

Predicting scientific research impacts in biotechnology by
machine learning algorithms

Assistant Professor, Policy evaluation and Monitoring of Science, Technology, and
Innovation Department, National Research Institute for Science Policy, Tehran, Iran.
azadi_gh@yahoo.com ORCID ID : 0000-0002-3610-2573 (Corresponding author)

Receive:

.././.....

Acceptance:

.././.....

Abstract

Purpose: "Research impact" is one of the key concerns of the stakeholders of this field, which can be considered as positive and profitable applications of research in various dimensions such as society, economy, environment, culture, health, etc. The current study aims to measure the relationship of each of the different variables of scientific outputs impacts on each other and also to examine which of the machine algorithms can predict the scientific, social, and economic impact of scientific outputs.

Methodology: The current research is applied in terms of purpose and descriptive in terms of method and has been done by scientometric approach. This study aims to investigate the relationship between the volume of scientific outputs and scientific cooperation as well as the scientific, social, and economic impact of Iran's scientific outputs in biotechnology; and which of the machine learning algorithms are better predictors for measuring the effectiveness of scientific outputs in different dimensions. The research community is Iran's biotechnology scientific outputs, which are indexed in the Scopus database from 2003 to 2024. The data extracted 1 Bahman 1402 equivalent to 21 January 2024. To extract relevant data, a Scival analytical database was used. In this research, Pearson's correlation coefficient and R software package were used to determine the relationship between the studied indicators. Machine learning algorithms such as multiple linear regression, nearest neighbor, decision trees, random forests, and gradient boosting were also used and evaluated as predictive models. To perform tests and algorithms, Python programming language has been used.

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. The relationship between international collaboration and indicators such as citations 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, Views per Publication, and Field-Weighted Views Impact of the domain were found to be positive and significant. The index of academic collaboration also has a positive and significant relationship with the 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, the Scholarly Output cited by Patents, Patents Count, Views Count and Field-Weighted Views Impact. Academic-government collaboration also has a positive and significant relationship 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 have a positive and significant relationship with the indicators Scholarly Output cited by Patents, Patents Count, Views Count, Views per Publication, and the Field-Weighted Views Impact of the biotechnology scientific outputs. In economic impact, the result indicated that the number of patent citations is one of the

representative indicators of this type of impact, with indicators such as academic Collaboration, international Collaboration, citations 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 the biotechnology scientific outputs. In terms of social impact, it was also concluded that Views Count has a positive and significant relationship with indicators such as 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 the biotechnology field. Based on the obtained results, multivariate linear regression with a higher accuracy score and a lower standard deviation score could better predict the scientific, technological, and social impact of Iran's scientific outputs in biotechnology.

Conclusion: The most important factor affecting the quality of articles, including citations, views, and applicability, is international cooperation, and it is necessary to about measures in this regard. It is suggested to use a variety of indicators during the quantitative and qualitative evaluation of the articles to obtain a clearer picture of the effectiveness of the research. The important point for policymakers in science and technology for scientific development in Iran is that despite the quantitative and qualitative growth of scientific outputs, the country's research system should be directed towards value creation and creating added value, especially in the economic field.

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

چکیده

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

روش‌شناسی: پژوهش حاضر از لحاظ هدف، کاربردی و از نظر روش، توصیفی بوده و با رویکرد علم‌سنجی انجام شده است. جامعه پژوهش، بروندهای حوزه زیست‌فناوری ایران است که در پایگاه اسکوپوس در بازه ۲۰۰۳-۲۰۲۴ نمایه شده‌اند. به منظور 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 پیش‌بینی‌کننده، مورد و 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 بازدهها رابطه مثبت و معنی‌داری با بسیاری از شاخص‌ها دارد. براساس نتایج حاصل شده، رگرسیون خطی چندمتغیره با نمره صحت بالاتر و نمره انحراف معیار پایین‌تر، بهتر توانست میزان اثرگذاری علمی، فناورانه و اجتماعی بروندهای علمی ایران در حوزه زیست‌فناوری را پیش‌بینی نماید.

نتیجه‌گیری: مهمترین عامل مؤثر بر کیفیت مقالات از جمله در بعد استنادها، بازدهها و کاربردی بودن، همکاری بین‌المللی بوده که در این خصوص لازم است تدابیری اندیشه شود. پیشنهاد می‌شود هنگام ارزیابی کمی و کیفی مقالات، از شاخص‌های متنوعی استفاده شود 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

۱. استادیار، گروه ارزیابی سیاست‌ها و پایش علم، فناوری و نوآوری، مرکز تحقیقات سیاست علمی کشور، تهران، ایران. کشور azadi_gh@yahoo.com | تلفن: ۸۸۰۳۶۱۴۴ | شناسه ارجید: 0000-0002-3610-2573 (نویسنده مسئول)

دریافت: ۰۰۰/۰۰/۰۰

پذیرش: ۰۰۰/۰۰/۰۰

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، بحث سنجش این تولیدات از زوایای گوناگون نیز از اهمیت بسیار زیادی برخوردار شده است. از ملزومات سیاست‌گذاری کارآمد و درست در حوزه علم و تحلیل حرکت علمی کشور، انجام پژوهش‌هایی به منظور شناسایی وضعیت موجود در جهت شناسایی نقاط قوت و ضعف آنهاست. شاخص‌های علم‌سنجی، مهم‌ترین ابزارهایی که می‌تواند چنین اطلاعاتی را در اختیار برنامه‌ریزان و سیاست‌گذاران قرار دهد (آزادی احمدآبادی، ۱۴۰۳).

با توجه به نقش و اهمیت پژوهش در توسعه و پیشرفت جوامع در برنامه‌های کلان کشورها در جهت نیل به توسعه و پیشرفت، به این امر 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 (باباکیبری 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 اغلب برای ارزیابی اثربخشی پژوهش مورد توجه قرار می‌گیرد معیارهای سنتی از قبیل تعداد مقالات، ضریب تأثیر مجلات، تعداد گرنت‌ها 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 به‌شمار می‌رود (آزادی احمدآبادی و همکاران، ۱۴۰۱).

