



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...



Συναρτήσεις απώλειας

Ταξινόμηση




Errors

Cross Entropy

Hinge Loss

Exp Loss

Παλινδρόμηση



MSE loss

L1 loss

Συναρτήσεις απώλειας

Ταξινόμηση


Παλινδρόμηση

Errors

Cross Entropy


Hinge Loss

Exp Loss



MSE loss

L1 loss



Από που προέρχονται αυτές οι συναρτήσεις απώλειας;

Ένα απλό πείραμα σκέψης

Διαλέγουμε ένα κέρμα, και το ρίχνουμε 100 φορές. Παρατηρούμε 37 φορές «κορόνα» και 63 φορές «γράμματα». Θέλουμε να εκτιμήσουμε την **πιθανότητα** πως θα ξαναβγεί κορόνα:

$$p = \mathbb{P}(\text{κορόνα})$$

Δύο κοσμοθεωρίες: (1) Ξέρουμε πώς είναι κατασκευασμένα τα κέρματα, και αυτό θα μας δώσει την απάντηση (Bayesian). (2) Ξέρουμε μόνο αυτά που έχουμε παρατηρήσει (Frequentist).

Ένα απλό πείραμα σκέψης

Διαλέγουμε ένα κέρμα, και το ρίχνουμε 100 φορές. Παρατηρούμε 37 φορές «κορόνα» και 63 φορές «γράμματα». Θέλουμε να εκτιμήσουμε την **πιθανότητα** πως θα ξαναβγεί κορόνα:

$$p = \mathbb{P}(\text{κορόνα})$$

Ιδέα 1: Τα κέρματα είναι ίδια, με $p = \frac{1}{2}$ και απλά έτυχε να βγουν 37Κ/63Γ.

Ιδέα 2: Το μόνο που ξέρουμε είναι ότι βγήκαν 37 Κ / 63 Γ

Ένα απλό πείραμα σκέψης

Διαλέγουμε ένα κέρμα, και το ρίχνουμε 100 φορές. Παρατηρούμε 37 φορές «κορόνα» και 63 φορές «γράμματα». Θέλουμε να εκτιμήσουμε την **πιθανότητα** πως θα ξαναβγεί κορόνα:

$$p = \mathbb{P}(\text{κορόνα})$$

Ιδέα 1: Τα κέρματα είναι ίδια, με $p = \frac{1}{2}$ και απλά έτυχε να βγουν 37Κ/63Γ.

Ιδέα 2: Το μόνο που ξέρουμε είναι ότι βγήκαν 37 Κ / 63 Γ

Αρχή Μέγιστης Πιθανοφάνειας (Maximum Likelihood)

Εάν η πραγματική πιθανότητα να βγεί «κορόνα» είναι $p = \mathbb{P}(\text{κορόνα})$, με ποια πιθανότητα θα βλέπαμε 37Κ/63Γ;

Πιθανότητα Κ: p

Πιθανότητα (Κ,Κ): $p \cdot p$

Πιθανότητα (Γ,Κ): $(1 - p) \cdot p$

Πιθανότητα (Κ,Γ): $p \cdot (1 - p)$

Πιθανότητα 1 Κ και 1 Γ: $(1 - p) \cdot p + p \cdot (1 - p)$

Πιθανότητα 2 Κ και 1 Γ: $\underbrace{p^2 \cdot (1 - p)}_{\text{ΚΚΓ}} + \underbrace{p \cdot (1 - p) \cdot p}_{\text{ΚΓΚ}} + \underbrace{(1 - p) \cdot p^2}_{\text{ΓΚΚ}}$

ΚΚΓ

ΚΓΚ

ΓΚΚ

Κωνσταντίνος Καραμανής

Αρχή Μέγιστης Πιθανοφάνειας (Maximum Likelihood)

Εάν η πραγματική πιθανότητα να βγει «κορόνα» είναι $p = \mathbb{P}(\text{κορόνα})$, με ποια πιθανότητα θα βλέπαμε 37Κ/63Γ;

Εάν η πραγματική πιθανότητα να βγει «κορόνα» είναι $p = \mathbb{P}(\text{κορόνα})$, με ποια πιθανότητα θα βλέπαμε 37Κ/63Γ;

$$\frac{100!}{37!63!} p^{37} \cdot (1-p)^{63} = \binom{100}{37} p^{37} \cdot (1-p)^{63}$$

