas, por volta de 1986. Este algoritmo, desencadeou um avanço significativo ao permitir o ajuste iterativo dos pesos das conexões da rede neural com base na comparação entre as saídas previstas e os valores reais do conjunto de treinamento e foi fundamental para estabelecer a capacidade inicialmente reconhecida como não linear das RNAs (DE ANGELO et al., 2011).

Desde então, diversos pesquisadores têm conduzido testes comparativos entre a

efetividade das RNAs e recursos estatísticos, buscando avaliar o desempenho dessas redes em diferentes contextos.

Baptista (2019) propôs em seu trabalho um estudo de métodos para aumentar a precisão das previsões de receitas no município de Belo Horizonte, modelos de combinação de previsões apresentaram um melhor desempenho para as quatro séries seguintes: Imposto sobre a Propriedade Predial e Territorial Urbana (IPTU); ISS; Receita Corrente e Receita Corrente Líquida; enquanto o método de redes neurais fez a melhor previsão para Imposto sobre a Transmissão de Bens Imóveis (ITBI) e Receita de Transferências. De Angelo et al. (2011) fizeram em seu trabalho uma análise comparativa de RNAs e o ARIMA na previsão de vendas do varejo brasileiro, as RNAs se mostram superior ao ARIMA.

Ferreira et al. (2016) aplicaram (RNAs) para prever a demanda diária de encomendas em um Centro de Tratamento de Encomendas ao longo de quinze dias. Os resultados obtidos demonstram que a aplicação das RNAs na previsão da demanda de encomendas apresentou uma boa aderência aos dados experimentais tanto nas fases de treinamento quanto nas de teste.

Aires, Dametto e Crepaldi (2018), aplicou RNAs na previsão do índice Bovespa e dos preços das ações, com objetivo de averiguar o poder de previsão das redes neurais em período de crises especificamente a crise do subprime, as redes apresentaram desempenho satisfatórios mesmo com período de crises. Furtuoso, Santos e Quintal (2022), aplicaram um modelo de rede neural recorrente, fundamentado em séries temporais, com o objetivo de prever e estimar os preços de ações. Os resultados destacaram a eficácia da rede neural em aprender com complexidades intrínsecas aos dados, sugerindo sua aplicabilidade em diversas áreas.

3 DESCRIÇÃO E ANÁLISE DA BASE DE DADOS

A LRF determina que o orçamento seja utilizado como uma ferramenta de transparência, sendo crucial promover sua ampla divulgação, inclusive por meio de plataformas eletrônicas de acesso público. Assim, os dados para análise dessa monografia foram coletados diretamente do Portal da Transparência do Estado de Alagoas cujo período é de janeiro de 2007 a dezembro de 2023. Cabe ressaltar que toda a base de dados utilizada neste estudo foi ajustada pelo Índice Nacional de Preços ao Consumidor Amplo (IPCA) e está expressa em valores relativos a dezembro de 2023.

3.1 Composição das Receitas Correntes

Segundo Giacomoni (2021), as receitas são divididas em duas categorias econômicas, receitas correntes e receitas de capital. As receitas correntes, de regra geral, são arrecadadas dentro do exercício financeiro. Estas aumentam as disponibilidades financeiras do estado, provocando efeitos positivos sobre o patrimônio líquido, constituindo-se meios para financiar os objetivos definidos nos programas e ações orçamentárias, com vistas a satisfazer finalidades públicas. As receitas ainda são divididas em suas origens conforme o Quadro 1.

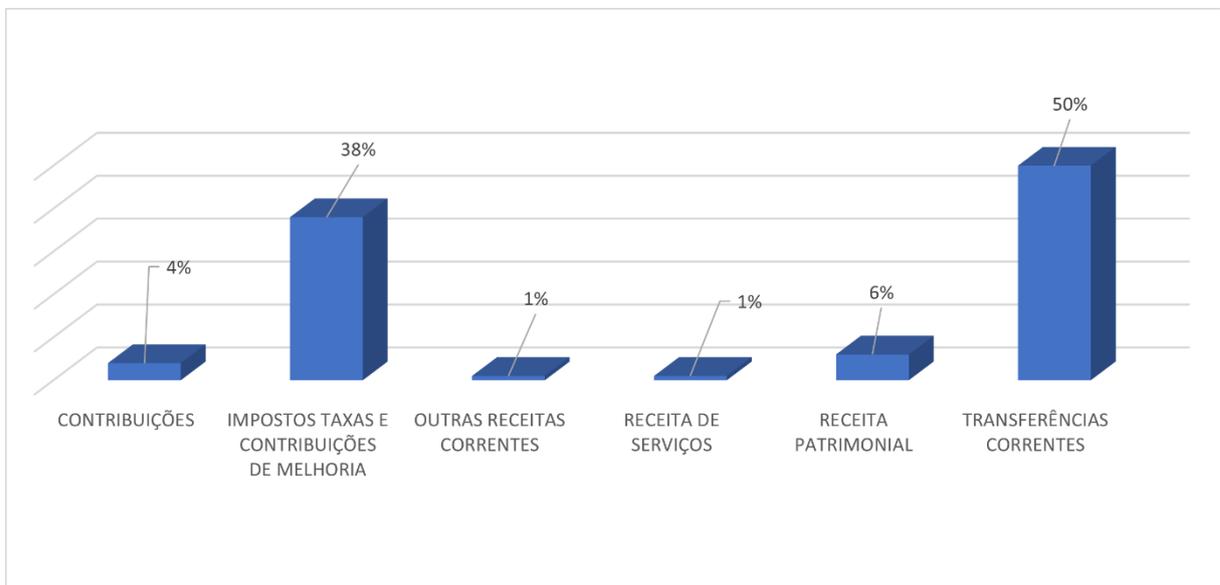
Quadro 1 – Receitas Correntes

Categoria Econômica	Origem
1. Receitas Correntes	1. Impostos, Taxas e Contribuições de Melhoria 2. Contribuições 3. Receita Patrimonial 4. Receita Agropecuária 5. Receita Industrial 6. Receita de Serviço 7. Transferências Correntes 9. Outras Receitas Correntes

Fonte: elaborado pelo autor.

Na Figura 2, destaca-se a notável predominância das transferências correntes, as quais representam cerca da metade da arrecadação total do estado, desempenhando um papel significativo na composição das receitas. Para analisar a composição das receitas correntes do estado de Alagoas, foi calculado a média das origens das receitas correntes ao longo dos últimos cinco anos (2018 a 2023).

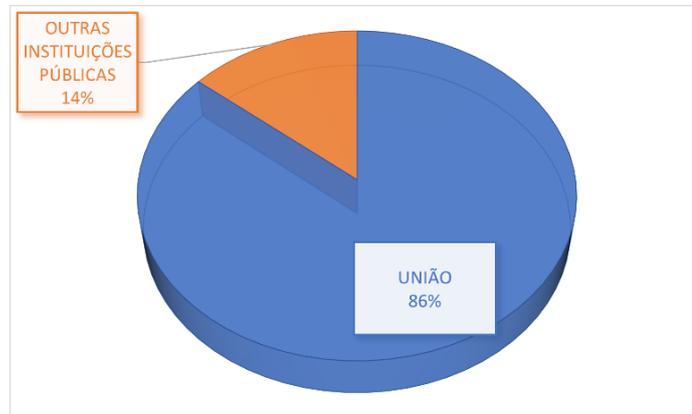
Figura 2- Média da Composição das Receitas Correntes de 2018 a 2023



Fonte: elaborado pelo autor.

Uma análise na Figura 3 revela que uma expressiva parcela de 86% das transferências correntes tem origem na União, enquanto os restantes 14% provêm de outras instituições públicas. Este dado confere uma singularidade a série temporal de Alagoas. Uma vez que evidencia a marcante dependência da receita corrente estadual dessas transferências.

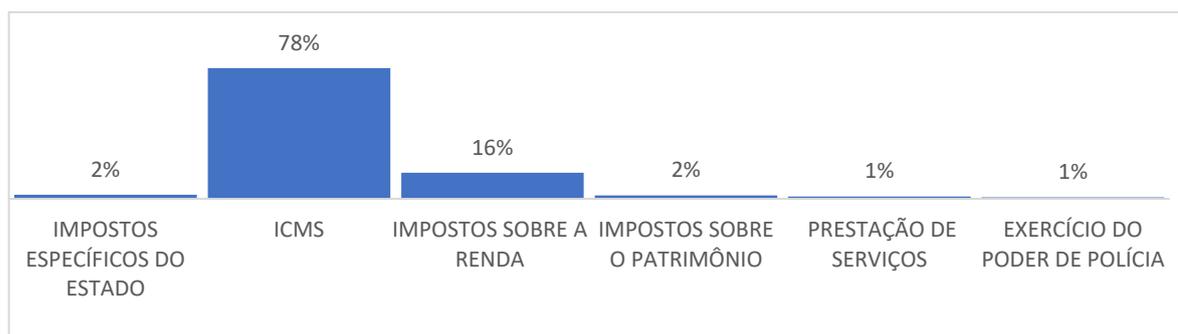
Figura 3 - Origem das Transferências Correntes



Fonte: elaborado pelo autor.