واقعیت آن است که سنجش تأثیر پژوهش‌ها در ابعاد مختلف به‌سادگی ممکن نیست. آن‌چه که در حال حاضر و به‌طور واقعی در رابطه با تأثیر پژوهش‌های انجام گرفته 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 منتشر شده در سطح جهان، نیاز به ارزیابی و روش‌های نوین سنجش کیفیت مقالات پژوهشی در حال افزایش است (Abrishami & Aliakbary, 2019). براین اساس، سنجش‌های مختلفی به‌منظور سنجش و ارزیابی تولیدات علمی به جامعه علمی معرفی شده که هر کدام، مزایا و معایب خاص خود را دارد و هر روزه برای تکمیل آنها سنجش‌های 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). دگرسنجی 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، به‌دنبال شناسایی اثرگذاری پژوهش‌های علمی بر فناوری بوده‌اند. بر این اساس، پایگاه سایول^۲، شاخص جدیدی را مطرح کرده که براساس آن، میزان کاربردی بودن پژوهش‌ها را رصد 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 عمدتاً مبتنی بر گذشته است، پیش‌بینی آن نیز از حوزه‌های جذاب و کاربردی در این زمینه می‌تواند باشد. این پیش‌بینی در سطوح مختلف و با رویکردها و شاخص‌های مختلفی قابل انجام است. با توجه به اهمیت پیگیری تأثیرات مختلف بروندهای علمی و تعیین ارتباط بین آنها مطالعه حاضر قصد دارد رابطه هر یک از متغیرهای مختلف بر همدیگر را مورد سنجش قرار داده و نیز بررسی کند که کدام‌یک از الگوریتم‌های ماشین می‌توانند اثرگذاری علمی، اجتماعی و اقتصادی بروندهای علمی را پیش‌بینی کنند. به این منظور، بروندهای حوزه زیست‌فناوری^۳ ایران که در پایگاه اسکوپوس^۴ در بازه ۲۰۰۳-۲۰۲۴ نمایه شده‌اند مورد مطالعه قرار گرفته است. در واقع، پرسش اساسی این پژوهش آن است که کدام‌یک از الگوریتم‌های ماشین در مقایسه با یکدیگر می‌توانند اثرگذاری علمی، اجتماعی و اقتصادی پژوهش‌های حوزه زیست‌فناوری ایران را بهتر پیش‌بینی کنند؟

1. Impact

2. Scival

3. Biotechnology

4. Scopus

پرسش‌های پژوهش

۱. وضعیت بروندهای حوزه زیست‌فناوری ایران براساس هر کدام از شاخص‌های اثرگذاری علمی، اجتماعی و اقتصادی چگونه است؟
۲. آیا بین تعداد بروندها 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. کدام‌یک از الگوریتم‌های ماشین در مقایسه با یکدیگر می‌توانند اثرگذاری علمی، اجتماعی و اقتصادی پژوهش‌ها را بهتر پیش‌بینی کنند؟

چارچوب نظری

ارزیابی پژوهش

ارزیابی پژوهش، مجموعه‌ای از مفاهیم و روش‌هاست برای تعیین اینکه آیا برتری در این زمینه، حاصل شده و تمرکز آن بر «کیفیت» و «تأثیر» است. چگونگی درک و سنجش تعالی، نحوه تصمیم‌گیری پژوهشگران را شکل می‌دهد و به نوبه خود، انواع دانشی تولید می‌شود که به‌طور بالقوه به نتایج سیاسی، اقتصادی یا اجتماعی تبدیل می‌شود. ارزیابی پژوهش به‌عنوان یک فعالیت فنی یا عملیاتی در نظر گرفته می‌شود که برای به تصویر کشیدن عناصر عینی فرآیند پژوهش، طراحی و پیاده‌شده 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).



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

امروزه مجموعه متنوعی از شاخص‌ها به‌منظور ارزیابی کیفیت و اثرگذاری پژوهش‌ها، از معیارهای سنتی تا جدیدترین معیارهای جدید و جایگزین به‌کار گرفته می‌شود. کتاب‌سنجی یکی از این حوزه‌های دیرینه‌ای است که شاخص‌های مبتنی بر استاندارد را برای سنجش پژوهش‌های علمی به خدمت می‌گیرد. در تحلیل‌های استنادی، سنجش کیفیت مقاله بر پایه استناد اتفاق می‌افتد. اگرچه استناد، سنجح علمی است ولی عدد مطلق نمی‌تواند گویای کیفیت باشد. به همین منظور، استنادها به‌هنگار می‌شوند تا قابل تعمیم به جامعه مورد بررسی باشند. عموماً به مقاله‌های پراستناد 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، با محدودیت‌هایی چون وابستگی زمانی، وابستگی به پایگاه‌های گران قیمت و با محدودیت دسترسی همراه است (Guthrie et al. 2013). گام‌های روش‌شناختی در مطالعات ارزیابی پژوهش از اهمیت بالایی برخوردار است. آینوس این مراحل را این چنین شرح می‌دهد: فرآیند ارزشیابی 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. آینوس 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 بعد به چند بعد، از معیارهای غیرساختارمند به معیارهای ساخت‌یافته رخ داده که در شکل شماره ۲ به نمایش درآمده است.



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

استنادها به طور ضمنی، قضاوت جامعه درباره اهمیت مقاله را رمزگذاری می‌کنند و 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 درک گذشته و حال تمرکز دارند، این سؤال را باز می‌گذارند که آیا می‌توان تأثیر علمی را در آینده پیش‌بینی کرد. این نتایج را می‌توان با استفاده از تکنیک‌های غیرخطی به خوبی انجام داد. به ویژه، 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 (Weih & Etzioni, 2017). در عین حال، به منظور 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 پیش‌بینی‌کننده با استفاده از الگوریتم‌های یادگیری ماشین

1 . Hirsch Index

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

۱. درخت تصمیم^۱

درختان تصمیم یکی از محبوب‌ترین الگوریتم‌های یادگیری ماشینی با توجه به درک و سادگی آنها هستند (Wu et al. 2008). از درخت تصمیم به‌عنوان 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 شی‌م‌جهز 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 نظارت شده 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 پیش‌بینی‌شده و مدل‌سازی آن‌ها در برابر متغیرهای ورودی چندگانه وجود دارد. این روشی برای ارزیابی و مدل‌سازی داده است که روابط خطی را بین متغیرهای وابسته و مستقل برقرار می‌کند. بنابراین 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 تقویت شده نامیده می‌شود (Piryonesi & El-Diraby, 2020; Hastie et al. 2009).

۵. قانون k-نزدیک‌ترین همسایه^۶

قانون k-نزدیک‌ترین همسایه نیز از قدیمی‌ترین و ساده‌ترین روش‌ها برای طبقه‌بندی الگوهاست. با این وجود، اغلب نتایج رقابتی را به همراه دارد و در حوزه‌های خاصی، هنگامی که هوشمندانه با دانش قبلی ترکیب می‌شود، به‌طور قابل‌توجهی 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 به‌شدت به شاخص فاصله مورد استفاده برای شناسایی نزدیک‌ترین همسایگان بستگی دارد. در الگو کی-نزدیک‌ترین همسایه برای طبقه‌بندی آماری و رگرسیون، در هر دو حالت کی شامل نزدیک‌ترین مثال آموزشی در فضای داده‌ای می‌باشد و خروجی آن بسته به نوع مورد استفاده در

¹. Decision Tree

². random forests

³. Regression

⁴. Linear Regression

⁵. Gradient boosting

⁶. k-nearest neighbors' algorithm

طبقه‌بندی و رگرسیون متغیر است. در حالت طبقه‌بندی با توجه به مقدار مشخص شده برای کی، 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 براساس فاصله است نرمال‌سازی داده‌ها می‌تواند به بهبود عملکرد آن کمک کند (Weinberger & Saul, 2009 Hastie & Tibshirani, 1995).

