

بِسْمِ اللّٰهِ الرَّحْمٰنِ الرَّحِيْمِ

الْحَمْدُ لِلّٰهِ رَبِّ الْعٰالَمِينَ





دانشگاه صنعتی اصفهان

دانشکده علوم ریاضی

داده‌های گمشده، تخصیص و بوتسترب

۱۳۸۱ / ۴ / ۳۰

پایان نامه کارشناسی ارشد آمار

الهام امیدوار



استاد راهنما

دکتر علی زینل همدانی

دکتر ایوب ساعی

۱۳۸۰

۱۴۱۵۸۷



دانشگاه صنعتی اصفهان

دانشکده علوم ریاضی

پایان نامه کارشناسی ارشد رشته آمار خانم الهام امیدوار

تحت عنوان

داده های گمشده، تخصیص و بوتست رپ

در تاریخ ۶/۴/۸۰ توسط کمیته تخصصی زیر مورد بررسی و تصویب نهائی قرار گرفت.

دکتر علی زینل همدانی - دکترا بیو باغی

دکتر محمد صالحی مژبارانی

دکتر مجتبی گنجعلی

دکتر سروش علیرادی

دکتر امیر نادری

سرپرست تحصیلات تکمیلی دانشکده

۱- استاد داور ۱

۲- استاد مشاور پایان نامه

۳- استاد داور ۲

۴- استاد داور ۳

تقدیر و تشکر

شکر و سپاس تنها از آن اوست، لکن شکر نعمت‌هایش نیز، حمد اوست پس سپاس می‌گوییم آنانکه با نثار جان خویش، آرامش جسم و جان ما را رقم زدند، آنانکه در راه اعتلای حق فداگشتند و آنانکه ایمان سلاحشان بود و عشق مرکب‌شان.

سپاس می‌گوییم آنانی که به گفته مولا‌یمان، «قد علمی حرفاً فقد سیرنی عبداً»، مرا به آنچه آموختند بندۀ خویش ساختند.

تشکر می‌کنم از تمامی استادی‌محترمی که در راه یادگیری هر چه بیشتر اینجانب، از هیچ چیز فروگذار نکردن. چه بسا زحمات آنان که فراتر از حس مسؤولیت بوده و چه بسا که در خلال آموزش علم، پرورش روح ایثار شکل گرفته است.

این حقیقت است که محبت‌ها را باید با محبت جبران نمود، اما زمان لگام گسیخته می‌رود و شرط حضور در مکان فرصت جبران نمی‌دهد و آنچه از من ساخته است جز دعای خیر چیز دیگری نیست.

از استاد بزرگوار جناب آقای دکتر علی همدانی که گاهی اوقات از کثرت زحمات خود، شرمگین می‌شدم، نهایت تشکر را دارم، همچنین از جناب آقای دکتر ساعی که با وجود مشکلاتشان هرگز در برابر مذاہمت‌های من خم به ابرو نیاورده‌ند کمال تشکر را داشته و همواره آرزومند سلامتی‌شان هستم.

از جناب آقای دکتر صالحی که سمت استاد مشاوری این پایان نامه را تقبل نمودند سپاس‌گذارم.

از جناب آقای دکتر امیر نادری، سرپرست تحصیلات تکمیلی که همکاری‌های لازم را به عمل آورده‌ند تشکر می‌کنم.

از آقایان دکتر گنجعلی و دکتر علیمرادی که بعنوان استادی‌متحن در جلسه دفاعیه شرکت نمودند و بازخوانی رساله را پذیرفتند متشکرم.

از دوستان محترم خانم افسوس و خانم صدرعاملی و خانم انوری که در تایپ پایان‌نامه مرا یاری دادند صمیمانه تشکر می‌کنم و در آخر از تمامی کسانی که به نحوی در تمامی دوران تحصیل از کمک و همراهی‌شان بهره برده‌ام قدردانی می‌نمایم.

”امید است که خداوند ارتقاء روح و رسیدن به کمال را جبران محبت‌هایشان قرار دهد.“

کلیه حقوق مترتب بر نتایج مطالعات،
ابتكارات و نوآوریهای ناشی از تحقیق موضوع
این پایان‌نامه متعلق به دانشگاه صنعتی اصفهان
است.

تقدیم به :

ساخت مقدس امام عصر(ع).

که عالمی در انتظار آمدنش چشم براهند.

تقدیم به پژو و نادر از رفاقت ارم

که همواره دلسوزیها و محبت‌هایشان از عمق چان پرخاسته است و من
هرگز نتوانسته‌ام که حتی ذره‌ای از این دریای بیکران را پاسخ‌گویم.

