


Predicting Scientific Research Impacts in Biotechnology by Machine Learning Algorithms

Ghasem
Azadi Ahmadabadi ^{1*}

 1. Assistant Professor, Policy Evaluation and Monitoring of Science, Technology, and Innovation Department, National Research Institute for Science Policy, Tehran, Iran.

Email: azadi_gh@yahoo.com

Abstract

Purpose: Research impact is a key concern for stakeholders, as it reflects the beneficial and profitable applications of research across multiple dimensions, including society, economy, environment, culture, and health. This study aims to analyze the interrelationships among variables influencing scientific outputs and to identify the most effective machine learning algorithms for predicting their scientific, social, and economic impacts.

Methodology: The current research is applied in purpose and descriptive in method, utilizing a scientometric approach. This study aims to explore the relationship between the quantity of scientific publications and scientific cooperation, as well as the scientific, social, and economic impact of Iran's scientific contributions in the field of biotechnology. Additionally, it seeks to determine which machine learning algorithms are more effective in predicting the impact of scientific outputs across various dimensions. The research focuses on Iran's biotechnology scientific outputs indexed in the Scopus database from 2003 to 2024. The data, extracted on 21 January 2024, were analyzed using the SciVal analytical database. In this research, Pearson's correlation coefficient and the R software package were used to examine the relationships between the studied indicators. Machine learning algorithms, including multiple linear regression, nearest neighbors, decision trees, random forests, and gradient boosting, were applied and evaluated as predictive models. The Python programming language was employed to conduct tests and implement these algorithms.

Findings: The findings of this study showed that Iran's scientific outputs in this field in the period from 2003 to 2023 had increased 36 times, which is considered extremely high progress. A positive and significant relationship was observed between international collaboration and various impact indicators, including citation counts, Field-Weighted Citation Impact, Output in Top 10% Citation Percentiles, Patent-Citations Count, Patent-Citations per Scholarly Output, Scholarly Output cited by Patents, Patents Count, Views Count, Output in Top 10% Views Percentiles,


Received:
22/08/2024

Revised:
28/10/2024

Accepted:
12/11/2024

Early online access:
19/11/2024

Published:
01/04/2025



Ghasem
Azadi Ahmadabadi ^{1*}


Received:
22/08/2024

Revised:
28/10/2024

Accepted:
12/11/2024

Early online access:
19/11/2024

Published:
01/04/2025



Views per Publication, and Field-Weighted Views Impact. The index of academic collaboration also shows a positive and significant relationship with several indicators, including citation counts, Field-Weighted Citation Impact, Output in the Top 10% Citation Percentiles, Publications in the Top 10% Journal Percentiles (by Cite Score Percentile), Patents Count, Scholarly Output cited by Patents, Views Count, and Field-Weighted Views Impact. Academic-government collaboration is also positively and significantly correlated with three indicators citations per publication, Patent-Citations Count, and Patent-Citations per Scholarly Output. In the case of the impact of the studied scientific outputs, citation counts are positively and significantly associated with several indicators, including Scholarly Output cited by Patents, Patents Count, Views Count, Views per Publication, and the Field-Weighted Views Impact of the field of biotechnology. In terms of economic impact, the result indicated that the number of patent citations is a key representative indicator. This indicator showed positive and significant relationships with other metrics, including academic Collaboration, international Collaboration, citation counts, citations per Publications, Field-Weighted Citation Impact, Views Count positive and significant relationship in Output in Top 10% Views Percentiles, Views per Publication and Field-Weighted Views Impact in the field of biotechnology. Regarding social impact, the analysis revealed that Views Count is positively and significantly correlated with several indicators, including citation counts, Field-Weighted Citation Impact, the number of patent citations, Patent-Citations per Scholarly Output, Scholarly Output cited by Patents and Patents Count in biotechnology. Based on the results, multivariate linear regression demonstrated higher accuracy and a lower standard deviation, making it a more effective model for predicting the scientific, technological, and social impact of Iran's scientific outputs in biotechnology.

Conclusion: International cooperation is the most significant factor influencing the quality of articles, including metrics such as citations, views, and applicability. Therefore, it is crucial to explore and implement strategies to enhance such collaborations. To better assess the effectiveness of research, it is recommended to employ a diverse set of indicators during both quantitative and qualitative evaluations of articles. For policymakers in science and technology, the primary focus should be on value creation and generating added value, particularly in the economic sector. This is essential despite the observed quantitative and qualitative growth in Iran's scientific outputs.

Keywords: Predicting research impact, Machine learning algorithms, Scientific research impact, Economic research impact, Social research impact.

پیش‌بینی تأثیر‌گذاری پژوهش‌های علمی حوزه زیست‌فناوری با استفاده از الگوریتم‌های یادگیری ماشین

قاسم آزادی احمدآبادی*

۱. استادیار، علم اطلاعات و دانش‌شناسی، گروه ارزیابی سیاست‌ها و پایش علم، فناوری و نوآوری، مرکز تحقیقات سیاست علمی کشور، تهران، ایران.

Email: azadi_gh@yahoo.com

چکیده

هدف: مطالعه حاضر قصد دارد رابطه هر یک از متغیرهای مختلف اثرگذاری بروندادهای علمی را بر همدیگر موردسنجش قرار داده و نیز بررسی کند کدام‌یک از الگوریتم‌های ماشین می‌توانند اثرگذاری علمی، اجتماعی و اقتصادی بروندادهای علمی را پیش‌بینی کنند.

روش‌شناسی: پژوهش حاضر از نظر هدف، کاربردی و از لحاظ روش، توصیفی بوده و با رویکرد علم‌سنجی انجام شده است. جامعه پژوهش، بروندادهای حوزه زیست‌فناوری ایران است که در پایگاه اسکوپوس در بازه ۲۰۰۳-۲۰۲۴ نمایه شده‌اند. برای استخراج داده‌ها از پایگاه تحلیلی سایول استفاده شد. در این پژوهش از ضریب همبستگی پیرسون و از بسته نرم‌افزاری R به منظور تعیین رابطه بین شاخص‌های مورد مطالعه استفاده شد و رگرسیون خطی چندگانه، نزدیک‌ترین همسایه، درخت‌های تصمیم‌گیری، جنگل‌های تصادفی و تقویت گرادیان نیز به عنوان مدل‌های پیش‌بینی کننده، مورد ارزیابی قرار گرفت. به منظور انجام آزمون‌ها و الگوریتم‌ها از زبان برنامه‌نویسی پایتون استفاده شد.

یافته‌ها: در عرصه اثرگذاری خروجی‌های علمی مورد مطالعه، حجم استنادها با شاخص‌های متعددی رابطه مثبت و معنی‌داری داشته است. در حوزه تأثیرگذاری اقتصادی نیز این نتیجه حاصل شد که تعداد استنادات ثبت اختراع به عنوان یکی از شاخص‌های معرف این نوع تأثیر، با موارد متعددی رابطه مثبت و معنی‌داری داشته است. در مورد تأثیرگذاری اجتماعی نیز تعداد بازدیدها رابطه مثبت و معنی‌داری با بسیاری از شاخص‌ها دارد. بر اساس نتایج حاصل شده، رگرسیون خطی چند متغیره با نمره صحت بالاتر و نمره انحراف معیار پایین‌تر، بهتر توانست میزان اثرگذاری علمی، فناورانه و اجتماعی بروندادهای علمی ایران در حوزه زیست‌فناوری را پیش‌بینی کند.

نتیجه‌گیری: مهم‌ترین عامل مؤثر بر کیفیت مقالات از جمله در بُعد استنادها، بازدیدها و کاربردی بودن، همکاری بین‌المللی بوده که در این زمینه لازم است تدابیری اندیشه شود. پیشنهاد می‌شود هنگام ارزیابی کمی و کیفی مقالات، از شاخص‌های متنوعی استفاده گردد تا تصویر شفاف‌تری از اثرگذاری پژوهش‌ها حاصل شود.

واژگان کلیدی: پیش‌بینی تأثیرگذاری پژوهش‌ها، الگوریتم‌های یادگیری ماشین، اثرگذاری علمی پژوهش‌ها، اثرگذاری اقتصادی پژوهش‌ها، اثرگذاری اجتماعی پژوهش‌ها.

صفحه ۲۴-۱

دریافت: ۱۴۰۳/۰۶/۰۱

بازنگری: ۱۴۰۳/۰۸/۰۷

پذیرش: ۱۴۰۳/۰۸/۲۲

زودآیند: ۱۴۰۳/۰۸/۲۹

انتشار: ۱۴۰۴/۰۱/۱۲





مقدمه و بیان مسئله

یکی از عوامل اصلی مؤثر بر توسعه هر جامعه، کمیت و کیفیت فعالیت‌ها و خروجی‌های علمی و فناورانه پژوهشگران و فناوران آن سرزمین است. به همین میزان، موضوع سنجش این تولیدات از زوایای گوناگون نیز اهمیت بسیاری یافته است. از ملزومات سیاست‌گذاری کارآمد و درست در حوزه علم و تحلیل حرکت علمی کشور، انجام پژوهش‌هایی برای شناسایی وضعیت موجود به‌منظور شناسایی نقاط قوت و ضعف آن‌هاست. شاخص‌های علم‌سنجی، مهم‌ترین ابزارهایی هستند که می‌تواند چنین اطلاعاتی را در اختیار برنامه‌ریزان و سیاست‌گذاران قرار دهند (آزادی احمدآبادی، ۱۴۰۳).

با توجه به نقش و اهمیت پژوهش در توسعه و پیشرفت جوامع در برنامه‌های کلان کشورها به‌منظور نیل به گسترش و پیشرفت، به این موضوع توجه اساسی شده و سرمایه‌گذاری‌های کلانی در دانشگاه‌ها و مراکز پژوهشی در این رابطه می‌شود. از این جهت، سرمایه‌گذاران و ذی‌نفعان مایل‌اند بدانند پژوهش‌های آن‌ها چه اثرات علمی درون دانشگاهی و چه اثرات اجتماعی، فرهنگی، اقتصادی و سیاسی خارج از دانشگاه دارد (بابااکبری و همکاران، ۱۴۰۰). از سویی دیگر، ارزیابی تأثیر^۱ پژوهش‌ها و تعیین میزان تحقق اهداف به‌آسانی ممکن نیست؛ زیرا اثربخشی واقعی پژوهش‌ها غیرخطی و غیرقابل پیش‌بینی هستند. آنچه امروزه برای ارزیابی اثربخشی پژوهش مورد توجه قرار می‌گیرد معیارهای سنتی از قبیل تعداد مقالات، ضریب تأثیر نشریات، تعداد گزینش‌ها و تعداد استنادها و غیره هستند (Newson et al., 2015). در واقع، «تأثیر پژوهش» که می‌توان آن را به معنی کاربردهای مثبت و سودآور پژوهش در زمینه‌های مختلف نظیر اجتماع، اقتصاد، محیط‌زیست، فرهنگ، بهداشت و غیره در نظر گرفت از دغدغه‌های کلیدی ذی‌نفعان این حوزه به شمار می‌رود (آزادی احمدآبادی و همکاران، ۱۴۰۱).

واقعیت این است که سنجش تأثیر پژوهش‌ها در ابعاد مختلف به‌سادگی ممکن نیست. آنچه در حال حاضر و به‌طور واقعی در رابطه با تأثیر پژوهش‌های انجام‌گرفته می‌توان پیگیری کرد خروجی‌های علمی است که در پایگاه‌های استنادی بین‌المللی نمایه شده و امکان پیگیری تأثیرگذاری علمی، اجتماعی و اقتصادی آن‌ها تا حدی امکان‌پذیر شده است.

