



# CONTENTS

- 확률의 개념
- 확률변수
- 통계적 평균
- 주요 확률분포
- 랜덤 프로세스
- 랜덤 프로세스의 확률밀도 함수
- 대역통과 랜덤 프로세스
- 백색잡음



# Probability

## □ Random Experiment

- 예 die tossing

## □ Outcome $\xi_1, \xi_2, \xi_3, \xi_4, \xi_5, \xi_6$

## □ Sample Space

- set of all possible outcomes,  $S = \{\xi_1, \xi_2, \xi_3, \xi_4, \xi_5, \xi_6\}$

## □ Event

- subset of sample space  $A = \{\xi_2, \xi_4, \xi_6\}$

# Probability

## □ Union of two events

표기:  $A+B$  또는  $A \cup B$

## □ Intersection of two events : 결합사건 (joint event)


표기:  $AB$  또는  $A \cap B$

## □ 상호배반 (mutually exclusive) 사건

- $A$ 와  $B$ 가 disjoint set

# Probability

□ Example: 주사위 던지는 시행에서의 샘플공간과 사건



- $A \cup B = \{\xi_2, \xi_3, \xi_4, \xi_6\}$
- $A \cap B = \{\xi_4\}$
- $A$ 와  $C$ 는 배반사건

# Probability

## □ Relative Frequency and Probability

- $N(A)$  : 불규칙 실험을  $N$  번 독립 시행하여 특정 사건  $A$  가 나온 횟수
- 사건  $A$  의 relative frequency

$$f(A) = \frac{N(A)}{N}$$

- 사건  $A$  의 확률

$$P(A) = \lim_{N \rightarrow \infty} \frac{N(A)}{N}$$

- 성질

$$0 \leq P(A) \leq 1$$

$$P(A) = 0 \quad \text{if } A = \emptyset$$

$$P(A) = 1 \quad \text{if } A = S$$

# Probability

## □ Event 사이의 관계

- 두 사건  $A$  또는  $B$  가 일어날 확률

$$P(A \cup B) = P(A + B) = P(A) + P(B) - P(AB)$$

- $A$  와  $B$  가 배반사건인 경우

$$P(A \text{ or } B) = P(A \cup B) = P(A) + P(B)$$

- 여사건의 확률

$$P(A^c) = 1 - P(A)$$

# Probability

## □ Conditional Probability

$$P(B|A) = \frac{P(AB)}{P(A)}$$

$$P(A|B) = \frac{P(AB)}{P(B)}$$

- 따라서

$$P(AB) = P(B)P(A|B)$$

## □ Bayes' rule

$$P(B|A) = \frac{P(A|B)P(B)}{P(A)}$$

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)}$$


- 의미: 어떤 조건부 확률은 역 조건부 확률(reversed conditional probability)을 사용하여 표현할 수 있다.

# Probability

## □ Total Probability

- 샘플 공간  $S$ 가 상호 배반인  $\{A_1, A_2, \dots, A_N\}$ 의 사건의 합으로 표현할 수 있다고 가정하자. 즉

$$S = \bigcup_{n=1}^N A_n \quad \text{with } A_i \cap A_j = \emptyset \text{ for all } i \neq j$$



- 그러면 어떤 사건  $B$ 는 다음과 같이 표현할 수 있다:

$$B = \bigcup_{n=1}^N (B \cap A_n)$$

- 사건  $B$ 의 확률은


$$P(B) = \sum_{n=1}^N P(B \cdot A_n) = \sum_{n=1}^N P(B|A_n)P(A_n)$$

# Probability

## □ Bayes' Rule

- Bayes 법칙을 이용하여 다음을 얻을 수 있다.

$$P(A_m|B) = \frac{P(B|A_m)P(A_m)}{P(B)} = \frac{P(B|A_m)P(A_m)}{\sum_{n=1}^n P(B|A_n)P(A_n)}$$



- 이 식의 의미는 사건  $B$ 가 일어난 조건하에서 사건  $A_m$ 이 일어날 확률을 구하는데 있어 역 조건확률, 즉 사건  $A_m$ 이 일어난 조건하의 사건  $B$ 의 확률들을 사용하여 표현할 수 있다는 것이다.

# Probability

## □ 독립사건

- 한 사건의 발생이 다른 사건의 발생 확률에 영향을 주지 않으면 두 사건은 서로 독립(**independent**)이라 한다.

- 즉 다음을 만족하면 사건  $B$ 는  $A$ 사건 에 독립이다.

$$P(B|A) = P(B)$$

- 사건  $B$ 가 사건  $A$ 에 독립이면 사건  $A$ 는 사건  $B$ 에 독립이다. 즉

$$P(A|B) = P(A)$$

- 따라서 사건  $A$ 와  $B$ 가 서로 독립이면 다음 식이 성립한다.

$$P(AB) = P(A)P(B)$$

## 예제 6.1

- 두 개의 동전을 던지는 실험을 한다고 하자. 사건 A는 두 개의 동전 중 최소한 한 개가 앞면이 나오는 경우라 하고, 사건 B는 두 개가 모두 같은 면이 나오는 경우라고 하자.
  - (a) 사건 A와 사건 B의 확률을 구하라.
  - (b)  $P(A|B)$ 와  $P(B|A)$ 를 구하라.
  - (c) 두 사건은 서로 독립인가?

## 예제 6.1

### □ 풀이

- 동전을 던져서 앞면이 나오면 H, 뒷면이 나오면 T로 표기하도록 하자.

$$S = \{HH, HT, TH, TT\} \quad A = \{HH, HT, TH\}, B = \{HH, TT\}$$

$$(a) \quad P(A) = \frac{3}{4}, P(B) = \frac{2}{4} = \frac{1}{2}$$

$$(b) \quad P(B|A) = \frac{P(AB)}{P(A)} = \frac{\frac{1}{4}}{\frac{3}{4}} = \frac{1}{3}$$

$$P(A|B) = \frac{P(AB)}{P(B)} = \frac{\frac{1}{4}}{\frac{2}{4}} = \frac{1}{2}$$

$$(c) \quad \frac{1}{4} = P(AB) \neq P(A) \cdot P(B) = \frac{3}{4} \cdot \frac{1}{2} = \frac{3}{8}$$

따라서 독립적이지 않다.


