

Sistemi Intelligenti Soft Clustering

Alberto Borghese

Università degli Studi di Milano

Laboratorio di Sistemi Intelligenti Applicati (AIS-Lab)

Dipartimento di Informatica

alberto.borghese@unimi.it





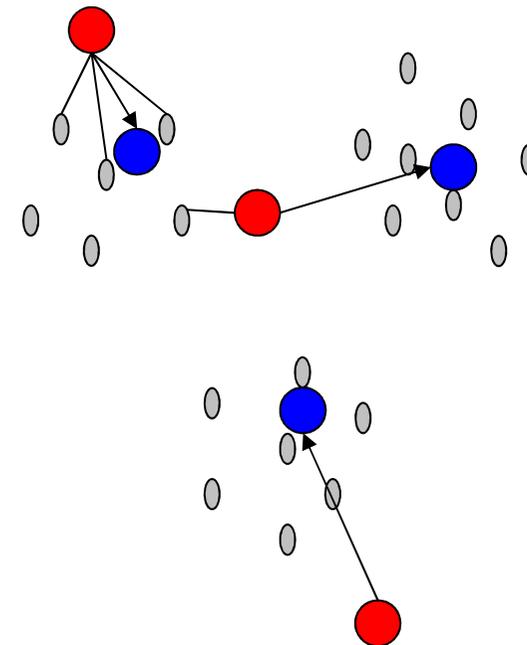
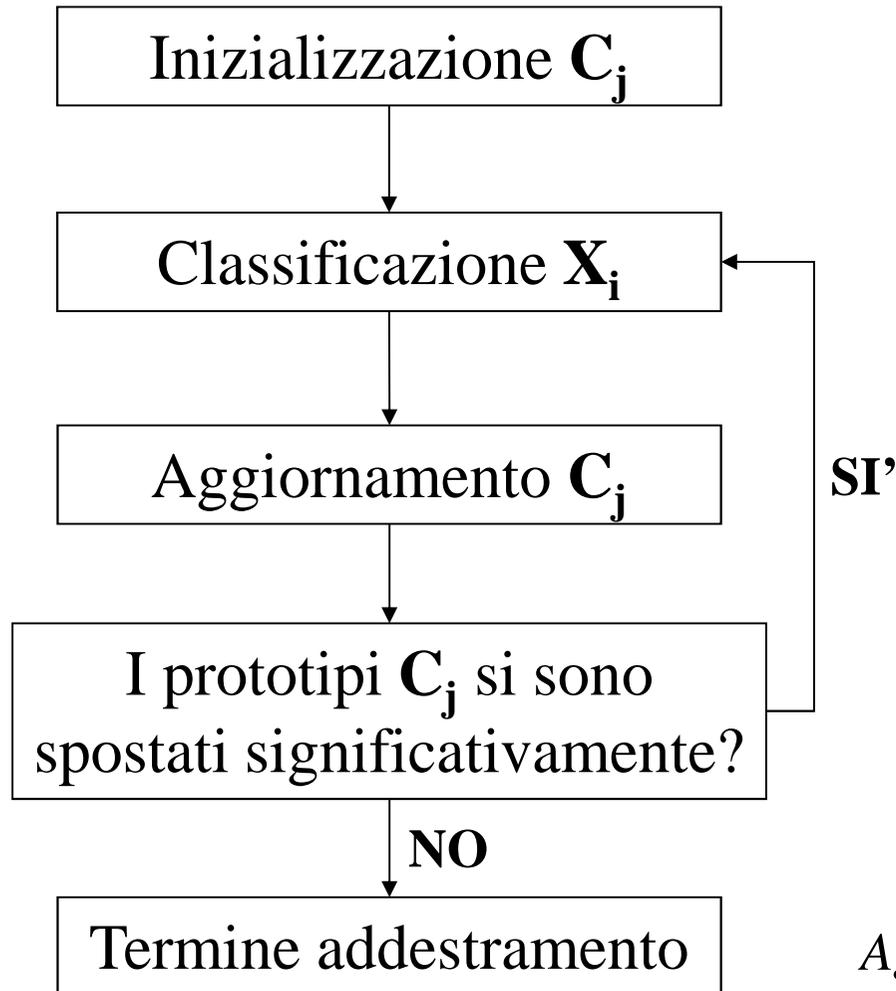
Riassunto



- **Soft Clustering**
- Mappe di Kohonen e altri utilizzi del clustering
- I modelli



K-means: addestramento



Aggiornamento C_j : baricentro degli X_i classificati da C_j .



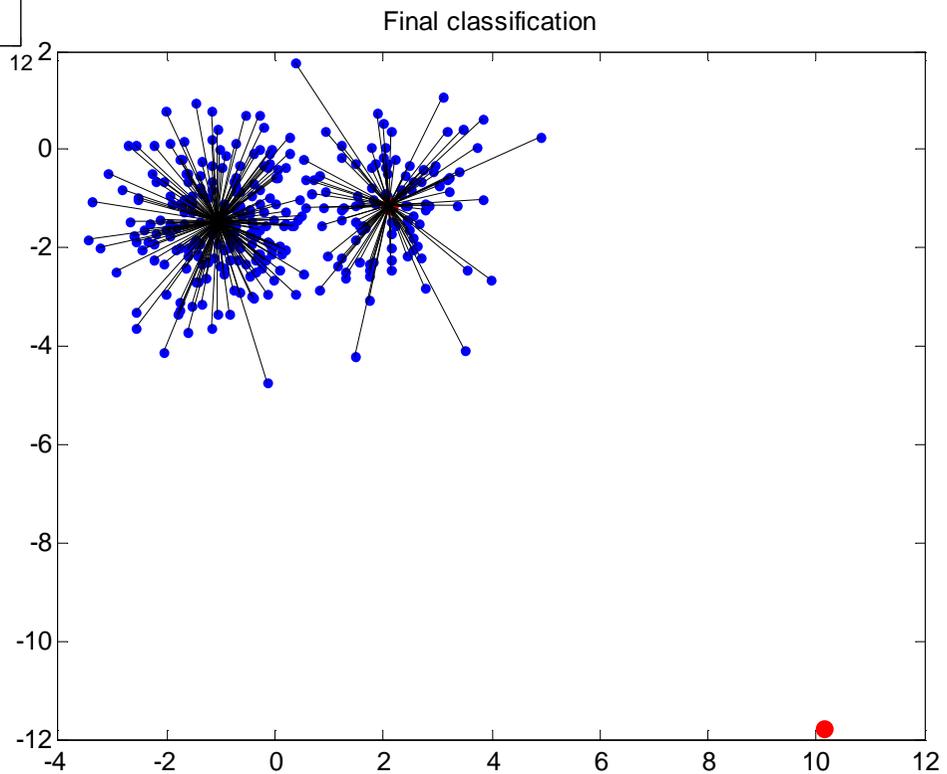
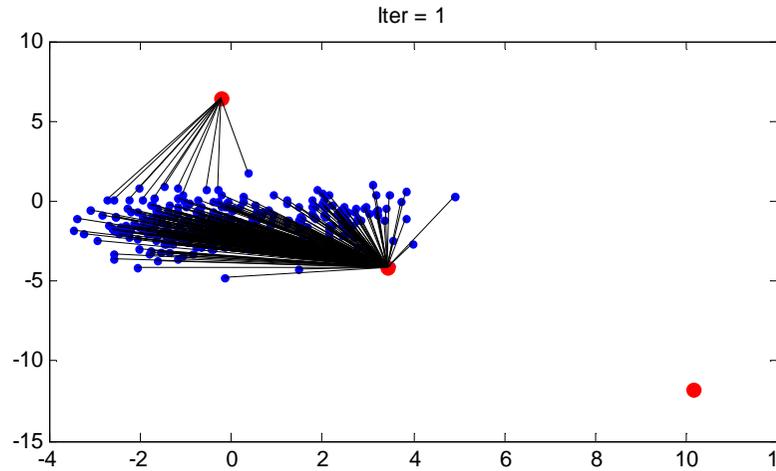
K-means::limiti

- Partitional, hard, deterministic;
- Veloce, semplice da implementare;
- Trova un minimo locale della funzione $f = \sum_j \sum_i [\text{dist}(x_i, \text{prot}_j)] / N_j$;
- Il risultato dipende dall'inizializzazione!
- Possono essere usati altri metodi (es. GA) per inizializzare K-means... es. GA per la minimizzazione di f , effettuano una ricerca globale, ma sono lenti!

Sw in Matlab available



Bad initialization





Principles of soft-clustering



- I centroidi vengono spostati e non posizionati
- Lo spostamento dei centroidi avviene analizzando iterativamente tutti i dati
- Lo spostamento viene ridotto via via che l'apprendimento procede



Competitive learning



- All'interazione k- esima, si presenti al sistema **un (1) dato**, \mathbf{X}_i ;
- **Aggiornamento di tutti i prototipi \mathbf{W}_j (“neuroni”)**
- Generalized competitive Learning Rule:

$$\blacklozenge \Delta \mathbf{W}_j = \eta_k \Lambda_k(i,j) (\mathbf{X}_i - \mathbf{W}_j)$$

← AGGIORNAMENTO
PESI (POSIZIONE)
DEI NEURONI

$\Lambda_k(i,j)$ è una funzione “campo recettivo”

$$\blacklozenge \Lambda_k(i,j) = \exp(-\|\mathbf{X}_i - \mathbf{W}_j\|^2 / 2\sigma_k^2)$$

☞ (spazio dei dati)

$$\blacklozenge \Lambda_k(i,j) = \exp(-\|f(\mathbf{X}_i) - f(\mathbf{W}_j)\|^2 / 2\sigma_k^2)$$

☞ (spazio delle feature)

← FUNZIONI DI
VICINATO



Competitive learning



- All'interazione k- esima, si presenti alla rete **un (1)** dato \mathbf{X}_i ; al termine dell'apprendimento.
- Unità vincente (associazione):

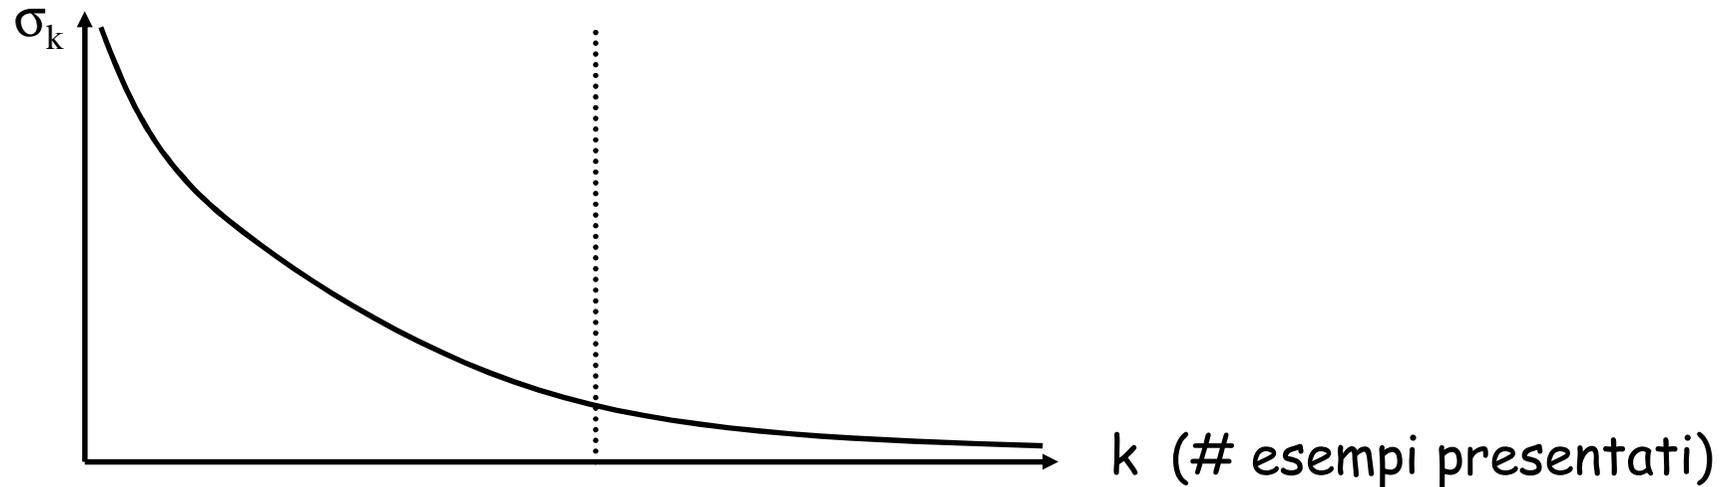
$$j^* \text{ t.c. } \|\mathbf{W}_{j^*} - \mathbf{X}_i\| = \min_j \|\mathbf{W}_j - \mathbf{X}_i\|$$

UNITA' VINCENTE

Anche qui viene indotta una tessellazione di Voronoj dallo spazio da tutte le unità vincenti.



Funzione di vicinato nel tempo

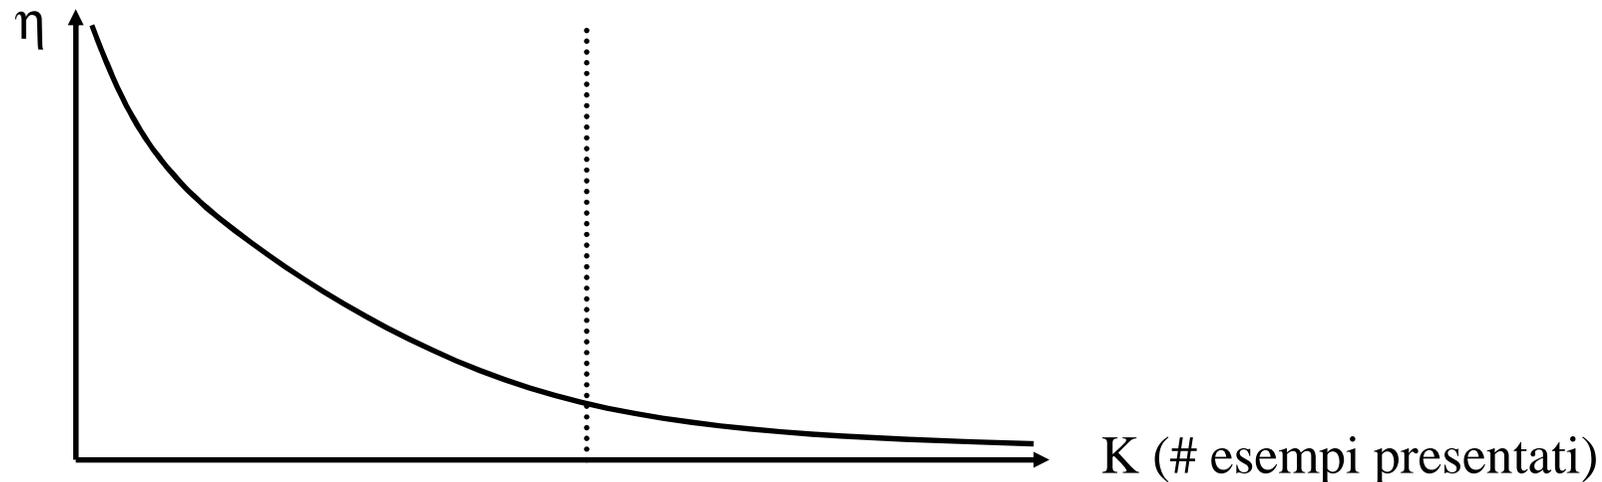


$$\Delta \mathbf{W}_j = \eta_k \Lambda_k(i,j) (\mathbf{X}_i - \mathbf{W}_j)$$

Procedendo nell'addestramento della rete, un neurone perde la capacità di spostare i suoi vicini.