پیشینه پژوهش

به‌منظور 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 دگرسنجی در پایگاه پلام‌ایکس پرداختند. یافته‌های حاصل از بررسی رابطه همبستگی و رگرسیون چندگانه بین تعداد استنادات و نمرات دگرسنجی نشان داد که رابطه قوی بین استنادات پلام‌ایکس و تعداد استنادات اسکوپوس برقرار است. همچنین بین ذکر و یادداشت پلام ایکس مشاهدات پلام‌ایکس با تعداد استنادات دریافتی در اسکوپوس رابطه معناداری وجود دارد. اما بین کاربرد پلام‌ایکس و شبکه‌های اجتماعی پلام‌ایکس رابطه‌ای وجود ندارد.

پژوهش بیرانوند و همکاران (۱۴۰۱) به بررسی امکان پیش‌بینی تعداد استنادات دریافتی تولیدات علمی حوزه وب‌معنایی از طریق شاخص‌های سایت-اسکور، اس‌ان‌آی‌پی و اس‌جی‌آر نشریات این حوزه پرداخت. نتایج آزمون ضریب همبستگی پیرسون و رگرسیون خطی چندگانه نشان داد که همبستگی بین تعداد استنادات با شاخص اس‌ان‌آی‌پی وجود ندارد. همچنین بین تعداد استنادات با اس‌جی‌آر و تعداد استنادات با سایت‌اسکور، رابطه معناداری وجود ندارد. هیچ‌یک از شاخص‌های سه‌گانه سایت‌اسکور، 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 داور در مجلات علمی بود تا بتوان در فرایند کنترل کیفیت مقالات علمی، میزان استناد به آن در آینده را پیش‌بینی نمود. در این پژوهش، ۳۰۰ مقاله حوزه شیمی بررسی شد. نتایج نشان داد که شاخص «چندنویسندگی و هم‌تألیفی» قوی‌ترین متغیر پیش‌بینی‌کننده استناد است که به‌صورت مثبت و معنادار میزان استناد را پیش‌بینی می‌کند. شاخص‌های «طول مقاله»، «تعداد منابع» و «شاخص اچ نویسنده» متغیرهای دیگری بودند که توانستند میزان استناد مقالات را به‌نحو 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 نشریه وب‌آو ساینس تالیف 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 (دگرسنجه) در پیش‌بینی تأثیر آتی مقالات براساس تعداد استنادها استفاده کردند. مبنای این بررسی، ۷۵۸۸ مقاله از ۱۰ مجله علوم رایانه بود. برای ساخت فضای ویژه برای پیش‌بینی، ۱۴ شاخص دگرسنجی 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 براساس 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 براساس عملکرد، جنگل تصادفی نسبت به دیگر طبقه‌بندی‌کننده‌ها، دگرسنجه‌ها می‌تواند استنادهای آینده را پیش‌بینی کند و مفیدترین نشانه‌های دگرسنجی، 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 دگرسنجی را به‌منظور تعیین میزان مقایسه و ارتباط آنها با یکدیگر بررسی کردند. نمرات دگرسنجی با تعداد استناد مقالات مرتبط با رشته علوم زیستی، زمین‌شناسی و محیط‌زیست، 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 دگرسنجی مقالات با اس.جی.آر. مجلات مقایسه شد. در نهایت، 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 دگرسنجی نشان داد، در حالی که برای نمره دگرسنجی و اس.جی.آر. در زمینه مذکور، چنین روندی قابل مشاهده نیست. تاریخ و باستان‌شناسی، همبستگی قوی بین دگرسنجی و نمرات استناد را به استثنای مقالات سال ۲۰۱۶ نشان می‌دهد و تا حدودی روند مشابهی برای امتیاز دگرسنجی و اس.جی.آر. انتشارات مشاهده شد. علوم زیستی همبستگی ضعیفی در هر دو متغیر نشان می‌دهند، در حالی که حوزه مطالعات اجتماعی عمدتاً برای هر دو مجموعه متغیر، ارتباط منفی نشان می‌دهند. بنابراین، بجز مقوله مطالعات اجتماعی، سه دسته دیگر عمدتاً همبستگی مثبتی بین دگرسنجی و امتیاز استناد نشریات و همچنین، تا حدی، برای نمره دگرسنجی و اس.جی.آر وجود دارد (Ayoub et al. 2023).

مطالعه آلوهای و همکاران با هدف بررسی عوامل و بخش‌های مؤثر بر تعداد استناد یک مقاله علمی در زمینه شنوایی سنجی انجام شد. این مطالعه، راه‌حل جدیدی را پیشنهاد داده و از یادگیری ماشین و پردازش زبان طبیعی برای پردازش متن انگلیسی استفاده نمود. الگوریتم‌های مختلفی مانند رگرسیون خطی، درخت تصمیم تقویت شده، 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 (Alohal et al. 2022).

در یک پایان‌نامه نیز داده‌های اسکوپوس با هدف تحلیل عملکرد متغیرهای مرتبط با مقاله، مجله و نویسنده به‌عنوان شاخص‌های تأثیر مقالات حوزه بازاریابی و اینکه چگونه می‌توانند مقالات پراستناد 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 هم‌نویسندگی 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، مجله و نویسنده در مقایسه با تنها یک نوع مؤلفه در پیش‌بینی مقالات پراستناد 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 را 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 منتشر شده و استنادات آن‌ها، متمایز کردن مشارکت چند نویسنده همکار در یک مقاله و غیره پشتیبانی می‌کند. نتایج تجربی نشان داد که رویکرد پیشنهادی به طور قابل توجهی بهتر از رقبای پیشرفته عمل می‌کند (Zhang & Wu, 2020).

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

ابریشمی و علی اکبری در مطالعه خود، روش جدیدی را به‌منظور پیش‌بینی استنادهای بلندمدت یک مقاله براساس 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 براساس الگوی توالی استنادها از سال‌های اولیه انتشار مقاله استفاده کردند. ارزیابی‌های جامع آنها نشان داد که روش پیشنهادی با توجه به دقت و توانایی پیش‌بینی استنادات مقالات پراستناد، بهتر از روش‌های پیشرفته پیش‌بینی تعداد استناد است (Abrishami & Aliakbary, 2019).

