

MAI4CAREU

Master programmes in Artificial
Intelligence 4 Careers in Europe



Πανεπιστήμιο Κύπρου - Τεχνητή Νοημοσύνη

MAI612 - ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ


Διάλεξη 3: Παλινδρόμηση

Βασίλης Βασιλειάδης, PhD

Χειμερινό Εξάμηνο 2022-2023



CYENS
CENTRE OF EXCELLENCE



MAI4CAREU

Master programmes in Artificial
Intelligence 4 Careers in Europe



Επανάληψη





Διάλεξη 3: Παλινδρόμηση

Μαθησιακά αποτελέσματα

Θα καταλάβετε:

1. Το πρόβλημα της «παλινδρόμησης» στην επιβλεπόμενη μάθηση
2. Το μοντέλο παλινδρόμησης των k - κοντινών γειτόνων
3. Το μοντέλο γραμμικής παλινδρόμησης
4. Κάθοδος κλίσης για την εύρεση των παραμέτρων του μοντέλου γραμμικής παλινδρόμησης
5. Η αναλυτική λύση στο μοντέλο γραμμικής παλινδρόμησης





Επιβλεπόμενη Μάθηση

Παρουσιάζουμε μια συμβολή στο σύστημα: ο «δάσκαλος» παρέχει την έξοδο «στόχο»

Το σύστημα προσπαθεί να ταιριάξει τις προβλέψεις του με τις προβλεπόμενες προβλέψεις

- Για παράδειγμα: εικόνες από γάτες και σκύλους με την αντίστοιχη ετικέτα τους

Στόχος: Χρησιμοποιήστε δεδομένα για να δημιουργήσετε ένα μοντέλο που γενικεύει σε

άγνωστα ζεύγη εισόδου-εξόδου

Δύο κοινά προβλήματα:

1. **Παλινδρόμηση** - Έξοδος: συνεχής αξία
2. **Ταξινόμηση** - Έξοδος: διακριτή τιμή