## 예제 6.2

### □ 이진 디지털 통신 시스템

- 송신측에서 전송할 정보가 0인 사건을  $A_0$ 로, 전송할 정보가 1인 사건을  $A_1$ 으로 나타내고, 수신측에서 0으로 판단하는 사건을  $B_0$ 로, 1로 판단하는 사건을  $B_1$ 으로 나타내자. 송신측에서 데이터가 0일 확률과 1일 확률이 각각  $P(A_0)=p_0=0.8$  과  $P(A_1)=p_1=1-p_0=0.2$ 로 사전에 주어졌다고 하자. 송신기에서 0을 전송하였는데 수신기가 1로 오판할 확률이  $\alpha=0.1$ 이며, 반대로 1을 전송하였는데 수신기가 0으로 오판할 확률도 동일하게  $\alpha=0.1$ 이라고 가정하자.

(a) 수신기의 오류 확률을 구하라.

(b) 수신측에서 신호를 1로 판단하였는데 실제로 송신측에서 1을 전송하였을 확률을 구하라.



## 예제 6.2

### □ 풀이

주어진 통신 채널의 특성은 다음과 같이 조건부 확률로써 표현된다.

$$P(B_1|A_0) = P(B_0|A_1) = \alpha = 0.1$$

$$P(B_0|A_0) = P(B_1|A_1) = 1 - \alpha = 0.9$$

#### (a) 수신기의 오류 확률

$$\begin{aligned} P(\text{error}) &= P(A_0 B_1) + P(A_1 B_0) = P(B_1|A_0)P(A_0) + P(B_0|A_1)P(A_1) \\ &= \alpha \cdot p_0 + \alpha \cdot p_1 = \alpha = 0.1 \end{aligned}$$

$$(b) \quad P(A_m|B) = \frac{P(B|A_m)P(A_m)}{P(B)} = \frac{P(B|A_m)P(A_m)}{\sum_{n=1}^n P(B|A_n)P(A_n)}$$

$$\Rightarrow P(A_1|B_1) = \frac{P(B_1|A_1)P(A_1)}{P(B_1|A_1)P(A_1) + P(B_1|A_0)P(A_0)} = \frac{(1-\alpha)p_1}{(1-\alpha)p_1 + \alpha p_0} = \frac{0.9 \times 0.2}{0.9 \times 0.2 + 0.1 \times 0.8} = 0.69$$

만일  $p_0 = p_1 = 0.5$  라면  $P(A_1|B_1) = 1 - \alpha$ 가 되어  $\alpha$ 의 함수가 된다.



---

# *Random Variable*

# 확률변수

## □ Random Variable

- 확률변수는 샘플 공간에 속한 각 원소  $\xi_i$  ( $i=1,2,\dots$ )에 대하여 대응하는 실수  $x_i$  ( $i=1,2,\dots$ ) 를 매핑시키는 함수이다.
- 따라서  $X(\xi_i) = x_i$  ( $i=1,2,\dots$ ) 와 같은 관계를 가지며 대문자로 표현된  $X(\cdot)$  는 확률변수를 나타내며 소문자로 표현된  $x_i$  는 확률변수가 갖는 값을 나타낸다.
- 확률변수를 사용한 사건과 확률의 표현

$$A = \{\zeta \in S : X(\zeta) \leq x\}$$

$$P(X \leq x) = P(A) = P(\{\zeta \in S : X(\zeta) \leq x\})$$


# 확률분포 함수

- 확률분포 함수(probability distribution function: PDF) 또는 누적분포 함수(cumulative distribution function: CDF)

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

- CDF의 성질

- i)  $0 \leq F_X(x) \leq 1$
- ii)  $F_X(\infty) = 1$
- iii)  $F_X(-\infty) = 0$
- iv)  $F_X(x_1) \leq F_X(x_2)$  for  $x_1 < x_2$



- 확률과의 관계

$$P(x_1 < X \leq x_2) = F_X(x_2) - F_X(x_1)$$

## 예제 6.3



- 주사위를 던져서 나온 눈의 개수를 확률변수의 값으로 취하는 실험을 고려하자. 이 확률변수의 CDF를 구하라.

$$P(X = 1) = P(X = 2) = P(X = 3) = P(X = 4) = P(X = 5) = P(X = 6) = \frac{1}{6}$$

$$\text{For } x < 1 \quad F_X(x) = 0$$

$$\text{For } 1 \leq x < 2 \quad F_X(x) = P(X \leq x) = P(X = 1) = 1/6$$

$$F_X(x) = \sum_{i=1}^6 P(X = i)u(x-i) = \sum_{i=1}^6 \frac{1}{6}u(x-i)$$



# 확률밀도 함수

## □ 확률밀도 함수(probability density function: pdf)


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

- 확률밀도 함수의 성질

- i)  $f_X(x) \geq 0$  for all  $x$

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

- iii)  $F_X(x) = \int_{-\infty}^x f_X(x) dx$



## 예제 6.4

□ 어떤 확률변수  $X$ 의 pdf가 다음과 같이 주어진다고 하자.

$$f_X(x) = a e^{-b|x|}$$

- (a) 확률분포함수  $F_X(x)$ 를 구하라.
- (b) 상수  $a$ 와  $b$ 는 어떤 관계를 가지는가?
- (c) 확률변수  $X$ 가 1과 2 사이의 값을 가질 확률을 구하라.