ΚΚΓ

Κωνσταντίνος Καραμανής

ΚΓΚ

ΓΚΚ

Αρχή Μέγιστης Πιθανοφάνειας (Maximum Likelihood)

Εάν η πραγματική πιθανότητα να βγει «κορόνα» είναι $p = \mathbb{P}(\text{κορόνα})$, η πιθανότητα να βλέπαμε 37Κ/63Γ είναι:

$$\frac{100!}{37!63!} p^{37} \cdot (1 - p)^{63} = \binom{100}{37} p^{37} \cdot (1 - p)^{63}$$

Αρχή Μέγιστης Πιθανοφάνειας (Maximum Likelihood)

Εάν η πραγματική πιθανότητα να βγει «κορόνα» είναι $p = \mathbb{P}(\text{κορόνα})$, η πιθανότητα να βλέπαμε 37Κ/63Γ είναι:

$$\frac{100!}{37!63!} p^{37} \cdot (1 - p)^{63} = \binom{100}{37} p^{37} \cdot (1 - p)^{63}$$

Max Likelihood: εάν δούμε 37Κ/63Γ, η αρχή της Μέγιστης Πιθανοφάνειας εκτιμάει πως το πραγματικό \hat{p} είναι αυτό που μεγιστοποιεί την πιθανότητα.

Αρχή Μέγιστης Πιθανοφάνειας (Maximum Likelihood)

$$f(p) = \binom{100}{37} p^{37} \cdot (1-p)^{63}$$

$$\operatorname{argmax}: f(p) \rightarrow f'(p) = 0$$

Εάν η πραγματική πιθανότητα να βγει «κορόνα» είναι $p = \mathbb{P}(\text{Κορόνα})$, η πιθανότητα να βλέπουμε 37 Κ/63 Γ είναι

$$f'(p) = \binom{100}{37} [37p^{36} \cdot (1-p)^{63} - 63p^{37} (1-p)^{62}]$$

$$\frac{100!}{37!63!} p^{36} \cdot (1-p)^{62} [37(1-p)^1 - 63p^1] = 0$$

Max Likelihood (εάν $p = 37/100$), η αρχή της Μέγιστης

Πιθανοφάνειας εκτιμάει πως το πραγματικό \hat{p} είναι αυτό

που μεγιστοποιεί $[37(1-p)^1 - 63p^1] = 0$

$$\hat{p} = \frac{37}{100}$$

Κωνσταντίνος

Maximum Likelihood και Λογιστική Παλινδρόμηση

Πως εφαρμόζουμε την ιδέα της μέγιστης πιθανοφάνειας στη λογιστική παλινδρόμηση, ώστε να βρούμε κατάλληλη συνάρτηση απώλειας;

Λογιστική Παλινδρόμηση: Με δεδομένα $\{(X_i, y_i)\}$, όπου έχουμε $y \in \{0,1\}$, θέλουμε να εκτιμήσουμε την *πιθανότητα* πως το $y = 1$:

$$P(Y = 1|X = x)$$

Maximum Likelihood και Λογιστική Παλινδρόμηση

Πως εφαρμόζουμε την ιδέα της
παλινδρόμηση, ώστε να βρούμε

Λογιστική Παλινδρόμηση: Με δεδομένη
 $y \in \{0,1\}$, θέλουμε να εκτιμήσουμε

$$P(Y = 1 | X = x)$$

Όπως έχουμε ήδη δει, αυτές οι ιδέες
επεκτείνονται σε γενικότερα προβλήματα
με K κατηγορίες (π.χ., CIFAR-10), όπου ο
στόχος μας είναι να προβλέψουμε την
πιθανότητα $Y = \kappa$, για κάθε κατηγορία κ .

$$\hat{p}_\kappa = P(Y = \kappa | X = x)$$

$$0 \leq \hat{p}_\kappa \leq 1, \sum_{\kappa \in K} \hat{p}_\kappa = 1$$

Λογιστική Παλινδρόμηση

Στόχος: εκτίμηση της πιθανότητας $Y=1$ ή $Y=0$

Πρώτο βήμα: υπολογίζουμε το λεγόμενο **score** ή **logit**:

$$Z_X = \beta_0 + \beta^T X = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_d X_d$$

