



# Μηχανική Μάθηση: Μαθηματικό Υπόβαθρο

---

Κωνσταντίνος Καραμανής

The University of Texas at Austin & Archimedes/Athena RC

[constantine@utexas.edu](mailto:constantine@utexas.edu)

<https://caramanis.github.io/>



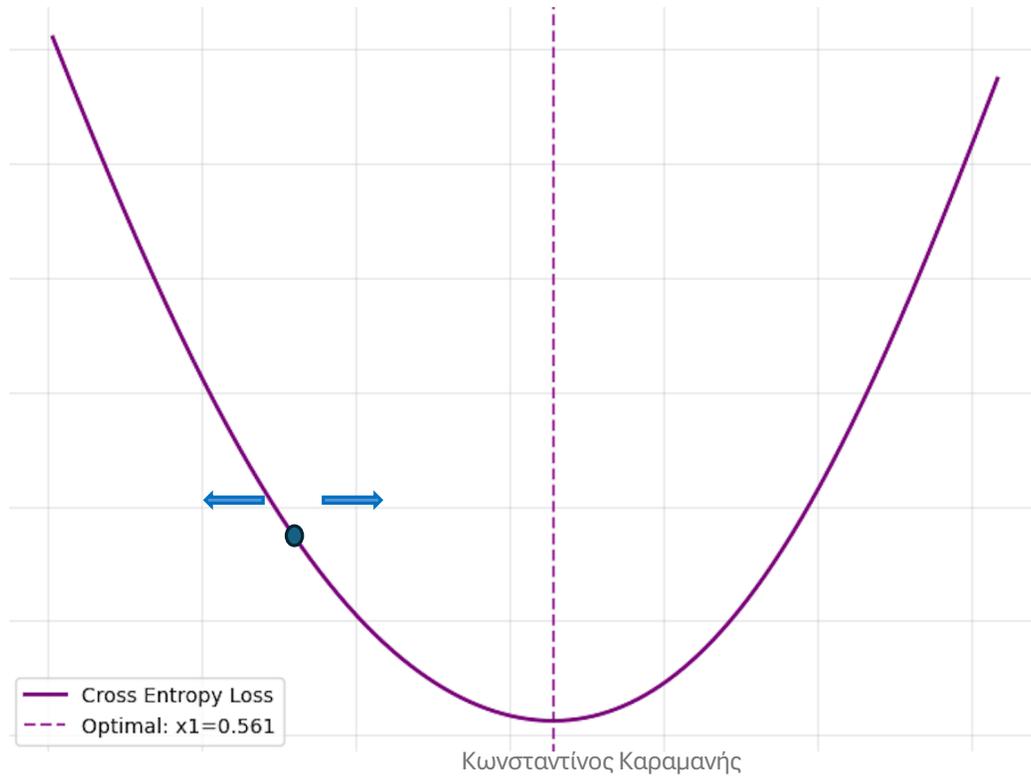


Ας θυμηθούμε τα  
προηγούμενα...

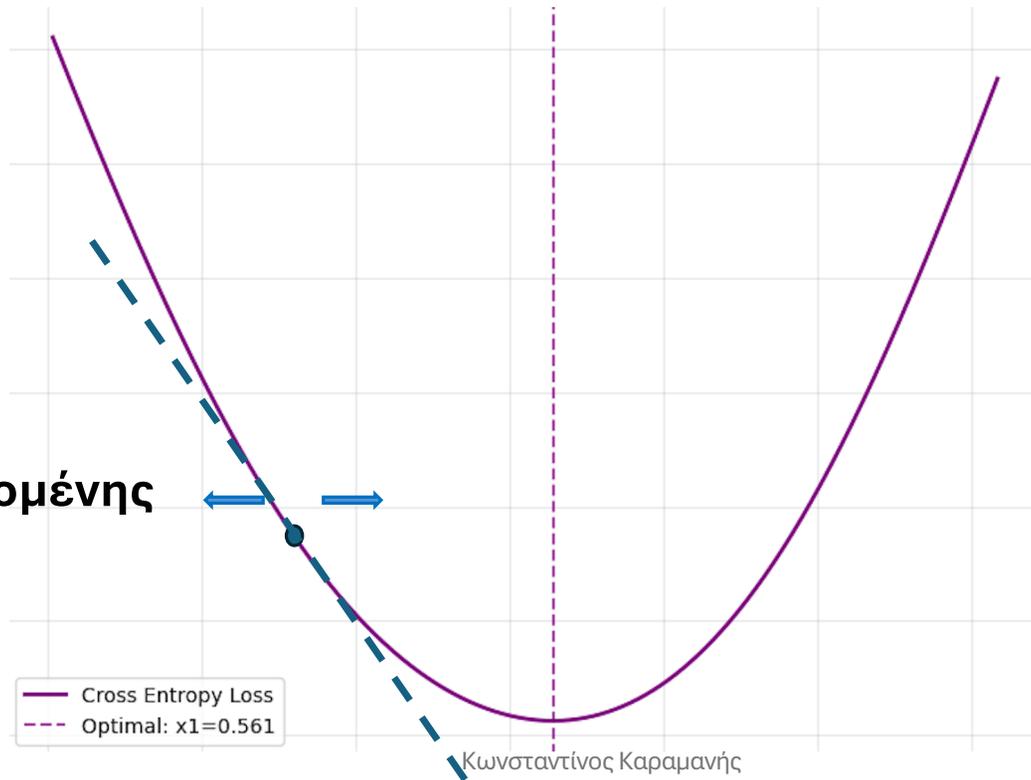


# Μέθοδος: Gradient Descent (Κάθοδος Κλίσης)

---

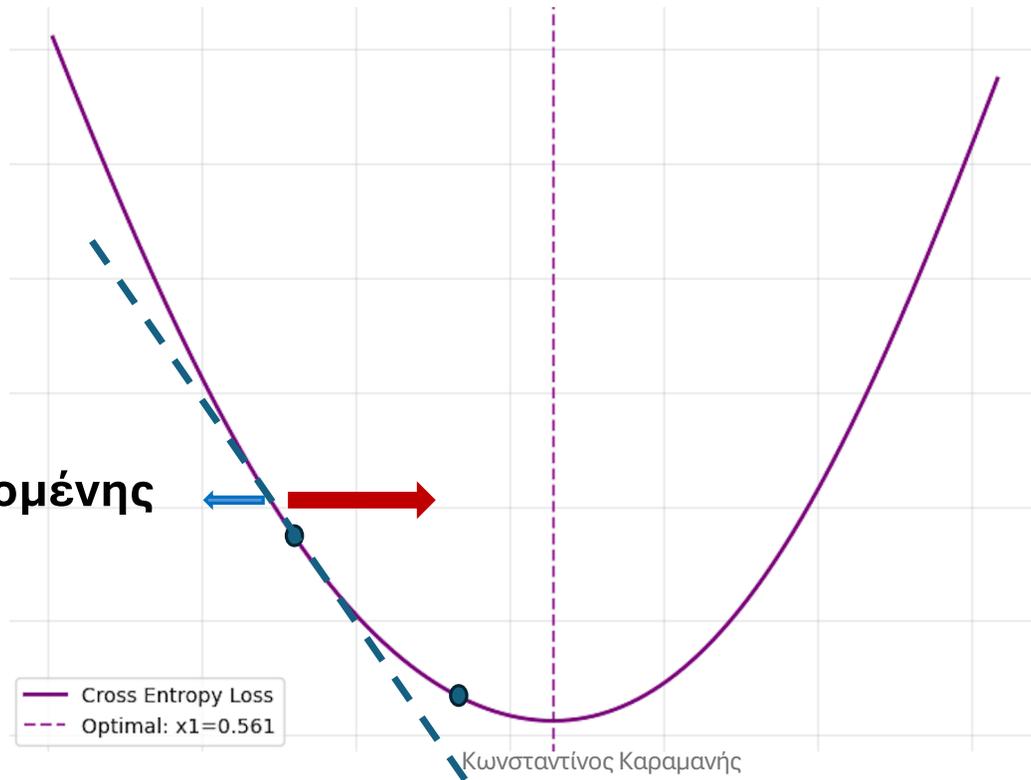


# Μέθοδος: Gradient Descent (Κάθοδος Κλίσης)



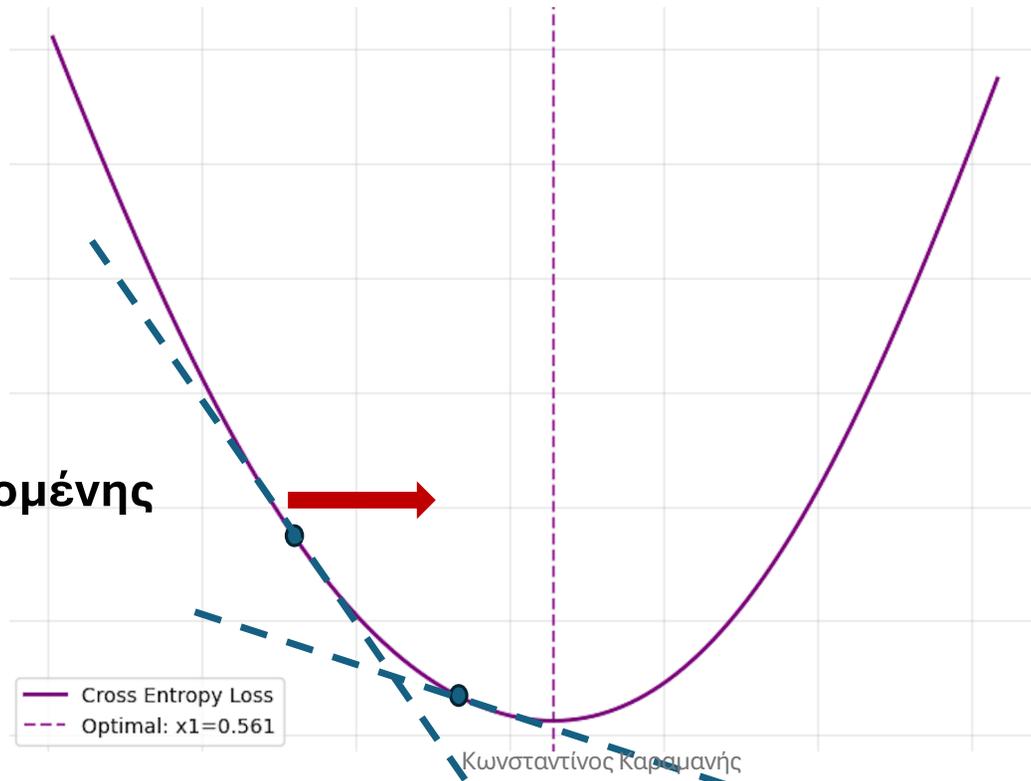
# Μέθοδος: Gradient Descent (Κάθοδος Κλίσης)

κλίση της εφαπτομένης  
= η παράγωγος



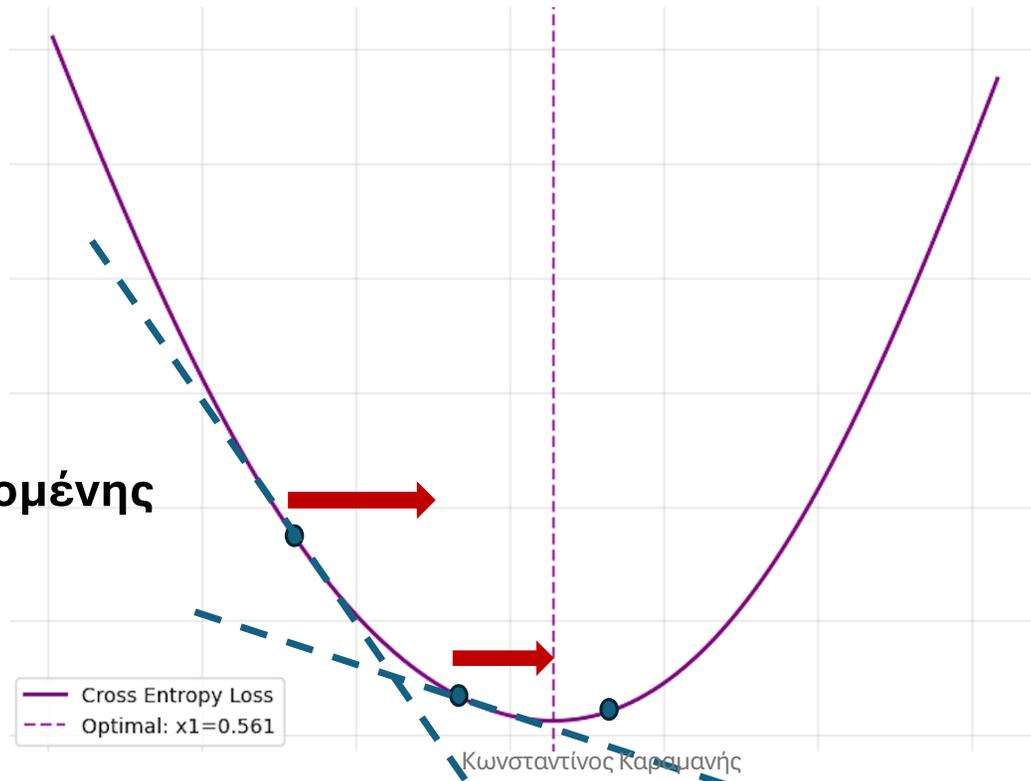
# Μέθοδος: Gradient Descent (Κάθοδος Κλίσης)

κλίση της εφαπτομένης  
= η παράγωγος



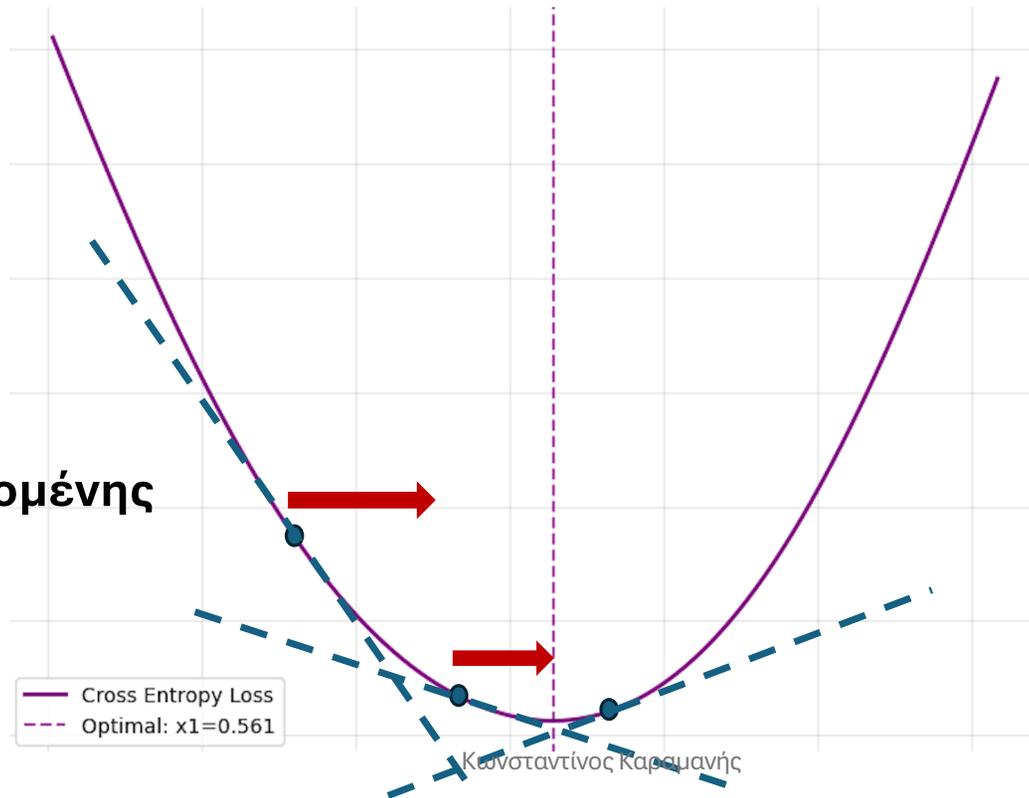
# Μέθοδος: Gradient Descent (Κάθοδος Κλίσης)

