

استخراج دانش از پایگاه داده نرم افزارهای مدیریت اطلاعات و مستندات با تکنیک های داده کاوی

مهدی فشار کی | دانشیار

دانشگاه صنعتی مالک اشتر

حسین شیرازی | دانشیار

دانشگاه صنعتی مالک اشتر

اکوم بخشی * | کارشناس،

دانشگاه صنعتی مالک اشتر تهران

دریافت: ۱۳۸۸/۱۰/۲۸ | پذیرش: ۱۳۸۸/۱۲/۲۵

فصلنامه علمی پژوهشی
پژوهشگاه علم و فناوری اطلاعات ایران
شایپا(چاپ) ۱۷۳۵-۵۲۰۶
۲۰۰۸-۵۵۸۳
نمایه در ISC و SCOPUS .LISA
<http://jist.irandoc.ac.ir>
دوره ۲۶ | شماره ۲ | ص ص ۲۵۹ - ۲۸۳
زمستان ۱۳۸۹

چکیده: چشم بزرگ داده‌ها به تنها بر می‌گیرد. باعث سردرگمی مدیران سازمان‌ها در تصمیم‌سازی و تصمیم‌گیری هیچ کمکی نمی‌کند، بلکه باعث سردرگمی مدیران سازمان‌ها نیز می‌شود. بنابراین مدیریت داده‌های خام و تبدیل داده‌های خارجی و داخلی سازمان به اطلاعات و دانش با استفاده از تکنیک‌های گوناگون، نقش اساسی و محوری دارد. از تکنیک‌های معروف در این زمینه داده کاوی است، که می‌تواند بر روی بانک اطلاعاتی انجام شود و دانش مورد نیاز را بدست آورد. «دی اسپیس» سیستمی نرم افزاری، آرشیو دیجیتالی یا مخزن اطلاعات سازمانی «وب»، فضایی برای ذخیره سازی، بازیافت و مدیریت اطلاعات سازمان‌ها و مؤسسات ایجاد می‌کند. هدف از ارائه این مقاله استخراج دانش از سوابق و تاریخچه جستجوهای کاربران در پایگاه داده‌ای اسپیس با استفاده از الگوریتم‌های داده کاوی است، تا با بدست آوردن ارتباطات و واپسنگی‌های میان عبارت‌های جستجو شده بتوان امکان جستجوی هوشمند را در «دی اسپیس» اضافه کرد. این کار علاوه بر افزایش سرعت و کارایی جستجوی کاربر، توانایی «دی اسپیس» را هم افزایش می‌دهد. با این ایندی هم اینکه از جستجوهای بسیار کاربر برای مفهومی جلوگیری می‌شود، که در صرف‌جویی در زمان بسیار مؤثر است و هم برای ایندی دادن به کاربر در راستای نشان دادن عبارت‌هایی که با هم ارتباط منطقی دارند و در رساندن کاربر به هدف از جستجو، کمک می‌کند. سرانجام در بخش ارزیابی پژوهش نشان داده شده است که تعداد رکوردهای بازیابی شده در «دی اسپیس» مجذب به داده کاوی بیشتر و هدف‌مندتر از «دی اسپیس» بدون این توانایی است و چون کاربر را در راستای جستجویش یاری داده و ایندی هوشمندانه به او می‌دهد، رضایتمندی کاربر را نیز، به همراه دارد.

کلیدواژه‌ها: داده کاوی؛ «دی اسپیس» مدیریت دانش؛ بانک‌های اطلاعاتی؛ مدیریت داده؛ مدیریت اطلاعات و مستندات.

* پذیده آور رابط: akram390@yahoo.com

۱. مقدمه

در سال‌های اخیر مدیریت دانش به موضوعی مهم و حیاتی در صنعت‌ها و شرکت‌ها تبدیل شده است. در واقع آن‌چه تضمین کننده برتری‌های بلند مدت برای سازمان‌ها و جوامع است، میزان بهره‌گیری آن‌ها از منابع دانش است و اگر سازمانی نتواند دانش موردنیاز را در جایگاه مناسب آن تشخیص دهد، در عرصه‌های رقابتی با مشکل مواجه خواهد شد. با این دیدگاه، مدیریت دانش ابزاری است که امکان بهره‌گیری مؤثرتر از دانش را در راستای اهداف و برنامه‌های سازمان‌ها فراهم آورده و رقابت‌پذیری سازمان را ممکن خواهد ساخت.

در راستای رقابت‌پذیری سازمان‌ها، فناوری اطلاعات در تبدیل داده‌های خارجی و داخلی سازمان به اطلاعات و دانش با استفاده از تکنیک‌های گوناگون نقشی اساسی و محوری دارد. اگرچه حجم زیادی از داده‌ها در سازمان‌ها وجود دارد، اما این داده‌ها به تنها یکی در نظر تصمیم‌سازان و تصمیم‌گیران دارای ارزش زیادی نیستند اما برای ایجاد و اجرای آنالیزهای کمی و کیفی و ایجاد اطلاعات و دانش مورد نیاز سازمان برای تصمیم‌گیری قاطع، به این داده‌ها نیاز خواهد بود. زمانی که حجم اطلاعات از حدی فراتر می‌رود، عملیات مدیریت و دست‌یابی به اطلاعات و کیفیت دسترسی به این اطلاعات از اهمیت زیادی برخوردار است.

«دی‌اس‌پی‌سی» سیستم آرشیو دیجیتالی یا مخزن اطلاعات سازمانی وب و دارای فضایی برای ذخیره‌سازی، بازیافت و مدیریت اطلاعات سازمان‌ها و مؤسسات است (Smith 2003). از سوی دیگر، الگوریتم‌ها و تکنیک‌های داده کاوی در حجم زیاد داده‌ها، می‌تواند اطلاعات و دانش مورد نیاز سازمان را استخراج کند. این دانش می‌تواند سازمان‌ها را در راستای اهداف و برنامه‌هایشان یاری داده و رقابت‌پذیری سازمانی را امکان‌پذیر سازد.

در بخش نخست مقاله ابتدا نرم‌افزار مدیریت اطلاعات و مستندات متن باز «دی‌اس‌پی‌سی»^۱ را توضیح و در بخش دوم به تشریح داده کاوی پرداخته می‌شود سپس در بخش سوم به انجام مراحل داده کاوی بر روی پایگاه داده «دی‌اس‌پی‌سی» و تشریح طرایح نتایج داده کاوی بر روی نرم‌افزار مدیریت اطلاعات و مستندات متن باز «دی‌اس‌پی‌سی» اشاره و نتایج به دست آمده بر روی یک مجموعه داده نمایان می‌شود.

۲. پیشینه پژوهش

محورهای علمی این مقاله شامل موضوعات مدیریت دانش، مدیریت داده و داده کاوی است. هدف اصلی این مقاله ارائه کاری جدید در لبه فناوری است و ادعایی در لبه‌های دانش ندارد.

1. Dspace

اجرای این کار فنّی نیازمند شناخت حوزه‌های مرتبط علمی در راستای موضوعات مدیریت دانش، مدیریت داده و داده کاوی به شرح زیر است:

۱. بیان مفاهیم، الگوها و کاربردهای داده کاوی (اکبرپور شیرازی ۱۳۸۷).

۲. داده کاوی و کاربرد آن در تصمیم گیری‌ها (نقوی فرد ۱۳۸۶).

۳. مدیریت دانش چه انجام می‌دهد؟ (Firestone 2005).

۴. مدیریت دانش در ارتباط با مشتری (غلامیان ۱۳۸۵).

۵. ارتباط مدیریت و انباره داده در پشتیبانی مدیریت دانش (Erdmann 2001).

۶. مدیریت دانش در محیط ابارة داده‌های ناهمگون (Kerschberg 2000).

۷. سیستم‌های مدیریت بر مبنای دانش و انباره دانش (Firestone 1999).

۸. مدیریت دانش ابارة داده و داده کاوی (Hahsler 2001).

بنابراین هدف مقاله این است که بر روی مرور فناوری‌های پیشرفته مدیریت اطلاعات و مستندات و داده کاوی تمرکز شود. نرم افزارهای چندی برای مدیریت داده ارائه شده که معروف‌ترین آن‌ها «دی‌اسپیس» است. در ادامه به توضیح نرم افزارهای پردازش:

الف. «کوها»^۱: نخستین سیستم کتابخانه‌ای کد منبع باز در دنیا است. سیستم کوها که در نیوزیلند ایجاد شده است، بسته کامل فهرست‌نویسی، سیستم گرددش «اوپک»^۲ و مدیریت اعضاء است. هر چند که این سیستم برای کتابخانه‌های بزرگ به اندازه کافی قوی نیست (از زبان برنامه‌نویسی «پرل»^۳ و پایگاه اطلاعاتی «ام.وای.اس.کیو.ال»^۴ استفاده می‌کند) اما تنها می‌تواند برای کتابخانه‌های کوچک تا متوسط استفاده شود (ارسطوپور ۱۳۸۶).

