

Η GAUSSIAN ΣΥΝΑΡΤΗΣΗ ΠΥΚΝΟΤΗΤΑΣ ΠΙΘΑΝΟΤΗΤΑΣ

- Η συνάρτηση πυκνότητας πιθανότητας του αθροίσματος ενός πλήθους στατιστικώς ανεξάρτητων τυχαίων μεταβλητών, τείνει στη *Gaussian* συνάρτηση πυκνότητας πιθανότητας, όταν το πλήθος των όρων του αθροίσματος τείνει στο άπειρο.

Πολυμεταβλητή Gaussian συνάρτηση πυκνότητας πιθανότητας

$$p(x) = \frac{1}{(2\pi)^{l/2} |S|^{1/2}} \exp\left(-\frac{1}{2}(x - m)^T S^{-1}(x - m)\right)$$

$m = E[x]$ είναι το μέσο διάνυσμα

S είναι ο πίνακας συνδιασποράς

$$S = E[(x - m)(x - m)^T]$$

$|S|$ είναι η ορίζουσα του S

Η Gaussian καλείται και κανονική

Μονοδιάστατη περίπτωση

- $N(m, S)$

$$p(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{(x - m)^2}{2\sigma^2}\right)$$

- σ^2 είναι η διασπορά

Παράδειγμα 1^ο

- Υπολογίστε την τιμή της Gaussian συνάρτησης πυκνότητας πιθανότητας, $N(m,S)$, για

$$x_1 = [0.2, 1.3]^T \quad x_2 = [2.2, -1.3]^T$$

$$m = [0, 1]^T, \quad S = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$$

Παράδειγμα 2^ο

- Θεωρήστε πρόβλημα ταξινόμησης δύο κλάσεων στον δισδιάστατο χώρο, όπου τα δεδομένα και στις δύο κλάσεις, ακολουθούν Gaussian κατανομές, $N(m_1, S_1)$, $N(m_2, S_2)$.

$$m_1 = [1, 1]^T, \quad m_2 = [3, 3]^T, \quad S_1 = S_2 = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$$

- Υποθέτοντας ότι $P(\omega_1) = P(\omega_2)$, ταξινομήστε το διάνυσμα σε μία εκ των δύο κλάσεων.

Παράδειγμα 3^ο

- Δημιουργήστε $N=500$ δισδιάστατα σημεία δεδομένων που υπακούουν στην Gaussian κατανομή $N(m, S)$

$$m = [0, 0]^T$$

$$S = \begin{bmatrix} \sigma_1^2 & \sigma_{12} \\ \sigma_{12} & \sigma_2^2 \end{bmatrix}$$

$$\sigma_1^2 = \sigma_2^2 = 1, \sigma_{12} = 0$$

$$\sigma_1^2 = \sigma_2^2 = 0.2, \sigma_{12} = 0$$

$$\sigma_1^2 = \sigma_2^2 = 2, \sigma_{12} = 0$$

$$\sigma_1^2 = 0.2, \sigma_2^2 = 2, \sigma_{12} = 0$$

$$\sigma_1^2 = 2, \sigma_2^2 = 0.2, \sigma_{12} = 0$$

$$\sigma_1^2 = \sigma_2^2 = 1, \sigma_{12} = 0.5$$

$$\sigma_1^2 = 0.3, \sigma_2^2 = 2, \sigma_{12} = 0.5$$

$$\sigma_1^2 = 0.3, \sigma_2^2 = 2, \sigma_{12} = -0.5$$

- Όταν οι δύο συνιστώσες του x είναι ασυσχέτιστες και έχουν ίδια διασπορά, τα διανύσματα δεδομένων σχηματίζουν ομάδες «σφαιρικού σχήματος»
- Όταν οι δύο συνιστώσες του x είναι ασυσχέτιστες και με διαφορετική διασπορά, τα διανύσματα δεδομένων σχηματίζουν ελλειψοειδείς ομάδες.
- Η συντεταγμένη με την μεγαλύτερη διασπορά αντιστοιχεί στον «πρωτεύοντα άξονα» της ελλειψοειδούς ομάδας, ενώ η συντεταγμένη με τη μικρότερη διασπορά αντιστοιχεί στο «δευτερεύοντα άξονα».
- Επιπλέον, ο «πρωτεύων» και ο «δευτερεύων» άξονας του ελλειψοειδούς είναι παράλληλοι με τους καρτεσιανούς άξονες

