



دانشگاه صنعتی اصفهان

دانشکده برق و کامپیوتر

یکپارچه سازی و کاوش مجموعه داده‌های حجیم RFID

پایان نامه کارشناسی ارشد مهندسی کامپیوتر - نرم افزار

لیلا حافظی

استاد راهنما

دکتر محمد حسین سرایی



دانشگاه صنعتی اصفهان

دانشکده برق و کامپیوتر

پایان نامه کارشناسی ارشد رشته مهندسی کامپیوتر - نرم افزار خانم لیلا حافظی

تحت عنوان

یکپارچه سازی و کاوش مجموعه داده‌های حجیم RFID

در تاریخ ۱۳۹۰/۲/۶ توسط کمیته تخصصی زیر مورد بررسی و تصویب نهایی قرار گرفت.

۱- استاد راهنمای پایان نامه دکتر محمد حسین سرایی

۲- استاد مشاور دکتر محمد علی منتظری

۳- استاد داور دکتر عبدالرضا میرزایی

۴- استاد داور دکتر پژمان خدیوی

سرپرست تحصیلات تکمیلی دکتر سید محمود مدرس هاشمی

تشکر و قدردانی:

نگارنده بر خود می‌داند که در ابتدا از زحمات بی‌دریغ، تلاش‌های بی‌وقفه و راهنمایی‌های ارزشمند استاد گرامی جناب آقای دکتر محمد حسین سرایی در راستای انجام این پروژه تشکر و قدردانی نماید. از جناب آقای دکتر محمد علی منتظری نیز که به عنوان استاد مشاور رحمت زیادی کشیده‌اند تشکر نموده، هم چنین از کمک خالصانه جناب آقای مهندس مسعود صفری که در ابتدای راه از راهنمایی‌هایی ارزشمند ایشان بهره گرفته شد و از تمامی افرادی که در طول انجام این پروژه به گونه‌ای کمک و مساعدت نمودند سپاسگزاری می‌نماید.

کلیه حقوق مادی مترتب بر نتایج مطالعات،
ابتكارات و نوآوری‌های ناشی از تحقیق موضوع
این پایان نامه (رساله) متعلق به دانشگاه صنعتی
اصفهان است.

تقدیم به آنانی که زیبایی زندگیشان را ارزانی ام داشتند:

پدر، مادر و همسر م

فهرست مطالب

<u>صفحه</u>	<u>عنوان</u>
..... هشت	فهرست مطالب.....
..... یازده	فهرست شکل ها.....
..... ۱	چکیده
	فصل اول: مقدمه
..... ۲	۱-۱ معرفی
..... ۳	۲-۱ هدف تحقیق
..... ۳	۳-۱ ساختار پایان نامه
	فصل دوم: داده کاوی بر روی داده های RFID
..... ۵	۱-۲ مقدمه
..... ۶	۲-۲ ویژگی های داده های RFID
..... ۷	۳-۲ پیش پردازش
..... ۸	۴-۲ انباره داده چیست
..... ۹	۵-۲ یکپارچه سازی داده ها
..... ۱۰	۶-۲ آبجکت های یکپارچه سازی داده ها
..... ۱۰	۱-۶-۲ جداول حقایق
..... ۱۱	۲-۶-۲ جداول ابعادی
..... ۱۳	۷-۲ اهداف معماری انباره داده
..... ۱۳	۸-۲ سیکل پروژه های داده کاوی
..... ۱۳	۱-۸-۲ تشکیل مسئله کاری
..... ۱۴	۲-۸-۲ جمع آوری داده
..... ۱۴	۳-۸-۲ پاک سازی و تبدیل داده ها
..... ۱۵	۴-۸-۲ ساخت مدل
..... ۱۶	۵-۸-۲ ارزیابی مدل
..... ۱۶	۶-۸-۲ گزارش دادن و پیشگویی
..... ۱۶	۷-۸-۲ یکپارچه سازی کار
..... ۱۶	۸-۸-۲ مدیریت مدل
..... ۱۷	۹-۲ کاوش OLAP در برابر کاوش رابطه ای
..... ۱۸	۱۰-۲ وظایف داده کاوی
..... ۱۸	۱۱-۲ کاوش الگوهای تکرار شونده، انجمنی و وابسته
..... ۲۷	۱۲-۲ الگوریتم خوشه بندی k-means
..... ۳۰	۱۳-۲ الگوریتم دسته بندی K نزدیکترین همسایه
..... ۳۲	۱۴-۲ درخت تصمیم گیری

فصل سوم: تکنولوژی شناسایی امواج رادیویی

۳۴	۱-۳ تاریخچه
۳۵	۲-۳ عناصر یک سیستم RFID
۳۵	۱-۲-۳ تگ های RFID
۳۷	۲-۲-۳ تگ خوان
۳۸	۳-۲-۳ آنتن ها و پیام های رادیویی
۳۹	۴-۲-۳ شبکه
۴۰	۳-۳ کاربردهای RFID
۴۰	۱-۳-۳ مشاهده زنجیره موجودی و مدیریت فهرست اموال
۴۱	۲-۳-۳ جاسازی تگ های RFID
۴۱	۴-۳ کاربردهای دیگر RFID

