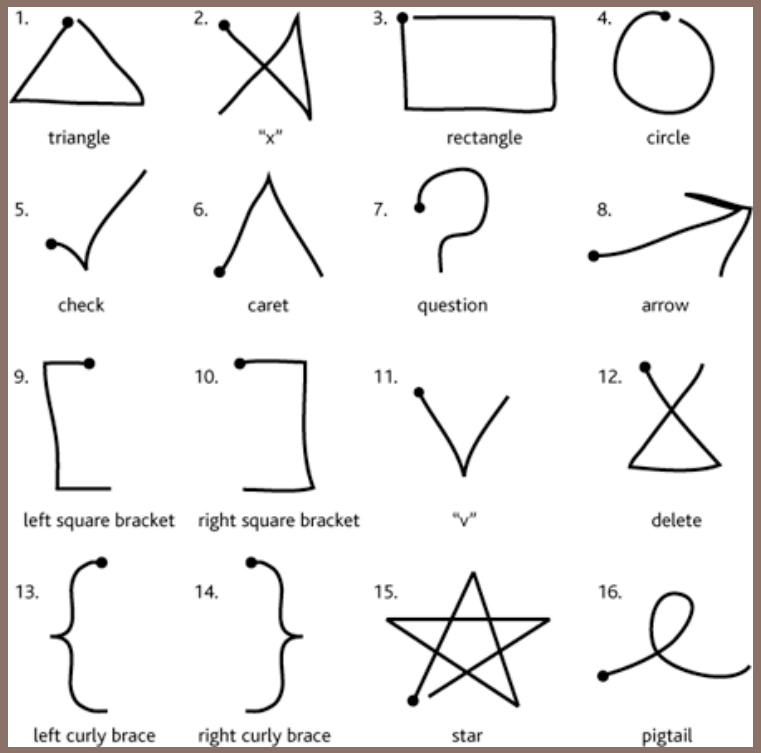

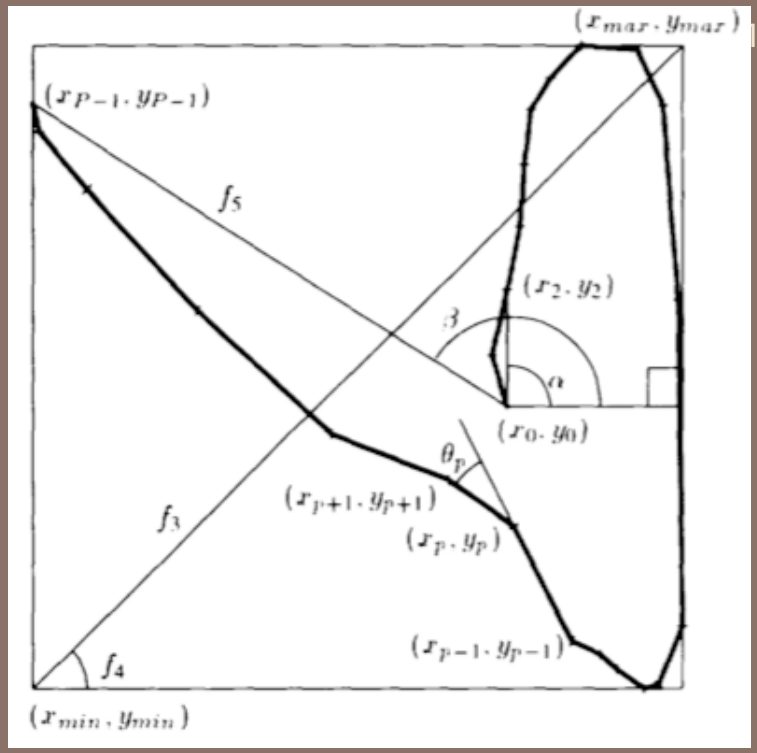

RECONNAISSANCE DE GESTES

Géry Casiez
M2 RVA - IHMA
https://gery.casiez.net

Minority report

Iron man

Plan

- Objectifs
- Technique libstroke
- Technique $1
- Rubine
- DTW

Objectifs

- Reconnaître des gestes réalisés par l'utilisateur pour les associer à des commandes
- On se limite aux gestes un seul trait (unistroke)

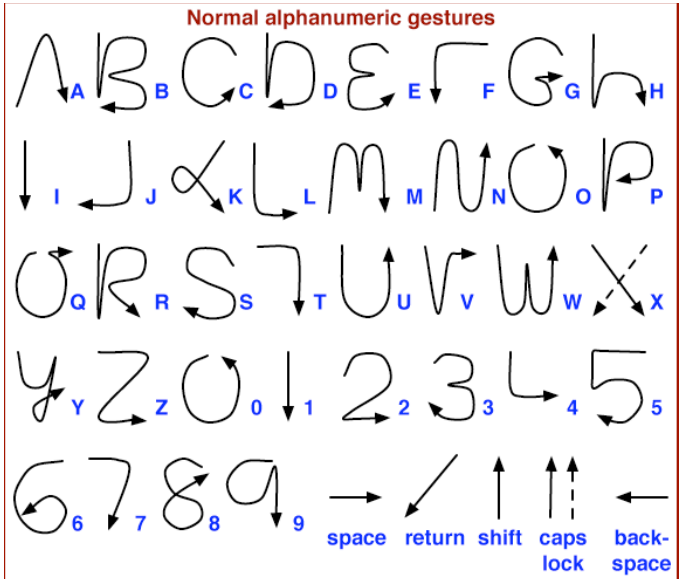

Unistroke - Graffiti (Palm OS)

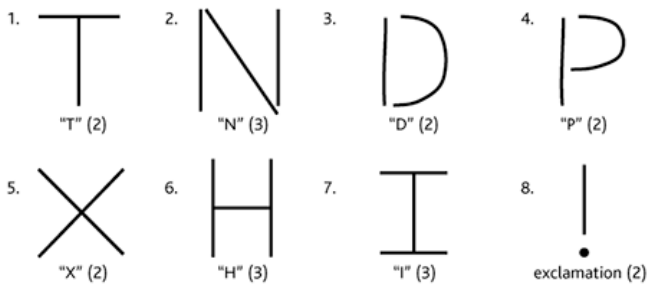

Multistroke

Technique de reconnaissance de gestes élémentaires: libstroke (1997)

- Librairie disponible dans FVWM
  https://directory.fsf.org/wiki/LibStroke
- Les gestes sont décrits par des séquences de chiffres

```
# Strokes
#       num        button context mod. action
Stroke  14789      2      A       N    Exec exec xlock -mode blank&
Stroke  258        2      A       N    Exec exec xterm&
Stroke  563214789  2      A       N    Exec exec exmh&
Stroke  7415963    2      A       N    Exec exec netscape&
Stroke  741236987  2      A       N    Destroy
Stroke  1478963    2      A       N    Popup "Apps"
Stroke  74123      2      A       N    Module "winlist" FvwmWinList
Stroke  74159      2      A       N    Move
Stroke  852        2      A       N    Menu "Apps" Nop
```

1	2	3
4	5	6
7	8	9

Libstroke: algorithme

- 1) détermination de la boite englobante (bounding box) à partir de min_x, max_x,min_y, max_y
- 2) division de la boite en 9 cellules
- 3) étiquetage des points
- 4) factorisation
- 5) comparaison aux motifs enregistrés

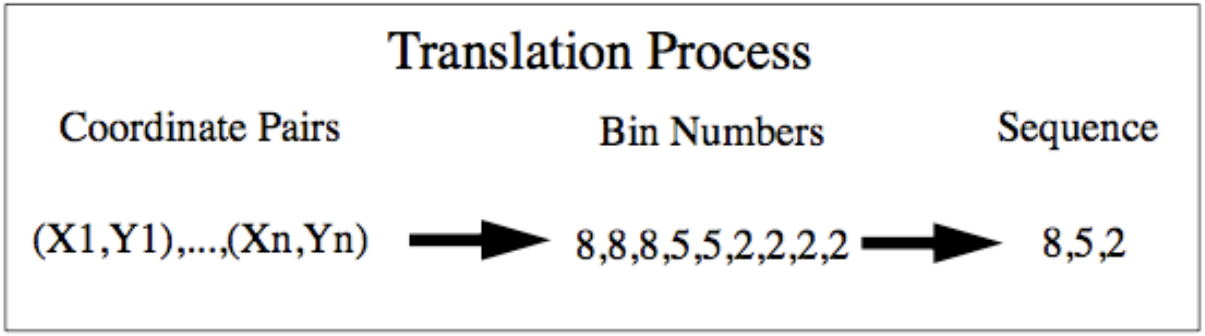

- Extension Firefox: Mouse Gestures Redox

Techniques de reconnaissance

- Classifieurs statistiques (Rubine, DTW)
- Modèles de Markov cachés
- Réseaux de neurones
- Méthodes ad-hoc (libstroke, $1)

Techniques de reconnaissance

- $1 recognizer
- Méthode simple à implémenter et donnant des taux de reconnaissance comparables à Rubine et DTW
- 1 seul exemple suffit
- Technique publiée dans l'article de recherche "Gestures without Librairies, Toolkits or Training: A $1 Recognizer for User Interface Prototypes" à la conférence User Interface Sofware and Technology (UIST) en 2007 (écrit par Wobbrock, Wilson et Li)

