

به نام خدا
دانشگاه فرهنگیان
واحد تربیت معلم نیشابور

Ph.D. Student Vahid Hajimirza

Email: vhc1359@gmail.com

Mobile: 091515170119

<http://www.htcnet.ir>

Ph.D. Student Vahid Hajimirza

به نام خدا

شیوه های تحلیل کمی و کیفی داده ها با کاربرد نرم افزارها

بارم بندی نمرات:

- ۱- مقاله کنفرانسی ۵ نمره
- ۲- سوالات و تمرین کلاسی ۲ نمره
- ۳- میان ترم و پایان ترم ۸ نمره
- ۴- پروژه SPSS به همراه مکتوبات ۵ نمره

نمره اضافی :

- ۱-مقاله علمی ترویجی یا علمی پژوهشی ۱۰ نمره
- ۲-مقاله اضافی کنفرانسی ۵ نمره
- ۳-ارفاق به کل دانشجویان ۱ نمره
- ۴- ترجمه بخشی از کتاب ۳ نمره

پیشگفتار:

در عصر حاضر کسی نمی‌تواند منکر این واقعیت باشد که آمار نقشی لاینفک در زندگی روزمره ما بازی می‌کند. اخبار روزانه رسانه‌های گروهی با گزارشی از وضع هوا به پایان می‌رسند و در طول اخبار، به جریانهای بازار بورس و سهام اشاره می‌شود و روزنامه‌ها خبر از افزایش نرخ اجناس می‌دهند...

آمار به عنوان پایه یک روش و راه موثر در بررسی مسائل موجود، در بسیاری از زمینه‌های علمی از جمله جامعه‌شناسی، کشاورزی، فیزیک و... به کار گرفته می‌شود. در دانش امروزی، معمولاً سعی می‌شود که اطلاعات موجود در یک زمینه خاص، در قالب اعداد نمایش داده شود تا به هنگام تجزیه و تحلیل اطلاعات، فهم بهتری از پدیده مورد مطالعه به دست آمده و امکان مقایسه فراهم گردد. در یک جمله آمار مجموعه‌ای از روشهای جمع‌آوری، تهیه و تنظیم و تجزیه و تحلیل اطلاعات است که برای کسب یک یا چند نتیجه به خدمت گرفته می‌شود.

فهرست مطالب:

آمار توصیفی

جدول‌های آماری

نمودارهای آماری

معیارهای مرکزی

معیارهای پراکندگی

منحنی‌های فراوانی

آشنایی با آمار توصیفی

Ph.D. Student Vahid Hajimirza

مروری بر مفاهیم اصلی و اهم کاربردهای امار

Ph.D. Student Vahid Hajimirza

مقدمه

آمار چیست و چگونه به ما کمک می کند؟

تعریف آمار

آمار مجموعه ایی از روشها را برای **جمع آوری**، و **خلاصه کردن داده ها**، **طبقه بندی آنها** و **روشهای تحلیلی برای پیش بینی**، **برآورد و تصمیم گیری** در شرایط مختلف ارائه می دهد.

تعریف

داده:

داده ها واقعیتها یا ارقامی هستند که می توان از آنها نتایجی را بیرون کشید. در واقع داده هامواد خام آماری هستند.

مجموعه داده:

داده هایی را که برای مطالعه ایی خاص گردآوری شده باشند مجموعه داده ها می نامیم.

عنصر:

هر عنصر اطلاعات یک یا چند مشخصه مجموعه داده را در بر می گیرد(مثل مشخصه های یک دانش آموز)

تعریف

متغیر:

متغیر مشخصه مربوط به یک عنصر است که می تواند برآمدهای مختلف را قبول کند. وقتی برآمدها مستقیما به صورت عددی بیان شود متغیر را کمی در غیر این صورت کیفی است. (مثل وزن و جنسیت)

مورد:

اطلاعات مربوط به تمام متغیرها برای یک عنصر از مجموعه داده ها را یک مورد می نامیم. مثل اطلاعات مربوط به پنج متغیر برای یک دانش آموز

مشاهده:

داده مربوط به یک عنصر از مجموعه داده ها در باره یک متغیر را یک مشاهده یا یک برآمد می نامند. مثلا عدد ۱۲ که سن دانش آموز را نشان می دهد یک مشاهده از متغیر سن برای این دانش آموز است

انواع داده :

۱- داده های اندازه گیری شده: مثل وزن

۲- داده های شمارشی: مثل تعداد افراد خانواده

۳- داده های رتبه ای: مثل رتبه دانشجویان از ۱ تا ۴

۴- داده های رده بندی شده: مثل جنسیت دانشجوها

تعریف

جامعه :

مجموعه عناصر مورد نظر برای مسأله ایی مفروض است(مثل مجموعه تولیدات یک کارخانه)

نمونه :

بخشی از جامعه تحت بررسی است، به قسمی که بتوان از آن نتایجی را در مورد جامعه استخراج نمود.

اندازه جامعه:

تعداد عناصر جامعه را اندازه جامعه می گویند.اگر تعداد عناصر جامعه متنهایی باشد جامعه را متنهایی در غیر این صورت نامتنهایی می گوئیم.

اندازه نمونه:

تعداد عناصر نمونه را اندازه نمونه می گویند.

آمار توصیفی:

برای اینکه نتایج مناسب و مطلوب از اطلاعات که در آمار گیری ها جمع آوری می کنیم، به دست آید باید:

اعداد نماینده واقعی مشاهدات بوده و غیرواقع یا غلط نباشند
به نحو مفیدی تهیه و تنظیم شوند
به نحو صحیح تجزیه و تحلیل گردند
قابل نتیجه گیری صحیح باشند



به طور کلی، روش هایی را که به وسیله آنها می توان اطلاعات جمع آوری شده را تنظیم کرده و خلاصه نمود، آمار توصیفی می نامیم و در یک کلام آمار توصیفی عبارت از مجموعه روش هایی است که پردازش داده ها را فراهم می سازد. اطلاع از اصطلاحات زیر در آمار ضروری است.

جمعیت

مجموعه افراد یا اشیایی را که می‌خواهیم یک یا چند خصوصیت مشترک آنها را مورد بررسی قرار دهیم، جمعیت یا جمعیت آماری می‌نامیم.

مثال:

اندازه قد یا وزن دانشجویان بیست ساله يك شهر، تعداد لامپهاي سالم و يا ناسالم تولید شده در يك کارخانه و در يك روز معین، مثالهایی از جمعیتهاي آماری هستند.

نکته:

معمولا مطالعه ویژگی‌هاي مورد نظر، به هنگامی که جمعیت آماری بسیار گسترده باشد، مستلزم صرف هزینه و وقت زیادی می‌باشد و در بسیاری از مواقع، این امر اصولا امکان پذیر نیست. بنابراین در چنین موردی، برای مطالعه ویژگی مورد نظر، به قسمتی از جمعیت آماری اکتفا می‌کنیم.

نمونه

قسمتی از جمعیت را که طبق قاعده و ضوابط خاصی، برای مطالعه خصوصیتی از جمعیت انتخاب می‌شود، یک نمونه از جمعیت می‌نامیم.

