

Decision Support in the Crypt currency Market with Conditional Probabilities: Maximum Likelihood and Bayesian Belief Networks

Reza Hosseingholizadeh 

Ph.D. Candidate in Information Technology Management, Department of Information Technology Management, Science and Research branch, Islamic Azad University, Tehran, Iran.

Mahmood Alborzi  *

Associate Professor, Department of Information Technology Management, Science and Research branch, Islamic Azad University, Tehran, Iran.

Abbas Toloie Eshlaghy 

Professor, Department of Information Technology Management, Science and Research branch, Islamic Azad University, Tehran, Iran.

Hamid Zargham
Boroujeni 

Associate Professor, Department of Tourism Management, Allameh Tabataba'i University, Tehran, Iran.

Abstract

Forecasting cryptocurrency market trends remains a significant challenge due to its fundamental differences from traditional currencies. This complexity arises from the interplay between conventional financial indicators, advancements in information technology, and government macroeconomic policies influencing market acceptance. This study introduces a novel decision support framework that, rather than analyzing individual cryptocurrencies,

* Corresponding Author: mahmood_alborzi@yahoo.com

How to Cite: Hosseingholizadeh, R., Alborzi, M., Toloie Eshlaghy, A., Zargham Boroujeni, H. (2025). Decision Support in the Crypt currency Market with Conditional Probabilities: Maximum Likelihood and Bayesian Belief Networks, *Journal of Business Intelligence Management Studies*, 14(53), 205-238. DOI: 10.22054/ims.2025.83291.2549

focuses on the overall acceptance of the cryptocurrency market. The proposed approach enables a more precise and realistic assessment of market trends, facilitating the generation of buy and sell guidance tables for any specified time interval. To achieve this, maximum likelihood estimation and Bayesian belief networks are employed, allowing for a comparative analysis of these methodologies. Additionally, a high-edge-strength Bayesian belief network is constructed from the generated networks to enhance prudent trading decisions. The method is validated using 1155 weekly and 484 daily time points across 21 cryptocurrencies with the highest market capitalization, covering two periods: the last quarter of 2024 and March–May 2025. The findings demonstrate that the proposed framework, with its high precision, accuracy, recall, and model robustness, supports buy and sell decisions with an average accuracy of at least 78% on a daily basis and 64.5% on a weekly basis. This approach offers a valuable tool for navigating the dynamic and uncertain nature of the cryptocurrency market.

1. Introduction

Centralized banking systems are governed by central authorities, such as central banks, which manage monetary policy, interest rates, and financial regulation to stabilize currency fluctuations. Conversely, decentralized financial systems, prevalent in cryptocurrencies, operate via distributed networks where decisions are made by multiple entities using blockchain technology. These systems exhibit higher volatility due to the absence of regulatory control and market sentiment influence. The complexity and volume of diverse information required for decision-making in the cryptocurrency market present significant challenges. Traditional technical and fundamental analyses, based on commodity markets and conventional currencies, are insufficient for these new dependencies. To address this, we propose using conventional machine learning techniques, specifically artificial neural networks, to enhance prediction accuracy while mitigating complexity. However, the black-box nature of these models limits market insight. Our approach involves creating a joint probability distribution function to consider variable interdependencies, providing a comprehensive analysis by simultaneously evaluating multiple

variables. Integrating this function into predictive models improves accuracy by accounting for market factor interactions. We compare the efficacy of maximum likelihood estimation and Bayesian belief networks in terms of accuracy, precision, recall, and robustness. Additionally, we present a method for generating a buying guide table to support cryptocurrency trading using conditional probabilities. This approach offers significant utility in adapting to the uncertainties of a decentralized economy while reducing reliance on traditional methods.

Research Question(s)

How effectively does maximum likelihood estimation predict the buying and selling prices of cryptocurrencies?

How effectively does Bayesian belief network estimation predict the buying and selling prices of cryptocurrencies?

What is the optimal structure of a Bayesian belief network for predicting buying and selling decisions in the cryptocurrency market?

Which estimation method maximum likelihood estimation or Bayesian belief network provides superior predictive accuracy for cryptocurrency prices?

Can a decision support guide table be developed to assist cryptocurrency market participants in making informed buying and selling decisions?

2. Literature Review

2.1. Maximum Likelihood Estimation

Maximum likelihood estimation is used to estimate model parameters. It identifies the parameter values that maximize the likelihood function and indicates how well the model explains the observed data. This behavior has made it a fundamental technique for developing accurate and reliable predictive models. Maximum likelihood estimation is known for its desirable properties such as consistency and efficiency.

2.2. Bayesian Belief Networks

Bayesian Belief Networks, on the other hand, are based on strong mathematics and are a reliable tool for modeling and probabilistic reasoning, and they work by taking advantage of the following advantages.

2.2.1. Comparing Bayesian Belief Networks and Maximum Likelihood Estimation

Both are vital tools in statistics and machine learning, but they differ significantly in their applications and properties. Bayesian belief networks are probabilistic graphical models that represent conditional relationships between variables through directed acyclic graphs. These networks are very useful for reasoning under uncertainty and predicting and understanding probabilistic relationships between variables, especially in domains where causal relationships are important. In contrast, maximum likelihood estimation is a powerful method for estimating the parameters of statistical models.

3. Methodology


Maximum likelihood estimation with a simple structure of random variables can be performed analytically (for straightforward models) or numerically (for more complex models). The log-likelihood function is frequently used to simplify these calculations. To implement this step, we employed the Naive Bayes classification model. Conversely, the structure of Bayesian belief networks comprises nodes (representing random variables) and directed edges (indicating conditional dependencies), generated through structural training based on constraint-based algorithms. Each node has a conditional probability table detailing the effects of its parent nodes. Bayesian belief networks utilize algorithms such as belief propagation to compute the posterior probabilities of variables based on observed evidence.

4. Results

Following structural training, the joint probability distribution function F_d is generated as per Equation 1, where P_d denotes the probability symbol. Subsequently, using parametric training and the Bayesian tree classification algorithm, we construct the Bayesian belief network illustrated in Figure 1.

$$\begin{aligned}
 F_d(P, O, C, L, H, V) \\
 &= P_d(P) \times P_d(H|P, C) \times P_d(O|P) \times P_d(C|O, P) \quad (1) \\
 &\times P_d(V|C, P) \times P_d(L|C, P)
 \end{aligned}$$

Figure 1. Bayesian belief network after structural and parametric training for daily data



We tested the method in terms of accuracy, precision, and recall with the remaining 20% of the data. To examine the robustness of the model, the above operation was repeated four times (randomly) and the results are shown in Table 1.

Table 1. Four iterations for daily data to check the precision, accuracy, recall, and robustness of the Bayesian belief network.

Iteration	Accuracy	precision	Recall
First	0.7320	0.7313	0.8587
Second	0.7010	0.6986	0.8793
Third	0.7319	0.8654	0.7031
Fourth	0.7527	0.7142	0.8333

5. Discussion

In this study, it was shown that Bayesian belief networks outperformed the maximum likelihood estimation-based classification method in terms of precision, accuracy, recall, robustness, and ROC and AUC metrics. In addition, Bayesian belief networks offer another

advantage over maximum likelihood estimation due to their ability to model and represent the relationships between nodes (random variables).

This study adopts an innovative approach, instead of focusing on the analysis of a specific cryptocurrency, to examine the entire cryptocurrency market as a subject. This comprehensive approach allows for a more accurate and in-depth analysis of market dynamics and helps researchers and decision makers gain a more reliable understanding of macro-market changes and trends. It should be noted that in previous studies, this issue has been mainly investigated by using media news and entering them as independent random variables, a method that is not consistent with the basic principles of Bayesian belief networks, especially in the context of the condition of independence of variables.

In addition, this research facilitates the intuitive decision-making process by providing a method for generating a qualitative and denumerical table. This method is designed to enable decision-makers to make better decisions. In other words, this research not only contributes to the enrichment of the scientific literature in the field of decision-making, but also provides practical and applicable tools to facilitate decision-making under uncertainty. Finally, by generating a Bayesian belief network with strong edges, we have produced a belief network with high reliability.

