

اصلو و روشهای یادگیری

علم داده

تألیف:
Sinan Ozdemir

مترجمان:
دکتر حامد تابش
الهام نظری، پرنیان عسگری، مرضیه افکن پور
مهران آغه میری، محبوبه اسلامی، شیوا قادری

انتشارات پندار پارس

عنوان و نام پدیدآور	: ازدمیر، سینان Ozdemir, Sinan	سرشناسه
مشخصات نشر	: اصول و روش‌های یادگیری علم داده/ تالیف سینان ازدمیر؛ مترجمان حامد تابش...[و دیگران .] .	عنوان و نام پدیدآور
مشخصات ظاهری	: تهران : پندار پارس، ۱۳۹۸.	مشخصات نشر
شابک	: ۴۱۰ صن: مصور، جدول، نمودار.	مشخصات ظاهری
فیبا	: ۹۷۸-۶۰۰-۸۲۰۱-۷۲-۴	شابک
پادداشت	: عنوان اصلی : Principles of Data Science: Learn the techniques and math you .need to start making sense of your data , 2016	وضعیت فهرست نویسی
پادداشت	: مترجمان حامد تابش، الهام نظری، پرنیان عسگری، مرضیه افکن‌پور، مهران آغمیری، محبوبه اسلامی، شیوا قادری.	پادداشت
موضوع	: دادهکاوی	موضوع
موضوع	: Data mining	موضوع
موضوع	: کسب و کار -- دادهکاری	موضوع
موضوع	: Business -- Data processing	موضوع
شناسه افزوده	: تابش، حامد، ۱۳۵۶--، مترجم	شناسه افزوده
رده بندی کنگره	: ۹/۷۶QA	رده بندی کنگره
رده بندی دیوبی	: ۳۱۲/۰۰۶	رده بندی دیوبی
شماره کتابشناسی ملی	: ۵۸۳۴۶۳۴	شماره کتابشناسی ملی

انتشارات پندارپارس



www.pendarepars.com

info@pendarepars.com

تلفن: ۰۹۱۲۲۴۵۲۳۴۸ - تلفکس: ۶۶۵۷۲۳۳۵

نام کتاب	: اصول و روش‌های یادگیری علم داده
ناشر	: انتشارات پندار پارس
تالیف	: سینان ازدمیر
ترجمه	: حامد تابش، الهام نظری، پرنیان عسگری، مرضیه افکن‌پور، مهران آغمیری، محبوبه اسلامی، شیوا قادری
چاپ نخست	: شهریور ۹۸
شمارگان	: ۵۰۰ نسخه
طرح جلد	: رامین شکرالهی
چاپ، صحافی	: فرشیوه
قیمت	: ۸۰۰۰ تومان
شابک :	۹۷۸-۶۰۰-۸۲۰۱-۷۲-۴

* هرگونه کپی برداری، تکثیر و چاپ کاغذی یا الکترونیکی از این کتاب بدون اجازه ناشر تخلف بوده و پیگرد قانونی دارد

فهرست

فصل ۱؛ چگونه به عنوان یک متخصص علوم داده به نظر برسیم؟ ۵
علم داده چیست؟ ۷
اصطلاحات پایه ۷
چرا علم داده؟ ۹
مثال - تکنولوژی‌های Sigma ۹
نمودار ون علم داده ۱۱
ریاضی ۱۳
مثال - مدل‌های spawner-recruit ۱۳
برنامه‌نویسی کامپیوتر ۱۵
چرا Python؟ ۱۵
پایتون در عمل ۱۶
مثال پایه از پایتون ۱۸
مثال - تجزیه یک توئیت واحد ۱۹
حوزه دانش ۲۰
برخی اصطلاحات بیشتر ۲۱
مطالعات موردنی در علوم داده ۲۳
مطالعه موردنی - خودکار و اتومازیسیون کردن فرم‌های کاغذی دولتی ۲۴
نادیده گرفتن جنبه انسانی، آیا درست است؟ ۲۵
مطالعه موردنی - دلارهای بازاریابی ۲۵
بودجه‌های تبلیغاتی ۲۶
نمودار بودجه‌های تبلیغاتی ۲۷

۲۷	مطالعه موردی - چه چیزهایی در توصیف یک شغل استفاده می‌شود؟
۲۸	یک مثال از لیست کارهای متخصصان علوم داده
۳۳	فصل ۲: انواع داده
۳۳	طعم و مزه داده‌ها
۳۴.....	چرا باید به این تمایز نگاه کنیم؟
۳۵.....	داده‌های ساختاریافته در برابر داده‌های بدون ساختار
۳۶.....	مثالهایی از پیش‌پردازش داده‌ها
۳۷	شمارش کلمه / عبارت
۳۷	وجود برخی کاراکترهای خاص
۳۷	طول نسبی متن
۳۸	انتخاب عنوان‌ها (موضوعات)
۳۹	داده‌های کمی در برابر داده‌های کیفی
۳۹	مثال - داده کافی شاپ
۴۰.....	دو مورد مهم برای یادآوری
۴۳.....	بررسی و کاوش عمیق‌تر
۴۳.....	مسیر تاکنون پیموده شده
۴۴.....	چهار سطح داده
۴۴.....	سطح اسمی
۴۵.....	عملیات ریاضی مجاز
۴۵.....	اندازه مرکز
۴۶.....	چه داده‌هایی در سطح اسمی است
۴۶.....	سطح رتبه‌ای
۴۶.....	مثال‌ها

عملیات ریاضی مجاز ۴۷
اندازه مرکز ۴۷
بررسی و بازنگری سریع ۴۹
سطح فاصله‌ای ۴۹
مثال ۴۹
عملیات ریاضی مجاز ۵۰
اندازه مرکز ۵۰
اندازه تغییرات ۵۱
انحراف معیار ۵۱
سطح نسبی ۵۳
مثال‌ها ۵۳
اندازه مرکز ۵۴
چالش‌های سطح نسبی ۵۴
داده‌ها در مقابل چشمان بیننده است!! ۵۵
فصل ۳: مراحل پنج‌گانه علوم داده ۵۷
معرفی علم داده ۵۷
بررسی پنج مرحله ۵۷
پرسیدن یک سؤال جالب ۵۸
به دست آوردن داده ۵۸
بررسی داده ۵۸
مدل‌سازی داده ۵۹
برقراری ارتباط و بصری سازی نتایج ۵۹
بررسی داده ۵۹

۶۰.....	سوالات اساسی برای اکتشاف داده
۶۱.....	مجموعه داده ۱ Yelp –
۶۴.....	فرمت داده‌ای
۶۴.....	سری‌ها
۶۵.....	نکات اکتشافی برای داده‌های کیفی
۶۷.....	فیلتر کردن در pandas
۶۹.....	ستون‌های سطح مرتبه‌ای
۷۱	مجموعه داده ۲ titanic –
۷۷	فصل ۴: ریاضیات پایه
۷۷	ریاضیات به عنوان یکرشته
۷۸	اصطلاحات و نمادهای پایه
۷۸	بردارها و ماتریس‌ها
۸۱	تمرین
۸۱	نمادهای علم حساب
۸۱	مجموع (جمع)
۸۲	تناسب
۸۳	حاصل ضرب نقطه‌ای
۸۶.....	نمودارها
۸۷	لگاریتم و نما
۹۰	نظریه مجموعه
۹۵.....	جبر خطی
۹۵.....	ضرب ماتریس‌ها
۹۵.....	نکاتی در رابطه با ضرب ماتریس‌ها

