

## Problématique

- La distraction du conducteur constitue un facteur majeur d'accidents routiers.
- Les approches existantes reposent principalement sur la classification d'images isolées [1], sans prendre en compte la dynamique temporelle des vidéos.
- Elles détectent difficilement les comportements inattendus ou non définis à l'avance.
- Une approche basée sur la détection d'anomalies permet de mieux modéliser le comportement normal et d'identifier les déviations de manière plus fiable.

## Objectifs

Ce travail vise à détecter automatiquement les comportements anormaux du conducteur à partir de vidéos.

- Extraire des informations pertinentes à partir de la posture du conducteur [2]
- Modéliser le comportement normal et identifier les anomalies
- Évaluer la performance du système en termes de détection et de fausses alertes

## Méthodologie

La méthodologie proposée s'articule autour de trois axes principaux :

### 1. Extraction des caractéristiques de posture

- **Caractéristiques extraites :**
  - Les caractéristiques sont extraites à partir des squelettes générés par OpenPose sur chaque frame.
  - Le conducteur principal est sélectionné selon la confiance des points détectés et sa position dans l'image.
  - **Joints utilisés :** tête (nez, yeux, oreille), tronc (cou), bras (épaules, coudes, poignets) et hanches.

Type	Rôle
Angles ( $\theta_1 - \theta_{13}$ )	Posture (bras, tête, tronc)
Ratios ( $r_1 - r_8$ )	Positions relatives des membres

Tableau 1. Types et rôles de caractéristiques extraites

### •Prétraitement :

- Complétion des points manquants par interpolation temporelle et estimation géométrique (bras, hanches)
- Propagation des positions pour les séquences partiellement détectées
- Lissage temporel pour stabiliser les trajectoires et réduire le bruit
- Normalisation des données pour assurer une échelle homogène
- Réduction de dimension (PCA) pour améliorer la compacité et réduire le bruit

• **Agrégation temporelle :** Les caractéristiques calculées sur chaque image sont regroupées sur toute la séquence afin de capturer le comportement global du conducteur.

• **Données :** Les séquences vidéo sont construites à partir des images successives du dataset *StateFarm Distracted Driver*.