6. Conclusion

The main limitation of this study is related to the lack of dynamics of the network and the inability to predict continuous future trends to predict future paths. In order to overcome this limitation and as a suggestion for future research, the Bayesian belief network introduced in Equation 5, which has high-confidence edges, can be used as the initial belief of the community under consideration. The outputs of this network can be used as the initial conditions for the agents in an agent-based simulation. In particular, the authors propose to exploit the agent-based method of opinion dynamics in the continuous mode.

Keywords: conditional probabilities, crypt currency, maximum likelihood estimation, Bayesian belief network, decision support.



پشتیبانی تصمیم در بازار رمزارزها با احتمالات شرطی: پیشینه درست‌نمایی و شبکه‌های باور بیزی

دانشجوی دکتری رشته مدیریت فناوری اطلاعات، گروه مدیریت فناوری اطلاعات، دانشکده مدیریت و اقتصاد، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

رضا حسینی‌زاده 

دانشیار گروه مدیریت فناوری اطلاعات، دانشکده مدیریت و اقتصاد، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

محمود البرزی  *

استاد گروه مدیریت فناوری اطلاعات، دانشکده مدیریت و اقتصاد، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران

عباس طلوعی اشلقی 

دانشیار گروه مدیریت جهانگردی، دانشکده مدیریت و حسابداری، دانشگاه علامه طباطبائی، تهران، ایران

حمید ضرغام بروجنی 

چکیده

پیش‌بینی روند بازار رمزارزها به دلیل تفاوت‌های بنیادین با ارزهای سنتی، همواره چالشی بزرگ بوده است. این چالش به‌طور عمده ناشی از تأثیرات متقابل سیگنال‌های مرسوم، پیشرفت‌های فناوری اطلاعات و سیاست‌های کلان دولت‌ها بر پذیرش این ارزها است. این مقاله با رویکردی نوین، بجای تحلیل جداگانه یک یا چند رمزارز فرایندی در راستای حمایت از تصمیم ارائه می‌دهد که معیار آن مقبولیت عمومی بازار رمزارزها است. رویکرد پیشنهادی امکان تحلیل دقیق‌تر و واقع‌بینانه‌تری از روندهای بازار را فراهم می‌آورد. با استفاده از این فرآیند، می‌توان در هر بازه زمانی دلخواه، جداول راهنمای خرید یا فروش تولید کرد. در این مطالعه از دو ابزار تحلیلی، پیشینه درست‌نمایی و شبکه‌های باور بیزی، استفاده شده است و امکان مقایسه این

مقاله حاضر برگرفته از رساله دکتری رشته مدیریت فناوری اطلاعات گرایش کسب و کار هوشمند، دانشگاه آزاد اسلامی واحد علوم و تحقیقات است.

* نویسنده مسئول: mahmood_alborzi@yahoo.com

دو روش نیز مورد بررسی قرار گرفته است. در ضمن با تولید یک شبکه باور بیزی دیگر با قدرت یال‌های بالا، حاصل از شبکه‌های تولید شده، تصمیم‌گیری معاملات محتاطانه را مقدور می‌سازیم. این روش با استفاده از ۱۱۵۵ نقطه زمانی در هر هفته و ۴۸۴ نقطه زمانی در هر روز از ۲۱ رمزارز با بالاترین ارزش بازار در دو بازه سه‌ماهه پایانی سال ۲۰۲۴ و ماه‌های مارس، آوریل و می ۲۰۲۵ اعتبارسنجی شده است. پژوهش حاضر فرآیندی را ارائه می‌دهد که با دقت، صحت، یادآوری و استحکام بالایی مدل‌هایش، توانایی پشتیبانی تصمیمات خرید و فروش با میانگین دقت حداقل ۷۸ درصد به صورت روزانه و ۶۴/۵ درصد به صورت هفتگی را دارد. این روش می‌تواند در سازگاری با پویایی و عدم قطعیت موجود این بازار به طور قابل توجهی مفید باشد.

کلیدواژه‌ها: احتمالات شرطی، رمزارز، برآوری بیشینه درستی، شبکه باور بیزی، پشتیبانی تصمیم.

مقدمه

در سیستم‌های مالی، بانکداری متمرکز به معنای کنترل سیستم مالی توسط یک مقام مرکزی مانند بانک مرکزی است. این سیستم شامل تصمیم‌گیری درباره سیاست‌های پولی، نرخ بهره و تنظیم نهادهای مالی است که به دلیل سیاست‌های پولی کنترل شده، می‌توانند نوسانات ارزی را تثبیت کنند. در مقابل، سیستم مالی غیرمتمرکز^۱ که در رمزارزها رایج است، شامل شبکه‌های توزیع شده‌ای است که تصمیم‌گیری در آن‌ها به وسیله چندین نهاد و معمولاً با استفاده از فناوری بلاک‌چین^۲ صورت می‌گیرد. این سیستم‌ها به دلیل نبود کنترل نظارتی و تأثیرپذیری از احساسات بازار، معمولاً نوسانات بیشتری دارند (Ozili, P. K., 2022).

متغیرهای خارجی مؤثر بر بازار رمزارزها نقشی اساسی و تعیین‌کننده در شکل‌گیری رفتار این بازار ایفا می‌کنند. با این حال، تعدد، تنوع و پیچیدگی این متغیرها به حدی است که گنجاندن تمامی آن‌ها در یک مدل تحلیلی جامع تقریباً غیرممکن به نظر می‌رسد. در ادامه، با اشاره به نمونه‌هایی اندک از این گستردگی و پیچیدگی، شواهدی ارائه می‌شود که تأثیرگذاری قابل توجه این عوامل را نشان می‌دهد.

سیستم‌های غیرمتمرکز می‌توانند منجر به نوآوری‌های مالی (صرافی‌ها، پروتکل‌های وام‌دهی، قرض‌گیری، استیبل کوین‌ها^۴ و ...) و شمول مالی^۵ (امکان استفاده از خدمات، صرف نظر از ارزش خالص شخصی یا شرکتی) بیشتری شوند (Lorenz, G., 2024). پیشرفت‌های فناوری نیز بر قیمت و پذیرش رمزارزها تأثیر غیرقابل پیش‌بینی دارند. به عنوان مثال، به روزرسانی اتریوم پکترا^۶ (۷ مه ۲۰۲۵) که هدف آن بهبود مقیاس‌پذیری، امنیت و کارآمدی است، برخلاف ماه‌ها انتظار، در حال حاضر (۶ ژوئن ۲۰۲۵) بر قیمت

1 Decentralized Finance (DeFi)

2 Cryptocurrency

3 blockchain

4 Stablecoin

5 Financial Inclusion

6 Ethereum Pectra

آن تأثیر مثبتی نگذاشته است. همچنین، پذیرش رمزارزها توسط مؤسسات مالی و شرکت‌های بزرگ می‌تواند قیمت آن‌ها را به‌طور قابل توجهی افزایش دهد. برای نمونه، زمانی که تسلا سرمایه‌گذاری خود را در بیت کوین اعلام کرد، قیمت بیت کوین افزایش یافت (Mironeanu et al., 2021). با این حال، عقب‌نشینی‌های فناورانه یا نقص‌های امنیتی می‌تواند منجر به کاهش شدید قیمت‌ها شود. رایانه‌های کوانتومی^۱ نیز چالش‌های جدیدی برای بازار رمزارزها ایجاد می‌کند، زیرا این فناوری توانایی شکستن الگوریتم‌های رمزنگاری را دارد که می‌تواند امنیت رمزارزها را به خطر بیندازد. هم‌زمان برای مقابله با این چالش‌ها، محققان در حال توسعه الگوریتم‌های مقاوم در برابر رایانه‌های کوانتومی هستند (Beato, 2024).

