



UNIVERSIDADE FEDERAL DA PARAÍBA – UFPB
CENTRO DE CIÊNCIAS EXATAS E DA NATUREZA – CCEN
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELOS DE DECISÃO
E SAÚDE - PPgMDS

GEO-HELMINTÍASES EM ALAGOAS: INSIGHTS DE SÉRIES TEMPORAIS PARA O
PLANEJAMENTO EM SAÚDE

Maria Eduarda Bezerra Lopes

João Pessoa – PB

2025

Maria Eduarda Bezerra Lopes

**GEO-HELMINTÍASES EM ALAGOAS: INSIGHTS DE SÉRIES TEMPORAIS PARA O
PLANEJAMENTO EM SAÚDE**

Dissertação submetida ao Programa de Pós-graduação em Modelos de Decisão e Saúde do Centro de Ciências Exatas e da Natureza da Universidade Federal da Paraíba, como requisito para obtenção do título de Mestre.

Linha de Pesquisa: Modelos de Saúde.

Orientadoras: Dr.^a Caliandra Maria Bezerra Luna Lima e Dr.^a Tatiene Correia de Souza.
Coorientador: Dr. Allan Batista Silva.

João Pessoa – PB

2025

Catálogo na publicação
Seção de Catalogação e Classificação

L864g Lopes, Maria Eduarda Bezerra.

Geo-helmintíases em Alagoas : insights de séries
temporais para o planejamento em saúde / Maria Eduarda
Bezerra Lopes. - João Pessoa, 2025.
69 f. : il.

Orientação: Caliandra Maria Bezerra Luna Lima,
Tatiene Correia de Souza.

Coorientação: Allan Batista Silva.
Dissertação (Mestrado) - UFPB/CCEN.

1. Helmintíase. 2. Enteropatias parasitárias. 3.
Saúde pública. 4. Séries empormais. I. Lima, Caliandra
Maria Bezerra Luna. II. Souza, Tatiene Correia de. III.
Silva, Allan Batista. IV. Título.

UFPB/BC

CDU 616.995.1(043)

Maria Eduarda Bezerra Lopes

GEO-HELMINTÍASES EM ALAGOAS: INSIGHTS DE SÉRIES TEMPORAIS PARA O PLANEJAMENTO EM SAÚDE

Data de defesa: 21 de fevereiro de 2025.

Documento assinado digitalmente
 **CALIANDRA MARIA BEZERRA LUNA LIMA**
Data: 06/03/2025 20:03:18-0300
Verifique em <https://validar.iti.gov.br>

Orientadora
Dr.^a Caliandra Maria Bezerra Luna Lima.

Documento assinado digitalmente
 **TATIENE CORREIA DE SOUZA**
Data: 05/03/2025 21:06:35-0300
Verifique em <https://validar.iti.gov.br>

Orientadora
Dr.^a Tatiane Correia de Souza.

Documento assinado digitalmente
 **ANA HERMINIA ANDRADE E SILVA**
Data: 13/03/2025 15:53:20-0300
Verifique em <https://validar.iti.gov.br>

Examinadora
Dr.^a Ana Hermínia Andrade e Silva.

Documento assinado digitalmente
 **FABIO MARCEL DA SILVA SANTOS**
Data: 13/03/2025 11:45:48-0300
Verifique em <https://validar.iti.gov.br>

Examinador
Dr. Fábio Marcel da Silva Santos.

Documento assinado digitalmente
 **TARCIANA LIBERAL PEREIRA DE ARAUJO**
Data: 13/03/2025 16:41:50-0300
Verifique em <https://validar.iti.gov.br>

Examinadora
Dr.^a Tarciana Liberal Pereira de Araújo

“All models are wrong, but some are useful”

George Box (1979)

RESUMO

As geo-helmintíases representam um desafio persistente à saúde pública, especialmente em regiões com infraestrutura sanitária limitada. Este estudo analisou a evolução temporal dessas infecções no estado de Alagoas entre 2010 e 2021, aplicando modelos preditivos baseados em séries temporais. Dados de prevalência foram extraídos do Programa de Controle da Esquistossomose, focando em indivíduos de 7 a 17 anos. Três abordagens analíticas foram utilizadas: Modelos Autorregressivos Integrados de Médias Móveis (ARIMA), modelo Erro, Tendência e Sazonalidade (ETS) e Alisamento Exponencial de Holt (AEHolt). A performance dos métodos foi comparada por métricas de acurácia como MAE, RMSE e MAPE. Os resultados indicaram uma queda expressiva da prevalência, de valores superiores a 30% em 2010 para menos de 10% em 2021. O modelo AEHolt destacou-se em previsões de curto prazo (1 e 3 passos), enquanto o ARIMA demonstrou maior robustez em horizontes longos (6 e 12 passos). O ETS apresentou desempenho intermediário e consistente. Conclui-se que o uso de técnicas preditivas pode aprimorar o planejamento estratégico em saúde pública, orientando políticas de intervenção para mitigação das desigualdades regionais. O fortalecimento do saneamento básico e da educação em saúde permanece essencial para o controle efetivo das geo-helmintíases.

Palavras-chave: Helmintíase; Enteropatias Parasitárias; Saúde Pública; Previsões; Estudos de Séries Temporais.

ABSTRACT

Geo-helminthiasis represent a persistent challenge to public health, especially in regions with limited sanitation infrastructure. This study analyzed the temporal evolution of these infections in the state of Alagoas between 2010 and 2021, applying predictive models based on time series. Prevalence data were extracted from the Schistosomiasis Control Program, focusing on individuals aged 7 to 17. Three analytical approaches were used: Autoregressive Integrated Moving Average (ARIMA) models, Error, Trend, and Seasonality (ETS) model, and Holt's Exponential Smoothing (AEHolt). The performance of the methods was compared using accuracy metrics such as MAE, RMSE, and MAPE. The results indicated a significant decline in prevalence, from values over 30% in 2010 to less than 10% in 2021. The AEHolt model excelled in short-term forecasts (1 and 3 steps), while ARIMA showed greater robustness in long-term horizons (6 and 12 steps). ETS presented intermediate and consistent performance. It is concluded that the use of predictive techniques can enhance strategic planning in public health, guiding intervention policies to mitigate regional inequalities. Strengthening basic sanitation and health education remains essential for the effective control of geo-helminthiasis.

Keywords: Helminthiasis; Parasitic Enteropathies; Public Health; Forecasts; Time Series Studies.

LISTA DE TABELAS

Tabela 1: Medidas descritivas para a série de prevalência percentual de geo-helminthiases no estado de Alagoas entre janeiro de 2010 e dezembro de 2021	33
Tabela 2: Valores reais e valores previstos pelo modelo ARIMA de ordem (1,1,1).	36
Tabela 3: Valores reais e valores previstos pelo algoritmo de AEHolt.....	38
Tabela 4: Valores reais e valores previstos pelo modelo ETS de ordem (A, Ad, A).....	40
Tabela 5: Medidas de acurácia para previsões geradas pelos modelos Autorregressivos Integrados de Médias Móveis (ARIMA) (1,1,1), Erro, Tendência e Sazonalidade (ETS) (A, Ad, A) e algoritmo de Alisamento Exponencial de Holt (AEHolt) em 1, 3, 6 e 12 passos	42

LISTA DE ILUSTRAÇÕES

Figura 1: Representação gráfica de um correlograma em uma análise de Séries Temporais...	20
Figura 2: Série temporal para a prevalência de geo-helminthíases no estado de Alagoas entre janeiro de 2010 e dezembro de 2021.	32
Figura 3: Ausência de padrões de sazonalidade para a série de prevalência de geo-helminthíases em Alagoas entre janeiro de 2010 e dezembro de 2021	33
Figura 4: Série real <i>versus</i> série obtida através do modelo ARIMA de ordem (1,1,1).	36
Figura 5: Série real <i>versus</i> série obtida através do algoritmo de AEHolt	38
Figura 6: Série real <i>versus</i> série obtida através do modelo ETS de ordem (A, Ad, A).	40
Figura 7: Valores reais <i>versus</i> valores preditos pelos modelos Autorregressivos Integrados de Médias Móveis (ARIMA) (1,1,1), Erro, Tendência e Sazonalidade (ETS) (A, Ad, A) e algoritmo de Alisamento Exponencial de Holt (AEHolt) a 12 passos.	42
Figura 8: Valores críticos da Estatística F	44

SUMÁRIO

1. INTRODUÇÃO	9
2. OBJETIVOS	12
2.1 Objetivo geral	12
2.2 Objetivos específicos	12
3. REFERENCIAL TEÓRICO	13
3.1 Caracterização das Infecções provocadas por parasitas transmitidos pelo solo	13
3.2 Ascaridíase – Infecção provocada pelo nematódeo <i>Ascaris lumbricoides</i>	14
3.3 Tricuríase – Infecção provocada pelo nematódeo <i>Trichuris trichiura</i>	15
3.4 Ancilostomíase – Infecção provocada pelos nematódeos <i>Necator americanus</i> ou <i>Ancylostoma duodenale</i>	16
3.5 Fundamentos para análise de Séries Temporais	17
3.6 Modelos Autorregressivos Integrados de Médias Móveis	20
3.7 Algoritmo de Alisamento exponencial de Holt	22
3.8 Modelos Erro, Tendência, Sazonalidade	24
3.9 Medidas de acurácia na avaliação de modelos preditivos	27
4. MATERIAIS E MÉTODOS	29
4.1 Tipo de estudo	29
4.2 Local e período	29
4.3 População e amostra	29
4.4 Critérios de inclusão e exclusão	30
4.5 Processamento e análise dos dados	30
4.6 Aspectos éticos	31
5. RESULTADOS	32
5.1 Análise exploratória	32
5.2 Análise preditiva	34
5.2.1 Modelo Autorregressivo Integrado de Médias Móveis (ARIMA)	35
5.2.2 Algoritmo de alisamento exponencial de Holt	37
5.2.3 Modelo ETS	39
5.3 Avaliação de desempenho	41
5.4 Análise de quebras estruturais	43
6. DISCUSSÃO	45

7. CONSIDERAÇÕES FINAIS	52
8. REFERÊNCIAS	53
9. APÊNDICE	62

1. INTRODUÇÃO

As doenças negligenciadas representam um conjunto de enfermidades infecciosas que afetam desproporcionalmente populações em situação de vulnerabilidade socioeconômica, caracterizando-se pela escassez de investimentos em pesquisa, prevenção e tratamento. Esse status de negligência decorre, em grande parte, da limitada atratividade comercial para a indústria farmacêutica, bem como da insuficiência de políticas públicas robustas e sustentáveis voltadas ao seu enfrentamento (WHO, 2023; Hotez et al., 2020).

Embora estejam distribuídas globalmente, sua incidência é mais expressiva em regiões tropicais e subtropicais, onde fatores como saneamento inadequado, baixa escolaridade e dificuldades de acesso aos serviços de saúde ampliam sua persistência. Estima-se que aproximadamente dois bilhões de pessoas convivam com essas enfermidades, o que reforça a necessidade de iniciativas governamentais e multilaterais para o seu controle e eliminação (OPAS, 2023; Silva et al., 2021). Organizações como a Organização Mundial da Saúde (OMS) e a Organização Pan-Americana da Saúde (OPAS) desempenham papel central na formulação de estratégias para mitigar os impactos dessas doenças, promovendo ações integradas que englobam diagnóstico precoce, acesso universal a tratamentos eficazes e melhorias estruturais em infraestrutura sanitária.

A superação desse cenário exige um compromisso global, envolvendo esforços coordenados entre governos, setor privado e academia para garantir que essas enfermidades deixem de ser um reflexo das desigualdades sociais e passem a ser uma prioridade em saúde pública. Prediz-se cerca de 200 mil mortes anuais e uma perda de aproximadamente 19 milhões de anos de vida por incapacidade em decorrência a esses agravos. Esses indicadores demonstram que apesar dos avanços globais obtidos na última década, perpetuam-se a estigmatização e a falta de assistência qualificada para erradicar essas doenças (WHO, 2023).

A saúde pública brasileira também é impactada pelas doenças tropicais negligenciadas, que são um importante causador de incapacidade física e morte precoce no país. Essas infecções estão presentes em todas as unidades federativas, apesar de serem mais abrangentes em regiões com maior vulnerabilidade social, onde o saneamento, a disposição de água potável e o acesso à serviços de saúde são limitados (Meurer; Coimbra, 2022). O Brasil é considerado um país endêmico para diversas doenças tropicais. Apesar disso, infecções intestinais ganham destaque no território devido as condições ambientais propícias. Destacam-se nesse cenário as regiões

Norte e Nordeste, que frente às demais possuem maior persistência de fatores que propiciam infecções enteroparasitárias (Brito *et al.*, 2022).

As enteroparasitoses são amplamente distribuídas em todo mundo. Na América Latina e Caribe, estipula-se que 59 milhões de crianças residam em áreas propícias à infecção ou reinfecção por parasitas intestinais. Ainda nesse cenário, o Brasil é um importante protagonista e expressa índices de prevalência que variam de 2% a 36% a depender da região geográfica, atingindo até 70% da população em idade escolar (OPAS, 2023; Teixeira *et al.*, 2022).

Alguns desses parasitas intestinais são transmitidos pelo solo e contaminam seres humanos através da ingestão de ovos ou contato com larvas presentes na crosta terrestre quente e úmida. Quando adultos, os vermes colonizam o trato gastrointestinal humano e provocam principalmente quadros de desnutrição. A esses parasitas dá-se o nome de geo-helminhos, sendo essa classificação atribuída aos patógenos *Ascaris lumbricoides*, *Trichuris trichiura*, *Necator americanus* ou *Ancylostoma duodenale* que causam a Ascariíase, Tricuríase e Ancilostomíase, respectivamente (Bethony *et al.*, 2006).

Estima-se que um bilhão e meio de pessoas estejam infectadas por geo-helminhos em todo o mundo. Nas Américas por exemplo, prediz-se que uma a cada três pessoas convivam com algum tipo de parasitose contraída pelo solo e que aproximadamente 46 milhões de indivíduos em idade escolar estejam sob risco de infecção por esses vermes (OPAS, 2024). No Brasil, a distribuição das geo-helminthíases não segue um padrão de homogeneidade populacional, sendo crianças, mulheres, pessoas indígenas e residentes da região nordeste, a parcela mais afetada em termos de morbimortalidade. Nesta perspectiva, ratifica-se que o comportamento endêmico dessas parasitoses varia entre as regiões territoriais nacionais e demonstra as iniquidades socioambientais vivenciadas por estas populações no país (Ziliotto; Ellwanger; Chies, 2022).

Ainda nesse tocante, as áreas de maior disseminação de helmintíases no Brasil são as zonas rurais e periferias urbanas, onde o saneamento básico e o baixo conhecimento sobre essas doenças prevalecem. Os inquéritos realizados no país ao longo dos anos 2005 e 2016 indicam que houve certa diminuição de casos na maior parte do território brasileiro, apesar disso, altos índices de infecção são observados nas regiões norte e nordeste do país (Katz, 2018).

As diferenças regionais e sua relação com os Índices de Desenvolvimento Humano impactam diretamente a ocorrência das geo-helminthíases no Brasil. Atualmente, a realidade sanitária do país ainda é insalubre e continua escancarando os impactos desse fato no

desenvolvimento social, já que o saneamento básico é um importante recurso para manutenção da saúde coletiva (Arruda, 2019).

O Sistema Nacional de Informação sobre Saneamento (SNIS) aponta que o percentual populacional atendido com rede de esgoto é de apenas 14% na região norte e 30,2% na região nordeste. Além disso, somente 20,6% e 35,5% do esgoto gerado é tratado nessas respectivas regiões. Cabe ressaltar, que a precariedade sanitária é um fator intimamente relacionado à contaminação ambiental e propagação de doenças de caráter parasitário (SNIS, 2022; Moreira et al., 2021).

O Nordeste tem destaque com a prevalência de geo-helminthiases desde o primeiro inquérito nacional realizado por Pellon e Teixeira (1950), período em que esse indicador chegou a 90% na região. Apesar do declínio de casos ocorridos ao longo dos anos, a região ainda é marcada pela ocorrência de doenças negligenciadas, sendo uma importante área endêmica para a esquistossomose e demais parasitas transmitidos pelo solo (Katz, 2018). O estado de Alagoas, por sua vez, também é um território referido nesses inquéritos quanto a existência de enteropatias transmitidas pelo solo, evidenciando essa região como endêmica e prioritária para monitoramento no Nordeste do país (Katz, 2018).

Nesta perspectiva, este estudo se propõe a compreender o comportamento das infecções provocadas por geo-helminthos no estado de Alagoas, frequentemente citado nos Inquéritos Nacionais de Prevalência da Esquistossomose Mansonii e Geo-helminthiases. Para tanto, foi observada a ocorrência destas parasitoses ao longo de pouco mais de uma década (2010 – 2021), afim de determinar padrões de adoecimento para o estado e traçar métodos de suporte à tomada de decisão frente a esse problema de saúde pública. Assim, este estudo visou analisar o comportamento temporal das geo-helminthiases em Alagoas entre 2010 e 2021 por meio de ferramentas de previsão. Esta abordagem, portanto, além de identificar tendências históricas, prevê cenários futuros, implicando maior exatidão de ações para estratégias mais empoderadas.

2. OBJETIVOS

2.1 Objetivo geral

Analisar o comportamento temporal das geo-helminthiases em Alagoas entre 2010 e 2021 por meio de ferramentas de previsão baseadas em Séries Temporais.