## 예제 6.4

□ 풀이

(a) 확률분포함수

$$F_X(x) = \int_{-\infty}^x f_X(x) dx = \int_{-\infty}^x a e^{-b|x|} dx$$
$$= \begin{cases} \frac{a}{b} e^{bx} & x \leq 0 \\ \frac{a}{b} (2 - e^{-bx}) & x \geq 0 \end{cases}$$

(b)  $\int_{-\infty}^{\infty} f_X(x) dx = \int_{-\infty}^{\infty} a e^{-b|x|} dx = \frac{2a}{b} = 1$

$\Rightarrow b = 2a$

(c) 확률변수  $X$ 가 1과 2 사이의 값을 가질 확률

$$P(1 < X \leq 2) = \frac{b}{2} \int_1^2 e^{-b|x|} dx = \frac{1}{2} [e^{-b} - e^{-2b}]$$

# Joint CDF and Joint pdf



- 결합분포 함수(joint distribution function)

$$F_{XY}(x, y) = P(X \leq x, Y \leq y)$$

- 결합확률밀도 함수(joint pdf)

$$f_{XY}(x, y) = \frac{\partial^2}{\partial x \partial y} F_{XY}(x, y)$$

$$P(x_1 \leq X \leq x_2, y_1 \leq Y \leq y_2) = \int_{y_1}^{y_2} \int_{x_1}^{x_2} f_{XY}(x, y) dx dy$$



# Joint CDF and Joint pdf

## □ Joint pdf의 성질

$$\text{i) } F_{XY}(\infty, \infty) = P(X \leq \infty, Y \leq \infty) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f_{XY}(x, y) dx dy = 1$$

$$\text{ii) } F_X(x) = P(X \leq x, -\infty \leq Y \leq \infty) = \int_{-\infty}^x \int_{-\infty}^{\infty} f_{XY}(x, y) dx dy$$

$$\text{iii) } f_X(x) = \int_{-\infty}^{\infty} f_{XY}(x, y) dy$$

## □ Independent random variables

- 두 확률변수  $X$ 와  $Y$ 가 서로 독립이라면

$$F_{XY}(x, y) = P(X \leq x, Y \leq y) = P(X \leq x) P(Y \leq y) = F_X(x) F_Y(y)$$

$$f_{XY}(x, y) = f_X(x) f_Y(y)$$



---

# *Statistical Averages*

# 통계적 평균

## □ 평균값(mean value)

$$m_X \equiv \bar{X} \equiv E[X] \triangleq \int_{-\infty}^{\infty} x f_X(x) dx$$

- 이산 확률변수의 경우

$$m_X \equiv \bar{X} \equiv E[X] \triangleq \sum_i x_i P(x_i)$$

where  $P(x_i) = P(X = x_i)$  is called probability mass function (pmf)

- Function of random variable  $Y=g(X)$ 의 평균

$$m_Y = E[Y] = \int_{-\infty}^{\infty} y f_Y(y) dy \quad \text{또는}$$

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

# 통계적 평균

## □ Moments

- 확률변수  $X$ 의  $n$ 차 moment

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

$$n = 1 \Rightarrow \text{mean}$$

$$n = 2 \Rightarrow \text{mean square value}$$

- 확률변수  $X$ 의  $n$ 차 central moment

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

$$n = 2 \Rightarrow \text{variance}$$

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

$$\sigma_X^2 = E[X^2] - 2m_X^2 + m_X^2 = E[X^2] - m_X^2$$

# 통계적 평균

## □ 예제 6.6

- 확률변수  $X$ 의 평균과 분산을 각각  $m_X$ 와  $\sigma_X$ 라고 하자. 상수  $a$ 와  $b$ 에 대하여  $Y=aX+b$ 로 표현되는 확률변수  $Y$ 의 평균과 분산을 구하라.

## □ 풀이

$$m_Y = E[aX + b] = \int_{-\infty}^{\infty} (ax + b) f_X(x) dx = am_X + b$$

$$\begin{aligned}\sigma_Y^2 &= E[(Y - m_Y)^2] = E[(aX + b - am_X - b)^2] \\ &= E[a^2(X - m_X)^2] \\ &= a^2\sigma_X^2\end{aligned}$$

# 통계적 평균

## □ Joint Moment

- 두 확률변수  $X$ 와  $Y$ 의  $jk$ 차 결합 모멘트

$$E[X^j Y^k] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x^j y^k f_{XY}(xy) dx dy$$

## □ Correlation

- For  $j = k = 1$ ,  $E[XY]$  is called correlation of  $X$  and  $Y$
- 만일 두 확률변수가 독립이라면

$$\begin{aligned} f_{XY}(xy) &= f_X(x) f_Y(y) \\ \Rightarrow E[XY] &= E[X] E[Y] \end{aligned}$$

# 통계적 평균

## □ Joint Central Moment

- 두 확률변수  $X$ 와  $Y$ 의  $jk$ 차 joint central moment

$$E[(X - m_X)^j (Y - m_Y)^k] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} (x - m_X)^j (y - m_Y)^k f_{XY}(xy) dx dy$$

## □ Covariance

- For  $j = k = 1$ ,

$\text{cov}(X, Y) = \sigma_{XY} = E[(X - m_X)(Y - m_Y)]$  is called covariance of  $X$  and  $Y$

- Correlation과의 관계

$$\sigma_{XY} = E[XY] - m_X m_Y$$

- 만일 두 확률변수가 독립이라면,  $E[XY] = E[X] E[Y]$  이므로

$$\sigma_{XY} = 0$$

# 통계적 평균

## □ 상관계수(Correlation Coefficient)

- Covariance를 normalize한 값

$$\rho = \frac{\sigma_{XY}}{\sigma_X \sigma_Y} = \frac{E[(X - m_X)(Y - m_Y)]}{\sqrt{E[(X - m_X)^2]E[(Y - m_Y)^2]}}$$

