



PREVISÃO DE DEMANDA CONTRATADA EM INDÚSTRIAS VIA MÉTODODE MONTE CARLO: UMA ABORDAGEM DIDÁTICA PARA A EDUCAÇÃOEM ENGENHARIA

DOI: 10.37702/2175-957X.COBENGE.2025.6047

Autores: ALDO CESAR DOS REIS, LUCAS SILVA PLACHI, CARLOS EDUARDO ALVES CARVALHO, TÁLISSON DE SOUZA BARBOSA

Resumo: Este artigo apresenta uma abordagem didática do Método de Monte Carlo para previsão de demanda energética industrial. Considerando a complexidade do setor e a necessidade de eficiência, o método probabilístico mostra-se eficaz para tratar incertezas no consumo energético. O estudo detalha as etapas: modelagem matemática, cálculo de variações históricas, geração de amostras aleatórias e análise estatística. Aplicando dados reais de uma indústria automotiva do sul de Minas Gerais Brasil, cobrindo o período de 2020 a 2023, foram realizadas 1.000.000 de simulações em Python para prever a demanda de 2024. Os resultados mostraram alinhamento entre previsões e consumo real, validando o método. Os resultados demonstraram forte alinhamento entre as previsões e o consumo real, validando a precisão e praticidade do método. O artigo também destaca o valor educacional desta abordagem, promovendo habilidades analíticas e tomada de decisão sob incerteza em estudantes de engenharia.

Palavras-chave: Simulação de Monte Carlo, Educação em Engenharia, Previsão de Demanda Contratada

PREVISÃO DE DEMANDA CONTRATADA EM INDÚSTRIAS VIA MÉTODO DE MONTE CARLO: UMA ABORDAGEM DIDÁTICA PARA A EDUCAÇÃO EM ENGENHARIA

1 INTRODUÇÃO

A crescente complexidade do setor industrial e as exigências por maior eficiência energética têm impulsionado o desenvolvimento e a aplicação de métodos avançados de previsão de consumo e demanda contratada de energia elétrica. Em um cenário onde oscilações na produção, sazonalidades e variações operacionais influenciam significativamente o perfil de consumo, torna-se fundamental adotar estratégias quantitativas que possibilitem estimativas mais realistas e seguras da demanda energética. Dentre os métodos existentes, destaca-se o Método Monte Carlo, cuja natureza probabilística o torna especialmente adequado para lidar com incertezas e variabilidades presentes em problemas reais de engenharia (CULLEN, 1999).

O Método Monte Carlo consiste em uma técnica de simulação estocástica baseada na geração de números aleatórios para a modelagem de sistemas complexos e aleatórios. Sua origem remonta aos trabalhos de Metropolis e Ulam na década de 1940, durante o Projeto Manhattan, com o objetivo de resolver problemas relacionados à física nuclear (METROPOLIS; ULAM, 1949). Desde então, o método tem sido amplamente utilizado em diversas áreas, como finanças, engenharia, ciências atuariais e, mais recentemente, na previsão energética (RUBINSTEIN; KROESE, 2017).

A simulação estocástica, da qual o Método Monte Carlo faz parte, difere das abordagens determinísticas por incorporar incertezas de forma explícita, utilizando distribuições de probabilidade para representar variáveis de entrada. Essa abordagem permite capturar a variabilidade inerente a sistemas reais, tornando os resultados mais representativos e úteis para a tomada de decisão. No contexto energético, a aplicação desse método permite a modelagem de diferentes cenários de consumo, considerando fatores como produção variável, turnos operacionais, climatologia, entre outros elementos que impactam diretamente a demanda de energia (LAW, 2015).

No entanto, apesar de sua robustez, a aplicação prática do Método Monte Carlo exige domínio técnico por parte dos profissionais envolvidos, o que ressalta a importância de metodologias eficazes de ensino-aprendizagem de tal ferramenta. Ensinar esse método de forma clara e contextualizada pode contribuir significativamente para a formação de engenheiros mais preparados para lidar com problemas reais de previsão energética, promovendo assim, a cultura de análise quantitativa e tomada de decisão baseada em dados.

