



مرکز تحقیقات فناوری اطلاعات در امور سلامت با همکاری معاونت بهداشتی دانشگاه علوم پزشکی اصفهان

داده کاوی در نظام سلامت

دکتر محمد ستاری

دکترای مهندسی کامپیوتر - نرم افزار

عضو هیات علمی گروه مدیریت و فناوری اطلاعات سلامت دانشگاه علوم پزشکی اصفهان

عضو مرکز تحقیقات فناوری اطلاعات در امور سلامت



فهرست مطالب

- هوش مصنوعی
- مقدمه ای بر داده کاوی
- تعریف و اهمیت داده کاوی
- مراحل داده کاوی
- کاربرد داده کاوی در حوزه‌ی سلامت
- انواع داده کاوی بر حسب نوع داده
- تکنیک‌های داده کاوی
- ارزیابی داده کاوی
- نرم افزار رپیدماینر



تاریخچه هوش مصنوعی

- شروع و سرچشمہ هوش مصنوعی به سال های جنگ جهانی دوم بر می گردد. زمانی که نیروهای آلمانی برای رمز نگاری و ارسال ایمن پیام ها از ماشین enigma استفاده می کردند و دانشمند انگلیسی، آلن تورینگ در تلاش برای شکست این کدها برآمد. تورینگ به همراه تیمش ماشین bombe را ساختند که enigma را رمز گشایی می کرد. هر دو ماشین enigma و bombe پایه های یادگیری ماشینی machine learning هستند که یکی از شاخه های هوش مصنوعی یا همان Artificial intelligence می باشد.
- تورینگ ماشینی را هوشمند می دانست که بدون اینکه به انسان حس صحبت با ماشین را بدهد، با او ارتباط برقرار کند و این مسئله پایه علم هوش مصنوعی است یعنی ساخت ماشینی که همانند انسان فکر، تصمیم گیری و عمل کند.

هوش مصنوعی

هوش مصنوعی یک فیلد مطالعاتی است که سعی دارد قابلیت‌های استدلال، برنامه‌ریزی، حل مسئله و یادگیری را در کامپیوتر ایجاد نماید.





مقدمه (داده کاوی)

از هنگامی که رایانه در تحلیل و ذخیره سازی داده ها بکار رفت (۱۹۵۰) پس از حدود ۲۱ سال حجم داده ها در پایگاه داده ها دو برابر شد. ولی پس از گذشت دو دهه و همزمان با پیشرفت فن آوری اطلاعات، هر دو سال یکبار حجم داده ها دو برابر شده و همچنین تعداد پایگاه داده ها با سرعت بیشتری در حال رشد است.

حال با ورود سیستم های یکپارچه اطلاعاتی، لحظه به لحظه به حجم داده های مربوط اضافه شده و باعث به وجود آمدن انبارهای عظیمی از داده ها شده است.

سازمان ها از لحاظ داده غنی از لحاظ دانش ضعیف



تعريف داده کاوی

- ▶ فلسفه‌ی داده کاوی این است که آینده بسیار به گذشته شبیه است.
- ▶ داده کاوی به شما کمک می‌کند تا رفتار کسب و کار خود در گذشته را دقیق بشناسید و بر اساس آن آینده را با تقریب بالایی پیش بینی کنید.

مطالعات داده کاوی

► مقطعي

► گذشته نگر






تعريف داده کاوی

▶ به مجموعه‌ای از روش‌های قابل اعمال بر پایگاه داده‌های بزرگ و پیچیده به منظور کشف الگوهای پنهان و جالب توجه نهفته در میان داده‌ها، داده کاوی گفته می‌شود.





