

SIMULAÇÃO DE MONTE CARLO PARA AVALIAÇÃO DE RISCO DE INVESTIMENTO EM EMPRESAS DO SETOR DE MINERAÇÃO DA B3

José Ronaldo do Nascimento
José.nascimento@estudante.ufla.br

Daniel dos Santos Cola
daniel.santos8@estudante.ufla.br

Rômula Keli Marino
romula.marino1@estudante.ufla.br

Larissa Xavier Lima Cecoti
larissa.cecoti@estudante.ufla.br

Cristina Lélis Leal Calegario
ccalegario@ufla.br

RESUMO: Este estudo analisou o risco e a eficiência de portfólios compostos por empresas do setor de mineração listadas na B3, utilizando a Simulação de Monte Carlo (SMC) como ferramenta de modelagem probabilística. Foram selecionados dez ativos do setor, cujos preços de fechamento mensais, entre 2022 e 2025, foram coletados e tratados para o cálculo dos retornos logarítmicos. A pesquisa incorporou métricas de risco como Value at Risk (VaR) e Conditional Value at Risk (CVaR), além de avaliar diferentes estratégias de alocação: pesos iguais, alocação aleatória e otimização pela média-variância de Markowitz. Os resultados demonstraram que a SMC possibilita identificar padrões de dispersão de retornos, evidenciando cenários de ganhos expressivos e de perdas significativas. Verificou-se ainda que estratégias de otimização apresentam maior eficiência em termos de retorno ajustado ao risco (Índice de Sharpe), quando comparadas às combinações aleatórias. Por fim, a análise de robustez mostrou que, embora os retornos médios dos portfólios permaneçam relativamente estáveis em diferentes cenários adversos, a assimetria entre ganhos potenciais e perdas extremas ressalta a importância da gestão ativa de risco. Assim, a SMC se confirma como um instrumento relevante para apoiar decisões de investimento em setores voláteis, como o de mineração.

Palavras-chave: simulação de Monte Carlo; *Value at Risk* (VaR); *Conditional Value at Risk* (CVaR); setor de mineração; B3.

1 INTRODUÇÃO

O setor de mineração ocupa posição estratégica na economia global e brasileira, sendo responsável pelo fornecimento de insumos para diversas cadeias produtivas. No entanto, trata-se de um segmento caracterizado por forte volatilidade, influenciada pela flutuação dos preços das commodities, instabilidades políticas, variações cambiais e riscos ambientais. Essas características aumentam a incerteza para investidores e gestores de portfólios, tornando indispensável o uso de metodologias quantitativas robustas para avaliar e mitigar riscos (Saputra et al., 2023; Indarwati; Kusumawati, 2021).

Entre essas metodologias utilizadas, a Simulação de Monte Carlo (SMC) se destaca por sua capacidade de reproduzir diferentes cenários de forma probabilística. Em vez de oferecer uma previsão única e determinística, essa técnica gera opções de trajetórias possíveis para os retornos de ativos, permitindo uma visão mais realista sobre os riscos e oportunidades de investimento. Essa flexibilidade faz da SMC uma ferramenta capaz de avaliar a dispersão dos resultados futuros e identificar a probabilidade de perdas extremas (Glasserman; Heidelberger; Shahabuddin, 2001). Além disso, estudos reforçam que a aplicação da SMC em diferentes setores tem se mostrado eficaz para compreender a relação entre risco e retorno, especialmente em contextos de elevada volatilidade (Syahchari; Hapsari, 2022)

Diante da elevada volatilidade e da forte interdependência entre empresas do setor de mineração listadas na B3, como a SMC, associada às métricas de risco Value at Risk (VaR) e Conditional Value at Risk (CVaR), pode contribuir para avaliar a eficiência e a resiliência de portfólios desse setor em diferentes estratégias de alocação e cenários de mercado?

A relevância desse estudo parte da crescente complexidade dos mercados financeiros e na necessidade de ferramentas para mensurar e mitigar riscos, sobretudo em setores sensíveis a oscilações macroeconômicas e de demanda global, como o de mineração. A volatilidade dos preços das commodities, associada a fatores externos como instabilidade política, variações cambiais e mudanças regulatórias, intensifica a incerteza sobre o desempenho das empresas listadas na B3. Nesse contexto, a utilização de métodos quantitativos avançados, como a SMC, contribui para a construção de cenários probabilísticos mais realistas, permitindo ao investidor compreender não apenas as expectativas médias de retorno, mas também a amplitude e a probabilidade de perdas significativa (Indarwati; Kusumawati, 2021).

A pesquisa tem como objetivo geral: avaliar o risco e a eficiência de portfólios compostos por empresas do setor de mineração da B3, por meio da Simulação de Monte Carlo e do uso das métricas VaR e CVaR, comparando diferentes estratégias de alocação de ativos e cenários de mercado.

Sendo assim os objetivos específicos são: (i) Mensurar a correlação entre os ativos do setor de mineração, identificando relações fortes e fracas que influenciam a diversificação e o risco do portfólio; (ii) Aplicar a SMC para projetar a evolução do capital investido, considerando distribuições probabilísticas dos retornos; (iii) Calcular e interpretar as métricas de risco (VaR e CVaR), avaliando a exposição do portfólio a perdas em cenários de estresse; (iv) Comparar portfólios formados por alocação aleatória, pesos iguais e otimização pela média-variância de Markowitz, verificando ganhos de eficiência em termos de retorno ajustado ao

risco (Índice de Sharpe); (v) Analisar padrões de risco-retorno dos portfólios simulados, identificando a existência de trade-offs entre volatilidade e expectativa de retorno.

Nesse contexto, o uso de métodos quantitativos avançados, como a SMC, mostra-se particularmente relevante. A técnica permite estimar a distribuição probabilística dos retornos e mensurar de forma mais realista a incerteza associada às decisões de investimento, complementando métricas tradicionais de risco como o VaR e o CVaR. Além disso, possibilita avaliar diferentes cenários de alocação de portfólio, desde estratégias balanceadas até combinações otimizadas, oferecendo suporte à gestão ativa e ao processo decisório em ambientes de alta complexidade.