ب. «گربن استون»^۵: سیستم گرین استون امکانات جستجو و کاوش متون و تصاویر دیجیتالی شده را ارائه می‌دهد (Witten 2005).

پ. «دی‌اسپیس»^۶: این سیستم به این منظور طراحی شده است که به گروه بزرگی از افراد اجازه می‌دهد فایلهای دیجیتال را بارگذاری کنند، دی‌اسپیس اجازه می‌دهد به آن فایلهای دسترسی داشته باشد و آنها را مدیریت کنید (dspace 2008). در ادامه به بخشی از توانایی‌های «دی‌اسپیس» اشاره می‌شود:

۱. دسته‌بندی موضوعی و محتوایی مناسب اطلاعات

۲. توانایی شناسایی انواع قالب پروندهای دیجیتالی اعم از متن، عکس، نرم افزار، صدا و فیلم

۳. ذخیره مجموعه مناسبی از فراداده^۷ در مورد اطلاعاتی از جمله موضوع، عنوان، ویرایش،

سال نشر، نام پدیدآورنده، انتشارات، شابک، تصویر، حجم، دسته‌بندی موضوعی،

مشارکت‌کننده و ...

1. koha
4. MySQL

2. (OPAC)
5. Greenstone

3. Perl
6. dspace
7. metadata

۴. امکان تعیین سطوح دسترسی به کاربران و گروه‌های کاربران
۵. امکان بررسی تغییرات در اطلاعات و تضمین کیفیت نگهداری اطلاعات
۶. نمایش استاندارد اطلاعات در تمامی سیستم‌های عامل و مرورگرهای وب
- ت. مای لایبراری:** با استفاده از مای لایبراری کاربران می‌توانند پنجره‌هایی برای مجموعه‌ها و منابع کتابخانه ایجاد کنند. با وارد شدن به سیستم و ویرایش کردن منابع انتخاب شده به صورت پیش‌فرض، کاربران کتابخانه می‌توانند جعبه‌های جستجوی مربوط به پایگاه‌های اطلاعاتی مورد علاقه‌شان را به علاوه لینک‌های مربوط به صفحات وب کلیدی در گروه‌های موضوعی گوناگون، به آسانی در دسترس داشته باشند (شیریف ۱۳۸۶).
- با بررسی و مطالعه دقیق «دی اسپیس» و با توجه به برتری توانایی‌ها و کارایی‌های آن نسبت به نرم‌افزارهای ذکر شده در بالا، «دی اسپیس» به عنوان سیستمی که کار مدیریت داده را به همراه پایگاه دانش انجام می‌دهد، برای انجام عمل داده کاوی انتخاب شده است.

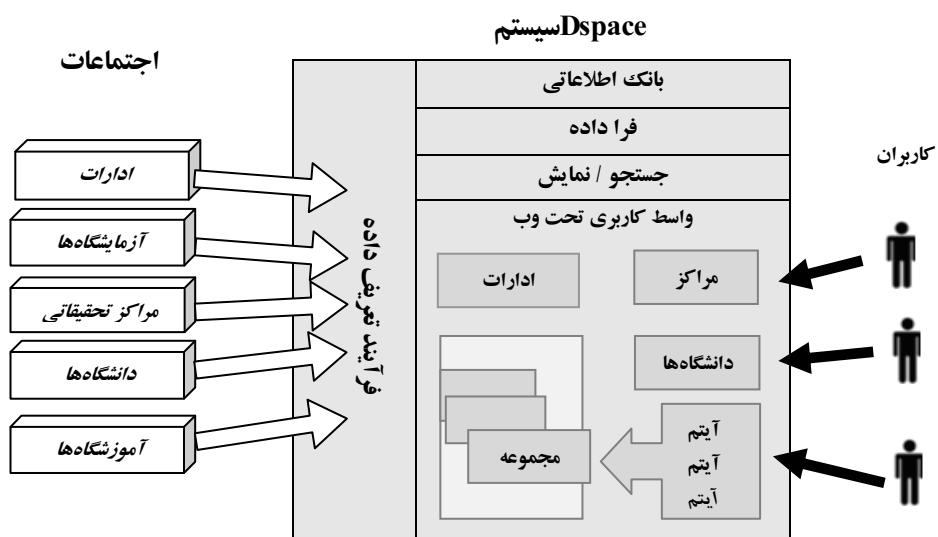
۳. نرم‌افزار متن باز مدیریت اطلاعات و مستندات «دی اسپیس».

سیستم‌های مخزن سازمانی همانند «دی اسپیس» محیط‌های کنترل شده‌ای هستند که با رعایت چارچوب‌های قانونی و تجاری مناسب و فارغ از محل نگهداری فیزیکی و حوزه تصدی گریشان، دسترسی یک‌پارچه‌را به متن کامل اطلاعات ذخیره شده به شکل دیجیتالی از طریق شبکه فراهم می‌آورند. در حقیقت مخزن سازمانی، فضایی برای ذخیره‌سازی، بازیافت و مدیریت اطلاعات سازمان‌ها و مؤسسات است. «دی اسپیس» سیستم آرشیو دیجیتالی یا مخزن اطلاعات سازمانی زیر نظر وب است که توسط دانشگاه «ام. آی. تی.»^۱ و شرکت «اچ. پی.»^۲ تولید شده است و گسترش یافته‌است (Smith 2003). این سیستم از پرکاربردترین و قدرتمندترین نرم‌افزارهای مدیریت اطلاعات سازمانی است که در بیش از سیصد مؤسسه بزرگ دنیا در ۵۵ کشور مورد استفاده شرکت‌های سازمان‌ها، کتابخانه‌ها، مراکز پژوهشی و دانشگاه‌های معتبر جهان مانند دانشگاه ملی استرالیا، کلمبیا، «ام. آی. تی.»^۳، اوهایو، کمبریج، تورنتو و واشنگتن قرار گرفته است. «دی اسپیس» در واقع گنجینه و مخزن الکترونیکی و مرکزیت یافته حجم زیادی ارایی‌های معنوی است که از طریق نهادهای پژوهشی معتبر ایجاد شده‌اند. «ام. آی. تی.» سالانه ده‌هزار مجموعه تولید می‌کند که به صورت الکترونیکی درآمده‌اند. این مجموعه‌ها شامل مجموعه مقاله‌های کنفرانس‌ها و گزارش‌های فنی دانشگاه‌ها است. بسیاری از این اطلاعات بسیار طولانی و غیرقابل دسترس هستند. متن باز بودن این محصول و بسترهای تولید آن، باعث افزایش سرعت و سهولت افزودن امکانات به سیستم شده است که توسعه آن در نسخه‌های آینده، این نرم‌افزار را تسهیل می‌کند.

سهولت دسترس جهانی به منابع محتوایی سازمان، جمع آوری محتوا در محلی متوجه کردن، نگهداری و ذخیره سازی دارایی های دیجیتال مانند پروندهای متنی و تصویر و صدا و فیلم، امکان انتقال اطلاعات و هماهنگی میان سیستم های نگهداری اطلاعات، از مهم ترین اهداف استفاده از این مخزن سازمانی است (Smith 2003).

۱-۳. مدل اطلاعاتی دی اسپیس

در شکل ۱ اجزای مدل اطلاعاتی «دی اسپیس» نمایش داده شده است، که در ادامه به تشریح این اجزاء پرداخته می شود (dspace 2008):



شکل ۱. مدل اطلاعاتی «دی اسپیس» (Smith 2003)

۱-۱-۳. فراداد

برای تشریح فرادادهای از استاندارد «دوبلین کور» که شامل اطلاعاتی از قبیل موضوع، عنوان، ویرایش، سال نشر، نام پدیدآورنده، انتشارات، زبان، شاپک، تصویر، حجم، دسته بندی موضوعی، مشارکت کننده و ... است، استفاده می شود. در این سیستم سه فیلد عنوان، زبان و تاریخ اجباری و بقیه فیلدهای اختیاری است. این اطلاعات برای نمایش و جستجو باید ایندکس گذاری شوند.

۲-۱-۳. واسط کاربری

واسط کاربری این سیستم زیر نظر وب است و برای دسترسی کاربر ارشد واسطی با تمامی دسترسی وجود دارد ولی برای کاربران عادی واسطی برای جستجو و نمایش وجود دارد.

۳-۱-۳. گردش کار

برای تعریف فراداده در «دی اسپیس» باید ابتدا قالب و چارچوب کار که به صورت سلسله مراتب زیر است، ساخته شود.

