

การประเมินพฤติกรรมผู้ขับขีรถยนต์ส่วนบุคคลโดยประยุกต์ใช้
เทคโนโลยีเทเลเมติกส์และปัญญาประดิษฐ์



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชาวิศวกรรมโทรคมนาคมและคอมพิวเตอร์
มหาวิทยาลัยเทคโนโลยีสุรนารี
ปีการศึกษา 2567

PERSONAL VEHICLE DRIVER BEHAVIOR EVALUATION USING
TELEMETRICS AND ARTIFICIAL INTELLIGENCE TECHNOLOGY



A Thesis Submitted in Partial Fulfillment of the Requirements for the Degree of
Master of Engineering in Telecommunication and Computer Engineering

Suranaree University of Technology

Academic Year 2024

การประเมินพฤติกรรมผู้ขับเคลื่อนส่วนบุคคลโดยประยุกต์ใช้
เทคโนโลยีเทเลเมติกส์และปัญญาประดิษฐ์

มหาวิทยาลัยเทคโนโลยีสุรนารี อนุมัติให้บัณฑิตวิทยาลัยฉบับนี้เป็นส่วนหนึ่งของการศึกษาตาม
หลักสูตรปริญญาโทบริหารธุรกิจ

คณะกรรมการสอบวิทยานิพนธ์



(รองศาสตราจารย์ ดร. พิชญา ชัยปัญญา)

ประธานกรรมการ



(รองศาสตราจารย์ ดร. พีระพงษ์ อุทาสกุล)

กรรมการ



(รองศาสตราจารย์ ดร. ปิยาภรณ์ มีสวัสดิ์)

กรรมการ



(ผู้ช่วยศาสตราจารย์ ดร. เศรษฐวิทย์ ภูญา)

กรรมการ (อาจารย์ที่ปรึกษาวิทยานิพนธ์)



(รองศาสตราจารย์ ดร.ยุพาพร รักสกุลพิวัฒน์)

รองอธิการบดีฝ่ายวิชาการและประกันคุณภาพ



(รองศาสตราจารย์ ดร.พรศิริ จงกล)

คณบดีสำนักวิชาวิศวกรรมศาสตร์

สิทธิศักดิ์ ทองศรี : การประเมินพฤติกรรมผู้ขับขี่รถยนต์ส่วนบุคคลโดยประยุกต์ใช้
เทคโนโลยีเทเลเมตริกส์และปัญญาประดิษฐ์ (PERSONAL VEHICLE DRIVER BEHAVIOR
EVALUATION USING TELEMETRICS AND ARTIFICIAL INTELLIGENCE TECHNOLOGY)
อาจารย์ที่ปรึกษา : ผู้ช่วยศาสตราจารย์ ดร.เศรษฐวิทย์ ภูญาญา, 84 หน้า.

คำสำคัญ: เทเลเมตริกส์, พฤติกรรมการขับขี่, ปัญญาประดิษฐ์

อัตราการใช้รถยนต์บนถนนเพิ่มขึ้นทำให้เกิดอุบัติเหตุมากขึ้น การเกิดอุบัติเหตุส่งผลให้เกิด
การบาดเจ็บ และการสูญเสีย สถิติอุบัติเหตุจากการเก็บรวบรวมของหน่วยงานที่เกี่ยวข้อง พบว่า
รถยนต์ส่วนบุคคลมีสถิติการเกิดอุบัติเหตุสูงที่สุด และการขับขี่รถยนต์ด้วยความเร็วสูงก่อให้เกิด
อุบัติเหตุสูง พฤติกรรมการขับขี่เป็นสาเหตุหลักของการเกิดอุบัติเหตุ จากสถิติมูลเหตุสันนิษฐาน
สาเหตุหลักการเกิดอุบัติเหตุมาจากการขับขี่เร็วเกินกำหนด จากสถิติการเกิดอุบัติเหตุที่ได้รับแจ้งในปี
พ.ศ.2566 มีการเกิดอุบัติเหตุทั้งหมด 20,872 ครั้ง โดยอุบัติเหตุส่วนใหญ่มาจากรถยนต์นั่งส่วนบุคคล
พฤติกรรมผู้ขับขี่รถยนต์จึงมีความน่าสนใจอย่างยิ่งที่จะศึกษา เพื่อลดความเสี่ยงในการเกิด
อุบัติเหตุบนถนน การศึกษาพฤติกรรมการขับขี่รถยนต์สามารถทำได้ 4 วิธี ได้แก่ วิธีการสำรวจ
(Survey) วิธีการเปรียบเทียบ (Benchmark) วิธีการจำลองแบบ (Simulation) และ วิธีการการได้มา
ซึ่งข้อมูลที่เป็นปัจจุบัน (Real-time) ซึ่งประกอบด้วยข้อมูลจาก ผู้ขับขี่ (Human) สภาพถนน
(Road) และรถยนต์ (Vehicle) ซึ่งวิธีการได้มาซึ่งข้อมูลปัจจุบันและการได้มาซึ่งข้อมูลจากรถยนต์
เป็นวิธีที่เลือกใช้ในงานวิจัยนี้มีการดึงข้อมูลพฤติกรรมการขับขี่จากชุดข้อมูลจากอุปกรณ์ติดรถ (OBE:
On Board Equipment/OBU: On Board Unit) และประยุกต์อุปกรณ์ตรวจรู้ 3 แกน ปัจจุบันการ
นำเทคโนโลยี V2N และเทคโนโลยีปัญญาประดิษฐ์ เข้ามาใช้ในชีวิตประจำวันมากขึ้นโดยข้อมูลที่ได้
จาก ECU อุปกรณ์ตรวจรู้ 3 แกน ที่ได้มาจากการแสดงออกถึงพฤติกรรมในการขับขี่รถยนต์ของผู้ขับขี่
จะถูกส่งขึ้นไปประมวลด้วยเทคโนโลยี V2N และปัญญาประดิษฐ์ เพื่อเก็บข้อมูลพฤติกรรมการขับขี่
เมื่อเสร็จสิ้นการขับขี่ และแจ้งเตือนผู้ขับขี่ในระหว่างขับขี่ด้วยแบบจำลองทางคณิตศาสตร์ และ
แบบจำลองทางปัญญาประดิษฐ์ หรือ Artificial Intelligence model ในการเพิ่มความแม่นยำในการ
ประเมินพฤติกรรมการขับขี่ในรถยนต์ส่วนบุคคล งานวิจัยนี้จึงได้นำเสนอการนำเทคโนโลยี V2N
ร่วมกับ แบบจำลองทางคณิตศาสตร์ และโมเดลปัญญาประดิษฐ์ เพื่อมาใช้เพิ่มความแม่นยำในการ
จำแนกพฤติกรรมการขับขี่ ในการแจ้งเตือนให้ผู้ขับขี่ถึงพฤติกรรมการขับขี่ของบุคคล