دریافت و تحلیل به‌موقع این حجم عظیم و متنوع از اطلاعات و به‌کارگیری آن‌ها در یک مدل جامع عملیاتی دشوار به نظر می‌رسد. از این رو، در این پژوهش از فرضیه‌ای پیروی شده است که معتقد است تمامی اطلاعات موجود در بازار، پیش از رسانه‌ای شدن هر خبر، در قیمت‌ها منعکس شده و پیش‌خور شده‌اند ((Fama, E. F. 1965) و Fama, E. (1970)). بر این اساس، با استفاده از داده‌های مرتبط با قیمت‌های آغازین، پایانی، پایین‌ترین قیمت، بالاترین قیمت‌ها و حجم معاملات تعداد زیادی از رمزارزهای دارای بالاترین ارزش بازار تلاش شده است تا فرآیندی برای حمایت از تصمیم‌گیری در خرید و فروش ارائه شود. هدف این مقاله ارائه فرایندی برای تولید مدل‌هایی کارآمد و انعطاف‌پذیر است که با دریافت موقعیت فعلی (داده‌های فوق برای یک رمزارز) احتمال عضویت آن رمزارز را در یکی از دو کلاس خریدنی یا فروختنی پیش‌بینی نمایند.

مبانی نظری

مدل‌های پیش‌بینی مبتنی بر تئوری احتمالات شرطی، می‌توانند تحلیل واضح‌تری از تعاملات بین متغیرهای تصادفی مختلف ارائه کرده و به‌عنوان یک ابزار قدرتمند در

1 Quantum computers

تصمیم‌گیری‌های مالی و معاملاتی مورد استفاده قرار گیرند (Levenchuk, L. 2022). رویکرد ما ایجاد توابع توزیع احتمال^۱ توأم برای این متغیرها است تا با در نظر گرفتن وابستگی‌های متقابل بین آن‌ها این امر را مقدور کنند. گنجاندن تابع توزیع احتمال توأم در مدل‌های پیش‌بینی‌کننده می‌تواند دقت پیش‌بینی‌ها را با توجه به تعاملات بین عوامل مختلف بازار بهبود بخشد (Zellner, M. et al., 2021). ما علاوه بر مقایسه توانایی دو روش قدرتمند و پیش‌رو «برآورد بیشینه درست‌نمایی»^۲ و «شبکه باور بیزی»^۳ به لحاظ صحت^۴، دقت^۵، یادآوری^۶ و استحکام^۷، در ضمن روشی برای تولید جدول راهنمای خرید لحظه‌ای ارائه نموده‌ایم تا با کمک احتمالات شرطی بتواند پشتیبانی برای معاملات باشد. ابتدا لازم است اشاره کنیم که منظور از تابع احتمال، تابعی است که احتمال داده‌های مشاهده‌شده را با استفاده از مجموعه‌ای از پارامترها نشان می‌دهد. بهینه‌سازی نیز به معنای یافتن مقادیر پارامتری است که این تابع احتمال را به حداکثر می‌رساند (McCullagh & Nelder, 1989).

برآورد بیشینه درست‌نمایی: برآورد بیشینه درست‌نمایی برای تخمین پارامترهای مدل استفاده می‌شود. این روش مقادیر پارامترهایی را که تابع احتمال را به حداکثر می‌رساند، شناسایی می‌کند و بیانگر این است که مدل چقدر خوب داده‌های مشاهده‌شده را توضیح می‌دهد. این نحوه عملکرد آن را به یک تکنیک اساسی برای توسعه مدل‌های پیش‌بینی دقیق و قابل اعتماد تبدیل کرده است. برآورد بیشینه درست‌نمایی به‌طور گسترده در الگوریتم‌های مختلف طبقه‌بندی برای تخمین پارامترهایی که به بهترین نحو کلاس‌های مختلف را جدا می‌کنند، استفاده می‌شود (Minka, 2000). از مزایای این روش می‌توان به مواد زیر نیز اشاره کرد.

-
- 1 Probability Distribution Function (PDF)
 - 2 Maximum Likelihood Estimation (MLE)
 - 3 Bayesian Belief Network (BBN)
 - 4 Accuracy
 - 5 Precision
 - 6 Recall
 - 7 Robustness

- انعطاف پذیری: برآورد بیشینه درست‌نمایی را می‌توان در طیف گسترده‌ای از مدل‌ها و توزیع‌ها اعمال کرد.

- بنیاد روش‌های پیشرفته: بسیاری از الگوریتم‌های پیشرفته یادگیری ماشین، مانند شبکه‌های عصبی و ماشین‌های بردار پشتیبان، بر اساس اصول برآورد بیشینه درست‌نمایی ساخته شده‌اند (Hastie, Tibshirani, & Friedman, 2009).

شبکه‌های باور بیزی: از طرف دیگر شبکه‌های باور بیزی، بر پایه ریاضیات قوی، با بهره‌گیری از نظریه گراف، قضیه بیز، استدلال احتمالی و استقلال مشروط کار می‌کنند (Jensen & Nielsen, 2007).

شبکه‌های باور بیزی برای مدل‌سازی روابط احتمالی پیچیده و تصمیم‌گیری آگاهانه در شرایط عدم قطعیت ابزارهایی بسیار مؤثرند (McCloskey, 2000). این شبکه‌ها راهی فشرده برای نمایش توزیع احتمال توأم مجموعه‌ای از متغیرها ارائه می‌کنند (Heckerman, 1995). شبکه‌های بیزی از یک گراف غیردوار جهت‌دار برای رمزگذاری وابستگی‌های شرطی بین متغیرها استفاده می‌کنند (Pearl, 1988). همچنین این شبکه‌ها با استفاده از استقلال شرطی تعداد پارامترهای موردنیاز برای تعیین توزیع توأم را کاهش می‌دهند. این بدان معنی است که توزیع احتمال توأم را می‌توان به حاصل ضرب احتمالات مشروط تجزیه کرد و به‌طور قابل توجهی محاسبات را کاهش داد (Jensen & Nielsen, 2007). در ضمن شبکه‌های باور بیزی می‌توانند داده‌های ازدست‌رفته را به‌طور طبیعی مدیریت کنند. آن‌ها می‌توانند مقادیر گم‌شده را بر اساس داده‌های مشاهده‌شده و ساختار شبکه استنباط کنند این توانایی آن‌ها را در برنامه‌های کاربردی دنیای واقعی که داده‌ها اغلب ناقص هستند، قدرتمند می‌کند (Mohan & Pearl, 2018).

پیشینه پژوهش

در ادامه، به بررسی پیشینه موضوع و ابزارهای مرتبط خواهیم پرداخت. در مقاله «پیش‌بینی بازار فارکس با استفاده از یادگیری ماشین: مرور ادبیات سیستماتیک و متا‌آنالیز» یک بررسی جامعی از الگوریتم‌های یادگیری ماشینی مورد استفاده برای پیش‌بینی بازار فارکس

