



# ConBRepro

XIII CONGRESSO BRASILEIRO DE ENGENHARIA DE PRODUÇÃO



IA nas Engenharias

29 nov. a 01  
de dezembro 2023

## Avaliação Comparativa da Simulação de Monte Carlo e Séries Temporais Utilizando o Microsoft Excel®

Fernando Rodrigo Souza

Departamento de Tecnologia de Gestão da Qualidade – Faculdade de Tecnologia de Sorocaba

**Resumo:** Este estudo abordou a previsão de vendas em uma empresa fabricante de componentes mecânicos, para atender eficazmente às demandas dos clientes, ao mesmo tempo em que minimizou os custos operacionais. Para alcançar esse objetivo, este estudo empregou a técnica de Simulação de Monte Carlo e a abordagem de Séries Temporais. A escolha do Microsoft Excel® como plataforma facilitou a acessibilidade para organizações de diversos portes, eliminando a necessidade de adquirir sistemas de Planejamento de Recursos Empresariais (ERPs) complexos. Os resultados revelaram que a Simulação de Monte Carlo apresentou acuracidade inferior a 90%, levantando preocupações sobre sua confiabilidade em previsões de vendas. Em contraste, a Simulação com Séries Temporais demonstrou resultados mais consistentes, fornecendo médias alinhadas com as vendas reais e limites inferiores e superiores adequados. Isso sugeriu que, ao usar o Microsoft Excel®, a abordagem de Séries Temporais era preferível para a previsão de vendas em fabricantes de componentes mecânicos. A previsão de vendas é um desafio contínuo, e a análise demonstrou que a abordagem de Séries Temporais era uma opção confiável e eficaz para a empresa no estágio que ele se encontra. No entanto, para empresas com um mix de produtos em crescimento, a consideração de um ERP poderia ser necessária.

**Palavras-chave:** Previsão de vendas; Simulação de Monte Carlo; Séries Temporais.

## ***Comparative Evaluation of Monte Carlo Simulation and Time Series Using Microsoft Excel®***

**Abstract:** *This study looked at sales forecasting in a mechanical components manufacturing company, in order to effectively meet customer demands while minimizing operating costs. To achieve this objective, this study employed the Monte Carlo Simulation technique and the Time Series approach. The choice of Microsoft Excel® as the platform facilitated accessibility for organizations of many sizes, eliminating the need to acquire complex Enterprise Resource Planning systems (ERPs). The results showed that Monte Carlo Simulation was less than 90% accurate, raising concerns about its reliability in sales forecasting. In contrast, Time Series Simulation demonstrated more consistent results, providing averages in line with actual sales and adequate lower and upper bounds. This suggested that, when using Microsoft Excel®, the Time Series approach was preferable for sales forecasting in mechanical component manufacturers. Sales forecasting is an ongoing challenge, and the analysis showed that the Time Series approach was a reliable and effective option for the company at the stage it is at. However, for companies with a growing product mix, consideration of an ERP might be necessary.*

**Keywords:** *Sales Forecasting; Monte Carlo Simulation; Time Series.*

## 1. Introdução

A previsão de vendas é uma atividade essencial em inúmeras organizações, desempenhando um papel crucial no planejamento e na gestão de operações. Esse processo torna-se especialmente vital em setores altamente competitivos, como a fabricação de componentes mecânicos, onde a demanda do mercado flutua constantemente. Uma previsão precisa de vendas não só evita o acúmulo de estoques não vendidos, o que pode resultar em custos elevados, mas também permite que as empresas atendam de forma eficiente às demandas de seus clientes, garantindo um nível satisfatório de serviço.

A importância da previsão de vendas não se limita apenas à gestão de estoques e produção. Ela permeia todas as áreas de uma organização, influenciando as estratégias de *marketing*, as decisões de compras, as alocações de recursos e até mesmo a estabilidade financeira da empresa. Um erro na previsão de vendas pode ter repercussões significativas, levando a custos adicionais, perda de clientes e, em última instância, impactando a saúde financeira da empresa.

Além disso, a viabilidade econômica desempenha um papel crítico no processo de previsão de vendas. Uma análise financeira abrangente, que leve em consideração não apenas os custos iniciais, mas também as despesas operacionais contínuas e a receita ao longo do tempo, é essencial para a tomada de decisões informadas. A capacidade de determinar se um investimento em produção ou estoque é sustentável a longo prazo é uma consideração essencial para o sucesso organizacional.