$1 recognizer

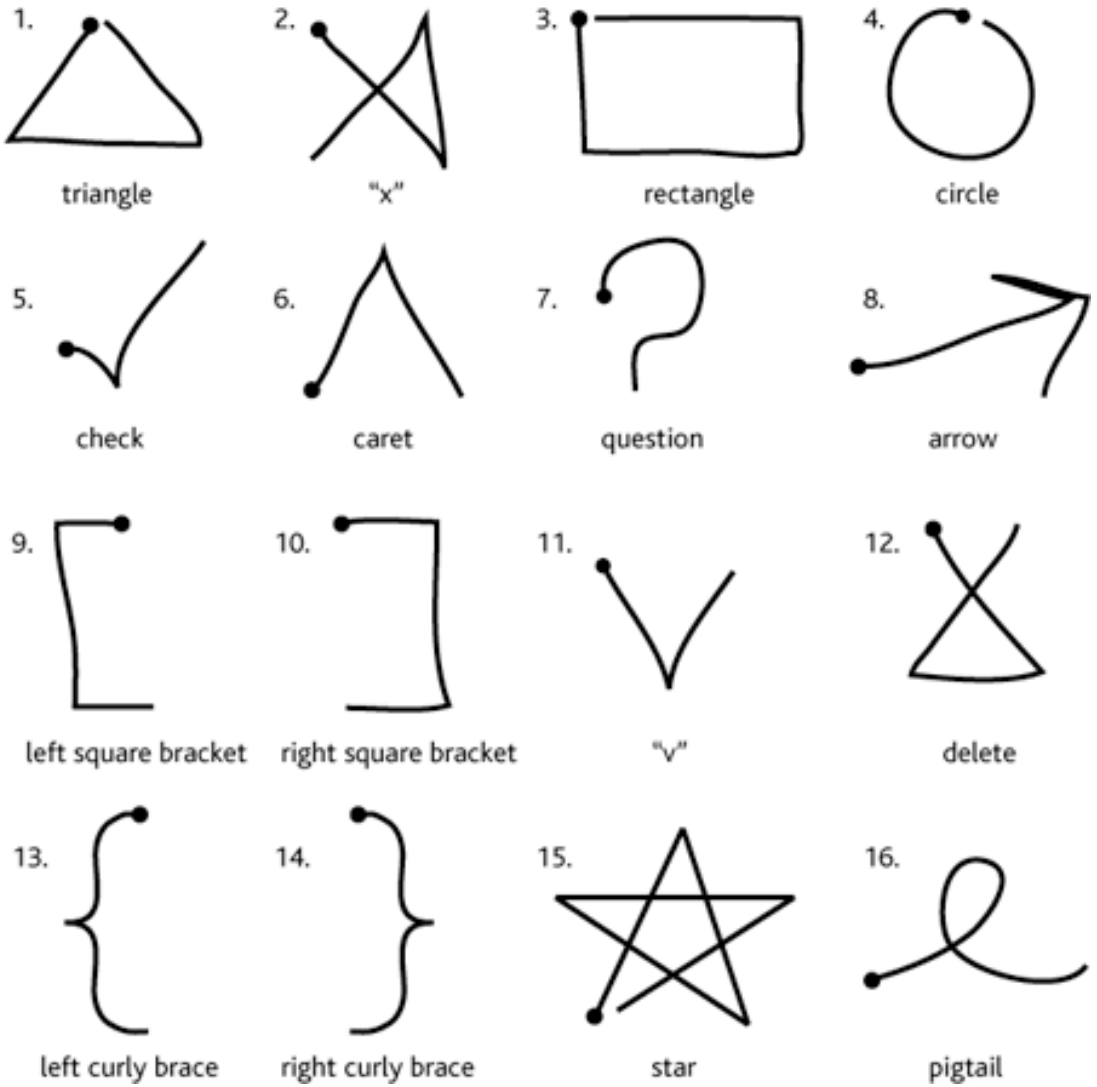

Algorithme

- 1) L'utilisateur réalise un geste
  - Le geste est représenté par une liste ordonnée de points
- 2) Ce geste est comparé à un ensemble de gestes de référence (templates) en utilisant une mesure de distance euclidienne
- 3) Le geste reconnu est celui pour lequel cette distance est minimale

Problèmes posés

- Le nombre de points pour définir un geste va dépendre de la vitesse d'exécution, de la fréquence d'échantillonnage du périphérique…

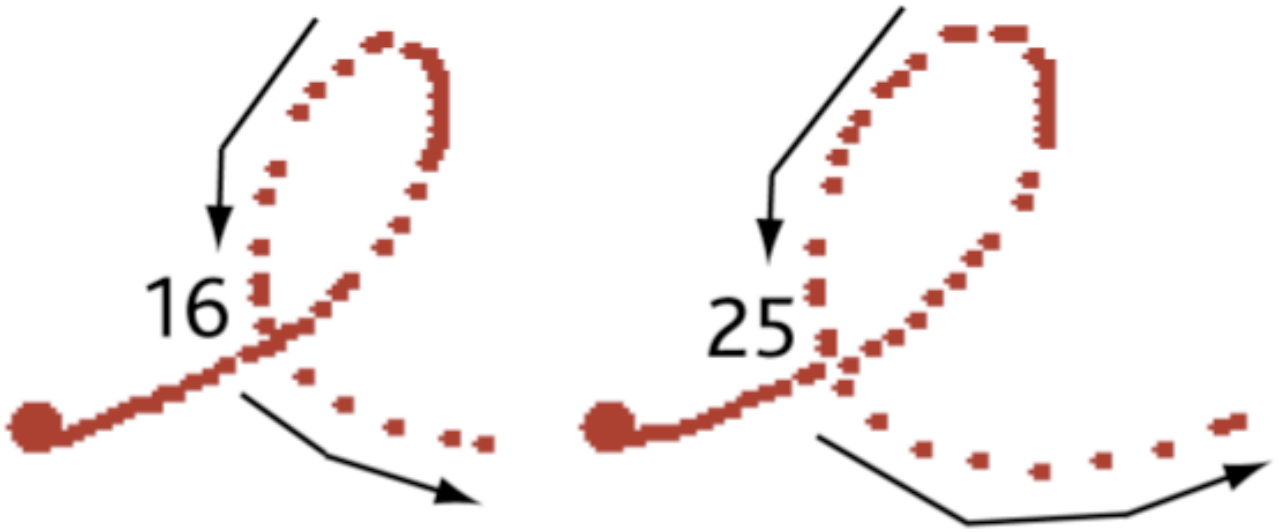

Problèmes posés

- Un geste peut être réalisé à différentes positions sur l'interface,
- Suivant différentes orientations

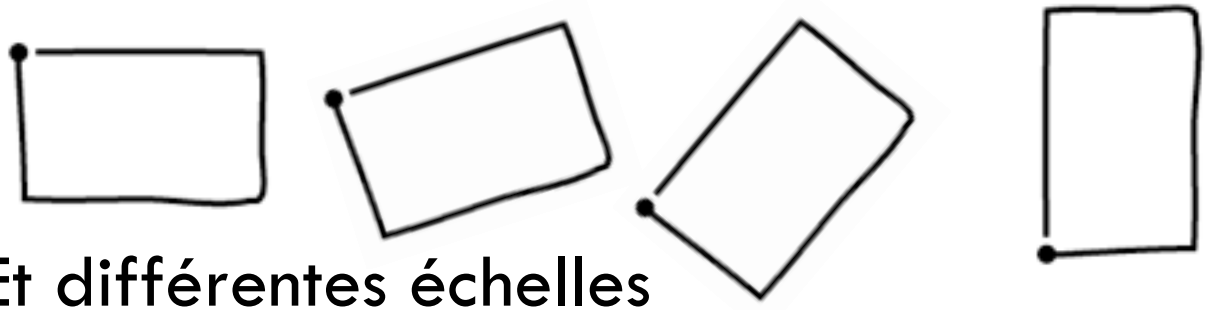

- Et différentes échelles

4 étapes

- 1) Ré-échantillonnage du geste pour être invariant à la fréquence d'acquisition et la vitesse d'exécution du geste
- 2) Ré-orientation du geste pour être invariant à l'orientation suivant laquelle il est exécuté
- 3) Mise à l'échelle et translation pour être invariant à l'échelle de réalisation du geste et la position à laquelle il est exécuté
- 4) Reconnaissance du geste

1ère étape: Ré-échantillonnage

- Le geste est défini par M points ordonnés
- On veut N points ordonnés équidistants les uns des autres
- N = 64

2e étape: Rotation « indicative »

- 1) Calcul du centre du geste (centroïde)
- 2) Calcul de l'angle entre le centroïde, le premier point et l'horizontale
- 3) Rotation des points en utilisant cet angle

