

Sistema híbrido de suporte à decisão de investimentos em criptomoedas

Juan G. Lazo Lazo*. Gonzalo H. Herrera Medina*. Luciana Faleti Almeida**.
Alvaro Talavera*

*Departamento Académico de Ingeniería, Universidad del Pacífico, Lima,
Perú (e-mail: jg.lazol@up.edu.pe, g.herreramedina@alum.up.edu.pe, ag.talaveral@up.edu.pe).

** Departamento de Engenharia Elétrica, Centro Federal de Educação Tecnológica Celso Suckow da Fonseca,
Rio de Janeiro, Brasil, (e-mail: lucianafaletti@gmail.com)

Abstract: Cryptocurrencies in recent years have been attracting all kinds of investors, from natural people to financial institutions that seek high returns, based on their rapid appreciation. However, this market is characterized by the level of volatility and uncertainty, leading the price to very high and also low levels these characteristics present great difficulty for the decision-making of investment managers. This work proposes a methodology to support decision making in investment management in the cryptocurrency market, which considers a conservative investment position, which seeks to reduce risk and maximize return on investment. The methodology seeks, based on the historical price of cryptocurrencies, establishes return levels and estimates the probabilities of the transition of returns for each level, this is done based on the analysis of Markov chains, which are integrated into the multiple decision trees to identify the cryptocurrency that projects the greatest return when it is sold in one or two periods after of the acquisition. The results are compared with the real data and the efficiency of the methodology is verified.

Resumo: As criptomoedas nos últimos anos vêm atraindo todo tipo de investidores, desde pessoas até instituições financeiras, que buscam altos retornos, com base em sua rápida valorização. No entanto, esse mercado é caracterizado pelo nível de volatilidade e incerteza, levando os preços a níveis muito altos e também a níveis baixos, estas características geram uma grande dificuldade para a toma de decisões dos gestores de investimentos. Este artigo propõe uma metodologia de apoio à toma de decisões no gerenciamento de investimentos no mercado de criptomoedas, que considera uma posição conservadora de investimento, que busca reduzir o risco e maximizar o retorno do investimento. A metodologia visa, com base no preço histórico das criptomoedas, estabelecer níveis de retorno e estimar as probabilidades de transição dos retornos para cada nível, isso é feito com base na análise das cadeias de Markov, que são integradas nas múltiplas árvores de decisão para identificar a criptomoeda que projeta o maior retorno quando é vendida um ou dois períodos após a aquisição. Os resultados são comparados com os dados reais e a eficiência da metodologia é verificada.

Keywords: Cryptocurrencies, Investment Management, Investment Decision, Markov Chains, Decision Trees.

Palavras-chaves: Criptomoedas; Gestão de Investimentos; Decisão de investimento, Cadeias de Markov, Árvores de decisão.

1. INTRODUÇÃO

Desde sua criação em 2009, com o lançamento da primeira criptomoeda, Bitcoin, o mercado de criptomoedas cresceu rapidamente, atraindo atenção tanto na mídia, redes sociais, meios empresariais, meios políticos e representantes de governos em todo o mundo. Também despertou forte interesse em investidores e instituições financeiras, especialmente por algumas de suas características, como o uso de criptografia para o processo de validação de transações, sendo anônimas, mais rápidas e mais simples que o uso de cartões de crédito (Nakamoto, 2008; Cocco et al. 2017). Além disso, as criptomoedas não exigem instituições intermediárias, como um banco central ou outro que controle ou emita uma criptomoeda. Todas as transações são avaliadas e armazenadas na rede, que é uma rede, em formatos ponto a ponto, coletiva com protocolo comum para adicionar e validar novos blocos

(Iglesias de Ussel, 2015). Devido a essas características, as criptomoedas têm sido cada vez mais aceitas pelas empresas e pelo público como meio de pagamento (Cuthbertson, 2015; Chokun, 2018; Moreau, 2019), favorecendo sua valorização. Assim, o mercado de criptomoedas nos últimos anos vem conseguindo atenção e atraindo cada vez mais investidores, devido à valorização alcançada pelas criptomoedas. Mas esse mercado, apesar de atraente para obter grandes retornos, também representa grandes riscos para os investidores, devido à grande variabilidade que os preços podem ter (Caporale e Zekokh 2019; Mallqui e Fernandes, 2019), isso porque, diferente de outros mercados, é realmente um mercado global, onde os preços são influenciados por muitas variáveis, como decisões ou expectativas de qualquer governo do mundo sobre criptomoedas, criação de novas criptomoedas que podem causar o fluxo de capital para a desvalorização de outros, divulgação de notícias verdadeiras ou falsas, sentimentos de

pessoas nas redes sociais sobre uma ou mais criptomoedas, o desempenho de várias variáveis econômicas locais ou globais, entre outras. Além disso, os mercados financeiros estão começando a criar vários instrumentos de investimento para criptomoedas, como o mercado futuro baseado em Bitcoin, causando interesse e maior participação de investidores institucionais.

