



ΚΕΣ 03 – Αναγνώριση Προτύπων και Ανάλυση Εικόνας



Εκτίμηση άγνωστων κατανομών πιθανότητας

Τμήμα Επιστήμης και Τεχνολογίας
Τηλεπικοινωνιών

Πανεπιστήμιο Πελοποννήσου

- Εισαγωγή
- Παραμετρικές μέθοδοι
- Μη παραμετρικές μέθοδοι
- Ο απλοϊκός ταξινομητής Bayes
- Ο ταξινομητής k-NN

Περιεχόμενα – Βιβλιογραφία



→ Περιεχόμενα Ενότητας

- ◆ Εισαγωγή
- ◆ Παραμετρικές μέθοδοι εκτίμησης κατανομών πιθανότητας
- ◆ Μη παραμετρικές μέθοδοι
- ◆ Ο απλοϊκός ταξινομητής Bayes (Naïve Bayes Classifier)
- ◆ Ο ταξινομητής των k-πλησιέστερων γειτόνων (k-NN Classifier)

→ Βιβλιογραφία:

- ◆ Παπαμάρκος [2005]: Κεφάλαιο 7
- ◆ Duda [2004]: Chapter 3
- ◆ Theodoridis [2002]: Chapter 2
- ◆ Bow [2002]: Chapter 2

- ★ Εισαγωγή
- Παραμετρικές μέθοδοι
- Μη παραμετρικές μέθοδοι
- Ο απλοϊκός ταξινομητής Bayes
- Ο ταξινομητής k-NN

Εισαγωγή



- Η εφαρμογή της ταξινόμησης σύμφωνα με τον κανόνα του Bayes απαιτεί τη γνώση των κατανομών πιθανότητας $p(\underline{x}|\omega_i)$, $i = 1, 2, \dots, M$
 - Αν οι ανωτέρω κατανομές δεν είναι γνωστές πρέπει να εκτιμηθούν από ένα σύνολο διανυσμάτων $\{\underline{x}_1, \underline{x}_2, \dots, \underline{x}_N\}$ για τα οποία είναι γνωστές οι κλάσεις στις οποίες ανήκουν
- Υπάρχουν δύο βασικές κατηγορίες εκτίμησης κατανομών πιθανότητας:
 - **Παραμετρικές.** Η μορφή της συνάρτησης κατανομής (π.χ. Gaussian, Rayleigh, Poison) είναι γνωστή και χρειάζεται να εκτιμηθούν οι παράμετροι της
 - **Μη παραμετρικές.** Δεν υπάρχει καμία γνώση της μορφής της κατανομής. Αυτή απλά εκτιμάται από τα δεδομένα εκπαίδευσης

© 2007 Nicolas Tsapatsoulis

- ★ Εισαγωγή
- Παραμετρικές μέθοδοι
- Μη παραμετρικές μέθοδοι
- Ο απλοϊκός ταξινομητής Bayes
- Ο ταξινομητής k-NN

Κανόνας του Bayes



- Ο κανόνας ταξινόμησης του Bayes μας λέει:
 - Δεδομένου του \underline{x} ταξινόμησε το σύμφωνα με τον κανόνα:

$$P(\omega_i|\underline{x}) > P(\omega_j|\underline{x}) \quad \forall j \neq i$$

- όπου $P(\omega_i|\underline{x})$ είναι η εκ των υστέρων (a-posteriori) πιθανότητα το \underline{x} να ανήκει στην κλάση ω_i ,

$$P(\omega_i|\underline{x}) = \frac{p(\underline{x}|\omega_i)P(\omega_i)}{p(\underline{x})}$$

$$p(\underline{x}) = \sum_{i=1}^M p(\underline{x}|\omega_i)P(\omega_i)$$

© 2007 Nicolas Tsapatsoulis

- Εισαγωγή
- Παραμετρικές μέθοδοι
- Μη παραμετρικές μέθοδοι
- Ο απλοϊκός ταξινομητής Bayes
- Ο ταξινομητής k-NN

Παραμετρικές μέθοδοι



- Σε κάποιες περιπτώσεις η μορφή των κατανομών πιθανότητας είναι γνωστή και χρειάζεται απλά να εκτιμηθούν οι παράμετροι της κατανομής
 - Στην (πολυδιάστατη) κατανομή Gauss $N(\underline{\mu}, \Sigma)$ οι παράμετροι $\underline{\mu}, \Sigma$.
 - Στη μονοδιάστατη εκθετική κατανομή οι παράμετροι α, λ .
 - Στη πολυδιάστατη κατανομή Βερνουλί το διάνυσμα $\underline{\theta}$.
- Στις ανωτέρω περιπτώσεις η εκτίμηση των συναρτήσεων κατανομής πιθανότητας πραγματοποιείται με την εκτίμηση των αγνώστων παραμέτρων
 - Υπάρχουν διάφορες μέθοδοι παραμετρικής εκτίμησης. Οι πιο συχνά χρησιμοποιούμενες αναλύονται στη συνέχεια