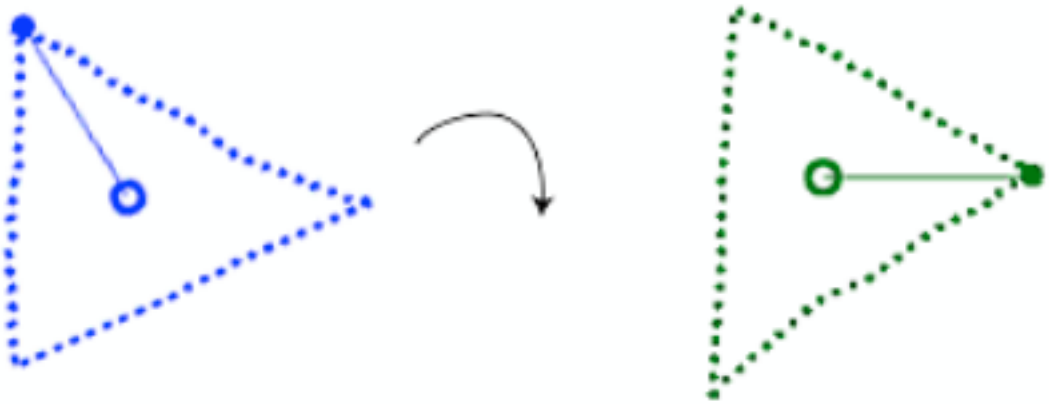

3e étape: mise à l'échelle et translation

- Mise à l'échelle non uniforme: on ramène le geste à un carré de référence
- 1) détermination de la boîte englobante du geste (bounding box)
  - Détermination de min_x, max_x, min_y, max_y
- 2) Mise à l'échelle
- 3) Translation à l'origine

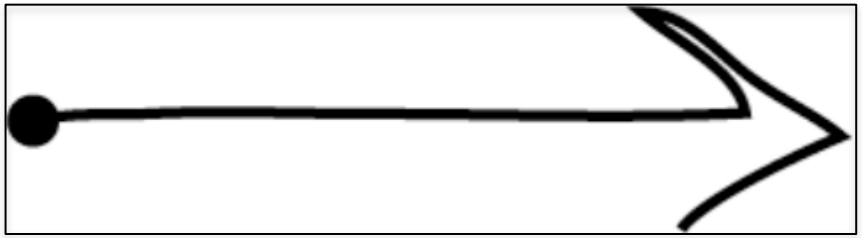

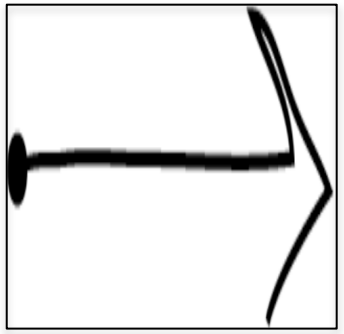

4e étape: reconnaissance

- Un geste candidat C est comparé à chacun des gestes enregistrés (templates) T_i pour calculer la distance moyenne d_i entre les points correspondants

$$d_i = \frac{\sum_{k=1}^{N} \sqrt{\left(C[k]_x - T_i[k]_x\right)^2 + \left(C[k]_y - T_i[k]_y\right)^2}}{N}$$

- Le template avec la distance moyenne la plus faible est le résultat de la reconnaissance
- La distance est tranformée en score entre 0 et 1

$$score = 1 - \frac{d_i^*}{\frac{1}{2}\sqrt{size^2 + size^2}}$$

Limitations

- Pas possible de distinguer un carré d'un rectangle, une ellipse d'un cercle, une flèche vers le bas d'une flèche vers le haut
- Pas possible de reconnaître des gestes « 1D »

Classifieur statistique

- Rubine
- Reconnaissance de gestes ne comportant qu'un seul tracé (unistroke)
- Traitement statistique de caractéristiques

Dean Rubine. 1991. Specifying gestures by example. In *Proceedings of the 18th annual conference on Computer graphics and interactive techniques* (SIGGRAPH '91). ACM, New York, NY, USA, 329-337. DOI=10.1145/122718.122753 http://doi.acm.org/10.1145/122718.122753

Rubine

- Liste de points en entrée
  - Traitement des points pour éliminer les points trop proches: tout point dont la distance est inférieure à 3 pixels du point précédent est supprimé
  - Calcul d'un vecteur de caractéristiques statistiques
  - Comparaison aux différents gestes de référence. Le geste avec le score le plus grand est renvoyé.
  - Détection des gestes ambigus

Caractéristiques

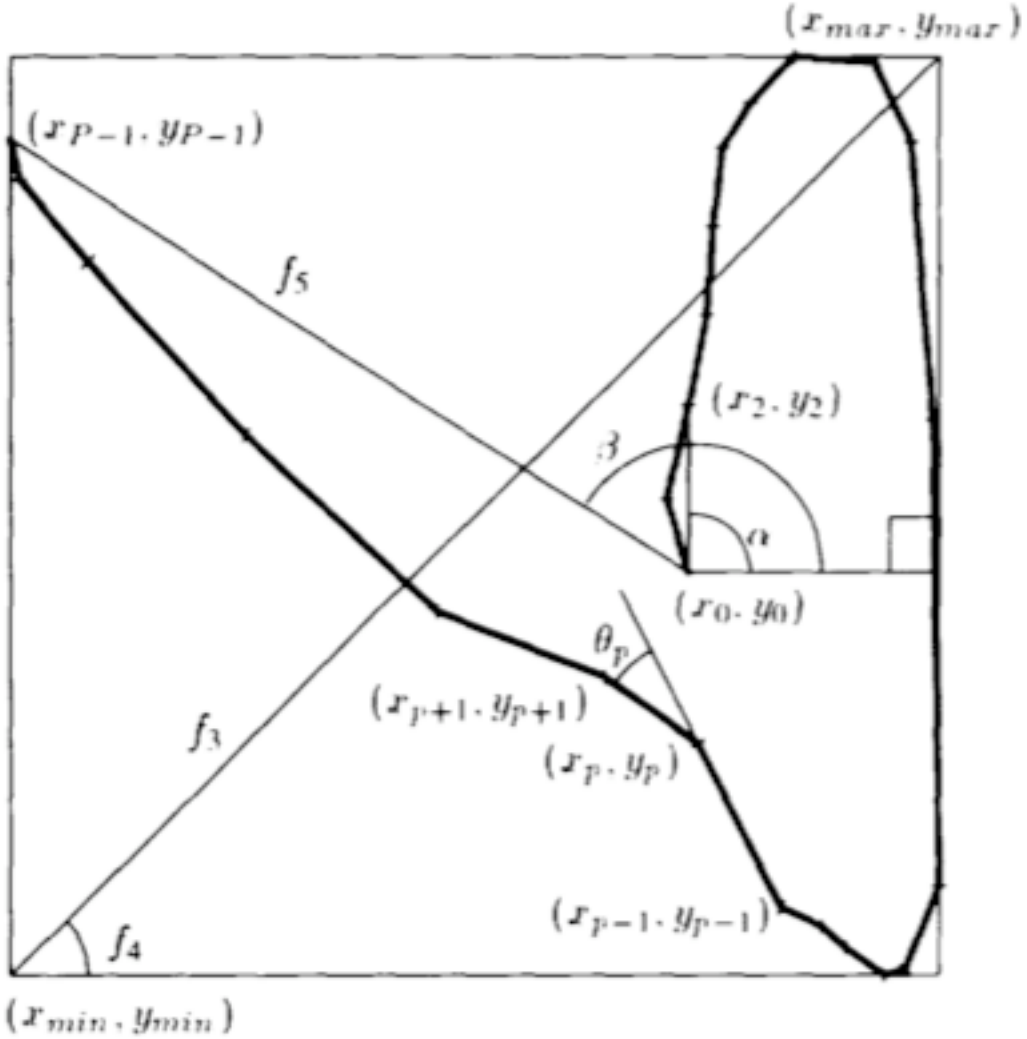

Initialisation

- Calcul des statistiques moyennes pour chaque caratéristique de chaque geste
- Calcul de la matrice de covariance moyenne de tous les gestes
- Objectif: trouver les coefficients pondérateurs des caractéristiques statistiques qui permettent de maximiser le score des gestes de chaque classe

Reconnaissance

- Calcul des caractéristiques du geste candidat
- Calcul d'une probabilité de correspondance pour chaque geste de référence
- Le geste avec la probabilité la plus importante est choisi

Dynamic Time Warping

- DTW
- Déformation temporelle dynamique
- Déterminer pour chaque élément d'une séquence, le meilleur élément correspondant dans l'autre séquence relativement à un certain voisinage et à une certaine métrique
- Complexité polynomiale

Applications

- Vidéo, audio, graphique…
- Toutes données qui peuvent être transformées en représentation linéaire en fonction du temps (séries temporelles)
- Echantillons ordonnés par une étiquette de temps
- Reconnaissance vocale
- Reconnaissance de gestes off-line et on-line
- alignement de protéines…