สาขาวิชาวิศวกรรมโทรคมนาคม
ปีการศึกษา 2567


ลายมือชื่อนักศึกษา.....สิทธิศักดิ์
ลายมือชื่ออาจารย์ที่ปรึกษา.....

SITTISAK THONGSRI: PERSONAL VEHICLE DRIVER BEHAVIOR EVALUATION USING
TELEMETRICS AND ARTIFICIAL INTELLIGENCE TECHNOLOGY. THESIS ADVISOR:
ASSOC. PROF. SETTAWIT POOCHAYA, Ph. D., 84 PP.

Keywords: Telematics, Driver behavior, Artificial Intelligence

Increased automobile usage on roads has led to a rise in accidents, resulting in injuries and losses. A review of the literature and accident statistics from relevant agencies reveals that personal vehicles have the highest accident rates. Speeding is identified as a major cause of accidents. Statistics show that the primary cause of accidents is speeding. In 2023, there were 20,872 accidents. Most accidents involved four-wheeled trucks and personal vehicles. Studying driver behavior is thus crucial for reducing road accident risks. Four methods are used to study driver behavior: surveys, benchmarks, simulations, and real-time data collection. This research utilizes real-time data and vehicle data collection methods. Data is gathered from on-board equipment (OBE) and applied to three-axis sensors. The use of V2N (Vehicle-to-Network) technology and artificial intelligence (AI). Data from ECU (Electronic Control Units) and three-axis sensors, which reflect driver behavior, are transmitted for processing using V2N technology and AI. This data is then analyzed using mathematical models and AI models to enhance the accuracy of driver behavior assessments, providing alerts during driving and after the drive. This work presents the integration of V2N technology with mathematical and AI models to improve the accuracy of driver behavior classification. This approach aims to alert drivers to their driving behaviors and contribute to the development of safer driving practices, ultimately reducing the accident rate.

School of Telecommunication Engineering
Academic Year 2024

Student's Signature 
Advisor's Signature 

กิตติกรรมประกาศ

ขอขอบคุณกองทุนส่งเสริมวิทยาศาสตร์ วิจัยและนวัตกรรม และมหาวิทยาลัยเทคโนโลยีสุรนารีที่ได้ให้การสนับสนุนทุนวิจัยสำหรับโครงการวิจัยนี้ขอขอบคุณผู้วิจัยในที่ปรึกษาของผู้วิจัยหลายๆ คนที่ช่วยเก็บผลการทดลองและมีส่วนร่วมดำเนินการวิจัยในหลายส่วนโดยเฉพาะอย่างยิ่งนายทัศนัย ดั่งหนองบัว และนายเกรียงไกร บุญเชษฐ์ ที่ดำเนินการวิจัยและทดสอบชุดอุปกรณ์ต่าง ๆ ที่เกี่ยวข้องร่วมกัน

ขอกราบขอบพระคุณผู้ช่วยศาสตราจารย์ ดร.เศรษฐวิทย์ ภูฉายา อาจารย์ที่ปรึกษาวิทยานิพนธ์ ที่ให้คำปรึกษา แนะนำและแนะแนวทางอันเป็นประโยชน์ยิ่งต่องานวิจัยรวมทั้งช่วยตรวจทานและแก้ไขวิทยานิพนธ์เล่มนี้จนเสร็จสมบูรณ์

