

Decifrando o Mercado de NFTs: A Influência das Conexões de Rede e Transações no Valor de Ativos

Nara Raquel Dias Andrade
Universidade Federal do Piauí
Picos, Piauí
nara.andrade@ufpi.edu.br

Carlos H. G. Ferreira
Universidade Federal de Ouro Preto
João Monlevade, Minas Gerais
chgferreira@ufop.edu.br

Oscar William N. de Carvalho
Universidade Federal do Piauí
Teresina, Piauí
oscarwilliam@ufpi.edu.br

Glauber D. Gonçalves
Universidade Federal do Piauí
Teresina, Piauí
ggoncalves@ufpi.edu.br

ABSTRACT

The market for Non-Fungible Tokens (NFTs) continues to evolve, yet it still lacks robust methodologies to estimate the future value of its assets. Unlike traditional financial markets, NFT pricing is challenged by intangible factors such as the artistic nature of the items and the influence of social and transactional networks among buyers and sellers. This study investigates whether the structural position of participants in the transaction network can serve as a relevant predictor of the future value of NFTs. To this end, we reconstructed the NFT trading network for the period 2020–2021, extracted both structural and transactional metrics of the participants, and applied supervised machine learning models, including deep neural networks. The results demonstrate the feasibility of the proposed approach, achieving 74% accuracy and a global F1-Score of 72%. Interpretability analysis using SHAP values revealed that, in addition to historical price averages, network metrics such as degree and neighborhood significantly contribute to prediction. These findings highlight the role of network dynamics in NFT valuation and point toward promising directions for more transparent and evidence-based pricing methodologies.

KEYWORDS

Tokens Não-Fungíveis, Análise de Redes, Aprendizado de Máquina, Avaliação de Ativos

1 INTRODUÇÃO

A Web Descentralizada, conhecida também como *Web3*, vem transformando os conceitos de propriedade e valoração de ativos digitais [19]. Nesse contexto, *Non-Fungible Tokens* (NFTs) emergem como um dos principais mecanismos para materializar tais transformações [9]. Diferentemente de criptomoeda, que é considerada um token fungível, NFTs são atrelados a metadados exclusivos que os identificam de forma única, ou seja, não fungível [16]. Para isso, um NFT é vinculado a objeto físico ou puramente digital, como imagem, vídeo ou documento, cuja singularidade é reforçada pela personalização artística ou pela função social associada ao objeto.

In: I Workshop Brasileiro de Sistemas Web (BrWeb3 2025). Anais Estendidos do XXXI Simpósio Brasileiro de Sistemas Multimídia e Web (WebMedia'2025). Rio de Janeiro, Brasil. Porto Alegre: Brazilian Computer Society, 2025.
© 2025 SBC – Brazilian Computing Society.
ISSN 2596-1683

Além disso, a tecnologia blockchain assegura um registro imutável de autenticidade e propriedade intelectual, ampliando a confiança na negociação desses ativos [12].

O mercado de comercialização de NFTs, por sua vez, apresenta características incomuns, marcadas por picos de valorização ou desvalorização inesperada de ativos, frequentemente impulsionados por efeitos de rede de fãs ou por personalidades midiáticas que endossam o trabalho de artistas¹. Esse aspecto torna complexo estimar o valor corrente de um ativo e ainda mais desafiadora a previsão de seu valor futuro. A análise concentra-se no período de 2020 a 2021, marcado por forte especulação e alta volatilidade. Nesse contexto, plataformas de negociação como *OpenSea*, *Blur*, *Rarible*², entre outras, desempenham papel central ao fornecer mercados globais para comercialização de NFTs, além de disponibilizar registros detalhados de transações e valores desde a emissão do NFT (*mint*) em redes *blockchain*. Essas bases, como destacado em [10], tornam-se insumos valiosos para análises baseadas em mineração de dados e técnicas de aprendizado de máquina, viabilizando investigações quantitativas mais rigorosas sobre a precificação e dinâmica desses ativos.

Na literatura, estudos como os de [20], [1] e [17] concentram-se na classificação do comportamento de carteiras e na identificação de comunidades de usuários. Outros trabalhos, como os de [14] e [18], aplicam modelos para detectar comportamentos maliciosos e ataques na rede Ethereum. No caso específico dos NFTs, [6] e [3] investigam características estruturais para clusterização de coleções e identificação de tokens relevantes. Apesar desses avanços, ainda persiste uma lacuna no sentido de que há pouca investigação voltada à classificação de NFTs considerando diretamente a rede de transações entre agentes, limitando a compreensão sobre como a posição estrutural de vendedores e compradores impacta a precificação futura dos ativos.

