


انتشارات دانشگاه کردستان



چاپ دوم

مقدمه‌ای بر

آمار و احتمال



قادر میرزا قادری

محمد مرادی

افشین فلاح

شامل حل مسائل منتخب با نرم افزار Minitab

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

مقدمه‌ای بر

آمار و احتمال

تألیف:

دکتر قادر میرزاقدری

عضو هیئت علمی دانشگاه کردستان

دکتر محمد مرادی

عضو هیئت علمی دانشگاه رازی

دکتر افشین فلاح

عضو هیئت علمی دانشگاه بین‌المللی امام خمینی

سرشناسه :	میرزاقداری، قادر، ۱۳۵۳-
عنوان و نام پدیدآور :	مقدمه‌ای بر آمار و احتمال / تألیف قادر میرزاقداری، محمد مرادی، افشین فلاح.
مشخصات نشر :	سنندج، دانشگاه کردستان، ۱۳۸۹.
مشخصات ظاهری :	۳۴۳ ص.: مصور، جدول، نمودار.
شابک :	۹۷۸-۹۶۴-۲۷۹۷-۲۷-۱
وضعیت فهرست‌نویسی :	فیبا
یادداشت :	کتابنامه.
موضوع :	آمار ریاضی - راهنمای آموزشی (عالی)
موضوع :	احتمالات - راهنمای آموزشی (عالی)
موضوع :	آمار ریاضی - مسائل، تمرین‌ها و غیره (عالی)
موضوع :	احتمالات - مسائل، تمرین‌ها و غیره (عالی)
شناسه افزوده :	مرادی، محمد، ۱۳۵۵ -
شناسه افزوده :	فلاح، افشین، ۱۳۵۴ -
شناسه افزوده :	دانشگاه کردستان
رده‌بندی کنگره :	۱۳۸۹ م۷ ۹۳//۲ QA۲۷۶
رده‌بندی دیویی :	۵۱۹/۵۰۷۶
شماره کتابشناسی ملی :	۲۱۵۵۲۶۰



انتشارات دانشگاه کردستان

نام کتاب: مقدمه‌ای بر آمار و احتمال

مؤلفین: میرزاقداری، مرادی، فلاح

چاپ دوم

ناشر: دانشگاه کردستان

تیراژ: ۲۰۰۰ نسخه

قطع: وزیری

فهرست مطالب

فصل ۱ آمار توصیفی

۱-۱	مقدمه	۱
۲-۱	جامعه آماری	۱
۳-۱	نمونه	۲
۴-۱	متغیر و داده	۳
۵-۱	مقیاس‌های استیونز	۳
۶-۱	پارامتر	۵
۷-۱	آماره	۵
۸-۱	جدول‌ها و نمودارهای فراوانی	۶
۹-۱	علامت مجموع و حاصلضرب	۱۱
۱۰-۱	شاخص‌های مرکزی	۱۲
۱۱-۱	مقایسه میانگین، میانه و نما	۲۱
۱۲-۱	چولگی (عدم قرینگی)	۲۲
۱۳-۱	برجستگی	۲۵
۱۴-۱	شاخص‌های پراکندگی	۲۵
۳۵	تمرین‌ها	۳۵

فصل ۲ احتمال

۱-۲	مقدمه	۳۹
۲-۲	برخی از اصول شمارش	۳۹
۳-۲	قوانین احتمال	۴۵
۵۳	تمرین‌ها	۵۳

فصل ۳ متغیرهای تصادفی گسسته

۱-۳	مقدمه	۵۷
۲-۳	متغیر تصادفی	۵۷
۳-۳	متغیر تصادفی گسسته یا پیوسته	۵۸
۴-۳	تابع چگالی احتمال	۵۸
۵-۳	میانگین و واریانس متغیر تصادفی گسسته	۵۹
۶-۳	توزیع دوجمله‌ای	۶۰

۶۸.....	توزیع چندجمله‌ای	۷-۳
۶۹.....	متغیر تصادفی پواسون	۸-۳
۷۱.....	تمرین‌ها	

فصل ۴ متغیرهای تصادفی پیوسته

۷۵.....	مقدمه	۱-۴
۷۵.....	تابع چگالی احتمال متغیر تصادفی پیوسته	۲-۴
۷۶.....	امید ریاضی و واریانس متغیر تصادفی پیوسته	۳-۴
۷۶.....	توزیع یکنواخت یا مستطیلی	۴-۴
۷۸.....	توزیع نرمال	۵-۴
۸۰.....	توزیع نرمال استاندارد	۶-۴
۸۴.....	فاصله ۹۵٪ و ۹۹٪ در توزیع نرمال	۸-۴
۸۶.....	بررسی نرمال بودن داده‌ها	۹-۴
۸۸.....	تمرین‌ها	

فصل ۵ توزیع‌های نمونه‌ای

۹۱.....	مقدمه	۱-۵
۹۱.....	برآورد نقطه‌ای	۲-۵
۹۲.....	توزیع نمونه‌ای	۳-۵
۹۲.....	ملاک‌های انتخاب یک برآوردگر	۴-۵
۱۰۱.....	ارتباط بین توزیع‌های گسسته و پیوسته	۵-۵
۱۰۱.....	تقریب توزیع دو جمله‌ای با توزیع نرمال	۱۰-۵
۱۰۳.....	تصحیح پیوستگی	۱۱-۵
۱۰۵.....	تمرین‌ها	

فصل ۶ استنباط آماری: فاصله اطمینان

۱۰۹.....	مقدمه	۱-۶
۱۰۹.....	فاصله اطمینان برای میانگین جامعه با استفاده از نمونه بزرگ	۲-۶
۱۱۳.....	فاصله اطمینان برای میانگین جامعه با استفاده از نمونه کوچک	۳-۶
۱۱۸.....	فاصله اطمینان برای نسبت جامعه با استفاده از نمونه بزرگ	۴-۶
۱۲۱.....	فواصل اطمینان یک‌طرفه	۵-۶
۱۲۲.....	تمرین‌ها	

فصل ۷ استنباط آماری: آزمون فرض

۱۲۳	مقدمه	۱-۷
۱۲۳	آزمون فرض	۲-۷
۱۲۷	خلاصه‌ای در مورد آزمون فرض‌های آماری	۳-۷
۱۲۸	آزمون فرض در مورد میانگین جامعه با استفاده از نمونه بزرگ	۴-۷
۱۳۲	مقدار احتمال	۵-۷
۱۳۶	آزمون فرض در مورد میانگین جامعه با استفاده از نمونه کوچک	۶-۷
۱۳۹	آزمون فرض در مورد نسبت جامعه با استفاده از نمونه بزرگ	۷-۷
۱۴۰	محاسبه خطای نوع دوم	۸-۷
۱۴۰	توان آزمون	۹-۷
۱۴۳	کاهش خطای نوع اول و دوم	۱۰-۷
۱۴۴	آزمون فرض برای واریانس جامعه	۱۱-۷
۱۵۰	تمرین‌ها	

فصل ۸ آزمون کای دو و کاربردهای آن

۱۵۳	مقدمه	۱-۸
۱۵۳	آزمون کای دو برای نیکویی برازش	۲-۸
۱۶۳	آزمون کای دو برای استقلال	۳-۸
۱۶۶	تمرین‌ها	

فصل ۹ استنباط آماری در مورد دو جامعه

۱۶۹	مقدمه	۱-۹
۱۶۹	مقایسه میانگین‌های دو جامعه با استفاده از دو نمونه مستقل از هم	۲-۹
۱۷۹	مقایسه میانگین‌های دو جامعه دارای واریانس‌های متفاوت	۳-۹
۱۸۱	مقایسه میانگین‌های دو نمونه غیر مستقل (مشاهدات جفت شده)	۴-۹
۱۸۵	مقایسه نسبت‌های دو جامعه	۵-۹
۱۹۱	اندازه نمونه	۶-۹
۱۹۳	مقایسه واریانس‌های دو جامعه	۷-۹
۱۹۷	تمرین‌ها	

فصل ۱۰ مقدمه‌ای بر تحلیل واریانس

۲۰۱	مقدمه	۱-۱۰
۲۰۱	اجزای یک آزمایش	۲-۱۰
۲۰۴	طرح کاملاً تصادفی تک‌عاملی	۳-۱۰
۲۱۵	مقایسه مدل با اثرات ثابت و مدل با اثرات تصادفی	۵-۱۰
۲۱۷	بررسی اعتبار مدل	۶-۱۰
۲۲۰	تفسیر عملی نتایج و مقایسه میانگین‌ها	۸-۱۰
۲۲۳	تبدیل داده	۹-۱۰
۲۲۹	طرح بلوک‌های کامل تصادفی	۱۰-۱۰
۲۳۱	تمرین‌ها	

فصل ۱۱ تحلیل رگرسیون خطی

۲۳۳	مقدمه	۱-۱۱
۲۳۴	کواریانس	۲-۱۱
۲۳۶	ضریب همبستگی پیرسون	۳-۱۱
۲۳۹	رگرسیون خطی ساده	۴-۱۱
۲۴۱	برازش خط رگرسیونی	۵-۱۱
۲۴۲	فرض‌های اولیه تحلیل رگرسیونی	۶-۱۱
۲۴۳	برآورد خطای مدل	۷-۱۱
۲۴۵	بررسی کارایی مدل رگرسیونی	۸-۱۱
۲۴۷	ضریب تعیین	۹-۱۱
۲۴۸	بررسی کارایی مدل رگرسیونی با آزمون F	۱۰-۱۱
۲۴۹	پیش‌بینی بر اساس مدل رگرسیونی	۱۱-۱۱
۲۵۳	تبدیل داده‌ها در رگرسیون	۱۲-۱۱
۲۵۶	رگرسیون چندگانه	۱۳-۱۱
۲۶۰	رگرسیون چندجمله‌ای	۱۴-۱۱
۲۶۲	بازبینی مدل آماری	۱۵-۱۱
۲۶۵	تمرین‌ها	

فصل ۱۲ آمار ناپارامتری

۲۶۷	مقدمه	۱-۱۲
۲۶۸	آزمون علامت	۲-۱۲

۲۷۳ آزمون رتبه علامت‌دار ویلکاکسون	۳-۱۲
۲۷۷ آزمون من-ویتنی برای مقایسه دو جامعه مستقل	۴-۱۲
۲۸۰ آزمون کروسکال-والیس	۵-۱۲
۲۸۳ آزمون فریدمن	۶-۱۲
۲۸۵ ضریب همبستگی رتبه‌ای اسپیرمن	۷-۱۲
۲۸۹ تمرین‌ها	

۲۹۳

پاسخ تمرین‌ها

جدول ضمیمه

۳۲۰ جدول ۱. اعداد تصادفی
۳۲۱ جدول ۲. احتمال تجمعی در دنباله راست منحنی نرمال استاندارد
۳۲۲ جدول ۳. مقادیر بحرانی t مربوط به سطوح داده شده
۳۲۳ جدول ۴. مقادیر بحرانی F مربوط به سطوح داده شده
۳۲۴ جدول ۵. مقادیر بحرانی در دنباله راست منحنی F
۳۳۰ جدول ۶. مقادیر بحرانی T در آزمون رتبه ویلکاکسون یا نمونه‌های جفت شده ویلکاکسون
۳۳۱ جدول ۷. مقادیر بحرانی U در آزمون من‌ویتنی

۳۳۴

واژه‌نامه

۳۳۸

منابع

۳۳۹

فهرست راهنما

فصل ۱ آمار توصیفی

۱-۱ مقدمه

علم آمار به عنوان مجموعه‌ای از روش‌های جمع‌آوری، پاک‌سازی، تلخیص، تحلیل و نتیجه‌گیری قابل اعتماد از داده‌ها، تعریف می‌شود. پس از جمع‌آوری و پاک‌سازی داده‌ها می‌توان کارهای آماری بروی آنها را به دو بخش کلی توصیف و استنباط تقسیم کرد. بخش اول شامل تلخیص داده‌های پاک‌سازی شده در قالب جداول فراوانی و نمایش آنها در نمودارها و محاسبه ویژگی‌هایی از داده‌ها مانند مرکزیت، پراکندگی، تقارن و عدم تقارن می‌باشد، که به آن آمار توصیفی می‌گویند. در واقع هدف آمار توصیفی، نمایش و توصیف داده‌ها به صورتی راحت و قابل فهم است. بویژه در صورتی که حجم داده‌ها زیاد باشد بررسی صرفاً چشمی آنها کاری دشوار خواهد بود. آمار فقط به توصیف داده‌ها ختم نمی‌شود، بلکه اغلب اوقات محقق نمونه‌ای از یک جامعه گرفته و با توجه به اطلاعات موجود در نمونه می‌خواهد در مورد جامعه اظهار نظر کند. تعمیم نتایج حاصل از نمونه به جامعه را با استفاده از روش‌های آماری، آمار استنباطی می‌نامند.