تقدیم به حسن میربان و صدیق

که مشوق ادامه تحصیل و از آن مهمتر، محرك در راه رسیدن
به اهدافم پوده است.

۶

تقدیم به علدران فهیم

که همیشه این حقیر را به دیده پذرگینی نگریسته‌اند.

فہرست

<u>صفحه</u>	<u>عنوان</u>
هشت	فهرست مطالب
۱	چکیده
فصل اول: داده‌های گمشده	
۲	۱-۱- مقدمه
۳	۱-۱-۱- تاریخچه
۴	۱-۲- روش‌های سریع
۶	۱-۲-۱- حذف کامل
۶	۱-۲-۲- حذف دو به دو
۸	۱-۲-۳- جایگزین کردن (تخصیص) میانگین
۹	۱-۴- اطلاعات موجود
۹	۱-۳-۱- عامل به وجود آمدن داده‌های گمشده
۱۰	۱-۴-۱- نمونه‌های یک متغیره با داده‌های گمشده
۱۳	۱-۵- بیش از یک متغیر، اما تنها یک متغیر با داده گمشده
۱۴	۱-۶- داده‌های گمشده در آزمایش‌ها
۱۵	۱-۶-۱- روش یتسن
۱۶	۱-۶-۲- تکرار دریافتن مقادیر گمشده
۱۷	۱-۳-۶- روش بارتلت
۱۹	۱-۷- نظریه استنباط براساس تابع درستنمایی
۱۹	۱-۷-۱- برآورد ماکریزم درستنمایی با داده‌های ناکامل
۲۴	۱-۸-۱- الگوریتم EM
۲۵	۱-۸-۱-۱- الگوریتم EM برای نمونه‌های نرمال چند متغیره ناکامل

۲۷	۹-۱- روشهای گمشده در داده‌های چند متغیره
۲۷	۱-۹-۱- هر واحد تنها یک مقدار گمشده دارد
۲۸	۲-۹-۱- هر واحد بیش از یک مقدار گمشده دارد
۲۹	۱۰-۱- تخصیص چندتایی:
۲۹	۱-۱۰-۱- تشریح روش
۳۰	۱۱-۱- افزایش داده
۳۱	۱-۱۱-۱- فرضیات
۳۱	۲-۱۱-۱- تشریح روش
۳۲	۳-۱۱-۱- استفاده از روش افزایش داده برای تولید تخصیص‌های چندتایی

فصل دوم: روش بوتسرب

۳۴	۱-۲- مقدمه
۲۶	۲-۲- تاریخچه
۳۸	۳-۲- روش بوتسرب
۳۹	۱-۳-۲- تابع توزیع تجربی
۴۰	۲-۳-۳- پلاگ - این
۴۰	۳-۳-۲- برآورد بوتسرب خطای استاندارد
۴۲	۴-۳-۲- تعداد تکرارهای بوتسرب B
۴۴	۵-۳-۲- بوتسرب پارامتری
۴۵	۶-۳-۲- ساختار داده‌های پیچیده‌تر
۴۶	۴-۴-۲- روش جکنایف در برآورد خطای استاندارد
۴۷	۵-۲- فواصل اطمینان براساس جدولهای بوتسرب
۴۷	۱-۵-۲- مقدمه
۴۹	۲-۵-۲- فاصله اطمینان بوتسرب t
۵۲	۳-۵-۲- فواصل اطمینان براساس صدکهای بوتسرب
۵۲	۶-۶-۲- فواصل اطمینان بهتر در بوتسرب
۵۶	۱-۶-۱- فاصله اطمینان BCa
۶۴	۲-۶-۲- فاصله اطمینان ABC

فصل سوم: داده‌های گمشده، تخصیص و بوتسرب

۶۸	۱-۳- مقدمه
۶۸	۲-۳- بوتسرب در مسأله داده‌های گمشده
۶۹	۱-۲-۳- بوتسرب ناپارامتری ساده

۷۱	- بوتسترب با مکانیزم کامل	۲-۲-۳
۷۳	- فواصل اطمینان در مسئله داده‌های گمشده با بکارگیری روش‌های بوتسترب	۳-۳
۷۳	- فاصله اطمینان BCa در مسئله داده‌های گمشده	۱-۳-۳
۷۴	- فاصله اطمینان ABC در مسئله داده‌های گمشده	۲-۳-۳
۸۳	- مثالها	۴-۳
۸۳	- مثال ۱	۱-۴-۳
۱۰۸	- مثال ۲	۲-۴-۳

فصل چهارم: نتیجه‌گیری

۱۳۴	- بحث و بررسی نتایج	۱-۴
۱۳۷	- پیشنهادات	۲-۴

پیوست‌ها

۱۳۹	پیوست ۱ (مدل‌های خطی)	
۱۵۲	پیوست ۲ (برنامه‌های کامپیوتری)	
۱۸۴	پیوست ۳ (خروجی‌های کامپیوتری)	
۲۱۳	مراجع	

چکیده

در بسیاری از مسائل آماری، به دلایل مختلف، تعدادی داده گشده وجود دارد که می‌تواند تجزیه و تحلیل اطلاعات را دچار مشکل سازد.