مراحل تبدیل داده به دانش





مشکلات قابل حل توسط داده کاوی

- ▶ مسئله‌ای پیچیده و ناساخت یافته و یا نیمه ساخت یافته
- ▶ داده‌های مرتبط وجود داشته باشند و به آنها دسترسی داشت
- ▶ داده‌ها در یکجا مجتمع شده و انباره داده‌ها ایجاد شود.
- ▶ توانایی کامپیوترها امکان استفاده از نرم افزارهای مرتبط با داده کاوی را به ما بدهند
- ▶ مدیران نیاز به استفاده از دانش استخراج شده از داده‌ها را حس کرده باشند

چرا داده کاوی

۹۰ درصد اطلاعات دنیا دیجیتال را بدون داده‌های ساختار (unstructured data) تشکیل می‌دهد.

منجر به تصمیمات واقع بینانه می‌شود.

سبب تکرار تصمیمات سودآور رخ داده در گذشته می‌گردد.





اهمیت داده کاوی در حوزه سلامت

امروزه صنعت بهداشت و درمان مقادیر زیادی داده پیچیده در مورد منابع بیمارستانی ، تشخیص بیماری ها ، پرونده های الکترونیکی بیماران ، تجهیزات پزشکی و غیره تولید می کند.

مقادیر زیادی از داده ها یک منبع کلیدی برای پردازش و تجزیه و تحلیل برای استخراج دانش است که پشتیبانی از صرفه جویی در هزینه و تصمیم گیری را امکان پذیر می کند.

کاربرد داده کاوی در حوزه سلامت



۱) تشخیص، درمان بیماری

۲) مدیریت منابع پزشکی

۳) جلوگیری از سو استفاده و تقلب

۴) کرونا



تشخیص، درمان بیماری

داده های سوابق درمانی خود را استخراج کرده است تا داروهای مناسب را کشف کنند

از طریق مطالعه ی گذشته نگر، می تواند الگوهای تشخیصی پر تکرار با میزان اطمینان بالا را استخراج نماید و این الگوها را با مشاوره با یک متخصص ارزیابی نماید و از این الگوها در جهت پیشگیری از بیماری ها استفاده نماید



مدیریت منابع پزشکی

- ▶ کاهش طول مدت اقامت بیمار
- ▶ جلوگیری از عوارض بالینی
- ▶ انتخاب بهترین روش ها
- ▶ ارائه اطلاعات مناسب به پزشکان
- ▶ کاهش هزینه ها



جلوگیری از سو استفاده و تقلب

اداره کل اهالی پزشکی یوتا با تحلیل انبوه داده های تولید شده توسط میلیون ها نسخه ، دوره عملیاتی و درمانی را برای شناسایی الگوهای غیرمعمول و کشف تقلب استخراج کرده است

شناسایی افرادی که سواستفاده انجام داده اند

کاربرد داده کاوی در کرونا



- ▶ ۱) **پیش بینی آغاز شیوع:** از تکنیک های داده کاوی و یادگیری ماشین برای پیش بینی یا تخمین حالت های آینده یک سیستم یا محیط استفاده می شود. یکی دیگر از حوزه هایی که مدل سازی پیش بینی مبتنی بر هوش مصنوعی در آن پررنگ شده است، حوزه شناسایی بیماری های واگیرداری مانند ویروس کرونا است. به عنوان مثال شرکت بلودات واقع در کانادا به خوبی شیوع کووید ۱۹ را در دهم دی ماه ۱۳۹۸ در کشور چین پیش بینی و اعلام کرد.


- ▶ ۲) **پیش بینی و مدل سازی نحوه گسترش:** پژوهشگران دانشگاه ساوت همپتون نحوه شیوع این بیماری را در طی جشن های ۴۰ روزه ای سال نو که بیشترین مسافرت ها در آن رخ می دهد، بر اساس داده های انجمن بین المللی حمل و نقل هوایی و داده های مکان یابی با کمک الگوریتم های داده کاوی پیش بینی کردند.