۲-۱ جامعه آماری

جامعه آماری مجموعه عناصری است که دست کم یک صفت مشترک دارند. جوامع آماری به دو نوع متناهی و نامتناهی تقسیم می‌شوند. جامعه متناهی به جامعه‌ای گفته می‌شود که تعداد عناصر آن محدود است و جامعه نامتناهی نیز جامعه‌ای است که تعداد عناصر آن بینهایت باشد. در عمل گاهی اوقات که تعداد افراد جامعه بسیار بزرگ باشد، جامعه را نامتناهی در نظر می‌گیرند مثل ماهی‌های یک دریا یا باکتری‌های موجود در یک متر مربع از زمین زراعی.

مجموعه افراد یک شهر یا مجموعه ارقام زراعی گندم در ایران مواردی از جامعه متنهای هستند ولی جامعه تعداد پرتاب‌های لازم یک سکه برای مشاهده اولین شیر (یک پرتاب، دو پرتاب،...) نامتنه‌ای است. اگر تعداد اعضای جامعه اندک باشد می‌توان نسبت به بررسی همه افراد آن اقدام کرد. بررسی آماری همه واحدهای جامعه را سرشماری گویند. به عنوان مثال در جامعه دانشجویان یک کلاس می‌توان نمرات همه دانشجویان را در یک درس خاص ثبت کرده و میانگین آنها را به دست آورد. گاهی در آمار با جوامع آنقدر بزرگی روبرو هستیم که بررسی همه اعضای آن غیرممکن، یا از لحاظ زمان یا هزینه سرشماری مقرون به صرفه نیست. برای مثال یک مزرعه بزرگ گندم را در نظر بگیرید. برای تعیین میانگین تعداد دانه در خوشه در این مزرعه نمی‌توان تعداد دانه را در همه خوشه‌ها شمارش و میانگین کل را به دست آورد. روش منطقی، انتخاب نمونه‌ای تصادفی از خوشه‌های گندم در این مزرعه و محاسبه میانگین تعداد دانه در خوشه‌های منتخب است.

۱-۳ نمونه

هر زیر مجموعه‌ای از واحدهای جامعه را نمونه گویند. نمونه ممکن است به صورت شانس انتخاب شود که اصطلاحاً به آن نمونه احتمالی می‌گویند. در مقابل، نمونه غیراحتمالی وجود دارد که بر اساس سلیقه افراد انتخاب می‌شود. در آمار نمونه احتمالی به دو دلیل بر نمونه غیر احتمالی ترجیح داده می‌شود. اول اینکه قوانین احتمال در مورد آن صادق است و استنباط آماری نیز بر اساس همین قوانین ساخته می‌شود، دوم اینکه نمونه‌های غیراحتمالی به دلیل سلیقه‌ای بودن همواره در معرض این اتهام هستند که بیانگر کل جامعه نمی‌باشند. به عنوان مثال نمونه‌ای از محصول که توسط کشاورز برای فروش به خریدار عرضه می‌شود، ممکن است از طرف خریدار مورد شک گل‌چین بودن واقع شود. شعار نمونه‌گیری این است که مشت باید نمونه خروار باشد و این شعار در مورد نمونه‌های احتمالی صادق است. ساده‌ترین نمونه احتمالی نمونه تصادفی ساده (یا به طور خلاصه نمونه تصادفی) است که در آن هر فرد جامعه شانس مساوی برای انتخاب شدن در نمونه دارد. یک نمونه تصادفی را از راه قرعه‌کشی، جدول اعداد تصادفی یا به کمک نرم‌افزارهای آماری می‌توان به دست آورد. نمونه‌ای می‌تواند مشخصات جامعه را با دقت

برآورد کند که حجم بهینه‌ای داشته باشد و نمونه‌های خیلی کوچک، برآوردهای دقیقی از جامعه به دست نخواهند داد.

۱-۴ متغیر و داده

متغیر، مشخصه یا صفتی است که از عنصری به عنصر دیگر تغییر می‌کند. مانند نژاد، رتبه کنکور، دمای بدن و وزن افراد. متغیرها را می‌توان به چهار نوع اسمی، رتبه‌ای، فاصله‌ای و نسبتی یا با تقسیم بندی کلی تری به کیفی و کمی تقسیم‌بندی نمود. داده یا مشاهده نیز اطلاعاتی است که از اندازه‌گیری یا تعیین مقدار متغیر مربوط به عناصر مورد مطالعه حاصل می‌شود مانند اندازه قد هر فرد، میزان محصول یک درخت یا رنگ گل‌های رز در یک باغچه.

۱-۵ مقیاس‌های استیونز

استیونز در سال ۱۹۵۱ چهار نوع مقیاس معرفی نمود که می‌توان همه متغیرهای ممکن را با این مقیاس‌ها اندازه‌گیری کرد.

۱-۵-۱ مقیاس اسمی

این مقیاس تنها برای شناسایی عناصر به کار می‌رود. مثلاً ممکن است کارگران کارخانه‌ای که متولد شهرهای تهران، تبریز، شیراز و اصفهان هستند با اعداد ۱، ۲، ۳ و ۴ مشخص شوند. این اعداد ارزش مقایسه نداشته و صرفاً بیانگر اسم شهرها هستند. لذا نمی‌توان روی آنها اعمال ریاضی مانند جمع، تفریق و تقسیم انجام است.

۱-۵-۲ مقیاس ترتیبی

اعداد تشکیل دهنده این مقیاس صرفاً برتری را نشان می‌دهند. مثلاً اگر مدیر یک کارخانه کارگران را از نظر مهارت با اعداد ۱، ۲، ۳، و ۴ مشخص کند، کارگر ۴ از کارگر ۲ ماهرتر است ولی نمی‌توان گفت که دو برابر او مهارت دارد. این گونه اعداد را می‌توان تنها برای مقایسه به کار برد و نمی‌توان با آنها چهار عمل اصلی ریاضی را انجام داد.

۱-۵-۳ مقیاس فاصله‌ای

اگر اعداد تشکیل دهنده مقیاسی، نسبت دو تفاضل (یا دو فاصله) را حفظ کند، آن را مقیاس فاصله‌ای گویند. مثلاً اگر دمای چهار جسم در مقیاس سانتیگراد (x) بصورت

$$x_1 = 10, \quad x_2 = 15, \quad x_3 = 20, \quad x_4 = 45, \quad \frac{x_4 - x_3}{x_2 - x_1} = 5$$

باشد، همین دماها در مقیاس فارانهایت (y) طبق رابطه $y = \frac{9x}{5} + 32$ برابر

$$y_1 = 50, \quad y_2 = 59, \quad y_3 = 68, \quad y_4 = 113, \quad \frac{y_4 - y_3}{y_2 - y_1} = 5$$

هستند. اگر درجه حرارت در مقیاس سانتیگراد صفر باشد در مقیاس فارانهایت درجه حرارت ۳۲ است. در مقیاس فاصله‌ای صفر معنی هیچ نداده و صرفاً قراردادی است. در مقیاس سانتیگراد x_3 دو برابر x_1 است ولی در مقیاس فارانهایت چنین نیست. بنابراین در مقیاس فاصله‌ای نسبت اعداد محفوظ نمی‌ماند پس نمی‌توان گفت که جسم ۳ دو برابر گرمتر از جسم ۱ است.

۱-۵-۴ مقیاس نسبی

مقیاس نسبی کامل‌ترین نوع مقیاس است و برای بیشتر متغیرهای قابل شمارش یا اندازه‌گیری مانند تعداد، وزن، طول، سطح و غیره به کار می‌رود. مثلاً اگر وزن دو جسم ۶۰۰۰ و ۲۰۰۰ کیلوگرم باشد، وزن آنها در مقیاس تن به ترتیب ۶ و ۲ می‌باشد. با اعداد حاصل از این نوع مقیاس می‌توان چهار عمل اصلی را انجام داد. صفر در این نوع مقیاس واقعی است.

متغیر کیفی

اگر متغیر با عدد قابل بیان نباشد، به آن متغیر کیفی گویند مانند متغیرهایی که با مقیاس‌های اسمی یا رتبه‌ای بیان می‌شوند. وجود یا عدم وجود کُرک بر روی برگ، رنگ گلبرگ و مقاومت گیاه گندم به بیماری زنگ مثال‌هایی از متغیرهای کیفی هستند.

متغیر کمی

متغیر کمی تغییری است قابل اندازه‌گیری یا شمارش، مانند متغیرهایی که با مقیاس‌های فاصله‌ای یا نسبی بیان می‌شوند. متغیرهای کمی خود به دو نوع پیوسته و گسسته تقسیم می‌شوند. بسیاری از متغیرهای فیزیکی قابل اندازه‌گیری، پیوسته هستند و می‌توانند هر مقدار ممکن در دامنه تغییرات (فاصله بین بیشترین و کمترین مقدار) موجود را به خود اختصاص دهند. متغیرهایی چون وزن دانه، ارتفاع گیاه، درصد روغن بذر، درصد چربی شیر و میزان تولید شیر در دام‌ها، پیوسته هستند. متغیر گسسته تغییری است که مجموعه مقادیر ممکن آن شمارا باشد. مانند تعداد گلبرگ‌های یک گل، تعداد دانه‌ها در یک سنبله و تعداد لاروهای موجود بر روی یک گیاه.

۶-۱ پارامتر

پارامتر کمیتی است که یک ویژگی جامعه را نشان می‌دهد. پارامتر جامعه کمیتی است ثابت ولی ناشناخته و عمدتاً از طریق نمونه‌گیری برآورد می‌شود. البته می‌توان مقدار دقیق آن را از طریق سرشماری به دست آورد. پارامتر با حروف کوچک یونانی بیان می‌شود. مثلاً میانگین جامعه را با μ (مو)، میانه را با η (اتا) و انحراف معیار جامعه را با σ (سیگما) نشان می‌دهند.

۷-۱ آماره

هر آماره تابعی است که بر اساس مشاهدات حاصل از نمونه تصادفی محاسبه می‌شود و ویژگی خاصی از نمونه را نشان می‌دهد. مقدار هر آماره به دلیل وابستگی آن به مشاهدات نمونه، از نمونه‌ای به نمونه دیگر متغیر است و از این رو تصادفی است. آماره‌ها با حروف انگلیسی نشان

داده می‌شوند.