پژوهشگر دیگری، قدرت نسبی تعداد استنادهای کوتاه مدت، معیارهای کتاب‌سنجی مانند عوامل تأثیر مجلات و رتبه‌بندی مجلات را از نظر پیش‌بینی استنادهای بلندمدت بررسی کرد. وی با استفاده از مجموعه‌ای از مقالات منتشر شده در شصت مجله اقتصادی متوجه شد که استنادهای دریافتی در بازه‌های کوتاه مدت (بین ۱ تا ۲ سال پس از انتشار) در مقایسه با مواردی مانند تأثیر مجلات، پیش‌بینی‌کننده‌های قوی‌تری برای تعداد استنادات بلندمدت یا سایر رتبه‌بندی‌های مجلات هستند. این مقاله بر مقایسه سهم نسبی استنادهای کوتاه مدت، معیارهای کیفیت مجلات مانند عوامل تأثیر مجله و امتیازات رتبه‌بندی مجله و ویژگی‌های مقاله تأکید داشت. از دید این پژوهشگر، این واقعیت که تعداد استنادهای کوتاه‌مدت نسبت به متغیرهای شاخص مجله، پیش‌بینی‌کننده بهتری برای استنادهای بلندمدت ارائه می‌کند، یک نتیجه واقعاً منحصر به فرد است (Kosteas, 2018).

تیمیلینا و همکاران (۲۰۱۶) 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 به طور 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 پیش‌بینی‌کننده 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 به منظور پیش‌بینی تعداد استنادات در حوزه فیزیک استفاده کردند. تحلیل‌ها نشان داد که هر دو پیش‌بینی‌کننده (یعنی ضریب تأثیر و استنادهای اولیه) به پیش‌بینی دقیق تأثیر استناد درازمدت کمک می‌کنند (Stegehuis et al. 2015).

یو و همکاران (۲۰۱۴) از چهار دسته از ویژگی‌ها، از جمله مقالات، نویسندگان، استنادها و مجلات برای پیش‌بینی استنادهای آینده یک مقاله بر اساس تحلیل رگرسیون گام به گام 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 به منظور پیش‌بینی تأثیرات آتی هر مقاله ارائه کرد. ویژگی‌های پیش‌بینی‌کننده براساس 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 پیش‌بینی‌کننده‌ترین الگوریتم بود، به طوری که 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).

اکلا و همکارانش در پژوهش خود از دگرسججه‌ها به منظور 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 امر هستند. ایشان دریافتند که خوانندگان مندلی مهم‌ترین عامل در پیش‌بینی استنادهای اولیه بوده و به دنبال آن، عوامل دیگری مانند وضعیت علمی خوانندگان (به‌عنوان مثال، دانشجوی، فوق دکترا، استاد)، دنبال‌کنندگان در توئیتر، طول پست آنلاین، تعداد نویسنده و تعداد ذکر شدن در توئیتر، ویکی‌پدیا و در کشورهای مختلف (Akella et al. 2009).

بولان و همکاران (۲۰۰۹) تحلیل مؤلفه اصلی رتبه‌های تولید شده توسط ۳۹ معیار تأثیر علمی موجود و پیشنهادی که براساس داده‌های استناد و گزارش استفاده، محاسبه شده، انجام دادند. نتایج نشان داد که تأثیر علمی یک سازه چندبعدی است که نمی‌توان آن را به طور 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 مجلات ایجاد شده 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 بر مقالات، متمرکز شده و گاهی نیز مجلات را هدف قرار داده‌اند. عمده تلاش‌ها نیز بر تشخیص رابطه

شاخص‌های استنادی سنتی و دگرسنگه‌ها 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 بروندهای علمی حوزه زیست‌فناوری ایران در یک بازه ۲۲ ساله را بر هم بررسی نماید و از الگوریتم‌های متفاوتی برای پیش‌بینی تأثیرات آنها استفاده کند.

روش‌شناسی پژوهش

پژوهش حاضر از لحاظ هدف، کاربردی و از نظر روش، توصیفی بوده و با رویکرد علم‌سنجی انجام شده است و به‌دنبال بررسی همکاری علمی و نیز تأثیرگذاری علمی، اجتماعی و اقتصادی آثار علمی ایران در حوزه زیست‌فناوری است و اینکه کدام‌یک از الگوریتم‌های یادگیری ماشین، پیش‌بینی‌کننده بهتری برای سنجش اثرگذاری بروندهای علمی در ابعاد مختلف هستند. جامعه پژوهش، بروندهای 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. به‌منظور 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. درواقع، 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 بدست آمده را با میانگین‌ها و استانداردهای جهانی فراهم می‌کند. به این ترتیب، با استفاده از سایول می‌توان عملکرد پژوهشی یک پژوهشگر، سازمان، کشور، منطقه، مجله، 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 پیش‌بینی‌کننده تأثیرات علمی، اقتصادی و اجتماعی به شرح زیر بودند.

جدول ۱. متغیرهای مورد مطالعه

عنوان متغیر
حجم برونداد علمی
همکاری فقط دانشگاهی (%)
تأثیر همکاری فقط دانشگاهی
تأثیر همکاری بین‌المللی
همکاری دانشگاهی و دولتی (%)
حجم استنادها
استناد به ازای برونداد
تأثیر استناد وزنی حوزه
بروندها در ۱۰٪ درصد برتر مجله توسط درصد CiteScore (%)
بروندها در ۱۰٪ درصد استنادهای برتر (%)
تعداد استنادات ثبت اختراع
استنادهای حق ثبت اختراع به ازای هر خروجی علمی
خروجی علمی استناد شده توسط ثبت اختراعات (%)
تعداد اختراعات استنادکننده به مقالات
تعداد بازدهیها
برونداد در ۱۰٪ درصد بازدهیهای برتر (%)
بازدید به ازای هر خروجی
تأثیر بازدید وزنی حوزه

¹ . InCites

جدول ۲. مؤلفه‌ها و شاخص‌های مرتبط به آنها به‌عنوان پیش‌بینی‌کننده تأثیر

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

شایان ذکر 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^۱ به‌منظور 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 تقویت‌گرادیان نیز به‌عنوان مدل‌های پیش‌بینی‌کننده، مورد استفاده و ارزیابی قرار گرفتند. به‌منظور 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 بایستی 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 نبود و مقداری برای آن گزارش نشده بود که برای انجام تحلیل‌ها بایستی 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. در ضمن، فونت داده‌های فارسی، قابل استفاده نبوده و تحلیل‌ها با استفاده از داده‌های انگلیسی انجام شد. در گام بعدی، مدل‌های یادگیری ماشین مختلفی بر روی داده‌ها مدل‌سازی و اجرا شد. مدل‌سازی در نرم‌افزار پایتون به گونه‌ای انجام شده که همه متغیرهای موجود در مجموعه داده، یک بار به‌عنوان مقدار هدف فرض شده‌اند و مدلی ساخته شده که بتواند براساس 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 است و به راحتی برای مشکل طبقه‌بندی دوحالتی و چندحالتی مناسب است.

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN}$$

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 به‌کار رفته برای پیش‌بینی آن پارامتر خاص، اصلاً مناسب نیست.