Assim, a presente pesquisa se justifica por sua relevância prática, ao fornecer subsídios para investidores, gestores e demais agentes do mercado financeiro no entendimento dos riscos do setor de mineração, e por sua contribuição acadêmica, ao aplicar a SMC de forma integrada à teoria de portfólios de Markowitz, testando sua aplicabilidade em um contexto específico e altamente representativo da economia brasileira.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Teoria de Portfólios e Risco

A teoria moderna de portfólios, proposta por Markowitz (1952), revolucionou a forma de compreender investimentos ao introduzir o modelo de média-variância. Esse arcabouço destaca que a diversificação pode reduzir o risco não sistemático sem comprometer o retorno esperado. Conforme reforça Elton e Gruber (1995), a diversificação eficiente depende não apenas do número de ativos, mas sobretudo da correlação entre eles.

Complementando essa abordagem, Sharpe (1964) desenvolveu o Capital Asset Pricing Model (CAPM), que relaciona o risco sistemático, medido pelo beta, ao retorno esperado de um ativo. O modelo evidencia que os investidores devem ser compensados apenas pelo risco de mercado, já que o risco diversificável pode ser eliminado. De acordo com Bodie, Kane e Marcus (2014), o CAPM permanece como um dos modelos mais utilizados na precificação de ativos, apesar de críticas sobre suas premissas simplificadoras.

2.2 Simulação de Monte Carlo (SMC) em Finanças

A SMC é amplamente aplicada em finanças pela capacidade de incorporar incerteza e variabilidade em modelos probabilísticos. O pioneiro estudo de Boyle (1977) demonstrou a utilidade da técnica na precificação de opções, abrindo caminho para aplicações em derivativos complexos.

Segundo Glasserman (2004), a SMC tornou-se uma das principais ferramentas da engenharia financeira, permitindo analisar o comportamento de carteiras em cenários estocásticos. Já Metropolis e Ulam (1949), considerados os precursores do método, mostraram sua aplicabilidade em problemas de física e matemática, antes de sua adoção nas finanças.

Além disso, Phelim Boyle, Mark Broadie e Paul Glasserman (1997) destacam que a SMC é especialmente útil quando o número de variáveis aleatórias é elevado e os métodos

analíticos tradicionais se tornam inviáveis. Kroese et al. (2014) reforçam que, devido à sua flexibilidade, a técnica continua sendo atual para modelagem de risco, precificação de ativos e gestão de incertezas.

2.3 Métricas de Risco em Carteiras

As métricas de risco são essenciais para avaliar a robustez de investimentos. O VaR, amplamente difundido após os estudos de Jorion (2007), estima a perda máxima esperada em um horizonte temporal para determinado nível de confiança. Porém, segundo Artzner et al. (1999), o VaR possui limitações, pois não é uma medida coerente de risco, já que não é subaditiva.

Para superar essa limitação, surge o CVaR, também conhecido como Expected Shortfall, que avalia a perda média nos piores cenários. De acordo com Rockafellar e Uryasev (2002), o CVaR é uma medida mais apropriada para decisões de investimento em contextos de risco extremo.

Além disso, a volatilidade permanece como medida clássica da dispersão dos retornos, sendo amplamente utilizada em finanças (BODIE; KANE; MARCUS, 2014). Já a correlação entre ativos é apontada por Damodaran (2012) como fator crítico para a diversificação efetiva, pois determina o grau em que os ativos se movem conjuntamente.

3 MÉTODO DE PESQUISA

A pesquisa quantitativa se caracteriza pelo uso da quantificação na coleta e análise dos dados, fundamentando-se em técnicas estatísticas que permitem mensuração de variáveis, identificação de padrões e teste de hipóteses. Esse enfoque busca conferir maior objetividade e precisão às investigações científicas, utilizando procedimentos que vão desde análises simples até métodos estatísticos complexos (GIL, 2008; MARTINS; THEÓPHILO, 2009).

A presente pesquisa adota uma abordagem quantitativa e experimental, fundamentada na utilização da SMC para avaliar o risco e o retorno de portfólios formados por ações listadas na B3. A metodologia foi estruturada em três etapas centrais: (i) simulação da evolução do capital investido, (ii) mensuração do risco por meio das métricas VaR e CVaR e (iii) comparação entre diferentes estratégias de alocação de portfólio, incluindo pesos iguais e otimização pela teoria média-variância.

A amostra é composta pelas dez ações mais líquidas da B3, selecionadas com base em dois critérios principais: (i) elevada liquidez, expressa pelo volume médio de negociação, e (ii) representatividade setorial, de modo a contemplar empresas de diferentes segmentos relevantes da economia brasileira. Essa escolha busca garantir tanto a consistência estatística da análise quanto a diversidade necessária para refletir o comportamento de um investidor exposto a múltiplos setores do mercado acionário nacional.

3.1 Seleção dos Ativos

Foram escolhidas dez empresas do setor de mineração listadas na B3, incluindo VALE3, CBAV3, GGBR4, GOAU4, BRAP4, CMIN3, AURA33, FESA4, PATI3 e PMAM3. A seleção considerou a liquidez dos ativos e sua representatividade no setor, permitindo construir portfólios diversificados e realistas.

3.2 Coleta e Tratamento dos Dados

Os preços históricos mensais no período de 01-2022 a 08-2025, foram obtidos em consulta a base da Economática. A partir dos preços, foram calculados os retornos logarítmicos mensais, amplamente utilizados em finanças por refletirem a proporcionalidade contínua e serem aditivos no tempo (Bodie; Kane; Marcus, 2014). Posteriormente, elaborou-se a matriz de correlação para identificar interdependências entre os ativos.

3.3 Simulação de Monte Carlo

A metodologia utilizou a SMC para projetar a evolução do capital em diferentes trajetórias de mercado.

Para a estimação da média e da volatilidade dos retornos históricos; foi feita a geração de milhares de trajetórias de capital, considerando distribuições probabilísticas baseadas nos parâmetros históricos;

Análise das distribuições de resultados para extrair métricas de risco como VaR e CVaR. Esse método é amplamente aplicado em finanças para avaliar cenários de risco e incerteza (Jorion, 2007; Glasserman, 2004).