Neste artigo, propõe-se uma abordagem didática para o ensino-aprendizagem do Método Monte Carlo voltada à previsão de demanda contratada no setor industrial. Através da apresentação dos conceitos teóricos fundamentais, da estruturação das etapas de simulação e da análise de estudos de caso práticos, busca-se demonstrar não apenas a viabilidade da aplicação do método, mas também sua relevância educacional. Espera-se, com isso, contribuir para o fortalecimento da formação de engenheiros com capacidade analítica ampliada e sensibilidade para os desafios energéticos contemporâneos.

2 METODOLOGIA

A simulação de Monte Carlo é um método matemático/estatístico, criado por John Von Neumann e Stanislaw Ulam, durante a Segunda Guerra Mundial, a fim de tratar as incertezas associadas às tomadas de decisão na guerra (IBM, 2025).

A simulação por meio do método de Monte Carlo caracteriza-se por explorar diferentes possibilidades futuras a partir de condições iniciais conhecidas de um sistema. Utilizando parâmetros estatísticos como média, desvio padrão e a suposição de distribuição normal, essa abordagem incorpora elementos de aleatoriedade para gerar uma ampla variedade de cenários. O resultado final é a projeção prospectiva composta por múltiplos desfechos possíveis, que vão desde os mais conservadores até os mais otimistas (Raychaudhuri, 2008, p. 2).

Este trabalho adota o método de Monte Carlo como ferramenta de análise e simulação. Já que o método se posiciona como técnica probabilística que utiliza amostragem aleatória para estimar o comportamento de sistemas complexos e incertos, sendo especialmente útil quando soluções analíticas são inviáveis ou de difícil obtenção, o mesmo se mostra adequado à estimação de cenários futuros de demanda para grandes consumidores de energia elétrica.

2.1 Etapas do Método de Monte Carlo

A implementação do método seguiu as etapas descritas a seguir:

2.1.1. Modelagem do problema

Para que o método de Monte Carlo possa ser aplicado é preciso, primeiramente modelar o problema desejado de forma matemática, implementando as variáveis de entrada que serão usadas de banco de dados, neste caso os dados reais de demanda medida durante 4 anos de determinado consumidor do subgrupo A4, do ramo de lanternas automotivas, localizado no Sul de Minas Gerais. Essas variáveis, serão tratadas como variáveis aleatórias, associadas a distribuições de probabilidade previamente conhecidas, ou estimadas com base no banco de dados, que irá conter valores históricos passados já registrados.

Para fins didáticos, será considerado que a variável desejada é do tipo normal, ou seja, possui variações simétricas e que seus valores foram registrados durante o período de 4 anos no intuito de estimar a previsão para o 5º ano.

Vale ressaltar que quanto maior o número de períodos e variáveis no banco de dados, mais preciso será o resultado a ser estimado.

2.1.2. Cálculo de variação entre os períodos registrados

Após estabelecer o banco de dados, que deve ser confiável e sólido, é necessário atribuir um intervalo para as diversas simulações aleatórias. Uma maneira eficaz de se fazer isso é calculando a variação pela diferença do valor atribuído durante cada ano.

$$\text{Variação} = [\text{Ano 2} - \text{Ano 1}, \text{Ano 3} - \text{Ano 2}, \text{Ano 4} - \text{Ano 3}] \quad (1)$$

Com os valores obtidos das variações, calcula-se a média e o desvio padrão desse vetor.

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n a_i \quad (2)$$

$$DP = \sqrt{\frac{\sum (x_i - \bar{x})^2}{n}}$$

onde: x_i = valor individual
 $\bar{x}$ = média dos valores
 n = número de valores

(3)

Assim define-se qual será a base de intervalo que a simulação irá gerar variações aleatórias.

2.1.3. Geração de amostras aleatórias

Utilizando algoritmos simples de geração de números aleatórios para criar um grande número de amostras independentes, obedecendo às distribuições de probabilidade definidas. A quantidade de simulações a serem realizadas (número de iterações) deve ser estabelecida de forma a garantir a convergência estatística dos resultados, respeitando critérios de precisão e confiabilidade.

