

Deep Learning Study

2020/04/28

ByungChan Lee

강의 목록

파이썬과 벡터화



벡터화

업데이트 : 2020.02.06 | ♥ 7



더 많은 벡터화 예제

업데이트 : 2020.03.23 | ♥ 8



로지스틱 회귀의 벡터화

업데이트 : 2020.02.22 | ♥ 8



로지스틱 회귀의 경사 계산을 벡터화 하기

업데이트 : 2020.02.06 | ♥ 7



파이썬의 브로드캐스팅

업데이트 : 2020.02.29 | ♥ 8



파이썬과 넘파이 벡터

업데이트 : 2020.02.11 | ♥ 8



Jupyter/iPython Notebooks 가이드

업데이트 : 2020.02.06 | ♥ 3



로지스틱 회귀의 비용함수 설명

업데이트 : 2020.02.29 | ♥ 13

Jupyter/iPython Notebooks

- <https://www.edwith.org/deeplearningai1/lecture/34817/>



Quick Tour of Jupyter/iPython Notebooks 원본보기



[WINDOWS]컴퓨터노트북설치하기 PDF

윈도우 운영체제 Jupyter notebook 튜토리얼입니다.



[MAC]컴퓨터노트북설치하기 PDF

MAC 운영체제 Jupyter notebook 튜토리얼입니다.

Review

- Loss function

$$\mathcal{L}(\hat{y}, y) = \frac{1}{2} (\hat{y} - y)^2$$



→ 경사하강법을 사용할 때, local optimum에 갇혀서 global optimum을 찾지 못할 수 있다.

→ Cross entropy

$$\mathcal{L}(\hat{y}, y) = -[y \log \hat{y} + (1 - y) \log(1 - \hat{y})]$$

- Cost function

$$J(w, b) = -\frac{1}{m} \sum_{i=1}^m [y^{(i)} \log \hat{y}^{(i)} + (1 - y^{(i)}) \log(1 - \hat{y}^{(i)})]$$



Logistic Regression : Cost function

- Interpret $\hat{y} = P(y = 1|x)$

$$\text{if } y = 1, \quad P(y|x) = \hat{y}$$

$$\text{if } y = 0, \quad P(y|x) = 1 - \hat{y}$$

- $P(y|x) = \hat{y}^y (1 - \hat{y})^{1-y}$

$$\log P(y|x) = y \log \hat{y} + (1 - y) \log(1 - \hat{y}) \equiv -\mathcal{L}(\hat{y}, y) \quad \text{maximum } P \rightarrow \text{minimum } L$$

- $P(\text{labels in training set}) = \prod_{i=1}^m P(y^{(i)}|x^{(i)})$

- $\log P = -\sum_{i=1}^m \mathcal{L}(\hat{y}^{(i)}, y^{(i)})$

- $J(w, b) = \frac{1}{m} \sum_{i=1}^m \mathcal{L}(\hat{y}^{(i)}, y^{(i)})$ average of loss functions

Vectorization

$$z = w^T x + b \quad x = \begin{bmatrix} \dots \\ \dots \\ \dots \\ \dots \end{bmatrix} \quad w = \begin{bmatrix} \dots \\ \dots \\ \dots \\ \dots \end{bmatrix}$$

- for loop

```
for i in range(1000000):
```

```
    c += w[i]*x[i]
```


- Vectorization

```
import numpy as np
```

```
c = np.dot(w.T, x)
```

- for loop을 최소화하고 벡터와 함수를 적극적으로 활용하면 연산속도가 **훨씬** 빨라진다.

- SIMD; Single instruction, multiple data



Vectorization

```
In [12]: 1 import numpy as np
          2 import time
          3
          4 a = np.random.rand(1000000)
          5 b = np.random.rand(1000000)
          6
          7 tic = time.time()
          8 c = np.dot(a,b)
          9 toc = time.time()
         10
         11 print(c)
         12 print("Vectorized Version : " + str(1000*(toc-tic)) + "ms")
         13
         14 c = 0
         15 tic = time.time()
         16 for i in range(1000000):
         17     c += a[i]*b[i]
         18 toc = time.time()
         19
         20 print(c)
         21 print("for-loop Version : " + str(1000*(toc-tic)) + "ms")
```

```
249965.8632635132
Vectorized Version : 0.9999275207519531ms
249965.86326351386
for-loop Version : 660.2320671081543ms
```

- 660 times faster
- 1 min vs 11 hours

```
In [ ]: 1
```

Vectorization

Numpy 함수

- exp
- log
- abs
- maximum
- **
- /
- zeros

$$a = \begin{bmatrix} a_1 \\ a_2 \\ a_3 \\ \vdots \end{bmatrix} \xrightarrow{e = \text{np.exp}(a)} e = \begin{bmatrix} e^{a_1} \\ e^{a_2} \\ e^{a_3} \\ \vdots \end{bmatrix}$$

