Machine Learning

Contents

5.1. Multi-Layer Perceptron (MLP)

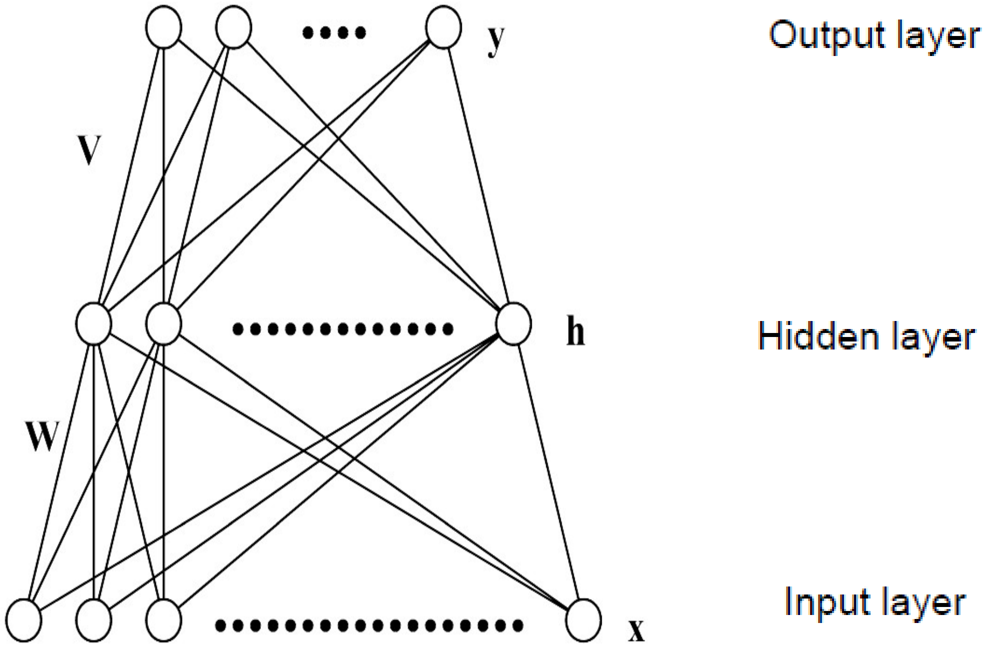

- Feed-forward structure: inputs from the previous layer and outputs to the next layer
- Output layer: sigmoid activation function for classification problems and linear activation function for regression problems
- Figure: two-layer network (two layer of weights)

Architecture of MLP (*N-H-M*): Forward Propagation

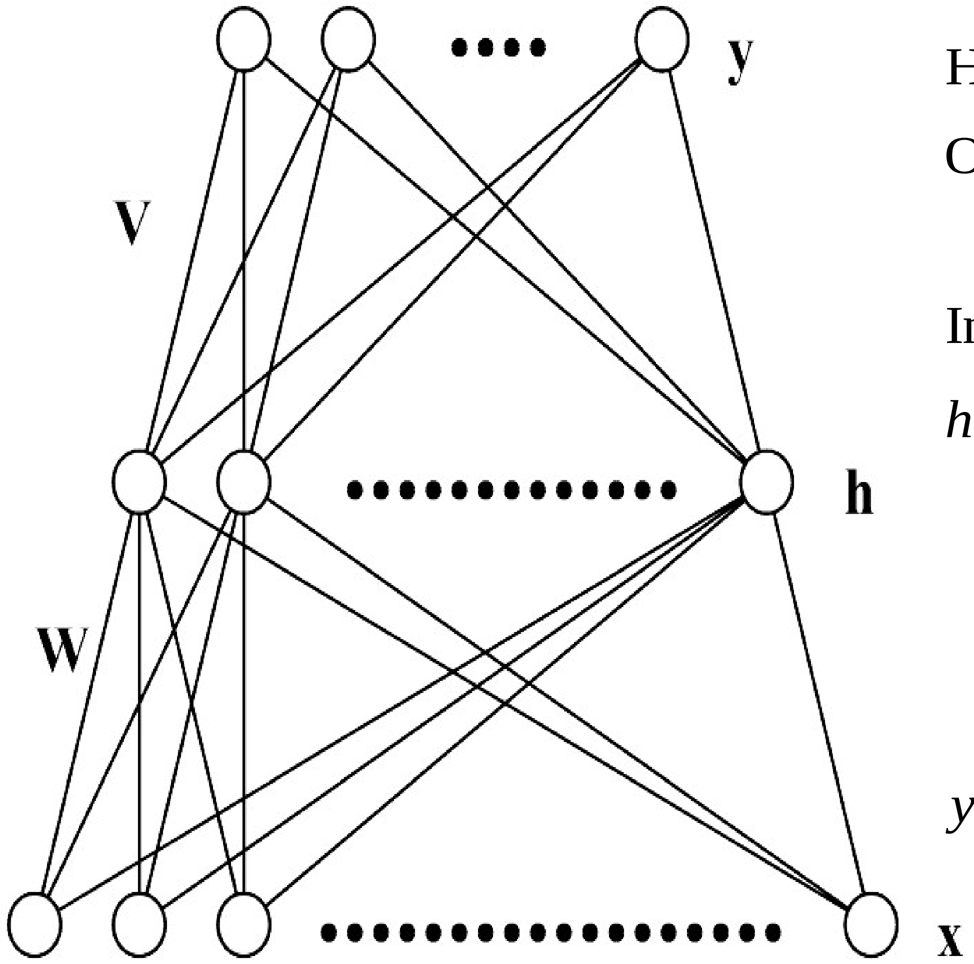

$$\text{Input Nodes}: \mathbf{x} = [x_1, x_2, \cdots, x_N]^T$$

$$\text{Hidden Nodes}: \mathbf{h} = [h_1, h_2, \cdots, h_H]^T$$

$$\text{Output Nodes}: \mathbf{y} = [y_1, y_2, \cdots, y_M]^T$$

$$\text{Input} \longrightarrow \text{Output(?)}$$

$$h_j = f(\hat{h}_j) = \tanh(\hat{h}_j / 2)$$

$$\text{where } \hat{h}_j = \sum_{i=1}^{N} w_{ji} x_i + w_{j0}$$

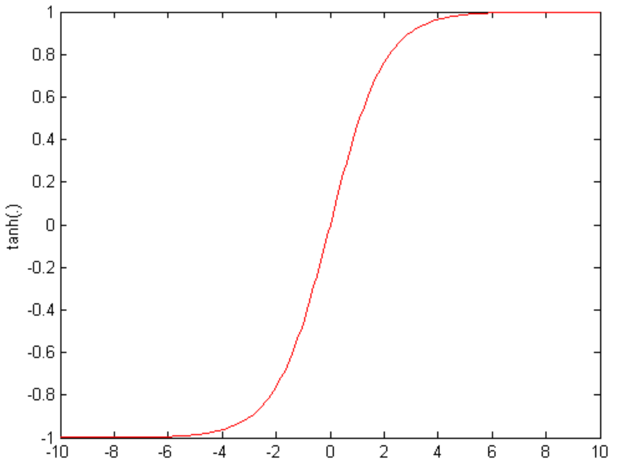

$$y_k = f(\hat{y}_k), \quad \text{where } \hat{y}_k = \sum_{j=1}^{H} v_{kj} h_j + v_{k0}$$

5.2. Representational Power of MLP

- MLP with two layers can represent arbitrary function
  - Each hidden unit represents a soft threshold function in the input space
  - Combine two opposite-facing threshold functions to make a ridge
  - Combine two perpendicular ridges to make a bump
  - Add bumps of various sizes and locations to fit any surface

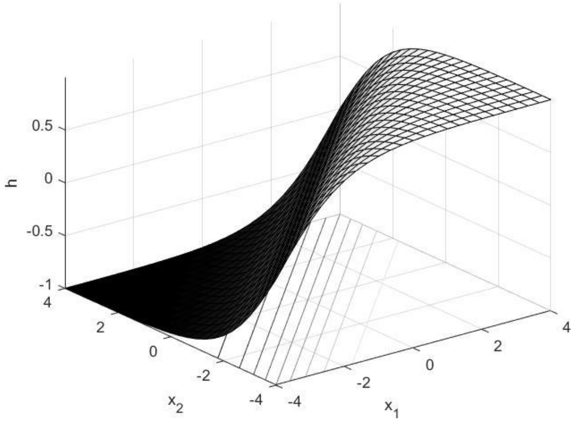

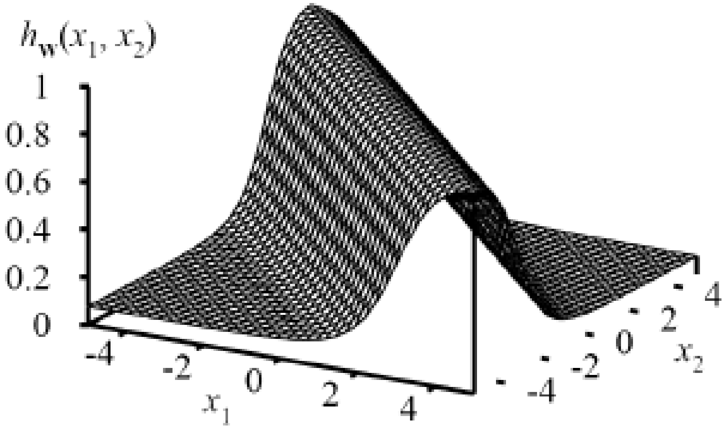

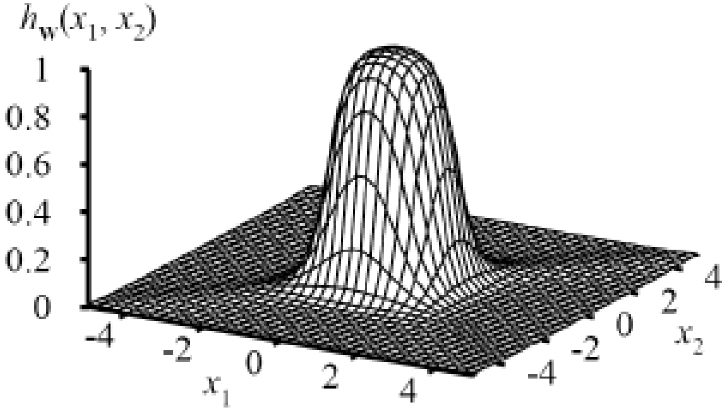

- Universal approximator
  - Given a sufficiently large number of hidden units , a two layer (linear output) network can approximate any continuous function on a compact input domain to arbitrary accuracy.

