

ارائه یک الگوریتم خوشه‌بندی مبتنی بر چگالی توسعه‌یافته در کلان داده‌ها

رضا قائمی*

استادیار، گروه مهندسی کامپیوتر، واحد قوچان، دانشگاه آزاد اسلامی، قوچان، ایران

بعقوب آزاد

مدیریت

اطلاعات

دوره ۸، شماره ۲

پاییز و زمستان ۱۴۰۱

دانشجوی دکتری، گروه مهندسی کامپیوتر، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی،

نیشابور، ایران

فرشته حاج قاضی

دانشجوی دکتری، گروه مهندسی کامپیوتر، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، نیشابور، ایران

چکیده: امروزه تولید داده از طریق تجهیزات هوشمند، از جمله تلفن‌های همراه، با رشد چشم‌گیری رویه‌رو بوده و خوشه‌بندی یکی از تکنیک‌های پرکاربرد کشف دانش در کلان داده‌ها است. خوشه‌بندی مبتنی بر چگالی (DBSCAN)، از الگوریتم‌های خوشه‌بندی کارا در داده‌کاوی بوده و با وجود داشتن مزایا، دارای مشکلاتی از جمله سختی در تعیین پارامترهای ورودی و همچنین، نداشتن توانایی در کشف خوشه‌هایی با چگالی متفاوت نیز هست. در الگوریتم پیشنهادی این مقاله، از الگوریتم K-DBSCAN در گروه‌بندی داده‌های حجمی با هدف کاهش زمان اجرای خوشه‌بندی الهام گرفته شده است. به علاوه، با استفاده از الگوریتم‌های K-Means و H-DBSCAN، چگالی‌های مختلف مجموعه‌داده تشخیص داده می‌شود، برای هر چگالی یک شاعع Eps تعیین شده و سپس، الگوریتم پیشنهادی خوشه‌بندی مبتنی بر چگالی توسعه‌یافته با پارامترهای منطبق روی داده‌ها اعمال می‌شود. در واقع، نوآوری این مقاله استفاده از خوشه‌بندی K-Means و تخمین چگالی‌های مختلف در روش خوشه‌بندی DBSCAN است. الگوریتم پیشنهادی روی چهار مجموعه‌داده استاندارد Shuttle، Pendigit، Letters و Image segmentation مقایسه شده است. نتایج نشان می‌دهد که الگوریتم پیشنهادی در زمانی که هر دو معیار زمان و دقت در خوشه‌بندی ملک باشند، در مقایسه با الگوریتم‌های دیگر، الگوریتم برتری است.

کلیدواژه‌ها: کلان داده‌ها، خوشه‌بندی، K-Means، H-DBSCAN، K-DBSCAN، DBSCAN

مقدمه

امروزه، با رشد اینترنت و شبکه‌های اجتماعی با حجم زیادی از داده‌ها مواجه هستیم؛ به همین دلیل، سیستم‌ها و الگوریتم‌های سنتی نمی‌توانند در زمان‌های پذیرفته‌شده‌ای پاسخ‌گو باشند. الگوریتم‌های سنتی یادگیری ماشین نیز از این قاعده مستثنا نبوده و روی داده‌های بزرگ با استفاده از یک ماشین تک‌پردازnde اجرایی نیستند (Li, 2020). بنابراین، روش‌هایی وجود دارد که الگوریتم‌ها را بهینه‌تر کرده و سرعت اجرای آنها را افزایش دهد. برای تکنیک خوشبندی، الگوریتم‌های مختلفی ارائه شده است که می‌توان از الگوریتم‌های^۱ DBSCAN (Li, 2020) و K-Means (De Moura Ventorim, et al., 2021) به عنوان روش‌های رایج این زمینه اشاره کرد.

الگوریتم پایه روش‌های خوشبندی، مبتنی بر چگالی DBSCAN است (Li, 2020). این الگوریتم قابلیت کشف خوشبندی با اندازه و اشکال متفاوت از حجم زیادی از داده‌ها را دارد و در مقابل نویز نیز مقاوم است (Sharma, & Upadhyay, 2018). به رغم وجود این مزایا، این الگوریتم چند مشکل اساسی نیز دارد. نخست، به دو پارامتر ورودی Minpts و Eps نیاز داشته که تعیین مقدار دقیق این پارامترها به خصوص در پایگاه‌داده‌هایی با حجم بالا بسیار دشوار است. دوم، این الگوریتم قابلیت کشف خوشبندی با چگالی متفاوت را ندارد (Wang, Gu & Shun, 2020).

برای داده‌های حجمی بسیار کند بوده و پیچیدگی بالایی دارد. به همین دلیل، برای داده‌های بزرگ نمی‌توان از آن بهره‌هایی استفاده کرد (Li, 2020). از طرفی دیگر، K-Means نیز یکی از الگوریتم‌های پرکاربرد شناخته‌شده مبتنی بر مرکزیت است که تلاش می‌کند مجموع مربعات فواصل اقلیدسی^۲ را از مرکز هر خوشبندی حداقل کند (Sheridan et al., 2020). هدف این مقاله، گروه‌بندی کلان‌داده‌ها در کمترین زمان و با دقت بالا با استفاده از الگوریتم K-Means و برگرفته شده از الگوریتم‌های مختلف مجموعه‌داده را تشخیص داده و برای داده‌ها اهمیت دارد و در ایجاد خوشبندی این مقاله، ابتدا داده‌ها با استفاده از K-Means و با یک تکرار مشخص خوشبندی می‌شوند، سپس چگالی مختلف مجموعه‌داده‌ها تشخیص داده شده و در هر یک از خوشبندی‌های ایجاد شده به صورت جداگانه اعمال می‌شود. در واقع، نوآوری در روش پیشنهادی، استفاده از خوشبندی K-Means و تخمین چگالی‌های متفاوت در خوشبندی DBSCAN در این مقاله، رفع مشکل سرعت و تغییرات چگالی الگوریتم DBSCAN است.

در ادامه این مقاله، در بخش ۲ برخی از توسعه و بهبودهای ارائه شده برای الگوریتم DBSCAN معرفی شده است. در بخش ۳ روش پیشنهادی تشریح شده است. در بخش ۴ نتایج آزمایش‌ها ارزیابی شده و در نهایت، در بخش ۵ به نتیجه‌گیری و کارهای آینده پرداخته شده است.

1. Density-based spatial clustering of applications with noise (DBSCAN)

2. Euclidean

پیشینه پژوهش

آنکرست و همکاران^۱ (1999)، نخستین بهبود برای رفع مشکل تغییرات چگالی الگوریتم DBSCAN را با عنوان الگوریتم OPTICS ارائه دادند. هدف کلیه بهبودهای ارائه شده عبارت است از: افزایش دقیقی الگوریتم و به طور همزمان، کاهش حساسیت به پارامترهای ورودی و قابلیت تشخیص هر نوع از خوشبندیها. تعداد زیاد این الگوریتمها، موجب سردرگمی کاربران در انتخاب الگوریتم مناسب شده است.

در سال های اخیر، برای داده های حجمی، الگوریتم های خوشبندی بی شماری ارائه شده است. در حالت کلی، این الگوریتم ها را می توان در دو دسته قرار داد. دسته ای از الگوریتم ها که روی یک ماشین اجرا شده و دسته دیگر که روی چند ماشین اجرا می شوند. روش Wu, Cheng, Zurita- (H-K-Means 2020)، جزء الگوریتم هایی است که روی یک ماشین اجرا می شوند و در گروه تکنیک های کاهش داده قرار می گیرند. در این الگوریتم، داده ها در یک ساختار سلسله مراتبی کاهش پیدا می کنند. به این صورت که مراکز هر خوشبندی نماینده داده های آن خوشبندی سطح بعد انتقال پیدا می کنند.

در مقاله حاضر سعی شده است در خوشبندی مبتنی بر چگالی، بهبودی ایجاد شود و این کار با استفاده از ادبیات پژوهشی این حوزه انجام می شود که استفاده از خوشبندی K-Means برای ایجاد خوشبندی هایی کوچک تر و پرداختن به مشکل تغییرات چگالی با استفاده از الگوریتم OPTICS را شامل می شود.

الگوریتم OPTICS (Ankerst et al,1999)، الگوریتم DBSCAN را به منظور حل مسئله تغییر چگالی تطبیق داده است. این الگوریتم، برای حل مسئله تغییر چگالی دو فیلد اضافی فاصله دسترسی پذیری و فاصله مرکز را ذخیره می کند. دقیق این الگوریتم بسیار پایین است، به گونه ای که فقط روی برخی مجموعه داده های خاص عملکرد مناسبی دارد. از طرفی، اگرچه الگوریتمی مانند Wang et (DVBCAN 2020 (al) دقیق این را نیز دارد، اما تعداد زیاد پارامترهای این الگوریتم باعث شده است تا انتخاب دقیق این پارامترها برای کاربران مشکل باشد. از این رو، ارائه یک الگوریتم واحد که به حل کلیه مشکلات ذکر شده پیرازد، بسیار ضروری است.

