



HAL
open science

Estimation automatique du ressenti conducteur dans les ADAS

Fan Yang

► **To cite this version:**

Fan Yang. Estimation automatique du ressenti conducteur dans les ADAS. CNRIUT 2023 Saint Pierre - La Réunion, IUT de Saint Pierre, Jun 2023, Saint Pierre (La Réunion), La Réunion. hal-04326918

HAL Id: hal-04326918

<https://hal.science/hal-04326918>

Submitted on 6 Dec 2023

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

Estimation automatique du ressenti conducteur dans les ADAS

Houda Rafi¹ Yannick Benezeth^{1,2} Cédric Demonceaux^{1,3} Fan Yang^{1,2}
prénom.nom@u-bourgogne.fr

¹ Laboratoire Imagerie et Vision Artificielle, EA 7535

² IUT Dijon-Auxerre, Université de Bourgogne

³ IUT Le Creusot, Université de Bourgogne

Thèmes – *Informatique - Robotique - Imagerie - Électronique - Mathématiques*

Résumé – *Les aides à la conduite (ADAS en anglais : Advanced Driver-Assistance System) ne peuvent pas être développées indépendamment du ressenti du conducteur. Selon le profil de celui-ci (conducteur expérimenté ou novice, prudent ou sportif), des grandeurs objectives telles que les accélérations latérales et radiales, la loi de variation du freinage ou encore le contrôle sous virage, seront considérés comme acceptables ou intolérables. Les sensations de confort et de sécurité consistent à corrélérer ces grandeurs physiques de la conduite avec le ressenti subjectif du conducteur, selon son profil. Le ressenti conducteur peut être capturé et mesuré sous différents angles : mouvements faciaux, comportement des mains (pieds), signaux physiologiques comme la pression sanguine, ou la réaction électrodermale, etc. Dans cet article, nous proposons une nouvelle méthode d'apprentissage du SVM (Support Vector Machine) pour catégoriser automatiquement le niveau de stress des conducteurs en exploitant deux signaux physiologiques EDA (Electrodermal Activity) et IBI (Inter-Beat-Interval). Avec ce modèle personnalisé en intelligence artificielle, le profil du conducteur peut bien être pris en compte. Les résultats expérimentaux obtenus avec une base de données publique prouvent la supériorité de notre approche par rapport à l'état de l'art.*

Mots-Clés – *Estimation d'émotion, signaux physiologiques, apprentissage fédératif, classification automatique.*

1. Introduction

Le monitoring du stress des conducteurs est crucial pour connaître leur tolérance vis-à-vis d'une situation. La méthode classique consiste à collecter des réponses auto-rapportées aux questionnaires ; souvent biaisées pour de diverses raisons, la principale limitation de ces réponses est le manque d'objectivité [1]. Des études plus récentes analysent des caractéristiques extraites des signaux physiologiques comme la pulsation sanguine (BVP – Blood Volume Pulse en anglais), l'activité électrodermale, la respiration ou le rythme cardiaque et obtiennent des résultats performants pour l'estimation du niveau de stress [2]. Avec l'avancé des nouvelles technologies, nous pouvons capter ces signaux d'une manière continue, non-invasive et sans contact permettant ainsi d'estimer objectivement l'état de stress des conducteurs.

De nos jours, l'apprentissage automatique entraîné avec des exemples fait avancer grandement l'intelligence artificielle dans beaucoup de domaines. Le traditionnel paradigme du SVM (Support Vector Machine) maximise les performances de l'ensemble des échantillons de la base de données utilisée. Cette approche ne permet pas de différencier le traitement pour chaque individu dans l'estimation du ressenti, pourtant chaque conducteur possède sa propre manière d'exprimer son état émotionnel. Dans ce contexte, si l'on arrive à considérer simultanément le facteur commun et la variance des caractéristiques des signaux physiologiques de chaque profil, nous pouvons espérer améliorer les performances du monitoring [3].

Basée sur cette idée, nous avons proposé un nouvel algorithme d'apprentissage du SVM : *apprentissage fédératif*, permettant de réaliser d'abord des calculs décentralisés avec des sous-ensembles de données différents et ensuite combiner collaborativement tous les résultats pour la mise à jour des paramètres.