Nesse contexto, técnicas avançadas de modelagem, como a simulação de Monte Carlo e a análise de séries temporais, desempenham papéis significativos. A simulação de Monte Carlo é uma abordagem numérica que permite avaliar modelos determinísticos, gerando distribuições de probabilidade para as variáveis analisadas. Por outro lado, a análise de séries temporais trata da modelagem e previsão de dados que variam ao longo do tempo, fornecendo *insights* valiosos sobre tendências e padrões. Essas técnicas, evoluíram para se tornar ferramentas na análise de problemas complexos.

A importância da previsão de vendas, da análise de viabilidade econômica e do uso da simulação de Monte Carlo e da análise de séries temporais como ferramentas cruciais para apoiar decisões críticas em organizações que fabricam componentes mecânicos. Abordaremos a aplicação prática dessas técnicas e sua relevância em um cenário empresarial diversificado, destacando como elas podem ser acessíveis e benéficas para uma gama de organizações.

## 2. Referencial Teórico

### 2.1 Simulação

A simulação é uma técnica matemática que cria um modelo semelhante à realidade, permitindo a análise de suas propriedades e características com o intuito de embasar decisões a partir dos resultados obtidos na simulação. Esta abordagem oferece uma série de vantagens, como a capacidade de explorar novos procedimentos sem afetar o sistema real, compreender a causa de certos fenômenos, identificar gargalos e testar cenários alternativos (CERAVOLO *et al.*, 2023; SOUZA *et al.*, 2023; MOTA, 2023).

Entretanto, a construção de modelos de simulação introduz incertezas, uma vez que estes modelos são simplificações do sistema real. Dessa forma, a precisão do modelo é de extrema importância para a interpretação dos resultados obtidos. A simulação se posiciona como a segunda melhor alternativa após a observação direta do sistema real, envolvendo a representação computacional do comportamento aleatório do sistema a fim de estimar seus indicadores de desempenho (TAHA, 2008; CERAVOLO *et al.*, 2023; SOUZA *et al.*, 2023).

A simulação, como um processo que visa imitar a realidade por meio de modelos, que podem ou não reproduzir fielmente as características físicas e lógicas do sistema real, implica o uso de formalizações matemáticas em ambientes computacionais para emular processos do mundo real. Portanto, a elaboração de um modelo computacional consistente se mostra como um passo essencial na prática da simulação (TAHA, 2008; CERAVOLO *et al.*, 2023; SOUZA *et al.*, 2023).

A simulação é uma ferramenta para a análise de sistemas complexos em diversas áreas, como aviação, gerenciamento de tráfego, economia, estratégia militar, logística e produção industrial. O escopo da simulação não se restringe à construção do modelo, envolvendo também a descrição do comportamento do sistema, a formulação de teorias e hipóteses, e a projeção de cenários futuros (TAHA, 2008; CERAVOLO *et al.*, 2023; SOUZA *et al.*, 2023).

A simulação é uma abordagem abrangente para a solução de problemas complexos, permitindo a emulação do comportamento de sistemas reais. Ela se mostra particularmente útil quando não é viável a realização de testes diretos no sistema real. Embora a simulação não seja uma técnica de otimização, ela desempenha um papel crucial na estimativa de indicadores de desempenho (SANTOS, 1999; TAHA, 2008; CERAVOLO *et al.*, 2023; SOUZA *et al.*, 2023).

As vantagens da simulação incluem a capacidade de avaliar novas políticas, procedimentos operacionais, regras de negócios e outros aspectos sem impactar o mundo real. Além disso, a simulação permite testar novos equipamentos e hipóteses relacionadas a fenômenos, bem como acelerar ou desacelerar o tempo e compreender as interações no sistema (SANTOS, 1999; CERAVOLO *et al.*, 2023; SOUZA *et al.*, 2023).

No entanto, a construção de modelos de simulação demanda treinamento específico e consome tempo e recursos financeiros. Adicionalmente, a interpretação dos resultados da simulação pode ser desafiadora devido à presença de variáveis aleatórias (CERAVOLO *et al.*, 2023; SOUZA *et al.*, 2023).

A simulação é aplicável em diversas áreas, como aviação, sistemas de tráfego, economia, estratégia militar, logística e indústria. Existem diversos tipos de simulação, abrangendo sistemas contínuos e discretos, modelos determinísticos e estocásticos, bem como simulações de terminação e não terminação (CERAVOLO *et al.*, 2023; SOUZA *et al.*, 2023).

