



دانشگاه صنعتی اصفهان

دانشکده علوم ریاضی

داده‌کاوی آماری؛ ترکیب رگرسیون لجستیک چندگانه با درخت تصمیم

پایان نامه کارشناسی ارشد آمار ریاضی

شکیبا خادم القرآنی

اساتید راهنمای پایان نامه

دکتر علی زینل همدانی
دکتر محمد حسین سرائی



دانشگاه صنعتی اصفهان

دانشکده علوم ریاضی

پایان نامه کارشناسی ارشد آمار ریاضی خانم شکیبا خادم القرآنی

تحت عنوان

داده‌کاوی آماری؛ ترکیب رگرسیون لجستیک چندگانه با درخت تصمیم

در تاریخ ۱۲/۲۲/۸۵ توسط کمیته تخصصی زیر مورد بررسی و تصویب نهائی قرار گرفت.

دکتر علی زینل همدانی

۱— استاد راهنمای پایان نامه

دکتر محمد حسین سرایی

۲— استاد راهنمای پایان نامه

دکتر محمدرضا خیام‌باشی

۳— استاد داور ۱

(گروه کامپیوتر دانشگاه اصفهان)

دکتر سروش علیمرادی

۴— استاد داور ۲

دکتر رسول نصر اصفهانی

سرپرست تحصیلات تکمیلی دانشکده

تشکر و قدردانی

حمد و سپاس پروردگار عالمیان را، او که همواره مرا از دریای بیکران فضل الهی اش بهره مند کرد و از آغازین لحظات زندگی نعمت‌هایش را بر من ارزانی داشت و او که از همین درگاه، نعمت مادر و پدری والا را بر من عطا فرمود.

بر خود واجب می‌دانم که از اولین و بزرگ‌ترین معلمان زندگیم مادر و پدر عزیزم که مرا به جان پروردند و امید رسیدن به افق‌های روشن را در دلم شکوفا ساختند از صمیم قلب تشکر کنم.

از خواهران عزیزم که همیشه مرا مورد مهربانی‌های خود قرار داده‌اند متشرکم.

بر خود لازم می‌دانم که نهایت تشکر و سپاس صمیمانه خود را به دوست و استاد عزیزم جناب آقای دکتر علی همدانی که از رهنماوهای ایشان در مراحل مختلف زندگی ام بهره برده‌ام ابراز نمایم.

همچنین از جناب آقای دکتر محمد حسین سرابی استاد ارجمند که با راهنمایی‌های ارزنده خود، در انجام تحقیقات مرا یاری نمودند صمیمانه سپاسگزارم.

از جناب آقای دکتر احمد پارسیان که برای اولین بار مرا با داده‌کاوی آشنا نمودند و مرا همواره همراه، همگام و پشتیبان بوده‌اند کمال تشکر را دارم.

از آقای دکتر محمدرضا خیام‌باشی و همچنین آقای دکتر سروش علیمرادی که زحمت بازخوانی و داوری پایان‌نامه را متقبل شدند، نهایت تشکر و قدردانی را دارم.

همچنین از دیگر اساتید ارجمند که در دانشگاه صنعتی اصفهان افتخار شاگردی ایشان را داشته و همواره بنده را تشویق و یاری نموده‌اند صمیمانه سپاسگزارم.

از تمامی دوستان و هم‌کلاسی‌های عزیزم به خصوص خانم‌ها ریحانه ریخته‌گران و مریم هاشمی که در طی دوران تحصیلی ام زیباترین لحظات زندگی ام را رقم زدند، متشرکم.

و در پایان دست همه کسانی را که در گذر زندگی چراغی فرا راهم داشته‌اند به گرمی می‌فشارم.

کلیه حقوق مادی مترتب بر نتایج مطالعات،
ابتكارات و نوآوری‌های ناشی از تحقیق موضوع
این پایان‌نامه متعلق به دانشگاه صنعتی
اصفهان است.

فهرست مطالب

۳	فصل اول داده‌کاوی
۴	۱-۱ پیشینه داده‌کاوی
۵	۲-۱ داده‌کاوی
۵	۱-۲-۱ داده‌کاوی چیست؟
۵	۲-۲-۱ ابزارهای داده‌کاوی
۶	۳-۲-۱ روش‌های داده‌کاوی
۷	۴-۲-۱ مراحل داده‌کاوی
۱۰	۳-۱ داده‌کاوی و آمار
۱۱	۴-۱ داده‌کاوی و کشف دانش از پایگاه داده‌ها
۱۲	۵-۱ معرفی نرم‌افزارهای داده‌کاوی
۱۴	فصل دوم روش مدل‌سازی لجیت در تحلیل داده‌های رسته‌ای
۱۵	۱-۲ مدل‌سازی آماری
۱۶	۲-۲ متغیر رسته‌ای
۱۸	۱-۲-۲ معیارهای توصیفی
۱۸	۲-۲-۲ اندازه‌های همبستگی
۲۰	۳-۲ رگرسیون لجستیک برای داده‌های دودویی
۲۱	۱-۳-۲ مقدمه
۲۱	۲-۳-۲ چرا رگرسیون لجستیک مشهور است؟
۲۵	۳-۳-۲ مدل لجستیک
۲۶	۴-۳-۲ تفسیر ضرایب

