

داده کاوی در R با استفاده از بسته Rattle

روح اله حسینی^۱، مجید سرمد^۲، مهدی جباری نوقایی^۳

چکیده

در این مقاله ضمن معرفی مختصری از مفاهیم، روش ها و الگوریتم های داده کاوی، داده کاوی در نرم افزار آماری R با استفاده از بسته Rattle ارائه می شود. بسته Rattle فضای گرافیکی مناسب را برای انجام برخی از روش ها و الگوریتم ها، بدون نیاز به برنامه نویسی فراهم می کند. برخی از بخش های این بسته ضمن مثال، شرح داده خواهد شد.

واژه های کلیدی: داده کاوی، خوشه بندی، درخت تصمیم، قواعد پیوند، ماشین بردار پشتیبان، R، Rattle.

۱ مقدمه

و دقیق دانش موجود در این داده ها بیش از پیش نمایان شده است. بنابراین نیاز به طراحی سیستم هایی که قادر به اکتشاف سریع اطلاعات مورد علاقه کاربران با تاکید بر حداقل مداخله انسانی باشند از یک طرف و روی آوردن به روش های تحلیل متناسب با حجم انبوه داده ها از سوی دیگر احساس می شود. رشد فزاینده تعداد روش های نوین ارائه شده برای استخراج اطلاعات از داده های خام موجب بوجود آمدن زمینه جدیدی از کاوش داده ها موسوم به داده کاوی^۴ شده است.

داده کاوی که در آغاز دهه ۹۰، با انجام تحقیقات در رشته های آمار، یادگیری ماشین، هوش مصنوعی، علوم رایانه و ...، پا به عرصه ظهور گذاشته، با نگرشی نو به مساله استخراج دانش از مجموعه عظیم داده ها می پردازد. اصطلاح داده کاوی نخستین بار توسط «فیاض»^۵ در اولین کنفرانس بین المللی «داده کاوی و کشف دانش»^۶ در سال ۱۹۹۵ مطرح گردید و هم زمان با آن داده کاوی به طور جدی وارد مباحث آمار شد. با وجود این که داده کاوی یک رشته جدید علمی است، امروزه کاربردهای

اطلاعات در جهان امروز به عنوان یکی از عوامل تولیدی مهم محسوب می شود. داده ها نمایی از واقعیت ها، معلومات، مفاهیم، رویدادها یا پدیده ها برای برقراری ارتباط، تفسیر یا پردازش، توسط انسان یا ماشین هستند. از سال ۱۹۵۰ با به کارگیری رایانه، در تحلیل و ذخیره سازی داده ها، حجم اطلاعات ذخیره شده پس از حدود ۲۰ سال دو برابر شده است. هم زمان با پیشرفت فناوری اطلاعات (IT)، هر دو سال یکبار حجم داده ها در پایگاه داده ها، دو برابر می شود. امروزه نیز با وجود شبکه جهانی وب، سیستم های یکپارچه بانکی، سیستم های یکپارچه اطلاعاتی و ... هر لحظه حجم داده ها در پایگاه داده ها افزایش یافته و باعث به وجود آمدن انبارهای عظیمی از داده ها شده است. با توجه به شدت رقابت ها در عرصه های علمی، اجتماعی، اقتصادی، سیاسی و نظامی در بین کشورها، موسسات و شرکت ها، ضرورت کشف و استخراج سریع

^۱ کارشناس ارشد، دانشگاه فردوسی مشهد

^۲ عضو هیأت علمی گروه آمار دانشگاه فردوسی مشهد

^۳ عضو هیأت علمی گروه آمار دانشگاه فردوسی مشهد

^۴ Data mining

^۵ Fayyad

^۶ Knowledge Discovery and Data mining

داده‌های مشاهده‌ای که اغلب از منابع مختلفی گردآوری شده‌اند، سروکار دارند و اغلب با اهداف ابتدایی که داده‌ها به‌خاطر آن جمع‌آوری شده‌اند، رابطه‌ای ندارند. در داده کاوی با انواع مختلفی از داده‌ها از جمله داده‌های عددی، متنی، رشته‌ای، دودویی، تاریخ و عکس سروکار داریم.

۲ داده کاوی

نگاهی به ترجمه لغوی داده کاوی، به ما در درک بهتر این واژه کمک می‌کند. واژه لاتین Mine به معنای استخراج از منابع نهفته و با ارزش زمین اطلاق می‌شود. ادغام این واژه با Data بر جستجوی عمیق از داده‌های قابل دسترس با حجم زیاد برای یافتن اطلاعات مفید که قبلاً نهفته بودند، تأکید دارند.

داده کاوی دارای تعاریف مختلفی است، این تعاریف به مقدار زیادی به پیش زمینه‌ها و نقطه نظرهای افراد بستگی دارد. هر نویسنده و محقق با توجه به دیدگاه و نوع نگرش خود تعریفی برای داده کاوی ارائه کرده است که برخی از آنها به صورت زیر است:

۱. داده کاوی فرآیند شناخت الگوهای معتبر، جدید، ذاتاً مفید و قابل فهم از داده‌ها است. [۲]

۲. فرآیند کشف الگوهای مفید از داده‌ها را داده کاوی گویند. [۳]

۳. داده کاوی، مجموعه‌ای از روش‌ها در فرآیند کشف دانش است که برای تشخیص الگوها و رابطه‌های نامعلوم در داده‌ها مورد استفاده قرار می‌گیرد. [۴]

۱.۲ آمار و داده کاوی

غالباً در آمار نیاز به فرضیه آماری داریم ولی در داده کاوی بدون داشتن فرضیه اولیه به تحلیل و کاوش در داده‌ها می‌پردازیم. روابط در داده کاوی معمولاً به صورت الگوها و مدل‌هایی از قبیل معادلات رگرسیونی، سری‌های زمانی، خوشه‌ها، رده‌بندی‌ها و گراف‌ها ارائه می‌شوند. در داده کاوی نیز همانند آمار غالباً داده‌هایی که تحلیل می‌شوند، نمونه‌ای از جامعه هستند که با توجه به حجم بزرگ جامعه با نمونه‌ای بزرگ مواجه هستیم. یک تفاوت در نوع داده‌ها است، آماردان‌ها با داده‌های دست اول که برای تحقیق درستی فرضیه‌های از پیش تعیین شده جمع‌آوری و تولید شده‌اند، مواجه هستند، اما داده کاوها با تحلیل داده‌های دست دوم^۷ و یا

