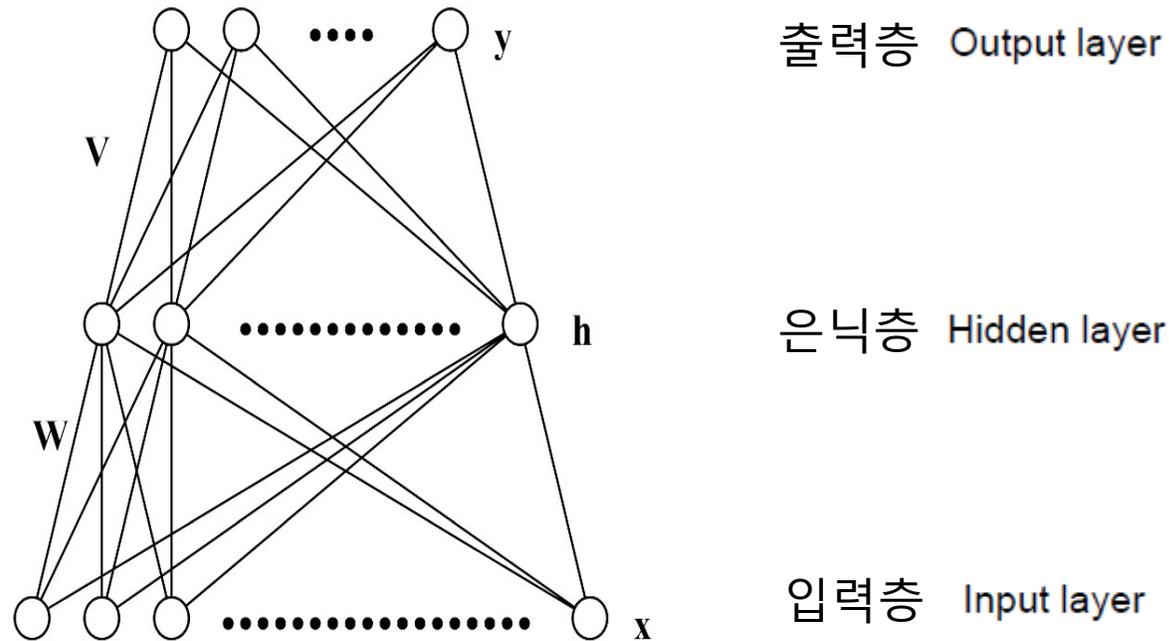


AI 실습

# Contents

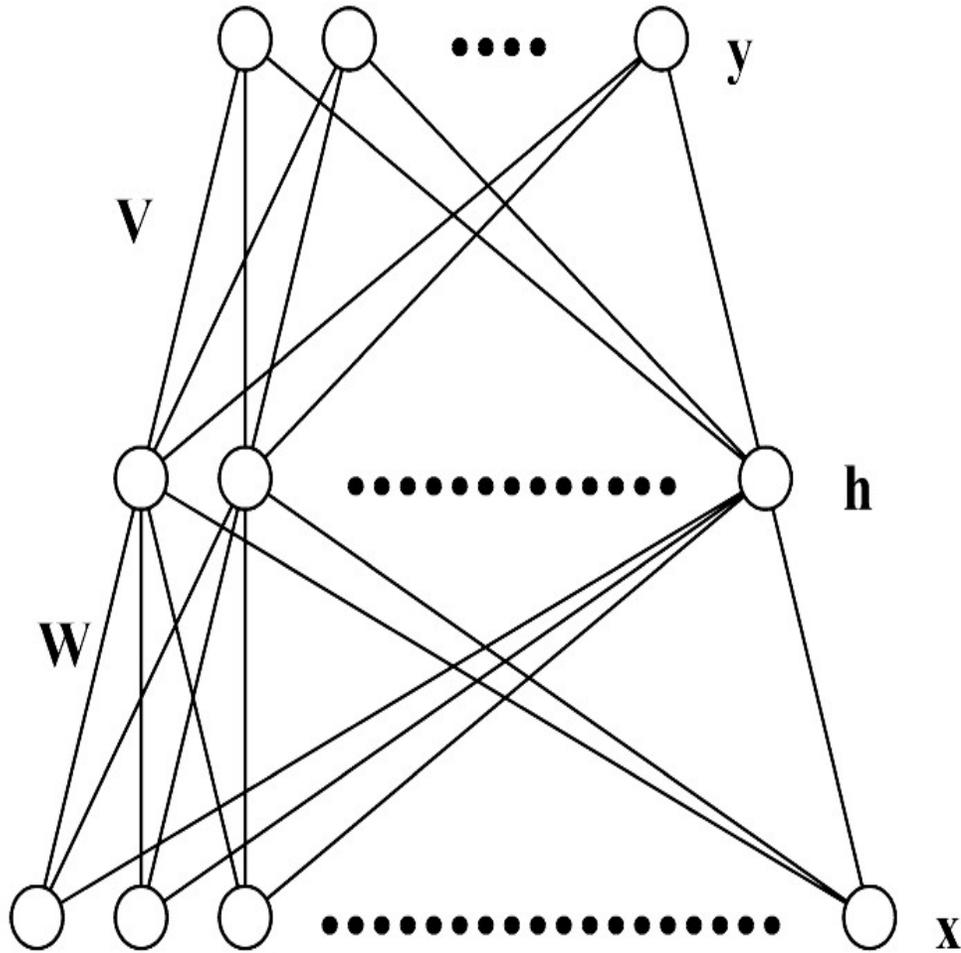
1. K-Nearest Neighbor Algorithm
2. Evaluation of Classifiers(인식기의 성능 평가)
3. Perceptron
4. **Feed-Forward Neural Networks: Multi-Layer Perceptron**

# 5.1. Multi-Layer Perceptron (MLP)



- Two-Layer Network (two-layer of weights)
- 전방향/순방향(Feed-forward) 구조: 전층에서 입력받아 다음 층으로 출력
- 출력층: 인식문제-시그모이드 활성화 함수, 회귀문제-선형 활성화 함수

# MLP 구조 (N-H-M): 전방향 전파(Forward Propagation)



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

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

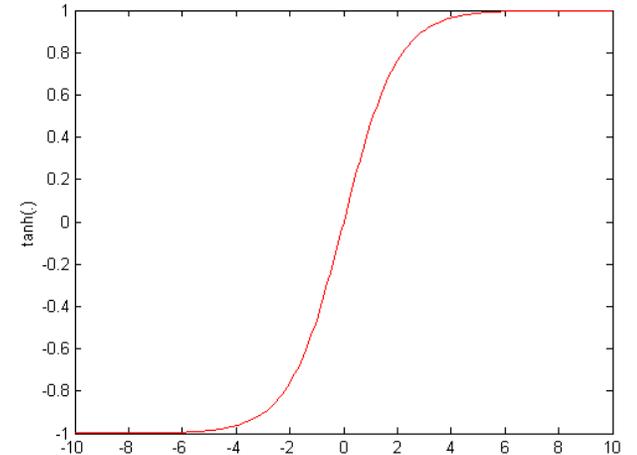
Output Nodes :  $\mathbf{y} = [y_1, y_2, \Lambda, y_M]^T$

Input  $\longrightarrow$  Output(?)

