

**Ministério da Educação**  
**Universidade Federal de Ouro Preto**  
**Escola de Minas**  
**Departamento de Engenharia de Produção, Administração e Economia**

KAMILA DE OLIVEIRA SUPERBI

**MODELOS DE SÉRIES TEMPORAIS: UMA  
ANÁLISE DAS ADMISSÕES DO TRABALHO  
FORMAL BRASILEIRO**

Ouro Preto  
2024

Kamila de Oliveira Superbi

# MODELOS DE SÉRIES TEMPORAIS: UMA ANÁLISE DAS ADMISSÕES DO TRABALHO FORMAL BRASILEIRO

Monografia apresentada ao Curso de Engenharia de Produção da Universidade Federal de Ouro Preto como parte dos requisitos para a obtenção do Grau de Engenheiro de Produção.

Universidade Federal de Ouro Preto

Orientador: Prof. Dr. Magno Silvério Campos

Ouro Preto  
2024



## FOLHA DE APROVAÇÃO

**Kamila de Oliveira Superbi**

### **Modelos de Séries Temporais: uma análise das admissões do trabalho formal brasileiro**

Monografia apresentada ao Curso de Engenharia de Produção da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Engenheira de Produção

Aprovada em 02 de outubro de 2024.

Membros da banca

Prof.º Dr.º **Magno Silvério Campos** - Orientador - Universidade Federal de Ouro Preto

Me. **Renato Fernandes Ferreira** - Examinador Convidado - Universidade Federal de Ouro Preto

Prof. Me. **Cristiano Luís Turbino de Franca e Silva** - Examinador Convidado - Universidade Federal de Ouro Preto

Magno Silvério Campos, orientador do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 07/10/2024.



Documento assinado eletronicamente por **Magno Silverio Campos, PROFESSOR DE MAGISTERIO SUPERIOR**, em 07/10/2024, às 18:36, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Renato Fernandes Ferreira, COORDENADOR(A) DE GOVERNANÇA E PROCESSOS ORGANIZACIONAIS**, em 07/10/2024, às 19:38, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Cristiano Luis Turbino de Franca e Silva, PROFESSOR DE MAGISTERIO SUPERIOR**, em 07/10/2024, às 20:44, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site [http://sei.ufop.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **0787624** e o código CRC **4E58EAEC**.

Dedico este trabalho aos meus pais, Maria e Reinaldo. Vocês foram pilares essenciais em cada etapa deste caminho, sempre me apoiando e incentivando. Este trabalho é, em grande parte, um reflexo de tudo o que sempre me proporcionaram.

## Agradecimentos

Agradeço a Deus por este momento tão desejado, sempre me concedendo forças e sabedoria ao longo de toda a minha trajetória acadêmica e pessoal.

Aos meus tios, Conceição, Toninho e Maurício, sou profundamente grata por todo o carinho, apoio e incentivo nos momentos mais desafiadores.

Aos meus amigos, a minha irmã, Ingrid que me apoiou e me encorajou, ao meu orientador, Magno Silvério Campos e a todos que, de alguma forma, contribuíram para a realização deste trabalho.

*“Não há limites para o que você pode alcançar, exceto os limites que você impõe a sua própria mente.”*

*Napoleon Hill*

## Resumo

Esta monografia busca aplicar modelos de séries temporais para analisar e prever admissões no mercado de trabalho formal brasileiro, utilizando dados do Cadastro Geral de Empregados e Desempregados (CAGED). O objetivo do estudo é identificar o modelo de previsão mais adequado para capturar tendências e padrões nas admissões de trabalhadores ao longo do tempo. Foram analisados vários modelos de séries temporais, incluindo médias móvel dupla, ajuste exponencial duplo, e o modelo de Holt-Winters, com a eficácia dos métodos determinada por medidas de acurácia. A pesquisa cobriu um período de 240 meses, compreendido entre janeiro de 2004 a dezembro de 2023, de modo a garantir uma análise abrangente e detalhada das flutuações e tendências que ocorrem no mercado de trabalho.

**Palavras-chave:** CAGED. Séries Temporais. Modelos de Previsão. MSD. Previsão.

## Abstract

This monograph seeks to apply time series models to analyze and forecast employment admissions in the Brazilian formal labor market, using data from the General Register of Employed and Unemployed (CAGED). The study aims to identify the most suitable forecasting model to capture trends and patterns in worker admissions over time. Several time series models were analyzed, including double moving averages, double exponential smoothing, and the Holt-Winters model, with the effectiveness of the methods determined by accuracy measures. The research covered a period of 240 months, from January 2004 to December 2023, ensuring a comprehensive and detailed analysis of the fluctuations and trends occurring in the labor market.

**Keywords:** CAGED. Time Series. Forecasting Models. MSD. Forecasting



## Lista de abreviaturas e siglas

CAGED	Cadastro Geral de Empregados e Desempregados
CLT	Consolidação das Leis do Trabalho
MAD	Mean Absolute Deviation (Desvio Absoluto Médio)
MAPE	Mean Absolute Percentage Error (Erro Percentual Médio Absoluto )
MSD	Mean Squared Deviation (Desvio Quadrático Médio)
PIB	Produto Interno Bruto
RMSD	Root Mean Squared Deviation (Raiz do Desvio Quadrático Médio)
ST	Série Temporal

# Sumário

1	INTRODUÇÃO . . . . .	10
2	REFERENCIAL TEÓRICO . . . . .	12
2.1	A Consolidação das Leis do Trabalho e o Cadastro Geral de Empregados e Desempregados . . . . .	12
2.2	Séries Temporais . . . . .	13
2.2.1	Objetivos e Componentes das Séries Temporais . . . . .	13
2.2.2	Modelos de Séries Temporais . . . . .	14
2.2.3	Medidas de Precisão . . . . .	15
2.2.4	Métodos Estacionários de Previsão . . . . .	16
2.2.4.1	Médias Móveis Simples . . . . .	16
2.2.4.2	Médias Móveis Ponderadas . . . . .	17
2.2.4.3	Ajuste Exponencial Simples . . . . .	18
2.2.4.4	Sazonalidade . . . . .	19
2.2.4.5	Efeitos Sazonais Aditivos . . . . .	19
2.2.4.6	Efeitos Sazonais Multiplicativos . . . . .	21
2.2.5	Métodos Não Estacionários de Previsão . . . . .	22
2.2.5.1	Média Móvel Dupla . . . . .	22
2.2.5.2	Ajuste Exponencial Duplo . . . . .	23
2.2.5.3	Método de Holt-Winter para efeitos sazonais . . . . .	24
2.2.5.4	Método de Holt-Winter para Efeitos Sazonais Aditivos . . . . .	24
2.2.5.5	Método de Holt-Winter para Efeitos Sazonais Multiplicativos . . . . .	25
2.2.6	Índices Sazonais e Refino dos Índices Sazonais . . . . .	26
2.3	Normalização de Dados . . . . .	26
3	METODOLOGIA . . . . .	27
4	APRESENTAÇÃO E DISCUSSÃO DOS RESULTADOS . . . . .	28
4.1	Aplicação do Método Média Móvel Dupla . . . . .	29
4.2	Aplicação do Método Ajuste Exponencial Duplo . . . . .	30
4.3	Aplicação do Método de Holt-Winter para Efeitos Sazonais Aditivos . . . . .	32
4.4	Aplicação do Método de Holt-Winter para Efeitos Sazonais Mutiplicativos . . . . .	35
4.5	Aplicação dos Índices e Refino dos Índices Sazonais . . . . .	39
4.6	Resultados . . . . .	42
5	CONCLUSÕES E CONSIDERAÇÕES FINAIS . . . . .	44

REFERÊNCIAS . . . . .	45
<b>ANEXOS</b>	<b>47</b>
ANEXO A – BASE DE DADOS . . . . .	48
ANEXO B – DECLARAÇÃO . . . . .	55

# 1 Introdução

O trabalho desempenha um papel central na sociedade, sendo essencial tanto pelo meio de subsistência quanto um indicador fundamental do bem-estar econômico e social de um país. Além de se tratar de uma fonte de renda, é a base para o acesso a serviços essenciais, dignidade e qualidade de vida. Em uma economia dinâmica, as condições do mercado de trabalho podem mudar rapidamente, influenciadas por fatores como recessão econômica, crises financeiras ou outras situações adversas que afetam a criação e a disponibilidade de empregos, como o caso da Covid-19, que, devido às medidas de distanciamento social, que reduziram significativamente as atividades econômicas, levando ao fechamento de muitos estabelecimentos comerciais e à consequente queda nas admissões no mercado de trabalho.

Nesse contexto, compreender a estrutura do emprego é fundamental para que decisões de curto e médio prazo possam ser tomadas, adaptando-se às condições do mercado de trabalho e antecipando-se a cenários desfavoráveis. A busca por dados sobre o mercado de trabalho e sua evolução do emprego ao longo dos anos se tornam essenciais para mostrar uma visão clara e precisa da realidade atual.

O Cadastro Geral de Empregados e Desempregados (CAGED), criado pela Lei nº 4923, de 23 de dezembro de 1965, desempenha um papel crucial ao monitorar e fiscalizar as movimentações de admissão e demissão dos trabalhadores, conforme as normas estabelecidas pela Consolidação das Leis Trabalhistas (MTE, 2017). Essa ferramenta permite análises relevantes para a economia nacional, contribuindo para uma melhor compreensão das flutuações do mercado de trabalho formal brasileiro ao longo do tempo.

Nesse sentido, discutir sobre modelos de previsão de séries temporais aplicados às admissões no mercado de trabalho formal brasileiro se mostra relevante. Compreender e prever as admissões de trabalhadores é vital para garantir oportunidades de emprego e o crescimento econômico sustentável. Através dos dados, é possível realizar uma análise do comportamento do mercado de trabalho e das evoluções do emprego ao longo dos anos, favorecendo na tomada de decisões e o desenvolvimento do país. Isso possibilita identificar períodos de crescimento e retração, através de comparações anuais, mensais e semestrais, para discernir padrões e tendências cruciais.

Diante desse cenário, o enfoque desta monografia é propor uma análise para a seguinte problemática de pesquisa: Qual modelo de previsão de séries temporais é mais adequado para analisar e prever as tendências e padrões nas admissões de empregados no mercado de trabalho formal brasileiro ao longo do tempo? Neste sentido, o objetivo geral do estudo é identificar o modelo que melhor se ajusta a essa finalidade, proporcionando previsões mais precisas e confiáveis sobre o comportamento das admissões ao longo do tempo.

Para alcançar este objetivo, estabelecem-se, ainda, os seguintes objetivos específicos:

- 1 Coletar os dados das admissões de empregados no mercado de trabalho formal brasileiro;
- 2 Realizar uma análise estatística dos dados para identificar a existência ou não de tendências, sazonalidades, verificando seu comportamento ao longo do tempo;
- 3 Aplicar os modelos de previsão de séries temporais, considerando métricas de erro e identificar o modelo de previsão que melhor se ajusta aos dados de admissões de empregados.

Para o efetivo desenvolvimento dos objetivos específicos adotados, optou-se pela realização de uma pesquisa aplicada de caráter descritivo e abordagem quantitativa, com levantamento de dados baseado em fontes primárias e secundárias, proporcionando um aprofundamento das técnicas utilizadas.

## 2 Referencial teórico

Compreender o conceito e os modelos de séries temporais é o primeiro passo para analisar o comportamento das admissões no mercado de trabalho formal brasileiro ao longo dos anos. Para isso, primeiramente, serão apresentados uma breve introdução sobre a Consolidação das Leis do Trabalho (CLT) e sua relação com o Cadastro Geral de Empregados e Desempregados (CAGED). Em seguida, será abordado o conceito de uma série temporal (ST), bem como seus objetivos, componentes e métodos de previsão, examinando se são estacionárias, não estacionárias, com e sem sazonalidade, aspectos relevantes para o desenvolvimento deste trabalho.

### 2.1 A Consolidação das Leis do Trabalho e o Cadastro Geral de Empregados e Desempregados

O mercado de trabalho formal brasileiro é regido por um conjunto de leis e diretrizes que buscam garantir direitos e as responsabilidades dos empregados e empregadores. A Consolidação das Leis do Trabalho (CLT), instituída pela Lei nº 5.452, de 1º de maio de 1943, é o principal instrumento legalizado que regula as relações de trabalho no Brasil. Ela estabelece direitos e deveres para ambas as partes, abrangendo aspectos fundamentais como jornada de trabalho, remuneração, férias e segurança no ambiente laboral. A principal função da CLT é promover um ambiente de trabalho justo, que proteja os direitos dos trabalhadores e garantindo condições adequadas para o desempenho das atividades laborais (BRASIL, 1943).

Antes da criação da CLT, a história do trabalho no Brasil era marcada por condições precárias e pela falta de regulamentação. A rápida industrialização e o crescimento urbano no início do século XX trouxeram novos desafios e conflitos entre trabalhadores e empregadores, evidenciando a necessidade urgente de uma legislação específica. O contexto histórico era de busca por justiça social e proteção aos trabalhadores, que enfrentavam jornadas extenuantes, baixos salários e condições de trabalho insalubres (NASCIMENTO; NASCIMENTO, 2018).