Sendo assim, para a otimização e comparação de portfólios, a pesquisa também comparou portfólios formados aleatoriamente com portfólios otimizados pela teoria Média-Variância de Markowitz (1952), por meio do cálculo do Índice de Sharpe. Essa etapa permitiu evidenciar o ganho de eficiência proporcionado por estratégias sistemáticas em relação à simples diversificação uniforme. Por fim, para a análise de robustez, foram testados cenários adversos e alternativos (queda de 20% na média dos retornos, aumento de 30% na volatilidade e combinação de queda com alta volatilidade). Essa etapa buscou avaliar a resiliência dos portfólios, seguindo metodologias sugeridas em estudos sobre estresse de mercado (Damodaran, 2012).

4 RESULTADOS E DISCUSSÃO

Para análise foram selecionadas ações de 10 empresas do seguimento de mineração listadas na Bolsa Brasileira B3, conforme apresenta a Tabela 1:

Tabela 1 - Seleção das 10 carteiras do setor de Mineração da B3

	Empresa	Bolsa	Ticker
1	Vale S.A.	B3	VALE3
2	CSN Mineração e Siderurgia	B3	CBAV3

3	Companhia Brasileira de Alumínio	B3	GGBR4
4	Gerdau S.A.	B3	GOAU4
5	Metalúrgica da Gerdau	B3	BRAP4
6	Bradespar	B3	CMIN3
7	CSN Mineração	B3	AURA33
8	Aura Minerals	B3	FESAA4
9	MMX Mineração e Metálicos	B3	PATI3
10	Paranapanema	B3	PMAM3

Fonte: Economática (2025).

Após a seleção dos dez ativos, foram obtidos os preços de fechamento mensais, derivados em Real – R\$ (moeda brasileira), no período compreendido entre janeiro de 2022 e julho de 2025. A coleta foi realizada por meio da plataforma de dados da Economática, conforme demonstrado na Tabela 2.

Tabela 2 - Valores de fechamentos mensais dos ativos do setor de mineração da B3

Mês	VALE3	CBAV3	GGBR4	GOA4	BRAP4	CMIN3	AURA33	FESA4	PATI3	PMAM3
01-2022	57,86	15,88	17,10	8,50	18,45	4,48	12,71	9,50	56,58	8,14
02-2022	66,03	18,28	15,63	7,65	20,71	3,98	13,52	9,05	61,34	7,77
03-2022	68,40	18,36	18,92	9,00	22,74	3,87	12,15	9,75	61,50	8,57
04-2022	61,88	15,70	17,30	8,42	20,14	3,34	10,46	9,35	63,55	7,78
05-2022	64,05	15,01	18,04	9,03	19,65	3,10	10,60	11,85	66,12	6,87
06-2022	56,88	10,72	14,11	7,25	18,34	2,72	9,26	9,76	59,27	5,73
07-2022	51,82	10,42	15,44	7,77	16,33	2,46	7,73	10,09	59,27	7,89
08-2022	47,92	11,90	14,72	7,57	15,91	2,55	8,30	11,20	49,06	7,53
09-2022	56,30	10,60	15,86	8,32	17,27	2,33	9,08	11,03	51,19	6,09
10-2022	52,46	10,22	16,71	8,84	17,45	2,32	9,97	11,21	36,26	5,92
11-2022	66,98	11,21	20,49	10,76	20,56	2,72	8,23	12,09	36,57	5,97
12-2022	69,46	10,70	20,53	10,60	22,94	3,22	8,28	11,43	29,86	4,66
01-2023	74,11	11,85	22,88	11,84	24,76	4,24	11,79	12,47	34,13	5,45
02-2023	66,90	9,73	20,01	10,28	21,47	3,70	10,66	12,63	41,81	5,00
03-2023	62,96	7,07	18,56	9,67	20,82	3,84	10,60	11,65	43,17	3,38
04-2023	58,02	4,93	18,62	9,61	18,40	3,68	10,76	11,32	38,65	3,82
05-2023	51,14	5,19	17,72	9,24	17,40	3,49	9,93	10,43	37,72	4,42
06-2023	51,47	5,03	18,93	10,01	18,16	3,65	9,09	10,65	30,15	4,57
07-2023	55,42	5,29	22,09	11,64	19,20	3,89	10,62	11,36	21,53	5,70
08-2023	52,15	4,28	19,52	10,01	18,39	3,74	9,33	10,36	21,53	5,00

09-2023	55,79	4,56	18,53	9,65	18,57	4,24	9,42	11,26	21,66	4,86
10-2023	56,96	3,80	16,72	8,94	18,26	4,53	9,56	11,00	23,68	4,11
11-2023	60,97	4,14	16,78	8,90	19,95	6,26	9,90	10,46	24,98	4,25
12-2023	65,70	5,10	18,61	10,17	22,46	7,09	10,09	10,51	25,07	4,34
01-2024	57,67	4,02	16,48	9,28	19,95	6,16	9,63	9,64	23,82	4,06
02-2024	57,01	4,00	16,84	9,47	18,56	5,56	9,20	9,00	25,77	3,72
03-2024	51,77	4,08	17,38	9,64	18,03	4,85	11,14	8,08	25,76	3,38
04-2024	56,27	5,17	17,24	9,96	17,45	4,52	11,05	7,41	25,76	2,83
05-2024	56,19	7,12	17,09	10,08	17,10	4,52	13,65	7,41	23,05	2,51
06-2024	55,32	6,96	17,60	10,20	16,49	4,92	14,19	7,52	22,43	2,38
07-2024	54,80	5,31	17,48	10,18	16,50	4,86	17,95	7,72	20,70	2,35
08-2024	52,97	4,98	17,52	10,04	17,34	5,39	16,92	7,65	35,11	1,85
09-2024	58,53	5,48	18,41	10,54	18,01	6,54	19,01	7,21	20,27	1,60
10-2024	57,19	5,82	17,64	9,91	17,49	5,89	23,24	7,14	27,22	0,97
11-2024	54,17	6,35	19,57	11,06	16,43	5,03	21,84	7,37	26,30	0,99
12-2024	50,27	4,69	17,75	10,01	15,52	4,90	23,78	7,74	24,84	1,02
01-2025	50,37	5,44	16,85	9,39	15,78	5,20	23,50	7,76	25,47	1,09
02-2025	51,28	5,19	16,31	8,95	15,73	4,89	28,91	7,43	23,33	1,07
03-2025	52,72	4,81	15,84	8,74	16,97	5,94	34,71	7,23	27,22	1,08
04-2025	51,07	3,93	14,76	8,26	15,34	5,89	37,87	7,22	30,63	2,18
05-2025	50,33	4,70	15,02	8,21	15,60	4,85	42,96	6,99	33,00	2,22
06-2025	50,87	4,81	15,88	8,85	15,70	4,96	47,50	6,77	38,94	1,80
07-2025	51,65	4,68	16,72	9,29	15,74	5,04	44,06	6,62	35,00	1,65
08-2025	55,56	3,53	16,66	9,46	16,38	5,20	53,00	6,44	45,71	1,63

Fonte: Elaborado pelos autores, em Python (2025).