ขอขอบคุณมหาวิทยาลัยเทคโนโลยีสุรนารีที่ให้การสนับสนุนด้านทุนการศึกษา

ขอขอบคุณพี่ เพื่อน และน้องบัณฑิตศึกษาทุกคนที่คอยให้ความช่วยเหลือและเป็นกำลังใจ และขอบคุณ คุณสายฝน สิบพลกรัง เลขานุการสาขาวิชาวิศวกรรมโทรคมนาคม ที่ให้คำปรึกษาและจัดการด้านเอกสารตลอดระยะเวลาการศึกษา

สำหรับคุณงามความดีอันใดที่เกิดจากวิทยานิพนธ์เล่มนี้ผู้วิจัยขอมอบให้กับบิดา มารดาและญาติพี่น้องซึ่งเป็นที่ยรักและเคารพยิ่งตลอดจนครูอาจารย์ผู้สอนที่เคารพทุกท่านที่ได้ถ่ายทอดประสบการณ์ที่ดีให้แก่ผู้วิจัยทั้งในอดีตและปัจจุบันจนสำเร็จการศึกษาไปได้ด้วยดี

มหาวิทยาลัยเทคโนโลยีสุรนารี

สิทธิศักดิ์ ทองศรี

สารบัญ

หน้า

บทคัดย่อ (ภาษาไทย)	ก
บทคัดย่อ (ภาษาอังกฤษ)	ข
กิตติกรรมประกาศ	ค
สารบัญ	ง
สารบัญตาราง	ช
สารบัญรูป	ซ
บทที่	
1 บทนำ	1
1.1 ความสำคัญและที่มาของปัญหาการวิจัย	1
1.2 วัตถุประสงค์ของการวิจัย	5
1.3 กรอบการวิจัย	6
2 เอกสารและงานวิจัยที่เกี่ยวข้อง	7
2.1 กล่าวนำ	7
2.2 การสำรวจปริทรรศน์วรรณกรรมที่เกี่ยวข้องกับโครงการวิจัย	8
2.2.1 การภูมิทัศน์ของการวิจัยเกี่ยวกับพฤติกรรมของคนขับรถบัส	8
2.2.2 การประเมินพฤติกรรมรถบัสด้วย Vehicle Data Condition	17
2.2.3 การประเมินพฤติกรรมรถบัสด้วย Geotab Technology	18
2.2.4 การเรียนรู้ของเครื่องและปัญญาประดิษฐ์สำหรับการจำแนกพฤติกรรมการขับขี่	19
2.2.5 วิเคราะห์พฤติกรรมการขับขี่ของผู้ขับขี่ด้วยคุณสมบัติจากชุดข้อมูลหน่วยวัดแรงเฉื่อยของสมาร์ทโฟน	21
2.2.6 ปัจจัยด้านมนุษย์ในวงจรการขับขี่: การระบุตัวตนและการยืนยันตัวตนของผู้ขับขี่โดยใช้แนวทางการเรียนรู้เชิงลึกโดยใช้ข้อมูลทางพฤติกรรมทางจิตวิทยา	22

สารบัญ (ต่อ)

หน้า

2.2.7	การจัดทำโปรไฟล์ผู้ขับขี่โดยใช้ Long Short-Term Memory (LSTM) และเครือข่ายประสาทเทียมแบบ Convolutional Neural Network (CNN)	23
2.2.8	การการทดลองฝึกโมเดล Support Vector Machine (SVM) ด้วยชุดข้อมูล IMU sensors	24
2.2.9	การประเมินประสิทธิภาพและสมรรถนะของการเรียนรู้ของเครื่อง และปัญญาประดิษฐ์	26
2.3	ITS (Intelligent Transportation System)	27
2.4	V2N Technology (Vehicle-to-Network)	27
2.5	บทสรุป	28
3	วิธีดำเนินการวิจัย	30
3.1	วัสดุที่ใช้ในการวิจัย	30
3.2	วิธีการดำเนินการวิจัย	31
3.2.1	Data visualization	31
3.2.2	การปรับขนาดคุณลักษณะ (Feature Scaling)	34
3.2.3	การแยกข้อมูล (Data Splitting)	35
3.2.4	การสร้างโมเดล (Model Creation)	35
3.3	การออกแบบระบบเทเลเมติกส์	39
3.3.1	ระบบจ่ายไฟ	39
3.3.2	ระบบส่งการจากโทรศัพท์	39
3.3.3	กล่อง ECU (Electronics Control Unit)	40
3.3.4	ระบบประมวลผล	40
3.3.5	ระบบแสดงผลและเก็บข้อมูล	41
4	ผลการวิจัย	44
4.1	การประเมินประสิทธิภาพโมเดลที่ถูกสร้างขึ้นด้วย Confusion metrics	42
4.1.1	Accuracy (ความถูกต้อง)	42
4.1.2	Precision (ความแม่นยำ)	42

สารบัญ (ต่อ)

