



Μηχανική Μάθηση: Μαθηματικό Υπόβαθρο

Κωνσταντίνος Καραμανής

The University of Texas at Austin & Archimedes/Athena RC

constantine@utexas.edu

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





Ας θυμηθούμε τα
προηγούμενα...



Εκπαίδευση Αλγορίθμου

1. Επιλέγουμε την οικογένεια αλγορίθμων:
παράδειγμα – δέντρα απόφασης βάθους 1


```
mymodel = DecisionTrees(max_depth=1)
```

2. Βρίσκουμε τις παραμέτρους που
ελαχιστοποιούν τα λάθη στα δεδομένα μας

```
mymodel.fit(X,y)
```

```
mymodel.predict(x)
```

Δέντρο απόφασης με βάθος = 1




Εκπο
Αλγο

Empirical Risk Minimization

1. Επιλέγουμε την οικογένεια αλγορίθμων:
παράδειγμα – δέντρα απόφασης βάθους 1

`mymodel.predict(x)`

Κωνσταντίνος Καραμανής




Εκπαίδευση Αλγορίθμου

`mymodel.fit(X,y)`



Δέντρο απόφασης με βάθος = 1




2. Βρίσκουμε τις παραμέτρους που ελαχιστοποιούν τα λάθη στα δεδομένα μας

`mymodel.fit(X,y)`

`mymodel.predict(x)`

Δέντρο απόφασης με βάθος = 1



1. Επιλέγω
παράδειγμα








`mymodel.fit(X,y)`

Δέντρο απόφασης με βάθος = 1

$$X_1 \geq 127.5$$

$$y = \text{blue}$$

$$y = \text{red}$$



βάθος = 1

Κινεσιολογικές Καρδιολογικές



`mymodel.fit(X,y)`



Δέντρο απόφασης με βάθος = 1


$$X_1 \geq 127.5$$

Το `mymodel.fit(X,y)`
προσπαθεί να
ελαχιστοποιήσει την
απώλεια



Εκπαίδευση
Αλγορίθμ

Ελαχιστοποιώντας την Απώλεια



Άθροισμα

$$\Sigma$$

Σωστή ετικέτα
(label)

Τι λέει το
μοντέλο


$$\text{Loss}(y_i, \hat{y}_i)$$

Συνάρτηση απώλειας

Ε

λαγιστοποιώντας την Απώλεια

$$\sum \text{Loss}(y_i, \hat{y}_i)$$





1. 0/1 – μετράμε λάθη

$$\text{Loss}(y_i, \hat{y}_i)$$

Συνάρτηση απώλειας

Ε





$$\sum \text{Loss}(y_i, \hat{y}_i)$$

1. 0/1 – μετράμε λάθη
2. Απόσταση από το σωστό: $\sum z_i$

$$\text{Loss}(y_i, \hat{y}_i)$$

Συνάρτηση απώλειας

Ε



$$\sum \text{Loss}(y_i, \hat{y}_i)$$

1. 0/1 – μετράμε λάθη
2. Απόσταση από το σωστό: $\sum z_i$
3. Πόσο σίγουροι είμαστε για το σωστό ή το λάθος:

$$\sum e^{z_i} + \sum e^{-\xi_j}$$


Συνάρτηση απώλειας

4. Συνάρτηση Απώλειας της Λογιστικής Παλινδρόμησης (cross-entropy)

$y = (y_1, y_2)$ όπου $y_1 = 1, y_2 = 0$ για κατηγορία (ετικέτα) 1

$y = (y_1, y_2)$ όπου $y_1 = 0, y_2 = 1$ για κατηγορία (ετικέτα) 2

Scatter Plot of Glucose vs BMI




$$\hat{y}_1 = \frac{\exp(z_1)}{\exp(z_1) + \exp(z_2)} = \frac{\exp(w_1^T x)}{\exp(w_1^T x) + \exp(w_2^T x)}$$

$$\hat{y}_2 = \frac{\exp(z_2)}{\exp(z_1) + \exp(z_2)} = \frac{\exp(w_2^T x)}{\exp(w_1^T x) + \exp(w_2^T x)}$$


$$Loss((y_1, y_2), (\hat{y}_1, \hat{y}_2)) = -(y_1 \log(\hat{y}_1) + y_2 \log(\hat{y}_2))$$

