




CPE 332

# Computer Engineering Mathematics II

Part II, Chapter 4 Cont.: Statistical Average  
Chapter 5: Random Process



# Today Topics

- HW 3 Due/ HW4 Due Next Week
- PDF
- Expectation
- Joint Density
- Correlation/Covariance
- Random Process
- Stationary
- Ergodic




# Random Variables




- Mapping ผลลัพธ์เป็นตัวเลข (One-to-One) ดังนั้นผลการทดลองสามารถไปคำนวณต่อได้
  - ที่สำคัญคือค่าเฉลี่ยทางสถิติ
    - Mean
    - Variance
    - Etc.
  - และกราฟแสดงคุณสมบัติ Probability
    - Cumulative Distribution Function (CDF)
    - Probability Density Function (PDF)
  - เมื่อผลลัพธ์ของการทดลอง (Sample Space) ได้ Infinite Set เราได้ Continuous Random Variable
  - เมื่อผลลัพธ์เป็น Finite Set การกำหนดจะใช้ Set ของตัวเลข มักจะเป็น Integer เราได้ Discrete Random Variable



# CDF: Cumulative Distribution Function of RV $X$




ถ้าให้ Function  $F_X(x) = P[X \leq x]$  และ Plot Graph ระหว่าง  $F_X(x)$  vs.  $x$  (ซึ่งก็คือ Graph  $P[X \leq x]$  vs.  $x$ ) Graph ที่ได้เราเรียกว่า Cumulative Distribution Function หรือ CDF (บางครั้งเราใช้ Probability Distribution Function) ลักษณะของ CDF จะเป็น Graph ที่จะไม่มีการลดค่าเนื่องจากเป็นค่าสะสม โดยจะเริ่มจากศูนย์ และมีค่าสูงสุดเป็นหนึ่ง คุณสมบัติของ CDF สามารถจะสรุปได้ดังนี้



**CDF of Normal (Gaussian) Distribution: Continuous**



# CDF Properties



(1)  $0 \leq F_X(x) \leq 1$

(2)  $F_X(x)$  เป็น Non-decreasing Function

(3)  $\lim_{x \rightarrow -\infty} F_X(x) = 0$  และ  $\lim_{x \rightarrow +\infty} F_X(x) = 1$

(4)  $F_X(x)$  เป็น Function ที่ต่อเนื่องจากทางด้านขวา นั่นก็คือ  $\lim_{\varepsilon \downarrow 0} F_X(x + \varepsilon) = F_X(x)$

(5)  $P[a < X \leq b] = F_X(b) - F_X(a)$

(6)  $P[X = a] = F_X(a) - F_X(a^-)$




# CDF การทอยเหรียญ: Discrete RV




- ให้ "หัว" = 0 และ "ก้อย" = 1

$$F_X(x) = P(X \leq x)$$




# PDF: Probability Density Function




ค่าของการเปลี่ยนแปลงใน CDF หรือ Slope ของมัน เมื่อ Plot กับแกน  $x$  เราจะได้ Probability Density Function

$(f_X(x))$  หรือ PDF นั่นก็คือ  $f_X(x) = \frac{dF_X(x)}{dx}$  และ  $F_X(x) = \int_{-\infty}^{x^+} f_X(x)dx$  คุณสมบัติของ PDF มีดังนี้



PDF of Normal(Gaussian) Distribution : Continuous



# Properties of PDF

$$(1) f_X(x) \geq 0$$

$$(2) \int_{-\infty}^{\infty} f_X(x) dx = 1$$


$$(3) \int_{a^+}^{b^+} f_X(x) dx = P[a < x \leq b]$$

$$(4) P[X \in A] = \int_{Area A} f_X(x) dx$$

$$(5) F_X(x) = \int_{-\infty}^{x^+} f_X(u) du$$

ในกรณีของ Discrete Random Variable บางครั้งเราใช้คำว่า Probability Mass Function (PMF) แทน ซึ่งมีนิยามดังนี้

$$PMF = \{P_i\}; P_i = P[X = x_i]$$






# Discrete Version

- ค่าของ Variable ไม่ต่อเนื่อง
  - RV  $X$  มีค่าเฉพาะที่  $X=x_i$
- $F(x) = P(X \leq x)$ 
  - Function นี้มีความต่อเนื่องด้านขวามือ
  - นิยามสำหรับทุกจุดใน Domain ของ  $x$
  - Function เป็นลักษณะขั้นบรรได
  - Monotonic Increasing Function จาก 0 ถึง 1
- $f(x_i) = P(X = x_i)$ 
  - นิยามเฉพาะจุด ไม่ต่อเนื่อง ค่าเป็นศูนย์ระหว่างนั้น
  - บางที่เรียก Probability Mass Function
  - $\sum f(x_i) = 1$  เสมอ




$f(x)$

PMF




$F(x)$

CDF



# Statistical Average



Random Variable สามารถที่จะอธิบายได้ด้วย PDF ของมัน แต่การแสดง PDF ของ RV บ่อยๆ ครั้งไม่จำเป็นและไม่เหมาะสม ยิ่งไปกว่านั้น ในปกติแล้ว การหา PDF ของ RV นั้นทำไม่ได้ง่ายๆ ดังนั้นเรามักจะแสดงคุณสมบัติของมันจากค่าเฉลี่ยทางสถิติซึ่งเราเรียกว่า **Expectation** หรือการคาดคะเนทางสถิติของมัน

ถ้ากำหนดให้ Function ของ RV  $X$  คือ  $g(X)$  เราสามารถหา Expectation ของ  $g(X)$  ได้จาก

$$E[g(X)] = \int_{-\infty}^{\infty} g(X) f_X(x) dx$$

ทั้งสังเกตไว้อย่างหนึ่งก็คือ Expectation หรือ  $E[\cdot]$  เป็น Linear Operation นั่นก็คือ  $E[X + Y] = E[X] + E[Y]$  นอกจากนี้แล้วเรายังได้  $E[C] = C$  และ  $E[kX] = kE[X]$  โดยที่  $C, k$  เป็นค่าคงที่

