

Modeling and identification of nonfragile variables affecting credit risk in Tejarat Bank with an emphasis on fintech technologies

Rahman Rahimi¹, Fatemeh Sarraf², Mahboobeh Jafari¹, Bijan Safavi³

Received: 11/09/2022

Accepted: 22/12/2022

Extended Abstract

Introduction

Financial risks include uncertainties related to any type of financing, including credit, commercial, investment, and operational risks. Among these risks, credit risk is particularly important. Facilities are the most important part of a bank's assets whose inappropriate quality causes problems for banks. As a result, due to information asymmetry between banks and borrowers, banks must have a system that can estimate default risks and manage credit ones. According to the traditional approach, banks are the most important source of financing in economy. The establishment and development of FinTech has significantly affected banking systems. FinTech has expanded in many financial areas such as credit, deposits, capital raising, payments and investments. FinTech has the ability to identify risky behaviors. Credit risk assessment is one of the most challenging issues in the banking sector; the main problem is the correct modeling of this type of risk. The variety of variables affecting credit risk and the lack of a specific model are the most important reasons for the failure of traditional models. Based on this, the aim of this research is to model the credit risks of Tejarat Bank in different economic regimes. The main problem of the research is the design of the optimal model in terms of econometrics, which faces two basic problems. First, identifying the correct model and secondly, a model that can provide a correct forecast of credit risk.

Literature Review


In domestic and foreign research, researchers have investigated credit risk with various approaches and variables. For example, in external studies, the combination of audit analysis and artificial neural networks (Yu *et al.*, 2008),

1. Department of Accounting, South Tehran Branch, Islamic Azad University, Tehran, Iran.

2. Department of Accounting, South Tehran Branch, Islamic Azad University, Tehran, Iran. (Corresponding Author).
f_sarraf@azad.ac.ir

3. Department of Economics, South Tehran Branch, Islamic Azad University, Tehran, Iran.

How to cite this paper: Rahimi, R., Sarraf, F., Jafari, M., & Safavi, B. (2022). Modeling and identification of nonfragile variables affecting credit risk in Tejarat Bank with an emphasis on fintech technologies. *Advances in Finance and Investment*, 3(9), 135-170. [In Persian]

 <https://doi.org/10.30495/afi.2023.1975352.1181>

decision tree, data envelopment analysis (Min and Lee, 2008); Com-bination of decision tree and neural network (Kabari and Nwachukwu, 2013); and big data based method using Monte Carlo simulation and mixed linear model (Pérez-Martín *et al.*, 2018); Panel data (Barra and Ruggiero, 2022), logistic model (Motedayen *et al.*, 2022) have been effective in credit risk modeling. In internal research, support vector machine (Raei and Fallahpour, 2009) and (Mansourfar *et al.*, 2014), Neural network based on artificial bee colony (Fallahpour *et al.*, 2013), decision tree and regression (Mirghafouri and Amin Ashouri, 2015); Meta-heuristic and multi-criteria hybrid algorithm of ant colony-fuzzy neural network (Horri and Mahdavi, 2015) and (Ghasemi Armaky *et al.*, 2022) and the support vector machine model and the genetic algorithm hybrid model (Mohammadian Haji Kord *et al.*, 2016) are among the successful models in predicting credit risk.

Research Methodology

One of the ways to overcome the uncertainty of determining the optimal model is to use the Bayesian Model Averaging (BMA) method. Another topic is the difference in the effect of variables on credit risk in different economic conditions. In order to consider this, the approach of self-regression of regime changes has been used. The statistical population of the research includes the customers of Tejarat Bank, and the information of 105,000 bank customers was used to design the credit risk model. The research data includes information about real and legal customers, request for the type of service required, on the way to perform the required service. The customer community of Tejarat Bank has been investigated during the 5-year period from 2018 to 2022. Algorithm programming and implementation is in MATLAB software environment. In this article, two econometric models are used; the application of each approach is explained in the table below.

Table (1) Application of research models

Method	Application
BMA, TVP-DMA, TVP-DMS	Identification of non-fragile variables to distinguish bank customers
MS-VAR	To investigate non-fragile variables in different economic regimes

The dynamic averaging model uses the average probability of each variable to design the best model for predicting credit risk. In this approach, the theoretical topics of Kalman filter - state space models and MCMCMC approaches are used. The prediction of a variable at time t , which includes the coefficient and the probability of its occurrence, is corrected based on the information of $t-1$, and the best estimate for the period t is calculated. MS-VAR model is one of the most useful nonlinear models in time series topics. The MS-VAR model is estimated based on the number of variables, in other words, it is a multi-equation model. This approach considers the structural break in the time series in the estimation of the model. For this reason, VAR models and VECM models that do not consider

these changes, are not suitable (Kuck and Schweikert, 2017). These methods are used when the exact time of structural failure is determined in the variables; in most cases this information is not available (Ghaderi Moghaddam *et al.*, 2022).

Results

The information of indicators of 33 factors affecting credit risk in Tejarat Bank was entered into BMA, TVP-DMA and TVP-DMS models. Based on the error rate, the BMA model had the highest accuracy. After estimating the model, eight main variables were identified; this process is depicted in the diagrams below.

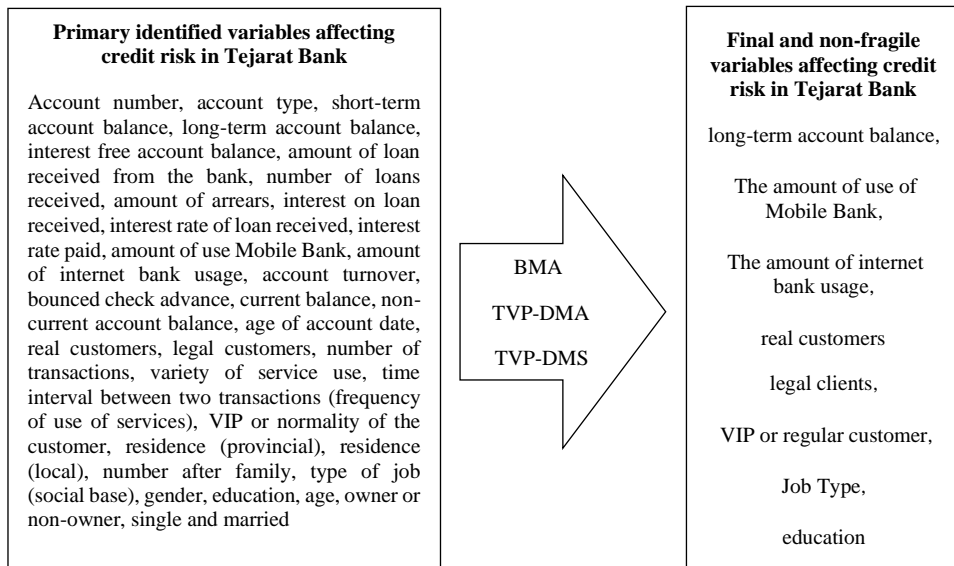


Chart (1) Identification of the most important non-fragile variables

The effect of non-fragile variables in the Markov switching model on credit risk was analyzed. Most of the variables, except for the variable of legal clients, have a significant and negative effect on the level of credit risk, and by moving from high prosperity to deep recession, the influence of variables on credit risk has increased. The results showed that the optimal credit risk model is different in each bank. Based on this, an optimal model was designed solely for credit risk in Tejarat Bank based on Bayesian averaging models. Based on the Markov switching approach, it was also concluded that the credit risk in the state of economic recession has a higher sensitivity to its explanatory variables; also, based on the results, it was determined that indicators related to FinTech have a significant effect on the level of credit risk in Tejarat Bank.

Discussion and Conclusion

Investment has a close relationship with economic growth and social welfare, as a result, equipping and providing investment resources has the most important role

in the banking system. Considering the role of banks and their impact on the financial market and the country's economy, it is particularly important to examine the risks that the banking system faces. Among the risks faced by banks, credit risk is the most prominent risk during the life of the bank, which can also be the cause of bank bankruptcy. Based on this, in the present research, modeling of factors affecting credit risk in Tejarat Bank was done.

Non-fragile variables in the Markov switching model were analyzed and all regression models were significant in all regimes and the validity of the regression line was confirmed in all models. Also, most of the variables had a positive and significant effect on the credit risk situation, and the model was improved with the inclusion of the mentioned variables. On the other hand, recession is the dominant and stable mode of credit risk in Tejarat Bank. The results showed that there is a significant relationship between the proxies defined for FinTech and credit risk in Tejarat Bank. Two indicators out of eight selected indicators affecting credit risk were variables related to FinTech; which is due to the high importance of this variable in identifying the credit risk of banks. Bank Tejarat must have a control system not only for its portfolio; Rather, it should maintain and always pay attention to the credit status and have a regular system to determine the adequacy of its resources and reserves, as well as the information system and analysis methods. So that the management can measure the existing credit risk in all banking activities through the mentioned systems and during the credit evaluation of the overall credit portfolio of individuals. Bank management should consider the possibility of changes in economic conditions.

Considering many dimensions of indicators affecting credit risk based on the Bayesian averaging approach; there is a need for a systemic view regarding this matter and because the human mentality does not have the ability to make this distinction, it is suggested to prepare computer programs based on statistical models to predict credit risk based on its components.

Since the dimensions of indicators affecting multiple credit risks and different effects (positive and negative) are combined, providing a composite index in this area will help managers, investors and policymakers of the banking sector in making decisions. Considering the many factors affecting the credit risk of customers, it is recommended that the managers of the banking system, along with the used forecasting methods, the effective factors mentioned in the research consider the history of the company and the individual.

The dependence of credit risk on the economic situation and the variability of the factors affecting it in terms of the intensity of the effect and the level of the probability of the effect, causes complex conditions; Therefore, it is suggested to design different models for different conditions in such a way that managers and policy makers make policy and make decisions in bank risk management according to the economic conditions. As a result, managers should consider

appropriate policies to economic conditions. Researchers are suggested to consider institutional indicators, audit indicators for legal clients and environmental indicators such as central bank guidelines, sanctions, business climate indicators and political and economic stability in future research.

The limitations of this research is lack of information in the field of Blockchain, Metaverse and Internet of Things and the emphasis of the present research is only on information and statistics in Internet Bank and Mobile Bank and services in this field.

Conflict of Interest

The authors of this article declared no conflict of interest regarding the authorship or publication of this article.

Keywords: Tejarat Bank, credit risk, fintech, risk management, Bayesian models.

JEL Classification: M41 ,E51,G32.

پیشرفت‌های مالی و سرمایه‌گذاری

سال سوم، زمستان ۱۴۰۱ - شماره ۹

صفحات ۱۷۰-۱۳۵

نوع مقاله: پژوهشی

مدل‌سازی و شناسایی متغیرهای غیرشکننده مؤثر بر ریسک اعتباری در بانک تجارت با تأکید بر فناوری‌های فین‌تک

رحمان رحیمی^۱، فاطمه صراف^۲، محبوبه جعفری^۳، بیژن صفوی^۴

تاریخ پذیرش: ۱۴۰۱/۱۰/۰۵

تاریخ دریافت: ۱۴۰۱/۰۶/۲۰

چکیده

هدف: ارزیابی ریسک اعتباری یکی از موضوعات چالش‌برانگیز در بخش بانکی است؛ مشکل اصلی مدل‌سازی صحیح این نوع ریسک می‌باشد. تنوع متغیرهای اثرگذار بر ریسک اعتباری و نبود یک مدل مشخص از مهم‌ترین علل شکست مدل‌های سنتی می‌باشد. براین اساس هدف تحقیق حاضر مدل‌سازی ریسک اعتباری بانک تجارت در رژیم‌های مختلف اقتصادی است.

روش‌شناسی پژوهش: این تحقیق کاربردی است. بازه زمانی تحقیق پنج سال (۱۳۹۶-۱۴۰۰) و از بین ۱۰۵ هزار مشتری بانک تجارت انتخاب شده است. برای این منظور، اطلاعات شاخص‌های ۳۳ عامل مؤثر بر ریسک اعتباری در بانک تجارت وارد مدل‌های BMA، TVP-DMA و TVP-DMS شد. پس از برآورد مدل، ۸ متغیر اصلی شناسایی گردید.

یافته‌ها: تأثیر متغیرهای غیرشکننده در مدل مارکوف سویچینگ بر ریسک اعتباری مورد تجزیه و تحلیل قرار گرفت. اکثریت متغیرها به جز متغیر مشتریان حقوقی تأثیر منفی و معناداری بر سطح ریسک اعتباری دارند و با حرکت از سمت رونق بالا به سمت رکود عمیق میزان تأثیرگذار متغیرها بر ریسک اعتباری افزایش یافته است.

اصالت / ارزش افزوده علمی: نتایج نشان داد مدل بهینه ریسک اعتباری در هر بانک متفاوت است. براین اساس اقدام به طراحی یک مدل بهینه صرفاً برای ریسک اعتباری در بانک تجارت بر اساس الگوهای میانگین‌گیری بی‌زین گردید. بر اساس رویکرد مارکوف سویچینگ نیز این نتیجه حاصل شد که ریسک اعتباری در حالت رکود اقتصادی حساسیت بالاتری نسبت به متغیرهای توضیح‌دهنده خود دارد. همچنین بر اساس نتایج مشخص گردید که شاخص‌های مرتبط با فین‌تک بر سطح ریسک اعتباری در بانک تجارت تأثیر معناداری دارند.

کلیدواژه‌ها: بانک تجارت، ریسک اعتباری، فین‌تک، مدیریت ریسک، مدل‌های بی‌زین.

طبقه‌بندی موضوعی: M41، E51، G32.

۱. گروه حسابداری، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران.

۲. گروه حسابداری، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران. (نویسنده مسئول). f_sarraf@azad.ac.ir

۳. گروه اقتصاد، واحد تهران جنوب، دانشگاه آزاد اسلامی، تهران، ایران.

استناد: رحیمی، رحمان؛ صراف، فاطمه؛ جعفری، محبوبه؛ صفوی، بیژن. (۱۴۰۱). مدل‌سازی و شناسایی متغیرهای غیرشکننده مؤثر بر ریسک اعتباری در بانک تجارت با تأکید بر فناوری‌های فین‌تک. *پیشرفت‌های مالی و سرمایه‌گذاری*، ۳(۹)، ۱۷۰-۱۳۵.

