



به نام خدا

ملزومات آماری در علم داده ها

شامل بیش از ۵۰ کد R و پایتون

مؤلفان:

ساره هرمزان (کارشناسی ارشد علوم کامپیوتر از دانشگاه تهران)

محمد رضاپور (عضو هیأت علمی وزارت علوم، تحقیقات و فناوری)

سینا توکلی بنیزی (کارشناسی مهندسی صنایع)



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: **ملزومات آماری در علم داده ها** **شامل بیش از ۵۰ کد R و پایتون**

مولفان: ساره هرمزان - محمد رضا پور - سینا توکلی بنیزی



- ناشر: موسسه فرهنگی هنری دیباگران تهران
- ویراستار: نرگس مهربد
- صفحه آرایی: نازنین نصیری
- طراح جلد: داریوش فرسایی
- نوبت چاپ: اول
- تاریخ نشر: ۱۴۰۱
- چاپ و صحافی: صدف
- تیراژ: ۱۰۰ جلد
- قیمت: ۲۴۰۰۰۰ ریال
- شابک: ۹۷۸-۶۲۲-۲۱۸-۶۰۰-۵
- نشانی واحد فروش: تهران، میدان انقلاب، خ کارگر جنوبی، روبروی پاساز مهستان، پلاک ۱۲۵۱ - تلفن: ۰۲۰-۸۵۱۱۱-۶۶۴۱۰۰۴۶
- فروشگاههای اینترنتی دیباگران تهران:
WWW.MFTBOOK.IR
www.dibagaran Tehran.com

نشانی تلگرام: **@mftbook** نشانی اینستاگرام دیبا

هر کتاب دیباگران، یک فرست جدید علمی و شغلی.

هر گوشی همراه، یک فروشگاه کتاب دیباگران تهران.

از طریق سایتهای دیباگران، در هرجای ایران به کتابهای مادرستی دارید.

این کتاب با کاغذ حمایتی منتشر شده است

فهرست مطالب

۱۲.....	مقدمه ناشر
۱۳.....	پیش‌گفتاری بر «ملزومات آماری در علم داده‌ها»
فصل صفر	
۱۵.....	کتاب‌شناسی و تقدیم به ...
۱۶.....	قواعد مورد استفاده در این کتاب
۱۷.....	اصطلاحات کلیدی و نمادهای استفاده شده در کتاب
۱۷.....	استفاده از مثال‌های کد
۱۸.....	تقدیم به
فصل اول	
۱۹.....	تحلیل اکتشافی داده‌ها
۲۰.....	عناصر داده‌های ساخت‌یافته
۲۲.....	مطالعه بیش‌تر
۲۳.....	داده‌های مستطیلی
۲۴.....	دیتا فریم‌ها و اندیس‌ها
۲۵.....	ساختارهای داده‌های غیرمستطیلی
۲۶.....	برآورد مکان
۲۷.....	خلاصه‌سازی داده‌ها
۲۷.....	میانگین
۲۸.....	میانه و برآوردهای مقاوم
۲۹.....	داده‌های پرت
۳۰.....	مثال: برآوردهای مکان جمعیت و نرخ جرم و جنایت
۳۱.....	مطالعه بیش‌تر
۳۱.....	برآورد پراکندگی
۳۳.....	انحراف استاندارد و برآوردهای مربوط به آن
۳۵.....	برآوردهای مبتنی بر صدک
۳۶.....	مثال: برآوردهای پراکندگی جمعیت ایالاتی
۳۷.....	مطالعه بیش‌تر

۳۷	کشف توزیع داده
۳۸	صدقها و نمودارهای جعبه‌ای
۴۰	جداول فراوانی و هیستوگرامها
۴۲	نمودارهای چگالی و برآوردها
۴۴	مطالعه بیشتر
۴۵	کشف داده‌های دودویی و دسته‌ای
۴۷	داده‌های «عددی» به عنوان داده‌های «دسته‌ای»
۴۷	مد
۴۷	امید ریاضی
۴۸	احتمال
۴۸	همبستگی
۵۲	نمودارهای نقطه‌ای
۵۳	مطالعه بیشتر
۵۳	اکتشاف دو یا چند متغیر
۵۴	انبارک شش‌ضلعی و کانتورها (رسم داده‌های عددی در مقابل داده‌های عددی)
۵۶	دو متغیر دسته‌ای
۵۸	داده‌های دسته‌ای و عددی
۶۰	نمایش چند متغیر
۶۲	مطالعه بیشتر
۶۲	خلاصه

