

Ανάλυση Συστάδων (Cluster Analysis)

(για το μάθημα «Αναλυτική Δεδομένων & Μηχανική Μάθηση»)

Γιάννης Θεοδωρίδης

Εργαστήριο Επιστήμης Δεδομένων (Data Science Lab.)
www.datastories.org

Πηγές

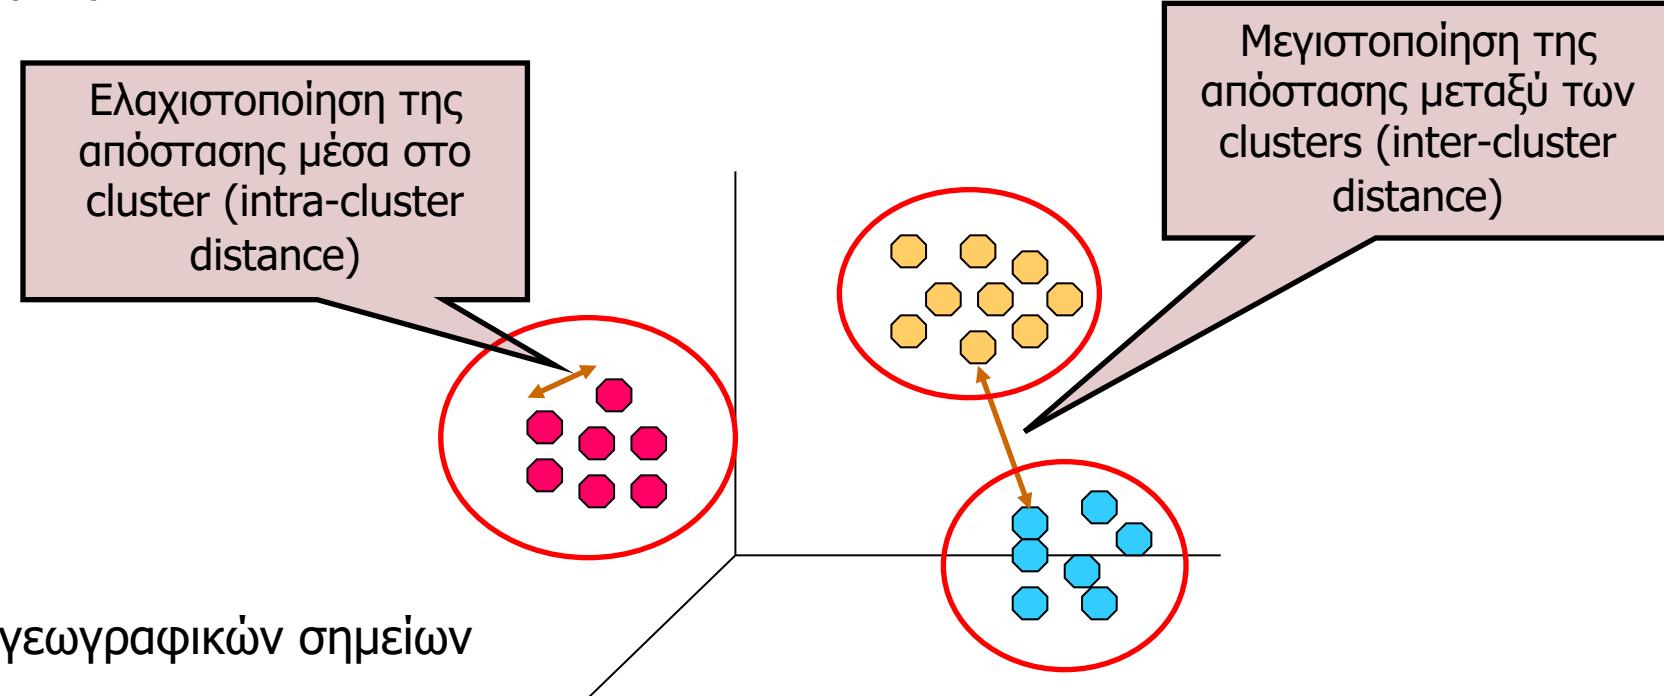
- Dunham: Data Mining – Introductory and Advanced Topics. Prentice Hall, 2003.
- Tan, Steinbach, Kumar: Introduction to Data Mining. Addison Wesley, 2006.
- Online από το διαδίκτυο κ.α.

Περιεχόμενα

- Το πρόβλημα της συσταδοποίησης
- Τεχνικές διαμέρισης (k-means)
- Τεχνικές βασισμένες στην πυκνότητα (DBSCAN, OPTICS)

Το πρόβλημα της συσταδοποίησης (1)

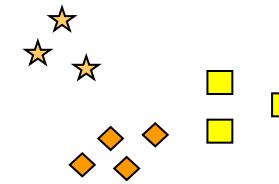
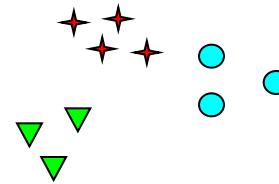
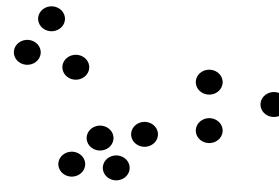
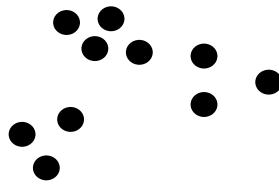
- **Διαμέριση (partitioning)** ενός συνόλου δεδομένων σε ομάδες (συστάδες) με βάση κάποιο κριτήριο ομοιότητας.



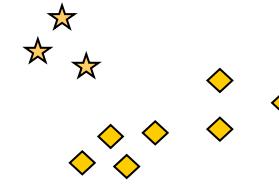
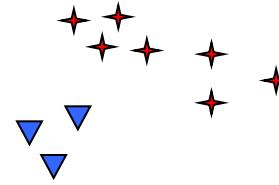
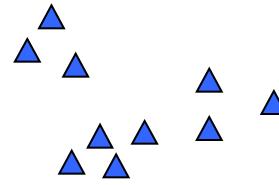
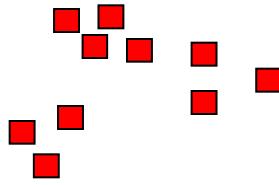
- Εφαρμογές
 - Ομαδοποίηση γεωγραφικών σημείων
 - Αναγνώριση νέων ειδών φυτών
 - Αναγνώριση παρόμοιων προτύπων στη χρήση του Web.

Το πρόβλημα της συσταδοποίησης (2)

- **Δεν έχει μία και μόνη λύση** – ποια είναι η βέλτιστη;



6 συστάδες (;)



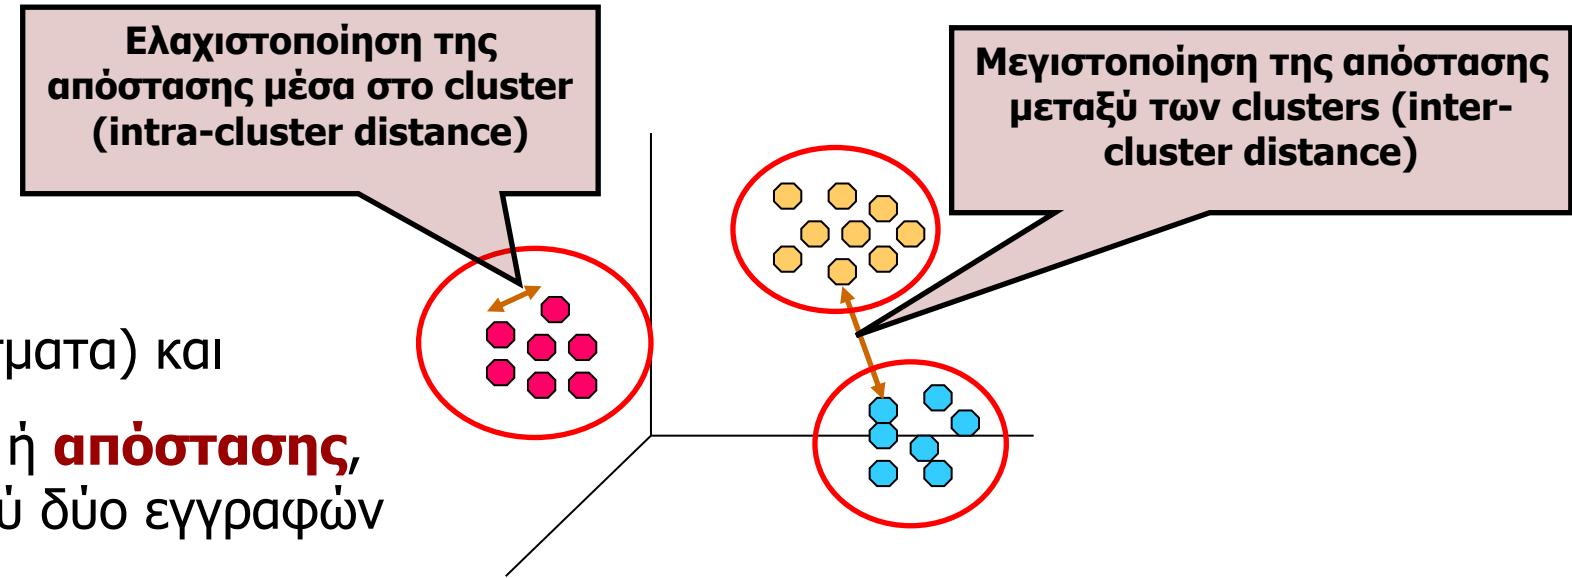
2 συστάδες (;)

4 συστάδες (;)

Το πρόβλημα της συσταδοποίησης (3)

Δοθέντων:

- ενός συνόλου δεδομένων $D=\{t_1, t_2, \dots, t_n\}$ από η εγγραφές (στοιχεία, διανύσματα) και
- ενός **μέτρου ομοιότητας** ή **απόστασης**, $\text{sim}(t_i, t_j)$ ή $\text{dist}(t_i, t_j)$ μεταξύ δύο εγγραφών του συνόλου δεδομένων



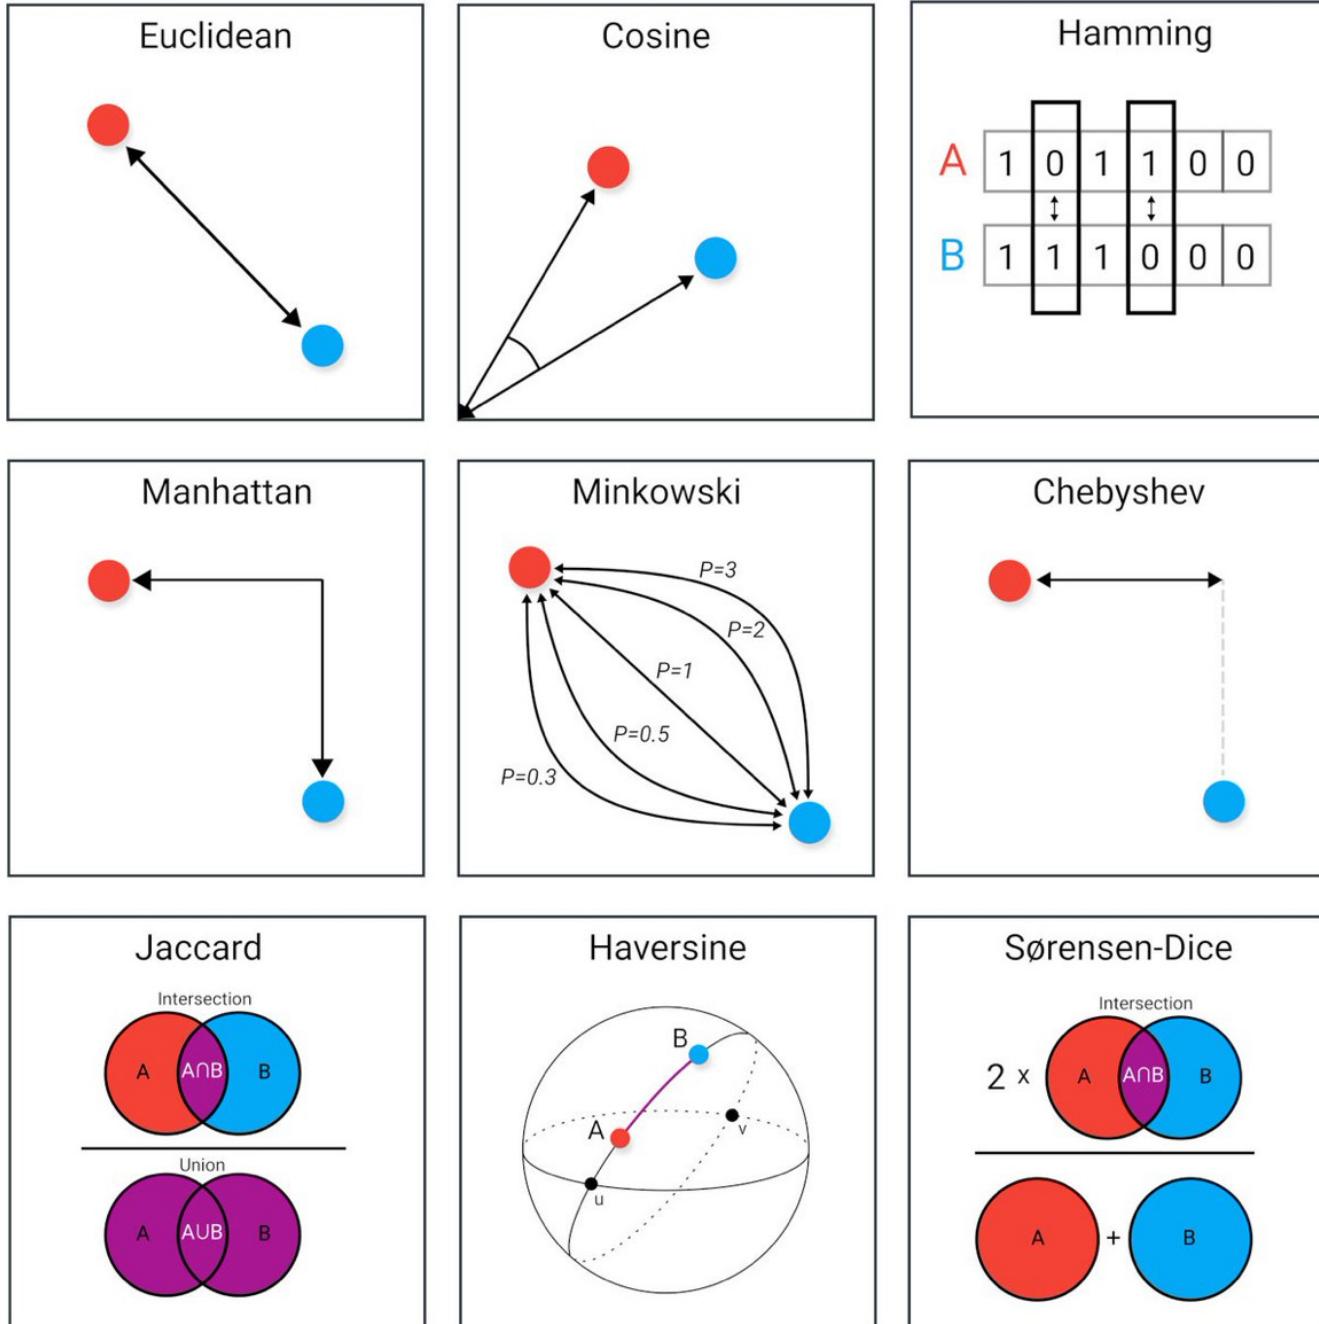
το **Πρόβλημα της Συσταδοποίησης** είναι η διαμέριση του συνόλου δεδομένων σε υποσύνολα (συστάδες), έτσι ώστε:

- να ελαχιστοποιείται η απόσταση μεταξύ των στοιχείων που ανήκουν στην ίδια συστάδα (intra-cluster distance).
- να μεγιστοποιείται η απόσταση μεταξύ των στοιχείων που ανήκουν σε διαφορετικές συστάδες (inter-cluster distance).