Learning rate nel tempo



$$\Delta \mathbf{W}_j = \eta_k \Lambda_k(i,j) (\mathbf{X}_i - \mathbf{W}_j)$$

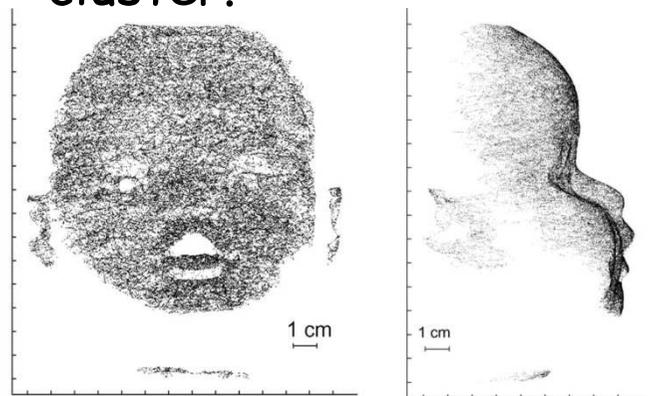
Procedendo nell'addestramento della rete, i pesi dei neuroni perdono la possibilità di muoversi \Rightarrow rete più stabile.



Competitive learning ("First search then converge")



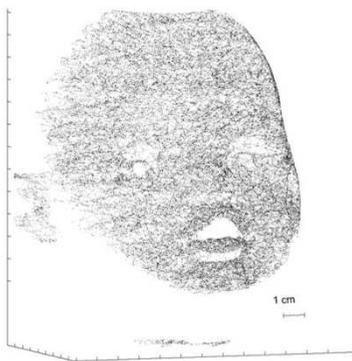
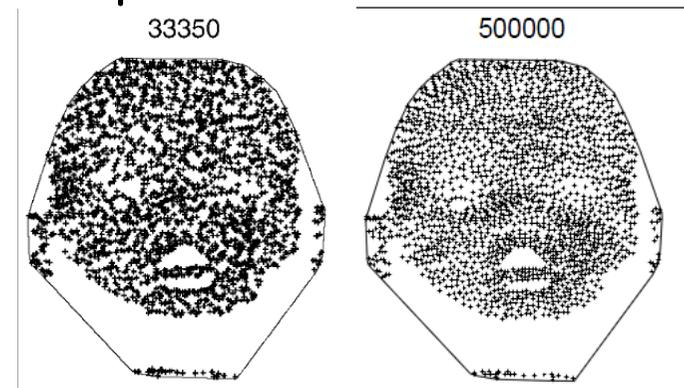
- 1) **ORDERING PHASE:** η , σ grandi; ogni neurone può spostarsi molto verso l'ingresso X_i ; il neurone trascina con sé i vicini; in tale fase la rete si dispiega nello spazio R^N "spargendo" i suoi neuroni.
- 2) **TUNING PHASE:** η , σ piccoli; ogni neurone si muove da solo; è una fase di raffinamento in cui vengono raggiunti con precisione i centri dei cluster.



(a)

(b)

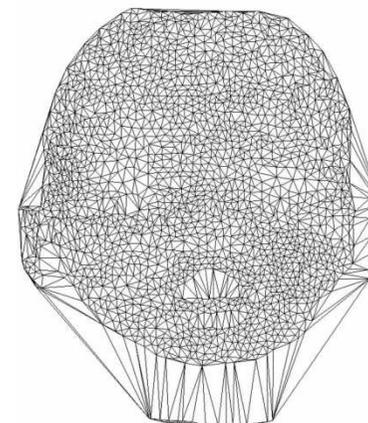
100,000 sampled
points
reconstructed
with 2,000 RV



(c)



(d)



(c)



(d)



Soft-clustering



$$\Delta \mathbf{W}_j = \eta_k \Lambda_k(i,j) (\mathbf{X}_i - \mathbf{W}_j)$$

$\Lambda_k(i,j)$ è l'elemento chiave. I “Campi recettivi” dei diversi neuroni sono parzialmente sovrapposti.

In “Competitive clustering” $\Lambda_k(i,j)$ è una Gaussiana nello spazio dei dati $\underline{0}$ dei prototipi (mappe di Kohonen).

In “Neural-gas” $\Lambda_k(i,j)$ è una ranking function nello spazio dei dati e dei prototipi.

In “Fuzzy c-means” $\Lambda_k(i,j)$ è realizzata mediante membership function nello spazio dei dati.



I problemi del soft-clustering

Dead-units: sono centroidi che non vengono aggiornati da un certo passo, k , in poi.

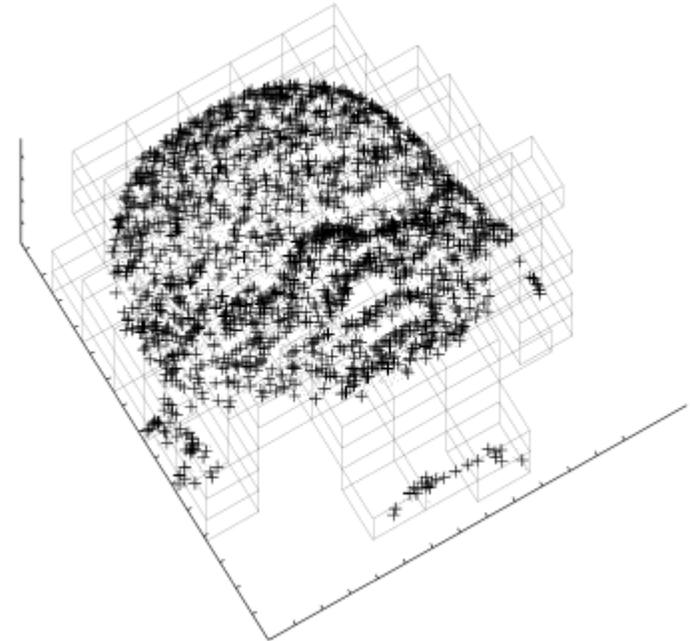
Inizializzazione guidata dai dati.

$$\rho_{Centroid} = \rho_{Data}^{\gamma} \quad \text{with} \quad \gamma = \frac{D}{D+2}$$

Partition of the input space and distribution of the number of centroids inside each box through a partitioning function:

$$M_k = M \frac{N_k^{\gamma}}{\sum_k N_k^{\gamma}}$$

Minimi locali.





Tipo di apprendimento

COMPETITIVE LEARNING. *Apprendimento competitivo. Dato un certo input, le unità competono tra loro per “aggiudicarsi” l’input.*

Questo meccanismo può essere hard. Nel caso estremo: “winner-take-all”, “spara” un solo neurone per volta (grandmother cell). Oppure può essere soft, le unità raggiungono un grado diverso di “vincita”.

Winner-take-all → hard approach

More than one winner → soft approach



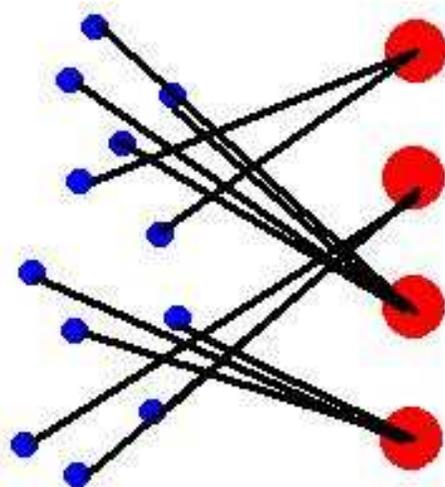
Riassunto



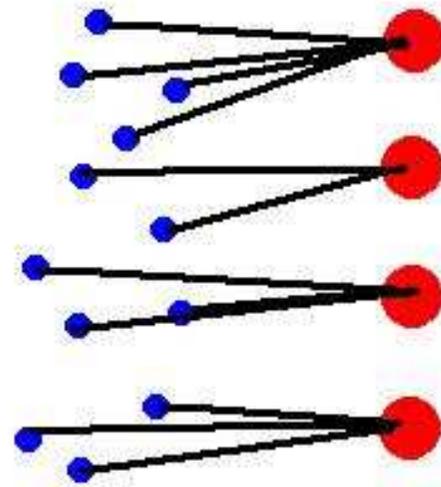
- Soft Clustering
- **Mappe di Kohonen e altri utilizzi del clustering**
- I modelli



Clustering vs. feature mapping



↑
Clustering

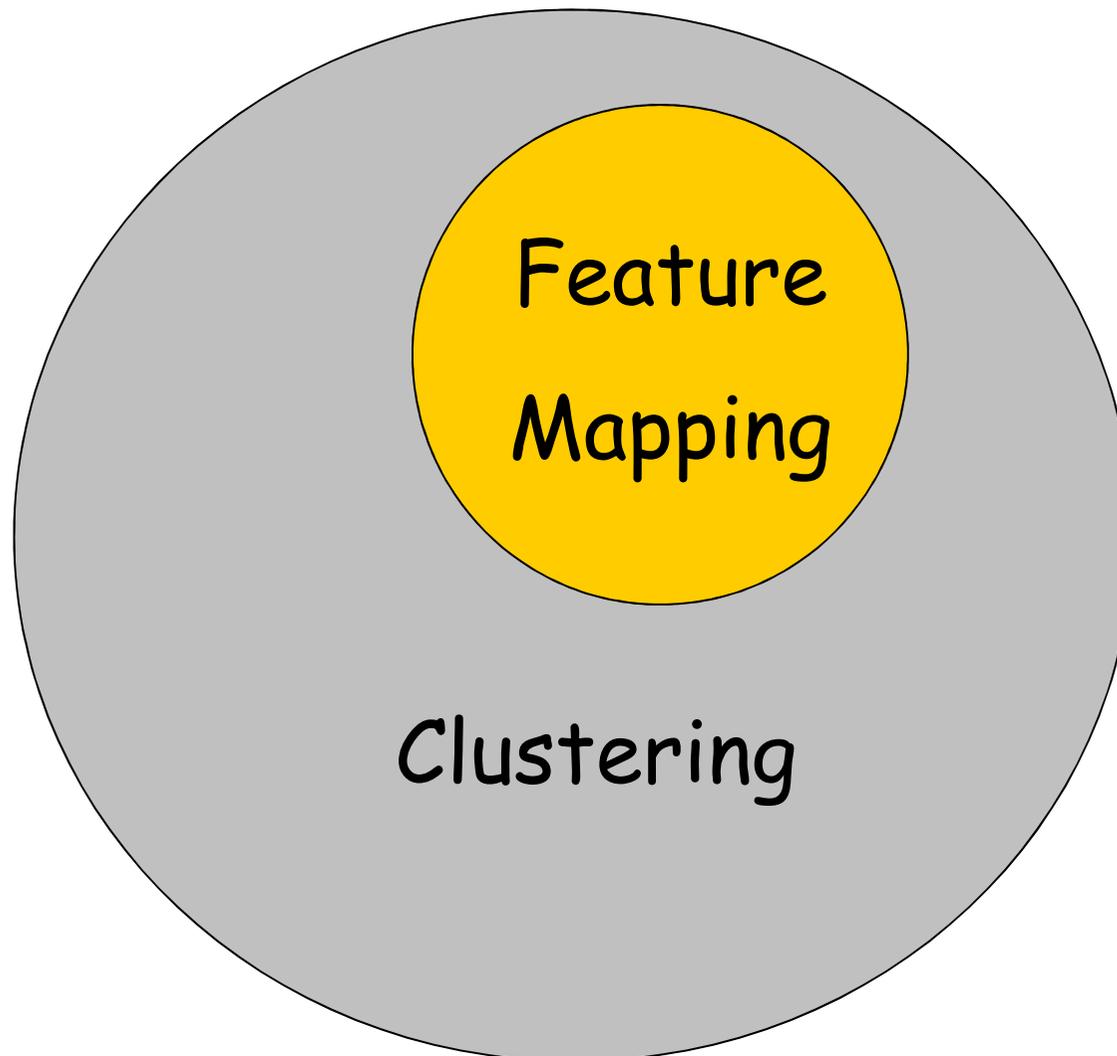


↑
Feature Mapping

A differenza di quanto accade con il clustering, nel feature mapping vengono preservate le relazioni topologiche tra i dati.



Clustering e feature mapping

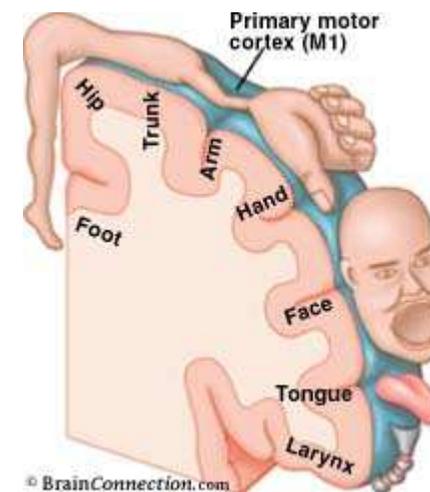


Feature mapping

Con il Feature Mapping si dà importanza alla posizione dei prototipi (xxx-topia, Homunculus motorio);