- ✓ هر سند دیجیتالی به شکل جریانی از بیت‌ها درآمده (رشته های بیتی^۱) و در قالب فایلی ذخیره‌سازی می‌شود.
- ✓ مجموعه‌ای از فایل‌های مرتبط با هم به همراه فراداده اختصاص داده شده به آن‌ها به عنوان یک آیتم^۲ تعریف می‌شوند مثل مقاله‌ای به همراه کدها و فایل‌های ضمیمه آن
- ✓ آیتم‌های داده مربوط به هم در گروه‌ها^۳ دسته‌بندی می‌شوند مثل شاخه‌های پژوهش‌ها، سری گزارش‌های فنی
- ✓ گروه‌های داده در قالب مجموعه‌ها^۴ دسته‌بندی می‌شوند مثل ادارات، مرکز پژوهشی و آزمایشگاه‌های پژوهشی

Communities

✓ Collections

- Items (metadata plus bitstreams)
 - Digital files(bitstreams)

چون هدف از این پژوهش داده کاوی بر روی پایگاه داده «دی اسپیس» است، بنابراین برای انتخاب داده و تعریف داده‌های مورد نیاز در فرایند داده کاوی، نیاز به شناخت کامل مدل اطلاعاتی «دی اسپیس» و پایگاه داده آن و ارتباطات میان جداول بانک اطلاعاتی است.

۲-۳. مشخصات فنی «دی اسپیس»

«دی اسپیس» سیستم متن بازی است که سازمان‌ها با کمترین منبع و هزینه می‌توانند به آسانی آن را اجرا کنند. این سیستم طوری طراحی شده است که بر روی هر نوع سیستم عاملی اجرا می‌شود. کد آن به زبان برنامه‌نویسی «جاوا» نوشته شده است. سیستم مدیریت پایگاه داده رابطه‌ای آن «پستگرس. کیو.ال.»^۵ است و از دیگر تکنولوژی‌های به کار رفته در آن وب سرورها و موتور «جاوا سرولت»^۶ «تامکت و پیچ»^۷ است.

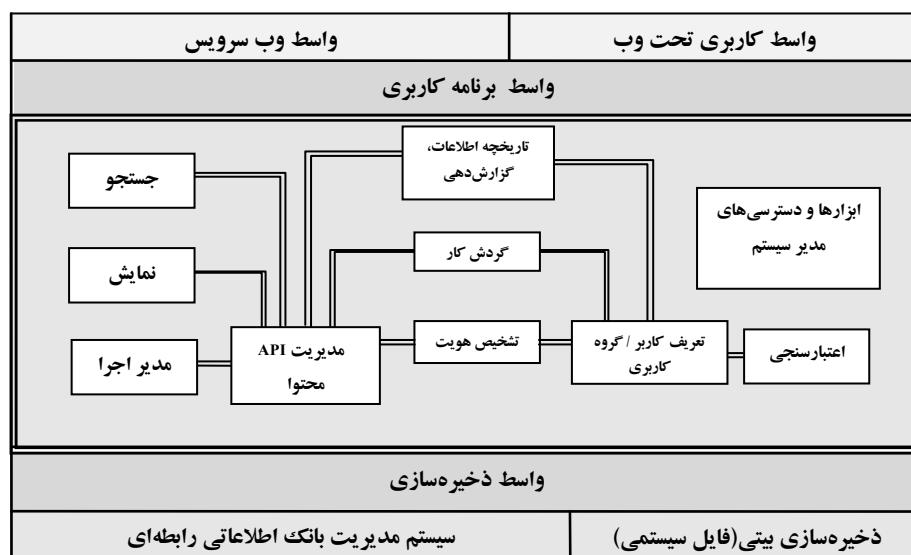
1. bitstream
5. PostgreSQL

2. item
6. Java Servlet

3. collection
7. Apache , Tomcat

4. community

«دی اسپیس» دارای معماری ای سه لایه است(شکل ۲) که شامل لایه های ذخیره سازی^۱، منطق کسب و کار^۲ و برنامه^۳ است و هر کدام از لایه ها با «ای.پی.آی.» های^۴ خاص خود، اجازه بهینه سازی و توسعه را دارد.(dspace 2008 Smith2003).



شکل ۲ معماری Dspace (Smith2003)

- لایه ذخیره سازی از فایل سیستم ها استفاده می کند. که این فایل سیستم ها توسط پایگاه داده (پستگرس.کیو.ال.) مدیریت می شوند. در این پایگاه داده اطلاعات اجتماعات، مجموعه ها، آیتم ها، فراداده ها و ارتباطات آن ها ذخیره می شود.
- لایه منطق کسب و کار لایه ای است که وظایف و فرآیندهای «دی اسپیس» در آن انجام می شود که شامل گردش کار، تاریخچه اطلاعات، جستجو، نمایش، تعیین دسترسی ها، تعریف کاربر و گروه ... است. هر «ماجول» با «ای.پی.آی.» مربوط به خود کار می کند و وظایف آن ماجول را در ارتباط با ماجول های دیگر انجام می دهد.
- لایه برنامه، لایه ارتباط با کاربر است و مهم ترین بخش آن واسط کاربری زیر نظر وب است. هدف از این پژوهش این است که پس از انجام داده کاوی بر روی پایگاه داده «دی اسپیس»، برای به کار بستن نتایج داده کاوی در «دی اسپیس»، در لایه منطق کسب و کار در «ماژول» جستجو،

1. storage
3. application

2. business logic
4. Application Programming Interface

توانایی جدید جستجوی هوشمند طرحی و پیاده‌سازی گردد، به طوری که با وصل شدن به بانک اطلاعاتی علاوه بر جستجوی کلمه درخواستی از طریق کاربر، کلمه مرتبط با آن را نیز اگر در فرایند داده کاوی کشف شده باشد، جستجو کند.

۴. داده کاوی

تعاریف گوناگونی از داده کاوی بیان شده است که نمونه‌ای از آنها به شرح زیر ارائه می‌شوند (Han 2006):

- داده کاوی (یا روش‌های اکتشاف دانش) پردازشی است که داده را از جنبه‌های متفاوت و با تلخیص‌های متفاوت آنالیز می‌کند تا از حجم زیاد داده‌ها، اطلاعات کاربردی استخراج نماید. در این تعریف منظور از اطلاعات کاربردی اطلاعاتی است که بتواند بهره‌وری را افزایش یا هزینه را کاهش دهد و هر دو منظور را همزمان برآورده سازد. نرم‌افزار داده کاوی نیز یکی از ابزارهایی است که می‌تواند این هدف را محقق سازد. این ابزار باید بتواند داده‌ها را در کلاس‌های گوناگون دسته‌بندی و آنها را از طریق آنالیز مؤلفه‌های متفاوت آنها بررسی و تحلیل نماید. در این صورت می‌تواند نتایجی را استخراج نماید که همان اطلاعات کاربردی در مدیریت منابع یا دیگر زمینه‌های کارکرد مورد نظر سازمان بهره‌بردار باشد.
- داده کاوی در مواردی از جمله خرده‌فروشی (تعیین الگوهای خرید مشتریان، تجزیه و تحلیل سبد خرید بازار، پیش‌گویی میزان خرید مشتریان از طریق پست (فروش الکترونیکی)، بانکداری (پیش‌بینی الگوهای کلاهبرداری از طریق کارت‌های اعتباری، تشخیص مشتریان ثابت، تعیین میزان استفاده از کارت‌های اعتباری بر اساس گروه‌های اجتماعی)، یمه (تجزیه و تحلیل دعاوی، پیش‌گویی میزان خرید یمه نامه‌های جدید توسط مشتریان)، پزشکی (تعیین نوع رفتار با بیماران و پیش‌گویی میزان موفقیت عمل‌های جراحی، تعیین میزان موفقیت روش‌های درمانی در برخورد با بیماری‌های سخت)، تجارت (تبليغات، مدیریت ارتباط با مشتری) (شاه‌سمندی ۱۳۸۴) و غیره کاربرد دارد. در ادامه به تشریح فنون داده کاوی پرداخته شده و علل انتخاب حوزه تحلیل و استگی در این پژوهش بیان می‌شود.
- فن‌های داده کاوی به دسته‌های زیر تقسیم می‌شوند (Han 2006)

 - توصیف و تمایزگذاری در داده از طریق دسته‌بندی‌ها و مفاهیم حاکم بر داده‌ها
 - توصیف داده‌ها از طریق گردآوری و خلاصه کردن داده‌های گروهی زیر نظر موضوع از عنوان‌های عمومی (که گروه، موضوع هدف نامیده می‌شود)