^۱ . Accuracy

یافته‌های پژوهش

پاسخ به پرسش اول پژوهش: وضعیت بروندهای حوزه زیست‌فناوری ایران براساس هر کدام یک از شاخص‌های اثرگذاری علمی، اثرگذاری اجتماعی و اثرگذاری اقتصادی چگونه است؟

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


ازداینده ویدئوایش نشانه

جدول ۳. وضعیت برندهای علمی ایران در حوزه زیست فناوری براساس داده‌های پایگاه سایول در بازه ۲۰۰۳ تا 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
بروناد علمی	۳۵	۴۵	۶۸	۱۰۳	۱۷۷	۲۸۴	۳۵۹	۵۸۹	۷۷۷	۹۴۶	۱۲۳۳	۱۷۳۳	۲۷۶	۳۶۵	۹۵۳	۱۱۳۹	۱۱۳۳	۱۱۶۹	۱۱۹۰	۱۲۲۹	۱۲۶۲	۱۲۷۴
همکاری فقط دانشگاهی (%)	۷۱٫۴	۶۴٫۴	۶۰٫۳	۷۶٫۷	۷۰٫۱	۷۷٫۱	۷۵٫۸	۷۹٫۳	۸۲٫۵	۷۶٫۵	۷۹٫۳	۸۰٫۹	۸۳٫۵	۸۲٫۷	۸۲٫۶	۸۲٫۶	۸۲٫۸	۸۴٫۵	۸۲٫۷	۸۲٫۲	۸۳٫۲	۸۳٫۲
تأثیر همکاری فقط دانشگاهی	۳۱٫۸	۴۰٫۹	۳۴٫۲	۳۹٫۶	۳۷٫۱	۳۷٫۶	۳۰٫۹	۲۲	۱۹٫۱	۳۰٫۷	۲۸٫۲	۲۰٫۷	۱۹	۲۶٫۳	۲۷	۲۵٫۹	۲۳٫۸	۱۸٫۴	۱۱٫۶	۶٫۷	۲	۰٫۱
تأثیر همکاری بین‌المللی	۲۶٫۵	۵۳٫۱	۴۶٫۵	۴۱٫۴	۳۴٫۵	۳۰٫۵	۲۶٫۹	۲۲٫۷	۲۹٫۶	۶۴٫۵	۲۶٫۸	۳۳	۲۹٫۶	۴۵٫۱	۴۲٫۵	۴۲٫۴	۳۴٫۹	۲۹٫۶	۲۰٫۵	۱۰٫۸	۳٫۱	۰٫۲
همکاری دانشگاهی و دولتی (%)	۱۴٫۳	۲۰	۱۹٫۱	۱۲٫۶	۱۵٫۶	۱۲٫۲	۱۵٫۳	۹٫۸	۸	۱۳٫۶	۱۲٫۵	۱۰	۹٫۷	۹٫۲	۱۰٫۴	۱۰٫۵	۱۰٫۷	۱۰٫۱	۱۱٫۵	۱۰٫۲	۱۰٫۷	۱۴٫۹
حجم استنادها	۱۱۱۱	۱۶۸۶	۲۴۶۱	۴۱۷۱	۵۱۷۳	۷۴۵۸	۷۸۷۳	۱۳۱۶	۱۴۹۹	۱۳۳۶	۱۴۲۶	۱۶۷۴	۱۴۸۷	۲۵۱۱	۲۲۵۴	۳۹۸۱	۲۵۲۷	۲۱۷۹	۱۴۷۰	۸۴۸۱	۲۵۵۶	۲۵۵۶
استناد به ازای بروناد	۳۱٫۷	۳۷٫۵	۳۶٫۳	۳۵٫۲	۳۶٫۵	۳۶٫۳	۳۱٫۹	۲۲٫۴	۲۰٫۱	۲۸٫۶	۲۶٫۱	۲۰٫۱	۱۹٫۲	۲۶	۲۵٫۸	۲۶٫۴	۲۲٫۳	۱۸٫۶	۱۲٫۴	۶٫۹	۲	۰٫۱
تأثیر استناد وزنی حوزه	۰٫۵۵	۰٫۵۹	۰٫۵۸	۰٫۷۳	۰٫۷۳	۰٫۶۳	۰٫۵۵	۰٫۵۵	۰٫۵۵	۰٫۷۲	۰٫۸۸	۰٫۹	۰٫۷۲	۰٫۹۴	۰٫۹۳	۱٫۱۱	۱٫۰۴	۱٫۰۷	۱٫۱	۱٫۱۸	۱٫۲۴	۰٫۲۴
برونادها در ۱۰٪ درصد برتر مجله CiteScore	۱۲٫۱	۷٫۷	۴٫۶	۱۱٫۱	۸٫۱	۶	۵٫۴	۲٫۷	۲٫۷	۴٫۲	۸	۶٫۳	۵٫۱	۱۲٫۲	۹٫۵	۱۱٫۸	۹	۹٫۲	۸٫۱	۴٫۹	۵٫۸	۱۱
برونادها در ۱۰٪ درصد استنادهای برتر (%)	۱۱٫۴	۸٫۹	۱۳٫۲	۱۳٫۶	۱۳٫۶	۱۱٫۶	۸٫۶	۸	۸٫۸	۱۳٫۱	۱۲٫۸	۱۱٫۳	۱۲	۱۷٫۷	۱۸٫۳	۲۱٫۲	۲۱٫۶	۲۲٫۳	۲۲٫۴	۲۲٫۹	۲۰٫۵	-
تعداد استنادات ثبت اختراع	۳۳	۳۳	۶۹	۱۷۰	۹۴	۹۰	۷۷	۱۹۵	۱۴۸	۷۴	۲۵۵	۱۵۳	۶۱	۲۵۰	۱۱۲	۷۹	۴۲	۳۶	۳۵	۳	-	-
استنادهای حق ثبت اختراع به ازای هر خروجی	۹۴۲٫۹	۷۳۲٫۳	۱۰۱۴٫۷	۱۶۵۰٫۵	۶۳۹٫۵	۳۱۶٫۹	۲۱۴٫۵	۳۳۱٫۱	۱۹۸٫۱	۱۵۹٫۵	۴۶۷	۲۰۸٫۷	۷۸٫۶	۲۵۹٫۱	۱۱۷٫۵	۷۰	۳۷٫۱	۳۰٫۸	۲۱	۲٫۴	-	-
خروجی علمی استناد شده توسط ثبت اختراعات	۳۱٫۴	۲۰	۱۷٫۶	۱۴٫۶	۱۸٫۴	۱۰٫۶	۹٫۲	۸٫۱	۵٫۸	۸	۸٫۲	۶٫۷	۴٫۸	۶٫۷	۶٫۱	۴٫۷	۲٫۶	۱٫۹	۱٫۸	۰٫۲	-	-
تعداد اختراعات	۳۳	۳۳	۶۹	۱۷۰	۹۴	۹۰	۷۷	۱۹۵	۱۴۸	۷۴	۲۵۴	۱۵۳	۶۱	۲۴۸	۱۱۰	۷۷	۴۲	۳۶	۳۵	۳	-	-
تعداد بازبیدها	۱۷۳۶	۲۸۰۳	۴۰۱۰	۶۴۵۷	۱۰۰۲	۱۹۶۷	۲۵۸۷	۴۴۸۱	۵۸۰۵	۳۸۱۷	۴۳۲۸	۴۷۴۵	۴۹۵۷	۶۶۴۰	۶۶۴۰	۷۵۶۶	۷۰۵۵	۵۷۲۱	۵۱۳۰	۴۷۰۶	۲۵۲۷	۵۲۲
بروناد در ۱۰٪ درصد بازبیدهای برتر (%)	۶۵٫۷	۶۴٫۴	۷۲٫۱	۷۰٫۹	۵۵٫۸	۵۳٫۵	۵۱٫۴	۵۱٫۳	۵۰٫۱	۵۱٫۳	۵۱٫۳	۴۰٫۵	۳۹٫۶	۴۸٫۱	۴۸٫۱	۴۲٫۴	۳۷٫۶	۳۷٫۶	۳۶٫۱	۳۶٫۱	۳۳٫۹	۱۳٫۵
بازدید به ازای هر خروجی	۳۹٫۶	۶۲٫۳	۵۹	۶۲٫۷	۶۸٫۲	۶۹٫۳	۷۳٫۱	۷۶٫۱	۷۷٫۷	۸۲٫۳	۷۹٫۳	۶۴٫۷	۶۲٫۹	۶۸٫۸	۶۶٫۷	۶۷	۶۲٫۳	۴۸٫۹	۴۳٫۱	۳۸٫۳	۲۸	۷٫۲
تأثیر بازدید وزنی حوزه	-	۱٫۷۴	۱٫۵۱	۱٫۳۱	۱٫۵۱	۱٫۶۴	۲٫۱۸	۲٫۲۷	۱٫۶	۱٫۶۶	۱٫۴۷	۱٫۳۸	۱٫۲۳	۱٫۵۳	۱٫۵۶	۱٫۷۲	۱٫۸۱	۱٫۷	۱٫۷۷	۱٫۶۷	۱٫۶۹	-