۲۷	برآورد ضرائب ۵-۳-۲
۲۸	فواصل اطمینان، آزمون و خطاهای استاندارد ۶-۳-۲
۳۱	رگرسیون لجستیک برای داده‌های چندگانه ۴-۲
۳۱	مدل‌سازی لجیت متغیر پاسخ اسمی ۱-۴-۲
۳۲	مدل‌سازی لجیت متغیر پاسخ ترتیبی ۲-۴-۲
۳۹	فصل سوم درخت تصمیم
۴۰	۱-۳ درخت تصمیم چیست؟
۴۴	۲-۳ معیار رده‌بندی
۴۵	۱-۲-۳ شاخص جینی
۴۵	۲-۲-۳ شاخص آنتروپی
۴۶	۳-۲-۳ ارزیابی کلی افرازهای درخت
۴۶	۳-۳ افراز کردن
۴۶	۱-۳-۳ افراز متغیر پیوسته
۴۶	۲-۳-۳ افراز متغیر رسته‌ای
۴۸	۴-۳ الگوریتم ساخت درخت
۴۹	۵-۳ هرس کردن درخت
۴۹	۱-۵-۳ پیش‌هرس کردن درخت
۵۰	۲-۵-۳ پس‌هرس کردن درخت
۵۰	۶-۳ اعتبارسنجی متقابل
۵۲	فصل چهارم کاربردهای ترکیب روش‌های آماری و یادگیری ماشین
۵۲	۱-۴ ترکیب مدل‌سازی لگاریتم خطی با رده‌بندی و رگرسیون درختی
۵۸	۲-۴ استفاده از تحلیل ممیزی، رگرسیون لجستیک و رده‌بندی درختی
۶۰	۳-۴ رده‌بندی درختی در مقابل مدل‌های چندجمله‌ای
۶۴	فصل پنجم ترکیب رگرسیون لجستیک چندگانه با درخت تصمیم و کاربردی از آن
۶۵	۱-۵ ترکیب رگرسیون لجستیک چندگانه با درخت تصمیم
۶۸	۲-۵ معرفی خط تولید نورد سرد
۷۱	۳-۵ آماده‌سازی داده‌ها

۷۴	۴-۵ رگرسیون لجستیک
۸۰	۵-۵ درخت تصمیم
۸۷	۶-۵ کاربرد ترکیب رگرسیون لجستیک و درخت تصمیم

۹۱

فصل ششم نتیجه‌گیری و پیشنهادات

۹۴

مراجع

چکیده:

داده‌کاوی یک شیوه نوین برای استخراج اطلاعات در فرایند تصمیم‌گیری‌های علمی است و اغلب از روش‌های آماری و یادگیری ماشین برای تجزیه و تحلیل داده‌ها استفاده می‌نماید. یک رویکرد جدید در این راستا ترکیب شیوه‌های آماری و یادگیری ماشین برای کسب اطلاعات بیشتر از استفاده جداگانه هریک می‌باشد.

در این پایان‌نامه فرایند داده‌کاوی، رگرسیون لجستیک و درخت‌های تصمیم معرفی می‌شوند و با ترکیب *CART*، یکی از الگوریتم‌های درخت‌های تصمیم، با رگرسیون لجستیک چندگانه شیوه نوینی برای تحلیل داده‌های چندرشته‌ای ارائه می‌گردد. سپس این روش ابداعی را برای داده‌های واقعی خط تولید ورق فولاد به کار گرفته که نتایج نشان می‌دهند تحلیل داده‌ها کاراتر و حاوی اطلاعات سازنده‌تر به خصوص برای پاسخ‌های رسته‌ای ترتیبی می‌باشد.

مقدمه

اندازه‌گیری یک ویژگی یا صفت از جامعه که معمولاً یک متغیر است، مجموعه‌ای از اعداد را شامل می‌شود که به طور متدالوں آن را داده می‌نامند. داده‌ها بر دو قسمند: داده پیوسته که یک عدد حقیقی است و به صورت اعشاری بیان می‌شود. داده گسسته که آن را داده جدا از هم نیز می‌نامند.

امروزه پیشرفت شگفت‌انگیز فن آوری رایانه‌ای و مجهرشدن بشر به این ابزار، موجب پیشرفت فوق العاده در کسب و ذخیره‌سازی داده‌ها و همچنین به وجود آمدن پایگاه داده‌های بزرگ در زمینه‌های مختلف شده است.

داده‌کاوی فرایندی است که با نگرشی نوبه مسئله استخراج اطلاعات نهفته پرداخته و در حال حاضر مهم‌ترین فن آوری جهت بهره‌برداری مؤثر از داده‌های حجمی می‌باشد و اهمیت آن به عنوان یک علم رو به فزونی است. روش‌های آماری و یادگیری ماشین متدالوں تکنیک‌های داده‌کاوی می‌باشند. با توجه به متدالوں بودن داده‌های رسته‌ای چندگانه و اهمیت تحلیل رده‌بندی در بررسی نتایج و فرایند پیش‌گویی در اکثر زمینه‌های مطالعاتی و خصوصاً داده‌کاوی، روش‌هایی که تاکنون ارائه شده‌اند از لحاظ نحوه رده‌بندی، میزان ارائه اطلاعات، نحوه نمایش نتایج و ... مورد بررسی قرار گرفتند.

متدالوں تکنیک آماری در تحلیل و مدل‌سازی داده‌های رسته‌ای دودویی و چندگانه، روش مدل‌سازی رگرسیون لجستیک است. در یادگیری ماشین، درخت تصمیم یک روش معمول در رده‌بندی داده‌ها می‌باشد و الگوریتم *CART* نیز از مشهورترین الگوریتم‌های ساخت درخت به شمار می‌آید.