Χρησιμοποιούμε την sigmoid (softmax) συνάρτηση για να μετατρέψουμε το «score» σε πιθανότητα:

$$P(Y = 1|X) = \hat{p}_X = \text{sigmoid}(z_X) = \frac{\exp(z_X)}{1 + \exp(z_X)} = \frac{1}{1 + \exp(-z_X)}$$

Λογιστική Παλινδρόμηση


Στόχο

Πρώτ

Χρησι

το «SC

P(



ουμε

x)


Λογιστική Παλινδρόμηση: πώς λειτουργεί

$$Z_X = \beta_0 + \beta^T X = \beta_0 + \beta_1 X_1 + \beta_2 X_2$$

$$P(Y = 1|X) = \frac{\exp(z_X)}{1 + \exp(z_X)}$$

Παράδειγμα A: $\beta_0 = 0, \beta_1 = 2, \beta_2 = -2$.

Ποιος διαχωρισμός του χώρου προκύπτει;




Λογιστική Παλινδρόμηση: πώς λειτουργεί

$$Z_X = \beta_0 + \beta^T X = \beta_0 + \beta_1 X_1 + \beta_2 X_2$$

$$P(Y = 1|X) = \frac{\exp(z_X)}{1 + \exp(z_X)}$$

Παράδειγμα Β : $\beta_0 = -5, \beta_1 = 1, \beta_2 = 0$.

Ποιος διαχωρισμός του χώρου προκύπτει;



Λογιστική Παλινδρόμηση: πώς λειτουργεί

$$Z_X = \beta_0 + \beta^T X = \beta_0 + \beta_1 X_1 + \beta_2 X_2$$

$$P(Y = 1|X) = \frac{\exp(z_X)}{1 + \exp(z_X)}$$


Παράδειγμα Γ: $\beta_0 = -15, \beta_1 = 3, \beta_2 = 0$

Ποιος διαχωρισμός του χώρου προκύπτει;

Ο διαχωρισμός του χώρου ορίζεται από την εξίσωση

$$Z_X = \beta_0 + \beta^T X = 0$$

Προσοχή: το όριο απόφασης είναι ανεξάρτητο της κλίμακας, αλλά το μοντέλο δεν είναι!



Λογιστική Παλινδρόμηση: πώς λειτουργεί

$$Z_X = \beta_0 +$$

$$P(Y = 1|X)$$


Παράδειγμα

Ποιος διακρίνει
προκύπτει

Παρατηρήστε πως μπορούμε να ορίσουμε μη-γραμμικό διαχωρισμό του χώρου για την λογιστική παλινδρόμηση. Παράδειγμα: προσθέτουμε τις στήλες $X_3 = X_1^2, X_4 = X_2^2$. Θεωρήστε το μοντέλο που έχει: $\beta_0 = -4, \beta_1 = 0, \beta_2 = 0, \beta_3 = 1, \beta_4 = 1$. Για ένα σημείο (X_1, X_2) , έχουμε:

$$Z_X = -4 + 0X_1 + 0X_2 + 1X_1^2 + 1X_2^2$$

Ποια είναι η μορφή του όριου απόφασης του μοντέλου;




Λογιστική Παλινδρόμηση: πώς λειτουργεί

7 Παρατηρήστε πως μπορούμε να ορίσουμε μη-γραμμικό διαχωρισμό του χώρου για την λογιστική παλινδρόμηση. Παράδειγμα: προσθέτουμε τις στήλες $X_3 = X_1^2, X_4 = X_2^2$. Θεωρήστε το μοντέλο που έχει: $\beta_0 = -4, \beta_1 = 0, \beta_2 = 0, \beta_3 = 1, \beta_4 = 1$. Για ένα σημείο (X_1, X_2) , έχουμε:

$$Z_X = -4 + 0X_1 + 0X_2 + 1X_1^2 + 1X_2^2$$

Ποια είναι η μορφή του όριου απόφασης του μοντέλου;



Λογιστική Παλινδρόμηση: πώς λειτουργεί

$$Z_X = \beta_0 + \beta^T X = \beta_0 + \beta_1 X_1 + \beta_2 X_2$$


$$P(Y = 1|X) = \frac{\exp(z_X)}{1 + \exp(z_X)}$$

Ένα καλό μοντέλο;