A simulação é uma ferramenta para modelar sistemas complexos e avaliar seu comportamento em diferentes cenários. A construção de modelos adequados e sua validação representam etapas cruciais, visto que a qualidade dos resultados obtidos

depende da qualidade do modelo. Portanto, é recomendável escolher um modelo com a menor complexidade necessária. Adicionalmente, os modelos não substituem os tomadores de decisão, mas fornecem informações para apoiar decisões objetivas (TAHA, 2008; CERAVOLO *et al.*, 2023; SOUZA *et al.*, 2023).

A simulação desempenha um papel fundamental em projetos de manufatura integrada, como sistemas flexíveis de manufatura e células robóticas. Nesse contexto, a construção de modelos apropriados é essencial para o sucesso da simulação. A validação dos modelos é crucial, e a escolha de modelos com a menor complexidade necessária é recomendada para otimizar recursos e custos. Vale ressaltar que os modelos não substituem os tomadores de decisão, mas fornecem informações para embasar escolhas objetivas (TAHA, 2008; CERAVOLO *et al.*, 2023; SOUZA *et al.*, 2023).

## **2.2 Simulação de Monte Carlo**

A Simulação de Monte Carlo é uma técnica que se baseia na geração de amostras aleatórias para estimar resultados em sistemas complexos e sujeitos a incertezas. Uma de suas características distintivas é a utilização de números aleatórios, frequentemente gerados por algoritmos, para representar a incerteza nas variáveis do modelo e permitir a avaliação de diferentes cenários de forma eficaz (GENTLE, 2013; WANG *et al.*, 2023; JESÚS GONZÁLEZ *et al.*, 2023; LI *et al.*, 2023; ŚWIECHOWSKI *et al.*, 2023).

Krajewski *et al.* (2017) enfatizam duas vantagens cruciais da simulação de Monte Carlo. Em primeiro lugar, ela possibilita a realização de experimentos sem afetar o sistema real. Em segundo lugar, ela oferece uma forma eficiente de examinar as características do sistema em um curto período de tempo. A simulação de Monte Carlo é frequentemente empregada em situações em que não é possível encontrar uma solução analítica, sendo particularmente valiosa na análise de risco (BUENO, 2017; LI *et al.*, 2023; ŚWIECHOWSKI *et al.*, 2023).

Na previsão baseada em simulação, é comum recorrer à simulação de grupo de Monte Carlo, uma técnica que envolve a manipulação de modelos estatísticos para a abordagem experimental de variáveis representadas por funções de probabilidade (ANDRADE, 2015; WANG *et al.*, 2023; JESÚS GONZÁLEZ *et al.*, 2023; LI *et al.*, 2023; ŚWIECHOWSKI *et al.*, 2023). A análise de sensibilidade desempenha um papel relevante na seleção das variáveis críticas e na definição das distribuições de probabilidade associadas a cada variável de entrada. Essa análise é crucial para compreender o impacto das mudanças nos pressupostos de avaliação e ajuda a identificar as variáveis mais sensíveis (SAVVIDES, 1994; CHOROL *et al.*, 2023; HOSSEINZADEH *et al.*, 2023; WANG *et al.*, 2023).

A Simulação de Monte Carlo é uma ferramenta que transforma modelos de avaliação determinísticos em modelos estocásticos, incorporando elementos de incerteza. A geração de cenários aleatórios e suas probabilidades de ocorrência garantem resultados imparciais. Além disso, a simulação é considerada o método mais completo para a medição de riscos em fluxos de caixa de empresas, superando abordagens determinísticas. A análise de sensibilidade pode ser usada para identificar pressupostos críticos e avaliar seu impacto no valor da avaliação (NETO *et al.*, 2002; WANG *et al.*, 2023; JESÚS GONZÁLEZ *et al.*, 2023; LI *et al.*, 2023; ŚWIECHOWSKI *et al.*, 2023).

## **2.3 Séries Temporais**

A análise de séries temporais é uma abordagem quantitativa que envolve o estudo de observações ao longo do tempo. Ela é frequentemente utilizada para prever valores futuros com base em dados passados (BOX e JENKINS, 2015; HAJIRAHIMI *et al.*, 2023; KAUR *et al.*, 2023; MASINI *et al.*, 2023; TALAGALA *et al.*, 2023). As previsões baseadas em séries temporais presumem que o comportamento futuro de uma variável depende principalmente

de suas observações passadas, sem a influência de outras variáveis (TUBINO, 2022; HAJIRAHIMI *et al.*, 2023; KAUR *et al.*, 2023; MASINI *et al.*, 2023; TALAGALA *et al.*, 2023).

