

به نام خداوند بخشنده مهربان

روش‌های آماری و اقتصادسنجی

در تحلیل و مدل‌سازی داده‌های حمل و نقلی

محمد مهدی بشارتی

besharati@iut.ac.ir

توزیع های نمونه ای

فصل
پنجم

Sampling distributions

مقدمه

بخش اول: مفاهیم کلی

بخش دوم: توزیع های نمونه ای



سوال: تفاوت احتمال با آمار در چیست؟

در احتمال،

➤ توزیع پارامتر جامعه «معلوم» است

➤ هدف: محاسبه احتمال مشاهده یک رویداد خاص

در آمار،

➤ مشخصات یا توزیع پارامترهای جامعه (اغلب) «نامعلوم» است

➤ هدف: ارائه یک برآورد از پارامتر مجهول جامعه براساس داده‌های نمونه

در این فصل و فصول آینده، یاد می‌گیریم که چطور از منطق‌های احتمالاتی برای ارائه برآورد در مورد پارامترهای جامعه استفاده می‌شود.



□ یک مثال از احتمال:

➤ اگر بدانیم تعداد تصادفات در یک بازه زمانی معین از یک توزیع پواسون با پارامتر (λ) ، پیروی می کند، آنگاه می توان احتمال مشاهده X_0 تصادف در یک بازه زمانی دلخواه را بدست آورد.

□ یک مثال از آمار:

➤ داده های «سرعت تردد خودروها» در یک قطعه بزرگراهی را با نمونه گیری جمع آوری کرده باشیم و بخواهیم به کمک آن، «**میانگین واقعی** سرعت تردد خودروها» در آن قطعه (یعنی یک مشخص از جامعه) را برآورد کنیم.

از آنجا که مقادیر «سرعت تردد خودروها» در نمونه، یک **متغیر تصادفی** است؛ بنابراین می بایست از **گزاره های احتمالاتی** برای استنباط در مورد میانگین سرعت ها استفاده کنیم.

توزیع های نمونه ای

فصل
پنجم

Sampling distributions

مقدمه

بخش اول: مفاهیم کلی

بخش دوم: توزیع های نمونه ای



نمونه. هر زیرمجموعه از جامعه، یک نمونه نامیده می شود.

مثلا اگر جامعه را بصورت "زمان سفر وسایل نقلیه در کمان A" در نظر بگیریم. در صورتیکه چند خودرو شناور را از این کمان عبور داده و زمان سفر آنها را ثبت نماییم؛ آنگاه یک نمونه چندتایی از زمان سفر در این کمان را خواهیم داشت.

پارامتر. مشخصه مجهول جامعه که قرار است در مورد آن استنباطی انجام شود.

مثلا اگر جامعه را بصورت "زمان سفر خودروها در کمان A" در نظر بگیریم؛ آنگاه، یکی از پارامترهای جامعه می تواند «**میانگین زمان سفر (μ) خودروهای عبوری از کمان مورد نظر**» باشد.



سوال: اغلب، بدست آوردن مقدار دقیق پارامترهای جامعه ممکن نیست. پس برای شناخت جامعه، چکار باید کرد؟

✓ بجای مقدار دقیق پارامتر جامعه، از **برآورد** پارامتر جامعه استفاده می شود.

برآورد (تخمین) (Estimate). «برآورد»، تخمینی از پارامتر مورد نظر است که به کمک نمونه گیری بدست می آید.

✓ در مثال قبل، میانگین زمان سفر نمونه یک برآورد از میانگین زمان سفر جامعه می باشد.

✓ هر کمیتی که براساس نمونه محاسبه می شود، برآورد نامیده می شود.



تفاوت «نمونه مشاهده شده» و «نمونه تصادفی»

۱- «نمونه مشاهده شده»:

نمونه مشاهده شده فقط شامل اعدادی است که پس از نمونه‌گیری به دست می‌آیند.

۲- «نمونه تصادفی»:

مفهوم نمونه تصادفی به مرحله قبل از نمونه‌گیری مربوط می‌شود؛ و مشخص نیست که چه مقادیری را مشاهده خواهیم کرد.

پس، نمونه تصادفی مجموعه‌ای از n متغیر تصادفی (X_1, X_2, \dots, X_n) است که مستقل از هم بوده و توزیع هر یک از آنها با توزیع X در جامعه آماری، یکسان است.

یعنی هر متغیر نمونه (X_i) دقیقاً همان ویژگی‌های متغیر تصادفی X در جامعه اصلی را دارد.



تفاوت «نمونه مشاهده شده» و «نمونه تصادفی»

در حالت کلی،

برداری از متغیرهای تصادفی (X_1, X_2, \dots, X_n) را داریم که مقادیر آنها با متغیر تصادفی (x_1, x_2, \dots, x_n) نشان داده می‌شود. اکنون، توزیع مشترک یا احتمال مشترک این نمونه تصادفی برابر است با؛

$$P(X_1=x_1, X_2=x_2, \dots, X_n=x_n)$$

این احتمال بیانگر این است که چقدر احتمال دارد در نمونه‌گیری تصادفی، مقادیر x_1, x_2, \dots, x_n مشاهده شود. از آنجا که این متغیرها مستقل از هم هستند، این احتمال برابر است با؛

$$P(X_1=x_1, X_2=x_2, \dots, X_n=x_n) = P(X_1=x_1) P(X_2=x_2) \dots P(X_n=x_n) = \prod_{i=1}^n P(X_i=x_i)$$



آماره یا برآوردگر (تابعی از متغیرهای تصادفی)

از آنجا که X_1, X_2, \dots, X_n متغیرهای تصادفی هستند، هر تابعی از این متغیرها نیز یک متغیر تصادفی است. مثلا میانگین نمونه یک متغیر تصادفی است.

$$\bar{X} = \frac{X_1 + X_2 + \dots + X_n}{n}$$

به هر یک از این توابع، آماره (یا برآوردگر) می‌گویند. مثلا میانگین نمونه تصادفی یک آماره است.

برآورد (تخمین): مقدار به دست آمده از تابع برآوردگر که بعد از نمونه‌گیری به دست می‌آید.



برآوردگر (آماره) (Estimator). هر تابعی که به کمک آن، برآورد انجام می‌گردد؛ برآوردگر نامیده می‌شود.

✓ برای مثال، میانگین نمونه یک برآوردگر برای میانگین جامعه است.

در حقیقت توابعی که برخی از آنها در فصل اول مرور شدند؛ برآوردگر نامیده شده و برای برآورد کردن پارامتر مجهول جامعه (مثلا میانگین جامعه) استفاده می‌شود.

برآورد (تخمین): مقدار به دست آمده از تابع برآوردگر که بعد از نمونه‌گیری به دست می‌آید.



