



Tax Evasion Modeling of Related Party Transactions: A Hybrid Approach of Graph Mining and Deep Neural Network

Amin Ahmadpour 

PhD Student in Accounting, Department of Management and Accounting, Islamic Azad University, South Tehran Branch, Tehran, Iran.

Seyedeh Mahboobeh Jafari* 

Assistant Professor, Department of Management and Accounting, South Tehran Branch, Islamic Azad University, Tehran, Iran.

Fateme Sarraf 

Assistant Professor, Department of Management and Accounting, South Tehran Branch, Islamic Azad University, Tehran, Iran.

Abstract

Tax evasion based on related party transactions is a new strategy in tax evasion that is carried out through legal transactions, such as transactions between a group of companies with heterogeneous, complex, and hidden interaction relationships for tax evasion. Existing studies cannot effectively identify tax evasion behaviors of related parties because machine learning-based audit methods can detect the abnormal financial status of individuals with high accuracy and efficiency. However, it is helpless when faced with heterogeneous, complex, and hidden interaction relationships and cannot identify tax evasion groups with related party transactions. The hybrid of graph mining and deep neural network approaches can detect anomalies in complex organizational structures. In this study, 1,780 companies with related party transactions, including 523 companies located in free trade zones and 1,257 companies located outside free trade zones, which have a common board member and economic activity of production or trade, were selected. In this study, financial and tax data from tax returns and the systems of the Iranian Tax Administration from 2016 to 2019 were used. This study is practical in terms of purpose. Python software and the Network

* Corresponding Author: Dr. Seyyede Mahboobeh Jafari

How to Cite: Ahmadpour, A., Jafari, S. M., & Sarraf, F. (2025). Tax Evasion Modeling of Related Party Transactions: A Hybrid Approach of Graph Mining and Deep Neural Network. *Journal of Tax Research*, 33(65), 7-51.

X package were used to estimate the model. To predict tax evasion in related party transactions, three algorithms were used: Convolutional Neural Network (CNN), Long Short-Term Memory (LSTM), and Multilayer Perceptron Neural Network (MLP) in deep mode. To identify suspicious groups, three steps were taken; first: detecting tax rate differences, matching the topological pattern, and identifying tax burden anomalies; second: experimental tests based on data from 16,756 related party transaction purchases and sales in the country; third: estimating the coefficients and the relationship between the topological pattern in the two cases of profit retention and profit transfer based on the graph mining approach and deep neural network. The results show that both profit retention and profit shifting exist in tax evasion of related party transactions. However, based on the results, the intensity of the profit retention relationship in tax evasion of related party transactions is stronger than the profit-shifting relationship. Based on the results, the graph mining approach was more accurate than the logit, probit, and linear probability models.

Introduction

Tax evasion is a financial crime against the tax system of countries in which taxpayers intentionally report false financial status to evade their tax obligations; therefore, this issue has become a serious economic problem for many countries due to the creation of a significant tax gap in the implementation of tax policies and the subsequent less reliance of governments on tax revenues in budgeting. In Iran, according to some existing laws, perpetrators of tax crimes are sentenced to the penalties prescribed by law.

It should be noted that recent research has used data analysis techniques to analyze and detect the tax evasion behaviors of individual taxpayers. However, they have failed to support the analysis and exploration of new tax evasion strategies through related party transactions (e. g. , transfer pricing) in which a group of taxpayers is involved. Effective analysis and investigation of tax evasion groups is challenging for the following reasons.

- The detection of tax evasion groups depends on the analysis of the topological interest relationship between different taxpayers and their various tax-related characteristics, which makes the investigation of tax evasion groups very complicated.
- The ambiguity in the accounting principle has led to a time-consuming audit method for tax officers to manually check whether a suspected group is committing tax evasion or not. Even recent advanced approaches to automatically detect group tax evasion can result in a high false positive rate and a large number of suspicious cases.
- Correlating and analyzing large volumes of financial data and transactions of related parties is time-consuming and complicates the exploration of suspicious patterns of tax evasion groups.

Methods and Material

To address the above challenges, we try to use graph mining to help tax officers identify, extract, and explore suspected tax evasion groups. It should be noted that today, deep learning is considered one of the hot topics in the fields of machine learning, artificial intelligence, as well as data science and analytics. In addition, it has become a rapidly developing approach for research in the field of artificial intelligence. Few methods in the literature can realize the advantages of machine learning-based audit methods and graph-based audit methods in detecting tax evasion based on related party transactions. In this study, we propose a new approach to effectively identify suspicious groups that exhibit both structural and commercial characteristics of tax evasion based on related party transactions through a uniform identification process. In this regard, information on net sales, cost of goods sold, operating profit (loss), special profit (loss), declared tax, and final tax from the performance tax returns of companies with related party transactions from 2016 to 2019 and the tax systems of the Iranian Tax Affairs Organization are used with confidentiality. In addition, data from 16,756 purchase and sale transactions have been extracted and used to monitor the pricing of related party transactions between parties. Then, we identify behavioral patterns of tax evasion based on related party transactions by extracting structural features from the network of related party interest groups and theoretically deducing the business characteristics of tax evasion instruments based on evidence.

Results and Discussion

In this study, an innovative hybrid model based on deep learning networks and graph mining has been presented to help determine topological relationships. Based on the results, both profit retention and profit transfer were observed in tax evasion of related party transactions. The results indicated that graph mining models are more accurate than the conventional logit and probit models.

Based on the results obtained, the intensity of the profit retention relationship in tax evasion of related party transactions is stronger than the profit transfer relationship. Given that previous research in this area has not been conducted with this process, in the general trend, it can be stated that the present study is in line with the results of Moqri Garderodbari et al. (2023); Ghanbarinejad et al. (2023); Sedaghati et al. (2021); Nasl Mousavi et al. (2020); Javadian Kootnai et al. (2020); Namazi et al. (2019); Lin et al. (2023); Leite et al. (2022); (2016); Roan et al. (2019); Tian et al. (2019); and Gonzalez et al. (2013).

Conclusion

Based on the results of the study, the following suggestions can be made.

In order to increase the accuracy of the model, the Iranian Tax Administration should use the information available in the databases of the Companies Registration Office and the Civil Registration Office to identify new interactive relationships and new behavioral topologies.

The Iranian Tax Administration should plan to identify complex and networked relationships between companies, which will play a key role in identifying

suspicious groups and their tax evasion.

The use of the aforementioned method by the Iranian Tax Administration will update the monitoring systems and use advanced technologies to identify suspicious transactions. In addition, the aforementioned method can also be used to better monitor and supervise financial activities in free trade and special economic zones.

Given the phenomenon of tax evasion through transactions between related parties, related business units with specific tax purposes should be specifically defined.

It is recommended that standard-setting bodies and regulators establish standards and rules to require companies to disclose more of the economic substance of related party transactions.

Investors are advised to use management contracts or audit mechanisms to reduce the detrimental effects of agency costs on related party transactions, by employing an audit committee in companies to control the price received or paid to related parties.

It is recommended that the Tax Administration of the country, within the framework of the “Risk-Based Tax Audit” project and the comprehensive tax plan, and using the data available in tax systems and databases, take action to identify related party transactions and financial irregularities in them, and then take special measures to train the tax officers in charge to be more careful in the auditing process of related files. In this regard, transactions with related parties that are identified by the Tax Administration based on the information available in tax systems and databases should be considered as one of the criteria and indicators for determining the risk of economic operators in the process of selecting appropriate files for auditing taxpayers who are members of the “Taxpayer System” or outside that system.

Penalties for failure of related business units to perform their duties, such as preparing and sending the related party transaction form to the relevant tax office, should be determined.

An appropriate procedure should be developed to resolve disputes between taxpayers and tax authorities on issues related to related party transactions.

To enact a clear and specific legal article on observing the arm’s length principle in financial transactions between related business units, and to develop precise tax guidelines and procedures, it seems necessary to conduct research related to transfer pricing before taking any action.

It is suggested that the Tax Affairs Organization actively cooperate with other countries that have experience in legislation, selecting appropriate cases for investigation, auditing, resolving disputes with taxpayers, and approving agreements on this matter.

Cooperation of the Tax Affairs Organization with other countries to exchange data and information of taxpayers related to the issue of related party transactions in the form of agreements to avoid double taxation.

Keywords: Graph Mining, Related Party Transactions, Suspicious Groups, Tax Evasion.



سازمان امور مالیاتی کشور

-- مجله علمی، پژوهشنامه مالیات --

شماره ۶۵، دوره ۳۳، بهار ۱۴۰۴، ۵۱-۷

taxjournal.ir

DOI:10.61882/taxjournal.33.65.7

مدل سازی فرار مالیاتی معاملات اشخاص وابسته رویکرد هیبریدی گراف کاوی و شبکه عصبی عمیق

دانشجوی دکتری رشته حسابداری، گروه مدیریت و حسابداری، دانشگاه آزاد اسلامی، واحد تهران جنوب، تهران، ایران.

امین احمدپور ^{ID}

استادیار، گروه مدیریت و حسابداری، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران.

سیده محبوبه جعفری* ^{ID}

استادیار، گروه مدیریت و حسابداری، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران.

فاطمه صراف ^{ID}

چکیده

فرار مالیاتی مبتنی بر معاملات وابسته، یک استراتژی جدید در فرار مالیاتی است که از طریق معاملات قانونی، مانند معاملات بین گروهی از شرکت‌ها که روابط تعاملی ناهمگن، پیچیده و پنهانی برای فرار مالیاتی دارند، انجام می‌شود. مطالعات موجود نمی‌توانند به طور مؤثر رفتارهای فرار مالیاتی اشخاص وابسته را شناسایی کنند، زیرا روش حسابرسی مبتنی بر یادگیری ماشین می‌تواند وضعیت مالی غیرعادی افراد را با دقت و کارایی بالا تشخیص دهد. با این حال، هنگام مواجهه با روابط تعاملی ناهمگن، پیچیده و پنهانی در مانده می‌شود و نمی‌تواند گروه‌های فرار مالیاتی دارای معاملات اشخاص وابسته را شناسایی کند. هیبرید رویکردهای گراف کاوی و شبکه عصبی عمیق، توانایی تشخیص ناهنجاری در ساختارهای سازمانی پیچیده را دارد. در این پژوهش، تعداد ۱۷۸۰ شرکت دارای معاملات وابسته، شامل ۵۲۳ شرکت واقع در مناطق آزاد تجاری و ۱۲۵۷ شرکت واقع در خارج از مناطق آزاد که دارای عضو هیأت مدیره مشترک و فعالیت اقتصادی تولیدی یا بازرگانی بوده‌اند، انتخاب شده‌اند. در این پژوهش، داده‌های مالی و مالیاتی سال‌های ۱۳۹۵ تا ۱۳۹۹ از اظهارنامه‌های مالیاتی و سامانه‌های سازمان امور مالیاتی کشور مورد استفاده قرار گرفته است. این پژوهش از نظر هدف، کاربردی می‌باشد. جهت برآورد مدل از نرم افزار پایتون و پکیج NetworkX بهره گرفته شده است. جهت پیش‌بینی فرار مالیاتی معاملات اشخاص وابسته از سه الگوریتم شبکه عصبی پیچشی (CNN)، حافظه کوتاه‌مدت ماندگار (LSTM)، و شبکه عصبی پرسپترون چند لایه (MLP) در حالت عمیق بهره گرفته شد. برای شناسایی گروه‌های مشکوک، سه مرحله: اول: تشخیص تفاوت نرخ مالیات، تطبیق الگوی توپولوژیکی و شناسایی ناهنجاری بار مالیاتی؛ دوم: آزمایش‌های تجربی بر اساس داده‌های ۱۶، ۷۵۶ مبادله خرید و فروش معاملات وابسته در کشور؛ سوم: برآورد ضرایب و نحوه ارتباط مابین الگوی توپولوژیک در دو حالت حفظ سود و انتقال سود بر اساس رویکرد گراف کاوی و شبکه عصبی عمیق صورت پذیرفته است. نتایج بدست آمده نشان می‌دهد که هر دو حالت حفظ سود و انتقال سود در فرار مالیاتی معاملات اشخاص وابسته وجود داشته است. با این وجود بر اساس نتایج، شدت رابطه حفظ سود در فرار مالیاتی معاملات اشخاص وابسته قوی‌تر از رابطه انتقال سود است و نیز رویکرد گراف کاوی نسبت به مدل‌های لاجیت، پرابیت و احتمال خطی از دقت بالاتری برخوردار می‌باشد. کلیدواژه‌ها: فرار مالیاتی، گراف کاوی، گروه‌های مشکوک، معاملات اشخاص وابسته.

* نویسنده مسئول: Sm_jafari@azad.ac.ir

مقدمه

امروزه فرار مالیاتی، اقدامی مجرمانه مالی علیه سیستم مالیاتی کشورها بوده به گونه‌ای که در آن مالیات‌دهندگان عمداً وضعیت مالی نادرستی را به منظور شانه خالی کردن از زیر تعهدات مالیاتی خود گزارش می‌کنند؛ لذا این موضوع به دلیل ایجاد شکاف مالیاتی قابل توجه در تحقق سیاست‌گذاری‌های مالیاتی و متعاقب آن، اتکای کم‌تر دولت‌ها به درآمدهای مالیاتی در بودجه‌ریزی، به یک معضل اقتصادی جدی برای بسیاری از کشورها تبدیل شده است. در واقع این شکاف به تفاوت بین درآمد مالیاتی حاصل از فعالیت‌های اقتصادی فعالان اقتصادی که وفق قوانین و مقررات می‌بایست به دولت پرداخت شود و درآمد مالیاتی که توسط دولت جمع‌آوری گردیده است تعبیر می‌شود؛ همچنین، فرار مالیاتی به فضای رقابت تجاری ناعادلانه و گسترش بی‌عدالتی و بی‌اعتمادی فعالان اقتصادی به سیستم‌های اجرایی کشورها نیز منجر می‌شود، به ویژه برای مؤدیانی که هزینه‌های عملیاتی آن‌ها بیشتر در مقایسه با رقبایشان است (Lin et al., 2021: 849).

اصولاً عدم تمکین به مقررات مالیاتی، موضوعی است که به دلیل جذابیت آن برای مؤدیان مالیاتی در همه جای دنیا حتی کشورهای پیشرفته نیز دارای اهمیت و محل چالش و کشمکش بوده است. از این‌رو دولت‌ها با طراحی و راه‌اندازی سیستم‌های اطلاعاتی پیشرفته و تدوین سازوکارهای بازدارنده، سعی در کاهش آن کرده‌اند (Li et al., 2020: 384).

