

# 기계학습 Assignment2

2023 2학기

1 (20 points) 본 문항은 constrained optimization을 위한 Lagrangian multiplier 에 관한 것이다. Bishop교재의 Appendix E를 중점적으로 참조하여 다음 물음에 답하시오.

(i) Equality constraint  $g(\mathbf{x}) = 0$ 가 만족하는 다음 최적화 문제를 가정하자.

$$\begin{aligned} & \text{maximize } f(\mathbf{x}) \\ & \text{subject to } g(\mathbf{x}) = 0 \end{aligned} \quad (1)$$

표기를 단순화 하기 위해, 임의의 함수  $h(\mathbf{x})$ 의 gradient 벡터  $\nabla h$ 를 다음과 같이 정의하자.

$$\nabla h = \frac{\partial h(\mathbf{x})}{\partial \mathbf{x}} \quad (2)$$

식 (1)의 최적화 문제의 solution을  $\mathbf{x}^*$ 라 할때, 다음과 같이  $\nabla f$ 와  $\nabla g$ 가 서로 **평행 (parallel)**이 되어야 함을 설명하시오<sup>1</sup>.

$$\nabla f(\mathbf{x}^*) = \lambda \nabla g(\mathbf{x}^*) \quad (3)$$

여기서  $\lambda \in \mathbb{R}$ 로 임의의 실수이다.

(ii) Inequality constraint  $g(\mathbf{x}) \geq 0$ 를 갖는 다음 최적화 문제가 주어졌다고 하자.

$$\begin{aligned} & \text{maximize } f(\mathbf{x}) \\ & \text{subject to } g(\mathbf{x}) \geq 0 \end{aligned} \quad (4)$$

식 (4)의 최적화 문제의 solution이  $\mathbf{x}^*$ 이라고 하자.  $\mathbf{x}^*$ 은 두 가지 case로 나뉘는데, 1) 제약 영역 경계에 위치하는  $g(\mathbf{x}^*) = 0$ 를 만족하는 *active solution*, 2) 제약 영역 안에 위치하는  $g(\mathbf{x}^*) > 0$ 를 만족하는 *inactive solution*의 두 가지 경우로 나뉜다. 먼저, active 해인  $g(\mathbf{x}^*) = 0$ 인 경우에 다음과 같이  $\nabla f$ 와  $\nabla g$ 이 방향이 서로 **반대**이어야 함을 설명하시오.

$$\nabla f(\mathbf{x}) = -\lambda \nabla g(\mathbf{x}) \quad (5)$$

이 경우에는 방향이 반대임을 보장하기 위해  $\lambda > 0$ 이다.

다음으로, inactive 해인  $g(\mathbf{x}^*) > 0$ 인 경우에는 다음과 같이 unconstrained optimization문제와 equivalent함을 간단히 설명하시오.

$$\nabla f(\mathbf{x}) = 0 \quad (6)$$

(iii) 앞 문항의 식 (4)의 최적화 문제를 다음 식 (7)의 *Lagrangian function* 를 최적화하는 문제로 변환하고자 한다.

$$L(\mathbf{x}, \lambda) = f(\mathbf{x}) + \lambda g(\mathbf{x}) \quad (7)$$

<sup>1</sup>두 벡터는 같은 방향이거나 반대 방향이 될 수 있다.

이때 다음 KKT (Karush-Kuhn-Tucker) 조건이 성립해야 함을 설명하시오.

$$\begin{aligned} g(\mathbf{x}) &\geq 0 \\ \lambda &\geq 0 \\ \lambda \cdot g(\mathbf{x}) &= 0 \end{aligned} \tag{8}$$

특히, 위의 KKT 조건이 앞에서 유도한 두 가지 경우에 대한 조건인 식 (5)과 식 (6)을 포함함을 보이시오.