Μέτρα ομοιότητας / απόστασης

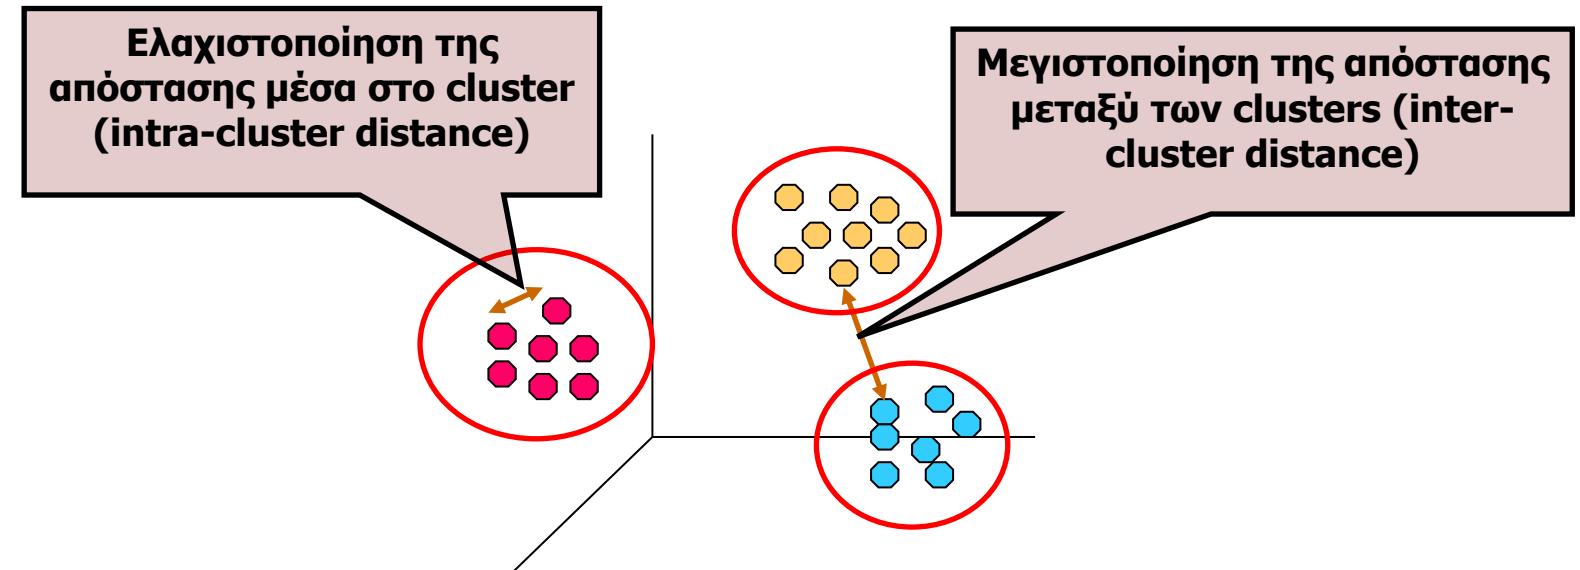
- Επιθυμητές ιδιότητες ενός μέτρου απόστασης **d** (για να ονομαστεί «**μετρική**»):

- $d(x,y) = 0$ iff $x=y$
- $d(x,y) = d(y,x)$
- $d(x,y) \leq d(x,z) + d(z,y)$



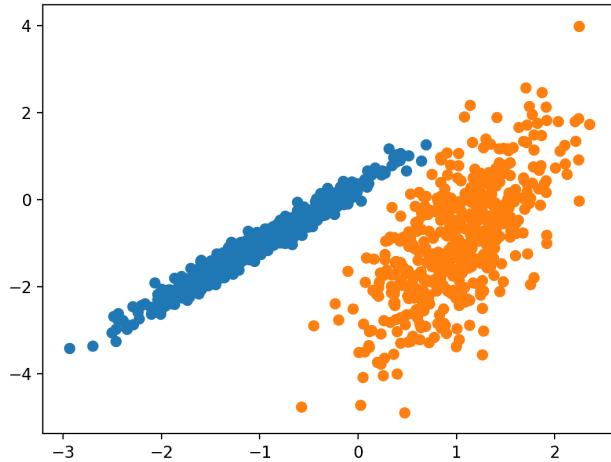
Ζητήματα στη Συσταδοποίηση

- Ποια δεδομένα θα χρησιμοποιηθούν;
 - Επιθυμούμε όλα τα δεδομένα να ενταχθούν σε συστάδες ή να μπορούν να εντοπιστούν ακραίες τιμές – «θόρυβος» (outliers / noise);
- Ποιος αλγόριθμος θα χρησιμοποιηθεί;
 - π.χ. γνωρίζουμε τον αριθμό συστάδων που στοχεύουμε;
- Πώς ερμηνεύουμε και αξιολογούμε το όποιο αποτέλεσμα;
 - π.χ. ποιο είναι το καλύτερο αποτέλεσμα; αυτό με τα 2 ή με τα 3 clusters;

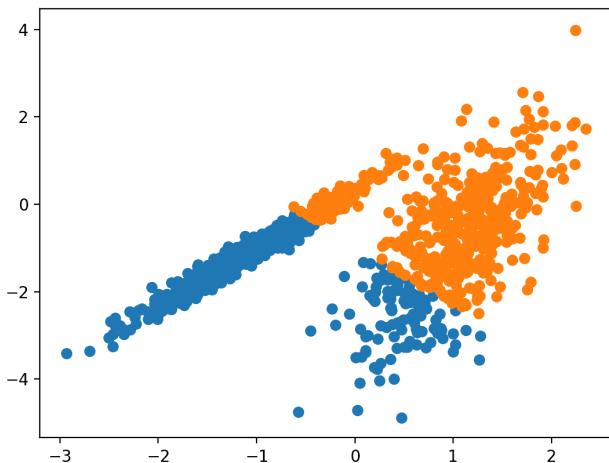


Ποιος αλγόριθμος (1);

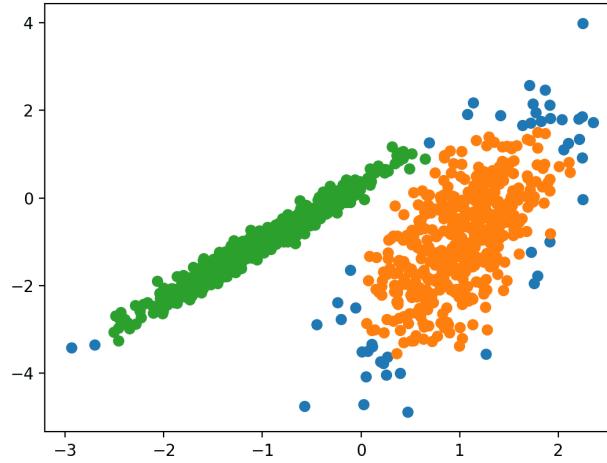
Synthetic dataset (2 clusters)



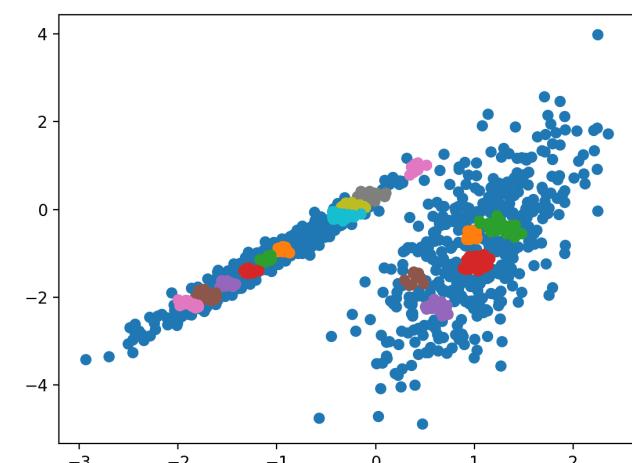
k-Means



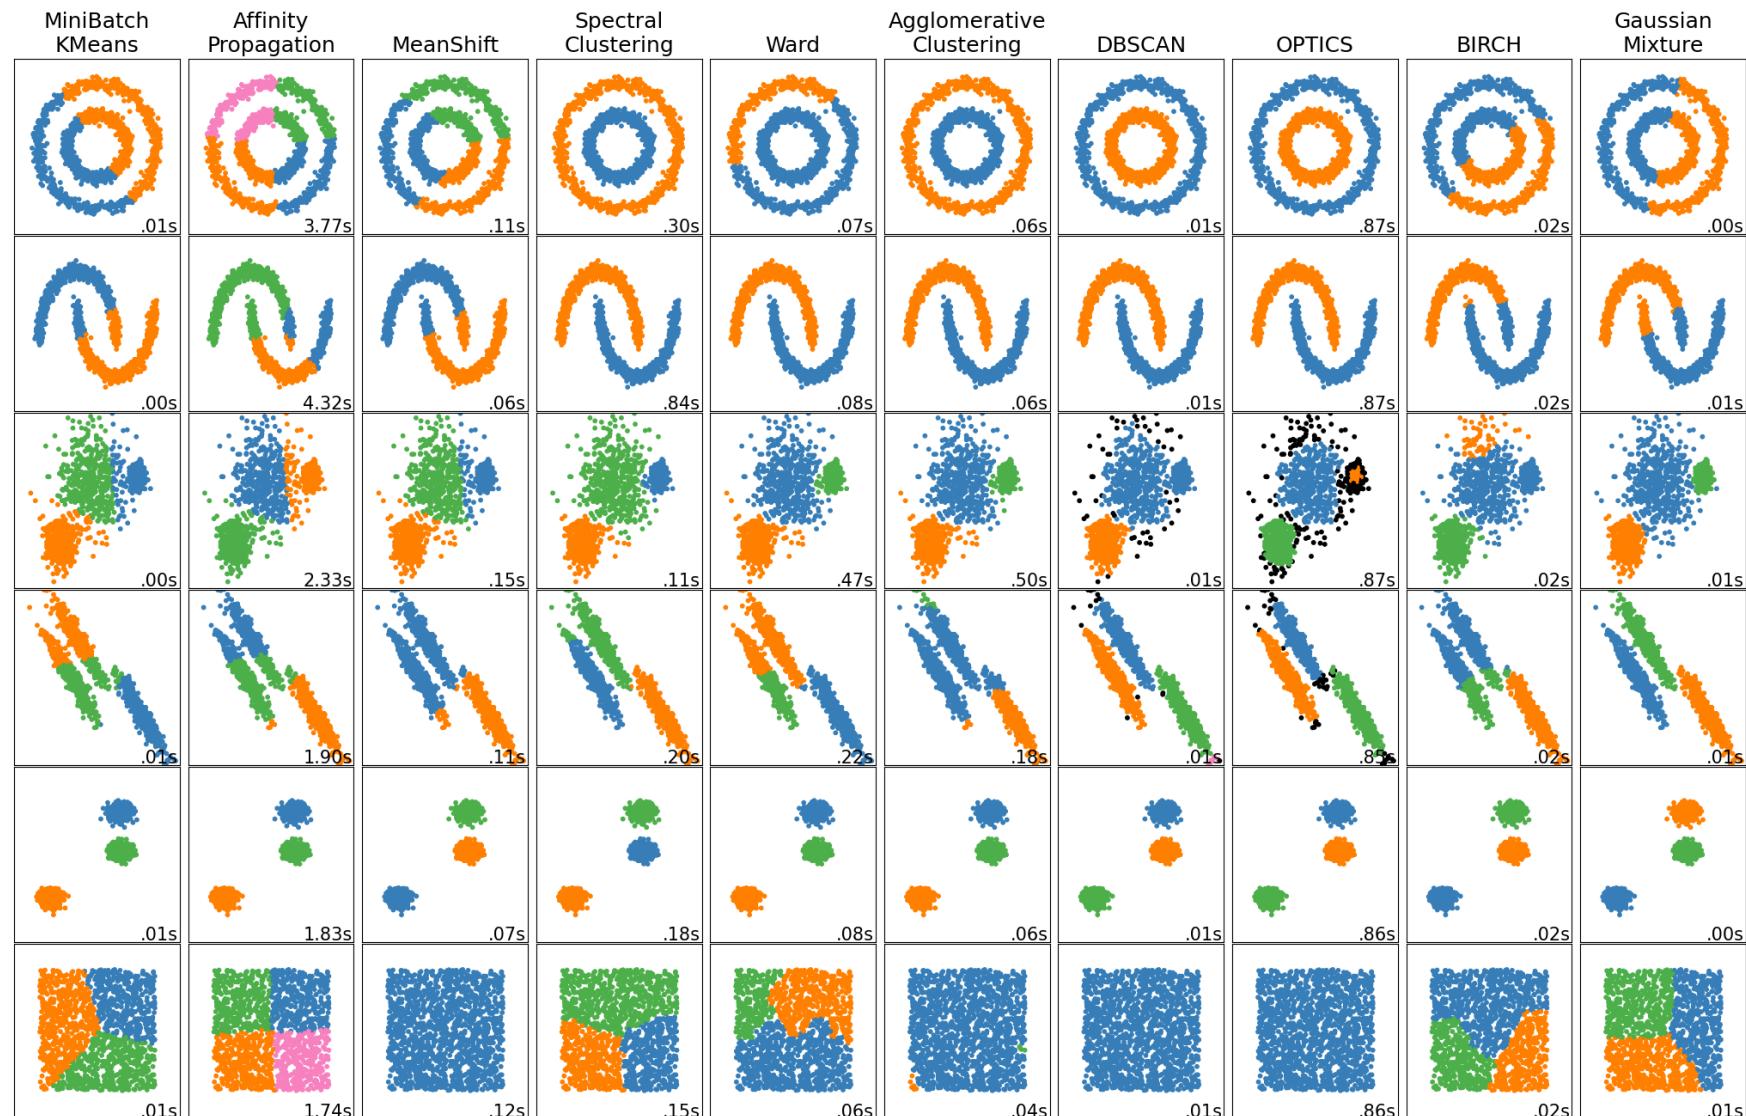
DBSCAN



OPTICS



Ποιος αλγόριθμος (2);



πηγή: https://scikit-learn.org/stable/auto_examples/cluster/plot_cluster_comparison.html

Συσταδοποίηση με Διαμέριση



- Ζήτημα: ο χρήστης απαιτείται να εισάγει τον επιθυμητό αριθμό των συστάδων, k. Όμως ...
 - Οι πιθανοί συνδυασμοί η στοιχείων σε k συστάδες είναι ένας πολύ μεγάλος αριθμός
 - Αναγκαστικά, η αναζήτηση γίνεται σε ένα μικρό υποσύνολο των πιθανών λύσεων
- Η πιο δημοφιλής τεχνική: **K-Μέσων** (K-means)
 - και πολλές άλλες τεχνικές βασισμένες σε γενετικούς αλγορίθμους, νευρωνικά δίκτυα κ.α.

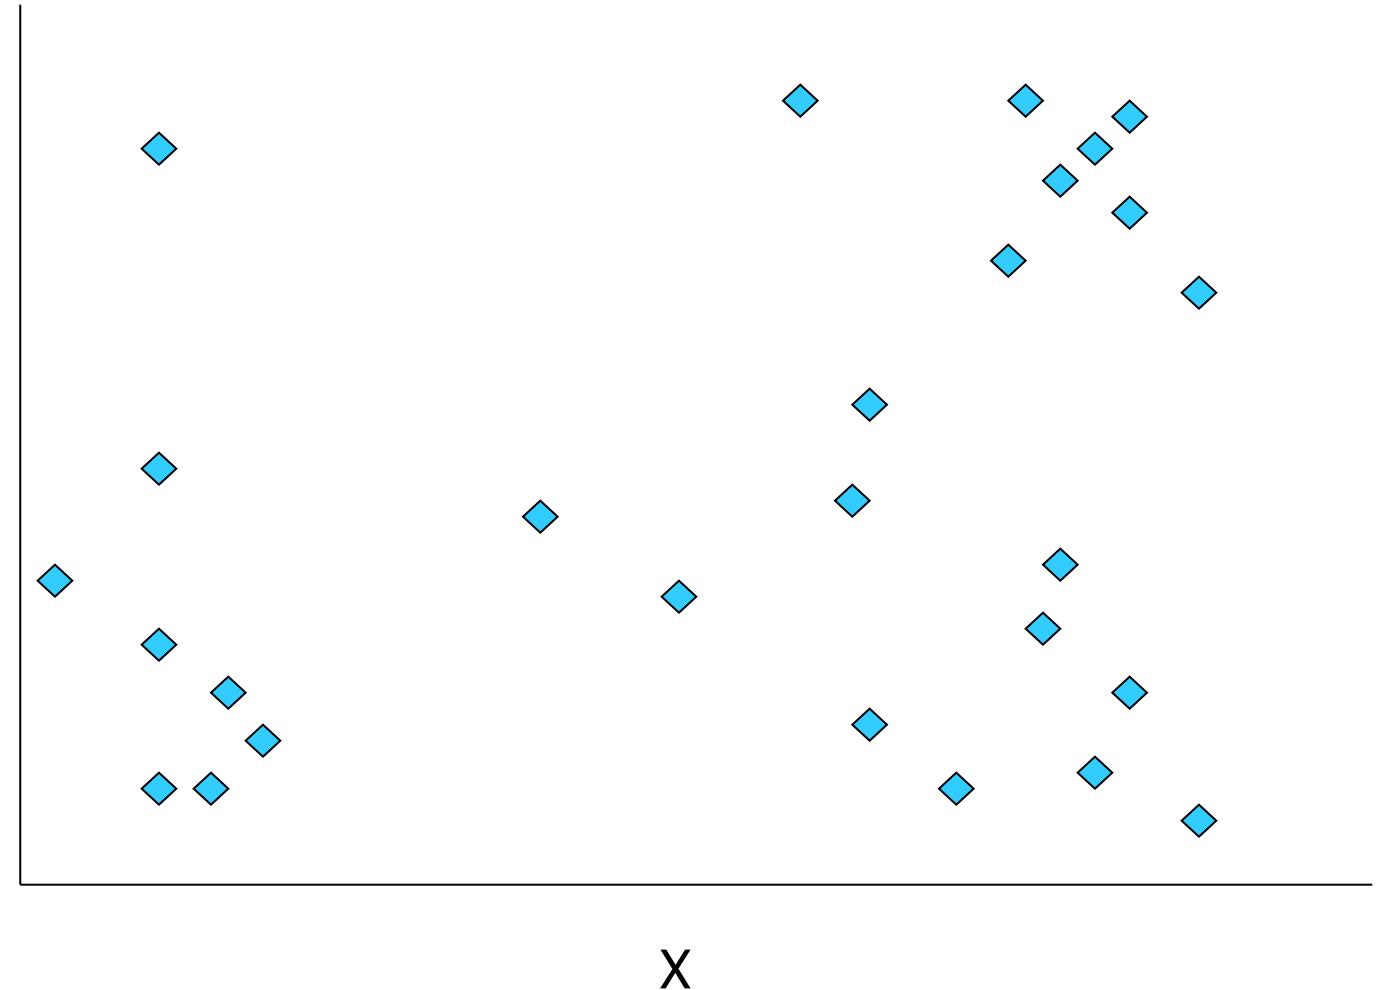
Συσταδοποίηση K-Means

- Βασική ιδέα:

- Τυχαία επιλέγεται το αρχικό σύνολο των μέσων⁽¹⁾ των συστάδων
- Επαναληπτικά, τα στοιχεία μετακινούνται μεταξύ των συστάδων μέχρι να επιτύχουμε ισορροπία

(1) Δεδομένης μίας συστάδας $K = \{t_1, t_2, \dots, t_m\}$, ο **μέσος ή κέντρο βάρους** (centroid) **της συστάδας** είναι $m = (1/m)(t_1 + \dots + t_m)$

