

Un filtre temporel crédibiliste pour la reconnaissance d'actions humaines dans les vidéos

A temporal belief filter for human action recognition in videos

E. Ramasso, M. Rombaut, D. Pellerin

Laboratoire des Images et des Signaux (LIS - UMR 5083)

46, avenue Félix Viallet, 38031 Grenoble, France,

{emmanuel.ramasso,michele.rombaut,denis.pellerin}@lis.inpg.fr

Résumé :

Ce papier présente un filtre temporel crédibiliste utilisé pour la reconnaissance d'actions humaines dans des vidéos. Ce filtre permet de s'affranchir au moins en partie des problèmes dus à la disparité dans la réalisation des actions, à la variabilité des conditions d'acquisition des vidéos et à la difficulté d'appliquer les algorithmes de traitements d'images sur des vidéos réelles. L'ensemble du système de reconnaissance est construit à partir du formalisme du Modèle des Croyances Transférables (Transferable Belief Model : TBM) proposé par P. Smets. Le TBM permet d'exprimer explicitement le doute entre les actions. De plus, l'information de conflit mise en lumière par le TBM est exploitée pour détecter le changement d'état des actions. Les performances du filtre sont estimées sur des vidéos d'athlétisme réelles acquises en caméra mobile avec des angles de vue variables.

Mots-clés :

Filtrage de fonctions de croyance, Modèle des Croyances Transférables, Indexation de vidéos.

Abstract:

In the context of human action recognition in video sequences, a temporal belief filter is presented. It allows to cope with human action disparity and low quality videos. The whole system of action recognition is based on the Transferable Belief Model (TBM) proposed by P. Smets. The TBM allows to explicitly model the doubt between actions. Furthermore, the TBM emphasizes the conflict which is exploited for action recognition. The filtering performance is assessed on real video sequences acquired by a moving camera and under several unknown view angles.

Keywords:

Belief functions filtering, Transferable Belief Model, video indexing.

1 Introduction

1.1 Contexte

L'analyse du comportement humain dans les vidéos est un domaine de recherche en plein essor dans la communauté de la vision par ordi-

nateur [1]. En effet, elle est au coeur de nombreuses applications telles que la surveillance de personnes, les interfaces homme-machine, l'indexation et la recherche dans de grandes bases de vidéos. Le lien entre le monde réel, de nature analogique, et la pensée humaine, plutôt symbolique, est une des difficultés majeures.

De nombreuses méthodes sont proposées pour la reconnaissance d'actions humaines dans les vidéos [1]. Elles peuvent être classées en deux catégories : les *templates matching* et les *machines à états*. Le premier type de méthodes ne parvient généralement pas à faire face aux conditions variables d'acquisition des vidéos telles que le changement d'angle de vue et la disparité dans la réalisation des actions. La deuxième catégorie concerne majoritairement des méthodes probabilistes [2] notamment les *Modèles de Markov Cachés* (HMM) et les *Réseaux Bayésiens Dynamiques* (DBN) [3]. La théorie des probabilités est particulièrement intéressante lorsque des jeux de données d'apprentissage conséquents [4] sont disponibles et lors de la prise de décision.

L'analyse du mouvement humain basée sur les fonctions de croyance est une approche récente. Un classifieur basé sur le modèle de Shafer [5] a été utilisé pour reconnaître des postures statiques [6] et des expressions faciales [7]. Nous avons proposé [8] une architecture originale pour la reconnaissance d'actions humaines basée sur le Modèle de Croyances Transférables

(Transferable Belief Model : TBM) [9]. Ce formalisme est particulièrement bien adapté car (i) le *doute* sur les états est modélisé explicitement, (ii) le *conflit* entre les sources d'information peut être utilisé pour détecter un changement d'état et pour remettre en question les sources fusionnées et (iii) la *fiabilité* des paramètres dépendant du contexte peut être prise en compte.

Les méthodes proposées jusqu'ici pour l'analyse du mouvement humain basée sur les fonctions de croyance n'intègrent pas l'information temporelle. Pour remédier à cela, deux solutions principales existent : les réseaux évidentiels [10] et les réseaux de Petri crédibilistes [11]. Cependant, ces deux méthodes sont sensibles au bruit pouvant apparaître sur les croyances et se traduisant généralement par la présence de fausses alarmes. De plus, les fonctions de croyance utilisées sont généralement normalisées pour supprimer le conflit.