با توجه به مطالب بیان شده، در این مقاله برای رفع مشکل سرعت و همچنین، تغییرات چگالی DBSCAN، الگوریتمی ارائه شده است که ضمن ساده و فهمیدنی بودن، کلیه جنبه های ذکر شده را در نظر داشته است. الگوریتم ارائه شده ضمن تشخیص خوشبندی هایی با چگالی متفاوت، به پارامترهای ورودی حساسیت پایینی دارد و قابلیت تشخیص خوشبندی هایی با اندازه و اشکال متفاوت و خوشبندی های چسبیده به هم و تودر تو را نیز دارد. ایده الگوریتم پیشنهادی به این صورت است که ابتدا، با استفاده از تکنیکی مقادیر مختلف پارامتر Eps به دست می آید. سپس، الگوریتم DBSCAN برای اعمال روی مجموعه داده با پارامترهای به دست آمده تطبیق داده می شود. الگوریتم پیشنهادی روی مجموعه داده های استاندارد آزمایش شده و نتایج به دست آمده با نتایج حاصل از الگوریتم پایه DBSCAN و چند الگوریتم بهبودیافته آن نیز مقایسه شده است.

در پژوهش چن و همکارانش^۱ (۲۰۲۰)، به منظور رفع مشکل، الگوریتم DBSCAN در تجزیه و تحلیل خوشهایی با چگالی متفاوت ارائه شده است. ایده این الگوریتم به این صورت است که قبل از اعمال الگوریتم DBSCAN با استفاده از مفهوم k-dist plot چگالی‌های مختلف را شناسایی کرده و برای هر چگالی یک مقدار Eps متناسب را برمی‌گزیند. بعد از تعیین مقادیر مختلف Eps، الگوریتم DBSCAN را به تعداد چگالی‌های به دست آمده با استفاده از مقادیر مختلف Eps به دست آمده روی مجموعه‌داده اعمال می‌کند. منحنی plot k-dist از مرتب‌سازی نقاط مجموعه‌داده براساس فاصله هر نقطه از kامین نزدیک‌ترین همسایه‌اش ساخته می‌شود. بعد از ساخت منحنی plot k-dist، هر تغییر شدید در این منحنی یک چگالی متفاوت را مشخص می‌کند. الگوریتم VDBSCAN به تعیین دقیق مقدار پارامتر k وابستگی دارد، به گونه‌ای که انتخاب نادرست آن باعث کاهش دقت نتایج می‌شود.

پژوهش سابور و همکاران^۲ (۲۰۲۱)، یکی دیگر از بهبودهای الگوریتم DBSCAN است که از مفهوم فاکتور دورافتادگی محلی و چگالی دسترسی پذیری محلی برای تشخیص خوشهایی با چگالی متفاوت استفاده می‌کند. در این الگوریتم، به منظور تشخیص نویز از فاکتور دورافتادگی محلی استفاده شده است، به گونه‌ای که اگر فاکتور دورافتادگی محلی یک نقطه کمتر از یک حد آستانه باشد، آن نقطه یک نقطه مرکزی است و در غیر این صورت، نویز محاسب می‌شود. هنگام بسط یک خوشه، یک نقطه در صورتی بسط داده می‌شود که چگالی دسترسی پذیری محلی آن نقطه به چگالی دسترسی پذیری محلی نقطه مرکزی خوشه متعلق به آن نزدیک باشد. در غیر این صورت، آن نقطه به طور ساده به خوشه افزوده شده و بسط داده نمی‌شود. انتخاب پارامترهای مناسب برای الگوریتم LDBSCAN در مقایسه با الگوریتم DBSCAN ساده‌تر است، اما با توجه به اینکه این الگوریتم به چهار پارامتر ورودی نیاز دارد، برای پایگاه‌داده‌های حجمی، ممکن است این تعداد زیاد پارامترهای ورودی مشکل‌ساز شود.

در پژوهش گلان^۳ (۲۰۱۹)، از مفاهیم واریانس چگالی خوشه^۴ و شاخص شباهت خوشه^۵ به منظور جلوگیری از بسط خوشه از ناحیه متراکم به ناحیه متراکم و بر عکس استفاده می‌شود. الگوریتم با انتخاب یک نقطه مرکزی شروع به شکل دهی خوشه‌ها می‌کند، سپس، کلیه نقاطی که در همسایگی Eps نقطه مرکزی انتخابی باشند را به یک صف وارد می‌کنند. این نقاط در صورتی اجازه بسط پیدا می‌کنند که واریانس چگالی خوشه کمتر یا مساوی از حد آستانه α بوده و شاخص شباهت خوشه یعنی اختلاف بین حداقل و حداکثر شیء قرار گرفته در خوشه نیز کمتر از حد آستانه β باشد. در غیر این صورت، نقطه به طور ساده به خوشه افزوده شده و دیگر بسط داده نمی‌شود. این الگوریتم علاوه بر دو پارامتر استفاده شده در DBSCAN، به تعیین دو پارامتر α و β که به منظور محدود کردن مقدار تغییر چگالی محلی اجازه داده شده در داخل خوشه استفاده می‌شوند، نیز نیاز دارد. الگوریتم DVBSCAN قابلیت

1. Chen et al.
2. Sabor et al.
3. Access density
4. Galán
5. Cluster density variance (CDV)
6. Cluster similarity index (CSI)

تشخیص خوشه‌های با اندازه، اشکال و چگالی متفاوت را دارد و در مقابل نویز نیز مقاوم است. با این حال، این الگوریتم به تعیین چهار پارامتر ورودی نیاز دارد که تعیین چهار پارامتر به مراتب دشوارتر از تعیین دو پارامتر نسبت به الگوریتم DBSCAN است. این در حالی است که نتایج این الگوریتم بسیار وابسته به تعیین دقیق این پارامترها است.

در پژوهش چن و همکاران (۲۰۱۸)، الگوریتمی دیگر برای یافتن خوشه‌هایی با چگالی متفاوت است و در این الگوریتم از مفهوم شیء مرکزی هم جنس استفاده شده است. شیء مرکزی هم جنس به شی ای گفته می‌شود که اولاً یک شیء مرکزی باشد و ثانیاً اختلاف چگالی با همسایه‌های خود در حد α باشد. الگوریتم با انتخاب یک شیء مرکزی هم جنس کار خود را آغاز می‌کند و تا زمانی خوشه را بسط می‌دهد که به یک شیء مرکزی غیرهم‌جنس که نشان‌دهنده تغییر وسیع در چگالی است، برسد. پیچیدگی زمانی این الگوریتم مانند الگوریتم DBSCAN است و یکی از مزایای آن، T کاهش وابستگی به پارامتر Eps است و این در حالی است که الگوریتم پیشنهادی برای رسیدن به این هدف، پارامتر سومی (پارامتر α) را نیز به الگوریتم افزوده است.

در پژوهش ونگ، گو و شان^۱ (۲۰۲۰)، توسعه از الگوریتم DBSCAN آمده است که قابلیت تشخیص خوشه‌هایی با چگالی متفاوت را دارد. الگوریتم در ابتدا چگالی هر نقطه را محاسبه می‌کند، سپس، متراکم‌ترین نقطه را به عنوان شیء مرکزی در نظر می‌گیرد و شروع به بسط خوشه به وسیله نقاط همسایه با چگالی مشابه می‌کند. هنگام بسط خوشه از بین نقاطی که جزء K -نزدیک‌ترین همسایه شیء مرکزی هستند، فقط نقاطی که چگالی آنها کمتر از میانگین چگالی خوشه باشد، به خوشه افزوده شده و بسط پیدا می‌کنند. در واقع در این الگوریتم، میانگین چگالی خوشه و چگالی هر نقطه تصمیم می‌گیرند که نقطه‌ای متعلق به خوشه‌ای باشد یا خیر. در این مقاله، به مسائل پرنویز و شکاف خوشه‌ها نیز اشاره شده است و این دو مسئله به دلیل انتخاب نامناسب مقدار k رخ می‌دهند. بنابراین، با انتخاب یک مقدار مناسب و دقیق برای k می‌توان بر این مشکلات غلبه کرد.

در پژوهش لیا، زائی، هو، بیان و سانگ^۲ (۲۰۱۹)، الگوریتمی به منظور غلبه بر مسئله تغییرات چگالی خوشه‌ها آمده است. این الگوریتم، ابتدا تابع چگالی هر نقطه را به دست می‌آورد، سپس، با اعمال DBSCAN روی مجموعه داده، مرکز هر خوشه را به دست می‌آورد. بعد از آن، به ازای هر شیء، تابع هم‌چنان تعداد خوشه‌های ناصحیح را به کار برد است.