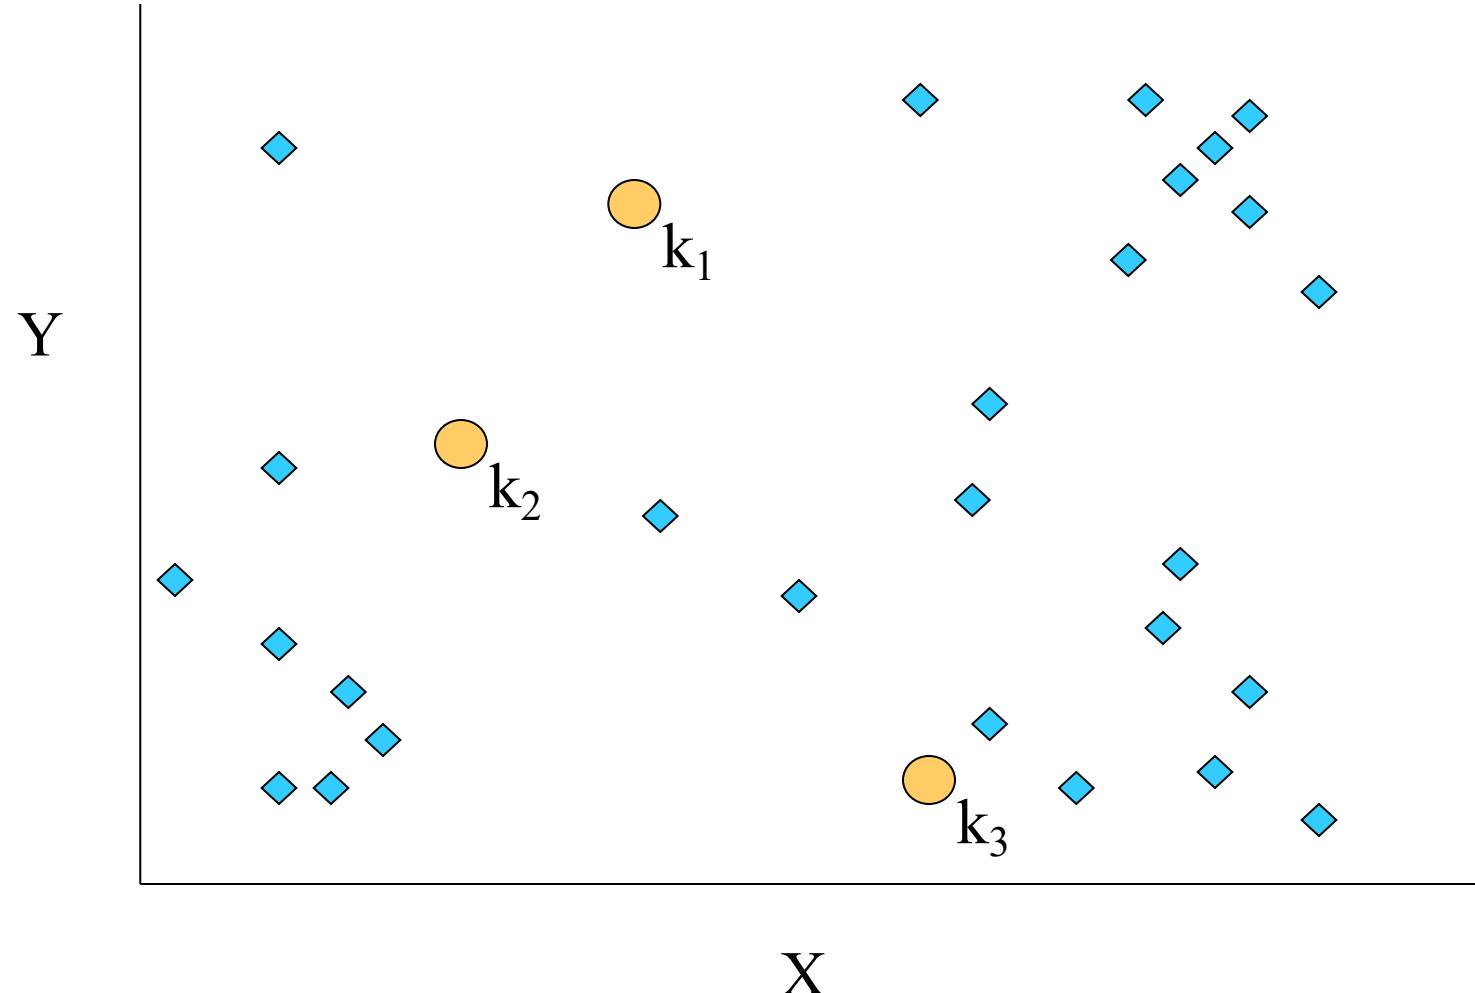
$k=2; k=3; k=4; \dots$



K-means visualization: <https://www.naftaliharris.com/blog/visualizing-k-means-clustering/>

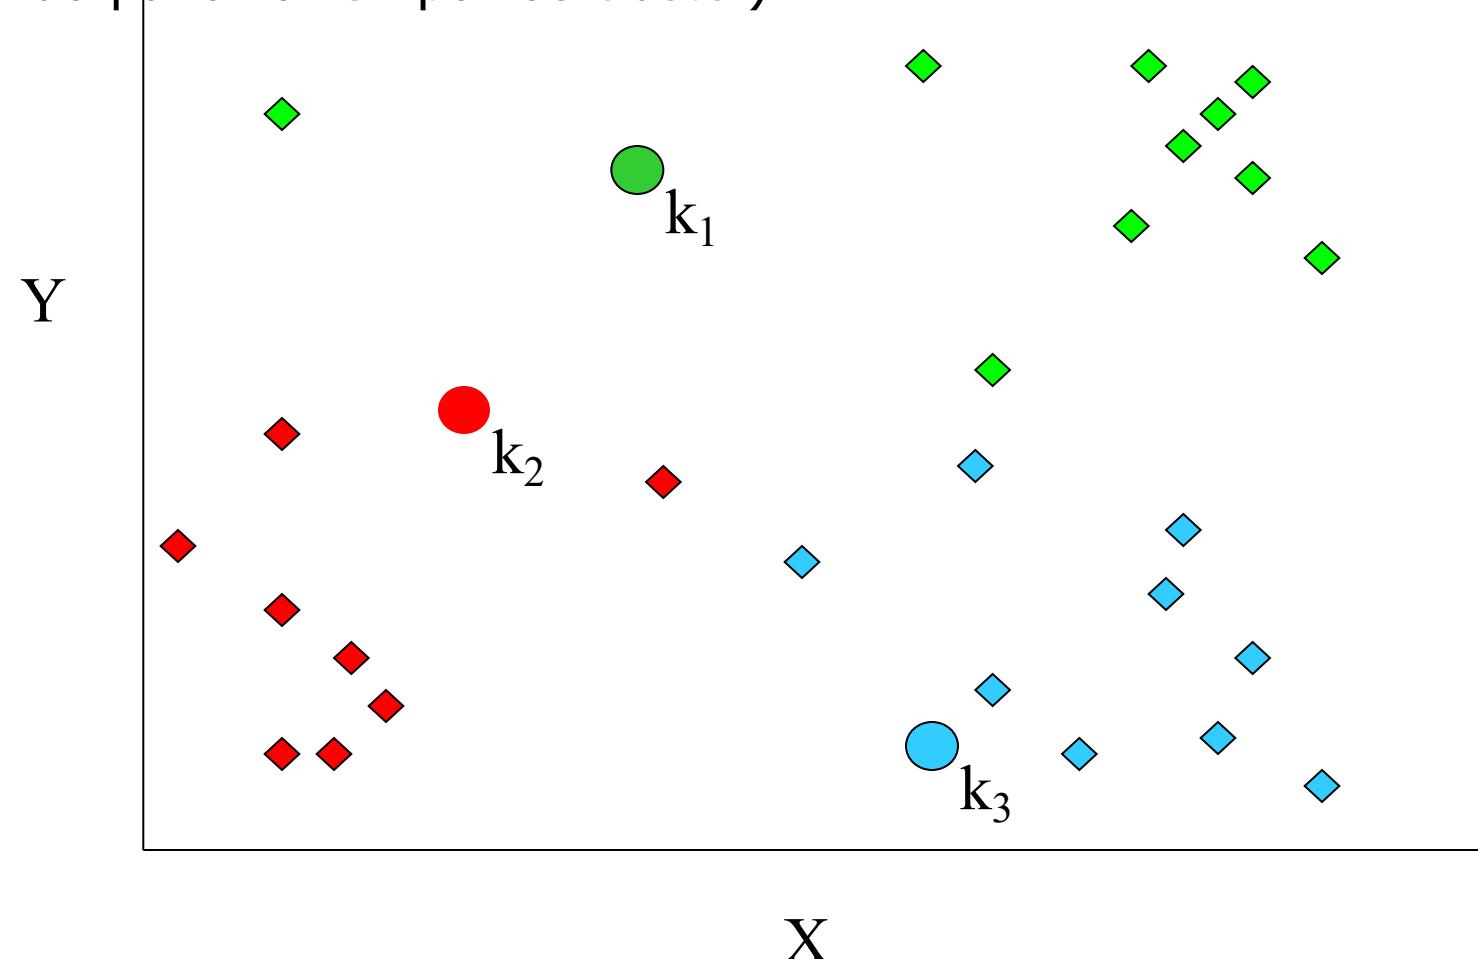
Παράδειγμα K-means (k=3)

- Τυχαία επιλογή τριών αρχικών κέντρων



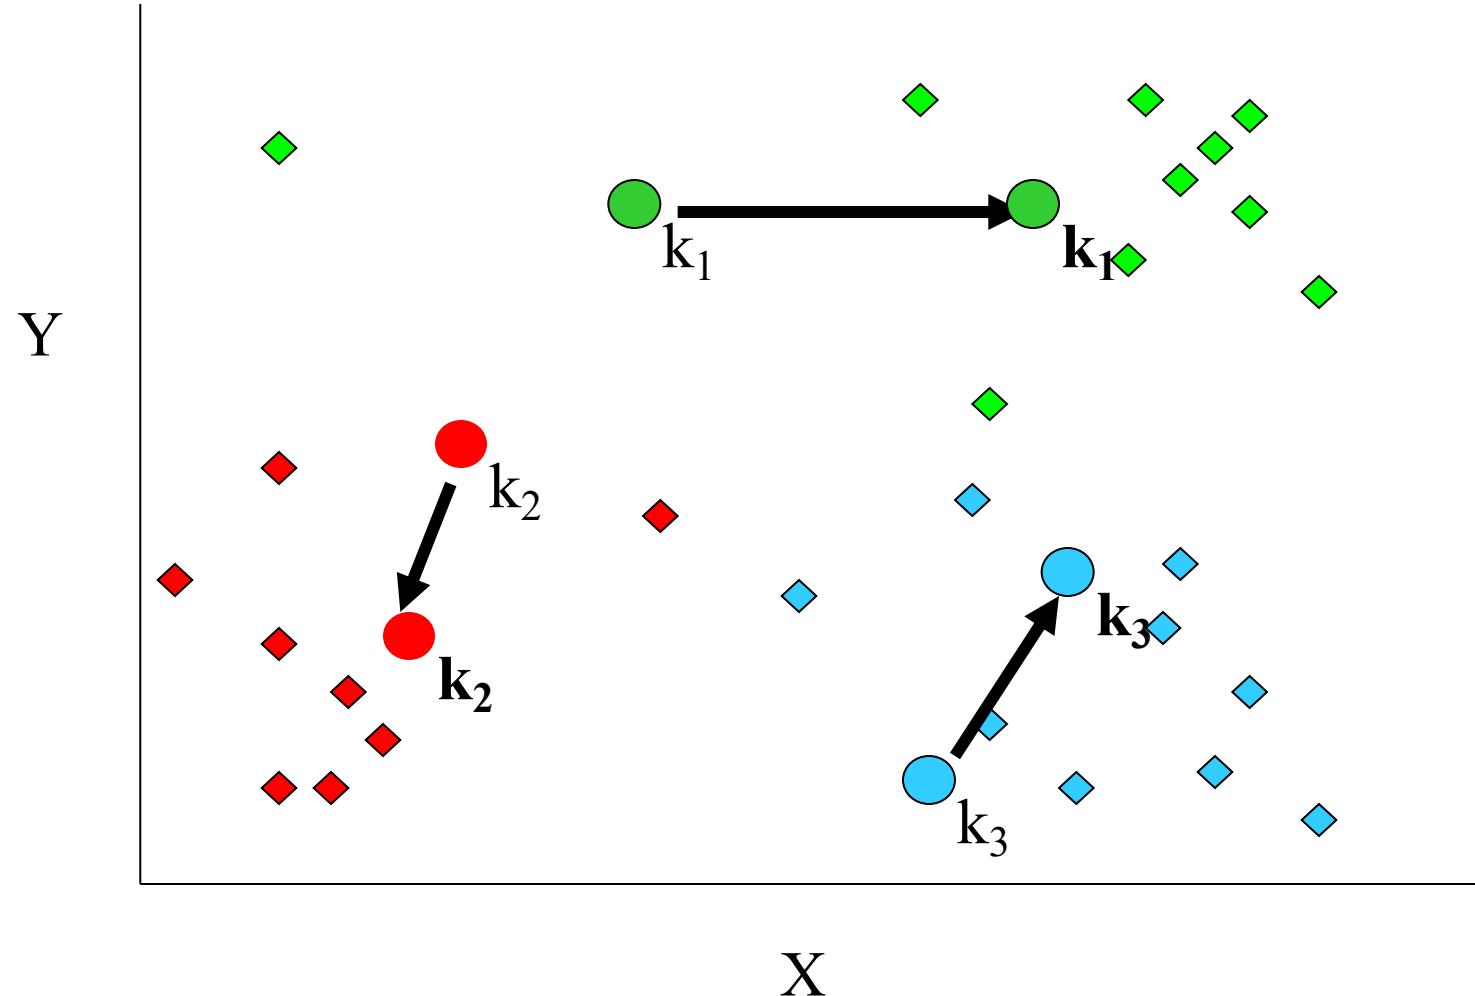
Παράδειγμα K-means, 1^η επανάληψη

- Για κάθε στοιχείο, εκχώρηση στο πλησιέστερο cluster
(με βάση την απόσταση από το κέντρο του cluster)