این نمونه وقتی مفید و قابل قبول خواهد بود که بتواند نماینده خوبی برای کل جمعیت مورد مطالعه باشد. با توجه به اهمیت این موضوع شاخه‌ای از آمار تحت عنوان نظریه نمونه‌گیری با بررسی نمونه‌ای به این امر مهم می‌پردازد. در بسیاری از موارد، معمولاً نمونه تصادفی ساده را در نظر می‌گیرند.

برای بررسی اندازه قد دانشجویان بیست ساله یک شهر، انتخاب مثالاً ۱۵۰ نفر از بین این جمعیت به طور تصادفی، یا انتخاب ۱۰۰ لامپ به تصادف از لامپهای تولیدی یک کارخانه در یک روز معین، برای تعیین کیفیت لامپهای تولیدی این کارخانه مثالهایی از نمونه تصادفی هستند.

نمونه

نکته

مثال:

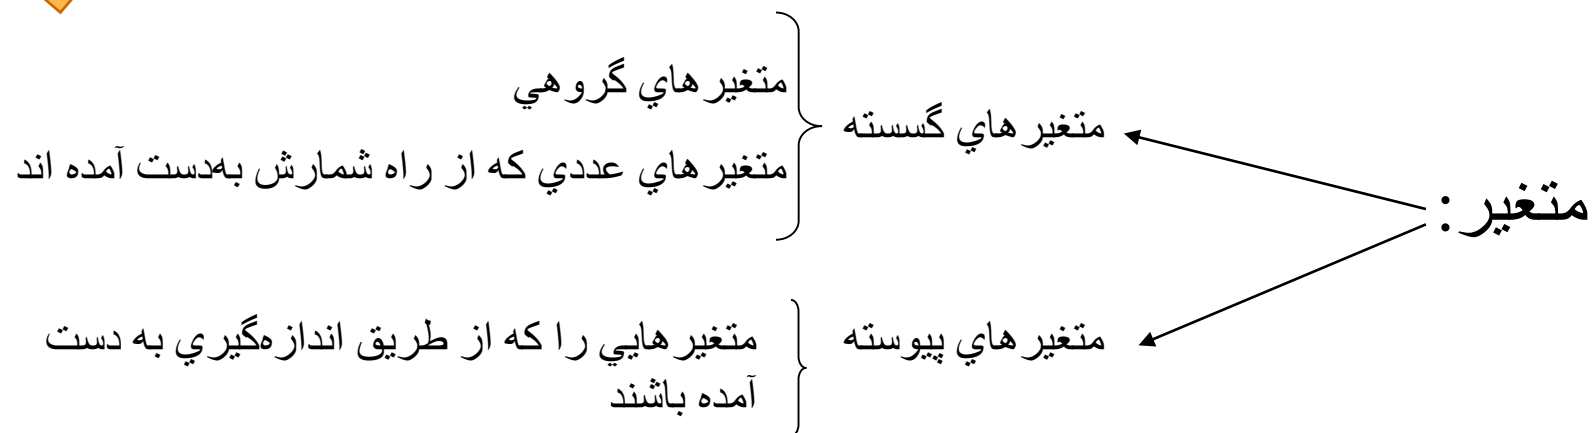
خصوصیت مورد مطالعه، از فردی به فرد دیگر، یا از شی به شی دیگر در جمعیت آماری تغییر می‌کند، که آن را اصطلاحاً متغیر می‌نامیم.

معمولاً دو نوع متغیر در آمار مورد نظر هستند:

متغیرهای گروهی، نظیر رنگ، نژاد، شغل و گروه خونی که شامل چند گروه یا طبقه می‌باشند.

متغیرهای عددی که ممکن است نتیجه شمارش باشد، مانند تعداد احشام هر خانوار در یک روستا، تعداد حوادث در یک کارخانه در روزهای مختلف، و یا نتیجه اندازه‌گیری باشد، مثل قد دانشجویان بیست ساله در یک شهر، حجم شربت مولتی ویتامین با استاندارد خاص.

متغیر



مقیاسهای اندازه‌گیری

در بسیار از مسائل پیش‌رو، اندازه‌گیری ویژگی يك متغیر مستلزم آگاهی و شناخت خاصی است. به طور کلی چهار نوع مقیاس برای اندازه‌گیری وجود دارد:

- مقیاس اسمی
- مقیاس ترتیبی
- مقیاس فاصله‌ای
- مقیاس نسبی

مقیاس اسمی:

این نوع مقیاس اندازه‌گیری عمدتاً برای طبقه‌بندی داده‌ها به کار می‌رود و منظور از آن اتلاق يك عدد طبیعی به داده‌های متفاوت است.

اختصاص اعداد ۱ تا ۴ به گروه‌های خونی A, B, AB, O.

مثال:

توجه داشته باشید که:

این اعداد را نمی‌توان برای مقایسه یا چهار عمل اصلی به کار برد

مقیاس‌های اندازه‌گیری

مقیاس ترتیبی:

این نوع مقیاس اندازه گیری عموماً برای طبقه بندی داده‌ها به منظور یک نوع برتری به کار می‌رود.

مثال:

در یک کارخانه ممکن است کارگران را به سه دسته ساده، نیمه ماهر و ماهر تقسیم بندی کنیم. اتلاق به ترتیب اعداد ۱ تا ۳ به این سه دسته یک مقیاس ترتیبی است.

نوجه داشته باشید که:

این اعداد تنها برای مقایسه به کار می‌روند و نمی‌توان با آنها چهار عمل اصلی را انجام داد.

مقیاس فاصله ای:

این نوع مقیاس انداز هگیری عموماً در زمینه‌هایی که علاوه بر حفظ ترتیب به نحوی فاصله بین ویژگی‌ها را نیز حفظ می‌کند. به عبارت دیگر در چنین مقیاسی نسبت تفاضلهای ثابت می‌ماند.

مثال:

اندازه‌گیری ضریب هوشی دانش آموزان کلاس اول دبستان در شهر اصفهان.

نوجه داشته باشید که:

در این نوع مقیاس، عدد صفر يك مفهوم قرار دادي است.

مقیاس نسبی:

این نوع مقیاس اندازه گیری علاوه بر حفظ فاصله، نسبت را نیز حفظ می کند. به عبارت دیگر در این نوع اندازه گیری نسبت دو مقدار بستگی به واحد اندازه گیری ندارد.

داده

اطلاعاتی که از مطالعه يك متغیر به دست می‌آیند، معمولاً شامل انبوهی عدد یا علامت می‌باشند که آنها را داده می‌نامیم. داده‌ها را نسبت به نوع تغییری که اندازه‌گیری می‌کنیم به دو دسته داده گسسته و داده‌های پیوسته تقسیم می‌کنیم.

معمولاً به داده‌های جمع‌آوری شده که انبوهی عدد است و هیچ نوع پردازشی روی آنها انجام نشده است داده خام می‌گویند.

داده خام



مواردی که در ارتباط با يك مجموعه از داده‌های می‌بایستی مد نظر قرار داد، عبارت‌اند از:

= خلاصه کردن و توضیح داده‌ها به وسیله تنظیم جداول و رسم نمودارها.
= محاسبه مقادیر عددی، برای دست یافتن به معیارهایی که تمرکز و یا پراکندگی داده‌ها را نشان دهد.