فصل دوم

۶۳	توزیع داده و نمونه‌گیری
۶۵	نمونه‌گیری تصادفی و بایاس نمونه
۶۶	بایاس نمونه‌گیری خودگزین
۶۷	بایاس
۶۸	انتخاب تصادفی
۶۸	اندازه در مقابل کیفیت: چه زمانی اندازه مهم است؟
۶۹	میانگین نمونه در مقابل میانگین جمعیت
۷۰	مطالعه بیشتر
۷۰	بایاس انتخاب
۷۲	رگرسیون به میانگین
۷۳	مطالعه بیشتر
۷۳	توزیع نمونه‌گیری یک آماره
۷۶	نظریه حد مرکزی

۷۶	خطای استاندارد
۷۷	مطالعه بیشتر
۷۸	بوت استرپ
۸۱	نمونه‌گیری مجدد در مقابل بوت استرپ
۸۱	مطالعه بیشتر
۸۲	بازه‌های اطمینان
۸۴	توزیع نرمال
۸۵	نمودارهای QQ و نرمال استاندارد
۸۷	توزیع‌های دمطولانی
۸۹	مطالعه بیشتر
۸۹	توزیع t دانش‌آموز
۹۱	مطالعه بیشتر
۹۱	توزیع دوچمله‌ای
۹۴	مطالعه بیشتر
۹۴	توزیع مربع-کای
۹۵	مطالعه بیشتر
۹۵	توزیع F
۹۵	مطالعه بیشتر
۹۶	پواسون و توزیع‌های مربوطه
۹۶	توزیع پواسون
۹۷	توزیع نمایی
۹۷	تخمین نرخ شکست (خرابی)
۹۸	توزیع ویبول
۹۹	مطالعه بیشتر
۹۹	خلاصه

فصل سوم

۱۰۰	آزمایش‌های علمی و آزمون معناداری
۱۰۱	آزمون A/B
۱۰۴	چرا باید گروه کنترل داشته باشیم؟
۱۰۵	چرا فقط A/B، C/D، ... نه؟
۱۰۶	مطالعه بیشتر
۱۰۶	آزمون‌های فرضیه
۱۰۷	فرض صفر
۱۰۸	فرضیه جایگزین

۱۰۸	آزمون‌های یک‌طرفه در مقابل آزمون‌های دوطرفه
۱۰۹	مطالعه بیشتر
۱۰۹	نمونه‌گیری مجدد
۱۱۰	آزمون جایگشت
۱۱۱	مثال: جذابیت وب
۱۱۵	آزمون‌های جایگشت بوت استرپ و کامل
۱۱۵	آزمون‌های جایگشت: خط پایان علوم داده
۱۱۶	مطالعه بیشتر
۱۱۶	معناداری آماری و مقادیر p
۱۱۹	مقدار p
۱۲۰	alfa
۱۲۱	جدال بر سر مقدار p
۱۲۲	معناداری کاربردی
۱۲۲	خطاهای نوع ۱ و نوع ۲
۱۲۲	علوم داده و مقدار p
۱۲۳	مطالعه بیشتر
۱۲۳	آزمون‌های t
۱۲۵	مطالعه بیشتر
۱۲۵	آزمون چندگانه
۱۲۹	مطالعه بیشتر
۱۲۹	درجه آزادی
۱۳۰	ANOVA
۱۳۴	F آماره
۱۳۵	ANOVA دوطرفه
۱۳۶	مطالعه بیشتر
۱۳۶	آزمون مریع کای
۱۳۶	آزمون مریع کای: یک روش نمونه‌گیری مجدد
۱۳۹	آزمون مریع کای: نظریه آماری
۱۴۰	آزمون دقیق فیشر
۱۴۲	ارتباط برای علوم داده
۱۴۳	مطالعه بیشتر
۱۴۳	الگوریتم راهزن چنددست
۱۴۶	مطالعه بیشتر
۱۴۶	قدرت و اندازه نمونه
۱۴۸	اندازه نمونه