کاربرد داده کاوی در کرونا


▶ ۳) تشخیص بیماری: یکی از کاربردهای داده کاوی در تشخیص بیماری کرونا استفاده از سی تی اسکن ریه افراد است. این الگوریتم‌ها از دقت بالایی برخوردار است و با استفاده از تصاویر سی تی اسکن هزاران مورد تأیید شده مبتلا به کرونا ارائه شده است. سیستم به طور رسمی توسط شرکت علی بابا (غول تکنولوژیک چین) ارائه شد و در صدها بیمارستان به کار گرفته شد. یکی دیگر از موارد استفاده داده کاوی برای تشخیص ویروس کرونا، سامانه‌های اندازه گیری دمای بدن برای تشخیص تب است. دو نمونه از این سامانه‌ها توسط شرکت‌های بایدو و مگوی توسعه داده شده‌اند. هر دوی این سامانه‌ها از ترکیب هوش مصنوعی و دوربین‌های حرارتی برای شناسایی افراد مشکوک به کرونا در مترو و در معابر پرتردد استفاده می‌کنند. سامانه شرکت مگوی می‌تواند با خطای $0,3^{\circ}$ درجه سلسیوس و در شعاع ۵ متری دمای افراد را حتی اگر ماسک و کلاه داشته باشند، اندازه گیری کند. این سامانه می‌تواند در هر ثانیه دمای بدن ۱۵ نفر را بسنجد و با استفاده از یک اپراتور انسانی افراد مشکوک را شناسایی کرده و اخطار بدهد.



متداولوزی crisp



روش های جمع آوری اطلاعات



مشکلات جمع آوری اطلاعات در پزشکی



► ۱. چالش یکپارچه سازی و استخراج داده ها


داده های مراقبت های بهداشتی از منابع با فرمت های مختلف مانند داده های ساختاریافته، کاغذ، فیلم، چند رسانه ای، تصاویر دیجیتال و غیره به دست می آیند. که یکپارچه سازی و استخراج داده ها را یک چالش واقعی می سازد.

► ۲. داده های دائما در حال تغییر:

بیماران و پزشکان ممکن است نقل مکان کنند، نام و حرفه خود را تغییر دهند، بازنشسته شوند. سازمان ها همچنین جابه جا می شوند، داروها و درمان جدید معرفی می شوند.

مشکلات جمع آوری اطلاعات در پزشکی

- ▶ ۳. حریم خصوصی و مقررات امنیتی: حفظ اعتماد بیماران، پایه و اساس ساخت یک سیستم پزشکی است.
- ▶ ۴. انتظارات بیمار: صنعت بهداشت و درمان باید درک درستی از نیازهای متغیر بیماران و ترجیحات آنها داشته باشد و سپس راه حل هایی همسو با روش زندگی آنها ارائه شوند.
- ▶ ۵. عدم وجود فرآیندهای تضمین کیفیت: چنین فرآیندی معمولاً وجود ندارد. کیفیت داده ها اغلب به شخصی بستگی دارد که داده ها را وارد می نماید





پیش پردازش داده



- انتخاب کلاس های هدف
- تکنیک های پاکسازی داده یا **Data cleaning**
- تکنیک های یکپارچگی داده یا **Data integration**
- تکنیک های کاهش داده یا **Data reduction**
- تکنیک های تبدیل داده یا **Data transformations**



انتخاب کلاس های هدف

Binary Class

Multi Class





پاکسازی داده

مدیریت داده های از دست رفته

مدیریت داده های پرت





پاکسازی داده - مدیریت داده های از دست رفته


حذف یک ردیف خاص - در این روش، یک ردیفی حذف می شود که بیش از ۷۵ درصد از مقادیر آن، از دست رفته است

محاسبه میانگین - این روش برای ویژگی هایی که داده های عددی دارند مانند سن، حقوق، سال و غیره مفید است. در اینجا می توانید میانگین و میانه یک ستون حاوی یک مقدار از دست رفته شده است، محاسبه و جایگزین نمایید.



یکپارچگی داده

بسیاری از موارد ممکن است داده ها در فایل ها و منابع مختلف نگهداری شوند و در این صورت نیاز است تا داده ها پیش از اجرای تکنیک های داده کاوی با یکدیگر یکپارچه شوند.