Discrete Version :

$$E[g(X)] = \sum_{\forall x_i \in X} g(x_i) p(x_i)$$



# Importance Expectation



4.7.1 Mean ( $m_X$  หรือ  $\mu_X$  หรือ  $\bar{X}$ ) คือเมื่อ  $g(X) = X$  เราได้  $E[X] = \bar{X} = \int_{-\infty}^{\infty} X f_X(x) dx$

4.7.2 Mean Square ( $\overline{X^2}$ ) หรือ Second Moment นั่นก็คือ  $g(X) = X^2$  และ  $E[X^2] = \int_{-\infty}^{\infty} X^2 f_X(x) dx$

4.7.3 Variance ( $\sigma^2$ ) หรือ Second Central Moment มาจาก  $g(X) = (X - \bar{X})^2$  และ

$E[(X - \bar{X})^2] = \int_{-\infty}^{\infty} (X - \bar{X})^2 f_X(x) dx$  ค่านี้สามารถคำนวณได้จาก Linear Property ของ Expectation ดังนี้

$$\sigma^2 = E[(X - \bar{X})^2] = E[X^2] - E[2\bar{X}X] + E[\bar{X}^2] = \overline{X^2} - \bar{X}^2$$

Discrete Version :

$$E[X] = \sum_{\forall x_i \in X} x_i p(x_i) = \sum_{i=1}^N x_i p(x_i) = \frac{1}{N} \sum_{i=1}^N x_i \mid p(x_i) = \frac{1}{N}$$

$$E[X^2] = \sum_{\forall x_i \in X} x_i^2 p(x_i) = \frac{1}{N} \sum_{i=1}^N x_i^2 \mid p(x_i) = \frac{1}{N}$$

$$\sigma_X^2 = \sum_{\forall x_i \in X} (x_i - \mu_X)^2 p(x_i) = E[X^2] - E[X]^2$$





- **Note:**

- ในกรณีของ Data ที่ได้จากการสุ่มตัวอย่าง เราได้เฉพาะค่า Estimate ของ Mean และ Mean Square เท่านั้น และ

From  $n$  Samples :  $p(x_i) = \frac{1}{N}$ , Each sample has the same probability

$$\hat{\mu}_X = \bar{X} = \frac{1}{N} \sum_{i=1}^N x_i$$

$$\text{Estimate } E[X^2] = \overline{X^2} = \frac{1}{N} \sum_{i=1}^N x_i^2$$

$\sigma_X^2 = E[X^2] - E[X]^2$  from estimation is biased.

We use the least biased formula :

$$\text{Sample Variance (Estimated)} : V_X^2 = s_{N-1}^2 = \frac{1}{N-1} \left( \sum_{i=1}^N (x_i - \bar{X})^2 \right)$$



# Multivariate: RV มากกว่า 1 ตัว



- จุดประสงค์ในการศึกษา RV มากกว่าหนึ่งตัวพร้อมๆกัน เพื่อจะหาความสัมพันธ์ระหว่าง RV
  - แสดงโดยกราฟ Joint PDF
  - หรือค่าเฉลี่ยทางสถิติ Correlation และ Covariance
- **กรณีของ Bivariate**
  - เป็นการศึกษาความสัมพันธ์ระหว่าง RV สองตัว คือ  $X$  และ  $Y$  แต่ละตัวอาจเป็น Discrete หรือ continuous
    - เช่นความสัมพันธ์ระหว่างส่วนสูงและอายุ
    - หรือความสัมพันธ์ระหว่างคะแนน Midterm และเกรดปลายเทอม
    - หรือความสัมพันธ์ระหว่าง GPA กับเงินเดือนที่ได้เมื่อจบการศึกษา



# Multivariate: RV มากกว่า 1 ตัว



- แต่ละ  $X$  และ  $Y$  จะมี PDF ของมัน เรียก Marginal PDF บ่งบอกเฉพาะคุณสมบัติของตัวมันเอง ไม่เกี่ยวกับตัวอื่น
  - $f_X(x)$  และ  $f_Y(y)$
- Marginal PDF ไม่มีข้อมูลแสดงความสัมพันธ์ของทั้งสอง RV
  - PDF ที่แสดงความสัมพันธ์ของสอง RV จะต้องเป็น Function ของทั้งสอง Variable และต่างจาก Marginal PDF



# Multivariate: RV มากกว่า 1 ตัว




- PDF ที่เป็น Function ของทั้งสอง RV เรียก Joint PDF จะมีข้อมูลแสดงความสัมพันธ์เพิ่มเข้ามา (สำหรับ 2 RV ต้อง Plot แบบ 3D)
  - $f_{XY}(x, y)$  Joint PDF ไม่สามารถหาได้จาก Marginal PDF อย่างเดียว
  - ยกเว้นเฉพาะกรณีพิเศษที่  $X$  และ  $Y$  ไม่ขึ้นต่อกันเท่านั้น (Statistical Independent) ที่ทำให้สมการล่างนี้เป็นจริง
    - $f_{XY}(x, y) = f_X(x) f_Y(y)$
- แต่เราสามารถแสดงได้ว่า Marginal Density
  - $f_X(x) = \int_{-\infty}^{\infty} f_{XY}(x, y) dy$  และ







# Joint CDF/Marginal Density



- $F_{XY}(x, y) = P[X \leq x, Y \leq y] = \int_{-\infty}^x \int_{-\infty}^y f_{XY}(x, y) dx dy$
- Joint PDF จะมี Marginal Density ตาม PDF ของแต่ละ Random Variable
  - $f_X(x) = \int_{-\infty}^{\infty} f_{XY}(x, y) dy$
  - $f_Y(y) = \int_{-\infty}^{\infty} f_{XY}(x, y) dx$



# Joint Moment




**4.7.4 Joint Moment** ในกรณีที่ Random Variable มากกว่าหนึ่งตัว เราได้ Joint Moment  $E[g(X, Y)]$  ดังนั้นเรานิยามให้ค่า Expectation ของ Joint Moment เป็นดังนี้

