

Χεμπιανά μοντέλα μάθησης

Κώστας Διαμαντάρας
Τμήμα Πληροφορικής
ΤΕΙ Θεσσαλονίκης


Ο Κανόνας του Hebb

Donald O. Hebb, *Organization of Behavior* (1949)

- Όταν ο άξονας ενός νευρώνα A είναι αρκετά κοντά ώστε να διεγείρει το νευρώνα B και συστηματικά συμμετέχει στην ενεργοποίησή του, τότε κάποια μεταβολική αλλαγή συμβαίνει είτε στο ένα απ' τα δύο είτε και στα δύο κύτταρα έτσι ώστε η αποτελεσματικότητα με την οποία ο A διεγείρει τον B αυξάνεται.

Ο Κανόνας του Hebb

- Αύξησε το συναπτικό βάρος της σύνδεσης μεταξύ του νευρώνα A και του νευρώνα B ανάλογα με το γινόμενο των εξόδων τους:



Χεμπιανή μάθηση και στατιστική ανάλυση

- Κανόνας του Hebb → Ανάλυση Κυρίων Συνιστωσών (Principal Component Analysis – PCA)
- PCA → Βέλτιστη εξαγωγή γραμμικών χαρακτηριστικών
- Συμπύεση πληροφορίας
- PCA = γνωστή και κλασσική στατιστική μέθοδος

Στατιστική παρατήρηση

Διάνυσμα παρατήρησης n διαστάσεις:

$$\mathbf{x} = [x_1, \dots, x_n]^T$$

$x_1, \dots, x_n =$ τυχαίες μεταβλητές

Διάνυσμα χαρακτηριστικών m διαστάσεις:

$$\mathbf{y} = [y_1, \dots, y_m]^T$$

$y_1, \dots, y_m =$ τυχαίες μεταβλητές (κρυμμένες, όχι άμεσα παρατηρήσιμες)

$$m < n$$

Γενικό μοντέλο χαρακτηριστικών

- $m < n$
- υπάρχουν συναρτήσεις $f_1(), \dots, f_n()$ ώστε

$$x_1 = f_1(y_1, \dots, y_m) = f_1(\mathbf{y})$$

⋮


$$x_n = f_n(y_1, \dots, y_m) = f_n(\mathbf{y})$$

Διάσταση διανύσματος παρατήρησης

- Επιφανειακή διάσταση = n
- Ουσιαστική διάσταση = m

$$n = 2$$

$$m = 1$$



$$x_1 = f_1(\mathbf{y})$$

$$x_2 = f_2(\mathbf{y})$$


Γραμμικό μοντέλο χαρακτηριστικών

- Ειδική περίπτωση

$$n = 2$$

$$m = 1$$

ή απλώς



$$x_1 = f_1 \times y$$

$$x_2 = f_2 \times y$$

$$x_1 = \mathbf{f}_1^T \mathbf{y}$$

⋮

$$x_n = \mathbf{f}_n^T \mathbf{y}$$

$$\mathbf{x} = \mathbf{F}\mathbf{y}$$

Ιδιότητες διανύσματος παρατήρησης ($m < n$)

- Παρατηρήσεις συσχετισμένες.

Πχ. $m=1, n=2,$

$f_1, f_2 =$ βαθμωτοί αριθμοί

$$x_1 = f_1 y$$

$$x_2 = f_2 y$$

και άρα

$$x_2 = (f_2/f_1)x_1$$


Πώς βρίσκω τα χαρακτηριστικά;

- Αν δεν γνωρίζω το \mathbf{F}
 - Ανάλυση ιδιοτιμών του $\mathbf{R}_x = E\{\mathbf{x}\mathbf{x}^T\}$
$$\mathbf{R}_x \mathbf{e}_i = \lambda_i \mathbf{e}_i$$
 - $\mathbf{e}_1, \dots, \mathbf{e}_n$ αντιστοιχούν σε $\lambda_1 > \dots > \lambda_n$
 - Θέτω $\mathbf{U} = [\mathbf{e}_1, \dots, \mathbf{e}_m]$

$$\mathbf{y}' = \mathbf{U}^T \mathbf{x}$$

Παράδειγμα PCA

- Ο κύριος άξονας
 - έχει την μεγαλύτερη στατιστική διασπορά
 - περιέχει την περισσότερη πληροφορία για το σήμα
 - έχει το μικρότερο σφάλμα προσέγγισης