با افزایش تعداد مقالات علمی منتشرشده در سطح جهان، نیاز به ارزیابی و روش‌های نوین سنجش کیفیت مقالات پژوهشی در حال افزایش است (Abrishami & Aliakbary, 2019). بر این اساس، سنجه‌های مختلفی به‌منظور سنجش و ارزیابی تولیدات علمی به جامعه علمی معرفی شده که هرکدام مزایا و معایب خاص خود را دارند و هرروزه برای تکمیل آن‌ها سنجه‌های جدیدتری ایجاد می‌شود. سالیان زیادی است که در حوزه علم‌سنجی در راستای بررسی اثرگذاری علمی پژوهشگران از روش تحلیل استنادی استفاده می‌شود (Bornmann et al., 2013). دگر سنجی نیز یکی از معیارهای نوینی است که بر پایه شاخص‌های مبتنی بر فعالیت در رسانه‌های اجتماعی استوار بوده و به‌عنوان ابزاری برای سنجش تأثیر علمی در محیط وب ظاهر شده است (Wooldridge & King, 2019) که می‌تواند نمایانگر تأثیر فعالیت‌های علمی بر سطوح مختلف جامعه باشد. در کنار این شاخص‌ها برخی ابزارهای تحلیلی که ورودی خود را از پایگاه‌های استنادی دریافت می‌کنند، به دنبال شناسایی اثرگذاری پژوهش‌های علمی بر فناوری بوده‌اند. بر این اساس، پایگاه سایول^۲، شاخص جدیدی را مطرح کرده که بر اساس آن، میزان کاربردی بودن پژوهش‌ها را رصد

1 . Impact
2 . Scival

می‌کند. این کار از طریق پیگیری میزان استنادهای دریافتی و خروجی به پروانه‌های ثبت اختراع انجام می‌شود. در کنار بررسی و ارزیابی اثر پژوهش‌ها که بیشتر مبتنی بر گذشته است، پیش‌بینی آن نیز می‌تواند از حوزه‌های جذاب و کاربردی در این زمینه باشد. این پیش‌بینی در سطوح مختلف و با رویکردها و شاخص‌های مختلفی قابل انجام است. با توجه به اهمیت پیگیری تأثیرات مختلف برودادهای علمی و تعیین ارتباط بین آن‌ها مطالعه حاضر قصد دارد رابطه هر یک از متغیرهای مختلف بر همدیگر را موردسنجش قرار داده و نیز بررسی کند که کدام یک از الگوریتم‌های ماشین می‌تواند اثرگذاری علمی، اجتماعی و اقتصادی برودادهای علمی را پیش‌بینی کنند. به این منظور، برودادهای حوزه زیست‌فناوری^۱ ایران که در پایگاه اسکوپوس^۲ در بازه ۲۰۰۳-۲۰۲۴ نمایه شده‌اند مورد مطالعه قرار گرفته است. در واقع، پرسش اساسی پژوهش حاضر این است که کدام یک از الگوریتم‌های ماشین در مقایسه با یکدیگر می‌توانند اثرگذاری علمی، اجتماعی و اقتصادی پژوهش‌های حوزه زیست‌فناوری ایران را بهتر پیش‌بینی کنند؟

پرسش‌های پژوهش

۱. وضعیت برودادهای حوزه زیست‌فناوری ایران بر اساس هر کدام از شاخص‌های اثرگذاری علمی، اجتماعی و اقتصادی چگونه است؟
۲. آیا بین تعداد برودادها و همکاری‌های علمی بر شاخص‌های مربوط به اثرگذاری علمی، اجتماعی و اقتصادی آن‌ها رابطه وجود دارد؟
۳. کدام یک از شاخص‌های اثرگذاری علمی، اجتماعی و اقتصادی پژوهش‌ها با یکدیگر ارتباط دارند؟
۴. کدام یک از الگوریتم‌های ماشین در مقایسه با یکدیگر می‌توانند اثرگذاری علمی، اجتماعی و اقتصادی پژوهش‌ها را بهتر پیش‌بینی کنند؟


چارچوب نظری

۷ ارزیابی پژوهش

ارزیابی پژوهش، مجموعه‌ای از مفاهیم و روش‌هاست برای تعیین اینکه آیا برتری در این زمینه، حاصل شده و تمرکز آن روی «کیفیت» و «تأثیر» است. چگونگی درک و سنجش تعالی، نحوه تصمیم‌گیری پژوهشگران را شکل می‌دهد و به سهم خود، انواع دانشی تولید می‌شود که به‌طور بالقوه به نتایج سیاسی، اقتصادی یا اجتماعی منجر می‌گردد. ارزیابی پژوهش به‌عنوان یک فعالیت فنی یا عملیاتی در نظر گرفته می‌شود که برای به تصویر کشیدن عناصر عینی فرآیند پژوهش، طراحی و پیاده شده و توسط سیاست‌گذاران علمی تشویق و پیگیری می‌شود (Williams & Lewis, 2021). مطالعات علم‌سنجی، مبتنی بر تجزیه و تحلیل کمی پیشرفت‌های علمی است و در حوزه «نتایج پژوهش»، تلاش می‌کند تأثیر را اندازه‌گیری کند. این ارزیابی (مطابق شکل ۱) می‌تواند در سطوح مختلف و شاخص‌های متفاوت سنجیده شود (آزادی احمدآبادی، زودآیند).

امروزه مجموعه متنوعی از شاخص‌ها به‌منظور ارزیابی کیفیت و اثرگذاری پژوهش‌ها، از معیارهای سنتی تا جدیدترین معیارهای جدید و جایگزین به کار گرفته می‌شود. کتاب‌سنجی یکی از این حوزه‌های دیرینه‌ای است که شاخص‌های مبتنی بر استناد را برای سنجش پژوهش‌های علمی به خدمت می‌گیرد. در تحلیل‌های استنادی، سنجش کیفیت

1 . Biotechnology
2 . Scopus



شکل ۱. سطوح مختلف سنجش پژوهش‌ها با رویکرد علم‌سنجی (آزادی احمدآبادی، ۱۴۰۳).

مقاله بر پایه استناد اتفاق می‌افتد. اگرچه استناد، سنجه علمی است ولی عدد مطلق نمی‌تواند گویای کیفیت باشد. به همین منظور، استنادها به هنجار می‌شوند تا قابل تعمیم به جامعه مورد بررسی باشند. عموماً به مقاله‌های پر استناد به‌عنوان نشانه‌ای از کیفیت فعالیت‌های علمی و در نتیجه، ارزیابی عملکرد پژوهشی توجه خاصی می‌شود. با وجود اینکه استناد از مهم‌ترین و قابل قبول‌ترین شاخص‌ها برای ارزیابی عملکرد و کارایی علمی است، اما با محدودیت‌هایی همچون وابستگی زمانی، وابستگی به پایگاه‌های گران‌قیمت و با محدودیت دسترسی همراه است (Guthrie et al., 2013). گام‌های روش‌شناختی در مطالعات ارزیابی پژوهش از اهمیت بسیاری برخوردار است. آنینوس این مراحل را این‌چنین شرح می‌دهد: فرآیند ارزیابی پژوهش با تعیین سطح علمی آغاز می‌شود. به دنبال آن، دوره تجزیه و تحلیل، پایگاه‌های داده برای استخراج داده‌ها و انواع قالب‌های انتشار برای تجزیه و تحلیل تعیین می‌شود. اگر ارزیابی مربوط به یک گروه پژوهشی (دانشکده) یا یک واحد پژوهشی باشد، باید انتشارات گروه و سازوکار شمارش مناسب، مشخص شود. تجزیه و تحلیل استنادی انجام شده و شاخص‌های کتاب‌سنجی در مرحله نهایی، گزارش می‌شود. آنینوس متوجه شد که برخی از شاخص‌ها در ارزیابی پژوهش، مفیدتر از سایرین هستند. این موارد شامل تعداد انتشارات؛ تعداد استنادها؛ میانگین تعداد استنادها در هر نشریه؛ درصد انتشارات بدون استناد و میانگین تعداد استناد به کلیه مقالات منتشر شده توسط بخش یا واحد هستند (Anninos, 2014).

ارزیابی و پیش‌بینی تأثیر مقاله در دهه‌های گذشته توجه زیادی را در عرصه دانشگاهی و علمی به خود جلب کرده است. تغییر رویکردها به این منظور، از یک بُعد به چند بُعد، از معیارهای غیرساختارمند به معیارهای ساخت‌یافته رخ داده که در شکل ۲ به نمایش درآمده است.



شکل ۲. روش‌های ارزیابی و پیش‌بینی تأثیر مقاله (Bai et al., 2017).

استنادها به‌طور ضمنی، قضاوت جامعه درباره اهمیت مقاله را رمزگذاری می‌کنند، بنابراین سیگنالی منحصر به فرد برای مطالعه تأثیر علمی ارائه می‌دهند. تلاش‌ها در درک و بازخوانی این سیگنال در مدل‌سازی احتمالی شبکه‌های استنادی و تکثیر معیارهای تأثیر مبتنی بر استناد مانند شاخص هیرش^۱ منعکس می‌شود. در حالی که این تلاش‌ها بر گذشته و حال تمرکز دارند، همچنان این سؤال باقی است که آیا می‌توان تأثیر علمی را در آینده پیش‌بینی کرد. این نتایج را می‌توان با استفاده از تکنیک‌های غیرخطی به‌خوبی انجام داد. به‌ویژه که این روش‌های هوش مصنوعی می‌توانند اندازه‌گیری‌های تأثیر علمی را برای مقالات و نویسندگان، یعنی نرخ استناد و شاخص‌های اچ، با دقت شگفت‌آوری پیش‌بینی کنند (Weihs & Etzioni, 2017). در عین حال، به‌منظور ارزیابی عینی تأثیر مقاله و پیش‌بینی دقیق تأثیر آن در آینده، تکنیک‌های یادگیری ماشین و داده‌کاوی نقش‌های حیاتی ایفا می‌کنند، مانند استخراج شخصیت‌های مهم شبکه‌های علمی و بهینه‌سازی عملکرد الگوریتم‌ها (Jordan & Mitchell, 2015). این ظرفیت پیش‌بینی می‌تواند به دانشگاه‌ها، دولت‌ها و سرمایه‌گذاران با هشدار دادن به مقالات تأثیرگذار آینده و همچنین به محققان، مؤسسات و حوزه‌هایی که چنین مقالاتی را تولید می‌کنند، کمک کند. پتانسیل ارزشمندی برای چنین ابزار تحلیلی در راستای کمک به توسعه سیاست و تصمیم‌گیری وجود دارد (McNamara et al., 2013).

✓ مدل‌های پیش‌بینی کننده با استفاده از الگوریتم‌های یادگیری ماشین

عمده‌ترین الگوهای پیش‌بینی کننده با استفاده از الگوریتم‌های یادگیری ماشین که در این مطالعه نیز از آن‌ها استفاده شده، به شرح زیر هستند:

1 . Hirsch Index

۱. درخت تصمیم^۱

درختان تصمیم یکی از محبوب‌ترین الگوریتم‌های یادگیری ماشینی با توجه به درک و سادگی آن‌ها هستند (Wu et al., 2008). درخت تصمیم همچون یک رویکرد یادگیری تحت نظارت در آمار، داده‌کاوی و یادگیری ماشین مطرح است. در این موارد، درخت تصمیم طبقه‌بندی یا رگرسیون به‌عنوان یک مدل پیش‌بینی برای نتیجه‌گیری در مورد مجموعه‌ای از مشاهدات استفاده می‌شود. مدل‌های درختی که در آن، متغیر هدف می‌تواند مجموعه‌ای از مقادیر مجزا داشته باشد، درختان طبقه‌بندی نامیده می‌شوند. در این ساختارهای درختی، برگ‌ها نشان‌دهنده برچسب‌های طبقه و شاخه‌ها نشان‌دهنده ترکیبی از ویژگی‌هایی هستند که به آن برچسب‌های طبقه منتهی می‌شوند. درخت‌های تصمیم که در آن متغیر هدف می‌تواند مقادیر پیوسته (معمولاً اعداد واقعی) بگیرد، درخت‌های رگرسیون نامیده می‌شوند. به‌طور کلی‌تر، مفهوم درخت رگرسیون را می‌توان به هر نوع شی مجهز به تفاوت‌های زوجی مانند دنباله‌های طبقه‌بندی بسط داد (Studer et al., 2011).

۲. جنگل تصادفی^۲

جنگل تصادفی از الگوریتم‌های محبوب درخت تصمیم‌گیری بوده و یک الگوریتم پیش‌بینی استاندارد در یادگیری ماشین نظارت‌شده است (Bernard et al., 2012). الگوریتم‌های جنگل تصادفی در مواجهه با داده‌های با ابعاد بالا، سریع، انعطاف‌پذیر و قوی بوده و به‌طور گسترده به‌عنوان یک رویکرد یادگیری ماشینی برای انواع زیادی از وظایف پذیرفته شده‌اند (Ziegler & König, 2014).

