

## Stochastic Processes

## Note 1

مهدی جعفری کیاوشانی

دانشگاه صنعتی مکریم

\* مطالب این درس گفتار:

- پیشگفتار

- مبانی درس

- مروری بر نظریه احتمالات

• اصول موضوعه احتمالات

• وقایع و آزمایش‌های مستقل

• متغیرهای تصادفی

• امید ریاضی

• گشتاورهای یک متغیر تصادفی

• امید ریاضی شرطی

• تابع مولد گشتاور

• نامساوی‌های پایه در نظریه احتمال

• قوانین اعداد بزرگ

• قضیه حد مرکزی

• نگاه‌های متغیرهای تصادفی

استفاده از این درس گفتار برای

مقاصد آموزشی (به شرطی که موجب کسب

درآمد مستقیم لزوم نگردد) یا ذکر منبع

بلا مانع است.

\* در این درس می‌خواهیم در مورد فرایندهای تصادفی صحبت کنیم.

قاعدتا شما قبلا از این کلاس درس و مقدماتی در باره احتمالات گذرانده اید. اما عموما درس‌های مقدماتی احتمالات بیشتر در مورد حل کردن مسائلی که از قبل تعریف شده اند (well posed problems) صحبت می‌کنند. اما نکته مهم و اصلی در تئوری احتمالات و (فرایندهای تصادفی) حل کردن well posed problems نیست بلکه کار دشوار یا حتی مدل مناسب برای مسائلی که در عمل دنیای واقعی با آن سروکار داریم است. در اینجا منظور از دنیای واقعی مفهومی مقابل تئوری است.

- باعث احتمالات چگونه در عمل شروع می‌شود؟

- شروع احتمالات از بازی‌های مبتنی بر شانس بوده است. در نتیجه این بازی‌ها مردم از نظر تئوری احساسی در مورد احتمالات به رست می‌آوردند و برایشان وقایع پراختلال و کم احتمال معنی پیدا می‌کنند.
- یکی از مسائلی که باعث می‌شود بررسی بازی‌های مبتنی بر شانس راحت تر از موارد دیگر که عدم قطعیت در آنها وجود دارد باشد این است که این بازی‌ها در عمل تکرار پذیر هستند. یعنی یک بازی (آزمایشی) یکسان بارها تکرار می‌شود (ریاضی‌ناکی، پرات سک، چرخان، میز و...) و به این ترتیب مفاهیمی مثل فرکانس نسبی، و وقایع کم احتمال (odds) و پراختلال و... که کم و کیف پیدا می‌کنند. (مهم است که یک آزمایشی به صورت مستقل بارها تکرار می‌شود).
- بسیاری از تصمیم‌گیری‌ها در زندگی شامل عدم قطعیت هستند. بنابراین در زندگی واقعی ما در مورد وقایعی که ممکن است رخ دهند حس‌هایی می‌زنیم. در طول زندگی و این فرایندهای تصمیم‌گیری بازی‌گریم که به گزیننده‌های مختلف احتمال وقوع نسبت دهیم (البته این مفهوم با مفهوم دقیق ریاضی احتمال که در ادامه در مورد آن صحبت می‌کنیم لزوماً یکی نیست) و به اساس آن تصمیم‌گیری انجام دهیم.

- چند نکته مهم در مورد احتمالات

- مثال ساده پرتاب سکه یا در نظر بگیرید (گاهی برای درک مسایل پیچیده خوب است با مثال‌های خیلی ساده شروع کنیم). در پرتاب سکه خروجی آزمایشی به سرعت و جهت‌گیری اولیه سکه که به مقاومت هوا، به سطحی که سکه به آن می‌خورد، به جنس و شکل سکه و... بستگی دارد. با دانستن این عوامل و استفاده از معادلات مناسب (در اینجا معادلات مکانیک نیوتونی) هیچ پدیده تصادفی‌ای در این

آزمایشی وجود ندارد. با این وجود می‌شود بحث کرد که مکمل ما تقارن دارد و سه مدل احتمالاتی برای این آزمایش ارائه کرده که در عمل پاسخ برقی سوالات ما را به حد.

به عنوان مثال دیگر، بیفت فشرده سازی را در نظر بگیرید. در اینجا می‌ای فشرده سازی اطلاعات از مدل‌های احتمالاتی برای داده استفاده می‌کنیم. نکته مهم اینست که مجموعه‌های داده‌هایی که با آنها سروکار داریم (مثلاً متن یک کتاب یا یک عکس یا فایل یک سخنرانی و...) به هیچ وجه تصادفی نیستند. ولی برای فشرده کردن داده‌ها را با یک مدل احتمالاتی و تصادفی (با ویژگی‌های معین) مدل می‌کنیم و این مدل برای کاربرد فشرده سازی جواب می‌دهد در صورتیکه داده‌ها واقعاً تصادفی نیستند.

• در مورد مسائل دیگر هم با چنین مسئله‌ای روبرو هستیم. مثلاً اگر علاقه‌مند باشیم وضعیت هوا را در دو سال آینده پیشی بینی کنیم یا احتمال اینکه رشد اقتصادی ایران در پنج سال بعد بالای 7 درصد باشد را محاسبه کنیم، نکته اصلی اینست که این پدیده‌ها را چگونه مدل کنیم. در اینجا فهم متوری احتمالات و ابزارهای ریاضی مربوطه کلیدی به این مدل سازی می‌کنند و تمرین مدل سازی برای یک مسئله خارج از متوری احتمالات است.

نکته بسیار مهم اینست که وقتی برای مسئله‌ای مدل غیر متامبی به کار می‌بریم جواب‌های اشتباهی به دست می‌آوریم که ممکن است به نفع ما منجر شوند (مثلاً وقوع افتادن یک زلزله ما را در یک منطقه را که بیست می‌آوریم و در طراحی ساختمانی که قرار است ساخته شود مقاومت سازی‌های لازم را انجام نمی‌دهیم). در اینجا محاسبات ما و ریاضیاتی که به کار می‌بریم غلط نیستند بلکه مدل ما مدل خوبی نیست.

- سوال: چگونه می‌توان مدل احتمالاتی برای مسائل دنیایی واقعی ارائه کنیم؟

- این کار وقتی است که نیاز به دانش و تجربه زیادی دارد.
- اگر مدل ما مشخص باشد استفاده از متوری احتمالات و ابزارهای ریاضی آن روش هستند (هرچند که ممکن است سخت باشند).
- برای شروع با مدل‌های خیلی ساده شروع می‌کنیم. در طول زمان مدل‌های استاندارد می‌مانند و هرچی که می‌توان از آنها برای شروع کار استفاده کرد. مجموعه نتایج تعلیل‌های ریاضی این مدل‌ها به ما در فهم بیشتر مسئله اصلی کمک می‌کنند. به این ترتیب در چندین مرحله می‌توان مدل

ارلیه کرده رابه تدوین کامل تر کنیم تا به فهم بهتر و دقیق تری از مسئله مورد نظرمان برسیم.

• در عمل هیچ مدلی کامل نیست.

Alfred North whitehead: Seek simplicity and distrust it!

- بهجت احتمالات به صورت عام و فرایندهای تصادفی به صورت خاصی بهجت بسیار گسترده ای است که حتی آنکسای با آن به چندین درس احتیاج دارد. در این کلاس هدف ما اینست که به فی مفاهیم و ابزارهای پایه ای فرایندهای تصادفی را معرفی کرده به طوریکه دانشجویان بتوانند با استفاده از این دانش و مهارت های که کسب کرده اند موضوعات مربوط به مسئله خودشان را عمیق تر دنبال کنند.

- به روشی که در این درس درباره آن صحبت می کنیم عبارتند از:

(3) • مروجی بر احتمالات (اصول موضوعه آماد و احتمال با بر فی نامساوی های مفید احتمالاتی و قوانین اعداد بزرگ و هگله ای)

(6) • معرفی فرایندهای تصادفی و مفاهیم پایه مربوط به آن (فرایندهای ایستا (Stationary) و تحلیل مبتنی

به فرایندهای تصادفی سیستم ها و طیف توان (Power spectrum) فرایندها و (ergodicity)

(2) • فرایندهای تصادفی پواسن (Poisson)

(4) • زنجیره مارکف (Markov chain) با تعداد متناهی حالت

(6) • تئوری تخمین (estimation theory)

(2) • تئوری پیش بینی (prediction theory)

(1) • مدل های گرافیکی و (HMM) hidden markov models

(1) • واکشت (random walk)

(2) • مارتنگال ها (Martingales)

- برای شروع سوال مهم اینست که چگونه یک مدل دتئوری احتمالات لمانه کنیم که از نظر ریاضی سازگار باشد.  
 در حال حاضر تئوری و مجموعه اصول موضوعه ای که کوپنهام و ف در سال 1933 ارائه کرد مورد پذیرش همگان است.

این اصول موضوعه در واقع تئوری احتمالات را بخشی از تئوری عمومی تر  $measure\ theory$  قرار می دهند.  
 برای رفع پارادوکس هایی که خصوصاً برای تعریف احتمال بر روی فضاها میسر نیست ممکن است ایجاد شوند، استفاده از این اصول موضوعه لاترم است. اما برای بهاد این درس خیلی به بهاد عمیق تر  $measure\ theory$  نیاز نداریم و دارد آن نمی گوئیم.

