

# مدل سازی و ارزیابی سیستم های کامپیووتری

امتحان پایان ترم٪۷۰

ارایه مقاله٪۱۵

گزارش پژوهشی٪۱۵

**مراجع درس:**

- 1-“Introduction to computer system performance Evaluation”,  
k.kant, Mcgraw-Hill/1992.**  
( کتاب اصلی درس است).
- 2-“Performance modeling of communication Networks and computerArchitecture”,  
Peter G. Harison and Naresh M. pattle, Addison- wesley pub 1td/1993.**
- 3-“Computer systems performance evaluation”, O. ferrari, 1978/prentice- Hall Inc.**
- 4-“Computer systems performance Modeling”, C.H. sauer and K.M. chandy,  
prentice- Hall/1981.**
- 5-“Reversibility and stochastic Networks”, F.P Kelly, John-willey/1979.**
- 6. "Performance by Design: Computer capacity planning by example." Prentice  
Hall, 2004 (NEW**
- 7. " Capacity Planning for web Services: metrics, models, and methods," Prentice  
Hall. 2002 (translated into Russian and Portuguese).**
- 8. "Scaling for E-Business: technologies, models, performance, and  
capacity planning." Prentice Hall, 2000 (translated into Korean)**
- 10. " Capacity Planning and performance Modeling: form mainframes to client-  
server System", Prentice- Hall, 1998.**
- 9. " Capacity Planning for Web Performance: metrics, models, and methods",  
Prentice Hall, 1998.**

# ضرورت بررسی احتمالی

- ضرورت بررسی احتمالی

- عدم قطعیت فرایند ها ( سیستم های چند پردازنده ای و چند برنامه ای )
- برای انتخاب یک مدل احتمالی مناسب می توان پدیده مورد نظر را نمونه برداری نموده و با توزیع مناسب پارامترهای سیستم را تخمین نمود.

- فضای نمونه

- دسترسی اطلاعات توسط CPU

- طاس

- پیشامد

- احتمال

# متغیر تصادفی گسته

- به  $X$  یک متغیر تصادفی گسته گفته می‌شود اگر تعداد مقادیر امکان‌پذیر  $X$  متناهی (finite) یا قابل شمارش (شمارا) (countably finite) باشد.

برای مثال کارهای واردہ به یک کارگاه را در نظر بگیرید:

- تعداد کارهای واردہ در یک هفته را با متغیر تصادفی  $X$  نشان می‌دهیم.
- فضای برد (range space) مقادیر امکان‌پذیر  $X$  را با  $R_x$  نشان می‌دهیم:
- احتمال اینکه مقدار متغیر برابر با  $x$  باشد را با  $p(x)$  نشان می‌دهیم:
- برای  $i = 1, 2, \dots$   $p(x_i)$  باید در شرایط زیر صدق کند:

$$1. p(x_i) \geq 0, \text{ for all } i$$

$$2. \sum_{i=1}^{\infty} p(x_i) = 1$$

- به مجموعه زوجهای مرتب  $[x_i, p(x_i)]$  توزیع احتمالی جرم احتمالی (probability distribution) و به  $p(x_i)$  تابع (pmf: probability mass function) متغیر تصادفی  $X$  گفته می‌شود.


# متغیر تصادفی گسته

- مثال
- یک مجموعه ای ۱۰۰ تایی از برنامه های کامپیووتری مورد بررسی قرار گرفت و ۲۰ برنامه خطای syntax، ۱۰ برنامه خطای I/O، ۵ برنامه Syntax && I/O، ۳ برنامه other، ۶ برنامه Syntax && other و ۲ برنامه شامل هر نوع خطای باشد.
- احتمال اینکه برنامه شامل خطای syntax یا I/O و یا هر دو خطای شود؟
- احتمال اینکه برنامه خطای داشته باشد؟
- احتمال اینکه برنامه خطای نداشته باشد؟

# متغیر تصادفی پیوسته

- به  $X$  یک متغیر تصادفی پیوسته گفته می‌شود اگر فضای برد ( $R_x$ ) آن یک بازه (پیوسته) یا مجموعه‌ای از بازه‌ها باشد.
- احتمال اینکه  $X$  در بازه  $[a, b]$  قرار گرفته باشد به صورت زیر بدست می‌آید:

$$P(a \leq X \leq b) = \int_a^b f(x)dx$$



- به  $f(x)$  تابع چگالی احتمالی (pdf: probability density function) گفته می‌شود.

## متغیر تصادفی پیوسته

$f(x)$  باید در شرایط ذیل صدق نماید: ■

1.  $f(x) \geq 0$ , for all  $x$  in  $R_X$
2.  $\int_{R_X} f(x) dx = 1$
3.  $f(x) = 0$ , if  $x$  is not in  $R_X$


خصوصیت‌ها: ■

1.  $P(X = x_0) = 0$ , because  $\int_{x_0}^{x_0} f(x) dx = 0$
2.  $P(a \leq X \leq b) = P(a < X \leq b) = P(a \leq X < b) = P(a < X < b)$

## متغیر تصادفی پیوسته

- مثال: فرض کنید که  $X$  یک متغیر تصادفی پیوسته که نماینده طول عمر یک دستگاه بوده و دارای pdf زیر باشد:

$$f(x) = \begin{cases} \frac{1}{2}e^{-x/2}, & x \geq 0 \\ 0, & \text{otherwise} \end{cases}$$



□ بعده خواهیم دید که  $X$  دارای توزیع نمایی با میانگین ۲ سال است.

- احتمال اینکه طول عمر دستگاه بین ۲ تا ۳ سال باشد برابر خواهد بود با:  
$$P(2 \leq x \leq 3) = \frac{1}{2} \int_2^3 e^{-x/2} dx = 0.14$$

# تابع توزیع تجمعی

■ تابع توزیع تجمعی (cumulative distribution function (cdf)) یک متغیر تصادفی  $X$  با  $F(X)$  یا  $F_x$  نشان داده شده و به صورت زیر تعریف می‌شود:

□  $F(x) = F_x = P(X \leq x)$

$$F(x) = \sum_{\substack{\text{all} \\ x_i \leq x}} p(x_i) \quad \text{اگر } X \text{ گسسته باشد:} \quad \square$$

$$F(x) = \int_{-\infty}^x f(t)dt \quad \text{اگر } X \text{ پیوسته باشد:} \quad \square$$

■ خصوصیت‌ها:

1.  $F$  is nondecreasing function : If  $a < b$ , then  $F(a) \leq F(b)$

2.  $\lim_{x \rightarrow \infty} F(x) = 1$

3.  $\lim_{x \rightarrow -\infty} F(x) = 0$

■ همه پرسش‌های احتمالی در باره  $X$  بر حسب cdf قابل پاسخگویی است. برای مثال:

$$P(a < X \leq b) = F(b) - F(a), \text{ for all } a < b$$

# تابع توزیع تجمعی

■ برای مثال در مورد توزیع احتمالی دستگاه مورد بحث خواهیم داشت:

$$F(x) = \frac{1}{2} \int_0^x e^{-t/2} dt = 1 - e^{-x/2}$$

□ احتمال اینکه این دستگاه کمتر از دو سال عمر کند چقدر است؟

$$P(0 \leq X \leq 2) = F(2) - F(0) = F(2) = 1 - e^{-1} = 0.632$$

□ احتمال اینکه این دستگاه دو الی سه سال عمر کند چقدر است؟

$$P(2 \leq X \leq 3) = F(3) - F(2) = (1 - e^{-(3/2)}) - (1 - e^{-1}) = 0.145$$

# فرایند تصادفی

- **اعداد تصادفی (random numbers):** اعداد حقیقی مستقلی هستند که به صورت یکنواخت در بازه  $(0, 1]$  توزیع شده‌اند:
  - این اعداد حاصل الگوریتم‌های تولید اعداد تصادفی (R.N. Generator) یا اعداد شبیه‌تصادفی (Pseudo R.N.G.) هستند.
  - در قالب جدولهایی از اعداد تصادفی نیز در دسترس هستند.
- **متغیر تصادفی (random variable):** یک تابع ریاضی است که برآمدهای (outcome) یک آزمایش تصادفی را به اعداد نگاشت می‌کند. برای مثال یک متغیر تصادفی می‌تواند برای توصیف فرایند پرتاپ یک تاس و برآمدهای احتمالی  $\{1, 2, 3, 4, 5, 6\}$  استفاده شود.