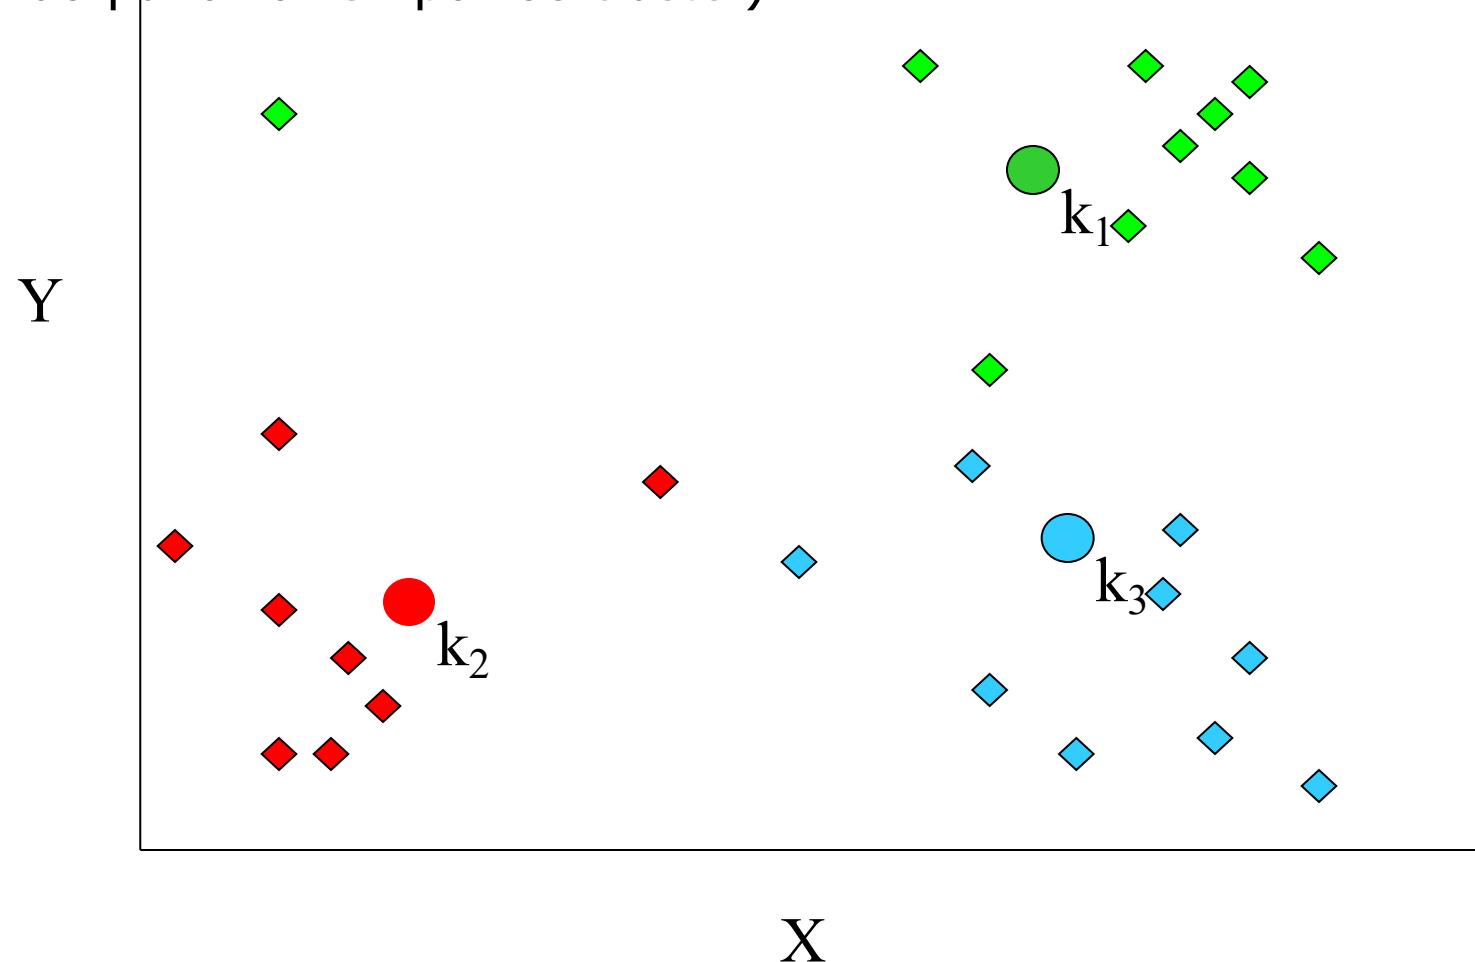
Παράδειγμα K-means, 1^η επανάληψη

- Για κάθε cluster, επανυπολογισμός του νέου κέντρου βάρους

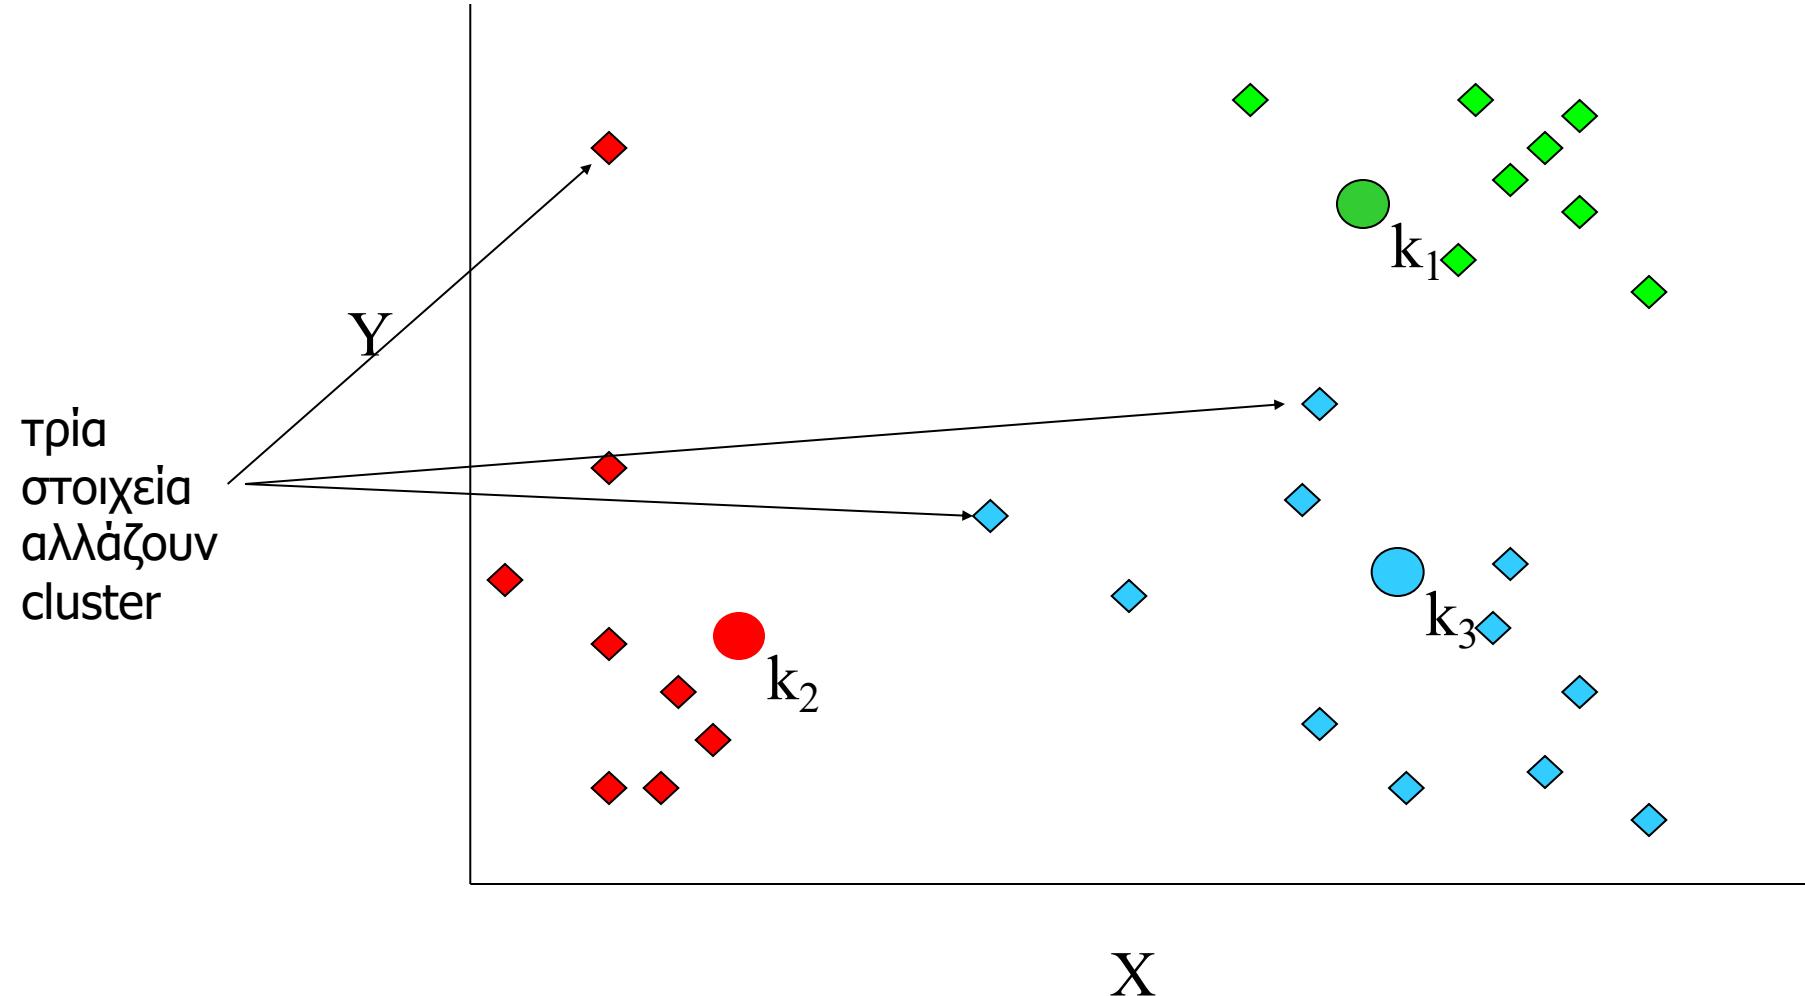


Παράδειγμα K-means, 2^η επανάληψη

- Για κάθε στοιχείο, εκχώρηση στο πλησιέστερο cluster
(με βάση την απόσταση από το κέντρο του cluster)

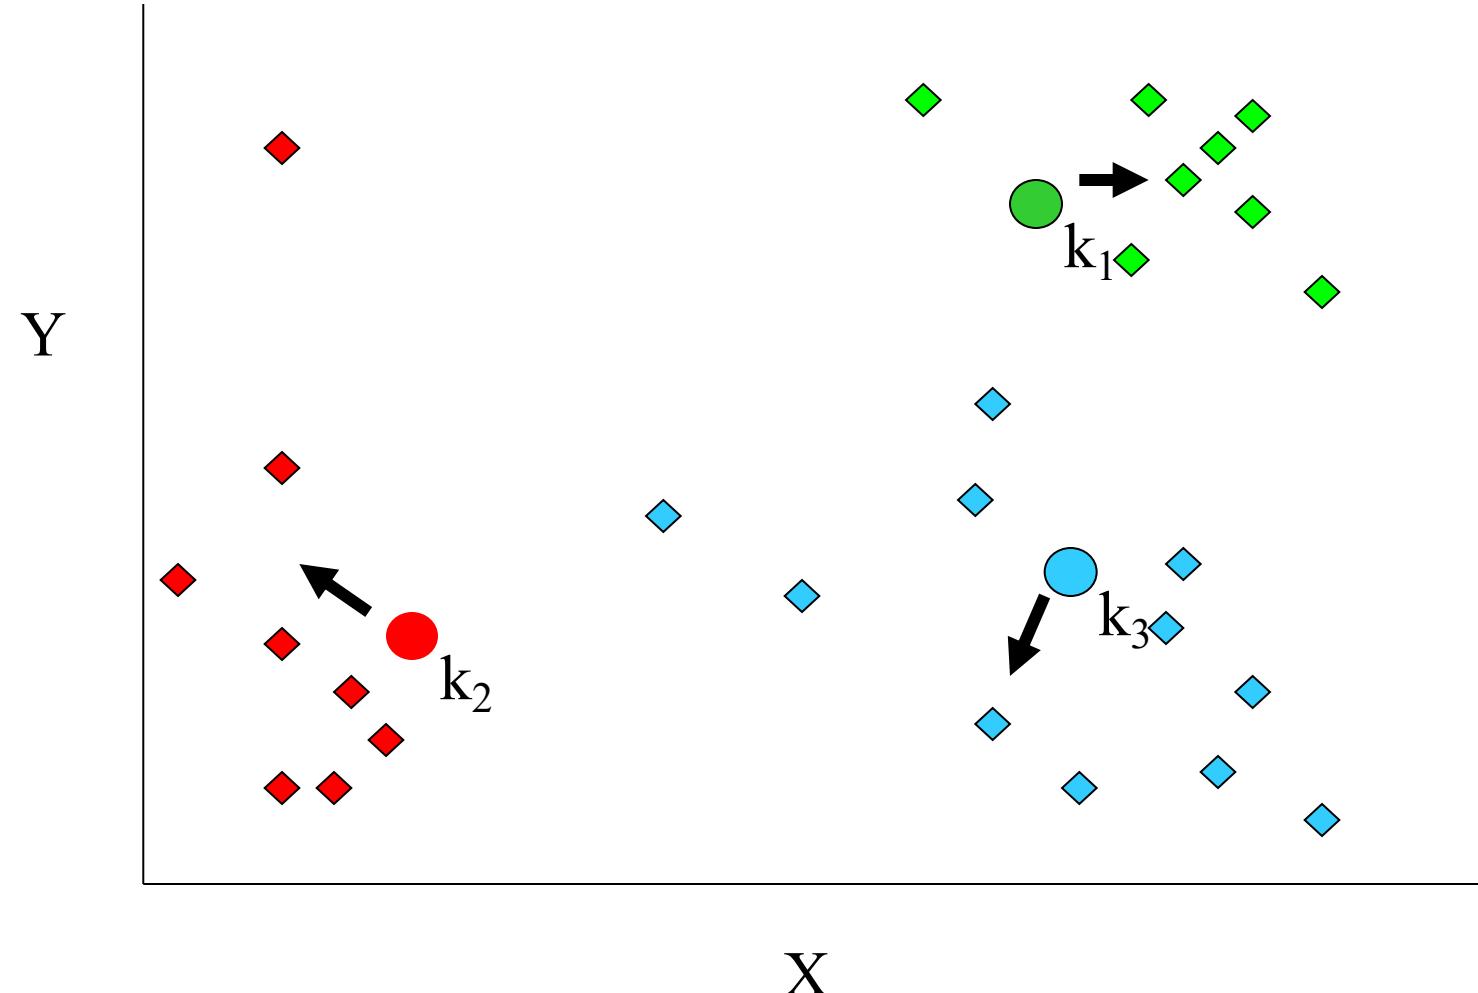


Παράδειγμα K-means, 2^η επανάληψη



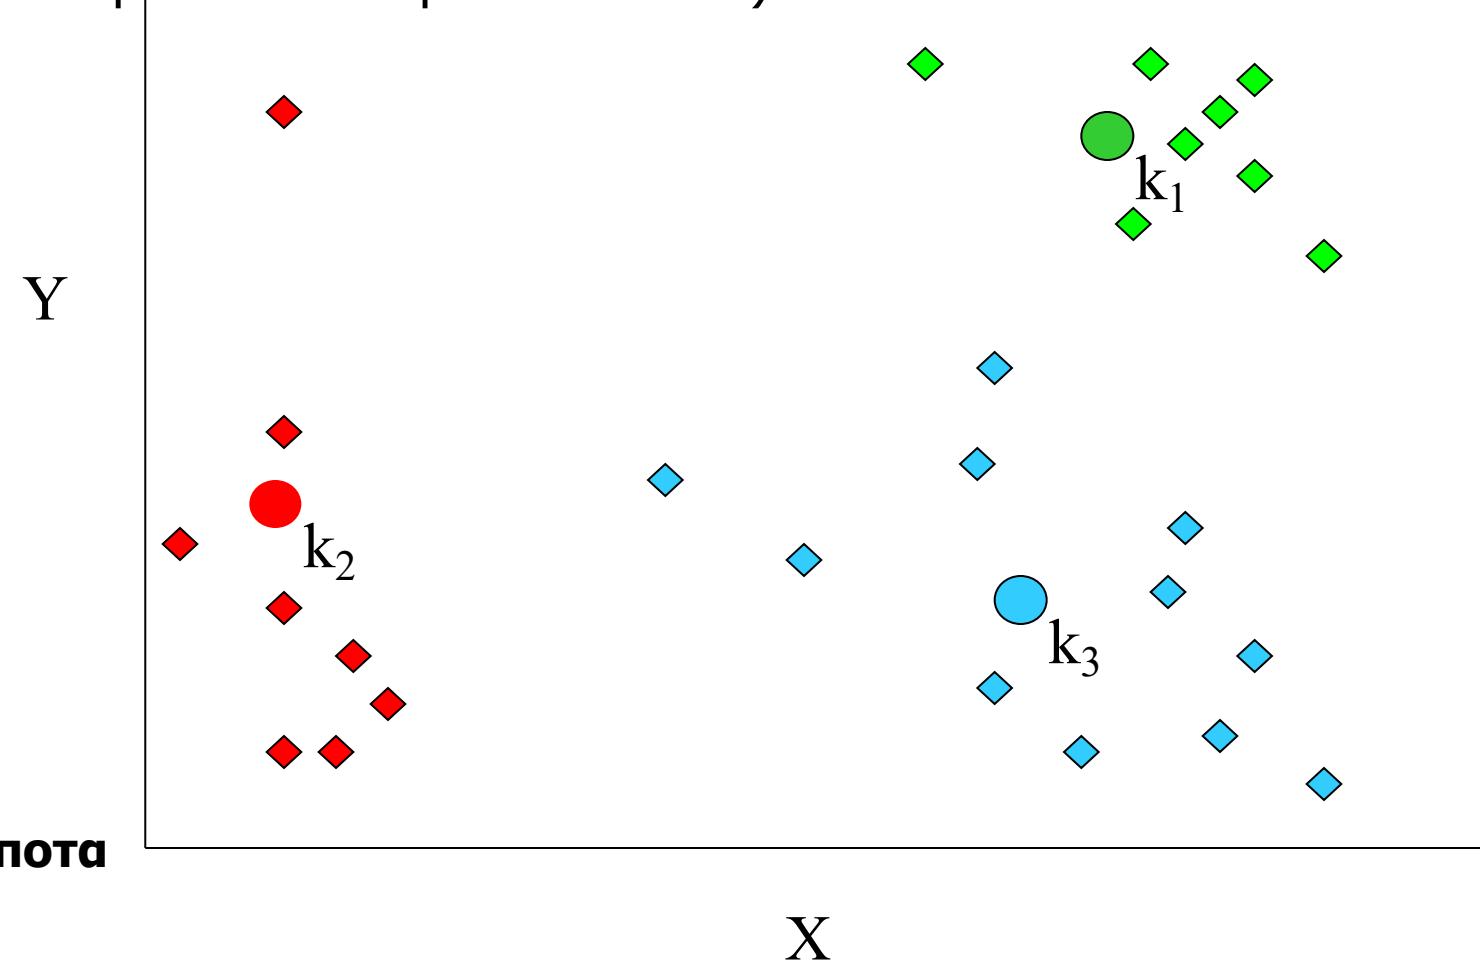
Παράδειγμα K-means, 2^η επανάληψη

- Για κάθε cluster, επανυπολογισμός του νέου κέντρου βάρους



Παράδειγμα K-means, 3^η επανάληψη

- Για κάθε στοιχείο, εκχώρηση στο πλησιέστερο cluster
(με βάση την απόσταση από το κέντρο του cluster)



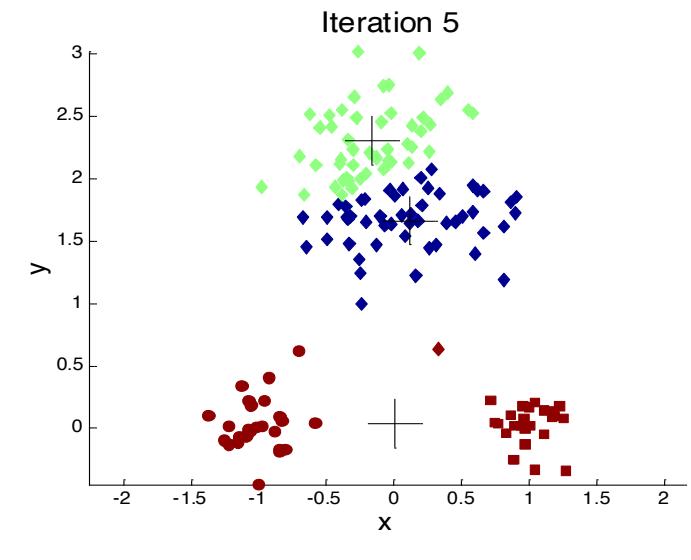
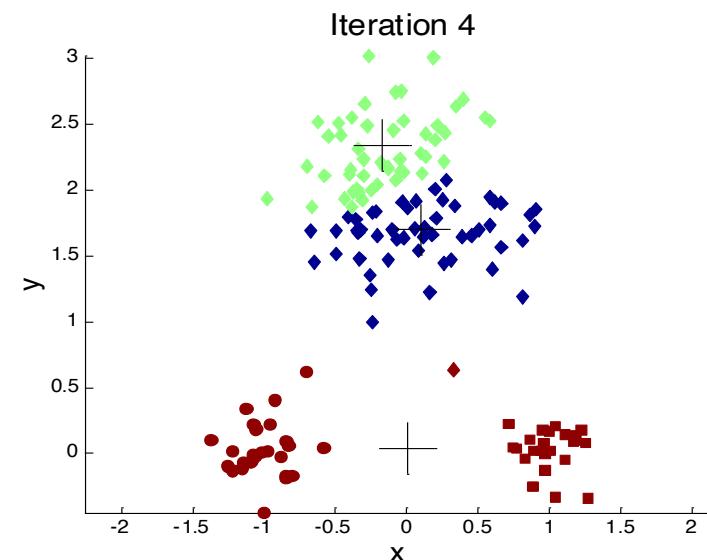
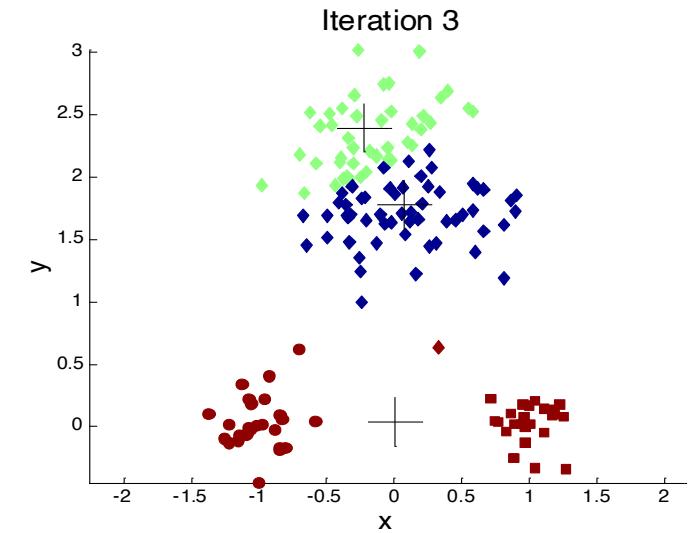
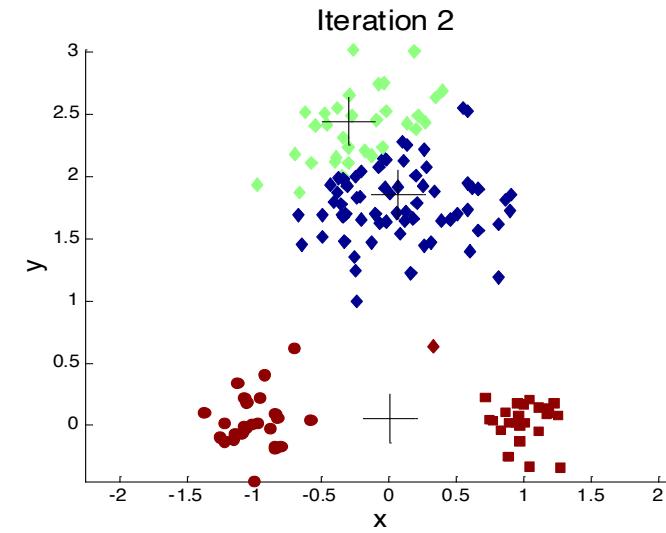
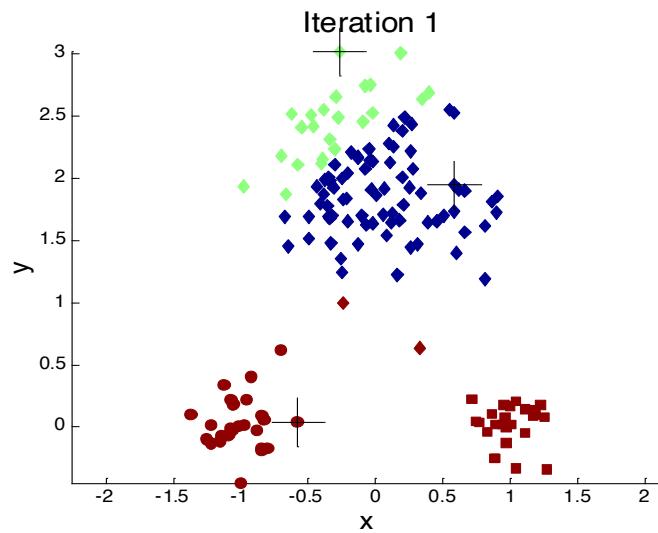
Αλγόριθμος K-Means

Algorithm 1 Basic K-means Algorithm.

