



مؤسسه فرهنگی هنری
دیباگران تهران

به نام خدا

مباحث نظری علم داده و یادگیری ماشین

در پایتون

با پیاده سازی کامل در محیط پایتون

مؤلف:

آتیلا قشقایی

(مدرس حوزه علم داده و هوش مصنوعی)



هرگونه چاپ و تکثیر از محتویات این کتاب بدون اجازه کتبی
ناشر ممنوع است. متخلفان به موجب قانون حمایت حقوق
مؤلفان، مصنفان و هنرمندان تحت پیگرد قانونی قرار می‌گیرند.

عنوان کتاب: مباحث نظری علم داده و یادگیری ماشین در پایتون

با پیاده سازی کامل در محیط پایتون

مؤلف: آتیلا قشقایی

ناشر: موسسه فرهنگی هنری دیباگران تهران

ویراستار: مهدیه مخبری

صفحه آرایی: نازنین نصیری

طراح جلد: داریوش فرسایی

نوبت چاپ: اول

تاریخ نشر: ۱۴۰۳

چاپ و صحافی: ثامن

تیراژ: ۱۰۰ جلد

قیمت: ۲۹۸۰۰۰۰ ریال

شابک: ۹۷۸-۶۲۲-۲۱۸-۸۵۸-۰

نشانی واحد فروش: تهران، خیابان انقلاب، خیابان دانشگاه

- تقاطع شهدای زاندارمی - پلاک ۱۵۸ ساختمان دانشگاه -

طبقه دوم - واحد ۴ تلفن ها: ۰۲۰۸۵۱۱۱-۶۶۹۶۵۷۴۹ -

فروشگاههای اینترنتی دیباگران تهران :

WWW.MFTBOOK.IR

www.dibagaran Tehran.com

dibagaran_publishing نشانی اینستاگرام دیبا

نشانی تلگرام: @mftbook

هر کتاب دیباگران، یک فرصت جدید علمی و شغلی.

هرگوشی همراه، یک فروشگاه کتاب دیباگران تهران.

از طریق سایتها دیباگران، در هر جای ایران به کتابهای ما دسترسی دارید.

فهرست مطالب

۷.....	مقدمه ناشر.....
۱۰	فصل اول تجزیه و تحلیل داده ها
۱۰.....	عناصر داده های ساخت یافته
۱۱.....	داده های مستطیلی
۱۳.....	چارچوب ها و شاخص های داده
۱۳.....	ساختارهای داده غیر مستطیلی
۱۵.....	خلاصه در علم داده
۱۶.....	تخمین موقعیت مکانی
۱۷.....	میانگین
۱۷.....	میانگین پیراسته یا میانگین اصلاحی
۱۸.....	میانگین وزنی
۱۸.....	میانه (Median)
۲۰.....	میانه وزنی (Weighted Mean)
۲۱.....	مقادیر پرت (Outliers)
۲۱.....	تخمین نوع و پراکندگی
۲۱.....	واریانس S^2
۲۲.....	انحراف معیار (STD)
۲۲.....	تفاوت واریانس و انحراف معیار
۲۳.....	میانگین قدر مطلق انحراف (Mean absolute Deviation)
۲۴.....	میانه قدر مطلق انحراف (Median Absolute Deviation - MAD)
۲۴.....	تشخیص ناپهنجاری (Anomaly Detection)
۲۵.....	ناهنجری نقطه ای (Point Anomaly)
۲۵.....	ناهنجری زمینه ای (Contextual Anomaly)
۲۶.....	روش های بصری ساده برای تشخیص ناپهنجاری
۲۸.....	روش های تشخیص ناپهنجاری با استفاده مدل ها و توابع
۳۱.....	Range
۳۲.....	چند ک در علم داده (Quantile)
۳۳.....	IQR یا فاصله بین چارکی (Interquartile Range)
۳۶.....	نما (Mode)
۳۶.....	گشتاور در آمار
۳۷.....	نمودارهای میله ای
۳۸.....	نمودارهای دایره ای

۳۹	نمودارهای خطی.....
۴۰	نمودارهای پراکنده‌گی.....
۴۱	نمودارهای جعبه‌ای.....
۴۲	نمودارهای حرارتی.....
۴۳	نمودار هیستوگرام (Histogram) در پایتون.....
۴۴	نمودار هگزبین Hexbin Plot.....
۴۵	همبستگی (Correlation).....
۴۶	همبستگی خطی.....
۴۷	روش تشخیص نوع همبستگی.....
۴۹	احتمال در آمار.....
۵۱	مفاهیم کلیدی در احتمال.....
۵۱	قوانين اساسی احتمال.....
۵۲	قانون جمع احتمال برای رویدادهای مستقل.....
۵۳	قانون جمع احتمال برای رویدادهای غیرمستقل.....
۵۴	امید ریاضی.....
۵۵	خلاصه.....

