

الجمهورية العربية السورية
المعهد العالي للعلوم التطبيقية والتكنولوجيا
قسم النظم الالكترونية والميكانيكية

التعرف على نمط القيادة غير الآمن بالاستعانة بحساسات هاتف ذكي

اعداد:

نور دياب


دراسة أُعدَّت لنيل درجة الماجستير في التحكم والروبوتيك
اختصاص روبوتيك

اشراف:

د. عمر حمدون

د. آصف جعفر

Syrian Arab Republic
Higher Institute for Applied Sciences and Technology
Department of Electronic and Mechanical Systems



Unsafe Driving Identification Using Smart Phone Sensors

By:
Nour Diab

Submitted in Fulfillment of the Requirements
For Master's Degree in Control and Robotics
Specialty: **Robotics**

Under supervision of:

Dr. Assef Jafer

Dr. Omer Hamdon

المعهد العالي للعلوم التطبيقية والتكنولوجيا

Higher Institute for Applied Sciences and Technology

المعهد العالي للعلوم التطبيقية والتكنولوجيا مؤسسة حكومية للتعليم العالي أحدثت بموجب المرسوم التشريعي رقم 24/ لعام 1983، وذلك بهدف إعداد كوادر علمية متميزة من مهندسين وباحثين للإسهام الفاعل في عملية التطوير العلمي والتنمية في الجمهورية العربية السورية.

يمنح المعهد العالي درجة الإجازة في الهندسة في الاتصالات والمعلوماتية والنظم الإلكترونية والميكاترونيكس وعلوم وهندسة المواد وهندسة الطيران. يقبل المعهد العالي لدراسة هذه الاختصاصات شريحة منتقاة من المتفوقين في الشهادة الثانوية من الفرع العلمي. يتيح المعهد العالي أيضاً برامج ماجستير أكاديمي في نظم الاتصالات وفي التحكم والروبوتيك وفي نظم المعطيات الكبيرة ونظم المعلومات ودعم القرار وفي علوم وهندسة المواد وعلوم وهندسة البصريات. وأخيراً، يمنح المعهد العالي درجة الدكتوراه في الاتصالات والمعلوماتية ونظم التحكم والفيزياء التطبيقية. تُحدث في المعهد العالي اختصاصات جديدة بحسب متطلبات سوق العمل وتوجهات البحث والتطوير المحلية والعالمية.

إلى جانب النشاط التعليمي، يمارس المعهد العالي عبر جهود أطره وفعالياته العلمية المختلفة نشاطاً حثيثاً في البحث والتطوير، إذ ينفذ مشاريع ودراسات واستشارات متنوعة لصالح الجهات العامة والخاصة في القطر، كما يتعاون مع جهات خارج القطر في بعض المشاريع البحثية والتطويرية. يسعى المعهد أيضاً، عبر دورات تدريبية نظرية وعملية متاحة للقطاعين العام والخاص وللأفراد، إلى إفادة أوسع فئة من المهتمين من إكسابهم مهارات وأطره العلمية ومختبراته. واستكمالاً لدوره الرائد في مجال التعليم ونشر العلم، ينشر المعهد العالي كتباً علمية عالية المستوى من نتاج أطره، منها ما هو تدريسي يوافق المناهج في المعهد العالي ويفيد شريحة واسعة من الطلاب الجامعيين عموماً، ومنها ما هو علمي ثقافي. يتيح المعهد العالي بعضاً من منشوراته على موقعه على الشبكة، كما يتيح إمكانية الاطلاع على رسائل الماجستير والدكتوراه المنفذة في المعهد العالي وعلى بعض منشورات طلابه وأطره من المقالات العلمية.

المعهد العالي للعلوم التطبيقية والتكنولوجيا، الجمهورية العربية السورية، دمشق، ص.ب 31983

Higher Institute for Applied Sciences and Technology – HIAST

P. O. Box 31983, Damascus, Syrian Arab Republic

هاتف 00963115123819 - فاكس 00963115140761

بريد إلكتروني contact@hiast.edu.sy

موقع إلكتروني www.hiast.edu.sy

أهدي هذا العمل إلى أبي وأمي وإخوتي.

كلمة شكر

أتقدم بالشكر الجزيل إلى الدكتور آصف جعفر والدكتور عمر حمدون لإشرافهم المتميز.

نور دياب

الملخص

تعتبر أنظمة القيادة المساعدة من أكثر الأنظمة التي تلقى اهتماماً كبيراً في الآونة الأخيرة. وذلك لأهميتها في تقليل الحوادث المرورية وتنبيه السائقين إلى سلوكيات قيادة أفضل تؤدي بالنتيجة إلى ترشيد استهلاك الوقود. يتناول هذا البحث تطوير نظام كشف نمط القيادة غير الآمن (نمط قيادة خطير Aggressive). يعمل هذه النظام على هاتف ذكي الذي أضحي متوفراً بكثرة وبالتالي استخدامه لا يتطلب وجود عتاد إضافي أو أن تكون المركبة بمواصفات معينة قد لا تتوفر في كل المركبات. تم تطوير النموذج بحيث يستفيد من الحساسات المتواجدة في أي هاتف ذكي بمواصفات متوسطة ويعمل بالزمن الحقيقي حيث تم اختبار زمن التنفيذ على هاتف بنظام Android 5.1. تم تدريب النموذج المطور باستخدام مجموعة المعطيات الحقيقية UAH Driveset وحصلنا على دقة هي 98.3% في التعرف على نمطي قيادة الآمن والعدواني وزمن تنفيذ أقل من 70 ميلي ثانية، كما حصلنا على دقة 98.7% في التعرف على أنماط القيادة (الآمن – العدواني – حالة الإعياء). يعتبر هذا البحث الأول من نوعه في استخدام تقدير احتمال الصدم بالاعتماد على نموذج Dronet في كشف نمط القيادة الخطير.

Abstract

Advanced Driver-Assistance Systems ADAS is receiving lots of attention lately. This is because of its importance in reducing traffic accidents and alerting drivers to follow better driving behavior in a way that leads to better fuel consumption. The aim of this research is developing an Unsafe Driving Identification system. The developed system works on a smart phone, which has become widely available, and therefore its usage does not require the presence of additional equipment or having certain specifications that may not be available in all vehicles. The model has been developed to take advantage of the sensors found in any mid-range smartphone and work in real time as it was tested on a phone running Android 5.1. The developed model was trained using the real dataset UAH Driveset and we obtained an accuracy of 98.3% and execution time less than 70 milli seconds in identifying two driving classes (Normal – Aggressive) and obtained an accuracy of 98.7% in identifying three driving classes (Normal – Aggressive – Drowsy). This research is the first of its kind to use the collision probability estimation based on the Dronet model to detect dangerous driving style.

فهرس المحتويات

III الملخص
VI قائمة الأشكال
VII قائمة الجداول
VIII الاختصارات
IX مقدمة عامة
1 الفصل الأول
1 تعريف بالمسألة البحثية
1 1-1 تحليل أداء السائق DRIVER BEHAVIOR ANALYSIS DBA
6 1-2-2 دوافع البحث
6 1-3-1 المسألة البحثية
7 1-4-1 المساهمات البحثية
8 الفصل الثاني
8 الدراسات المرجعية
8 1-2 تحديد نمط القيادة DRIVING STYLE DETECTION
9 1-1-2 مصادر المعطيات المستخدمة في تحديد نمط القيادة
11 1-1-1-2 مجموعات المعطيات الحقيقية المستخدمة في الدراسات المرجعية الخاصة بتحديد نمط القيادة
12 2-3-2 المقاربات والخوارزميات المستخدمة في تحديد نمط القيادة
12 1-3-2 المقاربات المعتمدة على العتبة THRESHOLD METHODOLOGY
 2-3-2 المقاربات المعتمدة على تطابق النماذج PATTERN MATCHING
13 METHODOLOGY
14 2-3-3-2 المقاربات المعتمدة على المنطق العائم FUZZY LOGIC METHODOLOGY
 2-3-4-2 المقاربات المعتمدة على خوارزميات تعلم الآلة التقليدية CLASSICAL MACHINE
15 LEARNING METHODOLOGY

DEEP LEARNING 5-3-2 المقاربات المعتمدة على خوارزميات التعلم العميق

16	METHODOLOGY
23	الفصل الثالث
23	المقاربة المقترحة لكشف أنماط القيادة
23	1-3- المقاربة المستخدمة
27	2-3- مجموعة المعطيات الحقيقية UAH DRIVESET
28	1-2-3- تثبيت الهاتف وجمع المعطيات SETUP AND METHODOLOGY
29	2-2-3- مجموعة المعطيات الناتجة UAH DRIVESET
32	2-3- شعاع المعطيات المقترح
34	3-3- نموذج تقدير احتمال الصدم DRONET
36	4-3- إعداد المعطيات ومزامنتها
39	5-3- الخوارزمية المقترحة
43	الفصل الرابع
43	التنفيذ العملي والنتائج العملية
43	1-4- اعداد مجموعة المعطيات
45	2-4- المعيار F1-SCORE
45	3-4- النتائج العملية والتنفيذ العملي
55	الخاتمة
56	المراجع

قائمة الأشكال

- الشكل 1-1 أنواع أنظمة دراسة وتحليل سلوك السائق [1]..... 2
- الشكل 1-2 توضيح الفرق بين المطابقة الاقليدية والمطابقة باستخدام الخوارزمية DTW..... 14
- الشكل 2-2 مخطط خوارزمية Stacked LSTM..... 17
- الشكل 3-2 مخطط عام لشبكات RNN..... 17
- الشكل 4-2 مخطط الخلية من نمط LSTM..... 18
- الشكل 5-2 المعادلة الخاصة ببوابة الدخل Input Gate..... 18
- الشكل 6-2 المعادلة الخاصة ببوابة النسيان Forget Gate..... 18
- الشكل 7-2 المعادلة الخاصة ببوابة الخرج Output Gate..... 19
- الشكل 8-2 المعادلة الخاصة بحساب إشارة الحالة الداخلية للخلية..... 19
- الشكل 9-2 مخطط خلية من نمط GRU..... 20
- الشكل 10-2 مخطط البنية LSTM-FCN..... 22
- الشكل 1-3 مخطط النموذج المقترح..... 26
- الشكل 2-3 معلومات خاصة بالسائقين الذين قاموا بالرحلات الخاصة بمجموعة المعطيات UAH Driveset..... 28
- الشكل 3-3 توضع الهاتف الذكي الذي يقوم بجمع معطيات المركبة [44]..... 28
- الشكل 4-3 الواجهة الأمامية للبرنامج DriveSafe أثناء القيادة [44]..... 29
- الشكل 5-3 الطائرة ذاتية القيادة التي تم العمل عليها في تطوير النموذج DRONET..... 35
- الشكل 7-3 بنية النموذج DRONET [7]..... 35
- الشكل 8-3 مخطط إعداد المعطيات ومزامنتها..... 38
- الشكل 9-3 الشبكات Temporal Convolutional Network TCN..... 40
- الشكل 10-3 جداء التلاف السبي..... 40
- الشكل 11-3 البنية Stacked LSTM المقترحة..... 41
- الشكل 12-3 البنية Stacked GRU المقترحة..... 42
- الشكل 1-4 تقسيم المعطيات باستخدام نافذة منزلقة وبوجود تراكب..... 44
- الشكل 2-4 المعاملات المستخدمة في النموذج TCN المستخدم..... 46

قائمة الجداول

- الجدول 1-2 مجموعات المعطيات الحقيقية المستخدمة في تحليل أداء السائق 11
- الجدول 1-3 شعاع المعطيات المقترح 33
- الجدول 1-4 المعاملات المستخدمة في تدريب النموذجين Stacked GRU و Stacked LSTM 46
- الجدول 2-4 نتائج تدريب نموذج Stacked LSTM دون اعتبار احتمال الصدم 47
- الجدول 3-4 نتائج تدريب نموذج Stacked GRU دون اعتبار احتمال الصدم 47
- الجدول 4-4 نتائج تدريب نموذج Stacked LSTM مع اعتبار احتمال الصدم 47
- الجدول 5-4 نتائج تدريب نموذج Stacked GRU مع اعتبار احتمال الصدم 48
- الجدول 6-4 عدد المعاملات الخاص بكل نموذج 48
- الجدول 7-4 عدد النقاط في مجموعة المعطيات من أجل نافذة زمنية متغيرة (الخاصة بالتدريب) 49
- الجدول 8-4 مقارنة مع الدراسات السابقة في حالة كشف نمطي قيادة 50
- الجدول 9-4 المعاملات المستخدمة في تدريب النموذج Stacked GRU 50
- الجدول 10-4 نتائج تدريب النموذج Stacked GRU بدون اعتبار تقدير الصدم 51
- الجدول 11-4 نتائج تدريب النموذج Stacked GRU مع اعتبار تقدير الصدم 51
- الجدول 12-4 عدد النقاط في مجموعة المعطيات عند تغيير طول النافذة الزمنية 52
- الجدول 13-4 مقارنة نتائج النموذج المستخدم مع نتائج الدراسات السابقة في حالة كشف 3 أنماط **Error!**

Bookmark not defined.

الاختصارات

المصطلح	English	عربي
ADAS	Advanced Driver-Assistance System	نظام متقدم مساعد للقيادة
DBA	Driver Behaviour Analysis	تحليل سلوك السائق أثناء القيادة
SVM	Support Vector Machine	خوارزمية تصنيف تهدف إلى الحصول على أفضل مستوى فاصل بين الأصناف
LSTM	Long Short-Term Memory	خوارزمية عودية تتعامل مع المعطيات ذات الترابط الزمني
GRU	Gated Recurrent Unit	خوارزمية عودية تتعامل مع المعطيات ذات الترابط الزمني (أبسط من LSTM)
DWT	Dynamic Warping Time	خوارزمية لمطابقة سلسلتين من المعطيات على طول المحور الزمني
LSTM-FCN	Long Short-Term Memory – Fully Convolutional Network	خوارزمية هجينة من خوارزمية LSTM وخوارزمية FCN
TCN	Temporal Convolutional Network	الشبكات العصبونية الالتفافية الزمنية

مقدمة عامة

أحد أهم العوامل المؤثرة في تعزيز السلامة الطرقية وتقليل الحوادث المرورية هو السلوك المنضبط للسائقين. تُعرّف أساليب القيادة على أنها مجموعة الإجراءات والمنهجيات التي يقود بها السائقون مركباتهم، والتي تتأثر بشدة بالعادات والخبرات التراكمية التي يكتسبونها مع الوقت. سلوكيات القيادة المتهورة هي مجموعة الأحداث غير الآمنة على الطرقات مثل السرعات غير الطبيعية، التغير المفاجئ بين المسارات على الطرقات السريعة، التسارع والتباطؤ القاسي. تعد سلوكيات القيادة المتهورة السبب الرئيسي للعدد الأكبر من الحوادث المرورية والتي تقود غالباً إلى العديد من حالات الوفاة، الإصابات الخطيرة، والخسائر الفادحة في الممتلكات. إذ تقدر منظمة الصحة العالمية WHO أنه حوالي 1.3 مليون شخص يتوفى نتيجة الحوادث المرورية سنوياً، مع ما يقارب من 20 مليون إصابة خطيرة.

يعد تصنيف سلوكيات القيادة مطلباً أساسياً في بيئة العمل الحقيقية ويندرج تحت العديد من السياقات ويخدم مختلف القطاعات. ففي مجال السلامة المرورية، يعد تجنب الحوادث من خلال اتخاذ إجراءات تصحيحية ضد السلوكيات العدوانية أمراً بالغ الأهمية لحماية السائقين والمركبات والمارة. وكذلك في صناعة تأمين السيارات يعد التمييز بين سلوكيات القيادة المختلفة أمراً ضرورياً لاعتماد سياسات التأمين على أساس الاستخدام Usage Based Insurance UBI. وفي صناعة النقل التشاركي، تعد مراقبة سلوكيات القيادة وتقييمها أمراً حيوياً في عملية تقييم المخاطر والتحسين المستمر للخدمات.

يعرض مشروعنا البحثي نموذجاً لكشف نمط القيادة غير الآمن بالاعتماد على خوارزميات التعلم العميق. يعمل النموذج المطور على هاتف ذكي ويستفيد من الحساسات المتوفرة ضمنه في تسجيل معطيات، كما يستفيد النموذج من القدرات الحسابية للهاتف دون الاعتماد على الاتصال بأي خدمة خارجية يتم ضمانها التنفيذ العملي للنموذج لحساب النتيجة النهائية. أي أن النموذج المطور يعمل ضمن معالج هاتف ذكي بالزمن الحقيقي.

تم تدريب النموذج المطور باستخدام مجموعة المعطيات الحقيقية UAH-DriveSet. وحصلنا على دقة باستخدام المعيار F1-score هي 98.3%. اعتمدنا على النموذج Dronet في حساب تقدير الصدم من المنظر الأمامي للمركبة الذي تلتقطه الكاميرا الخلفية للهاتف واستخدام هذه القيمة كسمة ضمن شعاع الدخل للنموذج المطور. يستعيض تقدير احتمال الصدم للمركبة من المنظر الأمامي عن مجموعة من السمات التي يمكن حسابها منها حساب عدد المركبات الظاهرة في المنظر الأمامي وحساب المسافة عن أقرب مركبة وحساب زمن الاصطدام بأقرب مركبة والكشف عن وجود أشخاص قريبين من المركبة وغيرها من السمات التي يمكن أن تفيد في تقييم نمط القيادة المتبع.

يعرض الفصل الأول تعريفاً بالدراسات الخاصة بتحليل أداء السائقين Driver Behavior Analysis ويعرض تعريفاً بمشكلة البحث والمساهمات البحثية. بينما يتناول الفصل الثاني دراسة مرجعية لطرق الكشف عن أنماط القيادة. يعرض الفصل الثالث والرابع المقارنة المقترحة والتنفيذ العملي وأخيراً الخاتمة.

الفصل الأول

تعريف بالمسألة البحثية

نعرض في هذا الفصل مقدمة تعريفية عن أشهر الدراسات المتخصصة بتحليل سلوك السائقين أثناء القيادة، ثم نقدم تعريف بمسألتنا البحثية وتوصيف الهدف الأساسي من هذا المشروع.

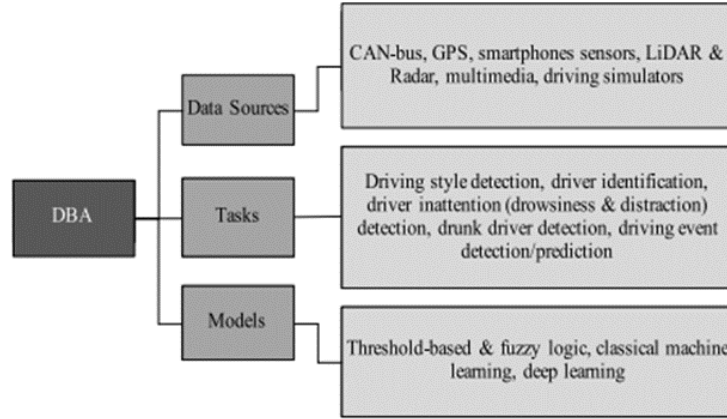
1-1- تحليل أداء السائق Driver Behavior Analysis DBA

يشمل مصطلح سلوك السائق أثناء القيادة Driving Behavior مجموعة القرارات التي يتخذها السائق أثناء القيادة ومنهجيته في التعامل مع المركبة والتحكم بها في مختلف الظروف والبيئات. ويعبر مصطلح تحليل سلوك السائق Driver Behavior Analysis (DBA) عن توصيف سلوك السائق أثناء القيادة لتحقيق هدف معين مثل تحديد فيما إذا كانت طريقة القيادة آمنة أو غير آمنة [1].

