


기계 학습

Part III

9. 신경망

❖ 신경망(neural network, artificial neural network)

- 인간 두뇌에 대한 계산적 모델을 통해 인공지능을 구현하려는 분야
- **신경세포** (neuron)



신경세포 8.6×10^{10} 개


신경연접 1.5×10^{14} 개

- **수상돌기**(樹狀突起, dendrite) : 다른 신경세포의 축색돌기와 연결되어 전기화학적 신호를 받아들이는 부위
- **축색돌기**(軸索突起, axon) : 수신한 전기화학적 신호의 합성결과 값이 특정 임계값이 이상이면 신호를 내보내는 부위.
- **신경연접**(神經連接, synapse) : 수상돌기와 축색돌기 연결 부위
 - 전달되는 신호의 증폭 또는 감쇄

9.1 퍼셉트론

❖ 신경세포의 계산 모델


▪ 신경세포



McCulloch & Pitts, 1943
신경세포의 계산 모델

▪ 퍼셉트론(Perceptron)



- 로젠블라트(Rosenblatt, 1957)이 제안한 학습가능한 신경망 모델




퍼셉트론

❖ 퍼셉트론(Perceptron)

- OR 연산을 수행하는 퍼셉트론



$$y = f(s) = f\left(\sum_{i=1}^2 w_i x_i + b\right) = f(\mathbf{w}^\top \mathbf{x}) = x_1 + x_2 - 0.5$$




- $p_1 (0,0): y = 0$
- $p_2 (1,0): y = 1$
- $p_3 (0,1): y = 1$
- $p_4 (1,1): y = 1$

퍼셉트론


❖ 퍼셉트론(Perceptron)

- **선형 분리가능 문제** (linearly separable problem)



- **선형 분리불가 문제** (linearly inseparable problem)

- **XOR(exclusive OR) 문제**






(0,0) : 0
(0,1) : 1
(1,0) : 1
(1,1) : 0

9.2 다층 퍼셉트론

❖ 다층 퍼셉트론(multilayer Perceptron, MLP)

- 여러 개의 퍼셉트론을 층 구조로 구성한 신경망 모델



$$y = f(s) = f\left(\sum_{i=1}^2 w_i x_i + b\right) = f(\mathbf{w}^\top \mathbf{x})$$

다층 퍼셉트론


❖ 다층 퍼셉트론(multilayer Perceptron, **MLP**) – cont.

▪ 다층 퍼셉트론의 학습


- 입력-출력 (x_i, y_i) 의 학습데이터에 대해서 출력값 $f(x_i)$ 의 차이, **오차** (error)가 최소가 되도록 **가중치 w** 를 결정하는 것

▪ 학습 가능한 다층 퍼셉트론


- 학습알고리즘 : **오차역전파** 알고리즘 발표 (Rumelhart&McClelland 1986)
- 계단모양 전달함수를 미분가능한 시그모이드(sigmoid) 함수로 대체



계단 (step) 함수



시그모이드(sigmoid) 함수




$$f(s) = \frac{1}{1 + e^{-as}}$$

$$f'(s) = \frac{ae^{-as}}{(1 + e^{-as})^2} = af(s)(1 - f(s))$$

다층 퍼셉트론

❖ 다층 퍼셉트론 MLP의 동작



입력 (x_1, x_2, \dots, x_d)


출력 (y_1, y_2, \dots, y_m)

은닉층
$$zsum_j = \sum_{i=1}^d u_{ij}x_i + u_{0j} \quad (1 \leq j \leq p)$$

$$z_j = f(zsum_j)$$


출력층
$$osum_k = \sum_{j=1}^p v_{jk}z_j + v_{0k} \quad (1 \leq k \leq m)$$

$$o_k = f(osum_k)$$



다층 퍼셉트론

❖ 다층 퍼셉트론 MLP의 학습



입력 : (x_1, x_2, \dots, x_d)

기대 출력 : y_k

MLP 출력 : o_k

▪ 학습 목표

- 기대 출력과 MLP 출력이 최대한 비슷해지도록 가중치를 변경하는 것

$$E = \frac{1}{2} (o_k - y_k)^2$$

- 최대 경사법 (gradient descent method) 사용


$$v_{jk}^{(t+1)} = v_{jk}^{(t)} - \eta \frac{\partial E}{\partial v_{jk}}$$

$$u_{ij}^{(t+1)} = u_{ij}^{(t)} - \eta \frac{\partial E}{\partial u_{ij}}$$

다층 퍼셉트론

❖ 다층 퍼셉트론 MLP의 학습

- 오차 역전파 알고리즘 (Error back propagation algorithm, Backprop algorithm)



입력 (x_1, x_2, \dots, x_d)