A segunda fonte mais significativa das receitas correntes provém dos impostos, taxas e contribuições de melhorias com 38%. Notavelmente, o ICMS assume uma posição predominante, contribuindo com 78% da arrecadação total dessa categoria, como evidenciado na Figura 4. Adicionalmente, 16% são provenientes de impostos sobre a renda.

Figura 4 - Estrutura Tributária



Fonte: elaborado pelo autor.

3.2 Variáveis Seleccionadas

Com base na composição das receitas correntes ao longo dos últimos cinco anos, as

variáveis selecionadas para previsão com base na sua relevância são apresentadas no Quadro 2, as transferências correntes representam metade da arrecadação corrente mensal do estado e o ICMS 78% dos impostos mensais arrecados pelo estado.

Quadro 2 - Lista de Variáveis

Variável	Descrição
Receita Corrente	Registra as receitas tributárias, de contribuições, patrimonial, agropecuária, industrial, de serviços e as provenientes de recursos financeiros recebidos de outras pessoas de direito público ou privado, quando destinadas a atender despesas classificáveis em despesas correntes.
Transferências Correntes	Montante recebido por meio de transferências de recursos entre entidades, normalmente de origem pública, destinado ao Estado de Alagoas.
ICMS	Imposto sobre Circulação de Mercadorias e Serviços, uma importante fonte de receita para o Estado de Alagoas.

Fonte: elaborado pelo autor.

Os valores dessas variáveis variam de milhões a bilhões de reais. Para simplificar a representação gráfica dessas variáveis nesta monografia, todas foram apresentadas em notação científica de 10^9 , ou seja, em bilhões de reais.

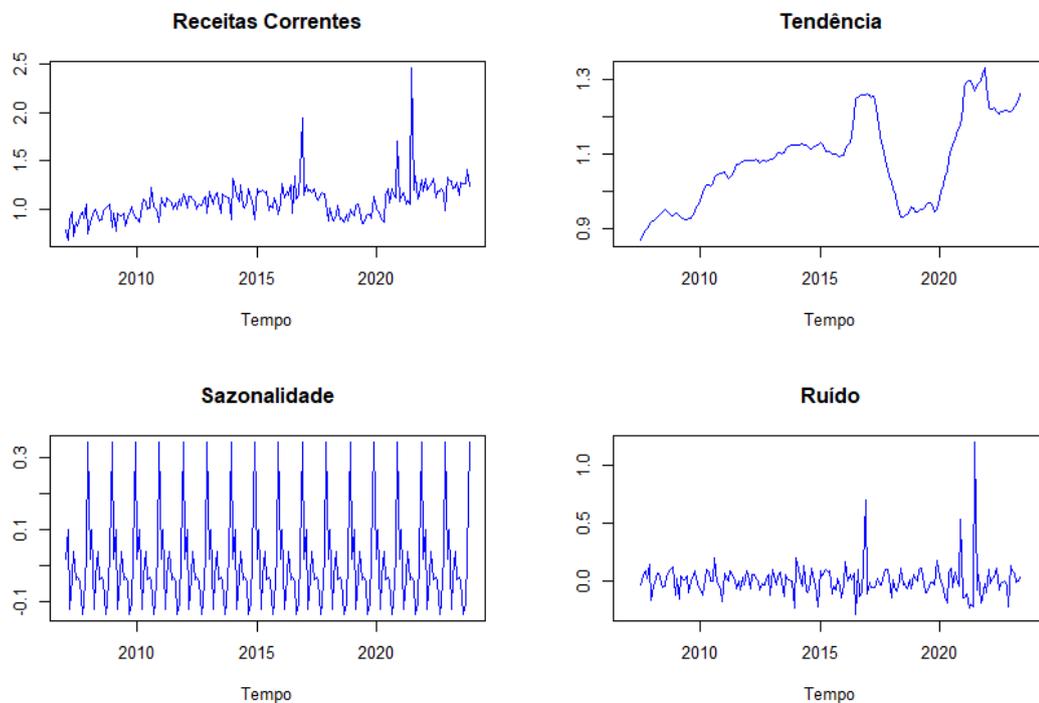
3.3 Séries Históricas

As séries históricas podem ser visualizadas nas Figuras 5 e 6, que mostra respectivamente as receitas correntes e as receitas de transferências, enquanto a Figura 7 mostra graficamente a representação do ICMS para o estado de Alagoas de janeiro de 2007 a dezembro de 2023.

Essa decomposição temporal das séries proporciona uma análise temporal da evolução mensal das receitas, permitindo uma avaliação das tendências que as três séries parecem

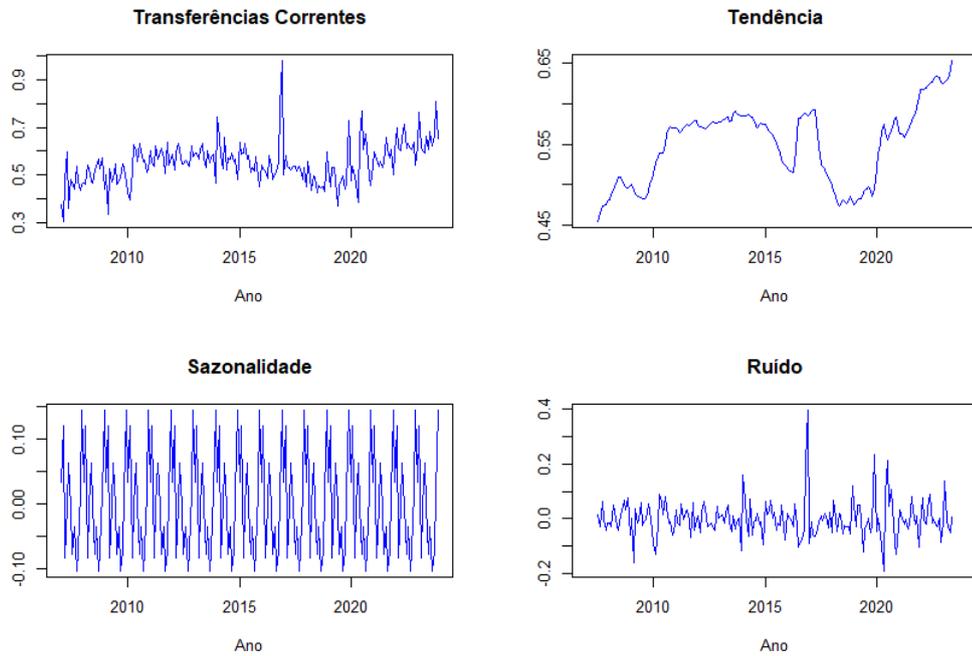
apresentar, todas exibindo características estocásticas. Além disso, observa-se que as três séries exibem sazonalidade definida, indicando padrões que se repetem ao longo do tempo, como variações mensais. Os ruídos das séries, que representam as flutuações aleatórias ou não sistemáticas, mostram uma variação significativa ao longo do período analisado. Isso sugere a presença de uma variabilidade intrínseca nos dados, conferindo a dificuldade de fazer previsões precisas para as receitas correntes do estado de Alagoas.

Figura 5 - Série Temporal Receitas Correntes



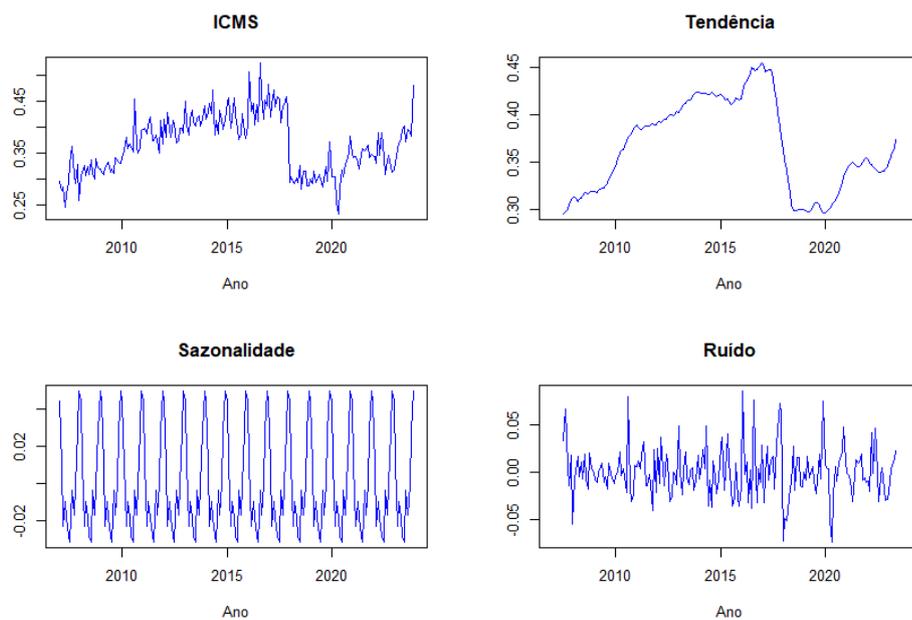
Fonte: elaborado pelo autor.