# فرایند تصادفی

□ تعریف ریاضی متغیر تصادفی: تابعی به صورت زیر است:

$$X: \Omega \rightarrow R_X$$

که در آن  $X$  یک متغیر تصادفی،  $\Omega$  یک فضای احتمالی (probability space) و  $R_X$  یک فضای برد (range space) است.

□ اگر  $R_X$  گسته باشد:

- $p(x_i) = \text{probability } X \text{ is } x_i = P(X = x_i)$  is called **pmf** (تابع جرم احتمالی)
- $[x_i, p(x_i)]$  is called discrete probability distribution

□ اگر  $R_X$  پیوسته باشد:

- $p(x) = P(a \leq X \leq b) = \int_a^b f(x)dx$  is called **pdf** (تابع چگالی احتمالی)

# فرایند تصادفی

■ فرایند تصادفی (stochastic or random process): اگر به هر کدام از مقادیر متغیر تصادفی  $X$  یک اندیس زمان منسوب کنیم،  $X$  یک فرایند تصادفی خواهد بود، که به صورت  $\{X(t), t \in T\}$  یا  $\{X_t, t \in T\}$  نشان داده می‌شود.

- اگر  $X$  یک فرایند تصادفی باشد،  $X(t)$  یک متغیر تصادفی است.
- در نتیجه فرایند تصادفی  $X$  عناصر فضای دو بعدی  $\Omega \times T$  را به عناصر  $R_X$  نگاشت می‌کند:  
$$X : \Omega \times T \rightarrow R_X$$
- به  $t$  پارامتر زمان (time parameter) گفته می‌شود که می‌تواند گسته یا پیوسته باشد:

- در حالت گسته  $T = N_0 = \{0, 1, \dots\}$  : (discrete-parameter)
- در حالت پیوسته  $T = (0, \infty)$  : (continuous-parameter) (مجموعه اعداد حقیقی مثبت)
- به مجموعه مقادیر  $(X(t), \text{فضای حالت})$  فرایند تصادفی گفته می‌شود که با  $S$  نشان داده می‌شود و می‌تواند گسته یا پیوسته باشد:

$$S = \{y: X(t) = y, \text{ for some } t \in T\}.$$

- در حالتی که فضای حالت گسته باشد، به فرایند، زنجیره (chain) گفته می‌شود.

# امید ریاضی

متغیر تصادفی  
گستته (تعداد خطوط آزاد) تابع توزیع  
پیوسته (زمان عمر دیسک) تابع چگالی

امید ریاضی  
متغیر گستته

$$E[X] = \sum_{x=i} xi * p[xi]$$

متغیر پیوسته

$$E(x) = \int_{-\infty}^{+\infty} x * f(x)dx$$

# واریانس

واریانس

$$\sigma^2 = \text{Var}(x) = \sum_{xi} (xi - E(x))^2 P(xi)$$

$$\sigma^2 = \text{Var}(x) = \int_{-\infty}^{+\infty} (xi - E(x))^2 f(x) dx$$

به جذر واریانس انحراف معیار (standard deviation (SD))  
گفته می شود

## مقدمه ای بر احتمالات

مثال اگر ۳ ترمینال داشته باشیم متغیر تصادفی گسته  $X$  را تعداد سرکشی برای یافتن ترمینال آزاد تعریف کنیم و تابع احتمال بصورت زیر تعریف کنیم

$$P(1) = .6, P(2) = .3, P(3) = .1$$

احتمال سرکشی ۲ بار و کمتر ؟

امید ریاضی ؟

انحراف معیار ؟

# مقدمه ای بر احتمالات

احتمال شرطی

$$P[A|B] = \begin{cases} \frac{P(A \cap B)}{P(B)} & p(B) > 0 \\ 0 & p(B) = 0 \end{cases}$$

مثال

احتمال دریافت پیام از خطوط ۱ تا ۵ به ترتیب ۲۵، ۱۵، ۳۰، ۲۰، ۱۰ درصد باشد و احتمال اینکه پیام دریافتی بیشتر از ۱۰۰ کاراکتر باشد برابر است با ۴۰، ۶۰، ۲۰، ۸۰، ۹۰ باشد

احتمال دریافت یک پیام بیش از ۱۰۰ کراکتری ؟

A پیشامدی که پیغام انتخاب شده بیش از ۱۰۰ کراکتر باشد

$A_1$  پیشامدی که پیغام در خط A دریافت شده باشد

$$P(A) = P(A_1) * P(A|A_1) + P(A_2) * P(A|A_2) + \dots$$

# مقدمه ای بر احتمالات

- شمارش
- $N_1 * N_2$
- $P(n,k) = \frac{n!}{(n-k)!}$
- $c(n,k) = \frac{n!}{(n-k)! * k!}$

# مقدمه ای بر احتمالات

مثال

فرض می کنیم 5 ترمینال توسط یک خط ارتباطی به سیستم کامپیوتری متصل شده اند

$$S = \{x_1, x_2, x_3, x_4, x_5\}$$

فضای نمونه؟

احتمال آمادگی 3 از 5 ترمینال؟

# توزیع برنولی

توزیع برنولی ؟ احتمال  $p$  پیروزی و  $1-p$  شکست  
توزیع دو جمله‌ای ؟ هر گاه در  $n$  بار آزمایش  $k$  بار موفقیت  
داشته باشیم

$$p(x = k) = \binom{n}{k} p^k q^{n-k}$$

مثال

یک کمپانی تجاری دارای ۲۰ خط ارتباطی مستقل می‌باشد  
احتمال مشغول بودن هر خط ۰.۶ باشد، احتمال حداقل ۱۰ خط  
مشغول باشد؟

## توزيع هندسی

توزيع هندسی – اگر آزمایش بر نولی را تا اولین موفقیت انجام دهیم و  $X$  تعداد آزمایش های لازم برای بدست آوردن اولین موفقیت باشد  $X$  را متغیر تصادفی هندسی می نامند

$$P_x(k) = pq^{k-1} \quad k=1,2,3,4,\dots$$

میانگین و واریانس این نوع متغیر تصادفی برابر است با

$$E(x) = \frac{q}{p}, \quad Var(x) = \frac{q}{p^2}$$

# توزیع پواسن


احتمال اینکه یک حادثه به تعداد مشخصی در فاصله زمانی یا مکانی ثابتی رخ دهد را شرح می دهد، به شرط اینکه این حوادث با نرخ میانگین مشخصی و مستقل از زمان آخرين حادثه رخ دهند.  
مثلا برای شمارش ایمیل های دریافتی در یک روز

اگر امید ریاضی ظهرورها در این بازه  $\lambda$  باشد، احتمال اینکه دقیقاً  $k$  ظهرور داشته باشیم

$$p(x = k) = \frac{e^{-\lambda} \lambda^k}{k!}$$

میانگین و واریانس متغیر تصادفی که دارای توزیع پواسن باشد عبارتست از  $\lambda$


# توزيع پواسن



# توزیع پواسن

اگر فاصله زمانی  $[0, t]$  را در نظر بگیریم، احتمال اینکه در این فاصله رخدادی اتفاق نیافتد:

$$P\{N(t)=0\} = e^{-\lambda t} (\lambda t)^0 / 0! = e^{-\lambda t}$$




A1 اولین رخداد، A2 دومین رخداد، ...