در آمار، برای اینکه از داده‌های خام و واقعیتهای موجود را استخراج کنیم، آنها را به نحوی مناسب دسته‌بندی کرده و جدولهایی به نام جدولهای آماری تهیه می‌نماییم. متداولترین جدول در آمار، جدول فراوانی است.

پیش از آنکه نحوه تنظیم جدول فراوانی را بیان نماییم، اطلاع از اصطلاحات زیر ضروری است.

جدول های آماری

Ph.D. Student Vahid Hajimirza

فراواني

هرگاه n داده y_1, y_2, \dots, y_n از k نوع x_1, x_2, \dots, x_k ، با فرض $2 \leq k \leq n$ ،
به ترتیب با تعدادهاي f_1, f_2, \dots, f_k تشکیل شده باشند، آنگاه f_i را فراواني x_i ،
مي گوييم. به عبارت ديگر تعداد دفعاتي را که x_i در داده هاي y_1, y_2, \dots, y_n
تکرار مي شود، فراواني x_i مي ناميم و آن را با نماد f_i نمايش مي دهيم.

به خاطر داشته باشيد که

اگر اندازه نمونه برابر n باشد، آنگاه براي $j = 1, \dots, k$

$$\sum_{i=1}^k f_i = n$$

$$1 \leq f_i \leq n$$

مثال:

داده‌های زیر میزان تصادف منجر به مرگ رد ۳۰ منطقه را نشان می‌دهد. فراوانی داده‌ها را تعیین نمایید.

۸ ۶ ۵ ۵ ۳ ۴ ۳ ۶ ۶ ۷
۳ ۵ ۵ ۸ ۵ ۷ ۴ ۸ ۴ ۳
۲ ۸ ۷ ۶ ۵ ۶ ۶ ۵ ۵ ۶

فراوانی

مشاهده می‌شود که داده‌های تکرار اعداد ۲، ۳، ۴، ۵، ۶، ۷، ۸ می‌باشند، بنابراین جدول زیر را برای فراوانی داده‌ها خواهیم داشت:

x_i	f_i
۲	۱
۳	۴
۴	۳
۵	۸
۶	۷
۷	۳

نسبت فراوانی به اندازه نمونه را فراوانی نسبی می‌نامیم. اگر فراوانی x_i در یک نمونه با اندازه n ، برابر f_i باشد، آنگاه فراوانی نسبی x_i را با نماد r_i نمایش خواهیم داد، به طوری که:

$$r_i = \frac{f_i}{n}$$

فراوانی نسبی

به خاطر داشته باشید که

برای $j = 1, \dots, k$

$$\sum_{i=1}^k r_i = n$$

$$0 \leq r_i \leq 1$$

فراواني نسبي

x_i	f_i	r_i
۲	۱	۰/۰۳۳
۳	۴	۰/۱۳۳
۴	۳	۰/۱۰۰
۵	۸	۰/۲۶۷
۶	۷	۰/۲۳۳
۷	۳	۰/۱۰۰
۸	۴	۰/۱۳۳

$$\frac{1}{30} = 0.033$$

$$\frac{4}{30} = 0.133$$

با توجه به تعریف فراوانی، فراوانی تجمعی ردیف i را با نماد F_i نمایش می‌دهیم و به صورت زیر تعریف می‌کنیم:

$$F_i = \sum_{j=1}^i f_j$$

فراوانی تجمعی

به خاطر داشته باشید که

برای اندازه نمونه n و $i = 1, \dots, k$ آنگاه

$$f_i = F_1 \leq F_1 \leq \dots \leq F_k = n$$

فراواني تجمعي

x_i	f_i	F_i
۲	۱	۱
۳	۴	۵
۴	۳	۸
۵	۸	۱۶
۶	۷	۲۳
۷	۳	۲۶
۸	۴	۳۰

$$1 + 4 = 5$$

$$1 + 4 + 3 + 8 + 7 = 23$$

با توجه به تعریف فراوانی نسبی، فراوانی نسبی جمع‌ی ردیف i را با نماد R_i نماد نمایش می‌دهیم و به صورت زیر تعریف می‌کنیم:

$$R_i = \sum_{j=1}^i r_j$$

فراوانی نسبی جمع‌ی

به خاطر داشته باشید که

برای اندازه نمونه n و $i = 1, \dots, k$ آنگاه

$$r_i R_1 \leq R_2 \leq \dots \leq R_k = 1$$

فراواني نسبي مجموعي

x_i	r_i	R_i
۲	$\frac{1}{30}$	$\frac{1}{30}$
۳	$\frac{4}{30}$	$\frac{5}{30}$
۴	$\frac{3}{30}$	$\frac{8}{30}$
۵	$\frac{8}{30}$	$\frac{16}{30}$
۶	$\frac{7}{30}$	$\frac{23}{30}$
۷	$\frac{3}{30}$	$\frac{26}{30}$
۸	$\frac{4}{30}$	$\frac{30}{30}$

$$\frac{1}{30} + \frac{4}{30} + \frac{3}{30}$$

مثال:

معدل ۵۰ دانشجوی دانشگاه با تقریب تا یک رقم اعشار، به شرح زیر است:

۱,۷	۱,۷	۱,۶	۲,۰	۲,۲	۱,۹	۱,۴	۱,۸	۱,۴	۲,۱
۱,۶	۲,۱	۱,۸	۲,۴	۱,۸	۲,۳	۱,۴	۲,۰	۱,۶	۲,۴
۱,۹	۱,۷	۲,۰	۲,۵	۱,۵	۲,۹	۱,۸	۲,۲	۱,۹	۲,۶
۲,۱	۲,۶	۱,۸	۲,۲	۲,۵	۱,۹	۲,۵	۲,۹	۲,۳	۲,۹
۲,۲	۲,۰	۲,۳	۱,۹	۱,۹	۲,۴	۲,۰	۱,۸	۲,۲	۲,۱

تشکیل جدول فراوانی
برای
داده های پیوسته

کمترین عدد ۱,۴ است و بیشترین عدد ۲,۹

چون داده‌ها تا یک رقم اعشار گرد شده‌اند، بنابراین می‌توان گفت که اندازه واقعی معدلها در

$$U = MAX + 0.5 \times 10^{-r}$$

فاصله $[1/35, 2/95]$

$$L = MIN - 0.5 \times 10^{-r}$$

تعداد ارقام گرد شده

$$W = \frac{U - L}{c} = \frac{2.95 - 1.35}{8} = 0.2$$

تعداد طبقات

R_i	F_i	r_i	f_i	x_i	کلاس
۰,۰۸	۴	۰,۰۸	۴	۱,۴۵	۱,۳۵-۱,۵۵
۰,۲۰	۱۰	۰,۱۲	۶	۱,۶۵	۱,۵۵-۱,۷۵
۰,۴۴	۲۲	۰,۲۴	۱۲	۱,۸۵	۱,۷۵-۱,۹۵
۰,۶۲	۳۱	۰,۱۸	۹	۲,۰۵	۱,۹۵-۲,۱۵
۰,۷۸	۳۹	۰,۱۶	۸	۲,۲۵	۲,۱۵-۲,۳۵
۰,۹۰	۴۵	۰,۱۲	۶	۲,۴۵	۲,۳۵-۲,۵۵
۰,۹۴	۴۷	۰,۰۴	۲	۲,۶۵	۲,۵۵-۲,۷۵
۱,۰۰	۵۰	۰,۰۶	۳	۲,۸۵	۲,۷۵-۲,۹۵
-	-	۱,۰۰	۵۰		جمع

