

ΑΝΑΓΝΩΡΙΣΗ ΠΡΟΤΥΠΩΝ (PATTERN RECOGNITION)

Σέργιος Θεοδωρίδης
Κωνσταντίνος Κουτρούμπας

(Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

Η περίπτωση του ταξινομητή Bayes

Εκτίμηση μέγιστης εκ των υστέρων πιθανότητας (Maximum A posteriori Probability (MAP) Estimation)

- Στην ML μέθοδο, το $\underline{\theta}$ λογιζόταν ως παράμετρος
- Εδώ θα θεωρήσουμε το $\underline{\theta}$ ως τυχαίο διάνυσμα που περιγράφεται από (υποτίθεται γνωστή) pdf $p(\underline{\theta})$.
- Δοθέντος

$$X = \{ \underline{x}_1, \underline{x}_2, \dots, \underline{x}_N \}$$

Υπολόγισε το μέγιστο της

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

- Από το Θεώρημα του Bayes έχουμε

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

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

(Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

Η περίπτωση του ταξινομητή Bayes

Εκτίμηση μέγιστης εκ των υστέρων πιθανότητας (MAP)

➤ Η μέθοδος:

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

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



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

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

(A) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

Η περίπτωση του ταξινομητή Bayes

Εκτίμηση μέγιστης εκ των υστέρων πιθανότητας (MAP)



(Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

Η περίπτωση του ταξινομητή Bayes

Εκτίμηση μέγιστης εκ των υστέρων πιθανότητας (MAP) - Παράδειγμα

$$p(\underline{x}) \propto N(\underline{\mu}, \Sigma), \quad \underline{\mu} \text{ γνωστός}, \dots, \underline{x} \in \{-1, \dots, -N\} \quad \Sigma = \sigma^2 I$$

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

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

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

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


(Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

Η περίπτωση του ταξινομητή Bayes

Η μέθοδος αναμονής-μεγιστοποίησης (expectation-maximization – EM) (μοντέλα μίξης - mixture models)

Μοντέλο μίξης: Σταθμισμένο άθροισμα pdfs γνωστής παραμετρικής μορφής

$$p(x) = \sum_{k=1}^K P_k p(x|k), \quad \sum_{k=1}^K P_k = 1, \quad \int_{-\infty}^{+\infty} p(x|k) = 1$$



❖ Η μέθοδος ML δεν μπορεί να αξιοποιηθεί εδώ εξαιτίας των **ετικετών** k , που είναι επίσης άγνωστες. **Λύση:** Ο αλγόριθμος **EM**.

Συμβολισμοί:

➤ $p(x|k) = p(x|k; \vartheta_k)$

➤ $\Theta = (\vartheta_1, \dots, \vartheta_K)$, $P = [P_1, \dots, P_K]^T$, $\Xi = (\Theta, P)$.



➤ $\mathcal{X} = \{\mathbf{x}_1, \dots, \mathbf{x}_N\}$: **μη πλήρες (incomplete)** (παρατηρούμενο) σύνολο δεδομένων.

➤ $\mathcal{X}^c = \{(\mathbf{x}_1, k_1), \dots, (\mathbf{x}_N, k_N)\}$: **πλήρες (complete)** σύνολο δεδομένων

(Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

Η περίπτωση του ταξινομητή Bayes

Η μέθοδος **EM** (μοντέλα μίξης)



(Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

Η περίπτωση του ταξινομητή Bayes

Η μέθοδος **EM** (μοντέλα μίξης)

Στόχος: Εκτίμησε τα Θ και P μέσω της **μεγιστοποίησης** της **αναμενόμενης τιμής (expectation)** της συνάρτησης **log-likelihood conditioned** στα **παρατηρούμενα δεδομένα**.

$$\ln p(X; \Theta, P) = \sum_{n=1}^N \sum_{j=1}^m P(j | \mathbf{x}_n; \theta_j) \ln p(\mathbf{x}_n, j; \theta_j) =$$

$$\sum_{n=1}^N \sum_{j=1}^m P(j | \mathbf{x}_n; \theta_j) \ln \left(p(\mathbf{x}_n | j; \theta_j) P_j \right)$$

Μίξη κανονικών κατανομών.