بنابراین،

✓ «پارامتر» یک ویژگی جامعه است،

✓ «آماره (برآوردگر)» یک ویژگی نمونه می باشد. تابعی که بر روی نمونه تعریف می شود.

✓ «برآورد (تخمین)» مقدار به دست آمده از تابع برآوردگر که بعد از نمونه گیری به دست می آید.

نسبت	اندازه	ضریب همبستگی	انحراف معیار	واریانس	میانگین	مشخصه	
\hat{p}	n	r	S	S^2	\bar{X}	آماره (برآوردگر)	نمونه
p	N	ρ	σ	σ^2	μ	پارامتر	جامعه



به طور کلی، **برآورد** به دو صورت انجام می شود:

الف) برآورد نقطه‌ای (Point estimation). برآورد نقطه‌ای به کمک آماره‌ی بدست آمده از نمونه محاسبه می شود.

✓ در برآورد نقطه‌ای، **تنها یک عدد** بعنوان پارامتر جامعه معرفی می شود.

✓ برای مثال اگر در یک نمونه تصادفی از جامعه، میانگین نمونه برابر با ۱۲ مشاهده شود و براین اساس بگوییم که

$\mu = 12$ است؛ در اینجا به کمک آماره میانگین نمونه، یک برآورد نقطه‌ای از پارامتر میانگین جامعه بدست آورده‌ایم.

سوال: نقص اساسی برآورد نقطه‌ای چیست؟

✓ به علت خطای نمونه‌گیری (تصادفی بودن نمونه‌گیری) نمی توان مطمئن شد که آماره مشاهده شده در نمونه، با دقت قابل قبولی همان پارامتر جامعه است.



به طور کلی، **برآورد** به دو صورت انجام می شود:

الف) برآورد نقطه‌ای (Point estimation). برآورد نقطه‌ای به کمک آماره‌ی بدست آمده از نمونه محاسبه می شود.

✓ در برآورد نقطه‌ای، **تنها یک عدد** بعنوان پارامتر جامعه معرفی می شود.

✓ برای مثال اگر در یک نمونه تصادفی از جامعه، میانگین نمونه برابر با ۱۲ مشاهده شود و براین اساس بگوییم که

$\mu = 12$ است؛ در اینجا به کمک آماره میانگین نمونه، یک برآورد نقطه‌ای از پارامتر میانگین جامعه بدست آورده‌ایم.

ب) برآورد فاصله‌ای (Interval estimation).

در برآورد فاصله‌ای، **یک بازه از مقادیر**، بعنوان مقادیر محتمل برای پارامتر جامعه ارائه می شود.

✓ «فاصله اطمینان (Confidence Interval (CI))» یکی از ابزارهای اصلی برای انجام برآورد فاصله‌ای



فاصله اطمینان. یک دامنه از مقادیری است که با یک حد بالا و یک حد پایین و با یک سطح اطمینان مشخص (مثلا ۹۵٪) می توان گفت که پارامتر جامعه در آن بازه قرار می گیرد.

توضیح بیشتر در فصل بعد...





- ✓ پارامتر یک مقدار **ثابت** است؛
- ✓ آماره (برآوردگر)، یک **متغیر تصادفی** بوده (چون تابعی از متغیرهای تصادفی است) و مقدار آن از یک نمونه به نمونه دیگر متفاوت خواهد بود.
- ✓ یک پارامتر ممکن است چند برآوردگر داشته باشد.
- ✓ یعنی برای برآورد یک پارامتر می‌توان برآوردگرهای متعددی را معرفی کرد.
- ✓ مثلاً مقدار **میانگین** یک متغیر تصادفی را می‌توان با **میان**، **میانگین** یا **مد** آن متغیر تصادفی برآورد کرد.

اینجا ۲ سوال مطرح می‌شود؛

- ۱- از میان برآوردگرهای یک پارامتر، کدامیک بهتر (مناسب‌تر) است (یک برآوردگر خوب چه خواصی دارد)؟
- ۲- چه روش‌هایی برای به دست آوردن برآوردگرهایی که دارای خواص مناسبی باشند، وجود دارد؟



۱- از میان برآوردگرهای یک پارامتر، کدامیک بهتر است (یک برآوردگر خوب چه خواصی دارد)؟

یک برآوردگر خوب، چهار ویژگی زیر را داراست:

الف) نااریبی (*Unbiasedness*).

ب) کارایی (*Efficiency*).

ج) سازگاری (*Consistency*).

د) بسندگی (*Sufficiency*).



الف) ناریبی (Unbiasedness). برآوردگر $\hat{\theta}$ را برای θ یک برآوردگر ناریب می‌نامند؛ هرگاه امیدریاضی این برآوردگر، با

$$E(\hat{\theta}) = \theta \quad \text{یا} \quad E(\hat{\theta}) - \theta = 0$$

✓ برای مثال، میانگین نمونه (\bar{X}) یک برآوردگر ناریب برای میانگین (μ) جامعه است. $E(\bar{X}) = \mu$

ناریبی یک برآوردگر یعنی آن برآوردگر «به طور متوسط» به پارامتر موردنظر گرایش دارد.

از طرف دیگر به برآوردگری که با افزایش حجم نمونه، مقدار اریب آن کاهش یافته و به صفر میل می‌کند، «برآوردگر ناریب حدی (مجانبی)» می‌گویند.

✓ برای مثال، واریانس نمونه (S^2) یک برآوردگر ناریب مجانبی برای واریانس جامعه (σ^2) است. $E(S^2) = \sigma^2 - \frac{\sigma^2}{n}$

✓ یعنی S^2 به طور متوسط مقدار σ^2 را به اندازه $\frac{\sigma^2}{n}$ کمتر از «مقدار واقعی» برآورد می‌کند.




هرگونه انحراف سیستماتیک برآوردگر از پارامتر جامعه را «**انحراف/اریب/تورش (bias)**» می‌نامند.

سوال: منظور از انحراف سیستماتیک چیست؟

مثلا اگر یک آماره، همواره مقادیری بیشتر از پارامتر جامعه داشته‌باشد، می‌گوییم انحراف سیستماتیک دارد.

برای مثال، هنگامی که گفته می‌شود میانگین نمونه، برآوردگر ناریبی از میانگین جامعه است؛ بدین معناست که میانگین نمونه، گاهی اوقات مقادیر کمتر از میانگین واقعی جامعه را به‌خود می‌گیرد و برخی اوقات نیز مقادیر بدست‌آمده برای میانگین نمونه، از میانگین جامعه بیشتر است.




$E(\bar{X}) = \mu_X$	$E(X^*) \neq \mu_X$
Unbiased estimator	Biased estimator



ب) کارایی (حداقل واریانس) (Efficiency).

کارایی یک ویژگی نسبی است. بدین معنا که از میان چندین برآوردگر ناریب $\hat{\theta}_1$ و $\hat{\theta}_2$ و ... هر کدام که توزیع نمونه‌گیری آن دارای واریانس کمتری باشد؛ کارایی بیشتری خواهد داشت.