ارائه می‌شود. متداول‌ترین مدل‌های مورد استفاده، مانند شبکه‌های عصبی مصنوعی را برجسته می‌کند و عملکرد آن‌ها را در پیش‌بینی حرکات ارز مورد بحث قرار می‌دهد (Ayitey et al., 2023). همان‌طور که در بررسی مطالعات آتی نیز مشاهده خواهد شد، روش‌های مبتنی بر احتمال شرطی به ندرت در فهرست روش‌های مورد استفاده در اکثر پژوهش‌ها قرار گرفته‌اند. در مقاله «پیش‌بینی قیمت رمزارزها و نوسانات با یادگیری ماشین» با استفاده از مدل‌های مختلف یادگیری ماشینی برای پیش‌بینی قیمت‌ها و نوسانات رمزارزها مانند بیت‌کوین و دوج‌کوین در بازه زمانی ۲۰۱۴ تا ۲۰۲۳ مورد بحث قرار گرفته است (Poudel, et al., 2023). نتایج به دست آمده این بوده است که مدل‌های رگرسیون شبکه‌های عصبی مصنوعی نسبت به بقیه مدل‌های بررسی شده بهتر عمل کرده‌اند. در این مقاله نیز مدل‌های مبتنی بر احتمالات شرطی آزمون نشده و بحث محدود به دو رمزارز یاد شده است. مقاله «پیش‌بینی و تجارت رمزارزها با یادگیری ماشینی تحت شرایط متغیر بازار» قابلیت پیش‌بینی رمزارزهای اصلی (بیت‌کوین، اتریوم و لایت‌کوین) را با استفاده از تکنیک‌های یادگیری ماشینی مانند مدل‌های خطی، جنگل‌های تصادفی^۱ و ماشین‌های بردار پشتیبان^۲ بررسی می‌کند. همچنین سودآوری استراتژی‌های معاملاتی را بر اساس این پیش‌بینی‌ها ارزیابی می‌کند (Sebastião, H., & Godinho, P. 2021). داده‌های این مقاله مربوط به ۱۵ آگوست ۲۰۱۵ تا ۳ مارس ۲۰۱۹ است نتیجه اینکه در شرایط بد بازار نیز یادگیری ماشین بهتر عمل کرده است. هر چند به یادگیری ماشین اشاره دارد باز از احتمالات شرطی و یادگیری مبتنی بر آن استفاده نشده این موضوع در سال‌های اخیر نیز ادامه داشته است. به عنوان دو نمونه دیگر، مقاله «پیش‌بینی قیمت رمزارز با استفاده از چندین مدل یادگیری عمیق» در این مقاله نیز بیت‌کوین، لایت‌کوین و اتریوم به عنوان بهترین ارزش‌های رمزنگاری شده در نظر گرفته شده و یک شبکه عصبی برای پیش‌بینی قیمت این رمزارزها مناسب تشخیص داده شده است (Durga, P. V. V., & Anusha, G. 2024). مقاله «پیش‌بینی قیمت رمزارزهای آینده با استفاده از الگوریتم‌های یادگیری

1 Random forests

2 Support Vector Machines (SVM)

ماشین» یک مطالعه جامع در مورد پیش‌بینی قیمت‌های رمزارزها با استفاده از الگوریتم‌های درون‌یابی است؛ که شامل داده‌های قیمت بیت کوین در طی ۷ ماه در سال ۲۰۱۸ ثبت شده است (Saha, V. 2023).

با پذیرش قدرت بالای تحلیل‌ها با استفاده از شبکه‌های عصبی مصنوعی و مشتقات آن که می‌توانند دقت پیش‌بینی‌ها را به‌طور قابل‌توجهی افزایش دهند، باید به محدودیت قابل‌توجه این روش‌ها نیز اشاره کرد. این محدودیت ناشی از ماهیت «جعبه سیاه» شبکه‌های عصبی است که منجر به عدم ارائه درک عمیق یا بینش جدیدی نسبت به موضوع موردبررسی برای کاربر می‌شود.

در مطالعه حبیبی راد و پناهی (۱۴۰۰) سعی شده از زاویه دیگری به مسئله نگریسته شود تا شاید درک بهتری از مناسبات بازار حاصل شود. آن‌ها در مقاله «تبیین رابطه قیمت بیت کوین در مبادلات مالی کسب و کارها و حجم جستجو به‌منظور شناسایی الگوی رفتاری آن» به یک مطالعه تطبیقی بین کشورها پرداخته‌اند. هدف از این تحقیق، مطالعه و بررسی رابطه حجم جستجوهای اینترنتی و تأثیر آن بر قیمت رمزارز بیت کوین است.

همانند دیگر روش‌های یادگیری ماشین شبکه‌های باور بیزی می‌توانند از داده‌ها با استفاده از الگوریتم‌های مختلف یاد بگیرند. هم ساختار شبکه (وابستگی‌های قابل درک و تفسیر بین متغیرها) و هم پارامترها (جداول احتمال شرطی^۱) را می‌توان از داده‌ها تخمین زد که به شبکه این توان را می‌دهد تا با اطلاعات جدید سازگار شود (Polotskaya et al., 2024). شبکه‌های باور بیزی با موفقیت در زمینه‌های مهمی به کار گرفته شده‌اند که استحکام و تطبیق‌پذیری آن‌ها را نشان می‌دهد. برای نمونه:

- تشخیص پزشکی: از آن‌ها برای مدل‌سازی روابط احتمالی بین بیماری‌ها و علائم، کمک به تصمیم‌گیری تشخیصی و تجویزی استفاده می‌شود (همان منبع).
- ارزیابی ریسک: در امور مالی و مهندسی، شبکه‌های بیزی با مدل‌سازی وابستگی بین عوامل خطر مختلف، به ارزیابی و مدیریت ریسک‌ها کمک می‌کنند (همان منبع).

- یادگیری ماشینی: آن‌ها در یادگیری ماشین برای کارهایی مانند طبقه‌بندی، رگرسیون و تشخیص ناهنجاری استفاده می‌شوند (همان منبع).

- حوزه علوم انسانی: در سیستم‌های پیچیده‌تری مانند مدل‌سازی باور حاکم بر ذینفعان گردشگری و پویایی عقاید آن‌ها کاربرد پیدا کرده‌اند (حسینقلی زاده و همکاران، ۱۴۰۱).

مقاله «مدل‌سازی تعیین‌کننده قیمت رمزارزها: رویکرد شبکه بیزی» شبکه‌های بیزی را برای استدلال و تشخیص علی مورد استفاده قرار می‌دهد و نتایج نشان می‌دهد که رسانه‌های اجتماعی (به‌ویژه داده‌های توییتر در این مطالعه) مهم‌ترین عامل تأثیرگذار بر قیمت آلت کوین‌ها هستند (Amirzadeh et al., 2023). این مقاله ضمن تأکید بر اینکه عوامل خارجی نباید نادیده گرفته شوند، به‌عنوان نکته ضعف به این سؤال پاسخ نمی‌دهد که چگونه مطمئن شده است که قیمت فعلی، خبر را پیش‌خور نکرده است. چون در صورت درست بود این ادعا (که بعید هم نیست) به لحاظ تئوری‌های آمار و احتمال استفاده از شبکه‌های باور بیزی که شرط استقلال متغیرها را دارد، اشتباه خواهد بود (Heckerman, 1995). مقاله «شبکه‌های پویا بیزی برای پیش‌بینی مسیرهای قیمت رمزارزها: کشف روابط علی» یک رویکرد مبتنی بر شبکه بیزی پویا را برای کشف روابط علی بالقوه میان ویژگی‌های مختلف، از جمله داده‌های رسانه‌های اجتماعی، عوامل سنتی بازار مالی و شاخص‌های فنی پیشنهاد می‌کند. این مطالعه بر روی شش ارز دیجیتال محبوب متمرکز است: بیت کوین، بایننس کوین، اتریوم، لایت کوین، ریپل و تتر. نتایج نشان می‌دهد شبکه‌های باور بیزی به‌طور قابل‌توجهی از چندین مدل پایه بهتر عمل می‌کنند (Amirzadeh et al., 2024). این مطالعه به‌عنوان نقطه قوت، از شبکه باور بیزی پویا بهره گرفته است که رویکردی توانمند در تحلیل داده‌ها ارائه می‌دهد. با این حال، به‌عنوان یک ضعف، می‌توان اشاره کرد که مشابه پژوهش پیشین، توجه کافی به مسئله اساسی استقلال متغیرها در این تحلیل صورت نگرفته است.

روش پژوهش

با استفاده از برآورد بیشینه درست‌نمایی و با یک ساختار ساده از متغیرهای تصادفی مدل‌سازی ریاضی انجام گرفته است. تابع لگاریتم درست‌نمایی^۱ را برای ساده‌سازی در محاسبات این برآورد استفاده کرده‌ایم. در پیاده‌سازی این مرحله، الگوریتم طبقه‌بندی نائو بیز را به خدمت گرفته‌ایم (Liu, R., et al., 2018).

