


# ΑΝΑΓΝΩΡΙΣΗ ΠΡΟΤΥΠΩΝ (PATTERN RECOGNITION)

**Σέργιος Θεοδωρίδης**  
**Κωνσταντίνος Κουτρούμπας**



## (B) ΜΗ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

### Η Bayesian περίπτωση

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

- Στο πλαίσιο αυτό, η τιμή κάθε pdf  $p(\mathbf{x} | \omega_j)$  που εμπλέκεται στον ταξινομητή Bayes για δεδομένο  $\mathbf{x}$  εκτιμάται βασιζόμενη άμεσα στα σημεία του  $X_j$ .

Δύο βασικές μέθοδοι της κατηγορίας αυτής

- Parzen windows

- Εκτίμηση πυκνότητας με βάση του k-πλησιέστερους γείτονες (k-nearest neighbor (NN) density estimation)

### Το πρόβλημα:

- Έστω  $Y = \{\mathbf{x}_1, \dots, \mathbf{x}_N\}$  δεδομένο σύνολο διανυσμάτων που έχουν προκύψει από άγνωστη pdf,  $p(\mathbf{x})$ .

- **Στόχος:** Εκτίμηση της τιμής της  $p(\mathbf{x})$  σε δεδομένο σημείο  $\mathbf{x}$  με βάση το σύνολο  $Y$ .




## (B) ΜΗ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

Η Bayesian περίπτωση – Μερικά προκαταρκτικά

1. η **σππ**  $p(x)$  τυχαίας μεταβλητής  $x$  μπορεί να **προσεγγιστεί** από **ιστόγραμμα** (με **μέγεθος bin**  $h$ ), με βάση ένα σύνολο  $N$  δειγμάτων.
2. Η **τιμή της σππ** θεωρείται **σταθερή** σε όλο το εύρος ενός **bin**.
3. Η **πιθανότητα**  $P$  που αντιστοιχεί σε **δεδομένο bin** **προσεγγίζεται** ως  $k_N / N$  ( $k_N$  είναι ο αριθμός των σημείων που ανήκουν στο bin), δηλ.,  $P \approx k_N / N$ .
4. Εστιάζοντας σε **συγκεκριμένο bin** και λαμβάνοντας υπ' όψιν ότι
  - (a)  $P \equiv P(x-h/2 < x < x+h/2) \approx p(x_{mean}) * h$  ( $x_{mean}$  είναι το **μέσο** του **bin**) και
  - (b) Την παρατήρηση 2 πιο πάνω, έχουμε ότι η  $p(x)$ , για κάθε  $x$  μέσα στο bin ικανοποιεί προσεγγιστικά την  $P \approx p(x) * h$ .
5. Από τις παρατηρήσεις 3 και 4, συμπεραίνουμε ότι **για κάθε  $x$  σε δεδομένο bin** έχουμε

$$p(x) \approx \frac{1}{h} \frac{k_N}{N}, \quad |x - x_{mean}| \leq \frac{h}{2}$$



$$x_{mean} - \frac{h}{2} \quad x_{mean} \quad x_{mean} + \frac{h}{2}$$



## (B) ΜΗ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

### Η Bayesian περίπτωση – Μερικά προκαταρκτικά

6. Αν η  $p(x)$  είναι **συνεχής**, η **εκτίμηση της  $p(x)$  για οποιοδήποτε  $x$**  προσεγγίζει την **πραγματική τιμή  $p(x)$** , υπό τις προϋποθέσεις ότι **(a)  $h \rightarrow 0$** , **(b)  $k_N \rightarrow \infty$**  and **(c)  $k_N / N \rightarrow 0$** , καθώς  $N \rightarrow \infty$ .




Διαμερισμός σε bins χώρων μεγαλύτερης διάστασης

(**τετράγωνα** στη **2-διάστατη** περίπτωση, **κύβοι** στην **3-διάστατη** περίπτωση).