في الآونة الأخيرة، حاز مجال تحليل سلوك السائقين ودراسة أدائهم الكثير من الاهتمام في القطاعين البحثي والصناعي لما له من أهمية كبرى في تطوير تطبيقات القيادة المساعدة المتقدمة Advanced Driver-Assistance Systems ADAS والمركبات المؤتمتة Automated Vehicles وأنظمة النقل الذكي Intelligent Transportation Systems وإدارة استهلاك المركبة للطاقة Vehicle Energy Management والسلامة المرورية Traffic Safety وغيرها من المجالات الحيوية الأخرى [1].

يمكن تصنيف أنظمة تحليل ودراسة أداء السائقين وفقاً لعدة عوامل منها [1] - الشكل 1-1:

- نوع الحساسات المستخدمة (مصدر المعطيات التي يتم تحليلها عند دراسة أداء السائق).
- الأهداف والمهام التي تعنى بها تلك الدراسة.
- التقنيات المستخدمة في تحقيق هذا الهدف.



الشكل 1-1 أنواع أنظمة دراسة وتحليل سلوك السائق [1].

سنعرض لاحقاً توصيفاً مختصراً للدراسات الخاصة بسلوك السائق من حيث تعدد الحساسات المستخدمة وتنوع الأهداف التي تخدمها هذه الدراسات، بالإضافة إلى أهم الخوارزميات والنماذج المستخدمة.

1-1-1- مصادر المعطيات المستخدمة في دراسة أداء السائق Data Sources

من غير الممكن تطوير أنظمة متقدمة تدرس سلوك السائقين لخدمة هدف معين دون توفر معطيات كافية وموثوقة. يمكن الحصول على تلك المعطيات من عدة مصادر مختلفة، مثل:

- إجراء استبيانات وإعداد تقارير تحليلية يذكر من خلالها السائقين نتائج خبراتهم وتقييمهم لسلوكهم أثناء القيادة.
- جمع معلومات المتعلقة بالحوادث المرورية وتحليلها.
- استخدام برمجيات خاصة (محاكيات) بهدف إجراء محاكاة للسيناريوهات المتنوعة المتعلقة بسلوكيات القيادة.
- استخدام معطيات حقيقية يتم جمعها من حساسات موزعة ضمن المركبات خلال عدة رحلات وتحت ظروف مختلفة بما يخدم الهدف البحثي. تسمى الدراسات البحثية التي تعتمد هذا النوع من المعطيات بالدراسات المعتمدة على معطيات حقيقية Naturalistic Driving Studies [2]. يعتبر هذا النوع من الدراسات الأفضل من حيث شمولية الحالات التي يمكن تحليلها. ومقارنةً بالدراسات المعتمدة على بيانات المحاكيات، يعتبر هذا النوع من الدراسات أكثر دقة نتيجةً لكون السائقين يعمدون إلى اتباع سلوكيات أفضل عند استخدام المحاكيات مقارنة بسلوكياتهم الحقيقية أثناء القيادة على أرض الواقع [3]. مصادر المعطيات الحقيقية في المركبات إما أن تكون حساسات خارجية External Sensors أو حساسات موجودة ضمن المركبة In-Vehicle Sensors. نذكر فيما يلي أهم هذه المصادر:

○ مسرى شبكة Can-bus

تعتبر من أكثر المصادر استخداماً في مجال دراسة سلوك السائق DBA. تم تطويرها ووضعها في الخدمة في منتصف 1980s من قبل Robert Bosch GmbH بهدف خفض تعقيد الاتصال بين الحساسات ووحدة التحكم الإلكترونية Electronic Control Unit في المركبات [22]. يوجد عدة دراسات اعتمدت بشكل أساسي على قراءات مسرى Cab-bus كما في [15]-[21].

○ جهاز تحديد المواقع GPS

يؤمن حساس تحديد الموضع قياسات غير مباشرة للسرعة والتسارع، وهي من السمات التي تعتمد عليها بكثرة أنظمة التعرف على سلوك السائق DBA. كما أنه تتوفر حساسات تحديد الموضع في العديد من الأنظمة المستخدمة وضمن معظم الهواتف الذكية واسعة الانتشار والتي تتواجد في كل مكان حالياً، إذ تكاد لا تخلو مركبة من تواجدها هاتف ذكي واحد فيها على الأقل. تعتمد بعض الدراسات التي أجريت سابقاً بشكل أساسي على المعطيات التي يوفرها جهاز تحديد الموقع مثل [23]-[25] والبعض الآخر يستخدم معطيات حساس الموضع مع وجود معطيات أخرى مساعدة مثل قراءات حساس التسارع.

○ الهواتف الذكية Smartphones

تحتوي الهواتف الذكية العديد من الحساسات مثل حساس تحديد الموقع GPS، حساسات Gyroscope، حساس التسارع Accelerometer والعديد من الحساسات الأخرى. لذلك يعتبرها الباحثون مصدراً ثرياً للمعطيات التي يمكن جمعها وتحليلها بما يخدم مختلف الأبحاث ومنها الأبحاث الخاصة بتحليل سلوك السائقين DBA. يحتوي المرجعان [13] و [14] عرضاً لمعظم أبحاث DBA التي تعتمد بشكل أساسي على الهواتف الذكية كمصدر للمعطيات.

○ الوسائط المتعددة Multimedia Data

يمكن باستخدام كاميرا أمامية ضمن المركبة التقاط صور للطريق واستخدامها في الكشف عن خطوط الطريق Lane Detection التي تعتمد عليها كثير من أبحاث تحليل القيادة مثل كشف المناورات Maneuver Detection والتعرف على القيادة غير الآمنة Unsafe Driving Identification.

○ Radar & LiDAR

تعد من أهم الحساسات المستخدمة في السيارات المؤتمتة Automated Vehicles وتعتمدها بعض دراسات تحليل القيادة في تصنيف طرق الانعطاف مثلاً Turning Behavior Classification [26].

1-1-2- برمجيات محاكاة القيادة Driving Simulators

تعتبر من مصادر المعطيات الهامة المستخدمة في تطوير أنظمة تحليل قيادة السائقين DBA. يعتمد الباحثون إلى جمع المعطيات باستخدام برمجيات المحاكاة لعدة أسباب منها عدم توفر مجموعات معطيات بالشكل الذي يخدم أبحاثهم وأن بعض مهمات تحليل القيادة مثل كشف تعاطي السائق للكحول Drunk Driving Detection تحتاج إلى جمع المعطيات ضمن بيئة متحكم بها Controlled Environment. وعلى الرغم من إمكانية دراسة سيناريوهات متنوعة للقيادة باستخدام المحاكاة إلا أنه لا يستطيع تمثيل الحالة الحقيقية بشكل كامل وما يجري تماماً في بيئة القيادة الواقعية [1].

اعتمدنا في هذا البحث على إحدى مجموعات المعطيات الحقيقية UAH-DriveSet وسندرس لاحقاً في فصل الدراسات المرجعية بشكل مفصل مجموعات المعطيات المستخدمة في الدراسات المعتمدة على معطيات حقيقية Naturalistic Driving Studies NDS.

تعتمد الكثير من الأبحاث الخاصة بدراسة سلوك السائق إلى استخدام عدة مصادر للمعطيات Data Fusion وهذا يضيف تعقيداً إلى المسألة، حيث أن شكل المعطيات يختلف من حساس إلى آخر، يمكن أن تكون هذه المعطيات structured أو semi-structured أو unstructured مما يتطلب جهداً في عملية إعداد المعطيات. إلا أن هذا التعقيد الإضافي يتيح معلومات هامة وحيوية عن حالة المركبة والسائق وفي كثير من الأحيان البيئة المحيطة، كما أنه يمكن من الحصول على نموذج نهائي بدقة أكبر ونتائج أفضل.

1-1-3- مهام تحليل سلوك السائق Driver Behavior Analysis Tasks

يمكن حصر المهام المباشرة في دراسة سلوك وأداء السائقين في خمس مهمات أساسية وهي:

- التعرف على السائق Driver Identification or Driver Fingerprinting
وتهدف الأنظمة هنا إلى تمييز هوية السائق من خلال دراسة سلوكه أثناء القيادة وباستخدام مصادر المعطيات المتنوعة التي ذكرناها سابقاً. نذكر على سبيل المثال من الأبحاث التي تخدم هذا الهدف ما تم إنجازه في [25] حيث تم الاعتماد على حساس تحديد موقع GPS في الهاتف الذكي للتعرف على السائقين. وفي [27] جرى العمل على تصنيف السائقين باستخدام حساس التسارع. في [28] أثبت أن تسجيل المعطيات الخاصة بانعطاف واحد ومن خلال النموذج الذي تم تطويره يمكن كشف هوية السائق بشكلٍ كافٍ.
- كشف عدم انتباه السائق Driver Inattention Detection
تتطلب القيادة حداً معيناً من التركيز والانتباه وإلا تصبح المركبة عرضة للحوادث. يعمل العديد من الباحثين على تطوير أنظمة تتمكن من الكشف المبكر عن تشتت انتباه السائق بهدف إطلاق الإنذارات التحذيرية الضرورية تلافياً

لوقوع الحوادث المرورية. يمكن أن يكون ضعف الانتباه لدى السائق ناجماً عن التشتت distraction أو الإرهاق fatigue. ويتولد عنه سلوكيات قيادة محددة مثل تغيير مفاجئ في زاوية المقود steering wheel angle أو تغيير مفاجئ في سرعة وتسارع المركبة. ومنه خلصت الدراسات [29] [30] [31] إلى أن السرعة والتسارع وزاوية المقود هي معطيات يمكن الاعتماد عليها بشكل أساسي في كشف ضعف انتباه السائق.

• التعرف على نمط القيادة Driver Style Identification

كشف نمط القيادة للسائق ضمن مجموعة محددة من الأنماط المعروفة مسبقاً، يمكن أن تكون هذه المجموعة مثلاً (قيادة آمنة، قيادة غير آمنة بمستوى منخفض، قيادة غير آمنة بمستوى عالٍ). هدف البحث الحالي هو تحديد نمط القيادة لذا سيتم دراسة هذا النوع بتفصيل أكبر ضمن فصل الدراسة المرجعية.

• كشف تعاطي السائق للكحول Drunk Driver Detection

عندما تزداد نسبة الكحول في دم السائق عن الحد 0.08 g/deciliter تصبح قدرته على قيادة المركبة شبه معدومة بسبب تأثير الكحول على قدراته العقلية وعلى زمن استجابته عند حدوث أي طارئ مما يجعله عرضة لحوادث مميتة. لذا تعمل العديد من الدراسات على تطوير أنظمة قادرة على كشف تعاطي السائق للكحول بشكل مبكر. هناك طريقتين للكشف: طريقة مباشرة وطريقة غير مباشرة. نعني بالطريقة المباشرة استخدام حساسات توضع على تماس مع السائق لتتمكن من تقدير نسبة الكحول في الدم. والطريقة غير المباشرة تكون من خلال تحليل سلوك السائق أثناء القيادة DBA. من الأبحاث التي عملت ضمن هذا المجال البحث [32] حيث أظهر أن القيادة تحت تأثير الكحول يمكن كشفها من خلال دراسة تغير الموقع الجانبي للمركبة أثناء القيادة ومجال هذا التغير lateral vehicle position range وكذلك من خلال دراسة مجال تغير زاوية المقود steering wheel angle range. عند استخدام هذه السمات كدخل لخوارزمية SVM تمكن من الحصول على نموذج تصنيف ثنائي (قيادة طبيعية، قيادة تحت تأثير الكحول).

• كشف أحداث القيادة والتنبؤ بها Driving Events Detection and Prediction

التعرف على أحداث القيادة على مستوى منخفض low level driving events مثل كشف الانعطاف يمين/يسار left/right turns، انعطاف كامل U-turns، تغيير المسار lane change إلى اليمين أو اليسار، التسارع والفرملة acceleration and braking وغيرها من الأحداث الجزئية التي يمكن أن تحدث أثناء القيادة. يستخدم كشف أحداث القيادة بشكل واسع ضمن تطبيقات عملية تتعلق بالمركبات المؤتمتة ومراقبة السائقين بما يخدم شركات التأمين. كما يمكن أن يوضع كأحد المراحل الأولية للتعرف على نمط القيادة driving style detection. من الأبحاث التي عملت على التنبؤ بأحداث القيادة [33] حيث تمكنوا عبر استخدام عدة سمات منها السرعة والتسارع وزاوية Yaw

وسمات محيطية تتعلق بنوع الطريق من التنبؤ بتغيير مسار المركبة left/right lane change بمدة قدرها 5 ثواني قبل وقوع هذا الحدث وبدقة وصلت إلى 96%.

4-1-1- نماذج وخوارزميات تحليل سلوك السائق Driver Behavior Analysis Models and Algorithms

الخوارزميات المستخدمة هي:

- خوارزميات تعتمد على العتبات والمطابقة والمنطق العائم Threshold-Based, Pattern Matching and Fuzzy Logic Algorithms
- خوارزميات تعلم الآلة التقليدية Classical Machine Learning Algorithms
- خوارزميات التعلم العميق Deep Learning Algorithms

سنعرض لاحقاً في فصل الدراسة المرجعية تفصيلاً لهذه الخوارزميات ومقارنةً بينها من حيث التعقيد والدقة.

2-1- دوافع البحث

تعدّ مواضيع تحليل قيادة السائق بكامل أنواعها من المواضيع البحثية الهامة والتي يتم التطرق إليها بكثرة في الآونة الأخيرة لما لها من أثر في تعزيز السلامة الطرقية وتجنب التكاليف غير الضرورية الناجمة عن الحوادث المتكررة. يتم التركيز بشكل خاص على استخدام معطيات حقيقية Naturalistic Driving Studies NDS في عمليات التحليل والتدريب بهدف الحصول على أنظمة تعمل بدقة أفضل على أرض الواقع.

من الأنظمة الرائجة بكثرة حالياً تلك التي تعتمد الهواتف الذكية. تستفيد هذه الأنظمة من الهاتف الذكي كونه يعتبر حاسباً صغيراً يتضمن مجموعة من الحساسات قادرة على جمع كم هائل من المعطيات عند تثبيته في المركبة، والتي يمكن أن تستخدم بشكل كافٍ في تحليل ودراسة طريقة القيادة.

3-1- المسألة البحثية

- إجراء دراسة بحثية عامة عن نظم تحليل أساليب القيادة وسلوك السائقين والتعرف على أهم الطرق والخوارزميات المستخدمة في هذا المجال.

- تطوير نظام عملي يتعرف على أسلوب قيادة السائق وقادر على تصنيفها كقيادة آمنة أو غير آمنة. استخدام مجموعة حساسات في هذا النظام العملي بحيث تتمكن من الحصول على توصيف كافي لحالة القيادة وتتمكن من تصنيفها كطريقة آمنة أو غير آمنة.
- تعتبر خوارزميات تعلم الآلة والتعلم العميق من أفضل الخوارزميات المستخدمة حالياً في مسائل التصنيف ومسائل تحليل المعطيات المترابطة زمنياً (مراقبة المعطيات ضمن نافذة زمنية). لذا يجب إيجاد الخوارزميات المثلى لمسألة تصنيف طريقة القيادة وإيجاد الشكل الأمثل لدخول هذه الخوارزمية (سلسلة زمنية من قيم الحساسات أو استخدام سمات احصائية).
- استخدام خوارزميات تعلم الآلة والتعلم العميق تتطلب وجود مجموعة معطيات شاملة ومتوازنة لذا يجب البحث عن معطيات حقيقية متاحة لتدريب نموذج تعلم عميق. دراسة المعطيات المتاحة واختيار الأفضل.
- يجب أن يكون النظام النهائي قابلاً للتنفيذ بشكل عملي ويعمل بالزمن الحقيقي على جهاز يحوي حاسب صغيري يمكن تثبيته ضمن المركبة.

1-4- المساهمات البحثية

حصلنا على النتائج التالية:

- دراسة الأبحاث المتعلقة بكشف طريقة القيادة Driver Style Detection ومجموعات المعطيات الحقيقية المتوفرة التي يمكن اعتمادها في دراستنا.
- تم اختيار مجموعة المعطيات الحقيقية UAH- DriveSet وإعدادها للاستخدام في تطوير نموذج التعرف على القيادة.
- تم تطوير نموذج يعتمد على خوارزميات السلاسل زمنية Stacked GRU ودخله هو معطيات عدة حساسات ضمن نافذة زمنية منزلقة بطول 4 ثواني يتعرف على طريقة القيادة بدقة 98.3% و 98.7% من أجل 3 أصناف وبطول نافذة زمنية 1 ثانية.
- النموذج المطور يعمل على هاتف ذكي وبالزمن الحقيقي.

الفصل الثاني

الدراسات المرجعية

تتناول في هذا الفصل أهم الدراسات المرجعية التي تتحدث عن التعرف على أسلوب القيادة *Driving Style Identification* من حيث المعطيات والمقاربات المستخدمة.

2-1- تحديد نمط القيادة Driving Style Detection

يشمل مصطلح سلوك السائق أثناء القيادة Driving Behavior مجموعة القرارات التي يتخذها السائق أثناء القيادة ومنهجيته في التعامل مع المركبة والتحكم بها في مختلف الظروف والبيئات. ويعبر مصطلح تحليل سلوك السائق Driver Behavior Analysis DBA عن توصيف سلوك السائق أثناء القيادة لتحقيق هدف معين مثل تحديد فيما إذا كانت طريقة القيادة آمنة أو غير آمنة [1].

نمط القيادة هو النمط الذي يتبعه السائق في التحكم بالمركبة بوجود مجموعة من العوامل الخارجية المؤثرة مثل مواصفات الطريق والحالة المرورية وحالة الطقس. يمكن تحديد مجموعة أنماط مخصصة بحيث نصنف نمط القيادة ضمن هذه الأنماط المحددة مثل نمط قيادة آمن safe driving، نمط قيادة خطير dangerous driving، نمط قيادة باستهلاك منخفض للوقود eco-friendly driving، وغيرها من الأنماط المخصصة التي يمكن أن تُوصف وتُبنى الدراسة على أساس هذا التوصيف.

تأتي أهمية أنظمة تحديد نمط القيادة من عدة أمور هي:

- يعد كشف أنماط القيادة التي توصف على أنها خطيرة بشكل مبكر إلى منع وقوع الحوادث المرورية التي يمكن أن تؤدي بحياة الأشخاص المتواجدين في المركبة والمتواجدين في الطرق.
- يمكن أن يساعد تنبيه السائقين لنمط القيادة الحالي في تحسين أدائهم.
- تعد المركبات أحد أهم العوامل في زيادة انبعاثات ثاني أكسيد الكربون CO₂، لذا تساهم الأنظمة التي تكشف القيادة الرعناء reckless driving مع اتخاذ التدابير المناسبة في تخفيف من هذه الانبعاثات. تعرض إحدى الدراسات نسبة الوقود التي تم توفيرها عند كشف نمطي القيادة aggressive & moderate وهي 7% و5% على الترتيب [35].

الأبحاث المرجعية التي تدرس طرق تحديد نمط القيادة في ازدياد مستمر، تعود أولى هذه الدراسات إلى العام 1997 [34] حيث تم اقتراح نموذج يعتمد على المنطق العائم لتصنيف نمط القيادة للسائق إما اقتصادي economic أو غير اقتصادي sportive. [1] نعرض في هذا الفصل الخطوط العامة لهذه الدراسات من حيث مصادر المعطيات والمقاربات المستخدمة.