Uma série temporal pode ser classificada como estacionária ou não estacionária. A estacionariedade implica que a série possui um comportamento constante ao longo do tempo, enquanto uma série não estacionária apresenta mudanças em seu comportamento ao longo do tempo (MORETTIN e TOLOI, 2006; MASINI *et al.*, 2023; TALAGALA *et al.*, 2023). As séries temporais podem ser compostas por componentes de sazonalidade, tendência e resíduos (EHLERS, 2007; HAJIRAHIMI *et al.*, 2023; KAUR *et al.*, 2023; MASINI *et al.*, 2023; TALAGALA *et al.*, 2023).

A sazonalidade refere-se a padrões cíclicos que se repetem em determinados períodos, enquanto a tendência representa mudanças de longo prazo no nível da série (PAL e PRAKASH, 2017; HAJIRAHIMI *et al.*, 2023; KAUR *et al.*, 2023; MASINI *et al.*, 2023; TALAGALA *et al.*, 2023). A análise de séries temporais é fundamental para entender as dinâmicas subjacentes aos dados ao longo do tempo e pode ser valiosa em previsões de curto e longo prazo.

## **2.4 Método da Simulação de Monte Carlo em Séries Temporais**

O Método de Simulação de Monte Carlo é uma técnica que pode ser aplicada a séries temporais, permitindo transformar um modelo de previsão determinístico em um modelo estocástico. Nesse contexto, é possível gerar múltiplas amostras para variáveis incertas e estimar a distribuição de probabilidade dos resultados. A análise de séries temporais com a Simulação de Monte Carlo é particularmente útil para avaliar o impacto da incerteza e da variabilidade nas previsões (OLIVEIRA, 2012; PEDERSEN, 2014; PAIXÃO e SILVA, 2019; JIA *et al.*, 2023; LEE *et al.*, 2023; MARTÍNEZ-HERNÁNDEZ *et al.*, 2023; PUMI *et al.*, 2023; SOHRABI *et al.*, 2023; TSAMTSAKIRI *et al.*, 2023; WANG *et al.*, 2023).

No processo de Simulação de Monte Carlo em séries temporais, é importante selecionar as distribuições de probabilidade adequadas para cada variável de entrada e realizar testes de aderência para validar o modelo. A análise dos resultados pode ser feita por meio de histogramas, intervalos de confiança e outros indicadores estatísticos (MORETTIN e TOLOI, 2006; PAIXÃO e SILVA, 2019; JIA *et al.*, 2023; LEE *et al.*, 2023; MARTÍNEZ-HERNÁNDEZ *et al.*, 2023; PUMI *et al.*, 2023; SOHRABI *et al.*, 2023; TSAMTSAKIRI *et al.*, 2023; WANG *et al.*, 2023).

O método de Simulação de Monte Carlo, com suas etapas bem definidas, pode ser aplicado a séries temporais para obter previsões e avaliações mais robustas, levando em consideração a incerteza inerente aos dados ao longo do tempo. No entanto, é importante reconhecer que essa abordagem requer a escolha adequada das distribuições de probabilidade e a validação do modelo para garantir a credibilidade dos resultados (PAIXÃO e SILVA, 2019; JIA *et al.*, 2023; LEE *et al.*, 2023; MARTÍNEZ-HERNÁNDEZ *et al.*, 2023; PUMI *et al.*, 2023; SOHRABI *et al.*, 2023; TSAMTSAKIRI *et al.*, 2023; WANG *et al.*, 2023).

## **3. Metodologia**

Neste estudo, foi realizada uma revisão de literatura que, emprega: simulações de Monte Carlo e simulações de Séries Temporais e a comparação entre elas. A abordagem visa orientar a geração de conhecimento direcionado à resolução de problemas práticos, conforme destacado por Gil (2019). Do ponto de vista da natureza da pesquisa, classifica-se como descritiva, conforme a categorização de Rudio (2015), pois utiliza métodos numéricos para descrever as condições realizadas. Foi realizado um estudo de caso, para validação dos métodos, que de acordo com Yin (2014), é uma investigação profunda de um fenômeno contemporâneo em seu contexto real, geralmente envolvendo a coleta de dados de várias fontes para compreendê-lo. A abordagem busca fornecer orientação na geração de conhecimento voltado para a resolução de problemas práticos.

A primeira etapa do estudo, envolveu a seleção de vários produtos afetados pela sazonalidade nas previsões de vendas do fabricante de peças mecânicas, para validação da consistência dos métodos propostos em relação aos dados históricos disponíveis.