$$p(\mathbf{x}) = \sum_{j=1}^m P_j p(\mathbf{x} | j; \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j),$$

$$p(\mathbf{x} | j; \boldsymbol{\mu}_j, \boldsymbol{\Sigma}_j) = \frac{1}{(2\pi)^{l/2} |\boldsymbol{\Sigma}_j|^{1/2}} \exp\left(-0.5 \cdot (\mathbf{x} - \boldsymbol{\mu}_j)^T \boldsymbol{\Sigma}_j^{-1} (\mathbf{x} - \boldsymbol{\mu}_j)\right)$$

(Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

Η περίπτωση του ταξινομητή Bayes

Ο αλγόριθμος **EM** για **μίξεις κανονικών κατανομών**.

- Αρχικοποίησε $\mu_j = \mu_j^{(0)}$, $\Sigma_j = \Sigma_j^{(0)}$, $P = P^{(0)}$

- $t=0$

- Επανάλαβε

$$P(j | \mathbf{x}_n; \Theta^{(t)}, P^{(t)}) = \frac{p(\mathbf{x}_n | j; \theta_k^{(t)}) P_j^{(t)}}{\sum_{q=1}^m p(\mathbf{x}_n | q; \theta_q^{(t)}) P_q^{(t)}} \equiv \gamma_{jn}^{(t)}$$

Expectation
step

➤ $t=t+1$

$$\mu_j^{(t+1)} = \frac{\sum_{n=1}^N \gamma_{jn}^{(t)} \mathbf{x}_n}{\sum_{n=1}^N \gamma_{jn}^{(t)}}$$

$$\Sigma_j^{(t+1)} = \frac{\sum_{n=1}^N \gamma_{jn}^{(t)} (\mathbf{x}_n - \mu_j^{(t+1)}) (\mathbf{x}_n - \mu_j^{(t+1)})^T}{\sum_{n=1}^N \gamma_{jn}^{(t)}}$$

$$P_j^{(t+1)} = \frac{1}{N} \sum_{n=1}^N \gamma_{jn}^{(t)}$$

Maximization
step

- Έως ότου ικανοποιηθεί ένα κατάλληλο κριτήριο τερματισμού.

(A) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

Ανασκόπηση του (προσεγγιστικού) ταξινομητή Bayes

- Available data: $X = X_1 \cup X_2 \cup \dots \cup X_M$. Each X_j corresponds to class ω_j .

Σχεδιασμός ταξινομητή

- Υιοθέτησε ένα μοντέλο pdf για κάθε ω_j , με άγνωστες παραμέτρους ϑ_j .

- Εφάρμοσε την **ML** (ή τις **MAP**, **EM**) μεθόδους **M φορές** (μία για κάθε κλάση) για την εκτίμηση των ϑ_j 's, με βάση τα αντίστοιχα σύνολα X_j ,

$$\hat{p}(x | \omega_j) \equiv p(x | \omega_j; \hat{\vartheta}_j)$$

- Προσέγγισε τις $P(\omega_j)$ ως εξής

$$\hat{P}(\omega_j) = N_j / N$$

- Όρισε

$$g_j(x) = \hat{P}(\omega_j) \hat{p}(x | \omega_j)$$

Χρήση ταξινομητή

- Για δεδομένο \mathbf{x} ,

- Υπολόγισε τις τιμές των $g_j(\mathbf{x})$, $j=1, \dots, M$.

- Καταχώρησε το \mathbf{x} στην κλάση k με $g_k(\mathbf{x}) = \max_{j=1, \dots, M} g_j(\mathbf{x})$.

Ένα σημαντικό ζήτημα – Η κατάρα της διαστατικότητας (Curse of dimensionality)