κλίση της εφαπτομένης  
= η παράγωγος



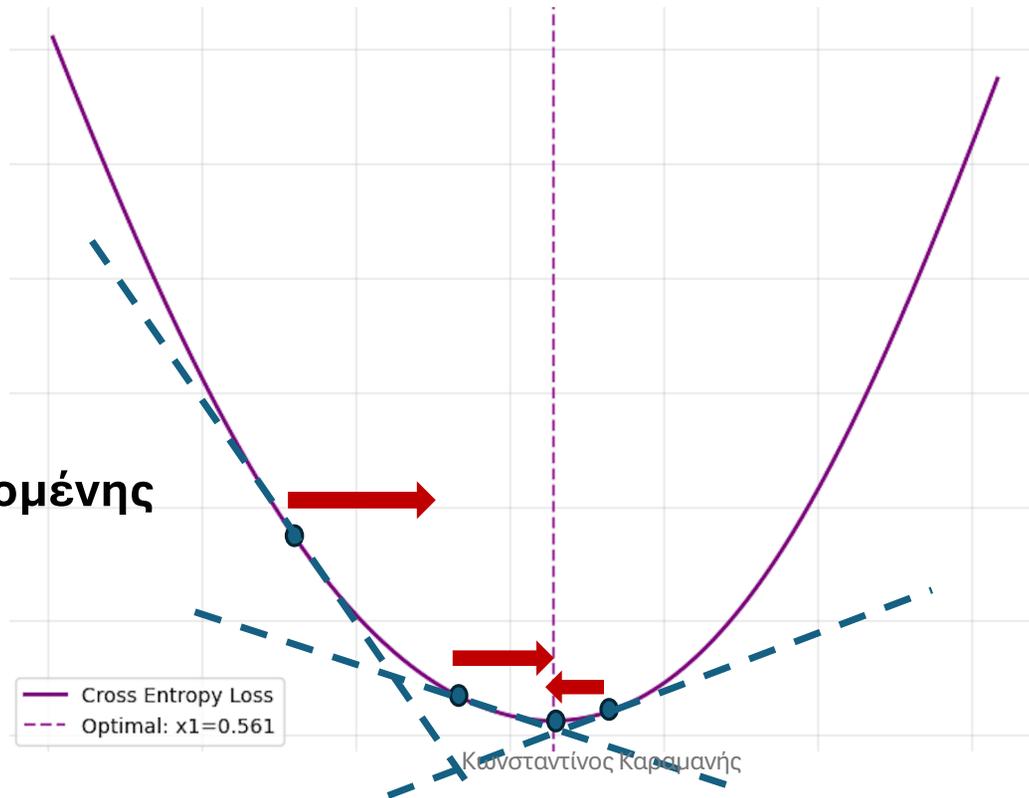
# Μέθοδος: Gradient Descent (Κάθοδος Κλίσης)

κλίση της εφαπτομένης  
= η παράγωγος



# Μέθοδος: Gradient Descent (Κάθοδος Κλίσης)

κλίση της εφαπτομένης  
= η παράγωγος



# Μέθοδος: Gradient Descent (Κάθοδος Κλίσης)

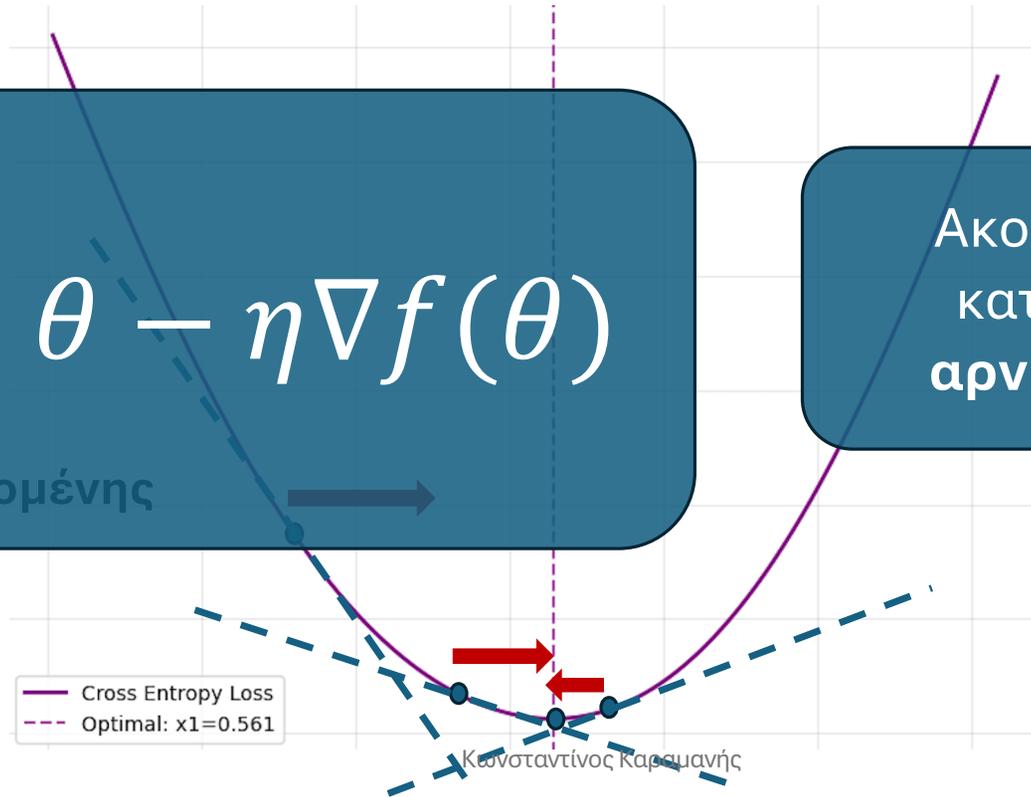
$$\theta_{+} = \theta - \eta \nabla f(\theta)$$

κλίση της εφαπτομένης  
= η παράγωγος

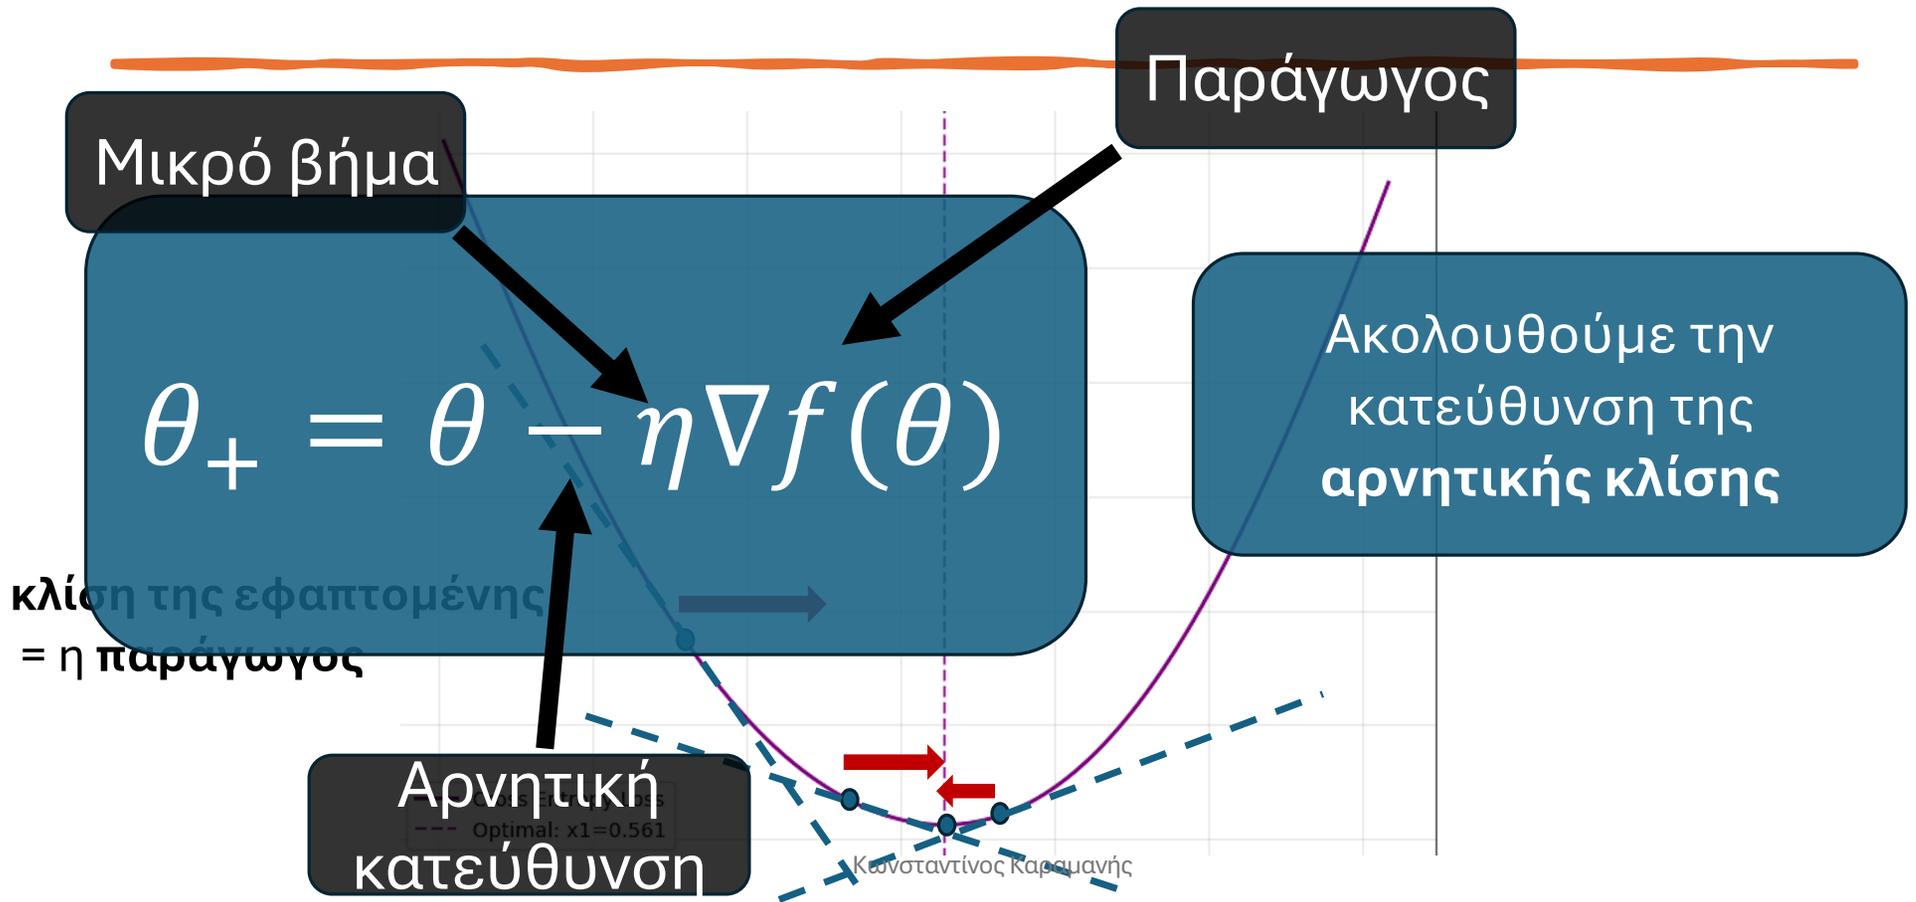
Ακολουθούμε την  
κατεύθυνση της  
αρνητικής κλίσης

— Cross Entropy Loss  
- - - Optimal:  $x_1=0.561$

Κωνσταντίνος Καραμανής



# Μέθοδος: Gradient Descent (Κάθοδος Κλίσης)



Η Μέθοδος:  
Gradient Descent  
(Κάθοδος Κλίσης)

$$\theta_+ = \theta - \eta \nabla f(\theta)$$

Εδώ αρχίζει μια πλούσια και πολυμελετημένη περιοχή των εφαρμοσμένων μαθηματικών: η θεωρία και οι αλγόριθμοι βελτιστοποίησης. (Optimization Theory and Algorithms)

$$\theta_{+} = \theta - \eta \nabla f(\theta)$$

Θεμελιώδεις ερωτήσεις:

Η Μέθοδος:

Gradient Descent

(Κάθοδος Κλίσης)

Ποια χαρακτηριστικά της συνάρτησης  $f(\theta)$  καθορίζουν πόσα βήματα της μεθόδου απαιτούνται για να προσεγγίσουμε το βέλτιστο σημείο  $\theta^*$

Η Θεωρία και Αλγόριθμοι της Βελτιστοποίησης  
(Optimization Theory and Algorithms)

$$\theta_{+} = \theta - \eta \nabla f(\theta)$$

Θεμελιώδεις ερωτήσεις:

Η Μέθοδος:  
Gradient Descent  
(Κάθοδος Κλίσης)