۲.۲ بیان دیدگاه‌ها

در متون مربوط به داده کاوی دو تعبیر مختلف از داده کاوی وجود دارد: برخی از جمله فیاض (۱۹۹۵) به داده کاوی به عنوان یک مرحله ضروری از فرآیند بزرگ‌تر «کشف دانش و شناخت از پایگاه داده‌ها»^۸ (KDD) می‌نگرند. برخی دیگر مانند چتفیلد (۱۹۹۵) داده کاوی را مترادف عبارت کشف دانش و شناخت از پایگاه داده‌ها می‌دانند. فرآیند KDD شامل مراحل زیر است:

۱. شناسایی و تعریف مساله

۲. دستیابی و پیش‌پردازش داده‌ها

• پاک‌سازی داده‌ها

• یک‌پارچه‌سازی داده‌ها

• تبدیل داده‌ها

• تلخیص داده‌ها

۳. داده کاوی

۴. ارزیابی الگوها

۵. ارائه دانش

۳.۲ روش‌های داده کاوی

روش‌های داده کاوی به دو دسته توصیفی و پیش‌بینانه تقسیم‌بندی می‌شوند. روش‌های توصیفی خواص عمومی داده‌ها را آشکار می‌کنند. هدف از توصیف، یافتن الگوهایی از داده‌هاست که برای انسان قابل تفسیر باشد. وظایف پیش‌بینانه به منظور پیش‌بینی رفتارهای آینده آن‌ها استفاده می‌شوند. منظور از پیش‌بینی به کارگیری چند متغیر برای پیش‌بینی مقادیر آینده یا ناشناخته سایر متغیرهای مورد علاقه است.

⁷Secondary Data Analysis

⁸Knowledge Discovery and Data Mining

۴.۲ الگوریتم‌ها و تکنیک‌های داده‌کاوی

الگوریتم‌ها و روش‌های داده‌کاوی راه‌های اجرا کردن عملیات‌های داده‌کاوی هستند. در بین الگوریتم‌های یاد شده بهترین به معنای مطلق وجود ندارد و لذا ابزار یا ابزارهایی انتخاب شده و مدل مناسب باید با توجه به داده‌ها و کارایی مورد نظر طراحی و اجرا شود. برخی از مهم‌ترین الگوریتم‌های داده‌کاوی عبارت از:

- خوشه‌بندی^۹

- قواعد پیوند^{۱۰}

- درخت‌های تصمیم

- روش‌های رگرسیونی

- شبکه عصبی مصنوعی

- ماشین بردار پشتیبان^{۱۱}

- الگوریتم ژنتیک

هستند.

باتوجه به نظرسنجی انجام شده از داده‌کاوان در سایت www.KDnuggets.com الگوریتم‌های درخت‌های تصمیم، رگرسیون و خوشه‌بندی در سال‌های ۲۰۱۰ و ۲۰۱۱ بیش از سایر الگوریتم‌ها مورد استفاده قرار گرفته‌اند.

۵.۲ نرم‌افزارهای داده‌کاوی

امروزه نرم‌افزارهای مختلفی با قابلیت انجام تحلیل‌های داده‌کاوی وجود دارد. بیشتر سیستم‌های نرم‌افزاری فقط جهت انجام روش‌های خاصی مناسب هستند و قابلیت انجام روش‌های دیگر را ندارند. برخی از نرم‌افزارهای آماری که قابلیت داده‌کاوی دارند عبارت از:

- R (Rattle package)
- SPSS Clementine
- SAS Enterprise Miner

• Rapid Miner

هستند. در سال‌های ۲۰۱۰ و ۲۰۱۱ نرم‌افزارهای Rapid Miner و R به دلیل منبع باز بودن، رایگان بودن، فضای گرافیکی مناسب و همچنین قابلیت‌های دیگر بیش از سایر نرم‌افزارها مورد استفاده داده‌کاوها قرار گرفته‌اند.

۳ داده‌کاوی در R با استفاده از Rattle

همان‌گونه که اشاره شد، در بین نرم‌افزارهایی که قابلیت داده‌کاوی دارند نرم‌افزار آماری R مورد توجه داده‌کاوها قرار گرفته است. برخی از دلایل این رویکرد عبارت از:

۱. رایگان بودن و کد باز بودن (Open Source)

۲. قابلیت نصب روی اکثر سیستم‌های عامل از جمله نسخه‌های مختلف لینوکس، ویندوز، مکینتاش و یونیکس

۳. سرعت در دست‌یابی به تکنیک‌های جدید در قالب کتابخانه‌ها و توابع آماده

۴. قابلیت اضافه کردن و نوشتن برنامه‌های جدید به صورت بسته‌های جدید در R

۵. دارا بودن قابلیت‌های قابل ملاحظه گرافیکی


است. در نرم‌افزار R چندین بسته برای داده‌کاوی وجود دارد که می‌توان با توجه به الگوریتم مورد استفاده برای داده‌کاوی از آنها استفاده کرد. اما یکی از بهترین بسته‌ها که مجموعه‌ای از الگوریتم‌ها و توابع را در کنار هم جمع کرده تا بتوان از آنها برای داده‌کاوی استفاده کرد بسته Rattle است. این بسته علاوه بر اینکه شامل مجموعه‌ای از الگوریتم‌ها و روش‌های داده‌کاوی است کاربر را از برنامه‌نویسی و دستورنویسی به زبان R بی‌نیاز می‌کند و این امکان را فراهم می‌کند که کاربر با چند کلیک ساده و انتخاب روش مورد نیاز برای داده‌کاوی به خواسته خود برسد.