Dans cet article, nous proposons une méthode de filtrage des fonctions de croyance qui est capable d'éliminer les fausses alarmes et qui exploite l'information de conflit.

1.2 Reconnaissance des actions

Indexer une vidéo à un niveau compatible avec la compréhension humaine nécessite de définir des concepts c'est à dire des informations dites de haut niveau symbolique. Nous nous intéressons ici au comportement d'un athlète au cours de meetings d'athlétisme et nous cherchons à détecter et reconnaître ses actions comme la *course*, le *saut* et la *chute*. Ces actions sont supposées indépendantes, non exhaustives et non exclusives.

Une action peut prendre deux états distincts : soit elle est vraie soit elle fausse. Pour déterminer l'état d'une action, des paramètres sont extraits du flux vidéo par des méthodes de traitements classiques comme l'estimation du mouvement de caméra et le suivi de points. Les

paramètres sont choisis pour leur pertinence par rapport aux actions à reconnaître. Dans le cadre de l'application avec caméra mobile, notre choix s'est basé sur deux hypothèses principales : (i) le cameraman suit l'athlète et (ii) la trajectoire de points particuliers de la silhouette suffit à décrire le comportement de l'athlète. Les paramètres qui ont été choisis sont : les mouvements de caméra entre deux images successives (horizontal, vertical, zoom) et la trajectoire de la tête, d'un des deux pieds et du centre de la silhouette. Ces derniers paramètres permettent d'extraire l'alternance des pieds, la courbure de la silhouette et son angle par rapport à l'horizon. Tous les paramètres sont ensuite traduits en croyance puis fusionnés dans le cadre du TBM. Finalement, à chaque image, une croyance sur la réalisation de chaque action est calculée.

Du fait de la diversité dans la réalisation des actions, des conditions d'acquisition des vidéos et de la complexité des algorithmes de traitement, les résultats de la fusion sont bruités. Il est bien sûr possible de filtrer les signaux numériques, mais cela pourrait éliminer des informations utiles aux actions notamment lorsque celles ci ne durent que quelques images. Nous avons donc développé un filtre temporel crédibiliste capable de filtrer le bruit sur les croyances mais aussi de détecter les changements d'états pour chacune des actions. Le système complet est présenté figure 1.

Dans le paragraphe 2, nous décrivons comment l'information concernant une action particulière est modélisée puis fusionnée dans le cadre du TBM. Le paragraphe 3 est consacré à la description du filtre temporel crédibiliste que nous avons développé. Enfin, le filtre est évalué dans le paragraphe 4.

2 Processus de fusion

2.1 Définition des fonctions de croyance

Soit $\Omega_A = \{R_A, F_A\}$ l'espace de discernement (FoD) d'une action A . Le FoD regroupe

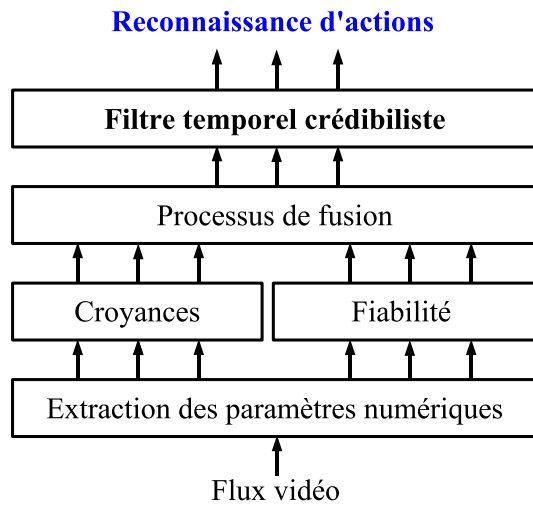


Figure 1 – Architecture du système de reconnaissance d'actions.

les états élémentaires d'une action (vrai ou faux). Une distribution de masse $m_P^{\Omega_A}$ concernant une action A , est une fonction de croyance dépendant du paramètre P définie sur l'ensemble des propositions $2^{\Omega_A} = \{\emptyset, R_A, F_A, R_A \cup F_A\}$ (où $R_A \cup F_A$ correspond au doute entre les états R_A et F_A). La distribution de masse est une application qui à tout $X \in 2^{\Omega_A}$ associe $m_P^{\Omega_A}(X) \in [0, 1]$. Par construction $m_P^{\Omega_A}(\emptyset) = 0$, et $\sum_{X \subseteq \Omega_A} m_P^{\Omega_A}(X) = 1$. La valeur de $m_P^{\Omega_A}(X)$ correspond à la masse qui indique la confiance sur la proposition $X \subseteq \Omega_A$ à partir de la connaissance du paramètre P . Cette valeur ne donne aucune information supplémentaire concernant les sous ensembles de X . C'est la différence fondamentale avec une mesure de probabilité.