نمودار های به صورت زیر دسته بندی می شوند

۱. گسسته

۱. میله ای

۲. دایره ای

۲. پیوسته

۱. هیستوگرام

۲. چندبر فراوانی

۳. چندبر فراوانی تجمعی

۴. منحنیهای فراوانی و فراوانی تجمعی

۵. نمایش نمودار تنه و شاخه

۶. نمودار جعبه ای

نمودارهاي آماری


Ph.D. Student Vahid Hajimirza

معمولا داده‌ها را با نمودارهای مختلف نمایش می‌دهند. عموماً این نمودارها در ارتباط با داده‌های پیوسته به کار گرفته می‌شود و منظور از نمایش آنها، **تجسم عینی اطلاعات نهفته در داده‌ها است.** در این بخش به معرفی چند نمودار معروف اکتفا می‌کنیم:

- هیستوگرام
- چندبر فراوانی
- چندبر فراوانی تجمعی
- منحنیهای فراوانی و فراوانی تجمعی
- نمایش نمودار تنه و شاخه
- نمودار جعبه‌ای


نمودار میله ای

در این نمودار محور X ها نمایش دهنده مقادیر داده‌ها و محور Y ها نمایش دهنده فراوانی نسبی می‌باشد. چون فراوانی نسبی داده‌های هر جامعه آماری مقادیر بین صفر و یک را می‌گیرد بنابراین می‌توان چندین نمودار را با یکدیگر مقایسه نمود. شکل نمودار میله‌ای را برای مثال ۱ نمایش می‌دهد.




نمودار دایره ای

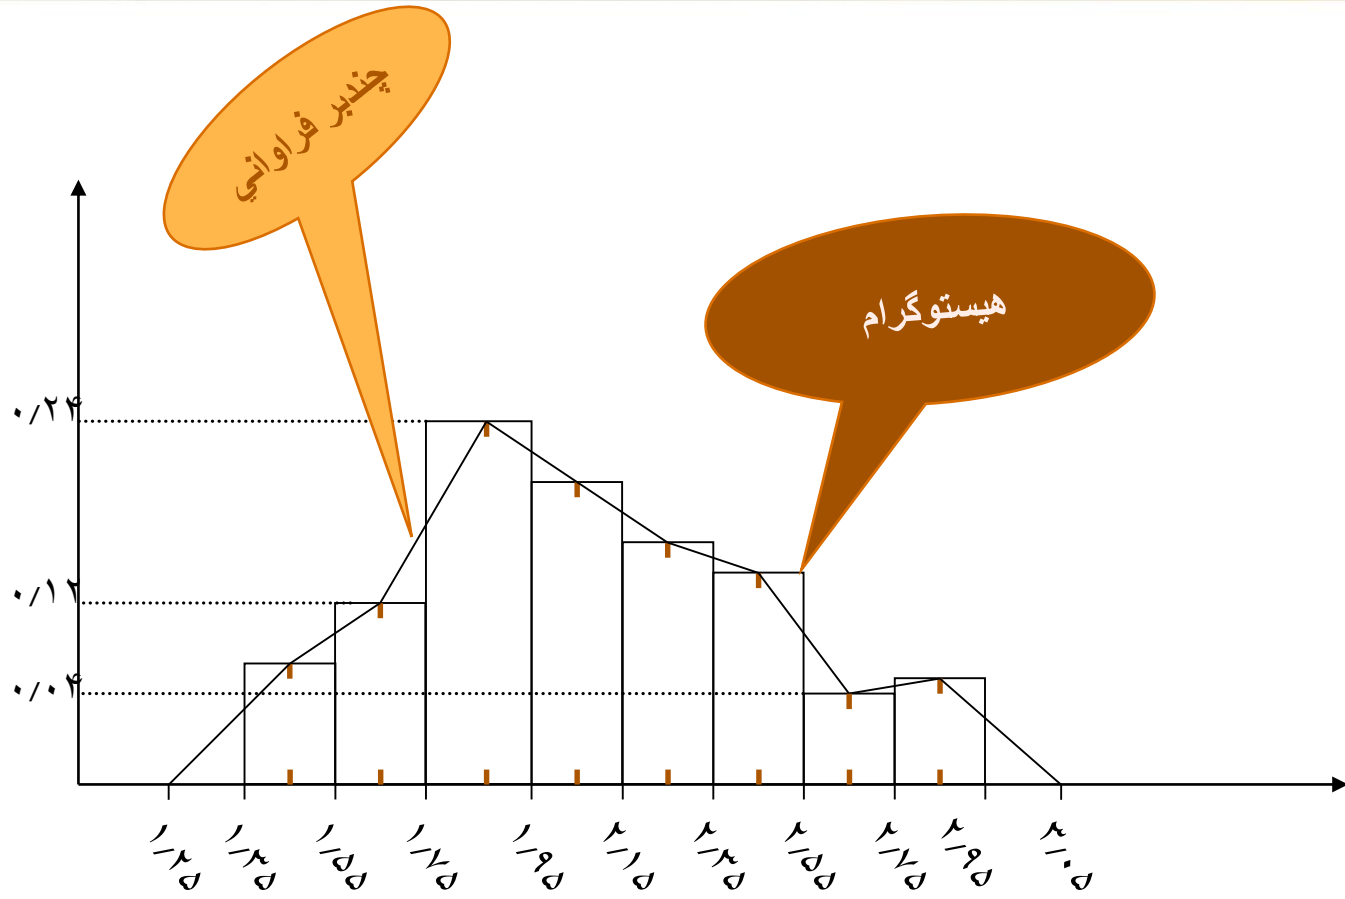
نمودار دایره‌ای: این نمودار درون دایره‌ای رسم می‌شود که به قطاع‌هایی تقسیم شده است و هر قطاع متناسب با مساحت خود معرف یکی از فراوانی‌های نسبی در جدول فراوانی می‌باشد. شکل زیر نمایش دهنده نمودار دایره‌ای برای مثال ۱ می‌باشد.

