

Marine Data Users Clustering Using Data Mining Technique

Farnaz Ghiasi¹ | Navid Nezafati² | Sajjad Shokohyar³

1. [Corresponding Author] MSc in Management of Information Technology; Shahid Beheshti University; Head of Iranian National Center for Ocean Data farpar2002@yahoo.com
2. PhD in Industrial Engineering; Assistant Professor; Shahid Beheshti University; nezafati@sbu.ac.ir
3. PhD in Industrial Engineering; Assistant Professor; Shahid Beheshti University; s_shokouhyar@sbu.ac.ir

Abstract: The objective of this research is clustering marine data users using data mining technique. Achieving this objective, marine organizations will be able to know their data and users' requirements. In this research, CRISP-DM standard model was used to implement the data mining technique. The required data was extracted from 500 marine data users profile database of Iranian National Institute for Oceanography and Atmospheric Sciences (INIOAS) from 1386 to 1393. The TwoStep algorithm was used for clustering. In this research, patterns were discovered between marine data users such as student, organization and scientist and their data request (data source, data type, data set, parameter and geographic area) using clustering for the first time. The most important clusters are: student with international data source, chemistry data type, "world ocean database" dataset, Persian Gulf geographic area and organization with nitrate parameter. Senior managers of the marine organizations will be able to make correct decisions concerning their existing data. They will be directed to planning for better data collection in the future. Also data users will be guided with respect to their requests. Finally, valuable suggestions are offered to improve the performance of marine organizations.

Keywords: CRISP-DM Standard; TwoStep Algorithm; Clustering; Data Mining; Marine Data



Iranian Research Institute
for Science and Technology

ISSN 2251-8223

eISSN 2251-8231

Indexed in SCOPUS, ISC & LISA

Vol.30 | No.4 | pp: 1025-1049

Summer 2015

خوشه‌بندی کاربران داده‌های دریایی با استفاده از تکنیک داده‌کاوی

فرناز غیاثی^۱ | نوید نظافتی^۲ | سجاد شکوهیار^۳

۱. [پدیدآور رابط] کارشناسی ارشد مدیریت فناوری اطلاعات؛ دانشگاه شهید بهشتی؛ سرپرست مرکز داده‌ها؛ پژوهشگاه ملی اقیانوس‌شناسی و علوم جوی farpar2002@yahoo.com
۲. دکتری مهندسی صنایع؛ استادیار؛ دانشگاه شهید بهشتی nezafati@sbu.ac.ir
۳. دکتری مهندسی صنایع؛ استادیار؛ دانشگاه شهید بهشتی s_shokouhyar@sbu.ac.ir

مقاله پژوهشی

دریافت: ۱۳۹۳/۰۹/۱۹

پذیرش: ۱۳۹۳/۱۱/۱۳

دوره ۳۰ شماره ۴
۱۰۴۹-۱۰۲۵ صص.

مکالمه پژوهشی

پژوهش‌نامه پردازش و مدیریت اطلاعات

فصلنامه | علمی پژوهشی

شما (چاپ) ۸۲۲۳-۲۲۵۱

شما (الکترونیکی) ۸۲۳۱-۲۲۵۱

نمایه در LISA و Scopus

<http://jipm.irandoc.ac.ir>

پژوهشگاه علوم و فناوری اطلاعات ایران

چکیده: هدف از این تحقیق خوشه‌بندی کاربران داده‌های دریایی با استفاده از تکنیک داده‌کاوی است. با محقق شدن این هدف، سازمان‌های دریایی قادر به شناخت داده‌های موجود و همچنین اطلاع از نیازهای کاربران خود خواهد شد. در این تحقیق برای پیاده‌سازی داده‌کاوی از مدل استاندارد CRISP-DM استفاده شده است. داده‌های مورد نیاز از اطلاعات و پروفایل ۵۰۰ کاربر داده‌های دریایی از سال ۱۳۸۶ تا ۱۳۹۳ در پژوهشگاه ملی اقیانوس‌شناسی و علوم جوی استخراج شده است. برای خوشه‌بندی از الگوریتم TwoStep استفاده شده است. در این تحقیق، برای نخستین بار با استفاده از خوشه‌بندی، الگویی میان کاربران داده‌های دریایی اعم از دانشجو، سازمان و پژوهشگر، و اطلاعات داده‌های مورد درخواست آنها (منبع داده، نوع داده، مجموعه داده، پارامتر و منطقه جغرافیایی) کشف شد. مهم‌ترین خوشه‌های به دست آمده عبارت‌اند از کاربر دانشجو با منبع داده بین‌المللی، کاربر دانشجو با نوع داده شیمی دریا، کاربر دانشجو با مجموعه داده «پایگاه داده اقیانوسی جهانی»، کاربر سازمان با پارامتر نیترات و کاربر دانشجو با منطقه جغرافیایی خلیج فارس. کشف این الگوها، مدیران ارشد را قادر می‌سازد تا به درستی در مورد داده‌های موجود خود و برنامه‌ریزی برای جمع‌آوری داده در آینده تصمیم‌گیری کنند و در ک بهتری از نیازهای کاربران خود داشته باشند و کاربران داده نیز در راستای تقاضای خود هدایت شوند. در پایان پیشنهاداتی به منظور بهبود عملکرد سازمان‌های دریایی ارائه شده است.

کلیدواژه‌ها: استاندارد CRISP-DM؛ الگوریتم TwoStep؛ خوشه‌بندی؛ داده‌کاوی؛ داده دریایی

۱. مقدمه

سازمان‌های تحقیقاتی دریایی داخل کشور برای انجام کارهای پژوهشی خود و ارائه خدمات به سایر ارگان‌ها، به جمع آوری داده‌های دریایی از سازمان‌های داخلی و خارجی، ماهواره‌ها و گشت‌های علمی در محیط‌های آبی ایران (خليج فارس، دریای عمان و دریا خزر) می‌پردازند. این داده‌ها از حجم زیادی برخوردارند و انواع مختلفی از مجموعه داده‌ها، انواع داده‌های دریایی از جمله فیزیک دریا، شیمی دریا، بیولوژی دریا ... و همچنین پارامترها را شامل می‌شوند.

با توجه به اهمیت حوضه‌های آبی و نیاز روزافزون به ثبت داده‌های دریایی به نظر می‌رسد امروزه جامعه دریایی کشور با پایگاه‌های حجمی از داده‌های دریایی روبروست (وفایی، چگینی، سقایی، و عظام ۱۳۹۲). دستگاه‌ها و تجهیزات جمع آوری این داده‌ها گران و نگهداری و مراقبت از آنها بسیار پرهزینه است. همچنین برگزاری گشت‌های دریایی نیازمند صرف بودجه فراوان می‌باشد. بنابراین، استفاده و به کار گیری از این داده‌ها و اطلاعات حاصل از پردازش این داده‌ها، حائز اهمیت است. به همین دلیل، نیاز به ابزاری می‌باشد که بتوان داده‌های ذخیره شده را پردازش نمود و اطلاعات حاصل از این پردازش و دانش کشف شده را در اختیار کاربران قرار داد.

ابزار داده کاوی کمک می‌کند تا خدمات، مناسب با نیاز کاربران ارائه شوند و بر اساس اهمیت تقاضاها، استراتژی لازم جهت ارائه بهتر خدمات در پیش گرفته شود. داده کاوی به بهره گیری از ابزارهای تجزیه و تحلیل داده‌ها بهمنظور کشف الگوها و روابط معتبری که تاکنون ناشناخته بوده‌اند، اطلاق می‌شود (وفایی، چگینی، سقایی، و عظام ۱۳۹۲).

داده کاوی، سازمان‌ها را قادر می‌سازد تا از سرمایه داده‌هایشان به درستی بهره‌برداری نمایند و از این ابزار برای پشتیبانی فرایند تصمیم گیری استفاده کنند. داده کاوی، پردازش بهینه تصمیم گیری را در سازمان‌ها تسهیل می‌کند و از طریق استخراج دانش بالارزش از داده‌ها، تصمیم گیری را برای مدیران سازمان‌ها تسهیل می‌کند. بنابراین، ضروری است که برای استفاده از این ابزار در سازمان‌ها اهمیت بیشتری قائل شد تا در نهایت به فرایند تصمیم گیری بهینه برای مدیران منجر شود.