فصل دوم داده‌ها و توزیع‌های نمونه‌گیری

۵۶	نمونه‌گیری تصادفی و سوگیری نمونه.....
۵۶	سوگیری (Bias).....
۵۸	انتخاب تصادفی.....
۵۹	اندازه در مقابل کیفیت.....
۶۰	چه زمانی به مقادیر انبوه داده نیاز است؟.....
۶۰	آشنایی با توزیع نمونه‌ای.....
۶۱	تفاوت توزیع نمونه با توزیع جمعیت.....
۶۲	خطای استاندارد (Standard Error).....
۶۲	تفاوت خطای استاندارد و انحراف استاندارد.....
۶۳	محاسبه خطای استاندارد با یک نمونه یا چند نمونه.....
۶۵	بوت استرپ (Bootstrapping) چیست؟.....
۶۸	فاصله اطمینان (Confidence Interval - CI).....
۷۲	نمودار چندک-چندک Q-Q-PLOT.....
۷۵	درجه آزادی (df) چیست؟.....
۷۷	چولگی (Skewness).....
۷۷	کشیدگی (Kurtosis).....
۷۸	توزع نرمال.....
۸۴	توزع یونیفرم (یکنواخت).....

۸۶	توزیع برنولی
۸۸	توزیع چند جمله‌ای (مالتی نومینال)
۹۰	توزیع آماری نوع t - (t-Distribution)
۹۴	توزیع دو جمله‌ای
۹۵	تابع جرم احتمال PMF
۹۶	تابع توزیع تجمعی CDF.
۹۷	تابع چگالی احتمال (PDF)
۹۹	توزیع نمایی (Exponential Distribution)
۱۰۴	توزیع پواسون
۱۰۷	توزیع خی دو (Chi-Square)

فصل سوم آزمایش‌های آماری و آزمون فرض آماری

۱۱۱	آزمون آماری و آزمون فرض آماری
۱۱۲	آزمون‌های فرضیه
۱۱۳	فرضیه صفر
۱۱۴	نمونه‌گیری مجدد
۱۱۵	تست A/B
۱۱۷	تست جایگشت - جابجایی (Permutation Test)
۱۲۴	آزمون t
۱۲۸	آزمون خی دو (Chi-Square)
۱۳۲	آزمون فیشر - F
۱۳۷	آزمون پواسون
۱۴۱	یادگیری ماشین کلاسیک چیست؟
۱۴۱	انواع یادگیری ماشین
۱۴۱	۱. یادگیری تحت نظارت (Supervised Learning)
۱۴۲	۲. یادگیری بدون نظارت (Unsupervised Learning)
۱۴۳	۳. یادگیری تقویتی (Reinforcement Learning)
۱۴۴	آینده یادگیری ماشین
۱۴۶	زمینه‌های نوظهور
۱۴۶	نتیجه‌گیری

فصل چهارم رگرسیون و پیش‌بینی

۱۴۹	رگرسیون خطی ساده (Simple Linear Regression)
۱۵۲	رگرسیون خطی چندگانه (Multiple Linear Regression)
۱۵۴	رگرسیون ریج (Ridge Regression)
۱۵۷	رگرسیون الاستیک نت (Elastic Net Regression)

۱۵۹.....	رگرسیون پولینومیال (Polynomial Regression)
۱۶۱.....	مدل های رگرسیون براساس فاکتور محبوبیت
۱۶۳.....	معیارهای بررسی عملکرد در مدل های رگرسیون
۱۶۳.....	کاربردهای متريک های مدل رگرسیون و انواع آن
۱۶۷.....	محبوبیت و کاربرد هر یک از متريکها