## (B) ΜΗ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ


### Η Bayesian περίπτωση – Parzen windows



## (B) ΜΗ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ


### Η Bayesian περίπτωση – Parzen windows

**Παράδειγμα:** Έστω τα ακόλουθα  $N=6$  σημεία δεδομένων (μαύρες κουκκίδες), τα οποία προέρχονται από μία άγνωστη κατανομή  $p(x)$ . Για  $h=1$ , να εκτιμήσετε την τιμή της συν. πυκν. πιθ. για την **κόκκινη** κουκκίδα.



- Κεντράρουμε υπερκύβο πλευράς  $h$  σε κάθε σημείο δεδομένων  
- Μετράμε σε πόσους υπερκύβους ανήκει το υπό μελέτη σημείο (**κόκκινη κουκκίδα**)  
→  $k=3 \rightarrow P = k/N = 3/6 \rightarrow p(x) = (1/h^2) * P = 0.5$

- Κεντράρουμε υπερκύβο πλευράς  $h$  στο υπό μελέτη σημείο (**κόκκινη κουκκίδα**)  
- Μετράμε πόσα σημεία δεδομένων ανήκουν στον υπερκύβο  
→  $k=3 \rightarrow P = k/N = 3/6 \rightarrow p(x) = (1/h^2) * P = 0.5$





➤ Ορίζουμε

$$\phi(\underline{x}_i) = \left\{ \begin{array}{l} 1 \quad |x_{ij}| \leq 1/2 \\ 0 \quad \text{διαφορετικά} \end{array} \right\}$$

- Δηλαδή, ισούται με 1 μέσα σε υπερκύβο μοναδιαίας πλευράς με κέντρο το 0

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

- $(1/\text{όγκος}) * (1/N) * \text{πλήθος σημείων εντός υπερκύβου πλευράς } h \text{ κεντραρισμένου στο } \underline{x}$ .

- Το πρόβλημα:  $p(\underline{x})$  συνεχής  
 $\phi(\cdot)$  ασυνεχής

- Παράθυρα Parzen-Πυρήνες-συναρτήσεις δυναμικού  
 $\phi(\underline{x})$  είναι ομαλή

$$\phi(\underline{x}) \geq 0, \quad \int_{\underline{x}} \phi(\underline{x}) d\underline{x} = 1$$

## (B) ΜΗ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

### Η Bayesian περίπτωση – Parzen windows

Αν  $\varphi(x)=N(0,1)$  τότε

$$\hat{p}(\mathbf{x}) = \frac{1}{N} \sum_{i=1}^N \frac{1}{(2\pi)^{\frac{l}{2}} h^l} \exp\left(-\frac{(\mathbf{x}-\mathbf{x}_i)^T(\mathbf{x}-\mathbf{x}_i)}{2h^2}\right)$$

**Παράδειγμα:** Εκτίμηση της τιμής κανονικής κατανομής  $N(0,1)$  στο σημείο  $x=1$ .

Παράγουμε  $n$  σημεία από την κατανομή και εκτιμούμε την  $p(1)$  ( $=0,2420$ ) για δεδομένα  $h$ .

	<b>h=0.01</b>	<b>h=0.05</b>	<b>h=0.1</b>	<b>h=0.5</b>	<b>h=0.8</b>
<b>n= 100</b>	0.1635	0.4750	0.1455	0.2305	0.2464
<b>n= 1000</b>	0.1776	0.2428	0.2629	0.2270	0.2211
<b>n= 10000</b>	0.2662	0.2415	0.2437	0.2365	0.2317
<b>n= 100000</b>	0.2543	0.2424	0.2403	0.2378	0.2304
<b>n= 1000000</b>	0.2413	0.2415	0.2406	0.2394	0.2296


## (B) ΜΗ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

### Η Bayesian περίπτωση – Parzen windows

➤ Διασπορά


- Όσο **μικρότερο** το  $h$ , τόσο **μεγαλύτερη** η διασπορά

$h=0.1, N=1000$



(a)


$h=0.8, N=1000$



(b)

(B) ΜΗ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ  
Η Bayesian περίπτωση – Parzen windows