### \* مروری بر احتمالات

- اصول موضوعه احتمالات

یک مدل احتمالاتی کامل که عنقه است:

① فضای نمونه (sample space)  $\Omega$  که مجموعه همه خروجی های ممکن یک آزمایش تصادفی است.

② یک مجموعه  $F$  از وقایع (event) که هر واقعه طبق تعریف یک زیر مجموعه از  $\Omega$  است.

$$\forall A \in F \Rightarrow A \subseteq \Omega$$

③ یک تابع احتمال  $P$  که به هر واقعه یک احتمال (عددی در بازه  $[0,1]$ ) نسبت می دهد.

- مجموعه وقایع  $F$  خواص زیر را دارد:

①  $\Omega \in F$  یک واقعه است:

② اگر  $A_1, A_2, \dots$  یک دنباله از وقایع باشند آنگاه:

$$\bigcup_{i=1}^{\infty} A_i \in F$$

③ اگر  $A \in F$  آنگاه  $A^c \in F$ .

• توجه کنیم که لزوماً هر زیر مجموعه  $\Omega$  یک واقعه نیست و احتمالاً واقعه ای وقایع تعریف می کنیم

(به اصطلاح برای زیر مجموعه های خوب یا بوردیفور  $\Omega$  که مجموعه  $F$  باشد).

به مجموعه  $F$  که خواص بالا را داشته باشد یک میدان (sigma-field) می گوئیم.

• زیر مجموعه هایی از  $\Omega$  که یک واقعه نیستند زیر مجموعه های عجیب هستند و تقریباً در لایه کاربردها

کاربردی به آنها نداریم.

• مواقعی که  $\Omega$  مجموعه ای متناهی یا شماراست معمولاً  $F$  را به صورت  $F = 2^{\Omega}$  در نظر می گیریم.

- نتایجی که لزومین بالا به دست می آید:

$$\emptyset = \Omega^c \Rightarrow \emptyset \in \mathcal{F}$$

• اگر  $\mathcal{F}$  مجموعه ای از رویدادها باشد و  $A \in \mathcal{F}$  داشته باشیم، در این صورت  $A^c$  نیز جزو  $\mathcal{F}$  است.

• متاهی و شمارهای واقع هستند (عضوی از  $\mathcal{F}$  هستند).

$$\text{اگر } A_1, A_2, \dots \in \mathcal{F} \text{ آنگاه } A_1^c, A_2^c, \dots \in \mathcal{F} \text{ بنا بر این:}$$

$$\bigcup_i A_i^c \in \mathcal{F} \Rightarrow \left[ \bigcup_i A_i^c \right]^c \in \mathcal{F} \Rightarrow \bigcap_i A_i \in \mathcal{F}$$

با استفاده از قانون دیرگان

بنابر این تعدادهای اکثری و قلی نیز یک واقع است.

• در نتیجه هر ترکیب شمارهای از اجتماع و اکثری و قلی یک واقع است.

- تابع احتمال  $P$  که بر روی مجموعه  $\mathcal{F}$  تعریف می شود (  $P: \mathcal{F} \rightarrow [0, 1]$  ) در اصول موضوعه زیر صدق می کند:

$$\textcircled{1} \quad P[\Omega] = 1 \quad \text{به هر واقعیتی که می گوئیم}$$

$$\textcircled{2} \quad \text{اگر } A \in \mathcal{F} \text{ آنگاه } P[A] \geq 0$$

$$\textcircled{3} \quad \text{اگر } A_1, A_2, \dots \text{ رویدادهای disjoint باشند ( } A_i \cap A_j = \emptyset \text{ ) آنگاه:}$$

$$P\left[\bigcup_{i=1}^{\infty} A_i\right] = \sum_{i=1}^{\infty} P[A_i] = \lim_{m \rightarrow \infty} \sum_{i=1}^m P[A_i]$$

- نکته جالب توجه این است که همین مقدار اندک اصول موضوعه برای ما فواید بیشتری فواید احتمالی کافی است.

- چند نتیجه زیر را می توانیم به سادگی به دست می آوریم:

$$A \text{ و } A^c \in \mathcal{F} \Rightarrow A \cap A^c = \emptyset \Rightarrow P[A \cup A^c] = P[A] + P[A^c]$$

$$\Rightarrow P[A^c] = 1 - P[A]$$

$$\Rightarrow P[\emptyset] = 1 - P[\Omega] = 0$$

$$A \text{ و } B \in \mathcal{F} \text{ and } A \subseteq B$$

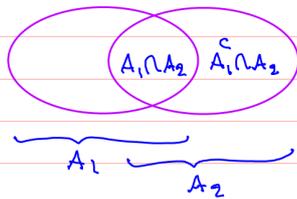
$$\Rightarrow P[B] = P[B \cap (A \cup A^c)] = P[(B \cap A) \cup (B \cap A^c)]$$

$$= P[A] + P[B \cap A^c] \Rightarrow P[A] \leq P[B] \leq 1$$

• Union Bound :

برای تعداد مشابه یا شمارا از وقایع  $A_i$  داریم:

$$P\left[\sum_i A_i\right] \leq \sum_i P[A_i]$$



$$\Rightarrow A_1 \cup A_2 = A_1 \cup (A_1^c \cap A_2)$$

$$\Rightarrow P[A_1 \cup A_2] = P[A_1] + P[A_1^c \cap A_2]$$

$$\leq P[A_1] + P[A_2]$$

- در بسیاری موارد به صورت مستقیم به اصول موضوعه احتمال نیاز پیدا نمی‌کنیم (هر چند که همیشه باید مد نظرمان باشن). بیشترین دقت را باید در مواردی انجام دهیم که با احتمالی که بر بی‌نهایتی واقعه اثر می‌کنند مانند جمع یا عددگیری) سروکار دارند.

- در درس‌های مقدماتی احتمال تاکید زیادی بر متغیرهای تصادفی و امید ریاضی وجود دارد. اما اصول موضوعه "وقایع" و "احتمال نسبت داده شده به آنها" را به عنوان مفاهیم بنیادی معرفی می‌کنند.

- وقایع و آزمایش‌های مستقل

$$P[A_1 \cap A_2] = P[A_1] \cdot P[A_2] \quad \text{• دو واقعه } A_1 \text{ و } A_2 \text{ مستقل هستند اگر}$$

• مدل توانان (Combined model):

فرض کنید دو مدل احتمالی با فضا‌های نمونه  $\Omega_1$  و  $\Omega_2$  داشته باشیم. مدل توانان این دو آزمایشی تصادفی به این صورت تعریف می‌شود که ابتدا فضای نمونه  $\Omega_1 \times \Omega_2$  را  $\Omega_C$  می‌نامیم. برای مدل توانان تشکیل می‌دهیم. بعد برای هر واقعه  $A \times B \subseteq \Omega_C$  احتمال را به صورت زیر تعریف می‌کنیم:

$$P_C[A \times B] = P_1[A] \cdot P_2[B]$$

در آزمایشی تصادفی اولیه را در این مدل توانان مستقل می‌گوییم و به این ترتیب استقلال دو مدل تصادفی را تعریف می‌کنیم.

به سادگی می‌توان بررسی کرد که اگر اصول موضوعه آمار و احتمال میراث هر یک از مدل‌های ابتدا ای برقرار باشد، برای مدل توانان نیز برقرار است.

به این ترتیب با ترکیب مدل‌های ساده می‌توانیم مدل‌های پیچیده‌تر بسازیم.

- متغیرهای تصادفی

یک متغیر تصادفی  $X$  (یا به بیان دقیق‌تر  $X(\omega)$ ) یک تابع از فضای نمونه  $\Omega$  به مجموعه اعداد حقیقی است. این تابع باید این خاصیت را داشته باشد که

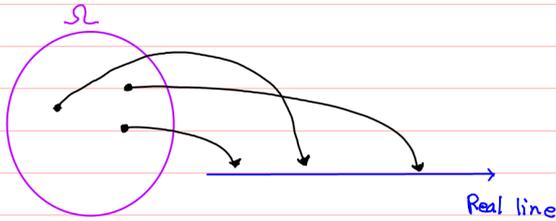
$$\{\omega : X(\omega) \leq a\}$$

به ازای هر  $a \in \mathbb{R}$  یک واقعه باشد.

- اگر بخواهیم از شکل استفاده کنیم داریم:

به بیان دیگر یک متغیر تصادفی فضای

نمونه  $\Omega$  را اندازه‌گیری (measure) می‌کند.



