

4장 연습문제 해답

01.

(a)

$$g(\lambda) = \inf_{x \in \mathbb{R}} L(x, \lambda) = L\left(-\frac{1}{\lambda}, \lambda\right) = -\frac{1}{\lambda} + 2022 + \lambda \cdot \frac{1}{2} \left(-\frac{1}{\lambda}\right)^2 = -\frac{1}{2\lambda} + 2022$$

(b)

$$\begin{aligned} g(\lambda, \nu) &= \inf_{(x, y) \in \mathbb{R}^2} L(x, y, \lambda, \nu) \\ &= L\left(\frac{1}{2}(\lambda - 3\nu), \frac{1}{2}(\lambda - 2\nu)\right) \\ &= \left(\frac{1}{2}(\lambda - 3\nu)\right)^2 + \left(\frac{1}{2}(\lambda - 2\nu)\right)^2 + \lambda\left(7 - \frac{1}{2}(\lambda - 3\nu) - \frac{1}{2}(\lambda - 2\nu)\right) + \nu\left(\frac{3}{2}(\lambda - 3\nu) + (\lambda - 2\nu) - 1\right) \\ &= -\frac{1}{4}(2\lambda^2 - (10\nu - 28)\lambda + 13\nu^2 + 4\nu) \end{aligned}$$

02.

$$g(\nu) = \begin{cases} -\sum_{i=1}^n \nu_i & W + \text{diag}(\nu) \geq 0 \\ -\infty & \text{otherwise} \end{cases}$$

03.

\mathbb{R}_+^n 에서 정의된 함수 $g(\mathbf{x}) = \mathbf{y}^T \mathbf{x} - \sum_{i=1}^n x_i \log x_i$ 의 헤세 행렬을 $\nabla^2 g(\mathbf{x})$ 라 할 때, 헤세 행렬의

정의에 의해 $[\nabla^2 g(\mathbf{x})]_{ij} = \frac{\partial^2 g}{\partial x_i \partial x_j}$ 이므로 $\frac{\partial^2 g}{\partial x_i \partial x_j}$ 를 구해보면 다음과 같습니다.

$$\frac{\partial^2 g}{\partial x_i \partial x_j} = \frac{\partial}{\partial x_i} \left(\frac{\partial g}{\partial x_j} \right) = \frac{\partial}{\partial x_i} \left(y_j - \left(\log x_j + x_j \cdot \frac{1}{x_j} \right) \right) = \frac{\partial}{\partial x_i} (y_j - (\log x_j + 1)) = \begin{cases} -\frac{1}{x_i}, & i = j \\ 0, & i \neq j \end{cases}$$

따라서 함수 g 의 헤세 행렬 $\nabla^2 g(\mathbf{x})$ 은 $[\nabla^2 g(\mathbf{x})]_{ii} = -\frac{1}{x_i}$ 인 대각행렬, 즉

$$\nabla^2 g(\mathbf{x}) = \begin{bmatrix} -\frac{1}{x_1} & 0 & \cdots & 0 \\ 0 & -\frac{1}{x_2} & \cdots & 0 \\ \vdots & \cdots & \ddots & \vdots \\ 0 & \cdots & 0 & -\frac{1}{x_n} \end{bmatrix} = - \begin{bmatrix} \frac{1}{x_1} & 0 & \cdots & 0 \\ 0 & \frac{1}{x_2} & \cdots & 0 \\ \vdots & \cdots & \ddots & \vdots \\ 0 & \cdots & 0 & \frac{1}{x_n} \end{bmatrix}$$