در این پایان‌نامه، علاوه بر معرفی دو روش فوق، روش مدل‌سازی لجیت و درخت تصمیم در تحلیل

داده‌های رسته‌ای، چند کاربرد از روش‌های آماری و یادگیری ماشین در فرایند داده‌کاوی نیز معرفی می‌شوند. در این کاربردها، محققان رویکرد نوینی را ابداع نموده‌اند که در آن به ترکیب این دو روش مستقل پرداخته و این امر موجب ارائه اطلاعاتی با جزئیات بیشتر می‌گردد [۱۱، ۲۸، ۳۸، ۴۰].

با تحقیق و تفحص در تحلیل داده‌های رسته‌ای چندگانه ترتیبی، پیرو این رویکرد نوین، روش جدیدی برای تحلیل و مدل‌سازی ابداع گردید. در این روش با ترکیب روش رگرسیون لجستیک چندگانه و الگوریتم *CART* در روش درخت تصمیم، شیوه جدیدی برای رده‌بندی داده‌های رسته‌ای ارائه می‌شود. در شیوه مدل‌سازی لجیت تجمعی، متغیرهای معنی‌دار برای رده‌های مختلف متغیر هدف شناسایی می‌شوند و تأثیرگذاری متغیرهای پیش‌گوی توضیح‌دهنده بر اساس آزمون‌های والد، تابع امتیاز و ... بررسی می‌گردد و میزان اثرگذاری هر متغیر دقیقاً محاسبه می‌شود. ولیکن نتایج این تحلیل به صورت گرافیکی نبوده و چنانچه هدف تحلیل، رده‌بندی متغیر مربوطه باشد، به دلیل این‌که از احتمالات تجمعی اثرات استفاده می‌شود، به سادگی با این روش امکان پذیر نمی‌باشد و حتی در مواردی که از دیگر مدل‌های لجیت برای تحلیل داده‌های دودویی یا چندگانه استفاده شود، نتایج قابل مقایسه با نتایج تحلیل درخت تصمیم نمی‌باشد، به عبارت دیگر درخت تصمیم نمایش منحصر به فرد، جذاب، ساده و سریعی را برای رده‌بندی ارائه می‌دهد که ترکیب این دو روش در تحلیل داده‌ها اطلاعاتی با جزئیات بیشتر، جذاب‌تر و حتی معتبرتر را فراهم می‌سازد و به عنوان کاربردی از این پژوهش، این روش ابداعی بر روی داده‌هایی از صنعت فولاد به کار گرفته می‌شود.

حاصل بررسی‌ها و مطالعات به عمل آمده در شش فصل به شرح زیر دسته‌بندی شده است:
فصل اول شامل پیشینه داده‌کاوی، معرفی داده‌کاوی، سیستم داده‌کاوی، ارتباط آن با کشف دانش از پایگاه داده‌ها و آمار، و معرفی برخی نرم‌افزارهای مفید و متداول در این زمینه، می‌باشد.

فصل دوم به مفهوم مدل‌سازی در آمار و متغیر رسته‌ای اشاره می‌کند، سپس به بررسی مدل‌سازی لجیت برای داده‌هایی با پاسخ رسته‌ای دوگانه و چندگانه می‌پردازد.

فصل سوم به معرفی درخت تصمیم و عوامل مؤثر در ساخت درخت اختصاص دارد.

فصل چهارم برخی کاربردهای ترکیب روش‌های آماری و درخت تصمیم را شرح می‌دهد.

فصل پنجم به معرفی روش ابداعی ترکیب رگرسیون لجستیک و درخت تصمیم می‌پردازد و کاربرد این شیوه را بر روی داده‌های صنعت فولاد ارائه می‌نماید.

فصل ششم خلاصه نتایج و پیشنهادات این مطالعه را مطرح می‌کند.

فصل ۱

داده کاوی

پیشرفت شگفت انگیز فناوری رایانه‌ای و مجهر شدن بشر به این ابزار، سبب پیشرفت فوق العاده در کسب و ذخیره‌سازی داده‌ها و همچنین به وجود آمدن پایگاه داده‌های بزرگ در زمینه‌های مختلف شده است، لذا مشکل دنیای امروز نبود داده کافی برای تصمیم‌گیری‌های علمی نیست و محققان در بیشتر زمینه‌های مطالعاتی از جمله کشاورزی، پزشکی، تجاری، ترافیک، اینترنت و . . . با سیلانی از داده‌های خام مواجه هستند.

امروزه اهمیت دستیابی به اطلاعات نهفته در داده‌های حجمی که لازمه مدیریت مؤثر است، روبه فروزنی است که با به کار بردن سیستم‌های سنتی میسر نمی‌باشد، از این رو محققان برای ارائه تحلیل‌های مفید و کارآمد نیازمند ترکیب روش‌های مختلف می‌باشند.

داده کاوی فرایندی است که به عنوان یک ابزار پرتوان به تجزیه و تحلیل حجم بالای داده‌ها و پایگاه‌های داده‌های با ابعاد زیاد می‌پردازد.

در این فصل ابتدا به پیشینه‌ای از داده کاوی اشاره شده و سپس به معرفی آن پرداخته می‌شود، سیستم داده کاوی و ارتباط آن با کشف دانش از پایگاه داده‌ها و آمار مطرح شده و با معرفی برخی نرم‌افزارهای مفید و متداول در این زمینه، فصل خاتمه می‌یابد.

۱-۱ پیشینه داده‌کاوی

داده‌کاوی^۱ و کشف دانش از پایگاه داده‌ها^۲ (*KDD*) از جمله موضوع‌هایی هستند که همزمان با ایجاد و استفاده از پایگاه داده‌ها در اوایل دهه ۸۰ برای جستجوی دانش در داده‌ها شکل گرفته‌اند. شاید بتوان لول (۱۹۸۳) را اولین شخصی که گزارشی در مورد داده‌کاوی تحت عنوان شبیه سازی فعالیت‌های داده‌کاوی ارائه نموده است، معرفی نمود. همزمان با وی پژوهشگران و متخصصان تحلیل داده‌ها، علوم رایانه، آمار، هوش مصنوعی، یادگیری ماشین و . . . نیز به پژوهش در این زمینه و زمینه‌های مرتبط پرداخته‌اند.