5.3. Training of MLP : Error Back-Propagation Algorithm

Input Pattern: $\mathbf{x} = [x_1, x_2, \cdots, x_N]^T$

Output Vector: $\mathbf{y} = [y_1, y_2, \cdots, y_M]^T$

Desired Output Vector: $\mathbf{t} = [t_1, t_2, \cdots, t_M]^T$

Mean-Squared Error Function:

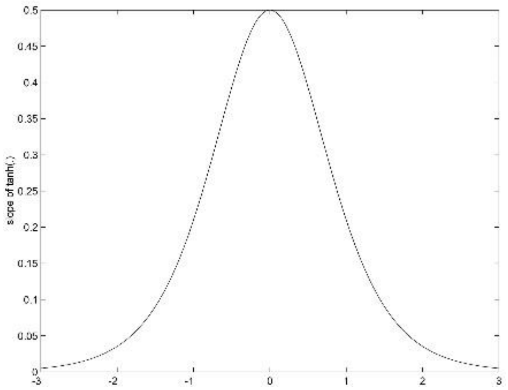

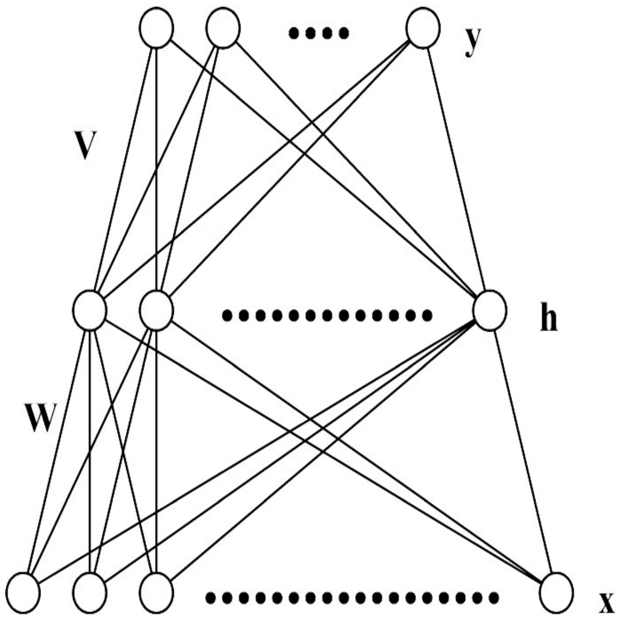

$$E_m(\mathbf{x}) = \frac{1}{2}\sum_{k=1}^{M}(t_k - y_k)^2$$

$$\Delta v_{kj} = -\eta \frac{\partial E_m(\mathbf{x})}{\partial v_{kj}} = \eta \delta_k^{(out)} h_j \quad \text{where } \delta_k^{(out)} = -\frac{\partial E_m(\mathbf{x})}{\partial \hat{y}_k} = (t_k - y_k) f'(\hat{y}_k)$$

$$\Delta w_{ji} = -\eta \frac{\partial E_m(\mathbf{x})}{\partial w_{ji}} = \eta \delta_j^{(hid)} x_i \quad \text{where } \delta_j^{(hid)} = -\frac{\partial E_m(\mathbf{x})}{\partial \hat{h}_j} = f'(\hat{h}_j)\sum_{k=1}^{M} v_{kj}\delta_k^{(out)}$$

참조:

시그모이드 활성화 함수의 미분을 구하여 보자.

$$y = f(x) = \tanh(x/2) = \frac{e^{x/2} - e^{-x/2}}{e^{x/2} + e^{-x/2}} \tag{5.3.7}$$

이다. $u = x/2$로 치환하여

$$f'(x) = \frac{dy}{dx} = \frac{dy}{du}\frac{du}{dx} \tag{5.3.8}$$

로 변경시켜서 계산하면, $du/dx = 1/2$이고

$$\frac{dy}{du} = (1-y)(1+y) \tag{5.3.9}$$

이므로

$$f'(x) = \frac{(1-y)(1+y)}{2} \tag{5.3.10}$$

이다.

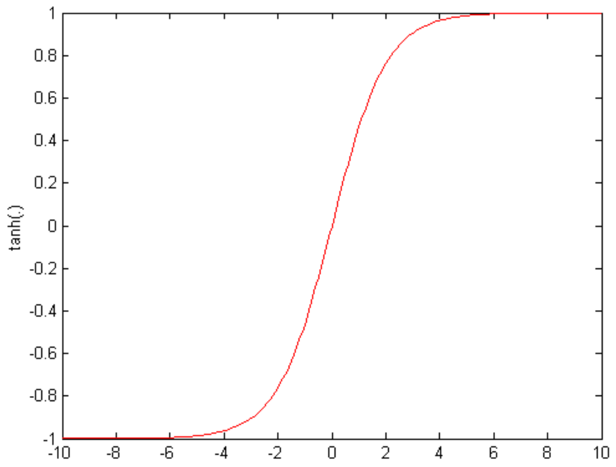

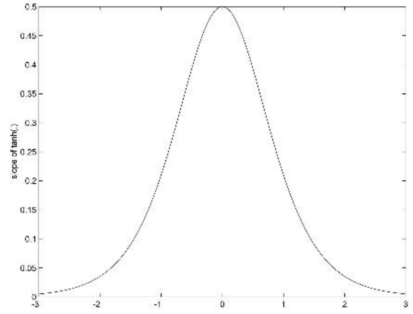

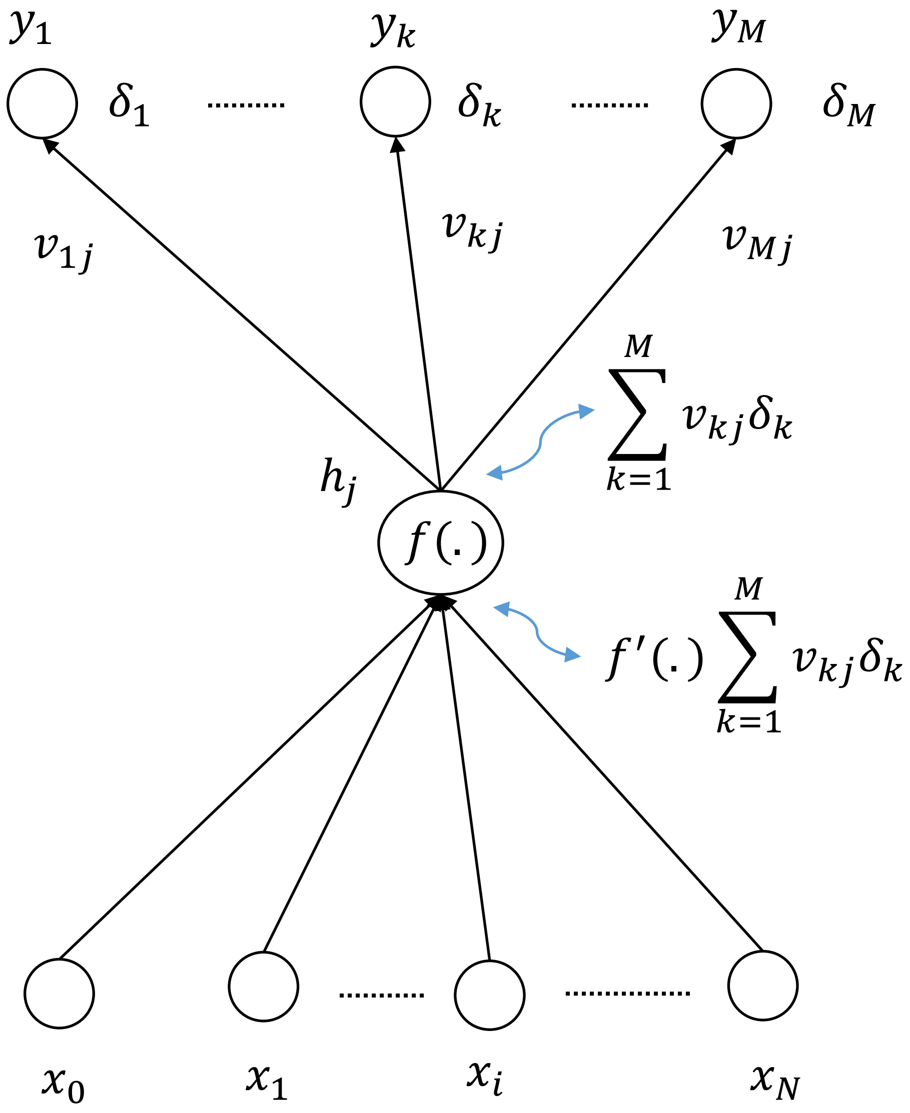
y_1
y_k
y_M
δ_1
δ_k
δ_M
v_{1j}
v_{kj}
v_{Mj}
$\sum_{k=1}^{M} v_{kj}\delta_k$
h_j
$f(.)$
$f'(.)\sum_{k=1}^{M} v_{kj}\delta_k$
x_0
x_1
x_i
x_N

