

Data Mining Methods for Quality Control of Research Data; Case Study of Iranian Scientific Database (GANJ)

Azadeh Fakhrzadeh*

PhD in Computer Image Processing; Assistant professor; Iranian Research Institute for Information Science and Technology (IranDoc); Tehran, Iran Email: Fakhrzadeh@mail.irandoc.ac.ir

Mohammad Javad Ershadi

PhD in Industrial Engineering; Associate Professor; Iranian Research Institute for Information Science and Technology (IranDoc); Tehran, Iran Email: Ershadi@mail.irandoc.ac.ir

Mohammad Mahdi Ershadi

MSc in Industrial Engineering; Amirkabir University of Technology; Tehran, Iran Email: Ershadi.mm1372@aut.ac.ir

**Iranian Journal of
Information
Processing and
Management**

Received: 20, Aug. 2020 Accepted: 15, May 2021

Abstract: Research information databases and search engines are one of the main resources used by researchers every day. To accurately retrieve information from these databases, data need to be stored correctly. Manual controlling of data quality is costly and time-consuming. Here we suggest data mining methods for controlling the quality of a research database. To this end, common errors that are seen in a database should be collected. Metadata of every record in addition to its error codes is saved in a dataset. Statistics and data mining methods are applied to this dataset and patterns of errors and their relationships are discovered. Here we considered Iran's scientific information database (Ganj) as a case study. Experts defined 59 errors. Intimate features of every record, such as its subject, authors' names and name of the university, with its error codes were saved in a dataset. The dataset containing 41021 records was formed. Statistics methods and association rules were applied to the dataset and the relationship between errors and their pattern of repetition were discovered. Based on our results, in average by considering 25% of errors in every subject, up to 80% of errors of all the records in a subject are covered. All the records were also clustered using K-means clustering. Although there was some similarity between records of different subjects, there was not seen any evident relationship between the pattern of repetition of the errors and the subject of records.

Keywords: Data Quality, Research Information Quality, Quality Control, Clustering

Iranian Research Institute
for Information Science and Technology
(IranDoc)

ISSN 2251-8223

eISSN 2251-8231

Indexed by SCOPUS, ISC, & LISTA

Vol. 38 | No. 3 | pp. 927-944

Spring 2023

<https://doi.org/10.22034/jipm.2023.698614>



* Corresponding Author

کاربست قوانین انجمنی و خوشبندی

در کنترل کیفیت داده‌های پژوهشی

مورد مطالعه: پایگاه اطلاعات علمی ایران (گنج)

آزاده فخرزاده

دکتری پردازش تصاویر کامپیوتری؛ استادیار؛
پژوهشگاه علوم و فناوری اطلاعات ایران (ایراندак)؛
تهران، ایران؛
پدیدآور رابط Fakhrzadeh@irandoc.ac.ir

محمدجواد ارشادی

دکتری مهندسی صنایع؛ دانشیار؛ پژوهشگاه علوم و
فناوری اطلاعات ایران (ایراندак)؛ تهران، ایران؛
Ershadi@irandoc.ac.ir

محمدمهدی ارشادی

کارشناسی ارشد مهندسی صنایع؛ دانشگاه صنعتی
امیرکبیر (پلی تکنیک)؛ تهران، ایران؛
Ershadi.mm1372@aut.ac.ir



نشریه علمی | دتبه بین‌المللی
پژوهشگاه علوم و فناوری اطلاعات ایران
(ایراندак)

شماره ۳۸ | سال ۱۴۰۲ | پژوهش نامه

۲۲۵۱-۸۲۳۳

شاپا (الکترونیکی) ۲۲۵۱-۸۲۳۱

نمایه در SCOPUS, ISC, و LISTA

jipm.irandoc.ir

دوره ۳۸ | شماره ۳ | صص ۹۲۷-۹۴۴

بهار ۱۴۰۲

<https://doi.org/10.22034/jipm.2023.698614>

مقاله برای اصلاح به مدت ۲۴ روز نزد پدیدآوران بوده است.

درباره: ۱۴۰۱/۰۲/۲۶ | پذیرش: ۱۴۰۰/۱۲/۰۲

چکیده: پایگاه‌های اطلاعات علمی و موتورهای جست‌وجو از ابزارهای اصلی کار پژوهشگران است. برای بازیابی دقیق و صحیح اطلاعات از این پایگاه‌ها نیاز است که اطلاعات با کیفیت مناسب و با کمترین خطای ذخیره شود. کنترل دستی اطلاعات زمان‌بر و پُرhzینه است. در این مقاله، روش‌های داده کاوی برای کنترل کیفیت پایگاه اطلاعات پژوهشی معرفی می‌شود. برای این منظور، ابتدا باید اطلاعاتی از خطاهای مرسوم را در کنار سایر اطلاعات هر رکورد جمع‌آوری کرد. سپس، با استفاده از روش‌های داده کاوی الگوهای پنهان و روابط بین خطاهای را کشف کرد و بر این اساس، راه‌های بهبود کیفیت داده را ارائه داد. در این مقاله پایگاه اطلاعات علمی ایران (گنج)، به عنوان مطالعه موردی در نظر گرفته شد. ۵۹ کد خطای نام دانشگاه، نام رشته، گرایش و حوزه تخصصی مدرک به همراه کدهای آن در یک مجموعه داده ذخیره شد. این مجموعه داده شامل ۴۱۰۲۱ رکورد در حوزه‌های مختلف است. با استفاده از روش‌های آماری و قوانین انجمنی رابطه بین خطاهای الگوی تکرار آن‌ها در هر حوزه بررسی شد.



نتایج نشان داد که به طور میانگین با در نظر گرفتن ۲۵ درصد از خطاهای در هر حوزه، می‌توان تا ۸۰ درصد از خطاهای همه رکوردهای یک حوزه را کاهش داد. این خطاهای شامل خطاهای پر تکرار در هر حوزه و همچنین خطاهایی است که با آن‌ها رابطه قوی دارند. با استفاده از روش خوشه‌بندی K-means رکوردها خوشه‌بندی شدند. نتایج نشان داد که اگرچه شباهت‌هایی بین رکوردهای از حوزه‌های مختلف وجود دارد، اما رابطه معناداری بین حوزه رکوردها و الگوی تکرار خطاهای وجود ندارد.

کلیدواژه‌ها: کیفیت داده، کیفیت اطلاعات پژوهشی، کنترل کیفیت، داده کاوی

۱. مقدمه

کیفیت داده یکی از موضوعات مهم در مدیریت داده است. مبنای تصمیم‌گیری و عملکرد هر سازمان، داده‌های موجود در آن سازمان است و یکی از مهم‌ترین گام‌ها برای رسیدن به نتایج مطلوب بهبود کیفیت داده است. با به وجود آمدن داده‌های عظیم اطلاعاتی، تغییرات بسیاری در مدیریت و تحلیل داده ایجاد شده است. امروزه، تحلیل و بررسی کلان‌داده‌ها، تشخیص داده‌های غیراستاندارد، تشخیص خطاهای استخراج دانش از مجموعه داده‌ها با استفاده از روش‌های قدیمی و دستی امکان‌پذیر نیست. استفاده از ماشین و روش‌های هوشمند در بررسی کیفیت داده، افزون بر اینکه از نظر زمان و هزینه به صرفه است، نسبت به روش‌های دستی قابل اطمینان‌تر و پایدارتر است. در روش‌های داده کاوی با به کار گیری مدل‌های آماری، الگوهای ریاضی و روش‌های یادگیرنده، الگوهای روابط معتبر بین اجزای مختلف داده استخراج می‌شود.