Πώς διαφέρουν οι
4 συναρτήσεις
απώλειας


Τι απώλεια αντιστοιχεί σε
σημεία που έχουν
ταξινομηθεί σωστά ή
λανθασμένα;



Πώς διαφέρουν οι 4 συναρτήσεις απώλειας




Loss Functions for $y=1$ as Point Moves Perpendicularly to Decision Boundary




Πώς μοιάζει η καμπύλη που περιγράφει η συνάρτηση απώλειας για τα 4 μας παραδείγματα;


Πώς διαφέρουν οι 4 συναρτήσεις απώλειας




Loss Functions for $y=1$ as Point Moves Perpendicularly to Decision Boundary




Πώς διαφέρουν οι 4 συναρτήσεις απώλειας




$L_{0/1}$ – μετράει τα λάθη




Approaching points Perpendicularly to Decision Boundary



L_{hinge} – απόσταση από σωστό




L_{exp} – εκθετική απώλεια




L_{ce} – cross-entropy


Πώς διαφέρουν οι 4 συναρτήσεις απώλειας







L_{hinge} – απόσταση από σωστό





Πώς διαφέρουν οι 4 συναρτήσεις απώλειας



Loss Functions for $y=1$ as Point Moves Perpendicularly to Decision Boundary




Πώς διαφέρουν οι 4 συναρτήσεις απώλειας




Κωνσταντίνος Καραμανής

L_{ce} - cross-entropy

Πώς διαφέρουν οι 4 συναρτήσεις απώλειας




Loss Functions for $y=1$ as Point Moves Perpendicularly to Decision Boundary




Πώς διαφέρουν οι
4 συναρτήσεις
απώλειας

Όταν αλλάζουμε την
συνάρτηση απώλειας,
αλλάζουμε και την
βέλτιστη λύση



Πώς διαφέρουν οι
4 συναρτήσεις
απώλειας


Όταν αλλάζουμε την
συνάρτηση απώλειας,
αλλάζουμε και την
βέλτιστη λύση




Πώς διαφέρουν οι
4 συναρτήσεις
απώλειας

Όταν αλλάζουμε την
συνάρτηση απώλειας,
αλλάζουμε και την
βέλτιστη λύση



Πώς βρίσκουμε την
βέλτιστη λύση;



Πώς βρίσκουμε την βέλτιστη λύση;








Πώς βρίσκουμε την βέλτιστη λύση;








Κωνσταντίνος Καραμανής

Πώς βρίσκουμε την βέλτιστη λύση;








Κωνσταντίνος Καραμανής

Πώς βρίσκουμε την βέλτιστη λύση;








Κωνσταντίνος Καραμανής

Πώς βρίσκουμε την βέλτιστη λύση;








Κωνσταντίνος Καραμανής

Πώς βρίσκουμε την βέλτιστη λύση;








Πώς βρίσκουμε την βέλτιστη λύση;








Κωνσταντίνος Καραμανής

Πώς βρίσκουμε την βέλτιστη λύση;




Κωνσταντίνος Καραμανής

Πώς βρίσκουμε την βέλτιστη λύση;







Κωνσταντίνος Καραμανής


Πώς βρίσκουμε την βέλτιστη λύση;







Χρόνο $\log\left(\frac{1}{\epsilon}\right)$
για ακρίβεια ϵ




Πώς βρίσκουμε την βέλτιστη λύση;







Χρόνο $\log\left(\frac{1}{\epsilon}\right)$
για ακρίβεια ϵ



Πώς βρίσκουμε την βέλτιστη λύση;








Χρόνος $\log\left(\frac{1}{\epsilon}\right)$
για ακρίβεια ϵ



Κωνσταντίνος Καραμανής

Πώς βρίσκουμε την βέλτιστη λύση;