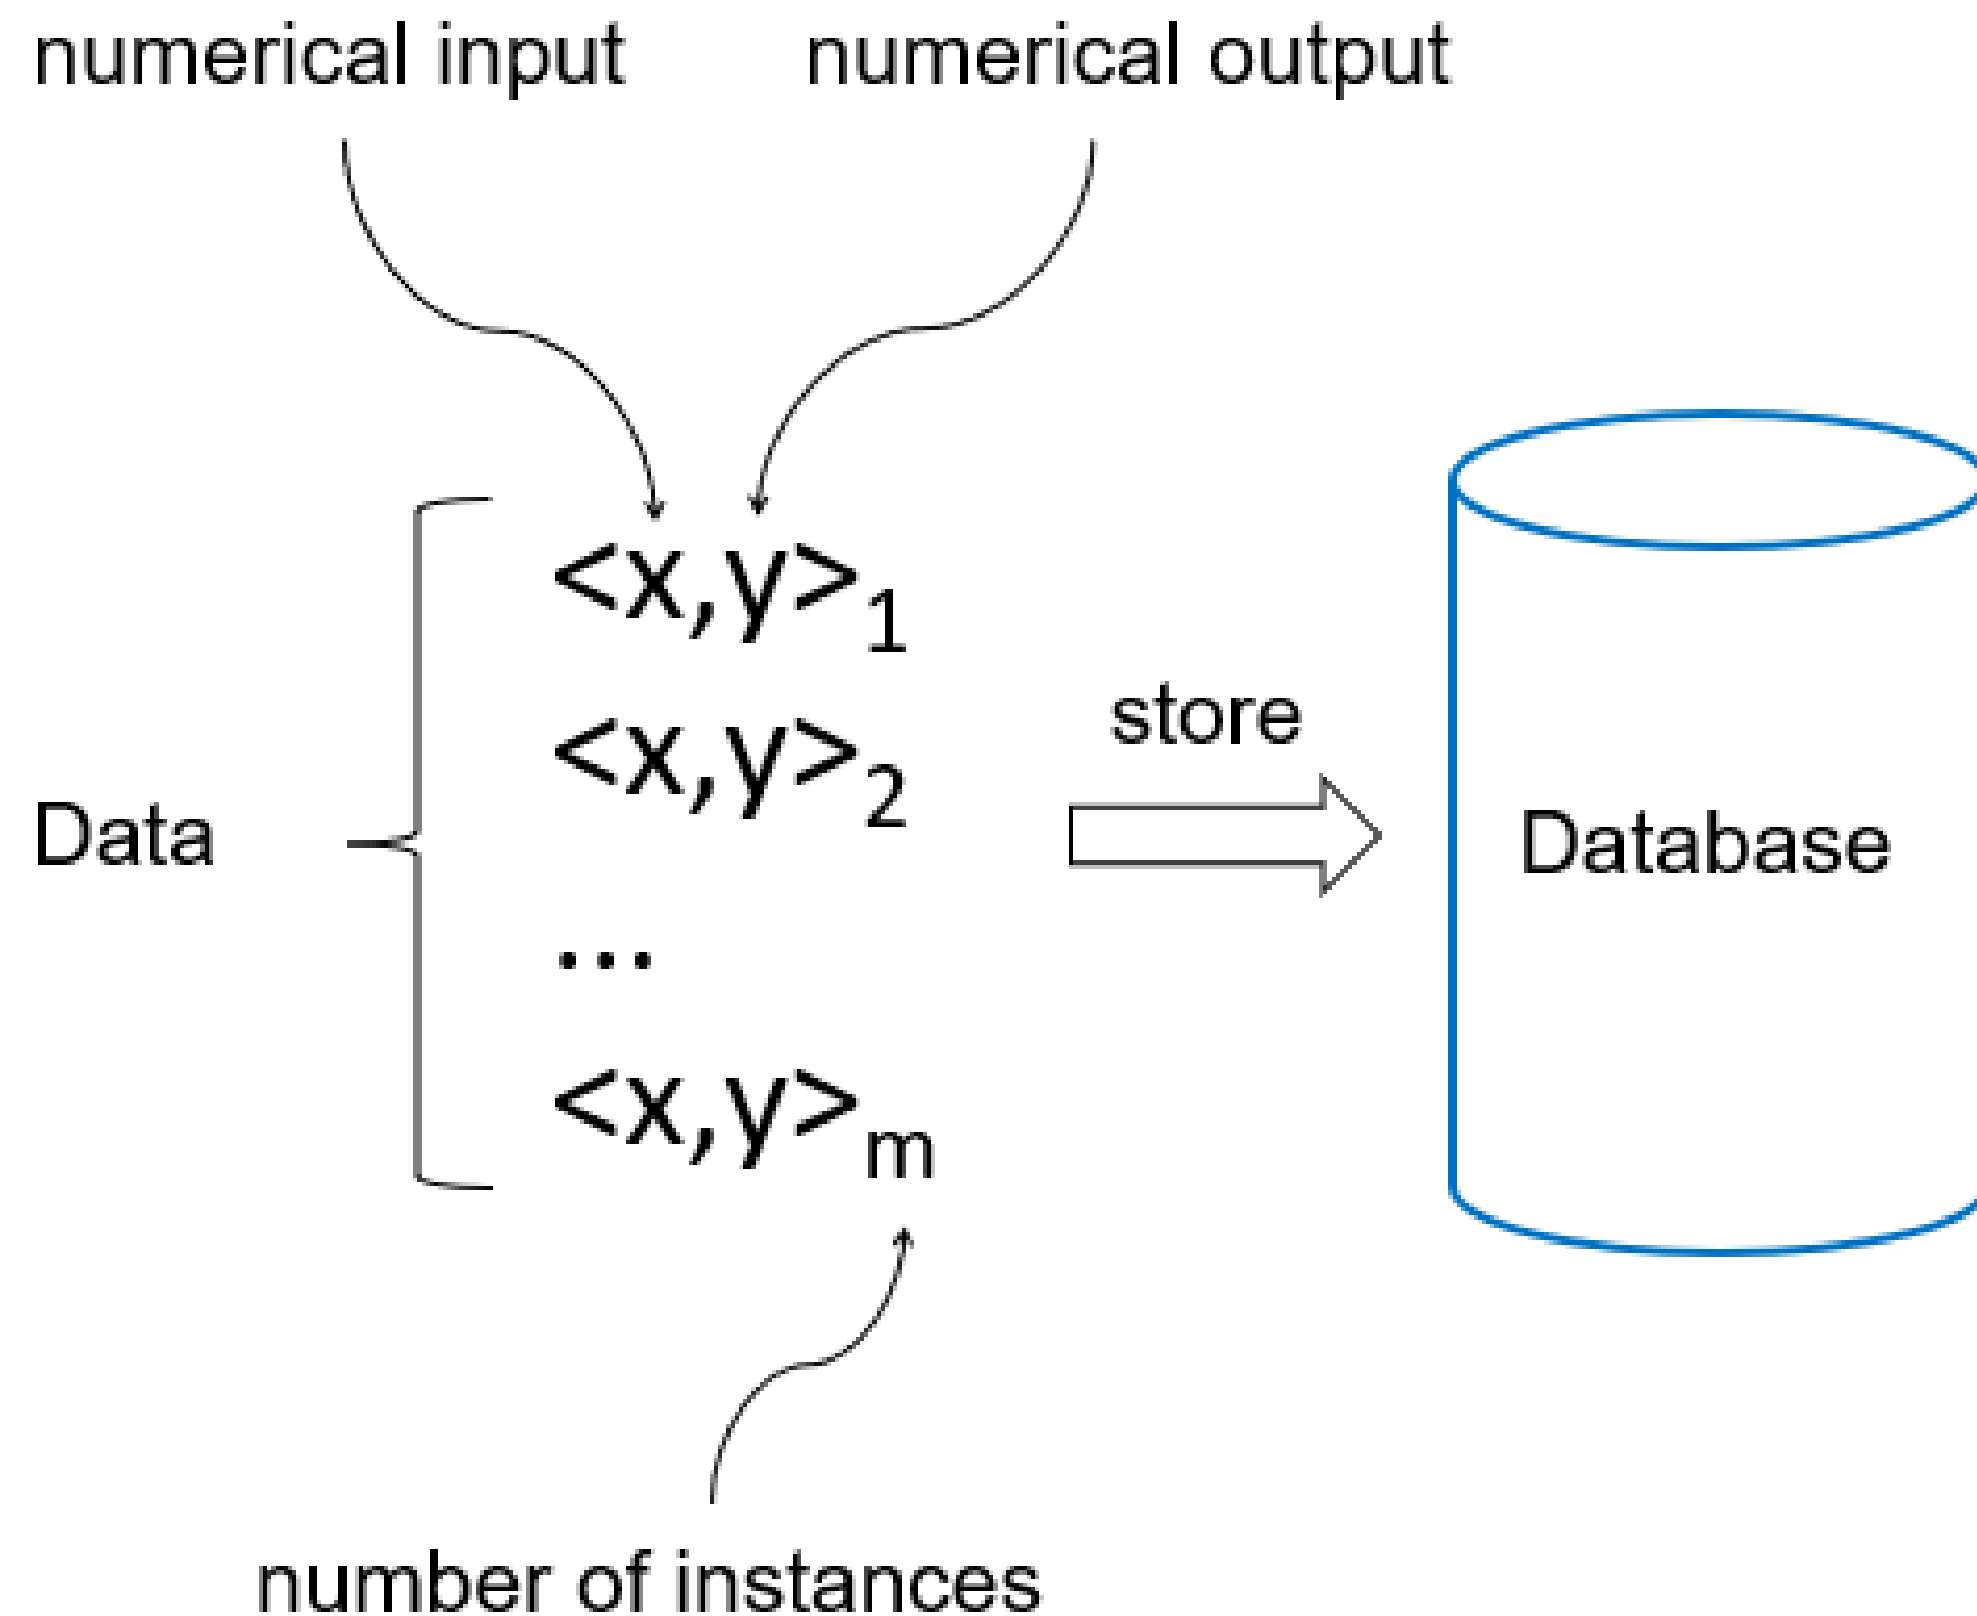
Cat



Dog



Παλινδρόμηση



Ποια είναι η τιμή του y δοθέντος x ;