5.4. Incorrect Saturation of Output Nodes

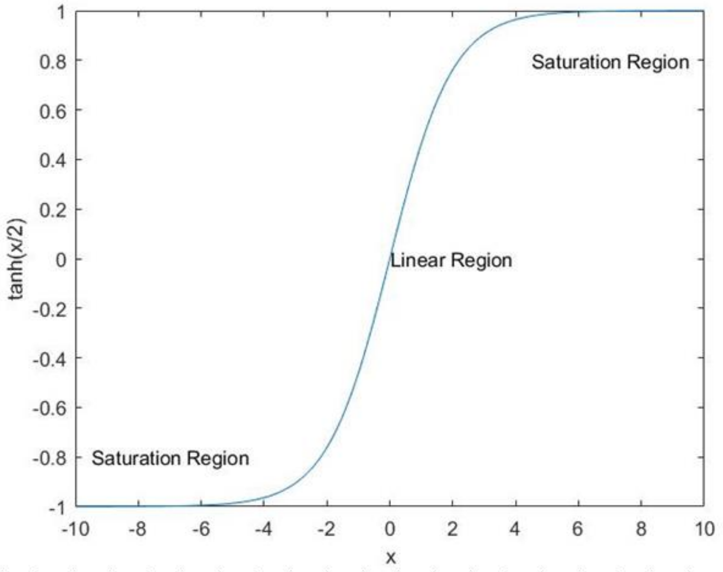

$$\delta_k \equiv -\frac{\partial E_{MSE}}{\partial \widehat{y_k}} = (t_k - y_k) f'(\widehat{y_k}) \qquad (5.3.4)$$

Correct Saturation

$y_k \approx t_k, \delta_k \approx 0$

Incorrect Saturation

If $y_k \approx \pm 1$ and $t_k = \mp 1$, $\delta_k \approx 0$ although $|t_k - y_k| \approx 2$

Incorrect Saturation of Output Nodes → Very Slow Convergence of Learning due to $\delta_k \approx 0$

Training of MLP : Error Back-Propagation Algorithm

< conv. MSE >

$$\delta_k^{out}(\mathbf{x}) = (t_k - y_k) f'(\hat{y}_k)$$

. Incorrect Saturation Problem

$$E_m(\mathbf{x}) = \frac{1}{2}\sum_{k=1}^{M}(t_k - y_k)^2$$

< Cross-Entropy Error >

$$\delta_k^{out}(\mathbf{x}) = (t_k - y_k)$$

. Overspecialization Problem

$$E_{CE}(\mathbf{x}) = -\sum_{k=1}^{M}\left[(1+t_k)\ln\left(1+y_k(\mathbf{x})\right) + (1-t_k)\ln\left(1-y_k(\mathbf{x})\right)\right]$$

< n-th order Extension of CE >

$$\delta_k^{out}(\mathbf{x}) = \frac{t_k^{\,n+1}(t_k - y_k)^n}{2^{n-1}}$$

$$E_{nCE} = -\sum_{k=1}^{M}\int \frac{t_k^{n+1}(t_k - y_k)^n}{2^{n-2}(1-y_k)(1+y_k)} dy_k$$

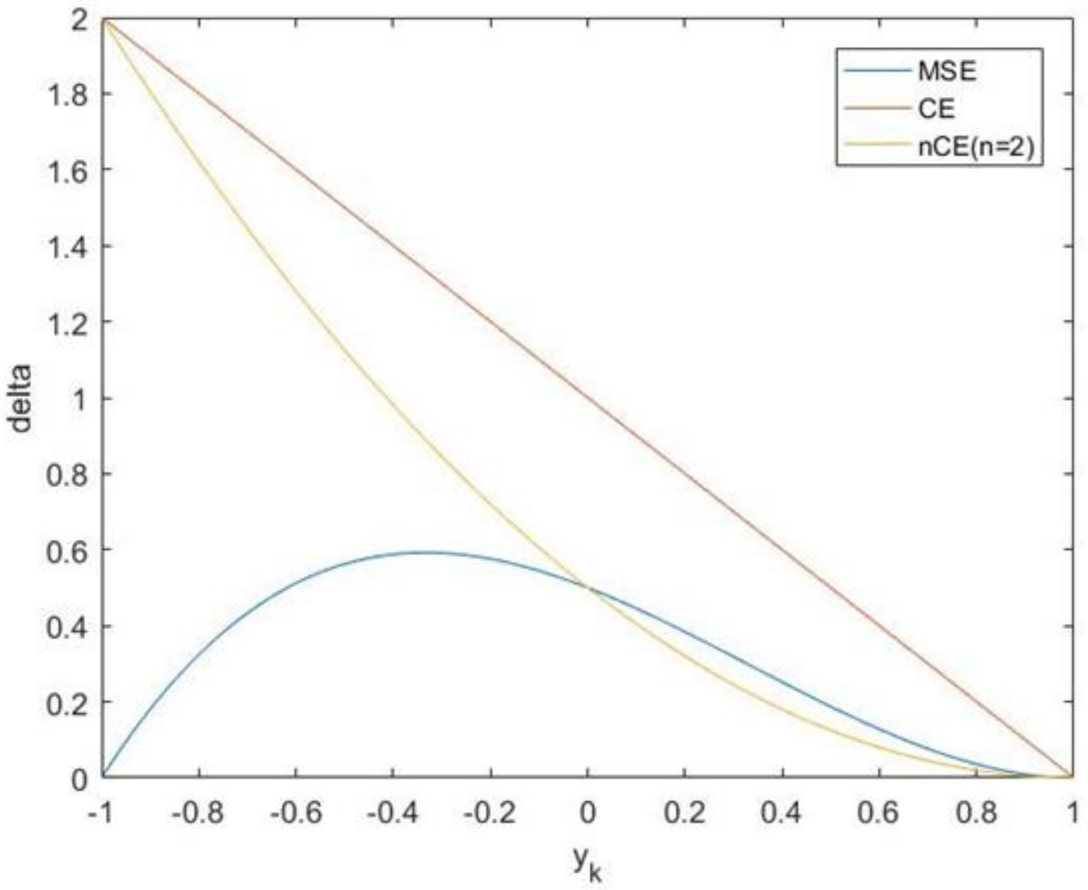

Plot of $\delta_k^{out}(\mathbf{x}^{(p)})$ when $t_k = 1$

Error Back-Propagation Algorithm

오류역전파(EBP) 알고리즘

① 다층퍼셉트론의 가중치들을 초기화 시킨다.

② 학습패턴 $\boldsymbol{x}$가 주어지면, 전방향 계산에 의해 출력노드 값을 구한다.

③ 출력노드의 오류 신호 δ_k를 계산한다.

④ 은닉노드의 오류신호 $\delta_j^{(hidden)}$을 역전파 방법에 의해 계산한다.

⑤ 출력층 가중치와 은닉층 가중치의 변경량을 계산한다.

⑥ 출력층 가중치와 은닉층 가중치를 변경시킨다.

참조: 오차함수의 통계적 의미

오차함수의 통계적 의미를 분류문제의 경우에 대하여 유도하여 보자. 분류문제에서 목표 값은

$$t_k = \begin{cases} +1 & \text{if } \mathbf{x} \text{ originats from class k} \\ -1 & \text{otherwise} \end{cases} \tag{5.4.6}$$

로 주어진다. 그러면, 학습패턴의 수가 무한대로 갈 경우 오차함수 E_{MSE}를 최소화 하는 다층퍼셉트론은

$$E[E_{MSE}] = E\left[\frac{1}{2}\sum_{k=1}^{M}(T_k - y_k(\boldsymbol{X}))^2\right] \tag{5.4.7}$$

을 최소화 시키는 다층퍼셉트론으로 수렴한다. 여기서, $E[.]$는 기대치(Expectation) 연산자이고, T_k는 목표값 확률변수이고, $\boldsymbol{X}$는 입력을 나타내는 확률벡터이다. 목표값이 식 (5.4.6)과 같이 코딩되어 있기 때문에 식 (5.4.7)에서

$$E\left[\sum_{k=1}^{M}(T_k - y_k(\boldsymbol{X}))^2\right] = \int \left[(1-y_k(\boldsymbol{x}))^2 Q_k(\boldsymbol{x}) + (-1-y_k(\boldsymbol{x}))^2(1-Q_k(\boldsymbol{x}))\right] f(\boldsymbol{x})d\boldsymbol{x} \tag{5.4.8}$$

로 된다. 여기서, $Q_k(\boldsymbol{X}) = \Pr[\boldsymbol{X} \text{ originates from class k} | \mathbf{X} = \mathbf{x}]$ 이고, $f(\boldsymbol{x})$는 $\boldsymbol{x}$의 확률밀도함수이다. 식 (5.4.8)을 최소화 시키는 함수 $b_k(\boldsymbol{X})$를 $(-1,+1)$ 구간의 함수 공간에서 찾아보자. 고정된 $Q_k(\boldsymbol{X}), 0 < Q_k(\boldsymbol{X}) < 1$,에 대하여 최적 해 $b_k(\boldsymbol{X})$는 식 (5.4.8)의 $y_k(\boldsymbol{x})$에 대한 미분이 0이 되는 조건에 의해

$$b_k(\boldsymbol{X}) = 2Q_k(\boldsymbol{X}) - 1,\ k = 1,2,\dots,M \tag{5.4.9}$$

으로 구해진다.