در پژوهش دنگ^۳ (۲۰۲۰)، الگوریتمی با قابلیت تشخیص خوشه‌هایی با چگالی متفاوت آمده است که از ساختار داده KD-Tree برای پردازش کارآمد داده‌هایی با ابعاد بالا، استفاده می‌کند. در واقع، استفاده از ساختار داده KD-Tree محاسبه کارآمد λ امین نزدیک‌ترین همسایه‌ها را به خصوص برای مجموعه داده‌های بزرگ ممکن می‌کند. روال کار این الگوریتم به این صورت است که برای هر نقطه فاصله تا λ امین نزدیک‌ترین همسایه را با استفاده از ساختار داده KD-Tree محاسبه کرده، سپس، با مشخص کردن زانوها

1. Wang, Gu & Shun

2. Lai, Zhou, Hu, Bian & Song

3. Deng

از روی منحنی k -dist، مجموعه پارامترهای Eps را تخمین می‌زند. یکی از مشکلات این الگوریتم، نیاز به پارامتر ورودی k است. با بررسی روش توضیح داده شده در این مقاله، به راحتی می‌توان گفت که این الگوریتم نیز نسخه‌ای از الگوریتم VDBSCAN است که با داشتن پرس‌وحوهای ناحیه‌ای بهینه، به سبب استفاده از ساختار شاخص KD-Tree برای مجموعه‌داده‌های حجمی نیز استفاده می‌شود. بنابراین، مشکلات اساسی الگوریتم VDBSCAN برای این الگوریتم نیز مطرح است.

در پژوهش هارتمن، ما، هامرلین، پرنال و وانگر^۱ (۲۰۱۸) برای تشخیص خوشه‌هایی با چگالی متفاوت، الگوریتمی ارائه شده است که در آن، با استفاده از روش‌های آماری دو پارامتر Eps و Minpts استخراج می‌شوند. یکی از ایرادهای اساسی این مقاله، مقایسه نکردن الگوریتم ارائه شده با سایر الگوریتم‌ها است، به گونه‌ای که الگوریتم ارائه شده فقط با الگوریتم پایه DBSCAN مقایسه شده و عملکرد آن در برابر سایر الگوریتم‌هایی که برای حل مشکل تغییرات چگالی ارائه شده‌اند، مشخص نیست.

اکثر روش‌های ارائه شده برای حل مشکل تغییرات چگالی الگوریتم DBSCAN روش‌های بدون نظارت هستند که در آنها از داشت قبلى برای بهبود نتایج خوشه‌بندی استفاده نمی‌شود. در پژوهش کیم و همکاران^۲ (۲۰۱۸) نشان داده شده است که می‌توان خوشه‌بندی مبتنی بر چگالی را برای تشخیص خوشه‌هایی با چگالی متفاوت استفاده کرد. روش ارائه شده در این مقاله به این صورت است که در مرحله نخست، مجموعه‌داده را به سطوح چگالی متفاوت تقسیم کرده و برای هر سطح چگالی، پارامترهای چگالی مناسب مربوط به آن سطح را تعیین می‌کند. در ادامه، الگوریتم مربوطه با استفاده از محدودیت‌های دو بد و فرایند خوشه‌بندی را بر مبنای پارامترهای بدست‌آمده بسط می‌دهد. نتایج ارزیابی این الگوریتم نشان می‌دهد که در مقایسه با برخی از الگوریتم‌های خوشه‌بندی نیمه‌نظراتی و بدون نظارت، نتایج بهتری ارائه شده است.

در پژوهش لوهیچی، گزرا و بن عبدالله^۳ (۲۰۱۸)، بهبود دیگری از الگوریتم DBSCAN آمده است که قابلیت تشخیص خوشه‌هایی با چگالی متفاوت را دارد. این الگوریتم در دو فاز انجام می‌شود. در فاز نخست، با استفاده از فرایند ریاضی (یکتابع هموار چندضابطه‌ای - چندجمله‌ای) روى فواصل k نزدیک‌ترین همسایه، تعداد سطوح چگالی مشخص می‌شود. در مرحله بعدی، از سطوح چگالی به دست‌آمده در مرحله نخست، به عنوان آستانه‌های چگالی محلی برای تشخیص خوشه‌هایی با چگالی و اشكال مختلف استفاده می‌شود. این الگوریتم در مقایسه با الگوریتم DBSCAN از دقت بالاتری برخوردار است. الگوریتم‌های خوشه‌بندی مبتنی بر چگالی، روش‌های بسیار ارزشمندی برای خوشه‌بندی جریان‌های داده هستند. به تازگی، تعدادی الگوریتم خوشه‌بندی مبتنی بر چگالی برای خوشه‌بندی جریان داده‌ها ارائه شده که یکی از ایرادهای این الگوریتم‌ها، کاهش کیفیت خوشه‌بندی به دلیل وجود خوشه‌هایی با چگالی متفاوت است.

1. Hartmann, Ma, Hameurlain, Pernul & Wagner

2. Kim et al.

3. Louhichi, Gzara & Ben-Abdallah

در پژوهش یو و همکاران^۱ (۲۰۲۱)، الگوریتم ارائه شده که توانایی خوشه‌بندی جریان‌های داده‌ای با چگالی‌های متفاوت را دارد، الگوریتم ارائه شده از روش مبتنی بر Grid برای مدیریت نویز و داده‌های با چگالی متفاوت و همچنین، برای کاهش زمان ادغام خوشه‌ها استفاده کرده است. همچنین، در پژوهش حیدری، البرزی، رادفر، افسار کاظمی و رجب‌زاده^۲ (۲۰۱۹)، الگوریتم دیگری برای خوشه‌بندی جریان‌های داده‌ای غیرایستا ارائه شده است که توانایی تشخیص خوشه‌هایی با چگالی متفاوت از جریان‌های داده‌ای را دارد. یکی از مزایای الگوریتم ارائه شده، کاهش وابستگی به پارامترهای ورودی است.

با توجه به اینکه وقتی خوشه‌ها نزدیک به یکدیگر باشند، ممکن است الگوریتم DBSCAN با شکست مواجه شود، در پژوهش لوهیچی و همکاران^۳ (۲۰۱۸) الگوریتم بهمنظور رفع مشکل خوشه‌های مجاور ارائه شده است. در این الگوریتم به جای استفاده از مفهوم دسترسی‌پذیری چگالی از مفهوم دسترسی‌پذیری چگالی مرکزی استفاده شده است. در واقع، این الگوریتم در زنجیره دسترسی‌پذیری بهبود انجام داده، به‌گونه‌ای که این زنجیره فقط شامل اشیای مرکزی است. روال کار به این صورت است که ابتدا، خوشه‌های متشكل از اشیای مرکزی پیدا شده، سپس، اشیای حاشیه‌ای به نزدیک‌ترین شیء مرکزی تشخیص داده می‌شوند. این الگوریتم روی داده‌های مکانی و غیرمکانی اعمال شدنی است. با توجه به هدف اصلی الگوریتم ارائه شده، این الگوریتم به خصوص در مجموعه‌داده‌های متراکم شامل خوشه‌های نزدیک به یکدیگر به خوبی عمل می‌کند و در سایر موارد نتایج نزدیک به الگوریتم DBSCAN را تولید می‌کند.

یکی از مشکلات الگوریتم DBSCAN، بحث پیچیدگی زمانی بالای این الگوریتم در مجموعه‌داده‌های با حجم و بعد بالا است. در پژوهش بنچینی، کربیسیون، دوکانش، مارسلونی و رندا^۴ (۲۰۲۰) با هدف بهبود زمان الگوریتم DBSCAN یک راه کار ارائه شده است. در این الگوریتم، اشیایی که توسط الگوریتم به عنوان بذر برای بسط دادن انتخاب می‌شوند، بهبود داده شده‌اند تا به کارایی بهتری برسد. با توجه به اینکه می‌توان از بسیاری از پرس‌جوهای ناحیه‌ای برای یافتن همسایه‌های اشیا چشم‌پوشی کرد، الگوریتم FDBSCAN تعدادی شیء را به نمایندگی از کلیه اشیا شامل داده‌هایی با چگالی متفاوت انتخاب می‌کند. این الگوریتم علاوه بر افزودن افزایش نقاط، توانایی افزودن افزایشی خوشه‌ها را نیز دارد. الگوریتم ارائه شده با عنوان IMD-DBSCAN^۵، نسخه افزایشی الگوریتم MDDBSCAN (لوهیچی و همکاران، ۲۰۱۸) است که این الگوریتم در مقایسه با DBSCAN کارایی بهتر و پیچیدگی محاسباتی و زمانی کمتری نیز دارد، اما در مقایسه با DBSCAN دقت پایین‌تری داشته و اشیای بیشتری در آن از دست می‌روند. افزون بر این، الگوریتم ارائه شده در پژوهش‌های کائو، ون و سابل^۶ (۲۰۱۸) و پاولیس، دولگا و سینگلتون^۷ (۲۰۱۷) نیز روش‌هایی برای بهبود پیچیدگی زمانی DBSCAN ارائه شده است.