در ایران نیز به استناد ماده ۵ قانون ارتقاء سلامت نظام اداری و مقابله با فساد مصوب ۱۳۸۷/۲/۲۹ و همچنین مواد ۲۷۴ تا ۲۷۷ قانون مالیات‌های مستقیم مصوب ۱۳۹۴/۴/۳۱، مرتکبان جرائم مالیاتی به مجازات‌های مقرر در قانون محکوم می‌شوند. به استناد بررسی‌های صورت گرفته توسط سازمان همکاری و توسعه اقتصادی، چنین پدیده‌ای در نهایت باعث عدم تمکین مالیاتی بیشتر برای به چالش کشیدن سیستم مالیاتی و ایجاد کشمکش می‌شود (OECD¹, 2020). در این راستا مقامات مالیاتی تلاش‌های زیادی را در تلاش برای کاهش شکاف مالیاتی و کاهش رفتارهای دارای فرار مالیاتی انجام داده‌اند (Kim et al., 2016). لازم به ذکر است که هر چند بسیاری از رویکردهای انتخاب پرونده مالیاتی به کمک رایانه به طور گسترده برای شناسایی رفتارهای دارای فرار مالیاتی فردی مانند: دستکاری حساب (Liu et al., 2010: 1 و Wu et al., 2012: 8769) و فاکتورهای نادرست

1. Organization for Economic Co-operation and Development

(González et al., 2013: 1427) استفاده شده است، با این حال، اقدامات یاد شده عمدتاً بر شناسایی افراد دارای فرار مالیاتی با طراحی مجموعه‌ای از شاخص‌های مالی و آموزش بیشتر یک مدل طبقه‌بندی‌کننده برای طبقه‌بندی نهادهای مالیات‌دهنده متمرکز هستند (Hsu et al., 2015: 221). ضمن این که قادر به شناسایی رفتارهای دارای فرار مالیاتی مبتنی بر معاملات با اشخاص وابسته نیستند (Matos et al., 2015)، جایی که گروه مالیات‌دهندگان وابسته در توزیع غیر قانونی سود و زیان خود برای کاهش بار مالیاتی کلی مشارکت دارند (Ruan et al., 2019). علاوه بر این اقدامات حسابرسی مالیاتی سنتی معمولاً با فرآیندهای خسته‌کننده زمان بر همراه است (Tian et al., 2016: 2651)؛ بنابراین، استفاده از اقدامات یاد شده در راستای تشخیص فرار مالیاتی مبتنی بر معاملات اشخاص وابسته مثرتر نیستند (Liu et al., 2010: 1). ذکر این نکته ضروری به نظر می‌رسد که پژوهش‌های اخیر از تکنیک‌های تجزیه و تحلیل داده‌ها برای تجزیه و تحلیل و تشخیص رفتارهای فرار مالیاتی مالیات‌دهندگان فردی استفاده کرده است (Klassen et al., 2017: 445). با این حال، آن‌ها در حمایت از تجزیه و تحلیل و کاوش استراتژی جدید فرار مالیاتی از طریق معاملات اشخاص وابسته (به عنوان مثال، قیمت‌گذاری انتقالی) که در آن گروهی از مالیات‌دهندگان درگیر هستند، شکست خورده‌اند. از آن جایی که رفتارهای فرار مالیاتی معاملات اشخاص وابسته اغلب از طریق معاملات اشخاص وابسته و قیمت‌گذاری انتقالی انجام می‌شود و به یک روند جهانی رو به رشد در فرار مالیاتی تبدیل شده است (Schmidt et al., 2017: 1; Ferrantino et al., 2012: 141)؛ بنابراین شناسایی، استخراج و اکتشاف مؤثر گروه‌های فرار مالیاتی در کاهش شکاف مالیاتی از اهمیت قابل توجهی برخوردار است. با این حال، تجزیه و تحلیل و بررسی مؤثر گروه‌های فرار مالیاتی به دلایل ذیل چالش‌برانگیز است.

- تشخیص گروه‌های فرار مالیاتی به تجزیه و تحلیل رابطه منافع توپولوژیکی بین مالیات‌دهندگان مختلف و ویژگی‌های مختلف وابسته با مالیات آن‌ها بستگی دارد که بررسی گروه‌های فرار مالیاتی را بسیار پیچیده می‌کند.
- ابهام در اصل حسابداری منجر به یک روش حسابرسی وقت‌گیر برای مأموران مالیاتی شده است تا به صورت دستی بررسی کنند که آیا یک گروه مشکوک فرار مالیاتی انجام می‌دهند یا خیر؟ حتی رویکردهای پیشرفته اخیر برای تشخیص خودکار فرار مالیاتی گروهی می‌تواند منجر به نرخ مثبت کاذب بالا و تعداد زیادی از موارد مشکوک شود (Lin et al., 2021: 851).

• مرتبط کردن حجم زیادی از داده‌های مالی و معاملات اشخاص وابسته و تجزیه و تحلیل آن‌ها زمان‌براست و کاوش الگوهای مشکوک گروه‌های فرار مالیاتی را پیچیده می‌کند. برای رسیدگی به چالش‌های فوق، سعی شده است از گراف کاوی برای کمک به مأمورین مالیاتی در شناسایی، استخراج و اکتشاف گروه‌های فرار مالیاتی مشکوک استفاده گردد. لازم به ذکر است که امروزه یادگیری عمیق به عنوان یکی از موضوعات داغ در حوزه یادگیری ماشین، هوش مصنوعی و همچنین علم داده و تجزیه و تحلیل در نظر گرفته می‌شود (Karhunen et al., 2015: 125). علاوه بر این به سرعت به رویکردی در حال توسعه برای پژوهش در حوزه هوش مصنوعی تبدیل شده است (Sarker, 2021). نظریه بازی‌ها در چند دهه اخیر کاربردهای خود را در ابعاد مختلف نشان داده است. یک بازی را می‌توان به عنوان تعاملی رقابتی یا مشارکتی بین اشیا یا بازیکنان تعریف کرد (Myer-son, 2013). نظریه بازی‌ها به مدل‌سازی یا حل مسائل مختلف مبتنی بر یادگیری عمیق کمک می‌کند. مشارکت‌های پژوهشی موجود نشان می‌دهد که نظریه بازی یک رویکرد بالقوه برای بهبود نتایج در مدل‌های یادگیری عمیق است. طراحی مدل‌های یادگیری عمیق اغلب شامل یک رویکرد نظری بازی است. بسیاری از مشکلات طبقه‌بندی که معمولاً از یک رویکرد یادگیری عمیق استفاده می‌کنند، می‌توانند به عنوان یک بازی استاگلیبگ^۱ دیده شوند (Hazra et al., 2022). تئوری بازی، زمینه‌ای ضروری برای پژوهش است و به انتخاب استراتژی مناسب بازیکنان در یک بازی کمک می‌کند و کاربردهای متعددی در حوزه‌های مختلف دارد (Myerson, 2013; Narahari, 2014). روش دیگر، یادگیری عمیق مطالعه الگوریتم‌های یادگیری مختلف است که از لایه‌های متعدد واحدهای پردازش غیرخطی استفاده می‌کند. خروجی لایه قبلی توسط هر لایه متوالی به عنوان ورودی گرفته می‌شود. الگوریتم‌های یادگیری عمیق در درجه اول به سه دسته طبقه‌بندی می‌شوند، به عنوان مثال، تحت نظارت، نیمه نظارت و بدون نظارت. الگوریتم‌های یادگیری عمیق، ویژگی‌های سطح بالاتری را که از ویژگی‌های سطح پایین استخراج می‌شوند، پیاده‌سازی می‌کنند. عمق در شبکه‌های عصبی نقش اساسی در نتیجه مدل دارد. چارچوب شبکه‌های عصبی می‌تواند محیط‌های پویا را نشان دهد و به طور مشابه، محیط‌های پویا را می‌توان بیشتر به عنوان بازی ارائه کرد (Goodfellow et al., 2016; LeCun et al., 2015: 436).

در مقابل، روش حسابرسی مبتنی بر گراف می‌تواند گروه‌های مشکوکی را که ویژگی‌های ساختاری فرار مالیاتی مبتنی بر معاملات اشخاص وابسته را نشان می‌دهند، شناسایی کند. اصولاً نظریه گراف برای ارائه ساختارهای پیچیده‌ای که مدل‌سازی آن‌ها دشوار است مورد استفاده قرار می‌گیرد (Rogelio, 2004: 313). علاوه بر این داده‌های رابطه‌ای زیادی وجود دارد که با این نظریه قابل مدل‌سازی می‌باشد. با این حال، ویژگی‌های تجاری تکنیک‌های فرار مالیاتی، مانند وضعیت مالی غیرعادی ارجاع شده که توسط مقامات مالیاتی تأیید شده و برای تشخیص فرار مالیاتی از طریق معاملات اشخاص وابسته حیاتی است، نادیده گرفته می‌شود. تشخیص فرار مالیاتی مبتنی بر معاملات اشخاص وابسته تنها براساس ویژگی‌های ساختاری می‌تواند منجر به نرخ مثبت کاذب بالا شود. روش‌های اندکی در ادبیات می‌توانند مزایای روش حسابرسی مبتنی بر یادگیری ماشین و روش حسابرسی مبتنی بر گراف را در تشخیص فرار مالیاتی مبتنی بر معاملات اشخاص وابسته درک کنند. علاوه بر این، راه‌حل‌های موجود به ندرت در شناسایی فرار مالیاتی مبتنی بر معاملات اشخاص وابسته در اکثر بخش‌های شرکت‌ها خوب عمل می‌کنند (Ruan et al., 2019). در این پژوهش، ما رویکردی جدید برای شناسایی مؤثر گروه‌های مشکوک که هم ویژگی‌های ساختاری و هم تجاری فرار مالیاتی مبتنی بر معاملات اشخاص وابسته را از طریق یک فرآیند شناسایی یکنواخت نشان می‌دهند، پیشنهاد می‌کنیم.

ابتدا شبکه‌ای مرتبط با منافع گروه‌های وابسته را برای مشخص کردن موارد داده ضروری برای تشخیص فرار مالیاتی مبتنی بر معاملات اشخاص وابسته ارائه می‌کنیم، به گونه‌ای که یک طرف معامله وابسته، شرکت واقع در مناطق آزاد دارای فعالیت تولیدی برخوردار از نرخ صفر مالیاتی موضوع بند «ت» ماده ۱۳۲ قانون مالیات‌های مستقیم بوده و طرف دیگر معامله بر اساس اطلاعات موجود در سامانه‌های مالیاتی دارای اعضای هیأت مدیره مشترک با شرکت واقع در مناطق آزاد تجاری باشند.

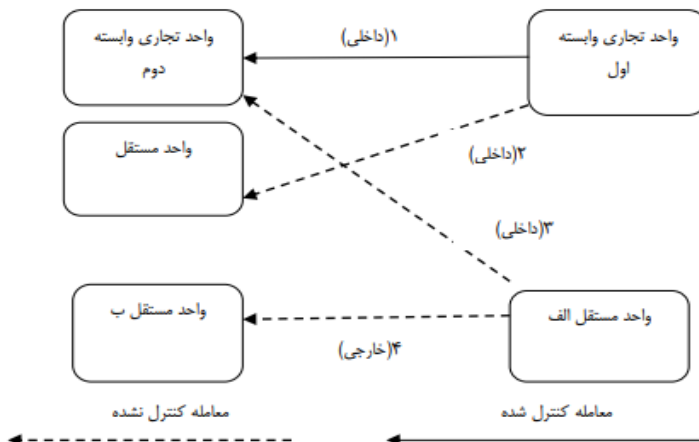
در این راستا، اطلاعات فروش خالص، بهای تمام شده کالای فروش رفته، سود (زیان) عملیاتی، سود (زیان) ویژه، مالیات ابرازی و مالیات قطعی از اظهارنامه‌های مالیاتی عملکرد سال‌های ۹۵ تا ۹۹ شرکت‌های دارای معاملات وابسته و سامانه‌های مالیاتی سازمان امور مالیاتی کشور با رعایت محرمانگی مورد استفاده قرار گرفته است. علاوه بر این در جهت رصد نحوه قیمت‌گذاری معاملات وابسته میان طرفین، داده‌های ۱۶، ۷۵۶ معامله خرید و فروش استخراج و مورد استفاده قرار گرفته است. سپس، الگوهای رفتاری فرار مالیاتی مبتنی بر معاملات اشخاص

وابسته را با استخراج ویژگی‌های ساختاری از شبکه مرتبط با منافع گروه‌های وابسته و استنتاج نظری ویژگی‌های تجاری ابزارهای فرار مالیاتی مبتنی بر معاملات اشخاص وابسته بر اساس شواهد شناسایی می‌کنیم.

مبانی نظری و پیشینه پژوهش

در رسوایی‌های مالی رخ داده اخیر آدلفیا و انرون در آمریکا و پارمالات در اروپا معاملات با اشخاص وابسته به یکی از کانون‌های نگرانی تبدیل شده است، به گونه‌ای که استفاده هدفمند از این معاملات و عدم افشای آن‌ها یا کافی نبودن افشا، از عوامل سقوط شرکت‌ها بوده است. به عبارت دیگر، یکی از دلایل رسوایی شرکت‌های بزرگ آمریکا ضعف در گزارش‌گری مالی و به خصوص ضعف در گزارش معاملات با اشخاص وابسته، شناخته شده است. وجود معامله با اشخاص وابسته یکی از نشانه‌های حسابداری متهورانه است. وجود معامله با اشخاص وابسته یکی از دلایل عمده‌ای است که شرکت‌ها را ترغیب می‌کند تا گزارش‌های مالی خود را دوباره ارائه کنند (Yusufabad et al., 2022). برای تعیین قیمت بر اساس اصل معاملات مستقل، از روش‌های مختلفی استفاده می‌شود. قبل از توضیح روش‌ها لازم است در قالب نمودار (۱)، در خصوص معاملات کنترل شده و نشده خارجی یا داخلی توضیح مختصری داده شود.

نمودار ۱. معاملات کنترل شده و نشده خارجی و داخلی



منبع: یافته‌های پژوهش.

طبق نمودار بالا فرض می‌شود واحد تجاری اول، تولیدکننده ماشین‌آلات (در منطقه اول) باشد که ماشین‌آلات تولیدی را به واحد تجاری وابسته خودش (در منطقه دوم) انتقال می‌دهد. واحد تجاری اول، شرکت مادر بوده و واحد تجاری دوم، واردکننده و وابسته شرکت مادر است. اصطلاحاً به معامله بین واحدهای تجاری وابسته اول و دوم، معامله کنترل شده گویند؛ همچنین منظور از معامله کنترل نشده این است که قیمت مربوطه، به طور آزاد و مستقل از اراده واحدهای تجاری وابسته به گروه بدست آمده باشد. در اینجا هدف، تعیین این موضوع است که آیا در معامله کنترل شده، قیمت بر مبنای اصل معاملات مستقل لحاظ شده یا خیر. سایر معاملات (یعنی معاملات ۲، ۳ و ۴)، در این نمودار، معاملات کنترل نشده محسوب می‌شوند. به معامله چهارم، اصطلاحاً معامله کنترل نشده قابل قیاس خارجی اطلاق می‌شود، زیرا هیچکدام از دو طرف معامله، واحد وابسته محسوب نمی‌شوند. در نهایت معاملات ۲ و ۳، معامله کنترل نشده قابل قیاس داخلی در نظر گرفته می‌شوند.