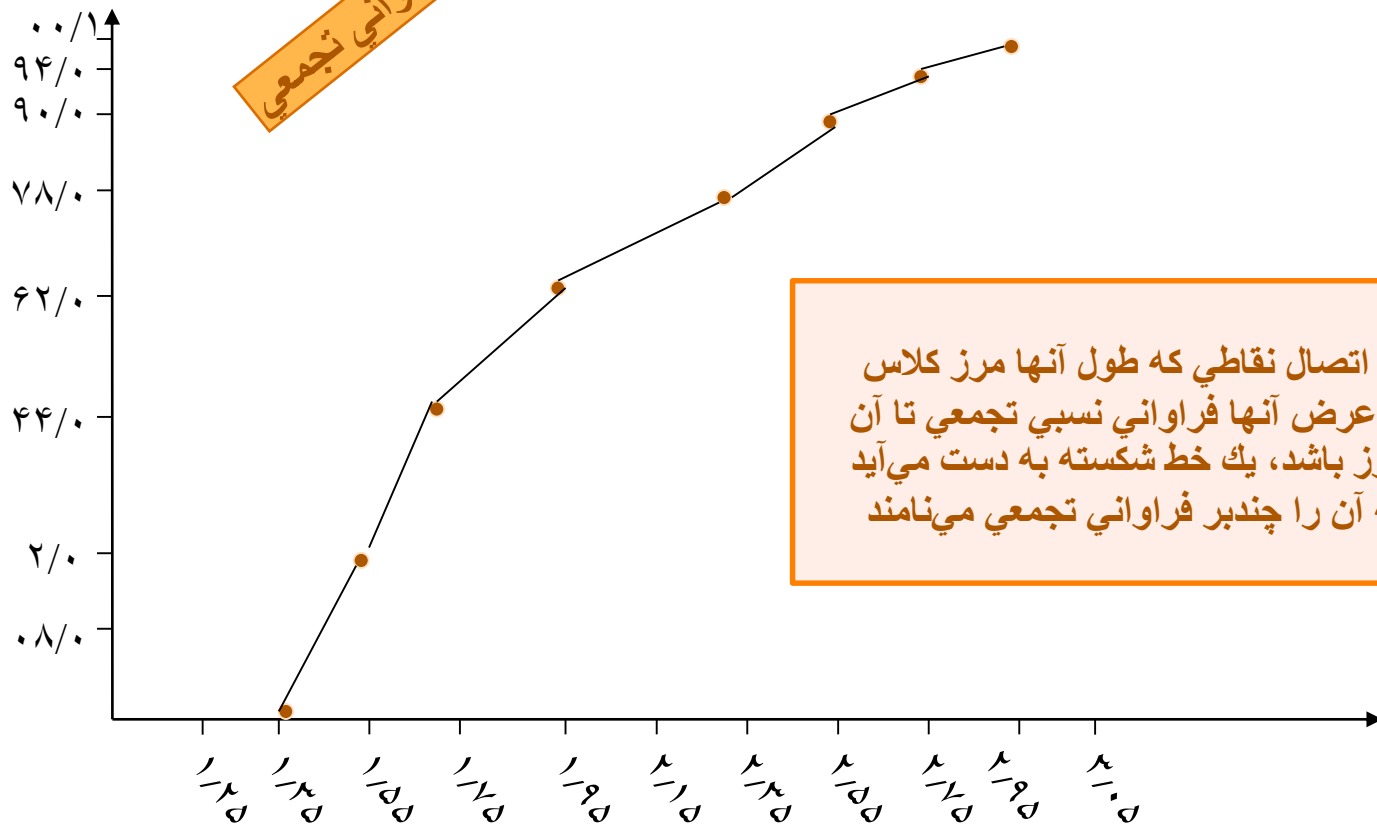


نمایش نمودار تته و شاخه
 منحنی های فراوانی و.....
 چندبر فراوانی، تجمعی
 چندبر فراوانی
 هیستوگرام




Ph.D. Student Vahid Hajimirza






از اتصال نقاطي كه طول آنها مرز كلاس و عرض آنها فراواني نسبي تجمعي تا آن مرز باشد، يك خط شكسته به دست مي آيد كه آن را چندبر فراواني تجمعي مي نامند

منحنی های فراوانی و.....



نمودار منحنی فراوانی

نمودار منحنی فراوانی تجمعی



منظمی های فراوانی و.....

۲ **
۲ ****
۴ ***
۵ ****
۶ ****
۷ ***
۸ ****



فراوانی

۱/۴ ***
۱/۵ *
۱/۶ ***
۱/۷ ***
۱/۸ ****
۱/۹ ****
۲/۰ ****
۲/۱ ****
۲/۲ ****
۲/۳ ***
۲/۴ ***
۲/۵ ***
۲/۶ **
۲/۷
۲/۸
۲/۹ ***



نمرات ۸۰ دانشجو در امتحانات نهایی درس احتمال و آمار به شرح زیر است:

۶۸ ۸۴ ۷۵ ۸۲ ۶۸ ۹۰ ۶۲ ۸۸ ۷۶ ۹۳
 ۷۳ ۷۹ ۸۸ ۷۳ ۶۰ ۹۳ ۷۱ ۵۹ ۸۵ ۷۵
 ۶۱ ۶۵ ۷۵ ۸۷ ۷۴ ۶۲ ۹۵ ۷۸ ۶۳ ۷۲
 ۶۶ ۷۸ ۸۲ ۷۵ ۹۴ ۷۷ ۶۹ ۷۴ ۶۸ ۶۰
 ۹۹ ۷۸ ۸۹ ۶۱ ۷۵ ۹۵ ۶۰ ۷۹ ۸۳ ۷۱
 ۷۹ ۶۲ ۶۷ ۹۷ ۷۸ ۸۵ ۷۶ ۶۵ ۷۱ ۷۵
 ۶۵ ۸۰ ۷۳ ۵۷ ۸۸ ۷۸ ۶۲ ۷۶ ۵۰ ۷۴
 ۸۶ ۶۷ ۷۳ ۸۱ ۷۲ ۶۳ ۷۶ ۷۵ ۸۵ ۷۷

نمایش نمودار تنه و شاخه



نمایش نمودار تنه و شاخه

پس از ساختن نمودار اولیه معمولاً بهتر است مقادیر هر شاخه را از کوچک به بزرگ، با تعداد دفعات تکرار، مرتب کرد، به صورت زیر:

۵	۰ ۷ ۹
۶	۰ ۰ ۰ ۱ ۱ ۲ ۲ ۲ ۲ ۳ ۳ ۵ ۵ ۵ ۶ ۷ ۸ ۸ ۹
۷	۱ ۱ ۱ ۲ ۲ ۳ ۳ ۳ ۳ ۴ ۴ ۴ ۵ ۵ ۵ ۵ ۵ ۵ ۶ ۶ ۶ ۶ ۷ ۷ ۸ ۸ ۸ ۸ ۸ ۹ ۹ ۹
۸	۰ ۱ ۲ ۲ ۳ ۴ ۵ ۵ ۵ ۶ ۷ ۸ ۸ ۸ ۹
۹	۰ ۳ ۳ ۴ ۵ ۵ ۷ ۹

معیارهای مرکزی

Ph.D. Student Vahid Hajimirza

با استفاده از جدول فراوانی و رسم نمودارها می‌توانیم داده‌ها را به نحو مطلوبی **تنظیم کرده و اطلاعات نهفته را تا حدودی مشخص کنیم**. با این حال برای آرایه یک گزارش مناسب، بهتر است آنها را در یک یا چند عدد مناسب نیز خلاصه کنیم. چنین عددی می‌تواند معیار مرکزی باشد. مهمترین معیارهای مرکزی **میانگین، میانه و نما** است که در بخش این به شرح هر یک از آنها خواهیم پرداخت.