✓ می‌توان ثابت کرد برای یک جامعه با توزیع نرمال، میانگین نمونه (\bar{X}) یک برآوردگر ناریب با کمترین واریانس برای میانگین جامعه (μ) است (برابر با $\frac{\sigma^2}{n}$).

✓ هنگامی که دو یا چند برآوردگر ناریب موجود باشد، برای انتخاب برآوردگر برتر، از شاخص «کارایی» استفاده می‌شود.



میانگین مجذور خطا (Mean Squared Error (MSE))

یکی دیگر از معیارهایی که برای ارزیابی و مقایسه برآوردگرها به کار می‌رود، میانگین مجذور خطا است که برابر است با «میانگین توان دوم انحراف $\hat{\theta}$ از θ »

$$MSE(\hat{\theta}) = E(\hat{\theta} - \theta)^2 = var(\hat{\theta}) + [E(\hat{\theta}) - \theta]^2$$

جمله دوم برابر با مجذور اریب است.

بنابراین، میانگین مجذور خطا، ترکیبی از کارایی (واریانس) و اریب را منعکس می‌کند.

برای میانگین توان دوم خطاها از یک مجموعه با n داده؛


$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2$$



ج) سازگاری (Consistency). اگر برای برآوردگر $\hat{\theta}$ ، با افزایش اندازه نمونه، احتمال نزدیک شدن مقدار برآوردگر به مقدار واقعی پارامتر جامعه (θ) افزایش یابد؛ آنگاه می‌گوییم این برآوردگر دارای ویژگی «سازگاری» است. یعنی وقتی حجم نمونه افزایش یابد، مقدار $\hat{\theta}$ کاملاً به θ نزدیک خواهد شد.

اگر با افزایش اندازه نمونه واریانس $\hat{\theta}$ به سمت صفر میل کند (یعنی انحراف $\hat{\theta}$ از θ به صفر میل کند)، $\hat{\theta}$ یک برآوردگر سازگار است.

✓ یک برآوردگر ممکن است ناریب نباشد، اما سازگار باشد. مثلاً، واریانس نمونه (S^2) یک برآوردگر اریب اما سازگار است.



تصویر: رفتار برآوردگر فرضی X^* برای میانگین جامعه با افزایش اندازه نمونه



(د) بسندگی یا کفایت (Sufficiency).

اگر یک برآورد تمام اطلاعات موجود درون داده‌ها در مورد پارامتر مورد نظر را درون خود گنجانده باشد، آنگاه می‌گویند آن برآوردگر، «بسندگی» دارد.

یعنی $\hat{\theta}$ از تمام اطلاعات نمونه که مربوط به برآورد θ است استفاده کند.

یعنی تمام n داده موجود در نمونه را استفاده کند و نهایتاً یک مقدار به عنوان برآورد θ ارائه کند.

مثال؛ داشتن یک نمونه n تایی برای محاسبه برآوردگر t (مجموع نمونه) و یا داشتن مقدار برآورد t برای نمونه مورد نظر،

- آیا برآورد t دقیقاً همان مقداری را ارائه می‌کند که با داشتن مقادیر نمونه می‌توانستیم حساب کنیم؟
- اگر بله؛ پس t یک برآوردگر کافی است (بسندگی دارد).



د) بسندگی یا کفایت (Sufficiency).

به عبارت دیگر، توزیع مشترک X_i ها (اطلاعات نمونه) به شرط $\hat{\theta}$ (یعنی $f(x_1, \dots, x_n | \hat{\theta})$) مستقل از θ باشد (یعنی در تابع $f(x_1, \dots, x_n | \hat{\theta})$ پارامتر θ وجود نداشته باشد).

اگر این احتمال مستقل از θ نباشد و به θ بستگی داشته باشد، آنگاه مشاهده یک نمونه خاص بستگی به θ دارد.

اگر این احتمال مستقل از θ باشد، آنگاه نمونه خاصی مانند (x_1, \dots, x_n) که منجر به برآورد θ می‌شود، برای هر مقدار از θ احتمال یکسانی با سایر نمونه‌ها دارد.

\bar{X} یک برآوردگر بسنده برای μ (میانگین جامعه نرمال با واریانس معلوم σ^2) است.



۲- چه روش‌هایی برای به دست آوردن برآوردگرهایی که دارای خواص مناسبی باشند، وجود دارد؟

برای برآورد پارامترهای موردنظر، روش‌هایی وجود دارد که هر یک دارای ویژگی‌هایی هستند.

دو مورد از مهمترین روش‌ها؛

الف) روش حداقل مربعات معمولی

ب) روش حداکثر درست‌نمایی

در واقع این روش‌ها به ما کمک می‌کنند که مناسب‌ترین برآوردگرها (و بالتبع، بهترین برآوردها) را برای پارامترهای مجهول پیدا کنیم.



روش حداقل مربعات معمولی (Ordinary Least Squares (OLS))

به دلیل خواص مطلوبی که دارد (البته هنگامی که فروض این روش برقرار باشند) به عنوان پرکاربردترین و غالبترین روش شناخته شده است.

این روش به کارل فردریک گوس، ریاضیدان نامی آلمان نسبت داده می‌شود.

از طریق **حداقل کردن مجموع مربعات انحرافات (جملات اخلاص، یا باقیمانده‌ها)** تلاش می‌کند که بهترین خط رگرسیونی برای داده‌ها را برازش نماید.



روش حداکثر درستنمایی (Maximum Likelihood Estimation (MLE))

فرض کنید X دارای توزیع معینی باشد که فقط یک پارامتر (θ) دارد.

تابع توزیع X : $P(x, \theta)$

وقتی نمونه‌گیری را انجام دهیم، مقادیر x_1, x_2, \dots, x_n و x_n به دست می‌آید.

احتمال مشاهده شدن این نمونه چقدر است؟

$$P(X_1 = x_1, \dots, X_n = x_n) = P(X_1 = x_1) \dots P(X_n = x_n) = P(x_1, \theta) \dots P(x_n, \theta)$$

مقدار این احتمال به مقدار θ بستگی دارد (مقادیر متغیرهای تصادفی X_1, \dots, X_n مشخص شده‌اند).

بنابراین، مقدار این احتمال، تابعی از θ است. آن را با $L(\theta)$ نمایش می‌دهیم.

$L(\theta)$: تابع درستنمایی: احتمال مشاهده شدن نمونه موردنظر (که آن را به صورت تابعی از پارامتر (های) توزیع نمایش می‌دهیم).

تابع درست‌نمایی برابر است با احتمال آنکه به ازای مقادیری معین برای پارامترها، نتایج مشاهده شده حاصل شود.