Figura 6 - Série Temporal Transferências Correntes



Fonte: elaborado pelo autor.

Figura 7 - Série Temporal ICMS

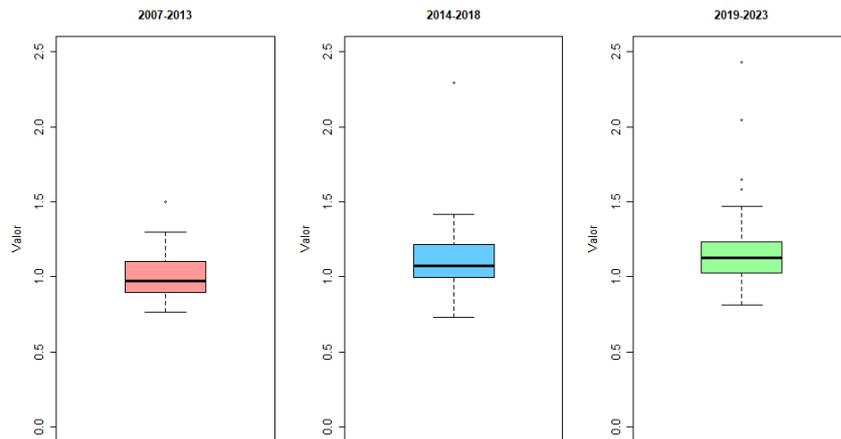


Fonte: elaborado pelo autor.

3.4 Estatísticas Descritivas

Para analisar as estatísticas descritivas das séries, foram construídos box plots, divididos em três conjuntos de anos: de 2007 a 2013, de 2013 a 2018 e, por fim, de 2019 a 2023. O box plot das Receitas Correntes pode ser visualizado na Figura 8. Observa-se um aumento consistente na arrecadação das receitas correntes ao longo dos períodos analisados.

Figura 8 - Box Plot (Receitas Correntes)



Fonte: elaborado pelo autor.

A Tabela 1 apresenta os dados do box plot das Receitas Correntes. No período de 2007 a 2013, observa-se uma variação que vai de 765,70 milhões a 1,13 bilhões. A mediana está aproximadamente em 975,18 milhões, e o terceiro quartil em torno de 1,10 bilhões.

No intervalo de 2014 a 2018, há uma variação mais ampla em comparação com o período anterior, indo de 730,73 milhões a 1,41 bilhões. A mediana fica em cerca de 1,07 bilhões, enquanto o terceiro quartil está em aproximadamente 1,22 bilhões.

Por fim, no período de 2019 a 2023, a variação é maior do que no primeiro período analisado, mas menor do que no período anterior, oscilando entre 813,80 milhões e 1,47 bilhões. A mediana está em torno de 1,13 bilhões, e o terceiro quartil em aproximadamente 1,23 bilhões. Essa tendência positiva na mediana ao longo do período analisado sugere um

aumento constante na arrecadação ao longo dos períodos.

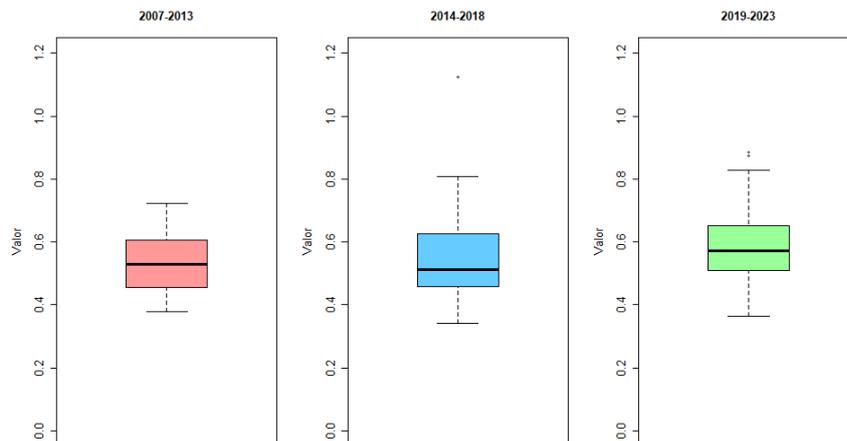
Tabela 1- Dados do Box Plot das Receitas Correntes

PERÍODO	MÍNIMO	Q1	MEDIANA	Q3	MÁXIMO
2007 - 2013	765.706.021,00	895.343.589,00	975.184.215,00	1.105.028.178,00	1.296.770.086,00
2014 - 2018	730.737.008,00	993.227.386,00	1.070.353.338,00	1.217.880.285,00	1.414.363.315,00
2019 – 2023	813.779.314,00	1.024.579.207,00	1.127.151.807,00	1.231.590.261,00	1.469.277.599,00

Fonte: elaborado pelo autor.

Na Figura 9, é possível visualizar o box plot das Transferências Correntes. Ao contrário das Receitas Correntes, não se observa um aumento consistente na arrecadação das Transferências Correntes ao longo dos períodos analisados.

Figura 9 - Box Plot Transferências Correntes



Fonte: elaborado pelo autor.

A Tabela 2 apresenta os dados do box plot das Transferências Correntes. No período de 2007 a 2013, observa-se a menor variação entre os períodos analisados, que vai de 455,49 milhões a 723,29 milhões. A mediana está aproximadamente em 529,14 milhões, e o terceiro quartil em torno de 604,96 milhões.

No intervalo de 2014 a 2018, há uma variação mais ampla em comparação com o período anterior, indo de 457,36 milhões a 807,41 milhões. A mediana fica em cerca de 511,36 milhões, enquanto o terceiro quartil está em aproximadamente 626,69 milhões.

Por fim, no período de 2019 a 2023, a variação é maior do que no primeiro período analisado, mas menor do que no período anterior, oscilando entre 509,09 milhões e 827,49 milhões. A mediana está em torno de 570,99 milhões, e o terceiro quartil em aproximadamente 650,98 milhões. Essa tendência negativa na mediana do primeiro período para o segundo, seguido de uma variação positiva do segundo para o terceiro período, não sugere um aumento constante na arrecadação ao longo dos períodos, como observado nas receitas correntes.

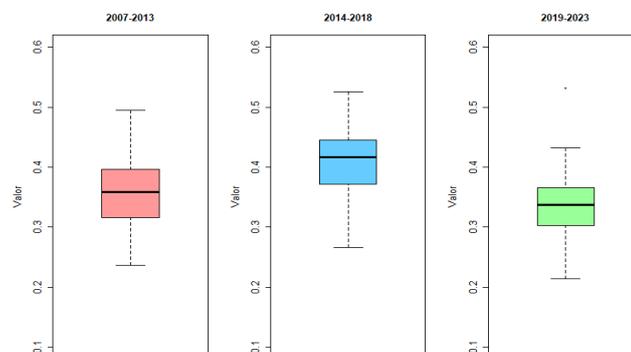
Tabela 2 - Dados do Box Plot das Transferências Correntes

PERÍODO	MÍNIMO	Q1	MEDIANA	Q3	MÁXIMO
2007 - 2013	379.476.682,00	455.495.249,00	529.137.579,00	604.961.304,00	723.294.344,00
2014 - 2018	341.653.569,00	457.366.855,00	511.365.412,00	626.686.150,00	807.414.740,00
2019 – 2023	363.657.732,00	509.097.310,00	570.998.081,00	650.981.794,00	827.495.730,00

Fonte: elaborado pelo autor.

Na Figura 10, é possível visualizar o box plot do ICMS. Observa-se um aumento na arrecadação do primeiro período analisado para o segundo, porém, uma queda do segundo para o terceiro período na arrecadação ao longo dos períodos analisados.

Figura 10 - Box Plot ICMS



Fonte: elaborado pelo autor.

A Tabela 3 apresenta os dados do box plot do ICMS. Observa-se que os períodos analisados têm quase a mesma amplitude de variação nos dados. No período de 2007 a 2013, a variação vai de 235,94 milhões a 494,26 milhões. A mediana está aproximadamente em 358,18 milhões, e o terceiro quartil em torno de 396,38 milhões.

No intervalo de 2014 a 2018, a variação vai de 265,63 milhões a 526,18 milhões. A mediana fica em cerca de 417,08 milhões, enquanto o terceiro quartil está em aproximadamente 444,82 milhões.

Por fim, no período de 2019 a 2023, a variação oscila entre 214,14 milhões e 431,45 milhões. A mediana está em torno de 337,73 milhões, e o terceiro quartil em aproximadamente 366,12 milhões. Essa queda da mediana no último período analisado em comparação com os períodos anteriores indica uma redução na arrecadação do ICMS no período de 2019 a 2023.