- 1: Select K points as the initial centroids.
 - 2: **repeat**
 - 3: Form K clusters by assigning all points to the closest centroid.
 - 4: Recompute the centroid of each cluster.
 - 5: **until** The centroids don't change
-

- Πολυπλοκότητα (βάσει του πλήθους η των στοιχείων): $O(n)$
- Υπέρ και κατά:
 - Ταχύς αλγόριθμος (γραμμική πολυπλοκότητα, εκτός εάν...)
 - Το πλήθος k των συστάδων πρέπει να δοθεί ως είσοδος (άρα, ποιο είναι το κατάλληλο k ?)
 - Το αποτέλεσμα επηρεάζεται από την επιλογή των αρχικών μέσων
 - Οδηγεί σε «φτωχά» αποτελέσματα όταν οι συστάδες δεν έχουν «σφαιρικό» σχήμα ή τα δεδομένα περιέχουν θόρυβο (δεν υπάρχει αυτή η έννοια στον αλγόριθμο)

Η επίδραση της αρχικοποίησης στο αποτέλεσμα



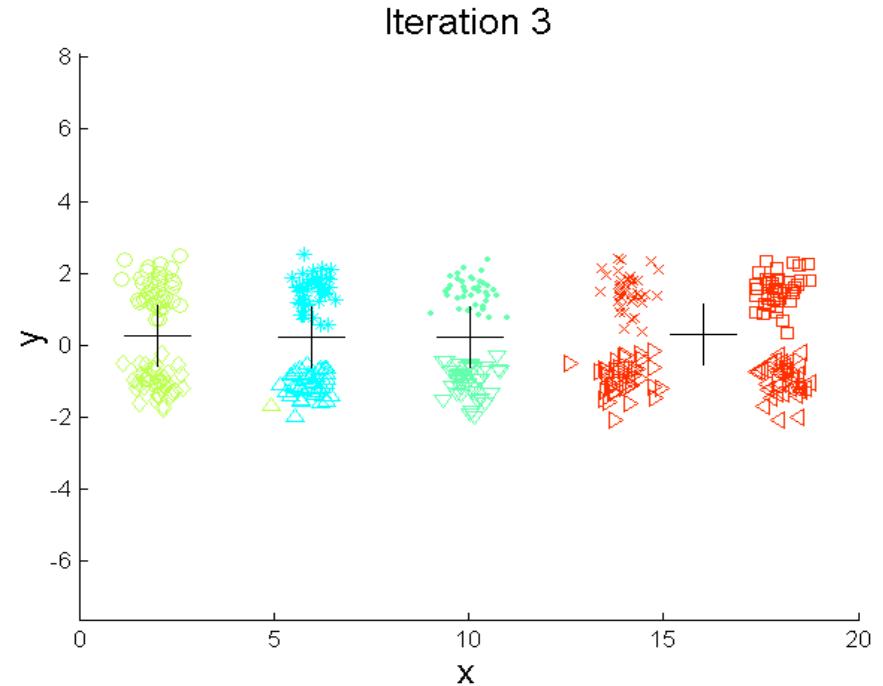
Παράδειγμα με $k=3$

... και πώς αντιμετωπίζεται

- Πολλαπλές εκτελέσεις (με διαφορετική αρχικοποίηση)
 - Σίγουρα βοηθάει αλλά κοστίζει!
- Επιλογή αρχικών μέσων με δειγματοληψία
- **Bisecting** (διχοτομικός) **K-means**
 - Διχοτομεί κάθε φορά μια από τις υπάρχουσες συστάδες με χρήση K-means
 - Δεν παρουσιάζει τόση ευαισθησία στην αρχικοποίηση

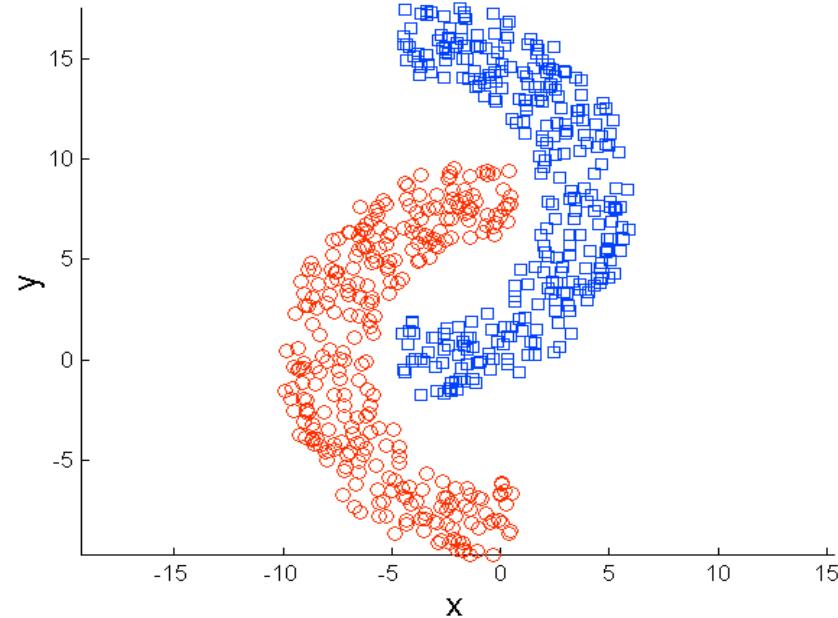
Bisecting K-means

- Παραλλαγή του K-means που παράγει διαμεριστική συσταδοποίηση με ιεραρχικό τρόπο
- Παράδειγμα: (τελικό) $k=4$

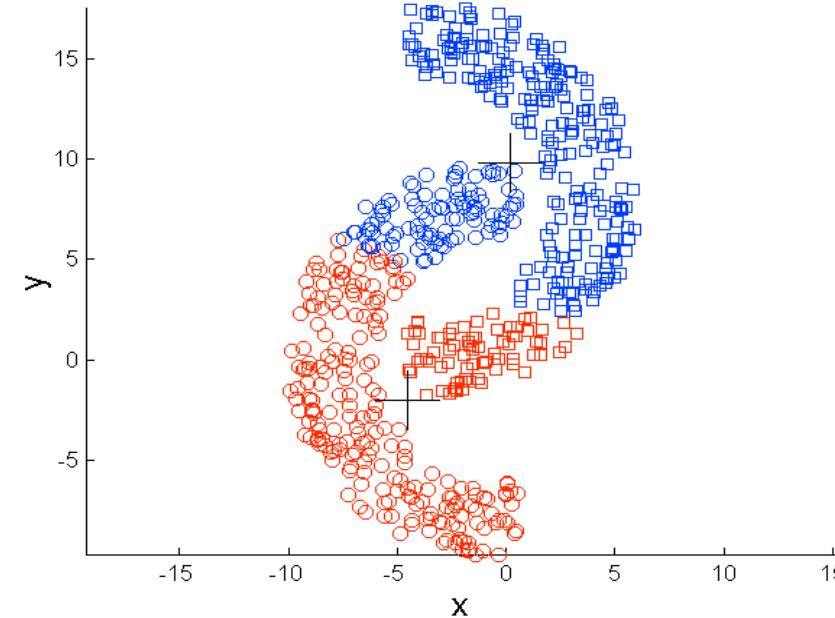


-
- 1: Initialize the list of clusters to contain the cluster containing all points.
 - 2: **repeat**
 - 3: Select a cluster from the list of clusters
 - 4: **for** $i = 1$ to *number_of_iterations* **do**
 - 5: Bisect the selected cluster using basic K-means
 - 6: **end for**
 - 7: Add the two clusters from the bisection with the lowest SSE to the list of clusters.
 - 8: **until** Until the list of clusters contains K clusters
-

Η επίπτωση του «περίεργου» σχήματος

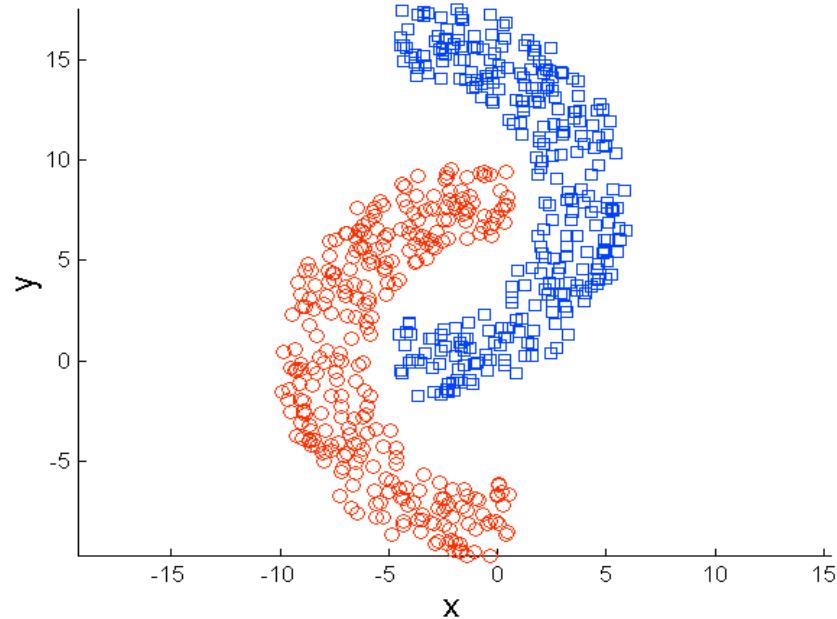


Αρχικά σημεία

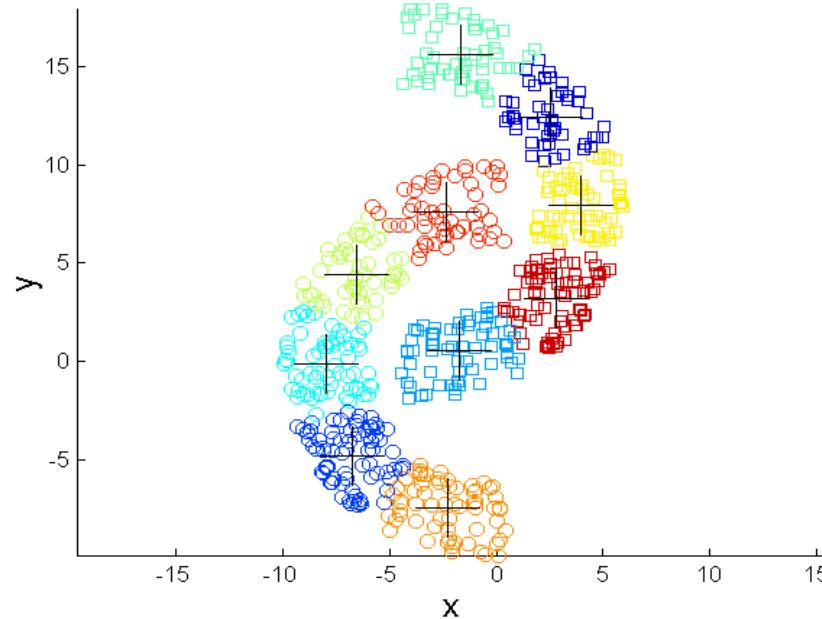


K-means (2 Clusters)

...και πώς αντιμετωπίζεται



Αρχικά σημεία

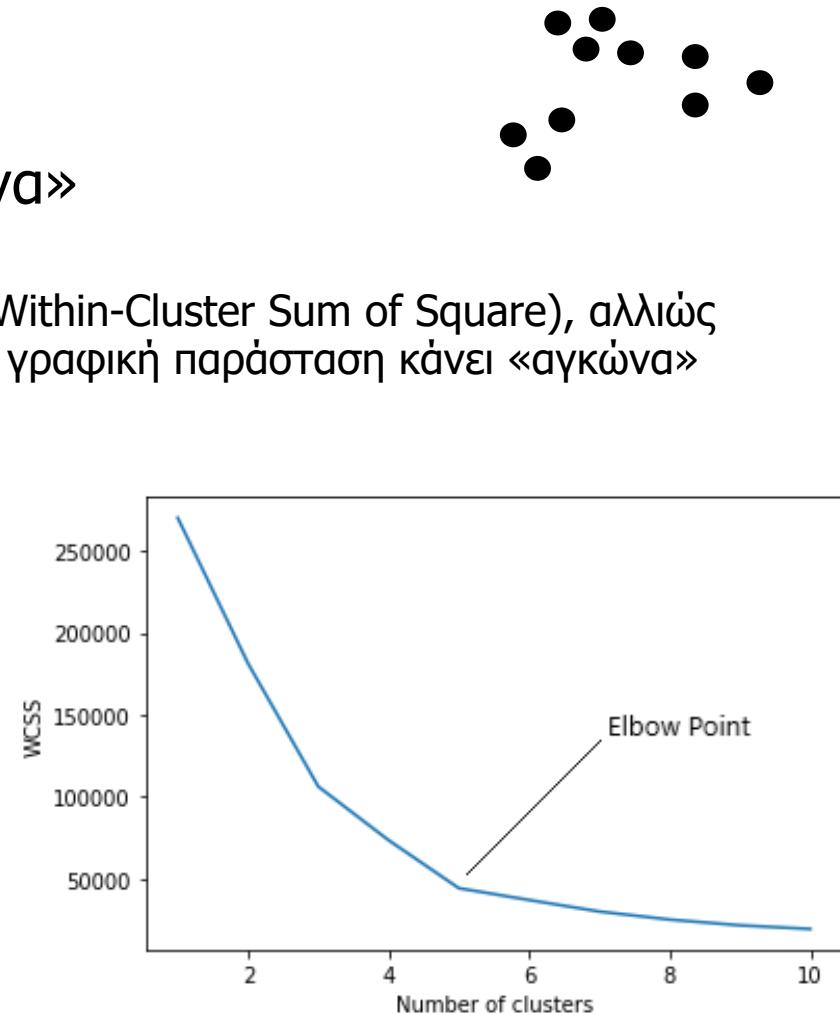


K-means (10 Clusters)

Το ζήτημα της εύρεσης του «κατάλληλου k»

- Δύσκολο πρόβλημα, χωρίς βέλτιστη λύση
- Μια ευριστική μέθοδος: το κριτήριο του «αγκώνα» (elbow criterion)
 - Για διαφορετικά k, υπολογίζουμε το μέτρο ποιότητας WCSS (Within-Cluster Sum of Square), αλλιώς SSE (Sum of Squared Errors), και βρίσκουμε το σημείο που η γραφική παράσταση κάνει «αγκώνα»
 - WCSS: το άθροισμα των τετραγώνων των αποστάσεων μεταξύ κάθε σημείου x και του μέσου μ της συστάδας στην οποία το x ανήκει

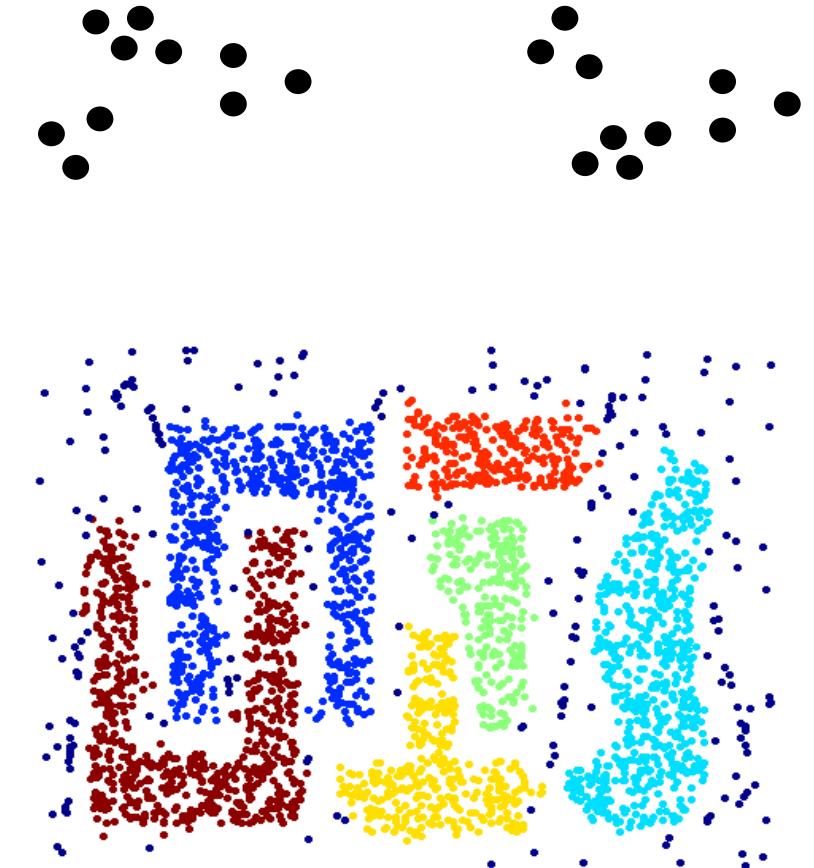
$$WCSS(K) = \sum_{i=1}^K \sum_{x \in C_i} \|x - \mu_i\|^2$$