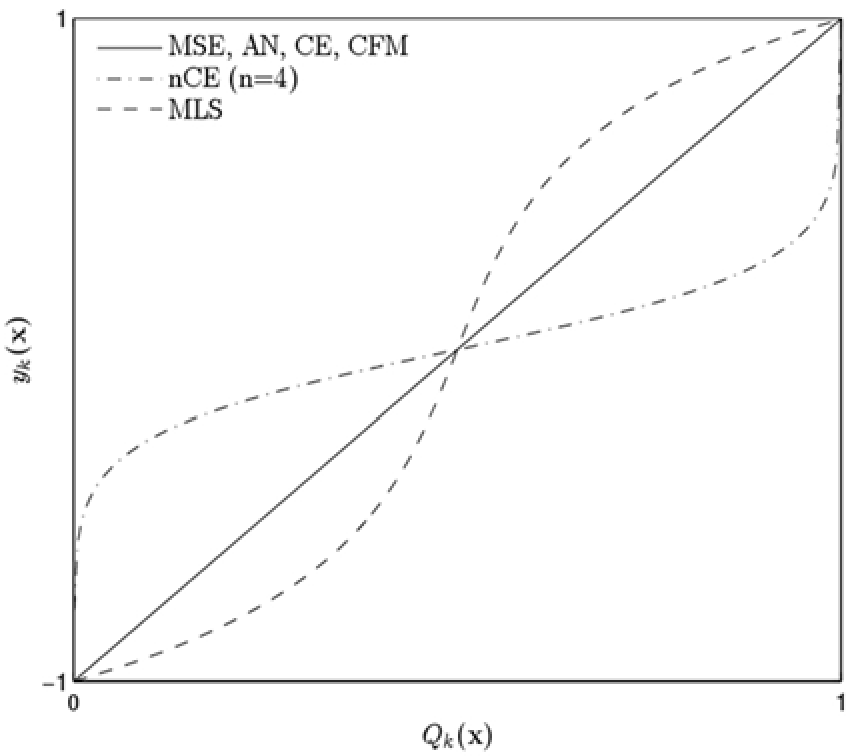

그림 5.6. 오차함수의 최적 해에 해당하는 출력

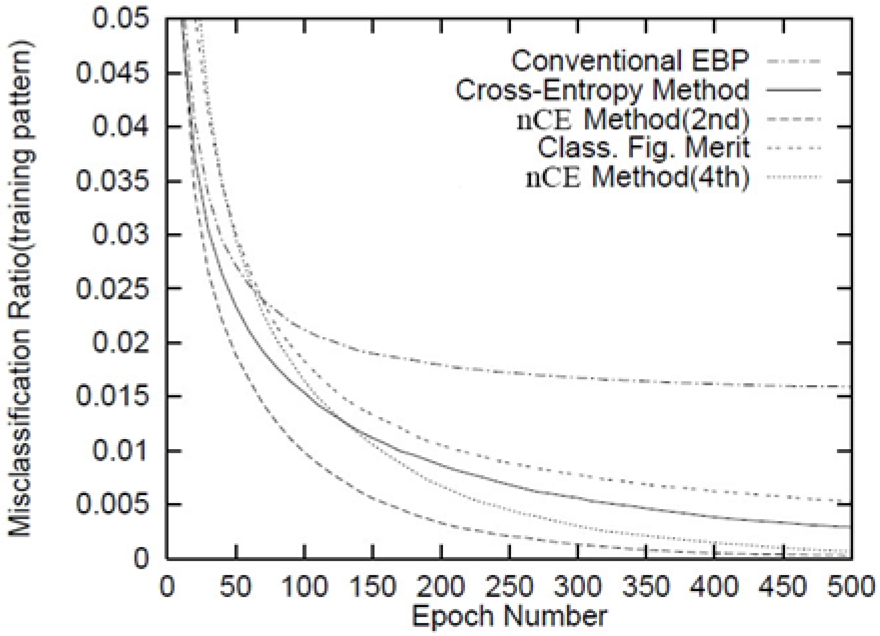

(a) 학습패턴에 대한 오인식률

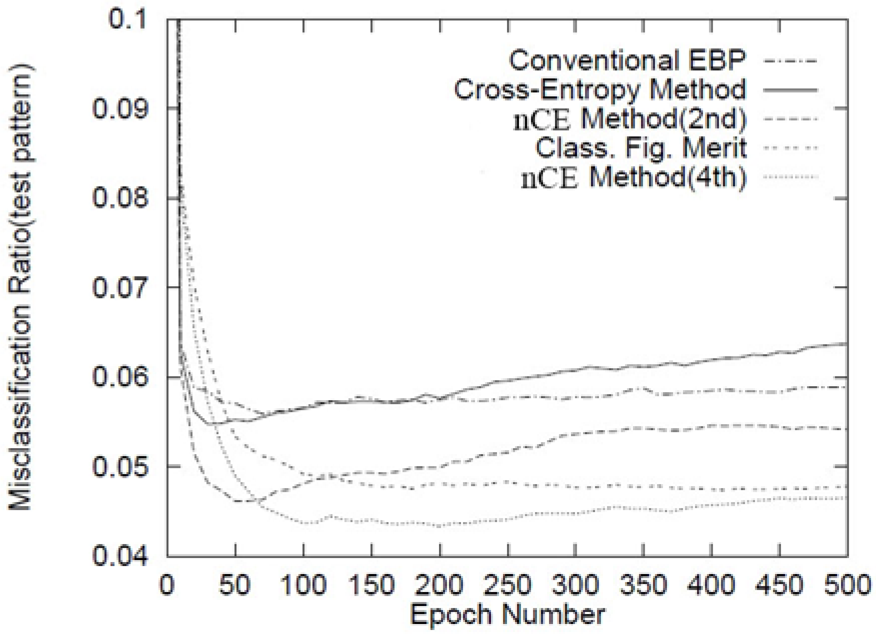

(b) 시험패턴에 대한 오인식률

그림 5.7. 필기체 숫자인식 문제의 학습 시뮬레이션 결과

예제 5.4-1

아래 그림으로 2차원 공간 상에 주어진 XOR 문제를 입력 2, 은닉노드 4, 출력 1개의 노드를 지닌 다층퍼셉트론으로 학습하기 위하여 초기 가중치를 $\boldsymbol{W} = \begin{pmatrix} w_{10} & w_{11} & w_{12} \\ w_{20} & w_{21} & w_{22} \\ w_{30} & w_{31} & w_{32} \\ w_{40} & w_{41} & w_{42} \end{pmatrix} = \begin{pmatrix} 0 & 1 & 0.5 \\ 0 & 1 & 0.9 \\ 0 & 0.9 & 1 \\ 0 & 0.5 & 1 \end{pmatrix}$와

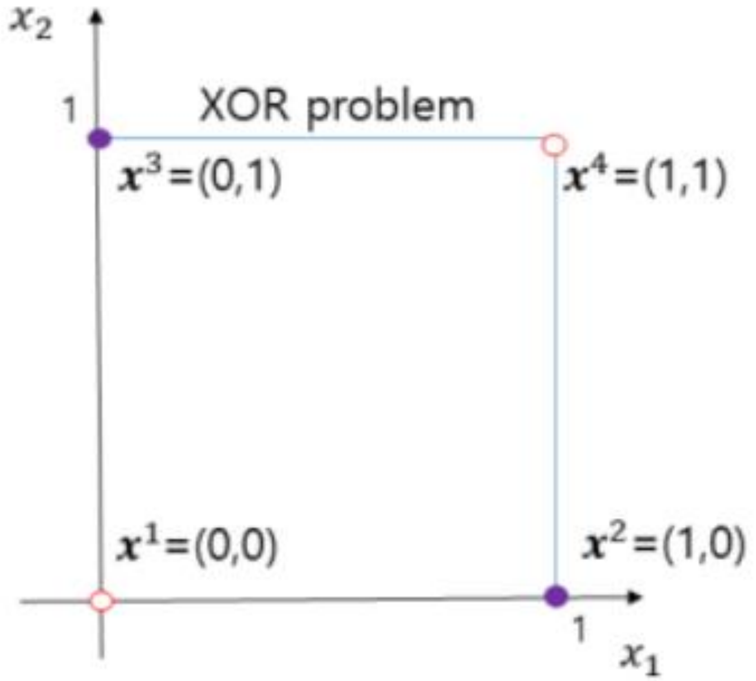

$\boldsymbol{v} = (v_0, v_1, v_2, v_3, v_4) = (0, 0.3, 0.6, 0.9, 1.2)$로 초기화 하였다고 가정하자. 출력 목표값은 입력 $\boldsymbol{x}^1$과 $\boldsymbol{x}^4$에 대해서만 -1이고 입력 $\boldsymbol{x}^2, \boldsymbol{x}^3$에 대해서는 1이다. 4개의 입력 중 임의의 하나를 골라서 다층퍼셉트론에 입력하여 MSE, CE, nCE(n=2) 오차함수에 따른 출력노드와 첫 은닉노드의 오류신호를 구하여 보아라.