	หน้า
4.1.3 Sensitivity or Recall (ความไว)	42
4.1.4 F1-Score (ค่าเฉลี่ยระหว่าง precision และ recall)	43
4.2 การติดตั้งชุดอุปกรณ์ทดสอบ	44
4.3 การทดสอบคุณภาพสัญญาณ 4G/5G สำหรับ V2N	46
4.4 การทดสอบเก็บผลจากการขับรถยนต์ส่วนบุคคลจริงเพื่อจำแนกพฤติกรรมการขับ	49
4.4.1 การทดสอบเก็บผลจากการขับรถยนต์ส่วนบุคคลจริงแบบผสม	50
4.4.2 การทดสอบเก็บผลจากการขับรถยนต์ส่วนบุคคลจริงแบบแยก	52
4.4.3 การทดสอบเก็บผลจากการขับรถยนต์ส่วนบุคคลจริงแบบแยกสถานการณ์	57
4.5 การทดสอบเวลาการประมวลผลของระบบ	59
4.5.1 เวลาโดยรวมการประมวลผลที่กล่อง TCU	60
4.5.2 เวลาโดยรวมจากการนำส่งข้อมูลผ่านเครือข่าย V2N	61
5 สรุปผลการวิจัย อภิปรายผล และข้อเสนอแนะ	69
5.1 สรุปผลการวิจัย	65
5.2 ข้อเสนอแนะ	65
เอกสารอ้างอิง	66
ภาคผนวก บทความวิจัยระดับนานาชาติที่ได้รับการตีพิมพ์	68
บทความวิจัยระดับนานาชาติที่ได้รับการตีพิมพ์	69
ประวัติผู้เขียน	84

สารบัญตาราง

ตารางที่	หน้า
2.1	ตัวอย่างข้อมูลที่ได้รับจาก ECU
2.2	พารามิเตอร์ของข้อมูลที่ได้จาก ECU
2.3	ขาสำหรับการเชื่อมต่อ OBD II TO DB9 CABLE
2.4	สูตรการคำนวณพารามิเตอร์ต่าง ๆ จาก ECU
2.5	Confusion matrix
2.6	ตารางสรุปผลการเลือกใช้งานจากการศึกษาปรีทัศน์วรรณกรรมทั้งหมด
3.1	การกำหนดพารามิเตอร์ของโครงข่ายประสาทเทียมแบบ LSTM
4.1	ตารางแสดงผลการทดสอบคุณภาพสัญญาณ 5G ด้าน End Parameters
4.2	ตารางแสดงผลการทดสอบคุณภาพสัญญาณ 5G ด้าน Radio Parameters
4.3	สรุปผลการขับขี่โดยรวมการขับขี่แยกสถานการณ์ของการขับขี่แบบปลอดภัย
4.4	สรุปผลการขับขี่โดยรวมการขับขี่แบบแยกสถานการณ์การขับขี่ไม่แบบปลอดภัย
4.5	ผลลัพธ์จากการประมวลผลที่กล่อง TCU
4.6	เวลาโดยรวมจากการนำส่งข้อมูลผ่านเครือข่าย V2N ไปยัง dashboard

สารบัญรูป

รูปที่	หน้า	
1.1	ปัจจัยหลักที่มีผลต่อพฤติกรรมผู้ขับขี่	2
1.2	การจัดเก็บข้อมูลในหมวดหมู่แบบ Survey Benchmark และ Simulation	3
1.3	การจัดเก็บข้อมูลในหมวดหมู่แบบ Real-Time	4
1.4	แผนภาพความเชื่อมโยงของการศึกษาพฤติกรรมผู้ขับขี่โดยใช้ V2N	5
2.1	ปัจจัยสภาพแวดล้อมที่ส่งผลกระทบต่อพฤติกรรมผู้ขับขี่	8
2.2	ปัจจัยด้านลักษณะของประชากรที่ส่งผลกระทบต่อพฤติกรรมผู้ขับขี่	8
2.3	ปัจจัยด้านสภาพจิตใจผู้ขับขี่ ที่ส่งผลกระทบต่อพฤติกรรมผู้ขับขี่	9
2.4	ปัจจัยด้านสภาพรถที่ส่งผลกระทบต่อพฤติกรรมผู้ขับขี่	9
2.5	ปัจจัยด้านการใช้ชีวิตประจำวันขณะขับรถที่ส่งผลกระทบต่อพฤติกรรมผู้ขับขี่	10
2.6	วิธีการหาพฤติกรรมผู้ขับขี่/วิธีการได้มาซึ่งข้อมูลพฤติกรรมผู้ขับขี่	11
2.7	วัตถุประสงค์ของการศึกษาพฤติกรรมผู้ขับขี่	13
2.8	OBD II TO DB9 CABLE	15
2.9	CAN-BUS SHIELD	16
2.10	โครงสร้างการหาพฤติกรรมผู้ขับขี่โดยใช้เทคโนโลยี V2N	17
2.11	Vehicle Data Condition	18
2.12	ตัวอย่างการประเมินพฤติกรรมรถที่ขับจาก Geotab Technology	19
2.13	การจำแนกพฤติกรรมรถที่ขับของรถยนต์ส่วนบุคคล	19
2.14	Features สำหรับการจำแนกพฤติกรรมรถที่ขับของรถยนต์ส่วนบุคคล	20
2.15	แบบจำลองด้าน Machine Learning สำหรับการจำแนกพฤติกรรมรถที่ขับของรถยนต์ส่วนบุคคล	20
2.16	กรอบการทำงานของงานวิเคราะห์พฤติกรรมของผู้ขับขี่	21
2.17	ผลลัพธ์เปรียบเทียบจากการประเมินผลโมเดลด้วยการควรวมการเลือกคุณสมบัติทั้ง 6 วิธี	21
2.18	ผลลัพธ์เปรียบเทียบจากการประเมินผลโมเดลในด้าน accuracy สำหรับการระบุตัวตนของผู้ขับ	22