اطلاعات پژوهشی به مجموعه فراداده‌هایی گفته می‌شود که به فعالیت پژوهشی مربوط است. اطلاعات مربوط به اشخاص، مقالات، داده‌های پژوهشی و اختراعات اطلاعات پژوهشی محسوب می‌شوند. نظام‌های اطلاعاتی پژوهشی وظیفه حمایت از فرایندهای حوزه پژوهش و ایجاد پایگاه داده برای جمع‌آوری، مدیریت اطلاعات و فراهم کردن اطلاعات در زمینه فعالیت‌های پژوهشی و نتایج تحقیقاتی را دارند. از جمله نظام‌های اطلاعاتی پژوهشی، پایگاه‌های اطلاعات علمی و موتورهای جست‌وجوست. پایگاه‌های اطلاعاتی علمی (مانند اسکوپوس^۱، وب‌آوساینس^۲، پاب‌مد^۳ و آرکایس^۴) روزانه توسط میلیون‌ها محقق

1. Scopus

2. Web of Science

3. Pubmed

4. Archive

مورد استفاده قرار می‌گیرند و بحث کیفیت داده در آن‌ها از موضوعات روزمره است. Azeroual et al. (2020) نشان دادند که کیفیت داده نقش مهمی در رضایت کاربران از نظام‌های اطلاعات پژوهشی دارد. بررسی مقالات منتشر شده در زمینه داده‌های پژوهشی نشان می‌دهد که اگرچه در حوزه اندازه‌گیری کیفیت داده در سامانه‌های اطلاعاتی پژوهشی مطالعاتی صورت گرفته، اما در مورد چگونگی تحلیل داده‌های حاصل از فرایند ارزیابی کیفیت این سامانه‌ها کار چندانی انجام نشده است. در این پژوهش روش‌های تشخیص خطاهای معتبر و تعیین کننده در یک پایگاه پژوهشی، با کمک روش‌های قدرتمند حوزه تحلیل داده مورد بررسی قرار می‌گیرد.

پایگاه اطلاعاتی «گنج» یکی از مهم‌ترین پایگاه‌های اطلاعاتی اسناد علمی ایران است. این پایگاه دستاوردهای کاربرد فناوری اطلاعات برای مدیریت اطلاعات علم و فناوری در «پژوهشگاه علوم و فناوری اطلاعات ایران (ایران‌داسک)» است. «گنج» با صدها هزار رکورد، که شامل اطلاعات پایان‌نامه‌ها و رساله‌ها و پیشنهاده آن‌هاست، بزرگ‌ترین پایگاه اطلاعات علمی و فنی کشور است. این پایگاه هم‌اکنون مرجع بسیاری از پژوهشگران ایران و جهان است و روزانه بیش از ده‌ها هزار جست‌وجو در آن انجام می‌گیرد. پایگاه اطلاعات «گنج» شامل نسخه «پی‌دی‌اف» و ورد پایان‌نامه‌ها/ رساله‌ها (پارساله‌ها) و اطلاعات کتاب‌شناختی مربوط به هر فایل است. اطلاعات واردشده در سامانه «گنج» توسط نیروی انسانی بررسی می‌شود. در صورتی که اطلاعات کتاب‌شناختی ثبت شده (فراداده) و فایل‌های بارگذاری شده (داده) کیفیت مطلوبی نداشته باشند، مدرک به کاربر بازگردانده می‌شود تا ناهمخوانی‌های شناسایی شده را بطریف نموده و دوباره ارزیابی شود. این فرایند، زمان‌بر و پرهزینه است. برطرف کردن مشکلات کیفی یک سامانه در دو مرحله انجام می‌شود: مرحله تشخیص خطا، که در آن خطاهای مختلف توسط خبرگان تشخیص داده شده و اعتبار آن‌ها سنجیده می‌شود و مرحله رفع خطا، که بر اساس خطاهای تشخیص داده شده پایگاه داده پاک‌سازی می‌شود. شناسایی مشکل‌های کیفی و دسته‌بندی آن‌ها بر اساس شاخص‌هایی مانند میزان وقوع از جنبه‌های گوناگون می‌تواند به بهبود کیفیت داده بیانجامد. بر این اساس، می‌توان لیستی از خطاهای مرسوم در پایگاه داده را تهیه کرد و با بررسی و تفسیر آن‌ها راهکارهایی برای بهبود کیفیت داده ارائه داد. با کشف الگوی تکرار هر خطا بهتنهایی و در ارتباط با خطاهای دیگر می‌توان خطاهای بارز و تعیین کننده را از مجموعه خطاهای استخراج کرد و با صرف زمان و هزینه کمتر مشکلات کیفی پایگاه داده

را بر طرف کرد. در پایگاه های عظیم اطلاعاتی خطاهای ایجاد شده نیز کلان داده محسوب می شود و برای تحلیل و کشف الگوهای پنهان آنها نیاز است از روش های داده کاوی استفاده کرد.

در این پژوهش برای استفاده از روش‌های داده کاوی، ابتدا نمونه‌های مورد نظر (در اینجا فایل‌های خطدار)، به همراه سایر ویژگی‌ها و مشخصات آن‌ها جمع آوری شد. برای هر خطایک کد (کد رد) در نظر گرفته شد و یک مجموعه داده شامل اطلاعات فراداده هر فایل و کد خطای آن ایجاد شد. با استفاده از روش‌های قوانین انجمانی^۱ و آماری، همبستگی بین خطاهای الگوی تکرار خطاهای تشخیص داده شد. بر اساس الگوهای کشف شده یک لیست از خطاهای بارز و تعیین کننده استخراج شد. با دسترسی به این لیست، بخش کنترل کیفیت در زمان کمتری می‌تواند مشکلات کیفی را بررسی و رفع کند. همچنین با در نظر گرفتن خط و اطلاعات فراداده هر فایل به عنوان ویژگی‌های آن فایل، با استفاده از روش K-means، نقش الگوی تکرار خطاهای در تمایز فایل‌ها بررسی شد. در بخش بعد به پیشینهٔ پژوهش‌های این حوزه اشاره خواهیم کرد. سپس، روش‌های داده کاوی استفاده شده معرفی و پیاده‌سازی می‌شوند و نتایج بررسی می‌شود.

۲. پیشینهٔ پژوهش

امروزه، با پیشرفت در تولید و جمع آوری و ذخیره داده، پایگاه‌های اطلاعات داده در مقیاس بزرگ به وجود آمده است که برای کنترل کیفیت آن‌ها نیازمند روش‌های خودکار هستیم (Shrivastava et al. 2019; Schelter et al. 2018). فرایند تشخیص الگوهای بدیع، معتبر و معنادار از داده را کشف اطلاعات از داده و داده کاوی می‌نامند (Fayyad, Piatetsky-Shapiro and Smyth 1996). بدلیل پیچیدگی و تنوع داده‌ها طراحی روش‌های داده کاوی متناسب با هر داده، به صورت ویژه مورد استفاده قرار گرفته و کاربرد روزافزون دارد. Altendeitering (2021) با استفاده از روش ماشین بردار پشتیبان^۳ و قوانین انجمنی، قوانین کنترل کیفیت برای انتقال داده اصلی را استخراج کرده است. (Fox et al. 2018) با استفاده از روش‌های فرایند کاوی^۴ یک چارچوب برای کنترل کیفیت داده‌های سلامت ارائه داده‌اند.