5.5. Remarks on Training

- Convergence(?)… may oscillate or reach a local minima.
- Many epochs (thousands) may be needed for adequate training
- Termination criteria:
  - Fixed number of training epochs
  - Threshold on error of training samples
  - Increasing of error on a validation samples
- For better performance, run several trials starting from different initial random weights
  - Take the result with the best training or validation performance.
  - Build a committee of networks (ensemble technique)…Chapter 8

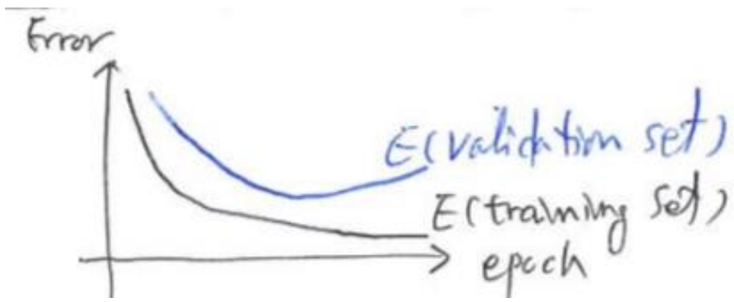

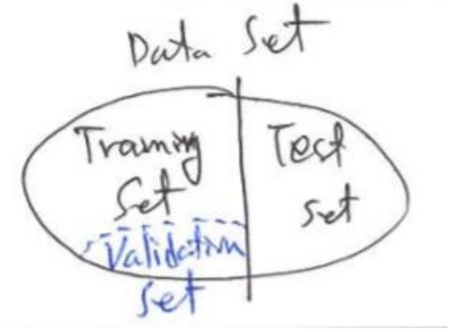

Initialization of Weights

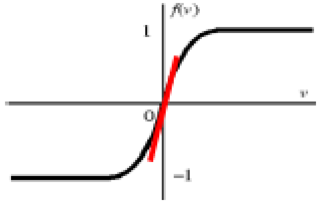

- Initialization of weights such that nodes are in the “linear” regions
  - To avoid the premature saturation problem
  - Keep all weights near zero, so that all sigmoid units are in their linear regions. Otherwise nodes can be initialized into flat regions of the sigmoid causing for very small gradients.$\Rightarrow$ Premature Saturation Problem

- Break symmetry
  – Each hidden node should have different input weights so that the hidden nodes move in different directions.

Online, Batch and Learning with Momentum

- **Online**: Take a gradient descent step with each input
- **Batch**: Sum the gradient for each example *i*. Then take a gradient descent step
- **Momentum factor**: Make the *t+1*-th update dependent on the *t*-th update

$$\Delta v_{kj}(t) = \eta \delta_k h_j + \alpha \Delta v_{kj}(t-1)$$

$$\Delta w_{ji}(t) = \eta \delta_j^{(hidden)} x_i + \alpha \Delta w_{ji}(t-1)$$

- to keep weight moving in the same direction and improves convergence

Overtraining Prevention

- Too many epochs → over-train the network

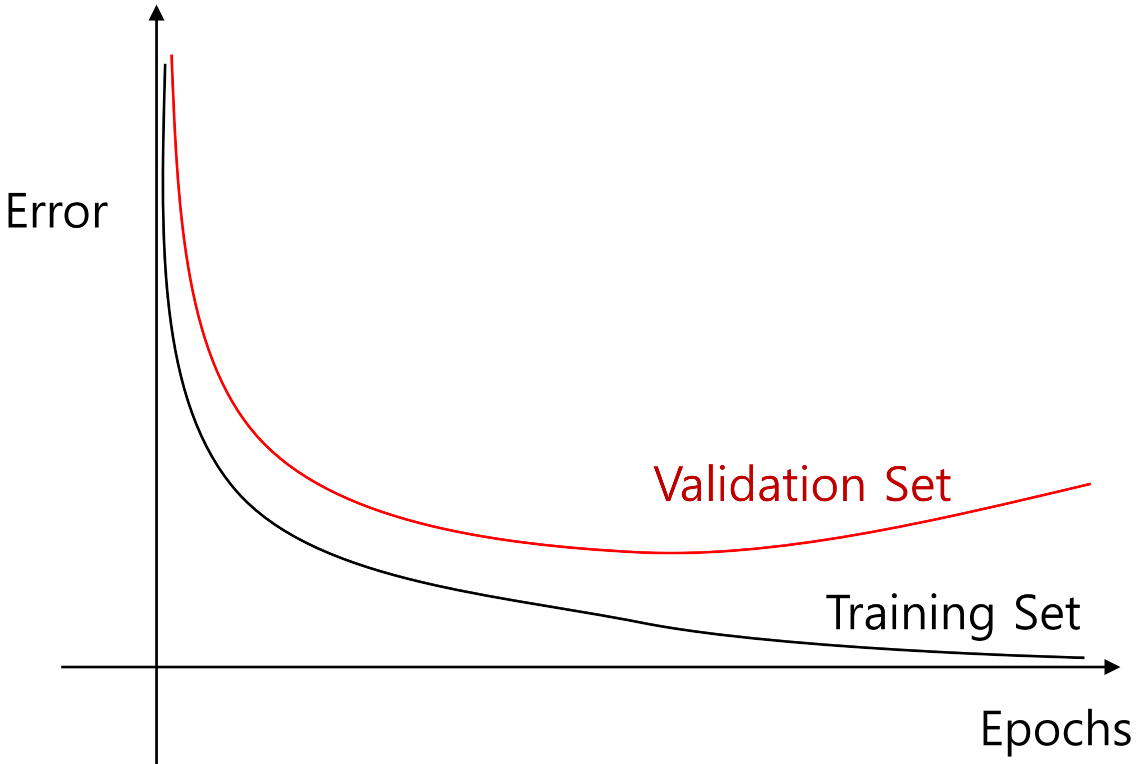

- Use a validation set to test accuracy in some intervals of epochs
- Stop the training when the performance on the validation set decreases
- 10-fold cross-validation

Over-fitting Prevention

- Too few hidden units prevent the system from adequately fitting the data and learning the concept.
- Too many hidden units leads to over-fitting.

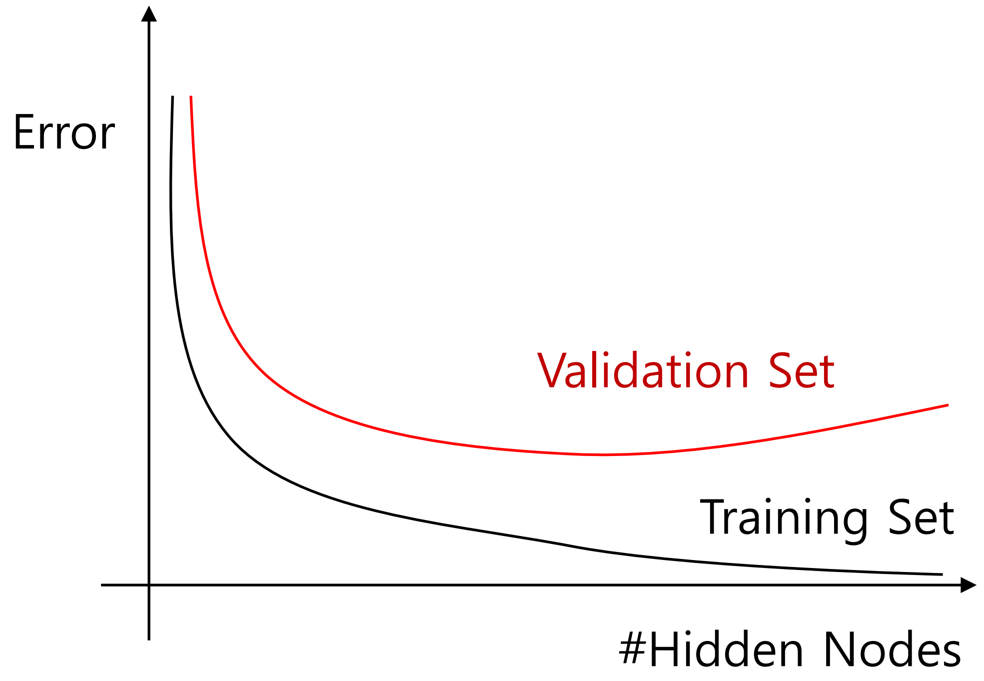

- Trial and error
- Another approach to preventing over-fitting is ***weight decay***

5.6. Learning Time Series Data

- Time-delay neural networks (TDNN)