$Y = \text{ανάλυση}(x)$

$Y = f[\text{γείτονες}(x)]$

Χαρακτηριστικά γνωρίσματα:

- + απλό
- + γρήγορο
- + θυμάται

Μειονεκτήματα:

- Δεν γενικεύει






Παλινδρόμηση με Κ-Κοντινότερο γείτονα





Παλινδρόμηση με Κ-Κοντινότερο γείτονα




ΠΗΓΗ





Παλινδρόμηση με Κ-Κοντινότερο γείτονα




ΠΗΓΗ





Παλινδρόμηση με Κ-Κοντινότερο γείτονα

ΠΗΓΗ




$K = 3$





Παλινδρόμηση με Κ-Κοντινότερο γείτονα

ΠΗΓΗ




$K = 3$





Παλινδρόμηση με Κ-Κοντινότερο γείτονα




$K = 3$





Παλινδρόμηση με Κ-Κοντινότερο γείτονα

ΠΗΓΗ




$K = 3$





Παλινδρόμηση με Κ-Κοντινότερο γείτονα



$K = 1$


Το μοντέλο καταγράφει τις
μικρές διαφορές και το θόρυβο
αντί για την τάση

Αυτό είναι γνωστό ως
υπερπροσαρμογή





Παλινδρόμηση με Κ-Κοντινότερο γείτονα



$K = 10$

Ομαλότερη πρόβλεψη, αλλά
πρόβλημα στις άκρες


Κι αν $K=m$;





Παλινδρόμηση με Κ-Κοντινότερο γείτονα

ΠΗΓΗ



$K = 3$





Παλινδρόμηση με Κ-Κοντινότερο γείτονα

Προτερήματα

- εύκολη στην υλοποίηση
- δεν υπάρχει χρόνος εκμάθησης
- Μπορεί να χειριστεί μη γραμμικότητα

Αδυναμίες

- η πρόβλεψη γίνεται πιο αργή καθώς τα δεδομένα γίνονται περισσότερα
- δεν λειτουργεί καλά σε μεγάλες διαστάσεις
- χρειάζεται κανικοποίηση χαρακτηριστικών
- ευαίσθητα σε θορυβώδη δεδομένα ή ακραίες τιμές
- έλλειψη ερμηνευσιμότητας





Παράδειγμα

```
In [1]: X = [[0], [1], [2], [3]]
      ...: y = [0, 0, 1, 1]


In [2]: from sklearn.neighbors import KNeighborsRegressor
      ...: neigh = KNeighborsRegressor(n_neighbors=2)
      ...: neigh.fit(X, y)
Out[2]:
KNeighborsRegressor(algorithm='auto', leaf_size=30, metric='minkowski',
                    metric_params=None, n_jobs=None, n_neighbors=2, p=2,
                    weights='uniform')

In [3]: print(neigh.predict([[1.5]]))
[0.5]
```






Παλινδρόμηση



Εναλλακτική προσέγγιση





Ποια είναι η απλούστερη συνάρτηση που μπορούμε να χρησιμοποιήσουμε;

Μάθηση με βάση την περίπτωση / μάθηση με βάση τη μνήμη
 ή
 Μη παραμετρικά μοντέλα / παραδειγματικά μοντέλα





Παλινδρόμηση




Μάθηση με βάση την περίπτωση / μάθηση με βάση τη μνήμη
ή
Μη παραμετρικά μοντέλα / υποδειγματικά μοντέλα