- Εισαγωγή
- Παραμετρικές μέθοδοι
- Μη παραμετρικές μέθοδοι
- Ο απλοϊκός ταξινομητής Bayes
- Ο ταξινομητής k-NN

Μέθοδος μέγιστης πιθανοφάνειας



- Η μέθοδος της μέγιστης πιθανοφάνειας (ML-Maximum Likelihood) με δεδομένο ένα σύνολο από διανύσματα παρατήρησης $\{x_1, x_2, \dots, x_N\}$ που ανήκουν στην κλάση ω_i , επιλέγει τις παραμέτρους θ_i της κατανομής $p(x/\omega_i)$ ώστε να μεγιστοποιείται η συνολική πιθανότητα των διανυσμάτων παρατήρησης
- **Παράδειγμα:** Το σχήμα μας δείχνει το ιστόγραμμα των τιμών 1000 παρατηρήσεων για τις οποίες γνωρίζουμε ότι ακολουθούν την κανονική κατανομή (με άγνωστες τιμές για το μ , και σ).
 - Επιλέξτε τις τιμές μ και σ σύμφωνα με τον κανόνα της μέγιστης πιθανοφάνειας
 - **Υπόδειξη:** Για κανονικές κατανομές $N(\mu, \sigma^2)$ ισχύουν τα κατωτέρω:

$$p(\mu) = \frac{1}{\sigma\sqrt{2\pi}}$$

$$P(x < (\mu - 2\sigma)) = P(x > (\mu + 2\sigma)) = 0.025$$

$$P(x) = \int_{-\infty}^x p(z) dz$$

- Εισαγωγή
- Παραμετρικές μέθοδοι
- Μη παραμετρικές μέθοδοι
- Ο απλοϊκός ταξινομητής Bayes
- Ο ταξινομητής k-NN

Μέθοδος μέγιστης πιθανοφάνειας



- Η μέθοδος της μέγιστης πιθανοφάνειας (ML-Maximum Likelihood) με δεδομένο ένα σύνολο από διανύσματα παρατήρησης $\{x_1, x_2, \dots, x_N\}$ που ανήκουν στην κλάση ω_i , επιλέγει τις παραμέτρους θ_i της κατανομής $p(x|\omega_i)$ ώστε να μεγιστοποιείται η συνολική πιθανότητα των διανυσμάτων παρατήρησης
- **Παράδειγμα:** Το σχήμα μας δείχνει το ιστόγραμμα των τιμών 1000 παρατηρήσεων για τις οποίες γνωρίζουμε ότι ακολουθούν την κανονική κατανομή (με άγνωστες τιμές για το μ , και σ).
 - Επιλέξτε τις τιμές μ και σ σύμφωνα με τον κανόνα της μέγιστης πιθανοφάνειας
 - **Υπόδειξη:** Για κανονικές κατανομές $N(\mu, \sigma^2)$ ισχύουν τα κατωτέρω:

$$p(\mu) = \frac{1}{\sigma\sqrt{2\pi}}$$


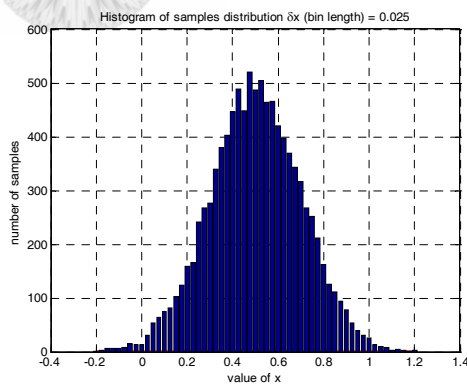
$$P(x < (\mu - 2\sigma)) = P(x > (\mu + 2\sigma)) = 0.025$$

$$P(x) = \int_{-\infty}^x p(z) dz$$

© 2007 Nicolas Tsapatsoulis

- Εισαγωγή
- Παραμετρικές μέθοδοι
- Μη παραμετρικές μέθοδοι
- Ο απλοϊκός ταξινομητής Bayes
- Ο ταξινομητής k-NN

Μέθοδος μέγιστης πιθανοφάνειας (II)



© 2007 Nicolas Tsapatsoulis

- Εισαγωγή
- Παραμετρικές μέθοδοι
- Μη παραμετρικές μέθοδοι
- Ο απλοϊκός ταξινομητής Bayes
- Ο ταξινομητής k-NN

Μέθοδος μέγιστης πιθανοφάνειας (III)