- Όταν οι δύο συνιστώσες του x παρουσιάζουν συσχέτιση, ο «κύριος» και ο «δευτερεύων» άξονας της ελλειψοειδής ομάδας δεν είναι πλέον παράλληλοι με τους καρτεσιανούς άξονες.
- Ο βαθμός της περιστροφής ως προς τους καρτεσιανούς άξονες εξαρτάται από την τιμή της σ_{12}
- Η συσχέτιση επιδρά ανάλογα με το αν έχει θετική ή αρνητική τιμή
- Όταν $\sigma_{12} \neq 0$, τα δεδομένα σχηματίζουν ελλειψοειδείς ομάδες παρά το γεγονός ότι οι διασπορές ανά συνιστώσα είναι ίδιες.

ΤΑΞΙΝΟΜΗΤΕΣ ΕΛΑΧΙΣΤΗΣ ΑΠΟΣΤΑΣΗΣ

ΤΑΞΙΝΟΜΗΤΗΣ ΕΥΚΛΕΙΔΕΙΑΣ ΑΠΟΣΤΑΣΗΣ

Ο βέλτιστος Bayesian ταξινομητής απλοποιείται σημαντικά υιοθετώντας τις παρακάτω παραδοχές:

- Οι κλάσεις είναι ισοπίθανες.
- Τα δεδομένα σε όλες τις κλάσεις ακολουθούν Gaussian κατανομές.
- Το μητρώο συνδιασποράς είναι το *ίδιο* για όλες τις κλάσεις.
- Το μητρώο συνδιασποράς είναι διαγώνιο και όλα τα στοιχεία της διαγωνίου είναι μεταξύ τους *ίσα*. Δηλαδή, $S = \sigma^2 I$, όπου I ο ταυτοτικός πίνακας.

- Προκύπτει ότι ο βέλτιστος Bayesian ταξινομητής είναι ισοδύναμος με τον ταξινομητή ελάχιστης Ευκλείδειας απόστασης.
- Δηλαδή, το άγνωστο διάνυσμα x , ταξινομείται στην κλάση ω_i αν

$$\|x - m_i\| \equiv \sqrt{(x - m_i)^T (x - m_i)} < \|x - m_j\|, \quad \forall i \neq j$$

- Είναι αξιολογημένο ότι, εξαιτίας της απλότητάς του, ο ταξινομητής Ευκλείδειας απόστασης χρησιμοποιείται συχνά, ακόμα και όταν γνωρίζουμε ότι οι παραπάνω υποθέσεις δεν ισχύουν.
- Ταξινομεί ένα πρότυπο στην κλάση της οποίας η μέση τιμή είναι πλησιέστερα στο πρότυπο με βάση την Ευκλείδεια νόρμα.

ΤΑΞΙΝΟΜΗΤΗΣ ΜΑΗΑΛΑΝΟΒΙΣ ΑΠΟΣΤΑΣΗΣ

- Αν αφαιρέσουμε την υπόθεση που απαιτεί να είναι διαγώνιο το μητρώο συνδιασποράς και τα στοιχεία της διαγωνίου να είναι ίσα μεταξύ τους, τότε ο βέλτιστος Bayesian ταξινομητής γίνεται ισοδύναμος με τον ταξινομητή **ελάχιστης Mahalanobis απόστασης**.

$$\sqrt{(x - m_i)^T S^{-1} (x - m_i)} < \sqrt{(x - m_j)^T S^{-1} (x - m_j)}, \quad \forall j \neq i$$

όπου S είναι το κοινό μητρώο συνδιασποράς

Παράδειγμα 4^ο

- Έστω πρόβλημα ταξινόμησης σε δύο κλάσεις στον τρισδιάστατο χώρο
- Να ταξινομηθεί το x με Ευκλίδειο και Mahalanobis ταξινομητή.

$$m_1 = [0, 0, 0]^T \quad m_2 = [0.5, 0.5, 0.5]^T$$

$$S = \begin{pmatrix} 0.8 & 0.01 & 0.01 \\ 0.01 & 0.2 & 0.01 \\ 0.01 & 0.01 & 0.2 \end{pmatrix}$$

$$x = [0.1, 0.5, 0.1]^T$$