Ποιο μοντέλο είναι καλύτερο;

$$Z_X = -10 + X_1 + X_2$$

$$Z_X = -50 + 5 \cdot X_1 + 5 \cdot X_2$$



Λογιστική Παλινδρόμηση: πώς λειτουργεί

$$Z_X = \beta_0 + \beta^T X = \beta_0 + \beta_1 X_1 + \beta_2 X_2$$

$$P(Y = 1|X) = \frac{\exp(z_X)}{1 + \exp(z_X)}$$

Ένα καλό μοντέλο;


Ποιο μοντέλο είναι καλύτερο;

$$Z_X = -10 + X_1 + X_2$$

$$Z_X = -50 + 5 \cdot X_1 + 5 \cdot X_2$$

Η συζήτηση «καλύτερου/χειρότερου» μοντέλου απαιτεί χρήση συνάρτησης απώλειας.

Scatter Plot of Synthetic Data



Λογιστική Παλινδρόμηση και Max Likelihood

Έχουμε δεδομένα: $\{(X_i, y_i)\}$ όπου $y = (1,0,1,1,0)$

Μοντέλο A έχει παραμέτρους (β_0^A, β^A) : εκτιμεί $\hat{y} = (0.6,0.4,0.55,0.52,0.45)$

Μοντέλο B έχει παραμέτρους (β_0^B, β^B) : εκτιμεί $\hat{y} = (0.9,0.55,0.45,0.85,0.1)$

Ποιο μοντέλο είναι «καλύτερο»;

Ακρίβεια:

Λογιστική Παλινδρόμηση και Max Likelihood

Έχουμε δεδομένα: $\{(X_i, y_i)\}$ όπου $y = (1,0,1,1,0)$

Μοντέλο A έχει παραμέτρους (β_0^A, β^A) : εκτιμεί $\hat{y} = (0.6, 0.4, 0.55, 0.52, 0.45)$

Μοντέλο B έχει παραμέτρους (β_0^B, β^B) : εκτιμεί $\hat{y} = (0.9, 0.55, 0.45, 0.85, 0.1)$

Ποιο μοντέλο είναι «καλύτερο»;

Ακρίβεια: Μοντέλο A – 5/5 vs 3/5

Πιθανοφάνεια (Likelihood):

$$\text{Μοντέλο A. } 0.6 \cdot (1 - 0.4) \cdot 0.55 \cdot 0.52 \cdot (1 - 0.45) = 0.05663$$

$$\text{Μοντέλο B. } 0.9 \cdot (1 - 0.55) \cdot 0.45 \cdot 0.85 \cdot (1 - 0.1) = 0.13122$$

Λογιστική Παλινδρόμηση και Max Likelihood

Έχουμε δεδομένα: $\{(X_i, y_i)\}$

Πως υπολογίζουμε την πιθανοφάνεια του μοντέλου με παραμέτρους (β_0, β) ?

$$Z_X = \beta_0 + \beta^T X \quad P(Y = 1|X) = \text{sigmoid}(z_X) = \frac{\exp(z_X)}{1 + \exp(z_X)}$$

$$\text{Πιθανοφάνεια: } \prod_i \underbrace{\text{sigmoid}(z_{X_i})}^{y_i} \cdot \underbrace{(1 - \text{sigmoid}(z_{X_i}))}^{1-y_i}$$

Η πιθανοφάνεια όταν έχουμε $y=1$

Η πιθανοφάνεια όταν έχουμε $y=0$

Λογιστική Παλινδρόμηση και Max Likelihood

Έχουμε δεδομένα: $\{(X_i, y_i)\}$

Πως υπολογίζουμε την πιθανοφάνεια του μοντέλου με παραμέτρους (β_0, β) ?

$$Z_X = \beta_0 + \beta^T X \quad P(Y = 1|X) = \text{sigmoid}(z_X) = \frac{\exp(z_X)}{1 + \exp(z_X)}$$

$$\text{Πιθανοφάνεια: } \prod_i \text{sigmoid}(z_{X_i})^{y_i} \cdot (1 - \text{sigmoid}(z_{X_i}))^{1-y_i}$$

$$\text{Λογαριθμική Πιθανοφάνεια: } \sum_i y_i \cdot \log \text{sigmoid}(z_{X_i}) + (1 - y_i) \log (1 - \text{sigmoid}(z_{X_i}))$$

Η πιθανοφάνεια όταν έχουμε $y=1$ ή $y=0$

Λογιστική Παλινδρόμηση και Max Likelihood

Αρνητική Λογαριθμική Πιθανοφάνεια

$$-\sum_i y_i \cdot \log \text{sigmoid}(z_{x_i}) + (1 - y_i) \log (1 - \text{sigmoid}(z_{x_i}))$$