- تمایزگذاری داده‌ها از طریق مقایسه گروه هدف با گروه‌های دیگر (که البته توانایی مقایسه آنها با یکدیگر وجود داشته باشد (که به طور عموم تضاد گروهی-کلассی نامیده می‌شود).
- و از طریق توصیف و تمایزگذاری داده‌ها که اجتماع دو حالت بالا رخ خواهد داد.
- تحلیل وابستگی
 - تحلیل وابستگی، کشف قوانین وابستگی میان اطلاعات است به نحوی که نمایان گر مقادیری از صفات اطلاعاتی است که بیشتر اوقات همراه با یکدیگر و در مجموعه‌ای داده در داده‌های بانک اطلاعاتی ظاهر می‌شوند.
 - در اساس ارتباط میان مجموعه اشیاء (چیزها) وابستگی‌های جالب توجهی هستند که منجر به امکان آشکارسازی الگوهای مفید و قوانین وابستگی برای پشتیبانی تصمیم، پیش‌بینی‌های مالی، سیاست‌های بازاریابی، واقعی پژوهشی و کاربردهای دیگر می‌شود . (S.Gyorodi 2001)
 - تحلیل وابستگی‌ها حالت غیر نظارتی داده کاوی است که به جستجو برای یافتن ارتباط در مجموعه داده‌ها می‌پردازد. یکی از کاربردی‌ترین حالات تحلیل وابستگی‌ها، تجزیه و تحلیل سبد بازار است که در آن هدف، یافتن کالاهایی است که به طور همزمان خریداری می‌شوند. این کار کمک می‌کند که خردروشان بهتر بتوانند کالاهای خود را سازماندهی کرده و چیدمان بهتری از محصولات خود داشته باشند (Ye 2003).
 - دسته‌بندی و پیش‌گویی
 - دسته‌بندی پردازشی است برای یافتن مجموعه‌ای از مدل‌ها (یا توابع) که مفاهیم یا کلاس‌های داده را برای تشخیص داده‌هایی که در هیچ کلاسی قرار نمی‌گیرند یا به صورتی نامشخص توصیف شده‌اند را توصیف نموده یا تشخیص دهند. در حقیقت دسته‌بندی داده‌ها، نوعی توانمندی را برای تشخیص یا پیش‌گویی داده‌های نامشخص ایجاد می‌کند و در عمل نیز مدل‌های برگرفته شده برپایه داده‌های جامعه آماری نمونه تعریف و توصیف می‌شوند و پس از آن بر روی داده‌های دیگر تعمیم داده شده و باعث تشخیص کلاس داده یا پیش‌گویی داده‌هایی می‌شوند که به صورت خام وارد جامعه آماری مورد کاوش گردیده‌اند.
 - در سیستم داده کاوی یا سیستم‌های مشابه از فرم‌های گوناگونی برای نمایش و ارائه مدل‌های برگرفته شده استفاده می‌شود که از آن جمله می‌توان به موارد زیر اشاره کرد:
 - قوانین دسته‌بندی (قوانین if-then)، درخت تصمیم، فرمول‌های ریاضی و شبکه‌های عصبی

• تحلیل خوشبندی

○ بر عکس کلاس‌بندی و پیش‌گویی که داده‌ها را براساس نشان کلاس آنها بررسی و تحلیل می‌کرد، در روش خوشبندی، تحلیل‌های انجام شده در این روش، بدون توجه به نشان کلاس داده‌ها انجام می‌شوند (اکبر پورشیرازی ۱۳۸۷).

• تحلیل تکامل و انحراف (تکمیل و خطأ)

○ تحلیل تکامل داده در حقیقت مدل‌سازی و توصیف سیر تکاملی و تغییرات گرایش‌های موجود در داده‌ها در یک بازه زمانی است. این نوع مدل‌سازی ممکن است شامل هر کدام از انواع توصیف، تمايز، خوشبندی، کلاس‌بندی و ارتباط میان داده‌هایی شود که به زمان بستگی دارند که این تحلیل‌ها به طور طبیعی از مقایسه الگوهای مربوط به داده‌های سری - زمانی، متناوب و یا تحلیل داده‌های مشابه یا موارد این چنینی، مجزا هستند.

در این پژوهش به دلایل زیر حوزه تحلیل وابستگی انتخاب شده است:

• حوزه کار در داده کاوی متناسب با هدف بیان شده در پژوهش است. در این نوشتار هدف، پیدا کردن قوانین و ارتباطات میان داده‌ها است.

• عدم وابستگی به زمان در هدف بیان شده

• عدم نیاز به دسته‌بندی داده‌ها در هدف بیان شده

• عدم نیاز به توزیع آماری در این حوزه

• عدم نیاز به داده‌های آموزشی در این حوزه

• در کم بهتر برای کاربران

با بررسی الگوریتم‌های این حوزه، الگوریتم معروف «آپریوری»¹ که کاربرد زیادی در این حوزه دارد و در این حوزه با این الگوریتم کار می‌شود، انتخاب گردیده است.

۵. فرایند داده کاوی بر روی پایگاه «دی اسپیس»

از آن جایی که «دی اسپیس» جستجوی عادی و پیشرفته را بر اساس کلمات ورودی انجام می‌دهد این نیاز وجود دارد که اگر «دی اسپیس» بتواند به کاربران خود به طور هوشمند، کلمات مرتبط با درخواست را معروفی کند، در رساندن کاربران به اهدافشان از جستجو، کمک شایانی کرده است. به علاوه در کم شدن زمان جستجو نیز بسیار مؤثر بوده است و این باعث افزایش سرعت و کارایی جستجوی کاربر و در نهایت رضایتمندی او می‌شود. بنابراین برای کشف این کلمات و

1. Apriori

عبارات مرتبط باید عمل داده کاوی بر روی پایگاه «دی اسپیس» انجام شود. در ادامه ابتدا فرایند استاندارد داده کاوی به طور کلی بیان می شود (Han 2006) سپس این فرایند گام به گام بر روی داده های این پژوهش به صورت عملی تشریح می شود:

- تعیین بازه و دامنه سیستم مورد کاربرد و هدف نهایی ایجاد دانش؛
- جمع آوری داده های موجود از تمامی حوزه های مورد نیاز؛
- پاک سازی و پیش پردازش داده ها که ممکن است تا ۶۰ درصد کل کار را از نظر حجم فعالیت پوشش دهد)؛
- کاهش و تغییر شکل دادن داده ها (که ممکن است از طریق طراحی و ساخت انباره داده ها انجام شود)؛
- انتخاب داده ها بر اساس نوع مفاهیم مورد نظر؛
- انتخاب پردازش های مورد نظر در داده کاوی (مانند گردآوری، دسته بندی، رگرسیون، تحلیل وابستگی، خوشه بندی و ...)؛
- انتخاب الگوریتم مورد نظر در داده کاوی؛
- انجام پردازش های داده کاوی (جستجو به دنبال الگوی مفاهیم مورد نظر)؛
- ارزیابی الگوهای و ارائه دانش حاصله از راه های بصری، دگرگونی داده ها، حذف الگوهای تکراری و ...؛
- و در پایان، دست یابی به دانش الگوهای رفتاری سیستم و استفاده از آن در کار کردهای عملیاتی.

در این میان برخی از گام ها قابل تکرار شدن بوده و برخی (مانند تشکیل انباره داده ها) قابل گذر است، اما نکته مهم، طی مسیر صحیح و منطبق بر هدف کاوش در داده ها است. متناسب با فرایند استاندارد بالا، فرایند داده کاوی بر روی پایگاه نرم افزار متن باز مدیریت اطلاعات و مستندات «دی اسپیس» به صورت دیاگرام در شکل ۳ مطرح می شود.



شکل ۳. فرایند انجام داده کاوی بر پایگاه «دی اسپیس». مراحل داده کاوی بر روی پایگاه داده «دی اسپیس»

طبق دیاگرام بالا در ادامه تشریح می شود:

۱. بیان هدف از داده کاوی:

انجام داده کاوی بر روی سوابق و تاریخچه جستجوهای کاربران در نرم افزار متن باز «دی اسپیس» برای به دست آوردن ارتباطات و وابستگی های میان عبارت های جستجو شده است تا با به دست آمدن این ارتباطات، بتوان امکان جستجوی هوشمند را در «دی اسپیس» اضافه کرد که علاوه بر افزایش توانایی «دی اسپیس»، به کاربر در هر چه سریع تر رسیدن به اهدافش کمک کرد.

۲. جمع آوری و انتخاب داده برای داده کاوی متناسب با هدف:

در این بخش دو دسته داده وجود دارد. دسته نخست، فراداده ها که بر اساس استاندارد «دوبلین کور» شامل اطلاعاتی مثل موضوع، عنوان، ویرایش، سال نشر، نام پدیدآورنده، انتشارات، شابک، تصویر، حجم، دسته بندی موضوعی، مشارکت کننده و ... است. در شکل ۴ بخشی از این اطلاعات در مورد تعریف فراداده نشان داده می شود.



استخراج داشت از پایگاه داده نرم‌افزارهای مدیریت اطلاعات | فشارکی و دیگران

The screenshot shows a Microsoft Internet Explorer window displaying a DSpace digital library record. The title bar reads "DSpace at My University: CRMwithERP - Microsoft Internet Explorer". The main content area shows a document record for "CRMwithERP.pdf". The record includes fields such as dc.contributor.author (Larry Knob), dc.date.accessioned (2009-11-15T16:34:39Z), dc.date.available (2009-11-15T16:34:39Z), dc.date.issued (2009-11-15T16:34:39Z), dc.identifier.uri (http://hdl.handle.net/123456789/13), dc.language.iso (en), dc.subject (Finance, Marketing, Sale, CRM, ERP), dc.title (CRMwithERP), and dc.type (Article). Below the record, it says "Appears in Collections: CRMwithERP". A "Files in This Item:" section shows a single file entry: CRMwithERP.pdf (31.91 kB, Adobe PDF, View/Open). The left sidebar contains links for Home, Browse (Communities & Collections, Issue Date, Author, Title, Subject), Sign on to (Receive email updates, My DSpace authorized users, Edit Profile), Help, and About DSpace.