^۹Clustering

^{۱۰}Association Rules

^{۱۱}Support Vector Machine

۱۰.۳ معرفی Rattle



شکل ۱: محیط گرافیکی Rattle

به طور کلی روند اجرای یک پروژه داده کاوی در Rattle را می توان به شرح زیر خلاصه کرد:

۱. بارگذاری یک مجموعه داده و انتخاب متغیرها
۲. کاوش کردن در داده ها برای شناخت توزیع های آنها
۳. آزمون کردن توزیع ها و پراکندگی ها
۴. تبدیل داده ها برای انطباق با مدل انتخاب شده برای داده کاوی
۵. ساخت مدل یا مدل ها
۶. ارزیابی مدل ها
۷. بازنگری مراحل و روش های داده کاوی

۲۰.۳ داده ها در Rattle

Rattle قابلیت فراخوانی داده ها را از منابع گوناگونی دارد که قالب پیش فرض آن (Comma Separated Values) CSV است. از جمله قالب های دیگری که Rattle قابلیت فراخوانی آنها را دارد می توان به موارد زیر اشاره کرد:

TXT (tab separated data), ARFF (a common data mining dataset format which adds type information to a CSV file)

با نصب بسته ODBC در R و استفاده از زیربخش ODBC بخش Data در Rattle اجازه دستیابی به بسیاری از منابع داده از جمله:

همان گونه که بیان شد برای انجام داده کاوی در نرم افزار R می توان از ابزاری به نام Rattle که مخفف عبارت R Analytical Tool To Learn Easily است استفاده کرد. این ابزار گرافیکی داده کاوی نوشته شده در R، گذرگاهی به R محسوب می شود. این برنامه برای انجام محاسبات داده کاوی ساده تا تحلیل های پیچیده بر روی داده ها به کمک یک زبان بسیار قدرتمند آماری، طراحی شده است. Rattle به همراه خود انبوهی از بسته های R مورد نیاز برای یک داده کاو را فراهم می آورد. در این محیط هرگاه به بسته ای نیاز باشد پیغام نصب این بسته ظاهر می شود که در صورت اتصال به اینترنت با انتخاب گزینه Yes در پیغام ظاهر شده این بسته نصب می شود. برای استفاده از Rattle نیاز به شناخت و آشنایی با R وجود ندارد.

برای نصب Rattle کتابخانه های Gnom و Glade مورد نیاز است. با فرض اینکه R و کتابخانه های فوق در R نصب شده باشند برای استفاده از محیط Rattle باید بسته های RGtk2 و Rattle را در R نصب و فراخوانی کرد. با وارد کردن دستورات زیر در R می توان این دو بسته را نصب و بسته Rattle را فراخوانی کرد.


```
> install.packages("RGtk2")
> install.packages("rattle")
> library(rattle)
```

آخرین نسخه توسعه یافته Rattle را می توان با استفاده از دستور زیر در R نصب کرد:


```
> install.packages("rattle", repos="http://
cran.um.ac.ir")
```

برای باز کردن محیط Rattle با وارد کردن دستور `rattle()` در R پنجره جدیدی مشابه شکل ۱ باز می شود. همان طور که ملاحظه می شود پنجره باز شده به فرم منویی بوده و دارای نوار عنوان، نوار ابزار و بخش خروجی نتایج است.

همچنین برای استفاده از فضای گرافیکی GGobi باید بسته rggobi را در R نصب کرد. بعلاوه باید نرم افزار GGobi را در سیستم نصب کرد این نرم افزار را می توان از <http://www.ggobi.org/> دانلود کرد. این فضاهای گرافیکی برای کاوش کردن در داده ها با ابعاد بالا همچنین نمایش انواع نمودارها و توزیع ها بصورت محاوره ای مناسب هستند. نمودار پراکندگی چند متغیر از مجموعه داده هواشناسی را در این دو محیط گرافیکی رسم کرده ایم که به صورت شکل های ۳، ۴ و ۵ هستند.




شکل ۳: محیط گرافیکی latticist



شکل ۴: محیط گرافیکی GGobi

MySQL, SQLite, Postgress, MS/Excel, MS/Access, SQL Server, Oracle, IBM DB2

را داریم. Rattle همچنین اجازه دستیابی و استفاده از مجموعه داده های بسته های نصب شده در R و مجموعه داده های استفاده شده و فراخوانی شده در محیط R را نیز به کاربر می دهد. بسته Rattle دارای یکی از این مجموعه داده ها بنام weather.csv شامل ۳۶۶ مشاهده با ۲۴ متغیر از داده های هواشناسی است. یک راه ساده برای فراخوانی این مجموعه داده در Rattle کلیک بر روی Execute و انتخاب Yes در پیغام ظاهر شده است. با انجام این کار نام متغیرهای این مجموعه داده همراه با نقش هریک از متغیرها، که Rattle بطور پیش فرض با توجه به نوع متغیر در نظر گرفته است، در پنجره خروجی Rattle نمایش داده می شود (شکل ۲).



شکل ۲: فراخوانی مجموعه داده هواشناسی در Rattle

۳.۳ کاوش در داده ها (Explore)

گاهی با بررسی داده ها و تحلیل کاوشگرانه آنها می توان به اطلاعات و دانش جدید در مورد داده ها دست یافت. بخش Explore در منوی Rattle بسیاری از ابزارهای عددی و گرافیکی را برای بدست آوردن آماره های توصیفی، انواع نمودارها و توزیع ها، همبستگی بین متغیرها و مشاهدات، مولفه های اصلی و ... را فراهم می کند. با انتخاب زیربخش interactive می توان با استفاده از گزینه های Latticist، GGobi و Plot Builder نمودارها و توزیع های آماری را در هر کدام از فضاهای گرافیکی موجود به نمایش درآورد. برای استفاده از فضای گرافیکی Latticist باید بسته های latticist و playwith را در R نصب کرد.

هنگامی که داده‌های مورد نیاز انتخاب شدند و داده‌های مورد کاوش مشخص گردیدند، معمولاً به تبدیلات خاصی روی داده‌ها نیاز است. نوع تبدیل به عملیات و تکنیک داده‌کاوی مورد استفاده بستگی دارد. تبدیلات ساده‌ای همچون تبدیل نوع داده‌ای به نوع دیگر تا تبدیلات پیچیده‌تر همچون تعریف صفات جدید با انجام عملیات‌های ریاضی و منطقی روی صفات موجود. بسیاری از این تبدیلات در بخش Transform بسته Rattle گنجانده شده است. تبدیلاتی همچون تغییر مقیاس، تبدیل داده‌های کمی به کیفی، جایگذاری مقادیر گمشده (با صفر، میانگین مشاهدات، میانه، مد و یا یک مقدار ثابت)، حذف مقادیر (گمشده، پرت، موارد انتخاب شده توسط کاربر) و برخی دیگر را می‌توان انجام داد.