2. Conception d'un SVM personnalisé en utilisant l'apprentissage fédératif

La figure 1 illustre le processus d'apprentissage fédératif pour établir un modèle personnalisé. Pour ce schéma simplifié, nous avons les données de 3 conducteurs servant d'exemples d'apprentissage pour prédire le niveau de stress du conducteur ciblé. L'idée consiste à accentuer les caractéristiques proches de celles de la cible [4].

Pour chaque itération d'apprentissage, nous calculons la distribution de probabilités des caractéristiques pour l'ensemble des conducteurs de la base d'apprentissage et le conducteur cible. Ensuite, le coefficient Bhattacharya (BC_i en anglais) est utilisé pour mesurer la similarité entre l'exemple i et le conducteur cible de test t . Finalement la matrice de paramètres W de cette itération est mise à jour

à l'aide d'une fonction d'agrégation proportionnelle aux BC_i . Un modèle de SVM personnalisé pour le conducteur de test est ainsi créé à la fin de toutes les itérations d'apprentissage.

La base de données AffectiveRoad [5] a été utilisée pour tester et valider notre approche. Cette base a été collectée en enregistrant les données de 13 conducteurs dans des conditions réelles avec trois environnements différents : à l'arrêt, ville et autoroute. Chaque conducteur est équipé de 2 capteurs (une montre E4 et une ceinture Zephyr), permettant de capter plusieurs signaux physiologiques comme EDA, IBI, le rythme respiratoire et la température de la peau, *etc.* Le niveau de stress a été annoté avec une courbe continue entre 0 et 1. Pour notre étude, nous classifions 3 niveaux de stress : 0 pour la zone [0, 0.3] d'une courbe, 1 entre [0.3 et 0.7] et 2 correspondant à l'intervalle [0.7, 1].

Notre étude se focalise sur deux signaux physiologiques : EDA et IBI enregistrés par la montre E4. Après quelques pré-traitements pour éliminer les bruits d'acquisition, ils sont entrés dans des fenêtres temporelles glissantes de 1 min avec une superposition de 30s entre les deux fenêtres successives. Trois caractéristiques sont calculées à partir de l'EDA et les 10 autres sont obtenues à partir du IBI (voir le tableau 1).

3. Résultats expérimentaux

Nous avons utilisé un SVM linéaire pour estimer les 3 niveaux de stress. Le protocole LOOCV (Leave One Out Cross-Validation) est appliqué pour évaluer les performances de prédiction. C'est-à-dire, pour chaque modèle seul un conducteur est considéré comme cible de test et ses caractéristiques ne participent pas à l'apprentissage.

Les performances finales ont été calculées par la moyenne obtenue sur chaque individu. Cette performance correspond à la formule suivante :

$$BA(\%) = \frac{1}{2} \left(\frac{TP}{TP+FN} + \frac{TN}{FP+TN} \right)$$

Ici les TP, FP, TN et FN correspondent respectivement au pourcentage de vrais positifs, de faux positifs, de vrais négatifs et de faux négatifs.

Plusieurs expériences ont été réalisées avec deux méthodes d'apprentissage (classique et fédératif) sur les caractéristiques issues de l'EDA seule, du IBI seul et de la combinaison des deux. Les résultats montrés au tableau 2 illustrent l'efficacité de notre approche : une augmentation de 15% (de 52% à 67%) peut être observée en utilisant les caractéristiques IBI ou EDA+IBI. De même, la valeur de BA a aussi accru de 5% (de 53% à 58%) pour l'EDA.