Χρόνος $\left(\frac{1}{\epsilon}\right)$
για ακρίβεια ϵ

Παλινδρόμηση (Linear Regression)

Ποια είναι η βέλτιστη
σχέση μεταξύ X και Y;

Πώς μετράμε την απώλεια;

MSE Loss: $L(y, \hat{y}) = (y - \hat{y})^2$



Κωνσταντίνος Καραμανής


Παλινδρόμηση (Linear Regression)

Ποια είναι η βέλτιστη
σχέση μεταξύ X και Y;

Πώς μετράμε την απώλεια;

MSE Loss: $L(y, \hat{y}) = (y - \hat{y})^2$

L₁ Loss: $L(y, \hat{y}) = |y - \hat{y}|$



Κωνσταντίνος Καραμανής


Παλινδρόμηση (Linear Regression)

Ποια είναι η βέλτιστη
σχέση μεταξύ X και Y;

Πώς μετράμε την απώλεια;

$$\text{MSE Loss: } L(y, \hat{y}) = (y - \hat{y})^2$$

$$L_1 \text{ Loss: } L(y, \hat{y}) = |y - \hat{y}|$$




Παλινδρόμηση (Linear Regression)

Ποια είναι η βέλτιστη
σχέση μεταξύ X και Y;

Πώς μετράμε την απώλεια;

$$\text{MSE Loss: } L(y, \hat{y}) = (y - \hat{y})^2$$

$$L_1 \text{ Loss: } L(y, \hat{y}) = |y - \hat{y}|$$



Παλινδρόμηση (Linear Regression)

Ποιοτικά, πώς διαφέρουν αυτές οι συναρτήσεις απώλειας;

Ένα απλό παράδειγμα: $y = h(X) = \beta_0 + \beta_1 X$

$$\text{MSE Loss: } L(y, \hat{y}) = (y - \hat{y})^2$$

Με δεδομένα $\{(X_i, y_i)\}$ το απλό μοντέλο μας ζητάει να λύσουμε: $\min_{\beta_0} \sum_i (y_i - \beta_0)^2$

$$\frac{d}{d\beta_0} \sum_i (y_i - \beta_0)^2 = -2 \sum_i (y_i - \beta_0) = 0$$

$$\hat{\beta}_0 = \frac{1}{n} \sum y_i$$

Ο μέσος όρος!

$$L_1 \text{ Loss: } L(y, \hat{y}) = |y - \hat{y}|$$

Παλινδρόμηση (Linear Regression)

Ποιοτικά, πώς διαφέρουν αυτές οι συναρτήσεις απώλειας;

Ένα απλό παράδειγμα: $y = h(X) = \beta_0$

$$\text{MSE Loss: } L(y, \hat{y}) = (y - \hat{y})^2$$

Με δεδομένα $\{(X_i, y_i)\}$ το απλό μοντέλο μας ζητάει να λύσουμε: $\min_{\beta_0} \sum_i (y_i - \beta_0)^2$

$$\frac{d}{d\beta_0} \sum_i (y_i - \beta_0)^2 = -2 \sum_i (y_i - \beta_0) = 0$$

$$\hat{\beta}_0 = \frac{1}{n} \sum y_i$$

Ο μέσος όρος!

Κωνσταντίνος Καραμανής

$$L_1 \text{ Loss: } L(y, \hat{y}) = |y - \hat{y}|$$

Με δεδομένα $\{(X_i, y_i)\}$ το απλό μοντέλο μας ζητάει να λύσουμε: $\min_{\beta_0} \sum_i |y_i - \beta_0|$

Πρόκληση: πως θα το λύσουμε ως προς β_0 ;

$$\hat{\beta}_0 = \text{median}(\{y_i\})$$

Η διάμεσος!