Assim, ao investir em criptomoedas, os gestores de investimento precisam enfrentar essas características que influenciam o preço e, principalmente, a volatilidade da taxa de câmbio, o que representa o principal risco de investimentos em criptomoedas (Van Alstyne, 2014; McIntyre e Harjes, 2016; Peng et al. 2018; Yermack, 2013). A gestão de investimentos busca maximizar a rentabilidade, controlar e minimizar os riscos. Para isso, devem ser buscadas e selecionadas as melhores oportunidades de investimento. Para realizar esta atividade, é necessário que o gestor analise as diferentes informações do mercado e as informações de cada ativo. Essa tarefa é cansativa, demorada e de grande importância para investimentos, por isso é muito relevante ter ferramentas para apoiar essas atividades.

Nesse sentido, este trabalho propõe uma metodologia simples, rápida e eficiente, que serve como uma ferramenta para apoiar à tomada de decisões em gerenciamento de investimentos para o mercado de criptomoedas. Considerando uma posição de investimento conservadora, que deve diminuir o risco e maximizar retorno do investimento, selecionando em qual criptomoeda o investimento deve ser realizado para obter um maior retorno (qual comprar) e indicando quando sair do investimento (quando vender a criptomoeda). Tal metodologia é realizada com base na análise das probabilidades de mudança de status dos retornos para os dois períodos seguintes para os quais são usadas as cadeias de Markov, que construirão árvores de decisão para os próximos dois períodos. Os resultados encontrados foram satisfatórios, pois a metodologia de suporte à decisão indica a criptomoeda mais rentável para as semanas seguintes, que é verificada com os dados reais.

Este artigo está organizado da seguinte forma: a seção 2 apresenta uma revisão da literatura relacionada a finanças e economia de criptomoedas, a seção 3 apresenta a metodologia proposta, a seção 4 analisa os dados e resultados e, finalmente, na seção 5 conclusões são apresentadas

2. REVISÃO DA LITERATURA

O *Blockchain* é uma tecnologia de registro distribuído, que utiliza criptografia, é descentralizada, ponto a ponto, pública e inalterável, na qual as criptomoedas são implementadas. Mantém um registro permanente de transações, agrupando várias transações em blocos e, em seguida, agrupa-as em uma cadeia de blocos (Nakamoto, 2008), onde cada transação possui um carimbo de data, hora e código de identificação (assinatura digital) vinculado à entrada anterior. A rede de uma criptomoeda é formada por uma grande quantidade variável de computadores conectados via internet, chamados nós; esses nós realizam cálculos matemáticos complexos com os quais verificam a precisão e a veracidade das transações; assim quando terminam esses cálculos, um novo bloco é adicionado a cadeia (*Blockchain*), que não pode ser alterada sem refazer todo o trabalho de cálculos matemáticos. Como incentivo, uma

nova moeda é criada, sendo o proprietário responsável pela geração do bloco, que é uma transação especial e representa a primeira transação em um bloco. A quantidade total de moedas eletrônicas ou criptomoedas que pode ser criada é equivalente a 21 milhões. Essa ação evita o risco de aumentar o número de moedas e gerar inflação (Cocco et al. 2017; Mallqui e Fernandes, 2019).

Nos últimos anos, vêm-se realizando estudos sobre o comportamento das criptomoedas, usando principalmente o Bitcoin como moeda de estudo, principalmente porque é a primeira e mais valiosa moeda eletrônica lançada no mercado. Tais estudos, analisam o comportamento do Bitcoin como uma forma de moeda em particular, usando frequentemente a volatilidade do Bitcoin para explicar seu comportamento com base em modelos estatísticos conhecidos na literatura financeira. Entre esses estudos, temos o de Balcilar et al. (2017), onde realiza um teste não paramétrico de causalidade inquantiles para identificar a relação causal entre o volume de operações com os retornos e a volatilidade do Bitcoin, Al-Yahyaee et al. (2018) avalia a eficiência do mercado de Bitcoin, comparando-o com o mercado de ouro, ações e moedas, Chaim e Laurini (2019) busca estudar a dependência não linear dos mercados de criptomoedas através do estudo da dinâmica dos retornos e da volatilidade das principais criptomoedas, Yu et al. (2019) estuda como a volatilidade dos retornos do Bitcoin é afetada pela disponibilidade de informações no mercado, Beneki et al. (2019) estuda a existência de capacidades de *hedging* entre Bitcoin e Ethereum, testando a transmissão de volatilidade unidirecional do Ethereum para Bitcoin e concluindo que é possível estabelecer estratégias de negociação lucrativas em um mercado de derivativos. Outros trabalhos buscam construir modelos estatísticos para fazer previsões da volatilidade, dos retornos ou do preço futuro do Bitcoin, como pode ser visto em Catania et al. (2019) que, através do uso de modelos estatísticos univariados e multivariados, prova que a previsibilidade das criptomoedas é possível, também em Eom et al. (2019), que estuda as características estatísticas, a previsibilidade do retorno e volatilidade do Bitcoin, comparando a alta volatilidade e a forte dependência do sentimento dos investidores para explicar as mudanças na volatilidade. Estudos recentes, abordam esse mesmo problema usando técnicas de *machine learning* e inteligência computacional, como em Mallqui e Fernandes (2019), que usa técnicas de *machine learning* para prever os preços diários do Bitcoin, alcançando em alguns casos um bom nível de previsão, melhorando os resultados apresentados na literatura, mas ainda com erros significativos de previsão em outros casos. Em Kristjanpoller e Minutolo (2018), propõe-se um modelo híbrido de redes neurais artificiais e *Generalized AutoRegressive Conditional Heteroskedasticity* (ANN-GARCH) para prever a volatilidade dos preços do Bitcoin. Já Lahmiri e Bekiros (2019) abordam o problema de prever preços de criptomoedas (Bitcoin, Digital Cash e Ripple) usando técnicas de *deep learning*, como as topologias *long-short term memory neural network* (LSTM), verificando um certo grau de eficiência nas previsões de preços. Também em estudos recentes, o comportamento do Bitcoin nas carteiras de investimentos com outros ativos financeiros (ações, futuros ou moedas) é analisado, como em Brière et al. (2015) que analisa