A etapa subsequente compreendeu a escolha das ferramentas para realizar os ajustes nas previsões de vendas. Sistemas de Planejamento de Recursos Empresariais (ERPs) como SAP, TOTVS, Protheus, Blocksim e outros foram considerados. No entanto, o intuito era a utilização do Microsoft Excel®, para validação, comparando o método de Monte Carlo e as análises de séries temporais.

## 4. Resultados e Discussões

### 4.1 Simulação de Monte Carlo e Séries Temporais

Para aplicar o estudo proposto, diversas peças foram simuladas para averiguação da previsão de vendas e suas vendas históricas foram consideradas. Como o objetivo desse trabalho, é a comparação entre a Simulação de Monte Carlo e Previsão de Séries Temporais, foram realizadas com datas retroativas, com o intuito de validação dos métodos de simulação.

### 4.2 Percurso utilizado para a Simulação de Monte Carlo

1. Coletar dados históricos disponíveis (100 meses anteriores à aplicação);
2. Definir em quais datas e quais quantidades havia no estoque;
3. As quantidades utilizadas no mês não foram contabilizadas por não terem sido disponibilizadas. Foi utilizado o lote mínimo considerado pelo almoxarife;
4. Foram feitas duas colunas na planilha Excel®, uma referente a tempo e outra a quantidades.
5. A sequência no Excel® foi: Dados – Planilha de Previsão – Opções.
6. Foram considerados os 100 meses conhecidos e simulados através de 12 meses, 24 meses e 36 meses e depois disso, através de 100 eventos para acuracidade da Simulação de Monte Carlo.
7. Foram solicitadas a inclusão das estatísticas de previsão.
8. Criação de dados visuais através dos gráficos.

### 4.3 Percurso utilizado para a simulação de Séries Temporais

1. Coletar dados disponíveis (100 meses anteriores à aplicação);
2. Uma coluna na planilha Excel®, referente aos dados coletados mensalmente.
3. Foi calculado desvio padrão dos 100 meses;
4. A sequência no Excel® foi: Dados – Análise de Dados – Geração de Número Aleatório.
5. Solicitada a geração de demanda aleatória normal;
6. Criação de dados visuais através dos gráficos.

**Tabela 1.** Comparação entre Séries Temporais e Simulação de Monte Carlo

Séries Temporais				SMC
Período	Valores	Previsão	Lim. Conf. Inf.    Lim.de Conf. Sup.	Demanda aleatória (normal)
01/01/2015	2903			2903
01/02/2015	2901			2901
01/03/2015	2902			2902
01/04/2015	2902			2902
01/05/2015	2902			2902
01/06/2015	2898			2898
01/07/2015	2896			2896

01/08/2015	2900				2900
01/09/2015	2901				2901
01/10/2015	2896				2896
01/11/2015	2897				2897
01/12/2015	2899				2899
01/01/2016	2894				2894
01/02/2016	2907				2907
01/03/2016	2896				2896
01/04/2016	2901				2901
01/05/2016	2895				2895
01/06/2016	2898				2898
01/07/2016	2890				2890
01/08/2016	2907				2907
01/09/2016	2909				2909
01/10/2016	2901				2901
01/11/2016	2893				2893
01/12/2016	2902				2902
01/01/2017	2905				2905
01/02/2017	2895				2895
01/03/2017	2899				2899
01/04/2017	2894				2894
01/05/2017	2897				2897
01/06/2017	2901				2901
01/07/2017	2904				2904
01/08/2017	2895				2895
01/09/2017	2902				2902
01/10/2017	2898				2898
01/11/2017	2889				2889
01/12/2017	2905				2905
01/01/2018	2901				2901
01/02/2018	2897				2897
01/03/2018	2901				2901
01/04/2018	2905				2905
01/05/2018	2905				2905
01/06/2018	2899	2899	2899	2899	2899
01/07/2018	2898	2898	2887	2909	2891
01/08/2018	2903	2903	2892	2915	2897
01/09/2018	2907	2907	2895	2919	2895
01/10/2018	2902	2902	2890	2914	2901
01/11/2018	2897	2897	2884	2909	2902
01/12/2018	2904	2904	2892	2917	2898
01/01/2019	2901	2901	2888	2914	2897
01/02/2019	2903	2903	2890	2917	2895
01/03/2019	2901	2901	2887	2915	2906
01/04/2019	2903	2903	2889	2917	2904
01/05/2019	2901	2901	2887	2915	2896