2-1-1- مصادر المعطيات المستخدمة في تحديد نمط القيادة

يتم اختيار مصادر المعطيات في أنظمة تحديد نمط القيادة بناءً على توافرها في المركبة ومدى ارتباطها بتعريف الأنماط المطلوبة، كما ذكرنا سابقاً في الفصل السابق أن مصادر المعطيات في المركبة التي تستفيد منها أنظمة تحليل أسلوب القيادة والتي يعد كشف نمط القيادة أحد فروعها هي:

- مسرى شبكة Can-Bus (شبكة من الحساسات الداخلية في المركبة)
- حساس تحديد الموقع GPS (حساس خارجي)
- الحساسات الموجودة ضمن الهواتف الذكية (حساسات خارجية)
- الوسائط المتعددة مثل صور وفيديوهات تلتقط من كاميرات مثبتة ضمن المركبة (حساسات خارجية - تستخدم بعض الأنظمة لاقط صوت Mic)
- حساسات رادار ولايدر RADAR & LIDAR (حساسات خارجية - داخلية في بعض المركبات)
- برامج محاكاة القيادة Driving Simulators

تعتمد المقاربة المقترحة على حساسات هواتف ذكي وهي حساس gyroscope وحساس تسارع accelerometer وحساس تحديد موقع GPS بالإضافة إلى وجود كاميرات أمامية وخلفية.

نستفيد في المقاربة المقترحة من حساس التسارع والجايرو وحساس تحديد الموقع والكاميرا الأمامية للهاتف الذكي لتحليل الصور الأمامية للمركبة.

تقوم الأبحاث عادة بمناقشة المعطيات المتوفرة التي يمكن الاعتماد عليها في تحليل نمط القيادة ومناقشة دلالة هذه المعطيات منطقياً، على سبيل المثال تعتبر السمة throttle position المرتبطة بدواسة الوقود gas pedal وتغيرات هذه السمة ومجال تغيير هذه السمة من أكثر المعطيات المستخدمة كدخل لنماذج التعرف على الأنماط وذلك لارتباط نمط القيادة العدواني وغير الآمن والذي سيفضي لاحقاً إلى حوادث قد تكون مميتة بطريقة استخدام السائق لدواسة الوقود في المركبة وتواتر استخدامه لها [20].

كما تعد السرعة والتسارع من أكثر المعطيات التي تعطي تصوراً عن نمط القيادة في حال تم تسجيلها وتحليلها على طول محور الزمن وبالتالي يمكن القول انه لا تخلو دراسة تقترح نمودجا يكشف نمط القيادة من استخدام هاتين السمتين (السرعة والتسارع).

يوجد العديد من الدراسات التي اعتمدت على إشارات مسرى الشبكة Can-Bus من خلال إضافة عتاد إضافي لرصد هذه الإشارات وتفسيرها ومن ثم إعدادها واستخدامها في النماذج المدروسة. إلا أن معظم الدراسات لم تعتمد على مصدر واحد للمعطيات بل تم الاعتماد على مجموعة من المعطيات (عبر استخدام حساسات خارجية) قد يكون أحدها مسرى الشبكة Can-bus. الأمر الذي سيضيف جهداً إضافياً في مزامنة واعداد شعاع المعطيات قبل استخدامه كدخل لنموذج الكشف. بعض الدراسات استخدمت العوامل الخارجية كدخل إضافي، هذه العوامل هي حالة الطقس، نوع الطريق، والحالة المرورية. [1] بعد تحديد المعطيات المطلوب استخدامها كدخل للنموذج، تبدأ عملية البحث عن مجموعة معطيات ليتم استخدامها في تدريب النماذج المدروسة واختبارها. يوجد الكثير من الدراسات التي اعتمدت على توليد معطيات خاصة بها من خلال تسجيل معطيات المركبة ضمن كل السيناريوهات الممكنة ومن ثم إضافة وسم لهذه المعطيات بناءً على السيناريو الموافق (قيادة عدوانية – قيادة آمنة – قيادة سائق متعب وغيرها) وذلك بما يتفق مع الأنماط المطلوب تحديدها وكشفها.

تعتبر هذه العملية في الحصول على مجموعة معطيات مجهددة وتتطلب الكثير من الوقت. لذلك اعتمدت بعض الدراسات على استخدام برنامج محاكي لتوليد مجموعة المعطيات المطلوبة إلا أن هذه الطريقة، كما ذكرنا سابقاً، لن تعطي نتائج دقيقة مقارنة بالدراسات المعتمدة على معطيات حقيقية وذلك لعدم تمكن هذه البرامج على الرغم من قوتها من محاكاة الواقع بمطابقة تامة. على اعتبار أن وجود مجموعات معطيات حقيقية هو حاجة ملحة في الدراسات التي تعمل ضمن مجال أنظمة القيادة المساعدة والقيادة الذاتية، قامت عدة دراسات بتوليد مجموعات معطيات حقيقية معيارية ليتم استخدامها ومقارنة دقة النماذج عليها.

2-1-1-1- مجموعات المعطيات الحقيقية المستخدمة في الدراسات المرجعية

الخاصة بتحديد نمط القيادة

يتضمن الجدول 1-1 أهم مجموعات المعطيات الحقيقية التي يمكن الاعتماد عليها في دراسة تحليل أداء السائق Driving Behavior Analysis

الجدول 1-2 مجموعات المعطيات الحقيقية المستخدمة في تحليل أداء السائق

نوع الطريق	الساكنين	هدف الدراسة	المدة/المسافة	حجم المجموعة	مصادر المعطيات	مجموعة المعطيات
Highway, Urban, Suburban	N/A	كشف أحداث القيادة	104 ساعات	150GB	Camera, LIDAR, GPS, Can-Bus	HDD [36] 2018
Highway , City-way	10	تنبؤ بالمناورات	1180 miles	16GB	Camera, GPS, maps	BRAIN4CARS [37] 2015
Highway, freeway, tunnel	10	تحليل أعباء القيادة Driving workloads analysis	300 دقيقة	450MB	GPS, multimedia, wearables	HCILAB [38] 2013
Highway, freeway, parking lot	+3400	التعرف على السائق، منع الحوادث، وإدارة المخاطر	+45000 ساعة	+700TB	Camera, GPS, Can-Bus, Smartphone, RADAR	SHRP2 [39] 2016
Urban, rural	241	منع الحوادث	+43000 ساعة	6.4TB	Multimedia, GPS, Can-Bus, RADAR, Smartphone	100-CAR [40] 2006
urban	3000	سلامة الطرقات	سنة ونص	N/A	Can-Bus, Multimedia, RADAR, RSE, V2V communication devices	SPMD [41] 2015
Urban, rural	400	سلامة الطرقات	سنة أشهر	60TB	Multimedia, Can-Bus, RADAR, GPS	400-CAR [42] 2013
City way, highway	53	تحديد نمط القيادة	+25Km	9TB	Multimedia, Can-Bus, GPS	UYANIK [43] 2007

Motorway, Secondary road	6	تحديد نمط القيادة	500 دقيقة	3.9GB	Smartphone (inertial sensors, GPS, Camera)	UAH DRIVESET [44] 2016
City way, motorway, parking	10	التعرف على السائق	23 ساعة/ 46 Km	17.7MB	Can-Bus	HCRL [45] 2016

من الجدول السابق، المجموعتان المتاحتان لدراسة تحديد نمط القيادة هما UYANIK و UAH Driveset. اخترنا UAH Driveset لأن مصدر المعطيات المستخدم فيها هو حساسات هاتف ذكي بالإضافة إلى الكاميرا الخلفية (المنظر الأمامي للمركبة).

الخطوة التي تلي تحديد مصادر المعطيات ومجموعة المعطيات هي تحديد الخوارزمية التي ستنبأ بأنماط القيادة. سنمر على الخوارزميات المستخدمة في الأبحاث السابقة مع ذكر الأمثلة.

2-3- المقاربات والخوارزميات المستخدمة في تحديد نمط القيادة

يمكن تصنيف الخوارزميات المستخدمة في الأبحاث السابقة الخاصة بتحديد نمط القيادة إلى 5 أنواع أساسية هي:

3-1- المقاربات المعتمدة على العتبة Threshold Methodology

تتميز أنماط القيادة الخطيرة عن أنماط القيادة الآمنة بقيم حساسات التسارع التي تكون مرتفعة. ومنه يمكن أن نكشف هذه الأنماط من خلال مقارنة قيم حساسات التسارع مع عتبة معينة. تتميز هذه الطريقة ببساطتها وسرعة تنفيذها مقارنة مع خوارزمية أخرى [49].



يمكن تثبيت الهاتف الذكي ضمن المركبة بحيث يتوازي محور الحركة للمركبة مع المحور Y للهاتف، الأمر الذي يتيح كشف أحداث التسارع والتباطؤ في القيادة من خلال مقارنة التسارع على المحور Y مع عتبة محددة، وكشف الأحداث في الالتفاف وتغيير المسار lane change من خلال مقارنة التسارع على المحور X مع عتبة أخرى، ويمكن أيضاً كشف الاهتزاز ووجود مطبات road anomalies من خلال دراسة التسارع على المحور Z ومقارنته بعتبة ثالثة. [49]

على الرغم من سهولة استخدام عتبة من حيث وقت التنفيذ ومن حيث الموارد البرمجية المستخدمة إلا أن لهذه الطريقة مساوئ نذكر منها:

- لا يمكن استخدام عتبة موحدة يعني العتبات المستخدمة على الهاتف A ضمن المركبة A، لن تعطي نفس النتائج عند استخدام هاتف B ضمن مركبة B. (في حال كان مصدر المعطيات هو حساسات هاتف ذكي).
- الطرقات غير المعبدة بشكل جيد ستعكس على قراءات الحساسات من خلال إضافة ضجيج قد يكون نبضي يتجاوز العتبات المحددة.
- تعمل هذه الخوارزمية فقط في حالة السرعة المنخفضة والمسافات القصيرة بسبب وجود خطأ تراكمي ضمن حساسات التسارع [50]، [51]
- تتطلب هذه الطريقة أن يكون الهاتف مثبتاً بشكل جيد ضمن المركبة.

2-3-2- المقاربات المعتمدة على تطابق النماذج Pattern Matching Methodology

في البداية يتم تسجيل معطيات لأحداث قيادة معروفة تحت نمط قيادة معين وتحفظ هذه المعطيات الزمنية كنماذج معبرة عن نمط القيادة. بوجود هذه النماذج يتم كشف أنماط القيادة من خلال تسجيل أحداث زمنية ومقارنتها مع النماذج المحددة المعرفة لكل أنماط القيادة. هذه المقارنة تتم من خلال خوارزمية مطابقة تدعى Dynamic Time Warping تعتمد هذه الخوارزمية على مقارنة التشابه بين سلسلتين من القيم بطريقة مختلفة عن الطريقة التقليدية التي تعتمد على المسافة الاقليدية بين كل زوجين متقابلين من القيم، يوضح الشكل 5 مقارنة بين الطريقة التقليدية وطريقة DTW.



الشكل 1-2 توضيح الفرق بين المطابقة الاقليدية والمطابقة باستخدام الخوارزمية DTW

الدراسة [52] بعنوان "التعرف على نمط القيادة باستخدام حساسات هاتف ذكي" المعمول بها في 2011 في جامعة كاليفورنيا. هدفت هذه الدراسة إلى تمييز نمط القيادة الآمن أو غير العدواني non-aggressive عن نمط القيادة العدواني aggressive من خلال استخدام المطابقة الزمنية لشعاع معطيات محدد بطول زمني محدد باستخدام نافذة زمنية منزقة مع نماذج معرفة بشكل مسبق لنمط القيادة العدواني. التحدي الأول في هذه الدراسة هو اختيار شعاع المعطيات الذي سيمتلك القدرة على التمييز بين نمطي القيادة العدواني وغير العدواني. بعد اجراء العديد من الاختبارات تبين أن دمج قراءات عدة حساسات هي (accelerometer – gyroscope – magnetometer) سيمكّن من تعريف كلاً من نمطي القيادة بشكل كافٍ. من قراءات هذه الحساسات تم اختيار شعاع يتألف من القراءات حول المحور X لحساس Gyroscope وقراءات حساس التسارع حول المحور Y وقراءات حساس magnetometer حول محور X (المحور Y منطبق على محور الحركة للمركبة). للاطلاع بشكل مفصّل على طريقة اختيار هذه القيم، راجع المرجع [52]. الخوارزمية التي تم اختيارها للتعامل مع التصنيف هي خوارزمية المطابقة وباستخدام طريقة Dynamic Time Warping في عملية المطابقة بين السلاسل الزمنية للأشعة. في البداية يتم تسجيل مجموعة من الرحلات المعرفة لنمط القيادة العدواني وحفظ قيم شعاع المعطيات المختار على طول هذه الرحلات. يتم تجزئة هذه الرحلات إلى أحداث زمنية أصغر تعرف نمط القيادة العدواني وحفظها على أنها نماذج معرفة للقيادة العدوانية والتي سيتم المقارنة معها لاحقاً. يمكن الاطلاع على المرجع [52] لمعرفة الطريقة التي تم استخدامها في كشف بداية ونهاية الحدث. أثناء القيادة يتم تسجيل شعاع المعطيات ضمن نافذة زمنية منزقة ومقارنة السلسلة الزمنية

المسجلة مع كل النماذج المحفوظة والمعرفة لنمط القيادة العدواني. إن مقارنة السلسلة الزمنية المسجلة أثناء القيادة مع كافة السلاسل الزمنية لنماذج القيادة العدوانية بشكل دائم أثناء القيادة يشكل عبءاً حسابياً كبيراً يتطلب وقتاً وموارد مقارنة بالإمكانات الحسابية لهاتف ذكي.

3-3-2- المقاربات المعتمدة على المنطق العائم Fuzzy Logic Methodology

يتميز المنطق العائم وأنظمة الاستدلال المعتمدة على المنطق العائم أن لها القدرة على نقل الخبرات والمعارف البشرية وتضمينها ضمن مجموعة من القواعد من الشكل IF-THEN. لذلك كانت المقاربات المعتمدة على المنطق العائم والاستدلال باستخدام المنطق العائم من أكثر المقاربات استخداماً في الأبحاث الخاصة بالتعرف على نمط القيادة في السنوات السابقة وقبل أن يتم الاعتماد على خوارزميات الذكاء الصناعي (تعلم الآلة والتعلم العميق) لاحقاً. من الأبحاث التي اعتمدت على هذه المقاربة، الدراسات في [20]، [53]، [54]. تعاني خوارزميات الاستدلال باستخدام المنطق العائم من عدم قدرتها على التعلم من المعطيات واعتمادها بشكل كامل على الخبرة البشرية في تحديد كافة المعاملات، ومنه يوجد معاملات سيتم تحديدها بشكل مسبق والتي يمكن أن تعطي نتيجة جيدة في حالات معينة ونتيجة سيئة في حالات أخرى (أثناء القيادة). ذلك لأننا اعتمدنا على الخبرة البشرية في تحديد معاملات نموذج التعرف والتي يمكن أن تكون قاصرة عن تحديد المعامل الأمثل. يوجد علاقة طردية بين رفع دقة نموذج التعرف على نمط القيادة المعتمد على الاستدلال بالمنطق العائم وزيادة عدد القواعد IF-THEN مما يعني تعقيداً برمجياً أكبر ويعني استخداماً أكبر للموارد الحسابية. يمكن الاعتماد على المنطق العائم بشكل جزئي دون أن يكون المقاربة الأساسية ضمن نموذج التعرف على نمط القيادة. كما هو الحال في العديد من الدراسات.

3-3-4- المقاربات المعتمدة على خوارزميات تعلم الآلة التقليدية Classical Machine Learning Methodology

يمكن حصر كل المقاربات التي اعتمدت على خوارزميات تعلم الآلة في نوعين هما:

- خوارزميات تعلم الآلة التقليدية Classical Machine Learning Algorithms (خوارزمية وحيدة) من أكثر الخوارزميات استخداماً خوارزمية Support Vector Machine وخوارزمية K Nearest Neighbor تعتمد هذه الخوارزميات في التصنيف على حفظ المعطيات الخاصة بالتدريب والاعتماد عليها في عملية التصنيف. أحد الأمثلة على استخدام SVM الدراسة [60]. ومن خوارزميات تعلم الآلة المستخدمة خوارزميات Regression Algorithms التي تم استخدامها في [61] من أجل التنبؤ بخطورة قيادة سائق معين risk driver status اعتماداً على مجموعة من

المعلومات الخاصة به. كما تعتبر خوارزميات تعلم الآلة المعتمدة على الاستدلال البايزي Bayes مستخدمة في مجال تحديد نمط القيادة، من الدراسات المعتمدة على هذه الخوارزميات الدراسات في [59]-[58]-[57].

- الخوارزميات المجمعـة Ensemble Algorithms (مجموعة من خوارزميات تعلم الآلة)

تتألف الخوارزميات المجمعـة من عدة خوارزميات تعلم آلة وتكون النتيجة النهائية للخوارزمية الكلية هي دمج بين خرج كل من الخوارزميات الجزئية المؤلفة لها. يتم تدريب كل خوارزمية على حدى وبشكل منفصل عن الخوارزمية الأخرى. أحد أشهر الأمثلة على هذا النوع من الخوارزميات والمستخدم بكثرة في أبحاث تحديد نمط القيادة هو استخدام خوارزمية Random Forest [56]. من هذه الخوارزميات يستخدم أيضاً خوارزمية Adaboost وخوارزمية Bagging وخوارزمية gradient boosting.

النتائج التي أعطتها الخوارزميات المجمعـة أفضل من نتائج التي أعطتها خوارزميات تعلم الآلة عند استخدامها بشكل وحيد. إلا ان أنها لم تستطع التفوق على خوارزميات التعلم العميق التي سنذكر لاحقاً أكثرها استخداماً.

2-3-5- المقاربات المعتمدة على خوارزميات التعلم العميق Deep

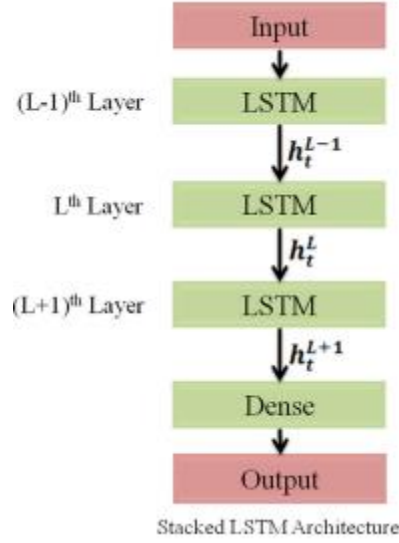
Learning Methodology

تتميز خوارزميات التعلم العميق بقدرتها على تعلم السمات من المعطيات دون الحاجة إلى دراسة المعطيات كخطوة مسبقة للتعرف على أفضلها وأكثرها ارتباطاً بالنتيجة النهائية للنموذج. وبالتالي عند وجود معطيات مترابطة زمنياً، نستغني عن تصميم سمات إحصائية انطلاقاً من معطيات الحساسات المتوافرة، وكحل بديل وفعال يمكن استخدام نماذج عميقة تتعامل مع السلاسل الزمنية وتستخلص السمات ضمناً اعتماداً على المعطيات فقط. يمكن أن نعتبر المعطيات التي نقوم بتسجيلها أثناء القيادة معطيات مترابطة زمنياً وخاصةً عندما يكون الهم الأساسي هو تقييم طريقة القيادة وتصنيفها. لذا تعتبر خوارزميات السلاسل الزمنية العميقة حلاً مقترحاً لمسألة تحديد أنماط القيادة وهو الحل المعتمد ضمن المقاربة المقترحة في هذا البحث.

أهم الخوارزميات المستخدمة في الأبحاث السابقة هي:

- خوارزمية Stacked LSTM

تتألف البنية Stacked LSTM من عدة طبقات على التسلسل من شبكة LSTM مع طبقة أخيرة هي شبكة عصبونية يكون خرجها نتيجة التصنيف. يمثل الشكل 2-2 مخطط لخوارزمية Stacked LSTM. [12]




الشكل 2-2 مخطط خوارزمية Stacked LSTM

تعتبر شبكة LSTM Long Short-Term Memory أكثر البنى استخداماً للتعامل مع السلاسل الزمنية. يوجد عدة أنواع منها حسب شكل الدخل والخرج

- سلسلة في الدخل والخرج شعاع وحيد "many to one"
- سلسلة في الخرج والدخل شعاع وحيد "one to many"
- الدخل والخرج سلاسل زمنية "many to many".