Έστω ότι τα διανύσματα $\underline{x}_1, \underline{x}_2, \dots, \underline{x}_N$ είναι γνωστά και μεταξύ τους ανεξάρτητα

Έστω $p(\underline{x})$ γνωστή υπό την αίρεση ενός αγνώστου διανύσματος παραμέτρων :

$$\underline{\theta} : p(\underline{x}) \equiv p(\underline{x}; \underline{\theta})$$

Έστω $X = \{\underline{x}_1, \underline{x}_2, \dots, \underline{x}_N\}$ το σύνολο των διανυσμάτων παρατήρησης
Ορίζουμε τη συνάρτηση :

$$p(X; \underline{\theta}) \equiv p(\underline{x}_1, \underline{x}_2, \dots, \underline{x}_N; \underline{\theta}) = \prod_{k=1}^N p(\underline{x}_k; \underline{\theta})$$

Η συνάρτηση $p(X; \underline{\theta})$ είναι γνωστή ως Πιθανοφάνεια (Likelihood) του $\underline{\theta}$ ως προς το σύνολο X

- Εισαγωγή
- Παραμετρικές μέθοδοι
- Μη παραμετρικές μέθοδοι
- Ο απλοϊκός ταξινομητής Bayes
- Ο ταξινομητής k-NN

Μέθοδος μέγιστης πιθανοφάνειας (IV)




Υπολογισμός των άγνωστων παραμέτρων.
Διάλεξε το διάνυσμα παραμέτρων που μεγιστοποιεί την πιθανοφάνεια :

$$\hat{\underline{\theta}}_{ML} : \arg \max_{\underline{\theta}} \prod_{k=1}^N p(\underline{x}_k; \underline{\theta})$$

Η συνάρτηση $\ln()$ είναι μια μονοτονική συνάρτηση.

$$L(\underline{\theta}) \equiv \ln p(X; \underline{\theta}) = \sum_{k=1}^N \ln p(\underline{x}_k; \underline{\theta})$$

$$\hat{\underline{\theta}}_{ML} : \frac{\partial L(\underline{\theta})}{\partial \underline{\theta}} = \sum_{k=1}^N \frac{1}{p(\underline{x}_k; \underline{\theta})} \frac{\partial p(\underline{x}_k; \underline{\theta})}{\partial \underline{\theta}} = \underline{0}$$



- Εισαγωγή
- Παραμετρικές μέθοδοι
- Μη παραμετρικές μέθοδοι
- Ο απλοϊκός ταξινομητής Bayes
- Ο ταξινομητής k-NN

Παράδειγμα



$p(\underline{x}) : N(\underline{\mu}, \Sigma)$: $\underline{\mu}$ άγνωστο, $\underline{x}_1, \underline{x}_2, \dots, \underline{x}_N$ $p(\underline{x}_k) \equiv p(\underline{x}_k; \underline{\mu})$

$$L(\underline{\mu}) = \ln \prod_{k=1}^N p(\underline{x}_k; \underline{\mu}) = C - \frac{1}{2} \sum_{k=1}^N (\underline{x}_k - \underline{\mu})^T \Sigma^{-1} (\underline{x}_k - \underline{\mu})$$

$$p(\underline{x}_k; \underline{\mu}) = \frac{1}{(2\pi)^{\frac{1}{2}} |\Sigma|^{\frac{1}{2}}} \exp\left(-\frac{1}{2} (\underline{x}_k - \underline{\mu})^T \Sigma^{-1} (\underline{x}_k - \underline{\mu})\right)$$

$$\frac{\partial L(\underline{\mu})}{\partial(\underline{\mu})} \equiv \begin{bmatrix} \frac{\partial L}{\partial \mu_1} \\ \cdot \\ \cdot \\ \frac{\partial L}{\partial \mu_l} \end{bmatrix} = \sum_{k=1}^N \Sigma^{-1} (\underline{x}_k - \underline{\mu}) = \underline{0} \Rightarrow \underline{\mu}_{ML} = \frac{1}{N} \sum_{k=1}^N \underline{x}_k$$

Υπόδειξη: Αν $A = A^T \Rightarrow \frac{\partial(\underline{\alpha}^T A \underline{\alpha})}{\partial \underline{\alpha}} = 2A\underline{\alpha}$

- Εισαγωγή
- Παραμετρικές μέθοδοι
- Μη παραμετρικές μέθοδοι
- Ο απλοϊκός ταξινομητής Bayes
- Ο ταξινομητής k-NN

Παράδειγμα (II)



→ Έστω οι τιμές παρατήρησης $\{x_1, x_2, \dots, x_N\}$ που είναι γνωστό ότι προέρχονται από την κατανομή

$$p(x) = \begin{cases} \theta e^{-\theta x} & x \geq 0 \\ 0 & x < 0 \end{cases}$$