สารบัญรูป (ต่อ)

รูปที่		หน้า
2.19	ผลลัพธ์จากการประเมินผลโมเดลในด้าน accuracy สำหรับการตรวจสอบของผู้ขับ	22
2.20	เปรียบเทียบผลลัพธ์ระหว่าง CNN และ LSTM	23
2.21	การนำแบบจำลองทางคณิตศาสตร์ด้านการศึกษาพฤติกรรมรถขับของผู้ขับรถยนต์ส่วนบุคคลมาประยุกต์กับ Machine Learning	24
2.22	ผลการจำลองแบบประสิทธิภาพของระบบที่นำเสนอด้วย SVM	24
2.23	ผลการจำลองแบบประสิทธิภาพของระบบที่นำเสนอหลังจากสลับชุดข้อมูล	25
2.24	ขนาดของโมเดลปัญญาประดิษฐ์ที่จะนำไปติดตั้งที่ TCU	25
2.25	ภาพรวมรูปแบบการสื่อสารในระบบขนส่งอัจฉริยะ	27
2.26	ตัวอย่างโครงสร้าง V2N	28
3.1	ระบบที่นำเสนอ	30
3.2	ขั้นตอนการคัดแยกข้อมูล	31
3.3	Visualization ข้อมูลด้วยกราฟอนุกรมเวลา	32
3.4	Visualization ข้อมูลด้วยกราฟฮีตเทแกรม	33
3.5	การคัดแยกข้อมูลและการกระจายตัวของชุดข้อมูล	34
3.6	การแบ่งชุดข้อมูลเพื่อใช้ในการฝึกฝนโมเดล การทดสอบโมเดล	35
3.7	การสร้างโมเดลและผลผลิตของโมเดลในการจำแนกพฤติกรรมรถขับ	35
3.8	มิติของการนำเข้าข้อมูล	37
3.9	มิติของการนำเข้าข้อมูล	37
3.10	ลักษณะกราฟของ sigmoid function ที่ผ่านการคำนวณ	38
3.11	โครงสร้างพื้นฐานระบบเทเลเมติกส์	39
3.12	Chevrolet Cruze 1.6 Model 2011	40
3.13	โครงสร้างของระบบ software	41
3.14	รูปแบบการแจ้งเตือนด้วย In-vehicle Display System	41
4.1	ผลการจำลองแบบ	43
4.2	ภาพจำลองสัดส่วนการจัดวางชุดอุปกรณ์ที่นำเสนอ	45
4.3	ภาพจำลองขนาดชุดอุปกรณ์ที่นำเสนอ	45
4.4	ภาพจำลองชุดอุปกรณ์ที่นำเสนอชุดสมบูรณ์	46

สารบัญรูป (ต่อ)


รูปที่		หน้า
4.5	ภาพชุดอุปกรณ์ที่นำเสนอ	46
4.6	แผนภาพการทดสอบคุณภาพสัญญาณ 5G	47
4.7	พื้นที่การทดสอบคุณภาพสัญญาณ 4G และ 5G	47
4.8	ผลการทดสอบคุณภาพสัญญาณ 5G ด้าน End Parameters	48
4.9	ผลการทดสอบคุณภาพสัญญาณ 5G ด้าน Radios Parameters	49
4.10	Chevrolet Cruze 1.6 Model 2011	50
4.11	IMU Features	51
4.12	IMU Driver State	51
4.13	ECU Features	51
4.14	ECU Driver State	51
4.15	Driver behavior Realtime dashboard	52
4.16	การขับขี่แบบปลอดภัยโดยนักศึกษาปริญญาตรี	52
4.17	การขับขี่แบบไม่ปลอดภัยโดยอาจารย์ที่ปรึกษา	53
4.18	ผลการทดสอบการขับขี่แบบแยกสถานการณ์	54
4.19	ผลการทดสอบการขับขี่แบบแยกสถานการณ์	55
4.20	ผลการทดสอบการขับขี่แบบแยกสถานการณ์	56
4.21	แสดงผลการแจ้งเตือนจากสถานการณ์การขับขี่แบบปลอดภัย	58
4.22	แสดงผลการแจ้งเตือนจากสถานการณ์การขับขี่แบบปลอดภัย	59
4.23	การนำระบบและกล่อง TCU ไปใช้งานจริง	59

