

기계학습 Assignment1

2023 2학기

- 1 (20 points) 본 문항에서는 Bishop's 교재의 Appendix C에 있는 유용한 Matrix Derivatives 공식을 유도하고자 한다. Eq. C.17에 처럼, scalar $x = f(\mathbf{a})$ 에 대한 벡터 \mathbf{a} 의 derivative는 다음과 같이 정의된다.

$$\left(\frac{\partial x}{\partial \mathbf{a}}\right)_i = \frac{\partial x}{\partial a_i} \quad (1)$$

Eq. C.18에서 처럼, vector $\mathbf{b} = f(\mathbf{a})$ 에 대한 벡터 \mathbf{a} 의 derivative는 다음과 같이 정의된다.

$$\left(\frac{\partial \mathbf{b}}{\partial \mathbf{a}}\right)_{ij} = \frac{\partial b_i}{\partial a_j} \quad (2)$$

다음 matrix derivative 식을 유도하시오.

(i)

$$\frac{\partial}{\partial \mathbf{x}} (\mathbf{a}^T \mathbf{x}) = \mathbf{a} \quad (3)$$

(ii)

$$\frac{\partial}{\partial \mathbf{x}} (\mathbf{x}^T \mathbf{x}) = 2\mathbf{x} \quad (4)$$

(iii)

$$\frac{\partial}{\partial \mathbf{x}} (\mathbf{x}^T \mathbf{A} \mathbf{x}) = 2\mathbf{A} \mathbf{x} \quad (5)$$

(iv) 다음 식 (Eq. C.20)을 유도하고,

$$\frac{\partial}{\partial \mathbf{x}} (\mathbf{A} \mathbf{B}) = \frac{\partial \mathbf{A}}{\partial \mathbf{x}} \mathbf{B} + \mathbf{A} \frac{\partial \mathbf{B}}{\partial \mathbf{x}} \quad (6)$$

위의 식으로 부터 square matrix \mathbf{A} 에 대해서 아래 식 (Eq. C.21)을 유도하시오.

$$\frac{\partial}{\partial x} (\mathbf{A}^{-1}) = -\mathbf{A}^{-1} \frac{\partial \mathbf{A}}{\partial x} \mathbf{A}^{-1} \quad (7)$$

(v) square matrix \mathbf{A} 에 대해서, 다음 식 (Eq. C.28)을 유도하시오.

$$\frac{\partial}{\partial \mathbf{A}} \ln |\mathbf{A}| = (\mathbf{A}^{-1})^T \quad (8)$$

- 2 (15 points) 다음 물음에 답하시오.

(i) 기계학습에서 overfitting이란 무엇인가?

- (ii) underfitting이란 무엇인가?
- (iii) 기계학습에서 model fitting의 최종 목적은 무엇인가?
- (iv) Model complexity와 overfitting, underfitting간의 일반적인 관계를 설명하고, overfitting에 빠지지 않도록 하는 방법 2개정도를 든다면 무엇인가? 각 방법에 대해 간략히 기술하시오.

3 (30 points) 선형 회귀 (linear regression)를 위한 학습 데이터셋 $\mathcal{D} = \{(\mathbf{x}_1, t_1), \dots, (\mathbf{x}_N, t_N)\}$ 가 주어지고, 회귀 함수 $y(\mathbf{x}; \theta)$ 는 $\theta = \{\mathbf{w}, w_0\}$ 를 파라미터로 하는 다음 함수로 정의된다고 하자.

$$y(\mathbf{x}; \theta) = \mathbf{x}^T \mathbf{w} + w_0$$

다음 물음에 답하시오.

- (i) 위의 선형 회귀 함수의 파라미터를 구하기 위해 다음과 같이 square error로 $Loss$ 를 정의하자.

$$Loss_{\mathcal{D}}(\mathbf{w}, w_0) = \frac{1}{2} \sum_{i=1}^N \|y(\mathbf{x}_i; \theta) - t_i\|^2 = \|\mathbf{y} - \mathbf{t}\|^2 \quad (9)$$

여기서, \mathbf{y} 와 \mathbf{t} 는 N -dimensional column vectors들로 각각 다음과 같이 정의된다.