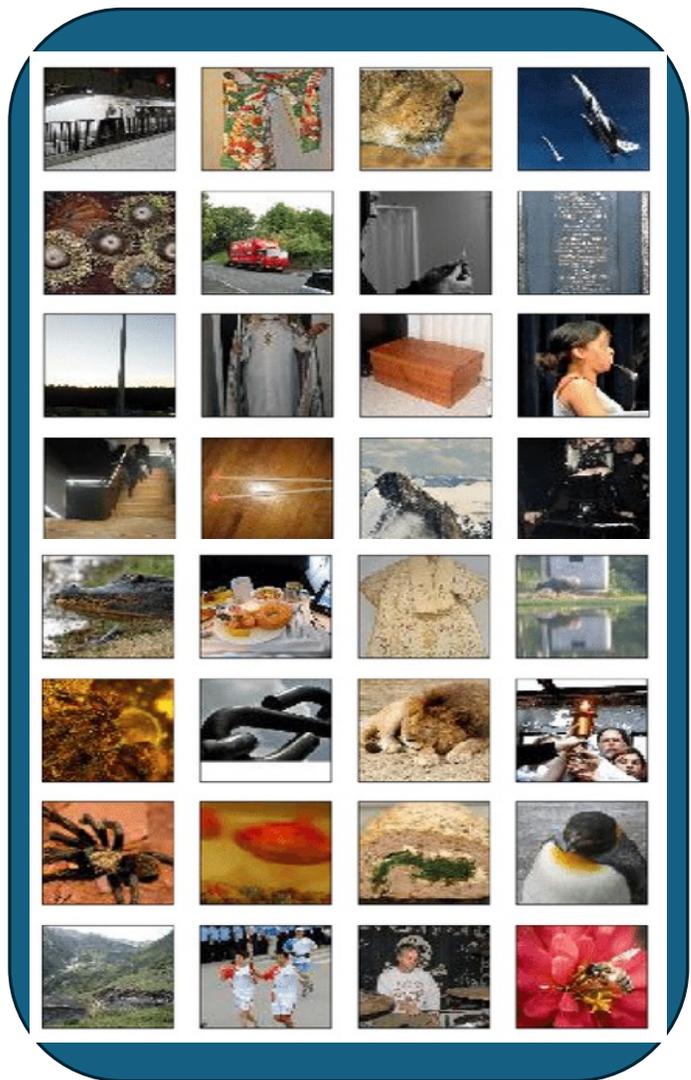
□

π

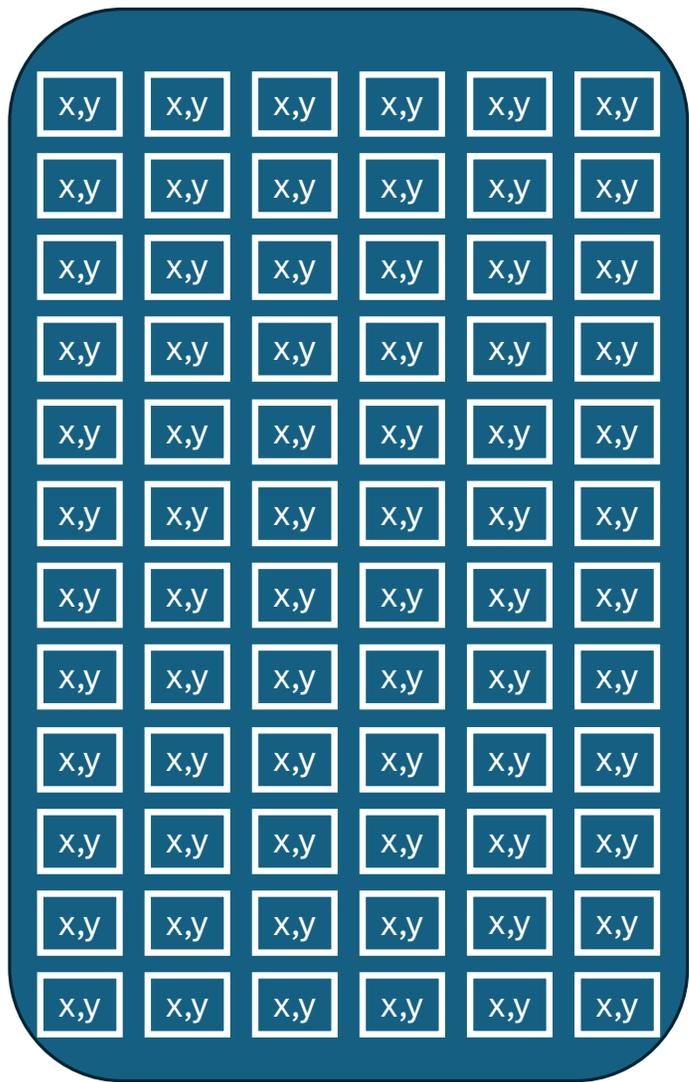
Πώς εφαρμόζεται ή  
χρησιμοποιείται στην  
εκπαίδευση και στη χρήση  
των νευρωνικών δικτύων;

# Gradient Descent & Νευρωνικά Δίκτυα

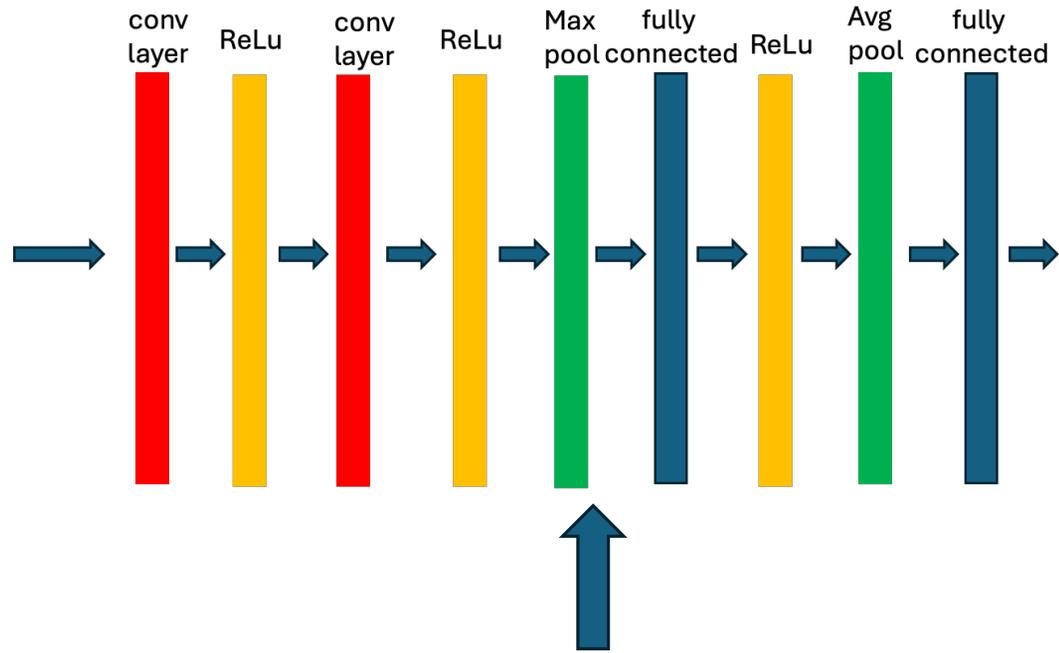
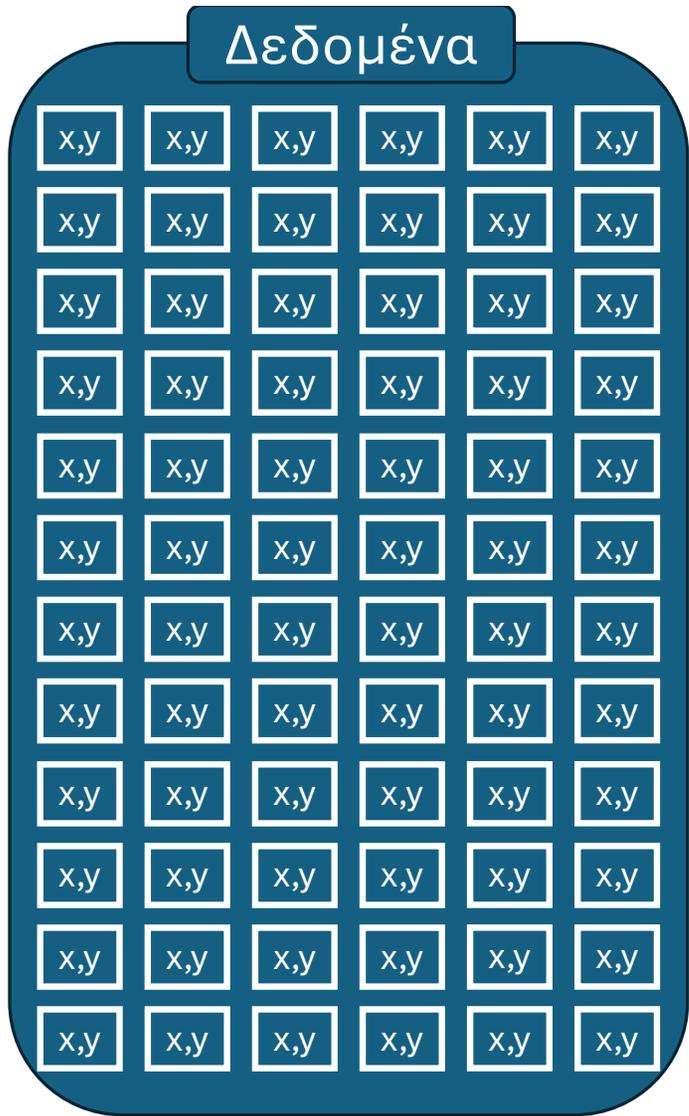
Κωνσταντίνος Καραμανής



Δεδομένα

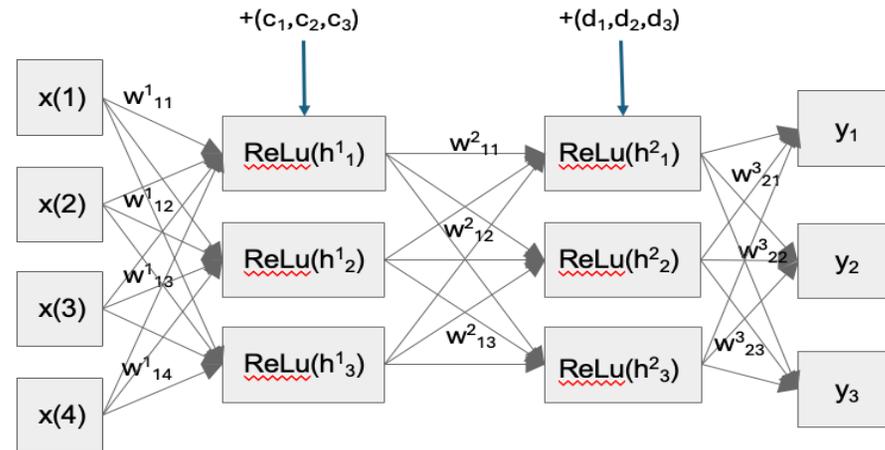
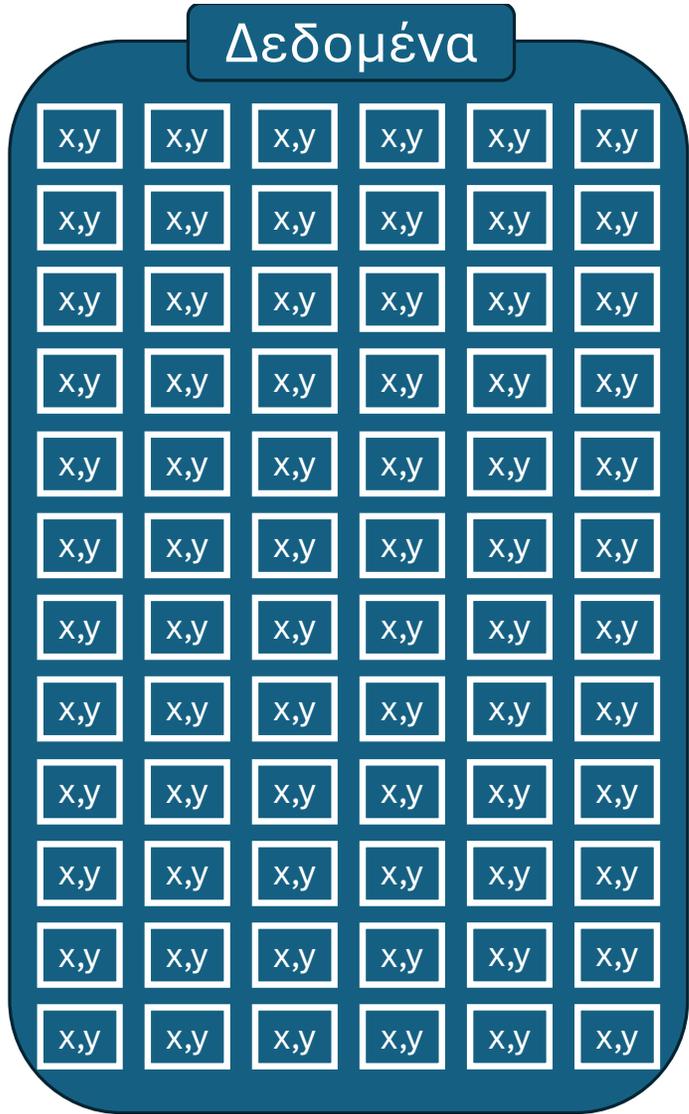


Δεδομένα



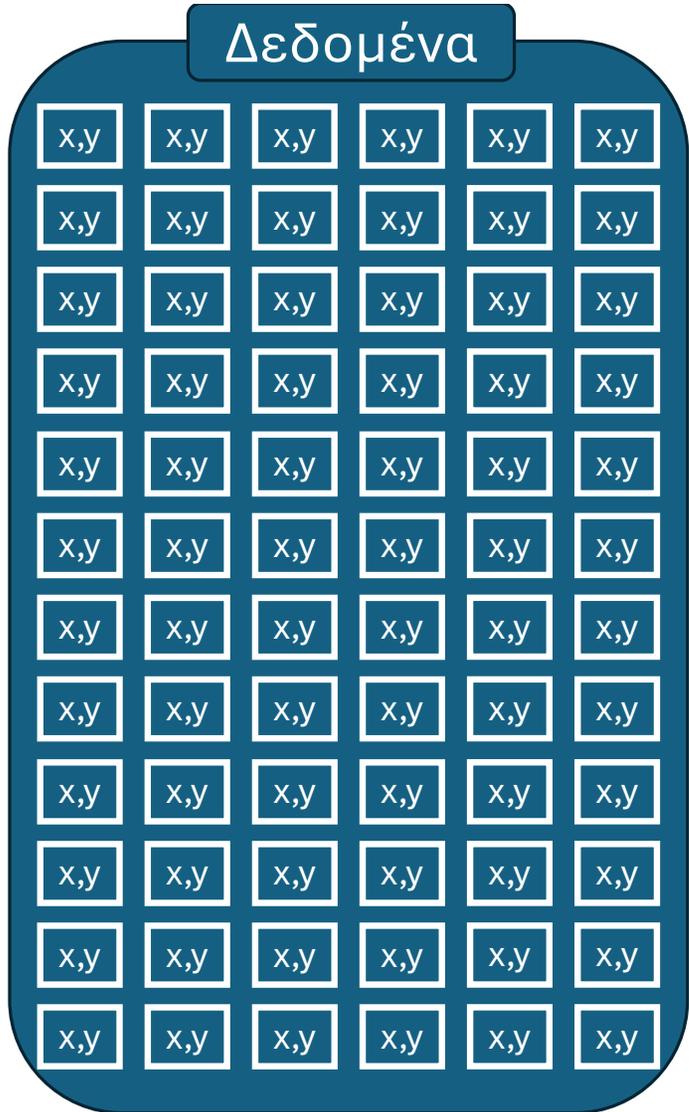
**Νευρωνικό**

## Δεδομένα

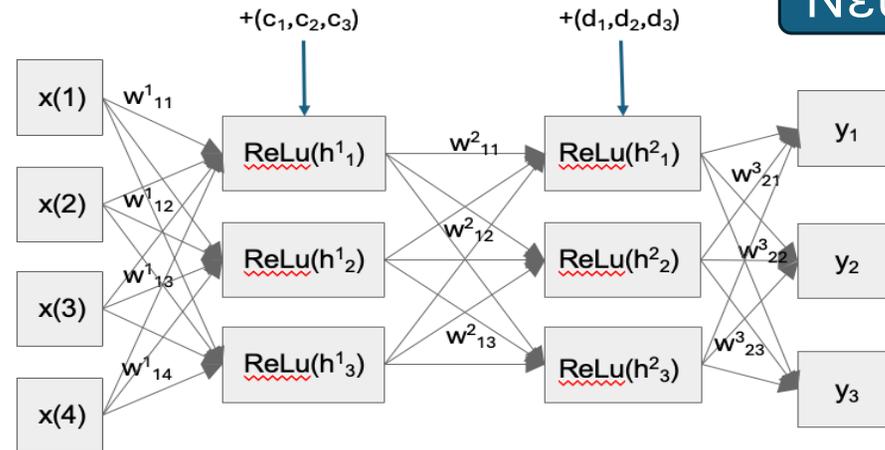


## Νευρωνικό

## Δεδομένα



## Νευρωνικό



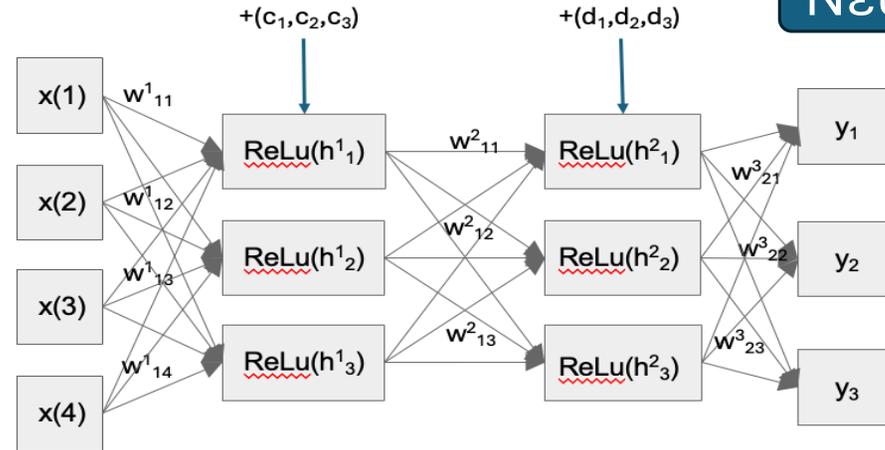
$$\theta = (W^1, c, W^2, d, W^3)$$

↑  
Παράμετροι  
του μοντέλου

## Δεδομένα

x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y

## Νευρωνικό



$$\theta = (W^1, c, W^2, d, W^3)$$

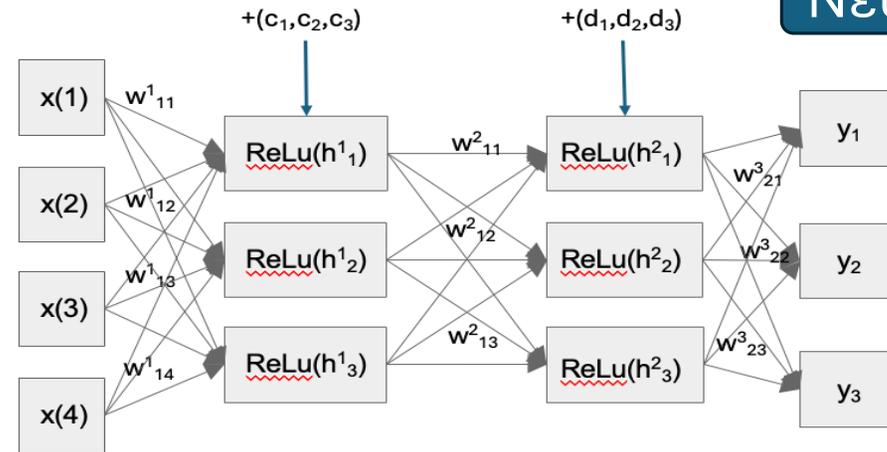
$$Loss(y_i, x_i, \theta) = Loss(y_i, x_i, W^1, c, W^2, d, W^3)$$