به طور جدی موضوع داده‌کاوی از اوایل دهه ۹۰ مطرح شد. پژوهش‌ها و مطالعه‌های زیادی تاکنون صورت گرفته و همچنین سمینارها، دوره‌های آموزشی و کنفرانس‌های متعددی برگزار شده‌اند [۴۲].

سال ۱۹۹۱ پیاتتسکی – شاپیرو استقلال آماری قاعده‌ها در داده‌کاوی را بررسی نمود. سال ۱۹۹۵ هافمن و نش استفاده از داده‌کاوی و داده‌انبار توسط بانک‌های آمریکا را مطرح نموده و بیان کردند که چگونه این سیستم‌ها برای بانک‌های آمریکا رقابت بیشتری ایجاد می‌کنند. چت‌فیلد مشکلات ایجاد شده توسط داده‌کاوی را بررسی نمود [۹] و همچنین مقاله‌ای تحت عنوان مدل‌های خطی غیر دقیق داده‌کاوی و استنباط آماری ارائه کرد. هندری نیز دیدگاه اقتصاد سنج‌ها روی داده‌کاوی را تهیه نمود. در این سال انجمن داده‌کاوی در اولین کنفرانس بین‌المللی کشف دانش و داده‌کاوی شروع به کار نمود. سال ۱۹۹۶ ایمیلنسکی و منیلا دیدگاهی از داده‌کاوی به عنوان پرس و جو کننده از پایگاه داده‌های استنتاجی^۳ را پیشنهاد کردند. فایاد، پیاتتسکی – شاپیرو، اودوراسامی پیشرفت‌های کشف دانش و داده‌کاوی را عنوان کردند [۱۶]. سال ۱۹۹۷ منیلا خلاصه مطالعه‌ای روی اساس داده‌کاوی را ارائه نمود. فریدمن مقاله‌ای در ارتباط با مفهوم آمار و داده‌کاوی [۱۹] و در سال ۱۹۹۸ هند مقاله‌ای تحت عنوان داده‌کاوی: آمار و بیشتر؟ [۲۲] ارائه نمودند. سال ۲۰۰۱ هند و اسمیت بحث‌های مقایسه‌ای بین آمار و داده‌کاوی را مطرح کردند [۲۴].

کهارت و همکارانش در سال ۲۰۰۰ دیدگاه جدیدی را ابداع کردند. برای کسب دانش و اطلاعات بیشتر از پایگاه داده‌ها به ترکیب مدل‌های ناپارامتری با رگرسیون لجستیک پرداختند و کاربرد این تکنیک را روی آسیب‌های حوادث وسائل نقلیه موتوری ارائه نمودند [۲۸]. پس از آن پیرو این شیوه، در سال ۲۰۰۲ چانگ روش *CART*^۴ و مدل‌سازی لگاریتم خطی را ترکیب و کاربرد آن را روی داده‌ها تولد بررسی نمود [۱۱]. اندر و ورت و مارک کرونین نیز در سال ۲۰۰۳ کاربرد روش‌های تحلیل ممیزی، رگرسیون

^۱ *Data Mining*

^۲ *Knowledge Discovery of Database*

^۳ *Inductive Database*

^۴ *Classification and Regression Trees*

لجستیک و تحلیل طبقه‌بندی درختی روی گسترش مدل‌های طبقه‌بندی را شرح داده‌اند [۴۰].



۱-۲ داده‌کاوی

نگاهی به ترجمه لغوی داده‌کاوی، در درک بهتر واژه مؤثر می‌باشد. کلمه 'Mine' به معنای استخراج از منابع نهفته و با ارزش زمین می‌باشد، ادغام آن با کلمه داده 'Data' به جستجویی عمیق از داده‌های قابل دسترس با حجم زیاد برای کسب اطلاعات مفید که قبلًا نهفته بودند، تأکید دارد.

۱-۲-۱ داده‌کاوی چیست؟

این اصطلاح را آماردانان، تحلیل‌گران داده‌ها و انجمن سیستم‌های اطلاعات مدیریت به کار برده‌اند. برای داده‌کاوی تعاریف متنوعی ارائه شده که به نوع نگرش و دیدگاه محققان در علوم مختلف اشاره دارد. برخی از این تعاریف عبارتند از:

۱. داده‌کاوی فرایند شناخت الگوهای معتبر، جدید، مفید و قابل فهم از داده‌ها می‌باشد.
 ۲. داده‌کاوی به فرایند استخراج اطلاعات نهفته، قابل فهم و قابل تعقیب از پایگاه داده‌های بزرگ و استفاده از آن در تصمیم‌گیری‌های تجاری مهم، اطلاق می‌شود.
 ۳. داده‌کاوی، مجموعه‌ای از روش‌ها در فرایند کشف دانش می‌باشد که برای تشخیص الگوها و روابط نامعلوم در داده‌ها مورد استفاده قرار می‌گیرد.
 ۴. فرایند کشف دانش الگوهای مفید از داده‌ها را داده‌کاوی می‌گویند.
 ۵. فرایند انتخاب، کاوش و مدل‌سازی داده‌های حجمی، جهت کشف روابط نهفته با هدف کسب نتایج واضح و مفید، را داده‌کاوی می‌گویند.
- که به طور کلی همه تعاریف داده‌کاوی به فرایند استخراج دانش از پایگاه داده‌ها اشاره دارند [۱۹].