이고, $x_1, \dots, x_n > 0$ 이므로 임의의 0이 아닌 $\mathbf{a} = (a_1, \dots, a_n) \in \mathbb{R}^n$ 에 대해

$$\mathbf{a}^T \nabla^2 g(\mathbf{x}) \mathbf{a} = [a_1 \ a_2 \ \dots \ a_n] \left(- \begin{bmatrix} \frac{1}{x_1} & 0 & \dots & 0 \\ 0 & \frac{1}{x_2} & \dots & 0 \\ \vdots & \dots & \ddots & \vdots \\ 0 & \dots & 0 & \frac{1}{x_n} \end{bmatrix} \right) \begin{bmatrix} a_1 \\ a_2 \\ \vdots \\ a_n \end{bmatrix} = -\frac{1}{x_1} a_1^2 - \frac{1}{x_2} a_2^2 - \dots - \frac{1}{x_n} a_n^2 < 0$$

임을 알 수 있습니다. 따라서, $\nabla^2 g(\mathbf{x})$ 는 음의 정부호 행렬입니다.

04.

(a)

$$\text{maximize} \quad -pe^{-1-\boldsymbol{\nu}^T \mathbf{a}_1} - qe^{-1-\boldsymbol{\nu}^T \mathbf{a}_2} - \boldsymbol{\nu}^T \mathbf{b}$$

(b)

$$\begin{aligned} &\text{maximize} && \sum_{i=1}^m \log \nu_i + m - \mathbf{b}^T \boldsymbol{\nu} \\ &\text{subject to} && A^T \boldsymbol{\nu} = \mathbf{0} \\ &&& \nu_i > 0, \ i = 1, \dots, m \end{aligned}$$

05.

$$\begin{aligned} &\text{maximize} && -\boldsymbol{\lambda}^T \mathbf{b} \\ &\text{subject to} && \mathbf{c} + A^T \boldsymbol{\lambda} = \mathbf{0} \\ &&& \lambda_i \geq 0, \ i = 1, \dots, m \end{aligned}$$

06.

주어진 볼록 최적화 문제

$$\begin{aligned} &\text{minimize} && f_0(\mathbf{x}) \\ &\text{subject to} && f_i(\mathbf{x}) \leq 0, \ i = 1, \dots, m \\ &&& A\mathbf{x} = \mathbf{b} \end{aligned}$$

에 대해 집합 A , B 를 다음과 같이 정의합시다.

$$A = \{(\mathbf{u}, \mathbf{v}, t) \mid \exists \mathbf{x} \in \text{dom} f, f_i(\mathbf{x}) \leq u_i (i = 1, \dots, m), A\mathbf{x} - \mathbf{b} = \mathbf{0}, f_0(\mathbf{x}) \leq t\}$$

$$B = \{(\mathbf{0}, \mathbf{0}, s) \mid s < p^*\}$$

여기서 p^* 는 위 볼록 최적화 문제의 최적값, 즉 $p^* = f(\mathbf{x}^*)$ 를 의미합니다. 위와 같이 정의된 집합 A , B 의 교집합이 없음을 보입니다. 만약, $(\mathbf{u}, \mathbf{v}, t) \in A \cap B$ 라 가정하면, 집합 A 의 정의에 의해 어떤 \mathbf{x} 가 존재해서 $f_i(\mathbf{x}) \leq u_i$, $A\mathbf{x} - \mathbf{b} = \mathbf{0}$, $f_0(\mathbf{x}) \leq t$ 를 만족해야 합니다. 한편, 집합 B 의 정의에 의해 $\mathbf{u} = \mathbf{0}$, $\mathbf{v} = \mathbf{0}$, $t < p^*$ 이므로, $f_0(\mathbf{x}) \leq t < p^*$ 를 만족하는 \mathbf{x} 가 존재하고, 이는 $p^* = f(\mathbf{x}^*)$ 가 볼록 최적화 문제의 최적값이라는 가정에 모순입니다. 따라서, A , B 의 교집합이 없습니다.