۶.۳ تحلیل خوشه‌ای

همان‌گونه که بیان شد روش‌های داده‌کاوی به دو دسته توصیفی و پیش‌بینانه تقسیم می‌شوند. تحلیل خوشه‌ای^{۱۲} یکی از روش‌های داده‌کاوی توصیفی است. در تحلیل خوشه‌ای تلاش می‌شود تا مشاهدات به k خوشه مختلف گروه‌بندی شوند، به طوریکه مشاهداتی که در یک خوشه قرار می‌گیرند به یکدیگر شبیه باشند و مشاهدات خوشه‌های مختلف با یکدیگر بیشترین تفاوت را داشته باشند. می‌توان گفت در تحلیل خوشه‌ای سه موضوع مورد توجه است؛ اولین موضوع تعداد خوشه‌ها است، چه تعداد خوشه می‌تواند دانش نهفته در داده‌ها را کشف کند. دومین نکته آن چیزی است که با نام شباهت^{۱۳} و یا فاصله^{۱۴} از آن یاد می‌شود. اینکه چه هنگام دو مشاهده به یکدیگر شبیه هستند و چه هنگام با یکدیگر تفاوت دارند و در نهایت پس از آن که تعداد خوشه‌ها و معیار شباهت داده‌ها مشخص شد باید با استفاده از روش‌های مختلف، که با نام روش‌های خوشه‌بندی^{۱۵} از آن‌ها یاد می‌شود، مشاهدات را در خوشه‌های معین قرار داد. کیفیت در خوشه‌بندی با این معیار تعریف می‌شود که مشاهدات هر خوشه بیشترین شباهت را به یکدیگر داشته و از کمترین شباهت با خوشه‌های دیگر برخوردار باشند.

¹²Cluster analysis


¹³Similarity

¹⁴Distance

¹⁵Clustering

¹⁶Crisp or hard

¹⁷Fuzzy



شکل ۵: محیط گرافیکی GGobi

۴.۳ آزمون‌های آماری

بخش Test در Rattle امکان دستیابی و اجرای بسیاری از آزمون‌های آماری پارامتری و ناپارامتری از توزیع‌ها را برای داده‌ها فراهم می‌کند. این ویژگی به تازگی به Rattle افزوده شده است و در حال تکمیل شدن است. با استفاده از این بخش آزمون‌های Kolmogorov-Smirnov، Wilcoxon Signed، F-test، T-test، Wilcoxon Rank-Sum Rank و Pearson's correlation را می‌توان برای داده‌ها و توزیع داده‌ها انجام داد.

۵.۳ تبدیل داده‌ها


آماده‌سازی داده‌ها برای داده‌کاوی هنر فشردن داده‌های موجود و استخراج داده‌های با ارزش است. در حالی که داده‌کاوی هنر کشف الگوهای معنی‌دار در داده‌ها است. معناداری الگو بستگی به مساله دارد. آماده‌سازی نیز به عنوان جزئی از داده‌کاوی بستگی به نوع مساله و نیز روش‌ها و ابزارهایی دارد که می‌خواهیم بر روی داده‌ها به کار ببندیم. به عنوان مثال شبکه عصبی نیازمند ارائه داده‌هایی است که حداقل عددی یا ترتیبی باشند و به داده‌های گمشده بسیار حساس است. درخت‌های تصمیم‌گیری اغلب بر روی داده‌های طبقه‌ای کار می‌کنند.

میانگین خوشه، می‌توان از مدوید (مشاهده‌ای که در مرکزی‌ترین مکان خوشه قرار دارد) خوشه استفاده کرد. تفاوت میانگین با مدوید در این است که میانگین داده‌ها ممکن است وجود خارجی نداشته باشد، در صورتی که مدوید وجود خارجی دارد یعنی یکی از مشاهدات مجموعه داده است.

در Rattle با انتخاب بخش Cluster می‌توان به برخی از این روش‌ها از جمله روش k- میانگین، روش سلسله مراتبی ادغامی، روش BiCluster و Ewkm دسترسی پیدا کرد.

درختی که خوشه‌بندی سلسله مراتبی را نشان می‌دهد دندروگرام^{۲۴} نامیده می‌شود که از رده‌بندی جانداران برگرفته شده است. در Rattle این امکان وجود دارد که دندروگرام و همچنین نمودارهای تشخیصی^{۲۵} و نمودار پراکندگی داده‌ها و نیز نمودار پراکندگی مشاهدات در خوشه‌ها را ترسیم نماییم. به عنوان مثال برای داده‌های هواشناسی بیان شده، خوشه‌بندی را به روش سلسله مراتبی با معیار فاصله اقلیدسی انجام داده و مشاهدات را در ۱۰ خوشه، خوشه‌بندی نموده‌ایم که دندروگرام و نمودار تشخیصی آن به صورت شکل‌های ۶ و ۷ هستند.

Cluster Dendrogram weather.csv



Rattle 2012-Oct-09 10:56:59 Bahram

شکل ۶: دندروگرام برای مجموعه داده هواشناسی

به طور کلی روش‌های خوشه‌بندی به دو دسته کلی قطعی^{۱۶} و فازی^{۱۷} تقسیم‌بندی می‌شوند. روش‌های قطعی نیز خود به دو نوع افزایشی^{۱۸} و سلسله مراتبی^{۱۹} تقسیم می‌شوند. روش‌های سلسله مراتبی نیز به دو نوع تجزیه‌ای یا تقسیمی^{۲۰} و تجمیعی^{۲۱} تقسیم می‌شود.

در خوشه‌بندی قطعی هر مشاهده تنها در یک خوشه می‌تواند قرار بگیرد ولی در خوشه‌بندی فازی هر مشاهده با یک درجه عضویتی، بین صفر و یک برای هر خوشه، می‌تواند در چندین خوشه قرار بگیرد. در روش‌های خوشه‌بندی افزایشی تعداد خوشه‌ها از قبل مشخص است. هدف تعیین کردن این است که هر مشاهده در کدام خوشه جای می‌گیرد. این روش‌ها برای مسائلی که تعداد متغیرها و یا تعداد مشاهدات و یا هر دو زیاد باشند مناسب هستند. در این روش‌ها به دنبال تعریف تابع خطا و حداقل کردن آن هستیم. در روش‌های ادغامی نخست هر مشاهده به صورت یک خوشه مستقل در نظر گرفته می‌شود، سپس در فرآیند خوشه‌بندی خوشه‌ها با هم ادغام می‌شوند تا به خوشه یکتایی برسیم. در روش‌های تجزیه‌ای کار برعکس است، ابتدا تمامی مشاهدات یک خوشه در نظر گرفته می‌شود و در فرآیند خوشه‌بندی، خوشه‌ها را به چند خوشه تجزیه می‌کنیم.