Μάθηση με βάση το μοντέλο
ή
Παραμετρικά μοντέλα






Γραμμική παλινδρόμηση




$$y = \alpha x + \beta$$

$$\alpha=0$$
$$y=\beta$$

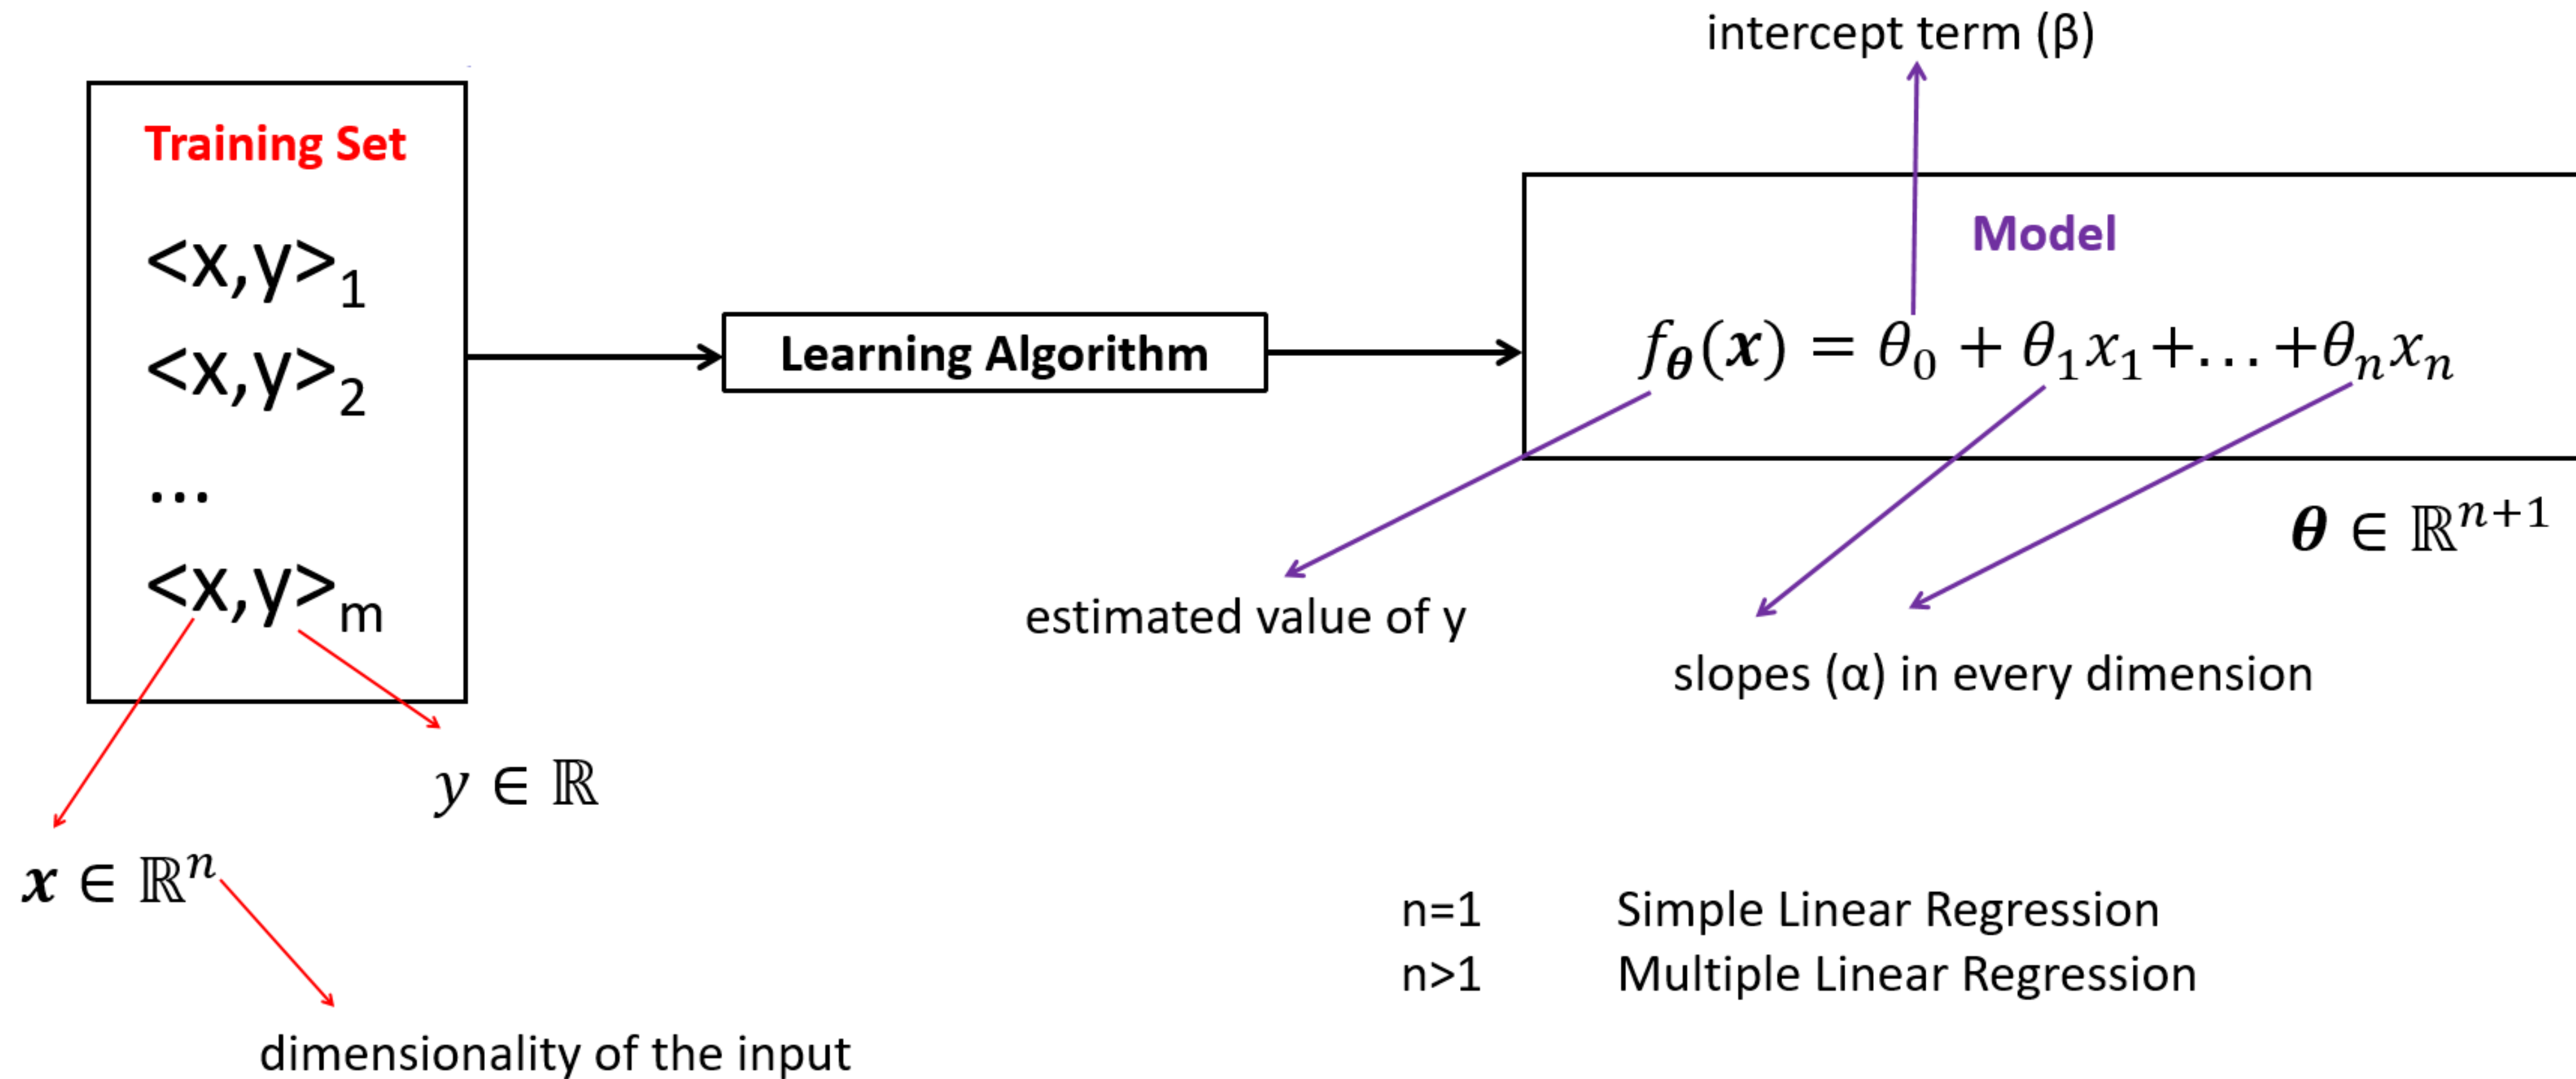


$$\beta=0$$
$$y=\alpha x$$





Αναπαράσταση Μοντέλου





Αναπαράσταση Μοντέλου

$$f_{\theta}(\mathbf{x}) = \theta_0 + \theta_1 x_1 + \dots + \theta_n x_n$$

$$f_{\theta}(\mathbf{x}) = \theta_0 x_0 + \theta_1 x_1 + \dots + \theta_n x_n$$

όπου $x_0 = 1$, έτσι τώρα $\mathbf{x} \in \mathbb{R}^{n+1}$

$$f_{\theta}(\mathbf{x}) = \boldsymbol{\theta}^T \mathbf{x}$$

$$[\theta_0 \quad \theta_1 \quad \dots \quad \theta_n] \cdot \begin{bmatrix} x_0 \\ x_1 \\ \vdots \\ x_n \end{bmatrix} = f_{\theta}(\mathbf{x})$$





Στόχος

Επιλέξτε $\theta_0, \dots, \theta_n$ έτσι ώστε το $f_{\theta}(\mathbf{x})$ να είναι **κοντά** το y σε **όλα** τα εκπαιδευτικά παραδείγματα μας $\langle \mathbf{x}, y \rangle_{1:m}$

Πώς;

Μια κοινή προσέγγιση είναι η χρήση της μεθόδου των **ελάχιστων τετραγώνων**

- Ελαχιστοποιήστε το **άθροισμα των τετραγώνων των υπολοίπων**
- **Υπόλοιπα**: διαφορά μεταξύ της πραγματικής τιμής (y) και της εκτιμώμενης τιμής (που $f_{\theta}(\mathbf{x})$ τοποθετείται από το μοντέλο)

$$(f_{\theta}(\mathbf{x}^{(i)}) - y^{(i)})^2$$





Στόχος και συνάρτηση σφάλματος