$$\mathbf{y} = [y(\mathbf{x}_1; \theta), \dots, y(\mathbf{x}_N; \theta)]^T \quad (10)$$

$$\mathbf{t} = [t_1, \dots, t_N]^T \quad (11)$$

다음 parameters에 대한 derivative (gradient)를 구하시오

$$\frac{\partial}{\partial \mathbf{w}} (Loss_{\mathcal{D}}(\mathbf{w}, w_0)) = \quad (12)$$

$$\frac{\partial}{\partial w_0} (Loss_{\mathcal{D}}(\mathbf{w}, w_0)) = \quad (13)$$

- (ii) 위의 gradient를 다음 design matrix \mathbf{X} 를 이용하여 정리하시오.

$$\mathbf{X} = \begin{bmatrix} \mathbf{x}_1^T \\ \vdots \\ \mathbf{x}_N^T \end{bmatrix} \quad (14)$$

- (iii) 앞서 유도한 gradient식을 이용해서, \mathbf{w} 와 w_0 에 대한 analytic solution을 구하시오.
- (iv) 위에서 구한 analytic solution이 **global minimum**임을 증명하시오.
- (v) 앞서 유도한 gradient식을 이용해서, \mathbf{w} 와 w_0 에 대한 **gradient descent** 방식을 통한 update식을 기술하시오.

4 (30 points) 앞 문항에서 정의된 bias parameter w_0 를 포함하도록 extended parameter vector $\tilde{\mathbf{w}}$ 를 다음과 같이 정의하자.

$$\tilde{\mathbf{w}} = [w_0; \mathbf{w}^T]^T \quad (15)$$

여기서 ;는 concatenation 연산자로 간주하였다. Bias term의 포함으로 차원이 늘어난 parameter벡터에 맞게, extended feature vector $\tilde{\mathbf{x}}$ 를 다음과 같이 정의하자.

$$\tilde{\mathbf{x}} = [1; \mathbf{x}^T]^T \quad (16)$$

또한, 회귀 함수 $y(\mathbf{x}; \theta)$ 를 extended feature vector를 취하는 다음 함수로 정의하자.

$$y(\tilde{\mathbf{x}}; \theta) = \tilde{\mathbf{x}}^T \tilde{\mathbf{w}}$$

다음 물음에 답하시오.

- (i) 위의 확장된 회귀 함수의 파라미터로 $Loss_{\mathcal{D}}(\tilde{\mathbf{w}})$ 및 Extended design matrix $\tilde{\mathbf{X}}$ 를 재정의하고, $\tilde{\mathbf{w}}$ 에 대한 analytic solution을 얻으시오.
- (ii) Regularization을 위해서 다음 항 $\|\tilde{\mathbf{w}}\|^2$ 을 추가하여 $Loss$ 를 다음과 같이 재정의하였다.

$$Loss_{\mathcal{D}}(\tilde{\mathbf{w}}) = \|\mathbf{y} - \mathbf{t}\|^2 + \lambda \|\tilde{\mathbf{w}}\|^2 \quad (17)$$

위의 regularized 버전의 $Loss$ 에 대한 $\tilde{\mathbf{w}}$ 의 Gradient를 구하시오.

- (iii) Regularized loss를 최소화하기 위한 $\tilde{\mathbf{w}}$ 의 analytic solution을 구하시오.
 - (iv) Regularized loss를 최소화하기 위한 $\tilde{\mathbf{w}}$ 의 gradient descent solution을 구하시오.
 - (v) 위와 같은 regularization의 효과는 무엇인가? 기계학습에서 알려진 이슈인 overfitting, generalization과 연관지어 설명하시오.
- 5 (10 points) X, Y 를 랜덤 변수 (random variable)일때, 확률론 (probability theory)의 기본 규칙인 다음 sum rule과 product rule을 이용하여 베이지안 정리 (Bayesian theorem) (Bishop's Eq. 1.12)을 유도하시오.

$$\begin{array}{ll} \text{sum rule} & p(X) = \sum_Y P(X, Y) \\ \text{product rule} & p(X, Y) = p(Y|X)p(X) \end{array}$$

베이지안 정리는 다음과 같다.

$$p(Y|X) = \frac{p(X|Y)p(Y)}{p(X)} \quad (18)$$

- 6 (20 points) Decision 문제는 주어진 feature vector \mathbf{x} 에 대한 범주를 결정하는 문제로, $p(C_k|\mathbf{x})$ 를 구하거나 discriminant function $f(\mathbf{x})$ 를 구하는 접근법으로 나눌 수 있다. 다음 물음에 답하시오.