Σαν συνάρτηση του (β_0, β) , η αρνητική λογαριθμική πιθανοφάνεια (negative log likelihood) ισοδυναμεί με την Cross Entropy σαν συνάρτηση του $\text{softmax}(\beta_0 + \beta^T x)$ (logits) $\text{sigmoid}(z_{x_i})$


Λογιστική Παλινδρόμηση και Max Likelihood

Αρνητική Λογαριθμική Πιθανοφάνεια


$$\sum_i - \left(y_i \log \frac{\exp(\beta_0 + \beta^\top x_i)}{1 + \exp(\beta_0 + \beta^\top x_i)} + (1 - y_i) \log \frac{1}{1 + \exp(\beta_0 + \beta^\top x_i)} \right)$$

Cross Entropy σαν συνάρτηση του softmax($\beta_0 + \beta^\top x$) (logits) $\text{sigmoid}(z_{x_i})$

Λογιστική Παλινδρόμηση και Max Likelihood



Λογιστική Παλινδρόμηση και Max Likelihood



oid(z_{X_i})

Λογιστική Παλινδρόμηση και Max Likelihood


Αρνητική Λογαριθμική Πιθανοφάνεια

$$\sum_i - \left(y_i \log \frac{\exp(\beta_0 + \beta^\top x_i)}{1 + \exp(\beta_0 + \beta^\top x_i)} + (1 - y_i) \log \frac{1}{1 + \exp(\beta_0 + \beta^\top x_i)} \right)$$


Λο
Η συνάρτηση απώλειας έχει νόημα και όταν έχουμε $y \in [0,1]$ και όχι μόνο $y \in \{0,1\}$

sigmoid(z_{x_i})


Λογιστική Παλινδρόμηση και Max Likelihood



Λογιστική Παλινδρόμηση και Max Likelihood




Λογιστική Παλινδρόμηση και Max Likelihood



Λογιστική Παλινδρόμηση και Max Likelihood

Μηχανική Όραση




- σκύλος
- γάτα
- ελάφι
- άλογο
- αυτοκίνητο
- φορτηγό
- πλοίο
- αεροπλάνο
- πτηνό
- βάτραχος

$$y = \begin{pmatrix} 0 \\ 0 \\ 1 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{pmatrix}$$

Λογιστική Παλινδρόμηση και Max Likelihood

Μηχανική Όραση




- σκύλος
- γάτα
- ελάφι
- άλογο
- αυτοκίνητο
- φορτηγό
- πλοίο
- αεροπλάνο
- πτηνό
- βάτραχος

$$y = \begin{pmatrix} 0 \\ 0 \\ 0 \\ 1 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{pmatrix}$$

Λογιστική Παλινδρόμηση και Max Likelihood

Μηχανική Όραση



σκύλος
γάτα
ελάφι
άλογο
αυτοκίνητο
φορτηγό
πλοίο
αεροπλάνο
πτηνό
βάτραχος

$$y = \begin{pmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 1 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{pmatrix}$$

Λογιστική Παλινδρόμηση και Max Likelihood

Μηχανική Όραση

Αρνητική λογαριθμική πιθανοφάνεια (Negative Log Likelihood) για δύο κατηγορίες

$$- \left(y \log \frac{\exp(\beta_0 + \beta^T x)}{1 + \exp(\beta_0 + \beta^T x)} + (1 - y) \log \frac{1}{1 + \exp(\beta_0 + \beta^T x)} \right)$$

σκύλος
γάτα
ελαφί
αυτοκίνητο
φορτηγό
αεροπλάνο
πτηνό
βάτραχος

$y = 1$
0
0
0
0
0
0

Λογιστική Παλινδρόμηση και Max Likelihood

Μηχανική Όραση

Αρνητική λογαριθμική πιθανοφάνεια (Negative Log Likelihood) για δύο κατηγορίες

$$- \left(y \log \frac{\exp(z_1)}{1 + \exp(z_1)} + (1 - y) \log \frac{1}{1 + \exp(z_1)} \right)$$