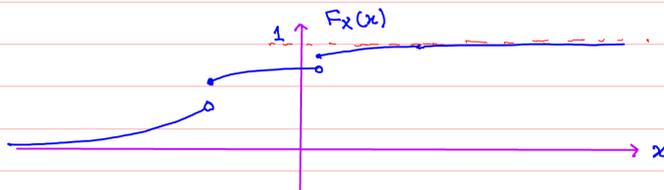
- اگر چندین متغیر تصادفی به طور همزمان بررسی یک آزمایش تصادفی تعریف می‌کنیم نمونه آنگاه باید

$$\{\omega : X_1(\omega) \leq a_1, \dots, X_n(\omega) \leq a_n\}$$

به ازای هر  $a_1, \dots, a_n \in \mathbb{R}$  واقعه باشد (در مورد چند متغیر تصادفی در ادامه بیشتر صحبت می‌کنیم).

- برای هر متغیر تصادفی  $X$  تابع توزیع (تبعی)  $F_X(x)$  به صورت زیر تعریف می‌شود

$$F_X(x) = P[X(\omega) \leq x]$$



- برخی از خواص تابع توزیع تبعی  $F_X(x)$ :

• این تابع یک تابع غیر نزولی است که از 0 تا 1 به خود محدود می‌گردد.

$$\lim_{x \rightarrow -\infty} F_X(x) = 0$$

$$\lim_{x \rightarrow \infty} F_X(x) = 1$$

• تابع  $F_X(x)$  از سمت راست پیوسته است:

$$\lim_{x \rightarrow 0^+} F_X(x + \varepsilon) = F_X(x) \quad ; \quad \forall x \in \mathbb{R}$$

- تعریف متغیر تصادفی گسسته و پیوسته:

• اگر  $X$  اعضای فضای نمونه را فقط به مقدار متناهی یا شمارایی بخمارا مقدار بگذارند در این صورت به آن متغیر تصادفی گسسته می‌گوئیم. در این حالت برای توصیف آن می‌توان از تابع چگالی احتمال (Probability mass function) استفاده کرد که به صورت زیر تعریف می‌گردد:

$$P_X(x) = P[X=x]$$

در این صورت تابع  $F_X(x)$  تابعی پیوسته نیست و در نقاطی که  $X$  به خود مقدار می‌دهد با احتمال نا صفر می‌گیرد. پیش دارد. در این حالت  $F_X(x)$  یک تابع پله‌کافی است.

• یک متغیر تصادفی پیوسته نامیده می‌شود اگر که یک تابع  $f_X(x)$  وجود داشته باشد که برای هر  $x \in \mathbb{R}$  تابع چگالی احتمال را بتوان به صورت زیر نوشت:

$$F_X(x) = \int_{-\infty}^x f_X(t) dt$$

اگر چنین تابعی وجود داشته باشد به آن تابع چگالی احتمال  $X$  می‌گوئیم.

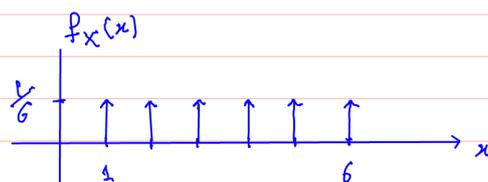
• اگر  $\frac{dF_X(x)}{dx}$  در همه نقاط موجود و متناهی باشد در این صورت  $X$  را یک متغیر تصادفی پیوسته می‌نامند. در این صورت تابع چگالی احتمال برای متغیر  $X$  به صورت زیر تعریف می‌گردد:

$$f_X(x) = \frac{dF_X(x)}{dx}$$

تعبیر دیگری که می‌توان برای چگالی احتمال دارد اینست که

$$f_X(x) = \lim_{\delta \rightarrow 0} \frac{P[x \leq X \leq x + \delta]}{\delta}$$

- نکته: گاهی برای اینکه متغیرهای تصادفی گسسته یا متغیرهای تصادفی ای که ترکیب گسسته و پیوسته هستند را یکجا در نظر بگیریم از تابع قهقهه در چگالی احتمال این متغیرها استفاده می‌کنیم.



مثلا برای یک تاس داریم:

$$f_X(x) = \sum_{i=1}^6 \frac{1}{6} \delta(x-i)$$

- اثبات اینکه  $F_X(x)$  تابعی از سمت راست پیوسته است.

• برای متغیر دلخواه  $X$  و عدد حقیقی  $x$  و هر عدد صحیح  $n \geq 1$  و تهایم زیر را تعریف می‌کنیم:

$$A_n = \left\{ \omega : X(\omega) > x + \frac{1}{n} \right\}$$

ی دامنه برای هر  $x$  :  $x + \frac{1}{n} \leq x + \frac{1}{n-1} \Rightarrow$  نتیجه

$$A_1 \subseteq A_2 \subseteq \dots$$

تعریف می‌کنیم:  $B_1 = A_1$  ,  $B_2 = A_2 - A_1$  ,  $B_k = A_k - A_{k-1}$

در این صورت  $B_k$  ها آنکترانی با یکدیگر ندارند (same disjoint).

$$P\left[\bigcup_{n \geq 1} A_n\right] = P\left[\bigcup_{k \geq 1} B_k\right] = \sum_{k=1}^{\infty} P[B_k] \quad \text{حال داریم:}$$

$$= \lim_{k \rightarrow \infty} \sum_{l=1}^k P[B_l]$$

$$= \lim_{k \rightarrow \infty} \left( P[A_1] + \sum_{l=2}^k P[A_l] - P[A_{l-1}] \right)$$

$$= \lim_{k \rightarrow \infty} P[A_k]$$

• با توجه به تعاریفی که کرده‌ایم داریم

$$A_n \subseteq \underbrace{\left\{ \omega : X(\omega) > x \right\}}_{\triangleq A_{\infty}}$$

و  $A_{\infty}$  کوچکترین مجموعه‌ای است که چنین خاصیتی دارد. بنابراین

$$\left\{ \omega : X(\omega) > x \right\} = \bigcup_{n=1}^{\infty} A_n$$

در نتیجه با استفاده از قسمت قبل داریم

$$P[X > x] = P\left[\bigcup_{n=1}^{\infty} A_n\right] = \lim_{n \rightarrow \infty} P[A_n] = \lim_{n \rightarrow \infty} P\left\{X > x + \frac{1}{n}\right\}$$

$$P[X \leq x] = \lim_{n \rightarrow \infty} P\left\{X \leq x + \frac{1}{n}\right\} \quad \text{• می‌نویسیم:}$$

$$\lim_{n \rightarrow \infty} F_X\left(x + \frac{1}{n}\right) = F_X(x) \quad \text{با این عبارتی}$$

چون دنباله  $x_n = x + \frac{1}{n}$  یک دنباله می‌گردد که افزایش می‌دهد  $x$  است پس حد از سمت راست

$F_X(x)$  وجود دارد و برابر خود  $F_X(x)$  است.

امید ریاضی متغیر تصادفی  $X$  را با  $E[X]$  نشان می‌دهیم. در واقع امید ریاضی یک متغیر تصادفی را می‌توان به عنوان بهترین تقریبی در نظر بگیریم اگرچه بتوانیم  $X$  را فقط با یک عدد تقریب بزنیم.

برای متغیرهای گسسته امید ریاضی به صورت زیر تعریف می‌کود:

$$E[X] = \sum_i a_i p_X(a_i)$$

در صورتی که این جمع وجود داشته باشد می‌گوییم امید ریاضی  $X$  وجود دارد.

برای متغیرهای پیوسته امید ریاضی به صورت زیر تعریف می‌کود:

$$E[X] = \int x f_X(x) dx$$

• برای متغیر تصادفی دلخواه و نامنتی  $X$  می‌توانیم امید ریاضی  $X$  را به صورت زیر هم بنویسیم:

$$E[X] = \int_0^{\infty} F_X^c(x) dx$$

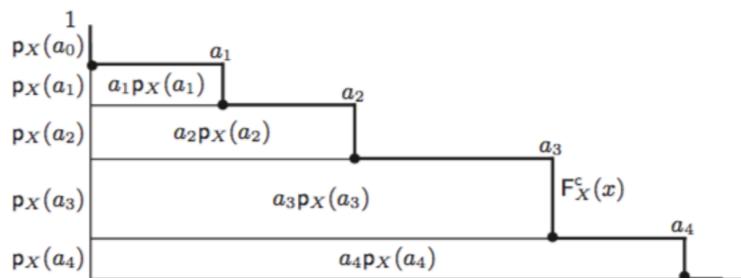
که:

$$F_X^c(x) = 1 - F_X(x) = P[X > x]$$

اگر آننگه‌ال فوق مشابه باشد می‌گوییم که امید ریاضی وجود دارد و در غیر این صورت می‌گوییم وجود ندارد یا متناهی نیست.

شکل زیر به طور شهودی رابطه بالا را برای یک مثال خاص و متغیرهای تصادفی گسسته نشان

می‌دهد:



The figure shows the complementary CDF  $F_X^c$  of a non-negative discrete rv  $X$ . For this example,  $X$  takes on five possible values,  $0 = a_0 < a_1 < a_2 < a_3 < a_4$ . Thus  $F_X^c(x) = \Pr\{X > x\} = 1 - p_X(a_0)$  for  $x < a_1$ . For  $a_1 \leq x < a_2$ ,  $\Pr\{X > x\} = 1 - p_X(a_0) - p_X(a_1)$ . Similar drops occur in  $\Pr\{X > x\}$  as  $x$  reaches  $a_2$ ,  $a_3$ , and  $a_4$ . From (1.28),  $E(X)$  is  $\sum_i a_i p_X(a_i)$ , which is the sum of the rectangles in the figure. This is also the area under the curve  $F_X^c(x)$ , i.e.,  $\int_0^{\infty} F_X^c(x) dx$ . It can be seen that this argument applies to any non-negative rv, thus verifying (1.30).