Principe de base

- Séquence de référence R = [r_1, r_2, ..., r_n]
- Séquence de test T = [t_1, t_2, ..., t_m]
- Si m=n alors on peut calculer la distance entre les deux signaux de la façon suivante (pas forcément idéal):

$$D = \sum_{i=1}^{n} distance(r_i, t_i)$$

- Possibilité de calculer la distance euclidienne ou d'utiliser une autre métrique (fonction qui donne un réel)
- Plus possible d'utiliser cette méthode dès que n ≠ m
- Attention: les échantillons des séquences doivent être équidistants en temps

Principe de base

- DTW réalise d'abord un alignement non linéaire en recherchant parmi tous les alignements possibles, celui qui minimise une fonction de coût cumulé
- «Time Warping»: Dilation ou compression des séquences pour obtenir le meilleur alignement possible

Principe de base

- Détermination du chemin W = [w_1, w_2, ..., w_k] de longueur minimale $\sum_{i=1}^{k} distance(w_i)$

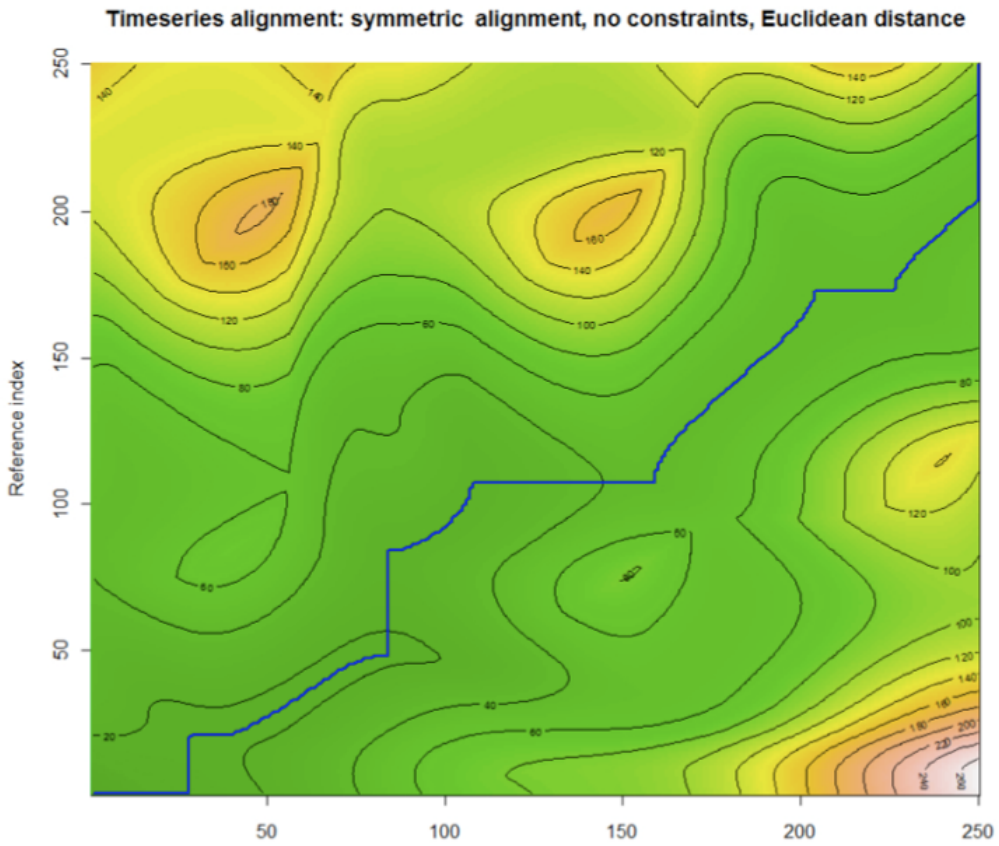

Principe de base

- Conditions aux frontières
  - $w_1 = (r_1, t_1)$
  - $w_k = (r_n, t_m)$
- Contraintes locales
  - Monotonicité pour respecter le séquencement des points
  - Eviter les sauts dans le temps
  - Pour tout couple (r_i, t_j), le choix des prédécesseurs est limité à
    - (r_{i-1},t_j), (r_i,t_{j-1}), (r_{i-1},t_{j-1})
- Exhaustivité
  - Chaque élément de R doit être mis en relation avec au moins un élément de T et vice-versa
  - $\max(m, n) \leq k \leq m + n - 1$

Principe de base

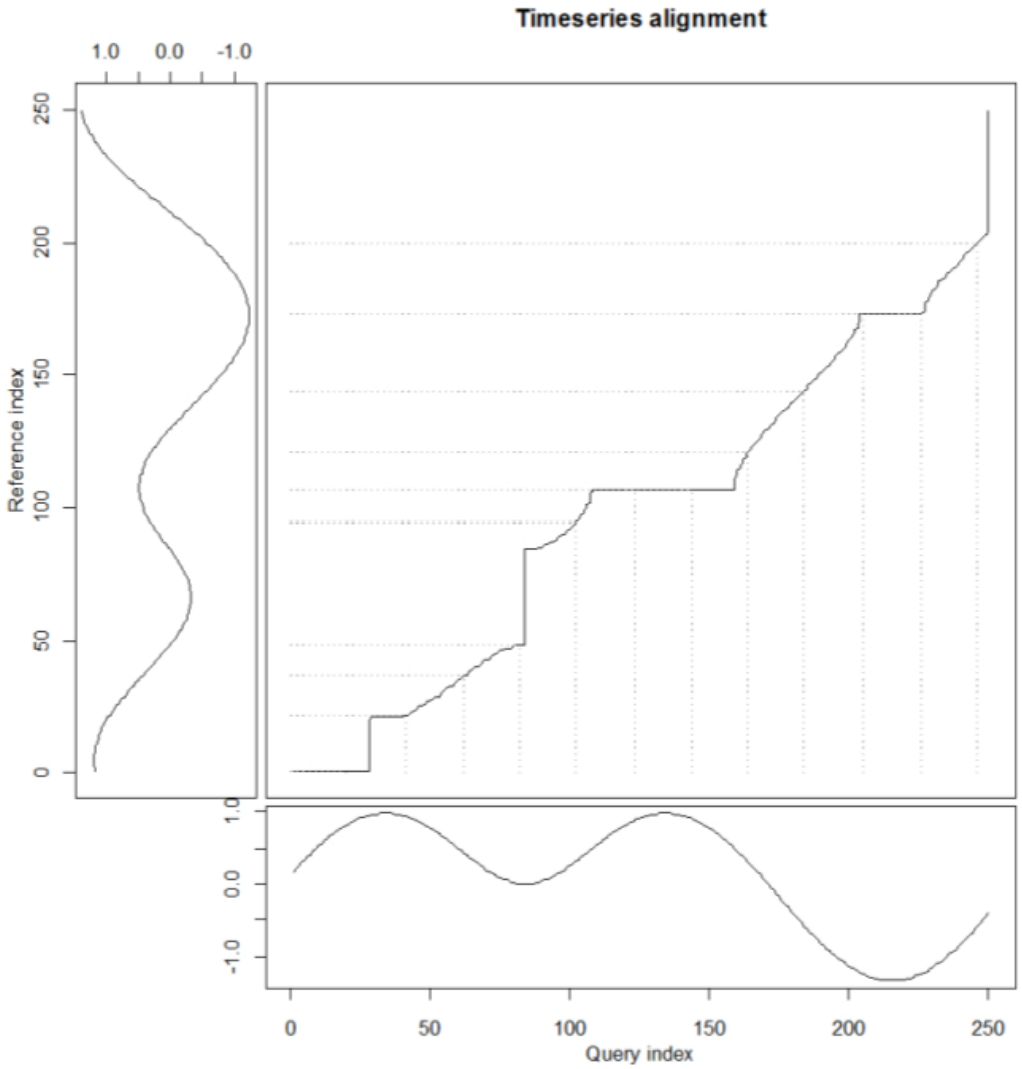

Principe de base

- Programmation dynamique
- Fonction d'optimisation:
  - Soit D(i,j) la longueur du chemin entre (r_1, t_1) et (r_i, t_j)
- Récursion:
  - $D(i,j) = dist(r_i,t_j) + min(D(i-1,j), D(i-1,j-1), D(i, j-1))$
  - condition initiale: $D(1,1) = dist(r_0,t_0)$
- Distance minimale entre les deux séquences
  - D(n,m)

Mise en application

- Construction d'une matrice D de dimensions n x m dans laquelle chaque élément (i,j) contient D(i,j)
- Remplissage de D(1,1) avec la condition initiale
- Utilisation de la formule récursive pour remplir la matrice ligne par ligne ou colonne par colonne
- Cas particuliers première ligne et première colonne
- Distance minimale donnée par l'élément D(n,m)
- La distance minimale peut être normalisée par la longueur du chemin