هدف اصلی این تحقیق، خوشبندی کاربران داده‌های دریایی بر اساس ویژگی‌های

داده درخواستی مانند نوع داده^۱، مجموعه داده^۲، پارامترها^۳، منبع داده^۴ و منطقه جغرافیایی با استفاده از تکنیک داده‌کاوی است.

در این تحقیق قصد داریم به سوالات زیر پاسخ دهیم:

سوال اصلی: چه الگویی بین کاربران داده با نوع داده، مجموعه داده، پارامترهای داده، منبع داده و منطقه جغرافیایی وجود دارد؟

سوال فرعی: چه استفاده مدیریتی می‌توان از داده‌کاوی بر روی کاربران داده‌های دریابانی در پژوهشگاه ملی اقیانوس شناسی و علوم جوی نمود؟

ارتباط بین کاربران داده و ویژگی‌های فوق برای مدیران سازمان‌های دریابانی مشخص نمی‌باشد. خوشبندی کاربران در سازمان‌ها توسط داده‌کاوی باعث می‌شود که مدیران بتوانند اطلاعات آنها را تحلیل نمایند، الگوی کاربران را پیدا کنند، و ارتباط بین سازمان و کاربران بهبود یابد تا در نهایت، کاربران احساس رضایت نمایند (Lai 2009).

اطلاع از این موضوع نیز از آنجا اهمیت دارد که خوشبندی کاربران بر اساس تقاضای آنها و شناخت نیاز کاربران موجب خواهد شد که با مدیریت مناسب داده‌های دریابانی، در جهت جلب رضایت کاربران گام برداشته شده و سرمایه‌های سازمانی به درستی استفاده شود. بدین ترتیب، از تمرکز روی جمع‌آوری داده‌های کم اهمیت جلوگیری می‌شود و برای داده‌های بالاهمیت تر، سرمایه‌گذاری بیشتری خواهد شد. نبود این شناخت باعث خواهد شد سرمایه‌های سازمان در پی داده‌های ناکارآمد اتلاف شود.

۲. پیشینه پژوهش

پیشینه پژوهش در دو بخش ارائه می‌گردد: در پیشینه نظری به تعاریف پایه، مباحث کشف دانش، داده‌کاوی، خوشبندی و الگوریتم TwoStep و مفاهیم داده‌های دریابانی پرداخته شده است و در پیشینه تجربی، پژوهش‌های مرتبط انجام شده با استفاده از تکنیک داده‌کاوی و الگوریتم‌های خوشبندی مرور شده است.

-
1. data type
 2. data set
 3. parameters
 4. data source

۲-۱. پیشینه نظری

۲-۱-۱. تعاریف پایه

داده^۱: به هر گونه نماد^۲، عدد، رقم، کاراکتر، رشته و یا سیگنال که معنای خاصی را به ذهن القاء نکند، داده گفته می‌شود.

اطلاعات^۳: چنانچه در کنار عدد، کاراکتر و یا هر عنصر داده‌ای، رشته‌ای به عنوان توصیف کننده وجود داشته باشد، داده ابتدایی به اطلاعات تبدیل خواهد شد.

دانش^۴: وجود یک رابطه میان دو عنصر اطلاعاتی، میان دانشی در آن زمینه است.

خرد^۵: خرد، عالی‌ترین سطح بینش است که توسط علائم و نمادهای قراردادی تبیین می‌شود.

پایه اصلی این تحقیق دو دسته داده می‌باشد: داده‌های خام جمع‌آوری شده از ایستگاه‌های اندازه‌گیری دریایی که پس از پردازش توسط متخصص علوم دریایی، از آنها اطلاعات حاصل می‌شود. همچنین داده‌های جمع‌آوری شده از پروفایل کاربران که شامل مشخصات حقیقی / حقوقی و درخواست آنها می‌باشد.

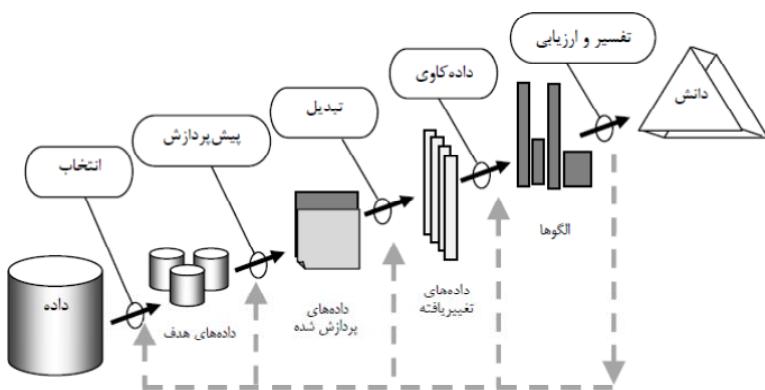
۲-۱-۲. کشف دانش از پایگاه داده^۶

کشف دانش از پایگاه داده در واقع فرایند تشخیص الگوها^۷ و مدل‌های موجود در داده‌هاست؛ الگوها و مدل‌هایی که معتبر، بدین^۸، بالقوه مفید و کاملاً قابل فهم هستند (Fayyad, Shapiro, & Smyth 1996). به عبارت دیگر، هدف این فرایند یافتن الگوها و یا مدل‌های جالب موجود در پایگاه داده‌هاست که در میان حجم عظیمی از داده‌ها مخفی هستند (غضنفری ۱۳۸۷).

فرایند کشف دانش از پایگاه داده شامل مراحل کلی انتخاب، پیش‌پردازش، تبدیل، به کار گیری روش‌های داده‌کاوی و ارزیابی محصولات حاصل از داده‌گاوی مطابق با

-
1. Data
 2. Symbol
 3. Information
 4. Knowledge
 5. Wisdom
 6. Knowledge Discovery from Database (KDD)
 7. patterns
 8. novel

شکل ۱ می‌باشد (Fayyad, Shapiro, & Smyth 1996).



شکل ۱. فرایند کشف دانش از پایگاه داده ۳-۲-۱-۲. داده‌کاوی

داده‌کاوی یکی از گام‌های فرایند کشف دانش از پایگاه داده است که شامل به کارگیری تحلیل داده و الگوریتم‌های کشف شده می‌باشد و با پذیرش محدودیت‌های محاسباتی، الگوهای خاصی را تولید می‌کند (Fayyad, Shapiro, & Smyth, 1996).

۱-۴. خوشبندی^۱

خوشبندی، به عمل تقسیم جمعیت ناهمگن به تعدادی از زیرمجموعه‌ها یا خوشبندی همگن گفته می‌شود. در خوشبندی هیچ دسته‌ای از پیش تعیین شده‌ای وجود ندارد و داده‌ها صرفاً بر اساس تشابه گروه‌بندی می‌شوند و عنوانی هر گروه نیز توسط کاربر تعیین می‌گردد (شهرابی ۱۳۹۲). خوشبندی به این شکل انجام می‌شود که رکوردهایی که بیشترین شباهت را با یکدیگر دارند، در یک خوش قرار می‌گیرند. در نتیجه، داده‌های موجود در خوشبندی متفاوت کمترین شباهت را با یکدیگر خواهند داشت. هدف در همه الگوریتم‌های خوشبندی کمینه کردن فاصله درون خوشبندی و بیشینه نمودن فاصله بین خوشبندی می‌باشد. عملکرد خوب یک الگوریتم خوشبندی زمانی

1. clustering

محرز می‌شود که تا حد امکان خوشها را از یکدیگر دور کند و علاوه بر آن، رکوردهای موجود در یک خوش بیشترین شباهت را با یکدیگر دارا باشند. طبق تحقیقی که در سال ۲۰۱۲ انجام شده، یکی از کاربردهای خوشبندی، کشف الگو در میان داده‌ها می‌باشد (Liao, Chu, & Hsiao 2012).