Tabela 3 - Dados do Box Plot ICMS

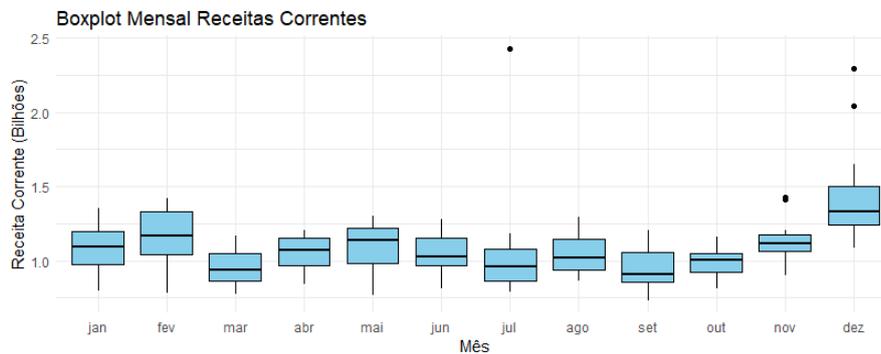
PERÍODO	MÍNIMO	Q1	MEDIANA	Q3	MÁXIMO
2007 - 2013	235.945.717,00	316.140.919,00	358.184.676,00	396.384.288,00	494.265.535,00
2014 - 2018	265.631.549,00	371.228.166,00	417.083.327,00	444.819.072,00	526.018.324,00
2019 – 2023	214.137.947,00	303.170.915,00	337.729.701,00	366.121.340,00	431.452.971,00

Fonte: elaborado pelo autor.

Para facilitar a interpretação do comportamento das receitas, foram criados outros Box Plots, que demonstram a distribuição dos dados de cada mês em cada série temporal para o período analisado de 2007 a 2023. A análise desses gráficos revela padrões mensais sazonais importantes das séries temporais. Ao longo dos meses, observam-se variações consistentes nos valores medianos e nos quartis, indicando tendências sazonais. Os meses finais do ano, como dezembro, exibem consistentemente valores mais elevados.

A Figura 11 exibe o Box Plot mensal das Receitas Correntes, proporcionando uma visão da distribuição dessas receitas ao longo dos doze meses do ano. Visualmente, é perceptível que o mês de dezembro se destaca como o de maior arrecadação

Figura 11 - Box Plot Mensal Receitas Correntes



Fonte: elaborado pelo autor.

Ao analisar a Tabela 3, que apresenta os dados do box plot da série temporal receitas correntes, é possível identificar padrões mensais sazonais significativos. Conforme observado anteriormente, os meses finais do ano, como dezembro, consistentemente registram valores mais elevados, com a mediana das receitas correntes atingindo 1,31 bilhões de reais, em comparação com outros meses. Em contrapartida, os meses de março, julho e setembro geralmente exibem queda nas receitas. Os meses de julho, novembro e dezembro possuem outliers.

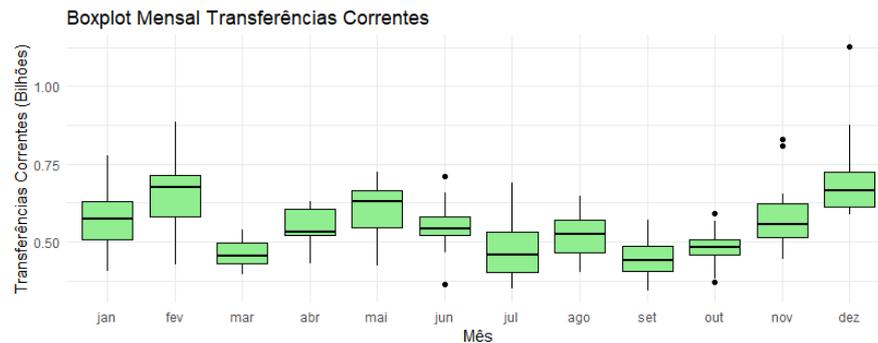
Tabela 3 – Dados do Box Plot Mensal Receitas Correntes

MÊS	LIM. INFERIOR	Q1	MEDIANA	Q3	LIM. SUPERIOR
JAN	798.341.576,00	971.670.311,00	1.093.303.639,00	1.200.422.271,00	1.352.597.219,00
FEV	780.793.377,00	1.038.609.591,00	1.164.121.085,00	1.331.314.325,00	1.419.090.527,00
MAR	774.115.965,00	861.763.439,00	934.118.685,00	1.049.912.696,00	1.167.216.943,00
ABR	843.009.520,00	963.811.691,00	1.073.528.947,00	1.149.691.702,00	1.205.164.963,00
MAI	765.706.021,00	980.587.644,00	1.134.102.268,00	1.215.846.673,00	1.297.855.794,00
JUN	813.779.314,00	963.627.054,00	1.022.947.060,00	1.149.316.478,00	1.281.811.250,00
JUL	790.362.935,00	865.944.177,00	961.881.410,00	1.077.455.164,00	1.180.742.454,00
AGO	863.191.287,00	938.041.757,00	1.022.681.766,00	1.142.024.391,00	1.296.997.767,00
SET	730.737.008,00	858.164.001,00	906.928.008,00	1.057.026.321,00	1.206.332.563,00
OUT	807.885.153,00	922.630.354,00	1.005.729.960,00	1.045.257.906,00	1.162.702.004,00
NOV	903.481.450,00	1.065.779.017,00	1.112.376.836,00	1.174.897.646,00	1.201.407.385,00
DEZ	1.083.133.552,00	1.239.678.663,00	1.328.028.916,00	1.501.245.652,00	1.649.127.471,00

Fonte elaborado pelo autor.

A Figura 12 exibe o Box Plot mensal da Transferências, proporcionando uma visão da distribuição dessas receitas ao longo dos doze meses do ano.

Figura 12 - Box Plot Mensal Transferências Correntes



Fonte: elaborado pelo autor.

Na Tabela 4, os valores mensais de transferências correntes variam ao longo do ano, com picos em fevereiro, maio e dezembro. Janeiro registra uma mediana de cerca de 573,99 milhões, aumentando consideravelmente para aproximadamente 673,62 milhões em fevereiro. Maio destaca-se com uma mediana de aproximadamente 628,80 milhões. Março, julho e setembro mostram uma queda, com medianas em torno de 454,39 milhões, 459,21 milhões e 440,44 milhões, respectivamente. Alguns meses apresentam outliers, como junho, outubro, novembro e dezembro.

Tabela 4 – Dados do Box Plot Mensal Transferências Correntes

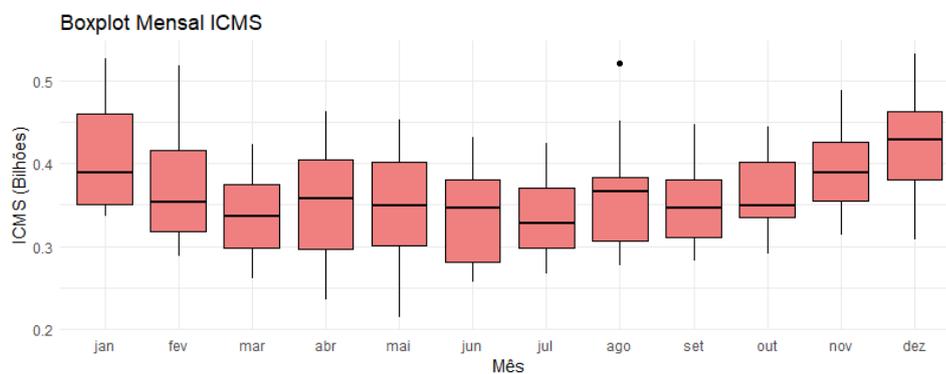
MÊS	LIM. INFERIOR	Q1	MEDIANA	Q3	LIM. SUPERIOR
JAN	406.419.175,00	507.743.490,00	573.996.841,00	629.224.750,00	778.128.787,00
FEV	425.120.139,00	579.171.262,00	673.615.474,00	712.661.684,00	884.776.059,00
MAR	394.748.242,00	430.069.769,00	454.390.249,00	498.136.253,00	538.744.045,00
ABR	431.378.829,00	520.964.006,00	533.148.695,00	604.641.597,00	628.564.062,00
MAI	422.037.274,00	546.325.906,00	628.799.645,00	665.631.337,00	723.527.434,00
JUN	464.357.331,00	519.756.310,00	541.700.672,00	579.438.757,00	656.777.807,00
JUL	348.369.537,00	401.767.250,00	459.208.322,00	530.180.511,00	689.781.294,00
AGO	402.926.252,00	464.659.141,00	524.705.200,00	569.413.556,00	647.515.536,00
SET	341.653.569,00	406.836.537,00	440.436.078,00	486.138.513,00	570.601.576,00
OUT	381.117.033,00	456.600.249,00	482.846.214,00	507.487.273,00	564.851.951,00
NOV	444.605.773,00	513.369.664,00	555.577.159,00	622.475.537,00	652.595.144,00

DEZ 586.157.175,00 612.334.176,00 664.322.133,00 723.294.344,00 875.035.623,00

Fonte elaborado pelo autor.