Nous nous sommes inspirés des sous ensembles flous [8] pour obtenir les distributions de masse de chaque paramètre numérique. Cette conversion numérique-symbolique est réalisée à chaque image de la vidéo analysée.

2.2 Fusion des fonctions de croyance

Les distributions de masses obtenues à partir des différents paramètres sont fusionnées dans le cadre du TBM [9]. Une fonction de croyance est alors obtenue pour chacune des actions

possibles prenant en compte toute l'information disponible. La fusion est réalisée image par image et pour chaque action.

La combinaison de deux distributions de masse $m_{P_1}^{\Omega_A}$ et $m_{P_2}^{\Omega_A}$ définies sur le même FoD Ω_A , concernant une même action A et calculées à partir de la valeur numérique de deux paramètres P_1 et P_2 , donne :

$$m_{P_1}^{\Omega_A} \triangle m_{P_2}^{\Omega_A}(E) = \sum_{C \triangle D = E} m_{P_1}^{\Omega_A}(C) \cdot m_{P_2}^{\Omega_A}(D) \quad (1)$$

avec $\triangle = \cap$ (resp. \cup) pour la combinaison conjonctive (resp. disjonctive). Une action est alors décrite par des règles logiques entre les états des paramètres (exemple : "si l'alternance des pieds est importante ET si la translation horizontale de la caméra est importante alors l'action est une course") puis retranscrites dans le cadre du TBM où le ET logique est remplacé par \cap et le OU logique par \cup en prenant soin d'avoir exprimé les fonctions de masse sur le même FoD.

2.3 Fiabilité des sources

Il est possible de prendre en compte la fiabilité des paramètres lors de la combinaison. Cela permet de modérer l'influence d'une source d'information pour laquelle les conditions de fonctionnement ne seraient pas optimales. Le paramètre de fiabilité $\alpha_P \in [0, 1]$ concernant le paramètre P agit sur la distribution de masse $m_P^{\Omega_P}$ de la façon suivante :

$$\begin{aligned} m_P^{\Omega_P, \alpha_P}(A) &= \alpha_P \times m_P^{\Omega_P}; \forall A \subsetneq \Omega_P \\ m_P^{\Omega_P, \alpha_P}(\Omega_P) &= (1 - \alpha_P) + \alpha_P \times m_P^{\Omega_P} \end{aligned} \quad (2)$$

L'estimation de α_P peut être réalisée à partir de connaissances statistiques [12]. Nous proposons ici de calculer en ligne le facteur de fiabilité lié à la qualité de la vidéo et des traitements associés à chaque image. Deux facteurs de fiabilité ont été définis. Tout d'abord α_{sup} qui est basé sur l'appartenance effective du pixel au mouvement dominant et qui permet de quantifier la qualité de l'estimation de mouvement. Ensuite, α_{dist} qui est calculé à partir du rapport normalisé entre les distances *pieds - cen-*

tre de gravité et tête - centre de gravité dont la valeur optimale est 1. Ce deuxième facteur permet d'évaluer la qualité de l'algorithme de suivi de points de la silhouette.

3 Filtre temporel crédibiliste

Les fonctions de croyance obtenues par fusion des paramètres sont traitées par un filtre temporel crédibiliste qui permet de lisser l'évolution des croyances et de détecter les changements d'états. Ce filtre est appliqué sur les croyances de chacune des actions indépendamment.

En sortie du filtre, une distribution de masse est obtenue. Elle est cohérente avec :

- *les paramètres* : le filtre permet de résoudre le conflit entre les sources associées à chacun des paramètres,
- *les variations dans le temps* : la croyance sur les actions ne peut varier brutalement d'une image à l'autre compte tenu de la différence entre la cadence vidéo et les mouvements humains,
- *la condition d'exclusivité* : le filtre permet de s'assurer de la consonance des distributions de masse c'est à dire que si l'une des hypothèses, e.g. R_A , a une masse non nulle alors l'autre hypothèse, e.g. F_A , a une masse nulle.