σκύλος
γάτα
ελάφι
αυτοκίνητο
φορτηγό
πλοίο
αεροπλάνο
πτηνό
βάτραχος

0
0
0
1
0
0
0
0
0

Λογιστική Παλινδρόμηση και Max Likelihood

Μηχανική Όραση

Αρνητική λογαριθμική πιθανοφάνεια (Negative Log Likelihood) για δύο κατηγορίες

$$-\left(y \log \frac{\exp(z_1)}{\exp(z_0) + \exp(z_1)} + (1 - y) \log \frac{\exp(z_0)}{\exp(z_0) + \exp(z_1)} \right)$$

σκύλος
γάτα
ελαφί
αυτοκίνητο
φορτηγό
αεροπλάνο
πτηνό
βάτραχος

0

Λογιστική Παλινδρόμηση και Max Likelihood

Μηχανική Όραση

Αρνητική λογαριθμική πιθανοφάνεια (Negative Log Likelihood) για δύο κατηγορίες

$$- \left(y_1 \log \frac{\exp(z_1)}{\exp(z_0) + \exp(z_1)} + y_0 \log \frac{\exp(z_0)}{\exp(z_0) + \exp(z_1)} \right)$$

σκύλος
γάτα
ελαφι
πτηνό
αυτοκίνητο
φορτηγό
πλοίο
εεροπλάνο
πτηνό
βάτραχος

0

Λογιστική Παλινδρόμηση και Max Likelihood

Μηχανική Όραση

Αρνητική Λογική Πιθανοφάνεια (Negative Log Likelihood)

CIFAR-10: 10 Κατηγορίες
ImageNet: 1000 Κατηγορίες

Φυσική Γλώσσα: 50.000 Κατηγορίες


Βάτραχος

Κωνσταντίνος Καραμανής

Λογιστική Παλινδρόμηση και Max Likelihood

Επεξεργασία Φυσικής Γλώσσας

Είναι σημαντικό πρόβλημα της επεξεργασίας φυσικής γλώσσας η επέκταση μιας [redacted]



$y =$

0.2: σκέψης
0.25: πρότασης
0.3: ιδέας
0.001: γάτας
...
...
...
...

Για την εκπαίδευση μεγάλων γλωσσικών μοντέλων
πάλι χρησιμοποιούμε την ίδια απώλεια: Cross
Entropy Loss / Negative Log Likelihood Loss

Maximum Likelihood & Παλινδρόμηση



Παλινδρόμηση

$$y = \beta^T x + \epsilon, \quad \epsilon \sim N(0, \sigma^2)$$

$$\text{Μοντέλο: } x \rightarrow \hat{y} = \hat{\beta}^T x$$

$$\text{Likelihood: } (y - \hat{\beta}^T x) \sim N(0, \sigma^2) \propto \exp\left(-\left(\frac{y - \hat{\beta}^T x}{\sigma^2}\right)^2\right)$$

$$\text{-log Likelihood: } \left(\frac{y - \hat{\beta}^T x}{\sigma^2}\right)^2$$

$$\text{Loss}(\mathbf{y}, \hat{\mathbf{y}}) = (\mathbf{y} - \hat{\mathbf{y}})^2$$

Maximum Likelihood & Παλινδρόμηση



Παλινδρόμηση

Αρχή Μέγιστης Πιθανοφάνειας (Maximum Likelihood)

(Λογιστική) Παλινδρόμηση: καλό μοντέλο \rightarrow μεγάλη πιθανοφάνεια

$$Loss(\mathbf{y}, \hat{\mathbf{y}}) = (\mathbf{y} - \hat{\mathbf{y}})^2$$

Maximum Likelihood & Λογιστική Παλινδρόμηση



Λογιστική Παλινδρόμηση

$$y = 0 \text{ ή } y = 1 \rightarrow y = \begin{pmatrix} 1 \\ 0 \end{pmatrix} \text{ ή } y = \begin{pmatrix} 0 \\ 1 \end{pmatrix}$$

$$x \rightarrow \beta^\top x \rightarrow \text{softmax}(\beta^\top x) = \begin{pmatrix} \hat{p}_1 \\ \hat{p}_2 \end{pmatrix} = \begin{pmatrix} \hat{p} \\ 1 - \hat{p} \end{pmatrix} = \begin{pmatrix} \frac{\exp(-\beta^\top x)}{1 - \exp(-\beta^\top x)} \\ \frac{1}{1 - \exp(-\beta^\top x)} \end{pmatrix}$$