از طرف دیگر برای تولید ساختار شبکه‌های باور بیزی که از گره‌ها و یال‌های جهت‌دار تشکیل شده از آموزش ساختاری بر پایه الگوریتم مبتنی بر قید^۲ استفاده شده است (Margaritis, 2005). در ادامه نوبت به آموزش پارامتری مدل می‌رسد که از الگوریتم طبقه‌بندی درخت بیز استفاده شده است (Friedman, Geiger & Goldszmit, 1997). در مدل حاصل هر گره دارای یک جدول احتمال شرطی است که تأثیرات گره‌های والد را مشخص می‌کند. مدل برای محاسبه احتمالات بعدی متغیرها با توجه به شواهد مشاهده‌شده استفاده می‌شود. این قابلیت امکان استدلال احتمالی و تصمیم‌گیری را فراهم می‌کند. در هر دو روش «برآورد بیشینه درست‌نمایی» و «شبکه‌های باور بیزی»، موارد زیر برقرار هستند:

- هر گره نماینده یکی از متغیرهای تصادفی قیمت آغازین، قیمت پایانی، بالاترین قیمت، پایین‌ترین قیمت، حجم و پیشنهاد (خرید یا فروش) است.
 - یال‌های جهت‌دار بین گره‌ها نشان‌دهنده وابستگی‌های شرطی بین متغیرها هستند.
- این فرایند با استفاده از ۱۱۵۵ نقطه زمانی برای هر هفته در ۲ دوره ۱۲ هفته‌ای و ۴۸۴ نقطه زمانی برای هر روز در ۲ دوره ۹۰ روزه از ۲۱ رمزارز (جدول ۱) با بالاترین ارزش بازار در سه ماهه پایانی سال ۲۰۲۴ و ماه‌های مارس، آوریل و می ۲۰۲۵ اعتبارسنجی شده است. داده‌ها از طریق وب‌سایت سی‌ام‌سی^۳ جمع‌آوری شده‌اند. این داده‌ها شامل قیمت‌های آغازین، پایانی، بالاترین، پایین‌ترین و حجم هستند.

1 log-likelihood

2 Constraint-based algorithms





3 <https://coinmarketcap.com> (CMC)








مقادیر همه متغیرها نرمال شده و قبل از تحلیل توسط احتمالات شرطی (برآورد بیشینه درست‌نمایی و شبکه‌های باور بیزی)، در بازه کمترین و بیشترین مقدار خود در هر دوره و برای هر رمزارز در سه سطح هم فاصله A, B, C طبقه‌بندی شده‌اند. سطح A بالاترین مقدار، سطح B متوسط و سطح C کمترین مقدار را نمایندگی می‌کند (شکل ۱). متغیرهای تصادفی به صورت رابطه (۱) تعریف شده‌اند که در آن x نام متغیر i شماره متغیر j نماد اختصاری رمزارز و n تعداد نمونه تصادفی مورد استفاده می‌باشد.

شکل ۱. سطح بندی متغیرهای تصادفی

$$\begin{array}{c}
 \begin{array}{c}
 \text{C} \quad \quad \quad \text{B} \quad \quad \quad \text{A} \\
 \hline
 x_i^j(\min) \quad \quad \quad x_i^j(\max)
 \end{array} \\
 x_i^j = \begin{cases} A, B \text{ or } C & \text{if } i = 1, 2, \dots, n; \quad j = BTC, ETH, \dots, SUI; \quad x = Open, \ell \\
 \text{Sell or Buy} & \text{if } i = 1, 2, \dots, n; \quad j = BTC, ETH, \dots, SUI.
 \end{cases} \quad (1)
 \end{array}$$

جدول ۱. ۲۱ رمزارز با بیشترین سهم بازار همراه با نمودارهای تغییرات روزانه و هفتگی

#	نام	نماد	اختصار	تغییرات روزانه	تغییرات هفتگی
۱	Bitcoin		BTC		
۲	Ethereum		ETH		
۳	Tether USD		USDT		
۴	Binance		BNB		
۵	Solana		SOL		
۶	USDC		USDC		
۷	Ripple		XRP		
۸	Toncoin		TON		

#	نام	نماد	اختصار	تغییرات روزانه	تغییرات هفتگی
۹	Dogecoin		DOGE		
۱۰	Cardano		ADA		
۱۱	TRON		TRX		
۱۲	Avalanche		AVAX		
۱۳	Shiba Inu		SHIB		
۱۴	Chainlink		LINK		
۱۵	Bitcoin cash		BCH		
۱۶	Polkadot		DOT		
۱۷	UNUS SED LEO		LEO		
۱۸	NEAR Protocol		NEAR		
۱۹	Litecoin		LTC		
۲۰	Dai		DAI		
۲۱	Sui		SUI		

در نهایت ۱۸۰ مدل روزانه و ۲۴ مدل هفتگی حاصل از رقابت بین الگوریتم‌های بیشینه-درست‌نمایی و شبکه باور بیزی به لحاظ، دقت، صحت، یادآوری و استحکام اجازه پیدا می-کنند طبق روابط ۲ در محاسبه نهایی میانگین دقت فرآیند ارائه شده برای معاملات روزانه و هفتگی شرکت نماید.

$$\frac{\sum_{t=1}^{180} Precision(Model_d(t))}{180} = P_d \quad (۲)$$

$$\frac{\sum_{t=1}^{24} Precision(Model_w(t))}{24} = P_w$$

یافته‌ها

در ادامه با جزئیات کامل به شیوه عملی به کارگیری روش پژوهش در تشریح نحوه تولید

مدل‌ها (روزانه و هفتگی) و مقایسه آن‌ها می‌پردازیم.


برآورد بیشینه درست‌نمایی: در این قسمت نخست به کمک ۸۰ درصد از داده‌های «هفتگی» برای شش متغیر تصادفی مورد بحث، از طبقه‌بندی به کمک برآورد بیشینه درست‌نمایی که توسط الگوریتم نایو بیز اعمال شده استفاده کرده‌ایم. همان‌طوری که در شکل ۲ نیز نمایش داده شده این الگوریتم سعی در تولید ساختار خاصی برای ارتباطات متغیرهای تصادفی ندارد و تنها وابستگی متغیرها به پیشنهاد (خرید یا فروش) را مدنظر دارد. این نوع وابستگی توسط رابطه (۳) بیان شده است؛ که در آن P_N نماد احتمال نایو می‌باشد.

$$P_N(P) \times P_N(P|O, C, L, H, V), \quad (3)$$

که در آن

$$P = \text{Position} \quad O = \text{Open}, C = \text{Close}, \quad L = \text{Low}, \quad H = \text{High}, \\ V = \text{Volume}$$

شکل ۲ ساختار نایو بیز برای متغیرهای تصادفی



با ۲۰ درصد باقیمانده داده‌ها به آزمون روش به لحاظ صحت، دقت و یادآوری پرداخته‌ایم. جهت بررسی استحکام مدل عملیات فوق چهار بار تکرار شده است. توانایی این مدل در طبقه‌بندی با داده‌های هفتگی به لحاظ صحت ۶۲ درصد، به لحاظ دقت ۶۲ و به لحاظ توان یادآوری ۶۴ درصد است.


در ادامه نخست به کمک ۸۰ درصد از داده‌های «روزانه» برای شش متغیر تصادفی

مورد بحث، از طبقه‌بندی به کمک برآورد بیشینه درست‌نمایی که توسط الگوریتم نائیبیز اعمال شده استفاده کرده‌ایم. با ۲۰ درصد باقیمانده داده‌ها به آزمون روش به لحاظ صحت، دقت و یادآوری پرداخته‌ایم و جهت بررسی استحکام مدل عملیات فوق چهار بار تکرار شده است. توانایی این مدل در طبقه‌بندی با داده‌های روزانه به لحاظ صحت ۷۰ درصد، به لحاظ دقت ۷۰ و به لحاظ توان یادآوری ۸۰ درصد است.