o comportamento de um portfólio diversificado (ações mundiais, bônus, moedas fortes) e Bitcoin, provando que a inclusão de uma pequena proporção de Bitcoins pode melhorar significativamente o desempenho do portfólio no nível de retorno, compensando o risco de portfólios bem diversificados. Em Symitsi e Chalvatzis (2019), foi avaliado o desempenho das carteiras sob quatro estratégias, verificando os benefícios da diversificação ao incluir o Bitcoin, mas a diminuição do risco da carteira devido à baixa correlação com outros ativos não é compensada pela sua alta volatilidade. Em Kajtazi e Moro (2019) analisa-se os efeitos da adição de Bitcoin a um portfólio ideal para os mercados dos EUA, Europa e China, mostrando que o desempenho do portfólio melhora, mas confirma as características especulativas do Bitcoin. Também existem trabalhos que estudam a influência das redes sociais e da internet nas criptomoedas, tanto no comportamento de seus preços e volatilidade quanto na capacidade de previsão, conforme mostrado em Smuts (2018), Park e Park (2019) e Nasir et al. (2019). Pesquisas relacionadas a criptomoedas estão apenas começando, bem como o uso de criptomoedas no mercado financeiro, no entanto, ainda existem poucos trabalhos que buscam fornecer estratégias que apoiem os investidores na tomada de decisões de investimento em criptomoedas, como é o objetivo deste trabalho. A seguir serão apresentados alguns conceitos relevantes sobre o mercado financeiro e as técnicas utilizadas neste trabalho:

2.1 Retorno do investimento

É a razão que compara o benefício ou o lucro obtido em relação ao investimento realizado, expressa-se em porcentagem, para calcular o retorno do investimento em ativos financeiros em geral, são utilizados os preços de compra e venda do ativo (Elton et al. 2009), como apresentado por (1):

$$R_t = \frac{P_t - P_{t-1}}{P_t} * 100 \quad (1)$$

Onde R_t é o retorno obtido no momento t , P_t é o preço do ativo (criptomoeda) no momento t (no momento da venda), P_{t-1} é o preço do ativo no momento $t - 1$ (no momento da compra).

2.2 Cadeias de Markov

As cadeias de Markov permitem modelar sistemas probabilísticos e de mudança de estado. É um processo estocástico em um tempo discreto, o qual cumpre com a propriedade de Markov (Draheim, 2017), o que significa que a probabilidade de ocorrência de um evento depende apenas do evento anterior. Sendo n um instante no tempo e s_n um estado ou valor que leva a variável X no instante n , na equação (2) pode-se observar que a probabilidade de ocorrência do evento $X_{n+1} = s_{n+1}$, dados n eventos anteriores ($X_0 = s_0, \dots, X_n = s_n$), é igual com a probabilidade do mesmo evento, dado o evento imediatamente anterior $X_n = s_n$. Essa probabilidade condicional é chamada de probabilidade de transição, ou seja, a probabilidade de passar de um estado no n ésimo instante para um estado no instante $n+1$. São essas probabilidades de transição que compõem a matriz de transição (Howard, 2012), que caracteriza uma cadeia de Markov (3).

$$P(X_{n+1} = s_{n+1} | X_0 = s_0, \dots, X_n = s_n) = P(X_{n+1} = s_{n+1} | X_n = s_n) \quad (2)$$

Onde X_n é a variável X no n ésimo momento, s_n é o n ésimo estado ou n ésimo valor que a variável X assume, $P(X_{n+1} = s_{n+1} | X_n = s_n)$ é a probabilidade de transição do n ésimo estado para um estado no instante $n+1$.

$$P' = \begin{pmatrix} p_{1,1} & \dots & p_{1,i} \\ \vdots & \ddots & \vdots \\ p_{i,1} & \dots & p_{i,i} \end{pmatrix} \quad (3)$$

Onde P' é a matriz de transição, $p_{1,1}$ é a probabilidade de permanecer no estado 1, $p_{1,i}$ é a probabilidade de passar para o estado i a partir do estado 1, $p_{i,1}$ é a probabilidade de ir para o estado 1 a partir do estado i , $p_{i,i}$ é a probabilidade de permanecer no estado i .