집합 A 와 B 의 교집합이 없기 때문에, 집합 A 와 B 를 구분하는 평면이 존재합니다. 즉, $\mathbf{0}$ 이 아닌 $(\hat{\lambda}, \hat{\nu}, \mu)$ 와 실수 c 가 존재해서

$$(\mathbf{u}, \mathbf{v}, t) \in A \quad \Rightarrow \quad \hat{\lambda}^T \mathbf{u} + \hat{\nu}^T \mathbf{v} + \mu t \geq c$$

$$(\mathbf{u}, \mathbf{v}, t) \in B \quad \Rightarrow \quad \hat{\lambda}^T \mathbf{u} + \hat{\nu}^T \mathbf{v} + \mu t \leq c$$

를 만족합니다. 첫 번째 조건 $((\mathbf{u}, \mathbf{v}, t) \in A \Rightarrow \hat{\lambda}^T \mathbf{u} + \hat{\nu}^T \mathbf{v} + \mu t \geq c)$ 에서, $\hat{\lambda}^T \mathbf{u} + \mu t$ 가 아래로 유계이기 위해서는 $\hat{\lambda}_i \geq 0$, $\mu \geq 0$ 임을 알 수 있고, 두 번째 조건 $((\mathbf{u}, \mathbf{v}, t) \in B \Rightarrow \hat{\lambda}^T \mathbf{u} + \hat{\nu}^T \mathbf{v} + \mu t \leq c)$ 은 $t < p^*$ 인 모든 t 에 대해 $\mu t \leq c$ 이므로, $\mu p^* \leq c$ 임을 알 수 있습니다. 따라서, 이를 종합하면 $f_i(\mathbf{x}) < 0$, $A\mathbf{x} = \mathbf{b}$ 를 만족하는 임의의 \mathbf{x} 에 대해, 다음이 성립합니다.

$$\sum_{i=1}^m \hat{\lambda}_i f_i(\mathbf{x}) + \hat{\nu}^T (A\mathbf{x} - \mathbf{b}) + \mu f_0(\mathbf{x}) \geq c \geq \mu p^*$$

① $\mu > 0$ 인 경우

위 부등식의 양변을 μ 로 나누면,

$$L\left(\mathbf{x}, \frac{\hat{\lambda}}{\mu}, \frac{\hat{\nu}}{\mu}\right) = \sum_{i=1}^m \frac{\hat{\lambda}_i}{\mu} f_i(\mathbf{x}) + \left(\frac{\hat{\nu}}{\mu}\right)^T (A\mathbf{x} - \mathbf{b}) + f_0(\mathbf{x}) \geq p^*$$

를 얻습니다. 따라서 $\lambda = \frac{\hat{\lambda}}{\mu}$, $\nu = \frac{\hat{\nu}}{\mu}$ 로 두면, $f_i(\mathbf{x}) < 0$, $A\mathbf{x} = \mathbf{b}$ 를 만족하는 임의의 \mathbf{x} 에 대해, $g(\lambda, \nu) \leq L(\mathbf{x}, \lambda, \nu) \geq p^*$ 를 얻고, 약쌍대성에 의해 $g(\lambda, \nu) \leq p^*$ 가 성립하므로 $g(\lambda, \nu) = p^*$, 즉 강쌍대성이 성립합니다.

② $\mu = 0$ 인 경우

이 경우, 위 부등식은

$$\sum_{i=1}^m \hat{\lambda}_i f_i(\mathbf{x}) + \hat{\nu}^T (A\mathbf{x} - \mathbf{b}) \geq 0$$

로 쓸 수 있고, 슬레이터 조건인 $f_i(\mathbf{x}) < 0$, $A\mathbf{x} = \mathbf{b}$ 를 만족하는 임의의 \mathbf{x} 에 대해, 이 조건은