01/06/2019	2901	2901	2886	2915	2901
01/07/2019	2898	2898	2883	2914	2903
01/08/2019	2903	2903	2887	2919	2901
01/09/2019	2907	2907	2891	2923	2902
01/10/2019	2902	2902	2885	2918	2902
01/11/2019	2897	2897	2880	2913	2902
01/12/2019	2904	2904	2887	2921	2898
01/01/2020	2901	2901	2883	2918	2896
01/02/2020	2903	2903	2886	2921	2900
01/03/2020	2901	2901	2883	2919	2901
01/04/2020	2903	2903	2885	2921	2896
01/05/2020	2901	2901	2883	2919	2897
01/06/2020	2901	2901	2882	2919	2899
01/07/2020	2898	2898	2879	2917	2894
01/08/2020	2903	2903	2884	2923	2907
01/09/2020	2907	2907	2887	2926	2896
01/10/2020	2902	2902	2882	2922	2901
01/11/2020	2896	2896	2876	2917	2895
01/12/2020	2904	2904	2884	2925	2898
01/01/2021	2901	2901	2880	2921	2890
01/02/2021	2903	2903	2882	2924	2907
01/03/2021	2901	2901	2880	2922	2909
01/04/2021	2903	2903	2881	2924	2901
01/05/2021	2901	2901	2879	2923	2893
01/06/2021	2900	2900	2879	2922	2902
01/07/2021	2898	2898	2875	2921	2905
01/08/2021	2903	2903	2880	2926	2895
01/09/2021	2907	2907	2883	2930	2899
01/10/2021	2902	2902	2878	2925	2894
01/11/2021	2896	2896	2873	2920	2897
01/12/2021	2904	2904	2880	2928	2901
01/01/2022	2900	2900	2876	2924	2904
01/02/2022	2903	2903	2879	2927	2895
01/03/2022	2901	2901	2876	2925	2902
01/04/2022	2903	2903	2878	2927	2898
01/05/2022	2901	2901	2876	2926	2889
01/06/2022	2900	2900	2875	2925	2905
01/07/2022	2898	2898	2872	2924	2901
01/08/2022	2903	2903	2877	2929	2897
01/09/2022	2906	2906	2880	2933	2901
01/10/2022	2901	2901	2875	2928	2905
01/11/2022	2896	2896	2870	2923	2905
01/12/2022	2904	2904	2877	2931	2899
01/01/2023	2900	2900	2873	2927	2891
01/02/2023	2903	2903	2875	2930	2897
01/03/2023	2901	2901	2873	2928	2895



01/04/2023	2903	2903	2875	2930	2901
------------	------	------	------	------	------

Fonte: Autores

Figura 1. Comparação entre Séries Temporais e Simulação de Monte Carlo



Fonte: Autores

Este trabalho apresenta um estudo envolvendo a aplicação dos métodos de Simulação de Monte Carlo e Séries temporais no Microsoft Excel®, não foram consideradas as bases teóricas de: Média móvel, Média móvel ponderada, Método da suavização exponencial simples, Método Holt Winter e Estimativa de mínimos quadrados, pois o objetivo do trabalho era minimizar os problemas oriundos na previsão de vendas em um fabricante de componentes mecânicos, visando possibilitar uma base de dados para tomada de decisão.

A partir das simulações de Monte Carlo, ficou evidenciado que são necessários ajustes nas previsões de venda, pois não se mostrou um método confiável, em média geral dos produtos testados e evidenciados através de dados históricos, seus resultados ficaram abaixo de 90% de acuracidade, sendo as simulações realizadas no programa Microsoft Excel®, enquanto com a Simulação com Séries Temporais, foi possível verificar que as médias atendiam e os limites inferiores e superiores, eram compatíveis com as vendas através dos métodos de análise de dados do programa Microsoft Excel®, foi possível identificar e fundamentar previsão de vendas em um fabricante de componentes mecânicos, é possível fazer simulações de probabilidades preventivistas para o pleno atendimento da demanda

## 5. Considerações finais

As considerações finais deste estudo, que explorou a previsão de vendas em um fabricante de componentes mecânicos, revelam aspectos relevantes para a gestão eficaz de operações e tomada de decisão em organizações similares. A previsão de vendas, sem dúvida, desempenha um papel crucial em evitar o excesso de estoque, atendendo às demandas dos clientes de maneira eficaz e minimizando os custos operacionais. No entanto, a busca pela acuracidade nas previsões é um desafio constante.

