

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
FACULDADE DE ECONOMIA
CURSO DE CIÊNCIAS ECONÔMICAS

Gabrielle Maria da Cruz Costa

Previsão da quantidade de consultas especializadas no HU-UFJF e em Juiz de Fora:
Uma abordagem através da análise de séries temporais

Juiz de Fora
2025

Gabrielle Maria da Cruz Costa

Previsão da quantidade de consultas especializadas no HU-UFJF e em Juiz de Fora:

Uma abordagem através da análise de séries temporais

Trabalho de conclusão de curso apresentado ao curso de Ciências Econômicas da Universidade Federal de Juiz de Fora como requisito parcial à obtenção do grau de bacharel em Economia.

Orientador: Prof. Dr. Alexandre Zanini

Coorientador: Bruno Barbosa Vieira

Juiz de Fora
2025

Ficha catalográfica elaborada através do programa de geração automática da Biblioteca Universitária da UFJF, com os dados fornecidos pelo(a) autor(a)

Costa, Gabrielle Maria da Cruz.

Previsão da quantidade de consultas especializadas no HU-UFJF e em Juiz de Fora : Uma abordagem através da análise de séries temporais / Gabrielle Maria da Cruz Costa. -- 2025.

46 f. : il.

Orientador: Alexandre Zanini

Coorientador: Bruno Barbosa Vieira

Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Juiz de Fora, Faculdade de Economia, 2025.

1. Séries temporais. 2. Previsão de demanda. 3. Saúde pública. 4. HU-UFJF. I. Zanini, Alexandre, orient. II. Vieira, Bruno Barbosa, coorient. III. Título.



UNIVERSIDADE FEDERAL DE JUIZ DE FORA
REITORIA - FACECON - Depto. de Economia

FACULDADE DE ECONOMIA / UFJF

ATA DE APROVAÇÃO DE MONOGRAFIA II (MONO B)

Na data de 02/12/2025, a Banca Examinadora, composta pelos professores

1 - Alexandre Zanini - orientador; e

2 - Eduardo Gonçalves,

reuniu-se para avaliar a monografia da acadêmica **GABRIELLE MARIA DA CRUZ COSTA**, intitulada: **PREVISÃO DA QUANTIDADE DE CONSULTAS ESPECIALIZADAS NO HU-UFJF E EM JUIZ DE FORA: UMA ABORDAGEM ATRAVÉS DA ANÁLISE DE SÉRIES TEMPORAIS**.

Após primeira avaliação, resolveu a Banca sugerir alterações ao texto apresentado, conforme relatório sintetizado pelo orientador. A Banca, delegando ao orientador a observância das alterações propostas, resolveu **APROVAR** a referida monografia.

ASSINATURA ELETRÔNICA DOS PROFESSORES AVALIADORES



Documento assinado eletronicamente por **Alexandre Zanini, Professor(a)**, em 02/12/2025, às 17:37, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **Eduardo Gonçalves, Professor(a)**, em 02/12/2025, às 22:04, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no Portal do SEI-Ufjf (www2.ufjf.br/SEI) através do ícone Conferência de Documentos, informando o código verificador **2776319** e o código CRC **AA9624AD**.

RESUMO

Este trabalho tem como objetivo realizar a previsão da quantidade de consultas ambulatoriais especializadas do Hospital Universitário da Universidade Federal de Juiz de Fora (HU-UFJF) e do município de Juiz de Fora, utilizando técnicas de análise de séries temporais. Considerando a relevância dos hospitais universitários no contexto do SUS e a importância da previsão de demanda para o planejamento de recursos, três metodologias foram aplicadas: o Método de Amortecimento Exponencial (MAE), o Modelo Univariado de Box e Jenkins (MBJ) e Redes Neurais Artificiais (RNA). As séries utilizadas apresentam comportamento irregular, influenciado por sazonalidades epidemiológicas, períodos letivos e efeitos da pandemia, o que reforça a necessidade de técnicas preditivas robustas. A análise abrange a estimação dos modelos, avaliação de desempenho via RMSE e comparação dos erros dentro da amostra. Os resultados indicaram que as Redes Neurais apresentaram o melhor desempenho para ambas as séries, com menor erro preditivo em comparação aos métodos tradicionais. Com base no modelo vencedor, foram realizadas previsões até dezembro de 2026, permitindo estimar a participação do HU-UFJF na rede municipal e antecipar oscilações futuras na demanda. Os achados reforçam a utilidade da modelagem de séries temporais como ferramenta estratégica para a gestão hospitalar, contribuindo para o planejamento eficiente de recursos e melhoria do atendimento à população.

Palavras-chave: séries temporais; previsão de demanda; HU-UFJF; saúde pública; redes neurais; ARIMA; amortecimento exponencial.

ABSTRACT

This study aims to forecast the number of specialized outpatient consultations at the University Hospital of the Federal University of Juiz de Fora (HU-UFJF) and in the municipality of Juiz de Fora using time series analysis techniques. Considering the strategic role of university hospitals within Brazil's Unified Health System (SUS) and the growing importance of demand forecasting for resource planning, three methodologies were applied: Exponential Smoothing (MAE), the Box-Jenkins univariate model (MBJ), and Artificial Neural Networks (ANN). The analyzed series showed irregular behavior influenced by epidemiological seasonality, academic cycles, and the effects of the COVID-19 pandemic, highlighting the need for robust predictive models. Model estimation, performance evaluation through RMSE, and in-sample error comparison were conducted. Results showed that Artificial Neural Networks outperformed traditional methods for both series, yielding the lowest prediction errors. Based on the best-performing model, forecasts were generated through December 2026, enabling the assessment of HU-UFJF's participation in the municipal healthcare network and the anticipation of future demand fluctuations. The findings reinforce the value of time series modeling as a strategic tool for hospital management, supporting efficient resource allocation and improving healthcare delivery.

Keywords: time series; demand forecasting; HU-UFJF; public health; neural networks; ARIMA, exponential smoothing.

LISTA DE FIGURAS

Figura 1: Série temporal como resultado de um filtro linear.....	21
Figura 2: Representação de um neurônio artificial.....	23
Figura 3: Arquitetura de uma NNAR.....	24
Figura 4: Consultas especializadas de JF de 2008 a 2025.....	26
Figura 5: Consultas especializadas do HU-UFJF de 2014 a 2025.....	27
Figura 6: Correlograma do erro gerado pelo MAE para HU-UFJF.....	30
Figura 7: Correlograma do erro gerado pelo MAE para Juiz de Fora.....	30
Figura 8: Previsão das Consultas especializadas do HU-UFJF através do MAE.....	31
Figura 9: Previsão das Consultas especializadas de Juiz de Fora através do MAE.....	31
Figura 10: Correlograma do erro gerado pelo MBJ para HU-UFJF.....	34
Figura 11: Correlograma do erro gerado pelo MBJ para Juiz de Fora.....	34
Figura 12: Previsão das Consultas especializadas do HU-UFJF através do MBJ.....	35
Figura 13: Previsão das Consultas especializadas de Juiz de Fora através do MBJ.....	35
Figura 14: Previsão das Consultas especializadas do HU-UFJF através da RNA.....	37
Figura 15: Previsão das Consultas especializadas de Juiz de Fora através da RNA.....	38

LISTA DE TABELAS

Tabela 1: Resultados MAE HU-UFJF.....	28
Tabela 2: Resultados MAE Juiz de Fora.....	28
Tabela 3: Parâmetros de Sazonalidade.....	29
Tabela 4: Estatísticas do MAE para consultas ambulatoriais do HU-UFJF e JF.....	30
Tabela 5: Previsão do MAE para o número de consultas médicas especializadas.....	32
Tabela 6: Estatísticas do MBJ para consultas ambulatoriais do HU-UFJF e JF.....	33
Tabela 7: Previsão do MBJ para o número de consultas médicas especializadas.....	36
Tabela 8: Previsão do NNAR para o número de consultas médicas especializadas.....	39
Tabela 9: RMSE de cada modelo.....	40
Tabela 10: Número de consultas especializadas anuais.....	40

LISTA DE ABREVIATURAS E SIGLAS

ARIMA	<i>AutoRegressive Integrated Moving Average</i>
ARMA	<i>AutoRegressive Moving Average</i>
BIC	<i>Bayesian Information Criterio</i>
BSC	<i>Balanced Scorecard</i>
BPA	Boletim de Produção Ambulatorial
Ebserh	Empresa Brasileira de Serviços Hospitalares
FPW	<i>Forecast pro for Windows</i>
HU-UFJF	Hospital Universitário da Universidade Federal de Juiz de Fora
JF	Juiz de Fora
MAE	Método de Amortecimento Exponencial
MBJ	Método de Box&Jenkins
MEC	Ministério da Educação
NNAR	Neural Network AutoRegression
REHUF	Programa Nacional de Reestruturação dos Hospitais Universitários Federais
RMSE	<i>Root Mean Square Error</i>
RN	Redes Neurais
SUS	Sistema Único de Saúde
UTI	Unidade de Terapia Intensiva

SUMÁRIO

1 INTRODUÇÃO.....	9
2 REVISÃO DE LITERATURA.....	12
2.1 Economia da Saúde.....	12
2.2 Saúde pública e hospital universitário.....	14
2.3 Planejamento estratégico nos hospitais públicos.....	15
2.4 Séries Temporais na previsão de demanda na saúde.....	16
3 METODOLOGIA.....	19
3.1 Séries Temporais.....	19
3.2 Método de Amortecimento Exponencial (MAE).....	19
3.3 Método Univariado de Box e Jenkins (MBJ).....	21
3.4 Redes Neurais de séries temporais.....	23
3.5 Competição de métodos.....	25
4 ANÁLISE DE DADOS E RESULTADOS.....	26
4.1 Base de Dados.....	26
4.2 Modelo de Amortecimento Exponencial para HU-UFJF e Juiz de Fora.....	27
4.3 Box e Jenkins para HU-UFJF e Juiz de Fora.....	33
4.4 Rede Neural para HU-UFJF e Juiz de Fora.....	36
4.5 Competição de métodos.....	39
5 CONCLUSÃO.....	42
REFERÊNCIAS BIBLIOGRÁFICAS.....	43

