

خوشبندی اطلاعات

چکیده

خوشبندی، فرایند سازماندهی عنصر بر گروههایی است که اجزای آن به هم شیوه هستند. یک خوش، مجموعه عناصری است که با هم مشابهت دارند و با اجزای دیگر خوشها ناهمگون می‌باشند. هدف خوشبندی، دستیابی سریع و مطمئن به اطلاعات همبسته، و شناسایی ارتباط منطقی میان آنهاست. بنابراین، الگوریتم‌های خوشبندی می‌توانند دررسیاری از حوزه‌های موضوعی به کار گرفته شود. از آنجا که نتایج خوشبندی می‌توانند با تعداد اصطلاح‌های مورد استفاده تغییر یابد، روش‌های تجربی متعددی برای تشخیص تعداد تقریبی اصطلاح‌هایی که می‌توان انتظار داشت تا توزیع مناسب داده‌ها را در میان خوشها فراهم سازد و حدود بالا و پایین الگوریتم خوشبندی را تعیین کند، ارائه شده است. یکی از کاربردهای خوشبندی، سازماندهی اصطلاحنامه‌هاست. در این مقاله، با بهره‌گیری از روش مطالعه کتابخانه‌ای، ضمن بررسی مفهوم خوشبندی اطلاعات، روش‌های مؤثر خوشبندی اطلاعات و کاربرد آن در ساختار تزاروس (اصطلاحنامه) بیان شده است. از جمله روش‌های عمده خوشبندی چهار شیوه خوشبندی دسته‌ای، تک‌پیوندی، ستاره‌ای، و رشته‌ای است. نتیجه این مطالعه نشان می‌دهد که بهره‌گیری از الگوریتم‌های مناسب و روش‌های سودمند خوشبندی اطلاعات می‌تواند نقشی مهم در سازماندهی بهینه اصطلاحنامه داشته باشد.

-کلیدواژه‌ها-

خوشبندی اطلاعات، تزاروس (اصطلاحنامه)، نظام‌های بازیابی اطلاعات، خوشبندی مدارک

خوشبندی اطلاعات

نرگس محمدعلیپور^۱ | فریز درودی^۲

دریافت: ۱۳۸۶/۹/۱ پذیرش: ۱۳۸۶/۵/۳۰

مقدمه

خوشبندی اطلاعات و منابع اطلاعاتی یکی از راهکارهای مؤثر در سازماندهی اطلاعات به شمار می‌آید. با انجام فرایندهای خوشبندی اطلاعات، حیطه گستردگی از داده‌های پراکنده در گروههای مدون و سازمان یافته قرار می‌گیرند. گروههای متعدد ایجاد شده، با برخورداری از ویژگی‌های مشترک درون هر گروه، دارای ارتباط ارگانیک و ساختاری با یکدیگر هستند. یکی از کاربردهای مؤثر و سودمند خوشبندی در ایجاد تزاروس یا اصطلاح‌نامه^۳ می‌باشد. برای بهره‌گیری از اصطلاحات تخصصی نیاز به تدوین و سازماندهی روشنمند واژگان است. در این رابطه انتخاب اصطلاح‌های اصلی، به همراه مترادف‌ها و هم معناهای آن، یکی از کاربردهای خاص خوشبندی می‌باشد. در نظامهای بازیابی اطلاعات نیز خوشبندی نقشی مؤثر ایفا می‌کند. برای دسترسی به منابع اطلاعاتی، شناسایی ابعاد و جنبه‌های خاص موضوعی مفاهیم، که با اصطلاح‌های تخصصی مشخص می‌شوند، ضروری است. با تدوین راهبردهای اثربخشی که در خوشبندی اطلاعات وجود دارد، می‌توان براساس نیاز اطلاعاتی کاربر، به نتایج مناسب‌تری در بازیابی اطلاعات دست یافت. شیوه‌های مؤثر خوشبندی، با تدوین رده‌های اصلی و زیررده‌های وابسته شکل می‌گیرد. انواع الگوریتم‌ها و روش‌های تخصصی در تدوین روابط میان خوشبندی اطلاعات و معرفی اصطلاحات مرتبط مورد بررسی قرار می‌گیرند.

۱. عضو هیئت علمی دانشگاه آزاد اسلامی

واحد رودهن

۲. دکتری کتابداری و اطلاع‌رسانی

سازمان اسناد و کتابخانه ملی ایران

f.doroudi@nlaei.ir

3. Thesaurus

و تعامل ساختاری، به کارآمد ساختن فرایندهای خوشبندی یاری می‌رساند. خوشبندی اطلاعات، درواقع، تدوین رده‌های ویژه برای گروه‌بندی مدون و منظم اطلاعات است که به بازیابی بهینه آن منجر می‌شود.

هدف پژوهش

هدف اصلی این پژوهش، تبیین دقیق و مناسب مفهوم خوشبندی اطلاعات است و انواع شیوه‌ها و روش‌های مناسب خوشبندی مورد بررسی قرار گرفته است. همچنین، مراحل انجام فرایند خوشبندی اطلاعات تشریح شده، و روابط خوشبندی بیان می‌شود. بررسی انواع الگوریتم‌های خوشبندی مورد توجه قرار گرفته و کاربرد خوشبندی در ساختار تزاروس و اصطلاحنامه مطرح شده و در این رابطه نکات مهم تشریح می‌شود.

روش پژوهش

روش انجام این پژوهش مطالعه کتابخانه‌ای و جستجو در منابع اطلاعاتی، بهمنظور به دست آوردن اطلاعات جدید در زمینه خوشبندی اطلاعات، فرایندها، روش‌ها، مراحل و انواع شیوه‌های مؤثر خوشبندی است.

پیشینهٔ پژوهش

جین، مورتی و فلین^۴ (۱۹۹۹)، در اثر تحقیقی خود با عنوان «مروری بر خوشبندی داده‌ها»، که در سال ۱۹۹۹ به انجام رسیده، بیان می‌کنند که خوشبندی، طبقه‌بندی غیرنظری‌تری الگوها، شامل مشاهدات، اقلام داده‌ای یا بُردارهای خصیصه‌ای، به گروه‌ها و خوشبندی‌های منظم است. آنان شرح می‌دهند که مشکل خوشبندی در بسیاری از زمینه‌ها، توسط محققان علوم مختلف مورد توجه قرار گرفته است. این امر، نشانگر فایده و درخواست وسیع آن به عنوان یکی از مراحل تحلیل داده‌کاوی است. خوشبندی، فرایند تخصصی دشواری است و اختلاف در فرضیه‌ها و زمینه‌های موضوعی باعث شده تا انتقال مفاهیم مفید به کندي صورت پذیرد. آنان همچنین، مروری کلی بر الگوهای خوشبندی از منظر الگوشناسی آماری، با هدف فراهم‌آوری مراجع و توصیه‌های مفید درخصوص مفاهیم بنیادین خوشبندی ارائه می‌دهند. علاوه بر آن، در این اثر یک طبقه‌بندی از فنون خوشبندی و پیشرفت‌های اخیر در زمینهٔ پرش مقطعی موضوع‌های مختلف ارائه شده است. در ادامه، برخی از کاربردهای حائز اهمیت الگوریتم‌های خوشبندی از قبیل قطعه‌بندی تصاویر، بازشناسی موضوعی و بازیابی اطلاعات توضیح داده می‌شود.

در پژوهش انجام یافته توسط برو و رید^۵ (۲۰۰۵)، درباره خوشبندی سلسه‌مراتبی

4. Jain, Murty & Flynn
5. Breaux & Reed

اطلاعات، با استفاده از زبان‌های هستی‌شناسی، در سال ۲۰۰۵، مشخص شد که ابزارهای تحلیل و تجسم‌سازی اطلاعات از منابع ناهمگن متعدد، با تکیه بر بهبود و پیشرفت روش‌های آماری، بهره گرفته است. تحقیقات انجام شده درخصوص زبان‌های هستی‌شناسی، راه‌های نویدبخشی را برای غلبه بر محدودیت‌های موجود ارائه می‌دهد. در این تحقیق، معلوم شد که در زبان‌های هستی‌شناسی، استفاده از خصیصه‌های معنایی، که به شکل رمز درآمده‌اند، می‌تواند از طریق روش‌هایی مانند جست‌وجوی کلیدواژه و خوشه‌بندی برای تحلیل و تصویرسازی مدارک در سطوح ادراکی بالاتر به کار گرفته شود. آنان مشخص کردند که یافته‌های حاصل از نظام خوشه‌بندی سلسله‌مراتبی اصلاح شده برای شاخص‌بندی زبان‌های هستی‌شناسی و اجرای آن در آزمون‌های موضوعی مجموعه مدرک‌هایی که کمتر از ۲۰۰ واژه را پوشش می‌دهند، به خوبی می‌تواند به کار گرفته شود.

جین و لا^۶ (۲۰۰۵)، در مقالهٔ خود با عنوان «خوشه‌بندی داده‌ها: معماه غیرقابل حل کاربر»، در سال ۲۰۰۵، به تحلیل وضعیت خوشه‌ها در ارتباط با ابزارهای کاوش خودکار در برنامهٔ گروه‌سازی مجموعهٔ الگوها می‌پردازند. آنان تشریح می‌کنند که با وجود آنکه بیش از ۴۰ سال از پژوهش‌های مربوط به این حوزه می‌گذرد، هنوز چالش‌های زیادی در فرایند خوشه‌بندی داده، چه از لحاظ نظری و چه از ابعاد عملی وجود دارد. همچنین، آنان تلاش کرده‌اند تا چند پیشرفت اخیر در ارتباط با فعالیت خوشه‌بندی داده‌ها را توضیح داده و ویژگی‌های آن را بیان کنند. خوشه‌بندی دسته‌جمعی، گزینش خصیصه‌ها و خوشه‌بندی دارای محدودیت، از زمرة مواردی است که در این اثر درباره آنها بحث شده است.

سونگ^۷ (۲۰۰۵)، نیز در پژوهشی که در سال ۲۰۰۵ با عنوان «الگوریتم خوشه‌بندی اطلاعات بالهمیت» به انجام رسانده است، بر موضوع خوشه‌بندی اطلاعات بالهمیت، برمبنای بهینه‌سازی کمینه‌سازی و بیشینه‌سازی اطلاعات متقابل، تمرکز داشته است. از مزایای اصلی این روش خوشه‌بندی اطلاعات آن است که یک روش غیرپارامتری است، و الگوریتم ساده خوشه‌بندی داده‌ها را براساس فاصلهٔ اقلیدسی مربع خطاهای تشکیل می‌دهد.