O Cadastro Geral de Empregados e Desempregados (CAGED), criado pela Lei nº 4.923 de 23 de dezembro de 1965, complementa a CLT ao fornecer um sistema detalhado para o registro das admissões e demissões de trabalhadores no mercado formal. Este registro é atualizado mensalmente pelos empregadores e enviado ao Ministério do Trabalho, formando uma base de dados essencial. Os dados do CAGED são fundamentais para o desenvolvimento de políticas públicas relacionadas ao emprego e ao salário, além de servir como base para pesquisas e análises sobre o mercado de trabalho (MTE, 2017).

## 2.2 Séries Temporais

Por definição, uma série temporal (ST) é um conjunto de valores tomados em instantes específicos de tempo. A hipótese básica é que a tendência dos valores anteriores pode ser usada para realizar previsões dos valores no futuro. Isso permite analisar como os dados mudam com o passar dos dias, semanas, meses ou até anos. Em outras palavras, ao observar os valores anteriores de uma série de dados, é possível ter uma ideia da direção em que ela seguirá. Nesse sentido, é possível reconhecer tendências e variações sazonais no nível de demanda de produtos ou serviços (MOREIRA, 2012).

Para Souza et al. (2021)[p. 11], as análises de séries temporais podem ser empregadas em diversos campos, incluindo a economia, monitoramento dos indicadores do Produto Interno Bruto (PIB), oferta e demanda, bem como outras aplicações, desempenhando também um papel fundamental no acompanhamento de fenômenos naturais, nas análises demográficas, estratégias de marketing e nas áreas de controle de qualidade e saúde.

### 2.2.1 Objetivos e Componentes das Séries Temporais

De acordo com Morettin e Tolo (2018)[p. 3], os objetivos de uma ST incluem:

- 1 Compreender a origem da ST: Isso envolve investigar a causa por trás da ST com o objetivo de entender como os dados foram gerados;
- 2 Realizar previsões futuras: Capacidade de fazer previsões para valores futuros da série, seja em curto ou longo prazo;
- 3 Descrever o comportamento da série: Descrever o comportamento da ST ao longo do tempo, verificando a existência de tendências, padrões cíclicos e variações sazonais;
- 4 Identificar periodicidades relevantes: Identificar padrões que se repetem em intervalos regulares, trazendo informações relevante aos dados..

Já para Moreira (2012), uma ST pode ser distinguida através de quatro comportamentos:

- 1 **Tendência:** Mudança sistemática e longo prazo nas observações ao longo do tempo, podendo ser crescente ou decrescente. Caso contrário, as observações são estacionárias, isto é, variando em torno de um valor médio
- 2 **Sazonalidade:** Corresponde as variações ou comportamentos semelhantes em períodos específicos de tempo;
- 3 **Ciclo de Negócios:** Refere-se a padrões altos e baixos na economia de um país, além de serem influenciados por muitos fatores complexos e de difícil previsão;

- 4 **Variações Irregulares:** variações muitas vezes imprevisíveis e aleatórias, também conhecidas como resíduos.

### 2.2.2 Modelos de Séries Temporais

Para realizarmos previsões das ST's, é fundamental identificar os modelos que se ajustam de maneira mais eficaz às flutuações e padrões observados ao longo do tempo. Essa identificação requer uma análise cuidadosa do comportamento dos dados. Os modelos de séries temporais contribuem significativamente para a realização de previsões mais assertivas, buscando aproximar-se ao máximo da realidade dos dados (SOUZA et al., 2021).

A fórmula geral de um modelo de previsão de série temporal, também chamada de extrapolação, é dada através da equação 2.1.

$$\hat{y}_{t+1} = f(y_t, y_{t-1}, y_{t-2}, \dots) + \varepsilon \quad (2.1)$$

Onde:

$\hat{y}_{t+1}$  indica o valor previsto para a variável no período  $t+1$ ;

$y_t$  representa o valor real no período de tempo  $t$ ;

$y_{t-1}$  representa o valor real no período  $t-1$ , e assim por diante;

$\varepsilon$  representa o erro aleatório.

De tal forma que o erro deve seguir a premissa apresentada na equação 2.2.

$$\varepsilon \sim NID(0, \sigma^2) \quad (2.2)$$

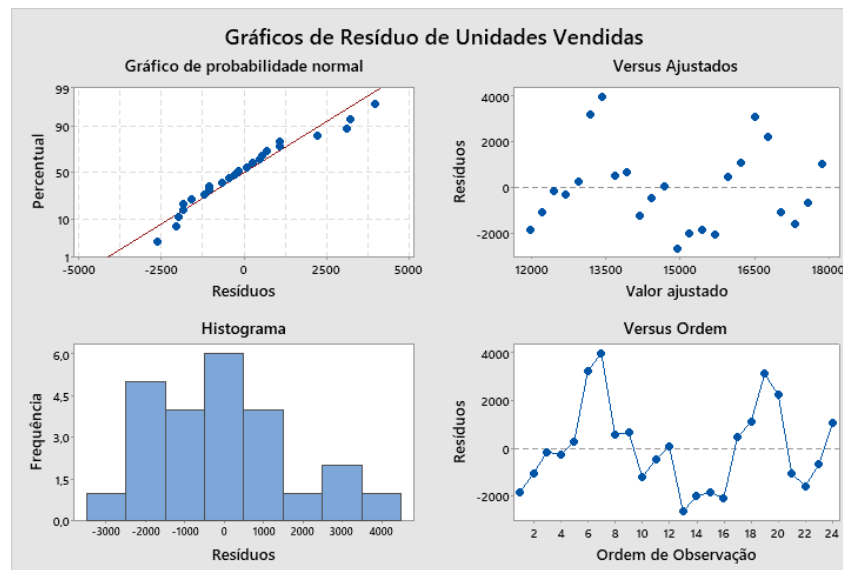
Em outras palavras, o erro deve seguir uma distribuição normal, ser independente, com média zero e variância constante. Essa premissa deve ser levada em consideração em todos os métodos de previsão, independentemente da presença ou ausência de tendências e sazonalidades. Quando satisfeito, podemos concluir que, para o modelo de previsões de séries temporais utilizado, a premissa é estabelecida (CAMPOS, 2022).

Uma maneira de realizar a verificação da premissa é através da análise residual, exemplificada na figura 1, onde utilizam-se os seguintes gráficos:

- 1 **Gráfico de Probabilidade Normal:** utilizado para verificar se os resíduos são normalmente distribuídos;
- 2 **Gráfico Resíduos vs Ajustados:** utilizado para verificar se os resíduos possuem variância constante;
- 3 **Histograma:** utilizado para determinar se os dados são assimétricos;
- 4 **Gráfico Resíduos vs Ordem:** utilizado para verificar se os resíduos não são correlacionados, isto é, são independentes.



Figura 1 – Gráfico 4 em 1 para análise residual.



Fonte: Adaptado de Campos, 2022.

### 2.2.3 Medidas de Precisão

Segundo Ragsdale (2021)[p. 461], existem muitos métodos disponíveis para a modelagem das ST's, porém, torna-se necessário identificar qual o modelo será o adequado, respeitando o comportamento dos dados ao longo do tempo. Para isso, utiliza-se a acurácia. As medidas de acurácia servem para verificar se dentro do conjunto de previsões, o erro de previsão é pequeno. Nesse sentido, o melhor modelo de ST será o que apresentar o menor erro de previsão. Em outras palavras, quanto menor o erro, mais assertivo será o modelo de ST. “Erro de previsão é caracterizado pela diferença entre os valores previstos e os valores efetivos e demanda realizados no período.”(FORNO et al., 2013).

Para Ragsdale (2021), quatro medidas de precisão são comuns para as modelagens das ST's:

1 Desvio Absoluto Médio (MAD):

$$\frac{1}{n} \cdot \sum_{i=1}^n |y_i - \hat{y}_i| \quad (2.3)$$

2 Erro Percentual Médio Absoluto (MAPE):

$$\frac{100}{n} \cdot \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i} \quad (2.4)$$

3 Desvio Quadrático Médio (MSD):

$$\frac{1}{n} \cdot \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.5)$$

4 Raiz do Desvio Quadrático Médio (RMSD):

$$\sqrt{MSD} \quad (2.6)$$

Para cada uma das medidas de precisão apresentadas acima,  $y_i$  representa o valor real correspondente à  $i$ -ésima observação, enquanto  $\hat{y}_i$  representa o valor previsto para essa observação.

## 2.2.4 Métodos Estacionários de Previsão

Compreende-se a estacionariedade de uma série temporal quando o conjunto de dados é distribuído aleatoriamente em torno de uma média constante sem apresentar tendência ao longo do tempo (GUTIERREZ, 2003).

Quando o comportamento dos dados apresenta estacionariedade, os métodos de séries temporais adequados para realizar previsões futuras englobam: médias móveis, médias móveis ponderadas, ajuste exponencial, efeitos sazonais aditivos e efeitos sazonais multiplicativos.

### 2.2.4.1 Médias Móveis Simples

A técnica de médias móveis é considerada um método simples e eficaz para realizar a extrapolação de dados estacionários nas ST. Esse método de previsão é utilizado para suavizar os dados, uma vez que quanto mais pontos de dados anteriores são utilizados para calcular a média, mais suave será sua previsão. Além disso, o método calcula a média das observações recentes, excluindo as observações mais antigas, fornecendo previsões de curto prazo. Nesse sentido, o valor previsto da série temporal no período  $t+1$ , é a média das  $k$  observações mais recentes na série (CAMPOS, 2022; RAGSDALE, 2021).

Com base nas informações acima, obtemos a expressão apresentada na equação 2.7.

$$\hat{y}_{t+1} = \frac{(y_{t-k+1} + y_{t-k+2} + \dots + y_{t-1} + y_t)}{k} \quad (2.7)$$

O valor de  $k$  na equação acima representa o número de observações prévias que serão incluídas nas médias móveis. Embora seja um método simples, de fácil entendimento e implementação, o modelo de médias móveis apresenta algumas limitações. Entre as desvantagens desse método, (DIAS, 2023) ressalta que todas as observações, independentemente de serem antigas ou atuais, possuem o mesmo peso, isto é,  $\frac{1}{n}$ . O método de médias móveis deve ser utilizado apenas para dados estacionários, em outras palavras, esse modelo não deve ser utilizado quando a série de dados apresentar tendências ou padrão sazonal (CAMPOS, 2022).

### 2.2.4.2 Médias Móveis Ponderadas

Conforme citado anteriormente, uma desvantagem do modelo de médias móveis é que os dados antigos e atuais são igualmente ponderados. O método de médias móveis ponderadas representa uma variação do modelo anterior, suprindo esse déficit ao atribuir pesos aos dados usados para o cálculo das médias (RAGSDALE, 2021).

A função de previsão do método de médias móveis ponderadas é dada pela equação 2.8.

$$\hat{y}_{t+1} = \frac{(w_k \cdot y_{t-k+1} + w_{k-1} \cdot y_{t-k+2} + \dots + w_2 \cdot y_{t-1} + w_1 \cdot y_t)}{\sum_{i=1}^k w_i} \quad (2.8)$$

Onde:

- $0 \leq w_i \leq 1$ ;
- $\sum_{i=1}^k w_i = 1$ .

Da mesma forma que o modelo de médias móveis, esse método não deve ser utilizado quando a série de dados apresentar tendências ou padrão sazonal (CAMPOS, 2022). Após determinar o valor de  $k$  observações, torna-se necessário também determinar os valores para os pesos  $w_i$  da equação 2.8. Para isso, uma das técnicas utilizadas adotadas é a utilização do *Solver* do Microsoft Excel<sup>®</sup>. Os valores de  $w_i$  escolhidos, serão os que minimizarem o MSD, descrita na equação 2.5. A figura 2 abaixo ilustra o caso.

Figura 2 – Implementação do *Solver* no modelo de médias móveis ponderadas

Pesos	
$w_1$	0,741212882
$w_2$	0,258787118
Soma	1
MSD	3,78E+09

Fonte: Adaptado de Campos, 2022.

### 2.2.4.3 Ajuste Exponencial Simples

O método de ajuste exponencial, ou suavização exponencial, é uma técnica também utilizada para os dados estacionários e que não apresentam padrões sazonais. Essa abordagem permite que os pesos decrescentes sejam atribuídos aos dados passados, valorizando os dados mais recentes (RAGSDALE, 2021).

A função de ajuste exponencial simples assume a fórmula expressa na equação 2.9.

$$\hat{y}_{t+1} = \hat{y}_t + \alpha(y_t - \hat{y}_t) \quad (2.9)$$

Onde:

- $\alpha$  é um parâmetro que pode assumir qualquer valor entre 0 e 1, isto é  $0 \leq \alpha \leq 1$ .

Valores menores de  $\alpha$  resultam em suavização mais intensa da série, o que leva a previsões mais lentas, que demoram a reagir às mudanças nos dados. Por outro lado, valores maiores de  $\alpha$  atribuem mais peso aos valores mais recentes, resultando em previsões mais rápidas e sensíveis às mudanças (RAGSDALE, 2021).