1 INTRODUÇÃO

O Hospital Universitário da Universidade Federal de Juiz de Fora (HU-UFJF), vinculado à Empresa Brasileira de Serviços Hospitalares (Ebserh), é um dos principais centros de assistência, ensino e pesquisa em saúde da Zona da Mata mineira. Atendendo integralmente pelo SUS, o HU-UFJF oferece mais de 60 especialidades médicas e multiprofissionais e desempenha papel essencial na atenção secundária e terciária de Juiz de Fora e região. Com duas unidades de assistência, ele é referência para uma região que abrange cerca de 94 municípios, totalizando aproximadamente 1,7 milhão de habitantes. Em 2023, o HU-UFJF realizou 163 mil consultas, 326 mil exames e quase 5 mil cirurgias, evidenciando sua ampla capacidade assistencial e relevância para o sistema de saúde (BRASIL, 2024). Além da dimensão assistencial, o hospital cumpre papel essencial na formação de profissionais de saúde, funcionando como campo de prática para os cursos da Universidade Federal de Juiz de Fora e abrigando programas de residência médica e multiprofissional em diversas áreas. Em 2025, foram disponibilizadas 72 vagas distribuídas em 27 especialidades, consolidando o HU-UFJF como um importante polo de qualificação profissional e de desenvolvimento científico (UFJF, 2025)

Atualmente, o HU-UFJF encontra-se em processo de expansão e modernização, com investimento de cerca de R\$234 milhões para a conclusão de sua nova estrutura hospitalar na Unidade Dom Bosco. A ampliação prevê o aumento de 137 para 377 leitos, além da criação de novos centros cirúrgicos, laboratórios e unidades de terapia intensiva. Essa reestruturação reforça o papel do HU-UFJF como polo regional de referência em saúde pública, ensino e pesquisa, ao mesmo tempo em que amplia a importância de estudos voltados à gestão hospitalar eficiente e baseada em evidências. (ANDIFES, 2025)

Segundo Luo et al. (2017), as séries de atendimento hospitalar tendem a apresentar padrões sazonais e irregulares, influenciados por aspectos como estações do ano, campanhas de vacinação, mudanças climáticas e ocorrência de surtos de doenças — especialmente doenças respiratórias e infecciosas. Esses fatores fazem com que certos períodos concentrem picos de demanda, enquanto outros apresentam redução significativa. Huang et al. (2020) complementam que a ausência de previsões quantitativas impede que gestores antecipem tais variações, resultando em planejamento reativo em vez de proativo, o que compromete a eficiência do sistema.

Os hospitais-escola, além de enfrentar as sazonalidades epidemiológicas, o calendário acadêmico exerce influência relevante sobre o volume de consultas. Durante os períodos

letivos, há maior disponibilidade de residentes e preceptores, o que amplia a capacidade de atendimento. Já em períodos de recesso, o número de consultas tende a cair, alterando o ritmo dos serviços especializados. Esse padrão reforça a importância de modelos de previsão que consigam capturar componentes sazonais institucionais, típicos de hospitais de ensino (SILVA; OLIVEIRA; FERREIRA, 2021). Conforme argumenta Mendes (2018), a falta de previsões acuradas em ambientes públicos de saúde pode levar à subutilização de leitos e profissionais em períodos de baixa demanda e, inversamente, à sobrecarga e aumento de filas em períodos de alta, comprometendo tanto a qualidade do cuidado quanto os indicadores de desempenho institucional.

A aplicação de modelos econométricos na área da saúde tem se consolidado como uma abordagem robusta para previsão de demanda, custos e utilização de serviços hospitalares, fornecendo subsídios para o planejamento e a gestão eficiente dos recursos públicos. Esses modelos permitem compreender a relação entre variáveis socioeconômicas, demográficas e epidemiológicas, capturando tanto tendências de longo prazo quanto variações sazonais e conjunturais que afetam o sistema de saúde (WOOLDRIDGE, 2016). E também, de acordo com Hansen e King (2020), os modelos econométricos permitem quantificar o impacto de políticas públicas e estimar a resposta da demanda hospitalar a mudanças no financiamento, no perfil populacional e na incidência de doenças. Assim, são ferramentas que auxiliam na tomada de decisões estratégicas e na formulação de políticas baseadas em evidências.

Existem diversos métodos que podem ser aplicados para a previsão da demanda em serviços de saúde, e serão aplicadas três abordagens amplamente utilizadas: ARIMA, Holt-Winters e Redes Neurais Artificiais. O modelo ARIMA é eficiente para séries temporais lineares, capturando tendências e autocorrelações históricas, enquanto o Holt-Winters é indicado para séries que apresentam tendência e sazonalidade, permitindo previsões mais ajustadas a padrões periódicos de atendimento (BOX et al., 2016; HYNDMAN; ATHANASOPOULOS, 2021). Já as Redes Neurais são capazes de modelar relações não lineares complexas entre variáveis, sendo úteis quando a demanda é influenciada por múltiplos fatores externos, como clima, políticas públicas e sazonalidade epidemiológica. A escolha do método depende do perfil da série temporal, da disponibilidade de dados e do objetivo da previsão, sendo cada abordagem complementar para subsidiar a gestão eficiente de consultas e recursos hospitalares (HUANG et al., 2020).

Dito isto, o objetivo deste trabalho é construir modelos de previsões para as consultas ambulatoriais especializadas do HU-UFJF e para a cidade de Juiz de fora e projetar o número

de consultas especializadas para o ano de 2026. Assim, além de obter a quantidade de consultas é esperado também entender a participação que o HU-UFJF tem na malha de saúde de Juiz de Fora. Para isso, serão estimados três modelos de previsão, um pelo Método de Amortecimento Exponencial (MAE), outro pelo Método de Box e Jenkins (MBJ) e por último pelo Método de Redes Neurais. Para decidir qual o melhor método, será feita uma competição entre os modelos, comparando a assertividade e a capacidade da previsão dentro e fora da amostra. A partir do modelo vencedor serão geradas previsões para as consultas ambulatoriais no HU-UFJF nos próximos 20 meses, de abril de 2025 até dezembro de 2026.

Feito estas considerações, atenta-se que este trabalho está organizado em cinco capítulos contando com essa introdução. No Capítulo 2 encontra-se uma revisão de escopo da literatura da participação dos hospitais universitários no SUS e como a economia da saúde e a utilização de previsão de séries temporais contribuem para o funcionamento da gestão hospitalar. No Capítulo 3 vê-se as metodologias que serão aplicadas neste trabalho monográfico. Já no Capítulo 4 podem ser vistos os resultados das análises. Por fim, no Capítulo 5 tem-se as considerações finais.

2 REVISÃO DE LITERATURA

2.1 Economia da Saúde

A economia da saúde constitui um campo interdisciplinar que busca compreender como os recursos são alocados, utilizados e distribuídos no setor de saúde, considerando as restrições orçamentárias e a necessidade de maximizar o bem-estar social. A partir de princípios econômicos clássicos, o enfoque recai sobre a eficiência, a equidade e a eficácia das políticas públicas de saúde, elementos fundamentais para a formulação de estratégias de gestão e previsão de demanda em serviços hospitalares (FOLLAND; GOODMAN, 2008). Silva, Toma e Soárez (2012) falam que por se tratar de uma vertente de conhecimento que o objetivo gira em torno da otimização das ações de saúde, isso coloca em evidência o caráter econômico da saúde pública, ou seja, um setor em que a escassez de recursos exige decisões baseadas em critérios racionais e técnicos.

Entretanto, Nero (1995) traz que a relação entre economia e saúde é marcada por tensões conceituais. Uma vez que as profissões da saúde tradicionalmente se orientam por uma ética individualista, no sentido de que a saúde não tem preço e uma vida salva justifica qualquer esforço, enquanto a economia parte de uma ética social, voltada ao bem comum e à alocação justa dos recursos escassos. Essa diferença de perspectivas reflete o desafio de conciliar a dimensão humana da assistência médica com a necessidade de gestão eficiente dos sistemas de saúde.

No entanto o campo de saúde não pode ser tratado como um setor igual aos demais presentes na economia, já que os serviços de saúde não podem ser vistos apenas como organizações distribuidoras de bens e serviços, mas também como instituições voltadas a auxiliar pessoas a ultrapassar dificuldades e inconvenientes da vida, o que é difícil de se traduzir em números. Essa característica exige instrumentos analíticos próprios, sensíveis à incerteza, à imprevisibilidade e às dimensões éticas envolvidas na oferta e no consumo dos serviços (NERO, 1995).

Os estudos de Iunes (1995) aprofundam essa complexidade ao abordar as especificidades da demanda por serviços de saúde, destacando que ela é irregular e imprevisível, ocorrendo geralmente em situações de doença e vulnerabilidade. Além disso, o consumidor de serviços de saúde não decide com plena racionalidade econômica, já que o consumo ocorre sob incerteza e risco, e a relação médico-paciente é mediada por confiança e assimetria de informações. Questões éticas e regulatórias, como a restrição à propaganda

médica e às práticas competitivas, reduzem a transparência de preços e limitam a concorrência, configurando um mercado com falhas estruturais. Assim, o comportamento da demanda é determinado tanto por fatores econômicos quanto por elementos não monetários, como tempo, acesso e percepção de necessidade.

Essas características revelam o caráter especial da saúde enquanto bem econômico. Iunes (1995) deixa claro que a atenção médica não pode ser tratada como uma mercadoria comum, pois apresenta falhas de mercado e elevado grau de incerteza. O que também foi apontado por Silva, Toma e Soárez (2012) que classificaram a saúde como um “bem de mérito”, dotado de valor social intrínseco. E assim, a análise econômica do setor deve reconhecer a importância da equidade na organização dos serviços e evitar que o atendimento se torne privilégio restrito a grupos de maior renda ou acesso.

Com essa perspectiva, a economia da saúde cumpre papel estratégico ao fornecer instrumentos de análise para o planejamento e a tomada de decisão no setor público. Seus principais objetivos são: fornecer técnicas analíticas que auxiliem na promoção da eficiência e da equidade; reconhecer a escassez de recursos e suas implicações; e maximizar os benefícios sociais obtidos a partir desses recursos. O uso de modelos quantitativos, como as séries temporais, pode subsidiar decisões gerenciais, permitindo projetar a demanda e otimizar a oferta de consultas e procedimentos hospitalares (SILVA; TOMA; SOÁREZ, 2012).