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

โดยที่  $f_{X, Y}(x, y)$  คือ Joint Probability Density Function ของทั้งสอง Random Variable สังเกตว่าปกติแล้วการรู้เพียงแต่ PDF ของแต่ละ Variable นั้นจะมีข้อมูลไม่เพียงพอที่จะหา PDF ของ Joint Variable ได้ ยกเว้นในกรณีพิเศษที่ทั้งสอง Random Variable นั้นเป็น Statistical Independent ซึ่งในกรณีนี้เราได้  $f_{X, Y}(x, y) = f_X(x) f_Y(y)$



# Correlation



- $G(x,y) = XY$

4.7.5 Correlation ในกรณี  $g(X,Y) = XY$  เราได้ Correlation ของ RV 2 ตัวเรียก Cross Correlation หาได้จาก  $E[XY]$  ซึ่งเราเรียกว่า Cross Correlation ของ  $X$  และ  $Y$  ให้เครื่องหมาย  $R_{XY}$  ดังนั้นเราสามารถเขียน

$$R_{XY} = E[XY] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} XY f_{XY}(x,y) dx dy$$


ในกรณีของ Statistical Independent เราจะได้  $R_{XY} = E[XY] = E[X]E[Y]$

*Discrete Version* :  $R_{XY} = \sum_{i=1}^N \sum_{j=1}^M x_i y_j p(x_i, y_j) = \sum_{i=1}^N \sum_{j=1}^M x_i y_j p(x_i) p(y_j)$

$$= \sum_{i=1}^N x_i p(x_i) \sum_{j=1}^M y_j p(y_j) \mid \text{independent} = \frac{1}{N} \sum_{i=1}^N x_i \frac{1}{M} \sum_{j=1}^M y_j \mid p(x_i) = \frac{1}{N}, p(y_j) = \frac{1}{M}$$



# Covariance



4.7.6 Covariance ถ้า  $g(X, Y) = (X - m_X)(Y - m_Y)$  เมื่อเราทำ Expectation เราได้ Covariance หรือ  $C_{XY}$  ดังนั้น


$$\begin{aligned} C_{XY} &= E[(X - m_X)(Y - m_Y)] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (X - m_X)(Y - m_Y) f_{XY}(x, y) dx dy \\ &= E[XY] - m_X E[Y] - m_Y E[X] + m_X m_Y = R_{XY} - m_X m_Y \end{aligned}$$

อีกค่าที่สำคัญก็คือ Correlation Coefficient หรือ  $\rho$  ซึ่งก็คือ Normalized Covariance กล่าวคือ

$$\rho = \frac{C_{XY}}{\sigma_X \sigma_Y}$$



# Correlation and Covariance



## 4.7.7 Notes เกี่ยวกับ Correlation

- RV 2 ตัว จะ Uncorrelated ก็ต่อเมื่อ  $C_{XY} = 0$
- RV 2 ตัว จะ Orthogonal ก็ต่อเมื่อ  $R_{XY} = E[XY] = 0$
- ถ้า  $X$  หรือ  $Y$  ตัวใดตัวหนึ่งมี Zero Mean และทั้งสองตัว Orthogonal กัน ดังนั้นมันจะ Uncorrelated
- ถ้า RV 2 ตัวเป็น Statistically Independent ทั้งสองตัวจะ Uncorrelated แต่ส่วนกลับจะไม่เป็นจริงเสมอไป ยกเว้นในกรณีที่ทั้งสองตัวเป็น Jointly Gaussian
- ในกรณีที่  $Y = X$  เราได้  $C_{XY} = \sigma_X^2$



# การประมาณค่า $R_{xy}$ และ $C_{xy}$ จาก Samples



- เราเก็บตัวอย่างเป็นคู่  $(x_i, y_i)$  จำนวน  $N$  คู่
- Probability ของการได้แต่ละตัวอย่างเท่ากัน คือ  $1/N$
- ดังนั้น

$$R_{XY} = E[XY] = \sum_i \sum_j x_i y_j P(x_i, y_j) = \sum_{i=1}^N x_i y_i \left(\frac{1}{N}\right) = \frac{1}{N} \sum_{i=1}^N x_i y_i$$

- และ

$$C_{XY} = E[(X - m_X)(Y - m_Y)] = \sum_{i=1}^N (x_i - m_X)(y_i - m_Y) \left(\frac{1}{N}\right)$$

$$= \frac{1}{N} \sum_{i=1}^N (x_i - m_X)(y_i - m_Y) = R_{XY} - m_X m_Y$$




# EX. จงหา $R_{xy}$ และ $C_{xy}$ จาก ตัวอย่างในตารางข้างล่าง




- ข้อมูลจากชายไทย อายุระหว่าง 12 - 30 ปี
- $X$ =อายุ และ  $Y$ =ส่วนสูง

No.(i)	$x_i$	$y_i$	No.(i)	$x_i$	$y_i$
1	20	178	7	12	168
2	25	176	8	18	156
3	19	163	9	26	174
4	21	184	10	20	171
5	30	180	11	24	182
6	16	165	12	17	179




# Scatter Diagram





# Calculation Table




$i$	$x_i$	$y_i$	$x_i y_i$	$x_i - m_X$	$y_i - m_Y$	$(x_i - m_X)(y_i - m_Y)$
1	20	178	3560	-0.6667	5	-3.3333
2	25	176	4400	4.3333	3	13.0000
3	19	163	3097	-1.6667	-10	16.6667
4	21	184	3864	0.3333	11	3.6667
5	30	180	5400	9.3333	7	65.3333
6	16	165	2640	-4.6667	-8	37.3333
7	12	168	2016	-8.6667	-5	43.3333
8	18	156	2808	-2.6667	-17	45.3333
9	26	174	4524	5.3333	1	5.3333
10	20	171	3420	-0.6667	-2	1.3333
11	24	182	4368	3.3333	9	30.0000
12	17	179	3043	-3.6667	6	-22.0000
$\sum_{i=1}^{12} (.)$	248	2076	43140	0	0	236
Average (N=12)	20.6667	173	$R_{XY} = 3595$	0	0	$C_{XY} = 19.6667$