پژوهش‌های داخلی

مقری گردردباری و همکاران (۱۴۰۲)، اقدام به پیش‌بینی فرار مالیاتی مؤدیان حقوقی با تأکید بر مؤلفه‌های اقتصادی، مؤدیان و حساب‌برسان مالیاتی، با تکیه بر هوش مصنوعی نمودند. در این پژوهش، مقوله فرار مالیاتی با استفاده از هوش مصنوعی و با تمرکز بر مجموعه‌ای متشکل از ۵۷ شاخص مالی و غیرمالی در سطح کلان اقتصادی، مؤدیان و حساب‌برسان مالیاتی، در نمونه‌ای شامل ۹۷۸ پرونده مؤدیان حقوقی اداره کل امور مالیاتی مازندران برای سال‌های ۱۳۹۱ تا ۱۳۹۸ مورد بررسی قرار گرفته است. همچنین به منظور استخراج ویژگی‌های تأثیرگذار، از الگوریتم‌های بهینه‌سازی سینوس کسینوس و گرگ خاکستری و جهت مدل‌سازی فرار مالیاتی و آزمون ویژگی‌ها، از الگوریتم‌های درخت تصمیم و شبکه عصبی مصنوعی استفاده شده است. براساس نتایج حاصله، الگوریتم بهینه‌سازی سینوس کسینوس به همراه پیش‌بینی‌کننده درخت تصمیم، مقدار خطای کمتری نسبت به سایر مدل‌ها دارد و مدلی دقیق‌تر جهت پیش‌بینی فرار مالیاتی ارائه می‌دهد.

قنبری‌نژاد و همکاران (۱۴۰۲)، به بررسی عوامل فرار مالیاتی در مناطق آزاد تجاری کشور ایران پرداختند. این پژوهش، به دنبال یافتن پاسخ به این سؤال است که عوامل فرهنگی، اقتصادی، سیاسی، تمکین مالیاتی، فرار مالیاتی و نرخ مالیاتی (انصاف مالیاتی)، می‌تواند موجبات فرار

مالیاتی را در مناطق آزاد تجاری کشور ایران فراهم کند یا خیر؟ بدین منظور، روش پژوهش بر اساس هدف، کاربردی و براساس روش، توصیفی - پیمایشی است. جامعه آماری این پژوهش، کلیه کارمندان و متخصصان اداره گمرک و اداره امور مالیاتی مناطق آزاد تجاری می‌باشند که ۴۸۰ نفر کارمند اداره مالیاتی مناطق آزاد تجاری و ۴۰۰ نفر کارمند اداره گمرک به روش نمونه‌گیری کوکران به عنوان حجم نمونه انتخاب شده‌اند. در این پژوهش از آزمون‌های رویکرد حداقل مربعات جزئی برای بررسی تأثیر متغیرهای مستقل بر متغیر وابسته استفاده شده است. نتایج پژوهش نشان داد که عوامل فرهنگی، اقتصادی، سیاسی، تمکین مالیاتی، فرار مالیاتی و نرخ مالیاتی (انصاف مالیاتی)، بر فرار مالیاتی و اجتناب مالیاتی در مناطق آزاد تجاری ایران تأثیر مثبت و معناداری داشته است.

صداقتی و همکاران (۱۴۰۳)، با استفاده از مدل‌سازی اپیدمیک پایه بر شبکه با استفاده از نظریه گراف، پویایی‌های سرایت در بازار سهام ایران در دوره سال‌های ۱۳۹۰ تا ۱۳۹۸ را در دو نتیجه کوتاه‌مدت و بلندمدت مورد تجزیه و تحلیل قرار دادند. به این منظور، ابتدا شبکه همبستگی ۴۶ گروه بازار سهام ایران ساخته شده و سپس با استفاده از شبیه‌سازی پویایی‌های سرایت در دو مقیاس تحلیل شده است. نتایج پژوهش نشان می‌دهد که سرعت سرایت در کوتاه‌مدت بسیار بیشتر از بلندمدت است و در بلندمدت، تعداد قابل توجهی از گروه‌ها مصون از سرایت منتشر می‌شود. در بلندمدت سرعت بازگشت به وضعیت قبل از سرایت، کمتر از کوتاه‌مدت است.

نسل موسوی و همکاران (۱۳۹۹)، مدلی جدید برای تشخیص فرار مالیاتی مؤدیان مالیاتی ارائه نموده‌اند. ایده اصلی این پژوهش، از مقایسه نسبت‌های مالی شرکت مورد نظر با نسبت‌های سال گذشته و همچنین برآورد مالیات سال مورد رسیدگی از روی مالیات سال قبل گرفته شده است. الگوریتمی که در تحقیق یاد شده از آن استفاده شده مبتنی بر الگوریتمی ترکیبی بوده که از ترکیب الگوریتم درخت تصمیم ID3 و شبکه بیزین تشکیل شده است.

جوادیان کوتنائی و همکاران (۱۳۹۹)، مدل شناسایی تقلب مالیاتی بر مبنای ترکیب الگوریتم درخت تصمیم ID3 بهبود یافته و شبکه‌های عصبی پرسپترون چند لایه را ارائه نموده‌اند. هدف از پژوهش مذکور، ارائه مدلی بوده که در آن از الگوریتم درخت تصمیم‌گیری ID3 بهبود یافته استفاده شود. همچنین برای بهبود عملکرد و دقت آن، با شبکه‌های عصبی پرسپترون چند لایه بهینه‌سازی شده توسط الگوریتم ژنتیک ترکیب شد تا نسبت‌های مالی مرتبط با تقلب مالیاتی را انتخاب

نموده و سربار محاسباتی کاهش یابد. درختی که در این مدل پیشنهادی ایجاد می‌شود، دارای کمترین عمق ممکن می‌باشد که از این رو دارای سرعت بالا و سربار محاسباتی پایینی می‌باشد. نمازی و همکاران (۱۳۹۷)، سودمندی روش انتخاب متغیر ریلیف در بهبود نتایج پیش‌بینی فرار مالیاتی با استفاده از داده‌های کاوی را بررسی نموده‌اند. پژوهش یاد شده به بررسی سودمندی روش‌های ریلیف و داده‌های کاوی در پیش‌بینی فرار مالیاتی شرکت‌های پذیرفته شده در بورس اوراق بهادار تهران، با استفاده از داده‌های حسابداری و الگوهای درخت تصمیم، در دو حالت بدون انتخاب و با انتخاب متغیرها می‌پردازد.

در پژوهش رحیمی کیا و همکاران (۱۳۹۷)، با توجه به اجرایی شدن سامانه عملیات الکترونیکی مؤدیان مالیاتی و ایجاد پایگاه داده‌های مالیاتی، امکان پایش اطلاعات موجود با مدل‌های مختلف فراهم شده است. لذا در پژوهش یاد شده از الگوریتم بهینه‌سازی جستجوی هارمونی به منظور بهینه‌سازی همزمان پارامترهای شبکه عصبی پرسپترون چند لایه و ترکیب مناسب ورودی‌ها استفاده شده است. علاوه بر آن، نتایج رگرسیون لجستیک به عنوان هسته سیستم، مورد مقایسه قرار گرفته است.

عرب مازار و همکاران (۱۳۹۲)، با استفاده از روش مطالعات کتابخانه‌ای، ابتدا قیمت‌گذاری انتقالات از ابعاد گوناگون را تبیین و سپس مسائل مختلف مالیاتی مرتبط با آن را در ایران بررسی نموده‌اند. نتایج تحقیق صورت گرفته نشان می‌دهد هر چند در متن صریح قوانین و مقررات مالیاتی ایران، به طور مستقیم به مسأله قیمت‌گذاری انتقالات اشاره‌ای نشده است، اما با استناد به مفاد برخی از بخشنامه‌های مالیاتی و مفاهیم لحاظ شده در آن‌ها، می‌توان با اعمال اصل معاملات مستقل، تاحدودی از فرار یا اجتناب مالیاتی ناشی از آن جلوگیری کرد.

پژوهش‌های خارجی

لین و همکاران (۲۰۲۰)، مدلی اکتشافی جهت استخراج روابط تعاملی گروه‌های فرار مالیاتی مشکوک از طریق معاملات اشخاص وابسته ارائه نموده‌اند. در این مقاله، یک سامانه تجزیه و تحلیل بصری تعاملی برای کمک به کارمندان مالیاتی جهت استخراج و کاوش گروه‌های فرار مالیاتی مشکوک از طریق تجزیه و تحلیل داده‌های ناهمگن مالیاتی ارائه شد و در این راستا، یک شبکه مالیات‌دهندگان ساخته شد. این شبکه با شبکه تجاری مربوط ترکیب می‌شود تا گروه‌های فرار مالیاتی معاملات اشخاص وابسته مشکوک را شناسایی کند.

لیت و همکاران (۲۰۲۲)، تجزیه و تحلیل بصری برای شناسایی رویدادهای تقلبی مکانیزم امتیازدهی را با امکانات تجزیه و تحلیل بصری تعاملی برای انجام اعتبارسنجی تقلب ارائه نموده‌اند. تسلیخ و همکاران (۲۰۱۶)، رویکرد استخراج نمودار منتسب برای کشف تقلب در قیمت‌گذاری انتقالی را ارائه نمودند. این مقاله، رویکردی مبتنی بر گراف منتسب را به یک مشکل پیچیده داده‌کاوی در آشکارسازی این موضوع که اشخاص وابسته و مرتبط به یکدیگر ممکن است در خطر وسوسه شدن به قیمت‌گذاری انتقال تقلبی باشند را نشان می‌دهد. از این رو مفاهیم معاملات کنترل شده و گروه‌های وابسته به یکدیگر را از نظر تئوری گراف رسمیت می‌دهد. در این راستا با استفاده از روش‌های خوشه‌بندی و القای قوانین شناسایی گروه‌های نامزد (نقاط داغ) اشخاص مشکوک بررسی می‌شوند.

روثان و همکاران (۲۰۱۹)، به شناسایی گروه‌های مشکوک فرار مالیاتی مبتنی بر معاملات اشخاص وابسته در داده‌های بزرگ اقدام نمودند. در این مقاله، شبکه‌ای مرتبط با منافع گروه‌های وابسته برای مدل‌سازی گروه‌های وابسته، روابط مرتبط با منافع و ویژگی‌های آن‌ها برای شناسایی فرار مالیاتی مبتنی بر معاملات اشخاص وابسته پیشنهاد شده سپس، الگوهای رفتاری فرار مالیاتی مبتنی بر معاملات اشخاص وابسته را از طریق انتزاع الگوی توپولوژیکی از شبکه وابسته به منافع گروه‌های وابسته و استنتاج نظری از طریق ویژگی‌های تجاری ابزارهای فرار مالیاتی مبتنی بر معاملات اشخاص وابسته شناسایی نموده‌اند.

تیان و همکاران (۲۰۱۹)، گروه‌های فرار مالیاتی مشکوک در داده‌های بزرگ را استخراج نمودند. در این مقاله در ابتدا از روشی مبتنی بر گراف برای مشخص کردن ویژگی‌های آن‌ها استفاده شده است به گونه‌ای که دو مسیر مشکوک رابطه را با یک گره قبلی در پشت یک معامله با شخص مرتبط با منافع توصیف می‌کند. در مرحله بعد، مدلی مبتنی بر شبکه رنگی برای توصیف رفتارهای اقتصادی، روابط اجتماعی و معاملات مرتبط با منافع بین مالیات‌دهندگان و همچنین ایجاد شبکه‌ای تعاملی با سود مالیات‌دهندگان پیشنهاد شده است. برای تشخیص فرار مالیاتی با کشف گروه‌های مشکوک در یک شبکه تعاملی با سود مالیات‌دهندگان، روش‌هایی برای ساخت درخت الگوها و الگوهای مؤلفه‌های تطبیق، معرفی شده و کامل بودن روش‌های مبتنی بر نظریه گراف ارائه شده است. سپس، آزمایشی بر اساس داده‌های واقعی و یک شبکه شبیه‌سازی شده توصیف نموده‌اند.

گونزالس و همکاران (۲۰۱۳)، مشخصات مؤدیان مالیاتی با فاکتورهای نادرست را با استفاده

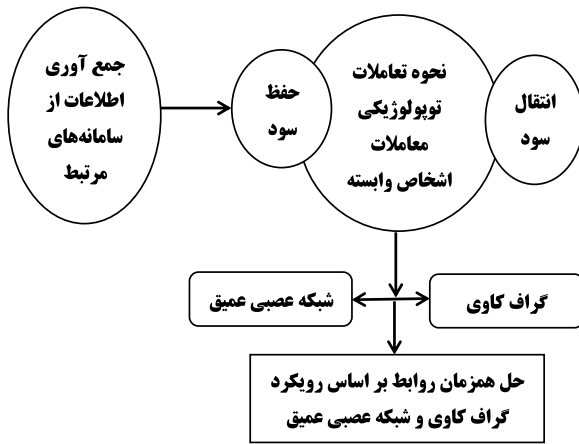
از تکنیک‌های داده کاوی تعیین نمودند. در این مقاله شواهدی ارائه شده است که با استفاده از انواع مختلف تکنیک‌های داده کاوی، می‌توان کاربران بالقوه فاکتورهای نادرست را در یک سال مشخص، بسته به اطلاعات موجود در پرداخت مالیات، عملکرد تاریخی و ویژگی‌های آن‌ها، شناسایی کرد. اول، الگوریتم‌های خوشه‌بندی و گاز عصبی برای شناسایی گروه‌هایی با رفتار مشابه در جهان مالیات‌دهندگان استفاده می‌شوند. سپس از درختان تصمیم، شبکه‌های عصبی و شبکه‌های بیزی برای شناسایی متغیرهایی که با انجام تقلب یا عدم تقلب مرتبط هستند، شناسایی الگوهای رفتار مرتبط و تعیین اینکه تا چه اندازه موارد تقلب یا نبود تقلب را می‌توان شناسایی کرد، استفاده می‌شود.

روش پژوهش

این پژوهش از نظر روش، جزو پژوهش‌های اکتشافی محسوب می‌شود. همچنین این پژوهش جنبه کاربردی در حوزه تصمیم‌گیری داشته و به منظور تجزیه و تحلیل داده‌ها و اطلاعات از روش‌های توصیفی و تحلیلی استفاده شده است. به کمک اطلاعات فعالان اقتصادی دارای معاملات با اشخاص وابسته، از طریق مراجعه به سامانه‌های اطلاعاتی و مالیاتی مرتبط با فعالان اقتصادی و بررسی وضعیت مالیاتی مؤدیان مالیاتی الزامات دقیق کشف و اکتشاف فرار مالیاتی شناسایی شد. در این پژوهش به منظور تدوین مبانی نظری از مطالعات کتابخانه‌ای و جهت جمع‌آوری داده از پایگاه‌های داده نرم‌افزاری رایج، سایت رسمی بورس اوراق بهادار تهران و بانک‌های اطلاعاتی در اختیار سازمان امور مالیاتی کشور استفاده شد. در این راستا از روش ترکیبی برای تجزیه و تحلیل داده‌ها استفاده می‌شود. در گام اول، پژوهشگر اقدام به مطالعه متون و ادبیات پژوهش از منابع مرتبط، شامل کتب، مقالات فارسی و انگلیسی و رساله‌های مرتبط با حوزه فرار مالیاتی از طریق معاملات اشخاص وابسته و رشته‌های مرتبط با موضوع نمود. در گام بعدی، داده‌های مورد نیاز و پارامترهای مؤثر در طراحی الگوی توپولوژیکی گروه‌های فرار مالیاتی مشکوک دارای معاملات با اشخاص وابسته از طریق مصاحبه‌های نیمه‌ساختاریافته با متخصصین و صاحب‌نظران حوزه مالیات و تعیین ریسک مؤدیان مالیاتی سازمان امور مالیاتی کشور و سایر حوزه‌های مرتبط جمع‌آوری شد و با استفاده از روش کیفی داده‌بنیاد سیستماتیک و با نرم‌افزارهای مرتبط، ابعاد، مؤلفه‌ها و شاخص‌های مورد نیاز جهت گراف کاوی با استفاده از تجزیه و تحلیل توپولوژیکی و سود بدست آمد.

