


## Prediction the Choice of Financing for Start-ups using Machine Learning Algorithms and Behavioral Biases

*Naiime Niazi, Hamideh Razavi*

1. MSc., Department of Industrial Engineering, Faculty of Engineering, University of Ferdowsi of Mashhad, Mashhad, Iran  
Email: [naimeniazi@gmail.com](mailto:naimeniazi@gmail.com)
2. Corresponding Author ,Associate Prof. Department of Industrial Engineering, Faculty of Engineering, University of Ferdowsi of Mashhad, Mashhad, Iran, Email :h-razavi@um.ac.ir

Article Info	ABSTRACT
<p><b>Article type:</b> Research Article</p> <p><b>Article history:</b> Received 17 - 8 - 2024 Received in revised form 30 - 8 - 2024 Accepted 15 - 9 - 2024 Published online 21 - 9 - 2024</p> <p><b>Keywords :</b> Cluster boosting algorithm (Catboost), Cognitive Biase, Ensemble learning , Financing, Startup.</p>	<p>The aim of this paper is to predict financing methods to support decision-making for startup founders and their investors. Initially, factors influencing the choice of financing methods, including structural, demographic, and behavioral factors, were identified. These factors were then assessed using a questionnaire consisting of 32 items, which was sent online to startup founders. Based on 70 responses received and using algorithms including binary matching, classification chains, label power set, K-nearest neighbors, extreme gradient boosting, cluster boosting algorithm and random forest, the financing methods chosen by startups were predicted. Comparison of the results from the algorithms shows that the boosting ensemble algorithm, with an F1 score of 89 and precision of 85%, predicts the selected financing methods on the test dataset better than other algorithms. Additionally, data analysis indicates that startups are more inclined towards personal funding methods, which aligns with the prevalence of loss aversion bias among entrepreneurs. Following loss aversion, overconfidence, anchoring, and illusion of control biases were the most frequent among entrepreneurs.</p>
<p>Cite this article..... :</p>	
	<p>©The Author(s) DOI: <a href="https://doi.org/">https://doi.org/</a></p>
<p>Publisher: University of Qom</p>	

## پیش‌بینی شیوه تأمین مالی استارت‌آپ‌ها با استفاده از الگوریتم‌های یادگیری ماشین و در نظر گرفتن سوگیری‌های رفتاری

نعیمه نیازی ۱، حمیده رضوی ۲\*

۱. کارشناسی ارشد، مهندسی صنایع، دانشکده مهندسی دانشگاه فردوسی مشهد، مشهد، ایران. رایانامه: naimeniazi@gmail.com

۲. نویسنده مسئول، دانشیار، مهندسی صنایع، دانشکده مهندسی دانشگاه فردوسی مشهد، مشهد، ایران رایانامه: h-razavi@um.ac.ir

اطلاعات مقاله	چکیده
<b>نوع مقاله:</b> مقاله پژوهشی <b>تاریخ دریافت:</b> ۱۴۰۳/۰۵/۲۲ <b>تاریخ بازنگری:</b> ۱۴۰۳/۰۵/۳۰ <b>تاریخ پذیرش:</b> ۱۴۰۳/۰۶/۲۵ <b>تاریخ انتشار:</b> ۱۴۰۳/۰۶/۳۱	<p>هدف از این مقاله، پیش‌بینی شیوه‌های تأمین مالی برای پشتیبانی تصمیم‌گیری بنیان‌گذاران استارت‌آپ‌ها و سرمایه‌گذاران آنهاست. در ابتدا عوامل موثر در انتخاب روش تأمین مالی شامل عوامل ساختاری، جمعیت‌شناختی و رفتاری شناسایی شدند. سپس این عوامل با استفاده از پرسشنامه‌ای مشتمل بر ۳۲ گویه، به صورت آنلاین برای بنیان‌گذاران استارت‌آپ‌ها ارسال گردید. براساس ۷۰ پاسخ دریافت‌شده و استفاده از الگوریتم‌های تطابق دودویی، زنجیره‌های طبقه‌بندی، مجموعه توان برچسب‌ها، K نزدیک‌ترین همسایه، تقویت گرادیان شدید، تقویت دسته و جنگل تصادفی به پیش‌بینی شیوه‌های تأمین مالی که استارت‌آپ‌ها انتخاب می‌کنند، پرداخته شد. مقایسه نتایج حاصل از الگوریتم‌ها نشان می‌دهد که الگوریتم تقویت دسته با شاخص ارزیابی FI معادل ۸۹ و دقت معادل ۸۵ درصد بهتر از سایر الگوریتم‌ها، روش‌های تأمین مالی منتخب را بر روی مجموعه داده آزمون پیش‌بینی می‌نماید. همچنین تحلیل داده‌ها نشان می‌دهد که استارت‌آپ‌ها بیشتر به روش پرداخت شخصی برای تأمین مالی تمایل دارند که با فراوانی سوگیری زیان‌گریزی در میان کارآفرینان همسو است. همچنین پس از سوگیری زیان‌گریزی، سوگیری‌های اعتماد به نفس بیش‌ازحد، لنگرانداختن و توهم کنترل، بیشترین فراوانی را در میان کارآفرینان داشتند.</p>

### کلیدواژه‌ها:

استارت‌آپ، الگوریتم تقویت دسته، تأمین مالی، سوگیری‌های رفتاری، یادگیری گروهی.

استناد: .....



© نویسندگان.

ناشر: دانشگاه قم

## ۱) مقدمه

استارت‌آپ‌ها، از شناسایی فرصت توسط کارآفرینان شکل می‌گیرند. گروهی از افراد باهم کار می‌کنند تا محصولی را بسازند یا خدمتی را به شکلی متفاوت از آنچه پیش از آن وجود داشته، به مشتریان ارائه کنند (Baldrige, 2022). در این کسب‌وکارهای ساختاریافته، نقش کارآفرینان در تصمیم‌گیری‌ها، پررنگ‌تر از شرکت‌های بزرگ و ساختاریافته است (Nguyen & Canh, 2021). یکی از این چالش‌ها و مسائل محدودکننده که از ابتدای شکل‌گیری تا بلوغ یک کسب‌وکار وجود دارد، مسئله انتخاب شیوه تامین مالی است.

در ابتدای کار، فعالیت‌ها برای سرمایه‌گذاران، دارای ابهامات زیادی در حوزه‌های مختلف از جمله زمینه فعالیت، توانایی سرمایه‌گذاری و جریان نقدی است که این مسئله برآورد ریسک سرمایه‌گذاران از سرمایه‌گذاری را افزایش می‌دهد (Bauer et al., 2023). بنابراین کسب‌وکارها در هنگام شکل‌گیری به تنهایی، ناچار به تامین منابع مالی مورد نیاز هستند. مقدار سرمایه قابل دسترس از این طریق، به استثنای کسب‌وکارهایی که بنیان‌گذاران ثروتمندی دارند، محدود است. بنابراین کارآفرینان تازه‌کاری که به سرمایه‌گذاری اولیه بیشتری نیاز دارند، به دنبال منابع مالی دیگری مانند وام‌های بانکی، فرشتگان کسب‌وکار و یا سرمایه‌گذاران خطرپذیر هستند. تامین مالی از طریق این منابع با توجه به عدم تقارن اطلاعاتی میان استارت‌آپ‌ها و سرمایه‌گذاران، اغلب پرهزینه است (Honjo et al., 2022). در صورت موفقیت در تامین سرمایه مورد نیاز از طریق هر یک از روش‌های تامین مالی غیرشخصی، بدهی‌هایی برای استارت‌آپ‌ها ایجاد می‌شود که این بدهی‌ها نرخ شکست کسب‌وکارها را در ابتدای کار افزایش می‌دهند (Berger & Hottenrott, 2021).

اغلب تصمیم‌گیری‌های مالی در محیط کسب‌وکارهای پیچیده و متغیر صورت می‌گیرد که با عدم قطعیت زیادی همراه هستند (Hallo et al., 2020)، این عدم قطعیت‌ها و پیچیدگی‌ها، موجب تشدید اولویت شهود کارآفرینان بر عقلانیتی که نظریه‌های متعارف اقتصاد و مالی بر آن استوار است، می‌گردد. هدف از آشنایی با سوگیری‌های رفتاری در فرآیند تصمیم‌گیری، شناسایی موقعیت‌هایی است که در آنها این سوگیری‌ها می‌توانند خود را بروز دهند تا بدینوسیله افراد بتوانند از اشتباهات در تصمیم‌گیری، به خصوص تصمیم‌گیری‌های مالی اجتناب کنند (Lien et al., 2022). تاکنون تعداد زیادی سوگیری رفتاری شناسایی شده و روزه‌روز بر این تعداد افزوده می‌شود (Harris, 2021).

این پژوهش به دنبال پیش‌بینی انتخاب شیوه تامین مالی در استارت‌آپ‌ها با در نظر گرفتن ویژگی‌های ساختاری، جمعیت‌شناختی و رفتاری است. برای رسیدن به این هدف، از پرسشنامه برای جمع‌آوری اطلاعات استفاده می‌شود و از آنجاییکه نظریات ساختاریافته‌ای در این زمینه برای حل مسئله وجود ندارد از ابزارهای داده‌محور برای تبیین آن استفاده می‌شود (Simon et al., 2000). منظور از عوامل ساختاری: تعداد کارمندان، سرمایه اولیه، درآمد، ماهیت محصول و امثال آن است. عوامل جمعیت‌شناختی عبارتند از: سن، جنسیت، تحصیلات و درآمد و چهار سوگیری شناختی شامل اعتماد به نفس بیش از حد، توهم کنترل، زیان‌گریزی و لنگرانداختن است.

در این مقاله، در ابتدا خلاصه‌ای از تحقیقات پیشین به تفکیک در زمینه عوامل ساختاری استارت‌آپ‌ها، عوامل جمعیتی و رفتاری کارآفرینان که در این پژوهش مورد بررسی قرار گرفته‌اند و تصمیم‌گیری انسانی توضیح داده می‌شود. سپس مدل مسئله، پردازش داده‌ها و الگوریتم‌های استفاده‌شده به تفکیک معرفی شده، نتایج حاصل از اجرای الگوریتم‌ها مورد مقایسه قرار گرفته و در انتها الگوریتم برتر شناسایی می‌شود. به کمک این روش، می‌توان برای هر استارت‌آپ جدید،

بر اساس اطلاعات اعضای آن و شناسایی سوگیری‌های رفتاری ایشان، روش تأمین مالی مناسب را پیش‌بینی و یا توصیه نمود.