آتنونی و دیزاردن^۸ (۲۰۰۶)، در مقاله‌ای که دربارهٔ مشکلات مطرح در خوشه‌بندی رابطه‌ای داده‌ها، در سال ۲۰۰۶، ارائه داده‌اند، بیان می‌کنند که وظيفة خوشه‌بندی داده‌ها، شناسایی الگوها در مجموعه‌ای از داده‌هاست. بیشتر الگوریتم‌ها، داده‌های غیرابطه‌ای را به عنوان ورودی در نظر گرفته و گاهی نیز قادر به یافتن الگوهای معنی دار نیستند. بسیاری از مجموعه داده‌ها، می‌توانند علاوه بر داشتن نشانه‌های موضوعی مستقل، شامل اطلاعات رابطه‌ای نیز باشند. آنان همچنین اظهار می‌دارند: در جایی که الگوریتم‌های غیرابطه‌ای شکست می‌خورند، خوشه‌بندی رابطه‌ای داده‌ها می‌تواند به یافتن الگوهای معنی دار کمک کند.

آنونی و دیزاردن^۹ (۲۰۰۷)، در اثر دیگر خود، دربارهٔ خوشه‌بندی داده‌ها با مدل رابطه‌ای

6. Jain & Law

7. Song

8. Anthony & desJardins

فشار-کشش، توضیح می‌دهند که خوشبندی رابطه‌ای داده‌ها، نوعی یادگیری رابطه‌ای است که داده‌ها را با استفاده از ساختار رابطه‌ای مجموعه داده‌ها به صورت خوشبندی متعدد درآورده تا فرایند خوشبندی را هدایت کند. در این میان، روش‌های متعددی برای خوشبندی رابطه‌ای پیشنهاد شده است. فرضیه متدالو در این پژوهش آن است که رابطه‌ها گرایش پیوندی دارند. یعنی فرض می‌شود لبه‌ها بیشتر در درون خوشبندی قرار می‌گیرند تا بین خوشبندی.

همچنین، در ارتباط با کاربرد خوشبندی اطلاعات در بخش تجاری، پرلیش و روزت^۹ (۲۰۰۷)، در تحقیقی که درباره شناسایی بسته‌های انتخابی محصول با استفاده از خوشبندی اطلاعات متقابل به انجام رسانده‌اند، روش بدیعی را به منظور کاهش تعداد انتخاب‌های پیکربندی محصولات پیچیده، از طریق شناسایی مجموعه‌های معنی‌داری مشخص ساخته‌اند. آنان روش‌های سنجش مختلف آماری و نظریه اطلاعات، تا ثبت میزان همبستگی میان گزینه‌های هر جفت مؤلفه محصول را بررسی کرده‌اند. در این تحقیق، از خوشبندی سلسله‌مراتبی برای شناسایی مجموعه‌های معنی‌داری از مؤلفه‌ها که می‌توانند با یکدیگر ترکیب شده تا تعداد مشخصات منحصر به فرد محصول را کاهش داده و استانداردسازی تولید را افزایش دهد، استفاده کرده‌اند. کانون توجه و تحلیل پدیدآورندگان بر بررسی تأثیر اختلاف در سنجش شباهت‌ها، در ارتباط با توانایی خوشبندی برای یافتن خوشبندی معنی‌دار است.

مفهوم خوشبندی

جین، مورتی و فلین (۱۹۹۹)، در خصوص کاربرد خوشبندی بیان می‌کنند که خوشبندی برای انواع الگوی‌های تحلیل اکتشافی^{۱۰}، گروه‌بندی^{۱۱}، تصمیم‌گیری، و موقعیت‌های فرآگیری ماشینی^{۱۲}، شامل: داده‌کاوی^{۱۳}، بازیابی مدارک^{۱۴}، بخش‌بندی تصویر^{۱۵}، و طرح رده‌بندی سودمند است. نویل^{۱۶} و همکاران (۲۰۰۳)، خوشبندی را یک فعالیت توصیفی می‌دانند که شناسایی گروه‌بندی طبیعی داده‌ها را مورد کاوش قرار می‌دهد. جیونیز^{۱۷} (۲۰۰۴)، خوشبندی را یک مرحله مهم از فرایند پردازش تحلیل داده^{۱۸}، همراه با کاربردهای آن در حوزه‌های متعدد، معرفی می‌کند و اظهار می‌دارد که براساس تعریفی ساده و اولیه، خوشبندی به عنوان مقوله بخش‌بندی داده‌ها درون گروه‌ها یا خوشبندی‌ها تعریف شده، که این داده‌های موضوعی در همان گروه مشابه مرتبط هستند؛ در صورتی که، این عناصر، در گروه‌های مختلف دارای مشابهت نیستند. کراسکف^{۱۹} و دیگران (۲۰۰۵)، اظهار می‌دارند که مقصود از خوشبندی، جداسازی عناصر درون دسته‌هایی است که صرفاً در بُردار مشخصه^{۲۰} - مجموعه‌ای از

- 9. Perlich & Rosset
- 10. Exploratory pattern-analysis
- 11. Grouping
- 12. Machine-learning situations
- 13. Data mining
- 14. Document retrieval
- 15. Image segmentation
- 16. Neville
- 17. Gionis
- 18. Data analysis
- 19. Kraskov
- 20. Characteristic vector

اجزا و ویژگی‌ها- به کار می‌رود. روسل^{۲۱} (۲۰۰۶)، هدف خوشبندی را بخش‌بندی یک مجموعه ساختاریافته از عناصر، درون خوشه‌ها یا گروه‌های مشخص معرفی می‌کند و شرح می‌دهد که شخص اغلب می‌خواهد اجزای خود را به عنوان عوامل مشترک در همان خوشه‌ای قرار دهد که دارای صفات یکسان استند؛ و عناصر غیرمشترک را، تا حد ممکن، در خوشه‌ای جای دهد که به آن تعلق دارد. وی همچنین بیان می‌کند که خوشبندی در بسیاری از حوزه‌های موضوعی به کار گرفته شده و انواع زیادی از الگوریتم‌های خوشبندی برای مقاصد و موقعیت‌های متفاوت وجود دارد. کوالسکی^{۲۲} (۱۹۹۷)، با طرح کاربرد خوشبندی در کتابخانه‌ها و مراکز اطلاع‌رسانی، هدف اصلی فرایند خوشبندی را یاری‌رسانی به کاربر در تشخیص محل دقیق اطلاعات می‌داند، که این عمل در نهایت موجب تهیه طرح‌های نمایه‌سازی برای سازماندهی بهتر مدارک در کتابخانه‌ها، و استانداردهای مرتبط با استفاده از نمایه‌های الکترونیکی^{۲۳} شده است. در مجموع، با بیان نظر متخصصان درباره مفهوم خوشبندی می‌توان اظهار کرد که خوشبندی عبارت است از: مرتب کردن واژه‌ها یا مدارک شبیه بهم در یک رده باعنوان کلی. از لحاظ کاربردی، خوشبندی سبب بهینه‌سازی فعالیت جست‌وجوی اطلاعات شده و زمان جست‌وجوی کاربر را کاهش می‌دهد. در یک کاوش نظاممند و بر مبنای استفاده از پرس‌وجوهای مبتنی بر راهبردهای کاوش، خوشبندی سبب ایجاد ارتباط میان خوشه‌های مختلف شده و در مجموع به نتایج سودمندی منجر می‌شود. از سوی دیگر، خوشبندی سبب شده تا گروهی از موضوعات مشابه در زیر یک رده، باعنوان کلی سازماندهی شوند. این فعالیت، در دستیابی به اطلاعات مرتبط با موضوع خواسته شده تأثیر بسزایی دارد و باعث دسترسی مطلوب به اطلاعات هم‌موضوع می‌شود.

انواع خوشبندی بر اساس روش کاری

فرایند خوشبندی اطلاعات، روشنی است که هرچه بهتر انجام شود، بازیابی اطلاعات دقیق‌تر انجام خواهد پذیرفت. توجه به کاربرد اثربخش خوشبندی ما را به این نکته رهنمون می‌سازد که کلید خوشبندی موفق در رعایت دو عامل مهم است: نخست انتخاب یک مقیاس مناسب برای تعیین تشابه‌ها؛ و دوم به کارگیری الگوریتم کارآمد، برای جانمایی مکان اجرا در رده‌های مشابه و مناسب. برای انجام چنین فعالیتی می‌توان از روش‌های دستی و یا ماشینی خوشبندی بهره‌گرفت. هریک از روش‌های نامبرده دارای ویژگی‌های خاص خود است. در ادامه به توضیح این دو نوع خوشبندی می‌پردازیم.