فرآیند انجام پژوهش در نمودار (۲) نشان داده شده است:

نمودار ۲. مدل مفهومی پژوهش



منبع: یافته‌های پژوهش.

جهت محاسبه متغیرهای فرار مالیاتی اشخاص وابسته از اطلاعات زیر بهره گرفته شده

است:

جدول متغیرهای تحقیق (فعالیت‌های اقتصادی در مناطق آزاد تجاری ماده ۱۳ قانون چگونگی اداره مناطق آزاد تجاری)

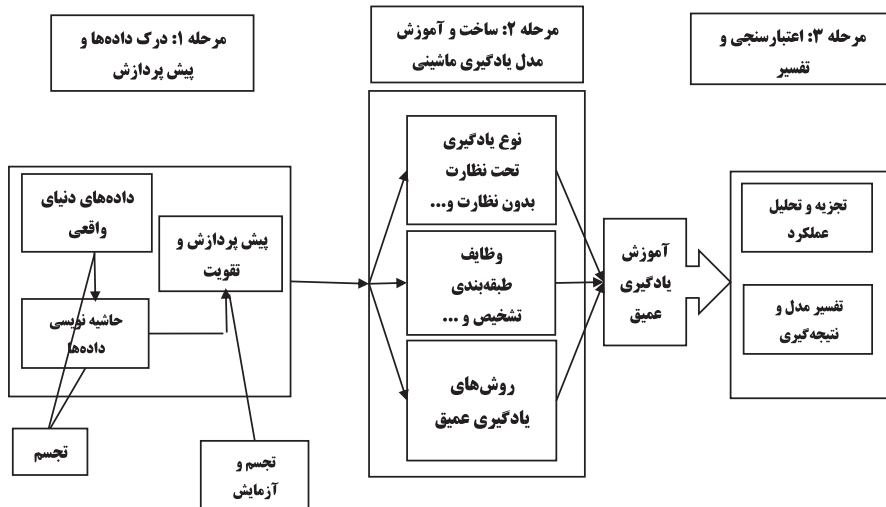
نوع استفاده در مدل	متغیر (واحد)/ میلیون ریال
لگاریتمی	خالص فروش سال جاری
لگاریتمی	بهای تمام شده کالای فروش رفته
لگاریتمی	سود و زیان عملیاتی - مانده سال جاری
لگاریتمی	سود و زیان ویژه - مانده سال جاری
لگاریتمی	مالیات متعلقه
لگاریتمی	جمع کل درآمد
لگاریتمی	هزینه‌های مستقیم
لگاریتمی	سهم از هزینه مشترک
لگاریتمی	سود (زیان) درآمد معاف
لگاریتمی	مالیات تشخیصی (سنیم)
لگاریتمی	مالیات قطعی (سنیم)

در این تحقیق از سه رویکرد یادگیری عمیق، گراف کاوی و مدل‌های متغیرهای وابسته در حالت گسسته بهره گرفته شده که در ادامه به شرح مختصری از هر یک پرداخته شده است:

الف. یادگیری عمیق

یادگیری عمیق، گونه‌ای از شبکه‌های عصبی مصنوعی است که شامل چندین لایه پردازش اطلاعات است که به الگوریتم، توانایی بیشترین همگامی را با داده‌ها می‌دهد. مهم‌ترین مزیت الگوریتم‌های یادگیری عمیق نسبت به روش سنتی شبکه عصبی، استخراج خودکار ویژگی‌های مناسب از ورودی‌های خام است که از آن برای روند یادگیری الگو استفاده می‌شود. مطالعات انجام شده در حوزه پیش‌بینی سری‌های زمانی مالی که در آن‌ها از الگوریتم‌های یادگیری عمیق استفاده شده است، بر اساس نوع خروجی مورد انتظار اغلب به دو دسته اصلی تقسیم می‌شود که یکی پژوهش‌هایی است که با هدف پیش‌بینی بازار (Chong et al., 2017; Chen et al., 2015) و دیگری با هدف پیش‌بینی روند قیمت (صعودی، نزولی یا خنثی) انجام شده است (Zhou et al., 2019). یادگیری عمیق اقدام به اجرای فعالیت‌هایی می‌نماید که انسان‌ها می‌توانند به طور مؤثرتری انجام دهند (Taye, 2023). یادگیری ماشینی با توسعه الگوریتم به عنوان نرم‌افزاری می‌باشد که می‌تواند الگوها، ویژگی‌ها یا روابط پنهان را از مجموعه داده‌ها یاد بگیرد و استخراج کند (Al-Hagery, 2019). مراحل اجرای یادگیری ماشینی در نمودار (۳) نشان داده شده است:

نمودار ۳. مراحل اجرای یادگیری ماشینی

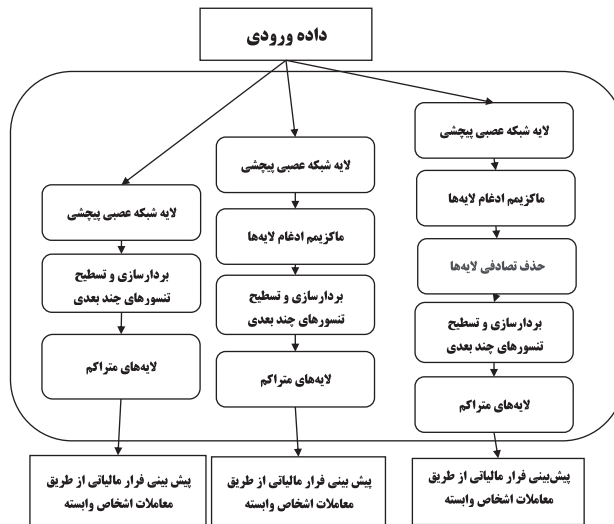


منبع: یافته‌های پژوهش.

در پژوهش‌های مرتبط با هدف پیش‌بینی قیمت، از روش‌های متنوعی در حوزه یادگیری عمیق استفاده شده است که از آن جمله می‌توان به الگوریتم شبکه عصبی مکرر یا بازگشتی (LSTM)^۱ (Li and Dai, 2020; Lee and Yoo, 2020) حافظه کوتاه‌مدت ماندگار (RNN) حافظه کوتاه‌مدت ماندگار (LSTM)^۲ و شبکه عصبی پیچشی (CNN)^۳ اشاره کرد که در این میان پژوهشگران به الگوریتم‌های حافظه کوتاه‌مدت ماندگار و شبکه عصبی پیچشی به دلیل دارا بودن برخی ویژگی‌ها بیشتر از بقیه روش‌ها توجه کرده‌اند.

برخی از پژوهشگران با استفاده از الگوریتم‌های شبکه عصبی پیچشی، حافظه کوتاه‌مدت ماندگار و پرسپترون‌های چند لایه^۴ MLP، داده‌های تاریخی قیمت پایانی شاخص S&P500 را بررسی کرده‌اند که نتایج، حکایت از عملکرد بهتر الگوریتم شبکه عصبی پیچشی داشته است (Livieris et al., 2020; Li and Dai, 2020; Gao, 2020; Gudelek, 2017; Ji et al., 2019). بررسی پژوهش‌های مرتبط با پیش‌بینی قیمت با استفاده از روش شبکه عصبی پیچشی نشان‌دهنده آن است که به طور معمول از سه معماری (لایه‌چینی) در نمودار (۴) استفاده شده که در این پژوهش، هر سه معماری مورد بررسی قرار خواهد گرفت.

نمودار ۴. فرآیند انتخاب معماری بهینه شبکه عصبی پیچشی



منبع: یافته‌های پژوهش.

1. Recurrent Neural Networks
2. Long-Short-Term-Memory Neural Network
3. Convolutional-Neural-Network
4. Multilayer Perceptrons

برای انتخاب معماری بهینه شبکه عصبی پیچشی نیاز است که هر سه روش استفاده شده با پارامترهای مختلف بررسی شوند. شایان ذکر است پارامترهای اثرگذار در ساخت معماری بهینه شبکه عصبی پیچشی شامل مواردی نظیر تعداد فیلترها^۱ در لایه شبکه عصبی پیچشی، اندازه دسته^۲ و تابع فعال‌سازی^۳ است.

برای مثال، تعداد کم فیلترها باعث ایجاد خطای بیشتر می‌شود و شبکه نیز هم‌گرا نمی‌گردد. از طرفی، تعداد فیلترهای زیاد به دلیل ایجاد بیش‌برازش منجر به خطای بالا می‌شود. از این رو، موارد مذکور با توجه به خروجی اخذ شده بهینه‌سازی شده است. انتخاب پارامترهای مختلف در جدول (۱)، بر اساس نتایج مطالعات انجام شده در این حوزه است (Livieris et al., 2020; Livieris et al., 2021; Gudelek, 2017).

جدول ۱. پارامترهای مختلف مورد استفاده در اجرای الگو

پارامتر	مقادیر
تعداد فیلتر	۲۵۶، ۱۲۸، ۶۴
اندازه دسته	۱۲۸، ۶۴، ۳۲
optimizer	Adam
Loss	Mean Square Error
توابع فعال‌سازی	رابطه ریاضی
تابع یکسوساز (ReLU)	$g(Z) = \max(0, Z)$
تانژانت هیپربولیک (Tanh)	$g(Z) = \frac{e^Z - e^{-Z}}{e^Z + e^{-Z}}$

منبع: یافته‌های پژوهش.

برای اجرای الگوریتم، داده‌ها به دو بخش آموزش (۸۰ درصد)، برای ساخت الگو و آزمایش (۲۰ درصد)، برای آزمون تقسیم شده است. برای بهتر شدن فرآیند یادگیری، مرحله آموزش به تعداد ۱۰۰۰ مرتبه تکرار^۴ شده است. علاوه بر این، باید توجه داشت که تفاوت مقیاس‌ها در متغیرهای مختلف، نتایج را تحت تأثیر قرار می‌دهد و به طور معمول برای از بین بردن تأثیر نامطلوب مذکور، نیاز به نرمال‌سازی داده می‌باشد که در این پژوهش برای نرمال‌سازی از روش


1. Filters
2. Batch Size
3. Activation Function
4. Epochs

کمینه - بیشینه^۱ جهت تبدیل داده‌ها به مجموعه جدیدی استفاده شده است که در آن همه مقادیر بین ۰ و ۱ است.

ب. گراف کاوی

در ترمینولوژی ریاضیاتی، نظریه گراف، مطالعه گراف‌ها است که روابط جفتی بین اجزای یک مجموعه با برخی ساختارهای ریاضیاتی مدل‌سازی شده است. یک گراف ساده را با $G = (V, E)$ نشان می‌دهیم که در آن V ، رأس‌ها^۲ یا گره‌ها^۳ و E مجموعه‌ای از یال‌ها^۴ است. یک گراف از یال‌هایی شکل گرفته که گره‌ها را به هم متصل کرده است. می‌گوییم که دو گره متصل^۵ هستند اگر که یک یال مشترک داشته باشند. ویژگی‌های اتصال‌های یک گراف را با استفاده از ماتریس مجاورت^۶ A توصیف می‌کنیم. ماتریس مجاورت، ماتریسی $n \times n$ است که n در آن تعداد گره‌ها در گراف است. اگر یک جفت از گره‌ها با یک یال متصل باشند به آن‌ها مجاور می‌گوییم و درایه سطر i و ستون j ماتریس مجاورت گراف که با a_{ij} نشان می‌دهیم به ازای آن مقدار ۱ می‌گیرد و در غیر این صورت، مقدار صفر. اگر ماتریس مجاورت متقارن باشد یعنی $a_{ij} = a_{ji}$ ، آن‌گاه نشان‌دهنده یک گراف بی‌جهت^۷ است. در نمودار (۵)، یک گراف ساده شامل (۴ گره و سه یال) و ماتریس مجاورت آن که متقارن بوده نمایش داده شده است.

نمودار ۵. یک گراف بی‌جهت و ماتریس مجاورت آن



$$A_G = \begin{pmatrix} 0 & 1 & 0 & 1 \\ 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 \\ 1 & 0 & 1 & 0 \end{pmatrix}$$

منبع: یافته‌های پژوهش.

1. Min-Max Normalization
2. Vertex
3. Node
4. Edge
5. Connected
6. Adjacency Matrix
7. Undirected Graph

اصطلاح اپیدمی به پدیده‌ای گفته می‌شود که بیش از آنچه انتظار می‌رود، شیوع دارد. این اصطلاح بیشتر در زمینه بیماری‌ها و انتشار آن‌ها در کل جمعیت استفاده می‌شود - مانند مالاریا، کرونا، طاعون و ایدز - اما بعضی مواقع به طور گسترده در زمینه‌های دیگر از جمله توصیف شیوع مسائلی در یک سیستم یا بازار نیز مورد استفاده قرار می‌گیرد. یکی از کلاس‌های پرکاربرد مدل‌های اپیدمیک، مدل‌های به اصطلاح مستعد-مبتلا-حذف شده^۱ یا SIR هستند. فرض کنیم یک جمعیت دارای $N+1$ عضو در هر نقطه از زمان است (شرکت‌های بورسی) و یک تعداد تصادفی، بگوئیم $NS(t)$ ، از اعضای جامعه مستعد مبتلا هستند (مبادلات وابسته)، تعداد تصادفی $NI(t)$ عضو مبتلا هستند و $NR(t)$ عضو در هر نقطه از زمان از مبتلا بهبود یافته‌اند (مبادلات مستقل) و دوباره مبتلا نمی‌شوند (در نتیجه از فرآیند بررسی حذف می‌شوند). فرض کنیم یک عضو مبتلا و N عضو مستعد داریم، یعنی $NI(0) = 1$ و $NS(0) = N$ و بگذاریم s و i تعداد مستعدین مبتلا و تعداد مبتلایان را نشان دهد. در مدل SIR تعداد مستعدین، مبتلایان و حذف شده‌ها، مطابق احتمالات انتقال آنی ذیل تغییر می‌یابند (Kolaczyk, 2014):

$$P(NS(t + \delta t) = s - 1, NI(t + \delta t) = i + 1 | NS(t) = s, NI(t) = i) \approx \beta si \delta t$$

$$P(NS(t + \delta t) = s, NI(t + \delta t) = i - 1 | NS(t) = s, NI(t) = i) \approx \gamma i \delta t$$

$$P(NS(t + \delta t) = s, NI(t + \delta t) = i - 1 | NS(t) = s, NI(t) = i) \approx (1 - (\beta s + \gamma)) i \delta t$$