Απώλεια σε  
ένα ζευγάρι  
δεδομένων

## Δεδομένα

x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y

## Νευρωνικό



$$\theta = (W^1, c, W^2, d, W^3)$$

$$Loss(y_i, x_i, \theta) = Loss(y_i, x_i, W^1, c, W^2, d, W^3)$$

$$L(\theta) = \sum Loss(y_i, x_i, \theta)$$

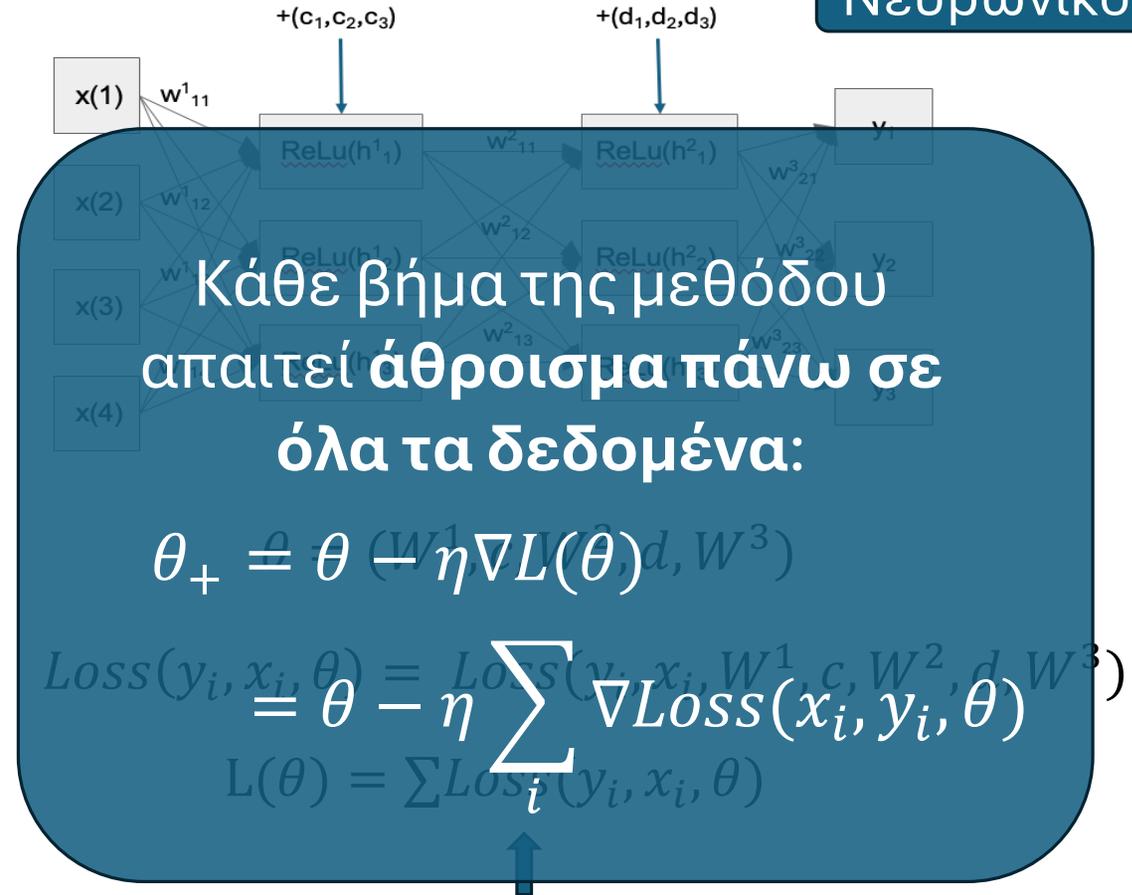


Συνολική απώλεια

## Δεδομένα

x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y

## Νευρωνικό

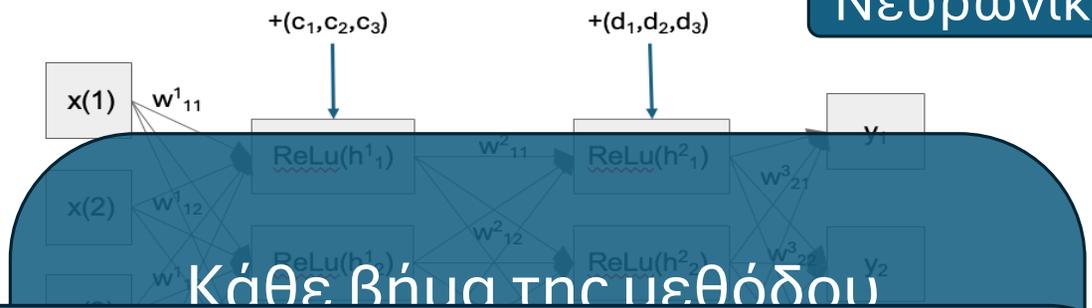


## Συνολική απώλεια

Δεδομένα

x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y
x,y	x,y	x,y	x,y	x,y	x,y

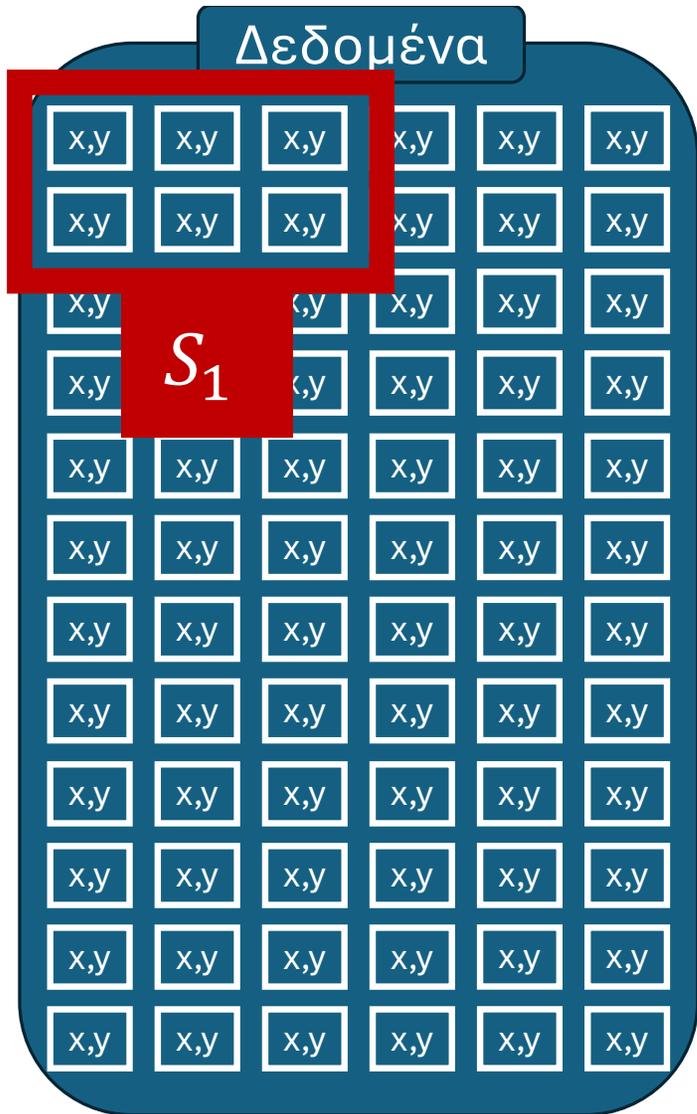
Νευρωνικό



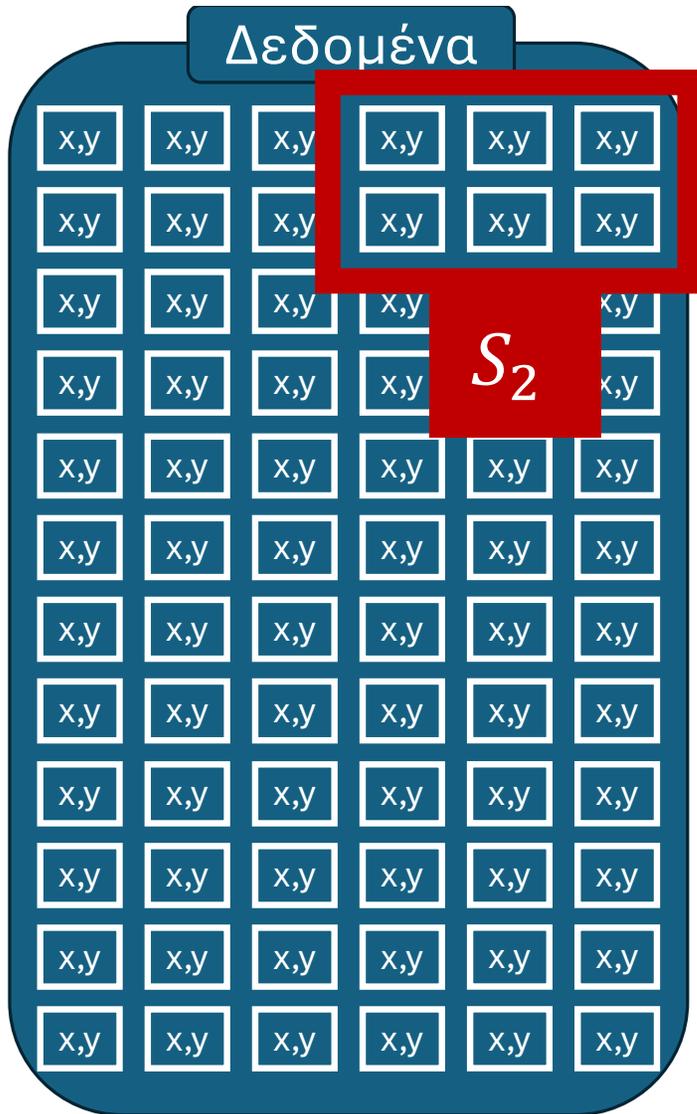
Κάθε βήμα της μεθόδου

Gradient Descent + Minibatch  
(batch\_size)  
→ Stochastic Gradient Descent

Συνολική απώλεια

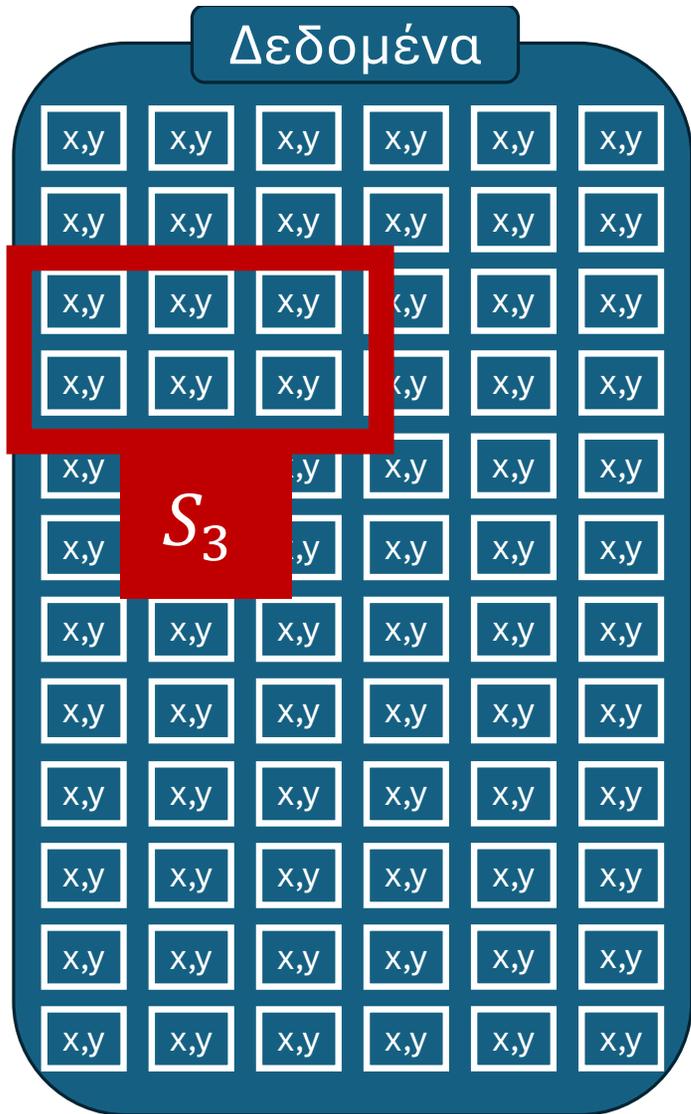


$$\theta_{t+1} = \theta_t - \eta \sum_{i \in S_1} \nabla \text{Loss}(x_i, y_i, \theta_t)$$



$$\theta_{t+1} = \theta_t - \eta \sum_{i \in S_1} \nabla \text{Loss}(x_i, y_i, \theta_t)$$