## ۲) پیشینه پژوهش

استارت‌آپ‌ها به عنوان سازمان‌های موقتی تعریف می‌شوند که برای جست‌وجوی مدل کسب‌وکاری قابل تکرار و مقیاس‌پذیر طراحی شده‌اند (Blank, 2010). این کسب‌وکارها اغلب سرمایه راه‌اندازی پایینی دارند و به دلایلی چون ریسک شکست بالا، وضعیت اعتباری کارآفرینان و هزینه‌های بالای مبادله، دسترسی کمی به روش‌های تأمین مالی بیرونی دارند. این مسئله، شیوه انتخاب تأمین مالی برای این کسب‌وکارها را در بستری متفاوت از سایر شرکت‌ها قرار می‌دهد (Bollaert et al., 2021). روش‌های تأمین مالی رایج در ادبیات برای تأمین بودجه موردنیاز این کسب‌وکارهای نوپا شامل ۱۰ روش تأمین مالی: ۱. پرداخت شخصی ۲. کمک خانواده، دوستان و نزدیکان ۳. وام‌های بانکی ۴. وام‌های همتابه‌همتا ۵. تأمین مالی جمعی ۶. سرمایه‌گذاران فرشته ۷. سرمایه‌گذاری شتاب‌دهنده‌ها ۸. سرمایه‌گذاری خطرپذیر ۹. سرمایه‌گذاری خطرپذیر شرکتی ۱۰. عرضه اولیه به‌امر هستند.

اولین و در دسترس‌ترین این روش‌ها، پرداخت شخصی است. در این روش، کارآفرینان برای سرمایه‌گذاری از پول و سرمایه شخصی خود استفاده می‌کنند. در ادبیات کارآفرینی، عبارت خودراه‌اندازی<sup>۱</sup> رایج‌تر از تأمین مالی شخصی است. خودراه‌اندازی علاوه بر تأمین مالی از طریق سرمایه شخصی شامل یافتن راه‌های خلاقانه برای مدیریت و اداره استارت‌آپ به گونه‌ای است که کمترین نیاز به سرمایه را پیدا کند (Tech, 2018).

روش بعدی، تأمین مالی از طریق خانواده، دوستان و نزدیکان است. باید توجه داشت که این روش می‌تواند در روابط شخصی افراد مشکلاتی را ایجاد کند و لازم است تا طرفین پیش از سرمایه‌گذاری تبعات آن مانند احتمال شکست، سهم سرمایه‌گذار و زمان خروج را در نظر بگیرند (Hill, 2018).

وام‌های بانکی یکی دیگر از روش‌های تأمین مالی موجود هستند. برای استارت‌آپ‌ها به خصوص در مراحل اولیه که کارآفرینان اعتبار و دارایی‌های ملموسی ندارند، تأمین مالی از طریق وام‌های بانکی دشوار است چراکه وام‌دهندگان به این دلیل که به دنبال کاهش ریسک هستند، عرضه را حتی در صورت تقاضا با نرخ‌های کارمزد بالاتر، محدود می‌کنند (Dhewanto et al., 2019).

وام‌های همتابه‌همتا نیز از جدیدترین ابزارهای تأمین مالی هستند. در این نوع وام‌ها، وام‌گیرندگان اطلاعات و شرایط خود را اعلام می‌کنند و وام‌دهندگان تصمیم می‌گیرند که در وام مشارکت کنند یا خیر (Basha et al., 2021).

از دیگر روش‌های تأمین مالی جدید و روبه‌رشد، تأمین مالی جمعی است (Cai et al., 2021). در سال‌های اخیر، نهادهای تأمین مالی جمعی در ایران به شیوه وام شکل گرفته و با رویدادهایی تحت عنوان سکوی سرمایه‌گذاری به جذب سرمایه موردنیاز متقاضیان می‌پردازند.

از دیگر روش‌های تأمین مالی، سرمایه‌گذاران فرشته هستند. این افراد سرمایه اولیه استارت‌آپ‌ها و کسب‌وکارهای نوپا را با

<sup>1</sup> Bootstrapping

استفاده از سرمایه شخصی تامین می کنند. سرمایه گذاری فرشتگان در شرایط عدم اطمینان بالایی شکل می گیرد و در این وضعیت برداشت های فردی فرشتگان در ارزیابی و تفسیر کسب و کارها نقش پررنگی در فرآیند ارزیابی و سرمایه گذاری آنان ایفا می کند (Lien et al., 2022).

شتاب دهنده ها در بسیاری از پژوهش ها به عنوان یک روش تامین مالی در نظر گرفته می شوند اما بطور کلی علاوه بر تامین سرمایه و فضای کار به کسب و کارهای نوپا کمک می کنند تا محصولات اولیه خود را تولید کنند و همچنین فرصت های ارتباطی برای آنان ایجاد می کنند (Harris, 2021).

روش تامین مالی بعدی، سرمایه گذاران خطرپذیر<sup>۱</sup> است. سرمایه گذاران خطرپذیر در واقع واسطه های مالی هستند که در شرکت های خصوصی سرمایه گذاری می کنند و در طی سرمایه گذاری نقش پررنگی در نظارت بر هزینه کرد مبلغ سرمایه گذاری دارند. هدف این سرمایه گذاران کمک به تامین مالی کسب و کارهای نوپا و خروج پس از کسب بازده مورد انتظار سرمایه گذاری است (Metrick & Yasuda, 2021).

سرمایه گذاران خطرپذیر شرکتی<sup>۲</sup>، روش تامین مالی بعدی هستند. این سرمایه گذاران شرکت های بزرگی هستند که به سرمایه گذاری در کسب و کارهایی می پردازند که بیشترین شباهت را با شرکت هایشان داشته باشند و بدینوسیله امکان رشد شرکت های استارتآپی مشابه که دارای دانش فنی تکمیل کننده و یا مشتریان جدیدی هستند را فراهم می کنند (Hegeman & Sørheim, 2021).

عرضه اولیه بهامهر<sup>۳</sup>، روش تامین مالی جدیدتری نسبت به سایر روش ها در ادبیات موضوع است. این روش شبیه تامین مالی جمعی از طریق سهام است. در این روش استارتآپ ها برای تامین سرمایه اولیه، توکن که اغلب این توکن ها یک ارز دیجیتال هستند را با تخفیف و قیمتی پایین تر از قیمت عادی برای فروش با ارزهای دیجیتال مرسوم مانند بیت کوین و اتریوم عرضه می کنند (Fisch, 2019).

پس از شناسایی روش های مرسوم تامین مالی استارتآپ ها، لازم است مهمترین عوامل موثر بر تصمیم گیری انتخاب شیوه تامین مالی شناسایی شوند. در امور مالی کارآفرینی، تصمیم گیری از دو جنبه عدم تقارن اطلاعاتی میان سرمایه گذاران و کارآفرینان و عدم دسترسی به عوامل تسهیل گر نظیر سرمایه اجتماعی، با شرکت های دیگر متفاوت است (Ding et al., 2021; Fernandez, 2015). انتظار می رود که کارآفرینان به دلیل قرار گرفتن در شرایط تصمیم گیری با عدم قطعیت زیاد، محدودیت زمانی و اطلاعات نامتقارن نسبت به سایرین، از رفتار منطقی و عقلایی فاصله بگیرند و در تصمیمات دچار سوگیری های متعددی شوند (Metrick & Yasuda, 2021). سوگیری های رفتاری یکی از چندین عاملی هستند که بر تصمیم گیری مالی کارآفرینان اثر می گذارند. علاوه بر سوگیری ها، عوامل متعدد دیگری شامل عوامل ساختاری و جمعیتی نیز بر انتخاب روش تامین مالی یا ساختار سرمایه شرکت ها تاثیرگذار هستند.

## ۱.۲ عوامل ساختاری استارتآپ ها

<sup>1</sup> Venture capital (VC)

<sup>2</sup> corporate venture capital (CVC)

<sup>3</sup> Initial Coin Offering (ICO)

عوامل ساختاری متفاوت، بسترهای تصمیم‌گیری متفاوت و انتخاب‌های متمایزی را برای استارت‌آپ‌ها فراهم کرده که این امر موجب پیامدهای متفاوتی برای کسب و کارها خواهد شد. از بین عوامل ساختاری که در ادبیات موضوع مورد بررسی قرار گرفته است، با توجه به پژوهش‌های پیشین و امکان دسترسی به اطلاعات، برخی از عوامل که در ادامه تشریح می‌شوند برای بررسی در این پژوهش انتخاب شدند.

۱. عمر استارت‌آپ: برخی پژوهش‌ها نشان می‌دهند که اگرچه شرکت‌های جوان نرخ شکست بالایی دارند اما مشروط به بقا، نرخ رشد بالاتری را در مقایسه با شرکت‌های قدیمی‌تر نشان می‌دهند (Ouimet & Zarutskie, 2014).
۲. اندازه استارت‌آپ: شرکت‌های کوچکتر مزایا و انعطاف‌پذیری بیشتری در محیط بازارهای در حال تغییر دارند و بنابراین احتمالاً بیشتر از شرکت‌های بزرگتر زنده می‌مانند (Lybaert & Umans, 2022).
۳. ثبت اختراع: وقتی شرکت‌ها در تأمین مالی اولیه و بدون سابقه تصمیم به جذب منابع مالی خارجی می‌گیرند، باید راه‌هایی برای نشان دادن کیفیت خود به سرمایه‌گذاران بالقوه پیدا کنند. ثبت اختراع‌ها می‌تواند به عنوان عاملی برای کیفیت در نظر گرفته شود (Vo, 2019).

## ۲.۲ عوامل جمعیت‌رفتاری کارآفرینان

کارآفرین به عنوان فردی که برای تبدیل ایده‌ها به فرصت‌های تجاری و ایجاد ارزش فکر و عمل می‌کند، شناخته می‌شود (Tech, 2018). در این پژوهش، واژه‌های کارآفرین و بنیان‌گذار استارت‌آپ در یک معنا بکار برده می‌شوند و عوامل جمعیت‌شناختی مانند سن، جنسیت و تحصیلات بر تصمیم‌گیری تأمین مالی استارت‌آپ‌ها مورد بررسی قرار می‌گیرد. پژوهش‌ها نشان می‌دهند که شرکت‌های رشد‌محور و افرادی که آنها را راه‌اندازی می‌کنند، این دیدگاه رایج را تکرار می‌کنند که موفق‌ترین و متحول‌کننده‌ترین سرمایه‌گذاری‌های جدید از سوی جوانان می‌آیند (Azoulay et al., 2020). بنابراین سن کارآفرینان یک عامل موثر در تصمیم‌گیری است. عامل موثر بعدی جنسیت است. پژوهش‌های مختلف نشان می‌دهند که کارآفرینان زن تقریباً بطور میانگین ۳۰ درصد از جمعیت بنیان‌گذاران استارت‌آپ‌ها را در طول زمان و در کشورهای مختلف تشکیل می‌دهند و از این تعداد ۱۰ تا ۱۵ درصد از آنها موفق به دریافت سرمایه خصوصی و سرمایه خطرپذیر می‌شوند (Hebert, 2020). سوابق تحصیلی بنیان‌گذاران استارت‌آپ‌ها می‌تواند به عنوان عاملی موثر و محرکی قوی برای عملکرد آنان تلقی شود (Franco et al., 2021).

## ۳.۲ عوامل رفتاری کارآفرینان

پژوهش بر روی تاثیر سوگیری‌های رفتاری با هدف درک این مسئله که کارآفرینان چگونه آگاهانه یا غیر آگاهانه تصمیم می‌گیرند، از اواسط دهه ۱۹۹۰ آغاز شده است و از آن زمان تاکنون به یکی از حوزه‌های مهم پژوهش‌های کارآفرینی تبدیل شده است (Rosyidah & Pratikto, 2022). جدول (۱) مرور مختصری است بر پژوهش‌هایی که در این زمینه مورد بررسی قرار گرفتند.