استفاده از انباره داده توصیه می شود



تبدیل داده

فعالیت های مانند نرمال سازی داده ها و گستته سازی داده

نرمال سازی داده ها : در موقعی که فاصله ای اعداد زیاد باشد می توان با نرمال سازی محدوده ای کوتاه تری را انتخاب نمود نرمال سازی سن به بازه ای صفر تا یک

گستته سازی داده ها : مثلا تبدیل مقادیر عددی فشارخون به سه سطح نرمال، پایین، بالا



کاهش ابعاد داده

در بسیاری از موارد، همه‌ی داده‌ها مدنظر نیستند در قسمت می‌توان از روش‌های انتخاب ویژگی استفاده نمود

مشخصات یک مجموعه داده ای برای استفاده در داده کاوی

- ۱) داشتن حداقل تعداد رکوردهای لازم
- ۲) داشتن حداقل تعداد صفات
- ۳) میزان **missing value** خیلی زیاد نباشد
- ۴) صفت هدف تا حد امکان **missing value** نداشته باشد



مشکلات داده کاوی در حوزه سلامت



۱) ناکامل بودن داده ها

۲) حریم شخصی

۳) کاغذی بودن اغلب پرونده ها

انواع داده

Numerical **عددی** ➤

Ordinal **ترتیبی** ➤

Nominal **اسمی** ➤



داده کاوی بر حسب نوع داده

۱) متن کاوی:

متن کاوی به فرایند تحلیل و اکتشاف انبوهی از متون غیرساخت یافته بوسیله نرم افزار به منظور شناسایی مفاهیم، الگوها، موضوعات، کلیدواژه‌ها و دیگر ویژگی‌های داده‌های متنی گفته می‌شود.

به عبارت دیگر هدف متن کاوی، کشف معنا (مفهوم و هدف) و استخراج اطلاعات نهفته (برای مثال موجودیت‌ها و روابط) در داده‌های متنی است.



داده کاوی بر حسب نوع داده

متن کاوی : کاربردها

- ▶ کسبوکارها : کاربردهایی از قبیل تحلیل حس و میزان رضایتمندی مشتریان نسبت به محصولات یا شرکت‌ها، گرایش و علاقه بازار نسبت به ویژگی‌های مختلف محصولات، شناسایی سلیقه یا رویدادهای زندگی کاربر و تبلیغات موثر، شناسایی خودکار و فیلتر نظرات نامناسب (غیرقابل انتشار) کاربران و ...
- ▶ کتابخانه‌ای : نمایهزنی و دسته‌بندی موضوعی مقالات و کتاب‌ها، مشابهت‌یابی بین مستندات مختلف، جستجوی (غیردقیق) متن یا عبارت در بین حجم انبوه منابع و ...
- ▶ جامعه‌شناسی و روان‌شناسی : تحلیل علائق، خصوصیات و خلقيات افراد، شناسایی و تحلیل لحن و نحوه بیان نشریات و رسانه‌های مختلف برای القای مقصود خود به افراد و ...
- ▶ زیست‌شناسی : نام این فیلد به متن کاوی داده‌های زیستی (Biomedical Text Mining) معروف است که بیشتر روی تحلیل تعاملات بین توالی پروتئین آنها و ارتباط و وابستگی بین آنها با بیماری‌ها با استفاده از تکنیک‌های متن کاوی تمرکز دارد.



داده کاوی بر حسب نوع داده

۲) وب کاوی

وب کاوی به دستیابی الگوهای اطلاعاتی از داده های موجود در وب کمک می کند.