21. Rosell

22. Kowalski

23. Electronic indexes

خوشبندی دستی

براساس بیان کوالسکی (۱۹۹۷، ص ۱۲۹ - ۱۳۰)، خوشبندی دستی بهمنظور تعیین موضوع و دامنه موضوعی و در واقع حد و حدود فعالیت کاری انجام می‌پذیرد. این فرایند را به دو منظور انجام می‌دهیم: ۱) تقلیل اشتباها مربوط به واژه‌های همنوشت و یا هم‌املا، ۲) کمک به افزایش تمرکز در ایجاد خوشها. از واژه‌نامه‌ها به عنوان نقطه شروع کار برای تهیه اصطلاحنامه استفاده شده که منجر به تهیه و تولید کشف‌اللغات می‌شود. کشف‌اللغات^{۲۴} عبارت است از فهرست الفبایی واژه‌ها، همراه با تعداد تکرار آن در متن و تعیین محل دقیق واژه. به عبارت دیگر، نمایه‌ای از واژه‌های اصلی هر اثر که جای آنها را در متن نشان داده و عموماً واژه‌های قبل و بعد از مطلب را ذکر می‌کند و گاهی اوقات تعریف واژه‌ها را نیز ارائه می‌دهد. برای ساخت اصطلاحنامه، به صورت دستی، کافی است واژه‌های مناسب انتخاب شود، البته ابزارهای دیگری نیز در انتخاب واژه‌ها مفید خواهد بود از قبیل: لغات کلیدی خارج از متن^{۲۵}، لغات کلیدی داخل متن^{۲۶} لغات کلیدی و متن^{۲۷}، و لغات کلیدی خارج از عنوان.^{۲۸}

خوشبندی ماشینی

خوشبندی خودکار (ماشینی) واژه‌های نوع دیگری از این فرایند است که انجام می‌پذیرد. برای ایجاد یک اصطلاحنامه آماری، روش‌های زیادی برای ماشینی کردن واژه‌ها وجود دارد. تمامی آنها به عنوان اساس کار، از این مفهوم استفاده می‌کنند که هر چه تکرار دو واژه در بخش‌های مشابه بیشتر باشد احتمال اینکه مفاهیم مشابهی داشته باشند بیشتر است. در ساده‌ترین مورد، داده‌ها یکبار در ایجاد رده‌ها به کار گرفته می‌شود. وقتی تعداد رده‌های ایجاد شده بسیار زیاد باشد، ممکن است رده‌های ابتدایی برای ایجاد رده‌های خلاصه‌تر یک سلسه‌مراتب ایجاد کنند، که به عنوان نقطه شروع استفاده می‌شوند. از ویژگی‌های این نوع خوشبندی آن است که حاوی رده‌هایی هستند که کاربرد واژه‌ها را منعکس می‌کنند. همچنین، رده‌ها به طور طبیعی اسم ندارند؛ بلکه به صورت گروه‌هایی با شرایط آماری مشابه هستند. به علاوه، تکنیک بهینه برای ایجاد رده‌ها نیاز به محاسبات زیادی دارد (کوالسکی، ۱۹۹۷، ص ۱۲۹ - ۱۳۱).

خوشبندی ماشینی روشی است که با تعیین معیارهای سنجش توسط رایانه به انجام می‌رسد و کلیه فرایندهای خوشبندی با تعیین رده‌های خاص در قالب هر خوش، به نحوی مؤثر در سازماندهی و دسته‌بندی داده‌ها مؤثر واقع می‌شود. تنظیم متعادل هر خوش با بهره‌گیری از الگوریتم خاص تعریف شده برای برنامه اعمال می‌شود. این الگوریتم روند تعیین اجزای هر رده را به خوبی مشخص ساخته و از راهبردهای رده‌شناسی^{۲۹} به نحو مطلوبی بهره می‌گیرد.

24. Concordance

25. Key Word out of context (Kwoc)

26. Key Word in context (Kwoc)

27. Key Word and context (Kwoc)

28. Key Word out of Title (Kwoc)

29. Taxonomy

الگوریتم‌های خوشبندی

برای انجام بهینه خوشبندی، باید از الگوریتم‌های مناسب این کار استفاده کرد. در این حوزه و فعالیت تخصصی، الگوریتم‌ها به ما کمک می‌کنند تا با بهره‌گیری از راه حل‌های فرمولی و مدون به خوشبندی مطلوب اطلاعات مبادرت ورزیم. این الگوریتم‌ها در رده‌های مختلف و با کاربردهای گوناگون معرفی شده‌اند. شناخت آنها به متخصصان کمک می‌کند تا به شیوه‌ای مناسب به انجام فرایند خوشبندی پردازند.

ماتوچی^{۳۰} (۲۰۰۳)، الگوریتم‌های خوشبندی را در چهار رده کلی معرفی می‌کند که شامل: خوشبندی انحصاری^{۳۱}، خوشبندی همپوشانی^{۳۲}، خوشبندی سلسه‌مراتبی^{۳۳}، و خوشبندی احتمالی^{۳۴} می‌شود. این تقسیم‌بندی کلی است و بر مبنای انواع کاربردهای خوشبندی ارائه شده است. برخی از این خوشبندی‌ها در فعالیت‌های این حوزه مورد توجه قرار گرفته، و در مواردی بسط داده است. چنانچه لیوسکی^{۳۵} (۲۰۰۲)، با توضیح پیرامون الگوریتم خوشبندی متراکم سلسه‌مراتبی^{۳۶} اظهار می‌کند که این الگوریتم، سلسه‌ای از خوشبندی‌ها را ایجاد می‌کند که با ساخت ارتباط درختی، در جایی که هر گره به عنوان خوشبندی از مفاهیم مطرح می‌شود، خوشبندی‌ها را مطابق با زیرمجموعه - فرزند - خود قرار می‌دهد که از یک بخش کامل از آن خوشبندی اخذ شده‌اند. کانانگو و همکاران^{۳۷} (۲۰۰۲)، به شرح الگوریتم خاصی در خوشبندی می‌پردازند که به نام الگوریتم خوشبندی کی مینز^{۳۸} شناخته شده است. این روش، یکی دیگر از الگوریتم‌های سودمند برای فرایند خوشبندی است. یک بحث اکتشافی عام درخصوص این خوشبندی الگوریتم لیود^{۳۹} می‌باشد، که آن را الگوریتم پالایش^{۴۰} نیز می‌نامند. کاربرد این الگوریتم ساده است و به راهبرد درخت کی دی^{۴۱}، به عنوان تنها ساختار داده اصلی، نیاز دارد. الگوریتم کی مینز به شکل اکتشافی برای حل مشکلات مطرح در این روش مورد استفاده قرار می‌گیرد و بر مبنای طرح تکرارشونده نمونه^{۴۲} پایه‌ریزی شده است، که جهت دستیابی به یک راه حل حداقلی به صورت موضعی عمل می‌کند. کوهن^{۴۳} (۲۰۰۶) نیز، با طرح موضوع خوشبندی معنایی^{۴۴}، بیان می‌کند که این شیوه یک روش غیرتعاملی و کنترل نشده است، که در ارتباط نزدیک با کارکردهای نمایه‌سازی معنایی پنهان^{۴۵} قرار دارد. دریاره این روش نمایه‌سازی، نظام نرم افزاری درون خوشبندی‌ها گروه‌بندی می‌شود. خوشبندی معنایی، یک رسته از موضوع‌هایی است که در همان مجموعه واژگان به کار برده می‌شود. براین‌اساس، هر خوشبندی، مفاهیم متفاوتی را مشخص می‌سازد که در نظام قابل بازیابی است. در نهایت، بهطور ذاتی، مفاهیم بدون مشخصه، با بهره‌گیری از برچسب‌های ویژه، از واژگان کدهای منبع مشخصه دریافت می‌کنند. الگوریتم خودکار، هر خوشبندی را با واژگانی که بیشترین ارتباط را دارند، برچسب گذاری

- 30. Matteucci
- 31. Exclusive clustering
- 32. Overlapping clustering
- 33. Hierarchical clustering
- 34. Probabilistic clustering
- 35. Leuski
- 36. Hierarchical agglomerative clustering algorithm
- 37. K-means clustering algorithms
 - 38. Lloyd's algorithm
 - 39. Filtering algorithm
- 40. K-D Tree
- 41. Simple iterative scheme
- 42. Kuhn
- 43. Semantic clustering
- 44. (Latent Semantic Indexing (LSI

می‌کند. این روش، برای انسان قابل درک بوده و بهمنظور فهم مفاهیم اصلی در نظام نرم‌افزاری تهیه می‌شود. روسل (۲۰۰۶)، مطرح می‌سازد که برای به کارگیری الگوریتم خوشبندی^{۴۵} دو عامل مورد نیاز است: ارائه یک عنصر و یا موضوع ویژه، و نیز معیار اندازه‌گیری شباهت یا اختلاف میان آن عنصر یا موضوع خاص. الگوریتم خوشبندی، بخش‌بندی یک مجموعه از عناصر ویژه، در ارتباط با برخی از معیارهای پایه در چنین شرایطی را تکمیل می‌کند. وکالی^{۴۶} (۲۰۰۷)، درباره منشأ و معیار کلی الگوریتم بیان می‌کند که الگوریتم‌های خوشبندی از حوزه‌های مختلف تخصصی چون آمار، شناسایی و تشخیص الگو، و نیز یادگیری ماشینی نشأت گرفته‌اند. هر طرح خوشبندی بهینه اصولاً باید دو معیار مهم را رعایت کرده باشد: نخست، فشرده‌سازی یعنی^{۴۷} داده‌های درون هر خوشبندی تا حد ممکن به یکدیگر نزدیک باشند. روش معمول سنجش انسجام، واریانس یا مجذور انحراف معیار است که باید در حداقل باشد. دوم، جداسازی^{۴۸} است، بهاین معنا که خوشبندی‌ها باید به‌طور قابل ملاحظه‌ای از هم جدا باشند. مفهوم فاصله خوشبندی معمولاً با تعیین اندازه‌تفکیک به کار می‌رود، که باید در مرز حداقل باشد.

برای خوشبندی فایل‌های داده‌های دیجیتالی، در ارتباط با داده‌های چندبعدی، الگوریتم‌های خاص خوشبندی وجود دارد که می‌توان با بهره‌گیری از آنها به تبیین وضعیت داده‌ها پرداخت. داده‌های چندبعدی، یکی از انواع داده‌های مبتنی بر بعد هستند که در فرایندهای مختلف رایانه‌ای کاربرد دارند. از جمله کاربری‌های آنها می‌توان به راهبردهای مصورسازی^{۴۹} اشاره کرد، که به نحوی با رویکردهای دیداری در نظامهای بازیابی اطلاعات ارتباط دارد. برای تعیین گروه‌بندی نوع خاص داده‌های ابعاد بالا^{۵۰}، می‌توان از الگوریتم خوشبندی داده^{۵۱} بهره گرفت. در مجموع، براساس انواع الگوریتم‌های پیشنهادی که توسط متخصصان این حوزه ارائه شده، می‌توان نتیجه گرفت که ساختار گوناگون الگوریتم‌های خوشبندی براساس نوع داده، ارتباط میان آنها، و ویژگی‌های خاص موجود با معیارهای تعیین شده به صورت کاربردی در فرایندهای خوشبندی به کار گرفته می‌شود. این الگوریتم‌ها فرایند کاری خوشبندی را فرمولیندی کرده، و با تدوین مشخص آن به یاری روش سازماندهی خوشبندی می‌شتابند. الگوریتم‌های خوشبندی با ارائه الگوهای پیشنهادی در مسیر بهینه‌سازی کارکرد خوشبندی حرکت می‌کنند.