فرمول فوق در واقع یعنی:

$$P\{A_1 > t\} = P\{N(t) = 0\}$$

حال می توانیم احتمال رخداد A1 را قبل از t بدست آوریم:



در این صورت حداقل A1 قبل از t رخ داده است. پس:

$$P\{A_1 \leq t\} = 1 - P\{A_1 > t\} = 1 - P\{N(t) = 0\} = 1 - e^{-\lambda t}$$

که CDF توزیع نمایی است و نشان می دهد که احتمال رخداد A1، طبق توزیع نمایی با نرخ  $\lambda$  است.

همین طور می توان نشان داد که توزیع رخدادهای بعدی، A2، A3، ...، An، نیز نمایی با نرخ  $\lambda$  است.

از اینرو نتیجه گیری می کنیم که توزیع زمانهای بین ورود در فرآیند پواسن دارای توزیع نمایی است.

# توزیع پواسن

## ■ خاصیت ۱: انشعاب تصادفی (random splitting)

- فرآیند پواسن  $\{N(t), t \geq 0\}$  را با نرخ  $\lambda$  در نظر بگیرید.
- همچنین، فرض کنید که این فرآیند شامل دو نوع رخداد است: نوع ۱ و نوع ۲.
- این دو نوع رخداد مستقل از هم اتفاق می‌افتد و احتمال اولی  $p$  و احتمال دومی  $1-p$  است.
- حال فرض کنید که  $N_1(t)$  و  $N_2(t)$  به ترتیب معرف تعداد رخدادهای نوع ۱ و ۲ باشند که در  $[0, t]$  اتفاق می‌افتد.
- در این صورت خواهیم داشت:



$$N(t) = N_1(t) + N_2(t)$$

- در این صورت می‌توان نشان داد که  $N_1(t)$  و  $N_2(t)$  هم فرآیندهای پواسن با نرخهای  $\lambda p$  و  $\lambda(1-p)$  هستند.
- انشعاب به بیش از دو نیز امکان‌پذیر است. ولی در هر حال باید  $\sum p_i = 1$ .


# توزيع پواسن

## ■ خاصیت ۲: فرآیند ادغامی (pooled process)

- حالت عکس انشعاب هم وجود دارد. یعنی دو فرآیند پواسن مستقل با هم ادغام شوند.
- یعنی اگر دو فرآیند پواسان  $N_1(t)$  و  $N_2(t)$  با نرخ‌های  $\lambda_1$  و  $\lambda_2$  با هم ترکیب شوند، آنگاه حاصل:

$$N(t) = N_1(t) + N_2(t)$$

نیز یک فرآیند پواسان با نرخ  $\lambda = \lambda_1 + \lambda_2$  خواهد بود.



- حالت بیش از دو نیز امکان‌پذیر است. یعنی بیش از دو فرآیند پواسن مستقل با هم ادغام شوند. در این صورت باید  $\lambda = \sum_i \lambda_i$ .

# توزيع نمایی

توزيع نمایی بیشتر در تخمین زدن مدت زمان لازم برای رخداد یک پیشامد خاص استفاده می‌شود. (اگر برای  $\pi$  پیشامد تعریف شود از توزیع گاما استفاده می‌شود)

برای نمونه، مدت زمان لازم (از هم‌اکنون) تا رخداد یک زمین‌لرزه، آغاز یک جنگ، دریافت یک تماس تلفنی اشتباه، و ... متغیرهای تصادفی با توزیع نمایی می‌باشند.

توزيع نمایی به عنوان توصیف کننده زمان بین دو رویداد در فرایند پواسن به طور طبیعی ظاهر می‌شود.

خاصیت بی حافظگی

# توزيع نمایی

تابع چگالی

$$f(X) = \begin{cases} \lambda e^{-\lambda x} & x > 0 \\ 0 & x \leq 0 \end{cases}$$

تابع توزيع تجمعی

$$F(X) = \begin{cases} 1 - e^{-\lambda x} & x > 0 \\ 0 & x \leq 0 \end{cases}$$

# توزيع نمایی

مثال

اگر زمان استفاده هر کلاینت از سرور با توزیع نمایی با مقدار میانگین ۳۶ دقیقه باشد

احتمال اینکه یک کلاینت کمتر از ۳۰ دقیقه ترمینال را اشغال کند؟

احتمال اینکه یک کلاین بیش از یک ساعت ترمینال را اشغال کند؟

احتمال اینکه اگر یک کلاینت یک سرور را قبل از ۳۰ دقیقه اشغال نموده و احتمال اینکه بیش از یک ساعت دیگر اشغال نماید؟

# توزيع نمایی

- تعریف: یک متغیر تصادفی پیوسته  $X$  دارای توزیع نمایی با پارامتر  $\lambda > 0$  است، اگر تابع چگالی احتمالی آن به صورت زیر باشد:

$$f(x) = \begin{cases} \lambda e^{-\lambda x}, & x \geq 0 \\ 0, & x < 0 \end{cases}$$

□ یا اگر CDF آن به صورت زیر باشد:

$$F(x) = \int_0^x \lambda e^{-\lambda x} dx = 1 - e^{-\lambda x}, x \geq 0$$

□ و امیدریاضی آن به صورت زیر خواهد بود:

$$E[X] = \int_{-\infty}^{\infty} xf(x) dx = \int_0^{\infty} \lambda x e^{-\lambda x} dx = -xe^{-\lambda x} \Big|_0^{\infty} + \int_0^{\infty} e^{-\lambda x} dx = \frac{1}{\lambda}$$

□ و واریانس آن:

$$\text{Var}(X) = E[X^2] - (E[X])^2 = 2/\lambda^2 - 1/\lambda^2 = 1/\lambda^2$$

$$E[X^2] = \int_{-\infty}^{\infty} x^2 f(x) dx = \int_0^{\infty} \lambda x^2 e^{-\lambda x} dx = \frac{2}{\lambda^2}$$

# توزيع نمایی

- خواص توزیع نمایی: یک متغیر تصادفی  $X$  را بدون حافظه (بی‌حافظه) (memoryless) گویند اگر برای تمام مقادیر  $s \geq 0$  و  $t \geq 0$  داشته باشیم:

$$P\{X>s+t|X>s\} = P\{X>t\}$$

■ مثال:

- اگر ما  $X$  را متغیر تصادفی متناظر با عمر یک دستگاه تصور کنیم، آنوقت این رابطه می‌گوید که احتمال اینکه دستگاه حداقل  $s+t$  ساعت عمر کند، وقتی بدانیم برای  $s$  ساعت کار کرده است، درست برابر است با همان احتمال اولیه‌ای که دستگاه از ابتدا حداقل  $t$  ساعت عمر کند.
- به عبارت دیگر اگر دستگاه در زمان  $s$  هنوز قابل استفاده باشد، آنوقت توزیع زمان باقیمانده عمر آن همان توزیع عمر اولیه آن است.
- یعنی، دستگاه به خاطر نمی‌آورد که قبلاً برای مدتی به طول  $s$  مورد استفاده قرار گرفته است.