A matriz de correlação evidenciada no gráfico 1, em que os retornos mensais dos principais ativos de mineração listados na B3 apresentam diferentes níveis de relacionamento entre si. Observa-se uma correlação forte entre VALE3 e CMIN3 (0,64), bem como entre VALE3 e BRAP4 (0,66), o que reflete a proximidade operacional das companhias e, no caso de BRAP4, sua condição de holding da Vale. Da mesma forma, destaca-se a relação quase perfeita entre GGBR4 e GOAU4 (0,96), resultado natural da forte interdependência entre as duas empresas do grupo Gerdau. Ainda nesse sentido, BRAP4 e CMIN3 também apresentam elevada correlação (0,71), reforçando a exposição comum ao setor de mineração e ao minério de ferro.


Em contrapartida, algumas empresas apresentam correlações moderadas, situadas entre 0,3 e 0,5, como no caso de VALE3 e GGBR4 (0,34) ou GOAU4 e CBAV3 (0,56). Isso sugere

uma certa sinergia setorial, ainda que com diferenças relevantes em seus modelos de negócio e mercados de atuação.

Por outro lado, destacam-se ativos com baixa ou até negativa correlação. É o caso de VALE3 e AURA33 (0,057), cujos retornos praticamente não se relacionam, indicando independência no comportamento de preços. O mesmo ocorre com FESA4, que apresenta baixas correlações com a maioria dos pares, e com PATI3 e PMAM3, que inclusive possuem relações negativas com determinados ativos, como VALE3 e CBAV3, respectivamente. Essas características indicam que a inclusão desses papéis em um portfólio pode contribuir de forma significativa para a diversificação e redução do risco.

De forma geral, a análise mostra que, enquanto determinados grupos de ações, como VALE3, BRAP4, GGBR4 e GOAU4, apresentam movimentos muito próximos e tendem a aumentar o risco sistêmico quando combinados, outros ativos como AURA33, FESA4, PATI3 e PMAM3 podem funcionar como importantes instrumentos de balanceamento, ao oferecerem maior independência em relação ao comportamento das grandes mineradoras.

Gráfico 1 - Correlação entre os ativos



Fonte: Elaborado pelos autores, em Python, (2025).

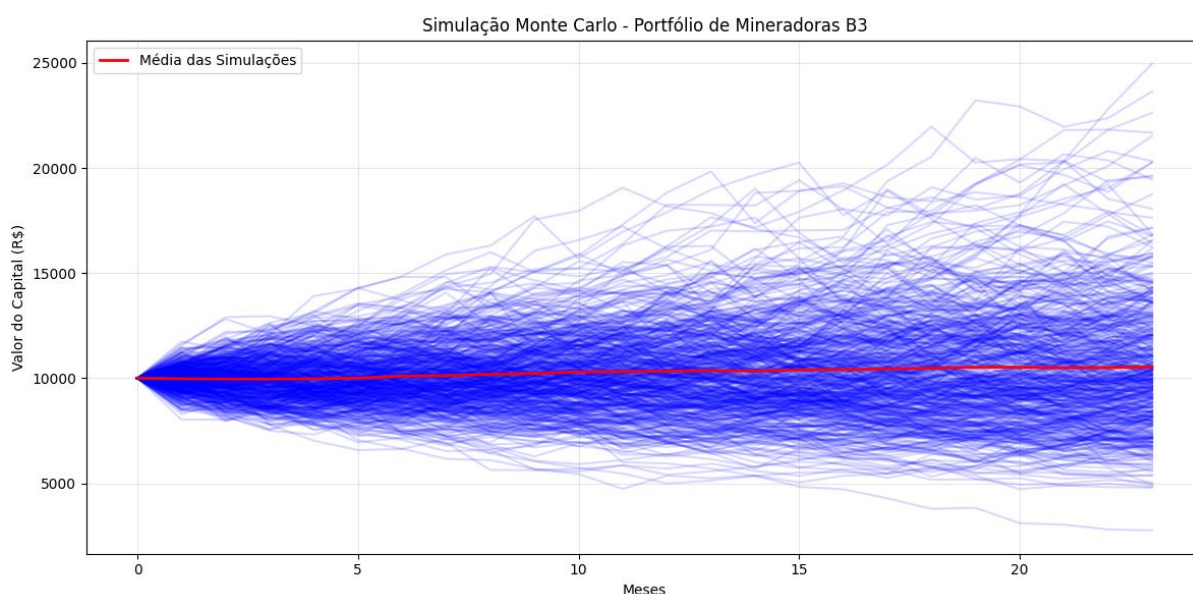
O gráfico 2 apresenta os resultados da SMC aplicada a um portfólio de mineradoras listadas na B3 ao longo de 24 meses. As diversas trajetórias em azul representam possíveis caminhos que o capital investido pode seguir, de acordo com a aleatoriedade dos retornos mensais. Nota-se que, embora todas as simulações partam de um valor inicial de R\$ 10.000, ao longo do tempo os resultados se dispersam, refletindo a incerteza e a volatilidade inerentes ao mercado de ações.

Enquanto algumas trajetórias apontam para ganhos expressivos, ultrapassando a marca de R\$ 20.000, outras demonstram perdas relevantes, chegando a níveis próximos de R\$ 5.000 ou até abaixo. Essa abertura crescente da “nuvem” de simulações ao longo do tempo ilustra o risco acumulado: quanto maior o horizonte de investimento, maior a variabilidade dos resultados possíveis.