2.2 Objetivos específicos

- ✓ Realizar análise exploratória para a ocorrência de geo-helminthiases no estado de Alagoas;
- ✓ Apresentar as taxas mensais de prevalência para geo-helminthiases no estado de Alagoas no período entre janeiro de 2010 e dezembro de 2021;
- ✓ Identificar padrões de sazonalidade e estacionariedade para ocorrência das geo-helminthiases;
- ✓ Utilizar o modelo Autorregressivo Integrado de Médias Móveis (ARIMA), algoritmo de Alisamento Exponencial de Holt (AEHolt) e modelo de suavização exponencial Erro, Tendência, Sazonalidade (ETS) para realizar previsões e comparar a performance desses métodos;
- ✓ Avaliar a presença de quebras estruturais na série temporal em estudo através do teste de Chow.

3. REFERENCIAL TEÓRICO

3.1 Caracterização das Infecções provocadas por parasitas transmitidos pelo solo

Doenças tropicais e associadas à pobreza são de suma relevância para a Saúde Pública, já que refletem as iniquidades vivenciadas por algumas populações e ratificam a importância de compreender suas ocorrências para um maior desenvolvimento humano e social (Brito *et al.*, 2022). Estes agravos afetam de maneira importante os continentes da África, Ásia e Américas, onde fatores determinantes de saúde como saneamento básico não abrangem toda a população e, portanto, favorecem a disseminação de agentes infecciosos e parasitários (Silva *et al.*, 2019).

Os parasitas são organismos que dependem de outros seres vivos, chamados de hospedeiros, para completar seu ciclo de vida. Esses hospedeiros podem ser vegetais ou animais e desempenham diferentes papéis na transmissão do parasita. O hospedeiro intermediário abriga o parasita em sua fase larvária ou assexuada, enquanto o hospedeiro definitivo é aquele no qual o parasita atinge sua fase reprodutiva (Oliveira *et al.*, 2023). Neste estudo, focamos em nematódeos parasitas que têm o ser humano como hospedeiro definitivo e utilizam o solo como principal meio de propagação.

Durante uma década (2010 – 2020), mais de 300 milhões de casos de parasitoses foram notificados no território brasileiro, sendo que 91.105 desses foram provocados por helmintos. Os helmintos são seres vivos que possuem corpo cilíndrico ou achatado visíveis a olho nu, podendo essa estrutura morfológica variar de centímetros à metros (Rodrigues *et al.*, 2023).

Os helmintos são nematódeos que possuem necessariamente parte do seu ciclo de vida no solo, por isso são classificados como geo-helmintos. Estes organismos se desenvolvem em seres humanos e outros animais por meio do contato direto com as formas ovoides ou larvais que colonizam o solo. Deste modo, a transmissão pode ocorrer de forma ativa ou passiva, sendo possível se contaminar com geo-helmintos através da ingestão de água ou alimentos contaminados por ovos parasitários, assim como, através da penetração de larvas parasitárias na pele (Albuquerque, 2019).

As infecções causadas por geo-helmintos apresentam-se na maioria dos casos de forma assintomática, favorecendo quadros de caráter crônico que podem desenfrear o crescimento da carga parasitária ao longo do tempo e desencadear uma série de sintomas clínicos que vão desde a desnutrição, até déficits cognitivos e obstruções intestinais (Ferreira *et al.*, 2002).

Nesta sessão, trataremos dos principais organismos transmitidos pelo solo responsáveis por parasitar seres humanos em todo o mundo. As doenças provocadas por estes geo-helminths, apesar de importantes para a saúde pública, recebem menos de 1% do orçamento global no que tange à investigação e pesquisa (Al Amin; Wadhwa, 2023).

3.2 Ascaridíase – Infecção provocada pelo nematódeo *Ascaris lumbricoides*

A ascaridíase é uma das infecções parasitárias mais comuns no mundo, responsável por afetar cerca de 800 milhões de pessoas em todo o globo. A doença se desenvolve por via fecal-oral, através da ingestão de água ou alimentos contaminados por ovos de parasitas. Após essa ingestão, os ovos transformam-se em larvas que irão eclodir no intestino delgado e migrar para o cólon com o intuito de penetrar na mucosa e chegar ao sangue portal para atingir o fígado e os pulmões (Veesenmeyer, 2022).

Este ciclo hepatotraqueal ocorre entre 10 e 14 dias após o contato com os ovos e permite que as larvas amadureçam ainda mais nos pulmões, penetrando os alvéolos, seguindo para os brônquios e traqueia para então serem engolidas pelo esôfago e chegarem ao intestino. É no intestino delgado que ocorre o desenvolvimento dos vermes para a fase adulta e reprodutiva, sendo possível a produção de até 200.000 ovos por dia (Claus *et al.*, 2018).

A morbidade e apresentação clínica da doença está associada à carga parasitária de vermes no intestino. Embora a infecção seja substancialmente assintomática na maior parte dos casos, é comum a apresentação de dores abdominais generalizadas associadas à vômito, distensão abdominal e obstipação. A ascaridíase também pode evoluir para quadros de pneumonites, danos hepáticos, biliares, pancreáticos e obstrução intestinal (Mbanga *et al.*, 2019).

O diagnóstico para a doença acontece por meio de avaliação clínica e investigação de ovos ou parasitas nas fezes. Além do exame parasitológico, durante o ciclo respiratório e intestinal inicial, os vermes podem ser identificados através de coleta de escarro e lavagens gástricas, ou ainda, pode haver alteração de marcadores séricos laboratoriais como eosinofilia, leucocitose e elevação da proteína C reativa (Claus *et al.*, 2018).

Ainda nos dias atuais, o esquema utilizado para redimir os casos de ascaridíase é a administração do albendazol, agente antiparasitário de amplo espectro que atua sobre os vermes no trato gastrointestinal e outros órgãos durante sua metabolização. A dose preconizada pela Organização Mundial da Saúde é de 400mg de albendazol em dose única, que tem se

demonstrado eficaz no controle de infecções dessa natureza em até quatro meses após o tratamento (Chai; Jung; Hong, 2021).

Outras estratégias para o controle da doença incluem melhorias nos sistemas de infraestrutura habitacionais, bons hábitos de higiene pessoal e administração de medicamentos em massa. Esses fatores quando postos em prática e atrelados a melhorias socioeconômicas nacionais despencam as taxas de prevalência para estas doenças, como aconteceu no Japão na década de 70 após implementação da Lei de Prevenção de Parasitoses (Hasegawa *et al.*, 2020).

3.3 Tricuríase – Infecção provocada pelo nematódeo *Trichuris trichiura*

A tricuríase é uma doença substancialmente endêmica em países tropicais e subtropicais, onde essa infecção afeta cerca de 500 milhões de pessoas. A doença se desenvolve através da ingestão de ovos parasitários em água e alimentos contaminados, onde após ingeridos se rompem no intestino delgado e migram para o cólon descendente, onde as larvas evoluem para vermes adultos (Doyle *et al.*, 2022).

Os vermes passam a habitar o intestino grosso provocando colite, doenças inflamatórias do intestino e em casos mais severos, prolapso retal. Cabe ressaltar, que o quadro de colite provocado pelo verme se dá pela liberação de ativos químicos produzidos por seu órgão único ao entrar em contato com a mucosa intestinal (Loukas; Maizels; Hotez, 2021).

O *T. trichiura* adulto possui entre um e dois anos de vida útil, e o número de ovos que podem ser postos por cada fêmea pode atingir a marca de 30.000 por dia. O diagnóstico da doença é dado com base nas apresentações clínicas do indivíduo e detecção de ovos ou DNA de parasitas nas fezes (Ishizaki *et al.*, 2021; Else *et al.*, 2020).

O tratamento recomendado para remissão de casos de tricuríase é a administração de anti-helmínticos como albendazol (400 mg/ dia – durante três dias) ou mebendazol (100 mg/ duas vezes ao dia – durante três dias ou 500 mg em dose única). Apesar disso, estudos apontam casos que evoluíram para a cura através da remoção de vermes de maneira endoscópica (Ishizaki *et al.*, 2022; Chai; Jung; Hong, 2021).

Cabe ressaltar que a dinâmica e fatores de risco para o desenvolvimento da Tricuríase dependem diretamente do consumo inadequado de água potável e maus hábitos de higiene das mãos e alimentos, assemelhando-se, portanto, ao comportamento da Ascaridíase que também é uma doença de transmissão fecal-oral (Almeida *et al.*, 2023).

3.4 Ancilostomíase – Infecção provocada pelos nematódeos *Necator americanus* ou *Ancylostoma duodenale*

A ancilostomíase é uma infecção crônica e comumente associada a casos de anemia ferropriva e déficit cognitivo em crianças. Essa doença afeta cerca de 230 milhões de pessoas em todo o mundo, impactando adversamente a produtividade anual e os indicadores de desenvolvimento humano (Hoogerwerf *et al.*, 2021).

A doença se desenvolve através da entrada percutânea de larvas parasitárias na pele, através dos pés e mãos ou ingesta oral. Após a infecção, os parasitas migram e se desenvolvem no intestino delgado, forçando o hospedeiro a criar uma tolerância imunológica ao parasita a longo prazo. Em consequência, com o passar do tempo a infecção pode começar a estabelecer alterações séricas e nutricionais no indivíduo ocasionando a perda de minerais como o ferro (Ellwanger *et al.*, 2022).

Os ancilostomídeos possuem dentes que se aderem à mucosa desencadeando uma pressão negativa que leva o hospedeiro a contrair sua musculatura e ocasionar a ruptura de capilares e arteríolas para ter o seu sangue drenado. O quadro de anemia ferropriva desencadeado pelos ancilostomídeos não se dá apenas pelo consumo de sangue pelo parasita, mas também pela eliminação de substâncias anticoagulantes liberadas por eles no intestino do hospedeiro que permitem que as áreas sangrantes permaneçam ativas (Al Amin; Wadhwa, 2023; Ellwanger *et al.*, 2022). Essa classe de helmintos é a única que se alimenta do sangue do hospedeiro. Todas as demais se fixam e interagem com a microbiota e mucosa intestinal, provocando alteração nos padrões de homeostase do organismo (Gordon *et al.*, 2020).

O diagnóstico da doença é dado a partir da interpretação de queixas clínicas, em suma gastrointestinais, e detecção de ovos parasitários ao microscópio através do exame parasitológico de fezes. Além desses métodos, atualmente é possível realizar método de cultura e técnicas de biologia molecular para identificação do parasita. Esses últimos recursos são considerados métodos mais avançados e acessíveis a sociedades mais desenvolvidas (Linghui *et al.*, 2022).

O tratamento recomendado para remissão de casos de ancilostomíase é a administração de albendazol (400 mg – em dose única), mebendazol (100 mg/ duas vezes ao dia – durante três dias ou 500 mg em dose única), ou ainda, pamoato de pirantel (11 mg/kg/ uma vez ao dia, durante três dias – dose máxima de 1g/dia). Ratifica-se que apesar de o esquema de doses

múltiplas ser mais complexo, a eficácia do tratamento é superior à do esquema de dose única, sendo, portanto, preferível quando tratar-se de áreas endêmicas (Veesenmeyer, 2022).

As queixas gastrointestinais, deficiência de micronutrientes e anemia são as principais complicações que impactam os índices de morbimortalidade, principalmente entre indivíduos em idade escolar. As complicações a longo prazo neste grupo vão desde o absenteísmo escolar até o atraso no desenvolvimento físico e cognitivo (Gitore *et al.*, 2020).

Ressalta-se que as coinfeções parasitárias são opções possíveis e facilitadas pela semelhança nas interações destes parasitas com o ambiente e hospedeiro (Kajero *et al.*, 2022). As infecções estudadas nessa sessão são de fácil associação no que tange a seu veículo de propagação e demais condições relacionadas ao ambiente, sociedade e indivíduo. Sabe-se que a carga parasitária influencia de maneira direta o prognóstico e indicadores de saúde, portanto, faz-se necessário reconhecer os casos em que infecções por múltiplos parasitas existam, principalmente em áreas endêmicas onde existe uma maior propensão à reinfeção (Kajero *et al.*, 2022).

3.5 Fundamentos para análise de Séries Temporais

Uma série temporal pode ser definida como um conjunto de observações ordenadas sequencialmente no tempo. Partindo desse conceito, a ideia de sequência no tempo garante que as observações exerçam certa dependência entre si e, portanto, tenham seus valores futuros influenciados por seus valores passados (Box; Jenkins; Reinsel, 2008; Chatfield, 1996).

A análise de séries temporais é voltada para séries do tipo discreta, ou ainda, séries que possuem observações com intervalos igualmente distribuídos (Chatfield, 1996). Nesta perspectiva, esse estudo discorrerá sob a análise de uma série histórica de prevalência de casos de geo-helmintíases no estado de Alagoas, onde as observações possuem periodicidade mensal e, portanto, intervalos igualmente distribuídos ao longo do tempo.

Nesse trabalho trataremos sistemas não-determinísticos, ou ainda, processos temporais estocásticos. Sistemas estocásticos são aqueles em que o futuro é parcialmente determinado por valores passados, portanto, a etapa de previsão segue a ideia de que os valores futuros possuem uma distribuição de probabilidade condicionada aos valores passados da série (Box; Jenkins; Reinsel, 2008).

Com o objetivo de fornecer um cenário estatístico que caracterize as flutuações aleatórias dos dados ao longo do tempo, assume-se que uma série temporal pode ser definida

como um conjunto de variáveis aleatórias indexadas no tempo. Portanto, podemos considerar uma sequência de variáveis aleatórias $x_1, x_2, x_3, \dots$, em que a variável aleatória x_1 denota o valor da série no instante de tempo um ($t=1$), x_2 denota o valor no instante de tempo dois ($t=2$) e assim, sucessivamente (Shumway; Stoffer, 2017).

Segundo Hyndman et al (2008), uma série temporal é formada pelos componentes: tendência (M_t), que conceitua a direção de longo-prazo da série; sazonalidade (S_t), que demonstra um padrão repetitivo em certa periodicidade; ciclos, que são padrões repetidos com certa regularidade, mas periodicidade desconhecida; e resíduos (R_t), o componente aleatório da série. Neste estudo a decomposição da série será dada da seguinte maneira:

$$X_t = M_t + S_t + R_t, t = 1, \dots, T$$

A tendência pode ser entendida como a mudança de direção de uma série no sentido de crescimento ou decrescimento, podendo assumir comportamento linear, quadrático ou exponencial. Ainda, pode ser determinada como uma mudança de longo termo no nível da média da série temporal (Chatfield, 1996).

Já a sazonalidade relaciona-se com flutuações periódicas no tempo que ocorrem em uma frequência fixa e conhecida. Geralmente, a sazonalidade em um conjunto está condicionada a periodicidade da coleta dos dados, podendo ser determinada em frequências diárias, semanais ou mensais, por exemplo (Lazzeri, 2020).

Os resíduos são resultantes da remoção da tendência e sazonalidade de uma série temporal, que pode ter comportamento aleatório ou não (Chatfield, 1996). Quando a variância dos resíduos é constante ao longo do tempo atribui-se o conceito de homoscedasticidade, que indica que a dispersão dos erros não muda conforme a série temporal avança. Mas quando esse pressuposto não é atendido, atribui-se o conceito de heterocedasticidade, que indica que a variância dos resíduos não é constante ao longo do tempo (Brockwell; Davis, 2010). Cabe ressaltar que a presença de ciclos é geralmente incorporada na tendência e, portanto, modelada implicitamente (Hyndman *et al.*, 2008).

Na análise de séries temporais também é explorado o conceito de processo estacionário, que segundo Morettin e Tolo (2006), é todo aquele que em qualquer período em que se faça uma medição, não exista comportamento dinâmico ao longo do tempo. Portanto, um processo estacionário é todo aquele em que suas propriedades estatísticas não sofrem interferência do

tempo, ou ainda, possuem sua média, variância e autocorrelação invariantes em relação ao deslocamento no tempo (de Matos, 2018; Chatfield, 1996).

Portanto, um processo estocástico $X = \{X_t, t \in T\}$ é estritamente ou fortemente estacionário se todas as distribuições conjuntas de $(X_{t_1}, X_{t_2}, \dots, X_{t_k})$ e de $(X_{t_1+t}, X_{t_2+t}, \dots, X_{t_k+t})$ são constantes para quaisquer $t_1, t_2, \dots, t_k$, para todo $t \in T$ (Marques, 2021).

A autocorrelação é uma medida de semelhança entre os valores de uma série temporal em diferentes instantes do tempo. Essa métrica é utilizada com o objetivo de detectar comportamentos não aleatórios, ou ainda, o grau de relação entre os valores da série temporal em diferentes atrasos ou *lags* (Chatfield, 1996). De modo geral, existem diversos coeficientes de correlação (r_k) para uma série, cada um correspondente a sua respectiva defasagem (k). Nesta perspectiva, seja r_k o coeficiente de autocorrelação com defasagem k , pode-se mensurar a correlação entre X_t e X_{t-k} , em que r_{-1} tratará a mensuração entre X_t e X_{t-1} , por exemplo. Assim sendo, podemos formalizar o coeficiente de correlação da seguinte maneira:

$$r_{-k} = \frac{\sum_{t=k+1}^T (x_t - \bar{x})(x_{t-k} - \bar{x})}{\sum_{t=1}^T (x_t - \bar{x})^2}$$


em que T é o comprimento da série e $\bar{x}$ a média dos valores da série (Metcalf; Cowpertwait, 2009; Hyndman; Athanasopoulos, 2018).