- 두 확률변수가 독립적이라면,  $\rho = 0$
- 두 확률변수가 완전히 종속되어  $Y=aX$  와 같은 관계를 가지는 경우

$$\rho = \frac{\sigma_{XY}}{\sigma_X \sigma_Y} = \frac{a\sigma_X^2}{\sqrt{a^2\sigma_X^2}} = \frac{a}{|a|} = \pm 1$$

- 상관계수의 범위  
 $-1 \leq \rho \leq +1$

# 통계적 평균

## □ 상관계수(Correlation Coefficient)

- 상관계수가 0인 경우, 두 확률변수가 **uncorrelated** 되었다고 한다.
- If two random variables are **independent**, they are also **uncorrelated**.
- 그러나 역은 반드시 성립하지는 않음
- 즉 uncorrelated 확률변수들의 joint pdf가 separable하지 않음
- Special case: jointly Gaussian random variable의 경우 uncorrelated되면 independent함

# 확률변수의 합

## □ 두 확률변수의 합 $Z = X + Y$

- 평균

$$m_Z = E[X + Y] = E[X] + E[Y] = m_X + m_Y$$

- 분산

$$\begin{aligned}\sigma_Z^2 &= E[(X + Y - m_X - m_Y)^2] = E[\{(X - m_X) + (Y - m_Y)\}^2] \\ &= E[(X - m_X)^2 + (Y - m_Y)^2 + 2(X - m_X)(Y - m_Y)] \\ &= \sigma_X^2 + \sigma_Y^2 + 2\sigma_{XY}\end{aligned}$$

확률변수들이 서로 독립적이라면

$$\sigma_Z^2 = \sigma_X^2 + \sigma_Y^2$$

# 확률변수의 합

## □ 두 확률변수의 합 $Z = X + Y$

- 분포 특성

$$F_Z(z) = P(Z \leq z) = P(-\infty < x < \infty, y \leq z - x)$$

$$= \int_{-\infty}^{\infty} \int_{-\infty}^{z-x} f_{XY}(x, y) dx dy$$

$$= \int_{-\infty}^{\infty} dx \int_{-\infty}^{z-x} f_{XY}(x, y) dy$$

$$f_Z(z) = \frac{dF_Z(z)}{dz} = \int_{-\infty}^{\infty} f_{XY}(x, z - x) dx \quad \text{Superposition integral}$$

- 두 확률변수가 서로 독립적이라면  $f_{XY}(x, z - x) = f_X(x)f_Y(z - x)$   
이므로

$$f_Z(z) = \int_{-\infty}^{\infty} f_X(x)f_Y(z - x) dx \quad \text{Convolutional integral}$$

# 확률변수의 합

□  $N$  개 확률변수의 합

$$Z = \sum_{k=1}^n X_k$$

• 평균

$$m_Z = \sum_{k=1}^n m_{X_k}$$

• 분산

$$\text{var}(Z) = \sum_{k=1}^n \text{var}(X_k) + \sum_{j=1}^n \sum_{\substack{k=1 \\ k \neq j}}^n \text{cov}(X_j, X_k)$$

확률변수들이 서로 독립적이라면

$$\text{var}(Z) = \sum_{k=1}^n \text{var}(X_k)$$

# 확률변수의 합

## □ Central Limit Theorem


- 확률변수  $X_1, X_2, \dots, X_n$  이 서로 독립적이면서 동일한 확률밀도함수를 가진다고 가정하자.
- 그러면  $Z$ 의 확률밀도 함수는  $X_k$ 의 확률밀도 함수를  $N$ 번 컨볼루션한 모양을 갖게 된다.
- 함수의 모양에 관계 없이 동일한 함수를 계속 컨볼루션 하게 되면 그 결과는 가우시안 pdf와 같이 종 모양의 함수에 근접하게 된다.
- 즉  $X_k$ 의 pdf 모양에 관계 없이  $Z$ 의 pdf는 가우시안 pdf에 근접하게 된다.



# Gaussian 분포

- 평균이  $m$ 이고 분산이  $\sigma^2$ 인 Gaussian 확률변수의 pdf

$$f_X(x) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left[-\frac{(x-m)^2}{2\sigma^2}\right]$$



# Q Function

- 평균이 0이고 분산이 1인 Gaussian 확률변수의 pdf

$$f_X(x) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{x^2}{2}\right)$$

- CDF

$$F_X(x) = P(X \leq x) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{u^2}{2}\right) du$$

- Q function

$$Q(x) \triangleq \int_x^{\infty} \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{u^2}{2}\right) du$$

- Q 함수의 성질

$$Q(x) = P(X > x) = 1 - F_X(x)$$

$$Q(0) = 0.5$$

$$Q(-x) = 1 - Q(x)$$

# Q Function

## □ Q function의 근사화

$$Q(x) \simeq \frac{1}{x\sqrt{2\pi}} \exp\left(-\frac{x^2}{2}\right) \quad \text{for } x \gg 1$$

## □ Gaussian 분포의 확률의 표현

$$\begin{aligned} P(X \leq x) &= F_X(x) = \int_{-\infty}^x \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{(u-m)^2}{2\sigma^2}\right) du \\ &= \frac{1}{\sqrt{2\pi}} \int_{-\infty}^{(x-m)/\sigma} \exp\left(-\frac{y^2}{2}\right) dy \\ &= 1 - Q\left(\frac{x-m}{\sigma}\right) \end{aligned}$$

$$P(X > x) = Q\left(\frac{x-m}{\sigma}\right)$$

$$P(x_1 < X \leq x_2) = Q\left(\frac{x_1-m}{\sigma}\right) - Q\left(\frac{x_2-m}{\sigma}\right)$$

# Q Function

## □ Error Function

$$erf(x) \triangleq \frac{2}{\sqrt{\pi}} \int_0^x \exp(-u^2) du$$

## □ Complementary Error Function

$$erfc(x) \triangleq 1 - erf(x) = \frac{2}{\sqrt{\pi}} \int_x^{\infty} \exp(-u^2) du$$