فصل چهارم: پیشنهاد تحقیق

۴۴	۱-۴ مقدمه
۴۴	۲-۴ یکپارچه سازی داده های RFID
۴۵	۳-۴ مروری بر عمده ترین تحقیقات

فصل پنجم: مدل پیشنهادی: یک مدل جدید یکپارچه سازی داده های RFID

۴۸	۱-۵ مقدمه
۴۸	۲-۵ تشریح سیستم RFID
۴۹	۳-۵ مدل یکپارچه سازی جدید
۵۰	۴-۵ ساختار جدید ارائه شده

فصل ششم: طراحی و پیاده سازی مدل پیشنهادی

۵۲	۱-۶ مقدمه
۵۳	۲-۶ پاک سازی داده ها
۵۳	۱-۲-۶ مقادیر مفقود
۵۴	۲-۲-۶ داده های خطدار
۵۶	۳-۲-۶ فرآیند پاک سازی داده ها
۵۸	۳-۶ پاک سازی و تبدیل داده ها
۵۹	۴-۶ شماهای یکپارچه سازی
۵۹	۱-۴-۶ شمای ستاره ای
۶۰	۲-۴-۶ شمای برف دانه ای
۶۱	۵-۶ طراحی پایگاه داده رابطه ای و مکعب های OLAP
۶۱	۱-۵-۶ کلیدها و ارتباطات
۶۱	۱۲-۵-۶ فرآیند کس ها
۶۲	۶-۶ فرآیند طراحی انباره داده
۶۲	۱-۶-۶ فرآیند طراحی انباره داده

۶۳	۲-۶-۶ چرا انباره داده جداگانه داریم
۶۳	۶-۳-۳ گام‌های طراحی و ساخت انباره داده
۶۵	۷-۶ از بکارچه سازی داده تا داده کاوی
۶۵	۷-۷-۶ استفاده از انباره داده
۶۷	۷-۸ ساخت انباره داده
	فصل هفتم: ارزیابی مدل پیشنهادی
۶۹	۱-۷ مقدمه
۷۰	۲-۷ اعتبارسنجی دسته‌های ۱۰ تایی
۷۰	۳-۷ نتایج به کارگیری ساختار فشرده سازی
۷۲	۴-۷ دسته‌بندی با استفاده از درخت تصمیم‌گیری
۷۳	۵-۷ به کارگیری الگوریتم کاوش قوانین انجمنی
۷۳	۶-۷ دقیق ساختار فشرده سازی
	فصل هشتم: نتیجه گیری و کارهای آینده
۷۵	۱-۸ مقدمه
۷۶	۲-۸ نتیجه گیری
۷۸	۳-۸ کارهای آتی
۸۰	مراجع

فهرست شکل‌ها

صفحه	عنوان
۶	شکل ۱-۲ دیدگاه کلی از مراحل ترکیب فرآیند کشف دانش.....
۱۰	شکل ۲-۲ مکعب داده.....
۱۸	شکل ۳-۲ دید رابطه‌ای از یک مدل کاوش OLAP.....
۲۲	شکل ۴-۲ تولید مجموعه آیتم‌های کاندید و مجموعه آیتم‌های تکرار شونده.....
۲۳	شکل ۵-۲ تولید و هرس مجموعه آیتم‌های C_3 از L_2 با استفاده از خاصیت Apriori.....
۲۴	شکل ۶-۲ الگوریتم Apriori برای کشف مجموعه آیتم‌های تکرار شونده برای کاوش قوانین انجمانی بولی.....
۲۹	شکل ۷-۲ تغییر در محل خوشه نمایش دهنده در طول اجرای الگوریتم K-meanss.....
۳۰	شکل ۸-۲ اثر مقداردهی اولیه نامطلوب بر نتایج K-means.....
۳۱	شکل ۹-۲ الگوریتم دسته بندی k نزدیک‌ترین همسایه.....
۵۵	شکل ۱-۶: متدهای binning برای هموارسازی داده‌ها.....
۵۶	شکل ۲-۶ یک طرح دو بعدی از داده‌های متري.....
۵۹	شکل ۳-۶ شمای ستاره‌ای.....
۶۰	شکل ۴-۶ شمای برف دانه‌ای.....
۶۷	شکل ۵-۶ شمای برف دانه‌ای از انباره داده ساخته شده.....
۶۸	شکل ۶-۶ شمای ستاره‌ای از انباره داده ساخته شده.....
۷۶	شکل ۱-۸ فرآیند کلی پروژه
۷۷	شکل ۲-۸ فلوچارت سیکل پروژه
۷۸	شکل ۳-۸ فرآیند ساخت انباره داده

چکیده:

تکنولوژی شناسایی از طریق امواج رادیویی یا به صورت خلاصه تر تکنولوژی رادیو شناسه چندین سال است که به عنوان یکی از تکنولوژی های کارآمد و مفید مطرح شده است. این تکنولوژی در کاربردهای زیادی به کار گرفته شده و نتایج مطلوبی نیز داشته است از جمله در مدیریت زنجیره تأمین، مدیریت چمدان های فروشگاهها، خرده فروشی ها، کترل دسترسی، شناسایی حیوانات خانگی و بیماران آزمایشی. در ساده ترین سطح این تکنولوژی اجزه می دهد یک بارکد از راه دور و در خطی غیر مستقیم با استفاده از امواج رادیویی خوانده شود. بارکدها در سیستم های رادیو شناسه معمولاً کدهای یونیکی هستند که به هر شیء اختصاص می یابند. این کد روی تراشه ای متصل به یک آنتن ذخیره می شود. به مجموعه این تراشه و آنتن تگ گفته می شود. از آنتن برای انتقال اطلاعات تراشه به تگ خوان استفاده می شود. تگ خوان امواج رادیویی را از تگ ها دریافت و آن ها را به اطلاعات قابل انتقال به کامپیوتر تبدیل می کند. این اطلاعات یا داده ها در کامپیوتر ذخیره و پردازش می شوند. داده هایی که به وسیله ای سیستم های رادیو شناسه تولید می شوند بسیار بزرگ و حجمی هستند. متدهای قدیمی در این مورد کارساز نیست و واضح است که با استفاده از تکنیک های جدید و کارآمدی برای پردازش این داده های حجمی به کار گرفته شود. استفاده از تکنیک های داده کاوی برای مدل کردن ارتباطات و کشف الگوهای مخفی در داده های بزرگ مفید به نظر می رسد. یکپارچه سازی داده های تکنولوژی رادیو شناسه آن ها را به صورت ابعادی، در فرمت مشخصی مرتب می کند و در نتیجه کار تحلیل و آنالیز راحت تر می شود. لذا قبل از کار گیری الگوریتم های داده کاوی ابتدا با استفاده از قوانین یکپارچه سازی، داده ها را به انباره داده تبدیل خواهیم کرد. در این پروژه هدف و تمرکز را بر روی مراحل پیش پردازش قرار داده و سعی شده با بهبود این مراحل گامی مؤثر در جهت بهبود داده کاوی برداشته شود. در این پروژه با ارائه مدل جدیدی از یکپارچه سازی داده ها که در آن علاوه بر فازهای موجود در مدل قدیمی یعنی فاز جمع آوری داده، فاز پاک سازی و فاز تبدیل داده، فاز دیگری به این مدل اضافه شد که آن فاز فشرده سازی است و برای فشرده سازی داده های کاربرد موردنظر در این پروژه ساختار جدیدی ارائه شد که البته این ساختار برای تمامی کاربردهایی از RFID که یک سری عملیات ثابت و تکراری بر روی داده ها انجام می شوند نیز قابل اعمال است. با به کار گیری این ساختار، داده هایی که از یک خط تولید موتور خودرو به دست آمده بودند و تعداد آن ها ۳۵۲، ۱۲۷، ۷۵ بود را تا ۰.۵٪ مقدار اولیه فشرده کردیم، که باعث بهبود انباره داده در هنگام اعمال الگوریتم های داده کاوی شد. علاوه بر فشرده سازی بسیار زیاد داده ها مزیت دیگر این ساختار این است که می توان با ذخیره روند فشرده سازی در یک جدول در دیتابیس، داده ها را به داده های اولیه قبل از فشرده سازی جداول اضافی که بر روی انباره داده انجام شد این بود که از نرمال بودن جداول در انباره داده به منظور کاهش تعداد بازگرداند. هم چنان کار گیری که بر روی انباره داده خواهد شد این بود که از نرمال بودن جداول در انباره داده کار گیری انجام شد، که آن چنان که نشان داده خواهد شد این کار نیز موجب بهبود زمان اجرای الگوریتم داده کاوی شد. با به کار گیری الگوریتم های داده کاوی بر روی انباره داده ساخته شده با استفاده از ساختار جدید میزان خطا را ۱۶ درصد به دست آوردیم که نشانده نهاده این است که روش ارائه شده روش قابل قبولی است.

واژه های کلیدی: تکنولوژی شناسایی از طریق امواج رادیویی، تکنیک های داده کاوی، یکپارچه سازی، انباره داده.

فصل اول

مقدمه

۱-۱ معرفی

تکنولوژی شناسایی از طریق امواج رادیویی^۱ یا رادیو شناسه اول بار در جنگ جهانی دوم توسط آلمانها برای شناسایی هواپیماهای خودی از دشمن استفاده شد. آن‌ها هواپیماهای خودی را با استفاده از سیگنال‌های کد شده‌ای که به وسیله‌ی امواج رادیویی فرستاده می‌شد تشخیص می‌دادند. پس از آن این تکنولوژی بسیار مورد استفاده قرار گرفت و نتایج قابل قبولی نیز به جای گذاشت. RFID تکنولوژی است که به یک حس‌گر (تگ‌خوان^۲) اجازه می‌دهد تا از مسافت دور و در خطی غیر مستقیم یک شناسه یونیک، که با استفاده از سیگنال‌های رادیویی با تگ‌های^۳ نسبتاً ارزان قیمت به آیتم‌ها وابسته شده‌اند را بخواند. این سیستم قابل مقایسه با سیستم‌های بارکد است ولی تفاوت آن‌ها در این است که در سیستم‌های RFID برخلاف سیستم‌های بارکد نیاز نیست که تگ‌خوان و تگ در خط مستقیم قرار داشته باشند و هم چنین در سیستم‌های بارکد فاصله بین تگ و تگ‌خوان حداقل چند سانتی‌متر است اما در سیستم‌های RFID این فاصله تا ۱۵ متر و حتی با تقویت آتن‌ها به چند برابر این مقدار افزایش می‌یابد. RFID روش بهتری برای سیستم‌های شناسایی بارکد پیشنهاد می‌دهد و کاربردهایی مثل ردیابی آیتم‌ها^۴، مدیریت زنجیره‌های موجودی^۵، شناسایی حیوانات خانگی، شناسایی بیماران، ردیابی پرسنل و بسیاری موارد دیگر را تسهیل می‌کند. این تکنولوژی مدیریت زنجیره‌های موجودی، مسیریابی و توزیع محصولات را ساده می‌کند و هزینه‌ها را با بهبود کارآیی کاهش می‌دهد. شرکت‌های بزرگ مثل Albertsons، Target و Walmart سیستم‌های RFID را در انبار و مراکز توزیع خود به کار گرفته‌اند. شرکت Walmart از این سیستم برای مدیریت زنجیره تأمین خود