پیش‌پردازش، داده‌های نویز^۱ حذف شده و به اصطلاح پایگاه داده پاکسازی می‌شود. روش‌های مختلفی برای تشخیص خطاهای پایگاه داده معرفی شده است. برای مثال، با طراحی محدودیت‌های مناسب یکپارچگی برای رفع ناهمگونی داده (Chu, Ilyas and Papotti 2013a) و یا با استفاده از روش‌های آماری برای تشخیص داده پرت^۲، می‌توان خطاهای داده را تشخیص داد (Hellerstein 2008). برای رفع خطاهای روش‌هایی مثل پیدا کردن حداقل مجموعه بروزرسانی برای رفع تخلف‌ها (Chu, Ilyas and Papotti 2013b) و روش‌هایی بر اساس مدل‌های آماری و تبدیل داده (He et al. 2018) پیشنهاد شده است. بعد از پالایش اولیه، با استفاده از روش‌های داده کاوی اطلاعات مفید از داده استخراج شده، و این اطلاعات تفسیر می‌شوند. روش‌های داده کاوی را می‌توان به دو گروه اصلی تقسیم‌بندی کرد. گروه اول، روش‌های توصیف کننده هستند که خوش‌بندی و قوانین انجمنی را شامل می‌شود (Agrawal and Sriknat 1994; Brin et al. 1997; Cheung et al. 1996; Zhang, Ramakrishnan 1996). در این دسته الگوها، روابط بین نمونه‌های مختلف داده کشف می‌شود. گروه دوم، روش‌های پیش‌بینی کننده است که در آن با استفاده از یک داده آزمایشی الگوریتم‌هایی طراحی می‌شود که می‌تواند برای تشخیص و پیش‌بینی داده‌های مشاهده‌نشده به کار رود (Cheeseman and Stutz 1996; Weiss and Kulikowski 1991).

یکی از مهم‌ترین کاربردهای داده کاوی، بهبود کیفیت داده و اطلاعات است. برای نمونه، در تولید نیمه‌هادی‌ها^۳، به طور معمول، بیش از ۵۰۰۰۰ اطلاعات آماری فرایند تولید رصد می‌شود تا کیفیت حدود ۳۰۰ مرحله در ساخت تراشه کنترل شود. برای تحلیل و بررسی کلان‌داده ایجاد شده نیاز به روش‌های خودکار و داده کاوی است. (Chien, Wang and Cheng 2007) برای تفسیر خطاهای و متغیرهای فرایند تولید نیمه‌هادی‌ها از روش K-means استفاده کردند. (Hu and Su 2004) برای توصیف رابطه بین ماشین‌ها و نرخ بازدهی ویفر، و (Skinner et al. 2002) برای بهبود بازدهی از روش خوش‌بندی سلسله‌مراتبی استفاده کردند. یکی دیگر از کاربردهای داده کاوی، کنترل کیفیت داده در نظام‌های اطلاعات پژوهشی است. هر قدر کیفیت داده در این نظام‌ها بهتر باشد، تفسیر و گزارش داده آسان‌تر و قابل اعتمادتر خواهد بود (Schöpfel, Azeroual and Saake 2019). تاکنون در مورد بهبود کیفیت سامانه‌های اطلاعاتی پژوهش‌های گوناگونی صورت پذیرفته است.

1. noise

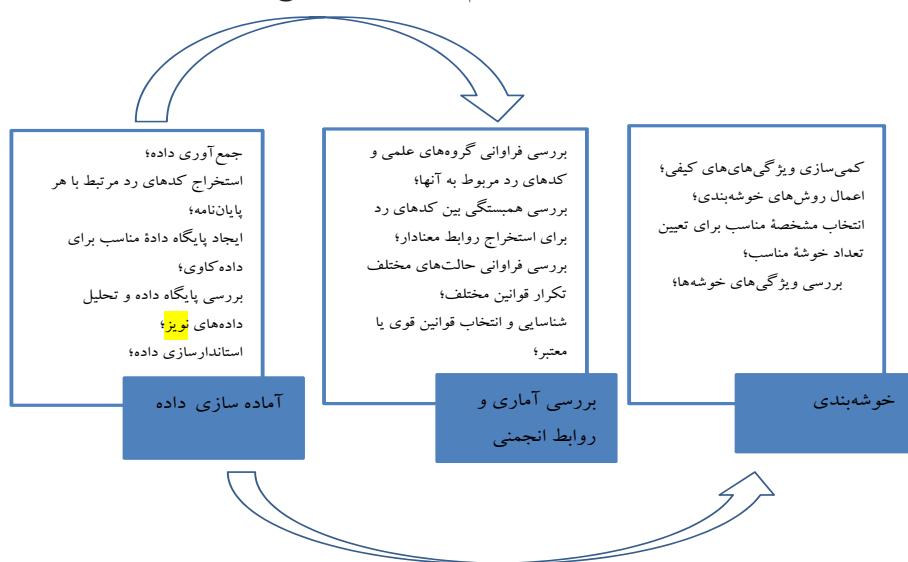
2. outlier

3. semiconductor

برای نمونه، می‌توان به (Azeroual et al. 2020; Falge, Otto and Österle 2012; Ershadi, Aiasi and Kazemi 2018) اشاره کرد. در ادامه و در بخش بعد به روش پژوهش خواهیم پرداخت. از آنجا که در این مقاله به دنبال بررسی روابط درون پایگاه داده با تمرکز بر ویژگی خطاهای هستیم، با استفاده از روش‌های قوانین انجمانی و خوشبندی به پردازش اطلاعات می‌پردازیم.

۳. روش پژوهش

در پایگاه اطلاعات «گنج» اطلاعات فراداده پارساهای و فایل‌های آن‌ها ذخیره می‌شود. کاربران، اطلاعات کتابشناختی پایان‌نامه/ رساله خود را در این سامانه در قالب فراداده وارد می‌کنند و سپس، نسخه‌پی‌دی‌اف و ورد آن را نیز بارگذاری می‌نمایند. اطلاعات واردشده در پایگاه داده ذخیره می‌شود. برای بازیابی مؤثر اطلاعات از پایگاه اطلاعات «گنج»، نیاز است داده با کمترین میزان خطای ذخیره‌سازی شود. در حال حاضر خطاهای به صورت دستی بررسی می‌شوند. در این پژوهش روش‌های قوانین انجمانی و خوشبندی برای بررسی خطاهای و کنترل کیفیت داده به کار برده می‌شود. برای این منظور، ابتدا داده آماده‌سازی شده و سپس، روش‌های مناسب برای تحلیل آن به کار گرفته می‌شود. در شکل ۱، گام‌های پژوهش نمایش داده شده و در ادامه، هر گام به تفصیل توضیح داده می‌شود.