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

نمودار زیر، میزان همبستگی بین حجم بروندهای علمی، همکاری، تأثیر علمی، اقتصادی و اجتماعی آنها را به تصویر می‌کشد.



نمودار ۱. نتایج آزمون همبستگی بین حجم بروندهای علمی، همکاری، تأثیر علمی، تأثیر اقتصادی و اجتماعی آنها داده‌های نمودار شماره ۱ روشن می‌کند که هر کدام از متغیرها با متغیرهای دیگر چه رابطه‌ای با هم دارند. عدد گزارش شده هر چقدر به +۱ و یا -۱ نزدیک‌تر باشد نشان می‌دهد رابطه بیشتری بین دو متغیر وجود دارد و هر چقدر به صفر نزدیک‌تر باشد نشان می‌دهد که آن دو متغیر رابطه خطی با یکدیگر ندارند. اعداد مثبت نشان می‌دهند که اگر یکی از متغیرها افزایش یابد متغیر دیگری نیز افزایش پیدا می‌کند. اعداد منفی نشان می‌دهند که اگر یکی از متغیرها افزایش پیدا کند متغیر دیگر کاهش می‌یابد. نکته قابل ذکر و بدیهی آن است که هر متغیر با خودش همبستگی کامل یعنی +۱ دارد. به همین دلیل در قطر ماتریس، تمام اعداد +۱ هستند.

پیش‌بینی تأثیر‌گذاری پژوهش‌های علمی حوزه زیست‌فناوری با استفاده از الگوریتم‌های یادگیری ماشین **زودآیند ویرایش نشده**

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 باز دیده‌ها و تأثیر باز دید وزنی حوزه رابطه مثبت و معنی‌داری داشته است. همکاری بین‌المللی با حجم استنادها، تأثیر استناد وزنی حوزه، بروندها در ۱۰٪ درصد برتر مجلات، 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 دید به ازای هر خروجی و تأثیر باز دید 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، بروندها در ۱۰٪ درصد برتر مجلات، بروندها در ۱۰٪ درصد استنادهای برتر، تعداد استنادات ثبت اختراع، خروجی علمی استناد شده توسط ثبت اختراعات، تعداد اختراعات، تعداد باز دیده‌ها و تأثیر باز دید وزنی حوزه رابطه مثبت و معنی‌داری داشته است.

پاسخ به پرسش سوم پژوهش: کدام یک از شاخص‌های اثرگذاری علمی، اجتماعی و اقتصادی با همدیگر ارتباط دارند؟

در مقوله اثرگذاری علمی بروندهای مورد مطالعه، حجم استنادها با شاخص‌های تعداد استنادات ثبت اختراع، تعداد اختراعات، تعداد باز دیده‌ها، باز دید به ازای هر خروجی و تأثیر باز دید وزنی حوزه، رابطه مثبت و معنی‌داری داشته است. در حوزه اثرگذاری 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 دید به ازای هر خروجی و تأثیر باز دید وزنی حوزه، رابطه مثبت و معنی‌داری داشته است. استنادات ثبت اختراع به ازای هر برونداد با شاخص‌های استناد به ازای هر برونداد، باز دید به ازای هر خروجی و تأثیر باز دید 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 باز دیده‌های برتر و باز دید 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 اثرگذاری علمی، اجتماعی و اقتصادی را پیش‌بینی کنند؟

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

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
	اثر علمی	۰,۷۸	۰,۱۳

مدل	شاخص هدف	نمره صحت مدل	نمره انحراف معیار مدل
رگرسیون خطی چندمتغیره	اثر فناورانه	۰,۵۲	۰,۲۸
	اثر اجتماعی	۰,۶۸	۰,۱۵
	اثر علمی	-۰,۷۰	۰,۹۶
تقویت گرادیان	اثر فناورانه	۰,۹۳	۰,۰۴
	اثر اجتماعی	۰,۵۱	۰,۵۹

در جدول شماره ۴، شاخص هدف، نمره صحت و نمره انحراف معیار ۴ مدل پیاده شده در این مطالعه، درج شده است. لازم به توضیح است که هر چقدر نمره صحت اجرای مدل بالاتر و نمره انحراف معیار حاصل شده پایین تر باشد، قدرت پیش‌بینی‌کنندگی الگوی پیاده شده بیشتر خواهد بود. اعداد منفی، بیانگر دقت بسیار پایین بوده و نشان می‌دهد مدل به کار رفته به منظور پیش‌بینی یک متغیر خاص، مناسب نیست. براساس نتایج حاصل شده، رگرسیون خطی چندمتغیره با نمره صحت بالاتر و نمره انحراف معیار پایین تر، بهتر توانسته است میزان اثرگذاری علمی، فناورانه و اجتماعی بروندهای علمی ایران در حوزه زیست‌فناوری را پیش‌بینی نماید.