No entanto, para encontrar a probabilidade de transição em mais de um instante no futuro, ou seja, a probabilidade de transição de um estado s_n para um estado s_{n+m} em que $m \geq 2$, é necessário usar a equação de Chapman-Kolmogorov (Hachigian, 1963), no qual a matriz de transição deve ser elevada para o número de instantes no futuro. Portanto, como observado em (4), para encontrar a probabilidade de transição do estado i para o estado j em m instantes seguintes desde o estado no n ésimo momento, a matriz de transição P' é elevada à potência de m e o elemento i,j será a probabilidade de transição procurada.

$$p_{i,j}(m) = (P'^m)_{i,j} \quad (4)$$

Onde $p_{i,j}(m)$ é a probabilidade de passar do estado i para o estado j em m etapas, $(P'^m)_{i,j}$ é o elemento i,j da matriz de probabilidade de transição elevada a m .

2.3 Árvore de decisão

É uma técnica de apoio à tomada de decisão na presença de incerteza (Hulett, 2006) onde decisões subsequentes são condicionadas por decisões tomadas previamente (Vitoriano, 2007). Consiste em nós de decisão, representados por quadrados, dos quais derivam as possíveis alternativas a escolher, e nós de probabilidade ou estado, representados por círculos, de onde desprendem-se os possíveis estados S (Maya Lopera, 2018). A Figura 1 apresenta a representação básica de uma árvore de decisão. Para obter um resultado, é necessário indicar a probabilidade de cada estado, $P(S_{i,j})$, bem como seu valor representativo ou estimado, $V_{i,j}$. A soma total das probabilidades de cada ramo deve ser igual a um (Kamiński et al. 2018).

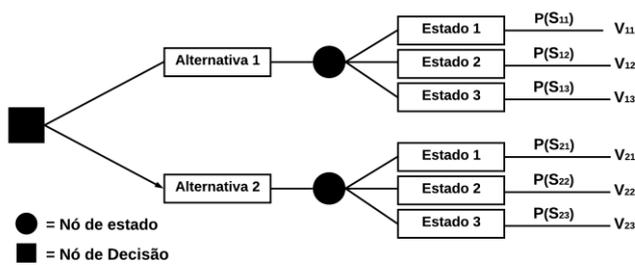


Fig. 1 Representação básica de uma árvore de decisão.

Com a árvore de decisão construída, o valor esperado de cada decisão é calculado pela soma ponderada dos valores representativos de cada estado, como pode ser visto em (5):

$$VE_i = \sum_{j=1}^{n_i} P(S_{i,j}) * V_{i,j} \quad (5)$$

Onde VE_i é o valor esperado da alternativa de decisão d_i , $P(S_{i,j})$ é a probabilidade do estado j , dada a decisão d_i , $V_{i,j}$ é o valor representativo da decisão d_i , dado o estado j , e n_i é o número de estados do nó de estado i . Finalmente, a alternativa com o maior valor esperado (VE) será a escolha ideal.

3. METODOLOGIA

A metodologia proposta visa apoiar à tomada de decisão para investir em duas criptomoedas para um horizonte semanal de tomada de decisão; essa metodologia consiste em quatro estágios. O primeiro é a coleta e integração de dados de cotação semanal para as criptomoedas escolhidas. O segundo estágio corresponde ao processamento de dados, cálculo de retornos semanais, criação de intervalos de rentabilidade e separação de dados, com eles, as probabilidades de transição foram calculadas para os respectivos períodos e foram calculados os valores médios de cada intervalo, que servirá de entrada para as árvores de decisão. No terceiro estágio, as árvores de decisão são construídas. Finalmente, no quarto estágio, os resultados são avaliados para obter a melhor estratégia de investimento. A Figura 2 mostra um diagrama com os estágios da metodologia e a seguir descreve-se cada estágio.

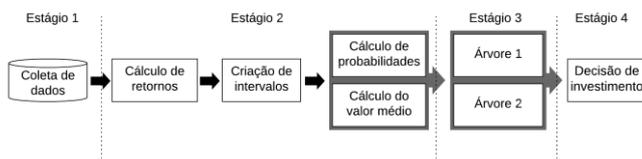


Fig. 2 Diagrama com as etapas da metodologia.

3.1 Primeiro estágio

Consiste em obter os dados da série histórica dos preços de fechamento semanais (*Close Price*) de duas criptomoedas: *Ethereum* e *Ripple*, obtidas através da plataforma web *Yahoo Finance*, desde o primeiro registro na plataforma de cada criptomoeda até em 5 de novembro de 2018. Para o *Ethereum*, foram obtidos dados de preços de fechamento de 167 semanas e para os dados do *Ripple* de 199 semanas. Esses dados foram divididos em dois conjuntos, o primeiro composto por todos os dados históricos até 7 de outubro de 2018, os que são

utilizados para a construção da metodologia e os demais dados do conjunto de testes utilizados para avaliar o resultado.