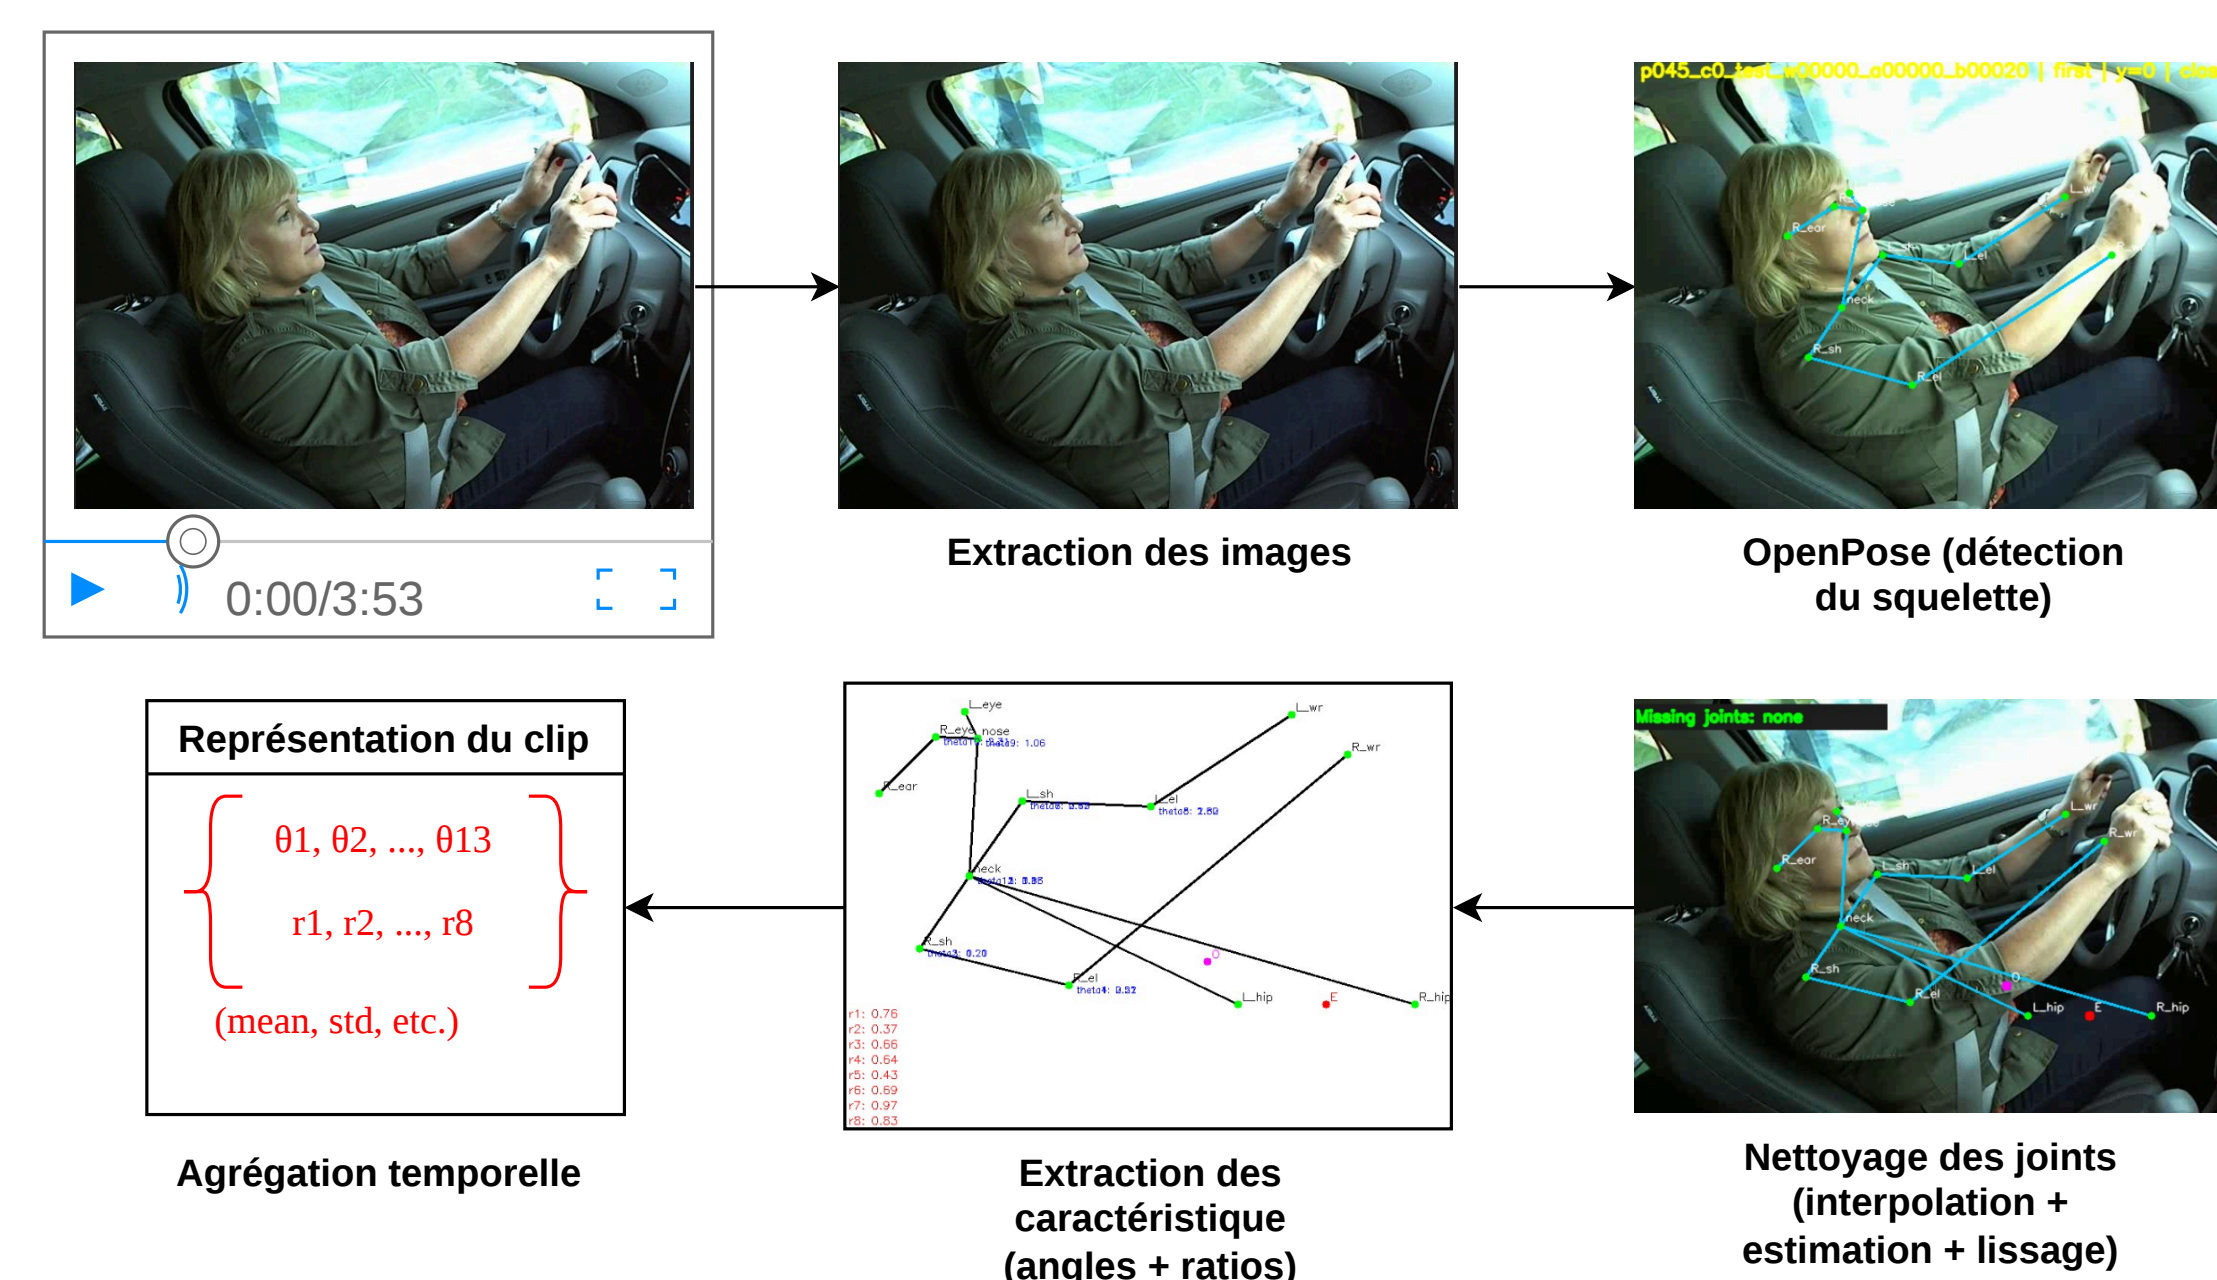


Figure 1. Pipeline d'extraction des caractéristiques basé sur la posture.

### 2. Évaluation des modèles

- Entraînement sur le comportement normal
- Évaluation basée sur la détection des anomalies

Modèle	Principe
Isolation Forest	Isolation des anomalies par partitions aléatoires
One-Class SVM	Apprentissage d'une frontière du comportement normal
LOF	Détection basée sur la densité locale
ECOD	Détection basée sur les valeurs extrêmes des caractéristiques

Tableau 2. Modèles de détection d'anomalies utilisés

• Combinaison des modèles par un système de vote (majoritaire ou basé sur les scores)

### 3. Comparaison avec d'autres méthodes d'extraction

• Comparaison de la méthodologie proposée avec des approches de référence :

- **HOG3D :** gradients spatio-temporels

- **CNN 3D :** caractéristiques apprises automatiquement
- Analyse de l'impact des différentes représentations sur la détection d'anomalies

## Résultats

Modèle	AUC	Acc	Prec	Recall	F1
OCSVM	0.84	0.95	0.88	<b>0.95</b>	<b>0.91</b>
IForest	0.84	0.95	0.87	0.95	0.88
LOF	<b>0.88</b>	0.82	0.82	0.96	0.82
ECOD	0.78	0.79	0.80	0.94	0.80

Tableau 3. Comparaison des performances des modèles de détection d'anomalies

LOF optimise le classement des anomalies (AUC), tandis que OCSVM offre le meilleur compromis global.

