

Consumo de Energia do Bitcoin na Era das Criptomoedas: um Estudo Exploratório e de Previsão Baseado em Dados

Pedro Mark Bianchi¹

FEC/UNESP, Rosana, SP

Marilaine Colnago²

IQ/UNESP, Araraquara, SP

Rafaella S. Ferreira,³ Wallace Casaca⁴

IBILCE/UNESP, São José do Rio Preto, SP

Resumo. A criptomoeda e a tecnologia *blockchain* têm sido um dos principais impulsionadores da Quarta Revolução Industrial no setor financeiro. Enquanto, por um lado, a mineração de criptomoedas permite que mineradores virtuais acumulem ativo financeiro, este processo também leva a um consumo progressivo de eletricidade em todo o mundo. De fato, a preocupação com o aumento desenfreado do consumo de energia decorrente da mineração de criptomoedas ganhou mais força em meados de 2018, quando o uso de eletricidade alcançou 1% de toda a demanda mundial, alertando especialmente países com baixa demanda energética, mas cujas fazendas de mineração têm operado em larga escala. Portanto, neste trabalho, dois modelos de inteligência artificial foram aplicados para prever o consumo global de energia derivado da mineração da criptomoeda Bitcoin. Além disso, foi realizada uma discussão acerca do papel das redes de mineração no crescimento sustentável do consumo global de eletricidade e de como modelos de regressão podem ser calibrados a partir de dados abertos a fim de obter previsões assertivas para o consumo elétrico, permitindo capturar o quadro geral do uso de energia relacionado à mineração, bem como apoiar planos de sustentabilidade energética para países que têm sofrido com atividades de mineração em larga escala.

Palavras-chave. Sustentabilidade Energética, Criptomoedas, Regressão, Séries Temporais.

1 Introdução

Nos últimos anos, as criptomoedas tem ganhado ampla notoriedade e representatividade no sistema financeiro mundial. Com a finalidade de preservar a identidade dos investidores e facilitar transações monetárias, o ativo digital e sua rede tecnológica conhecida como *blockchain* buscam conferir segurança e transparência aos seus usuários, dada a importância que o processo de mineração possui na efetivação da transação monetária virtual [7].

Tal como ocorre com a maioria das moedas digitais, a monetização do Bitcoin resulta de uma cadeia de processos computacionais complexos, que gera grande dispêndio de energia elétrica a fim de manter o funcionamento progressivo e de alta performance dos computadores da rede, que apresenta operacionalidade contínua, levando assim à elevados custos não apenas devido ao consumo elétrico, mas também com prevenção, resfriamento, e manutenção do *hardware* [6, 16].

A fim de melhor motivar a questão, o consumo energético associado à mineração do Bitcoin já chega a ultrapassar nações inteiras, inclusive aquelas que excedem 100 milhões de habitantes, como as Filipinas. Para efeito de comparação, caso a rede Bitcoin fosse avaliada como um país

¹pedro.mark@unesp.br

²marilaine.colnago@unesp.br

³rafaella.ferreira@unesp.br

⁴wallace.casaca@unesp.br

em termos de seu consumo energético, ela estaria classificada na 34^a posição do ranking mundial, ultrapassando países como Finlândia e Bélgica, consumindo ligeiramente menos que Holanda e Paquistão, e subindo, em apenas um ano, 10 posições na classificação geral [3]. Portanto, em vista dos desafios da geração e transmissão de eletricidade no mundo, entender e prever o ritmo de consumo energético associado à mineração de criptomoedas, que compreende 1% de todo consumo global, se faz necessário, especialmente em nações como a Islândia, onde a demanda supera o próprio gasto energético do país, ou em países como China e Estados Unidos, que detêm uma grande parcela do mercado minerador mundial [3].

Diante do exposto e da necessidade de explorar o problema sob uma ótica global e temporal, este trabalho propõe analisar e prever a dinâmica do consumo mundial de energia elétrica associada à mineração da rede Bitcoin nos anos de 2019, 2020 e 2021. Em contraste com as demais propostas da literatura, que procuram investigar apenas o preço de criptomoedas [2, 12], ou consumos de energia de ordem local [15], ou ainda, que partem de especificações técnicas de *hardware* [1, 16] ou de parâmetros macroeconômicos do mercado financeiro [9, 10], os modelos de Inteligência de Máquina (IM) explorados neste trabalho partem da análise dos padrões e do comportamento de séries históricas do consumo universal diário do criptoativo Bitcoin.