A Figura 13 exibe o Box Plot mensal do ICMS, proporcionando uma visão da distribuição dessas receitas ao longo dos doze meses do ano.

Figura 13 - Box Plot Mensal ICMS



Fonte: elaborado pelo autor.

Para o ICMS, observa-se na Tabela 5 uma variação nos valores medianos e quartis ao longo dos meses, indicando diferentes níveis de arrecadação. Os meses de pico são janeiro, novembro e dezembro, onde a mediana atinge, respectivamente, 388,15 milhões, 388,29 milhões e 428,52 milhões de reais. Por outro lado, os meses com menor arrecadação são março e julho, com medianas de 335,96 milhões e 327,89 milhões de reais.

Tabela 5 - Dados do Box Plot Mensal ICMS

MÊS	LIM. INFERIOR	Q1	MEDIANA	Q3	LIM. SUPERIOR
JAN	335.760.501,00	350.381.833,00	388.156.837,00	460.065.692,00	526.018.324,00
FEV	288.012.688,00	318.089.262,00	352.808.738,00	415.445.511,00	518.135.217,00
MAR	261.581.557,00	298.020.643,00	335.966.970,00	375.239.643,00	422.315.694,00
ABR	235.945.717,00	296.804.655,00	357.690.624,00	404.850.665,00	463.109.697,00
MAI	214.137.947,00	300.886.189,00	348.616.444,00	401.003.522,00	453.243.543,00
JUN	256.542.088,00	280.432.210,00	346.310.300,00	379.973.860,00	431.560.440,00
JUL	267.217.332,00	297.387.842,00	327.897.563,00	370.870.969,00	423.784.999,00
AGO	276.389.196,00	306.984.738,00	365.824.484,00	383.328.907,00	451.778.953,00

SET	281.852.986,00	310.775.705,00	346.335.968,00	379.830.724,00	447.257.703,00
OUT	290.865.120,00	335.141.885,00	349.453.809,00	401.957.061,00	444.197.784,00
NOV	313.774.496,00	354.872.096,00	388.285.430,00	425.157.760,00	487.753.958,00
DEZ	307.944.294,00	379.903.923,00	428.520.705,00	462.195.947,00	531.315.722,00

Fonte: elaborado pelo autor.

Essas análises descritivas forneceram informações valiosas sobre o comportamento das séries temporais, incluindo padrões de tendências de aumento ou diminuição da arrecadação e padrões de sazonalidade mensal.

Para a série temporal das Receitas Correntes, é evidente um aumento constante na mediana ao longo dos anos, indicando um crescimento na arrecadação. Além disso, padrões sazonais mensais são observados, com os meses finais do ano, especialmente dezembro, consistentemente registrando valores mais elevados. Por outro lado, março, julho e setembro geralmente mostram quedas nas receitas.

No caso da série temporal das Transferências Correntes, é notável uma tendência negativa na mediana do primeiro período para o segundo, seguida por uma variação positiva do segundo para o terceiro período. Isso sugere uma flutuação na arrecadação ao longo do tempo, sem um aumento constante, como observado nas receitas correntes. Os valores mensais das transferências correntes também variam ao longo do ano, com picos em fevereiro, maio e dezembro, enquanto março, julho e setembro mostram quedas nas medianas.

Para a série temporal do ICMS, destaca-se uma queda na mediana no período de 2019 a 2023, indicando uma redução na arrecadação durante esse intervalo de tempo. Os valores mensais do ICMS apresentam variações ao longo do ano, com picos observados em janeiro, novembro e dezembro, enquanto março e julho registram quedas.

4 METODOLOGIA

A metodologia adotada neste estudo é de natureza aplicada, conforme descrito por Marconi e Lakatos (2004), uma vez que visa a produção de conhecimentos direcionados para a solução de um problema específico. No caso, o problema em questão é a previsão das receitas correntes mensais do Estado de Alagoas. A pesquisa também possui caráter exploratório, como destacado por Gil (2002), uma vez que busca desenvolver e esclarecer conceitos e ideias relacionadas à análise comparativa entre modelos econométricos de séries temporais e redes neurais. Essa abordagem exploratória é fundamental para a formulação de problemas mais precisos e hipóteses pesquisáveis, fornecendo uma visão geral, ainda que aproximativa, sobre o fenômeno em estudo.

Essa abordagem fornecerá informações valiosas sobre a eficácia de diferentes métodos de previsão aplicados à receita corrente mensal, contribuindo para aprimorar as práticas de previsão de receitas correntes na região de Alagoas. Para alcançar esse objetivo, a abordagem metodológica incluirá a separação dos dados em conjuntos de treino e teste. O conjunto de treino abrangerá o período de 2007 a 2022, enquanto o conjunto de teste compreenderá o ano de 2023. A divisão em conjuntos de treino e teste permitirá avaliar o desempenho dos modelos, contribuindo para uma análise mais robusta.

Na etapa de seleção de modelos, para os modelos econométricos, foram utilizados os modelos SARIMA, considerando a sazonalidade nas receitas do estado e suas eficácias em séries temporais econômicas, conforme revisão da literatura. No âmbito das redes neurais, as estruturas de redes selecionadas incluem Modelos de Autorregressão de Redes Neurais Artificiais (NNAR).

Para avaliação do desempenho dos modelos, foram utilizados três métricas: Média Absoluta dos Erros (MAE), Média Absoluta Percentual dos Erros (MAPE) e Raiz do Erro Médio Quadrático (RMSE). O modelo escolhido é aquele que apresentar o menor valor em cada uma dessas métricas. As equações para o cálculo dessas métricas são as seguintes:

$$MAE = \frac{1}{N} \sum_{i=1}^N |Y_i - \hat{Y}_i| \quad (1)$$

$$\text{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \quad (2)$$

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (Y_i - \hat{Y}_i)^2} \quad (3)$$

Onde N é o número de observações;

Y_i são os valores reais;

e \hat{Y}_i são as previsões

Essas métricas permitirão uma compreensão aprofundada do quão bem os modelos conseguem prever a receita corrente em comparação com os dados reais, fundamentando a escolha do modelo mais eficaz para Alagoas.

4.1 Modelo Integrado Autorregressivo Médias Móveis Sazonal (SARIMA)

Para lidar com a presença de autocorrelação sazonal, Box e Jenkins (1976) propuseram uma generalização do modelo ARIMA, introduzindo o modelo ARIMA sazonal multiplicativo, comumente conhecido como SARIMA(p,d,q)(P,D,Q)m, onde o segundo componente faz referência à parte sazonal e m significa o número de períodos por estação, a ênfase do modelo está na análise probabilística, ou estocástica.

O conjunto de modelos de séries temporais do qual o SARIMA faz parte possibilita que sejam elaboradas previsões acuradas quando as variáveis explicativas são desconhecidas. Nele, a variável y é explicada por seus próprios valores passados, ou defasados, e pelos termos de erro estocástico o modelo geral pode ser visualizado na equação:

$$\Phi_P(L^S)\alpha_p(L)(1 - L^S)^D(1 - L)^d Y_t = C + \theta_q(L)\Theta_Q(L^S)\varepsilon_t \quad (4)$$

Onde:

$\phi_p(L^S)$ – Parte auto-regressiva sazonal de ordem P e estação sazonal S;

$\alpha_p(L)$ – Parte auto-regressiva não sazonal de ordem p

$(1 - L^S)^D$ – Parte da integração sazonal de ordem D e estação sazonal S;

$(1 - L)^d$ – Parte da integração não sazonal de ordem d;

$\theta_q(L)$ – Parte das médias móveis não sazonal de ordem q;

$\Theta_Q(L^S)$ – Parte sazonal das médias móveis de ordem Q estação sazonal S.

De acordo com Gujarati e Porter (2011) para implementar a metodologia é necessário seguir quatro etapas para construção do modelo de Box e Jenkins: Identificação, Estimação, Diagnóstico e Previsão. A primeira é a de identificação dos valores apropriados de p, d, q.

Para os valores de p e q é analisado as funções de autocorrelação (FAC) e autocorrelação parcial (FACP). A ordem d do modelo pode ser verificada através de testes de raízes unitárias que permitem verificar o número de diferenças necessário para torna a série temporal estacionária, no presente trabalho o teste de raiz unitária utilizado foi o teste dickey-fuller (ADF).