2 (30 points) 본 문항에서는 **Lagrange dual problem** 내용을 정리하고자 한다.  $m$ 개의 inequality constraint가 있는 다음 최적화 문제를 가정하자.

$$\begin{aligned} &\text{maximize } f(\mathbf{x}) \\ &\text{subject to } g_i(\mathbf{x}) \geq 0 \text{ for } 1 \leq i \leq m \end{aligned} \tag{9}$$

위의 식을 **primal form**이라고 하고, 이를 **dual form**으로 변환하기 위해 다음 Lagrangian function을 사용한다.

$$L(\mathbf{x}, \boldsymbol{\lambda}) = f(\mathbf{x}) + \sum_{i=1}^m \lambda_i g_i(\mathbf{x}) \tag{10}$$

여기서  $\lambda_i \geq 0$ ,  $\boldsymbol{\lambda} = [\lambda_1, \dots, \lambda_m]^T$ 이다. 주어진 제약을 모두 만족하는  $\mathbf{x}$ 를 *feasible point*라고 하고, 다음과 같이  $\mathcal{A}$ 를 모든 feasible point들이 집합으로 정의하자.

$$\mathcal{A} = \{\mathbf{x} | g_i(\mathbf{x}) \geq 0 \forall i \in \{1, \dots, m\}\} \tag{11}$$

Bishop 교재외에 다른 자료도 참조하여 다음 물음에 답하시오.

(i) 정의에 따라, 다음과 같이 모든 feasible  $\mathbf{x} \in \mathcal{A}$ 와  $\boldsymbol{\lambda}$ 에 대해서,  $L(\mathbf{x}, \boldsymbol{\lambda})$ 는  $f(\mathbf{x})$ 의 upper bound가 된다.

$$L(\mathbf{x}, \boldsymbol{\lambda}) \geq f(\mathbf{x}) \text{ for } \mathbf{x} \in \mathcal{A} \tag{12}$$

식 (9)의 Primal form의 해(solution)을  $\mathbf{x}^*$ 라고 할때, 다음이 성립함을 보이시오.

$$f(\mathbf{x}^*) = \max_{\mathbf{x}} \min_{\boldsymbol{\lambda} \geq 0} L(\mathbf{x}, \boldsymbol{\lambda}) \tag{13}$$

\*Hint:  $g_i(\mathbf{x}) \geq 0$ 를 만족하는 경우와 그렇지 않는 경우, 전자의 경우에서도  $g_i(\mathbf{x}) > 0$ 와  $g_i(\mathbf{x}) = 0$ 의 경우로 나누어 각 case별로  $\max_{\lambda_i} \lambda_i g_i(\mathbf{x})$ 의 값을 정리해보자.

(ii) Dual form에서는 다음 *Lagrangian dual function*을 사용한다.

$$\tilde{L}(\boldsymbol{\lambda}) = \max_{\mathbf{x}} L(\mathbf{x}, \boldsymbol{\lambda}) \tag{14}$$

Primal form의 해(solution)을  $\mathbf{x}^* \in \mathcal{A}$ 라고 할때, 임의의  $\boldsymbol{\lambda} \geq \mathbf{0}$ 에 대해서, 다음식과 같이 dual function이  $f(\mathbf{x}^*)$ 의 upper bound가 됨을 보이시오.

$$\tilde{L}(\boldsymbol{\lambda}) \geq f(\mathbf{x}^*) \tag{15}$$

\*Hint:  $\mathbf{x} \in \mathcal{A}$ 에 대해서, 식 (12)과 식 (14)을 결합해보자.