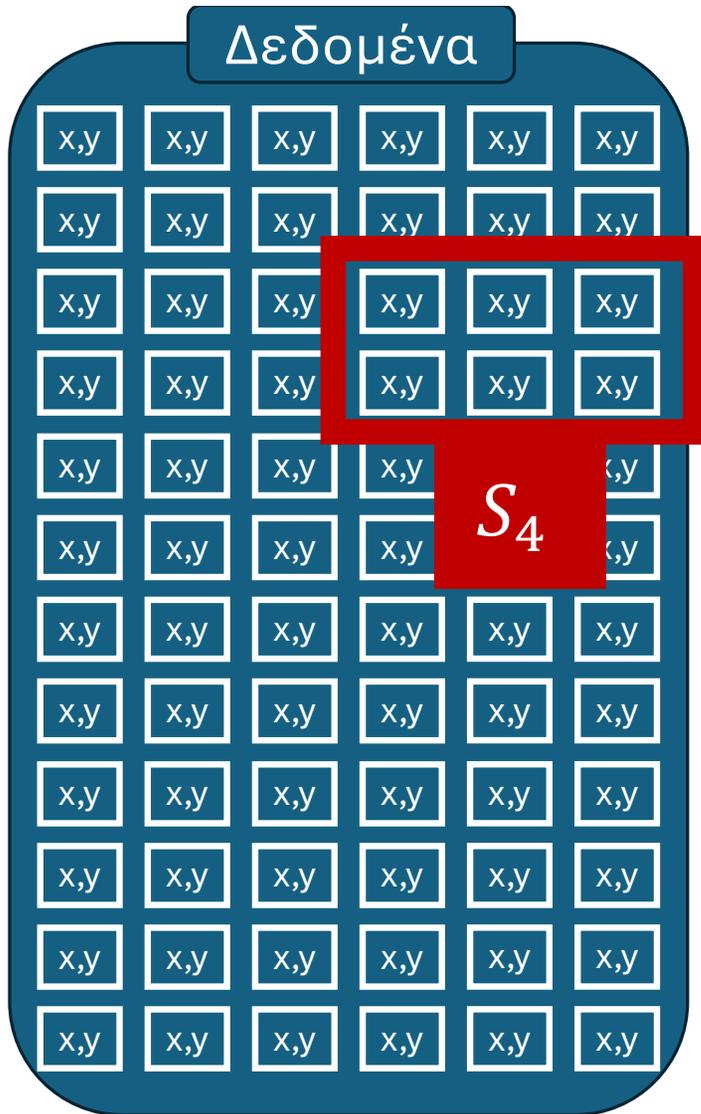
$$\theta_{t+2} = \theta_{t+1} - \eta \sum_{i \in S_2} \nabla \text{Loss}(x_i, y_i, \theta_{t+1})$$



$$\theta_{t+1} = \theta_t - \eta \sum_{i \in S_1} \nabla \text{Loss}(x_i, y_i, \theta_t)$$

$$\theta_{t+2} = \theta_{t+1} - \eta \sum_{i \in S_2} \nabla \text{Loss}(x_i, y_i, \theta_{t+1})$$

$$\theta_{t+3} = \theta_{t+2} - \eta \sum_{i \in S_3} \nabla \text{Loss}(x_i, y_i, \theta_{t+2})$$



$$\theta_{t+1} = \theta_t - \eta \sum_{i \in S_1} \nabla \text{Loss}(x_i, y_i, \theta_t)$$

$$\theta_{t+2} = \theta_{t+1} - \eta \sum_{i \in S_2} \nabla \text{Loss}(x_i, y_i, \theta_{t+1})$$

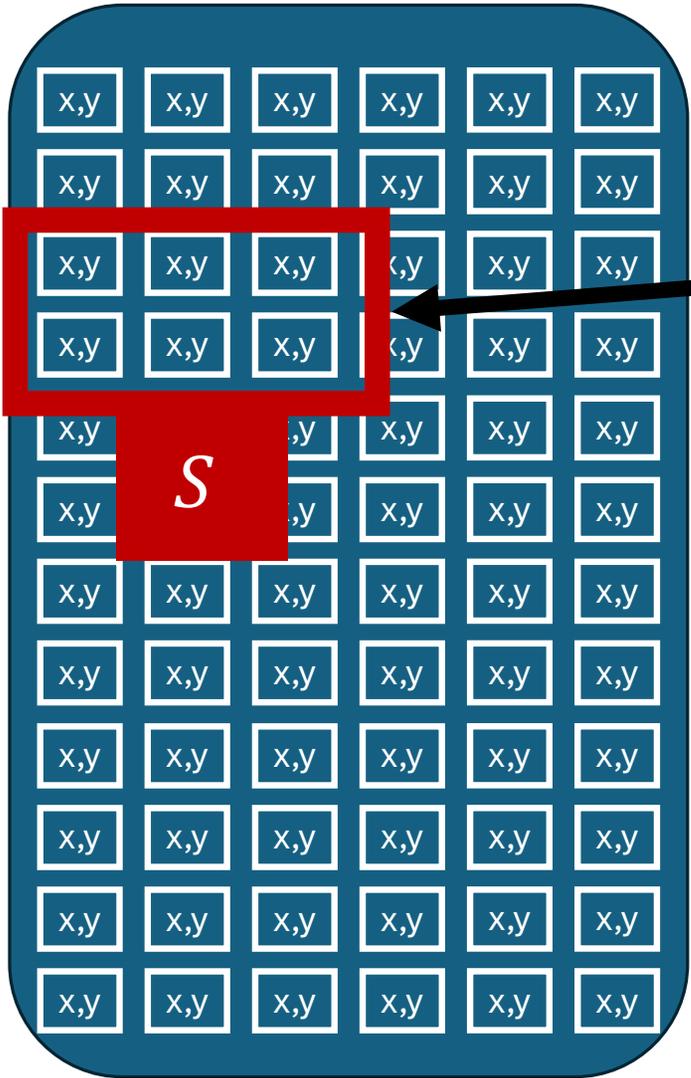
$$\theta_{t+3} = \theta_{t+2} - \eta \sum_{i \in S_3} \nabla \text{Loss}(x_i, y_i, \theta_{t+2})$$

$$\theta_{t+4} = \theta_{t+3} - \eta \sum_{i \in S_3} \nabla \text{Loss}(x_i, y_i, \theta_{t+3})$$

# Η Μέθοδος *Stochastic* Gradient Descent σε κώδικα Python

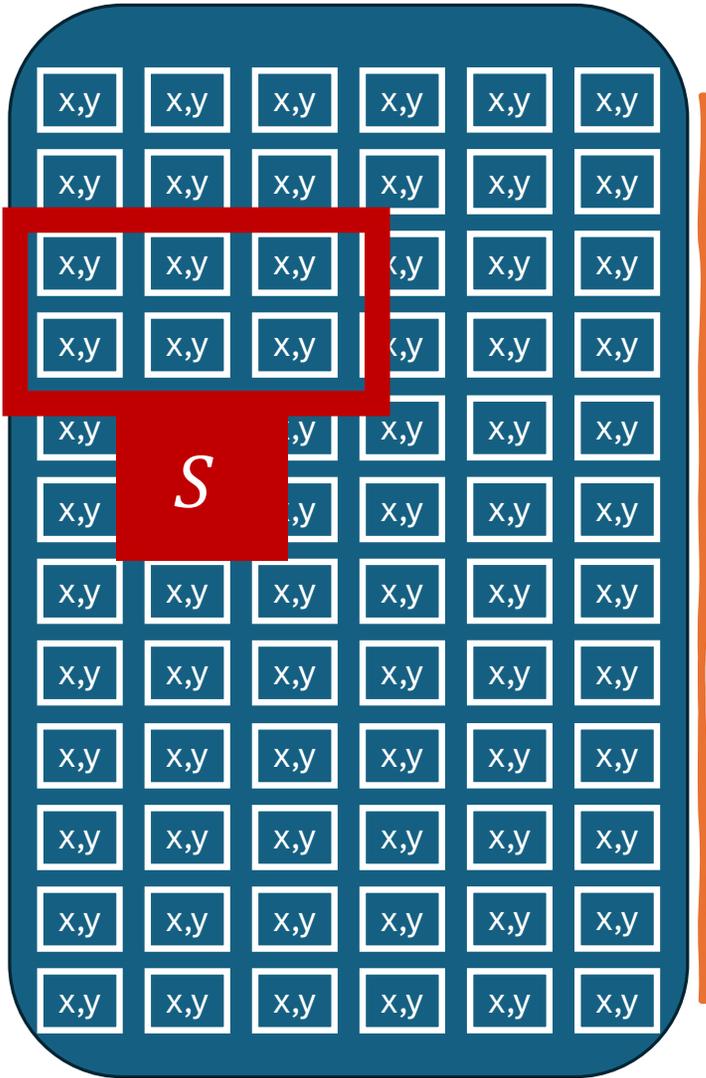
```
# dataloaders  
train_loader = DataLoader(train_dataset, batch_size=64,  
                           shuffle=True, num_workers=2)
```

```
for epoch in range(epochs):  
    model.train()  
    total_loss = 0  
    for images, labels in train_loader:  
        images, labels = images.to(device), labels.to(device)  
        optimizer.zero_grad()  
        outputs = model(images)  
        loss = criterion(outputs, labels)  
        loss.backward()  
        optimizer.step()
```



```
# dataloaders  
train_loader = DataLoader(train_dataset, batch_size=64,  
                           shuffle=True, num_workers=2)
```

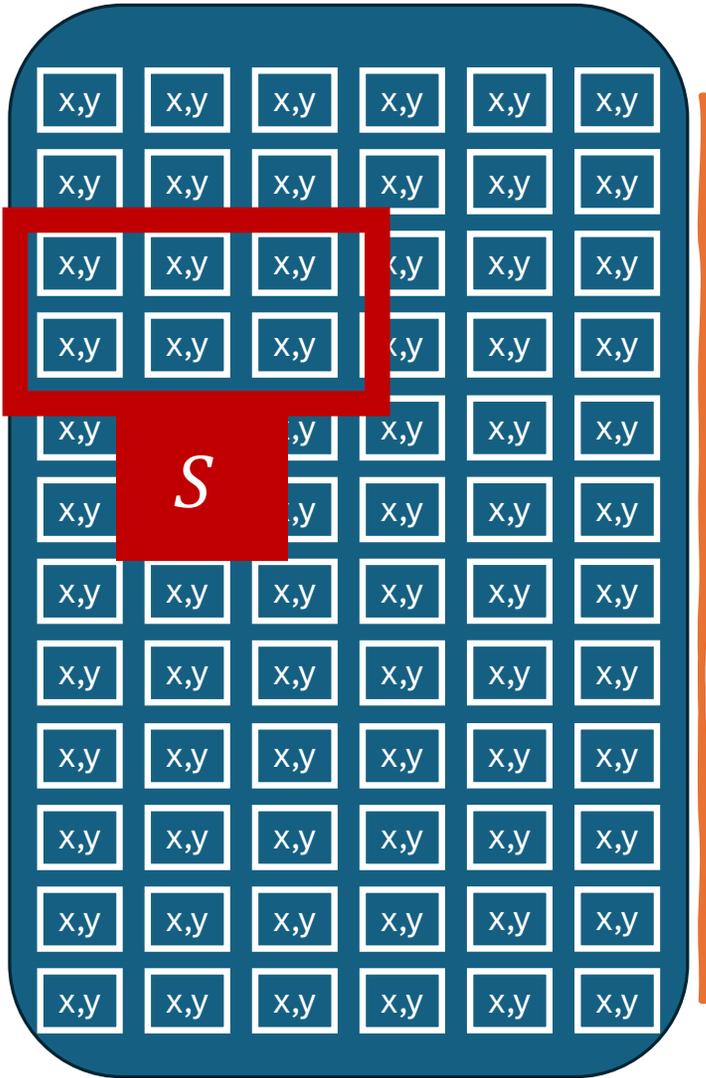
```
for epoch in range(epochs):  
    model.train()  
    total_loss = 0  
    for images, labels in train_loader:  
        images, labels = images.to(device), labels.to(device)  
        optimizer.zero_grad()  
        outputs = model(images)  
        loss = criterion(outputs, labels)  
        loss.backward()  
        optimizer.step()
```



```
# dataloaders
train_loader = DataLoader(train_dataset, batch_size=64,
                           shuffle=True, num_workers=2)
```

```
for epoch in range(epochs):
    model.train()
    total_loss = 0
    for images, labels in train_loader:
        images, labels = images.to(device), labels.to(device)
        optimizer.zero_grad()
        outputs = model(images)
        loss = criterion(outputs, labels)
        loss.backward()
```

loss.backward()  $\longleftrightarrow \sum_{i \in S} \nabla \text{Loss}(x_i, y_i, \theta_t)$



```
# dataloaders
train_loader = DataLoader(train_dataset, batch_size=64,
                           shuffle=True, num_workers=2)
```

```
for epoch in range(epochs):
    model.train()
    total_loss = 0
    for images, labels in train_loader:
        images, labels = images.to(device), labels.to(device)
        optimizer.zero_grad()
        outputs = model(images)
        loss = criterion(outputs, labels)
        # backward pass
        optimizer.step()
```

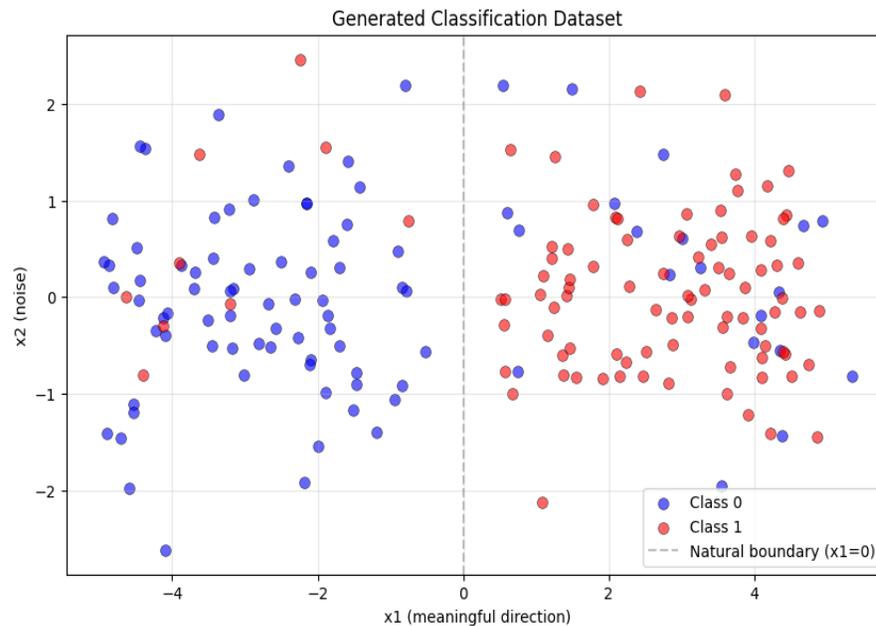
$$\theta_{t+1} = \theta_t - \eta \sum_{i \in S} \nabla \text{Loss}(x_i, y_i, \theta_t)$$

# Η Μέθοδος: Stochastic Gradient Descent

Η συνολική απώλεια:

$$\sum Loss(x_i, y_i, \theta)$$

Είναι συνάρτηση των παραμέτρων  
και των δεδομένων.



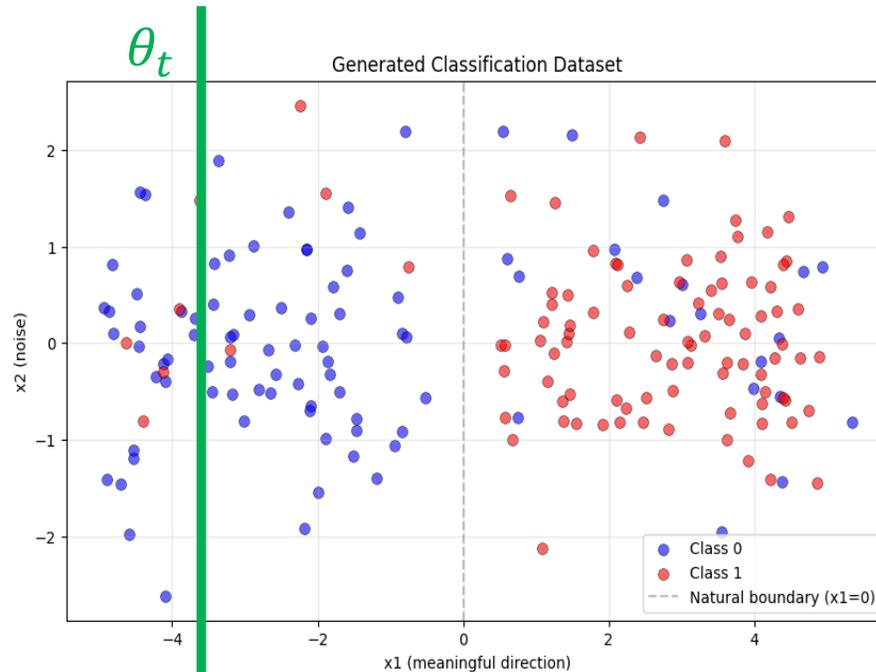
Κωνσταντίνος Καραμανής

# Η Μέθοδος: Stochastic Gradient Descent

Η συνολική απώλεια:

$$\sum Loss(x_i, y_i, \theta)$$

Είναι συνάρτηση των **παραμέτρων**  
και των **δεδομένων**.