1. Yu et al.

2. Heidari, Alborzi, Radfar, Afsharkazemi & Rajabzadeh

3. Bechini, Criscione, Ducange, Marcelloni & Renda

4. Kuo, Wen & Sabel

5. Pavlis, Dolega & Singleton

الگوریتم DBSCAN متکی بر مفهوم چگالی خوشها است و به منظور کشف خوشها با اشکال مختلف به همراه نویز است. در پژوهش باتس^۱ (۲۰۲۱) الگوریتمی ارائه شده که قادر است اشکال هندسی غیر از نقطه مانند چندضلعی‌های دوبعدی را نیز خوشبندی کند. همچنین، این الگوریتم توانایی این را دارد تا اشیای نقطه را به خوبی اشیای سطحیافته مکانی طبق هر دو خصوصیت مکانی و غیرمکانی آن اشیا خوشبندی کند. افزون بر این، در این پژوهش، کاربردهایی از دنیای واقعی مانند علوم زمین‌شناسی، زیست‌شناسی، نجوم و جغرافیا برای این الگوریتم ارائه شده است. الگوریتم ارائه شده، به خصوص در پایگاه داده‌های بسیار حجمی، خوب عمل می‌کند. این الگوریتم، خوشبندی یک‌سطحی را ایجاد می‌کند و این در حالی است که ممکن است خوشبندی سلسله‌مراتبی مفیدتر باشد، به خصوص زمانی که پارامترهای ورودی مناسب را نتوان به دقت برآورد کرد.

در پژوهش چیموابی و آنورادها^۲ (۲۰۱۸) یکی دیگر از توسعه‌های الگوریتم DBSCAN آمده است که برخلاف الگوریتم DBSCAN، قابلیت کشف خوشها را مطابق با مقادیر مکانی، غیرمکانی و زمانی اشیا دارد. این الگوریتم از سه جهت با الگوریتم DBSCAN تفاوت دارد. نخست، برخلاف الگوریتم DBSCAN و سایر الگوریتم‌های مبتنی بر چگالی موجود، قابلیت خوشبندی داده‌های مکانی - زمانی را طبق خصوصیت‌های مکانی، غیرمکانی و زمانی اشیا دارد. دوم، برخلاف DBSCAN، در مواقعی که خوشها ای با چگالی متفاوت در مجموعه‌داده وجود داشته باشند نیز قابلیت تشخیص نویز را دارد و درنهایت، اگر مقادیر غیرمکانی اشیای همسایه تفاوت اندکی داشته باشند و خوشها مجاور یکدیگر باشند، مقادیر اشیای حاشیه‌ای در یک طرف خوش ممکن است بسیار متفاوت با مقادیر اشیای حاشیه‌ای در طرف مقابل باشند. الگوریتم ST-DBSCAN این مشکل را با مقایسه مقدار میانگین یک خوش با مقادیر اشیای جدید افزوده شده به خوش حل می‌کند. پیچیدگی زمانی این الگوریتم مانند DBSCAN است. الگوریتم ST-DBSCAN کاربردهای متعددی دارد که از جمله این کاربردها می‌توان به سیستم اطلاعات جغرافیا، تصاویر پزشکی و پیش‌بینی وضع هوا اشاره کرد. یکی از ضعف‌های این الگوریتم، ناتوانی در کشف خوشها با چگالی متفاوت است. همچنین، پارامترهای ورودی آن به صورت خودکار تولید نمی‌شوند.

با توجه به مرور ادبیات مشخص می‌شود که در محیط‌های انباره داده، به صورت دوره‌ای حجمی از داده‌ها به داده‌های موجود در انباره اضافه می‌شوند. از این رو، نیاز است قبل از اینکه انباره داده در دسترس کاربران قرار بگیرد، خوشها ای که از قبل کشف شده‌اند با توجه به داده‌های جدید افزوده شده، به روز شوند و این خوشبندی می‌تواند به ارائه خدمات با کیفیت در حوزه‌های مختلف منجر شود. در پژوهش‌های مرورشده، مشخص است که برای خوشبندی، از روش‌های مبتنی بر چگالی به خوبی استفاده شده که برخی از موارد در این مقاله بررسی شد. نقطه اشتراک کلیه این پژوهش‌ها، لزوم خوشبندی در داده‌های حجمی است و وجه تمایز آنها در دو معیار سرعت و دقت خلاصه می‌شود. با توجه به نتایج مقاله‌های موجود در این حوزه، مشخص است که هر دو مسئله سرعت و دقت در خوشبندی اهمیت دارد،

1. Botts

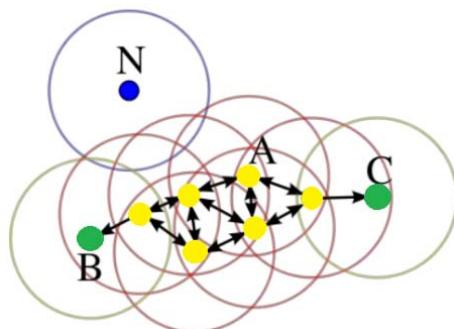
2. Chimiway & Anuradha

بنابراین، روش‌های مختلف ترکیبی با خوشبندی مبتنی بر چگالی توسعه یافته است. از این رو، با توجه به مرور ادبیات، در این مقاله هدف روش پیشنهادی ارتقای همزمان سرعت و دققت است و در این خصوص، مدلی برگرفته از خوشبندی ترکیبی با روش K-Means و همچنین، تخمین چگالی مختلف در داده‌ها ارائه شده است.

روش پژوهش

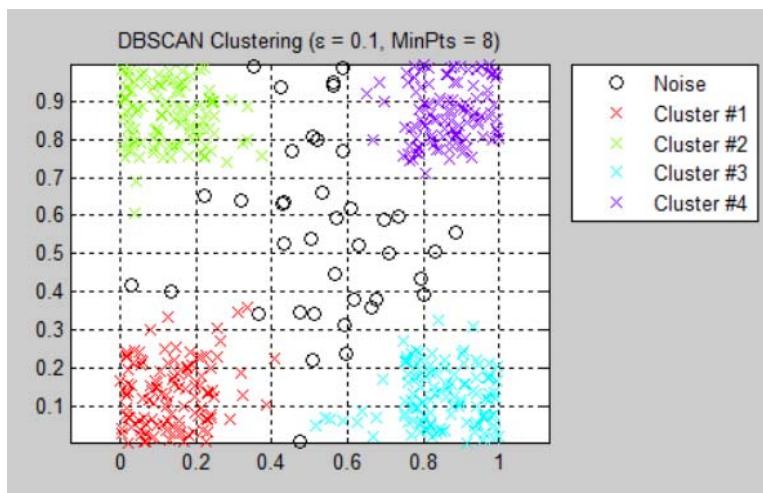
خوشبندی یک مجموعه داده حجمیم توسط الگوریتم‌های داده کاوی شناخته شده، زمان بر است. بنابراین، با توجه به افزایش حجم داده‌ها و کاهش توان الگوریتم‌ها در پردازش حجم عظیمی از داده‌ها، نیاز به ارائه روش‌های جدید بیش از پیش احساس می‌شود. الگوریتم پیشنهادی در این مقاله، با هدف افزایش سرعت خوشبندی داده در عین حفظ کیفیت خوشبندی ارائه شده است و بهبود یافته الگوریتم مشهور DBSCAN است. الگوریتم DBSCAN جزء الگوریتم‌های مبتنی بر چگالی است که وجود نویزها در داده‌های اصلی را به خوبی تشخیص می‌دهد. این روش، نقاط را به سه گروه شامل نقاط core، reachable و noise density طبقه‌بندی می‌کند.

یک نقطه، core در نظر گرفته می‌شود، در صورتی که در فاصله ϵ از آن به اندازه Minpts نقطه وجود داشته باشد (با احتساب خود نقطه core) که این نقاط به صورت مستقیم از طریق نقاط core قابل دستیابی هستند. سایر نقاط هر خوشبندی DBSCAN نقطه reachable-density در نظر گرفته می‌شوند که این نقاط به طور غیرمستقیم به نقاط core متصل هستند. به طور نقاطی که نتوانند به طور مستقیم یا غیرمستقیم به نقاط core بپیوندند، خارج از خوشبندی قرار گرفته و به عنوان نویز در نظر گرفته می‌شوند (شکل ۱). Minpts با مقدار عددی ۴ است و نقطه A و سایر نقاط زرد رنگ اطراف آن به عنوان نقاط شناخته شده‌اند و نقطه N نیز noise می‌باشد. شکل ۲ نیز خوشبندی داده، پس از اعمال DBSCAN را نشان می‌دهد.



شکل ۱. نمایش خوشبندی داده‌ها با الگوریتم DBSCAN
(Heidari et al., 2019)

شکل ۲، اجرای خوشبندی DBSCAN معمولی را نشان می‌دهد که برای شناسایی نقاط core در یک خوش و نقاط noise، به محاسبه فاصله هر نقطه تا کلیه نقاط دیگر نیاز است که این خود، افزایش حجم محاسبات، زمان اجرا و بدنبال آن کاهش سرعت، بهخصوص برای داده‌های جیجیم را بهمراه دارد. بنابراین، برای افزایش سرعت DBSCAN روی داده‌های جیجیم در روش پیشنهادی این مقاله، از الگوریتم K-Means در ابتدای الگوریتم DBSCAN استفاده می‌شود. هدف این ایده، این است که داده‌های نزدیک به یکدیگر تا حد ممکن در یک خوش قرار گیرند و الگوریتم DBSCAN نقاط با فواصل دور را در محاسبات خود در نظر نگیرد. به این ترتیب، این الگوریتم در هر خوش به دست آمده از K-Means به‌طور مجزا اجرا شده و نقاط core را تشخیص می‌دهد.