# توزيع نمایی

■ رابطه فوق را می‌توان به صورت زیر نوشت:

$$\begin{aligned} P[X > t+s | X > s] &= \frac{P[X > t+s, X > s]}{P[X > s]} \\ &= \frac{P[X > t+s]}{P[X > s]} \\ &= \frac{1 - F_X(t+s)}{1 - F_X(s)} \\ &= \frac{e^{-\lambda(t+s)}}{e^{-\lambda s}} \\ &= \frac{e^{-\lambda t} e^{-\lambda s}}{e^{-\lambda s}} \\ &= e^{-\lambda t} \\ &= P[X > t] \end{aligned}$$

■ با جاگذاری در مورد توزیع نمایی:

# توزیع نمایی

■ مثال: فرض کنید مدت زمانی که یک مشتری در بانک صرف می‌کند، دارای توزیع نمایی با میانگین ۱۰ دقیقه باشد:

۱. احتمال اینکه یک مشتری بیش از ۱۵ دقیقه وقت در بانک صرف کند چقدر است؟
۲. احتمال اینکه یک مشتری بیش از ۱۵ دقیقه در بانک صرف کند، وقتی بدانیم که بعد از ۱۰ دقیقه هنوز در بانک است چقدر است؟

■ حل:

۱. اگر  $X$  نماینده مدت زمانی باشد که مشتری در بانک صرف می‌کند، خواهیم داشت:

$$\lambda = 1/10 \Rightarrow P\{X > 15\} = e^{-15\lambda} = e^{-15/10} = e^{-1.5} \approx 0.220$$


۲. احتمال اینکه "یک مشتری که ۱۰ دقیقه در بانک بوده، حداقل ۵ دقیقه دیگر در بانک بماند" را می‌خواهیم بدست بیاوریم.

چون توزیع نمایی "به‌خاطر نمی‌آورد" که مشتری ۱۰ دقیقه در بانک بوده، پس این احتمال برابر است با احتمال اینکه یک مشتری تازه وارد حداقل ۱۵ دقیقه در بانک بماند:

$$P\{X > 15 | X > 10\} = P\{X > 5\} = e^{-5\lambda} = e^{-1/2} \approx 0.664$$

# توزیع نرمال (طبیعی)

یکی از مهمترین توزيعهای احتمالی پیوسته در نظریه احتمالات است. علت نامگذاری و همچنین اهمیت این توزیع، هم خوانی بسیاری از مقادیر حاصل شده، هنگام نوسانهای طبیعی و فیزیکی پیرامون یک مقدار ثابت با مقادیر حاصل از این توزیع است. بعنوان مثال، با اینکه متغیرهای زیادی بر میزان خطای اندازه‌گیری یک کمیت اثر می‌گذارند، (مانند خطای دید، خطای وسیله اندازه‌گیری، شرایط محیط، مثال دیگری از این نوسانهای طبیعی، طول قد، وزن یا بهره هوشی افراد است).



# توزیع نرمال (طبیعی)

فرض کنید تعداد پیغام های بافر شده در یک سیستم کامپیووتری که با متغیر تصادفی توزیع نرمال با میانگین ۱۰۰ و با انحراف معیار ۱۰ باشد احتمال تعداد بافرهای استفاده شده در شرایط زیر

- ۱- بیشتر از ۱۲۰ بافر نباشد
- ۲- بیشتر از ۱۳۰ بافر باشد

$$Z = \frac{x - \mu}{\sigma}$$

| z   | 0.00   | 0.01   | 0.02   | 0.03   | 0.04   | 0.05   | 0.06   | 0.07   | 0.08   | 0.09   |
|-----|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| 0.0 | 0.5000 | 0.5040 | 0.5080 | 0.5120 | 0.5159 | 0.5199 | 0.5239 | 0.5279 | 0.5319 | 0.5359 |
| 0.1 | 0.5398 | 0.5438 | 0.5478 | 0.5517 | 0.5557 | 0.5596 | 0.5636 | 0.5675 | 0.5714 | 0.5753 |
| 0.2 | 0.5793 | 0.5832 | 0.5871 | 0.5910 | 0.5948 | 0.5987 | 0.6026 | 0.6064 | 0.6103 | 0.6141 |
| 0.3 | 0.6179 | 0.6217 | 0.6255 | 0.6293 | 0.6331 | 0.6368 | 0.6406 | 0.6443 | 0.6480 | 0.6517 |
| 0.4 | 0.6554 | 0.6591 | 0.6628 | 0.6664 | 0.6700 | 0.6736 | 0.6772 | 0.6808 | 0.6844 | 0.6879 |
| 0.5 | 0.6915 | 0.6950 | 0.6985 | 0.7019 | 0.7054 | 0.7088 | 0.7123 | 0.7157 | 0.7190 | 0.7224 |
| 0.6 | 0.7257 | 0.7291 | 0.7324 | 0.7357 | 0.7389 | 0.7422 | 0.7454 | 0.7486 | 0.7517 | 0.7549 |
| 0.7 | 0.7580 | 0.7611 | 0.7642 | 0.7673 | 0.7704 | 0.7734 | 0.7764 | 0.7794 | 0.7823 | 0.7854 |
| 0.8 | 0.7881 | 0.7910 | 0.7939 | 0.7967 | 0.7995 | 0.8023 | 0.8051 | 0.8078 | 0.8106 | 0.8133 |
| 0.9 | 0.8159 | 0.8186 | 0.8212 | 0.8238 | 0.8264 | 0.8289 | 0.8315 | 0.8340 | 0.8365 | 0.8389 |
| 1.0 | 0.8413 | 0.8438 | 0.8461 | 0.8485 | 0.8508 | 0.8531 | 0.8554 | 0.8577 | 0.8599 | 0.8621 |
| 1.1 | 0.8643 | 0.8665 | 0.8686 | 0.8708 | 0.8729 | 0.8749 | 0.8770 | 0.8790 | 0.8804 | 0.8830 |
| 1.2 | 0.8849 | 0.8869 | 0.8888 | 0.8907 | 0.8925 | 0.8944 | 0.8962 | 0.8980 | 0.8997 | 0.9015 |
| 1.3 | 0.9032 | 0.9049 | 0.9066 | 0.9082 | 0.9099 | 0.9115 | 0.9131 | 0.9147 | 0.9162 | 0.9177 |
| 1.4 | 0.9192 | 0.9207 | 0.9222 | 0.9236 | 0.9251 | 0.9265 | 0.9279 | 0.9292 | 0.9306 | 0.9319 |
| 1.5 | 0.9332 | 0.9345 | 0.9357 | 0.9370 | 0.9382 | 0.9394 | 0.9406 | 0.9418 | 0.9429 | 0.9441 |
| 1.6 | 0.9452 | 0.9463 | 0.9474 | 0.9484 | 0.9495 | 0.9505 | 0.9515 | 0.9525 | 0.9535 | 0.9545 |
| 1.7 | 0.9554 | 0.9564 | 0.9573 | 0.9582 | 0.9591 | 0.9599 | 0.9608 | 0.9616 | 0.9625 | 0.9633 |
| 1.8 | 0.9641 | 0.9649 | 0.9656 | 0.9664 | 0.9671 | 0.9678 | 0.9686 | 0.9693 | 0.9699 | 0.9706 |
| 1.9 | 0.9713 | 0.9719 | 0.9726 | 0.9732 | 0.9738 | 0.9744 | 0.9750 | 0.9756 | 0.9761 | 0.9767 |
| 2.0 | 0.9773 | 0.9778 | 0.9783 | 0.9788 | 0.9793 | 0.9798 | 0.9803 | 0.9808 | 0.9812 | 0.9817 |
| 2.1 | 0.9821 | 0.9826 | 0.9830 | 0.9834 | 0.9838 | 0.9842 | 0.9846 | 0.9850 | 0.9854 | 0.9857 |
| 2.2 | 0.9861 | 0.9865 | 0.9868 | 0.9871 | 0.9874 | 0.9878 | 0.9881 | 0.9884 | 0.9887 | 0.9890 |
| 2.3 | 0.9893 | 0.9896 | 0.9898 | 0.9901 | 0.9904 | 0.9906 | 0.9909 | 0.9911 | 0.9913 | 0.9916 |
| 2.4 | 0.9918 | 0.9920 | 0.9922 | 0.9924 | 0.9927 | 0.9929 | 0.9931 | 0.9932 | 0.9934 | 0.9936 |
| 2.5 | 0.9938 | 0.9940 | 0.9941 | 0.9943 | 0.9945 | 0.9946 | 0.9948 | 0.9949 | 0.9951 | 0.9952 |
| 2.6 | 0.9953 | 0.9955 | 0.9956 | 0.9957 | 0.9959 | 0.9960 | 0.9961 | 0.9962 | 0.9963 | 0.9964 |
| 2.7 | 0.9965 | 0.9966 | 0.9967 | 0.9968 | 0.9969 | 0.9970 | 0.9971 | 0.9972 | 0.9973 | 0.9974 |
| 2.8 | 0.9974 | 0.9975 | 0.9976 | 0.9977 | 0.9977 | 0.9978 | 0.9979 | 0.9980 | 0.9980 | 0.9981 |
| 2.9 | 0.9981 | 0.9982 | 0.9982 | 0.9983 | 0.9984 | 0.9984 | 0.9985 | 0.9985 | 0.9986 | 0.9986 |
| z   | 3.00   | 3.10   | 3.20   | 3.30   | 3.40   | 3.50   | 3.60   | 3.70   | 3.80   | 3.90   |
| P   | 0.9986 | 0.9990 | 0.9993 | 0.9995 | 0.9997 | 0.9998 | 0.9998 | 0.9999 | 0.9999 | 1.0000 |