Aliado ao comportamento da FAC e da FACP, pode-se adotar os critérios de informação de Akaike (AIC) e Schwarz (BIC) para auxiliar na identificação do modelo. Segundo Fava (2000), esses critérios baseiam-se na variância estimada, no tamanho da amostra e nos valores de p e q. Nesse caso, a estimação dos modelos não deve ser realizada considerando valores precisos para p, q, mas diversos pares (p, q) e o modelo escolhido deve ser aquele que apresentar o menor valor para tais critérios. A segunda etapa é a da estimação, que consiste em estimar os parâmetros autorregressivos, os parâmetros de médias móveis e a variância do modelo.

A terceira etapa abrange o diagnóstico que se verifica o modelo previamente identificado e estimado é o modelo mais adequado. A correta especificação de um modelo SARIMA é verificada no termo de erro ε_t , pois ele deve constituir um processo white noise

(GRANGER; NEWBOLD, 2014). Assim, a verificação da adequabilidade do modelo é efetuada nas autocorrelações amostrais dos erros ε_t , as quais seguem assintoticamente uma distribuição normal, com média zero e variância constante se forem provenientes de um white noise. Para esta análise utilizou-se a estatística desenvolvida por Ljung-Box. A quarta e última etapa é a da previsão.

4.2 Modelos de Autorregressão de Redes Neurais Artificiais (NNAR)

Conforme Hyndman e Athanasopoulos (2018) uma rede neural é estruturada em camadas, onde os preditores (ou entradas) compõem a camada inferior e as previsões (ou saídas) formam a camada superior. Além disso, podem existir camadas intermediárias (ou ocultas). Quando uma camada intermediária com neurônios ocultos é adicionada, a rede neural se torna não linear, caracterizando uma rede de feedforward de multicamadas, na qual cada camada de nós recebe entradas das camadas anteriores.

A NNAR É um modelo de Redes Neurais Artificiais de feedforward com uma camada oculta, conforme desenvolvido por (HYNDMAN; ATHANASOPOULOS, 2018). Os parâmetros deste modelo são aprendidos a partir dos dados em um processo supervisionado.

Em análises de séries temporais, é comum utilizar os valores defasados das séries temporais como entradas para uma rede neural. Essa abordagem é denominada Autoregressão de Rede Neural, ou modelo NNAR. A notação NNAR (p, k) representa um modelo com p defasagens do preditor e k nós na camada intermediária. Um modelo NNAR (p, 0) equivale a um modelo ARIMA (p, 0, 0) sem as restrições de estacionariedade impostas pelo parâmetro.

Para modelos sazonais, é recomendável incluir a informação da variável no instante s, representando a sazonalidade. Assim, um modelo NNAR (p, P, k)_m equivale a um SARIMA(p, 0, 0)(P, 0, 0)_m sem as restrições de estacionariedade impostas pelo parâmetro.

No processo de previsão, a rede neural é aplicada de forma iterativa. Para prever um período à frente, as variáveis explicativas são baseadas na série temporal. Para prever múltiplos períodos à frente, são utilizadas a série temporal e as previsões dos períodos anteriores como preditores.

Dada a natureza flexível das redes neurais, não existe um processo sistemático rígido

para criar modelos. A obtenção de um modelo robusto de rede neural muitas vezes envolve a seleção de uma variedade de parâmetros, os quais são determinados empiricamente, por meio, de tentativa e erro (PALMER; MONTANO; SESÉ, 2006).

Vale salientar que para realizar as previsões e comparar a eficácia preditiva de modelos SARIMA automático e redes neurais do tipo feed-forward, foram utilizadas ferramentas da linguagem de programação R. As análises e previsões foram conduzidas no ambiente R Studio, uma extensão do R, com o auxílio do pacote forecast do R.

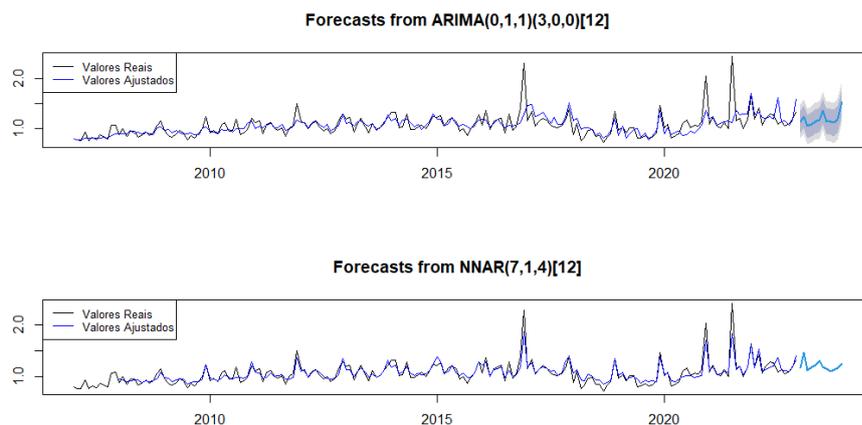
As funções específicas em R usadas para fazer as previsões foram o `auto.arima` para os modelos SARIMA automáticos e o `nnet` para as redes neurais do tipo feed-forward. Essas funções são amplamente reconhecidas e foram desenvolvidas por (HYNDMAN, 2008).

5 RESULTADOS E DISCUSSÕES

5.1 Previsão Receitas Correntes

Na Figura 14, são apresentados os modelos que foram mais precisamente ajustados aos dados das séries temporais das receitas correntes. Um dos modelos é uma NNAR com parâmetros (7,1,4), caracterizada por ter 7 neurônios na camada de entrada, 1 neurônio na camada oculta e 4 neurônios na camada de saída. O outro modelo é um modelo SARIMA (0,1,1)(3,0,0), que inclui uma componente de média móvel de ordem 1 e um componente autorregressiva sazonal de ordem 3.

Figura 14 - Previsão Receitas Correntes 2023 (12 Passos a Frente)



Fonte elaborado pelo autor.

As previsões geradas pelos modelos SARIMA e NNAR estão apresentadas na Tabela 6. Para alcançar esses resultados, foram utilizados os dados das Receitas Correntes dos meses anteriores, abrangendo o período de 2007 a 2022. Esses dados foram empregados para prever os valores de cada mês de 2023, projetando 12 meses à frente.

Após a obtenção das previsões, comparou-se os valores previstos com os valores reais das Receitas Correntes de 2023, com o objetivo de avaliar a precisão dos modelos de previsão. Essa tabela proporciona uma compreensão do desempenho dos modelos em relação

aos valores reais, facilitando a análise da eficácia de cada método na previsão das Receitas Correntes para o ano de 2023. Esse mesmo raciocínio foi aplicado às Transferências Correntes e ao ICMS.

Tabela 6 - Valores Previstos 12 passos à frente (Receitas Correntes 2023)

MÊS	VALOR REAL	SARIMA	NNAR
JAN/2023	1.352.597.218,69	1.148.972.961,00	1.176.007.794,00
FEV/2023	1.400.146.851,36	1.246.018.909,00	1.503.065.420,00
MAR/2023	1.167.216.942,80	1.052.057.079,00	1.128.488.682,00
ABR/2023	1.179.995.474,57	1.096.351.803,00	1.312.727.964,00
MAI/2023	1.272.828.630,82	1.148.252.868,00	1.224.662.161,00
JUN/2023	1.243.900.738,17	1.179.248.473,00	1.300.876.974,00
JUL/2023	1.120.201.345,67	1.362.141.436,00	1.202.604.603,00
AGO/2023	1.233.886.029,87	1.141.167.004,00	1.190.529.963,00
SET/2023	1.136.398.087,96	1.139.598.782,00	1.084.515.909,00
OUT/2023	1.162.702.004,42	1.118.411.503,00	1.153.901.836,00
NOV/2023	1.429.772.450,26	1.191.198.180,00	1.223.147.169,00
DEZ/2023	1.580.677.806,05	1.540.423.290,00	1.362.678.148,00
SOMA	15.280.323.580,64	14.363.842.288,00	14.863.206.623,00

Fonte: elaborado pelo autor.

O modelo NNAR demonstrou um desempenho superior em relação ao modelo SARIMA em todas as métricas avaliadas MAE, MAPE e RMSE. Em termos de MAE o modelo NNAR apresentou um valor significativamente menor (97.264.838,34) em comparação com o modelo SARIMA (117.230.238,44) Isso sugere que as previsões do modelo NNAR tiveram uma diferença média menor em relação aos valores reais das receitas correntes.

O MAPE também foi mais baixo para o modelo NNAR (7,31%) em comparação com o modelo SARIMA (9,20%), indicando que as previsões do modelo NNAR apresentaram uma taxa percentual de erro médio menor em relação aos valores reais.

Além disso, o RMSE do modelo NNAR (118.362.879,68) foi menor do que o do modelo SARIMA (139.289.022,52), o que significa que houve uma menor dispersão entre as previsões e os valores reais das receitas correntes com o modelo NNAR.

Portanto, podemos concluir que o modelo NNAR demonstrou um melhor desempenho em relação à precisão das previsões das receitas correntes mensais para o estado de Alagoas em 2023, quando comparado ao modelo SARIMA.