A linha vermelha, indica a média das simulações, permanece próxima ao valor inicial, sugerindo que, em média, o portfólio tende a manter o capital investido, sem apresentar um crescimento expressivo ao longo do período. Isso reforça a ideia de que o retorno esperado é relativamente estável, mas acompanhado de ampla incerteza quanto ao resultado final individual de cada trajetória.

Em síntese, a simulação evidencia que investir em um portfólio de mineradoras pode tanto gerar ganhos significativos quanto acarretar perdas relevantes, dependendo do comportamento dos preços ao longo do tempo. O estudo ressalta a importância de avaliar o risco e a variabilidade dos retornos, especialmente em setores voláteis como o de mineração, e demonstra a utilidade da SMC como ferramenta para projeção de cenários e gestão de risco.

Gráfico 2 - Simulação de Monte Carlo



Fonte: Elaborado pelos autores, em Python (2025).

O gráfico 3 apresenta os resultados de uma SMC aplicada a um portfólio de mineradoras listadas na B3 ao longo de 24 meses. Cada linha azul representa uma trajetória possível para a evolução do capital investido, partindo de um valor inicial de R\$ 10.000. A dispersão crescente

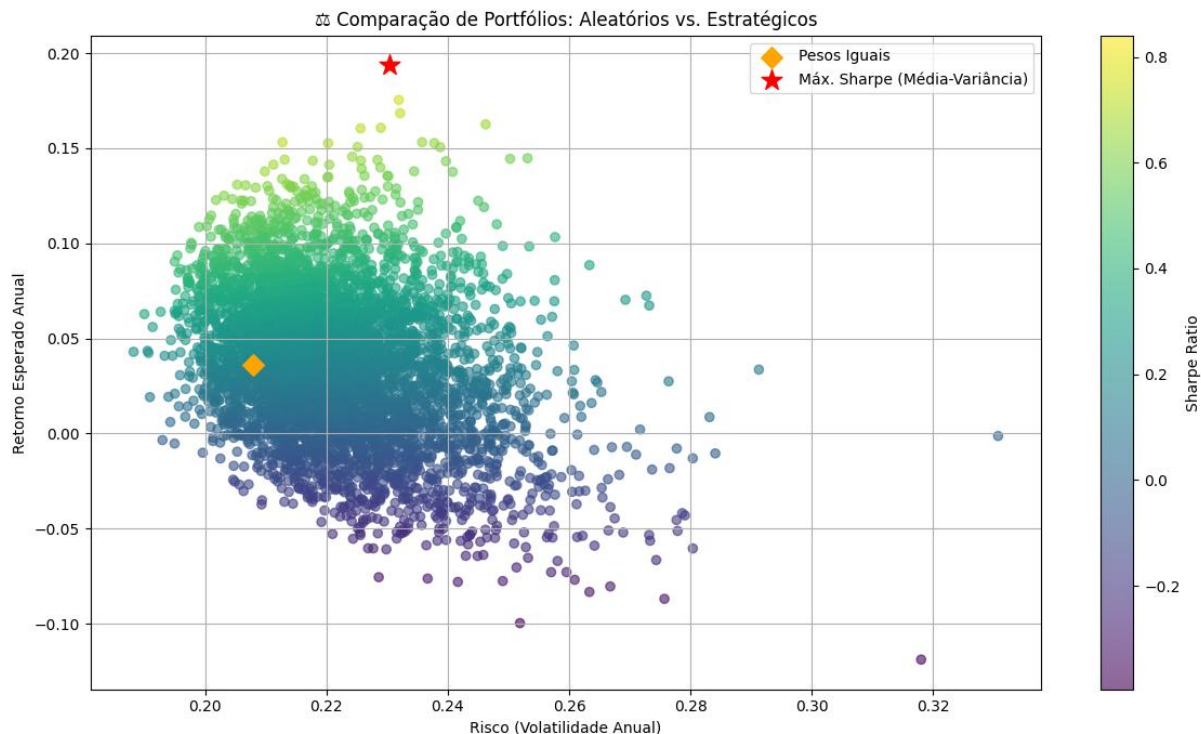
das linhas ao longo do tempo reflete a incerteza e a volatilidade associadas ao setor de mineração, mostrando que quanto maior o horizonte de investimento, maior também a amplitude de resultados possíveis.

Observa-se que algumas trajetórias apontam para ganhos significativos, ultrapassando a marca de R\$ 20.000, enquanto outras indicam perdas relevantes, chegando a valores próximos de R\$ 5.000 ou até abaixo desse patamar. Essa abertura da “nuvem” de simulações ao longo do tempo evidencia o risco acumulado, típico de mercados de alta volatilidade.

A linha vermelha, representando a média das simulações, permanece relativamente estável em torno do valor inicial, sugerindo que, em média, o portfólio tende a preservar o capital investido, sem apresentar crescimento expressivo ao longo do período analisado. Contudo, a variabilidade individual das trajetórias reforça a importância de se considerar não apenas o retorno esperado, mas também a dispersão e a probabilidade de perdas extremas.

Em síntese, a simulação demonstra que investir em mineradoras da B3 pode gerar tanto ganhos expressivos quanto perdas consideráveis, dependendo do comportamento futuro do mercado. Isso evidencia a relevância da gestão de risco e do uso de metodologias como a SMC para apoiar decisões de investimento em setores marcados pela incerteza e pela volatilidade.

Gráfico 3 - Comparação de Portfólios: Aleatórios vs. Estratégicos



Fonte: Elaborado pelos autores, em Python (2025).