فصل ۵: غیرممکن یا غیرمحتمل - مقدمه‌ای ساده بر احتمال	۱۰۱
تعریف پایه	۱۰۲
احتمال	۱۰۲
بیزین در مقابل فریکوئنسیست	۱۰۴
رویکرد فریکوئنسیست	۱۰۴
مثال - آمار بازاریابی	۱۰۵
قانون اعداد بزرگ	۱۰۵
رویدادهای ترکیبی	۱۰۷
احتمال شرطی	۱۱۰
قوانين احتمال	۱۱۱
قانون افزودن	۱۱۱
انحصار متقابل	۱۱۳
قانون ضرب	۱۱۳
استقلال	۱۱۵
رویدادهای تکمیلی	۱۱۵
کمی عمیق‌تر بنگریم	۱۱۶
فصل ۶: احتمال پیشرفته	۱۱۹
مجموعه رویدادهای جامع	۱۱۹
ایده‌های بیزی بازبینی شده	۱۲۰
قاعده بیز	۱۲۰
کاربردهای بیشتر قضیه بیز	۱۲۴
مثال- تایتانیک	۱۲۵
مثال- آزمایش‌های پزشکی	۱۲۶

۱۲۸.....	متغیرهای تصادفی
۱۲۹.....	متغیرهای تصادفی گستته
۱۳۵.....	انواع متغیرهای تصادفی گستته
۱۳۵.....	متغیرهای تصادفی دو جمله‌ای
۱۳۶.....	مثال- جلسات جمع‌آوری کمک مالی
۱۳۶.....	مثال- افتتاح رستوران
۱۳۷.....	مثال- گروه خونی
۱۳۸.....	متغیرهای تصادفی هندسی
۱۳۹.....	مثال- آب و هوای
۱۴۰.....	متغیر تصادفی پواسون
۱۴۱.....	مثال- مرکز تلفن
۱۴۲.....	متغیرهای تصادفی پیوسته
۱۴۷	فصل ۷: آمار پایه
۱۴۷.....	آمار چیست؟
۱۴۹.....	چگونه داده‌ها را به دست آوریم و نمونه بگیریم؟
۱۴۹.....	به دست آوردن اطلاعات
۱۴۹.....	مشاهده‌ای
۱۵۰	تجربی
۱۵۲.....	داده‌های نمونه‌گیری
۱۵۲.....	نمونه‌گیری احتمالی
۱۵۳.....	نمونه‌گیری تصادفی
۱۵۴.....	نمونه‌گیری احتمالی نابرابر
۱۵۵.....	چگونه می‌توانیم آمار را اندازه‌گیری کنیم؟

۱۵۵	اندازه‌گیری مرکز
۱۵۶	اندازه‌گیری متغیرها
۱۶۱	تعريف
۱۶۱	مثال - حقوق کارمندان
۱۶۲	اندازه‌گیری مقادیر نسبی
۱۶۸	بخش تفصیلی - همبستگی داده‌ها
۱۷۰	قواعد تجربی
۱۷۲	مثال - نمرات امتحان
۱۷۳	فصل ۸: آمار پیشرفته
۱۷۳	برآورد نقطه‌ای
۱۷۸	توزیع نمونه‌گیری
۱۸۱	فاصله اطمینان
۱۸۴	آزمون فرضیه
۱۸۵	انجام آزمون فرضیه
۱۸۷	آزمون t تک نمونه‌ای
۱۸۷	مثالی از آزمون t تک نمونه‌ای
۱۸۸	فرضیه‌های یک نمونه آزمون t
۱۹۱	خطای نوع اول و نوع دوم
۱۹۱	آزمون فرضیه برای متغیرهای دسته‌ای
۱۹۲	آزمون نیکویی برازش کای اسکوئر
۱۹۲	فرضیه‌هایی از آزمون نیکویی برازش کای اسکوئر
۱۹۳	مثالی از آزمون نیکویی برازش کای اسکوئر
۱۹۵	آزمون کای اسکوئر برای وابسته / مستقل

۱۹۵.....	فرضیه آزمون مستقل کای اسکوئر
فصل ۹؛ به اشتراک‌گذاری داده	
۲۰۰.....	چرا به اشتراک‌گذاری مهم است؟
۲۰۰.....	تشخیص بصری‌سازی مؤثر و غیرمؤثر
۲۰۱.....	نمودار پراکندگی
۲۰۳.....	نمودارهای خطی
۲۰۴.....	نمودار میله‌ای
۲۰۶.....	هیستوگرام
۲۰۸.....	نمودار جعبه‌ای
۲۱۱.....	هنگامی که نمودارها و آمارها دروغ می‌گویند
۲۱۱.....	همبستگی در مقابل علیت
۲۱۴.....	پارادوکس سیمپسون
۲۱۵.....	اگر همبستگی دو متغیر به معنی علت و معلول بودن آنها نباشد چه کار کنیم؟
۲۱۶.....	ارتباط کلامی
۲۱۶.....	گفتن یک داستان
۲۱۷.....	ارائه برای مکان‌های رسمی‌تر
۲۱۸.....	استراتژی "چرا، چگونه، چه چیزی"، برای ارائه دادن
فصل؛ یادگیری ماشین	
۲۲۱.....	یادگیری ماشین چیست؟
۲۲۲.....	مثال- تشخیص چهره
۲۲۴.....	یادگیری ماشین کامل نیست
۲۲۵.....	یادگیری ماشین چگونه کار می‌کند؟
۲۲۶.....	مروری بر مدل‌های یادگیری ماشین

۲۲۶.....	انواع مختلف یادگیری ماشین
۲۲۷.....	یادگیری تحت ناظارت
۲۲۷.....	مثال- پیش‌بینی حمله قلبی
۲۳۰.....	انواع مختلف مدل‌های یادگیری تحت ناظارت
۲۳۰.....	رگرسیون
۲۳۱.....	طبقه‌بندی
۲۳۱.....	مثال- رگرسیون
۲۳۲.....	داده در چشم‌های بیننده است
۲۳۲.....	یادگیری بدون ناظارت
۲۳۴.....	یادگیری تقویتی
۲۳۵.....	مروری بر انواع یادگیری ماشین
۲۳۷.....	چگونه مدل‌سازی آماری در همه این مدل‌ها تأثیر دارد؟
۲۳۷.....	رگرسیون خطی
۲۴۳.....	اضافه کردن پیشگوهای بیشتر
۲۴۵.....	معیارهای رگرسیون
۲۵۳.....	رگرسیون لجستیک
۲۵۴.....	احتمال، شанс و لگاریتم شанс
۲۵۸.....	محاسبات ریاضی رگرسیون لجستیک
۲۶۱.....	متغیرهای ساختگی
۲۶۷.....	فصل ۱۱؛ آیا می‌توان از طریق درختان پیش‌بینی‌ها را انجام داد؟
۲۶۷.....	طبقه و کلاسه‌بندی بیزین ساده
۲۷۶.....	درخت تصمیم
۲۷۸.....	چگونه یک کامپیوتر یک درخت رگرسیون ایجاد می‌کند؟