## □ Complementary error function과 Q function과의 관계

$$erfc(x) = 2Q(\sqrt{2} x)$$

# Rayleigh 분포

## □ 두 개의 확률변수

- X와 Y가 서로 독립적이며, 평균이 0이고 분산이 동일하게  $\sigma^2$ 인 가우시안 확률밀도 함수를 가진다고 하자.
- 두 확률변수의 결합 확률밀도 함수는 다음과 같이 주어진다.

$$\begin{aligned} f_{XY}(x, y) &= f_X(x)f_Y(y) \\ &= \frac{\exp\left(-\frac{x^2}{2\sigma^2}\right)}{\sigma\sqrt{2\pi}} \cdot \frac{\exp\left(-\frac{y^2}{2\sigma^2}\right)}{\sigma\sqrt{2\pi}} \\ &= \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right) \end{aligned}$$

## □ Transformation에 의해 만들어지는 새로운 확률변수

$$R = g_1(X, Y) = \sqrt{X^2 + Y^2}$$

$$\Theta = g_2(X, Y) = \tan^{-1}\left(\frac{Y}{X}\right)$$

# Rayleigh 분포


□ 확률변수  $R$ 과  $\Theta$ 의 분포 특성?

$$f_R(r) = \begin{cases} \frac{r}{\sigma^2} \exp\left(-\frac{r^2}{2\sigma^2}\right) & r \geq 0 \\ 0 & r < 0 \end{cases}$$

Rayleigh distribution

$$f_\Theta(\theta) = \begin{cases} \frac{1}{2\pi} & 0 \leq \Theta \leq 2\pi \\ 0 & \text{otherwise} \end{cases}$$

Uniform distribution



$$m_R = \sqrt{\frac{\pi}{2}} \sigma, \quad \sigma_R^2 = \left(2 - \frac{\pi}{2}\right) \sigma^2$$

# Rayleigh 분포

- $N_c$ 와  $N_s$ 가 서로 독립적이며, 평균이 0이고 분산이 동일하게  $\sigma^2$ 인 가우시안 확률변수라 하자.
- 복소 확률변수  $Z = N_c + j N_s$ 
  - 크기  $R = \sqrt{N_c^2 + N_s^2}$  는 Rayleigh 분포를 가지며
  - 위상  $\Theta = \tan^{-1}(N_s / N_c)$  는 uniform 분포를 가진다.

# Ricean 분포

- $N_c$ 와  $N_s$ 가 서로 독립적이며, 평균이 0이고 분산이 동일하게  $\sigma^2$ 인 가우시안 확률변수라 하자.
- 복소 확률변수  $Z = (A + N_c) + j N_s$ 
  - 크기  $R = \sqrt{(A + N_c)^2 + N_s^2}$ 의 분포?


$$f_R(r) = \frac{r}{\sigma^2} \exp\left(-\frac{r^2 + A^2}{2\sigma^2}\right) \cdot I_0\left(\frac{Ar}{\sigma^2}\right) \quad \text{Ricean distribution}$$

where

$$I_0(r) \triangleq \frac{1}{2\pi} \int_{-\pi}^{\pi} \exp(r \cos \theta) d\theta \quad \text{modified zero-order Bessel function of the first kind}$$

# Ricean 분포

- $A=0$ 이면 라이시안 밀도 함수는 레일리 밀도 함수가 되며,  $A$ 가  $\sigma$ 에 비해 점점 커질수록 라이시안 밀도 함수는 가우시안 밀도 함수에 근접해간다.






---

# *Random Process*

# Random Process


- 확률변수는 불확실한 어떤 사건을 숫자로 모델링하는데 사용
- Random process는 불확실한 어떤 신호를 모델링하는데 사용
- 모든 시간에 대해 신호의 값을 정확히 표현할 수 있으면 그 신호를 결정적 신호(deterministic signal)라 하고, 불확실성이 있어서 정확히 표현할 수 없을 때 그 신호를 랜덤 신호(random signal)라 한다.
- 특정한 순간  $t = t_i$ 에서의 랜덤 프로세스는 확률변수  $X_i = X(t)|_{t=t_i} = X(t_i)$ 가 된다.

# Random Process




# Random Process의 예

- 랜덤 프로세스  $X(t) = 10 \cos(100\pi t + \Theta)$ 의 표본 함수



# Random Process의 예

- 랜덤 프로세스  $X(t) = A \cos(100\pi t)$  의 표본 함수



# Statistical Averages

## □ Mean

$$m_X(t) = E[X(t)] = \int_{-\infty}^{\infty} xf_X(x;t)dx$$

- 평균은 시간의 함수임

## □ Variance

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

# Statistical Averages

## □ Autocorrelation

$$R_X(t_1, t_2) \triangleq E[X(t_1)X(t_2)] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x_1 x_2 f_{X_1 X_2}(x_1, x_2; t_1, t_2) dx_1 dx_2$$

- $t_1 = t_2$ 이면 autocorrelation은 전력이 된다.

$$P(t_1) \equiv R_X(t_1, t_1) \triangleq E[|X(t_1)|^2] = \int_{-\infty}^{\infty} |x_1|^2 f_{X_1}(x_1; t_1) dx_1$$

## □ Crosscorrelation



$$R_{XY}(t_1, t_2) \triangleq E[X(t_1)Y(t_2)] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x_1 y_2 f_{X_1 Y_2}(x_1, y_2; t_1, t_2) dx_1 dy_2$$

# Autocorrelation

## □ Autocorrelation의 의미

- $R_X(t_1, t_2)$ 는 랜덤 프로세스  $X(t)$ 의 통계적 특성이  $t_1$ 으로부터  $\tau = t_2 - t_1$  초 지난 후에 얼마나 유사한지를 나타낸다고 볼 수 있다.
- 다음 그림 (a)와 같이 느리게 변하는 랜덤 프로세스에서는 상당히 큰 값의  $\tau$ 에 대해서도  $X(t_1)$ 과  $X(t_2)$ 가 상관성을 가지겠지만, 그림 (b)와 같이 빠르게 변하는 랜덤 프로세스에서는 작은  $\tau$ 에 대해서도 상관성이 거의 없어진다.
- 따라서 자기상관 함수를 알면 그 랜덤 프로세스의 표본 함수의 파형이 빠르게 변하는지 느리게 변하는지 예측할 수 있으며, 결과적으로 주파수 성분에 대한 정보를 알 수 있게 된다.
- 랜덤 프로세스에 대한 전력스펙트럼 밀도(PSD)는 자기상관 함수의 푸리에 변환으로 주어진다.