- تعریف امید ریاضی در حالت کلی :

در حالت کلی امید ریاضی یک متغیر تصادفی دلخواه را با رابطه زیر تعریف می‌کنیم :

$$\begin{aligned} E[X] &= - \int_{-\infty}^0 F_X(x) dx + \int_0^{\infty} F_X^c(x) dx \\ &= \int_{-\infty}^{+\infty} [u(x) - F_X(x)] dx \end{aligned}$$

$$u(x) = \begin{cases} 1 & x \geq 0 \\ 0 & \text{otherwise} \end{cases}$$

- متغیرهای تصادفی می‌توانند تابعی از متغیرهای تصادفی دیگر

اگر  $h: \mathbb{R} \rightarrow \mathbb{R}$  یک تابع باشد و  $X$  یک متغیر تصادفی باشد در این صورت  $Y = h(X)$  هم یک متغیر

تصادفی است که پیشامد  $\omega$  را به تابع ترکیبی  $h(X(\omega))$  می‌برد.

با استفاده از رابطه بالا تابع توزیع تجمعی  $Y$  را می‌توان حساب کرد و امید ریاضی  $Y$  را از روی آن به دست آورد.

ولی می‌توان نشان داد که در حالت گسسته امید ریاضی  $Y$  برابر است با :

$$E[Y] = \sum_x h(x) P_X(x)$$

و در حالت پیوسته برابر است با :

$$E[Y] = \int_{-\infty}^{+\infty} h(x) f_X(x) dx$$

با استفاده از انتگرال Stieltjes دو عبارت بالا را می‌توان به طور همزمان به صورت زیر نوشت . یعنی برای

متغیر تصادفی دلخواه  $X$  داریم :

$$E[Y] = \int_{-\infty}^{+\infty} h(x) dF_X(x)$$

در این درس در بیشتر مواقع از عبارت بالا به عنوان مختصر نویسی برای عبارت‌های بالا به‌کار می‌بریم.

متغیر گسسته و پیوسته استفاده می‌کنیم.

More specifically, the Riemann–Stieltjes integral, abbreviated here as the Stieltjes integral, is denoted as  $\int_a^b h(x) dF_X(x)$ . This integral is defined as the limit of a generalized Riemann sum,  $\lim_{\delta \rightarrow 0} \sum_n h(x_n)[F(y_n) - F(y_{n-1})]$ , where  $\{y_n; n \geq 1\}$  is a sequence of increasing numbers from  $a$  to  $b$  satisfying  $y_n - y_{n-1} \leq \delta$  and  $y_{n-1} < x_n \leq y_n$  for all  $n$ . The Stieltjes integral is defined to exist over finite limits if the limit exists and is independent of the choices of  $\{y_n\}$  and  $\{x_n\}$  as  $\delta \rightarrow 0$ . It exists over infinite limits if it exists over finite lengths and a limit over the integration limits can be taken. See Rudin [24] for an excellent elementary treatment of Stieltjes integration, and see Exercise 1.15 for some examples.

- گشتاورها و گشتاورهای مرکزی یک متغیر تصادفی (moments and central moments):

گشتاور  $n$ ام متغیر تصادفی  $X$  طبق تعریف برابر است با:  $E[X^n]$

گشتاور مرکزی  $n$ ام متغیر تصادفی  $X$  برابر است با:  $E[(X - \mu_x)^n]$   $\mu_x = E[X]$

گشتاور مرکزی دوم یک متغیر تصادفی را واریانس می گویند:  $Var[X] = E[(X - \mu_x)^2]$

- یک رابطه مهم بین امید ریاضی و واریانس (یا بین امید ریاضی و انحراف معیار) اینست که

$$E[(X - \alpha)^2]$$

نسبت به  $\alpha$  در نقطه  $\alpha = E[X]$  کمینه می شود. در واقع می توان  $\sqrt{E[(X - Y)^2]}$  را به عنوان فاصله بین دو متغیر تصادفی در نظر گرفت (در فضای برداری متغیرهای تصادفی).

- امید ریاضی یک همگام خطی است:

مستقل از اینکه متغیرهای تصادفی  $X_1, \dots, X_n$  مستقل یا وابسته باشند داریم  $(a_i \in \mathbb{R}, b \in \mathbb{R})$ :

$$E[a_1 X_1 + \dots + a_n X_n + b] = a_1 E[X_1] + \dots + a_n E[X_n] + b$$

- اگر  $X$  و  $Y$  دو متغیر تصادفی باشند و تعریف کنیم  $Z = X + Y$ ، آنگاه تابع توزیع تجمعی  $Z$  را می توانیم به صورت زیر محاسبه کنیم:

$$F_Z(z) = \int_{-\infty}^{+\infty} F_X(z-y) dF_Y(y) = \int_{-\infty}^{+\infty} F_Y(z-x) dF_X(x)$$

اگر  $X$  و  $Y$  هر دو تابع چگالی احتمال داشته باشند، عبارت آگنای کولوشن را می توانیم به این صورت محاسبه کنیم:

$$f_Z(z) = \int_{-\infty}^{+\infty} f_X(z-y) f_Y(y) dy = \int_{-\infty}^{+\infty} f_Y(z-x) f_X(x) dx$$

- امید ریاضی شرطی :

- اگر  $X$  و  $Y$  هر دو متغیر تصادفی متصادفی هستند؛ اگر  $P_Y(y) > 0$  باشد، امید ریاضی  $X$  به شرط واقع  $\{Y=y\}$  به صورت زیر تعریف می شود:

$$E[X|Y=y] = \sum_x x P_{X|Y}(x|y)$$

- اگر  $X$  متغیر تصادفی دلخواه و  $Y$  متغیر تصادفی گسسته باشد، و اگر  $P_Y(y) > 0$  باشد، تابع توزیع تجمعی  $X$  به شرط  $\{Y=y\}$  برابر است با:

$$F_{X|Y}(x|y) = \frac{P[X \leq x, Y=y]}{P[Y=y]}$$

بنابراین امید ریاضی شرطی  $X$  به شرط  $Y=y$  را به صورت زیر تعریف می کنیم:

$$E[X|Y=y] = - \int_{-\infty}^0 F_{X|Y}(x|y) dx + \int_0^{\infty} F_{X|Y}^c(x|y) dx$$

- اگر  $X$  و  $Y$  هر دو پیوسته باشند امید ریاضی شرطی برای توانیم بر حسب توابع چگالی احتمال تعریف کنیم. به عبارت دیگر داریم:

$$E[X|Y=y] = \int_{-\infty}^{+\infty} x f_{X|Y}(x|y) dx$$

- نکته: می توان امید ریاضی شرطی را به عنوان تابعی از  $Y$  در نظر گرفت مثل

$$g(y) = E[X|Y=y]$$

و بعد با استفاده از این تابع متغیر تصادفی جدید  $g(Y)$  را تعریف کرد. این متغیر تصادفی جدید را به صورت زیر نشان می دهند:

$$E[X|Y]$$

- قضیه امید ریاضی کل (Total expectation):

در حالت کلی این قضیه بیان می کند که

$$E[X] = E[E[X|Y]]$$

در حالت کلی قضیه حقوق جز میات تریای دارد که باید به آنها دقت کرد (مثل مسئله هگرایم و...)؛ ولی

برای حالتی که  $X$  و  $Y$  هم دوگسسته یا پیوسته باشند می توان رابطه بالا را به صورت زیر بیان کرد.

•  $X$  و  $Y$  هر دو گسسته:

$$\begin{aligned} \mathbb{E}[X] &= \mathbb{E}[\mathbb{E}[X|Y]] = \sum_y P_Y(y) \mathbb{E}[X|Y=y] \\ &= \sum_y P_Y(y) \sum_x x P_{X|Y}(x|y) \end{aligned}$$

•  $X$  و  $Y$  هر دو پیوسته:

$$\begin{aligned} \mathbb{E}[X] &= \mathbb{E}[\mathbb{E}[X|Y]] = \int_{-\infty}^{+\infty} f_Y(y) \mathbb{E}[X|Y=y] dy \\ &= \int_{-\infty}^{+\infty} f_Y(y) \int_{-\infty}^{+\infty} x f_{X|Y}(x|y) dx dy \end{aligned}$$

- تابع مولد گشتاور (Moment generating function):

تابع مولد گشتاور متغیر تصادفی  $X$  به صورت زیر تعریف می‌شود ( $r \in \mathbb{R}$ ):

$$\phi_X(r) = \mathbb{E}[e^{rx}] = \int_{-\infty}^{+\infty} e^{rx} dF_X(x)$$

$$= \int_{-\infty}^0 e^{rx} dF_X(x) + \int_0^{+\infty} e^{rx} dF_X(x)$$

این دو انتگرال همیشه در نقطه  $r=0$  وجود دارد و مقدارش برابر 1 است.