۲۷۹.....	چگونه رایانه مناسب یک درخت طبقه‌بندی است؟
۲۸۴.....	یادگیری بدون نظارت
۲۸۴.....	چه موقعی از یادگیری بدون نظارت استفاده می‌کنیم
۲۸۵.....	خوشه‌بندی K-means
۲۸۷.....	یک مثال روشن - نقاط دادهای
۲۹۲.....	مثال - دلسیتر
۲۹۵.....	انتخاب یک شماره بهینه برای k و اعتبارسنجی خوش
۲۹۵.....	اثرگذاری Silhouette
۲۹۷.....	استخراج ویژگی و تحلیل مؤلفه اصلی
۳۰۹	فصل ۱۲؛ فراتر از نیاز
۳۱۰.....	توازن بین واریانس/بایاس
۳۱۰.....	خطای ناشی از بایاس
۳۱۰.....	خطای ناشی از واریانس
۳۱۱.....	مثال- مقایسه وزن بدن و مغز پستانداران
۳۱۳.....	نمودار پراکندگی وزن بدن و مغز پستانداران
۳۱۴.....	همان نمودار پراکندگی قبلی با نمایش رگرسیون خطی در آن
۳۱۵.....	نمودار پراکندگی برای نمونه‌های ۱ و ۲
۳۱۷.....	استفاده از چندجمله‌ای درجه چهار برای اهداف رگرسیون
۳۱۸.....	نمودار پراکندگی با استفاده از چندجمله‌ای درجه چهار به عنوان تخمین دهنده ما
۳۱۸.....	دو حالت نهایی از توازن واریانس/بایاس
۳۱۸.....	کم برازش
۳۱۹.....	بیش برازش
۳۱۹.....	چگونگی تأثیر بایاس/واریانس در تابع‌های خطا

۳۲۱.....	اعتبارسنجی متقاطع K فولد
۳۲۵.....	نمودار خطای KNN در مقابل پیچیدگی KNN
۳۲۵.....	جستوجوی توری
۳۲۹.....	بصری کردن خطای آموزشی در مقابل خطای اعتبارسنجی متقاطع
۳۳۱.....	روش‌های انسمبل
۳۳۳.....	جنگل تصادفی
۳۳۸.....	مقایسه جنگلهای تصادفی با درختهای تصمیم
۳۳۹.....	شبکه‌های عصبی
۳۳۹.....	ساختار اساسی
۳۴۷	فصل ۱۳؛ مطالعات موردی
۳۴۷.....	مطالعه موردی نخست: پیش‌بینی قیمت سهام بر اساس رسانه‌های اجتماعی
۳۴۷.....	آنالیز احساسات متن
۳۴۸.....	تجزیه و تحلیل داده‌های اکتشافی
۳۵۸.....	روش رگرسیون
۳۶۰.....	روش طبقه‌بندی
۳۶۳.....	فراتر از این مثال رفتن
۳۶۳.....	مطالعه موردی دوم: چرا برعی از مردم، همسران خود را فریب می‌دهند؟
۳۷۲.....	مطالعه موردی ۳ – استفاده از tensorflow
۳۷۷.....	Tensorflow و شبکه‌های عصبی
۳۸۵	ضمایم و پیوست‌ها
۳۸۵.....	واژگان مهم و ضروری کتاب

مقدمه

موضوع این کتاب علم داده است که در زمینه تحقیق و کاربرد علم داده توضیحات بسیار ارزشمندی را عنوان می‌کند. علم داده در چند دهه گذشته به سرعت در حال رشد و توسعه بوده است. به عنوان یک زمینه رو به رشد، توجه زیادی در رسانه‌ها و همچنین در بازار کار به دست آورده است. توجه به علم داده پس از ظهور شرکت‌های فناوری مدل‌سازی از اهمیت ویژه‌ای برخوردار گردید و اخیراً شروع به استخدام تیم‌های داده کاو متخصص کردند.

این کتاب تلاش خواهد کرد تا شکاف بین تخصص ریاضی / برنامه‌نویسی / داده‌کاوی را متوقف کند. امروزه اکثر مردم حداقل یک (یا شاید دو) تخصص دارند، اما علم داده‌کاوی به بیش از سه تخصص نیاز دارد. ما به موضوعاتی از هر سه تخصص وارد شدیم و مشکلات پیچیده را قابل حل ساخته‌ایم. برای ارزیابی نتایج علمی و دقیق، داده‌ها را تمیز، کشف و تحلیل خواهیم کرد. یادگیری ماشین و روش‌های یادگیری عمیق که برای حل وظایف پیچیده داده مورداستفاده قرار می‌گیرد را بیان می‌کنیم.

این کتاب چه مواردی را پوشش می‌دهد؟!!

فصل ۱، چگونه به عنوان یک متخصص داده به نظر برسیم: مقدمه‌ای بر اصطلاحات اساسی استفاده شده توسط متخصصان داده و نگاهی به انواع مشکلات که در سراسر این کتاب حل خواهد شد.

فصل ۲، انواع داده‌ها: به سطوح مختلف و نحوه دستکاری انواع داده نگاه اساسی می‌کند.

این فصل شروعی برای بررسی ریاضیات موردنیاز برای علم داده است.

فصل ۳، پنج مرحله علوم داده: پنج مرحله اساسی در انجام علوم داده، از جمله دستکاری و تمیز کردن داده‌ها را باز می‌کند، و نمونه‌هایی از هر مرحله را بیان می‌کند.

فصل ۴، ریاضیات پایه: به ما کمک می‌کند تا اصول پایه ریاضی را کشف کنیم که عملکردهای متخصصان داده را با دیدن و حل نمونه‌هایی در حساب، جبر خطی و غیره هدایت می‌کنند.

فصل ۵، غیرممکن یا غیرقابل پیش‌بینی-مقدمه‌ای ساده درباره احتمال: یک نگاه مبتدی به نظریه احتمال و نحوه استفاده از آن برای به دست آوردن درک جهان تصادفی ما است.

فصل ۶، احتمال پیشرفت: از اصول فصل قبلی استفاده می‌کند و قضیه‌ها و نظریه‌هایی نظیر قضیه بایاس را به کار می‌گیرد و امید به کشف معنای پنهان در دنیای داده‌ها دارد.

فصل ۷، آمار پایه: در پی بررسی انواع مشکلی است که استنتاج آماری تلاش می‌کند با استفاده از اصول آزمایشی، نرمال‌سازی و نمونه‌گیری تصادفی توضیح دهد.

فصل ۸، آمار پیشرفته: از آزمون فرضیه‌ها و فاصله اطمینان استفاده می‌کند تا بینشی را از آزمایش‌های ما به دست آورد. داشتن توانایی انتخاب تست مناسب و نحوه تفسیر مقادیر p و سایر نتایج نیز بسیار مهم است.

فصل ۹، ارتباطات داده‌ها: توضیح می‌دهد که چگونه ارتباطات و علیت بر تفسیر ما از داده تأثیر می‌گذارد. همچنین با استفاده از تجسم و بصری‌سازی به دنبال به اشتراک گذاشتن نتایج خود با جهان پیرامونمان است.