# Autocorrelation



# Ergodic Process

## □ Random signal의 전력과 자기상관 함수

- Ensemble average로 표현

$$R_X(t_1, t_2) = E[X(t_1)X(t_2)] = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} x_1 x_2 f_{X_1 X_2}(x_1, x_2; t_1, t_2) dx_1 dx_2$$

$$P(t_1) = E[|X(t_1)|^2] = \int_{-\infty}^{\infty} |x_1|^2 f_{X_1}(x_1; t_1) dx_1$$

## □ Deterministic signal의 전력과 자기상관 함수

- Time average로 표현

$$R_x(\tau) = \langle x(t)x(t + \tau) \rangle = \lim_{T \rightarrow \infty} \frac{1}{T} \int_{-T/2}^{T/2} x(t)x(t + \tau) dt$$

$$P = \langle x(t)^2 \rangle = \lim_{T \rightarrow \infty} \frac{1}{T} \int_{-T/2}^{T/2} x^2(t) dt$$


## □ Ergodic Process

- Ensemble average = time average

# Stationarity

## □ Joint pdf

- 일반적인 nonstationary process는 시간에 따라 다른 joint pdf를 가짐
- 예: 2차 joint pdf



## □ Second order stationary

$$f_{X_1 X_1'}(x_1, x_1'; t_1, t_1 + \tau) = f_{X_2 X_2'}(x_2, x_2'; t_2, t_2 + \tau)$$

# Stationarity

## □ Stationary Process

- First order stationary

$$f_{X_1}(x_1; t_1) = f_{X_1'}(x_1'; t_1 + \tau)$$

- Second order stationary

$$f_{X_1 X_2}(x_1, x_2; t_1, t_2) = f_{X_1' X_2'}(x_1', x_2'; t_1 + \tau, t_2 + \tau)$$

- (Strict sense) stationary

$$f_{X_1 X_2 X_3 \dots}(x_1, x_2, x_3, \dots; t_1, t_2, t_3, \dots) = f_{X_1' X_2' X_3' \dots}(x_1', x_2', x_3', \dots; t_1 + \tau, t_2 + \tau, t_3 + \tau, \dots)$$

# Stationarity

## □ Stationary Process의 성질

- First order stationary하면, 즉  $f_{X_1}(x_1; t_1) = f_{X_1'}(x_1'; t_1 + \tau)$   
 $E[X(t)] = m_X(t) = m_X \Rightarrow$  constant (not time varying)
- Second order stationary 하면, 즉  $f_{X_1 X_2}(x_1, x_2; t_1, t_2) = f_{X_1' X_2'}(x_1', x_2'; t_1 + \tau, t_2 + \tau)$   
 $E[X(t)] = m_X(t) = m_X \Rightarrow$  constant (not time varying)  
 $R_X(t_1, t_2) = R_X(t_1 - t_2) = R_X(\tau) \Rightarrow$  function of time difference
- Second order stationary 하면 평균은 상수이고 자기상관 함수는 시간차의 함수이지만, 역은 성립하지 않는다.
- 즉 평균이 상수이고 자기상관 함수가 시간차의 함수인 프로세스가 반드시 second order stationary한 것은 아님.

# Stationarity


## □ Wide Sense Stationary (WSS) Process

- 평균이 상수이고 자기상관 함수가 시간차의 함수인 프로세스
- WSS 프로세스의 자기상관 함수와 전력

$$R_X(\tau) = E[X(t)X(t + \tau)]$$

$$P = R_X(0) = E[X^2(t)]$$

## □ Random process의 분류



# Stationarity

## □ 예제 6.7 $X(t) = A \cos(2\pi t)$

- 여기서  $A$ 는 확률변수로  $f_A(a)$ 의 pdf를 갖는다고 하자.
- 이 랜덤 프로세스의 평균과 자기상관 함수를 표현해 보라.
- 이 랜덤 프로세스는 WSS인가?

## □ 풀이

$$\begin{aligned} m_X(t) &= E[X(t)] = \int_{-\infty}^{\infty} x f_X(x; t) dx = E[A \cos(2\pi t)] \\ &= \int_{-\infty}^{\infty} a \cos(2\pi t) f_A(a) da = E[A] \cos(2\pi t) \\ &= m_A \cos(2\pi t) \end{aligned}$$

$$\begin{aligned} R_X(t_1, t_2) &= E[X(t_1)X(t_2)] = E[A \cos(2\pi t_1) \cdot A \cos(2\pi t_2)] \\ &= E[A^2] \cos(2\pi t_1) \cos(2\pi t_2) \end{aligned}$$

- WSS하지 않음

# Stationarity

## □ 예제 6.8 $X(t) = \cos(\omega t + \Theta)$


- 여기서  $\Theta$ 는 확률변수로  $(-\pi, \pi)$ 에서 균일한 분포 특성을 갖는다.
- 이 랜덤 프로세스의 평균과 자기상관 함수를 표현해 보라.
- 이 랜덤 프로세스는 WSS인가?