Neste trabalho, propomos um método para avaliar o impacto da rede de compra e venda entre usuários nas negociações de NFTs. Essa investigação é particularmente relevante diante da escassez de estudos que quantifiquem como efeitos de rede influenciam a previsão do valor desses ativos. Partimos da hipótese de que a posição de um vendedor na rede de transações exerce influência substancial

¹Um exemplo de destaque foi a venda da coleção "WarNymph" da musicista Grimes, que arrecadou quase \$6 milhões em março de 2021. <https://www.bbc.com/news/technology-56252738>

²<https://opensea.io>, <https://blur.io>, <https://rarible.com>

sobre o valor futuro dos NFTs que ele comercializa. Nosso objetivo é quantificar essa influência de forma sistemática, em contraste com avaliações predominantemente subjetivas, como as analisadas em [11], ou com a ausência de critérios claros frequentemente observada no mercado³. Ao concentrarmos nossa análise em métricas de rede, buscamos oferecer uma compreensão mais objetiva e transparente dos fatores determinantes para a precificação de NFTs.

Nossos resultados validam a hipótese central deste trabalho. O modelo Multi-Layer Perceptron (MLP), que apresenta o melhor desempenho geral, alcança uma acurácia de 74% e um F1-Score global de 0.72 na tarefa de prever o quartil de preço futuro de um NFT. A análise de interpretabilidade com SHAP confirma que, além de características transacionais como o preço médio histórico do NFT, fatores estruturais como o grau médio dos vizinhos do vendedor (*mean_seller_neighbors*) e os graus de entrada e saída (*in_degree*, *out_degree*) estão entre os atributos mais influentes para as previsões do modelo. Em suma, as principais contribuições deste trabalho incluem a (i) validação quantitativa de que a posição de um vendedor na rede tem poder preditivo sobre o valor de seus ativos, e (ii) uma análise comparativa do desempenho de três modelos de classificação distintos para esta tarefa.

2 TRABALHOS RELACIONADOS

A literatura sobre o ecossistema de NFTs e suas particularidades tem crescido rapidamente ao longo dos anos, com estudos que buscam desvendar a dinâmica complexa desse mercado. Por exemplo, em [3], os autores analisam as propriedades topológicas da rede de transações de NFTs, evidenciando que estas se assemelham às redes sociais convencionais. Já no estudo de [15], essa ideia é complementada por meio da quantificação da evolução de redes de artistas, identificando a formação de grupos de sucesso impulsionados pelo fenômeno da homofilia. Em outros trabalhos, como [7], os autores exploram a inter-relação entre a inspiração visual e a performance financeira dos ativos digitais.

Diversos estudos também utilizam mineração de dados e técnicas de aprendizado de máquina para prever o desempenho de NFTs e caracterizar o comportamento dos nós que atuam nas redes. Em [10], os autores realizaram uma análise profunda e abrangente do mercado de NFTs, incluindo tendências de rede e de comércio, e em seguida aplicaram algoritmos de aprendizado de máquina para prever o preço de venda com base no histórico e em características visuais dos ativos. Em uma abordagem multimodal, [5] propuseram um modelo baseado em aprendizado profundo para previsão de preços de NFTs, explorando informações visuais e textuais, sem recorrer a métricas de rede ou financeiras. Já em [13], os autores investigam a eficiência de algoritmos de aprendizado supervisionado para classificar coleções de NFTs a partir de metadados, enquanto em [6] aplicaram técnicas de classificação não supervisionada para definir classes estruturais de coleções.