¹ RFID: Radio Frequency Identification

² Reader

³ Tag

⁴ Item Tracking

⁵ Supply Chain

استفاده کرده است به این ترتیب که از زمانی که کالای مورد نیاز خود را از کارخانه تولیدی تحویل می‌گیرد و در کامیون یا کشتی بار می‌کند و تا زمانی که به انبار می‌آورند و بعد به قفسه‌های فروشگاه خود منتقل می‌کند این کالاها پیگیری می‌شوند. در این پروژه نیز از یکی از سیستم‌های RFID که در خط تولید موتور خودرو استفاده شده بود بهره می‌بریم. چالش اصلی این است که چگونه شرکت‌ها حجم بالای داده‌های تولیدی کاربردهای RFID را مدیریت و تفسیر کنند. یک شرکت تحقیقاتی^۱ پیش‌بینی کرده است وقتی تگ‌های RFID در سطح آیتم‌ها استفاده شود، در حال حاضر در این شرکت به کالاها به صورت دسته‌ای تگ اختصاص می‌یابد یعنی هر دسته‌ای یک برچسب یا بارکد می‌خورد، شرکت Walmart در یک روز نزدیک به ۷ ترابایت داده تولید خواهد کرد. بنابراین برای این داده‌های حجمی بایست از تکنیک‌های یکپارچه سازی^۲، فشرده‌سازی^۳ و متراکم‌سازی^۴ به عنوان تکنیک‌های مهمی از پیش پردازش برای آماده سازی داده‌ها برای فرآیند داده کاوی استفاده کرد و از تکنیک‌های داده کاوی^۵ برای مدل کردن ارتباطات و کشف الگوهای مخفی استفاده شود[۱].

۱-۲ هدف تحقیق

در سیستم‌های RFID همان طور که ذکر شد داده‌های سطح پایین زیادی تولید می‌شوند و تکنولوژی‌ها و روش‌های قدیمی در مقابل این حجم عظیم داده با چالش‌های اساسی رو به رو خواهند بود. لذا برای استفاده از این داده‌های انبوه در این پروژه ابتدا با استفاده از تکنیک‌های یکپارچه سازی، داده‌ها را برای بهره‌گیری تکنیک‌های داده کاوی آماده می‌کنیم. در این تحقیق هدف و تمرکز را بر روی مراحل پیش پردازش قرار داده و سعی شده با بهبود این مراحل گامی مؤثر در جهت بهبود داده کاوی برداشته شود. تلاش شد تا با ارائه مدل جدیدی از یکپارچه سازی که در آن بعد از فازهای جمع‌آوری، پاک سازی و تبدیل داده، فاز فشرده سازی با ساختار جدید یشنهد شده قرار دارد فرآیند داده کاوی بهبود یابد. با ساختار جدید فشرده سازی و در نتیجه با کاهش حجم داده‌ها زمان اجرای الگوریتم داده کاوی تا حد زیادی کاهش یافت.

با استفاده از مجموعه داده‌های واقعی RFID پروسه داده کاوی تولید الگوهای حقیقی خواهد کرد و چالش‌های داده‌ها نیز واقعی خواهند بود. بنابراین در اختیار داشتن داده‌های سیستم‌های واقعی بسیار مفید می‌باشد، پس بر آن شدیم تا فرآیند داده کاوی و یکپارچه سازی را بر روی این نوع داده‌ها به کار گیریم. از این رو از داده‌های سیستم RFID خط تولید موتور یک شرکت معتبر خودرو سازی استفاده خواهیم کرد.

۳-۱ ساختار پایان نامه

پس از معرفی مختصر در فصل اول ادامه پایان نامه به شرح ذیل ادامه می‌یابد:
در فصل دوم داده کاوی معرفی شده و مراحل پیش پردازش و پردازشی که این تکنیک‌ها به کار خواهند گرفت مورد بحث خواهد بود.

در فصل سوم به صورت تفضیلی به تکنولوژی شناسایی از طریق امواج رادیویی می‌پردازیم، تاریخچه و عناصر اساسی آن را بررسی و سپس به بیان بعضی از کاربردهای آن خواهیم پرداخت.

در فصل چهارم مروری خواهیم داشت بر کارهای انجام شده تا کنون، در زمینه کاری خود و پیشینه تحقیق را بررسی خواهیم نمود.

¹ Venture Development Corporation

² Warehousing

³ Compression

⁴ Aggregate

⁵ Data Mining

در فصل پنجم مدل پیشنهادی ما که یک مدل جدیدی از یکپارچه سازی داده‌ها خواهد بود توضیح داده می‌شود.

در فصل ششم در مورد طراحی و پیاده سازی مدل پیشنهادی توضیحاتی داده خواهد شد.

در فصل هفتم ارزیابی از مدل پیشنهادی خواهیم داشت.

فصل هشتم نتیجه بحث و کارهایی که در آینده باید انجام شود مشخص شده است.

۱-۲ مقدمه

داده کاوی عبارت است از استخراج الگوهای و اطلاعات جالب از داده‌ها در پایگاه داده‌های بزرگ.