تعتبر هذه البنية تحسیناً عن الشبكات العودية Recurrent Neural Network RNN وذلك لتغلبها على مشكلة vanishing/exploding gradient أثناء عملية التدريب.


تحوي الشبكات RNN على حلقة عودية تسمح بتذكر المعطيات عبر الزمن. يمثل الشكل 3-2 مخططاً عاماً لهذا النوع من الشبكات.



An unrolled recurrent neural network.


الشكل 3-2 مخطط عام لشبكات RNN

تختلف بنية الشبكة LSTM عن الشبكات العودية RNN أنها تحوي بالإضافة إلى الخرج إشارة حالة الخلية. تتغير قيمة إشارة الحالة عبر ما يسمى ب Gating mechanism التي تضبط ما يتم تذكره أو نسيانه من المعطيات السابقة. يمثل الشكل 2-4 مخطط خلية LSTM.



الشكل 2-4 مخطط الخلية من نمط LSTM

يبين الشكل 2-5 المعادلة الخاصة ببوابة الدخل Input Gate التي تتحكم فيما إذا سيتم تحديث ذاكرة الخلية أم لا.




$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C)$$

الشكل 2-5 المعادلة الخاصة ببوابة الدخل Input Gate


يبين الشكل 2-6 المعادلة الخاصة ببوابة النسيان Forget Gate التي تتحكم فيما إذا سيتم تصفير ذاكرة الخلية reset memory



$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$$

الشكل 2-6 المعادلة الخاصة ببوابة النسيان Forget Gate

يبين الشكل 2-7 المعادلة الخاصة ببوابة الخرج Output Gate التي تتحكم بما سيتم مشاركته من الذاكرة في خرج الخلية.




$$o_t = \sigma(W_o [h_{t-1}, x_t] + b_o)$$

$$h_t = o_t * \tanh(C_t)$$

الشكل 7-2 المعادلة الخاصة ببوابة الخرج Output Gate

يبين الشكل 8-2 المعادلات الخاصة بحساب إشارة الحالة الداخلية للخلية.



$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t$$

الشكل 8-2 المعادلة الخاصة بحساب إشارة الحالة الداخلية للخلية

يوجد عدة دراسات استخدمت البنية Stacked LSTM في مسألة تحديد أنماط القيادة [4]-[3]. تعتبر البنية Stacked LSTM من أكثر البنى استخداماً في التعامل مع السلاسل الزمنية. عند استخدام عدة طبقات بدلاً من طبقة واحدة Stacked architecture، تكون السمات الضمنية المستخرجة من المعطيات ذات تعقيد أكبر، ومنه تكون قدرة النموذج على التصنيف أكبر.

يكون الدخل للبنية هو سلسلة زمنية بطول محدد من شعاع المعطيات الذي تم اختياره ويكون الخرج هو نتيجة التصنيف. في الدراستين تم دراسة شعاع المعطيات الأنسب للحصول على أفضل نتيجة تصنيف بين الأنماط التالية (قيادة عدوانية أو عنيفة aggressive - قيادة عادية normal driving - قيادة متعبة drowsy driving). كما تم دراسة أفضل طول للنافذة الزمنية بحيث تكون نتيجة التصنيف على مجموعة المعطيات UAH Driveset أفضل. تم استخدام مجموعة المعطيات UAH Driveset في هذه الدراسات لاعتبارها توفر قيم حساسات هاتفي ذكي وتتنوع ضمنها المعطيات بالشكل الذي يمكن من استخدامها في مسائل التعرف على نمط القيادة البحثية.

كما عمدت كلتا الدراستين إلى استخدام خوارزميات تعلم آلة تقليدية مثل Random forest ومقارنة النتيجة مع نتيجة البنية Stacked LSTM وبينتا أفضلية التعلم العميق في التعامل مع مسائل من هذه النمط.

الدراسة [3] اعتمدت شعاع معطيات مؤلف من 9 عناصر هي:

- التسارع والزوايا حول 3 محاور
- السرعة من حساس تحديد الموقع

- المسافة عن أقرب سيارة وعدد السيارات الظاهرة في صورة الكاميرا الموجهة للطريق.

وتم اعتماد نافذة زمنية بطول 6.4 ثانية. حصل على نتيجة تصنيف هي 91%

الدراسة [4] اعتمد شعاع معطيات مؤلف من 7 عناصر هي:

- السرعة والتسارع ومشتق التسارع (حسابياً من السرعة) من حساس تحديد الموقع

- الميلان وتغيير الميلان من حساس تحديد الموقع

- المسافة عن أقرب سيارة وعدد السيارات الظاهرة في صورة الكاميرا الموجهة للطريق.


تم دراسة عدة أطول للنافذة الزمنية وحساب دقة التصنيف من أجل كل منها. أفضلها نتيجةً هي 0.32 ثانية.

- خوارزمية Stacked GRU

كما هو الحال في حالة Stacked LSTM مع اختلاف هو استخدام البنية Gate Recurrent Units GRU بدلاً من

LSTM البنية

يبين الشكل 2-9 مخطط خلية GRU (تحتوي بوابتين بدلاً من ثلاث بوابات كما في حالة خلية LSTM)



$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t])$$

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t])$$

$$\tilde{h}_t = \tanh(W \cdot [r_t * h_{t-1}, x_t])$$

$$h_t = (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t$$

الشكل 2-9 مخطط خلية من نمط GRU

لدينا بوابتان، الأولى تسمى Update Gate وتدعى الأخرى Reset Gate، الأولى لتحديث ذاكرة الخلية والثانية لحذفها.

من الدراسات التي اعتمدت هذه البنية في تصنيف أنماط السائقين [11]، حيث أعتد على نافذة زمنية بطول 3 دقائق

وشعاع معطيات معتمد بشكل أساسي على معطيات حساس تحديد الموقع.

- خوارزمية Convolutional Neural Network

لا يقتصر استخدام الشبكات CNN في التعامل مع المعطيات المترابطة مكانياً كما في الصور في مجال الرؤية الحاسوبية

Computer Vision، بل أثبتت العديد من الدراسات على قدرتها على التعامل مع السلاسل الزمنية وأعطت نتائج جيدة.

يمكن مراجعة الدراسة [63] التي تتحدث عن استخدام الشبكات العصبونية الالتفافية في التعامل مع البنى ذات ترابط زمني

وقدرتها في بعض المسائل على الحصول على نتيجة تفوق النتيجة في حال استخدام خوارزميات السلاسل الزمنية RNN.

« Convolutional Networks have been demonstrated to be particularly useful for extracting high level feature in structural data. Temporal convolutional network (TCN) is a framework which

employs casual convolutions and dilations so that it is adaptive for sequential data with its temporality and large receptive fields. » [63]

من الدراسات التي اعتمدت على استخدام هذه البنية في تصنيف أنماط القيادة [10] .

- خوارزمية LSTM-FCN

تدمج البنية LSTM-FCN بين نوعين من البنى، الأول هو LSTM والثاني هو FCN Fully Convolutional Network. وبالتالي هي تستفيد من مزايا كلتا البنيتين. الشكل 2-10 يوضح مخطط هذه البنية. الشبكة FCN تتألف من عدة طبقات temporal convolutions التي تعمل على استخلاص السمات بشكل ضمني. كل طبقة تتألف من طبقة convolution و batch normalization و activation function. الدخل لكل من FCN و LSTM واحد ولكن كل شبكة تتعامل مع الدخل زمنياً بشكل مختلف. على سبيل المثال من أجل سلسلة زمنية مؤلفة من 30 شعاع لكل خطوة زمنية، تحتاج FCN 30 خطوة زمنية، بينما LSTM تحتاج إلى خطوة زمنية واحدة. المقال [6] يوضح هذه البنية بالتفصيل.


الدراسة [5] تعتمد هذه البنية في تصنيف نمط القيادة ضمن (قيادة عدوانية aggressive driving – قيادة عادية normal driving – قيادة متعبة drowsy driving).

تم الاعتماد على مجموعة المعطيات UAH-Driveset

شعاع المعطيات الذي تم اعتماده هو

- السرعة
- التسارعات
- الزوايا
- موقع المركبة عن خط المنتصف
- ميلان المركبة عن خط المنتصف
- المسافة عن السيارة الأمامية في المسار الحالي
- عرض الطريق
- زمن التأثير في المركبة الأمامية Time to impact to ahead vehicle

تم دراسة عدة أطوال للنافذة الزمنية واعتماد الطول الذي يعطي نتيجة تصنيف أفضل (5 دقائق) والدقة هي 95.88%



الشكل 10-2 مخطط البنية LSTM-FCN

عرضنا في هذا الفصل أهم الخوارزميات ومصادر المعطيات المستخدمة في الدراسات السابقة الخاصة بدراسة تحديد نمط القيادة. كما عرضنا معلومات تفصيلية تخص مجموعة المعطيات UAH Driveset التي تم استخدامها في المقارنة المقترحة في هذا البحث.

الفصل الثالث

المقارنة المقترحة لكشف أنماط القيادة

نعرض في هذا الفصل المقارنة المقترحة لنموذج تصنيف يكشف أحد نمطي القيادة (نمط قيادة غير آمن *Unsafe* – نمط قيادة آمن *Safe*) من حيث مصادر المعطيات (حساسات هاتف ذكي) ومن حيث الخوارزميات المستخدمة.

3-1- المقارنة المقترحة

تتعرف أيّ مقارنة خاصة بتطوير نظام تعرف على أنماط القيادة من خلال عدة جوانب هي: الأنماط المطلوب كشفها والمعطيات المستخدمة في تعريف هذه الأنماط (قواعد معينة أو معطيات سابقة كاستخدام مجموعة معطيات Dataset مثلاً) – المعطيات المستخدمة (الحساسات) – الخوارزمية المستخدمة – العتاد المستخدم في التنفيذ العملي.

بعد مراجعة أهم الأبحاث السابقة الخاصة بتطوير أنظمة التعرف على نمط القيادة *Driving Style Detection*، اقترحنا مقارنة يمكن تعريفها من خلال النقاط التالية (تتضمن كل من هذه النقاط التبرير الخاص بكل منها):

المعطيات التي يمكن استخدامها (الحساسات):

- يمكن استخدام معطيات خاصة بديناميكية المركبة (سرعة – تسارع – زوايا ... الخ) على اعتبار أن هذه المعطيات قادرة على تمييز أنماط القيادة المختلفة عند استخدام خوارزميات مناسبة وذلك مقارنة بالمعطيات الخاصة بالعلامات الحيوية للسائق وكون السائق في حالة فيزيولوجية مناسبة للقيادة (تشتت السائق مثل حالة عدم الانتباه للطريق أو شعوره بالنعاس) [4].
- استخدام حساسات خارجية لتوليد معطيات تصف ديناميكية المركبة دون اللجوء إلى قراءة هذه المعطيات من مسرى الشبكة *Can-Bu* وإضافة عتاد يختلف حسب نوع المركبة (السيارات الكبيرة تستخدم بروتوكولات مغايرة لتلك المستخدمة في السيارات الصغيرة).
- الحساسات الخارجية الأكثر انتشاراً والأكثر توفراً لدى جميع السائقين هي حساسات الهواتف الذكية. لا يخلو هاتف ذكي من الحساسات الآتية على اختلاف أنواعها (كاميرا خلفية بدقة مقبولة – حساسات تسارع وتحديد موقع) ولا

يشترط استخدام هاتف ذكي ضمن مركبة أي شروط تتعلق بنوع المركبة وبالتالي يمكن استخدام النظام المطور ضمن جميع المركبات من أصغرها إلى أكبرها ومن أبسطها إلى أعقدها تكنولوجياً.

- في حال تم اعتماد حساسات هاتف ذكي يمكن استخدام الكاميرا الخلفية لرصد الصورة الأمامية للمركبة (الطريق الأمامي) واستنباط العديد من المعطيات سنأتي على ذكرها لاحقاً، ويمكن قراءة الزوايا والسرعة والتسارعات من حساسات تحديد الموقع GPS وحساسات التسارع accelerometer (يتم تثبيت الهاتف ضمن المركبة بحيث تلتقط الكاميرا الأمامية المنظر الأمامي للطريق وبحيث تنطبق محاور المركبة مع محاور الهاتف).

العديد من الدراسات التي قمنا بذكرها في الفصل السابق أكدت فعالية استخدام حساسات هاتف ذكي في كشف نمط القيادة بدلاً من إضافة حساسات تجارية أو الاعتماد فقط على معلومات المسرى Can-Bus وإدخال عتاد إضافي لقراءة إشارات. [4] كما نهتم بالقدرة الحاسوبية التي أضحت في تزايد مع مرور الزمن وبالتالي النموذج المقترح سيعمل بالزمن الحقيقي بمساعدة الموارد الحاسوبية للهاتف الذكي.

- بالإضافة إلى استخدام معطيات خاصة بديناميكية المركبة، نقترح استخدام الصورة الأمامية للطريق في تقدير احتمال الصدم للمركبة بالأجسام الظاهرة في الصورة (المنظر الأمامي للطريق من منظور المركبة الأمامي). قد تكون هذه الأجسام إما مركبات أو شاخصات طريقية أو جدار أو أشخاص أو دراجات نارية أو أي جسم آخر من الأجسام التي يمكن أن تتواجد في الطرقات. لم يسبق استخدام تقدير احتمال الصدم من الصورة الأمامية في الأبحاث السابقة بل اعتمد معظمها على خوارزميات معالجة صورة تقليدية لكشف عدد المركبات الظاهر في الصورة والمسافة عن أقرب مركبة. لذا يعتبر هذا المقترح إضافة مهمة تميز هذا البحث عن الأبحاث السابقة. يمكن الاعتماد على النموذج DRONET في تقدير احتمال الصدم.

الأنماط المطلوب كشفها والمعطيات المستخدمة في تعريف هذه الأنماط:

- الهدف من البحث هو كشف نمط القيادة غير الآمن unsafe driving behavior، وبشكل خاص نمط القيادة العدوانية aggressive driving behavior.
- في حال تم اعتماد نظام استدلال عائم في تطوير نظام التعرف على نمط القيادة الحالي، نحتاج إلى مجموعة القواعد المعرفة لأنماط القيادة التي نرغب بكشفها وهذا الأمر يتطلب دراسةً وبخفاً معمقاً للوصول إلى شكل القيادة الخاصة بكل نمط لنستنبط منه نظام استدلال بشكل قواعد If-Then. لا يشمل هذا البحث على دراسة من هذا النمط وسنستعيز عنها بالبحث عن مجموعة معطيات بحيث تعرف بشكل ضمني أنماط القيادة المطلوب كشفها.
- يمكن استخدام مجموعة معطيات مولدة من برامج محاكاة أو مجموعة معطيات ناتجة عن تسجيل معطيات حقيقية لرحلات حقيقية يتم خلالها محاكاة أنماط القيادة المطلوبة بالاستعانة بعدد من السائقين وعلى عدة مركبات مختلفة.

اخترنا استخدام مجموعة معطيات حقيقية وبالتالي ستندرج الدراسة الحالية ضمن دراسات القيادة المعتمدة على معطيات طبيعية Naturalistic Driving Studies. من الجدول 1-1 واعتماداً على النقاط السابقة تكون مجموعة المعطيات UAH Driveset الخيار الأنسب لنا (تعتمد على معطيات حساسات هاتف ذكي – تستخدم لكشف نمطي قيادة غير آمنة Aggressive vs Drowsy وتمييزهما عن نمط القيادة الطبيعية أو الآمنة Normal or Safe Driving).

- مجموعة المعطيات التي سنستخدم عليها في تدريب نموذج التعرف هي مجموعة المعطيات الحقيقية UAH Driveset وبالتالي تعتبر الدراسة المقترحة ضمن الدراسات المعتمدة على معطيات حقيقية Naturalistic Driving Studies NDS. قمنا بذكر معلومات تفصيلية تخص مجموعة المعطيات المستخدمة في الفصل السابق.

الخوارزميات المستخدمة:

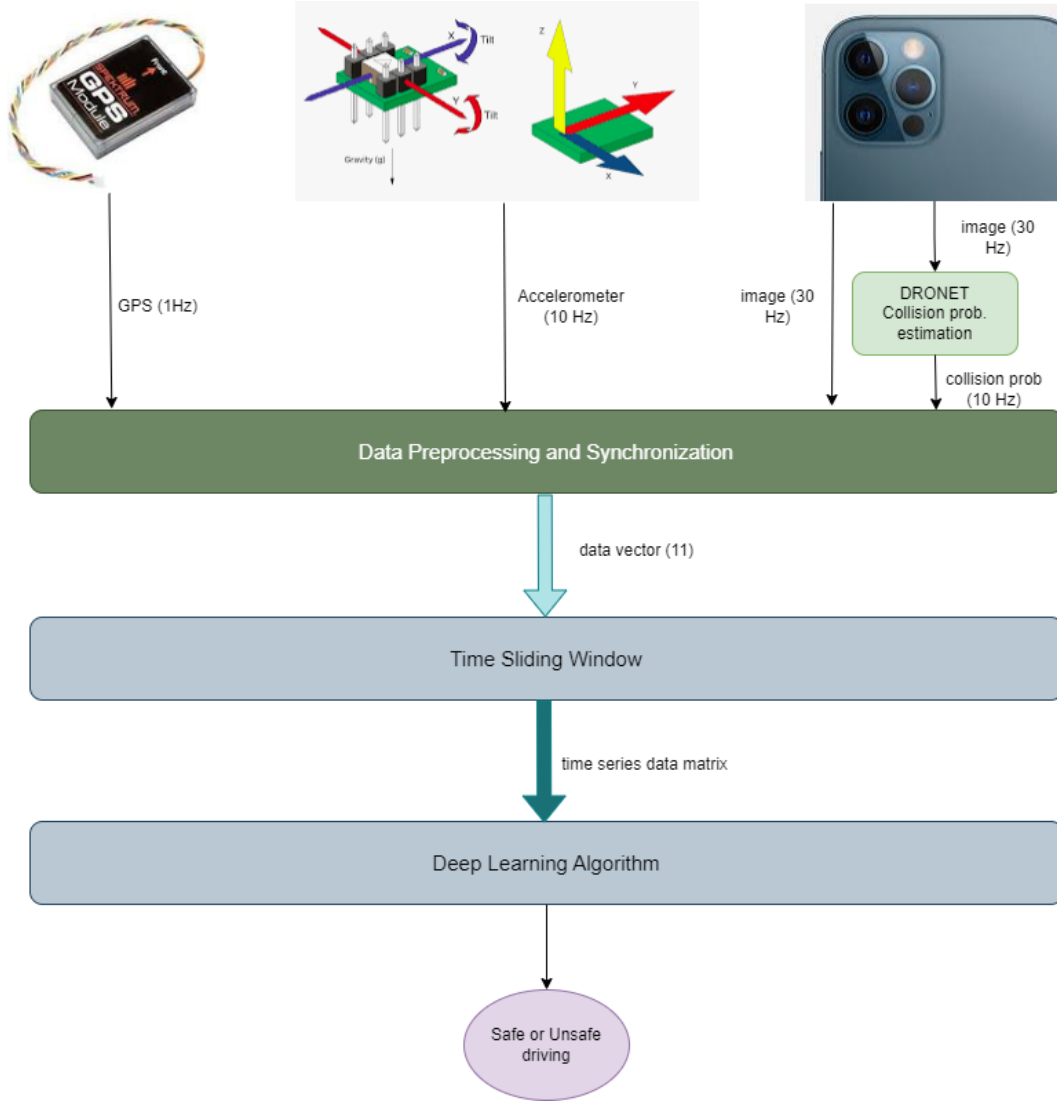
- يمكن استخدام نظام استدلاي إلا أن هذه المقاربة تتطلب دراسة معمقة لأنماط القيادة ولن تتمكن من الحصول على دقة كشف أفضل من الدراسات الأخيرة التي أثبتت تواضع النتائج الخاصة بالأنظمة المعتمدة على العتبات الثابتة أو أنظمة الاستدلال. ذلك لأن مسألة كشف نمط القيادة تعتمد على تغير العديد من المعاملات عبر الزمن (يمكن أن يكون بعد فضاء المعطيات يساوي 10 أو أكثر). وبالتالي فإن أفضل خوارزمية يمكن أن تجد النموذج الأقرب للواقع والمثل للعلاقة بين تغير ديناميك المركبة عبر الزمن وشكل القيادة (آمن أو غير آمن) هي خوارزميات التعلم العميق الخاصة بالسلاسل الزمنية، حيث تعمل على تعلم هذه العلاقة من خلال النظر إلى أكبر عدد من المعطيات (السلاسل الزمنية لمعطيات ديناميك المركبة) Data Driven Approach. ومنه فإن خوارزميات التعلم العميق التي تتعامل مع السلاسل الزمنية كدخل لها تعتبر الحل الأمثل لمسألة كشف نمط القيادة.