Em [4], o autor demonstra que as redes de vendedores e compradores são impulsionadas por laços preferenciais, nos quais os vendedores e artistas mais bem-sucedidos recebem atenção diferenciada do mercado. Apesar desses estudos, a literatura ainda é

³Um caso que ilustra bem isso foi o leilão da obra de arte digital "Everydays: The First 5000 Days" do artista Beeple, que atingiu o valor de \$69.3 milhões em 2021, <https://www.forbes.com/sites/jessedamiani/2021/03/12/beeples-the-first-5000-days-sold-to-metakovan-founder-of-metapurse-for-69346250/>

limitada no que diz respeito ao uso dessas métricas de forma preditiva para classificar o valor futuro dos NFTs. Assim, o presente trabalho se diferencia ao preencher essa lacuna, empregando métricas de rede extraídas de um período para prever a categorização de valor de NFTs em um período posterior. Para isso, utilizamos técnicas de aprendizado de máquina supervisionado no desenvolvimento de modelos de classificação. Nossa abordagem oferece uma metodologia explicável para compreender a relevância da estrutura da rede de transações na precificação de NFTs.

3 METODOLOGIA

Nesta seção, apresentamos a metodologia adotada. O código-fonte com dados e todas as rotinas descritas nesta seção estão disponíveis em repositório público⁴.

3.1 Conjunto de Dados e Modelagem da Rede

O conjunto de dados desta pesquisa foi obtido a partir da base pública de transações de NFTs disponibilizada no *Open Science Framework (OSF)* [10].

Para esta investigação, selecionamos as transações realizadas entre 2020 e 2021, período marcado pelo auge da comercialização de NFTs. Após pré-processamento, filtramos apenas os tokens transacionados em ambos os anos. Os dados foram então agrupados por identificador do token (*token_id*) e endereço do vendedor (*seller_address*), resultando em um total de 155.846 instâncias utilizáveis na base final, correspondentes a 59.908 NFTs únicos.

A rede de 2020 foi modelada como um grafo direcionado $G = (V, E)$, em que cada nó $v \in V$ corresponde a um endereço de usuário na rede blockchain⁵ e cada aresta $(u, v) \in E$ representa uma transação do vendedor u para o comprador v . O grafo resultante, com 69.435 arestas e 24.987 nós, serviu de base para o cálculo das métricas de cada nó.

3.2 Instanciação de Atributos

Os atributos considerados neste trabalho foram organizados em duas categorias de métricas de rede que são complementares entre si. As métricas estruturais dependem da modelagem da rede de transações como um grafo direcionado, capturando a posição relativa de cada nó na topologia da rede. Já as métricas transacionais são obtidas diretamente do conjunto de dados por meio de operações de agregação, refletindo padrões de compra e venda de cada nó. Essa distinção é importante porque permite analisar, de forma conjunta, tanto os efeitos da estrutura da rede quanto o histórico de negociações de cada nó.

Deve-se observar que as métricas estruturais e transacionais são originalmente atributos associados aos nós do grafo. No modelo de predição, entretanto, essas métricas passam a ser consideradas atributos dos NFTs transacionados, tomando sempre como referência os valores do último nó proprietário do NFT no período em que o grafo foi construído, por exemplo, o ano de 2020 em nossas análises. O alvo do modelo é definido como o preço médio de venda dos NFTs no ano subsequente, isto é, 2021 em nossas análises. Dessa forma, o treinamento e a avaliação do modelo incluem apenas NFTs

⁴https://github.com/LABPAAD/nfts_vp

⁵O endereço pode ser também um contrato inteligente, cujo comportamento é semelhante a um usuário para o modelo proposto.

que tenham sido negociados em ambos os períodos, ou seja, nos anos de 2020 e 2021.

3.2.1 Métricas Estruturais.

- Grau de Saída (*out_degree*): número de compradores únicos alcançados por um vendedor. Reflete a popularidade e alcance de mercado do vendedor. A premissa é que vendedores com maior visibilidade tendem a ter maior liquidez, o que pode elevar a percepção de valor de seus NFTs no futuro.
- Grau de Entrada (*in_degree*): número de vendedores únicos alcançados por um comprador. Relaciona-se à experiência e reputação como colecionador. Intuitivamente, compradores que interagem com muitos vendedores adquirem credibilidade e podem ser vistos como compradores confiáveis, o que aumenta a valorização de ativos revendidos por eles.
- Coeficiente de Agrupamento Local (*clustering_coefficient*): proporção de conexões existentes entre os vizinhos de um nó em relação ao total de conexões possíveis entre esses. Captura o nível de inserção em comunidades de negociação densas. A hipótese é que, em mercados mais fechados e interconectados, a circulação de informação e o apoio mútuo podem sustentar ou até inflacionar os preços dos NFTs.
- Grau Médio dos Vizinhos (*mean_neighbors_degree*): grau médio dos compradores de um vendedor. Reflete a centralidade e a qualidade de seus clientes. Assume-se que negociar com compradores influentes amplia a visibilidade do vendedor e o prestígio de seus ativos, impactando positivamente seus preços futuros.