Assim como no modelo anterior, é possível utilizar o *Solver* no método de ajuste exponencial simples para determinar o valor ótimo de  $\alpha$  e minimizar o MSD. Um exemplo de aplicação é demonstrado na figura 3 abaixo, onde foram utilizados os parâmetros de  $\alpha$  e a fórmula geral do método adotado.

Figura 3 – Implementação do *Solver* para o método de ajuste exponencial simples

Pesos	
$\alpha$	0,268

MSD	7,49
-----	------

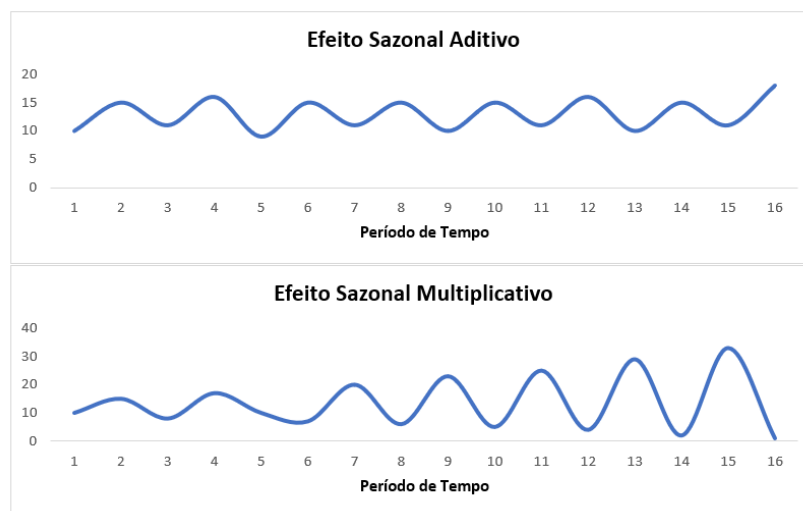
Fonte: Adaptado de Ragsdale, 2021.

#### 2.2.4.4 Sazonalidade

A sazonalidade em uma série temporal acontece quando a mesma é impactada por fatores que seguem um padrão previsível, como semestres ou dias específicos do ano, sendo esses períodos sempre identificáveis (DOWNING; CLARK, 2006). No mercado de trabalho, a sazonalidade refere-se aos padrões recorrentes nas variações no número de contratações ao longo do tempo, por exemplo.

Para Martin et al. (2015), o fator sazonal pode ser aditivo ou multiplicativo. No caso do efeito sazonal aditivo, a série exibe uma flutuação constante, independentemente do nível médio da série. Por outro lado, o efeito sazonal multiplicativo indica que os dados apresentam uma ordem de magnitude que cresce ou decresce ao longo do tempo. A figura 4 abaixo ilustra um exemplo de efeitos sazonais aditivos e multiplicativos para os dados estacionários.

Figura 4 – Efeitos sazonais aditivos e multiplicativos para dados estacionários



Fonte: Adaptado de Ragsdale, 2021.

#### 2.2.4.5 Efeitos Sazonais Aditivos

O modelo de efeitos sazonais aditivos para dados estacionários é dado através equação 2.10.

$$\hat{y}_{t+n} = e_t + s_{(t+n-p)} \quad (2.10)$$

Onde:

- $e_t$  representa o nível esperado da série temporal no período  $t$  e é calculado através da equação 2.11.

$$e_t = \alpha(y_t - s_{t-p}) + (1 - \alpha)e_{t-1} \quad (2.11)$$

- $s_t$  representa o fator sazonal para o período  $t$  e é calculado através da equação 2.12.

$$e_t = \beta(y_t - e_t) + (1 - \beta)s_{t-p} \quad (2.12)$$

- $p$  representa o número de períodos sazonais presentes nos dados;
- $\alpha$  e  $\beta$  são fatores de ponderação.

Segundo Ragsdale (2021), para utilizar as equações descritas acima, primeiramente, torna-se necessário inicializar os níveis estimados e os fatores sazonais para os primeiros  $p$  períodos de tempo. Dessa forma, temos que:

$$e_t = \sum_{i=1}^p \frac{y_i}{p} \quad (2.13)$$

$$s_t = y_t - e_t \quad (2.14)$$

De acordo com Campos (2022), é possível utilizar o Solver do Excel<sup>®</sup> a fim de determinar os valores de  $\alpha$  e  $\beta$  que minimizam o MSD. Para isso, o modelo de otimização não-linear da equação 2.15 é aplicado.

Minimizar a MSD:

$$\frac{1}{n^*} \cdot \sum_{t=1^*}^n (y_t - \hat{y}_t)^2 \quad (2.15)$$

Sujeito a:

- $\alpha \leq 1$ ;
- $\beta \leq 1$ ;
- $\alpha \geq 0$ ;
- $\beta \geq 0$ ;

Onde:

- $1^*$  representa o primeiro instante onde existe valores para a previsão e o valor real;
- $n^*$  representa o total de observações atualizado.

A figura 5 demonstra a implementação do *Solver* para o método aplicado.

Figura 5 – Implementação do *Solver* para o método de Efeitos Sazonais Aditivos

Pesos	
$\alpha$	0,577
$\beta$	0,277
<b>MSD</b>	<b>304,43</b>

Fonte: Adaptado de Campos, 2022

### 2.2.4.6 Efeitos Sazonais Multiplicativos

O modelo de efeitos sazonais multiplicativos para dados estacionários é dado através da expressão 2.16.

$$\hat{y}_{t+n} = e_t \cdot s_{(t+n-p)} \quad (2.16)$$

Onde:

- $e_t = \alpha(y_t/s_{t-p}) + (1-\alpha)e_{t-1}$ ;
- $s_t = \beta(y_t/e_t) + (1-\beta)s_{t-p}$ ;
- $0 \leq \alpha \leq 1$ ;
- $0 \leq \beta \leq 1$ ;

Para o modelo acima,

- $e_t$  representa o nível esperado da série temporal no período  $t$ ;
- $s_t$  representa o fator sazonal para o período  $t$ ;
- $p$  representa o número de períodos sazonais presentes nos dados;
- $\alpha$  e  $\beta$  são fatores de ponderação;

Para utilizar as equações descritas acima, é necessário inicializar os níveis estimados e os fatores sazonais para os primeiros  $p$  períodos de tempo. Dessa forma, temos que:

$$e_t = \sum_{i=1}^p \frac{y_i}{p} \quad (2.17)$$

$$s_t = y_t/e_t \quad (2.18)$$

Segundo Campos (2022), é possível utilizar o Solver do Excel<sup>®</sup> a fim de determinar os valores de  $\alpha$  e  $\beta$  que minimizam o MSD através do modelo de otimização não linear. Para o método de efeitos sazonais multiplicativos, a equação 2.15 também pode ser aplicada.

### 2.2.5 Métodos Não Estacionários de Previsão

Uma série não estacionária é uma sequência de valores ao longo do tempo que não possui uma média constante, variância constante e autocovariância constante. Em termos mais técnicos, uma série temporal é não estacionária se suas propriedades estatísticas mudam com o tempo (MORETTIN; TOLOI, 2018).

De acordo com Latorre e Cardoso (2001), uma série temporal pode ser considerada não estacionária em duas situações: quando os pontos oscilam em torno de uma média por um período e, posteriormente, mudam de nível; e quando a série apresenta não estacionariedade em relação à tendência, ou seja, a série tem uma tendência crescente ou decrescente ao longo do tempo, em vez de oscilar em torno de uma média fixa.

Para as séries não estacionárias, os métodos de séries temporais adequados para realizar previsões futuras englobam: Média Móvel Dupla, Ajuste Exponencial Duplo, Método de Holt-Winter para Efeitos Sazonais Aditivos e Método de Holt-Winter para Efeitos Sazonais Multiplicativos.

#### 2.2.5.1 Média Móvel Dupla

A média móvel dupla consiste em aplicar duas vezes a média móvel simples (RAGSDALE, 2021). Primeiramente, é calculado a média móvel para os  $k$  períodos de tempo passados, conforme a equação 2.19.

$$M_t = \frac{y_t + y_{t-1} + y_{t-2} + \dots + y_{(t-k+1)}}{k} \quad (2.19)$$

Em seguida, é realizado o cálculo da média das médias móveis, para os  $k$  períodos de tempo, representado pela equação 2.20.

$$D_t = \frac{M_t + M_{t-1} + M_{t-2} + \dots + M_{(t-k+1)}}{k} \quad (2.20)$$

A função de previsão para a média móvel dupla é dada pela equação 2.21.



$$\hat{y}_{t+n} = E_t + nT_t \quad (2.21)$$

Onde o nível estimado  $E_t$  e a tendência  $T_t$  calculada da série no período  $t$  são, respectivamente, representados nas equações 2.22 e 2.23.

$$E_t = 2M_t - D_t \quad (2.22)$$

$$T_t = \frac{2(M_t - D_t)}{k - 1} \quad (2.23)$$

### 2.2.5.2 Ajuste Exponencial Duplo

Quando o modelo de suavização exponencial simples é utilizado para prever séries temporais que exibem tendência nas observações anteriores, a precisão das previsões pode ser comprometida. Isso acontece devido ao modelo simples não acomodar a tendência presente nos dados, resultando em erros previsíveis. Diante disso, o método ajuste exponencial duplo, também conhecido como método de Holt é utilizado em séries temporais que possuem tendência linear, sem um padrão sazonal (BIUDES et al., 2009).

A função de previsão para o método de ajuste exponencial duplo é representada na equação 2.24.

$$\hat{y}_{t+n} = E_t + nT_t \quad (2.24)$$

Onde:

- $E_t = \alpha y_t + (1-\alpha)(E_{t-1} + T_{t-1})$ ;
- $T_t = \beta(E_t - E_{t-1}) + (1-\beta)T_{t-1}$ ;
- $0 \leq \alpha \leq 1$ ;
- $0 \leq \beta \leq 1$ ;

Para o modelo acima, temos que:

- $E_t$  representa o nível estimado da série temporal no período  $t$ ;
- $T_t$  representa a influência esperada da tendência  $t$ ;
- $\alpha$  e  $\beta$  são fatores de ponderação.

De acordo com Ragsdale (2021), uma prática simples e muito adotada como critério de inicialização é considerar, para  $t=1$ :

$$E_1 = y_1 \quad (2.25)$$

$$T_1 = 0 \quad (2.26)$$

Da mesmo modo que o modelo de efeitos sazonais aditivos e multiplicativos, o valor de  $\alpha$  e  $\beta$  a serem utilizados nas previsões serão os que minimizarem o MSD. O modelo de otimização não linear para o método de ajuste exponencial duplo segue a mesma forma apresentada na equação 2.15.

### 2.2.5.3 Método de Holt-Winter para efeitos sazonais

O método de Holt-Winter para efeitos sazonais é aplicado em séries temporais que exibem tanto tendência (crescente ou decrescente) quanto sazonalidade. A série é marcada por padrões cíclicos de variação que ocorrem repetidamente em intervalos definidos (RAGSDALE, 2021).

Os modelos de Winters são divididos em dois tipos: aditivo e multiplicativo. No modelo aditivo, a variação sazonal mantém uma amplitude constante ao longo do tempo, significando que a diferença entre o pico e o vale da demanda dentro das estações permanece relativamente estável. Por outro lado, no modelo multiplicativo, a amplitude da variação sazonal varia conforme o tempo, aumentando ou diminuindo ao longo do período analisado (PELLEGRINI, 2000).

### 2.2.5.4 Método de Holt-Winter para Efeitos Sazonais Aditivos

O método de Holt-Winters para efeitos sazonais aditivos é utilizado em séries temporais que apresentam uma sazonalidade com amplitude constante, independentemente do nível da série ao longo do tempo. Em outras palavras, a diferença entre os valores máximos e mínimos da demanda dentro de cada estação permanece estável (VERÍSSIMO et al., 2012).

A função de previsão é dada pela equação 2.27.

$$\hat{y}_{t+n} = E_t + nT_t + S_{(t+n-p)} \quad (2.27)$$

Onde:

- $E_t = \alpha(y_t - S_{t-p}) + (1-\alpha)(E_{t-1} + T_{t-1});$
- $T_t = \beta(E_t - E_{t-1}) + (1-\beta)T_{t-1};$
- $S_t = \gamma(y_t - E_t) + (1-\gamma)S_{t-p};$
- $0 \leq \alpha, \beta, \gamma \leq 1;$
- $p$  representa o valor sazonal da amostra.

Segundo Ragsdale (2021), o método de Holt-Winter consiste basicamente em quatro etapas:

1. Calcular o nível estimado  $E_t$  para o período de tempo  $t$ ;
2. Calcular o valor da tendência estimada  $T_t$  para o período de tempo  $t$ ;
3. Calcular o fator sazonal  $S_t$  para o período  $t$ ;
4. Calcular a previsão final.