Notes: เราสามารถคำนวณ  $C_{XY} = R_{XY} - m_X m_Y = 3595 - (20.6)(173) = 19.6$




# PDF ที่สำคัญ



**4.8.1 Bernoulli Trial** สมมุติว่าการทดลองมี Outcome ที่เป็นไปได้เพียง 2 แบบ เช่น 0 หรือ 1, ถูก หรือ ผิด, สำเร็จ หรือ ไม่สำเร็จ ลักษณะของการทดลองแต่ละครั้งเหล่านี้เราเรียก Bernoulli Trial โดยถ้าให้  $p$  และ  $q$  เป็นค่า Probability ของ Outcome ทั้งสอง เราจะได้  $p + q = 1$  หรือ  $q = 1 - p$



# Binomial Distribution



**4.8.2 Binomial Distribution** มีปัญหาหลายๆแบบสามารถแก้ไขได้จากการหา Probability ที่จะสำเร็จ  $k$  ครั้งจากการทำ

Bernoulli Trial ทั้งหมด  $n$  ครั้ง Probability ที่จะประสบผลสำเร็จเท่ากับ  $k$  ครั้งในการทำ Bernoulli Trial ที่ไม่ขึ้นต่อกัน


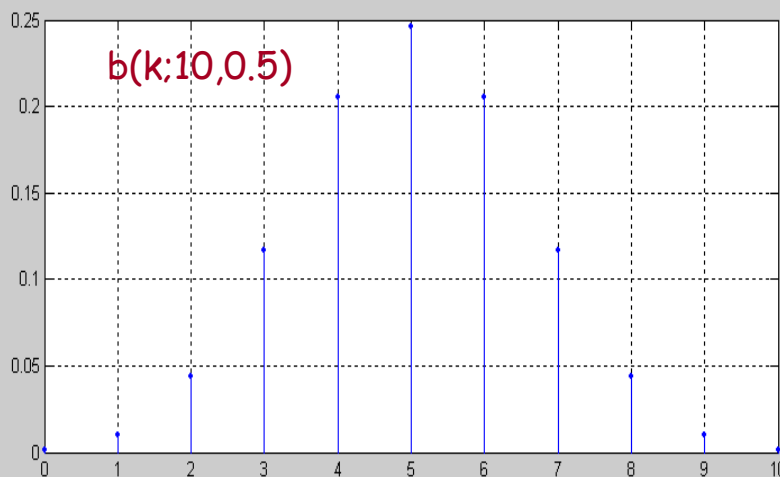
ทั้งหมด  $n$  ครั้ง ที่มีค่า Probability ในการประสบผลสำเร็จแต่ละครั้งเท่ากับ  $p$  และไม่สำเร็จ  $q = 1 - p$  จะหาได้

จาก  $C(n, k)p^k q^{n-k}$  ดังนั้น  $p(X = k) = C(n, k)p^k q^{n-k}$  และ  $E(X) = np$ ,  $\sigma_X^2 = npq$


ถ้า Probability ที่จะสำเร็จ  $k$  ครั้ง เป็น Function กับ  $k$  จัดเป็น Distribution Function ที่สำคัญอันหนึ่งที่เรียก Binomial

Distribution, เขียน  $b(k; n, p) = C(n, k)p^k q^{n-k}$  สังเกตว่า  $\sum_{k=0}^n C(n, k)p^k q^{n-k} = (p + q)^n = 1$

$$C(n, k) = C_k^n = {}^n C_k = \binom{n}{k} = \frac{n!}{k!(n-k)!}$$





# Geometric Distribution



4.8.3 Geometric Distribution Random Variable  $X$  จะเป็น Geometric Distribution ด้วย Parameter  $p$  ถ้า


$$p(X = k) = (1 - p)^{k-1} p \text{ สำหรับค่า } k = 1, 2, 3, \dots \text{ และค่า } E(X) = \frac{1}{p}, \sigma_X^2 = (1 - p) / p^2$$




# Uniform Distribution



4.8.4 Uniform Distribution  $P(X = k) = 1/(b - a)$  ถ้า  $X$  อยู่ระหว่าง  $[a, b]$  และจะเป็นศูนย์ในกรณีอื่นๆ ในกรณีนี้เราได้  $E(X) = (a + b)/2$ ,  $\sigma_X^2 = (b - a)^2 / 12$



# Gaussian Distribution



4.8.5 Normal Distribution(Gaussian Distribution) ด้วย Parameter  $\mu, \sigma$  สามารถหาได้จาก



$$N(\mu, \sigma) = f_X(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2}\left(\frac{x-\mu}{\sigma}\right)^2}$$

สังเกตว่า Function ดังกล่าวไม่สามารถหา


Integration ในลักษณะของ Closed Form ได้



# Gaussian



# Jointly Gaussian: $X, Y$



$$f_{XY}(x, y) = \frac{1}{2 \cdot \pi \cdot \sigma_X \cdot \sigma_Y \cdot \sqrt{1 - \rho}} \cdot e^{-\frac{1}{2(1-\rho^2)} \left[ \left( \frac{x-\mu_X}{\sigma_X} \right)^2 - \frac{2 \cdot \rho \cdot (x-\mu_X) \cdot (y-\mu_Y)}{\sigma_X \sigma_Y} + \left( \frac{y-\mu_Y}{\sigma_Y} \right)^2 \right]}$$



- ค่า  $\rho$  คือค่า Correlation Coefficient บ่งบอกถึงความสัมพันธ์ของสอง Variable จะมีค่าระหว่าง  $[-1, 1]$