πηγή εικόνας: <https://www.analyticsvidhya.com/blog/2021/01/in-depth-intuition-of-k-means-clustering-algorithm-in-machine-learning/>

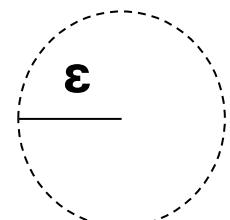
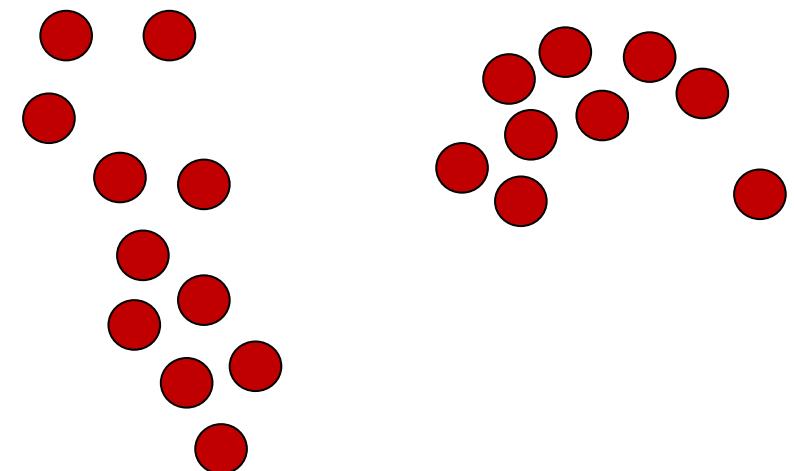
Συσταδοποίηση με βάση την πυκνότητα

- Διπλός στόχος:
 - Τα γειτονικά σημεία να ενταχθούν στην ίδια συστάδα
 - Τα ακραία σημεία («θόρυβος») να απομονωθούν
- Οι πιο δημοφιλείς τεχνικές:
 - **DBSCAN – density-based spatial clustering of applications with noise** («Συσταδοποίηση βάσει πυκνότητας εφαρμογών με θόρυβο»)
 - **OPTICS -- ordering points to identify the clustering structure** («Διάταξη σημείων για την ταυτοποίηση της δομής των συστάδων»)



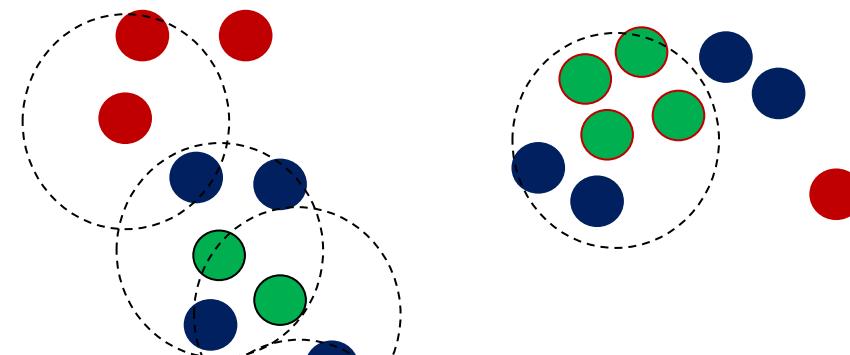
DBSCAN

- 2 παράμετροι εισόδου:
 - **MinPts** – κατώφλι πληθυσμού: ελάχιστος αριθμός σημείων μέσα στη συστάδα
 - **ϵ** – κατώφλι απόστασης: για κάθε σημείο της συστάδας θα πρέπει να υπάρχει ένα άλλο σημείο της συστάδας με απόσταση μικρότερη από ϵ .
- (Δηλαδή, δεν απαιτείται να δοθεί ως είσοδος το πλήθος κ των συστάδων)
- Έξοδος: συστάδες & θόρυβος

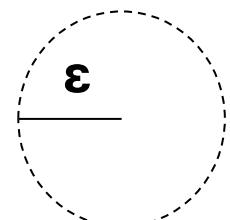


DBSCAN – η έννοια της πυκνότητας (1)

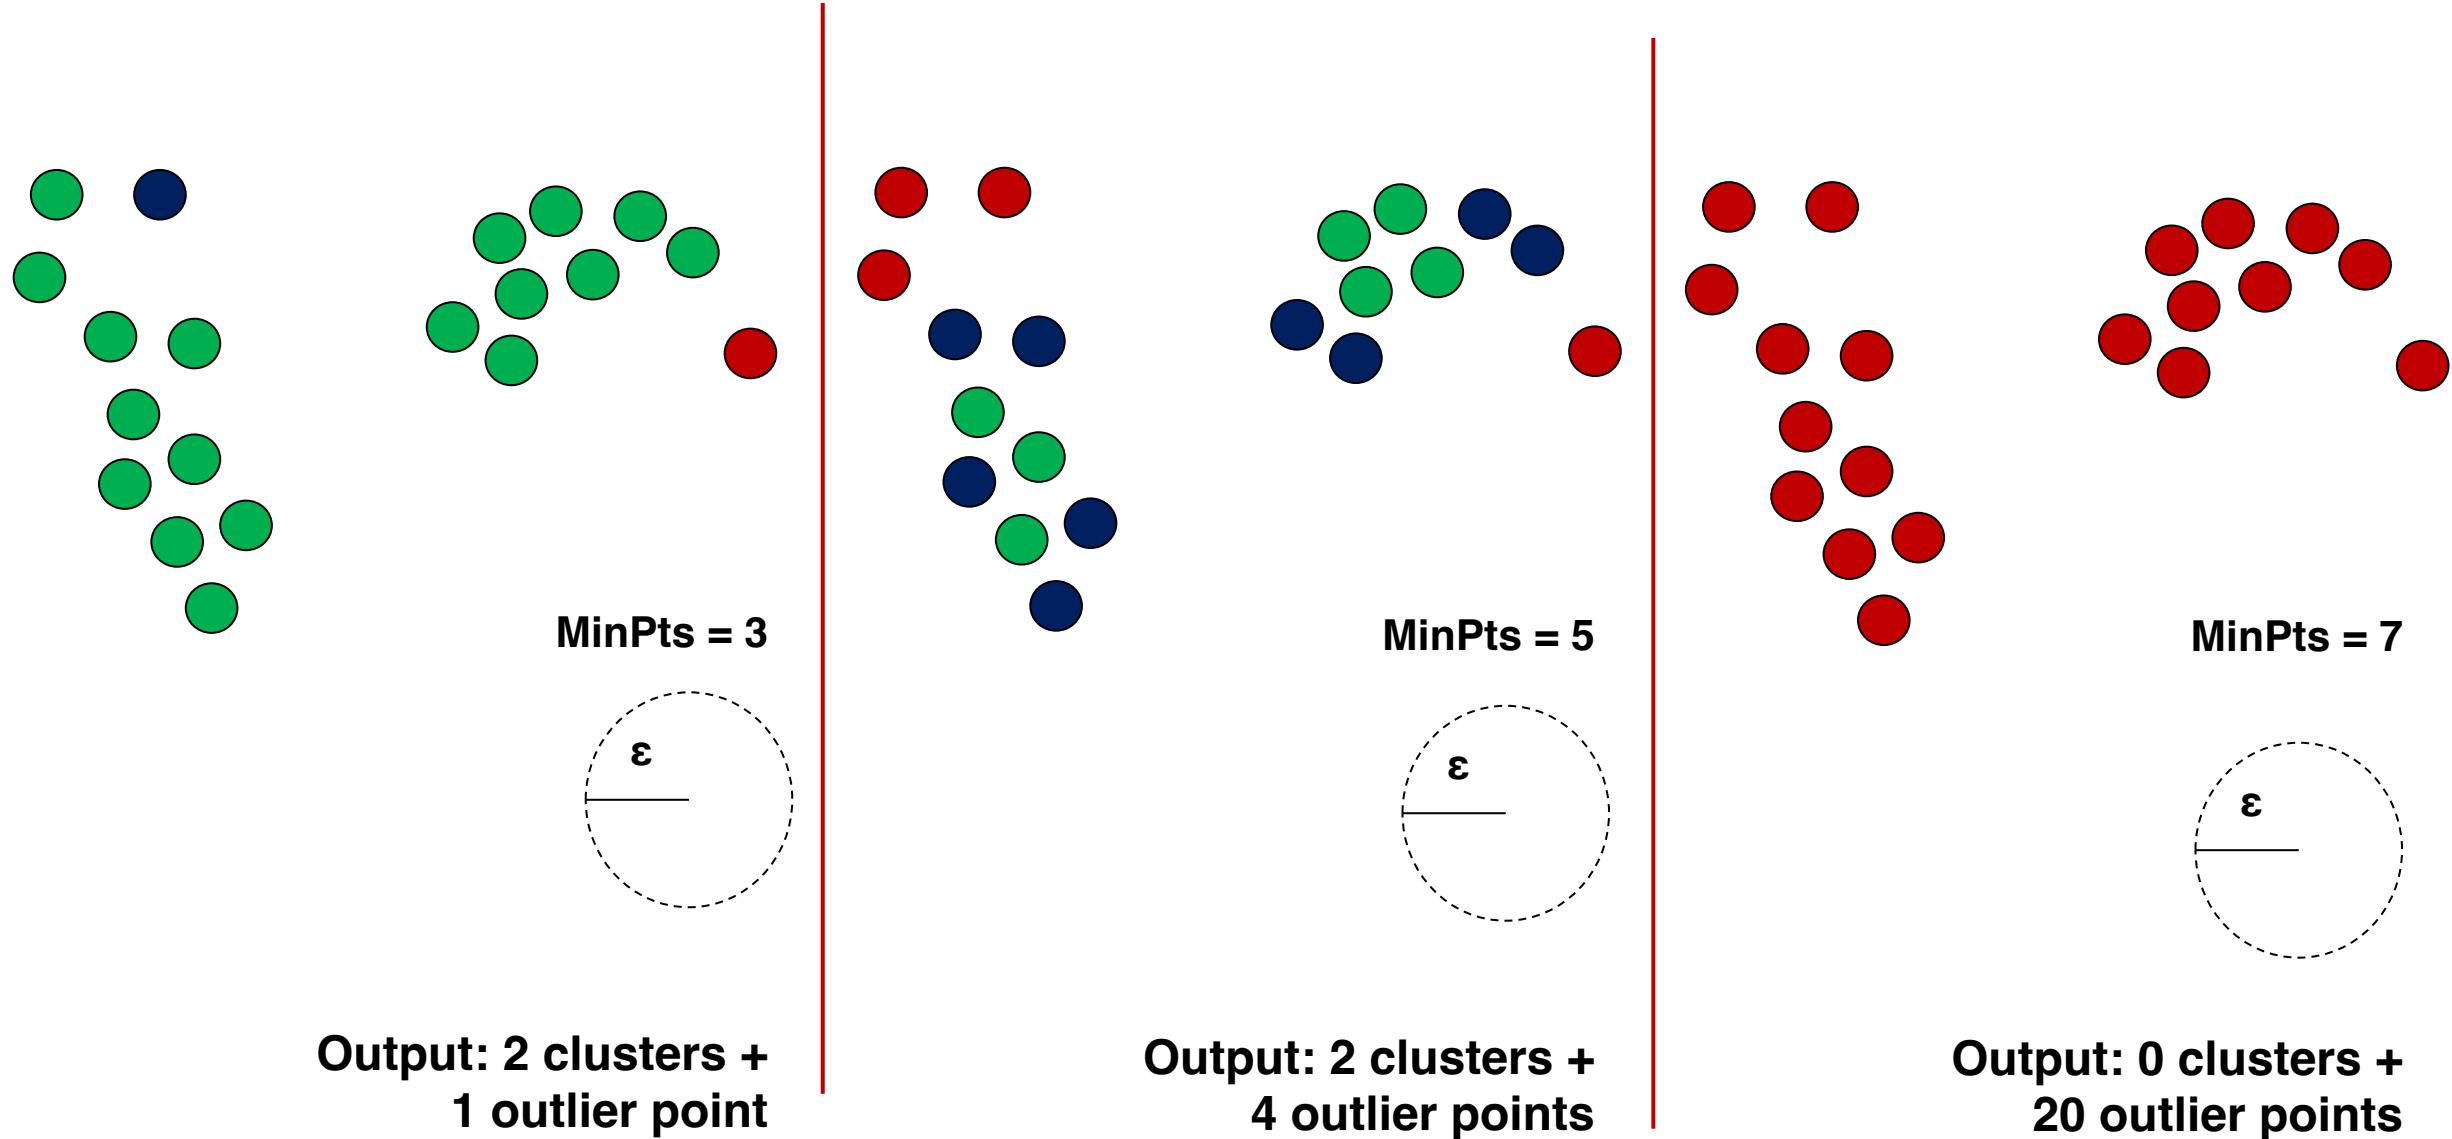
- **ε-γειτονιά (ε-neighborhood)** ενός σημείου p : σύνολο σημείων σε απόσταση $\leq \epsilon$ από το p
- ένα σημείο p με πληθυσμό ϵ -γειτονιάς (συμπεριλαμβανομένου του p) $\geq \text{MinPts}$ ονομάζεται **πυρήνας (core)**
- ένα σημείο p που δεν είναι πυρήνας αλλά ανήκει στην ϵ -γειτονιά ενός πυρήνα ονομάζεται **σύνορο (border)**
- ένα σημείο p που δεν είναι ούτε πυρήνας ούτε σύνορο ονομάζεται **θόρυβος (noise)**
- κεντρική ιδέα αλγορίθμου:
 - να σχηματιστούν συστάδες γύρω από πυρήνες,
 - τα σύνορα να ενσωματωθούν σε αυτές,
 - ο θόρυβος να απομονωθεί