روشهای گوناگون در برخورد با چنین مسائلی پیشنهاد شده است که بعضی داده‌های گشده را حذف یا مقادیری را جایگزین می‌کنند.

در مسائلی که برآورد پارامتر مدنظر است، روش بوتسترب با وجود داده‌های گشده و محدودیت تعداد نمونه، می‌تواند راه‌گشا باشد. بدین‌منظور در این پایان‌نامه، سه روش اصلی در بوتسترب همراه با تکییک‌های بکار گرفته شده در مسئله داده‌های گشده، مورد توجه قرار گرفته است که عبارتند از:

بوتسترب ناپارامتری، بوتسترب با مکانیزم کامل و بوتسترب با تخصیص چندگانه. در دو روش اول، با استفاده از تعداد تکرار زیاد نمونه‌های بوتسترب، برآورد فاصله‌ای برای پارامتر مورد علاقه θ حاصل می‌شود و در روش سوم با بکارگیری تخصیص چندگانه بعنوان تکنیکی در جایگزین کردن داده‌های گشده، روش محاسباتی و کارا برای محاسبه بازه اطمینان ارائه خواهد شد که با توجه به اختلافات نظری موجود در روش تخصیص چندگانه و بوتسترب، ارتباط جالب توجهی دیده می‌شود.

نهایتاً نتایج حاصل از هر سه روش، مزای و معایب و مزایای تکنیک‌های بکار گرفته شده، مورد بحث و بررسی قرار می‌گیرد.

فصل اول

داده‌های گمشده

۱-۱- مقدمه

بحث داده‌های گمشده، غالباً در بسیاری از مسائل مختلف آماری به چشم می‌خورد که گاهی آماردان برای آنکه خود را با حل اینگونه مسائل درگیر نسازد، سعی می‌کند تا چنین داده‌هایی را کنار بگذارد، در صورتیکه در کتابها و مقالاتی که در این زمینه ارائه گردیده، راه حل‌های جالب توجهی دیده می‌شود. داده‌های گمشده به دلایل بسیاری ممکن است به وجود آید. به عنوان مثال در بررسی‌ها، امکان دارد پاسخ دهنده جواب دادن به پرسشی را رد کند چراکه مثلاً بخواهد آنرا در خلوت و پنهانی پاسخ گوید، یا اینکه شخصی منظور از سؤال را نفهمد یا پاسخ آنرا نداند. گاهی اوقات نیز محدودیت زمانی باعث بی‌پاسخ ماندن بعضی از سؤال‌ها است. در تمام این موارد، سؤال بی‌پاسخ، یک داده گمشده محسوب می‌شود.

در تحقیقات نیز زمینه برای ایجاد داده‌های گمشده، زیاد است. بعنوان نمونه، ممکن است محقق گرفتن اندازه‌ای را فراموش کند. مثلاً: نبض بیمار. که این نیز یک داده گمشده به حساب می‌آید.

در برخی موارد، وجود داده‌های گمشده مسائل جدی‌ای را سبب می‌شود و چون تشخیص جدی بودن این داده‌ها کار آسانی نیست، چنین داده‌هایی قابل اطمینان نخواهند بود. در مواردی که نتایج در تصمیم‌گیریها تأثیر قابل توجهی خواهند داشت، مواجه شدن با داده‌های گمشده حساسیت ییشتی ایجاد می‌کند.

۱-۱-۱ - تاریخچه

تاریخچه داده‌های گمشده^۱ بسیار گسترده است. به طور حتم آمار دانان از زمانی که بر روی داده‌های آماری تجزیه و تحلیل‌هایی انجام داده‌اند با مسئله گمشده‌گی داده‌ها مواجه بوده‌اند، زیرا که عملاً امکان عدم مشاهده بعضی از داده‌ها وجود دارد. آنچه در این بخش عنوان تاریخچه ارائه می‌گردد، خلاصه‌ای از کارهایی است که نویسنده‌گان مختلف بر روی این مبحث انجام داده‌اند.