روش حداکثر درستنمایی (Maximum Likelihood Estimation (MLE)

تابع درستنمایی همان تابع توزیع مشترک است.

$$L(\theta) = f(x_1, \theta) \dots f(x_n, \theta) = \prod_{i=1}^n f(x_i, \theta)$$



روش حداکثر درست‌نمایی (Maximum Likelihood Estimation (MLE))

سوال: از بین تمام مقادیری که می‌توانستند نمایان شوند، چرا مقادیر x_1, x_2, \dots, x_n مشاهده شدند؟

پاسخ: چون این مشاهدات، بیشترین احتمال یا شانس را برای نمایان شدن داشته‌اند.

پس $L(\theta)$ باید بیانگر حداکثر احتمال باشد.

بنابراین، مقدار θ که برحسب مشاهدات نمونه تعیین می‌شود، باید به گونه‌ای باشد که احتمال مذکور $(L(\theta))$ را حداکثر نماید.

پس برآوردگر حداکثر درست‌نمایی از طریق حداکثر شدن تابع درست‌نمایی نسبت به پارامترهای مجهول (ضرایب θ) به دست می‌آید.

برای حداکثر شدن $L(\theta)$ شرط زیر را به کار می‌بریم:

$$\frac{\partial L}{\partial \theta} = 0 \rightarrow \hat{\theta}_{ML} = g(x_1, \dots, x_n)$$

$\hat{\theta}_{ML}$: برآوردگر حداکثر درست‌نمایی نامیده می‌شود.

نکته: معمولاً بهتر است ابتدا از $L(\theta)$ لگاریتم گرفته و سپس نسبت به θ مشتق بگیریم.



روش حداکثر درستنمایی (Maximum Likelihood Estimation (MLE))

سوال: فرض کنید X دارای توزیع برنولی است. پارامتر p این توزیع را با روش حداکثر درستنمایی برآورد کنید؟

$$P(x) = p^x(1 - p)^{1-x}$$

پاسخ:

اگر یک نمونه n تایی از این جامعه انتخاب شود، داریم؛

$$L(p) = P(x_1, p) \dots P(x_n, p) = p^{x_1}(1 - p)^{1-x_1} \dots p^{x_n}(1 - p)^{1-x_n} = p^{\sum x_i}(1 - p)^{n - \sum x_i}$$

$$\ln L(p) = \sum x_i \ln p + (n - \sum x_i) \ln(1 - p)$$

$$\frac{\partial \ln L}{\partial p} = \sum x_i \frac{1}{p} + (n - \sum x_i) \frac{-1}{1-p} = 0 \rightarrow \hat{p}_{ML} = \frac{\sum x_i}{n} = \bar{x} \quad \text{برآوردگر حداکثر درستنمایی پارامتر } p$$

بنابراین، هنگامی که پارامتر p برابر با $\hat{p} = \frac{\sum x_i}{n}$ یا همان میانگین (\bar{x}) باشد، تابع $L(p)$ حداکثر می‌شود.



روش حداکثر درستنمایی (Maximum Likelihood Estimation (MLE))

سوال: فرض کنید X دارای توزیع نرمال است. پارامترهای μ و σ^2 این توزیع را با روش حداکثر درستنمایی برآورد کنید؟

$$f(x; \mu, \sigma^2) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

پاسخ:

تابع درستنمایی؛

$$L(\mu, \sigma^2) = f(x_1, \mu, \sigma^2) \dots f(x_n, \mu, \sigma^2) = \frac{1}{(\sqrt{2\pi})^n \sigma^n} e^{-\frac{\sum_{i=1}^n (x_i - \mu)^2}{2\sigma^2}}$$

$$\ln L(\mu, \sigma^2) = -n \ln \sqrt{2\pi} - \frac{n}{2} \ln \sigma^2 - \frac{\sum_{i=1}^n (x_i - \mu)^2}{2\sigma^2}$$



روش حداکثر درستنمایی (Maximum Likelihood Estimation (MLE))

سوال: فرض کنید X دارای توزیع نرمال است. پارامترهای μ و σ^2 این توزیع را با روش حداکثر درستنمایی برآورد کنید؟

$$f(x; \mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$

پاسخ:

مشق‌گیری نسبت به پارامترها؛

$$\frac{\partial \ln L}{\partial \mu} = 0, \quad \frac{\partial \ln L}{\partial \sigma^2} = 0$$

با حل معادلات بالا، برآوردگرهای پارامترهای این متغیر تصادفی را به روش حداکثر درستنمایی به دست آورده‌ایم؛

$$\hat{\mu}_{ML} = \frac{\sum x_i}{n} = \bar{x}, \quad \hat{\sigma}_{ML}^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}$$



روش حداکثر درستنمایی (Maximum Likelihood Estimation (MLE))

دو نکته:

- تابع درستنمایی بعد از مشخص شدن مقادیر x_i فقط تابعی از ضرایب θ است.
- تعداد پارامترها به هر میزان که باشد، تابع درستنمایی، تابعی از همه پارامترهاست و لازم است نسبت به همه پارامترها مشتق جزئی گرفته و برآوردگر هر کدام از آن پارامترها را به دست آورد.
- ممکن است تابع درستنمایی دارای یک «فرم بسته» نباشد. در این شرایط نمی‌توان معادلات مشتق جزئی را حل کرد.

توزیع های نمونه ای

فصل
پنجم

Sampling distributions

مقدمه

بخش اول: مفاهیم کلی

بخش دوم: توزیع های نمونه ای



✓ مقادیر به دست آمده برای یک برآوردگر در نمونه‌گیری‌های مختلف با یکدیگر متفاوت است.

✓ بنابراین، هر برآوردگر، خود یک متغیر تصادفی است.

✓ توزیع احتمال مقادیری که یک برآوردگر می‌تواند داشته باشد را توزیع نمونه‌ای آن برآوردگر می‌نامند.

✓ **توزیع نمونه‌ای (یا توزیع نمونه‌گیری):** نمودار فراوانی مقادیر مشاهده شده برای یک آماره.

✓ **توزیع نمونه‌ای (یا توزیع نمونه‌گیری):** توزیع احتمال مقادیر موردانتظار برای یک آماره.

✓ **میانگین نمونه** یکی از برآوردهای پرکاربرد است و به توزیع نمونه‌ای آن، «توزیع نمونه‌ای میانگین» گفته می‌شود.

✓ واضح است که مقدار میانگین نمونه، از یک نمونه به نمونه دیگر، متفاوت است.

✓ اگر توزیع مقادیر میانگین نمونه‌های مختلف استخراج شده از یک جامعه را در یک نمودار ترسیم کنیم؛ توزیع نمونه-

ای میانگین آن جامعه را به دست خواهیم آورد.