→ Να εκτιμηθεί η τιμή της παραμέτρου θ με τη μέθοδο της μέγιστης πιθανοφάνειας

- ☑ Εισαγωγή
- ★ Παραμετρικές μέθοδοι
- ☐ Μη παραμετρικές μέθοδοι
- ☐ Ο απλοϊκός ταξινομητής Bayes
- ☐ Ο ταξινομητής k-NN

Μέθοδος της μέγιστης εκ των υστέρων πιθανότητας



- Η μέθοδος της μέγιστης εκ των υστέρων πιθανότητας (**MAP- Maximum A posteriori Probability**) θεωρεί ότι το διάνυσμα παραμέτρων $\underline{\theta}$ είναι ένα τυχαίο διάνυσμα με γνωστή κατανομή πιθανότητας $p(\underline{\theta})$.
- Με δεδομένο ένα σύνολο από διανύσματα παρατήρησης $X = \{x_1, x_2, \dots, x_N\}$ η εκτίμηση του διανύσματος $\underline{\theta}$ πραγματοποιείται με μεγιστοποίηση της συνάρτησης της εκ των υστέρων πιθανότητας:

$$p(\underline{\theta}|X)$$
- Από τον κανόνα του Bayes έχουμε:

$$p(\underline{\theta})p(X|\underline{\theta}) = p(X)p(\underline{\theta}|X) \Rightarrow$$

$$p(\underline{\theta}|X) = \frac{p(\underline{\theta})p(X|\underline{\theta})}{p(X)}$$

- ☑ Εισαγωγή
- ★ Παραμετρικές μέθοδοι
- ☐ Μη παραμετρικές μέθοδοι
- ☐ Ο απλοϊκός ταξινομητής Bayes
- ☐ Ο ταξινομητής k-NN

Μέθοδος της μέγιστης εκ των υστέρων πιθανότητας (II)




- Υπολογισμός του διανύσματος παραμέτρων $\underline{\theta}$.

$$\hat{\underline{\theta}}_{MAP} = \arg \max_{\underline{\theta}} p(\underline{\theta}|X) \text{ or}$$

$$\hat{\underline{\theta}}_{MAP} : \frac{\partial}{\partial \underline{\theta}} (p(\underline{\theta})p(X|\underline{\theta}))$$

Αν $p(\underline{\theta})$ είναι ομοιόμορφη ή αρκετά

ευρεία τότε $\hat{\underline{\theta}}_{MAP} \cong \underline{\theta}_{ML}$



- Εισαγωγή
- Παραμετρικές μέθοδοι
- Μη παραμετρικές μέθοδοι
- Απλοϊκός ταξινομητής Bayes
- Ταξινομητής k-NN

Παράδειγμα



- Έστω ότι ζητάμε να εκτιμήσουμε το μέσο διάνυσμα $\underline{\mu}$ μιας πολυδιάστατης κανονικής κατανομής $N(\underline{\mu}, \sigma^2)$, για την οποία γνωρίζουμε ότι το διάνυσμα της μέσης τιμής ακολουθεί επίσης κανονική κατανομή $N(\underline{\mu}_0, \sigma_\mu^2)$:

$$p(\underline{x}) : N(\underline{\mu}, \Sigma), \underline{\mu} \text{ unknown}, X = \{\underline{x}_1, \dots, \underline{x}_N\}$$

$$p(\underline{\mu}) = \frac{1}{(2\pi)^{\frac{1}{2}} \sigma_\mu^{\frac{1}{2}}} \exp\left(-\frac{\|\underline{\mu} - \underline{\mu}_0\|^2}{2\sigma_\mu^2}\right)$$

$$\hat{\underline{\theta}}_{MAP} : \frac{\partial}{\partial \underline{\mu}} \ln(\prod_{k=1}^N p(\underline{x}_k | \underline{\mu}) p(\underline{\mu})) = 0 \text{ or } \sum_{k=1}^N \frac{1}{\sigma^2} (\underline{x}_k - \underline{\mu}) - \frac{1}{\sigma_\mu^2} (\hat{\underline{\mu}} - \underline{\mu}_0) = \underline{0} \Rightarrow$$

$$\hat{\underline{\mu}}_{MAP} = \frac{\underline{\mu}_0 + \frac{\sigma_\mu^2}{\sigma^2} \sum_{k=1}^N \underline{x}_k}{1 + \frac{\sigma_\mu^2}{\sigma^2} N} \text{ For } \frac{\sigma_\mu^2}{\sigma^2} \gg 1, \text{ or for } N \rightarrow \infty$$

$$\hat{\underline{\mu}}_{MAP} \cong \hat{\underline{\mu}}_{ML} = \frac{1}{N} \sum_{k=1}^N \underline{x}_k$$

© 2007 Nicolas Tsapatsoulis

- Εισαγωγή
- Παραμετρικές μέθοδοι
- Μη παραμετρικές μέθοδοι
- Απλοϊκός ταξινομητής Bayes
- Ταξινομητής k-NN

Μεικτά μοντέλα



- Τα μεικτά μοντέλα (mixture models) προσεγγίζουν μια άγνωστη κατανομή πιθανότητας συνδυάζοντας πολλές κατανομές.