2 Metodologia

O processo metodológico empregado neste trabalho leva em consideração os seguintes pontos:

- **Plataforma:** Todas as implementações computacionais envolvidas na presente pesquisa foram realizadas por meio da linguagem de programação *Python*, juntamente com o auxílio da biblioteca de modelagem estatística inteligente *statsmodels*.
- **Base de Dados:** Os dados brutos explorados neste artigo foram coletados do repositório da Universidade de Cambridge, a partir do projeto denominado *Cambridge Bitcoin Electricity Consumption Index (CBECEI)* [3], que reúne o histórico diário do consumo estimado de energia da rede Bitcoin, para os anos de 2019 à 2021.
- **Modelos Preditivos:** A fim de prever o consumo de energia elétrica derivado da rede Bitcoin, duas técnicas de IM foram implementadas e devidamente ajustadas: Auto Regressor (AR) e o Auto Regressor Integrado com Médias Móveis (ARIMA). Usando apenas um passo regressivo, podemos usar a fórmula da Equação (1) para expressar a variável de auto-regressão (AR):

$$Y_t = \omega + \phi Y_{t-1} + \epsilon_t, \quad (1)$$

sendo que, para prever Y_t , utilizamos o valor anterior, Y_{t-1} [13].

Já o modelo ARIMA é, em sua essência, um método de extrapolação, que emprega dados históricos de séries temporais para aprender um conjunto de valores futuros. Para implementar e ajustar o algoritmo, são necessárias três etapas: identificar, estimar e diagnosticar o modelo. Portanto, o valor adjacente de qualquer variável é visto como uma função linear de seus valores e erros passados, isto é, conforme formulado na Equação (2) a seguir:

$$Y_t = \beta_0 + \beta_1 Y_{t-1} + \dots + \beta_p Y_{t-p} + \epsilon_t + \theta_1 \epsilon_{t-1} + \dots + \theta_q \epsilon_{t-q} + e, \quad (2)$$

em que Y_t é o valor da previsão da variável alvo, expressa como função de seus próprios valores de atraso no período de tempo passado t , em conjunção com o somatório de seus respectivos erros, ϵ_t , encontrados no período de tempo t .

A primeira metade da Equação (2), β_0 até $\beta_p Y_{t-p}$, caracteriza a parte Auto Regressiva (AR) do modelo, enquanto a segunda metade ressalta a parte das Médias Móveis (MA). Portanto, a expressão recebe o nome de modelo ARMA(p, q).

Já o nível no qual a variável dependente Y_t se torna estável, tem-se a introdução do termo $I(d)$, que indica a ordem da integração do método. Deste modo, os modelos ARIMA são expressos como $ARIMA(p, d, q)$, e passam a considerar a defasagem da variável dependente, o erro aleatório gerado pela estimativa, e a ordem em que a variável se torna estacionária. Por exemplo, a ordem de p e q do modelo pode ser identificada traçando-se um gráfico de correlação, usando a função de correlação automática e de autocorrelação parcial [17].

- **Treinamento e Ajuste de Parâmetros:** Para cada ano analisado, as observações diárias foram agrupadas em subintervalos mensais, os quais foram usados para treinar os modelos, tendo a semana posterior a cada mês de treinamento sido usada para fins de validação. Além disso, foi conduzida uma análise paramétrica dos hiperparâmetros dos modelos, a partir do uso da técnica *Random Search* [11]. A geração dos resultados com o modelo $AR(p)$ foi realizada tomando-se $p = 25$, enquanto que o modelo ARIMA, os parâmetros adotados foram os seguintes: valor máximo de p , d e q : 3; modo Sazonal: *false*; modo Stepwise: *true*.
- **Métricas de Validação:** Para a análise do desempenho dos preditores, empregou-se a métrica *Mean Absolute Percentage Error* (MAPE) [14], que foi computada a partir do valor atual Y_i (consumo registrado na série temporal, de n valores do intervalo de teste), e da estimativa \hat{Y}_i , obtida pelos modelos pós treinados, conforme a equação a seguir:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \times 100. \tag{3}$$

3 Resultados e Discussão

Esta seção contempla a análise e discussão dos dados do consumo elétrico da rede Bitcoin, bem como os resultados da aplicação de técnicas de *Análise Exploratória de Dados* (AED) e dos modelos preditivos descritos anteriormente.