مراحل خوشبندی

در فعالیت‌های حرفة‌ای کتابداری و اطلاع‌رسانی، برای نخستین بار خوشبندی در کاربرد خاص واژه‌هادر تزاروس یا اصطلاح‌نامه به کار گرفته شد. یکی از کاربردهای اولیه خوشبندی،

45. Clustering algorithm

46. Vakali

47. Compactness

48. Separation

49. Visualization

50. Data high-dimensional

51. Data clustering algorithm

رده‌بندی مدارک با موضوعات مشابه بوده است. در اصطلاح‌نامه‌های تخصصی برای ایجاد ارتباط منطقی میان مفاهیم مشترک و اصطلاح‌های مرتبط از راهبردهای خوشبندی به شیوه اثربخش استفاده شده است. در این میان، شناخت مراحل مختلف خوشبندی به ما کمک می‌کند تا بتوانیم به شیوه مناسبی از آن بهره‌گیری کنیم.

کوالسکی (۱۹۹۷، ص ۱۲۶-۱۲۷)، برای خوشبندی چهار مرحله ذکر می‌کند. مرحله نخست تعریف دامنه موضوعی خوشبندی است. در این مرحله، حدود کار که دارای یک دامنه کاربردی است، مشخص می‌شود. مانند فعالیتی که برای تهیه یک اصطلاح‌نامه پژوهشی یا علوم کتابداری و اطلاع‌رسانی بهانجام می‌رسد. مرحله دوم، تعیین خصوصیات و مشخصات واژه‌ها و مدارکی است که باید خوشبندی شوند. به تغییر دیگر، موضوع‌ها شامل چه بخش‌هایی هستند؛ نظیر تعیین خصوصیات مفرد و جمع اصطلاح‌ها. مرحله سوم، تعیین میزان رابطه بین واژگی‌های واژه بامدراک، با رده‌ای است که در آن قرار می‌گیرد؛ مانند تعیین این نکته که در فرهنگ مترادف‌ها چه کلماتی با یکدیگر هم‌معنا هستند و میزان ربط معنایی آنها به چه میزان است. مرحله نهایی نیز تهیه یک الگوریتم-راه حل فرمولی- برای تعیین رده‌های هر مقوله است و شامل مدارک و واژه‌هایی می‌گردد که به آن اختصاص داده می‌شود.

هریک از مراحل نامبرده در حیطه خاص خود به‌شکل کاربردی به مرحله اجرا درمی‌آید. تعریف دامنه موضوعی یکی از فرایندهای مهم کاری به‌شمار می‌آید. در این مرحله، ساختار اصلی رده‌ها و عناصر اطلاعاتی که باید درون دسته‌های معین قرار گیرند، مشخص می‌شود. حیطه کلی رده‌ها، ارتباط میان رده‌های ایجاد شده و سازه‌های مهمی که در ساخت آن نقش دارد، مورد بررسی و تحلیل قرار می‌گیرد. واژگی‌های مربوط به واژه‌ها که فرایند خوشبندی، با توجه به آن، به مرحله اجرا درمی‌آید، از موارد دیگر است. شناسایی و تحلیل واژه‌ها و روابط میان آنها در فعالیت خوشبندی نقشی مؤثر ایفا می‌کند. ارتباط میان واژه‌ها و اصطلاح‌ها از جنبه‌های متعدد مورد بحث واقع می‌شود. روابط اعم و اخص، کل و جزء، رابطه هم‌ارز، ارتباط معنایی، و تعیین مترادف‌ها و متضادها از مواردی است که باید به‌دققت بررسی شده و در ساختار رده‌های مربوط به فرایند خوشبندی لحاظ شود. یکی از موارد حساس و تعیین‌کننده، انتخاب الگوریتم خاص راهبرد خوشبندی است. الگوریتم‌های خوشبندی در واقع، مرحله اجرایی کردن فعالیت خوشبندی به‌شمار می‌آیند. ساختار الگوریتم، با توجه به شیوه کاری در ارتباط با گروه‌بندی کلی مفاهیم، تعیین دامنه موضوعی واژگان، مشخص ساختن رده‌ها، ایجاد ارتباط میان آنها، تحلیل اصطلاح‌های انتخاب شده، ساختار رسته‌بندی^{۵۲} گروه‌های مختلف اجزای داده‌ها، و در

مجموع روش اجرایی و کاربرد فرایندهای خوشه‌بندی اطلاعات طراحی می‌شود. در ادامه، به توضیح بیشتری درباره الگوریتم‌های خوشه‌بندی می‌پردازیم.

روابط خوشه‌بندی

آی تچیسون و گیل کریست^{۵۴} (۱۹۷۲)، سه نوع رابطه را مشخص کرده‌اند:

رابطه همارز^{۵۵} که متداول‌ترین رابطه بوده و مترادف‌های واژه را ارائه می‌دهد. در این نوع رابطه، واژه‌ای مورد نظر است که همپوشانی معناداری بین آنها وجود دارد، اما از لحاظ واژگانی متفاوت استند. مانند درد که دارای مترادف‌هایی چون الم، بیماری، تالم، رنج، سوز، کسالت، و مرض است؛ یا واژه‌های عکس و چاپ که گاهی می‌تواند مترادف هم تعریف شود (با توجه به اینکه کلمه چاپ شامل لیتوگرافی نیز می‌شود).

رابطه سلسله‌مراتبی^{۵۶} در این رابطه، یک واژه به عنوان رده اصلی انتخاب شده و مدخل‌ها، زیرمجموعه‌ها یا نمونه‌های خاصی از واژه کلی هستند. نظیر رایانه که به عنوان رده اصلی انتخاب، و ریزپردازنده‌ها، پتیوم، و مانند آن به عنوان زیرمجموعه در زیررده کلی قرار می‌گیرد.

رابطه غیرسلسله‌مراتبی^{۵۷} که انواع دیگر روابط بین واژه‌ها، غیر از دو مورد قبلی، از قبیل موضوع و ویژگی‌های مربوط را دربرمی‌گیرد، به عنوان مثال: کارمند ← عنوان شغل. در سال ۱۹۸۵، ونگ^{۵۸} و دیگران (۱۹۸۵)، طرح جدیدتری از ارتباط واژه‌ها را ارائه کردند که شامل پنج رابطه جزء-کل^{۵۹}، همنشینی-ترتیبی^{۶۰}، نمونه‌ای^{۶۱}، رده‌شناسی و مترادف‌ها^{۶۲}، و رده‌شناسی و متضادها^{۶۳} بود. در این میان، ارتباطات همنشینی و نمونه‌ای نیازمند توضیح بیشتری هستند. رابطه میان واژه‌ها به صورت همنشینی، ترتیبی یک مقیاس آماری است که از رابطه لغاتی که در کنار هم می‌آیند (در جمله، عبارت و یا پارگراف) تشکیل می‌شود. مانند سلام، حالت چطور است؟ و یا خسته‌ام، حالم خوب نیست. رابطه میان واژه‌ها به صورت نمونه‌ای عبارت است از واژه‌ای که معنای مشابهی دارند و در یک رده قرار می‌گیرند. نظیر فرمول و معادله. رابطه بین واژگان از نظر معنای واژه‌ها، روابط دیگری را نیز دربرمی‌گیرد. به طور نمونه، لغات متقابلی چون خُرد و جزء که بیان کنیم «کُره» جزء احجام هندسی است. یا کلان و کل، نظیر آنکه بگوییم «پی» که بخشی از ساختمان است. یا مثلاً لغت‌هایی که مفاهیم دیگری را برای ما تداعی می‌کند. مثل: عطر که با واژه‌های بوی خوش، رایحه، و شمیم ارتباطی نزدیک دارد.

برقراری ارتباط‌های متعدد میان واژه‌ها برای دستیابی به اطلاعات مرتبط از اهمیت بالایی برخوردار است. ایجاد رابطه در رده‌های تزاروس یا اصطلاح‌نامه، در کاربرد خاص

- 54. Aitchison & Gilchrist
- 55. Equivalence relationship
- 56. Hierarchical relationship
- 57. Non-hierarchical relationship
- 58. Wang
- 59. Parts-Wholes
- 60. Collocation
- 61. Paradigmatic
- 62. Taxonomy and synonymy
- 63. Taxonomy and antonymy

نظام‌های اطلاع‌رسانی، در واقع برای بالا بردن میزان بازیابی سودمند و مرتبط اطلاعات با نیازهای اطلاعاتی مطرح شده صورت می‌پذیرد. از این‌رو، کاربردی ساختن روابط واژه‌ها در واقع بهمنظور دستیابی به اطلاعات مؤثر است. ارتباط واژه‌ها از این‌حیث که سطوح متعدد برداشت کاربر از مقاهیم را فراهم می‌سازد قابل توجه است. فنون برقراری رابطه میان مجموعه‌عناصر و واژگان، بر مبنای نوع کاربردی که از آن انتظار می‌رود، متفاوت است، که در روش‌های خوشبندی بیان می‌شود.

روش‌های خوشبندی

برای انجام مؤثر فرایند خوشبندی داده‌ها، می‌توانیم از روش‌های مختلفی بهره‌گیریم. این روش‌ها، در واقع، برای انجام بهتر تنظیم رده‌های موضوعی در چارچوب گروه‌های همسان و مشترک به کار گرفته می‌شوند. یکی از این شیوه‌ها، روش ارتباط کامل بین واژه‌هاست. در این شیوه، شباهت موجود میان هر جفت واژه به عنوان مبنایی برای مشخص کردن رده‌ها محاسبه می‌شود. ساده‌ترین راه برای فهم این شیوه، در نظر گرفتن یک مدل بُرداری است. مدل بُرداری توسط یک ماتریس نشان داده می‌شود که در آن سطرها، موارد مستقل، و ستون‌ها، واژه‌های خاصی هستند. ارقام نیز نشانگر میزان تکرار واژه در هر مدرک هستند. در واقع، اعداد در هر ردیف، نشانگر میزان تکرار و اباستنگی لغت در هر مدرک هستند. شکل ۱ نمونه‌ای از یک بُردار را نشان می‌دهد. در این شکل میان واژه‌ها و عناصر تعیین شده رابطه مستقیم وجود دارد. با بهره‌گیری از فرمول تعیین شباهت می‌توان به ایجاد ماتریس‌های محاسباتی واژه به واژه و روابط واژه مبادرت ورزید.