- Αποδεικνύεται ότι με συνδυασμό κατανομών μπορεί να προσεγγίσουμε οποιαδήποτε άγνωστη κατανομή

$$p(\underline{x}) = \sum_{j=1}^M p(\underline{x}|j) P_j$$

$$\sum_{j=1}^M P_j = 1, \int_{\underline{x}} p(\underline{x}|j) d\underline{x} = 1$$

- Εργαζόμενοι όπως και πριν με παραμετρική μοντελοποίηση έχουμε:

$$p(\underline{x}|j; \underline{\theta})$$

- Ο στόχος είναι η εκτίμηση των $\underline{\theta}$ και P_1, P_2, \dots, P_j δεδομένου του συνόλου $X = \{\underline{x}_1, \underline{x}_2, \dots, \underline{x}_N\}$

© 2007 Nicolas Tsapatsoulis

- Εισαγωγή
- Παραμετρικές μέθοδοι
- Μη παραμετρικές μέθοδοι
- Ο απλοϊκός ταξινομητής Bayes
- Ο ταξινομητής k-NN

Μεικτά μοντέλα (II)



- Μπορούμε να εφαρμόσουμε τη μέθοδο μεγίστης πιθανοφάνειας όπως και πριν:

$$\hat{\Theta}_{opt} = \arg \max_{\theta, P_1, \dots, P_J} \prod_{k=1}^N P(x_k; \theta, P_1, \dots, P_J)$$

- Η διαφορά είναι ότι τώρα χρειάζεται να εκτιμηθούν οι εκ των προτέρων πιθανότητες $P_j, j = 1, 2, \dots, J$ για τις επιμέρους κατανομές οι οποίες δεν είναι άμεσα παρατηρήσιμες από το σύνολο X .
 - Το ανωτέρω πρόβλημα είναι ένα χαρακτηριστικό πρόβλημα μη πλήρους συνόλου δεδομένων (incomplete data set)
 - Μια πολύ διαδεδομένη μέθοδος για την επίλυση τέτοιων προβλημάτων είναι ο αλγόριθμος EM (Expectation Maximization)

- Εισαγωγή
- Παραμετρικές μέθοδοι
- Μη παραμετρικές μέθοδοι
- Ο απλοϊκός ταξινομητής Bayes
- Ο ταξινομητής k-NN

Ο αλγόριθμος EM



- Γενική θεώρηση:

→ Έστω \underline{y} το πλήρες σύνολο δεδομένων $\underline{y} \in Y \subseteq R^m$, με $\underline{y}(\underline{\theta})$,

τα οποία δεν είναι άμεσα παρατηρήσιμα

→ Αντίθετα παρατηρήσιμος είναι ο υπόχωρος \underline{x}

$$\underline{x} = g(\underline{y}) \in X_{ob} \subseteq R^l, l < m \text{ with } P_x(\underline{x}; \underline{\theta}),$$

→ Προφανώς για το μη παρατηρήσιμο μέρος των διανυσμάτων \underline{y} μπορεί να έχει οποιαδήποτε τιμή

→ Ο αλγόριθμος EM συμπληρώνει τα ελλιπή δεδομένα αναθέτοντας σε αυτά τις πιθανότερες τιμές (αναμενόμενες)

→ Στο προηγούμενο παράδειγμα οι εκτιμήσεις για τις εκ των προτέρων πιθανότητες $P_j, j=1, 2, \dots, J$ βασίζονται στην τρέχουσα εκτίμηση των παραμέτρων $\underline{\theta}$.

- Εισαγωγή
- Παραμετρικές μέθοδοι
- Μη παραμετρικές μέθοδοι
- Ο απλοϊκός ταξινομητής Bayes
- Ο ταξινομητής k-NN

Ο αλγόριθμος EM (II)



→ Έστω: $Y(x) \subseteq Y$ όλα τα $y \rightarrow$ που αντιστοιχούν σε ένα συγκεκριμένο x

$$p_x(x; \theta) = \int_{Y(x)} p_y(y; \theta) dy$$

→ Αυτό που ζητάμε να υπολογίσουμε είναι:

$$\hat{\theta}_{ML} : \sum_k \frac{\partial \ln(p_y(y_k; \theta))}{\partial \theta} = 0$$

- Αλλά δυστυχώς τα y_k δεν είναι παρατηρήσιμα
- Ο αλγόριθμος EM μεγιστοποιεί την αναμενόμενη τιμή για τα y_k δεδομένων των x_k και της τρέχουσας των αγνώστων παραμέτρων θ .