# فصل سوم مارکف

## مقدمه

- نظریه فرآیندهای مارکوف منتب به ریاضیدان روسی به نام A. A. Markov (۱۸۵۶-۱۹۲۲) است که از افراد پیشتاز در تحقیقات سیستماتیک توصیف ریاضی فرآیندهای تصادفی است.
- فرآیند مارکوف (Markov process) ابزاری بسیار منعطف، قوی و کارآ برای توصیف و تحلیل خصوصیت‌های سیستمهای پویای کامپیوتری و غیرکامپیوتری هستند.
- از مزایای این مدلها در مورد سیستمهای کامپیوتری، محاسبه و استخراج آسان معیارهای کارآیی و اتقاء‌پذیری از آنها است.

## تقسیم بندی فرایندهای تصادفی بر اساس زمان

- اگر تعداد نقاط زمانی یک فرایند تصادفی (یعنی  $|T|$  متناهی یا قابل شمارش (شمارا) (countable) باشد، آنگاه به آن **فرایند تصادفی گسته-زمان** (discrete-time random process) گفته می‌شود.
- اما اگر تعداد نقاط زمانی یک فرایند تصادفی (یعنی  $|T|$  غیر قابل شمارش (uncountable) باشد، آنگاه به آن **فرایند تصادفی پیوسته-زمان** (continuous-time random process) گفته می‌شود.
- برای مثال:
  - اگر  $X(t)$  تعداد خطاها اتفاق افتاده در یک سیستم تا زمان  $t$  باشد، چون  $t \in R$  یک **فرایند تصادفی پیوسته-زمان** خواهد بود.
  - اما اگر  $X(t)$  تعداد خطاها اتفاق افتاده در یک سیستم در روزهای مختلف سال باشد، چون  $t \in \{1..365\}$  یک **فرایند تصادفی گسته-زمان** خواهد بود.

## تقسیم بندی فرایندهای تصادفی بر اساس فضای حالت

- فرض کنید که  $X$  یک فرآیند تصادفی باشد. **فضای حالت** (state space) فرآیند تصادفی که با  $S$  نشان داده می‌شود، مجموعه همه مقادیر ممکنی است که  $X$  می‌تواند داشته باشد. یعنی:

$$S = \{y: X(t) = y, \text{ for some } t \in T\}$$

- اگر فضای حالت  $S$  یک فرآیند تصادفی  $X$  متناهی و قابل شمارش باشد (یعنی  $S = \{1, 2, 3, \dots\}$ ) آنگاه گفته می‌شود که  $X$  یک **فرآیند تصادفی گسته-فضا** (discrete-space R.P.) است.

- برای مثال اگر  $X$  یک فرآیند تصادفی باشد که تعداد بسته‌های خراب دریافت شده را نمایش می‌دهد، آنگاه  $X$  یک فرآیند تصادفی گسته-فضا خواهد بود.

- اگر فضای حالت  $S$  یک فرآیند تصادفی  $X$  نامتناهی و غیر قابل شمارش باشد (مثلاً  $S = R$ ) آنگاه گفته می‌شود که  $X$  یک **فرآیند تصادفی پیوسته-فضا** (continuous-space R.P.) است.

- برای مثال اگر  $X$  یک فرآیند تصادفی باشد که ولتاژ خط تلفن را نشان می‌دهد، آنگاه  $X$  یک فرآیند تصادفی پیوسته-فضا خواهد بود.

# فرایند مارکوف

- یک نوع خاص از فرآیندهای تصادفی که مورد بررسی دقیق‌تر قرار می‌دهیم، **فرآیند مارکوف** (Markov process) نامیده می‌شود.
- یک فرآیند مارکوف به‌طور غیرصوری به‌شکل زیر تعریف می‌شود:
  - با داشتن **حالت** (state) یا **مقدار** (value) یک فرآیند مارکوف  $X$  در زمان  $t$  (یعنی  $X(t)$ ، رفتار آینده  $X$  به‌طور کامل بر حسب  $X(t)$  قابل توصیف خواهد بود.
- فرآیند مارکوف دارای این خاصیت سودمند است که رفتار آینده آن مستقل از مقادیر گذشته آن است. یعنی بی‌حافظه است.
- به بیان دقیق‌تر، فرآیند مارکوف به صورت زیر تعریف می‌شود:
  - فرآیند  $\{X(t)\}$  دارای خاصیت مارکوفی یا بی‌حافظگی است اگر با داشتن مقدار  $X(t)$  در زمان  $t \in T$ ، مسیر آینده  $X(s)$  برای  $s > t$  به داشتن اینکه سابقه گذشته  $X(u)$  برای  $t < u$  چه بوده است بستگی نداشته باشد. یعنی برای  $t_1 < t_2 < \dots < t_n < t_{n+1}$  داشته باشیم:
$$P[X(t_{n+1}) = x_{n+1} | X(t_n) = x_n, \dots, X(t_1) = x_1] = P[X(t_{n+1}) = x_{n+1} | X(t_n) = x_n]$$

## زنجیره مارکوف

- یک زنجیره مارکوف (Markov chain)، یک فرآیند مارکوف دارای فضای حالت گسسته است.
- ما همیشه فرض می‌کنیم که یک زنجیره مارکوف دارای فضای حالتی در مجموعه  $\{0, 1, 2, \dots\}$  است و نیز زمان - همگن (time-homogeneous) است.
- همگن بودن زمان زنجیره مارکوف به صورت زیر تعریف می‌شود:
  - رفتار سیستم به اینکه چه موقع سیستم مشاهده شده است وابسته نباشد.
  - به عبارت دقیق‌تر، نرخهای گذر (transition rates) بین حالتها مستقل از زمانی که گذر در آن اتفاق می‌افتد باشد. بنا بر این برای همه  $i$ ها و  $j$ ها داشته باشیم:
- $$P[X(t+k) = x_k | X(t) = x_i] = P[X(s+k) = x_k | X(s) = x_i].$$
- زنجیره مارکوف در دو حالت گسسته زمان و پیوسته زمان بررسی خواهد شد

## زنجیره مارکوف گسته زمان

یک زنجیره مارکوف گسته زمان (DTMC: discrete-time M.C.) است اگر:

$$\begin{aligned} P[X(t+k) = j | X(t) = i, X(t-1) = n_{t-1}, X(t-2) = n_{t-2}, \dots, X(0) = n_0] \\ = P[X(t+k) = j | X(t) = i] \end{aligned} \quad (1)$$

$$= P_{ij}^{(k)} \quad (2)$$

توجه کنید که به ازای  $i$  و  $j$  داده شده،  $P_{ij}^{(k)}$  یک عدد است.

$P_{ij}^{(k)}$  می‌تواند به عنوان احتمال اینکه اگر  $X$  دارای مقدار  $i$  است بعد از  $k$  گام زمانی دارای مقدار  $j$  بشود، توصیف شود.