* tip : 구현하고 싶은 연산이 for 문을 필요로 하면, 내장 함수를 먼저 살펴봐라

Vectorization

$$X = \begin{bmatrix} | & | & | \\ x_1 & x_2 & \dots \\ | & | & | \end{bmatrix} \quad n \times m$$

$$Z = [z_1, z_2, \dots]$$

1

- $Z = \text{np.dot}(w.T, X) + b$
- $A = \sigma(z)$

2

- $dw = \text{np.zeros}(n, 1)$
- $dw += x[i] * dz[i]$
- $dw /= m$

Logistic regression derivatives

```
J = 0, dw1 = 0, dw2 = 0, db = 0
1 → for i = 1 to m:
    z(i) = wTx(i) + b
    a(i) = σ(z(i))
    J += -[y(i) log ŷ(i) + (1 - y(i)) log(1 - ŷ(i))]
    dz(i) = a(i)(1 - a(i))
    2 → dw1 += x1(i) dz(i)
        dw2 += x2(i) dz(i)
        db += dz(i)
J = J/m, dw1 = dw1/m, dw2 = dw2/m, db = db/m
```

Vectorization

```
J = 0, dw1 = 0, dw2 = 0, db = 0
for i = 1 to m:
    z(i) = wTx(i) + b
    a(i) = σ(z(i))
    J += -[y(i) log a(i) + (1 - y(i)) log(1 - a(i))]
    dz(i) = a(i) - y(i)
    dw1 += x1(i) dz(i)
    dw2 += x2(i) dz(i)
    db += dz(i)
J = J/m, dw1 = dw1/m, dw2 = dw2/m
db = db/m
```



```
z = wTX + b
    = np.dot(w.T, X) + b
A = σ(z)
dz = A - Y
dw = 1/m X dzT
db = 1/m np.sum(dz)

w := w - α dw
b := b - α db
```

- 경사하강법 전체를 for loop 없이 구현 가능

Broadcasting

```
In [27]: 1 a = np.array([1, 2, 3])
          2 b = 100
          3 c = a+b
          4 print(c)
```

```
[101 102 103]
```

```
In [30]: 1 a = np.array([[1, 2, 3],
          2                  [4, 5, 6]])
          3 b = np.array([[100, 200, 300]])
          4 c = a+b
          5 print(c)
```

```
[[101 202 303]
 [104 205 306]]
```

```
In [34]: 1 a = np.array([[100, 200, 300],
          2                  [450, 520, 664]])
          3 b = np.array([[100, 200, 300]])
          4 c = a/b
          5 print(c)
```

```
[[1.         1.         1.        ]
 [4.5        2.6        2.21333333]]
```

- 코드를 짧고 빠르게 만들어 준다.

Reshape

```
In [49]: 1 a = np.array([[100, 200, 300],
2               [450, 520, 664]])
3 b = a.reshape(2, 3)
4 c = a.reshape(6)
5 d = a.reshape(3, 2)
6 print(b)
7 print(c)
8 print(d)
```

```
[[100 200 300]
 [450 520 664]]
[100 200 300 450 520 664]
[[100 200]
 [300 450]
 [520 664]]
```

- 차원이 불분명할 때 reshape를 사용하여 확실히 의도하는 차원으로 만들어 줄 수 있다.
- reshape 함수를 호출할 때 상수시간이 소요되기 때문에 전체 속도에 큰 영향을 미치지 않는다.

Broadcasting

In [51]:

```
1 a = np.array([[10],  
2               [20],  
3               [30]])  
4 b = np.array([[1, 2, 3]])  
5 c = a+b  
6 print(c)
```

```
[[11 12 13]  
 [21 22 23]  
 [31 32 33]]
```

- Numpy의 유연성은 장점이자 단점이 될 수 있다.
- 브로드캐스팅의 작동 원리를 잘 모르면 원인을 알기 힘든 버그가 발생하기 쉽다.

Broadcasting

In [52]:

```
1 a = np.random.rand(5)
2 print(a)
3 print(a.T)
4 b = np.random.rand(5)
5 c = np.dot(a.T,b)
6 print(c)
```

```
[0.94279148 0.63942625 0.73003016 0.12247464 0.6993223 ]
[0.94279148 0.63942625 0.73003016 0.12247464 0.6993223 ]
0.9119557383994352
```

In [54]:

```
1 a = np.random.rand(1,5)
2 print(a)
3 print(a.T)
4 b = np.random.rand(1,5)
5 c = np.dot(a.T,b)
6 print(c)
```

```
[[0.95640169 0.88210857 0.69889984 0.26178702 0.20102956]]
[[0.95640169]
 [0.88210857]
 [0.69889984]
 [0.26178702]
 [0.20102956]]
[[0.84794601 0.24909704 0.67584544 0.74139408 0.00835518]
 [0.78207771 0.22974723 0.62334588 0.68380272 0.00770615]
 [0.61964479 0.18203009 0.49388063 0.54178094 0.00610563]
 [0.23210045 0.06818304 0.18499294 0.20293497 0.00228699]
 [0.17823286 0.05235862 0.14205842 0.15583632 0.00175621]]
```