- $\rho = \frac{\text{cov}(X, Y)}{\sigma_X \sigma_Y}$



- $f_{XY}(x, y)$  เป็น Joint PDF ที่มี Marginal











$P = 0.5$



$P = 0.9$




$P = 0.95$






$\rho = -0.99$



# Exponential Distribution





4.8.6 Exponential Distribution Exponential Distribution ที่มี Parameter  $A$  สามารถเขียนได้ในรูป

$$f_X(x) = Ae^{-Ax} \text{ และ } F_X(x) = 1 - e^{-Ax}, \quad E(X) = \frac{1}{A} \text{ และ } \sigma_X^2 = \frac{1}{A^2}$$


Exponential Distribution เป็น Distribution ที่สำคัญอีกอันหนึ่งใน Queuing Theory ซึ่งค่า Inter-arrival Time ของสอง Random Event ที่อยู่ติดกันจะมีการกระจายแบบนี้ ซึ่งเราสามารถหา Probability ที่ Event ที่สองจะเกิดหลังจาก Event แรกเกิดแล้วภายในเวลา  $t$  ได้จาก  $p(X \leq t) = 1 - e^{-At}$



# Exponential Distribution



# Poisson Distribution



**4.8.7 Poisson Distribution** เป็น Discrete Random Variable ที่สำคัญสำหรับ Queuing Theory ที่จะศึกษาต่อไป ได้จากการนับของ Independent Random Event ในช่วงเวลาใดเวลาหนึ่ง ถ้าค่าเฉลี่ยของการนับ Event ในช่วงเวลานั้นเท่ากับ  $\lambda$  ดังนั้น Probability ที่จะมีความ  $k$  Event เข้ามาในช่วงเวลาเดียวกันสามารถหาได้จาก



$$p(X = k) = p(k) = \frac{\lambda^k e^{-\lambda}}{k!}$$
 เราสามารถพิสูจน์ได้ว่า  $E(X) = \lambda$ , และ  $\sigma_X^2 = \lambda$

ประโยชน์อีกอย่างของ Poisson คือใช้ในการประมาณค่าของ Binomial Distribution โดยกำหนด  $\lambda = np$









# Lambda = 1





# Lambda = 3





# Lambda = 5




# Lambda = 8



# Lambda = 12




# Lambda = 18



# Break

- After Break Chapter 5 Random Process




# Random Process

- เมื่อ Random Variable เป็น Function กับเวลา
    - สัญญาณที่มีลักษณะ Random เช่น Noise
    - การส่ง Packet ใน Network
    - จำนวนรถที่วิ่งบนถนน
    - จำนวนลูกค้าที่เข้ามาใช้บริการ
  - เหล่านี้ ในแต่ละเวลาหนึ่งๆ ค่าของมันจะมีลักษณะเป็น Random คือมี PDF ตามแต่ชนิดของมัน
    - ที่เวลาต่างกัน PDF อาจะเปลี่ยน และค่าทางสถิติจะเปลี่ยนตาม
  - Random Variable ที่เป็น Function (Random Function หรือ Analytic Function) กับเวลา เราเรียก Random Process หรือ Stochastic Process
    - จาก RV  $X$  จะเป็น  $X(t)$
- Mean และ Variance จะเป็น Function กับเวลาด้วย
- การวิเคราะห์จะซับซ้อนกว่า RV






# Random Process (Stochastic Process)




## 5.1 นิยามและคำจำกัดความ

Random Process เป็นการขยายคำจำกัดความของ Random Variable, เราสามารถคิดได้อย่างง่ายๆว่า Random Process คือ Random Variable ที่เป็น Function กับเวลา(หรือ Independent Variable ตัวอื่น) ซึ่งบางครั้งเราเรียกอีกชื่อหนึ่งว่า **Stochastic Process** ดังนั้นถ้าเราให้  $X(t)$  เป็น Random Process เราจะได้ว่าในแต่ละจุดของเวลา  $t_1, t_2, \dots, t_n$  Random Process ที่เวลานั้นๆ  $X(t_1), X(t_2), \dots, X(t_n)$  แต่ละตัวจะเป็น Random Variable ซึ่งอาจจะมีหรือไม่มีค่า Probability Density Function ที่เหมือนกันหรือเท่ากันก็ได้

ค่าของ Random Process ที่เวลาหนึ่งๆเราเรียกมันว่าเป็น Random Variable ที่ Ensemble ของเวลานั้น อย่างไรก็ตามตามปกติการวัดค่าของสัญญาณนั้นเราจะได้ข้อมูลที่เป็น Sample Point ของ Random Variable ในแต่ละจุดของเวลา ซึ่งถ้าเราวัดติดต่อกันไป เราก็จะได้ Function หนึ่งซึ่งเป็นสัญญาณที่เปลี่ยนไปตามเวลา ซึ่งเราเรียกว่า Sample Function ของ Random Process



# Statistical Average



สำหรับในแต่ละเวลา ค่า  $X(t_i)$  ก็คือ RV ฉะนั้นค่าทางสถิติจะหาได้จาก Expectation ซึ่งค่าที่ได้จะเป็นค่าทางสถิติที่เป็น Function กับเวลา มีค่าทางสถิติที่เพิ่มมาที่สำคัญก็คือ Autocorrelation และค่า Autocovariance

**5.2.1 Mean** ค่าของ Mean ในความหมายทางสถิติก็คือค่า  $E[X(t)]$  เนื่องจาก  $X(t)$  เป็น Function กับเวลา ดังนั้นค่า Mean ที่ได้ก็จะเปลี่ยนไปตามเวลาด้วย นั่นก็คือ  $m_X(t) = E[X(t)]$

**5.2.2 Variance** ที่เวลา  $t_i$  เราสามารถหาค่า Variance  $\sigma_X(t_i)$  ได้จาก PDF ของ  $X(t_i)$  นั่นก็คือ

$$\sigma_X^2(t_i) = E[(X(t_i) - m_X(t_i))^2] = \int_{-\infty}^{\infty} (X(t_i) - m_X(t_i))^2 f_{X(t_i)}(x) dx$$





- **Notations:**

- Random Variable:  $X$
- Random Process:  $X(t)$

- **PDF**

- Random Variable:  $f_X(x)$
- Random Process:  $f_{X(t)}(x, t) = f_{X(t)}(x)$  ที่เวลา  $t$