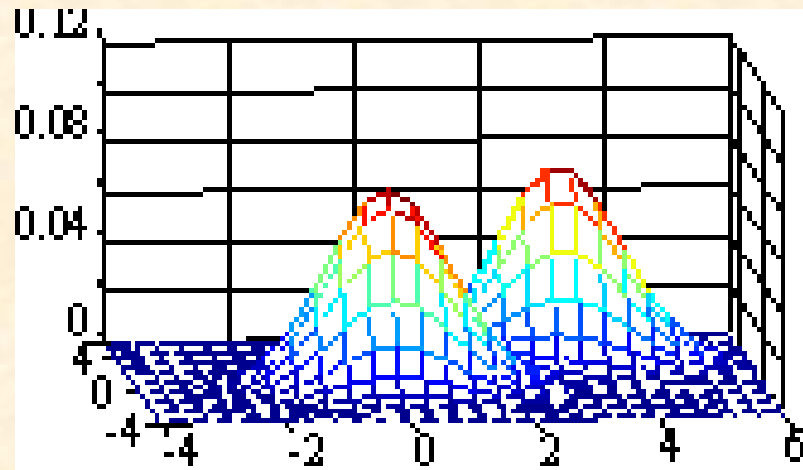
$h=0.1, N=10000$




➤ Όσο μεγαλύτερο το  $N$ , τόσο καλύτερη η ακρίβεια

## (B) ΜΗ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

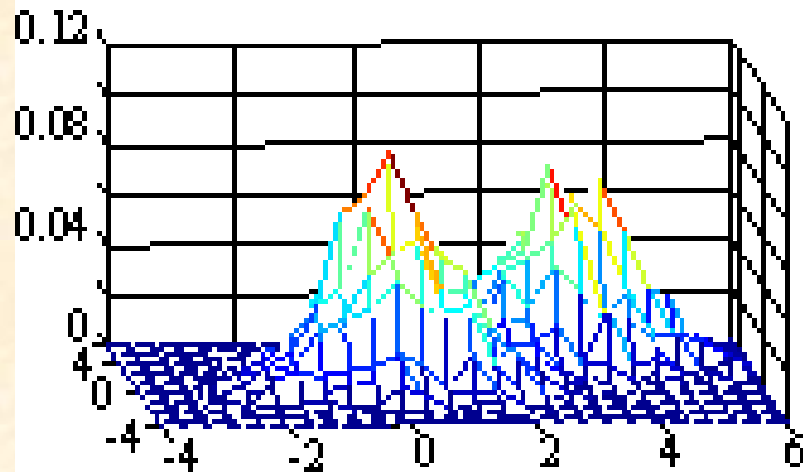
Η Bayesian περίπτωση – Parzen windows




(a)



(b)



(c)



(d)

(a) αρχ. κατανομή, (b)  $h=0.05$ ,  $N=1000$ , (c)  $h=0.05$ ,  $N=20000$ , (d)  $h=0.8$ ,  $N=20000$

## (B) ΜΗ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

### Η Bayesian περίπτωση – Parzen windows

- Έστω  $Y = \{\mathbf{x}_1, \dots, \mathbf{x}_N\}$  δεδομένο σύνολο διανυσμάτων που έχουν προκύψει από άγνωστη pdf,  $p(\mathbf{x})$ .

- **Στόχος:** Εκτίμησε την τιμή της  $p(\mathbf{x})$  σε δεδομένο σημείο  $\mathbf{x}$  με βάση το σύνολο  $Y$ .




- Η **ιδέα:** Προσέγγισε την  $p(\mathbf{x})$  με μια **μίξη συναρτήσεων πυρήνων** κεντραρισμένων στα  $\mathbf{x}_i$  του  $Y$ , οι οποίες μειώνονται πολύ γρήγορα γύρω από αυτά.

Μια συνηθισμένη συνάρτηση πυρήνων: Η **Gaussian**. Έτσι

$$p(\mathbf{x}) = \frac{1}{N} \sum_{i=1}^N \frac{1}{(2\pi)^{l/2} h^l} \exp\left(-\frac{(\mathbf{x} - \mathbf{x}_i)^T (\mathbf{x} - \mathbf{x}_i)}{2h^2}\right)$$

όπου  $h$  (η τυπική απόκλιση) καθορίζεται από το **χρήστη**.