شکل ۴. نمونه‌ای از تعریف فراداده

اطلاعات فراداده‌ها در قالب فرایند زیر تعریف می‌شوند:

تشریح فیلدها ← بارگذاری فایل ← بازبینی داده‌ها ← ارائه مجوز ← تکمیل و اتمام فرایند. در فرایند بالا ابتدا فیلدهای فراداده پر می‌شوند، سپس فایل سند به آن ضمیمه می‌شود و در مرحله بعد اطلاعات وارد شده، بازنگری شده و اگر ایرادی داشت اصلاح می‌شود و در مرحله بعد مجوز ثبت آن تأیید شده در پایان اطلاعات فراداده به‌طور کامل در بانک اطلاعاتی «دی اسپیس» در جدول فراداده‌ها ثبت می‌شود.

دسته دوم، کلمات و عبارت‌های جستجو شده توسعه کاربران است (جدول ۱). مجموعه داده‌های آزمایشی در این پژوهش، حدود ۲۰۰۰ کلمه جستجو شده از حدود ۳۰ کاربر است. این داده‌ها بخشی از اطلاعاتی است که توسعه جستجوهای کاربران شرکتی در پورتال سازمانی آن ذخیره شده و برای نمونه آزمایشی این پژوهش انتخاب شده است. این نهاد، شرکتی کامپیوتراست که در حوزه‌های نرم‌افزار، سخت‌افزار، شبکه و مشاوره پژوهه‌های فناوری اطلاعات فعالیت می‌کند و حدود ۴۰۰ کارمند و دو شرکت زیرمجموعه دارد. داده‌های ذکر شده در جدولی در بانک اطلاعاتی «پستگرس.کیو.ال»، با فیلدهای کد کاربر، کلمه جستجو شده و تاریخ جستجو ذخیره می‌شوند. این داده‌ها تمام حوزه‌ها را از جمله حوزه‌های علمی، پژوهشی، فناوری، اطلاعات عمومی و... پوشش می‌دهند.

برای انجام داده کاوی در راستای هدف بیان شده، به دسته دوم داده‌ها نیاز است و بر روی کلمات جستجو شده فرایند داده کاوی انجام می‌شود ولی برای آزمایش و ارزیابی «دی اسپیس» مجهز به داده کاوی، به دسته نخست داده‌ها نیاز است.

جدول ۱ بخشی از «دیتاسِت»^۱ مورد آزمایش

ID	UserCode	WordSearch	DateSearch
2	1	erp	1388/05/01
3	1	customer	1388/05/01
4	1	protocol	1388/05/01
5	1	linux	1388/05/01
6	1	sap	1388/05/01
7	1	irankhodro	1388/05/01
8	1	enterprise	1388/05/01
9	1	scm	1388/05/01
10	2	linux	1388/05/01
11	2	windows	1388/05/01
12	2	os	1388/05/01
13	2	crm	1388/05/01
14	2	customer	1388/05/01
15	2	olap	1388/05/01
16	2	datawarehouse	1388/05/02
17	2	oltp	1388/05/02
18	2	scm	1388/05/02
19	2	architecture	1388/05/02
20	2	soa	1388/05/02
21	2	memari	1388/05/02
22	3	olap	1388/05/02
23	3	oltp	1388/05/02
24	3	datawarehouse	1388/05/02
25	3	web	1388/05/02

1. DataSet

۳. اصلاح و پاکسازی مورد نیاز در داده‌ها:

در این مرحله داده‌ها مورد پاکسازی و اصلاح قرار گرفته و عمل پیش پردازش انجام می‌شود. در این پژوهش اطلاعات تا حدودی کامل بوده و داده‌های دارای نقص، حذف شده است.

۴. بررسی و مطالعه حوزه‌ها و الگوریتم‌های داده‌کاوی و انتخاب آن‌ها متناسب با هدف:

با مطالعه و بررسی‌های فن‌های متنوع داده‌کاوی و با ارائه دلایلی که در پایان بند چهار آمده است، فن تحلیل وابستگی به عنوان یکی از فنون داده‌کاوی بر روی پایگاه داده «دی اسپیس» انتخاب شده و از میان الگوریتم‌های این حوزه، با الگوریتم معروف «آپریبری» کار می‌شود.

۵. بررسی و اجرای نرم‌افزارهای داده‌کاوی در حوزه تحلیل وابستگی:

برای به‌دست آوردن ارتباطات و وابستگی‌های داده‌ای، نرم‌افزارهای «وکا» و «مگنیوم اپوس»^۱ مورد بررسی و مطالعه قرار گرفته است که به طور مختصر در ادامه به تشریح دو نرم‌افزار پرداخته می‌شود:

- نرم افزار «وکا» مجموعه‌ای از الگوریتم‌های روز یادگیری ماشینی و ابزارهای پیش پردازش داده‌ها است. این نرم‌افزار به گونه‌ای طراحی شده است که می‌توان به سرعت، روش‌های موجود را به صورت انعطاف‌پذیری روی مجموعه‌های جدید داده‌کاوی‌های آزمایش کرد. این نرم‌افزار، پشتیبانی‌های ارزشمندی را برای کل فرایند داده‌کاوی‌های تجربی فراهم می‌کند. این پشتیبانی‌ها، آماده‌سازی داده‌های ورودی، ارزیابی آماری چارچوب‌های یادگیری و نمایش گرافیکی داده‌های ورودی و نتایج یادگیری را در بر می‌گیرند. همچنین، هماهنگ با دامنه وسیع الگوریتم‌های یادگیری، این نرم‌افزار شامل ابزارهای گوناگون پیش‌پردازش داده‌ها است. این جعبه‌ابزار متنوع و جامع، از طریق واسطه متداول در دسترس است، به‌طوری که کاربر می‌تواند روش‌های متفاوت را در آن با یکدیگر مقایسه کند و روش‌هایی مناسب‌تر را تشخیص دهد (عطایی ۱۳۸۶).

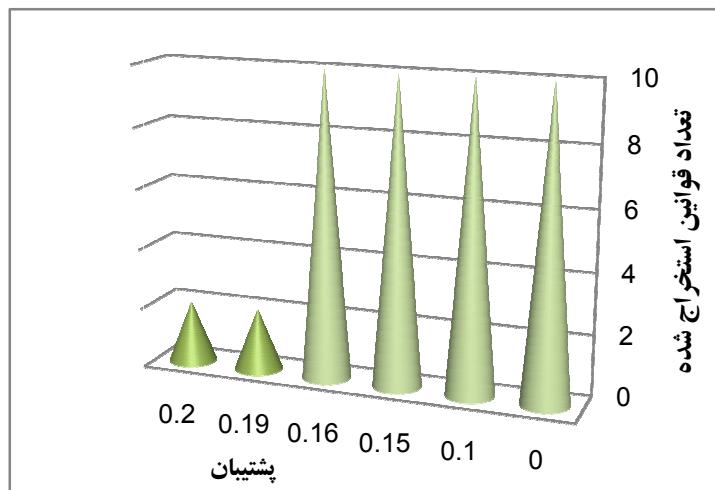
- نرم افزار «مگنیوم اپوس»:
 - «مگنیوم اپوس» از نرم‌افزارهای داده‌کاوی برای کشف ارتباطات میان داده‌ها است.
 - این نرم‌افزار ارتباطات و وابستگی‌هایی را که بیشترین یکسانی با معیارهای انتخاب شده را دارد، به‌دست می‌آورد که با مشخصات زیر است:

1. Magnum Opus

۱. دارای سابقه‌ی بالاتر از ده سال در خدمت رسانی به انجمن‌های داده‌کاوی
 ۲. طراحی شده توسط کارشناسان داده‌کاوی
 ۳. تبدیل داده به دانش در این سیستم
 ۴. امکان تشریح ارتباطات به شکل ساده
 ۵. امکان حذف خودکار ارتباطات نادرست و اشتباه (برای به دست آوردن ارتباطات صحیح و قابل اعتماد)
 ۶. طراحی «مگنیوم اپوس» برای تحلیل روی بانک‌های اطلاعاتی بزرگ و شایان توجه با میلیون‌ها رکورد
 ۷. سرعت عمل پردازش و تحلیل
- حال برای اجرای نرم‌افزارها، داده‌ها به فرمتهای ورودی مورد نیازشان تبدیل شده و پارامترهای ورودی هر دو نرم‌افزار تنظیم می‌شود. نرم افزار «وِکا» فایلی ورودی به فرمت «ای.آر.اف.اف.»^۱ و نرم افزار «مگنیوم اپوس» فایلی ورودی به فرمت «آی.تی.إل»^۲ برای انجام داده‌کاوی دریافت می‌کنند.
- در نرم افزار «وِکا»، قسمت «آسوسی ایشن»^۳ را انتخاب کرده و الگوریتم «اپرییری» را از لیست الگوریتم‌ها گزینش می‌کنیم سپس پارامترهای مورد نیاز این الگوریتم که به صورت پیش فرض موجود است را در صورت نیاز تغییر داده با اجرای نرم‌افزار، ارتباطات میان داده‌ها کشف شده و قوانین در قالب زیر خارج می‌شود.

```
keyword2=knowledgediscovery 6 ==> keyword1=datamining 6 conf:(1)
keyword1=datamining 6 ==> keyword2=knowledgediscovery 6 conf:(1)
keyword40=oracle 5 ==> keyword39=dbms 5 conf:(1)
keyword39=dbms 5 ==> keyword40=oracle 5 conf:(1)
keyword41=sqlserver 5 ==> keyword39=dbms 5 conf:(1)
keyword39=dbms 5 ==> keyword41=sqlserver 5 conf:(1)
keyword41=sqlserver 5 ==> keyword40=oracle 5 conf:(1)
keyword40=oracle 5 ==> keyword41=sqlserver 5 conf:(1)
```

در این پژوهش به ازای مقادیر گوناگون پارامتر پشتیبان^۴، نرم‌افزار «وِکا» اجرا شده و تعداد قوانین گوناگونی به دست آمده است که آن در شکل پنج نشان داده شده است ولی در پایان همان مقدار پیش فرض نرم‌افزار (پشتیبان = ۰.۱۵) برای اجرا و خروج قوانین در نظر گرفته شده است.