Para análise da autocorrelação são utilizados gráficos chamados de correlogramas. Esses gráficos demonstram os valores para a função de autocorrelação em diferentes *lags* de interesse, assim como, podem ser utilizados para identificar ordem de modelos autorregressivos e de médias móveis (Hyndman; Khandakar, 2008).

O correlograma é um suporte visual para compreender um conjunto de coeficientes de correlação em uma série. Nesse gráfico, os coeficientes são plotados contra as defasagens de autocorrelação k , para $k = 1, 2, 3, \dots, N$. Na prática, valores próximos de zero indicam ausência de correlação, enquanto valores próximos a 1 ou -1 indicam correlação máxima (Metcalf; Cowpertwait, 2009). O correlograma é interpretado por meio de um gráfico em que o eixo horizontal representa os *lags*, enquanto o eixo vertical indica o coeficiente de autocorrelação, variando entre -1 e 1. Valores elevados indicam forte relação entre observações passadas e presentes, sendo positivos quando há persistência de padrões e negativos quando há inversão de comportamento. As linhas tracejadas no gráfico representam intervalos de confiança, geralmente de 95%, permitindo verificar a significância estatística das correlações estimadas

(Haykin, 2009). Na Figura 1 é possível observar a representação gráfica dessa ferramenta estatística.

Figura 1: Representação gráfica de um correlograma em uma análise de Séries Temporais.



Fonte: Cowpertwait; Metcalfe, 2009.

A interpretação do correlograma possibilita a identificação de diferentes características da série. Quando as autocorrelações caem gradualmente ao longo dos *lags*, isso sugere a presença de uma tendência subjacente. Já a presença de picos regulares nos *lags* indica um padrão sazonal, comum em séries climáticas e epidemiológicas (Chatfield, 2004). Por outro lado, quando as correlações se mantêm próximas de zero e dentro do intervalo de confiança, a série pode ser considerada aleatória, sem dependência temporal evidente (Stock; Watson, 2015). A utilização do correlograma é essencial na modelagem de séries temporais, auxiliando na escolha de métodos estatísticos adequados, além de contribuir para o entendimento dos processos dinâmicos subjacentes às observações (Montgomery; Jennings; Kulahci, 2015).

3.6 Modelos Autorregressivos Integrados de Médias Móveis

Os Modelos Autorregressivos Integrados de Médias Móveis (ARIMA – *Autoregressive Integrated Moving Average*) são uma das abordagens amplamente utilizadas para modelagem e previsão de séries temporais. Esses modelos foram desenvolvidos por Box e Jenkins (1970) e se tornaram referência na estatística aplicada para a análise de dados sequenciais ao longo do tempo. A estrutura do ARIMA é definida por três componentes principais: autorregressão (AR),

integração (I) e médias móveis (MA), representados pelos parâmetros (p, d, q) , respectivamente (Box; Jenkins; Reinsel, 2015).

O componente autorregressivo (AR) refere-se à relação linear entre uma observação e seus valores passados (*lags*). Ele é formalmente expresso como:

$$Y_t = c + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t$$

onde Y_t representa o valor da série no tempo t , c é uma constante, ϕ_1 são os coeficientes autorregressivos e ε_t é um termo de erro ou ruído branco.

O termo integração (I) refere-se ao número de diferenciações necessárias para tornar a série estacionária, ou seja, para remover tendências e flutuações sazonais. A diferenciação é representada por:

$$Y'_t = Y_t - Y_{t-1}$$

quando $d=1$, e pode ser aplicada sucessivamente para alcançar estacionariedade.

Por fim, o componente médias móveis (MA) modela a relação entre o valor atual e os erros passados, sendo descrito como:

$$Y_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}$$

onde μ é a média da série; θ_i são os coeficientes de médias móveis; e ε_t são os erros aleatórios passados.

A modelagem ARIMA envolve a identificação dos parâmetros p, d, q , geralmente feita por meio dos critérios de informação quem podem ser de Akaike (AIC), Akaike corrigido (AICc) ou Bayesiano (BIC) para seleção do modelo (Hyndman; Athanasopoulos, 2018). O critério AIC penaliza modelos mais complexos para evitar sobreajuste, favorecendo aqueles que oferecem o melhor equilíbrio entre precisão e simplicidade, podendo ser representado por:

$$AIC = -2 \log(L) + 2k$$

em que, L é a verossimilhança do modelo e k é o número de parâmetros estimados (Hyndman; Athanasopoulos, 2018). Além disso, pode ser utilizado o AIC corrigido (AICc) para lidar com

situações em que o tamanho da amostra T é pequeno em relação ao número de parâmetros k do modelo, denotado por:

$$AICc = AIC + \frac{2k(k+1)}{T-k-1}$$

Ou o critério de informação bayesiano (BIC), uma variação do AIC, mas com uma penalização mais forte para modelos com muitos parâmetros, denotado por:

$$BIC = AIC + k [\log (T) - 2]$$

Diante desses critérios de informação, é escolhido o modelo com menor valor de AIC, AICc ou BIC, sendo considerado o mais adequado para a previsão. Uma extensão relevante do modelo ARIMA é o SARIMA (Seasonal ARIMA), que inclui componentes sazonais, tornando-o adequado para séries que apresentam padrões cíclicos (Hyndman; Athanasopoulos, 2018; Montgomery; Jennings; Kulahci, 2015).

A utilização do ARIMA em previsões de séries temporais tem ampla aplicação em epidemiologia, economia, engenharia e ciências ambientais. Sua flexibilidade e precisão fazem dele um dos modelos mais robustos para a identificação e projeção de padrões temporais, permitindo que gestores e pesquisadores tomem decisões fundamentadas em análises quantitativas rigorosas (Stock; Watson, 2015).

3.7 Algoritmo de Alisamento exponencial de Holt

O alisamento exponencial de Holt é uma extensão do alisamento exponencial simples, amplamente utilizado em modelos de previsão de séries temporais. Desenvolvido por Charles Holt (1957), esse método é particularmente eficaz para séries temporais que apresentam tendências, oferecendo uma previsão mais robusta em comparação aos métodos tradicionais. A técnica é fundamentada na suavização de componentes de nível e tendência, permitindo que o modelo se adapte tanto às flutuações sazonais quanto às variações de longo prazo observadas nas séries temporais (Holt, 2004). O princípio central do alisamento exponencial de Holt é atribuir maior peso aos dados mais recentes, o que reflete a suposição de que os eventos passados têm relevância para as previsões futuras. O modelo é composto por duas equações principais: a primeira atualiza o nível da série temporal, enquanto a segunda ajusta a tendência (Holt, 2004).

Essa abordagem busca capturar não apenas o comportamento médio dos dados ao longo do tempo, mas também a sua variação ou crescimento linear. A fórmula de atualização do nível leva em consideração o valor observado na série e a previsão do período anterior e pode ser representada por:

$$L'_t = \alpha \times y_t + (1 - \alpha) \times (L'_{t-1} + T'_{t-1})$$

em que, para a estimativa do nível da série, L'_t é a estimativa do nível no tempo t ; y_t é o valor real da série temporal no tempo t ; L'_{t-1} é a estimativa do nível no período anterior; T'_{t-1} é a estimativa da tendência no período anterior; e α o parâmetro de suavização do nível (onde $0 < \alpha < 1$).

Além disso, a modelagem da tendência depende tanto da previsão da tendência passada quanto do erro de previsão no período anterior. A fórmula para a estimação desse componente pode ser representada por:

$$T'_t = \beta \times (L'_t - L'_{t-1}) + (1 - \beta) \times T'_{t-1}$$

em que, T' é a estimativa da tendência no tempo t e β o parâmetro de suavização da tendência (onde $0 < \beta < 1$).

Essa técnica permite a introdução de parâmetros de suavização, que controlam a velocidade de adaptação do modelo às novas informações. Esses parâmetros são ajustados para otimizar a previsão, o que implica em encontrar o equilíbrio entre a suavização excessiva, que pode levar à perda de informações, e a adaptação excessiva, que pode resultar em um modelo muito volátil (Brown, 1963). A técnica de Holt, ao focar na captura da tendência, torna-se uma ferramenta poderosa para prever séries temporais que exibem um comportamento linear de crescimento ou decrescimento.

É importante destacar que a escolha dos parâmetros α e β pode influenciar significativamente a suavização e a qualidade das previsões. A otimização desses parâmetros, muitas vezes realizada por métodos de minimização de erro como o erro quadrático médio, é um aspecto crucial na implementação bem-sucedida do modelo (Hyndman; Athanasopoulos, 2018).

O algoritmo de alisamento exponencial de Holt é particularmente útil quando a série não apresenta variações sazonais, mas sim uma tendência de longo prazo. Sua principal vantagem

está na capacidade de previsão de séries com tendências, sendo utilizado em uma ampla gama de áreas, como economia, meteorologia e controle de estoques. No entanto, quando aplicado a séries com componentes sazonais, a versão de Holt-Winters é preferível, pois integra um componente de sazonalidade ao modelo (Hyndman & Athanasopoulos, 2018).

3.8 Modelos Erro, Tendência, Sazonalidade

Os Modelos Erro, Tendência e Sazonalidade (ETS) são uma classe importante de modelos de suavização exponencial para previsões de séries temporais. Além disso, combinam componentes de erro, tendência e sazonalidade para gerar previsões mais precisas, permitindo a modelagem de diferentes comportamentos em uma série. A principal vantagem dos modelos ETS é sua flexibilidade, pois eles podem ser ajustados para capturar uma variedade de padrões temporais, desde séries com componentes sazonais até séries com tendências lineares ou exponenciais (Hyndman et al., 2008).

Os modelos ETS são baseados na ideia de que uma série temporal pode ser decomposta em três componentes principais: erro (E), tendência (T) e sazonalidade (S). Esses componentes são modelados separadamente e, em seguida, combinados para formar a previsão. A equação geral para um modelo ETS pode ser representada da seguinte forma:

$$Y_t = \ell_{t-1} + \beta_{t-1} + S_{t-m} + \varepsilon_t$$

em que: Y_t denota o valor observado da série temporal no tempo t ; ℓ_{t-1} o nível da série temporal no tempo $t - 1$; β_{t-1} a tendência no tempo $t - 1$; S_{t-m} o componente sazonal no tempo $t - m$; enquanto ε_t representa o erro de previsão ou resíduo.

Os componentes ℓ_t , β_t e S_t são atualizados por fórmulas de suavização exponencial. Para um modelo ETS simples, com adição de erro, tendência e sazonalidade, as equações de suavização para nível (ℓ_t), tendência (β_t) e sazonalidade (S_t) são dadas por:

$$\begin{aligned}\ell_t &= \alpha (Y_{t-1} - S_{t-m}) + (1 - \alpha)(\ell_{t-1} + \beta_{t-1}) \\ \beta_t &= \gamma (\ell_t - \ell_{t-1}) + (1 - \gamma) \beta_{t-1} \\ S_t &= \delta (Y_t - \ell_t) + (1 - \delta) S_{t-1}\end{aligned}$$

em que α , γ , δ são os parâmetros de suavização para o nível, tendência e sazonalidade, respectivamente. Além disso, m representa a periodicidade da sazonalidade, como por exemplo, 12 para séries mensais com sazonalidade anual. Essas fórmulas são iterativas, ou seja, a cada nova observação, os parâmetros ℓ_t , β_t e S_t são atualizados para refletir a evolução da série temporal.

A escolha dos parâmetros α , γ , δ é crucial para o sucesso do modelo, pois define como os componentes de erro, tendência e sazonalidade são pesados na previsão. A otimização desses parâmetros, frequentemente realizada por meio de métodos de minimização de erro, como o erro quadrático médio (MSE), é uma etapa fundamental na implementação do modelo. A adequada configuração desses parâmetros permite que o modelo se ajuste de maneira eficaz aos dados, maximizando a acurácia das previsões (Hyndman; Athanasopoulos, 2018).

O comportamento de cada componente da série (erro, tendência e sazonalidade) pode ser modelado de formas aditiva, multiplicativa ou amortecida, dependendo das características da série temporal analisada. A diferença entre os modelos aditivos e multiplicativos está na forma como os componentes de erro, tendência e sazonalidade são combinados na equação de previsão. No modelo aditivo, a série temporal é representada pela soma dos componentes, como na representação abaixo:

$$Y_t = \ell_t + \beta_t + S_t + \varepsilon_t$$

em que, Y_t representa o valor observado da série temporal no tempo t ; ℓ_t o nível da série; β_t é a tendência; S_t a sazonalidade e ε_t o erro ou resíduo. Esse modelo é adequado quando a amplitude da variação sazonal e da tendência não muda com o nível da série. Ou seja, os efeitos de sazonalidade e tendência permanecem constantes, independentemente de quanto o nível da série aumente ou diminua (Hyndman; Athanasopoulos, 2018; Gardner, 1985).

Já no modelo multiplicativo, os componentes são multiplicados entre si e a série temporal é representada pelo produto dos componentes, como na representação abaixo:

$$Y_t = \ell_t \times \beta_t \times S_t \times \varepsilon_t$$

Este modelo é mais adequado quando a amplitude das flutuações sazonais e a tendência depende do nível da série temporal. Ou seja, quando a variação sazonal ou a tendência aumenta

ou diminui à medida que o nível da série muda (Hyndman; Athanasopoulos, 2018; Gardner, 1985).

O termo amortecido refere-se ao tipo de suavização utilizada para ajustar o nível e a tendência da série temporal. A suavização exponencial é usada para dar mais peso aos valores mais recentes e reduzir o impacto de valores mais antigos na previsão. A ideia é que a atualização do nível e da tendência não seja feita de forma completamente imediata, mas de forma gradual, utilizando um fator de amortecimento. A fórmula geral para suavização exponencial amortecida para o nível e a tendência é:

$$\begin{aligned}\ell_t &= \alpha (Y_t - S_{t-m}) + (1 - \alpha)(\ell_{t-1} + \beta_{t-1}) \\ \beta_t &= \gamma (\ell_t - \ell_{t-1}) + (1 - \gamma) \beta_{t-1}\end{aligned}$$

Para a escolha do modelo ideal, o algoritmo analisa diversas combinações de erro (E), tendência (T) e sazonalidade (S), testando quais melhor se ajustam à série temporal. As principais etapas envolvem a identificação do erro: que pode ser aditivo (A) ou multiplicativo (M); identificação da tendência: que pode ser inexistente (N), aditiva (A), amortecida (Ad) ou multiplicativa (M); e identificação da sazonalidade: que pode ser inexistente (N), aditiva (A) ou multiplicativa (M). Para cada combinação possível de ETS, os parâmetros do modelo são estimados usando suavização exponencial, normalmente ajustados por máxima verossimilhança. Isso garante que cada modelo seja treinado com valores ótimos para representar a série temporal. Após estimar os parâmetros, o algoritmo avalia a qualidade do ajuste usando critérios estatísticos, como os Critérios de Informação AIC, AICc ou BIC. Esse processo automatizado de seleção de modelos ETS permite identificar a configuração mais adequada para a previsão, garantindo que a escolha seja baseada em critérios estatísticos robustos e otimizados. Isso torna o método uma ferramenta poderosa para análise de séries temporais, especialmente em contextos haja a necessidade de modelagem flexível e precisa. (Hyndman; Athanasopoulos, 2018).

Cabe ressaltar que modelos numericamente instáveis, como aqueles com erro multiplicativo em séries contendo zeros ou valores negativos, tendem a ser descartados. Ademais, modelos muito complexos são penalizados para evitar sobreajuste e a tendência amortecida pode ser escolhida se for identificada uma redução gradual na taxa de crescimento. Algumas combinações específicas dos componentes de Erro, Tendência e Sazonalidade podem levar a instabilidades numéricas, dificultando a aplicação prática desses modelos. Em particular,

os modelos ETS (A, N, M), ETS (A, A, M) e ETS (A, Ad, M) apresentam desafios computacionais devido à possibilidade de divisão por valores próximos de zero nas equações de estado, o que pode comprometer a precisão dos resultados. Por esse motivo, tais configurações geralmente não são consideradas na seleção do modelo mais adequado (Hyndman; Athanasopoulos, 2018).

Além disso, modelos com erro multiplicativo são especialmente úteis para séries temporais estritamente positivas, pois permitem que a variabilidade do erro seja proporcional ao nível da série. No entanto, esses modelos tornam-se numericamente instáveis quando os dados contêm zeros ou valores negativos, o que inviabiliza sua aplicação em certos contextos. Para séries temporais que não são estritamente positivas, a abordagem mais apropriada consiste em utilizar apenas os seis modelos totalmente aditivos, garantindo maior robustez na modelagem e previsão (Hyndman; Athanasopoulos, 2018).

3.9 Medidas de acurácia na avaliação de modelos preditivos

A avaliação de modelos preditivos em séries temporais é uma etapa essencial para garantir previsões confiáveis e úteis. Diversas métricas de erro são utilizadas para quantificar o desempenho de um modelo, sendo as mais comuns o Erro Médio Absoluto (MAE), o Erro Médio Percentual Absoluto (MAPE) e a Raiz do Erro Quadrático Médio (RMSE). Cada uma dessas medidas oferece diferentes perspectivas sobre a precisão da previsão e deve ser escolhida de acordo com as características da série temporal analisada.

O Erro Médio Absoluto (MAE) mensura a média dos erros absolutos entre os valores previstos e os valores reais. Essa métrica tem a vantagem de ser interpretável diretamente na unidade dos dados analisados, facilitando a compreensão da magnitude do erro. Sua fórmula é dada por:

$$MAE = \frac{1}{n} \sum_{t=1}^n |Y_t - Y'_t|$$

em que, Y_t representa o valor real da série no instante t ; Y'_t o valor previsto pelo modelo, e n é o número total de observações. O MAE é amplamente utilizado por sua simplicidade e robustez, especialmente quando não se deseja penalizar discrepâncias extremas de maneira exagerada (Hyndman; Athanasopoulos, 2018).