۸-۱ جدول‌ها و نمودارهای فراوانی

داده‌های جمع‌آوری شده در اولین مرحله به صورت توده‌ای از اعداد خام هستند و قابلیت تعبیر و تفسیر جامعه را ندارند. پس ابتدا باید در یک جدول خلاصه شده و یا در نمودار مناسبی ترسیم شوند تا قابلیت توصیف جامعه را پیدا کنند. برای رسم جدول فراوانی مربوط به داده‌های کیفی یا گسسته، مقادیر مختلف متغیر در یک ستون نوشته شده و مواردی مثل فراوانی (فراوانی مطلق)، فراوانی نسبی و فراوانی تجمعی در ستون‌های دیگری قید می‌شود. فراوانی، تعداد دفعات تکرار هر داده بوده و با f_i نشان داده می‌شود که در آن i شماره داده یا شماره دسته است. فراوانی نسبی که با p_i نشان داده می‌شود برابر است با فراوانی هر داده یا دسته تقسیم بر تعداد کل (N). فراوانی تجمعی نیز با FC_i نشان داده می‌شود و برابر است با فراوانی هر دسته به اضافه فراوانی‌های طبقات قبل از آن.


مثال ۱-۱ تعداد خانواده‌های ۱، ۲، ۳، ۴، ۵ و ۶ فرزندی در یک روستا به ترتیب برابر با ۵، ۱۰، ۴۰، ۲۵، ۱۵ و ۵ بوده است. جدول فراوانی تعداد فرزندان می‌تواند به صورت زیر باشد.

جدول ۱-۱. جدول تعداد فرزندان در خانواده‌های یک روستا.

جمعیت خانواده	فراوانی (f_i)	فراوانی نسبی (p_i)	فراوانی تجمعی (FC_i)
۱	۵	۰/۰۵	۵
۲	۱۰	۰/۱۰	۱۵
۳	۴۰	۰/۴۰	۵۵
۴	۲۵	۰/۲۵	۸۰
۵	۱۵	۰/۱۵	۹۵
۶	۵	۰/۰۵	۱۰۰
جمع	$N=100$	۱	


علاوه بر جدول فراوانی، برای توصیف بهتر داده‌ها می‌توان از نمودارهای فراوانی نیز استفاده کرد. در این نمودارها معمولاً مقادیر مشاهده شده متغیر بر روی محور افقی و فراوانی، فراوانی

نسبی یا فراوانی نسبی تجمعی مشاهدات نیز بر روی محور عمودی، مشخص می‌شود (نمودار ۱-۱، نمودار ۲-۱ و نمودار ۳-۱).




نمودار ۱-۱. نمودار فراوانی ستونی مربوط به داده‌های جدول ۱-۱.

هرگاه فراوانی هر مقدار متغیر با یک نقطه مشخص و سپس نقاط به هم وصل شوند، نمودار چند ضلعی حاصل می‌شود.




نمودار ۲-۱. نمودار فراوانی چندضلعی مربوط به داده‌های جدول ۱-۱.



نمودار ۳-۱. نمودار فراوانی چندضلعی تجمعی مربوط به داده‌های جدول ۱-۱.

نمودار دایره‌ای (یا کلوچه‌ای) را نیز می‌توان برای داده‌های مثال ۱-۱ رسم نمود. در این نمودار دایره متناسب با فراوانی مقادیر متمایز متغیر تقسیم‌بندی می‌شود. زاویه هر قاچ برابر حاصلضرب فراوانی نسبی در عدد ۳۶۰ است.



نمودار ۱-۴. نمودار دایره‌ای مربوط به داده‌های جدول ۱-۱ که در آن اعداد هر قسمت، تعداد فرزندان و مساحت هر قسمت برابر با فراوانی می‌باشد.

به وسیله نمودارهای فراوانی می‌توان بسیاری از ویژگی‌های مشاهدات را براحتی بیان نمود. مثلاً دامنه تغییرات برابر با ۱۸ ($x_{max} - x_{min} = 20 - 2$) و بیشترین فراوانی مربوط به خانواده‌های سه فرزندی است. با استفاده از نمودار چند ضلعی نسبی تجمعی به آسانی می‌توان عنصری را که ۲۰٪ عناصر مقداری کمتر از آن دارند، پیدا کرد.

در حالتی که متغیر پیوسته یا گسسته دارای تعداد مقادیر متمایز زیادی باشد، معمولاً داده‌ها به چند دسته با فاصله مساوی تقسیم شده و فراوانی برای دسته‌ها مشخص می‌شود. در ستون اول جدول، حدود دسته‌ها نوشته می‌شود. یک ستون جداگانه نیز به نام نشان دسته اضافه می‌شود، که مقدار آن برابر نقطه وسط هر دسته است. برای مثال فرض کنید ارتفاع ۲۰ بوته از یک گونه گیاهی به صورت زیر بوده است.

جدول ۱-۲. ارتفاع ۲۰ بوته از یک گونه گیاهی بر حسب سانتی‌متر.

۱۹/۵	۲۳/۲	۲۰/۵	۲۳/۵	۱۳/۳	۲۲/۵	۱۸/۲	۱۸/۴	۱۹/۶	۲۳/۵
۱۶/۷	۱۵/۵	۲۲/۲	۲۴/۳	۱۷/۵	۲۰/۴	۲۱/۸	۲۲/۹	۲۲/۵	۲۷/۲

برای بررسی راحت‌تر بهتر است این داده‌ها، که مثالی از مقادیر یک متغیر پیوسته هستند، به چند دسته با فاصله مساوی تقسیم شده و فراوانی یا فراوانی نسبی داده‌ها در هر دسته مشخص شود. معمولاً بسته به تعداد کل داده‌ها، تعداد دسته‌ها را از ۶ تا ۲۵ در نظر می‌گیرند. برای مثال داده‌های


جدول ۱-۲ در نمودار ۱-۳ به ۷ دسته مجزا تقسیم شده و فراوانی و فراوانی نسبی افراد در هر دسته به دست آمده است. در این جدول دامنه هر دسته برابر با ۲ در نظر گرفته شده است. با توجه به اینکه بزرگترین و کوچکترین داده به ترتیب برابر با $13/3$ و $27/2$ می‌باشند، دامنه کلی تغییرات برابر با $13/9$ است. اگر هدف دسته بندی داده‌ها به ۷ دسته برابر باشد دامنه تغییرات به ۷ تقسیم می‌شود که برابر با $1/98$ خواهد بود. چون انجام محاسبات با این رقم مشکل است، معمولاً آن را گرد کرده و برابر با ۲ در نظر می‌گیرند. با وجود ۷ دسته با فواصل مساوی ۲، دامنه کلی تغییرات از $13/9$ به ۱۴ افزایش می‌یابد. لذا دسته اول از $13/25$ شروع و دسته آخر تا $27/25$ ادامه می‌یابد.

جدول ۱-۳. تقسیم‌بندی داده‌های جدول ۱-۲ در هفت دسته مجزا.

حدود دسته	فراوانی (f_i)	فراوانی نسبی (p_i)	نشان دسته
۱۳/۲۵-۱۵/۲۵	۱	۰/۰۵	۱۴/۲۵
۱۵/۲۵-۱۷/۲۵	۲	۰/۱۰	۱۶/۲۵
۱۷/۲۵-۱۹/۲۵	۳	۰/۱۵	۱۸/۲۵
۱۹/۲۵-۲۱/۲۵	۴	۰/۲۰	۲۰/۲۵
۲۱/۲۵-۲۳/۲۵	۶	۰/۳۰	۲۲/۲۵
۲۳/۲۵-۲۵/۲۵	۳	۰/۱۵	۲۴/۲۵
۲۵/۲۵-۲۷/۲۵	۱	۰/۰۵	۲۶/۲۵
	۲۰	۱	

بافت‌نگار

در بافت‌نگار یا نمودار مستطیلی برای هر دسته یک مستطیل رسم می‌شود که مساحت آن فراوانی نسبی دسته و عرض آن برابر با حدود دسته است بعلاوه مساحت تمام مستطیل‌ها برابر یک واحد است. بافت‌نگار برای داده‌های جدول ۱-۳ در زیر نشان داده شده است.



نمودار ۱-۵. بافت‌نگار مربوط به داده‌های جدول ۱-۳.

نمودار شاخه و برگ

نمودار شاخه و برگ، داده‌ها را به صورتی فشرده طوری نمایش می‌دهد که تمام داده‌ها را می‌توان در آن دید. در این نمودار ارقام هر داده به دو بخش تقسیم می‌شود. یک یا چند رقم اولیه در ستونی در سمت چپ (ستون شاخه) از کوچک به بزرگ و ارقام باقی‌مانده در ستونی دیگر در سمت راست (ستون برگ) نمایش داده می‌شود. نمودار ۱-۶ نمودار شاخه و برگ را برای داده‌های جدول ۱-۲، نشان می‌دهد. در این مورد، هر داده یه دو بخش عدد صحیح و عدد اعشاری تقسیم شده، اعداد صحیح در ستون مربوط به شاخه (ستون دوم)، به ترتیب صعودی مرتب شده و در ستون مربوط به برگ (ستون سوم) قسمت اعشاری آنها نمایش داده شده است. اعدادی در شاخه که هیچ رقم اعشاری (حتی صفر) برای آنها در برگ ثبت نشده است، در واقع در مجموعه داده‌ها وجود ندارند. همانگونه که در نمودار زیر دیده می‌شود، برخی نرم‌افزارهای آماری در ستون اول نیز از بالا و پایین به طرف مرکز، فراوانی تجمعی را نشان می‌دهند. به عنوان مثال به پنجمین داده از بالا (۱۸/۲) در نمودار ۱-۶ دقت کنید.

Stem-and-leaf of C1 N = 20
Leaf Unit = 0.10

1	13	3
1	14	
2	15	5
3	16	7
4	17	5
6	18	24
8	19	56
10	20	45
10	21	8
9	22	2559
5	23	255
2	24	3
1	25	
1	26	
1	27	2

نمودار ۱-۶. نمودار شاخه و برگ مربوط به

داده‌های جدول ۱-۲

نمودار نقطه‌ای

نمودار نقطه‌ای مربوط به داده‌های جدول ۱-۲ در زیر نشان داده شده است. در این نمودار، هر داده به صورت نقطه‌ای در بالای خط افقی نشان داده می‌شود. اگر داده‌ای دو بار تکرار شده باشد، نقاط مربوطه روی یکدیگر قرار می‌گیرند.