العتاد المستخدم في التنفيذ العملي

- يجب أن تكون خوارزمية الكشف قابلة للتنفيذ العملي ضمن نظام مضمن Embedded System وتعمل بالزمن الحقيقي ضمن قيود هذا النظام (القدرة الحاسوبية – موارد). بما أن المعطيات المستخدمة هي معطيات حساسات هاتف ذكي لذا يجب أن تكون الخوارزمية الناتجة قابلة للبرمجة ضمن نظام Android وتعمل ضمنه على هاتف متوسط الجودة بالزمن الحقيقي (نقترح التجريب على نظام Android >6).

مخطط النموذج المقترح

يبين الشكل 1-3 مخططاً لنموذج التعرف المقترح:



الشكل 1-3 مخطط النموذج المقترح

الخطوات الأساسية من المخطط:

- تحصيل قيم حساسات تحديد الموقع GPS بتردد 1 Hz وحساسات التسارع بتردد 10 Hz والصور من الكاميرا الخلفية بتردد 30 FPS.
- استخراج تقدير احتمال الصدم من الصورة الأمامية باستخدام النموذج DRONET.

- إعداد قيم معطيات الحساسات ومزامنتها وتشتمل على هذه الخطوات التالية بشكل مختصر:
 - استخلاص المسار الحالي للمركبة والميلان عنه من خلال تحليل الصورة الأمامية باستخدام إحدى خوارزميات كشف المسار lane detection
 - مزامنة المعطيات من خلال توحيد تردد التحصيل لكل منها بالإضافة إلى حساب القيم المعيارية لكل منها. سيتم ذكر هذه الخطوة بالتفصيل لاحقاً.
- يكون تجميع المعطيات ضمن سلاسل زمنية بطول محدد وتوليد الدخل المناسب لخوارزمية التعلم العميق المستخدمة. (سيتم دراسة الطول المناسب للسلسلة الزمنية بحيث تعبر بشكل كافٍ عن نمط القيادة المطلوب)
- خرج نموذج التعلم العميق هو نمط قيادة غير آمن (عدواني) أو نمط قيادة آمن (عادي). تجميع هذا الخرج على كامل الرحلة يمكن من تقييم أداء السائق على كامل الرحلة.

3-2- مجموعة المعطيات الحقيقية UAH Driveset

عمل الباحثين في الجامعة الاسبانية University of Alcala على تطوير برنامج مساعد للقيادة يمكن استخدامه على هاتف ذكي iPhone باسم DriveSafe. الأبحاث [46]، [47] تبين الخوارزميات المستخدمة في النسخة النهائية من البرنامج. الهدف منه بشكل أساسي هو كشف أحداث القيادة وتصنيف أنماط القيادة ضمن ثلاث أنواع هي (قيادة عادية normal - قيادة عدوانية aggressive - قيادة متعبة drowsy). المرحلة التي تسبق الحصول على نتيجة التصنيف ضمن البرنامج DriveSafe هي تحصيل المعطيات من الحساسات المختلفة في الهاتف (حساس تحديد الموقع - حساسات العطالة inertial sensors - تحصيل صور أمامية للمركبة ومعالجتها للحصول على سمات معينة مثل الميل عن منتصف الطريق، وعدد السيارات، والمسافة عن أقرب سيارة وغيرها) وحفظ هذه المعطيات ضمن ملفات بشكل معين ليتم لاحقاً معالجتها من قبل الخوارزميات المستخدمة والحصول على النتيجة النهائية. لذا يمكن اعتبار البرنامج بالإضافة إلى كونه أداة تقييمية للقيادة أداة لجمع معطيات مصدرها الحساسات المختلفة الموجودة ضمن الهاتف.

بسبب كثرة الأبحاث التي تدرس كشف نمط القيادة ولعدم وجود مجموعة معطيات عامة تخدم هذه الأبحاث في حال تم اعتماد حساسات الهاتف الذكي كمصدر للمعطيات، عمل الباحثان في هذه الجامعة على بناء مجموعة معطيات معيارية بمساعدة البرنامج المطور DriveSafe. يوجد في الرابط [48] فيديو يوثق عمل هذا البرنامج والواجهة الأمامية له.

تحتوي مجموعة المعطيات الناتجة UAH Driveset على معطيات مسجلة لعدة رحلات لـ 6 سائقين مختلفين، كل سائق منهم يقود مركبة مختلفة عن الأخر. الرحلات المسجلة تمت على نوعين من الطرق: طريق رئيسية Motorway - طرق فرعية Secondary road

يبين الشكل 3-2 معلومات خاصة بالسائقين الستة الذي قاموا بالرحلات [44].

LIST OF DRIVERS AND VEHICLES THAT PERFORMED THE TESTS.

Driver	Genre	Age range	Vehicle Model	Fuel type
D1	Male	40-50	Audi Q5 (2014)	Diesel
D2	Male	20-30	Mercedes B180 (2013)	Diesel
D3	Male	20-30	Citröen C4 (2015)	Diesel
D4	Female	30-40	Kia Picanto (2004)	Gasoline
D5	Male	30-40	Opel Astra (2007)	Gasoline
D6	Male	40-50	Citröen C-Zero (2011)	Electric

الشكل 3-2 معلومات خاصة بالسائقين الذين قاموا بالرحلات الخاصة بمجموعة المعطيات UAH Driveset

3-2-1- تثبيت الهاتف وجمع المعطيات Setup and Methodology

تم تثبيت هاتف ذكي iPhone في كل مركبة على الزجاج الأمامي في المنتصف بحيث تلتقط الكاميرا الخلفية المنظر الأمامي للمركبة بوضوح كما في الشكل 3-3، وتم تشغيل البرنامج DriveSafe. عندما يبدأ البرنامج بالعمل تبدأ مرحلة معايرة calibration لمطابقة المحاور العطالية مع محاور المركبة. وتم تثبيت هاتف ذكي آخر على يمين الهاتف الأول بنفس طريقة التموضع ليقوم بتصوير الطريق أثناء الرحلة. في كل رحلة يطلب من السائق أن يقوم بتمثيل أحد أنماط القيادة (قيادة عادية - قيادة عدوانية - قيادة في حالة التعب أو الإعياء) ويرافق السائق مشرف يساعد في تنبيه السائق في حال تعرضه لمخاطرة عالية.



الشكل 3-3 توضع الهاتف الذكي الذي يقوم بجمع معطيات المركبة [44]

يمثل الشكل 3-4 الواجهة الأمامية للبرنامج أثناء القيادة.



الشكل 3-4 الواجهة الأمامية للبرنامج DriveSafe أثناء القيادة [44]

3-2-2- مجموعة المعطيات الناتجة UAH Driveset

حجم ملفات مجموعة المعطيات هو 3.91GB وتحتوي على ما يقارب 500 دقيقة من المعطيات الحقيقية.

تتألف مجموعة المعطيات من مجموعة من المجلدات، كل مجلد يمثل معطيات خاصة برحلة معينة. على سبيل المثال المجلد (20151120133502-26km-D2-AGGRESSIVE-MOTORWAY) يحوي معطيات رحلة قام بها السائق الثاني على طريق رئيسي وتم محاكاة نمط القيادة العدواني في التاريخ وقطع مسافة قدرها 26 كيلو متر.

يحوي المجلد ملف الفيديو للمنظر الأمامي للمركبة لكامل الرحلة ويحوي 9 ملفات أخرى. تحوي هذه الملفات معطيات الحساسات غير المعالجة Raw Data من حساسي تحديد الموقع وحساس العطالة. كما تحوي معطيات تمت معالجتها مثل سمات مستخلصة من الصور الأمامية للمركبة.

يوجد أيضاً معطيات تم توليدها عبر تطبيق الخوارزميات المستخدمة في البرنامج DriveSafe وهي الاحداث التي تم كشفها من نمط كشف تسارع، كشف ميلان عن الطريق وغيرها من الأحداث، بالإضافة إلى نمط القيادة الحالي ومعلومات أخرى توصف طريقة القيادة. (لا نهتم في المقاربة المقترحة بهذه المعطيات كونها نتيجة الخوارزميات المستخدمة – نهتم فقط بالمعطيات الخام Raw Data بالإضافة إلى السمات المستخرجة من الصور الأمامية للمركبة)

يحوي كل ملف على مجموعة أعمدة، يمثل العمود الأول التوقيت الزمني للسطر timestamp وذلك لتتمكن من مزامنة الملفات مع بعضها.

3-2-2-1- Raw Data المعطيات غير المعالجة

3-2-2-1-1- GPS معطيات حساس تحديد الموقع

اسم الملف هو RAW_GPS، ويحوي معطيات حساس تحديد الموقع بتردد تقطيع قدره 1Hz هذه المعطيات بترتيب وردتها في الملف:

- التوقيت timestamp
- السرعة Speed Km/h
- احداثيات الطول degree
- احداثيات العرض degree
- الارتفاع meters
- الدقة العمودية degree
- الدقة الافقية degree
- الانحراف (degree) course
- تغيير الانحراف (degree) course variations

3-2-2-1-2- Inertial sensor معطيات حساس العطالة

اسم الملف هو RAW_ACCELEROMETERS، ويحوي على معطيات حساسات العطالة بتردد هو 10Hz، هذه المعطيات بترتيب ورودها في الملف:

- التوقيت timestamp
- متحول منطقي يعبر عن كون النظام مفعلاً أما لا (قراءات صحيحة او يجب اهمالها)
- التسارع حول المحور X (Gs)
- التسارع حول المحور Y (Gs)
- التسارع حول المحور Z (Gs)
- التسارع حول المحور X بعد تطبيق مرشح كالمن (Gs)

- التسارع حول المحور Y بعد تطبيق مرشح كالمن (Gs)
- التسارع حول المحور Z بعد تطبيق مرشح كالمن (Gs)
- الزاوية حول X (degree)
- الزاوية حول Y (degree)
- الزاوية حول Z (degree)

3-2-2-2-Processed Data المعطيات المعالجة

تبدأ أسماء الملفات من هذا النمط بـ "PROC" وهي ثلاثة ملفات:

3-2-2-2-1- السمات المستخلصة من الصور الأمامية الخاصة بميلان المركبة عن المنتصف :

اسم الملف هو PROC_LANE_DETECTION وتحتوي هذه المعطيات بترتيب ورودها في الملف:

- التوقيت timestamp
- بعد المركبة عن خط الطريقة الفاصل car position relative to lane center (meters)
- ميلان المركبة عن انحناء خط الطريق الفاصل car angle relative to lane curvature (degree)
- عرض الطريق (meters)
- حالة خوارزمية التعرف على خط المنتصف = 2 = 1 = undetected, 0 = initialization, [-1 = calibrating, detected/running]

3-2-2-2-2- السمات المستخلصة من الصور الأمامية الخاصة بكشف المركبات الأمامية

اسم الملف هو PROC_VEHICLE_DETECTION ويحتوي هذه المعطيات بترتيب ورودها في الملف:

- التوقيت timestamp
- المسافة عن المركبة الأمامية في المسار الحالي current lane (-1 تعني لا يوجد مركبة أمامية)
- زمن التأثير في المركبة الأمامية time to impact to ahead vehicle (ثواني)
- عدد المركبات التي تم كشفها في الصورة الحالية
- السرعة من حساس تحديد الموقع Km/h نفس القيمة الموجودة في الملف الخاص بحساس تحديد الموقع.

3-2-2-2-3- open street map الخاصة بالمعطيات

اسم الملف هو PROC_OPENSTREETMAP_DATA ويحوي هذه المعطيات بترتيب ورودها في الملف:

- التوقيت timestamp
- السرعة العظمى للطريق الحالي Km/h
- موثوقية السرعة العظمى (0 = unknown, 1 = reliable, 2 = used previously obtained max speed, 3 = estimated by type of road)
- نوع الطريق
- عدد المسارات ضمن الطريق
- المسار الحالي المقدر (1 = right lane, 2 = first left lane, 3 = second left lane ...)
- احداثية الطول المستخدمة لاستحضار المعلومات السابقة من خدمة open street maps
- احداثية العرض المستخدمة لاستحضار المعلومات السابقة من خدمة open street map
- تأخير الاستجابة للخدمة
- السرعة من حساس تحديد الموقع (نفس القيمة المذكورة في الملف الخاص بحساس تحديد الموقع).

اعتمدنا في المقارنة المقترحة على معطيات من الملفات التالية:

- RAW_GPS
- RAW_ACCELEROMETERS
- PRO_LANE_DETECTION

3-2- شعاع المعطيات المقترح

وجدنا من الدراسات السابقة أن الزوايا والسرعة الخطية والتسارع الخطي هي أهم المعطيات التي يمكن أن تعبر تغييراتها عبر الزمن عن أنماط القيادة المختلفة والتميز بينها. وبالتالي سيتضمن شعاع المعطيات المقترح هذه المعطيات بشكل أساسي. تعبر زاوية المركبة بالنسبة لخط منتصف الطريق وتغييراتها عن مدى التزام السائق بمسار الطريق الحالي. كما أن تغييرات هذه القيمة السريعة تعكس سلوكاً عدوانياً على عكس التغييرات البطيئة التي تعكس سلوكاً مشتملاً أو حالة إعياء أثناء القيادة. ومنه نقترح أن يتضمن شعاع المعطيات زاوية المركبة عن خط منتصف الطريق. كما أنه يمكن أن يتضمن شعاع المعطيات ميلان المركبة وتغير الميلان من حساس تحديد الموقع.

استخدمت بعض الدراسات السرعة المقروءة من حساس تحديد الموقع في حساب التسارع (اشتقاق السرعة) وحساب مقدار Jerk (اشتقاق السرعة مرتين). ذلك لأن التغييرات السريعة لهذين المقدارين تعكس سلوكاً عدوانياً في القيادة. اقتراب المركبة بشكل كبير من المركبات الأخرى أو الأجسام الأمامية يعكس نمط قيادة غير آمن. سواء كانت تغييرات المسافة عن هذه الأجسام سريعة في حالة القيادة العدوانية أو بطيئة في حالة التثنت أثناء القيادة. وبالتالي نقترح أن يتضمن شعاع المعطيات تقدير احتمال الصدم المحسوب من الصورة الأمامية للمركبة بالاعتماد على النموذج DRONET.

الجدول 3-1 شعاع المعطيات المقترح

المعطيات المستخدمة	المعلومة التي تقدمها
1	التسارع حول المحور Y (اتجاه حركة المركبة).
2	التسارع حول المحور X (الانعطاف).
3	التسارع حول المحور Z (تغير ميلان المركبة وحركتها أثناء المرور فوق مطب على سبيل المثال).
4	الزاوية حول المحور X (تفيد في التعرف على اهتزاز المركبة أثناء الحركة).
5	الزاوية حول المحور Y (تفيد في التعرف على اهتزاز المركبة أثناء الحركة).
6	الزاوية حول المحور Z (تفيد في التعرف على حركة السيارة أثناء الالتفاف والانعطاف).
7	السرعة الخطية على المحور Y (سرعة المركبة).
8	ميلان المركبة من حساس تحديد الموقع (تفيد في التعرف على حركة السيارة أثناء الالتفاف).
9	تغيير ميلان المركبة بالدرجات من حساس تحديد الموقع (تفيد في التعرف على حركة السيارة أثناء الالتفاف).
10	التسارع محسوباً من السرعة (التغييرات الكبيرة تعكس السلوك العدواني).

11	اشتقاق التسارع المحسوب من السرعة Jerk	التغييرات الكبيرة تعكس السلوك العدواني
12	زاوية انحراف المركبة عن خط منتصف المسار	تفيد في إعطاء مؤشر عن مدى التزام السائق بالمسار المحدد أثناء القيادة
13	تقدير احتمال صدم المركبة للأجسام الأمامية	يفيد في إعطاء معلومات عن مدى قرب المركبة أثناء القيادة من المركبات أو الأشخاص في حال تواجدهم

3-3- نموذج تقدير احتمال الصدم DRONET


البنية DRONET هي بنية شبكة عصبونية تم تطويرها لتستخدم ضمن الطائرات ذاتية القيادة Autonomous Drones لإعطائها إمكانية التنقل ضمن طرقات المدينة. دخل البنية هو صورة أمامية لكاميرا أمامية مثبتة في مقدمة الطائرة وخرج البنية هو زاوية الالتفاف Steering Angle وتقدير احتمال الصدم Collision Probability. وبالتالي يمكن أن تستخدم هذه البنية لتعطي الطائرة ذاتية القيادة القدرة على الطيران ضمن الطرقات. يطلق على هذه الطريقة في تحديد المسار للطائرة بتعلم الطيران من خلال القيادة Learning to fly by driving. تستطيع الطائرة تفادي العقبات ضمن الطرقات (سيارات - أشخاص - دراجات هوائية ...). من خلال الاعتماد على تقدير احتمال الصدم الذي توفره البنية ضمن شعاع الخرج. النموذج موجود بينيته وأوزانه بشكل مفتوح على الانترنت ومتاح للاستخدام من قبل الباحثين.

تم تدريب البنية باستخدام صور مُجمعت من كاميرات أمامية مثبتة على سيارات ودراجات هوائية بهدف أن تكون البنية الناجمة قادرة على توليد زوايا انعطاف بحيث تلتزم الطائرة بمسار الطريق وتتجنب العوائق المختلفة المتواجدة في الطرقات من مركبات ومشاة وغيرها.



الشكل 3-5 الطائرة ذاتية القيادة التي تم العمل عليها في تطوير النموذج DRONET

يبين الشكل 3-6 النموذج DRONET. دخل النموذج هو صورة رمادية (200 * 200) والخرج هو قيمتين الأولى هي تقدير احتمال الصدم Probability Collision والثانية هي زاوية القيادة Steering angle. [7]



الشكل 3-7 بنية النموذج DRONET [7]

يوضح الشكل 3-7 بنية النموذج DRONET وبشكل خاص الجزء المشترك للشبكة المسؤول عن توليد كلا القيمتين (زاوية الالتفاف - تقدير الصدم). تعتمد البنية المشتركة بشكل أساسي على البنية RESNET-8 (with 3 Residual blocks) كما في الشكل 3-7-b تليها Dropout بقيمة 0.5 تليها RELU. يلي الجزء المشترك جزئيين كلاً منهما خاص بأحد القيمتين الناتجتين (زاوية الالتفاف - تقدير الصدم) وهذين الجزئيين هما fully connected network. [7]

ما يميز البنية المستخدمة RESNET هو أنها تحوي وصلات إضافية تم اضافتها لتغلب على مشكلة Exploring/Vanishing Gradient أثناء مرحلة التدريب. [7]

تم توفير البنية مع الأوزان ليتم استخدامها من قبل الجميع من خلال الرابط [8].