که در آن δt اشاره به مقداری بی‌نهایت کوچک داشته و $NR(t)$ با توجه به قید $NS(t) = N + NI(t) + NR(t)$ بدست می‌آید. مدل فوق بیان می‌کند که در هر زمان t ، یک مبتلای جدید از میان مستعدین اتفاق می‌افتد (به دلیل تماس با یکی از مبتلایان) و احتمال آنی آن نسبتی است از حاصل ضرب تعداد مستعدین s و تعداد مبتلایان i . به طور مشابه مبتلایان با نسبتی از احتمال آنی i ریکاوری می‌شوند. این احتمالات با پارامترهای β و γ مقیاس دهی شده است که نرخ ابتدا و نرخ ریکاوری را نشان می‌دهند. همچنین پارامترهای β و γ پارامتر نرخ در توزیع نمایی^۲ هستند. مدل بیان می‌کند که با تعداد s مستعد و i مبتلای مفروض در دوره t ، فرآیند در حالت (s, i) برای یک زمان مشخص که به صورت متغیر تصادفی نمایی توزیع شده، با نرخ βs i ($+$) باقی می‌ماند. آنگاه یک انتقال به حالت $(s - 1, i + 1)$ با احتمال $\beta s i / (\beta s + \gamma)$ ، یا انتقال به حالت $(s, i - 1)$ با احتمال $\gamma i / (\beta s + \gamma)$ اتفاق می‌دهد. مدل‌سازی اپیدمیک موضوع

1. Susceptible-Infected-Removed

2. Rate Parameter of an Exponential Distribution

مورد علاقه محققانی است که بر روی مدل‌های فرآیند پویایی مبتنی بر شبکه کار می‌کنند. G را یک گراف شبکه در نظر می‌گیریم که توصیف‌کننده ساختار ارتباط بین N_V عضو شبکه است. فرض کنیم در زمان $t=0$ یک عضو (گره) درگیر شود (مثلاً در بازار سهام یک صنعت یا یک نماد دچار بحران شود). گره درگیر برای یک زمان مشخص که توزیع نمایی با نرخ گاما دارد درگیر است و پس از آن بهبود می‌یابد. در زمان درگیری، عضو با دیگر اعضای شبکه با توزیعی نمایی با نرخ بتا ارتباط دارد که نتیجه‌اش سرایت پدیده به دیگر اعضای شبکه می‌شود. تعریف می‌کنیم 1 و 2 و $X_i(t) = 0$ که طبق آن یک گره مستعد، درگیر شده است یا در زمان t بهبود یافته است. همچنین فرض کنیم $X(t) = (X_i(t))_{i \in V}$ فرآیند زمانی نتیجه شده برای گراف شبکه G باشد. با x حالت فرآیند را در زمان مشخص t نشان می‌دهیم. هر تغییر از x به x' در برگیرنده یک تغییر در یک و تنها یک عضو در یک زمان است و نیز فرض کنیم که x و x' در عضو i متفاوت باشد. آنگاه می‌توان نشان داد که فرآیند مدل با رابطه ذیل قابل توصیف است:

$$P(X(t + \delta t) = x' | X(t) = x) \approx \begin{cases} \beta M_i(x) \delta t & \text{if } x_i = 0 \text{ and } \dot{x}_i = 1 \\ \gamma \delta t & \text{if } x_i = 1 \text{ and } \dot{x}_i = 2 \\ 1 - [\beta M_i(x) + \gamma] \delta t & \text{if } x_i = 2 \text{ and } \dot{x}_i = 2 \end{cases}$$

که در آن $M_i(x)$ تعداد همسایگان عضو i است که در زمان t درگیر شده‌اند، $NS(t)$ اعضای شبکه مستعد درگیر شدن هستند، $NI(t)$ اعضای که درگیر شده‌اند و $NR(t)$ اعضای هستند که بهبود یافته یا مصون بوده‌اند. خصوصیات فرآیندهای $NS(t)$ و $NI(t)$ و $NR(t)$ تحت تأثیر خصوصیات و توپولوژی گراف شبکه G خواهد بود که از طریق شبیه‌سازی می‌توان به آن پی برد و دریافت که پویایی‌های سرایت در شبکه چگونه می‌شود.

ج- الگوی مدل‌های متغیرهای وابسته گسسته

- الگوی لاجیت

الگوی لاجیت، ابتدا با عنوان الگوهای لاجیت دوگانه که برای محاسبه میزان احتمال انتخاب بین دو گزینه به کار برده می‌شدند، معرفی شد. سپس این الگوها به صورت عمومی در آمدند و برای محاسبه میزان احتمال انتخاب از میان دو گزینه یا بیشتر مورد استفاده قرار گرفتند که به عنوان الگوهای لاجیت چندگانه یا چندجمله‌ای معروف شدند (Long et al., 2006). این

الگوها زمانی مورد استفاده قرار می‌گیرند که متغیر وابسته به صورت اسمی باشد (مجموعه‌ای از طبقه‌ها که نمی‌توان آن‌ها را به صورت معنادار رتبه‌بندی کرد). به عبارت دیگر، الگوی لاجیت چند جمله‌ای به منظور آزمون کلیه ترکیب‌ها بین J گروه در متغیر وابسته به کار برده می‌شود. این به مفهوم شبیه‌سازی $J-1$ الگوی لاجیت دوگانه است. ساختار کلی الگوی لاجیت چندگانه به صورت زیر است (Heij, 2004):

$$pr(Y_i = j) = \frac{\exp(X_i B_j)}{1 + \sum_{j=1}^J \exp(X_i B_j)} \quad j = 1, \dots, J \quad (1)$$

$$pr(Y_i = 1) = \frac{1}{1 + \sum_{j=1}^J \exp(X_i B_j)} \quad j = 1, \dots, J \quad (2)$$

Y_i متغیر وابسته مشاهده شده برای عضو i ام، X_i بردار متغیرهای پارامترهای مجهول مستقل برای عضو i ام و B_j معادله است. در صورتی که $J = 2$ باشد، لاجیت چند جمله‌ای به لاجیت دوگانه تبدیل می‌شود. در الگوی لاجیت چندگانه به منظور بررسی اثرگذاری متغیرهای مستقل بر متغیر وابسته از دو آزمون حداکثر درست‌نمایی و آزمون والد به طور جداگانه برای هر یک از متغیرهای مستقل الگو استفاده می‌شود (Maddala, 1983)، فرآیند تخمین -Likelihood Max-imum دو مرحله است: ابتدا تابع چگالی پیوسته نمونه را بدست می‌آوریم که تابع-Likelihood نامیده می‌شود. سپس مقادیر پارامتری که تابع-Likelihood را حداکثر می‌کنند، بدست می‌آوریم. برای نمونه‌ای با T فرد و J جایگزین تابع-Likelihood Maximum به صورت زیر است:

$$L(\beta) = \prod_{\forall t \in T} \prod_{\forall j \in J} (P_{jt}(\beta))^{\delta_{jt}} \quad (3)$$

شاخص δ_{jt} برابر یک می‌شود هنگامی که فرد t جایگزین j انتخاب کند و در غیر این صورت صفر است. P_{jt} : احتمال انتخاب جایگزین j توسط فرد t است. مقادیر پارامتری که تابع-Likelihood را ماکزیمم می‌کند از مشتق اول تابع-Likelihood و برابر قرار داده با صفر بدست می‌آید. چون لگاریتم تابع، ماکزیمم یکسانی از تابع می‌دهد و نسبت به مشتق آسان‌تر است، تابع-Likelihood - Log به جای خود تابع حداکثر می‌گردد:

$$LL(\beta) = \log(L(\beta)) = \sum_{\forall t \in T} \sum_{\forall j \in J} \delta_{jt} * \ln(P_{jt}(\beta)) \quad (4)$$

در راستای ارزیابی آزمون حداکثر درست‌نمایی، بر فرض مثال برای متغیر X_i فرض اساس

الگو)، دو جفت الگو مورد بررسی قرار می‌گیرد: الگوی نهایی (شامل کلیه متغیرهای مستقل) و الگوی تقلیل یافته یا الگوی صرفاً با عرض از مبدأ (شامل کلیه متغیرهای مستقل به جز متغیر مورد بررسی). آماره این آزمون (χ^2) از رابطه زیر محاسبه می‌شود:

$$\chi^2 = 2[LL(\cdot) - LL(\beta)] \quad (5)$$

که در آن $LL(\cdot)$ لگاریتم درستنمایی الگوی تقلیل یافته و $LL(\beta)$ لگاریتم درستنمایی الگوی نهایی که از روابط زیر حساب می‌شوند:

$$LL(\beta) = \sum_{j=1}^n \sum_{j=0}^J d_{ij} \ln \text{prob} Y_i = j \quad (6)$$

$$LL(\beta) = \sum_{j=0}^J n_j \ln \left(\frac{n_j}{n} \right) \quad (7)$$

در این روابط n اندازه نمونه، n_j اندازه نمونه در طبقه j ام و $d_{ij} = 1$ اگر مشاهده i ام در طبقه j قرار بگیرد، در غیر این صورت $d_{ij} = 0$ است. اگر آماره χ^2 در سطح اطمینان مورد نظر معنادار باشد به معنی وجود تفاوت معنادار بین الگوی نهایی و الگوی تقلیل یافته است که نشان‌دهنده اهمیت وجود متغیر X_i در الگو است. به عبارت دیگر، این متغیر دارای تأثیر معناداری بر متغیر وابسته است. از طرف دیگر، آماره والد عملی مشابه به این آماره را انجام می‌دهد. این آماره از توان دوم نسبت ضریب متغیر مستقل به انحراف معیار آن محاسبه می‌شود:

$$W_j = \left(\frac{\beta_j}{SE_{\beta_j}} \right)^2 \quad (8)$$

آماره والد نیز همانند آزمون حداکثر درستنمایی، به این فرض که آیا متغیر مستقل به طور معناداری در طبقه‌ها متغیر وابسته متفاوت است یا خیر می‌پردازد. آماره والد تنها در نمونه‌های بزرگ نتایج مناسبی ارائه می‌کند و در نمونه‌های کوچک بسیار حساس است. در حالی که آزمون حداکثر درستنمایی در نمونه‌های کوچک نیز بسیار دقیق و معتبر است و به همین دلیل در مطالعه‌های مختلف به آزمون والد ترجیح داده می‌شود. به منظور بررسی خوبی برازش مدل لاجیت چندگانه، آزمون‌ها و معیارهای متعددی وجود دارد. از جمله این معیارها، آماره‌های R^2 کاذب است (Hensher et al., 2003). از دیگر آزمون‌ها جهت بررسی خوبی برازش الگو می‌توان به آزمون‌های پیرسون و دویانس اشاره کرد. این معیارها به صورت زیر محاسبه می‌شوند:

$$\chi^2 = \sum \sum \left(\frac{o_{ij} - E_{ij}}{E_{ij}} \right)^2 \quad \text{معیار پیرسون} \quad (9)$$

$$D = 2 \sum \sum o_{ij} \ln \left(\frac{o_{ij}}{E_{ij}} \right) \quad \text{معیار دوینانس} \quad (10)$$

O_{ij} تعداد نمونه مشاهده شده در جایگزین زام و E_{ij} تعداد نمونه مورد انتظار در جایگزین زام است.

- الگوی پرابیت

معادله پروبیت به شکل زیر است:

$$y_t^* = \alpha_t + X_t \beta + \varepsilon_t \quad y_t = \begin{cases} 1 & \text{if } y_t^* > 0 \\ 0 & \text{if } y_t^* \leq 0 \end{cases} \quad (11)$$

y_t^* متغیر وابسته در گونه‌ای از این مدل‌ها دو ارزشی برداری بوده و مقدار صفر و یک می‌باشد. برداری از متغیرهای توضیحی است، اما پارامترهای ساختاری برآورد شده در معادله پروبیت، حساسیت احتمال بحران و آرامش را به تغییر نهایی در هر متغیر توضیحی نشان نمی‌دهند. به این منظور بایستی اثرات نهایی یا کشش را محاسبه نمود.


$$e(X_i) = \frac{\partial}{\partial X_i} F(X_i \beta) \beta \quad y_t = \begin{cases} 1 & \text{if } y_t^* > 0 \\ 0 & \text{if } y_t^* \leq 0 \end{cases} \quad (12)$$

X_i متغیر توضیحی نام و f مشتق تابع چگالی تجمعی است (Cameron and Trivedi, 2005).

- مدل احتمال خطی

ساده‌ترین رویکرد محاسبات داده‌هایی که متغیر وابسته آن گسسته است، رویکرد احتمال خطی است که به صورت یک تابع ضابطه دو جمله‌ای تعریف می‌گردد. تفاوت این رویکردها در نمودار زیر ترسیم شده است. همان‌گونه که در نمودار (۲) نمایش داده شده است، تفاوت این توابع در فرض این واقعیت است که پارامترهای برآوردی از چه نوع توزیعی تبعیت می‌نمایند.

نمودار ۶. تفاوت مدل‌های لاجیت، پرابیت و احتمال خطی



منبع: یافته‌های پژوهش.


برآورد مدل و تحلیل نتایج

قبل از برآورد مدل لازم است که به این واقعیت پرداخته شود که برخی از معاملات مشکوک فرار مالیاتی از طریق اشخاص وابسته در دو حالت صورت می‌پذیرد.

حالت اول: حفظ سود

فروش محصولات از شرکتی دارای نرخ مالیاتی پایین به شخص وابسته دارای نرخ مالیات بالا با قیمتی بیشتر از سطح بازار. فرآیند توپولوژیک این حالت به صورت نمودار (۷) می‌باشد.

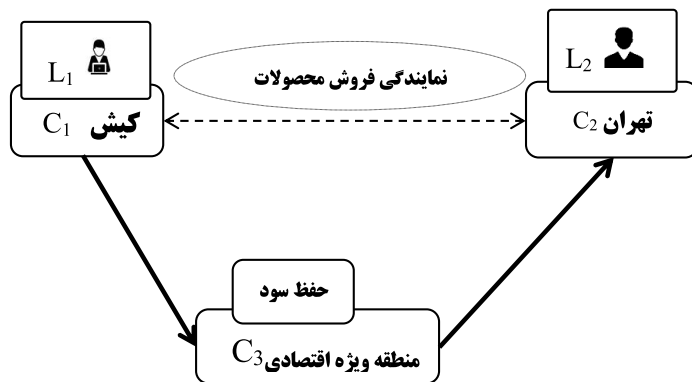
نمودار ۷. فرآیند توپولوژیک حفظ سود



منبع: یافته‌های پژوهش.

مسیرهای استاتیک این حالت $L_2 \rightarrow C_2$ و $L_1 \rightarrow C_3$ و $L_1 \rightarrow C_1$ تبعیت می‌نمایند. نمونه توپولوژیک این حالت در نمودار (۸) ترسیم شده است.

نمودار ۸. نمونه فرآیند توپولوژیک حفظ سود



منبع: یافته‌های پژوهش.