A utilização de números aleatórios é um dos pilares fundamentais do método de Monte Carlo. Esses números permitem simular o comportamento estocástico de sistemas reais, cujos parâmetros ou condições iniciais apresentam variabilidade e incerteza. Inicialmente, são gerados números pseudoaleatórios com distribuição uniforme no intervalo [0,1], os quais, por meio de técnicas de transformação, como a transformada inversa, amostragem de rejeição ou métodos numéricos mais avançados, são convertidos em amostras representativas de distribuições de probabilidade específicas, como a normal, exponencial ou triangular. Essas amostras são então utilizadas como entradas para o modelo, possibilitando a realização de múltiplas simulações independentes.

A repetição massiva dessas simulações fornece uma distribuição estatística dos resultados de saída, permitindo a análise de médias, variâncias, intervalos de confiança e outros indicadores que representam o comportamento provável do sistema sob diferentes condições. Dessa forma, o uso sistemático de números aleatórios viabiliza a avaliação de cenários e a quantificação da incerteza de maneira robusta e abrangente (COWAN, 2009).

2.1.4. Resultados Estatísticos

Após a execução de todas as simulações, os resultados devem ser tratados estatisticamente. Para isso, soma-se os valores do último período registrado (4º ano) com os valores obtidos da simulação de geração números aleatórios.

Obtendo este vetor, calculando a média e o desvio padrão novamente podemos obter uma estimativa do valor esperado para o próximo período a partir da média e margem de erro aproximada a partir do desvio padrão encontrado.

2.1.5. Justificativa da escolha método

A escolha do método de Monte Carlo se justifica pela sua flexibilidade, robustez e eficácia na quantificação de incertezas. Ao contrário de métodos determinísticos, essa abordagem permite incorporar variabilidade nas condições iniciais e nos parâmetros do modelo, fornecendo uma análise mais realista e abrangente dos possíveis cenários.

Na engenharia, esse método é amplamente aplicado em análise de riscos, otimização de processos, previsão de desempenho de sistemas, controle de qualidade, entre outras áreas. Seja na engenharia civil para estimativas de custos e prazos, na engenharia mecânica


para simulações térmicas e estruturais, ou na engenharia elétrica para análise de confiabilidade de sistemas, o método de Monte Carlo proporciona uma abordagem robusta diante da variabilidade dos parâmetros envolvidos (STEVENS, 2023).

Portanto, o uso do método de Monte Carlo se mostra amplamente aplicável à inúmeras áreas do conhecimento de engenharia, permitindo que engenheiros tomem decisões mais informadas e embasadas estatisticamente, mesmo diante de cenários incertos e com grande quantidade de variáveis. Seu contínuo desenvolvimento, aliado ao avanço do poder computacional, tende a ampliar ainda mais seu papel estratégico nas soluções de engenharia moderna.

Para aplicação do método foi seguido o passo a passo descrito no fluxograma mostrado na Figura 1.

Figura 1 – Fluxograma do Processo de simulação do método Monte Carlo

FLUXOGRAMA–MÉTODO DE MONTE CARLO



Fonte: Autores

3 DESENVOLVIMENTO

No contexto da Engenharia Elétrica esse método também pode ser aplicado para problemas pontuais em indústrias, a previsão de demanda contratada. Os consumidores de energia no Brasil são classificados em dois grandes grupos conforme a tensão de atendimento no ponto de conexão comum (ANEEL, 2021, p. 6 e p. 111). O Grupo B reúne cargas de pequeno porte, como residências e estabelecimentos rurais, atendidas em tensões inferiores a 2,3 kV e submetidas ao sistema de tarifa monômnia, no qual o faturamento considera apenas o consumo energético. Em contrapartida, o Grupo A engloba os grandes consumidores, como indústrias e grandes empreendimentos comerciais, atendidos em tensões superiores a 2,3 kV e tarifados pelo modelo binômio, que incorpora tanto a cobrança pela demanda contratada

quanto a do consumo de energia, com ou sem segmentação horária. Dentro do Grupo A, os usuários são organizados em subgrupos de acordo com o nível de tensão e podem optar entre duas modalidades tarifárias: a horária azul, que estabelece tarifas distintas de demanda e de consumo para os postos de ponta e fora de ponta; e a horária verde, que prevê uma única tarifa de demanda sem diferenciação horária (ANEEL, 2021, p. 111).