شکل ۱. گام‌های پژوهش

آماده‌سازی داده

برای استفاده از روش‌های قوانین انجمنی و خوش‌بندی در بررسی خطاهای ابتدا یک مجموعه داده شامل اطلاعات فراداده فایل‌ها و خطاهای مربوط به هر فایل ایجاد شد. بعد از بررسی اولیه توسط خبرگان، ۵۹ کد خطا (کد رد) تعریف شد. هر مدرک با رگذاری شده توسط کاربر، به صورت دستی بررسی و در صورت وجود خطا یک کد رد به مدرک تخصیص داده شد. به این ترتیب، ویژگی‌های ذاتی هر رکورد مثل نام دانشگاه، نام رشته، گرایش و حوزهٔ تخصصی مدرک به همراه کدهای خطای آن در یک مجموعه داده جهت بررسی کنترل کیفیت ذخیره شد. در این پژوهش پایگاهی با ۴۲۰۲۱ رکورد هست که هر رکورد مرتبط با دلیل رد شدن پایان‌نامه‌ای در سامانهٔ ثبت «ایران‌دادک» است. ویژگی‌های مرتبط با هر رکورد به ترتیب زیر هستند:

- ◊ ArticleId: شمارهٔ مرتبط با پایان‌نامهٔ مورد بررسی که با ویژگی Title متناسب است؛
- ◊ Title: عنوان مرتبط با پایان‌نامهٔ مورد بررسی که با ویژگی ArticleId متناسب است؛
- ◊ FullName: نام مسئول بررسی کنندهٔ پایان‌نامه‌ها؛
- ◊ UniversityName: نام دانشگاهی که پایان‌نامه در آنجا انجام شده است؛
- ◊ GroupName: گروه علمی تخصصی مرتبط با پایان‌نامه که پس از پیش‌پردازش و ادغام بعضی از آن‌ها در یکدیگر، در هفت گروه دسته‌بندی شده است؛
- ◊ Field: حوزهٔ علمی تخصصی مرتبط با پایان‌نامه؛
- ◊ Minor: زیرحوزهٔ تخصصی مرتبط با پایان‌نامه؛
- ◊ RejectId: کد مرتبط با رد پایان‌نامه که با ویژگی RejectTitle متناسب است. قابل ذکر است که کدهای مختلفی در این ستون وجود دارد که بعضی از آن‌ها با ۱ شروع می‌شوند و با مشکلات مشخصات فردی و پایان‌نامهٔ ثبت شده در سامانهٔ مرتبط هستند؛
- ◊ RejectTitle: تشریح دلیل مرتبط با رد پایان‌نامه که با ویژگی RejectId متناسب است.

در این مجموعه داده کد منحصر به‌فردی برای هر رکورد وجود ندارد. به عبارت دیگر، هر پایان‌نامه می‌تواند به چندین دلیل رد شود. بنابراین، نمی‌توان کد پایان‌نامه را منحصر به‌فرد دانست و ترکیبی از کد پایان‌نامه به همراه دلایل رد شدن آن می‌تواند کد منحصر به‌فرد برای هر رکورد ایجاد کند. برخی رکوردها در این پایگاه داده با تکرار یک کد رد برای یک پایان‌نامه مواجه بودند. برای مثال، یک پایان‌نامه مرتبط با گروه علوم

پایه در این پایگاه داده، ۲ بار با کد رد ۶۰۰ رد شده بود که موجب می شد این پایگاه داده شامل رکوردهای تکراری شود. این رکوردهای تکراری حذف شد.

۲-۳. بررسی اطلاعات آماری و روابط انجمنی

پس از آماده سازی داده ها، طبقه بندی و استخراج اطلاعات از دیدگاه آماری انجام شد. نتایج مرتبط با فراوانی و درصد تجمع هر کد تکرار به تفکیک هر رشته علمی محاسبه شد. به این منظور، ابتدا پایان نامه های مرتبط با هر گروه علمی شناسایی شد و سپس، تعیین شد که هر پایان نامه با چه کدهای ردی مرتبط بوده است. آنگاه فراوانی کدهای رد در هر گروه علمی مورد بررسی قرار گرفت و نتایج نهایی بر اساس آنها مرتب شد. به این ترتیب، جدولی از فراوانی هر کد خطاب و درصد تکرار آن در هر حوزه ایجاد شد. این جدول اطلاعات خوبی از خطاهای مرسوم در هر حوزه را به دست می دهد و به کنترل کیفیت داده کمک می کند. در محاسبات آماری، هر کد خطاب به شکل مستقل و انفرادی در نظر گرفته می شود.

از روش قوانین انجمنی برای یافتن روابط جذاب بین متغیرهای موجود در پایگاه داده های بزرگ استفاده می شود. در این روش قوانینی بین ویژگی های موجود ساخته می شود، اما چگونگی تحلیل و ارائه قوانین قوی یافت شده در پایگاه های داده با استفاده از معیارهای متفاوتی بررسی می شود. هر قانون از دو قسمت مقدم و تالی (تالی → مقدم) تشکیل شده است که هر کدام می تواند مجموعه های مختلفی باشد. مقدم، جزء اول یک عبارت منطقی و تالی، جزء دوم آن و به لحاظ معنایی دنباله جزء اول است. بر مبنای مفهوم معمول قوانین قوی، هر قدر مقدم و تالی یک قانون در یک پایگاه داده بیشتر تکرار شود، قانون محکم تری را ایجاد می کند. دو معیار کلیدی برای بررسی هر قانون ($x \rightarrow y$) به شرح زیر است:

- ◊ Support یا پشتیبان: به تعداد تکرار یک قانون تقسیم بر کل تعداد رکوردهای موجود گفته می شود ($\frac{\text{frq}(x,y)}{N}$);
- ◊ Confidence یا حمایت: به تعداد تکرار یک قانون تقسیم بر تعداد تکرار مقدم آن گفته می شود ($\frac{\text{frq}(x,y)}{\text{frq}(x)}$).

با توجه به روابط گفته شده، بدیهی است که اکثر قوانین، پشتیبانی کمتر از حمایت دارند. در تعیین قوانین قوی، ابتدا حدی برای پشتیبان تعیین می شود تا مجموعه قوانین

ممکن کاندید شوند. سپس، بر اساس حد دیگری که نشان‌دهنده حداقل حمایت است، قوانین قوی شناسایی می‌شوند. بر اساس این روش می‌توان قوانین موجود بین کدهای رد در پایگاه داده را بررسی کرد. برای این منظور، ساختار پایگاه داده به صورتی اصلاح می‌شود که نشان دهد هر پایان‌نامه با چه ترکیبی از کدهای رد مواجه شده است. سپس، بررسی ترکیب‌های مختلف موجب پیدا شدن قوانین قوی در این پایگاه داده خواهد شد.