	OpenPose		CNN 3D		HOG3D	
	Préd. N	Préd. D	Préd. N	Préd. D	Préd. N	Préd. D
<b>Normal</b>	73.7%	26.3%	50.9%	49.1%	14.0%	86.0%
<b>Distrait</b>	8.8%	91.2%	4.4%	95.6%	0.0%	100%
<b>Métriques de performance</b>						
Préc. globale	89.2%		89.2%		87.7%	
<b>Délect. D</b>	91.2%		95.6%		<b>100%</b>	
<b>Délect. N</b>	<b>73.7%</b>		50.9%		14.0%	
<b>F1</b>	93.2%		<b>93.8%</b>		93.3%	

Tableau 4. Comparaison des performances selon les méthodes d'extraction de caractéristiques

Notre approche offre le meilleur compromis entre détection des anomalies et réduction des fausses alertes, contrairement à HOG3D, qui est très sensible mais peu sélectif.

## Conclusion

- La détection d'anomalies permet une meilleure modélisation du comportement du conducteur
- Notre stratégie offre le meilleur compromis entre détection et fausses alertes
- Les méthodes visuelles sont plus sensibles mais moins sélectives

## Références

- [1] Amal Ezzouhri, Zakaria Charouh, Mounir Ghogho, and Zouhair Guennoun. Robust deep learning-based driver distraction detection and classification. *IEEE Access*, 9 :168080–168092, 2021.
- [2] Shuang-Jian Jiao, Lin-Yao Liu, and Qian Liu. A hybrid deep learning model for recognizing actions of distracted drivers. *Sensors*, 21(21) :7424, 2021.