۳. رگرسیون^۳

رگرسیون، تکنیکی است که برای دو نظریه استفاده می‌شود: اول، تحلیل‌های رگرسیون معمولاً برای پیش‌بینی استفاده می‌شوند که همپوشانی‌های عمده‌ای با حوزه یادگیری ماشین دارند. دوم، از تحلیل رگرسیون می‌توان در برخی موارد برای تعیین روابط علی بین متغیرهای مستقل و وابسته بهره برد. نکته مهم این است که رگرسیون‌ها تنها روابط بین یک متغیر وابسته و مجموعه داده ثابت از متغیرهای مختلف را نشان می‌دهند (Maulud & Abdulazeez, 2020). رگرسیون خطی^۴ معمولاً در روش‌های پژوهش ریاضی استفاده می‌شود، جایی که امکان اندازه‌گیری اثرات پیش‌بینی شده و مدل‌سازی آن‌ها در برابر متغیرهای ورودی چندگانه وجود دارد. این روش برای ارزیابی و مدل‌سازی داده است که روابط خطی را بین متغیرهای وابسته و مستقل برقرار می‌کند؛ پس این روش، روابط بین متغیرهای وابسته و متغیرهای مستقل را از تحلیل و یادگیری تا نتایج آموزشی فعلی مدل می‌کند (Wu et al., 2019).

۴. تقویت گرادیان^۵

تقویت گرادیان یک تکنیک یادگیری ماشینی است که مبتنی بر تقویت در یک فضای عملکردی بوده و یک مدل پیش‌بینی را در قالب مجموعه‌ای از مدل‌های پیش‌بینی ضعیف ارائه می‌کند؛ به‌عنوان مثال، مدل‌هایی که مفروضات بسیار کمی در مورد داده‌ها ایجاد می‌کنند که معمولاً درخت‌های تصمیم ساده هستند. هنگامی که درخت تصمیم یادگیرنده ضعیف باشد، الگوریتم حاصل درختان با گرادیان تقویت‌شده نامیده می‌شود (Piryonesi & El-Diraby, 2020; Hastie et al., 2009).

- 1 . Decision Tree
- 2 . random forests
- 3 . Regression
- 4 . Linear Regression
- 5 . Gradient boosting

۵. قانون k- نزدیک‌ترین همسایه^۱

قانون k- نزدیک‌ترین همسایه نیز از قدیمی‌ترین و ساده‌ترین روش‌ها برای طبقه‌بندی الگوهاست. با این وجود، اغلب نتایج رقابتی به همراه دارد و در حوزه‌های خاص، هنگامی که هوشمندانه با دانش قبلی ترکیب می‌شود، به‌طور قابل توجهی پیشرفت‌های عمده‌ای را ایجاد کرده است. این قانون، هر نمونه بدون برچسب را با برچسب اکثریت در میان نزدیک‌ترین همسایگان خود در مجموعه آموزشی طبقه‌بندی می‌کند. بنابراین عملکرد آن به شدت به شاخص فاصله مورد استفاده برای شناسایی نزدیک‌ترین همسایگان بستگی دارد. در الگوی k- نزدیک‌ترین همسایه برای طبقه‌بندی آماری و رگرسیون، در هر دو حالت k شامل نزدیک‌ترین مثال آموزشی در فضای داده‌ای است و خروجی آن بسته به نوع مورد استفاده در طبقه‌بندی و رگرسیون متغیر است. در حالت طبقه‌بندی با توجه به مقدار مشخص شده برای k، به محاسبه فاصله نقطه‌ای که می‌خواهیم برچسب آن را مشخص کنیم با نزدیک‌ترین نقاط می‌پردازد. برای محاسبه این فاصله می‌توان از روش‌های مختلفی استفاده کرد که یکی از مطرح‌ترین این روش‌ها، فاصله اقلیدسی است. با توجه به این که محاسبات این الگوریتم بر اساس فاصله است؛ نرمال‌سازی داده‌ها می‌تواند به بهبود عملکرد آن کمک کند (Weinberger & Saul, 2009 Hastie & Tibshirani, 1995).

پیشینه پژوهش

به منظور بررسی رابطه بین متغیرهای علم‌سنجی و نیز پیش‌بینی آن‌ها مطالعات مختلفی انجام شده که در ادامه به برخی از مهم‌ترین و مرتبط‌ترین آن‌ها اشاره می‌شود.

بذرافشان و همکاران (۱۴۰۲) به بررسی قدرت پیش‌بینی تعداد استنادات دریافتی مدارک حوزه فیزیک ذرات در پایگاه اسکوپوس از طریق نمرات دگر سنجی در پایگاه پلام ایکس پرداختند. یافته‌های حاصل از بررسی رابطه همبستگی و رگرسیون چندگانه بین تعداد استنادات و نمرات دگر سنجی نشان داد که رابطه قوی بین استنادات پلام ایکس و تعداد استنادات اسکوپوس برقرار است. همچنین بین ذکر و یادداشت پلام ایکس مشاهدات پلام ایکس با تعداد استنادات دریافتی در اسکوپوس رابطه معناداری وجود دارد؛ اما بین کاربرد پلام ایکس و شبکه‌های اجتماعی پلام ایکس رابطه‌ای وجود ندارد.

در پژوهش بیرانوند و همکاران (۱۴۰۱) امکان پیش‌بینی تعداد استنادات دریافتی تولیدات علمی حوزه وب‌معنایی از طریق شاخص‌های سایت-اسکور، اس‌ان‌آی‌پی و اس‌جی‌آر نشریات این حوزه مورد بررسی قرار گرفته است. نتایج آزمون ضریب همبستگی پیرسون و رگرسیون خطی چندگانه نشان داد بین تعداد استنادات با شاخص اس‌ان‌آی‌پی همبستگی وجود ندارد. همچنین بین تعداد استنادات با اس‌جی‌آر و تعداد استنادات با سایت اسکور، رابطه معناداری وجود ندارد. هیچ‌یک از شاخص‌های سه‌گانه سایت اسکور، اس‌ان‌آی‌پی و اس‌جی‌آر توان پیش‌بینی تعداد استنادات دریافتی در پایگاه اسکوپوس را ندارند.

هدف پژوهش ابراهیمی و همکاران (۱۳۹۶) امکان‌سنجی ارائه مدلی برای سنجش میزان تأثیرگذاری مقالات در مرحله داوری در نشریات علمی بود تا بتوان در فرایند کنترل کیفیت مقالات علمی، میزان استناد به آن در آینده را پیش‌بینی کرد. در این پژوهش، ۳۰۰ مقاله حوزه شیمی بررسی شد و نتایج نشان داد که شاخص «چند نویسنده‌گی و هم‌تألیفی» قوی‌ترین متغیر پیش‌بینی‌کننده استناد است که به صورت مثبت و معنادار میزان استناد را پیش‌بینی می‌کند.

1 . k-nearest neighbors' algorithm

پیش‌بینی تأثیر‌گذاری پژوهش‌های علمی حوزه زیست‌فناوری با استفاده از الگوریتم‌های یادگیری ماشین

شاخص‌های «طول مقاله»، «تعداد منابع» و «شاخص اچ نویسنده» متغیرهای دیگری بودند که توانستند میزان استناد مقالات را به نحو مثبت و معنادار پیش‌بینی کنند.

گو و کرن این فرضیه را آزمون کردند که پیش‌بینی‌های خوبی از تعداد استنادهای بلندمدت را می‌توان از طریق ترکیبی از استنادهای اولیه یک نشریه و ضریب تأثیر مجله میزبان به دست آورد. این آزمایش با استفاده از مدل‌های رگرسیون خطی روی مجموعه‌ای از ۱۲۳۱۲۸ پایگاه وب‌آوساینس تألیف دانشمندان ایتالیایی انجام شد. میانگین دقت پیش‌بینی برای بازه‌های زمانی استناد بالای دو سال خوب است، برای انتشارات کم استناد کاهش می‌یابد و در رشته‌های مختلف متفاوت است. همان‌طور که انتظار می‌رفت، نقش ضریب تأثیر در ترکیب تنها پس از دو سال از انتشار ناچیز می‌شود (Gu & Krenn, 2024).

آلکوهر و همکاران نیز از یک چارچوب یادگیری ماشین برای آزمون توانایی معیارهای جایگزین (دگر سنجه) در پیش‌بینی تأثیر آتی مقالات بر اساس تعداد استنادها استفاده کردند. مبنای این بررسی، ۷۵۸۸ مقاله از ۱۰ مجله علوم رایانه بود. برای ساخت فضای ویژه برای پیش‌بینی، ۱۴ شاخص دگر سنجی مختلف جمع‌آوری و سه رویکرد انتخاب ویژگی، یعنی آستانه واریانس، همبستگی پیرسون و روش اطلاعات متقابل به‌منظور به حداقل رساندن فضای ویژگی و رتبه‌بندی ویژگی‌ها بر اساس سهم آن‌ها استفاده شد. برای شناسایی عملکرد طبقه‌بندی این ویژگی‌ها، از سه الگو استفاده شد: درخت تصمیم، جنگل تصادفی و ماشین‌های بردار پشتیبانی. با توجه به داده‌های آزمایشی و بر اساس عملکرد، جنگل تصادفی نسبت به دیگر طبقه‌بندی‌کننده‌ها، دگر سنجه‌ها می‌تواند استنادهای آینده را پیش‌بینی کند و مفیدترین نشانه‌های دگر سنجی، تعداد رسانه‌های اجتماعی، توییت‌ها، شمارش اخبار، تعداد عکس‌برداری و نمای کامل متن هستند (Alchokr et al., 2023).

ایوب و همکاران در مطالعه خود دو مقوله استناد و نمره دگر سنجی را به‌منظور تعیین میزان مقایسه و ارتباط آن‌ها با یکدیگر بررسی کردند. نمرات دگر سنجی با تعداد استناد مقالات مرتبط با رشته علوم زیستی، زمین‌شناسی و محیط زیست، تاریخ و باستان‌شناسی و مطالعات اجتماعی از لیست ۱۰۰ مقاله برتر در پایگاه آلمتریک در دوره زمانی ۲۰۱۴ تا ۲۰۱۷ مقایسه شد. علاوه بر این، نمرات دگر سنجی مقالات با اس.جی.آر. مجلات مقایسه شد. درنهایت، همبستگی اسپیرمن برای سنجش ارتباط بین متغیرها محاسبه شد. این مطالعه نشان داد که زمین‌شناسی و محیط‌زیست بیشترین همبستگی را بین تعداد استناد و نمره دگر سنجی نشان داد، درحالی‌که برای نمره دگر سنجی و اس.جی.آر. درزمینه مذکور، چنین روندی قابل مشاهده نیست. تاریخ و باستان‌شناسی، همبستگی قوی بین دگر سنجی و نمرات استناد را به‌استثنای مقالات سال ۲۰۱۶ نشان می‌دهد و تا حدودی روند مشابهی برای امتیاز دگر سنجی و اس.جی.آر. انتشارات مشاهده شد. علوم زیستی همبستگی ضعیفی در هر دو متغیر نشان می‌دهند، درحالی‌که حوزه مطالعات اجتماعی عمدتاً برای هر دو مجموعه متغیر، ارتباط منفی نشان می‌دهند. بنابراین، به‌جز مقوله مطالعات اجتماعی، سه دسته دیگر عمدتاً همبستگی مثبتی بین دگر سنجی و امتیاز استناد نشریات و همچنین تا حدی، برای نمره دگر سنجی و اس.جی.آر وجود دارد (Ayoub et al., 2023).

مطالعه آلهالی و همکاران با هدف بررسی عوامل و بخش‌های مؤثر بر تعداد استناد یک مقاله علمی درزمینه شنوایی‌سنجی انجام شد. این مطالعه، راه‌حل جدیدی را پیشنهاد داده و از یادگیری ماشین و پردازش زبان طبیعی برای پردازش متن انگلیسی استفاده کرد. الگوریتم‌های مختلفی مانند رگرسیون خطی، درخت تصمیم تقویت‌شده، جنگل تصمیم و شبکه‌های عصبی به این منظور پیاده‌سازی شد. استفاده از رگرسیون شبکه عصبی نشان داد که چکیده

مقالات، تأثیر بیشتری بر تعداد استناد مقالات شنوایی سنجی دارد. بر این اساس، توصیه کردند که از مدل‌های یادگیری ماشینی برای بهبود چکیده مقالات پژوهشی برای دریافت استنادهای بیشتر استفاده شود (Alohali et al., 2022).