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



Maximum Likelihood & Λογιστική Παλινδρόμηση



Πιθανοφάνεια (Likelihood)
Λογιστική Παλινδρόμηση

$$y = 0 \text{ ή } y = 1: \begin{pmatrix} y \\ 1 - y \end{pmatrix}$$

$$x \rightarrow \beta^T x \rightarrow \text{Likelihood: } y = \begin{pmatrix} \hat{p}_1 \\ \hat{p}_2 \end{pmatrix}$$

$$\hat{p}^y (1 - \hat{p})^{1-y}$$

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

- log Likelihood: $-(y \log \hat{p} + (1 - y) \log(1 - \hat{p}))$

Η απώλεια της Λογιστικής Παλινδρόμησης είναι ακριβώς το
- Log Likelihood



Maximum Likelihood & Λογιστική Παλινδρόμηση

Παράδειγμα με 3 δεδομένα: $(x_1, y_1 = 1), (x_2, y_2 = 0), (x_3, y_3 = 0)$

Μοντέλο: $x_1 \rightarrow \begin{pmatrix} \hat{p}_1 \\ 1 - \hat{p}_1 \end{pmatrix}, x_2 \rightarrow \begin{pmatrix} \hat{p}_2 \\ 1 - \hat{p}_2 \end{pmatrix}, x_3 \rightarrow \begin{pmatrix} \hat{p}_3 \\ 1 - \hat{p}_3 \end{pmatrix}$

$y_1 = \begin{pmatrix} 1 \\ 0 \end{pmatrix}, y_2 = \begin{pmatrix} 0 \\ 1 \end{pmatrix}, y_3 = \begin{pmatrix} 0 \\ 1 \end{pmatrix}$

Πιθανοφάνεια σύμφωνα με το μοντέλο μας: $\hat{p}_1 \cdot (1 - \hat{p}_2) \cdot (1 - \hat{p}_3)$

Καλό μοντέλο → μεγάλη πιθανοφάνεια

Maximum Likelihood & Λογιστική Παλινδρόμηση

Καλό μοντέλο → μεγάλη πιθανοφάνεια

Παράδειγμα: $(x_1, y_1 = 1), (x_2, y_2 = 0), (x_3, y_3 = 0)$

Μοντέλο: $\hat{p}_1, \hat{p}_2, \hat{p}_3$
Πιθανοφάνεια (Likelihood): $\hat{p}_1 \cdot (1 - \hat{p}_2) \cdot (1 - \hat{p}_3)$

$y_1 = \begin{pmatrix} 1 \\ 0 \end{pmatrix}, y_2 = \begin{pmatrix} 0 \\ 1 \end{pmatrix}, y_3 = \begin{pmatrix} 0 \\ 1 \end{pmatrix}$
-Log Likelihood: $-(\log \hat{p}_1 + \log(1 - \hat{p}_2) + \log(1 - \hat{p}_3))$
 $= -(\log \hat{p}_1 + \log(1 - \hat{p}_2) + \log(1 - \hat{p}_3))$

Πιθανοφάνεια $= \hat{p}_1 \cdot (1 - \hat{p}_2) \cdot (1 - \hat{p}_3)$
 $= - (y_1 \log \hat{p}_1 + (1 - y_1) \log(1 - \hat{p}_1) + y_2 \log \hat{p}_2 + (1 - y_2) \log(1 - \hat{p}_2) + y_3 \log \hat{p}_3 + (1 - y_3) \log(1 - \hat{p}_3))$

Καλό μοντέλο → μεγάλη πιθανοφάνεια

$+y_3 \log \hat{p}_3 + (1 - y_3) \log(1 - \hat{p}_3)$

Maximum Likelihood & Λογιστική Παλινδρόμηση

Καλό μοντέλο → μεγάλη πιθανοφάνεια

Παράδειγμα: Λογιστική Παλινδρόμηση $(x_1, y_1 = 1), (x_2, y_2 = 0), (x_3, y_3 = 0)$

$$y_1 = 1, y_2 = 0, y_3 = 0$$

$$\sum_i - \left(y_i \log \frac{\exp(\beta^\top x_i)}{1 + \exp(\beta^\top x_i)} + (1 - y_i) \frac{1}{1 + \exp(\beta^\top x_i)} \right)$$

$$+ y_3 \log \hat{p}_3 + (1 - y_3) \log(1 - \hat{p}_3)$$