۱-۴-۱. الگوریتم TwoStep

این الگوریتم از یک روش خوشبندی دو مرحله‌ای استفاده می‌کند. مرحله اول، با یکبار گذر از داده‌ها، آنها را در مجموعه قابل قبولی از زیرخوشها فشرده می‌کند. قدم دوم، از یک روش خوشبندی سلسه‌مراتبی به منظور ادغام تکاملی این زیرخوشها به خوشها بزرگتر بهره می‌برد (شهرابی ۱۳۹۲). یکی از مزایای این الگوریتم اجرا بر روی مجموعه داده‌های بزرگ است (همان) و آنها را با کارایی زیاد اداره می‌کند (علیزاده ۱۳۹۲).

۱-۵-۱. دریابی

در کشورهای مختلف، داده‌ها و اطلاعات اقیانوسی از منابع مختلف، یا به‌طور مستقیم از اندازه‌گیری‌ها و مطالعات مستمر و یا موردي حاصل می‌شوند و یا ممکن است از دیگر مراکز فعال در حیطه علوم اقیانوسی به دست آیند. بنابراین، منابع داده دریابی یا ملی و یا بین‌المللی هستند. ماهیت منابع داده‌ها و همچنین نوع داده‌ای که حاصل می‌شود، متفاوت است. عمدهً منابع تهیه داده‌های دریابی عبارت‌اند از: اندازه‌گیری‌های ایستگاهی که ممکن است به صورت پروفایل‌های قائم، سری زمانی و یا نمونه‌برداری باشند. ایستگاه‌های اندازه‌گیری، محل‌هایی هستند که در آنها سنجش پارامترهای دریابی به صورت نقطه‌ای انجام می‌شود و داده‌هایی از نوع فیزیک دریا، شیمی دریا و ... برداشت می‌شوند (مرادی ۱۳۸۹). داده‌های دریابی در قالب مجموعه داده‌هایی توسط کشورهای مختلف در محیط‌های آبی در جهان برداشت می‌شوند که معمولاً به نام متولی سازمان برداشت کننده داده یا منطقه جغرافیایی یا گشت دریابی نام‌گذاری می‌شوند. این مجموعه داده‌ها علاوه بر پارامترهای اندازه‌گیری مانند دما و شوری آب شامل مشخصات مکانی ایستگاه اندازه‌گیری می‌باشد که منطقه جغرافیایی ایستگاه، مانند دریای خزر، خلیج فارس و دریای عمان را مشخص می‌کند.

۲-۲. پیشینه تجربی

در ساختار پیشینه تجربی به پژوهش‌هایی پرداخته شده که در داخل و خارج از کشور در زمینه به کار گیری الگوریتم‌های داده‌کاوی در موضوع خوشه‌بندی کاربران انجام شده است.

در سال ۱۳۸۵، تحقیقی با عنوان «خوشه‌بندی و برچسبزنی کاربران وبسایت با استفاده از روش‌های داده‌کاوی» انجام شد. در این تحقیق خوشه‌های بازدیدکنندگان شناسایی شدن و یک تقسیم‌بندی از کاربران بر اساس رفتارشان به دست آمد (اخاکیاز ۱۳۸۵). تحقیق حاضر با هدف استفاده از این تقسیم‌بندی و به منظور هدفمندسازی تبلیغات و سازماندهی مجدد سایت انجام شده است و در این تحقیق الگوریتم خوشه‌بندی کوهونن^۱ به کار گرفته شده است.

در سال ۱۳۸۷، تحقیقی برای دستیابی به ویژگی‌های تقاضای خدمت در بیمه ایران با استفاده از داده‌کاوی انجام شد. در این تحقیق، قواعدی جهت تحلیل رفتار کاربران خدمات بیمه ایران از داده‌های ثبت شده در رکوردهای کاربران استخراج گردید تا مدیران به سمت عرضه خدمات مناسب با خواسته‌های کاربران حرکت نمایند. در این تحقیق از خوشه‌بندی و قانون همبستگی استفاده شده است (حسینی ۱۳۸۷).

در سال ۱۳۸۸، تحقیقی به منظور به کار گیری تکنیک داده‌کاوی برای بهبود مدیریت ارتباط با کاربران در بانک پارسیان انجام شد. با استفاده از داده‌کاوی، روابط بین سرویس‌های مورد علاقه هر خوشه از کاربران کشف گردید تا در به کار گیری استراتژی مناسب برای ارائه سرویس مناسب به کاربران استفاده شود. در این تحقیق از الگوریتم خوشه‌بندی کوهونن و الگوریتم Apriori قوانین همبستگی استفاده شده است (حسینی ۱۳۸۸).²

در سال ۱۳۸۹، تحقیقی با عنوان طراحی مدل دسته‌بندی کاربران «بانک همرا» با استفاده از داده‌کاوی انجام شد. در این تحقیق با استفاده از تکنیک‌های درخت تصمیم، شبکه‌های عصبی مصنوعی و بیز ساده، مشتریان را دسته‌بندی کرده و با توجه به قوانین استخراج شده پیشنهادهایی جهت خدمات بهتر ارائه شده است (قبری ۱۳۸۹).

1. Kohonen

در سال ۱۳۸۹، تحقیقی در رابطه با سرویس دهی بهینه یک شرکت سرویس دهنده اینترنت مبتنی بر داده کاوی انجام شد تا با استفاده از داده‌های تماس پروفایل کاربران، کارایی شرکت را بهبود بخشد. در این تحقیق از الگوریتم درخت تصمیم C5.0 و تلفیق آن با الگوریتم خوشه‌بندی K-Means به منظور تخمین مدت زمان حل مشکلات مشترکان استفاده شده است (کریمی ۱۳۸۹).

در سال ۱۳۸۹، تحقیقی به منظور بخش‌بندی گردشگران بین‌المللی در ایران با استفاده از تکنیک داده کاوی انجام شد تا با شناخت نیازهای گردشگران به مزیت رقابتی دست یابد. در این تحقیق از روش‌های مختلف خوشه‌بندی شامل الگوریتم Kohonen، K-Means و TwoStep استفاده شده است (حاجی‌بابا ۱۳۸۹).

در سال ۱۳۸۹، تحقیقی به منظور شناسایی کاربران بانکداری الکترونیکی بر اساس میزان استفاده آنها از ابزارهای الکترونیکی انجام شد. در این تحقیق ضمن استفاده از الگوریتم K-Means و پروفایل کاربران و بررسی میزان استفاده آنها، خوشه‌بندی انجام شده است (امیری، علیزاده، و لطفی ۱۳۸۹).

در سال ۱۳۹۰، تحقیقی به منظور بخش‌بندی مشتریان لپ‌تاپ در ایران با استفاده از تحلیل توأم و خوشه‌بندی دومرحله‌ای انجام شد. این تحقیق قصد داشت که بر اساس نیازهای مشتریان به آنها خدمات ارائه دهد (اقدامی ۱۳۹۰).

در تحقیقی در سال ۲۰۱۰، از الگوریتم خوشه‌بندی دومرحله‌ای برای شناسایی پروفایل کاربران بانک استفاده شد تا با مدیریت مؤثر کاربران، منابع را بهتر مدیریت کنند. اشاره شده است از آنجا که داده‌های این تحقیق هم پیوسته^۱ و هم ردیابی^۲ هستند، الگوریتم دومرحله‌ای بهترین الگوریتم خوشه‌بندی است (Schiopu 2010).

در سال ۱۳۹۲، تحقیقی انجام شده و با استفاده از الگوریتم K-Means رشته کامپیوتر را بر اساس میزان علاقه به درس برنامه‌نویسی خوشه‌بندی کرده است (شیری‌فر، حسینی، و گلیج ۱۳۹۲).

در تحقیقی در سال ۱۳۹۳، با استفاده از الگوریتم دومرحله‌ای به خوشه‌بندی کاربران تلفن همراه پرداخته شد. این تحقیق متذکر شده است که در روش سنتی خوشه‌بندی

1. continuous
2. categorical

معمولًاً از روش‌های غیرسلسله‌مراتبی مانند K-Means استفاده می‌شده که برای داده‌های بازه‌ای مناسب هستند. لیکن، الگوریتم دو مرحله‌ای برای داده‌های رده‌ای مناسب می‌باشد و همچنین نیازی به تعیین اولیه تعداد خوش‌های ندارد (نبی‌زاده و نجمی ۱۳۹۳). نمونه‌هایی از مطالعات انجام شده در زمینه داده‌کاوی بر روی کاربران و الگوریتم‌های آن در جدول ۱ آورده شده است.