در یک پایان‌نامه نیز داده‌های اسکوپوس با هدف تحلیل عملکرد متغیرهای مرتبط با مقاله، نشریه و نویسنده به‌عنوان شاخص‌های تأثیر مقالات حوزه بازاریابی و اینکه چگونه می‌توانند مقالات پر استناد را در پنج سال آینده پیش‌بینی کنند، جمع‌آوری شد. برای یافتن معیارهای مرکزیت از تحلیل شبکه اجتماعی استفاده شد و تعداد استنادها یک سال پس از انتشار به‌عنوان تنها متغیر وابسته به زمان گنجانده شد. نتایج نشان داد که استنادهای یک سال بعد، محرک قوی و پیش‌بینی کننده برای استنادهای آینده پس از پنج سال است. تحلیل شبکه هم نویسندگی نشان داد که مرکزیت نزدیکی و بینیت نیز محرک استنادهای آینده در حوزه بازاریابی هستند که نشان می‌دهد نزدیک بودن به هسته شبکه و داشتن قدرت واسطه‌ای در این زمینه مهم است. محققان با استفاده از روش‌های یادگیری ماشین، متوجه شدند که ترکیبی از مؤلفه‌های مرتبط با مقاله، نشریه و نویسنده در مقایسه با تنها یک نوع مؤلفه در پیش‌بینی مقالات پر استناد بهتر عمل می‌کنند (Hansen & Torvund, 2022).

در مقاله ژانگ و وو، چارچوب جدید WMR-Rank را برای پیش‌بینی تأثیر آینده مقالات، محققان و مکان‌ها پیشنهاد می‌کنند. بر اساس شبکه پویا و ناهمگون موجودیت‌های متعدد، هفت نوع رابطه از بین آن‌ها استخراج شد. این چارچوب از ویژگی‌های مفیدی از جمله جزئیات دقیق نهادهای مرتبط مانند نویسندگان و مکان‌های برگزاری، آگاهی از زمان برای مقالات منتشرشده و استنادات آن‌ها، متمایز کردن مشارکت چند نویسنده همکار در یک مقاله و غیره پشتیبانی می‌کند. نتایج تجربی نشان داد که رویکرد پیشنهادی به‌طور قابل توجهی بهتر از رقبای پیشرفته عمل می‌کند (Zhang & Wu, 2020).

می‌هالا و همکارانش در مطالعه خود ۱۲۶ مقاله در مورد کووید ۱۹ در پایگاه وب‌آوساینس را برای تعیین اینکه آیا دگر سنجی با تأثیر علمی مقاله مرتبط است یا خیر، تحلیل کردند. روابط و سنجه‌های سنتی و دگر سنجی از طریق تحلیل مؤلفه‌های اصلی، تحلیل عاملی و همبستگی‌ها بررسی شدند. نتایج نشان داد که تعداد مندلی (خواننده‌ها) استفاده بالقوه آن‌ها برای پیش‌بینی استنادات وب‌آوساینس را نشان می‌دهد، امتیاز توجه دگر سنجی، همبستگی نسبتاً کمی با استنادهای آتی نشان می‌دهد؛ درحالی‌که گوگل اسکولار که با احتیاط استفاده می‌شود، می‌تواند پیش‌بینی کننده تعداد استنادهای آینده باشد (Mihaela et al., 2020).

ابریشمی و علی اکبری در مطالعه خود، روش جدیدی را به‌منظور پیش‌بینی استنادهای بلندمدت یک مقاله بر اساس تعداد استنادهای آن در چند سال اول پس از انتشار، پیشنهاد کردند. آن‌ها به‌منظور آزمون مدل پیش‌بینی تعداد استناد از شبکه عصبی مصنوعی استفاده کردند که یک ابزار یادگیری ماشینی قدرتمند با کاربردهای جدید در بسیاری از حوزه‌ها از جمله پردازش تصویر و متن است. آن‌ها از تکنیک‌های مدرن یادگیری عمیق (مانند شبکه عصبی بازگشتی و مدل دنباله به دنباله) به‌منظور یادگیری روش پیش‌بینی بر اساس الگوی توالی استنادها از سال‌های اولیه انتشار مقاله استفاده کردند. ارزیابی‌های جامع آن‌ها نشان داد که روش پیشنهادی با توجه به‌دقت و توانایی پیش‌بینی استنادات مقالات پر استناد، بهتر از روش‌های پیشرفته پیش‌بینی تعداد استناد است (Abrishami & Aliakbary, 2019).

پژوهشگر دیگری، قدرت نسبی تعداد استنادهای کوتاه‌مدت، معیارهای کتاب‌سنجی مانند عوامل تأثیر و رتبه‌بندی نشریات را از نظر پیش‌بینی استنادهای بلندمدت بررسی کرد. وی با استفاده از مجموعه‌ای از مقالات منتشرشده در شصت نشریه اقتصادی دریافت استنادهای دریافتی در بازه‌های کوتاه‌مدت (بین ۱ تا ۲ سال پس از انتشار) در مقایسه

پیش‌بینی تأثیر گذاری پژوهش‌های علمی حوزه زیست‌فناوری با استفاده از الگوریتم‌های یادگیری ماشین

با مواردی مانند تأثیر نشریات، پیش‌بینی کننده‌های قوی‌تری برای تعداد استنادات بلندمدت یا سایر رتبه‌بندی‌های نشریات هستند. این مقاله بر مقایسه سهم نسبی استنادهای کوتاه‌مدت، معیارهای کیفیت نشریات مانند عوامل تأثیر نشریه و امتیازات رتبه‌بندی نشریه و ویژگی‌های مقاله تأکید داشت. از دید این پژوهشگر، این واقعیت که تعداد استنادهای کوتاه‌مدت نسبت به متغیرهای شاخص نشریه، پیش‌بینی کننده بهتری برای استنادهای بلندمدت ارائه می‌کند، یک نتیجه واقعاً منحصر به فرد است (Kosteas, 2018).

تیمیلسینا و همکاران بر اساس یک شبکه علمی ناهمگون و با ادغام داده‌های کتاب‌سنجی با داده‌های اجتماعی مانند وبلاگ‌ها و اخبار اصلی، تأثیر علمی را پیش‌بینی کرد که نشان می‌دهد اندازه‌گیری مبتنی بر نمودار می‌تواند به‌طور منطقی تأثیر محققان مرحله اولیه را پیش‌بینی کند (Timilsina et al., 2016).

برخی محققان نیز مدلی را با هدف پیش‌بینی تعداد استنادهای آینده نشریه پیشنهاد کردند که از دو پیش‌بینی کننده استفاده شد: ضریب تأثیر مجله و تعداد استنادهایی که یک نشریه یک سال پس از انتشار دریافت کرده است. مدل پیشنهادی، مبتنی بر رگرسیون کمی بود. آن‌ها از این مدل به‌منظور پیش‌بینی تعداد استنادات در حوزه فیزیک استفاده کردند. تحلیل‌ها نشان داد که هر دو پیش‌بینی کننده (یعنی ضریب تأثیر و استنادهای اولیه) به پیش‌بینی دقیق تأثیر استناد درازمدت کمک می‌کنند (Steghuis et al., 2015).

بر اساس رگرسیون چندگانه، استگهویس و همکاران (Steghuis et al., 2015) مدلی برای پیش‌بینی توزیع احتمال به‌منظور استنادهای آینده یک مقاله پیشنهاد کردند و دو ویژگی کلیدی را در نظر گرفتند: استنادهای اولیه و ضریب تأثیر نشریه.

یو و همکاران از چهار دسته از ویژگی‌ها، از جمله مقالات، نویسندگان، استنادها و نشریات برای پیش‌بینی استنادهای آینده یک مقاله بر اساس تحلیل رگرسیون گام‌به‌گام استفاده کردند. بر اساس شبکه‌های هم‌نویسندگی، یک طبقه‌بندی یادگیری ماشین برای پیش‌بینی اینکه آیا یک نشریه استنادهای بالایی دریافت می‌کند یا خیر، توسعه داده شد (Yu et al., 2014).

یکی دیگر از پژوهش‌ها نیز روش متفاوتی را به‌منظور پیش‌بینی تأثیرات آتی هر مقاله ارائه کرد. ویژگی‌های پیش‌بینی کننده بر اساس موقعیت مقاله در شبکه استناد، با استناد و ارزیابی پژوهش‌های قبلی در مورد انتشار اطلاعات در شبکه‌ها استفاده شد. این روش با داده‌های اسکوپوس از سال ۱۹۹۶-۲۰۱۰، اجرا و ارزیابی شد. تعداد استنادهای مقاله در سال‌های اولیه پس از انتشار، تعداد استنادهای مقاله، میانگین تعداد استنادهای مقالات استناد کننده و استناد شونده و استنادهای بین‌رشته‌ای بیشتر از مقاله و مقالات استناد شده، همبستگی مثبت داشتند. سه الگوریتم رگرسیون خطی، درخت‌های تصمیم‌گیری و جنگل تصادفی برای پیش‌بینی تأثیر آتی مقالات آزمایش شد. نتایج نشان داد که جنگل تصادفی پیش‌بینی کننده‌ترین الگوریتم بود، به‌طوری‌که پیش‌بینی ۱۸ درصدی از سال انتشار مقاله و ۳۴ درصدی پیش‌بینی استناد از دو سال پس از آن به دست آمد (McNamara et al., 2013).

آکلا و همکارانش در پژوهش خود از دگر سنج‌ها به‌منظور پیش‌بینی استنادات کوتاه‌مدت و بلندمدت مقالات استفاده کردند. این پژوهشگران، مدل‌های طبقه‌بندی و رگرسیون مختلفی را پیاده کرده و تشخیص دادند که شبکه‌های عصبی و مدل‌های مجموعه دارای بهترین عملکرد برای این موضوع هستند. آن‌ها دریافتند که خوانندگان مندلی مهم‌ترین عامل در پیش‌بینی استنادهای اولیه بوده و به دنبال آن، عوامل دیگری مانند وضعیت علمی خوانندگان (به‌عنوان مثال، دانشجو، فوق‌دکتر، استاد)، دنبال کنندگان در توییتر، طول پست آنلاین، تعداد نویسنده و تعداد به اشتراک گذاشتن در توییتر، ویکی‌پدیا و در کشورهای مختلف (Akella et al., 2009).

بولان و همکاران تحلیل مؤلفه اصلی رتبه‌های تولیدشده توسط ۳۹ معیار تأثیر علمی موجود و پیشنهادی که بر اساس داده‌های استناد و گزارش استفاده، محاسبه شده، انجام دادند. نتایج نشان داد که تأثیر علمی یک سازه چند بُعدی است و نمی‌توان آن را به‌طور دقیق با هیچ شاخصی اندازه‌گیری کرد، اگرچه برخی از معیارها مناسب‌تر از سایرین هستند. ضریب تأثیر استنادی که معمولاً مورد استفاده است در هسته این ساختار جای نگرفته، بلکه در حاشیه آن قرار دارد و بنابراین باید با احتیاط استفاده شود. تحلیل مؤلفه‌های اصلی نشان داد که ۹۲ درصد از واریانس‌های بین همبستگی‌های رتبه‌بندی نشریات ایجادشده توسط ۳۷ معیار تأثیر را می‌توان با ۳ مؤلفه اول توضیح داد (Bollen et al., 2009).