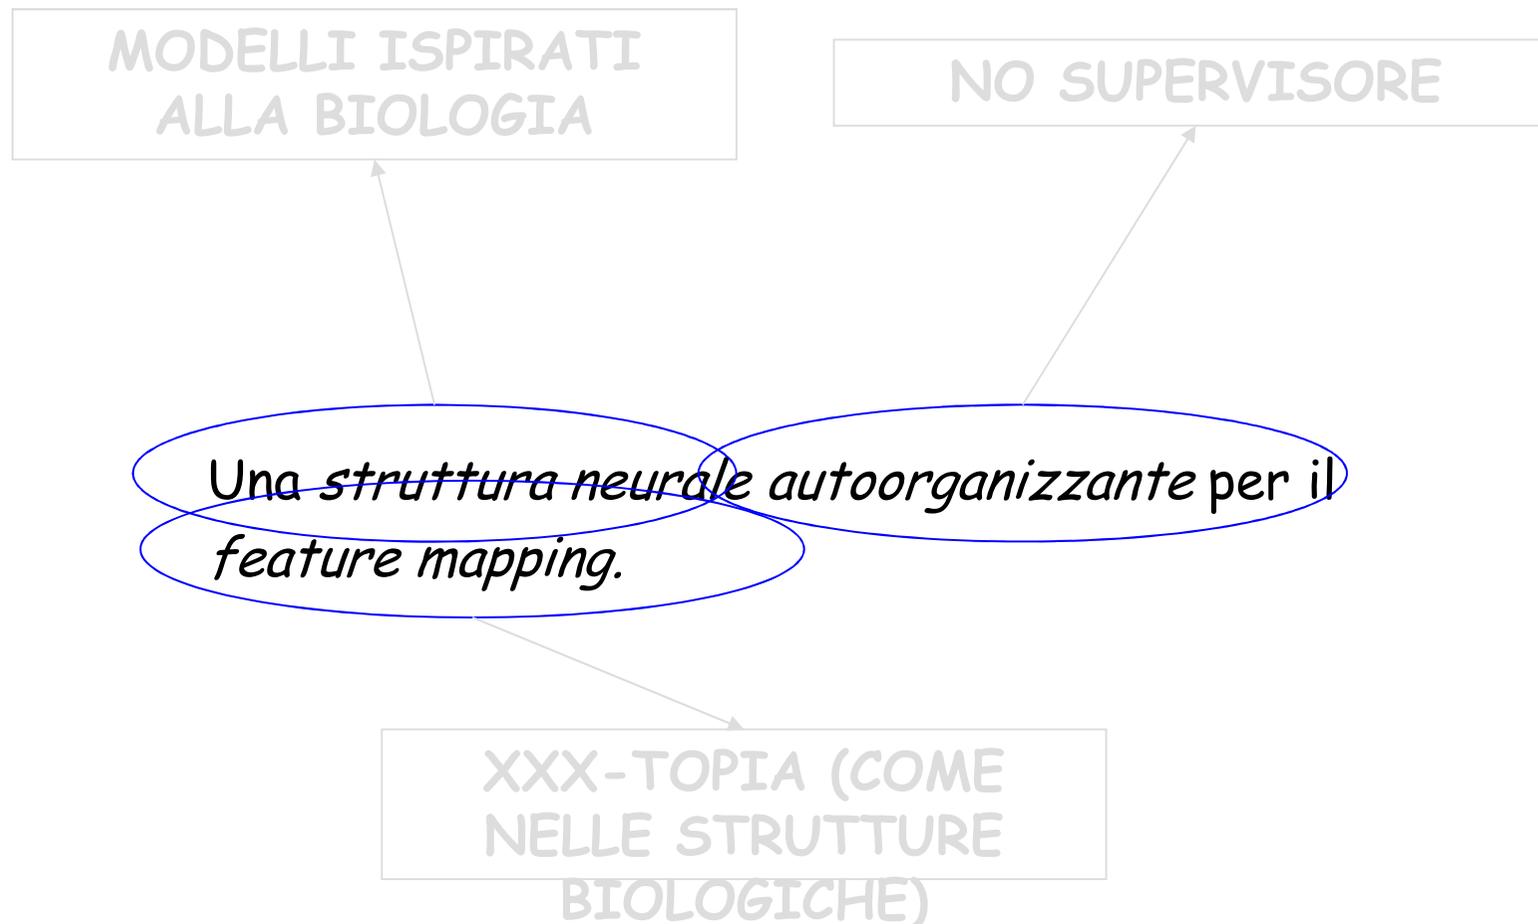
A uscite contigue corrispondono configurazioni d'ingresso contigue;

Il clustering opera una trasformazione tra lo spazio degli ingressi e lo spazio delle uscite (prototipi) che preserva le relazioni di vicinanza tra i vari elementi.





Self Organizing Maps (SOM)

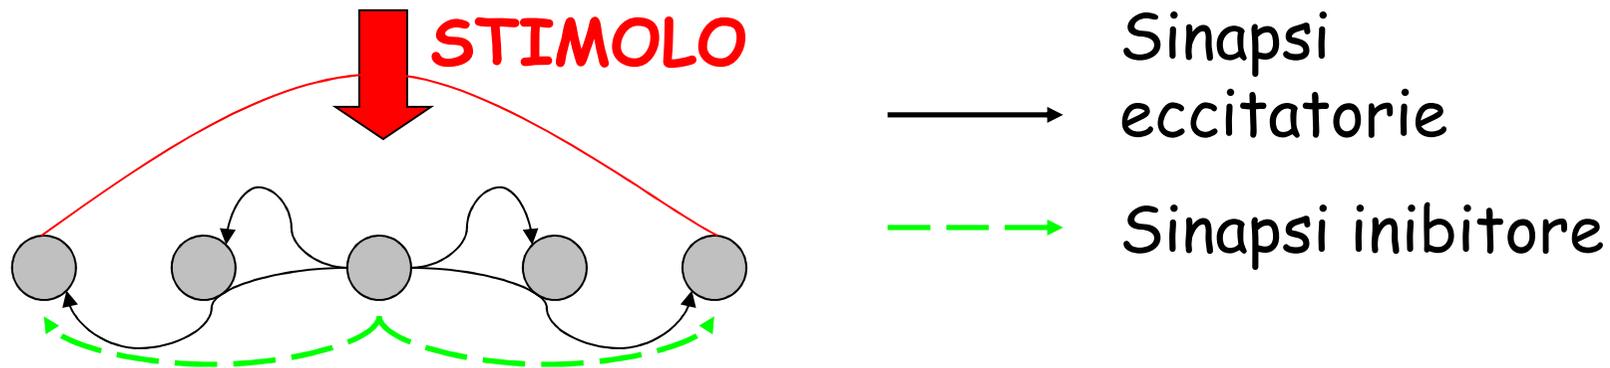




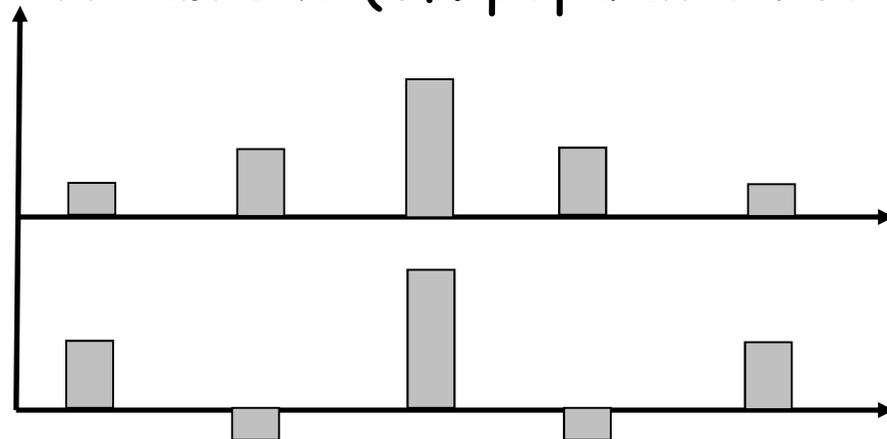
L'ispirazione biologica : Il campo recettivo



- Sinapsi eccitatorie verso i neuroni vicini;
- sinapsi inibitorie verso i neuroni lontani.



Attivazione (cf. population code)

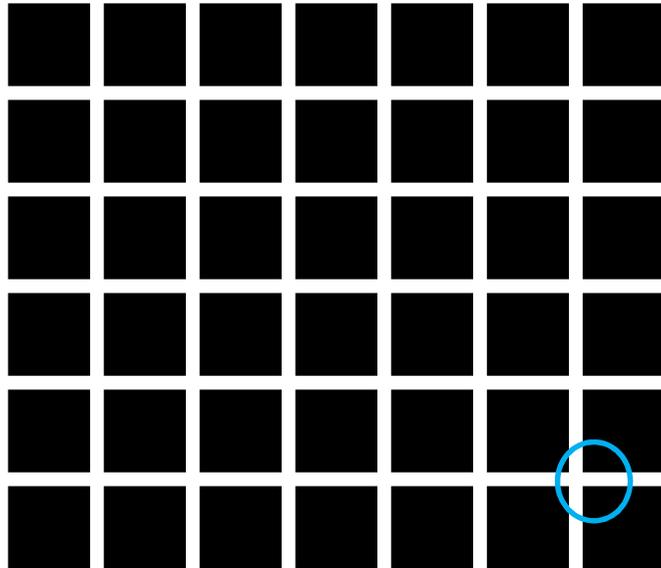


In assenza di sinapsi inibitorie

In presenza di sinapsi inibitorie



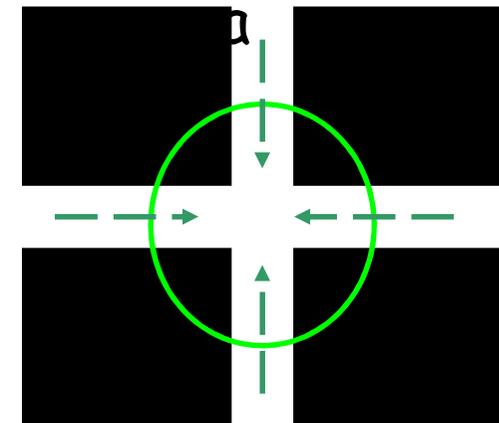
Il campo recettivo: effetto Hermann



Pallini neri agli incroci delle linee bianche.

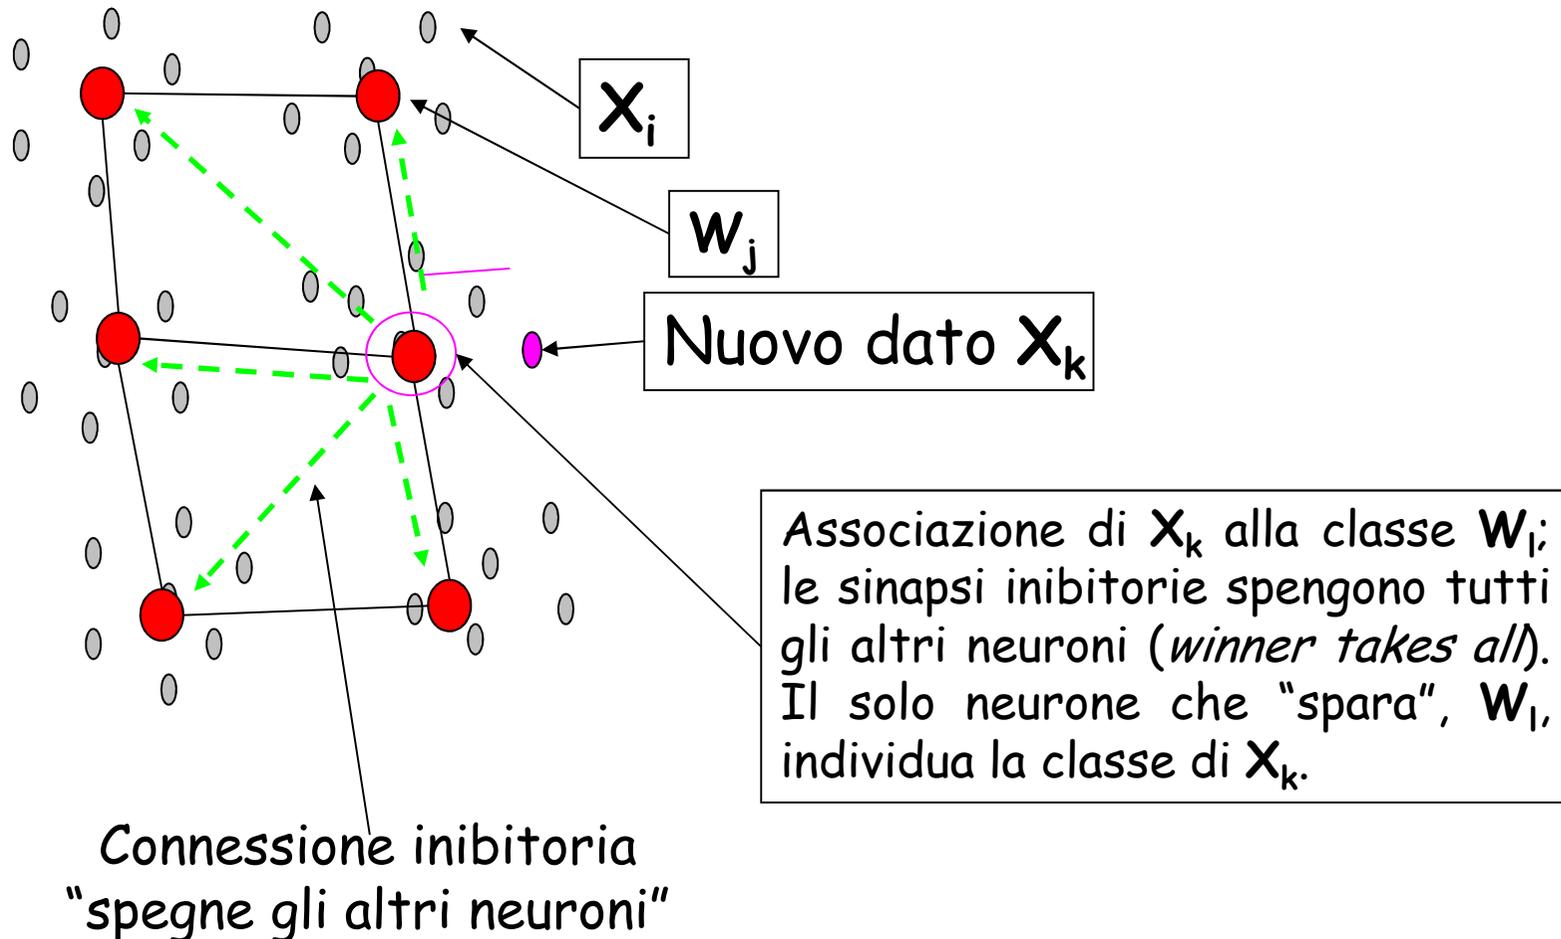
Il neurone centrale viene "spento" dai neuroni vicini attivi → generazione della zona scura.

--- → Inibitori





SOM: competitive learning in versione "hard"



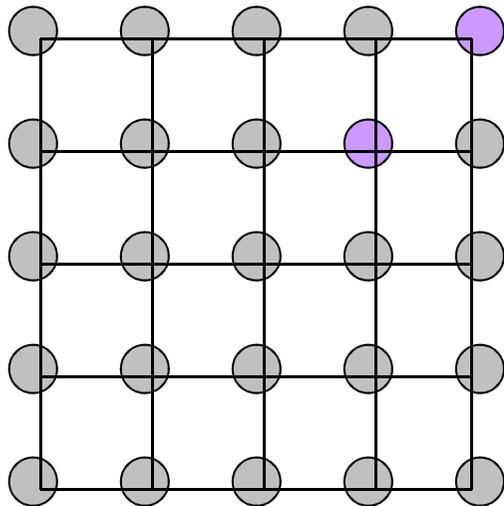
Mapping $R^N \rightarrow R^M$, con $M \leq N$ (da spazio delle caratteristiche a spazio delle classi).



SOM: organizzazione topologica



I neuroni della SOM sono ordinati topologicamente nello spazio dei neuroni (es. griglia ordinata in \mathbb{R}^2). In tale spazio viene definita la distanza tra neuroni.