- (i) $p(C_k|\mathbf{x})$ 을 구하는 방법은 다시 generative model을 이용한 방법, discriminant model에 기반한 방식으로 나뉘는데, 이들 두 방법이 각각 무엇인지 설명하시오.
- (ii) 앞서의 generative model과 discriminant model에 기반한 방법의 장단점이 무엇인지 상세히 서술하시오.
- (iii) $f(\mathbf{x})$ 은 \mathbf{x} 를 class로 매핑하는 discriminant function으로 $p(C_k|\mathbf{x})$ 를 통하지 않고 직접 구하는 방식의 예를 기술하시오.
- (iv) discriminant function에 기반한 방법대비 $p(C_k|\mathbf{x})$ 를 통하여 decision을 수행하는 probabilistic 방법의 장점을 기술하시오.

7 (15 points) 1-dimensional random variable에 대해 평균이 μ 이고 분산이 σ^2 일때, **differential entropy**를 최대로 하는 probability distribution p 가 Gaussian distribution임을 증명하시오 (Bishop교재 Eq. 1.109를 유도하면 된다)

8 (30 points) parameter μ 를 갖는 Bernoulli distribution은 다음과 같이 정의 된다 (Bishop의 Eq. 2.2)

$$\text{Bern}(x|\mu) = \mu^x(1 - \mu)^{(1-x)} \quad (19)$$

μ 가 unknown이고, N 개의 observed 데이터 $\mathcal{D} = \{x_1, \dots, x_N\}$ 가 주어질때의 likelihood는 다음과 같다.

$$p(\mathcal{D}|\mu) = \prod_{i=1}^N \text{Bern}(x_i|\mu) \quad (20)$$

다음 물음에 답하시오.

- (i) 위의 likelihood Eq. 20를 최대로 하는 μ 에 대한 식을 유도하시오.
- (ii) μ 를 랜덤 변수화 하고 이에 대한 prior distribution를 위해 mu 가 다음 Beta distribution을 따른다고 가정하자.

$$p(\mu) = p(\mu|a, b) = \text{Beta}(\mu|a, b) \quad (21)$$

parameter a, b 가 주어질때 beta distribution의 평균과 분산에 대한 식을 유도하시오.

- (iii) Conjugacy property란 무엇인가? μ 에 대한 prior distribution을 위해 beta distribution를 사용한 이유는 무엇인가?
- (iv) 위와 같이 N 개의 데이터 $\mathcal{D} = \{x_1, \dots, x_N\}$ 가 주어질때, μ 에 대한 posterior distribution는 다음과 같다.

$$p(\mu|\mathcal{D}) \propto p(\mathcal{D}|\mu)p(\mu|a, b) \quad (22)$$

위의 posterior가 beta distribution을 따름을 보이고, 해당 beta분포의 parameter에 대한 정확한 식을 유도하시오.

- (v) 위의 posterior 분포를 이용해서 다음과 같이 $x = 1$ 일 확률인 **predictive distribution**를 구하고자 한다.

$$p(x = 1|\mathcal{D}) = \int_0^1 p(x = 1|\mu)p(\mu|\mathcal{D})d\mu \quad (23)$$

위의 식을 hyper parameter a, b 및 dataset의 N 개의 관측값인 x_i 의 함수로 간결하게 기술하고, 이를 간단히 유도하시오.

9 (30 points) parameter vector $\boldsymbol{\mu} = (\mu_1, \dots, \mu_K)^T$ 를 갖는 Multinoulli distribution은 다음과 같이 정의 된다 (Bishop의 Eq. 2.26)

$$p(\mathbf{x}|\boldsymbol{\mu}) = \prod_{k=1}^K \mu_k^{x_k} \quad (24)$$

N 개의 one-hot vector로 구성된 관측 데이터 $\mathcal{D} = \{\mathbf{x}_1, \dots, \mathbf{x}_N\}$ 가 주어질때, likelihood는 다음과 같다 (Bishop의 Eq. 2.29).

$$p(\mathcal{D}|\boldsymbol{\mu}) = \prod_{n=1}^N \prod_{k=1}^K \mu_k^{x_{nk}} \quad (25)$$

다음 물음에 답하시오.