- **Expectation (Statistical Average)**

- $\mu_X(m_X) \rightarrow \mu_{X(t)}(t)$

$$\sigma_X^2 \rightarrow \sigma_{X(t)}^2(t)$$



# Random Process at $t_i$


- Random Process ที่เวลาใดเวลาหนึ่ง คือ Random Variable ที่มีค่า PDF, Mean, Variance เฉพาะ
  - เรียกค่าใน Ensemble (Ensemble Average)
- ค่าต่างๆนี้จะแปรผันไปกับเวลาได้
  - $X(t_1)$  เป็น Random Variable ได้จาก Random Process ที่  $t_1$  จะมี PDF, Mean, Variance  $f_{X(t_1)}(x), \mu_{X(t_1)}, \sigma_{X(t_1)}$




# Sample Function: Ensemble Average and Time Average




- ในการศึกษา Random Variable เราสามารถสุ่มตัวอย่างทีละตัวอย่าง เรียก Sample Point,  $\omega_i$
- ในกรณีของ Random Process ตัวอย่างที่สุ่มจะเป็นตัวอย่างที่เป็น Function กับเวลา เรียก Sample Function,  $\omega_i(t)$
- ค่าเฉลี่ยในแต่ละเวลา เราเรียก Ensemble Average
  - จะเหมือนค่าเฉลี่ยปกติของ Random Variable
- ค่าเฉลี่ยของแต่ละ Sample Function เรียก Time



# Sample Function and Ensemble



$$\frac{1}{T} \int_T \omega_i(t) dt$$




Ensemble Average

$$\overline{X(t_1)}, \sigma_{X(t_1)}^2$$


Ensemble Average

$$\overline{X(t_2)}, \sigma_{X(t_2)}^2$$



$$\overline{X(t)}, \sigma_X^2(t)$$

# Statistical Average: Correlation/Covariance



**5.2.3 Autocorrelation** ค่า Autocorrelation Function ของ Random Process  $X(t)$  คือความสัมพันธ์ของตัวมันเองที่เวลาต่างกัน(เปรียบเทียบกับ Autocorrelation ของ Deterministic Signal) นั่นก็คือ

$$R_{XX}(t_1, t_2) \equiv R_X(t_1, t_2) = E[X(t_1)X(t_2)] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x_1 x_2 f_{X(t_1)X(t_2)}(x_1, x_2) dx_1 dx_2$$

**5.2.4 Autocovariance Function** ในทำนองเดียวกัน เราสามารถหา Autocovariance Function ได้จาก

$$C_{XX}(t_1, t_2) \equiv C_X(t_1, t_2) = E[(X(t_1) - m_X(t_1))(X(t_2) - m_X(t_2))]$$



# Stationary RP



- ค่าทางสถิติของ RP Process ปกติเปลี่ยนไปกับเวลา (Ensemble Average ที่เวลาต่างกัน)
  - Mean
  - Variance
  - PDF
- สำหรับกรณีพิเศษที่ค่าทางสถิติของ RP ไม่แปรผันกับเวลา เราเรียกว่ามันเป็น Stationary
  - $f_{X(t)}(x, t) \rightarrow f_{X(t)}(x)$
  - $\mu_{X(t)}(t) \rightarrow \mu_{X(t)}(\mu_X)$
  - $\sigma_{X(t)}^2(t) \rightarrow \sigma_{X(t)}^2 = \sigma_X^2$





# Stationary RP



- Stationary RP

- Strict Sense Stationary (SSS)

- PDF ไม่เปลี่ยน ดังนั้นทุกๆ Moment (Expectation) ไม่เปลี่ยน

- ปกติ SSS จะหาได้ยากในทางปฏิบัติ บ่อยครั้งที่เราสนใจแค่สอง Moment แรก

- Wide Sense Stationary (WSS)

- เฉพาะ 2 Moment แรกคงที่ แต่ PDF อาจแปรผัน

- Mean

- Variance (Mean Square)




มีข้อที่น่าสนใจอีกอันหนึ่ง คือถ้า Random Process นั้นเป็น Gaussian Process นั่นก็คือทุกจุดเวลามันจะมีลักษณะ PDF

เป็นแบบ Gaussian เนื่องจาก Gaussian PDF สามารถอธิบายได้จากค่าทางสถิติเพียงแค่สองตัวคือค่า Mean และค่า Variance

ดังนั้นในกรณีของ Gaussian Process คำว่า Wide-Sense Stationary จะมีความหมายเดียวกันกับ Strict-Sense Stationary


# WIDE SENSE STATIONARY




-  $m_X(t)$  หรือ  $\mu_X(t)$  จะลดรูปลงเหลือ  $m_X$  และ  $\sigma_X(t)$  จะกลายเป็น  $\sigma_X$

-  $R_X(t_1, t_2)$  จะไม่ขึ้นกับเวลา  $t_1$  และ  $t_2$  อีกต่อไป แต่จะขึ้นกับผลต่างของเวลา  $t_2 - t_1 = \tau$  นั่นก็คือเรา  
ได้  $R_X(t_1, t_2) = R_X(t_2 - t_1) = R_X(\tau)$

-  $C_X(t_1, t_2)$  จะลดรูปลงเหลือ  $C_X(t_1, t_2) = R_X(\tau) - m_X^2$



# Autocorrelation(WSS)




คุณสมบัติที่สำคัญก็คือการลดรูปของค่า Autocorrelation ซึ่งจะอยู่ในรูปที่เหมือนกับในกรณีของ Deterministic Signal  
ต่อไปนี้เป็นคุณสมบัติของ Autocorrelation

-  $R_X(0) = E[X^2(t)]$  ซึ่งเกี่ยวข้องกับ Power และ Energy ของสัญญาณ Random ซึ่งก็คือสัญญาณที่เป็น Random Process