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

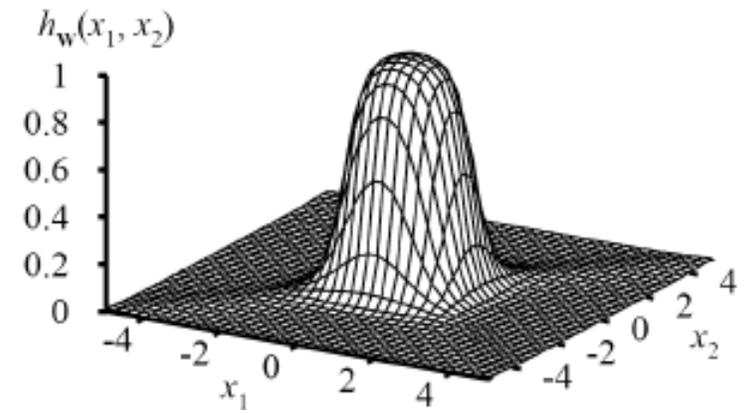
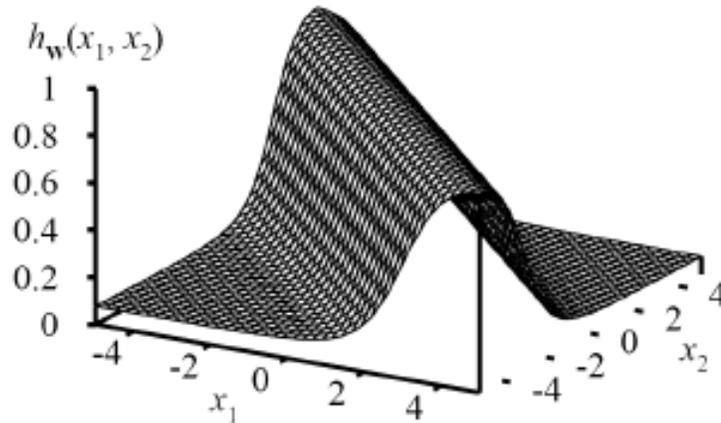
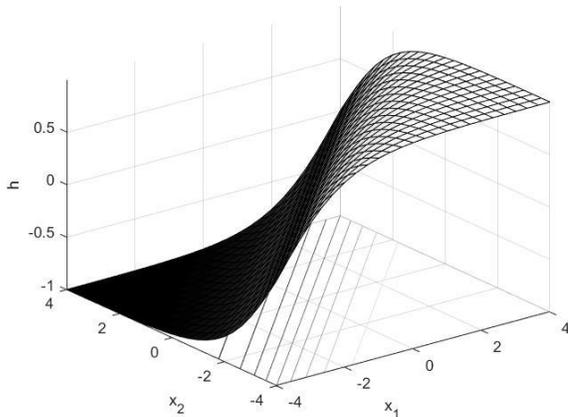
$$\text{where } \hat{h}_j = \sum_{i=1}^N w_{ji} x_i + w_{j0}$$

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



## 5.2. MLP의 표현능력

- 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



- 보편적 근사화 기계(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. 오류 역전파 학습(Error Back-Propagation Algorithm)

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

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

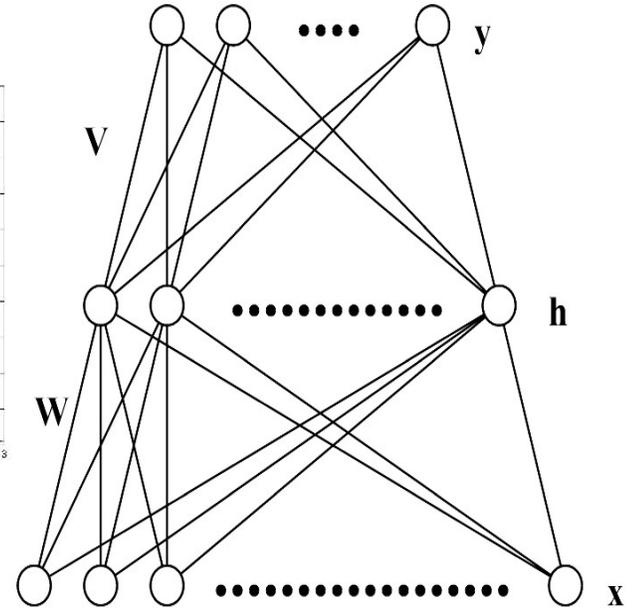
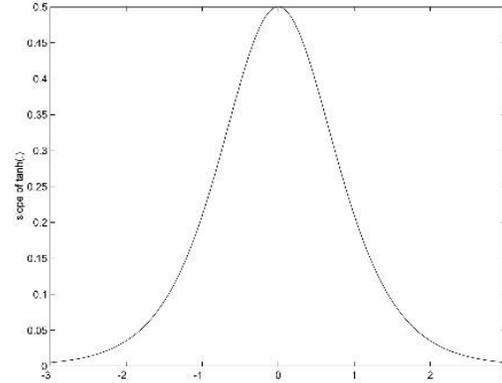
Desired Output Vector:  $\mathbf{t} = [t_1, t_2, \dots, t_M]^T$

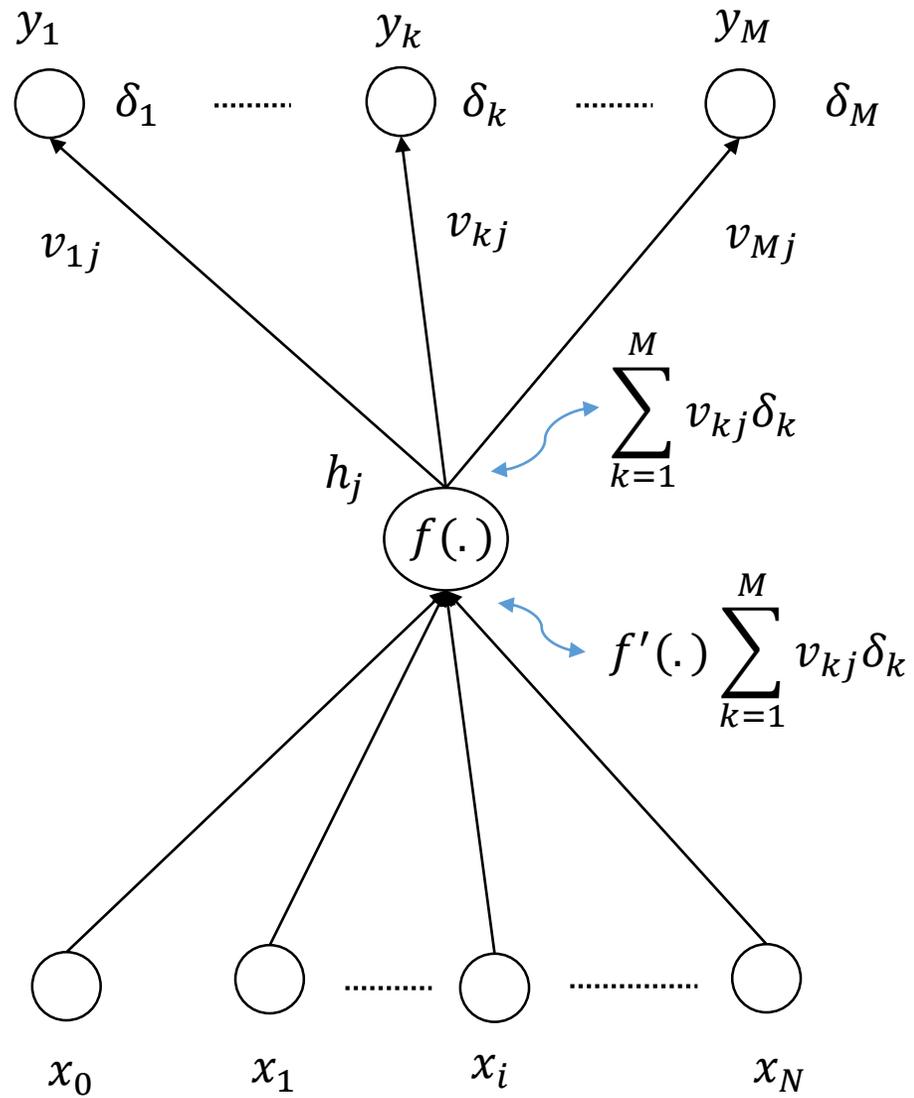
Mean-Squared Error Function:

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

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

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





# 실습(회귀)

```
from sklearn.datasets import fetch_california_housing
from sklearn.metrics import mean_squared_error
from sklearn.model_selection import train_test_split
from sklearn.neural_network import MLPRegressor
from sklearn.pipeline import make_pipeline
from sklearn.preprocessing import StandardScaler
```

```
housing=fetch_california_housing()
print(housing.DESCR)
```

## California Housing dataset

\*\*Data Set Characteristics:\*\*

:Number of Instances: 20640

:Number of Attributes: 8 numeric, predictive attributes and the target

:Attribute Information:

- MedInc median income in block
- HouseAge median house age in block
- AveRooms average number of rooms
- AveBedrms average number of bedrooms
- Population block population
- AveOccup average house occupancy
- Latitude house block latitude
- Longitude house block longitude

:Missing Attribute Values: None

This dataset was obtained from the StatLib repository.  
<http://lib.stat.cmu.edu/datasets/>

The target variable is the median house value for California districts.

This dataset was derived from the 1990 U.S. census, using one row per census block group. A block group is the smallest geographical unit for which the U.S. Census Bureau publishes sample data (a block group typically has a population of 800 to 3,000 people).