3-4- إعداد المعطيات ومزامنتها

بعد دراسة مجموعة المعطيات المقترحة والحساسات التي نود استخدامها في التنفيذ العملي، اقترحنا النقاط التالية:

- اختيار طول النافذة الزمنية المنزلة: مجموعة المعطيات UAH-Driveset تتضمن معطيات غير معالجة من الحساسات ومعطيات تمت معالجتها باستخدام مرشحات (مرشح كالمن)، كما تتضمن أحداث قيادة تم كشفها باستخدام خوارزميات معينة مذكورة بالمقالات الخاصة بمجموعة المعطيات [47] - [46]. قمنا بمراجعة الأطوال الزمنية لجميع الأحداث التي تم كشفها عبر مجموعة المعطيات وقمنا بتحديد أطول حدث زمنياً وهو حدث خروج عن مسار الطريق في حالة القيادة مع إعياء Drowsiness حيث بلغ طول هذا الحدث 5.2 ثانية وبالتالي يمكن أن نقترح بشكل مبدئي طول للنافذة الزمنية المنزلة 6 ثواني.

يجب أن يكون طول النافذة الزمنية كافياً ليحتوي كل الأحداث المميزة لأنماط القيادة وخاصة تلك التي تتميز بنمط قيادة معين من خلال التغيرات البطيئة لها أو السريعة في نمط قيادة آخر (طول حدث الانحراف عن مسار الطريق يختلف بين نمط القيادة العدواني والطبيعي والقيادة بحالة إعياء).

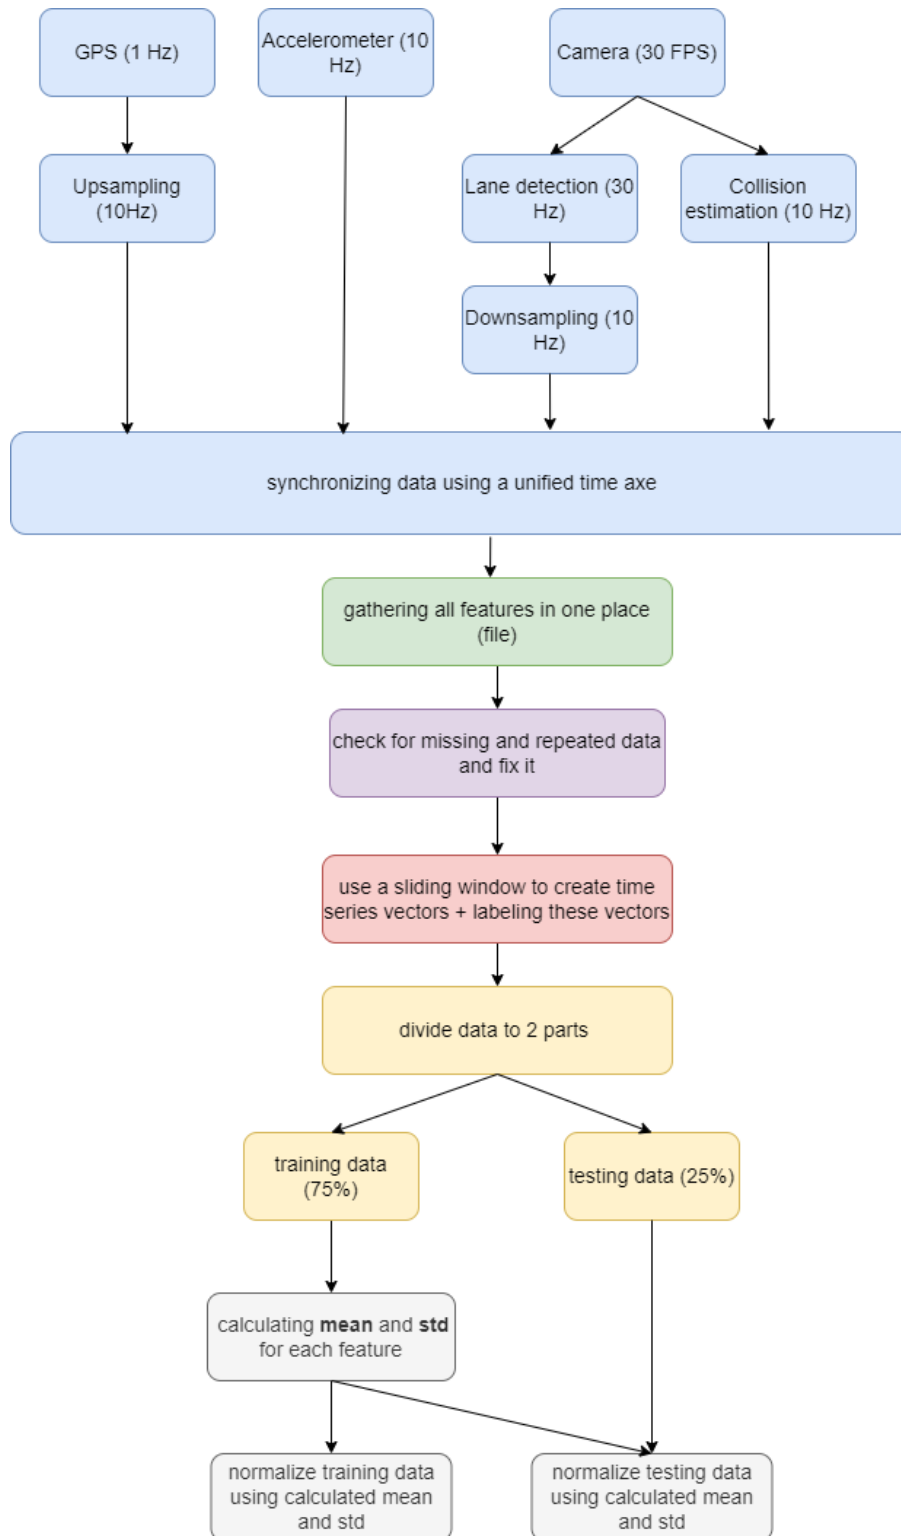
- مزامنة المعطيات: الحساسات المستخدمة لدينا هي كاميرا 30 FPS وحساس تحديد موقع GPS يعمل بتردد تحصيل 1 Hz وحساس تسارع يعمل بتردد تحصيل 10 Hz وبالتالي يجب اختيار تردد موحد لمجموعة المعطيات ولعمل الحساسات ضمن التنفيذ العملي لاحقاً.

نعلم أن حساسات تحديد الموقع التجارية يمكن رفع تردد تحصيلها حتى 10 Hz لذا يمكن اختيار تردد التحصيل الموحد 10 Hz ورفع تردد التحصيل لقيم المعطيات الخاصة بحساس تحديد الموقع (من خلال استخدام الاستيفاء الرياضي) وذلك ضمن معالجة المعطيات في Driveset قبل استخدامها في عملية التدريب. على أن نستخدم تردد التحصيل 10 Hz لحساس تحديد الموقع في التنفيذ العملي لاحقاً.

- إضافة تقدير الصدم إلى مجموعة المعطيات Driveset: المرور على كامل التسجيلات الخاصة بالرحلات ضمن Driveset (500 min of video) وحساب تقدير الصدم بتردد 10 Hz ومزامنة القيم مع باقي المعطيات.

- حساب القيم المعيارية لكل نقاط مجموعة المعطيات: حساب المتوسط والانحراف المعياري لجزء من المعطيات (الجزء الخاص بالتدريب) واستخدام هذه القيم في حساب القيم المعيارية لكامل المعطيات (الجزء الخاص بالتدريب والجزء الخاص بالاختبار).

يوضح المخطط التالي عملية اعداد المعطيات مع الاخذ بعين الاعتبار النقاط السابقة:



الشكل 3-8 مخطط إعداد المعطيات ومزامنتها

3-5- الخوارزمية المقترحة

كما بيّنا سابقاً أن خوارزميات التعلم العميق التي تتعامل مع السلاسل الزمنية ستكون الخيار الأفضل وذلك لعدة أسباب هي:

- تعريف أنماط القيادة لدينا هو مضمّن في معطيات تم تسجيلها لسائقين قاموا بمحاكاة أنماط القيادة المختلفة وبالتالي أي مقارنة تتضمن اختيار عتبة أو بناء نظام استدلاي أو مطابقة نماذج لن نستطيع استخدامها الا بعد دراسة مطولة لأنماط القيادة وتعريفها بدقة في قواعد واضحة. وبالتالي خيارنا الوحيد هو المقاربات المعتمدة على التعلم من المعطيات .Data Driven Approaches

- المقاربات المعتمدة على التعلم من المعطيات هي إما خوارزميات تعلم الآلة أو خوارزميات التعلم العميق. تتطلب خوارزميات تعلم الآلة عند التعامل مع معطيات ذات ترابط زمني استخراج سمات إحصائية معينة تعبر عن هذا الترابط الزمني بينما تتيح خوارزميات التعلم العميق إمكانية تعلم هذه السمات الإحصائية من المعطيات ذاتها دون اللجوء إلى دراستها والتنبؤ بالطرق الإحصائية المطلوبة لتمثيل السمات بشكل يمكن من الحصول على نموذج تصنيف بدقة عالية. نقترح استخدام أحد الخوارزميات التالية:

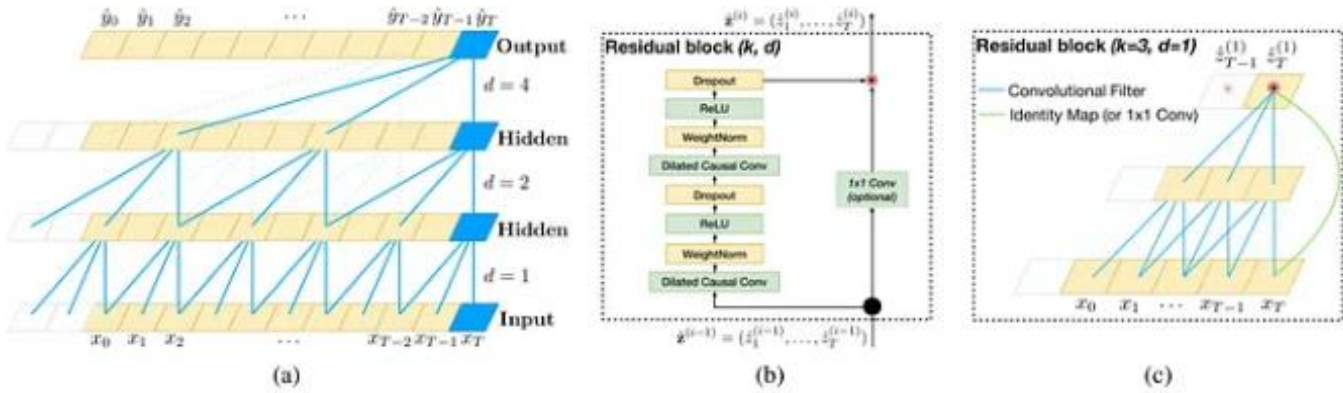
1- الشبكات الالتفافية الزمنية Temporal Convolutional Network TCN

2- شبكات LSTM

3- شبكات GRU

أكثر البنى استخداماً في التعامل مع السلاسل الزمنية بشكل عميق هي Transformers إلا أن هذه البنى تحتاج إلى عدد كبير من المعطيات لنحصل على دقة جيدة لذلك لم نقترح استخدام هذه البنية في تطوير خوارزمية كشف نمط القيادة التي يتم العمل عليها.


شبكات Temporal Convolutional Network TCN



الشكل 3-9 الشبكات Temporal Convolutional Network TCN

أثبتت الشبكات الالتفافية العصبونية CNN قدرتها على التعامل مع المعطيات ذات الترابط الزمني، ولم يعد التعامل مع هذا النوع من المعطيات حكراً على الخوارزميات العودية Recurrent Neural Network RNN التي تعاني من مشكلة Vanishing gradient. حيث يوجد العديد من الأبحاث السابقة التي اعتمدت هذه الشبكات في مسائل كشف نمط القيادة ومسائل ذات طبيعة مشابهة وحصلت على نتائج تصنيف جيدة.

يتم استبدال الترابط المكاني في المعطيات (التي لا تملك ترابطاً مكانياً) بالترابط الزمني (معطيات مترابطة زمنياً)، واستخدام جداءات تلاف سببية واستخدام مرشحات من النمط dilated convolutions، كما في الشكل 3-9، وذلك للتحكم بمساحة الرؤية Receptive field التي تحدد العمق الزمني الماضي الذي أدى إلى حساب القيمة الحالية. يمكن الاطلاع على طريقة حساب معاملات الشبكة للحصول على Receptive field بطول معين من المرجع [62].



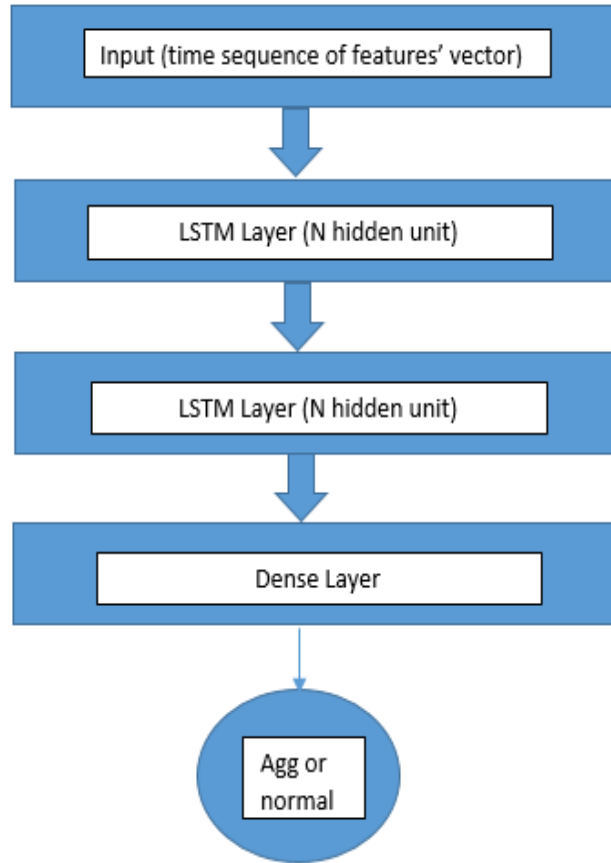
A casual convolution with filter kernel size $k=2$

الشكل 3-10 جداء التلاف السببي

الشبكات Long Short Memory Term LSTM

عرضنا في فصل الدراسة المرجعية البنية LSTM وتحدثنا عن أهمية هذه البنية في حل مشكلة Eploding/vanishing gradient. حيث تعتبر من أكثر البنى استخداماً للتعامل مع السلاسل الزمنية. يمكن لشبكة LSTM بطبقة وحيدة أن تستخرج

السمات الإحصائية وتصنف المعطيات بناءً على هذه السمات. إلا أن استخدام عدة طبقات يمكّن من استخراج سمات أكثر تعقيداً كما هو الحال في الشبكات العصبونية الالتفافية CNN حيث أن إضافة مرشحات ضمن عدة طبقات يؤدي إلى استخراج سمات معقدة يتم تعلمها من المعطيات. كذلك الأمر بالنسبة لشبكات LSTM حيث يمكن باستخدام طبقتين أو أكثر أن نحصل على سمات أكثر تعقيداً. نقترح استخدام طبقتين كبداية. يبين الشكل 3-11 البنية المقترحة Stacked LSTM

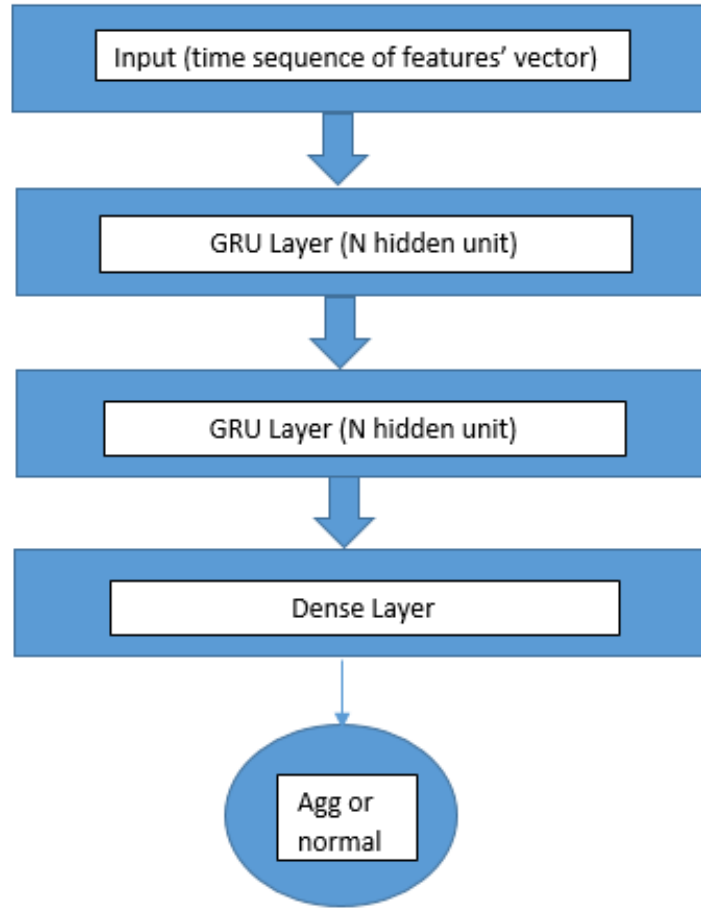


الشكل 3-11 البنية Stacked LSTM المقترحة

تتألف الطبقة الأولى من عدد من الوحدات الداخلية N hidden units تجعل شعاع الحالة للطبقة بطول N. نستخدم عدد الوحدات الداخلية ذاته للطبقة الثانية. خرج الطبقة الثانية (شعاع بطول N) هو دخل للطبقة الأخيرة Fully connected network والخرج هو نتيجة التصنيف (احتمال انتماء السلسلة الزمنية إلى الصنف الأول أو الثاني).

الشبكات GRU Gated Recurrent Unit

عرضنا في فصل الدراسة المرجعية البنية GRU وتحدثنا أنها بنية مشابهة لشبكة LSTM. تعد أيضاً من أكثر البنى استخداماً للتعامل مع السلاسل الزمنية. كما هو الأمر في حالة البنية LSTM نقترح استخدام طبقتين. يبين الشكل 3-12 البنية المقترحة Stacked GRU.



الشكل 3-12 البنية Stacked GRU المقترحة

الفصل الرابع

التنفيذ العملي والنتائج العملية

نعرض في هذا الفصل التنفيذ العملي والنتائج العملية ومقارنتها مع الدراسات السابقة.

الخطوة الأولى في التنفيذ العملي هي إعداد المعطيات واستخدامها في تدريب النماذج المقترحة في الفصل السابق. يلي ذلك البحث عن النموذج الأمثل من خلال تغيير قيم المعاملات hyper parameters، استخدمنا المعيار F1-score لتحديد دقة النماذج على مجموعة المعطيات المخصصة للاختبار وذلك لنتمكن من المقارنة مع نتائج الدراسات السابقة.