Algorithme

$n \leftarrow |X|$

$m \leftarrow |Y|$

$dtw[] \leftarrow new\ [n \times m]$

$dtw(0,0) \leftarrow 0$

for $i = 1;\ i < n;\ i++$ **do**

  $dtw(i,0) \leftarrow dtw(i-1,0) + c(i,0)$

end for

for $j = 1;\ j < m;\ j++$ **do**

  $dtw(0,j) \leftarrow dtw(0,j-1) + c(0,j)$

end for

for $i = 1; i \leq n; i++$ **do**

  for $j = 1; j \leq m; j++$ **do**

    $dtw(i,j) \leftarrow c(i,j) + \min\{dtw(i-1,j);\ dtw(i,j-1);\ dtw(i-1,j-1)\}$

  end for

end for

return dtw

Chemin de déformation

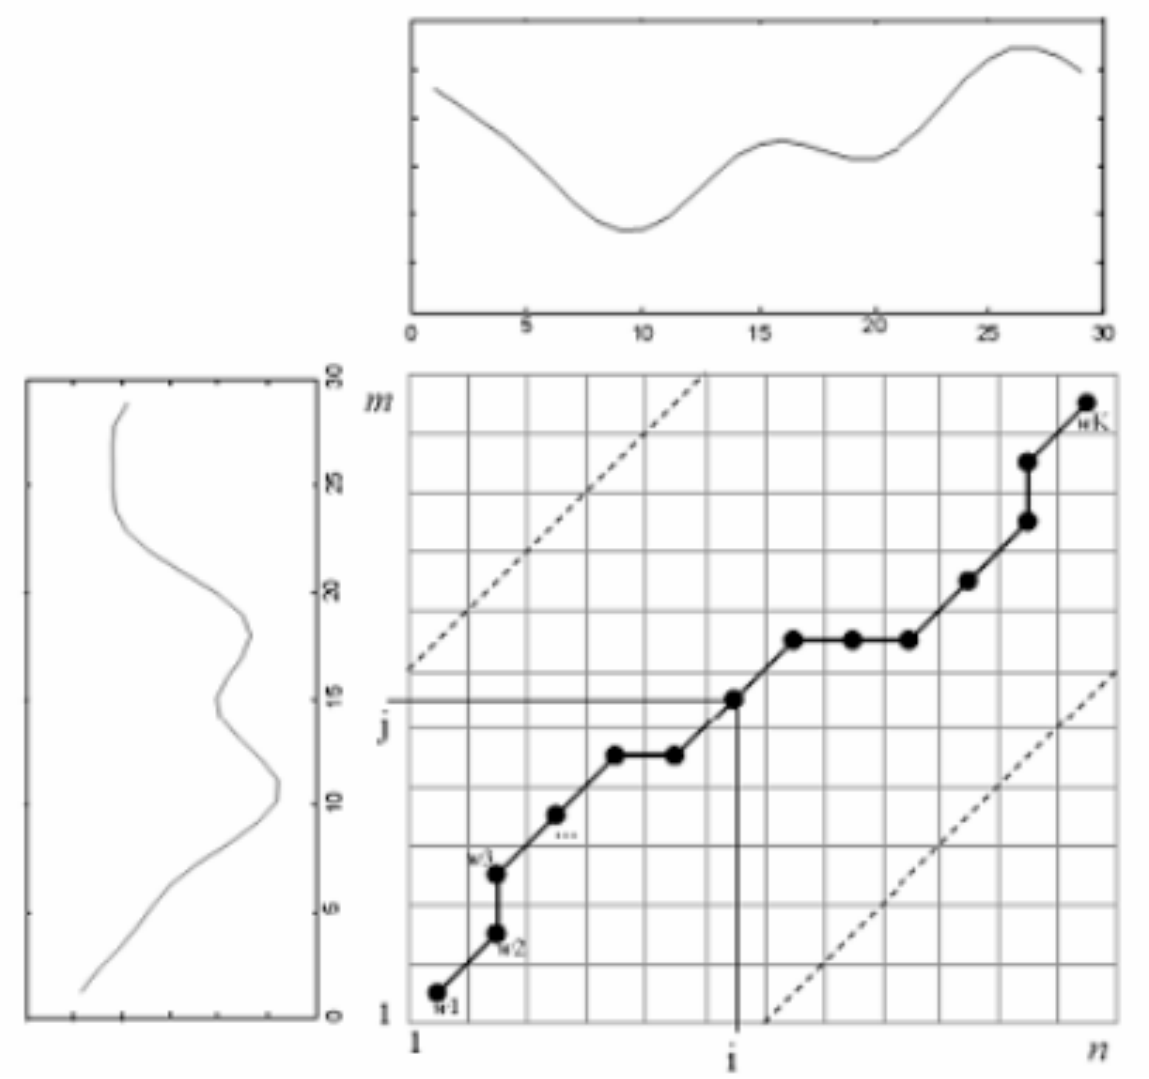

Chemin de déformation

- A chaque calcul de D(i,j), sauvegarde du prédécesseur qui minimise la distance
- Parcours des prédécesseurs en partant de D(n,m)

Complexité

- Complexité: O(m*n)
- Optimisation en limitant la région de recherche

Optimisation

- La zone supérieure gauche et la zone inférieure droite ne sont pas calculées
- Les distances locales associées sont mises à une valeur très élevée afin que le chemin n'y passe pas