It can be downloaded/loaded using the  
:func:`sklearn.datasets.fetch\_california\_housing` function.

.. topic:: References

- Pace, R. Kelley and Ronald Barry, Sparse Spatial Autoregressions, Statistics and Probability Letters, 33 (1997) 291-297

O'REILLY

## 핸즈온 머신러닝 3판

Hands-On Machine Learning  
with Scikit-Learn,  
Keras & TensorFlow

사이킷런, 케라스, 텐서플로 2로 완벽 이해하는  
머신러닝, 딥러닝 이론 & 실무

powered by



MLPRegressor-10장-p385-3rdEd.py

# 실습

O'REILLY

## 핸즈온 머신러닝 3판

Hands-On Machine Learning  
with Scikit-Learn,  
Keras & TensorFlow

사이킷런, 케라스, 텐서플로 2로 완벽 이해하는  
머신러닝, 딥러닝 이론 & 실무

powered by



실용적인 머신러닝  
이론과 실무를  
이해하는 데  
필수적인  
이론과 실무를  
이해하는 데  
필수적인

오랜만에 다시  
출판된  
이론과 실무를  
이해하는 데  
필수적인

# sklearn.neural\_network.MLPRegressor

```
class sklearn.neural_network.MLPRegressor(hidden_layer_sizes=(100,), activation='relu', *, solver='adam', alpha=0.0001,  
batch_size='auto', learning_rate='constant', learning_rate_init=0.001, power_t=0.5, max_iter=200, shuffle=True, random_state=None,  
tol=0.0001, verbose=False, warm_start=False, momentum=0.9, nesterovs_momentum=True, early_stopping=False,  
validation_fraction=0.1, beta_1=0.9, beta_2=0.999, epsilon=1e-08, n_iter_no_change=10, max_fun=15000)
```

[source]

Multi-layer Perceptron regressor.

This model optimizes the squared error using LBFGS or stochastic gradient descent.

```
from sklearn.datasets import fetch_california_housing  
from sklearn.metrics import mean_squared_error  
from sklearn.model_selection import train_test_split  
from sklearn.neural_network import MLPRegressor  
from sklearn.pipeline import make_pipeline  
from sklearn.preprocessing import StandardScaler
```

```
housing=fetch_california_housing()  
print(housing.DESCR)  
X_train_full, X_test, y_train_full, y_test = train_test_split(housing.data, housing.target, random_state=42)  
X_train, X_valid, y_train, y_valid = train_test_split(X_train_full, y_train_full, random_state=42)
```

```
mlp_reg=MLPRegressor(hidden_layer_sizes=[50,50,50], random_state=42)  
pipeline=make_pipeline(StandardScaler(), mlp_reg)  
pipeline.fit(X_train, y_train)
```

```
y_pred=pipeline.predict(X_valid)  
rmse=mean_squared_error(y_valid, y_pred, squared=False)  
print(rmse)
```

0.5053326657968681

**activation** : {'identity', 'logistic', 'tanh', 'relu'}, default='relu'

Activation function for the hidden layer.

- 'identity', no-op activation, useful to implement linear bottleneck, returns  $f(x) = x$
- 'logistic', the logistic sigmoid function, returns  $f(x) = 1 / (1 + \exp(-x))$ .
- 'tanh', the hyperbolic tan function, returns  $f(x) = \tanh(x)$ .
- 'relu', the rectified linear unit function, returns  $f(x) = \max(0, x)$

# 실습(인식)



## 5-7c.py

```
#MNIST load (핸즈온머신러닝3rdEd. 방법 사용)
from sklearn.datasets import fetch_openml
mnist=fetch_openml('mnist_784',as_frame=False)
```

```
X,y=mnist.data,mnist.target
x_train, x_test, y_train, y_test = X[:60000], X[60000:], y[:60000], y[60000:]
```

```
#파이썬으로 만드는 인공지능 5-7.py 가져옴
import numpy as np
import tensorflow as tf
from tensorflow.keras.datasets import mnist
```

```
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense
from tensorflow.keras.optimizers import Adam
```

```
x_train=x_train.astype(np.float32)/255.0 # ndarray로 변환
x_test=x_test.astype(np.float32)/255.0
y_train=tf.keras.utils.to_categorical(y_train,10) # 원핫 코드로 변환
y_test=tf.keras.utils.to_categorical(y_test,10)
```

과도한 학습, 학습 곡선의 요동 관찰  
Learning rate=0.0005, 0.0001  
N\_hidden = 2000, 500

```
n_input=784
n_hidden=1024
n_output=10
```

```
mlp=Sequential()
mlp.add(Dense(units=n_hidden,activation='tanh',input_shape=(n_input,),kernel_initializer='random_uniform',bias_initializer='zeros'))
mlp.add(Dense(units=n_output,activation='tanh',kernel_initializer='random_uniform',bias_initializer='zeros'))
```

```
mlp.compile(loss='mean_squared_error',optimizer=Adam(learning_rate=0.001),metrics=['accuracy'])
hist=mlp.fit(x_train,y_train,batch_size=128,epochs=30,validation_data=(x_test,y_test),verbose=2)
```

```
res=mlp.evaluate(x_test,y_test,verbose=0)
print("정확률은",res[1]*100)
```

```
Epoch 1/30
469/469 - 8s - loss: 0.0422 - accuracy: 0.8474 - val_loss: 0.0271 - val_accuracy: 0.9117
Epoch 2/30
469/469 - 5s - loss: 0.0223 - accuracy: 0.9298 - val_loss: 0.0200 - val_accuracy: 0.9400
```

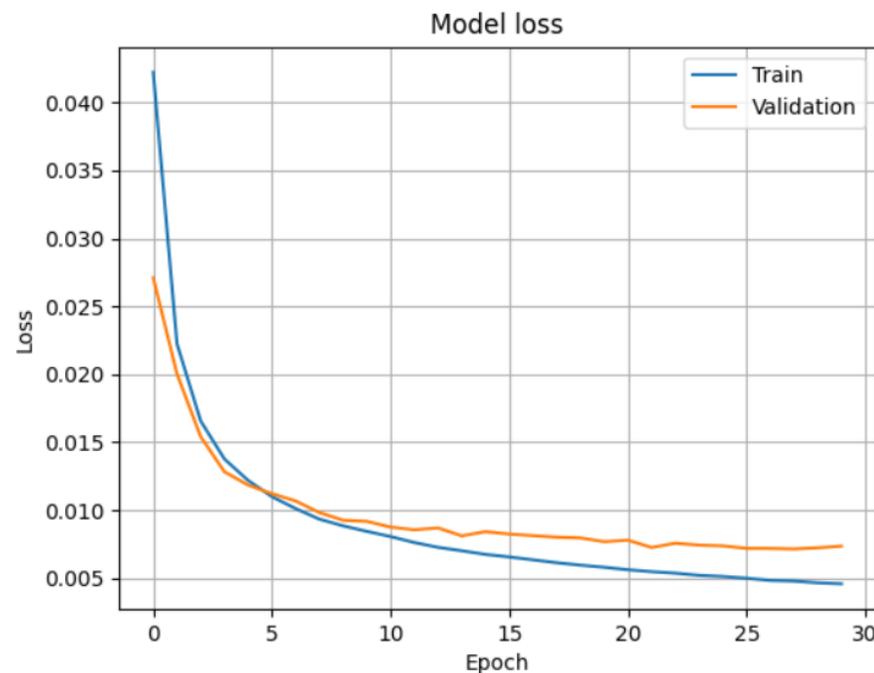
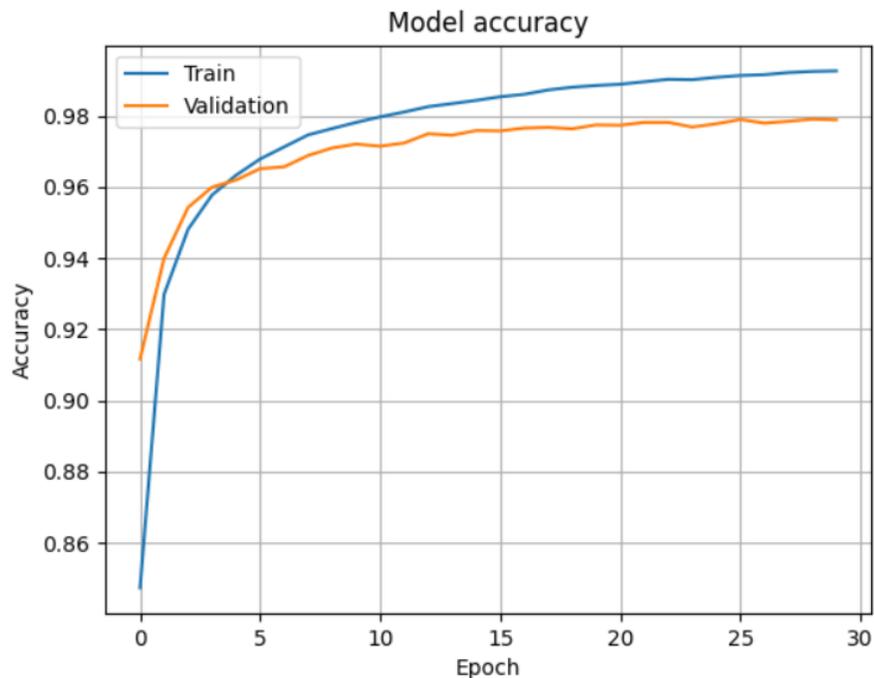
```
import matplotlib.pyplot as plt
```

```
# 정확률 곡선
```

```
plt.plot(hist.history['accuracy'])  
plt.plot(hist.history['val_accuracy'])  
plt.title('Model accuracy')  
plt.ylabel('Accuracy')  
plt.xlabel('Epoch')  
plt.legend(['Train', 'Validation'], loc='upper left')  
plt.grid()  
plt.show()
```

```
# 손실 함수 곡선
```

```
plt.plot(hist.history['loss'])  
plt.plot(hist.history['val_loss'])  
plt.title('Model loss')  
plt.ylabel('Loss')  
plt.xlabel('Epoch')  
plt.legend(['Train', 'Validation'], loc='upper right')  
plt.grid()  
plt.show()
```



## 5.4.3 fashion MNIST 인식

### ■ fashion MNIST 데이터셋

- MNIST와 비슷(28x28 입력크기, training sample 60,000, test sample 10,000)
- 내용이 패션 관련 그림이고 레이블이 {T-shirt/top, Trouser, Pullover, Dress, Coat, Sandal, Shirt, Sneaker, Bag, Ankle boot} 인 점만 다름



그림 5-7 fashion MNIST 데이터셋

# 실습(인식)



파이썬으로 만드는  
인공지능

인공지능

5-8b.py

```
import numpy as np
import tensorflow as tf
from tensorflow.keras.datasets import fashion_mnist

from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense
from tensorflow.keras.optimizers import Adam
import sys, os
sys.path.append(os.pardir) # 부모 디렉터리의 파일을 가져올 수 있도록 설정

path='dataset\MNISTfashion'
os.chdir(path)

# fashion MNIST 데이터셋을 읽어와 신경망에 입력할 형태로 변환
x_train = np.load('x_train.npy')
y_train = np.load('y_train.npy')
x_test = np.load('x_test.npy')
y_test = np.load('y_test.npy')
print(x_train.shape, y_train.shape, x_test.shape, y_test.shape)

x_train = x_train.reshape(60000,784) # 텐서 모양 변환
x_test = x_test.reshape(10000,784)
x_train=x_train.astype(np.float32)/255.0 # ndarray로 변환
x_test=x_test.astype(np.float32)/255.0
y_train=tf.keras.utils.to_categorical(y_train,10) # 원핫 코드로 변환
y_test=tf.keras.utils.to_categorical(y_test,10)

n_input=784
n_hidden=1024
n_output=10
```

```

mlp=Sequential()
mlp.add(Dense(units=n_hidden,activation='tanh',input_shape=(n_input,),kernel_initializer='random_uniform',bias_initializer='zeros'))
mlp.add(Dense(units=n_output,activation='tanh',kernel_initializer='random_uniform',bias_initializer='zeros'))

mlp.compile(loss='mean_squared_error',optimizer=Adam(learning_rate=0.001),metrics=['accuracy'])
hist=mlp.fit(x_train,y_train,batch_size=128,epochs=30,validation_data=(x_test,y_test),verbose=2)

```

```

res=mlp.evaluate(x_test,y_test,verbose=0)

```

```

print("정확률은",res[1]*100)
import matplotlib.pyplot as plt

```

```

# 정확률 곡선

```

```

plt.plot(hist.history['accuracy'])
plt.plot(hist.history['val_accuracy'])
plt.title('Model accuracy')
plt.ylabel('Accuracy')
plt.xlabel('Epoch')
plt.legend(['Train','Validation'], loc='upper left')
plt.grid()
plt.show()

```

```

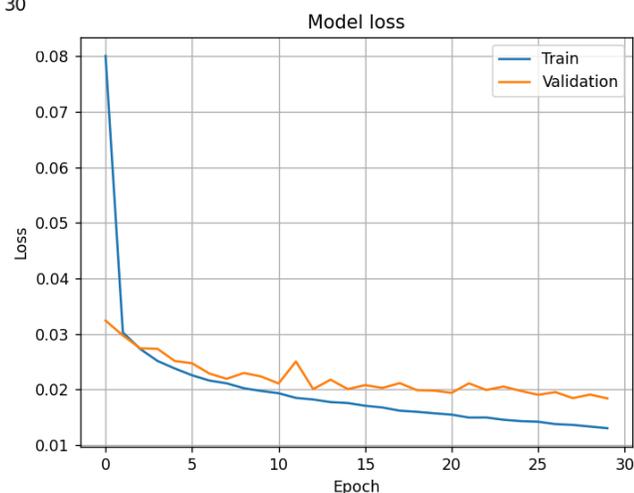
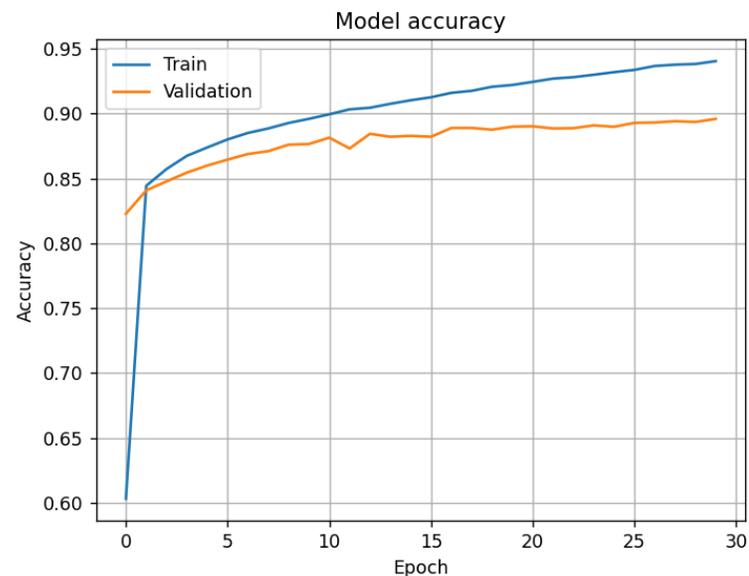
# 손실 함수 곡선

```

```

plt.plot(hist.history['loss'])
plt.plot(hist.history['val_loss'])
plt.title('Model loss')
plt.ylabel('Loss')
plt.xlabel('Epoch')
plt.legend(['Train','Validation'], loc='upper right')
plt.grid()
plt.show()

```

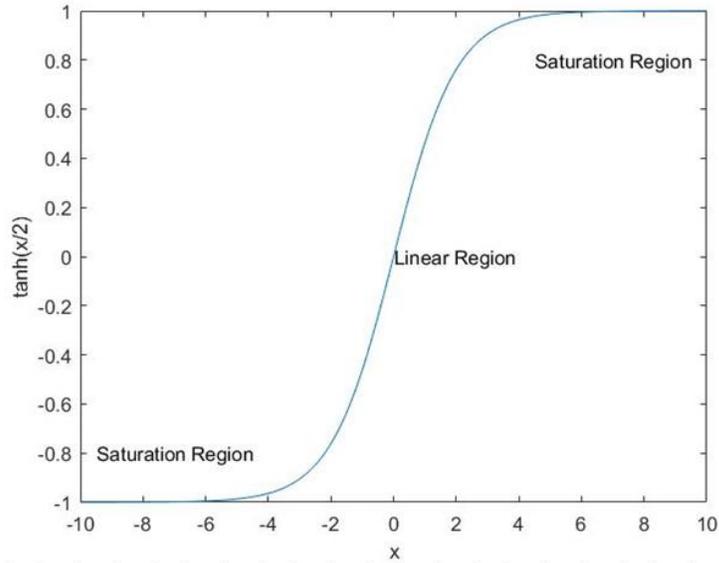


```

Epoch 30/30
469/469 - 12s - loss: 0.0130 - accuracy: 0.9405 - val_loss: 0.0184 - val_accuracy: 0.8960 - 12s/epoch - 26ms/step
정확률은 89.60000276565552

```

## 5.4. 부적절한 포화



$$\delta_k \equiv -\frac{\partial E_{MSE}}{\partial \hat{y}_k} = (t_k - y_k) f'(\hat{y}_k) \quad (5.3.4)$$

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  $\delta_k \approx 0$

# Error Back-Propagation Algorithm: 오차함수 비교

< 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 >

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

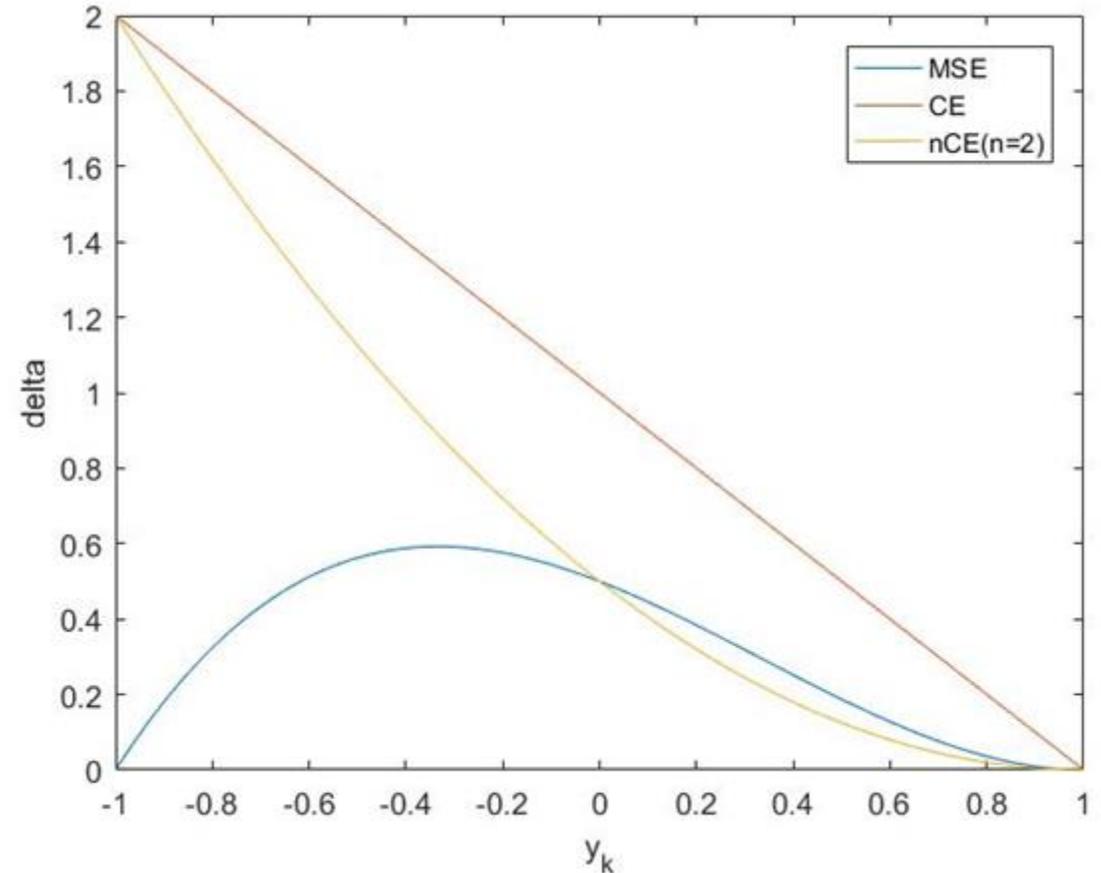
. Overspecialization Problem

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

< n-th order Extension of CE >

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

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

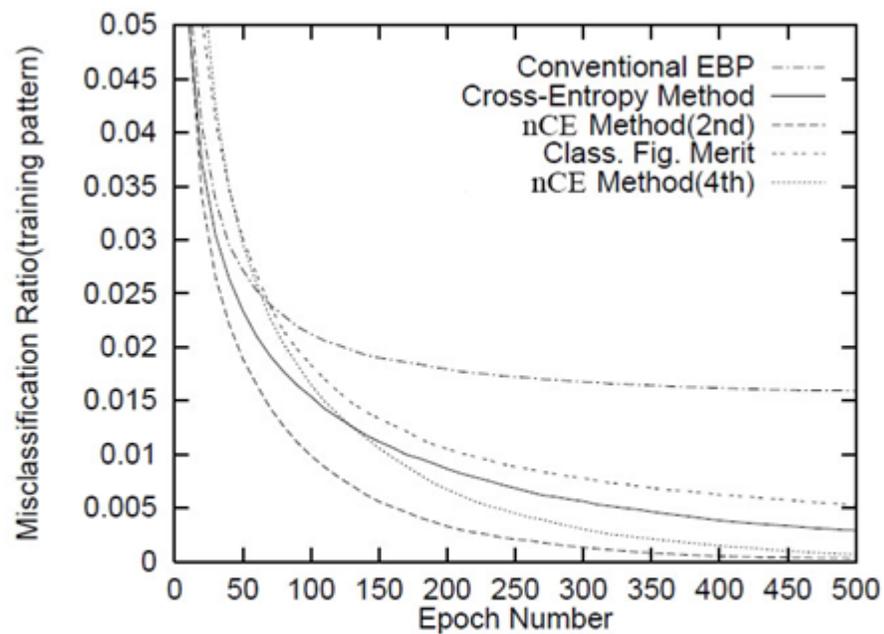


Plot of  $\delta_k^{out}(\mathbf{x}^{(p)})$  when  $t_k = 1$

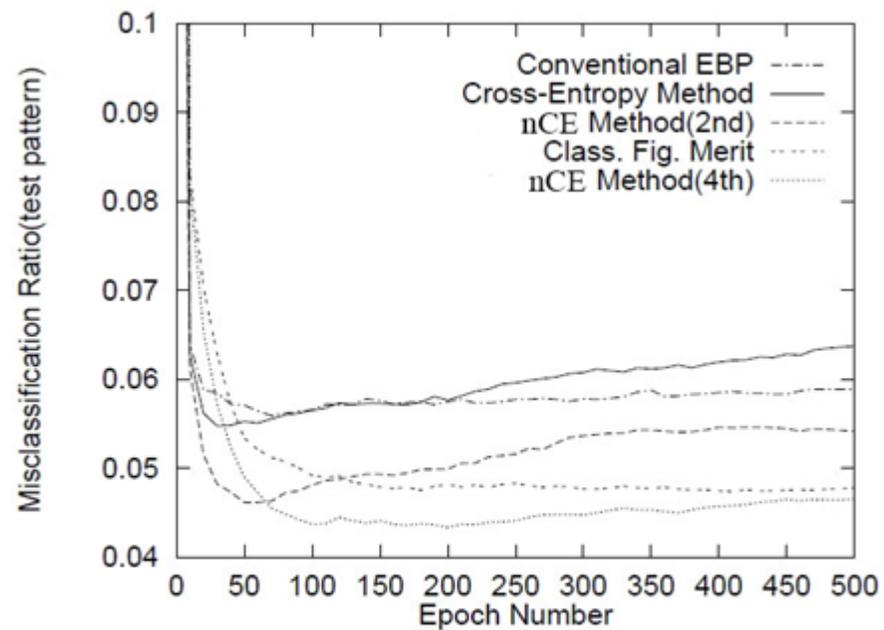
# Error Back-Propagation Algorithm

오류역전파(EBP) 알고리즘

- ① 다층퍼셉트론의 가중치들을 초기화 시킨다.
- ② 학습패턴  $x$ 가 주어지면, 전방향 계산에 의해 출력노드 값을 구한다.
- ③ 출력노드의 오류 신호  $\delta_k$ 를 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.



(a) 학습패턴에 대한 오인식률

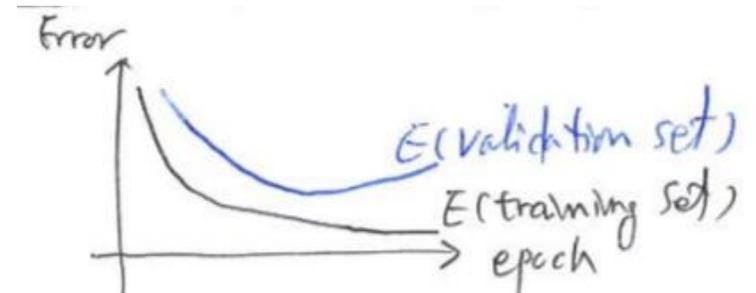


(b) 시험패턴에 대한 오인식률

그림 5.7. 필기체 숫자인식 문제의 학습 시뮬레이션 결과

## 5.5. 학습에 필요한 사항들

- 수렴(Convergence)(?)... 오차가 진동하거나 국소 최소(local minima)에 도달.
- 데이터의 구분
  - 학습데이터: 신경회로망의 파라미터를 학습에 의해 변경시킴
  - 검증데이터: 학습에 따른 성능 향상 정도를 파악하여 학습이 잘 된 모델을 선정하는 기준으로 사용
  - 시험데이터: 학습 과정 혹은 종료 및 학습이 잘 된 모델 선정에 관여하지 않으며 성능 조사만 수행함
- 초기 가중치의 범위 설정:
  - 작게...혹은 가중치 초기화 방법 사용(조기포화 현상 방지)
- 학습종료 조건:
  - 지정된 epochs 동안 학습시키고 종료
  - 학습데이터에 대한 오차의 문턱값 보다 낮아지면 학습 종료
  - 검증데이터에 대한 오차의 증가 시 학습종료
- 성능 좋은 결과
  - 초기 가중치를 달리 하면서 여러 번 학습 시도
  - 학습데이터 혹은 검증데이터에 대한 성능이 가장 좋은 결과를 취득
  - 앙상블 학습 (8장)



# Online, Batch and Learning with Momentum

- **Online:**

- 학습데이터를 하나씩 입력하면서 가중치 변경

- **Batch:**

- 학습데이터를 입력하면서 가중치 변경량을 계산하여 모든 학습데이터에 대한 변경량을 다 더한 후 이들의 평균으로 가중치를 변경...mini-batch

- **Momentum factor:**

- 현재 가중치 변경 시 이전 변경량을 반영함
- 학습에 의한 가중치벡터 변경 방향이 일관성이 있게 하여 학습 속도 개선

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

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

# 5.7. 심층 신경회로망(Deep Neural Networks)

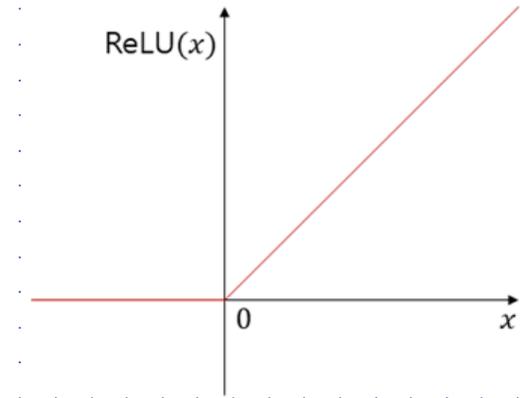
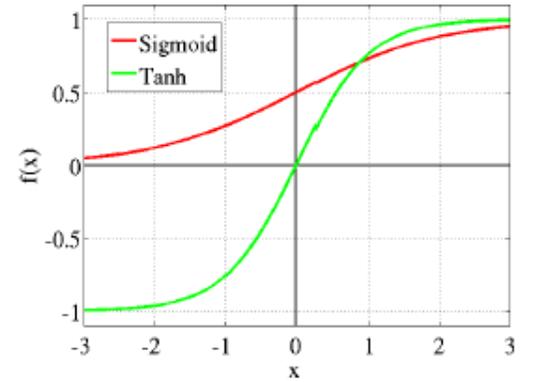
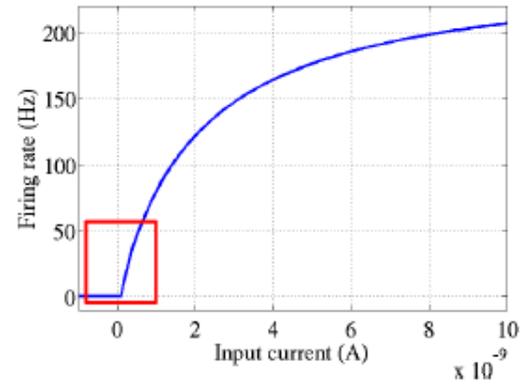
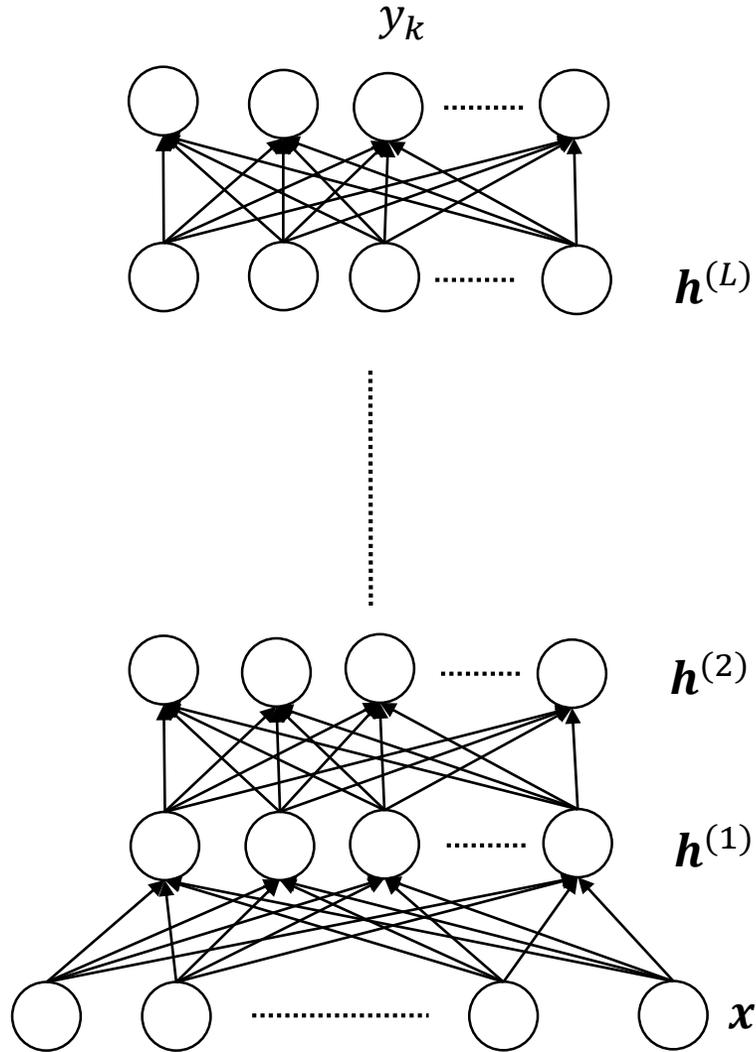
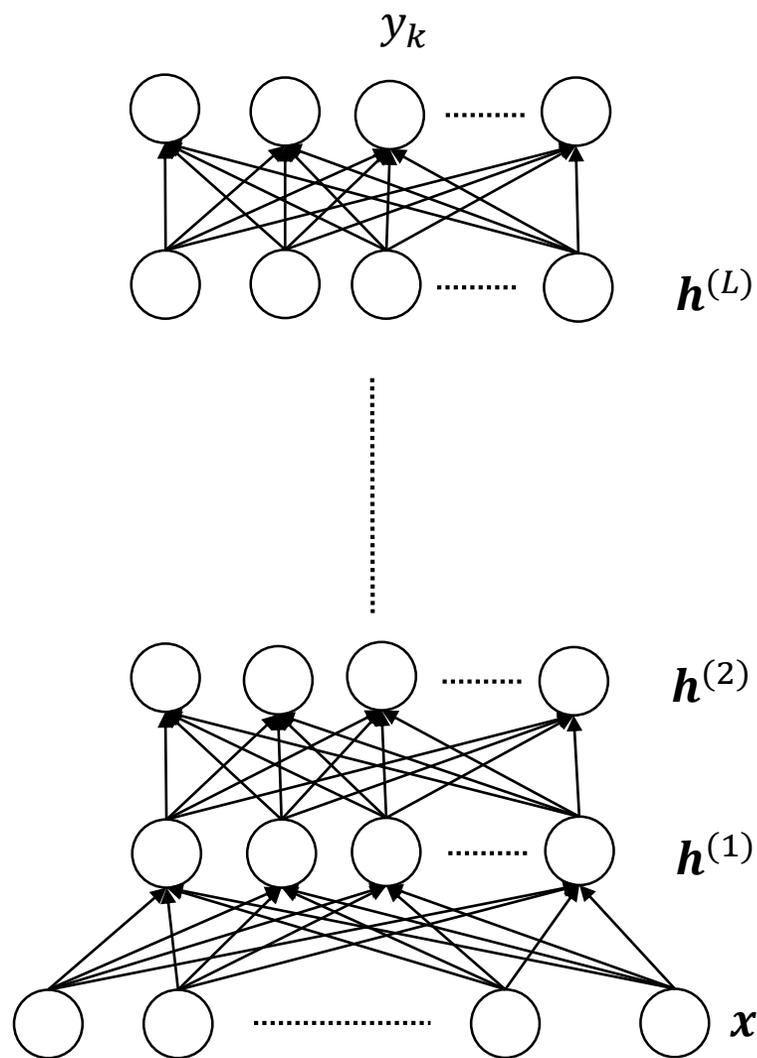


그림 5.10. ReLU 활성화 함수



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

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

$$y_k = \frac{e^{\hat{y}_k}}{\sum_j e^{\hat{y}_j}} \quad (5.7.3)$$

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

$$\frac{\partial y_k}{\partial \hat{y}_j} = \begin{cases} y_k(1 - y_k) & \text{if } j = k \\ -y_k y_j & \text{otherwise} \end{cases} \quad (5.7.5)$$

$$\frac{\partial E_{CE}}{\partial \hat{y}_k} = y_k - t_k \quad (5.7.6)$$

$$\delta_k = - \frac{\partial E_{CE}}{\partial \hat{y}_k} = t_k - y_k \quad (5.7.7)$$

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

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

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

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

와 같이 표현할 수 있다. 여기서,  $\mathbf{1}$ 은 지시함수(indicator function)로써 1과 0을 출력한다. GELU는 지시함수 대신에 평균  $\mu$ 이 0이고 표준편차  $\sigma$ 가 1인 Gaussian 확률변수의 CDF(Cumulative Distribution Function)  $\Phi(x)$ 을 사용하여

$$\text{GELU}(x) = x\Phi(x) = x \frac{1}{2} [1 + \text{erf}(x/\sqrt{2})] \quad (5.7.33)$$

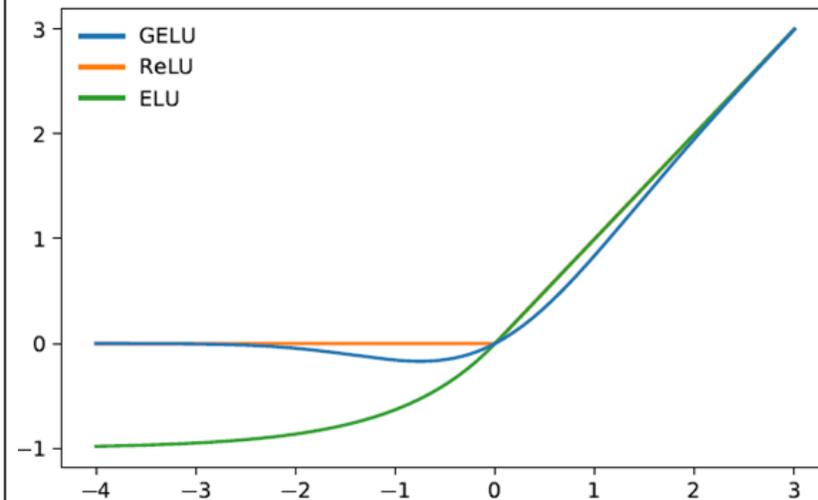
와 같이 주어진다. 여기서,  $\Phi(x)$ 는 erf(error function)으로 계산할 수 있다. GELU의 정확한 값 계산보다 계산 속도를 중시하면

$$\text{GELU}(x) \approx 0.5x(1 + \tanh[\sqrt{2/\pi}(x + 0.044715x^3)]) \quad (5.7.34)$$

혹은

$$\text{GELU}(x) \approx x\sigma(1.702x) \quad (5.7.35)$$

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



GELU는 ReLU를 매끄러운 모양으로 만든 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.  $h_j^{(l)}$  ( $l = 1, 2, \dots, L$ )과 아래층 사이의 연결 가중치를  $w_{ji}^{(l)}$  ( $l = 1, 2, \dots, L$ )이라 하고 마지막층 출력노드  $y_k$ 와 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.

# 실습(인식)



5-9c.py

```
#MNIST load (핸즈온머신러닝3rdEd. 방법 사용)
from sklearn.datasets import fetch_openml
mnist=fetch_openml('mnist_784',as_frame=False)
```

```
X,y=mnist.data,mnist.target
x_train, x_test, y_train, y_test = X[:60000], X[60000:], y[:60000], y[60000:]
```

```
# 숫자 그리기 기능 추가
```

```
from PIL import Image
import numpy as np
def img_show(img):
    pil_img = Image.fromarray(np.uint8(img))
    pil_img.show()
```

```
img = x_train[0]
label = y_train[0]
print(label) # 5
print(img.shape) # (784,)
img = img.reshape(28, 28) # 형상을 원래 이미지의 크기로 변형
print(img.shape) # (28, 28)
img_show(img)
```

```
#파이썬으로 만드는 인공지능 5-9.py 가져옴
```

```
import numpy as np
import tensorflow as tf
from tensorflow.keras.datasets import mnist
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense
from tensorflow.keras.optimizers import Adam
```

```
x_train=x_train.astype(np.float32)/255.0 # ndarray로 변환
x_test=x_test.astype(np.float32)/255.0
y_train=tf.keras.utils.to_categorical(y_train,10) # 원핫 코드로 변환
y_test=tf.keras.utils.to_categorical(y_test,10)
```

```
# 신경망 구조 설정
```

```
n_input=784
n_hidden1=1024
n_hidden2=512
n_hidden3=512
n_hidden4=512
n_output=10
```

### # 신경망 구조 설계

```
mlp=Sequential()  
mlp.add(Dense(units=n_hidden1,activation='tanh',input_shape=(n_input,),kernel_initializer='random_uniform',bias_initializer='zeros'))  
mlp.add(Dense(units=n_hidden2,activation='tanh',kernel_initializer='random_uniform',bias_initializer='zeros'))  
mlp.add(Dense(units=n_hidden3,activation='tanh',kernel_initializer='random_uniform',bias_initializer='zeros'))  
mlp.add(Dense(units=n_hidden4,activation='tanh',kernel_initializer='random_uniform',bias_initializer='zeros'))  
mlp.add(Dense(units=n_output,activation='tanh',kernel_initializer='random_uniform',bias_initializer='zeros'))
```

### # 신경망 학습

```
mlp.compile(loss='mean_squared_error',optimizer=Adam(learning_rate=0.00005),metrics=['accuracy'])  
hist=mlp.fit(x_train,y_train,batch_size=128,epochs=20,validation_data=(x_test,y_test),verbose=2)
```

### # 신경망의 정확률 측정

```
res=mlp.evaluate(x_test,y_test,verbose=0)  
print("정확률은",res[1]*100)
```

```
import matplotlib.pyplot as plt
```

### # 정확률 곡선

```
plt.plot(hist.history['accuracy'])  
plt.plot(hist.history['val_accuracy'])  
plt.title('Model accuracy')  
plt.ylabel('Accuracy')  
plt.xlabel('Epoch')  
plt.legend(['Train','Validation'],loc='upper left')  
plt.grid()  
plt.show()
```

### # 손실 함수 곡선

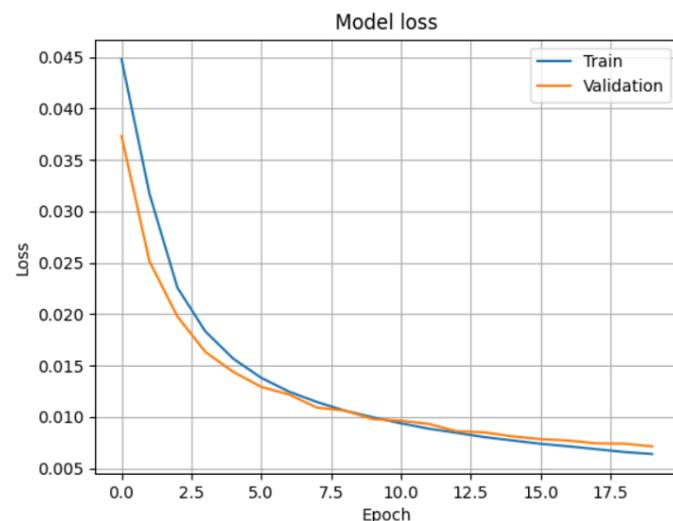
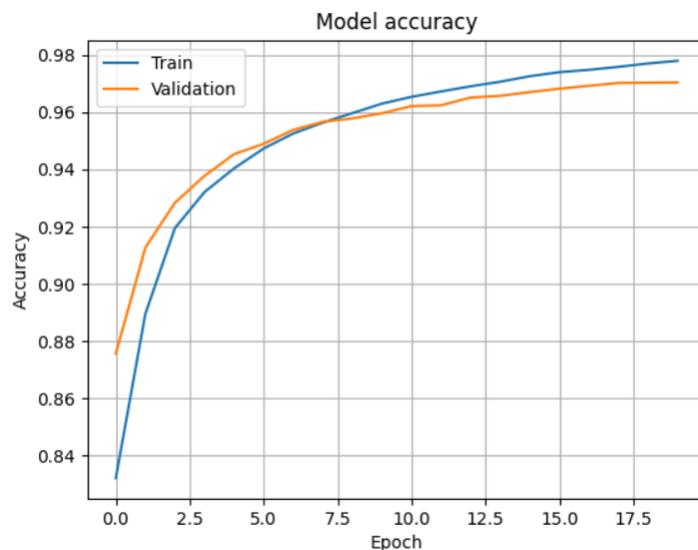
```
plt.plot(hist.history['loss'])  
plt.plot(hist.history['val_loss'])  
plt.title('Model loss')  
plt.ylabel('Loss')  
plt.xlabel('Epoch')  
plt.legend(['Train','Validation'],loc='upper right')  
plt.grid()  
plt.show()
```

Epoch 20/20

469/469 - 20s - loss: 0.0064 - accuracy: 0.9781 - val\_loss: 0.0071 - val\_accuac

y: 0.9705

정확률은 97.04999923706055



# 실습(인식)



파이썬으로 만드는  
인공지능

이것이 인공지능이다

인공지능이 뭐예요?

5-10c.py

```
#MNIST load (핸즈온머신러닝3rdEd. 방법 사용)
from sklearn.datasets import fetch_openml
mnist=fetch_openml('mnist_784',as_frame=False)
```

```
X,y=mnist.data,mnist.target
x_train, x_test, y_train, y_test = X[:60000], X[60000:], y[:60000], y[60000:]
```

```
#파이썬으로 만드는 인공지능 5-10.py 가져옴
```

```
import numpy as np
import tensorflow as tf
from tensorflow.keras.datasets import mnist
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense
from tensorflow.keras.optimizers import Adam
```

```
x_train=x_train.astype(np.float32)/255.0 # ndarray로 변환
x_test=x_test.astype(np.float32)/255.0
y_train=tf.keras.utils.to_categorical(y_train,10) # 원핫 코드로 변환
y_test=tf.keras.utils.to_categorical(y_test,10)
```

```
# 신경망 구조 설정
```

```
n_input=784
n_hidden1=1024
n_hidden2=512
n_hidden3=512
n_hidden4=512
n_output=10
```

### # 평균제곱오차를 사용한 모델

```
dmlp_mse=Sequential()  
dmlp_mse.add(Dense(units=n_hidden1,activation='tanh',input_shape=(n_input,)))  
dmlp_mse.add(Dense(units=n_hidden2,activation='tanh'))  
dmlp_mse.add(Dense(units=n_hidden3,activation='tanh'))  
dmlp_mse.add(Dense(units=n_hidden4,activation='tanh'))  
dmlp_mse.add(Dense(units=n_output,activation='softmax'))  
dmlp_mse.compile(loss='mean_squared_error',optimizer=Adam(learning_rate=0.0001),metrics=['accuracy'])  
hist_mse=dmlp_mse.fit(x_train,y_train,batch_size=128,epochs=30,validation_data=(x_test,y_test),verbose=2)
```

### # 교차 엔트로피를 사용한 모델

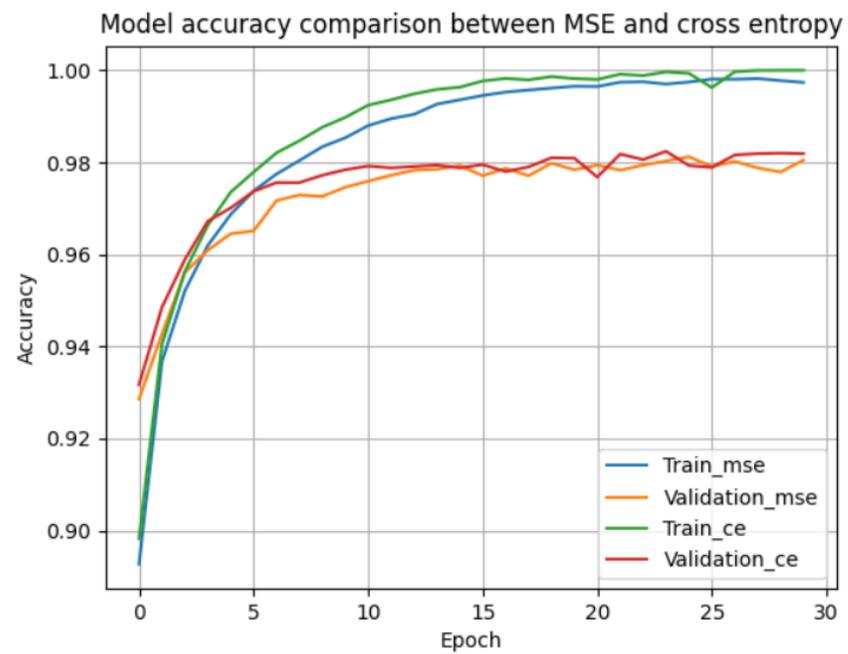
```
dmlp_ce=Sequential()  
dmlp_ce.add(Dense(units=n_hidden1,activation='tanh',input_shape=(n_input,)))  
dmlp_ce.add(Dense(units=n_hidden2,activation='tanh'))  
dmlp_ce.add(Dense(units=n_hidden3,activation='tanh'))  
dmlp_ce.add(Dense(units=n_hidden4,activation='tanh'))  
dmlp_ce.add(Dense(units=n_output,activation='softmax'))  
dmlp_ce.compile(loss='categorical_crossentropy',optimizer=Adam(learning_rate=0.0001),metrics=['accuracy'])  
hist_ce=dmlp_ce.fit(x_train,y_train,batch_size=128,epochs=30,validation_data=(x_test,y_test),verbose=2)
```

### # 두 모델의 정확도를 비교

```
res_mse=dmlp_mse.evaluate(x_test,y_test,verbose=0)  
print("평균제곱오차의 정확률은",res_mse[1]*100)  
res_ce=dmlp_ce.evaluate(x_test,y_test,verbose=0)  
print("교차 엔트로피의 정확률은",res_ce[1]*100)
```

### # 하나의 그래프에서 두 모델을 비교

```
import matplotlib.pyplot as plt  
plt.plot(hist_mse.history['accuracy'])  
plt.plot(hist_mse.history['val_accuracy'])  
plt.plot(hist_ce.history['accuracy'])  
plt.plot(hist_ce.history['val_accuracy'])  
plt.title('Model accuracy comparison between MSE and cross entropy')  
plt.ylabel('Accuracy')  
plt.xlabel('Epoch')  
plt.legend(['Train_mse','Validation_mse','Train_ce','Validation_ce'],loc='best')  
plt.grid()  
plt.show()
```



평균제곱오차의 정확률은 98.04999828338623  
교차 엔트로피의 정확률은 98.18999767303467