از بررسی پیشینه‌ها این نتیجه حاصل می‌شود که پژوهشگران تلاش کرده‌اند با رویکردها و شاخص‌های مختلف، اثرگذاری خروجی‌های علمی را پیش‌بینی کنند. این مطالعات گاهی روی مقالات، متمرکز شده و گاهی نیز نشریات را هدف قرار داده‌اند. عمده تلاش‌ها نیز بر تشخیص رابطه شاخص‌های استنادی سنتی و دگر سنج‌ها و توان پیش‌بینی آن‌ها از یکدیگر بوده است. حوزه‌های موضوعی متفاوتی نیز مورد مطالعه قرار گرفته است. پژوهش حاضر نیز تلاش کرد تأثیر شاخص‌های مختلف اثرگذاری برون‌دادهای علمی حوزه زیست‌فناوری ایران در یک بازه ۲۲ ساله را بر هم بررسی کند و از الگوریتم‌های متفاوتی برای پیش‌بینی تأثیرات آن‌ها استفاده کند.

روش‌شناسی پژوهش

پژوهش حاضر از نظر هدف، کاربردی و از لحاظ روش، توصیفی بوده که با رویکرد علم‌سنجی انجام شده است و به دنبال بررسی همکاری علمی و نیز تأثیرگذاری علمی، اجتماعی و اقتصادی آثار علمی ایران در حوزه زیست‌فناوری است. از آنجایی که این پژوهش در نظر دارد نشان دهد که کدام یک از الگوریتم‌های یادگیری ماشین، پیش‌بینی کننده بهتری برای سنجش اثرگذاری برون‌دادهای علمی در ابعاد مختلف هستند، جامعه آن، شامل برون‌دادهای حوزه زیست‌فناوری ایران است که در پایگاه اسکوپوس در بازه ۲۰۰۳-۲۰۲۴ نمایه شده‌اند. تاریخ استخراج داده‌ها نیز ۱ بهمن ۱۴۰۲ معادل ۲۱ ژانویه ۲۰۲۴ بود. به منظور استخراج داده‌های مربوط از پایگاه تحلیلی سایول استفاده شد. پایگاه سایول که برای اولین بار در سال ۲۰۰۹ معرفی شد، امکان تجزیه و تحلیل‌های استنادی پیشرفته و عمیق را بر مبنای داده‌های پایگاه اسکوپوس فراهم می‌سازد. در واقع، پایگاه استنادی سایول یک نمایه استنادی محسوب نمی‌شود، بلکه یک پایگاه استنادی تجزیه و تحلیل پژوهشی است که همچون این سائیس^۱، امکان مقایسه نتایج به دست آمده را با میانگین‌ها و استانداردهای جهانی فراهم می‌سازد. به این ترتیب، با استفاده از سایول می‌توان عملکرد پژوهشی یک پژوهشگر، سازمان، کشور، منطقه، نشریه، گروه پژوهشی و مانند آن‌ها را ارزیابی کرد (نوروزی چاکلی، ۱۴۰۲). متغیرهای مورد مطالعه در قالب مؤلفه و شاخص‌های مورد استفاده برای آزمون همبستگی و نیز پیش‌بینی کننده تأثیرات علمی، اقتصادی و اجتماعی به شرح زیر هستند:

جدول ۱. متغیرهای مورد مطالعه

عنوان متغیر
حجم برون‌داد علمی
همکاری فقط دانشگاهی (درصد)
تأثیر همکاری فقط دانشگاهی
تأثیر همکاری بین‌المللی



ادامه جدول ۱. متغیرهای مورد مطالعه

عنوان متغیر
همکاری دانشگاهی و دولتی (درصد)
حجم استنادها
استناد به ازای برونداد
تأثیر استناد وزنی حوزه
برونداها در ۱۰ درصد برتر نشریه توسط درصد CiteScore (درصد)
برونداها در ۱۰ درصد استنادهای برتر (درصد)
تعداد استنادات ثبت اختراع
استنادهای حق ثبت اختراع به ازای هر خروجی علمی
خروجی علمی استناد شده توسط ثبت اختراعات (درصد)
تعداد اختراعات استناد کننده به مقالات
تعداد بازدیدها
برونداها در ۱۰ درصد بازدیدهای برتر (درصد)
بازدید به ازای هر خروجی
تأثیر بازدید وزنی حوزه

جدول ۲. مؤلفه‌ها و شاخص‌های مرتبط به آن‌ها به‌عنوان پیش‌بینی کننده تأثیر.

مؤلفه	عنوان شاخص
تأثیر علمی	حجم استنادها
	استناد به ازای برونداد
	تأثیر استناد وزنی حوزه
تأثیر اقتصادی	برونداها در ۱۰ درصد برتر مجله توسط درصد CiteScore (درصد)
	برونداها در ۱۰ درصد استنادهای برتر (درصد)
	تعداد استنادات ثبت اختراع
	استنادهای حق ثبت اختراع به ازای هر خروجی علمی
تأثیر اجتماعی	خروجی علمی استناد شده توسط ثبت اختراعات (درصد)
	تعداد اختراعات
	تعداد بازدیدها
	برونداها در ۱۰ درصد بازدیدهای برتر (درصد)
	بازدید به ازای هر خروجی
	تأثیر بازدید وزنی حوزه

گفتنی است که منظور از تأثیر اجتماعی، اثری است که خروجی فعالیت‌های علمی در رسانه‌ها و شبکه‌های اجتماعی ایجاد می‌کنند. تأثیر اقتصادی نیز منظور تعاملاتی است که بین تولیدات علمی و پروانه‌های ثبت اختراع شکل می‌گیرد.

در این پژوهش از ضریب همبستگی پیرسون و از بسته نرم‌افزاری R به منظور تعیین رابطه بین شاخص‌های مورد مطالعه، استفاده شده است. در زمان بررسی همبستگی بین دو متغیر، اگر هر دو متغیر مورد نظر در مقیاس نسبی و فاصله‌ای باشند، از ضریب همبستگی پیرسون استفاده می‌شود.

الگوریتم‌های یادگیری ماشین مانند رگرسیون خطی چندگانه، درخت‌های تصمیم‌گیری، جنگل‌های تصادفی و تقویت گرادیان نیز به عنوان مدل‌های پیش‌بینی کننده، مورد استفاده و ارزیابی قرار گرفتند. به منظور انجام آزمون‌ها و الگوریتم‌ها از زبان برنامه‌نویسی پایتون استفاده شده است. تحلیل‌ها توسط زبان برنامه‌نویسی پایتون انجام شده که برای بررسی و نمایش صحیح آن باید از نرم‌افزار jupyter notebook استفاده کرد. داده‌ها برای استفاده توسط الگوریتم‌های یادگیری ماشین و انجام تحلیل‌های مربوطه نیازمند اصلاحات ساختاری بود که این اصلاحات انجام شد. تعداد اندکی از داده‌ها در دسترس نبودند و مقداری برای آن گزارش نشده بود که برای انجام تحلیل‌ها باید مقداری به آن‌ها نسبت داده می‌شد. این کار با استفاده از متد قابل قبول و معتبر knn Imputer انجام شد که این متد با در نظر گرفتن نزدیک‌ترین همسایگی‌ها اقدام به تکمیل داده‌ها می‌کند. همچنین، فونت داده‌های فارسی، قابل استفاده نبوده و تحلیل‌ها با استفاده از داده‌های انگلیسی انجام شد. در گام بعدی، مدل‌های یادگیری ماشین مختلفی روی داده‌ها مدل‌سازی و اجرا شد. مدل‌سازی در نرم‌افزار پایتون به گونه‌ای انجام شده که همه متغیرهای موجود در مجموعه داده، یک بار به عنوان مقدار هدف فرض شده‌اند و مدلی ساخته شده که بتواند بر اساس سایر متغیرها این مقدار را پیش‌بینی کند. برای ارزیابی مدل‌ها نیز از معیار صحت^۱ استفاده شد که اساسی‌ترین معیار اندازه‌گیری کیفیت یک دسته بند است. درک آن بسیار ساده و به راحتی برای مشکل طبقه‌بندی دو حالته و چند حالته مناسب است.

$$\text{Accuracy} = (\text{TP} + \text{TN}) / (\text{TP} + \text{TN} + \text{FP} + \text{FN})$$

صحت یعنی نسبت نتایج واقعی به کل موارد بررسی شده. نمره صحت مدل در واقع معرف صحت مدل است که اگر این اعداد در ۱۰۰ ضرب شود بیانگر درصد صحت و دقت مدل است. نکته آنکه اعداد منفی، بیانگر دقت بسیار پایین بوده و نشان می‌دهند مدل به کاررفته برای پیش‌بینی آن پارامتر خاص، اصلاً مناسب نیست.

یافته‌های پژوهش

پاسخ به پرسش اول پژوهش: وضعیت بروندادهای حوزه زیست‌فناوری ایران بر اساس هر کدام از شاخص‌های اثرگذاری علمی، اثرگذاری اجتماعی و اثرگذاری اقتصادی چگونه است؟

وضعیت بروندادهای علمی ایران در حوزه زیست‌فناوری بر اساس داده‌های پایگاه سایول در بازه زمانی ۲۰۰۳ - ۲۰۲۴ که مبنای تحلیل‌های بعدی قرار گرفت در جدول ۳ آمده است. نکته مهم در این زمینه، سیر صعودی و افزایش ۳۶ برابری حجم بروندادهای علمی ایران در این حوزه تا سال ۲۰۲۳ است که نشان از پیشرفت فوق‌العاده در این فاصله زمانی است. ضمن اینکه انتظار می‌رود کیفیت مقالات نیز هم‌راستا با رشد کمی آن‌ها رشد کند.

1 . Accuracy



پیش‌بینی تأثیر گذاری پژوهش‌های علمی حوزه زیست‌فناوری با استفاده از الگوریتم‌های یادگیری ماشین


جدول ۳. وضعیت بروندهای علمی ایران در حوزه زیست‌فناوری بر اساس داده‌های پایگاه سایبول در بازه ۲۰۰۳-۲۰۲۴

عنوان شاخص	۲۰۰۳	۲۰۰۴	۲۰۰۵	۲۰۰۶	۲۰۰۷	۲۰۰۸	۲۰۰۹	۲۰۱۰	۲۰۱۱	۲۰۱۲	۲۰۱۳	۲۰۱۴	۲۰۱۵	۲۰۱۶	۲۰۱۷	۲۰۱۸	۲۰۱۹	۲۰۲۰	۲۰۲۱	۲۰۲۲	۲۰۲۳	۲۰۲۴	
بروندا علمی حجم برون داد علمی	۳۵	۴۵	۶۸	۱۰۳	۱۴۷	۲۸۴	۳۵۹	۵۸۹	۷۴۷	۸۶۴	۱۰۵۶	۱۳۳۳	۱۷۷۶	۲۱۷۶	۲۷۶۳	۳۵۳۳	۴۵۳۳	۵۶۳۳	۶۷۳۳	۷۸۳۳	۸۹۳۳	۱۰۰۳۳	۱۱۱۳۳
همکاری فقط دانشگاهی (درصد)	۷۷	۸۳	۸۳	۸۳	۸۳	۸۳	۸۳	۸۳	۸۳	۸۳	۸۳	۸۳	۸۳	۸۳	۸۳	۸۳	۸۳	۸۳	۸۳	۸۳	۸۳	۸۳	۸۳
تأثیر همکاری فقط دانشگاهی	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱
تأثیر همکاری بین‌المللی	۰.۲	۰.۲	۰.۲	۰.۲	۰.۲	۰.۲	۰.۲	۰.۲	۰.۲	۰.۲	۰.۲	۰.۲	۰.۲	۰.۲	۰.۲	۰.۲	۰.۲	۰.۲	۰.۲	۰.۲	۰.۲	۰.۲	۰.۲
همکاری دانشگاهی و دولتی (درصد)	۱۴.۳	۱۴.۳	۱۴.۳	۱۴.۳	۱۴.۳	۱۴.۳	۱۴.۳	۱۴.۳	۱۴.۳	۱۴.۳	۱۴.۳	۱۴.۳	۱۴.۳	۱۴.۳	۱۴.۳	۱۴.۳	۱۴.۳	۱۴.۳	۱۴.۳	۱۴.۳	۱۴.۳	۱۴.۳	۱۴.۳
حجم استنادها	۸	۸	۸	۸	۸	۸	۸	۸	۸	۸	۸	۸	۸	۸	۸	۸	۸	۸	۸	۸	۸	۸	۸
استناد به ازای برون داد	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱	۰.۱
تأثیر استناد وزنی حوزه	۰.۵۵	۰.۵۹	۰.۵۸	۰.۷۳	۰.۷۴	۰.۷۳	۰.۷۳	۰.۷۳	۰.۷۳	۰.۷۳	۰.۷۳	۰.۷۳	۰.۷۳	۰.۷۳	۰.۷۳	۰.۷۳	۰.۷۳	۰.۷۳	۰.۷۳	۰.۷۳	۰.۷۳	۰.۷۳	۰.۷۳
برون دادها در ادرسد برتر مجله CiteScore	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱	۱۱
برون دادها در ادرسد استنادهای برتر (درصد)	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
تعداد استنادات ثبت اختراع	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳
استنادهای حق ثبت اختراع به ازای هر خروجی	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰
تأثیر اقتصادی خروجی علمی	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰
استناد شده توسط ثبت اختراعات	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰
تعداد اختراعات	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳	۳۳
تعداد باز دیده‌ها	۱۷۳۶	۲۸۰۳	۴۰۱۰	۶۵۷	۱۰۰۲۳	۱۹۶۷۷	۳۵۸۷۴	۴۴۸۱۶	۵۸۰۵۶	۷۳۸۱۷	۸۸۱۷۰	۱۰۳۳۸۱	۱۲۳۳۸۱	۱۴۳۳۸۱	۱۶۳۳۸۱	۱۸۳۳۸۱	۲۰۳۳۸۱	۲۲۳۳۸۱	۲۴۳۳۸۱	۲۶۳۳۸۱	۲۸۳۳۸۱	۳۰۳۳۸۱	۳۲۳۳۸۱
برون داد در باز دیده‌های برتر (درصد)	۱۳.۵	۱۳.۵	۱۳.۵	۱۳.۵	۱۳.۵	۱۳.۵	۱۳.۵	۱۳.۵	۱۳.۵	۱۳.۵	۱۳.۵	۱۳.۵	۱۳.۵	۱۳.۵	۱۳.۵	۱۳.۵	۱۳.۵	۱۳.۵	۱۳.۵	۱۳.۵	۱۳.۵	۱۳.۵	۱۳.۵
تأثیر اجتماعی بازدید به ازای هر خروجی	۷.۲	۷.۲	۷.۲	۷.۲	۷.۲	۷.۲	۷.۲	۷.۲	۷.۲	۷.۲	۷.۲	۷.۲	۷.۲	۷.۲	۷.۲	۷.۲	۷.۲	۷.۲	۷.۲	۷.۲	۷.۲	۷.۲	۷.۲
تأثیر بازدید وزنی حوزه	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰	۰