Tabela 7 - Medidas de Acurácia Previsão Receitas Correntes

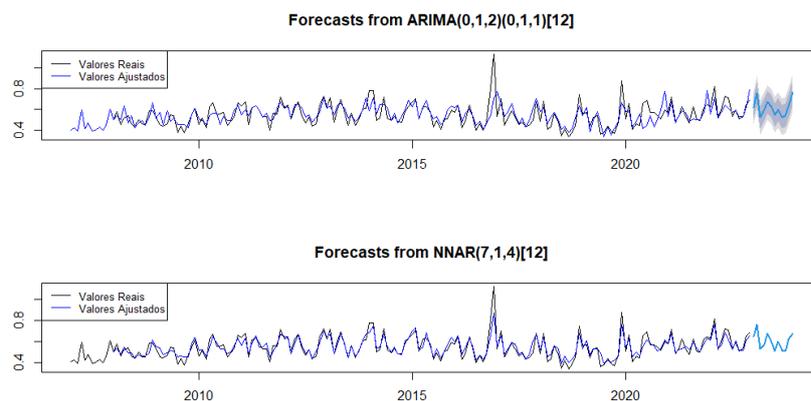
MODELO	MAE	MAPE	RMSE
SARIMA	117.230.238,44	9,20	139.289.022,52
NNAR	97.264.838,34	7,31	118.362.879,68

Fonte: elaborado pelo autor.

5.2 Previsão Transferências Correntes

Na Figura 15, são apresentados os modelos que foram mais precisamente ajustados aos dados das séries temporais das transferências correntes. Um desses modelos é uma NNAR com parâmetros (7,1,4), caracterizado por possuir 7 neurônios na camada de entrada, 1 neurônio na camada oculta e 4 neurônios na camada de saída. O outro modelo é um modelo SARIMA (0,1,2)(0,1,1), que incorpora um componente de média móvel de ordem 2 e um componente de média móvel sazonal de ordem 1. As previsões geradas por cada um desses modelos podem ser encontradas na Tabela 8.

Figura 15 - Previsão Transferências Correntes 2023



Fonte: elaborado pelo auto.

Tabela 8 - Valores Previstos 12 passos à frente (Transferências Correntes 2023)

MÊS	VALOR REAL	SARIMA	NNAR
-----	------------	--------	------

JAN/2023	649.368.443,83	615.748.319,00	657.065.110,00
FEV/2023	884.776.058,94	754.868.754,00	739.644.467,00
MAR/2023	538.744.045,27	527.438.912,00	575.255.685,00
ABR/2023	599.537.077,91	598.464.398,00	620.473.892,00
MAI/2023	657.411.418,37	671.053.185,00	679.653.868,00
JUN/2023	656.777.806,86	626.772.097,00	626.883.955,00
JUL/2023	530.180.510,56	548.718.307,00	503.492.983,00
AGO/2023	647.515.536,15	597.360.825,00	588.482.653,00
SET/2023	516.210.174,17	528.200.405,00	502.833.361,00
OUT/2023	590.020.164,04	545.106.599,00	549.387.897,00
NOV/2023	827.495.730,20	635.778.927,00	615.077.286,00
DEZ/2023	796.052.171,73	767.735.724,00	650.484.166,00
SOMA	7.894.089.138,03	7.417.246.452,00	7.308.735.323,00

Fonte: elaborado pelo autor.

Com base nos dados da Tabela 9, que apresenta as medidas de acurácia para os modelos SARIMA e NNAR na previsão das transferências correntes mensais para o estado de Alagoas em 2023, podemos observar que o modelo SARIMA demonstrou um desempenho superior em comparação com o modelo NNAR. O modelo SARIMA obteve valores mais baixos em todas as métricas de avaliação MAE, MAPE e RMSE, em comparação com o modelo NNAR.

Em termos de MAE, o modelo SARIMA registrou um valor de (47.098.522,82), enquanto o modelo NNAR teve um MAE de (63.344.079,52). Isso indica que as previsões do modelo SARIMA apresentaram uma menor diferença absoluta média em relação aos valores reais das transferências correntes.

Além disso, o MAPE do modelo SARIMA foi de (6,39%), em comparação com (8,62%) do modelo NNAR, indicando uma menor taxa percentual de erro médio nas previsões do SARIMA em relação aos valores reais.

No que diz respeito ao RMSE, o modelo SARIMA teve um valor de (71.762.866,80), enquanto o modelo NNAR apresentou um RMSE de (89.731.498,57). Isso sugere que o modelo SARIMA teve uma menor dispersão entre as previsões e os valores reais das transferências correntes.

Portanto, com base nessas medidas de acurácia, podemos concluir que o modelo SARIMA demonstrou um melhor desempenho na previsão das transferências correntes para o estado de Alagoas em 2023, em comparação com o modelo NNAR.

Tabela 9 - Medidas de Acurácia Previsão Transferências Correntes

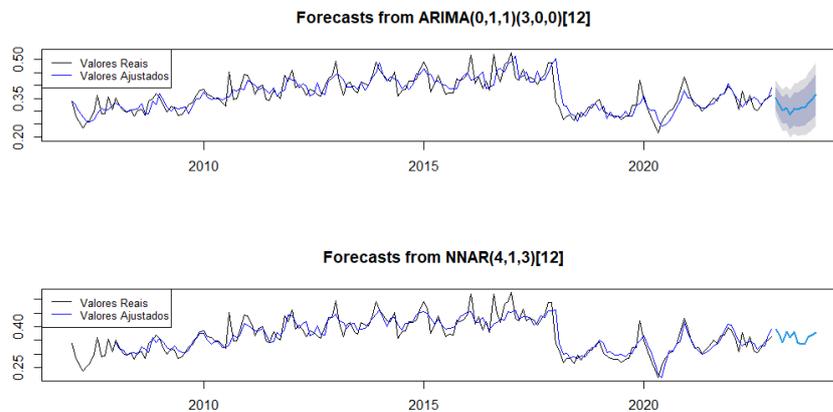
MODELO	MAE	MAPE	RMSE
SARIMA	47.098.522,82	6,39	71.762.886,80
NNAR	63.344.079,52	8,62	89.731.498,57

Fonte: elaborado pelo autor.

5.3 Previsão ICMS

Na figura 16 é apresentado os modelos mais bem ajustados aos dados das séries do ICMS que foram uma NNAR (4,1,3) com uma estrutura com 4 neurônios na camada de entrada, 1 neurônio na camada oculta e 3 neurônios na camada de saída. E um SARIMA (0,1,1) (3,0,0) com uma componente de média móvel de ordem 1 e um componente autorregressivo sazonal de ordem 3. As previsões de cada modelo estão na Tabela 10.

Figura 16- Previsão ICMS 2023 (12 Passos a Frente)



Fonte: elaborado pelo autor.

Tabela 10 -Valores Previstos 12 passos à frente (ICMS 2023)

MÊS	VALOR REAL	SARIMA	NNAR
JAN/2023	361.190.243,00	351.584.557,00	390.586.471,00
FEV/2023	339.870.097,00	327.217.614,00	375.025.634,00
MAR/2023	335.966.970,00	302.786.224,00	340.484.022,00
ABR/2023	357.690.624,00	311.712.128,00	377.499.329,00

MAI/2023	360.382.432,00	288.298.515,00	363.462.636,00
JUN/2023	368.487.178,00	309.656.084,00	383.786.831,00
JUL/2023	370.334.694,00	306.003.828,00	342.687.189,00
AGO/2023	367.260.932,00	312.535.762,00	336.508.344,00
SET/2023	379.830.724,00	316.323.963,00	343.453.490,00
OUT/2023	390.903.194,00	332.707.371,00	365.807.209,00
NOV/2023	410.947.526,00	345.581.490,00	375.025.317,00
DEZ/2023	531.315.722,00	365.777.193,00	382.741.549,00
SOMA	4.574.180.336,00	3.870.184.729,00	4.377.068.021,00

Fonte: elaborado pelo autor.

Os dados da Tabela 11, que exibem as medidas de acurácia para os modelos SARIMA e NNAR na previsão mensal do ICMS para o estado de Alagoas em 2023, indicam claramente que o modelo NNAR obteve um desempenho superior em relação ao modelo SARIMA.

Ao analisar as métricas de acurácia MAE, MAPE e RMSE observamos que o modelo NNAR apresentou valores significativamente menores em todas as métricas em comparação com o modelo SARIMA. Em particular, o MAE do modelo NNAR foi substancialmente menor (34.302.256,08) em comparação com o do modelo SARIMA (58.666.300,58), indicando uma diferença absoluta média menor entre as previsões e os valores reais do ICMS.

Além disso, o MAPE do modelo NNAR foi mais baixo (8,24%) em comparação com o do modelo SARIMA (14,67%), o que sugere que as previsões do modelo NNAR apresentaram uma taxa percentual de erro médio menor em relação aos valores reais do ICMS.