De acordo com Campos (2022), os valores de  $\alpha$ ,  $\beta$  e  $\gamma$  a serem escolhidos, serão os que minimizam o MSD. Deste modo, é estabelecido o seguinte modelo de otimização não linear representado na equação 2.28.

Minimizar a MSD:

$$\frac{1}{n^*} \cdot \sum_{t=1^*}^n (y_t - \hat{y}_t)^2 \quad (2.28)$$

Sujeito a:

- $\alpha, \beta, \gamma \leq 1$ ;
- $\alpha, \beta, \gamma \geq 0$ ;

Onde:

- $1^*$  representa o primeiro instante onde existe valores para a previsão e o valor real;
- $n^*$  representa o total de observações atualizado;
- $\hat{y}_{t+1} = E_t + 1T_t + S_{(t+1-p)}$ .

### 2.2.5.5 Método de Holt-Winter para Efeitos Sazonais Multiplicativos

O método de Holt-Winter para efeitos sazonais multiplicados é empregado nas séries temporais sazonais em que a amplitude da variação sazonal varia proporcionalmente ao nível da série ao longo do tempo (KOEHLER; SNYDER; ORD, 2001). Seu modelo é representado na equação 2.29.

$$\hat{y}_{t+n} = E_t + nT_t \times S_{(t+n-p)} \quad (2.29)$$

Onde:

- $E_t = \alpha(y_t/S_{t-p}) + (1-\alpha)(E_{t-1} + T_{t-1})$ ;
- $T_t = \beta(E_t - E_{t-1}) + (1-\beta)T_{t-1}$ ;
- $S_t = \gamma(y_t/E_t) + (1-\gamma)S_{t-p}$ ;
- $0 \leq \alpha, \beta, \gamma \leq 1$ ;

- $p$  representa o valor sazonal da amostra.

Assim como no método de Holt-Winters para efeitos sazonais aditivos, os valores de  $\alpha$ ,  $\beta$  e  $\gamma$  utilizados no método de Holt-Winters para efeitos sazonais multiplicativos são determinados de forma a minimizar o MSD (CAMPOS, 2022). Nesse sentido, o modelo de otimização não linear aplicado é o mesmo apresentado na equação 2.28.

### 2.2.6 Índices Sazonais e Refino dos Índices Sazonais

Para ajustar as previsões de tendência com maior precisão, são utilizados os índices sazonais. Esses índices são fatores multiplicativos que representam a variação percentual média das observações em cada estação em relação aos valores de tendência projetados. Para aprimorar ainda mais o método, adota-se o refino dos índices sazonais. Esse processo envolve a atualização e ajuste dos índices sazonais para refletir de forma mais precisa as variações observadas nos dados (RAGSDALE, 2021).

De acordo Campos (2022), os valores dos índices sazonais a serem utilizados nas previsões serão os que minimizarem o MSD. Para isso, o seguinte modelo de otimização não linear é aplicado:

Minimizar a MSD:

$$\frac{1}{n^*} \cdot \sum_{t=1}^n (y_t - \hat{y}_t)^2 \quad (2.30)$$

Sujeito a:

$$\frac{1}{p} \cdot \sum_{i=1}^p I_i = 100\% \quad (2.31)$$

Onde:

- $I_i$  representa o índice sazonal para cada estação;
- $\hat{y}_t = \hat{\beta}_0 + \hat{\beta}_1 t + \hat{\beta}_2 t^2$

### 2.3 Normalização de Dados

A normalização é um procedimento na análise de dados capaz de ajustar os valores para uma escala pré definida, realizando a substituição por valores entre 0 e 1, o que facilita a comparação entre os dados (LOPES, 2024). Um dos métodos empregados para a normalização de dados é o uso da técnica Min-Max, expressa pela equação 2.32.

$$X_{normalizado} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (2.32)$$

Onde  $X$  corresponde ao valor original dos dados,  $X_{min}$  indica o menor valor dentro do conjunto de dados e  $X_{max}$  o maior valor dos dados.

### 3 Metodologia

Uma das etapas necessárias para a elaboração do trabalho científico é a metodologia. Na pesquisa científica, a metodologia refere-se à abordagem, aos objetivos, aos procedimentos técnicos e à natureza do estudo, desempenhando um papel fundamental na definição da estrutura e dos métodos utilizados na pesquisa (VENANZI; SILVA, 2016).

O presente estudo consiste em pesquisa aplicada de caráter descritivo com o objetivo de identificar o modelo de previsão de séries temporais mais adequado para analisar e prever as tendências e padrões nas admissões de empregados no mercado de trabalho formal brasileiro ao longo do tempo. Os resultados foram apresentados de forma quantitativa, por meio de coleta de informações de fontes secundárias. O processo metodológico englobou, inicialmente, a revisão de literatura, para posteriormente alinhar essas informações às coletas de dados.

Como técnicas adotadas para essa pesquisa, estabeleceram-se critérios de inclusão que abrangeram os registros mensais de admissões de trabalho formal brasileiro, durante o período de janeiro de 2004 a dezembro de 2023. Isso incluiu a utilização de dados disponibilizados pelo Cadastro Geral de Empregados e Desempregados (CAGED), fornecidos pelo Ministério do Trabalho e Emprego (MTE) até dezembro de 2019, bem como os dados do novo CAGED a partir de janeiro de 2020 até dezembro de 2023.

A escolha desse intervalo de tempo levou em consideração a disponibilidade dos dados para a realização do estudo. Foram descartados quaisquer dados que não estivessem dentro do período mencionado, bem como informações de fontes distintas do CAGED ou no Novo CAGED. As informações utilizadas são de domínio público, conforme a Lei nº 4923 de 23/12/1965.


Os dados coletados foram organizados em uma planilha utilizando o *software* Microsoft Excel<sup>®</sup> 365 MSO (Versão 2406 Build 16.0.17726.20078) 64 bits, separados por duas colunas: uma para a data e outra para o quantitativo de admissões. Em seguida, os dados foram extraídos para o *software* estatístico Minitab<sup>®</sup> 22.1 (64-bit) com o objetivo de verificar o comportamento ao longo do tempo, verificando se há presença ou não de tendências e sazonalidades. Essa análise visa identificar quais modelos de previsão são os mais apropriados. Após a análise estatística do comportamento dos dados, procedeu-se para a identificação do modelo de previsão mais adequado, utilizando para este trabalho a medida de precisão MSD. O melhor modelo de previsão escolhido foi o que apresentou o menor MSD, indicando uma maior precisão nas previsões. Após a escolha do modelo, foi utilizado as técnicas de índice e refinamento dos índices sazonais, com o objetivo de melhorar a capacidade de modelagem e previsão do conjunto de dados desta pesquisa.

## 4 Apresentação e discussão dos resultados

Para o alcance dos objetivos da pesquisa, primeiramente, foi elaborado um gráfico de séries temporais referentes às admissões no mercado de trabalho formal brasileiro, abrangendo o período de janeiro de 2004 a dezembro de 2023, utilizando os dados dispostos na tabela 4 (Anexo A).

A figura 6 apresenta o gráfico das admissões versus o tempo (mês), e a linha de referência auxilia na verificação da oscilação dos dados em torno da linha central, permitindo verificar se os dados são ou não estacionários.

Figura 6 – Gráfico de Séries Temporais



Fonte: Elaborado pela autora.

Analisando a figura 6, nota-se que os valores da série não são distribuídos aleatoriamente em torno de um valor fixo, apresentando tendências, além de padrões de sazonalidade nos meses de dezembro ao longo dos anos. Portanto, conclui-se que os dados não são estacionários. Dessa forma, parte-se para o princípio de que os métodos de médias móveis, médias móveis ponderadas, ajuste exponencial, efeitos sazonais aditivos e efeitos sazonais multiplicativos não são os mais adequados para modelar o comportamento dos dados desta série temporal. Diante disso, seguem abaixo os métodos aplicados para esta série, levando em consideração a não estacionariedade dos dados e o menor valor de MSD.

### 4.1 Aplicação do Método Média Móvel Dupla

Para este método, inicialmente foi realizado o cálculo de  $M_t$  para os  $k$  períodos de tempo passados. Em seguida, foi calculada a média das médias móveis. O valor de  $k$  adotado para a equação foi 12, uma vez que a previsão será feita para o próximo ano, levando em consideração as 12 observações prévias.

Considera-se 1 como o número de admissões durante o período de janeiro de 2004 e 240 como o número de admissões em dezembro de 2023. O nível estimado a tendência também foram calculados a fim de obter o valor das previsões. Nota-se que, como foram utilizadas 12 observações prévias para o cálculo das médias, a primeira média móvel calculada foi no instante  $t=12$ . A mesma análise deve ser levada em consideração para o cálculo da média móvel dupla, do nível estimado, da tendência e da previsão.

Os cálculos adotados e o conjunto de dados foram passados para o Excel<sup>®</sup>, conforme apresentado na imagem 7, onde é possível observar que o MSD gerado foi de 3,353E+10.


Figura 7 – Recorte de Planilha: Aplicação do Método de Média Móvel Dupla

k		12		$M_t$		$D_t$		$E_t = 2M_t - D_t$		$T_t = \frac{2(M_t - D_t)}{k - 1}$		$\hat{y}_{t+1} = E_t + 1T_t$		$(y_t - \hat{y}_t)^2$		MSD
Ano	Mês	t	Admissões	Média Móvel	Média Móvel Dupla	Nível Estimado	Tendência	Previsão	Diferença							
2004	1	1	850.198	*	*	*	*	*	*							
	2	2	872.046	*	*	*	*	*	*							
	3	3	998.092	*	*	*	*	*	*							
	4	4	961.475	*	*	*	*	*	*							
	5	5	1.031.227	*	*	*	*	*	*							
	6	6	986.494	*	*	*	*	*	*							
	7	7	982.628	*	*	*	*	*	*							
	8	8	1.048.597	*	*	*	*	*	*							
	9	9	987.731	*	*	*	*	*	*							
	10	10	921.063	*	*	*	*	*	*							
	11	11	931.126	*	*	*	*	*	*							
	12	12	725.819	941.374,67	*	*	*	*	*							
2005	1	13	980.620	952.243,17	*	*	*	*	*							
	2	14	971.302	960.514,50	*	*	*	*	*							
	3	15	1.082.470	967.546,00	*	*	*	*	*							
	4	16	1.110.030	979.925,58	*	*	*	*	*							
	5	17	1.101.252	985.761,00	*	*	*	*	*							
	6	18	1.089.948	994.382,17	*	*	*	*	*							
	7	19	1.004.702	996.221,67	*	*	*	*	*							
	8	20	1.071.798	998.155,08	*	*	*	*	*							
	9	21	1.058.963	1.004.091,08	*	*	*	*	*							
	10	22	971.726	1.008.313,00	*	*	*	*	*							
	11	23	967.765	1.011.366,25	983.324,51	1.039.407,99	5.098,50									
	12	24	768.425	1.014.916,75	989.453,02	1.040.380,48	4.629,77	1.044.506,48	76.220.985.578,97							
2006	1	25	1.049.445	1.020.652,17	995.153,77	1.046.150,56	4.636,07	1.045.010,25	19.667.024,36							
	2	26	1.062.980	1.028.292,00	1.000.801,90	1.055.782,10	4.998,20	1.050.786,63	148.678.162,96							
	3	27	1.129.637	1.032.222,58	1.006.191,61	1.058.253,56	4.732,90	1.060.780,30	4.741.244.456,76							
	4	28	1.076.102	1.029.395,25	1.010.314,08	1.048.476,42	3.469,30	1.062.986,46	172.017.400,09							

Fonte: Elaborado pela autora.

Na figura 8 é apresentado as previsões para o método de média móvel dupla utilizando 12 observações prévias. Nota-se que o método de média móvel dupla tende a suavizar os dados, resultando em previsões mais estáveis e menos sujeitas a variações extremas. Em outras palavras, o método não acompanha as flutuações acentuadas dos picos e vales, mantendo as previsões mais próximas da linha central dos dados.

Figura 8 – Gráfico de Admissões x Previsão para o Método de Média Móvel Dupla



Fonte: Elaborado pela autora.

## 4.2 Aplicação do Método Ajuste Exponencial Duplo

Para a aplicação do método de ajuste exponencial duplo, foi utilizado o *software* Excel<sup>®</sup>. Como critério de inicialização para o primeiro período, adotou-se o primeiro valor real das admissões de 850.198, e a tendência inicial foi definida como 0.

Para o período de janeiro de 2004, considerou-se 1 como o número de admissões, enquanto 240 foi o número de admissões registrado em dezembro de 2023.

Os cálculos adotados para este método, bem como o conjunto de dados, foram passados para o Excel<sup>®</sup>, conforme ilustrado na imagem 9.

Para o cálculo da tendência e do valor estimado, foi necessário definir os valores de  $\alpha$  e  $\beta$  que minimizassem o MSD, utilizando um modelo de otimização não linear. Com o auxílio do *solver* do Excel<sup>®</sup>, os valores ótimos encontrados que minimizam o MSD para o método de ajuste exponencial duplo foram  $\alpha = 0,522$  e  $\beta = 0$ , o que resultou em um MSD de  $2,86E+10$ . A figura 10 ilustra este processo.