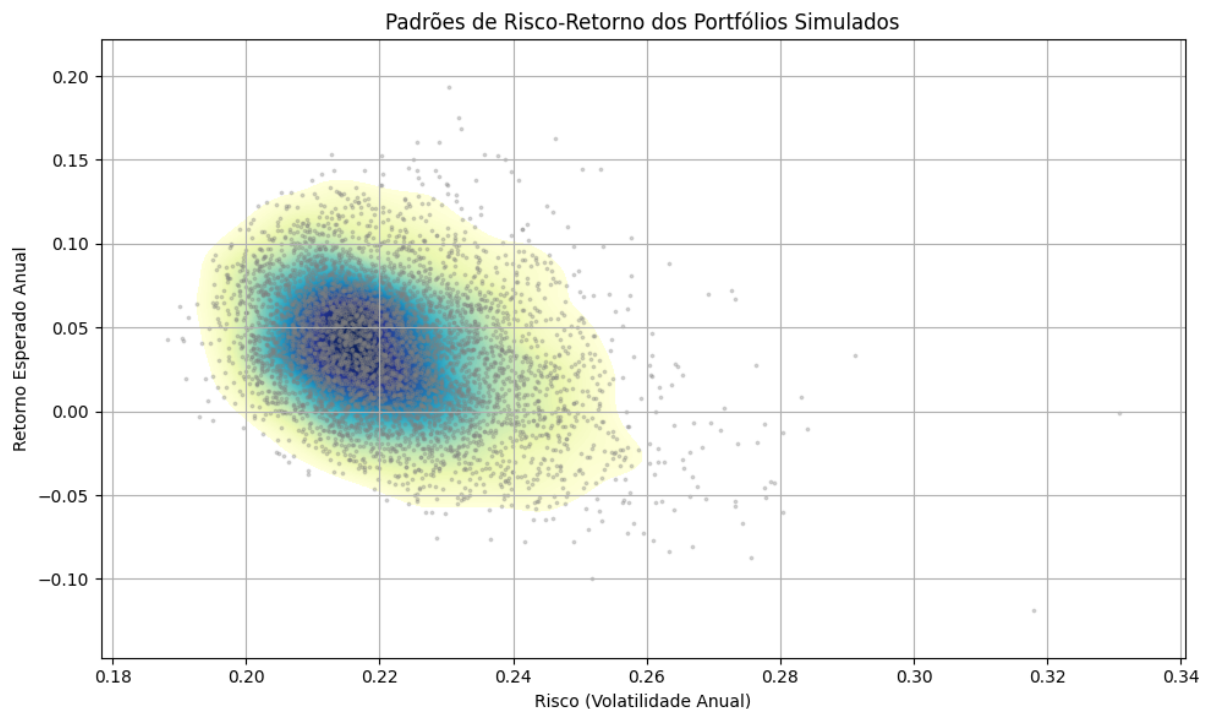
O gráfico 4 apresenta os padrões de risco-retorno dos portfólios simulados, onde cada ponto representa uma combinação de ativos gerada aleatoriamente. O eixo horizontal mostra o

risco, medido pela volatilidade anual, enquanto o eixo vertical indica o retorno esperado anual. A distribuição dos pontos evidencia que a maioria das simulações se concentra em uma faixa de risco entre 0,20 e 0,24 e em retornos esperados próximos a 0,04 e 0,07, formando uma região de maior densidade destacada pelo gradiente de cores.

As áreas mais escuras indicam a concentração de portfólios mais frequentes, sugerindo que, em termos estatísticos, as combinações tendem a convergir para essa região central de equilíbrio entre risco moderado e retorno positivo. Por outro lado, observa-se a presença de portfólios extremos nas bordas do gráfico: alguns com retornos negativos, apesar do risco elevado, e outros com retornos mais altos, mas menos prováveis.

De maneira geral, o gráfico demonstra a existência de um trade-off claro entre risco e retorno, evidenciando que retornos mais elevados estão associados a maior volatilidade, enquanto os portfólios de menor risco oferecem retornos modestos. Assim, o padrão visual reflete a distribuição estatística típica de carteiras aleatórias, na qual poucas combinações se mostram altamente eficientes, reforçando a importância da seleção estratégica de ativos para buscar retornos superiores dentro de níveis de risco controlados.

Gráfico 4 - Padrões de Risco-Retorno dos Portfólios Simulados



Fonte: Elaborado pelos autores, em Python (2025).


O gráfico 5 apresenta a análise de robustez dos portfólios em diferentes cenários de mercado, comparando o comportamento do retorno anual médio, máximo e mínimo. No eixo horizontal estão representados os quatro cenários: Original, Queda de 20% na Média, Aumento de 30% na Volatilidade e Queda da Média com Alta Volatilidade. Já o eixo vertical mostra os valores de retorno anual em percentual.

No cenário original, observa-se um retorno médio positivo em torno de 3% a 4%, com um máximo próximo de 19% e um mínimo negativo próximo de -12%, revelando alta dispersão entre os portfólios. Quando ocorre uma queda de 20% na média, a média do retorno diminui levemente, enquanto o máximo se reduz para cerca de 15%, e o mínimo melhora um pouco em relação ao cenário base, ficando em torno de -9% a -10%.

No cenário de alta de 30% na volatilidade, os resultados extremos se intensificam: o máximo retorno continua próximo a 19%, mas o mínimo volta a se aproximar de -12%, indicando maior exposição ao risco. Já no cenário combinado de queda da média com aumento da volatilidade, a média se mantém em patamares próximos aos 3%, o máximo cai novamente para perto de 15%, e o mínimo permanece próximo de -10%, evidenciando que a deterioração simultânea de retornos esperados e aumento do risco limita o potencial de ganhos e mantém elevada a possibilidade de perdas.

Em síntese, o gráfico demonstra que os portfólios simulados apresentam relativa consistência no retorno médio em todos os cenários, mas são sensíveis a alterações de volatilidade e tendência de mercado, refletindo uma distribuição assimétrica: poucos portfólios alcançam retornos elevados, enquanto uma parcela significativa pode apresentar perdas expressivas em condições adversas.

Gráfico 5 - Robustez dos Portfólios em diferentes cenários de Mercado



Fonte: Elaborado pelos autores, em Python, (2025).

O resumo de robustez dos portfólios conforme Figura 1, apresenta os resultados de quatro cenários distintos, considerando a média, o máximo e o mínimo dos retornos anuais simulados.

No cenário original, o retorno médio é de aproximadamente 3,58%, com um máximo de 19,36% e um mínimo de -11,89%, evidenciando uma ampla dispersão entre ganhos e perdas possíveis.

Quando ocorre uma queda de 20% na média dos retornos, a média cai para 2,87%, o máximo diminui para 15,49% e o mínimo melhora levemente para -9,51%, indicando que, embora o potencial de ganho seja reduzido, também há uma suavização das perdas extremas.