La dernière propriété permet de définir un "état" de l'action, i.e. soit *vrai* soit *faux*. Ces états sont évalués pour chaque action *indépendamment* en fonction des distributions de masse définies à partir de chaque paramètre.

Le principe du filtre temporel crédibiliste est décrit figure 2. Le filtre temporel est basé sur les *règles d'implication*. La formalisation de ces règles dans le cadre du TBM ainsi qu'un exemple concernant l'identification de cibles aériennes sont fournis dans [13]. Nous utilisons deux règles d'implication que nous interprétons

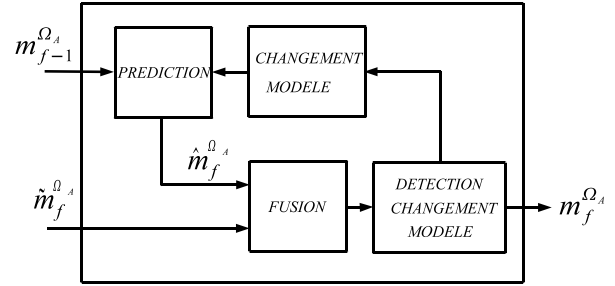


Figure 2 – Principe du filtre temporel crédibiliste où $\hat{m}_f^{\Omega_A}$ est la prédiction, $m_f^{\Omega_A}$ est la valeur de sortie du filtre à l'image f donnant l'état de l'action et $\tilde{m}_f^{\Omega_A}$ est la mesure en sortie de la fusion de paramètres à l'image f .

comme des modèles d'évolution des masses sur les actions. Nous notons les modèles $\mathcal{M} \in \{\mathcal{R}, \mathcal{F}\}$ avec \mathcal{R} pour le modèle *vrai* et \mathcal{F} pour le modèle *faux*. Chacun de ces modèles concerne l'une des hypothèses du FoD d'une action A , i.e. R_A ou F_A . A chaque image f (f pour frame), le filtre fonctionne en trois étapes : (i) prédiction, (ii) fusion et (iii) détection de changement d'état.

3.1 Prédiction

L'étape de prédiction s'appuie sur l'hypothèse suivante : si l'état de l'action est R_A (resp. F_A) à l'image $(f - 1)$ alors, à l'image f son état sera au moins partiellement R_A (resp. F_A). Ce modèle d'évolution \mathcal{R} (resp. \mathcal{F}) est pondéré par un coefficient de confiance $\gamma_{\mathcal{R}} \in [0, 1]$ (resp. $\gamma_{\mathcal{F}} \in [0, 1]$) :

Modèle \mathcal{R} :

Si R_A à $(f - 1)$
alors R_A à f avec la croyance $\gamma_{\mathcal{R}}$ (3)

Modèle \mathcal{F} :

Si F_A à $(f - 1)$
alors F_A à f avec la croyance $\gamma_{\mathcal{F}}$

Par la suite, la notation vectorielle de la distribution de masse définie sur le Ω_A est utilisée comme suit :

$$m^{\Omega_A} = [m^{\Omega_A}(\emptyset) \quad m^{\Omega_A}(R_A) \quad m^{\Omega_A}(F_A) \quad m^{\Omega_A}(\Omega_A)]^T$$

Le modèle d'évolution peut être interprété comme une distribution de masse. Par exemple, pour le modèle \mathcal{R} :

$$m_{\mathcal{R}}^{\Omega_A} = [0 \quad \gamma_{\mathcal{R}} \quad 0 \quad (1 - \gamma_{\mathcal{R}})]^T \quad (4)$$

La règle de combinaison disjonctive (eq. 1) est alors utilisée pour calculer la prédiction à partir de la distribution de masse à l'image $(f - 1)$ et du modèle d'évolution :

$$\hat{m}_{f,\mathcal{M}}^{\Omega_A} = m_{\mathcal{M}}^{\Omega_A} \oplus m_{f-1}^{\Omega_A} \quad (5)$$