جدول ۱. مطالعات پیشینه تحقیق

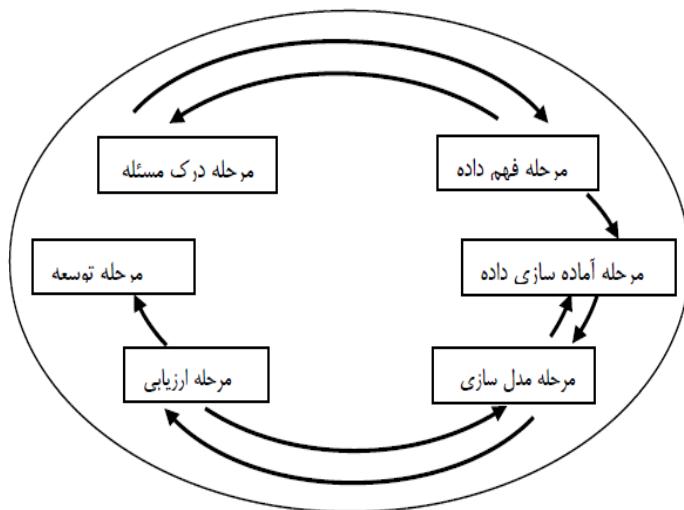
نام محقق	سال	موضوع	تکنیک داده‌کاوی	الگوریتم
خاکباز	۱۳۸۵	داده‌کاوی کاربران خوش‌بندی	خوش‌بندی	کوهونن
حسینی	۱۳۸۷	تحلیل رفتار کاربران خوش‌بندی	خوش‌بندی	
حسینی بامکان	۱۳۸۸	یافتن روابط بین سرویس‌های موردن علاقه کاربران بانک	خوش‌بندی	کوهونن
قنبیری	۱۳۸۹	دسته‌بندی کاربران بانک شبکه‌های عصبی همراه	درخت تصمیم، مصنوعی و بیز ساده	Apriori
کریمی	۱۳۸۹	سروریس دهی بهینه یک شرکت سرویس دهنده اینترنت	درخت تصمیم خوش‌بندی	C5.0 K-Means
حاجی بابا	۱۳۸۹	شناخت نیازهای گردشگران بین‌المللی	خوش‌بندی	K-Means Kohonen TwoStep

نام محقق	سال	موضوع	الگوریتم	تکنیک داده کاوی
امیری و علیزاده و لطیفی	۱۳۸۹	شناسایی کاربران خوشبندی بانکداری الکترونیکی بر اساس میزان استفاده آنها از ابزارهای الکترونیکی	K-Means	خوشبندی
اقدایی	۱۳۹۰	یافتن نیازهای مشتریان لپ تاپ بر اساس نیازهایشان	TwoStep	خوشبندی
Schiopu	۲۰۱۰	شناسایی پروفایل کاربران بانک	TwoStep	خوشبندی
شریفی و حسینی و گلیج	۱۳۹۲	یافتن میزان علاقه به درس برنامه نویسی دانشجویان رشته کامپیوتر	K-Means	خوشبندی
نبی‌زاده و نجمی	۱۳۹۳	خوشبندی کاربران تلفن همراه	TwoStep	خوشبندی
پژوهش حاضر	۱۳۹۳	داده کاوی در کاربران داده های دریابی	TwoStep	خوشبندی

با مرور پژوهش های انجام شده می توان دریافت که از تکنیک داده کاوی در خوشبندی کاربران دریایی تحقیقی انجام نشده است، در حالی که همان گونه که در مقدمه بیان شد، اطلاع از این موضوع حائز اهمیت است. در حوزه های دیگر مطالعات محدودی انجام شده است که تکنیک غالب در این تحقیقات، خوشبندی و الگوریتم های مورد استفاده آنها K-Means و TwoStep Kohonen هستند. جنبه نوآوری این تحقیق «خوشبندی کاربران داده های دریابی با استفاده از تکنیک داده کاوی برای اولین بار در ایران» می باشد.

۳. روش پژوهش

در این تحقیق از مدل استاندارد CRISP-DM^۱ که یکی از روش‌های بسیار قوی در داده‌کاوی است و توسط شرکت‌های دایملر کرایسلر^۲، اس‌پی‌اس‌اس^۳ و ان‌سی‌آر^۴ توسعه یافته، استفاده شده است. این متداول‌ترین از گام‌های شناخت سیستم، در ک داده آماده‌سازی داده‌ها، مدل‌سازی، ارزیابی و توسعه سیستم مطابق شکل ۲ تشکیل شده است.



شکل ۲. مراحل متداول‌ترین CRISP-DM

برای داشتن تحقیقی موفق در زمینه داده‌کاوی، باید متخصص داده‌کاوی از توان و تجربه متخصص کسب و کار در تمام فرایند داده‌کاوی بهره‌مند باشد (رادفر، نظافتی، و یوسفی اصل (۱۳۹۳)).

-
1. Cross Industry Standard Process for Data Mining
 2. Daimler Crysler
 3. SPSS
 4. NCR

۱-۳. شناخت کسب و کار (سیستم):

با توجه به رشد روزافزون تولید داده‌های دریایی و به کارگیری آنها توسط متخصصان علوم دریایی، شناخت رابطه میان کاربر با داده‌ها، می‌تواند هم برای کاربران و هم برای مدیران و تصمیم‌گیران مفید باشد. کاربران با توجه به دسته‌ای که در آن قرار می‌گیرند، می‌توانند از توصیه‌های مدیران دریایی برای استفاده از داده‌های دریایی بهره‌مند شوند و انتخاب صحیحی از داده‌ها برای انجام کارهای تحقیقاتی خود داشته باشند.

هدف داده‌کاوی در این تحقیق «خوشه‌بندی» و نوع آن «توصیفی» است؛ بدین معنا که اطلاعات جدید و غیربدهی را بر اساس مجموعه‌ای از داده‌های موجود ارائه می‌دهد و هدف کلی آن درک و شناخت سیستم‌های تجزیه و تحلیل شده با استفاده از الگوهای روابط موجود است (رادفر، نظافتی، و یوسفی اصل ۱۳۹۳).

کاربران با توجه به خوشه‌های استخراج شده می‌توانند از توصیه‌های مدیران دریایی برای استفاده از داده‌های دریایی بهره‌مند شوند و انتخاب صحیحی از داده‌ها برای انجام کارهای تحقیقاتی خود داشته باشند. مدیران نیز با شناخت تقاضای کاربران می‌توانند برنامه‌استراتژیک خود را پایه‌ریزی نمایند.

۲-۳. درک داده

در این تحقیق از میان جامعه آماری ۶۰۰ کاربر دریایی، اطلاعات و پروفایل ۵۰۰ کاربر که از سال ۱۳۸۶ تا ۱۳۹۳ در پژوهشگاه ملی اقیانوس‌شناسی و علوم جوی جمع‌آوری شده، استفاده شده است. این نمونه آماری به‌دلیل تشابه درخواست‌ها انتخاب شده‌اند و کاربرانی که تقاضاهای خاصی به لحاظ منبع داده، نوع داد، مجموعه داده، پارامتر و منطقه جغرافیایی داشتند، در نظر گرفته نشده‌اند. کاربران داده‌های دریایی را می‌توان به‌طور کلی به سه دسته عمده تقسیم کرد: دانشجویان کارشناسی ارشد و دکترای رشته‌های علوم دریایی، پژوهشگران و سازمان‌های درگیر در فعالیت‌های دریایی.

در این تحقیق برای ارتباط کاربران با داده‌های درخواستی خود، از میان جامعه آماری ۴۰ مجموعه داده، ۱۸ مجموعه داده که محیط‌های آبی ایران در شمال و جنوب را پوشش می‌دادند، از منابع ملی و بین‌المللی با نوع داده‌های فیزیک دریا، شیمی دریا، آلودگی دریا و هواشناسی با پارامترهای مرتبط در نظر گرفته شده است. مجموعه

داده‌هایی که خارج از محدوده آبی کشور ایران بودند و همچنین، مجموعه داده‌هایی که محدوده کوچکی را پوشش می‌دادند، در نظر گرفته نشده‌اند.