	Term 1	Term 2	Term 3	Term 4	Term 5	Term 6	Term 7	Term 8
Item 1	0	4	0	0	0	2	1	3
Item 2	3	1	4	3	1	2	0	1
Item 3	3	0	0	0	3	0	3	0
Item 4	0	1	0	3	0	0	2	0
Item 5	2	2	2	3	1	4	0	2

شکل ۱

نمونه‌ای از یک بُردار
(کوالسکی، ۱۹۹۷، ص ۱۳۲)

برای درک بهتر این روش، از فرمول ساده زیر استفاده می‌کنیم:

$$\text{SIM}^{\text{ff}} (\text{Term}_i, \text{Term}_j) = \sum_{k,i} (\text{Term}_{k,i}) (\text{Term}_{k,j})$$

در این فرمول، SIM نشان‌دهنده میزان مشابهت عناصر در فرایند خوشه‌بندی است. j, i مقادیر کمی از واژه‌های موجود در یک گروه خوشه‌بندی شده از اطلاعات است. k نیز مجموعه تمامی مقوله‌های است. و نیز \sum جمع کل است.

در نتیجه، فرمول، دو سطون از واژه تحلیل شده را گرفته و پس از ضرب آنها مقادیر مجموع را در هر سطر به دست می‌آورد. نتایج را می‌توان در یک ماتریس $m \times m$ به نام ماتریس واژه-واژه قرار داد (شکل ۲) که m تعداد واژه‌ها در ماتریس اصلی است. ارزش‌های ارائه شده در این ماتریس نشانگر همبستگی هر واژه با خود آن واژه و واژه‌های دیگر است.

	Term 1	Term 2	Term 3	Term 4	Term 5	Term 6	Term 7	Term 8
Term 1		7	16	15	14	14	9	7
Term 2	7		8	12	3	18	6	17
Term 3	16	8		18	6	16	0	8
Term 4	15	12	18		6	18	6	9
Term 5	14	3	6	6		6	9	3
Term 6	14	18	16	18	6		2	16
Term 7	9	6	0	6	9	2		3
Term 8	7	17	8	9	3	16	3	

شکل ۲

ماتریس واژه به واژه
(کوالسکی، ۱۹۹۷، ص ۱۳۳)

64. SIM= Similarity

مرحله بعد، انتخاب آستانه‌ای برای تعیین درجه شباهت دو واژه، به منظور قرار دادن آنها در یک رده است. در این مثال، آستانه عدد ۱۰ درنظر گرفته شده است. بنابراین، در صورتی که مقدار تشابه بین آنها ۱۰ یا بیشتر باشد، دو واژه در کنار هم قرار می‌گیرند. با این اقدام، یک ماتریس دوتایی جدید به نام ماتریس روابطه واژه‌ها (شکل ۳) ایجاد می‌شود و واژه‌هایی را تعریف می‌کند که مشابه هم هستند. مرحله نهایی در ایجاد رده‌ها، مشخص کردن این معناست که در چه صورت دو واژه در خوشه‌ای یکسان قرار می‌گیرند. برای این کار روش‌های بسیار متفاوتی وجود دارد که موجب می‌شود خوشه‌بندی به شیوه‌های زیر به وجود آید. متداول‌ترین آنها عبارت اند از: خوشه‌بندی دسته‌ای^{۶۵}، خوشه‌بندی تک^{۶۶}، پیوندی (یک پیوندی)^{۶۷}، خوشه‌بندی ستاره‌ای^{۶۸}، و خوشه‌بندی رشته‌ای^{۶۹} (کوالسکی، ۱۹۹۷، ص ۱۳۲). در ادامه به توضیح هریک از انواع نامبرده خواهیم پرداخت.

	Term 1	Term 2	Term 3	Term 4	Term 5	Term 6	Term 7	Term 8
Term 1		0	1	1	1	1	0	0
Term 2	0		0	1	0	1	0	1
Term 3	1	0		1	0	1	0	0
Term 4	1	1	1		0	1	0	0
Term 5	1	0	0	0		0	0	0
Term 6	1	1	1	1	0		0	1
Term 7	0	0	0	0	0	0		0
Term 8	0	1	0	0	0	1	0	

شکل ۳

ماتریس روابطه واژه
(کوالسکی، ۱۹۹۷، ص ۱۳۳)

- 65. Cliques clustering
 - 66. Single link clustering
 - 67. Star clustering
 - 68. String clustering
- خوشه‌بندی دسته‌ای:** در این روش تمامی واژه‌هایی که مشابه تشخیص داده شده‌اند، با توجه به مقدار ورودشان، در یک رده قرار می‌گیرند. باید توجه کرد که واژه ۱ و ۶ در بیش از یک رده قرار گرفته‌اند. یکی از مهم‌ترین خصوصیات این شیوه آن است که واژه‌ها

را می‌توان در چندین رده یافت. با به کارگیری الگوریتم برای شکل ۳ رده‌های زیر ایجاد می‌شوند که در پنج رده می‌توان آنها را نمایش داد:

Class 1 (Term 1, Term 3, Term 4, Term 6)

Class 2 (Term 1, Term 5)

Class 3 (Term 2, Term 4, Term 6)

Class 4 (Term 2, Term 6, Term 8)

Class 5 (Term 7)

خوشه‌بندی تک‌پیوندی (یک‌پیوندی): در این شیوه، هر واژه‌ای که شبیه واژه دیگری باشد در یک رده قرار می‌گیرد و یک واژه نمی‌تواند در دو رده قرار داشته باشد. با توجه به الگوریتم به کار رفته برای تهیه خوشه‌ها با استفاده از شیوه تک‌پیوندی ماتریس رابطه واژه در شکل ۳ به ایجاد رده‌های زیر منجر می‌شود که در قالب دو رده اصلی قابل نمایش است:

Class 1 (Term 1, Term 3, Term 4, Term 5, Term 6, Term 2)

Class 2 (Term 7)

خوشه‌بندی ستاره‌ای: در این روش، یک واژه را انتخاب کرده و سپس تمام واژه‌های مربوط به آن واژه را در همان رده قرار می‌دهیم. واژه‌هایی که هنوز در رده‌ای قرار نگرفته‌اند، به عنوان هسته‌های جدیدی انتخاب می‌شوند تا اینکه تمام واژه‌ها به رده‌ای اختصاص یابند. در این شیوه، یک واژه می‌تواند در چندین رده قرار گیرد. رده‌های زیر حاصل خوشه‌بندی ستاره‌ای است که در سه رده اصلی ظاهر شده‌اند:

Class 1 (Term 1, Term 3, Term 4, Term 6)

Class 2 (Term 2, Term 4, Term 8)

Class 3 (Term 7)

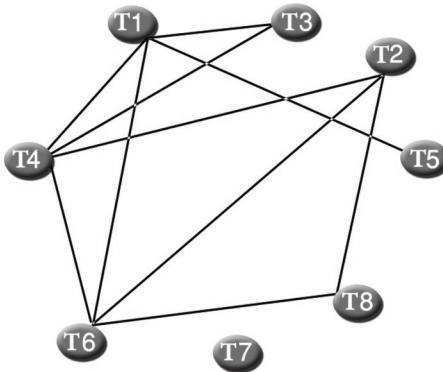
خوشه‌بندی رشته‌ای: در روش خوشه‌بندی رشته‌ای کار با یک واژه شروع می‌شود و واژه‌های مشابه، به صورت رشته‌ای به آن متصل می‌شوند. این فرایند ادامه می‌یابد تا اینکه هیچ واژه دیگری در این رده قرار نگیرد. در این روش، واژه‌های جدید به عنوان یک گروه جدید استفاده شده، و بر این اساس فرایند ادامه می‌یابد. با تکیه بر این رویکرد، سه رده اصلی ایجاد شده که به صورت زیر به نمایش در می‌آید:

Class 1 (Term 1, Term 3, Term 4, Term 2, Term 8, Term 6)

Class 2 (Term 5)

Class 3 (Term 7)

براین اساس، میان اصطلاح‌های تعریف شده ارتباطی چندوجهی ایجاد می‌شود که می‌توان این روابط را به صورت یک نمودار شبکه‌ای با ترسیم خطوط ارتباطی به شکل زیر نشان داد:



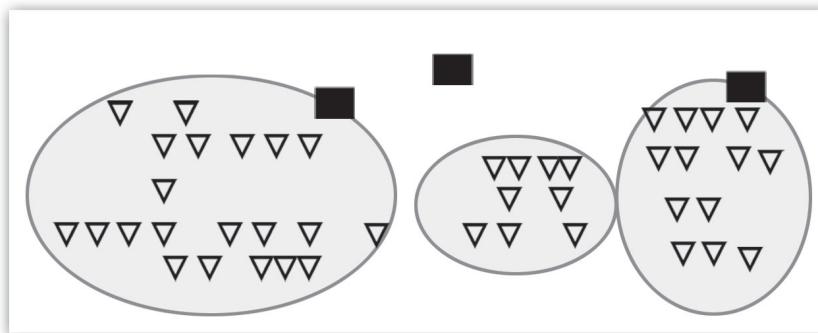
شکل ۴

نمودار شبکه‌ای
مشابهت‌های اصطلاح
(کوالسکی، ۱۹۹۷، ص ۱۳۵)

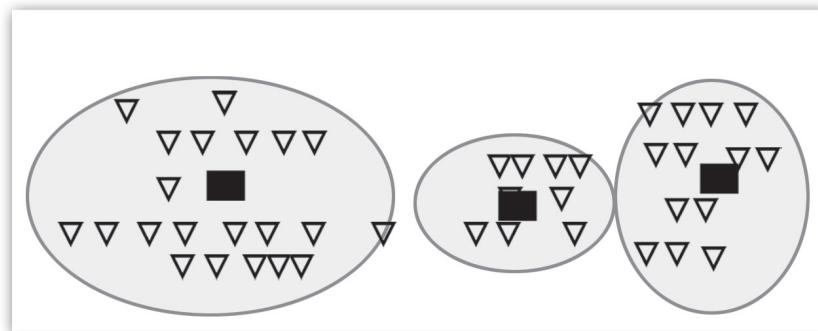
به عنوان نتیجه‌گیری از مبحث روش‌های خوشه‌بندی، در صورتی که بخواهیم یک مقایسه میان دو نوع از انواع مهم و پراستفاده خوشه‌بندی، یعنی خوشه‌بندی دسته‌ای و خوشه‌بندی تک‌پیوندی انجام دهیم باید به نکات زیر اشاره کنیم: خوشه‌بندی دسته‌ای، رده‌هایی را ایجاد می‌کند که قوی‌ترین روابط بین تمام واژه‌های آن وجود دارد؛ این رده احتمالاً مفهوم خاصی را تشریح می‌کند؛ بیشترین رده‌ها را نسبت به سایر الگوریتم‌ها ایجاد می‌کند؛ تعداد واژه‌های یک رده را کاهش می‌دهد؛ در این الگوریتم مانعیت بیشتری وجود داشته و جامعیت آن کاهش می‌باید (کوالسکی، ۱۹۹۷، ص ۱۳۶-۱۳۳). ولی ویژگی‌های خوشه‌بندی تک‌پیوندی را می‌توان به شرح ذیل برشمود؛ واژه‌ها را بین رده‌ها تقسیم‌بندی می‌کند (جزء‌بندی)؛ این روش کمترین تعداد رده را ایجاد می‌کند؛ ناپایدارترین ارتباط بین لغات را در نظر می‌گیرد؛ این احتمال نیز وجود دارد که دو واژه‌ای که مشابهت آنها نزدیک به صفر است در یک رده قرار گیرد (سالتون، ۱۹۷۲)؛ رده‌ها به جای رساندن یک مفهوم، تنوعی از مفاهیم را دربرمی‌گیرند؛ جامعیت را به حداقل می‌رساند ولی مانعیت را کاهش می‌دهد.