- Σε όλες τις μεθόδους που εξετάσαμε μέχρι στιγμής είδαμε ότι όσο **μεγαλύτερος** είναι ο αριθμός των σημείων, N , τόσο **καλύτερες** είναι και οι προκύπτουσες εκτιμήσεις.
- Αν στο μονοδιάστατο χώρο για ένα διάστημα μήκους L , N σημεία είναι **αρκετά** για να δώσουν μια καλή εκτίμηση των εμπλεκόμενων παραμέτρων, στο διδιάστατο χώρο για μια επιφάνεια διαστάσεων $L \times L$ απαιτούνται N^2 σημεία για να πάρουμε καλές εκτιμήσεις και, γενικά, στον l -διάστατο χώρο για έναν υπερκύβο διαστάσεων L^l απαιτούνται N^l σημεία.
- Η εκθετική αύξηση του αριθμού των σημείων που απαιτούνται για μια καλή εκτίμηση των εμπλεκόμενων παραμέτρων με τη διάσταση του χώρου είναι γνωστή ως **κατάρα της διαστατικότητας (curse of dimensionality)**. Πρόκειται για ένα σημαντικό πρόβλημα που απαντάται σε προβλήματα που απεικονίζονται σε χώρους υψηλής διαστατικότητας.

(Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

Ο απλοϊκός ταξινομητής Bayes (naive Bayes classifier)

- Διαθέσιμα δεδομένα: $X = X_1 \cup X_2 \cup \dots \cup X_M$. Κάθε X_j αντιστοιχεί στην κλάση ω_j . Έστω $X_j = X_{j1} \times \dots \times X_{jl}$

- **Υπόθεση:** Όλα τα **χαρακτηριστικά (features)** είναι μεταξύ τους **στατιστικώς ανεξάρτητα**. Έτσι

$$p(x | \omega_j) = \prod_{k=1}^l p(x_k | \omega_j), \quad j = 1, \dots, M$$

- Ως εκ τούτου, μπορούμε για κάθε κλάση να εργαστούμε για κάθε $p(x_k | \omega_j)$ ανεξάρτητα από τις υπόλοιπες $p(x_q | \omega_j)$, $q=1, \dots, l$, $q \neq k$.

(Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

Ο απλοϊκός ταξινομητής Bayes (naive Bayes classifier)

Σχεδιασμός ταξινομητή

- Υιοθέτησε ένα μοντέλο pdf για κάθε ω_j , με άγνωστες παραμέτρους ϑ_j .
- Εφάρμοσε την ML μέθοδο **M I φορές** (I φορές για κάθε κλάση) για την εκτίμηση των ϑ_{jk} 's των μονοδιάστατων $p(x_k | \omega_j)$, με βάση τα αντίστοιχα X_{jk}

- Προσέγγισε τις $P(\omega_j)$ ως ακολούθως

$$\hat{P}(\omega_j) = N_j / N$$

- Όρισε

$$g_j(x) = \hat{P}(\omega_j) \hat{p}(x | \omega_j) = \hat{P}(\omega_j) \prod_{k=1}^l \hat{p}(x_k | \omega_j)$$

Χρήση ταξινομητή

- Για δεδομένο \mathbf{x} ,
- Υπολόγισε τις τιμές των $g_j(\mathbf{x})$, $j=1, \dots, M$.
- Καταχώρησε το \mathbf{x} στην κλάση k με $g_k(\mathbf{x}) = \max_{j=1, \dots, M} g_j(\mathbf{x})$.

(Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

Γραμμικοί ταξινομητές – Ο ταξινομητής ελάχιστης Ευκλείδειας απόστασης

- Διαθέσιμα δεδομένα: $X = X_1 \cup X_2 \cup \dots \cup X_M$. Κάθε X_j αντιστοιχεί στην κλάση ω_j .

Σχεδιασμός ταξινομητή

- Εκτίμησε το μέσο διάνυσμα, m_j , κάθε κλάσης ω_j , με βάση το X_j , $j=1, \dots, N_j$.

(συνήθως, η μέθοδος **ML** χρησιμοποιείται για κάθε κλάση, με την υπόθεση ότι κάθε κλάση μοντελοποιείται από μια **κανονική** κατανομή αγνώστου μέσου διανύσματος και το m_j τίθεται ίσο με την προκύπτουσα **εκτίμηση** του μέσου διανύσματος)

-Όρισε

$$g_j(\mathbf{x}) = - \|\mathbf{x} - \mathbf{m}_j\|^2$$

Χρήση ταξινομητή

-Για δεδομένο \mathbf{x} ,

-Υπολόγισε τις τιμές των $g_j(\mathbf{x})$, $j=1, \dots, M$.