- (iii) Lagrangian dual problem (또는 dual form)은  $\tilde{L}(\boldsymbol{\lambda})$ 을 최적화 (최소화)하여  $f(\mathbf{x}^*)$ 의 best upper bound를 구하는 것으로 다음 최적화하는 문제를 가리킨다.

$$\begin{aligned} & \text{minimize } \tilde{L}(\boldsymbol{\lambda}) \\ & \text{subject to } \boldsymbol{\lambda} \geq \mathbf{0} \end{aligned} \quad (16)$$

식 (12)에 따라 마찬가지로 다음이 성립한다.

$$\min_{\boldsymbol{\lambda}} \tilde{L}(\boldsymbol{\lambda}) \geq f(\mathbf{x}^*) \quad (17)$$

Best upper bound와 최적해간의 차이를 **Duality gap**라고 하며, 다음과 같이 정의된다.

$$f(\mathbf{x}^*) - \min_{\boldsymbol{\lambda}} \tilde{L}(\boldsymbol{\lambda}) \quad (18)$$

일반적으로, 식 (18)의 duality gap은 nonzero이지만, 어떠한 최적화 문제의 경우에는 zero가 되며, 이때 dual form과 primal form의 최적값은 서로 동일하다.

이러한 **zero duality gap**의 특징을 가지는 최적화 문제 유형에 대한 조건 중, 주어진 제약식에 대한 feasible point의 존재 유무를 가지고 판단하는 **Slater's condition**이 간단하면서도 잘 알려져있다. Slater's condition이란 무엇인가? Slater's condition을 만족하는 경우와 그렇지 않는 경우의 예시를 각각 제시하시오.

- 3 (20 points) 본 문항에서는 2번의 Lagrangian dual problem 변환 방법을 간단한 예시를 통해 적용해보고자 한다. 다음 각 constrained optimization 문제에 대해서 Lagrangian dual problem로 변환하고 해당 dual form상에서 최적화를 수행하시오.

- (i) 아래 최적화 문제의 primal form 기술하고 dual form을 유도한 후에 해당 Lagrangian dual problem의 최적화를 수행하시오.

$$\begin{aligned} & \text{maximize } f(\mathbf{x}) = 1 - \|\mathbf{x}\|^2 \\ & \text{subject to } g(\mathbf{x}) = \mathbf{1}^T \mathbf{x} - 1 \geq 0 \end{aligned} \quad (19)$$

여기서  $\mathbf{x} \in \mathbb{R}^D$ 이다.

- (ii) 앞문항과 동일하게 최적화를 수행 하시오.

$$\begin{aligned} & \text{maximize } f(\mathbf{x}) = 1 - \|\mathbf{x} - \mathbf{1}\|^2 \\ & \text{subject to } g(\mathbf{x}) = \mathbf{1}^T \mathbf{x} - 1 \geq 0 \end{aligned} \quad (20)$$

\*Hint: KKT 조건도 활용하도록 하자.  $D = 2$ 인 경우에 대해서 2D 좌표상에서 목적 함수와 제약함수의 위치를 확인해봐도 좋다.

- (iii) 위의 최적화 문제가 Slater's condition을 만족하는 지 간단히 설명하시오.

- 4 (20 points) 본 문항은 Support vector machine (SVM)의 margin maximum solution에 관한 것이다.

Binary classification을 위한 학습데이터셋이  $\mathcal{D} = \{(\mathbf{x}_1, t_1), \dots, (\mathbf{x}_N, t_N)\}$ 로 주어지고, 이때  $t_i \in \{-1, 1\}$ 로,  $t_i = 1$ 인 경우는 positive샘플  $t_i = -1$ 인 경우는 negative샘플이라고 하자. Binary classification 위해 linear model을 사용한다고 가정한다.

$$y(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + b$$

학습 단계에서는  $\mathcal{D}$ 상의 모든 데이터들을 정확히 분류하도록 다음 조건을 만족하면서, parameters  $\mathbf{w}$ 와  $b$ 를 결정해야 한다.

$$t_n y(\mathbf{x}_n) > 0 \quad \forall n \in \{1, \dots, N\} \quad (21)$$

위의 조건을 만족하는  $\mathbf{w}$ 와  $b$ 의 집합을 *feasible parameters*  $\mathcal{A}_\theta$ 라고 하고, 구체적으로  $\mathcal{A}_\theta$ 는 다음과 같이 정의된다.

$$\mathcal{A}_\theta = \{(\mathbf{w}, b) | t_n y(\mathbf{x}_n) > 0 \quad \forall n \in \{1, \dots, N\}\} \quad (22)$$

다음 물음에 답하시오.