بهتر شدن قدرت موتور های جستجوی وب : از طریق شناساندن صفحات وب و طبقه بندی مستندات

وب کاوی برای فهمیدن رفتار مشتری، ارزیابی اثربخشی یک وبسایت خاص مفید است

کاویدن اطلاعات مفید از صفحات وب



داده کاوی بر حسب نوع داده

3) Image mining

استخراج اطلاعات مفید از عکس ها

کووید ۱۹ : استخراج اطلاعات از سی تی اسکن بیمار



داده کاوی بر حسب نوع داده



۴) داده‌ی جدولی (داده کاوی):

ستون‌ها : صفات سطرها: اطلاعات بیماران به صورت رکورد

سیستم‌های ثبت موجود در سطح دانشگاه و سطح کشور

انواع تکنیک های داده کاوی



۱) قواعد انجمنی :

تولید قواعد از الگوهای پر تکرار

۲) خوش بندی :

تشخیص مجموعه ای از دسته ها برای توصیف داده مثلا تشخیص گروه های مختلف در یک شبکه
یادگیری بدون ناظارت

۳) کلاسه بندی :

قرار دادن داده ها در یک دسته بندی از پیش تعریف شده
یادگیری با ناظارت

انواع تکنیک های داده کاوی - قواعد انجمنی

Basket	Product 1	Product 2	Product 3
1	Milk	Cheese	
2	Milk	Apples	Cheese
3	Apples	Banana	
4	Milk	Cheese	
5	Apples	Banana	
6	Milk	Cheese	Banana
7	Milk	Cheese	
8	Cheese	Banana	
9	Cheese	Milk	

فرکانس تکرار : در شش سبد خرید **Milk,Cheese** با هم رخ داده اند پس فرکانس تکرار آنها برابر با ۶ است (**absolutesupport**)

فرکانس تکرار نسبی : از ۹ سبد خرید، در ۶ سبد خرید **Milk,Cheese** با هم رخ داده اند پس فرکانس تکرار نسبی برابر با $\frac{6}{9}$ درصد است (**relativesupport**)

آستانه کمترین تکرار : برابر با ۵۰ درصد است (**min_sup**)

پس **Milk,Cheese** یک مجموعه‌ی پرتکرار است

Itemset


{Milk,Cheese,Apples,Banana}

Itemset : زیرمجموعه‌ی k عنصری از **k-itemset**

فرض کنید زیر مجموعه‌ی مورد نظر :



انواع تکنیک های داده کاوی - خوشه بندی




▶ خوشه بندی

- (۱) k نقطه را به عنوان مرکز خوشه در نظر گرفته می شود
- (۲) هر شی را به شبیه ترین مرکز خوشه اختصاص دهید
- (۳) به مرحله ۱ بازگردید ، وقتی تغییری ایجاد نشد، متوقف شوید.





انواع تکنیک های داده کاوی - خوشه بندی



خوشه بندی سلسله مراتبی ▶

Top-down .۱

Bottom-up .۲

انواع تکنیک های داده کاوی کلاسی بندی




درخت تصمیم

بیزین


شبکه عصبی

ماشین بردار پشتیبان

درخت تصمیم برای خوش خیم و بد خیم بودن سرطان




(a)



(b)



بیزین






شبکه عصبی مصنوعی

مغز انسان از نورون ها تشکیل شده که قادر هستند محاسبات معینی را سریعتر از کامپیوترهای دیجیتال انجام دهند

شبکه عصبی مصنوعی می خواهد عملکرد مغز را شبیه سازی نماید






ماشین بردار پشتیبان

بردارهای پشتیبان به زبان ساده، مجموعه ای از نقاط در فضای n بعدی داده ها هستند که مرز دسته ها را مشخص می کنند و مرزبندی و دسته بندی داده ها براساس آنها انجام می شود و با جابجایی یکی از آنها، خروجی دسته بندی ممکن است تغییر کند.

هدف ماشین بردار پشتیبان، بهینه کردن خط عمود بر فاصله‌ی بین دو کلاس است



ارزیابی تکنیک ها - 10-fold cross validation



قسمت اول، مجموعه‌ی داده‌ای آموزشی است که ۹۰ درصد مجموعه‌ی داده‌ای اصلی را تشکیل می‌دهد.