نمودار ۷-۱. نمودار نقطه‌ای مربوط به داده‌های جدول ۲-۱

۹-۱ علامت مجموع و حاصلضرب

فرض کنید مجموعه داده‌های $x_1, x_2, x_3, \dots, x_i, \dots, x_n$ موجودند. در این مجموعه، x_1 اولین داده، x_2 دومین داده، x_3 سومین داده، x_i i امین داده و بالاخره x_n n امین داده یا آخرین داده می‌باشد. در بیشتر محاسبات آماری لازم است که یک مجموعه از داده‌ها با هم جمع شوند. مجموع داده‌های مذکور $(x_1 + x_2 + x_3 + \dots + x_i + \dots + x_n)$ به صورت

$$x_1 + x_2 + x_3 + \dots + x_i + \dots + x_n = \sum_{i=1}^n x_i$$

نمایش داده می‌شود، که در آن علامت \sum (سیگما) برای کوتاه‌تر کردن عبارت بالا به کار رفته و بیانگر مجموع x ها از اولین تا آخرین داده می‌باشد. به همین ترتیب حاصلضرب داده‌ها یعنی $x_1 \cdot x_2 \cdot \dots \cdot x_N$ با استفاده از علامت \prod (پی) خلاصه شده و بصورت زیر نشان داده می‌شود.

$$x_1 \cdot x_2 \cdot \dots \cdot x_N = \prod_{i=1}^n x_i$$

در ادامه مثال‌های بیشتری با استفاده از مجموعه داده $x_1 = 3, x_2 = 9, x_3 = 11$ در مورد کاربرد علامت جمع آورده شده است.

$$\sum_{i=1}^3 x_i^2 = x_1^2 + x_2^2 + x_3^2 = 3^2 + 9^2 + 11^2 = 9 + 81 + 121 = 211$$

$$\sum_{i=1}^3 (3x_i + 1) = (3 \times 3 + 1) + (3 \times 9 + 1) + (3 \times 11 + 1) = 3 \times (3 + 9 + 11) + (3 \times 1) = 72$$

در موارد زیر a, b و c اعداد ثابت هستند.

$$\sum_{i=1}^n i = 1 + 2 + \dots + n$$

$$\sum_{i=1}^n c = nc$$

$$\sum_{i=1}^n ax_i = a \sum_{i=1}^n x_i$$

$$\sum_{i=1}^n (ax_i + b) = a \sum_{i=1}^n x_i + nb$$

$$\sum_{i=1}^n (x_i + y_i)^2 = \sum_{i=1}^n (x_i^2 + y_i^2 + 2x_i y_i) = \sum_{i=1}^n x_i^2 + \sum_{i=1}^n y_i^2 + 2 \sum_{i=1}^n x_i y_i$$

$$\sum_{i=1}^n (x_i + a)^2 = \sum_{i=1}^n (x_i^2 + a^2 + 2ax_i) = \sum_{i=1}^n x_i^2 + na^2 + 2a \sum_{i=1}^n x_i$$

۱۰-۱ شاخص‌های مرکزی

در توصیف مجموعه‌ای از داده‌ها دانستن محل تمرکز آنها اهمیت زیادی دارد. البته ممکن است محل تمرکز داده‌ها یک نقطه نباشد. توابع آماری مثل میانگین‌ها، میانه و نما (مد) از شاخص‌های مرکزی مشهور هستند.

۱-۱۰-۱ میانه

برای یک سری n عددی x_1, x_2, \dots, x_n که به ترتیب صعودی نوشته شده‌اند، اگر n فرد باشد میانه عبارت است از داده وسطی و اگر n زوج باشد میانه برابر است با میانگین دو داده وسطی.

مثال ۱-۲ میانه اعداد ۶، ۷، ۹، ۱۲، ۱۶ و ۲۰ را پیدا کنید.

$$m = \frac{9 + 12}{2} = 10.5$$

مثال ۱-۳ میانه اعداد ۶، ۷، ۹، ۱۲، ۱۶، ۲۰، ۲۲ را پیدا کنید. $m = 12$

محاسبه میانه در جدول فراوانی

برای محاسبه میانه لازم است که دسته‌ها از کوچک به بزرگ در جدول فراوانی مرتب شوند. در

این حالت، میانه معمولاً مقدار $n/2$ آمین داده است که به صورت زیر محاسبه می شود.

نحوه محاسبه میانه در جداول فراوانی

$$m = L_m + \frac{\left(\frac{n}{2} - g\right)}{f_m} w$$


L_m ، مرز پایین واقعی دسته میانه
 g ، فراوانی تجمعی دسته ماقبل دسته میانه
 f_m ، فراوانی دسته‌ای که میانه در آن قرار دارد و
 w ، فاصله دسته‌ها

مثال ۱-۴. میانه را در جدول فراوانی زیر حساب کنید.

حدود دسته	فراوانی	فراوانی تجمعی صعودی
۱۰-۱۲	۳	۳
۱۲-۱۴	۵	۸
۱۴-۱۶	۷	۱۵
۱۶-۱۸	۴	۱۹
۱۸-۲۰	۲	۲۱
۲۱		

نقطه $\frac{n}{2} = 10.5$ به عنوان عضو مرکزی داده‌ها در نظر گرفته می شود. این عضو در دسته سوم قرار گرفته است. از آنجا که حد پایین دسته سوم ۱۴ است، میانه به صورت زیر به دست می آید.

$$m = 14 + \left(\frac{10.5 - 8}{7}\right)2 = 14.71$$



نمودار ۱-۸ نمودار مستطیلی برای داده‌های مثال ۱-۴.

در مواردی که داده‌ها گسسته بوده و به صورت گسسته دسته‌بندی شده‌اند، برای محاسبه صحیح میانه لازم است که دسته‌ها به صورت پیوسته فرض شده و نقطه میانی دو دسته به عنوان مرز واقعی دسته‌ها در نظر گرفته شود.

مثال ۱-۵. میانه را برای مشاهدات زیر به دست آورید.


حدود دسته	فراوانی	فراوانی تجمعی صعودی
۹-۱۳	۲	۲
۱۴-۱۸	۹	۱۱
۱۹-۲۳	۱۰	۲۱
۲۴-۲۸	۹	۳۰
	۳۰	

با توجه به اینکه در اینجا دسته‌ها به صورت گسسته هستند باید ابتدا آنها را پیوسته فرض کرد. برای این منظور در هر دسته، نیم واحد از طرف چپ کم کرده و نیم واحد به طرف راست اضافه می‌کنیم. بدین ترتیب فاصله دسته‌ها از ۴ به ۵ افزایش می‌یابد.

$$m = 18/5 + \left(\frac{15-11}{10}\right)5 = 20/5$$

۱-۱۰-۲ چارک‌ها، دهک‌ها و صدک‌ها

چارک اول بر روی منحنی توزیع داده‌ای است که ۲۵٪ داده‌ها از آن کوچکتر و ۷۵٪ داده‌ها از آن بزرگتر هستند. به همین ترتیب چارک سوم داده‌ای است که ۷۵٪ از افراد جامعه مورد نظر از آن کوچکتر و ۲۵٪ افراد از آن بزرگتر هستند. چارک دوم نیز همان میانه می‌باشد. دهک‌ها و صدک‌ها نیز مفهومی چون چارک داشته و کل جامعه را به ترتیب به ۱۰ و ۱۰۰ قسمت مساوی تقسیم می‌کنند. به عنوان مثال دهک سوم (یا صدک سی‌ام) جامعه، داده‌ای است که ۳۰٪ داده‌ها از آن کوچکتر و ۷۰٪ داده‌ها یا افراد از آن بزرگتر هستند. روش محاسبه چارک‌ها، دهک‌ها و صدک‌ها نیز مانند میانه می‌باشد.



نمودار ۹-۱. نمودار یک توزیع متقارن که در آن مناطق چارکی نشان داده شده است.

مثال ۱-۶. در مورد داده‌های مثال ۱-۵، برای محاسبه چارک اول ابتدا فراوانی در $\frac{1 \times n}{4}$ ضرب تا دسته چارک اول با توجه به فراوانی‌ها مشخص شود ($\frac{1 \times 30}{4} = 7.5$). در این مورد، 7.5 امین عدد در دسته دوم قرار دارد. از آنجا که حد پایین واقعی این دسته، $14/5$ است، چارک اول بصورت $Q_1 = 14/5 + \left(\frac{7.5 - 2}{9}\right)5 = 17/55$ محاسبه می‌شود. به همین ترتیب سایر چارک‌ها، دهک‌ها یا صدک‌ها را می‌توان بصورت زیر محاسبه کرد.


$$\text{محاسبه چارک سوم: } \frac{3 \times n}{4} = \frac{3 \times 30}{4} = 22.5 \Rightarrow Q_3 = 24/5 + \left(\frac{22.5 - 21}{9}\right)5 = 25/33$$

$$\text{محاسبه چارک دوم: } \frac{2 \times n}{4} = \frac{2 \times 30}{4} = 15 \Rightarrow Q_2 = 19/5 + \left(\frac{15 - 11}{10}\right)5 = 21/5$$

$$\text{محاسبه دهک ششم: } \frac{6 \times n}{10} = \frac{6 \times 30}{10} = 18 \Rightarrow D_6 = 19/5 + \left(\frac{18 - 11}{10}\right)5 = 23$$

$$\text{محاسبه صدک سی‌ام: } \frac{30 \times n}{100} = \frac{30 \times 30}{100} = 9 \Rightarrow P_{30} = 13/5 + \left(\frac{9 - 2}{9}\right)5 = 16/89$$

یکی از روش‌های نشان دادن وضعیت پراکندگی داده‌ها استفاده از نمودار جعبه‌ای است. این نمودار چارک‌ها و کوچکترین و بزرگترین داده را نشان می‌دهد. نمودار جعبه‌ای در زیر برای مجموعه‌ای از داده‌ها نشان داده شده است و بیان می‌کند که چارک اول، میانه و چارک سوم در این مجموعه داده به ترتیب $12/5$ ، 17 و $18/5$ می‌باشد. همچنین نمودار نشان می‌دهد که کوچکترین داده 10 و بزرگترین داده 24 است.




نمودار ۱-۱۰. نمودار جعبه‌ای،
کمترین داده، چارک اول، میانه،
چارک سوم و بیشترین داده را به
ترتیب از پایین به بالا نشان می‌دهد.

۳-۱۰-۱ نما

نما یا مد داده‌ای است که بیشترین فراوانی را دارد. برای مثال در داده‌های ۹، ۹، ۶، ۷، ۶، ۶، ۵، ۴، ۴، ۳، ۲ نما برابر با ۶ است. حال به محاسبه نما در جدول فراوانی زیر پرداخته می‌شود.

دسته	۱۰-۱۲	۱۲-۱۴	۱۴-۱۶	۱۶-۱۸	۱۸-۲۰
فراوانی (f_i)	۳	۵	۷	۴	۲

اگر بافت‌نگار توزیع فراوانی در این جدول رسم شود، با رسم دو خط از گوشه‌های بلندترین مستطیل به گوشه مستطیل‌های مجاور، می‌توان موقعیت مد را بر روی بافت‌نگار به صورت زیر مشخص کرد.



نمودار ۱-۱۱. بافت‌نگار توزیع
فراوانی داده‌های اخیر که در آن
موقعیت نما (مد) نشان داده شده
است.

روش بالا یک روش ترسیمی است که موقعیت نما را بر روی بافت‌نگار نشان می‌دهد. برای محاسبه مقدار عددی نما به صورت زیر عمل می‌شود.

نحوه محاسبه نما در جدول فراوانی

$$M = A + \left(\frac{d_1}{d_1 + d_2}\right)w$$

A ، حد پایین دسته نما

d_1 ، فراوانی دسته نما منهای فراوانی دسته قبل از آن

d_2 ، فراوانی دسته نما منهای فراوانی دسته بعد از آن و

w ، فاصله دستهها

نما برای داده‌های جدول فراوانی صفحه قبل برابر است با:

$$M = 14 + \left[\frac{7-5}{(7-5) + (7-4)} \times 2\right] = 14 + \left[\frac{2}{2+3} \times 2\right] = 14/8$$

۴-۱۰-۱ میانگین حسابی

میانگین حسابی که از این پس آن را میانگین می‌نامیم، عبارت است از حاصل جمع داده‌ها تقسیم بر تعداد آنها. میانگین جامعه‌ای از داده‌ها را با حرف یونانی μ (مو)، هر داده را با x_i و تعداد کل داده‌ها یا مشاهدات را با N نشان می‌دهند. میانگین نمونه نیز با \bar{x} نشان داده می‌شود.

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i$$

اگر داده‌ها در جدول فراوانی تنظیم شده باشند، میانگین از طریق رابطه $\mu_x = \sum x_i f_i / \sum f_i$ یا $\mu_x = \sum x_i p_i$ محاسبه می‌شود. مثالی از محاسبه میانگین در جدول زیر آورده شده است.

جدول ۴-۱. داده‌های فرضی و فراوانی آنها.