- Εισαγωγή
- Παραμετρικές μέθοδοι
- Μη παραμετρικές μέθοδοι
- Ο απλοϊκός ταξινομητής Bayes
- Ο ταξινομητής k-NN

Ο αλγόριθμος EM (III)



→ Ο αλγόριθμος εκτελείται σε δυο βήματα:

→ Εύρεση της αναμενόμενης τιμής $Q(\theta; \theta(t))$ για τις τιμές των y_k δεδομένων των $X = \{x_1, x_2, \dots, x_N\}$ και της τρέχουσας εκτίμησης για τις παραμέτρους $\theta(t)$.

$$\rightarrow \text{E-step: } Q(\theta; \theta(t)) = E\left[\sum_k \ln(p_y(y_k; \theta) | X; \theta(t))\right]$$

→ Εύρεση της νέας εκτίμησης $\theta(t+1)$ για τις άγνωστες παραμέτρους με μεγιστοποίηση της αναμενόμενης τιμής

$$\rightarrow \text{M-step: } \theta(t+1) : \frac{\partial Q(\theta; \theta(t))}{\partial \theta} = 0$$

- ☑ Εισαγωγή
- ★ Παραμετρικές μέθοδοι
- ☐ Μη παραμετρικές μέθοδοι
- ☐ Ο απλοϊκός ταξινομητής Bayes
- ☐ Ο ταξινομητής k-NN

Ο αλγόριθμος EM στην προσέγγιση κατανομών



- Ο αλγόριθμος EM εφαρμόζεται στην εκτίμηση των αγνώστων κατανομών με χρήση μεικτών μοντέλων:
 - Πλήρη δεδομένα: $(\underline{x}_k, j_k), k = 1, 2, \dots, N$
 - j_k η κατανομή από την οποία δημιουργείται το διάνυσμα \underline{x}_k .
 - Παρατηρήσιμα είναι μόνο τα \underline{x}_k και όχι οι τιμές $j_k, \underline{x}_k, k = 1, 2, \dots, N$

$$p(\underline{x}_k, j_k; \underline{\theta}) = p(\underline{x}_k | j_k; \underline{\theta}) P_{j_k}$$
 - Θεωρώντας ότι τα διανύσματα παρατήρησης \underline{x}_k είναι μεταξύ τους ανεξάρτητα λαμβάνουμε τη λογαριθμική μορφή της συνάρτησης πιθανοφάνειας ως ακολούθως:

$$L(\underline{\theta}) = \sum_{k=1}^N \ln(p(\underline{x}_k | j_k; \underline{\theta}) P_{j_k})$$

- ☑ Εισαγωγή
- ★ Παραμετρικές μέθοδοι
- ☐ Μη παραμετρικές μέθοδοι
- ☐ Ο απλοϊκός ταξινομητής Bayes
- ☐ Ο ταξινομητής k-NN

Ο αλγόριθμος EM στην προσέγγιση κατανομών (II)



- Άγνωστες παράμετροι:

$$\underline{\Theta}^T = [\underline{\theta}^T, \underline{P}^T]^T, \underline{P} = [P_1, P_2, \dots, P_J]^T$$
- E-step:

$$Q(\underline{\Theta}; \underline{\Theta}(t)) = E\left[\sum_{k=1}^N \ln(p(\underline{x}_k | j_k; \underline{\theta}) P_{j_k})\right] = \sum_{k=1}^N E\left[\ln(p(\underline{x}_k | j_k; \underline{\theta}) P_{j_k})\right]$$

$$\sum_{k=1}^N \sum_{j_k=1}^J P(j_k | \underline{x}_k; \underline{\Theta}(t)) \ln(p(\underline{x}_k | j_k; \underline{\theta}) P_{j_k})$$
- M-step: $\frac{\partial Q}{\partial \underline{\theta}} = 0, \quad \frac{\partial Q}{\partial P_{j_k}} = 0, \quad j_k = 1, 2, \dots, J$


$$P(j | \underline{x}_k; \underline{\Theta}(t)) = \frac{p(\underline{x}_k | j; \underline{\theta}(t)) P_j}{P(\underline{x}_k; \underline{\Theta}(t))} \quad p(\underline{x}_k; \underline{\Theta}(t)) = \sum_{j=1}^J p(\underline{x}_k | j; \underline{\theta}(t)) P_j$$

- ☑ Εισαγωγή
- ☑ Παραμετρικές μέθοδοι
- ★ Μη παραμετρικές μέθοδοι
- ☐ Ο απλοϊκός ταξινομητής Bayes
- ☐ Ο ταξινομητής k-NN