Como supracitado, serão utilizados dados reais de demanda verificada de um consumidor do subgrupo A4, optante pela modalidade tarifária horária verde. O objetivo é explorar alternativas para a previsão de contratação de demanda para o ano de 2024 com base nos dados registrados da demanda medida no período dos 4 anos anteriores (2020-2023). Utilizando o 5º ano como referência para o teste de confiabilidade do método, buscando que essas estimativas se aproximem ao máximo do consumo real medido naquele ano, possibilitando assim, a posterior tomada de decisão quanto ao valor de demanda a ser contratado.

Os dados de demanda utilizados estão mostrados no Quadro 1:

Quadro 1 – Dados coletados da empresa

Meses	jan	fev	mar	abr	mai	jun	jul	ago	set	out	nov	dez
2020												
Demanda contratada (kW)	200	200	200	200	200	200	200	200	200	200	200	200
Demanda medida (kW)	159	154	153	160	150	162	150	155	157	159	153	154
2021												
Demanda contratada (kW)	200	200	200	200	200	200	200	200	200	200	200	200
Demanda verificada (kW)	179	172	174	189	170	183	170	169	167	178	177	209
2022												
Demanda contratada (kW)	200	200	200	200	200	200	200	200	200	300	300	300
Demanda verificada (kW)	207	213	224	241	267	274	269	271	281	279	281	276
2023												
Demanda contratada (kW)	300	300	300	300	300	300	300	300	300	300	300	300
Demanda verificada (kW)	273	285	278	268	280	292	292	297	299	290	303	303
2024												
Demanda contratada (kW)	400	400	400	400	400	400	400	400	400	400	400	400
Demanda verificada (kW)	312	326	341	333	338	344	330	345	369	389	396	390

Fonte: Autores

Esses registros servirão para a construção do banco de dados utilizado na simulação, cujo objetivo é prever a demanda a ser verificada de cada mês do ano de 2024. A previsão será realizada a partir dos valores inscritos nos meses correspondentes dos anos anteriores.

Dado que esse método exige a geração de milhares de possibilidades pseudo aleatórias, optou-se pela implementação de uma rotina em linguagem Python, facilitando e automatizando esse processo. Além disso, considerando que os dados serão atualizados mensalmente, o uso de recursos computacionais traz maior dinamismo e flexibilidade ao tratamento desses dados, reforçando a escolha por essa abordagem.


O código do programa contém todos os passos do processo de aplicação do método de Monte Carlos descritos anteriormente, voltados a satisfazer as condições desse caso em específico. Esperando um resultado que demonstrasse todo o potencial da aplicação de Monte Carlo, foram utilizadas 1.000.000 gerações de possibilidades para obter um valor mais preciso.

Aplicando essa abordagem mês a mês foi obtido o relatório das possíveis demandas medidas durante todo o ano de 2024 seus resultados serão analisados e comparados com os valores reais desse mesmo ano.

4 RESULTADOS


A geração das simulações para cada mês foi registrada graficamente, relacionando a potência demandada e a frequência dos resultados das simulações, compondo as curvas normais, apresentadas nos gráficos apresentados nas Figuras 2 e 3:

Figura 2 – Distribuição das previsões de demanda para o primeiro semestre de 2024



Fonte: Autores

Figura 3 – Distribuição das previsões de demanda para o segundo semestre de 2024



Fonte: Autores

A Figura 2 indica os resultados da simulação para a previsão para o 4º ano sendo de 311.00 kW (± 20.06) para o mês de janeiro, 326.65 kW (± 22.10) para o mês de fevereiro, 317.00 kW (± 14.16) para o mês de março, 303.35 kW (± 16.98) para o mês de abril, a 319.00 kW (± 31.92) para o mês de maio, 334.65 kW (± 33.49) para o mês de junho.


A Figura 3 indica os resultados da simulação para a previsão para o 4º ano sendo de 334.33 kW (± 29.50) para o mês julho, 340.64 kW (± 29.35) para o mês agosto, 342.98 kW ($\pm$

35.34) para o mês de setembro, 330.69 kW (± 35.76) para o mês de outubro, 347.68 kW (± 33.48) para o mês de novembro, 347.33 kW (± 29.58) para o mês de dezembro. Entre parênteses está o valor do erro das simulações.