مثال؛

یک جامعه کوچک و متناهی شامل ۵ داده سرعت به دست آمده از ۵ خودرو را در نظر بگیرید. مقادیر میانگین (μ) و واریانس (σ^2) این جامعه

((چون داده‌های مربوط به تمام اعضای جامعه را برداشت کرده‌ایم، توانستیم میانگین و واریانس جامعه را محاسبه نماییم))

شماره خودرو	۱	۲	۳	۴	۵
سرعت (X)	۶۰	۵۷	۶۶	۶۱	۵۴
احتمال (X)	۰/۲	۰/۲	۰/۲	۰/۲	۰/۲

$$\mu = \frac{60 + 57 + 66 + 61 + 54}{5} = 59.6$$

$$\sigma^2 = \frac{\sum_{i=1}^5 (x_i - \mu)^2}{N} = 16.24$$



مثال؛

فرض کنید به جای برداشت داده‌های کل جامعه، تنها می‌توانیم نمونه‌های دوتایی (بدون جایگذاری) از جامعه برداشت کنیم. بر این اساس، به ۱۰ شکل مختلف می‌توان نمونه‌هایی ۲ تایی از این جامعه برداشت کرد. نمونه‌های برداشت شده به همراه میانگین متناظر با هر نمونه:

شماره نمونه (i)	خودروهای نمونه‌گیری شده	سرعت خودروها (X_{i1}, X_{i2})	میانگین نمونه (\bar{X}_i)
۱	۱.۲	۵۷.۶۰	۵۸/۵
۲	۱.۳	۶۶.۶۰	۶۳
۳	۱.۴	۶۱.۶۰	۶۰/۵
۴	۱.۵	۵۴.۶۰	۵۷
۵	۲.۳	۶۶.۵۷	۶۱/۵
۶	۲.۴	۶۱.۵۷	۵۹
۷	۲.۵	۵۴.۵۷	۵۵/۵
۸	۳.۴	۶۱.۶۶	۶۳/۵
۹	۳.۵	۵۴.۶۶	۶۰
۱۰	۴.۵	۵۴.۶۱	۵۷/۵



مثال؛

با داشتن داده‌های مربوط به «میانگین نمونه‌ها» و نیز احتمال‌های متناظر با هر کدام (که در این مثال برابر با ۰.۱ است)؛ می‌توان توزیع نمونه‌ای میانگین (\bar{X}) را به صورت جدول زیر ارائه کرد.

۵۷/۵	۶۰	۶۳/۵	۵۵/۵	۵۹	۶۱/۵	۵۷	۶۰/۵	۶۳	۵۸/۵	\bar{X}
۰/۱	۰/۱	۰/۱	۰/۱	۰/۱	۰/۱	۰/۱	۰/۱	۰/۱	۰/۱	احتمال (\bar{X})

میانگین نمونه (\bar{X}_i)	سرعت خودروها (X_{i1}, X_{i2})	خودروهای نمونه‌گیری شده	شماره نمونه (i)
۵۸/۵	۵۷.۶۰	۱.۲	۱
۶۳	۶۶.۶۰	۱.۳	۲
۶۰/۵	۶۱.۶۰	۱.۴	۳
۵۷	۵۴.۶۰	۱.۵	۴
۶۱/۵	۶۶.۵۷	۲.۳	۵
۵۹	۶۱.۵۷	۲.۴	۶
۵۵/۵	۵۴.۵۷	۲.۵	۷
۶۳/۵	۶۱.۶۶	۳.۴	۸
۶۰	۵۴.۶۶	۳.۵	۹
۵۷/۵	۵۴.۶۱	۴.۵	۱۰

$$\mu_{\bar{X}} = \sum_{i=1}^{10} \bar{X}_i \left(\frac{1}{10} \right) = 59.6$$

$$\sigma_{\bar{X}}^2 = \frac{\sum_{i=1}^{10} (X_i - \bar{X}_i)^2}{N} = 61.09$$



با مقایسه مقادیر میانگین و واریانس جامعه، با میانگین و واریانس توزیع نمونه‌ای \bar{X} می‌توان نتیجه گرفت که:

۱. مقدار \bar{X} از نمونه‌ای به نمونه دیگر، متغیر است (یک متغیر تصادفی است) و لزوماً با میانگین جامعه (μ) برابر نیست.

۲. امید ریاضی توزیع نمونه‌ای \bar{X} (که به صورت $\mu_{\bar{X}}$ نمایش داده شده)، با میانگین جامعه برابر است.

۳. واریانس توزیع نمونه‌ای \bar{X} (که به صورت $\sigma_{\bar{X}}^2$ نمایش داده شده)، کمتر از واریانس جامعه است.



$$\mu_{\bar{X}} = \mu$$

برای یک جامعه نامتناهی

$$\sigma_{\bar{X}}^2 = \frac{\sigma^2}{n}$$

در حالتی که جامعه متناهی باشد

$$\sigma_{\bar{X}}^2 = \frac{\sigma^2}{n} \left(\frac{N-n}{N-1} \right)$$

N اندازه جامعه و n اندازه نمونه می‌باشد.

ضریب $\left(\frac{N-n}{N-1} \right)$ تحت عنوان ضریب تصحیح جامعه متناهی شناخته می‌شود.

در شرایطی که اندازه جامعه (N) بسیار بزرگ‌تر از اندازه نمونه باشد؛ (مثلاً هنگامی که $\left(\frac{n}{N} \right)$ کمتر از ۵٪ یا ۱۰٪ باشد) می‌توان ضریب تصحیح جامعه متناهی را برابر با ۱ در نظر گرفت.

در این مثال، اندازه جامعه برابر با ۵ و اندازه نمونه‌ها برابر با ۲ می‌باشد؛ بنابراین،

$$\left(\frac{N-n}{N-1} \right) = \left(\frac{2-5}{1-5} \right) = 0.75$$

با توجه به روابط قبلی، با داشتن میانگین و واریانس جامعه، می‌توان میانگین و واریانس توزیع نمونه‌ای میانگین را به دست آورد:

$$\mu_{\bar{X}} = \mu = 59.6$$

$$\sigma_{\bar{X}}^2 = \frac{\sigma^2}{n} \times \left(\frac{N-n}{N-1} \right) = \frac{16.24}{2} \times (0.75) = 6.09$$



دو ویژگی مهم توزیع نمونه‌ای میانگین:

۱- فارغ از این که توزیع جامعه به چه شکل است؛ در صورتی که یک نمونه تصادفی جمع‌آوری کرده و میانگین نمونه را حساب نماییم و این کار را تکرار کنیم؛ آنگاه، مقادیر میانگین نمونه‌ها حول میانگین جامعه متمرکز خواهند شد.

همچنین، واریانس \bar{X} مقداری کمتر از واریانس جامعه خواهد داشت (با ضریب کاهش $\frac{\sigma^2}{n}$ برای جامعه نامتناهی و $\frac{\sigma^2}{n} \left(\frac{N-n}{N-1} \right)$ برای جامعه متناهی).