3.2 Segundo estágio

Consiste no processamento de dados começando com o cálculo dos retornos semanais a partir do histórico de preços de fechamento de ambas as criptomoedas, usando (1). A partir do histórico de retorno semanal, foram criados 5 intervalos ou níveis de retorno para cada criptomoeda, que representa o quão atraente é o retorno em cada criptomoeda para a gestão de investimentos, definindo os intervalos como: Negativo, Baixo, Médio, Alto e Muito Alto. A Tabela 1 apresenta a definição de intervalos para cada denominação de nível de rentabilidade.

Tabela 1. Intervalos de retorno

Retorno	Intervalos
Negativo	$]-\infty, 0[$
Baixo	$[0, 20\%[$
Médio	$[20\%, 50\%[$
Alto	$[50\%, 70\%[$
Muito Alto	$[70\%, +\infty[$

Em seguida, as probabilidades de transição de um estado ou intervalo de retorno foram calculadas usando o processo de Markov ou cadeias de Markov, calculando primeiro as frequências absolutas (f) das vezes em que um nível de retorno passa para outro. Ou seja, o número de vezes que o nível de retorno h é passado para o nível h, i, j, k, l . A Figura 3 ilustra o diagrama de transição do nível de retorno h para os vários níveis de retorno (h, i, j, k, l).

Usando frequências absolutas, foram calculadas frequências relativas, que podem ser traduzidas como probabilidades de transição de um nível de retorno para outro. Estes foram agrupados em uma matriz para cada criptomoeda, respectivamente (Tabela 2). Essas matrizes são chamadas: Matrizes de Probabilidade de Transição; para entender a interpretação de seus valores, a matriz de probabilidade de transição para *Ethereum* será usada como exemplo, onde se lê que: Se o retorno desta semana foi *negativo*, é provável que o retorno semanal seja *negativo* na semana seguinte em $45,21\%$.

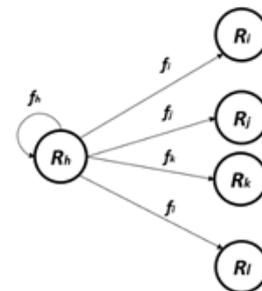


Fig. 3 Diagrama de transição do nível de rentabilidade h para os níveis de rentabilidade h, i, j, k, l

Tabela 2. Matriz de probabilidade de transição dos níveis de rentabilidade *Ethereum* e *Ripple* (primeira semana)

Ethereum					
Nível de Retorno	Negativo	Baixo	Médio	Alto	Muito Alto
Negativo	45.21%	46.58%	5.48%	2.74%	0.00%
Baixo	49.25%	35.82%	11.94%	2.99%	0.00%
Médio	37.50%	18.75%	12.50%	18.75%	12.50%
Alto	14.29%	57.14%	28.57%	0.00%	0.00%
Muito Alto	50.00%	50.00%	0.00%	0.00%	0.00%
Ripple					
Nível de Retorno	Negativo	Baixo	Médio	Alto	Muito Alto
Negativo	53.27%	36.45%	7.48%	0.93%	1.87%
Baixo	66.70%	23.33%	8.33%	0.00%	1.67%
Médio	44.40%	33.33%	11.11%	0.00%	11.11%
Alto	0.00%	0.00%	50.00%	0.00%	50.00%
Muito Alto	33.33%	16.67%	33.30%	16.67%	0.00%

Essas matrizes refletem a probabilidade de transição para uma semana, isto é, da semana (t) para a semana seguinte ($t+1$), em seguida a metodologia da Cadeia de Markov é aplicada para calcular as matrizes de probabilidade de transição para as duas semanas seguintes ($t+2$), é necessário elevar as matrizes de probabilidade de transição (M) de cada criptomoeda para o número de períodos subsequentes; portanto, as probabilidades de transição dos níveis de rentabilidade semanal de t para $t+1$ é M^1 e de t para $t+2$ é M^2 . A Tabela 3 apresenta as matrizes de probabilidade de transição dos níveis de retorno de Ethereum e Ripple para a segunda semana.

A seguir, para a construção das árvores de decisão, é necessário um valor representativo para cada ramificação, de forma que os valores esperados de cada decisão possam ser calculados. Para isso, os valores médios dos retornos pertencentes a cada intervalo (Negativo, Baixo, Médio, Alto, Muito Alto) foram calculados para cada criptomoeda. A Tabela 4 mostra os valores médios de retorno para cada intervalo e para cada criptomoeda. Pode-se observar que no passado, segundo os valores médios de cada intervalo, as rentabilidades de ambas criptomoedas são relativamente semelhantes, a exceção do intervalo Muito Alto, onde o retorno médio do Ripple é muito maior que do Ethereum, isto indica que se em algum momento no futuro na árvore se passar deste estado será possível obter ganhos significativamente altos, mas estes ganhos dependerão das probabilidades de transição.