مشاهدات (x_i)	فراوانی (f_i)	نسبت یا فراوانی نسبی (p_i)
۱	۱	۰/۰۵
۳	۶	۰/۳
۴	۷	۰/۳۵
۲	۴	۰/۲
۶	۲	۰/۱

$$\mu_x = \frac{\sum x_i f_i}{\sum f_i} = \frac{(1 \times 1) + (3 \times 6) + (4 \times 7) + (2 \times 4) + (6 \times 2)}{1 + 6 + 7 + 4 + 2} = 3/35$$

$$\mu_x = \sum x_i p_i = (1 \times 0.05) + (3 \times 0.3) + (4 \times 0.35) + (2 \times 0.2) + (6 \times 0.1) = 3/35$$

در مواردی که داده‌ها در جدول فراوانی دسته بندی شده باشند، از همان روابط $\mu_x = \sum x_i p(x_i)$ یا $\mu_x = \sum x_i f_i / \sum f_i$ برای محاسبه میانگین استفاده می‌شود که در آن x_i نشان دسته است (جدول ۱-۶، صفحه ۲۷).

۱-۱۰-۴ ویژگی‌های میانگین حسابی

- مجموع انحرافات مجموعه‌ای از مشاهدات از میانگین حسابی همیشه برابر با صفر است.

$$\sum_{i=1}^N (x_i - \mu) = \sum x_i - N\mu = N\mu - N\mu = 0$$

- اگر کلیه داده‌ها در عددی مانند a ضرب و با عددی مانند b جمع شوند، میانگین نیز با همین ضابطه تغییر می‌کند یعنی رابطه $\mu_{ax+b} = a\mu_x + b$ برقرار است.
- مقدار تک تک داده‌ها روی میانگین مؤثر است، طوری که یک داده پرت (خیلی بزرگ یا خیلی کوچک) می‌تواند مقدار میانگین را خیلی جا به جا کند. این ویژگی یک نقیصه برای میانگین محسوب می‌شود به طوری که میانگین در برابر داده‌های پرت، استوار نیست.
- مجموع توان دوم انحراف مقادیر از میانگین، کوچکتر از مجموع توان دوم انحراف مقادیر از هر عدد دیگری است. یعنی

$$\sum_{i=1}^N (x_i - \mu)^2 = \min \sum_{i=1}^N (x_i - a)^2$$

۱-۱۰-۵ میانگین حسابی وزنی

در برخی از داده‌ها برای محاسبه میانگین حسابی، به دلیل اینکه مقادیر مشاهده شده ارزش‌های متفاوت دارند لازم است به هر مشاهده وزنی را اختصاص داده و سپس میانگین داده‌های وزن داده شده را محاسبه نمود. میانگین وزنی از فرمول زیر محاسبه می‌شود.

$$\bar{x}_w = \frac{\sum w_i x_i}{\sum w_i} = \frac{w_1 x_1 + w_2 x_2 + \dots + w_n x_n}{w_1 + w_2 + \dots + w_n}$$

مثال ۱-۷. کارنامه دو داوطلب شرکت کننده در یک آزمون استخدامی به صورت زیر است. میانگین کدامیک بیشتر است؟

	زبان (ضریب ۳)	اطلاعات عمومی (ضریب ۱)	پرسش های تخصصی (ضریب ۳)
داوطلب اول	۱۹	۱۴	۱۷
داوطلب دوم	۱۷	۲۰	۱۶

$$\text{میانگین اولی } \bar{x}_w = \frac{\sum w_i x_i}{\sum w_i} = \frac{3(19) + 1(14) + 3(17)}{7} = 17/43$$

$$\text{میانگین دومی } \bar{x}_w = \frac{3(17) + 1(20) + 3(16)}{7} = 17$$

۱-۱۰-۱ میانگین پیراسته

برای محاسبه میانگین پیراسته تمام داده های بزرگتر از چارک سوم و کوچکتر از چارک اول را کنار گذاشته و سپس میانگین حسابی بقیه محاسبه می شود.

۱-۱۰-۱ میانگین هندسی

میانگین هندسی (g) برای N عدد غیر منفی $(x_1 \cdot x_2 \cdot \dots \cdot x_N)$ برابر با

$$g = \sqrt[n]{\prod_{i=1}^n x_i} = \sqrt[n]{x_1 \cdot x_2 \cdot \dots \cdot x_N} = (x_1 \cdot x_2 \cdot \dots \cdot x_N)^{\frac{1}{N}}$$

است. در صورتی که N بزرگ باشد، گرفتن ریشه N ام از آنها سخت است، در این موارد می توان لگاریتم داده ها را در مبنای ۱۰ بدست آورده و میانگین حسابی آن ها را محاسبه کرد. در این صورت، میانگین هندسی برابر با عدد ۱۰ به توان میانگین حسابی محاسبه شده خواهد بود.

مثال ۱-۸. میانگین هندسی اعداد ۳، ۴ و ۵ را به دست آورید.

$$\log g = \frac{1}{3}(\log 3 + \log 4 + \log 5) = \frac{1}{3}(0.477 + 0.602 + 0.699) = 0.592$$

$$g = \text{antilog } 0.592 = 10^{0.592} = 3.91$$

میانگین هندسی برای داده‌هایی که به صورت نسبت یا درصد هستند مورد استفاده قرار می‌گیرد.

مثال ۱-۹. قیمت کالای A در تیرماه دو برابر و در مردادماه ۳ برابر کالای B بوده است. میانگین نسبت کالای A به B را در این دو ماه حساب کنید.

$$g = \sqrt{2 \times 3} = 2.45$$

مثال ۱-۱۰. میانگین نسبت کالای B به A در این دو ماه در مثال بالا چقدر بوده است؟

$$g = \sqrt{\frac{1}{2} \times \frac{1}{3}} = \frac{1}{\sqrt{6}}$$

مثال ۱-۱۱. میزان خسارت ناشی از یک آفت در ۴ بوته مختلف ۲۵، ۳۰، ۲۴ و ۴۰ درصد بوده است. متوسط خسارت بر حسب درصد چقدر است؟

$$g = \sqrt[4]{25 \times 30 \times 24 \times 40} = 29.13$$

میانگین هندسی در جدول فراوانی با k دسته بصورت زیر محاسبه می‌شود که در آن N تعداد داده‌ها و x_i و f_i به ترتیب نشان و فراوانی دسته i ام می‌باشند.

$$g = \sqrt[N]{\prod x_i^{f_i}} = \sqrt[N]{x_1^{f_1} x_2^{f_2} \dots x_k^{f_k}}$$

۱-۱۰-۸ میانگین همساز

میانگین همساز (h) اغلب برای اندازه‌گیری متوسط سرعت‌ها وقتی که فواصل مربوط به آنها مساوی باشد به کار می‌رود و بصورت زیر محاسبه می‌شود.

$$h = \frac{N}{\sum \frac{1}{x_i}} = \frac{N}{\frac{1}{x_1} + \frac{1}{x_2} + \dots + \frac{1}{x_N}}$$

مثال ۱-۱۲. یک موتورسوار یک سوم فاصله‌ای را با سرعت ۳۰ کیلومتر در ساعت، یک سوم دیگر فاصله را با سرعت ۴۰ کیلومتر در ساعت و یک سوم آخر را با سرعت ۶۰ کیلومتر در ساعت پیموده است. متوسط سرعت او در این مسیر چقدر بوده است؟

$$h = \frac{3}{\frac{1}{30} + \frac{1}{40} + \frac{1}{60}} = 40$$

مثال ۱-۱۳. شخصی طی چهار سال متوالی کالایی را به قیمت کیلویی ۱۶، ۱۸، ۲۱ و ۳۵ ریال خریداری نموده است. متوسط قیمت پرداختی برای این کالا را در دو حالت زیر محاسبه کنید: الف) مقدار خرید در هر سال ۱۰ کیلوگرم بوده است. ب) میزان پول پرداختی در هر سال ۲۰۰۰ ریال بوده است.

الف) توجه داشته باشید که در حالت اول میانگین به میزان خرید بستگی ندارد، بنابراین از میانگین حسابی برای محاسبه مقدار متوسط استفاده می‌شود.

$$\mu = \frac{\text{قیمت کل}}{\text{مقدار کل}} = \frac{160 + 180 + 210 + 350}{40} = 22/5$$

ب) در صورت پرداخت یک مقدار ثابت پول در سال، هر چه کالا گران‌تر شود مقدار خرید کمتر خواهد شد. بنابراین از میانگین همساز برای محاسبه مقدار متوسط استفاده می‌شود.

$$h = \frac{4}{\frac{1}{16} + \frac{1}{18} + \frac{1}{21} + \frac{1}{35}} = 20/59$$

در کل برای یک گروه از اعداد مثبت رابطه $h \leq g \leq \mu$ برقرار است. البته در صورتی که اعداد با هم برابر باشند، هر سه نوع میانگین، برابر خواهند بود.

۱-۱۱ مقایسه میانگین، میانه و نما

میانگین حسابی در واقع نقطه ثقل داده‌ها است و متداول‌ترین شاخص مرکزی می‌باشد. میانگین حسابی دارای خواص احتمالی خوبی است بدین معنی که می‌توان میانگین جامعه را با اطمینان


بالایی به کمک میانگین نمونه برآورد کرد. اگر از جامعه‌ای که دنباله‌های توزیع آن خیلی به سمت چپ یا راست کشیده نیست، نمونه‌های مختلف انتخاب شوند، میانگین حسابی نمونه‌ها به میانگین جامعه نزدیکتر خواهند بود تا میانه آنها. میانه به اندازه میانگین تحت تأثیر داده‌های پرت قرار نمی‌گیرد و این موضوع به ویژه در مورد توزیع‌هایی که دنباله‌های کشیده دارند، اهمیت زیادی دارد. میانگین برای متغیرهای ترتیبی و اسمی کارایی ندارد. برای توصیف متغیرهای ترتیبی، میانه و نما و برای توصیف متغیرهای اسمی، تنها نما کاربرد دارد. برای توصیف مرکزیت داده‌های کمی، میانگین و میانه از اهمیت بیشتری برخوردارند. یک مجموعه داده ممکن است نما نداشته باشد یا بیش از یک نما داشته باشد. در توزیع‌های متقارن میانگین، میانه و نما با هم برابرند، ولی در توزیع‌های چوله (نامتقارن) چنین نیست. در مثال‌های زیر رابطه شاخص‌های مرکزی بیشتر مورد بررسی قرار می‌گیرند.

۱۲-۱ چولگی (عدم قرینگی)

داده‌های ۲۲ جدول ۱-۵ را در نظر بگیرید. نمودار ۱-۱۲ که مربوط به داده‌های این جدول است، نشان می‌دهد که شکل توزیع داده‌ها متقارن و تا حدودی زنگوله‌ای شکل است. همانگونه که مقادیر شاخص‌های مرکزی نشان می‌دهد، در چنین توزیع‌های متقارنی، میانگین، میانه و نما با هم برابر هستند.

جدول ۱-۵. داده‌های دسته‌بندی شده و فراوانی آنها.

حدود دسته	۱۰-۱۲	۱۲-۱۴	۱۴-۱۶	۱۶-۱۸	۱۸-۲۰
فراوانی (f_i)	۳	۵	۷	۵	۳



نمودار ۱-۱۲. نمودار داده‌های جدول ۱-۵ که نشان دهنده متقارن بودن شکل توزیع است.