La règle \oplus n'attribue jamais plus de masse à une hypothèse singleton que celle qu'elle avait avant fusion. Par conséquent, la distribution de masse prédite à l'image f à l'aide du modèle \mathcal{R} (eq. 4) est donc :

$$\hat{m}_{f,\mathcal{R}}^{\Omega_A} = \begin{bmatrix} 0 \\ \gamma_{\mathcal{R}} \times m_{f-1}^{\Omega_A}(R_A) \\ 0 \\ (1 - \gamma_{\mathcal{R}}) \times m_{f-1}^{\Omega_A}(R_A) + m_{f-1}^{\Omega_A}(\Omega_A) \end{bmatrix} \quad (6)$$

Quand $\gamma_{\mathcal{M}} = 1$, la prédiction à f est égale à la distribution de masse à $(f - 1)$. Quand $\gamma_{\mathcal{M}} = 0$, le modèle ne donne aucune indication sur l'évolution de la masse entre une image et la suivante.

3.2 Fusion

Prédiction $\hat{m}_{f,\mathcal{M}}^{\Omega_A}$ et mesure $\tilde{m}_f^{\Omega_A}$ sont deux sources d'information concernant l'état de l'action A . La combinaison conjonctive des distributions de masse associées (eq. 1) donne une nouvelle distribution de masse dont la masse sur l'ensemble vide quantifie le conflit entre modèle et données et donc reflète le besoin de changer de modèle :

$$\epsilon_f = (\hat{m}_{f,\mathcal{M}}^{\Omega_A} \odot \tilde{m}_f^{\Omega_A})(\emptyset) \quad (7)$$

Cependant, ϵ_f ne peut pas être utilisé directement car il peut provenir des erreurs de mesures sur les paramètres. Nous avons donc utilisé la somme cumulée (CUSUM) pour résoudre ce problème et éviter les changements d'état intempestifs. La CUSUM est bien adaptée pour traiter les *changements rapides et importants* ou *changements longs et graduels*.

3.3 Détection du changement d'état

Lorsque la valeur de la CUSUM atteint un seuil d'alerte \mathcal{T}_w (**w**arning threshold), le numéro de l'image f_w est mémorisé mais le modèle d'évolution courant reste valide. Quand la CUSUM s'accroît et atteint un seuil d'arrêt \mathcal{T}_s (**s**top threshold) à l'image f_s , alors le modèle d'évolution est changé, puis le nouveau modèle est appliqué à partir de f_s . Lorsque du conflit apparaît, les mesures ne sont pas prises en compte, seule la valeur prédite est utilisée. Cela revient à *faire confiance au modèle d'évolution*. Ceci permet de ne pas maintenir une masse sur le conflit qui est un élément absorbant par la combinaison conjonctive \odot :

$$m_f^{\Omega_A} = \begin{cases} \hat{m}_{f,\mathcal{M}}^{\Omega_A} \odot \tilde{m}_f^{\Omega_A} & \text{si } \epsilon_f = 0 \\ \hat{m}_{f,\mathcal{M}}^{\Omega_A} & \text{sinon} \end{cases} \quad (8)$$

L'équation (8) tient compte du fait que la distribution de masse $m_{f-1}^{\Omega_A}$ possède au plus deux éléments focaux (eq. 6) en fonction du modèle d'évolution courant \mathcal{M} . Au final, la distribution de masse est consonante, sans conflit et seulement l'une des deux hypothèses R_A ou F_A a une masse non nulle. De plus, le fait d'utiliser la règle disjonctive \oplus pour prédire l'état permet, en cas de conflit avec les mesures, d'aboutir à l'infini à une distribution de masse $m_{f \rightarrow \infty}^{\Omega_A}(\Omega_A) = 1$ qui reflète l'ignorance totale ce qui est tout à fait cohérent.

Tel qu'il a été décrit, le traitement de la CUSUM pose un problème pour les conflits très faibles mais de longue durée. Pour y remédier, nous proposons d'utiliser un mécanisme d'*oubli* qui permet d'atténuer l'effet du conflit qui serait intervenu depuis trop longtemps : CUSUM courante $\text{CS}(f)$:

$$\text{CS}(f) \leftarrow \text{CS}(f - 1) \times \lambda + \epsilon_f \quad (9)$$

Le coefficient d'oubli λ a été choisi constant et est appliqué à chaque image.