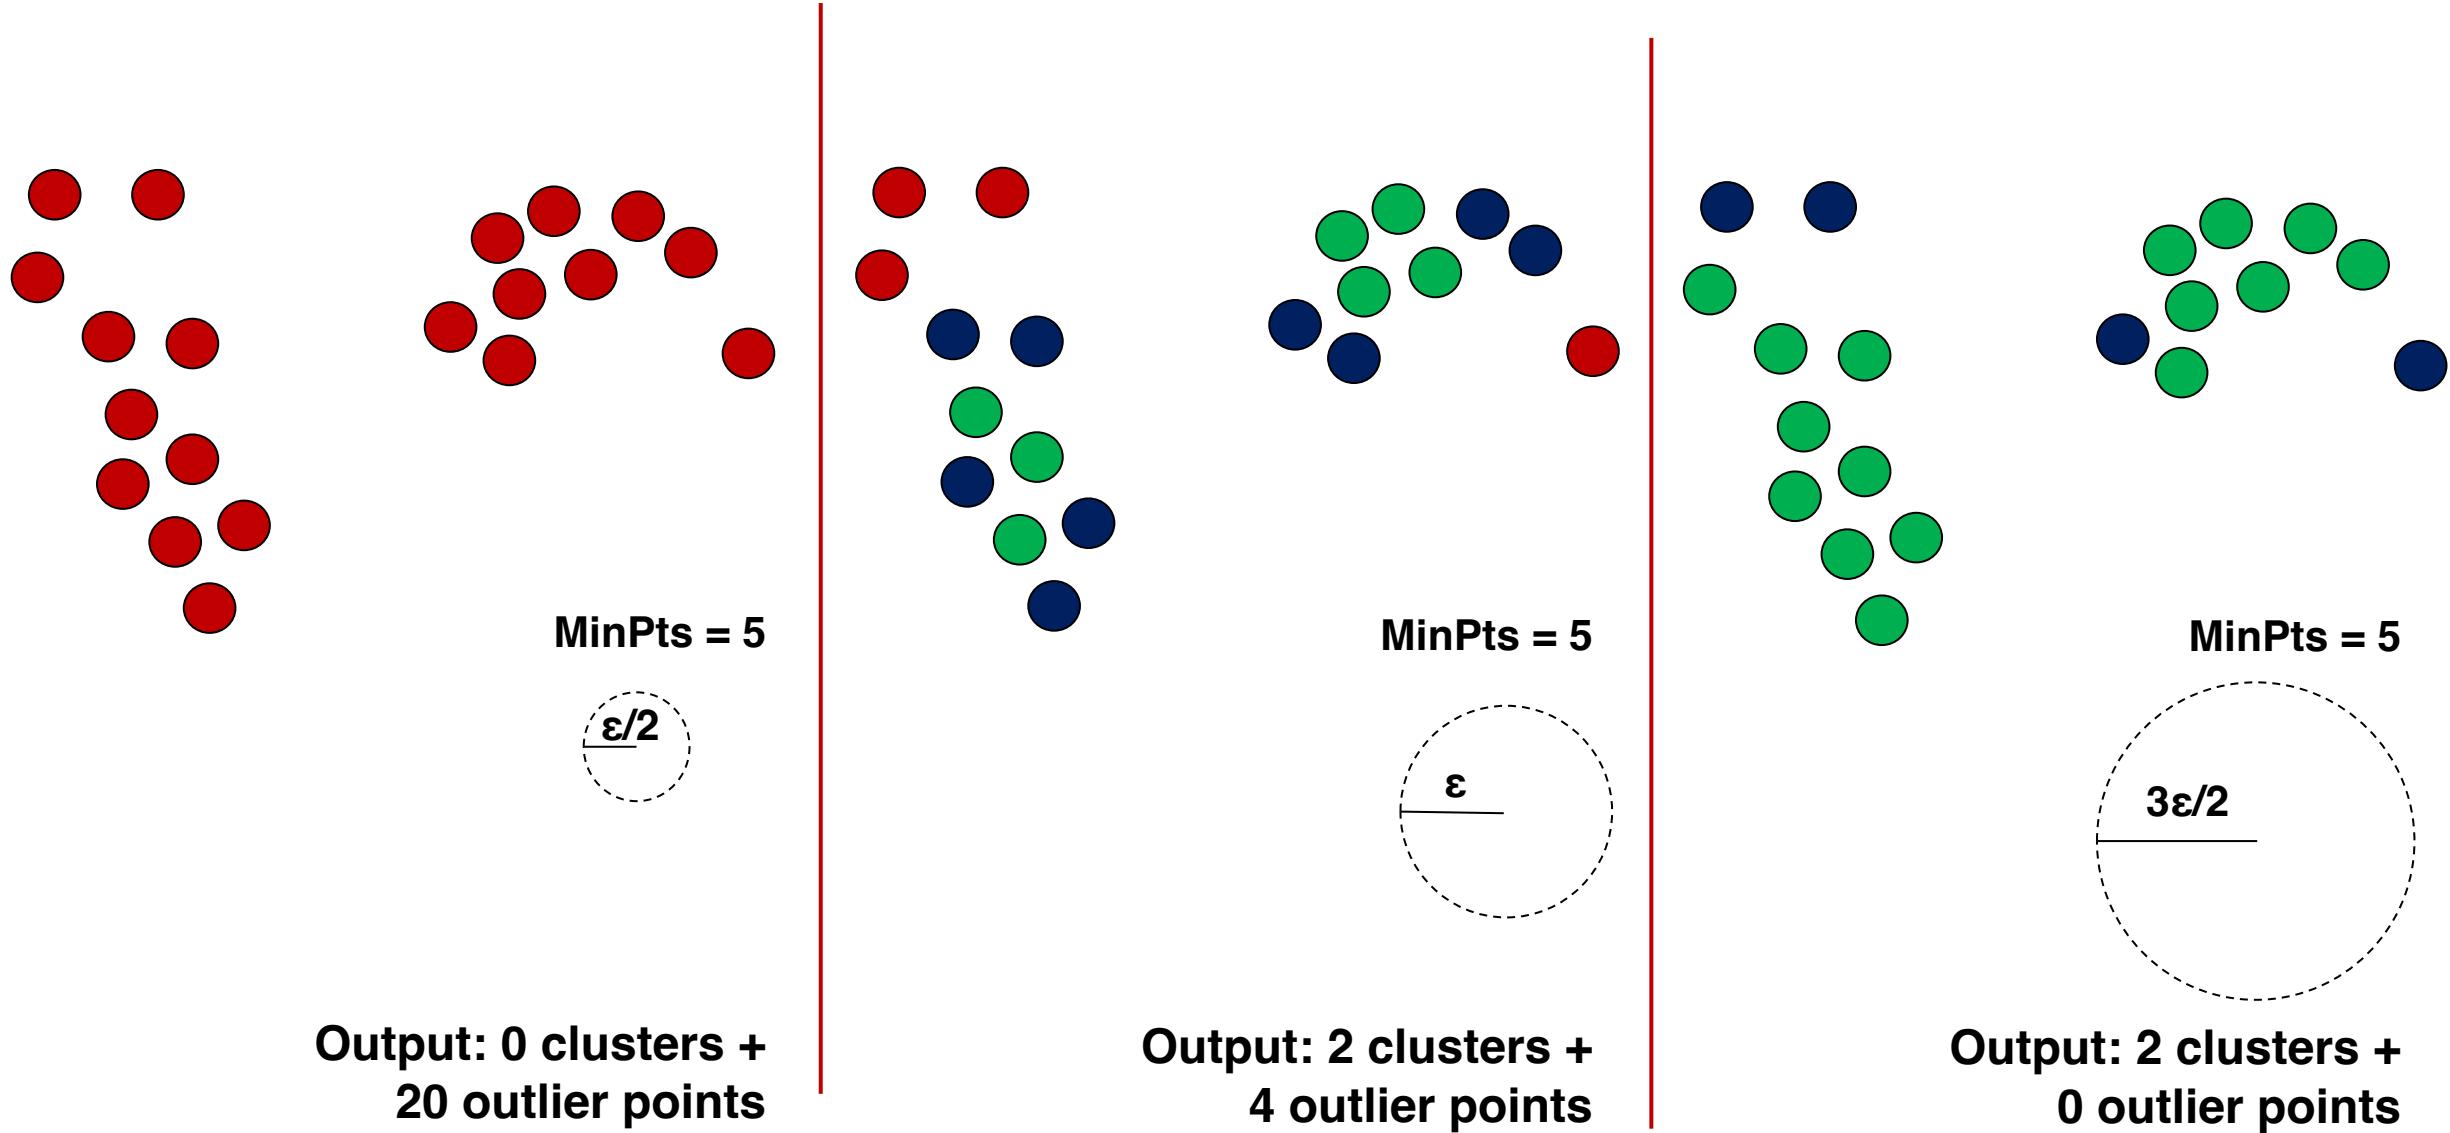
MinPts = 5
→ 2 clusters, 4 outliers



DBSCAN – η έννοια της πυκνότητας (2)



DBSCAN – η έννοια της πυκνότητας (3)

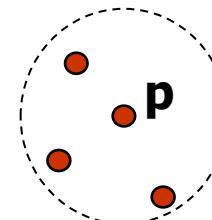


DBSCAN – η έννοια της συνδεσιμότητας (1)

- Ορισμοί των εννοιών:

- **γειτονιά** (neighborhood), **απευθείας προσεγγισιμότητα βάσει πυκνότητας** (directly density-reachability), **προσεγγισιμότητα βάσει πυκνότητας** (density-reachability), **συνδεσιμότητα βάσει πυκνότητας** (density-connectivity)

... με δεδομένες τιμές των παραμέτρων ϵ , MinPts

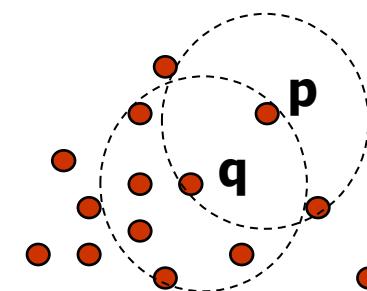


- **γειτονιά** σημείου p:

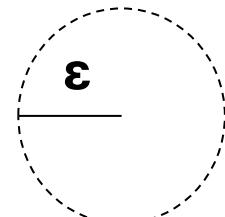
- σύνολο σημείων σε απόσταση μέχρι ϵ από το σημείο p,
δηλ. $N_\epsilon(p)$: $\{q \text{ ανήκει στο } D \mid \text{dist}(p,q) \leq \epsilon\}$

- σημείο p είναι **απευθείας προσεγγίσιμο βάσει πυκνότητας** από σημείο q αν:

- p βρίσκεται στη γειτονιά του q, δηλ. $p \in N_\epsilon(q)$, και
 - q είναι πυρήνας, δηλ. $|N_\epsilon(q)| \geq \text{MinPts}$



MinPts = 5



DBSCAN – η έννοια της συνδεσιμότητας (2)

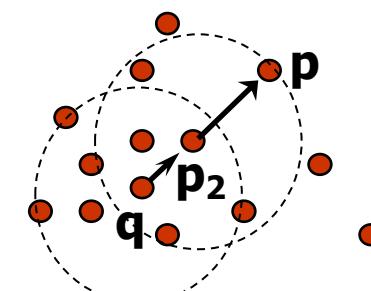
- Ορισμοί των εννοιών:

- **γειτονιά** (neighborhood), **απευθείας προσεγγισιμότητα βάσει πυκνότητας** (directly density-reachability), **προσεγγισιμότητα βάσει πυκνότητας** (density-reachability), **συνδεσιμότητα βάσει πυκνότητας** (density-connectivity)

... με δεδομένες τιμές των παραμέτρων ϵ , MinPts

- σημείο p είναι **προσεγγίσιμο βάσει πυκνότητας από** σημείο q αν:

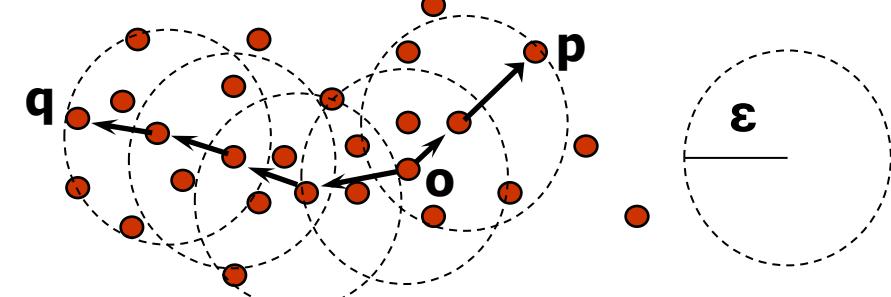
- υπάρχει αλυσίδα σημείων p_1, \dots, p_n , όπου $p_1 = q$, $p_n = p$, τέτοια ώστε: p_{i+1} απευθείας προσεγγίσιμο από p_i



MinPts = 5

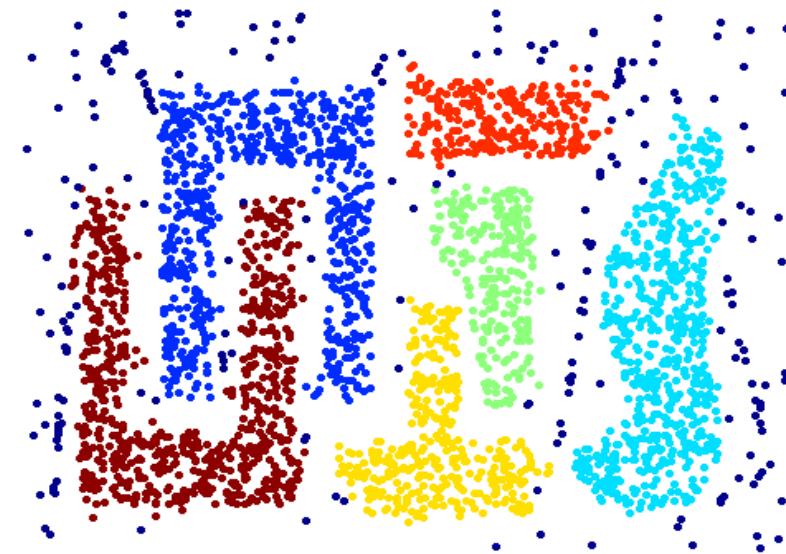
- σημεία p και q είναι **συνδεδεμένα βάσει πυκνότητας** αν:

- υπάρχει σημείο o τέτοιο ώστε: p προσεγγίσιμο από o και q προσεγγίσιμο από o



DBSCAN – ο αλγόριθμος (1)

- Μια συστάδα ορίζεται ως το **μέγιστο σύνολο συνδεδεμένων σημείων** (με βάση τον προηγούμενο ορισμό της συνδεσιμότητας)
- Φορμαλιστικά, μία συστάδα C ικανοποιεί 2 κριτήρια:
 1. **Κριτήριο μεγιστότητας (Maximality):**
 $\forall p \in C, q, \text{ εάν } q \text{ είναι προσεγγίσιμο βάσει πυκνότητας από } p, \text{ τότε } q \in C$
 2. **Κριτήριο συνδεσιμότητας (Connectivity):**
 $\forall p, q \in C, p \text{ και } q \text{ είναι συνδεδεμένα βάσει πυκνότητας}$
- Άρα ο αλγόριθμος είναι σε θέση να ανακαλύπτει συστάδες (διαφόρων μεγεθών & σχημάτων), καθώς και θόρυβος



Συστάδες & Θόρυβος

DBSCAN – ο αλγόριθμος (2)

```
DBSCAN(DB, distFunc, eps, minPts) {
    C = 0
    for each point P in database DB {
        if label(P) ≠ undefined then continue
    }
    Neighbors N = RangeQuery(DB, distFunc, P, eps)
    if |N| < minPts then {
        label(P) = Noise
        continue
    }
    C = C + 1
    label(P) = C
    Seed set S = N \ {P}
    for each point Q in S {
        if label(Q) = Noise then label(Q) = C
        if label(Q) ≠ undefined then continue
        label(Q) = C
        Neighbors N = RangeQuery(DB, distFunc, Q, eps)
        if |N| ≥ minPts then {
            S = S ∪ N
        }
    }
}
```

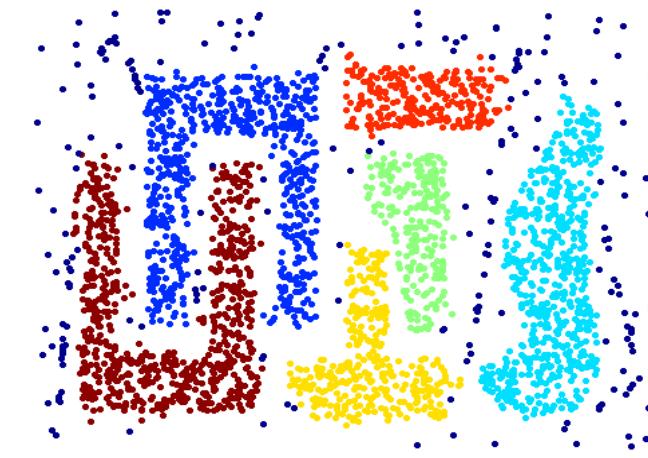
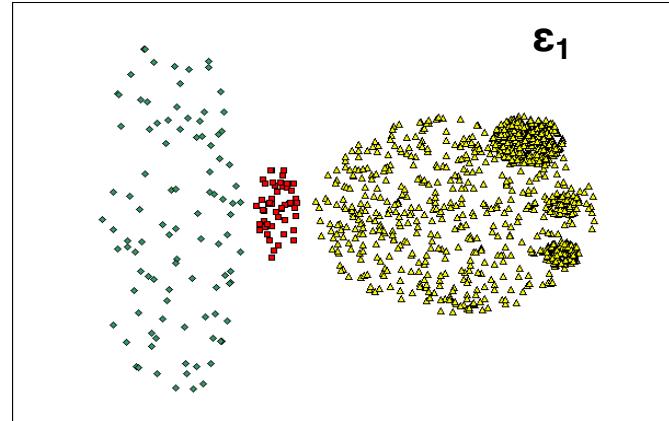
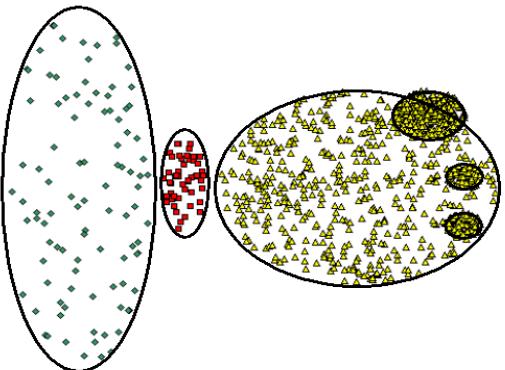
/ Cluster counter */*
/ Previously processed in inner loop */*
/ Find neighbors */*
/ Density check */*
/ Label as Noise */*

/ next cluster label */*
/ Label initial point */*
/ Neighbors to expand */*
/ Process every seed point */*
/ Change Noise to border point */*
/ Previously processed */*
/ Label neighbor */*
/ Find neighbors */*
/ Density check */*
/ Add new neighbors to seed set */*

Πολυπλοκότητα: $O(n^2)$ ή $O(n \log n)$ αν υπάρχει χωρικό ευρετήριο (index), π.χ. R-tree, για την επιτάχυνση των ερωτημάτων χωρικής γειτνίασης

Υπέρ και κατά του DBSCAN

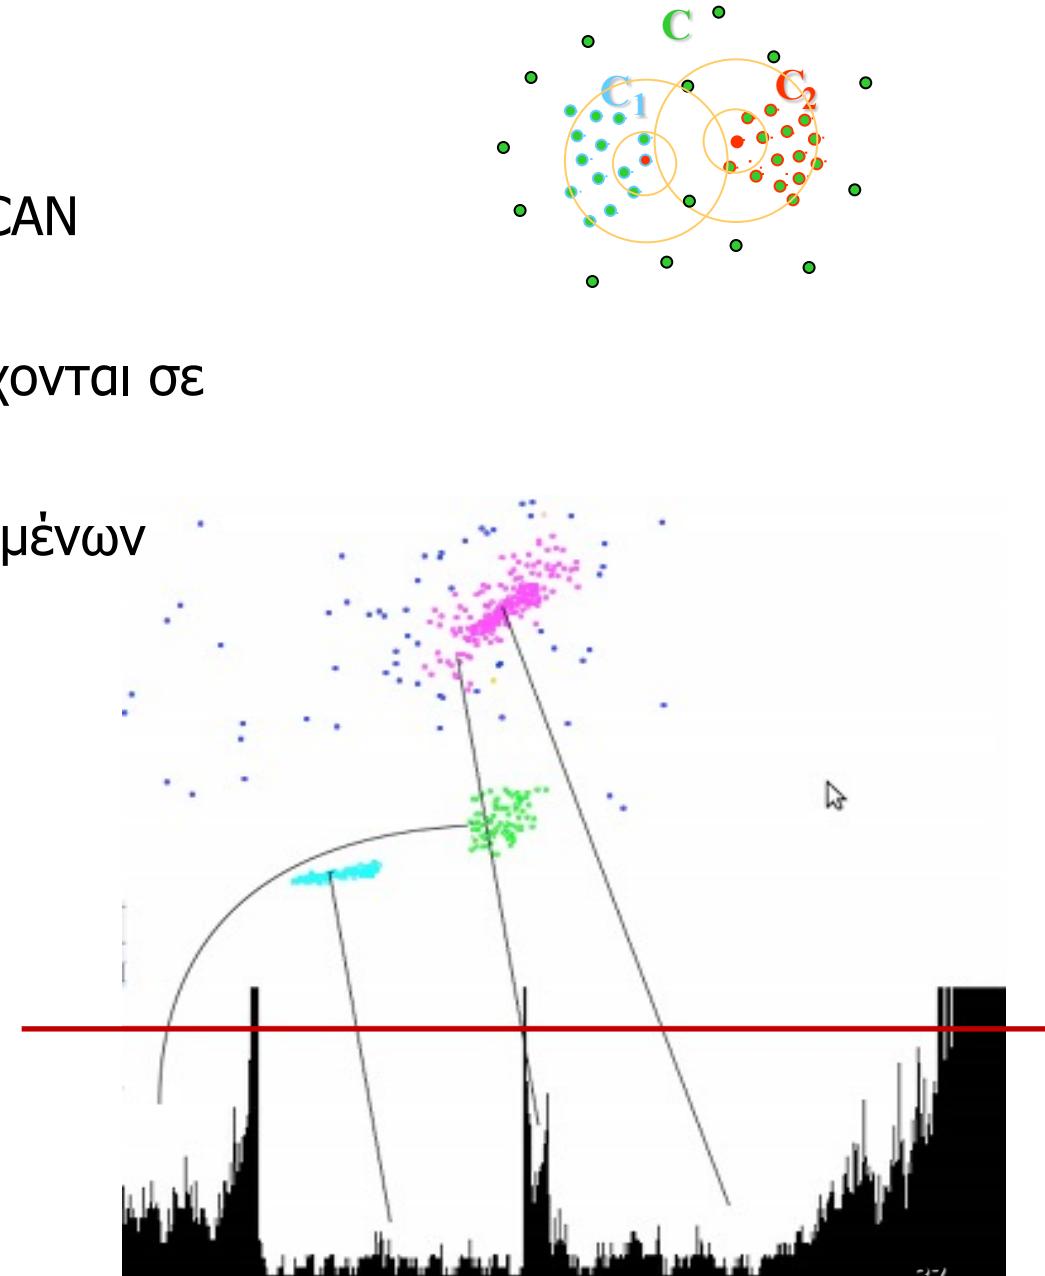
- Απομόνωση του θορύβου
- Ανακάλυψη συστάδων διαφορετικών μεγεθών / σχημάτων
- Ευαισθησία στις εναλλαγές στην πυκνότητα του συνόλου δεδομένων