۲- هرچه اندازه نمونه‌ها (n) بزرگ‌تر باشد، تغییرات مشاهده‌شده در توزیع نمونه‌ای کمتر خواهد بود.

به عبارت دیگر، مقدار میانگین نمونه‌ای که بر اساس یک نمونه با اندازه بزرگ‌تر به دست آمده باشد، نسبت به میانگینی که از یک نمونه با اندازه کوچک‌تر به دست آمده باشد، به میانگین واقعی جامعه نزدیک‌تر است.

این که انتظار داریم با افزایش اندازه نمونه، برآورد به دست آمده از پارامتر مورد نظر، به مقدار واقعی آن نزدیک‌تر شود؛ یک ویژگی خوب برای نمونه‌گیری تصادفی به حساب می‌آید (**ویژگی سازگاری؟**).



دو نکته مهم در مورد رابطه زیر:

$$\sigma_{\bar{X}} = \frac{\sigma}{n}$$

1. این رابطه همواره صحیح نیست. گاهی اوقات ممکن است یک نمونه تصادفی ۱۰ تایی، نسبت به یک نمونه ۱۰۰ تایی، برآورد نزدیک‌تری برای میانگین جامعه ارائه کند. اما هیچ راهی برای فهمیدن این که کدام برآورد به پارامتر جامعه نزدیک‌تر است وجود ندارد (زیرا اگر ما مقدار پارامتر جامعه را می‌دانستیم به سراغ نمونه‌گیری نمی‌رفتیم).
2. درحالی‌که با افزایش اندازه نمونه، واریانس توزیع نمونه‌ای کاهش می‌یابد (و به این ترتیب، احتمال این که برآورد به دست آمده، به مقدار واقعی میانگین نزدیک‌تر باشد، افزایش می‌یابد)؛ اما این افزایش، نرخ کاهشی دارد. به عبارت ساده‌تر، سود حاشیه‌ای اضافه نمودن ۱۰ مشاهده جدید به ۱۰ مشاهده قبلی، بیشتر از زمانی است که بخواهیم ۱۰ مشاهده را به ۱۰۰ مشاهده قبلی اضافه کنیم.



در مسائل عملی، ما تنها یک نمونه تصادفی با اندازه n (و نه چندین نمونه n تایی) از جامعه برداشت می‌کنیم. بدین ترتیب، میانگین نمونه برداشت‌شده، به‌عنوان برآوردی از میانگین مجهول جامعه مورداستفاده قرار خواهد گرفت.

سؤال: میانگین به‌دست‌آمده از نمونه، چقدر به میانگین واقعی جامعه نزدیک است؟

برای کمی کردن میزان نزدیکی میانگین نمونه به میانگین مجهول جامعه، می‌توان میزان این نزدیکی را در قالب یک گزاره احتمالاتی بیان کرد. برای مثال، احتمال این که مقدار میانگین یک نمونه (\bar{X}) با اندازه n در یک بازه $\pm E$ از میانگین واقعی جامعه قرار داشته باشد، چقدر است؟ (E همان خطای قابل قبول می‌باشد).

در صورتی که توزیع نمونه‌ای میانگین (\bar{X}) را بدانیم (مانند آنچه در **مثال قبل** نشان داده شد)، آنگاه می‌توان به این سؤال پاسخ داد.

از آنجا که اندازه جامعه (N) معمولاً نامتناهی یا بسیار بزرگ می‌باشد، ساختن توزیع نمونه‌ای غیرعملی است.

نظریه‌ها و قواعدی در مورد توزیع نمونه‌ای چند آماره معروف (مثلاً میانگین نمونه \bar{X}) وجود دارد که به ما کمک می‌کند بدون ساختن توزیع احتمالاتی آن آماره‌ها، احتمال‌های متناظر با مقادیر مختلف آن‌ها را به دست آوریم.



توزیع نمونه‌ای میانگین

به‌طور کلی ۳ حالت زیر وجود دارد:

الف) اگر \bar{X} میانگین یک نمونه تصادفی n تایی از یک جامعه نرمال با میانگین μ و واریانس σ^2 باشد؛ آنگاه، صرف‌نظر از اندازه نمونه، توزیع نمونه‌ای میانگین‌ها (\bar{X}) نیز از توزیع نرمال به‌صورت زیر پیروی خواهد کرد.

$$\bar{X} \sim N(\mu, \sigma^2/n)$$

یا به‌عبارت‌دیگر، توزیع نمونه‌ای \bar{X} استانداردشده، از توزیع نرمال استاندارد پیروی می‌کند

$$Z = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$$

در بسیاری از مسائل عملی، **واریانس جامعه مجهول است**. برای حل این مشکل، انحراف معیار نمونه را جایگزین انحراف معیار جامعه در رابطه بالا می‌کنند.

مطالعات پیشین نشان داده که این جایگذاری موجب می‌شود که توزیع حاصله، نسبت به توزیع نرمال استاندارد، پراکندگی بیشتری داشته باشد. در این حالت، توزیع نمونه‌ای آماره زیر، از توزیع t با $n-1$ درجه آزادی پیروی می‌کند:

$$T = \frac{(\bar{X} - \mu)}{(S/\sqrt{n})} \sim t_{n-1}$$



توزیع نمونه‌ای میانگین

به‌طور کلی ۳ حالت زیر وجود دارد:

(ب) هنگامی که اندازه نمونه (n) به قدر کافی بزرگ باشد. در این حالت از یک قضیه مشهور در علم آمار به نام قضیه حد مرکزی استفاده می‌شود. این قضیه در مورد توزیع نمونه‌ای \bar{X} فارغ از توزیع حاکم بر جامعه بیان می‌کند که:

اگر \bar{X} میانگین یک نمونه تصادفی با اندازه n باشد که از جامعه‌ای با میانگین (μ) و واریانس (σ^2) استخراج شده باشد؛ آنگاه، با افزایش اندازه نمونه (n)، توزیع \bar{X} به یک توزیع نرمال با میانگین $\mu_{\bar{X}} = \mu$ و واریانس $\sigma_{\bar{X}}^2 = \sigma^2/n$ میل می‌کند.

$$\bar{X} \sim N(\mu, \sigma^2/n)$$

به عبارت دیگر، توزیع نمونه‌ای \bar{X} استاندارد شده $(\frac{\bar{X} - \mu}{\sigma/\sqrt{n}})$ ، از توزیع نرمال استاندارد پیروی می‌کند.

$$Z = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0, 1)$$



توزیع نمونه‌ای میانگین

به‌طور کلی ۳ حالت زیر وجود دارد:

بدین ترتیب، با استفاده از قضیه حد مرکزی، می‌توان گفت در صورتی که اندازه نمونه n به اندازه کافی بزرگ باشد، آنگاه می‌توان توزیع نمونه‌ای \bar{X} را با یک توزیع نرمال تقریب زد. به‌طور کلی می‌توان گفت، این گزاره (در حالتی که توزیع جامعه چولگی شدیدی نداشته باشد) برای $n \geq 30$ قابل قبول است.