اغلب از  $P_{ij}^{(1)}$  به جای  $P_{ij}$  استفاده می‌شود: احتمال یک گامی (one-step probability).

## بردار احتمال اشغال حالت

■ حال بردار احتمال اشغال حالت (state occupancy probability vector) را تعریف می‌کنیم:

□ فرض کنید که  $\pi$  یک بردار ردیفی (row vector) باشد. عنصر  $i$ -ام این بردار را با  $\pi_i$  نشان می‌دهیم:

$$\pi = [\pi_1, \pi_2, \pi_3, \dots, \pi_{|S|}]$$

□ اگر  $\pi$  یک بردار اشغال حالت باشد، آنگاه  $\pi_i(k)$  احتمال آن خواهد بود که DTMC بعد از  $k$  گام زمانی دارای مقدار  $i$  بشود (یا در حالت  $i$  باشد).

□ فرض کنید که یک DTMC که با  $X$  نشان می‌دهیم دارای فضای حالت به اندازه  $n$  است (یعنی  $S = \{1, 2, \dots, n\}$ ). به طور صوری می‌گوییم که:

$$\pi_i(k) = P[X(k) = i]$$

$$\sum_{i=1}^n \pi_i(k) = 1$$

□ توجه کنید که برای همه زمانهای  $k$  داریم:

## محاسبه بردار احتمال اشغال حالت

$$\pi_j(1) = \sum_{i=1}^n \pi_i(0) P_{ij}$$

بنابر این با توجه به آنچه که دیدیم داریم:  
که برای همه مقادیر  $j$  صادق است.

محاسبه فوق مشابه ضرب بردار در ماتریس است.

در حقیقت اگر ماتریس  $\{P_{ij}\}$  را به صورت زیر مرتب کنیم:

$$P = \begin{bmatrix} p_{11} & \cdots & p_{1n} \\ \vdots & \ddots & \vdots \\ p_{n1} & \cdots & p_{nn} \end{bmatrix}$$

که به آن ماتریس احتمال گذر (transition probability matrix) می‌گوییم.

آنگاه  $p_{ij} = P_{ij}$  و  $P(0) = \pi(0)$  و  $P(1) = \pi(1)$  که در آن  $\pi(0)$  و  $\pi(1)$  بردارهای ردیفی هستند و  $P$  یک ضرب بردار در ماتریس است.

نتیجه مهمی که حاصل می‌شود این است که ما می‌توانیم به آسانی یک DTMC را بر حسب یک بردار احتمال اشغال حالت ( $\pi$ ) و یک ماتریس احتمال گذر ( $P$ ) مشخص کنیم.

## رفتار حالت گذرای زنجیره مارکوف - گستته زمانی

- با داشتن  $\pi(0)$  و  $P$ , چطور می‌توان  $\pi(k)$  را محاسبه نمود?
- حالت عمومی رابطه قبلی به صورت زیر است:

$$\pi(k) = \pi(k-1)P.$$

■ همچنین، چون  $\pi(k-1) = \pi(k-2)P$  می‌توانیم بنویسیم:

$$\pi(k) = (\pi(k-2)P)P = \pi(k-2)P^2$$

■ به طور مشابه، چون  $\pi(k-2) = \pi(k-3)P$  خواهیم داشت:

$$\pi(k) = [(\pi(k-3)P]P^2 = \pi(k-3)P^3$$

■ با تکرار عمل فوق به آسانی می‌توان دید که داریم:

$$\pi(k) = \pi(0)P^k$$

## فصل سوم مارکف

- در فرایند مارکف احتمال اینکه در حالت  $\alpha$  بوده احتمال انتقال به حالت  $\beta$  را با رابطه زیر بدست می آوریم

$$\bullet \quad P_{ij} = P[X_{n+1} = j | X_n = i]$$

- احتمالات انتقال یک مرحله ای  $P_{ij}$  به صورت ماتریس بیان می شود که جمع سطر ها برابر یک می باشد

- معادلات چپمن-کولموگرف

- اگر احتمال انتقال چند مرحله ای  $P_{ij}^n$  که عبارتست از احتمال اینکه در وضعیت  $\alpha$  بوده و پس از  $n$  انتقال به وضعیت  $\beta$  برسد را بصورت زیر می توان نوشت:

$$\bullet \quad P_{ij}^n = \sum_{r=0}^{\infty} P_{ik}^{(r)} P_{kj}^{(n-r)}$$

## فصل سوم مارکف

- مثال
- در یک شبکه انتقال پیغام چندین مرحله جهت انتقال بسته داریم. احتمال اینکه آنکه این بسته صحیح به مرحله بعدی انتقال یابد  $75\%$  می باشد احتمال اینکه یک بسته بعد از چهار مرحله صحیح دریافت گردد چقدر است؟

# مثال

- فرض کنید که هوای یک شهر به صورت زیر مدل شده است:
  - اگر امروز هوا آفتابی است، با احتمال ۶۰٪ فردا نیز آفتابی خواهد بود، با احتمال ۳۰٪ ابری و با احتمال ۱۰٪ بارانی خواهد بود.
  - اگر امروز هوا ابری است، با احتمال ۴۰٪ فردا آفتابی، با احتمال ۴۵٪ فردا ابری و با احتمال ۱۵٪ فردا بارانی خواهد بود.
  - اگر امروز بارانی است، با احتمال ۱۵٪ فردا آفتابی، با احتمال ۶۰٪ فردا ابری و با احتمال ۲۵٪ فردا بارانی خواهد بود.
- حال اگر جمعه بارانی باشد، پیش‌بینی هوا برای دوشنبه چه خواهد بود؟
- مدل وضع هوا چه نوع زنجیره مارکوفی است؟ چرا؟

## مثال

- به طور واضح مدل وضع هوا یک DTMC است. چون:
  - رفتار آینده تنها به حالت جاری بستگی دارد.
  - زمان (روزهای هفته) و حالت (آفتابی، ابری و بارانی) هر دو گسسته هستند.
  - همچنین زمان نیز همگن است.
- DTMC وضع هوا دارای سه حالت است. اجازه دهید که ۱ را به آفتابی، ۲ را به ابری و ۳ را به بارانی منتسب کنیم. همچنین فرض کنید که زمان در جمعه صفر است. آنگاه:

$$\pi(0) = (0, 0, 1)$$

$$P = \begin{pmatrix} .6 & .3 & .1 \\ .4 & .45 & .15 \\ .15 & .6 & .25 \end{pmatrix}$$

## مثال

- به طور واضح مدل وضع هوا یک DTMC است. چون:
  - رفتار آینده تنها به حالت جاری بستگی دارد.
  - زمان (روزهای هفته) و حالت (آفتابی، ابری و بارانی) هر دو گسسته هستند.
  - همچنین زمان نیز همگن است.
- DTMC وضع هوا دارای سه حالت است. اجازه دهید که ۱ را به آفتابی، ۲ را به ابری و ۳ را به بارانی منتسب کنیم. همچنین فرض کنید که زمان در جمعه صفر است. آنگاه:

$$\pi(0) = (0, 0, 1)$$

$$P = \begin{pmatrix} .6 & .3 & .1 \\ .4 & .45 & .15 \\ .15 & .6 & .25 \end{pmatrix}$$

## مثال

■ وضع هوا در شنبه که با  $\pi(1)$  نشان داده می‌شود عبارت است از:

$$\pi(1) = \pi(0)P = (0,0,1) \begin{pmatrix} .6 & .3 & .1 \\ .4 & .45 & .15 \\ .15 & .6 & .25 \end{pmatrix} = (.15,.6,.25),$$

که در نتیجه با احتمال ۱۵٪ آفتایی، با احتمال ۶۰٪ ابری و با احتمال ۲۵٪ بارانی خواهد بود.