Após a realização dos cálculos, foi apresentado as previsões para o método de ajuste exponencial duplo, conforme a figura 11.

Nota-se uma melhoria na precisão das previsões, com um acompanhamento melhor as flutuações dos picos e vales, em comparação com o método das médias móveis duplas. No entanto, conforme análise já realizada no gráfico de séries temporais apresentado na figura 6, o ajuste exponencial duplo, embora útil para dados com tendências, não é o modelo mais adequado para séries temporais que apresentam também padrões sazonais.



Figura 9 – Recorte de Planilha: Aplicação do Método de Ajuste Exponencial Duplo

$y_t$				$E_t$	$T_t$	$\hat{y}_{t+1} = E_t + 1T_t$	$(y_t - \hat{y}_t)^2$	$\alpha$	0,522
2004	1	1	850.198	850.198,00	0,00	*	*	$\beta$	0,000
	2	2	872.046	861.609,75	0,00	850.198,00	477335104,00	<b>MSD</b>	2,861E+10
	3	3	998.092	932.897,78	0,00	861.609,75	18627405389,93	$E_t = \alpha y_t + (1 - \alpha)(E_{t-1} + T_{t-1})$	
	4	4	961.475	947.824,36	0,00	932.897,78	816657521,17	$T_t = \beta(E_t - E_{t-1}) + (1 - \beta)T_{t-1}$	
	5	5	1.031.227	991.387,61	0,00	947.824,36	6955999742,02	<b>Soma</b>	6837587728874,69
	6	6	986.494	988.831,56	0,00	991.387,61	23947408,79	<b>n</b>	239
	7	7	982.628	985.591,29	0,00	988.831,56	38484117,24		
	8	8	1.048.597	1.018.500,72	0,00	985.591,29	3969719903,79		
	9	9	987.731	1.002.428,94	0,00	1.018.500,72	946775556,22		
	10	10	921.063	959.929,51	0,00	1.002.428,94	6620415976,88		
	11	11	931.126	944.884,73	0,00	959.929,51	82964222,39		
	12	12	725.819	830.461,32	0,00	944.884,73	47989793888,18		
2005	1	13	980.620	908.892,89	0,00	830.461,32	22547629519,70		
	2	14	971.302	941.490,70	0,00	908.892,89	3894897527,79		
	3	15	1.082.470	1.015.127,65	0,00	941.490,70	19875163333,58		
	4	16	1.110.030	1.064.697,48	0,00	1.015.127,65	9006455984,61		
	5	17	1.101.252	1.083.790,80	0,00	1.064.697,48	1336233056,95		
	6	18	1.089.948	1.087.006,86	0,00	1.083.790,80	37911078,01		
	7	19	1.004.702	1.044.017,01	0,00	1.087.006,86	6774089665,29		
	8	20	1.071.798	1.058.527,70	0,00	1.044.017,01	771783442,30		
	9	21	1.058.963	1.058.755,07	0,00	1.058.527,70	189483,44		
	10	22	971.726	1.013.297,65	0,00	1.058.755,07	7574058909,75		
	11	23	967.765	989.514,83	0,00	1.013.297,65	2073222127,09		
	12	24	768.425	874.034,18	0,00	989.514,83	48880712122,41		
2006	1	25	1.049.445	965.655,56	0,00	874.034,18	30768955407,66		

Fonte: Elaborado pela autora.

Figura 10 – Implementação do Solver para o Método de Ajuste Exponencial Duplo

Parâmetros do Solver

Definir Objetivo:  ↑

Para:  Máx.  Mín.  Valor de:

Alterando Células Variáveis:  ↑

Sujeito às Restrições:

\$P\$4:\$P\$5 <= 1

\$P\$4:\$P\$5 >= 0

Tornar Variáveis Irrestritas Não Negativas

Selecionar um Método de Solução:  Opções

Método de Solução


Selecione o mecanismo GRG Não Linear para Problemas do Solver suaves e não lineares. Selecione o mecanismo LP Simplex para Problemas do Solver lineares. Selecione o mecanismo Evolutionary para problemas do Solver não suaves.

Ajuda Resolver Fechar

$\alpha$	0,522
$\beta$	0,000
<b>MSD</b>	2,86E+10
$E_t = \alpha y_t + (1 - \alpha)(E_{t-1} + T_{t-1})$	
$T_t = \beta(E_t - E_{t-1}) + (1 - \beta)T_{t-1}$	
Soma	6837587728874,69
n	239

Fonte: Elaborado pela autora.

Figura 11 – Gráfico de Admissões x Previsão para o Método de Ajuste Exponencial Duplo



Fonte: Elaborado pela autora.

### 4.3 Aplicação do Método de Holt-Winter para Efeitos Sazonais Aditivos

Para aplicar o método Holt-Winters com sazonalidade aditiva, foram utilizados os softwares Excel<sup>®</sup> e Minitab<sup>®</sup>. Este modelo levou em consideração o nível estimado, a tendência e a sazonalidade.

Os cálculos foram realizados considerando 1 como o número de admissões em janeiro de 2004 e 240 como o número de admissões em dezembro de 2023. A Figura 12 ilustra o repasse das fórmulas necessárias para a realização das previsões.

Utilizando o *Solver* do Excel<sup>®</sup>, foi possível determinar os valores estimados de  $\alpha$ ,  $\beta$ , e  $\gamma$  para os cálculos do nível esperado, da tendência e do fator sazonal, respectivamente, conforme a figura 13. Para isso, adotou-se o modelo de otimização não linear que visa minimizar o MSD.

Assim, os valores ótimos de  $\alpha$ ,  $\beta$ , e  $\gamma$  para o modelo de ajuste de tendências com efeitos sazonais aditivos são  $\alpha = 0,710$ ,  $\beta = 0$  e  $\gamma = 0,633$ , resultando em um MSD de  $1,04E+10$ .

Ao aplicarmos o modelo no Minitab<sup>®</sup>, incluindo as constantes de suavização  $\alpha$ ,  $\beta$ , e  $\gamma$  já calculadas, obtemos o MSD de  $9,70E+9$ . Essa diferença pode ser atribuída ao método de inicialização adotado por cada um. No Minitab<sup>®</sup>, por exemplo, pode ter sido utilizado uma inicialização baseada em algoritmos. Já no Excel<sup>®</sup>, os cálculos iniciaram no primeiro instante onde há valores de previsão e valores reais.

Após a realização dos cálculos, nas figuras 14 e 15 são apresentadas as previsões do Método de Holt-Winter para Efeitos Sazonais Aditivos.

Figura 12 – Recorte de Planilha: Aplicação do Método de Holt-Winter para Efeitos Sazonais Aditivos

$y_t$				$E_t$	$T_t$	$S_t$	$\hat{y}_{t+1} = E_t + 1T_t + S_{(t+1-p)}$	$(y_t - \hat{y}_t)^2$	$\alpha$	0,710
Ano	Mês	t	Qtd Admissões	Nível Esperado	Tendência	Fator Sazonal	Previsão	Diferença	$\beta$	0,000
2004	1	1	850.198	*	*	-91176,67	*	*	$\gamma$	0,633
	2	2	872.046	*	*	-69328,67	*	*	MSD	1,042E+10
	3	3	998.092	*	*	56717,33	*	*	p	12
	4	4	961.475	*	*	20100,33	*	*	$E_t = \alpha(y_t - S_{t-p}) + (1 - \alpha)(E_{t-1} + T_{t-1})$	
	5	5	1.031.227	*	*	89852,33	*	*	$T_t = \beta(E_t - E_{t-1}) + (1 - \beta)T_{t-1}$	
	6	6	986.494	*	*	45119,33	*	*	$S_t = \gamma(y_t - E_t) + (1 - \gamma)S_{t-p}$	
	7	7	982.628	*	*	41253,33	*	*		
	8	8	1.048.597	*	*	107222,33	*	*		
	9	9	987.731	*	*	46356,33	*	*		
	10	10	921.063	*	*	-20311,67	*	*		
	11	11	931.126	*	*	-10248,67	*	*		
	12	12	725.819	941.374,67	0,00	-215555,67	*	*		
2005	1	13	980.620	1.033.946,40	0,00	-67210,31	850.198,00	17.009.898.084,00		
	2	14	971.302	1.038.690,80	0,00	-68100,37	964.617,73	44.679.418,82		
	3	15	1.082.470	1.029.507,49	0,00	54339,82	1.095.408,13	167.395.298,40		
	4	16	1.110.030	1.072.394,32	0,00	31203,52	1.049.607,83	3.650.839.217,91		
	5	17	1.101.252	1.029.101,16	0,00	78643,95	1.162.246,65	3.720.347.323,91		
	6	18	1.089.948	1.040.264,33	0,00	48009,42	1.074.220,49	247.354.564,01		
	7	19	1.004.702	985.741,63	0,00	27137,68	1.081.517,66	5.900.645.520,59		
	8	20	1.071.798	970.718,32	0,00	103332,87	1.092.963,97	447.998.105,99		
	9	21	1.058.963	1.000.450,09	0,00	54053,74	1.017.074,66	1.754.633.386,38		
	10	22	971.726	994.479,07	0,00	-21857,53	980.138,42	70.768.872,44		
	11	23	967.765	982.792,15	0,00	-13274,35	984.230,40	271.109.449,71		
	12	24	768.425	983.635,74	0,00	-215337,27	767.236,49	1.412.563,02		

Fonte: Elaborado pela autora.

Figura 13 – Implementação do Solver para o Método de Holt-Winter para Efeitos Sazonais Aditivos

**Parâmetros do Solver**

Definir Objetivo:  ↑

Para:  Máx.  Míq.  Valor de:

Alterando Células Variáveis:  ↑

Sujeito às Restrições:

\$P\$4:\$P\$6 <= 1  
\$P\$4:\$P\$6 >= 0

Tornar Variáveis Irrestritas Não Negativas

Selecionar um Método de Solução:  Opções


Método de Solução  
Selecione o mecanismo GRG Não Linear para Problemas do Solver suaves e não lineares. Selecione o mecanismo LP Simplex para Problemas do Solver lineares. Selecione o mecanismo Evolutionary para problemas do Solver não suaves.

Ajuda  Fechar

$\alpha$	0,710
$\beta$	0,000
$\gamma$	0,633
MSD	1,04E+10
p	12


Fonte: Elaborado pela autora.

Figura 14 – Gráfico de Admissões x Previsão para o Método de Holt-Winter para Efeitos Sazonais Aditivos no Minitab



Fonte: Elaborado pela autora.

Figura 15 – Gráfico de Admissões x Previsão para o Método de Holt-Winter para Efeitos Sazonais Aditivos



Fonte: Elaborado pela autora.

Ao analisar as figuras 14 e 15, observou-se que este modelo apresentou uma previsão superior, acompanhando melhor as flutuações dos picos e vales em comparação aos modelos anteriores, mesmo apresentando alguns desvios. Isso é demonstrado também pelo valor

do MSD, que foi menor que o do ajuste exponencial duplo, indicando que este modelo apresenta um ajuste mais preciso dos dados.

#### 4.4 Aplicação do Método de Holt-Winter para Efeitos Sazonais Mutiplicativos

O modelo multiplicativo de Holt Winter para efeitos sazonais foi aplicado utilizando o Excel<sup>®</sup> e o Minitab<sup>®</sup>. As fórmulas necessárias foram repassadas para a planilha, conforme demonstrado na imagem 16.

Figura 16 – Recorte de Planilha: Aplicação do Método de Holt-Winter para Efeitos Sazonais Multiplicativos

$Y_t$				$E_t$	$T_t$	$S_t$	$\hat{Y}_{t+1} = E_t + 1T_t \times S_{(t+1-p)}$	$(Y_t - \hat{Y}_t)^2$
Ano	Mês	t	Qtd Admissões	Nível Esperado	Tendência	Fator Sazonal	Previsão	Diferença
2004	1	1	850.198	*	*	0,90	*	*
	2	2	872.046	*	*	0,93	*	*
	3	3	998.092	*	*	1,06	*	*
	4	4	961.475	*	*	1,02	*	*
	5	5	1.031.227	*	*	1,10	*	*
	6	6	986.494	*	*	1,05	*	*
	7	7	982.628	*	*	1,04	*	*
	8	8	1.048.597	*	*	1,11	*	*
	9	9	987.731	*	*	1,05	*	*
	10	10	921.063	*	*	0,98	*	*
	11	11	931.126	*	*	0,99	*	*
	12	12	725.819	941.374,67	0,00	0,77	*	*
2005	1	13	980.620	1.034.322,90	0,00	0,92	850.198,00	17.009.898.084,00
	2	14	971.302	1.043.461,88	0,00	0,93	958.148,95	173.002.702,94
	3	15	1.082.470	1.028.977,21	0,00	1,06	1.106.329,91	569.295.295,69
	4	16	1.110.030	1.066.210,14	0,00	1,03	1.050.948,04	3.490.678.247,46
	5	17	1.101.252	1.027.004,40	0,00	1,08	1.167.977,77	4.452.328.657,93
	6	18	1.089.948	1.035.431,40	0,00	1,05	1.076.227,90	188.241.277,13
	7	19	1.004.702	988.503,43	0,00	1,03	1.080.806,53	5.791.899.995,65
	8	20	1.071.798	971.575,42	0,00	1,11	1.101.093,72	858.239.380,69
	9	21	1.058.963	995.833,31	0,00	1,06	1.019.418,94	1.563.732.813,28
	10	22	971.726	994.109,36	0,00	0,98	974.346,61	6.867.594,64
	11	23	967.765	984.008,98	0,00	0,99	983.286,58	240.919.415,34
	12	24	768.425	992.134,98	0,00	0,77	758.690,92	94.752.251,37
2006	1	25	1.049.445	1.083.964,55	0,00	0,95	917.506,10	17.407.873.700,35

$\alpha$	0,644
$\beta$	0,000
$\gamma$	0,481
MSD	1,011E+10
p	12

$$E_t = \alpha(Y_t/S_{t-p}) + (1 - \alpha)(E_{t-1} + T_{t-1})$$

$$T_t = \beta(E_t - E_{t-1}) + (1 - \beta)T_{t-1}$$


$$S_t = \gamma(Y_t/E_t) + (1 - \gamma)S_{t-p}$$

Fonte: Elaborado pela autora.