3.1 Consumo de Eletricidade da Rede Bitcoin: 2019

Com o objetivo de analisar as principais características do consumo ao longo de 2019, os dados foram segmentados em termos de suas componentes básicas como tendências, sazonalidade, amplitude e resíduo. Conforme apresentado na Figura 1, é possível identificar claramente a existência da sazonalidade no conjunto de dados. Já em termos de tendência, é possível identificar um comportamento prevalente de ascensão, sobretudo, no segundo semestre do ano.

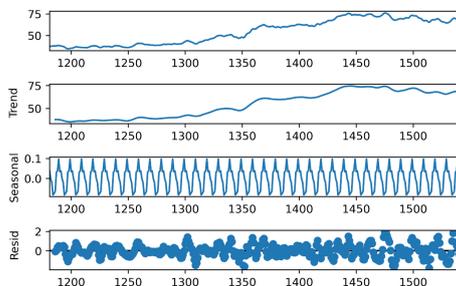


Figura 1: Análise de componentes da série temporal de consumo elétrico em 2019.

Outro aspecto relevante a ser mencionado são as variações presentes ao longo de toda a série temporal, com muitos pontos extremos locais, o que pode ser observado a partir do gráfico de resíduos na última linha da Figura 1.

Os gráficos do tipo *violin plot* (Figura 2), que combinam a visualização *boxplot* com a densidade dos dados, resumam a distribuição do consumo em termos mensal e semanal ao longo de 2019. Meses com representações mais “alargadas”, tais como junho, julho e agosto, concentram uma distribuição do consumo na faixa de 40-60 TWh e não carregam valores com alta discrepância (*outliers*), enquanto que áreas mais “afinadas” como novembro e dezembro agregam valores na faixa de 60-100 TWh. Considerando o gráfico de mesma natureza organizado por dias da semana (gráfico à direita), é possível constatar que não há diferenças significativas entre os níveis de consumo registrados na segunda-feira (índice 0) até domingo (índice 6), o que sugere que os equipamentos de mineração tem trabalhado de forma ininterrupta ao longo de cada semana.

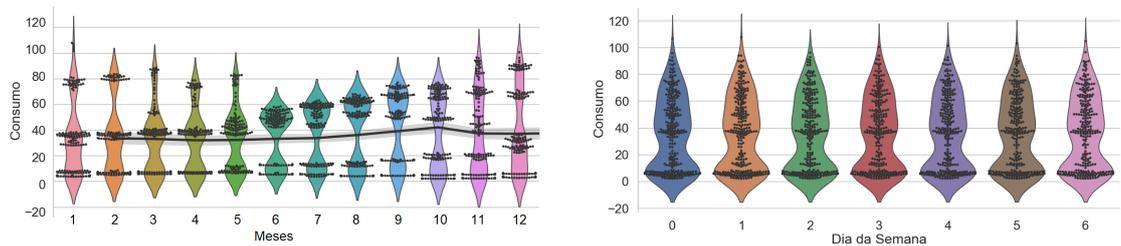


Figura 2: Distribuição mensal (esquerda) e semanal (direita) do consumo elétrico em 2019.

A Tabela 1 relaciona o MAPE para as predições dos modelos AR e ARIMA. Têm-se que ambos os modelos apresentam resultados bastante acurados na grande parte das mensurações. Além disso, é possível constatar que os meses de melhor predição em 2019 se concentram no primeiro trimestre, sendo dezembro o mês de menor performance preditiva. Ainda sobre 2019, embora os maiores escores foram obtidos no último trimestre, tanto o preditor ARIMA quanto o AR alcançam erros abaixo de 10% no segundo trimestre. Tal fato poderia ser explicado pelo aumento de mineradores no período, que entraram no mercado de mineração no final de 2019, bem como pelo efeito *halving*, que diminuiu pela metade a quantidade de Bitcoins “pagas” aos mineradores [5] no início de 2020, fatores externos estes que tornam a predição mais desafiadora por parte dos modelos.

Tabela 1: MAPE (%) da predição da energia consumida (Rede Bitcoin) em 2019, 2020 e 2021.