Κωνσταντίνος Καραμανής

# Η Μέθοδος: Stochastic Gradient Descent

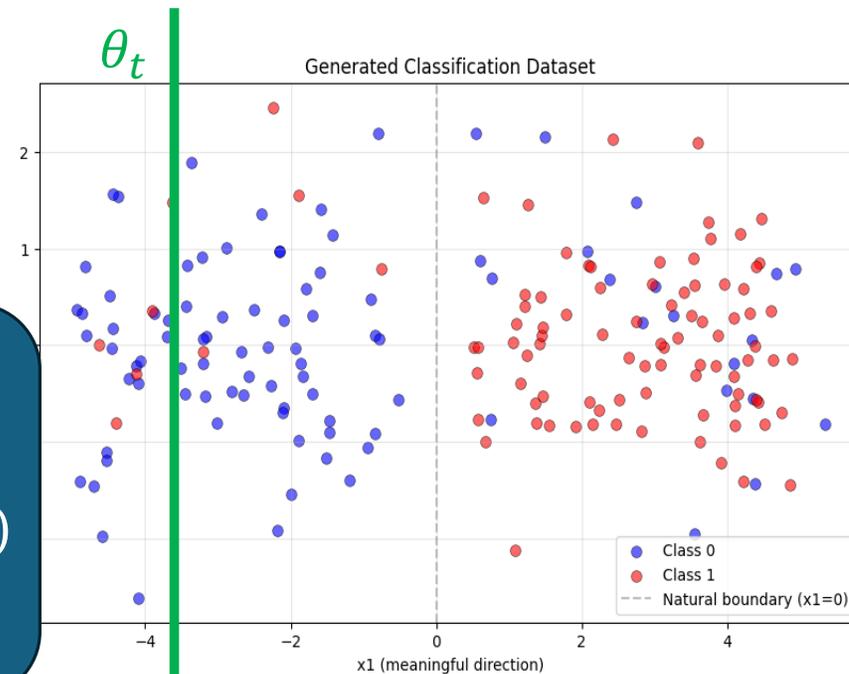
Πού είναι το  $\theta_{t+1}$ ;

$$\theta_{t+1} = \theta_t - \eta \sum_{i \in S} \nabla \text{Loss}(x_i, y_i, \theta_t)$$

Η συνολική απώλεια:

$$\sum \text{Loss}(x_i, y_i, \theta)$$

Είναι συνάρτηση των **παραμέτρων**  
και των **δεδομένων**.



Κωνσταντίνος Καραμανής

# Η Μέθοδος: Stochastic Gradient Descent

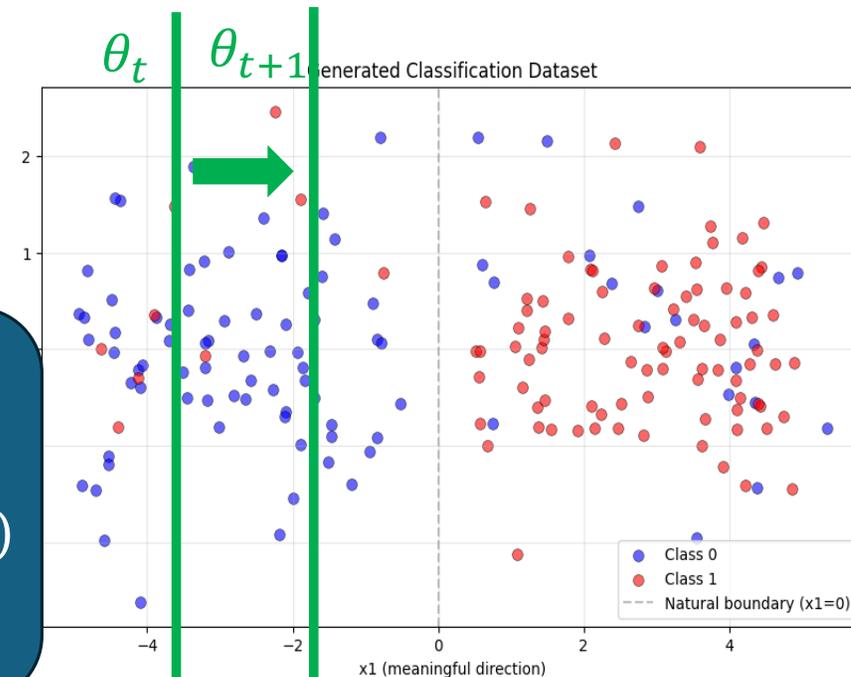
Πού είναι το  $\theta_{t+1}$ ;

$$\theta_{t+1} = \theta_t - \eta \sum_{i \in S} \nabla \text{Loss}(x_i, y_i, \theta_t)$$

Η συνολική απώλεια:

$$\sum \text{Loss}(x_i, y_i, \theta)$$

Είναι συνάρτηση των **παραμέτρων**  
και των **δεδομένων**.



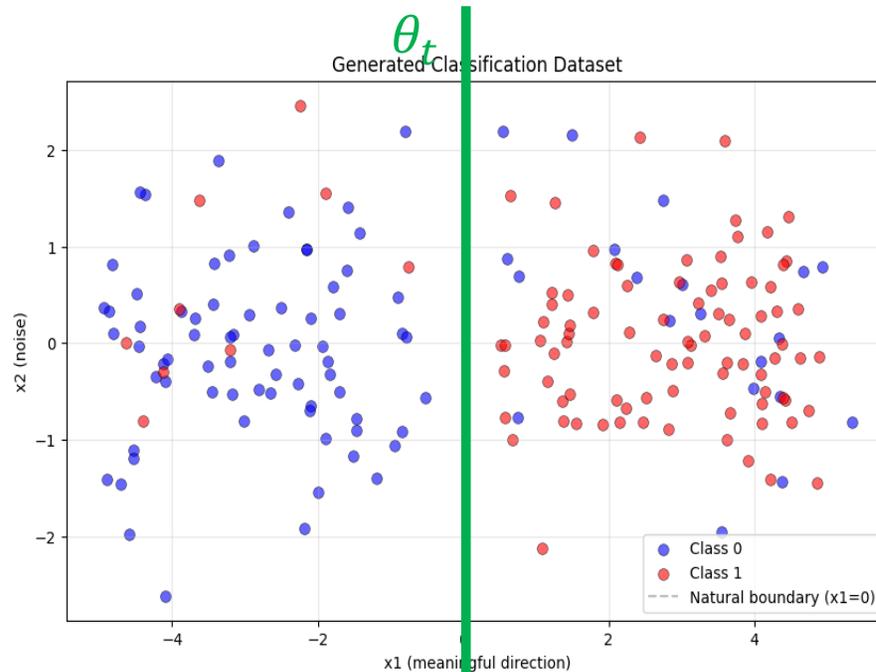
Κωνσταντίνος Καραμανής

# Η Μέθοδος: Stochastic Gradient Descent

Η συνολική απώλεια:

$$\sum Loss(x_i, y_i, \theta)$$

Είναι συνάρτηση των παραμέτρων  
και των δεδομένων.



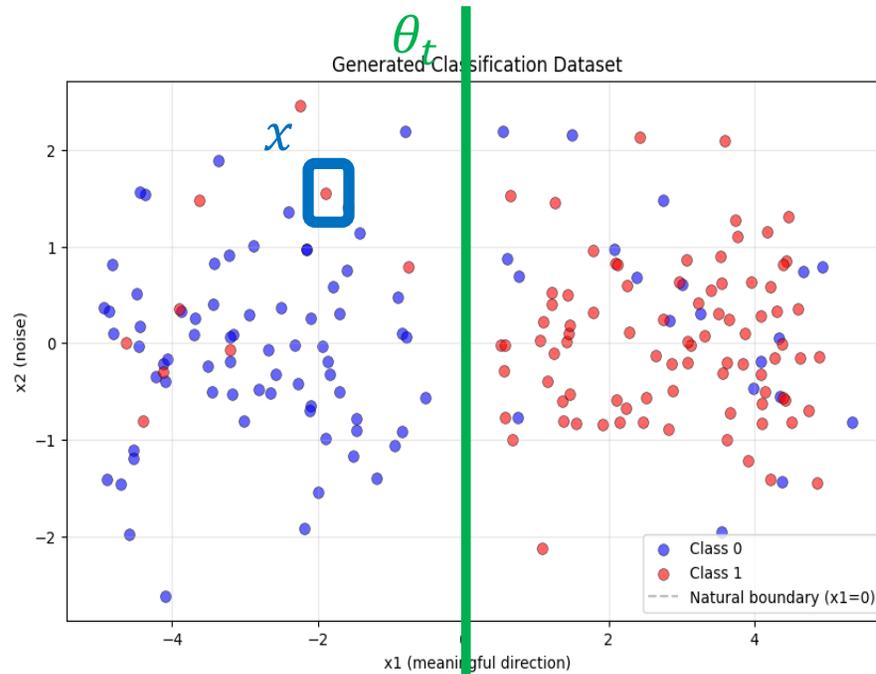
Κωνσταντίνος Καραμανής

# Η Μέθοδος: Stochastic Gradient Descent

Η συνολική απώλεια:

$$\sum Loss(x_i, y_i, \theta)$$

Είναι συνάρτηση των παραμέτρων  
και των δεδομένων.



Κωνσταντίνος Καραμανής

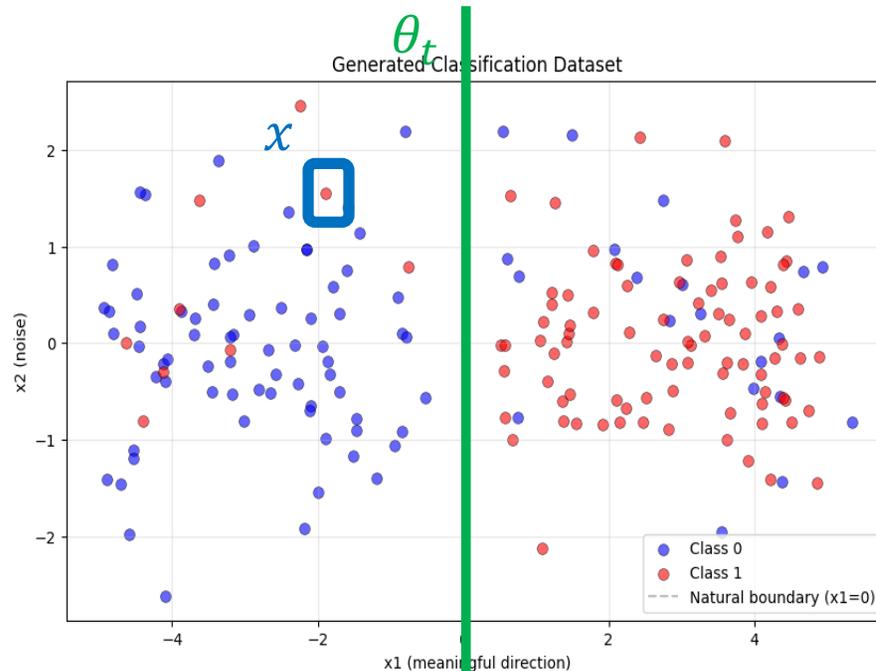
# Η Μέθοδος: Stochastic Gradient Descent

Πού είναι το  $x_+$ ;  
$$x_+ = x - \eta \nabla_x \text{Loss}(x, y, \theta_t)$$

Η συνολική απώλεια:

$$\sum \text{Loss}(x_i, y_i, \theta)$$

Είναι συνάρτηση των παραμέτρων  
και των δεδομένων.



Κωνσταντίνος Καραμανής

# Η Μέθοδος: Stochastic Gradient Descent

Πού είναι το  $x_+$ ;

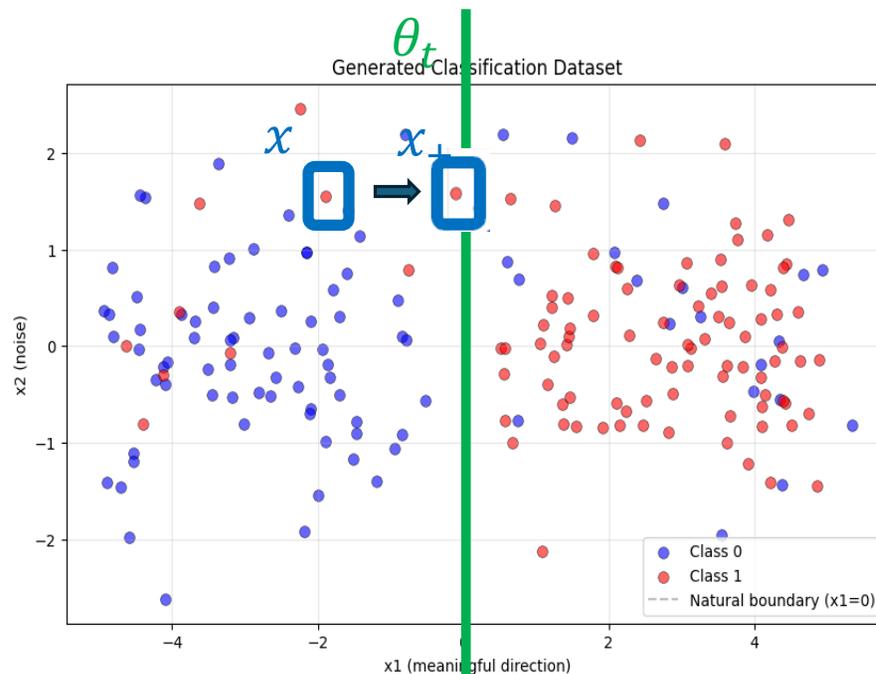
$$x_+ = x - \eta \nabla_x \text{Loss}(x, y, \theta_t)$$

Μειώνουμε την απώλεια

Η συνολική απώλεια:

$$\sum \text{Loss}(x_i, y_i, \theta)$$

Είναι συνάρτηση των παραμέτρων  
και των δεδομένων.