- (i)  $\mathbf{x}_n \in \mathbb{R}^D$  에서 decision surface  $y(\mathbf{x})$ 에 이르는 거리 (distance)가  $|y(\mathbf{x}_n)|/\|\mathbf{w}\|$ 임을 증명하시오. 또한,  $(\mathbf{w}, b) \in \mathcal{A}_\theta$ 에 대해서, distance가  $t_n y(\mathbf{x}_n)/\|\mathbf{w}\|$ 이 됨을 간단히 보이시오.
- (ii) SVM에서의 margin개념에 대해서 설명하고 generalization error를 감소시키는 측면에서 maximum margin 방법의 장점을 기술하시오.
- (iii) Maximum margin solution이 다음식으로 정리됨을 설명하시오 (Bishop교재 Eq. (7.3)).

$$\arg \max_{(\mathbf{w}, b) \in \mathcal{A}_\theta} \left\{ \frac{1}{\|\mathbf{w}\|} \min_n [t_n y(\mathbf{x}_n)] \right\} \quad (23)$$

- (iv) Bishop교재 Eq. (7.4)에서처럼,  $\mathbf{x}_n$ 를 decision surface상에서 가장 가까운 points인 support vectors 라고 할때, 다음과 같이  $t_n y(\mathbf{x}_n)$ 를 constant value로 고정하는 이유를 기술하시오.

$$t_n y(\mathbf{x}_n) = 1 \quad (24)$$

5 (40 points) Linear SVM의 primal form은 다음과 같다.

$$\begin{aligned} & \text{minimize } \frac{1}{2} \|\mathbf{w}\|^2 \\ & \text{subject to } t_n (\mathbf{w}^T \mathbf{x}_n + b) - 1 \geq 0 \quad \forall n \in \{1, \dots, N\} \end{aligned} \quad (25)$$

Design matrix  $\mathbf{X}$ 와 design target vector  $\mathbf{t}$ 는 아래와 같이 정의된다.

$$\begin{aligned} \mathbf{X} &= \begin{bmatrix} \mathbf{x}_1^T \\ \vdots \\ \mathbf{x}_N^T \end{bmatrix} \\ \mathbf{t} &= [t_1, \dots, t_N]^T \end{aligned} \quad (26)$$

다음 물음에 답하시오.

- (i) 위의 최적화 문제의 식 (25)에 대한 primal form이 아래와 같이 정리됨을 보이시오.

$$L(\mathbf{w}, b, \mathbf{a}) = \frac{1}{2} \|\mathbf{w}\|^2 - (\mathbf{a} \odot \mathbf{t})^T (\mathbf{X}\mathbf{w} + b\mathbf{1}) + \mathbf{a}^T \mathbf{1} \quad (27)$$

여기서  $\mathbf{a} = [a_1, \dots, a_N]^T$  로 Lagrangian multipliers이며  $\odot$ 는 element-wise multiplication로  $\mathbf{a} \odot \mathbf{t}$ 는 다음과 같다.

$$\mathbf{a} \odot \mathbf{t} = [a_1 \cdot t_1, \dots, a_N \cdot t_N]^T$$

\*Hint: minimize문제라는 것과, Lagrangian multiplier의 조건에 대해 유의할 것.

(ii) 식 (27)에 대한  $\mathbf{w}$ 와  $b$ 의 gradient를 유도하시오.

$$\frac{\partial L(\mathbf{w}, b, \mathbf{a})}{\partial \mathbf{w}} = \quad (28)$$

$$\frac{\partial L(\mathbf{w}, b, \mathbf{a})}{\partial b} = \quad (29)$$

$$(30)$$

(iii) 앞문항의 gradients를 zero로 취하여 Bishop교재 Eq. (7.8)과 Eq. (7.9)의 다음을 유도하시오.

$$\begin{aligned} \mathbf{w} &= \mathbf{X}^T(\mathbf{a} \odot \mathbf{t}) \\ 0 &= \mathbf{a}^T \mathbf{t} \end{aligned} \quad (31)$$

(iv)  $\mathbf{a}^T \mathbf{t} = 0$  조건은 어떤 의미를 갖는지 간단히 기술하시오. \*Hint:  $t_i = 1$ 인 경우와  $t_i = -1$ 인 경우로 나누어서 해당 식을 재구성해보자.