Período de Treinamento	2019		2020		2021	
	AR	ARIMA	AR	ARIMA	AR	ARIMA
Janeiro	1.90	1.24	1.24	1.20	3.98	5.91
Fevereiro	1.33	0.62	2.45	2.56	1.37	1.36
Março	1.08	0.70	9.12	1.24	1.02	0.83
Abril	4.24	2.10	6.56	7.42	12.89	8.73
Maio	2.48	1.46	4.35	7.25	6.00	3.40
Junho	2.37	1.06	2.34	2.64	10.77	4.63
Julho	2.34	0.77	4.24	2.42	1.45	4.66
Agosto	2.09	3.08	1.79	1.39	1.27	1.84
Setembro	2.61	2.15	6.86	6.49	4.04	3.79
Outubro	4.95	6.09	11.51	8.05	1.74	1.72
Novembro	5.49	3.27	0.86	1.88	9.96	8.38
Dezembro	5.96	8.27	2.51	1.40	1.44	1.94
Média	3.07	2.56	4.49	3.66	4.66	3.93

De forma a avaliar qualitativamente o comportamento dos modelos após a etapa de treinamento, na Figura 3 são retratados os valores preditos do consumo elétrico da Rede Bitcoin pelo preditor AR, como também pelo preditor ARIMA. Em termos de análise visual, é possível observar que o preditor ARIMA obteve uma melhor aderência à curva azul quando comparado com o modelo AR. Além disso, note que o modelo ARIMA também captura a tendência dos dados reais.

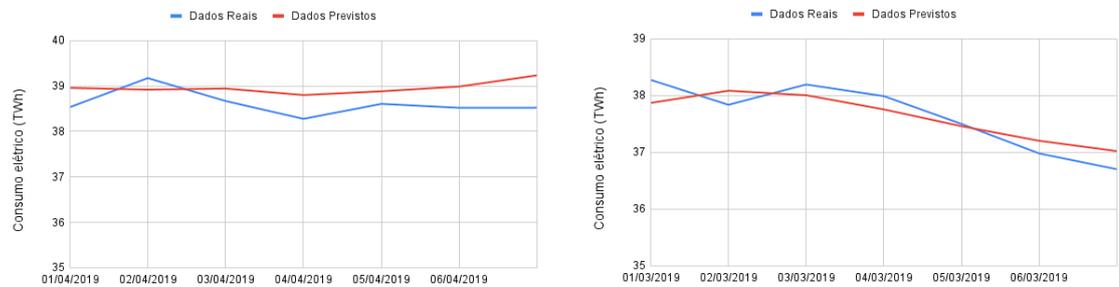


Figura 3: Resultados qualitativos produzidos pelo modelo AR (esquerda) e ARIMA (direita).

3.2 Consumo de Eletricidade da Rede Bitcoin: 2020 e 2021

Visando inspecionar numericamente a capacidade preditiva dos modelos ao longo do período pandêmico de 2020 e 2021, a Tabela 1 relaciona os escores mensais do MAPE em suas últimas colunas. Conforme os valores listados, é possível constatar que os modelos ARIMA e AR foram capazes de prever o consumo energético mensal da Rede Bitcoin mesmo diante de um cenário altamente imprevisível e inédito no mercado econômico-financeiro, ocasionado pelo surgimento da Covid-19. Além disso, no caso do modelo ARIMA, é válido destacar que os valores MAPE não transcenderam o teto de 10%, cujo escore médio anual foi de 3.66% e 3.93% em 2020 e 2021, respectivamente, indicando que as previsões geradas possuem alta acurácia.

Na sequência, investigamos a acurácia do preditor ARIMA quando o mesmo é aplicado para aferir dois cenários de difícil previsibilidade: Figura 4 (esquerda) - retomada da mineração, logo após a OMS (Organização Mundial da Saúde) declarar o status de pandemia global, em março de 2020, e Figura 4 (direita) - evento extraordinário em que foi registrado um salto de 69 para 80 TWh no consumo da Rede Bitcoin, isto é, um incremento da ordem de 16% no consumo mundial da referida rede em apenas uma semana.