Συγκρίνετε τα Parzen windows με τη μίξη των Gaussians που συζητήθηκε προηγουμένως



## (B) ΜΗ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

### Η Bayesian περίπτωση – Parzen windows

**Παράδειγμα:** Έστω τα ακόλουθα  $N=6$  σημεία δεδομένων (μαύρες κουκκίδες), τα οποία προέρχονται από μία άγνωστη κατανομή  $p(\mathbf{x})$ . Να εκτιμήσετε την τιμή της συν. πυκν. πιθ. για την **κόκκινη** κουκκίδα, θεωρώντας ότι η  $p(\mathbf{x})$  είναι το σταθμισμένο άθροισμα  $N$  κανονικών κατανομών  $N(\mathbf{x}_i, h^2)$ ,  $i=1, \dots, 6$ .



- Κεντράρουμε μία κανονική κατανομή  $N(\mathbf{x}_i, h^2)$  σε κάθε σημείο δεδομένων
- Υπολογίζουμε την τιμή κάθε κατανομής στο υπό μελέτη σημείο (**κόκκινη κουκκίδα**)
- Υπολογίζουμε το μέσο όρο των παραπάνω τιμών.

## (B) ΜΗ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

### Η Bayesian περίπτωση – Parzen windows

Θεωρείστε ένα πρόβλημα  $c$  κλάσεων με εμπλεκόμενες κλάσεις τις  $\omega_1, \dots, \omega_c$ .

Υπάρχουν  $N_j$  διαθέσιμα σημεία από κάθε κλάση  $\omega_j$ ,  $j=1, \dots, c$ , με  $N_1 + \dots + N_c = N$ .

**Πρόβλημα:** Ταξινομήστε δεδομένο σημείο  $\mathbf{x}$  σε μία από τις παραπάνω κλάσεις, κάνοντας χρήση της τεχνικής των Parzen windows.

-Υπολόγισε τις **συναρτήσεις διάκρισης**,  $j=1, \dots, c$

$$g_j(\mathbf{x}) = (2\pi)^{l/2} h^l P(\omega_j) p(\mathbf{x} | \omega_j) = \frac{P(\omega_j)}{N_j} \sum_{i=1}^{N_j} \exp\left(-\frac{(\mathbf{x} - \mathbf{x}_i)^T (\mathbf{x} - \mathbf{x}_i)}{2h^2}\right)$$

- Καταχώρησε το  $\mathbf{x}$  στην κλάση  $\omega_q$  για την οποία  $\mathbf{g}_q(\mathbf{x}) = \max_{j=1, \dots, c} \mathbf{g}_j(\mathbf{x})$ .

-Αν επιπλέον **προσεγγίσουμε**  $P(\omega_j) \approx N_j/N$ ,  $j=1, \dots, c$  και επανορίσουμε την  $\mathbf{g}_j(\mathbf{x})$  ως

$$g'_j(\mathbf{x}) = N(2\pi)^{l/2} h^l P(\omega_j) p(\mathbf{x} | \omega_j) = \sum_{i=1}^{N_j} \exp\left(-\frac{(\mathbf{x} - \mathbf{x}_i)^T (\mathbf{x} - \mathbf{x}_i)}{2h^2}\right)$$

έχουμε:

καταχώρησε το  $\mathbf{x}$  στην κλάση  $\omega_q$  για την οποία

$$\mathbf{g}_q(\mathbf{x}) = \max_{j=1, \dots, c} \mathbf{g}_j(\mathbf{x}) \Leftrightarrow \mathbf{g}'_q(\mathbf{x}) = \min_{j=1, \dots, c} \mathbf{g}'_j(\mathbf{x})$$