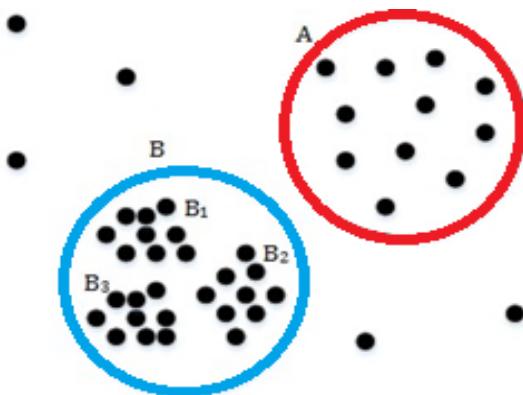


شکل ۲. خوشبندی داده با اعمال الگوریتم

(Heidari et al., 2019)

از طرفی، اکثر روش‌های خوشبندی موجود از جمله DBSCAN به پارامترهای ورودی نیاز دارند و انتخاب دقیق مقادیر این پارامترها روی خروجی الگوریتم بسیار تأثیرگذار است. هرچند برخی از الگوریتم‌ها کاربر را در انتخاب پارامتر صحیح کمک می‌کنند، اما در مجموعه داده‌هایی با حجم و ابعاد بالا، انتخاب دقیق این پارامترها مشکل آفرین است. الگوریتم VDBSCAN و بهبودهای انجام‌شده روی آن تلاش کرده‌اند که مقادیر این پارامترها را به‌طور خودکار تعیین کنند و تا حدی نیز در این کار موفق بوده‌اند، اما با پیاده‌سازی و انجام آزمایش‌های متعدد روی مجموعه داده‌های مختلف، به این نتیجه رسیدیم که الگوریتم VDBSCAN فقط روی مجموعه داده‌هایی قادر به تشخیص پارامترهایست که منحنی ملایم در k-dist plot مربوطه خود را نداشته باشند.

یکی از خصوصیت‌های مهم مجموعه‌داده‌های مختلف این است که خوشه‌های موجود در این مجموعه‌داده‌ها به دلیل وجود چگالی‌های محلی متفاوت، فقط با یک تنظیم پارامتر سراسری تشخیص داده می‌شوند، بنابراین، به بیش از یک چگالی محلی برای تشخیص خوشه‌ها نیاز است. برای نمونه، در مجموعه‌داده‌ای که در شکل ۳ نشان داده شده است، خوشه‌های B_1 ، B_2 و B_3 را نمی‌توان فقط با یک تنظیم پارامتر سراسری تشخیص داد. اگر پارامترها را مطابق با چگالی محلی خوشه‌ها تنظیم کنیم، خوشه A به عنوان نویز محسوب می‌شود. اگر پارامترها مطابق با چگالی محلی خوشه A تنظیم شوند، خوشه‌های B_1 و B_2 به اشتیاه با یکدیگر ترکیب می‌شوند. بنابراین، با یک تنظیم پارامتر سراسری نمی‌توان خوشه‌ها را به درستی تشخیص داد.

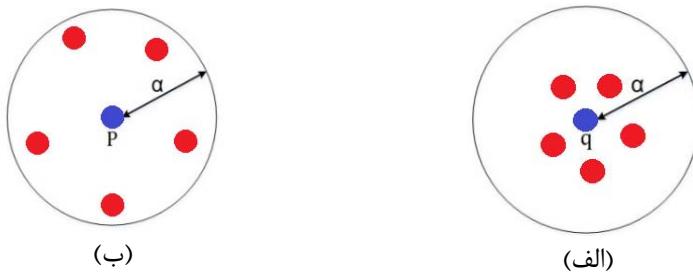


شکل ۳. خوشه‌هایی با چگالی متفاوت

یکی از مشکلاتی که ممکن است الگوریتم DBSCAN در مواجهه با مجموعه‌داده‌های حجمی با آن روبرو شود، بحث پیچیدگی زمانی بالای این الگوریتم است. الگوریتم DBSCAN به‌ازای کلیه نقاط موجود در پایگاهداده، عمل پرس‌وجوی ناحیه‌ای را انجام می‌دهد. در پایگاهداده‌های بزرگ، زمان انجام این عمل شایان توجه خواهد بود و در نتیجه، کارایی الگوریتم تنزل می‌یابد. همچنین، الگوریتم DBSCAN زمانی که خوشه‌ها نزدیک به یکدیگر باشند، ممکن است در تشخیص صحیح خوشه‌ها با مشکل مواجه شود.

همان‌طور که بیان شد، یکی از مشکلات الگوریتم DBSCAN پشتیبانی نکردن از تغییرات چگالی داخل خوشه‌ها است. برای غلبه بر این مشکل، در روش پیشنهادی، ابتدا مقادیر مختلف پارامتر Eps و محاسبه می‌شود، سپس، الگوریتم DBSCAN برای اعمال روی مجموعه‌داده با پارامترهای به‌دست‌آمده، تطبیق داده می‌شود. الگوریتم پیشنهادی بر مبنای مفهوم چگالی محلی نقاط عمل می‌کند. چگالی یک نقطه می‌تواند از طریق شمارش تعداد نقاط موجود در یک شعاع مشخص از آن نقطه محاسبه شود، اما این روش تقریب خوبی از چگالی نقاط را حاصل نمی‌کند. همان‌طور که در شکل ۴ مشاهده می‌شود، در

صورتی که تعداد نقاط موجود در شعاع α به عنوان چگالی نقاط در نظر گرفته شود، دو نقطه p و q دارای چگالی مشابه هستند، اما همان‌طور که مشاهده می‌شود، نقطه q دارای تراکم بالاتری است. بنابراین، استفاده از این روش تقریب خوبی از چگالی نقاط را حاصل نمی‌کند. این در حالی است که روش دقیق‌تر، روشی است که چگالی نقاط را براساس فاصله نقاط از همسایه‌های آنها محاسبه کند.



شکل ۴. چگالی مبتنی بر شمردن نقاط موجود در شعاع α

با فرض داشتن مجموعه‌داده D ، چگالی محلی شیء $x \in D$ از طریق محاسبه مجموع فاصله اقلیدسی شیء x از L نزدیک‌ترین همسایه آن طبق رابطه ۱ به دست می‌آید (تابع چگالی محلی) (, Weng et al., 2021):

$$\text{Local Density}(x) = \sum_{i=1}^L d(x, xi) \quad (\text{رابطه ۱})$$

که در آن، x_i معادل با نامین نزدیک‌ترین همسایه از شیء x است و همچنین، $d(x, xi)$ فاصله اقلیدسی بین دو شیء را برمی‌گرداند. در این تعریف، تصمیم‌گیری در خصوص مقدار L بسیار مهم است، به‌گونه‌ای که انتخاب نادرست آن به تنزل دقت نتایج خوشبندی منجر می‌شود. به دو دلیل مقدار L را نمی‌توان بزرگ در نظر گرفت. نخست، همان‌گونه که در بخش ارزیابی نتایج آزمایش نشان داده است، در نظر گرفتن مقادیر بزرگ برای L تقریب مناسبی از چگالی نقاط را حاصل نمی‌کند. همچنین، با توجه به اینکه بخش غالب پیچیدگی زمانی الگوریتم پیشنهادی مربوط به محاسبه چگالی محلی نقاط است، هرچه مقدار L بزرگ‌تر باشد، پیچیدگی زمانی الگوریتم نیز افزایش می‌یابد، به‌طوری که به‌ازای $L=n$ پیچیدگی زمانی الگوریتم از مرتبه $O(n^2 \log n)$ می‌شود. علاوه بر پارامتر L ، الگوریتم پیشنهادی به دو پارامتر ورودی k و $Minpts$ نیز نیاز دارد. پارامتر k حداقل تعداد نقاط موجود در یک خوشه را مشخص می‌کند و پارامتر k نیز برای محاسبه مقادیر Eps استفاده می‌شود.