$$\sum_{i=1}^m \hat{\lambda}_i f_i(\mathbf{x}) \geq 0$$

로 쓸 수 있습니다. 한편, $f_i(\mathbf{x}) < 0$ 이고 $\hat{\lambda}_i \geq 0$ 이므로 $\hat{\lambda}_i = 0$ 일때만 이 조건이 성립함을 알 수 있습니다. 따라서, $\hat{\lambda} = \mathbf{0}$, $\mu = 0$ 이므로 $(\hat{\lambda}, \hat{\nu}, \mu)$ 가 $\mathbf{0}$ 이 아니라는 가정에 의해 $\hat{\nu} \neq \mathbf{0}$ 이어야 합니다. 즉, $\sum_{i=1}^m \hat{\lambda}_i f_i(\mathbf{x}) + \hat{\nu}^T (A\mathbf{x} - \mathbf{b}) \geq 0$ 에 의해 $\hat{\nu}^T (A\mathbf{x} - \mathbf{b}) \geq 0$ 여야 하고, 슬레이터 조건을 만족하는 $\hat{\mathbf{x}}$ 에 대해서 $\hat{\nu}^T (A\hat{\mathbf{x}} - \mathbf{b}) = 0$ 이므로, $A^T \hat{\nu} = \mathbf{0}$ 가 아닌 이상 $\hat{\nu}^T (A\mathbf{x} - \mathbf{b}) < 0$ 을 만족하는 \mathbf{x} 가 존재해야 합니다. 이는 A 의 랭크가 p 라는 가정에 모순입니다.

따라서 ①, ②에 의해 슬레이터 조건을 증명했습니다.

07.

(a) 부등식 제약조건이 없으므로, 슬레이터 조건에 의해 $A^T \begin{bmatrix} x \\ y \end{bmatrix} = \mathbf{b}$ 를 만족하는 모든 $\begin{bmatrix} x \\ y \end{bmatrix}$ 에 대해 강쌍대성이 성립합니다.

(b) 부등식 제약조건에서 등호 조건이 없으므로, 슬레이터 조건에 의해 $\mathbf{a}_i^T \mathbf{x} < b_i$ 를 만족하는 모든 \mathbf{x} 에 대해 강쌍대성이 성립합니다.

08.

주어진 최적화 문제는 볼록 최적화 문제이므로 등식 제약조건에 대한 함수 $h_i(\mathbf{x})$ 는 어떤 \mathbf{a}_i 에 대해 $h_i(\mathbf{x}) = \mathbf{a}_i^T \mathbf{x}$ 로 표현할 수 있습니다. 따라서, $h_i(\mathbf{x})$ 의 헤세 행렬은 영행렬이고, \mathbf{x} 에 대한 라그랑주 함수 $L(\mathbf{x}, \boldsymbol{\lambda}, \boldsymbol{\nu}) = f(\mathbf{x}) + \sum_{i=1}^m \lambda_i f_i(\mathbf{x}) + \sum_{i=1}^p \nu_i (\mathbf{a}_i^T \mathbf{x})$ 의 헤세 행렬을 구해보면 다음과 같습니다.

$$\nabla^2 L(\mathbf{x}, \boldsymbol{\lambda}, \boldsymbol{\nu}) = \nabla^2 f(\mathbf{x}) + \sum_{i=1}^m \lambda_i \nabla^2 f_i(\mathbf{x})$$

볼록 최적화 문제의 정의에 의해 목적함수 f 와 부등식 제약조건에 대한 함수 f_i 모두 볼록함수이므로 $\nabla^2 f$ 와 $\nabla^2 f_i$ 는 양의 준정부호 행렬이고 $\lambda_i \geq 0$ 이므로, $\mathbf{0}$ 이 아닌 임의의 $\mathbf{x} \in \mathbb{R}^n$ 에 대해

$$\begin{aligned}\mathbf{x}^T \nabla^2 L(\mathbf{x}, \boldsymbol{\lambda}, \nu) \mathbf{x} &= \mathbf{x}^T \left(\nabla^2 f(\mathbf{x}) + \sum_{i=1}^p \nu_i \nabla^2 f_i(\mathbf{x}) \right) \mathbf{x} \\ &= \mathbf{x}^T \nabla^2 f(\mathbf{x}) \mathbf{x} + \sum_{i=1}^p \nu_i \mathbf{x}^T \nabla^2 f_i(\mathbf{x}) \mathbf{x} \geq 0\end{aligned}$$

이 성립합니다. 따라서, 헤세 판정법에 의해 볼록 최적화 문제의 라그랑주 함수는 볼록함수입니다.