-  $R_X(\tau) = R_X(-\tau)$  นั่นก็คือ  $R_X(\tau)$  เป็น Even Function ดังนั้นเราสามารถเขียน  $R_X(\tau) = E[X(t)X(t-\tau)]$

$$- |R_X(\tau)| \leq R_X(0)$$

$$R_{XX}(t_1, t_2) = R_X(t_2 - t_1) = R_X(\tau)$$



# Ergodic Random Process



- ถ้า RP เป็น Ergodic

- Time Average = Ensemble Average

- Mean Ergodic

- หมายถึงค่าเฉลี่ยในทางเวลา  $\frac{1}{T} \int_T \omega_i(t) dt$  เท่ากับค่าเฉลี่ย(mean =  $E(X(t_i))$ ) ของ Ensemble

- Correlation Ergodic

- หมายถึงค่า Variance ในทางเวลา  $\frac{1}{T} \int_T (\omega_i(t) - \overline{\omega_i(t)})^2 dt$  เท่ากับค่า Variance ที่ได้จาก Ensemble  $\sigma_{X(t_i)}^2$


- เราใช้ควบคู่กับ Concept ของ Stationary Random Process



# Discrete-Time Random Process




- อาจจะได้จากการสุ่มตัวอย่าง (Sampling) ของ Continuous RP
  - Uniform Sampling ด้วย Sampling Period  $T = \frac{1}{f_s}$
- เราได้  $\dots, X(-T), X(0), X(T), X(2T), X(3T), \dots$
- ปกติจะละ Sampling Period ไว้ฐานที่เข้าใจ เราได้  $\dots, X(-1), X(0), X(1), X(2), X(3), \dots$
- มักจะเขียนในลักษณะ  $X(n); n = \text{integer}$



# Discrete-Time Random Process (Limited Samples)



- จริงแล้ว  $n = (-\infty, +\infty)$  แต่ในทางปฏิบัติ เราสามารถสุ่มตัวอย่างได้ในช่วงเวลาที่มีจำกัด
  - $n = 0, 1, 2, \dots, N - 1$  หรือ  $n = -N, -N + 1, \dots, -1, 0, 1, \dots, N$
  - ขึ้นอยู่กับว่าเราจะใช้ Index เรียกตัวอย่างที่ได้อย่างไร
  - เสมือนเราคูณ  $X(n)$  ด้วย *Box Function* โดยถือว่าตัวอย่างที่อยู่ นอกขอบเขตของการสุ่มมีค่าเป็นศูนย์ เช่นในกรณีของ  $X(n); n = 0, \pm 1, \pm 2, \dots, \pm 5$
  - จะมีผลต่อการคำนวณ



# Ergodic Discrete RP



- ถ้า RP เป็น Ergodic ด้วยค่า Mean (Average จาก Ensemble = Average จาก Time)

## Mean Ergodic Process

ในกรณีของ Stationary Random Process มีค่า Mean

$$m_x = E[X(n)]$$

คราวนี้ถ้าเราสมมติค่า Time Average

$$\hat{m}_x = \frac{1}{2N+1} \sum_{n=-N}^N x(n)$$

และถ้า Process เป็น Ergodic, ดังนั้น

$$m_x = \lim_{N \rightarrow \infty} \frac{1}{2N+1} \sum_{n=-N}^N x(n)$$



# Ergodic Discrete RP



- ถ้า RP เป็น Ergodic สำหรับ Coorelation

## 5.4.2 Correlation Ergodic Process

เมื่อ Stationary Random Process เป็น Correlation Ergodic เราสามารถคำนวณค่า Autocorrelation และ Cross Correlation จากเพียงหนึ่ง Sample Function โดยใช้การเฉลี่ยในทางเวลาแทน ดังนี้

$$R_{XX}(m) = R_X(m) = E[X^*(n)X(n+m)] = \lim_{N \rightarrow \infty} \frac{1}{2N+1} \sum_{n=-N}^N x^*(n)x(n+m)$$

และ

$$R_{XY}(m) = E[X^*(n)Y(n+m)] = \lim_{N \rightarrow \infty} \frac{1}{2N+1} \sum_{n=-N}^N x^*(n)y(n+m)$$

ค่า Estimation ของ Autocorrelation จากหนึ่ง Sample Function สามารถหาได้จาก

$$\hat{R}_x(m) = \frac{1}{2N+1} \sum_{n=-N}^N x^*(n)x(n+m)$$





# กรณีที่จำกัด Sequence ความยาว $N$



ถ้าสมมติว่าเราได้ Sample Function ของ Discrete Random Process  $X(n)$  มาหนึ่งตัว คือ  $\omega_i(n) = x(n)$  ดังนั้นเราจะได้

$$E[X(n)] = E(X) = m_X = \lim_{N \rightarrow \infty} \frac{1}{2N+1} \sum_{i=-N}^N x(n)$$

ในทางปฏิบัติเราไม่สามารถเก็บ Sample Function ได้ตลอดทุกเวลา เราจำเป็นต้องตัดมาเพียงบางส่วน สมมติว่าเราได้ตัวอย่างความยาว  $N$  และให้  $x(n)$ ,  $n = 0, \dots, N-1$  คือจำนวนเพียง  $N$  Sample ดังนั้นค่าที่คำนวณได้จะเป็นเพียงค่า Estimation ของค่า  $m_X$  หรือ  $\hat{m}_X$  ซึ่งจะถูกต้องขึ้นถ้าเพิ่มจำนวน Sample มากขึ้น และสมการจะลดรูปเป็น

$$\hat{m}_X = \frac{1}{N} \sum_{i=0}^{N-1} x(n)$$

ถ้า  $x(n)$  ที่เราสนใจมีค่าอยู่ระหว่าง  $n = M$  ถึง  $n = N$  สมการจะลดรูปเป็น

$$\hat{m}_X = \frac{1}{N-M+1} \sum_{i=M}^N x(n)$$




# จำกัด Sequence ความยาว N



- ค่า Autocorrelation สำหรับ N Samples
  - สมการจะลดรูป เหลือแค่ Sum และเฉลี่ย N Point แต่จะเกิดการ Biased

$$R_{XX}(m) = \lim_{N \rightarrow \infty} \frac{1}{2N+1} \sum_{n=-N}^N x(n)x(n+m)$$






$$R_{XX}(m) = \begin{cases} \frac{1}{N} \sum_{n=0}^{N-m-1} x(n)x(n+m); & 0 \leq m \leq N-1 \\ R_{XX}(-m); & -N+1 \leq m < 0 \end{cases} ; \text{ Biased}$$