۱-۲-۲ ابزارهای داده‌کاوی

برای استخراج اطلاعات از پایگاه داده‌های بزرگ، چنانچه اشاره شد سیستم‌های سنتی به تنها‌یی کارا نمی‌باشند و لازم است در این راستا از روش‌ها، فنون و الگوریتم‌های به کار رفته در سایر رشته‌ها از قبیل آمار، هوش مصنوعی^۵، یادگیری ماشین^۶ . . . استفاده شود.

^۵ Artificial Intelligence

^۶ Machine Learning

به طور کلی داده‌کاوی، فرایند استخراج دانش از پایگاه داده‌های بزرگ، در سه شاخه قدیمی ریشه دارد [۴۱] که مهم‌ترین آنها آمار کلاسیک است. بدون آمار، داده‌کاوی وجود نخواهد داشت، زیرا آمار زیربنای بیشتر فناوری‌هایی است که داده‌کاوی بر اساس آنها بنا شده است. آمار کلاسیک از ابزاری همچون توزیع استاندارد، انحراف معیار، واریانس، بازه‌های اطمینان، تحلیل رگرسیون، تحلیل ممیزی، تحلیل خوش‌های . . . استفاده می‌کند تا جزئیات و روابط بین داده‌ها به طور دقیق مورد بررسی قرار گیرند، لذا یقیناً در قلب ابزار و روش‌های داده‌کاوی، امروزه تحلیل‌های آمار کلاسیک نقش مهمی را ایفا می‌کنند.

دومین شاخه مرتبط با داده‌کاوی، هوش مصنوعی است که برای تلخیص داده‌ها، تحلیل کاوشگرانه داده‌ها، ساختن مدل و . . . به کار می‌رود. این شاخه بر اساس اکتشاف، ساخته شده و سعی دارد پردازش‌هایی شبیه افکار انسان را در مسایل آماری به کار برد. این شاخه مستلزم قدرت پردازش رایانه‌ای بالایی بود که تا اویل دهه ۸۰، زمانی که رایانه‌ها با قدرت بالا و قیمت معقول عرضه شدند، امکان پذیر نبود. هوش مصنوعی تنها کاربردهای اندکی در پژوهش‌های پیشرفته، سازمان‌های دولتی ویژه و بازارهایی خاص داشت ولی در آن دوران ابررایانه‌های لازم برای بهره‌برداری از این فناوری به حدی محدود بود که کاربردی برای سایر افراد و سازمان‌های جامعه نداشت.

سومین شاخه مرتبط با داده‌کاوی، یادگیری ماشین است که تلفیقی از آمار و هوش مصنوعی است. یادگیری ماشین می‌تواند به عنوان هوش مصنوعی تکامل یافته مطرح شود زیرا اکتشاف‌های هوش مصنوعی را با تحلیل‌های آماری پیشرفته ادغام می‌کند. این شاخه سعی دارد به برنامه‌های رایانه‌ای این امکان را بدهد تا در مورد اطلاعاتی که به آنها داده می‌شود، یادگیرند تا چنین برنامه‌هایی بتوانند متناظر با کیفیت‌های متفاوتی که به آنها داده می‌شوند تصمیم‌گیری‌های متفاوتی انجام دهند. این تصمیم‌گیری‌ها بر اساس اصول پایه‌ای آمار انجام می‌گیرد. علاوه بر آمار، الگوریتم‌های هوش مصنوعی و هوش مصنوعی اکتشافی پیشرفته، ابزاری برای رسیدن به این هدف می‌باشند. مهم‌ترین تکنیک‌های این شاخه شبکه‌های عصبی، درخت تصمیم و الگوریتم رشته‌کی می‌باشند.

۱-۲-۳ روش‌های داده‌کاوی

اساساً دو روش برای داده‌کاوی عنوان می‌شود که از لحاظ ایجاد، طراحی مدل و یافتن الگوها با یکدیگر تفاوت دارند. اولین روش، مربوط به ساخت مدل است، جدا از مشکلاتی که ذاتاً در مجموعه داده‌های بزرگ وجود دارد مشابه روش‌های کاوشگرانه آماری مرسوم، می‌باشد. در این روش، هدف ارائه خلاصه‌ای

کلی از مجموعه‌ای از داده‌ها برای شناخت و شرح خصوصیت‌های اصلی شکل توزیع است (هند، ۱۹۹۸). تحلیل خوش‌ای بخشی از مجموعه داده‌ها، مدل رگرسیونی برای پیش‌گویی و قاعده رده‌بندی با ساختار درختی مثال‌هایی از این روش می‌باشد.

در طراحی مدل، بعضی موقع تفاوت‌هایی بین مدل‌های تجربی و ماشینی تشخیص داده می‌شود (باکس و هانتر، ۱۹۶۵، کاکس و هند، ۱۹۹۵). مدل تجربی که بعضی موقع مدل عملیاتی هم نامیده می‌شود، سعی می‌کند روابط بین داده‌ها را بدون در نظر گرفتن تئوری‌های زیربنایی، پایه‌ریزی و مدل‌بندی کند. مدل ماشینی که گاهی مدل بنیادی یا مدل پدیده شناختی هم نامیده می‌شود، بر اساس برخی تئوری‌ها یا مکانیسم‌هایی که برای فرایند تولید داده‌های زیربنایی به کار می‌رود پایه‌ریزی شده‌اند. داده‌کاوی بنا به تعریف، بیشتر با مدل عملیاتی سروکار دارد.