شکل ۵ نمودار مقایسه تعداد قوانین خارج شده به ازای پشتیبان‌های گوناگون در «وکا»

نرم‌افزار «مگنیوم اپوس» که ویژه کشف ارتباطات داده‌ای است، با تعیین پارامترهای آن، قابل اجرا است و قوانین در قالب زیر ارائه می‌شود.

```

apriorialghoritm -> apriorisoftware
Coverage=0.424 (14); Support=0.424 (14); Strength=1.000; Lift=2.36;
Leverage=0.2443 (8.1)

apriorisoftware -> apriorialghoritm
Coverage=0.424 (14); Support=0.424 (14); Strength=1.000; Lift=2.36;
Leverage=0.2443 (8.1)

backup -> recovery
Coverage=0.485 (16); Support=0.485 (16); Strength=1.000; Lift=1.94;
Leverage=0.2351 (7.8)

recovery -> backup
Coverage=0.515 (17); Support=0.485 (16); Strength=0.941; Lift=1.94;
Leverage=0.2351 (7.8)

oracle -> sqlserver
Coverage=0.333 (11); Support=0.333 (11); Strength=1.000; Lift=3.00;
Leverage=0.2222 (7.3)

sqlserver -> oracle
Coverage=0.333 (11); Support=0.333 (11); Strength=1.000; Lift=3.00;
Leverage=0.2222 (7.3)

windows -> linux
Coverage=0.364 (12); Support=0.364 (12); Strength=1.000; Lift=2.54;
Leverage=0.2204 (7.3)

linux -> windows
Coverage=0.394 (13); Support=0.364 (12); Strength=0.923; Lift=2.54;
Leverage=0.2204 (7.3)

soa -> architecture
Coverage=0.485 (16); Support=0.485 (16); Strength=1.000; Lift=1.83;
Leverage=0.2204 (7.3)

```

نتیجه داده کاوی پس از ارزیابی و حذف الگوهای تکراری برای انجام تغییر در کد «دی اسپیس»، در بانک اطلاعاتی «دی اسپیس»، جدول «ریزالتاینینگ^۱» ذخیره می‌شود.

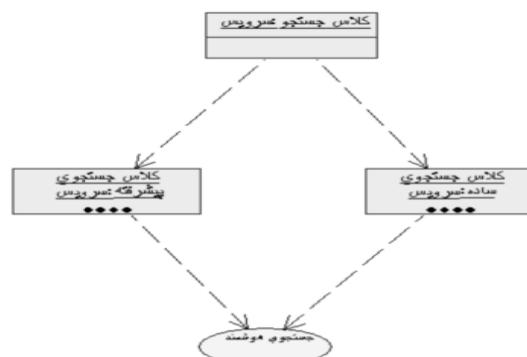
۶. به کار بستن نتایج داده کاوی در نرم‌افزار متن باز «دی اسپیس».

در این قسمت به طراحی سیستم مدیریت دانش با توجه به دانش‌های برگرفته از طریق داده کاوی در نرم‌افزار متن باز «دی اسپیس» پرداخته می‌شود. برای انجام طراحی از روش^۲ «آر.بی.پی.»^۳ و ابزار «یو.ام.ال.»^۴ استفاده می‌شود.

برای به کار بستن نتایج داده کاوی در «دی اسپیس» باید در طراحی ماجول جستجو تغییراتی انجام شود. در حالت پیشاز داده کاوی، «دی اسپیس» جستجوی خود را بر اساس کلمات ورودی کاربر انجام و نتیجه را نمایش می‌دهد، ولی با انجام تغییراتی در «دی اسپیس» که در زیر بیان شده است، پس از این که کاربر کلمات مورد جستجویش را وارد می‌کند، در ماجول جستجو (جستجوی ساده یا جستجوی پیشرفته)، پس از وصل به بانک اطلاعاتی به جدول «ریزالتاینینگ^۵» که نتایج داده کاوی و قوانین کشف شده (کلمات مرتبط به هم) در آن ذخیره شده است، متصل می‌شود و اگر کلمات مرتبط با پارامترهای ورودی را پیدا کند، کلمات معادل را هم جستجو می‌کند و اگر پیدا نکند، فقط همان کلمه ورودی کاربر را جستجو کرده و نمایش می‌دهد.

حال برای طراحی توانایی جستجوی هوشمند به تشریح نمودارهای کلاس، توالی و فرایند ریز جستجوی هوشمند می‌پردازیم.

در شکل ۶ نمودار کلاس فرایند جستجوی هوشمند نشان داده شده است. کلاس جستجو به دو کلاس جستجوی ساده و پیشرفته تقسیم شده و هر دو کلاس از توانایی جستجوی هوشمند استفاده می‌کنند.

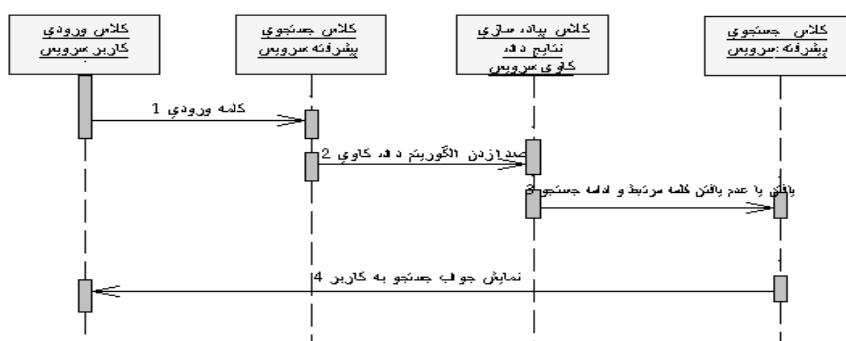


شکل ۶. نمودار کلاس فرایند جستجوی هوشمند

اطلاعات علوم‌پویانه‌واری

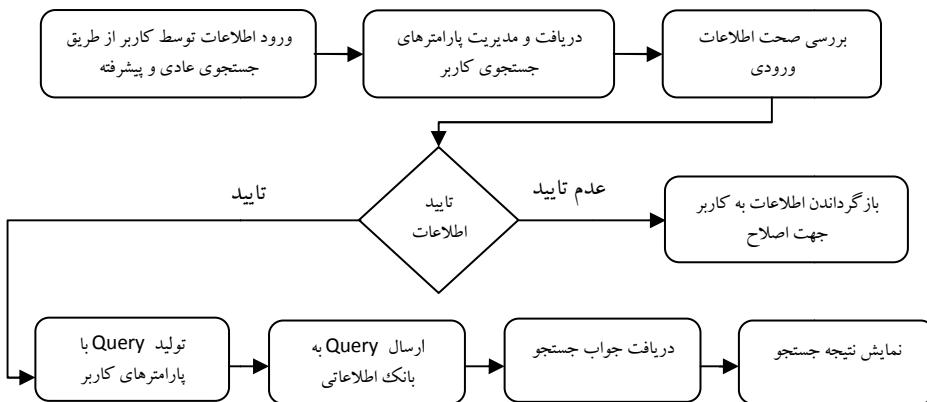
استخراج داشت از پایگاه داده نرم‌افزارهای مدیریت اطلاعات | فشارکی و دیگران

در شکل ۷، نمودار توالی فرایند جستجوی هوشمند ترسیم شده است. در این نمودار مراتب انجام فعالیت‌ها که در بالا بیان گردید، نشان داده می‌شود.