09.

주어진 최적화 문제의 쌍대 문제는 다음과 같습니다.

$$\begin{aligned}\text{maximize} \quad & \lambda_1 + 4\lambda_2 + 2\lambda_3 \\ & 1 - \lambda_1 - 2\lambda_2 - \lambda_3 - \lambda_4 = 0 \\ & 3 + 2\lambda_1 + 3\lambda_2 - 5\lambda_3 - \lambda_5 = 0 \\ \text{subject to} \quad & -2 - \lambda_1 + \lambda_2 - \lambda_3 - \lambda_6 = 0 \\ & \lambda_1, \lambda_2, \lambda_3, \lambda_4, \lambda_5, \lambda_6 \geq 0\end{aligned}$$

구하고자 하는 쌍대 문제의 최적해는 $\boldsymbol{\lambda}^* = (\lambda_1^*, \lambda_2^*, \lambda_3^*, \lambda_4^*, \lambda_5^*, \lambda_6^*) = \left(\frac{2}{7}, 0, \frac{5}{7}, 0, 0, 1\right)$ 입니다.

10.

주어진 최적화 문제에서 $f(\mathbf{x}) = -\log(a+x) - \log(\beta+y)$, $f_1(\mathbf{x}) = -x$, $f_2(\mathbf{x}) = -y$, $h(\mathbf{x}) = 1-x-y$ 로 두면, 주어진 문제에 대한 라그랑주 함수 $L(\mathbf{x}, \boldsymbol{\lambda}, \nu)$ 는 다음과 같습니다.

$$\begin{aligned}L(\mathbf{x}, \boldsymbol{\lambda}, \nu) &= f(\mathbf{x}) + \sum_{i=1}^2 \lambda_i f_i(\mathbf{x}) + \nu h(\mathbf{x}) \\ &= -\log(a+x) - \log(\beta+y) - \lambda_1 x - \lambda_2 y + \nu(1-x-y)\end{aligned}$$

[정리 4-6]의 KKT 조건을 사용하기 위해 $\nabla_{\mathbf{x}} L(\hat{\mathbf{x}}, \hat{\boldsymbol{\lambda}}, \hat{\nu}) = \mathbf{0}$ 을 만족하는 $\hat{\mathbf{x}}$ 를 계산하면 다음 식을 만족합니다.

$$\begin{aligned}\frac{\partial L}{\partial x} &= -\frac{1}{a+x} - \lambda_1 + \nu = 0 \\ \frac{\partial L}{\partial y} &= -\frac{1}{\beta+y} - \lambda_2 + \nu = 0\end{aligned} \quad (*)$$

한편, KKT 조건의 조건 ❹에 의해 $\hat{\lambda}_1, \hat{\lambda}_2$ 는 다음을 만족해야 합니다.

$$\hat{\lambda}_1 \hat{x} = 0, \hat{\lambda}_2 \hat{y} = 0$$

(*) 조건과 $\lambda_i \geq 0$ 을 이용하면,

$$\lambda_1 = \nu - \frac{1}{\alpha + x} \geq 0$$

$$\lambda_2 = \nu - \frac{1}{\beta + y} \geq 0$$

이므로, 상보 여유 조건에 의해

$$\textcircled{1} \lambda_1 = \nu - \frac{1}{\alpha + x} \neq 0, \text{ 즉, } \nu \geq \frac{1}{\alpha} \text{ 이면 } x = 0,$$

$$\lambda_1 = \nu - \frac{1}{\alpha + x} = 0 \text{ 이면 } \nu = \frac{1}{\alpha + x}, \text{ 즉 } x = \frac{1}{\nu} - \alpha$$

$$\textcircled{2} \lambda_2 = \nu - \frac{1}{\beta + y} \neq 0, \text{ 즉, } \nu \geq \frac{1}{\beta} \text{ 이면 } y = 0,$$

$$\lambda_2 = \nu - \frac{1}{\beta + y} = 0 \text{ 이면 } \nu = \frac{1}{\beta + y}, \text{ 즉 } y = \frac{1}{\nu} - \beta$$