هرگاه n داده y_1, y_2, \dots, y_n از k نوع x_1, x_2, \dots, x_k ، با فرض $2 \leq k \leq n$ ، به ترتیب با تعدادهای f_1, f_2, \dots, f_k تشکیل شده باشند، آنگاه f_i را فراوانی x_i می‌گوییم.

میانگین

$\bar{x} = \frac{1}{n} \sum_{i=1}^n f_i x_i$	میانگین حسابی
$\bar{x}_w = \frac{\sum_{i=1}^k w_i x_i}{\sum_{i=1}^k w_i}$	میانگین وزنی
$G = \left(\prod_{i=1}^k x_i^{f_i} \right)^{\frac{1}{n}}$ کلیه داده‌ها بزرگتر از صفر باشند	میانگین هندسی

اگر داده‌ها را از كوچك به بزرگ مرتب نماييم، عدد m را ميانه اين داده‌ها مي‌ناميم، اگر نصف داده‌ها در سمت چپ و نصف داده در سمت راست اين عدد قرار گيرد و گاه با m_e يا m_d نشان مي‌دهند

ميانه

محاسبه ميانه براي داده‌هاي گسسته

فرض كنيد y_1, y_2, \dots, y_n داده‌هاي ما باشند و شكل مرتب شده آنها را با $y_{(1)}, y_{(2)}, \dots, y_{(n)}$

نمايش دهيم آنگاه

$$M = \begin{cases} y_{\left(\frac{n+1}{2}\right)} & \text{اگر } n \text{ فرد باشد} \\ \frac{1}{2} \left[y_{\left(\frac{n}{2}\right)} + y_{\left(\frac{n}{2}+1\right)} \right] & \text{اگر } n \text{ زوج باشد} \end{cases}$$

مثال میانه داده های گسسته

مثال ۱: ۳، ۱۲، ۲، ۱، ۵

شکل صعودی: ۱، ۲، ۳، ۵، ۱۲

$$md = \frac{n}{2} + \frac{1}{2} = \frac{5}{2} + \frac{1}{2} = 3$$

مثال میانه داده های گسسته

مثال ۲: ۵، ۱، ۲، ۱۲، ۳، ۶

شکل صعودی: ۲، ۳، ۵، ۶، ۱۲

$$me = \frac{1}{2} * (6/2 + (6/2 + 2/2)) = 3.5$$

میانگانه

محاسبه میانگانه برای داده‌های پیوسته

کلاس	x_i	f_i	F_i
۱/۳۵-۱/۵۵	۴۵/۱	۴	۴
۱/۵۵-۱/۷۵	۶۵/۱	۶	۱۰
۱/۷۵-۱/۹۵	۸۵/۱	۱۲	۲۲
۱/۹۵-۲/۱۵	۰۵/۲	۹	۳۱
۲/۱۵-۲/۳۵	۲۵/۲	۸	۳۹
۲/۳۵-۲/۵۵	۲/۴۵	۶	۴۵
۲/۵۵-۲/۷۵	۶۵/۲	۲	۴۷
۲/۷۵-۲/۹۵	۸۵/۲	۳	۵۰
جمع		۵۰	—

$n/2 = 25$

$$m = L_m + \frac{\frac{n}{2} - F_i}{f_i} * w$$

- L_m کران پایین
- n تعداد کل
- F_i فراوانی تجمعی رده قبل
- f_i فراوانی همان رده
- w طول رده

طول هر رده

$M = 1.95 + ((25 - 22) / 9) * 0.2$
 $M = 2.02$

چندک یک معیار کلی تر از میانه است و در عنوان حالت خاص میانه را نیز در بر می گیرد. اگر p یک عدد حقیقی بین صفر و یک باشد، آنگاه عدد Q_p را چندک مرتبه p می نامیم هر گاه $p \cdot 100\%$ داده ها سمت چپ و $(1-p) \cdot 100\%$ داده ها سمت راست Q_p باشند.

چندکهای معروف عبارتند از :

چارکها اگر جامعه آماری به چهار قسمت مساوی تقسیم شود ، به هر یک از قسمت ها یک چارک گفته می شود و آنها را با Q نشان می دهند

چارکها به ازای $p = 0,25, 0,5, 0,75$ به دست می آیند و آنها را به ترتیب با نماد Q_1 (چارک اول)، Q_2 (چارک دوم) و Q_3 (چارک سوم) نشان می دهند.

دهکها

دهکها به ازای $p = 1/10, 2/10, \dots, 9/10$ به دست می آیند و آنها را به ترتیب با نماد D_1 (دهک اول)، D_2 (دهک دوم)، و D_9 (دهک نهم) نشان می دهند.

صدکها

صدکها به ازای $p = 0.01, 0.02, 0.03$ به دست می آیند و آنها را به ترتیب با نماد P_1 (صدک اول)، P_2 (صدک دوم)، و P_{99} (صدک نود و نهم) نشان می دهند.

چندکها

Q_1 : مقداری که ۲۵٪ مشاهدات ، پایین تر از آن است

Q_2 : مقداری که ۵۰٪ مشاهدات ، پایین تر از آن است

Q_3 : مقداری که ۷۵٪ مشاهدات ، پایین تر از آن است

نحوه بدست آوردن چهارک :

برای بدست آوردن چارک ها نظیر میانه عمل می کنیم یعنی ابتدا اعداد را به صورت صعودی نوشته و سپس به کمک فرمول زیر محل چارک و نهایتا خود چارک پیدا می شود.

$$CQ_a = \frac{aN}{4} + \frac{1}{2}$$

چارک مورد نظر ۱ و ۲ و ۳ = a

N = تعداد مشاهدات

چندکها

محاسبه چندک برای داده‌های گسسته

فرض کنید y_1, y_2, \dots, y_n داده‌های ما باشند و شکل مرتب شده آنها را با $y_{(1)}, y_{(2)}, \dots, y_{(n)}$ نمایش دهیم. برای محاسبه چندک

$$(n+1)p \begin{cases} \text{صحیح باشد} & r = (n+1)p, \quad Q_p = y_{(r)} \\ \text{صحیح نباشد} & r = [(n+1)p], \quad \omega = (n+1)p - r \rightarrow Q_p = (1-\omega)y_{(r)} + \omega y_{(r+1)} \end{cases}$$

محاسبه چندك براي داده‌هاي پيوسته

چندكها

كلاس	x_i	f_i	F_i
۱/۳۵-۱/۵۵	۴۵/۱	۴	۴
۱/۵۵-۱/۷۵	۶۵/۱	۶	۱۰
۱/۷۵-۱/۹۵	۸۵/۱	۱۲	۲۲
۱/۹۵-۲/۱۵	۰۵/۲	۹	۳۱
۲/۱۵-۲/۳۵	۲۵/۲	۸	۳۹
۲/۳۵-۲/۵۵	۲/۴۵	۶	۴۵
۲/۵۵-۲/۷۵	۶۵/۲	۲	۴۷
۲/۷۵-۲/۹۵	۸۵/۲	۳	۵۰
جمع		۵۰	—

با توجه به ستون فراواني جمعي در جدول فراواني،
كلاسي را كه چندك در آن قرار دارد مشخص
مي‌كنيم.