دوفصلنامه علمی دانشگاه شاهد / دوره ۱۱ / شماره ۱ / بهار و تابستان ۱۴۰۴ (پیاپی ۲۱) پژوهش‌نامه علم‌سنجی

پاسخ به پرسش دوم پژوهش: آیا بین تعداد بروندهای و همکاری‌های علمی با شاخص‌های مربوط به اثر گذاری، اجتماعی و اقتصادی رابطه وجود دارد؟

نمودار زیر میزان همبستگی بین حجم بروندهای علمی، همکاری، تأثیر علمی، اقتصادی و اجتماعی آن‌ها را نشان می‌دهد..



نمودار ۱. نتایج آزمون همبستگی بین حجم بروندهای علمی، همکاری، تأثیر علمی، تأثیر اقتصادی و تأثیر اجتماعی آن‌ها.

داده‌های نمودار ۱ نشان می‌دهد هرکدام از متغیرها با متغیرهای دیگر چه رابطه‌ای باهم دارند. عدد گزارش شده هرچقدر به +۱ و یا -۱ نزدیک‌تر باشد گویای این است که رابطه بیشتری بین دو متغیر وجود دارد و هرچقدر به صفر نزدیک‌تر باشد نشان می‌دهد که آن دو متغیر رابطه خطی با یکدیگر ندارند. اعداد مثبت نشان می‌دهند اگر یکی از متغیرها افزایش یابد متغیر دیگری نیز افزایش پیدا می‌کند. اعداد منفی نشان می‌دهند اگر یکی از متغیرها افزایش پیدا کند متغیر دیگر کاهش می‌یابد. بدیهی است هر متغیر با خودش همبستگی کامل یعنی +۱ دارد. به همین دلیل در قطر ماتریس، تمام اعداد +۱ هستند.

بر این اساس، حجم بروندهای علمی ایران در حوزه زیست‌فناوری با حجم استنادها، استناد به ازای برونداد، تأثیر استناد وزنی حوزه، بروندها در ۱۰ درصد استنادهای برتر، تعداد بازدیدها و تأثیر بازدید وزنی حوزه، رابطه مثبت و معنی‌داری داشته است.

پیش‌بینی تأثیر گذاری پژوهش‌های علمی حوزه زیست‌فناوری با استفاده از الگوریتم‌های یادگیری ماشین

همکاری بین‌المللی با حجم استنادها، تأثیر استناد وزنی حوزه، بروندادها در ۱۰ درصد برتر نشریات، تعداد استنادات ثبت اختراع، استنادهای حق ثبت اختراع به ازای هر خروجی علمی، خروجی علمی استناد شده توسط ثبت اختراعات، تعداد اختراعات، تعداد باز دیده‌ها، برونداد در ۱۰ درصد باز دیده‌های برتر، باز دیده به ازای هر خروجی و تأثیر باز دیده وزنی حوزه، رابطه مثبت و معنی‌داری داشته است. همکاری دولتی دانشگاهی نیز تنها بر سه شاخص استناد به ازای برونداد، تعداد استنادات ثبت اختراع و استنادهای حق ثبت اختراع به ازای هر خروجی علمی رابطه مثبت و معنی‌داری داشته است. همکاری فقط دانشگاهی بر حجم استنادها، تأثیر استناد وزنی حوزه، بروندادها در ۱۰ درصد برتر نشریات، بروندادها در ۱۰ درصد استنادهای برتر، تعداد استنادات ثبت اختراع، خروجی علمی استناد شده توسط ثبت اختراعات، تعداد اختراعات، تعداد باز دیده‌ها و تأثیر باز دیده وزنی حوزه، رابطه مثبت و معنی‌داری داشته است.

پاسخ به پرسش سوم پژوهش: کدام یک از شاخص‌های اثر گذاری علمی، اجتماعی و اقتصادی با یکدیگر ارتباط دارند؟

در مقوله اثر گذاری علمی بروندادهای مورد مطالعه، حجم استنادها با شاخص‌های تعداد استنادات ثبت اختراع، تعداد اختراعات، تعداد باز دیده‌ها، باز دیده به ازای هر خروجی و تأثیر باز دیده وزنی حوزه، رابطه مثبت و معنی‌داری داشته است.

در حوزه اثر گذاری اقتصادی، تعداد استنادات ثبت اختراع با همکاری دانشگاهی، تأثیر همکاری بین‌المللی، حجم استنادها، استناد به ازای برونداد، تأثیر استناد وزنی حوزه، تعداد باز دیده‌ها، برونداد در ۱۰ درصد باز دیده‌های برتر، باز دیده به ازای هر خروجی و تأثیر باز دیده وزنی حوزه، رابطه مثبت و معنی‌داری داشته است. استنادات ثبت اختراع به ازای هر برونداد با شاخص‌های استناد به ازای هر برونداد، باز دیده به ازای هر خروجی و تأثیر باز دیده وزنی حوزه، رابطه مثبت و معنی‌داری داشته است. تعداد اختراعات با مواردی مانند حجم استنادها، استناد به ازای برونداد، تعداد باز دیده‌ها، برونداد در ۱۰ درصد درصد باز دیده‌های برتر و باز دیده به ازای هر خروجی، رابطه مثبت و معنی‌داری داشته است.

تعداد باز دیده‌ها با شاخص‌هایی نظیر حجم استنادها، تأثیر استناد وزنی حوزه، تعداد استنادات ثبت اختراع، استنادهای حق ثبت اختراع به ازای هر خروجی علمی، خروجی علمی استناد شده توسط ثبت اختراعات و تعداد اختراعات، رابطه مثبت و معنی‌داری داشته است.

پاسخ به پرسش چهارم پژوهش: کدام یک از الگوریتم‌های ماشین می‌توانند اثر گذاری علمی، اجتماعی و اقتصادی را پیش‌بینی کنند؟

نتیجه بررسی میزان پیش‌بینی‌کنندگی الگوریتم‌های مورد استفاده در اثرات علمی، فناورانه و اجتماعی بروندادهای علمی در جدول ۴ آمده است.

در جدول ۴، شاخص هدف، نمره صحت و نمره انحراف معیار ۴ مدل پیاده شده در این مطالعه، آمده است. گفتنی است هرچقدر نمره صحت اجرای مدل بالاتر و نمره انحراف معیار حاصل شده پایین‌تر باشد، قدرت پیش‌بینی‌کنندگی الگوی پیاده شده بیشتر خواهد بود. اعداد منفی، بیانگر دقت بسیار پایین بوده و نشان می‌دهد مدل به کاررفته به‌منظور پیش‌بینی یک متغیر خاص، مناسب نیست. بر اساس نتایج حاصل شده، رگرسیون خطی چند متغیره با نمره صحت بالاتر و نمره انحراف معیار پایین‌تر، بهتر توانسته است میزان اثر گذاری علمی، فناورانه و اجتماعی بروندادهای علمی ایران در حوزه زیست‌فناوری را پیش‌بینی کند.

جدول ۴. میزان پیش‌بینی‌کنندگی اثرات علمی، فناورانه و اجتماعی بروندهای علمی در الگوریتم‌های مختلف.

مدل	شاخص هدف	نمره صحت مدل	نمره انحراف معیار مدل
نزدیک‌ترین همسایه	اثر علمی	۰.۴۴	۰.۵۷
	اثر فناورانه	-۰.۰۷	۰.۹۹
	اثر اجتماعی	۰.۰۸	۰.۸۶
درخت تصمیم	اثر علمی	-۰.۸۸	۰.۲۴
	اثر فناورانه	۰.۴۴	۰.۲۶
	اثر اجتماعی	-۰.۶۶	۱.۷۸
جنگل تصادفی	اثر علمی	-۰.۴۱	۰.۸۶
	اثر فناورانه	-۵۱.۳۰	۶۵.۹۶
	اثر اجتماعی	۰.۶۸	۰.۱۵
رگرسیون خطی چند متغیره	اثر علمی	۰.۷۸	۰.۱۳
	اثر فناورانه	۰.۵۲	۰.۲۸
	اثر اجتماعی	۰.۶۸	۰.۱۵
تقویت گرادیان	اثر علمی	-۰.۷۰	۰.۹۶
	اثر فناورانه	۰.۹۳	۰.۰۴
	اثر اجتماعی	۰.۵۱	۰.۵۹

بحث و نتیجه‌گیری

سنجش کمیت و کیفیت فعالیت‌ها و خروجی‌های علمی از زوایای گوناگون از اهمیت بسیار زیادی برخوردار است. با توجه به اهمیت موضوع، این مطالعه با هدف بررسی رابطه هر یک از متغیرهای مختلف اثرگذاری بر یکدیگر و نیز ارزیابی الگوریتم‌های ماشین که بتوانند اثرگذاری علمی، اجتماعی و اقتصادی بروندهای علمی را پیش‌بینی کنند، انجام گرفت. به این منظور، برندهای حوزه زیست‌فناوری نمایه شده ایران در پایگاه اسکوپوس در دوره ۲۰۰۳-۲۰۲۴ از ابعاد مختلف، ارزیابی و تحلیل شد.

یافته‌های این مطالعه نشان داد که برندهای علمی ایران در این حوزه در بازه زمانی ۲۰۰۳-۲۰۲۳، سیر صعودی داشته و افزایش ۳۶ برابری را تجربه کرده است که پیشرفت فوق‌العاده‌ای در این فاصله زمانی محسوب می‌شود. شکل‌گیری ستاد توسعه زیست‌فناوری در ایران و تصویب سند مربوط به این حوزه و در نتیجه افزایش حمایت‌ها از حوزه زیست‌فناوری می‌تواند از جمله دلایل این رشد باشد. ضمن اینکه رشد کیفیت مقالات نیز مورد انتظار است؛ اما از آنجاکه شاخص‌های موجود علم‌سنجی عمدتاً مبتنی بر استناد بوده و لازمه اثرگذاری در ابعاد مختلف، گذشت زمان بوده، قضاوت در مورد آن‌ها نیازمند توجه به بُعد زمان و انجام مطالعه جداگانه‌ای خواهد بود.