Broadcasting

```
In [61]: 1 a = np.random.rand(5)
          2 print(a.shape)
          3 b = np.random.rand(1,5)
          4 print(b.shape)
          5
          6 a = a.reshape(1,5)
          7 assert(b.shape == (1,5))
          8 print(a.shape)

(5,)
(1, 5)
(1, 5)
```

- `a = np.random.rand(5)` : do not use
- `a = np.random.rand(1,5)` : a row vector
- `a = np.random.rand(5,1)` : a column vector

assert와 reshape를 적극적으로 활용하라


- `assert(a.shape == (1,5))`
- `a = a.reshape(1,5)`

강의 목록


알은 신경망 네트워크	
	신경망 네트워크 개요 업데이트 : 2020.02.06 ♥ 8
	신경망 네트워크의 구성 알아보기 업데이트 : 2020.02.06 ♥ 5
	신경망 네트워크 출력의 계산 업데이트 : 2020.02.06 ♥ 9
	많은 샘플에 대한 벡터화 업데이트 : 2020.03.01 ♥ 6
	벡터화 구현에 대한 설명 업데이트 : 2020.03.01 ♥ 9
	활성화 함수 업데이트 : 2020.02.06 ♥ 7
	왜 비선형 활성화 함수를 써야할까요? 업데이트 : 2020.03.02 ♥ 6
	활성화 함수의 미분 업데이트 : 2020.03.05 ♥ 6
	신경망 네트워크와 경사 하강법 업데이트 : 2020.03.07 ♥ 8
	역전파에 대한 이해 업데이트 : 2020.03.09 ♥ 9
	랜덤 초기화 업데이트 : 2020.02.29 ♥ 7

Neural Network

■ Logistic regression




■ Neural network



Neural Network

- 2 Layer Neural Network



- Input layer는 세지 않는다. (convention)
- hidden layer의 값은 알 수 없다. training example은 (x, y) 로 주어진다.
- a : activation ($a^{[0]} = x$)

Neural Network

$$z^{[i]} = W^{[i]}a^{[i-1]} + b^{[i]}$$

$$a^{[i]} = \sigma(z^{[i]})$$

$$z^{[i]} = \begin{bmatrix} - & w_1^{[i]T} & - \\ - & w_2^{[i]T} & - \\ & \vdots & \end{bmatrix} \begin{bmatrix} a_1^{[i-1]} \\ a_2^{[i-1]} \\ \vdots \end{bmatrix} + \begin{bmatrix} b_1^{[i]} \\ b_2^{[i]} \\ \vdots \end{bmatrix}$$

$n_i \times n_{i-1}$

- 2-Layer NN, given input x

$$z^{[1]} = W^{[1]}x + b^{[1]}$$

$$a^{[1]} = \sigma(z^{[1]})$$

$$z^{[2]} = W^{[2]}a^{[1]} + b^{[2]}$$

$$a^{[2]} = \sigma(z^{[2]})$$

← Vectorized

Neural Network

- Vectorizing across Multiple examples

a single example

$$z^{[i]} = \begin{bmatrix} - & w_1^{[i]T} & - \\ - & w_2^{[i]T} & - \\ & \vdots & \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} + \begin{bmatrix} b_1^{[i]} \\ b_2^{[i]} \\ \vdots \end{bmatrix}$$

multiple examples

for i in range(m)

$$z^{[1]}(i) = W^{[1]}x^{(i)} + b^{[1]}$$

$$a^{[1]}(i) = \sigma(z^{[1]}(i))$$

$$z^{[2]}(i) = W^{[2]}a^{[1]}(i) + b^{[2]}$$

$$a^{[2]}(i) = \sigma(z^{[2]}(i))$$

Vectorizing

$$X = \begin{bmatrix} | & | & \\ x^{(1)} & x^{(2)} & \dots \\ | & | & \end{bmatrix}_{n \times m}$$

$$Z^{[i]} = \begin{bmatrix} | & | & \\ z^{[i]}(1) & z^{[i]}(2) & \dots \\ | & | & \end{bmatrix} \quad A^{[i]} = \begin{bmatrix} | & | & \\ a^{[i]}(1) & \dots & a^{[i]}(m) \\ | & | & \end{bmatrix}$$

Neural Network

- 2-Layer NN, given input X

$$Z^{[1]} = W^{[1]}X + b^{[1]}$$

$$A^{[1]} = \sigma(Z^{[1]})$$

$$Z^{[2]} = W^{[2]}A^{[1]} + b^{[2]}$$

$$A^{[2]} = \sigma(Z^{[2]})$$

Back up