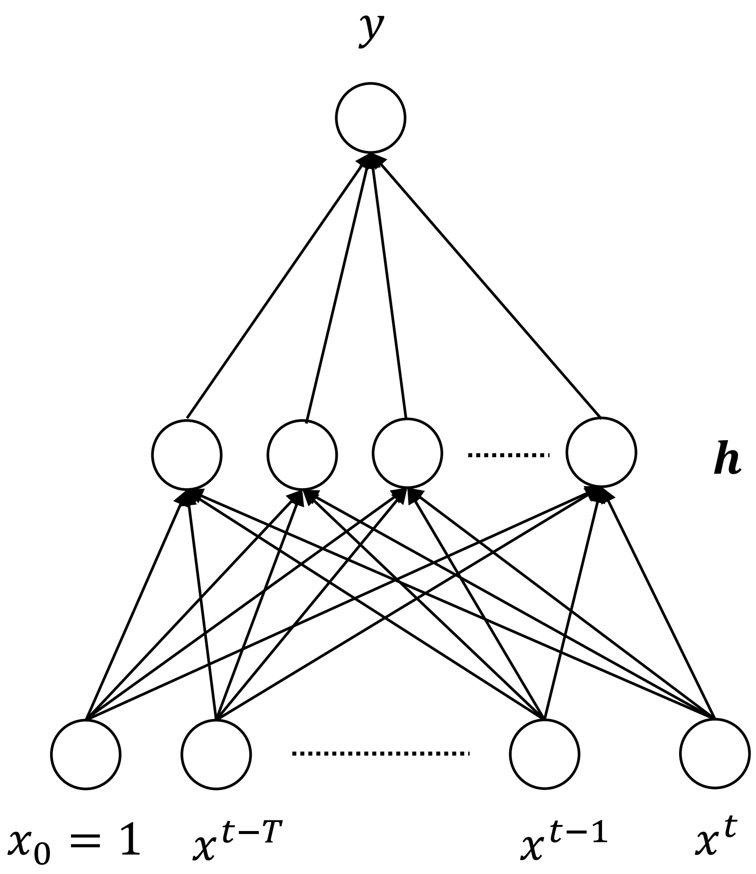

5.7. Deep Neural Networks

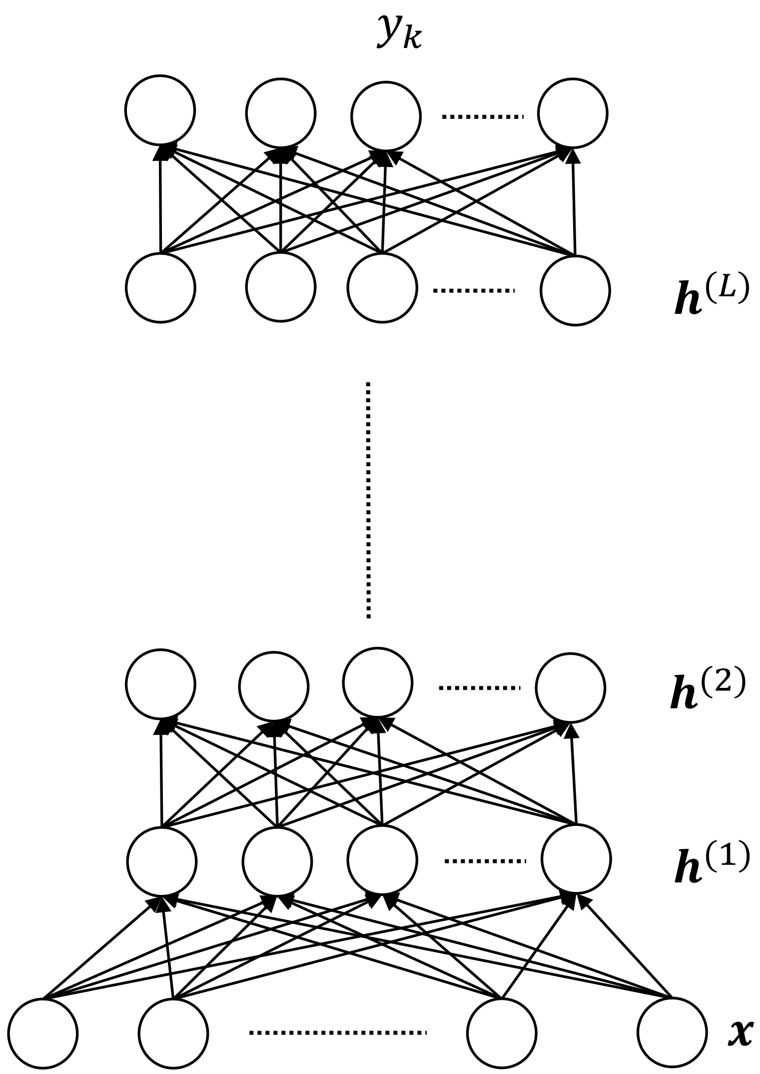

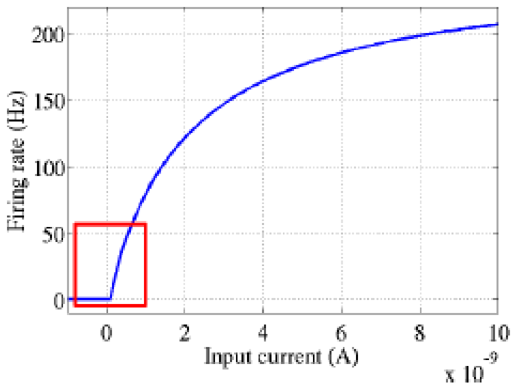

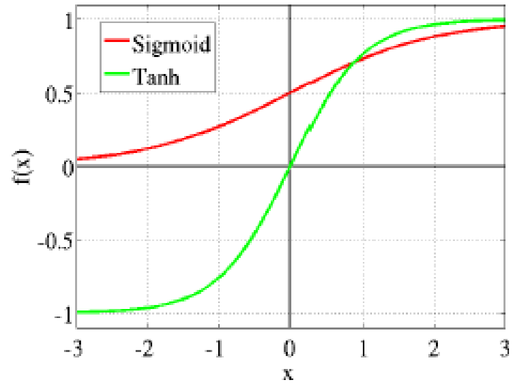

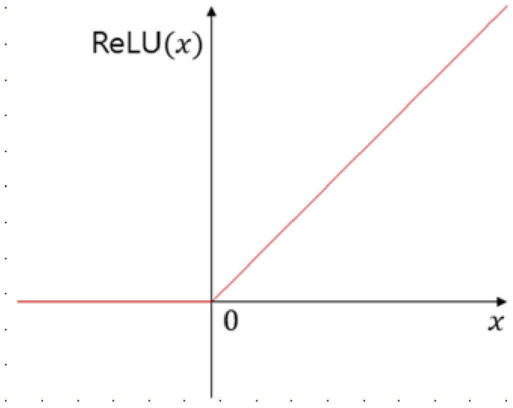

그림 5.10. ReLU 활성화 함수

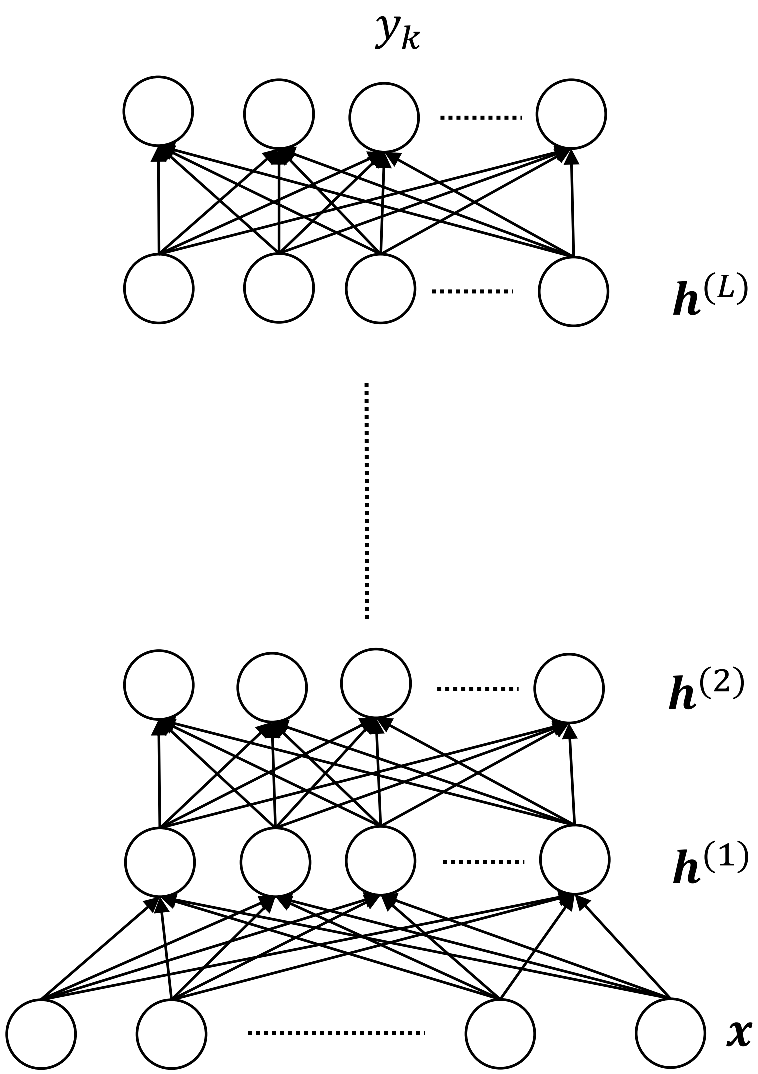

$$f(x) = \max(0, x) = \begin{cases} x & \text{if} \quad x > 0 \\ 0 & \text{otherwise} \end{cases} \tag{5.7.1}$$

$$f'(x) = \begin{cases} 1 & \text{if} \quad x > 0 \\ 0 & \text{otherwise} \end{cases} \tag{5.7.2}$$

$$y_k = \frac{e^{\hat{y_k}}}{\sum_j e^{\hat{y_j}}} \tag{5.7.3}$$

$$E_{CE} = -\sum_k t_k \log(y_k) \tag{5.7.4}$$

$$\partial\, y_k / \partial\, \hat{y_j} = \begin{cases} y_k(1 - y_k) & \text{if} \;\; j = k \\ -y_k y_j & \text{otherwise} \end{cases} \tag{5.7.5}$$

$$\frac{\partial E_{CE}}{\partial \hat{y_k}} = y_k - t_k \tag{5.7.6}$$

$$\delta_k = -\frac{\partial E_{CE}}{\partial \hat{y_k}} = t_k - y_k \tag{5.7.7}$$

참조: SoftMax의 미분

식 (5.7.3)으로 주어진 SoftMax 함수의 미분을 구해보자. 먼저

$$\frac{\partial y_k}{\partial \hat{y}_k} = \frac{\partial \dfrac{e^{\hat{y}_k}}{\sum_j e^{\hat{y}_j}}}{\partial \hat{y}_k} = \frac{e^{\hat{y}_k}\sum_j e^{\hat{y}_j} - e^{\hat{y}_k} e^{\hat{y}_k}}{\left[\sum_j e^{\hat{y}_j}\right]^2} \tag{5.7.8}$$

이 된다. 여기서,

$$\frac{d}{dx}\frac{f(x)}{g(x)} = \frac{f'(x)g(x) - f(x)g'(x)}{g^2(x)} \tag{5.7.9}$$

를 사용하였다. 식 (5.7.3)을 이용하여 식 (5.7.8)을 정리하면

$$\frac{\partial y_k}{\partial \hat{y}_k} = y_k(1 - y_k) \tag{5.7.10}$$

이다. 또한, $k \neq i$ 일때

$$\frac{\partial y_k}{\partial \hat{y}_i} = \frac{\partial \dfrac{e^{\hat{y}_k}}{\sum_j e^{\hat{y}_j}}}{\partial \hat{y}_i} = \frac{-e^{\hat{y}_k} e^{\hat{y}_i}}{\left[\sum_j e^{\hat{y}_j}\right]^2} = -y_k y_i \tag{5.7.11}$$

이다. 이를 정리하면,

$$\frac{\partial y_k}{\partial \hat{y}_i} = \begin{cases} y_k(1 - y_k) & \text{if } k = i \\ -y_k y_i & \text{otherwise} \end{cases} = y_i(\delta_{ki} - y_k) \tag{5.7.12}$$

이다. 여기서,

$$\delta_{ki} = \begin{cases} 1 & \text{if } k = i \\ 0 & \text{otherwise} \end{cases} \tag{5.7.13}$$

는 Kronecker delta 이다.