■ وضع هوا در یکشنبه که با  $\pi(2)$  نشان داده می‌شود عبارت است از:

$$\pi(2) = \pi(1)P = (.15,.6,.25) \begin{pmatrix} .6 & .3 & .1 \\ .4 & .45 & .15 \\ .15 & .6 & .25 \end{pmatrix} = (.3675,.465,.1675).$$

■ وضع هوا در دوشنبه که با  $\pi(3)$  نشان داده می‌شود عبارت است از:

$$\pi(3) = \pi(2)P = (.4316, .42, .1484),$$

که در نتیجه با احتمال ۴۳٪ آفتایی، با احتمال ۴۲٪ ابری و با احتمال ۱۵٪ بارانی خواهد بود.

# مثال

- راه حل دیگر این است که  $P^3$  را محاسبه کنیم. زیرا داریم:

$$\pi(3) = \pi(0) P^3$$

- حل دستی، دشوار و در معرض خطا است. مخصوصاً اگر مدل بزرگتر از مثال فوق باشد و دارای تعداد زیادی حالت باشد.


- از اینرو از بسته‌های نرم‌افزاری به‌طور گسترده برای این‌گونه تحلیل‌ها استفاده می‌شود (نظیر **MathLab** یا **Maple**).

- این بسته‌های نرم‌افزاری  $\pi(k)$  را بوسیله  $P((\pi(0)P)P)P\dots$  حساب می‌کنند، به جای آنکه  $P^k$  را حساب کنند. **چرا؟**

- محاسبه مستقیم  $P^k$  نیاز به حافظه بیشتری (به اندازه حداقل یک ماتریس) خواهد داشت. در حالی که حاصل  $\pi(0)P$  یک بردار ردیفی خواهد شد و  $P((\pi(0)P)P)P\dots$  نیز تماماً به یک بردار حافظه نیاز خواهد داشت.

# نمایش گرافی زنجیره های مارکوف

- اغلب در مورد زنجیره های مارکوف کوچک، مناسب است که DTMC ها را با یک گراف جهت دار (state transition diagram) یا یک نمودار حالت-گذر (state transition diagram) نشان دهیم:
  - گره ها متناظر با حالت هستند.
  - لبه ها توسط احتمالات برچسب گذاری شده اند.
- برای مثال در مورد مدل پیش بینی وضع هوا داریم:




# نمایش گرافی زنجیره های مارکوف



مثال دیگر: "حالت های مختلف کار کرد یک کامپیوتر ساده"

□ مثال: یک کامپیوتر یا بیکار (idle)، یا در حال کار (working) یا خراب (failed) است. وقتی که کامپیوتر بیکار است، کارها (jobs) با احتمال  $P_{arr}$  وارد می شوند. در کامپیوتر در حال کار، کارها با احتمال  $P_{com}$  کامل می شوند. وقتی که کامپیوتر درحال کار است با احتمال  $P_{fb}$  و وقتی بیکار است با احتمال  $P_{fi}$  خراب می شود. وقتی که کامپیوتر خراب احتمال  $P_r$  تعمیر می شود.



|         |                  |
|---------|------------------|
| $X = 1$ | computer idle    |
| $X = 2$ | computer working |
| $X = 3$ | computer failed  |

$$P = \begin{bmatrix} P_{idle} & P_{arr} & P_{fi} \\ P_{com} & P_{busy} & P_{fb} \\ P_r & 0 & P_{ff} \end{bmatrix}$$

## رفتار حالت پایدار در زنجیره مارکوف گسته- زمان

- با توجه به اینکه در مدلسازی مجبور هستیم که یک حالت اولیه را در نظر بگیریم. برای اینکه تاثیر حالت اولیه را در رفتار سیستم مورد ارزیابی خنثی کنم رفتار سیستم را در بازه زمانی طولانی بررسی می کنیم.
- به عبارتی دیگر حالت پایدار سیستم زمانی است که تاثیر حالت اولیه خنثی شده است.
- معمولاً ما به دنبال محاسبه  $\lim_{n \rightarrow \infty} \pi(n) = \lim_{n \rightarrow \infty} \pi(0) P^n$  هستیم که برای محاسبه  $n$  های خیلی بزرگ بطور تقریبی می تواناز معادله زیر برای تقریب زدن حالت پایدار  $\pi(n)$  استفاده کرد
- $\pi(n) \cong \pi(n + 1)$

## معادلات جریان


برای حل این معادله  $P = \pi$  از معادلات جریان استفاده می کنیم  
جریان ورودی به حالت  $a$  برابر است با جریان خروجی از حالت  $a$ .  
.1

$$\sum \pi_i = 1 \quad .2$$

# فصل سوم مارکف

- فرایند تصادفی
- به فرایندی اطلاق می گردد که قابل پیش بینی نبوده و در طول زمان تغییر می کند (تعداد برنامه های منتظر دریافت سرویس CPU)
- فرایند تولید و مرگ در یک سیستم پایدار (نرخ ورود = نرخ خروج)
- ۱) اگر وضعیت سیستم  $N(t)=n$  باشد، مدت زمان باقی مانده برای آنکه ورود بعدی اتفاق بیافتد دارای توزیع نمایی با پaramتر های  $n=0,1,2,\dots$   $\lambda_n$  می باشد
- ۲) اگر وضعیت سیستم  $N(t)=n$  باشد، مدت زمان باقی مانده برای آنکه خروج بعدی اتفاق بیافتد دارای توزیع نمایی با پaramتر های  $n=1,2,\dots$   $\mu_n$  می باشد
- ۳) در هر زمان یک ورود و یا یک خروج می تواند رخ دهد

# فصل سوم مارکف



- میانگین نرخ ورود به وضعیت صفر ؟
- میانگین نرخ ورود به وضعیت یک ؟
- میانگین نرخ خروج از وضعیت یک ؟

## فصل سوم مارکف

- همانطور که ملاحظه می شود تمامی احتمال ها را با استفاده از احتمال حالت  $P_0$  بدست آورد

- $P_1 = \frac{\lambda_0}{\mu_1} P_0$
- $P_{n+1} = \frac{\lambda_n \lambda_{n-1} \dots \lambda_0}{\mu_{n+1} \mu_n \dots \mu_1} P_0$
- $R_n = \frac{\lambda_{n-1} \dots \lambda_0}{\mu_n \dots \mu_1}$
- $P_n = R_n P_0 , \sum_{n=0}^{\infty} P_n = 1$

## فصل سوم مارکف

- همانطور که ملاحظه می شود تمامی احتمال ها را با استفاده از احتمال حالت  $P_0$  بدست آورد

- $P_1 = \frac{\lambda_1}{\mu_2} P_0$
- $P_{n+1} = \frac{\lambda_n \lambda_{n-1} \dots \lambda_0}{\mu_{n+1} \mu_n \dots \mu_1} P_0$
- $R_n = \frac{\lambda_{n-1} \dots \lambda_0}{\mu_n \dots \mu_1}$
- $P_n = R_n P_0 , \sum_{n=0}^{\infty} P_n = 1$

# زنجیره های مارکوف پیوسته - زمان

- در زنجیره های مارکوف گسسته-زمان، گذر از هر حالت به حالتی دیگر دارای زمان برابر است.
- اما در اغلب سیستم های مورد نظر، رخدادها در هر نقطه از زمان اتفاق می افتد. یعنی زمان گذر از هر حالت به حالتی دیگر طبق یک متغیر تصادفی پیوسته است.
- این امر باعث می شود که ما به مطالعه CTMCs بپردازیم.
- **CTMC** به صورت زیر تعریف می شود:

$$\begin{aligned} P[X(t+\tau) = j | X(t) = i, X(t-t_1) = k_1, X(t-t_2) = k_2, \dots, X(t-t_n) = k_n] \\ = P[X(t+\tau) = j | X(t) = i], \\ = P_{ij}(\tau) \end{aligned}$$

for all  $\tau > 0, 0 < t_1 < t_2 < \dots < t_n$

■ مفهوم time-homogeneous CTMC هم وجود دارد:

$$P[X(t+\tau) = x_k | X(t) = x_j] = P[X(s+\tau) = x_k | X(s) = x_j].$$

# زنجیره های مارکوف پیوسته - زمان

- تعریف CTMC تا زمانی که خصوصیت های آنرا ندانیم خیلی مفید نخواهد بود.
- در ابتدا توجه کنید که  $p_{ij}(\tau)$  مستقل از آن است که قبلاً چه مدت CTMC در حالت  $i$  بوده است. به این صورت که:

$$\begin{aligned} P[X(t+\tau) = j | X(u) = i \text{ for } u \in [0, t]] \\ = P[X(t+\tau) = j | X(t) = i] \\ = p_{ij}(\tau) \end{aligned}$$

- تعریف فوق برای CTMC همان تعریف بی حافظه بودن (memoryless) است.
- تنها یک متغیر تصادفی پیوسته است که دارای خاصیت فوق است و آن متغیر تصادفی نمایی است.
- از اینجا مشخص می شود که CTMC با توزیع نمایی دارای رابطه است:
  - نرخ زمان گذر از حالتی به حالتی دیگر دارای توزیع نمایی است.