- (i) 위의 likelihood Eq. 25를 최대화 하는 μ_k 에 대한 식을 유도하시오.
 (ii) $\boldsymbol{\mu}$ 에 대한 conjugate prior 분포로 다음 Dirichlet distribution을 가정하자.

$$p(\boldsymbol{\mu}) = Dir(\boldsymbol{\mu}|\boldsymbol{\alpha}) \quad (26)$$

이때 $\boldsymbol{\alpha}$ 는 $(a_1, \dots, a_K)^T$ 로 구성된 hyperparameter vector를 가리킨다. conjugacy에 의하여, 위의 \mathcal{D} 에 대한 $\boldsymbol{\mu}$ 의 posterior distribution은 Dirichlet 분포를 따르며, 이때의 updated hyper parameter를 구하고 이를 유도하시오.

- (iii) 위의 posterior 분포를 이용해서 다음과 같이 $x_k = 1$ 일 확률인 posterior **predictive distribution**를 구하고자 한다.

$$p(x_k = 1|\mathcal{D}) = \int p(x_k = 1|\boldsymbol{\mu})p(\boldsymbol{\mu}|\mathcal{D})d\boldsymbol{\mu} \quad (27)$$

위의 predictive distribution을 prior의 hyperparameter $\{a_k\}_{k=1}^K$ 과 N 개의 관측벡터 $\{\mathbf{x}_i\}_{i=1}^N$ 의 식으로 간결히 하고, 이를 유도하시오.

- 10 (10 points) D -dimensional vector \mathbf{x} 에 대한, multivariate Gaussian distribution은 아래와 같이 정의된다.

$$\mathcal{N}(\mathbf{x}|\boldsymbol{\mu}, \boldsymbol{\Sigma}) = \frac{1}{(2\pi)^{D/2}} \frac{1}{|\boldsymbol{\Sigma}|^{1/2}} \exp \left\{ -\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1}(\mathbf{x} - \boldsymbol{\mu}) \right\} \quad (28)$$

다음 물음에 답하시오.

- (i) Covariance matrix $\boldsymbol{\Sigma}$ 에 대한 eigendecomposition 결과가 다음과 같다고 하자.

$$\boldsymbol{\Sigma} = \mathbf{U}\boldsymbol{\Lambda}\mathbf{U}^T \quad (29)$$

여기서 $\boldsymbol{\Lambda}$ 는 $\boldsymbol{\Sigma}$ 의 eigenvalue λ_i 로 구성된 대각행렬 (diagonal matrix)이다.

$$\boldsymbol{\Lambda} = \begin{bmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & 0 \\ \vdots & \dots & \dots & \vdots \\ 0 & 0 & \dots & \lambda_D \end{bmatrix} \quad (30)$$

이때 아래 교재의 Eq. 2.52의 변환을 이용하여,

$$\mathbf{y} = \mathbf{U}(\mathbf{x} - \boldsymbol{\mu}) \quad (31)$$

위의 multivariate Gaussian distribution (Eq. 28)를 Bishop교재의 Eq. 2.56와 같이 D 개의 독립 (independent)된 univariate Gaussian distributions의 곱으로 표현되는 과정을 유도하시오.

- 11 (10 points) Bishop교재의 Partitioned matrix에 대한 다음 inverse식 (Eq. 2.76) 이 정당함을 유도하시오.

$$\begin{pmatrix} \mathbf{A} & \mathbf{B} \\ \mathbf{C} & \mathbf{D} \end{pmatrix}^{-1} = \begin{pmatrix} \mathbf{M} & -\mathbf{M}\mathbf{B}\mathbf{D}^{-1} \\ -\mathbf{D}^{-1}\mathbf{C}\mathbf{M} & -\mathbf{D}^{-1} + \mathbf{D}^{-1}\mathbf{C}\mathbf{M}\mathbf{B}\mathbf{D}^{-1} \end{pmatrix} \quad (32)$$

이때, \mathbf{M} 은 위의 좌측 행렬에 대한 Schur complement로 다음과 같이 정의된다.

$$\mathbf{M} = (\mathbf{A} - \mathbf{B}\mathbf{D}^{-1}\mathbf{C})^{-1} \quad (33)$$