3.3 Terceiro estágio

Nesse estágio as árvores de decisão são construídas. Essa ferramenta permite que o gestor de investimentos escolha a melhor opção de investimento entre as duas criptomoedas. Nesse caso, qual das criptomoedas fornecerá ao investidor um retorno esperado mais alto e, com isso, a melhor decisão de compra; as árvores são construídas para os dois períodos e, assim, se compara os resultados de cada árvore para obter também o melhor momento para vender o ativo. Os dados de entrada para cada árvore foram os valores médios e as matrizes de probabilidade de transição para cada período correspondente, sendo o estado inicial das duas criptomoedas: Retorno Negativo, portanto as probabilidades de transição

serão usadas a partir desse nível. Assim, duas árvores de decisão foram construídas.

Tabela 3. Matriz de probabilidade de transição dos níveis de rentabilidade do Ethereum e Ripple (segunda semana)

Ethereum					
Nível de Retorno	Negativo	Baixo	Médio	Alto	Muito Alto
Negativo	45.82%	40.33%	9.51%	3.66%	0.68%
Baixo	44.81%	39.72%	9.32%	4.66%	1.49%
Médio	39.80%	43.49%	11.21%	3.93%	1.56%
Alto	45.32%	32.48%	11.18%	7.45%	3.57%
Muito Alto	47.23%	41.20%	8.71%	2.86%	0.00%
Ripple					
Nível de Retorno	Negativo	Baixo	Médio	Alto	Muito Alto
Negativo	56.62%	30.72%	8.49%	0.81%	2.90%
Baixo	53.33%	32.80%	8.41%	0.90%	2.56%
Médio	54.54%	29.53%	11.04%	2.27%	2.62%
Alto	38.89%	25.00%	22.22%	8.33%	5.56%
Muito Alto	43.68%	27.15%	15.92%	0.31%	12.94%

Tabela 4. Valor médio de retorno por intervalo e por criptomoeda

Criptomoeda	Negativo	Baixo	Médio	Alto	Muito Alto
Ethereum	-11.10%	7.97%	33.66%	62.10%	79.16%
Ripple	-10.08%	6.32%	30.27%	61.10%	203.63%

3.4 Quarto estágio

Consiste em avaliar os resultados das árvores de decisão, obtendo a melhor estratégia de investimento em criptomoeda para o gestor de investimentos. A decisão consiste em qual criptomoeda investir e se a venda será realizada uma ou duas semanas após a sua compra buscando obter maior rentabilidade. Para obter a decisão ideal de investimento, duas árvores de decisão foram construídas usando as probabilidades de transição de cada criptomoeda para uma ou duas semanas (Tabela 2 e Tabela 3). A árvore da semana 1 permite obter a melhor decisão de investimento, caso você queira vender a criptomoeda uma semana após a compra e o retorno esperado da decisão é obtido, enquanto a árvore da semana 2 fornece a melhor decisão de investimento entre as duas criptomoedas, caso você queira vender duas semanas após o investimento e se obtém o retorno esperado da decisão.

4. RESULTADOS

Depois que as árvores são construídas, a melhor decisão de investimento pode ser obtida. Como mostra a Figura 4, a árvore correspondente à decisão de venda uma semana após a compra, apontando como melhor resultado a decisão de investir no Ripple, com um retorno esperado de 3,57%, superando o retorno esperado do investimento no Ethereum. No caso da árvore para a decisão de venda duas semanas após o investimento, a Figura 5 resulta em investimentos no Ripple, com um retorno esperado de 5,34%.

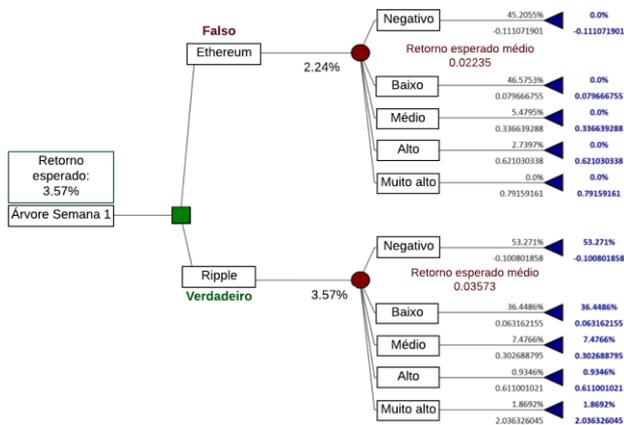


Fig. 4. Árvore de decisão para a decisão de venda uma semana após o investimento

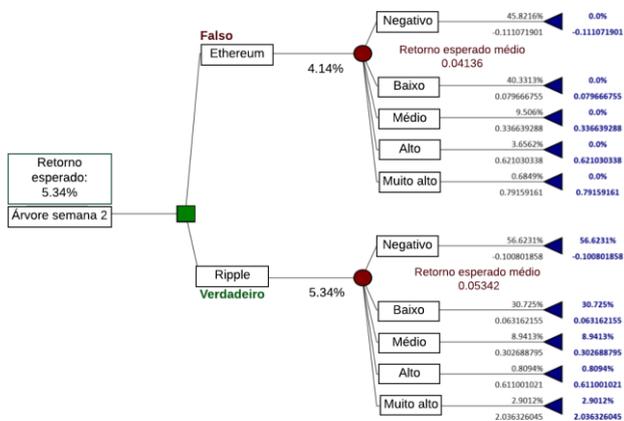


Fig. 5. Árvore de decisão para a decisão de venda duas semanas após o investimento