# ماتریس نرخ گذر - حالت

- یک CTMC با استفاده از یک توزیع اولیه  $\pi(0)$  و یک ماتریس نرخ-گذر-حالت (state-transition-rate matrix) که به آن ماتریس مولد بینهایت کوچک (infinitesimal generator matrix) نیز گفته می‌شود به طور کامل قابل توصیف است.
- ماتریس نرخ-گذر-حالت  $Q = [q_{ij}]$  به صورت زیر تعریف می‌شود:


$$q_{ij} = \begin{cases} \text{rate of going from} \\ \text{state } i \text{ to state } j & i \neq j, \\ -\sum_{k \neq i} q_{ik} & i = j. \end{cases}$$

## مثال

- یک کامپیوتر یا بیکار (idle)، یا در حال کار (working) یا خراب (failed) است. وقتی که کامپیوتر بیکار است، کارها (jobs) طبق یک توزیع نمایی با نرخ  $\alpha$  وارد می‌شوند و طبق یک توزیع نمایی با نرخ  $\beta$  کامل می‌شوند. وقتی که کامپیوتر درحال کار است طبق توزیع نمایی با نرخ  $\lambda_w$  و وقتی بیکار است طبق توزیع نمایی با نرخ  $\lambda_i$  خراب می‌شود.

# مثال

■ حالتهای CTMC :



X=1 نشان‌دهنده حالت بیکار، □

X=2 نشان‌دهنده حالت در حال کار و □


X=3 نشان‌دهنده حالت خرابی. □

■ و ماتریس Q:

$$Q = \begin{bmatrix} -(\alpha + \lambda_i) & \alpha & \lambda_i \\ \beta & -(\beta + \lambda_w) & \lambda_w \\ 0 & 0 & 0 \end{bmatrix}$$

# مثال

- حال یک تغییر کوچک در مثال فوق می‌دهیم: اگر زمان تعمیر کامپیوتر فوق دارای توزیع نمایی با نرخ  $\mu$  باشد.
- CTMC جدید به صورت زیر خواهد بود:



$$Q = \begin{bmatrix} -(\alpha + \lambda_i) & \alpha & \lambda_i \\ \beta & -(\beta + \lambda_w) & \lambda_w \\ \mu & 0 & -\mu \end{bmatrix}$$

# مثال

- سوالات زیر در مورد مدل کامپیوتر ساده با استفاده از مدل فوق قابل پاسخ دادن است:
  - قابلیت دسترسی (availability) کامپیوتر ساده در زمان  $t$  (قابلیت دسترسی لحاظهایی) چقدر است؟
  - میانگین زمان تا خرابی (MTTF) کامپیوتر ساده چقدر است؟
  - میانگین تعداد کارهایی که به خاطر خرابی در  $[0, t]$  از دست می‌روند (lost) چقدر است؟
  - میانگین تعداد کارهایی که قبل از خرابی در  $[0, t]$  سرویس‌داده می‌شوند چقدر است؟
  - توان عملیاتی (throughput) سیستم (تعداد کارهای پردازش شده در واحد زمان) با به حساب آوردن خرابیها و تعمیرات چقدر است؟
  - وغیره.

# مثال

- سئوالاتی که وابسته به زمان هستند جزء معیارهای اتکاء‌پذیری بوده و با **حل گذرای CTMC (transient solution)** پاسخ داده می‌شوند.
  - نظیر: قابلیت دسترسی لحظه‌ای
- اما سئوالاتی که مربوط به حالت پایدار هستند جزء معیارهای کارآیی بوده و با **حل حالت پایدار CTMC (steady-state solution)** پاسخ داده می‌شوند.
  - نظیر: توان عملیاتی
- ما در این درس به حل گذرای CTMC نمی‌پردازیم و هدف حل حالت پایدار است که در مورد ارزیابی کارآیی مورد نیاز است.
- مدل‌های کارآیی اغلب به حالت پایدار می‌رسند.


## حل حالت پایدار زنجیره های ماکوف پیوسته - زمان از طریق معادلات جریان

- در حالت پایدار داریم  $\pi^* Q = 0$  که برای رسیدن به این حالت باید جریان های ورودی به حالت  $\alpha$  برابر با جریان داده های خارج شونده با آن در نظر گرفت.
- همچنین داریم  $\sum_{i=1}^n \pi_i^* = 1$

با توجه به فرضیات فوق می توان دستگاه معادله خطی را تشکیل داده حل نمود

## مثال زنجیره های ماکوف پیوسته - زمان

- هر کدام از دو پردازنده با توزیع نمایی دارای نرخ  $\lambda$  درخواست دسترسی به حافظه مشترک صادر می کنند و زمان دسترسی به حافظه مشترک دارای توزیع نمایی با نرخ  $\mu$  است:



$$Q = \begin{bmatrix} -\lambda & \lambda \\ \mu & -\mu \end{bmatrix}$$

- حالت ۱: هیچکدام از دو پردازنده به حافظه مشترک دسترسی ندارند.
- حالت ۲: یکی از دو پردازنده به حافظه مشترک دسترسی دارد.

## مثال زنجیره های ماکوف پیوسته - زمان

■ حال دستگاه معادلات جریان را نویسند و حل می کنیم:

$$\begin{cases} 0 = -\lambda \pi_1 + \mu \pi_2 \\ 0 = \lambda \pi_1 - \mu \pi_2 \\ 1 = \pi_1 + \pi_2 \end{cases} \Rightarrow \pi_1 = \mu / (\lambda + \mu) \quad \pi_2 = \lambda / (\lambda + \mu)$$
$$\Rightarrow \pi^* = [\mu / (\lambda + \mu), \lambda / (\lambda + \mu)]$$

\* معنی آن این خواهد بود که در حالت پایدار هر کدام از پردازنده ها با احتمال  $\mu / (\lambda + \mu)$  در حال استفاده از حافظه داخلی خود هستند.

## مثال زنجیره های ماکوف پیوسته - زمان

- در حالت پایدار داریم  $\pi^* Q = 0$  که برای رسیدن به این حالت باید جریان های ورودی به حالت  $\alpha$  برابر با جریان داده های خارج شونده با آن در نظر گرفت.
- همچنین داریم  $\sum_{i=1}^n \pi_i^* = 1$

با توجه به فرضیات فوق می توان دستگاه معادله خطی را تشکیل داده حل نمود

## فصل سوم مارکف

- مثال
- در یک سیستم کامپیووتری وضعیت سیستم به صورت دو وضعیت مشغول و آزاد که فرایند ورود برنامه با توزیع پواسن  $\lambda$  و مدت دریافت سرویس  $M$  می باشد. احتمال قرار گرفتن در وضعیت آزاد و مشغول را بدست آورید.