## □ 풀이

$$\begin{aligned} m_X(t) &= E[X(t)] = \int_{-\infty}^{\infty} x f_X(x; t) dx = E[\cos(\omega t + \Theta)] \\ &= \int_{-\infty}^{\infty} \cos(\omega t + \theta) f_{\Theta}(\theta) d\theta = \frac{1}{2\pi} \int_{-\pi}^{\pi} \cos(\omega t + \theta) d\theta = 0 \end{aligned}$$

$$\begin{aligned} R_X(t_1, t_2) &= E[X(t_1)X(t_2)] = E[\cos(\omega t_1 + \Theta) \cdot \cos(\omega t_2 + \Theta)] \\ &= \int_{-\infty}^{\infty} \cos(\omega t_1 + \theta) \cos(\omega t_2 + \theta) f_{\Theta}(\theta) d\theta \\ &= \int_{-\pi}^{\pi} \frac{1}{2} [\cos\{\omega(t_1 - t_2)\} + \cos\{\omega(t_1 + t_2) + 2\theta\}] \cdot \frac{1}{2\pi} d\theta \\ &= \frac{1}{2} \cos\{\omega(t_1 - t_2)\} = \frac{1}{2} \cos(\omega\tau) \end{aligned}$$

- WSS



# Random Process의 주파수영역 해석

- 랜덤 프로세스를 입력으로 하는 선형 시스템의 해석
  - 랜덤 프로세스와 랜덤 프로세스를 입력으로 하는 선형 시스템의 해석도 주파수 영역 해석이 가능한지 의문을 갖게 된다.
  - 랜덤 프로세스의 모든 표본 함수들이 모든 시구간 에서 존재한다고 가정하면 랜덤 프로세스는 전력 신호로 분류된다는 것을 알 수 있다.
  - 그렇다면 랜덤 프로세스의 전력 스펙트럼 밀도(PSD)가 존재하는지 살펴 보아야 할 것이다.

# Random Process의 주파수영역 해석

- 랜덤 프로세스를 입력으로 하는 선형 시스템의 해석
  - 그러나 랜덤 프로세스의 푸리에 변환이나 PSD에 대한 개념을 적용하는데 몇 가지 문제가 있다.
  - 첫 째 랜덤 프로세스는 수식으로 정확하게 표현할 수 없으며,
  - 둘 째 랜덤 프로세스를 제공하여 적분함으로써 푸리에 변환이 존재하는지 판단하는 개념을 적용할 수 없어서 랜덤 프로세스에 직접적으로 푸리에 변환을 취할 수 없으며,
  - 셋 째 랜덤 프로세스의 표본 함수는 푸리에 변환이 가능하다고 하더라도 표본 함수가 모두 다르므로 주파수 특성을 일관적으로 나타내는 PSD를 제시하는 것은 불가능하다.
  - 그러나 랜덤 프로세스가 stationary(최소한 WSS)이라면 어느 정도 의미 있는 PSD를 정의하는 것이 가능하다.
  - **Nonstationary** 프로세스의 **PSD**는 존재하지 않는다.

# Random Process의 PSD

## □ Deterministic signal의 PSD

$$S_x(f) = \mathcal{F}[R_x(\tau)] = \lim_{T \rightarrow \infty} \frac{|X_T(f)|^2}{T}$$

where

$$R_x(\tau) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_{-T/2}^{T/2} x(t)x(t + \tau)dt = \lim_{T \rightarrow \infty} \frac{1}{T} \int_{-\infty}^{\infty} x_T(t)x_T(t + \tau)dt$$

## □ WSS process의 PSD

- 위의 수식에서 time average를 ensemble average로 대체
- Autocorrelation

$$R_x(\tau) = E[X(t)X(t + \tau)]$$

- PSD

$$S_X(f) = \mathcal{F}[R_x(\tau)]$$

- Power

$$P = E[X^2(t)] = R_x(0) = \int_{-\infty}^{\infty} S_X(f)df$$

# Linear System

## □ Linear system 출력의 PSD

- 랜덤 프로세스  $X(t)$ 가 전달함수가  $H(f)$ 인 선형 시불변 시스템의 입력으로 가해지는 경우 출력은 역시 랜덤 프로세스가 된다.
- 출력 프로세스  $Y(t)$ 의 자기상관 함수

$$R_Y(\tau) = h(\tau) * h(-\tau) * R_X(\tau)$$

- 출력 프로세스  $Y(t)$ 의 PSD

$$S_Y(f) = |H(f)|^2 S_X(f)$$

## 예제 6.9

### □ 랜덤 신호의 진폭변조

- 메시지 신호  $M(t)$ 가 WSS인 랜덤 프로세스라고 하자. 이 신호를 DSB-SC 변조한 신호

$$X(t) = M(t) \cos(\omega_c t + \Theta)$$

의 자기상관 함수와 PSD를 구하라. 여기서  $\Theta$ 는  $(0, 2\pi)$ 에서 균일한 분포 특성을 갖는 확률변수이며  $M(t)$ 와는 독립이라고 가정한다.