Optimisation

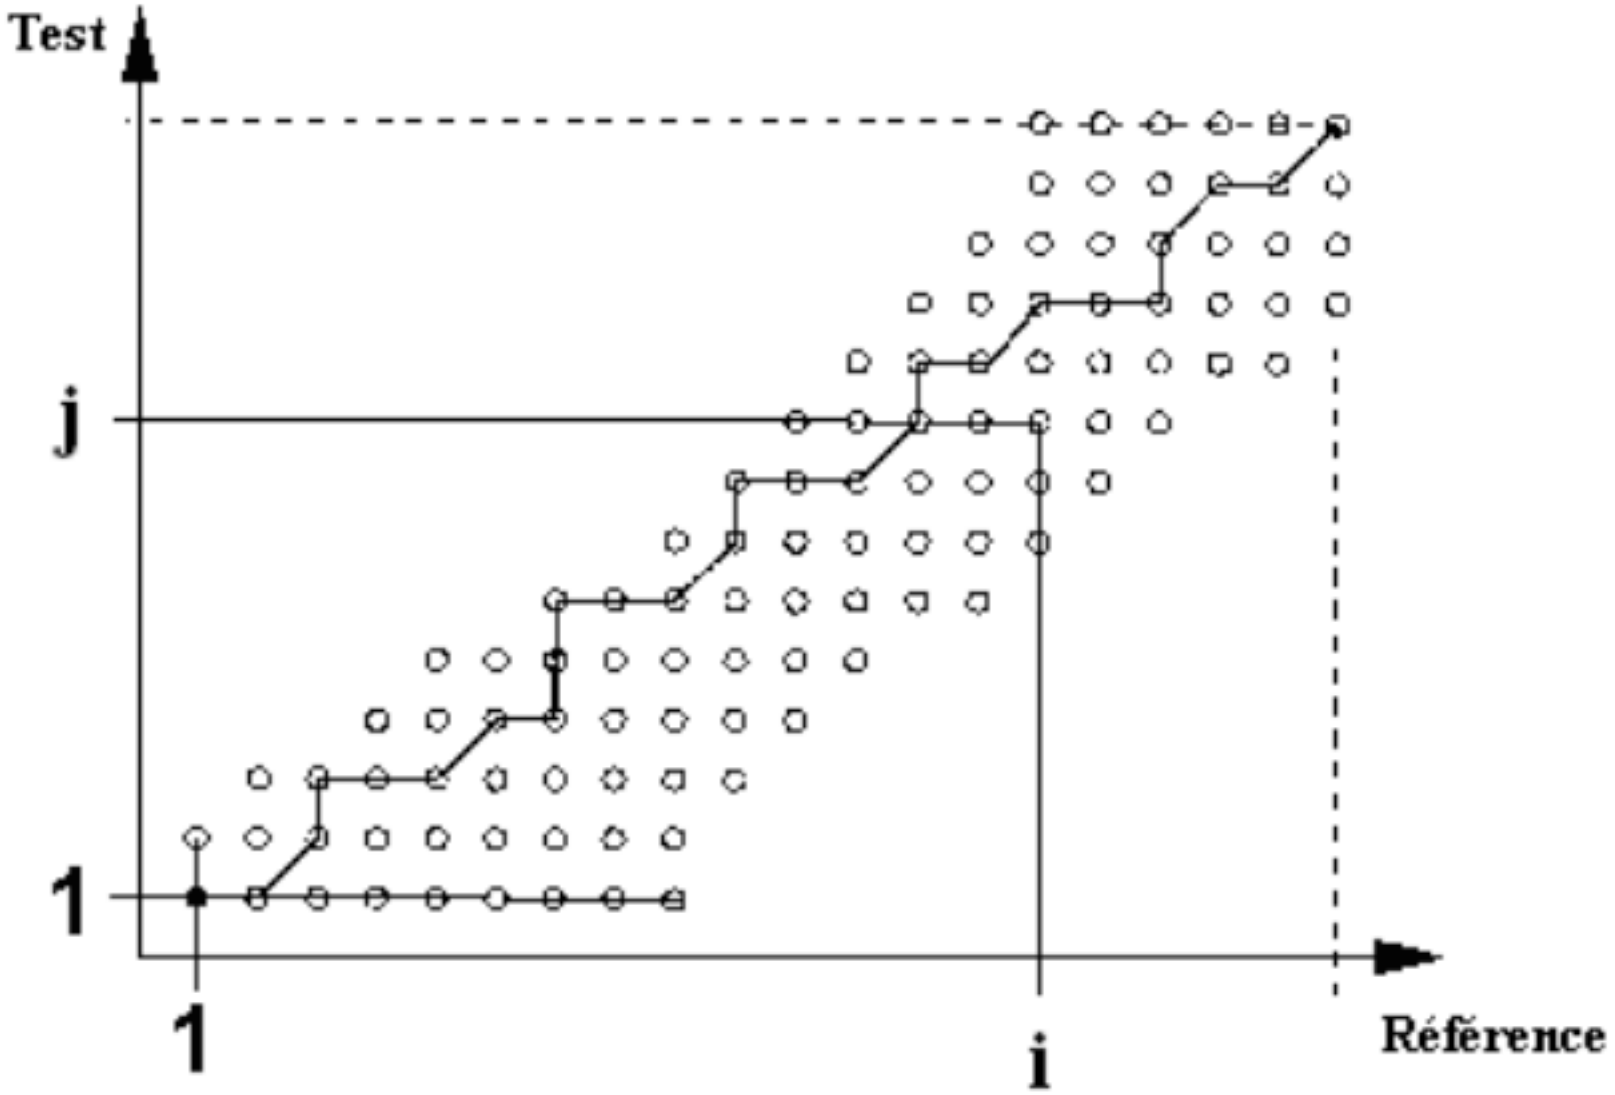

Optimisation

- Mise à l'échelle
  - Réduire les tailles de R et T

Singularités

- Une singularité apparaît quand un point d'une séquence est associé à de nombreux points de l'autre séquence sans raison valable

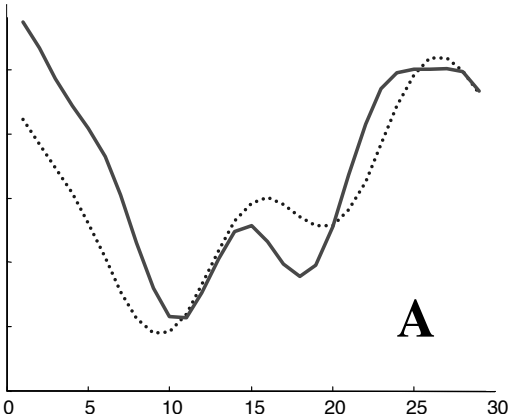

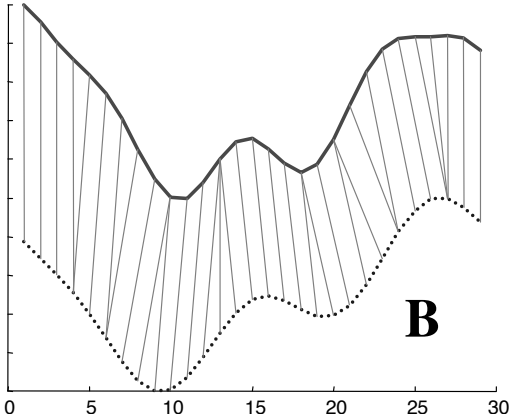

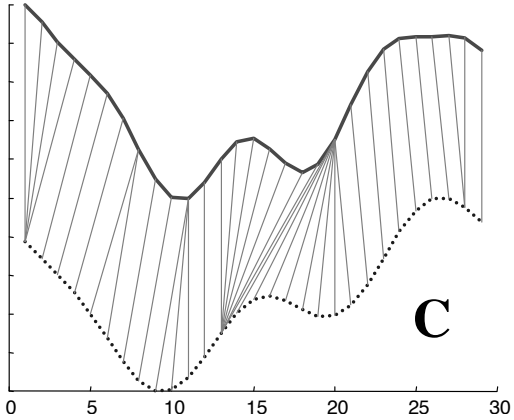

Singularités: technique de fenêtrage

- Ajout de contraintes dans les alignements possibles
- Technique de fenêtrage
  - Donne une borne supérieure à la singularité

for $i = 1; i \leq n; i++$ **do**
  for $j = 1; j \leq m; j++$ **do**
    $dtw(i,j) \leftarrow c(i,j) + \min\{dtw(i-1,j);\ dtw(i,j-1);\ dtw(i-1,j-1)\}$
  end for
end for

for j=max(1,i-w); j <= min (m,i+w); j++ do

Singularités: slope weighting

- Pondérer les déplacements suivant les directions:
  - $D(i,j) = dist(r_i,t_j) + \min(X*D(i-1,j), D(i-1,j-1), X*D(i, j-1))$
  - $X>1$
- Force l'alignement suivant la diagonale

Singularités: Step patterns

- $D(i,j) = dist(r_i,t_j) + \min(D(i-1,j-2), D(i-1,j-1), D(i-2, j-1))$
- Force le déplacement suivant la diagonale

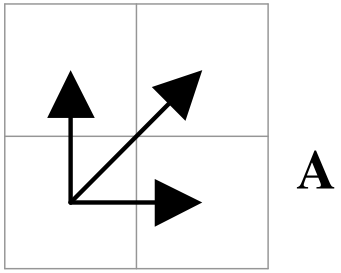

A

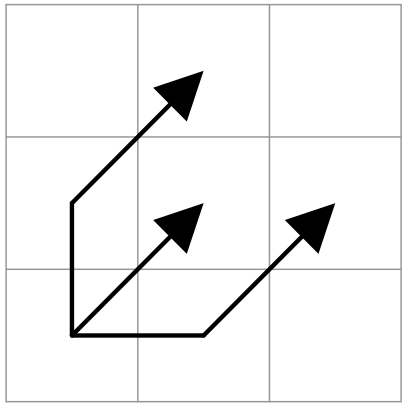

B

Singularités

- Problème: ces contraintes peuvent empêcher d'obtenir l'alignement correct
- Comment définir les différents paramètres des techniques de levée des singularités (taille de fenêtre, coefficients de pondération, motifs)?

DDTW: Derivative Dynamic Time Warping

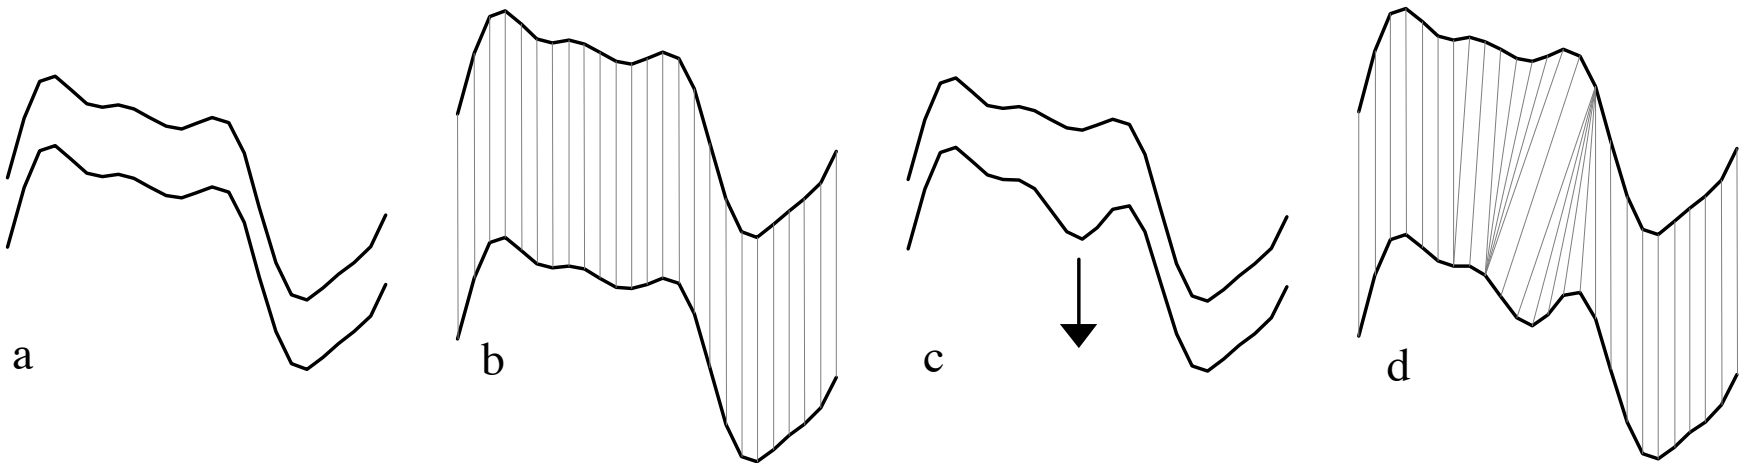


```
@INPROCEEDINGS{Keogh01derivativedynamic,
   author = {Eamonn J. Keogh and Michael J. Pazzani},
   title = {Derivative Dynamic Time Warping},
   booktitle = {In First SIAM International Conference on Data Mining (SDM'2001},
   year = {2001}
}
```