روش دوم داده‌کاوی، رویکرد تشخیص الگو است. این رویکرد سعی دارد انحراف‌هایی هر چند کوچک از حد مطلوب را تشخیص دهد، تا الگوهای روندهای غیر معمول نمایان شود. مثال‌هایی نظیر الگوهای نامعمول (برای تشخیص کلاهبرداری) در استفاده از کارت‌های اعتباری برای خرج کردن و موضوع‌هایی که الگوهایی با ویژگی‌های نامشابه با دیگران دارند و . . .

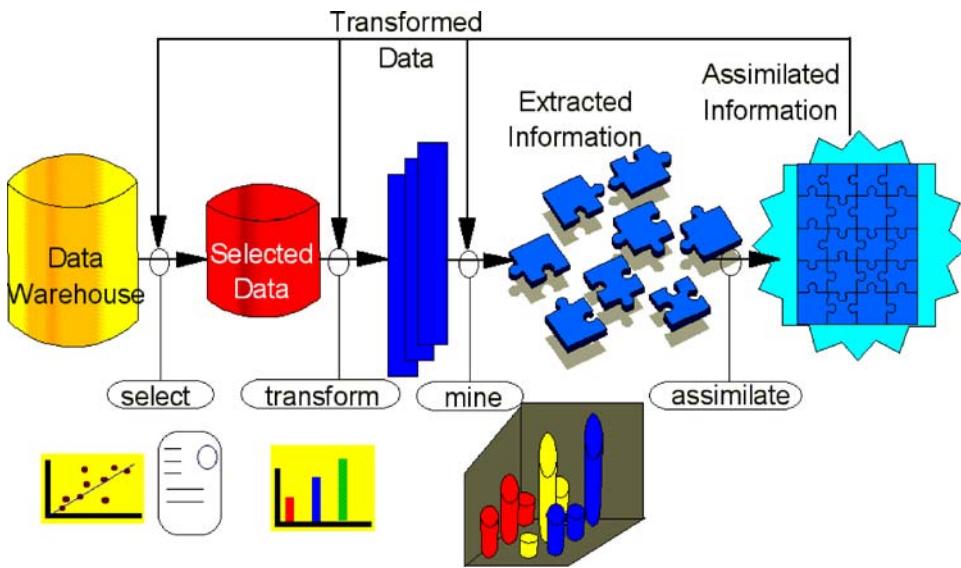
این رده از راهبردها است که موجب گردیده داده‌کاوی به عنوان علم جستجوی اطلاعات بالارزش از بین توده عظیمی از داده‌ها به حساب آید.

۴-۲-۱ مراحل داده‌کاوی

به طور خلاصه داده‌کاوی شامل مراحل زیر است:

تعیین موضوع: در ابتدا باید روشن کرد که با تجزیه و تحلیل، انتظار داریم به چه چیزی دست یابیم. بنابراین از قبل باید هدف از داده‌کاوی را تعیین و ثابت کنیم که این هدف قابل اندازه‌گیری است یا نه؟

انتخاب داده‌ها: گام بعدی، انتخاب داده‌ها برای رسیدن به این هدف است. این امر می‌تواند زیر مجموعه‌ای از پایگاه داده‌ای باشد که در اختیار داریم که برای این کار باید تا حد امکان داده‌ها را بخش‌بندی نمود.



نمودار ۱-۱ مراحل داده کاوی

آماده کردن داده‌ها: در مرحله قبل داده‌ها گرداوری شد. حال باید تصمیم گرفت کدامیک از ویژگی‌های موجود قابل استفاده هستند.

- اتخاذ تدابیری برای بررسی داده‌های گمشده، خطاهای خارجی و داده‌های پرت.
- تعیین متغیرهای اضافی در مجموعه داده‌ها و تصمیم‌گیری درباره اینکه کدام فیلد باید خارج شود.
- در صورت لزوم تصمیم‌گیری درباره انواع تبدیل‌ها: لگاریتمی، نمایی، توان دوم،
- بازرسی شهودی مجموعه داده‌ها برای درک پایگاه داده‌ها.

بازرسی داده‌ها: ارزیابی ساختار داده‌ها به منظور تعیین ابزارهای مناسب.

انتخاب ابزارها: اهداف کاری و ساختار داده‌ها دو رهنمون مهم برای انتخاب ابزار داده کاوی مناسب هستند. هر دو باید تحلیل‌گر را به ابزار یکسان هدایت کنند. به هنگام ارزیابی مجموعه‌ای از ابزارهای بالقوه معمولاً پرسش‌های زیر مطرح می‌شوند:

- آیا مجموعه داده‌ها صرفاً رسته‌ای است؟
- چه برنامه‌ای برای حمایت از ابزارهای منتخب داریم؟
- چه قالبی از داده‌ها می‌تواند برای ابزارها مفهوم داشته باشد؟

- قالب پاسخ : قالب پاسخ را بازرسی داده‌ها، هدف کاری و انتخاب ابزار، تعیین می‌کنند. سؤال‌های کلیدی در این مرحله عبارتند از:
- قالب بهینه حل درخت تصمیم چیست؟
 - قالب مناسب گزینه چیست؟
 - هدف از حل چیست؟
 - کاربر به چه چیزی احتیاج دارد: نمودارها، گزارش‌ها، برنامه‌ها، . . . ؟

طرح‌ریزی مدل : در این مرحله است که فرایند داده‌کاوی آغاز می‌شود. معمولاً اولین گام، استفاده از چند رده تصادفی برای جدا کردن داده‌ها در مجموعه تولیدی، مجموعه آزمون، ایجاد و ارزیابی یک مدل است. تولید قاعده‌های رده‌بندی، درخت‌های تصمیم، خوشبندی زیر گروه‌ها، برنامه‌ها، وزن‌ها و ارزیابی داده‌ها یا نسبت خط‌ها در این مرحله قرار دارند.