فصل ۱۰، مربوط به ملزمات یادگیری ماشین است: بر تعریف یادگیری ماشین مرکز است و به مثال‌های واقعی در مورد نحوه و زمان استفاده از یادگیری ماشینی می‌پردازد.

فصل ۱۱، پیش‌بینی‌ها و درخت تصمیم: به مدل‌های پیچیده‌تر یادگیری ماشین، مانند درخت تصمیم‌گیری و پیش‌بینی‌های مبتنی بر بیزین، به‌منظور حل وظایف مربوط به تحلیل پیچیده‌تر داده‌ها نگاه می‌کند.

فصل ۱۲، فراتر از ملزمات: برخی از نیروهای مرموز را که علوم داده‌ها را هدایت می‌کنند معرفی می‌کند، از جمله بایاس و واریانس. در این فصل شبکه‌های عصبی به عنوان روش یادگیری عمیق مدرن معرفی می‌شوند.

فصل ۱۳، مطالعات موردي: از مجموعه‌ای از مطالعات موردى استفاده می‌کند تا ایده‌های علوم داده را تقویت کند. همچنین نمونه‌ها و مثال‌های مختلف، از جمله پیش‌بینی قیمت سهام و تشخیص دستخط، بررسی خواهد شد.

آنچه شما در این کتاب نیاز دارید:

این کتاب از پایتون برای تمام نمونه‌های کد و حل مثال‌ها استفاده می‌کند. یک دستگاه کامپیوتر با سیستم‌عامل لینوکس / مک / ویندوز با دسترسی به ترمینال یونیکس با پایتون ۲.۷ نصب شده موردنیاز است.

نصب و راهاندازی توزیع Anaconda نیز توصیه می‌شود، بسیاری از بسته‌های مورداداستفاده نمونه‌ها در کتاب از آن استفاده کرده است.

این کتاب برای چه کسی است؟

این کتاب برای افرادی است که به دنبال درک و استفاده از شیوه‌های اساسی تحلیل علم داده برای هر حوزه کاری هستند.

خواننده باید با ریاضیات پایه (جبر، شاید احتمالات) نسبتاً آشنا باشد و باید کمی با آشنایی داشته باشد.

انتظار نمی‌رود که خواننده در زمینه داده پیش‌تر کارکرده باشد با این حال، باید تمایل به یادگیری و اعمال تکنیک‌های ارائه شده در این کتاب در مجموعه داده‌های خود و یا ارائه و تمرین مثال‌هایی از این قبیل را داشته باشد و تلاش خود را در راه یادگیری روش‌های علم تحلیل و بررسی داده همواره ادامه دهد تا نتایج ارزشمندی را به دست آورد و از آن‌ها در بالا بردن بهره‌وری کار و امور زندگی خود استفاده کند.

فصل ۱

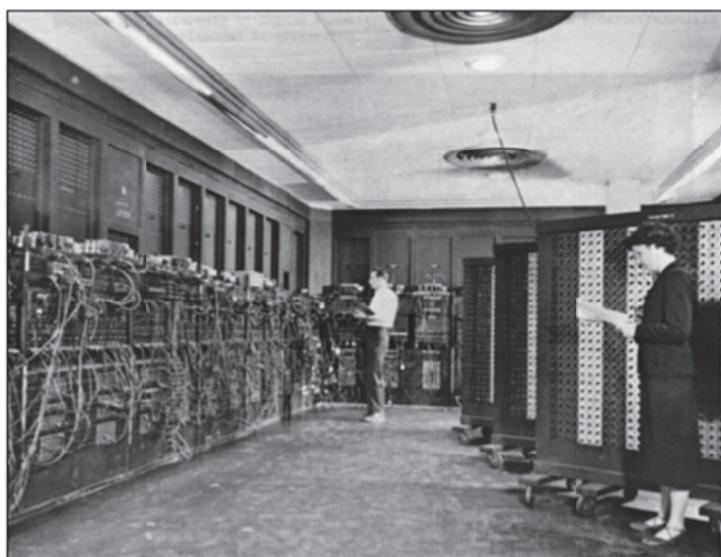
چگونه به عنوان یک متخصص علوم داده به نظر برسیم؟

مهم نیست شما در کدام صنعت کار می‌کنید؛ فناوری اطلاعات، مد، غذا یا سرمایه‌گذاری. شکی نیست که داده بر زندگی و کار شما تأثیر می‌گذارد. در این هفته، درزمانی خاص، شما یا مکالمه‌ای در مورد داده‌ها دارید یا می‌شنوید. رسانه‌های خبری داستان‌های بیشتر و بیشتری درباره فراوانی داده‌ها، جرائم اینترنتی و نحوه دسترسی به داده در زندگی ما را پوشش می‌دهند. اما چرا حالا؟ چه چیزی باعث می‌شود که این دوران چنین دورانی برای صنایع مرتبط با داده باشد؟

در قرن نوزدهم، جهان درگیر عصر صنعتی بود. بشر جایگاه خود در صنعت را کنار صنعت اختراعات ماشینی غولپیکر پیدا کرد. کاپیتان صنعت، مانند هنری فورد، فرسته‌های بزرگ بازار را در دست این ماشین‌ها به رسمیت شناخت و قادر به دستیابی به سود غیرقابل پیش‌بینی بود. البته عصر صنعتی دارای مزایا و معایبی هم بود. درحالی‌که تولید انبوه کالا را در اختیار مصرف‌کنندگان بیشتری قرارداد، در این زمان نبرد ما با آلودگی نیز شروع شد.

در قرن بیست و یکم، ما در ساخت ماشین‌آلات بسیار حرفه‌ای بودیم؛ هدف این بود که آن‌ها را در ابعاد کوچکتر و با سرعت بیشتر بسازیم. عصر صنعتی به پایان رسید و با آنچه به عنوان عصر اطلاعات معرفی می‌شد جایگزین شد. ما شروع به استفاده از ماشین‌هایی برای جمع‌آوری و ذخیره اطلاعات (داده‌ها) درباره خود و محیط‌زیست کردیم تا بتوانیم خود را بهتر درک کنیم.

از دهه ۱۹۴۰، ماشین‌آلاتی مانند ENIAC (به عنوان یکی از نه اولین کامپیوترها) محاسبه معادلات ریاضی و اجرای مدل‌ها و شبیه‌سازی‌ها را انجام می‌دادند که هرگز قبل از آن مانند این کامپیوترها نبوده است.

The ENIAC, <http://ftp.arl.mil/ftp/historic-computers/>

درنهایت یک دستیار آزمایشگاه مناسب داشتیم که می‌توانست اعداد را بهتر از ما اجرا کند! همانند عصر صنعتی، عصر اطلاعات نیز برای ما هم مزایا و هم معایبی داشت. از مزیت‌های این عصر، قطعات فوق العاده‌ای از فناوری، از جمله تلفن‌های همراه و تلویزیون بود. معایب در این مورد به بدی آلودگی در سراسر جهان نیست، اما هنوز هم در قرن بیست و یکم با یک مشکل روبه‌رو شده‌ایم که آن وجود داده‌های زیاد است.