فرض  $r_+(x) = \sup r$  هایی باشد که انتگرال دوم وجود دارد. داریم:  $0 \leq r_+(x) \leq \infty$

در این صورت انتگرال دوم برای  $r < r_+(x)$  وجود دارد. به طریق مشابه  $r_-(x)$  یا  $r_-(x) = \inf r$  هایی تعریف می‌کنیم که

انتگرال اول جواب داد کند:  $-\infty \leq r_-(x) \leq 0$ .

اگر  $\phi_X(r)$  در یک بازه باز حول صفر وجود داشته باشد (یعنی  $r_- < 0 < r_+$ ) آنگاه مشتقات هر مرتبه‌ای از

$\phi_X(r)$  وجود دارند و داریم:

$$\frac{d^k \phi_X(r)}{dr^k} = \int_{-\infty}^{+\infty} x^k e^{rx} dF_X(x) \Rightarrow \left. \frac{d^k \phi_X(r)}{dr^k} \right|_{r=0} = \mathbb{E}[X^k]$$

- تابع مولد گشتاور جمع چند متغیر تصادفی مستقل  $(S_n = X_1 + \dots + X_n)$ :

$$\begin{aligned} \phi_{S_n}(r) &= E[e^{rS_n}] = E[e^{r(X_1 + \dots + X_n)}] \\ &= E\left[\prod_{i=1}^n \exp(rx_i)\right] = \prod_{i=1}^n \phi_{X_i}(r) \end{aligned}$$

↑  
با استفاده از استقلال  $X_i$  ها

اگر  $X_1, \dots, X_n$  متغیرهای تصادفی iid باشند داریم:

$$\phi_{S_n}(r) = [\phi_X(r)]^n$$

این رابطه بیان می کند توانی ای که  $\phi_X$  و  $\phi_{S_n}$  وجود دارند یکسان هستند.

- نامساوی های پایه در نظریه احتمال:

نامساوی ها نقش مهمی در احتمالات بازی می کنند زیرا که بسیاری از مدل ها پیچیده تر از آن هستند که بتوان جواب دقیق برای شان پیدا کرد. از طرف دیگر قضایای مقید بسیاری در مورد رفتارهای حدی صحبت می کنند نه جواب های دقیق. در ادامه نامساوی مارکوف (Markov) ، چبیشف (Chebyshev) و چرنف (Chernoff) صحبت می کنیم.

• نامساوی مارکوف:

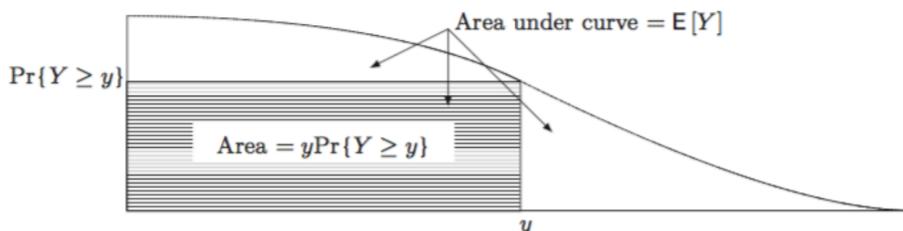
این نامساوی یکی از ساده ترین و پایه ای ترین نامساوی های احتمالاتی است.

اگر متغیر نامنفی  $Y$  امید ریاضی  $E[Y]$  داشته باشد آنگاه برای هر  $\alpha > 0$  داریم:

$$P[Y \geq \alpha] \leq \frac{E[Y]}{\alpha}$$

(برای اثبات می توان از این نکته استفاده کرد که:  $\alpha \leq \{Y \geq \alpha\} \cdot \alpha$ )

شکل زیر نیز روش دیگری برای درک این نامساوی است.



Demonstration that  $yPr\{Y \geq y\} \leq E[Y]$ . By letting  $y \rightarrow \infty$ , it can also be seen that the shaded area becomes a negligible portion of the area  $E[Y]$ , so that  $\lim_{y \rightarrow \infty} yPr\{Y > y\} = 0$  if  $E[Y] < \infty$ .

- نامساوی چیبیشف

حال با استفاده از نامساوی مارکوف نامساوی زیری بدست می آوریم.

فرض کنیم  $Z$  متغیر تصادفی دلخواهی با امید ریاضی  $\mu$  و واریانس متناهی باشد. متغیر نامنفی  $Y$

برای صورت  $Y = (Z - E[Z])^2$  تعریف می کنیم. بنابراین  $E[Y] = \sigma_Z^2$  پس با استفاده از

نامساوی مارکوف داریم:

$$P[(Z - E[Z])^2 \geq k] \leq \frac{\sigma_Z^2}{k} \quad \forall k > 0$$

رابطه بالا را می توان به شکل زیر بیان نمود کرد:

$$P[|Z - \mu| \geq \epsilon] \leq \frac{\sigma_Z^2}{\epsilon^2} \quad \forall \epsilon > 0$$

- چند نکته:

Note that the Markov inequality bounds just the upper tail of the CDF and applies only to non-negative r.v.s, whereas the Chebyshev inequality bounds both tails of the CDF. The more important differences, however, are that the Chebyshev bound requires a finite variance and approaches zero inversely with the square of the distance from the mean, whereas the Markov bound does not require a finite variance and goes to zero inversely with the distance from 0 (and thus asymptotically with distance from the mean).

- کران چرنف:

دیده ایم که نامساوی چیبیشف لزوماً نامساوی مارکوف بر متغیر تصادفی  $(Z - \mu)^2$  بدست آورد.

به طریق مشابهی کران چرنف هم از نامساوی مارکوف بر متغیر تصادفی  $e^{rZ}$  برای

یک  $r$  داده شده بدست می آید.

کران چرنف به صورت نمایی با افزایش فاصله از میانگین به سمت صفر میل می کند.

برای یک متغیر دلخواه  $Z$  فرض کنیم  $I(r)$  بازه ای باشد که ناحیه مولد گشتاور  $Z$  به آن متعلق ندارد.

با قرار دادن  $e^{rZ}$  برای  $r \in I(r)$  و استفاده از نامساوی مارکوف داریم:

$$P[e^{rZ} \geq \alpha] \leq \frac{\phi_Z(r)}{\alpha} \quad \forall \alpha > 0$$

برای اینکه رابطه ای معنادارتر بیان کنیم فرضی دهیم  $\alpha = e^{r\beta}$ . بنابراین برای هر  $\beta \in R$

$$P[Z \geq \beta] \leq \phi_Z(r) e^{-r\beta} \quad \forall r > 0, r \in I(r) \quad \text{داریم:}$$

$$P[Z \leq \beta] \leq \phi_Z(r) e^{-r\beta} \quad \forall r < 0, r \in I(r)$$

(به ازای  $r=0$  هر دو کران فوق نتیجه ای بدیهی می دهند).

در حالت کلی برای تست آردون بهترین کران باید عبارات فوق را نسبت به  $r$  بهینه کنیم.

• یکی از کاربردهای مهم کران چرنف برای جمع متغیرهای iid است. فرض کنید

$$S_n = X_1 + \dots + X_n \quad , \quad \phi_{X_i}(r) = \phi_X(r)$$

$$\Rightarrow \phi_{S_n}(r) = [\phi_X(r)]^n$$

بنابراین روابط بالا را می توان به صورت زیر نوشت:

$$P[S_n \geq na] \leq [\phi_X(r)]^n e^{-rna} \quad : \quad r > 0, r \in I(X)$$

$$P[S_n \leq na] \leq [\phi_X(r)]^n e^{-rna} \quad : \quad r < 0, r \in I(X)$$

**Lemma 1.6.1** Let  $\{X_i; i \geq 1\}$  be IID rvs and let  $S_n = X_1 + \dots + X_n$  for each  $n \geq 1$ . Let  $I(X)$  be the interval over which the semi-invariant MGF  $\gamma_X(r)$  is finite and assume  $0$  is in the interior of  $I(X)$ . Then, for each  $n \geq 1$  and each real number  $a$ ,

$$\Pr\{S_n \geq na\} \leq \exp(n\mu_X(a)) \quad \text{where } \mu_X(a) = \inf_{r \geq 0, r \in I(X)} \gamma_X(r) - ra. \quad (1.66)$$

Furthermore,  $\mu_X(a) < 0$  for  $a > \bar{X}$  and  $\mu_X(a) = 0$  for  $a \leq \bar{X}$ .

• در عمل محدودی از باند های کمتر tight ولی راحت تر زیر استفاده می کنیم:

$$P[S_n \geq (1+\delta) E[S_n]] \leq \exp\left(-\frac{\delta^2 E[S_n]}{3}\right), \quad 0 < \delta < 1$$

$$P[S_n \leq (1-\delta) E[S_n]] \leq \exp\left(-\frac{\delta^2 E[S_n]}{2}\right), \quad 0 < \delta < 1$$

- توانین اعداد بزرگ

توانین اعداد بزرگ به چوعدای از نتایج در تئوری احتمالات میگویند که رفتار میانگین حسابی (arithmetic average)  $n$  متغیر تصادفی را برای  $n$  های بزرگ توصیف می کند.