3.2.2 Métricas Transacionais.

- Valor Médio de NFTs Vendidos (*NFT_mean_origin*): média dos valores dos NFTs vendidos por um nó. Esse atributo sintetiza o histórico de preços praticados pelo vendedor, funcionando como proxy de reputação e prestígio de mercado.
- Valor Médio de NFTs Comprados (*NFT_mean_destiny*): média dos valores dos NFTs comprados por um nó. Pode refletir a disposição de um nó para pagar, bem como o poder de compra e credibilidade que ele demonstra como colecionador.
- Valor Médio dos Vizinhos Compradores (*mean_buyer_neighbors*): média dos valores dos NFTs comprados pelos vizinhos diretos de um nó. Combina informações de vizinhança com valores de mercado, sugerindo que vender para compradores que lidam com NFTs de maior valor tende a aumentar as chances de preços futuros mais altos.
- Valor Médio dos Vizinhos Vendedores (*mean_seller_neighbors*): média dos valores dos NFTs vendidos pelos vizinhos diretos de um nó. Esse atributo reflete o nível médio de valorização no entorno do nó, funcionando como indicador indireto do prestígio da comunidade em que ele atua.

3.3 Modelos de Classificação

Para a tarefa de predição, utilizamos três modelos supervisionados clássicos, cada um representando uma estratégia distinta de aprendizado de máquina [2]: *Random Forest (RF)*, um modelo de conjunto baseado em múltiplas árvores de decisão; *Support Vector Machine (SVM)*, um modelo que busca maximizar a margem entre classes; e *Perceptron Multicamadas (MLP)*, uma rede neural artificial capaz de aprender representações complexas e não-lineares.

Os modelos foram implementados utilizando os parâmetros default para permitir uma comparação direta do desempenho intrínseco de cada algoritmo no problema de classificação. A comparação desses três modelos visa investigar abordagens mais simples como RF quanto técnicas de maior capacidade de inferência e custo computacional como SVM e MLP, equilibrando custo computacional e poder preditivo.

3.4 Treinamento, Avaliação e Interpretabilidade

Os dados foram normalizados e divididos em treino (80%) e teste (20%), de forma estratificada por classe. Definimos classes a serem preditas de acordo com o procedimento mostrado em [5]. Assim, discretizamos o alvo do modelo, que representa o preço médio de venda dos NFTs no período seguinte aos atributos de rede calculados. Utilizando os quartis da distribuição do preço médio, os NFTs foram divididos em três classes de valor: Baixo (Classe 0) correspondendo a 25% dos NFTs no 1º quartil, Médio (Classe 1) contando com 50% dos NFTs no 2º e 3º quartis e Alto (Classe 2) contando com 25% dos NFTs no 4º quartil. Por fim, o desempenho dos modelos foi avaliado utilizando as métricas Acurácia (ACC), Precisão (P), Revocação (R) e F1-Score (F1), todas em versão macro, assegurando equilíbrio na comparação entre classes [2].

Para interpretar os modelos, empregamos o *SHapley Additive exPlanations (SHAP)*, técnica baseada na teoria dos jogos cooperativos. O SHAP atribui a cada atributo a contribuição marginal que ele exerce sobre a predição, permitindo identificar não apenas se uma métrica influencia positivamente ou negativamente (\pm), mas também a magnitude dessa influência. Optamos pelo SHAP devido à sua capacidade de fornecer explicações consistentes e localmente fíeis, diferentemente de métodos mais opacos como *permutation importance* ou gradientes parciais. Assim, além de avaliar desempenho, garantimos transparência na interpretação dos fatores que mais impactam o valor futuro dos NFTs [8].

4 RESULTADOS

A Tabela 1 apresenta o desempenho dos três modelos de classificação implementados neste estudo, considerando as métricas de Precisão (P), Revocação (R), F1-Score (F1), Acurácia (Acc) e F1-Score global (F1) para as classes de preço Baixo, Médio e Alto.