Para realizar as previsões, foi considerado 01 como o número de admissões em janeiro de 2004 e 240 como o número de admissões em dezembro de 2023 (coluna t). Além disso, os parâmetros  $\alpha$ ,  $\beta$ , e  $\gamma$  necessários para obter o nível esperado, a tendência e o fator sazonal foram calculados através do *solver* do Excel<sup>®</sup> por meio do modelo de otimização não linear, considerando as mesmas descrições da figura XX. Assim, os valores ótimos dos fatores de ponderação que minimizam o MSD foram  $\alpha=0,644$ ,  $\beta=0,00$  e  $\gamma=0,481$ , resultando em um MSD de 1,01E+10. No entanto, ao aplicarmos o método no Minitab<sup>®</sup>, incluindo as contantes de suavização  $\alpha$ ,  $\beta$ , e  $\gamma$  já calculadas anteriormente, obtemos o MSD de 9,28E+9, conforme ilustrado na figura 17. Da mesma forma que o método aditivo, a diferença pode ser justificada devido ao método de inicialização atribuído em cada *software*. Nota-se que este modelo apresentou o menor MSD dentre os métodos apresentados. As figuras 17 e 18 nos mostra as previsões para o método de ajuste Holt-Winter para Efeitos Sazonais Multiplicativos gerados no excel e minitab, respetivamente.

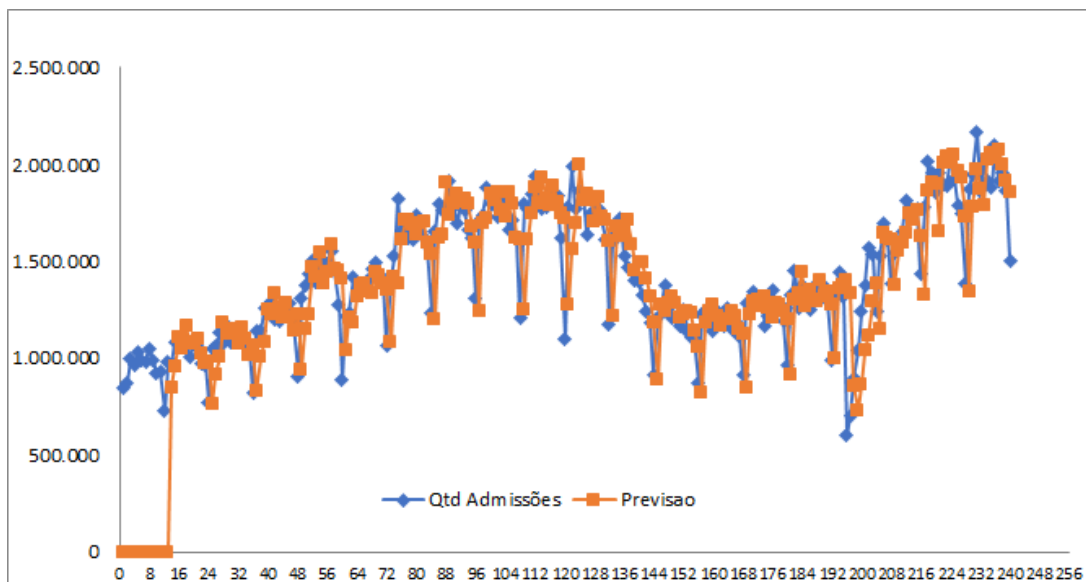
Ao analisarmos as figuras 17 e 18, observou-se uma melhoria na precisão das previsões em comparação com o método das médias móveis dupla, ajuste sazonal duplo e o modelo

Figura 17 – Gráfico de Admissões x Previsão para o Método de Holt-Winter Multiplicativo



Fonte: Elaborado pela autora.

Figura 18 – Gráfico de Previsões para o Método de Holt-Winter Multiplicativo



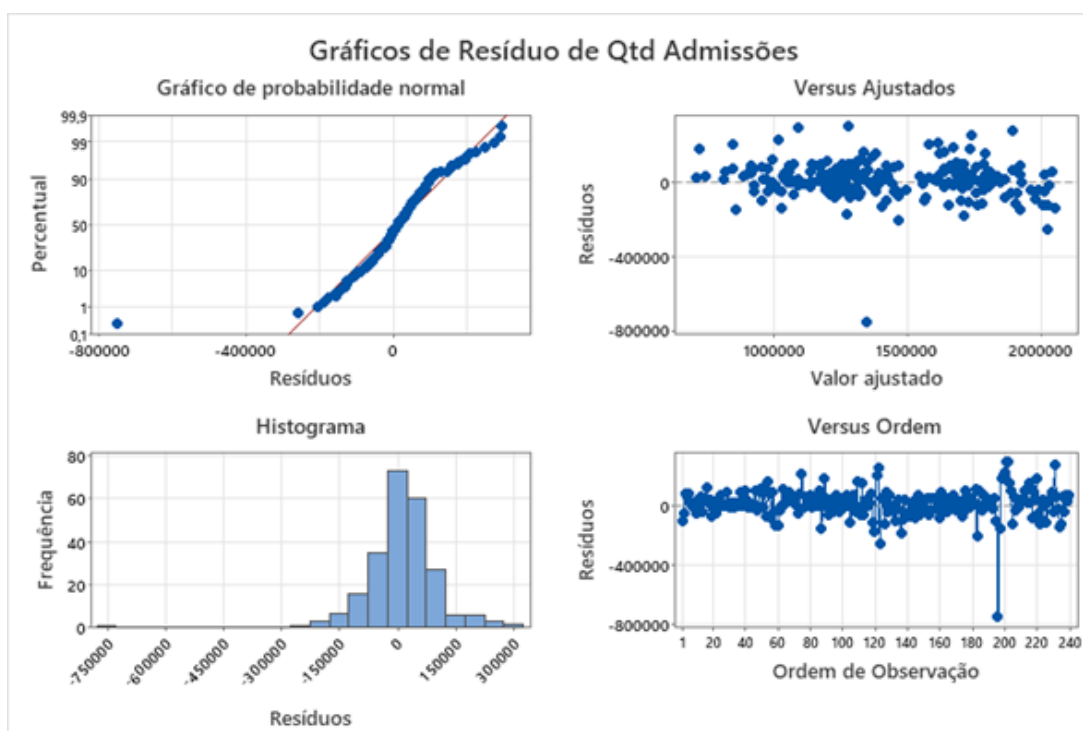
Fonte: Elaborado pela autora.

aditivo de Holt-Winters para efeitos sazonais. Isso é justificado, tendo em vista que a amplitude das variações sazonais dos dados reais varia conforme o nível da série temporal.

Essa é uma das características presente no modelo multiplicativo de Holt Winter que o diferencia do modelo aditivo aplicado. Diante disso, pode-se afirmar que dos modelos aplicados, o método multiplicativo de Holt-Winter é o que mais se adequa aos dados das admissões.

Contudo, é necessário verificar se o erro atende a premissa estabelecida na equação 2.2. Para isso, realizou-se a verificação através da análise residual, conforme ilustrado na figura 19 abaixo.

Figura 19 – Gráfico 4 em 1 para Análise Residual




Fonte: Elaborado pela autora.

1. **Gráfico de probabilidade normal:** Observou-se que os resíduos se distribuem ao longo de uma linha reta, indicando que seguem um padrão de normalidade.
2. **Gráfico Resíduos vs Ajustado:** Os resíduos são distribuídos aleatoriamente em torno de zero, indicando que possuem média zero e variância constante.
3. **Histograma:** Nota-se visualmente que os resíduos são simétricos, o que indica um padrão de normalidade.
4. **Gráfico Resíduos vs Ordem:** Os dados residuais oscilam ao redor de zero, o que demonstra ser independentes.

Diante disso, não há problemas quanto ao atendimento da premissa  $\varepsilon \sim NID(0, \sigma^2)$ . No entanto, observamos um dado que se desvia dos demais. Ao analisarmos o conjunto de dados dispostos no Apêndice A, verificamos que o ponto  $t = 196$  corresponde ao período de abril de 2020. Os impactos causados pelo COVID-19 podem ser um fator explicativo para essa discrepância observada.

Para avaliar com mais precisão esse comportamento, foi gerado um gráfico de boxplot, visando identificar a presença de possíveis *outliers*. Inicialmente, o ponto foi tratado como um *outlier* na análise residual, mas o gráfico de boxplot, representado na figura 20, indicou que os dados das admissões estão dentro dos limites aceitáveis. Isso evidencia que, apesar do comportamento atípico do valor, ele não ultrapassa os limites técnicos estabelecidos para ser considerado um desvio estatístico, permanecendo dentro do intervalo de confiança do modelo.

Figura 20 – Boxplot das Admissões no Mercado de Trabalho



Fonte: Elaborado pela autora.



### 4.5 Aplicação dos Índices e Refino dos Índices Sazonais

Através das análises dos modelos até então aplicados, verificou-se que o método de Holt-Winters para efeitos sazonais multiplicativos foi o que melhor se ajustou aos dados. Evidencia-se essa análise através dos gráficos gerados e pelo menor valor obtido do MSD, sendo 1,01E+10 para os cálculos realizados no Excel<sup>®</sup> e 9,28E+9 através do Minitab<sup>®</sup>. No entanto, existem ferramentas que possibilitam aprimorar ainda mais esses resultados através dos índices ou refino dos índices sazonais.

Para determinar os índices sazonais, primeiramente, foi calculado o percentual entre a quantidade de admissões e a previsão. Em seguida, foi realizado a média separada dos valores de cada mês. Assim, a previsão corrigida é dada pela multiplicação entre a previsão antiga e o percentual do índice sazonal correspondente ao mês. A imagem 21 ilustra o método de Holt-Winters multiplicativo com índices sazonais.

Figura 21 – Recorte de Planilha: Aplicação dos Índice Sazonais no Método de Holt-Winter para Efeitos Sazonais Multiplicativos


$y_t$				$E_t$	$T_t$	$S_t$	$\hat{y}_{t+1} = E_t + 1T_t \times S_{(t+1-p)}$			$(y_t - \hat{y}_t)^2$		
Ano	Mês	t	Qtd Admissões	Nível Esperado	Tendência	Fator Sazonal	Previsão	Admissão/Previsão	Previsão Corrigida	Diferença	$\alpha$	0,780
2004	1	1	850.198	*	*	0,90	*	*	*	*	$\beta$	0,000
	2	2	872.046	*	*	0,93	*	*	*	*	$\gamma$	0,000
	3	3	998.092	*	*	1,06	*	*	*	*	MSD	8,4747E+09
	4	4	961.475	*	*	1,02	*	*	*	*	p	12
	5	5	1.031.227	*	*	1,10	*	*	*	*	$E_t = \alpha(y_t/S_{t-p}) + (1 - \alpha)(E_{t-1} + T_{t-1})$	
	6	6	986.494	*	*	1,05	*	*	*	*	$T_t = \beta(E_t - E_{t-1}) + (1 - \beta)T_{t-1}$	
	7	7	982.628	*	*	1,04	*	*	*	*	$S_t = \gamma(y_t/E_t) + (1 - \gamma)S_{t-p}$	
	8	8	1.048.597	*	*	1,11	*	*	*	*		
	9	9	987.731	*	*	1,05	*	*	*	*		
	10	10	921.063	*	*	0,98	*	*	*	*		
	11	11	931.126	*	*	0,99	*	*	*	*		
	12	12	725.819	941.374,67	0,00	0,77	*	*	*	*		
2005	1	13	980.620	1.054.080,02	0,00	0,90	850.198,00	115%	990.377,79	95.214.377,43		
	2	14	971.302	1.049.741,91	0,00	0,93	976.451,03	99%	1.029.306,92	3.364.570.929,75		
	3	15	1.082.470	1.027.277,05	0,00	1,06	1.112.988,32	97%	1.016.420,75	4.362.503.727,09		
	4	16	1.110.030	1.073.751,14	0,00	1,02	1.049.211,58	106%	1.002.327,87	11.599.748.393,59		
	5	17	1.101.252	1.020.326,35	0,00	1,10	1.176.238,54	94%	1.102.631,49	1.903.004,74		
	6	18	1.089.948	1.035.756,56	0,00	1,05	1.069.229,78	102%	1.079.880,88	101.346.962,26		
	7	19	1.004.702	978.599,79	0,00	1,04	1.081.145,94	93%	1.098.020,89	8.708.416.023,16		
	8	20	1.071.798	965.802,96	0,00	1,11	1.090.062,06	98%	1.090.367,74	344.835.246,23		
	9	21	1.058.963	999.722,29	0,00	1,05	1.013.362,22	104%	1.043.722,63	232.268.943,87		
	10	22	971.726	994.596,71	0,00	0,98	978.151,68	99%	1.046.085,99	5.529.408.705,41		
	11	23	967.765	981.969,03	0,00	0,99	983.768,61	98%	942.220,63	652.515.005,20		
	12	24	768.425	993.414,40	0,00	0,77	757.118,08	101%	744.735,40	561.197.092,93		

Fonte: Elaborado pela autora.

