

Reconnaissance d'actions

Catherine Achard, Arash Mokhber,
Xingtai Qu et Maurice Milgram

Institut des Systèmes Intelligents et Robotique
Université Pierre & Marie Curie, Paris, France

But: Reconnaître des actions usuelles




La base comporte 8 actions réalisées par 7 personnes (1614 séquences):

(1)	s'accroupir	(5)	marcher
(2)	se relever de la position accroupie	(6)	se pencher
(3)	s'asseoir	(7)	se relever de la position penchée
(4)	se redresser	(8)	saute

Différents points de vue :


- de face
- à +/- 45°,
- à +/- 90°



➔ **37 actions.**

Idée :


- Extraire les silhouettes binaires et réaliser un apprentissage des actions par des chaînes de Markov cachées
- Détection de mouvement par modélisation du fond par une mixture de gaussiennes



1 pixel



1 GMM






Distance entre un pixel et les centres des gaussiennes

$$D(\vec{x}, \vec{m}_i) = (\vec{x} - \vec{m}_i)^T \Sigma_i^{-1} (\vec{x} - \vec{m}_i)$$

Mise à jour de l'image de référence:

$$\mu_t = (1 - \alpha)\mu_{t-1} + \alpha X_t$$

$$\Sigma_t = (1 - \alpha)\Sigma_{t-1} + \alpha(X_t - \mu_t)(X_t - \mu_t)^T$$




Seuillage



Distance aux
gaussiennes




Morphologie




Problème lié aux ombres



Modélisation de l'ombre par un volume conique




Carte d'angle




Résultats de détection





Avec modélisation de
l'ombre



Sans la
modélisation





Caractérisation des silhouettes par ses moments géométriques

$$A_{pq} = E \left\{ x^p y^q \right\}$$

Centrage des moments pour être invariants en translation:

$$AC_{pq} = E \left\{ (x - A_{10})^p (y - A_{01})^q \right\}$$

Normalisation qui préserve le ratio largeur hauteur pour être invariant à l'échelle :

$$M_{pq} = E \left\{ \left(\frac{x - A_{10}}{AC_{20}^{1/4} AC_{02}^{1/4}} \right)^p \left(\frac{y - A_{01}}{AC_{20}^{1/4} AC_{02}^{1/4}} \right)^q \right\}$$

Moments d'ordre 2 et 3

→ Une action = une chaîne temporelle de vecteur de dimension 6

$$o = \{M_{20}, M_{11}, M_{30}, M_{03}, M_{21}, M_{12}\}$$

$$O = \{o_1, o_2, \dots, o_T\}$$

Ces chaînes sont apprises avec les HMM

Les chaînes de Markov cachées.

En général, un HMM est noté $\Lambda = (A, B, \pi)$ où:

- A est une matrice de transition entre ses états si.


$$a_{ij} = P(X_{t+1} = j | X_t = i)$$

- B est une matrice d'observation.

$$b_{ij} = P(O_t = o_j | X_t = i)$$

- π est un vecteur de probabilité initiale.

$$\pi_i = P(X_1 = i)$$



En pratique, nous avons utilisé une gaussienne pour modéliser le vecteur de caractéristique

$$\Lambda = (A, \pi, \mu, \sigma)$$

- L'ensemble des paramètres Λ_k est appris pour chacune des 37 classes sur une base d'apprentissage avec l'algorithme de Baum-Welch
- Il utilise la méthode EM (Expectation- Maximization) pour maximiser la vraisemblance que les HMMs génèrent les séquences d'apprentissage

Séparation de la base de données:



➤ Apprentissage

➔ $\Lambda = (A, \pi, \mu, \sigma)$ pour chacune des 37 classes

➤ Reconnaissance

➔ On recherche la chaîne qui maximise la probabilité d'observation $P(O/\Lambda)$



→ Très mauvais résultats dus à la normalisation
Accroupit face lève



Saute



Idée : travailler sur une fenêtre temporelle et caractériser des micro-volumes



Volume caractérisé par ses moments géométriques :


$$\mu_{ijk} = \frac{1}{A} \sum_{(x,y,t) \in A} \left(\frac{y - y_0}{\sqrt{\sigma_x \sigma_y}} \right)^i \left(\frac{x - x_0}{\sqrt{\sigma_x \sigma_y}} \right)^j \left(\frac{t - t_0}{\sigma_t} \right)^k$$