حدوداً ۷۰ سال پیش ویشارت والان^۲ در سال ۱۹۳۰ [۱] روش برآورد محصول را از یک کرت گمشده^۳، مورد بحث قرار دادند. مقاله‌ای تحت عنوان "تکنیک‌های کرت گمشده" در سال ۱۹۴۶ [۲] توسط اندرسون^۴ ارائه شد. در اوایل سال ۱۹۵۸ برآورد مقادیر گمشده برای تجزیه و تحلیل داده‌های ناکامل^۵ را ویلکینسون^۶ [۳] مورد مطالعه قرار داد و همین نویسنده در اواخر همین سال تجزیه واریانس را برای داده‌های ناکامل به انجام رسانید [۴].

در سال ۱۹۶۶ الاشف و افیفی^۷ مقاله‌ای تحت عنوان «مشاهدات گمشده در آمارهای چند متغیره» [۵] ارائه دادند که این مقاله مروری بر تحلیل‌های انجام شده تا آن زمان می‌باشد.

مقاله پریس^۸ در سال ۱۹۷۱ [۶] روش‌های تکراری را برای مقادیر گمشده در آزمایش‌ها معرفی می‌کند و در همین سال با همکاری هارتلی و هاکینگ^۹ [۷] تجزیه و تحلیل داده‌های ناکامل ارائه می‌گردد. دمپستر، لیرد و روین^{۱۰} در سال ۱۹۷۷ [۸] ماکریم در ستتمایی برای داده‌های ناکامل را ابداع کردند و پس از آن در ۱۹۷۸ روشی تحت عنوان قانون اطلاعات گمشده^{۱۱} توسط دو آماردان بنامهای وودبوری و ارچارد^{۱۲}

۱- Missing Data

۲- Wishart & Allan

۳- Missing Plot

۴- Anderson

۵- Incomplete data

۶- Wilkinson

۷- Elashoff & Afifi

۸- Preece

۹- Hartley & Hocking

۱۰- Laird & Rubin

۱۱- Missing Information

۱۲- Woodbury & Orchard

[۹] معرفی گردید.

در فواصل هر کدام از این سالها نیز مقالات بسیاری در رابطه با داده‌های ناکامل، مقادیر مشاهده نشده^۱، داده‌های گمشده و ... موجود است.

در سال ۱۹۸۲ لیتل^۲ [۱۰] داده‌های ناکامل را در بررسیهای نمونه‌ای در مقاله‌ای منتشر ساخت. شاید آنچه تقریباً تمام روش‌های مختلف در این گونه مسائل را جمع آوری کرده است کتابی است با نام "تجزیه و تحلیل آماری با داده‌های گمشده" از همین نویسنده با همکاری رویین که در سال ۱۹۸۷ [۱۱] انتشار یافت. در این کتاب می‌توان خلاصه‌ای از کارهای انجام شده در رابطه با مسئله داده‌های گمشده را مشاهده نمود.

لازم به ذکر است، از آنجاکه هیچ علمی تاکنون در یک مقطع زمانی مشخص در پیشرفت خود متوقف نشده است پس از سال ۱۹۸۷ نیز تعداد کثیری از مقالات در همین زمینه ارائه گردیده است که از آنجمله می‌توان به مقاله‌های و ترن^۳ (۱۹۹۰) [۱۲] اشاره نمود که دو روش مشابه را در مسئله داده‌های گمشده مطرح می‌سازند.

* * * * *

۱-۲- روش‌های سریع در مسئله داده‌های گمشده

در تحلیلهای چند متغیره هر متغیر ممکن است تنها تعداد کمی پاسخ گمشده داشته باشد ولی در ترکیب متغیرها باهم، تعداد داده‌های گمشده زیاد خواهد بود. ساده‌ترین راهی راکه در حل این مشکل پیشنهاد می‌کنند، حذف مواردی است که در آنها داده گمشده به چشم می‌خورد، [۱۱، ۱۳ و ۱۴]. این عمل، گاهی اوقات سبب می‌شود که تعداد داده‌های باقی مانده برای تجزیه و تحلیل، کفايت نکند و یا آنکه نتایج حاصل معنی‌دار نباشد و یا بعلت آنکه ممکن است مواردی که تجزیه و تحلیل با آنها صورت گرفته، نمونه‌ای تصادفی از کل موارد نتیجه ندهد، نتایج گمراه‌کننده و غلط انداز شود.