DBSCAN visualization: <https://www.naftaliharris.com/blog/visualizing-dbscan-clustering/>

OPTICS (1)

- Στόχος: η αντιμετώπιση της κύριας αδυναμίας του DBSCAN (ευαισθησία στην εναλλαγή πυκνότητας)
- Παρατήρηση: οι περισσότερο πυκνές συστάδες εμπεριέχονται σε λιγότερο πυκνές συστάδες
- Ιδέα: γραμμική διάταξη των σημείων του συνόλου δεδομένων
 - Στη γραμμική διάταξη, η απόσταση μεταξύ 2 σημείων αντιστοιχεί στην πυκνότητα που πρέπει να ισχύει ώστε αυτά τα σημεία να τοποθετηθούν στην ίδια συστάδα
 - **Γραφική προσεγγισμότητας** (reachability plot)
- Παράμετροι: ϵ , MinPts (όπως στον αλγόριθμο DBSCAN)
 - Η παράμετρος ϵ θα μπορούσε και να απουσιάζει – υπάρχει για πρaktikoύς λόγους (απόδοσης)

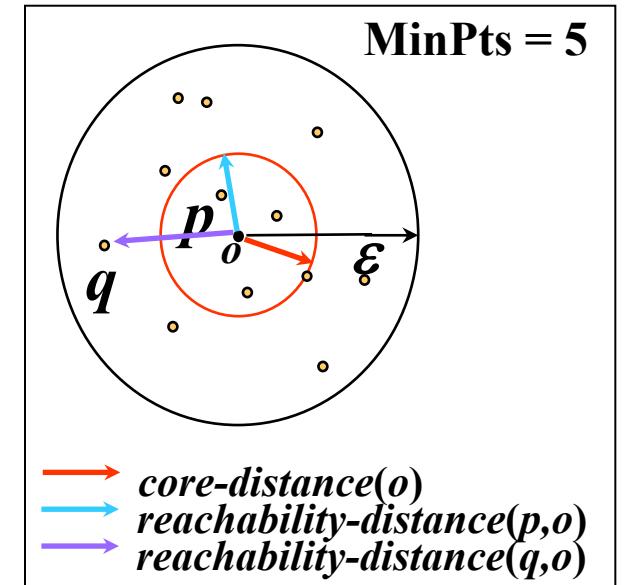


OPTICS (2)

$$\text{core-distance}_{\varepsilon, \text{MinPts}}(p) = \begin{cases} \text{UNDEFINED} & \text{if } |N_\varepsilon(p)| < \text{MinPts} \\ \text{distance to the } \text{MinPts}-\text{th closest point} & \text{otherwise} \end{cases}$$

$$\text{reachability-distance}_{\varepsilon, \text{MinPts}}(o, p) = \begin{cases} \text{UNDEFINED} & \text{if } |N_\varepsilon(p)| < \text{MinPts} \\ \max(\text{core-distance}_{\varepsilon, \text{MinPts}}(p), \text{distance}(p, o)) & \text{otherwise} \end{cases}$$

- **Απόσταση-πυρήνα (core-distance)** ενός σημείου p : η μικρότερη απόσταση ε ώστε η ε -γειτονιά του σημείου p να περιέχει τουλάχιστον MinPts σημεία
 - Με άλλα λόγια, η απόσταση του p από το MinPts -ο πλησιέστερο σημείο
- **Απόσταση-προσεγγισιμότητας (reachability-distance)** ενός σημείου o από ένα σημείο p : η μέγιστη μεταξύ δύο παρακάτω αποστάσεων:
 - της απόστασης μεταξύ των 2 σημείων και
 - της απόστασης-πυρήνα του σημείου p (το οποίο p πρέπει να είναι σημείο-πυρήνας)

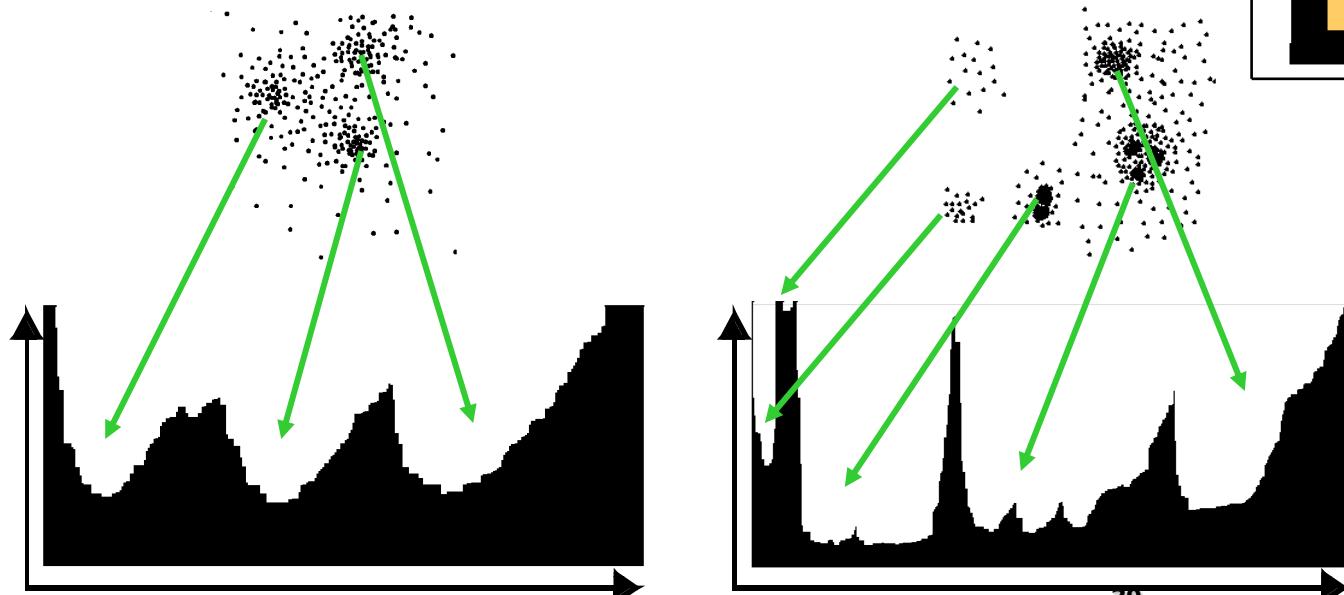


OPTICS (3)

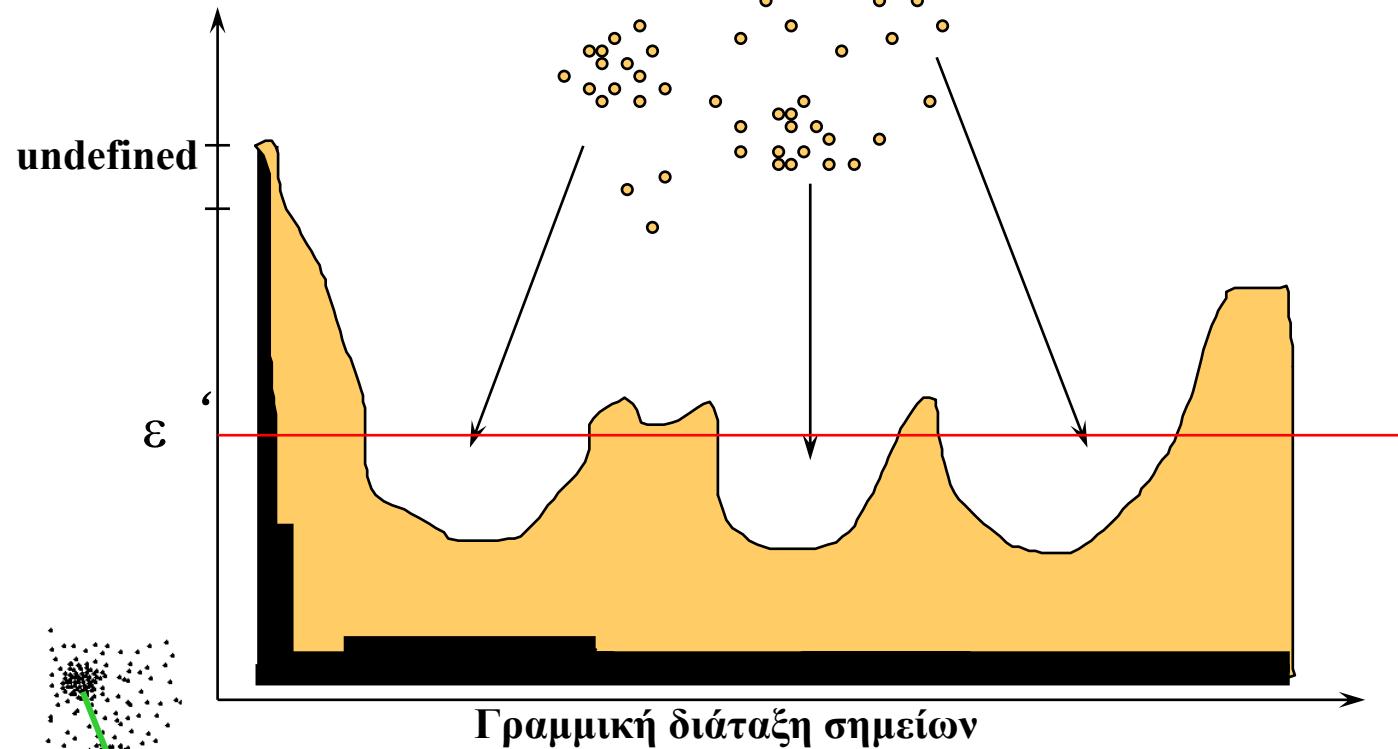
- **Γραφική προσεγγισμότητας**

(reachability plot): διάταξη με βάση την απόσταση-προσεγγισμότητας
(reachability distance)

- «**κοιλάδες**» (valleys) → συστάδες
- «**λόφοι**» (hills) → θόρυβος



Reachability-distance



- Στα υπέρ του OPTICS: αυτόματη αλλά και διαδραστική χρήση

OPTICS (4)

Πολυπλοκότητα: $O(n^2)$ ή $O(n \log n)$
αν υπάρχει χωρικό ευρετήριο
(index) για την επιτάχυνση των
ερωτημάτων χωρικής γειτνίασης

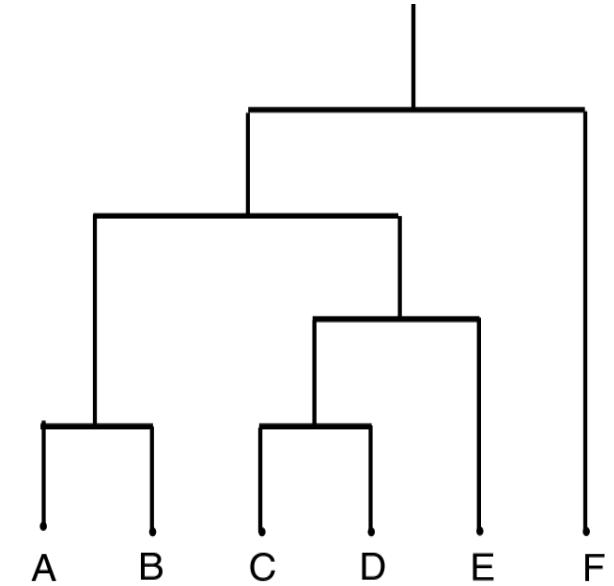
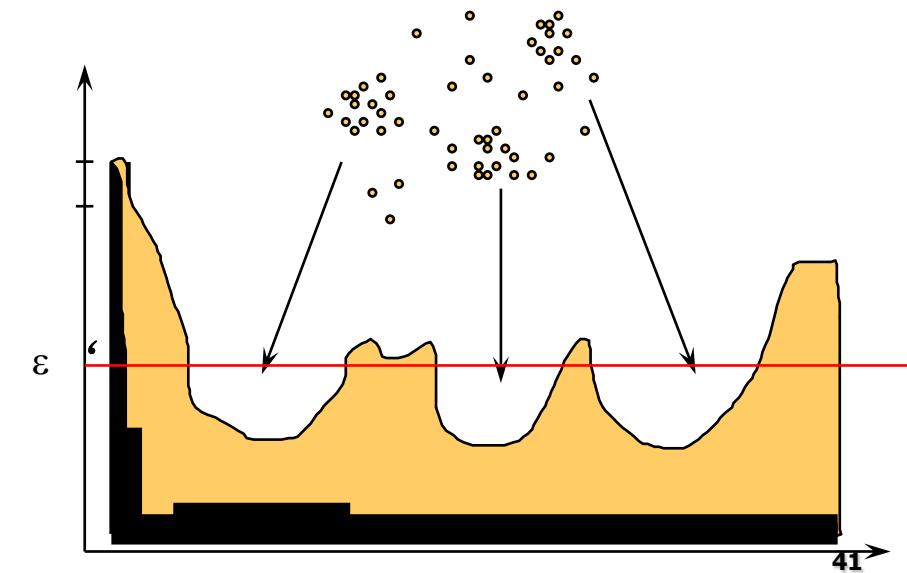
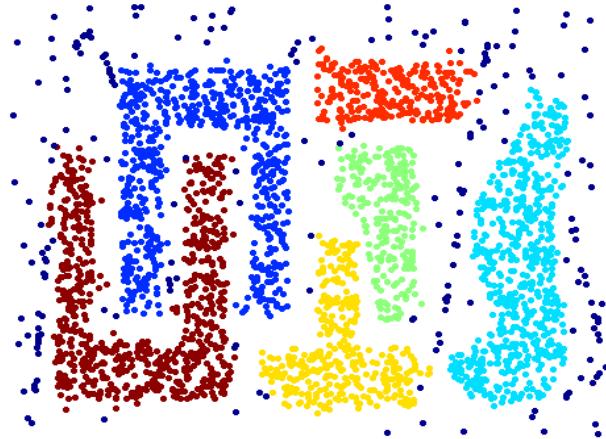
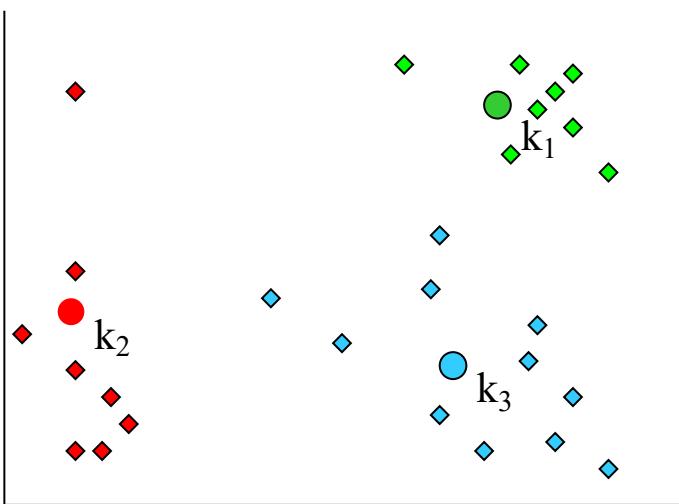
```
function OPTICS(DB, eps, MinPts) is
    for each point p of DB do
        p.reachability-distance = UNDEFINED
    for each unprocessed point p of DB do
        N = getNeighbors(p, eps)
        mark p as processed
        output p to the ordered list
        if core-distance(p, eps, MinPts) != UNDEFINED then
            Seeds = empty priority queue
            update(N, p, Seeds, eps, MinPts)
            for each next q in Seeds do
                N' = getNeighbors(q, eps)
                mark q as processed
                output q to the ordered list
                if core-distance(q, eps, MinPts) != UNDEFINED do
                    update(N', q, Seeds, eps, MinPts)
```

```
function update(N, p, Seeds, eps, MinPts) is
    coredist = core-distance(p, eps, MinPts)
    for each o in N
        if o is not processed then
            new-reach-dist = max(coredist, dist(p,o))
            if o.reachability-distance == UNDEFINED then // o is not in Seeds
                o.reachability-distance = new-reach-dist
                Seeds.insert(o, new-reach-dist)
            else // o in Seeds, check for improvement
                if new-reach-dist < o.reachability-distance then
                    o.reachability-distance = new-reach-dist
                    Seeds.move-up(o, new-reach-dist)
```

Πηγή: Wikipedia.org

Σύνοψη

- Συσταδοποίηση: η εύρεση ομάδων μεταξύ των δεδομένων ενός συνόλου
- Μεγάλη ποικιλία τεχνικών



Για περαιτέρω μελέτη

- Βιβλιογραφία (κατά σειρά: η μέθοδος k-means και μια κριτική στο «κριτήριο του αγκώνα», οι μέθοδοι DBSCAN και OPTICS, καθώς και 2 άρθρα επισκόπησης)
 - MacQueen J (1967) Some methods for classification and analysis of multivariate observations. In: Proc 5th Berkeley Symp Math Stat Probab 1: 281–297.
 - Schubert E (2022) Stop using the elbow criterion for k-means and how to choose the number of clusters instead. ACM SIGKDD Explorations Newsletter, 25(1): 36–42.
 - Ester M, Kriegel H, Sander J, Xu X (1996) A density-based algorithm for discovering clusters in large spatial databases with noise. In: Proc ACM SIGKDD Int Conf Knowledge Discovery and Data Mining (KDD), pp. 226–231.
 - Ankerst M, Breunig M, Kriegel H, Sander J (1999) OPTICS: ordering points to identify the clustering structure. In: Proc ACM SIGMOD Int Conf Management of Data, pp. 49–60.
 - Anil KJ, Murty MN, Flynn PJ (1999) Data clustering: A review. ACM Comput. Surv. 31(3): 264–323.
 - Xu D, Tian YA (2015) Comprehensive survey of clustering algorithms. Ann. Data. Sci. 2: 165–193.
- Ανοιχτός κώδικας:
 - scikit-learn: <https://scikit-learn.org/stable/modules/classes.html#module-sklearn.cluster>
 - PyClustering library: <https://codeloops.xyz/annoviko/pyclustering/index.html>