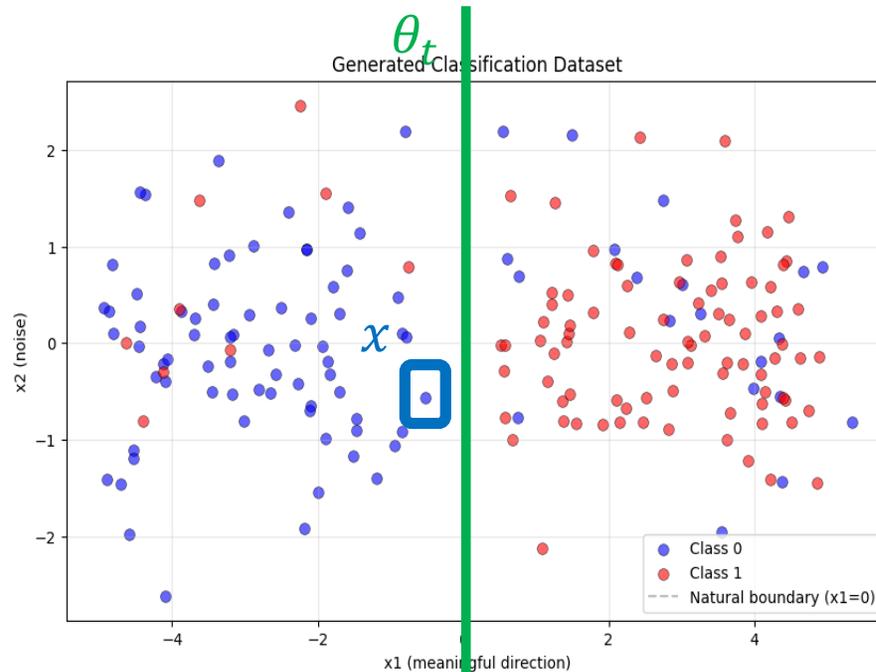


# Η Μέθοδος: Stochastic Gradient Descent

Η συνολική απώλεια:

$$\sum Loss(x_i, y_i, \theta)$$

Είναι συνάρτηση των παραμέτρων  
και των δεδομένων.



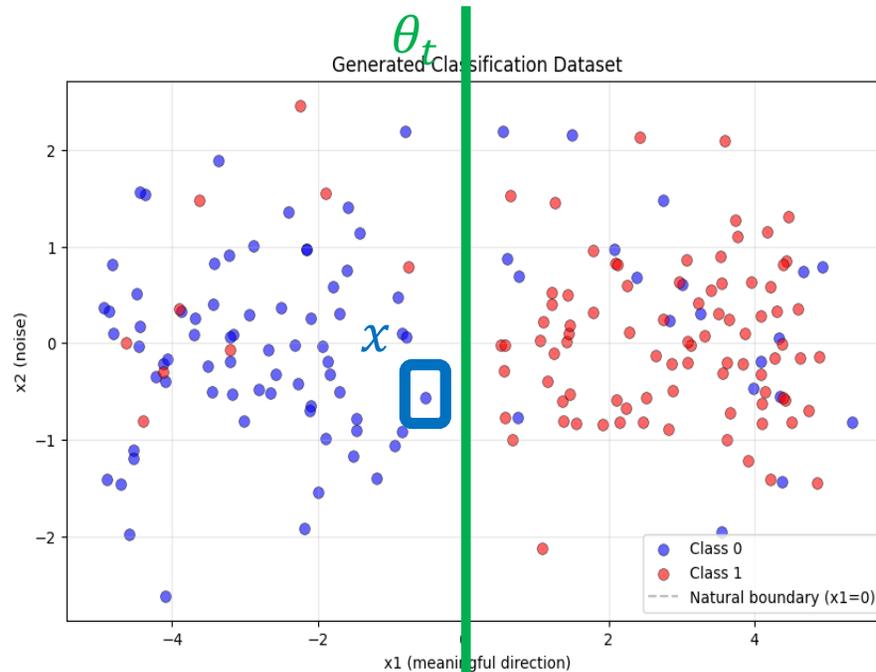
# Η Μέθοδος: Stochastic Gradient Descent

Τι πρέπει να κάνουμε  
για να **αυξήσουμε** την  
απώλεια του σημείου;

Η συνολική απώλεια:

$$\sum Loss(x_i, y_i, \theta)$$

Είναι συνάρτηση των **παραμέτρων**  
και των **δεδομένων**.



# Η Μέθοδος: Stochastic Gradient Descent

Αυξάνουμε την απώλεια

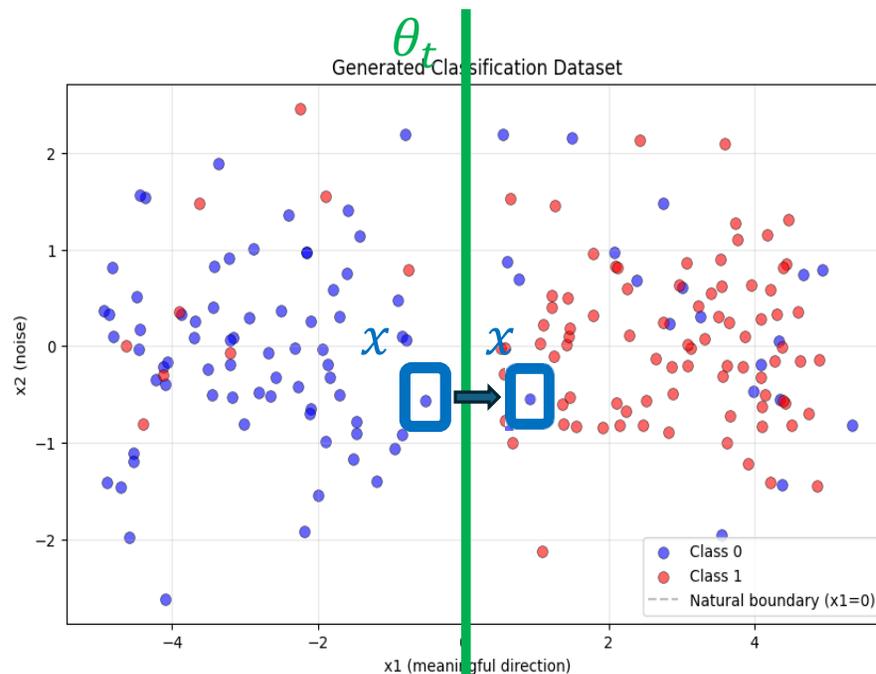
$$x_+ = x + \eta \nabla_x \text{Loss}(x, y, \theta_t)$$

Ακολουθούμε την κλίση

Η συνολική απώλεια:

$$\sum \text{Loss}(x_i, y_i, \theta)$$

Είναι συνάρτηση των παραμέτρων  
και των δεδομένων.



Κωνσταντίνος Καραμανής

# Η Μέθοδος: Stochastic Gradient Descent

Μειώνουμε  
Αυξάνουμε την απώλεια

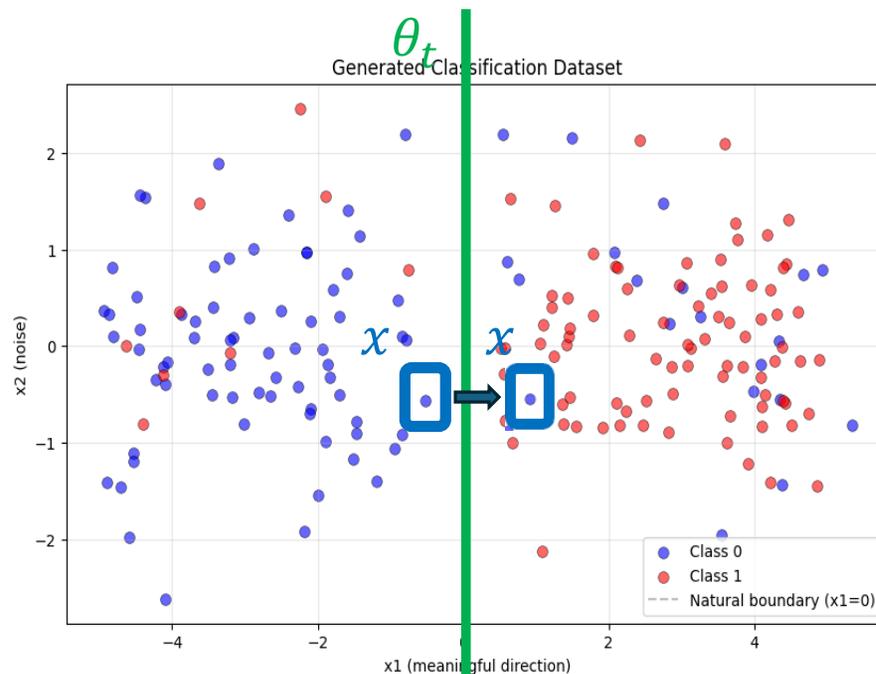
$$x_+ = x - \eta \nabla_x \text{Loss}(x, y, \theta_t)$$

Ακολουθούμε την αρνητική κλίση

Η συνολική απώλεια:

$$\sum \text{Loss}(x_i, y_i, \theta)$$

Είναι συνάρτηση των παραμέτρων  
και των δεδομένων.



Κωνσταντίνος Καραμανής

# Η Μέθοδος: Stochastic Gradient Descent

Αλλάζουμε το  $y$

Μειώνουμε  
Αυξάνουμε την απώλεια

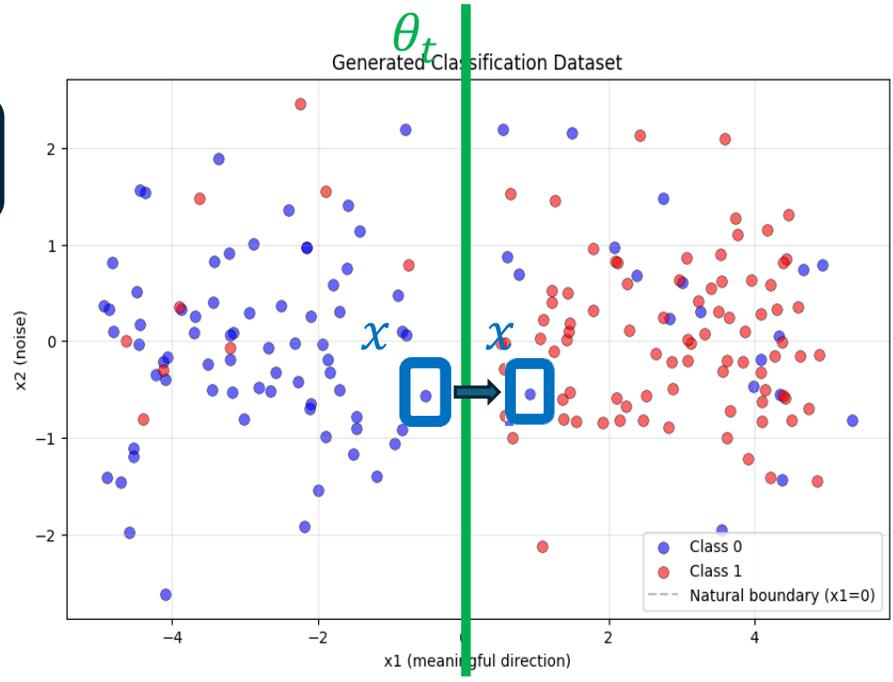
$$x_+ = x - \eta \nabla_x \text{Loss}(x, y, \theta_t)$$

Ακολουθούμε την αρνητική κλίση

Η συνολική απώλεια:

$$\sum \text{Loss}(x_i, y_i, \theta)$$

Είναι συνάρτηση των παραμέτρων  
και των δεδομένων.



# Η Μέθοδος: Stochastic Gradient Descent

Αλλάζουμε το  $y$

Μειώνουμε  
Αυξάνουμε την απώλεια

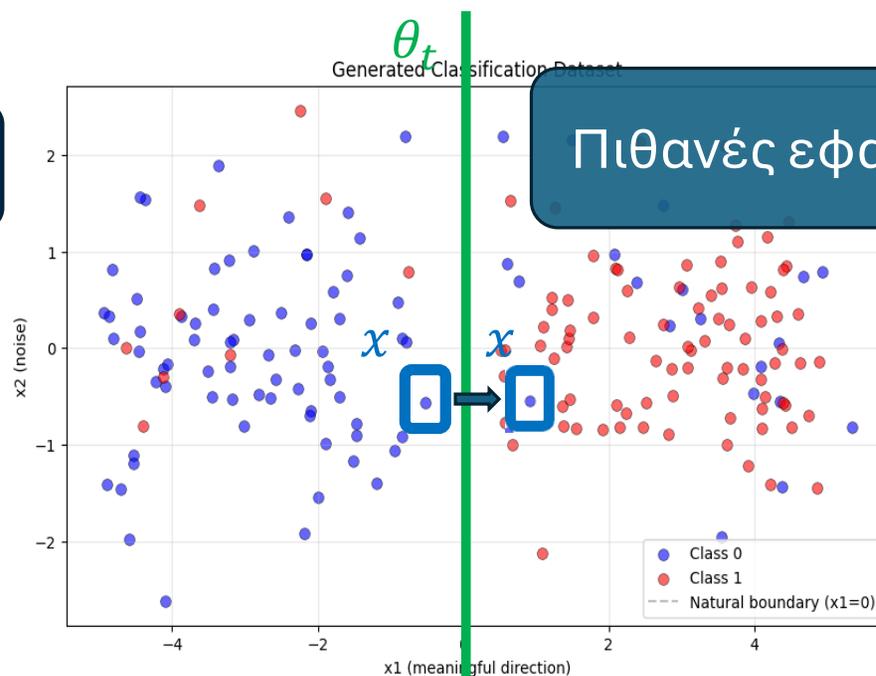
$$x_+ = x - \eta \nabla_x \text{Loss}(x, y, \theta_t)$$

Ακολουθούμε την αρνητική κλίση

Η συνολική απώλεια:

$$\sum \text{Loss}(x_i, y_i, \theta)$$

Είναι συνάρτηση των παραμέτρων  
και των δεδομένων.



Πιθανές εφαρμογές;

# Η Μέθοδος: Stochastic Gradient Descent

Αλλάζουμε το  $y$

Μειώνουμε  
Αυξάνουμε την απώλεια

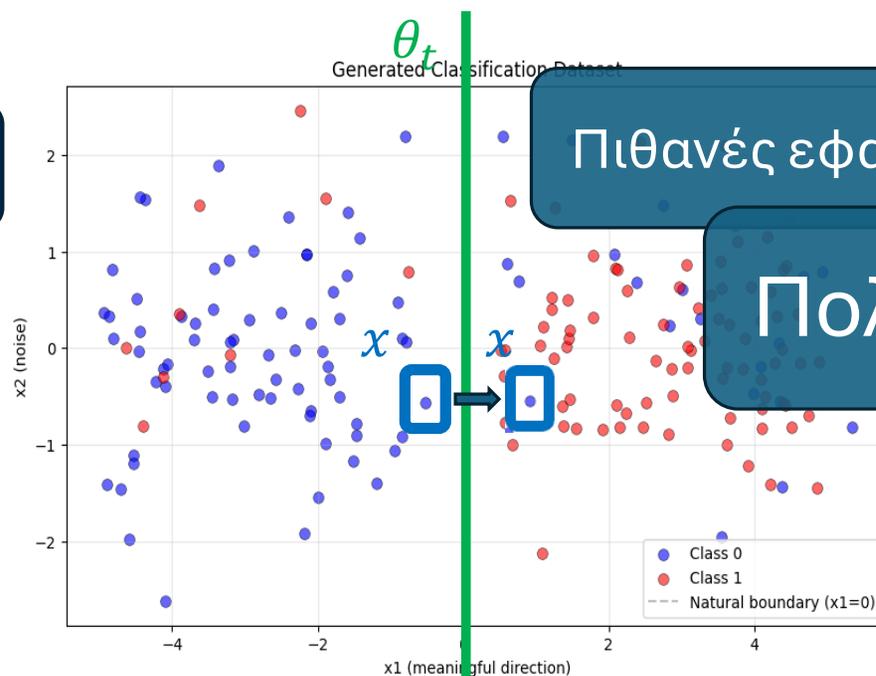
$$x_+ = x - \eta \nabla_x \text{Loss}(x, y, \theta_t)$$

Ακολουθούμε την αρνητική κλίση

Η συνολική απώλεια:

$$\sum \text{Loss}(x_i, y_i, \theta)$$

Είναι συνάρτηση των παραμέτρων  
και των δεδομένων.