-Καταχώρησε το \mathbf{x} στην κλάση k με $g_k(\mathbf{x}) = \max_{j=1, \dots, M} g_j(\mathbf{x})$.

ΣΗΜ: Γενικά, ο ταξινομητής ελάχιστης Ευκλείδειας απόστασης **δεν είναι βέλτιστος** ως προς το κριτήριο της **πιθανότητας λάθους** (κάτω από ποιές συνθήκες ο ταξινομητής αυτός θα μπορούσε να είναι βέλτιστος;)

(Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

Γραμμικοί ταξινομητές – Ο ταξινομητής ελάχιστης Mahalanobis απόστασης

- Διαθέσιμα δεδομένα: $X = X_1 \cup X_2 \cup \dots \cup X_M$. Κάθε X_j αντιστοιχεί στην κλάση ω_j .

Σχεδιασμός ταξινομητή

- Εκτίμησε το μέσο διάνυσμα, m_j , και το μητρώο συνδιασποράς, S_j , κάθε κλάσης ω_j , με βάση το X_j , $j=1, \dots, N_j$.

(συνήθως, η μέθοδος **ML** χρησιμοποιείται για κάθε κλάση, με την υπόθεση ότι κάθε κλάση μοντελοποιείται από μια **κανονική** κατανομή αγνώστου μέσου διανύσματος και μητρώου συνδιασποράς και τα m_j και S_j , τίθενται ίσα με τις προκύπτουσες εκτιμήσεις (το κοινό μητρώο συνδιασποράς μπορεί να τεθεί ίσο με το μέσο των εκτιμήσεων για τα S_j)

-Όρισε

$$g_j(\mathbf{x}) = -(\mathbf{x} - \mathbf{m}_j)^T S_j^{-1} (\mathbf{x} - \mathbf{m}_j)$$

Χρήση ταξινομητή

-Για δεδομένο \mathbf{x} ,

-Υπολόγισε τις τιμές των $g_j(\mathbf{x})$, $j=1, \dots, M$.

-Καταχώρησε το \mathbf{x} στην κλάση k με $g_k(\mathbf{x}) = \max_{j=1, \dots, M} g_j(\mathbf{x})$.

ΣΗΜ: Γενικά, ο ταξινομητής ελάχιστης Mahalanobis απόστασης **δεν είναι βέλτιστος** ως προς το κριτήριο της **πιθανότητας λάθους** (κάτω από ποιές συνθήκες ο ταξινομητής αυτός θα μπορούσε να είναι βέλτιστος;)

(Α) ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

Τετραγωνικοί ταξινομητές

- Διαθέσιμα δεδομένα: $X = X_1 \cup X_2 \cup \dots \cup X_M$. Κάθε X_j αντιστοιχεί στην κλάση ω_j .

Σχεδιασμός ταξινομητή

- Εκτίμησε το μέσο διάνυσμα, m_j , και το μητρώο συνδιασποράς, S_j , κάθε κλάσης ω_j , με βάση το X_j , $j=1, \dots, M$.

(συνήθως, η μέθοδος **ML** χρησιμοποιείται για κάθε κλάση, με την υπόθεση ότι κάθε κλάση μοντελοποιείται από μια **κανονική** κατανομή αγνώστου μέσου διανύσματος και μητρώου συνδιασποράς και τα m_j και S_j , τίθενται ίσα με τις προκύπτουσες εκτιμήσεις

-Όρισε

$$g_j(\mathbf{x}) = -(\mathbf{x} - \mathbf{m}_j)^T S_j^{-1} (\mathbf{x} - \mathbf{m}_j)$$

Χρήση ταξινομητή

-Για δεδομένο \mathbf{x} ,

-Υπολόγισε τις τιμές των $g_j(\mathbf{x})$, $j=1, \dots, M$.

-Καταχώρησε το \mathbf{x} στην κλάση k με $g_k(\mathbf{x}) = \max_{j=1, \dots, M} g_j(\mathbf{x})$.

ΣΗΜ: Γενικά, ο τετραγωνικός ταξινομητής **δεν είναι βέλτιστος** ως προς το κριτήριο της **πιθανότητας λάθους** (κάτω από ποιές συνθήκες ο ταξινομητής αυτός θα μπορούσε να είναι βέλτιστος;)