داده کاوی را "کشف دانش در داده‌ها"^۱ نیز می‌نامند. کشف دانش در داده‌ها دارای مراحل مختلفی می‌باشد که در اینجا به صورت خلاصه آنها را بیان می‌کنیم:

- استخراج اطلاعات از چندین منبع داده (پایگاه داده)^۲.
- یکپارچه سازی اطلاعات و حذف داده‌های زاید^۳.
- قرار دادن اطلاعات اصلاح شده در انبار داده‌ها^۴.
- انجام عملیات داده کاوی توسط نرم افزارهای مخصوص.
- نمایش نتایج به صورت قابل فهم مانند گزارش و گراف^۵.

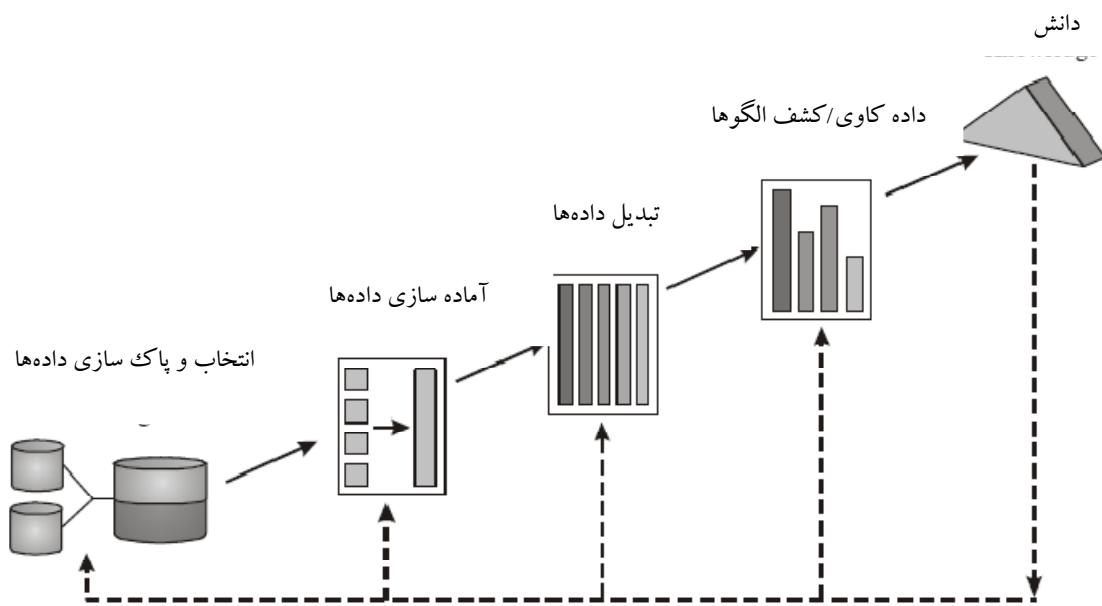
¹ Knowledge Discovery in Databases (KDD)

² Data Gathering

³ Data Cleaning

⁴ Data Warehousing

⁵ Result Presentation



شکل ۱-۲ دیدگاه کلی از مراحل ترکیب فرآیند کشف دانش

۲-۲ ویژگی‌های داده‌های RFID

طبيعت داده‌های RFID اساساً از داده‌های رابطه‌ای قدیمي و تكنولوژي‌های انباره داده متفاوت است، اين تفاوت چالش‌های تحقيقاتي بزرگی را مطرح می‌کند و نياز است تا اين تفاوت‌ها در سистем‌های مدیريت داده‌های RFID در نظر گرفته شود. اين ویژگی‌ها عبارتند از:

داده‌های ساده: داده‌هایی که از يك کاربرد RFID توليد می‌شود به عنوان رشته‌اي از تاپل‌های RFID به فرم (EPC, location, time) دیده می‌شود، که EPC کد شناسايي يك آيتم است. Location موقععيتي است که تگ‌خوان RFID آيتم را اسکن می‌کند و time زمان خواندن است. همان طور که مشخص است داده‌های RFID اطلاعات ييشتری را شامل نمی‌شوند. به منظور تبدیل اين داده‌های خام به فرمی که برای کاربردهای مهم قابل استفاده باشد چندين سطح استنتاج بايست انجام شود.

سيل عظيم^۱: يكى از بزرگ‌ترین مشكلات در RFID نحوه برخورد با سيل عظيم داده‌ها است. به عنوان مثال، Wal-Mart در سه روز به اندازه کل کتابخانه‌های آمريكا داده توليد می‌کند و اين فقط مشكل شركت Wal-Mart نيست. حتى توسعه بسيار کم RFID گيگابايت داده در هر روز توليد می‌کند و داده‌های در مورد time, location, EPC به صورت پيوسته فرستاده می‌شود.

عدم دقت: يكى از پارامترهای اوليه که اتخاذ گسترده تكنولوژي RFID را محدود می‌سازد عدم دقت رشته داده‌هایي است که توسط تگ‌خوان توليد می‌شود. نرخ خواندن ملاحظه شده در دنيا واقعی رشد RFID اغلب در رنج ۶۰-۷۰٪ است. متاسفانه اين نرخ‌های خطا که به داده‌های خام منتقل می‌شود آن‌ها را برای کاربردهای سطح بالاي RFID کم فايده می‌کند. بنابراین نياز است تا اين داده‌ها قبل از تعزييه سистем به اين داده‌های غيرقابل اعتماد زدوده شوند. در نتيجه داده‌ها در RFID معمولاً بى دقت هستند.