یکی از معروفترین و پرکاربردترین روش‌های افزایشی روش k- میانگین^{۲۲} است که نخستین بار توسط مک کوئین (۱۹۶۷) ارائه شد. این روش برای خوشه‌بندی داده‌های با مقادیر کمی طراحی شده است. هر خوشه دارای مرکزی بنام میانگین است. در ابتدا داده‌ها به صورت تصادفی به k خوشه تقسیم می‌شوند. در مرحله بعد، فاصله هر یک از داده‌ها از مرکز خوشه خود، که همان میانگین مشاهدات هر خوشه است، محاسبه می‌شود. در صورتی که فاصله مشاهده مورد نظر از میانگین خوشه خود زیاد و به خوشه دیگری نزدیکتر باشد، این مشاهده به خوشه‌ای که نزدیکتر است اختصاص می‌یابد. این کار تا حداقل شدن تابع خطا، که معمولاً مجموع فواصل مشاهدات از مرکز خوشه خودش است، و یا تغییر نیافتن اعضای خوشه‌ها ادامه می‌یابد.

روش دیگر روش k- مدوید^{۲۳} است. در این روش به جای استفاده از


¹⁸Partitional¹⁹Hierarchical²⁰divisive²¹agglomerative²²k-means²³k-medoids²⁴Dendrogram²⁵Discriminant plot

پشتیبانی برخوردار بوده و به اندازه کافی به آنها اعتماد داشته باشیم. فرض کنید $J = (i_1, i_2, \dots, i_n)$ یک مجموعه از عناصر مجزا باشد (مانند نام کالاهای مختلف یک فروشگاه)، D را مجموعه‌ای از تراکنش‌های پایگاه داده‌ای فرض کنید و T تراکنشی که زیر مجموعه‌ای از J است. اگر $A \subseteq T$ باشد آنگاه T شامل A خواهد بود. اگر $A \subset J$ ، $B \subset J$ و $A \cap B = \emptyset$ آنگاه $A \Rightarrow B$ یک قاعده پیوند است. پشتیبان این قاعده، که با نماد s نشان می‌دهیم، در D بصورت درصد تراکنش‌هایی تعریف می‌شود که $A \cup B$ را شامل شوند که آن را می‌توان معادل احتمال اجتماع A و B دانست، یعنی $P(A \cup B)$. C میزان اطمینان به این قاعده را به صورت درصد تراکنش‌هایی در D که علاوه بر شمول A ، B را نیز شامل شوند تعریف می‌کنیم و معادل احتمال وقوع B است به شرط وقوع A یعنی $P(B | A)$.

اگر یک قاعده پیوند حداقل پشتیبانی لازم را داشته باشد مکرر^{۲۷} خوانده می‌شود. به قواعدی که هم حداقل پشتیبانی را داشته و هم به میزان خاصی به آن‌ها اعتماد داشته باشیم قواعد قوی^{۲۸} گفته می‌شود. به طور معمول مقادیر کمینه‌ای برای میزان پشتیبانی و اطمینان، مشخص می‌شود و فقط قواعدی مورد تأیید قرار می‌گیرند که میزان پشتیبانی و اطمینان آن‌ها از این مقدار آستانه بیشتر باشد. تحلیل‌گران قواعدی را ترجیح می‌دهند که یا میزان اطمینان و یا میزان پشتیبانی و یا هر دو آن‌ها بالا باشند.

یکی از معروفترین الگوریتم‌های مورد استفاده در قواعد پیوند، الگوریتم Apriori است. به طور خلاصه می‌توان گفت الگوریتم Apriori برای پیدا کردن مجموعه وقایع مکرر، چندین گذر را بر روی مشاهده‌ها انجام می‌دهد. در k -امین گذر، این الگوریتم همه مجموعه وقایع دارای k عنصر را پیدا می‌کند. در Rattle این الگوریتم و الگوریتم سبد خرید^{۲۹} در بخش Associate گنجانده شده است. برای استفاده از این الگوریتم‌ها در Rattle باید میزان پشتیبانی و اطمینان را مشخص کرد که بصورت پیش فرض مقادیر 0/1 در نظر گرفته شده است. در Rattle بصورت پیش فرض الگوریتم Apriori مورد استفاده قرار می‌گیرد و برای استفاده از روش سبد خرید باید گزینه Baskets را در بخش Associate انتخاب نمود.

Discriminant Coordinates weather.csv



شکل ۷: نمودار تشخیصی برای مجموعه داده هواشناسی

۷.۳ قواعد پیوند

یکی از وظایف مهم داده کاوی، کاوش در پایگاه‌های داده زمانی به منظور استخراج اطلاعات و الگو از آن‌ها است. برای این منظور رویکردهای مختلفی پیشنهاد شده است که از جمله آن‌ها می‌توان به تحلیل سری‌های زمانی، قواعد پیوند و دنباله کاوی^{۲۶} یا تحلیل توالی اشاره نمود. از میان این روش‌ها، قواعد پیوند به بیان الگوهای موجود در یک سری از وقایع می‌پردازد، بدین ترتیب که بیان می‌کند، اگر بعضی از وقایع رخ دهند، آن‌گاه وقایعی دیگر نیز رخ خواهد داد. به عبارتی دیگر، این قوانین وابستگی‌ها را در حجم انبوهی از داده‌ها بیان می‌کنند.

عبارت $X \Rightarrow Y$ را در نظر بگیرید. به عنوان مثال فرض می‌کنیم عبارت X آنگاه Y بدین معنی باشد که هرگاه خریداری محصول X را بخرد، محصول Y را نیز خواهد خرید. اگر ۹۰٪ خریداران هنگامی که X را می‌خرند Y را نیز بخرند، ۹۰٪ به این قاعده اطمینان خواهیم داشت. اما این کافی نیست چون باید برای اطمینان بیشتر یک میزان تکرار مشخصی را از این قانون مشاهده کنیم. آنچه این قاعده را پشتیبانی می‌کند درصد خریدهایی است که هر دوی این محصول را با یکدیگر شامل شود. حال اگر $X \Rightarrow Y$ را یک قاعده‌ی پیوند بنامیم، مساله قواعد پیوند در اصل پیدا کردن قواعدی است که از یک حداقل

²⁶sequence mining²⁷Frequent²⁸Strong²⁹Baskets

۸.۳ مدل‌یابی برای پیشگویی

بر اساس آزمون‌های معنی‌داری تعیین کند. معیار انشعاب در این الگوریتم مقدار P-value برای آزمون Chi-square می‌باشد.