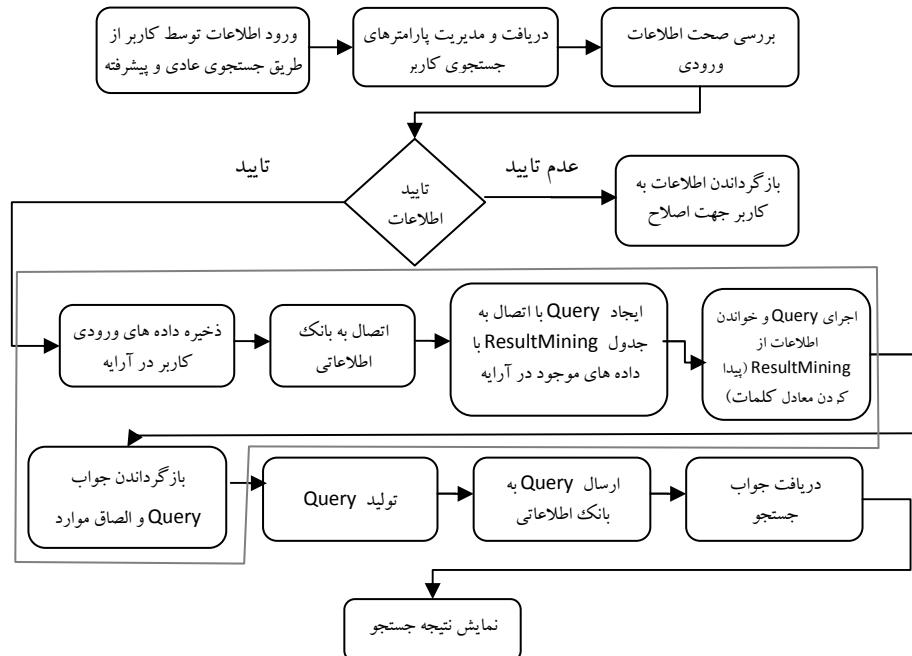
شکل ۷. نمودار توالی فرایند جستجوی هوشمند

در شکل ۸ فرایند ریز جستجو در نرم‌افزار متن باز «دی اسپیس» در حالت پیش از انجام تغییرات، نشان داده می‌شود.



شکل ۸. فرایند جستجو در «دی اسپیس»

در شکل ۹ فرایند ریز جستجو در نرم‌افزار متن باز «دی اسپیس» بعد از انجام تغییرات، نشان داده می‌شود (حلقه قرمز تغییرات جدید است).



شکل ۹ فرایند جستجوی هوشمند در «دی اسپیس»

با توجه به تغییرات بیان شده در بالا، در بخش ماجول جستجو در کد برنامه «دی اسپیس»، توابع زیر اضافه می شود:

- تابع «ماینینگ»: این تابع کلمات مورد نظر کاربر را دریافت کرده و در آرایهای به نام «فریس»^۱ ذخیره می کند و در پایان عبارت جستجوی تولید شده را به «کواری»^۲ اصلی اضافه می کند.
- تابع «گت‌ماینینگ»^۴: این تابع داده ها را از آرایه «فریس» خوانده و با اتصال به جدول «ریزالت‌ماینینگ»^۵(جدول نگهداری نتایج داده کاوی) از بانک اطلاعاتی «سُستِگر»^۶، جستجوی مربوطه را آغاز می کند و نتیجه را در یک «ریزالت‌ست»^۷ نگهداری می کند.
- تابع «سرچ. آی. ان. دی. بی.»: این تابع برای اتصال به بانک اطلاعاتی تعریف شده است.

۱. علاقه مندان می توانند از طریق تماس با نویسنده متن توابع را به دست آورند.

2. phrase
6. postgres

3. Query
7. resultset

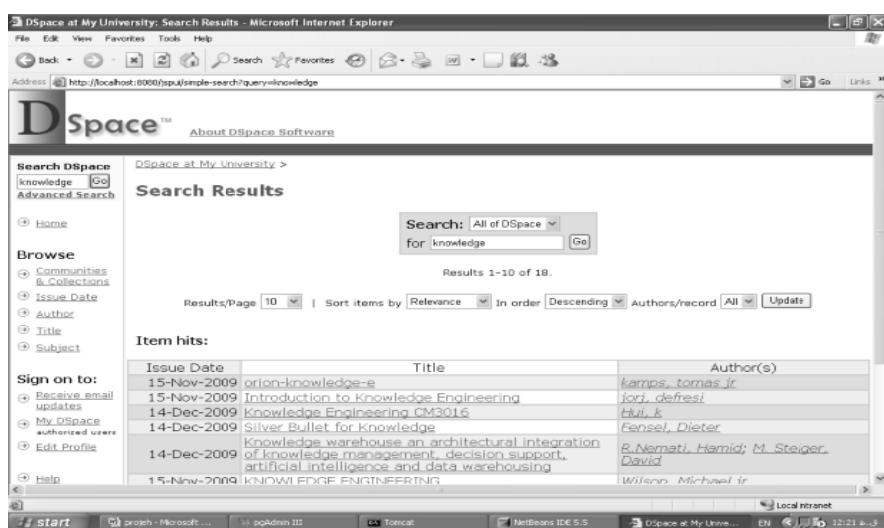
4. getMinings
8. searchInDB

5. Resultmining

نمایش نتیجه توابع اضافه شده بالا و توانایی جدید جستجوی هوشمند بر روی نمونه آزمایشی در قسمت ارزیابی نشان داده می شود.

۲. ارزیابی

این نوشتار، پژوهشی فناورانه است، که بحث فناوری یعنی (انجام تغییر در ساختار و معماری نرم افزار متن باز «دی اسپیس»، برای ایجاد توانایی جدید جستجوی هوشمند بعد از انجام فرایند داده کاوی است. این پژوهش بر لب فناوری گام بر می دارد نه بر لب دانشی. لیکن برای ارزیابی آن، اثبات کار کرد درست «دی اسپیس» با اضافه شدن توانایی جدید (جستجوی هوشمند) به آن کافی است. در ادامه به مقایسه «دی اسپیس» در حالت های پیش و بعد از انجام تغییرات پرداخته می شود. در شکل ۱۰ «دی اسپیس» با روش گذشته، پس از ورود کلمه «نالج»^۱ از طریق کاربر، فقط خود کلمه را جستجو کرده و ۱۸ مورد بازیابی کرده است.



شکل ۱۰ نمونه ای از کار کرد قدیمی «دی اسپیس»

در شکل ۱۱ «دی اسپیس» با روش جدید و تغییر یافته اش و با توانایی جستجوی هوشمند، پس از ورود کلمه «نالج» توسط کاربر ابتدا در پایگاه داده اش بررسی می کند که آیا کلمه «نالج» با کلمه دیگر ارتباطی منطقی دارد یا خیر؟ و پس از پیدا کردن کلمه مرتبط «این فیشن»^۲ با آن، هر دو را جستجو کرده و ۲۰ مورد را بازیابی می کند. تشریح این فرایند از این قرار است:

1. knowledge 2. information

- نتایج داده کاوی نرم افزارهای «وکا» و «مگنیوم اوپوس» در پایگاه داده «دی اسپیس»، در جدول «ریزالت ماینینگ» ذخیره می شود.
- در جستجوی هوشمند ابتدا تابع «ماینینگ» صدا زده می شود: این تابع کلمات جستجو شده توسط کاربر را دریافت کرده و در آرایه ای ذخیره می کند. این جا کلمه «نالج» در آرایه ذخیره می شود.
- سپس تابع «سرچ.آی.إن.دی.بی.» صدا زده می شود. این تابع برای اتصال به بانک اطلاعاتی تعریف شده است.
- در مرحله بعد تابع «گتماینینگ» صدا زده می شود. این تابع داده ها را از آرایه خوانده و با اتصال به جدول «ریزالت ماینینگ» (جدول نگهداری نتایج داده کاوی) از بانک اطلاعاتی «پستگر»، جستجوی مربوطه را آغاز می کند که آیا داده های آرایه (مثل «نالج»)، در جدول «ریزالت ماینینگ» موجود هستند یا خیر؟ در صورت وجود، کلمه معادل که در این مثال «اینفیمیشن» است را پیدا کرده و در یک «ریزالت» نگهداری می کند و به تابع «ماینینگ» بر می گرداند.
- سپس در تابع «ماینینگ» طبق نتایج موجود در «ریزالت»، عبارت جستجوی جدید ساخته می شود. که در این عبارت هم کلمه «نالج» است و هم کلمه «اینفیمیشن».

Issue Date	Title	Author(s)
16-Dec-2009	Knowledge Base Management Systems	Firestone, M.
14-Dec-2009	Towards the Integration of e-business, knowledge management and policy considerations within an information systems strategy framework	journal
15-Nov-2009	Open-Knowledge	kampos, tomás jr
15-Nov-2009	Introduction to Knowledge Engineering	jvt, defretz
14-Dec-2009	Knowledge Engineering CM3016	Paul, R.

شكل ۱۱. نمونه‌ای از کار کرد جدید «دی اسپیس»

در جدول ۲ نتایج چند نمونه از داده های ورودی به نرم افزار «دی اسپیس» در حالت های پیش و پس از تغییرات جستجوی هوشمند نشان داده می شود.