A Tabela 5 apresenta a comparação dos resultados da metodologia proposta, as decisões indicadas por cada árvore de decisão, a estimativa dos intervalos de retorno esperados para cada criptomoeda na primeira e segunda semana e o valor esperado de retorno, que são comparados com os valores reais, tanto em decisão, intervalo de retorno registrado e valor de retorno real. Observa-se que a metodologia proposta estima adequadamente o intervalo de retorno em que o Ethereum e o Ripple foram encontrados nas duas semanas, da mesma forma, a decisão de investimento sugerida (investir no Ripple) é a melhor para a primeira e a segunda semana. Apesar do retorno esperado diferir um pouco do real, isso não é muito relevante, pois o objetivo da metodologia é estimar adequadamente o intervalo de retorno (não a previsão de retorno), que foi realizada corretamente.

5. CONCLUSÕES

Este trabalho procura apoiar a gestão de investimentos na avaliação da decisão de investimento em duas criptomoedas, Ripple ou Ethereum, considerando que, ao comprar uma, a venda poderá ser feita em uma ou duas semanas depois. A metodologia proposta, baseada em cadeias de Markov e em árvores de decisão, provou ser muito eficiente no apoio à decisão de investimento, ao sugerir corretamente em qual

criptomoeda investir e estimar adequadamente seus níveis de retorno pelas próximas duas semanas, orientando a decisão para a criptomoeda que apresentará a maior rentabilidade nas seguintes duas semanas. Os resultados mostraram que as cadeias de Markov estimaram eficientemente as probabilidades de transição de um estado, o nível de retorno, para outro dentro da árvore de decisão.

Tabela 5. Comparação de valores reais e esperados para cada árvore de decisão

Semana 1						
Nível de Retorno	Resultado da Metodologia			Resultados Reais		
Criptomoeda	Melhor Alternativa	Intervalo	Retorno Esperado	Melhor Alternativa	Intervalo	Retorno Real
Ethereum	2da Melhor	Retorno Baixo	2.23%	2da Melhor	Retorno Baixo	5.01%
Ripple	1ra Melhor	Retorno Baixo	3.57%	1ra Melhor	Retorno Baixo	13.50%
Semana 2						
Nível de Retorno	Negativo	Baixo	Médio	Resultados Reais		
Criptomoeda	Melhor Alternativa	Intervalo	Retorno Esperado	Melhor Alternativa	Intervalo	Retorno Real
Ethereum	2da Melhor	Retorno Baixo	4.41%	2da Melhor	Retorno Baixo	4.48%
Ripple	1ra Melhor	Retorno Baixo	5.34%	1ra Melhor	Retorno Baixo	15.31%

REFERÊNCIAS

- Al-Yahyaee, K. H., Mensi, W., Yoon, S. Mn. (2018). Efficiency, multifractality, and the long-memory property of the Bitcoin market: A comparative analysis with stock, currency, and gold markets. *Finance Research Letters*, 27, pp. 228–234.
- Balcilar, M., Bouri, E., Gupta, R., Roubaud, D. (2017). Can volume predict Bitcoin returns and volatility? A quantiles-based approach. *Economic Modelling*, 64, pp. 74–81.
- Beneki, C., Koulis, A., Kyriazis, N. A., Papadamou, S. (2019). Investigating volatility transmission and hedging properties between Bitcoin and Ethereum. *International Business and Finance*, 48, pp. 219–227.
- Brière, M., Oosterlinck, K., Szafarz, A. (2015). Virtual currency, tangible return: Portfolio diversification with bitcoin. *Journal of Asset Management*, 16, pp. 365–373.
- Caporale, G., Zekokh, T. (2019). Modelling volatility of cryptocurrencies using Markov-Switching GARCH models. *Research in International Business and Finance*, 48, pp. 143–155.
- Catania, L., Grassi, S., Ravazzolo, F. (2019). Forecasting cryptocurrencies under model and parameter instability. *International Journal of Forecasting*, 35, pp. 485–501.
- Chaim, P., Laurini, M. P. (2019). Nonlinear dependence in cryptocurrency markets. *North American Journal of Economics and Finance*, 48, pp. 32–47.
- Chokun, J. (2018). Who accepts bitcoins as payment? list of companies, stores, shops”. Disponível em: <https://99bitcoins.com/who-accepts-bitcoins-payment-companies-stores-take-bitcoins/> [Consultado 20-02-2019]
- Cocco, L., Concas, G., Marchesi, M. (2017). Using an artificial financial market for studying a cryptocurrency market. *Journal of Economic Interaction and Coordination*, 12, pp. 345–365.
- Cuthbertson, A. (2015). Bitcoin now accepted by 100,000 merchants worldwide. *International business times*. Disponível em: <https://www.ibtimes.co.uk/bitcoin-now->

