

딥러닝 개요 및 Feedforward neural networks

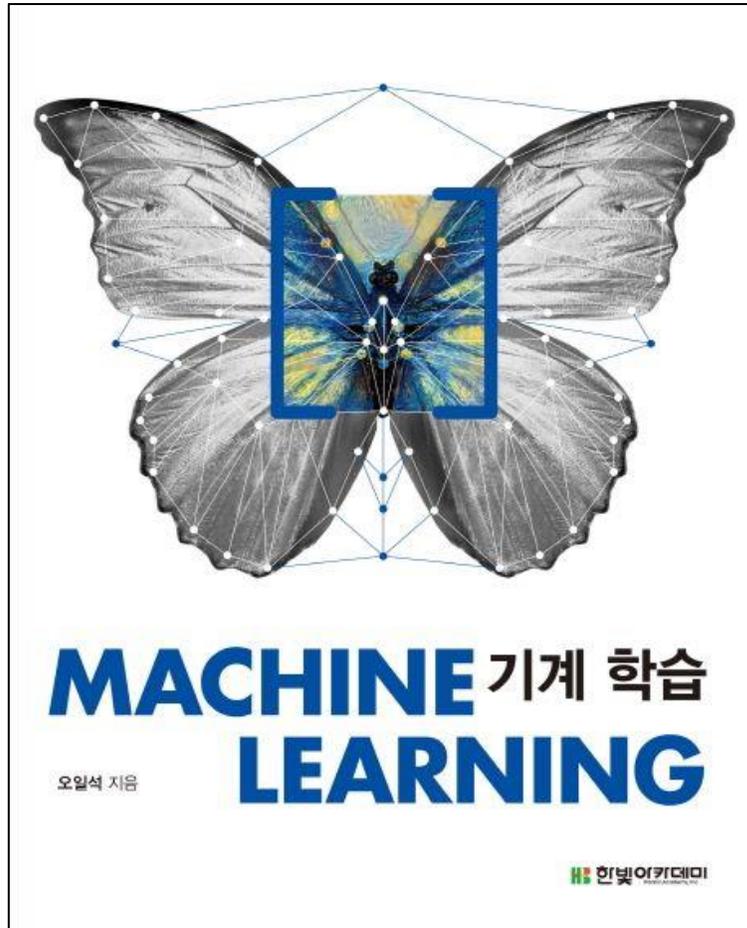
2024. 09. 02. - 09. 03.

컴퓨터비전연구실 서다솜

이 강의 자료는 <기계학습>(오일석 저, 한빛아카데미 2017)과 <파이썬으로 만드는 인공지능> (오일석,이진선 저, 한빛아카데미, 2021)의 내용을 인공지능 심화 교육에 맞게 발췌하고 정리한 것입니다.

전체 내용은 <http://cv.jbnu.ac.kr/>에서 받아볼 수 있습니다.

강의 동영상은 <https://bit.ly/2VJ1sgY>에 있습니다.



Artificial Intelligence

인공지능

사고나 학습 등 인간이 가진 지적 능력을 컴퓨터를 통해 구현하는 기술



Machine Learning

머신러닝

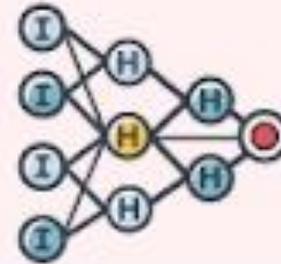
컴퓨터가 스스로 학습하여 인공지능의 성능을 향상 시키는 기술 방법



Deep Learning

딥러닝

인간의 뉴런과 비슷한 인공신경망 방식으로 정보를 처리



1.1.1 기계 학습의 정의

■ 학습이란? 〈표준국어대사전〉

“경험의 결과로 나타나는, 비교적 지속적인 행동의 변화나 그 잠재력의 변화. 또는 지식을 습득하는 과정[국립국어원2017]”

■ 기계 학습이란?

■ 인공지능 초창기 사무엘의 정의

“Programming computers to learn from experience should eventually eliminate the need for much of this detailed programming effort. 컴퓨터가 경험을 통해 학습할 수 있도록 프로그래밍할 수 있다면, 세세하게 프로그래밍해야 하는 번거로움에서 벗어날 수 있다[Samuel1959].”

1.1.1 기계 학습의 정의

■ 기계 학습이란?

▪ 현대적 정의

“A computer program is said to learn from experience E with respect to some class of tasks T and performance measure P , if its performance at tasks in T , as measured by P , improves with experience E . 어떤 컴퓨터 프로그램이 T 라는 작업을 수행한다. 이 프로그램의 성능을 P 라는 척도로 평가했을 때 경험 E 를 통해 성능이 개선된다면 이 프로그램은 학습을 한다고 말할 수 있다[Mitchell1997(2쪽)].”

“Programming computers to optimize a performance criterion using example data or past experience 사례 데이터, 즉 과거 경험을 이용하여 성능 기준을 최적화하도록 프로그래밍하는 작업[Alpaydin2010]”

“Computational methods using experience to improve performance or to make accurate predictions 성능을 개선하거나 정확하게 예측하기 위해 경험을 이용하는 계산학 방법들[Mohri2012]”

1.1.2 지식기반 방식에서 기계 학습으로의 대전환

■ 인공지능의 탄생

- 컴퓨터의 뛰어난 능력
 - 사람이 어려워하는 일을 아주 쉽게 함
 - $80932.46789076 * 0.39001324$ 와 같은 곱셈을 고속으로 수행(현재는 초당 수십억개)
 - 복잡한 함수의 미분과 적분 척척
- 컴퓨터에 대한 기대감 (컴퓨터의 능력 과신)
 - 사람이 쉽게 하는 일, 예를 들어 고양이/개 구별하는 일도 잘 하지 않을까
 - 1950년대에 인공지능이라는 분야 등장

■ 초창기는 지식기반 방식이 주류

- 예) “구멍이 2개이고 중간 부분이 홀쭉하며, 맨 위와 아래가 둥근 모양이라면 8이다”

1.1.2 지식기반 방식에서 기계 학습으로의 대전환

■ 큰 깨달음

- 지식기반(규칙기반)의 한계
- 단추를 “가운데 구멍이 몇 개 있는 물체”라고 규정하면 많은 오류 발생



그림 1-2 인식 시스템이 대처해야 하는 심한 변화 양상(8과 단추리는 패턴을 어떻게 기술할 것인가?)

- 사람은 변화가 심한 장면을 아주 쉽게 인식하지만, 왜 그렇게 인식하는지 서술하지는 못함

1.1.2 지식기반 방식에서 기계 학습으로의 대전환

■ 인공지능의 주도권 전환

- 지식기반(규칙 기반) → 기계 학습
- 기계 학습: 데이터 중심 접근방식



그림 1-3 기계 학습으로 만든 최첨단 인공지능 제품들

■ 인공지능, 기계 학습, 신경망, 딥러닝의 관계

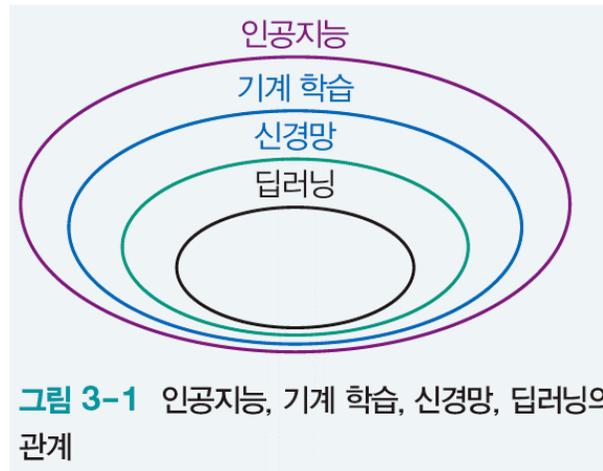


그림 3-1 인공지능, 기계 학습, 신경망, 딥러닝의 관계

3.2.2 규칙 기반 vs. 고전적 기계 학습 vs. 딥러닝

■ 규칙 기반 방법

- 분류하는 규칙을 사람이 구현. 예) “꽃잎의 길이가 a보다 크고, 꽃잎의 너비가 b보다 작으면 Setosa”라는 규칙에서 a와 b를 사람이 결정해 줌
- 큰 데이터셋에서는 불가능하고, 데이터가 바뀌면 처음부터 새로 작업해야 하는 비효율성

■ 기계 학습 방법

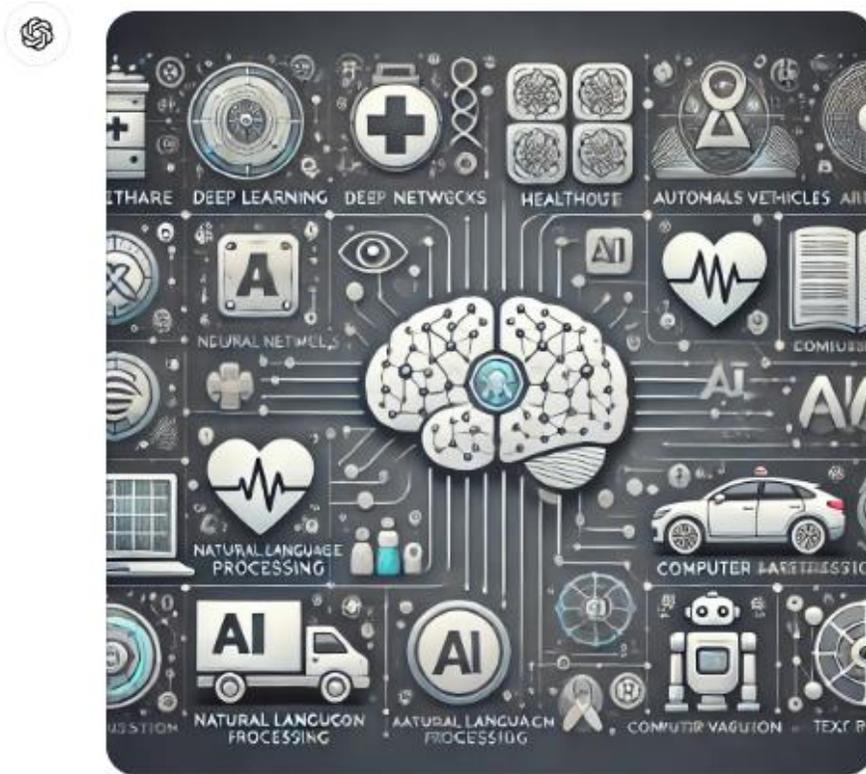
- 특징 벡터를 추출하고 레이블을 붙이는 과정은 규칙 기반과 동일(수작업 특징 hand-crafted feature)
- 규칙 만드는 일은 기계학습 모델을 이용하여 자동으로 수행(이 책의 3~4장)

■ 딥러닝 방법

- 레이블을 붙이는 과정은 기계 학습과 동일
- 특징 벡터를 학습이 자동으로 알아냄. 특징 학습 feature learning 또는 표현 학습 representation learning 을 한다고 말함
- 장점
 - 특징 추출과 분류를 동시에 최적화하므로 뛰어난 성능 보장
 - 인공지능 제품 제작이 빠름
- 이 책의 5장 이후

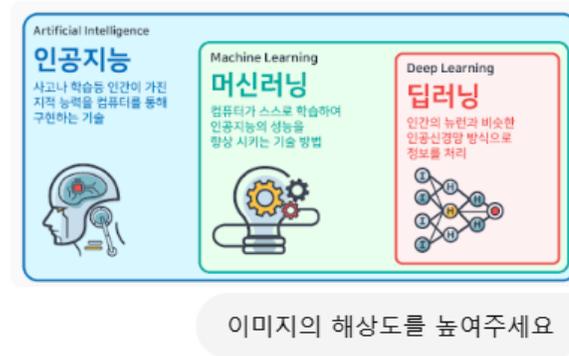
딥러닝의 주요 응용 분야

딥러닝의 주요 응용분야를 소개하는 이미지를 만들어주세요



여기 딥러닝의 주요 응용 분야를 소개하는 이미지를 만들어보았습니다. 이미지는 의료, 자율주행, 자연어 처리, 컴퓨터 비전, 로봇틱스 등 다양한 응용 분야가 포함되어 있습니다. 이 이미지는 딥러닝의 다양한 적용 사례를 한눈에 이해할 수 있도록 디자인되었습니다.

딥러닝의 주요 응용 분야

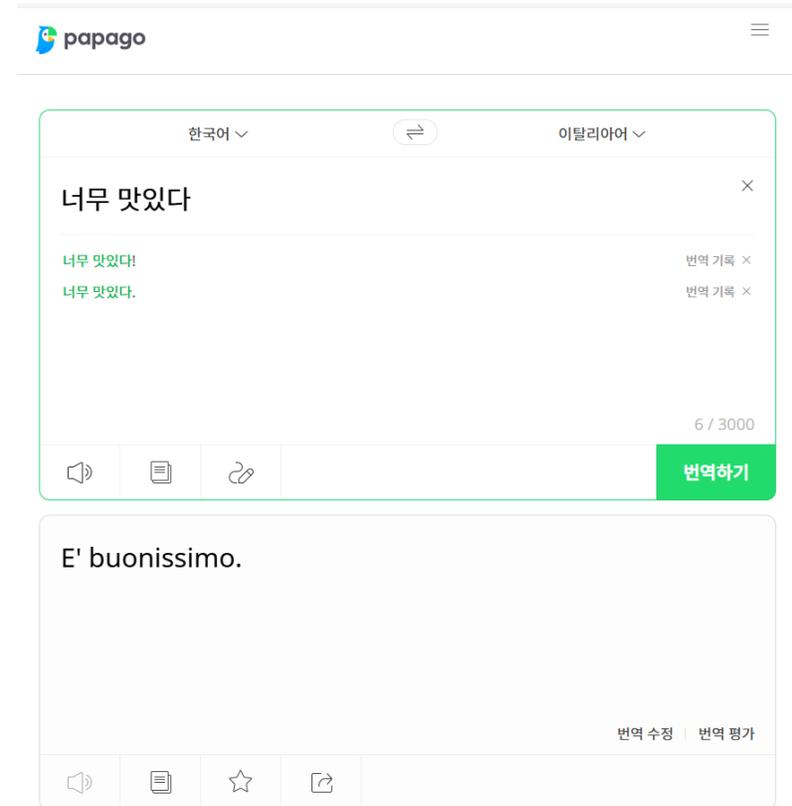


 해상도를 높인 이미지를 아래 링크에서 다운로드하실 수 있습니다:

[해상도가 높은 이미지 다운로드 \[~\]](#)

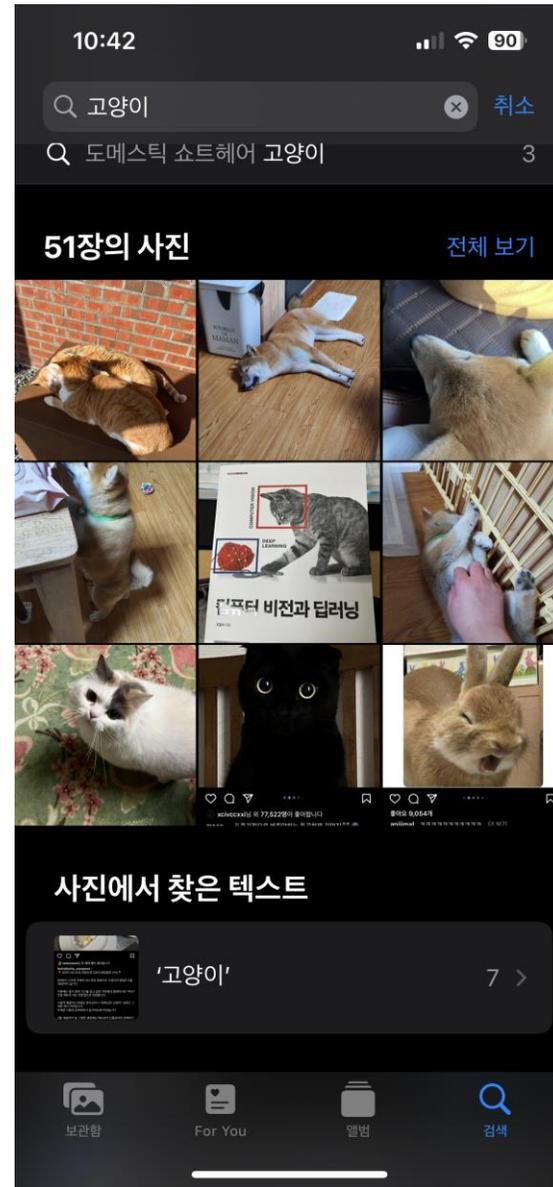


Hyper-resolution



기계 번역

딥러닝의 주요 응용 분야



딥러닝의 주요 응용 분야



3.2 인공지능 제품의 설계와 구현

■ [프로그램 3-1]은 인공지능 제품의 핵심

- 데이터를 읽고 모델링과 예측을 수행
- 붓꽃 영상을 획득하고 특징을 추출하는 컴퓨터 비전 모듈을 전처리로 붙이면 붓꽃 인식 프로그램 완성



(a) 인공지능이 인식할 붓꽃



(b) 과일의 등급 인식 인공지능



(c) 딸기 따는 로봇

그림 3-4 인공지능 제품

■ 실용적인 시스템 사례

- 과일 등급 분류([그림 3-4(b)])
- 딸기 따는 로봇([그림 3-4(c)])
- 모두 [프로그램 3-1]의 과정을 따름

1.1.3 기계 학습 개념

■ 간단한 기계 학습 예제

- 가로축은 시간, 세로축은 이동체의 위치
- 관측한 4개의 점이 데이터

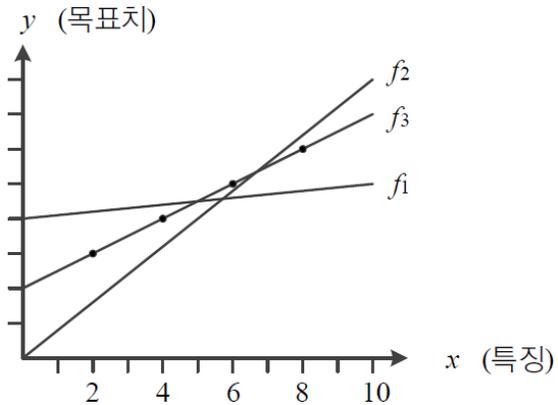


그림 1-4 간단한 기계 학습 예제

■ 예측prediction 문제

- 임의의 시간이 주어지면 이때 이동체의 위치는?
- 회귀regression 문제와 분류classification 문제로 나뉨
 - 회귀는 목표치가 실수, 분류는 부류값 ([그림 1-4]는 회귀 문제)

1.1.3 기계 학습 개념

■ 훈련집합

- 가로축은 **특징**, 세로축은 **목표치**
- 관측한 4개의 점이 **훈련집합**을 구성함

$$\text{훈련집합: } \mathbb{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}, \quad \mathbb{Y} = \{y_1, y_2, \dots, y_n\} \quad (1.1)$$

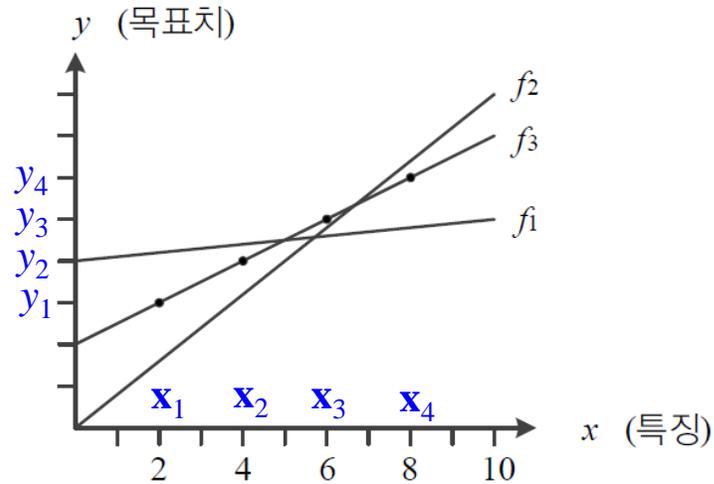


그림 1-4 간단한 기계 학습 예제

[그림 1-4] 예제의 훈련집합

$$\mathbb{X} = \{\mathbf{x}_1 = (2.0), \mathbf{x}_2 = (4.0), \mathbf{x}_3 = (6.0), \mathbf{x}_4 = (8.0)\}$$
$$\mathbb{Y} = \{y_1 = 3.0, y_2 = 4.0, y_3 = 5.0, y_4 = 6.0\}$$

1.1.3 기계 학습 개념

■ 데이터를 어떻게 모델링할 것인가

- 눈대중으로 보면 직선을 이루므로 직선을 선택하자 → 모델로 직선을 선택한 셈
- 직선 모델의 수식
 - 2개의 매개변수 w 와 b

$$y = \underline{w}x + \underline{b} \quad (1.2)$$

■ 기계 학습은

- 가장 정확하게 예측할 수 있는, 즉 최적의 매개변수를 찾는 작업
- 처음에는 최적값을 모르므로 임의의 값에서 시작하고, 점점 성능을 개선하여 최적에 도달
- [그림 1-4]의 예에서는 f_1 에서 시작하여 $f_1 \rightarrow f_2 \rightarrow f_3$
 - 최적인 f_3 은 $w=0.5$ 와 $b=2.0$

1.1.3 기계 학습 개념

■ 학습을 마치면,

- 예측에 사용
- 예) 10.0 순간의 이동체 위치를 알고자 하면, $f_3(10.0)=0.5*10.0+2.0=7.0$ 이라 예측함

■ 기계 학습의 궁극적인 목표

- 훈련집합에 없는 새로운 샘플에 대한 오류를 최소화 (새로운 샘플 집합: 테스트 집합)
- 테스트 집합에 대한 높은 성능을 **일반화**(generalization) 능력이라 부름

■ 기계학습의 전형적인 과정



그림 3-7 기계 학습의 과정

3.1.1 iris 데이터셋 읽기

■ [프로그램 3-1 (a)]: iris 데이터셋 읽기

```
프로그램 3-1(a)  iris 데이터셋 읽기

01  from sklearn import datasets
02
03  d=datasets.load_iris()    # iris 데이터셋을 읽고
04  print(d.DESCR)          # 내용을 출력
```

- 01행: sklearn 모듈의 datasets 클래스를 불러옴
- 03행: load_iris 함수를 호출해 iris 데이터셋을 읽어 객체 d에 저장
- 04행: 객체 d의 DESCR 변수를 출력

■ 기계 학습의 용어

- 샘플로 구성되는 데이터셋
- 특징으로 구성되는 특징 벡터(feature vector)
- 부류(class)

TIP 기계 학습이 사용하는 데이터는 여러 개의 샘플을 담고 있어서 데이터셋(data set)이라 부르기도 한다. 이 책에서는 데이터와 데이터셋을 엄밀히 구분하지 않고 함께 사용하는데, 데이터셋은 iris처럼 특정한 데이터를 가리킬 때 주로 사용한다.

3.1.1 iris 데이터셋 읽기

Iris plants dataset

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

150개의 샘플

- :Number of Instances: 150 (50 in each of three classes)
- :Number of Attributes: 4 numeric, predictive attributes and the class
- :Attribute Information:
 - sepal length in cm
 - sepal width in cm
 - petal length in cm
 - petal width in cm
 - class:
 - Iris-Setosa
 - Iris-Versicolour
 - Iris-Virginica

네 개의 특징(feature)

세 개의 부류

:Summary Statistics:

	Min	Max	Mean	SD	Class Correlation
sepal length:	4.3	7.9	5.84	0.83	0.7826
sepal width:	2.0	4.4	3.05	0.43	-0.4194
petal length:	1.0	6.9	3.76	1.76	0.9490 (high!)
petal width:	0.1	2.5	1.20	0.76	0.9565 (high!)

- :Missing Attribute Values: None
- :Class Distribution: 33.3% for each of 3 classes.
- :Creator: R.A. Fisher
- :Donor: Michael Marshall (MARSHALL%PLU@io.arc.nasa.gov)
- :Date: July, 1988

...

그림 3-2 iris의 세 가지 품종(왼쪽부터 Setosa, Versicolor, Virginica)



3.1.1 iris 데이터셋 읽기

■ iris의 내용 살펴보기

프로그램 3-1(b) iris의 내용 살펴보기

```
05 for i in range(0, len(d.data)):      # 샘플을 순서대로 출력
06     print(i+1, d.data[i], d.target[i])
```

```
1 [5.1 3.5 1.4 0.2] 0
2 [4.9 3.  1.4 0.2] 0
3 [4.7 3.2 1.3 0.2] 0
4 [4.6 3.1 1.5 0.2] 0
...
51 [7.  3.2 4.7 1.4] 1
52 [6.4 3.2 4.5 1.5] 1
53 [6.9 3.1 4.9 1.5] 1
54 [5.5 2.3 4.  1.3] 1
...
101 [6.3 3.3 6.  2.5] 2
102 [5.8 2.7 5.1 1.9] 2
103 [7.1 3.  5.9 2.1] 2
104 [6.3 2.9 5.6 1.8] 2
...
```

d.data(특징 벡터)

d.target(레이블)

3.1.1 기계 학습에서 데이터셋의 표현

■ 샘플을 특징 벡터와 레이블로 표현

- 특징 벡터는 \mathbf{x} 로 표기(d 는 특징의 개수로서 특징 벡터의 차원이라 부름)

$$\text{특징 벡터: } \mathbf{x}=(x_1, x_2, \dots, x_d) \quad (3.1)$$

- 레이블은 $0, 1, 2, \dots, c-1$ 의 값 또는 $1, 2, \dots, c-1, c$ 의 값 또는 원핫 코드
 - 원핫 코드는 한 요소만 1인 이진열
 - 예) Setosa는 (1,0,0), Versicolor는 (0,1,0), Virginica는 (0,0,1)로 표현

	특징 벡터 $\mathbf{x}=(x_1, x_2, \dots, x_d)$	레이블(참값) y
샘플 1:	(5.1, 3.5, 1.4, 0.2)	0
샘플 2:	(4.9, 3.0, 1.4, 0.2)	0
...
샘플 51:	(7.0, 3.2, 4.7, 1.4)	1
샘플 52:	(6.4, 3.2, 4.5, 1.5)	1
...
샘플 101:	(6.3, 3.3, 6.0, 2.5)	2
샘플 102:	(5.8, 2.7, 5.1, 1.9)	2
...
샘플 n:	(5.9, 3.0, 5.1, 1.8)	2

iris 데이터셋
(n=150, d=4)

그림 3-3 일반적인 데이터셋 표현 방법(iris 데이터셋 예시)

3.3.1 특징 공간에서 데이터 분포

■ iris 데이터

- 특징이 4개이므로 4차원 특징 공간을 형성
- 150개 샘플 각각은 4차원 특징 공간의 한 점
- [프로그램 3-2]는 차원을 하나 제외하고 3차원 공간에 데이터 분포를 그림

프로그램 3-2

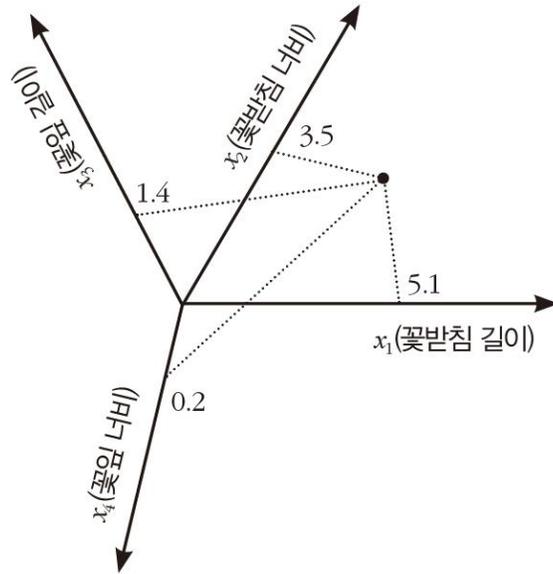
iris 데이터의 분포를 특징 공간에 그리기

```
01 import plotly.express as px
02
03 df = px.data.iris()
04 fig = px.scatter_3d(df, x='sepal_length', y='sepal_width', z='petal_width',
05                    color='species') # petal_length를 제외하여 3차원 공간 구성
06 fig.show(renderer="browser")
```

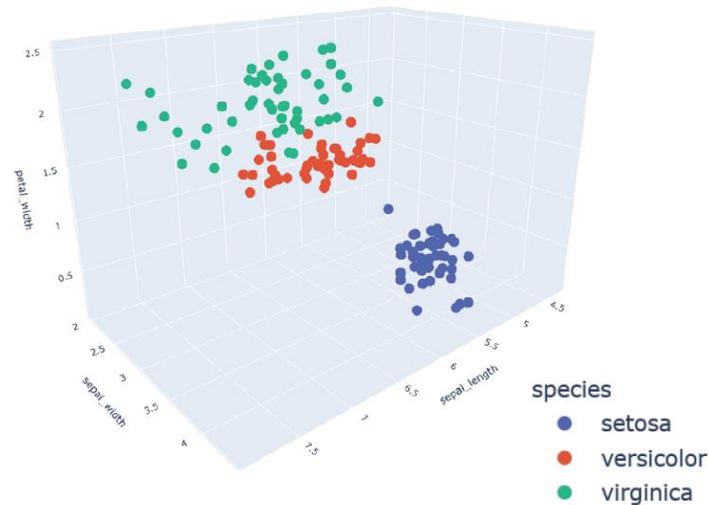
3.3.1 특징 공간에서 데이터 분포

■ 특징 공간에서 데이터 분포 관찰 ([프로그램 3-2]의 실행 결과인 [그림 3-5(b)])

- petal width(수직 축)에 대해 Setosa는 아래쪽, Virginica는 위쪽에 분포([프로그램 3-1(b)]의 실행 결과와 일치) → petal width 특징은 분별력(discriminating power)이 뛰어남
- sepal width 축은 세 부류가 많이 겹쳐서 분별력이 낮음
- 전체적으로 보면, 세 부류가 3차원 공간에서 서로 다른 영역을 차지하는데 몇 개 샘플은 겹쳐 나타남



(a) 4차원 특징 공간(가상의 그림)



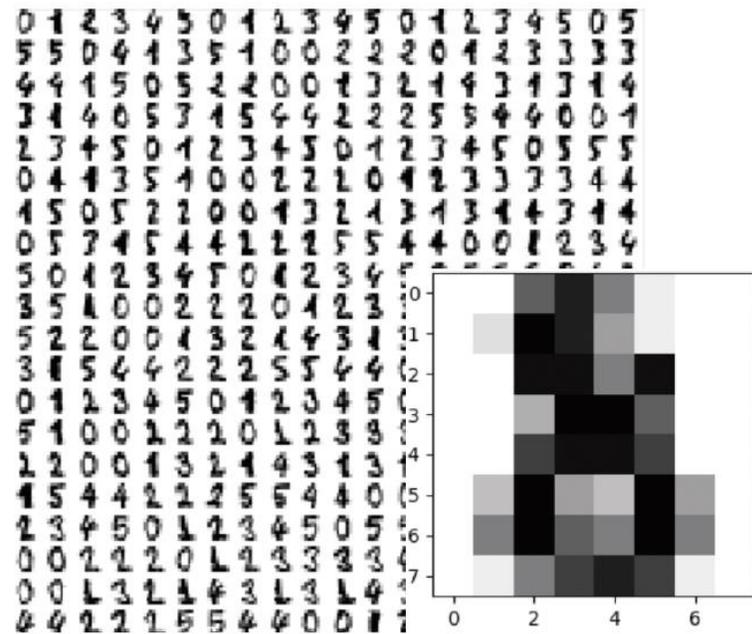
(b) 꽃잎 길이 축을 제외한 3차원 특징 공간

그림 3-5 iris 데이터를 특징 공간에 그리기

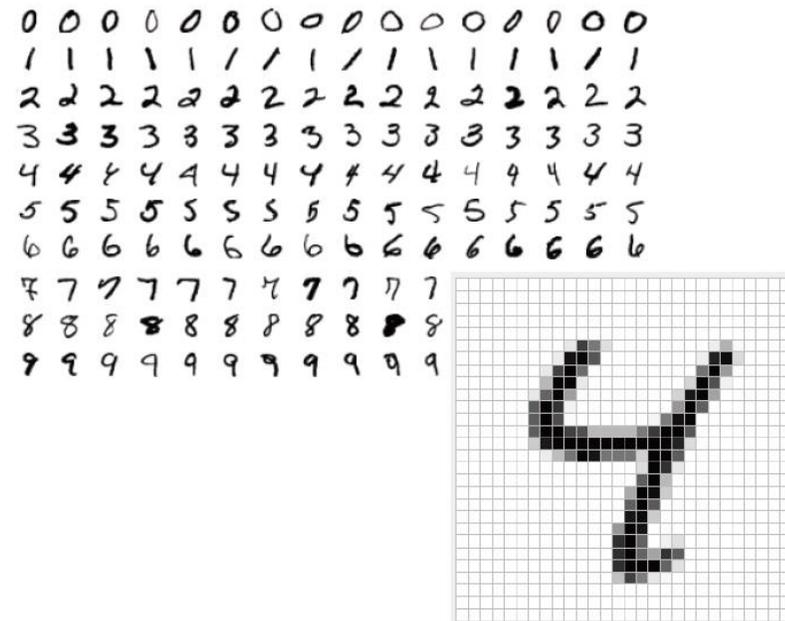
3.3.2 영상 데이터 사례: 필기 숫자

■ 두 가지 필기 숫자 데이터셋

- sklearn 데이터셋: 8*8 맵(64개 화소), 1797개 샘플, [0,16] 명암값
- MNIST 데이터셋: 28*28맵(784개 화소), 7만개 샘플, [0,255] 명암값



(a) sklearn에서 제공하는 데이터셋



(b) MNIST 데이터셋

그림 3-6 필기 숫자 데이터셋

3.3.2 영상 데이터 사례: 필기 숫자

■ [프로그램 3-3(a)]

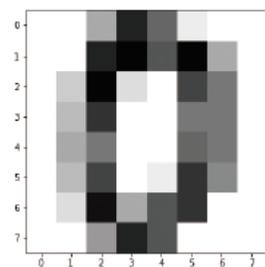
- matplotlib 라이브러리를 이용한 샘플 디스플레이와 샘플 내용(화소값) 출력

프로그램 3-3(a)

필기 숫자 데이터

```
01 from sklearn import datasets
02 import matplotlib.pyplot as plt
03
04 digit=datasets.load_digits()
05
06 plt.figure(figsize=(5,5))
07 plt.imshow(digit.images[0],cmap=plt.cm.gray_r,interpolation='nearest')
                                # 0번 샘플을 그림
08 plt.show()
09 print(digit.data[0])          # 0번 샘플의 화소값을 출력
10 print("이 숫자는 ",digit.target[0],"입니다.")
```

3.3.2 영상 데이터 사례: 필기 숫자



어떤 특징을 사용해야 높은 성능을 얻을 수 있을까? (3.4 절의 주제)

```
[ 0.  0.  5. 13.  9.  1.  0.  0.  0.  0. 13. 15. 10. 15.  5.  0.  0.  3.  
15.  2.  0. 11.  8.  0.  0.  4. 12.  0.  0.  8.  8.  0.  0.  5.  8.  0.  
 0.  9.  8.  0.  0.  4. 11.  0.  1. 12.  7.  0.  0.  2. 14.  5. 10. 12.  
 0.  0.  0.  0.  6. 13. 10.  0.  0.  0.  0.]
```

이 숫자는 0입니다.

NOTE matplotlib을 이용한 시각화

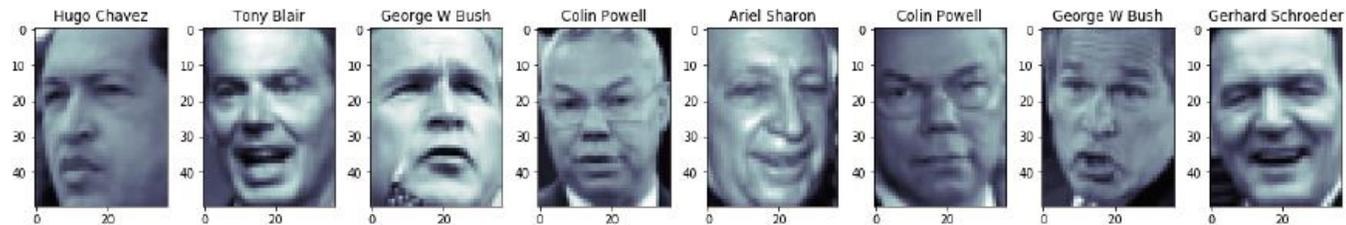
파이썬에서 matplotlib 라이브러리는 시각화에 가장 널리 쓰인다. 인공지능은 학습 과정이나 예측 결과를 시각화하는 데 matplotlib을 자주 사용한다. matplotlib 사용이 처음이라면 부록 B를 공부해 기초를 먼저 다진다. matplotlib의 공식 사이트에서 제공하는 튜토리얼 문서를 공부하는 것도 효과적인 방법이다. [표 2-1]에서 제시한 <https://matplotlib.org/users>에 접속해 [Tutorials] 메뉴를 선택한다. 튜토리얼은 Introductory, Intermediate, Advanced로 나뉘어 있으니 최소한 Introductory 코스를 숙지하고 넘어간다.

3.3.3 영상 데이터 사례: lfw 얼굴 데이터셋

- lfw(labeled faces in the wild) 데이터셋
 - 5749명의 유명인의 얼굴 영상 13233장. 50*37맵. [0,255] 명암 값
 - 데이터 편향 주의(어린이, 흑인 등이 적어 얼굴 인식 프로그램을 제작하는데 부적절)

프로그램 3-3(b) lfw 유명인 얼굴 데이터셋

```
11 lfw=datasets.fetch_lfw_people(min_faces_per_person=70,resize=0.4) # 데이터셋 읽기
12
13 plt.figure(figsize=(20,5))
14
15 for i in range(8): # 처음 8명을 디스플레이
16     plt.subplot(1,8,i+1)
17     plt.imshow(lfw.images[i],cmap=plt.cm.bone)
18     plt.title(lfw.target_names[lfw.target[i]])
19
20 plt.show()
```



3.3.4 텍스트 데이터 사례: 20newsgroups

■ 20newsgroups 데이터셋

- 웹에서 수집한 문서를 20개 부류로 구분. 텍스트로 구성되어 샘플의 길이가 다름
- 시계열 데이터(단어가 나타나는 순서가 중요. 8장의 순환 신경망에서 다룸)

프로그램 3-3(c) 20newsgroups 데이터셋

```
21 news=datasets.fetch_20newsgroups(subset='train') # 데이터셋 읽기
22 print("*****Wn",news.data[0],"Wn*****")      # 0번 샘플 출력
23 print("이 문서의 부류는 <",news.target_names[news.target[0]],"> 입니다.")
```

```
From: lerxst@wam.umd.edu (where's my thing)
Subject: WHAT car is this!?
Nntp-Posting-Host: rac3.wam.umd.edu
Organization: University of Maryland, College Park
Lines: 15
```

```
I was wondering if anyone out there could enlighten me on this car I saw
the other day. It was a 2-door sports car, looked to be from the late 60s/
early 70s. It was called a Bricklin. The doors were really small. In addition,
the front bumper was separate from the rest of the body. This is
```

...

이 문서의 부류는 < rec.autos >입니다.

3.4 특징 추출과 표현 - 3.4.1 특징의 분별력

■ 사람은 직관적으로 분별력(discriminating power)이 높은 특징을 사용

▪ 예) [그림 3-8]의 두 텀블러를 구분하는 특징

- 글씨 방향, 몸통 색깔, 손잡이 유무, 뚜껑 유무 등
- 뚜껑 유무라는 특징은 분별력이 없음
- 손잡이 유무라는 특징은 높은 분별력



그림 3-8 텀블러를 구분하기 위한 특징으로 무엇이 좋을까?

3.4.1 특징의 분별력

■ 기계 학습은 높은 분별력을 지닌 특징을 사용해야 함

- 예) 100여년 전의 iris 데이터는 사람이 네 종류의 특징을 자를 들고 직접 추출
- 현대에서는 붓꽃 영상을 그대로 입력하면 딥러닝이 최적의 특징을 추출해 줌

■ 다양한 형태의 특징 공간

- 실제 세상은 [그림 3-9(c)~(d)]와 같은 비선형 데이터를 생성(데이터의 원천적인 성질 또는 측정이나 레이블링 오류, 비합리적인 특징 추출 알고리즘에 기인)
- 가급적 [그림 3-9(d)]보다 [그림 3-9(c)]와 같은 특징을 사용해야 함

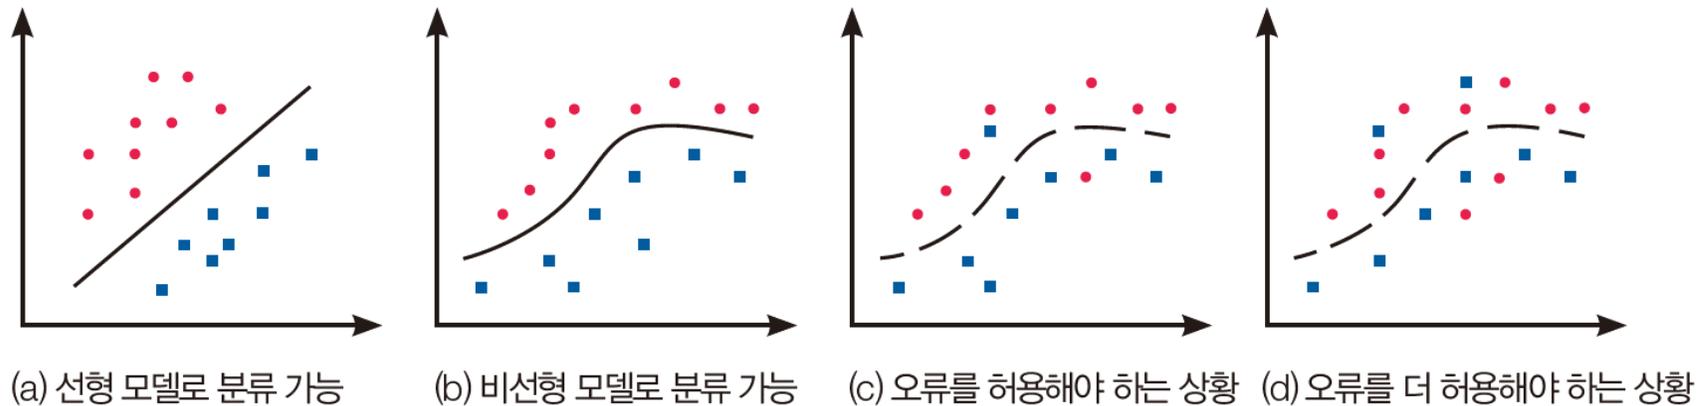


그림 3-9 특징의 분별력

3.4.2 특징 값의 종류

■ 수치형 특징

- 예) iris의 네 개 특징은 실수
- 거리 개념이 있음
- 실수 또는 정수 또는 이진값

■ 범주형 특징

- 학점, 수능 등급, 혈액형, 지역 등
- 순서형: 학점, 수능 등급 등
 - 거리 개념이 있음. 순서대로 정수를 부여하면 수치형으로 취급 가능
- 이름형
 - 혈액형, 지역 등으로 거리 개념이 없음
 - 보통 원핫_{one-hot} 코드로 표현. 예) A형(1,0,0,0), B형(0,1,0,0), O형(0,0,1,0), AB형(0,0,0,1)

3.1.2 기계 학습 적용: 모델링과 예측

■ [프로그램 3-1(c)]

- SVM(support vector machine)이라는 기계 학습 모델을 사용

```
프로그램 3-1(c) iris에 기계 학습 적용: 모델링과 예측

07 from sklearn import svm 하이퍼 매개변수
08
09 s=svm.SVC(gamma=0.1,C=10) # svm 분류 모델 SVC 객체 생성하고
10 s.fit(d.data,d.target) # iris 데이터로 학습
11
12 new_d=[[6.4,3.2,6.0,2.5],[7.1,3.1,4.7,1.35]] # 101번째와 51번째 샘플을 변형하여
13 res=s.predict(new_d) # 테스트 집합
14 print("새로운 2개 샘플의 부류는", res)
```

새로운 2개 샘플의 부류는 [2 1]

- 09행: SVM의 분류기 모델 SVC 클래스의 객체를 생성하여 s에 저장
- 10행: 객체 s의 fit 함수는 훈련 집합을 가지고 학습을 수행(매개변수로 특징 벡터 iris.data와 레이블 iris,target을 설정)
- 13행: 객체 s의 predict 함수는 테스트 집합을 가지고 예측 수행

1.5 모델 선택

- 1.5.1 과소적합과 과잉적합
- 1.5.2 바이어스와 분산
- 1.5.3 검증집합과 교차검증을 이용한 모델 선택 알고리즘
- 1.5.4 모델 선택의 한계와 현실적인 해결책

1.5.1 과소적합과 과잉적합

- [그림 1.13]의 1차 모델은 **과소적합**
 - 모델의 ‘용량이 작아’ 오차가 클 수밖에 없는 현상
- 비선형 모델을 사용하는 대안
 - [그림 1-13]의 2차, 3차, 4차, 12차는 다항식 곡선을 선택한 예
 - 1차(선형)에 비해 오차가 크게 감소함

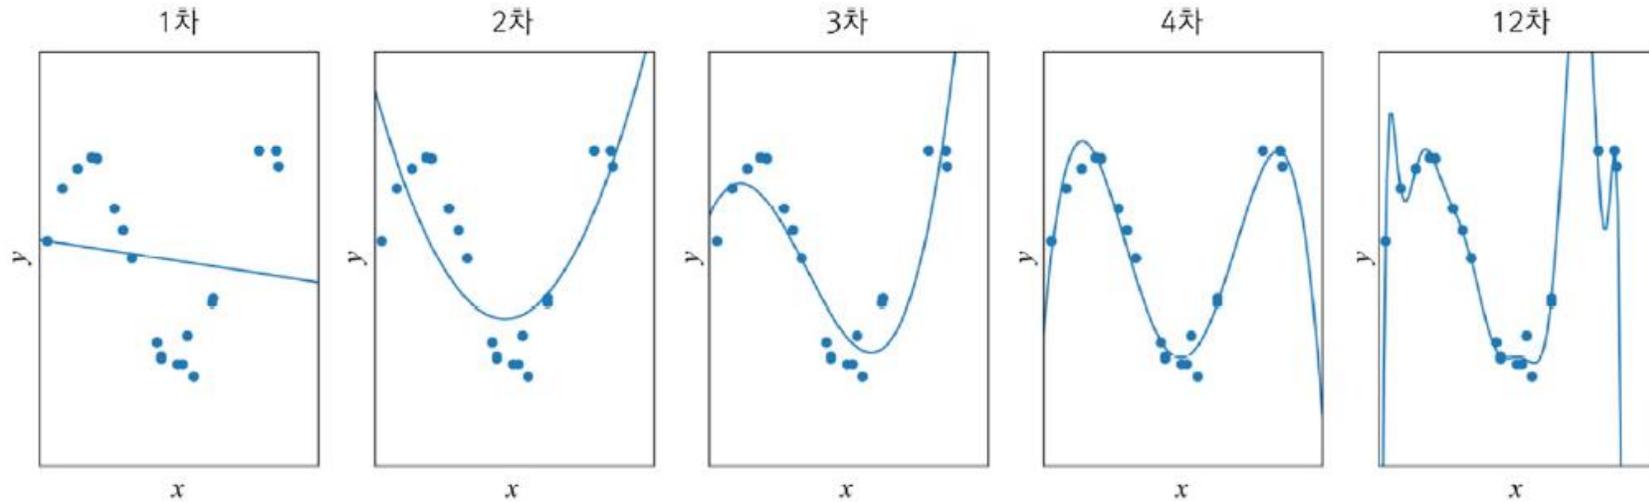


그림 1-13 과소적합과 과잉적합 현상

1.5.1 과소적합과 과잉적합

■ 과잉적합

- 12차 다항식 곡선을 채택한다면 훈련집합에 대해 거의 완벽하게 근사화함
- 하지만 '새로운' 데이터를 예측한다면 큰 문제 발생
 - x_0 에서 빨간 막대 근방을 예측해야 하지만 빨간 점을 예측
- 이유는 '용량이 크기' 때문. 학습 과정에서 잡음까지 수용 → 과잉적합 현상
- 적절한 용량의 모델을 선택하는 모델 선택 작업이 필요함

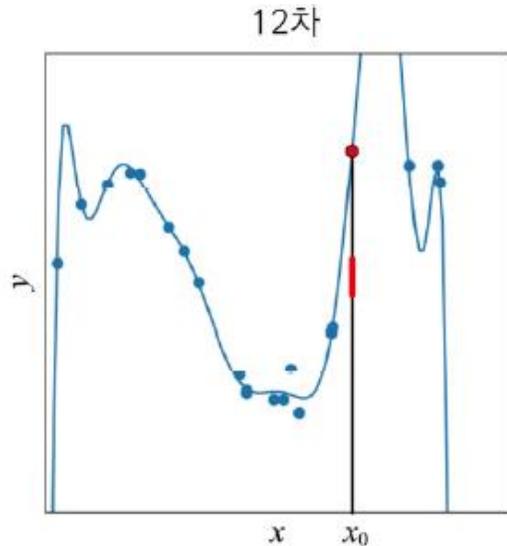


그림 1-14 과잉적합되었을 때 부정확한 예측 현상

1.5.2 바이어스와 분산

■ 1차~12차 다항식 모델의 비교 관찰

- 1~2차는 훈련집합과 테스트집합 모두 낮은 성능
- 12차는 훈련집합에 높은 성능을 보이거나 테스트집합에서는 낮은 성능 → 낮은 일반화 능력
- 3~4차는 훈련집합에 대해 12차보다 낮겠지만 테스트집합에는 높은 성능 → 높은 일반화 능력

1.5.2 바이어스와 분산

- 훈련집합을 여러 번 수집하여 1차~12차에 적용하는 실험
 - 2차는 매번 큰 오차 → 바이어스가 큼. 하지만 비슷한 모델을 얻음 → 낮은 분산
 - 12차는 매번 작은 오차 → 바이어스가 작음. 하지만 크게 다른 모델을 얻음 → 높은 분산
 - 일반적으로 용량이 작은 모델은 바이어스는 크고 분산은 작음. 복잡한 모델은 바이어스는 작고 분산은 큼
 - 바이어스와 분산은 트레이드오프 관계

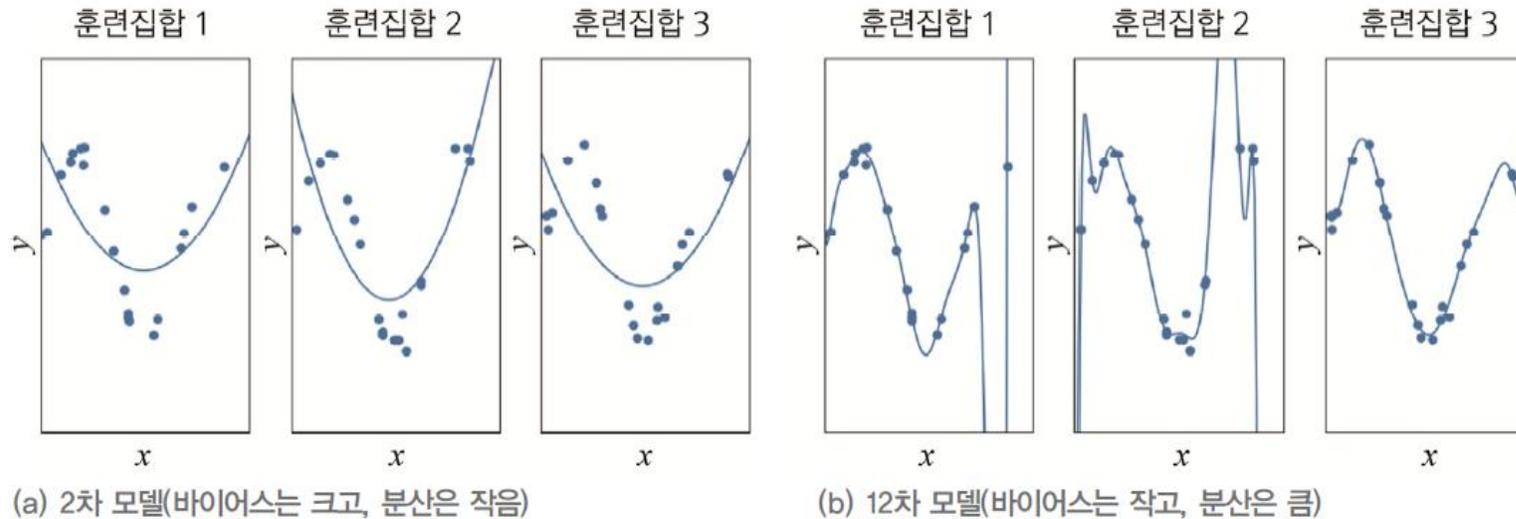


그림 1-15 모델의 바이어스와 분산 특성

1.5.2 바이어스와 분산

■ 기계 학습의 목표

- 낮은 바이어스와 낮은 분산을 가진 예측기 제작이 목표. 즉 왼쪽 아래 상황

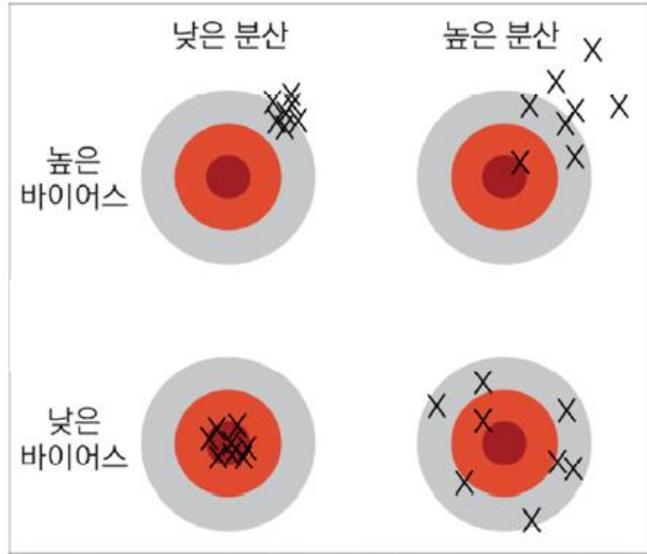


그림 1-16 바이어스와 분산

- 하지만 바이어스와 분산은 트레이드오프 관계
- 따라서 바이어스 희생을 최소로 유지하며 분산을 최대한 낮추는 전략 필요

1.5.3 검증집합과 교차검증을 이용한 모델 선택 알고리즘

■ 검증집합을 이용한 모델 선택

- 훈련집합과 테스트집합과 다른 별도의 검증집합을 가진 상황

알고리즘 1-2 검증집합을 이용한 모델 선택

입력: 모델집합 Ω , 훈련집합, 검증집합, 테스트집합

출력: 최적 모델과 성능

- 1 for (Ω 에 있는 각각의 모델)
- 2 모델을 훈련집합으로 학습시킨다.
- 3 검증집합으로 학습된 모델의 성능을 측정한다. // 검증 성능 측정
- 4 가장 높은 성능을 보인 모델을 선택한다.
- 5 테스트집합으로 선택된 모델의 성능을 측정한다.

1.5.3 검증집합과 교차검증을 이용한 모델 선택 알고리즘

■ 교차검증 cross validation

- 비용 문제로 별도의 검증집합이 없는 상황에 유용한 모델 선택 기법
- 훈련집합을 등분하여, 학습과 평가 과정을 여러 번 반복한 후 평균 사용

알고리즘 1-3 교차검증에 의한 모델 선택

입력: 모델집합 Ω , 훈련집합, 테스트집합, 그룹 개수 k

출력: 최적 모델과 성능

- 1 훈련집합을 k 개의 그룹으로 등분한다.
- 2 for (Ω 에 있는 각각의 모델)
- 3 for ($i=1$ to k)
- 4 i 번째 그룹을 제외한 $k-1$ 개 그룹으로 모델을 학습시킨다.
- 5 학습된 모델의 성능을 i 번째 그룹으로 측정한다.
- 6 k 개 성능을 평균하여 해당 모델의 성능으로 취한다.
- 7 가장 높은 성능을 보인 모델을 선택한다.
- 8 테스트집합으로 선택된 모델의 성능을 측정한다.

3.6.2 훈련/검증/테스트 집합으로 쪼개기

- 주어진 데이터를 적절한 비율로 훈련, 검증, 테스트 집합으로 나누어 씀
 - 모델 선택 포함: 훈련/검증/테스트 집합으로 나눔
 - 모델 선택 제외: 훈련/테스트 집합으로 나눔



그림 3-11 훈련/검증/테스트 집합으로 쪼개기

3.6.3 교차 검증

■ 훈련/테스트 집합 나누기의 한계

- 우연히 높은 정확률 또는 우연히 낮은 정확률 발생 가능성

■ k -겹 교차 검증 k -fold cross validation

- 훈련 집합을 k 개의 부분집합으로 나누어 사용. 한 개를 남겨두고 $k-1$ 개로 학습한 다음 남겨둔 것으로 성능 측정. k 개의 성능을 평균하여 신뢰도 높임



(a) 모델 선택 포함



(b) 모델 선택 제외

그림 3-12 k -겹 교차 검증($k=5$ 인 경우)

3.7 인공지능은 어떻게 인식을 하나?

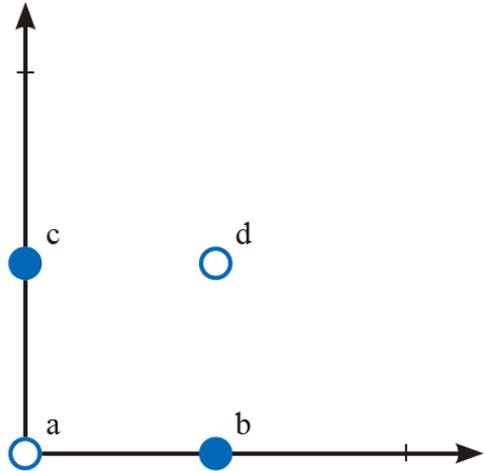
- 지금까지는 모델(분류기)의 원리에 대한 이해없이 프로그래밍 실습
 - 지금까지 기계 학습 모델인 SVM을 블랙 박스로 보고 프로그래밍
 - 동작 원리에 대한 이해 없으면 언젠가 한계가 드러남

3.7.1 특징 공간을 분할하는 결정 경계

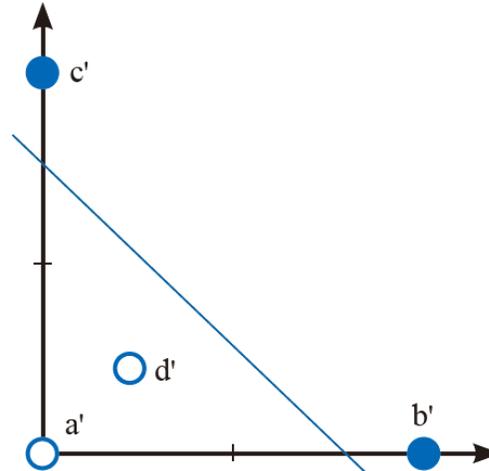
■ 인공지능의 인식은 철저히 수학에 의존

- 샘플은 특징 벡터로 표현되며, 특징 벡터는 특징 공간의 한 점에 해당
- 인식 알고리즘은 원래 특징 공간을 성능을 높이는데 더 유리한 새로운 특징 공간으로 여러 차례 변환한 다음 최종적으로 특징 공간을 분할하여 부류를 결정
- 특징 공간 변환 예

$$\text{원래 특징 공간 } \mathbf{x}=(x_1, x_2) \rightarrow \text{새로운 특징 공간 } \mathbf{x}'=\left(\frac{x_1}{2x_1x_2+0.5}, \frac{x_2}{2x_1x_2+0.5}\right) \quad (3.5)$$



(a) 원래 특징 공간



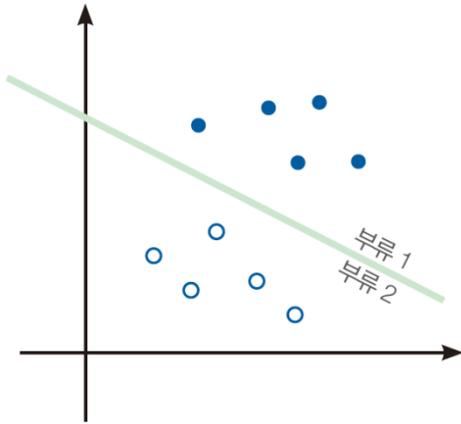
(b) 선형 분리가 가능하도록 변환된 새로운 공간

그림 3-13 특징 공간의 변환

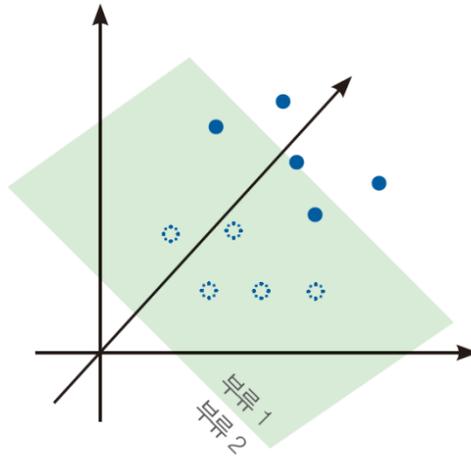
3.7.1 특징 공간을 분할하는 결정 경계

■ 특징 공간을 분할하는 결정 경계_{decision boundary}

- [그림 3-14]는 2차원과 3차원 예
- 2~3차원은 그림을 그릴 수 있는데 4차원 이상은 수학적 상상력 필요



(a) 2차원 특징 공간에서 결정 직선



(b) 3차원 특징 공간에서 결정 평면

그림 3-14 특징 공간의 분할

■ 현대 기계 학습이 다루는 데이터

- 수백~수만 차원 특징 공간
- 고차원 공간에서 부류들이 서로 꼬여있는 매우 복잡한 분포
- 딥러닝은 층을 깊게 하여 여러 단계의 특징 공간 변환을 수행(특징 학습 또는 표현 학습이라 부름)

기계학습의 유형

■ 지도 학습(Supervised learning)

- 레이블이 있는 데이터를 사용하여 학습
- 선형 회귀, 로지스틱 회귀, 서포트 벡터 머신(SVM), 결정 트리, 랜덤 포레스트, k-최근접 이웃(k-NN)

■ 비지도 학습(Unsupervised learning)

- 레이블이 없는 데이터를 사용하여 학습
- 클러스터링, 차원 축소, 이상 탐지 등
- K-평균 클러스터링, 계층적 클러스터링, 주성분 분석(PCA)

■ 준지도 학습(Semi-supervised learning)

- 레이블이 있는 데이터 일부와 없는 데이터를 함께 사용

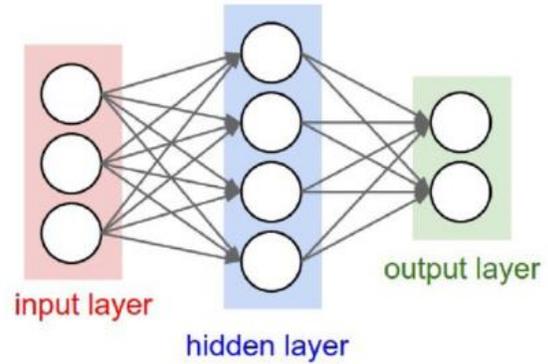
■ 강화 학습(Reinforcement learning)

- 에이전트가 행동을 취하고, 그 행동의 결과로 보상을 받으며 보상을 최대화하도록 학습
- 게임, 로봇, 자율주행 등 활용
- Q-러닝

딥러닝의 유형

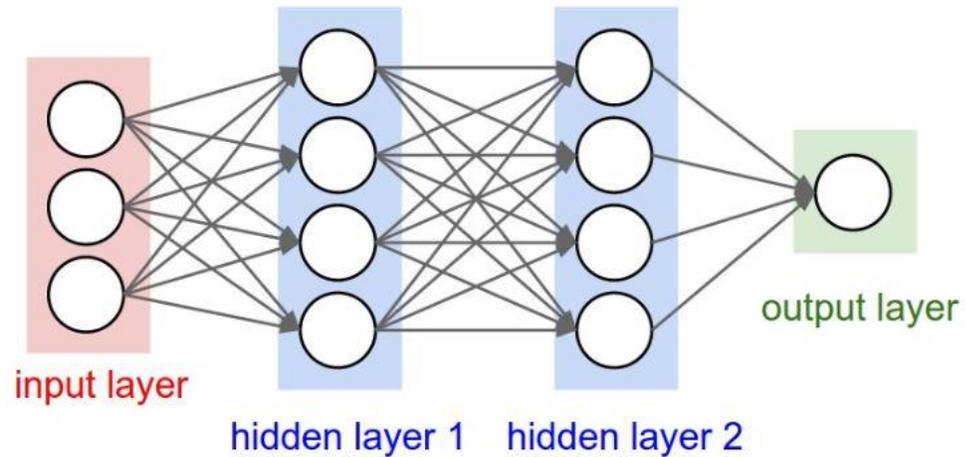
■ 인공신경망(Artificial neural network)

- 사람의 신경을 모방



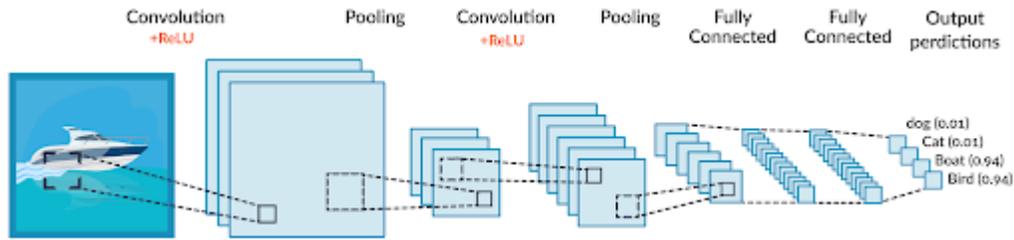
■ 깊은 신경망(Deep neural network)

- 은닉층(Hidden layer)가 2개 이상인 신경망



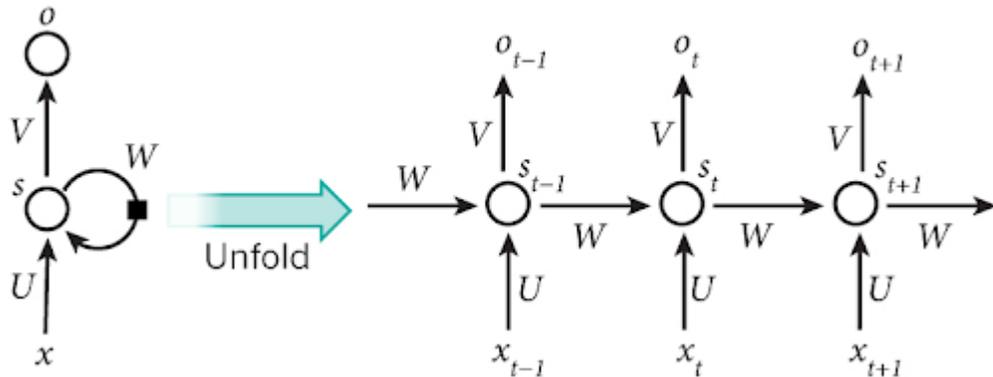
■ 합성곱 신경망(Convolutional neural networks, CNN)

- 컨볼루션 이용
- 영상 인식 - 영상 분류/객체 검출/객체 분할/객체 추적 등



■ 순환 신경망(Recurrent neural networks, RNN)

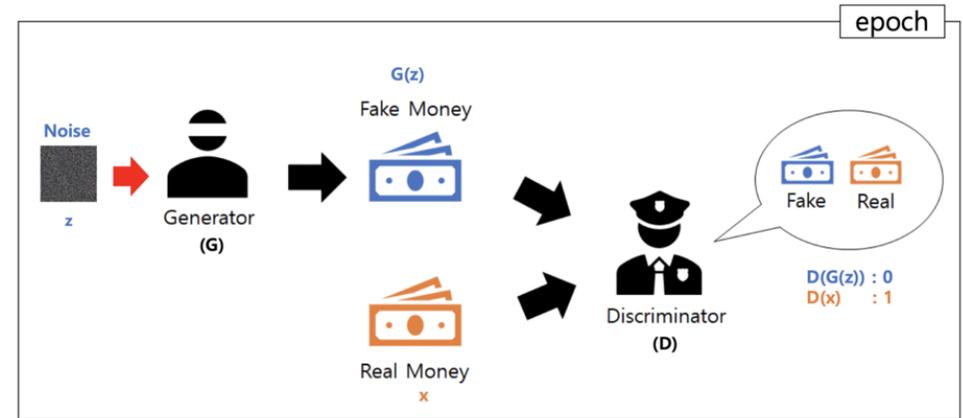
- 시퀀스 데이터(시간, 자연어 등) 처리
- 언어 모델링, 음성인식, 기계 번역 등



딥러닝의 유형

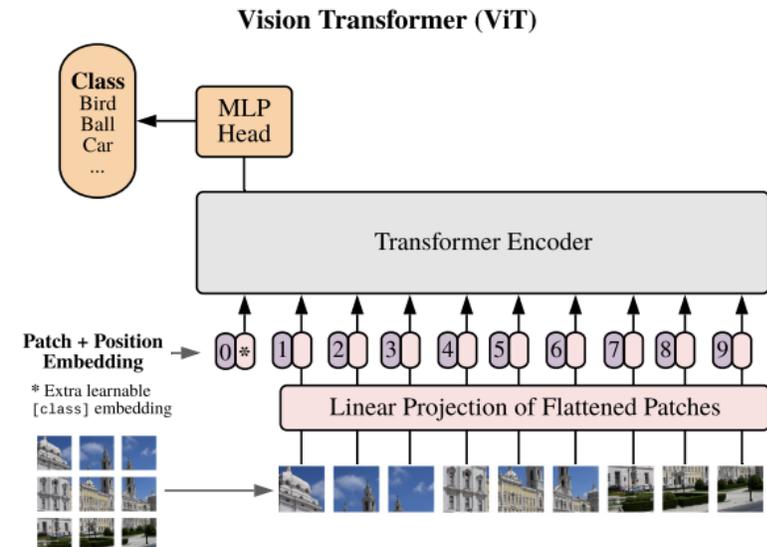
■ 생성적 적대 신경망(Generative adversarial networks, GAN)

- Generator-discriminator가 서로 경쟁하며 학습
- 이미지 생성, 딥페이크, 데이터 증강 등



■ 트랜스포머(Transformer)

- 컨볼루션 레이어 대신 Self-attention 매커니즘 이용



강의 개요

■ 신경망의 개념 및 구조

- 사람의 신경망을 어떻게 모방했을까?

■ 퍼셉트론(Perceptron)

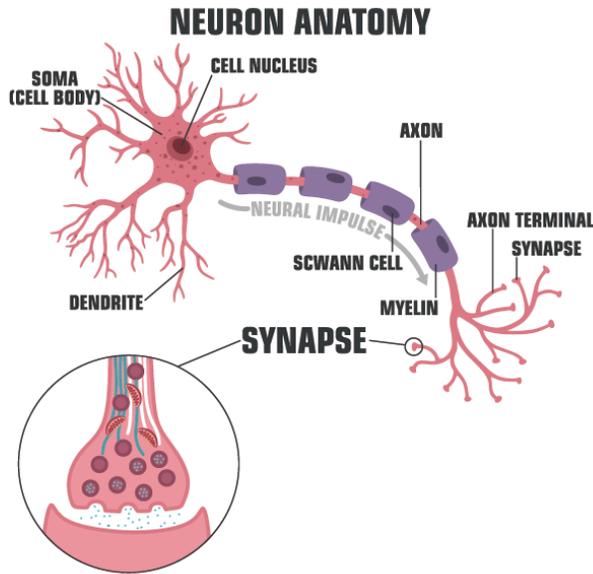
- 구조와 연산
- 학습 방법

■ 다층 퍼셉트론(Multi-layer perceptron, MLP)

- 오류 역전파(Error backpropagation)

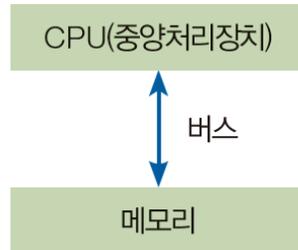
Feedforward Neural Networks

Human brain vs. Artificial neural network

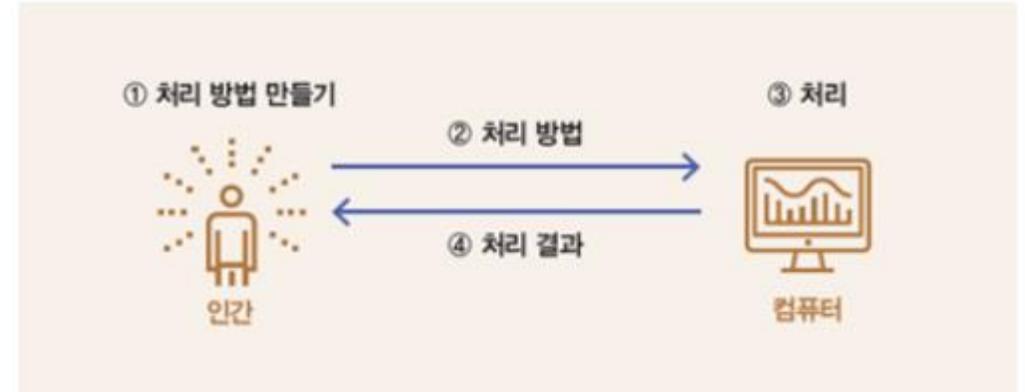


(a) 뇌의 정보처리 단위인 뉴런

그림 4-1 생물의 정보처리와 컴퓨터의 정보처리의 차이



(b) 폰 노이만 컴퓨터의 구조



<컴퓨터가 처리하는 방식>



<인공지능이 처리하는 방식>

Feedforward Neural Networks

Human brain vs. Artificial neural network

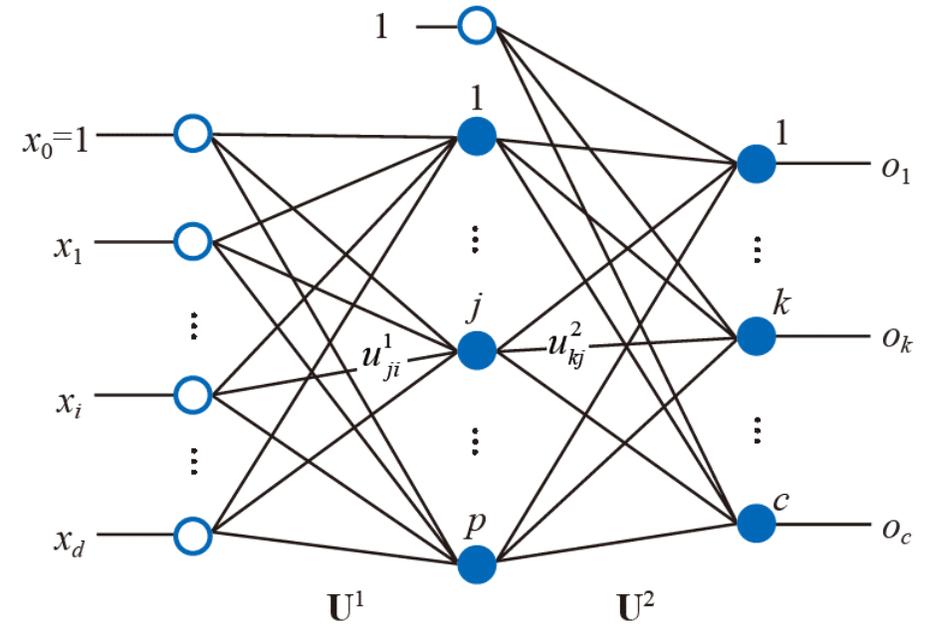
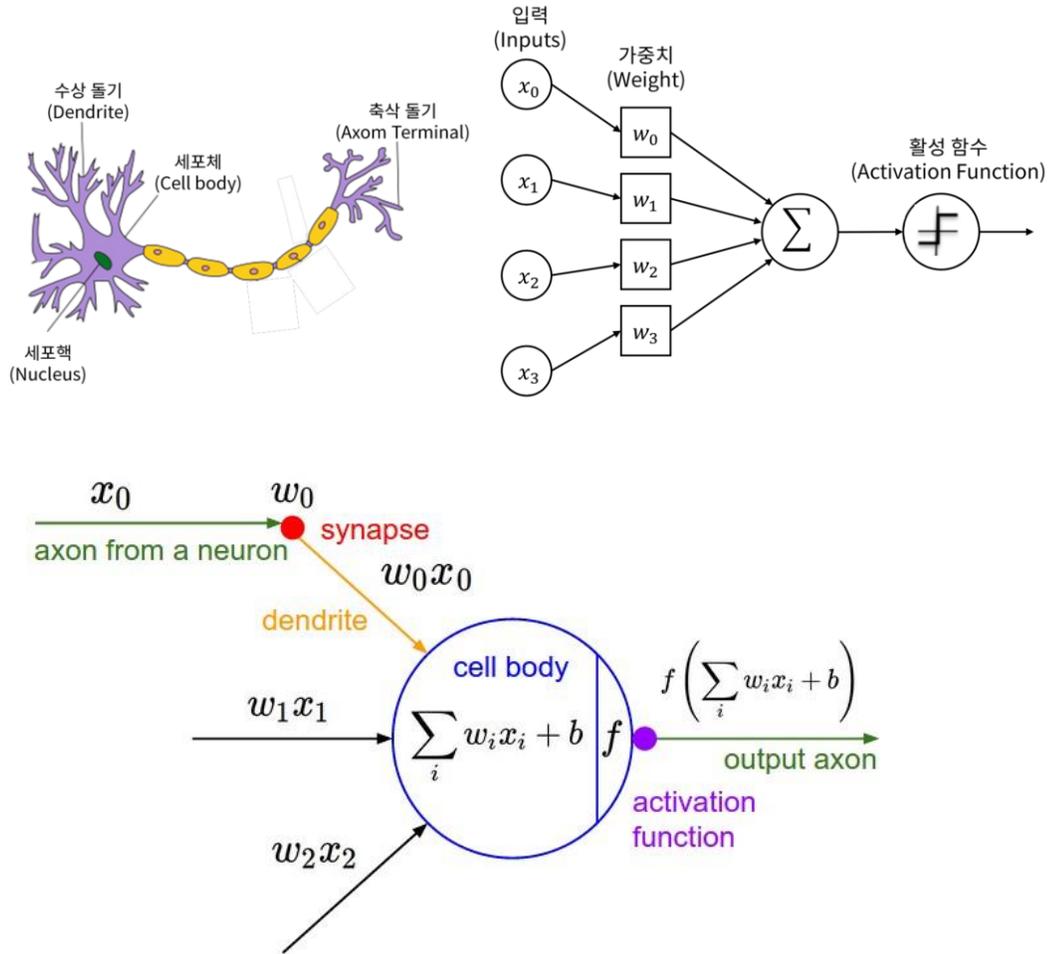


그림 4-13 다층 퍼셉트론의 구조

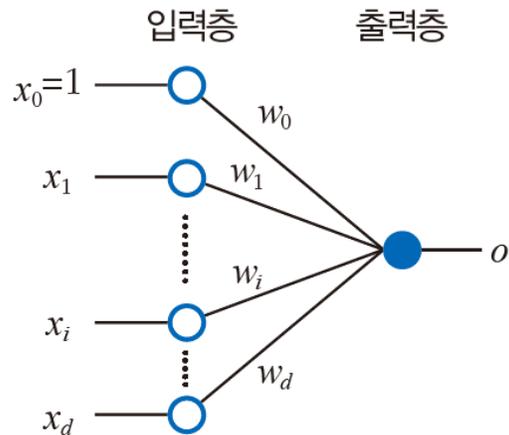
4.2.1 퍼셉트론의 구조와 연산

■ 퍼셉트론의 구조

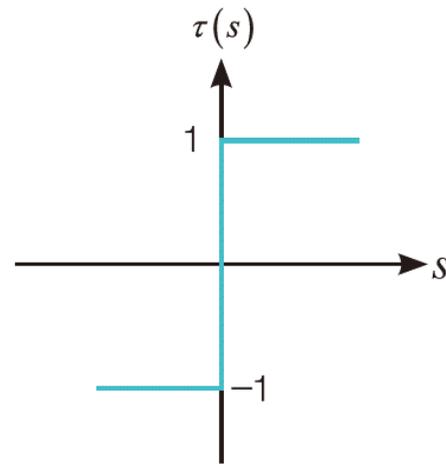
- 입력층과 출력층으로 구성(출력층은 한 개의 노드)
- 입력층은 $d+1$ 개의 노드(d 는 특징 벡터의 차원). 예) iris는 $d=4$, digit는 $d=64$

$$\text{특징 벡터: } \mathbf{x}=(x_1, x_2, \dots, x_d) \quad (4.1)$$

- i 번째 입력 노드와 출력 노드는 가중치 w_i 를 가진 에지(edge)로 연결됨



(a) 퍼셉트론의 구조



(b) 계단 함수를 활성화 함수로 사용

그림 4-2 퍼셉트론의 구조와 동작

4.2.1 퍼셉트론의 구조와 연산

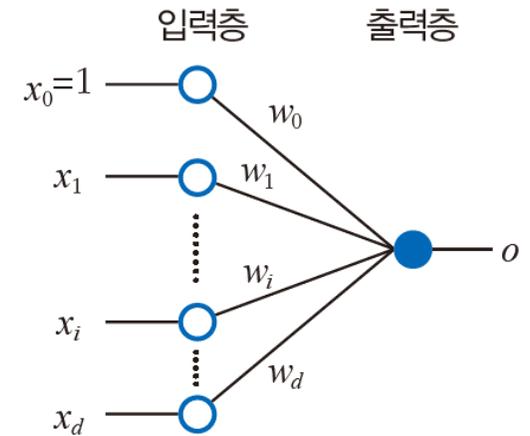
■ 퍼셉트론의 연산

- i 번째 에지는 x_i 와 w_i 를 곱해 출력 노드로 전달
- 0번째 입력 노드 x_0 은 1인 바이어스 노드
- 출력 노드는 $d+1$ 개의 곱셈 결과를 모두 더한 s 를 계산하고 활성화 함수_{activation function} 적용

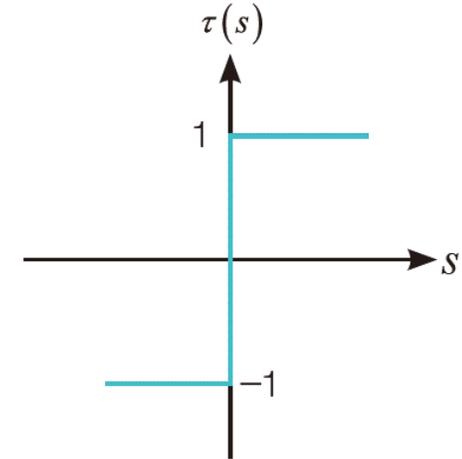
$$\left. \begin{aligned} o &= \tau(s) = \tau\left(\sum_{i=1}^d w_i x_i + w_0\right) \\ \text{이때 } \tau(s) &= \begin{cases} +1, s > 0 \\ -1, s \leq 0 \end{cases} \end{aligned} \right\} (4.2)$$

■ 활성화 함수

- 뉴런을 활성화하는 과정을 모방
- 퍼셉트론은 활성화 함수로 계단 함수 사용(s 가 0보다 크면 1, 그렇지 않으면 -1 출력)
- 따라서 퍼셉트론은 특징 벡터를 1 또는 -1로 변환하는 장치, 즉 이진 분류기



(a) 퍼셉트론의 구조



(b) 계단 함수를 활성화 함수로 사용

4.2.2 퍼셉트론으로 인식하기

■ 퍼셉트론은 이진 분류기 binary classifier

- 이진 분류 문제의 예)
 - 생산 라인에서 나오는 제품을 우량과 불량으로 구분
 - 병원에 온 사람을 정상인과 환자로 구분
 - 내가 등장하는 사진을 구별해 냄

■ [예제 4-1] 퍼셉트론의 인식 능력

- 제품을 크기와 색상을 나타내는 두 개의 특징으로 표현한다고 가정($d=2$). 특징 값은 0 또는 1이라 가정

$$\mathbf{x}=(\text{크기}, \text{색상})=(x_1, x_2)$$

- 생산 라인에서 제품 4개를 수집하여 관찰한 결과 다음 데이터를 확보([그림 4-3(a)])

$$x_1=(0,0), \quad x_2=(0,1), \quad x_3=(1,0), \quad x_4=(1,1)$$

$$y_1=-1, \quad y_2=1, \quad y_3=1, \quad y_4=1$$

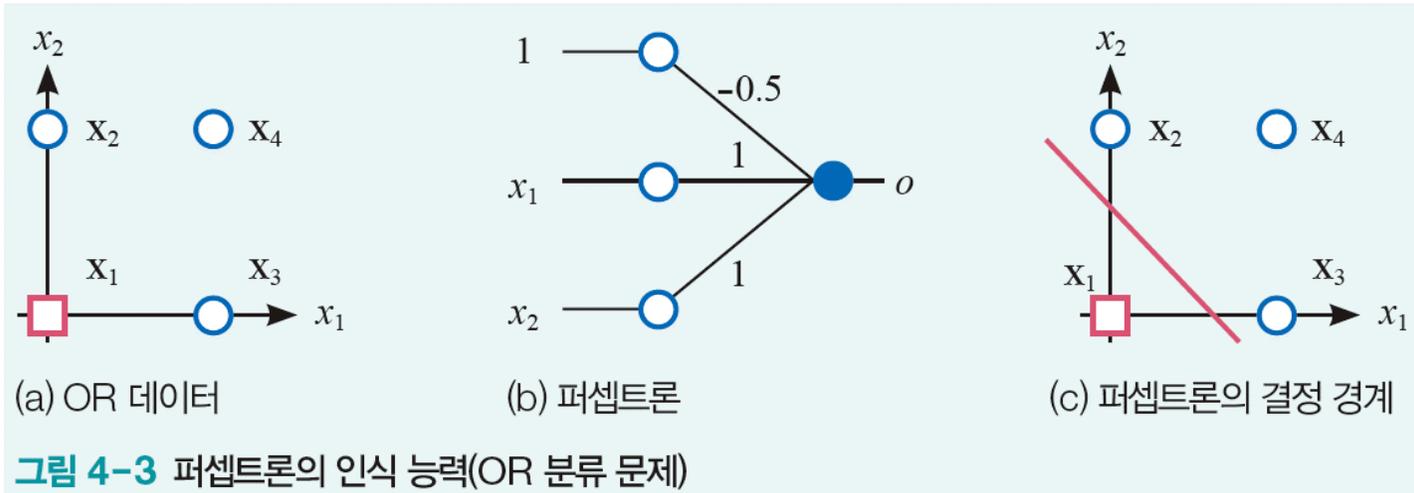
← 특징 벡터

← 레이블 ($y=1$ 은 불량, $y=-1$ 은 우량)

4.2.2 퍼셉트론으로 인식하기

- [그림 4-3(b)]는 데이터를 인식하는 퍼셉트론
 - $x_2=(0,1)$ 샘플을 예측해보면,

$$o = \tau(w_1x_1 + w_2x_2 + w_0) = \tau(1*0 + 1*1 - 0.5) = \tau(0.5) = 1$$



NOTE 논리 연산을 본뜬 OR 데이터와 XOR 데이터

[그림 4-3(a)]의 데이터를 분류하는 문제를 OR 분류라고 한다. 1을 참, 0을 거짓으로 간주하면 이진 논리의 OR 연산에 해당하기 때문이다. 단순하여 설명하기 쉽기 때문에 초심자에게 신경망의 동작을 설명할 때 종종 사용한다. 레이블을 $y_1=-1, y_2=-1, y_3=-1, y_4=1$ 로 설정하면 AND 데이터가 되고, $y_1=-1, y_2=1, y_3=1, y_4=-1$ 로 설정하면 XOR 데이터가 된다.

4.2.2 퍼셉트론으로 인식하기

■ 퍼셉트론을 수학적으로 해석하면([그림 4-3(c)])

- 가중치 $w_0=-0.5$, $w_1=1$, $w_2=1$ 을 식 (4.2)에 대입하면,

$$o = w_1 * x_1 + w_2 * x_2 + w_0 = x_1 + x_2 - 0.5$$

- $o=0$ 으로 설정하면 직선의 방정식을 얻음 → 특징 공간을 분할하는 결정 경계([그림 4-3(c)])

$$x_1 + x_2 - 0.5 = 0 \quad \text{또는} \quad x_2 = -x_1 + 0.5$$

- 퍼셉트론은 특징 공간을 두 부분 공간으로 분할하는 이진 분류기

■ 퍼셉트론은 선형으로 국한됨

■ 퍼셉트론의 행렬 표기는?

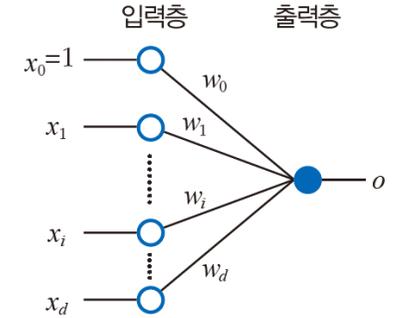
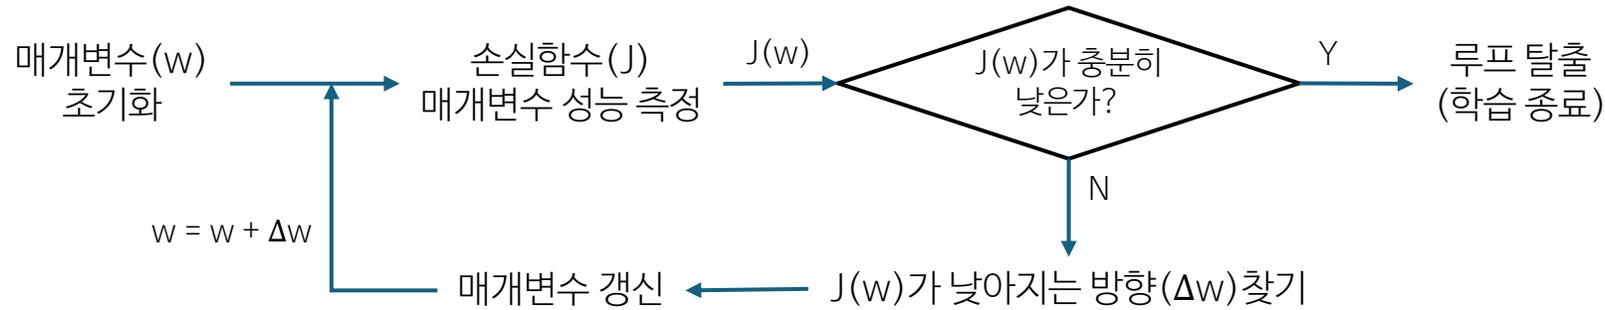
4.3 사람의 학습과 신경망의 학습

■ 퍼셉트론의 학습

- [그림 4-3]에서는 데이터와 함께 데이터를 인식하는 퍼셉트론(가중치)이 주어짐.
즉 데이터로 학습을 마친 퍼셉트론이 주어짐
- 실제 상황에서는 데이터만 주어지므로, 학습 알고리즘으로 가중치(w_0, w_2, \dots, w_d)를 알아내야 함
 - OR 데이터의 경우 2차원 특징 벡터이고 샘플이 4개 뿐이라 연필을 가지고 쉽게 가중치를 알아낼 수 있음
 - sklearn의 필기 숫자 데이터는 64차원 특징 벡터이고 1,797개 샘플을 가지므로 학습 알고리즘 없이 불가능

4.3.2 신경망의 학습 알고리즘

■ 학습 알고리즘 고안



(a) 퍼셉트론의 구조

- 전형적인 최적화 문제(optimization problem)!!
- 손실 함수(loss function) J 를 설계 ([알고리즘 4-3]의 03행)
- 손실 함수의 값을 낮추는 방향을 찾는 방법 ([알고리즘 4-3]의 05행)
- 구현에 필요한 사항
 - 1행의 초기화는 어떻게? 4행의 멈춤 조건은 어떻게?
 - 3행의 손실 함수 정의(보통 오류의 양을 사용)
 - 5행에서 Δw 를 어떻게 구하나? (미분을 사용)

[알고리즘 4-3] 신경망의 학습

입력: 훈련 데이터

출력: 최적의 매개변수 값

01. 난수로 매개변수 벡터 \mathbf{w} 를 초기화한다. # \mathbf{w} 는 신경망의 가중치([그림 4-2(a)]의 (w_0, w_1, \dots, w_d))
02. while (true)
03. \mathbf{w} 에 따라 데이터를 인식하고 손실 함수 $J(\mathbf{w})$ 를 계산한다.
04. if ($J(\mathbf{w})$ 가 만족스러움) break
05. 손실 함수 값을 낮추는 방향 $\Delta \mathbf{w}$ 를 계산한다.
06. $\mathbf{w} = \mathbf{w} + \Delta \mathbf{w}$
07. \mathbf{w} 를 저장한다.

4.4.1 손실 함수 설계

■ 손실 함수 J 가 만족해야 할 조건

- ① \mathbf{w} 가 훈련 집합에 있는 샘플을 모두 맞히면, 즉 정확률이 100%이면 $J(\mathbf{w})$ 는 0이다.
- ② \mathbf{w} 가 틀리는 샘플이 많을수록 $J(\mathbf{w})$ 의 값이 크다.

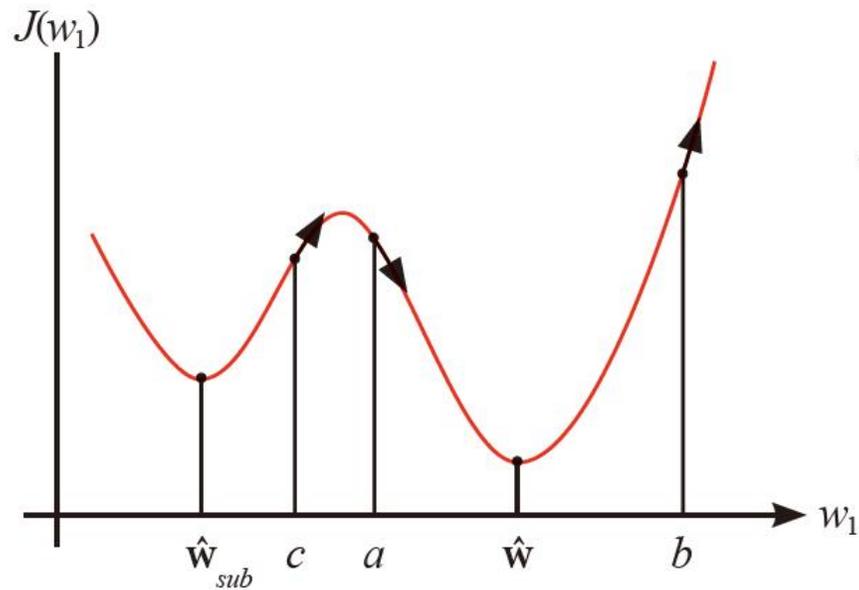
- 조건을 만족하는 함수는 여럿. 식 (4.5)는 그 중 하나로서 직관적으로 이해하기 쉬움
 - I 는 \mathbf{w} 가 틀리는 샘플
 - x 가 +1 부류라면(즉 $y=1$ 이라면), 퍼셉트론의 출력 $\mathbf{w}\mathbf{x}^T$ 는 음수. $-y(\mathbf{w}\mathbf{x}^T)$ 는 양수
 - x 가 -1 부류라면(즉 $y=-1$ 이라면), 퍼셉트론의 출력 $\mathbf{w}\mathbf{x}^T$ 는 양수. $-y(\mathbf{w}\mathbf{x}^T)$ 는 양수
 - 결국 틀린 샘플 x 는 손실 함수의 값을 증가시킴(틀린 샘플이 많을수록 손실 함수 값은 커짐)

$$J(\mathbf{w}) = \sum_{\mathbf{x} \in I} -y(\mathbf{w}\mathbf{x}^T) \quad (4.5)$$

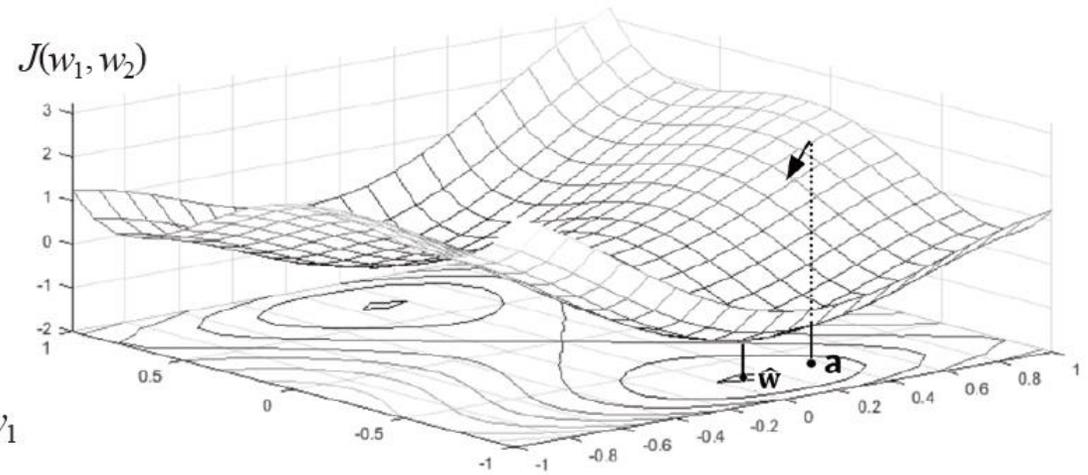
4.4.2 학습 알고리즘 설계

■ 경사 하강법 gradient descent 의 원리 ([그림 4-5]는 가상의 손실 함수)

- 편의상 매개변수가 한 개인 경우와 두 개인 경우를 가지고 설명
- 학습 알고리즘은 J 의 최저점 $\hat{\mathbf{w}}$ 을 찾아야 함



(a) 매개변수가 1개인 경우: $\mathbf{w}=(w_1)$



(b) 매개변수가 2개인 경우: $\mathbf{w}=(w_1, w_2)$

그림 4-5 경사 하강법

4.4.2 학습 알고리즘 설계

■ 학습 규칙 유도 ([그림 4-5(a)]는 매개변수가 하나인 경우)

- 경사 하강법은 미분을 이용하여 최적해를 찾는 기법
- 미분값 $\frac{\partial J}{\partial w_1}$ 의 반대 방향이 최적해에 접근하는 방향이므로 현재 w_1 에 $-\frac{\partial J}{\partial w_1}$ 를 더하면 최적해에 가까워짐
→ 식 (4.6)의 학습 규칙
- 방향은 알지만 얼마큼 가야하는지에 대한 정보가 없기 때문에 학습률 ρ 를 곱하여 조금씩 이동
- ρ 는 하이퍼 매개변수로서 보통 0.001이나 0.0001처럼 작은 값 사용

$$w_1 = w_1 + \rho \left(-\frac{\partial J}{\partial w_1} \right) \quad (4.6)$$

■ 매개변수가 여럿인 경우

- 편미분으로 구한 그레이디언트를 사용 (매개변수 별로 독립적으로 미분)

$$\left. \begin{aligned} \mathbf{w} &= \mathbf{w} + \rho(-\nabla \mathbf{w}) \\ \nabla \mathbf{w} &= \left(\frac{\partial J}{\partial w_0}, \frac{\partial J}{\partial w_1}, \frac{\partial J}{\partial w_2}, \dots, \frac{\partial J}{\partial w_d} \right) \end{aligned} \right\} \quad (4.7)$$

4.4.2 학습 알고리즘 설계

■ 퍼셉트론에 식 (4.7) 적용

- 식 (4.5)를 매개변수 w_i 로 편미분하면,

$$\frac{\partial J}{\partial w_i} = \sum_{\mathbf{x} \in I} \frac{\partial(-y(w_0 + w_1x_1 + \dots + w_ix_i + \dots + w_dx_d))}{\partial w_i} = \sum_{\mathbf{x} \in I} -yx_i$$

- 정리하면,

$$\frac{\partial J}{\partial w_i} = \sum_{\mathbf{x} \in I} -yx_i, \quad i = 0, 1, 2, \dots, d \quad (4.8)$$

- 식 (4.8)을 식 (4.7)에 대입하면,

$$\text{퍼셉트론 학습 규칙: } w_i = w_i + \rho \sum_{\mathbf{x} \in I} yx_i, \quad i = 0, 1, 2, \dots, d \quad (4.9)$$

퍼셉트론 학습 알고리즘이 사용하는 핵심 공식

- 식 (4.9)를 행렬 형태로 쓰면,

$$\text{퍼셉트론의 학습 규칙(행렬 표기): } \mathbf{w} = \mathbf{w} + \rho \sum_{\mathbf{x} \in I} y\mathbf{x} \quad (4.10)$$

4.4.2 학습 알고리즘 설계

■ 퍼셉트론의 학습 알고리즘

- 식 (4.10)을 [알고리즘 4-3]에 적용하면 [알고리즘 4-4]
- 03~08행을 수행하여 훈련 집합에 있는 샘플 전체를 한번 처리하는 일을 세대_{epoch}라 부름

[알고리즘 4-4] 퍼셉트론의 학습

입력: 훈련 집합(n 은 샘플의 개수)

출력: 최적의 매개변수 $\hat{\mathbf{w}}$

```
01. 난수로 매개변수 벡터  $\mathbf{w}$ 를 초기화한다. #  $\mathbf{w}$ 는 퍼셉트론 가중치
02. while (true)
03.    $I=[]$  # 공집합
04.   for  $j=1$  to  $n$ 
05.      $o=\tau(\mathbf{w}\mathbf{x}_j^T)$  # 식 (4.4)를 적용해 인식 수행
06.     if( $o \neq y_j$ )  $I=I \cup \mathbf{x}_j$  # 틀린 샘플을  $I$ 에 추가
07.     if( $I=$ 공집합) break # 모든 샘플을 맞히면(손실 함수가 0) 루프를 빠져 나감
08.      $\mathbf{w}=\mathbf{w}+\rho \sum_{\mathbf{x} \in I} y\mathbf{x}$  # 식 (4.10)을 적용해 매개변수 갱신
09.  $\hat{\mathbf{w}}=\mathbf{w}$ 
```

- [알고리즘 4-4]는 데이터가 선형 분리 불가능한 경우 무한 루프
 - 여러 세대에 걸쳐 I 의 크기가 줄지 않으면 수렴했다고 판단하고 루프를 빠져나오게 수정

4.4.2 학습 알고리즘 설계

- [그림 4-6]은 퍼셉트론의 학습 알고리즘을 개념적으로 설명
 - 알고리즘은 전방 계산(05행) → 오차 계산(06행) → 후방 가중치 갱신을 반복(08행)
 - 딥러닝을 포함하여 신경망 학습 알고리즘은 모두 이 절차를 따름
(딥러닝은 많은 층을 거쳐 전방 계산과 후방 가중치 갱신을 수행)

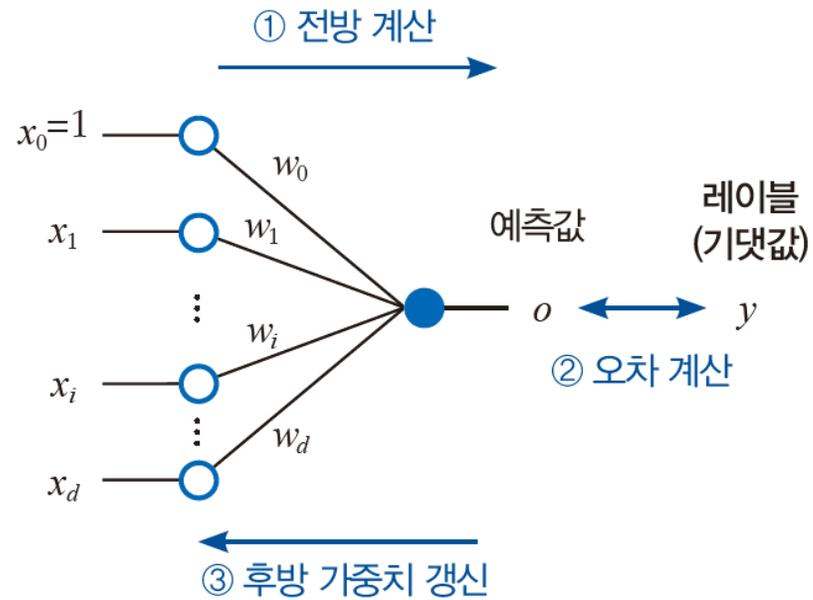


그림 4-6 퍼셉트론 학습 알고리즘의 절차

스토캐스틱 경사하강법(SGD)

■ 에포크(Epoch)와 반복(Iteration)

- Epoch: 학습 과정에서 데이터셋 전체를 1회 학습하는 과정
- Iteration: 모델의 매개변수를 1회 업데이트하는 과정

■ 학습 모드

▪ (Batch) Gradient descent - 배치 모드(Batch mode)

- 학습데이터셋 전체를 한꺼번에 사용해 그래디언트 계산 및 매개변수 갱신 (Epoch = Iteration)
- 모든 데이터 포인트 고려 → 기울기 추정이 정확한 편
- 안정적인 수렴
- 계산이 느리고 메모리 소모가 큼 → 비효율적

↙ 랜덤하게 샘플링해서 데이터 선택

▪ Stochastic gradient descent - 패턴 모드(Pattern mode)

- 랜덤하게 선택된 하나의 데이터 샘플을 사용해 그래디언트 계산 및 매개변수 업데이트
- 위 과정을 모든 데이터셋에 대해 반복하며 학습(한 에포크에서 여러 번의 매개변수 업데이트 발생)
- 빠른 업데이트 → 실시간 학습, 큰 데이터셋에 효율적
- 정확하지 않은 기울기 계산 → local minima 탈출 가능성

→ 수렴과정에서 진동, 학습률 설정 중요

스토캐스틱 경사하강법(SGD)

- Mini-batch gradient descent - 미니 배치 모드(Mini-batch mode) ★ ★ ★

- SGD의 변형
- 데이터셋의 여러 개의 작은 배치로 나누고, 각 배치에 대해 매개변수 업데이트
- 위 과정을 각 배치에 대해 반복하며 학습 진행
- 배치 단위보다 빠르고, SGD 보다 안정적

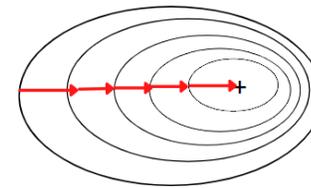


- MNIST 데이터셋을 학습시킨다면

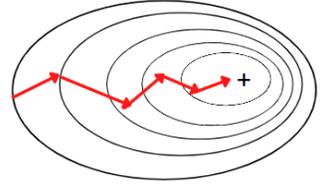
- Training dataset: 60,000 이미지

1Epoch 당	Gradient descent	SGD	Mini-batch (batch=8)
이미지 수	60,000	1	8
Iteration 수	1	60,000	7,500
	안정적/느림	빠름/불안정	균형 잡힘

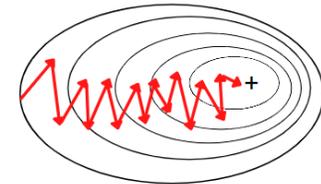
Batch Gradient Descent



Mini-Batch Gradient Descent



Stochastic Gradient Descent



4.5 현대 기계 학습으로 확장

■ 앞 절은

- 이 책에서 수학이 가장 많이 등장하는 절(앞으로는 수학이 적게 등장)
- 단순한 퍼셉트론을 이용하여 기계 학습의 원리를 설명하고 딥러닝으로 도약할 발판을 마련할 목적이었음

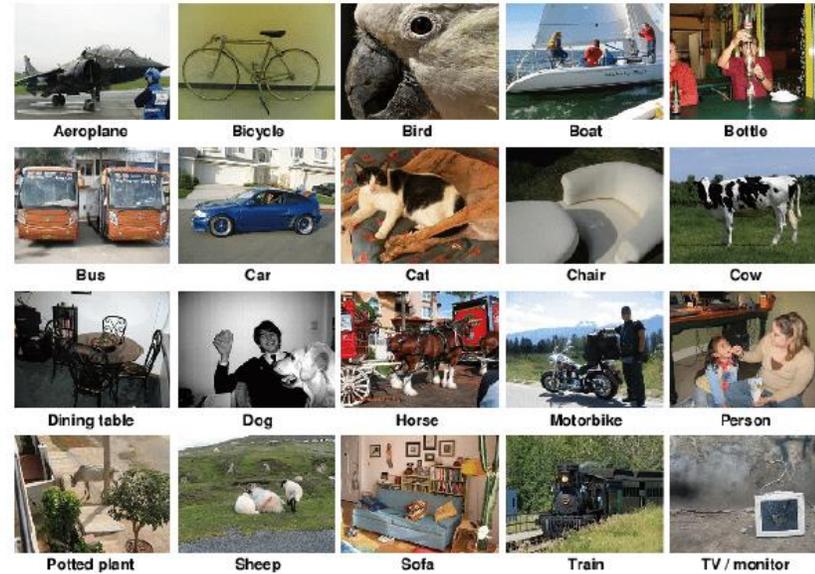
■ 이 절은

- 앞 절에서 공부한 퍼셉트론 원리를 바탕으로 현대 기계 학습으로 개념 확장

4.5.1 현대적인 기계학습의 복잡도

■ [그림 4-7]의 세 가지 문제

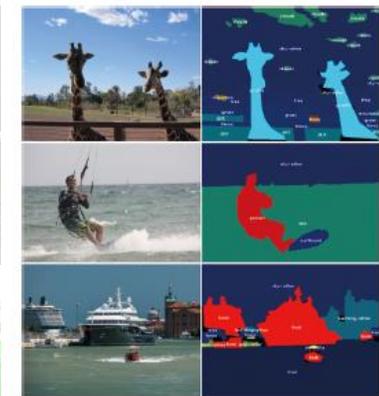
- 분류 classification: 지정된 몇 가지 부류로 구분하는 문제
- 물체 검출 object detection: 물체 위치를 바운딩 박스로 찾아내는 문제
(사진 촬영에서 얼굴 초점 응용)
- 물체 분할 object segmentation: 화소 수준으로 물체를 찾아내는 문제
(추적 대상 물체를 형광색으로 칠하는 응용)



(a) 분류 문제



(b) 검출 문제



(c) 분할 문제

그림 4-7 세 종류의 문제와 데이터셋

4.5.1 현대적인 기계학습의 복잡도

■ 적절한 손실 함수 필요

- 분류: 참 값과 예측 값의 차이를 손실 함수에 반영
- 물체 검출: 참 바운딩 박스와 예측한 바운딩 박스의 겹침 정도 (Intersection of union, IoU)를 손실 함수에 반영
- 물체 분할: 화소 별로 레이블이 지정한 물체에 해당하는지 따지는 손실 함수

■ 실용적인 신경망의 매개변수 개수는 방대

- 예) 딥러닝 모델 ResNet-50은 50개의 층을 가지며 매개변수는 2천300만개 이상
- 다행히 1~2차원에서 개발한 공식이 고차원에 그대로 적용
- 단지 과잉 적합을 방지하기 위해 더 많은 데이터 사용 또는 더 정교한 규제 기법 적용. 속도 향상을 위한 GPU 사용

4.5.2 스토캐스틱 경사 하강법

■ 경사 하강법

- 자연과학과 공학에서 오랫동안 사용해온 최적화 방법 ([그림 4-5])
- 예) 항공공학자
 - 날개를 설계할 때 두께, 폭, 길이, 곡률 등을 매개변수로 설정한 다음 유체 역학 이론을 기반으로 손실 함수 정의
 - 손실 함수는 매개변수 변화에 따른 연료 소비량을 측정
 - 경사 하강법으로 최적해를 구한 다음 날개 제작

■ 기계 학습의 경사 하강법

- 여러 측면에서 표준 경사 하강법과 다름
 - 잡음이 섞인 데이터가 개입
 - 매개변수가 방대
 - 일반화 능력 필요

← 이런 특성은 최적해를 찾는 일을 어렵게 만듦. 정확률이 등락을 거듭하며 수렴하지 않는다거나 훈련 집합에 대해 높은 성능을 얻었는데 테스트 집합에 대해 형편 없는 성능 등의 문제

4.5.2 스토캐스틱 경사 하강법

■ 기계 학습은 스토캐스틱 경사 하강법으로 확장하여 사용

▪ 배치 모드 vs. 패턴 모드

- [알고리즘 4-4]는 배치 모드: 틀린 샘플을 모은 다음 한꺼번에 매개변수 갱신
- 패턴 모드는 패턴 별로 매개변수 갱신(세대를 시작할 때 샘플을 뒤섞어 랜덤 샘플링 효과 제공)

▪ 딥러닝은 주로 미니 배치 사용(패턴 모드와 배치 모드의 중간)

- 훈련 집합을 일정한 크기의 부분 집합으로 나눈 다음 부분 집합 별로 처리
- 부분 집합으로 나눌 때 랜덤 샘플링을 적용하기 때문에 스토캐스틱 경사 하강법(SGD, stochastic gradient descent)이라 부름

4.7 다층 퍼셉트론

■ 퍼셉트론은 선형이라는 한계

- [그림 4-9]의 선형 분리 불가능한 데이터에서는 높은 오류율 ([프로그램 4-2]의 6.12% 오류율의 원인)

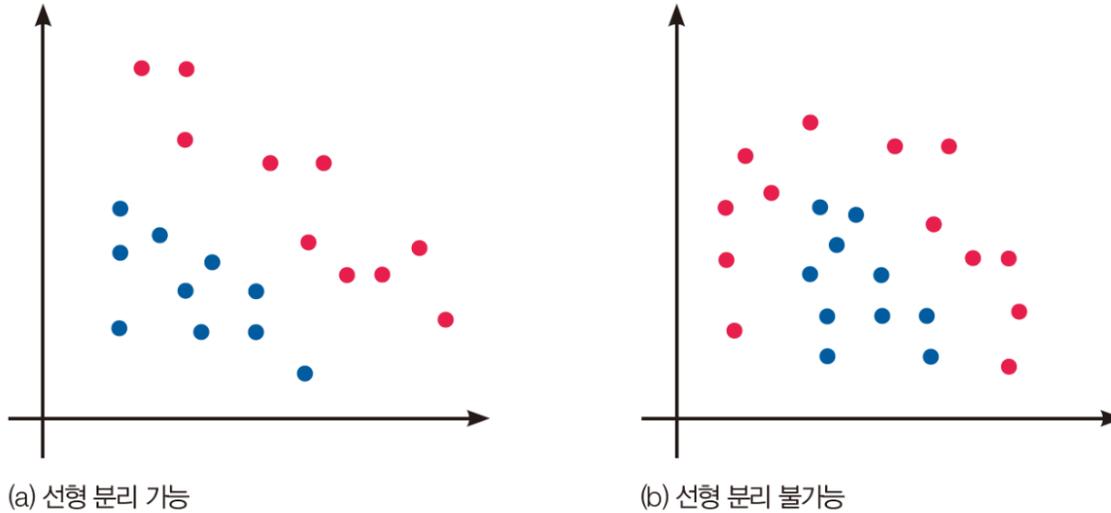


그림 4-9 데이터의 선형 분리 가능성

- XOR에서는 25% 오뉴플 ([그림 4-10(a)])

■ 이 절에서는 은닉층을 추가한 다층 퍼셉트론으로 비선형으로 확장

4.7.1 특징 공간 변환

- 퍼셉트론 두 개로 특징 공간을 세 개의 부분 공간으로 나눌 수 있음

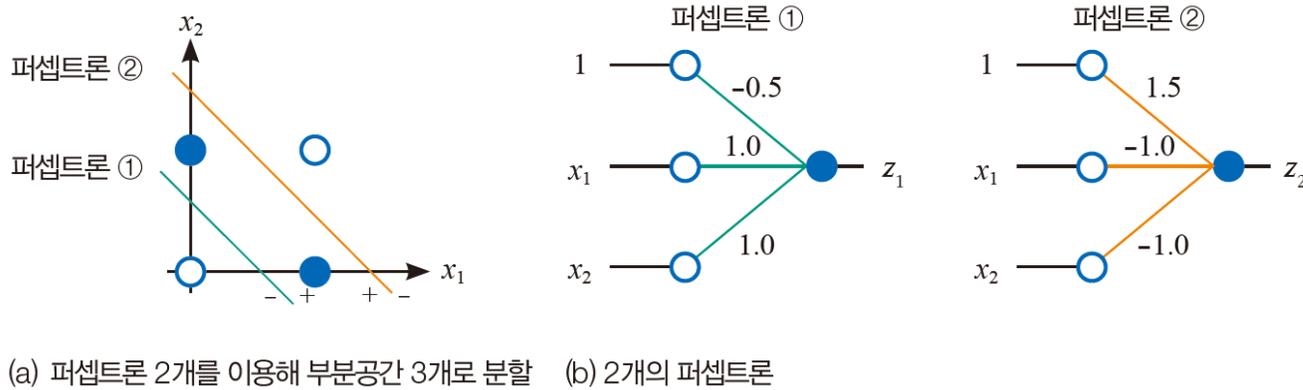


그림 4-10 퍼셉트론 2개로 XOR 데이터를 인식하는 길을 찾음

- 두 퍼셉트론을 병렬로 결합하면 (x_1, x_2) 공간을 (z_1, z_2) 공간으로 변환

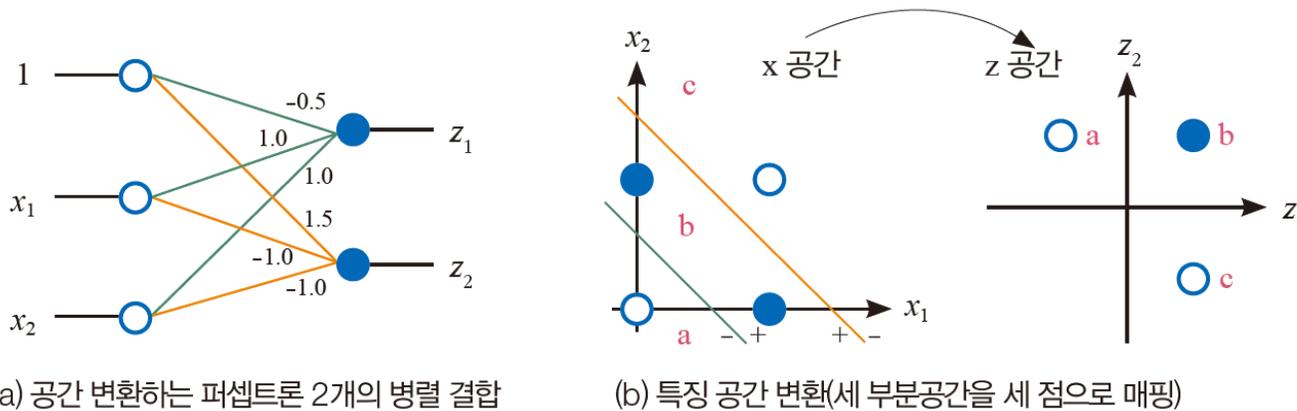
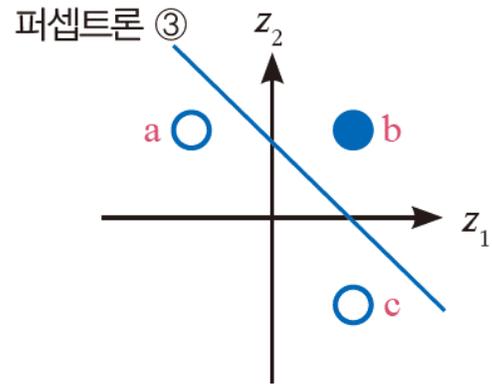


그림 4-11 퍼셉트론 2개를 병렬 결합해 특징 공간을 변환

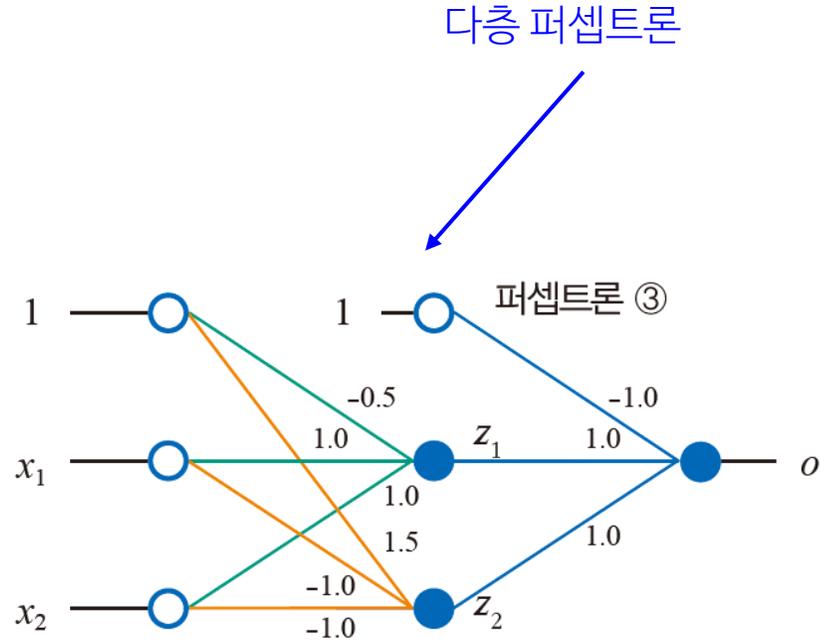
4.7.1 특징 공간 변환

■ 새로운 공간 (z_1, z_2)의 흥미로운 특성

- 선형 분리 불가능하던 네 점이 선형 분리 가능해짐
- 퍼셉트론을 하나 더 쓰면 XOR 문제를 푸는 신경망 완성



(a) 공간 분할하는 세 번째 퍼셉트론



(b) 세 번째 퍼셉트론을 순차적으로 덧붙임

그림 4-12 다층 퍼셉트론

4.7.1 특징 공간 변환

■ [예제 4-2] XOR를 푸는 다층 퍼셉트론

[그림 4-12(b)]의 다층 퍼셉트론에 XOR 데이터의 샘플 4개를 차례로 입력하고 제대로 인식하는지 확인해보자. 아래 표는 샘플 4개를 인식하는 과정을 보여준다. 100% 옳게 분류하는 것을 확인할 수 있다.

원래 특징 공간(x_1, x_2)	은닉 특징 공간(z_1, z_2)	출력 o	레이블 y
(0,0)	(-1,1)	-1	-1
(0,1)	(1,1)	1	1
(1,0)	(1,1)	1	1
(1,1)	(1,-1)	-1	-1

4.7.1 특징 공간 변환

■ 신경망을 공간 변환기로 볼 수 있음

- 원래 특징 공간을 임시 공간으로 변환하고, 임시 공간을 레이블 공간으로 변환하는 두 단계 처리
- 임시 공간에 해당하는 층을 은닉층 hidden layer 이라 부름. 임시 공간을 은닉 공간 hidden space 또는 잠복 공간 latent space 이라 부름
- 새로운 공간은 이전 공간보다 분류에 더 유리하도록 학습됨
- 자연 영상이나 자연어처럼 복잡한 데이터는 대여섯 은닉층 또는 수십~수백 개의 은닉층 → 이런 깊은 신경망의 학습을 딥러닝이라 부름

4.7.2 다층 퍼셉트론의 구조

- 입력층, 은닉층, 출력층으로 구성된 다층 퍼셉트론
 - 층을 연결하는 가중치 문치가 두 개 있어 3층이 아니라 2층 신경망으로 간주함
 - 데이터에 따라 입력층과 출력층의 노드 개수 확정
 - 예) iris에서는 5개의 입력 노드와 3개의 출력 노드
 - 은닉층의 노드 개수는 하이퍼 매개변수
 - 은닉 노드가 많으면 신경망 용량이 커지지만 과잉 적합 가능성 높아짐

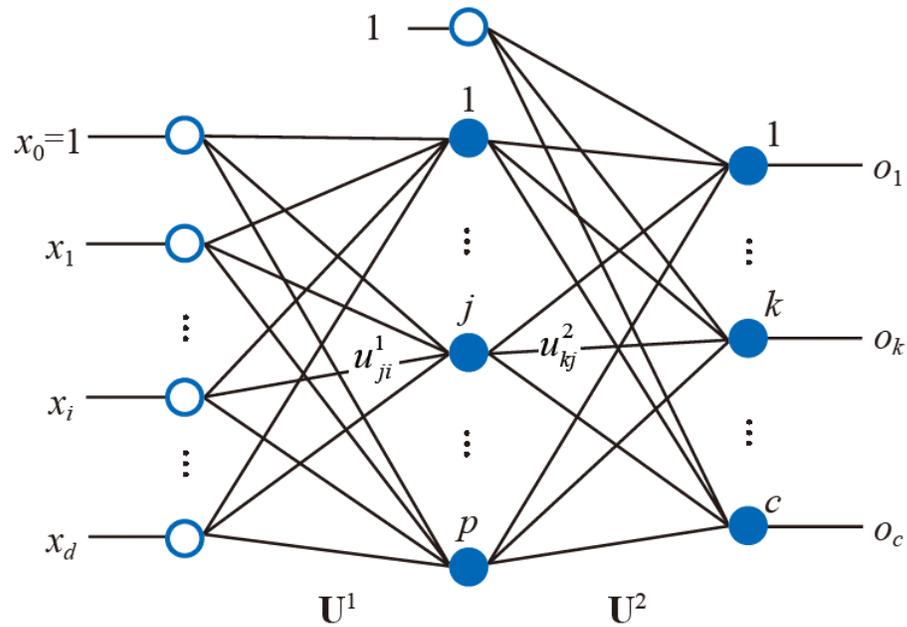


그림 4-13 다층 퍼셉트론의 구조

4.7.2 다층 퍼셉트론의 구조

■ 가중치 행렬 \mathbf{U}^1 과 \mathbf{U}^2

- u_{ji}^1 은 i 번째 입력 노드와 j 번째 은닉 노드를 연결하는 가중치
- u_{kj}^2 는 j 번째 은닉 노드와 k 번째 출력 노드를 연결하는 가중치

$$\mathbf{U}^1 = \begin{pmatrix} u_{10}^1 & u_{11}^1 & \cdots & u_{1d}^1 \\ u_{20}^1 & u_{21}^1 & \cdots & u_{2d}^1 \\ \vdots & \vdots & \ddots & \vdots \\ u_{p0}^1 & u_{p1}^1 & \cdots & u_{pd}^1 \end{pmatrix}, \quad \mathbf{U}^2 = \begin{pmatrix} u_{10}^2 & u_{11}^2 & \cdots & u_{1p}^2 \\ u_{20}^2 & u_{21}^2 & \cdots & u_{2p}^2 \\ \vdots & \vdots & \ddots & \vdots \\ u_{c0}^2 & u_{c1}^2 & \cdots & u_{cp}^2 \end{pmatrix} \quad (4.11)$$

4.7.3 다층 퍼셉트론의 동작

■ j번째 은닉 노드의 동작 ([그림 4-13])

- \mathbf{u}_j^1 은 U^1 의 j번째 행
- 은닉층 때문에 첨자가 많아져 복잡해 보이지만 본질적으로 퍼셉트론의 식 (4.2)와 동일

j번째 은닉 노드의 연산:

$$z_j = \tau_1(s_j), j = 1, 2, \dots, p \quad (4.12)$$

이때 $s_j = \mathbf{u}_j^1 \mathbf{x}^T$ 이고 $\mathbf{u}_j^1 = (u_{j0}^1, u_{j1}^1, \dots, u_{jd}^1)$, $\mathbf{x} = (1, x_1, x_2, \dots, x_d)$

■ k번째 출력 노드의 동작

- \mathbf{u}_k^2 는 U^2 의 k번째 행

k번째 은닉 노드의 연산:

$$o_k = \tau_2(s_k), k = 1, 2, \dots, c \quad (4.13)$$

이때 $s_k = \mathbf{u}_k^2 \mathbf{z}^T$ 이고 $\mathbf{u}_k^2 = (u_{k0}^2, u_{k1}^2, \dots, u_{kp}^2)$, $\mathbf{z} = (1, z_1, z_2, \dots, z_p)$

4.7.3 다층 퍼셉트론의 동작

■ [예제 4-3] 다층 퍼셉트론의 동작

- [그림 4-12(b)] 다층 퍼셉트론의 가중치 행렬($d=2, p=2, c=1$)

$$\mathbf{U}^1 = \begin{pmatrix} -0.5 & 1.0 & 1.0 \\ 1.5 & -1.0 & -1.0 \end{pmatrix}, \mathbf{U}^2 = (-1 \quad 1.0 \quad 1.0)$$

- 샘플을 하나씩 처리하는 식 (4.14) 적용

- $\mathbf{x}=(0,1)$ 샘플을 처리(계단 함수 사용, 바이어스 항을 추가해 $(1,0,1)$ 형식으로 입력)

$$\begin{aligned} \mathbf{O} &= \tau_2 \left((-1 \quad 1.0 \quad 1.0) \tau_1 \left(\begin{pmatrix} -0.5 & 1.0 & 1.0 \\ 1.5 & -1.0 & -1.0 \end{pmatrix} \begin{pmatrix} 1 \\ 0 \\ 1 \end{pmatrix} \right) \right) \\ &= \tau_2 \left((-1 \quad 1.0 \quad 1.0) \tau_1 \left(\begin{pmatrix} 0.5 \\ 0.5 \end{pmatrix} \right) \right) \\ &= \tau_2 \left((-1 \quad 1.0 \quad 1.0) \begin{pmatrix} 1 \\ 1.0 \\ 1.0 \end{pmatrix} \right) \\ &= \tau_2 \left((1) \right) = 1 \quad \leftarrow \text{레이블과 같으므로 맞음} \end{aligned}$$

4.7.3 다층 퍼셉트론의 동작

■ [예제 4-3] 다층 퍼셉트론의 동작(...앞에서 계속)

- 데이터를 한꺼번에 처리하는 식 (4.16) 적용

$$\mathbf{X} = \begin{pmatrix} 1 & 0 & 0 \\ 1 & 0 & 1 \\ 1 & 1 & 0 \\ 1 & 1 & 1 \end{pmatrix}$$

$$\begin{aligned} \mathbf{O} &= \tau_2 \left((-1 \ 1.0 \ 1.0) \tau_1 \left(\begin{pmatrix} -0.5 & 1.0 & 1.0 \\ 1.5 & -1.0 & -1.0 \end{pmatrix} \begin{pmatrix} 1 & 1 & 1 & 1 \\ 0 & 0 & 1 & 1 \\ 0 & 1 & 0 & 1 \end{pmatrix} \right) \right) \\ &= \tau_2 \left((-1 \ 1.0 \ 1.0) \tau_1 \left(\begin{pmatrix} -0.5 & 0.5 & 0.5 & 1.5 \\ 1.5 & 0.5 & 0.5 & -0.5 \end{pmatrix} \right) \right) \\ &= \tau_2 \left((-1 \ 1.0 \ 1.0) \begin{pmatrix} 1 & 1 & 1 & 1 \\ -1.0 & 1.0 & 1.0 & 1.0 \\ 1.0 & 1.0 & 1.0 & -1.0 \end{pmatrix} \right) \\ &= \tau_2 \left((-1 \ 1 \ 1 \ -1) \right) = (-1 \ 1 \ 1 \ -1) \end{aligned}$$

네 개 샘플의 레이블과 같으므로 모두 맞힘

4.7.3 다층 퍼셉트론의 동작

■ 출력 벡터 \mathbf{O} 의 모양

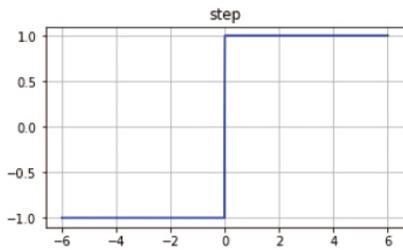
- [예제 4-3]은 출력 노드가 하나이고 샘플이 4개이므로 \mathbf{O} 는 1*4 행렬
- 일반적으로 출력 노드가 c 이고(c 는 부류 개수) 샘플이 n 개 이면 \mathbf{O} 는 $c*n$ 행렬
- 열은 샘플을 나타내며, 값이 가장 큰 인덱스를 최종 분류 결과로 출력
- 예) 숫자 인식

$$\mathbf{O} = \begin{pmatrix} 0.1 & 0 & 0.9 & 0 & \dots & 0.78 \\ 0 & 0 & 0 & 0 & & 0 \\ 0 & 0 & 0 & 0 & & 0 \\ 0.001 & 0 & 0 & 0.01 & & 0 \\ 0.899 & 0 & 0 & 0 & \dots & 0.02 \\ 0 & 0 & 0 & 0.99 & & 0 \\ 0 & 0.22 & 0.1 & 0 & & 0.2 \\ 0 & 0 & 0 & 0 & & 0 \\ 0 & 0 & 0 & 0 & & 0 \\ 0 & 0.78 & 0 & 0 & & 0 \end{pmatrix} \rightarrow \text{최종 분류 결과} = (4 \ 9 \ 0 \ 5 \ \dots \ 0)$$

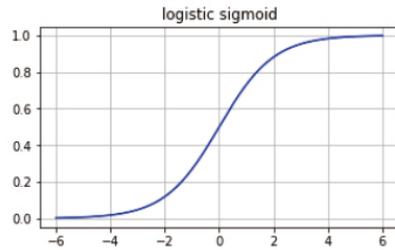
4.7.4 활성화 함수

■ 다양한 활성화 함수

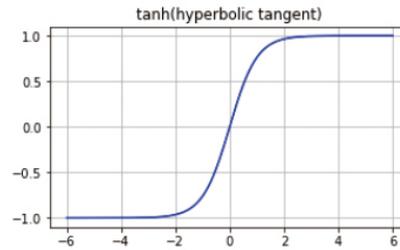
- 퍼셉트론은 계단 함수를 사용하는데, 예측 결과를 0~1 사이의 확률로 표현해야 하는 경우에 계단 함수는 부적절함
- 따라서 다층 퍼셉트론은 시그모이드, 딥러닝은 ReLU와 softmax를 주로 사용 → 비선형성!



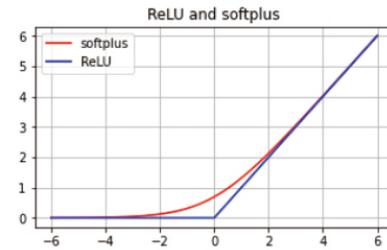
(a) 계단 함수



(b) 로지스틱 시그모이드



(c) 하이퍼볼릭 탄젠트 시그모이드



(d) 소프트플러스와 ReLU

그림 4-14 신경망이 사용하는 다양한 활성화 함수

4.7.4 활성화 함수

■ 다양한 활성화 함수

표 4-1 신경망에서 사용하는 여러 가지 활성화 함수

함수 이름	함수	1차 도함수	범위
계단	$\tau(s) = \begin{cases} 1 & s \geq 0 \\ -1 & s < 0 \end{cases}$	$\tau'(s) = \begin{cases} 0 & s \neq 0 \\ \text{불가} & s = 0 \end{cases}$	-1과 1
로지스틱 시그모이드	$\tau(s) = \frac{1}{1+e^{-as}}$	$\tau'(s) = a\tau(s)(1-\tau(s))$	(0,1)
하이퍼볼릭 탄젠트 (tanh) 시그모이드	$\tau(s) = \frac{2}{1+e^{-as}} - 1$	$\tau'(s) = \frac{a}{2}(1-\tau(s)^2)$	(-1,1)
소프트플러스	$\tau(s) = \log_e(1+e^s)$	$\tau'(s) = \frac{1}{1+e^{-s}}$	(0,∞)
렉티파이어(ReLU)	$\tau(s) = \max(0, s)$	$\tau'(s) = \begin{cases} 0 & s < 0 \\ 1 & s > 0 \\ \text{불가} & s = 0 \end{cases}$	(0,∞)

■ 출력층에서 주로 사용하는 소프트맥스 함수 (확률로 간주할 수 있음)

$$o_k = \frac{e^{s_k}}{\sum_{i=1,c} e^{s_i}} \quad (4.17) \quad \leftarrow o_1 + o_2 + \dots + o_c = 1.0 \text{을 만족함}$$

4.8 오류 역전파 알고리즘

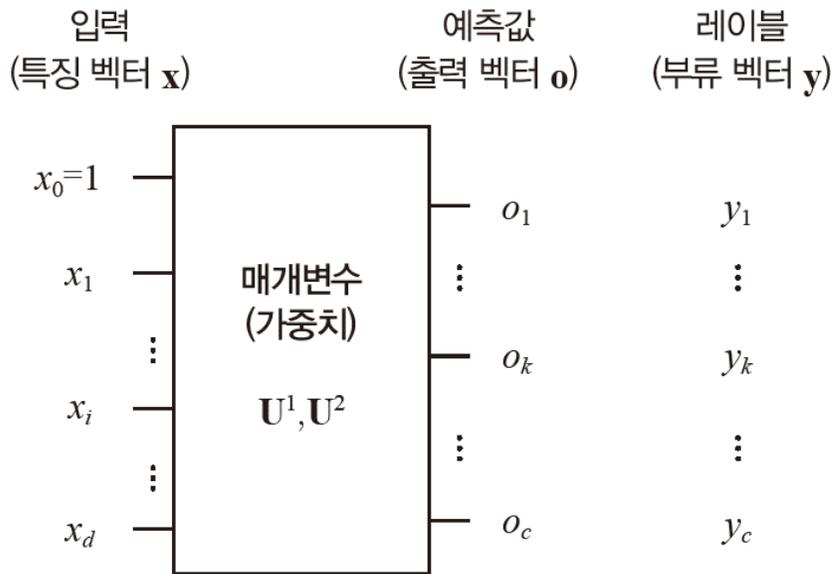
- 다층 퍼셉트론은 오류 역전파 알고리즘으로 학습함

- 은닉층이 있고 활성화 함수가 시그모이드이므로 퍼셉트론 학습 알고리즘보다 복잡하지만 기본 원리는 같음

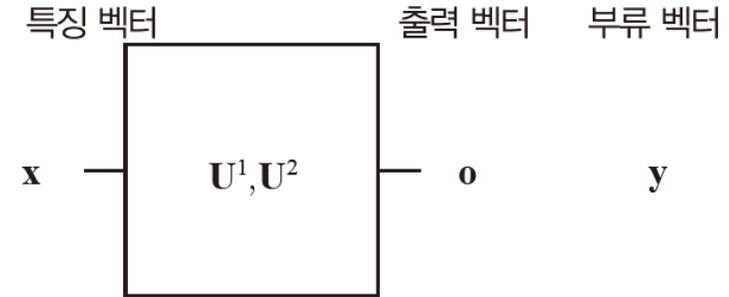
4.8.1 손실 함수 설계

■ 다층 퍼셉트론의 블록 다이어그램

- 신경망의 출력 벡터(예측값) \mathbf{o} 가 부류 벡터(참값) \mathbf{y} 와 같을수록 매개변수 U^1 과 U^2 는 데이터를 잘 인식. 다르면 \mathbf{o} 와 \mathbf{y} 가 가까워지도록 U^1 과 U^2 를 갱신해야 함. 오차가 클수록 갱신하는 양이 큼



(a) 입력과 출력, 기댓값의 관계



(b) 벡터 표현

그림 4-15 다층 퍼셉트론의 블록 다이어그램

4.8.1 손실 함수 설계

■ 샘플 하나의 오차를 측정하는 손실 함수

- 보통 \mathbf{y} 는 원핫 코드로 표현. 예) 숫자 0이면 $\mathbf{y}=(1,0,0,\dots,0)$, 2면 $\mathbf{y}=(0,0,1,0,\dots,0)$

$$J(\mathbf{U}^1, \mathbf{U}^2) = \sqrt{(y_1 - o_1)^2 + (y_2 - o_2)^2 + \dots + (y_c - o_c)^2} = \|\mathbf{y} - \mathbf{o}\| \quad (4.18)$$

■ 식 (4.18)을 확장

- 계산 편의를 위해 제곱을 하여 제곱근 제거
- 미니 배치 단위로 처리(샘플의 오차를 평균)

평균제곱오차(MSE, mean squared error)

$$\begin{aligned} J(\mathbf{U}^1, \mathbf{U}^2) &= \frac{1}{|M|} \sum_{\mathbf{x} \in M} \|\mathbf{y} - \mathbf{o}\|^2 \\ &= \frac{1}{|M|} \sum_{\mathbf{x} \in M} \left\| \mathbf{y} - \tau_2 \left(\mathbf{U}^2 \tau_1 \left(\mathbf{U}^1 \mathbf{x}^T \right) \right) \right\|^2 \end{aligned} \quad (4.19)$$

4.8.2 학습 알고리즘

■ 가중치 갱신 규칙

- 퍼셉트론과 비슷
- $\frac{\partial J}{\partial u_{ji}^1}$ 와 $\frac{\partial J}{\partial u_{kj}^2}$ 를 구하는 과정은 생략

$$\begin{aligned} \mathbf{U}^2 &= \mathbf{U}^2 + \rho(-\nabla \mathbf{U}^2) & \mathbf{U}^1 &= \mathbf{U}^1 + \rho(-\nabla \mathbf{U}^1) \\ \nabla \mathbf{U}^2 &= \begin{pmatrix} \frac{\partial J}{\partial u_{10}^2} & \frac{\partial J}{\partial u_{11}^2} & \cdots & \frac{\partial J}{\partial u_{1p}^2} \\ \frac{\partial J}{\partial u_{20}^2} & \frac{\partial J}{\partial u_{21}^2} & \cdots & \frac{\partial J}{\partial u_{2p}^2} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial J}{\partial u_{c0}^2} & \frac{\partial J}{\partial u_{c1}^2} & \cdots & \frac{\partial J}{\partial u_{cp}^2} \end{pmatrix} & \nabla \mathbf{U}^1 &= \begin{pmatrix} \frac{\partial J}{\partial u_{10}^1} & \frac{\partial J}{\partial u_{11}^1} & \cdots & \frac{\partial J}{\partial u_{1d}^1} \\ \frac{\partial J}{\partial u_{20}^1} & \frac{\partial J}{\partial u_{21}^1} & \cdots & \frac{\partial J}{\partial u_{2d}^1} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial J}{\partial u_{p0}^1} & \frac{\partial J}{\partial u_{p1}^1} & \cdots & \frac{\partial J}{\partial u_{pd}^1} \end{pmatrix} \end{aligned} \quad (4.20)$$

TIP 미분값을 구하는 수식 유도는 이 책의 범위를 넘으므로 생략한다. 관심있는 독자는 「기계 학습(오일석, 한빛아카데미)」의 3.4절을 참조한다.

4.8.2 학습 알고리즘

■ 오류 역전파 error-backpropagation 학습 알고리즘

- 출력층에서 시작하여 역방향으로 오류를 전파한다는 뜻에서 오류 역전파라 부름

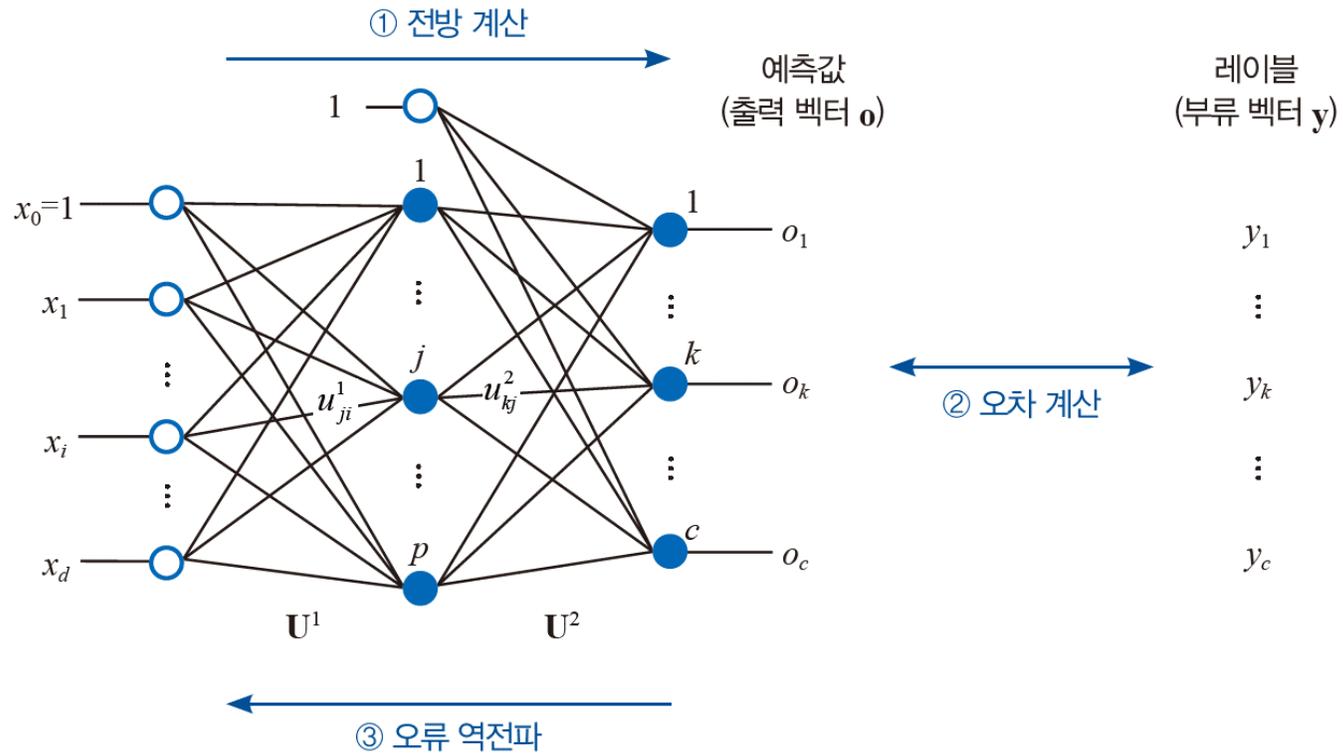


그림 4-16 오류 역전파 학습 알고리즘

4.9 다층 퍼셉트론 프로그래밍

■ 다층 퍼셉트론

- 1980~1990년대 실용적인 시스템을 구현하는데 널리 사용
- 현재도 사용됨

4.9.1 sklearn의 필기 숫자 데이터셋

■ [프로그램 4-3]

프로그램 4-3 sklearn 필기 숫자 데이터에 다층 퍼셉트론 적용

```
01 from sklearn import datasets
02 from sklearn.neural_network import MLPClassifier
03 from sklearn.model_selection import train_test_split
04 import numpy as np
05
06 # 데이터셋을 읽고 훈련 집합과 테스트 집합으로 분할
07 digit=datasets.load_digits()
08 x_train,x_test,y_train,y_test=train_test_split(digit.data,digit.target,train_
size=0.6)
09
10 # MLP 분류기 모델을 학습
11 mlp=MLPClassifier(hidden_layer_sizes=(100),learning_rate_init=0.001,batch_
size=32,max_iter=300,solver='sgd',verbose=True)
12 mlp.fit(x_train,y_train)
13
14 res=mlp.predict(x_test) # 테스트 집합으로 예측
15
16 # 혼동 행렬
17 conf=np.zeros((10,10))
18 for i in range(len(res)):
```

4.9.1 sklearn의 필기 숫자 데이터셋

```
19     conf[res[i]][y_test[i]]+=1
20     print(conf)
21
22     # 정확률 계산
23     no_correct=0
24     for i in range(10):
25         no_correct+=conf[i][i]
26     accuracy=no_correct/len(res)
27     print("테스트 집합에 대한 정확률은 ", accuracy*100, "%입니다.")
```

4.9.1 sklearn의 필기 숫자 데이터셋

■ 실행 결과

- 정확률 97.2%로서 [프로그램 3-6]의 SVM(C [프로그램 4-2]의 퍼셉트론(93.8%)보다 우수

```
Iteration 1, loss = 1.93427517
Iteration 2, loss = 0.32451464
Iteration 3, loss = 0.20142691
Iteration 4, loss = 0.14313824
...
Iteration 40, loss = 0.01163957
Iteration 41, loss = 0.01127886
...
Iteration 80, loss = 0.00538125
Iteration 81, loss = 0.00538663
...
Iteration 107, loss = 0.00405861
Iteration 108, loss = 0.00402524
Iteration 109, loss = 0.00397349
Training loss did not improve more than tol=0.000100 for 10 consecutive epochs. Stopping.
```

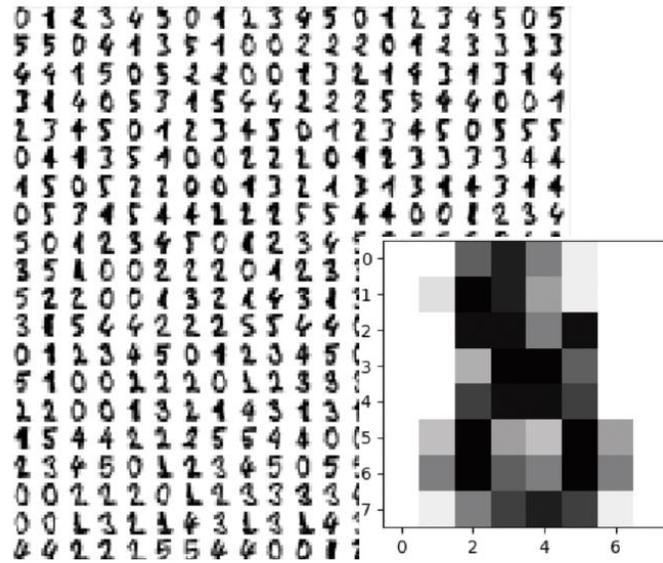
```
[[73.  0.  0.  0.  0.  0.  0.  0.  0.  0.]
 [ 0. 69.  1.  0.  1.  0.  1.  0.  1.  0.]
 [ 0.  0. 70.  1.  0.  0.  0.  0.  0.  0.]
 [ 0.  0.  0. 67.  0.  0.  0.  0.  1.  3.]
 [ 1.  0.  0.  0. 77.  0.  1.  0.  0.  0.]
 [ 1.  0.  0.  0.  0. 64.  1.  0.  0.  1.]
 [ 0.  0.  0.  0.  0.  0. 67.  0.  0.  0.]
 [ 0.  0.  0.  1.  0.  1.  0. 83.  0.  0.]
 [ 0.  2.  0.  0.  0.  0.  0.  1. 58.  0.]
 [ 0.  0.  0.  1.  0.  0.  0.  0.  0. 71.]]
```

테스트 집합에 대한 정확률은 97.2183588317107%입니다.

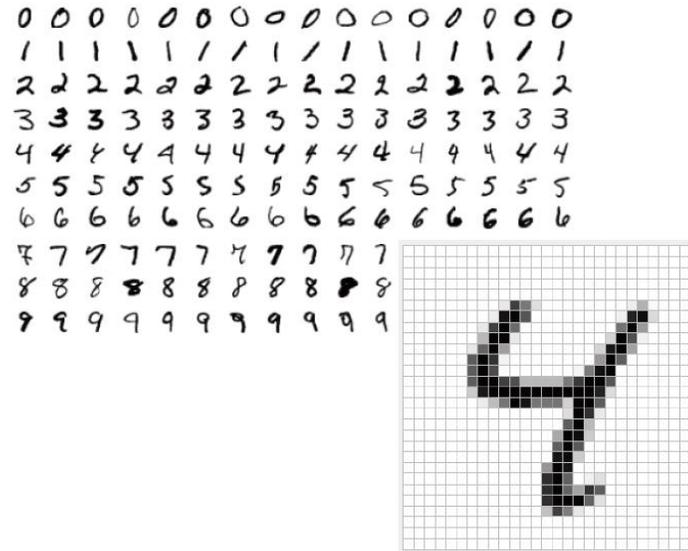
4.9.2 MNIST 데이터셋으로 확장하기

■ MNIST 필기 숫자 데이터셋 ([그림 3-6(b)])

- 훈련 집합 60000자 + 테스트 집합 10000자
- 샘플은 28*28 맵으로 표현



(a) sklearn에서 제공하는 데이터셋



(b) MNIST 데이터셋

그림 3-6 필기 숫자 데이터셋

4.9.2 MNIST 데이터셋으로 확장하기

■ [프로그램 4-4]

- [프로그램 4-3]과 매우 유사

09~10행: 앞 6만 자를 훈련,
뒤 1만 자를 테스트로 분할

프로그램 4-4 MNIST 데이터셋을 다층 퍼셉트론으로 인식

```
01 from sklearn.datasets import fetch_openml
02 from sklearn.neural_network import MLPClassifier
03 import matplotlib.pyplot as plt
04 import numpy as np
05
06 # MNIST 데이터셋을 읽고 훈련 집합과 테스트 집합으로 분할
07 mnist=fetch_openml('mnist_784')
08 mnist.data=mnist.data/255.0
09 x_train=mnist.data[:60000]; x_test=mnist.data[60000:]
10 y_train=np.int16(mnist.target[:60000]); y_test=np.int16(mnist.target[60000:])
11
12 # MLP 분류기 모델을 학습
13 mlp=MLPClassifier(hidden_layer_sizes=(100),learning_rate_init=0.001,batch_
size=512,max_iter=300,solver='adam',verbose=True)
14 mlp.fit(x_train,y_train)
15
16 # 테스트 집합으로 예측
17 res=mlp.predict(x_test)
18
19 # 혼동 행렬
20 conf=np.zeros((10,10),dtype=np.int16)
21 for i in range(len(res)):
22     conf[res[i]][y_test[i]]+=1
23 print(conf)
24
25 # 정확률 계산
26 no_correct=0
27 for i in range(10):
28     no_correct+=conf[i][i]
29 accuracy=no_correct/len(res)
30 print("테스트 집합에 대한 정확률은", accuracy*100, "%입니다.")
```

8행: [0,255] 범위를 [0,1] 범위로 변환

4.9.2 MNIST 데이터셋으로 확장하기

■ 실행 결과 97.78% 정확률을 얻음

```
Iteration 1, loss = 0.61803286
Iteration 2, loss = 0.26101832
Iteration 3, loss = 0.20624874
Iteration 4, loss = 0.17280300
...
Iteration 82, loss = 0.00074115
Iteration 83, loss = 0.00072676
Iteration 84, loss = 0.00067264
Iteration 85, loss = 0.00065032
Training loss did not improve more than tol=0.000100 for 10 consecutive epochs.
Stopping.
```

```
[[ 970   0   4   0   0   1   4   0   4   1]
 [  0 1124   2   0   0   0   2   4   1   3]
 [  1   3 1002   6   3   0   1  10   4   0]
 [  0   1   6  988   2  10   1   1   6   5]
 [  1   0   2   2  964   2   4   3   7   9]
 [  1   1   0   3   0  863   3   0   4   3]
 [  2   2   2   0   2   7  942   0   0   1]
 [  1   1   5   5   3   2   0 1003   3   6]
 [  3   3   8   3   1   4   1   3  942   1]
 [  1   0   1   3   7   3   0   4   3  980]]
```

테스트 집합에 대한 정확률은 97.78%입니다.

4.10 하이퍼 매개변수 최적화

■ 하이퍼 매개변수

- 모델의 구조와 모델의 학습 과정을 제어하는 역할. 예) 은닉 노드 개수, 식 (4.20)의 학습률, 미니 배치 크기 등
- [프로그램 4-3]의 경우 은닉 노드는 100개, 학습률은 0.001 ← 어떻게 결정했나?
- 이 절에서는 체계적으로 최적의 하이퍼 매개변수 값을 결정하는 방법을 공부

4.10.1 하이퍼 매개변수 살피기

- [프로그램 4-3] 11행의 MLPClassifier 함수는 6개의 매개변수를 가짐

```
mlp=MLPClassifier(hidden_layer_sizes=(100), learning_rate_init=0.001, batch_size=32, max_iter=300, solver='sgd', verbose=True)
```

- 앞의 5개는 하이퍼 매개변수
 - hidden_layer_sizes=(100): 100개 노드를 가진 은닉층 한 개를 둠(100개와 80개 노드를 가진 은닉층 두 개를 설정하려면 hidden_layer_sizes=(100,80)으로 함)
 - learning_rate_init=0.001: 식 (4.20)의 학습률 ρ 를 0.001로 설정
 - batch_size=32: 미니 배치 크기를 32로 설정
 - max_iter=300: 최대 세대 수를 300으로 설정
 - solver='sgd': 최적화 알고리즘으로 스토캐스틱 경사 알고리즘을 사용
- MLPClassifier 함수의 매개변수는 6개가 전부인가?

4.10.1 하이퍼 매개변수 살피기

■ 함수의 API

- 예) MLPClassifier는 23개의 매개변수를 가짐

- 파란색은 11행이 사용한 것들. 나머지는 기본값을 사용

- 예) activation='relu'가 기본값이므로 활성 함수로 ReLU 사용

- 예) shuffle=True가 기본값이므로 세대를 시작할 때마다 훈련 집합의 샘플 순서를 섞음

```
class sklearn.neural_network.MLPClassifier(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)
```

- 11행에서 max_iter=300으로 설정했는데, 109 세대에서 학습을 멈춤

- tol=0.0001과 n_iter_no_change=10 때문(10세대 동안 손실 함수 감소량이 0.0001 이하이면 멈추라는 뜻)

4.10.1 하이퍼 매개변수 살피기

- 하이퍼 매개변수 설정 가이드라인
 - 논문이나 공식 문서를 따라 함
 - 라이브러리 함수가 제공하는 기본값 사용
 - 중요한 하이퍼 매개변수를 골라 최적화

4.10.2 단일 하이퍼 매개변수 최적화: validation_curve 함수 이용

- [프로그램 4-5]는 은닉 노드 개수를 최적화

프로그램 4-5

validation_curve 함수로 최적의 은닉 노드 개수 찾기

```
01 from sklearn import datasets
02 from sklearn.neural_network import MLPClassifier
03 from sklearn.model_selection import train_test_split, validation_curve
04 import numpy as np
05 import matplotlib.pyplot as plt
06 import time
07
08 # 데이터셋을 읽고 훈련 집합과 테스트 집합으로 분할
09 digit=datasets.load_digits()
10 x_train,x_test,y_train,y_test=train_test_split(digit.data,digit.target,train_size=0.6)
11
```

훈련:테스트를 6:4로 분할



4.10.2 단일 하이퍼 매개변수 최적화: validation_curve 함수 이용

```
12 # 다층 퍼셉트론을 교차 검증으로 성능 평가 (소요 시간 측정 포함)
13 start=time.time() # 시작 시각
14 mlp=MLPClassifier(learning_rate_init=0.001,batch_size=32,max_iter=300,solver='sgd')
15 prange=range(50,1001,50)
16 train_score,test_score=validation_curve(mlp,x_train,y_train,param_name="hidden_
    layer_sizes",param_range=prange,cv=10,scoring="accuracy",n_jobs=4)
17 end=time.time() # 끝난 시각
18 print("하이퍼 매개변수 최적화에 걸린 시간은",end-start,"초입니다.")
19
20 # 교차 검증 결과의 평균과 분산 구하기
21 train_mean = np.mean(train_score,axis=1)
22 train_std = np.std(train_score,axis=1)
23 test_mean = np.mean(test_score,axis=1)
24 test_std = np.std(test_score,axis=1)
25
26 # 성능 그래프 그리기
27 plt.plot(prange,train_mean,label="Train score",color="r")
28 plt.plot(prange,test_mean,label="Test score",color="b")
29 plt.fill_between(prange,train_mean-train_std,train_mean+train_std,alpha=0.2,color="r")
30 plt.fill_between(prange,test_mean-test_std,test_mean+test_std,alpha=0.2,color="b")
31 plt.legend(loc="best")
32 plt.title("Validation Curve with MLP")
33 plt.xlabel("Number of hidden nodes"); plt.ylabel("Accuracy")
34 plt.ylim(0.9,1.01)
35 plt.grid(axis='both')
36 plt.show()
```

50에서 시작하여 50씩 증가시키면서 1000까지 조사

10-겹 교차 검증으로 성능 측정

코어 4개를 사용하여 병렬 처리

4.10.2 단일 하이퍼 매개변수 최적화: validation_curve 함수 이용

```
37
38 best_number_nodes=np.argmax(test_mean) # 최적의 은닉 노드 개수
39 print("\n최적의 은닉층의 노드 개수는",best_number_nodes,"개입니다.\n")
40
41 # 최적의 은닉 노드 개수로 모델링
42 mlp_test=MLPClassifier(hidden_layer_sizes=(best_number_nodes),learning_rate_
    init=0.001,batch_size=32,max_iter=300,solver='sgd')
43 mlp_test.fit(x_train,y_train)
44
45 # 테스트 집합으로 예측
46 res=mlp_test.predict(x_test)
47
48 # 혼동 행렬
49 conf=np.zeros((10,10))
50 for i in range(len(res)):
51     conf[res[i]][y_test[i]]+=1
52 print(conf)
53
54 # 정확률 계산
55 no_correct=0
56 for i in range(10):
57     no_correct+=conf[i][i]
58 accuracy=no_correct/len(res)
59 print("테스트 집합에 대한 정확률은", accuracy*100, "%입니다.")
```

4.10.2 단일 하이퍼 매개변수 최적화: validation_curve 함수 이용

■ 실행 결과

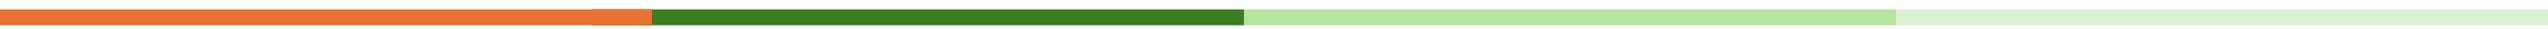
하이퍼 매개변수 최적화에 걸린 시간은 433.8679416179657초입니다.



최적의 은닉층의 노드 개수는 700개입니다.

```
[[65. 0. 0. 0. 0. 0. 0. 0. 0. 0.]  
 [ 0. 71. 0. 0. 0. 1. 0. 0. 3. 1.]  
 [ 0. 0. 67. 0. 0. 1. 0. 0. 0. 0.]  
 [ 0. 0. 0. 64. 0. 0. 0. 0. 0. 0.]  
 [ 0. 0. 0. 0. 78. 0. 0. 0. 0. 0.]  
 [ 2. 0. 0. 0. 0. 80. 0. 0. 2. 0.]  
 [ 0. 0. 0. 0. 0. 1. 78. 0. 0. 0.]  
 [ 0. 0. 0. 0. 0. 0. 0. 64. 0. 0.]  
 [ 0. 0. 0. 1. 0. 0. 0. 0. 74. 1.]  
 [ 0. 0. 0. 0. 0. 0. 0. 1. 0. 64.]]
```

테스트 집합에 대한 정확률은 98.0528511821975%입니다.



감사합니다

질문: dasomseo@jbnu.ac.kr