La distanza tra i due neuroni (nello spazio dei neuroni) è:

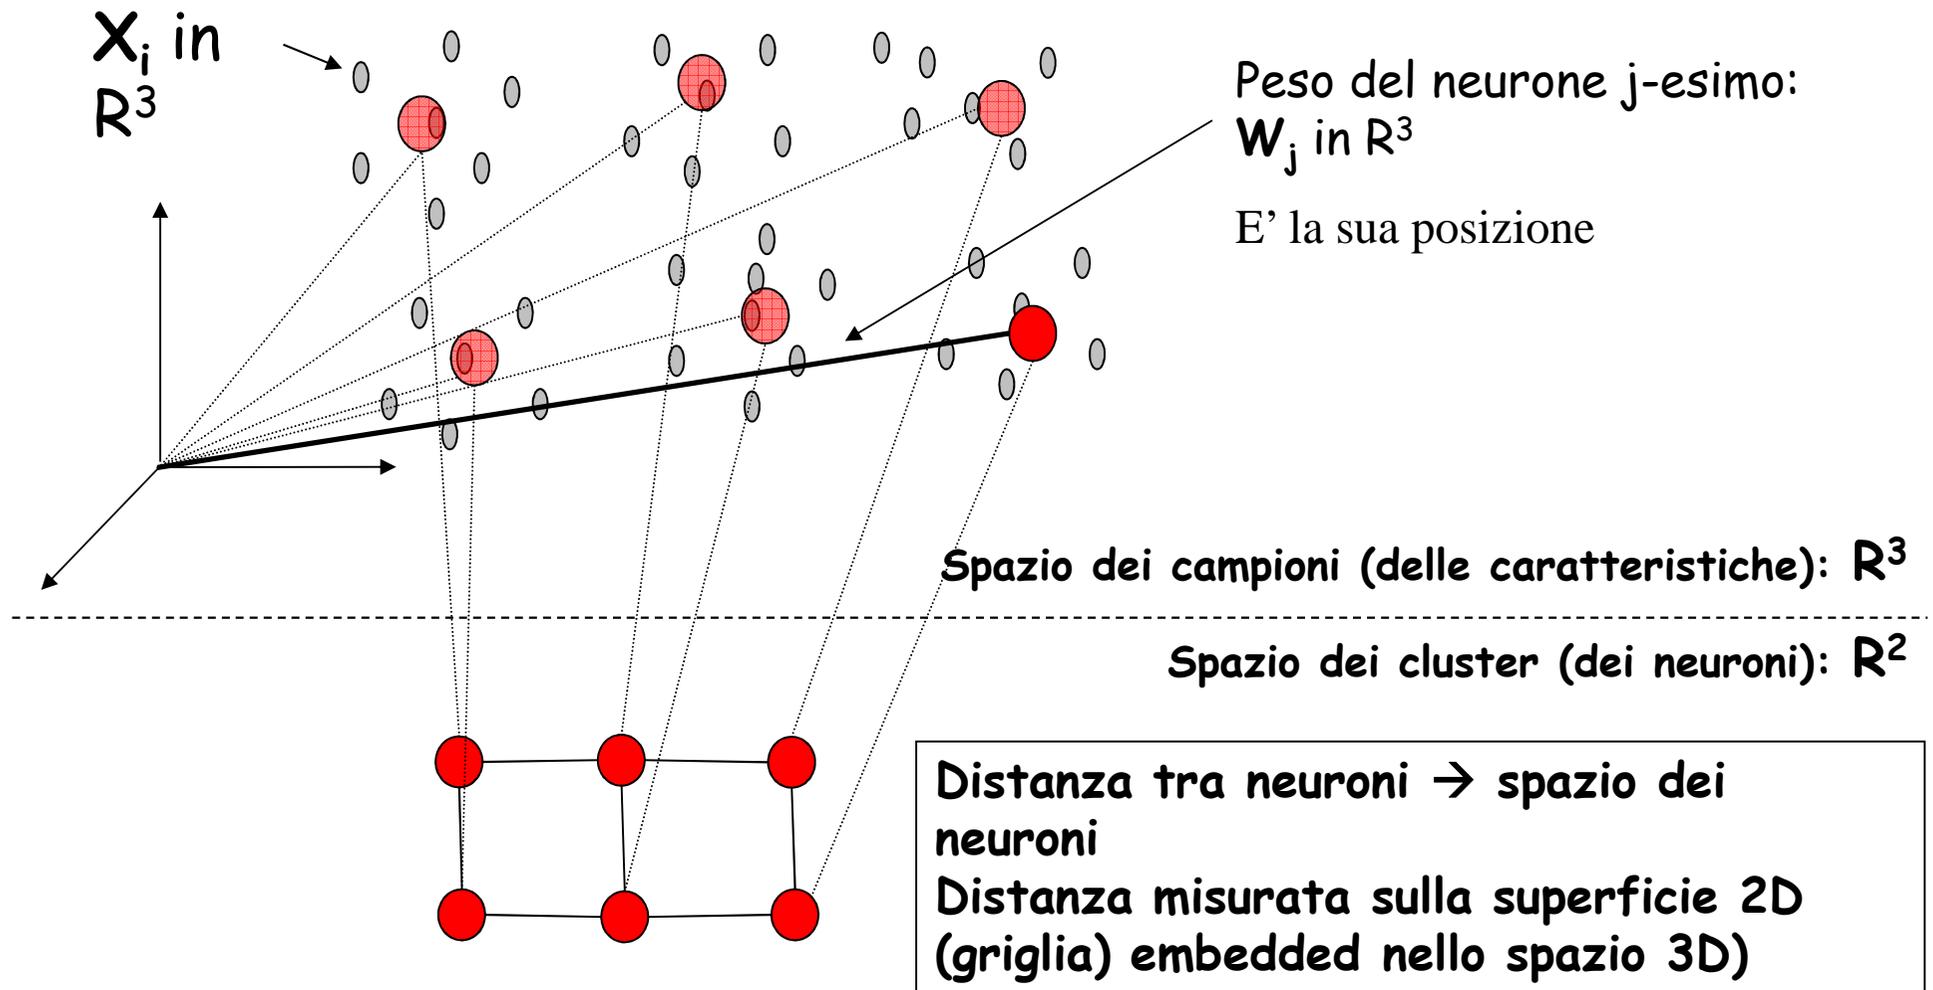
$$\sqrt{(\Delta x)^2 + (\Delta y)^2} = 1.4142 \quad [\text{Metrica Euclidea}]$$

$$|\Delta x| + |\Delta y| = 2 \quad [\text{Manhattan}]$$

...



SOM: pesi dei neuroni





SOM: addestramento



- Siano $\mathbf{X}_1, \dots, \mathbf{X}_D$ i dati di addestramento (per semplicità, definiti in \mathbb{R}^3);
- siano $\mathbf{W}_1, \dots, \mathbf{W}_K$ i *prototipi* di K classi, definiti anch'essi in \mathbb{R}^3 ; ogni *prototipo* identifica il peso di un neurone della SOM (\mathbf{W}_j);
- lo schema di associazione adottato sia il seguente: “ \mathbf{X}_i appartiene a \mathbf{W}_j se e solo se \mathbf{W}_j è il *prototipo* (*peso del neurone*) più vicino a \mathbf{X}_i , nello spazio dei campioni (delle caratteristiche, \mathbb{R}^3)”;
- l'algoritmo di addestramento permette di determinare i pesi dei neuroni (le posizioni dei *prototipi*) \mathbf{W}_j mediante successive approssimazioni;
- L'algoritmo di addestramento tiene conto della topologia dei neuroni nello spazio dei neuroni (*feature mapping*).



SOM: output



- All'interazione k- esima, si presenti alla rete il dato \mathbf{X}_i ;
- Unità vincente (associazione):
$$j^* \text{ t.c. } \|\mathbf{W}_{j^*} - \mathbf{X}_i\| = \min_j \|\mathbf{W}_j - \mathbf{X}_i\|$$
- Uscita:
 - ◆ $u_{j^*} = 1$, se $j = j^*$
 - ◆ $u_j = 0$ se $j \neq j^*$

UNITA'
VINCENTE





SOM e competitive learning



- All'interazione k- esima, si presenti alla rete il dato \mathbf{X}_i ;
- Unità vincente (associazione):
$$j^* \text{ t.c. } \|\mathbf{W}_{j^*} - \mathbf{X}_i\| = \min_j \|\mathbf{W}_j - \mathbf{X}_i\|$$

- Competitive Learning Rule (SOM, Kohonen '81):

- ◆ $\Delta \mathbf{W}_j = \eta_k \Lambda_k(j^*, j) (\mathbf{X}_i - \mathbf{W}_j)$

← AGGIORNAMENTO
PESI DEI NEURONI

- ◆ $\Lambda_k(j^*, j) = \exp(-\|\mathbf{W}_{j^*} - \mathbf{W}_j\|^2 / 2\sigma_k^2)$

← FUNZIONE DI
VICINATO

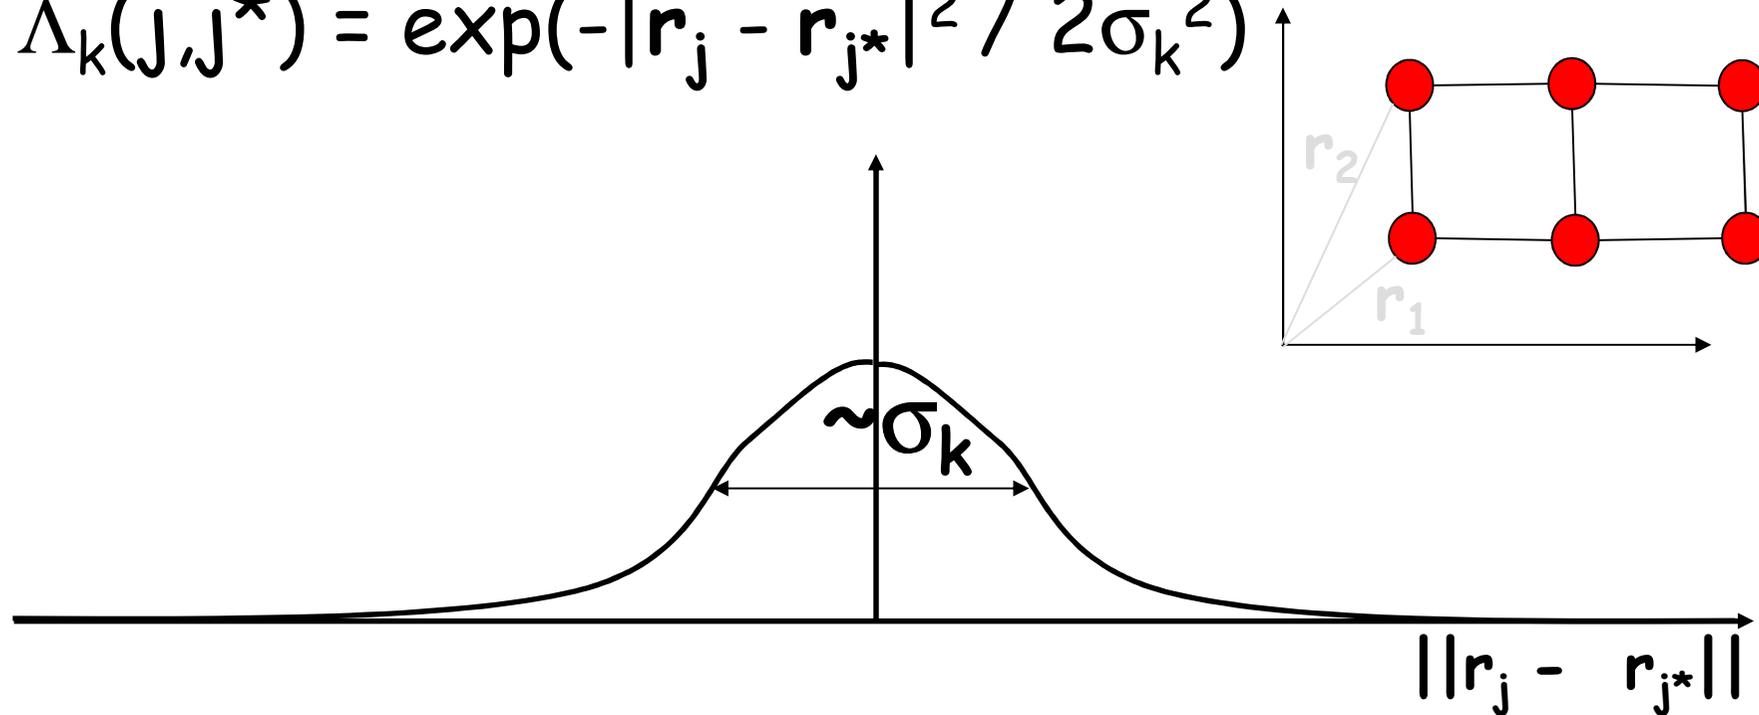
Calcolata nello spazio
dei prototipi



Funzione di vicinato



$$\Lambda_k(j, j^*) = \exp(-|r_j - r_{j^*}|^2 / 2\sigma_k^2)$$

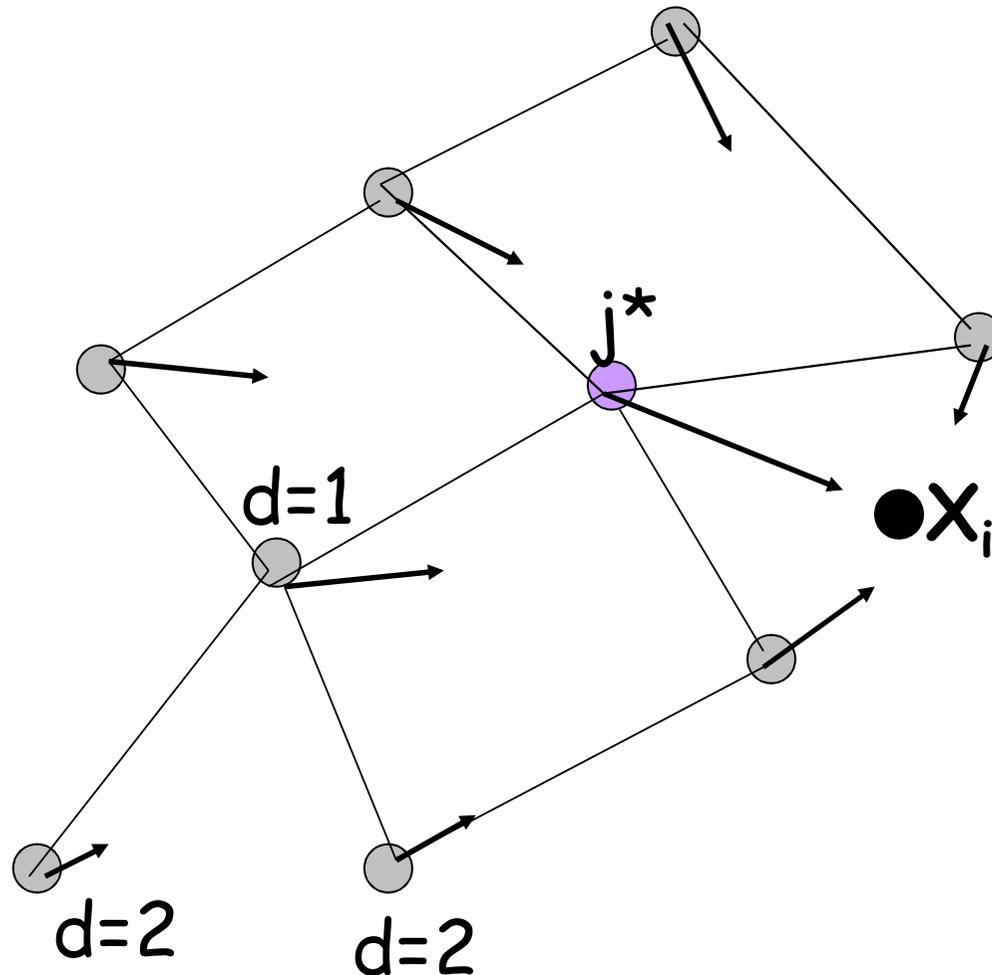


Neurone lontano dal neurone vincente: $\Lambda_k(j, j^*) \rightarrow 0$, $k \rightarrow \infty$
 $\sigma_k \rightarrow 0$, l'esponenziale va rapidamente a 0, solo il neurone vincente, j^* , viene aggiornato.