- 12 (20 points) D-dimensional vector \mathbf{x} 에 대한 joint Gaussian distribution $\mathcal{N}(\mathbf{x}|\boldsymbol{\mu}, \boldsymbol{\Sigma})$ 이 주어지고, precision matrix 는 covariance matrix의 inverse로 $\boldsymbol{\Lambda} = \boldsymbol{\Sigma}^{-1}$ 형태로 주어졌다고 하자. 입력 차원을 두 block으로 나누어,

$$\mathbf{x} = \begin{pmatrix} \mathbf{x}_a \\ \mathbf{x}_b \end{pmatrix}, \boldsymbol{\mu} = \begin{pmatrix} \boldsymbol{\mu}_a \\ \boldsymbol{\mu}_b \end{pmatrix} \quad (34)$$

$$\boldsymbol{\Sigma} = \begin{pmatrix} \boldsymbol{\Sigma}_{aa} & \boldsymbol{\Sigma}_{ab} \\ \boldsymbol{\Sigma}_{ba} & \boldsymbol{\Sigma}_{bb} \end{pmatrix},$$

$$\boldsymbol{\Lambda} = \begin{pmatrix} \boldsymbol{\Lambda}_{aa} & \boldsymbol{\Lambda}_{ab} \\ \boldsymbol{\Lambda}_{ba} & \boldsymbol{\Lambda}_{bb} \end{pmatrix} \quad (35)$$

로 할때, 다음 conditional distribution에 대한 식 (Eq. 2.96)

$$p(\mathbf{x}_a|\mathbf{x}_b) = \mathcal{N}(\mathbf{x}|\boldsymbol{\mu}_{a|b}, \boldsymbol{\Lambda}_{aa}^{-1})$$

$$\boldsymbol{\mu}_{a|b} = \quad (36)$$

Marginal distribution에 대한 식 (Eq. 2.98)

$$p(\mathbf{x}_a) = \mathcal{N}(\mathbf{x}_a|\boldsymbol{\mu}_a, \boldsymbol{\Sigma}_{aa})$$

에서 $\boldsymbol{\mu}_{a|b}$ 을 완성하고, 위의 두 conditional distribution 및 marginal distribution 식을 유도하시오.

- 13 (20 points) \mathbf{x} 에 대한 marginal distribution과, \mathbf{x} 가 주어질때의 \mathbf{y} 에 대한 conditional distribution이 다음과 같이 Gaussian을 따른다고 하자.

$$p(\mathbf{x}) = \mathcal{N}(\boldsymbol{\mu}, \boldsymbol{\Lambda}^{-1})$$

$$p(\mathbf{y}|\mathbf{x}) = \mathcal{N}(\mathbf{A}\mathbf{x} + \mathbf{b}, \mathbf{L}^{-1})$$

이때 \mathbf{y} 에 대한 marginal distribution과 \mathbf{y} 가 주어질때의 \mathbf{x} 에 대한 conditional distribution의 다음 식을 완성하시오 (Bishop Eq. 2.115 와 2.116).

$$p(\mathbf{y}) =$$

$$p(\mathbf{x}|\mathbf{y}) =$$

또한, Bishop 교재를 참조하면서 위의 $p(\mathbf{y})$ 와 $p(\mathbf{x}|\mathbf{y})$ 의 공식을 유도하시오.

- 14 (15 points) Multivariate Gaussian distribution을 따르는 관측 데이터가 Design matrix로 $\mathbf{X} = (\mathbf{x}_1, \dots, \mathbf{x}_N)^T$ 로 주어졌다고 하자. 이에 대한 log-likelihood를 최대화 하는 평균과 분산의 MLE (maximum likelihood estimation)이 다음과 같음을 증명하시오 (교재 Eq. 2.121- 2.122).

$$\boldsymbol{\mu}_{ML} = \frac{1}{N} \sum_{n=1}^N \mathbf{x}_n$$

$$\boldsymbol{\Sigma}_{ML} = \frac{1}{N} \sum_{n=1}^N (\mathbf{x}_n - \boldsymbol{\mu}_{ML})(\mathbf{x}_n - \boldsymbol{\mu}_{ML})^T$$