Estudos empíricos reforçam que o comportamento da demanda por serviços de saúde está condicionado por múltiplos fatores, tais como demográficos, epidemiológicos e socioeconômicos que influenciam a utilização dos serviços ambulatoriais e especializados. observaram aumento expressivo no uso de serviços de saúde no Brasil nas últimas décadas, evidenciando mudanças estruturais no sistema e a necessidade de aprimorar o planejamento da oferta. Essa ampliação da demanda, quando não acompanhada por instrumentos de previsão e análise, pode gerar desequilíbrios entre oferta e procura, comprometendo a eficiência dos serviços públicos (BASTOS et. al, 2011).

Zucchi, Del Nero e Malik (2008) ressaltam que, ao lado dos objetivos humanitários, as políticas de saúde devem estimular a eficiência e o uso racional dos recursos, sem perder de vista o paciente e a coletividade. Essa visão converge com a abordagem moderna da economia da saúde, que propõe a integração entre avaliação econômica, planejamento de recursos e previsão de demanda, como base para políticas públicas sustentáveis. No contexto hospitalar, tais instrumentos permitem antecipar variações no volume de consultas, identificar gargalos e otimizar a capacidade de atendimento, exatamente o objetivo do presente estudo.

2.2 Saúde pública e hospital universitário

A saúde pública brasileira conta com a atuação de hospitais universitários para atender parte de sua demanda desde 1990 quando foram integrados oficialmente ao SUS pela Lei 8080/90 (BRASIL,1990). Antes dessa data, os HUs não eram considerados pontos estratégicos na rede de atendimento pelo Ministério da Saúde, ainda que os hospitais tivessem um grande arcabouço de conhecimento, avanços tecnológicos e atividades de pesquisa, estes tinham como principal objetivo o ensino de práticas médicas e pesquisas (ALMEIDA, 2021; TORO, 2015).

Assim, após a inserção no SUS os HUs passaram a fornecer atendimento para a população. Contudo, se de um lado foi positivo devido a concentração de conhecimento e avanço tecnológico, por outro lado houve uma sobrecarga nas instituições que não tinham estrutura suficiente para a grande demanda da população (TORO, 2015).

Devido às dificuldades enfrentadas pelos centros de ensinos para manter uma boa gestão dos hospitais universitários que, diante o desafio de grande complexidade e que exigem iniciativas pontuais em termos de modernização na gestão estratégica e operacional em saúde, foi necessário a intervenção estatal para tentar resolver esses problemas. Foi assim que desde meados dos anos 2000, foram desenvolvidas algumas ações para melhorar a gestão desses hospitais, entre elas a criação da comissão interinstitucional e o Programa Nacional de Reestruturação dos Hospitais Universitários Federais (REHUF), mas essas medidas ainda não foram suficientes para sanar os problemas estrutural, financeiro e de gestão. (ABBADÉ, 2022).

Até que em 2011, pela Lei 12550 foi criado a Ebserh (BRASIL,2011). Uma empresa estatal órgão do MEC e responsável pela gestão do REHUF que atua em duas áreas desafiadoras do Brasil: Educação e Saúde. No âmbito da educação, cabe a competência de prestar apoio às instituições federais em funções de ensino, pesquisa e extensão, também ao ensino-aprendizagem e a formação de pessoas no campo da saúde. Já no âmbito da saúde, a estatal tem por finalidade a prestação de serviços de assistência médico-hospitalar, ambulatorial e de apoio diagnóstico e terapêutico à comunidade, esses sendo integralmente e exclusivamente inseridos no SUS (Ebserh, 2022).

Abbade (2022) e Lobo (2009) pontuam que mesmo após a criação da Ebserh e a adesão dos HUs a gestão da mesma, ao tratar de saúde coletiva e saúde pública brasileira apesar de importante a implementação de modelos de gestão aprimorados e com eficiência

comprovada, estes não são suficientes para se atribuir o sucesso das organizações de saúde, uma vez que há grande complexidade nas organizações de saúde e da gestão em saúde pública. E isso se justifica pelas externalidades enfrentadas por essas organizações, marcado por subfinanciamento persistente, defasagem tecnológica e deterioração da infraestrutura, então a implementação de modelos de gestão mais eficientes pode não ser suficiente para promover melhorias significativas em seu desempenho, mas continuam sendo fundamentais para o funcionamento dos hospitais.

2.3 Planejamento estratégico nos hospitais públicos

O setor público no geral é reconhecido pela abrangência de normas legais enquanto é simultaneamente pressionado pela escassez de recursos e isso traz a necessidade de uma gestão profissionalizada que consiga passar pelas adversidades desse cenário vago e abrangente e adote medidas estratégicas certas para trazer o melhor desempenho de cada setor. (PEDRO, 2004).

O gerenciamento nos hospitais públicos encontra ainda mais desafios, dentro do contexto em que se encontram há uma demanda por maior eficiência, eficácia e melhor gestão dos recursos públicos. Além da complexidade derivada da tecnologia, política, legislação e economia, os hospitais têm que se ajustar às mudanças de comportamentos dos usuários do sistema de saúde (SILVA; ASSIS, 2016).

Misozcky e Guedes (2016) fala da importância do planejamento na administração pública e o traz como uma ferramenta que organiza a complexidade das relações na sociedade e nas organizações. O planejamento é o cálculo situacional que correlaciona o presente com o futuro e o conhecimento com a ação, nele se passa constantemente pelas fases de conceber ações e operações para atingir um objetivo, acompanhar a realização de ações, introduzir modificações nas decisões tomadas (caso necessárias) e aprender com erros e acertos para conceber novas ações e operações.

A gestão estratégica é uma abordagem implementada em ambientes dinâmicos para ter êxito, pois trilha o caminho a ser seguido até o objetivo almejado, consegue antecipar e responder às mudanças e ainda minimiza falhas e riscos. Na primeira vista, o planejamento estratégico pode ser associado a obtenção de lucros, mas sobrevivência financeira, competitividade e assistência à saúde com qualidade almejada pelos hospitais públicos também podem ser alcançados com a construção de um plano estratégico (SENA et al., 2022).

Para a gestão de hospitais universitários, Silva e Assis (2016) abordam as muitas dificuldades que podem ser encontradas, além das já mencionadas relacionadas a parte hospitalar, faz presente os desafios da gestão da parte educacional já que são hospitais-escola e surge também a necessidade de gerir a capacitação das equipes, o conhecimento de seus ambientes e certificação de seus serviços. E para superar esses desafios é preciso uma gestão estratégica que articule recursos e equipes com o intuito de promover planos eficazes.

Diante do desafio para gerir mais de quarenta hospitais universitários em diferentes níveis de gestão e perfil assistencial, a rede Ebserh se vincula às melhores práticas de gestão estratégica, como a BSC (Ebserh, 2024). Essa ferramenta tem como objetivo ampliar a visão dos sistemas de controle para além de indicadores financeiros e se baseia na construção de informação financeira e não financeira, informação interna e externa, informação constante sobre o desempenho organizacional e informação sobre os resultados presentes e futuros. (PEDRO, 2004).

Assim, o principal objetivo do planejamento estratégico tanto para os hospitais públicos quanto para os hospitais universitários não é apenas obter um serviço excelente, mas sim superar as expectativas dos usuários e dos profissionais envolvidos de forma a buscar o mais alto nível de qualidade, conveniência, eficiência e satisfação do paciente (SENA et al., 2022).

2.4 Séries Temporais na previsão de demanda na saúde

As séries temporais consistem em sequências de dados coletados ao longo do tempo, permitindo identificar padrões de tendência, sazonalidade e ciclos. Na área da saúde, essas análises são fundamentais para prever a demanda hospitalar, como internações, ocupação de leitos de UTI e atendimentos em pronto-socorro, permitindo uma gestão eficiente de recursos e tomada de decisão baseada em evidências (BORGES, 2023; CAMBUÍ et al., 2023).

Entre os modelos clássicos, destaca-se o ARIMA (AutoRegressive Integrated Moving Average), amplamente utilizado para séries estacionárias, e a Suavização Exponencial (Holt-Winters), adequada para séries com tendência ou sazonalidade, sendo ambos eficazes na previsão de demanda em ambientes hospitalares (BORGES, 2023).

No contexto local, o trabalho de Sampaio (2024), intitulado “O uso de modelos preditivos para as internações nos hospitais públicos de Juiz de Fora/MG em 2024” mostra a aplicabilidade prática dessas técnicas ao utilizar os modelos ARIMA e Amortecimento Exponencial para estimar o número de internações clínicas e cirúrgicas em cinco hospitais

públicos de Juiz de Fora. O autor conclui que as séries temporais oferecem subsídios confiáveis para o planejamento hospitalar, permitindo antecipar períodos de maior demanda e otimizar o uso de recursos humanos e materiais. A pesquisa evidencia que a análise de tendência e sazonalidade é fundamental para compreender o comportamento das internações e que a previsão quantitativa pode apoiar de forma eficaz a gestão hospitalar e o planejamento operacional no SUS, fortalecendo a governança baseada em dados (SAMPAIO, 2024).

Em contextos emergenciais, como a pandemia de COVID-19, o trabalho “Previsão, por meio de análise de Séries Temporais, de leitos de Unidades de Terapia Intensiva no Rio Grande do Norte” aplicou ARIMA e Suavização Exponencial a dados diários de ocupação de leitos, mostrando que as séries temporais possibilitam decisões rápidas de expansão de capacidade e realocação de recursos críticos (LEITE, 2021).

Os modelos de aprendizado de máquina, como as redes neurais recorrentes LSTM (Long Short-Term Memory), permitem capturar padrões temporais complexos e relações não lineares, ampliando a precisão das previsões (FARIAS; SILVA; ARAÚJO, 2023). Além disso, modelos híbridos, que combinam abordagens estatísticas e inteligência artificial, têm demonstrado desempenho superior na previsão de demanda hospitalar, especialmente em situações de alta variabilidade, como surtos ou epidemias (VOLLMEER et al., 2020).