Seul l'un des deux modèles (\mathcal{R} et \mathcal{F}) est appliqué à chaque image. Lorsqu'un change-

ment de modèle intervient pour l'action A , c'est à dire que le seuil d'arrêt \mathcal{T}_s est atteint par la CUSUM, l'intervalle des images $\mathbf{IT} = [f_w, \min(f_s, f_w + \mathcal{W})]$ est interprété comme un intervalle de transition entre les deux états de l'action A . Le paramètre \mathcal{W} limite la taille de la transition. Une distribution de masse modélisant l'ignorance est affectée en sortie du filtre sur tout l'intervalle \mathbf{IT} : $m_{\mathbf{IT}}^{\Omega_A}(\Omega_A) = 1$. Puis, à partir de la borne supérieure de \mathbf{IT} , la CUSUM est remise à zéro et le nouveau modèle, en concordance avec les mesures, est appliqué.

3.4 Quelques indications sur l'initialisation et le réglage des paramètres

Initialisation. Le filtre temporel crédibiliste est un mécanisme qui fonctionne en ligne. Lors de l'initialisation, le modèle qui correspond le mieux aux premières mesures est sélectionné. Pour cela, le calcul de la CUSUM est réalisé sur les premières images pour les deux modèles puis celui présentant la plus petite CUSUM est choisi.

Réglages des paramètres. Il est nécessaire de configurer les paramètres dans le bon ordre : le paramètre d'oubli λ ainsi que les deux coefficients associés aux modèles $\gamma_{\mathcal{R}} \in [0, 1]$ (resp. $\gamma_{\mathcal{F}}$) doivent être traités ensemble et en premier lieu. Puis le seuil d'arrêt \mathcal{T}_s de la CUSUM ainsi que le seuil d'alerte \mathcal{T}_w sont réglés. Enfin le paramètre \mathcal{W} est fixé.

Pour un paramètre d'oubli donné, la valeur de \mathcal{T}_s peut être estimée si une vérité terrain concernant la validité des actions est disponible c'est à dire si l'image de départ f_{sref} (**s**tart frame) et l'image d'arrêt f_{eref} (**e**nd frame) sont connues. Dans ce cas, le filtre est appliqué avec le modèle \mathcal{F} (*état faux*) avec un seuil d'arrêt \mathcal{T}_s inatteignable. Alors, le seuil vaut $\mathcal{T}_s = \mathbf{CS}(f_{sref})$. S'il y a beaucoup de bruit sur les données, alors il se peut que la valeur estimée ne soit pas optimale. Dans ce cas, le paramètre d'oubli λ doit être augmenté et la procédure réitérée.

4 Expérimentations

Description de la base de test. Nous avons utilisé ce système pour reconnaître les actions d'un athlète dans différents meetings d'athlétisme. Les vidéos utilisées concernent des *sauts en hauteur* et des *sauts à la perche*. Les actions recherchées sont la *course*, le *saut* et la *chute*. La base de données est composée de 34 vidéos filmées par une caméra mobile. Il y a 22 sauts à la perche et 12 sauts en hauteurs soit environ 5500 images. Cette base est caractérisée par son hétérogénéité (fig. 3) : angles de vue divers, environnements extérieurs ou intérieurs, présence d'autres personnes ou d'objets mobiles dans la scène, athlètes hommes ou femmes de différentes nationalités.



Figure 3 – Exemples illustrant l'hétérogénéité de la base de vidéos.

Réglages. Pour montrer les performances et la robustesse du filtre temporel crédibiliste, un seul réglage a été réalisé pour toutes les actions et toutes les vidéos en utilisant les recommandations décrites au paragraphe 3. Pour information, les valeurs choisies sont : $\lambda = 0.9$, $\gamma_{\mathcal{R}} = \gamma_{\mathcal{F}} = 0.9$, $\mathcal{T}_s = 3$, $\mathcal{T}_w = 0.5$ et $\mathcal{W} = 5$.

Critère de décision. Afin d'évaluer les capacités du système proposé, il est nécessaire de prendre une décision à partir des croyances sur l'état des actions. Pour cela, nous utilisons la transformation pignistique proposée par Smets, qui vaut dans notre cas :

$$\mathbf{BetP}(R_A) = \frac{m_f^{\Omega_A}(R_A) + 0.5 \times m_f^{\Omega_A}(R_A \cup F_A)}{1 - m_f^{\Omega_A}(\emptyset)} \quad (10)$$

avec $m_f^{\Omega_A}$ la sortie du système avec et sans filtre. Si $\mathbf{BetP}(R_A) > 0$ alors A est considérée comme étant vraie.