Já o Erro Percentual Absoluto Médio (MAPE) é uma métrica relativa que expressa o erro médio em termos percentuais, facilitando a comparação entre diferentes séries temporais ou modelos aplicados a escalas distintas. Sua equação é dada por:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Y_t - Y'_t}{Y_t} \right| \times 100$$

O MAPE é frequentemente utilizado para medir a precisão relativa de um modelo, sendo interpretado como o erro médio percentual da previsão. Um MAPE de 10%, por exemplo, indica que, em média, as previsões erram cerca de 10% em relação aos valores reais. Apesar de sua utilidade, o MAPE possui limitações importantes, especialmente quando os valores reais da série podem assumir valores próximos de zero. Nessas situações, a fração $\frac{Y_t - Y'_t}{Y_t}$ pode gerar valores extremamente altos, distorcendo a métrica (Makridakis; Wheelwright; Hyndman, 1998).

A Raiz do Erro Quadrático Médio (RMSE) é uma métrica que penaliza fortemente erros grandes, tornando-a útil em contextos em que desvios extremos são críticos. Essa métrica pode ser denotada por:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - Y'_t)^2}$$

Diferentemente do MAE, o RMSE eleva os erros ao quadrado antes de calcular a média, o que amplifica discrepâncias maiores. Assim, ele é especialmente sensível a previsões que falham em capturar picos e variações abruptas da série temporal. Isso pode ser desejável em aplicações onde erros maiores são mais prejudiciais (Chatfield, 2000).

A escolha da métrica de erro depende dos objetivos da previsão e da natureza da série temporal. Se o foco for a interpretabilidade na unidade original dos dados, o MAE é uma opção adequada. Para comparações relativas entre diferentes modelos ou séries, o MAPE é útil, desde que os valores reais não sejam próximos de zero. Já o RMSE é preferido quando erros grandes precisam ser mais penalizados. Em muitos estudos, a utilização combinada dessas métricas é recomendada, proporcionando uma visão mais abrangente sobre a qualidade das previsões. Dessa forma, a avaliação da acurácia deve ser sempre contextualizada, garantindo que a métrica escolhida esteja alinhada com os objetivos práticos da modelagem e previsão (Hyndman; Koehler, 2006; Makridakis; Wheelwright; Hyndman, 1998; Chatfield, 2000).

4. MATERIAIS E MÉTODOS

4.1 Tipo de estudo

Trata-se de um estudo ecológico, observacional, de abordagens retrospectiva e prospectiva, do tipo Séries Temporais. Os estudos ecológicos possuem como principal característica, a premissa de que sua unidade de pesquisa seja grupos de indivíduos. Nesta perspectiva, essa metodologia permite a verificação de possíveis relações entre exposições e desfechos de saúde em populações ou grupos (Pereira, 2017).

Na análise de séries temporais o tempo é utilizado como variável de mensuração, o que permite modelar dados relacionados a fenômenos de adoecimento e realizar previsões para a ocorrência de doenças, contribuindo para o fortalecimento de políticas de prevenção e controle mais efetivas (Xavier, 2020).

4.2 Local e período

A pesquisa será desenvolvida com base nos indicadores de Vigilância Epidemiológica disponibilizados pelo Programa de Controle da Esquistossomose (PCE) <https://datasus.saude.gov.br/acesso-a-informacao/programa-de-controle-da-esquistossomose-pce/>. O PCE é uma iniciativa ao combate de doenças negligenciadas, e embora o seu foco seja a esquistossomose, o programa monitora a ocorrência de ascaridíase, ancilostomíase e tricuriase, que são doenças frequentemente associadas ao saneamento deficitário e semelhantes em sua dinâmica de transmissão (Katz, 2018).

Os dados coletados fazem referência ao número de casos dessas geo-helmintíases notificado pelo programa no período entre janeiro de 2010 e dezembro de 2021. Essas parasitoses afetam uma parcela importante da população brasileira e são detectadas através dos exames parasitológicos oferecidos pelo PCE em áreas endêmicas (Katz, 2018).

4.3 População e amostra

A população-alvo deste estudo é composta por indivíduos residentes no estado de Alagoas, que abriga 102 municípios e apresenta uma densidade demográfica de 112,38 habitantes/km² (IBGE, 2022). O estado alagoano fica situado na região Nordeste do Brasil,

território historicamente relacionado a ocorrência de doenças associadas a baixas condições econômicas e de saneamento básico (Katz, 2018). Cabe ressaltar que cerca de 69% da população nordestina não é contemplada com o esgotamento sanitário, fator de importância para a propagação de parasitoses nesse território (SNIS, 2022). A amostra utilizada nesta pesquisa foi composta por crianças e adolescentes de 7 a 17 anos de idade, faixa etária monitorada pelo programa no período de janeiro de 2010 a dezembro de 2021.

4.4 Critérios de inclusão e exclusão

Foram considerados para a pesquisa os casos de ascaridíase, tricuriase e ancilostomíase notificados em residentes alagoanos, de ambos os sexos, com idade entre 7 e 17 anos no período entre janeiro de 2010 e dezembro de 2021 (Katz, 2018; PCE, 2024). Não foram incluídas informações relacionadas a outras doenças monitoradas, ou ainda, variáveis coproparasitológicas também reportadas pelo programa (PCE, 2024).

4.5 Processamento e análise dos dados

As informações coletadas foram tabuladas e submetidas à análise através do software R (versão 4.3.1), que pode ser entendido como uma linguagem de programação ou ambiente computacional que facilita a interação e análise de dados diversos através de modelos estatísticos (*R Development Core Team*, 2024). Para a análise da série temporal fez-se uso das bibliotecas *seastests*, *tseries* e *forecast*. Além dessas, foram utilizadas as bibliotecas *ggplot2* e *RColorBrewer* para criação de gráficos e a *strucchange* para realização do teste de quebra estrutural.

A modelagem dos dados para Séries Temporais foi realizada a partir da taxa de prevalência das geo-helminthíases (ascaridíase, tricuriase e ancilostomíase) para cada mês e ano em questão na população monitorada pelo PCE. As taxas foram calculadas a partir do somatório de casos para as doenças e população trabalhada pelo programa nos respectivos meses de cada ano, ou seja:

$$Prevalência\ percentual = \frac{\sum \text{casos mensais de geo-helminthíases a cada ano}}{\text{População mensal trabalhada pelo PCE a cada ano}} \times 100$$

As taxas de prevalência foram modelados em uma série temporal mensal. Portanto, este estudo contará com a presença de 144 observações para compor o modelo preditivo, sendo a distribuição, iniciada em janeiro de 2010 e finalizada em dezembro de 2021.

Uma Série Temporal pode ser entendida como um conjunto de observações sequenciais ordenados no tempo. Sua principal característica parte do pressuposto de que suas observações estão correlacionadas e que esse conjunto corresponde a um processo estocástico ou arbitrário (Morettin; Toloi, 2006). Nesta perspectiva, seja T um conjunto arbitrário, ou ainda, uma trajetória de observações sequenciais ao longo do tempo, o mecanismo gerador da série pode ser representado pela seguinte equação:

$$X = \{X_t; t \in T\}, t = 1, \dots, T$$

em que X é o conjunto de todas as observações (X_t) ao longo do tempo (t) e todos os valores possíveis de t pertencentes a T .

Neste estudo, a análise da série temporal foi realizada a partir de abordagens para séries univariadas. Os dados foram modelados utilizando o modelo Autorregressivos Integrados de Médias Móveis (ARIMA), Alisamento Exponencial de Holt (AEHolt) e o Modelo Erro, Tendência e Sazonalidade (ETS). A performance dos algoritmos foi avaliada em diferentes horizontes de previsão, garantindo uma análise abrangente e comparativa. Além disso, a série foi analisada quanto a presença de quebras estruturais, etapa que permitiu a identificação de mudanças significativas na estrutura do processo gerador dos dados.

4.6 Aspectos éticos


A pesquisa utilizou dados de origem secundária, portanto, não demandou submissão ao Comitê de Ética e Pesquisa envolvendo Seres Humanos, conforme a Resolução Nº 510 de 2016 do Conselho Nacional de Saúde.

5. RESULTADOS

5.1 Análise exploratória

Nesta etapa da análise concedemos a abordagem retrospectiva, dando-se ênfase a caracterização da série através da identificação de padrões, tendências e relação entre as variáveis nos dados históricos (Box *et al.*, 2015). A série temporal estudada possui o total de 144 observações, que representam as taxas mensais de prevalência de geo-helmintíases no estado de Alagoas entre janeiro de 2010 e dezembro de 2021. A Figura 1 apresenta a evolução temporal das taxas de prevalência de geo-helmintíases no estado de Alagoas ao longo do tempo.

Figura 2: Série temporal para a prevalência de geo-helmintíases no estado de Alagoas entre janeiro de 2010 e dezembro de 2021.



Fonte: elaboração própria, 2024.

É possível observar uma tendência geral de redução nas taxas de prevalência ao longo do período, com valores iniciais acima de 30% em 2010, declinando progressivamente até níveis inferiores a 10% em 2021. Entretanto, apesar da tendência decrescente, a série exibe oscilações significativas, com picos em momentos específicos, como em 2016 e 2018, possivelmente associados a fatores sazonais ou eventos pontuais, como períodos de intensificação de chuvas ou alterações na eficácia das intervenções de controle.


A prevalência média de geo-helminhos na amostra foi de 12,7% e a análise dos quartis da distribuição evidenciou que 75% das taxas percentuais estiveram abaixo de 16,87%. As medidas descritivas da série temporal podem ser observadas na Tabela 1.

Tabela 1: Medidas descritivas para a prevalência de geo-helmintíases no estado de Alagoas entre janeiro de 2010 e dezembro de 2021.

Medida descritiva	Valor mensurado
Valor mínimo	5,186
Valor máximo	31,339
Média	12,714
Mediana	10,923
1º quartil	7,968
3º quartil	16,871

Para detectar a sazonalidade na série temporal foi realizado o teste de Friedman, comumente utilizado para comparar fenômenos mensurados sob as mesmas condições, ou ainda, observações consideradas dependentes (Friedman, 1937). Esse teste verifica a hipótese nula de que as medianas dos rankings nos períodos são iguais, contra a hipótese alternativa de que ao menos um dos períodos apresenta uma mediana diferente, indicando sazonalidade (Friedman, 1937). Para a série em estudo foi identificada a não rejeição da hipótese nula sob um nível de significância de 5% e, portanto, ausência de padrões de sazonalidade. Na Figura 2 é possível visualizar como as taxas de prevalência se comportaram nos diferentes períodos ou anos.

Figura 3: Ausência de padrões de sazonalidade para a série de prevalência de geo-helmintíases em Alagoas entre janeiro de 2010 e dezembro de 2021.



Fonte: elaboração própria, 2024.

A ausência de sazonalidade para a série em estudo indica que as geo-helminthiases não apresentam padrões de ocorrência repetitivos ou regulares ao longo do tempo. Ou seja, a prevalência das doenças no estado de Alagoas não segue um padrão de regularidade em ciclos temporais definidos, como em meses ou estações do ano.

A estacionariedade foi observada através do teste de Kwiatkowski-Phillips-Schmidt-Shin (KPSS) (Kwiatkowski *et al.*, 1992), que verifica se uma série temporal possui média e variância constantes ao longo do tempo. Aqui procura-se avaliar a hipótese nula de que uma série temporal é estacionária em torno de uma tendência determinística e a hipótese alternativa de que a série temporal é não estacionária (Kwiatkowski *et al.*, 1992). Na série estudada foi identificada a rejeição da hipótese nula sob um nível de significância de 5% (p-valor <0,01) e, portanto, ausência de estacionariedade. Essa métrica permite inferir que a prevalência de geo-helminthiases em Alagoas segue padrões de aleatoriedade e que não possuem propriedades como média e variância constantes ao longo do tempo.

5.2 Análise preditiva

Na próxima etapa da análise concedemos a abordagem prospectiva, dando-se ênfase a utilização de modelos para previsão de valores futuros com base em séries de dados históricos (Hyndman; Athanasopoulos, 2018). Aqui objetiva-se a realização de possíveis projeções para a ocorrência de geo-helminthiases no estado de Alagoas com base nos dados observados entre janeiro de 2010 e dezembro de 2021.

Quatro séries temporais distintas foram desenvolvidas para avaliar a capacidade preditiva em diferentes horizontes de previsão: 1, 3, 6 e 12 passos à frente. Para realizar a previsão de 1 passo à frente, foram consideradas 143 observações, abrangendo dados de prevalência de janeiro de 2010 a novembro de 2021. Para a previsão de 3 passos à frente, utilizaram-se 141 observações, cobrindo o período de janeiro de 2010 a setembro de 2021. Já para a previsão de 6 passos à frente, a série foi composta por 138 observações, com valores de janeiro de 2010 a junho de 2021. Por fim, para a previsão de 12 passos à frente, a análise considerou 132 observações, correspondentes ao intervalo de janeiro de 2010 a dezembro de 2020.

A análise dos dados em diferentes momentos do tempo é motivada para que haja a observação das previsões quando a dinâmica da série varia. A avaliação da precisão das previsões foi realizada por meio das métricas de acurácia: Erro Absoluto Médio (MAE), Raiz

do Erro Quadrático Médio (RMSE) e Erro Percentual Absoluto Médio (MAPE), permitindo uma análise detalhada do desempenho dos modelos em cada horizonte de previsão.

Essas são métricas amplamente utilizadas para avaliar a precisão de previsões feitas por modelos. O MAE mensura, em média, o quanto as previsões diferem dos valores reais, considerando apenas a magnitude dos erros, o que facilita sua interpretação de forma clara e direta (Hyndman; Koehler, 2006). O RMSE, por sua vez, também avalia o desvio médio, mas atribui maior peso a erros maiores, pois eleva essas diferenças ao quadrado antes de calcular a média, destacando desvios mais pronunciados. Ambas as métricas são expressas na mesma unidade dos dados analisados, com o RMSE geralmente sendo ligeiramente maior devido à sua sensibilidade a erros mais amplos (Chai; Draxler, 2014). Além disso, o MAPE mensura o erro percentual médio entre os valores previstos e os valores reais. Nesse sentido, quanto menor o valor do MAPE, melhor a precisão do modelo de previsão (Makridakis; Wheelwright; Hyndman, 1998).

5.2.1 Modelo Autorregressivo Integrado de Médias Móveis (ARIMA)

Inicialmente foi aplicada a classe de modelos Autorregressivos Integrados de Médias Móveis (ARIMA), composta por três etapas principais: identificação do modelo, estimação dos parâmetros por máxima verossimilhança e análise diagnóstica para verificar a adequação do ajuste (Box; Jenkins; Reinsel, 2008; Box; Tiao, 1975).


A identificação do modelo foi realizada por meio de um algoritmo (Hyndman; Khandakar, 2008) que estima os parâmetros de um modelo ARIMA de ordem (p,d,q) , em que p corresponde aos termos autorregressivos (AR), d ao número de diferenciações necessárias para tornar a série estacionária e q aos parâmetros de média móvel (MA). Os valores de p e q foram selecionados com base no Critério de Informação de Akaike (AIC), enquanto d foi definido por meio do teste KPSS, que avalia a estacionariedade da série. Após identificar o modelo mais adequado, foi utilizado um procedimento *stepwise* para refinar e selecionar o melhor candidato (Akaike, 1970; Basseto, 2022).

O critério AIC apontou o modelo ARIMA (0,1,1) como a melhor opção para a série, uma vez que minimizou o valor do critério. Entretanto, optou-se por ajustar a série utilizando o segundo modelo mais bem classificado, o ARIMA (1,1,1), com o objetivo de incluir parâmetros autorregressivos e avaliar seu impacto no desempenho preditivo.

Com o modelo ajustado, foi conduzida a análise diagnóstica para verificar o comportamento dos resíduos. Para isso, aplicou-se o teste de Ljung-Box, que testa a hipótese nula de independência residual contra a hipótese alternativa de dependência entre os resíduos (Ljung; Box, 1978). Os resultados indicaram que a hipótese nula não foi rejeitada ao nível de significância de 5% (p-valor = 0,148), confirmando a independência residual. Essa validação garantiu a adequação do modelo para a etapa subsequente de previsão.

A Figura 3 representa a série real e a série predita pelo modelo ARIMA (1,1,1) para previsões a 12 passos. Essa representação permite observar a precisão do modelo para capturar a dinâmica da série ao longo do tempo.

Figura 4: Série real *versus* série obtida através do modelo ARIMA de ordem (1,1,1).



Fonte: elaboração própria, 2024.

Na Tabela 2 é possível comparar os valores reais e os valores das previsões do modelo ARIMA (1,1,1) para 1, 3, 6 e 12 passos à frente.

Tabela 2: Valores reais e valores previstos pelo modelo ARIMA de ordem (1,1,1).