برای  $n$  متغیر تصادفی  $X_1, \dots, X_n$  میانگین حسابی آنگاه صورت زیر تعریف می شود:

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

از آنجایی که در هر توجی آزمایشی تصادفی مقدار نمونه (Sample Value) این متغیر تصادفی میانگین حسابی

مقادیر متغیرهای  $X_1, \dots, X_n$  در آن آزمایشی است به این متغیر تصادفی میانگین نمونه (sample avg.) هم گفته می شود.

اگر  $X_1, \dots, X_n$  را به عنوان متغیرهای متوالی ای در زمان در نظر بگیریم، این میانگین نمونه، میانگین زمانی نیز نامیده می شود.

تحت شرایط نسبتاً عمومی، اندک محیار میانگین نمونه با افزایش  $n$  به سمت 0 میل می کند. به این معنی که میانگین نمونه با امید ریاضی میل می کند.

این نتایج نقش محوری در بحث فرایندهای تصادفی دارند زیرا که اجازه می دهند متوسله زمانی (یعنی میانگین زمانی بر روی یک مسیر نمونه (Sample path)) را به متوسله گروهی (ensemble avg.) (یعنی امید ریاضی یک فرایند در یک زمان خاص) مربوط کنیم.

در اینجا در مورد قانون ضعیف اعداد بزرگ (weak law of large number) صحبت می کنیم.

همچنین اشاره به مفهومی به قانون قوی اعداد بزرگ می کنیم. در مورد قضیه حد مرکزی هم صحبت خواهیم کرد. هر به علت اینکه مفهوم ما از قانون اعداد بزرگ را افزایش می دهد و هم به علت اهمیت که مستقل دارد.

- قانون ضعیف اعداد بزرگ با واریانس مشابهی:

فرض کنید  $X_1, \dots, X_n$  متغیرهای iid باشند که امید ریاضی  $\mu$  و واریانس  $\sigma^2$  دارند. تعریف می کنیم:

$$S_n = X_1 + \dots + X_n$$

و میانگین نمونه را به صورت  $\frac{S_n}{n}$  در نظر می گیریم. چون  $X_i$  ها مستقل از یکدیگر هستند، داریم:

$$\sigma_{S_n}^2 = n\sigma^2$$

بنابراین برای واریانس  $\frac{S_n}{n}$  داریم:

$$\text{Var}\left[\frac{S_n}{n}\right] = \mathbb{E}\left[\left(\frac{S_n - n\mu}{n}\right)^2\right] = \frac{1}{n^2} \mathbb{E}\left[(S_n - n\mu)^2\right] = \frac{\sigma^2}{n}$$

همانطور که می بینیم واریانس میانگین نمونه  $\frac{S_n}{n}$  با افزایش  $n$  به سمت 0 می رود.

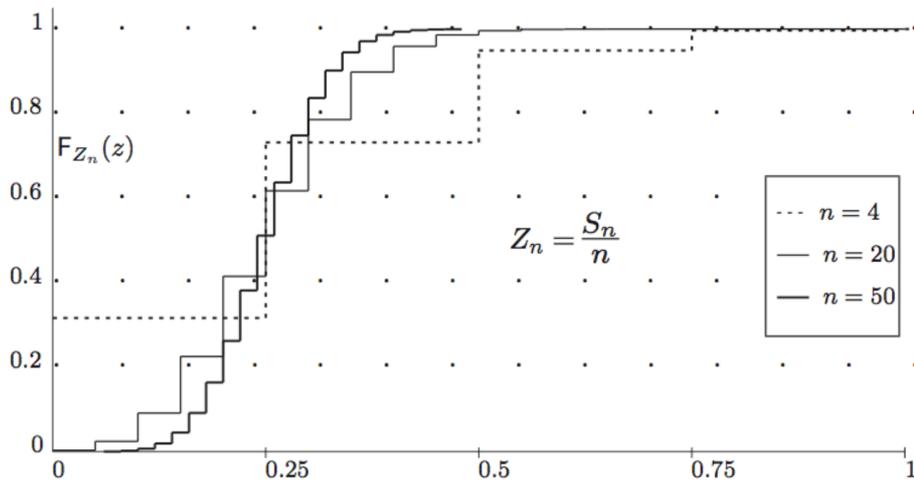
(توجه کنید که واریانس  $S_n$  با افزایش  $n$  به سمت  $\infty$  می رود ولی واریانس  $\frac{S_n}{n}$  به سمت 0 می رود).

از عبارت بالا نتیجه می گیریم:

$$\lim_{n \rightarrow \infty} \mathbb{E}\left[\left(\frac{S_n}{n} - \mu\right)^2\right] = 0$$

در این شرایط می گوئیم  $\frac{S_n}{n}$  به صورت mean square به  $\mu$  (امید ریاضی  $X_i$  ها) میل می کند.

شکل زیر نحوه کاهش واریانس  $\frac{S_n}{n}$  با افزایش  $n$  را نشان می دهد:



The same CDF as Figure 1.5, scaled differently to give the CDF of the sample average  $Z_n$ . It can be visualized that as  $n$  increases, the CDF of  $Z_n$  becomes increasingly close to a unit step at the mean, 0.25, of the variables  $X$  being summed.

هنگامی به صورت mean square بیان می کنند که میانگین نمونه  $Z_n = \frac{S_n}{n}$  با امید ریاضی  $\mathbb{E}[X_i] = \mu$

به اندازه یک متغیر تصادفی اختلاف دارد که با افزایش  $n$  واریانس آن به سمت 0 می رود.

در اینجا در باره هنگامی یک دنباله از متغیرهای تصادفی (یک دنباله از توالی) که به یک عدد ثابت میل می کنند صحبت

می کنیم که مسئله پیچیده تری از هنگامی یک دنباله از اعداد به یک عدد ثابت است. در ادامه این نوشتار در این باره

بیشتر صحبت خواهیم کرد.

قانون اعداد بزرگ این لیده مرکزی را به طریق بنیادی تری برجسته می کند.

فرض کنید نامساوی چیسف را به میانگین نمونه  $\frac{S_n}{n}$  اعمال کنیم:

$$(1.74) \quad P\left[\left|\frac{S_n}{n} - \mu\right| > \epsilon\right] \leq \frac{\text{Var}\left(\frac{S_n}{n}\right)}{\epsilon^2} = \frac{\sigma^2}{n\epsilon^2}$$

این عبارت کران بالایی برای احتمال اینکه  $\frac{S_n}{n}$  بیش از  $\epsilon$  با  $\mu$  متفاوت باشد بیان می کند.

مشکل قبل که تابع توزیع تجمعی  $\frac{S_n}{n}$  را برای چندین  $n$  رسم کرده این مسئله را نشان می دهد. شکل فوق بیان

$$\lim_{n \rightarrow \infty} F_{S_n/n}(z) = 0 \quad : \quad z < \mu$$

$$\lim_{n \rightarrow \infty} F_{S_n/n}(z) = 1 \quad : \quad z > \mu$$

تقریب زیر که به قانون ضعیف اعداد بزرگ (WLLN) مشهور است این مسئله را به نحو روشنی تر بیان می کند.

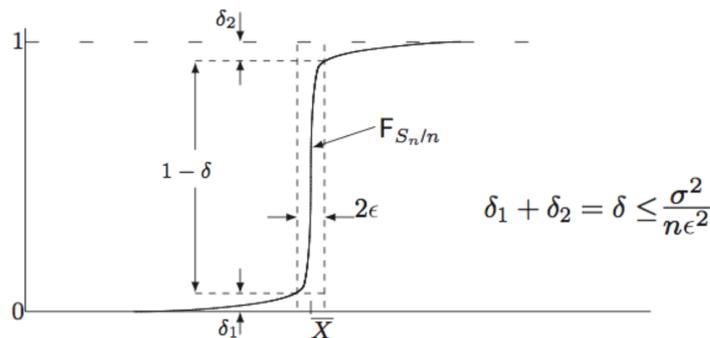
• قضیه (قانون ضعیف اعداد بزرگ با ولریانس متناهی):

برای هر  $n > 1$  فرض کنید  $S_n = X_1 + \dots + X_n$  جمع  $n$  متغیر تصادفی iid با ولریانس متناهی باشد. در این صورت:

$$\lim_{n \rightarrow \infty} P\left[\left|\frac{S_n}{n} - \mu\right| > \epsilon\right] = 0 \quad : \quad \forall \epsilon > 0$$

برای اثبات می توان از نامساوی چیسف که در بالا نوشته شده استفاده کرد.

البته شکل زیر نیز به فهم بهتر مطلب کمک می کند چرا CDF  $\frac{S_n}{n}$  به تابع پله میل می کند.