Tabela 1: Comparativo de desempenho dos modelos MLP, Random Forest (RF), SVM

Métrica	Classe	MLP	RF	SVM
Precisão (P)	Baixo (Classe 0)	0,68	0,75	0,59
	Médio (Classe 1)	0,85	0,76	0,88
	Alto (Classe 2)	0,58	0,66	0,47
Revocação (R)	Baixo (Classe 0)	0,81	0,77	0,76
	Médio (Classe 1)	0,71	0,74	0,66
	Alto (Classe 2)	0,77	0,68	0,83
F1-Score (F1)	Baixo (Classe 0)	0,74	0,76	0,66
	Médio (Classe 1)	0,77	0,75	0,75
	Alto (Classe 2)	0,66	0,67	0,60
Acurácia (Acc)		0,74	0,73	0,70
F1-Score Global/Macro (F1)		0,72	0,72	0,67

Os resultados indicam que MLP apresentou a maior acurácia (0,74), seguido de perto por RF (0,73) e por SVM (0,70). O F1-Score global foi idêntico para MLP e RF (0,72), superando o SVM (0,67). Considerando as métricas por classe, observa-se que o MLP manteve um desempenho equilibrado: alcançou a maior precisão para a classe

de preço Médio (0,85), obteve a maior revocação para a classe de preço baixo (0,81) e bom desempenho para a classe de preço Alto.

Sobre os classificadores de menor desempenho é importante mencionar que RF exibiu resultados consistentes e intermediários em todas as classes, considerando seu baixo custo computacional, não superando apenas o desempenho do MLP para a maioria das métricas. O SVM, por sua vez, destacou-se na predição de NFTs na classe de preço Alto, alcançando revocação de 0,83, além de apresentar a maior precisão para a classe de preço Médio (0,88). Entretanto, essa vantagem foi acompanhada por quedas relevantes em outras métricas, como a baixa precisão para a classe Alto (0,47), o que evidencia instabilidade.

De forma geral, RF é o modelo que oferece previsões mais homogêneas e estáveis, sendo adequado para previsões rápidas em grandes volumes de dados com baixo custo computacional, mas sem alcançar o melhor desempenho de inferência. Já o MLP se mostrou o modelo mais robusto, conciliando melhores desempenhos para as três classes e na maioria das métricas avaliadas. Logo, focamos em MLP para as próximas análises.

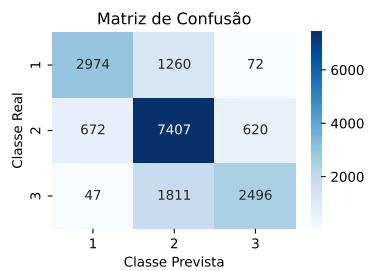


Figura 1: Matriz de confusão do modelo MLP.

A Figura 1 apresenta a matriz de confusão do MLP, permitindo examinar com maior detalhe a distribuição das previsões entre as classes reais e previstas. Observa-se que a classe de preço Médio foi a mais corretamente classificada, com 7.453 instâncias corretamente identificadas e menor incidência de erros. As classes Baixa (2.944 acertos) e Alta (2.439 acertos) se mostraram desafiadoras, tendo 1.292 e 1.866 erros, respectivamente, atribuídos à classe de preço Médio. Esse comportamento aponta para uma sobreposição entre os padrões das classes de preços alto e médio, possivelmente associada à variabilidade das características estruturais da rede e à heterogeneidade das transações nesse segmento.

A Figura 2 apresenta o impacto médio absoluto das variáveis no processo de decisão do MLP, calculado a partir dos valores SHAP. Observa-se que a variável `NFT_mean_origin` se destacou como a mais importante, indicando que o valor médio dos NFTs emitidos por um nó é um forte preditor do preço futuro. Em seguida, `mean_buyer_neighbors` surge como a segunda variável mais relevante, sugerindo que a média dos valores de compras dos vizinhos diretos exerce influência significativa na predição. As variáveis `out_degree` e `in_degree`, que representam respectivamente o número de vendas e compras por um nó, ocupam a terceira e quarta posições, apresentando relevância moderada, mas ainda assim com impacto considerável no modelo.