ارزیابی یافته‌ها: تهیه یک گزارش نهایی برای کاربران، که این گزارش باید مستند به فرایند داده‌کاوی بی‌عیب و نقص، شامل آماده‌سازی داده‌ها، ابزارهای به کار رفته، نتایج آزمون، کد منابع، قاعده‌ها و . . . باشد.

- برخی از این نتایج عبارتند از:
- آیا داده‌های اضافی تجزیه و تحلیل را بهبود خواهند بخشید؟
 - از تجزیه و تحلیل داده‌کاوی چه نتایجی می‌تواند پیشنهاد شود؟
 - آیا یافته‌ها مناسب هدف کاری هستند؟

هماهنگ کردن پاسخ‌ها : یافته‌ها با کلیه علایق کاربران در واحدهای کاری مناسب تقسیم می‌شود. می‌توان به طور کامل نتایج تجزیه و تحلیل در روش‌های کار را بهم پیوند داد. اگر چه ابزارهای داده‌کاوی، پایگاه داده‌ها را به طور خودکار تجزیه و تحلیل می‌کنند، ولی اگر مراقب نباشیم ممکن است به یافته‌های نادرست و نتایج غلط منجر شود. در نظر داشته باشید که داده‌کاوی فرایندی کاری با هدف مشخص برای استخراج اطلاعات مفید از داده‌های موجود در پایگاه داده‌ها است.

۱-۳ داده کاوی و آمار

داده کاوی و آمار هر دو با روش‌های تحلیل و مدل‌بندی داده‌ها مرتبط می‌باشند، لذا اشتراک زیادی بین این دورشته وجود دارد. به عنوان یک لطیفه یکی از نویسندها در پاسخ به سؤال داده کاوی چیست بیان می‌دارد که «همان آمار است اما با یک نام جذاب‌تر».

داده کاوی همپوشانی زیادی با آمار کلاسیک دارد، به طوری که حتی برخی از محققان داده کاوی را زیر مجموعه‌ای از آمار تلقی می‌کنند. از طرف دیگر داده کاوی از ابزار و روش‌های دیگری از جمله یادگیری ماشین، نظریه و فناوری پایگاه داده‌ها و . . . استفاده می‌نماید و ضرورتی ندارد که به برخی از سطوحی که مد نظر آمار است مربوط شود.

داده کاوی اساساً یک شیوه تحلیل اطلاعات است که در آن سعی می‌شود با ایجاد ارتباط بین آمار و علوم رایانه‌ای، روش‌های کارا و سریعی برای استخراج اطلاعات نهفته مجموعه‌ای بزرگ از داده‌ها ارائه گردد. روابط در داده کاوی غالباً به صورت الگوها و مدل‌هایی از جمله معادلات رگرسیونی، سری‌های زمانی، خوشبندی، رده‌بندی، گراف و غیره بیان می‌شوند.

داده کاوی و آمار هر دو به طرح استنباط از داده‌ها مربوط می‌شوند. هدف از استنباط ممکن است درک الگوهای همبستگی و پیوندهای سببی بین مقادیر داده‌ها، یا ساخت پیش‌گویی از مقادیر داده‌های قبلی باشد. آمار کلاسیک در برگیرنده مدلی برای توزیع احتمال داده‌ها و ساخت استنباط به صورت بیان احتمال است. روش‌های داده کاوی در بسیاری از موارد مسائلی را در بر می‌گیرد که به سادگی در چارچوب آمار کلاسیک برآش داده نمی‌شوند و از آمار فاصله گرفته‌اند.

در آمار با جامعه سروکار داریم در حالی که داده کاوی با پایگاه داده‌ها سروکار دارد.

داده کاوی با نمونه‌گیری مانند آمار سروکار ندارد، یعنی دوباره می‌توان از داده‌ها استفاده نمود.

داده کاوی از میان مجموعه مدل‌های برآش داده شده، بهترین مدل را انتخاب می‌کند ولی در آمار تنها یک مدل برآش داده می‌شود.

آمار مدل برآش داده شده را برای تعمیم به جامعه به کار می‌برد ولی در داده کاوی مدل برآش داده شده انتخابی برای پیش‌گویی داده‌های جدید است.

مجموعه داده‌ها در داده کاوی می‌تواند خیلی وسیع تر و گسترده‌تر از مجموعه داده‌های معمول در آمار، شامل چند صد میلیون یا هزار میلیارد رکورد باشد.

نوع داده‌ها در آمار کمی و کیفی است ولی داده کاوی داده‌های کمی، کیفی و متنی را شامل می‌شود.

نوع متغیرهای ورودی در آمار عددی و در داده کاوی از نوع عددی، طبقه‌ای و متنی می‌باشند.

نوع تمرکز در آمار روی مدل و در داده کاوی روی الگو است.

زیربخش‌های اصلی آماربرآورد، توزیع‌های احتمالی، آزمون فرضیه‌ها امتیازبندی مدل و پیش‌گویی است و زیربخش‌های داده‌کاوی مدل‌بندی پیش‌گویی‌ها، بخش‌بندی پایگاه داده‌ها و ساخت فرضیه‌ها است. هدف اصلی از به کارگیری روش‌ها در آمار استفاده از برآوردها و توزیع‌ها برای ادغام اطلاعات است و در داده‌کاوی هدف اصلی کشف دانش مورد علاقه است.