^۱ Large in-flood

موقعی و فاصله‌ای: کاربردهای RFID به صورت پویا مشاهدات (مثلاً تغییرات منظم موقعیت‌های آیتم‌های تگ‌دار) را تولید می‌کنند و داده‌ها تغییرات حالت‌ها را در برابر دارند. بنابراین در مدیریت داده‌های RFID ضروری است که همه داده‌ها به وسیله مدل داده‌ای رسا و با معنی مناسب برای سطح کاربرد مدل شوند. با دانستن این حقیقت که نه تنها تگ‌خوان بلکه تگ‌ها نیز داخل PDAها، تلفن‌های همراه و آججکت‌های متحرک قرار می‌گیرند بنابراین هم آیتم تگ‌دار و تگ‌خوان حرکت ثابتی دارند [۲،۳].

۳-پیش پردازش

همان طور که ذکر شد داده‌های RFID از دقت بسیار پایینی برخوردارند و شامل داده‌های خط‌دادار(داده‌های نامتعارف^۱، مقادیر غیر دقیق و داده‌های اشتباه)، داده‌های ناسازگار(نام‌ها یا کدهای متفاوت، مقادیر غیر ممکن یا خارج از محدوده) و ناکامل(صفات از دست رفته یا مقادیر صفات از دست رفته) می‌باشد بنابراین برای بالا بردن کیفیت داده کاوی بایست داده‌های با کیفیتی نیز در اختیار داشت. در نتیجه پیش پردازش یک گام مهم در موفقیت داده کاوی به حساب می‌آید. گام‌های پیش پردازش معمولاً به قرار زیر است [۴]:

استخراج خصایص^۲: برای شناسایی صفات مرتبط برای یک کار داده کاوی با استفاده از تکنیک‌هایی مانند کشف رخدادها، انتخاب خصایص و تبدیل خصایص.

پاک سازی داده‌ها: برای بالا بردن کیفیت داده‌ها با رفع مشکلاتی مثل داده‌های خط‌دادار، داده‌های پرت، مقادیر از دست رفته و خطاهای مقیاس‌گذاری و درجه بندی.

تغییر شکل یا تبدیل داده‌ها^۳: شامل نرمال کردن داده‌ها

کاهش داده‌ها^۴: برای بهبود زمان پردازش یا کاهش تغییر پذیری در داده‌ها با استفاده از تکنیک‌هایی مثل نمونه‌گیری آماری یا تجمع داده‌ها.

کاهش بعد: برای کاهش تعداد خصایص حاضر در الگوریتم داده کاوی؛ بعضی از تکنیک‌های کاهش بعد خطی یا غیر خطی (PCA، principal component analysis (PCA)، locally linear embedding (LLE) هستند.

یکپارچه سازی داده‌ها: شامل سازگاری داده‌ها، تجمعی چندین منبع داده و deduplication , geocoding . ساختن و استفاده از انباره داده یک وظیفه پیچیده است زیرا نیاز به مهارت‌هایی در زمینه‌های کسب و کار، تکنولوژی و مدیریت برنامه دارد. در راستای مهارت‌های کسب و کار ساختن یک انباره داده شامل فهمیدن این که چنین سیستم‌هایی چگونه ذخیره می‌شوند و داده‌هایشان چگونه مدیریت می‌شوند، استخراج کننده‌ها چگونه ساخته شوند تا داده‌ها از سیستم‌های عملیاتی به انباره داده منتقل شوند، نرم افزار به روز نگه داشتن انباره چگونه ساخته شود تا انباره

¹ Outlier

² Feature extraction

³ Data Transformation

⁴ Data Reduction

⁵ Data integration

داده را با داده‌های سیستم عملیاتی به صورت منطقی به روز نگه دارد. استفاده از انباره داده شامل فهم اهمیت و معنی و مفهوم داده‌های آن است و هم چنین فهم و ترجمه نیازمندی‌های کاری به پرس و جویی که بایست توسط انباره پاسخ داده شود. در راستای مهارت‌های تکنولوژی، تحلیل‌گرها بایست بفهمند چگونه اطلاعات کمی را ارزیابی کنند و حقایق را بر اساس نتایج از اطلاعات تاریخی در انباره داده استخراج کنند. این مهارت‌ها شامل توانایی کشف الگوها و گرایش‌ها، پیش‌بینی گرایش‌ها بر اساس تاریخ و نظر به غیر متعارف‌ها و ارائه توصیه‌های مدیریتی منسجم بر اساس این آنالیزهاست. نهایتاً مهارت‌های مدیریت برنامه شامل نیاز به رو به رو شدن با خیل عظیم تکنولوژی، فروشنده‌گان و کاربران نهایی است که نتایج را با زمان و هزینه قابل قبول تحويل می‌گیرند [۵، ۶].

۲-۴ انباره داده چیست

یکپارچه سازی داده سازمان و ابزاری برای اجرای کارها فراهم می‌آورد تا داده‌ها برای گرفتن تصمیمات استراتژیک به صورت سیستماتیک سازمان دهی، فهمیده و استفاده شوند. سیستم انباره داده در دنیا رقبای امروز یک ابزار ارزشمند محسوب می‌شود. در سال‌های اخیر بسیاری از شرکت‌ها میلیون‌ها دلار برای ساخت انباره داده هزینه کرده‌اند.