(p) (n)

$$0.25 \times 50 = 12.5$$

$$Q_p = L_{Q_p} + \left(\frac{np - F_b}{f_{Q_p}} \right) w$$

$$Q_p = 1.75 + \left(\frac{50 \times 0.25 - 10}{12} \right) \times 0.2$$

داده‌ای که فراوانی آن نسبت به دیگر داده‌ها بیشتر باشد، نما یا مد نامیده می‌شود و آن را با نماد M نمایش می‌دهیم. برای به دست آوردن نما، نخست فراوانی داده‌ها را پیدا می‌کنیم و داده‌ای را که فراوانی آن بیشتر باشد، به عنوان نما اختیار می‌کنیم و اگر دو داده، دارای فراوانی یکسان و بیش از دیگر فراوانی‌ها باشند، هر دو را به عنوان نما اختیار می‌کنیم و داده‌ها را دو نمایی می‌گوییم، به شرط آن که این دو داده در یک صف غیر نزولی، کنار هم نباشند. در صورتی که این دو داده در یک صف غیر نزولی، کنار هم باشند نصف مجموع آنها را به عنوان نما اختیار می‌کنیم. اگر تمام داده دارای فراوانی یکسان باشند، می‌گوییم داده‌ها بدون نما هستند. به یاد داشته باشید که نما، به عنوان یک معیار تمرکز در داده‌های گروهی به کار گرفته می‌شود.

مثال: برای داده‌های ۲، ۲، ۵، ۷، ۹، ۹، ۹، ۱۰، ۱۰، ۱۱، ۱۲ و ۱۸ نما برابر $M=9$ است، زیرا فراوانی داده ۹ بیش از فراوانی دیگر داده‌ها است.

مثال: برای داده‌ها ۲، ۳، ۴، ۴، ۴، ۵، ۵، ۷، ۷ و ۹، دو داده ۴ و ۷ به عنوان نما اختیار می‌شوند، زیرا فراوانی این دو داده، بیش از فراوانی داده‌های دیگر است.

مثال: برای داده‌های ۳، ۵، ۸، ۱۰، ۱۲، ۱۵ و ۱۶، نما وجود ندارد، زیرا تمام داده‌ها دارای فراوانی یکسان هستند.

مثال: برای داده‌ها ۲، ۳، ۴، ۴، ۴، ۵، ۵، ۵، ۷ و ۹ دو داده ۴ و ۵ را که دارای بیشترین فراوانی هستند به عنوان نما بر می‌گزینیم، اما از آنجا که این دو داده در یک صف غیر نزولی در کنار یکدیگر قرار دادند، نصف مجموع دو داده به عنوان نما اختیار می‌شود، یعنی $M=4.5$.

محاسبه تما برای داده‌های پیوسته

نما

کلاس	x_i	f_i	r_i
۱,۳۵-۱,۵۵	۴۵/۱	۴	۰,۸/۰
۱,۵۵-۱,۷۵	۶۵/۱	۶	۱۲/۰
۱,۷۵-۱,۹۵	۸۵/۱	۱۲	۲۴/۰
۱,۹۵-۲,۱۵	۰,۵/۲	۹	۱۸/۰
۲,۱۵-۲,۳۵	۲۵/۲	۸	۱۶/۰
۲,۳۵-۲,۵۵	۲/۴۵	۶	۱۲/۰
۲,۵۵-۲,۷۵	۶۵/۲	۲	۰,۴/۰
۲,۷۵-۲,۹۵	۸۵/۲	۳	۰,۶/۰
جمع		۵۰	۰,۰/۱

از روی جدول ملاحظه می‌شود که فراوانی رده ۱.۷۵-۱.۹۵ دارای بیشترین فراوانی است بنابراین به عنوان رده نما در نظر می‌گیریم.

$$M = L_M + \frac{d_1}{d_1 + d_2} \times \omega$$



$$M = 1.75 + \frac{0.12}{0.12 + 0.06} \times 0.2 = 1.9$$

با وجود این که در بسیاری از موارد، میانگین توصیف نسبتاً کاملی از مجموعه داده‌ها ارائه می‌دهد، اما گاهی وجود اطلاعات بیشتر در مورد داده‌ها ضروری است. یک مفهوم مهم در ارتباط با داده‌های آماری، میزان تغییرات آنهاست، بدین معنی که اندازه‌گیریها تا چه اندازه از فردی به فرد دیگر یا شیئی به شیئی دیگر تغییر می‌کنند. در این بخش، به بررسی و محاسبه میزان تغییرات به عنوان معیارهای پراکندگی خواهیم پرداخت. مهمترین معیارهای پراکندگی عبارتند از **دامنه، میانگین انحراف ها از میانگین یا از میانه، میان دامنه چارکها، دامنه صدکی، واریانس و انحراف معیار است. علاوه بر مطالب فوق، در این بخش داده‌های استاندارد و ضریب تغییرات را نیز معرفی خواهیم کرد.**

واریانس

در این شاخص پراکندگی ، از مجذور (توان ۲) انحرافات استفاده می شود
فرمول

$$\delta_x^2 = \frac{\sum (X_i - \mu_x)^2}{N}$$

مثال

X_i	$X_i - \mu$
1	-2
2	-1
6	3
9 جمع	0

$$\delta_X^2 = \frac{\sum (X_i - \mu_x)^2}{N}$$

$$\mu = \frac{9}{3} = 3$$

$$\delta_X^2 = \frac{4 + 1 + 9}{3} = \frac{14}{3}$$

خواص واریانس

۱- اگر تمام مشاهدات با عدد ثابت b جمع شوند ، واریانس جدید تغییر نمی کند

۲- اگر تمام مشاهدات ، به عدد ثابت b ضرب شوند ، واریانس جدید b^2 برابر افزایش می یابد

انحراف معیار

این شاخص به منظور برطرف کردن عیوب شاخص
واریانس و افزایش دادن تأثیر این انحراف توسط

$$\delta_x^2$$

فرمول انحراف معیار

$$\delta_x = \sqrt{\delta_x^2}$$

و یا

$$\delta_x = \sqrt{\frac{\sum (X_i - \mu_x)^2}{N}}$$

معیارهای پراکندگی

Ph.D. Student Vahid Hajimirza

ضریب پراکندگی

ضریب پراکندگی یکی از معیارهای پراکندگی نسبی است که با فرمول زیر بیان می شود

$$C.V = \frac{\delta_X}{\mu_X}$$

δ_X = انحراف معیار مشاهدات

μ_X = میانگین مشاهدات

کاربردهای ضریب پراکندگی

برای مقایسه دو جامعه در مواردی که :

- ۱- مقیاس ها یکسان نیستند
- ۲- مقیاس یکسان ولی تفاوت زیادی در بزرگی مشاهدات وجود دارد
- ۳- واریانسهای جوامع یکسان ولی میانگین هایشان متفاوت است

سری اعداد طبقه بندی شده معیارهای مرکزی میانگین

این فرمول برای داده های طبقه بندی شده به شرح ذیل است:

$$\mu_x \cong \frac{\sum F_i X_i}{N}$$

F_i = فراوانی مطلق

X_i = متوسط طبقات

N = کل مشاهدات

مثال

C_i	F_i	X_i	$F_i X_i$
30-50	8	40	320
50-70	15	60	900
70-90	25	80	2000
90-110	8	100	800
110-130	4	120	480
جمع	60		4500

$$\mu_x \cong \frac{\sum F_i X_i}{N}$$

$$\mu_x \cong \frac{4500}{60} = 75$$

اگرچه دامنه يك وسیله ساده برای اندازه‌گیری اختلاف و پراکندگی در يك سری از داده‌ها است، اما در بیشتر موارد رضایتبخش نیست. داده‌های بسیار بزرگ یا بسیار کوچک مانع از آن هستند که دامنه، معرف واقعی میزان انحراف باشد. در چنین مواردی، واریانس يك معیار مورد قبول همگان به شمار می‌رود.