جدول ۱. پژوهش‌های گذشته در مورد تاثیر سوگیری‌های مختلف

ردیف	نام نویسندگان	سال انتشار	سوگیری‌های مورد بررسی	روش پژوهش
۱	ژانگ و همکاران <sup>۱</sup> ( Zhang & Cueto, 2017 )	۲۰۱۸	اعتماد به نفس بیش از حد <sup>۲</sup> ، خوش بینی <sup>۳</sup> ، خود استنادی <sup>۴</sup> ، توهم کنترل <sup>۵</sup> ، قانون اعداد کوچک <sup>۶</sup> ، مغالطه در برنامه ریزی <sup>۷</sup> و تشدید تعهد <sup>۸</sup>	مروری
۲	زهیرا <sup>۹</sup> و همکاران ( Zahera & Bansal, 2018 )	۲۰۱۸	اعتماد بیش از حد، رفتار گله‌ای، حسابداری ذهنی <sup>۱۰</sup> ، تایید <sup>۱۱</sup> ، واپس نگری <sup>۱۲</sup> ، نمادگرایی، اثر اهدا <sup>۱۳</sup> یا بیزاری از واگذاری، زیان‌گریزی، قالب‌بندی <sup>۱۴</sup> ، خانه <sup>۱۵</sup> ، خود اسنادی، محافظه‌کاری <sup>۱۶</sup> ، پشیمانی‌گریزی، لنگر انداختن، تازگی <sup>۱۷</sup> و اثر وضع <sup>۱۸</sup>	مروری
۳	رامالکشمی و همکاران <sup>۱۹</sup> ( Ramalakshmi et al., 2019 )	۲۰۱۹	اعتماد به نفس بیش از حد، پشیمانی‌گریزی، رفتار گله‌ای و نمادگرایی	معادلات ساختاری
۴	دومینیک و همکاران <sup>۲۰</sup> ( Dominic & Gupta, 2020 )	۲۰۲۰	سوگیری اعتماد به نفس بیش از حد، مغالطه قمارباز، لنگر انداختن و رفتار گله‌ای	آزمون‌های فرض با استفاده از همبستگی و رگرسیون

<sup>1</sup> Zhang et al

<sup>2</sup> Overconfidence

<sup>3</sup> Overoptimism

<sup>4</sup> Self-serving attribution

<sup>5</sup> Illusion of control

<sup>6</sup> The law of small numbers

<sup>7</sup> Planning fallacy

<sup>8</sup> Escalation of commitment

<sup>9</sup> Zahera et al

<sup>10</sup> Mental Accounting

<sup>11</sup> Confirmation

<sup>12</sup> Hindsight

<sup>13</sup> Endowment Effect

<sup>14</sup> Framing

<sup>15</sup> Home

<sup>16</sup> Conservatism

<sup>17</sup> Recency

<sup>18</sup> Disposition

<sup>19</sup> Ramalakshmi et al.

<sup>20</sup> Dominic et al

کیفی و کمی	خوداستنادی <sup>۱</sup> ، خوش‌بینی و توهم کنترل	۲۰۲۲	آبدین و همکاران <sup>۱</sup> (Ul Abdin et al., ) (2022)	۵
------------	---	------	---	---

پس از بررسی پژوهش‌های پیشین و با توجه به نظر خبرگان در این پژوهش، چهار سوگیری اعتمادبه‌نفس بیش‌ازحد، زیان‌گریزی، لنگرانداختن و توهم کنترل بر تصمیم‌گیری تأمین مالی در بین بنیان‌گذاران استارت‌آپ‌ها انتخاب شدند که در ادامه به تفکیک شرح داده می‌شوند.

اعتمادبه‌نفس بیش‌ازحد یکی از سوگیری‌های رفتاری رایج است. این سوگیری به معنای تمایل افراد به دست‌بالا گرفتن برآوردهایشان است (Bazerman & Moore, 2012). اعتمادبه‌نفس بیش‌ازحد موجب ناچیز انگاشتن ریسک در بسیاری از تصمیم‌های کارآفرینان می‌شود (Simon & Houghton, 2003).

در سوگیری زیان‌گریزی، اغلب باخت‌ها بسیار بزرگتر از بردها به نظر می‌رسند و افراد از باخت یا زیان، گریزان هستند. به بیان دیگر برخلاف نظریه‌های کلاسیک اقتصادی افراد بجای آنکه به دنبال حداکثر کردن مطلوبیت موردانتظار<sup>۳</sup> باشند، احتمالاً در جستجوی راهی هستند که از زیان جلوگیری کنند و بدیهی است که در معرض سوگیری زیان‌گریزی باشند (Kahneman, 2011).

در تصمیم‌گیری‌های اقتصادی اثر لنگرانداختن بسیار قوی و مهم به نظر می‌رسد. این سوگیری زمانی رخ می‌دهد که افراد از قبل، تخمین کمیتی برای آن ارزش خاص قائل باشند (Kahneman, 2011).

سوگیری توهم کنترل، زمانی رخ می‌دهد که افراد باور دارند می‌توانند بر اتفاقات و عواملی که در کنترل آنها نبوده و دیگر عوامل محیطی در وقوع آنان نقش مهمی را ایفا می‌کنند، کنترل داشته باشند (Langer, 1975).

## ۴.۲ پیش‌بینی تصمیم‌گیری‌های انسانی

پژوهش‌ها نشان می‌دهند که ثبت جزئیات موثر بر تصمیم‌گیری انسانی و پیش‌بینی یک تصمیم و عمل براساس آن پیش‌بینی، مسئله ساده‌ای نیست و چالش‌های زیادی را به همراه دارد. برخی از پژوهش‌ها، به سه رویکرد برای پیش‌بینی تصمیم‌گیری‌های انسانی اشاره می‌کنند که این رویکردها عبارتند از خبره‌محور، داده‌محور و ترکیبی. مدل‌های خبره‌محور برای پیش‌بینی تصمیم‌گیری انسانی شامل تئوری‌ها و نظریه‌هایی هستند که توسط متخصصان هر حوزه بیان می‌شوند. یک مدل مبتنی بر داده، عموماً بر مبنای الگوریتم‌های یادگیری ماشین است که با استفاده از مجموعه داده‌های مختلف درباره تصمیم‌های افراد آموزش داده می‌شود. اگرچه مشاهده شده‌است که این رویکرد، از نظر دقت در پیش‌بینی انتخاب بسیار

<sup>1</sup> Abdin et al

<sup>2</sup> Self-attribution bias

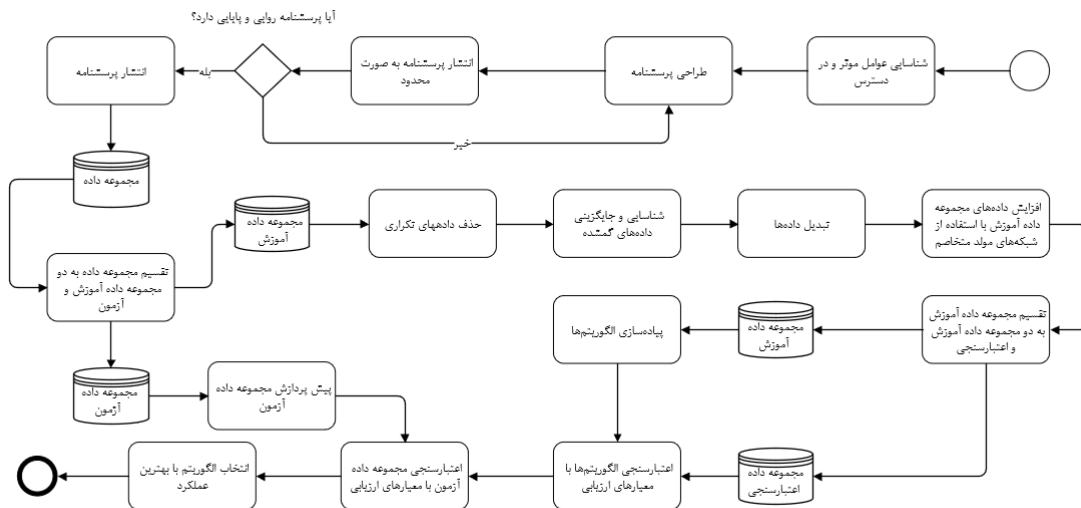
<sup>3</sup> Expected Utility



عالی است اما در ارائه بینش و استدلال در مورد چرایی ترجیحات، عملکرد مناسبی ندارد. در رویکردهای ترکیبی، هر دو رویکرد خبره محور و داده محور ترکیب می شوند. در مورد اینکه برای یک مسئله مفروض، کدامیک از رویکردهای پیش بینی ذکر شده، اتخاذ شود به عوامل زیادی بستگی دارد. اگرچه بطور شهودی بیان می شود که هیچ الگوریتم واحدی بهترین کارآیی را در همه مسائل و حوزه ها ندارد اما با توجه به عواملی مانند در دسترس بودن داده ها، دانش تخصصی و ویژگی های حوزه مورد پژوهش، یکی از این رویکردها انتخاب می شوند (Rosenfeld & Kraus, 2018). بر اساس تعاریف فوق و با توجه به ماهیت مسئله، در این پژوهش از رویکرد داده محور استفاده شده است.

### ۳) روش شناسی پژوهش

شکل (۱) مراحل این پژوهش برای مدل سازی انتخاب شیوه تامین مالی استارت آپ ها را به اختصار نشان می دهد.



شکل ۱. مراحل پژوهش

### ۱.۳ جمع آوری مجموعه داده

شیوه جمع آوری داده در این پژوهش پرسشنامه است. پیش از استفاده از پرسشنامه باید از دقت و سازگاری این ابزار اطمینان حاصل پیدا کرد. دقت و سازگاری پرسشنامه ها در ادبیات موضوع، تحت عناوین روایی و پایایی شناخته می شوند. معیار روایی تضمین کننده این است که آیا نتایج، بازتابی واقعی از ساختار مورد مطالعه هستند؟ و آیا معیار پایایی، معیاری برای تعیین سازگاری و تکرارپذیری نتایج یک پژوهش است و تضمین می کند که نتایج به دلیل شانس یا خطای تصادفی به دست نیامده اند. در این پژوهش و با توجه به ماهیت مسئله برای پایایی از روش آزمون-آزمون مجدد که عبارت است از تکرار استفاده از یک ابزار اندازه گیری یکسان مانند پرسشنامه برای افراد یکسان تحت شرایط یکسان و پس از مدت زمان مشخص، استفاده می گردد. در این آزمون، اگر ضریب همبستگی پاسخ های آزمون و آزمون مجدد بزرگتر یا مساوی ۰/۷ باشد، پرسشنامه از نظر پایایی قابل اتکا و معتبر در نظر گرفته می شود. به منظور بررسی پایایی، پرسشنامه در دو نوبت به فاصله زمانی

۱۴ روز برای ۱۰ نفر ارسال شد و ضریب همبستگی پاسخ‌های هر دو پرسشنامه، بزرگتر از ۹۴ درصد به دست آمد. برای روایی نیز از روایی صوری در این پژوهش استفاده می‌شود. این معیار، درجه‌ای که سئوالات آنچه را که قرار است اندازه‌گیری کنند، اندازه‌گیری می‌کنند یا خیر را می‌سنجد. این معیار توسط کارشناسانی که محتوای پرسشنامه را ارزیابی می‌کنند، تعیین می‌شود (Bolarinwa, 2015).