O estudo de Leite (2021), “Previsão, por meio de análise de Séries Temporais, de leitos de Unidades de Terapia Intensiva – UTI na rede de atendimento do SUS no município de Goiânia” amplia o tema ao aplicar diferentes modelos estatísticos e de aprendizado de máquina à previsão de diárias de leitos de UTI com base em dados do Sistema de Informações Hospitalares do SUS (SIHSUS). O autor compara modelos como SARIMA, Holt-Winters, XGBoost e LSTM (Long Short-Term Memory), concluindo que as redes neurais recorrentes (LSTM) apresentaram o melhor desempenho preditivo, superando os métodos tradicionais em aproximadamente 15% no erro médio quadrático (RMSE). O trabalho evidencia que a combinação entre abordagens estatísticas e de aprendizado profundo potencializa a acurácia das previsões e amplia a capacidade de resposta da gestão pública, especialmente na alocação de leitos e na prevenção de colapsos hospitalares. Assim, o estudo de Leite (2021) reforça a importância da inovação metodológica na área da saúde, mostrando que a integração entre modelos clássicos e redes neurais representa uma tendência promissora para o aprimoramento das previsões de demanda hospitalar.

Além disso, Ackermann (2020) exemplificou a aplicação de modelos híbridos em hospitais de pronto-atendimento, combinando ARIMA e modelos caóticos para prever atendimentos de urgência. O estudo também destacou o potencial de redes neurais artificiais

(ANN e DNN) na identificação de padrões não lineares, permitindo otimizar recursos, reduzir tempo de espera e aumentar a eficiência operacional.

Portanto, a análise de séries temporais, seja por modelos clássicos, redes neurais ou abordagens híbridas, mostra-se indispensável para o planejamento estratégico e operacional da saúde, oferecendo previsões confiáveis que contribuem para a alocação eficiente de leitos, insumos e profissionais, especialmente em períodos de alta variabilidade de demanda (SOUZA; NETO, 2023; VOLLMEER et al., 2020).

Feitas estas considerações, no próximo capítulo será apresentada especificamente a metodologia a ser aplicada neste trabalho monográfico.

3 METODOLOGIA

3.1 Séries Temporais

Morettin e Tolo (2006) definem série temporal como qualquer conjunto de observações que possam ser ordenadas no tempo. Para fazer a análise das séries temporais existem dois ângulos que podem ser explorados, o primeiro tipo de análise utiliza o domínio de frequência, portanto gerando modelos não paramétricos. O outro utiliza o domínio temporal o que resulta em modelos paramétricos, os modelos que serão utilizados neste trabalho são exemplos desse tipo de modelo.

Um processo estocástico caracteriza-se por uma sequência no tempo de variáveis aleatórias, ou seja, um modelo que descreve a estrutura de probabilidade de uma sequência de observações é chamado de processo estocástico. Desta forma, processos estocásticos são sistemas que evoluem no tempo e/ou no espaço de acordo com leis probabilísticas (ZANINI, 2023). Assim, relacionando as duas definições Morettin e Tolo (2006) e Zanini (2023) uma série temporal é uma parte de uma trajetória entre outras que poderiam ter sido observadas ou então uma realização parcial do processo estocástico.

De forma matemática, uma série temporal pode ser definida por Morettin e Tolo (2006) um vetor $Z(t)$, de ordem $r \times 1$, e t sendo um vetor $p \times 1$

$$Z(t) = \{z_t \in R | t = 1, 2, 3 \dots N\} \quad (3.1)$$

A partir da equação 3.1 tem a definição de que uma série é univariada quando ($r = 1$) e multivariada quando ($r > 1$), da mesma forma, tem-se que uma série é unidimensional quando ($t = 1$) e multidimensional quando ($t > 1$) (MORETTIN; TOLOI, 2006).

De forma geral, o objetivo do estudo de uma série temporal consiste em: dada uma realidade (processo estocástico) retira-se uma amostra finita de observações equiespaçadas no tempo (série temporal) e através do estudo desta amostra (análise de séries temporais) identifica-se um modelo cujo objetivo é inferir sobre o comportamento da realidade (modelo estocástico) (ZANINI, 2023).

3.2 Método de Amortecimento Exponencial (MAE)

O primeiro modelo que será utilizado neste trabalho é o método de amortecimento exponencial. Esse modelo tem como objetivo estimar uma equação de previsão pela

decomposição da série histórica em parâmetros de nível, tendência e sazonalidade, que de forma matematicamente pode ser escrita através da equação 3.2 a seguir

$$Z_t = (a_1 + a_2 t) \rho_t + \varepsilon_t \quad (3.2)$$

Em que:

Z_t = Série temporal

a_1 = Parâmetro de nível

a_2 = Parâmetro de tendência

t = Variável tempo

ρ_t = Parâmetros de sazonalidade

ε_t = erro de previsão em que $\varepsilon_t \sim N(0, \sigma^2)$.

Zanini (2023) fala que todo modelo é uma simplificação da realidade, e dessa forma a equação matemática precisa conter exatamente os parâmetros que caracterizam a série temporal, ou seja, da equação (3.2) tem a possibilidade de outras estruturas a depender da série de tempo que está sendo estudada. Por exemplo, uma série temporal que não apresenta sazonalidade não terá os ρ_t (parâmetros de sazonalidade) em sua equação final.

Para estimar os parâmetros do modelo é utilizado a ideia de pesos de modo que seja possível reestimar os parâmetros do modelo adicionando a informação mais recente. Assim é feita uma combinação convexa, onde é dado um peso α para o “presente” e um peso $(1 - \alpha)$ para o “passado”. Para cada um dos parâmetros da equação (3.2) será utilizada as seguintes atualizações paramétricas representadas nas equações (3.3) a (3.5) (ZANINI, 2023).

$$\hat{a}_1 = \alpha * \frac{Z_T}{\hat{\rho}_t(T-1)} + (1 - \alpha) * [\hat{a}_1(T - 1) + \hat{a}_2(T - 1)] \quad (3.3)$$

$$\hat{a}_2 = \beta * [\hat{a}_1(T) - \hat{a}_1(T - 1)] + (1 - \beta) * [\hat{a}_2(T - 1)] \quad (3.4)$$

$$\hat{\rho}_t = \gamma * \frac{Z_T}{\hat{a}_1(T)} + (1 - \gamma) * [\hat{\rho}_t(T - 1)] \quad (3.5)$$

É possível observar que existem três hiperparâmetros (α , β , e γ), uma para cada parâmetro da equação. Para cada um desses hiperparâmetros existe apenas um valor que é


encontrado a partir da série temporal que está sendo estudada e é a partir dessa constante que é feita a atualização dos parâmetros a medida que novos dados reais chegam (ZANINI, 2023).

3.3 Método Univariado de Box e Jenkins (MBJ)

Dentro do conceito de processo estocástico discutido na seção 3.1, Mattos (2023) demonstra uma subdivisão importante dentro de processos estocásticos, os processos estocásticos estacionários, esse que apresentam média e variância constante e a autocovariância depende apenas da defasagem. Quando um desses critérios não é cumprido se tem um processo estocástico não estacionário.

Assim para as séries estacionárias, Box e Jenkins (1994) a partir da Teoria Geral de Sistemas Lineares em que a passagem de um ruído branco por um filtro linear de memória infinita gera um processo estacionário de segunda ordem, o que pode ser representado pela figura 1 a seguir:

Figura 1: Série temporal como resultado de um filtro linear



Fonte: Box e Jenkins (1994)

Zanini (2023) levanta o problema de que nessa representação $\Psi(B)$ é um polinômio infinito, mas que Box & Jenkins falam que pode-se afirmar que todo polinômio infinito pode ser expresso pelo quociente de dois polinômios finitos, com algumas restrições. E dessa forma tem-se as equações (3.6), (3.7) e (3.8) a seguir:

$$\Psi(B) = \theta(B) / \phi(B) \text{ , Sendo:} \quad (3.6)$$

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q \Rightarrow \text{Polinômio MA (q)} \quad (3.7)$$

$$\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p \Rightarrow \text{Polinômio AR (p)} \quad (3.8)$$

E a partir disso surgem os Modelos ARMA(p,q) para os processos estacionários, representado na equação a seguir:

$$\phi(B)z_t = \theta(B)a_t \quad (3.9)$$

No entanto, muitas séries temporais encontradas apresentam um comportamento não estacionário, mas que com o passar do tempo pode apresentar um comportamento

homogêneo. Isso pode ser observado pelo polinômio $\varphi(B)$, de modo que se d raízes unitárias desse polinômio estiverem no círculo unitário e as demais fora tem-se uma série temporal não estacionária homogênea, ou seja, uma série não estacionária que se diferenciada d vezes se comporta como uma série estacionária (BOX;JENKINS, 1994).

$$\phi(B)w_t = \theta(B)a_t, \text{ onde:} \quad (3.10)$$

$$w_t = \nabla^d z_t = (1 - B)^d z_t \quad (3.11)$$

E pelas equações (3.10) e (3.11) Box e Jenkins (1994) apresenta o modelo ARIMA (p,d,q), que também pode ser visto como um modelo ARMA(p,q) diferenciado d vezes.