روال کار الگوریتم پیشنهادی به این صورت است که ابتدا، چگالی محلی کلیه نقاط طبق تعریف تابع چگالی محلی محاسبه شده، سپس، نقاط براساس چگالی محلی خود به صورت نزولی مرتب می‌شوند. شایان ذکر است که نقطه با مقدار چگالی محلی کمتر، از چگالی بیشتری برخوردار است. سپس، از بین

مجموعه نقاطی که هنوز خوشبندی نشده اند، متراکم ترین نقطه (مانند p) انتخاب می شود. هدف مقاله این است که خوش باره با تراکم بالاتر، زودتر تشخیص داده شود. در واقع، با توجه به اینکه در مجموعه داده هایی با چگالی متفاوت، برای هر چگالی یک مقدار Eps متفاوت وجود دارد، در صورتی که کار از خوش بندی با چگالی کمتر آغاز شود، یعنی خوش بندی هایی که مقدار Eps آنها بزرگ است، خوش بندی هایی با چگالی بالا نیز ممکن است به اشتباہ با خوش بندی هایی با چگالی پایین ترکیب شوند. به بیان دیگر، خوش بندی هایی با چگالی کمتر، خوش بندی هایی با چگالی بالاتر زودتر تشخیص داده شوند. سپس، با صرف نظر کردن از این نقاط که خوشبندی شده اند، از خوشبندی شدن مکرر یک نقطه طی تکرارهای بعدی جلوگیری شده است. در تکرار Δ بعد از انتخاب متراکم ترین نقطه p از بین نقاطی که هنوز خوشبندی نشده اند، فاصله تا k اامین نزدیک ترین همسایه از p به عنوان $Epsi$ در نظر گرفته می شود.

بعد از آن، الگوریتم DBSCAN با پارامتر $Minpts$ که از مرودی گرفته شده و پارامتر $Epsi$ که در مرحله قبل محاسبه شده است، فراخوانی می شود. بعد از پایان کار الگوریتم DBSCAN و صرف نظر کردن از نقاطی که خوشبندی شده اند، از طریق برچسب خوش بندی هایی که به نقاط داده می شود، طی یک فرایند تکراری از بین مجموعه نقاطی که هنوز خوشبندی نشده اند، متراکم ترین نقطه انتخاب شده و فاصله آن نقطه تا k اامین نزدیک ترین همسایه خود به عنوان پارامتر $Epsi+1$ در نظر گرفته می شود و الگوریتم DBSCAN با پارامتر جدید $Epsi+1$ فراخوانی می شود. این فرایند تا زمانی ادامه دارد که کلیه نقاط خوشبندی شوند یا تعداد نقاط خوشبندی نشده کمتر از مقدار $Minpts$ باشند. اگر تعداد نقاط باقی مانده خوشبندی نشده کمتر از $Minpts$ شود، این نقاط برچسب نویز خواهند گرفت، زیرا در این حالت دیگر امکان تشکیل خوش بندی نیست.

فرض کنید، r تعداد نقاط باقی مانده از مجموعه داده برای خوشبندی بعد از فراخوانی چندین باره الگوریتم DBSCAN باشد. زمانی که $Minpts \leq r < k$ باشد، فاصله تا r اامین نزدیک ترین همسایه از متراکم ترین نقطه خوشبندی نشده به عنوان Eps جدید در نظر گرفته می شود. حال اگر $Minpts < r$ باشد، نقاط باقی مانده به عنوان نویز برچسب گذاری می شوند. مراحل اصلی الگوریتم پیشنهادی به طور خلاصه در شکل ۵ نشان داده شده است.



شکل ۵. مراحل اصلی الگوریتم پیشنهادی

یکی از خصوصیت‌های روش پیشنهادی این است که تعیین مقدار دقیق پارامترهای ورودی (پارامتر Eps به صورت خودکار تعیین می‌شود) ساده‌تر است. به طور کلی، الگوریتم ارائه شده با تعیین خودکار پارامتر Eps، حساسیت به پارامترهای ورودی را کاهش داده است. در نگاه نخست به نظر می‌رسد که الگوریتم سه پارامتر دارد و شاید چندان مناسب نباشد، اما بهترین مقدار برای پارامتر L همان مقدار Minpts است. یعنی برای داشتن نتایج ایده‌آل، مقدار پارامتر L را برابر با مقدار Minpts قرار داده و از این پارامتر صرف نظر می‌شود. بنابراین، برای این الگوریتم فقط تعیین مقدار دو پارامتر k و L کافی است و برای فهم بهتر و دقیق الگوریتم است که پارامتر L به صورت یک پارامتر جداگانه در نظر گرفته شده است. در رابطه با پارامتر k نیز گفته می‌شود که اولاً همان‌گونه که اشاره شد، حد پایین این پارامتر مشخص است و این پارامتر باید حداقل به اندازه Minpts باشد، ثانیاً مقدار این پارامتر در یک طیف وسیع تغییرپذیر است (برخلاف پارامتر Eps)، بدون اینکه در نتایج الگوریتم تغییری حاصل شود و این به معنای کاهش حساسیت به پارامتر ورودی است. این کاهش حساسیت باعث انتخاب سریع‌تر و ساده‌تر مقدار دقیق پارامترها می‌شود، به گونه‌ای که در ارزیابی‌های انجام شده روی نتایج آزمایش‌ها، فقط با تعداد معده‌دی آزمون روی مجموعه‌داده‌ها نتایج مطلوبی به دست آمده است.

به علاوه، یکی از خصوصیت‌های بارز الگوریتم DBSCAN سادگی و درک‌پذیر بودن آن است. در الگوریتم پیشنهادشده، این سادگی و درک‌پذیر بودن به خوبی رعایت شده است، بنابراین، نقاط نویز ممکن است طی فراخوانی‌های بعدی الگوریتم DBSCAN برچسب خوشه بگیرند.

الگوریتم پیشنهادی با استفاده از شاخص مکانی KD-Tree پیاده‌سازی شده است.تابع K-نزدیک‌ترین همسایه^۱ با گرفتن یک نقطه به عنوان ورودی، k ‌امین نزدیک‌ترین همسایه آن نقطه را بر می‌گرداند. تابع Distance نیز فاصله بین دو شیء ورودی‌اش را محاسبه می‌کند. همان‌طور که اشاره شد، تعیین پارامترهای الگوریتم پیشنهادی در مقایسه با سایر الگوریتم‌ها ساده‌تر است. پارامتر Minpts که حداقل تعداد نقاط یک خوشه را مشخص می‌کند، بسته به مجموعه‌داده بررسی شده قابل تعیین است. بدیهی است که پارامتر k حداقل باید به اندازه Minpts باشد، زیرا در غیر این صورت ممکن است خوشه‌ای یافت نشود. به بیان دیگر، پارامتر k باید به گونه‌ای باشد که در فاصله بین نقطه بررسی شده و k ‌امین نزدیک‌ترین همسایه‌اش یک خوشه تشکیل شود، یعنی حداقل Minpts نقطه در این فاصله قرار گرفته باشد. بنابراین، اگر پارامتر k حداقل به اندازه Minpts باشد، این شرط برقرار خواهد بود. در رابطه با پارامتر L نیز همان‌گونه که در آزمایش‌ها نشان داده شده است، می‌توان این پارامتر را با مقدار ثابت Minpts تنظیم کرد.

ارزیابی نتایج آزمایش

در این بخش، ابتدا مجموعه‌داده آزمون تشریح شده، سپس، تنظیمات سخت‌افزاری و شبیه‌سازی آزمایش و در بخش نهایی، ارزیابی نتایج تشریح شده است. پیاده‌سازی الگوریتم پیشنهادی و الگوریتم‌های

مقایسه شده، روی رایانه شخصی با مشخصات پردازنده سه‌هسته‌ای اینتل، حافظه ۴ گیگابایت و سیستم عامل ویندوز ۱۰، و در محیط نرم‌افزاری MATLAB-R2020b انجام شده است. در شبیه‌سازی آزمایش‌ها، از ۴ مجموعه داده استاندارد استفاده شده است شامل Image segmentation با ۲۳۱۰ نمونه، ۷ کلاس و ۱۹ ویژگی، Pendigit با ۱۰۹۹۲ نمونه، ۴۴ کلاس و ۱۶ ویژگی، Letters با ۲۰۰۰ نمونه، ۴۰ کلاس و ۱۶ ویژگی و درنهایت، Shuttle control با ۵۸۰۰ نمونه، ۲ کلاس و ۱۵ ویژگی. این ۴ مجموعه داده از پایگاه داده‌های UCI^۱ برداشته شده است.

در کلیه آزمایش‌ها، از روش اعتبارسنجی $K=10$ استفاده شده و نتایج به صورت میانگین محاسبه و نشان داده شده است. برای ارزیابی سرعت از معیار ثانیه و برای دقت دسته‌بندی از معیار خطای MSE استفاده شده است که مطابق رابطه ۲ محاسبه شده است.