همان‌طور که در نمودار بالا نشان داده شده است، شرکت C3 در منطقه ویژه اقتصادی تولیدکننده قطعه بوده و از نرخ صفر مالیاتی با رعایت شرایط برخوردار بوده است. ۸۰ درصد از سهام C3 در منطقه ویژه اقتصادی در اختیار شرکت C1 بوده و مواد اولیه اصلی را برای C3 فراهم می‌کرده است. تمام محصولات C3 به شرکتی به نام C2 فروخته شد و نرخ مالیات C2 برابر با ۲۵ درصد بود. علاوه بر این، اعضای هیأت مدیره دو شرکت C1 و C2 یکسان می‌باشند (L1 و L2). بررسی‌های مالیاتی تأیید کردند که:

۱. یک رابطه پنهانی (هیأت مدیره مشترک) در دو شرکت وجود دارد؛ به این معنی که آن‌ها گروه‌های وابسته یکدیگر بودند.
۲. فروش کالا توسط شرکت C3 به C2 بیشتر از قیمت بازار بود.
۳. نرخ بار مالیاتی C3 بالاتر از نرخ شرکت‌های با موقعیت مشابه و C2 کمتر از نرخ شرکت‌های با موقعیت مشابه بود. سپس مشاهده شد که کنترل‌کننده غیرمستقیم (L1) C3 و کنترل‌کننده مستقیم (L2) C2 توافق کردند که با قیمتی فراتر از قیمت بازار معامله کنند، به طوری که سود با نرخ مالیات پایین از طریق شرکت، یعنی C3 (که از آن به عنوان حافظ سود یاد می‌شود) حفظ شود. بنابراین، معامله وابسته بین C3 و C2 منجر به کاهش مالیات بر درآمد کلی شرکت شد. از این استراتژی فرار مالیاتی به عنوان استراتژی حفظ سود یاد می‌شود.

حالت دوم: انتقال سود

فروش محصولات از شرکتی با نرخ مالیاتی بالا به شخص وابسته با نرخ مالیاتی پایین و قیمتی پایین تر از سطح بازار. فرآیند توپولوژیک در این حالت به صورت زیر می باشد.

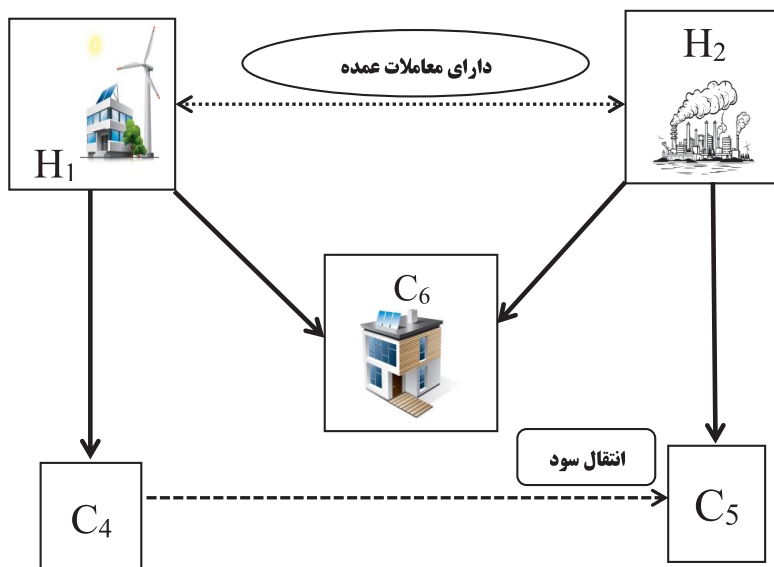
نمودار ۹. فرآیند توپولوژیک انتقال سود



منبع: یافته‌های پژوهش.

مسیرهای استاتیک این حالت $H_2 \rightarrow H_1 \rightarrow C_4$ ، $C_4 \rightarrow C_5$ و $H_1 \rightarrow H_2 \rightarrow C_5$ تبعیت می نماید. نمونه توپولوژیک در نمودار زیر ترسیم شده است.

نمودار ۱۰. نمونه فرآیند توپولوژیک انتقال سود



منبع: یافته‌های پژوهش.

همان‌طور که در شکل بالا نشان داده شده است، یک شرکت تولیدکننده محصولات آرایشی به نام C4 دارای نرخ مالیاتی ۲۵ درصد، محصولات دارای قیمت بالای خود را به یک شرکت فروشنده محصولات آرایشی واقع در منطقه آزاد تجاری به نام C5 و با نرخ صفر مالیاتی، تقریباً به قیمت تمام شده یعنی ۳۷ درصد کمتر از بازار فروخت. H1 و H2 به عنوان سهامداران عمده شرکت‌های C4 و C5 سهام‌دار عمده شرکت C6 نیز بوده و کنترل آن را در دست دارند. بررسی‌های مالیاتی تأیید کردند که:


۱. یک رابطه پنهان بین C4 و C5 وجود دارد، به این معنی که آن‌ها گروه‌های وابسته یکدیگر بودند.

۲. فروش کالا توسط C4 به C5 کمتر از قیمت بازار بود.

۳. نرخ بار مالیاتی C4 کمتر از نرخ شرکت‌های با موقعیت مشابه و در خصوص C5 بالاتر از نرخ شرکت‌های با موقعیت مشابه بود. سپس مشاهده شد که سهام‌دار C4 یعنی H1 با سهام‌دار C5 یعنی H2 برای معامله با قیمتی بسیار کمتر از قیمت بازار داخلی توافق کرد تا سود به شرکت با نرخ پایین، یعنی C5 منتقل شود؛ بنابراین، معامله وابسته بین C4 و C5 منجر به کاهش نرخ بار مالیاتی شد. از این استراتژی فرار مالیاتی به عنوان استراتژی انتقال سود یاد می‌شود.

در ادامه لازم است معماری شبکه عصبی پیچشی تعیین شود. برای انتخاب معماری بهینه شبکه عصبی پیچشی، هر سه معماری معرفی شده با پارامترهای مختلف اجرا شده است. در نهایت بهترین نتایج حاصل از هر معماری مقایسه شده است. بنابراین معماری منتخب، حاصل از اجرای الگوریتم به تعداد ۶۴ دفعه با لایه‌ها و پارامترهای متفاوت است. در مرحله اول، روش شبکه عصبی پیچشی با معماری لایه‌های ذیل اجرا شده است (معماری اول شبکه عصبی پیچشی).

نمودار ۱۱. معماری اول شبکه عصبی پیچشی



منبع: یافته‌های پژوهش.

در جداول (۲) و (۳)، خطاهای میانگین قدر مطلق درصد خطا (MAPE)^۱ و مجذور میانگین مربعات خطای نرمال (NRMSE)^۲ در اجرای الگو به تعداد ۱۸ دفعه با استفاده از جایگشت‌های مختلف تعداد فیلتر، اندازه دسته و استفاده از دو تابع فعال‌سازی یکسوساز و تابع تانژانت هیپربولیک آورده شده است.

جدول ۲. خطای اجرای معماری شبکه عصبی پیچشی به تفکیک پارامترهای مختلف با تابع فعال‌سازی یکسوساز

تابع فعال‌سازی ReLU	نوع خطا	تعداد فیلتر		
		۶۴	۱۲۸	۲۵۶
۳۲	MAPE	۲.۷۵	۲.۷۶	۱۰.۸۸
	NRMSE	۳.۷۷	۳.۶۲	۱۱.۳۰
اندازه دسته ۶۴	MAPE	۴.۳۲	۲.۲۴	۳.۵۴
	NRMSE	۵.۶۹	۳.۱۹	۴.۶۰
۱۲۸	MAPE	۳.۶۳	۲.۳۲	۲.۹۳
	NRMSE	۴.۵۴	۳.۲۸	۳.۷۶

منبع: یافته‌های پژوهش.

جدول ۳. خطای اجرای معماری اول شبکه عصبی پیچشی به تفکیک پارامترهای مختلف

با تابع فعال‌سازی تانژانت هیپربولیک

تابع فعال‌سازی تانژانت هیپربولیک	نوع خطا	تعداد فیلتر		
		۶۴	۱۲۸	۲۵۶
۳۲	MAPE	۲.۳۹	۲.۴۰	۹.۴۷
	NRMSE	۳.۲۸	۳.۱۵	۹.۸۳
اندازه دسته ۶۴	MAPE	۳.۷۶	۲.۰۲	۱.۹۴
	NRMSE	۴.۹۵	۲.۸۵	۲.۷۸
۱۲۸	MAPE	۳.۱۶	۳.۰۸	۲.۵۵
	NRMSE	۳.۹۵	۴.۰۰	۳.۲۷


منبع: یافته‌های پژوهش.

نتایج بدست آمده از اجرای معماری اول حاکی از آن است که ترکیب پارامترها با تعداد فیلتر ۲۵۶، اندازه دسته ۶۴ و با تابع فعال‌سازی تانژانت هیپربولیک بهترین دقت پیش‌بینی را دارد. در مرحله دوم، روش شبکه عصبی پیچشی با معماری لایه‌های ذیل اجرا شده است (معماری دوم شبکه عصبی پیچشی با لحاظ لایه ادغام بیشینه).

1. Mean Absolute Percentage Error

2. Normalized Root Mean Square Error


نمودار ۱۲. معماری دوم شبکه عصبی پیچشی



منبع: یافته‌های پژوهش.

قرار دادن یک لایه ادغام بین چندین لایه پیچشی پشت سر هم در یک معماری شبکه عصبی پیچشی امری رایج است. کارکرد این لایه کاهش تعداد پارامترها و محاسبات در داخل شبکه و کنترل بیش برآزش^۱ است. لایه ادغام به صورت مستقل بر هر برش عمقی از توده ورودی عمل می‌کند و آن را با استفاده از عملیات بیشینه^۲ از لحاظ مکانی تغییر اندازه^۳ می‌دهد. رایج‌ترین نحوه استفاده از این لایه به صورت استفاده آن با فیلترهایی با اندازه 1×3 به همراه گام^۴ ۳ است که همانند نمودار (۱)، عملیات بیشینه در این قسمت، بزرگ‌ترین عدد بین سه عدد (یک ناحیه 1×3 در برش عمقی)، را انتخاب می‌کند و باعث حذف ۶۷ درصد مقادیر موجود در آن برش عمقی می‌شود. گفتنی است بُعد عمق، بدون تغییر باقی می‌ماند.

نمودار ۱۳. عملکرد لایه ادغام بیشینه



منبع: یافته‌های پژوهش.

نتایج اجرای الگوریتم شبکه عصبی پیچشی با لحاظ کردن لایه ادغام بیشینه به شرح جداول (۴) و (۵) است.

1. Over Fitting
2. Max
3. Resize
4. Stride

جدول ۴. خطای اجرای معماری دوم شبکه عصبی پیچشی به تفکیک پارامترهای مختلف با تابع فعال‌سازی یکسوساز

تابع فعال‌سازی ReLU	نوع خطا	تعداد فیلتر		
		۶۴	۱۲۸	۲۵۶
۳۲	MAPE	۲.۱۸	۲.۱۹	۸.۶۲
	NRMSE	۲.۹۹	۲.۸۷	۸.۹۴
اندازه دسته ۶۴	MAPE	۳.۴۲	۱.۸۴	۱.۷۷
	NRMSE	۴.۵۰	۲.۵۹	۲.۵۳
۱۲۸	MAPE	۲.۸۸	۲.۸۰	۲.۳۲
	NRMSE	۳.۵۹	۳.۶۴	۲.۹۸

منبع: یافته‌های پژوهش.

جدول ۵. خطای اجرای معماری دوم شبکه عصبی پیچشی به تفکیک پارامترهای مختلف با تابع


فعال‌سازی تانژانت هیپربولیک

تابع فعال‌سازی تانژانت هیپربولیک	نوع خطا	تعداد فیلتر		
		۶۴	۱۲۸	۲۵۶
۳۲	MAPE	۲.۳۰	۲.۳۱	۹.۰۹
	NRMSE	۳.۱۵	۳.۰۳	۹.۴۴
اندازه دسته ۶۴	MAPE	۳.۶۱	۱.۹۴	۲.۹۶
	NRMSE	۴.۷۵	۲.۷۴	۳.۸۴
۱۲۸	MAPE	۳.۰۴	۱.۸۷	۲.۴۴
	NRMSE	۳.۷۹	۲.۶۷	۳.۱۴

منبع: یافته‌های پژوهش.

نتایج بدست آمده از اجرای معماری دوم نشان‌دهنده آن است که ترکیب پارامترها با اندازه دسته ۶۴، تعداد فیلتر ۲۵۶ و با تابع فعال‌سازی یکسوساز بهترین دقت پیش‌بینی را دارد. همان‌گونه که مشخص است خطای بدست آمده با پارامترهای مذکور از نتایج منتخب معماری اول نیز به مراتب بهتر است. در مرحله سوم، روش شبکه عصبی پیچشی با معماری لایه‌های ذیل اجرا شده است (معماری سوم شبکه عصبی پیچشی با لحاظ لایه ادغام بیشینه و حذف تصادفی).


نمودار ۱۴. معماری سوم شبکه عصبی پیچشی



منبع: یافته‌های پژوهش.

از معایب مربوط به شبکه‌های عصبی عمیق، مشکل بیش‌برازش و زمان محاسباتی بالا است. شبکه‌های عصبی عمیق در معرض بیش‌برازش هستند، چون تعداد لایه‌های اضافه شده این امکان را ایجاد می‌کند که وابستگی‌های نایاب در داده‌های آموزشی حساب شود. با استفاده از روش حذف تصادفی می‌توان به از بین بردن بیش‌برازش کمک کرد. در این شیوه، درصد مشخصی از واحدها به صورت تصادفی از لایه‌های مخفی حذف می‌شود. این کار، به از بین بردن وابستگی‌های نادر در داده‌های آموزشی کمک می‌کند (Pourzaker et al., 2018). در نمودار (۱۵)، نحوه عملکرد لایه حذف تصادفی نشان داده می‌شود.

نمودار ۱۵. عملکرد لایه حذف تصادفی



منبع: یافته‌های پژوهش.

نتایج اجرای الگوریتم شبکه عصبی پیچشی با لحاظ کردن لایه حذف تصادفی و ادغام پیشینه در جداول (۶) و (۷) ارائه شده است.

جدول ۶. خطای اجرای معماری سوم شبکه عصبی پیچشی به تفکیک پارامترهای مختلف با تابع فعال‌سازی یکسوساز

تابع فعال‌سازی یکسوساز	نوع خطا	تعداد فیلتر		
		۶۴	۱۲۸	۲۵۶
۳۲	MAPE	۱.۵۵	۱.۵۵	۶.۱۲
	NRMSE	۲.۱۲	۲.۰۴	۶.۳۵
اندازه دسته ۶۴	MAPE	۲.۴۳	۱.۳۱	۱.۲۶
	NRMSE	۳.۲۰	۱.۸۴	۱.۸۰
۱۲۸	MAPE	۲.۰۴	۱.۹۹	۱.۶۵
	NRMSE	۲.۵۵	۲.۵۸	۲.۱۲

منبع: یافته‌های پژوهش.

جدول ۷. خطای اجرای معماری سوم شبکه عصبی پیچشی به تفکیک پارامترهای مختلف با تابع فعال‌سازی تانژانت هیپربولیک

تابع فعال‌سازی تانژانت هیپربولیک	نوع خطا	تعداد فیلتر		
		۶۴	۱۲۸	۲۵۶
۳۲	MAPE	۱.۷۵	۱.۷۶	۶.۹۰
	NRMSE	۲.۳۹	۲.۳۰	۷.۱۷
اندازه دسته ۶۴	MAPE	۲.۷۴	۱.۴۷	۲.۲۵
	NRMSE	۳.۶۱	۲.۰۸	۲.۹۲
۱۲۸	MAPE	۲.۳۱	۱.۴۲	۱.۸۵
	NRMSE	۲.۸۸	۲.۰۳	۲.۳۹

منبع: یافته‌های پژوهش.