Horizonte de previsão	Período	Valores reais	Modelo ARIMA (1,1,1)
1	Dez 2021	5,2308	6,5906
3	Out 2021 -- Dez 2021	6,9524	6,6807
		5,4492	6,8841
		5,2308	6,8522

6	Jul 2021 -- Dez 2021	5,6084	6,7709
		6,3587	6,6565
		7,9783	6,6752
		6,9524	6,6722
		5,4492	6,6727
		5,2308	6,6726
12	Jan 2021 -- Dez 2021	5,2646	5,9521
		6,5262	5,8204
		8,0308	5,8442
		7,7091	5,8399
		6,7323	5,8406
		6,0723	5,8405
		5,6084	5,8405
		6,3587	5,8405
		7,9783	5,8405
		6,9524	5,8405
		5,4492	5,8405
		5,2308	5,8405


A análise dos resultados das previsões utilizando o modelo ARIMA (1,1,1) indica uma tendência de aproximação dos valores estimados aos valores reais ao longo dos diferentes horizontes temporais. Para previsões 1 passo à frente, o valor real foi 5,2308, enquanto a previsão do modelo foi 6,5906, mostrando um leve desvio. No horizonte de 3 passos à frente, os valores previstos mantêm-se próximos, mas ainda superiores aos reais, indicando uma superestimação. Já no horizonte de 6 passos à frente, observa-se uma oscilação entre os valores reais e os previstos. Embora o modelo tenha captado a tendência geral, os valores previstos tendem a se manter acima da média dos valores reais. Para o horizonte de 12 passos à frente há um comportamento semelhante, os valores previstos apresentam menor variabilidade do que os reais. Isso indica que o modelo pode estar captando bem a tendência central da série, mas não suas variações bruscas. De forma geral, o ARIMA (1,1,1) demonstrou capacidade de captar a tendência dos dados, mas apresentou superestimação em alguns períodos e suavização excessiva em horizontes mais longos.

5.2.2 Algoritmo de alisamento exponencial de Holt

Posteriormente, foi aplicado o algoritmo de Alisamento Exponencial de Holt (AEHolt) (Holt, 1957), desenvolvido para prever séries temporais que apresentam uma tendência definida. Esse método incorpora uma constante adicional de suavização que reflete o crescimento da série de um período para outro, representando a direção ou o padrão de tendência da série temporal (Makridakis; Wheelwright; Hyndman, 1998).

Diferentemente do alisamento exponencial simples, que suaviza apenas o nível da série, o método de Holt suaviza também a tendência, fator que permite modelar séries com crescimento ou declínio. Os parâmetros de suavização são ajustados utilizando métodos heurísticos, que buscam otimizar o desempenho do modelo ao adaptar os pesos aplicados às observações mais recentes e às tendências. Vale destacar que as previsões geradas por este método tendem a exibir um comportamento linear constante ao longo do tempo, o que pode levar à sobrestimação dos valores em horizontes de previsão mais longos (Hyndman; Athanasopoulos, 2018). A Figura 4 apresenta a série real e a série predita pelo algoritmo de AEHolt. Essa representação permite observar a capacidade preditiva do algoritmo ao realizar previsões a 12 passos.

Figura 5: Série real *versus* série obtida através do algoritmo de AEHolt.



Fonte: elaboração própria, 2024.

A Tabela 3 apresenta a comparação dos valores reais e os valores das previsões realizadas pelo AEHolt para 1, 3, 6 e 12 passos.

Tabela 3: Valores reais e valores previstos pelo algoritmo de AEHolt.

Horizonte de previsão	Período	Valores reais	Alisamento exponencial de Holt
1	Dez 2021	5,2308	6,0218
3	Out 2021 -- Dez 2021	6,9524	6,2075
		5,4492	6,1208
		5,2308	6,0341

6	Jul 2021 -- Dez 2021	5,6084	5,9851
		6,3587	5,8425
		7,9783	5,6999
		6,9524	5,5574
		5,4492	5,4148
		5,2308	5,2722
		5,2646	5,5643
12	Jan 2021 -- Dez 2021	6,5262	5,4164
		8,0308	5,2685
		7,7091	5,1206
		6,7323	4,9728
		6,0723	4,8249
		5,6084	4,6770
		6,3587	4,5291
		7,9783	4,3812
		6,9524	4,2334
		5,4492	4,0855
		5,2308	3,9376

Ao analisar os resultados do AEHolt, podemos observar que no horizonte de 1 passo à frente, o valor real foi 5,2308, enquanto a previsão foi 6,0218. Aqui, esse resultado mostra uma leve superestimação. Para o horizonte de 3 passos à frente, os valores previstos estiveram próximos dos reais, mas o algoritmo ainda, tendeu a superestimar de maneira constante. No horizonte de 6 passos à frente, os valores mostraram uma maior suavização por parte do algoritmo, com previsões relativamente próximas, mas uma subestimação no final do período. Isso sugere que o modelo está projetando um valor mais constante, enquanto a realidade dos dados mostra flutuações mais amplas. Finalmente, no horizonte de 12 passos à frente, os valores reais variam consideravelmente, enquanto as previsões do algoritmo seguem uma tendência de queda. Essa redução nas previsões está mais pronunciada do que o comportamento real dos dados, sugerindo que o algoritmo está projetando uma diminuição contínua, embora os dados reais mostrem flutuações mais significativas ao longo do ano. De maneira geral, o AEHolt é eficaz em identificar tendências gerais nos dados, mas tem a propensão de suavizar as flutuações, resultando em uma previsão que não reflete com precisão as variações observadas nos valores reais.

5.2.3 Modelo ETS

Além desses, foi utilizado o modelo Erro, Tendência e Sazonalidade (ETS), uma classe mais abrangente de modelos de suavização que inclui componentes de erro, tendência e sazonalidade, permitindo a modelagem de padrões mais complexos (Hyndman; Athanasopoulos, 2018). O modelo ETS é ajustado por máxima verossimilhança, com os

parâmetros estimados para maximizar a probabilidade de observação dos dados. O algoritmo seleciona o modelo mais adequado com base em critérios de informação, como AIC ou BIC (Akaike, 1970; Schwarz, 1978), e retorna um código de três letras que caracteriza os componentes de erro, tendência e sazonalidade da série (Hyndman; Athanasopoulos, 2018).

No caso deste estudo, o algoritmo retornou o modelo (A, Ad, A), indicando um comportamento aditivo para os componentes de erro, tendência e sazonalidade, sendo a tendência classificada como aditiva amortecida. A Figura 5 apresenta a série real e a série predita pelo modelo ETS (A, Ad, A). Essa representação permite observar a precisão do algoritmo para capturar a dinâmica da série ao longo do tempo.

Figura 6: Série real *versus* série obtida através do modelo ETS de ordem (A, Ad, A).



Fonte: elaboração própria, 2024.

Na Tabela 4 é possível comparar os valores reais e os valores das previsões do modelo ETS (A, Ad, A) para 1, 3, 6 e 12 passos.

Tabela 4: Valores reais e valores previstos pelo modelo ETS de ordem (A, Ad, A).

Horizonte de previsão	Período	Valores reais	Modelo ETS (A, Ad, A)
1	Dez 2021	5,2308	4,2372
		6,9524	7,1367
3	Out 2021 -- Dez 2021	5,4492	6,8471
		5,2308	4,5898

6	Jul 2021 -- Dez 2021	5,6084	6,0340
		6,3587	6,7551
		7,9783	5,8539
		6,9524	6,8132
		5,4492	6,5718
		5,2308	4,2854
12	Jan 2021 -- Dez 2021	5,2646	8,4306
		6,5262	6,8643
		8,0308	6,5482
		7,7091	7,3912
		6,7323	6,0347
		6,0723	6,4562
		5,6084	5,7482
		6,3587	6,4835
		7,9783	5,7072
		6,9524	6,6004
		5,4492	6,5868
		5,2308	4,1575


A análise dos resultados utilizando o modelo ETS revela que para o horizonte de 1 passo à frente, o valor real foi 5,2308, enquanto a previsão do modelo ETS foi 4,2372, indicando uma subestimação. Para o horizonte de 3 passos à frente, os valores reais variaram, tendo acontecido uma superestimação dos valores iniciais, mas uma subestimação expressiva do último valor. No horizonte de 6 passos à frente, o modelo apresentou uma previsão distante do comportamento real dos dados. Embora pareça ter captado as tendências, a subestimação no final do período indica a dificuldade em lidar com a variabilidade da série temporal. Finalmente, no horizonte de 12 passos à frente, observa-se uma discrepância nas previsões, com o modelo inicialmente superestimando os valores e depois apresentando uma subestimação ao longo do ano. A variação nos valores previstos sugere que o modelo tem dificuldades em capturar as flutuações mais amplas e em prever os picos de valores nos dados reais. De modo geral, o modelo ETS foi eficaz em identificar algumas tendências gerais, mas apresentou erros significativos, principalmente em horizontes mais longos. O modelo subestimou consistentemente os valores em muitos períodos e teve dificuldades em ajustar as flutuações.

5.3 Avaliação de desempenho

A performance dos algoritmos foi avaliada em diferentes horizontes de previsão (1, 3, 6 e 12 passos) garantindo uma análise abrangente e comparativa. A Figura 6 apresenta a evolução da série temporal original das geo-helminthíases em Alagoas, juntamente com as previsões geradas pelos modelos Autorregressivos Integrados de Médias Móveis (ARIMA) (1,1,1), Erro, Tendência e Sazonalidade (ETS) (A, Ad, A) e algoritmo de Alisamento Exponencial de Holt

(AEHolt). Observa-se que todos os modelos acompanham a tendência decrescente da série, com variações pontuais ao longo do tempo. Essa análise permite identificar o modelo mais adequado para capturar a dinâmica dos dados e aprimorar futuras previsões epidemiológicas.

Figura 7: Valores reais *versus* valores preditos pelos modelos Autorregressivos Integrados de Médias Móveis (ARIMA) (1,1,1), Erro, Tendência e Sazonalidade (ETS) (A, Ad, A) e algoritmo de Alisamento Exponencial de Holt (AEHolt) a 12 passos.



Fonte: elaboração própria, 2024.

A Tabela 5 apresenta as métricas de desempenho de três algoritmos de previsão — ARIMA (1,1,1), AEHolt e ETS (A, Ad, A) — avaliados em diferentes horizontes de previsão (1, 3, 6 e 12 passos à frente). As métricas utilizadas incluem o Erro Absoluto Médio (MAE), a Raiz do Erro Quadrático Médio (RMSE) e o Erro Percentual Absoluto Médio (MAPE). Esses indicadores avaliam, respectivamente, a precisão média, o desvio quadrático médio e a precisão percentual média das previsões realizadas por cada modelo.

Tabela 5: Medidas de acurácia para previsões geradas pelos modelos Autorregressivos Integrados de Médias Móveis (ARIMA) (1,1,1), Erro, Tendência e Sazonalidade (ETS) (A, Ad, A) e algoritmo de Alisamento Exponencial de Holt (AEHolt) em 1, 3, 6 e 12 passos

		Horizonte de previsão			
Algoritmos	Métricas de desempenho	1	3	6	12
Modelo ARIMA (1, 1, 1)	MAE	1,3597	1,1093	0,9514	0,9644

	RMSE	1,2598	1,2598	1,0639	1,1813
	MAPE	25,9956	20,4129	15,9652	13,8602
	MAE	0,7910	0,7399	0,7736	1,7917
AEHolt	RMSE	0,7910	0,7418	1,1216	2,0079
	MAPE	15,1222	12,7982	10,8134	26,3890
	MAE	0,9935	0,7410	0,8589	0,9570
Modelo ETS (A, Ad, A)	RMSE	0,9935	0,8942	1,0820	1,3176
	MAPE	18,9950	13,5191	13,5211	15,3300

O modelo ARIMA (1,1,1) apresentou resultados consistentes em termos de RMSE e MAPE, com desempenho que melhora à medida que o horizonte de previsão aumenta. Os valores de MAE reduziram de 1,3597 no horizonte de 1 passo para 0,9644 no horizonte de 12 passos, indicando uma boa adaptação em previsões de médio e longo prazo. O MAPE, por sua vez, apresentou uma redução significativa, passando de 25,99% para 13,86%, o que reforça a eficiência do modelo em horizontes maiores.

O algoritmo AEHolt demonstrou o melhor desempenho para previsões de curto prazo, com os menores valores de MAE (0,7910 e 0,7399) e MAPE (15,12% e 12,80%) nos horizontes de 1 e 3 passos, respectivamente. Contudo, o desempenho do modelo caiu em horizontes mais longos, como 12 passos, onde o MAE aumentou para 1,7917 e o MAPE para 26,39%. Esses resultados sugerem que o AEHolt é mais adequado para previsões imediatas, mas menos eficaz em lidar com tendências de longo prazo.

O modelo ETS (A, Ad, A) apresentou um desempenho intermediário em todos os horizontes analisados. Embora os valores de MAE e MAPE sejam maiores que os do AEHolt para 1 e 3 passos, o ETS manteve uma boa estabilidade ao longo do tempo, com MAE variando de 0,9935 (1 passo) a 0,9570 (12 passos). Além disso, o MAPE apresentou valores equilibrados, entre 13,52% e 15,33%, o que destaca sua consistência em horizontes maiores, mesmo sem superar o desempenho do ARIMA.

De forma geral, o AEHolt é a melhor escolha para previsões de curto prazo devido à sua alta precisão nos horizontes iniciais. Já o ARIMA (1,1,1) se destaca em previsões de médio e longo prazo, apresentando resultados robustos e consistentes. Por fim, o modelo ETS oferece uma solução equilibrada, com desempenho estável em diferentes horizontes, sendo uma opção confiável para cenários que exigem previsões consistentes ao longo do tempo.


5.4 Análise de quebras estruturais

Objetivando identificar mudanças de comportamento abruptas na série foi realizado o teste proposto por Gregory Chow (1960), que permite a observação de quebras estruturais em

uma série temporal ao longo do tempo. Esse teste procura confrontar a hipótese nula de que a série temporal não possui quebra estrutural e a hipótese alternativa de que na série há uma quebra estrutural.

Para este caso foi ajustado um modelo de regressão com a média das observações ao longo dos anos. Essa etapa foi seguida pelo cálculo dos possíveis pontos de mudança estrutural, também chamada de estatística F, e observações dos *breakpoints*. O resultado do teste indicou a rejeição da hipótese nula sob um nível de significância de 5% ($p\text{-valor} < 2,2 \times 10^{-16}$), evidenciando que na série existe quebra estrutural. As estatísticas F geradas permitem evidenciar pontos potenciais para a quebra e podem ser visualizadas na Figura 7.

Figura 8: Valores críticos da Estatística F



O gráfico apresentado permite observar que as probabilidades estiveram muito acima do valor crítico, indicando pontos de quebra estrutural e o período em que a série pode ter sofrido uma mudança significativa na média (2012-2020). Por fim foram identificados quatro *breakpoints*, as observações: 31, 52, 78 e 117. Esses momentos correspondem aos momentos: julho de 2012, abril de 2014, junho de 2016 e setembro de 2019 e permitem inferir que a série histórica apresentou mudanças abruptas em seus parâmetros nesses períodos do tempo.

6. DISCUSSÃO

Neste estudo, observou-se uma variação na prevalência de geo-helmintíases ao longo do tempo, com uma tendência de redução gradual nas taxas ao longo dos anos. A ausência de estacionariedade na série temporal indica que a prevalência dessas infecções em Alagoas segue padrões de aleatoriedade, sem apresentar propriedades como média e variância constantes ao longo do período analisado. Esse comportamento reforça a hipótese de que ações de controle realizadas ao longo da década, como intervenções em saneamento básico e programas educativos, podem ter contribuído para a diminuição gradual das infecções por geo-helminthos no estado de Alagoas (Strunz *et al.*, 2014).

Os picos de altas prevalências, registrados ao longo do tempo desempenharam um papel crítico na elevação da média geral da série. Esses valores atípicos podem estar associados a eventos sazonais específicos, como períodos de chuva intensa, que favorecem a sobrevivência e transmissão de geo-helminthos (Amaral Neto *et al.*, 2021). No entanto, a ausência de sazonalidade bem definida na série sugere que os padrões de prevalência podem estar mais relacionados a fatores estruturais, como condições de saneamento básico e desigualdades regionais. A estabilização das taxas em níveis mais baixos nos últimos anos reflete avanços significativos nas estratégias de controle e monitoramento, indicando a eficácia de ações como melhorias em infraestrutura sanitária e educação em saúde pública.

A análise dos quartis revelou uma distribuição assimétrica das taxas de prevalência, com 25% das observações abaixo de 7,96% e 75% dos valores concentrados abaixo de 16,87%. Essa disparidade sugere a existência de subgrupos populacionais ou regiões específicas dentro do estado que apresentam maior vulnerabilidade às infecções. A combinação de altas prevalências em algumas áreas e baixas prevalências em outras pode estar relacionada a desigualdades regionais em infraestrutura de saneamento e condições socioeconômicas (Gazzinelli *et al.*, 2014).

Apesar da tendência geral de queda observada em estudos nacionais, como o último Inquérito Brasileiro de Geo-Helminthíases (Katz, 2018), a região Nordeste continua a apresentar taxas consideráveis de prevalência para helmintíases transmitidas pelo solo. Essa persistência está diretamente relacionada a fatores estruturais, como os baixos índices de saneamento básico e os elevados números de internações hospitalares associadas à contaminação da água e do solo. A ausência de tratamento adequado de água e esgoto está fortemente correlacionada com a alta prevalência de ascaridíase, ancilostomíase e tricuriase na região (Calandro; Arbex, 2022).