Παλινδρόμηση: δεύτερο παράδειγμα

Συναρτήσεις που περνάνε από το 0

μοντέλο: $y = h(X) = \beta_0 X + \beta_1 X$


Python:

```
model = LinearRegression(fit_intercept = false)
```

```
model.fit(X,y)
```

```
 $\beta_1 = \text{model.coef}_1$ 
```

Εμείς;



Παλινδρόμηση: δεύτερο παράδειγμα

Συναρτήσεις που περιγράφουν

Δεδομένα: $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$

μοντέλο: $y = h(X) = \beta_0 X + \beta_1 X$

Python:


```
model = LinearRegression(fit_intercept = false)
```

```
model.fit(X,y)
```

```
 $\beta_1 = \text{model.coef}_1$ 
```

$$\min_{\beta_1} \sum_i (y_i - \beta_1 x_i)^2$$

$$\text{Απάντηση: } \hat{\beta}_1 = \frac{\sum_i x_i y_i}{\sum_i x_i^2}$$



Εμείς:

Παλινδρόμηση: δεύτερο παράδειγμα

Συναρτήσ

μοντέλο:

Python:

```
model
```

```
model
```

```
 $\beta_1 = \text{mo}$ 
```

Αυτά τα απλά παραδείγματα είναι καλή εξάσκηση, αλλά δεν γενικεύονται: κατά κύριο λόγο, δεν μπορούμε να βρούμε σε κλειστή μορφή τις παραμέτρους που ελαχιστοποιούν την απώλεια.

Εμείς:

Εκπαίδευση Αλγορίθμου

1. Επιλέγουμε την οικογένεια αλγορίθμων:
παράδειγμα – λογιστική παλινδρόμηση
2. Επιλέγουμε την συνάρτηση απώλειας

`mymodel = LogisticRegression()`
3. Βρίσκουμε τις παραμέτρους που
ελαχιστοποιούν τα λάθη στα δεδομένα
ελαχιστοποιούν το άθροισμα της
απώλειας στα δεδομένα (εκπαίδευσης)

```
mymodel.fit(X,y)
```

Αλλάζοντας την
συνάρτηση απώλειας,
αλλάζουμε και την
βέλτιστη λύση

Εκπαίδευση
Αλγορίθμου

1. Επιλέγουμε την οικογένεια αλγορίθμων:
παράδειγμα – λογιστική παλινδρόμηση
2. Επιλέγουμε την συνάρτηση απώλειας
`mymodel = LogisticRegression()`
3. Βρίσκουμε τις παραμέτρους που
ελαχιστοποιούν τα λάθη στα δεδομένα
ελαχιστοποιούν το άθροισμα της
απώλειας στα δεδομένα (εκπαίδευσης)

`mymodel.fit(X,y)`

Εκπαίδευση Αλγορίθμου

Αλλάζοντας την
συνάρτηση απώλειας,
αλλάζουμε και την
πολυπλοκότητα επίλυσης

1. Επιλέγουμε την οικογένεια αλγορίθμων:
παράδειγμα – λογιστική παλινδρόμηση
2. Επιλέγουμε την συνάρτηση απώλειας

`mymodel = LogisticRegression()`
3. Βρίσκουμε τις παραμέτρους που
ελαχιστοποιούν τα λάθη στα δεδομένα
ελαχιστοποιούν το άθροισμα της
απώλειας στα δεδομένα (εκπαίδευσης)

`mymodel.fit(X,y)`

Εκπαίδευση
Αλγόριθμοι

Πώς βρίσκουμε τις παραμέτρους που ελαχιστοποιούν την απώλεια;

1. Επιλέγουμε την οικογένεια αλγορίθμων:
παράδειγμα – λογιστική παλινδρόμηση

2. Επιλέγουμε την συνάρτηση απώλειας

```
mymodel = LogisticRegression()
```

3. Βρίσκουμε τις παραμέτρους που
ελαχιστοποιούν το άθροισμα της
απώλειας στα δεδομένα (εκπαίδευσης)

```
mymodel.fit(x,y)
```

Αλλάζοντας την
συνάρτηση απώλειας,
αλλάζουμε και την
πολυπλοκότητα επίλησης