CART یک درخت تصمیم دو-دویی است که گوناگونی را به عنوان معیار انشعاب قرار می‌دهد و برای این کار از معیار شاخص جینی و یا شاخص آنتروپی استفاده می‌کند. این روش درخت را با کمینه‌سازی خطای تخمینی رده‌بندی نادرست، هرس می‌نماید. این روش برای متغیرهای رده‌ای و پیوسته کاربرد دارد.

C4.5 گونه توسعه یافته یک الگوریتم درخت تصمیم معروف به نام ID3 است. معیار انشعاب در الگوریتم C4.5، نسبت gain است که نسبت اطلاعات تولید شده با هر انشعاب را نشان می‌دهد. هرس نمودن این درخت بر اساس معیار خطا است.

به طور کلی هدف الگوریتم‌های درخت تصمیم، بیشینه‌سازی فاصله بین رده‌ها است. اختلاف این الگوریتم‌ها در معیارهای مختلف فاصله‌ای، روش‌های هرس کردن، وضعیت داده‌های گمشده، تعداد شاخه‌ها در هر گره و نوع داده‌هایی است که با آن سر و کار دارند. می‌توان به طور خلاصه برخی از ویژگی‌های درخت تصمیم را به صورت زیر بیان کرد:

- برای تقریب توابع گسسته بکار می‌رود
- برای داده‌های با حجم بالا کاراست، از این رو در داده‌کاوی استفاده می‌شود.
- می‌توان درخت را به صورت قوانین «اگر-آنگاه» نمایش داد که قابل فهم برای کاربر است.
- امکان ترکیب عطفی و فصلی فرضیه‌ها را می‌دهد.
- نسبت به داده‌های پرت مقاوم است.

در بخش Model با انتخاب گزینه Tree می‌توان برخی از الگوریتم‌های درخت تصمیم را انجام داد. با انتخاب گزینه Traditional می‌توان الگوریتم‌های CART، ID3 و C4.5 را انجام داد. برای این منظور باید مقادیر تعداد انشعاب، عمق درخت، و میزان پیچیدگی را مشخص کرد که نرم‌افزار به صورت پیش‌فرض، مقادیری را برای هر یک در نظر گرفته است. در اینجا، برای داده‌های هواشناسی این کار انجام شده است که درخت تصمیم آن به صورت شکل ۸ است.

رده‌بندی در دسته وظایف پیش‌بینانه داده‌کاوی قرار می‌گیرد و عبارت است از به کارگیری تعدادی متغیر برای پیش‌بینی مقادیر ناشناخته سایر متغیرها. در این فرآیند داده‌ها به دو دسته آموزش و آزمایش تقسیم می‌شوند، داده‌های آموزش برای یادگیری مدل متغیر پیش‌بینی شونده به کار می‌رود و داده‌های آزمایش برای تعیین صحت مدل به کار می‌رود. رده‌بندی از یک تابع یا مدل نتیجه می‌شود که برچسب رده یک مشاهده را بر اساس ویژگی‌هایش مشخص می‌کند.

بخش Model در Rattle شامل بسیاری از روش‌ها و الگوریتم‌های داده‌کاوی برای مدل‌سازی و رده‌بندی مجموعه داده‌ها است. روش‌هایی چون درخت تصمیم، انواع رگرسیون (خطی، لجستیک، پروبیت، چندگانه)، ماشین بردار پشتیبان، شبکه عصبی، Forest و boost را می‌توان با استفاده از این بخش انجام داد.

۱.۸.۳ درخت تصمیم

درخت تصمیم یک روش داده‌کاوی است که غالباً برای رده‌بندی و پیش‌بینی به کار می‌رود. یکی از مزایای درخت تصمیم در رده‌بندی داده‌ها نسبت به سایر روش‌های رده‌بندی مانند شبکه عصبی، سادگی تفسیر و فهم برای تصمیم‌گیرندگان جهت مقایسه نتایج با دانش حوزه خودشان و تعیین اعتبار و تعدیل تصمیماتشان است. علاوه بر این، درخت‌های تصمیم می‌توانند داده‌های مختلفی را تحلیل کنند بدون این‌که به فرضیاتی در مورد توزیع داده‌ها نیاز باشد.

درخت تصمیم در ساختار درختی با شاخه و برگ ارائه می‌شود. ساختار سلسله‌مراتبی درخت می‌تواند سطوح مختلف فاکتورها را تحلیل کند. هر برگ نشان‌دهنده نتیجه رده‌بندی، و هر شاخه نشانگر شرایط متغیرها است. با داشتن یک مجموعه آموزشی، شامل متغیرهای ورودی و یک متغیر خروجی، می‌توان یک درخت تصمیم ایجاد کرد، این مسأله به نوع استراتژی به کار گرفته شده برای یادگیری بستگی دارد. از جمله الگوریتم‌هایی که برای ایجاد درخت تصمیم توسعه یافته‌اند می‌توان به CART^{۳۰}، CHAID^{۳۱}، ID3، C4.5 اشاره کرد.

CHAID یک درخت تصمیم غیر دو-دویی است که به طور خاص برای متغیرهای رده‌ای طراحی شده و می‌تواند بهترین رده‌بندی داده‌ها را

³⁰Classification and regression tree

³¹Chi-squared automatic interaction detection

است که شماره آن‌ها به صورت اعداد رنگی در شکل ۸ نشان داده شده است. در هر گره تعداد مشاهداتی که متغیر هدف برای آن‌ها یکی از دو مقدار (Yes, No) را دارند مشخص شده است. همچنین به صورت درصد فراوانی نیز نشان داده شده است. معیار انشعاب در این درخت شاخص جینی است.


درخت ایجاد شده با روش CHAID معیار انشعاب در این درخت بر اساس مقدار P-Value برای آزمون Chi-square است. این درخت دارای ۱۱ گره می باشد. در انتهای هر شاخه میزان فراوانی هر یک از مقادیر متغیر هدف به صورت نمودار ستونی نشان داده شده است.