جدول ۲ مقایسه نتایج «دی اسپیس» در پیش و پس از تغییرات

نتیجه جستجو در نرم افزار Dspace بعد از تغییرات		نتیجه جستجو در نرم افزار Dspace قبل از تغییرات	کلمه ورودی توسط کاربر
تعداد	کلمه مرتبط		
۲۰	Information	۱۸ رکورد	Knowledge
۷	Information	۵ رکورد	Data
۱۴	Recovery	۸ رکورد	Backup
۱۶	Linux	۱۰ رکورد	Windows
۹	Sqlserver	۵ رکورد	Oracle
۱۵	Dbms	۵ رکورد	oracle
۱۹	Architecture	۱۱ رکورد	Soa
۱۳	Baby	۲ رکورد	child
۷	Apriorialghoritm	۲ رکورد	apriorisoftware
۱۳	Knowledge discovery	۸ رکورد	datamining
۱۴	Sqlserver	۱۰ رکورد	dbms

در نمونه های بالا علاوه بر افزایش نتیجه جستجو، نتایج غیر مستقیم زیر نیز به دست می آید:

- افزایش سرعت جستجوی کاربر
- ارائه هوشمند کلمات مرتبط با کلمه ورودی کاربر
- ارائه ایده کلمات مرتبط به کاربر
- جلوگیری از جستجوهای متعدد توسط کاربر درباره مفهوم
- خشنودی کاربر
- صرفه جویی در زمان

۸. نتیجه گیری

در این پژوهش ابتدا نگاهی کوتاه و گذرا بر توانایی ها، کارکردها و مشخصات فنی نرم افزار متن باز «دی اسپیس» انجام شد. «دی اسپیس» که سیستم مدیریتی اطلاعات و مستندات است،

پیاده‌سازی آن در سازمان‌ها به منظور پیاده‌سازی مدیریت دانش در آن سازمان است. با اجرای آن می‌توان چرخه ساده مدیریت دانش که شامل شناسایی و جمع‌آوری، ذخیره‌سازی و سازمان‌دهی، انتشار و به کارگیری اطلاعات است، را در سازمان پیاده کرد. در گام بعد با انجام فرایند داده‌کاوی بر روی پایگاه داده آن و با استفاده از دو ابزار داده‌کاوی «وِکا» و «منگیوم‌اپوس» برای استخراج دانش، این نرم‌افزار مجهز به توانایی داده‌کاوی گشته تا علاوه بر افزایش کارایی و توانایی‌های آن، افزایش سرعت جستجوی کاربر را در رسیدن به هدف و کاهش زمان صرف شده، داشته باشد. این نوشتار پژوهشی فناورانه است و بر لبۀ فناوری حرکت می‌کند و در گام پایانی، در ساختار طراحی فرایند جستجو در نرم‌افزار متن باز «دی اسپیس» نفوذ کرده‌است و این فرایند، در راستای جستجویی که از نتایج داده‌کاوی استفاده می‌کند، تغییر کرده و با این تغییر امکان جستجوی هوشمند در «دی اسپیس» فراهم شده‌است. همچنین در این پژوهش چهارچوب استاندارد داده‌کاوی بر روی پایگاه داده معرفی شده و تمامی مراحل آن بر روی مجموعه داده آزمایشی انجام شده‌است. برای ارزیابی پژوهش نیز تعداد رکوردهای بازیابی شده در «دی اسپیس» مجهز به توانایی داده‌کاوی، با تعداد رکوردهای بازیابی شده در «دی اسپیس»‌های بدون این توانایی مقایسه شده که در «دی اسپیس» تغییر داده شده تعداد رکوردهای بیشتر است و کاربر را سریع‌تر به هدف می‌رساند.

نتایج پژوهش که برای استخراج دانش از پایگاه داده «دی اسپیس» با استفاده از فنون داده‌کاوی به دست می‌آید، به شرح زیر است:

پیاده‌سازی سیستم مدیریت دانش «دی اسپیس» در سازمان و فرهنگ‌سازی آن، اجرای فرایند داده‌کاوی بر روی نمونه داده آزمایشی، طراحی و پیاده‌سازی توانایی جدید جستجوی هوشمند در «دی اسپیس» که پیامدهای این توانایی جدید شامل افزایش نتایج جستجوی کاربر، افزایش سرعت جستجوی کاربر، ارائه هوشمند کلمات مرتبط با کلمه ورودی کاربر، جلوگیری از جستجوهای متعدد توسط کاربر درباره مفهوم، خشنودی کاربر و صرفه‌جویی در زمان است.

۹. فهرست منابع

- ارسطوپور شعله. ۱۳۸۶. نرم افزار نظامی با کد منبع باز: نگاهی کوتاه به قابلیت‌ها و مأموریت‌های نظام یکپارچه کتابخانه‌ای کوها (KOHA). مجله الکترونیکی پژوهشگاه اطلاعات و مدارک علمی ایران. دوره هفتم شماره دوم اکبرپور شیرازی، محسن، و حسن توپچی. ۱۳۸۷. داده‌کاوی: مفاهیم، روش‌ها و کاربردها. تهران: دانشگاه خواجه نصیرالدین طوسی
- تقوی فرد محمد تقی، و طاها منصوری. ۱۳۸۶. داده‌کاوی و کاربرد آن در تصمیم‌گیری‌ها. مجله دانش مدیریت. دوره ۲۰ شماره ۷۹.
- شاه‌سمندی، پرستو. ۱۳۸۴. داده‌کاوی در مدیریت ارتباط با مشتری. ماهنامه علمی آموزشی تدبیر. سال شانزدهم شماره ۱۵۶.

شریف، عاطفه. ۱۳۸۶. نگاهی به یک نرم‌افزاری کتابخانه‌ای متن باز از دیدگاه یک کتابدار. مجله الکترونیکی پژوهش‌گاه اطلاعات و مدارک علمی ایران. دوره هفتم شماره اول
عطایی، شروان، و سید محمدزاده. ۱۳۸۶. کاوش پایگاه اطلاعات خطوط راه آهن
غلامیان، محمدرضا، و مریم خواجه‌فضلی. ۱۳۸۵. مدیریت دانش در ارتباط با مشتری. تدبیر شماره ۱۸۷.

- Dspace .2008. <http://www.dspace.org> .DSpace 1.5.1 Manual.
Erdmann Michael. 2001. The Data Warehouse as a Means to Support Knowledge Management.
Firestone Joseph. 1999. Knowledge Base Management Systems and TheKnowledge Warehouse.
Firestone Joseph et al. 2005. Doing Knowledge Management. Learning Organization Journal, Vol. 12.
Hahsler Michael. 2001. Knowledge Management Data Warehouses and Data Mining.
Han Jiawei and Kamber Micheline. 2006. Data Mining:Concepts and Techniques. publisher:
Elsevier.
Kerschberg Larry. 2000. Knowledge Management in Heterogeneous DataWarehouse Environments.
S.Gyorodi Robert. 2001.A Comparative Study of Iterative Algorithm in Association Rules Mining . Studies in Information and control, Vol.12, No.3.
Smith MacKenzie et al . 2003 . DSpace: An Open Source Dynamic Digital Repository. D-Lib Magazine. Volume 9 Number 1, ISSN 1082-9873
Witten.H and Lan. 2005. StoneD A Bridge between Greenstone and DSpace. D-Lib Magazine. volume11Number9 . ISSN 1082-9873
Ye N. 2003. The Handbook of Data Mining. Lawrence Erlbaum Association (LEA).

Knowledge Acquisition from Database of Information Management and Documentation Softwares by DataMining Techniques

Mehdi Fesharaki

Associate professor of Malek Ashtar Industrial University, Scientific Community of Malek Ashtar Industrial University of Tehran

Hossein shirazi

Associate professor of Malek Ashtar Industrial University, Scientific Community of Malek Ashtar Industrial University of Tehran

Akram Bakhshi*

Malek Ashtar Industrial University of Tehran



Iranian Research Institute
For Science and Technology
ISSN 1735-5206
eISSN 2008-5583
Indexed in LISA, SCOPUS & ISC
Vol.26 | No.2 | pp: 259-283
Winter 2011

Abstract: Using the high amount of data, not only isn't useful for the managers in deciding and decision making, but also will be so much problematic for the organization's managers. So it's very important and essential to manage the raw data, and changing the internal and external data to information and knowledge by using different techniques. One of the typical techniques is data mining, it can be used in databases to acquire the needed knowledge. Dspace is a software system of digital archive or a kind of repository for organizational information on the web, that will provide the possibility of saving, recovery and managing the organizational information. The purpose of this paper is to acquire information from the previous data and the history of user's researching in the database of Dspace by using data mining algorithms. By procuring the communications and dependencies of researches terms, it would be possible to use data mining for having intelligent research in Dspace software, so the efficiency of user's research will be increased. By using this idea, it would be prevented from multiple researching of every user for each concept; it would be effective for time reducing and helping users in finding the appropriate keywords of researching. So, by using a data mining based Dspace, the retrieved records will be more than the Dspace which hasn't this capability. Dspace, will make users more satisfied by helping the user in researching and preparing the intelligent ideas.

Keywords: data mining, Dspace, knowledge management, database, data management, information and document management.

* Corresponding Author: akram390@yahoo.com