Επιλέξτε $\theta_0, \dots, \theta_n$ έτσι ώστε το $f_{\theta}(\mathbf{x})$ να είναι **κοντά** το y σε **όλα** τα εκπαιδευτικά παραδείγματα μας $\langle \mathbf{x}, y \rangle_{1:m}$

$$\underset{\theta}{\text{minimize}} L(\theta)$$

$$L(\theta) = \frac{1}{2m} \sum_{i=1}^m (f_{\theta}(\mathbf{x}^{(i)}) - y^{(i)})^2$$

Συνάρτηση μέσου τετραγωνικού σφάλματος


Μπορεί το σφάλμα να είναι < 0 ;






Συνάρτηση σφάλματος

$$f_{\theta_1}(x)$$



$$L(\theta_1)$$





Gradient Descent






Βελτιστοποίηση: Gradient Descent

1. Ξεκινήστε από τυχαίο θ_1

2. Επαναλάβετε μέχρι τη σύγκλιση



Αλλαγή θ_1 έτσι ώστε να κινηθεί προς τα **κάτω**

$$\theta_1 = \theta_1 - \alpha \frac{dL(\theta_1)}{d\theta_1} \quad \alpha \in [0,1]$$

$\frac{dL(\theta_1)}{d\theta_1} > 0$ μειώσεις θ_1

$\frac{dL(\theta_1)}{d\theta_1} < 0$ αυξήσεις θ_1


Εδώ θέλουμε να καταλήξουμε (τοπικό ελάχιστο)






Gradient Descent: ρυθμός εκμάθησης α

πολύ μικρό



αργή σύγκλιση

πολύ μεγάλο





πιθανή απόκλιση





Gradient Descent

minimize $L(\theta_1)$
 θ_1





[ΠΗΓΗ](#)





Gradient Descent

$$\underset{\theta_0, \theta_1}{\text{minimize}} L(\theta_0, \theta_1)$$



[ΠΗΓΗ](#)





Gradient Descent στην πράξη

Υλοποίηση:

Επαναλάβετε μέχρι τη σύγκλιση:

1. Υπολογίστε το σφάλμα

$$L(\theta_0, \theta_1)$$

$$\|\nabla L\| < \varepsilon$$

2. Υπολογισμός διανύσματος κλίσης

$$\begin{bmatrix} \frac{\partial L(\theta_0, \theta_1)}{\partial \theta_0} \\ \frac{\partial L(\theta_0, \theta_1)}{\partial \theta_1} \end{bmatrix}$$

$$\frac{1}{m} \sum_{i=1}^m (f_{\theta_0, \theta_1}(x^{(i)}) - y^{(i)})$$

3. Ενημέρωση διανύσματος παραμέτρων

$$\begin{bmatrix} \theta_0 \\ \theta_1 \end{bmatrix} = \begin{bmatrix} \theta_0 - \alpha \frac{\partial L(\theta_0, \theta_1)}{\partial \theta_0} \\ \theta_1 - \alpha \frac{\partial L(\theta_0, \theta_1)}{\partial \theta_1} \end{bmatrix}$$

$$\frac{1}{m} \sum_{i=1}^m (f_{\theta_0, \theta_1}(x^{(i)}) - y^{(i)}) x^{(i)}$$

$$f_{\theta_0, \theta_1}(x) = \theta_0 + \theta_1 x$$

$$L(\theta_0, \theta_1) = \frac{1}{2m} \sum_{i=1}^m (f_{\theta_0, \theta_1}(x^{(i)}) - y^{(i)})^2$$





Gradient Descent στην πράξη

Gradient Descent «παρτίδας»:

- Χρησιμοποιεί όλα τα παραδείγματα κατάρτισης (m)
- Χρησιμοποιείται όταν το μέγεθος του συνόλου εκπαίδευσης είναι μικρό (π.χ. $m = 10^1 — 10^3$)

Άλλες παραλλαγές του Gradient Descent:

- Στοχαστικό Gradient Descent
- Gradient Descent μίνι παρτίδων
- Θα τα δούμε σε μεταγενέστερες διαλέξεις





Gradient Descent στην πράξη

Χρήση κανονικοποίησης χαρακτηριστικών

Βεβαιωθείτε ότι τα χαρακτηριστικά είναι σε

παρόμοια κλίμακα

Παράδειγμα:

x_1 = μέγεθος (0-2000 πόδια²)

x_2 = αριθμός υπνοδωματίων (1-5)