$\sigma_k \rightarrow \infty$ l'esponenziale rimane costantemente = 1. aggiornano tutti i neuroni di una quantità pari a: $\Delta W_j = \eta_k (X_i - W_j)$



SOM: addestramento



In definitiva:

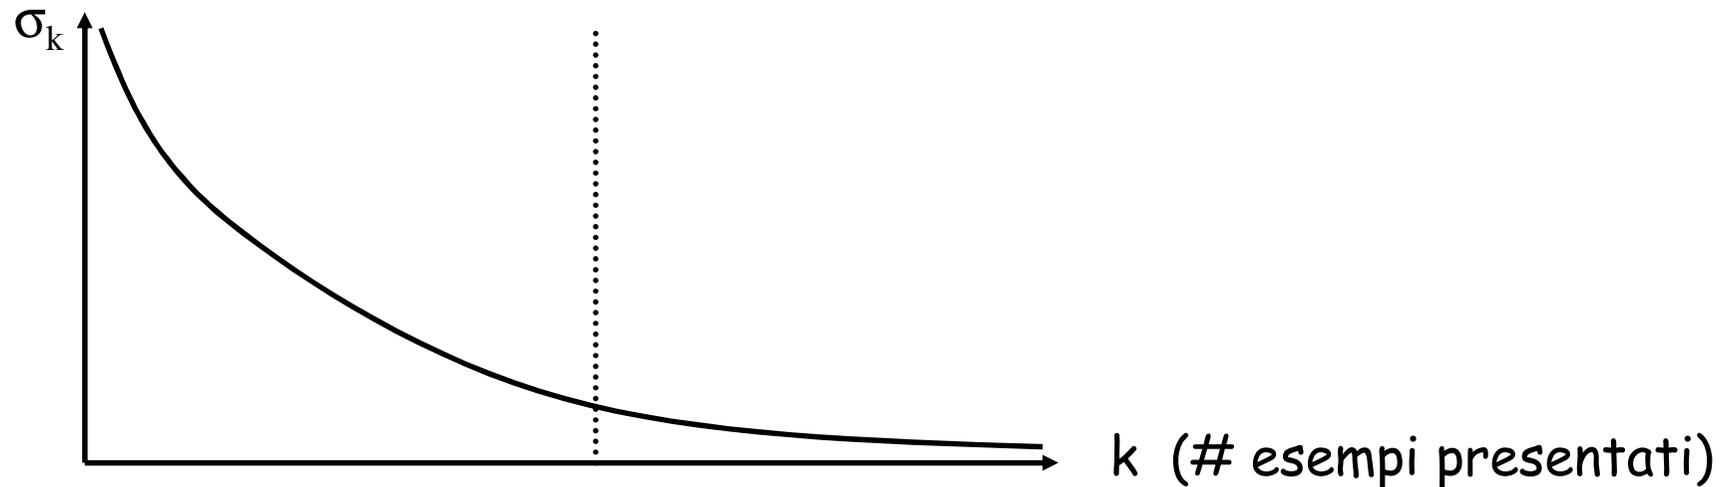
- Il neurone vincente si sposta verso X_i , trascinando i vicini in proporzione alla loro distanza nello spazio delle feature.

- L'ordinamento dei pesi dei neuroni nello spazio dei dati è simile all'ordinamento dei neuroni nello spazio dei neuroni.

<http://borghese.di.unimi.it/>



Funzione di vicinato nel tempo



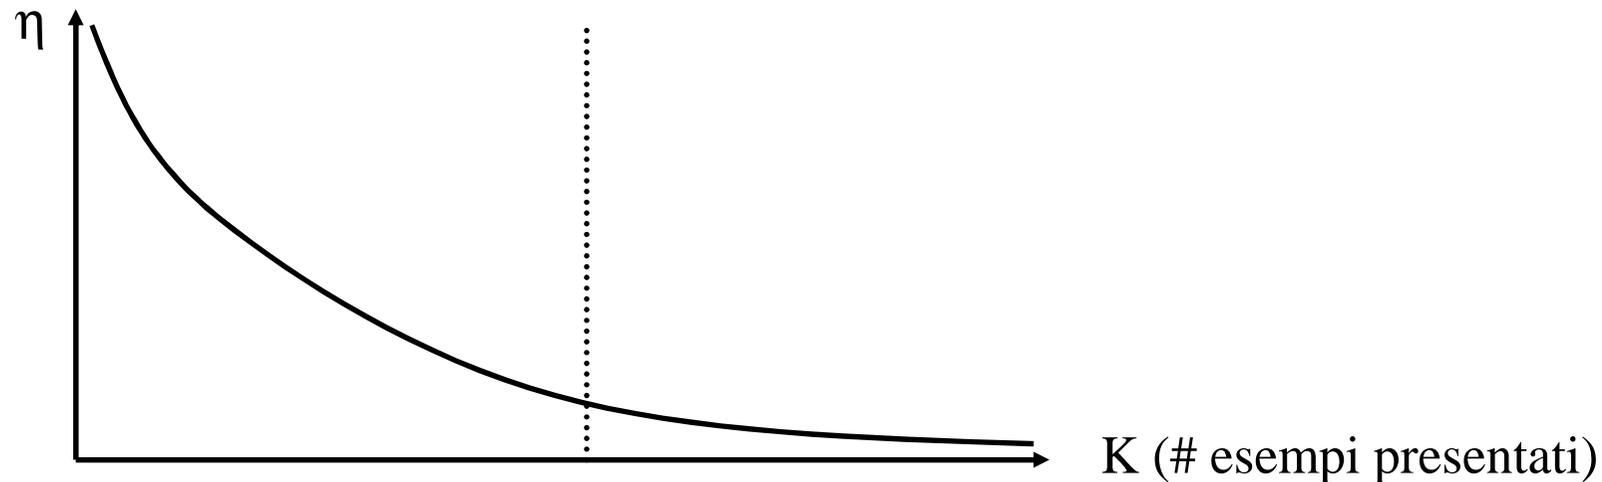
$$\Delta \mathbf{w}_j = \eta_k \Lambda_k(j, j^*) (\mathbf{X}_i - \mathbf{w}_j) \rightarrow \mathbf{w}' = \mathbf{w} + \eta_k \Lambda_k \mathbf{X}_i - \eta_k \Lambda_k \mathbf{w}$$

$$\Lambda_k(j, j^*) = \exp(-\|r_j - r_{j^*}\|^2 / 2\sigma_k^2)$$

Procedendo nell'addestramento della rete, un neurone perde la capacità di spostare i suoi vicini.



Learning rate nel tempo



$$\Delta \mathbf{w}_j = \eta_k \Lambda_k(j, j^*) (\mathbf{X}_i - \mathbf{w}_j) \rightarrow \mathbf{w}' = \mathbf{w} + \eta_k \Lambda_k \mathbf{X}_i - \eta_k \Lambda_k \mathbf{w}_i$$

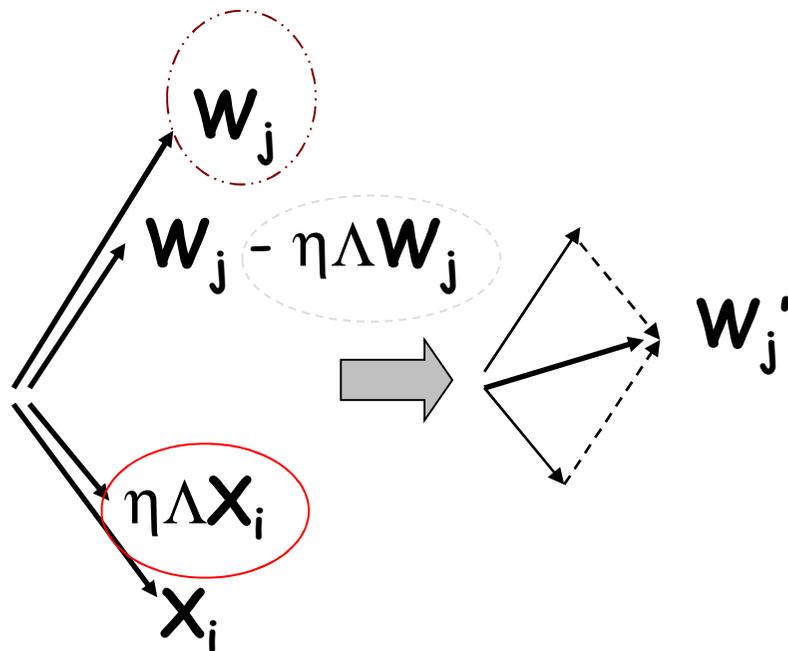
Procedendo nell'addestramento della rete, i pesi dei neuroni perdono la possibilità di muoversi \Rightarrow rete più stabile.



Competitive Learning come forze contrapposte



$$\Delta \mathbf{W}_j = \eta_k \Lambda_k(i,j) (\mathbf{X}_i - \mathbf{W}_j) \rightarrow \mathbf{W}_j' = \mathbf{W}_j + \eta_k \Lambda_k(i,j) \mathbf{X}_i - \eta_k \Lambda_k(i,j) \mathbf{W}_j$$



Il peso \mathbf{W}_j del neurone vincente j si sposta verso l'ingresso presentato \mathbf{X}_i .
- $\eta \mathbf{W}_j$ evita che il peso \mathbf{W}_j cresca a dismisura.



SOM: addestramento



- L'addestramento avviene presentando alla rete i vettori (dati) $X_i \in \mathbb{R}^N$ per un numero di epoche E ;
- Per ogni esempio presentato X_i vengono aggiornati i pesi dei neuroni della rete;
- Durante l'addestramento il learning rate η e la neighborhood distance σ decrescono;
- Se presentiamo alla rete un nuovo esempio X_i alla fine dell'addestramento, la rete lo associa al neurone vincente (clustering);

In più:

- Categorie simili sono rappresentate da neuroni vicini (feature mapping).



SOM: problemi



- E' necessario scegliere η , σ , numero di epoche, durata della ordering phase \rightarrow metodi empirici(!);
- Scelta della topologia e del numero di neuroni corretti;
- I dati di addestramento devono presentare una certa ridondanza;
- Unità "morte" (dead-units);

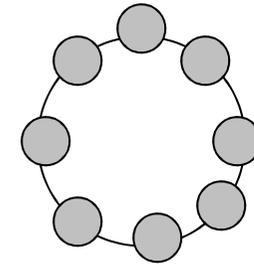


SOM per ordinamento



Spazio dei dati X_i (e dei pesi w) : \mathbb{R}^3

Topologia della SOM : circolare



Parametri di addestramento : # neuroni, $\eta(t)$, $\sigma(t)$, ...

Movie here (with RealPlayer)

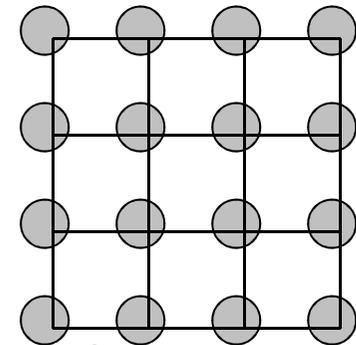


SOM per ricostruzione 3D



Spazio dei dati q (e dei pesi w) : \mathbb{R}^3

Topologia della SOM : griglia 2D



Parametri di addestramento
10x10, 0.5 \rightarrow
1 lin, ...

: # neuroni =
0.1 lin, 10 \rightarrow

[Movie here](#)



SOM per ricostruzione 3d



Problemi:

- Oscillazioni della rete all'inizio dell'addestramento;

Sol.: Scelta accurata di $\eta(t)$, $\sigma(t)$

- Raggiungimento dei confini della superficie aperta;

modificati

Sol.: Boundary First Method + η , σ

- Numero insufficiente di neuroni;

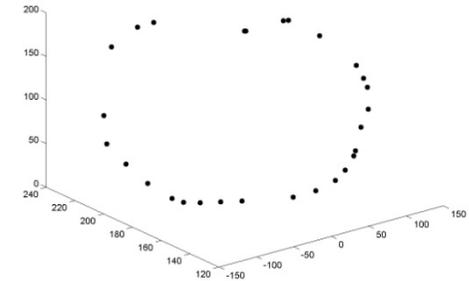
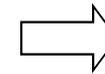
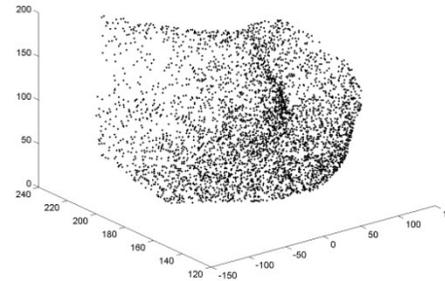
Sol.: Parametrizzazione della points cloud



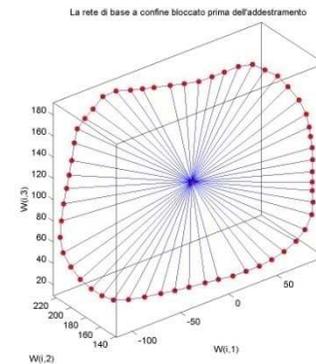
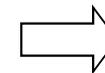
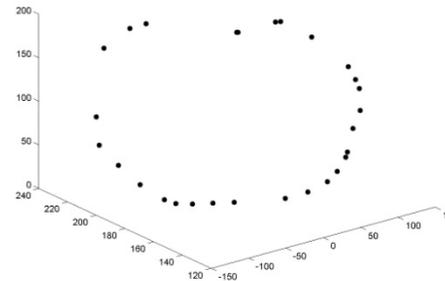
Boundary First Method



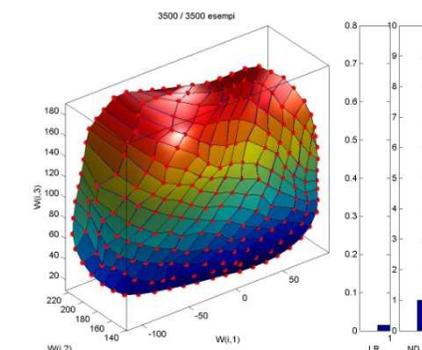
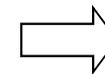
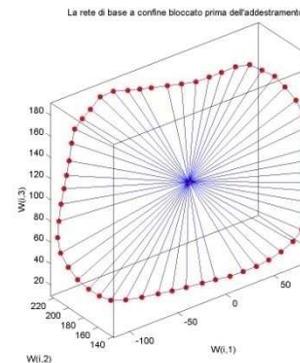
1) Individuazione dei punti di confine della superficie