(v) 식 (31)을 이용하여, Linear SVM의 dual form  $\tilde{L}(\mathbf{a}) = \min_{(\mathbf{w}, b) \in \mathcal{A}_\theta} L(\mathbf{w}, b, \mathbf{a})$ 이 다음과 같이 정리됨을 유도하시오.

$$\tilde{L}(\mathbf{a}) = -\frac{1}{2}(\mathbf{a} \odot \mathbf{t})^T \mathbf{X} \mathbf{X}^T (\mathbf{a} \odot \mathbf{t}) + \mathbf{a}^T \mathbf{1} \quad (32)$$

(vi) 위의 dual form은 *Feasible* parameters  $(\mathbf{w}, b) \in \mathcal{A}_\theta$ 에 대한 KKT 조건에 따라 다음 식과 같이 Bishop교재 Eq. (7.14-16)의 추가로 만족되어야 한다.

$$\begin{aligned} a_n &\geq 0 \\ t_n y(\mathbf{x}_n) - 1 &\geq 0 \\ a_n (t_n y(\mathbf{x}_n) - 1) &= 0 \end{aligned} \quad (33)$$

**support vectors**들은  $a_n > 0$ 인 데이터 샘플들의 집합으로 다음과 같이 정의된다.

$$\mathcal{S} = \{\mathbf{x}_n | a_n > 0\} \quad (34)$$

Bishop교재 Eq. (7.13)를 참고하여,  $y(\mathbf{x})$ 를  $\mathcal{S}$ 를 이용하여 다시 기술하시오. 이때 새로운 new example벡터를 분류하는 test단계에서  $y(\mathbf{x})$ 의 효율성에 대해서 간단히 서술하시오.

**6** (30 points) Overlapped class분포상에서는 Linear SVM의 margin 제약에서 벗어나는 샘플들이 존재하며, 이를 위해 데이터별로 slack variable  $\xi_n$ 을 도입하여, 다음과 같이 확장된 primal form을 고려하자 (Bishop교재 Eq. (7.20-21)).

$$\text{minimize } \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{n=1}^N \xi_n$$

$$\text{subject to } t_n (\mathbf{w}^T \mathbf{x}_n + b) - 1 + \xi_n \geq 0 \quad \forall n \in \{1, \dots, N\}$$

$$\xi_n \geq 0 \quad \forall n \in \{1, \dots, N\} \quad (35)$$

(i) 식 (35)에 대한 Lagrangian function이 다음과 같이 정리됨을 보이시오.

$$L(\mathbf{w}, b, \mathbf{a}) = \frac{1}{2} \|\mathbf{w}\|^2 + C \cdot \boldsymbol{\xi}^T \mathbf{1} - (\mathbf{a} \odot \mathbf{t})^T (\mathbf{X} \mathbf{w} + b \mathbf{1}) + \mathbf{a}^T \mathbf{1} - (\mathbf{a} + \boldsymbol{\mu})^T \boldsymbol{\xi} \quad (36)$$

여기서  $\boldsymbol{\xi} = [\xi_1, \dots, \xi_N]^T$ ,  $\mathbf{a} = [a_1, \dots, a_N]^T$ 와  $\boldsymbol{\mu} = [\mu_1, \dots, \mu_N]^T$ 로 Lagrangian multipliers이다.