۳-۳. خوش‌بندی

در روش خوش‌بندی، گروه‌بندی مجموعه‌ای از داده‌ها انجام می‌شود. این کار به این صورت است که داده‌ها در یک گروه (به نام خوش) در مقایسه با دیگر خوش‌های مشابه هستند. این روش یکی از روش‌های داده‌کاوی اکتشافی و روشنی معمول برای تجزیه و تحلیل داده‌های آماری است که در بسیاری از زمینه‌ها از جمله تشخیص الگو، تجزیه و تحلیل تصویر و فشرده‌سازی داده‌ها استفاده می‌شود. قابل ذکر است که روش خوش‌بندی یک الگوریتم خاص نیست، بلکه روند کلی است و می‌تواند توسط الگوریتم‌های مختلفی به دست آید. خوش‌ها شامل گروه‌هایی با فاصله‌های کم بین اعضای خوش، مناطق متراکم فضای داده، فواصل و یا توزیع‌های آماری خاص است. الگوریتم خوش‌بندی مناسب و تنظیمات پارامتر (از جمله پارامترهای مانند تابع فاصله مورد استفاده، آستانه تراکم یا تعداد خوش مورد انتظار) بستگی به تنظیم مجموعه داده‌ها توسط فرد و استفاده خاص فرد از نتایج دارد. تجزیه و تحلیل خوش‌ای یک فرایند تکراری از کشف دانش یا بهینه‌سازی دارای چند هدف، تعاملی است که شامل آزمایش و شکست است. بیشتر لازم است که داده‌های پیش‌پردازش شده و پارامترهای مدل اصلاح شوند تا نتیجه حاصل، همان نتیجه دلخواه باشد. روش‌های خوش‌بندی مختلفی وجود دارد که در این پژوهش با توجه به نوع داده‌ها و کاربرد، از روش K-means استفاده شده است. این روش خوش‌بندی با هدف تجزیه n مشاهده به k خوش‌های انجام می‌شود. در این روش ابتدا k داده به عنوان مرکز خوش‌ها فرض می‌شود و نزدیک‌ترین داده به آن‌ها به عنوان عضوی از خوش مربوطه در نظر گرفته می‌شود. در ادامه، مرکز هر خوش بروز می‌شود و از میانگین گیری داده‌های آن خوش به دست می‌آید. بنابراین، در این روش هر یک از مشاهدات متعلق به خوش‌های با نزدیک‌ترین میانگین آن است و این میانگین به عنوان پیش‌نمونه استفاده می‌شود.

برای محاسبه تعداد بهینه خوشها از معیار تفاضل تفکیک‌پذیری-فسردگی^۱ می‌توان استفاده کرد. در این معیار تلاش می‌شود دو خوشها بیشترین فاصله را از هم داشته باشند (Separation) در حالی که تراکم درون خوشها بیشترین مقدار ممکن را داشته باشند (Compactness). برای محاسبه Sep میانگین فاصله مرکز خوشها از هم، و برای محاسبه Comp میانگین فاصله داده‌های متعلق به یک خوشها از مرکز آن در نظر گرفته می‌شود. به این ترتیب، ابتدا مرکز هر خوشة μ_j محاسبه می‌شود. در معادله زیر n_j تعداد فایل‌های موجود در خوشة j است و x_i فایل i در خوشه j است:

$$\mu_j = \frac{1}{n_j} \sum_{x_i \in C_j} x_i$$

فسردگی هر خوشه به صورت میانگین فاصله داده‌های متعلق به یک خوشه از مرکز آن در نظر گرفته می‌شود:

$$comp_j = \frac{1}{n_j} \sum_{x_i \in C_j} \|x_i - \mu_j\|^2$$

از میانگین فسردگی همه خوشها به دست می‌آید: (n_c تعداد خوشهاست)

$$comp = \frac{1}{n_c} \sum_{j=1}^c comp_j$$

معیار Sep از میانگین فاصله دو-به-دوی میانگین خوشها (D_{jk}) به دست می‌آید:

$$sep = \frac{1}{n_c} \sum_{j=1,2,\dots,c-1; k=2,3,\dots,c; j > k} D_{jk}$$

$$D_{jk} = \|\mu_j - \mu_k\|^2$$

معیار Sep-Comp از تفاضل sep و $comp$ به دست می‌آید. در نتیجه، هرچه معیار Sep-Comp بزرگ‌تر باشد، خوشبندی بهتری انجام شده است. چنانچه اطلاعات فراداده و کد رد هر فایل به عنوان ویژگی‌های هر فایل در نظر گرفته شود، با اعمال خوشبندی و بررسی هر خوشه می‌توان ویژگی‌هایی را که در تمایز فایل‌ها مؤثر هستند، شناسایی کرد. همچنین با در نظر گرفتن تمام ویژگی‌ها می‌توان فایل‌های مشابه و ویژگی‌های مشترک آن‌ها را کشف کرد.

1. sep-comp (separation-compactness)

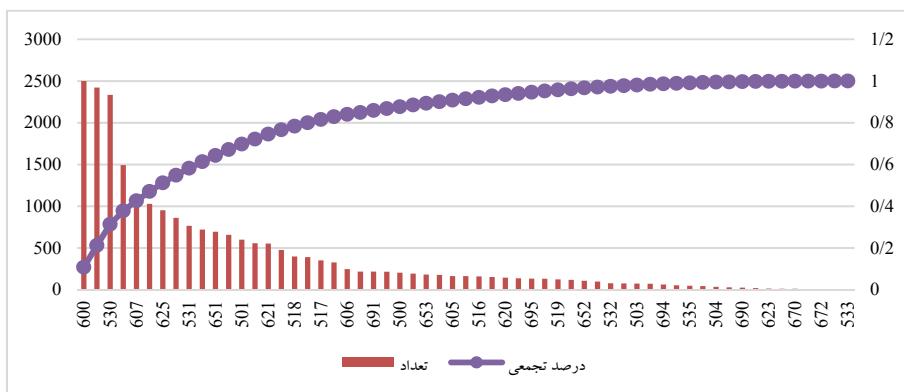
پیاده‌سازی و بررسی نتایج

برای کشف اطلاعات و الگوهای پنهان موجود در پایگاه داده، مجموعه داده مطابق الگوی ارائه شده آماده‌سازی شد. سپس، روش‌های قوانین انجمنی و خوش‌بندی بر آن اعمال شد. برای این منظور، کدنویسی در مطلب^۱ و پایتون^۲ و (محیط ژوپیتر نوت بوک^۳) انجام شد. نتایج آماری و قوانین انجمنی در جدول ۱، آمده است. در ستون اول، سه کد رد با بیشترین فراوانی به همراه درصد آن‌ها نمایش داده شده است. در ستون دوم، ترکیب سه تایی کدهای خطای خطای پر تکرار را که بیشترین فراوانی در هر حوزه را دارند، مشاهده می‌کنید. در ستون آخر، لیستی از قوانین بین کدها ارائه گردیده است. قواعد نمایش داده شده در این ستون از قوی‌ترین الگو با بیشترین درصد پشتیبان و اطمینان، به ضعیف‌ترین الگوی یافت شده مرتب شده‌اند.