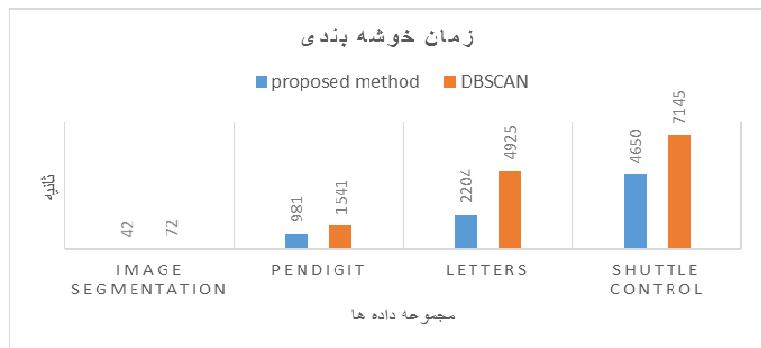
$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (رابطه ۲)$$

که در آن، پارامتر \hat{Y} خروجی واقعی، \hat{Y} خروجی الگوریتم است و n تعداد نمونه‌ها است. نتایج تجربی آزمایش، به منظور ارزیابی عملکرد الگوریتم پیشنهادی و الگوریتم استاندارد DBSCAN مقایسه شده است. در واقع، در این مقایسه پس از خوشه‌بندی و برچسب‌گذاری داده‌ها در خوشه‌های مختلف، میزان صحیح برچسب‌گذاری شده‌ها با توجه به مجموعه داده‌ها مقایسه شده و میزان خطای محاسبه شده است. در جدول ۱، زمان اجرای خوشه‌بندی و میزان خطای در آزمایش روش پیشنهادی و الگوریتم استاندارد DBSCAN مقایسه شده است.

جدول ۱. مقایسه نتایج الگوریتم پیشنهادی

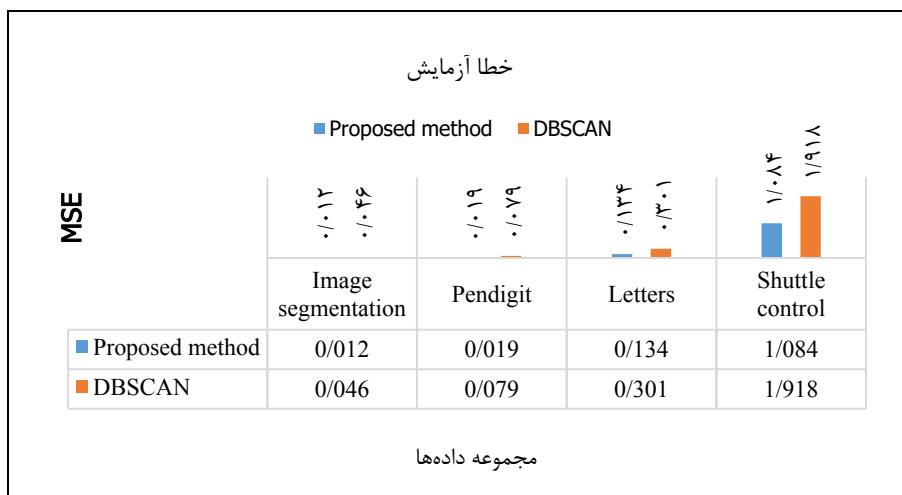
روش استاندارد		DBSCAN		مجموعه داده
(MSE) در صد خطای	زمان (S)	(MSE) در صد خطای	زمان (S)	
۰/۰۴۶	۷۲	۰/۰۱۲	۴۲	Image segmentation
۰/۰۷۹	۱۵۴۱	۰/۰۱۹	۹۸۱	Pendigit
۰/۳۰۱	۴۹۲۵	۰/۱۳۴	۲۲۰۴	Letters
۱/۹۱۸	۷۱۴۵	۱/۰۸۴	۴۶۵۰	Shuttle control

در شکل ۶، میزان زمان اجرای خوشه‌بندی برای مجموعه داده‌های آزمایش شده نشان داده شده است که نشان می‌دهد در خوشه‌بندی پیشنهادی، زمان اجرای خوشه‌بندی کاهش یافته و هرچه مجموعه داده حجمی‌تر باشد، کاهش زمان اجرای خوشه‌بندی محسوس‌تر است.



شکل ۶. مقایسه زمان خوشه‌بندی

در شکل ۷، میزان خطای آزمایش برای مجموعه داده‌ها نشان داده شده است. در خوشه‌بندی پیشنهادی، میزان معیار خطا کاهش یافته، زیرا برچسب داده‌ها متناسب با کلاس داده‌ها، با تعداد بیشتر بوده است.



شکل ۷. مقایسه خطای آزمایش

مقایسه بین الگوریتم‌های پیشنهادی و بهبودیافته خوشه‌بندی DBSCAN شامل دو روش K-DBSCAN و H-DBSCAN که روش پیشنهادی هم برگرفته از آنها است، در جدول ۲ نشان می‌دهد که روش پیشنهادی در مجموعه داده‌های مشترک توانسته است که معیارهای زمان اجرای خوشه‌بندی و دقیقیت مناسبی را به همراه داشته باشد.

جدول ۲. مقایسه نتایج الگوریتم پیشنهادی با سایر روش‌ها

روش h-DBSCAN		روش K-DBSCAN		روش پیشنهادی DBSCAN		مجموعه داده
درصد خطأ (MSE)	زمان (S)	درصد خطأ (MSE)	زمان (S)	درصد خطأ (MSE)	زمان (S)	
۵۳	۰/۰۱۱	۴۱	۰/۰۱۳	۴۲	۰/۰۱۲	Image segmentation
۱۰۸۱	۰/۰۱۷	۹۷۵	۰/۰۲۵	۹۸۱	۰/۰۱۹	Pendigit
۲۴۸۰	۰/۱۲۹	۲۱۱	۰/۱۴۶	۲۲۰۴	۰/۱۳۴	Letters
۴۹۹۱	۱/۰۷۱	۲۴۸۰	۱/۱۱۲	۴۶۵۰	۱/۰۷۱	Shuttle control

در جدول ۲، زمان اجرای خوشه‌بندی در روش پیشنهادی با دو روش K-DBSCAN و H-DBSCAN مقایسه شده است و نشان می‌دهد که خوشه‌بندی در روش K-DBSCAN با زمان کمتری در مقایسه با سایر روش‌های خوشه‌بندی انجام شده است. معیار خطای خوشه‌بندی در روش پیشنهادی با دو روش K-DBSCAN و H-DBSCAN مقایسه شده که نشان می‌دهد خوشه‌بندی در روش H-DBSCAN با خطای کمتری در مقایسه با سایر روش‌های دیگر خوشه‌بندی انجام شده است.

همان‌طور که از نتایج تجربی جدول ۲ مشخص است، روش پیشنهادی نتایج زمان اجرای خوشه‌بندی و خطای آزمایش کمتری از روش H-DBSCAN دارد. در واقع، با توجه به اینکه از خاصیت هر دو روش استفاده می‌کند، نتایج آن حد متوسطی دارد. در حالتی که هر دو معیار زمان اجرای خوشه‌بندی و دقت هم‌زمان مد نظر باشند، روش پیشنهادی می‌تواند روش مطلوب‌تری باشد.

نتیجه‌گیری و کارهای آتی

همان‌طور که در شبیه‌سازی‌های روش پیشنهادی مشاهده شد، این روش توانسته در مقایسه با خوشه‌بندی استاندارد DBSCAN به طور مطلوب‌تری عمل کند و خوشه‌بندی در زمان کمتر و دقت بالاتری در آزمایش‌ها داشته باشد. براساس ارزیابی نتایج آزمایش‌ها، روی مجموعه داده Image segmentation، الگوریتم پیشنهادی در ۴۲ ثانیه زمان خوشه‌بندی داشت، در صورتی که در مقایسه با خوشه‌بندی استاندارد DBSCAN میزان ۲۰ ثانیه کمتر و در مقایسه با الگوریتم خوشه‌بندی H-DBSCAN میزان ۱۱ ثانیه کمتر بود. به علاوه، خطای الگوریتم پیشنهادی به اندازه ۰/۰۳۴ در مقایسه با خوشه‌بندی استاندارد DBSCAN و در مقایسه با الگوریتم خوشه‌بندی K-DBSCAN میزان ۰/۰۰۱ کمتر بوده است. همچنین، روی مجموعه داده Pendigit، الگوریتم پیشنهادی نیاز به ۹۸۱ ثانیه خوشه‌بندی داشت که این در مقایسه با الگوریتم خوشه‌بندی H-DBSCAN ۱۰۰ ثانیه کمتر بوده است. روی مجموعه داده‌های Letters و Shuttle control که تعداد نمونه‌های بیشتری دارد، نتایج اختلاف بیشتری را نشان می‌دهد، به‌طوری که روی مجموعه داده Letters در الگوریتم پیشنهادی، زمان خوشه‌بندی ۲۲۰۴ ثانیه بود، اما در خوشه‌بندی استاندارد DBSCAN زمان بیشتر از دو برابر بوده و

همچنین، در مقایسه با الگوریتم خوشه‌بندی H-DBSCAN نیز زمان خوشه‌بندی کمتری داشته است. میزان خطای روی مجموعه‌داده Shuttle control در روش پیشنهادی حدود $0/834$ کمتر از خوشه‌بندی استاندارد DBSCAN است. به علاوه، در الگوریتم پیشنهادی زمان لازم برای خوشه‌بندی 4650 ثانیه بود، اما در خوشه‌بندی استاندارد DBSCAN زمان 7145 ثانیه است. میزان خطای در این مجموعه‌داده در روش پیشنهادی حدود $0/028$ در مقایسه با الگوریتم K-DBSCAN کمتر بوده است.