Approximation of the CDF  $F_{S_n/n}$  of a sample average by a step function at the mean. From (1.74), the probability  $\delta$  that  $S_n/n$  differs from  $\bar{X}$  by more than  $\epsilon$  (i.e.,  $\Pr\{|S_n/n - \bar{X}| \geq \epsilon\}$ ) is at most  $\sigma^2/n\epsilon^2$ . The complementary event, where  $|S_n/n - \bar{X}| < \epsilon$ , has probability  $1 - \delta \geq 1 - \sigma^2/n\epsilon^2$ . This means that we can construct a rectangle of width  $2\epsilon$  centered on  $\bar{X}$  and of height  $1 - \delta$  such that  $F_{S_n/n}$  enters the rectangle at the lower left (say at  $(\bar{X} - \epsilon, \delta_1)$ ) and exits at the upper right, say at  $(\bar{X} + \epsilon, 1 - \delta_2)$ . Now visualize increasing  $n$  while holding  $\epsilon$  fixed. In the limit,  $1 - \delta \rightarrow 1$  so  $\Pr\{|S_n/n - \bar{X}| \geq \epsilon\} \rightarrow 0$ . Since this is true for every  $\epsilon > 0$  (usually with slower convergence as  $\epsilon$  gets smaller),  $F_{S_n/n}(z)$  approaches 0 for every  $z < \bar{X}$  and approaches 1 for every  $z > \bar{X}$ , i.e.,  $F_{S_n/n}$  approaches a unit step at  $\bar{X}$ . Note that there are two 'fudge factors' here,  $\epsilon$  and  $\delta$  and, since we are approximating an entire CDF, neither can be omitted, except by directly going to a limit as  $n \rightarrow \infty$ .

$$F_{S_n/n}(\mu + \epsilon) - F_{S_n/n}(\mu - \epsilon) = P\left[\left|\frac{S_n}{n} - \mu\right| < \epsilon\right] = 1 - \delta \gg 1 - \frac{\sigma^2}{n\epsilon^2}$$

به هکرای ای که در قضیه بالا مطرح شده است نگاه ای در احتمال (in probability) می گوئیم.

یک نکته مهم در مورد رابطه (1.74) اینست که کران فوق خیلی خل (loose) است. در واقع اگر تابع مولد گشتاور  $X_i$  در یک یا تره حول 0 وجود داشته باشد می توان نامساوی چبیشف را توسط کران چرنف خیلی بهبود بخشید.

$$P\left[\left|\frac{S_n}{n} - \mu\right| \geq \epsilon\right] \leq \underbrace{P\left[\frac{S_n}{n} \geq \mu + \epsilon\right]} + \underbrace{P\left[-\frac{S_n}{n} \geq -\mu + \epsilon\right]}$$

به صورت نمایی نسبت به  $n$  کوچک می شوند.

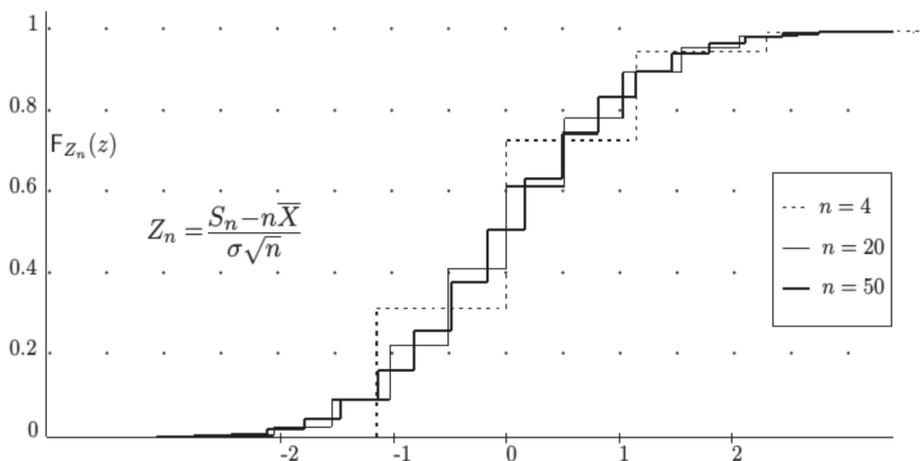
- قضیه حد مرکزی (Central limit theorem):

قانون ضعیف اعداد بزرگ بیان می کند که با احتمال زیاد  $\frac{S_n}{n}$  نزدیک  $\mu$  است برای  $n$  های بزرگ. همانطور که در شکل های قبل دیدیم تابع توزیع تجوی  $\frac{S_n}{n}$  با افزایش  $n$  حول  $\mu$  فشرده و فشرده تر می شود تا در نهایت در حد  $n \rightarrow \infty$  به صورت یک تابع پله در بیاید.

حال اگر متغیر  $\frac{S_n}{n}$  را به یک متغیر با امید ریاضی 0 و واریانس 1 نرمالیزه کنیم متغیر نرمالیزه شده زیر را

$$Z_n = \frac{\frac{S_n}{n} - \mu}{\sigma/\sqrt{n}} = \frac{S_n - n\mu}{\sigma\sqrt{n}} \quad \text{داریم:}$$

تابع توزیع تجوی  $Z_n$  برای همان مقادیر  $n$  که در شکل های قبلی استفاده شده است را در شکل زیر می بینیم. تفاوت این شکل با شکل قبل در این است که محور افقی آن مقیاس شده است.



The same CDFs as Figure 1.5 normalized to 0 mean and unit standard deviation, i.e., the CDFs of  $Z_n = (S_n/n - \bar{X})\sqrt{n}/\sigma$  for  $n = 4, 20, 50$ . Note that as  $n$  increases, the CDF of  $Z_n$  slowly starts to resemble the normal CDF.

با مشاهده شکل قبل، به نظری آید که تابع توزیع تجمعی متغیر نرمالیزه شده  $Z_n$  به یک توزیع خاص میل می‌کند. این مسئله در قضیه زیر بیان شده است.

• قضیه حد مرکزی (Central Limit Theorem):

فرض کنید  $X_1, \dots, X_n$  متغیرهای تصادفی iid با امید ریاضی متناهی  $\mu$  و واریانس متناهی  $\sigma^2$  باشند. برای هر  $z \in \mathbb{R}$  داریم:

$$\lim_{n \rightarrow \infty} P\left[\frac{S_n - n\mu}{\sigma\sqrt{n}} \leq z\right] = \Phi(z)$$

که  $\Phi(z)$  تابع توزیع تجمعی توزیع نرمال است:

$$\Phi(z) = \int_{-\infty}^z \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{t^2}{2}\right) dt$$

قضیه بالا بیان می‌کند که:

$$\lim_{n \rightarrow \infty} F_{Z_n}(z) = \Phi(z) \quad : \forall z \in \mathbb{R}$$

به این نوع همگرایی، همگرایی در توزیع (Convergence in dist.) گفته می‌شود، چرا که به جای اینکه دنباله‌ای از متغیرهای تصادفی همگرا شوند دنباله‌ای از توابع توزیع تجمعی همگرا می‌شوند.

پس نکته:

• قضیه حد مرکزی در مورد نحوه میل کردن تابع توزیع تجمعی  $\frac{S_n}{n}$  به تابع پایه بیشتر اطلاعات می‌دهد.

در واقع با افزایش  $n$   $\frac{S_n}{n}$  نزدیک به توزیع  $N\left(\mu, \frac{\sigma^2}{n}\right)$  می‌شود.

• لغت "مرکزی" در نام قضیه اشاره به این دارد که بر خلاف گران چرnof در این قضیه احتمال

اینکه میانگین نمونه به اندازه مقداری که به صورت  $\frac{1}{\sqrt{n}}$  مقیاس می‌گردد از امید ریاضی فاصله داشته

باشد محاسبه می‌گردد. در گران چرnof مقدار تفاوت یک عدد ثابت است که به گران بالای

برای احتمال منتفی می‌گردد که به صورت نمایی نسبت به  $n$  کاهش می‌یابد.

• قضیه مرکزی توضیح می‌دهد که چرا در بسیاری از مسائل فرض ضمنی اینکه متغیر خاصی توزیع نرمال

دارد تا آنکه به نتایج معقولی منتفی می‌گردد.

• باید دقت کرد که در مورد قضیه حد مرکزی به دقت بیشتر از چیزی که ممکن است نکتیم. به عنوان

مثال متغیر  $\frac{S_n - n\mu}{\sigma\sqrt{n}}$  لزوماً تابع گیلالی احتمالی که با تقریب گاوسی باشد ندارد.

اگر متغیرهای  $X_i$  گسسته باشند این مجموع نرمالیزه شده یک متغیر تصادفی گسسته است و تابع چگالی احتمال برای آن وجود ندارد ولی به علت اشتراک گسسته بودن اثر این گسستگی ها محو می شود و تابع توزیع تجمعی این متغیر به تابع توزیع تجمعی نرمال میل می کند.

- همگرایی متغیرهای تصادفی:

تا اینجا در قانون ضعیف اعداد بزرگ و قضیه حد مرکزی دو نوع همگرایی دنباله ای از متغیرهای تصادفی را دیده ایم. دنباله ای از متغیرهای تصادفی عملاً دنباله ای از توابع هستند که بر روی فضای نمونه تعریف شده اند و همگرایی آنها پیچیده تر از همگرایی دنباله ای از اعداد است.