برای جمع‌آوری داده‌ها باید اطمینان حاصل کرد که داده‌ها تنها محدود به منطقه یا صنعت خاصی نباشند و همچنین نتایج تنها ناشی از تجزیه و تحلیل بازماندگان یا برندگان نباشد (Cassar, 2004). در همین راستا در هنگام جمع‌آوری داده به سوگیری بقا<sup>۱</sup> یا بازمانده توجه شد (Elston, 2021). برای تعیین حداقل حجم نمونه با توجه به اینکه مسئله مورد بررسی دارای حجم جامعه نامعین است، از رابطه ۱ که تحت عنوان رابطه کوکران<sup>۲</sup> شناخته می‌شود، استفاده می‌گردد. با استفاده از این رابطه، تعداد حداقل نمونه مورد نیاز از طریق برآورد واریانس نمونه اولیه و درصد خطا محاسبه می‌شود (Israel, 1992)

$$n = \frac{Z_{\alpha}^2 \times p(1-p)}{d^2} \quad \text{رابطه ۱}$$

حداقل نمونه مورد نیاز با استفاده از رابطه ۱، با انحراف معیار ۰/۳۶ داده‌های اولیه و با در نظر گرفتن ۸ درصد خطا، ۷۷ نمونه به دست آمد.

لینک پرسشنامه در بازه زمانی برای بیش از ۳۰۰ بنیان‌گذار استارت‌آپ از طریق بسترهای مختلف فضای مجازی ارسال و مجموعاً ۷۰ پاسخ دریافت و با توجه به اختلاف نزدیک با حداقل تعداد نمونه داده‌های حاصل از آن جهت مدل‌سازی استخراج گردید.

### ۲.۳ آماده‌سازی داده‌ها

مجموعه داده‌ها اغلب دارای مقادیر گمشده هستند. عدم وجود داده‌ها می‌تواند باعث انحراف در تجزیه و تحلیل آماری شود. علاوه بر این، بسیاری از الگوریتم‌های یادگیری ماشین از مجموعه داده‌هایی که دارای مقادیر گمشده هستند، پشتیبانی نمی‌کنند (Zhang & Thorburn, 2022). مرحله بعدی در آماده‌سازی مجموعه داده، شناسایی داده‌های گمشده و انتخاب رویکرد مناسب در برخورد با آنان است. بطور کلی برای مواجهه با داده‌های گمشده، دو رویکرد اصلی حذف یا جایگزینی، وجود دارد و به منظور جایگزینی داده‌های گمشده می‌توان از روش‌های ساده و یا مبتنی بر یادگیری ماشین استفاده کرد (Brownlee, 2020). در اغلب مواقع مقادیر داده‌ها برای پیاده‌سازی الگوریتم‌های یادگیری ماشین مناسب نیستند و بنابراین لازم است تبدیلاتی<sup>۳</sup> در ماهیت داده‌ها به منظور تطبیق مجموعه داده با نیازهای الگوریتم‌ها صورت بگیرد. مهمترین این تبدیلات، تبدیل متغیرهای اسمی و مقیاس‌بندی داده‌های مجموعه داده هستند (McCallum, 2012). در این پژوهش پس از جمع‌آوری داده‌ها و به منظور آماده‌سازی و مدل‌سازی، از زبان برنامه‌نویسی پایتون و محیط ژوپیترونوت‌بوک<sup>۴</sup> استفاده

<sup>1</sup> Survivorship Bias

<sup>2</sup> Cochran

<sup>3</sup> Encoding

<sup>4</sup> Jupyter Notebook

شد. پس از فراخوانی مجموعه داده، داده‌های گمشده با میانه<sup>۱</sup> جایگزین شدند. داده‌های کیفی با استفاده از روش تبدیل داده، کدگذاری دو دویی به ۰ و ۱ تبدیل شدند و سایر داده‌ها که ماهیت رتبه‌بندی داشتند، با استفاده از تبدیل رتبه‌بندی، کمی‌سازی شدند که این داده‌ها و تبدیلات انجام‌شده در پیوست ۱ قابل مشاهده است. پیش از پیاده‌سازی، لازم است تا داده‌ها به دو مجموعه داده آموزش و آزمون تقسیم شوند. این کار با استفاده از روش نگهدارنده<sup>۲</sup> با نسبت ۳۰ درصد انجام شد و مجموعه داده آزمون برای ارزیابی نهایی الگوریتم‌ها کنار گذاشته شد. سپس مجموعه داده حاصل با روش اعتبارسنجی متقابل<sup>۳</sup> ( $K=5$ ) و با ۱۰۰ مرتبه تکرار، به دو مجموعه داده آموزش و اعتبارسنجی تقسیم شدند.

### ۳.۳ برخورد با عدم تعادل در داده‌های هدف مسئله

در بیشتر موارد، الگوریتم‌های رایج یادگیری ماشین در مسائل طبقه‌بندی، تعداد نمونه‌های کلاس‌های مختلف را مساوی فرض می‌کنند و در نتیجه، تعداد نابرابر داده‌ها در کلاس‌های مختلف باعث ایجاد مشکلاتی در فرآیند یادگیری الگوریتم‌ها می‌شود. از سوی دیگر در مسائل واقعی، جمع‌آوری مجموعه داده‌هایی که در آنها، داده‌ها در کلاس‌های مختلف به صورت متعادل توزیع شده باشند، دشوار است (Fotouhi et al., 2019). برای مواجهه با این مشکل، رویکردهای متفاوتی وجود دارد. یکی از این رویکردها، شبکه‌های متخاصم مولد<sup>۴</sup> هستند. این شبکه‌ها از دو شبکه مجزای مولد و تشخیص‌دهنده تشکیل می‌شوند. شبکه مولد، نویز تصادفی را به عنوان ورودی می‌گیرد و آن را به نمونه‌های مصنوعی تبدیل می‌کند. شبکه تشخیص‌دهنده مانند یک طبقه‌بندی‌کننده دودویی عمل کرده و بین نمونه‌های واقعی و مصنوعی تمایز قائل می‌شود. هر دو شبکه بطور همزمان در یک بازی مجموع صفر<sup>۵</sup> آموزش داده می‌شوند و در طول آموزش، شبکه مولد سعی می‌کند نمونه‌های مصنوعی تولید کند که به اندازه کافی واقعی باشد. این فرآیند تا زمانی ادامه می‌یابد که شبکه تشخیص‌دهنده فریب داده شود. فرآیند آموزش تا زمانی که شبکه مولد نمونه‌هایی را تولید کند که برای شبکه تشخیص‌دهنده از داده‌های واقعی قابل تمایز نباشند، ادامه می‌یابد (Goodfellow et al., 2020). علاوه بر این رویکرد، در این پژوهش برای غلبه بر عدم تعادل در داده‌های مسئله از روش‌های یادگیری گروهی و معیارهای ارزیابی متنوع (Ma & He, 2013) استفاده شده است.

### ۴.۳ مدل‌سازی

<sup>1</sup> Median

<sup>2</sup> Holdout

<sup>3</sup> Repeated K-fold Cross Validation

<sup>4</sup> Generative adversarial networks (GANs)

<sup>5</sup> Zero-sum game

در مسائل یادگیری ماشین چهار رویکرد کلی یادگیری با نظارت<sup>۱</sup>، یادگیری بدون نظارت<sup>۲</sup>، یادگیری نیمه‌نظارتی<sup>۳</sup> و یادگیری تقویتی<sup>۴</sup> یا فعال<sup>۵</sup> وجود دارد. در پژوهش حاضر با توجه به اینکه داده‌ها دارای برجسب هستند و این برجسب‌ها گسسته هستند، از الگوریتم‌های طبقه‌بندی استفاده می‌شود (Han et al., 2012; Marsland, 2014). در این پژوهش ۹ الگوریتم طبقه‌بندی براساس چهار ویژگی پاسخگویی مناسب در برابر تعداد کم داده‌ها و عدم توازن در برجسب‌ها، مقاومت در برابر بیش‌برازش و پیچیدگی کم، مقایسه و با توجه به جدول (۲) چهار الگوریتم برتر، برای مدل‌سازی انتخاب شدند. در ارتباط با تعداد داده‌ها، پژوهش‌ها نشان می‌دهند که در مجموعه داده‌هایی با تعداد کم، الگوریتم‌های یادگیری ماشین نسبت به الگوریتم‌های یادگیری<sup>۶</sup> عمیق عملکرد بهتری از خود نشان می‌دهند (Bailly et al., 2022). از نظر توازن میان برجسب‌ها، طبقه‌بندی‌کننده‌های سنتی نظیر ماشین‌بردار پشتیبان و درخت تصمیم براساس توازن میان برجسب‌ها طراحی شده‌اند و در صورت عدم تعادل در برجسب‌های مسئله، تمایل به طبقه‌بندی نادرست و یا حذف طبقه اقلیت دارند (Gong & Kim, 2017). در مقابل، الگوریتم‌های یادگیری گروهی، عملکرد مناسبی در مجموعه داده‌هایی با عدم تعادل در برجسب‌ها دارند (Ding et al., 2023). در مورد ویژگی پیچیدگی و مستعد بیش‌برازش بودن الگوریتم‌ها لازم است از مفهوم تعمیم‌پذیری<sup>۷</sup> استفاده شود. تعمیم‌پذیری عبارت از توانایی مدل در به تصویر کشیدن ویژگی‌های جامعه با مشاهده ویژگی‌های نمونه است. زمانیکه آموزش تعمیم‌پذیر نباشد، مدل دچار بیش‌برازش خواهد شد (Myung, 2000). از آنجاییکه

---

<sup>1</sup> Supervised Learning

<sup>2</sup> Unsupervised Learning

<sup>3</sup> Semi-supervised Learning

<sup>4</sup> Reinforcement Learning

<sup>5</sup> Active Learning

<sup>6</sup> Deep Learning

<sup>7</sup> Generalization

مجموعه داده مورد بررسی در این پژوهش، محدود و در نتیجه مستعد بیش برآزش است، بهتر است برای جلوگیری از این اتفاق، تا حد امکان از الگوریتم‌هایی با پیچیدگی کمتر استفاده شود.