۱- مقدمه

ریسک‌های مالی شامل عدم قطعیت‌های مرتبط با هر نوع تأمین مالی، از جمله ریسک‌های اعتباری، تجاری، سرمایه‌گذاری و عملیاتی است (Han and Wang, 2021) و (Motedayen et al., 2022). در بین این ریسک‌ها، ریسک اعتباری مربوط به مشتریان از اهمیت ویژه‌ای برخوردار است (Bellotti and Crook, 2012). تسهیلات مهم‌ترین بخش دارایی یک بانک است که کیفیت نامناسب آن باعث ایجاد مشکلاتی برای بانک‌ها می‌شود (Han and Wang, 2021).

کیفیت پایین تسهیلات از فرآیند جمع‌آوری اطلاعات شکل می‌گیرد، بدین معنی که اطلاعات کاملی درباره مشتریان و تسهیلات‌گیرندگان وجود ندارد (Motedayen et al., 2022). این مسئله، زمانی که رویکرد و فرآیند هدفمندی در این خصوص در بانک وجود نداشته باشند یا ضعیف و ناقص باشند، نمود بیش‌تری از خود نشان می‌دهد (Brownbridge, 1998)، از طرف دیگر حداقل نمودن ریسک اعتباری از طریق وجود سیستم مناسب ریسک اعتباری رخ می‌دهد (Santomero, 1997)، در نتیجه به دلیل وجود عدم تقارن اطلاعات بین بانک‌ها و قرض‌گیرندگان، بانک‌ها باید سیستمی داشته باشند که بتواند ریسک نکول را تخمین زده و ریسک اعتباری را مدیریت نماید (Bester, 1994) و (Gobbi et al., 1999).

طبق رویکرد سنتی بانک‌ها مهم‌ترین منبع تأمین مالی در اقتصاد هستند، ظهور فین‌تک‌ها جهت مدیریت ریسک بانک‌ها و مؤسسات مالی می‌باشد (Cornelli et al., 2020). استقرار و توسعه فین‌تک به طور قابل توجهی بر سیستم‌های بانکی تأثیر گذاشته است (Petralia et al., 2019). فین‌تک در بسیاری از زمینه‌های مالی؛ مانند اعتبار، سپرده، افزایش سرمایه، پرداخت و سرمایه‌گذاری گسترش یافته است. فین‌تک توانایی شناسایی رفتارهای ریسک‌پذیر را دارد (An and Rau, 2019)، (Cheng and Wang, 2020)، (Qu, 2020)، (Guo and Shen, 2016)، (Qiao et al., 2018)، (Phan et al., 2020) و (Wang et al., 2020). فین‌تک به طور معناداری توانسته است ریسک اعتباری را تحت تأثیر قرار دهد. مهم‌ترین تأثیر و تحول بخش فین‌تک بر بازار خدمات مالی ایران مربوط به خدمات بانکی، یعنی پرداخت‌ها و نقل و انتقالات است؛ از این رو، به تبعیت از مطالعه سدیگو و همکاران (Sadigov et al., 2020)، جهت لحاظ فین‌تک متغیرهای مرتبط با موبایل بانک، اینترنت بانک و خدمات این حوزه تعریف شده است (Buchak et al., 2018) و (Cornelli et al., 2020). یکی از روش‌های مدیریت ریسک اعتباری، تفکیک نمودن مشتریان با سطوح مختلف ریسک اعتباری است (Derban et al., 2005) و (Barra and Ruggiero, 2022). سیستم‌های رتبه‌بندی اگر مناسب طراحی شده باشند باید بتوانند تأثیر معناداری بر کاهش ریسک اعتباری داشته باشند (Santomero, 1997)؛ مسئله اصلی تحقیق طراحی مدل بهینه از نظر اقتصادسنجی است که با دو مشکل اساسی روبه‌رو است. اول شناسایی مدل صحیح و دوم مدلی که بتواند پیش‌بینی درستی از ریسک اعتباری را ارائه نماید.

یکی از روش‌های فائق آمدن بر نااطمینانی تعیین مدل بهینه، استفاده از روش میانگین‌گیری مدل بی‌زین (BMA) است. مبحث دیگر تفاوت میزان اثرگذاری متغیرها بر ریسک اعتباری در شرایط مختلف اقتصادی است. جهت لحاظ این امر از رویکرد خود رگرسیون برداری تغییرات رژیم بهره گرفته شده است. پس از مقدمه در بخش دوم مبانی نظری تحقیق، در بخش سوم روش تحقیق موضوع حاضر و در بخش چهارم نتایج برآورد مدل و در نهایت در بخش پنجم بحث و نتیجه‌گیری ارائه شده است.

۲- مبانی نظری و پیشینه پژوهش

امروزه ارزیابی عوامل مؤثر بر ریسک اعتباری از مهم‌ترین موضوعات در زمینه مدیریت ریسک مالی است که اهمیت آن در شبکه بانکی و به‌خصوص در اقتصادهایی با نظام مالی بانک محور، مانند ایران، پررنگ‌تر است (Dadashi et al., 2020). هر چند شبکه بانکی باتوجه‌به ویژگی‌های خاص آن، با انواع گوناگونی از ریسک‌ها و مخاطرات، مانند ریسک‌های اعتباری، نقدینگی و عملیاتی، بازار روبه‌رو است؛ با این‌وجود، به عقیده اکثر کارشناسان بانکی، مهم‌ترین ریسک که نظام بانکی هر کشوری را تهدید کرده و آسیب‌های فراوانی به صنعت بانکی وارد می‌کند، ریسک اعتباری است (Rostamzadeh et al., 2018).

ریسک اعتباری را می‌توان رویدادهای غیرمنتظره که معمولاً به‌صورت تغییر در ارزش دارایی‌ها یا بدهی‌ها رخ می‌دهد نیز تعریف نمود. این ریسک زمانی به وجود می‌آید که دریافت‌کنندگان تسهیلات، تمایل یا توانایی باز پرداخت بدهی خود را به بانک نداشته باشند که از آن نیز به‌عنوان نکول نیز یاد می‌شود. به بیان کمیته بازل، ریسک اعتباری احتمال عدم بازپس‌گیری تسهیلات اعطا شده توسط افراد حقیقی و حقوقی طبق شرایط توافق شده فی‌مابین بانک با طرفین مذکور می‌باشد (Rostamzadeh et al., 2018).

در تحقیقات داخلی و خارجی با رویکردها و متغیرهای متنوعی به بررسی ریسک اعتباری پرداخته‌اند. به‌عنوان مثال در مطالعات خارجی، ترکیب تحلیل ممیزی و شبکه‌های عصبی مصنوعی (Yu et al., 2008)، درخت تصمیم، تحلیل پوششی داده‌ها (Min and Lee, 2008)، ترکیب درخت تصمیم و شبکه عصبی (Kabari and Nwachukwu, 2013) و روش مبتنی بر داده‌های بزرگ با استفاده از شبیه‌سازی مونت کارلو و مدل خطی مختلط (Pérez-Martín et al., 2018)، پانل دیتا (Barra and Ruggiero, 2022)، مدل لاجستیک (Motedayen et al., 2022)، در مدل‌سازی ریسک اعتباری مؤثر واقع شده‌اند. در تحقیقات داخلی نیز، ماشین بردار پشتیبان (Raei and Fallahpour, 2009) و شبکه عصبی مبتنی بر کلونی زنبورعسل مصنوعی (Fallahpour et al., 2018)، درخت تصمیم و رگرسیون (Mirghafouri and Amin Ashouri, 2015)، الگوریتم

فراابتکاری و هیبریدی چندمعیاره شبکه کلونی مورچگان - عصبی فازی (Horri and Mahdavi, 2015) و (Ghasemi Armaky et al., 2022) و مدل ماشین بردار پشتیبان و مدل هیبریدی الگوریتم ژنتیک (Mohammadian Haji Kord et al., 2016)، از جمله مدل‌های موفق در پیش‌بینی ریسک اعتباری هستند.

با این وجود بسیاری از این مدل‌ها، حوزه جامعی از ویژگی‌ها و عوامل ریسک را مورد توجه قرار نداده و بیش‌تر مبتنی بر خصوصیات مالی و اقتصادی بوده‌اند. در شناسایی این متغیرها در بیش‌تر مطالعات داخلی، صرفاً بر مجموعه متغیرهای مالی (Mirghafouri and Amin Ashouri, 2015)، (Mohammadian Haji Kord et al., 2016)، متغیرهای اقتصادی (Noroozi, 2014)، (Rostamzadeh et al., 2018)، (Rostami et al., 2019) و (Mohaghegh Nia et al., 2019)، متغیرهای خصوصیتی قرارداد (Jafari Eskandari and Rohii, 2017) و (Tari et al., 2018) و یا حتی متغیرهای مالی در کنار متغیرهای غیرمالی (Safari et al., 2020) و (Ebrahimi and Fallahpour, 2012) تأکید شده است؛ همچنین بیش‌تر این مطالعات بر مشتریان حقیقی (Habibi et al., 2018) و (Tari et al., 2018)، (et al., 2013) و (Pourkazemi et al., 2018) متمرکز بوده است و از این‌رو ضرورت تمرکز بیش‌تر بر مشتریان حقوقی با ارزش اسمی بالاتر اعتبار، مشاهده می‌شود. در مورد نحوه تصریح متغیرهای ذکر شده در مطالعات تجربی نیز تقریباً هیچ توافقی حاصل نشده است.

امروزه بانک‌ها با چالش‌هایی نظیر تغییر انتظارات مشتریان، تحولات فناوری، الزامات قوانین و مقررات و بحران در اقتصاد مواجه‌اند و این مسئله منجر به تغییر و تحول در نظام بانکی شده است؛ بنابراین بانک‌ها بهتر است از توسعه شرکت‌ها یا استارت‌آپ‌های حوزه فناوری مالی (فین‌تک‌ها)^۱ به نفع خود بهره ببرند (Antoni Haber et al., 2018). پیشرفت‌های اخیر در فناوری اطلاعات منجر به توسعه سریع خدمات مالی جدید و نوآورانه به نام فین‌تک شده است (Zhao et al., 2019). از طرف دیگر، بانک‌های سنتی به خاطر بی‌حرکی و ساختار بوروکراتیک مجبور به انطباق با فین‌تک‌ها شده‌اند (Furlonger and Newton, 2018)؛ از این‌رو، بانک‌ها به اتخاذ راهبردهای مختلفی برای مهار تهدید احتمالی فین‌تک روی آورده‌اند که از مهم‌ترین آن‌ها می‌توان به تشکیل همکاری راهبردی اشاره کرد. همکاری راهبردی ترتیبات همکاری بین سازمان‌ها است و به مزیت رقابتی طرفین کمک می‌کند. از جمله مزایای همکاری راهبردی بین نظام بانکی با فین‌تک، کارایی از نظر سرعت، هزینه و دستیابی به مشتریان جدید است.

بر اساس اطلاعات جمع‌آوری شده فناوری فین‌تک از جدول (۱) بر صنعت بانکداری اثرگذار است.

۱. در ادامه متن این پژوهش به منظور رعایت اختصار از لفظ فینتک برای اشاره به شرکت‌ها یا استارت‌آپ‌های حوزه فناوری‌های مالی استفاده خواهد شد.

براین اساس در تحقیق حاضر برای اولین بار در تحقیقات داخلی سعی بر آن گردید با استفاده از مدل های میانگین گیری بیزین، پویا و انتخابی اقدام به شناسایی مدل بهینه نماییم. بخشی از ادبیات مالی در دهه های اخیر، میزان اطلاعات لازم برای دستیابی به برآورد قوی از پیش بینی متغیرهای اقتصادی و مالی را مورد بررسی قرار دادند (Marcellino *et al.*, 2003)، (Bernanke and Boivin, 2003)، (Forni *et al.*, 2004)، (Boivin and Ng, 2006)، (Greve *et al.*, 2022) و (D'Agostino *et al.*, 2013). از جمله دستاوردهای مهم در این خصوص، استفاده از روش های مختلف اقتصادسنجی برای به کارگیری اطلاعات داده های حجیم (کلان داده)، برای پیش بینی بود. در چنین رویکردی، مدل های عاملی، بیش تر مورد توجه بوده و استفاده از آن ها بسیار رایج شده است. مدل های عاملی، اطلاعات را از یک مجموعه حجیمی (کلان داده)، از شاخص ها در تعداد کمی از مؤلفه های اساسی غیرقابل مشاهده خلاصه می کنند.

استاک و واتسون (Stock and Watson, 2005)، استاک و واتسون (Stock and Watson, 2006)، فورنی و همکاران (Forni *et al.*, 2004)، مارسلیانو و همکاران (Marcellino *et al.*, 2003)، آنجلینی و همکاران (Angelini *et al.*, 2010)، آرتیس و همکاران (Artis *et al.*, 2005) و شوماخر (Schumacher, 2007)، نمونه هایی از مطالعات تجربی با استفاده از مدل های عاملی هستند. استخراج اطلاعات از داده های حجیم (کلان داده)، می تواند در بهبود فرآیند پیش بینی، کمک به سزایی کند؛ در حالی که نتایج اولیه حاصل از پیش بینی در مطالعات تجربی در این خصوص، بسیار امیدوارکننده بوده است (Stock and Watson, 2005)، (Forni *et al.*, 2004) و (Naser, 2014) که می توان به مطالعه استاک و واتسون (Stock and Watson, 2006) که با به کارگیری بیش از ۲۱۵ متغیر، به پیش بینی متغیرهای کلان کشور آمریکا پرداختند، اشاره نمود. مدل های پارامتر متغیر در طول زمان (TVP)، روش های فضا حالت (مانند فیلتر کالمن)، را به کار می گیرند که این موضوع، عموماً در تحقیقات تجربی اقتصاد کلان در راستای تجزیه و تحلیل ساختاری و پیش بینی استفاده می شود. چنانچه مجموعه بزرگی از داده ها به منظور پیش بینی متغیرهای کلان اقتصادی استفاده گردد، مدل های TVP تمایل به بیش برآزشی در داخل نمونه دارند؛ لذا عملکرد پیش بینی ضعیفی در خارج از نمونه خواهند داشت. برای تصحیح این کاستی ها در مدل های TVP از مدل های DMS و DMA، استفاده شده است (Aye *et al.*, 2015)؛ همچنین بر اساس نتایج تحقیقات (Dadashi *et al.*, 2020) و (Jafari Eskandari and Rohii, 2017). سعی شده است در قالب مدل های مارکوف سوچینگ تأثیر رشد اقتصادی بر ریسک اعتباری را در مدل طراحی شده مورد ارزیابی قرار گیرد؛ اما جهت ارتقای نتایج رشد اقتصادی در رژیم های مختلف اقتصادی در مدل لحاظ شده است.