جدول ۱. نتایج آماری و قوانین انجمنی

حوزه	خطای پر تکرار	ترکیب سه خطای پر تکرار	سه قانون انجمنی بین خطای
علوم پزشکی	۵۳۰ (۱۳ درصد)	[۵۱۹, ۵۱۲, ۵۱۱]	۵۳۰<→۶۰۰
	۶۰۰ (۱۲ درصد)		۶۰۰<→۵۳۰
	۶۵۵ (۴ درصد)		۵۱۲<→۵۱۱
کشاورزی	۵۳۰ (۹ درصد)	[۶۵۵, ۵۳۷, ۵۳۰]	۵۳۰<→۶۵۵
	۶۵۵ (۷ درصد)		۶۵۵<→۵۳۰
	۶۲۵ (۶ درصد)		۶۸۰<→۶۰۷
علوم انسانی	۶۰۰ (۲۰ درصد)	[۶۸۰, ۶۰۷, ۵۱۵]	۶۸۰<→۶۰۷
	۶۸۰ (۱۰ درصد)		۶۰۷<→۶۸۰
	۵۳۰ (۱۰ درصد)		۶۸۰<→۵۰۰
فنی مهندسی	۶۰۰ (۱۱ درصد)	[۶۰۷, ۶۰۰, ۵۱۵]	۶۸۰<→۶۰۷
	۶۸۰ (۱۰ درصد)		۶۰۷<→۶۸۰
	۵۱۵ (۷ درصد)		۶۰۰<→۶۰۷
دانپژوهشکی	۶۰۰ (۱۰ درصد)	[۶۵۵, ۵۳۷, ۵۱۹]	۶۰۰<→۵۳۸
	۶۵۵ (۸ درصد)		۶۰۰<→۵۳۰
	۶۳۰ (۷ درصد)		۵۳۰<→۶۰۰
هنر	۶۸۰ (۱۱ درصد)	[۶۸۰, ۶۰۷, ۵۱۵]	۶۸۰<→۶۰۷
	۶۰۰ (۹ درصد)		۶۰۷<→۶۸۰
	۵۳۰ (۸ درصد)		۶۸۰<→۶۰۰
علوم پایه	۶۰۰ (۹ درصد)	[۶۸۰, ۶۰۷, ۵۳۰]	۶۸۰<→۶۰۷
	۶۹۶ (۹ درصد)		۶۰۷<→۶۸۰
	۵۳۰ (۸ درصد)		۶۰۰<→۶۸۰

در گروه دامپزشکی، ۳۱ پایان‌نامه با کد رد ۶۰۰ (کامل نبودن صفحه عنوان فارسی) مرتبط بوده‌اند و این کد رد بیشترین فراوانی را بین سایر کدهای رد داشت. کد رد بعدی با بیشترین تکرار در گروه دامپزشکی، کد رد شماره ۶۵۵ (فونت نامناسب) است که مرتبط با ۲۵ پایان‌نامه است. همچنین رابطه‌ای قوی بین خطای ۵۳۸ (خطا در نگارش نام خانوادگی انگلیسی در فراداده) و ۵۳۰ (وارد نشدن صحیح چکیده) با خطای ۶۰۰ وجود دارد. در علوم انسانی کد رد ۶۰۰ برای ۲۵۰۰ پایان‌نامه در این گروه وجود داشته است که از نظر فراوانی بیش از ۱۰ درصد از پایان‌نامه‌های این گروه را تشکیل می‌دهد. کد رد ۶۸۰ (کامل نبودن صفحه عنوان انگلیسی) با ۲۴۲۱ پایان‌نامه، دومین کد رد پر تکرار در این گروه است. همچنین رابطه‌ای قوی بین خطای ۶۸۰ و ۶۰۷ (نبودن چکیده فارسی یا انگلیسی)، ۶۰۰ و ۶۸۰ وجود دارد. همان‌طور که از این جدول در کمی شود، در اکثر رشته‌ها رابطه‌ای قوی بین کامل نبودن صفحه عنوان فارسی، کامل نبودن صفحه عنوان انگلیسی و نبودن چکیده وجود داشت. در رشته کشاورزی رابطه‌ای قوی بین وارد نشدن صحیح چکیده و وجود صفحات سفید در پایان‌نامه ۶۵۵ وجود داشت. جزئیات فراوانی کدهای رد و درصد تجمعی آن در رشته علوم انسانی در شکل ۲، نمایش داده شده است. همان‌طور که در این شکل مشاهده می‌شود، از مجموعه ۵۹ خطابا در نظر گرفتن ۱۵ خطاب حدود ۸۰ درصد خطاهای موجود در این حوزه پوشش داده می‌شود. با داشتن این اطلاعات لازم نیست برای هر گروه علمی تمامی کدهای رد را مورد بررسی قرار داد و می‌توان با در نظر گرفتن چند کد رد که بیشترین درصد فراوانی را دارند، و کدهایی که با آن‌ها ارتباطی قوی دارند، در زمان کوتاه‌تری کیفیت داده را بهبود بخشد. با این روش، به طور میانگین با در نظر گرفتن ۲۵ درصد از خطاهای در هر حوزه می‌توان تا ۸۰ درصد از خطاهای همه رکوردهای یک حوزه را پوشش داد.