در صورت وجود چولگی شدید در توزیع جامعه، نمونه‌ای با اندازه به مراتب بزرگ‌تر از ۳۰ مورد نیاز است تا بتوان گفت قضیه حد مرکزی برقرار است.



توزیع نمونه‌ای میانگین

به‌طور کلی ۳ حالت زیر وجود دارد:

ج) هنگامی که توزیع جامعه غیر نرمال بوده و اندازه نمونه نیز کوچک است.

برای این حالت، یک قضیه کلی که بتوان به کمک آن، توزیع نمونه‌ای \bar{X} را توضیح داد، وجود ندارد.

زیرا در این حالت، توزیع نمونه‌ای \bar{X} به توزیع جامعه بستگی دارد. در این شرایط، نمی‌توان به راحتی در مورد کیفیت برآورد انجام شده، اظهار نظر کرد.

برای حل این مشکل، از روش‌های ناپارامتری استفاده می‌شود.



توزیع نمونه‌ای میانگین

در ادامه و در قالب یک مثال، به صورت اجمالی خواهیم دید که چگونه می‌توان تنها با انجام یک مرتبه نمونه‌گیری و استفاده از مفهوم توزیع نمونه‌ای، در مورد مقدار تقریبی میانگین واقعی جامعه اظهار نظر کرد.

فرض کنید توزیع نمونه‌ای میانگین یک جامعه، به صورت یک توزیع نرمال با میانگین مجهول μ و واریانس معلوم σ^2 باشد. (حالت الف از سه حالت تشریح شده در قسمت قبل)

اگر تنها یک بار نمونه‌گیری کنیم و میانگین نمونه برابر \bar{X} شود؛

آنگاه با داشتن خطای استاندارد میانگین (به صورت σ/\sqrt{n})، به دو شکل می‌توان در مورد میانگین مجهول جامعه (μ) استنباط انجام داد؛

1. **حالت اول.** اظهار نظر در مورد میزان نزدیکی یک مقدار مفروض به مقدار واقعی میانگین جامعه.
2. **حالت دوم.** ارائه بازه‌ای از مقادیر که با یک درصد اطمینان مشخص، شامل میانگین جامعه است.

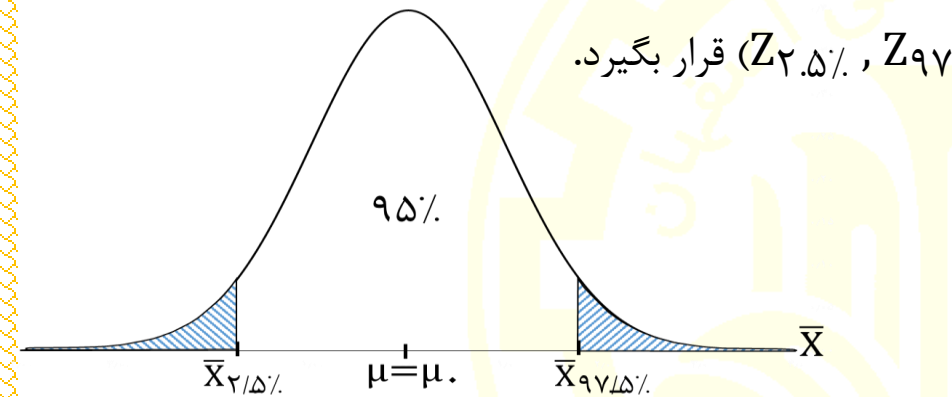


توزیع نمونه‌ای میانگین

حالت اول. اظهار نظر در مورد میزان نزدیکی یک مقدار مفروض به مقدار واقعی میانگین جامعه.

می‌توانیم بگوییم اگر مقدار مفروض برای میانگین جامعه (μ_0) ، صحیح باشد؛ آنگاه، اگر یک نمونه تصادفی با میانگین \bar{X} از جامعه برداشت

شده باشد؛ در ۹۵٪ اوقات انتظار داریم مقدار آماره $Z = \frac{\bar{X} - \mu_0}{\sigma / \sqrt{n}}$ در بازه $(Z_{۲.۵\%}, Z_{۹۷.۵\%})$ قرار بگیرد.




به عبارت دیگر، اگر نمونه‌ای تصادفی از جامعه‌ای با میانگین μ انتخاب شده باشد؛ احتمال این که میانگین نمونه مذکور در قسمت ۲.۵٪ ابتدا یا انتهای توزیع نمونه‌ای قرار بگیرد، ۰.۰۵ است.

پس اگر مقدار آماره مورد نظر، در این بازه قرار نگیرد؛ بدین معناست که؛

(۱) یا یک رویداد نادر اتفاق افتاده (در این حالت، با احتمال ۰.۰۵) و

(۲) یا این که مقدار فرض شده برای میانگین جامعه (یعنی μ_0)، با مقدار

واقعی میانگین جامعه (μ) تفاوت دارد.





توزیع نمونه‌ای میانگین

حالت دوم. ارائه بازه‌ای از مقادیر که با یک درصد اطمینان مشخص، شامل میانگین جامعه است.

می‌دانیم که میانگین نمونه‌ها یک متغیر تصادفی است.

اگر توزیع نمونه‌ای میانگین نمونه‌ها را داشته باشیم، می‌توانیم بازه‌ای از مقادیر را ارائه کنیم که با یک درصد اطمینان مشخص، شامل میانگین جامعه است (Confidence Interval).



توزیع نمونه‌ای میانگین

حالت دوم. ارائه بازه‌ای از مقادیر که با یک درصد اطمینان مشخص، شامل میانگین جامعه است.


مثلا، اگر توزیع مقادیر میانگین نمونه‌ها، به صورت توزیع نرمال با میانگین μ و واریانس σ^2/n باشد؛ آنگاه، میانگین به‌دست‌آمده از یک‌بار نمونه‌گیری تصادفی، با احتمال ۹۵٪ در بازه $(\bar{X}_{.97.5}, \bar{X}_{.2.5})$ از توزیع نمونه‌ای میانگین، قرار خواهد گرفت. یا به‌عبارت‌دیگر، اگر یک نمونه تصادفی از جامعه برداشت شود (و میانگین آن برابر با \bar{X} به دست آید)، در ۹۵٪ اوقات انتظار داریم مقدار آماره $\frac{\bar{X}-\mu}{\sigma/\sqrt{n}}$ در بازه $(Z_{.2.5}, Z_{.97.5})$ قرار بگیرد.

تحلیل‌گر از این‌که مقدار میانگین به‌دست‌آمده از نمونه تصادفی، کدام‌یک از مقادیر $\bar{X}_1, \bar{X}_2, \bar{X}_{.2.5}, \bar{X}_{.99}$ و یا ... می‌باشد؛ اطلاعی ندارد.