جدول ۲. قابلیت الگوریتم‌های طبقه‌بندی

ویژگی‌های مسئله				
مقاومت در برابر بیش‌برآزش	پیچیدگی کم	عدم توازن در برچسب‌های مسئله	تعداد کم داده‌ها	
	*		*	رگرسیون لاجستیک
	*		*	بیزی ساده
	*		*	درخت تصمیم
	*		*	ماشین بردار پشتیبان
*	*	*	*	K- نزدیکترین همسایه
*	*	*	*	تقویت گرادیان شدید
*	*	*	*	تقویت دسته
*		*		شبکه‌های عصبی
*	*	*	*	جنگل تصادفی

الگوریتم‌های طبقه‌بندی

اگرچه پژوهش‌ها با فرض‌های قانع‌کننده‌ای نظیر آنچه پیش از این گفته شد، به دنبال محدود کردن الگوریتم‌های قابل استفاده هستند اما نمی‌توان با قطعیت بر مبنای این دلایل، الگوریتمی را تا پیش از پیاده‌سازی، ارجح بر دیگری دانست. هر چند به علت محدودیت‌های موجود، در هر پژوهش معمولاً سعی می‌شود الگوریتم‌هایی را که ظاهراً عملکرد بهتری در مسئله مورد بررسی دارند، انتخاب و پیاده‌سازی شوند (Jafari, 2022). در ادامه چهار الگوریتم طبقه‌بندی که برای مدل‌سازی در این پژوهش استفاده شدند، شرح داده می‌شوند. اما لازم است پیش از آن، با توجه به ماهیت چندبرچسبی بودن مسئله،

طبقه‌بندی این مسائل تبیین گردد. در مسائل چندبرچسبی، هدف مسئله شامل مجموعه‌ای از عوامل است. عمده‌ترین رویکردهای حل این مسائل، تبدیل مسئله<sup>۱</sup> و الگوریتم‌های تطابق‌یافته<sup>۲</sup> هستند (Ganda & Buch, 2018).

در تبدیل مسئله تلاش بر این است تا مسئله چندبرچسبی به مسئله‌های یک برچسبی تبدیل شود. رویکردهای حل مسئله با این روش عبارتند از: تطابق دودویی<sup>۳</sup>، زنجیره‌های طبقه‌بندی‌کننده<sup>۴</sup> و مجموعه توان برچسب‌ها<sup>۵</sup> که در تطابق دودویی، هر برچسب به‌عنوان یک مسئله مستقل تک‌برچسبی در نظر گرفته می‌شود. در روش زنجیره‌های طبقه‌بندی‌کننده، منحصر با یک برچسب آموزش می‌بیند و طبقه‌بند بعدی روی طبقه‌بند قبلی و برچسب بعدی آموزش می‌بیند. در مجموعه توان برچسب‌ها، تلاش بر این است تا مسئله چندبرچسبی به یک مسئله چند کلاسه<sup>۶</sup> تبدیل شود (Pushpa & Karpagavalli, 2017). در الگوریتم‌های تطابق‌یافته، از الگوریتم‌هایی برای حل مسئله استفاده می‌شود که صرفاً برای حل اینگونه مسائل توسعه یافته‌اند (Zheng et al., 2019). در ادامه چهار الگوریتم تطابق‌یافته‌ای که برای مدل‌سازی در این پایان‌نامه استفاده شدند، بطور مختصر شرح داده می‌شود.

### ۳.۴.۱) K- نزدیکترین همسایه<sup>۷</sup>

در این الگوریتم از یک سنجه<sup>۸</sup> فاصله مانند فاصله اقلیدسی<sup>۹</sup> برای یافتن K نزدیک‌ترین نقاط به نقطه هدف استفاده می‌شود و پس از آن برچسب را براساس بیشترین برچسب در میان نقاط، به نقطه هدف اختصاص می‌دهد (Han et al., 2012).

### ۳.۴.۲) تقویت گرادیان شدید<sup>۱۰</sup>

این الگوریتم یکی از الگوریتم‌های توسعه‌یافته یادگیری گروهی<sup>۱۱</sup> با رویکرد تقویت کردن<sup>۱۲</sup> است که بر مبنای گرادیان کاهش<sup>۱۳</sup> عمل می‌کند (Dong et al., 2020). این الگوریتم با یک مدل ساده مبتنی بر درخت تصمیم شروع می‌شود و سپس درخت‌های دیگر را با رویکرد حریم‌صانه و با استفاده از تقویت گرادیان، تکنیک‌های منظم‌سازی و هرس بهینه می‌کند. در این روش در هر مرحله از تکرار میزان پیچیدگی درخت به‌صورت جداگانه انتخاب و کنترل می‌شود و تعداد برگ‌ها در همه تکرارها ثابت نخواهد بود (Chen et al., 2015).

### ۳.۴.۳) تقویت دسته<sup>۱۴</sup>

تقویت دسته (Dorogush et al., 2018) از زیرمجموعه رویکردهای تقویت گرادیان الگوریتم‌های یادگیری گروهی است. این الگوریتم شامل تکنیک‌های منظم‌سازی برای جلوگیری از بیش‌برازش است و همچنین قابلیت آموزش موازی را برای

<sup>1</sup> Problem Transformation

<sup>2</sup> Adapted Algorithm

<sup>3</sup> Binary Relevance

<sup>4</sup> Classifier Chains

<sup>5</sup> Label Powerset

<sup>6</sup> Multi-Class

<sup>7</sup> K-Nearest Neighbors (KNN)

<sup>8</sup> Metric

<sup>9</sup> Euclidean Distance

<sup>10</sup> XGBoost (Extreme Gradient Boosting)

<sup>11</sup> Ensemble Learning

<sup>12</sup> Boosting

<sup>13</sup> Gradient descent

<sup>14</sup> Category Boosting (CatBoost)

محاسبات سریع تر فراهم می کند. این الگوریتم از دو مرحله برای ساخت درخت تشکیل شده است. مرحله اول عبارتست از انتخاب ساختار درخت و مرحله دوم شامل تعیین مقدار برگ است (Tanha et al., 2020).

### ۴.۴.۳ جنگل تصادفی<sup>۱</sup>

در این الگوریتم که یکی از الگوریتم های یادگیری گروهی است، چندین درخت تصمیم بر روی زیرمجموعه های مختلف داده های آموزشی و زیرمجموعه های مختلف ویژگی های ورودی، آموزش داده می شوند. هر درخت باید روی همان زیرمجموعه، طبقه بند خود را بسازد و پیش بینی را ارائه دهد. پیش بینی نهایی تجمیع اکثریت آرای پیش بینی های درختان تصمیم گیر منفرد است. جنگل های تصادفی با وجود سادگی، یکی از قدرتمندترین الگوریتم های یادگیری ماشین در دسترس هستند و به دلیل ترکیب نتایج درختان مختلف احتمال پایینی وجود دارد تا دچار بیش برآزش شوند (Pavlov, 2019).

### ۵.۳ ارزیابی

پیش از ارزیابی عملکرد الگوریتم های پیاده سازی شده، لازم است مجموعه داده به دو مجموعه داده آموزش و ارزیابی تقسیم شوند. در این پژوهش ابتدا از روش نگهدارنده<sup>۲</sup> برای کنار گذاشتن بخشی از مجموعه داده به عنوان مجموعه داده آزمون استفاده و سپس روش اعتبارسنجی<sup>۳</sup> متقابل برای تقسیم مجموعه داده آموزش به دو مجموعه آموزش و اعتبارسنجی بکار برده می شود.

### ۱.۵.۳ معیارهای ارزیابی عملکرد الگوریتم های ارزیابی

معیارهای ارزیابی مورد استفاده در این پژوهش و نحوه محاسبه آنها در جدول (۳) ارائه شده اند. معیارهای دقت و یادآوری از ماتریس درهم ریختگی<sup>۴</sup> استخراج می شوند (Han et al., 2012) و معیار شاخص ارزیابی F1، میانگین هارمونیک دو معیار بازخوانی و دقت است (Rivoli et al., 2020).

جدول ۳. معیارهای ارزیابی

رابطه	نام معیار
$\text{دقت} = \frac{\text{تعداد منفی صحیح} + \text{تعداد مثبت صحیح}}{\text{تعداد منفی کاذب} + \text{تعداد مثبت صحیح}}$	دقت <sup>۵</sup>
$\text{بازخوانی} = \frac{\text{تعداد مثبت صحیح}}{\text{تعداد منفی صحیح} + \text{تعداد مثبت صحیح}}$	بازخوانی <sup>۶</sup>

<sup>1</sup> Random Forrest

<sup>2</sup> Hold-Out

<sup>3</sup> Cross Validation

<sup>4</sup> Confusion matrix

<sup>5</sup> Precision

<sup>6</sup> Recall

$F1 - Score = 2 \times \frac{\text{بازخوانی} \times \text{دقت}}{\text{بازخوانی} + \text{دقت}}$	شاخص ارزیابی $F1^1$ (Tsoumakas et al., 2010)
$Hamming Loss = \frac{1}{NL} \sum_{j=1}^N \sum_{i=1}^L xor[\tilde{y}_j^i \neq y_j^i]$ <p> <math>y_j^i</math> = برچسب‌های واقعی  <math>\tilde{y}_j^i</math> = برچسب‌های پیش‌بینی شده  <math>N</math> = تعداد نمونه‌ها یا رکوردها </p>	ضرر همینگ <sup>۲</sup> (Wu & Zhu, 2020)
$Jaccard Index = \frac{\tilde{y}_j^i \cap y_j^i}{\tilde{y}_j^i \cup y_j^i}$	جاکارد <sup>۳</sup> (Krawezik et al., 2018)

#### ۴ یافته‌های پژوهش

پیش از آنکه ادامه مراحل مدل‌سازی انتخاب شیوه تأمین مالی در استارت‌آپ‌ها با در نظر گرفتن الگوهای رفتاری تشریح گردد، لازم است تا شناختی از مجموعه داده مورد بررسی به دست آید. به این منظور در بخش بعدی، داده‌های حاصل از پرسشنامه به اختصار تشریح می‌گردند.

#### ۱.۴ آمار توصیفی

همانطور که گفته شد تعداد داده‌های جمع‌آوری شده در این پژوهش ۷۰ نفر از بنیان‌گذاران استارت‌آپ‌ها، شامل ۵۶ مرد و ۱۴ زن بودند که ۷۴ درصد آنان در بازه سنی کمتر از ۴۰ سال قرار دارند. این مسئله حاکی از این امر است که بیشتر بنیان‌گذاران استارت‌آپ‌ها جوان هستند و در تصمیم‌گیری‌ها از راهنمایی‌های بیرونی استفاده می‌نمایند. ۳۲ درصد بنیان‌گذاران پاسخ‌دهنده به پرسشنامه این پژوهش، درآمدی کمتر از ۱۰ میلیون تومان در ماه دارند. توجه به این مسئله برای انتخاب روش‌های تأمین مالی نکته بااهمیتی است چراکه درآمد بالا تنها عاملی است که افراد را در مراحل ابتدایی و راه‌اندازی، از اتکا به روش‌های تأمین مالی بیرونی بی‌نیاز کرده و همچنین در بسیاری از روش‌های تأمین مالی، یکی از ملاک‌های تاثیرگذار در اعتبارسنجی مالی است. حدود ۸۳ درصد پاسخ‌دهندگان دارای تحصیلات کارشناسی یا کارشناسی‌ارشد هستند که در دسترسی ایشان به شیوه‌های تأمین مالی مختلف موثر است.