A análise das técnicas empregadas destacou a utilidade da Simulação de Monte Carlo e da abordagem de Séries Temporais. Enquanto a Simulação de Monte Carlo oferece uma perspectiva valiosa ao lidar com incerteza e risco, os resultados apresentaram acuracidade inferior a 90%, levantando preocupações sobre sua confiabilidade em previsões de vendas. Por outro lado, a Simulação com Séries Temporais demonstrou resultados mais consistentes, fornecendo médias alinhadas com as vendas reais e limites inferiores e superiores adequados.

Uma observação importante é que a escolha da plataforma Microsoft Excel® para a implementação das técnicas torna este estudo acessível a um espectro de organizações, eliminando a necessidade de investir em sistemas de Planejamento de Recursos Empresariais (ERPs) complexos e dispendiosos. Isso ressalta a importância da acessibilidade e da utilidade prática das metodologias utilizadas.

Em termos de aplicação prática, este estudo sugere que a abordagem de Séries Temporais é preferível ao usar o Microsoft Excel® para a previsão de vendas em fabricantes de componentes mecânicos. A capacidade de alinhar as médias das previsões com as vendas reais oferece uma base mais sólida para a tomada de decisão e a gestão da demanda. Além disso, a análise das Séries Temporais permite uma compreensão mais profunda dos padrões sazonais e tendências de vendas ao longo do tempo.

A previsão de vendas é um desafio contínuo para as organizações, e a escolha da técnica apropriada desempenha um papel significativo. Este estudo contribui ao demonstrar que a Simulação de Monte Carlo, embora valiosa em muitos contextos, pode não ser a melhor escolha para previsões de vendas em empresas de componentes mecânicos. A preferência pela abordagem de Séries Temporais oferece uma solução mais confiável, promovendo a eficácia das operações e a gestão de estoque de forma mais precisa, com a utilização Microsoft Excel®, mas se o *mix* de produtos for crescente, é importante considerar a aquisição de um ERP.

## Referências

ANDRADE, E. L. **Introdução à Pesquisa Operacional** - Métodos e Modelos para Análise de Decisões. 5. ed. [s.l.] Ltc, 2015.

BOX, G. E. P. *et al.* **Time series analysis: Forecasting and control**. 5. ed. Nashville, TN, USA: John Wiley & Sons, 2015.

BUENO, L.P. **Métodos estatísticos básicos em seguros gerais**. Rio de Janeiro: CPES, 2017.

CERAVOLO, F. E. *et al.* CFD Simulation of isothermal upward two-phase flow in a vertical annulus using interfacial area transport equation: Simulação Computacional de fluxo bifásico ascendente isotérmico em um anel vertical usando a equação de transporte de área interfacial. **Concilium**, v. 23, n. 15, p. 21–48, 2023.

CHOROL, L.; GUPTA, S. K. Evaluation of groundwater heavy metal pollution index through analytical hierarchy process and its health risk assessment via Monte Carlo simulation. **Process safety and environmental protection: transactions of the Institution of Chemical Engineers**, Part B, v. 170, p. 855–864, 2023.

EHLERS, R. S. **Análise de Séries Temporais**. 4ª edição ed. Paraná: Laboratório de Estatística e Geoinformação Universidade Federal do Paraná, 2007.

GENTLE, J. E. **Random number generation and Monte Carlo methods**. 1998. ed. Nova Iorque, NY, USA: Springer, 2013.

GIL, A. C. **Métodos e Técnicas de Pesquisa Social**. 7. ed. São Paulo: Atlas, 13 março 2019.

HAJIRAHIMI, Z.; KHASHEI, M. Hybridization of hybrid structures for time series forecasting: a review. **Artificial intelligence review**, v. 56, n. 2, p. 1201–1261, 2023.

HOSSEINZADEH, M. *et al.* Probabilistic health risk assessment of occupational exposure to BTEX in a paint manufacturing plant using Monte-Carlo simulation. Human and ecological risk assessment: **HERA**, v. 29, n. 3–4, p. 859–880, 2023.

JESÚS GONZÁLEZ, A.; RANGEL VÁZQUEZ, N. A. PM3 semi-empirical method and Monte Carlo simulation application on pesticides adsorption on SWCNT. *Colloids and interface science communications*, v. 53, n. 100699, p. 100699, 2023.

JIA, Y. *et al.* Latent Gaussian count time series. **Journal of the American Statistical Association**, v. 118, n. 541, p. 596–606, 2023.

KAUR, J.; PARMAR, K. S.; SINGH, S. Autoregressive models in environmental forecasting time series: a theoretical and application review. **Environmental science and pollution research international**, v. 30, n. 8, p. 19617–19641, 2023.