임을 알 수 있습니다. 따라서, 제약조건 $x + y = 1$ 에 의해

$$x + y = 1 \Leftrightarrow \max\left\{0, \frac{1}{\nu} - \alpha\right\} + \max\left\{0, \frac{1}{\nu} - \beta\right\} = 1$$

을 만족하는 ν 를 찾음으로써 주어진 문제의 최적해를 찾을 수 있습니다. 이 값은 α 와 β 에 따라 달라지므로 풀이는 여기서 마치도록 합니다¹⁾.

11.

주어진 최적화 문제의 목적함수를 $f(\mathbf{x}) = \frac{1}{2} \mathbf{x}^T P \mathbf{x} + \mathbf{q}^T \mathbf{x} + r$ 이라 하고 등식 제약조건에 대한 함수를 $h(\mathbf{x}) = A\mathbf{x} - \mathbf{b} = 0$ 이라고 하면, 주어진 최적화 문제의 라그랑주 함수 $L(\mathbf{x}, \nu)$ 는 다음과 같습니다.

$$L(\mathbf{x}, \nu) = f(\mathbf{x}) + \nu^T h(\mathbf{x}) = \frac{1}{2} \mathbf{x}^T P \mathbf{x} + \mathbf{q}^T \mathbf{x} + r + \nu^T (A\mathbf{x} - \mathbf{b})$$

1) 참고로 주어진 최적화 문제는 water-filling이라고 불리는 유명한 최적화 문제입니다. 자세한 내용은 Boyd의 Convex Optimization 책을 참고하세요.

최적해 \mathbf{x}^* 와 $\boldsymbol{\nu}^*$ 는 KKT 조건에 의해 다음을 만족해야 합니다.

$$\textcircled{1} \nabla_{\mathbf{x}} L(\mathbf{x}^*, \boldsymbol{\nu}^*) = P\mathbf{x}^* + \mathbf{q} + A^T \boldsymbol{\nu}^* = 0$$

$$\textcircled{2} h(\mathbf{x}^*) = A\mathbf{x}^* - \mathbf{b} = 0$$

따라서 이를 행렬 형태로 쓰면

$$\begin{array}{l} P\mathbf{x}^* + \mathbf{q} + A^T \boldsymbol{\nu}^* = 0 \\ A\mathbf{x}^* = \mathbf{b} \end{array} \Leftrightarrow \begin{bmatrix} P & A^T \\ A & 0 \end{bmatrix} \begin{bmatrix} \mathbf{x}^* \\ \boldsymbol{\nu}^* \end{bmatrix} = \begin{bmatrix} -\mathbf{q} \\ \mathbf{b} \end{bmatrix}$$

임을 알 수 있습니다.

12.

서포트 벡터 머신을 나타내는 최적화 문제의 목적함수 $f(\mathbf{w}) = \frac{1}{2} \|\mathbf{w}\|_2^2$ 는 노름 함수의 제곱이므로 볼록함수이고, 부등식 제약조건에 해당하는 함수 $f_i(\mathbf{w}) = 1 - y_i(\mathbf{w}^T \mathbf{x}_i + b) \leq 0$ 은 \mathbf{w} 에 대한 선형함수이므로 볼록함수입니다. 따라서, 볼록 최적화 문제의 정의에 의해 서포트 벡터 머신을 나타내는 주어진 최적화 문제는 볼록 최적화 문제입니다.

13.