### □ 풀이

$$\begin{aligned} R_X(\tau) &= E[X(t)X(t + \tau)] \\ &= E[M(t) \cos(\omega_c t + \Theta) M(t + \tau) \cos(\omega_c(t + \tau) + \Theta)] \\ &= E[M(t)M(t + \tau)] \cdot E[\cos(\omega_c t + \Theta) \cos(\omega_c(t + \tau) + \Theta)] \\ &= \frac{1}{2} R_M(\tau) \cos(\omega_c \tau) \\ S_X(f) &= \frac{1}{4} [S_M(f - f_c) + S_M(f + f_c)] \end{aligned}$$



# Bandpass Process

- 대역폭이  $2B$  Hz인 대역통과 랜덤 프로세스의 예



- Quadrature form

$$X(t) = X_c(t) \cos 2\pi f_c t + X_s(t) \sin 2\pi f_c t$$


여기서  $X_c(t)$ 와  $X_s(t)$ 는 대역폭이  $B$  Hz인 기저대역 랜덤 프로세스이다

- Polar form

$$X(t) = R(t) \cos(2\pi f_c t + \Theta(t))$$

# Bandpass Process

□  $X_c(t)$ 와  $X_s(t)$ 의 통계적 특성과  $X(t)$ 와의 관계?




$$S_{X_c}(f) = S_{X_s}(f) = \begin{cases} S_X(f - f_c) + S_X(f + f_c) & |f| < B \\ 0 & |f| > B \end{cases}$$

$$E[X^2(t)] = E[X_c^2(t)] = E[X_s^2(t)]$$

## 예제 6.11

### □ 대역통과 백색잡음

- 그림과 같이 대역폭이  $2B$ 이고 PSD가 일정한 크기  $N_0/2$ 인 대역통과 랜덤 프로세스  $N(t)$ 가 있다고 하자. 이 프로세스를 직교 성분들을 이용하여 표현하라. 직교 성분  $N_c(t)$ 와  $N_s(t)$ 의 PSD를 유도하고 전력을 구하라.



## 예제 6.11

### □ 풀이

$$N(t) = N_c(t) \cos 2\pi f_c t + N_s(t) \sin 2\pi f_c t$$

- 직교 성분들의 PSD

$$\begin{aligned} S_{N_c}(f) = S_{N_s}(f) &= \begin{cases} S_N(f - f_c) + S_N(f + f_c) & |f| < B \\ 0 & |f| > B \end{cases} \\ &= \begin{cases} N_0 & |f| < B \\ 0 & |f| > B \end{cases} \end{aligned}$$

- $N(t)$ 의 전력

$$E[N^2(t)] = \int_{-\infty}^{\infty} S_N(f) df = 2 \int_{f_c-B}^{f_c+B} \frac{N_0}{2} df = 2N_0B$$

- 직교 성분들의 전력

$$E[N_c^2(t)] = E[N_s^2(t)] = \int_{-B}^B N_0 df = 2N_0B$$

- 따라서  $N_c(t)$ ,  $N_s(t)$ ,  $N(t)$ 는 모두 동일한 전력을 갖는다:

$$E[N_c^2(t)] = E[N_s^2(t)] = E[N^2(t)] = 2N_0B$$



# White Noise


## □ PSD

$$S_N(f) = N_0 / 2$$

## □ Autocorrelation

$$R_N(\tau) = \frac{N_0}{2} \delta(\tau)$$

## □ Power = $\infty$



# Lowpass White Noise

## □ PSD


$$S_N(f) = \frac{N_0}{2} \Pi\left(\frac{f}{2B}\right)$$

## □ Autocorrelation

$$R_N(\tau) = N_0 B \operatorname{sinc}(2B\tau)$$


## □ Power

$$P = E[N^2(t)] = \int_{-\infty}^{\infty} S_N(f) df = \int_{-\infty}^{\infty} \frac{N_0}{2} df = N_0 B$$



# Lowpass White Noise


## □ Lowpass White Noise의 Generation Model



$$|H(f)| = \Pi\left(\frac{f}{2B}\right)$$

# Bandpass White Gaussian Noise

- 평균이 0이고 주파수  $f_c$ 를 중심으로 대역폭  $2B$ 에 걸쳐서 PSD가 균일하게  $N_0/2$ 인 대역통과 백색 가우시안 랜덤 프로세스



$$N(t) = N_c(t) \cos 2\pi f_c t + N_s(t) \sin 2\pi f_c t$$

$$S_{N_c}(f) = S_{N_s}(f) = \begin{cases} N_0 & |f| < B \\ 0 & |f| > B \end{cases}$$

$$E[N_c^2(t)] = E[N_s^2(t)] = E[N^2(t)] = 2N_0B$$

# Bandpass White Gaussian Noise

- 직교 성분  $N_c(t)$ 와  $N_s(t)$ 는 uncorrelated이며 평균이 0이고 분산이  $\sigma^2 = 2N_0B$ 인 가우시안 분포 특성을 갖는다.
- 일반적으로 결합 확률 분포에서 두 확률 변수가 독립이면 서로 무상관이지만 그 역은 성립하지 않는다.
- 그러나 가우시안 분포의 경우에는 두 확률 변수가 무상관인 것과 두 확률 변수가 독립이라는 것이 동등하게 성립한다.
- 따라서 대역통과 백색 가우시안 랜덤 프로세스에서  $N_c(t)$ 와  $N_s(t)$ 는 서로 독립이며, 이들의 pdf는 동일하게 다음과 같이 주어진다.

$$f_{N_c}(n) = f_{N_s}(n) = \frac{1}{\sigma\sqrt{2\pi}} \exp\left(-\frac{n^2}{2\sigma^2}\right)$$

where

$$\sigma^2 = 2N_0B$$

# Bandpass White Gaussian Noise

## □ Bandpass White Noise의 Polar Form 표현

$$N(t) = R(t) \cos[2\pi f_c t + \Theta(t)]$$

$$R(t) = \sqrt{N_c^2(t) + N_s^2(t)}$$

$$\Theta(t) = -\tan^{-1}\left(\frac{N_s(t)}{N_c(t)}\right)$$

## □ 크기와 위상의 분포특성?

- $R(t)$ 와  $\Theta(t)$ 는 서로 독립이며,  $R(t)$ 는 Rayleigh 분포 특성을 갖고,  $\Theta(t)$ 는 uniform 분포 특성을 갖는다.

$$f_R(r) = \frac{r}{\sigma^2} \exp\left(-\frac{r^2}{\sigma^2}\right), \quad r \geq 0, \quad \sigma^2 = 2N_0B$$

$$f_\Theta(\theta) = \frac{1}{2\pi}, \quad 0 \leq \theta \leq 2\pi$$