Nota-se que na proporção que a variação dos dados de entrada aumenta o erro também aumenta.

Dado os resultados das simulações, fora feita o gráfico comparando a potência real, a potência estimada e a demanda contratada para fins comparativos apresentados no gráfico apresentado na Figura 4.

Figura 4 – Gráfico comparativo de resultados



Fonte: Autores

Observa-se na Figura 4, a presença de uma curva paralela na cor azul, deslocada 5% em relação aos resultados da simulação, ela tem como objetivo servir como parâmetro para estabelecer a confiabilidade e precisão do método. Essa diferença também pode ser atribuída ao critério regulatório estabelecido pela ANEEL (2021, p. 134), segundo o qual, se no mês vigente a demanda registrada for inferior ou igual a 5% abaixo do valor contratado, o consumidor será faturado com base no valor contratado, sem incidência de multa por ultrapassagem.

A linha em cinza representa o consumo real da empresa, em vermelho o que foi contratado, com isso é visível a diferença entre os valores, em amarelo é a previsão pelo método Monte Carlo, vale destacar que, caso a empresa em questão optasse por um modelo de contratação mensal de demanda, a aplicação deste método estatístico poderia se mostrar uma ferramenta valiosa para embasar decisões quanto à quantidade de potência a ser

contratada. Essa abordagem possibilitaria não apenas uma potencial redução de custos, mas também o fortalecimento de práticas voltadas à eficiência energética.

Considerando a análise de todos os gráficos apresentados anteriormente, observa-se que os resultados obtidos na previsão de demanda para o ano de 2024 apresentam forte consonância com os valores reais contratados. A maior taxa de erro registrada foi da ordem de 60 kW, valor considerado aceitável dentro do contexto deste estudo, especialmente considerando que a base de dados utilizada foi composta exclusivamente por medições de demanda de anos anteriores. Em cenários que envolvam um maior número de variáveis, é esperado que a acurácia da metodologia adotada seja ainda mais elevada.

5 CONSIDERAÇÕES FINAIS

A partir da análise dos resultados obtidos e dos fatos apresentados, constatou-se que o método de Monte Carlo é viável, pois obteve-se resultados coerentes e também se revelou uma ferramenta extremamente valiosa no contexto do ensino de engenharia, não apenas por sua aplicabilidade em diversos ramos da área, mas também por sua capacidade de tornar o aprendizado mais dinâmico, intuitivo e próximo da realidade prática. Ao permitir a análise de problemas complexos por meio da simulação de múltiplos cenários, esse método favorece o desenvolvimento do pensamento probabilístico, da análise crítica e da tomada de decisão sob incerteza, competências fundamentais para a formação de engenheiros mais preparados para os desafios do mundo real.

Além disso, sua natureza computacional estimula o uso de ferramentas modernas e promove a interdisciplinaridade, integrando conhecimentos de estatística, programação e modelagem. Por essas razões, o método de Monte Carlo se destaca como uma abordagem pedagógica eficaz, contribuindo significativamente para a formação sólida e completa dos futuros profissionais da engenharia.

AGRADECIMENTOS

Os autores deste trabalho gostariam de registrar seus mais sinceros agradecimentos a todas as pessoas e instituições que, de alguma forma, contribuíram para a realização deste estudo.

Em primeiro lugar agradecemos a Deus e expressamos profunda gratidão ao magnífico professor Tálisson de Souza Barbosa, cuja orientação precisa, incentivo constante e disponibilidade ao longo de todo o processo foram fundamentais para o desenvolvimento do artigo. A dedicação e o conhecimento compartilhados foram essenciais para a consolidação das ideias aqui apresentadas, sendo uma fonte permanente de inspiração e motivação.

Agradecimentos especiais são direcionados também aos colegas de pesquisa e amigos que estiveram presentes durante a trajetória acadêmica até o momento. As trocas de ideias, as críticas, todo apoio significativo na construção deste trabalho, tornando o percurso mais produtivo e enriquecedor.