Para o cálculo dos fatores de ponderação  $\alpha$ ,  $\beta$ , e  $\gamma$ , foi realizado o modelo de otimização não linear, através do *solver*, obtendo-se os valores de  $\alpha=0,780$ ,  $\beta=0$ , e  $\gamma=0$ , o que gerou um MSD de 8,475E+9. Após os calculos, foi gerado o gráfico de admissões versus previsão para o método aplicado, conforme a imagem 22. Já a figura 23 fornece um comparativo entre a aplicação dos índices sazonais e o método de Holt Winter Multiplicativo.


Observa-se que a linha de previsão ajustada pelo índice sazonal acompanha de forma mais precisa os dados reais em comparação ao método Holt-Winters multiplicativo. Esse aprimoramento é especialmente evidente nos períodos de alta e baixa sazonalidade, onde a previsão corrigida reflete melhor as flutuações dos picos e vales observadas nos dados históricos, apesar de conter desvios.

Figura 22 – Aplicação dos Índice Sazonais no Método de Holt-Winter para Efeitos Sazonais Multiplicativos



Fonte: Elaborado pela autora.

Figura 23 – Comparativo entre os métodos



Fonte: Elaborado pela autora.

Já o refino dos índices sazonais foi uma adaptação dos índices sazonais. Sua diferença se encontra na forma de calcular o percentual de valores de cada mês. No caso dos índices sazonais, foi realizado a média separada dos valores de cada mês. Já para o refino, foi utilizado o *Solver* para determinar os valores ótimos dos índices sazonais, com o objetivo de minimizar o MSD. O modelo de otimização não linear considerou restrições importantes: os fatores de ponderação  $\alpha$ ,  $\beta$ , e  $\gamma$  devem ser maiores que 0 e menores que 1, e a média dos índices sazonais deveria ser 1 (ou 100%), conforme imagem. As figuras 24 e 25 ilustram as etapas.

Após os cálculos, os valores ótimos de  $\alpha$ ,  $\beta$ , e  $\gamma$  foram, respectivamente 0,758, 0,003 e 0,044, resultando em um MSD de 8,480E+9. Nota-se, conforme figura 26 uma melhoria em compensação ao Método Multiplicativo de Holt Winter, porém, inferior ao resultado do índice sazonal.

Figura 24 – Recorte de Planilha: Aplicação dos Refino dos Índice Sazonais para o Método de Holt-Winter Multiplicativo

			$\hat{Y}_t$	$E_t$	$T_t$	$S_t$	$\hat{Y}_{t+1} = E_t + 1T_t \times S_{(t+1-p)}$				$(Y_t - \hat{Y}_t)^2$			
Ano	Mês	t	Qty Admissões	Nível Esperado	Tendência	Fator Sazonal	Previsão	Admissão/Previsão	Mês	Índice Sazonal	Previsão Corrigida	Diferença	$\alpha$	0,758
2004	1	1	850.198	*	*	0,90	*	*	1	113%	*	*	$\beta$	0,003
	2	2	872.046	*	*	0,93	*	*	2	107%	*	*	$\gamma$	0,044
	3	3	998.092	*	*	1,06	*	*	3	92%	*	*	<b>MSD</b>	8,480E+09
	4	4	961.475	*	*	1,02	*	*	4	95%	*	*	<b>p</b>	12
	5	5	1.031.227	*	*	1,10	*	*	5	94%	*	*		
	6	6	986.494	*	*	1,05	*	*	6	98%	*	*		
	7	7	982.628	*	*	1,04	*	*	7	100%	*	*		
	8	8	1.048.597	*	*	1,11	*	*	8	99%	*	*		
	9	9	987.731	*	*	1,05	*	*	9	102%	*	*		
	10	10	921.063	*	*	0,98	*	*	10	106%	*	*		
	11	11	931.126	*	*	0,99	*	*	11	96%	*	*		
	12	12	725.819	941.374,67	0,00	0,77	*	*	12	97%	*	*		
2005	1	13	980.620	1.050.768,03	323,60	0,90	850.198,00	115%			959.447,23	448.286.228,53		
	2	14	971.302	1.049.144,79	317,84	0,93	973.682,73	100%	<b>Média</b>	100%	1.041.451,95	4.921.015.961,50		
	3	15	1.082.470	1.027.869,49	253,97	1,06	1.112.692,21	97%			1.021.340,24	3.736.847.668,57		
	4	16	1.110.030	1.072.590,67	385,51	1,02	1.050.076,06	106%			995.984,47	13.006.383.978,85		
	5	17	1.101.252	1.021.708,40	233,85	1,09	1.175.389,62	94%			1.102.849,69	2.552.615,38		
	6	18	1.089.948	1.035.694,94	274,53	1,05	1.070.923,12	102%			1.054.733,69	1.240.047.628,57		
	7	19	1.004.702	980.331,04	109,95	1,04	1.081.368,18	93%			1.084.360,18	6.345.426.033,06		
	8	20	1.071.798	966.625,45	69,08	1,11	1.092.112,96	98%			1.086.623,13	219.784.520,50		
	9	21	1.058.963	998.941,72	164,47	1,05	1.014.297,69	104%			1.032.431,33	703.929.297,01		
	10	22	971.726	994.597,94	151,13	0,98	977.548,87	99%			1.036.432,29	4.186.904.600,02		
	11	23	967.765	982.377,05	114,54	0,99	983.919,32	98%			948.505,53	370.927.217,54		

Fonte: Elaborado pela autora.

Figura 25 – Recorte de Planilha: Implementação do Solver para o Refino dos Índices Sazonais no método de Holt-Winter Multiplicativo

**Parâmetros do Solver**

Definir Objetivo:

Para:  Máx.  Míq.  Valor de:

Alterando Células Variáveis:

Sujeito às Restrições:

- \$PS\$19 = 1
- \$WS\$5:\$WS\$7 <= 1
- \$WS\$5:\$WS\$7 >= 0

Tornar Variáveis Irrestritas Não Negativas


Selecionar um Método de Solução:

Método de Solução: Selecione o mecanismo GRG Não Linear para Problemas do Solver suaves e não lineares. Selecione o mecanismo LP Simplex para Problemas do Solver lineares. Selecione o mecanismo Evolutionary para problemas do Solver não suaves.

$\alpha$	0,758
$\beta$	0,003
$\gamma$	0,044
<b>MSD</b>	8,480E+09
<b>p</b>	12

Fonte: Elaborado pela autora.

Figura 26 – Gráfico de Previsões Corrigidas com Refino dos Índices Sazonais para o Método de Holt-Winters Multiplicativo



Fonte: Elaborado pela autora.

#### 4.6 Resultados

Durante o processo de análise dos métodos não estacionários aplicados aos dados, diversos modelos foram testados, com os resultados apresentados na tabela 1 e seu MSD normalizado na tabela 2, utilizando o MSD como métrica de desempenho. A Média Móvel Dupla apresentou o maior MSD, com um valor de  $3,353E+10$ , e ao ser normalizada, obteve um valor de 1, indicando o pior desempenho em termos de erro de previsão. O Ajuste Exponencial Duplo apresentou uma leve melhoria, com um MSD de  $2,861E+10$ , e seu valor normalizado foi de 0,804, mostrando ainda desvios consideráveis. Os modelos de Holt-Winters para Efeitos Sazonais Aditivos e Multiplicativos apresentaram MSDs de  $1,042E+10$  e  $1,011E+10$ , respectivamente, com valores normalizados de 0,078 e 0,065, refletindo um desempenho superior ao incorporar a sazonalidade dos dados. O método de Índices Sazonais com Holt-Winters Multiplicativo foi o mais eficaz, com o menor MSD de  $8,475E+09$ , o que corresponde a um valor normalizado de 0, demonstrando ser o método mais preciso. O Refino dos Índices Sazonais, embora tenha sido submetido a uma otimização adicional, apresentou um MSD de  $8,480E+09$  e um valor normalizado de 0,0002, indicando que, apesar de um leve aumento no erro, ainda oferece um ajuste bastante próximo do melhor método. Com base na análise dos resultados, a tabela 3 apresenta as previsões para os próximos meses de 2024, utilizando o modelo de Índices Sazonais com Holt-Winters Multiplicativo.

Tabela 1 – Comparativo de Resultados.

<b>Métodos Aplicados</b>	<b>MSD</b>
Índices Sazonais Holt-Winter Multiplicativos	8,475E+09
Refino dos Índices Sazonais Holt-Winter Multiplicativos	8,480E+09
Holt-Winter para Efeitos Sazonais Multiplicativos	1,011E+10
Holt-Winter para Efeitos Sazonais Aditivos	1,042E+10
Ajuste Exponencial Duplo	2,861E+10
Média Móvel Dupla	3,353E+10

Fonte: Elaborado pela autora.

Tabela 2 – MSD Normalizado.

<b>Métodos Aplicados</b>	<b>MSD</b>
Índices Sazonais Holt-Winter Multiplicativos	0,0000
Refino dos Índices Sazonais Holt-Winter Multiplicativos	0,0002
Holt-Winter para Efeitos Sazonais Multiplicativos	0,0653
Holt-Winter para Efeitos Sazonais Aditivos	0,0774
Ajuste Exponencial Duplo	0,8036
Média Móvel Dupla	1,0000

Fonte: Elaborado pela autora.

Tabela 3 – Previsões para os meses de 2024

Meses	Previsões
Janeiro	2.039.872,43
Fevereiro	2.160.595,15
Março	2.305.045,83
Abril	2.134.888,70
Maiο	2.267.039,33
Junho	2.108.757,78
Julho	2.099.360,99
Agosto	2.306.908,16
Setembro	2.078.453,06
Outubro	2.158.146,95
Novembro	1.932.766,89
Dezembro	1.984.989,50

Fonte: Elaborado pela autora.

## 5 Conclusões e considerações finais

Esta monografia buscou explorar a aplicação de modelos de séries temporais para analisar e prever as admissões no mercado de trabalho formal brasileiro, utilizando dados do CAGED.

Este estudo é relevante para as admissões no mercado de trabalho formal brasileiro, pois fornece uma abordagem quantitativa e estruturada para prever tendências e padrões de contratação. Ao aplicar modelos de séries temporais, é possível obter previsões mais precisas sobre a dinâmica do mercado de trabalho nos meses subsequentes, permitindo uma melhor compreensão e planejamento estratégico para empresas e formuladores de políticas.

Neste estudo, foram aplicados métodos não estacionários após a análise do comportamento do gráfico de série temporal. Essa análise revelou tendências e padrões sazonais nos dados, indicando que os métodos estacionários tais como Médias Móveis, Médias Móveis Ponderadas, Ajuste Exponencial Simples, Efeitos Sazonais Aditivos e Multiplicativos, não seriam adequados para modelar com precisão o comportamento das admissões ao longo do tempo.

Neste sentido, foram aplicados métodos não estacionários como Média Móvel Dupla, Ajuste Exponencial Duplo, e os modelos de Holt-Winters com efeitos sazonais aditivos e multiplicativos, onde o melhor modelo seria o que obtivesse o menor MSD, indicando um melhor ajuste aos dados. O melhor método foi o de Holt-Winter para efeitos sazonais multiplicativos, com sua premissa confirmada após a análise residual.

Com o objetivo de melhorar ainda mais o método, o índice e o refino dos índices sazonais foram aplicados. Como resultado, concluiu-se que o modelo de Holt-Winters com efeitos sazonais multiplicativos, combinado com índices sazonais, apresentou o melhor desempenho. Apesar de o modelo com índices sazonais ter apresentado o menor MSD em comparação aos outros métodos, é importante destacar que o valor do MSD ainda foi considerável. Isso sugere que, embora o modelo tenha sido o mais eficaz entre os avaliados, há limitações na precisão das previsões não identificadas pelo autor, indicando a necessidade de considerar possíveis melhorias adicionais.