(ii) 식 (36)에 대한  $\mathbf{w}$ 와  $b$ ,  $\boldsymbol{\xi}$ 의 gradient를 유도하시오.

$$\frac{\partial L(\mathbf{w}, b, \mathbf{a})}{\partial \mathbf{w}} = \quad (37)$$

$$\frac{\partial L(\mathbf{w}, b, \mathbf{a})}{\partial b} = \quad (38)$$

$$\frac{\partial L(\mathbf{w}, b, \mathbf{a})}{\partial \boldsymbol{\xi}} = \quad (39)$$

$$(40)$$

원래의 기본 Linear SVM과 마찬가지로, 위의 gradients를 zero로 하여, 다음과 같이 Bishop교재 Eq. (7.29-31)가 됨을 유도하시오.

$$\begin{aligned} \mathbf{w} &= \mathbf{X}^T(\mathbf{a} \odot \mathbf{t}) \\ 0 &= \mathbf{a}^T \mathbf{t} \\ \mathbf{a} + \boldsymbol{\mu} &= C \cdot \mathbf{1} \end{aligned} \quad (41)$$

(iii) 식 (41)을 이용하여, *Class-overlapped* 케이스에 대한 Linear SVM의 dual form  $\tilde{L}(\mathbf{a}) = \min_{(\mathbf{w}, b) \in \mathcal{A}_\theta} L(\mathbf{w}, b, \mathbf{a})$ 이 다음과 같이 기본 Linear SVM의 dual form과 동일함을 증명하시오.

$$\tilde{L}(\mathbf{a}) = -\frac{1}{2} (\mathbf{a} \odot \mathbf{t})^T \mathbf{X} \mathbf{X}^T (\mathbf{a} \odot \mathbf{t}) + \mathbf{a}^T \mathbf{1} \quad (42)$$

다만 Bishop교재의 KKT 조건인 Eq. (7.23-28)로 부터, 기본 Linear SVM와의 유일한 차이는 다음과 같이  $a_n$ 에 대한 upper bound 조건만이 추가된다는 점을 증명하시오.

$$\mathbf{0} \leq \mathbf{a} \leq C \cdot \mathbf{1} \quad (43)$$

7 (30 points)  $K$  component로 구성된 Mixture of Gaussians에서 data sample은 *one-hot* latent variable  $\mathbf{z}$ 를 이용하여 두 단계에서 생성 (generation) 과정을 따른다고 볼 수 있다.

$$\begin{aligned} \text{Sample } z_k &\sim P(z_k = 1 | \boldsymbol{\pi}) = \pi_k \\ \text{Sample } \mathbf{x} &\sim \mathcal{N}(\mathbf{x} | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) \end{aligned}$$

Latent variable  $\mathbf{z}$ 을 통해,  $p(\mathbf{x})$ 는 다음과 같이  $p(\mathbf{x}, \mathbf{z})$ 의 marginalization로 기술될 수 있다 (Bishop Eq. (9.10-12)).

$$p(\mathbf{x}) = \sum_{\mathbf{z}} p(\mathbf{x}, \mathbf{z}) = \sum_{k=1}^K \pi_k \mathcal{N}(\mathbf{x} | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)$$

학습데이터셋은 label이 없이  $\mathcal{D} = \{\mathbf{x}_1, \dots, \mathbf{x}_N\}$ 로 주어지고, Design matrix  $\mathbf{X}$ 와 마찬가지로, latent design matrix  $\mathbf{Z}$ 는 아래로 정의된다고 하자.

$$\mathbf{Z} = \begin{bmatrix} \mathbf{z}_1^T \\ \vdots \\ \mathbf{z}_N^T \end{bmatrix}$$

교재의 Eq. (9.14)와 같이 데이터셋에 대한 log-likelihood  $\ln p(\mathcal{D})$ 는 다음과 같다.

$$\ln p(\mathcal{D}) = \ln p(\mathbf{X}|\pi, \boldsymbol{\mu}, \boldsymbol{\Sigma}) = \sum_{n=1}^N \ln \left\{ \sum_{k=1}^K \pi_k \mathcal{N}(\mathbf{x}_n | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) \right\} \quad (44)$$

log-likelihood를 maximize하기 위한 EM algorithm 유도를 위해 다음 물음에 답하시오.