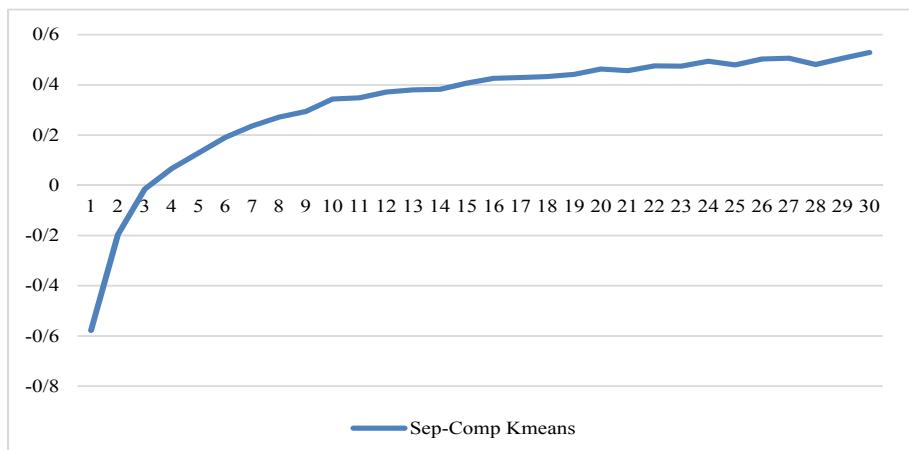


شکل ۲. نمودار تعداد و درصد تجمعی کدهای رد مرتقب شده در گروه علوم انسانی

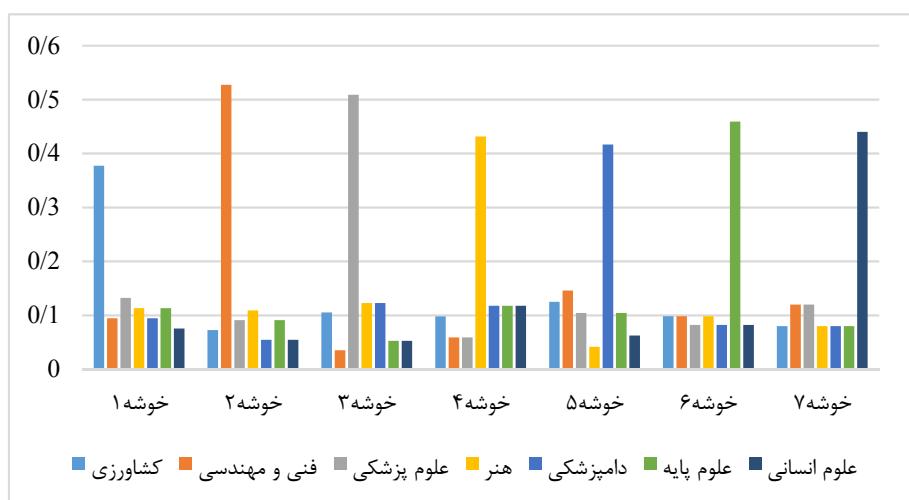
برای استفاده از خوش‌بندی K-means، تمام ویژگی‌های یک رکورد در نظر گرفته شد. ابتدا با استفاده از روش رمزگذاری برچسب^۱ برای هر ویژگی ذاتی یک عدد منظور شد. به عنوان مثال، هفت حوزه برای تمام مقالات وجود داشت. برای هر حوزه یک عدد بین صفر تا ۶ اختصاص داده شد. بعد از اختصاص معادل عددی به هر ویژگی، ویژگی‌ها در بازه ۰ تا ۱ استانداردسازی شد؛ به طوری که بیشترین عدد از یک ویژگی به یک و کوچک‌ترین عدد به صفر تصویر شد. برای تعیین تعداد مناسب خوش‌های از معیار Sep-Comp استفاده شده است که نتیجه آن در شکل ۳، آمده است. روند افزایش معیار به ازای افزایش تعداد خوش از ۱ تا ۷ نمایی بوده است و پس از آن روند صعودی کند می‌شود. بنابراین، به نظر می‌رسد که ۷ خوش مناسب‌ترین تعداد خوش برای این پایگاه داده است. در شکل ۴، فراوانی تعداد رکوردهای مربوط به هر حوزه در هر خوش نمایش داده شده است و همان‌طور که مشاهده می‌شود، در هر خوش یک حوزه خاص فراوانی بیشتری دارد و هر خوش می‌تواند نماینده یک حوزه خاص باشد. از این نمودار می‌توان درک کرد که حوزه هر فایل نقش مهمی در خوش‌بندی داشته است و برای مثال، حوزه کشاورزی در خوش ۱ با علوم انسانی بیشترین شباهت، و با حوزه فنی و مهندسی کمترین شباهت را دارد. برای بررسی همبستگی و درک ارتباط بین خطاهای هر خوش، فراوانی خطاهای در هر خوش هم بررسی شد. شکل ۵، الگوی تکرار خطای در سه خوش تصادفی را نشان می‌دهد. همان‌طور که مشاهده می‌شود، الگوی تکرار خطاهای در این خوش‌ها

1. label encoding

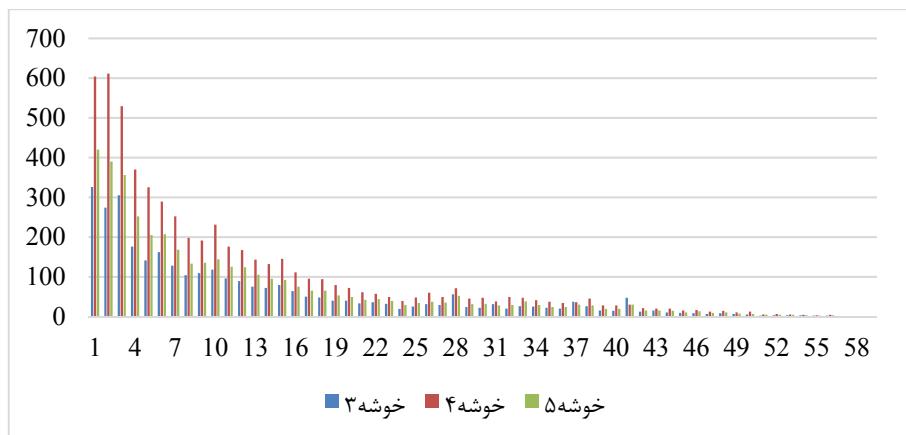
بسیار شبیه به هم هستند. بررسی‌ها نشان داد که تفاوت اندکی در الگوی تکرار خطای خوش‌ها وجود داشت. در همه خوش‌ها خطای ۶۸۰، ۶۰۷، ۵۳۳ سه خطای کم تکرار بودند. از نتایج خوش‌بندی می‌توان نتیجه گرفت که همبستگی‌ای بین ویژگی‌های ذاتی از جمله حوزه هر فایل و خطاهای وجود ندارد. بنابراین، در بررسی خطاهای ایجاد قوانین بهبود کیفیت فایل‌ها، برای تمام فایل‌ها می‌توان یکسان عمل کرد.



شکل ۳. نمودار sep-comp برای خوش‌بندی



شکل ۴. خروجی K-means



شکل ۵. الگوی تکرار خطاهای در هر خوش

۴. نتیجه‌گیری

پایگاه‌های اطلاعاتی پژوهشی یکی از مهم‌ترین پایگاه‌های اطلاعاتی هستند که نقش بهسازایی در امر پژوهش دارند. روزانه هزاران سند تحقیقاتی تولید شده و در یکی از پایگاه‌های اطلاعاتی شناخته شده ذخیره می‌شود. کیفیت داده در این پایگاه‌های اطلاعاتی نقش مهمی در بازیابی صحیح و قابل اعتماد اطلاعات از پایگاه‌ها را دارد. برخی از پایگاه‌های اطلاعاتی عمومی‌تر هستند؛ به این معنا که اطلاعات پژوهشی در هر حوزه و با هر موضوع و قالبی در آن‌ها ذخیره می‌شود. در این پایگاه‌ها که الگوی نوشتاری خاصی تعریف نمی‌شود، احتمال خطای بیشتر است. بررسی این خطاهای به صورت دستی بسیار زمان‌بر و پرهزینه است. در این تحقیق روش‌های قوانین انجمنی و خوشبندی برای تحلیل و بررسی مجموعه مشکلات کیفی داده پژوهشی بررسی شد. برای این منظور، در یک مطالعه موردنی از پایگاه اطلاعاتی «گنج»، یک مجموعه داده شامل اطلاعات فراداده فایل (ویژگی‌های ذاتی) و مشکلات کیفی و خطاهای مرسوم تهیه شد. سپس، با استفاده از محاسبه فراوانی خطاهای و قوانین انجمنی، یک مجموعه بهینه از خطاهای بارز و تعیین کننده ایجاد شد. نتایج نشان داد که با در نظر گرفتن ۲۵ درصد از خطاهای می‌توان تا ۸۰ درصد از کل خطاهای فایل‌ها را حذف کرد. به این ترتیب، واحد کنترل کیفیت با در نظر گرفتن فهرست بهینه خطاهای با صرف انرژی و وقت کمتری می‌تواند مشکلات کیفی را مرتفع سازد. برای کشف رابطه ووابستگی بین الگوی تکرار خطاهای و ویژگی‌های ذاتی

فایل (حوزه، نام دانشگاه، نام نویسنده و ...) از روش خوشه‌بندی استفاده شد. در روش خوشه‌بندی، ویژگی‌های بارز در هر خوشه که نقش اساسی در تمایز خوشه‌ها دارند، مشخص می‌شود. نتایج K-means بر داده آزمایشی نشان داد که ویژگی‌های ذاتی و بهویژه حوزه هر فایل منجر به تمایز / شباهت فایل‌ها و قرار گرفتن آن‌ها در خوشه‌های متفاوت شده است. الگوی تکرار خطاهای در هر خوشه نیز بررسی شد. این الگو در خوشه‌ها شبیه هم بود و وابستگی‌ای بین خطاهای حوزه فایل‌ها و سایر ویژگی‌ها دیده نشد. در نتیجه، در مورد این داده آزمایشی قوانین رفع خطاهای و بهبود کیفیت داده می‌تواند مستقل از ویژگی‌های ذاتی فایل‌ها ارائه شود.