참조: 교차 엔트로피 오차함수의 미분

SoftMax 함수를 지닌 출력층에서 CE 오차함수가 식 (5.7.4)로 주어진 경우, $\widehat{y_k}$에 대한 미분을 계산하면

$$\frac{\partial E_{CE}}{\partial \widehat{y_k}} = -\sum_j t_j \frac{\partial \log(y_j)}{\partial \widehat{y_k}} = -\sum_j t_j \frac{\partial \log(y_j)}{\partial y_j} \frac{\partial y_j}{\partial \widehat{y_k}} \tag{5.7.14}$$

이며, 미분에서 연쇄법칙(Chain Rule)을 이용하면 마지막 항을 얻게 된다. 이를 $j \neq k$일 때와 $j = k$ 때를 구분하여 정리하면

$$\begin{aligned} \frac{\partial E_{CE}}{\partial \widehat{y_k}} &= -\sum_j \frac{t_j}{y_j} \frac{\partial y_j}{\partial \widehat{y_k}} = -\frac{t_k}{y_k} y_k (1 - y_k) - \sum_{j \neq k} \frac{t_j}{y_j} (-y_j y_k) \\ &= \sum_j t_j y_k - t_k \end{aligned} \tag{5.7.15}$$

이다. $\sum_j t_j = 1$ 이므로,

$$-\frac{\partial E_{CE}}{\partial \widehat{y_k}} = t_k - y_k \tag{5.7.16}$$

이 된다.

참조: ELUs(Exponential Linear Units)와 GELUs(Gaussian Error Linear Units)

식 (5.7.1)로 주어진 ReLU 활성화 함수는 입력 값 $x < 0$의 영역에서 0을 출력하며 기울기도 0이다. 즉, $x < 0$에서 정보의 전달과 학습을 위한 가중치의 변경이 이루어지지 않으며, 이를 "dead ReLU" 문제라고 한다. 이 단점을 해결하기 위하여 제안된 활성화 함수가 ELUs(Exponential Linear Units)[17]이며, 그 수식은

$$\mathrm{ELU}_{\alpha}(x) = \begin{cases} x & \text{if } x > 0 \\ \alpha(\exp(x) - 1) & \text{otherwise} \end{cases} \tag{5.7.31}$$

이다. ELU 활성화 함수는 $x < 0$이어도 값이 출력되며, 기울기가 0이 아니어서 dead ReLU 문제가 해결된다. 또한, ReLU 활성화 함수는 $x = 0$에서 급격하게 변하는 단점이 있는데, ELU는 이 문제도 해결되어 학습의 수렴 속도가 빠르다.

GELUs(Gaussian Error Linear Units)[18] 역시 ReLU 보다 뛰어난 학습 성능을 지니도록 제안된 활성화 함수이다. 식 (5.7.1)의 ReLU는

$$\mathrm{ReLU}(x) = \max(x, 0) = x\mathbf{1}(x > 0) \tag{5.7.32}$$

와 같이 표현할 수 있다. 여기서, **1**은 지시함수(indicator function)로써 1과 0을 출력한다. GELU는 지시함수 대신에 평균 μ이 0이고 표준편차 σ가 1인 Guassian 확률변수의 CDF(Cummulative Distribution Function) $\Phi(x)$을 사용하여

$$\mathrm{GELU}(x) = x\Phi(x) = x\frac{1}{2}\left[1 + \mathrm{erf}(x/\sqrt{2})\right] \tag{5.7.33}$$

와 같이 주어진다. 여기서, $\Phi(x)$는 erf(error function)으로 계산할 수 있다. GELU의 정확한 값 계산보다 계산 속도를 중시하면

$$\mathrm{GELU}(x) \approx 0.5x\left(1 + \tanh\left[\sqrt{2/\pi}(x + 0.044715x^3)\right]\right) \tag{5.7.34}$$

혹은

$$\mathrm{GELU}(x) \approx x\sigma(1.702x) \tag{5.7.35}$$

와 같이 근사치를 사용해도 된다. 여기서, $\sigma(.)$는 식 (4.6.3)으로 주어진 시그모이드 함수이다.

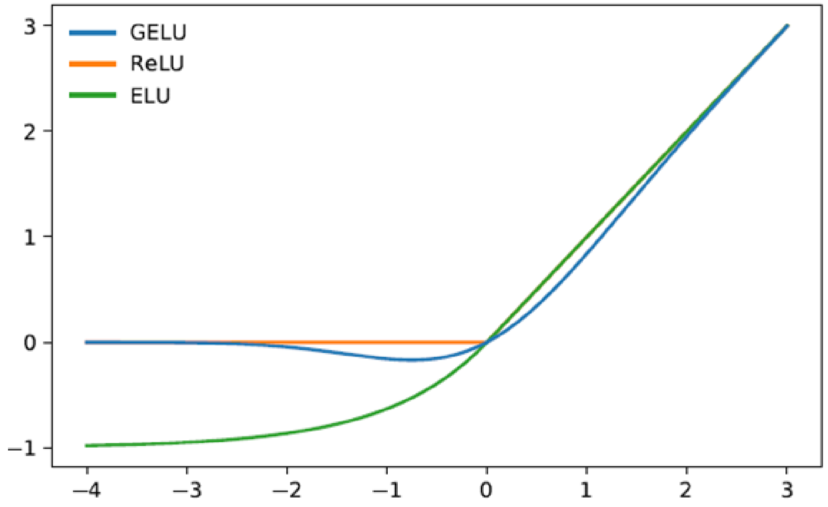

GELU는 ReLU를 매끄러운 모양으로 만들은 형태이다. GELU는 단조함수가 아니며 모든 지점에서 곡률을 지닌 것이 ReLU 및 ELU와 다른 특징이다. 이 특징이 GELU가 ReLU 및 ELU보다 더 뛰어난 학습 성능을 지니도록 해준다[18].

예제 5.7-1

그림 5.10과 같이 심층신경회로망이 주어졌다. $h_j^{(l)}\,(l=,1,2,,,,L)$과 아래층 사이의 연결 가중치를 $w_{ji}^{(l)}\,(l=,1,2,,,,L)$이라 하고 마지막층 출력노드 y_k와 아래층 $h_j^{(L)}$ 사이의 연결 가중치를 v_{kj} 라고 할 때, 정방향 전파의 계산 과정을 적어보아라. 또한, 출력노드의 오류신호가 $\delta_k = t_k - y_k$로 주어지면 역방향 전파에 의한 은닉노드의 오류신호를 적어보아라.

예제 5.7-2

SoftMax 함수는 벡터 요소들 중에서 큰 값은 더 크게, 작은 값은 더 작게 상대적으로 조정하며 그 값들의 합은 1이 되게 한다. SoftMax 함수에 4차원 벡터 [4 10 6 5]가 입력되었을 때, SoftMax 함수를 통과한 후의 4차원 벡터를 구하여 보아라.

5.8. Radial Basis Function Networks

- Locally-tuned units:

$$h_j = \exp\left[-\frac{\|\boldsymbol{x} - \boldsymbol{m}_j\|^2}{2s_j^2}\right] \qquad (5.8.1)$$