KRAJEWSKI, L.; RITZMAN, L.; MALHOTRA, M. **Administração de Produção e Operações**. 11. ed. [s.l.] Pearson Universidades, 20 novembro 2017.

LEE, S.; KIM, D.; KIM, B. Modeling and inference for multivariate time series of counts based on the INGARCH scheme. **Computational statistics & data analysis**, v. 177, n. 107579, p. 107579, 2023.

LI, J. *et al.* Monte Carlo simulations of deformation behaviour of unbound granular materials based on a real aggregate library. **International journal of pavement engineering**, v. 24, n. 1, 2023.

MARTÍNEZ-HERNÁNDEZ, I.; GENTON, M. G. Surface time series models for large spatio-temporal datasets. **Spatial statistics**, v. 53, n. 100718, p. 100718, 2023.

MASINI, R. P.; MEDEIROS, M. C.; MENDES, E. F. Machine learning advances for time series forecasting. **Journal of Economic Surveys**, v. 37, n. 1, p. 76–111, 2023.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de Séries Temporais**. 2ª edição ed. São Paulo: Editora Blucher, 2006.

MOTA, P. H. A. **Modelagem numérico-computacional multiníveis de processos de corrosão em sistemas fluidodinâmicos**. 2023.

OLIVEIRA, G. **Simulação de Monte Carlo e Valuation**: Uma Abordagem Estocástica. *Revista de Gestão*, v. 19, n. 3, p. 493-512, 2012.

PAIXÃO, K. W. M.; SILVA, A. M. DA. Sales forecasting in a mechanical component manufacturer: comparison between monte carlo simulation and time series analysis. **Independent Journal of Management & Production**, v. 10, n. 4, p. 1324, 2019.

PAL, A.; PRAKASH, P. K. S. **Practical Time Series Analysis**: Master Time Series Data Processing, Visualization, and Modeling using Python. [s.l.] Packt Publishing, 2017.

PEDERSEN, M. **Monte Carlo Simulation in Financial Valuation**. Disponível em: <https://ssrn.com/abstract=2332539>. Acesso em: 18 de out. 2023.

PUMI, G.; PRASS, T. S.; LOPES, S. R. C. A novel copula-based approach for parametric estimation of univariate time series through its covariance decay. **Statistical papers** (Berlin, Germany), 2023.

- RUDIO, F. V. **Introdução ao projeto de pesquisa científica**. 43. ed. Petrópolis: Editora Vozes, 1 janeiro 2015.
- SANTOS, M. P. **Introdução a simulação discreta**. Rio de Janeiro, 1 edition, 1999.
- SAVVIDES, C. *Risk Analysis in Investment Appraisal*. **Project Appraisal**, v. 9, n. 1, p. 3-18, 1994.
- SOHRABI, P.; JODEIRI SHOKRI, B.; DEHGHANI, H. Predicting coal price using time series methods and combination of radial basis function (RBF) neural network with time series. **Mineral economics**, v. 36, n. 2, p. 207–216, 2023.
- SOUZA, L. A. L. *et al.* Simulação computacional e Big Data como inserção tecnológica em processos industriais: uma revisão sistemática da literatura: Computational simulation and Big Data as technological insertion in industrial processes: a systematic literature review. **Brazilian Journal of Business**, v. 5, n. 2, p. 1110–1125, 2023.
- ŚWIECHOWSKI, M. *et al.* Monte Carlo Tree Search: a review of recent modifications and applications. **Artificial intelligence review**, v. 56, n. 3, p. 2497–2562, 2023.
- TAHA, H A. **Pesquisa operacional: uma visão geral**. 8. ed. São Paulo: Pearson, 2008
- TALAGALA, T. S.; HYNDMAN, R. J.; ATHANASOPOULOS, G. Meta-learning how to forecast time series. **Journal of forecasting**, v. 42, n. 6, p. 1476–1501, 2023.
- TSAMTSAKIRI, P.; KARLIS, D. On Bayesian model selection for INGARCH models viatrans-dimensional Markov chain Monte Carlo methods. **Statistical modelling**, v. 23, n. 1, p. 81–98, 2023.
- TUBINO, D. F. **Planejamento e Controle da Produção - Teoria e Prática**. 3. ed. São Paulo: Atlas, 2022.
- WANG, L. *et al.* Quantification of model uncertainty and variability for landslide displacement prediction based on Monte Carlo simulation. *Gondwana research: international geoscience journal*, v. 123, p. 27–40, 2023.
- YIN, R. K. **Estudo de Caso - Planejamento e Métodos**. 5. Ed. Porto Alegre: Bookman, 27 outubro 2014.