Além da dificuldade de achar processos estacionários, como apontado anteriormente, Zanini(2023) acrescenta que muitas das vezes estes apresentam comportamentos sazonais e para isso foi formulado os modelos SARIMA, que pode ser representado pela seguinte equação:

$$\phi(B)\Phi(B^S)\nabla_S^D\nabla^d w_t = \theta(B)\Theta(B^S)a_t \quad (3.12)$$

Onde:

$\phi(B)$: operador não sazonal auto-regressivo

ϕ_i : parâmetros auto-regressivo não-sazonais

$\Phi(B^S)$: operador sazonal auto-regressivo

Φ_i : parâmetros auto-regressivo sazonais

$\nabla_S^D = (1 - B^S)^D$: operador diferença sazonal de ordem D

$\nabla^d = (1 - B)^d$: operador diferença não sazonal de ordem d

$\theta(B)$: operador não sazonal de médias móveis

θ_i : parâmetros de médias móveis não sazonais

$\Theta(B^S)$: operador sazonal de médias móveis

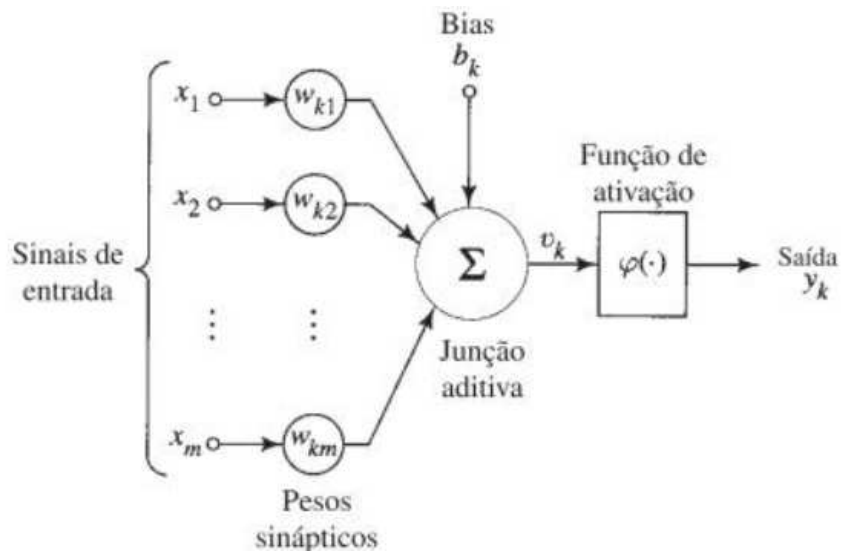
Θ_i : parâmetros de médias móveis sazonais

A modelagem de Box & Jenkins se baseiam em dois princípios, o primeiro é a parcimônia (escolher um modelo com o menor número de parâmetros possíveis para uma representação matemática adequada) e a construção de modelos através de um ciclo iterativo (estratégia de seleção de modelos até a obtenção de um modelo satisfatório). Desta forma, atenta-se que a modelagem através da metodologia de Box & Jenkins, abrange várias etapas de análise indo desde a identificação da estrutura do modelo, passando pela estimação paramétrica e por fim, fazendo vários testes de validação do modelo (ZANINI, 2023).

3.4 Redes Neurais de séries temporais

As RNAs fazem parte de uma categoria de modelos computacionais inspirados no funcionamento do cérebro humano que é muito utilizado para problemas de previsão, classificação e detecção de padrões complexos. Sua arquitetura é composta por unidades de processamento, neurônios artificiais, organizados em camadas interligadas (HAYKIN, 2001).

Figura 2: Representação de um neurônio artificial



Diferente dos modelos apresentados nas seções anteriores, as RNAs também têm a capacidade de aprender relações não lineares entre variáveis através de treinamento, seja este supervisionado ou não supervisionado. Essa aprendizagem acontece por meio do ajuste dos pesos sinápticos da rede, representado pelo vetor $W(m)$ na figura 2 acima, com o objetivo de minimizar o erro entre a saída produzida e a saída desejada (HAYKIN, 2001).


Hyndman e Athanasopoulos (2021) abordam diferentes arquiteturas de redes, que são as formas como os neurônios podem se organizar a depender do objetivo, como as redes

recorrentes, redes convolucionais e redes *feed-forward*. Essa última sendo utilizada em previsões de séries temporais pela sua simplicidade, eficiência computacional e capacidade de capturar dependências dinâmicas de curto prazo.

Este trabalho vai ser abordado apenas as redes *feed-forward*, mais especificamente o modelo NNAR, que é estruturada com uma camada de entrada composta pelos valores defasados da própria série, uma camada intermediária (*hidden layer*) e uma camada de saída, responsável pela previsão do valor futuro da série (HYNDMAN; ATHANASOPOULOS, 2021).

O modelo NNAR é formalmente representado como $NNAR(p, k)$, em que p corresponde ao número de defasagens consideradas na entrada e k ao número de neurônios presentes na camada oculta. Assim, cada previsão é gerada por uma combinação não linear dessas entradas por meio de funções de ativação, geralmente a sigmoide, permitindo capturar padrões complexos, que modelos lineares podem não identificar (HAYKIN, 2001). Uma representação desta estrutura pode ser visualizada na Figura 3.

Figura 3: Arquitetura de uma NNAR



Em séries com sazonalidade, utiliza-se a extensão $NNAR(p, P, k)$, em que P representa as defasagens sazonais (HYNDMAN, 2018).

Sendo:

- p : número de defasagens
- P : número de defasagens sazonais
- m : comprimento do lag sazonal
- k : número de neurônio na camada intermediária

A título de curiosidade um modelo NNAR(p,P,0)m é equivalente a um modelo linear ARIMA(p,0,0)(P,0,0)m sem restrição de estacionariedade (HYNDMAN, 2018). Segundo Zhang (2003), redes neurais autoregressivas tendem a apresentar melhor desempenho em séries com padrões não lineares, volatilidade persistente ou estruturas dinâmicas irregulares.

3.5 Competição de métodos

Sabe-se que o processo de estimação de uma equação de previsão passa pela análise da estrutura de correlação dos dados históricos e da representação desta, por exemplo, através do cálculo de fatores como nível, tendência e sazonalidade. Estimado os parâmetros do modelo, o que se faz, antes de calcular as previsões, é projetar os valores históricos de forma a comparar os valores reais e os valores “ajustados”. Esta comparação fornece o nível de erro de previsão gerado pelo modelo ao se projetar os dados históricos. Este nível de erro, calculado para as previsões um passo-à-frente, ou seja, um período à frente, constitui um “indicador” do desempenho preditivo do modelo para o horizonte futuro, caso não aconteçam grandes mudanças no processo gerador da série histórica (ZANINI, 2023)

Em síntese, a partir da comparação dos valores reais e dos valores “ajustados” pelo modelo, podem ser calculadas várias métricas para medir o desempenho. Estas medidas servem, então, para avaliar o desempenho do modelo estimado dentro da amostra de dados utilizados na modelagem (ZANINI, 2023). Para este trabalho será utilizado o RMSE que calcula o erro quadrático do modelo como pode ser visto na equação (3.13) a seguir:

$$RMSE = \sqrt{\frac{\sum_{t=1}^N (Y(t) - \hat{Y}(t))^2}{N}} \quad (3.12)$$

Sendo:

$Y(t)$: Valor da série temporal no período (t)

$\hat{Y}(t)$: Valor ajustado da série temporal para o período (t)

N : Total de observações


4 ANÁLISE DE DADOS E RESULTADOS

4.1 Base de Dados

A base de dados utilizada neste trabalho é a de atendimento de consulta médica em atenção especializada, por local, ano e mês de atendimento, para o hospital universitário da Universidade Federal de Juiz de Fora e para a cidade de Juiz de Fora. Os dados são disponibilizados pelo Ministério da Saúde, pelo Sistema de Informação Ambulatorial (SIA-SUS), retirados do Tabnet DataSUS que faz a tabulação desses dados (BRASIL, 2025). E para as análises e cálculos dos modelos preditivos foi utilizado o RStudio e o FPW.


Os dados foram coletados em novembro de 2025 e optou-se por utilizar as informações referente ao mês e ano de atendimento para poder evitar viés na análise, uma vez que existe a possibilidade de ocorrer um represamento dos boletins de produção ambulatorial (BPA), o que faz com que as informações do DataSUS Tabnet tenham variações dentro dos últimos seis meses. Assim, a série referente a Juiz de Fora tem periodicidade mensal de janeiro de 2008 a fevereiro de 2025, representada na Figura 4, enquanto a série do HU-UFJF tem início em outubro de 2014 a fevereiro de 2025, representada na Figura 5.

Figura 4: Consultas especializadas de JF de 2008 a 2025



Fonte: Elaboração própria.

Figura 5: Consultas especializadas do HU-UFJF de 2014 a 2025



Fonte: Elaboração própria.

Ao observar o gráfico é possível ver que ambas as séries apresentam um comportamento um tanto irregular e ambos tiveram uma queda considerável no período de pandemia, apesar do HU-UFJF ter demorado um pouco mais de tempo para retomar os seus números. Vale acrescentar que o HU-UFJF representa de 10% a 48% dos atendimentos de consultas especializadas de Juiz de Fora (BRASIL,2025).

4.2 Modelo de Amortecimento Exponencial para HU-UFJF e Juiz de Fora

O primeiro método aplicado foi o de amortecimento Exponencial, e como falado na sessão anterior ambas as séries são irregulares e por isso é difícil identificar pelo gráfico a tendência e a sazonalidade das mesmas, por isso foi escolhido o modelo de Holt-Winters para que assim fosse possível identificar esses parâmetros matematicamente. Nas tabelas 1 e 2 são apresentados os resultados do MAE para o HU-UFJF e para Juiz de Fora respectivamente, onde pode-se observar que para estimar os parâmetros o peso para o passado de todas as estimativas foi maior ou seja, os últimos dados possuem um peso menor na estimação dos parâmetros. Para o parâmetro de nível para o HU-UFJF o presente teve um peso de 44,51% e o passado 55,49% e para Juiz de Fora o presente teve um peso de 45,09% e o passado 54,91%. O mesmo se repete para o parâmetro de tendência para o HU-UFJF o presente teve um peso de 0,24% para Juiz de Fora o presente teve um peso de 0,001%, assim como o parâmetro de sazonalidade que no HU-UFJF o presente teve um peso de 2,62% para Juiz de Fora o presente teve um peso de 9,14%.

Tabela 1: Resultados MAE HU-UFJF

Componentes	Hiperparâmetro	Parâmetro
Nível	0,44511	9.249
Tendência	0,0024	1,6874
Sazonalidade	0,02618	*

Fonte: Elaboração própria. Nota* fatores sazonais na tabela 3

Tabela 2: Resultados MAE Juiz de Fora

Componentes	Hiperparâmetro	Parâmetro
Nível	0,45902	37.635
Tendência	0,00001	-0,0012923
Sazonalidade	0,09140	*

Fonte: Elaboração própria. Nota* fatores sazonais na tabela 3

A tabela 3 apresenta os fatores sazonais estimado para os dois modelos. É possível observar que ambas as séries têm o mesmo padrão de sazonalidade, ou seja, as variações entre os meses acontecem no mesmo sentido de modo que se em janeiro apresenta queda em Juiz de Fora no HU-UFJF também e assim por diante em todos os outros meses. A diferença é que vemos uma intensidade diferente, no HU tem um intervalo de variação de - 4% a + 4%, enquanto para Juiz de Fora tem-se uma variação de - 12% a + 11%. Ambas as variações são referentes aos parâmetros de nível com incremento do parâmetro de tendência.