No cenário de alta de 30% na volatilidade, os resultados se mantêm idênticos ao cenário original: média em 3,58%, máximo em 19,36% e mínimo em -11,89%. Isso mostra que o aumento da volatilidade não alterou significativamente as métricas médias, mas reforça a manutenção de riscos de perdas expressivas.

Já no cenário combinado de queda na média e aumento da volatilidade, os números são equivalentes ao cenário de queda isolada: média em 2,87%, máximo em 15,49% e mínimo em -9,51%. Esse comportamento evidencia que a redução do retorno esperado tem maior impacto sobre os portfólios do que a variação da volatilidade isoladamente.

Em síntese, os dados revelam que os portfólios simulados são relativamente resilientes em termos de retorno médio, mantendo-se entre 2,8% e 3,6% ao ano, mas apresentam forte assimetria, já que o potencial de ganhos máximos é muito superior ao retorno médio, enquanto as perdas mínimas permanecem significativas. Isso reforça a importância de avaliar não apenas a média, mas também os cenários extremos no processo de tomada de decisão em investimentos.

Figura 1 - Resumo de Robustez dos Portfólios

Resumo de Robustez dos Portfólios:

	Cenário	Média Retorno	Máximo Retorno	Mínimo Retorno
0	Original	0.0358	0.1936	-0.1189
1	Queda 20% Média	0.0287	0.1549	-0.0951
2	Alta 30% Volatilidade	0.0358	0.1936	-0.1189
3	Queda Média e Alta Vol	0.0287	0.1549	-0.0951

Fonte: Elaborado pelos autores, em Python (2025).

O gráfico 6 apresenta a distribuição de retornos simulados de um portfólio de mineradoras na B3, obtida por meio da SMC. No eixo horizontal estão os retornos simulados do portfólio e, no eixo vertical, a frequência com que esses valores ocorreram nas simulações.

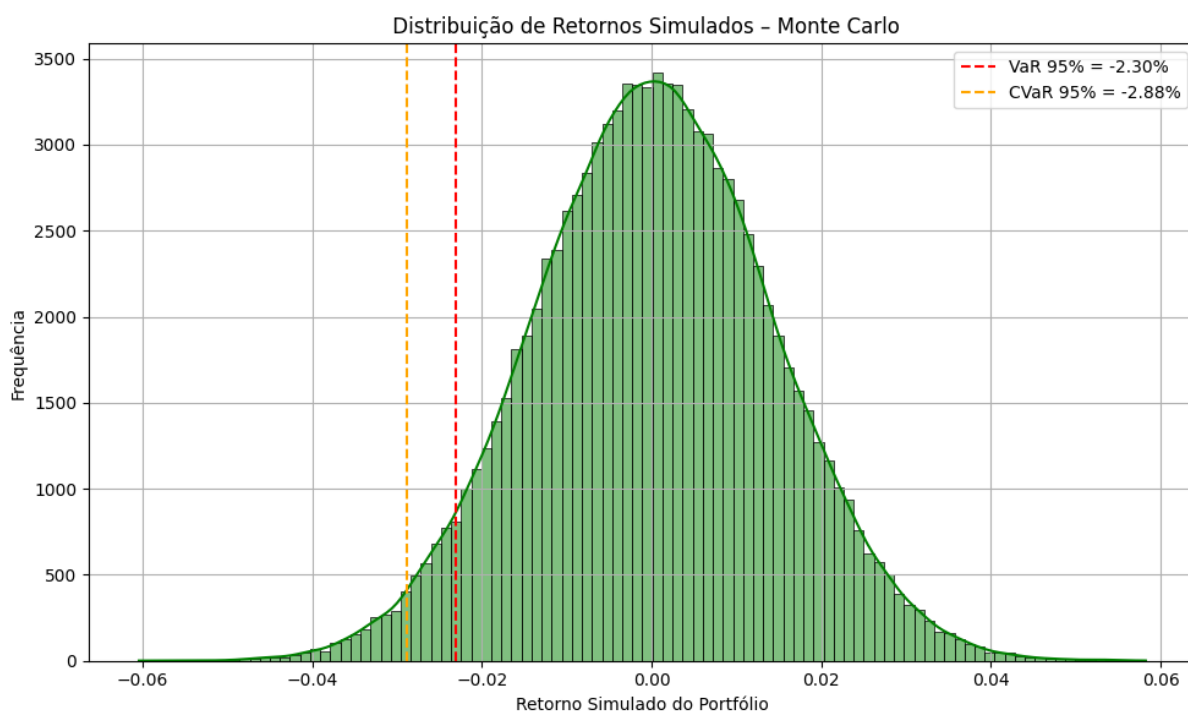
A distribuição possui formato aproximadamente normal, com concentração em torno de retornos próximos a zero, indicando que a maior parte das simulações resulta em pequenas variações positivas ou negativas do portfólio. Entretanto, observa-se a presença de caudas mais longas, que representam a possibilidade de retornos extremos, tanto positivos quanto negativos. As linhas verticais representam duas métricas importantes de risco:

A linha vermelha tracejada indica o VaR a 95%, que neste caso é de -2,30%. Isso significa que, com 95% de confiança, a perda máxima diária do portfólio não deve ultrapassar 2,30%.

A linha amarela tracejada representa o CVaR a 95%, de -2,90%, que mede a perda média nos piores 5% dos cenários. Esse indicador é mais conservador, pois considera não apenas o limite da perda (VaR), mas também sua intensidade média nos cenários adversos.

A interpretação conjunta mostra que o portfólio apresenta risco controlado em termos de perdas moderadas, mas ainda exposto a cenários de estresse que podem gerar retornos significativamente negativos. Ao mesmo tempo, a cauda positiva da distribuição evidencia a possibilidade de ganhos relevantes, reforçando a natureza assimétrica do risco-retorno no mercado acionário.

Gráfico 6 - Distribuição de Retornos Simulados - Monte Carlo



Fonte: Elaborado pelos autores, em Python (2025).

5 CONCLUSÕES

A pesquisa demonstrou que a Simulação de Monte Carlo é uma metodologia robusta para mensuração e compreensão dos riscos associados a carteiras de investimentos em empresas do setor de mineração da B3. Ao permitir a geração de milhares de trajetórias possíveis para a evolução do capital, a técnica forneceu uma visão probabilística dos resultados, evidenciando a natureza incerta e volátil desse segmento. A análise das correlações entre os ativos mostrou que determinados grupos de ações apresentam movimentos muito próximos, o que aumenta o

risco sistêmico quando combinados, enquanto outros papéis, de menor correlação, contribuem de forma significativa para a diversificação e redução do risco agregado do portfólio.