برای مثال، یک تحلیل رگرسیونی برای پیش‌بینی مالکیت خانه براساس سن و سابقه فرهنگی انجام شده

۱- Unobserved Value

۲- Little

۳- Wei & Tanner

است. چنانچه جدول (۱-۱) نشان می‌دهد، موارد گمشدہ با علامت "•" نشان داده شده که اگر از مواردی که هر یک از متغیرها پاسخ گمشدہ دارد، چشم پوشی شود، تعداد کل نمونه‌ها در تحلیل، به طور جدی کاهش می‌یابد.

جدول ۱-۱: نمونه ۸ تایی برای پیش‌بینی مالکیت خانه براساس سن و سابقه فرهنگی

نمونه	سن	جنس	خانه	سابقه فرهنگی	وضعیت شغلی
۱	•	زن	خیر	۱۶	غیررسمی
۲	۲۲	مرد	خیر	•	غیررسمی
۳	۳۹	مرد	•	۲۰	رسمی
۴	•	زن	بله	•	رسمی
۵	۴۰	•	بله	۱۶	غیررسمی
۶	۲۲	زن	خیر	۱۶	•
۷	۳۵	مرد	بله	۱۸	رسمی
۸	۳۹	مرد	بله	۲۰	رسمی

در مثالی دیگر، می‌توان گمراه کنندگی نتایج را دید. در جدول (۱-۲) و (۱-۳) دو بررسی نشان داده می‌شود که در اولی داده گمشدہ وجود دارد در حالیکه در جدول بعد داده‌ها کاملاً جمع آوری شده‌اند. میانگین سن در جدول (۱-۲) برابر با ۲۹ و در جدول (۱-۳)، ۳۹ می‌باشد و این تفاوت آشکار نشان می‌دهد که کارکردن با داده‌های گمشدہ غالباً نتایج گمراه کننده‌ای خواهد داشت.

جدول ۱-۲: نمونه ۸ تایی با داده گمشدہ جدول ۱-۳: نمونه ۸ تایی بدون داده گمشدہ

نمونه	سن	جنس
۱	۲۱	زن
۲	۲۲	مرد
۳	۳۹	مرد
۴	۲۰	زن
۵	۴۲	مرد
۶	۱۸	زن
۷	۳۷	مرد
۸	۳۹	مرد

نمونه	سن	جنس
۱	•	زن
۲	•	مرد
۳	۳۹	مرد
۴	•	زن
۵	۴۲	مرد
۶	•	زن
۷	۳۷	مرد
۸	۳۹	مرد

بنابراین این سوال مطرح می‌شود که تجزیه مشاهداتی را که داده گمشده دارند، چگونه باید انجام داد؟

روشهای متفاوتی در این رابطه وجود دارد ولی آنچه تحت عنوان روشهای سریع از آن نام برده‌اند، چهار روش ساده است، [۱۱، ۱۲ و ۱۴]. در هر ۴ روش سعی بر آن است که به طریقی مشکل داده‌های گمشده برطرف گردد.

روشها عبارتند از:

۱) حذف کامل^۱

۲) حذف دو به دو^۲

۳) جایگزین کردن (تخصیص) میانگین^۳

۴) اطلاعات موجود^۴

۱-۲-۱- حذف کامل

این روش همان روشی است که در دو مثال قبل مورد بحث قرار گرفت. اگر k متغیر موجود باشد در هر نمونه از این k متغیر، حتی اگر تنها یکی از متغیرها بی‌پاسخ مانده، آن نمونه به طور کامل از لیست خارج می‌شود. معایب این روش همانطور که قبل ذکر شد، قابل اطمینان نبودن نتایج حاصل و کاهش زیاد نمونه‌های است. این روش با حروف اختصاری LD (Listwise Deletion) نشان داده می‌شود.

۱-۲-۲- حذف دو به دو

روش حذف دو به دو که با حروف اختصاری PD (Pairwise Deletion) نشان داده می‌شود، برای هر دو متغیر، کواریانس را از همه نمونه‌هایی که این دو متغیر با هم مشاهده شده‌اند، برآورد می‌کند. لازم به ذکر است که تجزیه و تحلیل داده‌های چند متغیره معمولاً با در نظر گرفتن یک مدل چند متغیره، انجام می‌گیرد و در ابتدای کار، برآورد بردار میانگین و ماتریس واریانس - کواریانس محاسبه می‌گردد. LD به وضوح دیده می‌شود که روش PD اطلاعات بیشتری را از داده‌ها بکار می‌گیرد و کاراتر از روش LD است. اما یکی از معایب آشکار این روش استفاده از اندازه نمونه‌های متفاوت در برآورد هر کواریانس است.

۱- Listwise Deletion

۲- Pairwise Deletion

۳- Mean Imputation

۴- Available-Case Method