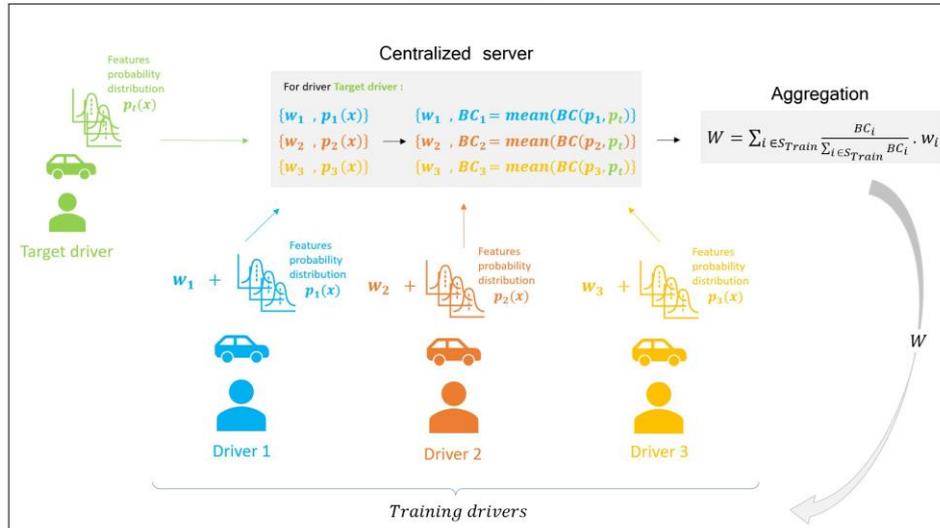


Figure 1 – Illustration du processus d’apprentissage fédératif.

EDA – L’activité électrodermale	La valeur maximale de la réponse de conductance cutanée (SCR), composante de l’EDA
	Nombre de pics dans la réponse de conductance cutanée (SCR)
	La somme des valeurs moyenne des deux composantes de l’EDA : la réponse de conductance cutanée (SCR) et le niveau de conductance de la peau (SCL)
IBI - Intervalle entre battements successifs	La valeur moyenne des intervalles RR (RR : le temps entre chaque battement cardiaque détecté)
	La valeur médiane des intervalles RR
	Ecart type des intervalles RR
	La racine carrée moyenne des différences d’intervalle RR successifs
	Le nombre d’intervalles RR successifs différant de plus de 50 ms (NN50)
	La valeur correspondante du NN50 en pourcentage.
	Le rapport du coefficient de variation de l’écart type des intervalles RR par rapport à l’intervalle RR moyen.
	La valeur maximale des IBIs
	La valeur minimale des IBIs
	L’écart type de l’IBIs

Table 1 – 13 Caractéristiques extraites de l’EDA et l’IBI.

	EDA + IBI	EDA	IBI
Apprentissage classique	52%	53%	52%
Apprentissage fédératif	67%	58%	67%

Table 2 – Comparaison des performances d’estimation.

4. Conclusion et perspectives

Dans cet article, nous proposons une chaîne de traitements pour prédire automatiquement le ressenti du conducteur dans les ADAS. Pour mieux prendre en compte le profil particulier de chaque conducteur, nous avons

conçu un nouvel algorithme d’apprentissage SVM : *apprentissage fédératif*. L’approche proposée a été testée et validée sur la base de données publique *AffectiveRoad*. Une augmentation de performance entre 5% et 15% a été constatée par rapport à l’apprentissage classique. Dans le futur, avant de valider cette approche pour résoudre d’autres problèmes d’informatique affective, nous allons d’abord effectuer plus d’expériences avec des précisions pour analyser les limites des modèles, ensuite nous souhaitons aussi tester la robustesse avec d’autres caractéristiques et des bases de données plus larges.

Remerciements

Les auteurs expriment leur gratitude à la société Renault pour le financement de la thèse CIFRE.

Références

- [1] Randall A Gordon, *Social desirability bias: A demonstration and technique for its reduction*, Teaching of Psychology, 14(1): 40–42, 1987.
- [2] Giorgos Giannakakis, Dimitris Grigoriadis, et al. , *Review on psychological stress detection using biosignals*, IEEE Transactions on Affective Computing, 13(1):440–460, 2022.
- [3] Sara Taylor, Natasha Jaques, Ehimwenma Nosakhare, Akane Sano, and Rosalind Picard, *Personalized multitask learning for predicting tomorrow’s mood, stress, and health*, IEEE Transactions on Affective Computing, 11(2):200–213, 2017.
- [4] Jakub Konečný, H Brendan McMahan, Felix X Yu, Peter Richtárik, Ananda Theertha Suresh, and Dave Bacon, *Federated learning: Strategies for improving communication efficiency*, arXiv preprint arXiv:1610.05492, 2016.
- [5] Neska El Haouij, Jean-Michel Poggi, Sylvie Sevestre-Ghalila, Raja Ghozi, and Mériem Jaïdane, *Affectiveroad system and database to assess driver’s attention*, In Proceedings of the 33rd Annual ACM Symposium on Applied Computing, pages 800–803, 2018.