میانگین، میانه و نما برای این توزیع متقارن بصورت زیر محاسبه می‌شود.

$$\mu = \frac{11(3) + 13(5) + 15(7) + 17(5) + 19(3)}{23} = 15$$

$$m = 14 + \left(\frac{11/5 - 8}{7}\right)2 = 15$$

$$M = 14 + \left(\frac{2}{2+2}\right)2 = 15$$

مثال ۱-۱۴. تعداد تصادفات رانندگی در ۱۲ شهر در طول یک ماه ۳، ۴، ۵، ۲، ۳، ۵، ۴، ۵، ۱، ۴، ۶، ۵ بوده است. نمودار میله‌ای داده‌ها را رسم کرده و میانگین، میانه و نما را برای داده‌ها به دست آورید. چه ارتباطی بین میانگین، میانه و نما با شکل توزیع وجود دارد؟




نمودار ۱-۱۳. نمودار توزیع فراوانی داده‌های مثال ۱-۱۴ که نشان‌دهنده چولگی (عدم تقارن) توزیع به سمت چپ است.

$$\mu = \frac{\sum x_i}{N} = \frac{47}{12} = 3.91$$

$$m = 3/5 + \left(\frac{7-4}{3}\right)1 = 4.16$$

$$M = 4/5 + \left(\frac{1}{1+3}\right)1 = 4.75$$

ملاحظه می‌شود در مورد یک توزیع چوله به چپ میانگین کوچکتر از میانه و نما بوده و نما بزرگترین است. به طور کلی همانگونه که در نمودار زیر مشاهده می‌شود، در توزیع‌های دارای چولگی مثبت، رابطه $M < m < \mu$ و در توزیع‌های دارای چولگی منفی رابطه $\mu < m < M$ وجود دارد.



اگر n داده $x_1, x_2, x_3, \dots, x_i, \dots, x_n$ با فراوانی های $f_1, f_2, f_3, \dots, f_i, \dots, f_n$ موجود باشد، میانگین توان r ام $x_i - \mu$ را گشتاور مرتبه r ام پیرامون μ نامیده و صورت زیر نشان می دهند.

$$\mu_r = \frac{\sum (x_i - \mu)^r}{N}$$

واضح است که گشتاور مرتبه دوم پیرامون μ همان واریانس جامعه است ($\mu_2 = \sigma^2$). پارامتر $\frac{\mu_3}{\sigma^3}$ که ضریب چولگی گشتاوری نام دارد، برابر با

$$SK = \frac{\mu_3}{\sigma^3} = \frac{\frac{\sum (x_i - \mu)^3}{N}}{\left(\sqrt{\frac{\sum (x_i - \mu)^2}{N}} \right)^3}$$

بوده و به عنوان مهمترین شاخص چولگی (عدم تقارن) مورد استفاده قرار می گیرد. از دیگر پارامترهایی که به عنوان شاخص چولگی به کار می روند می توان به ضریب چولگی اول پیرسون، $(\mu - M)/\sigma$ و ضریب چولگی دوم پیرسون، $[3(\mu - m)]/\sigma$ اشاره کرد که در آن M و m به ترتیب مد و میانه هستند. در صورتیکه داده ها نسبت به میانگین متقارن باشند، همه ضرایب چولگی برابر صفر خواهند بود.

گرچه روابط مختلفی برای محاسبه مقدار چولگی وجود دارد ولی در نرم افزارهای آماری از جمله *SPSS*، *SAS*، *Excel*، *Minitab* برای برآورد چولگی از ضریب چولگی گشتاوری، $\frac{\mu_3}{\sigma^3}$ استفاده شده و مقدار آن از رابطه زیر با استفاده نمونه برآورد می شود.

$$SK = \frac{n}{(n-1)(n-2)} \sum \left(\frac{x_i - \bar{x}}{s} \right)^3$$

۱-۱۳ برجستگی

میزان برجستگی یا تیزی منحنی در نقطه ماکزیمم منحنی فراوانی را نسبت به منحنی نرمال استاندارد، برجستگی می نامند. فرض کنید μ گشتاور مرکزی چهارم و σ انحراف استاندارد باشد. در این صورت معیار برجستگی را از رابطه $K = \frac{\mu_4}{\sigma^4} - 3$ محاسبه می شود. مقدار K برای منحنی نرمال نزدیک صفر است. بر حسب آنکه K مثبت یا منفی باشد منحنی فراوانی نسبت به منحنی نرمال استاندارد مرتفع تر یا مسطح تر می باشد. همانگونه که در مورد چولگی گفته شد، رابطه ای که برای برآورد ضریب کشیدگی در اغلب نرم افزارهای آماری از جمله *Minitab*، *Excel*، *SAS* و *SPSS* برای برآورد برجستگی در نمونه مورد استفاده قرار می گیرد، مقداری با رابطه $\frac{\mu_4}{\sigma^4} - 3$ متفاوت است.

۱-۱۴ شاخص های پراکندگی

شاخص های پراکندگی میزان پراکندگی داده ها را نشان می دهند. دو مجموعه داده ممکن است میانگین یکسانی داشته باشند، ولی پراکندگی آنها با هم متفاوت باشد به عنوان مثال میانگین مجموعه داده ۲، ۳ و ۴ برابر با میانگین ۱، ۳ و ۵ است، ولی میزان پراکندگی داده های مجموعه دوم بیشتر است.

۱-۱۴-۱ دامنه

ساده ترین معیار پراکندگی دامنه (R) است که تفاوت بین بزرگترین داده و کوچکترین داده را نشان می دهد. دامنه اغلب معیار خوبی برای پراکندگی نیست. زیرا مفهوم واقعی پراکندگی به فاصله کلیه داده ها از هم بستگی دارد، در حالی که فقط بزرگترین و کوچکترین داده در محاسبه دامنه مورد استفاده قرار می گیرند. برای مثال دو مجموعه متفاوت از داده ها را در نظر بگیرید. با فرض اینکه مجموعه اول داده های ۱۰، ۰، ۸، ۱۰ و ۹ و مجموعه دوم متشکل از داده های ۰، ۵، ۳، ۷ و ۱۰ باشند، دامنه برای هر دو مجموعه برابر با ۱۰ خواهد بود.

۱-۱۴-۲ میانگین انحرافات

انتظار می‌رود میانگین فاصله مشاهدات از میانگین خود، شاخص خوبی برای بیان پراکندگی باشد، اما با توجه به اینکه مجموع انحرافات یک سری داده از میانگین آنها یعنی $\sum (x_i - \mu)$ همیشه برابر صفر است، در نتیجه مقدار $\sum (x_i - \mu)$ در اندازه‌گیری پراکندگی فاقد ارزش است. یک راه حل، استفاده از مجموع قدر مطلق انحرافات یعنی $\sum |x_i - \mu|$ است. اگر مجموع قدر مطلق انحرافات بر تعداد داده‌ها تقسیم شود، میانگین انحرافات از میانگین (MD) به دست می‌آید که می‌تواند به عنوان شاخصی در اندازه‌گیری پراکندگی داده‌ها به کار رود. به عنوان مثال MD برای دو مجموعه از داده‌های مذکور در بند قبل به صورت زیر محاسبه می‌شود.

$$MD_1 = \frac{\sum |x_i - \mu|}{N} = \frac{|2/6| + |-7/4| + |0/6| + |2/6| + |1/6|}{5} = 2/96$$

$$MD_2 = 2/8$$

۱-۱۴-۳ واریانس

می‌توان به جای قدر مطلق انحرافات از میانگین، از توان دوم آنها استفاده نمود. میانگین توان دوم انحرافات، شاخص پراکندگی دیگری است که واریانس نام دارد.

واریانس (میانگین توان دوم انحرافات از میانگین) یک مجموعه داده به صورت زیر محاسبه می‌شود:

$$\sigma_x^2 = \frac{\sum (x_i - \mu)^2}{N} = \frac{\sum x_i^2 - \frac{(\sum x_i)^2}{N}}{N}$$

محاسبه واریانس با استفاده از اعداد خام

به عنوان مثال واریانس اعداد ۳، ۵، ۶، ۳ و ۳ به صورت زیر به دست می‌آید.

$$\sigma^2 = \frac{(3-4)^2 + (5-4)^2 + (6-4)^2 + (3-4)^2 + (3-4)^2}{5} = \frac{(9+25+36+9+9) - \frac{(3+5+6+3+3)^2}{5}}{5} = 1/6$$

محاسبه واریانس با استفاده از جدول فراوانی

اگر در جدول فراوانی، میان دسته‌ها $x_1 \cdot x_2 \cdot \dots \cdot x_N$ و فراوانی متناظر با آنها $f_1 \cdot f_2 \cdot \dots \cdot f_N$ باشد، واریانس به صورت زیر به دست می‌آید.

$$\sigma_x^2 = \frac{\sum (x_i - \mu)^2 f_i}{N} = \frac{\sum x_i^2 f_i - \frac{(\sum x_i f_i)^2}{N}}{N}$$

مثال ۱-۱۵. در جدول زیر طول بلال در ۲۰ بوته ذرت به سانتی متر داده شده است. میانگین و واریانس را با استفاده از داده‌های اصلی و جدول فراوانی به دست آورده و با هم مقایسه کنید.

۱۹/۵	۲۳/۲	۲۰/۵	۲۳/۵	۱۳/۳	۲۲/۵	۱۸/۲	۱۸/۴	۱۹/۶	۲۳/۵
۱۶/۷	۱۵/۵	۲۲/۲	۲۴/۳	۱۷/۵	۲۰/۴	۲۱/۸	۲۲/۹	۲۲/۵	۲۷/۲

جدول ۱-۶. تقسیم داده‌های جدول بالا در هفت دسته مجزا.

فاصله دسته	فراوانی (f_i)	نسبت یا فراوانی نسبی (p_i)	نشان دسته
۱۳/۲۵-۱۵/۲۵	۱	۰/۰۵	۱۴/۲۵
۱۵/۲۵-۱۷/۲۵	۲	۰/۱۰	۱۶/۲۵
۱۷/۲۵-۱۹/۲۵	۳	۰/۱۵	۱۸/۲۵
۱۹/۲۵-۲۱/۲۵	۴	۰/۲۰	۲۰/۲۵
۲۱/۲۵-۲۳/۲۵	۶	۰/۳۰	۲۲/۲۵
۲۳/۲۵-۲۵/۲۵	۳	۰/۱۵	۲۴/۲۵
۲۵/۲۵-۲۷/۲۵	۱	۰/۰۵	۲۶/۲۵
	۲۰	۱	

در ابتدا میانگین با استفاده از جدول توزیع فراوانی محاسبه می‌شود.

$$\mu = \frac{\sum x_i f_i}{\sum f_i} = \frac{(14/25 \times 1) + (16/25 \times 2) + \dots + (26/25 \times 1)}{1 + 2 + 3 + 4 + 6 + 3 + 1} = 20/75 \text{ cm}$$

سپس واریانس با استفاده از جدول توزیع فراوانی بصورت زیر بدست می‌آید.

$$\sigma^2 = \frac{[(14/25 - 20/75)^2 \cdot 1] + [(16/25 - 20/75)^2 \cdot 2] + \dots + [(26/25 - 20/75)^2 \cdot 1]}{20} \\ = 9/15 \text{ cm}^2$$

اگر واریانس به دست آمده با استفاده از جدول فراوانی با واریانس به دست آمده از داده‌های خام مقایسه شود، مشاهده می‌شود که این دو کاملاً برابر نیستند. واضح است که واریانس حاصل از داده‌های خام دقیق‌تر است زیرا در جدول فراوانی، داده‌ها دسته‌بندی شده و در هر دسته یک داده به عنوان نماینده در نظر گرفته می‌شود. لذا واریانس به دست آمده در این حالت (۹/۱۵) اندکی از مقدار واقعی (۱۰/۷۱) انحراف نشان داده است.

$$\mu = \frac{\sum x_i}{N} = \frac{19/5 + \dots + 27/2}{20} = 20/66 \text{ cm} \\ \sigma^2 = \frac{(19/5 - 20/66)^2 + \dots + (27/2 - 20/66)^2}{20} = 10/71 \text{ cm}^2$$

۱-۱۴-۳-۲ واریانس نمونه

روابطی که تا اینجا ذکر شد برای محاسبه واریانس جامعه بود. غالباً کل داده‌های جامعه در اختیار نیست و هدف، برآورد واریانس جامعه از طریق نمونه‌ای n عضوی است. در این حالت واریانس باید به گونه‌ای محاسبه شود که تقریباً برابر با واریانس جامعه باشد.