## (B) ΜΗ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

### Η Bayesian περίπτωση – Εκτίμηση πυκνότητας $k$ -NN


- Έστω  $Y = \{\mathbf{x}_1, \dots, \mathbf{x}_N\}$  δεδομένο σύνολο σημείων τα οποία προέρχονται από **άγνωστη pdf,  $p(\mathbf{x})$** .
- **Στόχος:** Εκτίμησε την τιμή της  $p(\mathbf{x})$  σε δεδομένο σημείο  $\mathbf{x}$ , με βάση το σύνολο  $Y$ .
- Η **ιδέα:**
- Διάλεξε μια τιμή για το  $k$ .
- Για δεδομένο  $\mathbf{x}$ , στο οποίο θέλουμε να εκτιμήσουμε την  $p(\mathbf{x})$ , κάνε τα ακόλουθα
  - Ανάμεσα στα σημεία του  $Y$ , προσδιόρισε τα  $k$  **εγγύτερα στο  $\mathbf{x}$**  σημεία
  - Προσδιόρισε τον **όγκο  $V(\mathbf{x})$**  της **υπερσφαίρας** με κέντρο το  $\mathbf{x}$  και **ακτίνα** ίση με την απόσταση του  $\mathbf{x}$  από το μακρύτερο από τα  $k$  παραπάνω σημεία.
  - Προσέγγισε την  $p(\mathbf{x})$  ως

$$p(\mathbf{x}) \approx \frac{k}{NV(\mathbf{x})}$$

## (B) ΜΗ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ


### Η Bayesian περίπτωση – Εκτίμηση πυκνότητας $k$ -NN

$$p(x) \approx \frac{k}{NV(x)} = \frac{\frac{k}{N}}{V(x)} \approx \frac{P}{V(x)} \Leftrightarrow P \approx p(x)V(x)$$



$$P(x < X < x+h) = \int_{-\infty}^{+\infty} p(y)dy \approx p(x) \cdot h$$

$$P(x < X < x+h) \approx k_n / N$$



## (B) ΜΗ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

### Η Bayesian περίπτωση – Εκτίμηση πυκνότητας $k$ -NN

Θεωρείστε ένα πρόβλημα  $c$  κλάσεων, με εμπλεκόμενες κλάσεις  $\omega_1, \dots, \omega_c$ .

Υπάρχουν  $N_j$  διαθέσιμα σημεία από κάθε κλάση  $\omega_j$ ,  $j=1, \dots, c$ , με  $N_1 + \dots + N_c = N$ .

**Πρόβλημα:** Ταξινόμηση δεδομένο σημείο  $\mathbf{x}$  σε μια από τις παραπάνω κλάσεις, χρησιμοποιώντας εκτιμήσεις πυκνότητας με βάση τους  $k$ -NN.

- Προσέγγισε  $p(\mathbf{x} | \omega_j) \approx k / N_j V_j(\mathbf{x})$ ,  $j=1, \dots, c$ .

- Υπολόγισε τις συναρτήσεις διάκρισης,  $j=1, \dots, c$

$$g_j(x) = \frac{1}{k} P(\omega_j) p(x | \omega_j) = \frac{1}{k} P(\omega_j) \frac{k}{N_j V_j(x)} = \frac{P(\omega_j)}{N_j V_j(x)}$$

- Καταχώρησε το  $\mathbf{x}$  στην κλάση  $\omega_q$  για την οποία  $g_q(\mathbf{x}) = \max_{j=1, \dots, c} g_j(\mathbf{x})$ .

- Αν επιπλέον προσεγγίσουμε  $P(\omega_j) \approx N_j / N$ ,  $j=1, \dots, c$  και επανορίσουμε την  $g_j(\mathbf{x})$  as

$$g'_j(x) = \frac{N}{k} P(\omega_j) p(x | \omega_j) = \frac{N}{k} \frac{N_j}{N} \frac{k}{N_j V_j(x)} = \frac{1}{V_j(x)}$$


έχουμε: καταχώρησε το  $\mathbf{x}$  στη κλάση  $\omega_q$  για την οποία

$$g_q(\mathbf{x}) = \max_{j=1, \dots, c} g_j(\mathbf{x}) \Leftrightarrow V_q(\mathbf{x}) = \min_{j=1, \dots, c} V_j(\mathbf{x})$$

## (B) ΜΗ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

### Η Bayesian περίπτωση – Εκτίμηση πυκνότητας $k$ -NN

Ένα παράδειγμα ταξινόμησης



➤  $k=5$

➤ Ισοπίθανες κλάσεις

➤ Το σημείο “\*” ταξινομείται στη **μπλε κλάση** αφού η **επιφάνεια του κύκλου** με κέντρο αυτό που περιέχει 5 σημεία από την μπλε κλάσης είναι μικρότερη από την αντίστοιχη για την **μαύρη κλάση**.