Critère d'évaluation. La base a été annotée manuellement ce qui nous sert de référence. Les indices de rappel (\mathcal{R}) et précision (\mathcal{P}) sont calculés de la façon suivante : $\mathcal{R} = \frac{C \cap R}{C}$ et $\mathcal{P} = \frac{C \cap R}{R}$, où C est l'ensemble des images correctes, i.e. les références données par l'annotation de l'expert, R est l'ensemble des images retrouvées à l'aide du critère sur la probabilité pignistique **BetP**, et $C \cap R$ est le nombre d'images correctes retrouvées.

Illustration. Le tableau 1 présente les résultats de reconnaissance des actions pour toutes les séquences avant et après filtrage par le filtre temporel crédibiliste. Un gain important peut être observé pour toutes les actions grâce au filtrage. La figure 4 illustre un résultat du filtre sur une distribution de masse concernant une action *saut* dans un saut en hauteur. La croyance sur les différentes propositions est représentée : \emptyset (paramètres discordants pour A), R_A (A est vraie), F_A (A est fausse) et $R_A \cup F_A$ (doute sur l'état de A). L'accumulation du conflit (CUSUM) est aussi illustrée soulignant l'effet du coefficient d'oubli pendant les fausses alarmes.

Tableau 1 – Rappel (\mathcal{R}) et précision (\mathcal{P}) en % avant et après filtrage pour les actions *course*, *saut* et *chute* dans des sauts à la perche et des sauts en hauteur. La colonne de droite donne le gain apporté par le filtre.

PERCHE	avant		après		gain	
course	83.8	71.0	91.7	67.9	(+)7.90	(-)3.1
saut	40.2	94.7	78.4	95.3	(+)38.2	(+)0.6
chute	51.5	87.0	67.5	83.8	(+)16.0	(-)3.2
moyenne	63.4	77.3	82.3	77.0	(+) 18.9	(-) 0.3
HAUTEUR	avant		après		gain	
course	89.5	86.1	99.8	84.1	(+)10.3	(-)2.0
saut	80.1	79.7	84.2	79.0	(+)4.10	(-)0.7
chute	95.5	91.0	97.8	90.1	(+)2.30	(-)0.9
moyenne	88.2	85.6	95.8	84.0	(+)7.60	(-)1.6

5 Conclusion

Cet article propose un filtre temporel crédibiliste appliqué à la reconnaissance d'actions humaines dans les vidéos. Ce filtre, basé sur le Modèle de Croyances Transférables,

permet de lisser les croyances et de détecter les changements d'états de l'action considérée. La technique consiste à utiliser le conflit entre un modèle d'évolution des croyances et des mesures. Les mesures ont été obtenues par fusion de croyances issues de paramètres extrais des vidéos. L'utilisation d'une somme cumulée (CUCUM) du conflit permet d'éviter les changements d'états intempestifs.

Dans cette article, les actions ont été considérées indépendantes. Nous cherchons à présent à intégrer des relations de causalité entre les actions telles que rencontrées dans les réseaux évidentiels [10] et dans les réseaux de Petri crédibilistes [11]. L'objectif est la reconnaissance de séquences d'actions, aussi appelées activités.

Remerciements :

Ce travail est en partie soutenu par le réseau d'excellence SIMILAR. Nous remercions l'université de Crète pour les échanges de données.

Références

- [1] L. Wang, W. Hu, and T. Tan, "Recent developments in human motion analysis," *Pattern Recognition*, vol. 36, no. 3, pp. 585–601, 2003.
- [2] S. Hongeng, R. Nevatia, and F. Bremond, "Video-based event recognition and probabilistic recognition methods," *Computer Vision and Image Understanding*, vol. 96, pp. 129–162, 2004.
- [3] Y. Luo, T.D. Wu, and J.N. Hwang, "Object-based analysis and interpretation of human motion in sports video sequences by dynamic bayesian networks," *Computer Vision and Image Understanding*, vol. 92, pp. 196–216, 2003.
- [4] N.D. Freitas, E. Brochu, K. Barnard, P. Duygulu, and D. Forsyth, "Bayesian models for massive multimedia databases : a new frontier," in *7th Valencia Int. Meeting on Bayesian Statistics/2002 ISBA Int. Meeting*, 2002.