اما انباره داده دقیقاً چیست؟ انباره داده به طرق مختلفی تعریف می‌شود و این باعث شده تا فرموله کردن یک تعریف کارا سخت باشد. در کلام انباره داده دیتابیسی عملیاتی و سازمان یافته است. سیستم انباره داده باعث جمع‌آوری سیستم‌های کاربردی مختلف می‌شود. آن‌ها پردازش اطلاعات را با فراهم کردن پلت فرمی از داده‌های یک شکل شده برای آنالیز پشتیبانی می‌کنند.

طبق گفته William H. Inmon انباره داده یک مجموعه‌ای از داده‌های موضوع گرا، یک شکل شده، با زمان‌های مختلف و غیرفار است که پروسه مدیریت تصمیم گیری را پشتیبانی می‌کند. این تعریف کوتاه‌اما جامع طرح اصلی انباره داده را نمایان می‌سازد. چهار کلید واژه موضوع گرا، یک شکل شده، با زمان‌های مختلف و غیرفار انباره داده را از سایر سیستم‌های ذخیره داده مثل سیستم‌های دیتابیس رابطه‌ای، سیستم‌های پردازش تراکنش و سیستم‌های فایل متمایز می‌سازد. نگاهی اجمالی به این چهار واژه داریم:

موضوع گرا: انباره داده بر اساس یک موضوع خاص مثل مشتری، محصول و فروش نسبت به تمرکز روی عملیات روز به روز و فرآیند تراکنش‌های یک سازمان سازمان دهی می‌شود. انباره داده روی مدل کردن و آنالیز داده‌ها برای تصمیم گیری متمرکز است. بنابراین انباره داده یک دید مختصر و ساده حول موضوع خاص با حذف داده‌هایی که در فرآیند پشتیبانی تصمیم گیری مفید نیستند فراهم می‌کند.

یک شکل شده: یک انباره داده معمولاً با گردآوری چندین منبع ناهمگن مثل دیتابیس رابطه‌ای، فایل و رکوردهای تراکنشی آنلاین ساخته می‌شود. تکنیک‌های پاک سازی داده و یک شکل سازی داده برای تأمین سازگاری در تبدیل نام‌ها، ساختار رمزگذاری، مقیاس خصیصه‌ها و غیره به کار گرفته می‌شوند.

با زمان‌های مختلف: داده‌ها به منظور فراهم آوردن اطلاعاتی از یک چشم انداز تاریخی (مثلاً ۵-۱۰ سال گذشته) ذخیره می‌شوند. هر ساختار کلیدی در اینباره داده به صورت صریح یا ضمنی شامل عنصری از زمان است.

غیر فرار: یک اینباره داده از لحاظ فیزیکی همیشه از داده‌های تبدیل شده کاربردی در محیط‌های عملیاتی، جدا ذخیره شده است. به خاطر این جدا سازی یک اینباره داده به پردازش تراکنش‌ها، ترمیم و مکانیسم کنترل همزمانی نیازی ندارد. فقط به دو عملیات در دسترسی به داده‌ها نیاز است: لود اولیه داده و دسترسی داده‌ها^[۴].

۵-۲ یکپارچه‌سازی داده‌ها

یکپارچه‌سازی داده‌ها مجموعه‌ای از تکنولوژی‌های پشتیبان تصمیم‌گیری است که تصمیم‌ها را سریع‌تر و بهتر می‌کند. اگر داده‌های مناسب در یک اینباره داده جمع‌آوری و ذخیره شوند پتانسیل داده کاوی افزایش می‌یابد. یک اینباره داده یک سیستم مدیریت پایگاه داده رابطه‌ای است که برای تسهیل گزارش‌گیری و تحلیل ساخته می‌شود. یکپارچه‌سازی داده‌ها یک تکنیک جدید است که داده‌های عملیاتی را استخراج می‌کند و بر ناسازگاری میان فرمتهای داده‌ای متفاوت غلبه می‌کند.

اینباره داده پایگاه داده‌ای با خصوصیات خاص است. داده‌های آن نتیجه تغییر شکل^۱، بهبود کیفیت و یکپارچه‌سازی داده‌ها می‌باشد. تغییر شکل داده پروسه تغییر فرم یا ساختار خصیصه‌های موجود است. تغییر شکل با پاک سازی یا غنی سازی^۲ داده‌ها متفاوت است زیرا خصیصه‌های موجود را تصحیح نمی‌کند و خصیصه‌ای نیز اضافه نمی‌کند بلکه فقط خصایص موجود را برای هدف داده کاوی بهبود می‌دهد.

برای طراحی اینباره داده رابطه‌ای دو روش وجود دارد یکی تکنیک‌های مدل سازی ابعادی^۳ را به کار می‌گیرد و دیگری بر اساس مفهوم materials است. مدل‌های ابعادی داده را در ساختار cube نمایش می‌دهند و با مدیریت داده OLAP داده‌ها سازگارتر نمایش داده می‌شوند. هدف مدل ابعادی:

الف) تولید ساختار پایگاه داده‌ای است که برای کاربران نهایی فهم و نوشتمن پرس و جو ساده باشد.
ب) حداکثر کردن کارآیی پرس و جوها

این اهداف با مینیمم کردن تعداد جداول و روابط بین آن‌ها به دست می‌آید. دیتاپس‌های نرمال خصوصیاتی دارند که برای سیستم‌های OLTP مناسب است و برای اینباره داده مناسب نمی‌باشد:

الف) ساختار آن برای فهم و استفاده برای کاربران نهایی آسان نیست. در سیستم‌های OLTP این مشکل ساز نیست زیرا کاربران نهایی با دیتاپس با استفاده از یک لایه نرم‌افزاری تعامل دارند.