۳-۳. آماده‌سازی داده

در این مرحله انتخاب داده، با انتخاب جداول، رکوردها و ویژگی‌ها انجام شده است. در مرحله پاکسازی داده‌ها مشکلات داده‌های پرت^۱ و مقادیر مفقوده^۲ بر طرف شده‌اند. در مرحله یکپارچه‌سازی داده‌ها کلیه داده‌ها از جداول مختلف در یک پایگاه داده مجمع شده‌اند و در کاهش داده فیلدهای نوع کاربر، منبع داده، مجموعه داده، پارامتر و منطقه جغرافیایی از میان فیلدهای مجموعه داده‌ها استخراج شده‌اند.

۴. مدل‌سازی

در این مرحله از تکنیک خوشبندی برای مدل‌سازی استفاده شده است. به‌منظور مدل‌سازی از نرم‌افزار IBM SPSS Modeler که یکی از نرم‌افزارهای مشهور در زمینه داده‌کاوی است، استفاده شده است. با استفاده از این نرم‌افزار سه نوع الگوریتم K-Means و TwoStep برای مدل‌سازی به کار گرفته شده است. هر یک از این سه الگوریتم Kohonen بر روی داده‌ها اعمال شد و با توجه به شاخص‌های ارزیابی بهترین الگوریتم انتخاب شد.

۵. ارزیابی

ارزیابی کیفیت خوشبندی، میزان برتری یک خوشبندی نسبت به خوشبندی‌های دیگر به‌وسیله الگوریتم‌های متفاوت خوشبندی یا الگوریتم‌های مشابه، ولی با مقدار پارامترهای متفاوت می‌باشد (سفیداری، کدخدائی، و شریفی ۱۳۹۲). در این تحقیق از شاخص سیلوئت^۳ به همراه زمان اجرا و تعداد خوشبندی‌ها استفاده شده است.

شاخص سیلوئت:

شاخص تراکم و جدایی سیلوئت با مقادیر ضعیف^۴، متوسط^۵ و خوب^۶ نشان داده

-
- 1. outlier data
 - 2. missing value
 - 3. Silhouette
 - 4. poor
 - 5. fair
 - 6. good

می‌شود. میانگین مقدار شاخص سیلوئت برای ارزیابی اعتبار خوشبندی و همچنین برای تصمیم‌گیری در مورد انتخاب تعداد کلاس‌های بهینه مورد استفاده قرار می‌گیرد که این میزان بر اساس دوری و نزدیکی مشاهدات و خوشباه به یکدیگر محاسبه می‌شود. مقدار $S(i)$ با استفاده از فرمول ۱ قابل محاسبه است:

$$S(i) = \frac{(b(i)-a(i))}{\max(a(i), b(i))} \quad \text{فرمول ۱}$$

$a(i)$ میانگین فاصله بین مشاهده‌ها با سایر مشاهدات در یک خوشبندی مشابه و $b(i)$ میانگین فاصله مشاهده‌ها با تمام مشاهدات در خوشباه دیگر می‌باشد. بر اساس فرمول بالا مقدار $S(i)$ بین -1 و $+1$ قرار دارد. اگر $S(i)$ به $+1$ نزدیک‌تر باشد، به این معنی است که خوشبندی نمونه خوب صورت گرفته است و خوشباه داشده برای نمونه مورد نظر مناسب می‌باشد، ولی اگر $S(i)$ به -1 نزدیک‌تر باشد، به این معنی است که خوشبندی نمونه، به خوبی انجام نشده و خوشباه داشده برای داده مورد نظر نامناسب می‌باشد. با مقایسه سه معیار شاخص سیلوئت، زمان اجرا و تعداد خوشباه، الگوریتم TwoStep مطابق جدول ۲ برای خوشبندی نوع کاربران با داده‌های درخواستی انتخاب شد.

جدول ۲. معیارهای ارزیابی در الگوریتم TwoStep برای خوشبندی نوع کاربر و منبع داده

مدل‌سازی	معیار	زمان اجرا (ثانیه)	تعداد خوشباه	شاخص سیلوئت
نوع کاربر با منبع داده	۱	۴	۰/۹	
نوع کاربر با نوع داده	۱	۵	۱	
نوع کاربر با مجموعه داده	۲	۵	۰/۶	
نوع کاربر با پارامتر	۵	۱۰	۰/۳	
نوع کاربر با منطقه جغرافیایی	۱	۵	۰/۸	

یکی از مزایای این الگوریتم، اجرا بر روی مجموعه داده‌های بزرگ است (شهرابی ۱۳۹۲)، و آنها را با کارایی زیاد اداره می‌کند (علیزاده ۱۳۹۲). از دیگر نقاط قوت آن این است که قادر به مدیریت داده‌هایی با انواع مختلف فیله‌است.

در تحقیقی که در سال ۱۳۹۰ انجام شده، از الگوریتم TwoStep برای خوشبندی خلیج چابهار بر اساس چگالی استفاده شده است (وفایی و همکاران ۱۳۹۲).

۴. تجزیه و تحلیل یافته‌ها

در این بخش از پژوهش، الگوریتم پذیرفتشده در بخش مدل‌سازی تحقیق روی داده‌ها اعمال شده و نتایج حاصل از آنها در قالب نمودار و جدول ارائه شده است. الگوریتم TwoStep نوعی تحلیل خوشبندی است که از فیلد هدف استفاده نمی‌کند. این خوشبندی یک روش خوشبندی دو مرحله‌ای است. گام اول، با یک گذر از روی داده‌های ورودی، آنها را به زیرخوشه‌های قابل مدیریت فشرده می‌کند. گام دوم، از یک روش خوشبندی سلسله‌مراتبی به منظور ادغام تکاملی این زیرخوشه‌ها به خوشه‌های بزرگ‌تر بهره می‌برد.

◇ نتایج خوشبندی نوع کاربر با منبع داده

با انتخاب الگوریتم TwoStep به عنوان الگوریتم بهینه در زمان ارزیابی مدل، نتایج خوشبندی مطابق جدول ۳ به دست آمد.

جدول ۳. نتایج خوشبندی نوع کاربر با منبع داده با الگوریتم TwoStep

نام خوشبندی	نوع کاربر	منبع داده	سایز خوشه‌ها به درصد
خوشة ۱	دانشجو	بین‌المللی	۵۲/۲
خوشة ۳	سازمان	بین‌المللی	۲۱/۱
خوشة ۴	پژوهشگر	بین‌المللی	۱۶/۹
خوشة ۲	دانشجو	ملی	۹/۸

چهار خوشبندی نوع کاربر با منبع داده به دست آمد که بر اساس میزان تقاضا به ترتیب از زیاد به کم به شرح زیر بودند:

خوشة ۱: نوع کاربر دانشجو با منبع داده بین‌المللی

خوشة ۳: نوع کاربر سازمان با منبع داده بین‌المللی

خوشة ۴: نوع کاربر پژوهشگر با منبع داده بین‌المللی

خوشة ۲: نوع کاربر دانشجو با منبع داده ملی

از تحلیل خوشبندی‌های فوق، نتایج و الگوهای زیر به دست آمد:

نتیجه ۱: منابع بین‌المللی چون در اندازه‌گیری‌های خود، مناطق وسیع‌تر و ابزارهای

اندازه‌گیری دقیق‌تری را در برمی‌گیرند، تقاضای بیشتری در میان سه نوع کاربر به نسبت سایر منابع داده برخوردار هستند.

نتیجه ۲: منابع ملی و ملی-بین‌المللی از تقاضای کمتری برخوردار هستند.

◊ نتایج خوشه‌بندی نوع کاربر با نوع داده

با انتخاب الگوریتم TwoStep به عنوان الگوریتم بهینه در زمان ارزیابی مدل، نتایج خوشه‌بندی مطابق جدول ۴ به دست آمد.