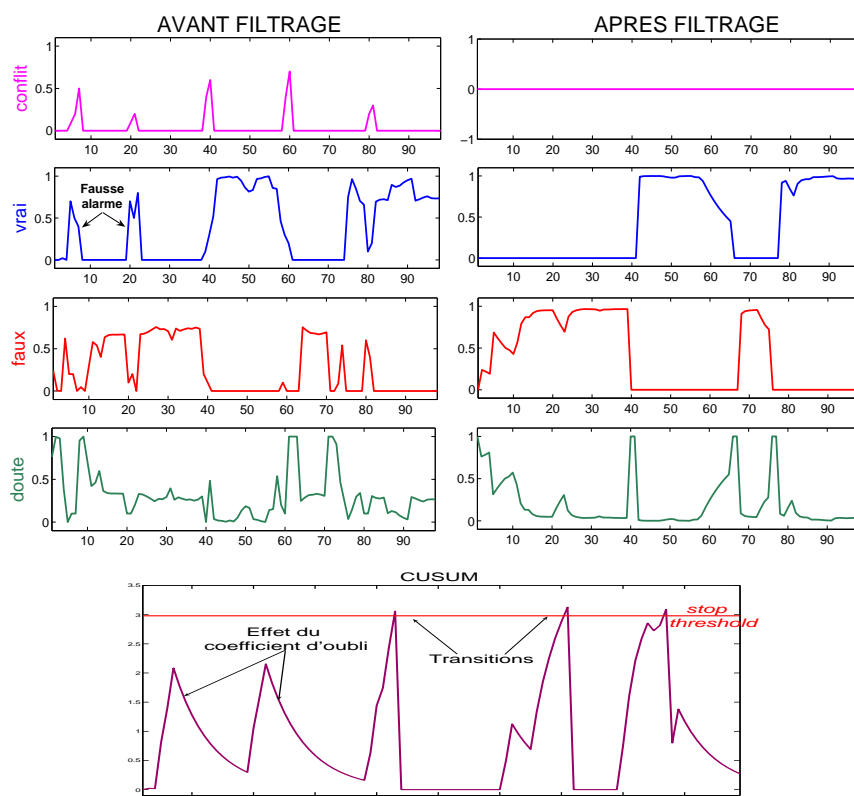


Figure 4 – Les croyances avant et après application du filtre temporel de croyances, et visualisation de la CUSUM pour une action *saut* dans un saut en hauteur.

- [5] G. Shafer, *A mathematical theory of evidence*, Princeton University Press, Princeton, NJ, 1976.
- [6] V. Girondel, A. Caplier, L. Bonnaud, and M. Rombaut, “Belief theory-based classifiers comparison for static human body postures recognition in video,” *Int. Jour. of Signal Processing*, vol. 2, no. 1, pp. 29–33, March 2005.
- [7] Z. Hammal, A. Caplier, and M. Rombaut, “Belief theory applied to facial expressions classification,” in *Int. Conf. on Advances in Pattern Recognition*, Bath, United Kingdom, August 2005.
- [8] E. Ramasso, D. Pellerin, C. Panagiotakis, M. Rombaut, G. Tziritas, and W. Lim, “Spatio-temporal information fusion for human action recognition in videos,” in *13th European Signal Processing Conf. (EUSIPCO)*, Antalya, Turkey, Sept. 2005.
- [9] P. Smets and R. Kennes, “The Transferable Belief Model,” *Artificial Intelligence*, vol. 66, no. 2, pp. 191–234, 1994.
- [10] H. Xu and P. Smets, “Evidential reasoning with conditionnal belief functions,” *Uncertainty in Artificial Intelligence*, vol. 94, pp. 598–606, 1994.
- [11] M. Rombaut, I. Jarkass, and T. Denoëux, “State recognition in discret dynamical systems using petri nets and evidence theory,” in *Europ. Conf. on Symbolic and Quantitative Approaches to Reasoning with Uncertainty*, 1999.
- [12] Z. Elouedi, K. Mellouli, and Ph. Smets, “Assessing sensor reliability for multisensor data fusion within the transferable belief model,” *IEEE Trans. Systems, Man and Cybernetics*, vol. 34, no. 1, pp. 782–787, 2004.
- [13] B. Ristic and P. Smets, “Target identification using belief functions and implication

rules,” *IEEE Trans. Aerospace and Electronic Systems*, vol. 41, no. 3, pp. 1097–1102, July 2005.