۱۵۰	مطالعه بیشتر
۱۵۰	خلاصه

فصل چهارم

۱۵۱ رگرسیون و پیش‌بینی

۱۵۲	رگرسیون خطی ساده
۱۵۳	معادله رگرسیون
۱۵۶	مقادیر برآش شده و ماندها
۱۵۸	حدائق مربعات
۱۵۹	پیش‌بینی در مقابل توضیح (پروفایلینگ)
۱۵۹	رگرسیون خطی چندگانه
۱۶۰	مثال: داده‌های خانه‌های کینگ کانتی
۱۶۲	ارزیابی مدل
۱۶۶	اعتبارسنجی متقابل
۱۶۷	انتخاب مدل و رگرسیون گام به گام
۱۷۱	رگرسیون وزن دار
۱۷۳	مطالعه بیشتر
۱۷۳	پیش‌بینی با استفاده از رگرسیون
۱۷۳	خطرات برون‌بایی
۱۷۴	بازه‌های اطمینان و پیش‌بینی
۱۷۵	متغیرهای عامل در رگرسیون
۱۷۶	نمایش متغیرهای ساختگی
۱۷۹	متغیرهای عامل با چندین سطح
۱۸۱	متغیرهای عاملی مرتب
۱۸۲	تفسیر معادله رگرسیون
۱۸۲	پیشگوهای همبسته
۱۸۴	هم خطی چندگانه
۱۸۴	متغیرهای مختلط
۱۸۶	تعامل‌ها و اثرات مهم
۱۸۸	تشخیص‌های رگرسیون
۱۸۹	داده‌های پرت
۱۹۱	مقادیر تأثیرگذار
۱۹۳	ناهمواریانسی، نرمال نبودن و خطاهای همبسته
۱۹۶	نمودارهای مانده جزئی و غیرخطی بودن
۱۹۸	رگرسیون اسپیلاین و چندجمله‌ای

۱۹۹	چندجمله‌ای
۲۰۱	اسپیلاین
۲۰۲	مدل‌های جمعی تعمیم‌یافته
۲۰۴	مطالعه بیشتر
۲۰۴	خلاصه

فصل پنجم

۲۰۵	طبقه‌بندی
۲۰۷	نایو بیز
۲۰۸	چرا طبقه‌بندی بیزین دقیق غیرکاربردی است؟
۲۰۸	راه حل نایو
۲۱۱	متغیرهای پیشگوی عددی
۲۱۲	مطالعه بیشتر
۲۱۲	تحلیل افتراقی
۲۱۳	ماتریس کوواریانس
۲۱۴	تفکیک‌کننده خطی فیشر
۲۱۴	مثال
۲۱۷	مطالعه بیشتر
۲۱۸	رگرسیون لجستیک
۲۱۸	تابع پاسخ لجستیک و لا جیت
۲۲۰	رگرسیون لجستیک و GLM
۲۲۱	مدل‌های خطی تعمیم‌یافته
۲۲۲	مقادیر پیش‌بینی شده رگرسیون لجستیک
۲۲۳	تفسیر ضرایب و نسبت شانس
۲۲۴	رگرسیون خطی و لجستیک: شباهت‌ها و تفاوت‌ها
۲۲۴	برازش مدل
۲۲۵	ارزیابی مدل
۲۲۷	تحلیل مانده‌ها
۲۲۹	مطالعه بیشتر
۲۲۹	ارزیابی مدل‌های طبقه‌بندی
۲۳۰	ماتریس اغتشاش
۲۳۲	مسئله کلاس نادر
۲۳۳	صحت، یادآوری و ویژگی
۲۳۴	منحنی ROC
۲۳۶	AUC

۲۳۷	لیفت.....
۲۳۹	مطالعه بیشتر
۲۳۹	استراتژی هایی برای داده های نامتوارن
۲۴۰	نمونه برداری کاهشی.....
۲۴۲	نمونه برداری افزایشی یا وزن دهی افزایشی / کاهشی
۲۴۳	تولید داده
۲۴۴	طبقه بندی مبتنی بر هزینه
۲۴۴	بررسی پیش بینی ها
۲۴۶	خلاصه