درست است که عصر اطلاعات، در تلاش برای تهیه داده‌ها، تولید داده‌های الکترونیکی را گستردۀ کرده است. برآوردها نشان می‌دهد که در سال ۲۰۱۱ حدود ۱.۸ تریلیون گیگابایت اطلاعات ایجاد کردیم (تنها یک لحظه فکر کنید که این مقدار چقدر است). فقط یک سال بعد، در سال ۲۰۱۲، ما بیش از ۲.۸ تریلیون گیگابایت اطلاعات ایجاد کردیم! گسترش این تعداد ادامه می‌یابد تا به ۴۰ تریلیون گیگابایت تخمين زده شده در سال ۲۰۲۰ تنها در یک سال برسد. هر زمان افراد یک (tweet) در فیسبوک به اشتراک بگذارند، هر بار که بخواهند، یک رزومه جدید را در نرم‌افزار MS Word ذخیره کنند، یا فقط یک عکس از طریق پیام متنی برای مادرشان ارسال کنند، این کار را انجام می‌دهند.

نه تنها داده‌ها را با سرعت بی‌سابقه‌ای ایجاد می‌کنیم، آن‌ها را با سرعت نیز مصرف می‌کنیم. تنها سه سال پیش، در سال ۲۰۱۳، کاربری با استفاده در حد متوسط از تلفن همراه در ماه، کمتر از ۱ گیگابایت اطلاعات استفاده می‌کرد. امروزه این تعداد در ماه به بیش از ۲ گیگابایت تخمين زده شده است. آنچه ما دنبال آن هستیم فهم (درک) است. (که از همه این اطلاعات در بیرون، فقط برخی از آن‌ها برای من مفید است! و برخی می‌تواند مفید باشد!)

بنابراین در قرن ۲۱ با مشکل مواجه هستیم. ما اطلاعات زیادی داریم و همچنان در حال تولید مقدار بیشتر از آن هستیم. بشر ماشین‌های کوچک که داده‌ها را ۲۴/۷ جمع‌آوری کنند، ساخته است و کار ما این است که همه آن‌ها را درک کنیم. سن داده را وارد کنید. این سن زمانی است که ماشین‌ها را با اجداد قرن نوزدهم و داده‌های ایجادشده توسط همتایان قرن بیست و یکم و ایجاد فهم و منابع داشت که هر انسان بر روی زمین می‌تواند از آن بهره‌مند شوند، در نظر می‌گیریم. ایالات متحده نقش کلیدی جدیدی در دولت برای متخصصان پیشرو در داده ایجاد کرد. شرکت‌های فناوری مانند Reddit، که تاکنون هیچ متخصص داده‌ای در تیم خود نداشتند، اکنون آن‌ها را به‌سوی خود می‌برند. این مزیت کاملاً آشکار است – استفاده از داده‌ها برای پیش‌بینی دقیق و شبیه‌سازی، دیدی از دنیا به ما می‌دهد که پیش از این هرگز نبوده است.

به نظر عالی می‌رسد، اما دست آورد چیست؟

در این فصل، اصطلاحات و واژگان مرتبط با علوم داده مدرن را بررسی خواهیم کرد. کلمات و عبارات کلیدی را که در بحث ما در مورد علوم داده در این کتاب ضروری است، خواهیم دید. همچنین خواهیم دید که چرا از علم داده‌ها استفاده می‌کنیم و سه حوزه کلیدی علم داده‌ها از پیش تعیین شده در کد پایتون که زبان اصلی مورداستفاده در این کتاب است را شروع می‌کنیم:

- اصطلاحات پایه علم داده
- سه حوزه علم داده
- دستورالعمل پایه پایتون

علم داده چیست؟

پیش از هر چیز، به برخی از تعاریف اساسی که در سراسر این کتاب استفاده می‌کنیم خواهیم پرداخت. یک مسئله در این فیلد^۱ این است که این فیلد به قدری جوان است که تعاریف آن می‌تواند در کتاب درسی تا روزنامه، تا متن مقاله متفاوت باشند.

اصطلاحات پایه

به طور کلی تعاریف زیر به قدری عمومی هستند که در گفتگوهای روزانه مورداستفاده قرار می‌گیرند و در جهت هدف کتاب مقدمه‌ای بر اصول علم داده است.

¹ Field

با این تعریف شروع می‌کنیم که داده چیست. در ابتدا ممکن است به عنوان یک تعریف احمقانه به نظر برسد، اما بسیار مهم است. هرگاه ما از کلمه Data یا "داده" استفاده می‌کنیم، درواقع، به مجموعه‌ای از اطلاعات در فرم سازمان‌یافته یا غیر سازمان‌دهی شده اشاره می‌کنیم:

- داده‌های سازمان‌یافته: به داده‌هایی اشاره دارد که در ساختار ردیف / ستون مرتب شده‌اند. به طوری‌که هر سطر مشاهدات واحد را نشان می‌دهند و ستون‌ها ویژگی‌های آن مشاهدات را نشان می‌دهند.
- داده‌های سازمان‌دهی نشده: این نوع داده‌ها در فرم آزاد هستند، معمولاً متن یا صوت / سیگنال خام است که باید برای سازمان‌دهی بیشتر تجزیه شود.
- زمانی که اکسل (یا هر برنامه دیگری از صفحات گسترده) را باز کنید، یک ساختار سطر / ستون خالی در انتظار اطلاعات سازمان‌یافته را می‌بینید. این برنامه‌ها در رابطه با داده‌های سازمان‌دهی نشده به خوبی عمل نمی‌کنند. در بیشتر موارد، ما با داده‌های سازمان‌دهی شده به عنوان ساده‌ترین راه برای درک و فهم سروکار داریم، اما از پرداختن به داده‌هایی به صورت متن خام و روش‌های پردازش داده‌های سازمان‌دهی نشده نیز خسته نخواهیم شد.

علم داده‌ها، هنر و کسب دانش از طریق داده‌ها است. این تعریف کوچکی برای چنین عنوان بزرگی است. علم داده‌ها بسیاری از موارد را پوشش می‌دهد که صفحات آن را گرفته و همگی را لیست می‌کند.

علم داده در مورد چگونگی گرفتن داده‌ها و استفاده از آن برای کسب دانش است، سپس از این دانش برای انجام موارد زیر استفاده می‌کنیم:

- تصمیم‌گیری
- پیش‌بینی آینده
- درک گذشته / حال
- ایجاد صنایع / محصولات جدید

در این کتاب همه‌چیز راجع به روش‌های علوم داده است، از جمله نحوه پردازش داده‌ها، جمع‌آوری مفاهیم و استفاده از این مفاهیم برای تصمیم‌گیری و پیش‌بینی‌های آگاهانه.

علم داده در مورداستفاده از داده‌ها به منظور به دست آوردن بینش جدید است که در غیر این صورت از دست می‌رفت.

به عنوان مثال، تصور کنید که شما در کنار یک میز با سه نفر دیگر نشسته‌اید. چهار نفر از شما باید بر اساس برخی داده‌ها تصمیم‌گیری کنند. چهار نظر برای بررسی وجود دارد. شما می‌توانید از علم داده‌ها برای آوردن افکار پنجم، ششم و حتی هفتم به جدول استفاده کنید.

به همین دلیل است که علم داده جایگزینی برای مغز انسان نیست، بلکه مکمل آن است، در کنار آن کار می‌کند. علم داده‌ها نباید به عنوان یک راه حل نهایی برای نگرانی‌های داده‌ای ما در نظر گرفته شود؛ این فقط یک نظر است، یک نظر بسیار آگاهانه است، اما به‌هرحال یک نظر است.