(a) 여러 가지 답이 존재하지만 이 풀이에서는 직관적인 답을 제시합니다. 서포트 벡터 머신의 라그랑주 함수는 b 와 λ 에 대해서는 선형인 함수이고, \mathbf{w} 에 대해서는 전형적인 볼록함수 형태의 이차형식입니다. 따라서, 서포트 벡터 머신의 라그랑주 함수는 볼록함수입니다.

$$\text{(b) } \textcircled{1} \frac{\partial L}{\partial w_j} = w_j - \sum_{i=1}^N \lambda_i y_i (\mathbf{x}_i)_j$$

이차원 데이터 $\mathbf{x}_1 = (x_{11}, x_{12})$, $\mathbf{x}_2 = (x_{21}, x_{22})$ 에 대한 서포트 벡터 함수의 라그랑주 함수는 (a)에 의해 다음과 같습니다.

$$L(w_1, w_2, b, \lambda_1, \lambda_2) = \frac{1}{2}(w_1^2 + w_2^2) + \lambda_1 [1 - y_1(w_1 x_{11} + w_2 x_{12} + b)] + \lambda_2 [1 - y_2(w_1 x_{21} + w_2 x_{22} + b)]$$

따라서, 라그랑주 함수를 w_1 과 w_2 로 각각 미분하면,

$$\begin{aligned} \frac{\partial L}{\partial w_1} &= w_1 + \lambda_1(-y_1 x_{11}) + \lambda_2(-y_2 x_{21}) = w_1 - \sum_{i=1}^2 \lambda_i y_i (\mathbf{x}_i)_1 \\ \frac{\partial L}{\partial w_2} &= w_2 + \lambda_1(-y_1 x_{12}) + \lambda_2(-y_2 x_{22}) = w_2 - \sum_{i=1}^2 \lambda_i y_i (\mathbf{x}_i)_2 \end{aligned}$$

이므로 $\frac{\partial L}{\partial w_j} = w_j - \sum_{i=1}^N \lambda_i y_i (\mathbf{x}_i)_j$ 입니다.

$$\textcircled{2} \quad g(\boldsymbol{\lambda}) = \sum_{i=1}^N \lambda_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \lambda_i \lambda_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j$$

이를 보이기 위해, $\frac{\partial L}{\partial b}$ 를 구해보면 $\frac{\partial L}{\partial b} = -\lambda_1 y_1 - \lambda_2 y_2$ 입니다. 따라서, $g(\boldsymbol{\lambda})$ 는 $\frac{\partial L}{\partial w_i} = 0$,

$\frac{\partial L}{\partial b} = 0$ 인 w_i 와 b 에서의 L 의 값을 통해서 얻을 수 있으므로,

$$\begin{aligned} g(\boldsymbol{\lambda}) &= g(\lambda_1, \lambda_2) = \inf_{(w_1, w_2, b)} L(w_1, w_2, b) \\ &= L(\lambda_1 y_1 x_{11} + \lambda_2 y_2 x_{21}, \lambda_1 y_1 x_{21} + \lambda_2 y_2 x_{22}, b) \\ &= \frac{1}{2} ((\lambda_1 y_1 x_{11} + \lambda_2 y_2 x_{21})^2 + (\lambda_1 y_1 x_{21} + \lambda_2 y_2 x_{22})^2) \\ &\quad + \lambda_1 [1 - y_1 ((\lambda_1 y_1 x_{11} + \lambda_2 y_2 x_{21}) x_{11} + (\lambda_1 y_1 x_{21} + \lambda_2 y_2 x_{22}) x_{12} + b)] \\ &\quad + \lambda_2 [1 - y_1 ((\lambda_1 y_1 x_{11} + \lambda_2 y_2 x_{21}) x_{21} + (\lambda_1 y_1 x_{21} + \lambda_2 y_2 x_{22}) x_{22} + b)] \end{aligned}$$

입니다. 위 식을 정리하면 다음을 얻습니다.

$$g(\boldsymbol{\lambda}) = g(\lambda_1, \lambda_2) = \lambda_1 + \lambda_2 - \frac{1}{2} (\lambda_1^2 y_1^2 \mathbf{x}_1^T \mathbf{x}_1 + 2\lambda_1 \lambda_2 y_1 y_2 \mathbf{x}_1^T \mathbf{x}_2 + \lambda_2^2 y_2^2 \mathbf{x}_2^T \mathbf{x}_2) = \sum_{i=1}^2 \lambda_i - \frac{1}{2} \sum_{i=1}^2 \sum_{j=1}^2 \lambda_i \lambda_j y_i y_j \mathbf{x}_i^T \mathbf{x}_j$$