ضعف الگوریتم پیشنهادی، در زمان خوشه‌بندی در مقایسه با الگوریتم K-DBSCAN روی مجموعه‌داده Image segmentation مقدار 1 ثانیه، روی مجموعه‌داده Pendigit مقدار 6 ثانیه، روی مجموعه‌داده Letters مقدار 93 ثانیه و روی مجموعه‌داده Shuttle control مقدار 485 ثانیه بود. به علاوه، خطای آزمایش در مقایسه با الگوریتم H-DBSCAN روی مجموعه‌داده Image segmentation مقدار $0/001$ ، روی مجموعه‌داده Pendigit مقدار $0/002$ ، روی مجموعه‌داده Letters مقدار $0/005$ و روی مجموعه‌داده Shuttle control مقدار $0/013$ بوده است. به طور کلی، می‌توان گفت که الگوریتم پیشنهادی، در معیار دقت در مقایسه با الگوریتم H-DBSCAN، ضعف کمتری دارد، اما از طرفی در مقایسه با آن، زمان خوشه‌بندی مناسب‌تری دارد.

فهرست منابع

- Ankerst, M., Breunig, M. M., Kriegel, H.P., & Sander, J. (1999). OPTICS. *ACM SIGMOD Record*, 28(2), 49–60.
- Bechini, A., Criscione, M., Ducange, P., Marcelloni, F., & Renda, A. (2020). FDBSCAN-APT: A Fuzzy Density-based Clustering Algorithm with Automatic Parameter Tuning. *2020 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)*.
- Botts, C. H. (2021). A Novel Metric for Detecting Anomalous Ship Behavior Using a Variation of the DBSCAN Clustering Algorithm. *SN Computer Science*, 2(5).
- Chen, Y., Tang, S., Bouguila, N., Wang, C., Du, J., & Li, H. (2018). A fast clustering algorithm based on pruning unnecessary distance computations in DBSCAN for high-dimensional data. *Pattern Recognition*, 83, 375–387.
- Chen, Y., Zhou, L., Bouguila, N., Wang, C., Chen, Y., & Du, J. (2020). BLOCK-DBSCAN: Fast Clustering For Large Scale Data. *Pattern Recognition*, 107624.
- Chimwayi, K. B., & Anuradha, J. (2018). Clustering West Nile Virus Spatio-temporal data using ST-DBSCAN. *Procedia Computer Science*, 132, 1218–1227.
- De Moura Ventorim, I., Luchi, D., Rodrigues, A. L., & Varejão, F. M. (2021). BIRCHSCAN: A sampling method for applying DBSCAN to large datasets. *Expert Systems with Applications*, 184, 115518.
- Deng, D. (2020). DBSCAN Clustering Algorithm Based on Density. *2020 7th International Forum on Electrical Engineering and Automation (IFEEA)*.
- Galán, S. F. (2019). Comparative evaluation of region query strategies for DBSCAN clustering. *Information Sciences*, 502, 76–90.

- Gholizadeh, N., Saadatfar, H., & Hanafi, N. (2021). K-DBSCAN: An improved DBSCAN algorithm for big data. *The Journal of supercomputing*, 77, 6214-6235.
- Hartmann, S., Ma, H., Hameurlain, A., Pernul, G., & Wagner, R. R. (Eds.). (2018). *Database and Expert Systems Applications*. Lecture Notes in Computer Science.
- Heidari, S., Alborzi, M., Radfar, R., Afsharkazemi, M. A., & Rajabzadeh Ghatari, A. (2019). Big data clustering with varied density based on MapReduce. *Journal of Big Data*, 6, 1-16.
- Kim, J. H., Choi, J.H., Yoo, K. H., & Nasridinov, A. (2018). AA-DBSCAN: an approximate adaptive DBSCAN for finding clusters with varying densities. *The Journal of Supercomputing*, 75(1), 142- 169.
- Kuo, F. Y., Wen, T.H., & Sabel, C. E. (2018). Characterizing Diffusion Dynamics of Disease Clustering: A Modified Space–Time DBSCAN (MST-DBSCAN) Algorithm. *Annals of the American Association of Geographers*, 108(4), 1168–1186.
- Lai, W., Zhou, M., Hu, F., Bian, K., & Song, Q. (2019). A New DBSCAN Parameters Determination Method Based on Improved MVO. *IEEE Access*, 7, 104085–104095.
- Li, S. (2020). An Improved DBSCAN Algorithm Based on the Neighbor Similarity and Fast Nearest Neighbor Query. *IEEE Access*, 1–1.
- Louhichi, S., Gzara, M., & Abdallah, H. B. (2018). Skin Lesion Segmentation Using Multiple Density Clustering Algorithm MDCUT And Region Growing. *2018 IEEE/ACIS 17th International Conference on Computer and Information Science (ICIS)*.
- Louhichi, S., Gzara, M., & Ben-Abdallah, H. (2018). MDCUT2: a multi-density clustering algorithm with automatic detection of density variation in data with noise. *Distributed and Parallel Databases*, 37, 73-99.
- Pavlis, M., Dolega, L., & Singleton, A. (2017). A Modified DBSCAN Clustering Method to Estimate Retail Center Extent. *Geographical Analysis*, 50(2), 141–161.
- Sabor, K., Jougnot, D., Guerin, R., Steck, B., Henault, J.M., Apffel, L., & Vautrin, D. (2021). A data mining approach for improved interpretation of ERT inverted sections using the DBSCAN clustering algorithm. *Geophysical Journal International*, 225(2), 1304–1318.
- Sharma, A., & Upadhyay, D. (2018). VDBSCAN clustering with map-reduce technique. In Recent Findings in Intelligent Computing Techniques: *Proceedings of the 5th ICACNI 2017*, Volume 2 (pp. 305-314). Springer Singapore.
- Sheridan, K., Puranik, T. G., Mangortey, E., Pinon-Fischer, O. J., Kirby, M., & Mavris, D. N. (2020). An application of dbscan clustering for flight anomaly detection during the approach phase. In *AIAA Scitech 2020 Forum* (p. 1851).
- Wang, Q., Wang, Z., Zhang, L., Liu, P., & Zhang, Z. (2020). A novel consistency evaluation method for series-connected battery systems based on real-world operation data. *IEEE Transactions on Transportation Electrification*, 7(2), 437-451.

- Wang, Y., Gu, Y., & Shun, J. (2020, June). Theoretically-efficient and practical parallel DBSCAN. In *Proceedings of the 2020 ACM SIGMOD International Conference on Management of Data* (pp. 2555-2571).
- Weng, S., Gou, J. & Fan, Z. (2021). h-DBSCAN: A simple fast DBSCAN algorithm for big data. *Proceedings of The 13th Asian Conference on Machine Learning*, PMLR 157:81-96, 2021.
- Wu, X., Cheng, C., Zurita-Milla, R., & Song, C. (2020). An overview of clustering methods for geo-referenced time series: from one-way clustering to co- and tri-clustering. *International Journal of Geographical Information Science*, 1-27.
- Yu, X., Zeng, F., Mwakapesa, D. S., Nanehkaran, Y. A., Mao, Y. -M., Xu, K. -B., & Chen, Z. -G. (2021). DBWGIE-MR: A density-based clustering algorithm by using the weighted grid and information entropy based on MapReduce. *Journal of Intelligent & Fuzzy Systems*, 40(6), 10781–10796.

An Extended Density-based Clustering Algorithm in Big Data

Reza Ghaemi *¹

Assistant Prof., Department of Computer Engineering, Quchan Branch, Islamic Azad University, Quchan, Iran

Yaghoob Arad

Ph.D. Candidate, Department of Computer Engineering, Science and Research Branch, Islamic Azad University, Neyshabour, Iran

Fereshteh Hajghazi

Ph.D. Candidate, Department of Computer Engineering, Science and Research Branch, Islamic Azad University, Neyshabour, Iran

Abstract

Today, data generation through smart equipment, including mobile phones, has faced a significant growth, and clustering is one of the most widely used knowledge discovery techniques in big data. Density-based clustering (DBSCAN) is one of the most efficient clustering algorithms in data mining, and despite having advantages, it also has problems, such as the difficulty in determining the input parameters, as well as not being able to detect clusters with different densities. In the proposed algorithm of this article, it is inspired by the K-DBSCAN algorithm in grouping large data with the aim of reducing the clustering execution time. In addition, by using K-Means and H-DBSCAN algorithms, different densities of the data set were identified and an Eps radius was determined for each density, and then, the proposed density-based clustering algorithm was developed with parameters. The matching is applied to the data, and in fact, the innovation of this article is the use of K Means clustering and the estimation of different densities in the DBSCAN clustering method. The proposed algorithm has been compared with the simple DBSCAN clustering algorithm and two developed K-DBSCAN and H-DBSCAN algorithms on four standard data sets: Image segmentation, Pendigit, Letters and Shuttle control. The results show that the proposed algorithm is superior to other algorithms when both time and accuracy are criteria in clustering.

Keywords: Big data, Clustering, DBSCAN, K-DBSCAN, H-DBSCAN, K-Means.

1. Corresponding Author: r.ghaemi@iauq.ac.ir