2) Posizionamento dei neuroni di bordo



3) Addestramento della SOM (neuroni di bordo bloccati), η, σ maggiori ai lati





SOM per ricostruzione 3D



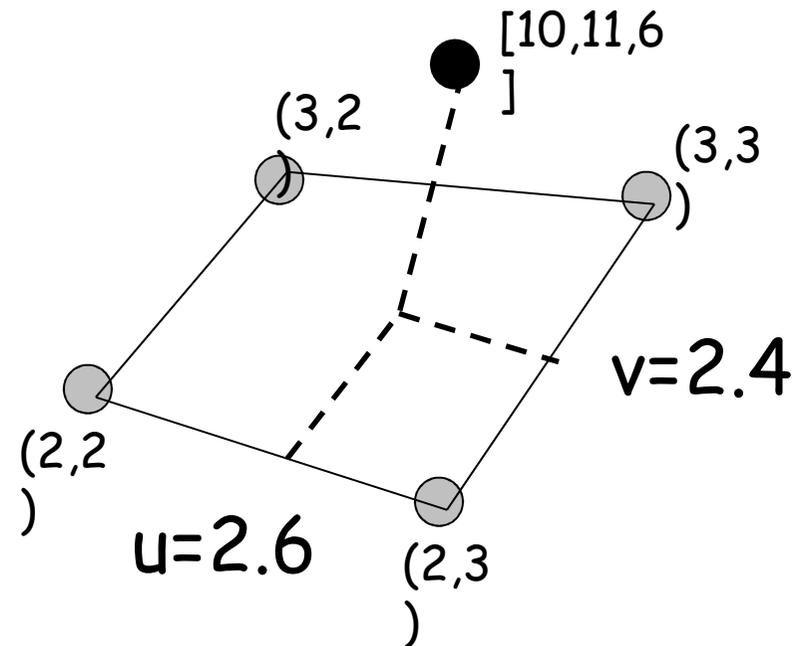
- Movie here
- Movie here



Parametrizzazione Points Cloud



- Ad ogni punto 3D $[x,y,z]$ vengono assegnate le coordinate 2D $[u,v]$ corrispondenti nello spazio 2D della SOM tramite una proiezione (parametrizzazione)

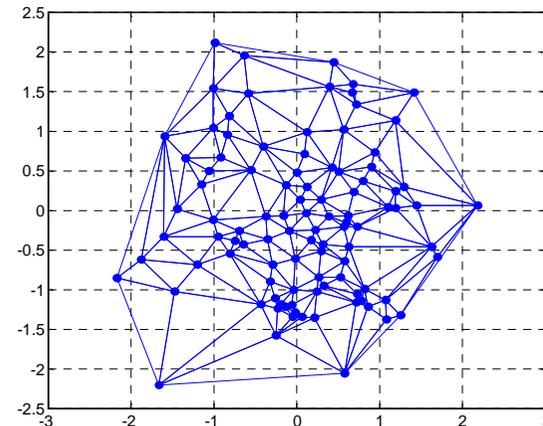
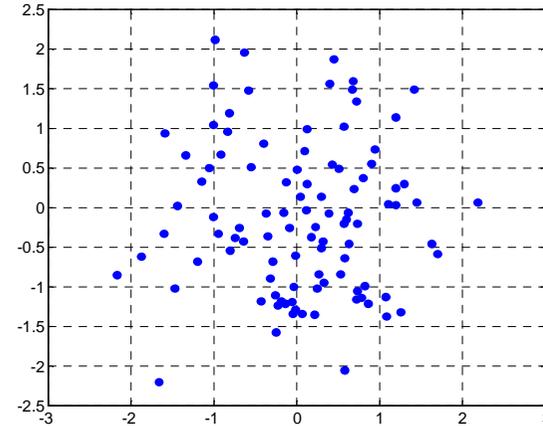




Triangolazione punti in $[u, v]$ (Delaunay)



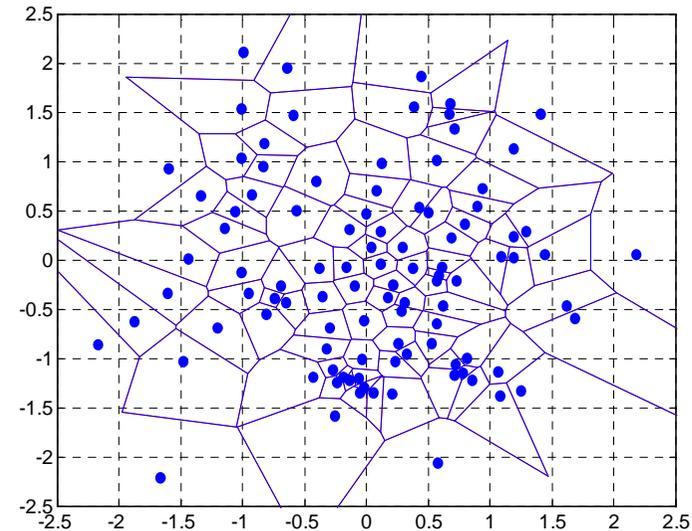
- Dato un set di punti nello spazio 2D, è possibile trovare un set di triangoli tale per cui (triangolazione di Delaunay):
 - ◆ ogni punto si trova al vertice di uno o più triangoli
 - ◆ nessun punto si trova all'interno di un triangoli
- Utile in computer graphics.
- In modo più rigoroso:
a Delaunay triangulation for a set P of points in the plane is a triangulation $DT(P)$ such that no point in P is inside the circumcircle of any triangle in $DT(P)$. Delaunay triangulations **maximize the minimum angle of all the angles of the triangles** in the triangulation; they tend to **avoid "sliver" triangles**.





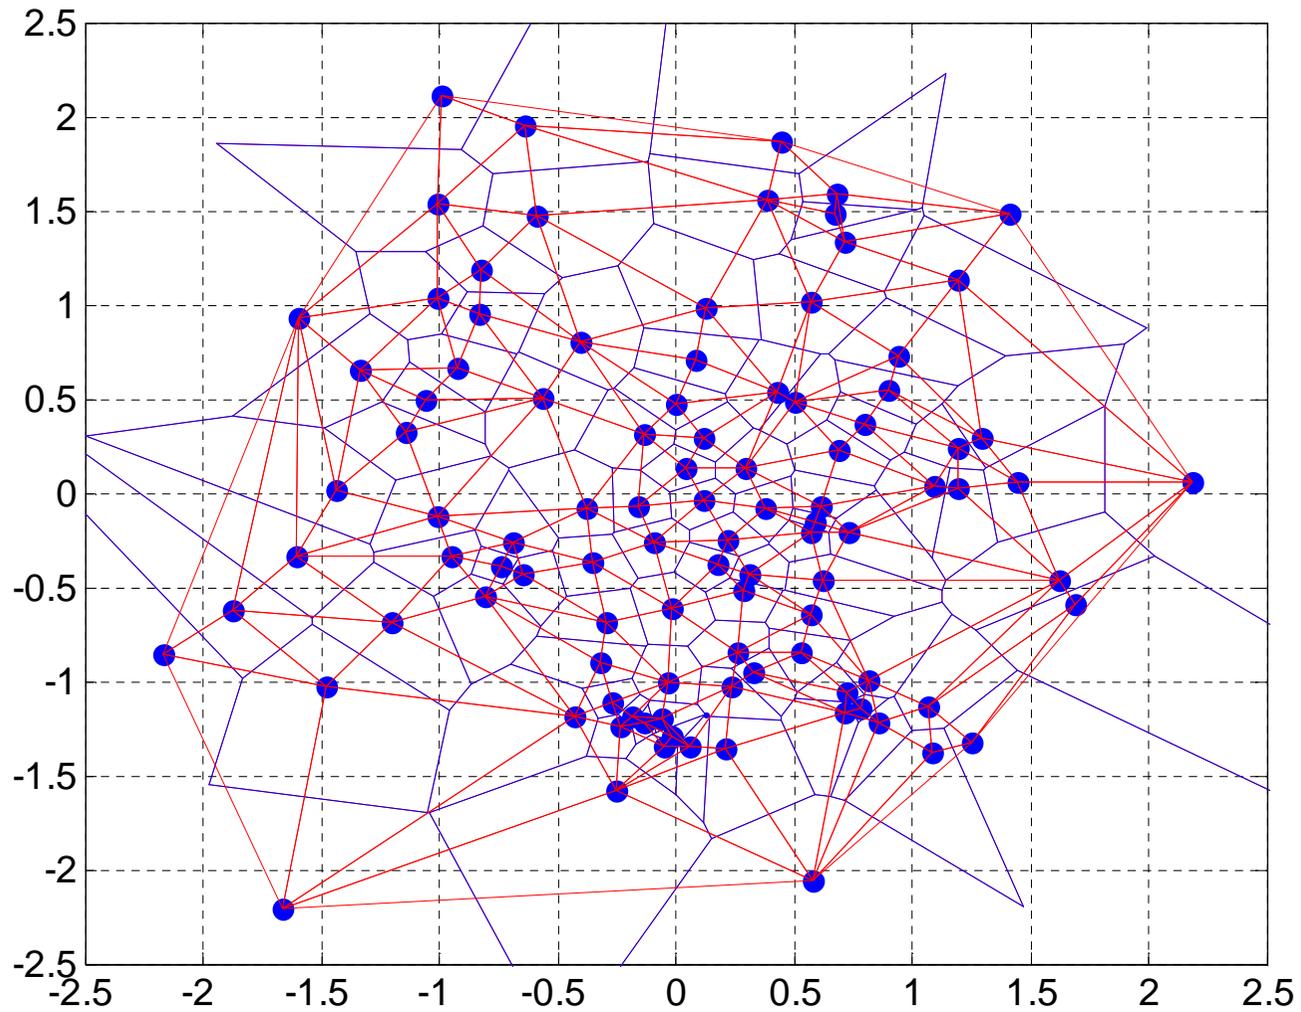
Delaunay e Voronoi

- Duale della triangolazione di Delaunay → Tessellazione di Voronoi.
- Suddivisione “regolare” dello spazio.





Dealunay & Voronoi

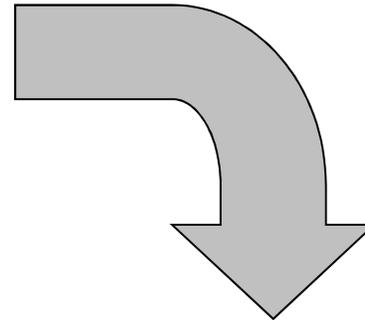
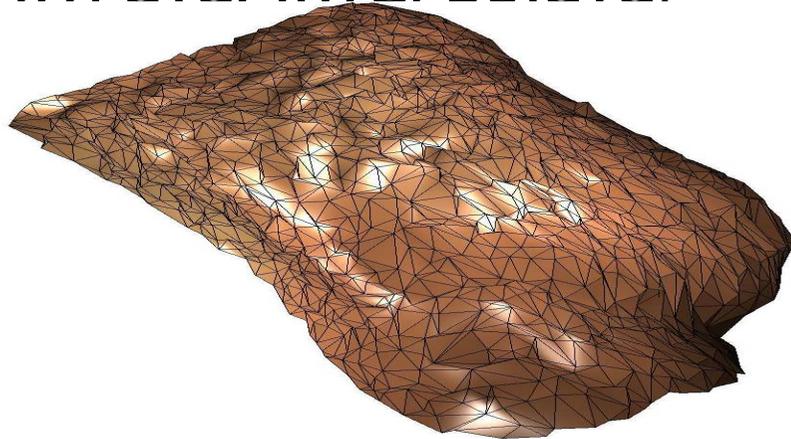




Parametrizzazione Points Cloud

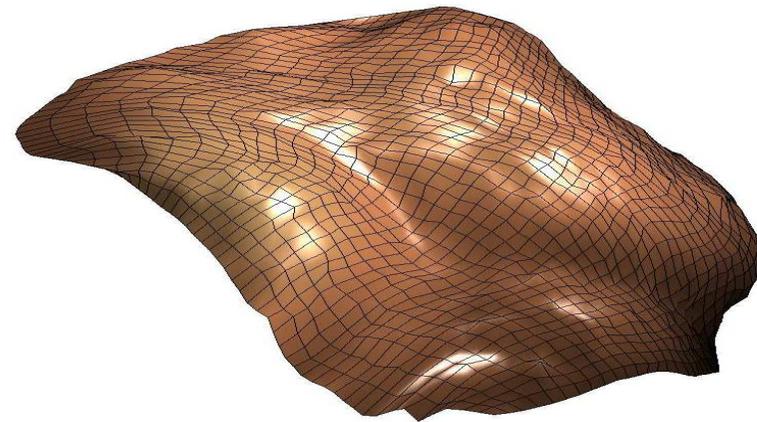


I punti 2D $[u,v]$ possono essere triangolati (ricostruzione a mesh di triangoli). La mesh viene poi filtrata/interpolata.

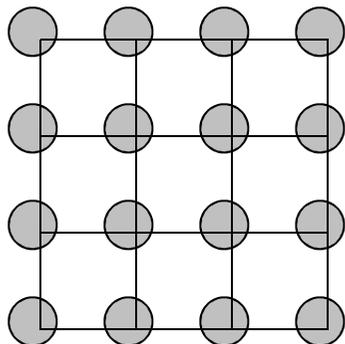


Filtraggio o
interpolazione

e



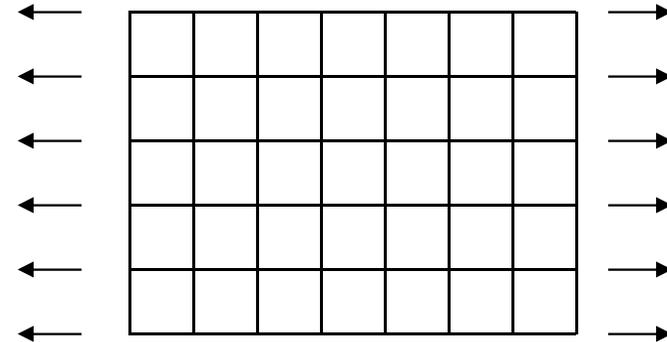
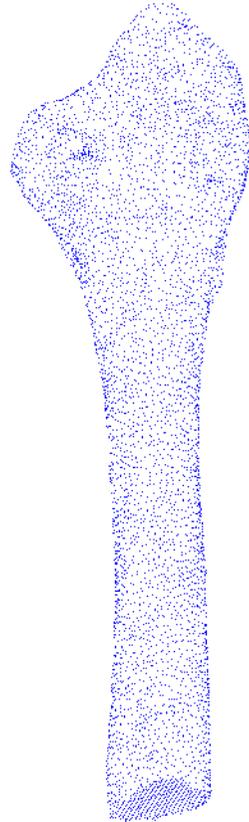
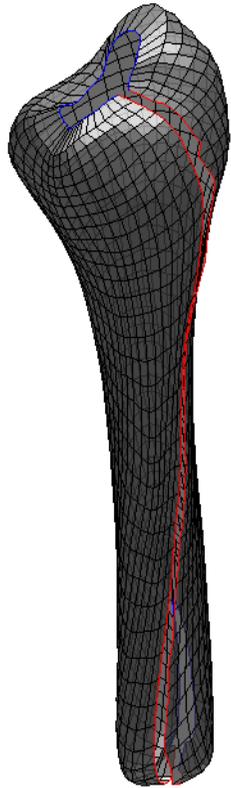
Ricostruzione a mesh di
triangoli