شكل نتایج در آمار به صورت مدل‌های کلی برآورد می‌شود ولی در داده‌کاوی مدل‌های موضوعی محاسبه می‌شوند.

ارزش اطلاعاتی نتایج در آمار معلوم و محدود است در حالی که در داده‌کاوی نامعلوم و نامحدود می‌باشد. در آمار جستجو برای دستیابی به نتایج محدود به جستجوهای جهت‌دار بوده و با نتایج نیز آشنا هستیم ولی در داده‌کاوی جستجوها اکثراً از طریق کاربر تعیین شده و ممکن است جهت‌دار باشند، اما اصولاً روش خودکار بوده و نوع نتایج نامعلوم است.

در مقایسه با آمار، داده‌کاوی توجه کمتری به ویژگی‌های مجانبی استنباط‌های بزرگ نمونه‌ای دارد و فلسفه کلی یادگیری، بیشتر شامل ملاحظه پیچیدگی مدل‌ها و محاسباتی که آنها نیاز دارند، می‌باشد.

۱-۴ داده‌کاوی و کشف دانش از پایگاه داده‌ها

در متون مربوط به داده‌کاوی دو تعبیر مختلف از آن وجود دارد. برخی مؤلفان مانند چتفیلد (۱۹۹۵) داده‌کاوی را مترادف کشف دانش از پایگاه داده‌ها می‌دانند^[۶]. گروه دوم از جمله فایاد (۱۹۹۶) داده‌کاوی را به عنوان یک مرحله ضروری از فرایند بزرگتر کشف دانش از پایگاه داده‌ها (*KDD*) در نظر می‌گیرند^[۷].

عبارت داده‌کاوی توسط آماردانان، محققین پایگاه داده‌ها و سیستم‌های اطلاعات مدیریتی و جوامع بازرگانی به کار برده می‌شود. عبارت کشف دانش از پایگاه داده‌ها (*KDD*) عموماً برای اشاره به فرایند کلی کشف دانش مفید از داده‌هایی که داده‌کاوی گام مهمی در این فرایند است، مورد استفاده قرار می‌گیرد. به طور خلاصه *KDD* شامل مراحل زیر است:

۱. پاکسازی داده‌ها^۷ : حذف داده‌های ناپایدار و مزاحم.
۲. یکپارچه سازی داده‌ها^۸ : ترکیب منابع متعدد، پراکنده و احتمالاً ناهمگن داده‌ها.
۳. انتخاب داده‌ها^۹ : بازیابی داده‌های مربوط به عمل کاوش از پایگاه داده‌ها.

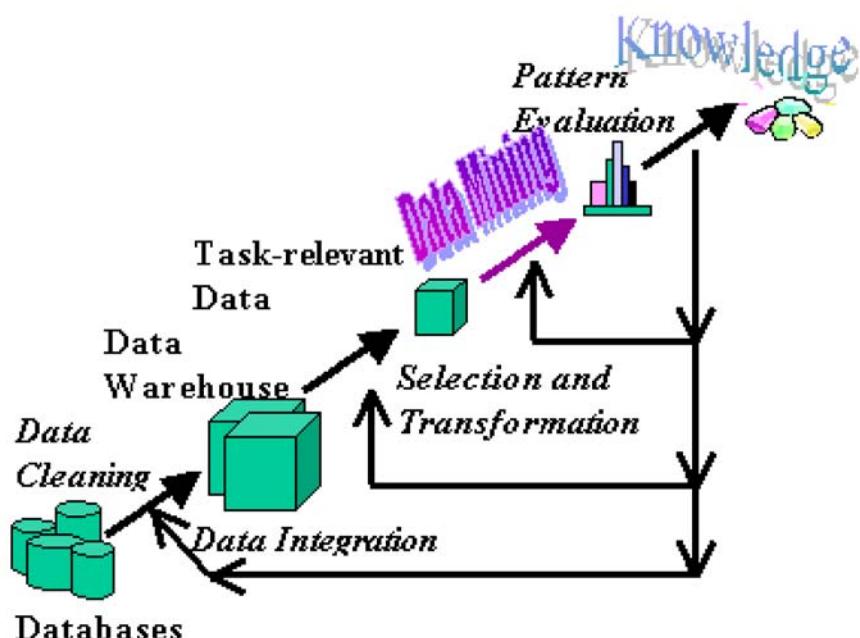
^۷ Data Cleaning

^۸ Data Integration

^۹ Data Selection

۴. تبدیل داده‌ها^{۱۰} : تبدیل داده‌ها به اشکالی مناسب برای به کار بردن روش‌های مختلف.
۵. داده‌کاوی : مرحله‌ای ضروری از فرایند *KDD* است که در آن از روش‌های مختلف آماری و یادگیری ماشین برای استخراج الگوهای استفاده می‌شود، که خود شامل مراحل زیر است:
 - انتخاب عملیات داده‌کاوی
 - انتخاب روش داده‌کاوی
 - جستجو برای یافتن الگوی مناسب
۶. ارزیابی الگوهای^{۱۱} : شناسایی الگوهای جذاب ارائه دانش، بر اساس معیارهای جذابیت.
۷. ارائه دانش^{۱۲} : ارائه دانش استخراج شده با استفاده از تکنیک‌های نمایش اطلاعات.

شكل ۱-۲ مراحل فرایند کشف دانش از پایگاه داده‌ها را نشان می‌دهد.



نمودار ۱-۲ داده‌کاوی هسته اصلی کشف دانش از پایگاه داده‌ها

^{۱۰}Data Transformation

^{۱۱}Pattern Evaluation

^{۱۲}Knowledge Presentation