4-1- اعداد مجموعة المعطيات

كما ذكرنا سابقاً في الفصل السابق المعطيات ضمن مجموعة المعطيات UAH Driveset موجودة ضمن ملفات حسب نوع المعطيات وكل نوع له تردد تحصيل مختلف. وبالتالي لنتمكن من استخدام هذه المعطيات لابد من مزامنتها وتوحيد تردد التحصيل لكل منها وتوحيد مجالات قيمها وغيرها من الإجراءات التي سنذكرها فيما يلي:

- **توحيد تردد التحصيل للحساسات المستخدمة:** تردد معطيات حساس تحديد الموقع GPS هو 1 Hz وتردد معطيات حساسات العطالة هي 10 Hz بينما ميلان المركبة عن خط منتصف المسار يتم حسابه على كل صورة من صور الكاميرا الخلفية بتردد هو 30 Hz. اعتمدنا التردد الموحد 10 Hz وذلك من خلال رفع تردد معطيات حساس تحديد الموقع (باستخدام الاستيفاء الرياضي ومعادلة خط مستقيم بين كل نقطتين) وخفض تردد المعطيات المستخلصة من الصور إلى 10 Hz. بينما بقيت معطيات حساسات العطالة كما هي.
- **تعويض المعطيات المفقودة وحذف المعطيات المكررة:** تم كشف المعطيات المكررة بكل ملف باستخدام توقيت التحصيل timestamp، وتم تعويض المعطيات المحذوفة من خلال عملية استيفاء رياضي.
- **حذف الأسطر التي تحوي معطيات غير صحيحة:** بالاستعانة بالعمود system activated في ملف معطيات حساسات العطالة تم حذف الأسطر التي كان فيها الحساس غير مفعّل.
- **استخلاص تقدير الصدم من الفيديوهات المسجلة لكل رحلة:** بعد مقاطعة بداية ونهاية المحور الزمني لقيم الحساسات في جميع الملفات، تم تثبيت بداية كل رحلة ونهايتها على اعتبار توافر كامل المعطيات ضمن هذا المجال بشكل كامل

ومنها التسجيل الخاص بالكاميرا الخلفية. أي تم اقتطاع الجزء المهم من الفيديو والمرور على كل الصور ضمنه بتردد المخفض 10 Hz وحساب خرج النموذج Dronet على كل صورة لحساب تقدير الصدم. قمنا باقتطاع الأجزاء الظاهرة من المركبة في الصور وإعادة حجم الصورة بعد الاقتطاع إلى الحجم 200*200 . Resize

- **مزامنة جميع المعطيات وتجميعها في ملف واحد:** تم وضع نقاط زمنية محددة على المحور الزمني ضمن المجال الذي ذكرناه سابقاً الناجم عن مقاطعة معطيات الملفات مع بعضها لكل رحلة. والفرق بين كل نقطتين زمنيتين هو 0.1 ثانية. وباستخدام الاستيفاء الرياضي تم حساب كامل المعطيات عند كل نقطة زمنية من هذا المحور الزمني المعياري. بعد توحيد التوقيت لكامل المعطيات تم جمعها في ملف واحد.
- **تقسيم المعطيات إلى سلاسل زمنية وإضافة الوسم:** بعد تقسيم المعطيات إلى سلاسل زمنية بطول معين وباستخدام التراكب Overlapping بنسبة معينة كما في الشكل 4-1، تم إضافة الوسم Label إلى هذه السلاسل حسب نوع القيادة المذكور ضمن مجموعة المعطيات.



الشكل 4-1 تقسيم المعطيات باستخدام نافذة منزلقة وبوجود تراكب

تم استخدام أطوال مختلفة للسلاسل الزمنية (80 time steps – 60 time steps – 40 time steps) علماً أن الخطوة الزمنية طولها 0.1 ثانية. تم استخدام تراكب بنسبة 80% وذلك لزيادة عدد النقاط في مجموعة المعطيات التي سيتم تدريب النموذج المدروس عليها.

- **خلط المعطيات وتقسيمها إلى جزئين (جزء خاص بالتدريب وجزء خاص بالاختبار):** بعد خلط نقاط مجموعة المعطيات الناجمة عن الخطوة السابقة، نقسمها إلى جزئين بنسبة 75% – 25% للتدريب والاختبار على الترتيب.
- **توحيد مجال القيم للمعطيات:** تم حساب المتوسط والانحراف المعياري لكل نوع من المعطيات المستخدمة وذلك للمجموعة المخصصة للتدريب، واستخدام هذه القيم لحساب Z score لكل قيمة في مجموعة المعطيات بجزئها الخاص بالتدريب والخاص بالاختبار.

4-2- F1-score المعيار

المعيار المستخدم في اختبار صحة نموذج التصنيف هو F1-score. تبين المعادلات التالية طريقة حساب المعامل F1-score بالاعتماد على Accuracy و Precision.

$$\begin{aligned} \text{Accuracy} &= \frac{TP + TN}{TP + TN + FP + FN} \\ \text{Precision} &= \frac{TP}{TP + FP} \\ \text{Recall} &= \frac{TP}{TP + FN} \\ \text{F1 - score} &= \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \end{aligned}$$

حيث أن TP تعني True Positive (النموذج أعطى قيمة 1 والقيمة الحقيقية هي 1). على اعتبار أن 1 هي اختيار الصنف الأول و 0 هي اختيار الصنف الثاني.

و TN تعني True Negative أي أن النموذج أعطى قيمة 0 والقيمة الحقيقية هي 0

و FP تعني False Positive أي أن النموذج أعطى قيمة 1 والقيمة الحقيقية هي 0

و FN تعني False Negative أي أن النموذج أعطى قيمة 0 والقيمة الحقيقية هي 1

4-3- النتائج العملية والتنفيذ العملي

4-3-1- نموذج تصنيف لنمطي قيادة (طبيعي - عدواني)

أول نموذج قمنا باقتراحه هو نموذج الشبكة الالتفافية الزمنية Temporal Convolutional Network TCN. تم استخدام المكتبة Keras-TCN واستخدام المعاملات الظاهرة في الكود الموجود ضمن الشكل 4-2. شعاع المعطيات المستخدم هو ذاته الشعاع المقترح في الفصل السابق.

تم التدريب على المجموعة المخصصة للتدريب واختبار صحة النموذج بعد التدريب على المجموعة المخصصة للاختبار. لم يعطي النموذج دقة جيدة مقارنة بالنماذج Stacked LSTM و Stacked GRU.

```

TCN(
    nb_filters=64,
    kernel_size=3,
    nb_stacks=1,
    dilations=(1, 2, 4, 8, 16, 32),
    padding='causal',
    use_skip_connections=True,
    dropout_rate=0.0,
    return_sequences=False,
    activation='relu',
    kernel_initializer='he_normal',
    use_batch_norm=False,
    use_layer_norm=False,
    use_weight_norm=False,
    go_backwards=False,
    return_state=False,
    **kwargs
)

```

الشكل 4-2 المعاملات المستخدمة في النموذج TCN المستخدم

قمنا بتدريب النموذج Stacked LSTM بطبقتين من أجل عدة معاملات hyper parameters هي طول النافذة الزمنية المولدة للسلاسل الزمنية (4 ثانية - 6 ثواني - 8 ثواني)، وعدد الوحدات الداخلية للبنية (hidden units 80 - 100 - 120 - 125). كذلك الأمر بالنسبة لنموذج Stacked GRU.

استخدمنا المعاملات التالية في تدريب النماذج المقترحة

الجدول 4-1 المعاملات المستخدمة في تدريب النموذجين Stacked LSTM و Stacked GRU

Optimizer	Adam
Learning rate	0.001
Epochs	200
Batch size	16

تم استخدام شعاع المعطيات المقترح في الفصل السابق والاختبار وتبين أن حذف السميتين (مشتقي السرعة الأول والثاني) يعطي نتائج أفضل. وقمنا باختبار حالتين لشعاع المعطيات: الأول هو الشعاع المقترح باستثناء (مشتقي السرعة الأول والثاني) وتقدير

الصدمة) والثاني هو الشعاع المقترح باستثناء (مشتقي السرعة الأول والثاني). قمنا بالتدريب على مجموعة المعطيات المخصصة للتدريب واختبار النموذج على المجموعة المخصصة للاختبار وحساب المعيار F1-score لكل نموذج.

يبين الجدول 2-4 والجدول 3-4 نتيجة التدريب مع تغيير المعاملات (عدد الوحدات الداخلية hidden units – طول النافذة الزمنية المنزلة) بدون استخدام تقدير الصدمة كسمة إضافية ضمن شعاع المعطيات.

الجدول 2-4 نتائج تدريب نموذج **Stacked LSTM** دون اعتبار احتمال الصدمة

Window length	80	100	120	125
4 secs	%94	%92.6	%92	%93.4
6 secs	%88.5	%87.7	%87.8	%87.7
8 secs	%88.7	%88.6	%88.1	%85.8

الجدول 3-4 نتائج تدريب نموذج **Stacked GRU** دون اعتبار احتمال الصدمة

Window length	80	100	120	125
4 secs	%95.8	%97.5	%97	%93.9
6 secs	%90.2	%94.2	%94.3	%95.4
8 secs	%92.7	%94.4	%91.5	%92.6

نلاحظ من الجدولين السابقين أن أفضل نتيجة حققها نموذج stacked LSTM هي %94 بينما أفضل نتيجة حققها نموذج stacked GRU هي %97.5 من أجل شعاع معطيات طوله 10 (شعاع المعطيات الأول).

يبين الجدول 4-4 والجدول 5-4 نتيجة التدريب مع تغيير المعاملات (عدد الوحدات الداخلية hidden units – طول النافذة الزمنية المنزلة) مع استخدام تقدير الصدمة كسمة إضافية ضمن شعاع المعطيات.

الجدول 4-4 نتائج تدريب نموذج **Stacked LSTM** مع اعتبار احتمال الصدمة

Window length	80	100	120	125
4 secs	94.4	%94.4	%94.5	%94.8
6 secs	%93.3	%92.8	%90.5	%88
8 secs	%88.7	%85.5	%89.5	%89

الجدول 4-5 نتائج تدريب نموذج Stacked GRU مع اعتبار احتمال الصدم

Window length	80	100	120	125
4 secs	%96.3	%96.8	%98.3	%97
6 secs	%94.3	%95.6	%95.7	%95.8
8 secs	%95.5	%96.3	%93.5	%94

لاحظ من الجدولين السابقين أن أفضل نتيجة حققها نموذج stacked LSTM هي %94.8 بينما أفضل نتيجة حققها نموذج stacked GRU هي %98.3 من أجل شعاع معطيات طوله 11 (شعاع المعطيات الثاني).

يبين الجدول 4-6 عدد المعاملات الخاصة بكل نموذج. يمكن ملاحظة الفرق بين النماذج المعتمدة على الخلية GRU والمعتمدة على LSTM. ومن أجل الحالتين مع وبدون تقدير صدم. (عدد المعاملات ذاته في الحالات التالية - الدخل هو سلسلة زمنية بطول 4 ثواني - 6 ثواني - 8 ثواني)

الجدول 4-6 عدد المعاملات الخاص بكل نموذج

Cell type	80	100	120	125
LSTM /10	80802	125002	178802	193752
11	81122	125402	179282	194252
GRU /10	61122	94402	134882	146127
11	61362	94702	135242	146502

يرتبط عدد المعاملات بقدرة النموذج على التعلم من مجموعة المعطيات المتاحة. كما يرتبط عدد المعاملات بسرعة الحصول على الخرج عند التنفيذ العملي. من الجدول السابق يتضح الفرق في عدد المعاملات بين الحالتين GRU vs LSTM cell. لذا من المتوقع أن يكون النموذج المعتمد على GRU cell أسرع في مرحلة التعلم وسيعطي نتائج أفضل بوجود عدد أكبر من الوحدات الداخلية (دقة أفضل). وهذا ما يمكن ملاحظته من النتائج السابقة.

نلاحظ أن نتائج النماذج Stacked GRU و Stacked LSTM تكون أفضل في حالة نافذة زمنية أصغر (حالة نافذة زمنية بطول 6 ثواني حققت نتائج أفضل من الحالة التي تكون فيها بطول 8 ثواني وكذلك الحال عند مقارنة نتائج النافذتين الزمنيتين 6 ثواني و 4 ثواني) وذلك لأن تصغير النافذة الزمنية يؤدي إلى عدد نقاط أكبر في مجموعة المعطيات الخاصة بتدريب النموذج. يبين الجدول التالي عدد النقاط المستخدمة في التدريب في حالة استخدام مجموعة من النوافذ الزمنية متغيرة الطول وباستخدام تراكم قدره %80 من أجل نمطي القيادة (آمن - عدواني) ضمن مجموعة المعطيات.

الجدول 4-7 عدد النقاط في مجموعة المعطيات من أجل نافذة زمنية متغيرة (الخاصة بالتدريب)

خطوة زمنية	10	20	40	60	80	
Normal	12954	6472	3231	2152	1161	
Aggressive	7830	3913	1954	1300	974	

من النتائج السابقة نستنتج أن أفضل نموذج من حيث الدقة هو Stacked GRU بعدد وحدات داخلية 120 وطول نافذة منزلقة هو 40 خطوة زمنية (سلسلة زمنية بطول 4 ثواني) وبوجود تقدير احتمال الصدم كسمة ضمن شعاع السمات. دقة النموذج هي 98.3%. ومنه نستنتج أن إضافة احتمال الصدم كسمة ضمن شعاع المعطيات له أهمية في تمييز نمط القيادة الطبيعي والآمن عن نمط القيادة العدواني Aggressive.

باستخدام المكتبة Tensorflow lite نحصل على نموذج قابل للبرمجة ضمن نظام Android. زمن التنفيذ لنموذج على هاتف ذكي Redmi Note 10 Lite (طول نافذة زمنية هو 4 ثانية - نموذج stacked GRU بعدد وحدات داخلية 120) هو 29 ميلي ثانية. وبالتالي النموذج المقترح قابل للعمل بالزمن الحقيقي. كما تم اختبار النموذج على هاتف HTC بنظام Android 5.1 وكان زمن التنفيذ هو 69 ميلي ثانية.

مقارنة مع نتائج الدراسات السابقة

الدقة التي حصلنا عليها أفضل من النتائج الموجودة في الدراسات السابقة باستثناء الدراسة [4] حيث حصل على نتيجة تتجاوز 99% إلا ان النموذج المستخدم ليس من المتوقع أن يعمل على معطيات مختلفة عن المعطيات الموجودة في UAH Driveset وذلك لأن النافذة الزمنية المستخدمة هي 0.32 ثانية، وبتردد تحصيل للحساسات هو 50 Hz. برأيي هذا النموذج لن يتمكن من التدريب على معطيات أخرى وإعطاء دقة ماثلة كون تردد تحصيل المعطيات عالي والنافذة الزمنية ضيقة لدرجة أنها لن تكون قادرة على حصر كامل أحداث القيادة الخطيرة. كما أن هذه الدراسة لم تهتم بالتنفيذ العملي ولم تعطي أي معلومات عن كون النموذج قابل للعمل بالزمن الحقيقي، حالها حال معظم الدراسات التي اكتفت بعرض نتيجة التدريب دون الإشارة إلى كون النموذج الناتج قادراً على العمل بالزمن الحقيقي. يبين الجدول التالي مقارنة مع النتائج في الدراسة [4]

الجدول 4-8 مقارنة مع الدراسات السابقة في حالة كشف نمطي قيادة

Diab 2022	Koudairy 2021	
طوله 11 مع الاستعانة باحتمال الصدم	طوله 7	شعاع المعطيات
4 ثواني	0.32 ثانية	طول النافذة الزمنية
Stacked-GRU(120)	Stacked-LSTM (120)	النموذج المستخدم
98.3%	99.34%	دقة النموذج
بالاستعانة بمكتبة tensorflow lite على Android	لم يتطرق للتنفيذ العملي	التنفيذ العملي

4-3-2- نموذج تصنيف لأنماط القيادة الثلاثة (طبيعي - عدواني - حالة إعياء)

قمنا باستخدام نموذج Stacked GRU للتعرف على أنماط القيادة المتاحة ضمن مجموعة المعطيات وهي قيادة آمنة Safe - قيادة عدوانية Aggressive - قيادة بحالة إعياء Drowsy. وذلك لأن النموذج Stacked GRU حقق أفضل نتيجة في كشف نمطي القيادة الآمن والعدواني.

قمنا بتدريب النموذج Stacked GRU بطبقتين من أجل عدة معاملات hyper parameters هي طول النافذة الزمنية المولدة للسلاسل الزمنية (1 ثانية - 2 ثانية - 4 ثواني - 6 ثواني)، وعدد الوحدات الداخلية للبنية (80 - 100 - 120).

استخدمنا المعاملات التالية في تدريب النموذج المقترح

الجدول 4-9 المعاملات المستخدمة في تدريب النموذج Stacked GRU

Optimizer	Adam
Learning rate	0.001
Epochs	200
Batch size	16

قمنا باستخدام شعاعي المعطيات المذكورين سابقاً:

- شعاع المعطيات الأول (الشعاع المقترح باستثناء مشتقي السرعة الأول والثاني وتقدير الصدم).

- شعاع المعطيات الثاني (الشعاع المقترح باستثناء مشتقي السرعة الأول والثاني).

قمنا بالتدريب على مجموعة المعطيات المخصصة للتدريب واختبار النموذج على المجموعة المخصصة للاختبار وحساب المعيار F1-score لكل نموذج.

يبين الجدول 4-10 نتيجة التدريب مع تغيير المعاملات (عدد الوحدات الداخلية hidden units - طول النافذة الزمنية المنزلة) بدون استخدام تقدير الصدم كسمة إضافية ضمن شعاع المعطيات.

الجدول 4-10 نتائج تدريب النموذج Stacked GRU بدون اعتبار تقدير الصدم

	10 خطوة زمنية	20 خطوة زمنية	40 خطوة زمنية	60 خطوة زمنية
80	%98.3	%95.3	%92.6	%91.8
100	%98.7	%96.2	%94.3	%91.8
120	%98.2	%96.0	%95.1	%94.8

يبين الجدول 4-11 نتيجة التدريب مع تغيير المعاملات (عدد الوحدات الداخلية hidden units - طول النافذة الزمنية المنزلة) مع استخدام تقدير الصدم كسمة إضافية ضمن شعاع المعطيات.

الجدول 4-11 نتائج تدريب النموذج Stacked GRU مع اعتبار تقدير الصدم

	10 خطوة زمنية	20 خطوة زمنية	40 خطوة زمنية	60 خطوة زمنية
80	%98.2	%96.9	%93.1	%92.4
100	%98.0	%95.3	%93.5	%92.4
120	%97.0	%93.9	%94.8	%91.9

أفضل نتيجة من أجل شعاع المعطيات الأول هي عند استخدام نافذة زمنية بطول 10 خطوات زمنية (1 ثانية) وهي %98.7 بينما أفضل نتيجة من أجل شعاع المعطيات الثاني هي عند استخدام نافذة زمنية بطول 10 خطوات زمنية وهي %98.2. ومنه نستنتج أن إضافة سمة احتمال الصدم في حالة التمييز بين 3 أصناف لم تحسن النتائج بل أعطت نتائج متقاربة.

نلاحظ أن نتائج النموذج Stacked GRU تكون أفضل في حالة نافذة زمنية أصغر (حالة نافذة زمنية بطول 4 ثواني حققت نتائج أفضل من الحالة التي تكون فيها بطول 6 ثواني وكذلك الحال عند مقارنة النتائج الأخرى) وذلك لأن تصغير النافذة الزمنية يؤدي إلى عدد نقاط أكبر في مجموعة المعطيات الخاصة بتدريب النموذج. يبين الجدول التالي عدد النقاط المستخدمة في التدريب في حالة استخدام مجموعة من النوافذ الزمنية متغيرة الطول وباستخدام تراكب قدره 80% من أجل كل نمط من أنماط القيادة الموجود ضمن مجموعة المعطيات.