Quanto ao RMSE, o modelo NNAR também registrou um valor inferior (49.819.936,93) em comparação com o modelo SARIMA (69.733.670,46), indicando uma menor dispersão entre as previsões e os valores reais do ICMS.

Dessa forma, com base nessas análises, podemos concluir que o modelo NNAR demonstrou um melhor desempenho na previsão do ICMS mensal para o estado de Alagoas em 2023, em comparação com o modelo SARIMA.

Tabela 11 - Medidas de Acurácia Previsão (ICMS 2023)

MODELO	MAE	MAPE	RMSE
SARIMA	58.666.300,58	14,67	69.733.670,46
NNAR	34.302.256,08	8,24	49.819.936,93

Fonte: elaborado pelo autor.

6 CONCLUSÃO

Os resultados apresentados possibilitaram uma análise comparativa entre modelos econométricos e de redes neurais para prever as receitas correntes em Alagoas, revelando informações sobre a eficácia dessas abordagens no contexto estadual específico. Observou-se que o modelo NNAR se destacou como o melhor preditor tanto para as receitas correntes quanto para o ICMS, enquanto o SARIMA demonstrou um desempenho superior nas previsões de Transferências Correntes.

Essa diferenciação no desempenho dos modelos de acordo com as séries temporais analisadas ressalta a importância de considerar as particularidades de cada categoria de receita. No contexto de Alagoas, esses resultados têm implicações práticas significativas para o planejamento financeiro do estado. A precisão na previsão das receitas correntes é crucial para uma gestão fiscal eficiente, permitindo uma alocação otimizada dos recursos disponíveis.

A preferência por um modelo específico deve ser orientada não apenas pelas métricas de desempenho, mas também pela natureza das séries temporais e pelas necessidades específicas do estado.

Contudo, é crucial reconhecer as limitações deste estudo, incluindo as restrições nos dados disponíveis no Portal da Transparência de Alagoas. É essencial estar ciente das limitações inerentes aos dados primários. Embora esses dados sejam fundamentais para análises e previsões, é de suma importância abordar essas limitações, tais como possíveis inconsistências nos dados e lacunas na informação disponível.

Recomenda-se que futuras pesquisas explorem outras técnicas, considerem variáveis adicionais e realizem análises mais aprofundadas para melhorar ainda mais a precisão das previsões. Em suma, a análise comparativa desses modelos oferece valiosas informações para o cenário econômico de Alagoas. A abordagem criteriosa na escolha do modelo de previsão, considerando tanto aspectos teóricos quanto a aplicabilidade prática, é essencial para otimizar a eficácia das previsões e contribuir para uma gestão financeira mais eficiente e informada no âmbito estadual.

REFERÊNCIAS

AIRES, D. B.; DAMETTO, R. C.; CREPALDI, A. F. Previsão de séries temporais financeiras utilizando redes neurais artificiais: um comparativo na crise de 2008. **Revista Gestão da Produção Operações e Sistemas**, v. 13, n. 1, p. 177–177, 1 mar. 2018.

ALMEIDA, T. R. C. DE. Previsão de arrecadação tributária na crise: alisamento exponencial de HOLT-WINTERS E SARIMA. **Revista da Estatística da Universidade Federal de Ouro Preto**, v. 6, 20 dez. 2017.

BAPTISTA, M. I. B. D. G. Orçamento público e receitas da prefeitura de Belo Horizonte: um estudo de métodos para previsão de receitas correntes. 29 nov. 2019.

BENELLI, F. C. Previsão da receita tributária federal por base de incidência. 2013.

CALDART, W. L. Modelo de previsão de arrecadação do ISSQN para o Município de Caxias do Sul. **Universidade de Caxias do Sul, apresentação de Artigo Científico no IV Encontro sobre os Aspectos Econômicos e Sociais da Região Nordeste do RS. Caxias do Sul-RS**, v. 10, 2006.

CLAUDIO CORDEIRO TETI, A. **Modelo de previsão da receita tributária: o caso do ICMS no Estado de Pernambuco**. masterThesis. Disponível em: <<https://repositorio.ufpe.br/handle/123456789/3786>>. Acesso em: 28 dez. 2023.

CLEMENTE, A.; CLEMENTE, L. T. Aplicação da metodologia Box-Jenkins para previsão do ICMS do estado do Paraná de agosto de 2011 a julho de 2012. **Economia & Tecnologia**, v. 27, n. 7, p. 47–57, 2011.

COELHO NETO, R. G. Modelos de previsão como ferramenta para o planejamento na gestão municipal: uma aplicação para a Prefeitura de Maracanaú-Ce. 2014.

DA SILVA ZONATTO, V. C.; HEIN, N. Eficácia da previsão de receitas no orçamento dos municípios gaúchos: uma investigação empírica dos exercícios de 2005 a 2009 utilizando a análise de clusters. **Estudos do CEPE**, p. 102131, 2013.

DE ANGELO, C. F. et al. Séries temporais e redes neurais: uma análise comparativa de técnicas na previsão de vendas do varejo brasileiro. **BBR-Brazilian Business Review**, v. 8, n. 2, p. 1–21, 2011.

FABRIS, T. R.; GONÇALVES, J. P. A previsibilidade das receitas tributárias para o município de Criciúma. **Textos de Economia**, v. 15, n. 1, p. 41–59, 2012.

FAVA, V. L. Manual de econometria. **Vasconcelos, MAS; Alves, D. São Paulo: Editora Atlas**, 2000.

FERREIRA, A. et al. Um estudo sobre previsão da demanda de encomendas utilizando uma rede neural artificial. **Blucher Marine Engineering Proceedings**, v. 2, n. 1, p. 353–364, 2016.

FURTUOSO, G. D. V.; SANTOS, M. DOS; QUINTAL, R. S. APLICAÇÃO DE REDES NEURAIAS RECORRENTES NA PREVISÃO DE SÉRIES TEMPORAIS: UM ESTUDO DE PREÇOS DE AÇÕES DA BOLSA DE VALORES. **Revista Gestão em Análise**, v. 11, n. 2, p. 25–36, 3 maio 2022.

GIACOMONI, J. **Orçamento Público**. 18ª ed. [s.l.] Atlas, 2021.

GIAMBIAGI, F.; ALEM, A.; PINTO, S. G. B. **Finanças Públicas**. [s.l.] Elsevier Brasil, 2021.

GIL, A. C. **Como elaborar projetos de pesquisa**. [s.l.] Atlas São Paulo, 2002. v. 4

GRANGER, C. W. J.; NEWBOLD, P. **Forecasting economic time series**. [s.l.] Academic press, 2014.

GUJARATI, D. N.; PORTER, D. C. **Econometria básica-5**. [s.l.] Amgh Editora, 2011.

HYNDMAN, R. Automatic Time Series Forecasting: the Forecast Package for R. **Journal of ...**, 1 jan. 2008.

HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: principles and practice**. [s.l.] OTexts, 2018.

MARCONI, M. DE A.; LAKATOS, E. M. **Metodologia científica**. [s.l.] Atlas São Paulo, 2004. v. 4

NASCIMENTO, M. DE N. S.; BOENTE, D. R. Fatores associados aos erros de previsão orçamentária da receita do setor público. **Administração Pública e Gestão Social**, 7 abr. 2022.

PALMER, A.; MONTANO, J. J.; SESÉ, A. Designing an artificial neural network for forecasting tourism time series. **Tourism management**, v. 27, n. 5, p. 781–790, 2006.

PESSOA, F. DE M. C.; CORONEL, D. A.; LIMA, J. E. DE. Previsão de arrecadação de ICMS para o estado de Minas Gerais: uma comparação entre modelos Arima e Arfima. **Revista Brasileira de Gestão e Desenvolvimento Regional**, v. 9, n. 2, 2013.

PORTUGAL, M. S.; FERNANDES, L. G. L. Redes neurais artificiais e previsão de séries econômicas: uma introdução. **Nova Economia**, v. 6, n. 1, p. 51–73, 1996.

SANTOS, A. V. Análise de modelos de séries temporais para a previsão mensal do imposto de renda. 2003.

SANTOS, S. R. T. DOS; ALVES, T. W. O impacto da Lei de Responsabilidade Fiscal no desempenho financeiro e na execução orçamentária dos municípios no Rio Grande do Sul de 1997 a 2004. **Revista de Administração Pública**, v. 45, p. 181–208, fev. 2011.

SCHEFFER, D.; SOUZA, A. M.; ZANINI, R. R. Utilização de modelos ARIMA para previsão da arrecadação de ICMS do Estado do Rio Grande do Sul. **XVII Simpósio de Pesquisa Operacional e Logística da Marinha-SPOLM. Anais...** São Paulo, 2014.

SOUSA, A. P. DE. ANÁLISE COMPARATIVA DE MÉTODOS DE PREVISÃO DE SÉRIES TEMPORAIS ATRAVÉS DE MODELOS ESTATÍSTICOS E REDE NEURAL ARTIFICIAL. 9 mar. 2012.