- 15 (15 points) 분산이 σ^2 이 정해졌으나 μ 가 unknown인 Gaussian distribution에 대한 Bayesian inference를 위해, 총 N 개의 1-dimensional observed samples들이 Design vector인 $\mathbf{X} = (x_1, \dots, x_N)^T$ 로 주어졌다고 하자. μ 에 대한 Bayesian inference를 위해 prior distribution으로 다음 Gaussian을 따른다고 하자.

$$p(\mu) = \mathcal{N}(\mu_0, \sigma_0^2) \quad (37)$$

Bishop교재의 Eq. 2.116를 이용하여, μ 에 대한 다음 posterior distribution의 파라미터 μ_N 와 σ_N^2 을 유도하시오 (Bishop교재 Eq. 2.141-142).

$$p(\mu|\mathbf{X}) = \mathcal{N}(\mu|\mu_N, \sigma_N^2) \quad (38)$$

- 16 (15 points) 선형 회귀에 대한 Least squares 방식의 해가 Gaussian noise 모델의 maximum likelihood estimation를 보이려고 한다. 이를 위해 주어진 입력 벡터 \mathbf{x} (bias entry가 포함된 확장된 벡터로 간주)에 대한 regression 값 t 에 대한 probability distribution을 다음과 같이 Gaussian을 따른다고 하자.

$$p(t|\mathbf{x}, \mathbf{w}, \beta) = \mathcal{N}(t|\mathbf{w}^T \mathbf{x}, \beta^{-1}) \quad (39)$$

N 개의 관측 데이터가 Design matrix $\mathbf{X} = (\mathbf{x}_1, \dots, \mathbf{x}_N)^T$ 로, 이에 대한 target regression values들이 $\mathbf{t} = (t_1, \dots, t_N)$ 로 주어졌다고 하자. 데이터에 대한 likelihood는 다음과 같다.

$$p(\mathbf{t}|\mathbf{X}, \mathbf{w}, \beta) = \prod_{n=1}^N \mathcal{N}(t_n|\mathbf{w}^T \mathbf{x}_n, \beta^{-1}) \quad (40)$$

다음 물음에 답하시오.

- (i) 위의 Log-likelihood를 전개하면 Sum-of-squares error항이 포함됨을 유도하시오 (교재 Eq 3.11).
 - (ii) 위의 Log-likelihood를 최대로 하는 β^{-1} 의 식을 유도하고, 해당 값의 의미에 대해서 서술하시오.
- 17 (15 points) 앞 문항을 확장하여 Bayesian linear regression을 유도하고자 한다. 이를 위해, parameter vector \mathbf{w} 의 prior distribution이 다음 Gaussian분포를 따른다고 가정하자 (교재 Eq. 3.48).

$$p(\mathbf{w}) = \mathcal{N}(\mathbf{w}|\mathbf{m}_0, \mathbf{S}_0) \quad (41)$$

다시 Bishop교재의 Eq. 2.116를 적용하여, \mathbf{w} 에 대한 다음 posterior distribution의 파라미터 \mathbf{m}_N 와 \mathbf{S}_N 을 유도하시오 (Bishop교재 Eq. 3.50-51).

$$p(\mathbf{w}|\mathbf{X}, \mathbf{t}) = \mathcal{N}(\mathbf{w}|\mathbf{m}_N, \mathbf{S}_N) \quad (42)$$

- 18 (30 points) Binary classification에서의 Logistic regression 학습과정을 유도하고자 한다. 입력 벡터 \mathbf{x} 에 대해, class \mathcal{C}_1 으로 분류할 확률은 linear regression된 값에 logistic sigmoid function을 적용하여 다음과 같이 구한다고 가정한다 (교재 Eq. 4.87)

$$p(\mathcal{C}_1|\mathbf{x}) = \sigma(\mathbf{w}^T \mathbf{x}) \quad (43)$$

N 개의 입력 데이터가 Design matrix $\mathbf{X} = (\mathbf{x}_1, \dots, \mathbf{x}_N)^T$ 로, 이에 대한 target **class** values 이 $\mathbf{t} = (t_1, \dots, t_N)^T$ 로 주어진다고 하자. Regression setting과 달리 여기서, $t_n \in \{0, 1\}$ 로 이진값으로 제한된다. Data likelihood는 다음과 같다.

$$p(\mathbf{t}|\mathbf{X}, \mathbf{w}) = \prod_n y_n^{t_n} (1 - y_n)^{1-t_n} \quad (44)$$

여기서, $y_n = p(\mathcal{C}_1|\mathbf{x}_n) = \sigma(\mathbf{w}^T \mathbf{x}_n)$ 이다.