Πιθανές εφαρμογές;

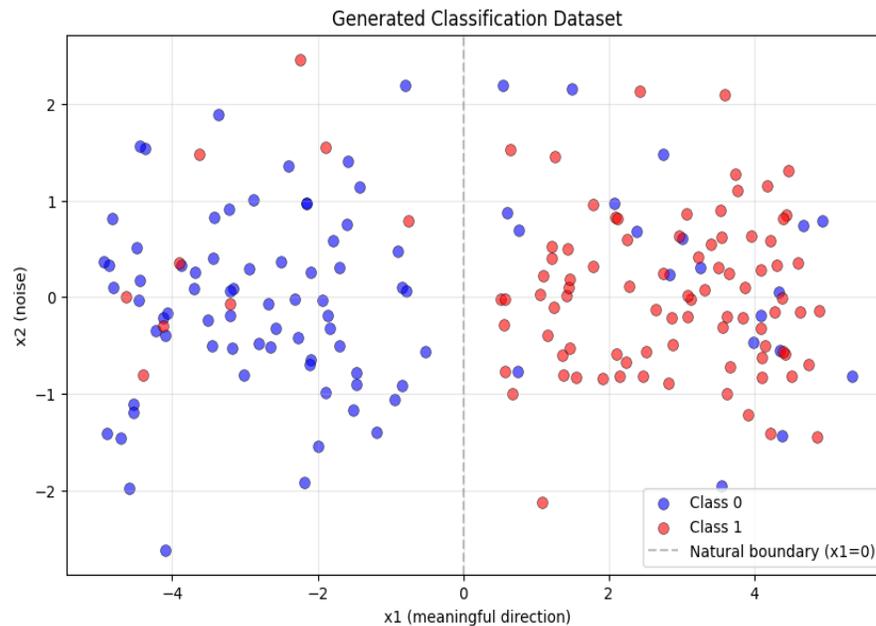
Πολλές!

# Η Μέθοδος: Stochastic Gradient Descent

Η συνολική απώλεια:

$$\sum Loss(x_i, y_i, \theta)$$

Είναι συνάρτηση των παραμέτρων  
και των δεδομένων.



Κωνσταντίνος Καραμανής

Όταν εκπαιδεύουμε  
βρίσκουμε παραμέτρους  
που ελαχιστοποιούν την  
απώλεια

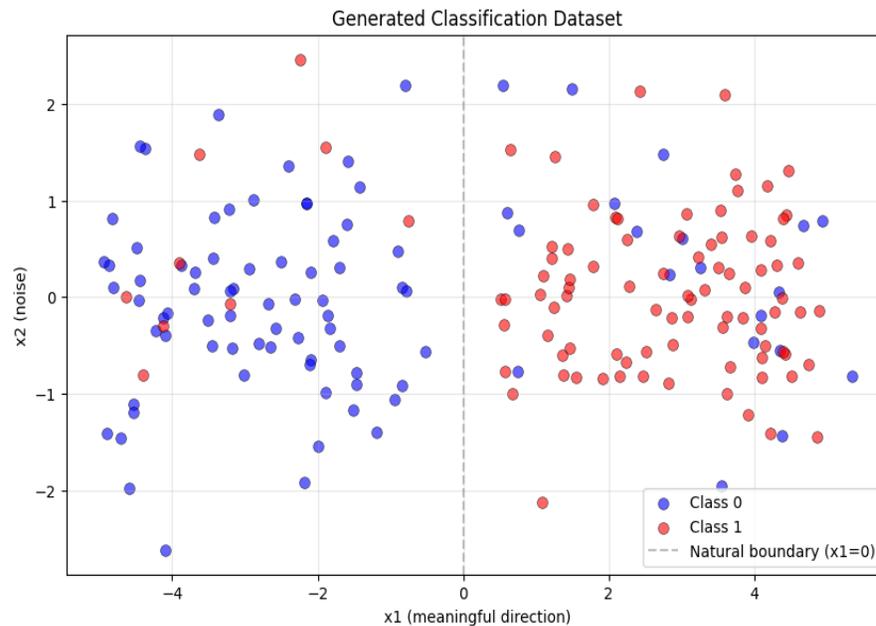
**Stochastic Gradient Descent**

$$\theta_+ = \theta - \eta \sum_{i \in S} \nabla \text{Loss}(x_i, y_i, \theta)$$

Η συνολική απώλεια:

$$\sum \text{Loss}(x_i, y_i, \theta)$$

Είναι συνάρτηση των παραμέτρων  
και των δεδομένων.



Κωνσταντίνος Καραμανής

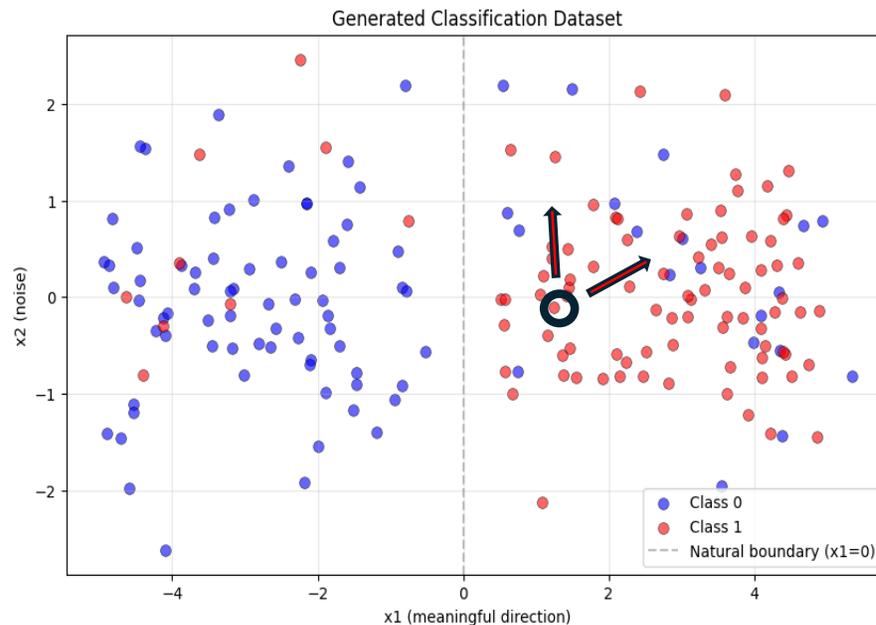
Πότε θα θέλαμε να μετακινήσουμε ένα σημείο, ώστε να αυξήσουμε ή να μειώσουμε την απώλειά του, χωρίς να πειράξουμε ή να αλλάξουμε το νευρωνικό δίκτυο;

$$x_+ = x \pm \eta \nabla_x \text{Loss}(x, \theta)$$

Η συνολική απώλεια:

$$\sum \text{Loss}(x_i, y_i, \theta)$$

Είναι συνάρτηση των παραμέτρων και των δεδομένων.



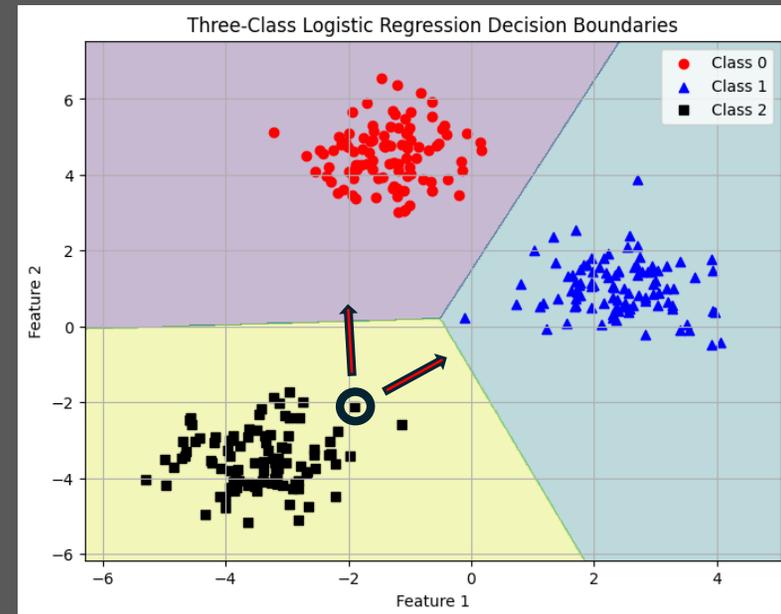
## Η συνολική απώλεια:

Κακόβουλη επίθεση ενάντια στο νευρωνικό δίκτυο  
“Adversarial Attacks”

$x$  – μαύρο σημείο

$$x^+ = x - \eta \nabla_x L(x, y, \theta)$$

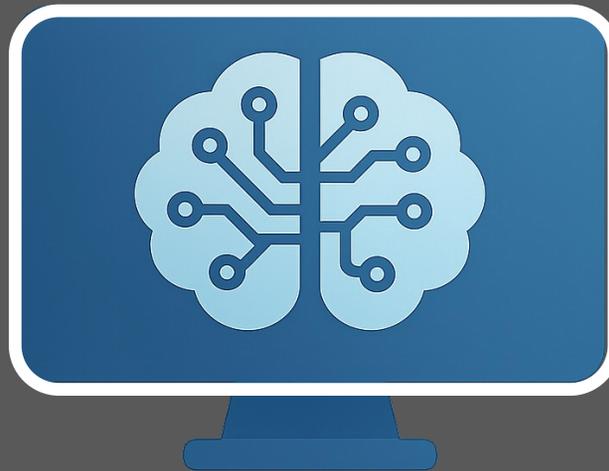
$$x^+ = x - \eta \nabla_x L(x, y, \theta)$$



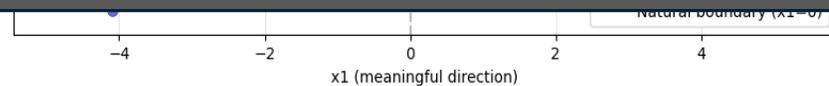
Η συνολική απώλεια:

Κακόβουλη επίθεση ενάντια στο νευρωνικό δίκτυο  
“Adversarial Attacks”

**resnet18**



Golden retriever: 50%  
Dog: 99.96%

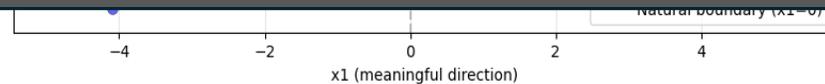


Η συνολική απώλεια:

Κακόβουλη επίθεση ενάντια στο νευρωνικό δίκτυο  
“Adversarial Attacks”



$$- \eta \nabla_x L(x_{\text{dog}}, y_{\text{cat}}, \theta)$$



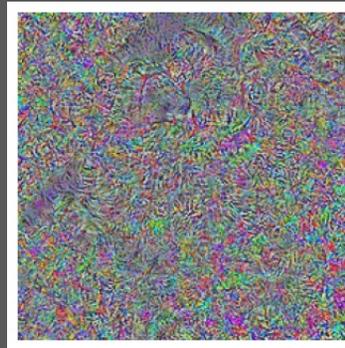
Κωνσταντίνος Καραμανής

## Η συνολική απώλεια:

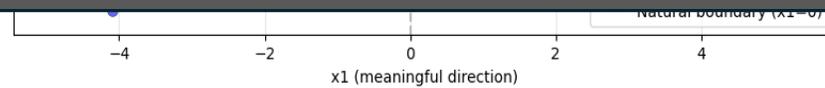
Κακόβουλη επίθεση ενάντια στο νευρωνικό δίκτυο  
“Adversarial Attacks”



−  $\eta$



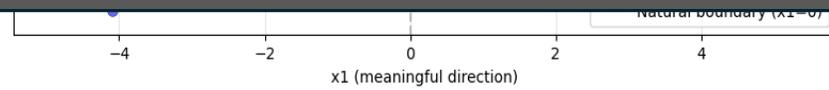
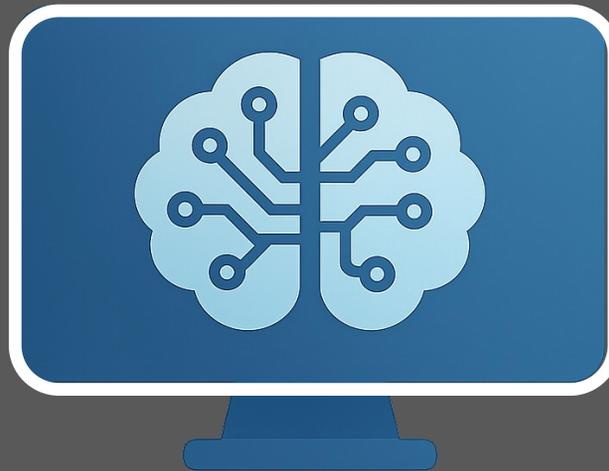
=



Η συνολική απώλεια:

Κακόβουλη επίθεση ενάντια στο νευρωνικό δίκτυο  
“Adversarial Attacks”

**resnet18**

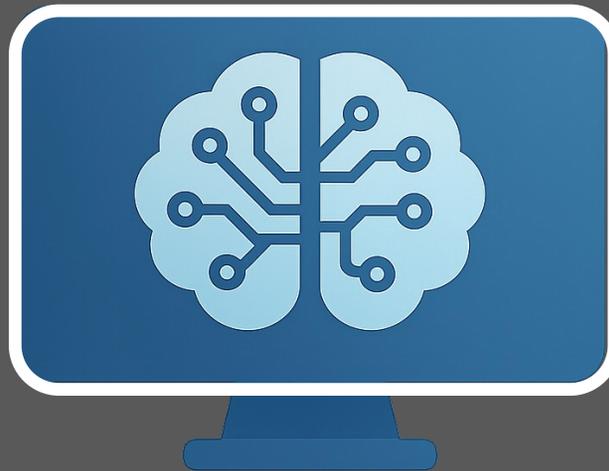


Κωνσταντίνος Καραμανής

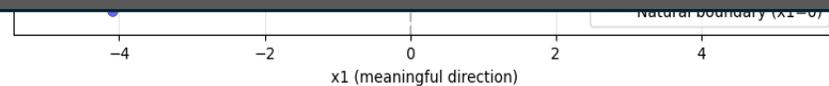
Η συνολική απώλεια:

Κακόβουλη επίθεση ενάντια στο νευρωνικό δίκτυο  
“Adversarial Attacks”

**resnet18**

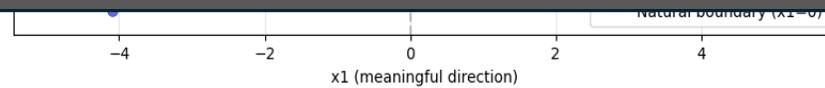
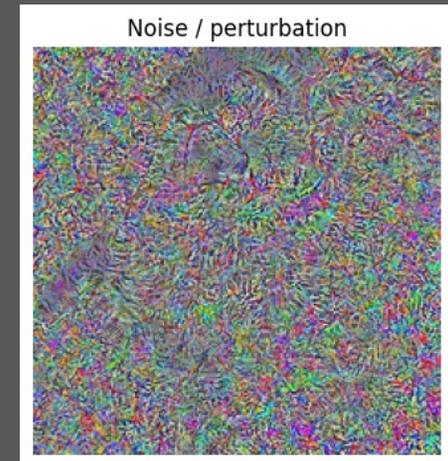


Siamese Cat: 100%



## Η συνολική απώλεια:

Κακόβουλη επίθεση ενάντια στο νευρωνικό δίκτυο  
“Adversarial Attacks”



Εκπαίδευση: Αλλάζουμε το μοντέλο ( $\theta$ )

**Stochastic Gradient Descent**

$$\theta_+ = \theta - \eta \sum_{i \in S} \nabla \text{Loss}(x_i, y_i, \theta)$$

Επίθεση: Αλλάζουμε το σημείο ( $x$ )

$$x_+ = x \pm \eta \nabla_x \text{Loss}(x, y, \theta)$$