۲.۸.۳ ماشین بردار پشتیبان

ماشین بردار پشتیبان (SVM) یکی دیگر از روش‌های رده‌بندی داده‌هاست که بر پایه مفهوم صفحات تصمیم که مرز تصمیم را تعریف می‌کنند، بنا شده است. یک صفحه تصمیم داده‌های با برجسب رده مختلف را از هم تفکیک می‌کند. در برخی مواقع، به ساختارهای غیرخطی برای جداسازی بهینه مشاهدات نیاز است. فلسفه‌ای که در SVM وجود دارد این است که زمانی که برای تفکیک داده‌ها به ساختارهای پیچیده و غیرخطی صفحه تصمیم نیاز است، داده‌های اصلی با به کارگیری مجموعه‌ای از توابع ریاضی که کرنل^{۳۲} نام دارند، در فضای جدیدی نگاشت داده می‌شوند. در فضای جدید، داده‌های نگاشت‌شده به صورت خطی قابل تفکیک هستند. بنابراین به جای ساختن یک منحنی پیچیده جداساز، باید به دنبال یک خط بهینه جداساز باشیم. مسأله یادگیری SVM می‌تواند به صورت یک مسأله بهینه‌سازی محدب فرمول‌بندی شود.

الگوریتم‌های مبتنی بر ماشین‌های بردار پشتیبان الگوریتم‌هایی هستند که سعی می‌کنند یک حاشیه^{۳۳} را بیشینه کنند. این الگوریتم‌ها، در فضای دو بعدی، برای پیدا کردن خط جدا کننده رده‌ها، از دو خط موازی شروع کرده، این خطوط را در خلاف جهت یکدیگر حرکت می‌دهند تا هر کدام از خطوط به یک مشاهده از یک رده خاص برسد. پس از انجام این مرحله، میان دو خط موازی یک نوار یا حاشیه شکل می‌گیرد. هر چه پهنای این نوار بیشتر باشد، به این معنا است که الگوریتم توانسته است هدف بیشینه‌سازی حاشیه را محقق سازد. در مرکز حاشیه، خط


Decision Tree weather.csv \$ RainTomorrow



Rattle 2012-Dec-10 11:19:44 Bahram

شکل ۸: درخت تصمیم ساخته شده به روش CART

با انتخاب گزینه Conditional می‌توان درخت تصمیم را با الگوریتم CHAID انجام داد. برای داده‌های هواشناسی درخت تصمیم به صورت شکل ۹ بدست آمده است.



شکل ۹: درخت تصمیم ساخته شده به روش CHAID

برای ساخت درخت‌های تصمیم فوق از ۳۶۶ مشاهده، ۲۰ متغیر ورودی و متغیر هدف Rain Tomorrow، که دو-دویی است، از مجموعه داده هواشناسی استفاده شده است. از میان متغیرهای ورودی ۹ متغیر برای ساخت درخت تصمیم به روش CART استفاده شده است که نام این متغیرها را می‌توان در شکل ۸ مشاهده نمود. این درخت شامل ۵۱ گره

^{۳۲}kernel

^{۳۳}Margin

دوم نرم بردار وزن یعنی $\|w\|^2$ نسبت مستقیم دارد. در واقع اگر ما $\|w\|^2$ را محدود کرده و کمینه کنیم، بعد VC رده‌بند را کمینه کرده و تخمین مقدار ریسک به صورت احتمالی دقیق‌تر بوده و خاصیت تعمیم رده‌بند بیشتر خواهد بود. فرض کنید داده‌های دو کلاس جدایی پذیر باشند و بردارهای ویژگی مرزی کلاس اول روی ابرصفحه H^+ و بردارهای ویژگی کلاس دوم روی ابرصفحه H^- قرار گیرند. ابرصفحات H^+ و H^- به صورت رابطه (۴) تعریف می‌شوند.

$$\begin{aligned} H^+ : w \cdot x + b &= +1 \\ H^- : w \cdot x + b &= -1 \end{aligned} \quad (4)$$

در واقع معادله یک رده‌بند ابرصفحه‌ای با ناحیه حاشیه بهینه به صورت رابطه (۵) خواهد بود.

$$\begin{aligned} \text{Min } \phi(w) &= \frac{1}{2} \|w\|^2 \\ \text{Subject to } y_i(w \cdot x_i + b) &\geq 1 \\ i &= 1, 2, \dots, n \end{aligned} \quad (5)$$

مساله فوق، یک مساله بهینه‌سازی از نوع محدب و درجه دوم است. برای حل این مساله باید تابع لاگرانژ را تشکیل داد (معادله ۶) و ضرایب لاگرانژ را بدست آورد. در واقع هر یک از ضرایب لاگرانژ بدست آمده متناظر با یکی از الگوهای X است. الگوهای x_i را که متناظر با ضرایب مثبت α_i هستند بردار پشتیبان svi می نامند.

$$L(w, b, \alpha) = \frac{1}{2} w \cdot w - \sum_{i=1}^n \alpha_i (y_i (w \cdot x_i + b) - 1) \quad (6)$$

همچنین می‌توان با بدست آوردن مقدار w و قرار دادن مقدار آن در رابطه (۶) مسئله را به مسئله دوگان تبدیل کرد و جواب‌های بهینه را برای مسئله دوگان بدست آورد.

برای اجرای روش ماشین بردار پشتیبان در Rattle باید در بخش Model گزینه SVM را انتخاب کرد. در ابتدا باید تابع کرنل مورد نظر را انتخاب کرد. Rattle از چندین تابع کرنل پشتیبانی می‌کند، توابعی همچون خطی ساده، چندجمله‌ای، لاپلاس، بسل، تانژانت هیپربولیک و ...

۳.۸.۳ روش‌های تجمیعی (Boosting)


روش‌های تجمیعی، الگوریتم‌هایی هستند که یک مجموعه از رده‌بندهای ضعیف را گرفته و خروجی آنها را با یکدیگر ترکیب می‌نماید تا رده‌بند

جداکننده رده‌ها یا همان خط مرکزی قرار می‌گیرد. حال از بین خطوطی که رسم می‌شوند، خطی که حاشیه کناری آن بیشترین باشد، به عنوان خط جداکننده رده‌ها انتخاب می‌شود شکل (۱۰). محاسبه حاشیه به صورت رابطه (۱) است

$$M \arg in = \frac{2}{\|\vec{w}\|^2} \quad (1)$$

بیشینه نمودن حاشیه معادل با کمینه کردن رابطه (۲) است

$$L(w) = \frac{\|\vec{w}\|^2}{2} \quad (2)$$



شکل ۱۰: حاشیه خطوط رده‌بند در ماشین بردار پشتیبان

فرض کنید برای n مشاهده، مقادیر d متغیر بیان‌کننده ویژگی‌ها و یک متغیر هدف به صورت دو-دویی داریم. هدف اصلی، حل یک مسئله رده‌بندی دو کلاسه به صورت بهینه است. فرض کنید بخواهیم این دو کلاس را از یکدیگر تفکیک کنیم در این صورت تابع تمایز $f(x)$ و ابرصفحه H به صورت رابطه (۳) تعریف می‌شوند

$$\begin{aligned} H : w \cdot x + b &= 0 \\ f(x) &= \text{sign}(w \cdot x + b) \end{aligned} \quad (3)$$