DDTW: Derivative Dynamic Time Warping

- Utilisation de la dérivée des données des séquences

$$D_x[q] = \frac{(q_i - q_{i-1}) + ((q_{i+1} - q_{i-1})/2)}{2}$$

- Calcul du carré de la différence des dérivées

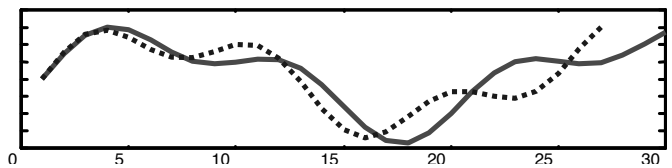

1

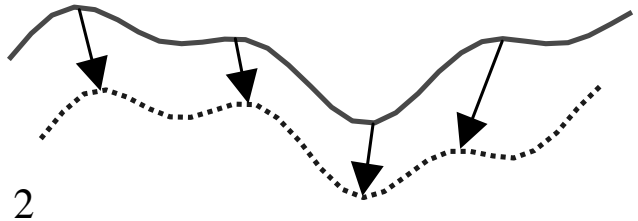

2

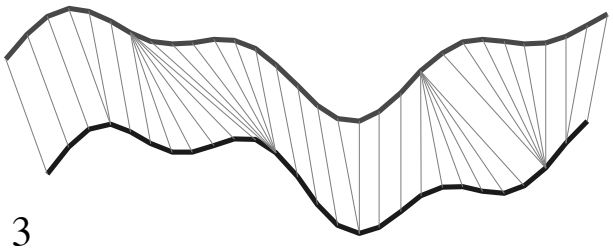

3

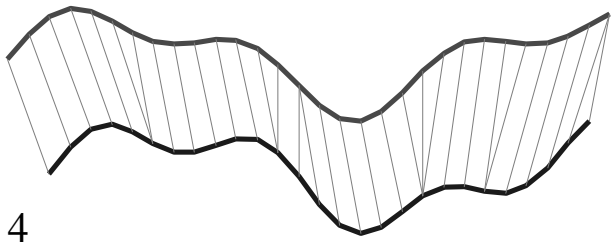

4

DDTW: Derivative Dynamic Time Warping

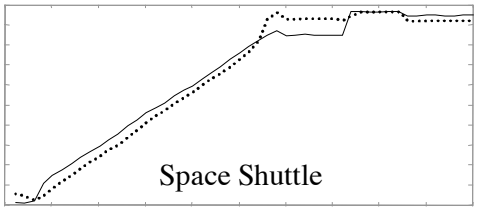

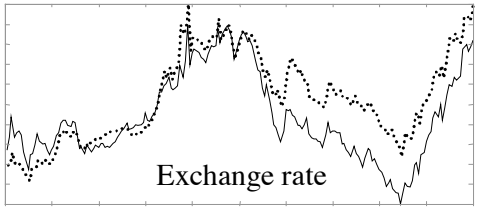

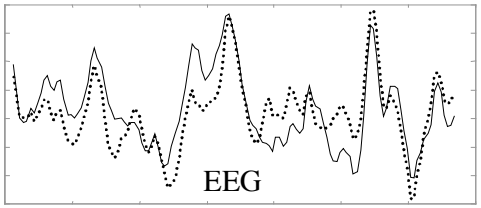

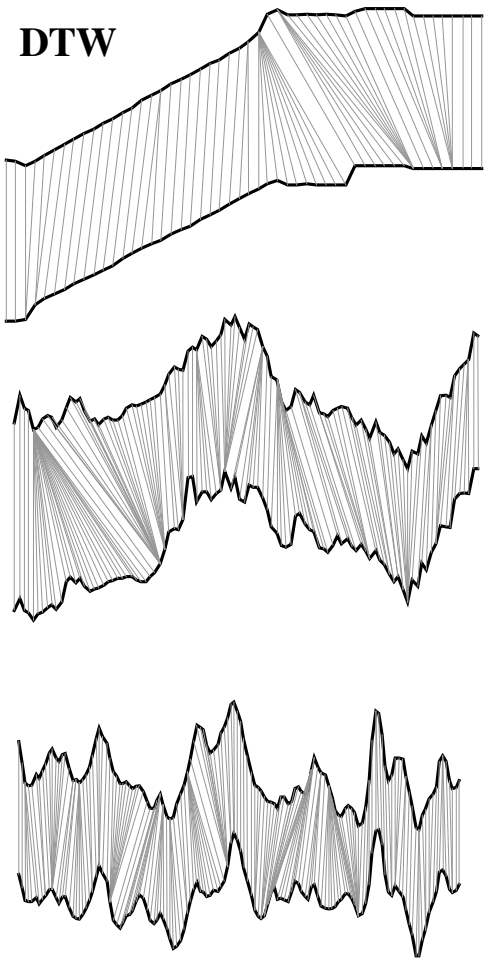

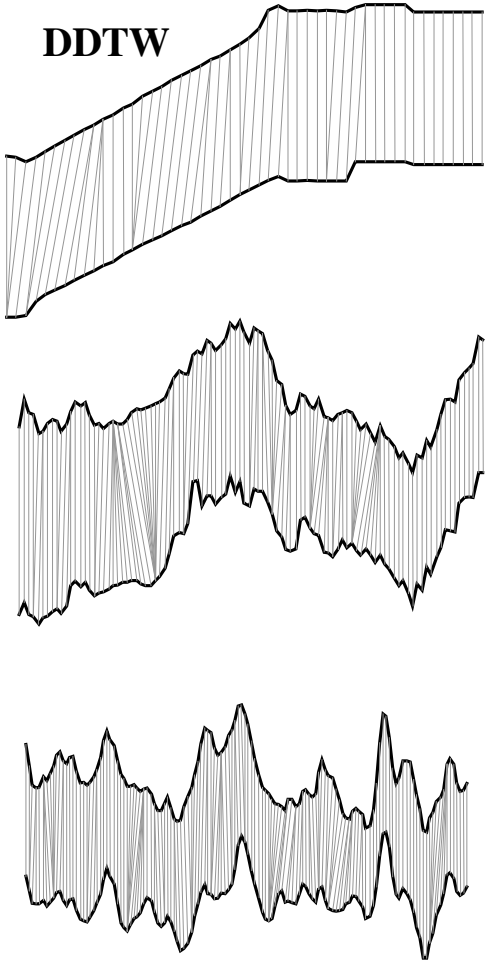

Recherche de motifs

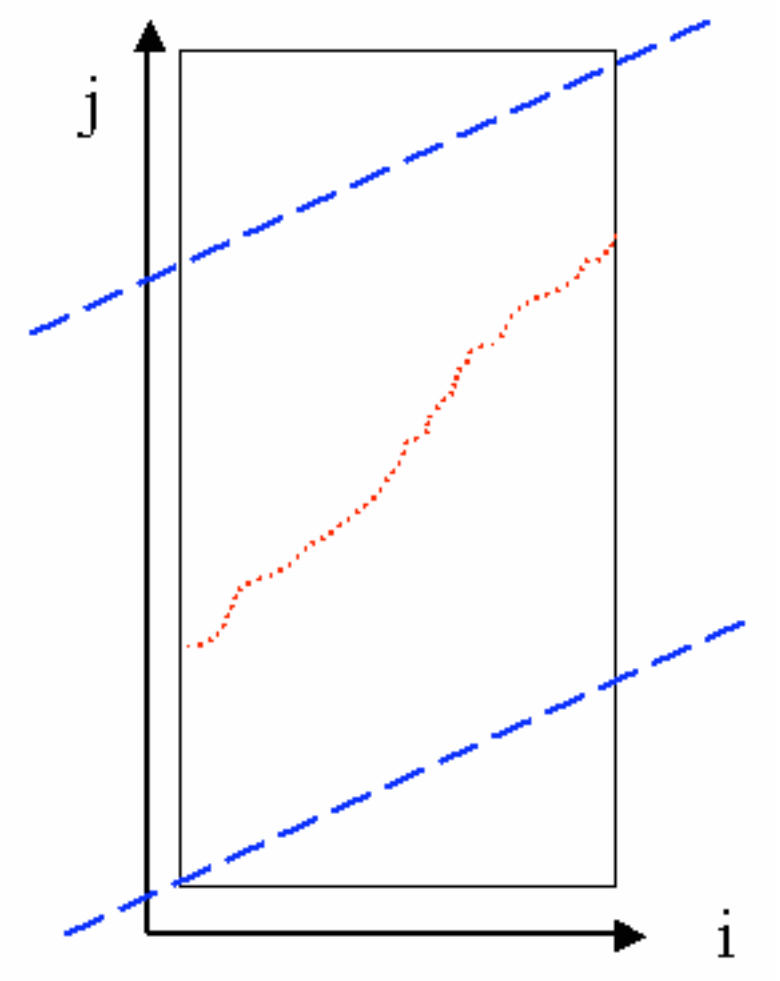

Reconnaissance de gestes

- Pré-traitement des gestes de référence et du geste réalisé par l'utilisateur
  - mise à l'échelle, changement origine, rotation…
- Alignement avec chacun des gestes
- Le geste de référence pour lequel la distance entre les deux séquences est la plus faible est considéré comme reconnu

Affine invariant DTW

- Problème: identifier dans une séquence un objet qui subit une transformation affine
- Choix de la fonction de coût?