- accepted-by-100000-merchants-worldwide-1486613 [Consultado 20-02-2019]
- Draheim, D. (2017). *Semantics of the Probabilistic Typed Lambda Calculus: Markov Chain Semantics, Termination Behavior, and Denotational Semantics*. Springer.
- Elton, E. J., Gruber, M. J., Brown, S. J., Goetzmann, W.N. (2009). *Modern portfolio theory and investment analysis*. John Wiley & Sons.
- Eom, C., Kaizoji, T., Kang, S. H., Pichl, L. (2019). Bitcoin and investor sentiment: Statistical characteristics and Predictability. *Physica A*, 514, pp. 511–521.
- Hachigian, J. (1963). Collapsed Markov chains and the Chapman-Kolmogorov equation. *The Annals of Mathematical Statistics*, 34, pp. 233-237.
- Howard, R. A. (2012). *Dynamic probabilistic systems: Markov models, vol. 1*. Courier Corporation.
- Hulett, D. T. (2006). “Decision tree analysis for the risk averse organization”, *Project Management Institute Europe-Middle East-Africa Congress*. Madrid, 2006.
- Iglesias de Ussel, J. (2015). *Bitcoin: a new way to understand Payment Systems* (Ph.D. thesis), Massachusetts Institute of Technology.
- Kajtazi, A., Moro, A. (2019). The role of bitcoin in well diversified portfolios: A comparative global study. *International Review of Financial Analysis*, 61, pp. 143-157.
- Kamiński, B., Jakubczyk, M., Szufel, P. (2018). A framework for sensitivity analysis of decision trees. *Central European journal of operations research*, 26, pp. 135-159.
- Kristjanpoller, W., Minutolo, M. C. (2018). A hybrid volatility forecasting framework integrating GARCH, artificial neural network, technical analysis and principal components analysis. *Expert Systems With Applications*, 109, pp. 1–11.
- Lahmiri, S., Bekiros, S. (2019). Cryptocurrency forecasting with deep learning chaotic neural networks. *Chaos, Solitons and Fractals*, 118, pp. 35-40.
- Mallqui, D., Fernandes, R. (2019). Predicting the direction, maximum, minimum and closing prices of daily Bitcoin exchange rate using machine learning techniques. *Applied Soft Computing Journal*, 75, pp. 596-606.
- Maya Lopera, E. (2018). *Los árboles de decisión como herramienta para el análisis de riesgos de los proyectos*. Master's thesis. Universidad EAFIT.
- McIntyre, K. H., Harjes, K. (2016). Order flow and the bitcoin spot rate. *Applied Economics and Finance*, 3 (3), pp. 136-147.
- Moreau, E. (2019). *15 Major Retailers and Services That Accept Bitcoin (Updated)*. Disponible em: <https://www.lifewire.com/big-sites-that-accept-bitcoin-payments-3485965> [Consultado 20-02-2019]
- Nakamoto, S. (2008) *Bitcoin: a peer-to-peer electronic cash system*. Disponible em: www.bitcoin.org [Consultado 25-02-2019]
- Nasir, M. A., Huynh, T. L. D., Nguyen, S. P., Duong, D. (2019). Forecasting cryptocurrency returns and volume using search engines. *Financial Innovation*, 5 (1), pp. 1-13.
- Park, S., Park, H. W. (2019). Diffusion of cryptocurrencies: web traffic and social network attributes as indicators of cryptocurrency performance, *Quality and Quantity*, 54 (1), pp. 297-314.
- Peng, Y., Albuquerque, P. H. M., de Sá, J. M. C., Padula, A. J. A., Montenegro, M. R. (2018). The best of two worlds: Forecasting high frequency volatility for cryptocurrencies and traditional currencies with Support Vector Regression. *Expert Systems with Applications*, 97, pp. 177-192.
- Smuts, N. (2018). What Drives Cryptocurrency Prices? An Investigation of Google Trends and Telegram Sentiment. *ACM SIGMETRICS Performance Evaluation Review*, vol. 46, pp. 135-138, 2018.
- Symitsi, E., Chalvatzis, K. J. (2019). The economic value of Bitcoin: A portfolio analysis of currencies, gold, oil and stocks. *Research in International Business and Finance*, vol. 48, pp. 97–110.
- Van Alstyne, M. (2014). Why Bitcoin has value. *Communications of the ACM*, vol. 57, pp. 30-32, 2014.
- Vitoriano, B. (2007). *Teoría de la decisión: decisión con incertidumbre, decisión multicriterio y teoría de juegos*. Universidad Complutense de Madrid.
- Yermack, D. (2013). Is Bitcoin a real currency? An economic appraisal. *Technical Report, National Bureau of Economic Research*.
- Yu, J. H., Kang, J., Park, S. (2019). Information availability and return volatility in the bitcoin Market: Analyzing differences of user opinion and interest. *Information Processing and Management*, 56, pp. 721–732.