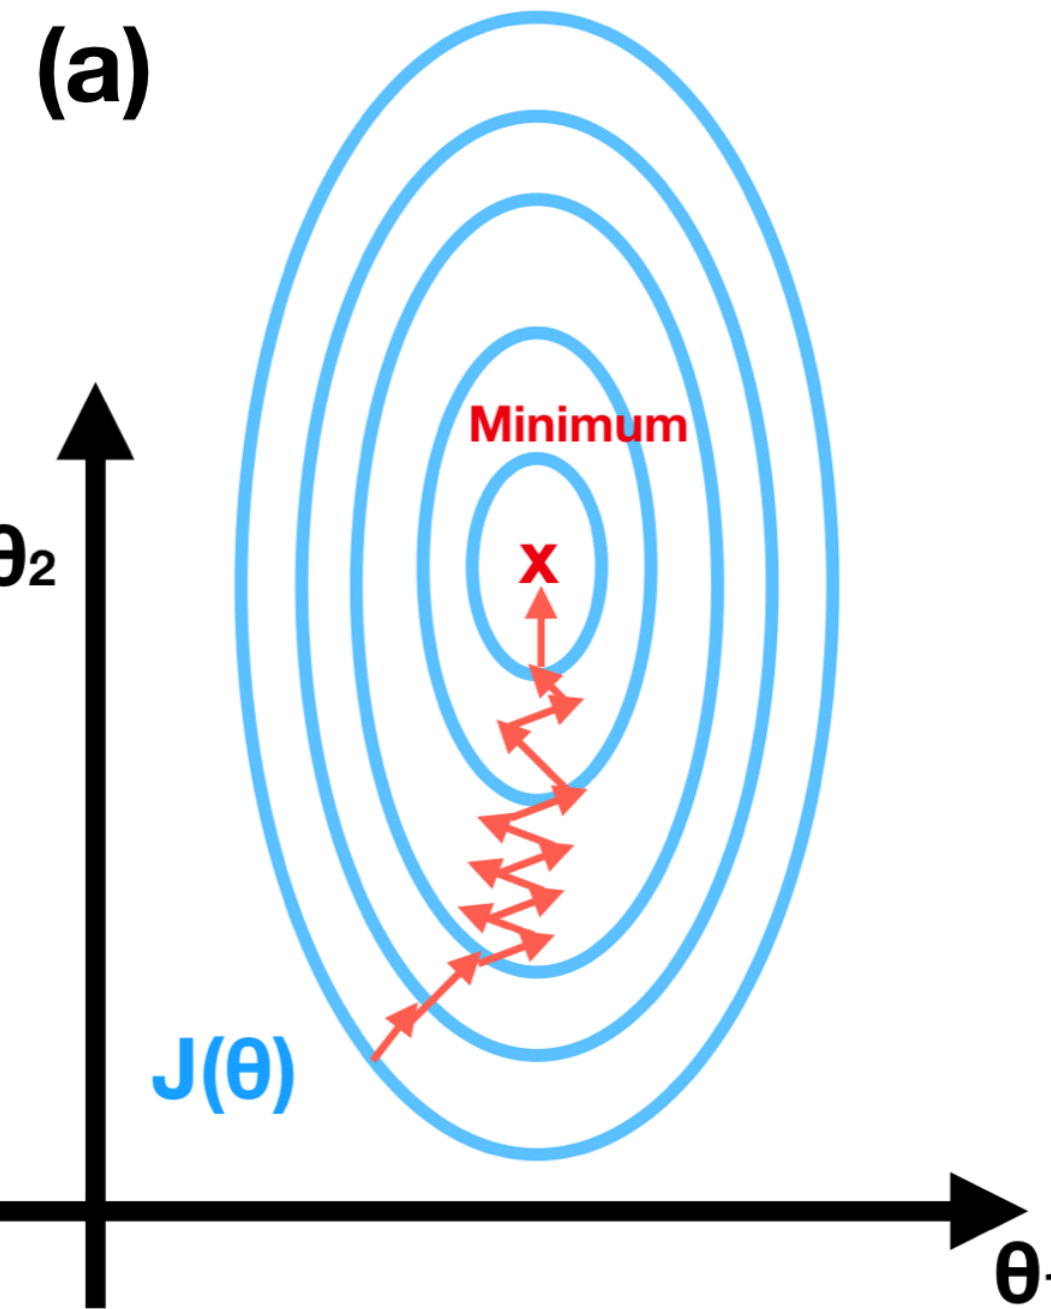
$new_x_1 = x_1 / 2000$

$new_x_1 \in [0,1]$

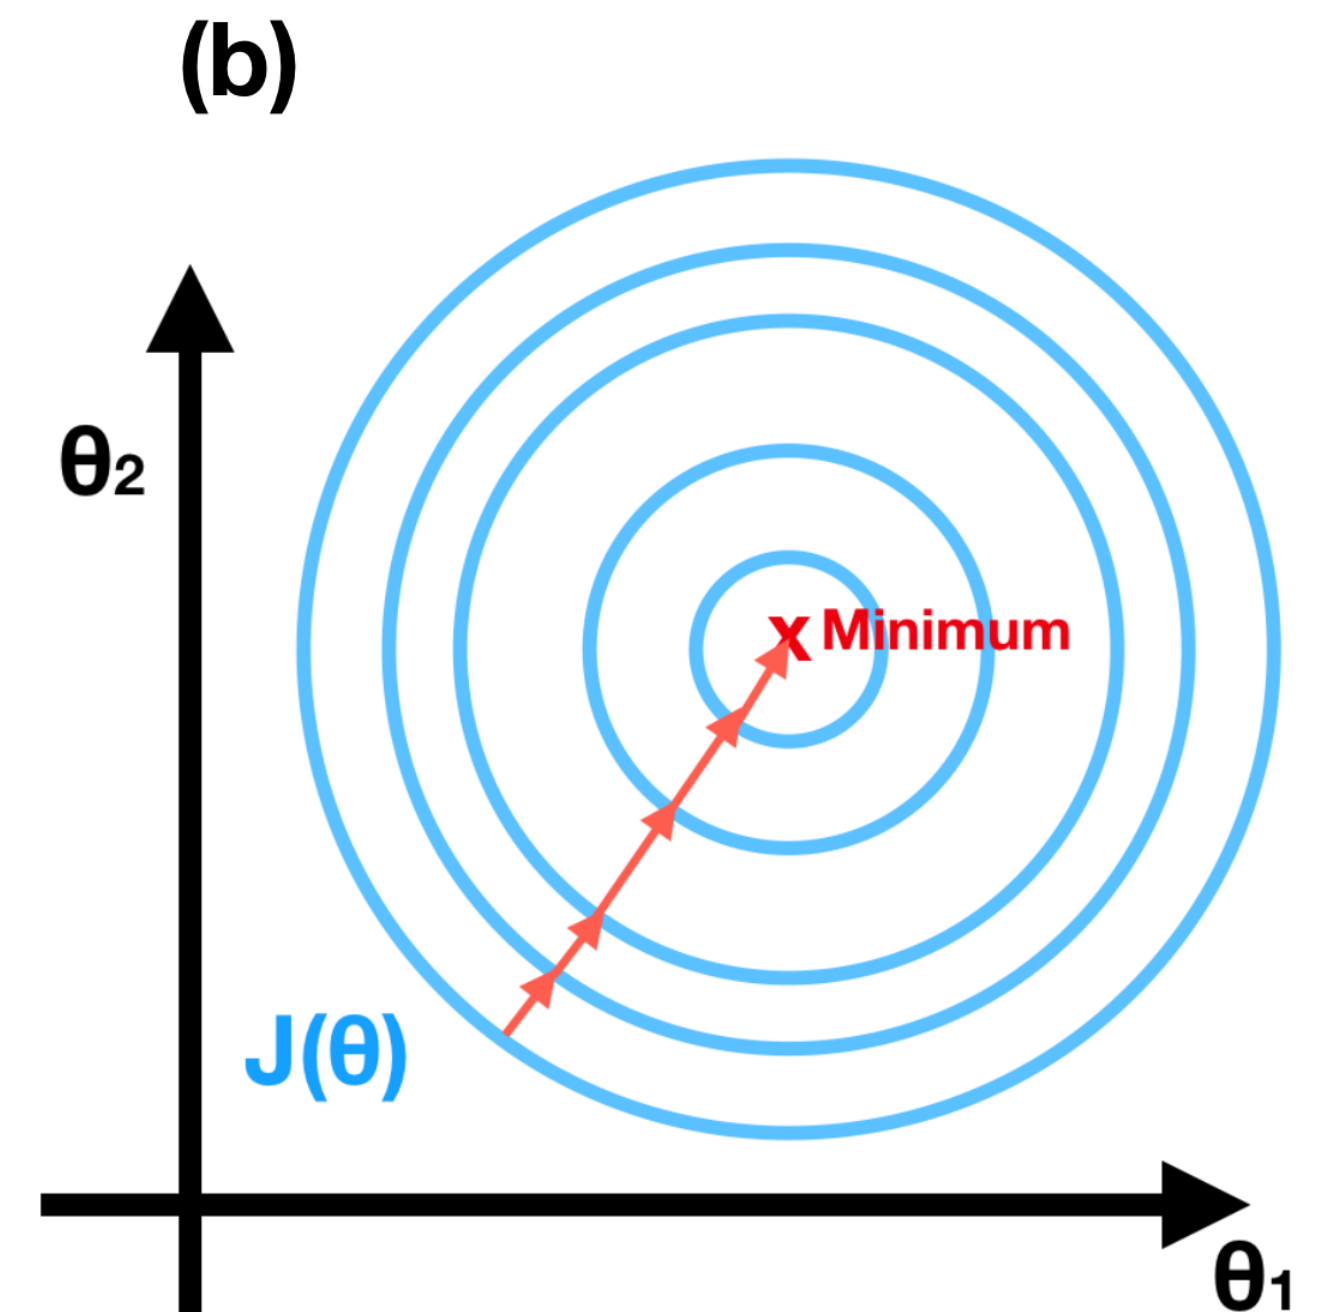
$new_x_2 = x_2 / 5$

$new_x_2 \in [0,1]$

Χωρίς κανονικοποίηση
χαρακτηριστικών






Με κανονικοποίηση
χαρακτηριστικών





Gradient Descent σε μια μη κυρτή 2D συνάρτηση

More than one local minimum



[ΠΗΓΗ](#)





Gradient Descent στο μέσο τετραγωνικό σφάλμα

Το ΜΤΣ όταν χρησιμοποιείται το γραμμικό μοντέλο παλινδρόμησης έχει περισσότερα από ένα ελάχιστα;

- Όχι — ένα ενιαίο παγκόσμιο ελάχιστο

Για τη συγκεκριμένη περίπτωση, υπάρχει μια αναλυτική (κλειστή μορφή/μη-δραστική) λύση.





Αναλυτική λύση: Κανονικές εξισώσεις

$$\theta_0 + \theta_1 x_1 + \dots + \theta_n x_n \approx y$$

x	y
$x^{(1)}$	$y^{(1)}$
$x^{(2)}$	$y^{(2)}$
...	...
$x^{(m)}$	$y^{(m)}$

$$\underbrace{\begin{bmatrix} 1 & x_1^{(1)} & \dots & x_n^{(1)} \\ 1 & x_1^{(2)} & \dots & x_n^{(2)} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_1^{(m)} & \dots & x_n^{(m)} \end{bmatrix}}_X \underbrace{\begin{bmatrix} \theta_0 \\ \theta_1 \\ \vdots \\ \theta_n \end{bmatrix}}_\theta \approx \underbrace{\begin{bmatrix} y^{(1)} \\ y^{(2)} \\ \vdots \\ y^{(m)} \end{bmatrix}}_y$$

$$\theta = (X^T X)^{-1} X^T y$$

Σημαντικό: $m > n$





Παράδειγμα

```
In [1]: import numpy as np
...: from sklearn.linear_model import LinearRegression
...: X = np.array([[1, 1], [1, 2], [2, 2], [2, 3]])

In [2]: #  $y = 1 * x_0 + 2 * x_1 + 3$ 
...: y = np.dot(X, np.array([1, 2])) + 3
...: reg = LinearRegression().fit(X, y)

In [3]: reg.score(X, y)
Out[3]: 1.0

In [4]: reg.coef_
Out[4]: array([1., 2.])

In [5]: reg.intercept_
Out[5]: 3.000000000000000018

In [6]: reg.predict(np.array([[3, 5]]))