مطابق با پژوهش‌های پیشین، در دسترس‌ترین شیوه تأمین مالی برای استارت‌آپ‌ها در مراحل اولیه، روش پرداخت شخصی پیش‌بینی شد و نتایج داده‌های این پژوهش نیز موید و حاکی از این است که نزدیک به ۸۶ درصد بنیان‌گذاران استارت‌آپ‌ها از این روش جهت تأمین مالی استفاده کرده‌اند.

<sup>1</sup> F1-Score

<sup>2</sup> Hamming Loss

<sup>3</sup> Jaccard






شکل ۲. روش‌های تامین مالی که بنیان‌گذاران استارت‌آپ‌ها استفاده/عدم استفاده کرده‌اند

نتایج حاصل از چهار سوگیری رفتاری که در پرسشنامه این پژوهش مورد سنجش قرار گرفتند، در شکل (۳) قابل مشاهده است. به ترتیب بیشترین سوگیری‌های مشاهده شده در بین بنیان‌گذاران پاسخ‌دهنده به پرسشنامه این پژوهش، ریسک‌گریزی، اعتماد به نفس بیش از حد، لنگرانداختن و توهم کنترل است. این مسئله تاییدکننده این است که بنیان‌گذاران استارت‌آپ‌ها در معرض سوگیری‌های رفتاری هستند. برخلاف تصور اقتصاد متعارف از رفتار انسان در تصمیمات مالی و غیرمالی، سوگیری‌های رفتاری موجب فاصله گرفتن افراد از تصمیمات عقلانی می‌شود. اطلاع از این امر که افراد در تصمیم‌گیری عقلایی عمل نمی‌کنند، برای سرمایه‌گذاران و سرمایه‌پذیران این فرصت را فراهم می‌کند که با به‌دست آوردن شناخت کافی از این سوگیری‌ها از آثار منفی آن در تصمیمات خود اجتناب کنند.



شکل ۳. سوگیری‌های شناسایی شده در بنیان‌گذاران پاسخ‌دهنده به پرسشنامه پژوهش

شکل (۴) نشان‌دهنده روش‌های تأمین مالی است که بنیان‌گذاران استارت‌آپ‌ها در صورت فراهم بودن تمامی شرایط، تمایل به استفاده از آن دارند. مطابق این نمودار حتی در صورت فراهم بودن تمامی شرایط، روش پرداخت شخصی اولویت اصلی پاسخ‌دهندگان را تشکیل می‌دهد. این مسئله تایید‌کننده و همسو با فراوانی سوگیری زیان‌گریزی در بین پاسخ‌دهندگان این پرسشنامه است و نشان می‌دهد که لزوماً در دسترس بودن روش تأمین مالی، علت انتخاب یا عدم انتخاب یک روش نیست. نکته قابل توجه دیگر در این نمودار، گزینه سایر در بین روش‌های تأمین مالی است. مطابق پاسخ‌ها، سایر روش‌های تأمین مالی شامل کمک‌های حمایتی نهادهایی مانند صندوق نوآوری و شکوفایی، معاونت علمی، فناوری و اقتصاد دانش‌بنیان ریاست جمهوری، پارک‌های علم و فناوری، مراکز رشد و صندوق‌های پژوهش و فناوری است. این روش‌های تأمین مالی معمولاً دارای کارمزدهای ترجیحی نسبت به سایر روش‌های تأمین مالی هستند و شرایط دریافت آنان به گونه‌ای است که برای استارت‌آپ‌ها قابل استفاده باشند.



شکل ۴. روش های تامین مالی که بنیان گذاران پاسخ دهنده در این پژوهش تمایل به استفاده/عدم استفاده داشتند

#### ۲.۴ مدل سازی و پیاده سازی الگوریتم ها

همانطور که در بخش قبل شرح داده شد، الگوریتم ها بر روی مجموعه داده پیاده سازی شدند و نتایج پیاده سازی الگوریتم ها بر روی مجموعه داده اعتبارسنجی در جدول (۴) قابل مشاهده است.

جدول ۴. عملکرد الگوریتم های پیاده سازی بر روی مجموعه داده اعتبارسنجی

جاکارد	ضرر همینگ	شاخص ارزیابی FI	فراخوانی	دقت	رویکرد حل مسئله	
۰/۳۷	۰/۵۵	%۵۲	%۴۰	%۸۲	تطابق دو دویی	تبدیل مسئله
۰/۴۶	۰/۴۷	%۶۱	%۵۰	%۸۴	زنجیره های طبقه بندی کننده	
۰/۷۵	۰/۲۳	%۸۵	%۸۵	%۸۵	مجموعه توان بر چسب ها	
۰/۷۸	۰/۲۱	%۸۸	%۹۳	%۸۵	تقویت گرادیان شدید	الگوریتم های تطابق یافته
۰/۸	۰/۱۹	%۸۹	%۹۵	%۸۴	K- نزدیکترین همسایه (K=۱۳)	
۰/۸۳	۰/۱۵	%۹۱	%۹۹	%۸۴	تقویت دسته	
۰/۸۱	۰/۱۸	%۹۰	%۹۸	%۸۴	جنگل تصادفی	

مشاهده می شود که اکثر الگوریتم های پیاده سازی شده، عملکرد قابل قبولی را با معیارهای ارزیابی در مجموعه داده اعتبارسنجی ارائه داده اند. این امر نشان می دهد که انتخاب عوامل و رویکرد حل مسئله با توجه به ماهیت داده ها به درستی طی شده است. در میان الگوریتم های پیاده سازی شده، الگوریتم تقویت دسته در اکثریت معیارهای ارزیابی، عملکرد بهتری نسبت به سایر الگوریتم ها در مجموعه داده اعتبارسنجی دارد. بنابراین الگوریتم تقویت دسته انتخاب شده و مجموعه داده

آزمون که کنار گذاشته شده بود، فراخوانی می‌گردد. پس از آن آماده‌سازی داده‌ها اجرا شده و الگوریتم بر روی آن پیاده‌سازی می‌گردد. در جدول (۵) عملکرد این الگوریتم در مجموعه داده آزمون قابل مشاهده است.

جدول ۵. ارزیابی عملکرد بهترین الگوریتم پیاده‌سازی در مجموعه داده آزمون

رویکرد حل مسئله	دقت	فراخوانی	شاخص ارزیابی FI	ضرر همینگ	جاکارد
تقویت دسته	٪۸۱	٪۹۹	٪۸۹	۰/۲۰	۰/۷۹

مقادیر ویژگی‌های ورودی و ویژگی‌های پیش‌بینی شده برای مجموعه داده آزمون این پژوهش به شرح پیوست ۲ است. همانطور که در جدول (۵) مشاهده می‌شود با استفاده از این الگوریتم، مدل قادر خواهد بود با دریافت ورودی‌ها که مطابق توضیحات بخش ۳ آماده‌سازی می‌شوند، روش‌های تأمین مالی که بنیان‌گذاران استارت‌آپ‌ها انتخاب می‌کنند را در مجموعه داده آزمونی که در فرآیند آموزش حضور نداشته‌است، با شاخص ارزیابی FI معادل ۸۹ درصد پیش‌بینی نماید.

#### ۴.۲.۱ مطالعه موردی

برای بررسی عملکرد مدل؛ یک بنیان‌گذار استارت‌آپ مراجعه‌کننده برای تأمین مالی، با ویژگی‌های ورودی مطابق جدول (۶) مورد مطالعه قرار گرفته‌است. پس از طی فرآیند آماده‌سازی داده‌ها، نتیجه پیش‌بینی در جدول (۷) نشان داده شده‌است. مطابق نتیجه به دست آمده، فرد مورد مطالعه از روش‌های تأمین مالی پرداخت شخصی و سرمایه‌گذاری خطرپذیر استفاده می‌کند. نتیجه حاصل از مطالعه استارت‌آپ‌های مختلف به سرمایه‌گذاران اعم از شتاب‌دهنده‌ها، پارک‌های علم و فناوری، سکوی‌های تأمین مالی و سایرین امکان می‌دهد که با در اختیار داشتن این اطلاعات بتوانند در مذاکرات تأمین مالی، پیشنهادات مناسبی به سرمایه‌پذیران ارائه دهند.

جدول ۶. نمونه داده ورودی

سرمایه‌گذاران	سرمایه‌گذاران	سرمایه‌گذاران	سرمایه‌گذاران	سرمایه‌گذاران	سرمایه‌گذاران	سرمایه‌گذاران	سرمایه‌گذاران	سرمایه‌گذاران	سرمایه‌گذاران	سرمایه‌گذاران	سرمایه‌گذاران
خط‌پذیر	خط‌پذیر	خط‌پذیر	خط‌پذیر	خط‌پذیر	خط‌پذیر	خط‌پذیر	خط‌پذیر	خط‌پذیر	خط‌پذیر	خط‌پذیر	خط‌پذیر
۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱

سابقه فروش	سابقه تولید	ثبت اختراع	نوع استارت‌آپ	تعداد اعضای تیم	سابقه کار کارآفرینی	سابقه کار تجاری	درآمد ماهانه	تحصیلات	سن	جنسیت	سن استارت‌آپ	استارت‌آپ فعال است؟
۱	۱	۱	۰	۱۲	۱۲	۰	۵	۵	۴	۱	۵	۱

جدول ۷. روش‌های تامین مالی پیش‌بینی شده توسط مدل توسعه یافته برای نمونه داده ورودی

فرد خاص داخلی	خانواده و دوستان	وام‌های بانکی	سرمایه‌گذاران فروخته	شتاب‌دهنده‌ها	سرمایه‌گذاران خطرپذیر	سرمایه‌گذاران خطرپذیر
۰	۱	۱	۱	۱	۰	۱

### ۵) نتیجه‌گیری و پیشنهادها

این پژوهش با هدف پیش‌بینی انتخاب شیوه تامین مالی در استارت‌آپ‌ها، با ادغام سوگیری‌های رفتاری در چارچوب مدل‌سازی داده‌محور، بازنمایی جامع‌تر و واقعی‌تر از فرآیند تصمیم‌گیری را ارائه می‌دهد. همچنین کارآفرینان و سرمایه‌گذاران را قادر می‌سازد تا پیچیدگی‌های تامین مالی استارت‌آپ‌ها را به‌طور موثرتری دنبال کنند. در این پژوهش ۱۰ روش تامین مالی رایج در ادبیات موضوع شناسایی شده و تعدادی از عوامل موثر و دردسترس، برای مدل‌سازی انتخاب و عملکرد مدل بر روی مجموعه داده آموزش و آزمون موردبررسی قرار گرفت. همانطور که مشاهده شد مدل توسعه یافته با دقت قابل قبولی، روش‌های تامین مالی مناسب برای هر استارت‌آپ را پیش‌بینی می‌کند و به سرمایه‌گذاران امکان می‌دهد تا پیشنهادات شخصی‌سازی شده‌ای ارائه دهند. با بررسی داده‌های جمع‌آوری شده مشاهده گردید که فراوانی سوگیری‌های رفتاری در بنیان‌گذاران استارت‌آپ‌ها با انتخاب شیوه‌های تامین مالی که استفاده یا تمایل به استفاده دارند، هم‌خوانی دارد. نتایج این پیش‌بینی می‌تواند برای سیاست‌گذاران جهت تدوین برنامه و فراهم آوردن زیرساخت‌های مناسب بابت استفاده از شیوه‌های تامین مالی مختلف و متناسب با نیاز هر یک از کارآفرینان موثر باشد. همچنین این نتایج برای سرمایه‌گذاران جهت شناسایی انتخاب‌ها و اولویت‌های کارآفرینان و بهره‌برداری از آن بابت دستیابی به اهداف سرمایه‌گذاری کمک‌کننده می‌باشد. این موضوع برای کارآفرینان نیز بی‌تاثیر نبوده و جهت سنجش گزینه‌های تامین مالی پیش از ورود به بازار و راه‌اندازی کسب‌وکار و یا در جهت توسعه کسب‌وکار مفید خواهد بود.