جدول ۴. نتایج خوشه‌بندی نوع کاربر با نوع داده با الگوریتم TwoStep

نام خوشه به ترتیب اندازه	نوع کاربر	نوع داده	سایز خوشه‌ها به درصد
خوشه ۲	دانشجو	شیمی دریا	۳۵/۳
خوشه ۱	دانشجو	فیزیک دریا	۲۰/۹
خوشه ۳	پژوهشگر	شیمی دریا	۱۵/۷
خوشه ۵	سازمان	شیمی دریا	۱۵/۱
خوشه ۴	سازمان	فیزیک دریا	۱۳/۱

پنج خوشه بر اساس نوع کاربر با نوع داده به دست آمد که بر اساس میزان تقاضا به ترتیب از زیاد به کم به شرح زیر بودند:

خوشه ۲: نوع کاربر دانشجو با نوع داده شیمی دریا

خوشه ۱: نوع کاربر دانشجو با نوع داده فیزیک دریا

خوشه ۳: نوع کاربر پژوهشگر با نوع داده شیمی دریا

خوشه ۵: نوع کاربر سازمان با نوع داده شیمی دریا

خوشه ۴: نوع کاربر سازمان با نوع داده فیزیک دریا

از تحلیل خوشه‌بندی‌های فوق، نتایج و الگوهای زیر به دست آمد:

نتیجه ۱: بیشترین تقاضای داده از نظر نوع کاربر با دانشجویان با نوع داده شیمی دریا می‌باشد.

نتیجه ۲: بیشترین تقاضای داده از نظر هر ۳ نوع کاربر داده دانشجویان، پژوهشگران و سازمان‌ها با نوع داده شیمی دریا می‌باشد.

نتیجه ۳: از آنجا که مجموعه داده‌های شیمی دریا و فیزیک دریا به عنوان نوع داده‌های اساسی در مطالعات دریایی هستند، از اهمیت بیشتری برای دانشجویان، پژوهشگران و سازمان‌ها برخوردار می‌باشد.

نتیجه ۴: اندازه گیری‌های نوع داده زمین شناسی، ژئوفیزیک و ... پیچیده‌تر و مشکل‌تر از نوع داده شیمی و فیزیک می‌باشد.

◊ نتایج خوشبندی نوع کاربر با مجموعه داده با انتخاب الگوریتم TwoStep به عنوان الگوریتم بهینه در زمان ارزیابی مدل، نتایج خوشبندی مطابق جدول ۵ به دست آمد.

جدول ۵. نتایج خوشبندی نوع کاربر با مجموعه داده با الگوریتم TwoStep

نام خوش بے ترتیب اندازه	نوع کاربر	مجموعه داده	سایز خوش‌ها به درصد
خوشة ۲	دانشجو	پایگاه داده اقیانوسی جهانی	۲۵/۱
خوشة ۱	سازمان	پایگاه داده اقیانوسی جهانی	۲۴/۷
خوشة ۳	پژوهشگر	پایگاه داده اقیانوسی جهانی	۱۸/۱
خوشة ۵	دانشجو	پایگاه داده مرکز داده هند	۱۷/۲
خوشة ۴	دانشجو	پایگاه داده اقیانوسی جهانی	۱۴/۹

پنج خوش برد اساس نوع کاربر با مجموعه داده به دست آمد که بر اساس میزان تقاضا به ترتیب از زیاد به کم به شرح زیر بودند:

خوشة ۲: نوع کاربر دانشجو با مجموعه داده پایگاه داده اقیانوسی جهانی

خوشة ۱: نوع کاربر سازمان با مجموعه داده پایگاه داده اقیانوسی جهانی

خوشة ۳: نوع کاربر پژوهشگر با مجموعه داده پایگاه داده اقیانوسی جهانی

خوشة ۵: نوع کاربر دانشجو با مجموعه داده پایگاه داده مرکز داده هند

خوشة ۴: نوع کاربر دانشجو با مجموعه داده پایگاه داده اقیانوسی جهانی

از تحلیل خوشبندی‌های فوق، نتایج و الگوهای زیر به دست آمد:

نتیجه ۱: بیشترین تقاضای داده از نظر نوع کاربر با دانشجویان با مجموعه داده «پایگاه داده

اقیانوسی جهانی» در دریای خزر می‌باشد.

نتیجه ۲: بیشترین تقاضای داده از نظر هر ۳ نوع کاربر داده دانشجویان، سازمان‌ها و پژوهشگران با مجموعه داده «پایگاه داده اقیانوسی جهانی» می‌باشد.

نتیجه ۳: «پایگاه داده اقیانوسی جهانی» بدلیل وسعت مناطق جغرافیایی، تاریخی بودن و تعدد پارامترهای اندازه‌گیری، مجموعه داده غنی برای کاربران مختلف می‌باشد.

◇ نتایج خوشه‌بندی نوع کاربر با پارامتر با انتخاب الگوریتم TwoStep به عنوان الگوریتم بهینه در زمان ارزیابی مدل، نتایج خوشه‌بندی مطابق جدول ۶ به دست آمد.

جدول ۶. نتایج خوشه‌بندی نوع کاربر با پارامتر با الگوریتم TwoStep

نام خوشه به ترتیب اندازه	نوع کاربر	پارامتر	سایز خوشه‌ها به درصد
۶ خوشه	سازمان	نیترات	۱۴/۰
۲ خوشه	دانشجو	دمای آب	۱۳/۸
۱۰ خوشه	پژوهشگر	شوری	۱۰/۸
۱ خوشه	دانشجو	شوری	۹/۷
۳ خوشه	دانشجو	اکسیزن	۹/۵
۹ خوشه	سازمان	دمای آب	۸/۹
۷ خوشه	دانشجو	آلکالینیتی	۸/۶
۵ خوشه	دانشجو	نیترات	۸/۵
۴ خوشه	دانشجو	سیلیکات	۸/۳
۸ خوشه	پژوهشگر	دمای آب	۷/۹

د خوشه بر اساس نوع کاربر با پارامتر به دست آمد که بر اساس میزان تقاضا به ترتیب از زیاد به کم به شرح زیر بودند:

خوشه ۶: نوع کاربر سازمان با پارامتر نیترات

خوشه ۲: نوع کاربر دانشجو با پارامتر دمای آب

خوشه ۱۰: نوع کاربر پژوهشگر با پارامتر شوری

خوشة ۱: نوع کاربر دانشجو با پارامتر شوری

خوشة ۳: نوع کاربر دانشجو با پارامتر اکسیژن

خوشة ۹: نوع کاربر سازمان با پارامتر دمای آب

خوشة ۷: نوع کاربر دانشجو با پارامتر آلکالینیتی

خوشة ۵: نوع کاربر دانشجو با پارامتر نیترات

خوشة ۸: نوع کاربر دانشجو با پارامتر سیلیکات

خوشة ۶: نوع کاربر پژوهشگر با پارامتر دمای آب

نتیجه ۱: بیشترین تقاضای داده از نظر نوع کاربر سازمان‌ها با پارامتر نیترات و سپس نوع کاربر دانشجو با پارامتر دمای آب و شوری می‌باشد.

نتیجه ۲: پارامترهای دمای آب و شوری از پارامترهای اصلی مطالعات دریابی می‌باشند.

نتیجه ۳: دسترسی و اندازه‌گیری سایر پارامترها به سختی انجام می‌شود.

نتیجه ۴: پارامترهای شیمی دریا و فیزیک دریا از اهمیت بیشتری برای کاربران داده برخوردار می‌باشد.

◇ نتایج خوشبندی نوع کاربر با منطقه جغرافیایی

با انتخاب الگوریتم TwoStep به عنوان الگوریتم بهینه در زمان ارزیابی مدل، نتایج

خوشبندی مطابق جدول ۷ به دست آمد.