نتایج بدست آمده از اجرای معماری سوم حاکی از آن است که ترکیب پارامترها با اندازه دسته ۶۴، تعداد فیلتر ۲۵۶ و با تابع فعال‌سازی یکسوساز بهترین دقت پیش‌بینی را در این بخش دارد. بر اساس نتایج، دقت منتخب معماری سوم شبکه عصبی پیچشی نسبت به روش‌های دیگر بالاتر است. مقادیر مجذور میانگین مربعات خطای نرمال برای هر سه روش کمتر از سطح ۰.۰۵ است که نشان از برآزش مناسب الگوریتم‌های مذکور دارد. در ادامه، به منظور بررسی رابطه بین مقدار واقعی معاملات وابسته و مقدار پیش‌بینی شده از ضریب همبستگی پیرسون استفاده شده است که نتایج آن در جدول (۸) آورده شده است. با توجه

به اینکه سطح معناداری برای هر سه روش از سطح خطای یک درصد کمتر است، وجود همبستگی بین مقدار واقعی معاملات وابسته و مقدار پیش‌بینی شده به لحاظ آماری تأیید شده است.


جدول ۸. ضریب همبستگی پیرسون بین مقدار واقعی معاملات وابسته و مقدار پیش‌بینی شده

نام روش شرح	منتخب معماری اول شبکه عصبی پیچشی	منتخب معماری دوم شبکه عصبی پیچشی	منتخب معماری سوم شبکه عصبی پیچشی
ضریب همبستگی پیرسون	۹۰.۳۷	۹۷.۳	۹۹.۲۵
سطح معناداری	۰.۰۰۰	۰.۰۰۰	۰.۰۰۰
تعداد داده آزمایش	۱۳۵	۱۳۵	۱۳۵

منبع: یافته‌های پژوهش.

نظر به اینکه بر اساس نتایج جدول (۸)، منتخب معماری سوم شبکه عصبی پیچشی نسبت به روش‌های دیگر عملکرد بهتری داشته است. در ادامه، نتایج حاصل از اجرای این روش آورده شده است. فرآیند کاهش خطا در مرحله آموزش معماری منتخب با تکرار ۱۰۰ مرتبه بهینه‌سازی در نمودار (۱۶)، مشخص است.


نمودار ۱۶. فرآیند کاهش خطا برای مرحله آموزش در معماری منتخب شبکه عصبی پیچشی



منبع: یافته‌های پژوهش.

پس از اعمال شبکه عصبی عمیق جهت شناسایی عمیق‌تر روابط مابین معاملات اشخاص وابسته گراف پژوهش به شرح زیر می‌باشد:

نمودار ۱۷. گراف کاوی بین داده‌های پژوهش



منبع: یافته‌های پژوهش.

با توجه به نمودار فوق مشاهده می‌گردد با حرکت به سمت سطح تفکیک و طبقه‌بندی داده‌ها افزایش یافته است و این امر به معنای توانایی شناسایی الگوی رفتاری مدل گراف کاوی در تبیین رفتار متغیر معاملات اشخاص وابسته است. در ادامه ضرایب برآوردی ژوپولتیک مابین مسیرهای حفظ سود و انتقال سود ارائه شده است.

جدول ۹. ضرایب توپولوژیک

حفظ سود		انتقال سود	
L1→L2	۰.۵۷	H1→H2	۰.۳۰
L1→C1	۰.۴۹	H1→C6	۰.۲۹
L2→C2	۰.۳۶	H2→C6	۰.۳۲
C1→C3	۰.۴۲	H1→C4	۰.۵۴
C3→C2	۰.۴۰	H2→C5	۰.۳۹
		C4→C5	۰.۴۷
میزان انطباق	۰.۹۲	میزان انطباق	۰.۸۳

منبع: یافته‌های پژوهش.

بر اساس نتایج هر دو حالت حفظ سود و انتقال سود در فرار مالیاتی معاملات اشخاص وابسته مشاهده شد. بر اساس نتایج شدت رابطه حفظ سود در فرار مالیاتی معاملات اشخاص وابسته قوی‌تر از رابطه انتقال سود است. در ادامه بر اساس رویکردهای لاجیت، پرابیت و احتمال

خطی میزان دقت در شناسایی فرار مالیاتی معاملات اشخاص وابسته محاسبه شده است. علت استفاده از این رویکردها مقایسه قدرت مدل گراف کاوی در شناسایی مدل در فرار مالیاتی معاملات اشخاص وابسته با مدل‌های مذکور است.

جهت اعتبارسنجی مدل از هر کدام از مدل‌ها در ۱۰۰ شرکت، ۱۵۰ شرکت و ۲۰۰ شرکت جهت پیش‌بینی درون نمونه‌ای برای ارزیابی قدرت مدل‌های سه‌گانه به کار گرفته شده است. تشکیل نمونه‌های مختلف جهت جلوگیری از سوگیری در نتایج است.

جدول ۱۰. دقت پیش‌بینی مدل در نمونه‌های با اندازه مختلف

اولویت	مدل	تعداد نمونه	۱۰۰ شرکت	۱۵۰ شرکت	۲۰۰ شرکت
		تعداد پیش‌بینی صحیح فرار مالیاتی اشخاص وابسته	۴۵	۵۱	۸۲
		تعداد پیش‌بینی صحیح عدم فرار مالیاتی اشخاص وابسته	۳۳	۶۳	۷۳
رتبه ۲	مدل پرابیت	تعداد پیش‌بینی غلط فرار مالیاتی اشخاص وابسته	۹	۱۴	۲۱
		تعداد پیش‌بینی غلط عدم فرار مالیاتی اشخاص وابسته	۱۳	۱۷	۲۴
		درصد صحت	۷۸ درصد	۷۸.۶ درصد	۷۷.۵ درصد
		تعداد پیش‌بینی صحیح فرار مالیاتی اشخاص وابسته	۴۷	۵۳	۸۵
		تعداد پیش‌بینی صحیح عدم فرار مالیاتی اشخاص وابسته	۳۵	۶۷	۷۹
رتبه اول	مدل لاجیت	تعداد پیش‌بینی غلط فرار مالیاتی اشخاص وابسته	۱۰	۱۳	۱۷
		تعداد پیش‌بینی غلط عدم فرار مالیاتی اشخاص وابسته	۱۰	۱۷	۱۹
		درصد صحت	۸۰.۴ درصد	۸۰ درصد	۸۲ درصد
		تعداد پیش‌بینی صحیح فرار مالیاتی اشخاص وابسته	۳۱	۴۴	۶۶
		تعداد پیش‌بینی صحیح عدم فرار مالیاتی اشخاص وابسته	۲۷	۴۵	۵۹
رتبه سوم	مدل احتمال خطی	تعداد پیش‌بینی غلط فرار مالیاتی اشخاص وابسته	۲۲	۲۸	۴۶
		تعداد پیش‌بینی غلط عدم فرار مالیاتی اشخاص وابسته	۲۰	۳۳	۲۹
		درصد صحت	۵۸ درصد	۵۹.۳ درصد	۶۲.۵ درصد

منبع: یافته‌های پژوهش.

با توجه به جدول دقت مدل رویکردهای لاجیت و پرابیت و احتمال خطی نسبت به مدل‌های گراف کاوی کمتر می‌باشد که نشان دهنده قدرت بالاتر رویکردهای گراف کاوی نسبت به این رویکردها است. لازم به ذکر است از میان مدل‌های رگرسیونی دقت رویکرد لاجیت نسبت به سایر رویکردها در شناسایی فرار مالیاتی معاملات اشخاص وابسته از قدرت بالاتری برخوردار است.

نتیجه‌گیری

در این پژوهش یک مدل ترکیبی نوآورانه بر اساس شبکه‌های یادگیری عمیق و گراف کاوی ارائه شده است تا بتواند در تعیین روابط توپولوژیکی کمک کند. جهت پیش‌بینی فرار مالیاتی معاملات اشخاص وابسته که به طور معمول در روش‌های سنتی شناسایی نمی‌شوند از سه الگوریتم شبکه عصبی پیچشی، حافظه کوتاه‌مدت ماندگار و پرسپترون‌های چند لایه در حالت عمیق بهره گرفته شد. برای شناسایی گروه‌های مشکوک سه مرحله صورت پذیرفته است. اول: تشخیص تفاوت نرخ مالیات، تطبیق الگوی توپولوژیکی و شناسایی ناهنجاری بار مالیاتی؛ دوم: آزمایش‌های تجربی بر اساس داده‌های ۱۶۷۵۶ معامله خرید و فروش اشخاص وابسته در کشور؛ سوم: برآورد ضرایب و نحوه ارتباط مابین الگوی توپولوژیک در دو حالت حفظ سود و انتقال سود بر اساس رویکرد گراف کاوی و شبکه عصبی عمیق. بر اساس نتایج، هر دو حالت حفظ سود و انتقال سود در فرار مالیاتی معاملات اشخاص وابسته مشاهده شد. نتایج، گویای دقت بالاتر مدل‌های گراف کاوی نسبت به مدل‌های مرسوم لاجیت و پرابیت بود. بر اساس نتایج بدست آمده، شدت رابطه حفظ سود در فرار مالیاتی معاملات اشخاص وابسته، قوی‌تر از رابطه انتقال سود است. با توجه به اینکه تحقیقات پیشین در این حوزه با این فرآیند صورت نگرفته است، در روند کلی می‌توان گفت که تحقیق حاضر در راستای نتایج این تحقیقات قرار دارد: مقری گردودباری و همکاران (۱۴۰۲)؛ قنبری‌نژاد و همکاران (۱۴۰۲)؛ صداقتی و همکاران (۱۴۰۰)؛ نسل موسوی و همکاران (۱۳۹۹)؛ جوادیان کوتنائی و همکاران (۱۳۹۹)؛ نمازی و همکاران (۱۳۹۷)؛ لین و همکاران (۲۰۲۳)؛ لیت و همکاران (۲۰۲۲)؛ تسلیخ و همکاران (۲۰۱۶)؛ روئان و همکاران (۲۰۱۹)؛ تیان و همکاران (۲۰۱۹) و گونزالس و همکاران (۲۰۱۳).

بر اساس نتایج پژوهش، پیشنهاد‌های زیر قابل ارائه است: از آنجایی که گروه‌های فرار مالیاتی از طریق معاملات اشخاص وابسته همواره رفتارهای جدیدی که مبتنی بر روابط تعاملی

ناهمگن، پیچیده و پنهانی هستند را بروز می‌دهند، سازمان امور مالیاتی کشور می‌باید با استفاده از اطلاعات موجود در بانک‌های اطلاعاتی اداره ثبت شرکت‌ها و اداره ثبت احوال نسبت به شناسایی توپولوژی‌های جدید رفتاری اقدام نماید. از این رو در راستای افزایش دقت مدل، باید دائماً روابط تعاملی جدیدی شناسایی و ملاک عمل قرار گیرد.

لازم به ذکر است که برنامه‌ریزی جهت شناسایی روابط پیچیده و شبکه‌ای بین شرکت‌ها نقش کلیدی در شناسایی گروه‌های مشکوک و به تبع آن شناسایی فرار مالیاتی دارد. علاوه بر این، استفاده از روش یادشده توسط سازمان امور مالیاتی کشور سبب می‌شود سیستم‌های نظارتی به‌روزرسانی شوند. در این راستا، می‌توان از فناوری‌های پیشرفته برای شناسایی معاملات مشکوک بهره جست. ضمن آن که روش مذکور می‌تواند برای نظارت و پایش بهتر بر فعالیت‌های مالی در مناطق آزاد تجاری و ویژه اقتصادی نیز استفاده شود. با توجه به وجود پدیده فرار مالیاتی از طریق معاملات اشخاص وابسته باید واحدهای تجاری وابسته با اهداف خاص مالیاتی، به طور مشخص تعریف شوند. برای عملی نمودن چنین تعریفی باید هزینه‌های اداری تعریف وسیع واحدهای وابسته را در نظر داشت، زیرا تعریف به صورت وسیع، هزینه‌های اجرایی بالایی برای سازمان امور مالیاتی کشور خواهد داشت. لازم به ذکر است به منظور افزایش اثربخشی این تعریف و نیز در راستای کاهش تفاسیر مختلف مأموران و مؤدیان مالیاتی از تعریف اشخاص وابسته لازم است اشخاص مزبور به صورت مشخص و معین (به عنوان مثال متناسب با تعریف استانداردهای حسابداری)، تعریف شوند.




نظر به اینکه الزامات استانداردهای حسابداری و حسابرسی در خصوص افشای اطلاعات معاملات اشخاص وابسته در ایران صرفاً بر اساس اطلاعات افشاء شده شرکت‌ها در صورت‌های مالی و یادداشت‌های توضیحی، به صورتی نیست که بتوان از افشای قیمت‌گذاری انتقالی بین واحدهای تجاری وابسته در جهت تقویت حاکمیت شرکتی در واحدهای تجاری در راستای حمایت از سرمایه‌گذاران و اعتباردهندگان برای سنجش شاخص ریسک و همچنین برای حمایت از حسابرسان برای افزایش کیفیت گزارش‌گری مالی و اعتباردهی به گزارش‌های مالی اطمینان خاطر داشت. لذا پیشنهاد می‌شود که نهادهای تدوین‌کننده استانداردها و قانون‌گذاران، استانداردها و قوانینی برای الزام شرکت‌ها به افشای بیشتر محتوای اقتصادی معاملات با اشخاص وابسته وضع کنند.