Μη παραμετρικές μέθοδοι



- Στις μη παραμετρικές μεθόδους η συναρτήσεις πυκνότητας πιθανότητας δεν έχουν μια προδιαγεγραμμένη μορφή.
- Μπορούν να είναι απλά το ιστόγραμμα των εκτιμήσεων πιθανότητας σε ένα εύρος τιμών των διανυσμάτων παρατήρησης



$$P \approx \frac{k_N}{N} \begin{matrix} \nearrow \\ \searrow \end{matrix} \begin{matrix} k_N \text{ in } h \\ N \text{ total} \end{matrix}$$

$$\hat{p}(x) \equiv \hat{p}(\hat{x}) = \frac{1}{h} \frac{k_N}{N}, |x - \hat{x}| \leq \frac{h}{2}$$

$\hat{x} - \frac{h}{2}$ \hat{x} $\hat{x} + \frac{h}{2}$

Αν η $p(x)$ είναι συνεχής, $\hat{p}(x) \rightarrow p(x)$ όταν $N \rightarrow \infty$, εφόσον $h_N \rightarrow 0$, $k_N \rightarrow \infty$, $\frac{k_N}{N} \rightarrow 0$

- ☑ Εισαγωγή
- ☑ Παραμετρικές μέθοδοι
- ★ Μη παραμετρικές μέθοδοι
- ☐ Ο απλοϊκός ταξινομητής Bayes
- ☐ Ο ταξινομητής k-NN

Μέθοδος παραθύρων Parzen



- Διαιρούμε το πολυδιάστατο χώρο σε υπερκύβους:



Ορίζουμε τη συνάρτηση $\varphi(\underline{x}_i) = \begin{cases} 1 & |x_{ij}| \leq \frac{1}{2} \\ 0 & \text{otherwise} \end{cases}$

- Δηλαδή ένα υπερκύβο με πλευρά 1 και κεντραρισμένο στο 0

$$\hat{p}(\underline{x}) = \frac{1}{h^l} \left(\frac{1}{N} \sum_{i=1}^N \varphi\left(\frac{\underline{x}_i - \underline{x}}{h}\right) \right)$$

$\frac{1}{\text{όγκος}} * \frac{1}{N} * \text{αριθμός σημείων εντός του κύβου}$
με πλευρά h - και κεντραρισμένο στο \underline{x}

- Υπάρχει ένα πρόβλημα: $p(\underline{x})$ συνεχής
 $\varphi(\cdot)$ ασυνεχής
- Για εξομάλυνση ορίζουμε τα παράθυρα Parzen μέσω κάποιων συναρτήσεων πυρήνα (kernel functions – παράδειγμα N(0,1):
 $\varphi(\underline{x})$ is smooth
 $\varphi(\underline{x}) \geq 0, \int \varphi(\underline{x}) d\underline{x} = 1$


- Εισαγωγή
- Παραμετρικές μέθοδοι
- Μη παραμετρικές μέθοδοι
- απλοϊκός ταξινομητής Bayes
- ταξινομητής k-NN

Μέθοδος παραθύρων Parzen (II)




→ **Μεταβλητότητα:**

→ Όσο μικρότερο είναι το h τόσο μεγαλύτερη είναι η διασπορά



→ Όσο μεγαλύτερο το N τόσο καλύτερη η ακρίβεια της εκτίμησης



© 2007 Nicolas Tsapatsoulis

- Εισαγωγή
- Παραμετρικές μέθοδοι
- Μη παραμετρικές μέθοδοι
- απλοϊκός ταξινομητής Bayes
- ταξινομητής k-NN

Μέθοδος παραθύρων Parzen (III)



→ Εφαρμογή της μεθόδου στη ταξινόμηση με τον κανόνα Bayes:

$$l_{12} \equiv \frac{p(x|\omega_1)}{p(x|\omega_2)} (><) \frac{P(\omega_2)}{P(\omega_1)} \frac{\lambda_{21} - \lambda_{22}}{\lambda_{12} - \lambda_{11}} \equiv \theta$$

$$\frac{\frac{1}{N_1 h^l} \sum_{i=1}^{N_1} \varphi\left(\frac{x_i - x}{h}\right)}{\frac{1}{N_2 h^l} \sum_{i=1}^{N_2} \varphi\left(\frac{x_i - x}{h}\right)} (><) \theta$$

© 2007 Nicolas Tsapatsoulis

- Εισαγωγή
- Παραμετρικές μέθοδοι
- Μη παραμετρικές μέθοδοι
- Ο απλοϊκός ταξινομητής Bayes
- Ο ταξινομητής k-NN

Μέθοδος k-NN (II)