در ادامه چهار نوع همگرایی برای متغیرهای تصادفی معرفی می کنیم که عبارتند از:

همگرایی در توزیع، همگرایی در احتمال، همگرایی با معیار mean square و همگرایی با احتمال 1.

• تعریف: همگرایی در توزیع (Convergence in dist.)

می گوییم یک دنباله از متغیرهای تصادفی  $X_1, \dots, X_n$  در توزیع به متغیر تصادفی  $X$  همگرای کولمب اگر که:

$$\lim_{n \rightarrow \infty} F_{X_n}(x) = F_X(x)$$

به ازای همه  $x$ هایی که  $F_X(x)$  پیوسته باشد.

در قضیه حد مرکزی متغیرهایی که در توزیع همگرای کولمب هستند که  $\left\{ \frac{S_n - n\mu}{\sigma\sqrt{n}} \right\}$  و  $n \geq 1$  هستند که به توزیع نرمال همگرای کولمب.

دقت کنید که این همگرایی به این معنی نیست که متغیرهای تصادفی دنباله می یک متغیر خاص میل می کنند بلکه فقط توزیع آنها به یک توزیع خاص میل می کند.

به عنوان مثال دنباله ای از متغیرهای تصادفی iid  $Y_1, \dots, Y_n$  را با تابع توزیع تجمعی  $F_Y$  در نظر بگیرید. برای هر  $n \geq 1$  تعریف می کنیم:

$$Z_n = Y_n + \frac{1}{n}$$

به راحتی می توان بررسی کرد که دنباله متغیرهای  $Z_n$  در توزیع به  $Y$  میل می کنند. هر چند که اگر فرض

کنیم  $Y$  از  $Z_i$  ها مستقل باشد، آنگاه  $Z_n - Y$  دارای چگالی  $2\sigma^2$  دارد. بنابراین  $Z_n$  با افزایش

$n$  به  $Y$  نزدیک نمی شود. همچنین  $Z_n - Z_m$  نیز با افزایش  $m$  و  $n$  کوچک نمی شود.

فقط مشابه نیز برای قضیه حد مرکزی می توان ترکه هر کدام از جمله  $Z_n$  در بنامه

$$\frac{S_n - n\mu}{\sigma\sqrt{n}}$$

حتی با افزایش  $n$  به هم نزدیک نمی شوند و به متغیر خاصی هم میل نمی کنند.

• تعریف: همگرایی در احتمال (Convergence in Prob.)

می گوئیم یک دنباله از متغیرهای تصادفی  $X_1, \dots, X_n$  در احتمال به متغیر  $X$  همگرا می شود اگر که:

$$\lim_{n \rightarrow \infty} P[|X_n - X| > \epsilon] = 0 \quad ; \quad \forall \epsilon > 0$$

همگرایی در احتمال نسبت به همگرایی در توزیع اطلاعات بیشتری در مورد دنباله متغیرهای تصادفی

می دهد. به عنوان مثال اگر  $\{X_n, n \geq 1\}$  در احتمال به 0 میل کند آنگاه برای  $m$  و  $n$  به اندازه

کافی بزرگ  $X_m$  و  $X_n$  با احتمال زیاد نزدیک هستند و بنابراین نزدیک یکدیگر هستند:

$$\lim_{m \rightarrow \infty, n \rightarrow \infty} P[|X_m - X_n| > \epsilon] = 0 \quad ; \quad \forall \epsilon > 0$$

به بیان دقیق تر داریم:

$$P[|X_m - X_n| > \epsilon] \leq P[|X_m - 0| + |X_n - 0| > \epsilon] \quad \text{بنابراین:}$$

$$\leq P[|X_m - 0| > \frac{\epsilon}{2} \text{ or } |X_n - 0| > \frac{\epsilon}{2}]$$

$$\leq P[|X_m - 0| > \frac{\epsilon}{2}] + P[|X_n - 0| > \frac{\epsilon}{2}]$$

$$\xrightarrow{n \rightarrow \infty} 0$$

• تعریف: همگرایی با معیار mean square:

می گوئیم یک دنباله از متغیرهای تصادفی  $X_1, \dots, X_n$  با معیار MS به متغیر  $X$  همگرا می شود اگر که:

$$\lim_{n \rightarrow \infty} E[(Z_n - Z)^2] = 0$$

توجه کنید که همگرایی با معیار MS همگرایی در احتمال را نتیجه می دهد.

• تعریف: همگرایی با احتمال 1 (Convergence with prob. 1):

به این نوع همگرایی almost surely و almost everywhere هم گفته می‌شود.

مفروض کنید  $X_1, \dots, X_n$  دنباله‌ای از متغیرهای تصادفی بر روی فضای نمونه  $\Omega$  باشند و

$X$  نیز متغیر تصادفی دیگری بر روی  $\Omega$  باشد.

می‌گوییم  $\{X_n, n \geq 1\}$  به  $X$  با احتمال 1 همگرا می‌شود اگر:

$$\mathbb{P}\left[\omega \in \Omega : \lim_{n \rightarrow \infty} Z_n(\omega) = Z(\omega)\right] = 1$$

به ازای هر  $\omega \in \Omega$  یک مسیر نمونه (Sample path) که دنباله‌ای از اعداد است داریم. این دنباله از

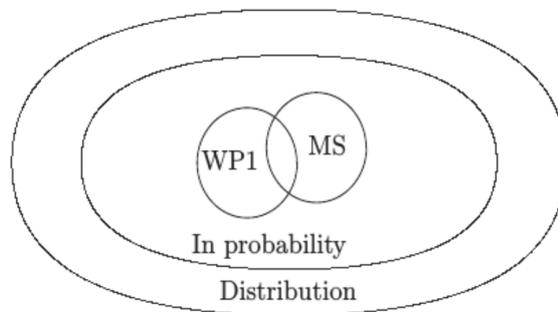
اعداد ممکن ممکن است به عدد  $Z(\omega)$  همگرا شود یا به عدد دیگری همگرا شود یا اصلاً همگرا

نشود.

همگرایی با احتمال 1 می‌گوید که مجموعه‌ای از مسیرهای  $\omega$  که مسیر نمونه  $Z_n(\omega)$  به  $Z(\omega)$  میل

می‌کند، با احتمال 1 است.

شکل زیر رابطه بین انواع همگرایی برای متغیرهای تصادفی را نشان می‌دهد:



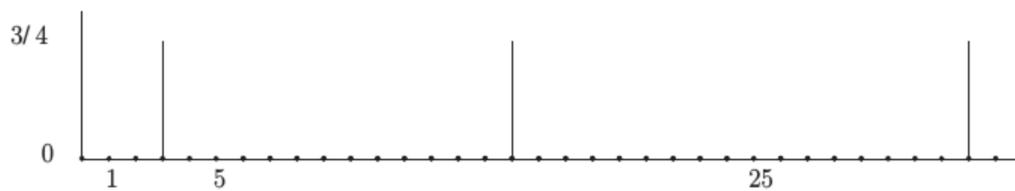
Relationship between different kinds of convergence: Convergence in distribution is the most general and is implied by all the others. Convergence in probability is the next most general and is implied both by convergence with probability 1 (WP1) and by mean-square (MS) convergence, neither of which implies the other.

مثال غیر در بنای از دستگیرهای مقادیری تعریف می‌کنند که در افعال گنگا می‌گویند ولی با افعال 1  
گنگا اینی گویند.

**Example 1.7.9** Consider a sequence  $\{Y_n; n \geq 1\}$  of rv s for which the sample paths constitute the following slight variation of the sequence of real numbers in Figure 1.16. In particular, as illustrated in Figure 1.17, the non-zero term at  $n = 5^j$  in Figure 1.16 is replaced by a non-zero term at a randomly chosen  $n$  in the interval<sup>34</sup>  $[5^j, 5^{j+1})$ .

Since each sample path contains a single one in each segment  $[5^j, 5^{j+1})$ , and contains zeroes elsewhere, none of the sample paths converges. In other words,  $\Pr\{\omega : \lim Y_n(\omega) = 0\} = 0$ . On the other hand,  $\Pr\{Y_n = 0\} = 1 - 5^{-j}$  for  $5^j \leq n < 5^{j+1}$ , so  $\lim_{n \rightarrow \infty} \Pr\{Y_n = 0\} = 1$ .

Thus this sequence of rv s converges to 0 in probability, but does not converge to 0 WP1. This sequence also converges in mean square and (since it converges in probability) in distribution. Thus we have shown (by example) that convergence WP1 is not implied by any of the other types of convergence we have discussed. We will show in Section 5.2 that convergence WP1 does imply convergence in probability and in distribution but not in mean square (as illustrated in Figure 1.14).



**Figure 1.17** Illustration of a sample path of a sequence of rv s  $\{Y_n; n \geq 0\}$  where, for each  $j \geq 0$ ,  $Y_n = 1$  for an equiprobable choice of  $n \in [5^j, 5^{j+1})$  and  $Y_n = 0$  otherwise.