فصل ششم

۲۴۷	یادگیری ماشین آماری.....
۲۴۹	- نزدیک ترین همسایه k
۲۵۰	مثال: پیش بینی نکول.....
۲۵۲	معیارهای فاصله
۲۵۳	رمزگذار وان هات
۲۵۴	استانداردسازی (نرمال سازی، امتیاز Z)
۲۵۷	انتخاب K
۲۵۸	KNN به عنوان موتور ویژگی
۲۶۰	مدل های درختی
۲۶۲	مثال
۲۶۴	الگوریتم پارتبیشن بندی بازگشتی
۲۶۶	اندازه گیری همگن بودن یا خلوص
۲۶۸	جلوگیری از رشد درخت
۲۶۸	کنترل پیچیدگی در R
۲۶۹	کنترل پیچیدگی درخت در پایتون
۲۶۹	پیش بینی یک مقدار پیوسته
۲۷۰	درخت ها چگونه استفاده می شوند؟
۲۷۱	بگینگ و جنگل تصادفی
۲۷۲	بگینگ
۲۷۳	جنگل تصادفی
۲۷۷	اهمیت متغیر
۲۸۰	فرآپارامترها
۲۸۱	بوستینگ
۲۸۲	الگوریتم بوستینگ

۲۸۳	XGBOOST
۲۸۶	lightgbm
۲۸۸	Catboost
۲۸۹	اجتناب از بیش برآذش
۲۹۴	فرآپارامترها و اعتبارسنجی متقابل
۲۹۷	خلاصه

فصل هفتم

یادگیری بدون نظارت

۳۰۰	تحلیل مؤلفه اساسی
۳۰۱	مثال
۳۰۴	محاسبه مؤلفه‌های اساسی
۳۰۷	تحلیل تناظر
۳۰۹	خوشه‌بندی
۳۰۹	خوشه‌بندی k-means
۳۱۰	مثال
۳۱۳	k-means الگوریتم
۳۱۴	تفسیر خوشه‌ها
۳۱۵	انتخاب تعداد خوشه‌ها
۳۱۷	ارزیابی خوشه‌بندی
۳۱۸	Kmeans++ الگوریتم
۳۲۰	Mini-batch kmeans الگوریتم
۳۲۱	خوشه‌بندی DBSCAN
۳۳۰	خوشه‌بندی سلسله‌مراتبی
۳۳۱	مثال
۳۳۲	دندوگرام
۳۳۴	الگوریتم تجمعی
۳۳۴	معیارهای عدم تشابه
۳۳۶	خوشه‌بندی مبتنی بر مدل
۳۳۶	توزيع نرمال چندمتغیره
۳۳۸	ترکیب نرمال‌ها
۳۴۰	انتخاب تعداد خوشه‌ها
۳۴۳	مقیاس‌بندی و متغیرهای دسته‌ای
۳۴۳	روش‌های مختلف برای مقیاس‌بندی
۳۴۴	تأثیر مقیاس‌بندی خوشه‌بندی

۳۴۸	متغیرهای غالب
۳۴۷	داده‌های دسته‌ای و فاصله گاور
۳۵۰	مشکلات خوشه‌بندی داده‌های ترکیبی
۳۵۱	خلاصه
۳۵۲	منابع و مأخذ

مقدمه ناشر

خط میش 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 "سرکارخانم ساره هرمزان و آقایان محمدرضاپور- و سینا توکلی بنیزی" 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

پیش‌گفتاری بر «ملزومات آماری در علم داده‌ها»

روش‌های آماری بخش زیربنایی علوم داده هستند؛ اما با این وجود، تعداد کمی از دانشمندان علوم داده آموزش رسمی در این زمینه دیده‌اند. از طرف دیگر، سرفصل‌های درس‌هایی؛ مانند آمار مهندسی یا آمار و احتمالات و کتاب‌های آماری نیز، به ندرت موضوع‌های آماری را برای تکمیل نیازمندی‌های یک دانشمند علوم داده‌ها و از تگرش داده‌کاوی پوشش می‌دهند. این کتاب، با پر کردن این جای خالی، فاصله ظاهرآ قهرآمیز آمار و تحلیل داده‌ها با زبان‌های روز را پُر کرده و خواننده با شروع خواندن اولین فصل از کتاب درمی‌یابد، که تحلیلگران آماری فقط خود را به SPSS محدود نمی‌کنند و داده‌کاوی هم با وجود تسلط بر کدنویسی در زبان‌های تحلیل داده‌ها، از داشن آماری مربوطه بی‌نیاز نیستند.

