

تحليل وتصنيف أسلوب القيادة باستخدام تقنيات التعرف على الأنماط

مؤيد احمد يحي خضيرى

بحث مقدم لنيل درجة الماجستير في علوم الحاسبات

إشراف

أ. د. ماهر علي خمائم

د. جبرائيل ابوسمرة

كلية الحاسبات وتقنية المعلومات

جامعة الملك عبد العزيز

جدة - المملكة العربية السعودية

١٤٤٢ هـ - ٢٠٢١ م

المخلص

يعتبر تحديد سلوك القيادة من المتطلبات الملحة في وقتنا الحالي في عدة جوانب. إحدى هي الجوانب هو مجال السلامة المرورية، حيث يُعد تجنب الحوادث المرورية من خلال اتخاذ الإجراءات التصحيحية ضد السلوكيات العدوانية لقيادة السيارات أمراً ضرورياً لحماية السائقين على الطريق. وجانب آخر من هذه الجوانب هي خدمات التأمين على السيارات، حيث يعد التمييز بين سلوكيات القيادة أمراً ضرورياً لاعتماد سياسات التأمين على أساس الاستخدام (UBI). وكذلك في خدمة مشاركة السيارات، حيث تعد مراقبة سلوكيات القيادة وتقييمها بشكل لحظي أمراً بالغ الأهمية لتقييم المخاطر وتحسين الخدمة. يقدم هذا البحث حلاً قائماً على التعلم العميق لتصنيف سلوك القيادة باستخدام نموذج Stacked-LSTM المحسن استناداً إلى إشارات أجهزة الاستشعار المدمجة بالهاتف الذكي وذلك بهدف تولد نموذجين مختلفين للتصنيف: التصنيف ثلاثي الفئات والتصنيف الثنائي. حيث يُميز التصنيف ثلاثي الفئات بين السلوكيات العادية، والنعاس، والعدواني وذلك بغرض دعم أنظمة مساعدة السائق المتقدمة (ADAS). في المقابل يُميز التصنيف الثنائي بين السلوكيات العدوانية وغير العدوانية وذلك بغرض دعم التطبيقات التجارية، مثل خدمات مشاركة السيارات وخدمات التأمين على السيارات القائمة على أساس الاستخدام (UBI). تم تقييم نماذج تصنيف السلاسل الزمنية الخاصة بنا على مجموعة بيانات UAH-DriveSet مفتوحة المصدر. حيث أدى استخدام الميزات المثلي لتصنيف سلوك القيادة، والعامل الأمثل لاختزال الإشارات الأولية، والحجم الأمثل لنافذة السلسلة الزمنية، على نموذج Stacked-LSTM المقترح إلى تحقيق زيادة كبيرة في درجة F1 عند تطبيقه على مجموعة البيانات المذكورة أعلاه. حيث إن النتائج المحققة هي 99.49% و 99.34% لنماذج التصنيف ثلاثي الفئات وثنائي الفئات، على التوالي. وبالمقارنة مع أحدث نموذج حقق أعلى درجة منشورة بنسبة 91% لتصنيف ثلاثي الفئات، فقد تجاوزه نموذجنا المقترح بنسبة 8.49% عند تطبيقها على مجموعة البيانات المذكورة أعلاه.

المستخلص

قدم هذا البحث نماذج متفوقة لتصنيف سلوك القيادة تتضمن مهمتين مختلفتين (التصنيف ثلاثي الفئات والتصنيف الثنائي) باستخدام بنية Staked-LSTM استناداً على إشارات أجهزة الاستشعار المدمجة بالهاتف الذكي والممثلة على هيئة نوافذ من السلاسل الزمنية. تُفرق مهمة التصنيف ثلاثي الفئات بين سلوكيات القيادة العادية، والنعاس، والعدوانية، بينما تُفرق مهمة التصنيف الثنائي بين السلوكيات العدوانية وغير العدوانية. أولاً، قمنا بتحسين المعلمات الهيكلية والتدريبية لنموذج Stacked-LSTM المقترح، والذي حقق درجة F1 بنسبة 95.26% وهي أعلى من أحدث درجة F1 تم الإبلاغ عنها وهي 91% بزيادة مقدرها 4.26%. بعد ذلك، استخدمنا ميزات إضافية (التسارع، وعجلة التسارع، وزاوية المسار، وتغيرات في زاوية المسار)، وقمنا بزيادة حجم الإشارات بمقدار ٥ مرات باستخدام تقنية استيفاء بيني خطي لزيادة معدل تمثيل العينات، وقمنا بتكوين حجم إطار أصغر (١٦ خطوة زمنية)، مما زاد من درجة F1 بمقدار 4.23%. أخيراً، تفوقت نماذجنا المُحسَّنة على أحدث مستوى من الدقة مع مجموعة بيانات UAH-DriveSet من خلال تحقيق درجة F1 بنسبة 99.49% و 99.34% للتصنيف ثلاثي الفئات والتصنيف ثنائي الفئات، على التوالي.

Analyzing and Categorizing Driving Style using Pattern Recognition Techniques

By
Moayed Ahmad Yahya Khodairy

A thesis submitted for the requirements of the degree of Master of Science in Computer
Science

Supervised By
Prof. Maher Ali Khemakhem
Dr. Gibrael Abosamra

Faculty of Computing and Information Technology
King Abdulaziz University
Jeddah-Saudi Arabia
1441 H –2020 G

Abstract

Driving behavior classification is an essential real-world requirement in different contexts. In traffic safety, avoiding traffic accidents by taking corrective actions against aggressive behaviors is necessary to protect drivers. Similarly, in the automotive insurance industry, distinguishing between driving behaviors is essential to adopt usage-based insurance (UBI) policies. Also, in the ridesharing industry, monitoring and evaluating driving behaviors is critical for risk assessment and service improvement. This research presents a deep learning-based solution for driving behavior classification using an optimized Stacked-LSTM model based on the signals of smartphone embedded sensors generating two different classification models: three-class and binary. Three-class classification distinguishes between normal, drowsy, and aggressive behaviors to support advanced driver-assistance systems (ADAS). Binary classification differentiates between aggressive and non-aggressive behaviors to support commercial applications, such as ridesharing services and automotive insurance services based on UBI. Our time-series classification models have been evaluated on the public UAH-DriveSet dataset. Using the proper number and type of features, the optimum factor of upsampling for the raw signals, and the optimum time-series window size, our proposed Stacked-LSTM model made a breakthrough in the F1-score when applied to the aforementioned dataset. The achieved scores are 99.49% and 99.34% for the three-class and binary classification models, respectively. Comparisons with state-of-the-art models, our three-class classification model surpassed the highest published F1-score of 91% by 8.49% when applied to the aforementioned dataset.

Conclusion

This research has presented superior models for driving behavior classification featuring two different tasks (three-class classification and binary classification) using a Staked-LSTM architecture based on smartphone embedded sensors' signals represented as time-series windows. The three-class classification task distinguished between normal, drowsy, and aggressive driving behaviors, while the binary classification task differentiated between aggressive and non-aggressive behaviors. First, we optimized the structural and training parameters of the proposed Stacked-LSTM model, which achieved an F1-score (95.26%), which is higher than the latest reported state-of-the-art F1-score (91%) by 4.26%. Next, we utilized extra features (acceleration, jerk, course angle, and course angle variations), upsampled the signals by a factor of five, and configured a smaller window size (16 timesteps), which increased the F1-score by an extra 4.23%. Finally, our optimized models have outperformed the state-of-the-art accuracy with the UAH-DriveSet dataset by achieving an F1-score of 99.49% and 99.34% for the three-class classification and the binary classification, respectively.