Agradecimentos ainda ao suporte institucional da PUC Minas, responsável por fornecer os recursos necessários e criar um ambiente propício à pesquisa. Destaca-se também o reconhecimento aos profissionais da instituição que viabilizaram a realização do projeto por meio do apoio técnico.

Aos familiares, os autores expressam sincera gratidão pelo carinho, paciência e compreensão ao longo de toda a jornada. O apoio emocional e a confiança foram fundamentais para que o trabalho pudesse ser conduzido com serenidade e persistência, mesmo diante dos desafios.

Por fim, os autores estendem seus agradecimentos a todos aqueles que, direta ou indiretamente, contribuíram para a concretização deste estudo. Cada gesto de apoio e cada palavra de encorajamento tiveram grande importância para a conclusão desta etapa acadêmica.

REFERÊNCIAS

ANEEL – Agência Nacional de Energia Elétrica, (2021). **Resolução Normativa ANEEL nº 1.000, de 7 de dezembro de 2021**. Brasília: Governo Federal. Disponível em: <https://www2.aneel.gov.br/cedoc/ren20211000.html>. Acesso 18 abr. 2025.

COWAN, G. (2009). Monte Carlo Techniques. In K. Nakamura et al. (Eds.), Review of Particle Physics. Physics Letters B, 667(1).

CULLEN, Kathleen Ann. **Forecasting electricity demand using regression and Monte Carlo simulation under conditions of insufficient data**. 1999. 1 v. Dissertação (Mestrado em Economia) – Chambers College of Business and Economics, West Virginia University, Morgantown, 1999. Disponível em: <https://researchrepository.wvu.edu/etd/974>. Acesso em: 27 abr. 2025

IBM, (2025). O que é a Simulação de Monte Carlo?. IBM - United States. Disponível em: <https://www.ibm.com/br-pt/topics/monte-carlo-simulation>. Acesso 18 abr. 2025.

LAW, Averill M. **Simulation Modeling and Analysis**. 5. ed. New York: McGraw-Hill Education, 2015.

METROPOLIS, N., & ULAM, S. (1949). The Monte Carlo Method. Journal of the American Statistical Association, 44(247), 335–341.

RAYCHAUDHURI, S., (2008). **Introduction to Monte Carlo simulation**. Winter Simulation Conference (WSC), 7–10 de dezembro de 2008, Miami, FL, USA . IEEE. [Consultado em 17 de março de 2025]. Disponível em: doi: 10.1109/wsc.2008.4736059

RUBINSTEIN, R. Y., & Kroese, D. P. (2017). **Simulation and the Monte Carlo Method**. 3. ed. Wiley.

STEVENS, Alan. **Monte-Carlo simulation: an introduction for engineers and scientists**. Boca Raton: CRC Press, 2023.

**INSTRUCTIONS FOR PREPARATION AND SUBMISSION OF MANUSCRIPTS TO THE
SCIENTIFIC COMMITTEE OF THE 53º BRAZILIAN CONGRESS ON ENGINEERING
EDUCATION AND VIII INTERNATIONAL SYMPOSIUM ON EDUCATION IN ENGINEERING
– COBENGE 2025**

Abstract: *This article presents a didactic approach to the Monte Carlo Method for industrial energy demand forecasting. Considering the sector's complexity and efficiency needs, this probabilistic method proves effective in addressing energy consumption uncertainties. The study details the steps: mathematical modeling, calculation of historical variations, generation of random samples, and statistical analysis. Using real data from an automotive industry in southern Minas Gerais, Brazil, covering the period from 2020 to 2023, 1,000,000 simulations were performed in Python to forecast demand for 2024. The results showed alignment between predictions and actual consumption, validating the method. The results demonstrated strong alignment between forecasts and actual consumption, validating the method's accuracy and practicality. The article also highlights the educational value of this approach, promoting analytical skills and decision-making under uncertainty in engineering students.*

Keywords: *Monte Carlo Simulation; Contracted Demand Forecasting; Energy Efficiency; Industrial Engineering; Stochastic Modeling; Energy Consumption; Engineering Education; Python Programming; Quantitative Analysis; Uncertainty Analysis.*