چرا علم داده؟

در عصر داده‌ها، واضح است که انبوهی از داده‌ها را داریم. اما ضرورت دانستن یک مجموعه جدید از واژگان چیست؟ مگر تجزیه و تحلیل پیشین ما چه ایرادی داشت؟ اولاً، حجم مطلق داده‌ها باعث می‌شود که به معنای واقعی کلمه برای یک انسان غیرممکن باشد که آن را در زمان قابل قبول تحلیل کند. داده‌ها در اشکال مختلف و از منابع مختلف و اغلب به صورت غیر سازماندهی شده جمع‌آوری می‌شوند.

داده‌ها می‌توانند از دست رفته، ناقص و یا فقط ظاهراً اشتباه باشند. اغلب داده‌هایی در مقیاس بسیار متفاوت داریم که کار مقایسه آن‌ها را نیز مشکل می‌کند. داده‌های مربوط به ماشین‌های مورداستفاده در قیمت‌گذاری را در نظر بگیرید. یکی از مشخصه‌های یک خودرو سال ساخت آن و دیگری ممکن است تعداد مسافت پیموده شده (مایل^۱) آن ماشین باشد. هنگامی که داده‌ها را تمیز می‌کنیم (که ما زمانی معادل خواندن این کتاب را صرف می‌کنیم)، روابط بین داده‌ها بیشتر آشکار می‌شود و دانشی که در عمق میلیون‌ها ردیف از داده‌ها محول شده بود، به سادگی آشکار می‌شود. یکی از اهداف اصلی علوم داده‌ها، ایجاد روش‌های صریح برای کشف و به‌کارگیری این روابط در داده‌ها است.

پیش از این، به علم داده با دیدگاه تاریخی نگاه کردیم، حال با استفاده از یک مثال ساده، نقش علم داده را در کسب و کار امروزی موردنبحث قرار خواهیم داد.

مثال - تکنولوژی‌های Sigma

Ben Runkle، مدیرعامل، تکنولوژی‌های سیگما^۲، در حال تلاش برای حل یک مشکل بزرگ است. این شرکت به‌طور مداوم مشتریان همیشگی خود را از دست می‌دهد. وی نمی‌داند چرا آن‌ها می‌روند، اما

¹ Mile

² Sigma

باید سریع‌تر کاری انجام دهد. او متقاعد شده است که باید محصولات و ویژگی‌های جدیدی ایجاد کند و فن‌آوری‌های موجود را یکپارچه کند. او برای اطیبان، به دکتر جسی هوگان^۱، متخصص ارشد داده خود مشورت می‌کند. با این حال، جسی متقاعد نشده است که محصولات و ویژگی‌های جدید به تنهایی این شرکت را نجات دهد. در عوض، Jessie به رونوشت‌های اخیر بلیط‌های خدمات مشتری آخرين Runkle Jessie به آنها رونوشت را نشان می‌دهد و چیزی شگفت‌آور پیدا می‌کند:

- "... مطمئن نیستید چگونه این صادرات را انجام دهید؛ همین‌طور است؟"
- "دکمه‌ای که یک لیست جدید ایجاد می‌کند کجاست؟"
- "صبر کنید، آیا شما می‌دانید کجا لغزنده است؟"
- "اگر امروز نمی‌توانم این را تصور کنم، این یک مشکل واقعی است ..."

واضح است که مشتریان با UX / UI موجود مشکل داشتند و به دلیل کمبود امکانات تاراحت نشدند. Runkle و Hughan یک پیاده‌سازی UX / UI انبوه را سازمان‌دهی کردند و فروش آن‌ها هرگز بهتر نشده بود.

البته، علم مورداستفاده در آخرین مثال، حداقل بود، اما یک نکته دارد که ما تعامل داریم افرادی مانند Runkle، را یک محرك بنامیم. امروزه رایج است مدیرعامل^۲ شرکت سهامی عام می‌خواهد همه تصمیمات را به سرعت بگیرد و راه حل‌ها را تا زمانی که آن چیز کار کند تکرار کند. دکتر هوگان بسیار تحمل‌گر است. او می‌خواهد مشکل را بیشتر از آنچه Runkle می‌خواهد، حل کند، او به جای احساس خستگی، برای پاسخ، به داده‌های تولیدشده کاربر رو آورد. علم داده در مورد به‌کارگیری مهارت‌های ذهنی تحلیلی و استفاده از آن‌ها به عنوان یک محرك است.

هر دو این ذهنیت‌ها در شرکت‌های امروز جای دارند. با این حال، این روش تفکر هوگان است که بر ایده‌های علوم داده حکم‌فرمایست یعنی - استفاده از داده‌های تولیدشده یک شرکت به عنوان منبع اطلاعات به جای این‌که فقط یک راه حل را برگزیند و با آن کنار بیایند.

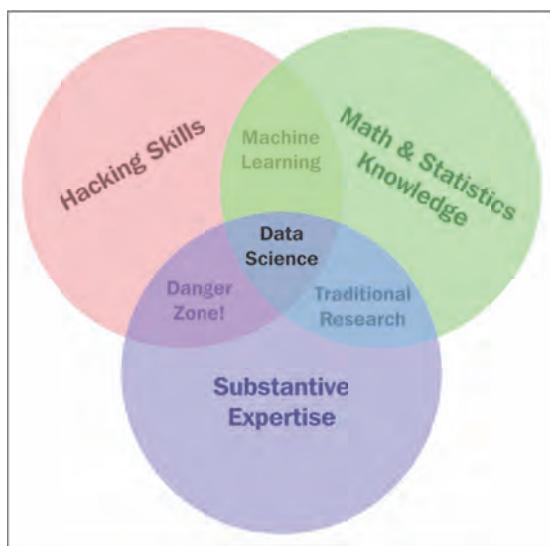
¹ Dr. Jessie Hughan

² CEO : Chief Executive Officer

نمودار ون علم داده^۱

یک تصور غلط رایج این است که گفته می‌شود تنها افراد نابغه و یا فارغ‌التحصیلان دکتری می‌توانند ریاضی به‌کاررفته در علوم داده را درک کنند. این مطلب کاملاً نادرست است. درک علوم داده با سه حوزه اساسی زیر همراه است:

- ریاضی / آمار: این حوزه به استفاده از معادلات و فرمول‌ها برای انجام تجزیه و تحلیل می‌پردازد.
- برنامه‌نویسی کامپیوتر: در این حوزه به توانایی استفاده از کد برای دستیابی به نتایج در کامپیوتر پرداخته می‌شود.
- دانش دامنه: در این حوزه به درک دامنه مشکل (موردمطالعه) اشاره می‌شود. (پزشکی، امور مالی، علوم اجتماعی و غیره)
- نمودار ون زیر یک نمایش دیداری را از چگونگی ارتباط این سه حوزه نشان می‌دهد:



شکل ۲ نمودار ون علم داده

افراد دارای مهارت‌های هک کردن^۲ می‌توانند الگوریتم‌های پیچیده را با استفاده از زبان‌های کامپیوتری درک کنند. داشتن دانش در زمینه ریاضی و آمار، امکان فرضیه‌سازی و ارزیابی

¹ The data science Venn diagram

² Hacking

الگوریتم‌ها را فراهم نموده و روش‌های موجود با موقعیت‌های خاص را تنظیم می‌کند. با داشتن تخصص اصلی (تخصص دامنه) امکان به کارگیری مفاهیم و نتایج به روشنی مؤثر و معنی‌دار فراهم می‌شود.