محاسبه واریانس جامعه و برآورد نمونه‌ای آن

واریانس جامعه:

$$\sigma_x^2 = \frac{\sum (x_i - \mu_x)^2}{N}$$

برآورد واریانس جامعه هنگامی که فقط نمونه‌ای از جامعه موجود است:

$$s_x^2 = \frac{\sum (x_i - \bar{x})^2}{n-1}$$

ثابت می‌شود که این رابطه، واریانس جامعه را به طور نازیب برآورد می‌کند، به این معنی که اگر همه نمونه‌های n عضوی ممکن از جامعه‌ای استخراج شود، میانگین واریانس نمونه‌ها برابر با واریانس جامعه خواهد بود.

مثال ۱-۱۶. نمونه‌ای از داده‌های ۰، ۱، ۲، ۳ و ۴ به ترتیب با فراوانی‌های ۱۸، ۲۳، ۶، ۲ و ۱ تشکیل شده است. واریانس این نمونه را محاسبه کنید.

$$s_x^2 = \frac{\sum (x_i - \bar{x})^2 f_i}{n-1} = \frac{\sum x_i^2 f_i - \frac{(\sum x_i f_i)^2}{n}}{n-1} = \frac{۸۱ - \frac{۴۵^2}{۵۰}}{۴۹} = \frac{۸۱ - ۴۰/۵}{۴۹} = ۰/۸۲$$

۱-۱۴-۳ ویژگی‌های واریانس

اگر همه داده‌ها در عددی غیر صفر مانند a ضرب و با عددی مانند b جمع شوند، واریانس داده‌های جدید a^2 برابر خواهد شد. لذا اگر مقدار ثابتی به همه داده‌ها افزوده شود واریانس بدون تغییر باقی خواهد ماند، یعنی رابطه $\sigma_{ax+b}^2 = a^2 \sigma_x^2$ برقرار است.

مثال ۱-۱۷. اگر $x_1 = ۳$ ، $x_2 = ۵$ ، $x_3 = ۷$ و همچنین $y_i = ۲x_i + ۳$ باشد، واریانس x و y را حساب کرده و روابط آنها را بدست آورید.

$$y_1 = 9, y_2 = 13, y_3 = 17$$

$$\sigma_x^2 = \frac{\sum (x_i - \mu_x)^2}{N} = 2/66$$

$$\sigma_y^2 = \frac{\sum (x_i - \mu_y)^2}{N} = 10/66$$

$$\sigma_y^2 = 2^2 \times \sigma_x^2 = 4 \times 2/66 = 10/66$$

مثال ۱-۱۸. واریانس جامعه داده‌های زیر را به دست آورید.

دسته	۱۵-۲۵	۲۵-۳۵	۳۵-۴۵	۴۵-۵۵	۵۵-۶۵
فراوانی	۳	۵	۲	۵	۵

در ابتدا نشان هر دسته را به عنوان نماینده آن دسته در نظر می‌گیریم:

$$\sigma_x^2 = \frac{\sum x_i^2 f_i - \frac{(\sum x_i f_i)^2}{N}}{N} = \frac{(20^2 \times 3) + \dots + (60^2 \times 5) - \frac{[(20 \times 3) + \dots + (60 \times 5)]^2}{20}}{20} = 206$$

یک روش ساده کردن محاسبات این است که با یک تبدیل خطی، مقادیر نشان دسته به اعداد ساده‌تری تبدیل و میانگین و واریانس آنها محاسبه شوند. سپس میانگین و واریانس متغیر اصلی به کمک روابط موجود به دست آیند. اگر نشان دسته‌ها در مثال ۱-۱۸ بر ۱۰ تقسیم شوند، محاسبه واریانس داده‌های حاصل ساده‌تر است.

x_i	۲	۳	۴	۵	۶
فراوانی	۳	۵	۲	۵	۵

$$\sigma_x^2 = \frac{(2^2 \times 3) + \dots + (6^2 \times 5) - \frac{[(2 \times 3) + (3 \times 5) + \dots + (6 \times 5)]^2}{20}}{20} = 2/06$$

اگر واریانس حاصل (۲/۰۶) در 10^2 ضرب شود واریانس داده‌های اصلی (۲۰۶) به دست می‌آید. روش دیگر ساده کردن این است که ابتدا میانگین از همه داده‌ها کم شده و سپس واریانس داده‌های جدید به دست آیند.

مثال ۱-۱۹. ارتفاع بوته‌ها در جامعه‌ای متشکل از شش بوته، ۲، ۳، ۹، ۵ و ۶ سانتی‌متر بوده است. واریانس را به دست آورید.

اگر میانگین (یعنی ۵) از هر کدام از این داده‌ها کم شود، اعداد ۳-، ۲-، ۴، ۰ و ۱ به دست خواهند آمد که میانگین آنها برابر با صفر است. واریانس این داده‌ها برابر با واریانس داده‌های اولیه خواهد بود.

$$\sigma_{x'}^2 = \frac{\sum (x'_i - \mu)^2}{N} = \frac{\sum (x'_i - 0)^2}{N} = \frac{\sum x_i'^2}{N} = \frac{9 + 4 + 16 + 0 + 1}{5} = 6 \text{ cm}^2$$

اگر مجموع داده‌ها صفر باشد، میانگین نیز برابر با صفر شده و واریانس برابر با مجموع توان دوم داده‌ها تقسیم بر N است.

۱-۱۴-۴ انحراف معیار

واحد واریانس توان دوم واحد اصلی داده‌هاست در حالی که اغلب بیان واحد اندازه‌گیری در همان واحد اصلی داده‌ها مورد نظر است. انحراف معیار، چنین معیاری از پراکندگی است که با جذر گرفتن از واریانس به دست می‌آید. انحراف معیار در مورد مثال ۱-۱۹ برابر است با:

$$\sigma = \sqrt{\sigma^2} = \sqrt{6} = 2/45 \text{ cm}$$

در اینجا انحراف معیار با ارائه یک مثال دیگر بیشتر بررسی می‌شود. فرض کنید ۳۰ دانش‌آموز در مسابقه‌ای، مسافتی را در فواصل زمانی مختلف پیموده و نتایج بر حسب دقیقه مطابق جدول ۱-۷ بوده است.

جدول ۱-۷. فاصله‌های زمانی (بر حسب دقیقه) که طی آن ۳۰ دانش‌آموز یک مسافت مشخص را طی کردند.

۱/۹۷	۰/۶۰	۴/۰۲	۳/۲۰	۱/۱۵	۶/۰۶	۴/۴۴	۲/۰۲	۳/۳۷	۳/۶۵
۱/۷۴	۲/۷۵	۳/۸۱	۹/۷۰	۸/۲۹	۵/۶۳	۵/۲۱	۴/۵۵	۷/۶۰	۳/۱۶
۳/۷۷	۵/۳۶	۱/۰۶	۱/۷۱	۲/۴۷	۴/۲۵	۱/۹۳	۵/۱۵	۲/۰۶	۱/۶۵

در این مجموعه داده چه تعداد از داده‌ها در فاصله یک انحراف معیار از میانگین قرار دارند؟ چه

تعداد از داده‌ها در فاصله دو انحراف معیار از میانگین قرار دارند؟ پس از یک محاسبه ساده $\bar{x} = ۳/۷۴$ و $s = ۲/۱۹۸$ به دست می‌آید که در خروجی نرم‌افزار Minitab نیز نشان داده شده است.

جدول ۸-۱ محاسبه میانگین و انحراف معیار با نرم‌افزار Minitab.

مراحل:							
۱. داده‌ها را در ستون اول صفحه داده‌ها وارد کنید و وارد مسیر زیر شوید:							
Stat > Basic Statistics > Display Descriptive Statistics...							
۳. در پنجره مربوطه در قسمت Variables ستون اول یا C1 را انتخاب کنید (همچنین می‌توانید بر روی Statistics... کلیک کرده و در پنجره حاصل آماره‌های مورد نظر را برای محاسبه انتخاب نمایید).							
۴. گزینه OK را انتخاب نمایید.							
Variable	N*	Mean	SE Mean	StDev	Minimum	Median	Maximum
C1	0	3.744	0.401	2.198	0.600	3.510	9.700

در این مثال:

$$\begin{aligned}\bar{x} - s &= ۳/۷۴ - ۲/۲۰ = ۱/۵۴ & \bar{x} + s &= ۳/۷۴ + ۲/۲۰ = ۵/۹۴ \\ \bar{x} - ۲s &= ۳/۷۴ - ۴/۴۰ = -۰/۶۶ & \bar{x} + ۲s &= ۳/۷۴ + ۴/۴۰ = ۸/۱۴\end{aligned}$$

با بررسی داده‌ها متوجه می‌شویم که ۲۳ داده از ۳۰ داده (تقریباً ۷۷٪ داده‌ها) در فاصله $\bar{x} - s$ تا $\bar{x} + s$ یعنی ۱/۵۴ تا ۵/۹۴ و ۲۸ داده (تقریباً ۹۳٪ آنها) در فاصله $\bar{x} - ۲s$ تا $\bar{x} + ۲s$ یعنی -۰/۶۶ تا ۸/۱۴ قرار گرفته‌اند. غالب داده‌های مربوط به پدیده‌های طبیعی دارای چنین ویژگی بوده و حداقل ۷۵٪ آنها در فاصله دو انحراف معیار از میانگین ($\bar{x} - ۲s$ تا $\bar{x} + ۲s$) قرار می‌گیرند. این ویژگی برای اولین بار توسط چیشیف ریاضی‌دان روسی به صورت زیر بیان شد.

قاعده چیشف

در یک مجموعه N تایی از مشاهدات حداقل $(1 - \frac{1}{K^2})$ درصد از مشاهدات در دامنه K انحراف معیار از میانگین قرار می‌گیرند. K عددی مثبت است که مقادیر بزرگتر از یک را شامل می‌شود. به عنوان مثال اگر K برابر با ۲ باشد، حداقل $\frac{3}{4}$ یعنی ۷۵٪ داده‌ها در فاصله دو انحراف معیار از میانگین $(\bar{x} - 2s)$ تا $(\bar{x} + 2s)$ ، و اگر K برابر با ۳ باشد، حداقل $\frac{8}{9}$ یعنی ۸۹٪ داده‌ها در فاصله $\bar{x} - 3s$ تا $\bar{x} + 3s$ قرار دارند.

قاعده دومی نیز در این مورد وجود دارد که به قاعده تجربی معروف است. این قاعده نیز همانند قاعده چیشف یک حساب سرانگشتی از پراکندگی داده‌ها نسبت به میانگین ارائه می‌دهد. قاعده تجربی که به صورت زیر تعریف می‌شود، غالباً در مورد توزیع‌های متقارن صدق می‌کند.

قاعده تجربی

در صورتی که توزیع داده‌ها متقارن باشد (میانگین، میانه و نما تقریباً برابر باشند) تقریباً ۶۸٪ داده‌ها در فاصله یک انحراف معیار از میانگین قرار دارند. همچنین تقریباً ۹۵٪ داده‌ها در فاصله دو انحراف معیار از میانگین و ۹۹٫۷٪ داده‌ها (تقریباً تمام آنها) در فاصله سه انحراف معیار از میانگین قرار دارند.