با توجه به اینکه در محاسبه واریانس داده‌ها را مربع می‌کنیم، بدین جهت ریشه دوم مثبت آن را که انحراف معیار یا انحراف استاندارد می‌نامیم، به عنوان يك معیار پراکندگی بر مبنای مقیاس اندازه‌گیری به کار می‌بریم.

ضریب تغییر عبارت است از اندازه نسبی انحراف معیار در مقایسه با میانگین. ضریب همبستگی به واحد اندازه‌گیری وابسته نیست و برای مقایسه جمعیت‌های یکسان به کار می‌رود. در مقایسه هر اندازه که ضریب تغییر ویژگی جمعیتی کمتر باشد، ویژگی آن جمعیت بهتر ارزیابی می‌شود.

$R = y_{(n)} - y_{(1)}$	$y_{(1)}$ کوچکترین و $y_{(n)}$ بزرگترین داده هستند	دامنه
$MD_{\bar{x}} = \frac{1}{n} \sum_{i=1}^k f_i x_i - \bar{x} $		میانگین انحرافها از میانگین
$MD_m = \sum_{i=1}^k f_i x_i - m $		میانگین انحرافها از میانه
$IQR = Q_3 - Q_1$		دامنه چارکي
$IPR = P_{90} - P_{10}$		دامنه صدکي
$s^2 = \frac{1}{n} \sum_{i=1}^k f_i (x_i - \bar{x})^2 = \frac{1}{n} \sum_{i=1}^k f_i x_i^2 - \bar{x}^2$		واریانس داده‌ها
$s = \sqrt{\frac{1}{n} \sum_{i=1}^k f_i (x_i - \bar{x})^2}$		انحراف معیار
$v = \frac{s}{x}$	Ph.D. Student Vahid Hajimirza	ضریب تغییرات

اگر y_1, y_2, \dots, y_n نمایانگر داده‌های خام باشند، بر اساس جدول فراوانی f_1 برابر x_1 و f_2 برابر x_2 تا f_k ها برابر x_k .

می‌دانیم که \bar{x} و S به ترتیب میانگین و انحراف معیار داده است. اگر از هر داده \bar{x} را کم و بر S تقسیم کنیم، یعنی

داده‌های استاندارد

$$z_i = \frac{x_i - \bar{x}}{S}, \quad i=1, \dots, k$$

آنگاه z_1, z_2, \dots, z_k با فراوانی‌های به ترتیب f_1, f_2, \dots, f_k را داده‌های استاندارد می‌نامیم. به سادگی می‌توان نشان داد که داده‌های استاندارد دارای میانگین برابر با صفر و واریانس برابر با یک هستند و به واحد اندازه‌گیری بستگی ندارند.

معیارهای پراکندگی

فرض کنید یک دسته از دانشجویان در دو امتحان شرکت کرده‌اند و خلاصه نتایج آزمونها به شرح زیر است.

آزمون اول: میانگین نمرات برابر ۶۰، انحراف معیار برابر ۶، ماکزیمم نمره از ۱۰۰

آزمون دوم: میانگین نمرات ۷۰۰، انحراف معیار برابر ۷، ماکزیمم نمره از ۱۰۰۰

الف- چگونه این دو نتیجه را با هم مقیسه و ارزیابی می‌کنید؟

ب- اگر دانشجویی در آزمون اول نمره ۶۵ و در آزمون دوم نمره ۷۲۰ را کسب کرده باشد، وضعیت دانشجوی در کدام آزمون مطلوبتر است؟

حل: الف) با محاسبه ضریب تغییر دو آزمون معلوم می‌شود که

$$v_1 = \frac{s_1}{x_1} = \frac{6}{60} = \frac{1}{10} = 10\%$$

$$v_2 = \frac{s_1}{x_2} = \frac{7}{700} = \frac{1}{100} = 1\%$$

چون $v_1 > v_2$ ، بنابراین نتیجه می‌گیریم که دانشجویان در امتحان دوم نمرات مطلوبتری را کسب کرده‌اند.

(ب) برای مقایسه، ابتدا نمرات دانشجو را استاندارد می‌کنیم

$$z_1 = \frac{65 - 60}{6} = \frac{5}{6}, \quad z_2 = \frac{720 - 700}{7} = \frac{20}{7}$$


چون $z_1 < z_2$ ، بنابراین نمره آزمون دوم دانشجو در مقایسه از موقعیت بهتری برخوردار است.

منحنی های فراوانی


Ph.D. Student Vahid Hajimirza

منحني هاي فراواني در طبيعت تنوع زيادي دارند، اما بسياري از منحنيهاي فراواني تك نمايي يا متقارن هستند يا چوله و يا برجسته و يا پخ. ايده آل ترين منحني فراواني متقارن، منحني فراواني نرمال استاندارد است. براي منحنيهاي فراواني كاملا متقارن تك نمايي مقادير ميانگين، ميانه و نما بر هم منطبق مي شوند. در طبيعت، عموما منحني فراواني متقارن ايده آل كمتر يافت مي شود و بسياري از منحنيهاي فراواني موجود در طبيعت نامتقارن برجسته يا پخ هستند. ميزان انحراف از تقارن ايده آل را معمولا با دو معيار چولگي و برجستگي مي سنجند.


پخ




نامتقارن / چوله به چپ




نامتقارن / چوله به راست




برجسته




منحنی نرمال استاندارد





$$M < m < \bar{x}$$

به راست یا مثبت



$$M > m > \bar{x}$$

به چپ یا منفي

چولگي:

معیار اندازه گیری چولگی:

$$\text{ضریب چولگی اول پیرسن} = \frac{\bar{x} - M}{s}$$

میزان کشیدگی یا پخی منحنی فراوانی را نسبت به منحنی نرمال استاندارد، برجستگی منحنی فراوانی می نامیم. فرمول زیر را می توان به عنوان معیار برجستگی به کار برد.

$$\text{ضریب برجستگی} = k = \frac{(Q_3 - Q_1) / 2}{P_{90} - P_{10}}$$

نشان داده شده است که برای منحنی فراوانی نرمال استاندارد $k=0.263$ ، بنابراین معمولا ضریب برجستگی را به صورت زیر تعریف می کنند:

$$\text{ضریب برجستگی} = k = \frac{(Q_3 - Q_1) / 2}{P_{90} - P_{10}} - 0.263$$

برحسب آن که این مقدار مثبت یا منفی باشد گوییم منحنی فراوانی برجسته یا پخ است.