Os elevados índices de parasitismo refletem as desigualdades sociais da região, fortemente associadas a baixos indicadores de desenvolvimento humano, incluindo renda e escolaridade reduzidas, além de condições precárias de vida. Essas condições expõem a população a riscos contínuos, ressaltando a necessidade urgente de políticas públicas que vão além da expansão da infraestrutura urbana. São fundamentais iniciativas que promovam melhorias nas áreas de educação e saúde, especialmente entre populações mais vulneráveis (Gomes *et al.*, 2025). Além disso, fatores comportamentais, como andar descalço, e ambientais, como altos índices pluviométricos, também influenciam significativamente a prevalência dessas infecções (Mesquita *et al.*, 2021).

Neste estudo, não foram identificados padrões sazonais na ocorrência de geohelmintíases em Alagoas. A ausência de sazonalidade sugere que essas infecções não seguem ciclos regulares, como os relacionados a estações do ano ou meses específicos. Esse achado contradiz pesquisas anteriores que associaram a infecção por *Ascaris lumbricoides* a períodos de maior precipitação (Amaral Neto *et al.*, 2021). No entanto, algumas pesquisas apontam uma maior concentração de infecções em regiões do estado com índices pluviométricos elevados, como o Litoral, a Zona da Mata e o Baixo São Francisco, que possuem clima quente e úmido, condições favoráveis para a sobrevivência e transmissão de helmintos (Silva *et al.*, 2023).

De acordo com a Embrapa, o estado de Alagoas apresenta irregularidades na precipitação pluviométrica, com pouca variação sazonal na radiação solar, fotoperíodo e temperatura do ar (Embrapa, 2012). A proximidade com a linha do Equador resulta em um número elevado de horas de incidência solar por ano e índices acentuados de evapotranspiração, contribuindo para uma precipitação média anual entre 1.200 e 1.800 milímetros, dependendo da região. Geralmente, os meses mais chuvosos ocorrem entre abril e julho, enquanto os meses de menor precipitação situam-se entre setembro e dezembro. Por exemplo, em Maceió, a precipitação média anual é de 1.304 mm, com os meses mais secos sendo novembro e dezembro (Climate Data, 2025).

No entanto, estudos específicos sobre a sazonalidade das geo-helmintíases em Alagoas não identificaram padrões sazonais claros na ocorrência dessas infecções, sugerindo que elas não seguem ciclos regulares relacionados às estações do ano ou meses específicos. Fatores como condições socioeconômicas, saneamento básico e hábitos de higiene pessoal desempenham um papel mais significativo na prevalência dessas infecções (Moreira *et al.*, 2021). Portanto, embora seja relevante compreender os padrões climáticos de Alagoas, as

evidências atuais indicam que a ocorrência de geo-helmintíases no estado está mais associada a fatores socioeconômicos e de infraestrutura do que a variações sazonais de precipitação.

Outros fatores, como densidade populacional e superlotação, são particularmente relevantes nas regiões do Agreste e do Litoral alagoano, onde estão localizadas as cidades mais populosas, como Maceió e Arapiraca. Esses fatores contribuem significativamente para o aumento da transmissão de helmintos (Silva *et al.*, 2023). Um estudo (Ferreira *et al.*, 2002) realizado na capital Maceió com crianças em idade escolar revelaram alta prevalência de helmintos, reforçando o impacto das desigualdades sociais e econômicas. Noutra pesquisa (Silva *et al.*, 2023), 47,4% das crianças analisadas apresentavam infecção por *Ascaris lumbricoides*, 21,2% por *Trichuris trichiura* e 10% por ancilostomídeos. Enquanto uma outra pesquisa (Silva *et al.*, 2016) registrou prevalências de 51,5% para *Trichuris trichiura*, 46,6% para *Ascaris lumbricoides* e 22,1% para ancilostomídeos em uma amostra de 367 crianças.

Diante desses achados, é evidente que as helmintíases estão diretamente associadas a indicadores sociais e econômicos desfavoráveis, configurando-se como um desafio persistente para a saúde pública na região. Essas infecções afetam significativamente a qualidade de vida da população, evidenciando a necessidade de desenvolver e implementar estratégias que visem não apenas a erradicação dessas doenças, mas também a ampliação de condições dignas para as comunidades afetadas (Ferreira *et al.*, 2023).

Pesquisas (Gunawardena; Karunaweera; Ismail, 2004; Perera *et al.*, 2012; Ramos Neto *et al.*, 2023) sugerem que a prevalência de helmintíases transmitidas pelo solo pode ser determinada por fatores de clima, vegetação, saneamento e hábitos de vida. Esses autores também expõem que somente 30,7% dos indivíduos parasitados com *Ascaris* têm acesso a sanitários, e desses, a grande maioria (96,6%) compartilha moradias de um cômodo. Além disso, esses autores também retratam um baixo nível de conhecimento entre os indivíduos, o que justifica contextos de reinfecção mesmo com a adoção de medidas de controle. Esses fatores evidenciam cenários de precariedade sanitária e o aumento do risco de propagação de infecções intestinais, especialmente em comunidades mais carentes (Jayakody *et al.*, 2024).

A prevalência de parasitas intestinais está diretamente relacionada ao desenvolvimento socioeconômico de uma população. A alta desse indicador em países de clima tropical e subtropical fortalece a hipótese de que os fatores ambientais influenciam fortemente a propagação de parasitas, mas para além disso, evidencia a vulnerabilidade desses territórios, muitas vezes negligenciados socialmente e com baixos investimentos em pesquisas, saúde e educação (Ramos Neto *et al.*, 2023).

Apesar de ser comum a regiões subdesenvolvidas, um estudo ecológico realizado no Reino Unido entre 1999 e 2019 evidenciou um aumento de 412,9% em internações hospitalares por doenças infecciosas e parasitárias, sendo 33,6% dessas, por infecção intestinal. Nesse mesmo estudo foi demonstrado que a maior parte das internações gerais aconteceu em pacientes com menos de 15 anos de idade e que 53,7% desses episódios estiveram relacionados a alguma parasitose intestinal (Sweiss *et al.*, 2022). Essa pesquisa traz à tona o estigma que cerca a ocorrência destas doenças e expõe a necessidade de políticas de monitoramento eficazes, mesmo em territórios considerados desenvolvidos.

A ascaridíase, tricuriase e ancilostomíase comumente se apresentam em quadros de poliparasitismo. As coinfeções são possíveis graças às características que esses organismos têm entre si, o que os fazem compartilhar desde dinâmicas de transmissibilidade e ciclo biológico, até as formas de diagnóstico e tratamento (Karshima, 2018). Outra conexão mais atual entre essas infecções é a deficiência de ferro. A anemia ferropriva relacionada às parasitoses intestinais é comumente associada à ancilostomíase. Entretanto, pesquisas (Amare; Lindtjorn, 2021; Aderoba *et al.*, 2015; Mengist *et al.*, 2017; Boltana *et al.*, 2021) referiram associação entre infecções por *Ascaris lumbricoides* e anemia ferropriva em mulheres grávidas e imigrantes em países como a Nigéria, Etiópia e Tailândia. De todo modo, a associação da anemia como consequência à infecção parece variar de acordo com o país, a exemplo de uma pesquisa realizada na Indonésia, que relatou um risco diminuído de anemia em crianças infectadas com alguma geo-helminíase (Djuardi *et al.*, 2021).

Além disso, algumas características epidemiológicas podem ser comuns às espécies de helmintos, como nos casos em que os indivíduos vivem em aglomerados domiciliares, achado importante em uma amostra de venezuelanos que trouxe à tona a existência de associação entre o agrupamento domiciliar e a coinfeção com ascaridíase e tricuriase em comunidades rurais (Incani; Grillet; Mughini-Gras, 2021).

Nos últimos anos, tem sido cada vez mais evidente a busca por associações entre a prevalência de helmintos e as variações climáticas. Atualmente, é sabido que esses organismos respondem de maneira distinta aos diferentes ecossistemas, sendo as características de temperatura e pluviometria cruciais para o seu desenvolvimento. Esses efeitos podem interferir de modo direto ou indireto na sobrevivência desses organismos, aumentando o tamanho de seus habitats em casos de alta precipitação, ou ainda, acelerando o desenvolvimento embrionário em casos de aumento de temperatura. Tais fatores impactam as dinâmicas de propagação já

conhecidas, provocando alterações nos padrões sazonais de transmissibilidade, e consequentemente, ampliando sua capacidade de distribuição espacial (Maicher; Bailly, 2024).

Os resultados obtidos nesta pesquisa evidenciam a relevância da análise de séries temporais na compreensão da dinâmica das geo-helminthíases em Alagoas. A avaliação da prevalência dessas infecções ao longo dos anos permitiu identificar tendências que podem subsidiar políticas públicas mais eficazes de controle e prevenção. O uso de séries históricas para realizar previsões demonstrou-se uma ferramenta útil para antecipar surtos e direcionar ações preventivas. A modelagem estatística aplicada sugere que apesar da diminuição dos casos, sem intervenções significativas, a prevalência das geo-helminthíases pode permanecer elevada em determinadas regiões, sobretudo em comunidades rurais e periféricas. Esse achado reforça a necessidade de investimentos contínuos em infraestrutura sanitária e educação em saúde.

Adicionalmente, a análise de quebra estrutural revelou mudanças significativas na tendência da série histórica das geo-helminthíases em Alagoas. O gráfico gerado permitiu observar que as probabilidades permaneceram muito acima do valor crítico, indicando pontos de ruptura na média da série. Foram identificados quatro breakpoints nos períodos de julho de 2012, abril de 2014, junho de 2016 e setembro de 2019. Ao cruzarmos essa informação com os padrões climáticos do estado, observamos que alguns desses momentos coincidem com períodos de maior índice pluviométrico, em que a maior concentração de chuva geralmente ocorre entre abril e julho, enquanto os meses mais secos predominam entre setembro e dezembro (Climate Data, 2025). Dessa forma, dois dos breakpoints identificados (julho de 2012 e abril de 2014) estão situados dentro da estação chuvosa, enquanto junho de 2016 e setembro de 2019 estão em momentos de transição ou de estiagem. A ausência de um padrão sazonal claro nos breakpoints pode ser justificada por fatores externos que influenciam a ocorrência das geo-helminthíases além das variações climáticas.

A identificação dessas quebras estruturais permite compreender melhor os períodos de maior instabilidade na prevalência das infecções, auxiliando no planejamento de intervenções mais eficazes. Esses achados reforçam a necessidade de um monitoramento contínuo e da incorporação de técnicas avançadas de modelagem para prever e mitigar o impacto das geo-helminthíases ao longo do tempo.

Além disso, ao comparar os dados de Alagoas com outras regiões do Brasil, percebe-se que a dinâmica das infecções pode variar conforme as condições climáticas e socioeconômicas locais (Katz, 2028). Estudos semelhantes (Katz, 2018; Albuquerque, 2019) realizados em estados do Nordeste apontam para desafios comuns, como baixa cobertura de esgotamento

sanitário e acesso limitado a serviços de saúde preventiva. Dessa forma, os achados desta pesquisa reforçam a importância do monitoramento epidemiológico contínuo e da utilização de ferramentas preditivas para orientar a tomada de decisão em saúde pública. Estratégias integradas, incluindo intervenções ambientais e campanhas de educação sanitária, são fundamentais para reduzir a carga das geo-helminthiases e melhorar os indicadores de saúde em Alagoas, e demais localidades que sofrem com essa endemicidade.

As geo-helminthiases são prevalentes em regiões com saneamento básico inadequado, hábitos de higiene deficientes e baixa renda. Em Alagoas, estudos realizados entre 2019 e 2021, no município de Maceió, mostraram uma alta prevalência de amostras positivas para essas infecções, com destaque para ancilostomídeos. Foram identificadas 1.037 amostras positivas em 2019, 429 em 2020 e 741 em 2021 (Sarmiento et al., 2024).

O Programa de Controle da Esquistossomose (PCE) foi implementado no Brasil em 1976 pelo Ministério da Saúde, com o objetivo de guiar os municípios no controle de doenças, como geo-helminthiases e esquistossomose, concentrando suas ações no diagnóstico e tratamento de infectados em áreas endêmicas (Brito; Silva; Quinino, 2020). A partir de 2010, o PCE intensificou suas ações, buscando aprimorar a vigilância epidemiológica e a integração com a atenção básica de saúde. Estudos realizados em municípios da Zona da Mata de Pernambuco, por exemplo, avaliaram a implantação das ações do PCE e identificaram deficiências na gestão e na execução de ações de educação em saúde, embora tenha sido constatado um envolvimento relevante da atenção básica nas ações do programa (Costa et al., 2017).

Atualmente, não há informações específicas que indiquem um aumento significativo no financiamento do PCE a partir de 2010. Contudo, a continuidade das ações de controle e a busca por melhorias nas intervenções foram evidentes, com esforços direcionados para a redução da prevalência da esquistossomose e geo-helminthiases. Estudo aponta que, embora as infecções geo-helminthicas ainda sejam prevalentes no país, houve uma ligeira queda nos últimos cinco anos, com *Ascaris lumbricoides* sendo o geo-helmintho mais prevalente (Moreira et al., 2021).

Além disso, cabe a reflexão acerca do impacto da pandemia de COVID-19, que afetou diversas áreas da saúde pública, incluindo os programas de controle de doenças tropicais. No estado de Alagoas, um estudo avaliou o impacto da pandemia no diagnóstico de helmintos e observou uma redução significativa no número de exames realizados durante os dois primeiros anos da pandemia. Essa diminuição pode estar associada às medidas de distanciamento social

e à priorização de recursos para o enfrentamento da COVID-19, o que possivelmente levou a uma subnotificação de casos de geo-helminthiases (Silva et al., 2023).

A redução dos casos ao longo do tempo pode ser atribuída a melhorias nas condições socioeconômicas, investimentos em saneamento básico e educação em saúde. Entretanto, a pandemia de COVID-19 representou um desafio adicional, possivelmente afetando a continuidade das ações de controle e levando à subnotificação de casos. É essencial que os programas de controle de geo-helminthiases sejam fortalecidos, garantindo a retomada e a intensificação das ações de vigilância, diagnóstico e tratamento, especialmente em áreas endêmicas como Alagoas.

7. CONSIDERAÇÕES FINAIS

O presente estudo demonstrou que a modelagem preditiva baseada em séries temporais é uma ferramenta valiosa para o monitoramento e controle das geo-helminthiases no estado de Alagoas. A análise da evolução da prevalência dessas infecções entre 2010 e 2021 revelou uma redução significativa, reflexo possível de esforços estruturais em saneamento, educação em saúde e medidas de controle parasitário. No entanto, a persistência de taxas ainda expressivas em determinados territórios sugere que desafios importantes permanecem e requerem intervenções estratégicas.

A utilização combinada dos modelos ARIMA (1,1,1), ETS (A, Ad, A) e algoritmo AEHolt permitiu uma abordagem comparativa robusta, destacando as potencialidades e limitações de cada técnica. Os resultados evidenciaram a eficiência do AEHolt para previsões de curto prazo, tornando-o uma opção viável para resposta rápida em gestão de saúde. Por outro lado, a confiabilidade do modelo ARIMA em horizontes mais longos reforça sua aplicação no planejamento de políticas de saúde pública a médio e longo prazo. O desempenho intermediário do modelo ETS sugere sua aplicabilidade em cenários de tendências suavizadas, garantindo estabilidade nas previsões.

Os achados deste estudo ressaltam a importância de estratégias baseadas em dados para a tomada de decisão em saúde pública. A capacidade de prever a dinâmica das geo-helminthiases possibilita intervenções direcionadas, otimizando recursos e maximizando impactos. Ademais, os resultados reforçam a necessidade de investimentos sustentáveis em infraestrutura sanitária, distribuídos de forma equitativa, a fim de mitigar disparidades regionais e interromper o ciclo de transmissão dessas infecções.

Em um contexto mais amplo, este trabalho contribui para a literatura científica ao demonstrar a aplicabilidade de modelos estatísticos e algoritmos preditivos em um tema de relevância epidemiológica e social. Os métodos aqui empregados podem ser replicados em outras regiões e contextos, promovendo uma gestão de saúde baseada em evidências. Para estudos futuros, recomenda-se a incorporação de variáveis socioeconômicas e ambientais, ampliando a compreensão dos fatores determinantes da dinâmica das geo-helminthiases.

Por fim, os resultados apresentados são um chamado à ação: para que avanços na prevenção e controle das geo-helminthiases sejam sustentáveis, é imperativo o fortalecimento de políticas intersetoriais que integrem saúde e infraestrutura básica. O combate às doenças negligenciadas exige um compromisso contínuo, pautado em inovação, equidade e justiça social.