قاسمی ارمکی و همکاران (Ghasemi Armaky et al., 2022)، اقدام به توسعه و تبیین نظام اعتبارسنجی مشتریان بانک‌ها بر اساس مدل‌های هیبریدی فرایادگیر: مطالعه موردی بانک ملت نمودند. بدین نتیجه دست یافتند که ویژگی‌هایی همچون میزان وثیقه، نوع وثیقه و میزان تسهیلات به ترتیب مهم‌ترین ویژگی‌ها در تشخیص مشتریان خوب (دارای ریسک اعتباری کم) از بد (دارای ریسک اعتباری بالا)، بوده‌اند.

ترابیان و همکاران (Torabian et al., 2022)، اقدام به بررسی مدیریت ریسک اعتباری با استفاده از روش‌های رگرسیون لاجیت و اعتبارسنجی و رتبه‌بندی مشتریان حقیقی بانک صادرات پرداختند. در تحقیق خود مشخصاتی نظیر سن، جنسیت، مبلغ و وثیقه تسهیلات به‌عنوان متغیرهای مستقل در نظر گرفته شدند. این پژوهش رابطه بین نتایج کسب شده از این مدل و وضعیت اعتباری مشتریان انتخاب شده را مورد مطالعه قرار می‌دهد. نتایج حاصل نشان می‌دهد که متغیرهای سن و تحصیلات بر سطح ریسک اعتباری و رتبه‌بندی آن‌ها تأثیر می‌گذارد، درحالی‌که دیگر متغیرهای ذکر شده با وضعیت اعتباری مشتری رابطه معناداری دارد.

مرادی و همکاران (Moradi et al., 2022)، در این پژوهش با در نظر گرفتن جابه‌جاشدن مشتری در طول زمان در گروه‌های مختلف کم‌ریسک، ریسک متوسط و ریسک بالا و با به‌کارگیری روش‌های تحلیل داده‌های بزرگ، الگوهای رفتار پویای مشتریان را استخراج نموده‌اند. برای این منظور، اطلاعات مشتریان حقیقی سه بانک مورد بررسی قرار گرفت و نتایج نشان داد که مدل با درجه حساسیت ۹۲/۱ درصد و درجه تشخیص ۸۹/۱ درصد از کارایی بالایی برخوردار است و در مقایسه با مدل‌های پروبیت، لاجیت، و شبکه عصبی بهتر عمل می‌کند و کارایی بالاتری دارد. دستاورد این پژوهش، تشخیص الگوهای پویای ریسک اعتباری مشتریان است.

داداشی و همکاران (Dadashi et al., 2020)، به بررسی ریسک اعتباری با استفاده از نسبت مانده واقعی مطالبات غیرجاری و با تمرکز بر مجموعه‌ای گسترده از متغیرها شامل متغیرهای مالی، غیرمالی، خصوصیتی قراردادهای حسابرسی و اقتصادی، در نمونه‌ای از ۶۷۷ پرونده تسهیلاتی مشتریان حقوقی یک بانک دولتی برای سال‌های ۱۳۸۵ تا ۱۳۹۶ مورد توجه قرار گرفت. بر اساس نتایج حاصله، در انتخاب متغیرهای تأثیرگذار بر ریسک اعتباری، الگوریتم لاس و با عملکرد بهتر به شناسایی ۱۰ متغیر کلیدی از گروه متغیرهای مالی، اقتصادی و حسابرسی منتهی شد. با این وجود نتایج آموزش این ویژگی‌ها توسط مدل ماشین بردار و درخت تصمیم که بیانگر بهترین نتایج در قالب الگوریتم لاس و به همراه درخت تصمیم هستند، ضریب اهمیت اندکی را برای متغیرهای حسابرسی در نظر می‌گیرند. از این رو استفاده از

الگوریتم لاس و به همراه درخت تصمیم با تمرکز بر متغیرهای مالی و اقتصادی می‌تواند از کفایت لازم برخوردار باشد.

نظر آقایی و همکاران (Nazaraghaei et al., 2019)، در مدلی عوامل مهم و مؤثر در رفتار اعتباری مشتریان را ارائه داده‌اند. در این مدل از شبکه عصبی و درخت تصمیم فازی استفاده شده است. نتایج تحقیق آن‌ها نشان می‌دهد که درآمد و تراکنش‌های مالی مشتریان بالاترین اهمیت را در تعیین ریسک اعتباری مشتریان دارد و نیز درخت تصمیم فازی با روش بگینگ از دقت بالاتری در مقایسه با روش شبکه عصبی و درخت تصمیم فازی معمولی برخوردار است.

بارا و روجیرو (Barra and Ruggiero, 2022)، به بررسی عوامل مؤثر بر ریسک اعتباری بانک‌ها در کشور ایتالیا پرداختند. بر اساس نتایج، نوع حساب، مانده حساب، میزان معوقات و نرخ بهره وام دریافتی بر ریسک اعتباری تأثیر گذارند؛ همچنین بر اساس نتایج رقابت در سیستم بانکی بر ریسک اعتباری تأثیر نامطلوب دارد.

نگو و همکاران (Ngo et al., 2021)، به بررسی عوامل مؤثر بر ریسک اعتباری در وام‌دهی بانک‌های تجاری پرداختند. نتایج نشان داد که سودآوری و تورم اثرات مثبتی بر ریسک اعتباری دارند، در حالی که سرمایه بانک، اندازه بانک، رشد اقتصادی و نسبت وام به سپرده اثرات منفی بر این شاخص دارند.

متدین و همکاران (Motedayen et al., 2022)، اقدام به شناسایی و ارزیابی عوامل مؤثر بر ریسک اعتباری با استفاده از رویکرد رگرسیون لجستیک چندجمله‌ای نمودند. داده‌های نهایی شاخص‌ها شامل ۷۳۳۰ پرونده مشتریان طبیعی بانک ملت جمع‌آوری شد و از رگرسیون لجستیک چندجمله‌ای در بررسی شاخص‌های ارزیابی ریسک اعتباری مشتریان بانک در چهار کلاس بهره گرفته شد. نتایج مدل برآورد شده نشان می‌دهد که شاخص‌های جنسیت، میزان تسهیلات، سن، مدت اقساط، وام قبلی، شغل، مدت بازپرداخت وام، تعداد اقساط، مقدار هر قسط، تمدید وام، نوع وثیقه، میانگین مانده، نرخ تسهیلات، نوع تسهیلات و سطح تسهیلات تأثیر به‌سزایی بر ریسک اعتباری دارد.

۳- روش شناسایی پژوهش

جامعه آماری تحقیق شامل مشتریان بانک تجارت می‌باشد که از اطلاعات ۱۰۵ هزار مشتری بانک جهت طراحی مدل ریسک اعتباری بهره گرفته شد. داده‌های تحقیق شامل اطلاعات مربوط به مشتریان حقیقی و حقوقی، درخواست نوع سرویس موردنیاز، نحوه انجام خدمات موردنیاز ارائه شده است. جامعه مشتریان بانک تجارت طی دوره ۵ ساله ۱۳۹۶ تا ۱۴۰۰ مورد بررسی قرار گرفته است. برنامه‌نویسی و

اجرای الگوریتم در محیط نرم‌افزار متلب می‌باشد. در این مقاله ۲ مدل اقتصادسنجی به کار گرفته شده است که کاربرد هر رویکرد در **جدول (۲)**، تشریح شده است.

جدول (۲) کاربرد مدل‌های تحقیق

Table (2) Application of research models

کاربرد	روش
شناسایی متغیرهای غیرشکونده جهت تفکیک مشتریان بانک	BMA, TVP-DMA ¹ , TVP-DMS ²
جهت بررسی متغیرهای غیرشکونده در رژیم‌های مختلف اقتصادی	MS-VAR

در ادامه به شرح مختصری از این رویکردها پرداخته شده است:

مدل میانگین‌گیری پویا با استفاده از میانگین احتمال حضور هر متغیر اقدام به طراحی بهترین مدل جهت پیش‌بینی ریسک اعتباری می‌نماید. در این رویکرد از مباحث تئوریک فیلتر کالمن^۳ - مدل‌های فضا حالت و رویکردهای MCMCMC^۴ بهره گرفته می‌شود. پیش‌بینی یک متغیر در زمان t که شامل ضریب و احتمال وقوع آن است بر اساس اطلاعات $t-1$ ، تصحیح شده و بهترین برآورد برای دوره t محاسبه می‌گردد (Koop, 2012). در راستای استفاده از این روش‌ها و به‌منظور معرفی برتری‌های این مدل اشاره به مواردی، ضروری به نظر می‌رسد:

اول اینکه ضرایب تخمین‌زن‌ها می‌توانند در طول زمان تغییر کنند؛ به‌عنوان نمونه می‌توان گفت که شیب منحنی ریسک اعتباری در طول زمان تغییر می‌کند؛ این تغییر در ضرایب در سری‌های زمانی با شکست ساختاری متعدد کارایی بسیار بالایی از خود نمایش می‌دهند. در اقتصاد ایران و سیستم بانکی ایران به علت تنش‌ها و شوک‌های متعدد خارجی و داخلی به‌کارگیری این رویکردها از توجیه تجربی بالایی برخوردار است (Stock and Watson, 2006).

دوم اینکه مدل‌های کلاسیک به علت مشکل خطای تصریح، هم خطی و کاهش درجه آزادی توانایی برآورد مدل در مقیاس تعداد بزرگ متغیر را ندارد (Groen et al., 2013) و (Stock and Watson, 1998). در صورت وجود m متغیر، امکان برآورد $2m$ مدل وجود دارد. در چنین شرایطی، بهره‌گیری از مدل‌های TVP بیزی از توجیه کافی برخوردار است (Huber et al., 2021)، (Koop et al., 2019)، (Korobilis, 2021) و (Baur and Glover, 2014). مهم‌تر از آن اینکه قدرت سیگنال‌دهی هر متغیر در برخی از بازه‌های زمانی معتبر بوده و از یک متغیر در تمامی بازه‌های زمانی

1. Time-Varying Parameters Dynamic Model Averaging
 2. Time-Varying Parameters Dynamic Model Selection
 3. Kalman Filter
 4. Metropolis-Coupled Markov Chain Monte Carlo

نمی‌توان به‌عنوان متغیر غیرشککننده بهره برد (Stock and Watson, 2006). گاراتا و همکاران (Garratt et al., 2011)، مدل‌ها در مقاطع مختلف قابلیت تعمیم کلی ندارد. در یک مطالعه دیگر برای بازار سهام پسران و تیمرمن (Pesaran and Timmermann, 2000)، اثبات نمودند دقت مدل‌ها در بازه‌های زمانی مختلف دچار نوسان شده و از ثبات بالایی برخوردار نیستند. در چنین شرایط، مدل‌های اقتصادسنجی کلاسیک تخمین‌های کارایی را ارائه نمی‌نمایند (Koop and Korobilis, 2011). استفاده از مدلی که بتواند این تعداد از مدل‌ها را به‌طور هم‌زمان تخمین بزند، هدف این مطالعه است که از مدل پویای میانگین‌گیری پویا، انتخابی و بیزی پیشنهادی رافتری و همکاران (Raftery et al., 2010)، می‌شود.

مدل MS-VAR¹ توسط (Hamilton, 1989) برای اولین بار ارائه گردید. این مدل یکی از کاربردی‌ترین مدل‌های غیرخطی در مباحث سری زمانی است. مدل MS-VAR بر اساس تعداد متغیرها، اقدام به برآورد می‌نماید و به عبارتی چند معادله‌ای است. این رویکرد شکست ساختاری در سری‌های زمانی را در برآورد مدل در نظر می‌گیرد. به همین دلیل، مدل‌های VAR² و مدل VECM³ که این تغییرات را در نظر نمی‌گیرند، مناسب نیستند (Kuck and Schweikert, 2017). این روش‌ها زمانی کاربرد دارند که زمان دقیق شکست ساختاری در متغیرها مشخص گردد که در بیش‌تر موارد این اطلاعات موجود نیست (Ghaderi Moghaddam et al., 2022).

۴- تجزیه و تحلیل داده‌ها

باتوجه به اینکه مدل‌های DMS و DMA به مقادیر گذشته ضرایب و احتمال وابسته هستند. در جدول (۳)، به تحقیقاتی که از این مقادیر بهره گرفته‌اند، اشاره شده است.