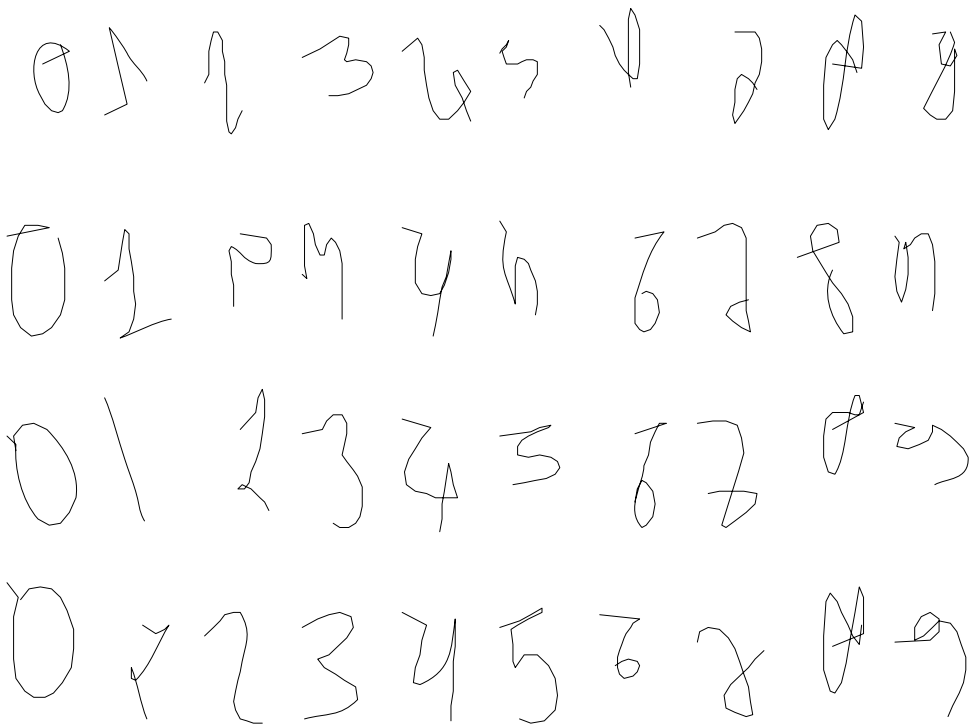

Affine invariant DTW

Optimization Algorithm of AI-DTW:

Initialize

The warping path $w^{(1)}=DTW\_PATH(T, R)$.

Iteration number $k=1$

While not convergence

$k=k+1$;

Update the transformation matrix by:

$$A^{(k)} = \arg\min_{A} \{\sum_{i=1}^{n} \left\| t_i - r_{w^{(k-1)}(i)} A \right\|^2 \} \ .$$

Update the warping path by:

$w^{(k)}=DTW\_PATH(T, RA^{(k)})$.

End While

Yu Qiao and Makoto Yasuhara. 2006. Affine Invariant Dynamic Time Warping and its Application to Online Rotated Handwriting Recognition. In *Proceedings of the 18th International Conference on Pattern Recognition - Volume 02* (ICPR '06), Vol. 2. IEEE Computer Society, Washington, DC, USA, 905-908. DOI=10.1109/ICPR.2006.228 http://dx.doi.org/10.1109/ICPR.2006.228

Multi-Dimensional Dynamic Time Warping

- Comment appliquer DTW quand plusieurs grandeurs sont mesurées à chaque instant?
- Modification de la fonction de distance:
  - Chaque dimension est normalisée avec une moyenne de 0 et une variance de 1
  - Calcul de la somme des valeurs absolues des différences suivant chaque dimension

G. A. ten Holt, M. J. T. Reinders and E. A. Hendriks. Multi-dimensional dynamic time warping for gesture recognition. In Proceedings of the Thirteenth annual conference of the Advanced School for Computing and Imaging, 2007.

Multi-Dimensional Dynamic Time Warping

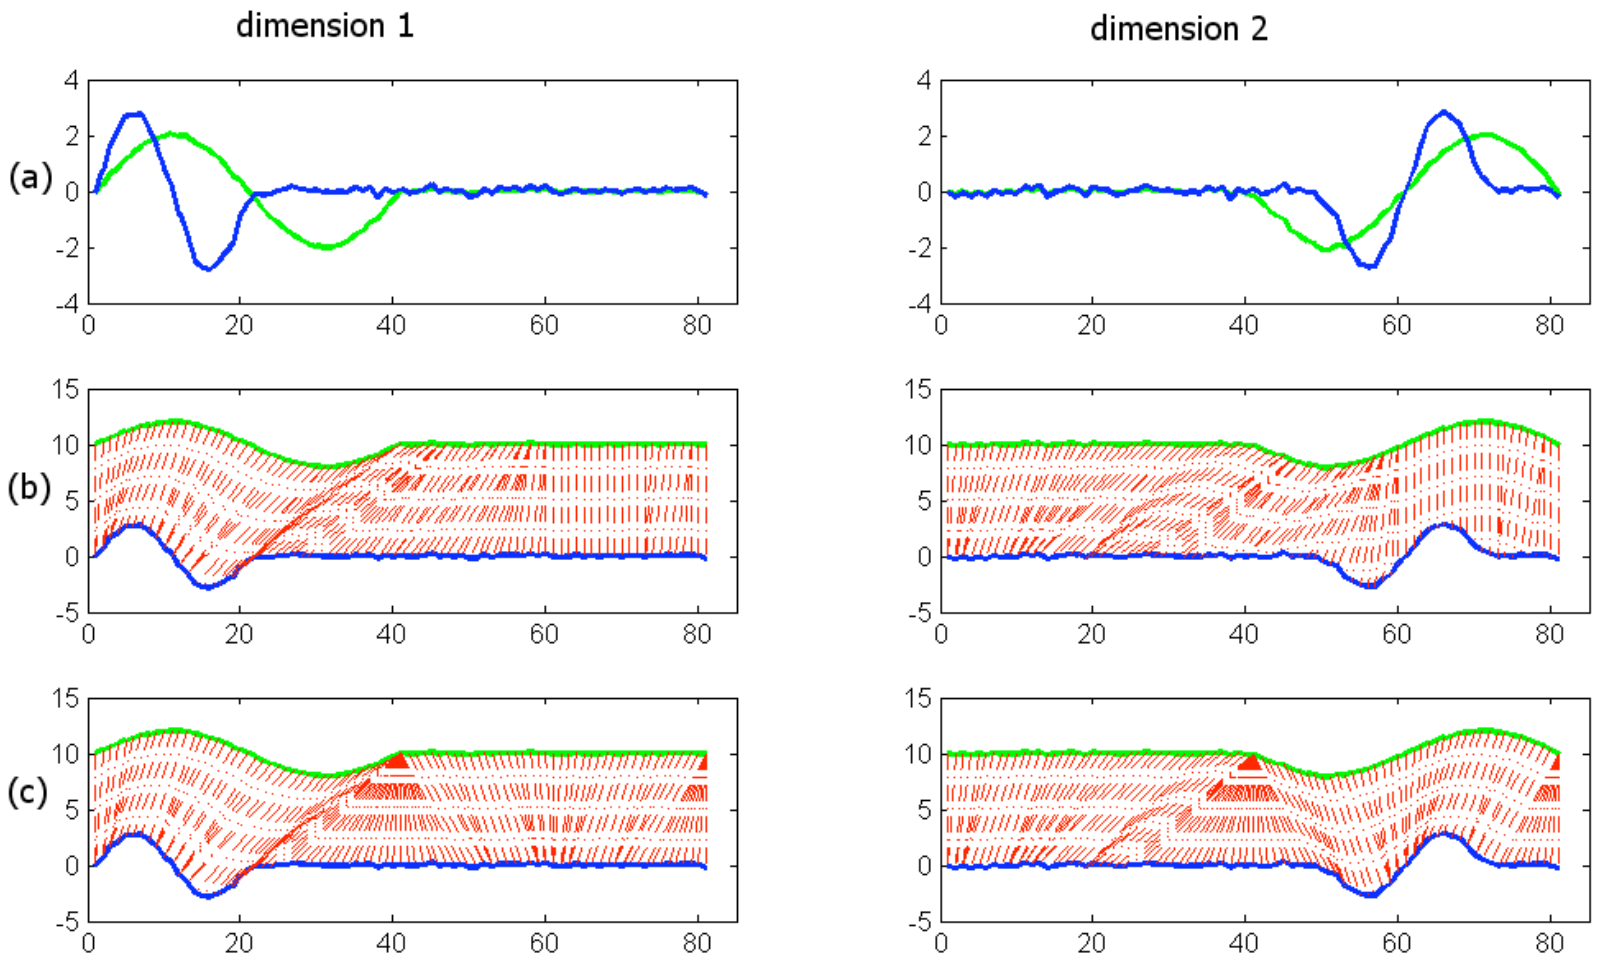

Mutli-Dimensional Dynamic Time Warping

- Possibilité d'utiliser les signaux et leur dérivée

TP

question