8. REFERÊNCIAS

- ADEROBA, A. K.; IRIBHOGBE, O. I.; OLAGBUJI, B. N.; OLOKOR, O. E.; OJIDE, C. K.; ANDE, A. B. Prevalence of helminth infestation during pregnancy and its association with maternal anemia and low birth weight. **International Journal of Gynaecology & Obstetrics**, v. 129, n. 3, p. 199-202, 2015. DOI: [10.1016/j.ijgo.2014.12.002](https://doi.org/10.1016/j.ijgo.2014.12.002).
- AKAIKE, H. Statistical predictor identification. **Annals of the institute of Statistical Mathematics**, v. 22, n. 1, p. 203-217, 1970.
- ALBUQUERQUE, M. E. **Inquérito coproparasitológico e ações de educação em saúde em escolas da rede pública de três municípios de Pernambuco**. Trabalho de Conclusão de Curso apresentado ao curso de Bacharelado em Ciências Biológicas, da Universidade Federal Rural de Pernambuco – UFRPE. Recife. 2019.
- ALMEIDA, V. V. et al. Geo-helminthiasis: cenário atual, agentes etiológicos, diagnósticos, tratamento e prevenção. **Cuadernos de Educación y Desarrollo**, v. 15, n. 5, 2023.
- AL AMIM, A. S. M.; WADHWA, R. **Helminthiasis**. StatPearls [Internet]. 2023. Disponível em: < <https://www.ncbi.nlm.nih.gov/books/NBK560525/>>. Acesso em: junho de 2024.
- AMARAL NETO, L. F. G. et al. Estudo retrospectivo das helmintoses diagnosticadas em ruminantes baseado em pesquisas realizadas no estado do Maranhão nos últimos 20 anos. **Brazilian Journal of Development**, v. 7, n. 6, p. 56557-56571, 2021. DOI: 10.34117/bjdv7n6-186.
- AMARE, H. H.; LINDTJORN, B. Concurrent anemia and stunting among schoolchildren in Wonago District in southern Ethiopia: a cross-sectional multilevel analysis. **PeerJ**, v. 9, e11158, 2021. DOI: <https://peerj.com/articles/11158/>
- ARRUDA, L. P. S. **Pernambuco: agravos à saúde relacionados a falta de saneamento**. Monografia apresentada ao Curso de Saúde Coletiva da Universidade Federal de Pernambuco – UFPE. Vitória de Santo Antão. 2019.
- BASSETO, P. **Análise comparativa de modelos lineares para previsão do preço do açúcar**. Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção, da Universidade Tecnológica Federal do Paraná - UTFPR. Ponta Grossa. 2022.
- BETHONY, J. *et al.* Soil-transmitted helminth infections: ascariasis, trichuriasis, and hookworm. **The Lancet**, v. 367, p. 1521-1532, 2006.
- BOLTENA, M. T. et al. Comorbidity of geo-helminthes among malaria outpatients of the health facilities in Ethiopia: systematic review and meta-analysis. **International Journal of Environmental Research and Public Health**, v. 18, n. 3, p. 862, 2021. DOI: [10.3390/ijerph18030862](https://doi.org/10.3390/ijerph18030862)
- BOX, G.E.P.; JENKINS, G. M.; REINSEL, G. C. **Time series analysis: forecasting and control**. 4 ed. John Wiley e Sons, 2008.

BOX, G. E. P. et al. **Time Series Analysis: Forecasting and Control**. John Wiley & Sons, Hoboken, 2015.

BOX, G. E. P.; TIAO, G. C. Intervention analysis with applications to economic and environmental problems. **Journal of the American Statistical Association**, v. 70, p. 70-79, 1975.

BRITO, M. I. B. S.; SILVA, M. B. A.; QUININO, L. R. M. Situação epidemiológica e controle da esquistossomose em Pernambuco: estudo descritivo, 2010-2016. **Epidemiol. Serv. Saúde**, v. 29, n. 2, 2020.

BRITO, S. P. S. et al. Hospitalizações por doenças tropicais negligenciadas no Piauí, Nordeste do Brasil: custos, tendências temporais e padrões espaciais, 2001-2018. **Cadernos de Saúde Pública**, v. 38, n. 8, 2022.

BRITO, S. P. S. et al. Mortalidade por doenças tropicais negligenciadas no Piauí, Nordeste do Brasil: tendência temporal e padrões espaciais, 2001-2018. **Epidemiologia e Serviços de Saúde**, v. 31, n. 1, 2022.

BROCKWELL, P. J.; DAVIS, R. A. **Introduction to time series and forecasting**. Springer New York, 2010.

BROWN, R. G. **Smoothing, Forecasting and Prediction of Discrete Time Series**. Prentice-Hall, 1963.

CALANDRO, H. E.; ARBEX, A. P. O. Frequência de geo-helminthos em regiões brasileiras com a falta de saneamento básico. **Revista Conexão Saúde FIB**, v. 5, p. 23-36, 2022.

CHAI, J.; JUNG, B.; HONG, S. Albendazole and Mebendazole as Anti-Parasitic and Anti-Cancer Agents: an Update. *Korean Journal Parasitology*, v. 59, n. 3, p. 189-225, 2021. DOI: 10.3347/kjp.2021.59.3.189

CHAI, T. DRAXLER, R. R. Root Mean Square Error (RMSE) or Mean Absolute Error (MAE)? - Arguments against Avoiding RMSE in the Literature. **Geoscientific Model Development**, v. 7, p. 1247-1250. DOI: 10.5194/gmd-7-1247-2014

CHAMMARTIN, F. et al. Soil-transmitted helminth infection in South America: A systematic review and geostatistical meta-analysis. **Lancet**, v. 13, n. 6, p. 507-18, 2013.

CHATFIELD, C. **The Analysis of Time Series: An Introduction**. 5 ed. Londres: Chapman and Hall CRC, 1996.

CHATFIELD, C. **The analysis of time series: an introduction**. 6th ed. Boca Raton: Chapman and Hall/CRC, 2004.

CHOW, G. C. Tests of equality between sets of coefficients in two linear regressions. **Econometrica**, v. 28, n. 3, p. 591-605, 1960.

CLAUS, P. E. *et al.* Ascaris lumbricoides: challenges in diagnosis, treatment and prevention strategies in a European refugee camp. **Acta Clinica Belgica**, v. 73, n. 6, p. 431-434, 2018.

CLIMATE-DATA. **Clima**: Maceió (Alagoas), Brasil. Disponível em: <https://pt.climate-data.org/america-do-sul/brasil/alagoas/maceio-2193/>. Acesso em: 5 mar. 2025.

COSTA, C. S. et al. Programa de Controle da Esquistossomose: avaliação da implantação em três municípios da Zona da Mata de Pernambuco, Brasil. **Saúde em debate**, v. 41, 2017.

DE MATTOS, R. S. **Tendências e Raízes Unitárias**. Texto Didático. UFJF: Juiz de Fora, 2018.

DJUARDI, Y.; LAZARUS, G.; STEFANIE, D.; FAHMIDA, U.; ARIAWAN, I.; SUPALI, T. Soil-transmitted helminth infection, anemia, and malnutrition among preschool-age children in Nangapanda subdistrict, Indonesia. **PLOS Neglected Tropical Diseases**, v. 15, n. 6, p. e0009506, 2021. DOI: [10.1371/journal.pntd.0009506](https://doi.org/10.1371/journal.pntd.0009506).

DOYLE, S. R. et al. Population genomics of ancient and modern *Trichuris trichiura*. **Nature Communications**, v. 13, n. 3888, 2022.

ELLWANGER, J. H. et al. Iron deficiency and soil-transmitted helminth infection: classic and neglected connections. **Parasitology Research**, v. 121, p. 3381-3392, 2022).

ELSE, K. J. et al. Whipworm and roundworm infections. **Nature Reviews Disease Primers**, v. 6, n. 1, p. 44, 2020. DOI: [10.1038/s41572-020-0171-3](https://doi.org/10.1038/s41572-020-0171-3).

EMBRAPA. **Climatologia do Estado de Alagoas**. Disponível em: https://www.embrapa.br/busca-de-publicacoes/-/publicacao/950797/climatologia-do-estado-de-alagoas?utm_source=chatgpt.com. Acesso em: 5 mar. 2025.

FERREIRA, H.S. *et al.* Saúde de populações marginalizadas: desnutrição, anemia e enteroparasitoses em crianças de uma favela do “Movimento dos Sem Teto”, Maceió, Alagoas. *Rev. bras. Saúde matern. Infant.*, v. 2, n. 2, p.177-185, 2002.

FERREIRA, W. S. et al. **Uma revisão integrativa sobre a prevalência das parasitoses intestinais causadas por helmintos na região nordeste do Brasil**. In: Estudos em Zoologia: aspectos gerais, p. 50-59. Wissen Editora. 2023.

FRIEDMAN, M. The Use of Ranks to Avoid the Assumption of Normality Implicit in the Analysis of Variance. **Journal of the American Statistical Association**, v. 32, n. 200, p. 675–701, 1937.

GARDNER, E. S. Exponential smoothing: The state of the art. **Journal of Forecasting**, v. 4, n. 1, p. 1-28, 1985.

GAZZINELLI, A.; et al. A research agenda for helminth diseases of humans: social ecology, environmental determinants, and health systems. **PLOS Neglected Tropical Diseases**, v. 6, n. 4, e1603, 2014. DOI: [10.1371/journal.pntd.0001603](https://doi.org/10.1371/journal.pntd.0001603)

GITORE, W. A. et al. Prevalence of soil-transmitted helminthes and its association with water, sanitation, hygiene among schoolchildren and barriers for schools level prevention in technology villages of Hawassa University: Mixed design. **PLOS One**, v. 15, n. 9, 2020.

GOMES, D. C. S. et al. A ocorrência de enteroparasitos em escolares na Região Nordeste: uma revisão integrativa. **Diversitas Journal**, v. 5, n. 1, p. 34-43, 2020.

GUNAWARDENA, G. S.; KARUNaweera, N. D.; ISMAIL, M. M. Socio-economic and behavioural factors affecting the prevalence of Ascaris infection in a low-country tea plantation in Sri Lanka. **Annals of Tropical Medicine and Parasitology**, v. 98, n. 6, p. 615-621, set. 2004. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/15324467/>. Acesso em: janeiro de 2025.

HANN, T. H.; STEURER, E. Much ado about nothing? Exchange rate forecasting: neural. **Neurocomputing**, v. 10, p. 323–339, 1996.

HAYKIN, S. **Neural networks and learning machines**. 3rd ed. Upper Saddle River: Pearson Education, 2009.

HYNDMAN, R. J. et al. **Forecasting with exponential smoothing: the state space approach**. [S.l.]: Springer Science & Business Media, 2008.

HYNDMAN, R. J.; KHANDAKAR, Y. Automatic time series forecasting: The forecast package for R. **Journal of Statistical Software**, 2008.

HYNDMAN, R. J. KOEHLER, A. B. Another Look at Measures of Forecast Accuracy. **International Journal of Forecasting**, v. 22, p. 679-688, 2006.
DOI: 10.1016/j.ijforecast.2006.03.001

HYNDMAN, R.J.; ATHANASOPOULOS, G. **Forecasting: principles and practice**. 2 ed, OTexts: Melbourne, Australia. 2018.

HYNDMAN, R. J.; AKRAM, M.; ARCHIBALD, B. The admissible parameter space for exponential smoothing models. **Annals of Statistical Mathematics**, v. 60, n. 2, p. 407–426, 2008.

HOLT, C. C. Forecasting seasonals and trends by exponentially weighted moving averages. **Carnegie Institute of Technology**, ONR Memorandum, 52. 1957.

HOLT, C. C. Forecasting seasonals and trends by exponentially weighted moving averages. **International Journal of Forecasting**, v. 20, n. 3, p. 347-357, 2004.

HOTEZ, P. J. et al. Global progress in addressing neglected tropical diseases through preventive chemotherapy: a quantitative assessment using population-based indicators. **The Lancet Global Health**, v. 8, n. 9, p. e1162-e1169, 2020. DOI: 10.1016/S2214-109X(20)30308-2.

HOOGERWERF, M. et al. A Randomized Controlled Trial to Investigate Safety and Variability of Egg Excretion After Repeated Controlled Human Hookworm Infection. **The Journal of Infectious Diseases**, v. 223, n. 5, p. 905-913, 2021.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Censo demográfico**. 2022. Disponível em: <<https://censo2022.ibge.gov.br/panorama/>>.

INCANI, R. N.; GRILLET, M. E.; MUGHINI-GRAS, L. Hotspots and correlates of soil-transmitted helminth infections in a Venezuelan rural community: Which are the “wormy” houses? *Journal of Infection*, v. 82, p. 143–149, 2021.

ISHIZAKI, Y. et al. *Trichuris trichiura* Incidentally Detected by Colonoscopy and Identified by a Genetic Analysis. **Internal Medicine**, v. 61, n. 6, p. 821–825, 2021.
DOI: [10.2169/internalmedicine.8012-21](https://doi.org/10.2169/internalmedicine.8012-21)

JAYAKODY, N. K. et al. Human intestinal nematode infections in Sri Lanka: A scoping review. **PLOS Neglected Tropical Diseases**, 2024. DOI: 10.1371/journal.pntd.0012689

KAJERO, O. T. et al. Co-infection of intestinal helminths in humans and animals in the Philippines. **Trans R Soc Trop Med Hyg**, v. 116, p. 727–735, 2022. DOI: [10.1093/trstmh/trac002](https://doi.org/10.1093/trstmh/trac002)

KARSHIMA, S. N. Prevalence and distribution of soil-transmitted helminth infections in Nigerian children: a systematic review and meta-analysis. **Infectious Diseases of Poverty**, v. 7, n. 69, 2018.

KATZ, N. **Inquérito Nacional de Prevalência da Esquistossomose mansoni e Geohelmintos**. Fiocruz. Belo Horizonte. 2018.

KWIATKOWSKI, D.; PHILLIPS, P. C. B.; SHIN, Y. Testing the Null Hypothesis of Stationarity against the Alternative of a Unit Root. **Journal of Econometrics**, v. 54, p. 159–178, 1992.

TEIXEIRA, F. J. M. et al. Perfil epidemiológico das parasitoses em escolares no distrito administrativo do Guamá, Belém-Pará. **Research, Society and Development**, v. 11, n.16, 2022.

LAZZERI, F. **Machine learning for time series forecasting with Python**. John Wiley e Sons, 2020.

LJUNG, G. M.; BOX, G. E. P. On a measure of lack of fit in time series models. **Biometrika**, v. 65, p. 297–303, 1978.

LOUKAS, A.; MAIZELS, R. M.; HOTEZ, P. J. The yin and yang of human soil-transmitted helminth infections. **Internacional Journal Parasitology**, v. 51, n. 13, p. 1243-1253, 2021. DOI: 10.1016/j.ijpara.2021.11.001.

MAICHER, C.; BAILLY, M. L. The impact of climate change upon intestinal parasites in central Europe during the 4th millennium BCE. **Quaternary Science Reviews** v. 338, 2024.

MAKRIDAKIS, S.; WHEELWRIGTH, S. C.; HYNDMAN, R. J. (1998) *Forecasting: Methods and Applications*. John Wiley & Sons, New York. 1998.

MARQUES, M. G. **Análise da Evolução da COVID-19 com Recurso aos Modelos ARIMA**. Dissertação apresentada a Faculdade de Ciências e Tecnologia – FCT. Lisboa. 2021.

MENGIST, H. M.; ZEWDIE, O.; BELEW, A. Intestinal helminthic infection and anemia among pregnant women attending ante-natal care (ANC) in East Wollega, Oromia. **BMC Research Notes**, v. 10, n. 1, p. 440, 2017. DOI: [10.1186/s13104-017-2770-y](https://doi.org/10.1186/s13104-017-2770-y)

METCALFE, A. V.; COWPERTWAIT, P. S. **Introductory time series with R**. [S.l.]: Springer, 2009.

MBANGA, C. M. *et al.* Small Bowel Obstruction Complicating an *Ascaris lumbricoides* Infestation in a 4-Year-Old Male: A Case Report. **Journal of Medical Case Reports**, v. 13, n. 155, 2019. DOI: [10.1186/s13256-019-2103-y](https://doi.org/10.1186/s13256-019-2103-y)

MESQUITA, C. A. M. *et al.* Prevalência de infecções por geo-helminhos em comunidades brasileiras: uma revisão sistemática. **Spei Domus**, v. 17, n. 2, 2021.

MEURER, I. R.; COIMBRA, E. S. Doenças tropicais negligenciadas e o seu contexto no Brasil. **HU Revista**, v. 48, p. 1-2, 2022. DOI: [10.34019/1982-8047.2022.v48.37905](https://doi.org/10.34019/1982-8047.2022.v48.37905)

MIKHAIL, E.; ACKERMAN, F. **Observations and Least Squares**. University Press of America, 1976.

MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. **Introduction to time series analysis and forecasting**. 2nd ed. Hoboken: John Wiley & Sons, 2015.

MOREIRA, M. A. *et al.* Cenário da prevalência e condições socioambientais associadas às geo-helmintíases no Brasil: Uma revisão integrativa da literatura. **Research, Society and Development**, v. 10, n.5, 2021.

MORETTIN, P. A.; TOLOI, C. **Análise de séries temporais**. 2. ed. Blucher, 2006.

OLIVEIRA, S. A. B. M. *et al.* Doenças parasitárias helmínticas e suas relações zoonóticas com os seres humanos durante o Quaternário: uma revisão. **Pesquisa e Ensino em Ciências Exatas e da Natureza**, v. 7, p. 153-176, 2023. Disponível em: <https://dialnet.unirioja.es/descarga/articulo/9000371.pdf>.

OLLECH, D. **seastests**: Seasonality Tests. Versão 0.15.4. CRAN, 2021. Disponível em: <https://CRAN.R-project.org/package=seastests>. Acesso em: agosto de 2024.

OPAS. **Enfermedades tropicales desatendidas**: OPS pide poner fin a su postergación en las Américas. 2023. Disponível em: <<https://www.paho.org/pt/noticias/28-1-2022-doencas-tropicais-negligenciadas-opas-pede-fim-dos-atrasos-no-tratamento-nas>>. Acesso em: junho de 2024.

OPAS. **Geohelmintiasis**. 2024. Disponível em: <<https://www.paho.org/es/temas/geohelmintiasis>>. Acesso em: junho de 2024.

OPAS. **Doenças tropicais negligenciadas**: enfrentando o desafio global. Brasília: OPAS, 2023. Disponível em: <https://www.paho.org/pt/temas/doencas-tropicais-negligenciadas>. Acesso em: 3 mar. 2025.