출력 (y_1, y_2, \dots, y_m)

$$E = \frac{1}{2} \sum_{k=1}^n (o_k - y_k)^2 \quad \text{오차함수}$$

$$\mathbf{v}^{(t+1)} = \mathbf{v}^{(t)} - \eta \frac{\partial E}{\partial \mathbf{v}}$$

$$\mathbf{u}^{(t+1)} = \mathbf{u}^{(t)} - \eta \frac{\partial E}{\partial \mathbf{u}}$$

$$\frac{\partial E}{\partial v_{jk}} = \frac{\partial E}{\partial o_k} \frac{\partial o_k}{\partial v_{jk}} = (o_k - y_k) f'(osum_k) z_j = \delta_k z_j$$

$$\frac{\partial E}{\partial u_{ij}} = \frac{\partial E}{\partial z_j} \frac{\partial z_j}{\partial u_{ij}} = \sum_{k=1}^m \frac{\partial E}{\partial o_k} \frac{\partial o_k}{\partial z_j} f'(zsum_j) x_i$$

$$= \sum_{k=1}^m (o_k - y_k) f'(osum_k) v_{jk} f'(zsum_j) x_i$$

$$= \sum_{k=1}^m \delta_k v_{jk} f'(zsum_j) x_i$$

$$osum_k = \sum_{j=1}^p v_{jk} z_j + v_{0k} \quad (1 \leq k \leq m)$$

$$o_k = f(osum_k)$$


$$zsum_j = \sum_{i=1}^d u_{ij} x_i + u_{0j} \quad (1 \leq j \leq p)$$

$$z_j = f(zsum_j)$$

신경망

❖ 소프트맥스 층 (softmax layer)

- 최종 출력을 **분류 확률**(classification probability)로 변환하는 층
 - 출력의 합 = 1



$$y_k = \frac{e^{\sum_{j=1}^m w_{jk} x_j}}{\sum_{l=1}^n e^{\sum_{j=1}^m w_{jl} x_j}}$$

신경망

❖ 학습 데이터

$$D = \{(\mathbf{x}_1, \mathbf{t}_1), (\mathbf{x}_2, \mathbf{t}_2), \dots, (\mathbf{x}_N, \mathbf{t}_N)\}$$

- i 번째 데이터의 입력 : \mathbf{x}_i
- i 번째 데이터의 입력 : $\mathbf{t}_i = (t_{i1}, t_{i2}, \dots, t_{iK})$ $t_{ij} \in \{0, 1\}$, $\sum_{j=1}^K t_{ij} = 1$
one-hot 벡터 표현

❖ 학습 데이터 $(\mathbf{x}_i, \mathbf{t}_i)$ 의 조건부 확률

$$p(\mathbf{t}_i | \mathbf{x}_i, \mathbf{w}) = \prod_{k=1}^K y_k(\mathbf{x}_i, \mathbf{w})^{t_{ik}} \quad \mathbf{w} : \text{신경망의 동작을 결정하는 전체 가중치 벡터}$$

❖ 전체 데이터 D 에 대한 가능도(likelihood)

$$p(D; \mathbf{w}) = \prod_{i=1}^N \prod_{k=1}^K y_k(\mathbf{x}_i, \mathbf{w})^{t_{ik}}$$

신경망

- ❖ 최대 가능도 추정(maximum likelihood estimation, MLE)
 - 데이터의 가능도를 최대로 하는 파라미터를 추정하는 것

$$\operatorname{argmax}_{\mathbf{w}} \prod_{i=1}^N \prod_{k=1}^K y_k(\mathbf{x}_i, \mathbf{w})^{t_{ik}}$$

- 오차함수 $E(\mathbf{w})$: 음의 로그 가능도로 정의

$$E(\mathbf{w}) = -\log \prod_{i=1}^N \prod_{k=1}^K y_k(\mathbf{x}_i, \mathbf{w})^{t_{ik}} = -\sum_{i=1}^N \sum_{k=1}^K t_{ik} \log y_k(\mathbf{x}_i, \mathbf{w})$$

- 오차함수 = $(t_{i1}, t_{i2}, \dots, t_{iK})$ 와 (y_1, y_2, \dots, y_K) 에 대한 교차 엔트로피


$$E(\mathbf{w}) = -\sum_{k=1}^K t_{ik} \log y_k(\mathbf{x}_i, \mathbf{w})$$

9.3 RBF 망

❖ RBF(radial basis function) 함수

- 기존 벡터 μ 와 입력 벡터 x 의 유사도를 측정하는 함수
- 예.

$$\phi(x, \mu) = \exp(-\beta \|x - \mu\|^2)$$




RBF 망

❖ RBF 망 (RBF network)

- 어떤 함수 $f_k(\mathbf{x})$ 를 다음과 같이 RBF 함수들의 선형 결합 형태로 근사시키는 모델

$$f_k(\mathbf{x}) \approx \sum_{i=1}^N w_{kj} \phi_i(\mathbf{x}, \boldsymbol{\mu}_i) + b_k$$



$$\phi_j = \exp(-\beta_j \|\mathbf{x} - \boldsymbol{\mu}_j\|^2)$$

$$o_k = \sum_{j=1}^N w_{kj} \phi_j + b_k$$

RBF 망

❖ RBF 망의 학습

- 오차 함수 E


$$E = \frac{1}{2} \sum_{k=1}^m (o_k - y_k)^2$$

- 경사 하강법 (gradient-descent method) 사용
 - 기준 벡터 μ_j 와 파라미터 β_j , 가중치 w_{kj} 결정
- 부류 별 군집화 결과를 사용한 기준 벡터 μ_j 와 파라미터 β_j 초기화
 - 군집 중심 : 기준(평균) 벡터 μ_j
 - 분산의 역수 : β_j


$$\sigma = \frac{1}{m} \sum_{i=1}^m \|x_i - \mu\| \quad \beta = \frac{1}{2\sigma^2}$$

RBF 망

- ❖ RBF 망을 이용한 분류의 예
 - o 부류와 x 부류



★ : 군집화 결과 군집 중심



곡선 : 분류 결정 경계