# ความหมายของ $x(n)x(n+m)$


$$R_{XX}(m) = \lim_{N \rightarrow \infty} \frac{1}{2N+1} \sum_{n=-N}^N x(n)x(n+m)$$



# ความหมายของ $x(n)x(n+m)$ , N Points

$$R_{XX}(m) = \frac{1}{N} \sum_{n=0}^N x(n)x(n+m) = \frac{1}{N} \sum_{n=0}^{N-m+1} x(n)x(n+m)$$

$X(n): n=0,1,\dots,9$



เราไม่ควรเฉลี่ยทั้ง N ตัว (Biased) แต่ควรเฉลี่ย  $N-m$  ตัว (non-Biased)



# จำกัด Sequence ความยาว N



- ค่า Autocorrelation สำหรับ N Samples

- สมการจะลดรูป เหลือแค่ Sum และเฉลี่ย N Point แต่จะเกิดการ Biased เพราะเราเฉลี่ยน้อยกว่านั้น


$$R_{XX}(m) = \begin{cases} \frac{1}{N} \sum_{n=0}^{N-m-1} x(n)x(n+m); & 0 \leq m \leq N-1 \\ R_{XX}(-m); & -N+1 \leq m < 0 \end{cases} ; \text{ Biased}$$

ดังนั้นการคำนวณที่ไม่ Biased จะเป็นค่าที่ Normalized จากจำนวนจุดของการคำนวณจริงๆ และเราได้

$$R_{XX}(m) = \begin{cases} \frac{1}{N-|m|} \sum_{n=0}^{N-m-1} x(n)x(n+m); & 0 \leq m \leq N-1 \\ R_{XX}(-m); & -N+1 \leq m < 0 \end{cases} ; \text{ Non - biased}$$



# Sequence ความยาว $N$ / RAW



ในการคำนวณปกติมักจะคำนวณค่าในลักษณะ “Raw Autocorrelation” และละส่วนของการ Normalization หรือส่วนของการหารไว้ สำหรับผู้ใช้จะพิจารณาเองว่าจะใช้แบบ Bised หรือ Non-Biased และเราได้


$$R_{XX}(m) = \sum_{n=0}^{N-1} x(n+m)x(n) = \begin{cases} \sum_{n=0}^{N-m-1} x(n)x(n+m); m \geq 0 \\ R_{XX}(-m); m < 0 \end{cases}; \text{ Raw Data}$$

ในการทำงานเดียวกัน สำหรับ Cross Correlation เมื่อ  $X(n)$  และ  $Y(n)$  มีความยาว  $N$  เท่ากัน โดยการเติมศูนย์ เราได้

$$R_{XY}(m) = \sum_{n=0}^{N-1} x(n)y(n+m) = \begin{cases} \sum_{n=0}^{N-m-1} x(n)y(n+m); m \geq 0 \\ \sum_{n=0}^{N-m-1} x(n-m)y(n); m < 0 \end{cases}; \text{ Raw Data}$$



# Sequence ทั่วไป



ในกรณีที่สัญญาณไม่ได้เริ่มจาก  $n = 0$  และ/หรือทั้งสอง Random Variable มีความยาวไม่เท่ากัน ผลลัพธ์ที่ได้จะมีความยาวของ Sequence  $N + M - 1$  โดยที่  $N$  และ  $M$  เป็นความยาวของทั้งสอง Variable และในกรณีนี้ค่า Index ของ Summation จะเปลี่ยนไป อย่างไรก็ตาม สมการข้างล่างยังใช้ได้สำหรับ Raw Data ที่ไม่ได้ทำการ Normalized




$$R_{XX}(m) = \sum_{n=-\infty}^{\infty} x(n)x(n+m); -\infty < m < \infty \quad \text{Raw Data}$$

$$R_{XY}(m) = \sum_{n=-\infty}^{\infty} x(n)y(n+m); -\infty < m < \infty \quad \text{Raw Data}$$



# Example: $R_{xx}$




- $x = [1 \ \underline{2} \ 3]$









# Example: $R_{xx}$

- $x = [1 \ \underline{2} \ 3]$







# Example: $R_{xx}$

- $x = [1 \ \underline{2} \ 3]$






# Example: $R_{xx}$

- $x = [1 \ \underline{2} \ 3]$





# Example: $R_{xx}$

- $x = [1 \ \underline{2} \ 3]$






# Example: $R_{xx}$

- $x = [1 \ \underline{2} \ 3]$





# Example: $R_{xx}$

- $x = [1 \ \underline{2} \ 3]$




# Example: $R_{xx}$

- $x = [1 \ \underline{2} \ 3]$





# $R_{xx}(m)$








# Example: Rxy

- $x=[1 \underline{2} 3], y=[4 \underline{5} 6 7]$






# Example: Rxy

- $x=[1 \underline{2} 3], y=[4 \underline{5} 6 7]$





# Example: Rxy

- $x=[1 \underline{2} 3], y=[4 \underline{5} 6 7]$






# Example: Rxy

- $x=[1 \underline{2} 3], y=[4 \underline{5} 6 7]$






# Example: Rxy

- $x=[1 \underline{2} 3], y=[4 \underline{5} 6 7]$







# Example: $R_{xy}$

- $x = [1 \ \underline{2} \ 3], y = [4 \ \underline{5} \ 6 \ 7]$





# Example: $R_{xy}$

- $x = [1 \ \underline{2} \ 3], y = [4 \ \underline{5} \ 6 \ 7]$



$R_{xy}(m)$





# End of Week 5

- Download HW 4: Probability
  - ส่งต้นชั่วโมงสัปดาห์หน้า