بنابراین، با در نظر گرفتن کمترین و بیشترین مقدار محتمل، بازه‌ای به‌صورت زیر ارائه کرده و با ۹۵٪ اطمینان می‌گوییم این بازه شامل میانگین واقعی جامعه است؛

$$Z_{.2.5} < \frac{\bar{x}-\mu}{\sigma/\sqrt{n}} < Z_{.97.5}$$

$$[\bar{x}-|Z_{.2.5}|\times \sigma/\sqrt{n} < \mu < \bar{x}+|Z_{.97.5}|\times \sigma/\sqrt{n}]$$





توزیع نمونه‌ای واریانس یک نمونه

هنگامی که داده‌ها به‌عنوان یک نمونه تصادفی از جامعه هستند و واریانس جامعه (σ^2) مجهول است؛ واریانس نمونه (S^2) می‌تواند برای ارائه برآوردی از واریانس جامعه (σ^2)، مورد استفاده قرار گیرد.

اما واریانس نمونه نیز مانند میانگین آن، برای نمونه‌های مختلف می‌تواند مقادیر متفاوتی داشته باشد.

بنابراین، واریانس نمونه‌ها (S^2) نیز یک متغیر تصادفی است و به توزیع مقادیر آن، **توزیع نمونه‌ای واریانس** گفته می‌شود.

اما توزیع نمونه‌ای S^2 در آمار کاربرد اندکی دارد. به‌جای آن، نسبت زیر، یک متغیر تصادفی پرکاربرد به حساب می‌آید.

اگر S^2 ، واریانس به‌دست‌آمده از یک نمونه تصادفی n تایی انتخاب‌شده از **یک جامعه نرمال با واریانس σ^2** باشد؛ آنگاه، آماره زیر از **توزیع کای دو با $n-1$ درجه آزادی** پیروی خواهد کرد؛

$$\chi^2 = \frac{(n-1)s^2}{\sigma^2} = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{\sigma^2} \sim \chi_{n-1}^2$$

- توجه: این رابطه در صورتی برقرار است که جامعه، توزیع نرمال داشته باشند.
- اگر جامعه توزیع نرمال نداشته باشد، از روش‌های غیرپارامتری استفاده می‌شود.
- از رابطه اخیر، به‌عنوان پایه‌ای برای انجام استنباط در مورد واریانس مجهول جامعه استفاده می‌شود.



توزیع نمونه‌ای نسبت در یک نمونه

اگر داده‌ها از نوع طبقه‌ای (گسسته) باشند، می‌توان نسبت‌هایی از جامعه را برآورد کرد.

برای مثال، یک جامعه شامل تمام مسافرینی که از مترو تهران استفاده می‌کنند را در نظر گرفته و متغیر تصادفی X را به صورت «جنسیت مسافری که از این شیوه حمل‌ونقلی استفاده می‌کند»، تعریف می‌کنیم:

$$X_i = \begin{cases} 0 & \text{اگر مسافر مذکر باشد} \\ 1 & \text{اگر مسافر مؤنث باشد} \end{cases}$$

فرض کنید می‌خواهیم بدانیم چه نسبتی از مسافرینی که از مترو استفاده می‌کنند، مؤنث هستند؟ بنابراین، پارامتر p برابر خواهد بود با نسبت زن‌ها از کل افرادی که از مترو استفاده می‌کنند.

همانند میانگین و واریانس نمونه، مقدار یک نسبت در یک نمونه (\hat{p}) نیز از نمونه‌ای به نمونه دیگر متفاوت می‌باشد.

این تغییرپذیری سبب می‌شود مفهوم توزیع نمونه‌ای، برای برآوردگر \hat{p} نیز قابل استفاده باشد.



توزیع نمونه‌ای نسبت در یک نمونه

فرض کنید یک نمونه تصادفی با اندازه n به صورت (X_1, X_2, \dots, X_n) برای برآورد کردن مقدار p جمع‌آوری شده است. تعداد موفقیت‌ها در n آزمایش برنولی را می‌توان با توزیع دوجمله‌ای مدل کرد.

بنابراین، تعداد زن‌های مشاهده‌شده در نمونه تصادفی n تایی از مسافران، از یک توزیع دوجمله‌ای به صورت زیر پیروی می‌کند:

$$\sum_{i=1}^n X_i \sim B(n, p)$$

به علاوه، نسبت نمونه \hat{p} از تقسیم کردن تعداد مسافری زن درون نمونه، بر اندازه نمونه (n) به شکل زیر به دست می‌آید

$$\hat{p} = \frac{\sum_{i=1}^n X_i}{n}$$

همان‌طور که مشاهده می‌شود، شکل رابطه نسبت موفقیت در یک نمونه را می‌توان مشابه با میانگین نمونه در نظر گرفت.

می‌توان ثابت کرد که میانگین و واریانس توزیع نمونه‌ای \hat{p} برابر است با

$$E(\hat{p}) = \mu_{\hat{p}} = p$$

$$\sigma_{\hat{p}}^2 = \text{Var}(\hat{p}) = \frac{p(1-p)}{n}$$



توزیع نمونه‌ای نسبت در یک نمونه

به‌طور کلی، در ارتباط با توزیع نمونه‌ای \hat{p} ، یکی از سه حالت زیر ممکن است رخ دهد:

(الف) اگر نمونه‌ها از **جامعه‌ای متناهی** برداشت شده باشند؛ توزیع نمونه‌ای \hat{p} ، از **توزیع فوق هندسی** پیروی می‌کند.

(ب) اگر نمونه‌ها از **جامعه‌ای نامتناهی** برداشت شده باشند؛ توزیع نمونه‌ای \hat{p} ، از **توزیع دو جمله‌ای** پیروی می‌کند.

(ج) به‌عنوان یک قاعده کلی، اگر دو شرط $n\hat{p} \geq 5$ و $n(1-\hat{p}) \geq 5$ برقرار باشد؛ آنگاه می‌توان توزیع نمونه‌ای آماره \hat{p} را با

یک **توزیع نرمال با میانگین $\mu_{\hat{p}}$ و واریانس $\sigma_{\hat{p}}^2$** تقریب زد.

$$\hat{p} \sim N\left(p, \frac{p(1-p)}{n}\right)$$

بنابراین، قضیه حد مرکزی برای توزیع نمونه‌گیری \hat{p} برقرار خواهد بود.

به‌علاوه، در صورتی که آماره Z را به‌صورت زیر تعریف کنیم، آنگاه، این آماره از توزیع نرمال استاندارد پیروی خواهد کرد

$$(Z \sim N(0, 1))$$

$$Z = \frac{\hat{p} - p}{\sqrt{\frac{p(1-p)}{n}}} \sim N(0, 1)$$