برای این‌که در این حوزه، از مهارت‌های کافی بهره‌مند شوید (در این حوزه باهوش باشید) داشتن تنها دو مورد از تخصص‌های ذکر شده لازم است اما کافی نیست و سبب ایجاد شکاف در این زمینه از علم خواهد شد. فرض کنید شما فرد ماهری در کدنویسی (برنامه‌نویسی) هستید ضمن این‌که در زمینه تجارت روزانه نیز از آموزش رسمی برخوردار شده باشید. در این صورت می‌توانید یک سیستم خودکار برای تجارت در محل خود ایجاد کنید. اما از آنجاکه مهارت‌های ریاضی برای ارزیابی الگوریتم‌های خود ندارید بنابراین درنهایت، در بلندمدت پول خود را از دست می‌دهید. تنها زمانی می‌توانید علم داده را به درستی انجام دهید که در سه حوزه برنامه‌نویسی، ریاضی و دانش حوزه موردنظر، از مهارت‌های کافی برخوردار باشید.

^۱ دانش حوزه^۱، موردنی است که ممکن است برای شما تعجب‌برانگیز باشد. در حقیقت دانش حوزه، همان دانش خاص حوزه‌ای است که در آن کار می‌کنید. اگر یک تحلیلگر مالی بخواهد داده‌های مربوط به حملات قلبی را تجزیه و تحلیل کند، آنگاه برای درک تعدادی زیادی از اعداد به کمک یک متخصص قلب نیاز خواهد داشت.

علم داده اشتراک سه حوزه اصلی است که پیش‌تر ذکر شد. برای دستیابی به دانش از روی داده، باید از برنامه‌نویسی کامپیوتر برای دسترسی به داده استفاده نمود. از ریاضی برای فهم مدل‌هایی که ایجاد می‌شوند بهره برد و از همه مهم‌تر این‌که موقعیت‌های تجزیه و تحلیل را در حوزه دانشی که هستیم درک کنیم. این شامل ارائه داده‌ها می‌شود. اگر یک مدل برای پیش‌بینی حملات قلبی در بیماران ایجاد کنیم، آنگاه بهتر است برنامه یا پی‌دی‌افی از اطلاعات تهیه نمود به‌طوری‌که بتوان اعداد (شماره‌ها) را در آن تایپ نمود و پیش‌بینی سریع را دریافت کرد. همه این تصمیمات باید توسط یک متخصص علوم داده گرفته شود.

همچنین توجه داشته باشید که اشتراک دو حوزه ریاضی و برنامه‌نویسی، یادگیری ماشین است. در این کتاب با جزئیات بیشتری به یادگیری ماشین خواهیم پرداخت. اما توجه به این مطلب مهم است که الگوریتم‌های یادگیری ماشین دارای قابلیت‌های واضحی برای تعمیم مدل یا نتایج در هر حوزه‌ای به شمار می‌روند که به راحتی بر روی کامپیوتر قرار می‌گیرند. شما ممکن است بهترین الگوریتم را برای پیش‌بینی سرطان داشته باشید. می‌توانید بیماری سرطان را با صحت ۹۹٪ بر اساس داده‌های گذشته

^۱ Domain knowledge

بیماران مبتلا به سرطان پیش‌بینی کنید اما اگر توانایی به کارگیری این مدل را از لحاظ عملی نداشته باشید، نظیر این‌که پزشکان و پرستاران بتوانند به راحتی از این مدل استفاده کنند، آنگاه این مدل بی‌فایده است.

هر دو حوزه برنامه‌نویسی کامپیوتر و ریاضی به‌طور گسترده در این کتاب پوشش داده شده است. دانش حوزه با هر دو جنبه عملی علم داده و خواندن نمونه‌هایی از تحلیل‌های دیگران همراه است.

ریاضی

بیشتر مردم وقتی فردی در مورد کلمه math صحبت می‌کند، گوش دادن را متوقف می‌کنند و تلاش می‌کنند خود را بی‌اطلاع از موضوع نشان دهند.

در سراسر این کتاب به ریاضیات موردنیاز برای علوم داده، بهویژه دو مبحث آمار و احتمال می‌پردازیم. هم‌چنین با استفاده از این زیر حوزه از ریاضی به ایجاد مدل‌ها خواهیم پرداخت.

یک مدل داده^۱ به یک ارتباط رسمی و سازمان‌یافته بین عناصر داده اشاره دارد که معمولاً باهدف شبیه‌سازی یک پدیده در دنیای واقعی ایجاد می‌شود.

به‌طور اساسی، از ریاضی برای فرمول سازی روابط بین متغیرها استفاده خواهیم نمود. به‌عنوان یک ریاضیدان (محض) سابق و معلم ریاضی فعلی، می‌دانم که چقدر این مرحله می‌تواند دشوار باشد. تا حد امکان این مراحل را با بهترین توضیح به‌صورت واضح انجام خواهم داد. در بین سه حوزه علوم داده، ریاضی قابلیت حرکت از یک حوزه به حوزه‌ای دیگر را فراهم می‌کند. درک این نظریه امکان به کارگیری مدل ساخته شده در صنعت مد را برای ایجاد یک مدل مالی نیز فراهم می‌کند.

مباحث ریاضی که در این کتاب پوشش داده می‌شود شامل جبر پایه تا مدل‌سازی‌های پیشرفته آماری و احتمالی هست. این فصل‌ها را از قلم نیندازید حتی اگر مطالبی را در مورد آن‌ها از قبل می‌دانید. هر مفهوم ریاضی را با دقت معرفی نموده و مثال‌ها و اهداف آن را توضیح خواهم داد. ریاضیات ارائه شده در این کتاب برای متخصصان علوم داده ضروری است.

مثال - مدل‌های spawner-recruit

در زیست‌شناسی، در میان بسیاری از مدل‌ها، از مدل شناخته شده spawner-recruit استفاده می‌کنیم که این مدل برای تشخیص سلامت بیولوژیکی یک‌گونه جانوری به کار می‌رود. در این مدل به ارتباط

^۱ Data model

اساسی بین تعداد واحدهای سالم والدین یک‌گونه و تعداد واحدهای جدید در یک گروه از جانوران پرداخته می‌شود. در مجموعه داده‌های عمومی تعداد recruits و salmon spawners، نمودار زیر برای تجسم ارتباط بین این دو گونه ترسیم شده است. به طورقطع نوعی ارتباط مثبت وجود دارد. (به دنبال افزایش یکی، دیگری نیز افزایش می‌یابد). اما چگونه می‌توان این رابطه را فرمول سازی کرد؟ برای مثال، اگر تعداد spawnerها در یک جمعیت معلوم باشد، آیا می‌توان تعداد recruit به دست آمده در یک گروه را پیش‌بینی نمود و بر عکس؟