บทที่ 1

บทนำ


1.1 ความสำคัญและที่มาของปัญหาการวิจัย

การศึกษาพฤติกรรมของผู้ขับขี่สามารถทำได้หลายวิธี ได้แก่ การจัดทำแบบสอบถาม (Survey) การจำลองแบบผ่านโปรแกรม Simulation การทำการเปรียบเทียบ (Benchmark) และการวิเคราะห์แบบ Real time โดยทิศทางและแนวโน้มจากการทำปรัทัศน์วรรณกรรม สามารถระบุได้ชัดว่า การวิเคราะห์แบบ Real time ได้รับความนิยมจากนักวิจัยเป็นอย่างมาก อีกทั้งระบบขนส่งอัจฉริยะ (ITS) นับได้ว่าได้รับความนิยมจากนักวิจัยทั่วโลก ซึ่งการศึกษาพฤติกรรมผู้ขับขี่ เป็นอีกหัวข้อย่อยหนึ่ง ที่จะทำให้ระบบขนส่งอัจฉริยะ ประสบความสำเร็จ ด้วยการพัฒนาของเทคโนโลยีด้านอุปกรณ์อิเล็กทรอนิกส์และยานพาหนะยุคใหม่ ดังนั้นงานวิจัยในการศึกษาพฤติกรรมผู้ขับขี่ยานพาหนะด้วยเทคโนโลยี V2N นี้ ประกอบด้วยการศึกษาปัจจัยที่มีผลต่อพฤติกรรมผู้ขับขี่ซึ่งมุ่งเน้นการนำข้อมูลจริงที่ผู้ขับขี่กระทำต่อตัวรถ และส่งข้อมูลผ่าน V2N เพื่อคำนวณค่าคะแนนผู้ขับขี่แล้วแยกประเภทการขับขี่ด้วย Machine Learning จึงมีความน่าสนใจอย่างยิ่ง โดยที่ผู้ที่มีค่าคะแนนการขับขี่สูง หมายถึง ผู้ที่สามารถขับขี่ยานพาหนะได้ปลอดภัยต่อผู้ร่วมใช้ถนน นอกจากนี้ ผลที่เกิดจากโครงการวิจัยดังกล่าว ยังสามารถนำไปประยุกต์ใช้กับผู้ขับขี่ยานพาหนะสาธารณะได้อีกด้วย งานวิจัยที่ (1) เป็นการทำปรัทัศน์วรรณกรรมที่ทันสมัยที่สุดจากการรวบรวมการศึกษาพฤติกรรมผู้ขับขี่ประกอบไปด้วยปัจจัยหลัก 5 ประการตามรูปที่ (1) ได้แก่ สภาพแวดล้อม ประชากรผู้ขับขี่ สุขภาพใจของผู้ขับขี่ สภาพยานพาหนะ และ ข้อมูลจากยานพาหนะที่ผู้ขับขี่สะท้อนลงไปยังตัวยานพาหนะ




รูปที่ 1.1 ปัจจัยหลักที่มีผลต่อพฤติกรรมผู้ขับขี่

การศึกษาพฤติกรรมผู้ขับขี่สามารถทำได้ด้วยการออกแบบแบบจำลองทางคณิตศาสตร์ และ ระบุการจัดเก็บข้อมูลที่แม่นยำ ซึ่งแนวโน้มการจัดทำข้อมูลในปัจจุบันเน้นไปที่ทิศทางการจัดเก็บ ข้อมูลแบบ Real-time ผ่านอุปกรณ์ OBD และ OBE ดังรูปที่ 1.2 และ 1.3



รูปที่ 1.2 การจัดเก็บข้อมูลในหมวดหมู่แบบ Survey Benchmark และ Simulation



รูปที่ 1.3 การจัดเก็บข้อมูลในหมวดหมู่แบบ Real-Time

จากการทำปรัศนัวรรณกรรมที่เกี่ยวข้องพบว่า ปัจจัยที่สามารถเก็บข้อมูลพฤติกรรมผู้ขับขี่ผ่านข้อมูลจริงจากยานพาหนะ ได้แก่ อัตราเร่ง การเหยียบคันเร่ง ความเร็วของยานพาหนะ การเหยียบเบรก รอบเครื่องยนต์ และอื่นๆ สามารถนำไปคำนวณผ่านการสร้างแบบจำลองทางคณิตศาสตร์ดังสมการที่ 1 และ 2 ในการแยกประเภทผู้ขับขี่ได้ดังรูปที่ 1.4

$$R_{cz} = \frac{cs(t)}{220} \div \frac{zs(t)}{8000} \quad (1)$$

$$R_{jz} = \frac{jq'(t)}{\max(jq')} \div \frac{zs'(t)}{\max(zs')} \quad (2)$$

โดยที่ R_{cz}	คือ อัตราส่วนความสัมพันธ์ระหว่างรอบเครื่องยนต์กับความเร็วของยานพาหนะ
$cs(t)$	คือ ความเร็วของยานพาหนะ ณ เวลา t
$zs(t)$	คือ รอบเครื่องยนต์ ณ เวลา t
R_{jz}	คือ อัตราส่วนความสัมพันธ์ตำแหน่งของคันเร่งกับความเร็วรอบเครื่องยนต์
$jq'(t)$	คือ อัตราการเปลี่ยนแปลงของตำแหน่งคันเร่ง ณ เวลา t
$zs'(t)$	คือ อัตราการเปลี่ยนแปลงของตำแหน่งความเร็วรอบเครื่องยนต์ ณ เวลา t