جدول (۳) مقادیر (α, λ) در مدل‌های DMS و DMA
Table (3) Values (α, λ) in DMS and DMA models

محققین	مقادیر α و λ
کوپ و همکاران (Koop et al., 2020)، دی فیلیپو (Di Filippo, 2015)، آی و همکاران (Aye et al., 2015).	$(\alpha = 0/95, \lambda = 1)$
کوپ و کوروبیلیس (Koop and Korobilis, 2011)، کوپ و کوروبیلیس (Koop and Korobilis, 2009).	$(\alpha = 1, \lambda = 1)$

1. Markov-Switching Vector Autoregressive
2. Vector Autoregressive
3. Vector Error Correction Model

کوپ و کوروبیلیس (Koop and Korobilis, 2011)، کوپ و کوروبیلیس
 Ferreira and Palma, (2012)، فریرا و پالما (Koop and Korobilis, 2012)،
 بانسیک و مورتو (Buncic and Moretto, 2015) و ناصر و علاعلی (2015)
 (Naser and Alaali, 2018).

$$(\alpha = 0/99, \lambda = 1)$$

رافتری و همکاران (Raftery et al., 2010)، کوپ و کوروبیلیس (Koop and
 Korobilis, 2012)، بلمونته و کوپ (Belmonte and Koop, 2014)، فریرا و
 پالما (Ferreira and Palma, 2015)، دی فیلیپو (Di Filippo, 2015)، آی و
 همکاران (Aye et al., 2015)، رایس و کرن (Risse and Kern, 2016)،
 ناصر (Naser, 2014)، دراچل (Drachal, 2016) و ناصر و علاعلی (Naser
 and Alaali, 2018).

$$(\alpha = \lambda = 0/99)$$

نیکولتی و پاسارو (Nicoletti and Passaro, 2012)، کوپ و کوروبیلیس
 Belmonte and Koop, (2012)، بلمونته و کوپ (Koop and Korobilis, 2012)
 (2014)، فریرا و پالما (Ferreira and Palma, 2015)، دی فیلیپو (Di
 Filippo, 2015)، ناصر (Naser, 2014)، باور و همکاران (Baur et al.,
 2016) و دراچل (Drachal, 2016).

$$(\alpha = \lambda = 0/95)$$

نیکولتی و پاسارو (Nicoletti and Passaro, 2012)، باور و همکاران (Baur
 et al., 2016) و دراچل (Drachal, 2016).

$$(\alpha = \lambda = 0/90)$$

در ادامه نتایج اعمال λ و α های مختلف جهت تبیین مدل بهینه ارائه شده است. λ و α های مختلف موجب برآورد ضریب‌های متفاوت و به تبع آن پیش‌بینی متفاوتی برای ریسک اعتباری حاصل خواهد شد. در این بخش، از پیش‌بینی درون نمونه‌ای بهره گرفته شده است؛ چرا که هدف تعیین مدل بهینه جهت متغیرهای غیرشکننده است. در جدول (۳)، جهت ایجاز در کلام نتایج مدل‌های کلاسیک مانند مدل‌های خودرگرسیون برداری، خودرگرسیون برداری بیزین و حداقل مربعات جزئی ارائه نشده است؛ چون این مدل‌ها نسبت به مدل‌های میانگین‌گیری بیزین از خطای بالاتری برخوردار بودند.

جدول (۴) معیارهای عملکرد پیش‌بینی در افق‌های پیش‌بینی مختلف

Table (4) Prediction performance criteria in different prediction horizons

h = 1						
LOG (PL)	MAFE	MSFE	MAPE	FEV	Bias	
۶۸/۹۵۸	۰/۰۷۱	۰/۰۰۹	۰/۱۸۷	۰/۰۰۹	-۰/۰۱۷	TVP – AR(1) – X DMA ($\alpha = \lambda = 0/99$)
۷۶/۳۰۹	۰/۰۶۲	۰/۰۰۷	۰/۱۸۳	۰/۰۰۷	-۰/۰۱۴	TVP – AR(1) – X DMA ($\alpha = \lambda = 0/95$)
۷۸/۰۰۱	۰/۰۵۷	۰/۰۰۶	۰/۱۶۸	۰/۰۰۶	-۰/۰۱۳	TVP – AR(1) – X DMA ($\alpha = \lambda = 0/90$)
۶۹/۷۳۹	۰/۰۷۶	۰/۰۱۱	۰/۱۹۱	۰/۰۱۰	-۰/۰۱۸	TVP – AR(1) – X DMS ($\alpha = \lambda = 0/99$)
۸۰/۴۸۳	۰/۰۶۷	۰/۰۰۸	۰/۱۶۹	۰/۰۰۸	-۰/۰۱۱	TVP – AR(1) – X DMS ($\alpha = \lambda = 0/95$)

۱۰۰/۳۹۸	۰/۰۵۳	۰/۰۰۶	۰/۱۵۲	۰/۰۰۶	۰/۰۱۵	TVP – AR(1) – X DMS ($\alpha = \lambda = 0/90$)
۶۶/۵۹۹	۰/۰۷۳	۰/۰۱۰	۰/۱۹۴	۰/۰۰۹	۰/۰۱۶	TVP – AR(1) – X DMA ($\alpha = 0.99, \lambda = 1$)
۷۱/۰۴۵	۰/۰۶۷	۰/۰۰۸	۰/۲۲۱	۰۰۷	۰/۰۲۳	TVP – AR(1) – X DMA ($\alpha = 0.95, \lambda = 1$)
۱۰۹/۶۹۸	۰/۰۱۴	۰/۰۰۲	۰/۱۰۶	۰/۰۲۱	۰/۰۰۵	TVP – AR(1) – X BMA($\alpha = \lambda = 1$)
h = ۴						
۶۵/۳۲۱	۰/۰۷۴	۰/۰۱۰	۰/۱۸۳	۰/۰۱۰	۰/۰۲۰	TVP – AR(1) – X DMA ($\alpha = \lambda = 0/99$)
۷۲/۱۵۴	۰/۰۶۲	۰/۰۰۷	۰/۱۷۱	۰/۰۰۷	۰/۰۱۵	TVP – AR(1) – X DMA ($\alpha = \lambda = 0/95$)
۷۳/۳۶۷	۰/۰۵۷	۰/۰۰۶	۰/۱۶۰	۰/۰۰۶	۰/۰۱۴	TVP – AR(1) – X DMA ($\alpha = \lambda = 0/90$)
۶۵/۴۱۵	۰/۰۷۹	۰/۰۱۱	۰/۱۸۷	۰/۰۱۱	۰/۰۲۰	TVP – AR(1) – X DMS ($\alpha = \lambda = 0/99$)
۷۵/۰۷۸	۰/۰۶۸	۰/۰۰۸	۰/۱۶۷	۰/۰۰۸	۰/۰۰۹	TVP – AR(1) – X DMS ($\alpha = \lambda = 0/95$)
۹۲/۰۴۵	۰/۰۵۷	۰/۰۰۷	۰/۱۶۱	۰/۰۰۷	۰/۰۰۹	TVP – AR(1) – X DMS ($\alpha = \lambda = 0/90$)
۶۳/۰۳۶	۰/۰۷۴	۰/۰۱۰	۰/۱۵۸	۰/۰۰۹	۰/۰۱۵	TVP – AR(1) – X DMA ($\alpha = 0/99, \lambda = 1$)
۶۸/۷۱۴	۰/۰۶۶	۰/۰۰۷	۰/۱۹۴	۰/۰۰۷	۰/۰۲۱	TVP – AR(1) – X DMA ($\alpha = 0/95, \lambda = 1$)
۹۳/۲۹۵	۰/۰۱۶	۰/۰۰۳	۰/۰۹۹	۰/۰۰۲	۰/۰۱۴	TVP – AR(1) – X BMA($\alpha = \lambda = 1$)
h = ۸						
۶۱/۵۱۴	۰/۰۷۶	۰/۰۱۰	۰/۵۱۶	۰/۰۱۰	۰/۰۱۰	TVP – AR(1) – X DMA ($\alpha = \lambda = 0/99$)
۶۸/۱۴۱	۰/۰۶۲	۰/۰۰۷	۰/۳۷۸	۰/۰۰۷	۰/۰۱۲	TVP – AR(1) – X DMA ($\alpha = \lambda = 0/95$)
۶۹/۱۳۷	۰/۰۵۶	۰/۰۰۶	۰/۲۹۸	۰/۰۰۶	۰/۰۱۳	TVP – AR(1) – X DMA ($\alpha = \lambda = 0/90$)
۵۹/۵۰۲	۰/۰۸۰	۰/۰۱۱	۰/۵۱۹	۰/۰۱۱	۰/۰۰۹	TVP – AR(1) – X DMS ($\alpha = \lambda = 0/99$)
۷۱/۶۹۴	۰/۰۷۱	۰/۰۱۰	۰/۴۳۲	۰/۰۰۹	۰/۰۰۸	TVP – AR(1) – X DMS ($\alpha = \lambda = 0/95$)
۸۵/۲۵۸	۰/۰۶۱	۰/۰۰۸	۰/۴۰۲	۰/۰۰۸	۰/۰۱۱	TVP – AR(1) – X DMS ($\alpha = \lambda = 0/90$)
۶۳/۱۷۷	۰/۰۷۳	۰/۰۰۹	۰/۵۳۴	۰/۰۰۹	۰/۰۱۰	TVP – AR(1) – X DMA ($\alpha = 0.99, \lambda = 1$)
۶۸/۱۹۷	۰/۰۶۲	۰/۰۰۷	۰/۴۴۵	۰/۰۰۶	۰/۰۱۲	TVP – AR(1) – X DMA ($\alpha = 0.95, \lambda = 1$)
۷۸/۲۵۵	۰/۰۱۶	۰/۰۰۲	۰/۰۷۴	۰/۰۰۵	۰/۰۰۲	TVP – AR(1) – X BMA($\alpha = \lambda = 1$)

بر اساس نتایج مدل BMA در تمامی حالتها از عملکرد مطلوبتری برخوردار است. در نتیجه در ادامه به بررسی نتایج مدل BMA پرداخته می‌شود. در این تحقیق بر اساس مطالعات اسپینوزا و پراساد (Espinoza and Prasad, 2010)، لوئیز و همکاران (Louzis et al., 2010)، بک و همکاران (Beck et al., 2013) و بارا و روجیرو (Barra and Ruggiero, 2022)، برای تعریف ریسک اعتباری از نسبت وام‌های غیرجاری به کل وام‌ها بهره گرفته شده است. در ادامه اقدام به بررسی بهترین مدل برآوردی نموده و ضرایب متغیر و احتمال وقوع هر ضریب را در طی زمان ارائه می‌کنیم. در ادامه اقدام به بررسی بهترین مدل برآوردی نموده و ضرایب متغیر و احتمال وقوع هر ضریب را در طی زمان ارائه می‌کنیم. در این رویکرد ابتدا تمامی حالت‌های ممکن حضور متغیرهای توضیحی بر روی متغیر وابسته رگرسیون می‌گردد. در این روش چندین نکته حائز اهمیت است. اول اینکه یک متغیر در تمامی مدل‌های

ممکن حضور ندارد. نکته دوم اینکه لزوماً متغیر مذکور در تمامی مدل‌هایی که حضور دارد تأثیر معناداری بر متغیر وابسته ندارد؛ براین اساس نسبت تعداد مدل‌هایی که متغیر مذکور معنادار شده به تعداد مدل‌هایی که حضور دارد، شاخصی جهت حضور متغیر مذکور در مدل بهینه است. سوم اینکه با افزایش تعداد متغیرها محاسبه تمامی حالت‌ها امکان‌پذیر نیست. در نتیجه بر اساس دیدگاه سالای مارتین از یک تعداد برآورد به بعد (حدود ۵ تا ۱۰ میلیون رگرسیون)، نسبت حضور معنادار یک متغیر به تمامی حالت‌ها، به سمت یک عدد مشخص میل می‌نماید و در نتیجه نیازی به برآورد تمامی حالت‌ها نمی‌باشد. در نهایت نیاز به یک آستانه تصمیم‌گیری جهت حذف متغیرها وجود دارد؛ برای تعیین حد بهینه از نسبت k تقسیم بر کل متغیرها بهره گرفته خواهد شد (k تعداد متغیرهای پیشنهادی است که از دیدگاه محقق بالاترین تأثیر را بر متغیر وابسته دارند). این k تجربی بوده و بر اساس دیدگاه محقق انتخاب می‌شود. برای دستیابی به نتیجه می‌بایست محاسبات روی تمام مدل‌ها در فضای مدل انجام شود. با توجه به تعداد متغیرهای بررسی شده، مدل‌های موجود (بر اساس حضور یا عدم حضور هر متغیر)، در فضای مدل برابر ۲۳۳ مدل می‌باشد که بیش از ۸,۵۸۹,۹۳۴,۵۹۲ مدل رگرسیون است. به عبارت دیگر فضای مدل شامل ۲۳۳ مدل می‌باشد که با توجه به فرض عدم اطمینان مدل یعنی به دور از اعمال نظر شخصی در انتخاب مدل می‌بایست همه مدل‌ها بررسی شده و از اطلاعات همه مدل‌ها برای دستیابی به نتیجه استفاده شود. به پیروی از سالای مارتین (Sala-i-Martin, 1997)، مقدار k در این مقاله مساوی هشت در نظر گرفته شده است. این عدد بیانگر این است که انتظار می‌رود از میان m متغیر هشت متغیر بیش‌ترین احتمال اثرگذاری دارند. در ابتدا با به دست آوردن نمونه‌ای شامل ۲ میلیون رگرسیون از فضای مدل، ضرایب و احتمال پسین هر متغیر محاسبه شد. در ادامه ۱ میلیون رگرسیون به نمونه اول اضافه شده و محاسبات برای ۳ میلیون رگرسیون انجام شد و ضرایب و احتمالات پسین به دست آمد. با ادامه این روند در نمونه‌ای که شامل ۵ میلیون رگرسیون بود، همگرایی حاصل گردید. براین اساس دیگر نیازی به افزایش حجم نمونه جهت تعیین متغیرهای غیرشکندنده وجود ندارد **جدول (۵)**. جهت غیرشکندنده معرفی نمودن یک متغیر دو شرط لازم است تحقق یابد.

(۱) افزایش احتمال پسین هر متغیر نسبت به احتمال پیشین

(۲) بالا بودن سطح احتمال پسین از سطح آستانه تعریف شده ($0/۲۴ = ۳۳ \div ۸ =$ سطح آستانه اولیه).

در مرحله اول ۱۶ متغیر غیرشکندنده شناسایی شدند و در مرحله دوم با این متغیرها که احتمال

پسین بالاتری نسبت به احتمال پیشین دارند، محاسبات ارائه شده است.