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 همدیگر و نیز ارزیابی الگوریتم‌های ماشین که بتوانند اثرگذاری علمی، اجتماعی و اقتصادی بروندهای علمی را پیش‌بینی کنند، انجام گرفت. به این منظور، بروندهای 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 بروندهای علمی ایران در این حوزه در بازه زمانی ۲۰۰۳ تا ۲۰۲۳، سیر صعودی داشته و افزایش ۳۶ برابری را تجربه کرده است که پیشرفت فوق‌العاده بالایی 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 بعد زمان و انجام مطالعه جداگانه‌ای خواهد بود.

براساس داده‌های حاصل شده، حجم بروندهای علمی ایران در حوزه زیست‌فناوری بین 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 برقرار بوده است. از این نظر می‌توان تا حدی عنوان کرد که در کنار رشد کمی، شاخص‌های سنتی استناد و نیز میزان رؤیت‌پذیری 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 وجود انگیزه پژوهشگران برای تجاری‌سازی یافته‌های خود را از علل این امر برشمرد.

رابطه بین همکاری بین‌المللی با شاخص‌هایی از جمله حجم استنادها، تأثیر استناد وزنی حوزه، بروندها در ۱۰٪ درصد برتر مقالات، تعداد استنادات ثبت اختراع، استنادهای حق ثبت اختراع به ازای هر خروجی علمی، خروجی علمی استناد شده توسط ثبت اختراعات، تعداد اختراعات، تعداد بازدیدها، بروندها 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 بعد 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

پیش‌بینی تأثیر‌گذاری پژوهش‌های علمی حوزه زیست‌فناوری با استفاده از الگوریتم‌های یادگیری ماشین **زودآیند ویرایش نشده**

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، برودادها در ۱۰٪ درصد برتر مجلات، برودادها 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 پراستناد، بهتر عمل می‌کند (Hansen, 2022). ایوب، امین و وانی در مطالعه خود دو مقوله استناد و نمره دگرسنجی مقالات رشته علوم زیستی، علوم زمین و محیط‌زیست، تاریخ و باستان‌شناسی را به‌منظور تعیین میزان مقایسه و ارتباط آنها با یکدیگر بررسی کردند و به این یافته رسیدند که همبستگی مثبتی بین دگرسنجی و امتیاز استناد و همچنین نمره دگرسنجی 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 دگرسنجی نشان داد که رابطه قوی بین استنادات پلام‌ایکس و تعداد استنادات اسکوپوس برقرار است.

در حوزه شاخص‌های مرتبط با تعامل بین برودادهای علمی با پروانه‌های ثبت اختراع نیز این نتیجه حاصل شد که تعداد استنادات ثبت اختراع به عنوان یکی از شاخص‌های معرف این نوع تأثیر، با مواردی از قبیل همکاری دانشگاهی، همکاری بین‌المللی، حجم استنادها، استناد به ازای بروداد، تأثیر استناد وزنی حوزه، تعداد بازدیدها، بروداد در ۱۰٪ درصد بازدیدهای برتر، بازدید به ازای هر خروجی و تأثیر بازدید وزنی حوزه، رابطه مثبت و معنی‌داری داشته است. درواقع، کاربردی شدن مقالات و پژوهش‌های حوزه زیست‌فناوری ایران زمینه‌ساز تحقق بسیاری از شرایط دیگر خواهد بود از جمله همکاری بین‌المللی، افزایش حجم استنادها و بهبود تعداد بازدیدها. در همین رابطه، بین استنادات ثبت اختراع به ازای هر بروداد با شاخص‌های استناد به ازای هر بروداد، بازدید به ازای هر خروجی و تأثیر بازدید وزنی حوزه، رابطه مثبت و معنی‌داری برقرار بوده است. همچنین تعداد اختراعات با مواردی مانند حجم استنادها، استناد به ازای بروداد، تعداد بازدیدها، بروداد در ۱۰٪ درصد بازدیدهای برتر و بازدید به ازای هر خروجی، رابطه مثبت و معنی‌داری برقرار نموده 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 دگرسنجی نیز این نتیجه به دست آمد که تعداد بازدیدها رابطه مثبت و معنی‌داری 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 این حوزه دارد. براساس 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 نمود.

یکی دیگر از پرسش‌هایی که این مطالعه درصدد پاسخ به آن بود این بود که کدام‌یک از الگوریتم‌های ماشین می‌تواند اثرگذاری علمی، اجتماعی و اقتصادی را دقیق‌تر پیش‌بینی نمایند. براساس نتایج به دست آمده، الگوی رگرسیون خطی چندمتغیره با نمره صحت بالاتر و نمره انحراف معیار پایین‌تر، بهتر توانست میزان اثرگذاری برودادهای علمی ایران در حوزه زیست‌فناوری را در ابعاد علمی، فناوری و اجتماعی پیش‌بینی نماید. الگوهر و همکاران نیز از چارچوب یادگیری ماشین برای آزمون توانایی دگرسنجی‌ها در پیش‌بینی تعداد استنادها استفاده کردند و نشان دادند از بین الگوهای درخت تصمیم، جنگل تصادفی و ماشین‌های بردار پشتیبانی، جنگل تصادفی نسبت به دیگر طبقه‌بندی‌کننده‌ها، بهتر می‌تواند استنادهای 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 پراستناد، 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 استنادهای آینده، ضرایب رگرسیون چندگانه برای پیش‌بینی توزیع استنادها مناسب است (Stegehuis et al. 2015).

پیشنهاد‌های اجرایی پژوهش

با توجه به یافته‌های حاصل از این مطالعه، موارد زیر قابل پیشنهاد است:

- ✓ نظر به اینکه مدل رگرسیون خطی چندمتغیره، 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.
- ✓ 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 نمایند.
- ✓ 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 بازدیدهایی که در فضای مجازی اتفاق می‌افتد و بر سایر شاخص‌های کیفیت و اثرگذاری علمی، مؤثر است 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 رؤیت‌پذیری 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 بکار 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 برون‌دادهای علمی: مطالعه موردی حوزه زیست‌فناوری ایران» با شماره ۱۴۰۲/ص/۱۰۴ است. بدینوسیله از مرکز تحقیقات سیاست علمی کشور به سبب حمایت‌های مادی و معنوی در رابطه با این طرح، صمیمانه سپاسگزارم.