PELLON, A. B.; TEIXEIRA, I. **Distribuição Geográfica da Esquistossomose Mansônica no Brasil**. Rio de Janeiro: Divisão da Organização Sanitária, 1950.

PEREIRA, M. G. **Artigos científicos: como redigir, publicar e avaliar**. Rio de Janeiro: Guanabara Koogan; 2017.

PERERA, P. J. et al. Knowledge and practices related to helminth infections among mothers living in a suburban area of Sri Lanka. **Southeast Asian Journal of Tropical Medicine and Public Health**, v. 43, n. 6, p. 1326-1332, nov. 2012. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/23413694/>. Acesso em: janeiro de 2025.

RAMOS NETO, A. F. et al. Why Are We Still a Worm World in the 2020s? An Overview of Risk Factors and Endemicity for Soil-Transmitted Helminthiasis. **Acta Parasitologica**, v. 68, p. 481–495, 2023. DOI: 10.1007/s11686-023-00701-1

R Core Team. **R: A Language and Environment for Statistical Computing**. Vienna, Austria, 2014. Disponível em: <http://www.R-project.org/>.

SARMENTO, V. A. S. et al. **Frequência das geo-helminthiases em Maceió, Alagoas (2019-2021)**. In: 59º Congresso da SBMT: Medicina Tropical sob olhar de Saúde Única. São Paulo. 2024. Disponível em: <https://medtrop2024.com.br/evento/medtrop2024/trabalhosaprovados/naintegra/2294?utm>. Acesso em: 05 mar. 2025.

SCHWARZ, G. Estimating the dimension of a model. **Annals of statistics**, v. 6, n. 2, p. 461-464, 1978.

SEGUÍ, R. et al. Intestinal symptoms and Blastocystis load in schoolchildren of Paranaguá Bay, Paraná, Brazil. **Rev Inst Med Trop Sao Paulo**. v. 59, p. 2–4, 2017.

SHUMWAY, R. H.; STOFFER, D. S. **Time Series Analysis and Its Applications: with R examples**. 5. ed. Cham: Springer, 2017.

SILVA, J. V. L. et al. Factors Associated with Gastrointestinal Parasitic Infections among Young Population in Northeast Brazil. **Canadian Journal of Infectious Diseases and Medical Microbiology**. 2016.

SILVA, J. P. *et al.* Doenças negligenciadas em Minas Gerais e determinantes sociais. **Atenas Higéia**, v. 1, n. 1, 2019.

SILVA, L. A. et al. Diagnóstico de helmintos de importância médica no estado de Alagoas durante dois anos de Pandemia de Covid-19. **Journal of Health and Biological Sciences**, v. 11, n. 1, 2023.

SILVA, M. L. F. et al. Contaminação parasitária das praças públicas do Município de João Pessoa, Paraíba. **Research, Society and Development**, v. 10, n.10, 2021.

SILVA, M. R.; SOUZA, A. C.; OLIVEIRA, T. P. Neglected tropical diseases: epidemiological scenario and control strategies. **Revista Brasileira de Epidemiologia**, v. 24, p. e210034, 2021. DOI: 10.1590/1980-549720210034.

SNIS. **Sistema Nacional de Informações sobre Saneamento**. 2022. Disponível em: <<https://www.gov.br/cidades/pt-br/aceso-a-informacao/acoes-e-programas/saneamento/snis>>.

SOARES, A. A. **Análise comparativa de séries temporais para determinação de um modelo de previsão da demanda em uma indústria têxtil**. Trabalho de conclusão de curso apresentado à Coordenação do Curso de Graduação em Administração, da Universidade Federal de Pernambuco – UFPE. Caruaru. 2017.

STOCK, J. H.; WATSON, M. W. **Introduction to econometrics**. 3rd ed. Boston: Pearson Education, 2015.

STRUNZ, E. C. et al. Water, Sanitation, Hygiene, and Soil-Transmitted Helminth Infection: A Systematic Review and Meta-Analysis. **PLOS Medicine**, v. 11, n. 3, 2014.

SWEISS, K. et al. Hospital admissions due to infectious and parasitic diseases in England and Wales between 1999 and 2019: an ecological study. **BMC Infectious Diseases**, v. 22, n. 398, 2022.

TRAPLETTI, A.; HORNIK, K.; LeBARON, B. **tseries**: Análise de séries temporais e finanças computacionais. Versão 0.10-54. CRAN, 2023. Disponível em: <https://CRAN.R-project.org/package=tseries>. Acesso em: Agosto de 2024.

WEBEL, K.; OLLECH, D. An overall seasonality test. **Deutsche Bundesbank's Discussion Paper series**. 2019.

VEESENMEYER, A. F. Important Nematodes in Children. *Pediatric Clinics of North America*, v. 69, n. 1, p. 129-139. DOI: 10.1016/j.pcl.2021.08.005.

WICKHAM, H. et al. **ggplot2**: Create Elegant Data Visualisations Using the Grammar of Graphics. Versão 3.5.1. CRAN, 2024. Disponível em: <https://CRAN.R-project.org/package=ggplot2>. Acesso em: Agosto de 2024.

WORLD HEALTH ORGANIZATION. **Ending the neglect to attain the Sustainable Development Goals: a road map for neglected tropical diseases 2021–2030**. Geneva: World Health Organization, 2023. Disponível em: <https://www.who.int/publications/i/item/9789240010352>. Acesso em: 3 mar. 2025.

WORLD HEALTH ORGANIZATION. **Neglected tropical diseases**. Geneva: World Health Organization, 2023. Disponível em: <https://www.who.int/health-topics/neglected-tropical-diseases#tab=tab_1>. Acesso em: 3 mai. 2024.

XAVIER, D. B. **Estudo ecológico de séries temporais das doenças tropicais negligenciadas, malária e tuberculose - Brasil, 2008 a 2030**. Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Medicina Tropical da Universidade de Brasília – UNB. Brasília. 2020.

ZILIOTTO, M.; ELLWANGER, J. H.; CHIES, J. A. B. Geo-helminthíases no Rio Grande do Sul: uma análise a partir da perspectiva de Saúde Única. **Ciência na Pandemia**, v. 2, n. 1, 2022.

9. APÊNDICE

```
library(ggplot2)
library(tseries)
library(forecast)
library(seastests)

#Comparação entre algoritmos preditivos (ARIMA, ETS E AE)
#ESTADO DE ALAGOAS - SEGUNDO MAIOR NÚMERO DE CASOS DO NDE

#PREVALÊNCIA MENSAL (%) DE HELMINTÍASES EM AL

ts<- ts(ST.AL, c(2010,1), frequency = 12)

summary(ts)
str(ts)
autoplot(ts)+
  labs(x = "Tempo", y = "Prevalência (%)", caption = "")+
  theme_minimal() +
  theme(
    plot.title = element_text(hjust = 0.4),
    legend.position = "right",
    panel.grid.major = element_line(color = "gray80", size = 0.5),
    panel.grid.minor = element_line(color = "gray90", size = 0.25)
  )

hist(ts)

dec <- decompose(ts)
autoplot(dec)+
  labs(x = "Tempo", y = c("", "Tendência", "Sazonalidade", "Ruído"),
  caption = "Fonte: DataSUS, 2024.")+
  theme_minimal() +
  theme(
    plot.title = element_text(hjust = 0.4),
    legend.position = "right",
    panel.grid.major = element_line(color = "gray80", size = 0.5),
    panel.grid.minor = element_line(color = "gray90", size = 0.25)
  )

isSeasonal(ts, test = "fried") #se este teste quando estiver
comparando grupos dependentes

ggseasonplot(ts)+
  labs(x = "Meses")+
  ggtitle("")+
  theme_minimal() +
  theme(
    plot.title = element_text(hjust = 0.4),
    legend.position = "right",
    panel.grid.major = element_line(color = "gray80", size = 0.5),
    panel.grid.minor = element_line(color = "gray90", size = 0.25)
  )+
```



```

guides(colour = guide_legend(title = "Ano"))

# Criando o gráfico

ggseasonplot(ts) +
  labs(x = "Meses") +
  ggtitle("") +
  theme_minimal() +
  theme(
    plot.title = element_text(hjust = 0.4),
    legend.position = "right",
    panel.grid.major = element_line(color = "gray80", size = 0.5),
    panel.grid.minor = element_line(color = "gray90", size = 0.25)
  ) +
  guides(colour = guide_legend(title = "Ano"))

# ausência de sazonalidade

adf.test(ts)
kpss.test(ts, null= "Trend")
# ausência de estacionariedade

ndiffs(ts)
acf(ts)

#MODELOS ARIMA

auto.arima(ts, ic="aic",trace=TRUE)
auto.arima(ts, ic="bic",trace=TRUE)
auto.arima(ts, ic="aicc",trace=TRUE)

#MODELO ALTERNATIVO
library(lmtest)
ajusteB = arima(ts, order=c(1,1,1))
coeftest(ajusteB)
checkresiduals(ajusteB)
tsdiag(ajusteB)
# % MA *** e independência residual

#PREVISÃO

#1 passo
l <- length(ts)
GEO.1 <- ts(ts[-(144)], start=c(2010,1), frequency=12)
plot(GEO.1)

```

```

AIC.ajuste= arima (GEO.1 , order=c(1,1,1))
summary(AIC.ajuste)
coeftest(AIC.ajuste)
tsdiag(AIC.ajuste)
checkresiduals(AIC.ajuste)
Box.test(AIC.ajuste$residuals)

serie.est.AIC = fitted(AIC.ajuste)
print(serie.est.AIC)

accuracy(ts, serie.est.AIC)

x <- forecast(AIC.ajuste,1 )
y1 <- as.numeric(x$mean)
print(y1)

h.1 <- ts[144]
print(h.1)

#3 passos
l <- length(ts)
GEO.3 <- ts(ts[-(142:l)], start=c(2010,1), frequency=12)
plot(GEO.3)

AIC.ajuste= arima (GEO.3 , order=c(1,1,1))
summary(AIC.ajuste)
coeftest(AIC.ajuste)
tsdiag(AIC.ajuste)
checkresiduals(AIC.ajuste)
Box.test(AIC.ajuste$residuals)

serie.est.AIC = fitted(AIC.ajuste)
print(serie.est.AIC)

accuracy(ts, serie.est.AIC)

x <- forecast(AIC.ajuste,3 )
y3 <- as.numeric(x$mean)
print(y3)

h.3 <- ts[142:l]
print(h.3)

#6 passos
l <- length(ts)
GEO.6 <- ts(ts[-(139:l)], start=c(2010,1), frequency=12)
plot(GEO.6)

AIC.ajuste= arima (GEO.6 , order=c(1,1,1))
summary(AIC.ajuste)
coeftest(AIC.ajuste)
tsdiag(AIC.ajuste)
checkresiduals(AIC.ajuste)
Box.test(AIC.ajuste$residuals)

serie.est.AIC = fitted(AIC.ajuste)

```

```

print(serie.est.AIC)

accuracy(ts, serie.est.AIC)

x <- forecast(AIC.ajuste,6 )
y6 <- as.numeric(x$mean)
print(y6)

h.6 <- ts[139:1]
print(h.6)

#12 passos
l <- length(ts)
GEO.12 <- ts(ts[-(133:1)], start=c(2010,1), frequency=12)
plot(GEO.12)

BIC.ajuste= arima (GEO.12 , order=c(1,1,1))
summary(BIC.ajuste)
coefest(BIC.ajuste)
tsdiag(BIC.ajuste)
checkresiduals(BIC.ajuste)
Box.test(BIC.ajuste$residuals)

serie.est.BIC = fitted(BIC.ajuste)
print(serie.est.BIC)

accuracy(ts, serie.est.BIC)

x <- forecast(BIC.ajuste,12 )
y12 <- as.numeric(x$mean)
print(y12)

h.12 <- ts[133:1]
print(h.12)

# comparacao entre valores reais e previstos

?accuracy
accuracy(y1, h.1)[1,c(2,3,5)]
accuracy(y3, h.3)[1,c(2,3,5)]
accuracy(y6, h.6)[1,c(2,3,5)]
accuracy(y12, h.12)[1,c(2,3,5)]

library(ggplot2)
library(forecast)

GEO <- ts(ts, start=c(2010,1), frequency=12)
pred= arima (GEO , order=c(1,1,1))
serie = fitted(pred)
print(serie)

```

```

autoplot(ts, series = "Série original") +
  autolayer(serie, series = "Série predita ARIMA (1,1,1)") +
  labs(x = "Tempo", y = "Valores", caption = "") +
  theme_bw() +
  theme(
    plot.title = element_text(hjust = 0.5),
    legend.position = "bottom",
    panel.border = element_rect(color = "gray60", fill = NA),
    panel.grid.major = element_line(color = "gray80"),
    panel.grid.minor = element_line(color = "gray90")
  )

```

#ALISAMENTO EXPONENCIAL

```

#1 passo
fit = holt(GEO.1, 1)
Z1 <- fit$mean
autoplot(fit)
print(Z1)

```

```
accuracy(fit, ts )
```

```

#3 passos
fit = holt(GEO.3, 3)
Z3 <- fit$mean
autoplot(fit)
print(Z3)

```

```

#6 passos
fit = holt(GEO.6, 6)
Z6 <- fit$mean
autoplot(fit)
print(Z6)

```

```

#12 passos
fit = holt(GEO.12, 12)
Z12 <- fit$mean
autoplot(fit)
print(Z12)

```

```
accuracy(fit, ts )
```

```

accuracy(Z1, h.1)[1,c(2,3,5)]
accuracy(Z3, h.3)[1,c(2,3,5)]
accuracy(Z6, h.6)[1,c(2,3,5)]
accuracy(Z12, h.12)[1,c(2,3,5)]

```

```

GEO <- ts(ts, start=c(2010,1), frequency=12)
fit = holt(GEO)
serie2 = fitted(fit)
print(serie2)

autoplot(ts, series = "Série original") +
  autolayer(serie2, series = "Série predita Alisamento exponencial de
Holt") +
  labs(x = "Tempo", y = "Valores", caption = "") +
  theme_bw() +
  theme(
    plot.title = element_text(hjust = 0.5),
    legend.position = "bottom",
    panel.border = element_rect(color = "gray60", fill = NA),
    panel.grid.major = element_line(color = "gray80"),
    panel.grid.minor = element_line(color = "gray90")
  )

#MODELOS DE SUAVIZAÇÃO EXPONENCIAL
## function "ETS"

ets_model <- ets(ts)

summary(ets_model)

#modelo estável, (A,Ad,A)

#1 passo
l <- length(ts)
ts.1 <- ts(ts[-(l44)], start=c(2010,1), frequency=12)

fit1 <- ets(ts.1, model= "AAA", damped = TRUE )
fit1

forecast_ets <- forecast(fit1, h = 1)
Y1 <- forecast_ets$mean
Y1

#3 passos
l <- length(ts)
ts.3 <- ts(ts[-(l42:l)], start=c(2010,1), frequency=12)

fit3 <- ets(ts.3, model= "AAA", damped = TRUE )
fit3

forecast_ets <- forecast(fit3, h = 3)
Y3 <- forecast_ets$mean
Y3

```

```

#6 passos
l <- length(ts)
ts.6 <- ts(ts[-(139:1)], start=c(2010,1), frequency=12)

fit6 <- ets(ts.6, model= "AAA", damped = TRUE )
fit6

forecast_ets <- forecast(fit6, h = 6)
Y6 <- forecast_ets$mean
Y6

#12 passos
l <- length(ts)
ts.12 <- ts(ts[-(133:1)], start=c(2010,1), frequency=12)

fit12 <- ets(ts.12, model= "AAA", damped = TRUE )
fit12

forecast_ets <- forecast(fit12, h =12)
Y12 <- forecast_ets$mean
Y12

?accuracy
accuracy(Y1, h.1)[1,c(2,3,5)]
accuracy(Y3, h.3)[1,c(2,3,5)]
accuracy(Y6, h.6)[1,c(2,3,5)]
accuracy(Y12, h.12)[1,c(2,3,5)]

#PLOT
estim <- ets(ts, model= "AAA", damped = TRUE )
estim

forecast_ <- forecast(estim)
Y <- fitted(forecast_)
serie3 <- Y

autoplot(ts, series = "Série original") +
  autolayer(Y, series = "Série predita modelo ETS (A,Ad,A)") +
  labs(x = "Tempo", y = "Valores", caption = "") +
  theme_bw() +
  theme(
    plot.title = element_text(hjust = 0.5),
    legend.position = "bottom",
    panel.border = element_rect(color = "gray60", fill = NA),
    panel.grid.major = element_line(color = "gray80"),
    panel.grid.minor = element_line(color = "gray90")
  )

#Plot das 3 séries
autoplot(ts, series = "Série original") +
  autolayer(serie, series = "Série ARIMA (1,1,1)") +

```

```

autolayer(serie2, series = "Série AEHolt") +
autolayer(serie3, series = "Série ETS (A, Ad, A)") +
labs(x = "Tempo", y = "Valores", caption = "") +
theme_bw() +
theme(
  plot.title = element_text(hjust = 0.5),
  legend.position = "bottom",
  panel.border = element_rect(color = "gray60", fill = NA),
  panel.grid.major = element_line(color = "gray80"),
  panel.grid.minor = element_line(color = "gray90")
)

# Instalar e carregar o pacote strucchange
install.packages("strucchange")
library(strucchange)

estatisticaF <- strucchange::Fstats(formula= ts ~ 1)
result <- strucchange::sctest(estatisticaF)

plot(estatisticaF)
estatisticaF$Fstats

strucchange::breakpoints(ts ~ 1)

```