جدول (۵) مرحله اول فرآیند نمونه‌گیری و محاسبات با فرض $\bar{K} = 8$

Table (5) The first stage of the sampling process and calculations with the assumption of $\bar{K} = 8$

نمونه اول شامل ۲ میلیون		نمونه اول شامل ۴ میلیون		متغیر
رگرسیون	رگرسیون	رگرسیون	رگرسیون	
-۰/۰۰۲	-۰/۱۰۷	-۰/۱۳۲	-۰/۱۲۱	تعداد حساب
-۰/۰۰۴	-۰/۰۷۳	-۰/۰۰۳	-۰/۰۹۲	نوع حساب
-۰/۳۱۹	-۰/۵۳۵	-۰/۱۷۶	-۰/۸۷۸	مانده حساب کوتاه مدت
-۰/۰۲۹	-۰/۴۷۰	-۰/۰۳۴	-۰/۸۸۱	مانده حساب بلندمدت
-۰/۰۸۰	-۰/۲۰۷	-۰/۰۵۱	-۰/۶۸۸	مانده حساب قرض الحسنه
-۰/۴۲۸	-۰/۱۱۸	-۰/۲۰۹	-۰/۱۵۵	میزان وام دریافتی از بانک
-۰/۱۴۷	-۰/۲۰۷	-۰/۷۸۸	-۰/۲۳۴	تعداد وام دریافتی
-۰/۱۱۱	-۰/۱۹۹	-۰/۰۶۸	-۰/۳۶۲	میزان معوقات
-۰/۴۱۷	-۰/۱۴۵	-۰/۱۲۷	-۰/۱۶۹	سود وام دریافتی
-۰/۰۲۴	-۰/۰۷۰	-۰/۰۲۳	-۰/۱۴۶	نرخ بهره وام دریافتی
-۰/۰۰۰	-۰/۱۲۲	-۰/۴۰۰	-۰/۲۴۷	نرخ بهره پرداختی
-۰/۰۰۶	-۰/۲۲۲	-۰/۰۰۷	-۰/۴۴۱	میزان استفاده از موبایل بانک
-۰/۵۹۹	-۰/۴۰۲	-۰/۱۲۷	-۰/۴۶۱	میزان استفاده از اینترنت بانک
-۰/۰۳۹	-۰/۳۳۰	-۰/۰۲۲	-۰/۵۶۲	گردش حساب
-۰/۶۹۲	-۰/۳۷۹	-۰/۷۱۸	-۰/۴۱۹	سابقه چک برگشتی
-۰/۰۱۵	-۰/۱۷۳	-۰/۰۲۵	-۰/۲۳۰	مانده جاری
-۰/۰۰۰	-۰/۱۵۲	-۰/۰۰۰	-۰/۲۲۵	مانده حساب غیر جاری
-۰/۰۵۹	-۰/۱۳۸	-۰/۱۸۸	-۰/۳۳۰	قدمت تاریخ حساب
-۰/۴۸۹	-۰/۱۶۲	-۰/۹۵۵	-۰/۴۱۲	مشتریان حقیقی
-۰/۱۸۹	-۰/۱۹۰	-۰/۰۴۴	-۰/۳۹۵	مشتریان حقوقی
-۰/۰۰۰	-۰/۱۰۹	-۰/۰۰۰	-۰/۱۲۸	تعداد تراکنش‌ها
-۰/۱۲۹	-۰/۱۲۳	-۰/۵۴۶	-۰/۱۴۸	تنوع استفاده از خدمت
-۰/۰۱۷	-۰/۲۰۵	-۰/۰۱۴	-۰/۲۳۹	فاصله زمانی بین دو تراکنش (تناوب استفاده از خدمات)
-۰/۰۰۲	-۰/۱۰۶	-۰/۰۳۴	-۰/۳۹۸	VIP یا عادی بودن مشتری
-۰/۰۶۰	-۰/۱۹۱	-۰/۰۳۱	-۰/۲۲۶	محل سکونت (استانی)
-۰/۰۳۴	-۰/۱۶۴	-۰/۰۲۰	-۰/۱۸۳	محل سکونت (محلی)
-۰/۱۸۷	-۰/۲۱۷	-۰/۰۵۷	-۰/۱۹۲	تعداد بعد خانواده
-۰/۰۰۲	-۰/۰۷۳	-۰/۰۰۲	-۰/۲۶۳	نوع شغل (پایگاه اجتماعی)
-۰/۰۰۰	-۰/۲۳۹	-۰/۰۰۰	-۰/۱۹۸	جنسیت
-۰/۰۰۶	-۰/۲۲۲	-۰/۰۰۷	-۰/۳۹۵	تحصیلات
-۰/۰۰۶	-۰/۵۰۲	-۰/۰۱۳	-۰/۱۲۷	سن
-۰/۳۹۴	-۰/۱۳۰	-۰/۲۱۶	-۰/۳۳۲	مالک یا غیر مالک بودن
-۰/۰۰۲	-۰/۱۵۷	-۰/۰۰۱	-۰/۱۲۹	مجرد و متأهل بودن

در مرحله اول با استفاده از شروط دوگانه **جدول (۵)**، جهت تعیین نمودن متغیرهای غیرشکننده، ۱۶ متغیر انتخاب شدند. یعنی ۱۶ متغیر مقدار احتمال پسین بیش‌تری نسبت به احتمال پیشین داشتند و این ۱۶ متغیر سطح احتمال پسین بالاتر از سطح آستانه ۰/۲۴ داشتند. در ادامه مراحل انجام شده در مرحله اول در مرحله دوم بر روی ۱۶ متغیر باقیمانده اعمال شده است. در مرحله دوم نیز ابتدا یک نمونه شامل ۱ میلیون رگرسیون بر روی ۱۶ متغیر منتخب اعمال شده و محاسبات ضرایب و احتمالات پسین صورت گرفته است. در ادامه با اعمال دو شرط مذکور ($0/50 = 0/16 \div 8 =$ سطح آستانه ثانویه)، مهم‌ترین متغیرهای مؤثر بر ریسک اعتباری شناسایی خواهند شد. نتایج در **جدول (۶)**، می‌توان دید.

جدول (۶) مرحله دوم فرآیند نمونه‌گیری و محاسبات با فرض $\bar{K} = 8$

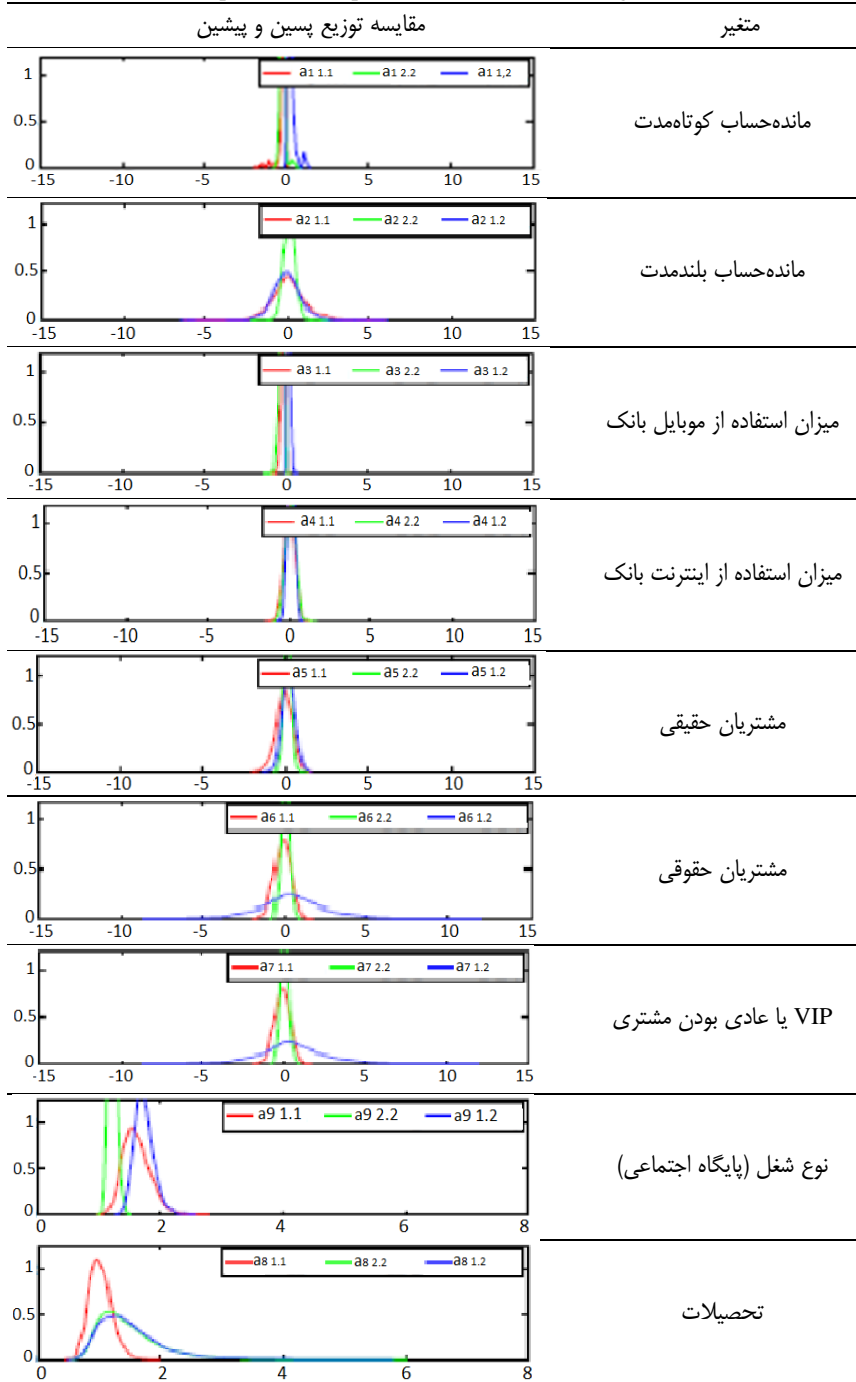
Table (6) The second stage of the sampling process and calculations assuming $\bar{K} = 8$

نمونه اول شامل ۲ میلیون		نمونه اول شامل ۱ میلیون		متغیر
رگرسیون	ضریب پسین	رگرسیون	ضریب پیشین	
احتمال پسین		احتمال پیشین		
۰/۴۹۹	۰/۰۳۵	۰/۲۸۱	۰/۰۲۰	مانده حساب کوتاه‌مدت
۰/۷۰۲	۰/۰۵۲	۰/۴۵۵	۰/۲۷۱	مانده حساب بلندمدت
۰/۲۱۹	۰/۰۶۹	۰/۱۸۵	۰/۳۶۴	مانده حساب قرض‌الحسنه
۰/۲۲۳	۰/۷۳۲	۰/۱۶۹	۰/۰۹۴	میزان موقوفات
۰/۵۱۶	۰/۹۷۴	۰/۱۴۷	۰/۰۱۳	میزان استفاده از موبایل بانک
۰/۵۹۹	۰/۰۴۵	۰/۲۰۳	۰/۰۰۰	میزان استفاده از اینترنت بانک
۰/۲۳۴	۰/۰۱۴	۰/۲۷۵	۰/۱۱۰	گردش حساب
۰/۱۰۶	۰/۰۳۵	۰/۰۹۰	۰/۰۰۲	سبقه چک برگشتی
۰/۱۸۷	۰/۰۲۰	۰/۲۰۳	۰/۰۰۰	مانده حساب غیرجاری
۰/۱۹۶	۰/۰۵۸	۰/۱۸۹	۰/۰۰۵	قدمت تاریخ حساب
۰/۵۳۸	۰/۰۰۲	۰/۴۲۷	۰/۰۰۵	مشتریان حقیقی
۰/۵۰۶	۰/۰۰۰	۰/۴۵۱	۰/۳۳۵	مشتریان حقوقی
۰/۴۳۹	۰/۰۲۶	۰/۳۹۱	۰/۱۷۳	VIP یا عادی بودن مشتری
۰/۴۶۳	۰/۲۰۸	۰/۱۴۷	۰/۰۰۲	نوع شغل (پایگاه اجتماعی)
۰/۵۰۴	۰/۳۴۴	۰/۲۶۰	۰/۰۰۵	تحصیلات
۰/۲۱۷	۰/۰۰۰	۰/۴۵۳	۰/۰۰۲	مالک یا غیر مالک بودن

در **جدول (۷)** توزیع پسین و پیشین متغیرهای غیرشکننده پژوهش ارائه شده است.

جدول (۷) توزیع پسین و پیشین متغیرهای غیرشکننده

Table (7) posterior and prior distribution of non-fragile variables



همان گونه که نمودارهای جدول (۷) نشان می‌دهند در متغیرهایی منتخب انطباق بالایی در توزیع پیشین، پسین و توزیع مشترک بین آن‌ها وجود دارد که این امر دلالت بر اهمیت متغیرهای مذکور در پیش‌بینی ریسک اعتباری در بانک تجارت دارد.

بر اساس تست LR نیز تعداد رژیم بهینه را تعیین می‌کند. آماره تست LR به‌وسیله رابطه‌ی $LR=2|\ln LMS-AR - \ln LAR|$ سنجیده شده و ارزش بحرانی آماره مبتنی بر ارزش P داویس (Davies, 1987)، که به‌وسیله گارسیا و پرون (Garcia and Perron, 1996) پیشنهاد گردیده محاسبه می‌شود. نتایج این بخش در جدول (۶)، قابل مشاهده‌است. بر اساس نتایج در ردیف آخر جدول (۸)، تفکیک به شش رژیم مورد تأیید قرار نگرفت. به‌عبارتی مدل‌های غیرخطی نسبت به مدل‌های خطی در برآورد مدل ریسک اعتباری در بانک تجارت از کارایی بالاتری برخوردارند.