به سرمایه‌گذاران پیشنهاد می‌شود به منظور کاهش تأثیرات مخرب هزینه‌های نمایندگی در

خصوص معاملات با اشخاص وابسته، از قراردادهای مدیریتی یا مکانیزم‌های حسابرسی استفاده کنند، چرا که هزینه‌های نمایندگی را می‌توان به واسطه حسابرسی یا انعقاد قراردادهای مؤثر مالک - مدیر کاهش داد. کمیته حسابرسی در شرکت‌ها، قیمت دریافتی یا پرداختی اشخاص وابسته را کنترل می‌کند. شرکت‌هایی که کمیته حسابرسی در هیأت مدیره آن‌ها وجود دارد و شرکت‌هایی با تحلیل گران بزرگ، معاملات با اشخاص وابسته را در قیمت‌های مناسب‌تر انجام می‌دهند. با توجه به اینکه اتکای مأموران مالیاتی به استانداردهای حسابداری و حسابرسی برای وصول مالیات در اغلب موارد در حوزه حسابرسی کفایت نمی‌کند، به سازمان امور مالیاتی کشور پیشنهاد می‌شود تا در قالب پروژه «حسابرسی مالیاتی مبتنی بر ریسک» و طرح جامع مالیاتی و با استفاده از داده‌های موجود در سامانه‌های مالیاتی و بانک‌های اطلاعاتی نسبت به شناسایی معاملات اشخاص وابسته و ناهنجاری‌های مالی موجود در آن‌ها اقدام نماید و سپس تدابیری ویژه جهت آموزش مأمورین مالیاتی رسیدگی‌کننده به منظور دقت نظر بیشتر در فرآیند حسابرسی پرونده‌های مرتبط اتخاذ نماید. شناسایی ناهنجاری‌های مالی در معاملات وابسته، موجب شفافیت بیشتر و کاهش امکان سوءاستفاده از خلأهای قانونی می‌شود. در این راستا، معاملات با اشخاص وابسته که توسط سازمان امور مالیاتی بر اساس اطلاعات موجود در سامانه‌های مالیاتی و بانک‌های اطلاعاتی شناسایی می‌شوند، باید به عنوان یکی از معیارها و شاخص‌های تعیین ریسک فعالان اقتصادی در فرآیند نحوه انتخاب پرونده‌های مناسب برای حسابرسی مؤدیان عضو «سامانه مؤدیان» یا خارج از آن سامانه قلمداد گردد. بدیهی است تدابیر اتخاذی جهت رصد توافق قیمت‌گذاری می‌تواند نقش بسیار مهمی در افزایش کارایی و اثربخشی رسیدگی‌های مالیاتی مرتبط با معاملات اشخاص وابسته ایفا نماید. علاوه بر این، جرائم عدم تمکین واحدهای تجاری مرتبط در باب عمل به وظایف خود از قبیل تهیه و ارسال فرم معاملات اشخاص وابسته به اداره مالیاتی مربوطه تعیین شود. بی‌شک اعمال جرائم مناسب در این موضوع می‌تواند ضمانت اجرای قوانین مالیاتی مرتبط با این حوزه را افزایش دهد. همچنین تعیین شود که در صورت بروز اختلاف بین مؤدی و مسئولان مالیاتی، به چه نحوی اختلافات میان آن‌ها حل و فصل شود. به عبارت دیگر، آیین دادرسی مناسبی برای حل و فصل اختلافات بین مؤدیان و ادارات مالیاتی در خصوص مسائل مرتبط با معاملات اشخاص وابسته تدوین شود. همچنین به منظور تصویب ماده قانونی صریح و مشخصی در باب رعایت اصل معاملات مستقل در مبادلات مالی میان واحدهای تجاری وابسته، تدوین دستورالعمل و رویه‌های مالیاتی دقیق،

قبل از هر اقدامی، انجام تحقیقات مرتبط با قیمت‌گذاری انتقالات، ضروری به نظر می‌رسد. به این دلیل که کشورهای در حال توسعه (از جمله ایران)، دانش و اطلاعات بسیار اندکی در این موضوع دارند، به سازمان امور مالیاتی پیشنهاد می‌شود با کشورهای همکاری فعالانه داشته باشند که تجربه قانون‌گذاری، انتخاب پرونده‌های مناسب رسیدگی، حسابرسی، حل اختلافات با مؤدی، و تصویب موافقت‌نامه‌ها در این مورد را دارند. جنبه دیگر، همکاری با سایر کشورها، تبادل داده‌ها و اطلاعات مؤدیان مرتبط با مسأله معاملات اشخاص وابسته در قالب توافق‌نامه‌های اجتناب از اخذ مالیات مضاعف است. بدین منظور، عضویت سازمان امور مالیاتی کشور در برخی از نهادهای بین‌المللی مرتبط با این موضوع، می‌تواند مناسب باشد.

ORCID

Amin Ahmadpour  <http://orcid.org/0000-0001-9908-5558>
Seyedeh Mahboobeh Jafari  <http://orcid.org/0000-0002-1748-852x>
Fatemeh Sarraf  <http://orcid.org/0000-0001-8946-5610>

Resources:

1. Al-Hagery, M. A. (2019). Extracting Hidden Patterns from Dates' Product Data Using a Machine Learning Technique. *IAES International Journal of Artificial Intelligence*, 8(3), 1-20.
2. Arab Mazar, A., Bagheri, B., & Jafar Parvar, M. (2013). Tax Approach to Transfer Pricing and Its Investigation in Iran. *Tax Research Paper*, 22(21), 9-38. [In Persian]
3. Asadi Yusufabad, M., Pifeh, A., & Ahmadzadeh, H. (1401). The Effect of Transactions with Related Parties on Company Value with an Emphasis on Social Responsibility. *Accounting, Auditing and Financial Services in Islamic Environments*, 1, 2(2), 100-129. [In Persian]
4. Cameron, A. C., & Trivedi, P. K. (2005). *Microeconometrics Methods and Applications*. Cambridge: Cambridge University Press.
5. Chen, K., Zhou, Y., & Dai, F. (2015). An LSTM-Based Method for Stock Returns Prediction: A Case Study of China Stock Market. *2015 IEEE International Conference on Big Data (Big Data)*(2823-2824). New York: IEEE Publication.
6. Chong, E., Han, C., & Park, F. C. (2017). Deep Learning Networks for Stock Market Analysis and Prediction: Methodology, Data Representations, And Case Studies. *Expert Systems with Applications*, 83, 187-205.
7. Ferrantino, M. J., Liu, X., & Wang, Z. (2012). Evasion Behaviors of Exporters and Importers: Evidence from the US–China Trade Data Discrepancy. *Journal of International Economics*, 86(1), 141-157.
8. Gao, P., Zhang, R., & Yang, X. (2020). The Application of Stock Index Price Prediction with Neural Network. *Mathematical and Computational Applications*, 25(3), 53-69.
9. Garderodbari, M., Dadashi I., Mohseni Maleki, B., & Zabihi A. (1402). Predicting Tax Evasion of Legal Taxpayers with an Emphasis on Economic Components, Taxpayers and Tax Auditors; Relying on Artificial Intelligence. *Tax Research Paper*, 32(58), 131-164. [In Persian]
10. González, P. C., & Velásquez, J. D. (2013). Characterization and Detection of Taxpayers with False Invoices Using Data Mining Techniques. *Expert Systems with Applications*, 40(5), 1427-1436.
11. Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Feedforward Networks. *Deep Learning*, 1, 161-217.
12. Gudelek, M. U., Boluk, S. A., & Ozbayoglu, A. M. (2017). A Deep Learning Based Stock Trading Model With 2-D CNN Trend Detection. In *2017 IEEE Symposium Series on Computational Intelligence (SSCI)* (1-8). New York: IEEE.
13. Hazra, T., & Anjaria, K. (2022). Applications of Game Theory in Deep Learning: A Survey. *Multimedia Tools and Applications*, 81(6), 8963-8994.
14. Heij, C. (2004). *Econometric Methods with Applications in Business and Economics*. Oxford: Oxford University Press.

15. Hensher, D. A., & Greene, W. H. (2003). The Mixed Logit Model: The State of Practice. *Transportation*, 30, 133-176.
16. Hsu, K. W., Pathak, N., Srivastava, J., Tschida, G., & Bjorklund, E. (2014). Data Mining Based Tax Audit Selection: A Case Study of a Pilot Project at the Minnesota Department of Revenue. In *Real World Data Mining Applications* (221-245). Cham: Springer International Publishing.
17. Javadian Kotanaie, A., Pouraghajan Sarhamami, A., & Hosseini Shirvani, M. (2019). Presenting a Tax Fraud Detection Model Based on the Combination of the Improved ID3 Decision Tree Algorithm and Multilayer Perceptron Neural Networks. *Management Accounting*, 13(46), 53 -70. [In Persian]
18. Ji, L., Zou, Y., He, K., & Zhu, B. (2019). Carbon Futures Price Forecasting Based with ARIMA-CNN-LSTM Model. *Procedia Computer Science*, 162, 33-38.
19. Karhunen, J., Raiko, T., & Cho, K. (2015). Unsupervised Deep Learning: A Short Review. *Advances in Independent Component Analysis and Learning Machines*, 2015, 125-142.
20. Kim, Y. J., Baik, B., & Cho, S. (2016). Detecting Financial Misstatements with Fraud Intention Using Multi-Class Cost-Sensitive Learning. *Expert Systems with Applications*, 62, 32-43.
21. Klassen, K. J., Lisowsky, P., & Mescall, D. (2017). Transfer Pricing: Strategies, Practices, and Tax Minimization. *Contemporary Accounting Research*, 34(1), 455-493.
22. Kolaczyk, E. D., & Csárdi, G. (2014). *Statistical Analysis of Network Data with R* (65). New York: Springer.
23. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep Learning. *Nature*, 521 (7553), 436-444.
24. Lee, S. I., & Yoo, S. J. (2020). Threshold-based Portfolio: The Role of the Threshold and Its Applications. *The Journal of Supercomputing*, 76(10), 8040-8057.
25. Leite, R. A., Gschwandtner, T., Miksch, S., Kriglstein, S., Pohl, M., Gstrein, E., & Kuntner, J. (2017). Eva: Visual Analytics to Identify Fraudulent Events. *IEEE Transactions on Visualization and Computer Graphics*, 24(1), 330-339.
26. Li, J., Wang, X., & Wu, Y. (2020). Can Government Improve Tax Compliance by Adopting Advanced Information Technology? Evidence from the Golden Tax Project III in China. *Economic Modelling*, 93, 384-397.
27. Li, Y., & Dai, W. (2020). Bitcoin Price Forecasting Method Based on CNN-LSTM Hybrid Neural Network Model. *The Journal of Engineering*, 2020(13), 344-347.
28. Lin, Y., Wong, K., Wang, Y., Zhang, R., Dong, B., Qu, H., & Zheng, Q. (2020). Taxthemis: Interactive Mining and Exploration of Suspicious Tax Evasion Groups. *IEEE Transactions on Visualization and Computer Graphics*, 27(2), 849-859.

29. Liu, L., Schmidt-Eisenlohr, T., & Guo, D. (2020). International Transfer Pricing and Tax Avoidance: Evidence from Linked Trade-Tax Statistics in the United Kingdom. *Review of Economics and Statistics*, 102(4), 766-778.
30. Liu, X., Pan, D., & Chen, S. (2010). Application of Hierarchical Clustering in Tax Inspection Case-Selecting. In *2010 International Conference on Computational Intelligence and Software Engineering* (1-4). New York: IEEE.
31. Livieris, I. E., Kiriakidou, N., Stavroyiannis, S., & Pintelas, P. (2021). An Advanced CNN-LSTM Model for Cryptocurrency Forecasting. *Electronics*, 10(3), 1-16.
32. Livieris, I. E., Pintelas, E., & Pintelas, P. (2020). A CNN-LSTM Model for Gold Price Time-Series Forecasting. *Neural Computing & Applications*, 32(23), 17351-17360.
33. Long, J. S., & Freese, J. (2006). *Regression Models for Categorical Dependent Variables Using Stata* (7). College Station: Stata Press.
34. Maddala, G. S. (1983). *Introduction to Econometrics* (3rd Ed.). Ohio: Formerly Ohio State University
35. Matos, T., de Macedo, J. A. F., & Monteiro, J. M. (2015). An Empirical Method for Discovering Tax Fraudsters: A Real Case Study of Brazilian Fiscal Evasion. In *Proceedings of the 19th International Database Engineering & Applications Symposium* (41-48). New York: Association for Computing Machinery.
36. Myerson, R. B. (2013). *Game Theory*. Cambridge, MA: Harvard University Press.
37. Namazi, M., & Sadeghzadeh Maharlouei, M. (2017). Investigating the Usefulness of the Relief Variable Selection Method in Improving the Results of Tax Evasion Prediction Using Data Mining. *Applied Research in Financial Reporting*, 7(13), 44-70. [In Persian]
38. Narahari, Y. (2014). *Game Theory and Mechanism Design* (4). Toh Tuck Link: World Scientific Publishing.
39. Nasl Mousavi, H., Hosseini Shirvani, M., & Nazarpour, M. (1399). Presenting a Tax Evasion Prediction Model Based on ID3 Decision Tree Algorithm and Bayesian Network. *Tax Research Paper*, 28(45), 59-87. [In Persian]
40. OECD. (2017). Shining Light on the Shadow Economy: Opportunities and Threats. Retrieved 20 February from <https://www.oecd.org/tax/crime/shining-light-on-the-shadow-economy-opportunities-and-threats.pdf>
41. Oliva, R. (2004). Model Structure Analysis Through Graph Theory: Partition Heuristics and Feedback Structure Decomposition. *System Dynamics Review: The Journal of the System Dynamics Society*, 20(4), 313-336.
42. Pourzaker Arabani, S., & Ebrahimpour Komleh, H. (2018). Optimizing Cash Demand Forecasting of Atms in the Country's Banking Network Using LSTM Deep Recurrent Neural Network. *Operations Research in Its Applications*, 16(3), 69-88. [In Persian]

43. Rahimi Kia, I., Mohammadi, Sh., & Ghazanfari, M. (2014). Detection of Tax Evasion Using Hybrid Intelligent System. *Research Journal of Taxation*, 23(26), 136-164. [In Persian]
44. Ruan, J., Yan, Z., Dong, B., Zheng, Q., & Qian, B. (2019). Identifying Suspicious Groups of Affiliated-Transaction-Based Tax Evasion in Big Data. *Information Sciences*, 477, 508-532.
45. Sedaghati, S., Farhadi, R., & Fallah Shams, M. (1403). Contagion of Topological Dynamics in the Iranian Stock Market Network. *Investment Knowledge*, 13(49), 279-298. [In Persian]
46. Sarker, I. H. (2021). Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions. *SN Computer Science*, 2(6), 1-20.
47. Taye, M. M. (2023). Machine Learning with Deep Learning: Architectures, Workflow, Applications and Future Directions. *Computers*, 12(5), 91.
48. Tian, F., Lan, T., Chao, K. M., Godwin, N., Zheng, Q., Shah, N., & Zhang, F. (2016). Mining Suspicious Tax Evasion Groups in Big Data. *IEEE Transactions on Knowledge and Data Engineering*, 28(10), 2651-2664.
49. Tselykh, A., Knyazeva, M., Popkova, E., Durfee, A., & Tselykh, A. (2016, July). An Attributed Graph Mining Approach to Detect Transfer Pricing Fraud. *Proceedings of the 9th International Conference on Security of Information and Networks* (72-75). New York: Associate for Computing Machinery.
50. United Nations. (2017). Practical Manual on Transfer Pricing for Developing Countries. Retrieved from chrome-extension://efaidnbmnnnibpcajpcglclefindmkaj/https://www.un.org/esa/ffd/wp-content/uploads/2017/04/Manual-TP-2017.pdf
51. Wu, R. S., Ou, C. S., Lin, H. Y., Chang, S. I., & Yen, D. C. (2012). Using Data Mining Technique to Enhance Tax Evasion Detection Performance. *Expert Systems with Applications*, 39(10), 8769-8777.
52. Zhou, F., Zhou, H. M., Yang, Z., & Yang, L. (2019). EMD2FNN: A Strategy Combining Empirical Mode Decomposition and Factorization Machine Based Neural Network for Stock Market Trend Prediction. *Expert Systems with Applications*, 115, 136-151.

استناد به این مقاله: احمدپور، امین، جعفری، سیده محبوبه، و صراف، فاطمه. (۱۴۰۴). مدل‌سازی فرار مالیاتی معاملات اشخاص وابسته رویکرد هیبریدی گراف‌کاوی و شبکه عصبی عمیق. پژوهشنامه مالیات، ۳۳(۶۵)، ۷-۵۱.



Journal of Tax Research is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.