다음 물음에 답하시오.

- (i) $Loss(\mathbf{w})$ 를 다음과 같이 negative log-likelihood로 두자.

$$Loss(\mathbf{w}) = -\ln p(\mathbf{t}|\mathbf{X}, \mathbf{w}) \quad (45)$$

위의 Loss에 대한 \mathbf{w} 의 다음 gradient를 구하시오.

$$\nabla_{\mathbf{w}} Loss(\mathbf{w}) = \frac{\partial}{\partial \mathbf{w}} Loss(\mathbf{w}) = \quad (46)$$

Gradient 를 Design matrix \mathbf{X} 를 이용하여 간결하게 정리하시오.

- (ii) 위의 Loss에 대한 \mathbf{w} Hessian matrix를 구하시오. $f(\mathbf{x})$ 에 대한 vector \mathbf{x} Hessian matrix \mathbf{H} 는 다음과 같이 정의된다.

$$\mathbf{H}_{ij} = \frac{\partial^2 f(\mathbf{x})}{\partial x_i \partial x_j}$$

Hessian matrix를 Design matrix \mathbf{X} 를 이용하여 간결하게 정리하시오.

- (iii) $\frac{\partial}{\partial \mathbf{w}} Loss(\mathbf{w}) = \mathbf{0}$ 가 되는 analytic solution을 구할 수 있는가? 근거를 설명하시오.
 (iv) Gradient descent 방식에 기반한 \mathbf{w} 의 update 수식을 기술하시오.

- 19 (20 points) Multiclass Logistic regression 학습방법을 유도하고자 한다. K 개의 class중에서 입력 벡터 \mathbf{x} 에 대해, class \mathcal{C}_k 으로 분류할 확률은 linear regression된 값에 softmax를 적용하여 다음과 같이 얻는다 (교재 Eq. 4.104).

$$p(\mathcal{C}_k|\mathbf{x}) = y_k(\mathbf{x}) = \text{softmax}_k(a_{i=1}^K) \quad (47)$$

여기서 $a_k = \mathbf{w}_k^T \mathbf{x}$ 이고 softmax_k 는 다음과 같이 정의된다.

$$\text{softmax}_k(a_{i=1}^K) = \frac{\exp(a_k)}{\sum_j \exp(a_j)} \quad (48)$$

N 개의 입력 데이터가 Design matrix $\mathbf{X} = (\mathbf{x}_1, \dots, \mathbf{x}_N)^T$ 로, 이에 대한 target matrix는 N 개의 one-hot vector로 $\mathbf{T} = (\mathbf{t}_1, \dots, \mathbf{t}_N)^T$ 로 주어진다고 하자. 여기서, \mathbf{t}_i 는 K -dimensional one-hot vector이다. 이때 Data likelihood는 다음과 같다 (교재 Eq. 4.107).

$$p(\mathbf{T}|\mathbf{X}, \mathbf{w}_1, \dots, \mathbf{w}_K) = \prod_{n=1}^N \prod_{k=1}^K y_{nk}^{t_{nk}} \quad (49)$$

여기서 $y_{nk} = y_k(\mathbf{x})$ 이다.

다음 물음에 답하시오.

(i) $Loss(\mathbf{w}_1, \dots, \mathbf{w}_K)$ 를 다음과 같이 cross entropy (negative log-likelihood)로 두자.

$$Loss(\mathbf{w}_1, \dots, \mathbf{w}_K) = -\ln p(\mathbf{T}|\mathbf{X}, \mathbf{w}_1, \dots, \mathbf{w}_K) \quad (50)$$

위의 Loss에 대한 \mathbf{w}_j 의 다음 gradient를 구하시오.

$$\nabla_{\mathbf{w}_j} Loss(\mathbf{w}_1, \dots, \mathbf{w}_K) = \frac{\partial}{\partial \mathbf{w}_j} Loss(\mathbf{w}_1, \dots, \mathbf{w}_K) = \quad (51)$$

Gradient 를 Design matrix \mathbf{X} 와 target matrix \mathbf{T} 를 이용하여 간결하게 표현하시오.

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).