بر اساس داده‌های حاصل شده، حجم برندهای علمی ایران در حوزه زیست‌فناوری بین حجم استنادها، استناد به ازای بروناد، تأثیر استناد وزنی حوزه، بروندها در ۱۰ درصد استنادهای برتر، تعداد بازبینی‌ها و تأثیر بازبینی وزنی حوزه، رابطه مثبت و معنی‌داری برقرار بوده است. از این نظر می‌توان تاندازه‌ای گفت در کنار رشد کمی، شاخص‌های

سنجی استناد و نیز میزان رؤیت پذیری در شبکه‌های علمی نیز ارتقا پیدا کرده‌اند. در عین حال، با افزایش این تعداد، شاخص‌های کاربردی بودن مقالات که مبتنی بر استناد در پروانه‌های ثبت اختراع است، بهبود پیدا نکرده‌اند. در واقع می‌توان گفت شکاف زیادی بین مقالات علمی و پژوهش‌های کاربردی حوزه زیست‌فناوری ایران وجود دارد. شاید بتوان وجود موانع متعدد در مسیر کاربردی کردن پژوهش‌ها، حمایت‌های ناکافی دولتی و عدم انگیزه پژوهشگران برای تجاری‌سازی یافته‌های خود را از دلایل این موضوع برشمرد.

رابطه بین همکاری بین‌المللی با شاخص‌هایی از جمله حجم استنادها، تأثیر استناد وزنی حوزه، بروندادها در ۱۰ درصد برتر نشریات، تعداد استنادات ثبت اختراع، استنادهای حق ثبت اختراع به ازای هر خروجی علمی، خروجی علمی استناد شده توسط ثبت اختراعات، تعداد اختراعات، تعداد بازدیدها، بروندادها در ۱۰ درصد بازدیدهای برتر، بازدید به ازای هر خروجی و تأثیر بازدید وزنی حوزه، مثبت و معنی‌دار تشخیص داده شد. به این ترتیب، این شاخص بر بسیاری از موارد، اثرگذار بوده و در واقع مهم‌ترین عامل مؤثر بر کیفیت مقالات از جمله در بُعد استنادها، بازدیدها و کاربردی بودن، همکاری بین‌المللی بوده و در این مطالعه، هیچ شاخصی به این میزان اهمیت نداشته است. همکاری دولتی دانشگاهی نیز با سه شاخص استناد به ازای برونداد، تعداد استنادات ثبت اختراع و استنادهای حق ثبت اختراع به ازای هر خروجی علمی رابطه مثبت و معنی‌داری داشته است. طبق این یافته می‌توان ادعا کرد با اینکه درصد این نوع همکاری بالا بوده اما حمایت‌های دولت در مسیر اثرگذاری اقتصادی پژوهش‌های این حوزه، مؤثر افتاده به نحوی که تبادل استناد بیشتری بین مقالاتی که با همکاری نهادهای دولتی منتشر شده و پروانه‌های ثبت اختراع رخ داده است. شاخص همکاری دانشگاهی نیز رابطه مثبت و معنی‌داری با حجم استنادها، تأثیر استناد وزنی حوزه، بروندادها در ۱۰ درصد برتر نشریات، بروندادها در ۱۰ درصد استنادهای برتر، تعداد استنادات ثبت اختراع، خروجی علمی استناد شده توسط ثبت اختراعات، تعداد اختراعات، تعداد بازدیدها و تأثیر بازدید وزنی حوزه، داشته است. به این ترتیب، عمده نقطه اثرگذاری مقالات، در بخش استنادهای علمی و مطالعات سایر پژوهشگران هم‌تراز تبلور یافته است. ضمن اینکه حوزه کاربرد و جامعه را نیز متأثر ساخته است.

همچنین در عرصه اثرگذاری خروجی‌های علمی مورد مطالعه، حجم استنادها با شاخص‌های تعداد استنادات ثبت اختراع، تعداد اختراعات، تعداد بازدیدها، بازدید به ازای هر خروجی و تأثیر بازدید وزنی حوزه، رابطه مثبت و معنی‌داری داشته است. در این رابطه، محققان با کمک روش‌های یادگیری ماشین، به این نتیجه دست یافتند که ترکیبی از مؤلفه‌های مرتبط با مقاله، مجله و نویسنده در مقایسه با استفاده از تنها یک نوع مؤلفه در پیش‌بینی مقالات پر استناد، بهتر عمل می‌کند (Hansen, 2022). ایوب، امین و وانی در مطالعه خود دو مقوله استناد و نمره دگر سنجی مقالات رشته علوم زیستی، علوم زمین و محیط‌زیست، تاریخ و باستان‌شناسی را به منظور تعیین میزان مقایسه و ارتباط آن‌ها با یکدیگر بررسی کردند و به این نتیجه رسیدند که همبستگی مثبتی بین دگر سنجی و امتیاز استناد و همچنین نمره دگر سنجی و اس.جی.آر وجود دارد (Ayoub et al., 2023). پژوهش بذرافشان و همکاران (۱۴۰۲) با بررسی رابطه همبستگی و رگرسیون چندگانه بین تعداد استنادات و نمرات دگر سنجی نشان داد که رابطه قوی بین استنادات پلام‌ایکس و تعداد استنادات اسکوپوس برقرار است.

در حوزه شاخص‌های مرتبط با تعامل بین بروندادهای علمی با پروانه‌های ثبت اختراع نیز این نتیجه حاصل شد که تعداد استنادات ثبت اختراع به‌عنوان یکی از شاخص‌های معرف این نوع تأثیر، با مواردی از قبیل همکاری دانشگاهی، همکاری بین‌المللی، حجم استنادها، استناد به ازای برونداد، تأثیر استناد وزنی حوزه، تعداد بازدیدها، برونداد در ۱۰

درصد بازدهی‌های برتر، بازدید به ازای هر خروجی و تأثیر بازدید وزنی حوزه، رابطه مثبت و معنی‌داری داشته است. در واقع، کاربردی شدن مقالات و پژوهش‌های حوزه زیست‌فناوری ایران زمینه‌ساز تحقق بسیاری از شرایط دیگر خواهد بود از جمله همکاری بین‌المللی، افزایش حجم اسنادها و بهبود تعداد بازدهی‌ها. در همین رابطه، بین استنادات ثبت اختراع به ازای هر برونداد با شاخص‌های استناد به ازای هر برونداد، بازدید به ازای هر خروجی و تأثیر بازدید وزنی حوزه، رابطه مثبت و معنی‌داری برقرار بوده است. همچنین تعداد اختراعات با مواردی مانند حجم اسنادها، استناد به ازای برونداد، تعداد بازدهی‌ها، برونداد در ۱۰ درصد بازدهی‌های برتر و بازدید به ازای هر خروجی، رابطه مثبت و معنی‌داری برقرار کرده است. نکته قابل تأمل برای سیاست‌گذاران عرصه علم و فناوری در کشور این است که برای توسعه علمی ایران، علی‌رغم رشد کمی و کیفی تولیدات علمی، نظام پژوهشی کشور باید به سمت ارزش‌آفرینی و ایجاد ارزش‌افزوده به‌ویژه در حوزه اقتصادی سوق داده شود.

در مورد شاخص‌های دگر سنجی نیز این نتیجه به دست آمد که تعداد بازدهی‌ها رابطه مثبت و معنی‌داری با شاخص‌هایی نظیر حجم اسنادها، تأثیر استناد وزنی حوزه، تعداد استنادات ثبت اختراع، استنادهای حق ثبت اختراع به ازای هر خروجی علمی، خروجی علمی استناد شده توسط ثبت اختراعات و تعداد اختراعات این حوزه دارد. بر اساس این یافته می‌توان به قدرت و ظرفیت رسانه‌های اجتماعی در راستای زمینه‌سازی به‌منظور ورود آخرین یافته‌های علمی دانشمندان و پژوهشگران به فضای عمومی جامعه اذعان کرد.

یکی دیگر از پرسش‌هایی که این مطالعه درصدد پاسخ به آن بود این است که کدام‌یک از الگوریتم‌های ماشین می‌تواند اثرگذاری علمی، اجتماعی و اقتصادی را دقیق‌تر پیش‌بینی کنند. بر اساس نتایج به‌دست‌آمده، الگوی رگرسیون خطی چند متغیره با نمره صحت بالاتر و نمره انحراف معیار پایین‌تر، بهتر توانست میزان اثرگذاری بروندادهای علمی ایران در حوزه زیست‌فناوری را در ابعاد علمی، فناورانه و اجتماعی پیش‌بینی کند. آکوهر و همکاران نیز از چارچوب یادگیری ماشین برای آزمون توانایی دگر سنجی‌ها در پیش‌بینی تعداد اسنادها استفاده کردند و نشان دادند از بین الگوهای درخت تصمیم، جنگل تصادفی و ماشین‌های بردار پشتیبانی، جنگل تصادفی نسبت به دیگر طبقه‌بندی‌کننده‌ها، بهتر می‌تواند اسنادهای آینده را پیش‌بینی کند (Alchokr et al., 2023). برخی نیز به این نتیجه رسیدند که استفاده از تکنیک‌های مدرن یادگیری عمیق مانند شبکه عصبی بازگشتی و مدل دنباله به دنباله با توجه به دقت و توانایی پیش‌بینی استنادات مقالات پر استناد، بهتر از روش‌های پیشرفته پیش‌بینی تعداد استناد است (Abrishami & Aliakbary, 2019). نتایج مطالعه‌ای دیگر نشان داد که جنگل تصادفی پیش‌بینی‌کننده‌ترین الگوریتم برای پیش‌بینی تأثیر آتی مقالات است (McNamara et al., 2013). در راستای نتایج این مطالعه، برخی محققان نیز به این نتیجه دست یافتند که برای پیش‌بینی توزیع احتمال برای تعداد اسنادهای آینده، ضرایب رگرسیون چندگانه برای پیش‌بینی توزیع اسنادها مناسب است (Stegehuis et al., 2015).

پیشنهاد‌های اجرایی پژوهش

- با توجه به یافته‌های این مطالعه، موارد زیر قابل پیشنهاد است:
- نظر به اینکه مدل رگرسیون خطی چند متغیره، قدرت پیش‌بینی‌کنندگی بالاتری نسبت به سایر مدل‌ها داشت، پیشنهاد می‌شود مدیران، سیاست‌گذاران و متخصصان علم‌سنجی که به دنبال ارزیابی و آینده‌پژوهی اثرگذاری بروندادهای علمی هستند از این الگو به این منظور استفاده کنند.

پیش‌بینی تأثیر گذاری پژوهش‌های علمی حوزه زیست‌فناوری با استفاده از الگوریتم‌های یادگیری ماشین

- هنگام ارزیابی کمی و کیفی مقالات، استفاده از شاخص‌های متفاوت پیشنهاد می‌شود تا تصویر شفاف‌تری از اثرگذاری پژوهش‌ها حاصل شود.
- با توجه به تأثیر همکاری بین‌المللی بر کیفیت فعالیت‌های پژوهشی، به مدیران و سیاست‌گذاران حوزه علم و فناوری کشور توصیه می‌شود زمینه‌های مشارکت پژوهشگران داخلی با پژوهشگران بین‌المللی را فراهم سازند و مشوق‌هایی را برای همکاری‌های بین‌المللی پیش‌بینی کنند.
- به پژوهشگران نیز توصیه می‌شود تا حد ممکن مطالعات خود را با همکاری افراد بین‌المللی پیگیری و اجرا کنند.
- با در نظر گرفتن تأثیر مثبت تعداد بازدیدهای فضای مجازی در سایر شاخص‌های کیفیت و اثرگذاری علمی، پیشنهاد می‌شود پژوهشگران در شبکه‌های اجتماعی علمی فعال باشند و دستاوردها و یافته‌های پژوهش‌های خود را از طریق این سکوها با سایرین به اشتراک بگذارند تا رؤیت پذیری پژوهش‌ها بیشتر شود.
- با توجه به شکاف زیاد بین مقالات علمی و پژوهش‌های کاربردی حوزه زیست‌فناوری ایران، شناسایی و رفع موانع تجاری‌سازی دستاوردهای علمی، امری ضروری برای مدیران و سیاست‌گذاران این حوزه است.