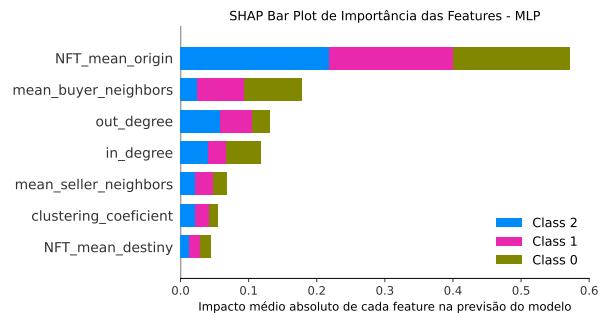


Figura 2: Importância de atributos de rede no melhor modelo (MLP).

As demais variáveis, como `mean_seller_neighbors`, `clustering_coefficient` e `NFT_mean_destiny`, mostraram importância reduzida, embora contribuam de forma residual para o processo de predição. De modo mais amplo, observa-se que tanto atributos transacionais (como o `NFT_mean_origin`) quanto métricas estruturais de rede (grau, vizinhança, coeficiente de agrupamento) desempenham papéis relevantes. Enquanto as métricas transacionais apresentaram maior impacto direto nas previsões de curto prazo, as estruturais capturaram efeitos mais globais associados à posição do nó na rede.

5 CONCLUSÕES E TRABALHOS FUTUROS

Este estudo demonstrou a viabilidade de utilizar métricas extraídas da rede de compra e venda de NFTs para prever o valor futuro desses ativos. Os resultados confirmam que a posição estrutural de um vendedor na rede, combinada a seu histórico de transações, é um fator relevante para a precificação desses ativos. O *Multi-layer Perceptron* (MLP) apresentou o melhor desempenho entre os modelos testados, com acurácia de 0,74 e *F1-Score* macro de 0,72. A análise de interpretabilidade via SHAP destacou a importância do valor médio de NFTs vendidos por um nó (`NFT_mean_origin`) e de métricas estruturais como grau de entrada e saída, fornecendo fortes evidências para validar a hipótese sobre a relevância de efeitos de rede no preço de NFTs, apresentada nesse trabalho.

Futuramente, análises com testes ou comparações de médias podem reforçar as conclusões. Além disso, novos atributos podem ser incorporados, em especial variáveis temporais (como frequência de negociação e tempo de atividade), que capturem a dinâmica da rede. Outra direção promissora é o uso de dados semiestruturados e textuais. Modelos de Linguagem de Grande Escala (LLMs) podem extrair representações semânticas de descrições e metadados dos NFTs, gerando atributos categóricos mais ricos. Também seria relevante avaliar arquiteturas de aprendizado baseadas em grafos (*Graph Neural Networks*), capazes de explorar a topologia da rede diretamente. Adicionalmente, uma evolução consiste na aplicação de algoritmos de regressão, que permitem a predição contínua do valor de venda, para uma estimativa de preço mais precisa.

AGRADECIMENTOS

Esta pesquisa é financiada com o apoio da Fundação de Amparo à Pesquisa do Piauí (FAPEPI) processo no. 00110.000473/2023-64 e Programa Institucional de Bolsas de Iniciação em Desenvolvimento Tecnológico e Inovação (PIBITI) UFPI.