14.

$$(a) \quad \textcircled{1} \quad \inf_{\mathbf{x}} (f(\mathbf{x})) \geq -\sup_{\mathbf{x}} (-f(\mathbf{x}))$$

$\alpha = \inf_{\mathbf{x}} (f(\mathbf{x}))$ 라고 하면, \inf 의 정의에 의해, 모든 \mathbf{x} 에 대해 $\alpha \leq f(\mathbf{x})$ 이 성립합니다. 이 부등식의 양변에 -1 을 곱하면,

$$\alpha \leq f(\mathbf{x}) \quad \Leftrightarrow \quad -\alpha \geq -f(\mathbf{x})$$

이고, \sup 의 정의에 의해 $\sup_{\mathbf{x}} (-f(\mathbf{x})) \geq -\alpha$, 즉

$$-\sup_{\mathbf{x}} (-f(\mathbf{x})) \leq \alpha = \inf_{\mathbf{x}} (f(\mathbf{x}))$$

를 얻습니다.

$$\textcircled{2} \quad \inf_{\mathbf{x}} (f(\mathbf{x})) \leq -\sup_{\mathbf{x}} (-f(\mathbf{x}))$$

$\beta = \sup_{\mathbf{x}} (-f(\mathbf{x}))$ 라고 하면 \inf 의 정의에 의해, 모든 \mathbf{x} 에 대해 $\beta \geq -f(\mathbf{x})$ 이 성립합니다.

이 부등식의 양변에 -1 을 곱하면,

$$\beta \geq -f(\mathbf{x}) \quad \Leftrightarrow \quad -\beta \leq f(\mathbf{x})$$

이고, \inf 의 정의에 의해 $\inf_{\mathbf{x}}(f(\mathbf{x})) \leq -\beta$, 즉 다음을 얻습니다.

$$\inf_{\mathbf{x}}(f(\mathbf{x})) \leq -\beta = -\sup_{\mathbf{x}}(-f(\mathbf{x}))$$

따라서 ①, ②에 의해 $\inf_{\mathbf{x}}(f(\mathbf{x})) = -\sup_{\mathbf{x}}(-f(\mathbf{x}))$ 이 성립합니다.

(b) $f(x, y) = 5x^2 - 6xy + 5y^2$ 이 볼록함수임을 보이기 위해, 주어진 함수의 헤세 행렬을 구해보면 다음과 같습니다.

$$[H(f)](x, y) = \begin{bmatrix} \frac{\partial^2 f}{\partial x^2} & \frac{\partial^2 f}{\partial x \partial y} \\ \frac{\partial^2 f}{\partial y \partial x} & \frac{\partial^2 f}{\partial y^2} \end{bmatrix} = \begin{bmatrix} 10 & -6 \\ -6 & 10 \end{bmatrix}$$

(0,0)이 아닌 임의의 (x, y) 에 대해,

$$\begin{aligned} [x \ y] \begin{bmatrix} 10 & -6 \\ -6 & 10 \end{bmatrix} \begin{bmatrix} x \\ y \end{bmatrix} &= 10x^2 - 12xy + 10y^2 \\ &= 10 \left(x^2 - \frac{6}{5}xy + \frac{9}{25}y^2 - \frac{9}{25}y^2 \right) + 10y^2 \\ &= 10 \left(x - \frac{3}{5}y \right)^2 + \frac{32}{5}y^2 > 0 \end{aligned}$$

임을 알 수 있습니다. 따라서, 헤세 판정법에 의해 주어진 함수는 볼록함수입니다.

15.

[예제 4-11]과 비슷합니다. 직접 해봅시다!