در میان روش‌های استفاده شده برای مدل‌سازی در این پژوهش، الگوریتم تقویت دسته از الگوریتم‌های یادگیری گروهی می‌تواند روش‌های تامین مالی که استارت‌آپ‌ها انتخاب می‌کنند را با شاخص ارزیابی F1 معادل ۸۹ درصد و دقت معادل ۸۵ درصد بر روی مجموعه داده آزمون پیش‌بینی نماید. برای ادامه این پژوهش می‌توان مدل‌سازی را با در نظر گرفتن عوامل اقتصاد کلان از جمله انتظارات تورمی و بررسی تمایل به ریسک‌پذیری افراد با تغییرات انتظارات تورمی انجام داد و یا مدل این مسئله را در موسسات مالی پیاده‌سازی کرده و صحت عملکرد آن را بررسی نمود. همچنین با توجه به استفاده بالای ۸۵ درصدی از روش تامین مالی پرداخت شخصی در میان بنیان‌گذاران استارت‌آپ‌های این پژوهش، در پژوهش‌های آتی به واکاوی این انتخاب پرداخته می‌شود.

## منابع

1. Azoulay, P., Jones, B. F., Kim, J. D., & Miranda, J. (2020). Age and high-growth entrepreneurship. *American Economic Review: Insights*, 2(1), 65-82. <https://dx.doi.org/10.3386/w24489>
2. Bailly, A., Blanc, C., Francis, É., Guillotin, T., Jamal, F., Wakim, B., & Roy, P. (2022). Effects of dataset size and interactions on the prediction performance of logistic regression and deep learning models. *Computer Methods and Programs in Biomedicine*, 213, 106504. <http://dx.doi.org/10.1016/j.cmpb.2021.106504>.
3. Bazerman, M. H., & Moore, D. A. (2012). *Judgment in managerial decision making*. John Wiley & Sons. <http://dx.doi.org/10.4324/9780203141939-11>
4. Bolarinwa, O. A. (2015). Principles and methods of validity and reliability testing of questionnaires used in social and health science researches. *Nigerian Postgraduate Medical Journal*, 22(4), 195. <http://dx.doi.org/10.4103/1117-1936.173959>
5. Brownlee, J. (2020). *Data preparation for machine learning: data cleaning, feature selection, and data transforms in Python*. Machine Learning Mastery .
6. Cassar, G. (2004). The financing of business start-ups. *Journal of Business Venturing*, 19(2), 261-283. [https://doi.org/10.1016/S0883-9026\(03\)00029-6](https://doi.org/10.1016/S0883-9026(03)00029-6)
7. Chen, T., He, T., Benesty, M., Khotilovich, V., Tang, Y., Cho, H., Chen, K., Mitchell, R., Cano, I., & Zhou, T. (2015). Xgboost: extreme gradient boosting. R package version 0.4-2, 1(4), 1-4. <http://dx.doi.org/10.32614/cran.package.xgboost>
8. Ding, H., Sun, Y., Wang, Z., Huang, N., Shen, Z., & Cui, X. (2023). RGAN-EL: A GAN and ensemble learning-based hybrid approach for imbalanced data classification. *Information Processing & Management*, 60(2), 103235. <http://dx.doi.org/10.1016/j.ipm.2022.103235>
9. Dominic, C., & Gupta, A. (2020). Psychological factors affecting investors decision making. *Journal of Xi'an University of Architecture and Technology*, 7(6), 169-181. <http://dx.doi.org/10.55041/ijrsrem30872>.
10. Dong, X., Yu, Z., Cao, W., Shi, Y., & Ma, Q. (2020). A survey on ensemble learning. *Frontiers of Computer Science*, 14, 241-258. <http://dx.doi.org/10.1007/s11704-019-8208->.
11. Dorogush, A. V., Ershov, V., & Gulin, A. (2018). CatBoost: gradient boosting with categorical features support. arXiv preprint arXiv:1810.11363. <https://doi.org/10.48550/arXiv.1810.1136>.
12. Elston, D. M. (2021). Survivorship bias. *Journal of the American Academy of Dermatology*. <http://dx.doi.org/10.1016/j.jaad.2021.06.84>.
13. Fotouhi, S., Asadi, S., & Kattan, M. W. (2019). A comprehensive data level analysis for cancer diagnosis on imbalanced data. *Journal of biomedical informatics*, 90, 103089. <https://doi.org/10.1016/j.jbi.2018.12.003>
14. Franco, S., Cappa, F., & Pinelli, M. (2021). Founder Education and Start-Up Funds Raised. *IEEE Engineering Management Review*, 49(3), 42-48. <https://doi.org/10.1109/EMR.2021.3077966>
15. Frid, C. J., Wyman, D. M., Gartner, W. B., & Hechavarria, D. H. (2016). Low-wealth entrepreneurs and access to external financing. *International Journal of Entrepreneurial Behavior & Research*. <http://dx.doi.org/10.1108/ijeb-08-2015-0173>
16. Ganda, D., & Buch, R. (2018). A survey on multi label classification. *Recent Trends in Programming Languages*, 5(1), 19-23
17. Gong, J., & Kim, H. (2017). RHSBoost: Improving classification performance in imbalance data. *Computational Statistics & Data Analysis*, 111, 1-13. <http://dx.doi.org/10.1016/j.csda.2017.01.005>
18. Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y. (2020). Generative adversarial networks. *Communications of the ACM*, 63(11), 139-144 .
19. <https://doi.org/10.1145/3422622>
20. Han, J., Kamber, M., & Pei, J. (2012). *Data mining concepts and techniques third edition*. University of Illinois at Urbana-Champaign Micheline Kamber Jian Pei Simon Fraser University .
21. Hebert, C. (2020). Gender stereotypes and entrepreneur financing. 10th Miami Behavioral Finance Conference.

22. Israel, G. D. (1992). Determining sample size. <https://dx.doi.org/10.2139/ssrn.3318245>
23. Jafari, R. (2022). Hands-On Data Preprocessing in Python: Learn How to Effectively Prepare Data for Successful Data Analytics. Packt Publishing. <https://books.google.com/books?id=nzmnzgEACAAJ>.
24. Kahneman, D. (2011). Thinking, fast and slow. Macmillan .
25. Krawezik, G. P., Kogge, P. M., Dysart, T. J., Kuntz, S. K., & McMahon, J. O. (2018). Implementing the jaccard index on the migratory memory-side processing emu architecture. 2018 IEEE High Performance extreme Computing Conference (HPEC).
26. Langer, E. J. (1975). The illusion of control. *Journal of personality and social psychology*, 32(2), 311. <http://dx.doi.org/10.1037//0022-3514.32.2.311>
27. Lybaert, N., & Umans, I. (2022). Start-up Performance: Looking for an Explanation in Entrepreneurial Characteristics and Financing Choice. *European Conference on Innovation and Entrepreneurship*, <https://doi.org/10.34190/ecie.17.1.833>
28. Marsland, S. (2014). *Machine Learning: An Algorithmic Perspective, Second Edition*. CRC Press. <https://books.google.com/books?id=6GvSBQAAQBAJ>.
29. McCallum, Q. E. (2012). *Bad data handbook: cleaning up the data so you can get back to work*. " O'Reilly Media, Inc .".
30. Myung, I. J. (2000). The importance of complexity in model selection. *Journal of mathematical psychology*, 44(1), 190-204. <https://doi.org/10.1006/jmps.1999.1283>
31. Ouimet, P., & Zarutskie, R. (2014). Who works for startups? The relation between firm age, employee age, and growth. *Journal of financial Economics*, 112(3), 386-407. <https://doi.org/10.1016/j.jfineco.2014.03.003>
32. Pavlov, Y. L. (2019). Random forests. In *Random Forests*. De Gruyter .
33. Pushpa, M., & Karpagavalli, S. (2017). Multi-label classification: problem transformation methods in Tamil phoneme classification. *Procedia Computer Science*, 115, 572-579. <https://doi.org/10.1016/j.procs.2017.09.116>
34. Ramalakshmi, V., Pathak, V. K., & Mary, C. (2019). Impact of Cognitive Biases on investment decision making. *Journal of Critical Reviews*, 6(6), 59-64
35. Rivolli, A., Read, J., Soares, C., Pfahringer, B., & de Carvalho, A. C. (2020). An empirical analysis of binary transformation strategies and base algorithms for multi-label learning. *Machine Learning*, 109, 1509-1563. <https://doi.org/10.1007/s10994-020-05879-3>
36. Rosenfeld, A., & Kraus, S. (2018). Predicting human decision-making: From prediction to action. *Synthesis lectures on artificial intelligence and machine learning*, 12(1), 1-150. [https://doi.org/10.1007/978-3-031-01578-6\\_3](https://doi.org/10.1007/978-3-031-01578-6_3)
37. Rosyidah, U., & Pratikto, H. (2022). The role of behavioral bias on financial decision making: a systematic literature review and future research agenda. *Journal of Enterprise and Development (JED)*, 4(1), 156-179. <https://doi.org/10.20414/jed.v4i1.5102>
38. Simon, M., & Houghton, S. M. (2003). The relationship between overconfidence and the introduction of risky products: Evidence from a field study. *Academy of management journal*, 46(2), 139-149. <https://doi.org/10.5465/30040610>
39. Tanha, J., Abdi, Y., Samadi, N., Razzaghi, N., & Asadpour, M. (2020). Boosting methods for multi-class imbalanced data classification: an experimental review. *Journal of Big Data*, 7, 1-47. <https://doi.org/10.1186/s40537-020-00349-y>
40. Tech, R. P. (2018). *Financing high-tech startups*. Springer. <https://doi.org/10.1007/978-3-319-66155-1>
41. Tsoumakas, G., Katakis, I., & Vlahavas, I. (2010). Mining multi-label data. *Data mining and knowledge discovery handbook*, 667-685. [https://doi.org/10.1007/978-0-387-09823-4\\_34](https://doi.org/10.1007/978-0-387-09823-4_34)
42. Ul Abdin, S. Z., Qureshi, F., Iqbal, J., & Sultana, S. (2022). Overconfidence bias and investment performance: A mediating effect of risk propensity. *Borsa Istanbul Review*, 22(4), 780-793. <https://doi.org/10.1016/j.bir.2022.03.001>
43. Vo, D. H. (2019). Patents and Early-Stage Financing: Matching versus Signaling. *Journal of small business management*, 57(4), 1252-1279. <https://doi.org/10.1111/jsbm.12414>