รูปที่ 1.4 แผนภาพความเชื่อมโยงของการศึกษาพฤติกรรมผู้ขับขี่โดยใช้ V2N

ดังนั้นจากการทำปรัทัศน์วรรณกรรมที่เกี่ยวข้อง การศึกษาพฤติกรรมผู้ขับขี่ และการพัฒนาแบบจำลองทางคณิตศาสตร์ตลอดจนการนำ Machine Learning เข้ามาประยุกต์ใช้ จะทำให้สามารถเพิ่มความปลอดภัยให้แก่ผู้ขับขี่และผู้ร่วมใช้ทางได้เป็นอย่างดี

1.2 วัตถุประสงค์ของการวิจัย

1. เพื่อศึกษาพฤติกรรมผู้ขับขี่ยานพาหนะส่วนบุคคลด้วยข้อมูลจริงผ่านเทคโนโลยี V2N
2. เพื่อพัฒนาแบบจำลองทางคณิตศาสตร์ที่สามารถแยกประเภทการขับขี่แบบปลอดภัยและไม่ปลอดภัย
3. เพื่อเพิ่มความปลอดภัยของผู้ร่วมใช้ถนนด้วยการใช้ประโยชน์จากการระบุพฤติกรรมผู้ขับขี่

1.3 กรอบการวิจัย

1. งานวิจัยที่นำเสนอ ใช้ข้อมูลพฤติกรรมการขับขี่จากการเชื่อมต่อสัญญาณจากกล่อง ECU ของรถยนต์ส่วนบุคคลเท่านั้น
2. พฤติกรรมการขับขี่ สามารถจำแนกได้ด้วยปัญญาประดิษฐ์ที่ให้สมรรถนะให้การทำนายแม่นยำที่สุด และแจ้งเตือนผ่านหน้าจอแสดงผลในรถยนต์ส่วนบุคคล และสามารถแสดงผลผ่าน V2N ไปยัง On line Dashboard ได้
3. ชุดอุปกรณ์ที่ติดตั้งปัญญาประดิษฐ์ที่เหมาะสมกับการจำแนกพฤติกรรมการขับขี่ติดตั้งที่รถยนต์ส่วนบุคคลโดยไม่มีการตัดต่อสายไฟของระบบรถยนต์ (Plug and play)



บทที่ 2

เอกสารและงานวิจัยที่เกี่ยวข้อง

2.1 กล่าวนำ


ในส่วนนี้กล่าวถึงการทำวิจัย ทัศนวิสัยการมองเห็น เทคโนโลยี 4G-LTE และการศึกษาพฤติกรรมการขับขี่ การสื่อสารระหว่างยานพาหนะ หรือ Vehicle-to-Everything (V2X) ประกอบด้วย V2V (Vehicle-to-Vehicle) V2I (Vehicle-to-Infrastructure) V2N (Vehicle-to-Network) และ V2P (Vehicle-to-Pedestrian) ในงานวิจัยนี้สนใจที่ V2N (Vehicle-to-Network) เป็นการสื่อสารระหว่างยานพาหนะกับอินเทอร์เน็ต การสื่อสารระหว่างยานพาหนะ กับอินเทอร์เน็ต ใช้เทคโนโลยี 4G-LTE จากนั้นนำผลการศึกษาพฤติกรรมการขับขี่ มาใช้ทดสอบพฤติกรรมการขับขี่ และใช้เทคโนโลยี 4G-LTE ในการส่งข้อมูลพฤติกรรมการขับไปเก็บที่คลาวด์พร้อมทั้งคำนวณพฤติกรรมการขับขี่ และแจ้งเตือนพฤติกรรมการขับขี่ไปยังผู้ขับขี่ในรูปแบบเรียลไทม์ และออฟไลน์ เพื่อนำไปพัฒนาการขับขี่ ในปัจจุบันมีการนำเทคโนโลยีการขับขี่ ใช้ร่วมกับพฤติกรรมการขับขี่ และกระบวนการทางกฎหมายมากขึ้น โดยผลพลอยได้จากการนำเสนอเทคโนโลยีดังกล่าวส่งผลให้เกิดความปลอดภัยในการใช้ถนน จากการขับขี่ที่ปลอดภัยของผู้ขับขี่ที่ได้รับการแจ้งเตือนในระหว่างการขับ อีกทั้งยังสามารถวิเคราะห์พฤติกรรมการขับขี่หลังจากขับแล้วเสร็จได้อีกด้วย