Tabela 3: Parâmetros de Sazonalidade

Componentes	$\rho(\tau_1)$ HU-UFJF	$\rho(\tau_2)$ Juiz de Fora
Janeiro	0,97227	0,88210
Fevereiro	0,99367	0,94865
Março	1,03904	1,03647
Abril	0,96607	0,98607
Maio	0,96157	0,96575
Junho	0,99027	0,99054
Julho	0,96346	0,94851
Agosto	1,03922	1,10938
Setembro	1,01307	1,05627
Outubro	1,02601	1,03229
Novembro	1,04361	1,07300
Dezembro	0,99707	0,99283

Fonte: Elaboração própria.

As equações de previsão estão representadas na equação 4.1 para o HU-UFJF, sendo o parâmetro de nível 9.249, parâmetro de tendência 1,6874 e na equação 4.2 para Juiz de Fora, sendo o parâmetro de nível 37.635, parâmetro de tendência $-0,0012923$ e, $\rho(\tau_1)$ e $\rho(\tau_2)$ os fatores sazonais multiplicativos apresentados na tabela 3.

$$\hat{Z}_t = (9249 + 1,6874t) \rho(\tau_1) + \varepsilon_t \quad (4.1)$$

$$\hat{Y}_t = (37635 - 0,0012923t) \rho(\tau_2) + \varepsilon_t \quad (4.2)$$

Na tabela 4 estão representadas algumas das estatísticas dos modelos. Para o HU-UFJF o poder de explicação do modelo é de 48,8% e em média ele erra 38,9% ao realizar as previsões para o mês seguinte. E para Juiz de Fora o poder de explicação do modelo é de 37,85% e em média ele erra 13,51% ao realizar as previsões para o mês seguinte. Além disso, o teste de Ljung-Box teve sua hipótese nula (erros são descorrelatados) rejeitada no nível de confiança de 5% para ambos os modelos. Mas é possível ver pelas figuras 6 e 7 que a


correlação dos erros está dentro do intervalo de -0,2 e +0,2, o que mostra uma correlação estatisticamente irrelevante.

Tabela 4: Estatísticas do MAE para consultas ambulatoriais do HU-UFJF e JF

	HU-UFJF	Juiz de Fora
P-valor do Teste de Ljung-Box*	0,169	0,339
MAPE (%)	38,9%	13,51%
R ² ajustado (%)	48,8%	37,85%


Fonte: Elaboração própria. Nota: * No software do FPW, rejeita-se a hipótese nula quando o p-valor é \geq ao nível de confiança.

Figura 6: Correlograma do erro gerado pelo MAE para HU-UFJF



Fonte: Elaboração própria.


Figura 7: Correlograma do erro gerado pelo MAE para Juiz de Fora



Fonte: Elaboração própria.


As figuras 8 e 9 mostram a evolução de ambas as séries e consulta especializada ao longo de todo o período de estudo. Nas duas é possível observar oscilações durante todo o período, com uma queda marcante na pandemia e depois a recuperação dos números de consultas.

Figura 8: Previsão das Consultas especializadas do HU-UFJF através do MAE



Fonte: Elaboração própria. Nota: ____ Valor Real ____ Valor ajustado/previsões ____ Intervalo de confiança de 95%.

Figura 9: Previsão das Consultas especializadas de Juiz de Fora através do MAE



Fonte: Elaboração própria. Nota: ____ Valor Real ____ Valor ajustado/previsões ____ Intervalo de confiança de 95%.

Na tabela 5, estão expostas as previsões para o período de março de 2025 até dezembro de 2026 gerados pelo Método de Amortecimento Exponencial, com o modelo de Holt Winters para as duas séries trabalhadas. Vale pontuar que a previsão é probabilística, ou

seja, na forma de um intervalo de confiança que fornece uma probabilidade de se observar o valor estimado.

Tabela 5: Previsão do MAE para o número de consultas médicas especializadas

Data	Limite Inferior	Previsão HU-UFJF	Limite Superior	Limite Inferior	Previsão JF	Limite Superior
03/2025	5.665	9.612	13.559	26.302	39.008	51.714
04/2025	4.869	8.938	13.007	23.689	37.111	50.532
05/2025	4.528	8.898	13.269	22.030	36.346	50.663
06/2025	4.417	9.166	13.915	21.730	37.279	52.828
07/2025	3.959	8.919	13.879	19.554	35.697	51.840
08/2025	4.196	9.622	15.049	23.344	41.751	60.159
09/2025	3.746	9.382	15.017	20.766	39.753	58.740
10/2025	3.581	9.503	15.426	19.145	38.850	58.556
11/2025	3.454	9.668	15.882	19.527	40.383	61.238
12/2025	2.886	9.239	15.591	16.234	37.365	58.496
01/2026	2.491	9.010	15.530	12.067	33.198	54.329
02/2026	2.442	9.210	15.979	13.579	35.702	57.826
03/2026	2.564	9.633	16.701	15.681	39.008	62.335
04/2026	1.821	8.958	16.095	13.386	37.111	60.835
05/2026	1.604	8.918	16.231	12.104	36.346	60.588
06/2026	1.640	9.186	16.731	12.289	37.279	62.269
07/2026	1.258	8939	16619	10.333	35.697	61.061
08/2026	1.654	9643	17633	14.890	41.751	68.613
09/2026	1.269	9402	17535	12.491	39.753	67.015
10/2026	1.190	9524	17859	11.083	38.850	66.618
11/2026	1.145	9689	18233	11.788	40.383	68.977
12/2026	613	9259	17904	8.569	37.365	66.161

Fonte: Elaboração própria. Nota: Intervalo de Confiança de 95%.

4.3 Box e Jenkins para HU-UFJF e Juiz de Fora

Para os modelos MBJ a escolha da estrutura do modelo foi feita por um critério automático de minimização do BIC (*Bayesian Information Criterio*). Assim, o modelo estimado para o HU-UFJF foi um ARIMA (0,1,1), que a equação 4.3 mostra e apresenta o coeficiente de MA simples. Pela tabela 6 o modelo possui um poder de explicação 49,13% com um erro médio de 39,65%.

$$(1 - B)\hat{Z}_t = (1 - 0,5502B)a_t \quad (4.3)$$

Já para Juiz de Fora, foi estimado um SARIMA (1,0,1)(1,0,0) representado pela equação 4.4 que tem os coeficientes AR sazonal, AR simples e MA simples estimados. Pela tabela 6 o modelo possui um poder de explicação 37,09% com um erro médio de 13,99%.

$$(1 - 0,7687B)(1 - 0,2735B^{12})\hat{Y}_t = 6243,8 + (1 - 0,3361B)a_t \quad (4.4)$$


Tabela 6: Estatísticas do MBJ para consultas ambulatoriais do HU-UFJF e JF

	HU-UFJF	Juiz de Fora
P-valor do Teste de Ljung-Box*	0,04234	0,0481
MAPE (%)	39,65%	13,99%
R ² ajustado (%)	49,13%	37,09%

Fonte: Elaboração própria. Nota: * No software do FPW, rejeita-se a hipótese nula quando o p-valor é \geq ao nível de confiança.


Além disso, o teste de Ljung-Box teve sua hipótese nula aceita ao nível de confiança de 5% para as duas séries, o que é confirmado pelas figuras 10 e 11.

Figura 10: Correlograma do erro gerado pelo MBJ para HU-UFJF



Fonte: Elaboração própria.


Figura 11: Correlograma do erro gerado pelo MBJ para Juiz de Fora



Fonte: Elaboração própria.


As figuras 12 e 13 são uma representação gráfica das séries temporais de Consultas especializadas para HU-UFJF e Juiz de Fora respectivamente, e também as previsões resultantes do método de Box e Jenkins.

Figura 12: Previsão das Consultas especializadas do HU-UFJF através do MBJ



Fonte: Elaboração própria. Nota: ____ Valor Real ____ Valor ajustado/previsões ____ Intervalo de confiança de 95%..

Figura 13: Previsão das Consultas especializadas de Juiz de Fora através do MBJ



Fonte: Elaboração própria. Nota: ____ Valor Real ____ Valor ajustado/previsões ____ Intervalo de confiança de 95%.

Na tabela 7, como na seção 4.2 estão discriminadas as previsões probabilísticas para o período de março de 2025 até dezembro de 2026 e o seu intervalo de confiança.

Tabela 7: Previsão do MBJ para o número de consultas médicas especializadas


Data	Limite Inferior	Previsão HU-UFJF	Limite Superior	Limite Inferior	Previsão JF	Limite Superior
03/2025	5.598	9.205	12.812	31.019	40.063	48.880
04/2025	5.250	9.205	13.160	31.154	40.063	49.217
05/2025	4.930	9.205	13.480	31.217	40.063	48.829
06/2025	4.632	9.205	13.777	26.699	34.892	46.291
07/2025	4.353	9.205	14.057	26.640	34.892	45.940
08/2025	4.089	9.205	14.321	30.422	40.063	48.848
09/2025	3.838	9.205	14.572	30.730	40.063	48.912
10/2025	3.598	9.205	14.812	30.842	40.063	49.372
11/2025	3.368	9.205	15.042	28.482	40.063	47.769
12/2025	3.147	9.205	15.263	25.839	34.892	44.200
01/2026	2.933	9.205	15.476	25.378	33.275	42.465
02/2026	2727	9.205	15.683	26.929	34.892	46.964
03/2026	2.527	9.205	15.883	27.448	40.063	49.413
04/2026	2.332	9.205	16.077	27.236	40.063	48.152
05/2026	2.144	9.205	16.266	26.986	40.063	47.979
06/2026	1960	9.205	16.450	26.116	34.892	46.865
07/2026	1.780	9.205	16.629	25.761	34.892	46.077
08/2026	1.605	9.205	16.805	27.524	40.063	47.871
09/2026	1.434	9.205	16.976	27.026	40.063	47.790
10/2026	1.266	9.205	17.143	25.280	40.063	48.197
11/2026	1.102	9.205	17.307	27.192	40.063	47.433
12/2026	941	9.205	17.468	24.603	34.892	46.395

Fonte: Elaboração própria. Nota: Intervalo de Confiança de 95%.