Out[6]: array([16.])
```





Γραμμική παλινδρόμηση

Θετικά

- εύκολο στην υλοποίηση (αναλυτική λύση)
- μικρός χρόνος υπολογισμού για την προσαρμογή (αναλυτικό διάλυμα)
- σταθερός χρόνος πρόβλεψης (δεν αποθηκεύει σημεία δεδομένων)
- η αναλυτική λύση δεν χρειάζεται κανονικοποίηση χαρακτηριστικών
- λιγότερο ευαίσθητα σε θορυβώδη δεδομένα
- πιο ερμηνεύσιμα

Αρνητικά

- Δεν μπορεί να χειριστεί μη γραμμικές σχέσεις στα δεδομένα
- για μεγάλα σύνολα δεδομένων απαιτεί επαναληπτικές μεθόδους, π.χ. gradient descent
- Το gradient descent χρειάζεται κανονικοποίηση χαρακτηριστικών





Γραμμική παλινδρόμηση

Θετικά

- εύκολο στην υλοποίηση (αναλυτική λύση)
- μικρός χρόνος υπολογισμού για την προσαρμογή (αναλυτικό διάλυμα)
- σταθερός χρόνος πρόβλεψης (δεν αποθηκεύει σημεία δεδομένων)
- η αναλυτική λύση δεν χρειάζεται κανονικοποίηση χαρακτηριστικών
- λιγότερο ευαίσθητα σε θορυβώδη δεδομένα
- πιο ερμηνευσιμα

Αρνητικά

- Δεν μπορεί να χειρίσκει μη γραμμικές σχέσεις στα δεδομένα
- για μεγάλα σύνολα δεδομένων απαιτεί επαναληπτικές μεθόδους, π.χ. gradient descent
- Το gradient descent χρειάζεται κανονικοποίηση χαρακτηριστικών

Πώς μπορούμε να το διορθώσουμε αυτό;

... χωρίς να αλλάξει ο αλγόριθμος;





Πολυωνυμική παλινδρόμηση

1. Χρήση της μηχανικής χαρακτηριστικών για την κατασκευή πολυωνυμικών χαρακτηριστικών

π.χ. για 2 μεταβλητές
και πολυωνυμικός βαθμός = 2 $x_1, x_2, x_1^2, x_2^2, x_1x_2$

2. Βρείτε τη λύση στο νέο πρόβλημα γραμμικής παλινδρόμησης

$$\theta_0 + \theta_1 x_1 + \theta_2 x_2 + \theta_3 x_1^2 + \theta_4 x_2^2 + \theta_5 x_1 x_2 \approx y$$

$$\theta = (X^T X)^{-1} X^T y$$



MAI4CAREU

Master programmes in Artificial
Intelligence 4 Careers in Europe



Σας ευχαριστούμε