این پیوند بین آمار و علوم داده‌ها را با مثال‌های جامعی در دو زبان R و Python به کتاب آورده‌ایم تا راهنمای کاربردی برای استفاده از روش‌های آماری برای علوم داده بوده و به شما کمک کند تا از این روش‌ها در جای مناسب استفاده کنید و بالآخره به شما نشان دهد که کدام روش مهم است و کدام‌یک از این منظر چندان اهمیتی ندارد! بی‌آنکه بخواهیم زحمات نویسنده‌گان دیگر را که ارزش جلوه دهیم؛ اما این مهم را قاطع‌تر مطرح کرده و در پی رفع آن برآمدیم؛ اینکه بسیاری از منابع علوم داده از روش‌های آماری استفاده می‌کنند؛ اما فاقد چشم‌انداز آماری عمیق و در خور داوری علمی هستند. پس اگر شما تا کنون با یکی از زبان‌های R یا پایتون هم آشنایی دارید و از بعضی از آماره‌های آن استفاده کرده‌اید، این راهنمای سریع می‌تواند شکاف موجود را به‌طور خوانا و دسترس‌پذیر پُر نماید.

در این کتاب می‌آموزید:

- چرا تحلیل داده‌های توصیفی یک گام کلیدی در علوم داده است.
- چگونه نمونه‌گیری تصادفی می‌تواند بایاس را کاهش داده و به مجموعه داده‌ای باکیفیت‌تر حتی هنگام کار با کلان‌داده‌ها شود.
- چگونه اصول طراحی آزمایشی به جواب‌های قطعی برای سوالات منجر می‌شود.
- چگونه از رگرسیون برای تخمین خروجی‌ها و تشخیص ناهنجاری‌ها استفاده می‌شود.
- روش‌های یادگیری ماشین آماری که از روی داده‌ها «یاد می‌گیرند».
- روش‌های یادگیری نظارت‌نشده برای استخراج مفاهیم از داده‌های بدون برچسب.

این کتاب نه یک کتاب آمار و نه یک راهنمای یادگیری ماشین است، بلکه تلفیقی از این دو است: مفاهیم مهم و ضروری آماری با اصطلاحات داده‌کاوی که در زبان‌های امروزی تحلیل داده‌ها متدال هستند، در این کتاب تلفیق و تبیین می‌شوند، آن‌هم همراه با توضیحات واضح و مثال‌های فراوان. بی‌اعراق بگوییم، متنی آماده شده که برای مبتدیان علوم داده لازم و برای افراد با تجربه هم لذیذ است!

لذت کتاب صرفاً به خاطر مرور دانسته‌های دانشی نیست؛ کتاب مبنای آماری دقیق از کاربردهای مهندسی داده‌ها را شرح می‌دهد که یکی از فواید آن بسنده نکردن به خروجی نرم‌افزارها و ارائه پژوهش‌های قابل پذیرش در داوری‌های سخت‌گیرانه است!

در واقع، یکی از مشکلات سال‌های اخیر که گریبان‌گیر پژوهشگران شده، کار با نرم‌افزارهای محبوبی است که تحلیلگری داده را انجام داده و افراد بیش از آنکه به زیربنای آماری الگوریتم‌ها توجه داشته باشند، به نتیجه فوری آن ها بسنده می‌کنند و نتیجه این فرایند، عدم پذیرش مقالات برخی از فارغ‌التحصیلان عزیز ما که روی پای خود ایستاده‌اند، توسط داوران گرامی و متبحر برخی مجلات معتبر گردیده‌است و این کتاب بخش قابل توجهی از این معضل را با ترویج «علم مفید» جبران می‌نماید و امید است گام کوچکی در جهت تعبیر این دعای پُرمعنای پیامبر گرامی^(ص) باشد که:

«اللهُمَّ إِنِّي أَعُوذُ بِكَ مِنْ عِلْمٍ لَا يَنْفَعُ
«خدایا به تو پناه می‌برم از علمی که سودی نمی‌بخشد!».

مخاطبان کتاب را می‌توان دانشجویان مقاطع کارشناسی و ارشد رشته‌های علوم کامپیوتر، فناوری اطلاعات، مهندسی نرم‌افزار، مهندسی صنایع، مدیریت فناوری، ریاضی کاربردی، آمار، مدیریت و تمامی علاقمندان به مباحث آماری و تحلیلگری داده‌ها دانست، که ضمن تقدیم مطالب به خوانندگان گرامی، درخواست دارد ما را از نظرات سازنده خویش دریغ نفرمایند.