شبکه باور بیزی: حال با استفاده از الگوریتم مبتنی بر قید می‌خواهیم با همان ۸۰ درصد داده‌های «هفتگی» استفاده شده در بخش برآورد بیشینه درست‌نمایی ساختار گرافیکی شبکه باور بیزی را تولید نماییم که روابط و وابستگی‌های بین متغیرهای تصادفی را تولید می‌کند. پس از آموزش ساختاری تابع توزیع احتمال توأم هفتگی F_w به صورت معادله (۴) تولید می‌شود که در آن P_w نماد احتمال می‌باشد. این تابع توزیع به صورت یک گراف جهت‌دار غیر دوار در شکل ۳ نشان داده شده است.


$$F_w(P, O, C, L, H, V) = P_w(P) \times P_w(H|P, C) \times P_w(O|P) \times P_w(C|O, P) \times P_w(V|L, P) \times P_w(L|C, P) \quad (4)$$

شکل ۳. ساختار تولید شده برای داده‌های هفتگی پس از آموزش ساختاری



با استفاده از آموزش پارامتری بر پایه برآورد بیزی روی ساختار به دست آمده و استفاده از الگوریتم طبقه‌بندی درخت بیز به شبکه باور بیزی شکل ۴ می‌رسیم.

شکل ۴. شبکه باور بیزی برای داده‌های هفتگی پس از آموزش پارامتری




با ۲۰ درصد باقیمانده داده‌ها به آزمون روش به لحاظ صحت، دقت و یادآوری پرداخته-ایم. جهت بررسی استحکام مدل عملیات فوق چهار بار تکرار شده است. توانایی این مدل در طبقه‌بندی با داده‌های «هفتگی» به لحاظ صحت ۶۳ درصد، به لحاظ دقت ۶۲ و به لحاظ توان یادآوری ۶۹ درصد است.

با استفاده از الگوریتم مبتنی بر قید می‌خواهیم با همان ۸۰ درصد داده‌های «روزانه» استفاده‌شده در بخش برآورد پیشینه درست‌نمایی ساختار گرافیکی شبکه باور بیزی را تولید نماییم که روابط و وابستگی‌های بین متغیرهای تصادفی را نمایش خواهد داد. پس از آموزش ساختاری تابع توزیع احتمال توأم روزانه F_d طبق معادله ۵ تولید می‌شود که در آن نماد احتمال می‌باشد. حال با استفاده از آموزش پارامتری و استفاده از الگوریتم طبقه‌بندی درخت بیز به شبکه باور بیزی شکل ۵ می‌رسیم.

$$F_d(P, O, C, L, H, V) \quad (5)$$

$$= P_d(P) \times P_d(H|P, C) \times P_d(O|P) \times P_d(C|O, P) \\ \times P_d(V|C, P) \times P_d(L|C, P)$$

شکل ۵. شبکه باور بیزی بعد از آموزش ساختاری و پارامتری برای داده‌های روزانه



با ۲۰ درصد باقیمانده داده‌ها به آزمون روش به لحاظ صحت، دقت و یادآوری پرداخته- ایم. جهت بررسی استحکام مدل عملیات فوق چهار بار تکرار شده و نتایج در جدول ۵ نشان داده شده است.

جدول ۲. چهار تکرار برای داده‌های روزانه جهت بررسی دقت، صحت، یادآوری و استحکام شبکه

باور بیزی

تکرار	پیش‌بینی	صحت	دقت	یادآوری
اول	فروش	۰/۷۳۲۰	۰/۷۳۱۳	۰/۸۵۹۷
	خرید			
	۴۹			
۲۲	فروش	۸		
	خرید			

تکرار	پیش‌بینی		صحت	دقت	یادآوری
دوم	فروش	خرید	۰/۷۰۱۰	۰/۶۹۸۶	۰/۸۷۹۳
	۲۲	۵۱			
	۱۷	۷			
سوم	فروش	خرید	۰/۷۳۱۹	۰/۸۶۵۴	۰/۷۰۳۱
	۷	۴۵			
	۲۶	۱۹			
چهارم	فروش	خرید	۰/۷۵۲۶	۰/۷۱۴۲	۰/۸۳۳۳
	۱۶	۴۰			
	۳۳	۸			


توانایی این مدل در طبقه‌بندی با داده‌های روزانه به‌طور متوسط به لحاظ صحت ۷۴ درصد، به لحاظ دقت ۷۵ و به لحاظ توان یادآوری ۸۹ درصد است.

در ادامه با استفاده از منحنی مشخصه عملکرد^۱ و محاسبه مساحت زیر منحنی^۲ آن به مقایسه این دو روش در عملکرد روزانه می‌پردازیم (Zhou, Obuchowski & McClish, 2011). نمودارهای ارائه‌شده در شکل‌های ۶ و ۷ نشان‌دهنده مساحت زیر منحنی برای روش مبتنی بر شبکه باور بیزی ۰/۸۵ و در روش نائو (درست‌نمایی) برابر با ۰/۸۴ می‌باشد. این نتایج حاکی از آن است که هرچند اختلاف موجود بین دو روش کم است، اما شبکه‌های باور بیزی باز عملکرد بهتری را در مقایسه با روش برآورد بیشینه درست‌نمایی (نائو بیز) نشان می‌دهند.


1 Receiver Operating Characteristic (ROC)

2 Area Under the ROC Curve (AUC)

شکل ۶. منحنی ROC و مساحت زیر منحنی برای روش شبکه باور بیزی




شکل ۷. نمودار منحنی ROC و مساحت زیر منحنی برای روش پیشنهادی در دستنمایی



تولید شبکه‌های باور بیزی با قوی‌تری یال‌ها: این کار با مقایسه دو ساختار برای داده‌های هفتگی (شکل ۴) و داده‌های روزانه (شکل ۵) انجام گرفته است. شکل ۶ مقایسه این دو شبکه را نمایش می‌دهد که از ۹ یال جهت‌دار در ۸ یال مشابه بوده در ۱ یال باهم اختلاف دارند.

شکل ۶. مقایسه شبکه باور بیزی روزانه و هفتگی



با محاسبه قدرت هر یک از یال‌ها (مقدار احتمال)^۱ در هر دو شبکه باور بیزی روزانه و هفتگی به ترتیب جداول ۳ و ۴ را خواهیم داشت. هر چه مقدار کمتر باشد قدرت یال به لحاظ وابستگی نیز بیشتر خواهد بود.

جدول ۳. قدرت (مقدار احتمال) یال‌ها برای داده‌های روزانه

#	From	To	Strength
1	P	H	2.710403e-08
2	C	H	1.057543e-60
3	P	O	2.661608e-09
4	O	C	1.529443e-72
5	P	C	1.193610e-44
6	C	V	2.242027e-09
7	P	V	6.219013e-02
8	C	L	4.695342e-54
9	P	L	3.350230e-04

^۱ P-value

جدول ۴. قدرت (مقدار احتمال) یال‌ها برای داده‌های هفتگی


#	From	To	Strength
1	P	H	3.190903e-11
2	C	H	3.993275e-235
3	P	O	8.205500e-12
4	O	C	7.453317e-284
5	P	C	2.258582e-57
6	L	V	4.792410e-10
7	P	V	8.683576e-02
8	C	L	8.473307e-263
9	P	L	2.422278e-06

قدرت‌های یال‌های معرفی شده در سطرهای ۲، ۴، ۵ و ۸ مربوط به جداول ۶ و ۷ از بقیه یال‌ها نسبت به هم گروهی خود بسیار بالاتر هستند. لذا با اطمینان بیشتری می‌توان روی وابستگی آن‌ها حساب کرد. در نتیجه با تکیه بر این یافته‌های می‌توان تابع توزیع احتمال توأم (شبکه باور بیزی) رابطه ۶ را به عنوان قدرتمندترین شبکه باور بیزی برای ارتباطات بین مقادیر قیمت، باز شدن، بسته شدن، پایین‌ترین، بالاترین و نیز ارتباط با موقعیت‌های خرید یا فروش معرفی نمود؛ که در آن F_s تابع توزیع احتمال توأم و P_s نماد احتمال است و بقیه نمادها همان‌هایی هستند که در رابطه ۴ معرفی شده‌اند.

$$F_s(P, O, C, L, H) = P_s(P) \times P_s(C|O, P) \times P_s(H|C) \times P_s(L|C) \quad (۶)$$

شکل ۸ شبکه باور بیزی را بعد از آموزش پارامتری را نشان می‌دهد.