Moments invariants en

- translation,
- changement d'échelle spatiale

Moments du 2nd et 3^{ième} ordre → vecteur de dimension 14

Etude en fonction de la longueur de la fenêtre temporelle et du nombre d'état des HMMs (taux moyens pour les 7 personnes)




Meilleur résultat (89%) obtenu pour 3 états et 7 images par micro-volume

Matrice de confusion moyenne

- (1) s'accroupir
- (2) se relever de la position accroupie
- (3) s'asseoir
- (4) se redresser
- (5) marcher
- (6) se pencher
- (7) se relever de la position penchée
- (8) sauter

	1	2	3	4	5	6	7	8
1	88.6	0	0.3	0	0	2.6	0	8.5
2	0	93.8	0	0.6	0	0	0.3	5.2
3	0.83	0	81.5	0.28	1.7	3.9	0.3	11.6
4	0	3.6	0	81.5	0	0	10.2	4.7
5	0	0	0.1	0.6	95.4	2.4	0.1	1.3
6	6.2	0	5.1	0	0.2	84.6	0	3.9
7	0	2.9	0.4	2.1	0.4	0.4	91.5	2.3
8	0	1.29	3.3	0	0.4	0.4	2.5	92.1




Une séquence d'image d'une personne qui saute



Personne	1	2	3	4	5	6	7	Moy
Taux	95.3	93.6	80.2	90.8	88.2	93.3	70.3	89.0

Problème de la septième personne:





Autre idée: caractériser directement toute la séquence donc tout le volume par les moments géométriques

→ Une séquence = un vecteur de dimension 14

Taux de reconnaissance obtenus en plaçant tour à tour chaque personne dans la base de test


Personne	1	2	3	4	5	6	7	Moy
Taux	89.9	90.2	82.7	97.2	92.1	95.2	77.1	89.5

Matrice de confusion moyenne

- (1) s'accroupir
- (2) se relever de la position accroupie
- (3) s'asseoir
- (4) se redresser
- (5) marcher
- (6) se pencher
- (7) se relever de la position penchée
- (8) sauter

	1	2	3	4	5	6	7	8
1	97.2	0.0	0.0	0.0	0.0	2.8	0.0	0.0
2	0.0	90.5	0.0	0.0	0.0	0.0	9.5	0.0
3	4.8	0.0	84.1	0.0	0.0	9.4	1.2	0.5
4	0.0	3.3	0.0	76.1	0.0	0.0	17.1	3.6
5	0.0	0.0	0.0	0.0	98.4	0.9	0.2	0.4
6	11.1	0.0	0.0	0.0	0.0	88.3	0.0	0.5
7	0.0	10.7	0.0	0.7	0.0	0.0	88.2	0.3
8	0.0	8.6	0.0	0.0	0.0	1.7	0.9	88.8

Volumes non binaires



Personne	1	2	3	4	5	6	7	Moy
Taux	92,6	88,3	88,1	93,1	89,8	96,2	77,1	90,0

Personne	1	2	3	4	5	6	7	Moy
Taux	95,8	85,9	85,7	94,4	88,3	97,1	74	89,7

Sans segmentation préalable,

➤ Calcul du flot optique sur chaque image:




➤ Estimation des moments géométriques centrés, réduits

Personne	1	2	3	4	5	6	7	Moy
Taux	90,2	75,2	89	91,3	81,1	84,8	87,5	85,9

Segmentation

Calcul de vecteurs moments sur les volumes binaires V_i centrés autour de l'instant de référence



Volumes contenant 5 à 50 images




46 vecteurs à comparer avec ceux de la base




Choix du vecteur le plus proche et attribution de l'étiquette de la référence la plus proche

Résultat de segmentation



Vérité de terrain



Conclusion

- Comme en signal, la caractérisation n'est pas robuste si elle est réalisée image par image
- Mise en place de deux méthodes de reconnaissance d'actions. La première modélise les actions par les HMMs, tandis que la seconde caractérise les actions de manière globale

Bilan

- Résultats similaires quant aux taux de reconnaissance
- Les approches par HMMs facilitent la segmentation des séquences

Perspectives

- Etendre la base de données et principalement, le nombre d'acteurs
- Comparer avec des méthodes « globales » basées sur l'algorithme adaboost
- Utiliser une version multi-classes d'adaboost pour détecter plusieurs actions
- Réaliser une sélection de caractéristiques