44. Wu, G., & Zhu, J. (2020). Multi-label classification: do Hamming loss and subset accuracy really conflict with each other? *Advances in Neural Information Processing Systems*, 33, 3130-3140. <https://doi.org/10.48550/arXiv.2011.07805>
45. Zahera, S. A., & Bansal, R. (2018). Do investors exhibit behavioral biases in investment decision making? A systematic review. *Qualitative Research in Financial Markets*. <https://doi.org/10.1108/QRFM-04-2017-0028>
46. Zhang, S. X., & Cueto, J. (2017). The study of bias in entrepreneurship. *Entrepreneurship theory and Practice*, 41(3), 419-454. <https://doi.org/10.1111/etap.12212>
47. Zhang, S. X., Foo, M.-D., & Vassolo, R. S. (2021). The ramifications of effectuation on biases in entrepreneurship—Evidence from a mixed-method approach. *Journal of Business Venturing Insights*, 15, e00238. <https://doi.org/10.1016/j.jbvi.2021.e00238>
48. Zhang, Y., & Thorburn, P. J. (2022). Handling missing data in near real-time environmental monitoring: A system and a review of selected methods. *Future Generation Computer Systems*, 128, 63-72. <https://doi.org/10.1016/j.future.2021.09.033>



## پیوست (۱)

جدول ۷. متغیرهای مستقل و هدف پژوهش

مقدار		نام ویژگی	ردیف
۱	بله	آیا شرکت شما فعال است؟	۱
۰	خیر		
		چند سال از تاسیس شرکت شما می‌گذرد؟	۲
۱	زن	جنسیت	۳
۰	مرد		
۰	زیر ۲۵	سن	۴
۱	۲۶ تا ۳۰		
۲	۳۱ تا ۳۵		
۳	۳۶ تا ۴۰		
۴	بالای ۴۰		
۰	زیر دیپلم	تحصیلات	۵
۱	دیپلم		
۲	فوق دیپلم		
۳	کارشناسی		
۴	کارشناسی ارشد		
۵	دکتری		
۶	فوق دکتری	میزان درآمد ماهانه	۶
۰	درآمدی ندارد		
۱	زیر ۵م		
۲	از ۵ تا ۱۰ م		
۳	از ۱۰ تا ۱۵ م		
۴	از ۱۵ تا ۲۰ م		
۵	۲۰ م به بالا	سابقه کار تجاری	۷
۶	تمایلی ندارد بگویم		
		سابقه کار آفرینی	۸
		تعداد کارمندان شرکت	۹
۰	خدماتی	نوع شرکت	۱۰
۱	تولیدی		
۲	سایر		
۰	پایین	درجه فناوری	۱۱
۱	متوسط		
۲	بالا		
۱	دارد	ثبت اختراع	۱۲
۰	ندارد		
۱	دارد	تولید محصول	۱۳
۰	ندارد		
۱	دارد	فروش	۱۴
۰	ندارد		
		میزان سرمایه راهاندازی	۱۵
در صورت امکان تمایل به استفاده از چه شیوه‌های تامین مالی دارید؟ ۱: تمایل ندارد		سرمایه شخصی	۱۶
		خانواده و دوستان	۱۷

ویژگی‌های مستقل

و ۰: تعامیل دارد	وام‌های بانکی	۱۸	
	سرمایه‌گذاران فرشته	۱۹	
	شتاب‌دهنده‌ها	۲۰	
	سرمایه‌گذاران خطرپذیر	۲۱	
	سرمایه‌گذاران خطرپذیر شرکی	۲۲	
	سایر	۲۳	
۱	دارد	سوگیری اعتماد به نفس بیش از حد	۲۴
۰	ندارد		
۱	دارد	سوگیری زبان‌گزینی	۲۵
۰	ندارد		
۱	دارد	سوگیری لنگرانداختن	۲۶
۰	ندارد		
۱	دارد	سوگیری توهم کنترل	۲۷
۰	ندارد		
استفاده از شیوه/های تأمین مالی؟ ۱: استفاده نمی‌کند و ۰: استفاده می‌کند	پرداخت شخصی	تأمین مالی	۲۸
	خانواده و دوستان		۲۹
	وام‌های بانکی		۳۰
	سرمایه‌گذاران فرشته		۳۱
	شتاب‌دهنده‌ها		۳۲
	سرمایه‌گذاران خطرپذیر		۳۳
	سرمایه‌گذاران خطرپذیر شرکی		۳۴
	سایر		۳۵

پیوست ۲

مقادیر ویژگی‌های مستقل و هدف در جدول ۹ و ۱۰ قابل مشاهده هستند.

جدول ۹. مجموعه داده آزمون (ویژگی‌های ورودی)

نمونه‌ها	استار تاپ فعال است؟	سن استار تاپ	جنسیت	سن	تحصیلات	درآمد ماهانه	سابقه کار تجاری	سابقه کار آفرینی	تعداد اعضای تیم	نوع استار تاپ	تبت اختراع	سابقه تولید	سابقه فروش	سرمایه اولیه	پرداخت شخصی	خانواده و دوستان	وام‌های بانکی	سرمایه‌گذاران فرشته	شتاب‌دهنده‌ها	سرمایه‌گذاران	سرمایه‌گذاران	سوگیری زبان گریزی	سوگیری لنگر انداختن	سوگیری اعتماد به	سوگیری توهم کنترل
۱	۰	۲	۱	۱	۲	۰	۰	۲	۲	۰	۱	۱	۰	۵۰,۰۰۰,۰۰۰	۱	۰	۱	۱	۰	۱	۱	۰	۱	۱	
۲	۱	۵	۰	۴	۲	۳	۲۰	۱۵	۷	۰	۰	۰	۱	۱۰۰,۰۰۰	۰	۱	۱	۰	۱	۱	۰	۱	۰	۱	۰
۳	۱	۲	۱	۲	۲	۰	۰	۰	۴	۰	۰	۰	۰	۲۰۰,۰۰۰	۰	۱	۰	۰	۰	۱	۰	۱	۱	۰	۰
۴	۱	۲	۰	۱	۲	۰	۰	۰	۲	۰	۰	۰	۱	۱,۰۰۰,۰۰۰	۰	۰	۱	۱	۱	۱	۱	۱	۱	۱	۰
۵	۱	۴	۰	۰	۴	۵	۷	۳	۱۰۰	۲	۰	۰	۱	۳۰۰,۰۰۰,۰۰۰	۱	۱	۱	۱	۱	۱	۰	۱	۰	۱	۱
۶	۱	۴	۰	۱	۴	۰	۵	۵	۲	۲	۰	۱	۱	۱۱۰,۰۰۰,۰۰۰	۱	۱	۰	۱	۱	۱	۱	۰	۱	۰	۰
۷	۱	۴	۰	۱	۴	۶	۵	۴	۰	۰	۰	۱	۱	۰	۱	۱	۰	۱	۰	۱	۱	۱	۱	۱	۰
۸	۱	۲	۱	۲	۳	۱	۴	۳	۵	۰	۰	۰	۱	۷,۰۰۰,۰۰۰	۰	۱	۱	۱	۱	۱	۱	۱	۰	۰	۱
۹	۱	۴	۰	۲	۴	۵	۰	۰	۲	۰	۰	۰	۰	۵,۰۰۰,۰۰۰	۰	۱	۱	۱	۱	۱	۰	۰	۱	۰	۰
۱۰	۱	۱	۱	۱	۴	۲	۰	۲	۵	۰	۰	۱	۱	۵,۰۰۰,۰۰۰	۰	۱	۱	۰	۱	۱	۱	۱	۱	۱	۰
۱۱	۰	۵	۱	۳	۴	۶	۱۲	۰	۲	۰	۰	۰	۱	۰	۱	۱	۰	۱	۱	۱	۱	۱	۱	۱	۱
۱۲	۰	۵	۰	۱	۳	۰	۷	۳	۲	۰	۰	۰	۱	۲۵۰,۰۰۰,۰۰۰	۰	۱	۱	۰	۱	۰	۱	۱	۱	۱	۰
۱۳	۰	۳	۰	۱	۴	۰	۵	۳	۱۵	۰	۰	۱	۱	۵۰,۰۰۰,۰۰۰	۰	۱	۰	۱	۱	۱	۱	۰	۰	۰	۰
۱۴	۱	۵	۰	۱	۴	۳	۰	۳	۴	۰	۰	۱	۱	۳,۰۰۰,۰۰۰	۱	۱	۰	۱	۱	۱	۱	۱	۰	۱	۰
۱۵	۱	۵	۱	۴	۵	۵	۰	۱۲	۱۲	۰	۱	۱	۱	۱۰,۰۰۰,۰۰۰	۰	۰	۱	۰	۰	۱	۱	۱	۱	۰	۱
۱۶	۱	۴	۱	۱	۴	۱	۰	۲	۱۲	۰	۱	۱	۱	۵۰,۰۰۰,۰۰۰	۱	۱	۰	۱	۰	۰	۱	۱	۰	۰	۰
۱۷	۰	۸	۱	۲	۴	۰	۰	۰	۵	۱	۰	۰	۰	۵۰۰,۰۰۰	۰	۱	۰	۱	۱	۱	۱	۱	۰	۰	۰
۱۸	۱	۶	۰	۱	۳	۴	۸	۰	۵	۲	۰	۱	۱	۱۰۰,۰۰۰,۰۰۰	۰	۰	۰	۱	۱	۰	۱	۱	۱	۱	۰
۱۹	۱	۴	۰	۴	۴	۵	۲۰	۱۲	۸	۰	۰	۱	۱	۱۵۰,۰۰۰,۰۰۰	۰	۱	۱	۱	۰	۱	۱	۰	۱	۰	۰
۲۰	۱	۴	۰	۰	۴	۳	۱	۲	۲۰	۰	۱	۱	۱	۱,۵۰۰,۰۰۰,۰۰۰	۱	۱	۰	۱	۱	۱	۰	۰	۱	۰	۰
۲۱	۱	۳	۰	۲	۳	۵	۵	۲	۱۲	۰	۰	۰	۱	۱۰,۰۰۰,۰۰۰	۰	۱	۰	۰	۰	۰	۱	۰	۰	۱	۱

جدول ۱۰ مجموعه داده آزمون (متغیر هدف) ۲۱	۲۰	۱۹	۱۸	۱۷	۱۶	۱۵	۱۴	۱۳	۱۲	۱۱	۱۰	۹	۸	۷	۶	۵	۴	۳	۲	۱	نمونه‌ها
۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	پرداخت شخصی
۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	خانواده و دوستان

۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	وام‌های بانکی
۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	سرمایه‌گزاران فرشته
۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	شتاب‌دهنده‌ها
۰	۱	۱	۱	۱	۱	۰	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	سرمایه‌گزاران خطرپذیر
۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	۱	سرمایه‌گزاران خطرپذیر شرکتی