خوشه‌بندی با استفاده از خوشه‌های موجود^{۶۹}

یک روش دیگر برای ایجاد خوشه‌ها، استفاده از مجموعه خوشه‌های موجود در شروع کار است. این شیوه، تعداد محاسبات مورد نیاز برای تعیین مشابهت‌ها در تهیه خوشه‌ها را کاهش می‌دهد. روش نامبرده دارای ویژگی‌هایی به این قرار است: برای به حداقل رساندن محاسبات، مراکز ثقل برای هر خوشه تعیین می‌شود. در فیزیک به مرکز جرم یک مجموعه از اجسام، مرکز ثقل گفته می‌شود. در زمینه بُردارها، این مفهوم برابر میانگین تمام بُردارها در یک خوشه است؛ اولین تخصیص واژه به خوشه‌ها، مراکز ثقلی را ایجاد می‌کند که ارتباطی به خوشه‌بندی نهایی ندارد؛ تشابه بین کل واژه‌های موجود و مراکز ثقل خوشه‌ها قابل محاسبه است؛ واژه به خوشه‌هایی راه می‌یابد که بیشترین تشابه را داشته باشد؛ این روند آنقدر تکرار می‌شود تا اینکه به یک وضعیت پایدار برسد (کوالسکی، ۱۹۹۷، ص ۱۳۷). نمایش نموادارهای واژه‌ها و مراکز ثقل اولیه نشان می‌دهد که چگونه رده پس از تعیین مکان اولیه جایه‌جا می‌شود. در واقع، خوشه‌ها، سازماندهی و ترکیب نهایی رده‌های اصلی را درون ساختار منظم گروه‌بندی بر عهده دارند.



شکل ۵
مراکز ثقل اولیه برای خوشه‌ها
(کوالسکی، ۱۹۹۷، ص ۱۳۷)



شکل ۶
مراکز ثقل پس از
تخصیص مجدد واژه‌ها
(کوالسکی، ۱۹۹۷، ص ۱۳۷)

69. Clustering using existing clusters

مربع توپر سیاه نشانگر مراکز ثقل رده‌های است که در این روش با تخصیص مجدد واژه‌ها به ایجاد یک وضعیت متعادل منجر شده است. می‌توان به عنوان نتیجه رده‌های سه‌گانه زیر را مشخص ساخت:

Class 1= (Term 1 and Term 2)

Class 2= (Term 3 and Term 4)

Class 3= (Term 5 and Term 6)

به این ترتیب مراکز ثقل زیر برای هر رده به شرح زیر مشخص می‌شود:

Class 1= $(0+4)/2, (3+1)/2, (3+0)/2, (0+1)/2, (2+2)/2$

$$= 4/2, 4/2, 3/2, 1/2, 4/2$$

Class 2= $0/2, 7/2, 0/2, 3/2, 5/2$

Class 3= $2/2, 3/2, 3/2, 0/2, 5/2$

علاوه بر آن، جدول مخصوص انتقال رده تکرار شونده در قالب زیر قابل ارائه است.

در این جدول، موقعیت هر واژه در ارتباط با هر یک از رده‌ها مشخص شده و محاسبه

مربوط به آن در جدول درج می‌شود:

	Term 1	Term 2	Term 3	Term 4	Term 5	Term 6	Term 7	Term 8
Class 1	29/2	29/2	24/2	27/2	17/2	32/2	15/2	24/2
Class 2	31/2	20/2	38/2	45/2	12/2	34/2	6/2	17/2
Class 3	28/2	21/2	22/2	24/2	17/2	30/2	11/2	19/2
Assign	Class2	Class1	Class2	Class2	Class3	Class2	Class1	Class1

شكل ۷

انتقالات رده تکرار شونده
(کوالسکی، ۱۹۹۷، ص ۱۳۸)

اگرچه این شیوه نیاز به محاسبات کمتری نسبت به روش رابطه کامل واژه دارد، دارای برخی محدودیت‌های ذاتی نیز می‌باشد. یکی از مشکلات این روش، آن است که ابتدا تعداد رده‌ها تعریف می‌شود و نمی‌توان آنها را توسعه داد. این امکان وجود دارد که در انتهای فرایند، تعداد رده‌ها کمتر شود. تمام واژه‌ها باید به یک رده اختصاص یابند. بنابراین،

حتی اگر مشابهت آنها نسبت به سایر واژه‌های قرار گرفته بسیار ضعیف باشد، واژه‌ها را مجبور به قرارگرفتن در یک رده می‌کند. وضعیت جدید گروه‌بندی منظم و متعادل برای تخصیص واژه‌ها در قالب رده‌های تعیین شده، به شکل جدول زیر قابل نمایش است.

	Term 1	Term 2	Term 3	Term 4	Term 5	Term 6	Term 7	Term 8
Class 1	23/3	45/3	16/3	27/3	15/3	36/3	23/3	34/3
Class 2	67/4	45/4	70/4	78/4	33/4	72/4	17/4	40/4
Class 3	12/1	3/1	6/1	6/1	11/1	6/1	9/1	3/1
Assign								
	Class2	Class1	Class2	Class2	Class3	Class2	Class3	Class1

۸ شکل

انتقال رده‌ها و مراکز ثقل جدید
(کوالسکی، ۱۹۹۷، ص ۱۳۹)

کاربرد خوشبندی اطلاعات در ساختار اصطلاحنامه

در فرایند خوشبندی رده‌های موضوعی در ساختار اصطلاحنامه تعیین وضعیت رده‌ها از اهمیت زیادی برخوردار است. بر این اساس باید هر رده کاملاً تعریف شده و از معنای مناسبی برخوردار باشد، زیرا گاهی اوقات واژه انتخاب شده باعث سوء‌تعییر می‌شود. بنابراین، بهتر است از اعداد برای شناسایی رده‌ها استفاده کرد؛ اندازه رده‌ها باید از نظر بزرگی تقریباً یکسان باشد. یکی از مصارف ابتدایی رده‌ها، بسط دادن جستجوها یا نتیجه موارد بازیابی شده است. داخل هر رده، مدارک و واژه‌ها نباید بر ردۀ اصلی برتری داشته باشد. برای مثال، کامپیوتر یا ریزپردازنده و نظایر آن، یک واژه یا مدرک می‌تواند به چند رده تعلق داشته باشد و یا به عنوان موضوعی اصلی انتخاب شود. این فرایند با تأکید بر دو رویکرد به انجام می‌رسد: نخست آنکه به صورت اخسن باشد، یعنی واژه‌ای که بر موضوعی خاص دلالت دارد و مفهوم آن به مراتب محدودتر از واژه‌ای است که معنای عام و وسیعی را پوشش می‌دهد. مانند کبوتر یا پرنده‌گان؛ دوم آنکه موضوع، از نظر معنایی، قابلیت قرار گرفتن در رده‌های مختلف را داشته باشد. به‌تعییر دیگر، واژه کلی، برای نشان دادن رابطه معنایی بین توصیفگرهای زبان در اصطلاحنامه غنی باشد (کوالسکی، ۱۹۹۷، ص ۱۲۷).

در خوشبندی اطلاعات اصطلاحنامه، اینکه یک موضوع در چندین رده قرار بگیرد یا

تنها در یک رده، بستگی به تصمیمی دارد که در آغاز گرفته می‌شود. با توجه به اینکه زبان معمولاً ایهام دارد، بهتر است که موضوع در چندین رده قرار گیرد. این عمل انعطاف‌پذیری بیشتری را در پی خواهد داشت. در ایجاد یک اصطلاح‌نامه مسائل مهم دیگری نیز وجود دارد که جزء خوشه‌بندی مدارک بیان نمی‌شود (آی تچیسون و گیل کریست، ۱۹۷۲) از قبیل: رویکرد همارایی واژه^{۷۰}، رابطه میان واژه‌ها^{۷۱}، تفکیک لغات با املای یکسان^{۷۲}، و محدودیت‌های واژگان^{۷۳}. در روش همارایی واژه، عبارات در قالب اصطلاح‌های خاص و جداگانه رده‌بندی شده که به صورت روش‌های پس‌همارایی و پیش‌همارایی ظاهر می‌شود. در مقوله رابطه میان واژه‌ها در تهیه یک اصطلاح‌نامه که در آن انسان نیز می‌تواند دخالت داشته باشد - در مقابل اصطلاح‌نامه خودکار - ایجاد رابطه‌های متنوعی بین واژه‌ها امکان‌پذیر است. در باره تفکیک لغات با املای یکسان (هم‌نوشت) باید بیان کرد که منظور، مرزبندی و مشخص ساختن واژه‌ای است که املای یکسان با معانی کاملاً مختلف دارد. مثلاً: شیر که می‌تواند شامل شیر خوارکی، شیر آب، یا شیر جنگل باشد. برای تدوین راه حل این مشکل پیشنهاد شده که وقتی می‌خواهیم از این کلمات استفاده کنیم باید همزمان با آن کلمه دیگری آورده شود که نتیجه صحیح جستجو را ارائه دهد. ولی در موضوع محدودیت‌های واژگان با دو مقوله عادی‌سازی و اخلاص شدن مواجه هستیم (آی تچیسون و گیل کریست، ۱۹۷۲).