REFERÊNCIAS

- [1] Ayana T Aspembitova, Ling Feng, and Lock Yue Chew. 2021. Behavioral structure of users in cryptocurrency market. *Plos one* 16, 1 (2021), e0242600.
- [2] Andriy Burkov. 2019. *The hundred-page machine learning book*. Vol. 1. Andriy Burkov Quebec City, QC, Canada.
- [3] Simone Casale-Brunet, Paola Ribecca, Patrick Doyle, and Marco Mattavelli. 2021. Networks of Ethereum Non-Fungible Tokens: A graph-based analysis of the ERC-721 ecosystem. In *2021 IEEE International Conference on Blockchain (Blockchain)*. IEEE, 188–195.
- [4] Giovanni Colavizza. 2023. Seller-buyer networks in NFT art are driven by preferential ties. *Frontiers in Blockchain* 5 (2023), 1073499.
- [5] Davide Costa, Lucio La Cava, and Andrea Tagarelli. 2023. Show me your NFT and I tell you how it will perform: Multimodal representation learning for NFT selling price prediction. In *Proceedings of the ACM Web Conference 2023* (Austin, TX, USA) (WWW '23). Association for Computing Machinery, New York, NY, USA, 1875–1885. <https://doi.org/10.1145/3543507.3583520>
- [6] Samuel de Oliveira Ribeiro, Dayan Ramos Gomes, Emanuel Coutinho, and Glauher Dias Gonçalves. 2023. Análise de Características Estruturais de Tokens não Fungíveis no Ethereum. In *Anais do VI Workshop em Blockchain: Teoria, Tecnologias e Aplicações*. SBC, 1–14.
- [7] Lucio La Cava, Davide Costa, and Andrea Tagarelli. 2025. Visually wired NFTs: Exploring the role of inspiration in non-fungible tokens. *ACM Transactions on the Web* 19, 2 (2025), 1–18.
- [8] Scott M Lundberg and Su-In Lee. 2017. A Unified Approach to Interpreting Model Predictions. In *Advances in Neural Information Processing Systems*, I. Guyon, U. Von Luxburg, S. Bengio, H. Wallach, R. Fergus, S. Vishwanathan, and R. Garnett (Eds.), Vol. 30. Curran Associates, Inc. https://proceedings.neurips.cc/paper_files/paper/2017/file/8a20a8621978632d76c43dfd28b67767-Paper.pdf
- [9] Alex Murray, Dennis Kim, and Jordan Combs. 2023. The promise of a decentralized internet: What is Web3 and how can firms prepare? *Business horizons* 66, 2 (2023), 191–202.
- [10] Matthieu Nadini, Laura Alessandretti, Flavio Di Giacinto, Mauro Martino, Luca Maria Aiello, and Andrea Baronchelli. 2021. Mapping the NFT revolution: market trends, trade networks, and visual features. *Scientific reports* 11, 1 (2021), 20902.
- [11] Mark Ng, Monica Law, Chi-Bo Wong, and Michael Liang. 2025. Drivers of non-fungible token (NFT) investment intention: the roles of innovativeness, knowledge, subjective norms and perceived value. *Journal of Electronic Business & Digital Economics* (2025).
- [12] Renana Peres, Martin Schreier, David A Schweidel, and Alina Sorescu. 2023. Blockchain meets marketing: Opportunities, threats, and avenues for future research. *International Journal of Research in Marketing* 40, 1 (2023), 1–11.
- [13] Samuel Ribeiro, Dayan Gomes, Nara Andrade, Emanuel Miranda, and Glauher Gonçalves. 2024. Classificação de Coleções de NFTs Explorando Meta-dados e Aprendizagem de Máquina. In *Anais do II Colóquio em Blockchain e Web Descentralizada* (Brasília/DF). SBC, Porto Alegre, RS, Brasil, 50–55. <https://doi.org/10.5753/cblockchain.2024.3172>
- [14] Rohit Saxena, Deepak Arora, and Vishal Nagar. 2023. Classifying transactional addresses using supervised learning approaches over Ethereum blockchain. *Procedia Computer Science* 218 (2023), 2018–2025.
- [15] Kishore Vasan, Milán Janosov, and Albert-László Barabási. 2022. Quantifying NFT-driven networks in crypto art. *Scientific reports* 12, 1 (2022), 2769.
- [16] Qin Wang, Ruijia Li, Qi Wang, and Shiping Chen. 2021. Non-Fungible Token (NFT): Overview, Evaluation, Opportunities and Challenges. *arXiv preprint arXiv:2105.07447* (2021).
- [17] Sissi Xiaoxiao Wu, Zixian Wu, Shihui Chen, Gangqiang Li, and Shengli Zhang. 2021. Community detection in blockchain social networks. *Journal of Communications and Information Networks* 6, 1 (2021), 59–71.
- [18] Guangquan Xu, Bingjiang Guo, Chunhua Su, Xi Zheng, Kaitai Liang, Duncan S Wong, and Hao Wang. 2020. Am I eclipsed? A smart detector of eclipse attacks for Ethereum. *Computers & Security* 88 (2020), 101604.
- [19] Javad Zarrin, Hao Wen Phang, Lakshmi Babu Saheer, and Bahram Zarrin. 2021. Blockchain for decentralization of internet: prospects, trends, and challenges. *Cluster Computing* 24, 4 (2021), 2841–2866.
- [20] Yiqing Zhu. 2023. *Classificação das carteiras na Blockchain Ethereum usando machine learning*. Ph.D. Dissertation. Instituto Superior de Economia e Gestão.