الجدول 4-12 عدد النقاط في مجموعة المعطيات عند تغيير طول النافذة الزمنية

	10 خطوة زمنية	20 خطوة زمنية	40 خطوة زمنية	60 خطوة زمنية	80 خطوة زمنية	
Normal	12954	6472	3231	2152	1161	
Aggressive	7830	3913	1954	1300	974	
Drowsy	9783	4889	2441	1625	1217	

مقارنة مع نتائج الدراسات السابقة

كذلك الأمر بالنسبة لكشف 3 أنماط قيادة، الدقة التي حصلنا عليها أفضل من النتائج الموجودة في الدراسات السابقة باستثناء الدراسة [4] حيث حصل على نتيجة تتجاوز 99% إلا ان النموذج المستخدم ليس من المتوقع أن يعمل على معطيات مختلفة عن المعطيات الموجودة في UAH Driveset وذلك لأن النافذة الزمنية المستخدمة هي 0.32 ثانية، وبتردد تحصيل للحساسات هو 50 Hz. كما ذكرت سابقاً برأيي هذا النموذج لن يتمكن من التدريب على معطيات أخرى وإعطاء دقة مماثلة كون تردد تحصيل المعطيات عالي والنافذة الزمنية ضيقة لدرجة أنها لن تكون قادرة على حصر كامل أحداث القيادة الخطيرة والقيادة في حالة الإعياء. يبين الجدول التالي مقارنة مع النتائج في الدراسات السابقة

الجدول 4-13 مقارنة نتائج النموذج المستخدم مع نتائج الدراسات السابقة في حالة كشف 3 أنماط

Diab 2022	Koudairy 2021	Y. Moukafih 2019	Saleh 2017	
طوله 10	طوله 13	طوله 12	طوله 9	شعاع المعطيات
1 ثانية	0.32 ثانية	5 دقائق	6.4 ثانية	طول النافذة الزمنية
Stacked-GRU(100)	Stacked-LSTM (120)	LSTM-FCN	Stacked LSTM (100)	النموذج المستخدم
98.7%	99.49%	95.88%	91%	دقة النموذج
بمكتبة tensorflow على Android	بالاستعانة lite	لم يتطرق للتنفيذ العملي	لم يتطرق للتنفيذ العملي	التنفيذ العملي

ملاحظة خاصة بمجموعة المعطيات UAH Driveset

تم اقتراح طول النافذة الزمنية لشعاع الدخل بناءً على سير كل الاحداث الواردة ضمن المعطيات المعالجة ضمن ملفات مجموعة المعطيات بحيث يكون للنافذة القدرة على الإحاطة بأطول حدث (الخروج عن مسار الطريق في حالة كانت القيادة Drowsy 5.2 ثانية).

وعلى اعتبار أن أحداث نمط القيادة Drowsy يمكن تمييزها عن أحداث نمط القيادة Aggressive من كونها تتميز بتغيرات بطيئة ومن كون نافذة زمنية بطول 1 ثانية قادرة على تمييز الأنماط بدقة عالية 98.7% لذا يمكن القول إن مجموعة المعطيات لم تشمل كل الأحداث المعرفة للأنماط الثلاثة.

عمل النموذج الحالي ضمن البيئة المحلية

ليس متوقفاً أن يعمل النموذج الحالي ضمن البيئة المحلية بالكفاءة المطلوبة وذلك بسبب الاختلاف بين شكل الطرقات التي تم جمع بيانات مجموعة المعطيات UAH Driveset ضمنها وبين الطرقات في البيئة المحلية. لتحقيق الكفاءة العالية، يمكن أن نستخدم البرنامج النهائي لجمع المعطيات كما تم جمعها في UAH Driveset وإعادة تدريب النموذج على المعطيات الجديدة. عرضنا في هذا الفصل المقارنة المقترحة لكشف نمط القيادة ضمن المركبات وحصلنا على نموذج بدقة عالية 98.3% على مجموعة المعطيات المستخدمة ويعمل بالزمن الحقيقي على نظام Android. بعد برمجة المقارنة المقترحة ضمن نظام Android

يمكن استخدامها في جمع مجموعة معطيات جديدة خاصة بالبيئة المحلية وتدريب نموذج مشابه للمعروض في المقارنة للحصول على برنامج تعرف على أنماط القيادة يعمل بكفاءة عالية ضمن طرق البيئة المحلية.

الخاتمة

قدمنا في هذه البحث مقارنة لكشف نمط القيادة باستخدام هاتف ذكي تعمل بالزمن الحقيقي. تعتمد المقارنة المقترحة بشكل أساسي على استغلال الميزات العتادية والقدرات الحاسوبية التي تتواجد في الهواتف الذكية التي أضحت منتشرة بكثرة وأصبحت تشهد تزايداً ملحوظاً في القدرات الحاسوبية والموارد الخاصة بها.

أثبتنا بشكل عملي أن خوارزمية التصنيف المقترحة في هذا البحث يمكن أن تتم برمجتها على أجهزة Android بالاعتماد على مكتبة Tensorflow Lite وبزمن تنفيذ لا يتجاوز 30 ميلي ثانية، أي أن البرنامج المعتمد على الخوارزمية المقترحة يعمل بالزمن الحقيقي.

النموذج النهائي المطور في هذا البحث لن يصلح للعمل في البيئة المحلية وذلك لاختلاف طبيعة الطرقات بين المدينة التي جمعت فيها مجموعة المعطيات UAH Driveset والبيئة المحلية. ولكن يمكن الاستفادة من البرنامج النهائي في بناء مجموعة معطيات جديدة محلية وتدريب خوارزمية التصنيف من جديد على المعطيات الجديدة المحلية والتي ستمثل أنماط قيادة محددة بأي توصيف مطلوب.

المراجع

- [1] Azadani, Mozghan Nasr, and Azzedine Boukerche. "Driving behavior analysis guidelines for intelligent transportation systems." *IEEE Transactions on Intelligent Transportation Systems* (2021).
- [2] Singh, Harpreet, and Ankit Kathuria. "Analyzing driver behavior under naturalistic driving conditions: A review." *Accident Analysis & Prevention* 150 (2021): 105908.
- [3] Saleh, Khaled, Mohammed Hossny, and Saeid Nahavandi. "Driving behavior classification based on sensor data fusion using LSTM recurrent neural networks." *2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC)*. IEEE, 2017.
- [4] Khodairy, Moayed A., and Gibrael Abosamra. "Driving behavior classification based on oversampled signals of smartphone embedded sensors using an optimized stacked-LSTM neural networks." *IEEE Access* 9 (2021): 4957-4972.
- [5] Y. Moukafih, H. Hafidi and M. Ghogho, "Aggressive Driving Detection Using Deep Learning-based Time Series Classification," *2019 IEEE International Symposium on INnovations in Intelligent SysTems and Applications (INISTA)*, 2019, pp. 1-5, doi: 10.1109/INISTA.2019.8778416.
- [6] Karim, Fazle, et al. "LSTM fully convolutional networks for time series classification." *IEEE access* 6 (2017): 1662-1669.
- [7] Loquercio, Antonio, et al. "Dronet: Learning to fly by driving." *IEEE Robotics and Automation Letters* 3.2 (2018): 1088-1095.
- [8] https://github.com/uzh-rpg/rpg_public_dronet
- [9] <https://www.youtube.com/watch?v=ow7aw9H4BcA>
- [10] M. M. Bejani and M. Ghatee, "Convolutional neural network with adaptive regularization to classify driving styles on smartphones," *IEEE Trans. Intell. Transp. Syst.*, vol. 21, no. 2, pp. 543–552, Feb. 2020.
- [11] Talebloo, Farid. A Practical Deep Learning Approach to Detect Aggressive Driving Behaviour. MS thesis. Schulich School of Engineering, 2022.
- [12] Shastri S, Singh K, Kumar S, Kour P, Mansotra V. Time series forecasting of Covid-19 using deep learning models: India-USA comparative case study. *Chaos, Solitons, and Fractals*. 2020 Nov;140:110227. DOI: 10.1016/j.chaos.2020.110227. PMID: 32843824; PMCID: PMC7440083.
- [13] J. Engelbrecht, M. J. Booyesen, G. Rooyen, and F. J. Bruwer, "Survey of smartphone-based sensing in vehicles for intelligent transportation system applications," *IET Intell. Transp. Syst.*, vol. 9, no. 10, pp. 924–935, Dec. 2015.
- [14] T. K. Chan, C. S. Chin, H. Chen, and X. Zhong, "A comprehensive review of driver behavior analysis utilizing smartphones," *IEEE Trans. Intell. Transp. Syst.*, vol. 21, no. 10, pp. 4444–4475, Oct. 2020.

- [15] M. Enev, A. Takakuwa, K. Koscher, and T. Kohno, "Automobile driver fingerprinting," *Proc. Privacy Enhancing Technol.*, vol. 2016, no. 1, pp. 34–50, Jan. 2016.
- [16] J. Zhang et al., "A deep learning framework for driving behavior identification on in-vehicle CAN-BUS sensor data," *Sensors*, vol. 19, no. 6, p. 1356, Mar. 2019.
- [17] Y. Xun, J. Liu, N. Kato, Y. Fang, and Y. Zhang, "Automobile driver fingerprinting: A new machine learning based authentication scheme," *IEEE Trans. Ind. Informat.*, vol. 16, no. 2, pp. 1417–1426, Feb. 2020.
- [18] S. M. Iranmanesh, H. Nourkhiz Mahjoub, H. Kazemi, and Y. P. Fallah, "An adaptive forward collision warning framework design based on driver distraction," *IEEE Trans. Intell. Transp. Syst.*, vol. 19, no. 12, pp. 3925–3934, Dec. 2018.
- [19] J. Hu, L. Xu, X. He, and W. Meng, "Abnormal driving detection based on normalized driving behavior," *IEEE Trans. Veh. Technol.*, vol. 66, no. 8, pp. 6645–6652, Aug. 2017.
- [20] B. Shi et al., "Evaluating driving styles by normalizing driving behavior based on personalized driver modeling," *IEEE Trans. Syst., Man, Cybern. Syst.*, vol. 45, no. 12, pp. 1502–1508, Dec. 2015.
- [21] U. Fugiglando et al., "Driving behavior analysis through CAN bus data in an uncontrolled environment," *IEEE Trans. Intell. Transp. Syst.*, vol. 20, no. 2, pp. 737–748, Feb. 2019.
- [22] U. Kiencke, S. Dais, and M. Litschel, "Automotive serial controller area network," in *Proc. SAE Tech. Paper*, Feb. 1986, pp. 823–828.
- [23] Z. Constantinescu, C. Marinoiu, and M. Vlodoiu, "Driving style analysis using data mining techniques," *Int. J. Comput. Commun. Control*, vol. 5, no. 5, pp. 654–663, 2010.
- [24] A. Mudgal, S. Hallmark, A. Carriquiry, and K. Gkritza, "Driving behavior at a roundabout: A hierarchical Bayesian regression analysis," *Transp. Res. D, Transp. Environ.*, vol. 26, pp. 20–26, Jan. 2014
- [25] A. Chowdhury, T. Chakravarty, A. Ghose, T. Banerjee, and P. Balamuralidhar, "Investigations on driver unique identification from smartphone's GPS data alone," *J. Adv. Transp.*, vol. 2018, pp. 1–11, Feb. 2018.
- [26] M. Zhang, R. Fu, D. D. Morris, and C. Wang, "A framework for turning behavior classification at intersections using 3D LIDAR," *IEEE Trans. Veh. Technol.*, vol. 68, no. 8, pp. 7431–7442, Aug. 2019.
- [27] S. H. Sánchez, R. F. Pozo, and L. A. H. Gómez, "Driver identification and verification from smartphone accelerometers using deep neural networks," *IEEE Trans. Intell. Transp. Syst.*, early access, Jul. 21, 2020
- [28] S. Ezzini, I. Berrada, and M. Ghogho, "Who is behind the wheel? Driver identification and fingerprinting," *J. Big Data*, vol. 5, no. 1, p. 9, Dec. 2018.
- [29] O. Dehzangi and S. Masilamani, "Unobtrusive driver drowsiness prediction using driving behavior from vehicular sensors," in *Proc. 24th Int. Conf. Pattern Recognit. (ICPR)*, Aug. 2018, pp. 3598–3603.

- [30] M. S. Wang et al., “Drowsy behavior detection based on driving information,” *Int. J. Automot. Technol.*, vol. 17, no. 1, pp. 165–173, Feb. 2016
- [31] M. Shahverdy, M. Fathy, R. Berangi, and M. Sabokrou, “Driver behavior detection and classification using deep convolutional neural networks,” *Expert Syst. Appl.*, vol. 149, Jul. 2020, Art. no. 113240.
- [32] Z. Li, X. Jin, and X. Zhao, “Drunk driving detection based on classification of multivariate time series,” *J. Saf. Res.*, vol. 54, pp. e29-61.–e29-64, Sep. 2015.
- [33] A. Das, M. N. Khan, and M. M. Ahmed, “Detecting Lane change maneuvers using SHRP2 naturalistic driving data: A comparative study machine learning techniques,” *Accident Anal. Prevention*, vol. 142, Jul. 2020, Art. no. 105578.
- [34] M. Schüler, C. Onnen, and C. Bielaczek, “A fuzzy-system for a classification of the driver behavior and the driving situation,” *IFAC Proc. Volumes*, vol. 30, no. 8, pp. 693–698, Jun. 1997.
- [35] S. Yang, W. Wang, F. Zhang, Y. Hu, and J. Xi, “Driving-style-oriented adaptive equivalent consumption minimization strategies for HEVs,” *IEEE Trans. Veh. Technol.*, vol. 67, no. 10, pp. 9249–9261, Oct. 2018.
- [36] W. Wang, J. Xi, and D. Zhao, “Driving style analysis using primitive driving patterns with Bayesian nonparametric approaches,” *IEEE Trans. Intell. Transp. Syst.*, vol. 20, no. 8, pp. 2986–2998, Aug. 2019.
- [37] A. Jain, H. S. Koppula, B. Raghavan, S. Soh, and A. Saxena, “Car that knows before you do: Anticipating maneuvers via learning temporal driving models,” in *Proc. IEEE Int. Conf. Comput. Vis. (ICCV)*, Dec. 2015, pp. 3182–3190.
- [38] S. Schneegass, B. Pfleging, N. Broy, A. Schmidt, and F. Heinrich, “A data set of real world driving to assess driver workload,” in *Proc. 5th Int. Conf. Automot. User Interfaces Interact. Veh. Appl. (AutomotiveUI)*, 2013, pp. 150–157.
- [39] J. M. Hankey, M. A. Perez, and J. A. McClafferty, “Description of the shrp 2 naturalistic database and the crash, near-crash, and baseline data sets,” *Virginia Tech Transp. Inst., Blacksburg, VA, USA, Tech. Rep.*, 2016. [Online]. Available: <https://vtechworks.lib.vt.edu/handle/10919/70850>
- [40] T. A. Dingus et al., “The 100-car naturalistic driving study, phase ii-results of the 100-car field experiment,” *United States. Depart. Transp. NHTSA, New York, NY, USA, Tech. Rep. DOT-HS-810-593*, 2006.
- [41] U. D. of Transp, “Safety pilot model deployment data,” *Tech. Rep.*, Oct. 2015, doi: 10.21949/1504482.
- [42] M. A. Regan et al., “The Australian 400-car naturalistic driving study: Innovation in road safety research and policy,” in *Proc. Australas. Road Saf. Res., Policing Educ. Conf.*, 2013, pp. 1–13.
- [43] H. Abut et al., “Data collection with, ‘UYANIK’: Too much pain; but gains are coming,” in *Proc. Biennial DSP Vehicle Mobile Syst.*, Jun. 2007.

- [44] E. Romera, L. M. Bergasa, and R. Arroyo, "Need data for driver behaviour analysis? Presenting the public UAH-DriveSet," in Proc. IEEE 19th Int. Conf. Intell. Transp. Syst. (ITSC), Nov. 2016, pp. 387–392.
- [45] B. I. Kwak, J. Woo, and H. K. Kim, "Know your master: Driver profiling-based anti-theft method," in Proc. 14th Annu. Conf. Privacy, Secur. Trust (PST), Dec. 2016, pp. 211–218.
- [46] L. M. Bergasa, D. Almería, J. Almazán, J. J. Yebes and R. Arroyo, "DriveSafe: an App for Alerting Inattentive Drivers and Scoring Driving Behaviors", in IEEE Intelligent Vehicles Symposium (IV), pp. 240-245, Dearborn, Michigan (United States), June 2014. BEST POSTER AWARD.
- [47] E. Romera, L. M. Bergasa and R. Arroyo, "A Real-time Multi-scale Vehicle Detection and Tracking Approach for Smartphones", in IEEE Intelligent Transportation Systems Conference (ITSC), pp. 1298-1303, Las Palmas, Canary Islands (Spain), September 2015.
- [48] <https://www.youtube.com/watch?v=xdl8UgMUICA>
- [49] M. Fazeen, B. Gozick, R. Dantu, M. Bhukhiya, and M. C. González, "Safe driving using mobile phones," IEEE Trans. Intell. Transp. Syst., vol. 13, no. 3, pp. 1462–1468, Sep. 2012.
- [50] Q. Wang, Y. Gu, J. Liu, and S. Kamijo, "DeepSpeedometer: Vehicle speed estimation from accelerometer and gyroscope using LSTM model," in Proc. IEEE 20th Int. Conf. Intell. Transp. Syst. (ITSC) Workshop, Yokohama, Japan, Oct. 2017, pp. 214–219.
- [51] Y. Gu, Q. Wang, and S. Kamijo, "Intelligent driving data recorder in smartphone using deep neural network-based speedometer and scene understanding," IEEE Sensors J., vol. 19, no. 1, pp. 287–296, Jan. 2019.
- [52] D. A. Johnson and M. M. Trivedi, "Driving style recognition using a smartphone as a sensor platform," in Proc. 14th Int. IEEE Conf. Intell. Transp. Syst., Washington, DC, USA, Oct. 2011, pp. 1609–1615.
- [53] V. C. Magana and M. Munoz-Organero, "Artemisa: A personal driving assistant for fuel saving," IEEE Trans. Mobile Comput., vol. 15, no. 10, pp. 2437–2451, Oct. 2016.
- [54] D. Dörr, D. Grabengiesser, and F. Gauterin, "Online driving style recognition using fuzzy logic," in Proc. 17th Int. IEEE Conf. Intell. Transp. Syst. (ITSC), Oct. 2014, pp. 1021–1026.
- [55] A. Campolina, A. Boukerche, and A. A. F. Loureiro, "Context and location awareness in eco-driving recommendations," in Proc. IEEE/IFIP Netw. Oper. Manage. Symp. (NOMS), Apr. 2020, pp. 1–6.
- [56] G. Li, S. E. Li, B. Cheng, and P. Green, "Estimation of driving style in naturalistic highway traffic using maneuver transition probabilities," Transp. Res. C, Emerg. Technol., vol. 74, pp. 113–125, Jan. 2017.
- [57] W. Han, W. Wang, X. Li, and J. Xi, "Statistical-based approach for driving style recognition using Bayesian probability with kernel density estimation," IET Intell. Transp. Syst., vol. 13, no. 1, pp. 22–30, Jan. 2019.
- [58] W. Wang, J. Xi, and D. Zhao, "Driving style analysis using primitive driving patterns with Bayesian nonparametric approaches," IEEE Trans. Intell. Transp. Syst., vol. 20, no. 8, pp. 2986–2998, Aug. 2019.

[59] L. Yan, Z. Huang, Y. Zhang, L. Zhang, D. Zhu, and B. Ran, "Driving risk status prediction using Bayesian networks and logistic regression," *IET Intell. Transp. Syst.*, vol. 11, no. 7, pp. 431–439, Sep. 2017.

[60] W. Wang, J. Xi, A. Chong, and L. Li, "Driving style classification using a semisupervised support vector machine," *IEEE Trans. Human-Mach. Syst.*, vol. 47, no. 5, pp. 650–660, Oct. 2017.

[61] L. Yan, Z. Huang, Y. Zhang, L. Zhang, D. Zhu, and B. Ran, "Driving risk status prediction using Bayesian networks and logistic regression," *IET Intell. Transp. Syst.*, vol. 11, no. 7, pp. 431–439, Sep. 2017.

[62] <https://medium.com/the-artificial-impostor/notes-understanding-tensorflow-part-3-7f6633fcc7c7>

[63] He, Yangdong, and Jiabao Zhao. "Temporal convolutional networks for anomaly detection in time series." *Journal of Physics: Conference Series*. Vol. 1213. No. 4. IOP Publishing, 2019.