→ Μέθοδος Parzen

- Ο όγκος του κάθε υπερκύβου
- Ο αριθμός των σημείων εντός κάθε υπερκύβου κυμαίνεται

→ Μέθοδος k-NN

- Ο αριθμός των σημείων διατηρείται σταθερός
- Ο όγκος αυξάνεται

$$\frac{\frac{k}{N_1 V_1}}{\frac{k}{N_2 V_2}} = \frac{N_2 V_2}{N_1 V_1} (><) \theta$$



- Εισαγωγή
- Παραμετρικές μέθοδοι
- Μη παραμετρικές μέθοδοι
- Ο απλοϊκός ταξινομητής Bayes
- Ο ταξινομητής k-NN

Ο απλοϊκός ταξινομητής Bayes



→ Η κατάρρα της διάστασης (curse of dimensionality)

- Σε όλες τις μεθόδους μη παραμετρικής εκτίμησης όσο περισσότερα σημεία **N** λαμβάνονται σε κάθε υπερκύβο τόσο καλύτερη εκτίμηση έχουμε για τη συνάρτηση πυκνότητας πιθανότητας
- Αν στη μονοδιάστατη περίπτωση (οι παρατηρήσεις είναι απλά μεμονωμένες τιμές και όχι διανύσματα) απαιτούνται **N** σημεία σε κάθε διάστημα εύρους **h** τότε στη πολυδιάστατη περίπτωση (διανύσματα μήκους **l**) απαιτούνται **N^l** σημεία για καλή εκτίμηση.
- Η εκθετική αύξηση των απαιτούμενων σημείων με την αύξηση της διάστασης του διανύσματος ονομάζεται **κατάρρα της διάστασης**

- ☑ Εισαγωγή
- ☑ Παραμετρικές μέθοδοι
- ☑ Μη παραμετρικές μέθοδοι
- ★ Ο απλοϊκός ταξινομητής Bayes
- ☐ Ο ταξινομητής k-NN

Ο απλοϊκός ταξινομητής Bayes (II)



- Έστω $\underline{x} \in \mathfrak{R}^\ell$ και ότι επιθυμούμε να εκτιμήσουμε τις κατανομές $p(\underline{x} | \omega_i)$ $i = 1, 2, \dots, M$.
- Για αποτελεσματική εκτίμηση χρειάζονται N^ℓ σημεία (διανύσματα παρατήρησης).
- Υποθέτοντας ότι όλα τα στοιχεία των διανυσμάτων είναι μεταξύ τους ανεξάρτητα (x_1, x_2, \dots, x_ℓ mutually independent). Τότε:

$$p(\underline{x} | \omega_i) = \prod_{j=1}^{\ell} p(x_j | \omega_i)$$
- Σε αυτή την περίπτωση απαιτούνται N σημεία για κάθε συνάρτηση πυκνότητας πιθανότητας. Επομένως ένας συνολικός αριθμός της τάξης των $N \cdot \ell$ σημείων είναι αρκετός.
- Η ανωτέρω εκτίμηση οδηγεί στο απλοϊκό ταξινομητή Bayes (δηλαδή εφαρμογή της ταξινόμησης Bayes με βάση την απλοϊκή εκτίμηση της κατανομής)

© 2007 Nicolas Tsapatsoulis

- ☑ Εισαγωγή
- ☑ Παραμετρικές μέθοδοι
- ☑ Μη παραμετρικές μέθοδοι
- ☑ Ο απλοϊκός ταξινομητής Bayes
- ★ Ο ταξινομητής k-NN

Ο ταξινομητής k-NN



- Έστω ένα διάνυσμα εισόδου \underline{x} . Επιλέγουμε τα k πλησιέστερα σε αυτό διανύσματα παρατήρησης (από το σύνολο των N)
- Από τα k αυτά διανύσματα τα k_i ανήκουν στην κατηγορία ω_i .
- Ανέθεσε το \underline{x} σύμφωνα με τον κανόνα: $\underline{x} \rightarrow \omega_i : k_i > k_j \quad \forall i \neq j$
- Στην απλούστερη περίπτωση $k=1$!!!
- Για μεγάλο αριθμό δειγμάτων N η προσέγγιση αυτή δεν απέχει πολύ από τον βέλτιστο ταξινομητή (κανόνας Bayes).
- Έστω P_B η πιθανότητα σφάλματος ταξινόμησης με τον κανόνα Bayes και P_{NN} η αντίστοιχη πιθανότητα στον ταξινομητή 1-NN. Ισχύει:

$$P_B \leq P_{NN} \leq P_B \left(2 - \frac{M}{M-1} P_B\right) \leq 2P_B \quad P_B \leq P_{kNN} \leq P_B + \sqrt{\frac{2P_{NN}}{k}}$$

© 2007 Nicolas Tsapatsoulis