قسمت دوم، مجموعه‌ی داده‌ای آزمایشی است که ۱۰ درصد مجموعه‌ی داده‌ای اصلی را تشکیل می‌دهد.

تقسیم به این دو مجموعه، ۱۰ بار انجام می‌شود و هر بار یک گروه به صورت تصادفی به عنوان مجموعه‌ی آزمایشی و بقیه‌ی گروه‌ها به عنوان مجموعه‌ی آموزشی در نظر گرفته می‌شوند. از مجموعه‌ی داده‌ای آموزشی برای تولید الگوها و از مجموعه‌ی داده‌ای آزمایشی برای ارزیابی صحت تکنیک‌های مورد استفاده در نظر گرفته می‌شود.

پارامترهای ارزیابی عملکرد یک کلاسه بند - تعاریف براساس کلاسه بندی دودویی

Accuracy

نسبت نمونه‌های درست پیش‌بینی شده به کل نمونه‌های پیش‌بینی شده

Sensitivity

حساسیت نسبتی از نمونه‌های مثبت است که مدل آن‌ها را به درستی به عنوان نمونه مثبت تشخیص داده است.

Specificity

نسبتی از نمونه‌های منفی است که مدل آن‌ها را به درستی به عنوان نمونه منفی تشخیص داده است




پارامترهای ارزیابی عملکرد یک کلاسه بند - تعاریف براساس کلاسه بندی دودویی

AUC

: منحنی های ROC منحنی های دو بعدی هستند که در آنها Sensitivity در محور Y و 1-Specificity در محور X رسم می شوند.

وقتی مقدار ناحیه‌ی تحت منحنی ROC برابر ۱ باشد، دسته‌بند می‌تواند بین تمام نقاط کلاس مثبت و منفی به طور صحیح تمایز قائل شود. اما، اگر مقدار ناحیه‌ی تحت منحنی ROC برابر ۰ باشد، دسته‌بند همه منفی‌ها را مثبت و همه مثبت‌ها را منفی پیش‌بینی می‌کند.

AUC سطح ناحیه‌ی تحت منحنی ROC را نشان می‌دهد.





ارزیابی الگوها توسط متخصصین بالینی

در این گام، الگوها در اختیار متخصصین بالینی قرار می‌گیرد و سپس با دریافت نظرات آنها، الگوهایی و قواعد تایید شده گزارش می‌شوند.



نرم افزارهای موجود

▶ ۱) نرم افزار رپیدماینر

قوی ترین و ساده ترین ابزار توسط کمپانی رپیدماینر تولید شده است

▶ ۲) نرم افزار weka

زبان جاوا، رایگان و متن باز


▶ ۳) Orange

به زبان پایتون



نمونه : پردازش با کلاسه بندی - رپیدماینر

انتخاب یکی از تکنیک ها به عنوان مثال درخت تصمیم



نمونه : پردازش با کلاسه بندی - رپیدماینر

Result History X

Tree (Decision Tree) X

Graph

Zoom + -

Mode □ ↗

Description ▼


Tree

Node Labels

Edge Labels

Annotations

Outlook	Temperature	Humidity	Windy	Play
Sunny	85	85	false	no
Sunny	80	90	true	no
Overcast	83	86	false	yes
Rainy	70	96	false	yes
Rainy	68	80	false	yes
Rainy	65	70	true	no
Overcast	64	65	true	yes
Sunny	72	95	false	no
Sunny	69	70	false	yes
Rainy	75	80	false	yes
Sunny	75	70	true	yes
Overcast	72	90	true	yes
Overcast	81	75	false	yes
Rainy	71	91	true	no



حامیان و اطلاعات تماس

حامیان

معاونت بهداشتی دانشگاه علوم پزشکی اصفهان

دانشکده مدیریت و اطلاع رسانی پزشکی

مرکز تحقیقات فناوری اطلاعات در امور سلامت

گروه مدیریت و فناوری اطلاعات سلامت

ایمیل دکتر محمد ستاری msattarimng.mui@gmail.com