جدول ۷. نتایج خوشبندی نوع کاربر با منطقه جغرافیایی با الگوریتم TwoStep

خوشة	نوع کاربر	منطقه جغرافیایی	سایز خوشه‌ها به درصد
خوشة ۳	دانشجو	خلیج فارس	۱۴/۰
خوشة ۱	سازمان	خلیج فارس	۱۳/۸
خوشة ۴	دانشجو	دریای خزر	۱۰/۸
خوشة ۲	پژوهشگر	دریای خزر	۹/۷
خوشة ۵	دانشجو	دریای عمان	۹/۵

پنج خوش بر اساس نوع کاربر با منطقه جغرافیایی به دست آمد که بر اساس میزان تقاضا به ترتیب از زیاد به کم به شرح زیر بودند:

خوشة ۳: نوع کاربر دانشجو با منطقه خلیج فارس

خوشة ۱: نوع کاربر سازمان با منطقه خلیج فارس

خوشة ۴: نوع کاربر دانشجو با منطقه دریای خزر

خوشة ۲: نوع کاربر پژوهشگر با منطقه دریای خزر

خوشة ۵: نوع کاربر دانشجو با منطقه دریای عمان

نتیجه ۱: بیشترین تقاضای داده از نظر نوع کاربر دانشجویان و سازمان‌ها با منطقه خلیج فارس می‌باشد.

نتیجه ۲: خلیج فارس به دلیل موقعیت اقتصادی، استراتژیک و ژئولوژیک از اهمیت بیشتری میان کاربران داده برخوردار است.

نتیجه ۳: تقاضای داده از نظر ۲ نوع کاربر دانشجویان و پژوهشگران با منطقه دریای خزر در اولویت بعدی می‌باشد.

نتیجه ۴: دسترسی به داده‌های دریای خزر از طریق کشورهای حاشیه آن مشکل‌تر می‌باشد.

نتیجه ۵: دسترسی به خلیج فارس و دریای خزر از نظر کار تحقیقاتی نسبت به دریای عمان ساده‌تر است.

نتیجه ۶: دسترسی به داده‌های دریای عمان به دلیل عمق زیاد و عدم همکاری کشورهای پاکستان و هند در تبادل داده مشکل می‌باشد.

نتیجه ۷: در دریای عمان، شکاف کار تحقیقاتی وجود دارد.

◇ بروزی اعتبار الگوهای کشف شده

داده‌های تحقیق با استفاده از روش داده کاوی به الگوهای جدید تبدیل می‌شود. در واقع، الگوهای جدید همان اطلاعات هستند. با ارائه این اطلاعات به خبرگان علوم دریایی و تأیید نتایج توسط آنها این اطلاعات تبدیل به دانش می‌شود. اعتبار نتایج به دست آمده، توسط ۵ نفر از اعضای هیئت علمی پژوهشگاه تأیید شد.

۵. نتیجه‌گیری

از تحلیل خوشه‌بندی نوع کاربران با داده‌های درخواستی آنها، با کمک فرد خبره نتایج و الگوهایی در علوم دریابی به شرح زیر به دست آمد:

منابع بین‌المللی چون در اندازه‌گیری‌های خود، مناطق وسیع‌تر و ابزارهای اندازه‌گیری دقیق‌تری را دربرمی‌گیرند، از تقاضای بیشتری در میان سه نوع کاربر به نسبت منابع ملی برخوردار هستند. بیشترین تقاضای داده از نظر هر سه نوع کاربر داده دانشجویان، پژوهشگران و سازمان‌ها با نوع داده شیمی دریا می‌باشد. از آنجا که مجموعه داده‌های شیمی دریا و فیزیک دریا به عنوان نوع داده‌های اساسی در مطالعات دریابی هستند، از اهمیت بیشتری برای کاربران برخوردار می‌باشند. بیشترین تقاضای داده از نظر هر سه نوع کاربر داده با مجموعه داده «پایگاه داده اقیانوسی جهانی» می‌باشد. این پایگاه داده، به دلیل وسعت مناطق جغرافیایی، تاریخی بودن داده‌ها و تعدد پارامترهای اندازه‌گیری، مجموعه داده‌غذی برای کاربران مختلف می‌باشد. بیشترین تقاضای داده از نظر نوع کاربر سازمان‌ها با پارامتر نیترات و سپس نوع کاربر دانشجو با پارامتر دمای آب و شوری می‌باشد. پارامترهای دمای آب و شوری از پارامترهای اصلی مطالعات دریابی می‌باشند. دسترسی و اندازه‌گیری سایر پارامترها، به سختی انجام می‌شود. بیشترین تقاضای داده از نظر نوع کاربر دانشجویان و سازمان‌ها با منطقه خلیج فارس می‌باشد. خلیج فارس به دلیل موقعیت اقتصادی، استراتژیک و ژئوپلیتیک از اهمیت بیشتری میان کاربران داده برخوردار است. دسترسی به داده‌های دریای خزر از طریق کشورهای حاشیه آن مشکل تر می‌باشد. هند در تبادل داده مشکل می‌باشد. در دریای عمان، شکاف کار تحقیقاتی وجود دارد.

فوايد اين الگوها برای پژوهشگاه ملی اقیانوس‌شناسی و علوم جوی اين است که می‌توانند سرمایه‌گذاری مالی و انسانی بیشتری برای جمع‌آوری داده‌های بین‌المللی، شیمی دریا، فیزیک دریا، مجموعه داده «پایگاه داده اقیانوسی جهانی»، پارامترهای دما، شوری و منطقه خلیج فارس نمایند و از سرمایه‌گذاری برای سایر منابع، نوع داده، مجموعه داده‌ها، پارامترها و مناطق دریابی پرهیز نمایند.

در این قسمت با توجه به تجزیه و تحلیل داده‌ها و نتایج حاصل از طرح به سؤالات تحقیق پاسخ داده می‌شود.

سؤال اصلی: چه الگویی بین کاربران داده با نوع داده، مجموعه داده، پارامترهای داده، منبع داده و منطقه جغرافیایی وجود دارد؟

پاسخ سؤال اصلی: از خوشهای به دست آمده و نتایج حاصل از آنها می‌توان دریافت که به طور خلاصه، الگوی بین کاربران با منبع داده این است که منابع بین‌المللی، تقاضای بیشتری در میان سه نوع کاربر به نسبت سایر منابع داده برخوردار هستند. الگوی بین کاربران با نوع داده این است که بیشترین تقاضای داده از نظر هر ۳ نوع کاربر داده با نوع داده شیمی دریا می‌باشد. الگوی بین کاربران با مجموعه داده این است که بیشترین تقاضای داده از نظر هر ۳ نوع کاربر داده با مجموعه داده «پایگاه داده اقیانوسی جهانی» می‌باشد. الگوی بین کاربران با پارامتر این است که پارامترهای شیمی دریا و فیزیک دریا از اهمیت بیشتری برای کاربران داده، برخوردار می‌باشند. و در نهایت، الگوی بین کاربران با مناطق جغرافیایی این است که خلیج فارس به دلیل موقعیت اقتصادی، استراتژیک و ژئوپلیتیک از اهمیت بیشتری میان کاربران داده برخوردار است.

سؤال فرعی: چه استفاده مدیریتی می‌توان از داده کاوی بر روی کاربران داده در پژوهشگاه ملی اقیانوس‌شناسی و علوم جوی نمود؟

پاسخ سؤال فرعی: با توجه به الگوهای به دست آمده، مدیران ارشد که در گیر فعالیت‌های تصمیم‌گیری هستند و همچنین، مدیران فناوری اطلاعات که در فرایند مدیریت داده‌های دریایی فعالیت می‌کنند، قادر خواهند بود به درستی در مورد داده‌های موجود خود و برنامه‌ریزی برای جمع‌آوری داده در آینده تصمیم‌گیری کنند و در کم بهتری از نیازهای کاربران خود داشته باشند. اطلاع از این موضوع نیز از آنجا اهمیت دارد که شناخت نیاز کاربران، موجب خواهد شد با مدیریت مناسب داده‌های دریایی، درجهت جلب رضایت کاربران گام برداشته شود و سرمایه‌های سازمانی به درستی استفاده شود. بدین ترتیب، از تمرکز روی جمع‌آوری داده‌های کم استفاده یا بدون استفاده جلوگیری خواهد شد.