خوشه‌بندی مدارک

فرآیند خوشه‌بندی مدارک بسیار شبیه خوشه‌بندی واژه‌ها برای ایجاد یک اصطلاح‌نامه است که به دو صورت دستی و خودکار انجام می‌شود. در روش خوشه‌بندی دستی مدارک جزء ذاتی هر کتابخانه یا نظام بایگانی است. در این شیوه، فردی مدرک را مطالعه می‌کند و سپس تصمیم می‌گیرد که مدرک به چه گروه یا گروه‌هایی تعلق دارد. در سیستم دستی معمولاً هر مدرک به یک گروه تعلق می‌گیرد. با به کارگیری نمایه‌سازی، یک مدرک در یک گروه اولیه ذخیره شده و می‌تواند در گروه‌های دیگر به صورت نمایه‌ای تعریف شود. با ظهور نظام‌های الکترونیکی، نگهداری مدارک خوشه‌بندی به شیوه خودکار امکان‌پذیر شده است. روش‌هایی که برای خوشه‌بندی واژه‌ها بیان شد، برای خوشه‌بندی مدارک نیز به کار می‌رود. تشابه بین مدارک براساس دو معیار تعیین می‌شود: نخست واژه‌های مشترک، سپس رابطه‌های مشترک. فرمول آن نیز چنین است:

$$SIM (Item_i, Item_j) = \sum_k (Item_i, k)(Term_j, k)$$

بر همین اساس، ماتریسی ایجاد می‌شود که ستون‌ها و ردیف‌هایش مبین مدارک است:

70. Word coordination approach

71. Words relationship

72. Homograph resolution

73. Vocabulary constraints

	Item 1	Item 2	Item 3	Item 4	Item 5
Item 1		11	3	6	22
Item 2	11		12	10	36
Item 3	3	12		6	9
Item 4	6	10	6		11
Item 5	22	36	9	11	

شکل ۹

ماتریس مدرک به مدرک
(واژه‌های مشترک)
(کوالسکی، ۱۹۹۷، ص ۱۴۱)

	Item 1	Item 2	Item 3	Item 4	Item 5
Item 1		1	0	0	1
Item 2	1		1	1	1
Item 3	0	1		0	0
Item 4	0	1	0		1
Item 5	1	1	0	1	

شکل ۱۰

رابطه‌های مشترک
(کوالسکی، ۱۹۹۷، ص ۱۴۱)

در این شیوه، با استفاده از الگوریتم خوشبندی دسته‌ای، رده‌های زیر به دست می‌آید:

Class 1= Item 1, Item 2, Item 5

Class 2= Item 2, Item 3

Class 3= Item 2, Item 4

در صورتی که از الگوریتم خوشبندی تک‌پیوندی استفاده کنیم، رده زیر حاصل می‌شود. در این روش، کلیه مدارک در یک رده قرار گرفته‌اند (مدارک ۳ و ۴ به علت تشابه آنها با مدرک ۲ به این رده اضافه شده‌اند):

Class 1= Item 1, Item 2, Item 5, Item 3, Item 4

چنانچه قصد بهره‌گیری از الگوریتم خوشبندی ستاره‌ای داشته باشیم، رده‌های زیر

به عنوان نتیجه فرایند خوشبندی مدارک ظاهر می‌شود:

Class 1 - Item 1, Item 2, Item 5

Class 2 - Item 2, Item 3, Item 4, Item 5

و، در نهایت، با استفاده از الگوریتم خوشبندی رشته‌ای رده‌های زیر حاصل می‌شود:

Class 1- Item 1, Item 2, Item 3

Class 2- Item 4, Item 5

باید بر مطالب پیشین افزود که در محدوده واژه‌ها، آن بخش که دارای املاه‌های مشابه هستند، سبب بروز ایهام و نیز خطأ می‌شود. در محدوده مدارک نیز، عنوان‌های چندگانه برای یک مدرک می‌تواند باعث مشکلات مشابهی شود. این مشکل به صورت خاص، هنگام مرزبندی میان مدارک، بیشتر مشخص می‌شود. بدون پیش‌همارابی معنای مفاهیم، مدرکی که در مورد «سیاست» در «آمریکا» و «اقتصاد» در «مکزیک» است می‌تواند در یک رده خوشبندی شوند که بر روی سیاست در مکزیک تمرکز دارد.

ایجاد سلسله‌مراتب در فرایند خوشبندی

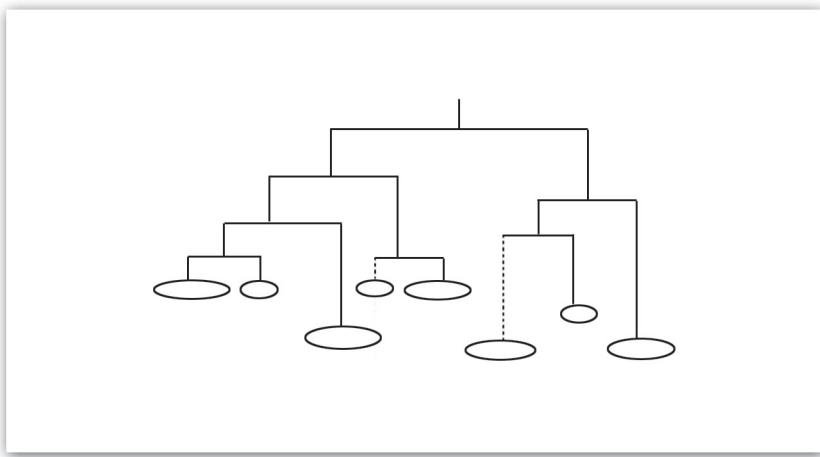
مجموعه‌ای از رده‌ها، که برای نمایش رابطه‌های نوعی فراتر، فروتر، و هم‌سطح بین رده‌های موازی و همتراز منظم شده‌اند، به عنوان سلسله‌مراتب خوشبندی^{۱۷} شناخته می‌شوند. در این سلسله‌مراتب، تقدم و تأخیر موضوع‌هاد طرح رده‌بندی به‌نحوی است که هریک از عناصر مذکور در توالی موضوعی، وابسته به عنصر منحصر به‌فرد ماقبل خود باشد. یعنی درست همانگونه که در خدمت دانش سنتی مرسوم بوده است.

بر این اساس، کاهش سریز اطلاعات از طریق اجرای جست‌وجوهای بالا به پایین، تعیین مراکز ثقل خوشبندی در سلسله‌مراتب، و حذف شاخه‌های زائدی که مرتبط نیستند، انجام می‌شود. باید بیان کرد که نمایش تصویری از فضای اطلاعاتی مدارک کار بسیار دشواری است. استفاده از نمودار درختی همراه با نشانه‌های تصویری، تعیین اندازه خوشبندی، و توانایی ایجاد ارتباط بین آنها، بهترین روش برای ایجاد سلسله‌مراتب است. این روش سودمند به توسعه بازیابی مدارک مرتبط منجر می‌شود که دارای اثربخشی زیادی در فرایند بازیابی اطلاعات است.

استفاده از نمودار درختی فواید خاص خود را دارد. ویژگی‌های مهم این شیوه شامل سه مورد زیر می‌شود: ۱) این مدل به استفاده‌کننده اجازه می‌دهد مسیر جست‌وجوه در پایگاه اطلاعاتی را به آسانی بازیابی کند؛ ۲) استفاده‌کننده، تمامی مدارک یا واژه‌های مورد نظر در خوشبندی را ملاحظه می‌کند؛ ۳) استفاده‌کننده می‌تواند اخص بودن مدرک یا

74 . Hierarchy of cluster

واژه‌ها را از طریق رفتن به خوشه‌های پایین‌تر افزایش دهد، و یا با رفتن به خوشه‌های بالایی جست‌وجو را به شیوهٔ عمومی‌تری دنبال کند. ساختار سلسله‌مراتبی، در واقع، یکی از روش‌های مناسب برای نمایش روابط میان رده‌های تعیین‌شده است. معمولاً در ساختار برنامه‌های رایانه‌ای نیز در بازنمایی اطلاعات مرتبط از روش سلسله‌مراتبی بهره می‌گیرند.



شکل ۱۱

مودار روابط سلسله‌مراتبی
(کوالاسکی، ۱۹۹۷، ص ۱۴۳)

خوشه‌بندی در محیط وب؛ رویکردی نوین

منابع وب، با توجه به پارامترهای خاص خود، و نیز ویژگی‌هایی از قبیل معروف بودن، ساختار متمايز و یا محتوای آن دسته‌بندی می‌شوند. خوشه‌بندی در وب می‌تواند یکی از انواع زیر باشد:

خوشه‌بندی کاربر وب^{۷۵}: یعنی ایجاد گروه‌هایی از کاربران که الگوهای مرور^{۷۶} مشابهی را نجام می‌دهند. چنین مهارتی خصوصاً برای اشاره به آمار کاربران به منظور انجام فعالیت‌های متنوعی از قبیل تقسیم‌بندی بازار در کاربردهای تجارت الکترونیک مفید است. بهمین ترتیب، این نوع خوشه‌بندی، به فهم بهتر رفتار هدایتی کاربران کمک کرده و در خواست خدمت کاربران وب را از طریق کاهش طول مسیرهای خط سیر هدایت وب بهبود می‌بخشد.

خوشه‌بندی اسناد وب^{۷۷}: که عبارت است از گروه‌بندی اسناد با محتوای مرتبط. این اطلاعات در بسیاری از کاربردها مفید و سودمند است. برای مثال، کاربرد آن در موتورهای جست‌وجوی وب، به منظور بهبود فرایند بازیابی اطلاعات (نظیر خوشه‌بندی پرس‌وجوهای وب) است. علاوه بر آن، خوشه‌بندی اسناد وب موجب افزایش دسترسی به اطلاعات وب شده و ارسال محتوا را بهبود می‌بخشد (واکالی، ۲۰۰۷). تقسیم‌بندی خوشه‌بندی در وب به دو گروه کاربران و اسناد، یکی از طبقه‌بندی‌هایی است که در پژوهش‌های مربوط به حوزهٔ

75. Web user clustering
76. Browsing patterns
77. Web document clustering

خوشه‌بندی وب کاربرد دارد. باید بیان کرد که فرایند خوشه‌بندی در وب، براساس داده‌های ارائه شده، مبتنی بر خوشه‌بندی اسناد وب است. در این میان، بیشترین توجه بر ساختار مدارک و اطلاعات موجود در وب بوده است. ولی اگر خوشه‌بندی اسناد و اطلاعات را به عنوان پایه اصلی این فرایند در مطالعات وب‌مدار در نظر بگیریم، با دو رویکرد عمدۀ در خوشه‌بندی منابع وب روبه‌رو خواهیم بود.