Ορισμοί

- \mathbf{e}_i : i κύριο ιδιοδιάνυσμα
- $y_i = \mathbf{e}_i^T \mathbf{x}$: i κύρια συνιστώσα (ΚΣ)
- Μετασχηματισμός Karhunen-Loeve (KLT)

$$\mathbf{z} = \mathbf{U}\mathbf{x}$$

Ιδιότητες

- Τα κύρια ιδιοδιανύσματα είναι ορθογώνια
- Οι κύριες συνιστώσες (ΚΣ) είναι ασυσχέτιστες
- Η διασπορά της i ΚΣ είναι λ_i


Εφαρμογή: Εξαγωγή χαρακτηριστικών: Βιομετρικά δεδομένα χελώνας

- x_1 = μήκος καυκάλου
- x_2 = πλάτος καυκάλου
- x_3 = ύψος καυκάλου

Όλη σχεδόν η πληροφορία
στο γραμμικό συνδυασμό
 $0.813x_1 + 0.496x_2 + 0.307x_3$

	Κύρια Συνιστώσα		
Μεταβλητή	1	2	3
Μήκος	0.813	-0.545	-0.205
Πλάτος	0.496	0.832	-0.249
Ύψος	0.307	0.101	0.947
Διασπορά	680.4	6.5	2.9
Ποσοστό συνολικής διασποράς	98.6%	0.9%	0.4%

Εφαρμογή: συμπίεση δεδομένων



4




8




12

Εφαρμογή: Ομαδοποίηση δεδομένων (clustering)



PCA και γραμμικά Χεμπιανά μοντέλα



$$y = \sum w_i x_i = \mathbf{w}^T \mathbf{x}$$

Χεμπιανή μάθηση χωρίς περιορισμούς

$$\mathbf{w}(k+1) = \mathbf{w}(k) + \beta[y(k) \mathbf{x}(k)]$$

- Πρόβλημα σύγκλισης

$$\mathbf{w}(k) \rightarrow \infty$$

Χεμπιανή μάθηση με κανονικοποίηση


- Κανόνας του Oja (Oja1982)

$$\mathbf{w}(k+1) = \mathbf{w}(k) + \beta[y(k) \mathbf{x}(k) - y(k)^2 \mathbf{w}(k)]$$


$\mathbf{w}(k) \rightarrow \mathbf{e}_1 =$ κύριο ιδιοδιάνυσμα

$$||\mathbf{w}(k)|| \rightarrow 1$$

Σύγκλιση του κανόνα του Oja



Εξαγωγή πολλών κύριων συνιστωσών



Μοντέλο ΑΡΕΧ

Αλγόριθμος APEX

Σχέση εισόδου-εξόδου

$$y_i = \sum_j w_{ij} x_j - \sum_j c_{ij} y_j$$

Αλγόριθμος

$$w_{ij}(k+1) = w_{ij}(k) + \beta [y_i(k) x_j(k) - y_i(k)^2 w_{ij}(k)] \quad c_{ij}(k+1) = c_{ij}(k) + \beta [y_i(k) y_j(k) - y_i(k)^2 c_{ij}(k)]$$

Αλγόριθμος APEX

$\mathbf{w}_1(k) \rightarrow \mathbf{e}_1 =$ κύριο ιδιοδιάνυσμα

$\mathbf{w}_2(k) \rightarrow \mathbf{e}_2 =$ δεύτερο ιδιοδιάνυσμα

$\mathbf{w}_3(k) \rightarrow \mathbf{e}_3 =$ τρίτο ιδιοδιάνυσμα

.....

$||\mathbf{w}_1(k)||, ||\mathbf{w}_2(k)||, \dots, ||\mathbf{w}_m(k)|| \rightarrow 1$