شکل ۸ شبکه باور بیزی با قوی ترین یال‌ها بعد از آموزش پارامتری



بعد از تکرار عملیات فوق برای همان رمزارزها و با همان تعداد داده روزانه برای بقیه روزها (دو بازه زمانی سه ماهه) میانگین دقت P_d مطابق رابطه (۲) ۷۸ درصد شده است. بعد از تکرار عملیات فوق برای همان رمزارزها و با همان تعداد داده هفتگی برای بقیه هفته‌ها (دو بازه زمانی سه ماهه) میانگین دقت P_w مطابق رابطه (۲) ۶۴/۵ درصد شده است. در خصوص ساختار شبکه‌های باور تولیدشده هم باید ذکر کنیم که نه برای داده‌ای هفتگی و نه برای داده‌های روزانه ساختارهای تولیدشده تغییر محسوسی نسبت شکل‌های ۴ و ۵ نداشته‌اند. نحوه‌ی تولید جداول راهنمای خرید: در پایان و مطابق سطح‌بندی رابطه (۱) به نحوه تولید جداولی می‌پردازیم که تمامی ۴۸۶ حالت ممکن پیشروی معامله‌گر را برای متغیرهای

تصادفی شامل هستند. برای نمونه جدول ۵ بخشی از همه حالت‌های ممکن (روزانه) که توسط رابطه ۷ تولید می‌شود را نمایش می‌دهد. برای مثال سطر ۲۴۱ یعنی احتمال اینکه خرید موفق برای رمزارز موردنظری داشته باشیم، به شرطی که بالاترین قیمت آن (H) در ۲۴ ساعت گذشته در سطحی بالا (A) بوده و بقیه متغیرها در پایین‌ترین سطح (C) باشند، ۶۷/۸ درصد است.

cpquery(Fited.bayes.daily.102, (P=="buy"), (۷)
((H=="A")&(V=="C")&(O=="C")&(L=="C")&(C=="C"))))
= 0.67857143

جدول ۵. بخش جدول حالات ممکن برای متغیرهای تصادفی و پیشنهادهای خرید و فروش

	H	V	O	L	C	P	result_matrix
240	C	B	C	C	C	buy	0.56250000
241	A	C	C	C	C	buy	0.67857143
242	B	C	C	C	C	buy	0.33333333
243	C	C	C	C	C	buy	0.78546099
244	A	A	A	A	A	sell	0.57392687
245	B	A	A	A	A	sell	0.44019139
246	C	A	A	A	A	sell	0.06250000
247	A	B	A	A	A	sell	0.26363636
248	B	B	A	A	A	sell	0.13953488
249	C	B	A	A	A	sell	0.12500000

Showing 240 to 249 of 486 entries, 7 total columns

بحث و نتیجه‌گیری

در این پژوهش نشان داده شد که شبکه‌های باور بیزی از نظر دقت، صحت، یادآوری، استحکام و معیارهای ROC و AUC نسبت به روش طبقه‌بندی مبتنی بر برآورد بیشینه درست‌نمایی عملکرد برتری دارند. علاوه بر این، شبکه‌های باور بیزی با توجه به قابلیتشان در مدل‌سازی و نمایش ارتباطات میان گره‌ها (متغیرهای تصادفی)، مزیت دیگری در

مقایسه با برآورد پیشینه درست‌نمایی ارائه می‌کنند.

این پژوهش با اتخاذ رویکردی نوآورانه، به‌جای تمرکز بر تحلیل یک رمزارز خاص، کل بازار رمزارزها را به‌عنوان موضوع موردبررسی قرار داده است. این رویکرد جامع امکان تحلیل دقیق‌تر و عمیق‌تری از دینامیک‌های بازار را فراهم کرده و به پژوهشگران و تصمیم‌گیرندگان کمک می‌کند تا درک مطمئن‌تری از تغییرات و روندهای بازار را به‌دست آورند. لازم به ذکر است که در مطالعات پیشین، این مسئله عمدتاً از طریق استفاده از اخبار رسانه‌ها و وارد کردن آن‌ها به‌عنوان متغیرهای تصادفی مستقل بررسی شده است، روشی که با اصول اولیه شبکه‌های باور بیزی، به‌ویژه در زمینه شرط استقلال متغیرها، همخوانی ندارد.

علاوه بر این، این تحقیق با ارائه روشی برای تولید جدولی کیفی و عددزدایی شده، فرایند تصمیم‌گیری را تسهیل می‌کند. این روش به‌گونه‌ای طراحی شده است که تصمیم‌گیرندگان بتوانند تصمیمات آگاهانه‌تری اتخاذ کنند؛ به‌عبارت‌دیگر، این پژوهش نه تنها به غنای ادبیات علمی در زمینه تصمیم‌گیری کمک می‌کند، بلکه ابزارهای عملی و کاربردی را برای تسهیل تصمیم‌گیری در شرایط عدم قطعیت ارائه می‌دهد. درنهایت، با تولید یک شبکه باور بیزی با یال‌های قوی یک شبکه با قابلیت بالای اطمینان تولید کرده‌ایم.

محدودیت اصلی این مطالعه به عدم قابلیت پیش‌بینی روندهای پیوسته آینده برای پیش‌بینی مسیرهای آتی مربوط می‌شود. به‌منظور رفع این محدودیت و به‌عنوان پیشنهادی برای پژوهش‌های آینده، می‌توان از شبکه باور بیزی معرفی شده در معادله ۵ که دارای یال‌های با اطمینان بالا است، به‌عنوان باور اولیه جامعه، استفاده کرد. خروجی‌های این شبکه می‌تواند به‌عنوان شرایط اولیه برای ویژگی‌های عوامل (رمزارزها) در یک شبیه‌سازی عامل‌بنیان به کار گرفته شود. به‌ویژه، نویسندگان پیشنهاد می‌دهند از روش عامل‌بنیان پویایی عقاید در حالت پیوسته بهره‌برداری شود.

تعارض منافع

هیچ گونه تعارض منافی در این پژوهش وجود ندارد کلیه کارهای برنامه نویسی و خروجی های رایانه نیز در محیط زبان برنامه نویسی R و بسته های نرم افزاری متن باز این زبان انجام گرفته است.

ORCID

Reza Hosseingholizadeh
Mahmood Alborzi
Abbas Toloie Eshlaghy
Hamid Zargham Boroujeni



<http://orcid.org/0000-0001-8417-5972>



<http://orcid.org/0000-0001-6619-992X>



<http://orcid.org/0000-0001-6050-1016>



<http://orcid.org/0000-0002-6624-5268>

منابع

۱. حبیبی راد امین، پناهی علی. (۱۴۰۰). تبیین رابطه قیمت بیت کوین در مبادلات مالی کسب و کارها و حجم جستجو به منظور شناسایی الگوی رفتاری آن: یک مطالعه تطبیقی بین کشورها. *مطالعات مدیریت کسب و کار هوشمند*, 10(37), 347-372. doi: 10.22054/ims.2021.61455.1982
۲. حسینی زاده رضا، البرزی محمود، طلوعی اشقی عباس، ضرغام بروجنی، حمید. (۱۴۰۱). پویایی عقاید ذی نفعان گردشگری ایران در مواجهه با گردشگران چینی. *فصلنامه مطالعات مدیریت گردشگری*, ۱۷(۶۰), ۴۷-۶۷. doi: 10.22054/tms.2022.69532.2746۷۷-۴۷