پیش‌بینی تأثیرگذاری پژوهش‌های علمی حوزه زیست‌فناوری با استفاده از الگوریتم‌های یادگیری ماشین **زودآیند ویرایش نشده**

فهرست منابع

- ابراهیمی، س.، دهقان، م.، و جوکار، ع. (۱۳۹۶). بررسی شاخص‌های پیش‌بینی‌کننده تأثیرگذاری علمی برای افزایش استنادگیری 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 برون‌دادهای علمی: مطالعه موردی حوزه زیست‌فناوری ایران*. [گزارش طرح پژوهشی]. مرکز تحقیقات سیاست علمی کشور.
- آزادی احمدآبادی، ق. (۱۴۰۳). سطوح و شاخص‌های ارزیابی تأثیرات پژوهش براساس تحلیل نظام‌های ارزیابی. *ترویج علم*، (۱)، -.
<https://doi.org/10.22034/popsci.2024.424371.1306>
- آزادی احمدآبادی، ق.، عبدی، س.، و رضانی، ا. (۱۴۰۱). مطالعه تأثیرات علمی، اقتصادی و اجتماعی پژوهش‌های حوزه محیط‌زیست ایران. *محیط‌زیست و توسعه فرابخشی*، ۷(۷۸)، ۳۸-۵.
<https://doi.org/10.22034/envj.2023.351434.1217>
- باباگیری ساری، ا.، قهرمانی، م.، فتحی واجارگاه، ک.، و مؤتمنی، ع. (۱۴۰۰). ارائه الگوی ارزشیابی اثرات پژوهش‌های مدیریتی. *پژوهش‌های مدیریت ایران*، ۲۱(۱)، ۹۳-۱۱۹.
<https://dori.net/dor/20.1001.1.2322200.1396.21.1.4.6>
- بذرافشان، ا.، بیرانوند، ع.، و شجاعی فرد، ع. (۱۴۰۲). پیش‌بینی تعداد استنادات دریافتی حوزه فیزیک ذرات در اسکوپوس به کمک نمرات دگرسنجی پلام‌ایکس. *فصلنامه بازیابی دانش و نظام‌های معنایی*، (۱)، -.
<https://doi.org/10.22054/jks.2023.71392.155>
- بیرانوند، ع.، گلشنی، م.، و دلقندی، ف. (۱۴۰۱). بررسی تأثیر شاخص‌های سایت‌اسکور، اس‌ان‌آی‌پی و اس‌جی‌آر نشریات حوزه وب‌معنایی بر تعداد استنادات دریافتی مقالات. *فصلنامه بازیابی دانش و نظام‌های معنایی*، (۱)، -.
<https://doi.org/10.22054/jks.2022.67616.1501>
- نوروزی چاکلی، عبدالرضا (۱۴۰۲). *آشنایی با علم سنجی (مبانی، مفاهیم، روابط و ریشه‌ها)*. تهران: سازمان مطالعه و تدوین کتب علوم انسانی دانشگاه‌ها (سمت)، مرکز تحقیق و توسعه علوم انسانی؛ دانشگاه شاهد، مرکز چاپ و انتشارات.
<https://samt.ac.ir/fa/book/99/>
- Abrishami, A., & Aliakbary, S. (2019). Predicting citation counts based on deep neural network learning techniques. *Journal of Informetrics*, 13(2), 485-499.
<https://doi.org/10.48550/arXiv.1809.04365>
- Akella, A. P., Alhoori, H., Kondamudi, P. R., Freeman, C., & Zhou, H. (2021). Early indicators of scientific impact: Predicting citations with altmetrics. *Journal of Informetrics*, 15(2), 101128. <https://doi.org/10.1016/j.joi.2020.101128>
- Alchokr, R., Haider, R., Shakeel, Y., Leich, T., Saake, G., & Krüger, J. (2023). Forecasting Publication's Success Using Machine Learning [Conference presentation]. In *International Workshop on Bibliometric-Enhanced Information (BIR)*. CEUR-WS. org. <https://jacobkrueger.github.io/assets/papers/Alchokr2023ForecastingSuccess.pdf>
- Alohali, Y. A., Fayed, M. S., Mesallam, T., Abdelsamad, Y., Almuhawwas, F., & Hagr, A. (2022). A machine learning model to predict citation counts of scientific papers in otology field. *BioMed Research International*, 2022. <https://doi.org/10.1155/2022/2239152>
- Anninos, L. N. (2014). Research performance evaluation: Some critical thoughts on standard bibliometric indicators. *Studies in Higher Education*, 39, 1542-1561.
<https://doi.org/10.1080/03075079.2013.801429>

- Ayoub, A., Amin, R., & Wani, Z. A. (2023). Exploring the Impact of Altmetrics in Relation to Citation Count and SCImago Journal Rank (SJR). *Journal of Scientometric Research*, 12(3), 603-608. <https://doi.org/10.5530/jscires.12.3.058>
- Azadi Ahmadabadi, G., Abdi, S., & Ramezani, A. (2022). Studying the Scientific, Economic and Social Effects of Iranian Environmental Researches. *Environment and Interdisciplinary Development*, 7(78), 38-55. <https://doi.org/10.22034/envj.2023.351434.1217> [In Persian].
- Azadi Ahmadabadi, G. (2024). *Evaluation of the effects of scientific outputs: case study of Iran's biotechnology* [Research project report]. National Research Institute for Science Policy (NRISP). [In Persian].
- Azadi Ahmedabadi, G. [In Press]. Levels and indicators of evaluation of research impacts based on the analysis of evaluation systems. *Popularization of Science*. <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://dori.net/dor/20.1001.1.2322200.1396.21.1.4.6> [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*, (), -. <https://doi.org/10.22054/jks.2023.71392.155> [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*, (), -. <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. *arXiv preprint arXiv:2402.08640*. <https://doi.org/10.48550/arXiv.2402.08640>
- Guthrie, S., Wooding, S., Grant, J., Diepeveen, S., & Wamae, W. (2013). *Developing a research evaluation framework*. RAND Corporation, MG-1217-AAMC, 2013. As of February 20, 2024: <https://www.rand.org/pubs/monographs/MG1217.html>
- Hansen, I. S. (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., Hastie, T., Tibshirani, R., & Friedman, J. (2009). Boosting and additive trees. *The elements of statistical learning: data mining, inference, and prediction*, 337-387. <https://hastie.su.domains/Papers/ESLII.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(4), 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: DMAApps, DANTh, QIMIE, BDM, CDA, CloudSD, Gold Coast, QLD, Australia, April 14-17, 2013, Revised Selected Papers 17* (pp. 14-25). Springer Berlin Heidelberg. <https://dblp.org/rec/conf/pakdd/2013-w.html>
- Mihaela, P. A. U. N., Abigaela, B. I. L. B. I. I. E., Paul, B. U. Z. O. I. A. N. U., Anastasia, C. O. S. M. A., Catalina, E. N. E., Anne, H. R. I. S. C. U., ... & Eduard, M. I. L. E. A. (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., ... & 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/fa/book/99/> [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), 04019036. [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, August). 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)*, (pp. 1-10). <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*, 10(2). <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. (2019). 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>
- Wu, J., Liu, C., Cui, W., & Zhang, Y. (2019, November). Personalized Collaborative Filtering Recommendation Algorithm based on Linear Regression [Conference presentation]. In *2019 IEEE International Conference on Power Data Science (ICPDS)* (pp. 139-142). IEEE. <https://doi.org/10.18280/mmep.060307>
- Wu, X., Kumar, V., Ross Quinlan, J., Ghosh, J., Yang, Q., Motoda, H., ... & Steinberg, D. (2008). Top 10 algorithms in data mining. *Knowledge and information systems*, 14, 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, 1233-1252. <https://doi.org/10.1007/s1192-014-1279-6>
- 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. (2014). 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>