Os resultados evidenciaram que, em média, os retornos das carteiras tendem a se manter estáveis ao longo do tempo, porém acompanhados de elevada dispersão, o que confirma o caráter assimétrico da distribuição de ganhos e perdas no setor. As métricas de risco utilizadas, VaR e CVaR, reforçaram a importância de avaliar não apenas a perda máxima esperada em determinado nível de confiança, mas também a intensidade média dos prejuízos em cenários adversos. Essa abordagem mostrou-se essencial para mensurar a vulnerabilidade dos portfólios diante de choques externos e de condições de mercado desfavoráveis.

Outro ponto relevante foi a constatação de que estratégias de alocação otimizadas, baseadas no modelo média-variância de Markowitz, apresentaram desempenho superior em termos de eficiência, ao proporcionarem retornos mais elevados para níveis de risco semelhantes aos das estratégias de alocação uniforme ou aleatória. Isso reforça a importância da gestão ativa e do uso de ferramentas quantitativas avançadas na busca por melhor equilíbrio entre risco e retorno.

A análise de robustez, por sua vez, destacou que choques de volatilidade e quedas nos retornos médios impactam diretamente a distribuição dos resultados, limitando o potencial de ganhos e mantendo o risco de perdas significativas. Apesar disso, observou-se uma relativa resiliência no retorno médio anual das carteiras, o que indica que a diversificação e a gestão estratégica podem atenuar parte dos efeitos adversos, ainda que não eliminem totalmente a exposição ao risco.

Em termos práticos, os achados deste estudo reforçam que a Simulação de Monte Carlo, associada às métricas VaR e CVaR, é uma ferramenta poderosa para apoiar investidores e gestores no processo de tomada de decisão, principalmente em setores marcados por volatilidade e forte dependência de fatores externos, como o de mineração. Além de possibilitar uma visão realista da variabilidade dos resultados, o método contribui para o desenvolvimento de estratégias mais resilientes e alinhadas às necessidades de gestão de risco em ambientes de incerteza.

Por fim, destaca-se que este trabalho abre caminho para pesquisas futuras que possam ampliar a análise para outros setores da economia, incorporar horizontes de tempo distintos, ou mesmo integrar variáveis macroeconômicas e ambientais que impactam diretamente o desempenho do setor mineral. Dessa forma, a presente investigação não apenas reforça a utilidade prática da SMC na análise de investimentos, mas também evidencia sua relevância acadêmica e aplicabilidade em contextos complexos e dinâmicos do mercado financeiro.

REFERÊNCIAS

ARTZNER, P. et al. Coherent Measures of Risk. *Mathematical Finance*, v. 9, n. 3, p. 203–228, 1999.

BODIE, Z.; KANE, A.; MARCUS, A. J. *Investments*. 10. ed. New York: McGraw-Hill, 2014.

BOYLE, P. Options: A Monte Carlo Approach. *Journal of Financial Economics*, v. 4, n. 3, p. 323–338, 1977.

BOYLE, P.; BROADIE, M.; GLASSERMAN, P. Monte Carlo Methods for Security Pricing. *Journal of Economic Dynamics and Control*, v. 21, n. 8–9, p. 1267–1321, 1997.

DAMODARAN, A. **Investment Valuation: Tools and Techniques for Determining the Value of Any Asset**. 3. ed. Hoboken: Wiley, 2012.

ELTON, E. J.; GRUBER, M. J. **Modern Portfolio Theory and Investment Analysis**. 5. ed. New York: Wiley, 1995.

GIL, Antonio Carlos. **Métodos e técnicas de pesquisa social**. 6. ed. São Paulo: Atlas, 2008.

GLASSERMAN, P. **Monte Carlo Methods in Financial Engineering**. New York: Springer, 2004.

GLASSERMAN, P.; HEIDELBERGER, P.; SHAHABUDDIN, P. **Efficient Monte Carlo methods for value-at-risk**. 2001.

INDARWATI, E.; KUSUMAWATI, R. Estimation of the portfolio risk from conditional value at risk using Monte Carlo simulation. *Jurnal Varian*, v. 17, n. 3, p. 370–380, 2021. DOI: 10.20956/J.V17I3.11340.

JORION, P. *Value at Risk: The New Benchmark for Managing Financial Risk*. 3. ed. New York: McGraw-Hill, 2007.

KROESE, D. P. et al. *Handbook of Monte Carlo Methods*. Hoboken: Wiley, 2014.

MARKOWITZ, H. Portfolio Selection. *The Journal of Finance*, v. 7, n. 1, p. 77–91, 1952.

METROPOLIS, N.; ULAM, S. The Monte Carlo Method. *Journal of the American Statistical Association*, v. 44, n. 247, p. 335–341, 1949.

ROCKAFELLAR, R. T.; URYASEV, S. Conditional Value-at-Risk for General Loss Distributions. *Journal of Banking and Finance*, v. 26, n. 7, p. 1443–1471, 2002.

SAPUTRA, D.; ZUKHRI, N.; ALTIN, D.; NUGROHO, A. A.; SETIAWAN, R. D.; FITARI, T.; THOHARI, M. Value at Risk **Analysis Using Historical Method and Monte Carlo Simulation in Banking and Mining** Sector Companies. *International Journal of Applied Management and Business*, 2023. DOI: 10.54099/ijamb.v1i1.436.

SHARPE, W. F. Capital Asset Prices: A Theory of Market Equilibrium under Conditions of Risk. *The Journal of Finance*, v. 19, n. 3, p. 425–442, 1964.

SYAHCHARI, D. H.; HAPSARI, A. Utilizing Monte Carlo Simulation to Determine Value at Risk in the Wireless Telecommunications Industry. **International Conference on Engineering and Emerging Technologies (ICEET)**. 2022.

MARTINS, Gilberto de Andrade; THEÓFILO, Carlos Renato. **Metodologia da investigação científica para ciências sociais aplicadas**. 2. ed. São Paulo: Atlas, 2009.