Ricostruzione
Finale



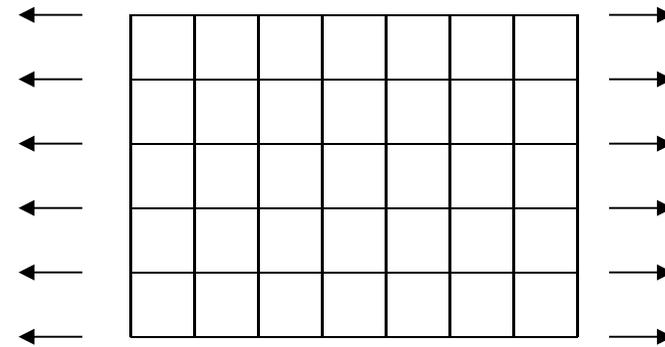
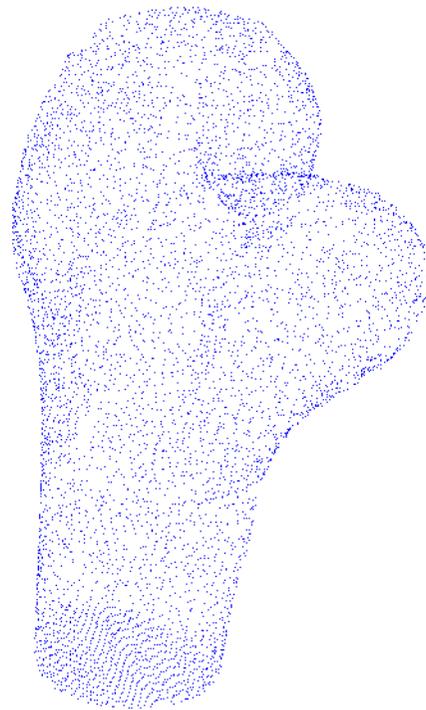
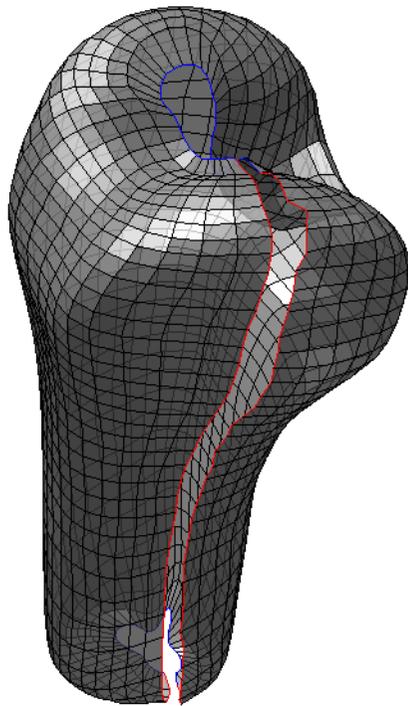
Tibia Left



Topologia: cilindro



Femoral Bone Left



Topologia: cilindro



Varianti SOM



- SELF CREATING MAP
 - Aggiunta di un neurone:
 - Vicino al neurone vincente con f maggiore;
 - Vicino al neurone con curvatura massima;
- SOM SUPERVISIONATE (per la classificazione);
- ...

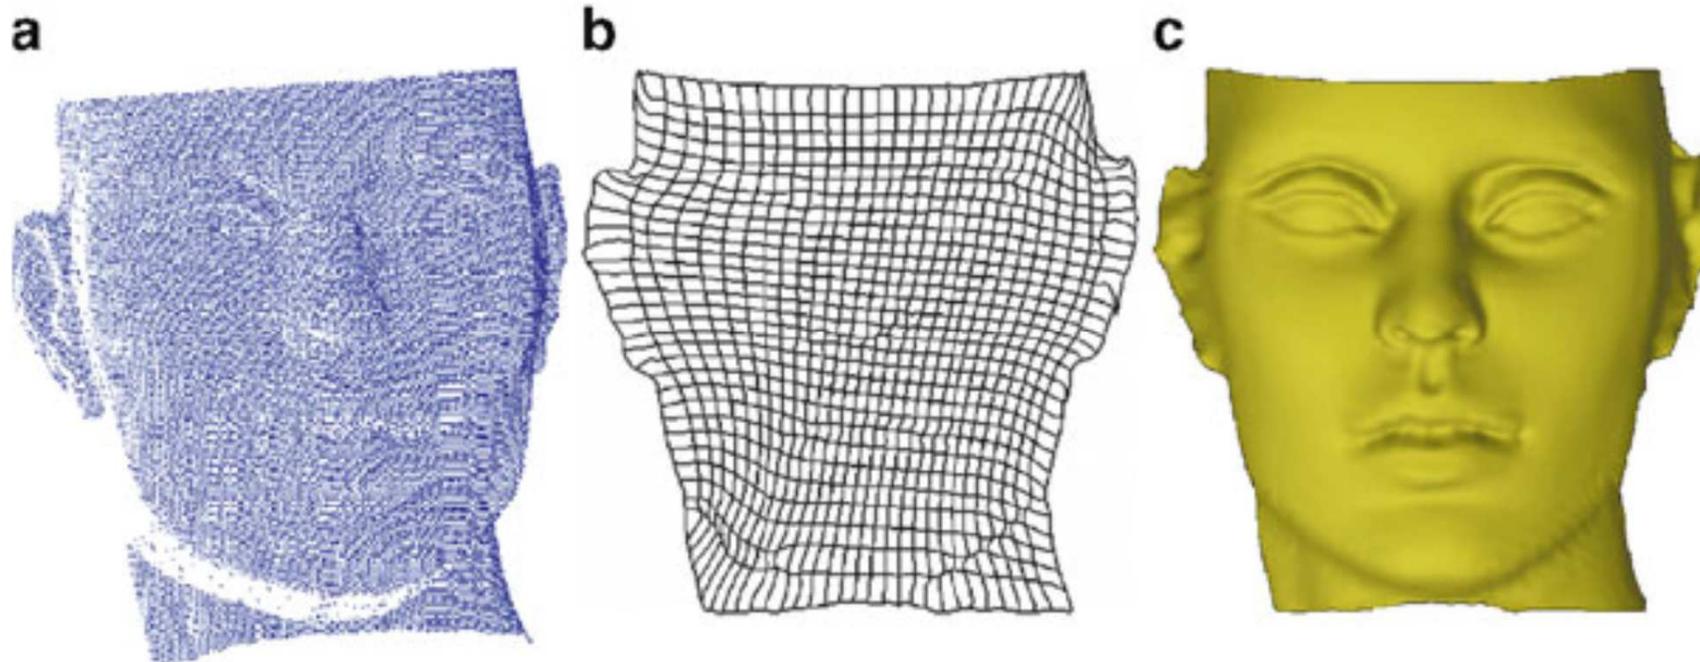


Self Organizing Maps approach

Barhak et al., 2001



- A regular pre-defined mesh (map) is «attracted» and «deformed (warped)» by the points



$$w_j(i+1) = w_j(i) + \eta \cdot h_j(k) \cdot (p - w_j(i))$$

w grid intersection p data point h(k) neighbour region (k is its amplitude)



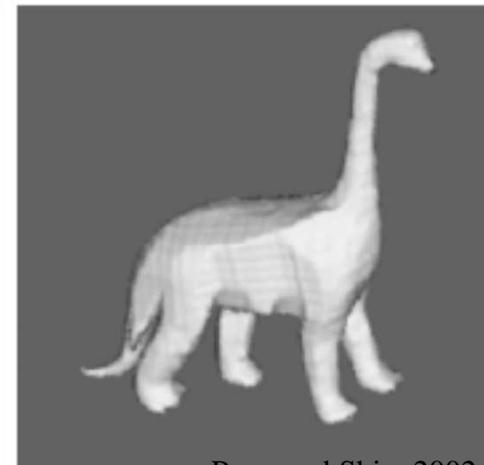
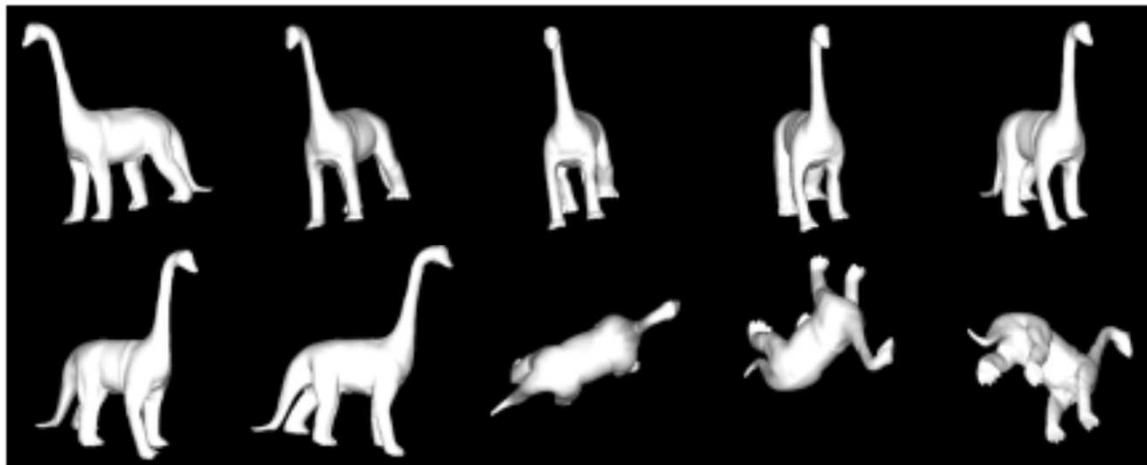
Other methods



Balloons

Level sets

Volume carving



Pyon and Shin, 2002

Kinect fusion = camera motion + 3D reconstruction



Riassunto

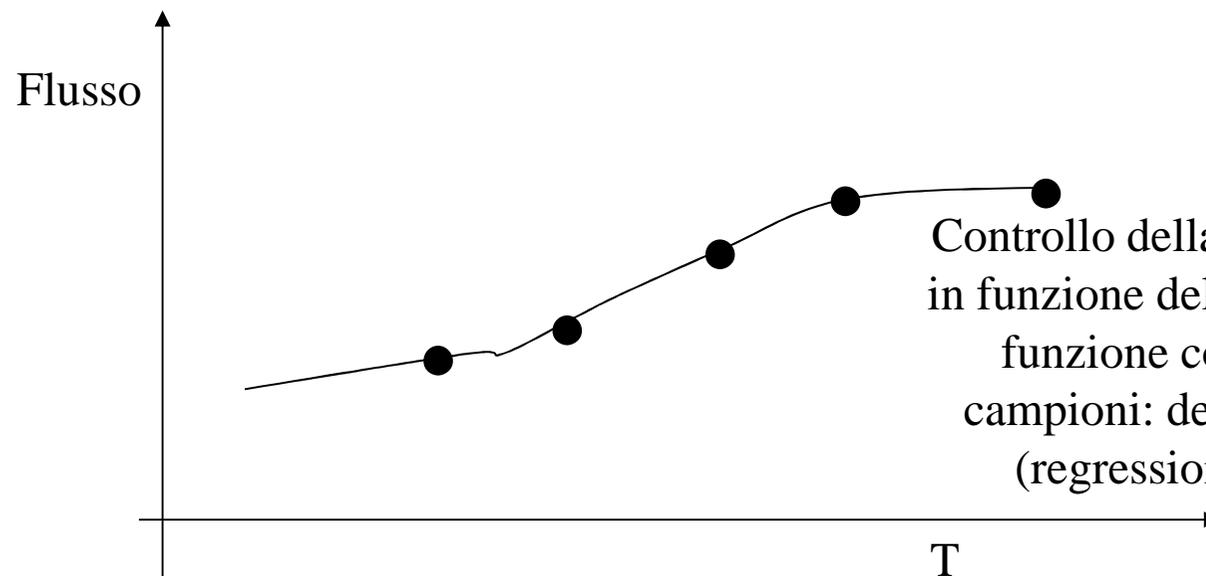
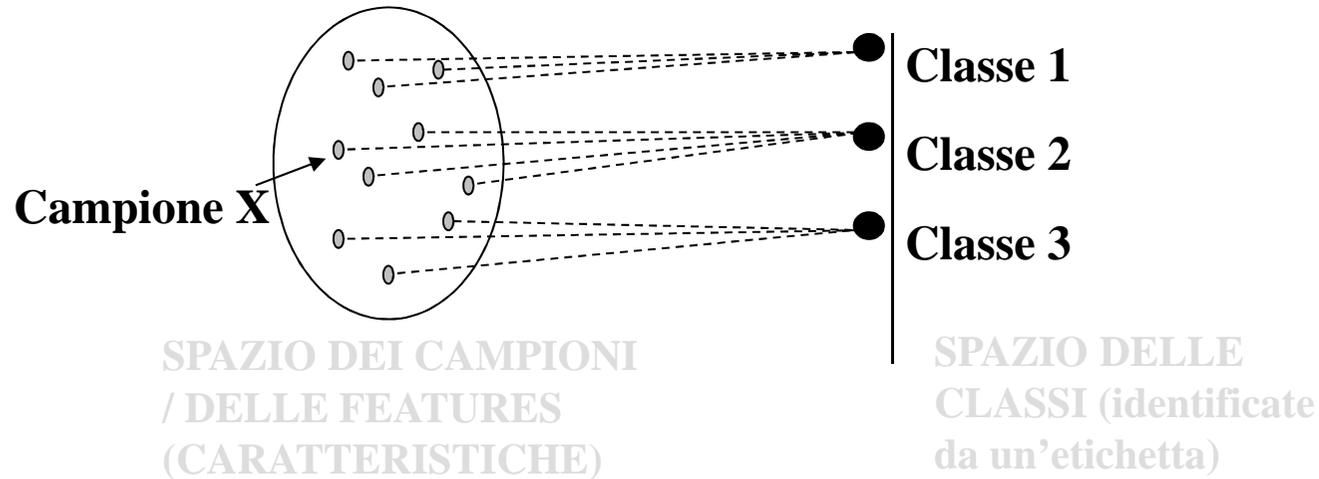


- Soft Clustering
- Mappe di Kohonen
- **I modelli**



Classificazione e regressione

Mappatura dello spazio dei campioni nello spazio delle classi.



Controllo della portata di un condizionatore in funzione della temperatura. “Imparo” una funzione continua a partire da alcuni campioni: devo imparare ad **interpolare** (regressione = **predictive learning**).