با توجه به نتایج فوق، به مدیران ارشد پژوهشگاه ملی اقیانوس‌شناسی و علوم جوی و سایر ارگان‌های دریایی کشور که در گیر فعالیت‌های تصمیم‌گیری هستند، همچنین مدیران فناوری اطلاعات که در فرایند مدیریت داده‌های دریایی فعالیت می‌کنند، و کاربران داده که استفاده کننده داده‌ها هستند، پیشنهاد می‌شود:

۱. علاوه بر تقویت و بروزرسانی بانک اطلاعات دریایی پژوهشگاه با داده‌های منابع بین‌المللی، به کارهای میدانی، برگزاری گشتهای دریایی داخلی، و تقویت منابع داده ملی توسط ارگان‌های دریایی پرداخته شود.
 ۲. به دلیل تقاضای بیشتر نوع داده شیمی دریا، فیزیک دریا و پارامترهای نیترات، دمای آب، و شوری به اندازه‌گیری مستمر این داده‌ها پرداخته شود. همچنین، به جمع آوری داده در مناطق خلیج فارس و دریای خزر و تقویت بانک اطلاعاتی خود در این زمینه پردازند و هزینه کمتری در جمع آوری داده در مناطق دریایی عمان و دریایی عرب صرف نمایند.
 ۳. دانشجویان تحصیلات تکمیلی، پژوهشگران و سازمان‌ها برای دسترسی آسان‌تر و بیشتر به منابع تحقیقاتی می‌توانند نوع داده مورد مطالعه خود را شیمی و فیزیک دریا و پارامترهای مورد مطالعه خود را نیترات، دمای آب، و شوری و مناطق مورد مطالعه خود را در خلیج فارس و دریای خزر تعریف نمایند.
 ۴. دانشجویان تحصیلات تکمیلی، پژوهشگران و سازمان‌ها به منظور انجام کار تحقیقاتی بدیع و تازه می‌توانند نوع داده مورد مطالعه خود را بیولوژی دریا، آلودگی دریا، زمین‌شناسی و ژئوفیزیک دریایی و پارامتر مورد مطالعه خود را از میان این نوع داده‌ها و مناطق مورد مطالعه خود را در دریای عمان و دریایی عرب تعریف نمایند.
 ۵. پژوهشگاه به دریافت مستمر مجموعه داده «پایگاه داده اقیانوسی جهانی» که از اهمیت بهسزایی در میان کاربران داده برخوردار است و به روزرسانی بانک اطلاعاتی با مجموعه داده فوق اقدام نماید.
 ۶. پیشنهاد می‌شود، سازمان‌های دریایی به ایجاد مجموعه داده تاریخی ملی، مشابه «پایگاه داده اقیانوسی جهانی» (که منع آن بین‌المللی می‌باشد) پردازند.
- در انتها از آنجا که داده‌های این تحقیق متعلق به داده‌های پژوهشگاه ملی اقیانوس‌شناسی و علوم جوی است، پیشنهاد می‌شود تحقیقی با روش‌های به کاررفته در این تحقیق، در سایر سازمان‌های دریایی انجام گیرد و نتایج آن با نتایج این تحقیق مقایسه شود. در صورتی که مدیران ارشد پژوهشگاه ملی اقیانوس‌شناسی و علوم جوی به مطالعه الگوهای تقاضای کاربران داده تمایل داشته باشند، می‌توان درخواست‌های کاربران را در

سال‌های پس از ۱۳۹۳ نیز بررسی کرده و از نتایج آنها در تدوین چشم‌انداز و برنامه‌های راهبردی پژوهشگاه استفاده نمایند.

فهرست منابع

- اقدابی، محمدحسن. ۱۳۹۰. بخش‌بندی منافعی مشتریان لپ‌تاپ در ایران با استفاده از تحلیل توأم و خوشبندی دو مرحله‌ای. آمل. دانشگاه شمال.
- امیری، فهیمه، سمیه علیزاده، و فریبا طفی. ۱۳۸۹. تحلیل و شناسایی رفتار مشتریان با انکاری الکترونیکی با استفاده از داده کاوی. چهارمین کنفرانس بین‌المللی مدیریت بازاریابی، تهران.
- حاجی‌بابا، هما. ۱۳۸۹. بخش‌بندی گردشگران بین‌المللی در ایران با استفاده از تکنیک داده کاوی. تهران: دانشگاه الزهرا.
- حسینی، زهرا. ۱۳۸۷. به کارگیری فرایند داده کاوی برای دستیابی به ویژگی‌های تقاضای خدمت. مشهد: دانشگاه فردوسی مشهد.
- حسینی بامکان، سیدمجتبی. ۱۳۸۸. به کارگیری تکنیک‌های داده کاوی جهت بهبود مدیریت ارتباط با مشتری در صنعت با انکاری. تهران: دانشگاه علامه طباطبائی.
- خاکباز، محمدحسین. ۱۳۸۵. خوشبندی وبر چسب‌زنی کاربران وب‌سایت با استفاده از روش‌های داده کاوی. تهران: دانشگاه تربیت مدرس.
- رادفر، رضا، نوید نظافتی، و سعید یوسفی اصلی. ۱۳۹۳. طبقه‌بندی مشتریان با انک کمک الگوریتم‌های داده کاوی. مجله مدیریت فناوری اطلاعات. دوره ۶. شماره ۱. صص ۷۱-۹۰.
- سفیداری، ابراهیم، علی کدخدائی، و محمد شریفی. ۱۳۹۲. مقایسه روش‌های شبکه عصبی خودسازنده و آنالیز خوشبندی برای ارزیابی مقدار کربن آلی در سازنده‌های محتوی هیدروکربن با استفاده از سیستم‌های هوشمند. پژوهشنامه نفت. سال پیست و سوم. شماره ۷۵. صفحه ۱۱۷-۱۳۰.
- شریفی، ابوصالح محمد، سیدمهدي حسيني، و ابراهيم گلبيج. ۱۳۹۲. استفاده از الگوریتم K-Means خوشبندی دانشجویان رشته کامپیوتر بر اساس میزان علاقه‌مندی و عوامل مؤثر بر یادگیری دروس برنامه‌نویسی. اولین کنفرانس ملی نوآوری در مهندسی کامپیوتر و فناوری اطلاعات. تکابن.
- شهرابی، جمال. ۱۳۹۲. داده کاوی و کشف دانش گام به گام با نرم‌افزار. تهران: دانشگاه صنعتی خواجه نصیرالدین طوسی.
- غضنفری، مهدی. ۱۳۸۷. داده کاوی و کشف دانش. تهران: دانشگاه علم و صنعت.

- قبری، محمد حسام. ۱۳۸۹. طراحی مدل دسته‌بندی کاربران بانک همراه با استفاده از الگوریتم داده کاوی. تهران: دانشگاه تربیت مدرس.
- کریمی، فائزه. ۱۳۸۹. ارائه راهکار مناسب در راستای سرویس‌دهی بهینه مرکز تماس یک شرکت ISP ایرانی مبتنی بر داده کاوی. تهران: دانشگاه تربیت مدرس.
- مرادی، مسعود. ۱۳۸۹. مدیریت داده‌های آقیانوس‌شناسی. تهران: مسعود مرادی.
- نبی‌زاده، محمد، و منوچهر نجمی. ۱۳۹۲. ارائه روشی نوین در خوشبندی بازار خدمات تلفن همراه با استفاده از داده کاوی. تهران: دانشگاه صنعتی شریف.
- وفایی، بشار، وحید چگینی، عباس سقایی، و مجتبی عظام. ۱۳۹۲. دسته‌بندی توده‌های آب در خلیج چابهار با استفاده از روش خوشبندی آقیانوس‌شناسی. سال چهارم. شماره ۱۳. صفحه ۱۹-۱۱.
- Fayyad, U., G. Piatetsky-Shapiro, and P. Smyth. 1996. From data mining to knowledge discovery in databases. *AI magazine* 17 (3): 37 .
- Lai, X.-a. 2009. *Segmentation Study on Enterprise Customers Based on Data Mining Technology*. Paper presented at the First International Workshop on Database Technology and Applications.
- Liao, S.-H., P-H. Chu, and P-Y. Hsiao. 2012. Data mining techniques and applications—A decade review from 2000 to 2011. *Expert Systems with Applications* 39 (12): 11303-11311 .
- Schiopu, D. 2010. Applying TwoStep cluster analysis for identifying bank customers' profile. *Stiinte Economice* 1.LXII, 66-75.