4.4 Rede Neural para HU-UFJF e Juiz de Fora

O modelo RNA estimado para o HU-UFJF foi um NNAR(1,1,2)[12], ou seja, um modelo sazonal, 1 lag de defasagem, com uma camada escondida e 2 neurônios. É possível ver na figura 14 a representação gráfica das previsões feitas pela rede .

Figura 14: Previsão das Consultas especializadas do HU-UFJF através da RNA




Fonte: Elaboração própria. Nota: _____ Valor Real _____ Valor ajustado _____ Previsões/Intervalo de confiança de 95%.

O modelo RNA estimado para Juiz de Fora foi um NNAR(3,1,3)[12], ou seja, um modelo sazonal, 3 lag's de defasagem, com uma camada escondida e 3 neurônios. Na figura 15 a seguir a representação gráfica das previsões feitas pela rede.

É válido destacar que, ao contrário dos métodos antes expostos, no método de RNA's não é possível derivar uma equação matemática de previsão. No entanto, cabe explorar para cada série diferentes arquiteturas alterando número de camadas escondidas e quantidade de neurônios.

Figura 15: Previsão das Consultas especializadas de Juiz de Fora através da RNA



Fonte: Elaboração própria. Nota: ____ Valor Real ____ Valor ajustado Previsões/Intervalo de confiança de 95%.

Na tabela 8, como nos métodos anteriores estão discriminadas as previsões probabilísticas para o período de março de 2025 até dezembro de 2026 e o seu intervalo de confiança de 95%.

Tabela 8: Previsão do NNAR para o número de consultas médicas especializadas

Data	Limite Inferior	Previsão HU-UFJF	Limite Superior	Limite Inferior	Previsão JF	Limite Superior
03/2025	5.793	9.088	12.478	31.534	39.043	46.127
04/2025	2.606	11.147	13.410	31.233	39.384	47.576
05/2025	2.378	9.758	12.864	30.843	39.849	48.658
06/2025	2.392	9.284	12.539	28.877	39.947	47.216
07/2025	2.095	10.176	13.201	27.955	39.937	47.301
08/2025	1.797	9.366	12.882	27.492	39.897	47.850
09/2025	1.894	9.921	12.874	26.459	39.906	47.675
10/2025	1.792	9.472	13.435	26.836	39.867	47.924
11/2025	1.969	9.161	12.377	25.208	39.930	47.490
12/2025	1.703	8.887	12.546	22.971	39.969	47.027
01/2026	1.773	8.424	11.882	20.584	39.981	45.688
02/2026	1.811	10.639	12.316	19.734	39.941	48.563
03/2026	1.364	9.652	12.291	16.422	39.929	47.139
04/2026	2.052	10.334	12.893	15.543	39.924	47.907
05/2026	1.534	9.450	12.357	16.145	39.918	46.859
06/2026	1.954	8.996	12.011	15.196	39.917	47.599
07/2026	1.513	10.769	12.590	13.649	39.917	48.278
08/2026	1.643	9.674	12.295	14.571	39.917	46.546
09/2026	1.541	9.197	11.690	14.247	39.917	47.648
10/2026	1.870	9.289	12.145	14.733	39.917	46.835
11/2026	1.691	8.969	12.166	14.859	39.917	47.321
12/2026	1.716	9.031	11.917	14.396	39.916	48.040

Fonte: Elaboração própria. Nota: Intervalo de Confiança de 95%.

4.5 Competição de métodos

Para escolher qual dos métodos apresenta o melhor desempenho, foi escolhido analisar o RMSE, indicador esse que mede a raiz do erro quadrático que o modelo gera, na tabela 9 é apresentado os resultados para cada uma das séries.

Tabela 9: RMSE de cada modelo

	HU-UFJF	Juiz de Fora
MAE	1.823	6.065
MBJ	1.869	6.102
RNA	1.017	2.813

Fonte: Elaboração própria.

O critério utilizado para a escolha foi o modelo que teve o menor RMSE, assim as RNA's apresentaram o melhor desempenho, tanto para a série do HU-UFJF quanto para a série de Juiz de Fora. Desse modo, as previsões para o final de 2025 e o ano de 2026 para o número de consultas especializadas para o HU-UFJF e para Juiz de Fora foram calculadas por Redes Neurais Artificial, estas podem ser conferidas na tabela 8 e nas figuras 14 e 15.

Por fim, na tabela 10 os valores mensais foram agregados anualmente, podendo-se ver a variação percentual anual do número de atendimentos de consultas especializadas para o HU-UFJF e para Juiz de Fora.

Tabela 10: Número de consultas especializadas anuais

Ano	HU-UFJF	Variação %	Juiz de Fora	Variação %
2020	62.850	-	357.211	-
2021	52.243	-16,88%	346.442	-3,01%
2022	99.570	90,59%	414.956	19,78%
2023	123.797	24,33%	457.371	10,22%
2024	112.874	-8,82%	459.068	0,37%
2025*	114.200	1,17%	454.402	-1,02%
2026*	114.424	0,20%	453.284	-0,25%

Fonte: Elaboração própria. Nota: *valores projetados por RNA

Essa variação mais uma vez confirma o que foi falado no início do capítulo sobre o comportamento irregular das séries. Para o HU-UFJF o número que mais chama a atenção é a

variação de 90%, de 2021 para 2022, ou seja, o número de consultas especializadas atendidas no hospital quase dobrou. Uma das hipóteses para que isso possa ter ocorrido é que, com o fim da pandemia em 2022, foi possível a expansão de agendamento de consultas eletivas. Os anos seguintes seguem em oscilação, mas pela projeção é provável que ocorra uma estabilização no volume de consultas. Já para a cidade de Juiz de Fora vê-se a queda de atendimentos em 2021, o que pode ser explicado pelas restrições de atendimento durante a pandemia. Nos anos seguintes teve uma recuperação marginal positiva, mas decrescente a ponto das projeções do modelo sugerirem uma estabilização para o próximo biênio.

5 CONCLUSÃO

O presente trabalho demonstrou que a utilização de modelos de previsão baseados em séries temporais é uma ferramenta eficaz e necessária para o planejamento de serviços de saúde, especialmente em ambientes públicos complexos como o HU-UFJF. A análise das séries temporais evidencia forte irregularidade, marcada por sazonalidade institucional e epidemiológica, além de choques significativos, como a pandemia. A aplicação dos métodos MAE, MBJ e RNA permitiu comparar diferentes abordagens lineares e não lineares, evidenciando que as Redes Neurais apresentaram o melhor desempenho preditivo para ambas as séries analisadas, com menor RMSE e maior capacidade de capturar padrões complexos.

As previsões realizadas até 2026 mostram estabilidade nos atendimentos especializados do HU-UFJF após a recuperação pós-pandemia, bem como leve queda na série de Juiz de Fora. Esses resultados oferecem informações importantes para o planejamento e otimização do uso dos recursos. Além disso, reforçam o papel estratégico da previsão quantitativa na gestão hospitalar, permitindo decisões mais eficientes em um contexto caracterizado pela escassez de recursos e crescente demanda.

Conclui-se que a incorporação de ferramentas estatísticas e computacionais avançadas deve ser estimulada na gestão pública da saúde, contribuindo para um modelo de planejamento baseado em evidências. Para estudos futuros sugere-se a monitoração do desempenho preditivo do modelo, assim como podem integrar variáveis exógenas, e desenvolver modelos causais, assim como explorar modelos híbridos, ampliando ainda mais a capacidade preditiva e fortalecendo a gestão estratégica dos hospitais universitários e da rede de saúde como um todo.

REFERÊNCIAS BIBLIOGRÁFICAS

ABBADE, E. B.. O impacto da gestão EBSEH na produção dos hospitais universitários do Brasil. *Ciência & Saúde Coletiva*, v. 27, n. 3, p. 999–1013, mar. 2022.

ACKERMANN, A. E. F. Modelo de previsão de demanda do serviço de urgência em um hospital de pronto atendimento. 2020. Dissertação (Mestrado em Engenharia de Produção e Sistemas) — Universidade do Vale do Rio dos Sinos, São Leopoldo, 2020. BORGES, F. A. S. Análise de séries temporais na previsão de demanda. 2023. Disponível em: https://aprepro.org.br/conbrepro/anais/2023/arquivos/10312023_231034_6541b9b2c0fa9.pdf. Acesso em: 14 out. 2025.

ALMEIDA, Nathália Cardoso Amorim Salvino de. O Hospital Universitário no Sistema Único de Saúde. 2021. 119f. Dissertação (Mestrado em Direito) - Centro de Ciências Sociais Aplicadas, Universidade Federal do Rio Grande do Norte, Natal, 2021.

ASSOCIAÇÃO NACIONAL DOS DIRIGENTES DAS INSTITUIÇÕES FEDERAIS DE ENSINO SUPERIOR (ANDIFES). HU-UFJF terá investimento de R\$ 234 milhões em infraestrutura e expansão dos serviços. 2025. Disponível em: <https://www.andifes.org.br/2025/04/29/ufjf-hu-tera-investimento-de-r234-milhoes-em-infraestrutura-e-expansao-dos-servicos/>. Acesso em: 3 out. 2025.

BASTOS, Gisele Alsina Nader; SANTOS, Iná S.; DIAS-DA-COSTA, Juvenal Soares; CAPILHEIRA, Marcelo Fernandes. Uso de serviços ambulatoriais nos últimos 15 anos: comparação de dois estudos de base populacional. *Revista Brasileira de Epidemiologia*, São Paulo, v. 14, n. 4, p. 620-632, 2011.

BOX, G. E. P., JENKINS, G. M.. *Time Series Analysis, Forecasting and Control*, San Francisco, Holden-Day, 1994.

BOX, George E. P.; JENKINS, Gwilym M.; REINSEL, Gregory C.; LJUNG, Greta M. *Time Series Analysis: Forecasting and Control*. 5. ed. Hoboken: John Wiley & Sons, 2016.

BRASIL. Constituição Federal de 1988. Brasília: Senado Federal, 1988.