در این رابطه بردار وزن w ، بردار عمود بر ابرصفحه جداکننده بوده و b مقدار اریبی است و منظور از $w \cdot x$ حاصل ضرب داخلی است. واپنیک^{۳۴} (۱۹۹۵) ثابت کرد که بعد VC ^{۳۵} برای رده‌بندی کننده‌هایی از نوع ابرصفحات کانونی، دارای یک کران بالاست که این کران بالا با توان

³⁴Vapnik

³⁵Vapnik-chervonenkis

اشتباه رده‌بندی شده‌اند. زیرا اگر براساس این مشاهدات آموزش ببینند و مدل بسازند، کارایی مدل ساخته شده افزایش می‌یابد. این فرآیند تا زمانی که مجموع وزن مشاهدات از آستانه‌ای مشخص کمتر شود ادامه می‌یابد. در Rattle نیز امکان استفاده از روش Boosting در زیربخش Boost برای رده‌بند درخت تصمیم فراهم شده است. این روش را می‌توان با انتخاب گزینه Boost و مشخص کردن تعداد درخت‌ها، عمق درخت‌ها، میزان پیچیدگی و ... انجام داد. شایان ذکر است در Rattle برای هر یک از این موارد مقداری به صورت پیش فرض در نظر گرفته شده است که کاربر می‌تواند آن را به میزان دلخواه خود تغییر دهد.

۹.۳ ارزیابی

دانشی که در مرحله یادگیری مدل تولید می‌شود، باید در مرحله ارزیابی مورد تحلیل قرار بگیرد تا بتوان ارزش آن را تعیین نمود و در پی آن کارایی الگوریتم یادگیرنده مدل را نیز مشخص کرد. بخش Evaluate در Rattle شامل بسیاری از معیارهای ارزیابی مدل ایجاد شده توسط کاربر است. در این بخش الگوریتم‌هایی را که کاربر مورد استفاده قرار داده است، برای ارزیابی فعال نموده است. از جمله معیارهای ارزیابی که در این بخش قابل اجرا هستند می‌توان به ماتریس خطا یا ماتریس درهم‌ریختگی^{۳۶}، منحنی ROC^{۳۷}، Cost Curve و ... اشاره کرد. می‌توان ارزیابی را بر روی هر یک از نمونه آموزشی، نمونه برای ارزیابی، نمونه برای آزمون و یا تمام مجموعه داده‌ها انجام داد. در Rattle این کار با انتخاب هر یک از گزینه‌های زیربخش Data در بخش Evaluate امکان‌پذیر است. همچنین می‌توان داده‌های جدیدی را فراخوانی کرد و ارزیابی را بر روی آنها انجام داد که این امر با انتخاب هر یک از گزینه‌های CSV File و R Dataset زیر بخش Data در بخش Evaluate امکان‌پذیر است.

نهایی به گونه‌ای تشکیل شود که کارایی آن از کارایی تک‌تک رده‌بندهای استفاده شده در الگوریتم بیشتر باشد. در نهایت رده مشاهدات استفاده نشده در مرحله ارزیابی را با ترکیب خروجی تک‌تک رده‌بندهای استفاده شده تعیین می‌کنند.

استفاده از الگوریتم‌های تجمیعی باعث کاهش خطا می‌شود. در واقع هنگامی که برای رسیدن به خروجی نهایی، خروجی حاصل از چند رده‌بند با یکدیگر ترکیب می‌شوند، رده‌بندها خطای یکدیگر را می‌پوشانند. به طور کلی، هر چه تعداد رده‌بندهای ضعیف در روش‌های تجمیعی بیشتر باشد، خطای رده‌بند نهایی به میزان بیشتری کاهش می‌یابد. بدیهی است که نکته منفی که در اینجا وجود دارد کندتر شدن فرآیند یادگیری الگوریتم تجمیعی خواهد بود. به هر حال توجه داریم که الگوریتم‌های تجمیعی کندتر از الگوریتم‌های معمولی هستند. در الگوریتم‌های تجمیعی دو ایده برای ترکیب رده‌بندها وجود دارند که

- Bagging
- Boosting

Boosting: هستند. روش Boosting از یک الگوریتم تکرار شونده استفاده می‌کند تا به طور تطبیقی، توزیع نمونه‌های آموزشی را تغییر دهد. همچنین این روش در فرآیند یادگیری بیشتر روی مشاهداتی که در مراحل قبلی به اشتباه رده‌بندی شده‌اند تمرکز می‌کند. در ابتدا به تمام N مشاهده موجود وزن برابر نسبت داده می‌شود. در انتهای هر مرحله ممکن است وزن مشاهدات تغییر کند، به این صورت که وزن مشاهداتی که به اشتباه رده‌بندی شده‌اند افزایش یافته و وزن مشاهداتی که به درستی رده‌بندی شده‌اند کاهش می‌یابد. همچنین وزن مشاهداتی که مدل ساخته شده نتوانسته آنها را رده‌بندی کند ثابت باقی می‌ماند. در این صورت پس از گذشت چند مرحله رده‌بندها برای یادگیری به سمت مشاهداتی می‌روند که وزن بیشتری داشته باشند، یعنی مشاهداتی که به

³⁶Confusion Matrix

³⁷Receiver Operating Characteristic

مراجع

- [۱] مشکانی، ع و ناظمی، ع. (۱۳۸۸)، *مقدمه ای بر داده کاوی*، ناشر علی مشکانی، مشهد
- [2] Fayyad. U.M, Piatetsky Shapiro, Smyth P and Uthurusamy R. (1996), *Advances in Knowledge Discovery and Data Mining*, Menlo park California: AAAI Press.
- [3] George, H. J. (1996) *Enhancements to the Data Mining Process*, Ph. D. thesis, Department of Computer Science, Stanford University.
- [4] George, H. j. (1997) *Enhancements to the Data Mining Process*, Ph. D. thesis, Department of Computer Science, Stanford University.
- [5] Williams. G, (2011) *Data Mining with Rattle and R: The Art of Excavating Data for Knowledge Discovery*, Use R, Springer Science+Business Media, LLC 2011.