References

- Agrawal, R. and R. Srikant. 1994. *Fast Algorithms for Mining Association Rules in Large Databases*, Proceedings of the 20th International Conference on Very Large Data Bases. September, pp. (487–499) Chile.
- Altendeitering, M. 2021. *Mining Data Quality Rules for Data Migrations: A Case Study on Material Master Data*. Margaria, Steffen (eds) Leveraging Applications of Formal Methods, Verification and Validation. ISO-LA 2021. Lecture Notes in Computer Science, vol 13036. Cham: Springer. https://doi.org/10.1007/978-3-030-89159-6_12
- Azeroual, O., G., M. Saake, Abuosba and J. Schöpfel. 2020. Data Quality as a Critical Success Factor for User Acceptance of Research Information Systems. *Data* 5 (2): 35.
- Brin, S., R. Motwani, J. D. Ullman, and S. Tsur. 1997. *Dynamic itemset counting and implication rules for market basket data*. ACM SIGMOD Conference, Tucson, Arizona, USA, pp. 255–264.
- Chien, C. F., W. C. Wang and J. Cheng. 2007. Data mining for yield enhancement in semiconductor manufacturing and an empirical study. *Expert Systems with Applications* 33 (1): 192–198.
- Cheung, D. W., J. Han, V. T. Ng, and C. Y. Wong. 1996. *Maintenance of discovered association rules in large databases: an incremental updating approach*. IEEE International Conference on Data Engineering, pp. (106–114). Washington, DC.
- Cheeseman, P., and J. Stutz. 1996. *Bayesian classification (AutoClass): theory and results*. U.M. Fayyad, G. Piatetsky-Shapiro, P. Smyth, & R. Uthurusamy (Eds.), *Advances in knowledge discovery and data mining* . pp (153–180). Menlo Park: American association for Artificial Intelligence.
- Chu, X., I. F. Ilyas, and P. Papotti. 2013a. *Discovering denial constraints*. *Proceedings of the VLDB Endowment*, 6 (13): 1498–1509.
- _____. 2013b. *Holistic data cleaning: Putting violations into context*. IEEE International Conference on Data Engineering, pp. 458–469. Brisbane, Australia.
- Ershadi, M. J., R. Aiasi, and S. Kazemi. 2018. Root cause analysis in quality problem solving of research information systems: a case study. *International Journal of Productivity and Quality Management* 24 (2): 28.
- Falge, C., B. Otto, and H. Österle. 2012. *Data quality requirements of collaborative business processes*. 45th Hawaii International Conference on System Sciences. pp. (4316-4325). IEEE Hawaii.
- Fayyad, U., G. Piatetsky-Shapiro, and P. Smyth. 1996. The KDD process for extracting useful knowledge from volumes of data. *Communication of ACM*, 39.34–27 :(11)

- Fox, V., R. Aggarwal, H. Whelton, and O. Johnson. 2018. *A Data Quality Framework for Process Mining of Electronic Health Record Data*, 2018 IEEE International Conference on Healthcare Informatics (ICHI), 2018, pp. (12-21), doi: 10.1109/ICHI.2018.00009. New York, NY, USA.
- He ,Y., X. Chu, K. Ganjam, Y. Zheng, V. Narasayya, and S. Chaudhuri. 2018. Transform-data-by-example (tde): an extensible search engine for data transformations. *Proceedings of the VLDB Endowment*, 11 (10): 1165–1177.
- Hellerstein, J. M. 2008. *Quantitative data cleaning for large databases*. United Nations Economic Commission for Europe (UNECE).
- Hu, C., and S. Su. 2004. *Hierarchical clustering methods for semiconductor manufacturing data*. Proceedings of the IEEE international conference on networking, sensing and control, Taiwan.
- Schelter S., D. Lange, P. Schmidt, M. Celikel, F. Biessmann, and A. Grafberger. 2018. *Automating large-scale data quality verification*. Proc. *Proceedings of the VLDB Endowment* 11 (12): 1781–1794.
- Schöpfel, J., O. Azeroual, and G. Saake. 2019. Implementation and user acceptance of research information systems: An empirical survey of German universities and research organisations. *Data Technologies and Applications*. 2019, 54: 1–15.
- Shrivastava, S., D. Patel, A. Bhamidipaty, W. M. Gifford, S. A. Siegel, V. S. Ganapavarapu, and J. R. Kalagnanam. 2019. *Dqa: Scalable, automated and interactive data quality advisor*. IEEE International Conference on Big Data (Big Data), pp. 2913–2922.
- Skinner, K. R., D. C. Montgomery, G. C. Runger, J. W. Fowler, D. R. McCarville, T. R. Rhoads, et al. 2002. Multivariate statistical methods for modeling and analysis of wafer probe test data. *IEEE Transactions on Semiconductor Manufacturing* 15 (4): 523–530.
- Weiss, S. M., and C. A. Kulikowski. 1991. *Computer systems that learn: classification and prediction methods from statistics, neural nets. Machine learning and expert systems*. Los Altos, CA: Morgan Kaufman.
- Zhang, T., R. Ramakrishnan, and M. Livny. 1996. *BIRCH: an efficient data clustering method for very large databases*. ACM SIGMOD International Conference Management of Data, pp. (103–114), Montreal, Canada.

آزاده فخرزاده

دارای مدرک تحصیلی دکتری در رشته پردازش تصویر از دانشگاه اوپسالای سوئد است. ایشان هم‌اکنون استادیار پژوهشکده فناوری اطلاعات، پژوهشگاه علوم و فناوری اطلاعات ایران (ایراندак) است. پردازش تصویر، یادگیری ماشین، کلان‌داده‌ها، و یادگیری عمیق از جمله علایق پژوهشی وی است.



محمد جواد ارشادی

دارای مدرک دکتری مهندسی صنایع است. ایشان هم‌اکون دانشیار گروه پژوهشی مدیریت فناوری اطلاعات پژوهشگاه علوم و فناوری اطلاعات ایران (ایران‌داک) است.

کنترل کیفیت آماری، مدیریت کیفیت جامع، بازمهندسی فرایندهای کسب و کار، بهینه‌سازی، الگوریتم‌های فرآبستکاری، تجزیه و تحلیل نظام‌ها و داده‌کاوی از جمله علایق پژوهشی است.



محمد مهدی ارشادی

دارای مدرک کارشناسی ارشد در رشته مهندسی صنایع دانشگاه صنعتی امیرکبیر است.

یادگیری ماشین، علوم داده، تحلیل شبکه، مهندسی نظام‌های سلامت و برنامه‌ریزی زنجیره تأمین از جمله علایق وی است.