جدول (۸) تست LR بررسی حال خطی‌بودن متغیرهای مدل

Table (8) LR test to check the linearity of the variables of the model

LR test statistica	MS-AR (ln LMS-AR) (دو رژیم)	AR (ln LAR) (تک رژیم)	آزمون ریسک اعتباری در دو رژیم نسبت به یک رژیم
۵۶/۱۹ ***	-۸۷/۳۴	-۱۴۵/۵۶	
LR test statistica	MS-AR (ln LMS-AR) (سه رژیم)	MS-AR (ln LMS-AR) (دو رژیم)	ریسک اعتباری در سه رژیم نسبت به دو رژیم
۱۶/۴۴ ***	-۷۰/۱۲	-۸۷/۳۴	
LR test statistica	MS-AR (ln LMS-AR) (چهار رژیم)	MS-AR (ln LMS-AR) (سه رژیم)	ریسک اعتباری در چهار رژیم نسبت به سه رژیم
۱۰/۸۷ ***	-۶۱/۱۴	-۷۰/۱۲	
LR test statistica	MS-AR (ln LMS-AR) (پنج رژیم)	MS-AR (ln LMS-AR) (چهار رژیم)	ریسک اعتباری در پنج رژیم نسبت به چهار رژیم
۷/۸۲ ***	-۵۷/۳۳	-۶۱/۱۴	
LR test statistica	MS-AR (ln LMS-AR) (شش رژیم)	MS-AR (ln LMS-AR) (پنج رژیم)	ریسک اعتباری در شش رژیم نسبت به پنج رژیم
۳/۱۱	-۵۶/۱۷	-۵۷/۳۳	

رژیم یک نوسان خیلی پایین، رژیم دو نوسان پایین، رژیم سه نوسان عادی، رژیم چهار نوسان بالا و رژیم پنج نوسان خیلی بالا را نمایش می‌دهد. در این بخش مدل ریسک اعتباری بانک صرفاً بر اساس وقفه گذشته خود متغیر در رژیم‌های مختلف مورد بررسی قرار می‌گیرد. در این مرحله هیچ متغیر توضیحی منتخبی وارد مدل ریسک اعتباری مشتریان نمی‌گردد. بر اساس نتایج تحقیق می‌توان بیان داشت که وقوع سیکل‌های تجاری شیب و عرض از مبدأ ریسک اعتباری را تغییر می‌دهد و میزان

ریسک اعتباری بانک به وضعیت اقتصادی در کشور وابسته است. در نتیجه لازم است برای تخمین مدل در رژیم‌های رکود و رونق تخمین‌های جداگانه‌ای صورت گیرد. هیچ اولویتی میان رژیم‌های مورد بررسی نیست و تفکیک انجام شده تنها در جهت توضیح‌دهندگی مدل تخمینی می‌باشد. با استفاده از مقادیر بحرانی آکائیک (Akaike, 1974)، تعداد وقفه بهینه ۳ تعیین گردید. نتایج در جدول (۹)، ارائه شده است.

جدول (۹) میزان شاخص آکائیک

Table (9) Akaike index

وقفه	آماره آکائیک
وقفه اول	-۰/۸۴۶۷
وقفه دوم	-۱/۶۰۹۷
وقفه سوم	-۱/۸۰۴۵
وقفه چهارم	-۱/۷۵۰۴

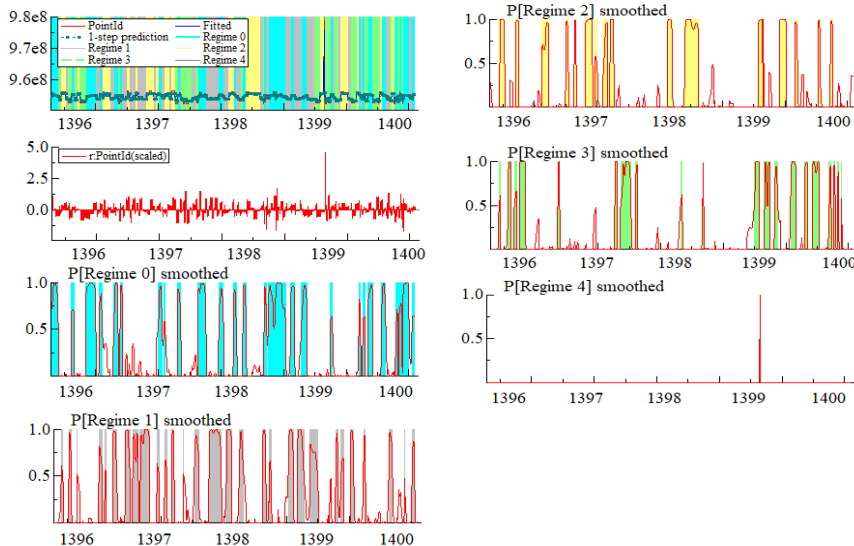
خلاصه نتایج برآورد مدل اتو رگرسیون به شرح جدول (۱۰) هست.

جدول (۱۰) تخمین پارامترهای مدل (3) AR - (5) MS متغیرهای مدل ریسک اعتباری

Table (10) Estimation of MS (5) - AR (3) model parameters of credit risk model variables

نام متغیر	مدل اول	مدل دوم	مدل سوم	مدل چهارم	مدل پنجم
جمله ثابت	۴/۲۹۸ (۰/۰۰۰) ***	۴/۷۲۵ (۰/۰۰۰) ***	۵/۹۳۴ (۰/۰۰۰) ***	۶/۳۲۶ (۰/۰۰۰) ***	۷/۳۵۷ (۰/۰۰۰) ***
(1) AR	۰/۱۲۴ (۰/۰۴۳) ***	۰/۱۳۸ (۰/۰۴۳) **	۰/۱۴۲ (۰/۰۴۱) **	۰/۱۴۷ (۰/۰۲۱) **	۰/۱۷۳ (۰/۰۰۳) **
(2) AR	-۰/۰۹۷ (۰/۰۳۲) **	-۰/۱۱۳ (۰/۰۳۶) **	-۰/۱۳۴ (۰/۰۳۲) **	-۰/۱۴۹ (۰/۰۳۱) **	-۰/۱۱۳ (۰/۰۲۳) **
(3) AR	-۰/۱۴۵ (۰/۰۵۲) *	-۰/۱۶۱ (۰/۰۴۱) **	-۰/۱۸۵ (۰/۰۳۲) **	-۰/۱۴۹ (۰/۰۳۷) **	-۰/۲۱۷ (۰/۰۲۸) **

*** در سطح ۱٪ معنی‌دار است. ** در سطح ۵٪ معنی‌دار است. * در سطح ۱۰٪ معنی‌دار است



شکل (۱) احتمالات انتقال مدل MS (2) - AR (3) متغیر ریسک اعتباری

Figure (1) Transfer probabilities of the MS (2) - AR (3) model of the credit risk

بر اساس نتایج که در جدول (۸)، ارائه گردیده است جمله ثابت مدل در رژیم‌های مختلف معنی‌دار ارزیابی شده‌است. در شکل (۱)، احتمالات حضور ریسک اعتباری توسط مدل MS-AR، در پنج رژیم به تصویر کشیده‌است؛ متغیر وابسته به احتمال وقوع و آستانه‌های ۴ گانه (برای ۵ رژیم نیاز به ۴ آستانه وجود دارد)، در رژیم‌های مختلف قرار گرفته و در هر رژیم اقدام به برآورد مدل نموده‌ایم. در ادامه متغیرهای مؤثر بر ریسک اعتباری را به مدل ریسک اعتباری اضافه می‌کنیم. برای این منظور مدل MS-AR در مقابل یک مدل (MS-ARX)، مورد آزمون قرار می‌گیرد و منظور از بردار X متغیرهای مؤثر بر ریسک اعتباری می‌باشد. در جدول (۱۱)، نتایج دقت دو حالت مقایسه شده است.

جدول (۱۱) تست LR بررسی تأثیر یا عدم تأثیر متغیرهای مؤثر بر ریسک اعتباری

Table (11) LR test to investigate the effect or lack of effect of variables affecting credit risk

LR test statistica	MS-ARX (ln MS-ARX)	MS-AR (ln L MS-AR)	
۲۱/۷۶***	-۴۱/۰۸	-۵۷/۳۳	ریسک اعتباری

*** در سطح ۱٪ معنی‌دار می‌باشد.

نتایج آزمون نشان می‌دهد مدل MS-ARX نرخ راست‌نمایی بالاتری در مقایسه به مدل MS-AR دارد در نتیجه متغیرهای شناسایی شده توانایی افزایش دقت پیش‌بینی ریسک اعتباری مشتریان را دارند. در جدول (۱۲)، نتایج تخمین مدل MS-ARX برای ریسک اعتباری ارائه شده است.

جدول (۱۲) شمول متغیرهای مؤثر بر در مدل MS-ARX ریسک اعتباری

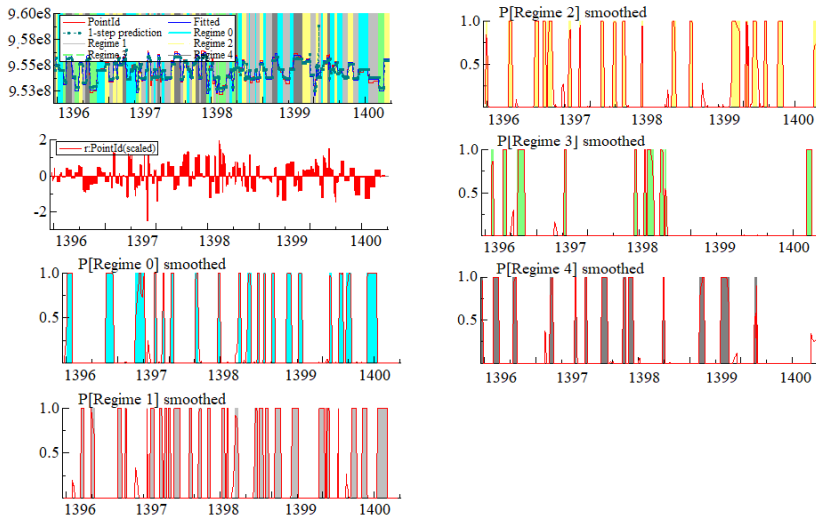
Table (12) Inclusion of variables affecting credit risk in the MS-ARX model

رژیم رونق بالا	رژیم رکود عمیق ←				
نام متغیر	مدل اول	مدل دوم	مدل سوم	مدل چهارم	مدل پنجم
عرض از مبدأ	۸/۱۷۸ (۰/۰۰۰)***	۸/۲۰۹ (۰/۰۰۰)***	۹/۲۷۸ (۰/۰۰۰)***	۱۰/۱۹۰ (۰/۰۰۰)***	۱۰/۲۲۲ (۰/۰۰۰)***
مانده حساب بلندمدت	-۰/۱۷۸ (۰/۰۶۷)*	-۰/۱۸۲ (۰/۰۵۴)*	-۰/۱۹۷ (۰/۰۳۹)**	-۰/۱۸۴ (۰/۰۵۱)*	-۰/۱۹۲ (۰/۰۴۷)**
میزان استفاده از موبایل بانک	-۰/۳۴۸ (۰/۰۰۰)***	-۰/۴۰۱ (۰/۰۰۰)***	-۰/۴۲۶ (۰/۰۰۰)***	-۰/۳۰۹ (۰/۰۰۰)***	-۰/۴۰۱ (۰/۰۰۰)***
میزان استفاده از اینترنت بانک	-۰/۱۳۴ (۰/۰۲۴)**	-۰/۱۴۷ (۰/۰۰۹)***	-۰/۱۷۷ (۰/۰۰۰)***	-۰/۱۵۶ (۰/۰۰۰)***	-۰/۲۰۹ (۰/۰۰۰)***
مشتریان حقیقی	-۰/۰۹۶ (۰/۰۲۵)**	-۰/۱۰۵ (۰/۰۲۱)**	-۰/۱۱۲ (۰/۰۰۴)***	-۰/۱۴۲ (۰/۰۰۳)***	-۰/۱۴۸ (۰/۰۰۱)***
مشتریان حقوقی	۰/۰۸۴ (۰/۰۶۶)*	۰/۰۹۹ (۰/۰۰۱)***	۰/۱۰۴ (۰/۰۰۰)***	۰/۱۱۳ (۰/۰۰۰)***	۰/۱۴۵ (۰/۰۰۰)***
VIP یا عادی بودن مشتری	-۰/۲۰۴ (۰/۰۵۷)*	-۰/۲۲۵ (۰/۰۴۲)**	-۰/۲۷۲ (۰/۰۰۰)***	-۰/۲۱۴ (۰/۰۳۶)**	-۰/۲۵۷ (۰/۰۰۰)***
نوع شغل (پایگاه اجتماعی)	-۰/۲۱۳ (۰/۰۰۰)***	-۰/۲۲۳ (۰/۰۰۰)***	-۰/۲۴۱ (۰/۰۰۰)***	-۰/۲۳۴ (۰/۰۰۰)***	-۰/۲۵۶ (۰/۰۰۰)***
تحصیلات	-۰/۰۲۶ (۰/۰۴۱)**	-۰/۰۴۵ (۰/۰۳۷)**	-۰/۰۷۴ (۰/۰۳۵)**	-۰/۰۴۸ (۰/۰۱۱)**	-۰/۰۸۹ (۰/۰۲۴)**
آماره f	۴/۶۷۴ (۰/۰۰۵)***	۷/۰۰۹ (۰/۰۰۰)***	۱۰/۲۷۵ (۰/۰۰۰)***	۵/۳۳۳ (۰/۰۰۰)***	۸/۱۳۲ (۰/۰۰۰)***

*** در سطح ۱٪ معنی دار است. ** در سطح ۵٪ معنی دار است. * در سطح ۱۰٪ معنی دار است و نبود ستاره به معنای عدم معناداری آن ضریب است.

بر اساس نتایج جدول (۱۲)، مشاهده می‌گردد که در هر پنج رژیم، مانده حساب بلندمدت، میزان استفاده از موبایل بانک، میزان استفاده از اینترنت بانک، مشتریان حقیقی، VIP یا عادی بودن مشتری، نوع شغل (پایگاه اجتماعی) و تحصیلات موجب کاهش ریسک اعتباری می‌گردند؛ اما مشتریان حقوقی تأثیر مثبتی بر ریسک اعتباری دارند؛ به عبارتی اعطای تسهیلات به بخش حقوقی موجب بالاتر رفتن ریسک اعتباری بانک تجارت می‌شود. پرداخت تسهیلات در حجم بالا، دستوری بودن این نوع وام‌ها از مهم‌ترین علل تأثیر مثبت مشتریان حقوقی بر ریسک اعتباری بانک است. بر اساس نتایج با حرکت از

سمت رونق بالا به سمت رکود عمیق میزان تأثیرگذار متغیرها بر ریسک اعتباری افزایش یافته است. به عبارتی ریسک اعتباری از حساسیت بالاتری به متغیرهای توضیح‌دهنده دارد.