_____. Lei nº 8080, de 19 de setembro, 1990.

_____. Lei nº 12550, de 15 de dezembro, 2011. Autoriza o Poder Executivo a criar a empresa pública denominada Empresa Brasileira de Serviços Hospitalares - EBSEH, 2011.

_____. Ministério da Saúde. Sistema de Informação Ambulatorial (SIA-SUS) DATASUS. Tabnet. Brasília, DF: Ministério da Saúde, 2025.

BRASIL. Empresa Brasileira de Serviços Hospitalares (Ebserh). Hospital Universitário da UFJF – Ebserh: notícias e informações institucionais. Brasília: Ministério da Educação, 2024. Disponível em: <https://www.gov.br/ebserh/pt-br/hospitais-universitarios/regiao-sudeste/hu-ufjf>. Acesso em: 3 out. 2025.

BONACIM, C. A. G.; ARAUJO, A. M. P. DE .. Valor econômico agregado por hospitais universitários públicos. *Revista de Administração de Empresas*, v. 49, n. 4, p. 419–433, out. 2009.

CAMBUÍ, C. M.; PIRATELLI, C. L.; ACHCAR, J. A.; PINTO, R. H. F.; PACHECO, B. C. S. Aplicações de previsão de demanda por meio de séries temporais. *Revista de Gestão e Secretariado*, v. 14, n. 2, p. 1477–1490, 2023. Disponível em: <https://doi.org/10.7769/gesec.v14i2.1627>. Acesso em: 14 out. 2025.

FARIAS, L. R. C.; SILVA, T. P.; ARAÚJO, P. H. M. A. Multitask LSTM for Arboviral Outbreak Prediction Using Public Health Data. 2023. Disponível em: <https://arxiv.org/abs/2505.04566>. Acesso em: 14 out. 2025.

FOLLAND, Sherman; GOODMAN, Allen C.; STANO, Miron. *A economia da saúde*. 5. ed. Porto Alegre: Artmed, 2008

HANSEN, Bruce E.; KING, Garry. Econometrics and Causal Inference for Health Policy Analysis. *Health Economics Journal*, v. 29, n. 4, p. 515–533, 2020.

HUANG, Y. et al. Medical service demand forecasting using a hybrid model. *BMC Health Services Research*, 2020. Disponível em: <https://bmchealthservres.biomedcentral.com/>. Acesso em: 4 out. 2025.

HYNDMAN, Rob J. Advanced forecasting methods: Neural network models. In: *Forecasting: Principles and Practice*. Australia: Otexts, 2018.

HYNDMAN, Rob J.; ATHANASOPOULOS, George. *Forecasting: Principles and Practice*. 3. ed. Melbourne: OTexts, 2021. Disponível em: <https://otexts.com/fpp3/>. Acesso em: 6 out. 2025.

IUNES, Roberto F. Demanda e demanda em saúde. In: PIOLA, Sérgio Francisco; VIANNA, Solon Magalhães (orgs.). *Economia da saúde: conceitos e contribuição para a gestão da saúde*. Brasília: IPEA. p. 99-121, 1995

LEITE, Gilleddson Fryttys Menezes. *Previsão, por meio de análise de Séries Temporais, de leitos de Unidades de Terapia Intensiva – UTI na rede de atendimento do Sistema Único de Saúde – SUS no município de Goiânia*. São Carlos: Universidade de São Paulo, Instituto de Ciências Matemáticas e de Computação, 2021. 52 f. Monografia (MBA em Ciências de Dados) – ICMC/USP, 2021.

LOBO, M. et al.. Impacto da reforma de financiamento de hospitais de ensino no Brasil. *Revista de Saúde Pública*, v. 43, n. 3, p. 437–445, maio 2009.

MATTOS, Rogério Silva de. *Modelos ARIMA: (Metodologia de Box & Jenkins)*. Universidade Federal de Juiz de Fora, Faculdade de Economia, Juiz de Fora, 2023. Notas de aula.

MENDES, Eugênio Vilaça. *O cuidado das condições crônicas na atenção primária à saúde: o imperativo da consolidação da estratégia da saúde da família*. Brasília: Organização Pan-Americana da Saúde, 2018.

MISOZCKY, Maria Ceci Araujo; GUEDES, Paulo. Planejamento e programação na administração pública. 3. ed. rev. e atual. Florianópolis: Departamento de Ciências da Administração/UFSC; Brasília: CAPES: UAB, 2016.

MORETIN, P.A; TOLOI, C.M.. Análise de Séries Temporais. 2. Ed. São Paulo: Blucher, 2006

NERO, Carlos R.D. O que é economia da saúde. In: PIOLA, Sérgio Francisco; VIANNA, Solon Magalhães (orgs.). Economia da saúde: conceitos e contribuição para a gestão da saúde. Brasília: IPEA. p. 5-22, 1995.

PEDRO, José Maria. O Balanced Scorecard (BSC) no setor público. Informação & Informática, n. 28, p. 41–61, 2004.

Rede EBSEH. Relatório Gerencial dos hufs 2019 a 2022. Brasília, 2022. Disponível em:[https://www.gov.br/ebserh/pt-br/hospitais-universitarios/relatorios-gerenciais/2019-2022/relatorio-gerencial-dos-hufs-2019-2022_e.pdf/view]. Acesso em: 15 junho 2025.

Rede EBSEH. Plano Diretor Estratégico 2024-2028: Hospital Universitário da Universidade Federal de Juiz de Fora - HU-UFJF. Juiz de Fora, 2024. Disponível em: [https://www.gov.br/ebserh/pt-br/hospitais-universitarios/regiao-sudeste/hu-ufjf/governanca/superintendencia/unidade-de-planejamento/plano-diretor-estrategico-pde/PDE_20242028_HUUFJF.pdf]. Acesso em: 15 junho 2025.

SAMPAIO, João Victor Rezende. O uso de modelos preditivos para a internação nos hospitais públicos de Juiz de Fora/MG em 2024. 2024. Trabalho de conclusão de curso Especialização em Economia e Administração. Hospital Universitário, Universidade Federal de Juiz de Fora, Juiz de Fora, 2024.

SENA, Daniely Bezerra de Castro; PEDROSA, Kamyla de Arruda; MOTA, Márcio de Oliveira. Evidências científicas do planejamento estratégico em hospitais públicos: revisão de escopo. Conjecturas, v. 22, n. 12. 2022.

SILVA, Christian Luiz da; ASSIS, Luana de. Aplicabilidade do planejamento estratégico em hospitais universitários federais. Revista de Gestão em Sistemas de Saúde, São Paulo, v. 5, n. 2, p. 39–51, jul./dez. 2016. DOI: 10.5585/rgss.v5i2.257. Disponível em: <https://periodicos.uninove.br/saude/article/view/257>. Acesso em: 16 junho 2025

SILVA, E. P; COSTA, P. S; TIBÉRIO, C. S. B. Gestão estratégica de custos: estudo de caso aplicado a hospitais universitários. In: CONGRESSO INTERNACIONAL DE CUSTOS, 8, 2003, Montevideu. Anais. Montevideu: 2003. CD-ROM.

SILVA, R. F.; OLIVEIRA, C. M.; FERREIRA, A. P. Gestão e planejamento de hospitais universitários: desafios e estratégias. Revista Brasileira de Gestão em Saúde, v. 12, n. 2, p. 45–59, 2021.

SILVA, S.A.L.S.; TOMA, T. S.; SOÁREZ, P. C.. Economia da saúde no processo de decisão e gestão de programas, ações e serviços de saúde. In: SÃO PAULO (Cidade). Secretaria Municipal da Saúde. Coordenação de Epidemiologia e Informação (CEInfo). A economia da

saúde: desafios para incorporação da dimensão econômica na produção de informação para a gestão do SUS em São Paulo. São Paulo: CEInfo. p. 35–71, 2012.

SODRÉ, F. et al.. Empresa Brasileira de Serviços Hospitalares: um novo modelo de gestão?. Serviço Social & Sociedade, n. 114, p. 365–380, abr. 2013.

SOUZA, E. F.; NETO, A. R. S. Aplicação de métodos de previsão de demanda para dietas enterais em uma central de abastecimento farmacêutico. XLIII Encontro Nacional de Engenharia de Produção, Fortaleza, 17 a 20 out. 2023. Disponível em: https://www.researchgate.net/publication/373711592_Aplicacao_de_metodos_de_previsao_de_demanda_para_dietas_enterais_em_uma_central_de_abastecimento_farmaceutico. Acesso em: 13out. 2025.

TORO, Ivan Felizardo Contrera. O papel dos hospitais universitários no SUS: avanços e retrocessos. Serviço Social & Saúde, Campinas, SP, v. 4, n. 1, p. 55–60, 2015. Disponível em: <https://periodicos.sbu.unicamp.br/ojs/index.php/sss/article/view/8634978>. Acesso em: 16 julho 2025.

UNIVERSIDADE FEDERAL DE JUIZ DE FORA (UFJF). Hospital Universitário da UFJF – Serviços e Estrutura. Juiz de Fora: UFJF, 2023. Disponível em: <https://www2.ufjf.br/ufjf/servicos/hu/>. Acesso em: 3 out. 2025.

VOLLMEER, M. A. C.; GLAMPSON, B.; MELLAN, T. A.; MISHRA, S.; MERCURI, L.; COSTELLO, C.; KLABER, R.; COOKE, G.; FLAXMAN, S.; BHATT, S. A unified machine learning approach to time series forecasting applied to demand at emergency departments. 2020. Disponível em: <https://arxiv.org/abs/2007.06566>. Acesso em: 13 out. 2025.

WOOLDRIDGE, Jeffrey M. Introductory Econometrics: A Modern Approach. 6. ed. Boston: Cengage Learning, 2016.

ZANINI, Alexandre. Modelos de Previsão para Séries Temporais. Material Didático. Juiz de Fora, 2023

ZHANG, G. Peter. Time series forecasting using a hybrid ARIMA and neural network model. Neurocomputing, v. 50, p. 159–175, 2003.

ZUCCHI, Paola; DEL NERO, Carlos; MALIK, Ana Maria. Gastos em saúde: os fatores que agem na demanda e na oferta dos serviços de saúde. Revista de Administração em Saúde, São Paulo: Faculdade de Saúde Pública da USP / FGV-EAESP, 2008.