پیشنهاد برای پژوهش‌های آتی

- پیشنهاد می‌شود محورهای زیر، در برنامه مطالعاتی پژوهشگران بعدی قرار گیرد:
- استفاده از شاخص‌های به کار رفته در مطالعه حاضر برای حوزه‌های علمی متفاوت.
- تکرار این مطالعه در سال‌های بعد و مقایسه نتایج حاصل شده.
- مقایسه آمار و اطلاعات اثرگذاری پژوهش‌های علمی ایران در مقایسه با کشورهای اسلامی، منطقه، خاورمیانه یا جهان.
- استفاده از الگوریتم‌های مورد استفاده در این مطالعه برای پیش‌بینی اثرگذاری پژوهش‌ها در یکی از حوزه‌های علمی.
- استفاده از پایگاه‌های داده متفاوت برای استخراج داده‌ها و تحلیل اثرات مختلف آن‌ها.

تقدیر و تشکر

این مقاله، برگرفته از بخشی از طرح پژوهشی مصوب در مرکز تحقیقات سیاست علمی کشور با عنوان: «ارزیابی تأثیرات بروندهای علمی: مطالعه موردی حوزه زیست‌فناوری ایران» با شماره ۱۰۴/ص/۱۴۰۲ است. بدین‌وسیله از مرکز تحقیقات سیاست علمی کشور به سبب حمایت‌های مادی و معنوی در رابطه با این طرح، صمیمانه سپاسگزارم.

فهرست منابع

- ابراهیمی، س.، دهقان، م.، و جوکار، ع. (۱۳۹۶). بررسی شاخص‌های پیش‌بینی کننده تأثیرگذاری علمی برای افزایش استناد گیری مقالات نشریه‌های علمی. *پژوهشنامه پردازش و مدیریت اطلاعات*، ۳۲(۳)، ۶۶۱-۶۹۴.
- <https://doi.org/10.35050/JIPM010.2017.033>
- آزادی احمدآبادی، ق. (۱۴۰۳). *ارزیابی تأثیرات بروندهای علمی: مطالعه موردی حوزه زیست‌فناوری ایران*. گزارش طرح پژوهشی. [مرکز تحقیقات سیاست علمی کشور]. <https://nrisp.ac.ir/%D8%A7%D8%B1%D>
- آزادی احمدآبادی، ق. (۱۴۰۳). سطوح و شاخص‌های ارزیابی تأثیرات پژوهش بر اساس تحلیل نظام‌های ارزیابی. *ترویج علم*. ۱۵(۱)، ۷۶-۱۰۳. <https://doi.org/10.22034/popsci.2024.424371.1306>

- Azadi, G. (2024). Evaluation research impacts: levels and indicators. *Journal of the Popularization of Science*, 15(1), 76-103. <https://doi.org/10.22034/popsci.2024.424371.1306> [In Persian].
- Babaakbarisari, A., Ghahremani, M., Fathi vajargah, K., & Moatameni, A. (2021). Developing Management Researches Impacts Assessment Model. *Management Research in Iran*, 21(1), 93-119. https://mri.modares.ac.ir/article_418.html [In Persian].
- Bazrafshan, A., Biranvand, A., & Shojaeifard, A. (2023). Predicting the number of citations received in particle physics Scopus with the help of Plumx-Altmetric scores. *Knowledge Retrieval and Semantic Systems*, [Available online from 6 June]. <https://doi.org/10.22054/jks.2023.71392.1551> [In Persian].
- Bai, X., Liu, H., Zhang, F., Ning, Z., Kong, X., Lee, I., & Xia, F. (2017). An overview on evaluating and predicting scholarly article impact. *Information*, 8(3), 73. <https://doi.org/10.3390/info8030073>
- Bernard, S., Adam, S., & Heutte, L. (2012). Dynamic random forests. *Pattern Recognition Letters*, 33(12), 1580-1586. <https://doi.org/10.1016/j.patrec.2012.04.003>
- Biranvand, A., Golshani, M., & Delghandi, F. (2022). Investigating the impact of Citescore, SNIP, and SJR indicators of semantic web publications on the number of received citations of articles. *Knowledge Retrieval and Semantic Systems*, 12(42). <https://doi.org/10.22054/jks.2022.67616.1501> [In Persian].
- Bollen, J., Van de Sompel, H., Hagberg, A., & Chute, R. (2009). A principal component analysis of 39 scientific impact measures. *PloS one*, 4(6), e6022. <https://doi.org/10.1371/journal.pone.0006022>
- Bornmann, L., Leydesdorff, L., & Wang, J. (2013). Which percentile-based approach should be preferred for calculating normalized citation impact values? An empirical comparison of five approaches including a newly developed citation-rank approach (p100). *Journal of Informetrics*, 7(4), 933-944. <https://doi.org/10.1016/j.joi.2013.09.003>
- Ebrahimi, S., Dehghan, M., & Jowkar, A. (2017). Evaluation the predictive indicators of scientific impact to increase the citations of articles in scientific journals. *Iranian Journal of Information Processing and Management*, 32(3), 661-694. <https://doi.org/10.35050/JIPM010.2017.033> [In Persian].
- Gu, X., & Krenn, M. (2024). Forecasting high-impact research topics via machine learning on evolving knowledge graphs (Version 2). *arXiv*. <https://doi.org/10.48550/arXiv.2402.08640>
- Guthrie, S., Wamae, W., Diepeveen, S., Wooding, S., & Grant, J. (2013). Measuring research, A guide to research evaluation frameworks and tools, RAND Corporation, MG-1217-AAMC, 2013. <https://www.rand.org/pubs/monographs/MG1217.html>
- Hansen, I. S., & Torvund, M. (2022). Predicting the impact of academic articles on marketing research: Using machine learning to predict highly cited marketing articles [Unpublished master's dissertation] Norwegian School of Economics. <https://openaccess.nhh.no/nhh-xmlui/bitstream/handle/11250/3015929/masterthesis.pdf?sequence=1>
- Hastie, T., & Tibshirani, R. (1995). Discriminant adaptive nearest neighbor classification and regression. *Advances in neural information processing systems*, 8, 409-415. <https://dl.acm.org/doi/10.5555/2998828.2998886>

- Hastie, T., Tibshirani, R., & Friedman, J. (2009). The elements of statistical learning: data mining, inference, and prediction, Springer Series in Statistics, 337-387. <https://www.sas.upenn.edu/~fdiebold/NoHesitations/BookAdvanced.pdf>
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255-260. <https://doi.org/10.1126/science.aaa8415>
- Kosteas, V. D. (2018). Predicting long-run citation counts for articles in top economics journals. *Scientometrics*, 115(3), 1395-1412. <https://doi.org/10.1007/s11192-018-2703-0>
- Maulud, D., & Abdulazeez, A. M. (2020). A review on linear regression comprehensive in machine learning. *Journal of Applied Science and Technology Trends*, 1(2), 140-147. <https://doi.org/10.38094/jastt1457>
- McNamara, D., Wong, P., Christen, P., & Ng, K. S. (2013). Predicting high impact academic papers using citation network features [Conference presentation]. In *Trends and Applications in Knowledge Discovery and Data Mining- PAKDD 2013 International Workshops: DMAPps, DANTh, QIMIE, BDM, CDA, CloudSD, Gold Coast, QLD, Australia, April 14-17, 2013, Revised Selected Papers 17* (pp. 14-25). Springer Berlin Heidelberg. https://link.springer.com/chapter/10.1007/978-3-642-40319-4_2
- Paun, M., Abigaela, B., Paul, B., Anastasia, C., Catalina, E., Anne, H., Nicoleta, I., & Eduard, M. (2020). Predicting long-term citation counts in Web of Science: COVID-19 early publications case study. *Romanian Statistical Review*, (4). https://www.revistadestatistica.ro/wp-content/uploads/2020/12/A4-RRS4_2020.pdf
- Newson, R., King, L., Rychetnik, L., Bauman, A. E., Redman, S., Milat, A. J., Schroeder, J., Cohen, G., & Chapman, S. (2015). A mixed methods study of the factors that influence whether intervention research has policy and practice impacts: perceptions of Australian researchers. *BMJ open*, 5(7), e008153. <https://doi.org/10.1136/bmjopen-2015-008153>
- Noroozi Chakoli, A. (2023). *Introduction to scientometric (foundations, concepts, relations & origins)*. Tehran: SAMT, Shahed University. <https://samt.ac.ir/en/book/3376/introduction-to-scientometric> [In Persian].
- Piryonesi, S. M., & El-Diraby, T. E. (2020). Data analytics in asset management: Cost-effective prediction of the pavement condition index. *Journal of infrastructure systems*, 26(1). [http://dx.doi.org/10.1061/\(ASCE\)IS.1943-555X.0000512](http://dx.doi.org/10.1061/(ASCE)IS.1943-555X.0000512)
- Stegehuis, C., Litvak, N., & Waltman, L. (2015). Predicting the long-term citation impact of recent publications. *Journal of informetrics*, 9(3), 642-657. <https://doi.org/10.1016/j.joi.2015.06.005>
- Studer, M., Ritschard, G., Gabadinho, A., & Müller, N. S. (2011). Discrepancy analysis of state sequences. *Sociological methods & research*, 40(3), 471-510. <https://doi.org/10.1177%2F0049124111415372>
- Timilsina, M., Davis, B., Taylor, M., & Hayes, C. (2016). Towards predicting academic impact from mainstream news and weblogs: A heterogeneous graph-based approach [Conference presentation]. In *2016 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining (ASONAM)* (pp. 1388-1389). IEEE. <https://ieeexplore.ieee.org/document/7752425>
- Weihs, L., & Etzioni, O. (2017). Learning to predict citation-based impact measures. [Conference presentation]. In *2017 ACM/IEEE joint conference on digital libraries (JCDL)*, (p 49-58). <https://dl.acm.org/doi/abs/10.5555/3200334.3200341>

- Weinberger, K. Q., & Saul, L. K. (2009). Distance metric learning for large margin nearest neighbor classification. *Journal of machine learning research*, 244-207.
<https://jmlr.csail.mit.edu/papers/volume10/weinberger09a/weinberger09a.pdf>
- Williams, K., & Lewis, J. M. (2021). Understanding, measuring, and encouraging public policy research impact. *Australian Journal of Public Administration*, 80(3), 554-564.
<https://doi.org/10.1111/1467-8500.12506>
- Wooldridge, J., & King, M. B. (2018). Altmetric scores: An early indicator of research impact. *Journal of the Association for Information Science and Technology*, 70(3), 271-282.
<https://doi.org/10.1002/asi.24122>
- Xiong, C., Sun, H., Pan, D., & Li, Y. (2019). Personalized Collaborative Filtering Recommendation Algorithm based on Linear Regression [Conference presentation]. In *2019 IEEE International Conference on Power Data Science (ICPDS)* (pp. 363-368). IEEE.
<https://doi.org/10.18280/mmep.060307>
- Wu, X., Kumar, V., Ross Quinlan, J., Ghosh, J., Yang, Q., Motoda, H., McLachlan, G. J., Ng, A., Liu, B., Yu, P. S., Zhou, Z.H., Steibach, M., Hand, D. J., & Steinberg, D. (2007). Top 10 algorithms in data mining. *Knowledge and information systems*, 14(1), 1-37.
<https://doi.org/10.1007%2Fs10115-007-0114-2>
- Yu, T., Yu, G., Li, P.-Y., & Wang, L. (2014). Citation impact prediction for scientific papers using stepwise regression analysis. *Scientometrics*, 101(2), 1233-1252.
<https://doi.org/10.1007/s11192-014-1279-6>
- Zhang, F., & Wu, S. (2020). Predicting future influence of papers, researchers, and venues in a dynamic academic network. *Journal of Informetrics*, 14(2), 101035.
<https://doi.org/10.1016/j.joi.2020.101035>
- Ziegler, A., & König, I. R. (2013). Mining data with random forests: current options for real-world applications. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 4(1), 55-63. <https://doi.org/10.1002/widm.1114>