شکل (۲) احتمالات انتقال مدل MS(5) - ARX(3) متغیر ریسک اعتباری با شمول متغیرهای مستقل
Figure (2) Transfer probabilities of the MS(5) - ARX(3) model of credit risk variable with the inclusion of independent variables

در جدول (۱۳)، ماتریس احتمالات انتقال از یک رژیم به رژیم دیگر ارائه شده است:

جدول (۱۳) ماتریس احتمالات انتقال از یک رژیم به رژیم دیگر

Table (13) Probability matrix of transition from one regime to another regime

ریسک اعتباری					
رژیم ۵	رژیم ۴	رژیم ۳	رژیم ۲	رژیم ۱	
۰/۰۹۶	۰/۱۹۱	۰/۱۵۴	۰/۲۷۶	۰/۳۴۶	رژیم ۱
۰/۱۲۵	۰/۱۹۸	۰/۲۵۷	۰/۳۰۶	۰/۱۱۴	رژیم ۲
۰/۰۵۸	۰/۲۰۶	۰/۳۴۵	۰/۱۸۳	۰/۲۰۸	رژیم ۳
۰/۰۱۹	۰/۳۸۶	۰/۱۳۹	۰/۱۴۹	۰/۱۵۴	رژیم ۴
۰/۷۰۲	۰/۴۱۶	۰/۱۰۵	۰/۰۸۶	۰/۱۷۸	رژیم ۵

باتوجه به نتایج جدول (۱۳)، پایدارترین رژیم در ریسک اعتباری بانک تجارت با میزان ۰/۷۰۲ رژیم رکود عمیق می‌باشد. به عبارتی سطح ریسک اعتباری بانک تجارت در وضعیت مطلوبی قرار ندارد و در اغلب بازه زمانی مورد بررسی شرایط اقتصادی کشور موجب بالاتر رفتن ریسک اعتباری در این بانک شده است.

۵- بحث و نتیجه‌گیری

سرمایه‌گذاری رابطه نزدیکی با رشد اقتصادی و به تبع آن رفاه اجتماعی دارد، تجهیز و تأمین منابع سرمایه‌گذاری مهم‌ترین نقش نظام بانکی می‌باشد. باتوجه به نقش بانک‌ها و تأثیرگذاری آن‌ها در بازار مالی و اقتصاد کشور بررسی ریسک‌هایی که نظام بانکی با آن‌ها روبه‌رو هستند از اهمیت ویژه‌ای برخوردار است. در میان ریسک‌های پیش روی بانک‌ها، ریسک اعتباری برجسته‌ترین ریسک در طول حیات بانک می‌باشد که می‌تواند عامل ورشکستگی بانک‌ها نیز باشد. براین اساس در تحقیق حاضر به مدل‌سازی عوامل مؤثر بر ریسک اعتباری در بانک تجارت اقدام شد.

اطلاعات شاخص‌های ۳۳ عامل مؤثر بر ریسک اعتباری در بانک تجارت وارد مدل‌های BMA، TVP-DMA و TVP-DMS گردید. بر اساس میزان خطا مدل BMA از بالاترین دقت برخوردار بود. پس از برآورد مدل هشت متغیر اصلی شناسایی گردید. بر اساس نتایج متغیرهای مانده حساب بلندمدت، میزان استفاده از موبایل بانک، میزان استفاده از اینترنت بانک، مشتریان حقیقی، مشتریان حقوقی، VIP یا عادی بودن مشتری، نوع شغل، تحصیلات شناسایی و به‌عنوان متغیرهای غیرشککننده تعریف گردید. در نهایت متغیرهای غیرشککننده در مدل مارکوف سوئیچینگ مورد تجزیه و تحلیل واقع و تمامی مدل‌های رگرسیون در تمامی رژیم‌ها معنادار و اعتبار خط رگرسیون در تمامی مدل‌ها مورد تأیید قرار گرفت. همچنین اکثر متغیرها تأثیر مثبت و معناداری بر وضعیت ریسک اعتباری داشته و مدل با ورود متغیرهای مذکور با بهبود همراه شد. از طرفی حالت رکود، رژیم غالب و پایدار ریسک اعتباری در بانک تجارت است. نتایج بیانگر وجود ارتباط معناداری میان پراکسی‌های تعریف شده برای فین‌تک و ریسک اعتباری در بانک تجارت بود. ۲ شاخص از ۸ شاخص منتخب مؤثر بر ریسک اعتباری از متغیرهای مرتبط با فین‌تک بودند که ناشی از اهمیت بالای این متغیر در شناسایی میزان ریسک اعتباری بانک‌ها است. باتوجه به اینکه تا کنون تحقیقی در راستای موضوع حاضر صورت نپذیرفته است، به‌صورت روند کلی می‌توان اذعان داشت نتایج تحقیق حاضر در راستای نتایج تحقیقات داداشی و همکاران (Dadashi et al., 2020)، جعفری اسکندری و روحی (Jafari Eskandari and Rohii, 2017)، قاسمی ارمکی و همکاران (Ghasemi Armaky et al., 2022)، ترابیان و همکاران (Torabian et al., 2022)، مرادی و همکاران (Moradi et al., 2022)، داداشی و همکاران (Dadashi et al., 2020)، نظرآقایی و همکاران (Nazaraghaei et al., 2019)، بارا و روجیرو (Barra and Ruggiero, 2022)، نگو و همکاران (Ngo et al., 2021)، متدین و همکاران (Motedayen et al., 2022)، قرار دارد. براین اساس پیشنهادهایی ارائه می‌شود:

بر اساس نتایج مدل میانگین‌گیری بیزین می‌توان دریافت که بانک تجارت در ارائه تسهیلات و وام‌ها صرفاً نباید بر اخذ وثایق تمرکز نماید و می‌بایست از حسن شهرت و اعتبار تسهیلات گیرندگان اطمینان حاصل کند و بر اساس قدرت بازپرداخت متقاضی، وام پرداخت شود. این دیدگاه که بانک در قبال اخذ وثایق، تسهیلات پرداخت کند دیدگاه درستی نمی‌باشد. گرچه اتخاذ رویه‌هایی برای ارزیابی مستمر وثایق و داشتن ضمانت اجرایی یکی از تکنیک‌های کاهش ریسک اعتباری می‌باشند.

حفظ یک روش صحیح برای مدیریت ارزیابی و اعتبارسنجی: بانک تجارت نه تنها برای پرتفوی خود باید از یک سیستم کنترلی برخوردار باشد، بلکه باید وضعیت اعتباری را حفظ و همواره موردتوجه قرار دهد و دارای سامانه منظمی برای تعیین کفایت منابع و ذخایر خود و نیز سیستم اطلاعاتی و روش‌های تجزیه و تحلیل باشد به طوری که، مدیریت بتواند ریسک اعتباری موجود را در تمامی فعالیت‌های بانکی از طریق سیستم‌های ذکر شده و در طول ارزیابی اعتبارات پرتفوی کلی اعتباری اشخاص اندازه‌گیری کند. مدیریت بانک باید احتمال تغییرات در شرایط اقتصادی را مدنظر قرار دهد.

باتوجه به متعدد بودن ابعاد شاخص‌های مؤثر بر ریسک اعتباری بر اساس رویکرد میانگین‌گیری بیزین، نیاز به دیدگاه سیستمی در خصوص این امر وجود دارد و چون ذهنیت انسان توانایی این تفکیک را دارا نیست پیشنهاد می‌گردد اقدام به تهیه برنامه‌های رایانه‌ای مبتنی بر مدل‌های آماری برای پیش‌بینی ریسک اعتباری بر اساس اجزای تشکیل‌دهنده آن بنماییم.

از آنجایی که ابعاد شاخص‌های مؤثر بر ریسک اعتباری متعدد و تأثیرهای مختلف (مثبت و منفی)، بر هم دارند ارائه یک شاخص ترکیبی در این حوزه، در تصمیم‌گیری کمک شایانی به مدیران، سرمایه‌گذاران و سیاست‌گذاران حوزه بانکی خواهد نمود.

با عنایت به عوامل متعدد اثرگذار بر ریسک اعتباری مشتریان، به مدیران سیستم بانکی توصیه می‌شود در کنار روش‌های پیش‌بینی مورد استفاده، عوامل مؤثر ذکر شده در پژوهش، سابقه شرکت و فرد را نیز مدنظر قرار بدهند.

تبعیت ریسک اعتباری از وضعیت اقتصادی و متغیر بودن عوامل مؤثر بر آن از لحاظ شدت اثرگذاری و سطح احتمال اثرگذاری، باعث شرایط پیچیده می‌شود؛ لذا پیشنهاد می‌گردد مدل‌های متفاوتی برای شرایط مختلف طراحی گردد؛ به گونه‌ای که در هر شرایط مدیران و سیاست‌گذاران متناسب با شرایط اقتصادی اقدام به سیاست‌گذاری و تصمیم‌گیری در مدیریت ریسک بانک نمایند. در نتیجه مدیران باید سیاست‌های متناسب با شرایط اقتصادی را مدنظر قرار دهند.

به پژوهشگران پیشنهاد می‌شود که شاخص‌های نهادی، شاخص‌های حسابرسی برای مشتریان حقوقی و شاخص‌های محیطی چون دستورالعمل‌های بانک مرکزی، تحریم‌ها، شاخص‌های فضای کسب‌وکار و ثبات سیاسی و اقتصادی را در تحقیقات آتی مدنظر قرار دهند. از جمله محدودیت‌های این پژوهش نبود اطلاعات در حوزه بلاک‌چین، متاورس و اینترنت اشیا و تأکید تحقیق حاضر صرفاً بر اطلاعاتی و آمار در اینترنت بانک و موبایل بانک و خدمات در این حوزه بوده است.

۶- تعارض منافع

هیچ‌گونه تعارض منافع در این پژوهش وجود ندارد.

۷- منابع

- Akaike, H. (1974). A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, 19(6), 716–723.
- An, J; Rau, R. (2019). Finance, technology and disruption. *The European Journal of Finance*, 27(4-5), 1–12.
- Angelini, E; Banbura, M; Rünstler, G. (2010). Estimating and forecasting the euro area monthly national accounts from a dynamic factor model. *OECD Journal: Journal of Business Cycle Measurement and Analysis*, 2010(1), 1–22.
- Antoni Haber, J; D'yakonova, I; Milchakova, A. (2018). Estimation of fintech market in Ukraine in terms of global development of financial and banking systems. *Public and Municipal Finance*, 7(2), 14–23.
- Artis, M. J; Banerjee, A; Marcellino, M. (2005). Factor forecasts for the UK. *Journal of Forecasting*, 24(4), 279–298.
- Aye, G; Gupta, R; Hammoudeh, S; Kim, W. J. (2015). Forecasting the price of gold using dynamic model averaging. *International Review of Financial Analysis*, 41, 257–266.
- Barra, C; Ruggiero, N. (2022). Bank-specific factors and credit risk: evidence from Italian banks in different local markets. *Journal of Financial Regulation and Compliance*.
- Baur, D. G; Beckmann, J; Czudaj, R. (2016). A melting pot - Gold price forecasts under model and parameter uncertainty. *International Review of Financial Analysis*, 48, 282–291.
- Baur, D. G; Glover, K. J. (2014). Heterogeneous expectations in the gold market: Specification and estimation. *Journal of Economic Dynamics and Control*, 40, 116–133.

- Beck, R; Jakubik, P; Piloiu, A. (2013). Non-Performing Loans: What Matters in Addition to the Economic Cycle? *SSRN Electronic Journal*.
- Bellotti, T; Crook, J. (2012). Loss given default models incorporating macroeconomic variables for credit cards. *International Journal of Forecasting*, 28(1), 171–182.
- Belmonte, M; Koop, G. (2014). Model Switching and Model Averaging in Time-Varying Parameter Regression Models. *Advances in Econometrics*, 34, 45–69.
- Bernanke, B. S; Boivin, J. (2003). Monetary policy in a data-rich environment. *Journal of Monetary Economics*, 50(3), 525–546.
- Bester, H. (1994). The Role of Collateral in a Model of Debt Renegotiation. *Journal of Money, Credit and Banking*, 26(1), 72.
- Boivin, J; Ng, S. (2006). Are more data always better for factor analysis? *Journal of Econometrics*, 132(1), 169–194.
- Brownbridge, M. (1998). Financial Distress in Local Banks in Kenya, Nigeria, Uganda and Zambia: Causes and Implications for Regulatory Policy. *Development Policy Review*, 16(2), 173–188.
- Buchak, G; Matvos, G; Piskorski, T; Seru, A. (2018). Fintech, regulatory arbitrage, and the rise of shadow banks. *Journal of Financial Economics*, 130(3), 453–483.
- Buncic, D; Moretto, C. (2015). Forecasting copper prices with dynamic averaging and selection models. *The North American Journal of Economics and Finance*, 33, 1–38.
- Cheng, M; Qu, Y. (2020). Does bank FinTech reduce credit risk? Evidence from China. *Pacific-Basin Finance Journal*, 63, 101398.
- Cornelli, G; Frost, J; Gambacorta, L; Rau, R; Wardrop, R; Ziegler, T. (2020). Fintech and big tech credit: a new database. *BIS Working Paper*, 887.
- Dadashi, I; Kordmanjiri, S; Khoshnoud, Z; Gholamnia Roshan, H. (2020). Investigating the Variables Affecting Banks' Legal Customers Credit Risk, Using Support Vectors Machine and Decision Tree. *Journal of Financial Management Perspective*, 10(31), 53-73. [In Persian]
- D'Agostino, A; Gambetti, L; Giannone, D. (2013). Macroeconomic Forecasting and Structural Change. *Journal of Applied Econometrics*, 28(1), 82–101.
- Davies, R. B. (1987). Hypothesis Testing when a Nuisance Parameter is Present Only Under the Alternatives. *Biometrika*, 74(1), 33-43.
- Derban, W. K; Binner, J. M; Mullineux, A. (2005). Loan Repayment Performance in Community Development Finance Institutions in the UK. *Small Business Economics*, 25(4), 319–332.
- Di Filippo, G. (2015). Dynamic Model Averaging and CPI Inflation Forecasts: A Comparison between the Euro Area and the United States. *Journal of Forecasting*, 34(8), 619–648.