۱۷۰ طبقه بندی و پیش بینی فصل پنجم

۱۷۰.....	رگرسیون لجستیک (Logistic Regression)
۱۷۴.....	الگوریتم K نزدیک ترین همسایه (K-Nearest Neighbors)
۱۸۱.....	درخت تصمیم (Decision Tree Model)
۱۸۴.....	مدل جنگل تصمیم (Random Forest)
۱۸۸.....	ماشین بردار پشتیبان (SVM)
۱۹۲.....	مدل SVR برای مسائل رگرسیون
۱۹۳.....	معیارهای ارزیابی مدل های طبقه بندی در یادگیری ماشین
۱۹۸.....	محبوبیت و کاربرد هر یک از معیارهای طبقه بندی

۲۰۰ الگوریتم های خوش بندی فصل ششم

۲۰۲.....	الگوریتم K-Means
۲۰۶.....	خوش بندی سلسله مراتبی (Hierarchical Clustering)
۲۱۰.....	الگوریتم DBSCAN (خوش بندی فضایی مبتنی بر تراکم با نویز)
۲۱۵.....	الگوریتم OPTICS (شناسایی ساختار خوش بندی با مرتب سازی نقاط)
۲۱۷.....	مدل پنهان مارکوف (HMM) چیست؟
۲۲۰.....	معیارهای ارزیابی دقت (Metrics) مدل های خوش بندی

۲۲۵ مدل های کاهش بعد (Dimensionality Reduction) فصل هفتم

۲۲۸.....	مدل کاهش بعد PCA (تجزیه و تحلیل مؤلفه اصلی)
۲۳۱.....	مدل کاهش بعد ICA (تجزیه و تحلیل مؤلفه مستقل)
۲۳۸.....	مدل کاهش بعد Random Projection RP

۲۴۰ مدل های دسته بندی (Ensemble Methods) فصل هشتم

۲۴۵.....	مدل جنگل تصادفی (Random Forest) این بار برای دسته بندی
۲۴۹.....	مدل بوستینگ (Boosting)
۲۵۱.....	الگوریتم پایلینگ (Stacking)
۲۵۳.....	معیارهای متريک برای مدل های دسته بندی
۲۵۵.....	معیارهای متداول برای مدل های دسته بندی به ترتیب محبوبیت

مقدمه ناشر

خط مشی انتشارات مؤسسه فرهنگی هنری دیباگران تهران در عرصه کتاب های با کیفیت عالی است که بتواند خواسته های بر روز جامعه فرهنگی و علمی کشور را تا حد امکان پوشش دهد.

هر کتاب دیباگران تهران، یک فرصت جدید شغلی و علمی

حمد و سپاس ایزد منان را که با الطاف بیکران خود این توفیق را به ما ارزانی داشت تا بتوانیم در راه ارتقای دانش عمومی و فرهنگی این مرز و بوم در زمینه چاپ و نشر کتب علمی و آموزشی گامهایی هر چند کوچک برداشته و در انجام رسالتی که بر عهده داریم، مؤثر واقع شویم.

گستردگی علوم و سرعت توسعه روزافزون آن، شرایطی را به وجود آورده که هر روز شاهد تحولات اساسی چشمگیری در سطح جهان هستیم. این گسترش و توسعه، نیاز به منابع مختلف از جمله کتاب را به عنوان قدیمی ترین و راحت ترین راه دستیابی به اطلاعات و اطلاع رسانی، بیش از پیش برجسته نموده است.

در این راستا، واحد انتشارات مؤسسه فرهنگی هنری دیباگران تهران با همکاری اساتید، مؤلفان، مترجمان، متخصصان، پژوهشگران و محققان در زمینه های گوناگون و مورد نیاز جامعه تلاش نموده برای رفع کمبودها و نیازهای موجود، منابعی پُربار، معتربر و با کیفیت مناسب در اختیار علاقمندان قرار دهد.

کتابی که در دست دارد تألیف "جناب آقای آتیلا قشقایی" است که با تلاش همکاران ما در نشر دیباگران تهران منتشر گشته و شایسته است از یکایک این گرامیان تشکر و قدردانی کنیم.
با نظرات خود مشوق و راهنمای ما باشید

با ارائه نظرات و پیشنهادات و خواسته های خود، به ما کمک کنید تا بهتر و دقیق تر در جهت رفع نیازهای علمی و آموزشی کشورمان قدم برداریم. برای رساندن پیام هایتان به ما از رسانه های دیباگران تهران شامل سایتها فروشگاهی و صفحه اینستاگرام و شماره های تماس که در صفحه شناسنامه کتاب آمده استفاده نمایید.