Na Figura 4 (esquerda), podemos verificar a grande variação de consumo energético da mineração nas primeiras semanas da pandemia, sendo este o resultado da maior queda na cotação da

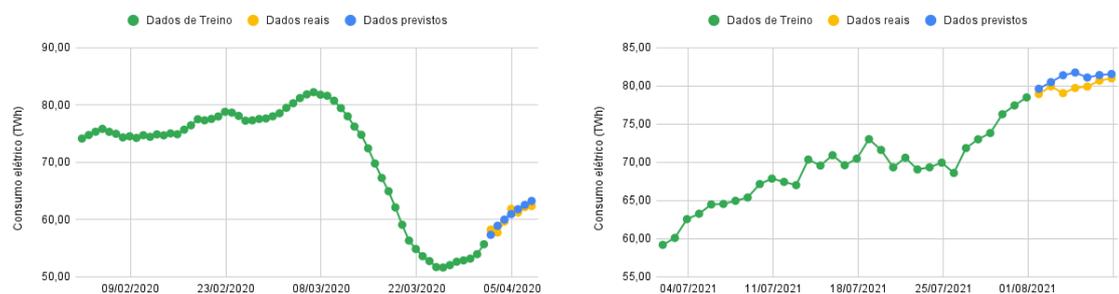


Figura 4: Aplicação do modelo ARIMA para estimar o consumo energético da Rede Bitcoin nas primeiras semanas da pandemia, em 2020 (esquerda), e entre julho-agosto de 2021 (direita).

moeda da história. Mesmo diante das variações repentinas no consumo, o modelo pós-treinado ARIMA consegue capturar o comportamento de recrudescimento da curva, tanto em tendência como em amplitude. Dentre as possíveis razões apontadas para a dinâmica do preço do Bitcoin neste período, que reverbera diretamente na carga elétrica agregada, destacam-se: a pandemia e suas incertezas, o choque do petróleo, que fez com que os ativos de risco parecessem mais arriscados, a ansiedade por liquidez em meio às quedas históricas nas bolsas, o mercado vulnerável à especulação e, a inserção, de uma só vez, de US\$ 3 bilhões em criptoativos por uma empresa chinesa, desequilibrando a oferta-e-demanda [8].

Com relação à Figura 4 (direita), podemos constatar a existência de um elevado salto no consumo energético derivado da mineração entre o final de julho e início de agosto de 2021, que deve-se à alguns fatores como: os rumores de que o grupo de tecnologia *Amazon* passaria a aceitar Bitcoins como forma de pagamento, bem como lançar sua própria criptomoeda, o aumento da taxas de empréstimo em dólar, e uma maior confiança do mercado no interesse institucional sobre a moeda digital [4].

4 Conclusões

Este trabalho discutiu o problema do consumo elétrico da mineração de criptomoedas sob a ótica global e temporal. Foram explorados dados da Rede Bitcoin nos anos de 2019, 2020 e 2021, de modo a avaliar não apenas aspectos de tendência, sazonalidade e amplitude da demanda, mas também a dinâmica do consumo ao longo dos meses pré e pós Covid-19, bem como o impacto de eventos extraordinários que ocorreram devido à fatores exógenos ao longo da pandemia. Para a análise dos dados, foram aplicadas técnicas de Análise Exploratória de Dados como decomposição de séries temporais e *violin plots*, enquanto que para construção dos modelos de predição foram implementados, calibrados e validados dois algoritmos de IM: Auto Regressor e ARIMA.

Considerando os resultados alcançados pelos modelos, foram obtidos erros MAPE (total), que com base nas avaliações quantitativas, constatam que a performance preditiva do modelo ARIMA foi superior à do AR, embora este último também tenha apresentado resultados satisfatórios.

Finalmente, fica claro a partir da avaliação dos dados e da discussão apresentada neste trabalho que a crescente expansão das criptomoedas tem desencadeado um problema de ordem global em razão do aumento da energia demandada. Em vista da problemática atual, vale destacar a importância de estudos para avançar no tratamento do problema, o que inclui a aplicação de técnicas de Inteligência de Máquina e Análise de Dados a fim de avaliar e prever o consumo elétrico associado à mineração de criptoativos, possibilitando assim às concessionárias de energia e gestores institucionais planejar a geração futura de carga, ou ainda gerenciar a atual demanda de modo dirimir o impacto desta expansão na matriz energética dos países que abrigam de forma massiva a tecnologia de mineração de criptomoedas.