- Drachal, K. (2016). Forecasting spot oil price in a dynamic model averaging framework - Have the determinants changed over time? *Energy Economics*, 60, 35–46.
- Ebrahimi, M; Daryabor, A. (2012). Credit risk management in the banking system - A comparative approach of Data Envelopment Analysis and Neural Network and Logistic Regression. *Journal of Investment Knowledge*, 1(2), 35-62. [In Persian]
- Espinoza, R. A; Prasad, A. (2010). Nonperforming Loans in the GCC Banking System and Their Macroeconomic Effects. *SSRN Electronic Journal*.
- Fallahpour, S; Raei, R; Hendijani, M. (2013). Neural Network Approach Based on Artificial Bee Colony. *Financial Engineering and Securities Management*, 5(21), 33-53. [In Persian]
- Ferreira, D; Palma, A. (2015). Forecasting Inflation with the Phillips Curve: A Dynamic Model Averaging Approach for Brazil. *Revista Brasileira de Economia*, 69(4).
- Forni, M; Hallin, M; Lippi, M; Reichlin, L. (2004). The generalized dynamic factor model consistency and rates. *Journal of Econometrics*, 119(2), 231–255.
- Furlonger, D; Newton, A. (2018). Digitalization Will Make Most Heritage Financial Firms Irrelevant by 2030. *Gartner*.
- Garcia, R; Perron, P. (1996). An Analysis of the Real Interest Rate Under Regime Shifts. *The Review of Economics and Statistics*, 78(1), 111-125.
- Garratt, A; Mitchell, J; Vahey, S; Wakerly, E. (2011). Real-time inflation forecast densities from ensemble Phillips curves. *The North American Journal of Economics and Finance*, 22(1), 77–87.
- Ghaderi Moghaddam, R; baseri, B; falehi, N; abbasi, G. (2022). Investigating the Impact of Uncertainty in Macroeconomic Variables on Electricity and Gas Consumption in Iran (Markov-Switching approach). *Quarterly Economic Research*, 6(19), 77-97. [In Persian]
- Ghasemi Armaky, A; Fallah, M; Alborzi, M. (2022). Development and Explanation of Bank Customers' Credit System Based on Hybrid Learning Models: A Case Study of Bank Mellat. *Journal of Financial Management Perspective*, 12(37), 69-94. [In Persian]
- Gobbi, H; Dupont, W. D; Simpson, J. F; Plummer, W. Dale; Schuyler, P. A; Olson, S. J; Arteaga, C. L; Page, D. L. (1999). Transforming Growth Factor- β and Breast Cancer Risk in Women With Mammary Epithelial Hyperplasia. *JNCI: Journal of the National Cancer Institute*, 91(24), 2096–2101.
- Greve, J; Grün, B; Malsiner-Walli, G; Frühwirth-Schnatter, S. (2022). Spying on the prior of the number of data clusters and the partition distribution in Bayesian cluster analysis. *Australian & New Zealand Journal of Statistics*, 64(2), 205–229.

- Groen, J. J. J; Paap, R; Ravazzolo, F. (2013). Real-Time Inflation Forecasting in a Changing World. *Journal of Business & Economic Statistics*, 31(1), 29–44.
- Guo, P; Shen, Y. (2016). The impact of Internet finance on commercial banks' risk taking: evidence from China. *China Finance and Economic Review*, 4(1).
- Habibi, R; Kouhi, H; Baidi, H. (2018). Bank Lending Decision Using Genetic Algorithm (Case Study: Bank Sepah Legal Customer). *Quarterly Studies in Banking Management and Islamic Banking*, 4(9), 33-71. [In Persian]
- Hamilton, J. D. (1989). A New Approach to the Economic Analysis of Nonstationary Time Series and the Business Cycle. *Econometrica*, 57(2), 357-384.
- Han, Y; Wang, T. (2021). Semi-Supervised Clustering for Financial Risk Analysis. *Neural Processing Letters*, 53(5), 3561–3572.
- Horri, M. Sadegh; Mahdavi, K. (2015), Designing A Model to Predict the Credit Rating of Bank Customers Using Meta-Heuristic and Multi-Criteria Hybrid Algorithm of Fuzzy Neural Network - Ant Colony (Case Study of Post Bank Branches of Tehran Province). *Management Research in Iran*, 19(1), 91-116. [In Persian]
- Huber, F; Koop, G; Onorante, L. (2021). Inducing Sparsity and Shrinkage in Time-Varying Parameter Models. *Journal of Business & Economic Statistics*, 39(3), 669–683.
- Jafari Eskandari, M; Rohii, M. (2017). Credit Risk Management of Banking Customers Using Support Vector Machine Optimized by Genetic Algorithm with Data Mining Approach. *Journal of Asset Management and Financing*, 5(4), 17-32. [In Persian]
- Kabari, L. G; Nwachukwu, E. O. (2013). Credit Risk Evaluating System Using Decision Tree – Neuro Based Model. *International Journal of Engineering Research & Technology*, 2(6), 2738-2745.
- Koop, G. (2012). Using VARs and TVP-VARs with Many Macroeconomic Variables. *Central European Journal of Economic Modelling and Econometrics*, 4(3), 143–167.
- Koop, G; Korobilis, D. (2009). Bayesian Multivariate Time Series Methods for Empirical Macroeconomics. *SSRN Electronic Journal*.
- Koop, G; Korobilis, D. (2012). Forecasting Inflation Using Dynamic Model Averaging. *International Economic Review*, 53(3), 867–886.
- Koop, G; Korobilis, D. (2011). UK macroeconomic forecasting with many predictors: Which models forecast best and when do they do so? *Economic Modelling*, 28(5), 2307–2318.
- Koop, G; Korobilis, D; Pettenuzzo, D. (2019). Bayesian compressed vector autoregressions. *Journal of Econometrics*, 210(1), 135–154.

- Koop, G; McIntyre, S; Mitchell, J; Poon, A. (2020). Regional output growth in the United Kingdom: More timely and higher frequency estimates from 1970. *Journal of Applied Econometrics*, 35(2), 176–197.
- Korobilis, D. (2021). High-Dimensional Macroeconomic Forecasting Using Message Passing Algorithms. *Journal of Business & Economic Statistics*, 39(2), 493–504.
- Kuck, K; Schweikert, K. (2017). A Markov regime-switching model of crude oil market integration. *Journal of Commodity Markets*, 6, 16–31.
- Louzis, D. P; Vouldis, A. T; Metaxas, V. L. (2010). Macroeconomic and Bank-Specific Determinants of Non-Performing Loans in Greece: A Comparative Study of Mortgage, Business and Consumer Loan Portfolios. *SSRN Electronic Journal*.
- Mansourfar, Gh; Piri, P; Alikhani, Z; Asadi, M. (2018). Forecasting financial helplessness according to the effects of adjustment clauses in the independent auditor's report. *The 16th National Accounting Conference of Iran*. [In Persian]
- Marcellino, M; Stock, J. H; Watson, M. W. (2003). Macroeconomic forecasting in the Euro area: Country specific versus area-wide information. *European Economic Review*, 47(1), 1–18.
- Min, J. H; Lee, Y. C. (2008). A practical approach to credit scoring. *Expert Systems with Applications*, 35(4), 1762–1770.
- Mirghafouri, S. H; Amin Ashouri, Z. (2015). Presenting a Model for Measuring Credit Risk of Bank Customers using Data Mining Approach. *Journal of Business Administration Researches*, 7(13), 247-266. [In Persian]
- Mohaghegh Nia, M. J; Dehgan Dahnavi, M. A; Baei, M. (2019). The Effect of internal and external factors of credit banks and banks' credit industry in Iran. *Financial Economics*, 13(46), 127-144. [In Persian]
- Mohammadian Haji Kord, Amin; Asgharzadeh Zafarani, Malihe; Emam Doost, Mostafa. (2016). Credit risk assessment of corporate customers using support vector machine and genetic algorithm hybrid model - a Case Study of Tejarat Bank. *Financial Engineering and Portfolio Management*, 7(27), 17-32. [In Persian]
- Moradi, S; Mokhtab Rafiei, F; Saghaee, A. (2022). Identifying patterns of the dynamic credit risk of banks customers and financial institutions: case study-an Iranian bank. *Journal of Monetary and Banking Research*, 15(51), 121-154. [In Persian]
- Motedayen, N; Nazarian, R; Damankeshideh, M; Seifipour, R. (2022). Identification and Evaluation of the Factors Affecting Credit Risk Management Using the Multinomial Logistic Regression Model. *Iranian Economic Review*, 26(3), 707-720.

- Naser, H. (2014). An Econometric Investigation of Forecasting GDP, Oil Prices, and Relationships among GDP and Energy Sources. *Etheses.whiterose.ac.uk*.
- Naser, H; Alaali, F. (2018). Can oil prices help predict US stock market returns? Evidence using a dynamic model averaging (DMA) approach. *Empirical Economics*, 55(4), 1757–1777.
- Nazaraghaei, M; Ghiasi, H; Asgharkhah Chafi, M. (2019). Classification of Customer's Credit Risk Using Ensemble learning (Case study: Sepah Bank). *Journal of Monetary and Banking Research*, 12(39), 129-166. [In Persian]
- Ngo, T; Le, V; Le, H. (2021). Factors affecting credit risk in lending activities of joint-stock commercial banks in Vietnam. *Journal of Eastern European and Central Asian Research (JEECAR)*, 8(2), 228–239.
- Nicoletti, G; Passaro, R. (2012). Sometimes it Helps: The Evolving Predictive Power of Spreads on GDP Dynamics. *SSRN Electronic Journal*.
- Noroozi, P. (2014). The Effect of Macroeconomic Variables on Credit Risk of Banks in Iran. *Journal of Monetary and Banking Research*, 7(20), 237-257. [In Persian]
- Pérez-Martín, A; Pérez-Torregrosa, A; Vaca, M. (2018). Big Data techniques to measure credit banking risk in home equity loans. *Journal of Business Research*, 89, 448–454.
- Pesaran, M. H; Timmermann, A. (2000). A Recursive Modelling Approach to Predicting UK Stock Returns. *The Economic Journal*, 110(460), 159–191.
- Petralia, K; Philippon, T; Rice, T; Véron, N. (2019). Banking disrupted? Financial intermediation in an era of transformational technology. *Geneva Reports on the World Economy*.
- Phan, D. H. B; Narayan, P. K; Rahman, R. E; Hutabarat, A. R. (2020). Do financial technology firms influence bank performance? *Pacific-Basin Finance Journal*, 62, 101210.
- Pourkazemi, M. H; Sedaghat Parast, E; Dehpanah, R. (2018). Estimating Default Probability of Bank Customers Using Neural Networks Method (Case Study: Pasargad Bank). *Quarterly Studies in Banking Management and Islamic Banking*, 3(6-7), 1-23. [In Persian]
- Qiao, H; Chen, M; Xia, Y. (2018). The Effects of the Sharing Economy: How Does Internet Finance Influence Commercial Bank Risk Preferences? *Emerging Markets Finance and Trade*, 54(13), 3013–3029.
- Raei, R; Fallahpour, S. (2009). Support Vector Machines Application in Financial Distress Prediction of Companies Using Financial Ratios. *Accounting and Auditing Review*, 15(4). [In Persian]
- Raftery, A. E; Kárný, M; Ettlér, P. (2010). Online Prediction Under Model Uncertainty via Dynamic Model Averaging: Application to a Cold Rolling Mill. *Technometrics*, 52(1), 52–66.

- Risse, M; Kern, M. (2016). Forecasting house-price growth in the Euro area with dynamic model averaging. *The North American Journal of Economics and Finance*, 38, 70–85.
- Rostami, M. R; Nabizade, A; Shahi, Z. (2019). Factors Affecting Credit Risk of Commercial Banks of Iran with Emphasis on Banking and Macroeconomic Specific Factors. *Journal of Asset Management and Financing*, 6(4), 79-92. [In Persian]
- Rostamzadeh, P; Shahnazi, R; Neisani, M S. (2018). Identification of Factors Affecting on Credit Risk in the Iran Banking Industry of Iran Using Stress Test. *Journal of Economic Modeling Research*, 9(32), 91-128. [In Persian]
- Sadigov, S; Vasilyeva, T; Rubanov, P. (2020). Fintech in economic growth: cross-country analysis. *55th International Scientific Conference on Economic and Social Development*.
- Safari, S; Ebrahimi Shaghaghi, M; Taherifard, M. (2020). Credit Risk Management In The Banking System. *Commercial Strategies*, 9(47), 121-140. [In Persian]
- Sala-I-Martin, X. X. (1997). I Just Ran Two Million Regressions. *The American Economic Review*, 87(2), 178–183.
- Santomero, A. M. (1997). Commercial Bank Risk Management: An Analysis of the Process. *Journal of Financial Services Research*, 12(2-3), 83–115.
- Schumacher, C. (2007). Forecasting German GDP using alternative factor models based on large datasets. *Journal of Forecasting*, 26(4), 271–302.
- Stock, J; Watson, M. (2005). An Empirical Comparison of Methods for Forecasting Using Many Predictors. *Scholar.harvard.edu*.
- Stock, J; Watson, M. (1998). Diffusion Indexes. *RePEc - Econpapers*.
- Stock, J. H; Watson, M. (2006). Forecasting with Many Predictors. *RePEc - Econpapers*.
- Tari, F; Ebrahimi, S. A; Mousavi, S. J; Kalantari, M. (2018). Comparison Between Neural Network, Genetic Algorithm and Logit Models in Evaluating Consumer Credit Risk. *Journal of Monetary and Banking Research*, 10(34), 657-680. [In Persian]
- Torabian, A; Nahidi Amirkhiz, M. R; Jani, S; Hasanzadeh, R. (2022). Bank Client Accreditation And Ranking: A Case Study Of Saderat Bank Of Iran. *Journal Of Investment Knowledge*, 11(41), 145-162. [In Persian]
- Wang, R; Liu, J; Luo, H. (2020). Fintech development and bank risk taking in China. *The European Journal of Finance*, 27(4-5), 397–418.
- YU, L; WANG, S; LAI, K. (2008). Credit risk assessment with a multistage neural network ensemble learning approach. *Expert Systems with Applications*, 34(2), 1434–1444.

Zhao, Q; Tsai, P. H; Wang, J. L. (2019). Improving Financial Service Innovation Strategies for Enhancing China's Banking Industry Competitive Advantage during the Fintech Revolution: A Hybrid MCDM Model. *Sustainability*, 11(5), 1419.

COPYRIGHTS

© 2022 by the authors. Published by Islamic Azad University, Esfarayen Branch. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0) (<http://creativecommons.org/licenses/by/4.0/>).