مدیر انتشارات

مؤسسه فرهنگی هنری دیباگران تهران
dibagaran@mftplus.com

بنام حضرت دوست

تقدیم به روان پاک پدرم

در ابتدا باید تشکر کنم از مادر عزیزم که مشوق من برای نگارش این کتاب بود، کاری که یکسال از وقت من را گرفت ولی خروجی آن باعث می‌شود دانشجویان حوزه علم داده و یادگیری ماشین پس از اتمام دوره‌های لازم در این گرایش‌ها بتوانند با تکمیل کردن دانششان در این علوم، آماده رویارویی با مسائل واقعی در این حوزه‌ها گردند و اینگونه نباشد که فقط دانش ابزاری در این زمینه را یدک بکشند و درکی از مسئله و رویکرد حل آن نداشته باشند.

مطلوبی که در این کتاب بیان شده است مسلمًا خارج از وقت و حوصله دوره‌های تخصصی این گرایش‌ها می‌باشدند چون آنقدر در این حوزه‌ها ابزار فراوانند که وقتی برای بیان علوم پایه آن نمی‌ماند و عموماً کسب این دانش به عهده دانشجو گذارده می‌شود و یا حتی انتظار می‌رود که این دانش را دانشجو از قبل همراه داشته باشد.

مخاطب این کتاب

مخاطب این کتاب دانشجویان پایتون و علاقمندان علم داده می‌باشند که اولاً به زبان پایتون آشنا بوده و همچنین با کتابخانه‌های مورد نیاز آنالیز داده و یادگیری ماشین در پایتون مانند Numpy، Pandas، Matplotlib، Sklearn آشنایی حداقلی را داشته باشند و در این مرحله می‌خواهند آن فضاهای خالی علمی میان این ابزارها تا نقطه انجام یک پروژه واقعی را پر کنند همان بخش‌هایی که در هیچ کلاس استاندارد علم داده‌ای به آنها پرداخته نخواهد شد و آن را پوشش نخواهد داد این کتاب تمام مفاهیم مهم و کاربردی علم آمار برای علم داده را همراه با نحوه پیاده‌سازی آنها در زبان پایتون را به شما عرضه می‌دارد و شما را قادر می‌سازد درکی درست از مفاهیم و اصطلاحات علم آمار برای علم داده بدست آورید، همچنین نگاهی کاربردی به انواع الگوریتم‌های یادگیری ماشین دارد و آنها را از بُعد حل مسئله مورد بررسی و طبقه‌بندی قرار می‌دهد.

در این کتاب بر عکس اکثر کتاب‌های این حوزه که چند سکویی می‌باشند و هر قسمت از یک مسئله را با یک نرم‌افزار یا زبانی خاص بیان می‌کنند، تک سکویی بوده و فقط از پایتون برای پیاده‌سازی تمامی این مفاهیم استفاده می‌نماید که البته من به شخصه این را بزرگترین نقطه قوت این کتاب می‌دانم.

درنهایت این کتاب را باید به عنوان یک مرجع نگاه کرد نه صرفاً یک کتاب آموزشی و اکیداً توصیه می‌شود اگر به این علوم علاقمندید آن را کنار دست خود داشته باشید.

همراه کتاب فایل‌ها و دیتاسته‌های مربوطه نیز وجود دارد که می‌توانید از آدرس مخزن عمومی اینجا نسب در گیت هاب دانلود نمایید.

<https://github.com/atila1358/DS-ML>

در پایان تشکر می‌کنم از جناب مهندس فرسایی مدیریت انتشارات دیباگران تهران و تیم سخت‌کوش ایشان که با وجود شرایط بسیار بد در حوزه نشر هنوز هم به جهت اعتلای دانش این سرزمهین تلاش می‌کنند و امیدوارم در این مسیر همچون گذشته پر فروغ باشند.

Site: www.poyeshmashin.ir

Email: atila.gh@gmail.com

با طلب خیر

آتیلا قشقایی

۱۴۰۳