Agradecimentos

Os autores agradecem à Fundação de Amparo a Pesquisa do Estado de São Paulo – FAPESP (#2020/10083-4 e #2021/03328-3), e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico – CNPq (#316228/2021-4) pelo apoio concedido para o desenvolvimento deste trabalho.

Referências

- [1] Sergio Luis Nández Alonso et al. “Cryptocurrency Mining from an Economic and Environmental Perspective. Analysis of the Most and Least Sustainable Countries”. Em: **Energies** 14.14 (2021), p. 4254. DOI: 10.3390/en14144254.
- [2] Amin Azari. “Bitcoin Price Prediction: An ARIMA Approach”. Em: **arXiv:1904.05315** (2019). URL: <https://arxiv.org/abs/1904.05315>.
- [3] University of Cambridge. **Bitcoin Network Power**. Online. Acessado em 10/03/2023, <https://www.cbeci.org/>.
- [4] Gabriel Rubinsteinn - Exame. **Bitcoin ganha força, sobe 12% e registra maior preço dos últimos 40 dias**. Online. Acessado em 10/03/2023, <https://encurtador.com.br/deitu>. 2021.
- [5] Foxbit. **Halving do bitcoin: Como estar preparado?** Online. Acessado em 10/03/2023, <https://foxbit.com.br/blog/halving-do-bitcoin>. 2020.
- [6] Pierce Greenberg e Dylan Bugden. “Energy Consumption Boomtowns in the United States: Community Responses to a Cryptocurrency Boom”. Em: **Energy Research & Social Science** (2019), pp. 162–167. DOI: 10.1016/j.erss.2018.12.005.
- [7] **How does Bitcoin work?** Online. Acessado em 08/03/2023, <https://bitcoin.org/en/how-it-works>.
- [8] Rafael Gregório - Valor Investe. **Bitcoin tem maior queda diária da história e derrete 50% em uma semana; e agora?** Online. Acessado em 10/03/2023, <https://encurtador.com.br/kmYZ5>. 2020.
- [9] S. Küfeoglu e M. Özkuran. “Energy Consumption of Bitcoin Mining”. Em: **Faculty of Economics, University of Cambridge** (2019). DOI: <https://doi.org/10.17863/CAM.41230>.
- [10] Sinan Küfeoglu e Mahmut Özkuran. “Bitcoin mining: A global review of energy and power demand”. Em: **Energy Research & Social Science** (2019), p. 101273. DOI: 10.1016/j.erss.2019.101273.
- [11] João Vitor Leme et al. “Towards Assessing the Electricity Demand in Brazil: Data-Driven Analysis and Ensemble Learning Models”. Em: **Energies** 13.6 (2020), p. 1407. DOI: 10.3390/en13061407.
- [12] Mingxi Liu et al. “Forecasting the price of Bitcoin using deep learning”. Em: **Finance Research Letters** 40 (2021), p. 101755. DOI: 10.1016/j.fr1.2020.101755.
- [13] Douglas C. Montgomery, Cheryl L. Jennings e Murat Kulahci. **Introduction to Time Series Analysis and Forecasting**. Wiley-Interscience, 2015. ISBN: 9780471653974.
- [14] Matheus Paula et al. “Predicting Long-Term Wind Speed in Wind Farms of Northeast Brazil: A Comparative Analysis Through Machine Learning Models”. Em: **IEEE Latin America Transactions** 18.11 (2020), pp. 2011–2018. DOI: 10.1109/TLA.2020.9398643.
- [15] Bianca Reichert, Adriano Mendonça Souza e Meiri Mezzomo. “Forecasting electricity generation from renewable sources during a pandemic”. Em: **Gestão & Produção** 29.1 (2022), pp. 1–19. DOI: 10.1590/1806-9649-2022v29e024.
- [16] Guilherme Albuquerque Barbosa Silva e Carlo Kleber da Silva Rodrigues. “Rentabilidade econômica da mineração de Bitcoins e Litecoins”. Em: **UniCEUB** 7.1 (2017), pp. 1–8.
- [17] Lakshmi Yermal e Balasubramanian P. “Application of Auto ARIMA Model for Forecasting Returns on Minute Wise Amalgamated Data in NSE”. Em: **IEEE International Conference on Computational Intelligence and Computing Research**. 2017, pp. 1–5.