می‌توان روش‌های خوشه‌بندی را به دو رویکرد خوشه‌بندی مبتنی بر متن^{۷۸} و خوشه‌بندی مبتنی بر پیوند^{۷۹} تقسیم کرد. رویکرد خوشه‌بندی مبتنی بر متن از محتوى متن اسناد برای برآوردن شباهت میان اسناد استفاده می‌کند. خوشه‌بندی مبتنی بر متن اسناد وب، معمولاً توسط مدل‌های فضای بُرداری^{۸۰} در فضای بُرداری بعد بالا^{۸۱} نمایش داده می‌شود، که در آن عبارات با مؤلفه‌های بُردار، همبستگی دارند. هنگامی که اسناد وب، بُرداری شدند، روش‌های خوشه‌بندی بُرداری، خوشه‌های اسناد وب را فراهم می‌سازد. ولی در روش خوشه‌بندی مبتنی بر پیوند، وب به صورت یک نمودار مستقیم تلقی می‌شود که در آن گروه‌ها، نمایشگر اسناد وب، همراه با آدرس و نشانی مکان یا ب پیشان متابع^{۸۲} هستند و لبه‌های میان گروه‌ها، نمایشگر فرایوندهای بین اسناد وب می‌باشند. فنون مبتنی بر پیوند از وضعیت مکان‌شناسی^{۸۳} وب‌سایت برای خوشه‌بندی اسناد وب استفاده می‌کنند (واکالی، ۲۰۰۷). در شیوه خوشه‌بندی مبتنی بر پیوند، تعیین ویژگی‌های خاص پیوندهای برقرار شده از اهمیت بالایی برخوردار است. نشانی اینترنتی نقشی مؤثر ایفا می‌کند و بر اساس آن می‌توان بهتر و بیشتر از امکان خوشه‌بندی بهره جست. خوشه‌بندی در محیط وب، بیشتر با اطلاعات دیجیتالی در فضای مجازی ارتباط می‌یابد، و بُردارها نقشی بسزا در تثبیت خوشه‌ها بر عهده دارند.

نتیجه‌گیری

خوشه‌بندی داده‌ها یکی از راهکارهای سودمندی است که می‌توان با کمک آن به ایجاد توازن در گروه‌بندی اطلاعات اقدام کرد. خوشه‌بندی داده، گروهی از داده‌های همسان را که از ویژگی‌های مشابه برخوردار هستند، در یک رده، با عنوان واحد، سازماندهی می‌کند. بر این اساس، خوشه‌بندی، مرتب‌کردن واژه‌ها یا مدارک شبیه بهم در یک رده، زیر یک عنوان کلی است. خوشه‌بندی یک مرحله مهم از فرایند پردازش تحلیل داده است که هدف آن تقسیم‌بندی منطقی یک مجموعه ساختاریافته از اجزاء، درون خوشه‌ها یا گروه‌های مشخص است.

در واقع، هدف اصلی فرایند خوشه‌بندی، کمک به استفاده کنندگان برای تعیین محل دقیق اطلاعات است.

این فعالیت با شناسایی گروه‌بندی طبیعی داده‌ها شکل می‌گیرد. از کارکردهای مهم خوشه‌بندی داده می‌توان به ساخت و ایجاد تزاروس و اصطلاحنامه اشاره کرد. در

78. Text-Based clustering approach

79. Link-Based clustering approach

80. Vector space model

81. High-dimension vector space

82. Uniform Resource Locator (URL)

83. Topology

مراحل کاری خوشه‌بندی داده، تعیین حد و حدود کار اولین مرحله آن است. سپس، تعیین خصوصیات و مشخصات واژه‌ها و مدارک مطرح می‌شود. از مراحل دیگر، باید به تعیین میزان رابطه بین واژگی‌های واژه اشاره کرد. آخرین مرحله نیز ایجاد الگوریتم است. انواع الگوریتم‌های خوشه‌بندی، با توجه به نوع اطلاعات و ساختار و روابط مورد نظر مورد استفاده قرار می‌گیرد. روش‌های عمده خوشه‌بندی نیز چهار شیوه خوشه‌بندی دسته‌ای، تک‌پیوندی، ستاره‌ای، و رشته‌ای است. روش دیگری که باید علاوه بر روش‌های پیشین نام برد، روش خوشه‌بندی با استفاده از خوشه‌های موجود است. این شیوه تعداد محاسبات مورد نیاز برای تعیین مشابهت‌ها در تهیه خوشه‌ها را کاهش می‌دهد. خوشه‌بندی مدارک نیز شبیه خوشه‌بندی واژه‌ها برای ساخت اصطلاحنامه به کار می‌رود، که به دو صورت دستی و خودکار انجام می‌شود. خوشه‌بندی وب‌مدار یکی از انواع جدید خوشه‌بندی است که با فضای بُرداری و متون و پیوندهای موجود در محیط وب ارتباط دارد. تمامی فرایندهای خوشه‌بندی، در نهایت تضمین‌کننده دستیابی سریع و مطمئن به اطلاعات همبسته، و شناسایی ارتباط منطقی میان آنهاست.

منابع

- Aitchison, J.; Gilchrist, A. (1972). *Thesaurus construction: A practical manual*, London: ASLIB.
- Anthony, Adam; desJardins, Marie(2006). "Open Problems in relational data clustering". ICML Workshop on Open Problems in Statistical Relational Learning, Pittsburgh, PA. Retrieved Nov.30, 2007, from: <http://maple.cs.umbc.edu/papers/aanthMDJRelClustFinal.pdf>
- Anthony, Adam; DesJardins, Marie(2007). "Data clustering with a relational push- pull model". Retrieved Nov.30, 2007, from: <http://maple.cs.umbc.edu/papers/anthonya-ClusteringRPPM.pdf>
- Breaux, Travis D.; Reed, Joel W. (2005). "Hierarchical information clustering Using Ontology Languages". 38th Hawaii Int'l Conf. on System Sciences(January). Retrieved Nov.30, 2007, from: <http://www.csm.ornl.gov/~reed/publications/HierarchicalInfoClustering.pdf>
- Gionis, Aristides; Mannila, Heikki; Tsaparas, Panayiotis (2004). "Clustering aggregation". Helsinki Institute for Information Technology, BRU, Department of Computer Science, University of Helsinki, Finland. Retrieved feb.13, 2007, from: www.cs.helsinki.fi/u/gionis/papers/icde05.pdf
- Jain, A. K.; Law, Martin H.C. (2005). "Data clustering: A user's dilemma". 1st International Conference, PReMI, Kolkata, India, December 20 - 22. Retrieved Nov. 30, 2007, from: http://www.cse.msu.edu/~lawhiu/papers/JainLaw_PReMI.pdf
- Jain, A.K.; Murty, M.N; Flynn, PJ (1999). "Data clustering: A review". *ACM Computing Sur-*

- vey, 31 (3): 265 - 323. Retrieved Feb.19, 2007, from: <http://www.cs.rutgers.edu/~mlittman/courses/lightai03/jain99data.pdf>
- Kanungo, Tapas ... [et al] (2002). "An efficient k-means clustering algorithm: Analysis and implementation". IEEE Transaction on Pattern Analysis and Machine Intelligence, 24 (7): 881 - 892.
- Kowalski, Gerald (1997.) *Information retrieval systems: Theory and implementation*. Boston: Kluwer Academic Publishers.
- Kraskov, A. ... [et al] (2005). "Hierarchical clustering using mutual information". *Europhysics Letters*, 70 (2) 278 – 284.
- Kuhn, Adrian Ivo (2006). "Semantic clustering making use of linguistic information to reveal concepts in source code". Institut f"ur Informatik und angewandte Mathematik. Retrieved Feb.19, 2007, from: www.iam.unibe.ch/~scg/Archive/Diploma/Kuhn06a.pdf
- Leuski, Anton (2002). "Evaluating document clustering for interactive information retrieval". Retrieved Feb.19, 2007, from: wkd.iis.sinica.edu.tw/~slchuang/lecture/2002-01-17/ir-235.pdf
- Matteucci, Matteo (2003). "A tutorial on clustering algorithms". Retrieved Mar.4, 2007. from: http://www.elet.polimi.it/upload/matteucc/ Clustering/tutorial_html
- Neville, Jennifer; Adler, Micah; Jensen, David (2003). "Clustering relational data using attribute and link information". Retrieved Feb.19, 2007, from: <http://kdl.cs.umass.edu//papers/neville-et-al-textlink2003.pdf>
- Perlich, Claudia; Rosset, Saharon (2007). "Identifying bundles of product options using mutual information clustering". Retrieved Nov.30, 2007, from: <http://www.siam.org/meetings/proceedings/2007/ datamining/ papers/035perlich.pdf>
- Rosell, Magnus (2006). "Introduction to information retrieval and text clustering". Retrieved Feb.19, 2007, from: www.nada.kth.se/~rosell/undervisning/sprakt/irintro060801.pdf
- Salton, G. (1972). "Experiments in automatic thesaurus construction for information retrieval". Information processing, 71th, North Holland Publishing Co, Amsterdam, p. 115 - 123.
- Song, Qing (2005). "A robust information clustering algorithm". *Neural computation*, 17 (12): 267 – 298. Retrieved Nov.30, 2007, from: <http://www.galenicom.com/pt/medline/article/16212767>
- Vakali, Athena; Pallis, George; Angelis, Lefteris (2007). "Clustering web information sources". Idea Group Inc. Retrieved Feb.13, 2007, from: oswinds.csd.auth.gr/papers/idea06.pdf
- Wang, Y-C; Vandenthorpe, J; Evans, M.(1985). "Relationship thesauri in information retrieval". *American Society of Information Science*, 15 - 27.