## (B) ΜΗ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

### Ο ταξινομητής των $k$ πλησιέστερων γειτόνων (k-nearest neighbor classifier (k-NN))

- Έστω

$$X = \{(x_i, d_i), x_i \in R^l, d_i \in \{1, 2, \dots, M\}, i = 1, \dots, N\}$$

δεδομένο σύνολο που περιέχει διανύσματα από  $M$  κλάσεις,  $\omega_1, \dots, \omega_M$ .

- **Στόχος:** Καταχώρησε δεδομένο διάνυσμα  $\mathbf{x}$  σε μια από τις παραπάνω κλάσεις, βασιζόμενος στο σύνολο  $X$ .

- Η **ιδέα:**

- Διάλεξε μία (περιττή) τιμή για το  $k$ .

- Για δεδομένο  $\mathbf{x}$

➤ **Προσδιόρισε** τους  $k$  πλησιέστερους γείτονες του από το σύνολο  $X$ .

➤ Ανάμεσα στα  $k$  σημεία έστω  $k_j$  εκείνα τα οποία προέρχονται από την  $j$ -στη κλάση,  $j=1, \dots, M$  (εδώ μπορούμε να ορίσουμε  $g_j(\mathbf{x})=k_j$ ).

➤ **Καταχώρησε** το  $\mathbf{x}$  στην κλάση  $\omega_q$  για την οποία  $k_q = \max_{j=1, \dots, M} k_j$ .

**Ένα μειονέκτημα:** Αυξημένη υπολογιστική πολυπλοκότητα ( $O(N)$ ) για κάθε διάνυσμα

## (B) ΜΗ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

### Ο ταξινομητής των k πλησιέστερων γειτόνων (k-nearest neighbor classifier (k-NN))

#### Μερικά θεωρητικά αποτελέσματα

Έστω  $P_B$  η πιθανότητα λάθους του ταξινομητή Bayes.

-Για τον ταξινομητή του **1-πλησιέστερου γείτονα** (1-Nearest neighbor ή, απλά, **NN**) είναι

$$P_B \leq P_{NN} \leq P_B \left( 2 - \frac{M}{M-1} P_B \right) \leq 2P_B$$

-Για τον ταξινομητή k-πλησιέστερων γειτόνων είναι

$$P_B \leq P_{kNN} \leq P_B + \sqrt{\frac{2P_{NN}}{k}}$$

$$k \rightarrow \infty, P_{kNN} \rightarrow P_B$$

Συσχέτιση του ταξινομητή **kNN** με τον **ταξινομητή που βασίζεται στην εκτίμηση της πυκνότητας με βάση τους k-πλησιέστερους γείτονες**: Είναι ισοδύναμοι για  $k=1$  (Γιατί;)

## (B) ΜΗ ΠΑΡΑΜΕΤΡΙΚΟΙ ΤΑΞΙΝΟΜΗΤΕΣ ΒΑΣΙΣΜΕΝΟΙ ΣΕ ΣΥΝΑΡΤΗΣΕΙΣ ΔΙΑΚΡΙΣΗΣ

### Ο ταξινομητής των k πλησιέστερων γειτόνων (k-nearest neighbor classifier (k-NN))

Μια γεωμετρική άποψη για τον ταξινομητή του πλησιέστερου γείτονα -NN classifier

Ο ταξινομητής πλησιέστερου γείτονα **διαμερίζει** το χώρο  $R^l$  σε  **$N$  περιοχές** (τόσες, όσες είναι και τα στοιχεία του συνόλου  $X$ ) έτσι ώστε

$$R_i = \{ \underline{x} : d(\underline{x}, \underline{x}_i) = \min_{j=1, \dots, N} d(\underline{x}, \underline{x}_j) \}$$