ب) افزونگی داده‌ها کاهش می‌یابد و این کارآیی به روز رسانی را حداکثر می‌کند اما بازیابی را سخت‌تر می‌کند. افزونگی در اینباره داده یک مشکل نیست زیرا داده‌ها به صورت آنلاین به روز نمی‌شوند.

مفاهیم ابتدایی مدل‌های ابعادی حقایق^۴، ابعاد و مقیاس‌ها^۵ هستند. یک حقیقت مجموعه‌ای از آیتم‌های داده‌ای مرتبط به هم است که شامل مقیاس‌ها و داده‌های مفهومی است و آیتم‌های کاری یا تراکنش‌های کاری را در بر

¹ Transformation

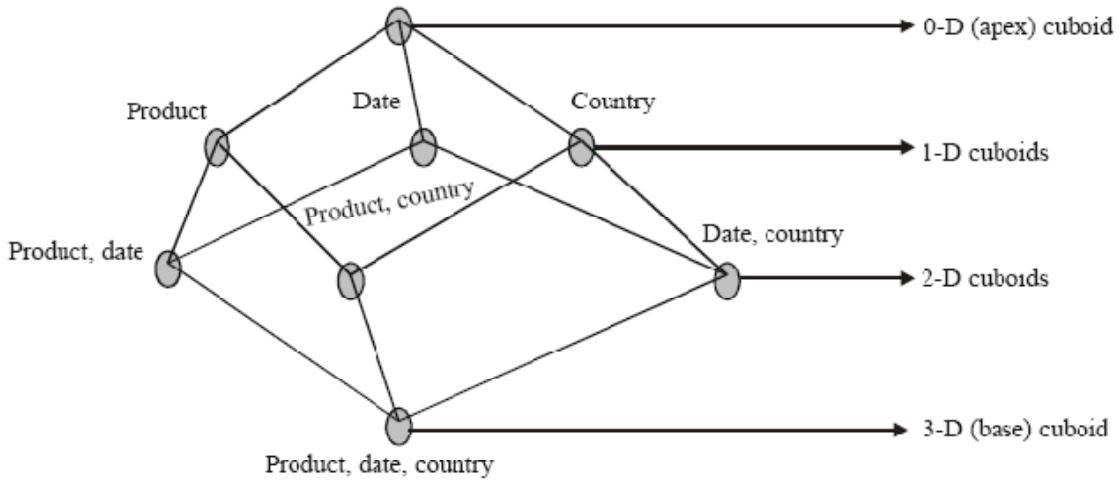
² Data Enrichment

³ Dimensional Modeling

⁴ Facts

⁵ Dimensions

می‌گیرد. یک بعد مجموعه‌ای از داده‌هایی است که یک بعد کاری را تشریح می‌کنند. ابعاد زمینه مفهومی حقایق را تعیین می‌کنند. یک مقیاس یک خصیصه عددی از یک حقیقت است، کارآیی یا رفتار کاری وابسته به ابعاد را ارائه می‌دهد. اگر انباره داده‌ای برای پشتیبانی کاربران برای پرس و جوی داده‌ها طراحی شود نیازمندی‌های طراحی مکعب OLAP نتیجه طبیعی مدل ابعادی خواهد بود.^[۴,۷]



شکل ۲-۲ مکعب داده

۶-۲ آبجکت‌های یکپارچه سازی داده‌ها

انواع آبجکت‌هایی که در زیر آمده معمولاً در شمای انباره داده ابعادی استفاده می‌شود:

جداول حقایق: جداول بزرگی در شمای انباره که مقیاس‌های کاری را در خود ذخیره می‌کنند. این جداول اصولاً شامل حقایق و کلیدهای خارجی به جداول ابعادی است. جداول حقایق معمولاً شامل داده‌های عددی و افزایشی است که می‌توانند آنالیز و پرسی شوند. مثال از این نوع جداول شامل فروش، هزینه و سود است.

جداول ابعادی: این نوع جداول هم چنین جداول مرجع یا lookup نیز گفته می‌شود و شامل داده‌های ایستای وابسته در انباره است. جداول ابعادی اطلاعاتی را ذخیره می‌کند که برای پرس و جوها استفاده می‌شود. این جداول معمولاً متنی و تشریحی هستند و به عنوان هدرهای سطرهای مجموعه نتایج استفاده می‌شوند. مثالی از این جداول شامل جداول مشتری، زمان، مکان، محصول و تولید کننده است [۸,۹].

٦-٢ جداول حقائق

یک جدول حقیقت دو نوع ستون دارد: ستون‌هایی شامل حقایق عددی (معمولاً به آن‌ها اندازه^۲ می‌گویند) و ستون‌هایی که کلید خارجی به جداول ابعادی هستند. یک جدول حقیقت هم چنین شامل حقایقی در سطح جزئی یا حقایقی که جمع‌آوری شده است می‌باشد. جدول حقیقت که شامل حقایق جمع‌آوری شده می‌باشد اغلب جداول خلاصه^۳ نامیده می‌شوند. یک جدول حقیقت معمولاً شامل حقایق افزایشی، نیمه افزایشی یا غیر افزایشی است. حقایق

1 Measures

² Measurement

³ Measurement Summary Tables