به طور اساسی، با به کارگیری مدل‌ها می‌توان یک متغیر را به متغیری دیگر مرتبط کرد. مثال زیر را در نظر بگیرید:

$$\text{Recruits} = 0.5 * \text{Spawners} + 60$$

در این مثال، فرض کنید تعداد salmonها 1.15 (در هزار) در spawnerها باشد. در این صورت معادلات زیر را خواهیم داشت:

$$\text{Recruits} = 0.5 * 1.15 + 60$$

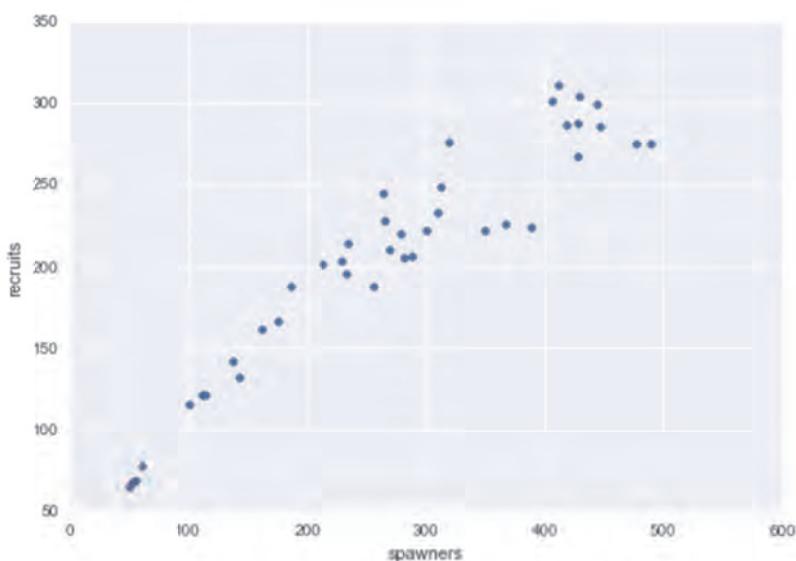
$$\text{Recruits} = 60.575 (\text{in thousands})$$

این نتیجه برای برآورد این‌که چه طور سلامت یک جامعه تغییر می‌کند، می‌تواند بسیار مفید باشد. اگر این مدل را ایجاد کنیم، آنگاه می‌توان به صورت عینی مشاهده کرد که چه طور ارتباط بین این دو متغیر می‌تواند تغییر کند.

انواع زیادی از مدل‌های داده‌ای شامل مدل‌های آماری و احتمالی وجود دارند. هر دو این‌ها زیرمجموعه‌ای از یک نمونه بزرگتر هستند که یادگیری ماشین^۱ نامیده می‌شود. ایده اصلی در این سه موضوع این است که از داده‌ها برای ارائه بهترین مدل ممکن استفاده کنیم. دیگر به غرایز انسانی وابسته نیستیم بلکه به داده‌ها متکی هستیم.

هدف از این مقال نشان دادن این است که چگونه می‌توان ارتباط بین عناصر داده‌ای را با استفاده از معادلات ریاضی تعریف کرد. این واقعیت که مثلاً از داده‌های سلامت salmon استفاده شد، بی‌اهمیت است! در سراسر این کتاب، ارتباط‌هایی شامل بازاریابی دلار، تمایل داده‌ها (احساس)، بازدیدهای رستوران و بسیاری موارد دیگر را خواهیم دید. هدف اصلی این است که خوانندگان تا حد امکان در معرض هر دامنه‌ای قرار گرفته و با آن حوزه خاص آشنا شوند.

¹ Machine learning



The spawner-recruit model

ریاضی و برنامه‌نویسی ابزارهایی هستند که این امکان را برای متخصصان علوم داده فراهم می‌کنند که به عقب بازگشته و مهارت‌های خود را تقریباً در هر کجا اعمال کنند.

برنامه‌نویسی کامپیووتر

بیایید باهم صادق باشیم. احتمالاً فکر می‌کنید علوم کامپیووتر جالب‌تر از ریاضی باشد. بسیار خوب، شما را سرزنش نمی‌کنم. محتوای اخبار شامل خبرهایی از ریاضی نیست، بلکه حاوی خبرهایی از فن‌آوری است. تلویزیون را روشن نمی‌کنید که خبری را در مورد قضیه جدیدی از اعداد اول ببینید، بلکه به دنبال گزارش‌های تحقیقاتی هستید که چگونه آخرین گوشی‌های هوشمند می‌توانند باکیفیت بهتر، از گربه‌ها یا هر چیز دیگری عکس‌برداری کنند. زبان‌های کامپیووتری چگونگی برقراری ارتباط با ماشین را نشان داده و پیشنهادها را برای انجام به ماشین می‌دهند. یک کامپیووتر مانند یک کتاب می‌تواند به زیان‌های زیادی صحبت نموده و همین‌طور به زیان‌های زیادی نوشته شود. به همین ترتیب (به‌طور مشابه) علم داده نیز می‌تواند توسط زبان‌های بسیاری انجام شود. Python، Julia و R از جمله زبان‌های در دسترس هستند. این کتاب منحصراً در استفاده از پایتون تمرکز خواهد کرد.

چرا Python؟

به دلایل مختلف زیر از پایتون استفاده خواهیم کرد:

- پایتون یک زبان بسیار ساده برای خواندن و نوشتن است، حتی اگر پیش‌تر هرگز کدنویسی نکرده باشید، مثال‌های بعدی را حتی پس از اینکه شما این کتاب را خواندید آسان می‌سازد.
- یکی از رایج‌ترین زبان‌هایی است که هم در تولید و هم در محیط دانشگاهی (یکی از سریع‌ترین پیشرفت‌ها، به عنوان یک واقعیت) مورد استفاده قرار می‌گیرد.
- انجمان آنلاین این زبان به صورت گسترشده و دوستانه است، به این معنی که یک جست‌وجوی سریع در گوگل باید شامل نتایج متعدد از افرادی باشد که آن‌ها نیز با چنین شرایط مشابه (نه به‌طور کاملاً مشابه) مواجه شده و (مشکل آن‌ها) حل شده باشد.
- پایتون دارای ماژول‌های^۱ داده‌ای از پیش ساخته‌شده است که هر دو گروه افراد مبتدی و خبره در حوزه علوم داده می‌توانند از آن بهره‌مند شوند.

آخرین مورد احتمالاً بزرگ‌ترین دلیلی است که بر روی پایتون تمرکز خواهیم نمود. این ماژول‌های از پیش ساخته‌شده نه تنها قدرتمند هستند، بلکه به سادگی ایجاد می‌شوند. در پایان چند فصل اول، از این ماژول‌ها به راحتی استفاده خواهید نمود. برخی از این ماژول‌ها عبارت‌اند از:

- pandas
- sci-kit learn
- seaborn
- numpy/scipy
- requests (to mine data from the Web)
- BeautifulSoup (for the Web-HTML parsing)

پایتون در عمل

پیش از این‌که ادامه دهیم، مهم است که به بسیاری از مهارت‌های برنامه‌نویسی موردنیاز در پایتون اشاره کنیم.

در پایتون، متغیرهایی داریم که متغیرهایی برای اشیاء هستند. در ابتدا تنها روی مواردی اندک از این نوع اشیاء اساسی تمرکز خواهیم کرد:

- int (an integer)
 - Examples: 3, 6, 99, -34, 34, 11111111
- float (a decimal):
 - Examples: 3.14159, 2.71, -0.34567

¹ Modules