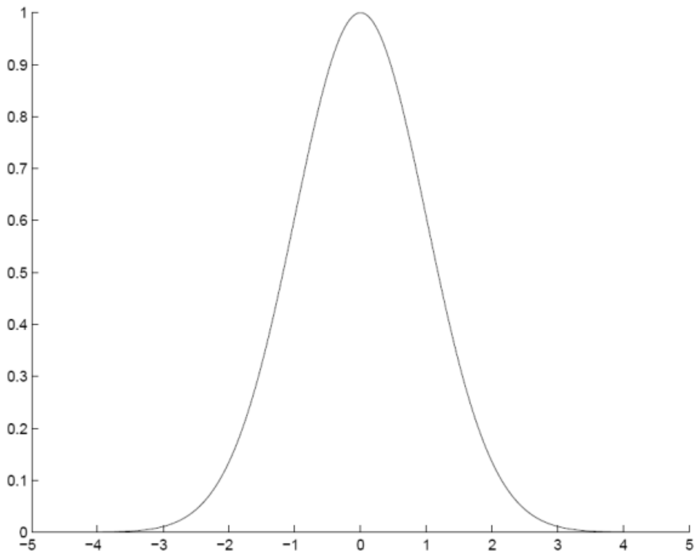

$$y_k = \sum_j w_{kj} h_j \qquad (5.8.2)$$

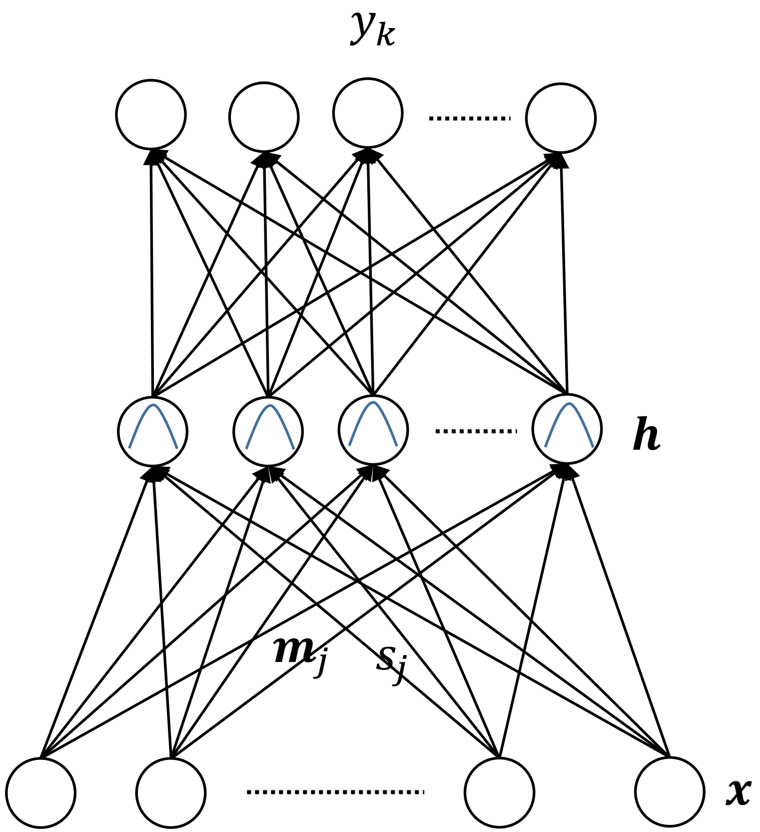

Local vs. Distributed Representation

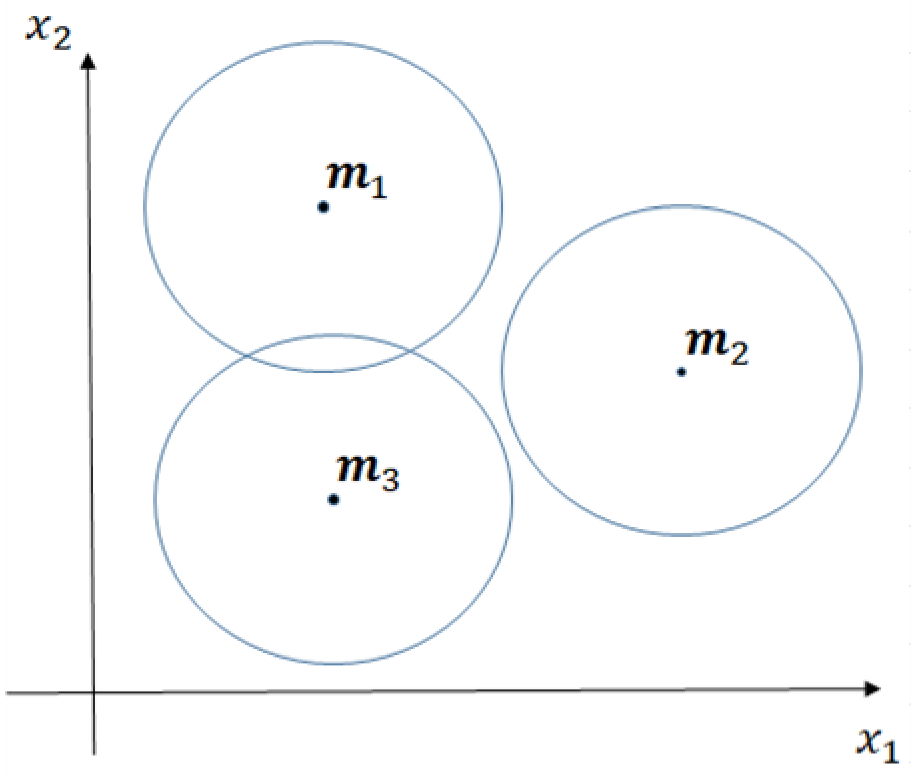

그림 5.12. RBFN의 국소 표현

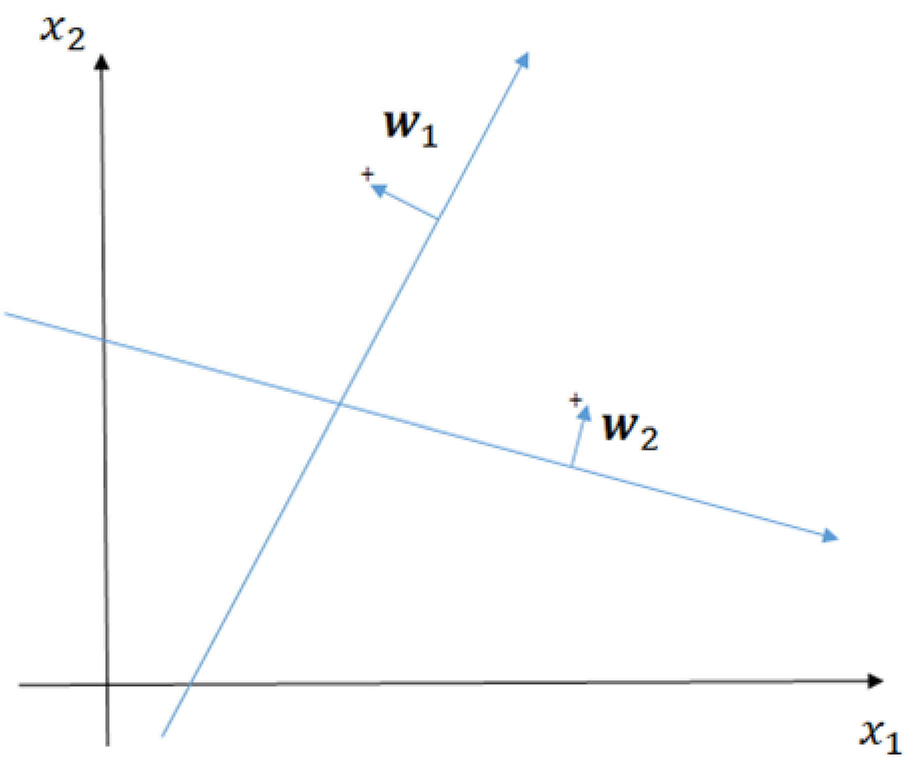

그림 5.13. 다층퍼셉트론의 분포된 표현

Training RBF Network

- Hybrid learning
  - First layer centers and spreads (Unsupervised k-means)
  - Second layer weights (Supervised gradient descent)
- Fully supervised
  - Similar to backpropagation in MLP, gradient descent for all parameters

RBF Network: Fully Supervised Method

- Similar to backpropagation in MLP

$$E_{MSE}=\frac{1}{2}\sum_{k=1}^{M}(t_k-y_k)^2 \qquad (5.8.3)$$

$$\frac{\partial E_{MSE}}{\partial w_{kj}}=-(t_k-y_k)h_j \qquad (5.8.4)$$

$$\Delta w_{kj}=-\eta\frac{\partial E_{MSE}}{\partial w_{kj}}=\eta(t_k-y_k)h_j \qquad (5.8.5)$$

$$\begin{aligned}-\frac{\partial E_{MSE}}{\partial m_{jh}}&=-\frac{1}{2}\sum_k\frac{\partial(t_k-y_k)^2}{\partial m_{jh}} \qquad (5.8.6)\\&=\sum_k-\frac{1}{2}\frac{\partial(t_k-y_k)^2}{\partial y_k}\frac{\partial y_k}{\partial h_j}\frac{\partial h_j}{\partial m_{jh}}\\&=\sum_k(t_k-y_k)w_{kj}\frac{\partial h_j}{\partial m_{jh}}\end{aligned}$$

$$\frac{\partial h_j}{\partial m_{jh}}=\frac{\partial\exp\left(-\frac{\sum_i(x_i-m_{ji})^2}{2s_j^2}\right)}{\partial m_{jh}}=h_j\frac{x_h-m_{jh}}{s_j^2} \qquad (5.8.7)$$

$$\Delta m_{jh}=\eta h_j\frac{x_h-m_{jh}}{s_j^2}\sum_k w_{kj}(t_k-y_k) \qquad (5.8.8)$$

RBF Network: Fully Supervised Method

- Similar to backpropagation in MLP

$$-\frac{\partial E_{MSE}}{\partial s_j} = -\frac{1}{2}\sum_k \frac{\partial (t_k - y_k)^2}{\partial s_j} \tag{5.8.9}$$

$$= \sum_k -\frac{1}{2}\frac{\partial (t_k - y_k)^2}{\partial y_k}\frac{\partial y_k}{\partial h_j}\frac{\partial h_j}{\partial s_j}$$

$$= \sum_k (t_k - y_k) w_{kj} \frac{\partial h_j}{\partial s_j}$$

$$\frac{\partial h_j}{\partial s_j} = \frac{\partial \exp\left(-\frac{\|\boldsymbol{x} - \boldsymbol{m}_j\|^2}{2s_j^2}\right)}{\partial s_j} = h_j \frac{\partial \left(-\frac{\|\boldsymbol{x} - \boldsymbol{m}_j\|^2}{2s_j^2}\right)}{\partial s_j} = h_j \frac{\|\boldsymbol{x} - \boldsymbol{m}_j\|^2}{s_j^3} \tag{5.8.10}$$

$$\Delta s_j = \eta h_j \frac{\|\boldsymbol{x} - \boldsymbol{m}_j\|^2}{s_j^3} \sum_k (t_k - y_k) w_{kj} \tag{5.8.11}$$