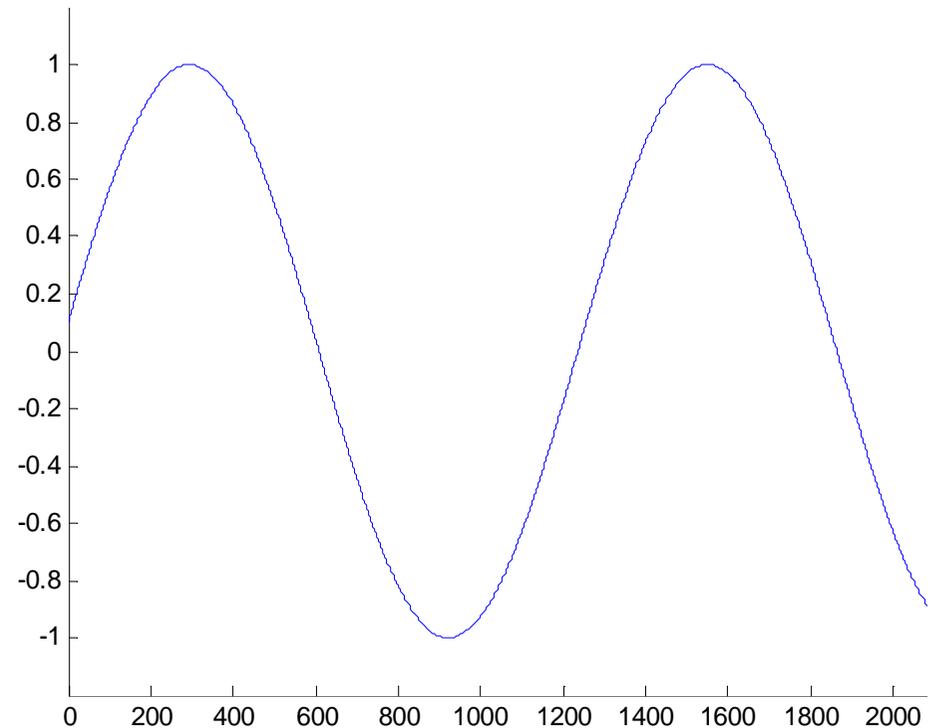
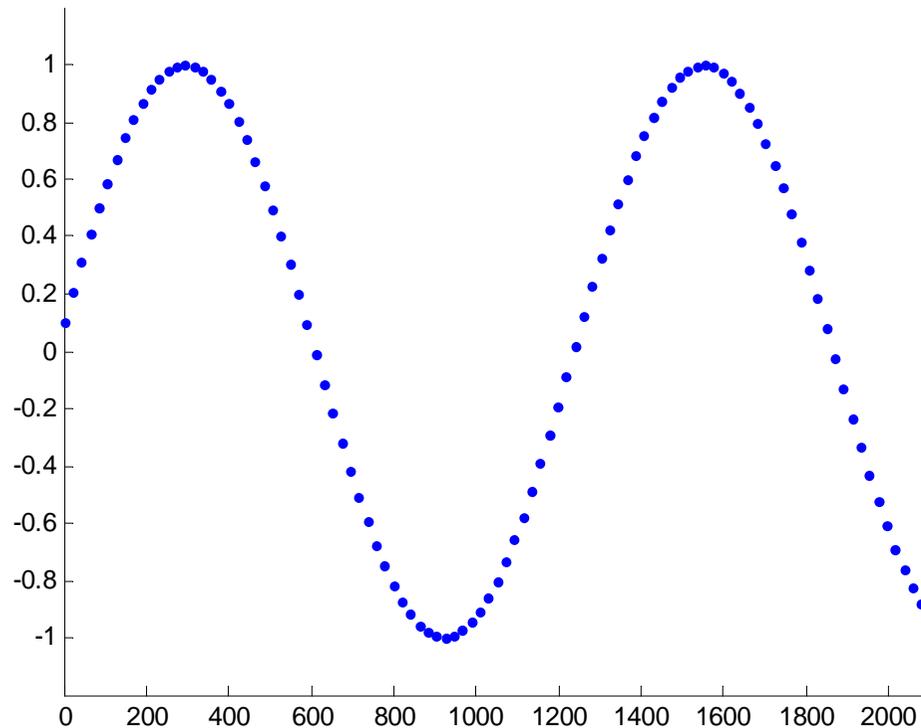


Ruolo dei modelli

- **Identificazione:** stimo i parametri di un modello a partire dai dati: identifico il modello.
- **Utilizzo:** utilizzo il modello per inferire informazioni su nuovi dati (controllo, regressione predittiva, classificazione).



Modello parametrico



I punti vengono fittati perfettamente da una sinusoide: $y = A \sin(\omega x + \phi)$. Devo determinare solo i 3 parametri della sinusoide (non lineare), i cui valori ottimali sono: $\omega = 1/200$, $\phi = 0.1$, $A = 1$. I parametri hanno un significato semantico.



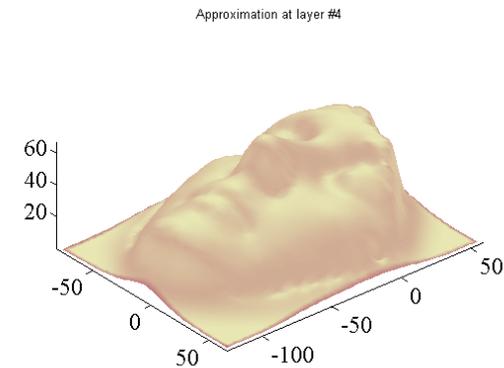
I modelli semi-parametrici

- L'approssimazione è ottenuta mediante funzioni “generiche”, dette di **base**, soluzione molto utilizzata nelle NN e in Machine learning. E' anche associato all' approccio «black-box» in cibernetica. Non si hanno informazioni sulla struttura dell'oggetto che vogliamo rappresentare.
- (Il concetto di Base in matematica è definito mediante certe proprietà di approssimazione che qui non consideriamo, consideriamo solo l'idea intuitiva). Il concetto di base è simile a quello dei “replicating kernels”.
- E' anche l'idea che sta alla base delle Reti Neurali Artificiali

$$z(p(x, y)) = \sum_i w_i G(p, p_i; \sigma)$$

Combinazione
lineare di funzioni
di base

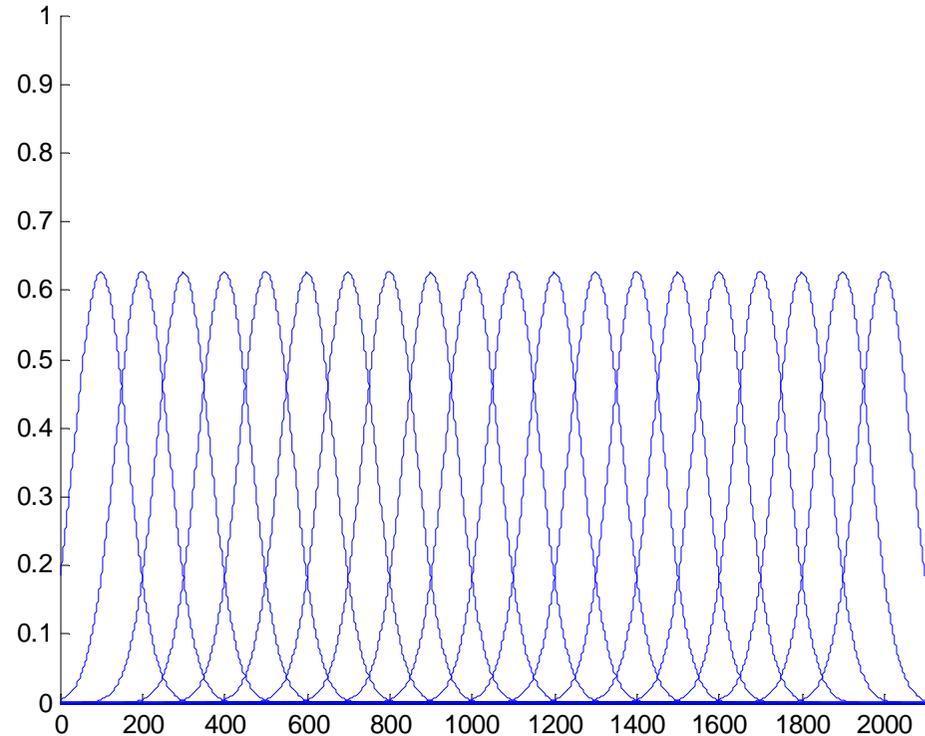
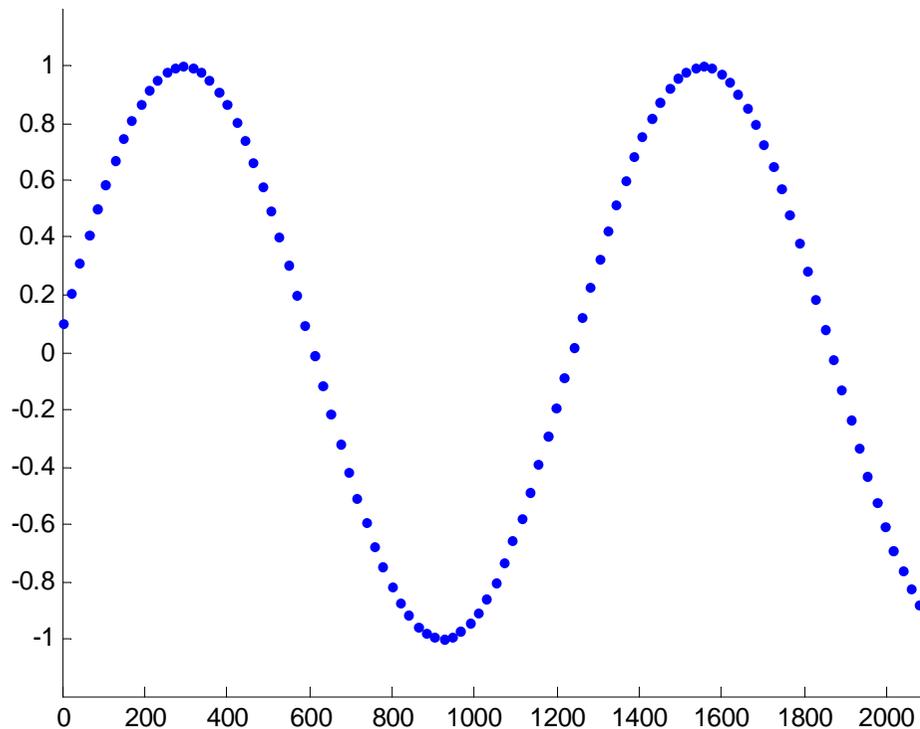
Da calcolare



Funzione di base (fissate)



Approssimazione mediante un modello semi-parametrico (lineare)

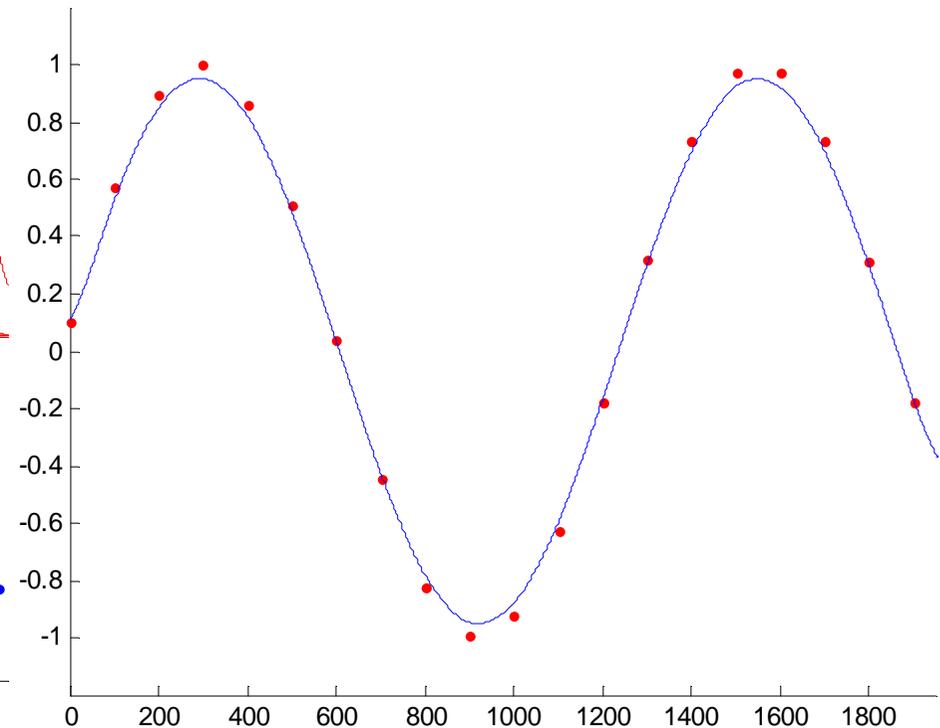
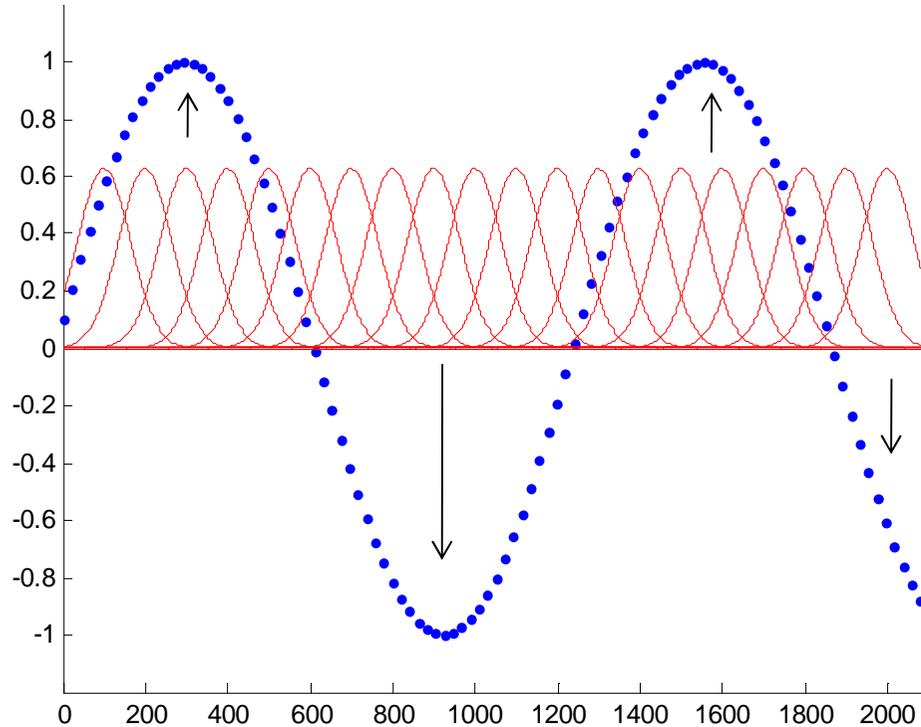


Sinusoide $y = A \sin(\omega x + \phi)$ con $\omega = 1/200$, $\phi = 0.1$.

Vogliamo fittare i punti con l'insieme di Gaussiane riportate sulla dx. In questo caso hanno tutte $\sigma = 90$. Come le utilizzo?



Funzionamento di un modello semi-parametrico (**lineare**)



$$y(x) = \sum_{i=1}^{20} w_i G(x - x_{o_i}; 90^\circ)$$

Devo definire, gli $M \{w_i\}$.
 $3 \ll M \ll N$ – numero punti.

I σ sono tutti uguali ed uguali a 90° , le Gaussiane sono equispaziate.
Le Gaussiane sono note tutte a priori, devono essere definiti i pesi.



Modelli lineari e non lineari

Classificazione alternativa dei modelli. Vengono utilizzate classi molto diversi di algoritmi per stimare i parametri di questi due tipi di modelli.

$$z(p(x, y)) = f(x) = \sum_i w_i x$$

$f(\cdot)$ è funzione lineare nei $\{w_i\}$

$$z(p(x, y)) = \sum_i f_i(p; w)$$

$f(\cdot)$ è funzione non lineare

e.g. $f(\cdot) = e^{w x}$
 $f(\cdot) = x \ln(w x)$
....



Riassunto



- Soft Clustering
- Mappe di Kohonen
- I modelli