۱-۱۴-۵ ضریب تغییرات

ضریب تغییرات از تقسیم انحراف معیار بر میانگین به دست آمده و معمولاً بر حسب درصد بیان می‌شود. در واقع ضریب تغییرات پراکندگی داده‌ها را نسبت به میانگین نشان می‌دهد.

$$CV = \frac{\sigma}{\mu} \times 100\% \quad \text{ضریب تغییرات جامعه}$$

$$CV = \frac{s}{\bar{x}} \times 100\% \quad \text{ضریب تغییرات نمونه}$$

برای مثال دو نمونه: الف) ۲/۱، ۳/۵، ۴/۷، ۵/۲ و ۶/۴ و ب) ۱/۲، ۱/۳، ۱/۴، ۱/۵ و ۱/۱۰

۱۰۶/۴ را در نظر بگیرید. این دو مجموعه پراکندگی یکسانی دارند و انحراف معیار در هر دو برابر با ۱/۶۴۵ است. با این حال پراکندگی در مجموعه "الف" نسبت به میانگین آن (۴/۳۸) خیلی بیشتر بوده و ضریب تغییرات در آن برابر با ۳۷/۵۶٪ است. این در حالی است که داده‌های مجموعه دوم نسبت به میانگین خود خیلی متغیر نبوده و ضریب تغییرات آن فقط ۱/۵۸٪ است. اگر متغیر تعداد دانه در خوشه گندم دارای انحراف معیار ۱/۴ و میانگین ۵۰ و متغیر وزن دانه بر حسب گرم دارای انحراف معیار ۰/۱۴ و میانگین ۵ باشد، مقایسه پراکندگی تعداد دانه و وزن دانه از طریق مقایسه ضریب تغییرات مشخص می‌شود. ضریب تغییرات نشان می‌دهد که میزان پراکندگی نسبت به میانگین در هر دو صفت یکسان است:

$$CV_1 = \frac{1/4}{50} \times 100\% = 2/8\%$$

$$CV_2 = \frac{0/14}{5} \times 100\% = 2/8\%$$

۱-۱۴-۶ استاندارد کردن داده‌ها

مقایسه داده‌های مربوط به جوامع مختلف، به این دلیل که ممکن است داده‌ها دارای واحدهای اندازه‌گیری متفاوت و میانگین یا انحراف معیار متفاوتی باشند بی‌فایده است. برای حذف اثر واحد اندازه‌گیری و یکسان نمودن میانگین و انحراف معیار، داده‌های جوامع مختلف را با استفاده از رابطه زیر استاندارد می‌کنند. مقایسه نمره‌ها پس از تبدیل آنها به داده‌های استاندارد در شرایط عادلانه صورت می‌گیرد. نمره‌های استاندارد حاصل از هر جامعه‌ای بدون واحد بوده و توزیعی با میانگین و پراکندگی یکسان تشکیل می‌دهند. میانگین و واریانس چنین جامعه‌ای که به جامعه استاندارد معروف است، به ترتیب برابر با صفر و یک می‌باشد.

$$z_i = \frac{x_i - \mu_x}{\sigma_x} \quad (\text{نمره استاندارد})$$

مثال ۱-۲۰. نمرات دانشجویان دانشکده‌ای در درس آمار دارای توزیعی متقارن با میانگین ۱۴/۵ و انحراف معیار ۴ و در درس ریاضیات دارای توزیعی متقارن با میانگین ۱۴/۴ و انحراف معیار ۲ می‌باشند. دانشجویی در درس آمار ۱۷/۵ و در درس ریاضیات ۱۶ گرفته است. او در کدام درس

به طور نسبی قوی تر است؟

این دو نمره را نمی توان مستقیماً با هم مقایسه کرد، زیرا نمونه های مربوط به آنها میانگین و انحراف معیار متفاوت دارند. لذا برای مقایسه آنها لازم است که ابتدا نمره ها استاندارد شوند.

$$z_1 = \frac{x_1 - \mu_1}{\sigma_1} = \frac{17/5 - 14/5}{4} = 0,75$$

$$z_2 = \frac{x_2 - \mu_2}{\sigma_2} = \frac{16 - 14/4}{2} = 0,80$$

مقایسه نمره های استاندارد نشان می دهد که با وجود اینکه دانشجوی مذکور در درس ریاضیات نمره کمتری گرفته ولی نسبت به همکلاسی هایش در این درس قوی تر است.

جدول ۹-۱. محاسبه نمرات استاندارد در نرم افزار Minitab.

مراحل:

۱. داده هایی را که می خواهید استاندارد شوند در یک ستون وارد کرده و سپس وارد مسیر زیر شوید.

Calc > Standardize...

۲. در مقابل Input column(s) ستونی را که داده ها در آن قرار دارند انتخاب و در مقابل Store results in ستونی را که می خواهد داده های استاندارد شده در آنجا ذخیره شوند (مثلاً C2)، بنویسید.
۳. گزینه های مختلفی در این پنجره وجود دارد. می توانید گزینه Subtract first value and divide by second را انتخاب و به ترتیب میانگین و انحراف معیار را وارد کنید. سپس بر روی OK کلیک کنید.

تمرین ها

۱-۱. میانه و نما را برای داده های زیر به دست آورید.

- الف) ۱, ۲, ۳, ۴, ۵, ۵, ۵, ۷, ۷, ۹
 ب) ۱, ۲, ۳, ۴, ۵, ۵, ۵, ۶, ۸

۲-۱. نمودار بافت نگار را برای ۵۰۰ داده جدول زیر رسم کنید به طوری که محور عمودی، فراوانی نسبی باشد.

حدود دسته	فراوانی نسبی
۰/۵-۲/۵	۰/۱۰
۲/۵-۴/۵	۰/۱۵
۴/۵-۶/۵	۰/۲۵
۶/۵-۸/۵	۰/۲۰
۸/۵-۱۰/۵	۰/۰۵
۱۰/۵-۱۲/۵	۰/۱۰
۱۲/۵-۱۴/۵	۰/۱۰
۱۴/۵-۱۶/۵	۰/۰۵

۳-۱. در جامعه داده‌های تمرین ۱-۲، الف) تعداد افرادی که در هر کلاس قرار می‌گیرند را به دست آورید. ب) میانگین حسابی، میانگین هندسی، میانه، نما و انحراف معیار را به دست آورید.

۴-۱. جدول زیر را که نمرات دانشجویان در درس آمار است، تکمیل کنید.

نمرات	فراوانی	فراوانی نسبی
۹۰-۱۰۰		۰/۰۸
۸۰-۸۹	۳۶	
۶۵-۷۹	۹۰	
۵۰-۶۴	۳۰	
کمتر از ۵۰	۲۸	
جمع	۲۰۰	۱

۵-۱. سه ماشین به تولید یک کالا مشغولند. اولی کالا را در ۲، دومی در ۳ و سومی در ۶ دقیقه تولید می‌کند. اگر این سه ماشین با هم کار کنند به طور متوسط یک کالا در چند دقیقه تولید می‌شود؟

۶-۱. به سؤالات مطرح شده در ارتباط با تغییرات داده‌ها پاسخ دهید. الف) نشان دادن پراکنندگی داده‌ها بر حسب دامنه تغییرات چه عیبی دارد؟ ب) واریانس نمونه را در جمله‌ای تعریف کنید. ج) واریانس جامعه را در جمله‌ای تعریف کنید. د) آیا واریانس می‌تواند منفی باشد؟ چرا؟ ه) آیا واریانس می‌تواند کوچکتر از انحراف معیار باشد؟ چرا؟

۷-۱. واریانس و انحراف معیار را در موارد زیر به دست آورید.

الف) $(n = 10, \sum x^2 = 84, \sum x = 20)$ ب) $(n = 40, \sum x^2 = 380, \sum x = 100)$

ج) $(n = 20, \sum x^2 = 18, \sum x = 17)$

۸-۱. دامنه، واریانس و انحراف معیار را برای نمونه‌های زیر به دست آورید. الف) $(1, 0, 1, 2, 3)$ ب) $(3, 3, 2, 2, 1, 1, 0, 0, -1, -1, 2, 3, 5, 4, 4, 1, 3, 3)$ ج) $(3, 3, 2, 2, 1, 1, 0, 0, -1, -1, -2, 1, -1, 1, -1, 2, 3, 5, 4, 4, 1, 3, 3)$ د) $(1, 0, -1, -2, -3, -3, -1, -1, -1, 1, 2, 3, 5, 4, 4, 1, 3, 3)$

۹-۱. مقادیر \bar{x} ، s^2 و s را برای داده‌های زیر به دست آورده و در هر مورد در صورت وجود واحد را نیز ذکر

کنید.

الف) ۳, ۱, ۱۰, ۱۰, ۴

ب) ۳m, ۱۰m, ۳۲m, ۵m

ج) -۳, -۲, -۴, -۵, -۴

د) ۱/۵kg, ۱/۵kg, ۲/۵kg, ۴/۵kg

۱۰-۱. با استفاده از داده‌های ۱ تا ۱۰ دو مجموعه داده بنویسید که میانگین یکسان ولی واریانس‌های متفاوت داشته باشند.

۱۱-۱. نمونه مقابل را که متشکل از ۵ داده می‌باشد در نظر بگیرید: ۱, ۱, ۱, ۰, ۳. الف) دامنه، s^2 و s را به دست آورید. ب) به هر کدام از داده‌ها ۳ را اضافه کرده و محاسبات را تکرار کنید. ج) عدد ۴ را از هر کدام کم کرده و محاسبات خواسته شده در قسمت الف را تکرار کنید. د) جواب‌ها را مقایسه کرده و اثر افزودن یا کاستن یک مقدار ثابت از داده‌ها را بر روی دامنه، s^2 و s بیان کنید.

۱۲-۱. جوامع زیر را در نظر بگیرید. الف) حدس می‌زنید چه رابطه‌ای بین واریانس جوامع a با b و همچنین c با d وجود داشته باشد؟ ب) واریانس‌ها را به دست آورده و مقایسه کنید. ج) نمودار نقطه‌ای را برای جوامع a و b رسم کنید.

الف) ۲, ۳, ۵, ۷

ب) ۲, ۲, ۲, ۳, ۳, ۳, ۵, ۵, ۵, ۷, ۷, ۷

ج) ۶, ۹, ۱۵, ۲۱

د) ۱۰, ۱۳, ۱۹, ۲۵

۱۳-۱. داده‌های تمرین ۱-۱ را به عنوان یک جامعه در نظر بگیرید. الف) میانگین را به دست آورید. ب) واریانس و انحراف معیار داده‌ها را به دست آورید.

۱۴-۱. در یک نمونه ۶ عضوی میانگین ۲ و مجموع توان دومها ۳۰ می‌باشد. واریانس نمونه را به دست آورید.

۱۵-۱. الف) ضریب تغییرات متغیر x ، ۲۰٪ است. اگر داده‌های مربوطه بر ۵ تقسیم شوند، ضریب تغییرات چقدر خواهد شد؟

۱۶-۱. اگر $N=10$ ، $\sum x_i = 200$ و $\sum x_i^2 = 5000$ باشد، مقدار ضریب تغییرات را به دست آورید.

۱۷-۱. در چه صورتی هر سه نوع میانگین h ، g و l با یکدیگر برابر خواهند بود؟

۱۸-۱. کدام یک از پارامترهای واریانس، میانگین، دامنه میانچارگی و میانگین انحرافات بیشتر تحت تأثیر داده‌های پرت قرار می‌گیرند؟