References

3. Amirzadeh, R., Nazari, A., Thiruvady, D. R., & Ee, M. S. (2023). Modelling determinants of cryptocurrency prices: A Bayesian network approach. *arXiv preprint*. <https://doi.org/10.48550/arXiv.2303.16148>
4. Amirzadeh, R., Thiruvady, D., Nazari, A., & Ee, M. S. (2024). Dynamic Bayesian networks for predicting cryptocurrency price directions: Uncovering causal relationships. *arXiv preprint arXiv:2306.08157*. <https://doi.org/10.48550/arXiv.2306.08157>
5. Ayitey Junior, M., Appiahene, P., Appiah, O., & Bombie, C. N. (2023). Forex market forecasting using machine learning: Systematic literature review and meta-analysis. *Journal of Big Data*, 10(1), Article 9. <https://doi.org/10.1186/s40537-022-00676-2>
6. Beato, F. (2024). US unveils new tools to withstand encryption-breaking quantum. World Economic Forum. Retrieved from <https://www.weforum.org/stories/2024/08/us-tools-encryption-breaking-quantum-computing-nist/>
7. Durga, P. V. V., & Anusha, G. (2024). Predicting cryptocurrency price using multiple deep learning models. In *Accelerating Discoveries in Data Science and Artificial Intelligence I* (pp. 247–258). Springer. https://doi.org/10.1007/978-3-031-51167-7_24
8. Fama, E. F. (1970). Efficient capital markets: A review of theory and empirical work. *The Journal of Finance*, 25(2), 383–417. <https://doi.org/10.2307/2325486>
9. Fama, E. F. (1965). The behavior of stock-market prices. *Journal of Business*, 38(1), 34-105. <https://doi.org/10.1086/294743>
10. Friedman, N., Geiger, D., & Goldszmit, M. (1997). Bayesian network classifiers. *Machine Learning*, 29(2-3), 131-163. <https://doi.org/10.1023/A:1007465528199>

11. Hastie, T., Tibshirani, R., & Friedman, J. (2009). The elements of statistical learning: Data mining, inference, and prediction (2nd ed.). Springer. <https://doi.org/10.1007/978-0-387-84858-7>
12. Heckerman, D. (1995). A tutorial on learning with Bayesian networks. *Machine Learning*, 20(3), 197–243. <https://doi.org/10.1007/BF00994016>
- Hexn. (2024). Understanding Ethereum 2.0: Improving scalability and security. Hexn. Retrieved from <https://hexn.io/blog/what-you-need-to-know-about-ethereum-20-225>
13. Jensen, F. V., & Nielsen, T. D. (2007). Bayesian networks and decision graphs. Springer. <https://doi.org/10.1007/978-0-387-68282-0>
14. Levenchuk, L. (2022). The Bayesian approach to analysis of financial operational risk. *Finance*, 10(2), 123–135. <https://doi.org/10.21303/2313-8416.2022.002377>
15. Liu, R., Yang, B., Zio, E., & Chen, X. (2018). Artificial intelligence for fault diagnosis of rotating machinery: A review. *Mechanical Systems and Signal Processing*, 108, 33–47. <https://doi.org/10.1016/j.ymssp.2018.02.016>
16. Lorenz, G. (2024). Regulating decentralized financial technology: A qualitative study on challenges and opportunities in the DeFi space. *Stanford Journal of Blockchain Law & Policy*, 8(1). <https://doi.org/10.21428/96c8d426.8f7b8a3b>
17. McCullagh, P., & Nelder, J. A. (1989). Generalized linear models (2nd ed.). Chapman & Hall/CRC. <https://doi.org/10.1201/9781315133156>
18. McCloskey, S. (2000). Probabilistic reasoning and Bayesian networks. *Neural Networks and Machine Learning*, Winter 1999-2000. Retrieved from <https://www.cim.mcgill.ca/~scott/RIT/researchPaper.html>
19. Margaritis, D. (2005). Learning Bayesian Network Model Structure from Data. [PhD Thesis]. Retrieved from <https://www.cs.cmu.edu/~dmarg/Papers/PhD-Thesis-Margaritis.pdf>. DOI: 10.5555/12345678
20. Minka, T. P. (2000). Expectation propagation for approximate Bayesian inference. *Proceedings of the 17th Conference on Uncertainty in Artificial Intelligence*, 362-369. <https://doi.org/10.5555/2073878>
21. Mironeanu, A., Irimia, B., Săndulescu, V., & Teodoroiu, C. (2021). The impact of Tesla's bitcoin investment and its plans to accept it as a payment method on the evolution of bitcoin. *Proceedings of the International Conference on Business Excellence*, 15, 58-74. <https://doi.org/10.2478/picbe-2021-0007>
22. Mohan, K., & Pearl, J. (2018). Graphical models for processing missing data. *arXiv preprint arXiv:1801.03583*.

- <https://doi.org/10.48550/arXiv.1801.03583> Pearl, J. (1988). Probabilistic reasoning in intelligent systems: Networks of plausible inference. Morgan Kaufmann. <https://doi.org/10.5555/56670>
23. Ozili, P. K. (2022). Decentralized finance research and developments around the world. *Journal of Banking and Financial Technology*, 6(1), 117–133. <https://doi.org/10.1007/s42786-022-00044-x>
 24. Pearl, J. (1988). *Probabilistic reasoning in intelligent systems: Networks of plausible inference*. Morgan Kaufmann. <https://doi.org/10.1016/C2009-0-27609-4>
 25. Polotskaya, K., Muñoz-Valencia, C. S., Rabasa, A., Quesada-Rico, J. A., Orozco-Beltrán, D., & Barber, X. (2024). Bayesian networks for the diagnosis and prognosis of diseases: A scoping review. *Machine Learning and Knowledge Extraction*, 6(2), 1243–1262. <https://doi.org/10.3390/make6020058>
 26. Poudel, S., Paudyal, R., Cankaya, B. et al. (2023). Cryptocurrency price and volatility predictions with machine learning. *J Market Anal* 11, 642–660. <https://doi.org/10.1057/s41270-023-00239-1>
 27. Saha, V. (2023). Predicting future cryptocurrency prices using machine learning algorithms. *Journal of Data Analysis and Information Processing*, 11(4), 400–419. <https://doi.org/10.4236/jdaip.2023.114021>
 28. Sebastião, H., & Godinho, P. (2021). Forecasting and trading cryptocurrencies with machine learning under changing market conditions. *Financial Innovation*, 7(1), Article 3. <https://doi.org/10.1186/s40854-020-00217-x>
 29. Zellner, M., Abbas, A. E., Budescu, D. V., & Galstyan, A. (2021). A survey of human judgement and quantitative forecasting methods. *Royal Society Open Science*, 8(2), 201187. <https://doi.org/10.1098/rsos.201187>
 30. Zhou, X. H., Obuchowski, N. A., & McClish, D. K. (2011). Statistical methods in diagnostic medicine. Wiley. <https://doi.org/10.1002/9780470906514>

References [In Persian]

1. Habibirad, A., & Panahi, A. (2021). Explaining the Relationship Between Bitcoin Price in Business Financial Transactions and Search Volume in Order to Identify its Behavioral Pattern: A Comparative Study Between Countries. *Business Intelligence Management Studies*, 10(37), 347-372. doi: 10.22054/ims.2021.61455.1982 [In Persian]
2. Hosseingholizadeh, R., Alborzi, M., Toloie Eshlaghy, A., & Zargham Boroujeni, H. (2023). Iranian Tourism Stakeholders' Opinion

Dynamics in the Face of Chinese Tourists. *Tourism Management Studies*, 17(60), 47 -77. doi: 10.22054/tms.2022.69532.2746 [In Persian]

استناد به این مقاله: حسینی زاده، رضا، البرزی، محمود، طلوعی اشلقی، عباس،، ضرغام بروجنی، حمید. (۱۴۰۴). پشتیبانی تصمیم در بازار رمزارزها با احتمالات شرطی: بیشینه درست‌نمایی و شبکه‌های باور بیزی، *مطالعات مدیریت کسب و کار هوشمند*، ۱۴(۵۳)، ۲۰۵-۲۳۸. DOI: 10.22054/ims.2025.83291.2549



Journal of Business Intelligence Management Studies is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License..