Para trabalhos futuros, recomenda-se a aplicação do método Box-Jenkins (ARIMA) de modo a dar continuidade a este estudo, oferecendo uma abordagem mais robusta para a modelagem de séries temporais.

## Referências

- BIUDES, M. S. et al. Uso de séries temporais em análise de fluxo de seiva de mangabeira. *Ciência e Natura - Universidade Federal de Mato Grosso*, 2009.
- BRASIL. *Lei nº 5.452, de 1º de maio de 1943*: Aprova a consolidação das leis do trabalho. diário oficial da união: seção 1. Brasília: [s.n.], 1943. Disponível em: <<https://download.govbox.com.br/terceiros/caged/ManualCAGED.pdf>>. Acesso em: 29 jul. 2024.
- CAMPOS, M. S. *Métodos Estocásticos da Engenharia IV*: Capítulo i - modelos de previsão (forecasting models). [S.l.: s.n.], 2022.
- DIAS, M. A. P. *Administração De Materiais: Princípios, Conceitos E Gestão: Princípios, Conceitos e Gestão*. 7. ed. São Paulo: Atlas, 2023.
- DOWNING, D.; CLARK, J. *Estatística Aplicada*. 2. ed. São Paulo: Saraiva, 2006.
- FORNO, A. J. D. et al. Erro de previsões, sistemas e desempenho do processo de previsão de demanda - resultados iniciais em aplicação de survey em empresas brasileiras. *ENEGETP*, 2013.
- GUTIERREZ, J. L. C. Monitoramento da instrumentação da barragem de corumbá-i por redes neurais e modelos de box jenkins. *Pontífica Universidade Católica do Rio de Janeiro*, 2003.
- KOEHLER, A. B.; SNYDER, R. D.; ORD, J. *Forecasting models and prediction intervals for the multiplicative Holt-Winters method*. v.17, n.2, p.269-286, apr./jun. USA: International Journal of Forecasting, 2001.
- LATORRE, M. do Rosário Dias de O.; CARDOSO, M. R. A. Análise de séries temporais em epidemiologia: uma introdução sobre os aspectos metodológicos. *Revista Brasileira de Epidemiologia*, 2001.
- LOPES, V. H. S. Análise comparativa do pré-processamento de dados na classificação de sementes. *Universidade Federal do Pampa*, 2024.
- MARTIN, A. C. et al. Análise de séries temporais para previsão da evolução do número de automóveis no município de joinville. *Revista Espacios*, 2015.
- MOREIRA, D. A. *Administração da Produção e Operações*. 2. ed. São Paulo: Cengage Learning, 2012.
- MORETTIN, P. A.; TOLOI, C. M. C. *Análise de Séries Temporais: Modelos lineares univariados*. 3. ed. São Paulo: Edgard Blucher Ltda, 2018.
- MTE. *CAGED*: Manual de orientação do caged. Ministério do Trabalho e Emprego, 2017. Disponível em: <<https://download.govbox.com.br/terceiros/caged/ManualCAGED.pdf>>. Acesso em: 06 fev. 2024.
- NASCIMENTO, A. M.; NASCIMENTO, S. M. *Iniciação ao Direito do Trabalho*. 41. ed. São Paulo: LTR, 2018.

PELLEGRINI, F. R. Metodologia para implementação de sistemas de previsão de demanda. *Dissertação (Mestrado) – Departamento de Engenharia de Produção e Transportes, Universidade Federal do Rio Grande do Sul*, 2000.

RAGSDALE, C. T. *Modelagem de planilha e análise de decisão: Uma introdução prática a business analytics* ). 8. ed. São Paulo: Cengage, 2021.

SOUZA, A. R. dos S. et al. *Análise de Séries Temporais*. São Paulo: Sagah, 2021.

VENANZI, D.; SILVA, O. R. da. *Introdução à engenharia de produção: conceitos e casos práticos*. Rio de Janeiro: LTC, 2016.

VERÍSSIMO, A. J. et al. Métodos estatísticos de suavização exponencial de holtwinters para previsão de demanda em uma empresa do setor metal mecânico. *Revista Gestão Industrial, [S.L.], v. 8, n. 4, p. 154-171*, 2012.



## Anexos

## ANEXO A – Dados Mensais de Admissões de Empregados (2004-2023)

Tabela 4 – Quantidade de Admissões por Ano e Mês

<b>Ano</b>	<b>Mês</b>	<b>t</b>	<b>Qtd Admissões</b>
2004	1	1	850.198
2004	2	2	872.046
2004	3	3	998.092
2004	4	4	961.475
2004	5	5	1.031.227
2004	6	6	986.494
2004	7	7	982.628
2004	8	8	1.048.597
2004	9	9	987.731
2004	10	10	921.063
2004	11	11	931.126
2004	12	12	725.819
2005	1	13	980.620
2005	2	14	971.302
2005	3	15	1.082.470
2005	4	16	1.110.030
2005	5	17	1.101.252
2005	6	18	1.089.948
2005	7	19	1.004.702
2005	8	20	1.071.798
2005	9	21	1.058.963
2005	10	22	971.726
2005	11	23	967.765
2005	12	24	768.425
2006	1	25	1.049.445
2006	2	26	1.062.980
2006	3	27	1.129.637
2006	4	28	1.076.102
2006	5	29	1.165.777
2006	6	30	1.080.412
2006	7	31	1.079.746

<b>Ano</b>	<b>Mês</b>	<b>t</b>	<b>Qtd Admissões</b>
2006	8	32	1.146.722
2006	9	33	1.092.661
2006	10	34	1.080.392
2006	11	35	1.047.987
2006	12	36	819.288
2007	1	37	1.144.043
2007	2	38	1.137.737
2007	3	39	1.255.630
2007	4	40	1.272.951
2007	5	41	1.293.497
2007	6	42	1.197.609
2007	7	43	1.190.535
2007	8	44	1.253.523
2007	9	45	1.224.287
2007	10	46	1.280.701
2007	11	47	1.182.648
2007	12	48	908.128
2008	1	49	1.308.922
2008	2	50	1.376.908
2008	3	51	1.433.140
2008	4	52	1.503.158
2008	5	53	1.389.589
2008	6	54	1.492.051
2008	7	55	1.502.808
2008	8	56	1.484.007
2008	9	57	1.554.571
2008	10	58	1.451.205
2008	11	59	1.275.674
2008	12	60	887.299
2009	1	61	1.216.550
2009	2	62	1.233.554
2009	3	63	1.419.511
2009	4	64	1.350.446
2009	5	65	1.348.575
2009	6	66	1.356.349
2009	7	67	1.398.181
2009	8	68	1.457.455
2009	9	69	1.491.580

<b>Ano</b>	<b>Mês</b>	<b>t</b>	<b>Qtd Admissões</b>
2009	10	70	1.433.915
2009	11	71	1.413.043
2009	12	72	1.068.481
2010	1	73	1.410.462
2010	2	74	1.526.321
2010	3	75	1.820.045
2010	4	76	1.660.075
2010	5	77	1.693.332
2010	6	78	1.623.079
2010	7	79	1.614.319
2010	8	80	1.740.659
2010	9	81	1.688.585
2010	10	82	1.620.535
2010	11	83	1.576.872
2010	12	84	1.230.563
2011	1	85	1.650.372
2011	2	86	1.797.217
2011	3	87	1.765.922
2011	4	88	1.774.378
2011	5	89	1.912.665
2011	6	90	1.781.817
2011	7	91	1.696.863
2011	8	92	1.830.321
2011	9	93	1.763.026
2011	10	94	1.664.566
2011	11	95	1.620.422
2011	12	96	1.305.051
2012	1	97	1.711.490
2012	2	98	1.740.062
2012	3	99	1.881.127
2012	4	100	1.798.101
2012	5	101	1.785.075
2012	6	102	1.732.327
2012	7	103	1.753.241
2012	8	104	1.819.767
2012	9	105	1.664.747
2012	10	106	1.710.580
2012	11	107	1.624.306

<b>Ano</b>	<b>Mês</b>	<b>t</b>	<b>Qtd Admissões</b>
2012	12	108	1.211.216
2013	1	109	1.794.272
2013	2	110	1.774.411
2013	3	111	1.849.148
2013	4	112	1.938.169
2013	5	113	1.827.122
2013	6	114	1.772.194
2013	7	115	1.781.308
2013	8	116	1.845.915
2013	9	117	1.805.458
2013	10	118	1.841.106
2013	11	119	1.618.426
2013	12	120	1.094.522
2014	1	121	1.778.077
2014	2	122	1.989.181
2014	3	123	1.767.969
2014	4	124	1.862.515
2014	5	125	1.849.591
2014	6	126	1.639.407
2014	7	127	1.746.797
2014	8	128	1.748.818
2014	9	129	1.770.429
2014	10	130	1.718.373
2014	11	131	1.613.006
2014	12	132	1.176.896
2015	1	133	1.600.094
2015	2	134	1.646.703
2015	3	135	1.719.219
2015	4	136	1.527.681
2015	5	137	1.464.645
2015	6	138	1.453.335
2015	7	139	1.397.393
2015	8	140	1.392.343
2015	9	141	1.326.735
2015	10	142	1.237.454
2015	11	143	1.179.079
2015	12	144	917.031
2016	1	145	1.205.040

<b>Ano</b>	<b>Mês</b>	<b>t</b>	<b>Qtd Admissões</b>
2016	2	146	1.276.620
2016	3	147	1.374.485
2016	4	148	1.258.970
2016	5	149	1.209.991
2016	6	150	1.204.763
2016	7	151	1.168.011
2016	8	152	1.253.728
2016	9	153	1.142.797
2016	10	154	1.104.431
2016	11	155	1.103.767
2016	12	156	869.439
2017	1	157	1.225.262
2017	2	158	1.250.831
2017	3	159	1.261.332
2017	4	160	1.141.850
2017	5	161	1.242.433
2017	6	162	1.181.930
2017	7	163	1.167.770
2017	8	164	1.254.951
2017	9	165	1.148.307
2017	10	166	1.187.819
2017	11	167	1.111.798
2017	12	168	910.586
2018	1	169	1.284.498
2018	2	170	1.274.965
2018	3	171	1.340.153
2018	4	172	1.305.225
2018	5	173	1.277.576
2018	6	174	1.167.531
2018	7	175	1.219.187
2018	8	176	1.353.422
2018	9	177	1.234.591
2018	10	178	1.279.502
2018	11	179	1.189.414
2018	12	180	961.145
2019	1	181	1.325.183
2019	2	182	1.453.284
2019	3	183	1.261.177

<b>Ano</b>	<b>Mês</b>	<b>t</b>	<b>Qtd Admissões</b>
2019	4	184	1.374.628
2019	5	185	1.347.304
2019	6	186	1.248.106
2019	7	187	1.331.189
2019	8	188	1.382.407
2019	9	189	1.341.716
2019	10	190	1.365.054
2019	11	191	1.291.837
2019	12	192	990.848
2020	1	193	1.342.262
2020	2	194	1.443.388
2020	3	195	1.316.655
2020	4	196	598.596
2020	5	197	703.921
2020	6	198	895.460
2020	7	199	1.043.650
2020	8	200	1.239.478
2020	9	201	1.379.509
2020	10	202	1.571.402
2020	11	203	1.532.189
2020	12	204	1.239.280
2021	1	205	1.527.083
2021	2	206	1.694.604
2021	3	207	1.608.007
2021	4	208	1.381.767
2021	5	209	1.548.715
2021	6	210	1.601.001
2021	7	211	1.656.182
2021	8	212	1.810.434
2021	9	213	1.780.161
2021	10	214	1.760.739
2021	11	215	1.772.766
2021	12	216	1.437.910
2022	1	217	1.777.646
2022	2	218	2.013.143
2022	3	219	1.953.071
2022	4	220	1.854.557
2022	5	221	1.960.960

<b>Ano</b>	<b>Mês</b>	<b>t</b>	<b>Qtd Admissões</b>
2022	6	222	1.898.876
2022	7	223	1.886.537
2022	8	224	2.051.800
2022	9	225	1.926.572
2022	10	226	1.789.462
2022	11	227	1.747.894
2022	12	228	1.382.923
2023	1	229	1.874.226
2023	2	230	1.949.844
2023	3	231	2.168.418
2023	4	232	1.865.279
2023	5	233	2.014.492
2023	6	234	1.914.130
2023	7	235	1.883.198
2023	8	236	2.099.211
2023	9	237	1.917.057
2023	10	238	1.955.460
2023	11	239	1.866.752
2023	12	240	1.502.563

*Fonte: Dados da Pesquisa 2024.*



## ANEXO B – Declaração

Declaro que esse Trabalho de Conclusão de Curso - Monografia foi realizado de acordo com as exigências do Regulamento do Curso de Engenharia de Produção da Escola de Minas da Universidade Federal de Ouro Preto e que ele não foi submetido a nenhum outro prêmio acadêmico. Exceto quando indicado por referência específica, esse texto é próprio da autora. Quaisquer opiniões expressas no texto são de responsabilidade única e exclusiva da autora.

Data: 09 de outubro de 2024.

Assinatura: