인공지능 심화학습

인공지능의 시작부터 딥러닝의 기본 개념까지

Computer Vision Lab 김은경

http://cv.jbnu.ac.kr/

차례

- 인공지능이란? – 역사 및 사례
- 퍼셉트론
- 활성함수
- Fully Connected Network
- 교차검증
- 성능평가

인공지능이란?

인공지능의 역사

1843 Ada "... 해석엔진은 꽤 복잡한 곡을 작곡할 수도 있다" 논문 발표

1950 인공지능 여부를 판별하는 튜링 Turing 테스트

1958 로젠블렛 Rosenblatt이 퍼셉트론 제안

1959 사무엘 Samuel이 기계학습을 이용한 체커 게임 프로그램 개발

1969 민스키 Minsky가 퍼셉트론의 과대포장 지적

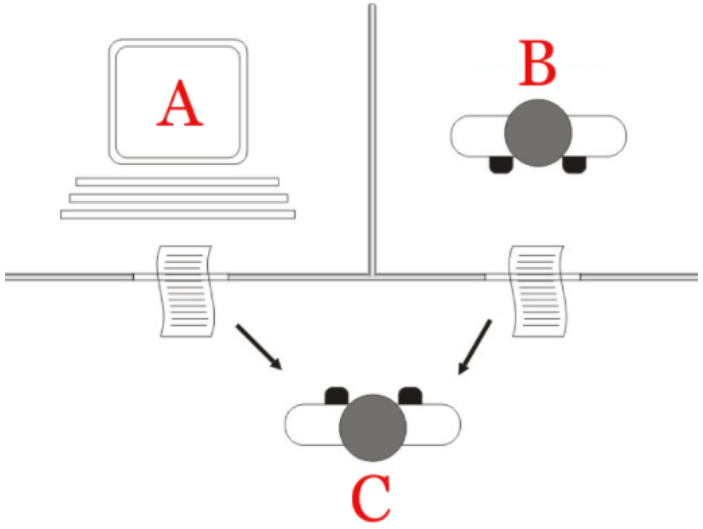

인공지능의 역사

1973 라이트힐 보고서로 인해 인공지능 내리막길. 첫번째 인공지능 겨울 시작

1986 다층 퍼셉트론으로 신경망 부활

1987 Lisp 머신의 시장 붕괴로 두번째 인공지능 겨울 시작

1997 IBM 딥블루가 세계 체스 챔피언인 카스파로프 이김

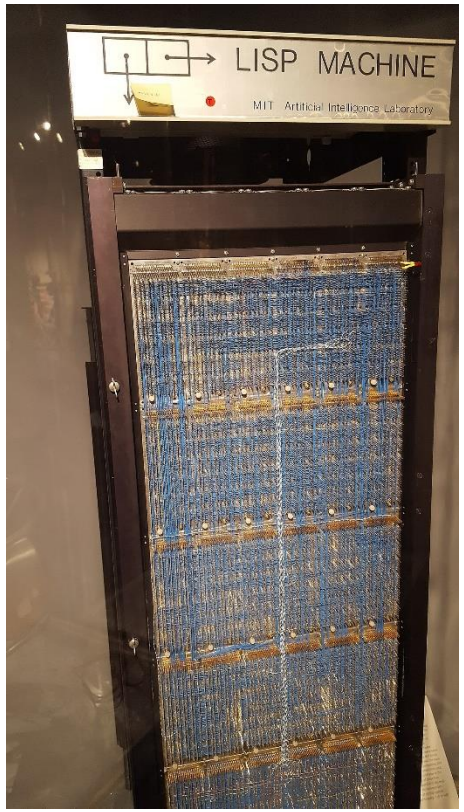

인공지능의 역사

2011 IBM 왓슨이 미국 퀴즈쇼 제퍼디의 우승자 꺾음

2012 딥러닝으로 필기숫자 데이터베이스 MNIST에 대해 0.23% 오류율 달성

AlexNet 발표(3회 ILSVRC 우승)

2016 알파고와 이세돌의 바둑 대회에서 알파고 승리

2017 알파고 제로가 알파고를 100:0으로 이김

딥러닝

그림 3.1 인공지능, 기계학습, 신경망, 딥러닝의 관계

- 인공지능
  - 규칙 기반
  - 규칙을 사람이 결정
- 기계학습 & 딥러닝
  - 기계가 사람을 대신할 수 있도록 프로그래밍

기계학습 vs 딥러닝

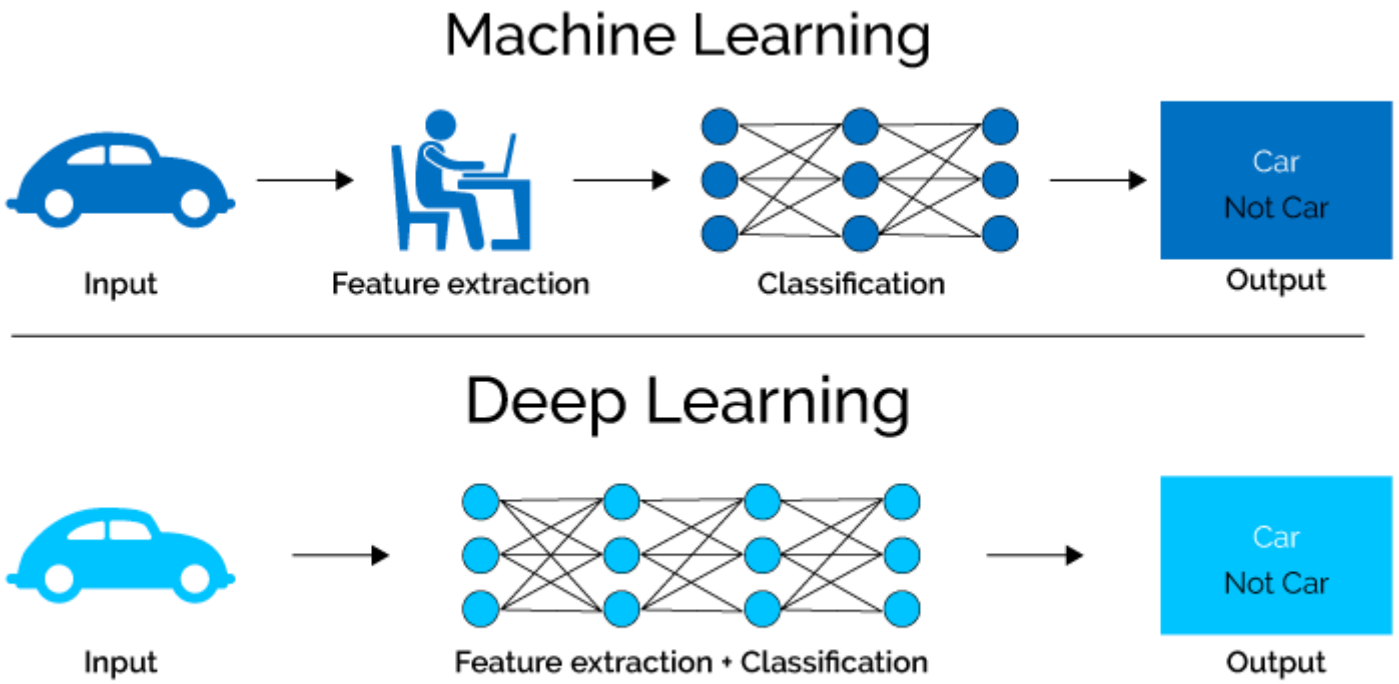
Machine Learning
Input
Feature extraction
Classification
Car
Not Car
Output
Deep Learning
Input
Feature extraction + Classification
Car
Not Car
Output

딥러닝 적용 분야

강화학습

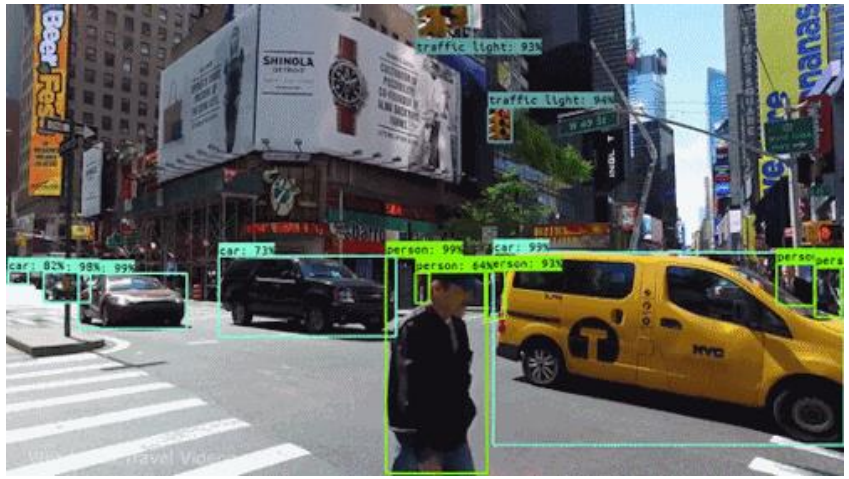

컴퓨터 비전

음성인식

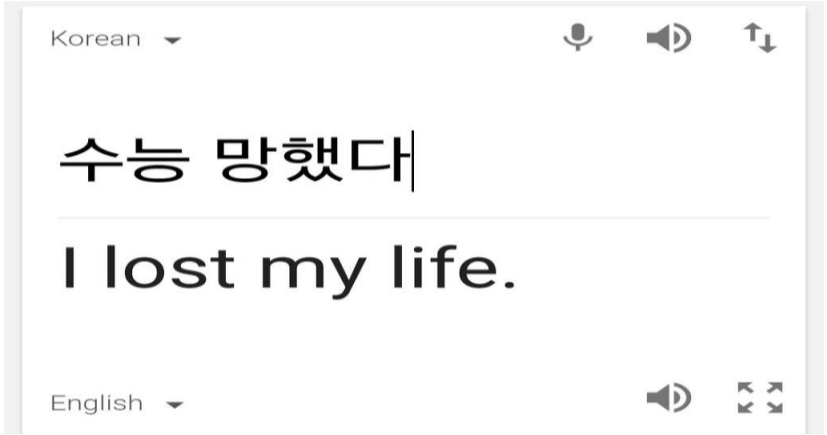

자연어처리

딥러닝 강화학습

https://youtu.be/TmPfTpjtdgg

딥러닝 적용 사례

- DLSS
- https://www.nvidia.com/ko-kr/geforce/technologies/dlss/

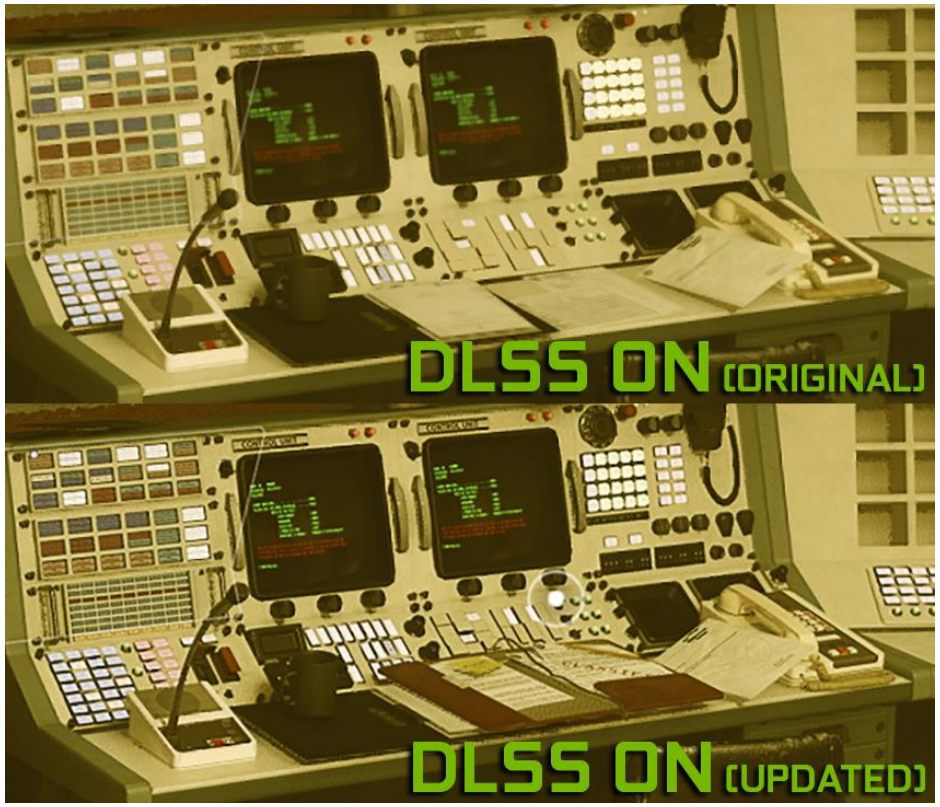

딥러닝 적용 사례

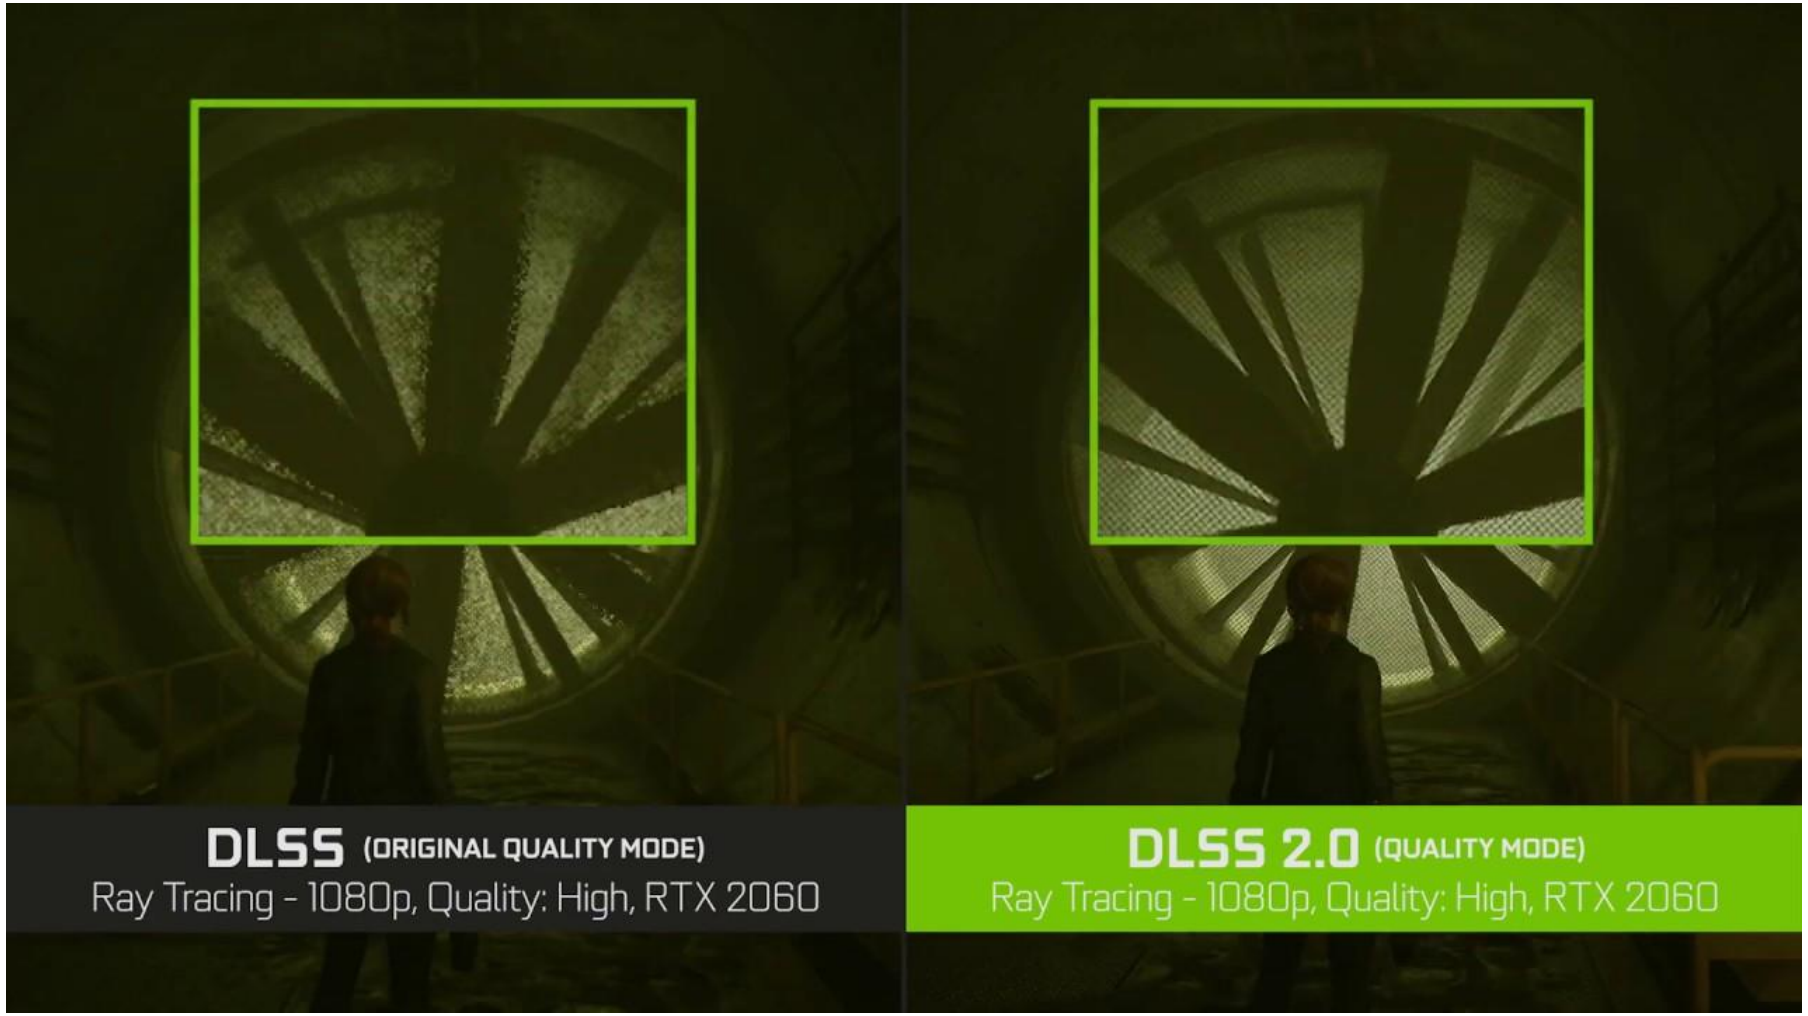
DLSS (ORIGINAL QUALITY MODE)
Ray Tracing - 1080p, Quality: High, RTX 2060
DLSS 2.0 (QUALITY MODE)
Ray Tracing - 1080p, Quality: High, RTX 2060

딥러닝 적용 사례

- 자율주행
- 테슬라, 구글

구글의 웨이모

딥러닝 적용 사례

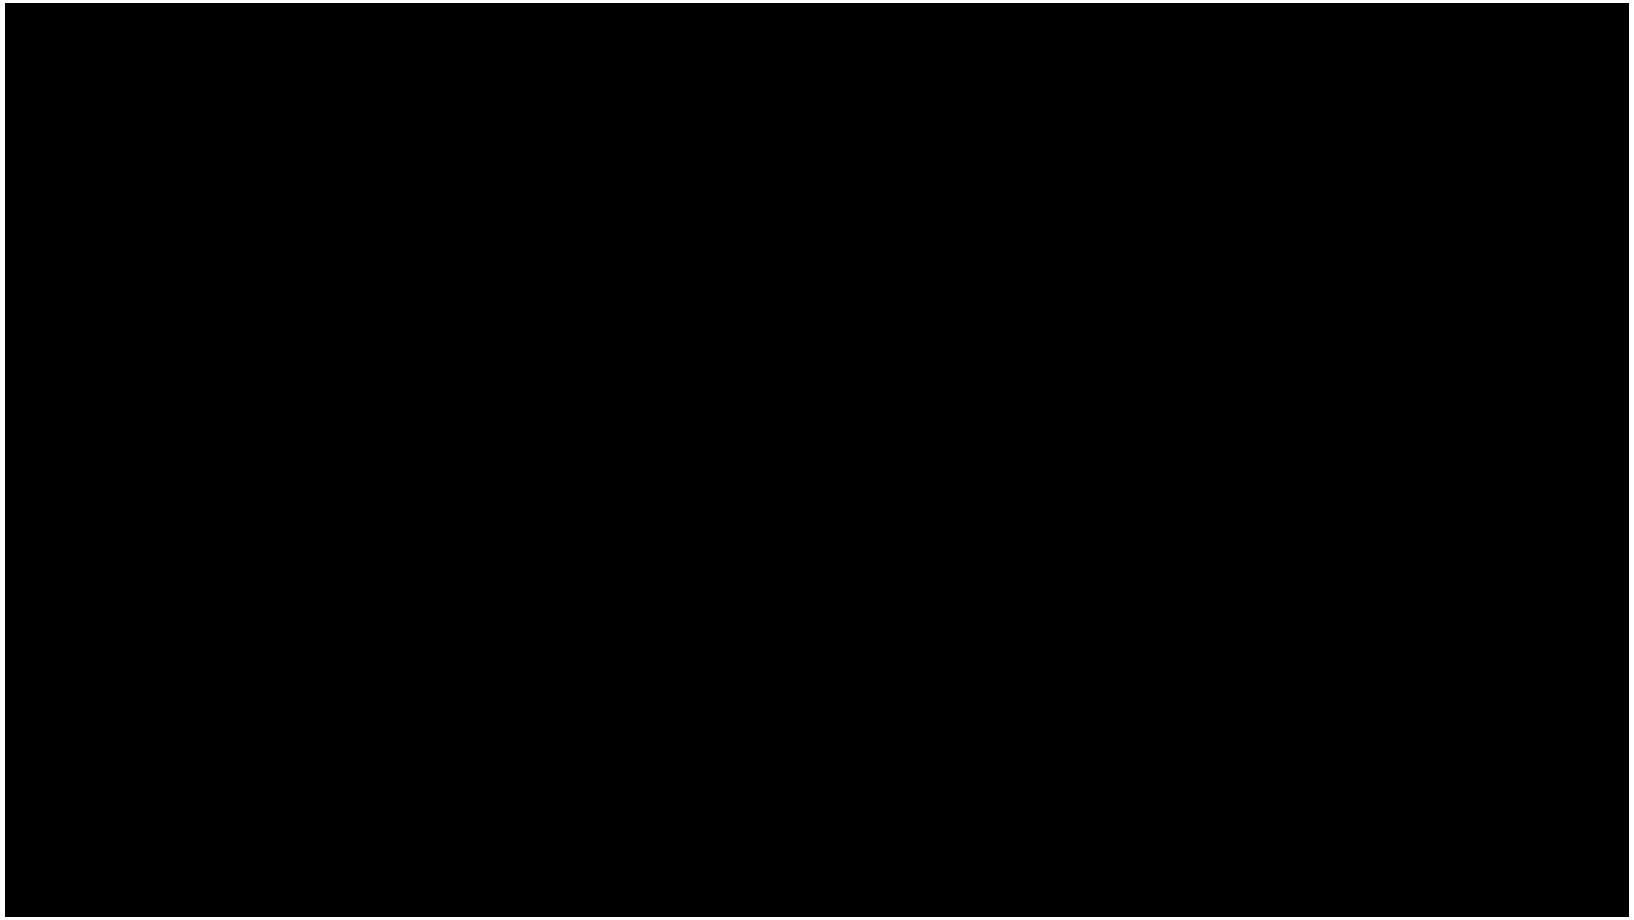

테슬라 오토파일럿

딥러닝 적용 사례

- Open AI DOTA2
- https://openai.com/projects/five/

https://youtu.be/UZHTNBMAfAA

Crystal Maiden's Freezing Field
and Viper's Nethertoxin force
the human team to scatter

딥러닝 적용 사례

- 흑백영상을 컬러영상으로 변환
- https://demos.algorithmia.com/colorize-photos
- Nvidia에서 진행하는 딥러닝 체험
- https://www.nvidia.com/en-us/research/ai-playground/
- 스케치를 특정 사물로 변환
- https://affinelayer.com/pixsrv/
- 인공지능이 도와주는 드로잉
- https://www.autodraw.com/

딥러닝의 기본 원리

퍼셉트론

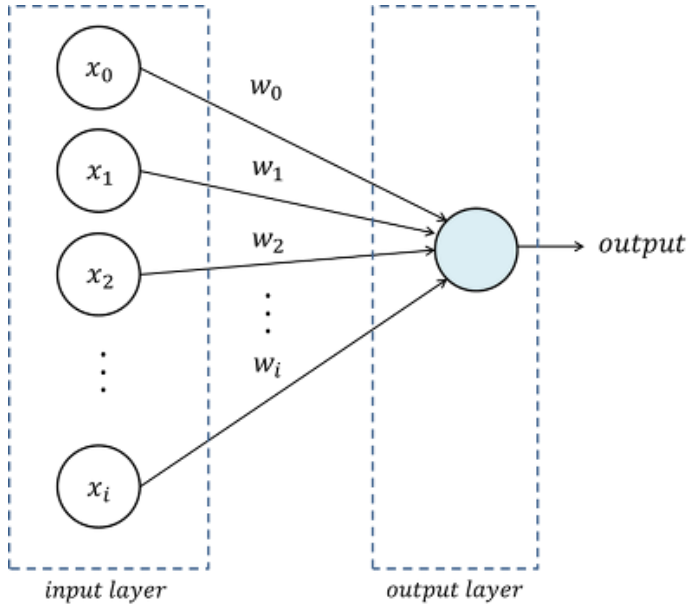

퍼셉트론

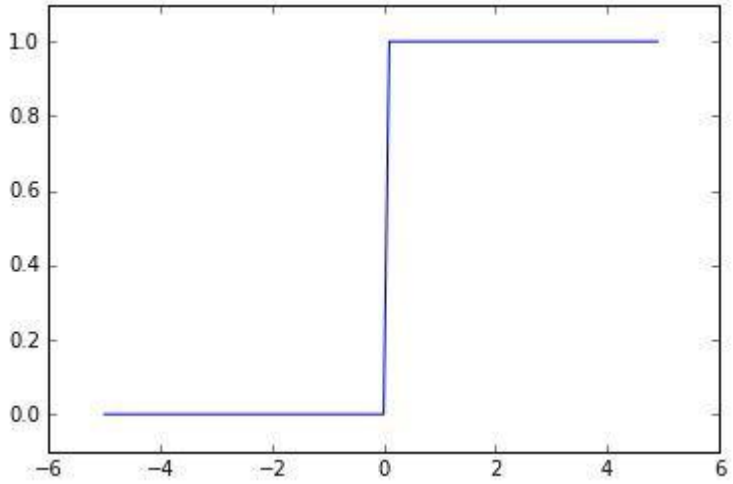

활성함수(계단함수)

퍼셉트론은 딥러닝의 핵심 구성 요소

퍼셉트론

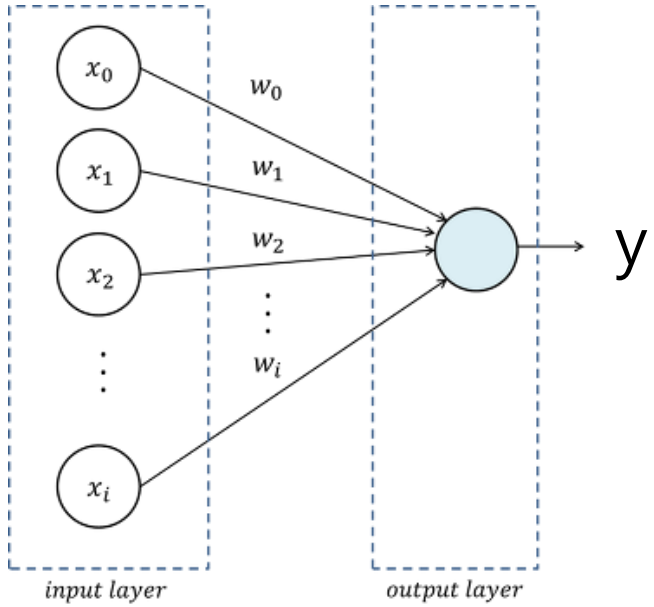

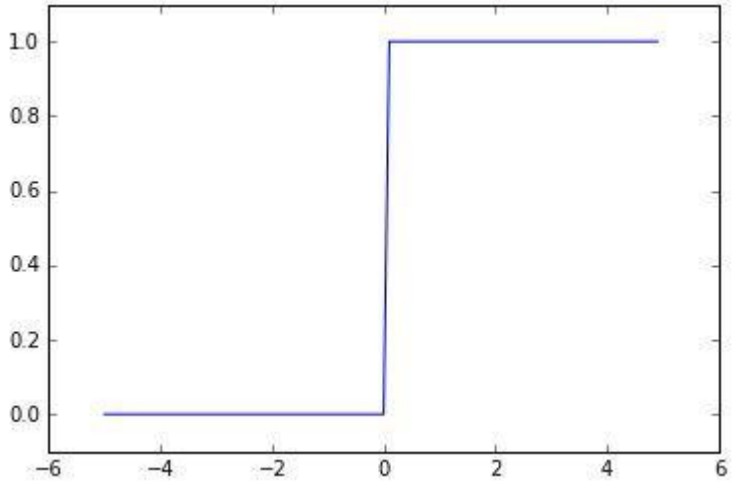

τ : 계단함수. 결과값은 0 또는 1

$$output = \tau(y) = \tau(x_0w_0 + x_1w_1 + x_2w_2 + \ldots + x_nw_n)$$

활성함수

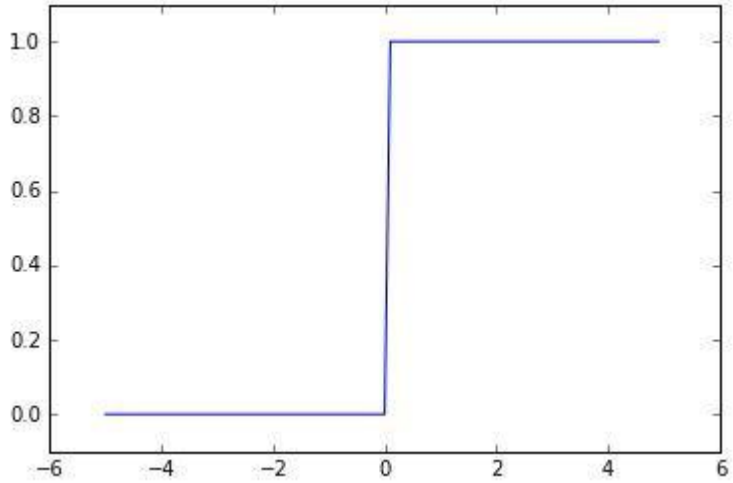

활성함수(계단함수)

- 어떤 신호를 입력 받아 그 신호를 적절한 처리를 통해 출력해주는 함수
- 인공신경망에서 입력된 데이터를 다음 층으로 출력할지 말지를 결정
- 계단함수를 활성함수로 사용하면 0, 1로 딱 떨어지는 이진 문제

활성함수

Sigmoid

$$\sigma(x) = \frac{1}{1+e^{-x}}$$

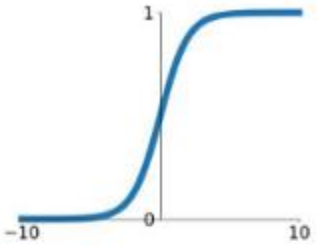

tanh

$$\tanh(x)$$

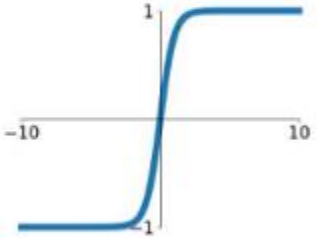

ReLU

$$\max(0, x)$$

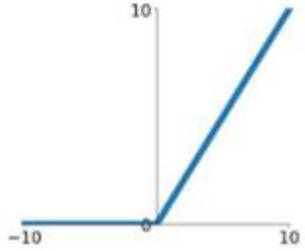

Leaky ReLU

$$\max(0.1x, x)$$

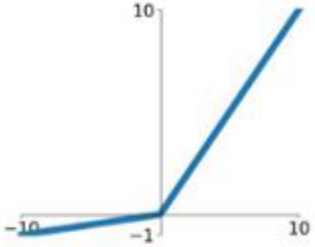

Maxout

$$\max(w_1^T x + b_1, w_2^T x + b_2)$$

ELU

$$\begin{cases} x & x \geq 0 \\ \alpha(e^x - 1) & x < 0 \end{cases}$$

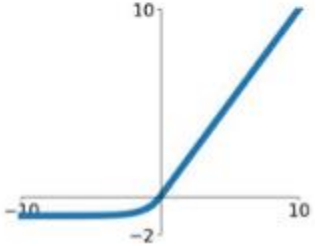

퍼셉트론

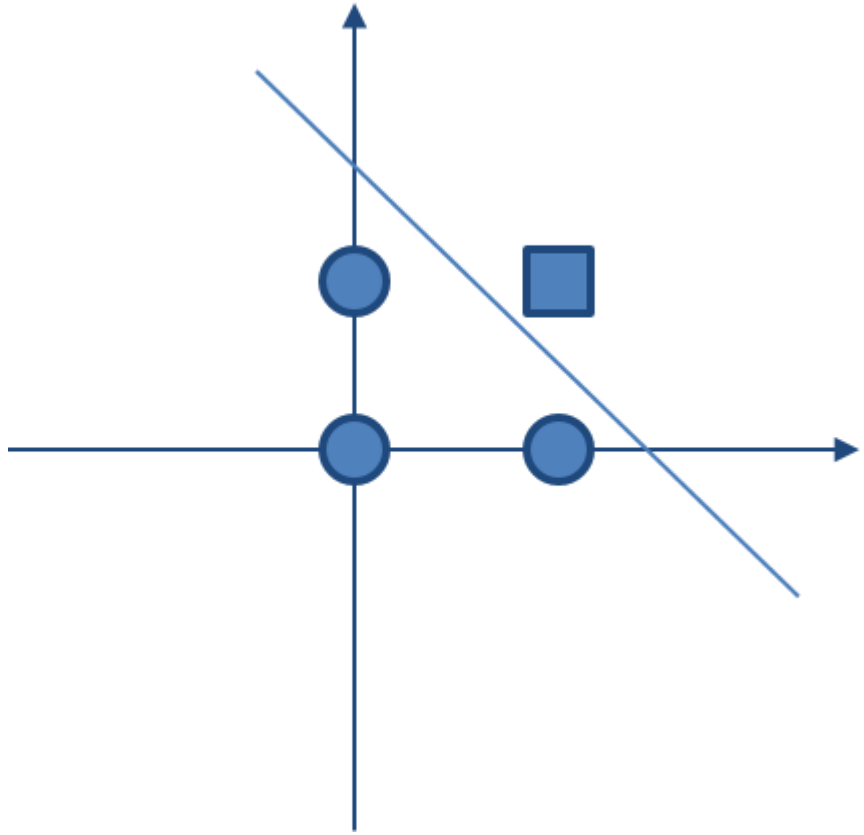

x1	x2	y
0	0	0
0	1	0
1	0	0
1	1	1

퍼셉트론

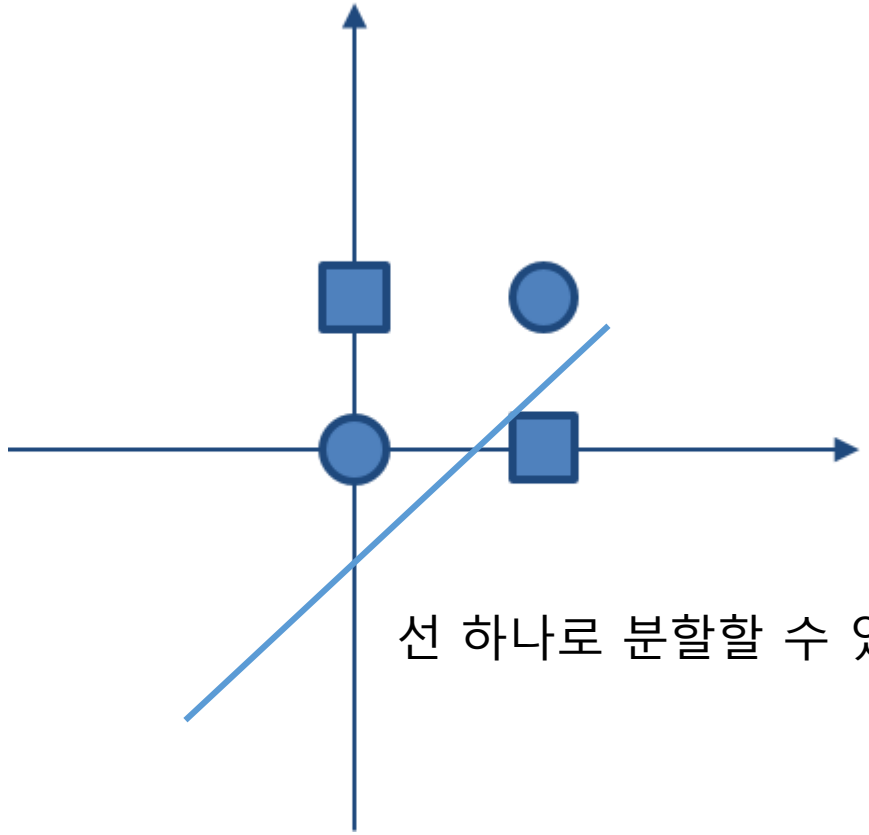

선 하나로 분할할 수 있는가?

x1	x2	y
0	0	0
0	1	1
1	0	1
1	1	0

퍼셉트론을 이용한 XOR 문제 해결

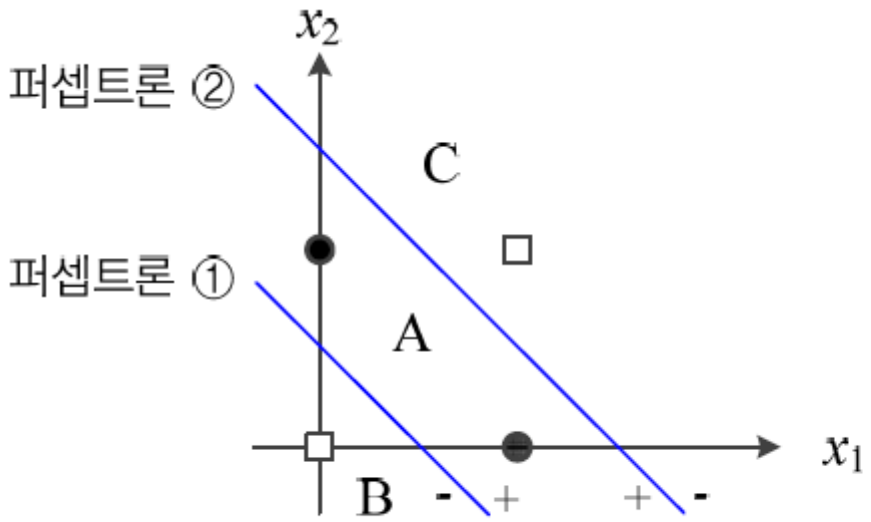

(a) 퍼셉트론 2개를 이용한 공간분할

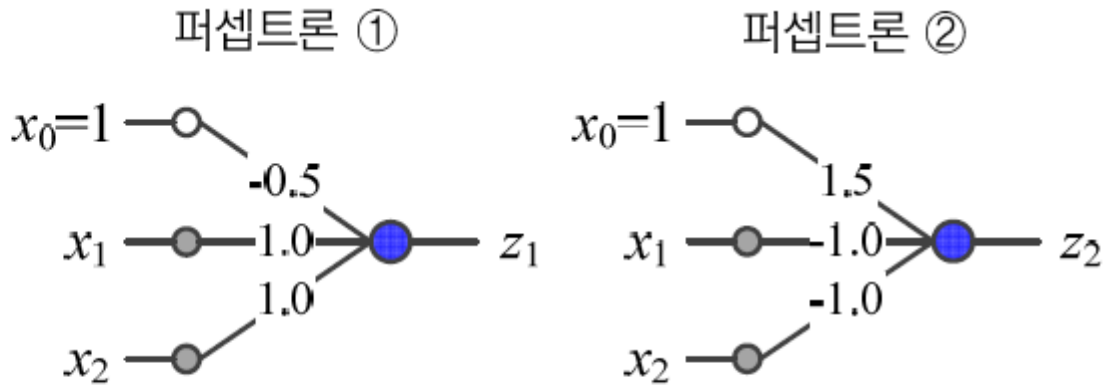

(b) 퍼셉트론 2개

- XOR 문제는 퍼셉트론 2개를 사용해서 공간분할을 할 수 있음

다층 퍼셉트론

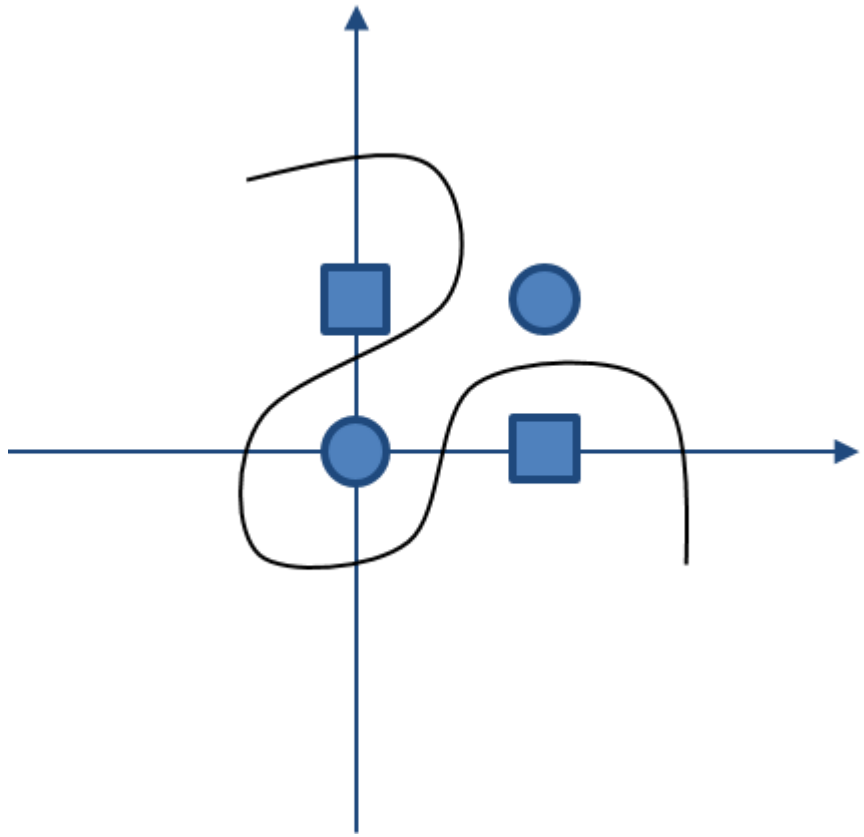

x1	x2	y
0	0	0
0	1	1
1	0	1
1	1	0

다층 퍼셉트론을 이용한 XOR 문제 해결

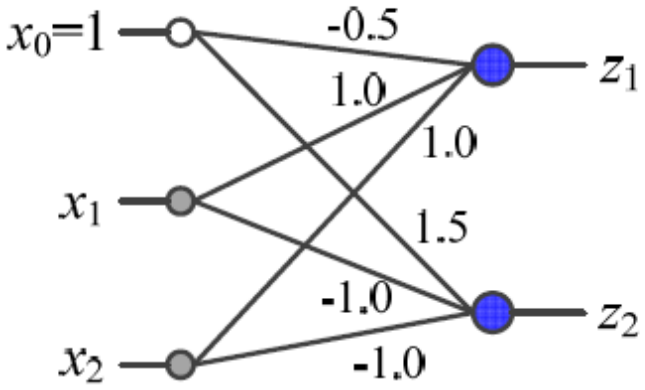

(a) 두 퍼셉트론을 병렬로 결합

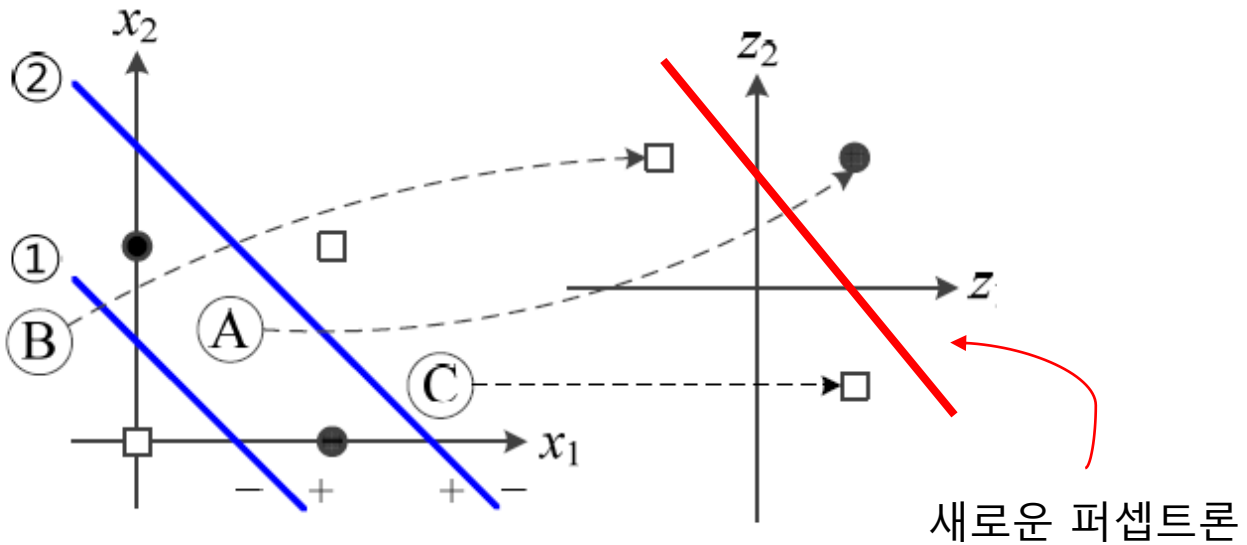

(b) 원래 특징 공간 x를 새로운 특징 공간 z로 변환

- 두 퍼셉트론을 병렬로 결합하면 새로운 특징 공간이 되며 퍼셉트론 하나로 구분 가능한 새로운 문제로 변함

FCN (Fully Connected Network)

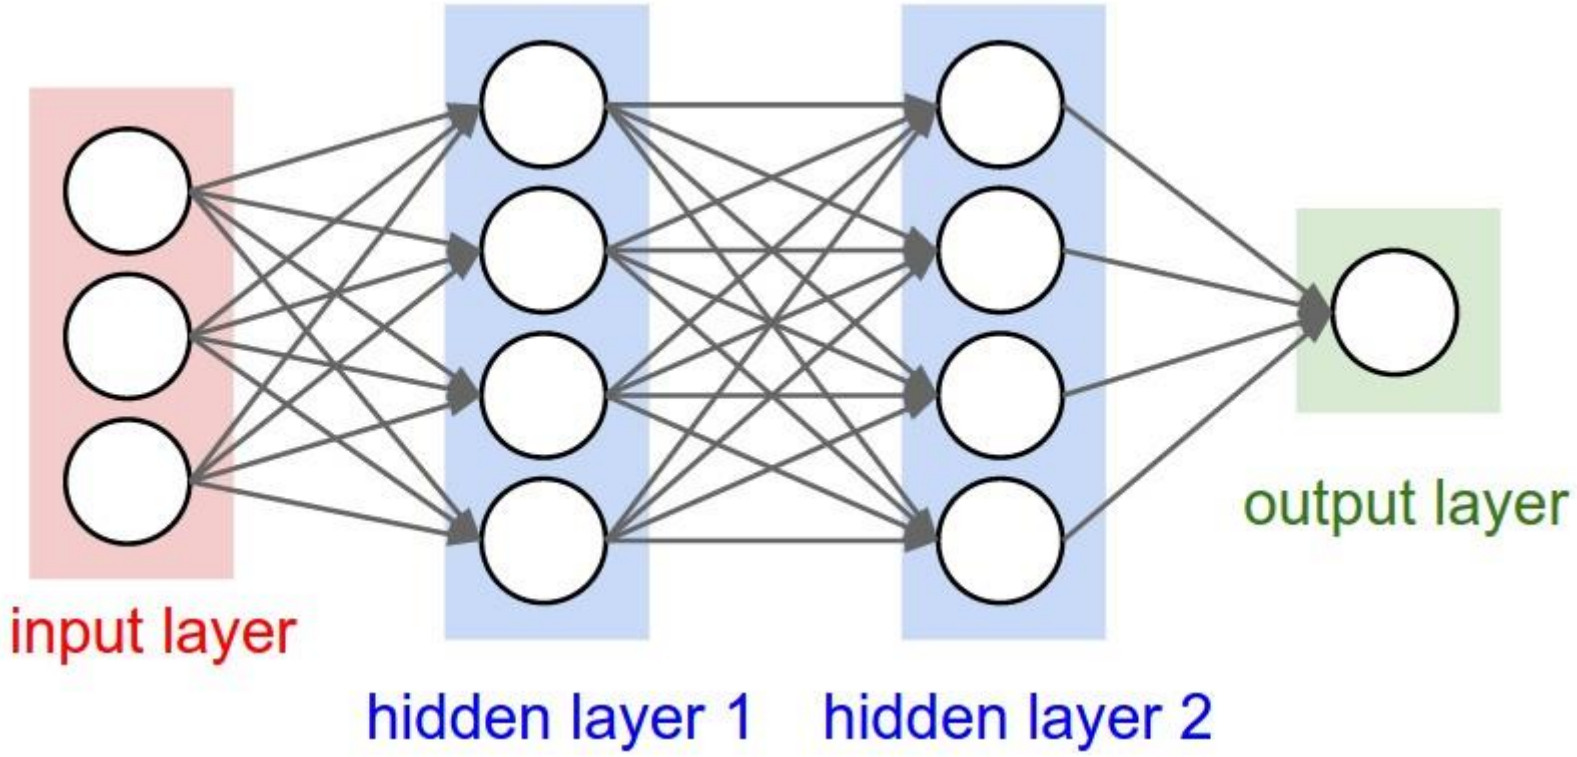

3층 FCN

FCN (Fully Connected Network)

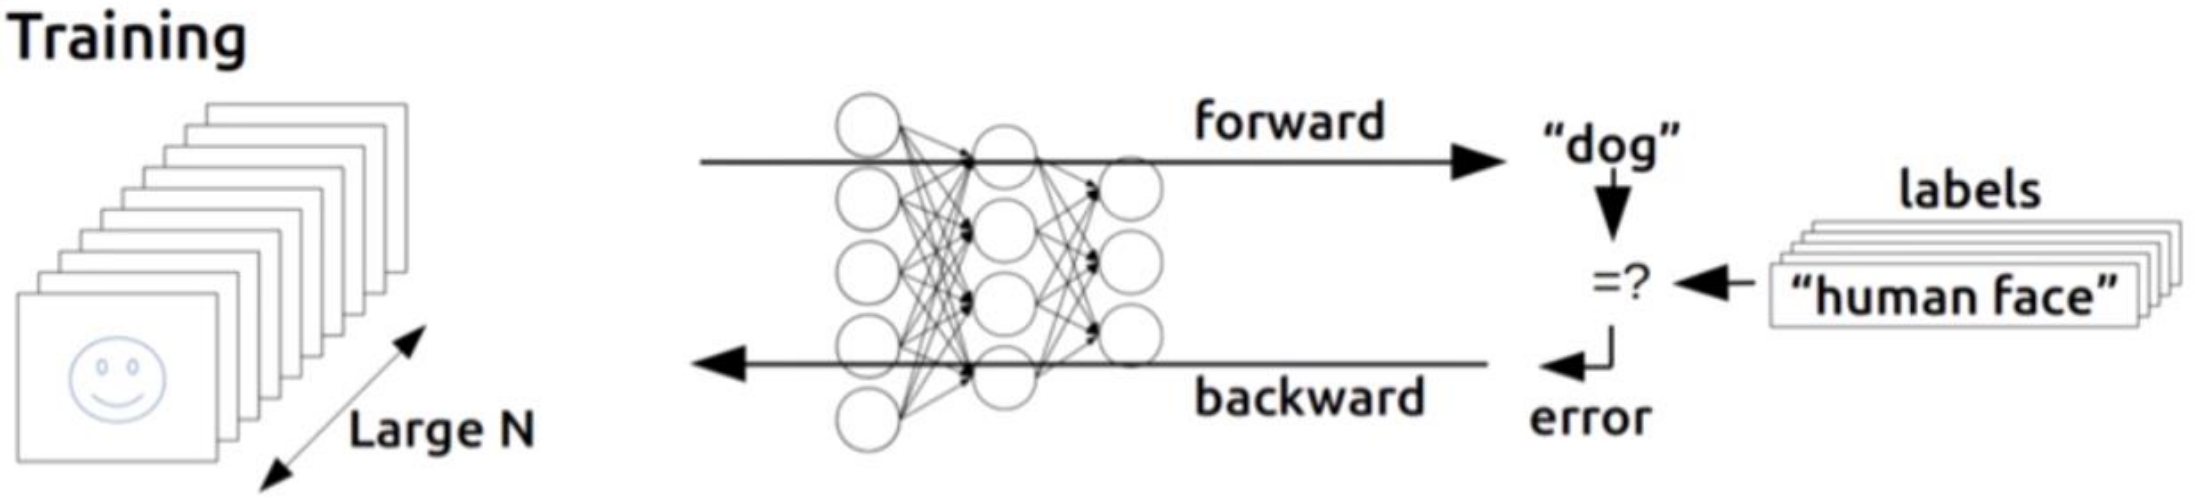

Loss 함수

Loss 함수는 추정치가 실제 데이터와 얼마나 차이 나는지 평가하는 지표

정답을 잘 맞출수록 Loss 함수의 값이 낮아지고 정답으로부터 멀어질수록 Loss 함수의 값이 커진다.

Loss 함수가 J(w)라고 하면 가중치 w가 문제를 잘 맞출수록 J(w)가 0에 가까워진다.

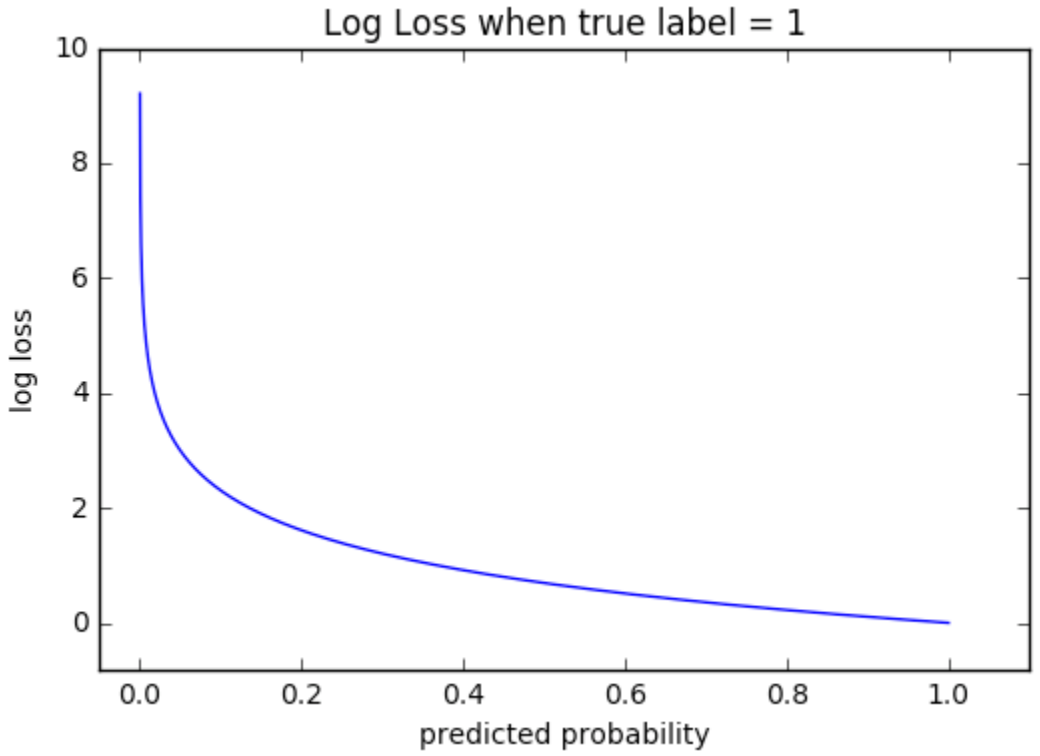

Forward Propagation

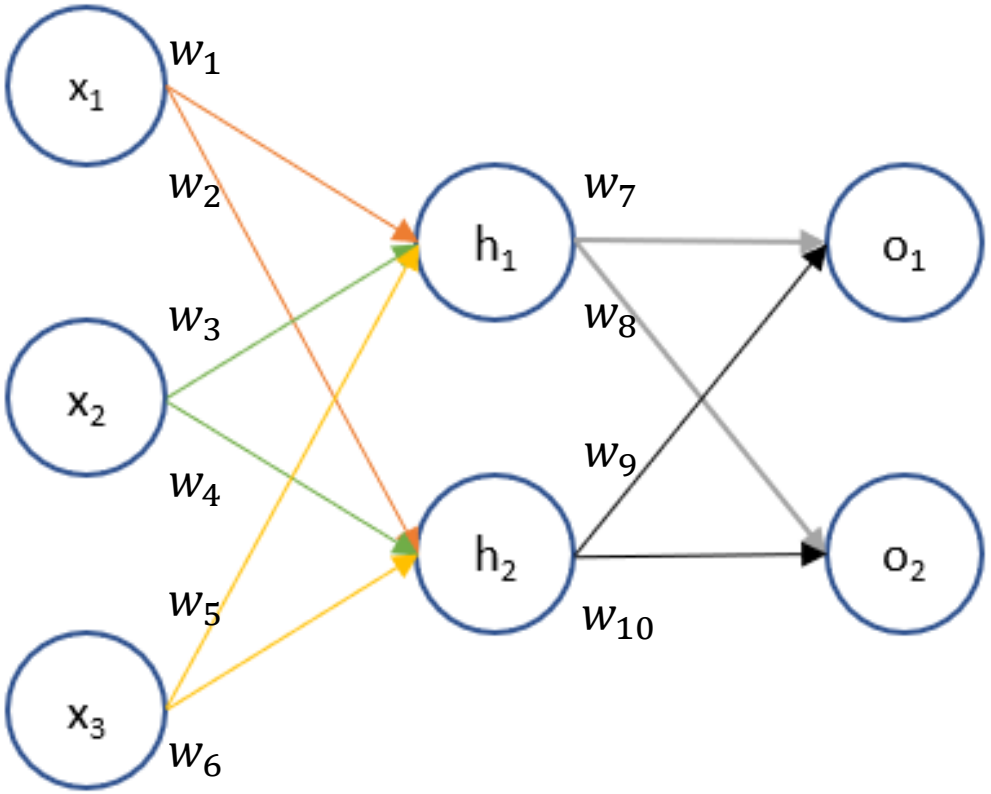

$$z_{h_1} = x_1 w_1 + x_2 w_3 + x_3 w_5$$
$$z_{h_2} = x_1 w_2 + x_2 w_4 + x_3 w_6$$
$$h_1 = sigmoid(z_{h_1})$$
$$h_2 = sigmoid(z_{h_2})$$

Sigmoid 함수:

$$sigmoid(x) = \frac{1}{1 + e^{-x}}$$

$$z_{o_1} = h_1 w_7 + h_2 w_9$$
$$z_{o_2} = h_1 w_7 + h_2 w_9$$
$$o_1 = sigmoid(z_{o_1})$$
$$o_1 = sigmoid(z_{o_2})$$

Error(MSE):

$$E = \frac{1}{2}[(o_1 - t_1)^2 + (o_2 - t_2)^2]$$

어떻게 학습을 할까

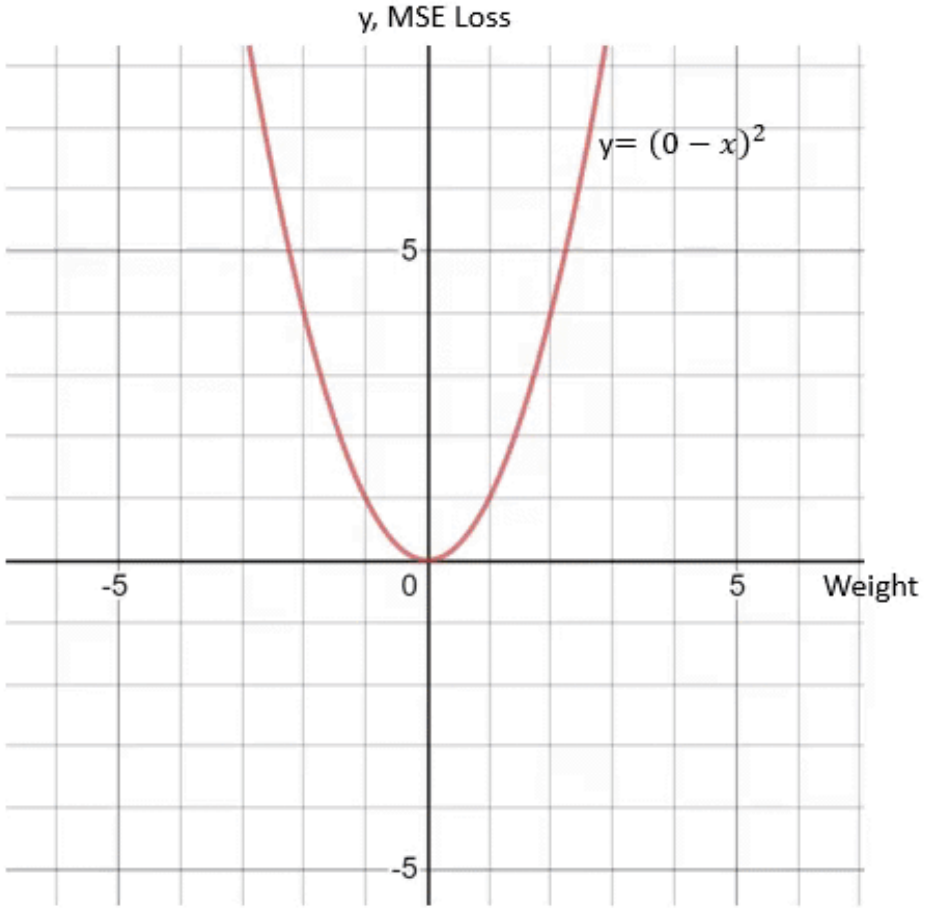

함수의 최솟값을 찾는 문제

최적의 가중치에서 Loss 함수의 값이 가장 낮다.
Loss 함수의 최저점으로 가는 방향을 찾기 위해
1차 미분을 사용

2차 미분을 사용하지 않는 이유:
- 실제 딥러닝에서의 함수는 형태가 복잡하여 미분 계수의 계산이 힘들다

Loss 함수 – 0에 가까울수록 딥러닝 모델의 성능이 높음

어떻게 학습을 할까

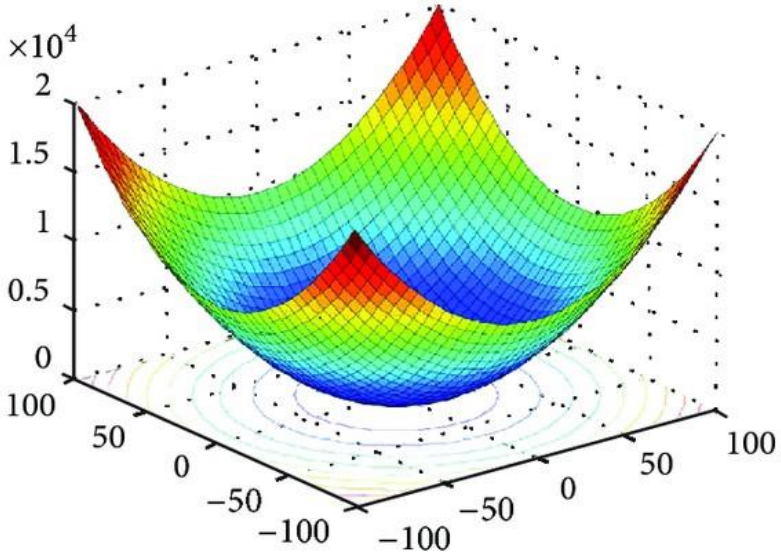

가중치가 2개인 loss function

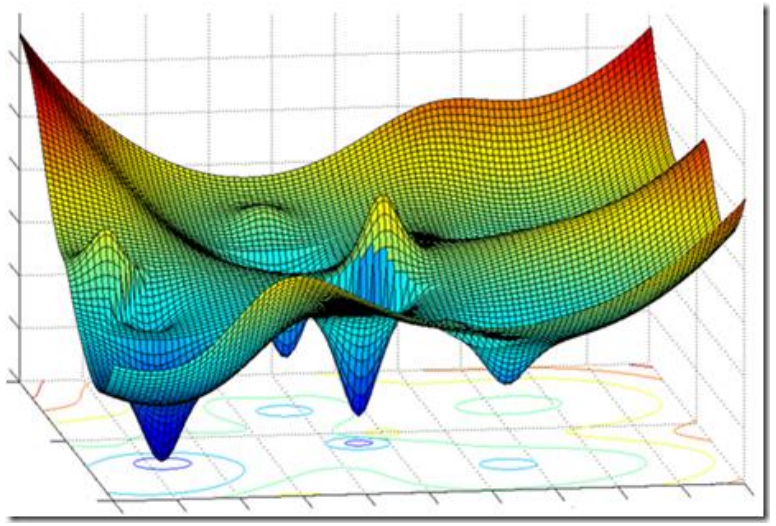

가중치가 2개인 복잡한 문제에서의 loss function

딥러닝으로 다루는 문제는 복잡한 문제이며 가중치의 개수도 엄청나게 많다.
-> 2차 미분을 구하기가 매우 어려움

경사 하강법(Gradient Descent)

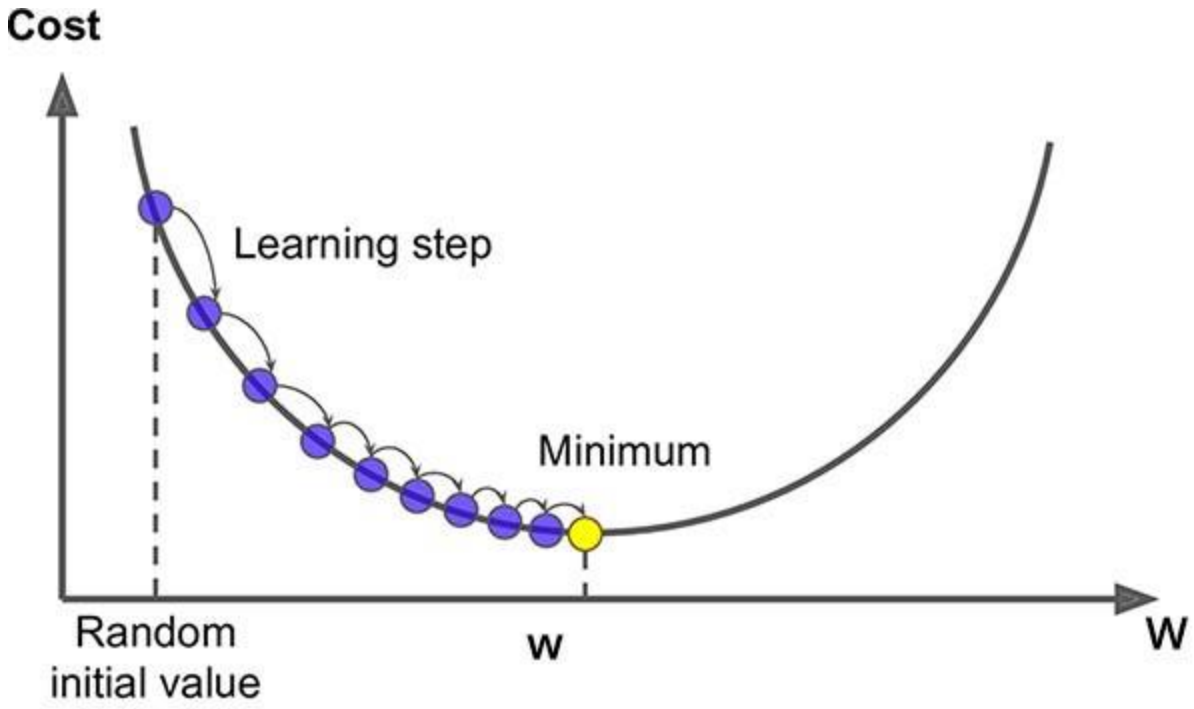

함수의 기울기를 구해 최저점으로 가는 방향을 찾고 learning rate만큼 그 방향을 향해 가중치를 업데이트한다.

Learning rate

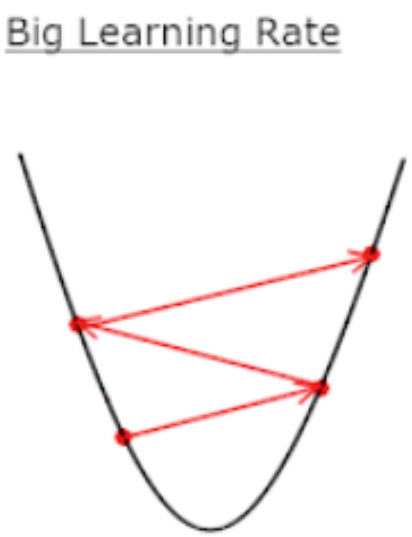

최저점에 수렴하지 못함

최저점에 도달

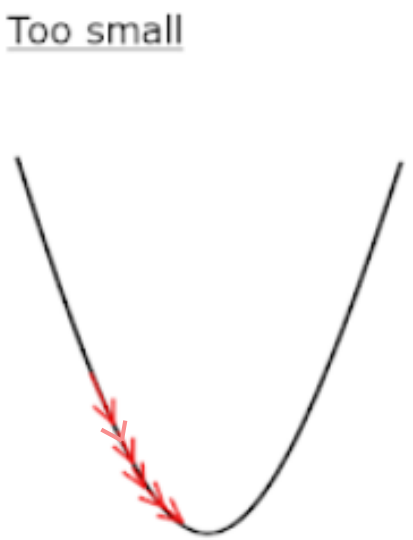

학습이 오래 걸리며
최저점에 도달하지 못함

Learning rate

$$w^{+} = w - \eta * \frac{\partial E}{\partial w}$$

learning rate :
한번에 얼마나 학습할지

gradient :
어떤 방향으로 학습할지

연쇄 법칙

f(g(x))를 x에 대해 미분하면

$$\frac{df}{dx} = \frac{df}{dg} \times \frac{dg}{dx}$$

$$\frac{d}{dx}\Big(f\big(g(x)\big)\Big) = \frac{df}{dg} \times \frac{dg}{dx}$$

$$= f'\{g(x)\} \times g'(x)$$

역전파

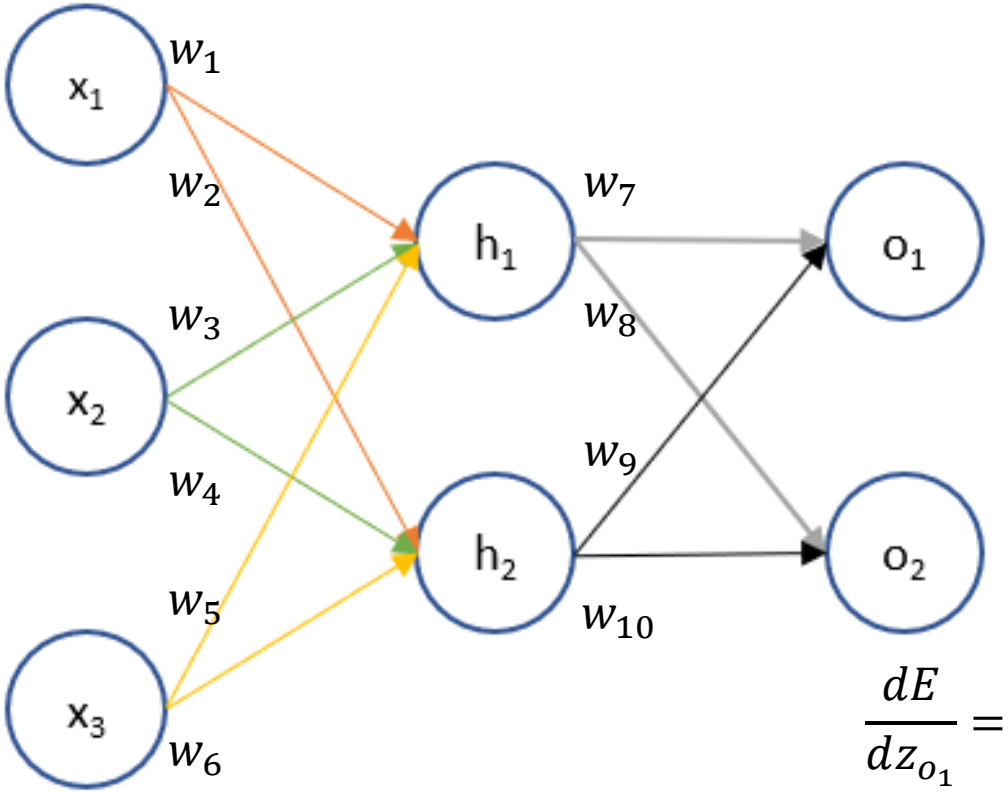

Sigmoid 함수:

$$sigmoid(x) = \frac{1}{1+e^{-x}}$$

Sigmoid 함수 미분:

$$\frac{d}{dx} sigmoid(x) = sigmoid(x)(1 - sigmoid(\mathrm{x}))$$

$$\frac{dE}{do_1} = o_1 - t_1$$

$$\frac{dE}{do_2} = o_2 - t_2$$

$$\frac{dE}{dz_{o_1}} = \frac{dE}{do_1}\frac{do_1}{dz_{o_1}} = (o_1 - t_1)(sigmoid(z_{o_1})(1 - sigmoid(z_{o_1}))$$

$$= (o_1 - t_1)o_1(1 - o_1)$$

$$(z_{o_1} = h_1 w_7 + h_2 w_9)$$

역전파

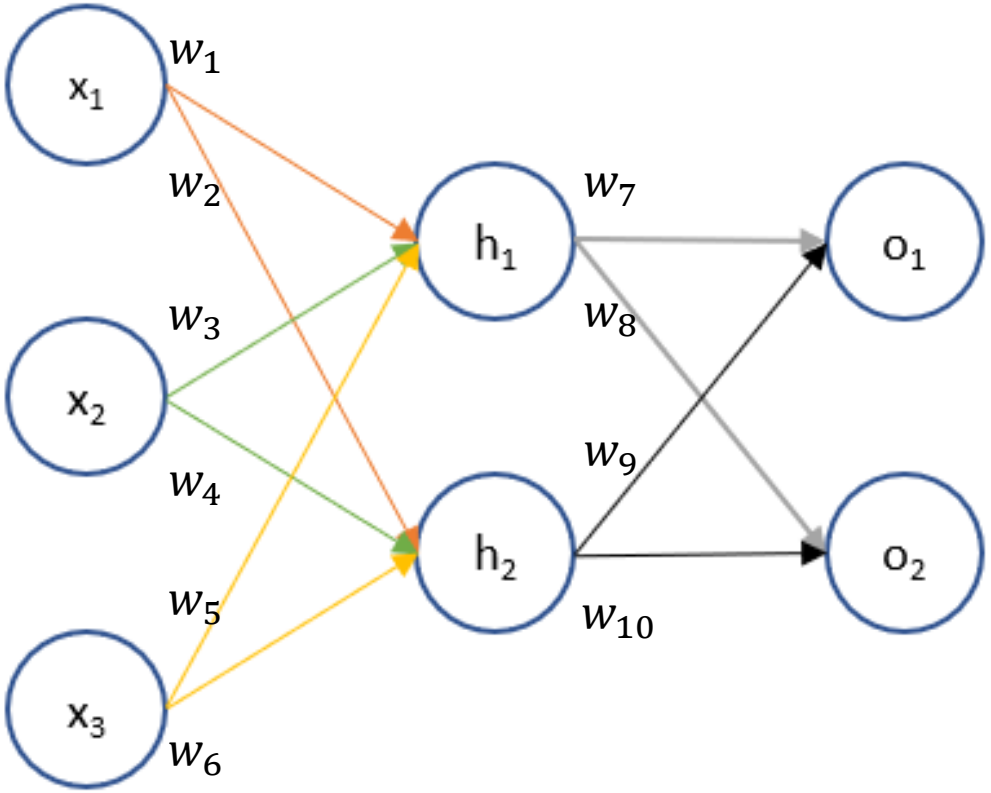

$$\frac{dE}{dz_{o_1}} = \frac{dE}{do_1}\frac{do_1}{dz_{o_1}}$$
$$= (o_1 - t_1)(sigmoid(z_{o_1})(1 - sigmoid(z_{o_1}))$$
$$= (o_1 - t_1)o_1(1 - o_1)$$

$$\frac{dz_{o_1}}{dw_7} = h_1$$

$$\frac{dE}{dw_7} = \frac{dE}{do_1}\frac{do_1}{dz_{o_1}}\frac{dz_{o_1}}{dw_7} = \frac{dE}{do_1}\frac{do_1}{dz_{o_1}}h_1$$

$$(z_{o_1} = h_1 w_7 + h_2 w_9)$$

순전파

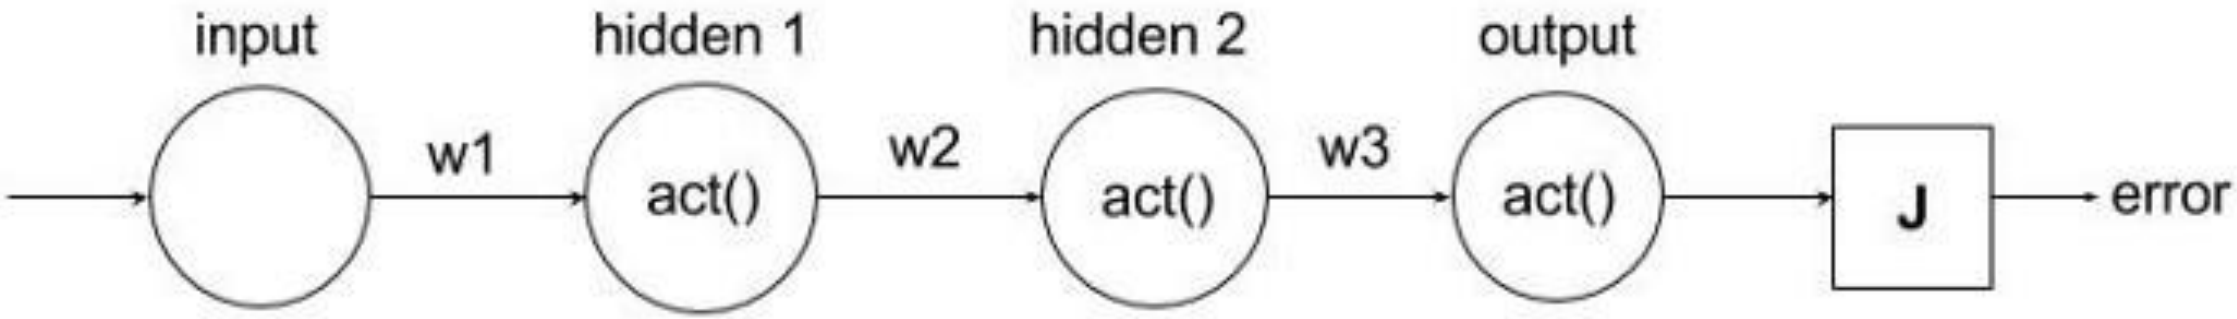

활성 Activation 함수 = Sigmoid 함수

$$sigmoid(x) = \frac{1}{1 + e^{-x}}$$

hidden1 = sigmoid(w1*input)

hidden2 = sigmoid(w2*hidden1)

output = sigmoid(w3*hidden2)

output = sigmoid(w3*sigmoid(w2*sigmoid(w1*input)))

역전파

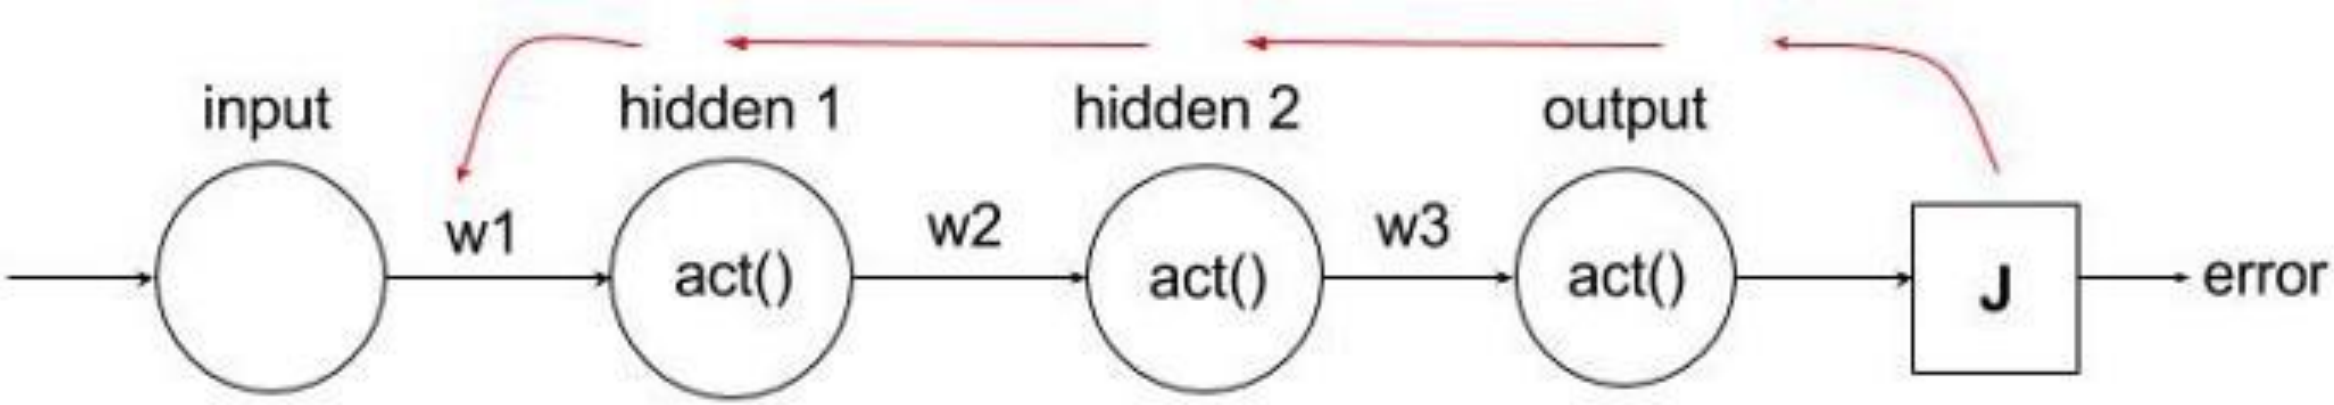

$$\frac{dE}{do} = o - t$$

$$\frac{dE}{dw1} = \frac{dE}{d\ output} \times \frac{d\ output}{d\ hidden2} \times \frac{d\ hidden2}{d\ hidden1} \times \frac{d\ hidden1}{dw1}$$

$$sigmoid(x) = \frac{1}{1 + e^{-x}}$$

$$\frac{d}{dx} sigmoid(x) = sigmoid(x)(1 - sigmoid(\mathrm{x}))$$

오류 역전파를 이용하여 미리 해당 노드에서 역전파되는 기울기의 변화에 대한 설정을 해두면,
따로 계산할 것도 없이 기울기를 알아낼 수 있음.

Epoch

1 Epoch : 모든 데이터 셋을 한 번 학습
1 iteration : 1회 학습

minibatch : 데이터 셋을 batch size 크기로 쪼개서 학습

ex) 총 데이터가 100개, batch size가 10이면,
1 iteration = 10개 데이터에 대해서 학습
1 Epoch = 100/batch size = 10 iteration

Epoch

Epoch: 전체 데이터를 한 번 학습하는 것

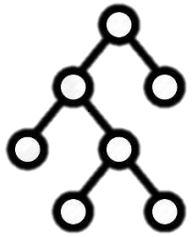

Batch: 한 번에 학습하는 데이터 집합

Iteration: epoch를 나누어서 학습하는 횟수. 1000개의 데이터를 100개씩 학습하면 10 iterations.

Optimizer

상황에 맞게 학습률을 조정하여 가중치를 업데이트하는 방법

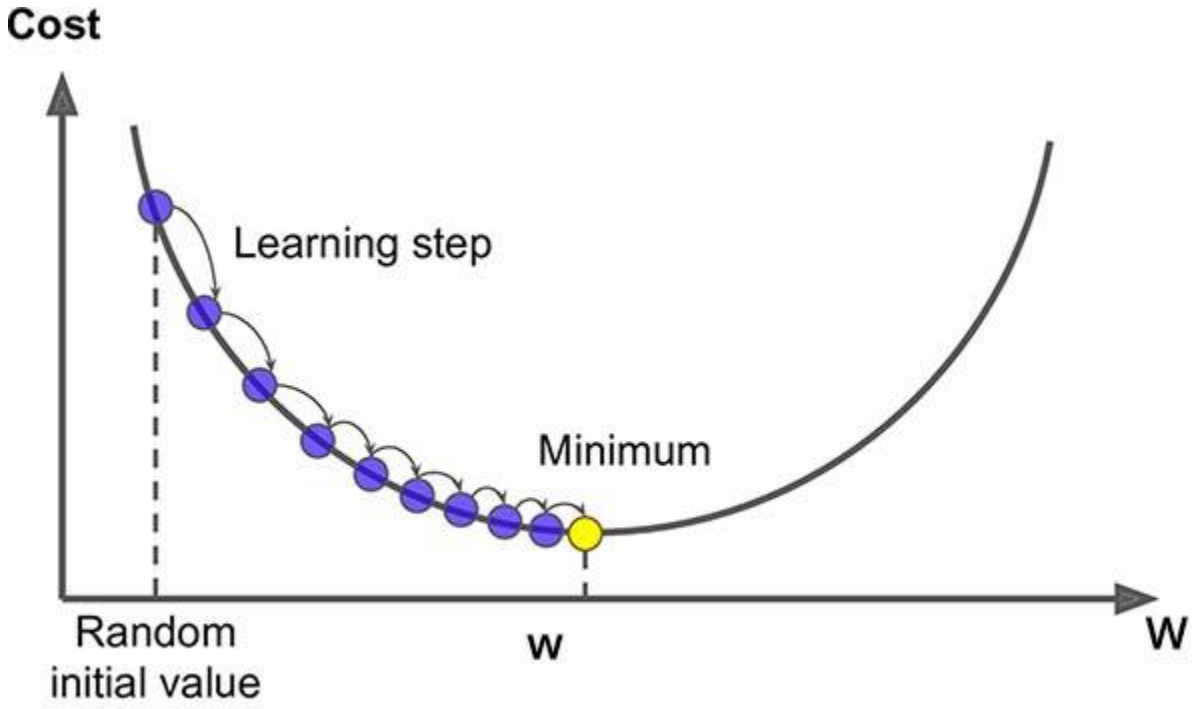

Optimizer

- GD(Gradient Descent)의 문제점
  - 한 번 학습에 모든 데이터를 사용
  → 학습이 오래걸림

- SGD를 사용하여 빠르게 학습!

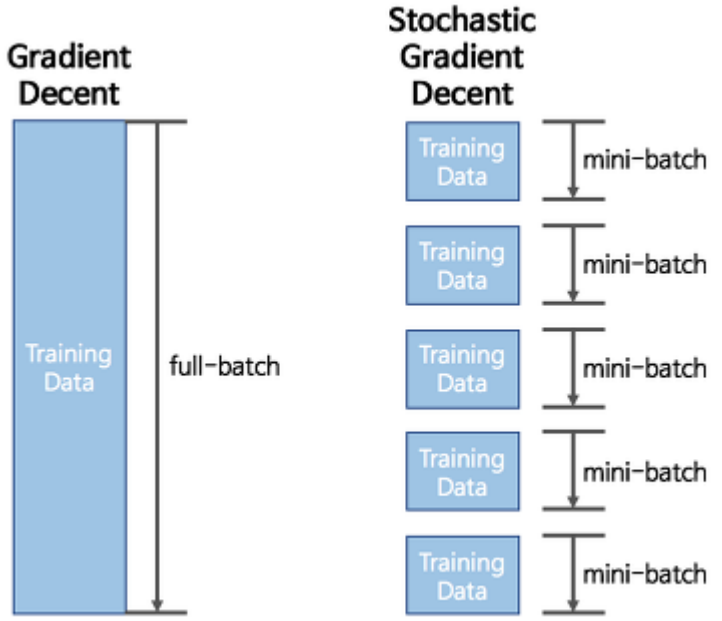

Optimizer (SGD)

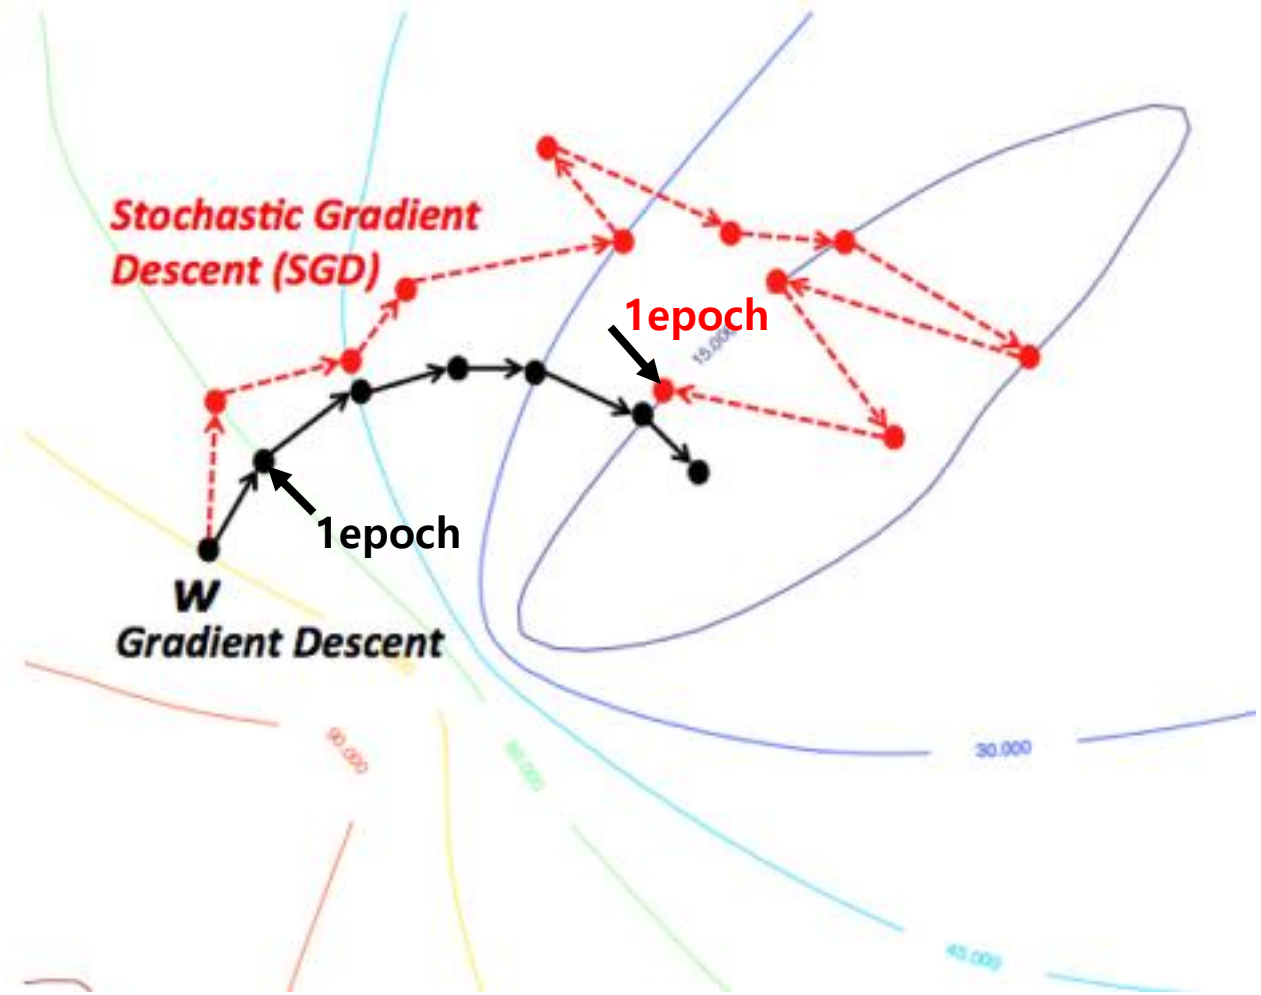

Optimizer

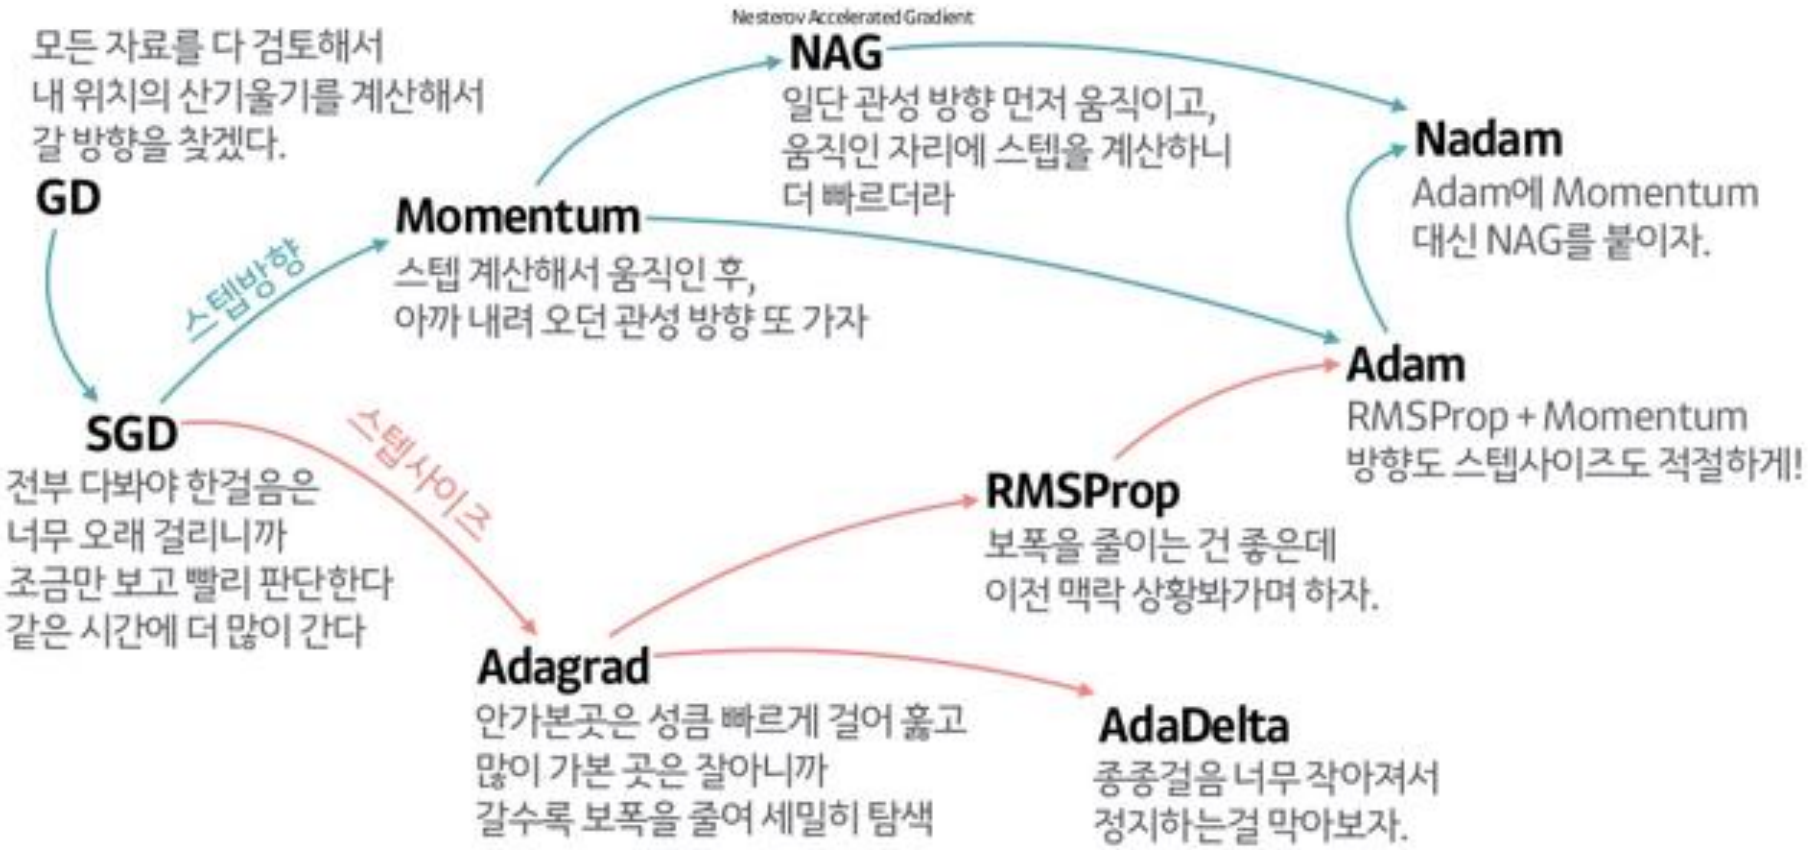
모든 자료를 다 검토해서
내 위치의 산기울기를 계산해서
갈 방향을 찾겠다.
GD
스텝방향
Momentum
스텝 계산해서 움직인 후,
아까 내려 오던 관성 방향 또 가자
Nesterov Accelerated Gradient
NAG
일단 관성 방향 먼저 움직이고,
움직인 자리에 스텝을 계산하니
더 빠르더라
Nadam
Adam에 Momentum
대신 NAG를 붙이자.
Adam
RMSProp + Momentum
방향도 스텝사이즈도 적절하게!
SGD
전부 다봐야 한걸음은
너무 오래 걸리니까
조금만 보고 빨리 판단한다
같은 시간에 더 많이 간다
스텝사이즈
RMSProp
보폭을 줄이는 건 좋은데
이전 맥락 상황봐가며 하자.
Adagrad
안가본곳은 성큼 빠르게 걸어 훑고
많이 가본 곳은 잘아니까
갈수록 보폭을 줄여 세밀히 탐색
AdaDelta
종종걸음 너무 작아져서
정지하는걸 막아보자.

Optimizer

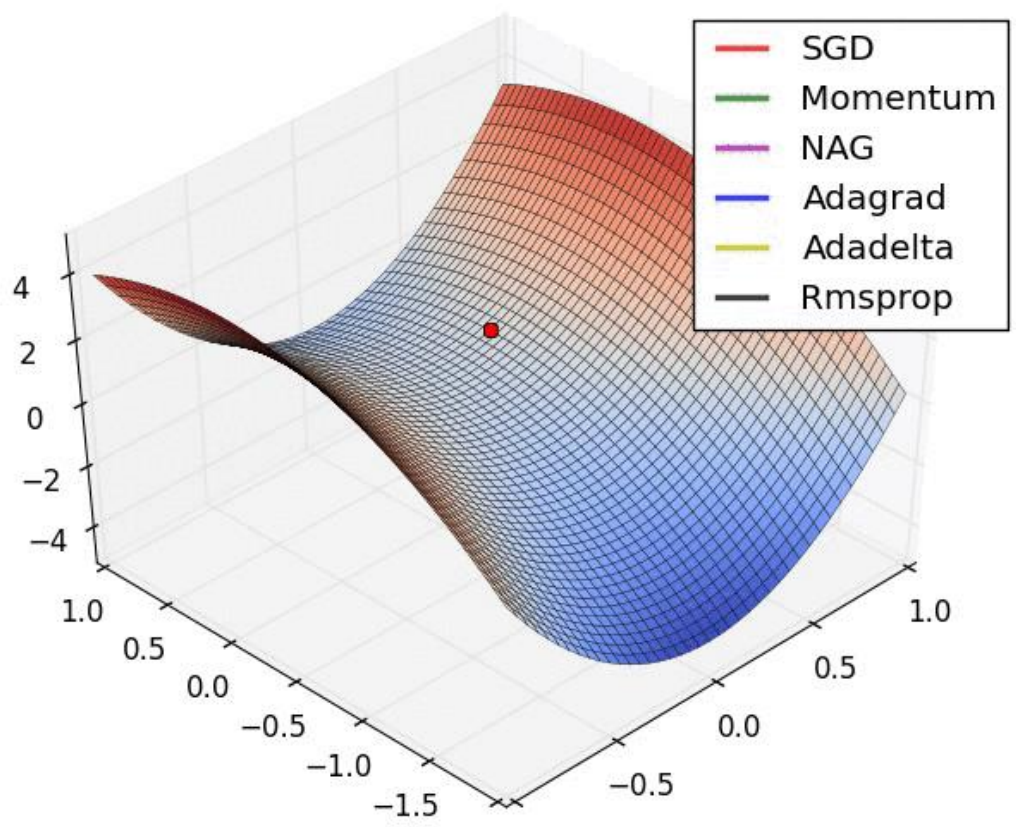
SGD
Momentum
NAG
Adagrad
Adadelta
Rmsprop
4
2
0
−2
−4
1.0
0.5
0.0
−0.5
−1.0
−1.5
1.0
0.5
0.0
−0.5

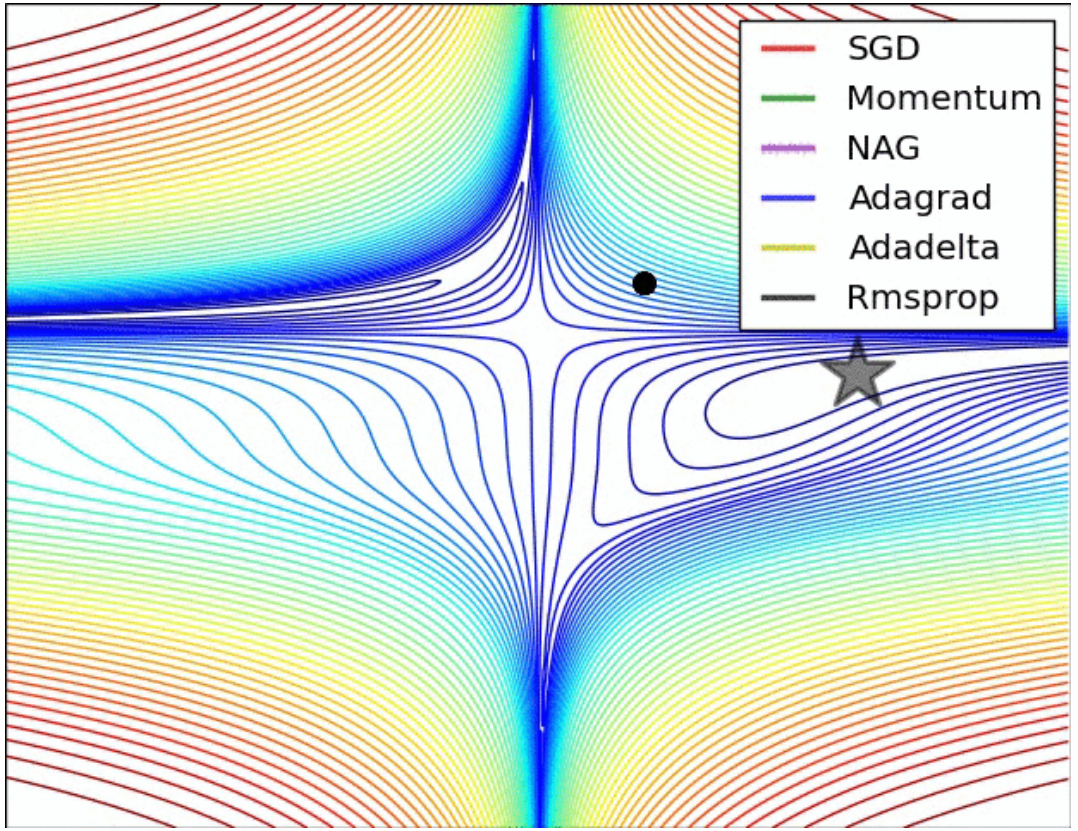
SGD
Momentum
NAG
Adagrad
Adadelta
Rmsprop

Momentum

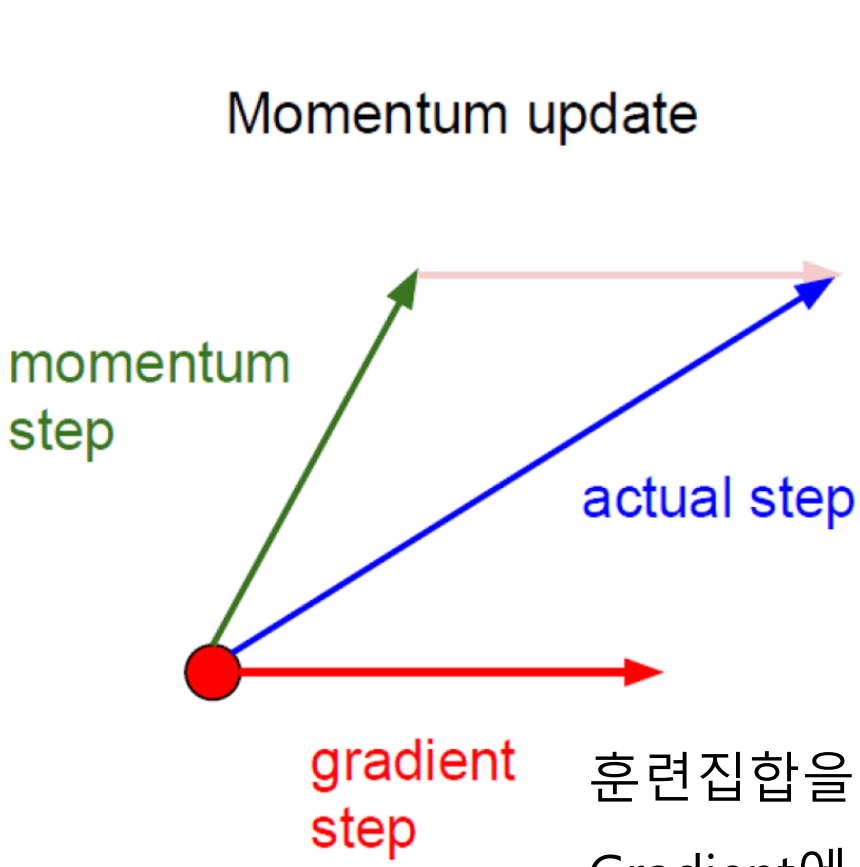

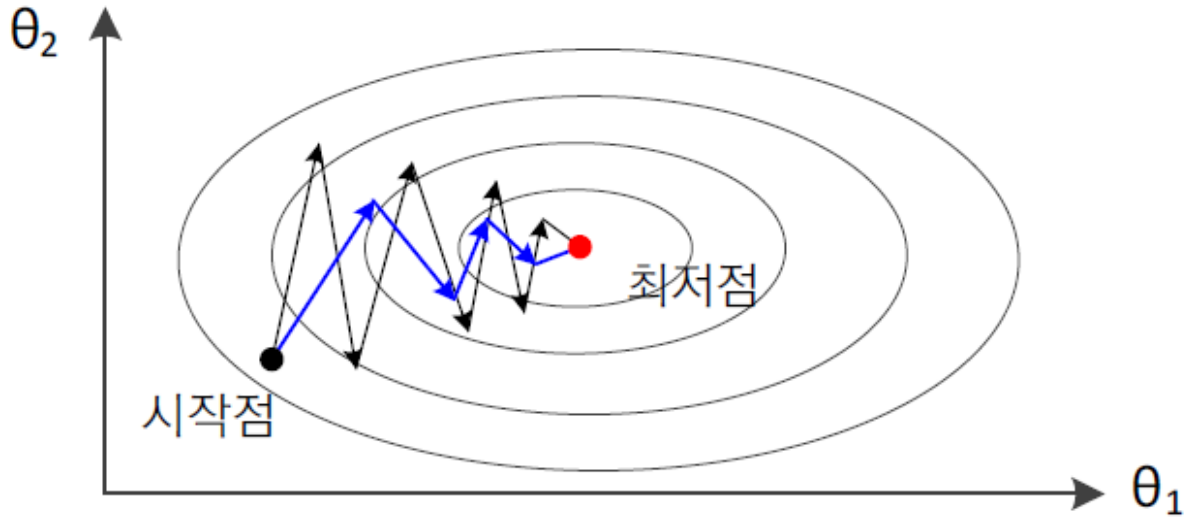

훈련집합을 이용해 gradient를 추정하면 잡음 가능성(오버슈팅 현상) 높음

Gradient에 스무딩을 가해 잡음 효과를 줄여 수렴 속도 향상

Softmax

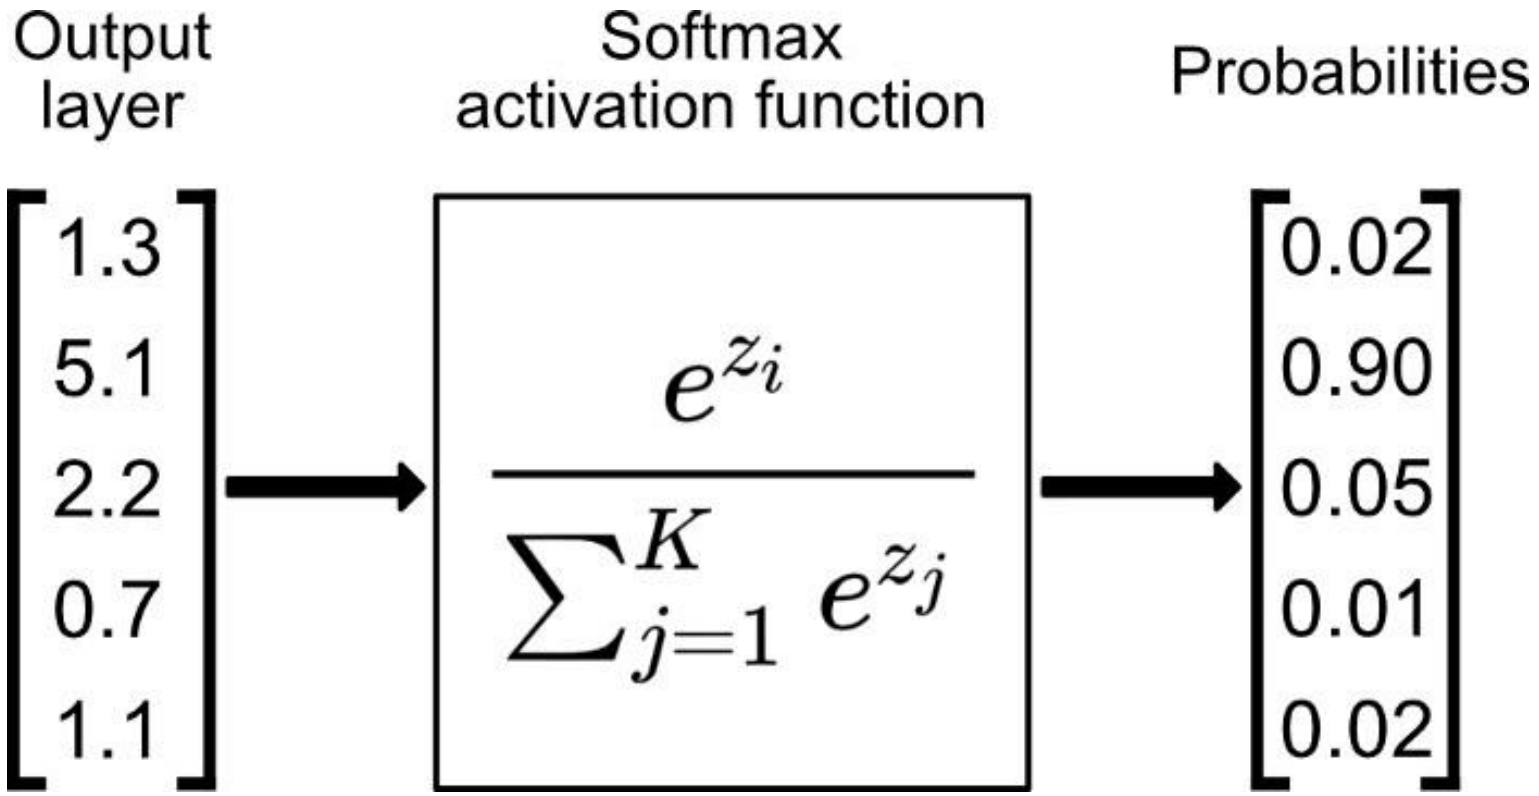

결과값을 확률값으로 변환하는 함수

전체 확률의 합은 1

FCN의 동작

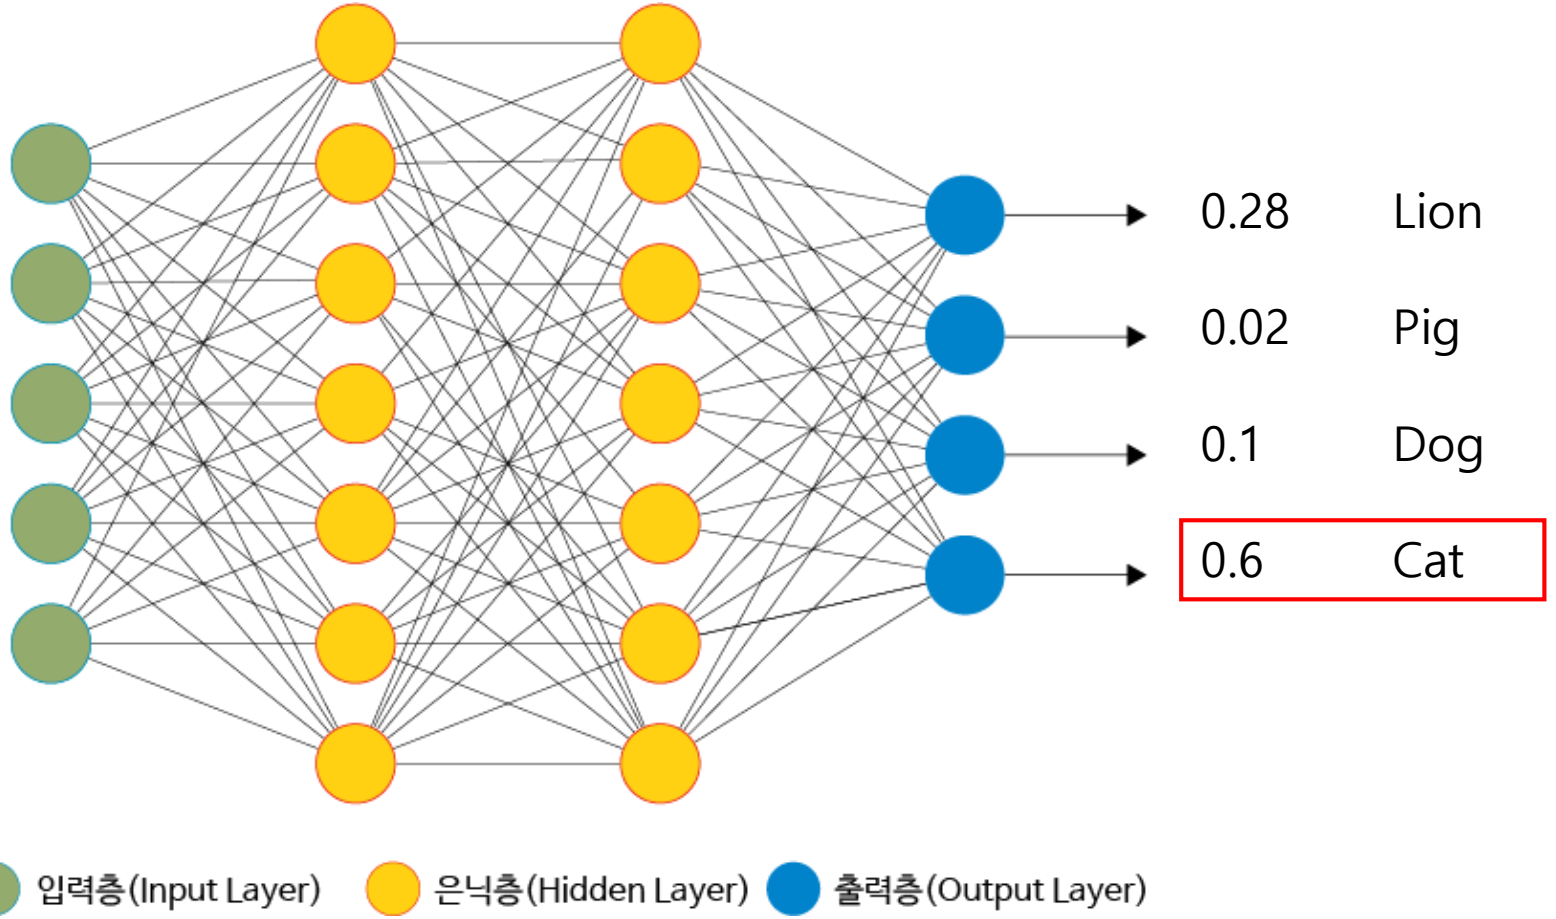
0.28 Lion
0.02 Pig
0.1 Dog
0.6 Cat
입력층(Input Layer)
은닉층(Hidden Layer)
출력층(Output Layer)

학습의 종류

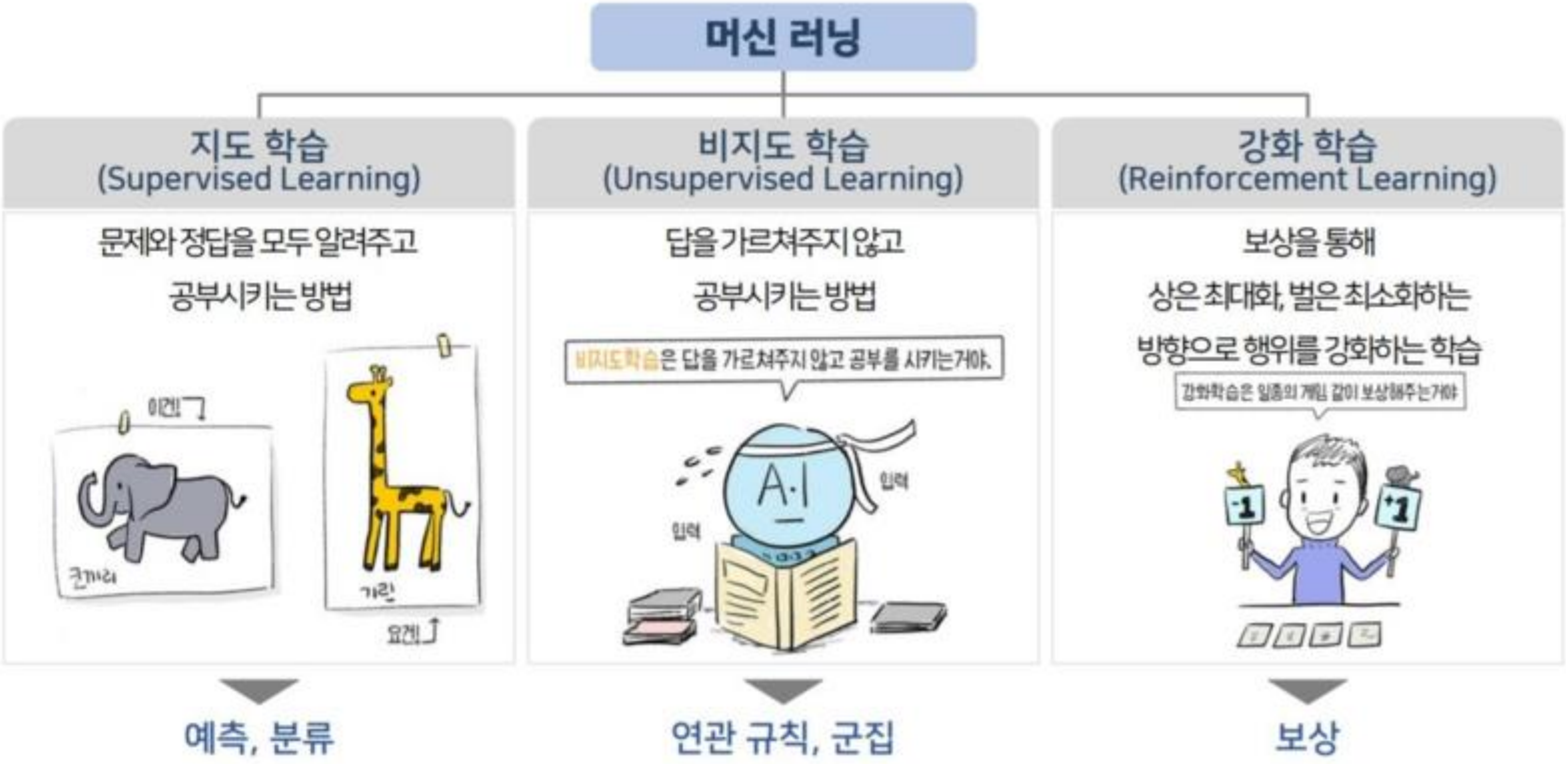

머신 러닝
지도 학습 (Supervised Learning)
문제와 정답을 모두 알려주고 공부시키는 방법
이건!
요건!
코끼리
기린
예측, 분류
비지도 학습 (Unsupervised Learning)
답을 가르쳐주지 않고 공부시키는 방법
비지도학습은 답을 가르쳐주지 않고 공부를 시키는거야.
A.I
입력
입력
연관 규칙, 군집
강화 학습 (Reinforcement Learning)
보상을 통해 상은 최대화, 벌은 최소화하는 방향으로 행위를 강화하는 학습
강화학습은 일종의 게임 같이 보상해주는거야
-1
+1
보상

딥러닝 검증 방법

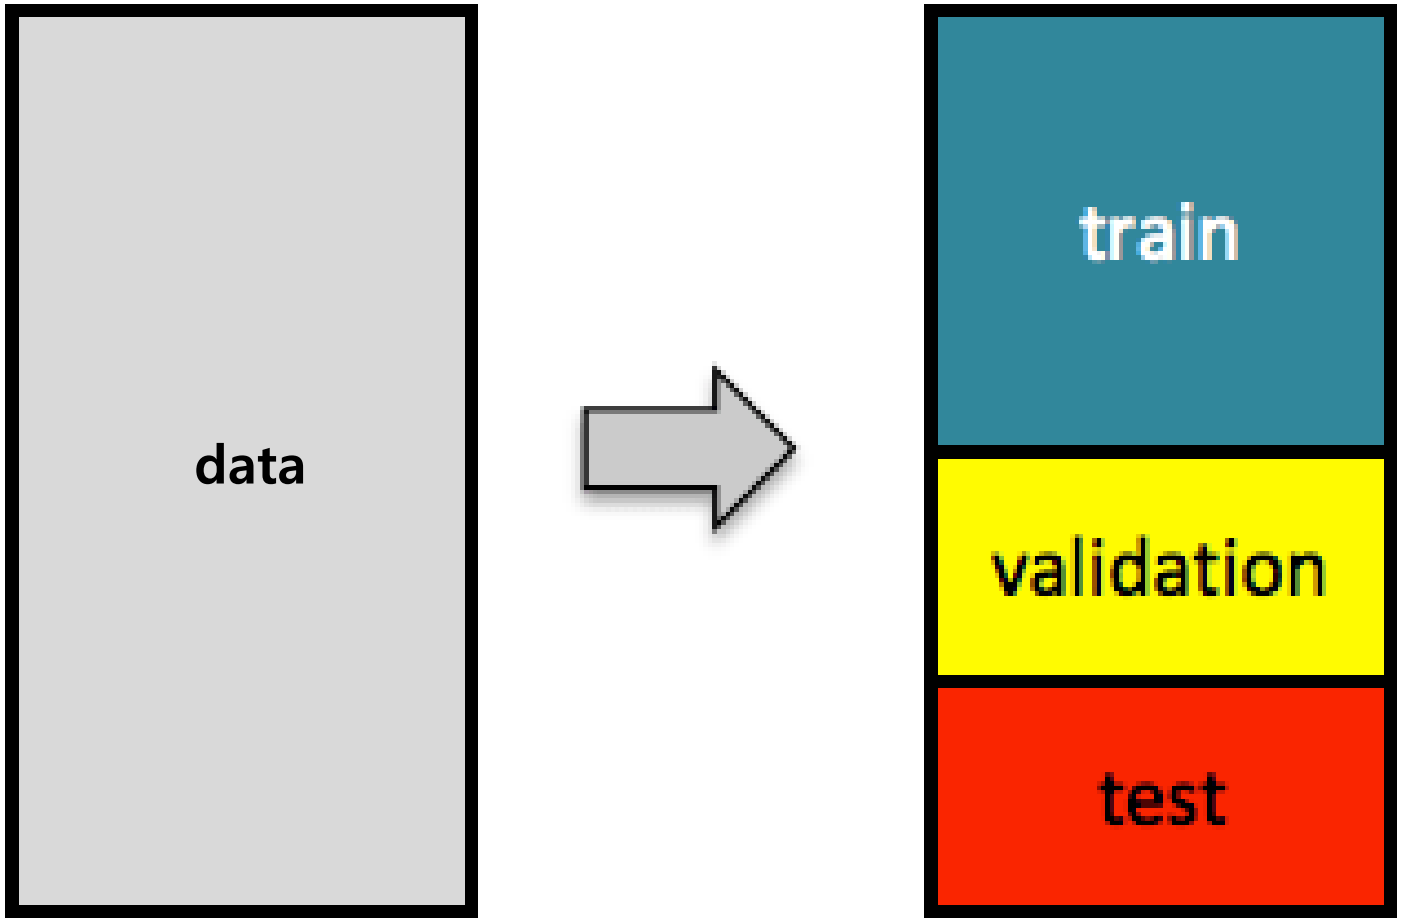

교차 검증

Train, Test set으로만 분할하면 Test set에 과적합되어 실제 데이터에서 성능이 낮아질 수 있다.

교차 검증이 모델의 일반화에 도움이 된다.

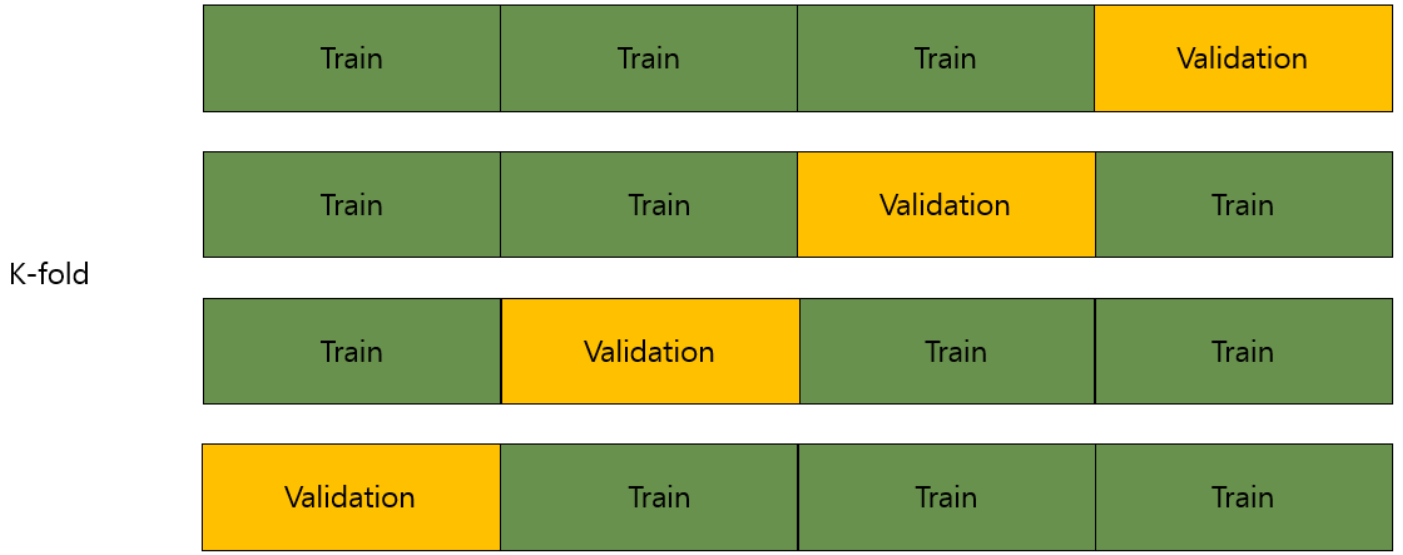

성능 평가

- 객관적인 성능 측정의 중요성
  - 모델 선택의 기준
- 일반화 능력
  - 학습에 사용하지 않았던 새로운 데이터에 대한 성능
  - 주어진 데이터를 분할하여 평가 전용으로 사용

성능 평가

Accuracy & Precision

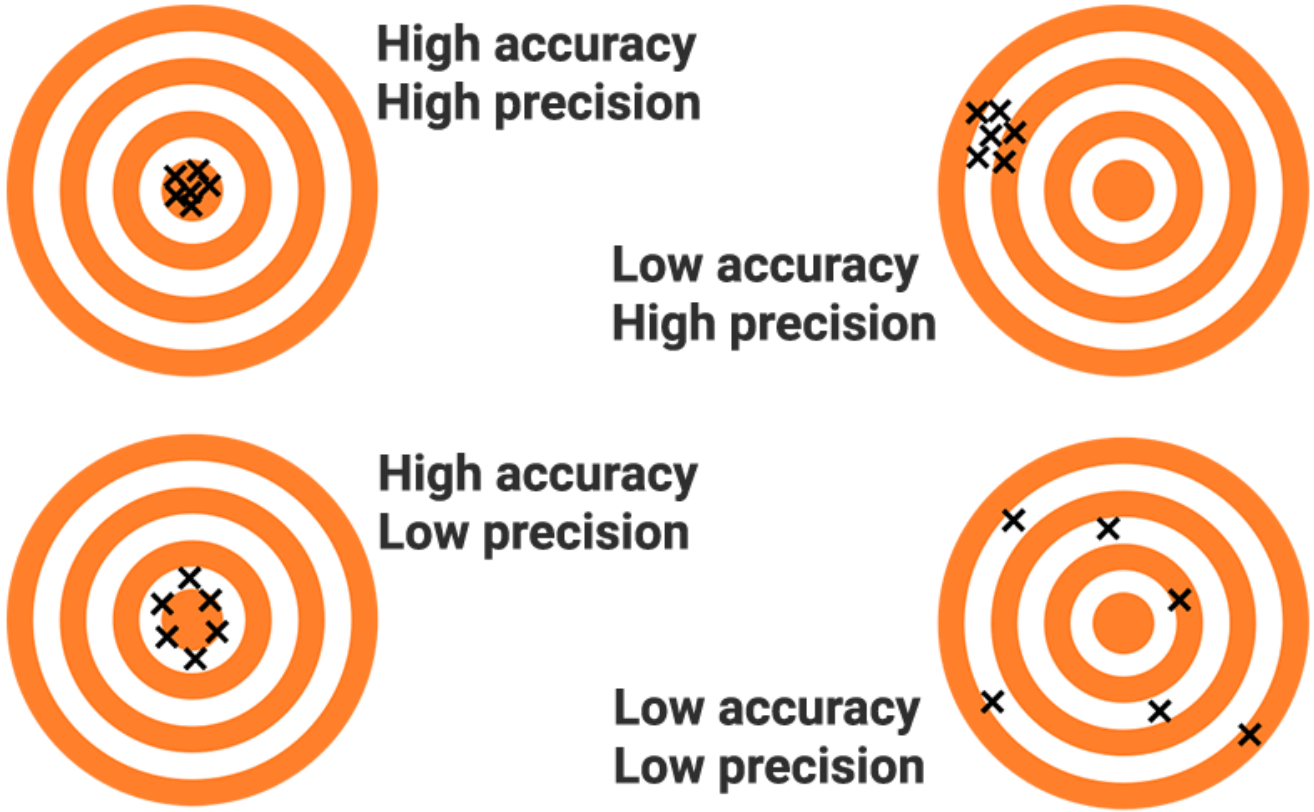

성능 평가

Confusion matrix

	Has disease	Does not have disease
Identified as having disease	True positive (TP)	False positive (FP)
Identified as not having disease	False negative (FN)	True negative (TN)

성능 평가

- Confusion Matrix 부류가 c개인 경우

		참값 (그라운드 트루스)					
		부류1	부류2	...	부류j	...	부류c
예측한 부류	부류1	n_{11}	n_{12}		n_{1j}		n_{1c}
	부류2	n_{21}	n_{22}		n_{2j}		n_{2c}
	...						
	부류i	n_{i1}	n_{i2}		n_{ij}		n_{ic}
	...						
	부류c	n_{c1}	n_{c2}		n_{cj}		n_{cc}

성능 평가

- 성능 측정 기준

$$\text{정확률} = \frac{\text{맞힌 샘플 수}}{\text{전체 샘플 수}} = \frac{\text{대각선의 샘플 수}}{\text{전체 샘플 수}}$$

$$\text{특이도} = \frac{\text{TN}}{\text{FP+TN}}, \ \text{민감도} = \frac{\text{TP}}{\text{TP+FN}}$$

$$\text{정밀도} = \frac{\text{TP}}{\text{TP+FP}}, \ \text{재현률} = \frac{\text{TP}}{\text{TP+FN}}$$

$$Fall\text{-}out(FPR) = \frac{FP}{TN + FP}$$

Over-fitting vs Under-fitting

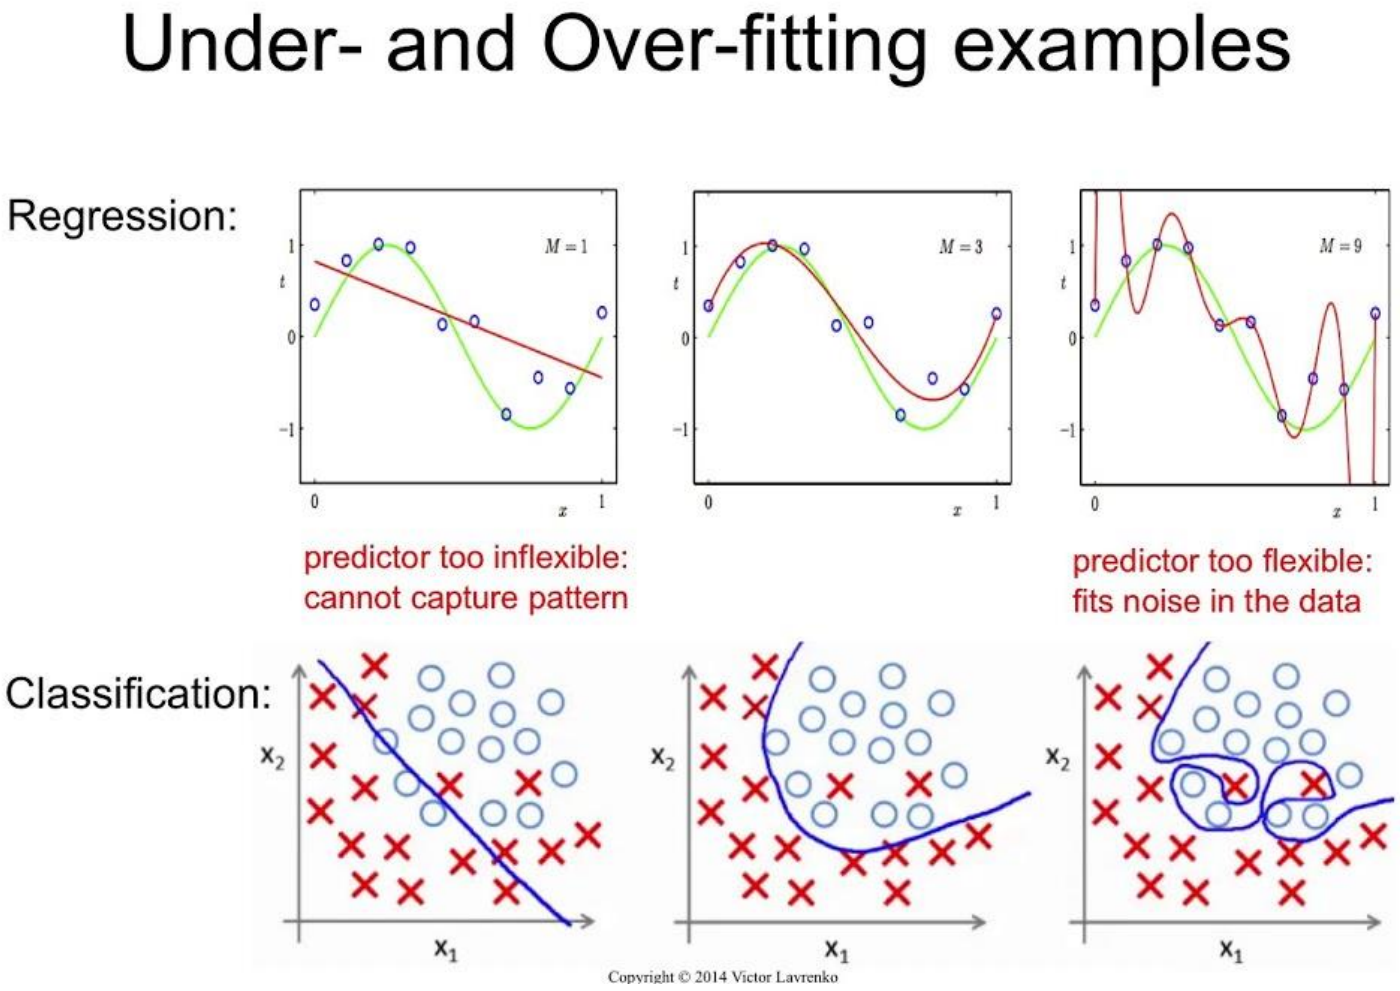

Over-fitting vs Under-fitting

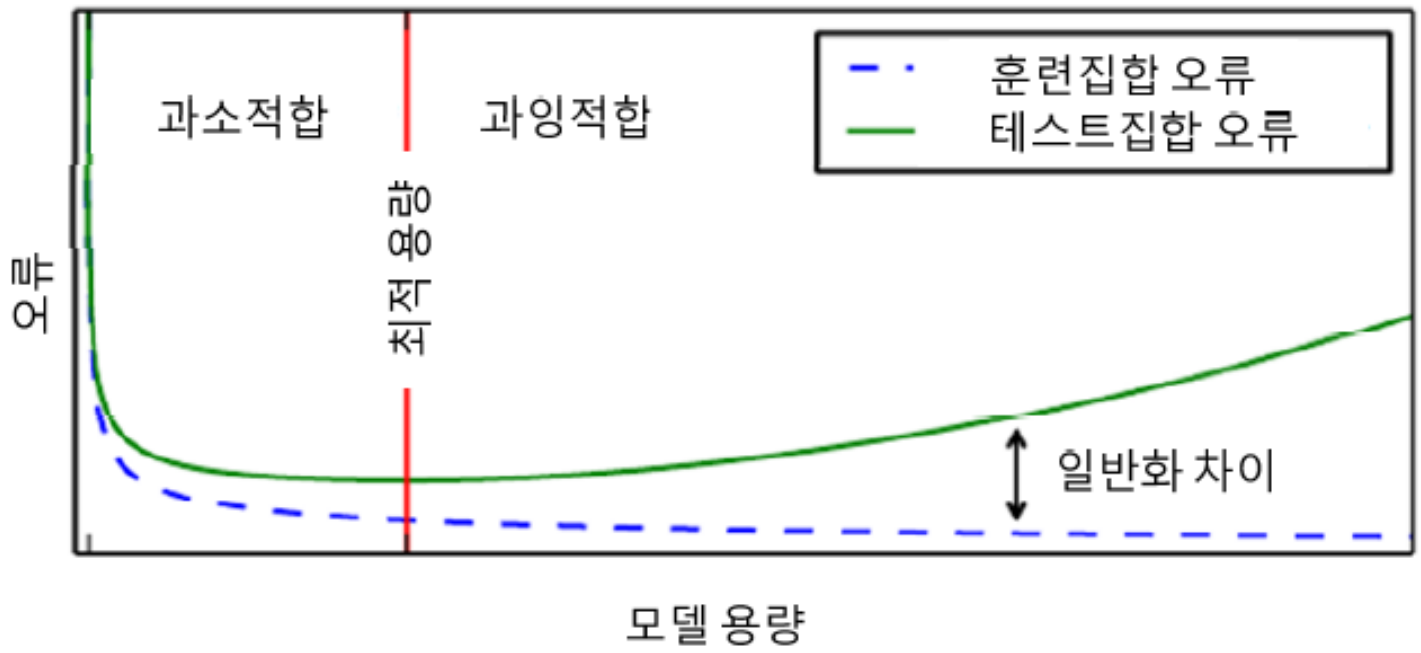

- 학습 모델 용량에 따라 일반화 능력 차이 생김
- 대부분 가진 데이터에 비해 모델의 용량이 큼
- 현대 기계학습 = 충분한 용량의 모델 설계 + 규제 기법 적용

규제 Regularization

- 과잉적합을 피하기 위함
- 명시적 규제: 가중치 감쇠, 드롭아웃 등 loss 함수나 신경망 구조 직접 수정
- 암시적 규제: 앙상블 등 간접적으로 영향

가중치 감쇠

- 복잡한 모델일수록 과적합 될 가능성이 높다.
- 네트워크의 복잡도를 줄임으로써 과적합을 완화시킨다.
- 가중치 감쇠 기법은 가중치가 작은 값을 가지도록 강제함으로써 복잡도를 줄인다.

Drop-out

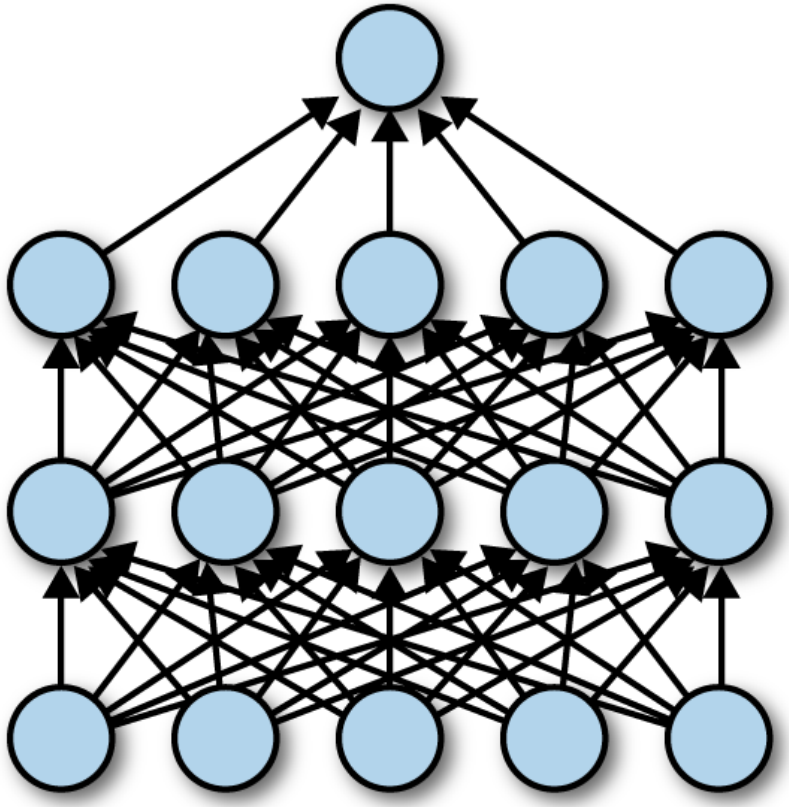

(a) Standard Neural Net

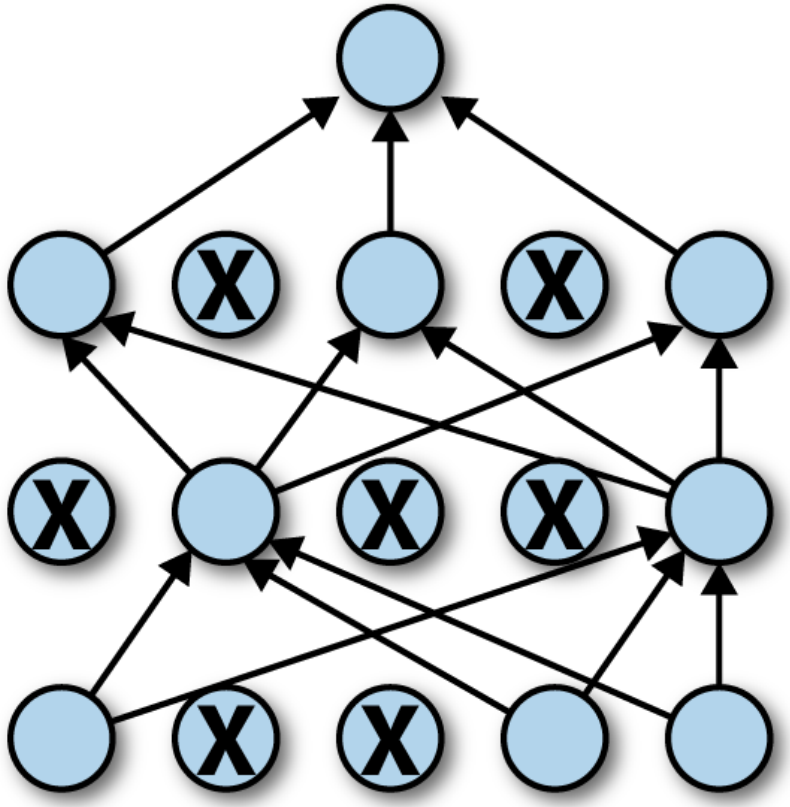

(b) After applying dropout

앙상블 기법

- 서로 다른 여러 개의 모델을 결합해 일반화 오류를 줄이는 기법
- 주로 투표 방식을 사용

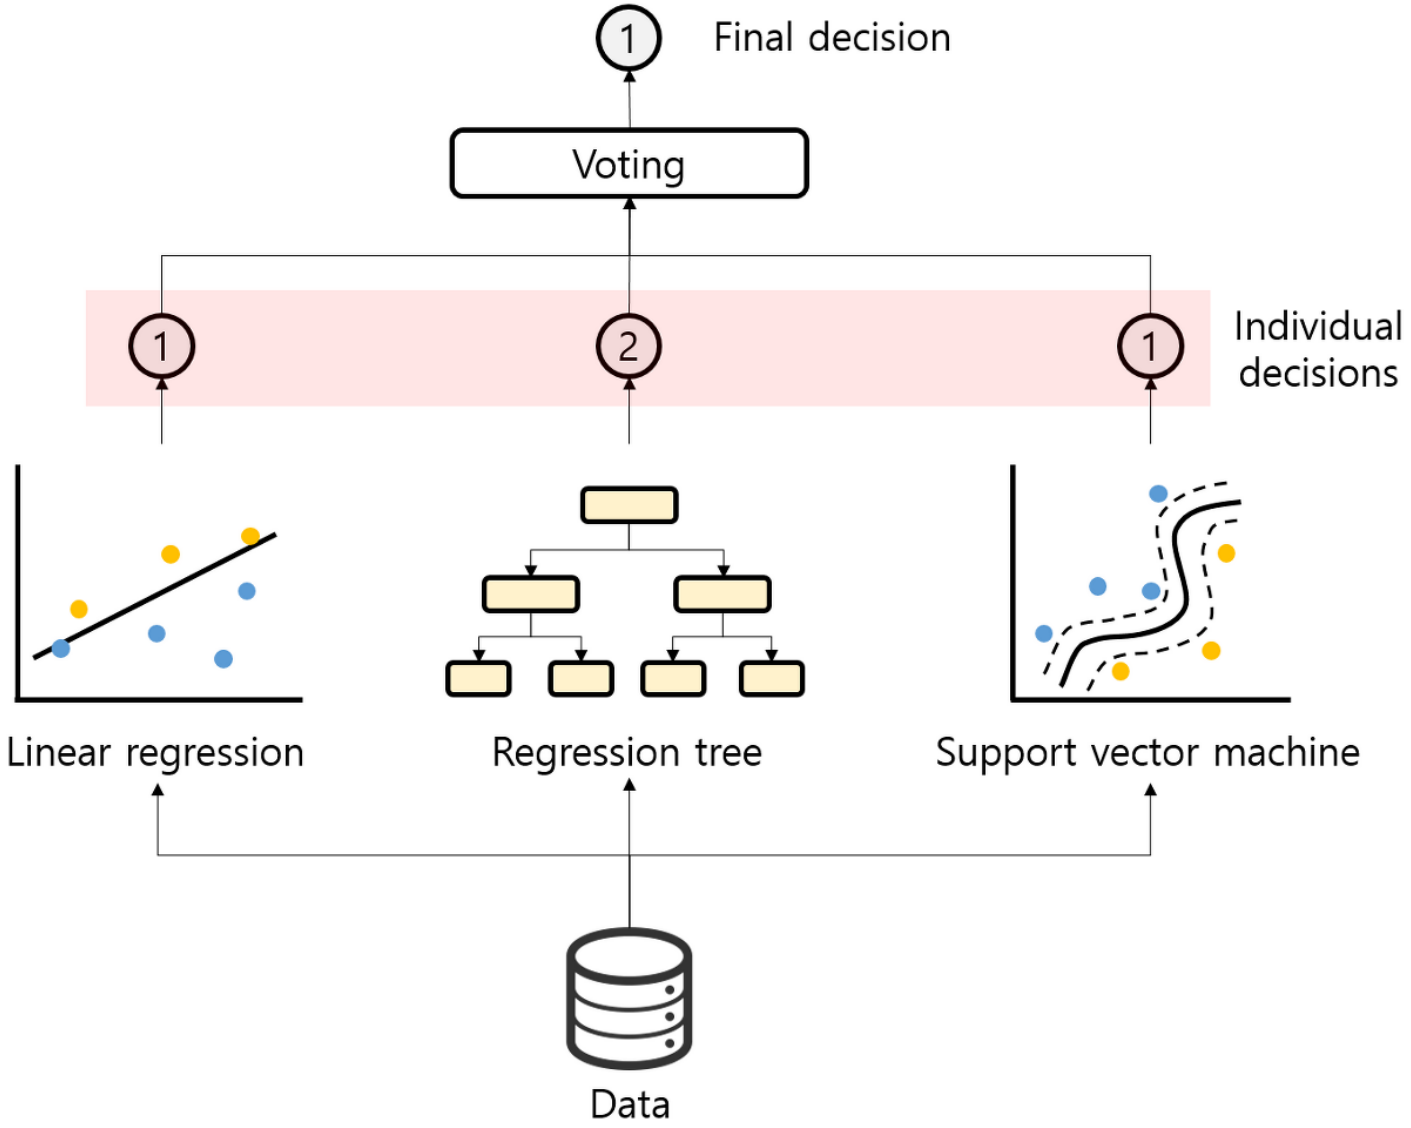

활성함수의 문제점

- 계단함수는 perceptron에서 사용하던 활성함수
  다층 퍼셉트론에서 사용하려니 미분 문제 발생
- Sigmoid 함수는 미분 시 0에서 1사이 값 발생
  층이 깊어질수록 gradient가 작아지는 문제 발생
- Tanh 함수는 sigmoid와 비슷하고 문제를 완화시킨다. 완전히 해결하지는 못함.
- ReLU 함수가 가장 많이 사용된다.

계단함수의 문제점

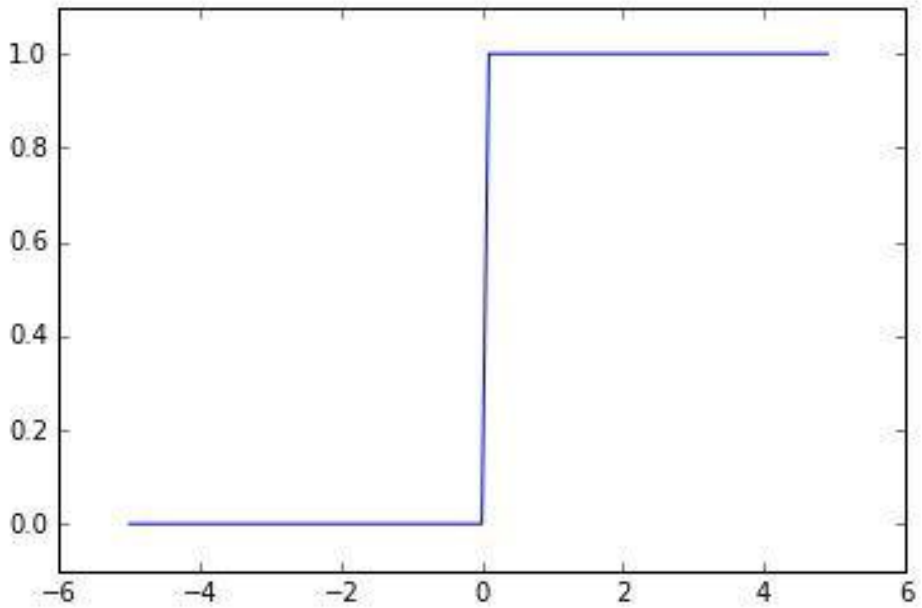

계단함수의 미분값은 0

$$w^{+} = w - \eta * \frac{\partial E}{\partial w}$$

learning rate :
한번에 얼마나 학습할지

gradient :
어떤 방향으로 학습할지

$$w = w - \eta * 0$$

$$= w$$

학습이 되지 않는다!

시그모이드 함수의 문제점

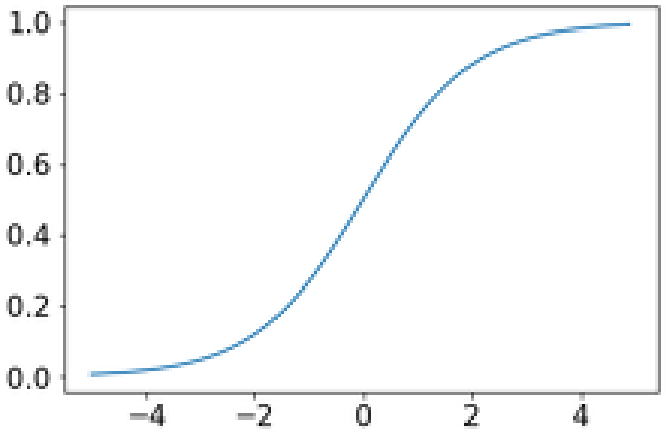

$$Sigmoid(x) = \frac{1}{1+e^{-x}}$$

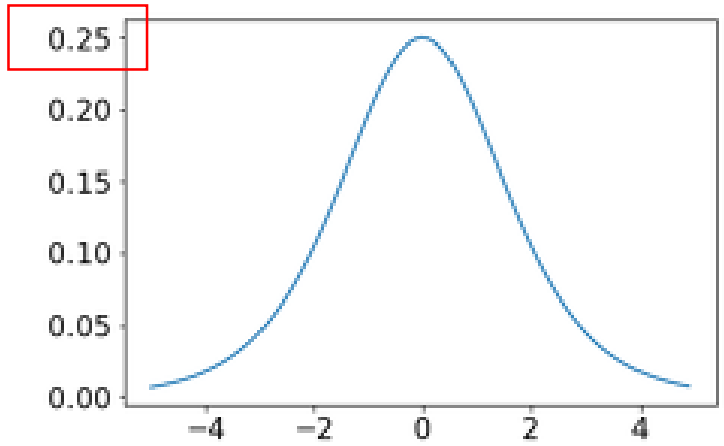

$$S'(x) = \frac{1}{1+e^{-x}}\left(1 - \frac{1}{1+e^{-x}}\right)$$

(0 , ¼] – 최대점 ¼, 0 에서 수평

gradient의 최대값이 0.25

층 하나를 거칠 때마다 gradient가 적어도 ¼씩 작아짐 -> vanishing gradient 문제

Tanh 함수

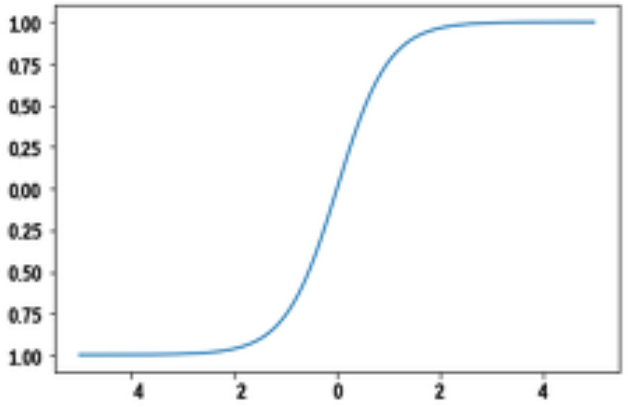

$$Tanh(x) = \frac{e^{2x}+1}{e^{2x}-1}$$

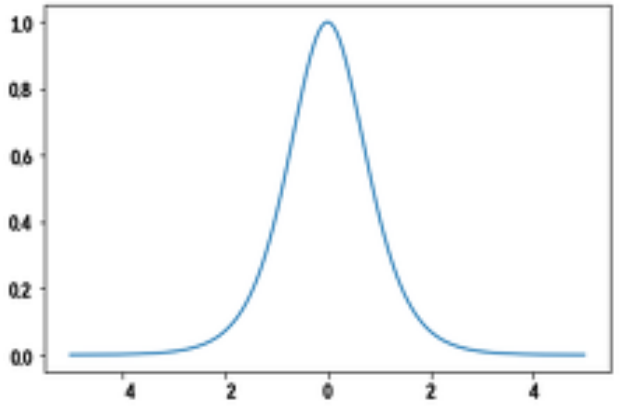

$$T'(x) = 1 - \tanh^2(x)$$

(0 , 1] – 최대점 1, 0 에서 수평

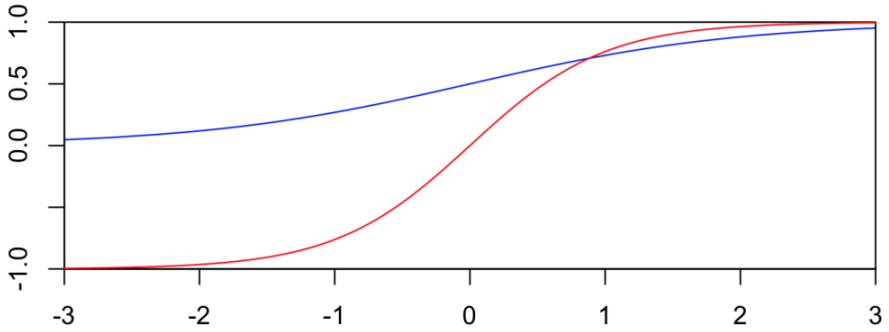

sigmoid 함수와의 비교
빨간색이 tanh 함수

하이퍼볼릭 탄젠트 함수

gradient의 최대값: 1

vanishing gradient 문제를 완화시키지만 완전히 해결하지 못한다.

ReLU 함수

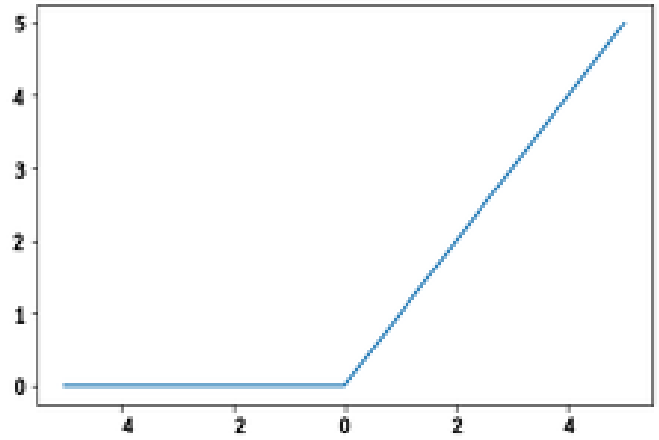

$$ReLU(x) = \max(0,\ x)$$

Rectified Linear Unit

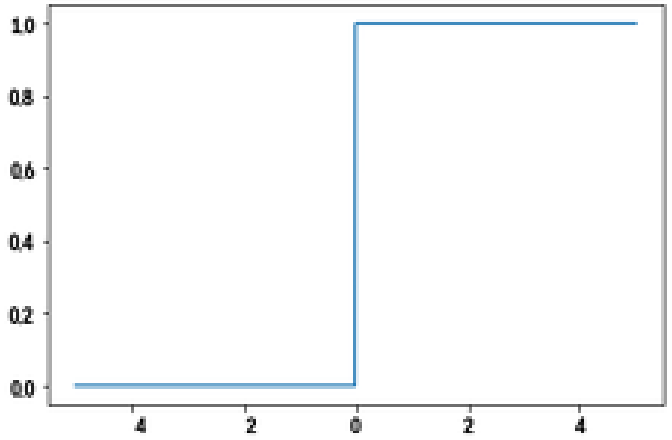

$$R'(y) = \begin{cases} 1 & (x \geq 0) \\ 0 & (x < 0) \end{cases}$$

gradient가 0 또는 1(계단함수 형태) -> 계산 속도가 빠르다.

vanishing gradient 문제를 덜 겪는다.

x < 0인 값들의 경우 gradient가 0이기 때문에 뉴런이 죽을 수 있다는 단점이 존재한다.

Leaky ReLU, PReLU, ELU등의 발전된 함수가 있다.

실습 수업 소개

- 파이썬과 pytorch 라이브러리를 사용

- 숫자 필기 데이터를 인식하여 분류

=> 5 0 4 1

딥러닝 기법

- 전이학습
- 가중치 초기화
- 배치 정규화

감사합니다

출처

- https://en.wikipedia.org/wiki/Turing_test
- https://www.ibm.com/ibm/history/ibm100/us/en/icons/ibm700series/impacts/
- https://www.mentalfloss.com/article/503178/brief-history-deep-blue-ibms-chess-computer
- https://commons.wikimedia.org/wiki/File:MIT_lisp_machine.jpg
- https://sciencebasedmedicine.org/ibm-watson-versus-cancer-hype-meets-reality/
- https://cv.gluon.ai/build/examples_datasets/imagenet.html
- https://semiengineering.com/deep-learning-spreads/
- https://www.alphagomovie.com/
- https://towardsdatascience.com/what-even-is-computer-vision-531e4f07d7d0
- https://medium.com/analytics-vidhya/automatic-speech-recognition-systems-in-deep-learning-a6f91bbe7500
- https://www.nvidia.com/en-us/geforce/news/nvidia-dlss-2-0-a-big-leap-in-ai-rendering/
- https://m.blog.naver.com/dududuapp/220656729283
- https://www.tesla.com/autopilot
- https://www.teslarati.com/openai-bots-defeat-pro-dota-2-players/
- https://snowdeer.github.io/machine-learning/2018/01/02/perceptron/
- https://yeowool0217.tistory.com/502
- https://blog.naver.com/handuelly/221824080339
- https://m.blog.naver.com/PostView.nhn?blogId=pmw9440&logNo=221401111139&proxyReferer=https:%2F%2Fwww.google.com%2F
- https://cs231n.github.io/convolutional-networks/
- https://leechanho.tistory.com/29
- https://ml-cheatsheet.readthedocs.io/en/latest/loss_functions.html
- https://www.anotsorandomwalk.com/backpropagation-example-with-numbers-step-by-step/
- https://mc.ai/visualising-relationships-between-loss-activation-functions-and-gradient-descent/
- https://techblog-history-younghunjo1.tistory.com/78

출처

- https://www.fromthegenesis.com/gradient-descent-part1/
- https://mc.ai/an-introduction-to-gradient-descent-2/
- https://bioinformaticsandme.tistory.com/130
- http://blog.naver.com/PostView.nhn?blogId=qbxlvnf11&logNo=221449297033&parentCategoryNo=&categoryNo=52&viewDate=&isShowPopularPosts=false&from=postView
- https://www.infinitycodex.in/
- https://seamless.tistory.com/38
- https://ratsgo.github.io/deep%20learning/2017/04/22/NNtricks/
- https://becominghuman.ai/alphagos-mastery-continues-3cd01493f539
- https://gomguard.tistory.com/
- https://towardsdatascience.com/softmax-activation-function-explained-a7e1bc3ad60
- https://www.medcalc.org/manual/tanh_function.php
- https://knight76.tistory.com/m/entry/%EC%98%A4%EB%B2%84-%ED%94%BC%ED%8C%85over-fitting%EA%B3%BC-%EC%96%B8%EB%8D%94-%ED%94%BC%ED%8C%85under-fitting?category=689271
- http://www.tcpschool.com/deep2018/deep2018_deeplearning_intro
- https://jjeongil.tistory.com/578
- https://untitledtblog.tistory.com/156
- http://blog.naver.com/PostView.nhn?blogId=k0sm0s1&logNo=221863569856&categoryNo=6&parentCategoryNo=0&viewDate=&currentPage=1&postListTopCurrentPage=1&from=postView
- http://www.appliedmachinelearningacademy.com/?p=4057
- https://rk1993.tistory.com/entry/%EA%B5%90%EC%B0%A8%EA%B2%80%EC%A6%9DCross-Validation-%EC%89%BD%EA%B2%8C-%EC%9D%B4%ED%95%B4%ED%95%98%EA%B8%B0
- https://soluzionesolare.com/guides/difference-between-accuracy-and-precision/
- https://www.dataschool.io/simple-guide-to-confusion-matrix-terminology/
- https://qastack.kr/stats/336455/fpr-false-positive-rate-vs-fdr-false-discovery-rate
- https://towardsdatascience.com/softmax-activation-function-explained-a7e1bc3ad60
- https://brenocon.com/blog/2013/10/tanh-is-a-rescaled-logistic-sigmoid-function/
- https://tensorflowkorea.gitbooks.io/tensorflow-kr/content/g3doc/tutorials/mnist/download/
- https://ayearofai.com/rohan-lenny-1-neural-networks-the-backpropagation-algorithm-explained-abf4609d4f9d