(i)  $\mathbf{x}_n$ 에 대한 responsibilities  $\gamma(z_{nk})$ 를 다음과 같이 정의하자.

$$\gamma(z_{nk}) = \frac{\pi_k \mathcal{N}(\mathbf{x}_n | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)}{\sum_j \pi_j \mathcal{N}(\mathbf{x}_n | \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j)} \quad (45)$$

Log-likelihood 식 (44)의  $\boldsymbol{\mu}$ 에 대한 gradient인  $\partial \ln p(\mathcal{D}) / \partial \boldsymbol{\mu}_k$ 를 zero로 둬으로써, 다음식을 유도하시오 (Bishop교재 Eq. (9.17)).

$$\begin{aligned} \boldsymbol{\mu}_k &= \frac{1}{N_k} \sum_{n=1}^N \gamma(z_{nk}) \mathbf{x}_n \\ N_k &= \sum_{n=1}^N \gamma(z_{nk}) \end{aligned} \quad (46)$$

이때, 우변의  $\gamma(z_{nk}) = h(\pi, \boldsymbol{\mu}, \boldsymbol{\Sigma})$ 는  $\boldsymbol{\mu}_k$ 가 포함되어 있으므로, optimal  $\boldsymbol{\mu}_k$ 는 closed-form으로 구해지지 않고, *fixed-point algorithm*처럼 iterative하게 식 (46)을 반복적으로 수행하여 얻어져야 함을 설명하시오.

(ii)  $\partial \ln p(\mathcal{D}) / \partial \boldsymbol{\Sigma}_k^{-1} = 0$ 로 둬으로써, 다음식을 유도하시오.

$$\boldsymbol{\Sigma}_k = \frac{1}{N_k} \sum_{n=1}^N \gamma(z_{nk}) (\mathbf{x}_n - \boldsymbol{\mu}_k)(\mathbf{x}_n - \boldsymbol{\mu}_k)^T \quad (47)$$

\*Hint: Assignment 1의 Problem 1.(v) 및 Problem 14의 전개에서 사용한 유도과정을 참조

(iii) Bishop교재 Eq. (9.20-21)의 과정을 통해, 다음식을 유도하시오.

$$\pi_k = \frac{N_k}{N} \quad (48)$$

(iv) 위의 유도내용을 바탕으로 Bishop교재의 Eq. (9.23-28) EM 알고리즘 과정을 서술하시오.

8 (15 points) General EM알고리즘과 Variational inference에서 기반이 되는 다음 식을 유도하시오 (Bishop교재의 Eq. (9.70)).

$$\begin{aligned} \ln p(\mathbf{X}|\boldsymbol{\theta}) &= \mathcal{L}(q, \boldsymbol{\theta}) + KL(q||p) \\ \mathcal{L}(q, \boldsymbol{\theta}) &= \sum_{\mathbf{Z}} q(\mathbf{Z}) \ln \left\{ \frac{p(\mathbf{X}, \mathbf{Z}|\boldsymbol{\theta})}{q(\mathbf{Z})} \right\} \\ KL(q||p) &= \sum_{\mathbf{Z}} q(\mathbf{Z}) \ln \left\{ \frac{p(\mathbf{Z}|\mathbf{X}, \boldsymbol{\theta})}{q(\mathbf{Z})} \right\} \end{aligned}$$

여기서  $q(\mathbf{Z})$ 는  $\mathbf{Z}$ 에 대한 임의의 variational 분포이다.

## 제출 방법

각 문항별 수식 유도 및 풀이 과정을 정리한 **문제 풀이 답안지** 파일을 email로 제출해야 한다. (수기 작성시에는 별도 용지의 스캔본 제출 보다는 전자펜으로 답안을 작성하여 생성된 파일로 제출하는 것을 권장함).