2.2 การสำรวจปริทรรศน์วรรณกรรมที่เกี่ยวข้องกับโครงการวิจัย

2.2.1 การภูมิทัศน์ของการวิจัยเกี่ยวกับพฤติกรรมของคนขับรถยนต์

1. อนุกรมวิธานของปัจจัยสำคัญของพฤติกรรมของคนขับ


การศึกษาพฤติกรรมผู้ขับขี่สามารถทำได้หลากหลายวิธี เมื่อพิจารณาจัดกลุ่มปัจจัยที่ส่งผลกระทบต่อพฤติกรรมผู้ขับขี่ที่สามารถแบ่งกลุ่มได้ 5 ประเภท ได้แก่ ปัจจัยด้านสิ่งแวดล้อม ยานพาหนะ ประชากร นิสัย และกิจวัตรประจำวันบนรถของผู้ขับ โดยมีรายละเอียดดังนี้



รูปที่ 2.1 ปัจจัยสภาพแวดล้อมที่ส่งผลกระทบต่อพฤติกรรมผู้ขับขี่

1.1 ประเภทที่ 1 ปัจจัยสภาพแวดล้อม (Environmental Factors)

แสดงดังรูปที่ 2.1 ซึ่งปัจจัยที่เกิดขึ้นได้ในประเทศไทยประกอบด้วย สภาพอากาศ ประเภทถนน สภาพถนน สภาพแวดล้อม ห่วงเวลา/สภาพแสง และโครงสร้างของถนน/สภาพประกอบทาง เป็นต้น ทั้งนี้ปัจจัยสภาพแวดล้อม เป็นอีกปัจจัยหนึ่งที่ส่งผลกระทบต่อการแสดงออกถึงพฤติกรรมการขับขี่ของผู้ขับขี่



รูปที่ 2.2 ปัจจัยด้านลักษณะของประชากรที่ส่งผลกระทบต่อพฤติกรรมผู้ขับขี่

1.2 ประเภทที่ 2 ปัจจัยด้านลักษณะของประชากร (Demographic Factors)

แสดงดังรูปที่ 2.2 ประกอบด้วย ระดับการศึกษา ประสบการณ์ในการขับขี่ เพศสภาพ ประวัติการได้รับบาดเจ็บจากอุบัติเหตุหรืออื่น ๆ อายุ และสุขภาพของผู้ขับขี่ ที่กล่าวมาข้างต้น ล้วนส่งผลกระทบต่อพฤติกรรมผู้ขับขี่ทั้งสิ้น

1.3 ประเภทที่ 3 ปัจจัยด้านสภาพจิตใจผู้ขับขี่ (Habit Factors)


แสดงดังรูปที่ 2.3 อาทิเช่น การสูบบุหรี่ การดื่มเครื่องดื่มที่มีแอลกอฮอล์ ผสมพฤติกรรมทานอาหารขณะขับรถ เป็นต้น เหล่านี้ล้วนส่งผลกระทบต่อพฤติกรรมผู้ขับขี่ทั้งสิ้น

1.4 ประเภทที่ 4 ปัจจัยด้านสภาพรถ (Vehicle Factors)


แสดงดังรูปที่ 2.4 ได้แก่ อุณหภูมิเครื่องยนต์ น้ำมันเครื่อง อายุการใช้งาน ของรถการออกแบบรถ จุดบอด/จุดอับสายตาของผู้ขับขี่ ประเภทของรถ เช่น รถบรรทุก รถยนต์ส่วนบุคคล รถบัสโดยสาร เหล่านี้ล้วนส่งผลกระทบต่อพฤติกรรมผู้ขับขี่ทั้งสิ้น



รูปที่ 2.3 ปัจจัยด้านสภาพจิตใจผู้ขับขี่ ที่ส่งผลกระทบต่อพฤติกรรมผู้ขับขี่



รูปที่ 2.4 ปัจจัยด้านสภาพรถที่ส่งผลกระทบต่อพฤติกรรมผู้ขับขี่




รูปที่ 2.5 ปัจจัยด้านการใช้ชีวิตประจำวันขณะขับรถที่ส่งผลกระทบต่อพฤติกรรมผู้ขับขี่

1.5 ประเภทที่ 5 ปัจจัยด้านการใช้ชีวิตประจำวันขณะขับรถ (On-board Factors)

แสดงดังรูปที่ 2.5 ได้แก่ ความเร็วที่ใช้ในการขับขี่ การหลบหลีกสิ่งกีดขวางบนถนน ความรู้สึกของผู้โดยสารขณะที่มีการเบรก หรือ เร่ง อัตราการสิ้นเปลืองพลังงาน การเหยียบเบรก สภาพการขับขี่ ความเหนื่อยของผู้ขับขี่ ความเครียดของผู้ขับขี่ ความง่วง ความโกรธ โดยสิ่งที่กล่าวมาข้างต้นล้วนส่งผลกระทบต่อพฤติกรรมผู้ขับขี่ทั้งสิ้น

จากที่กล่าวมาข้างต้น พบว่า ปัจจัยหลายปัจจัยล้วนส่งผลกระทบต่อพฤติกรรมผู้ขับขี่เป็นอย่างมาก โดยเฉพาะปัจจัยประเภทที่ 5 ซึ่งส่งผลกระทบต่อการแสดงออกถึงพฤติกรรมของผู้ขับขี่บนถนนหลากหลายรูปแบบดังปรากฏตามสื่อสังคมออนไลน์ต่าง ๆ พฤติกรรมผู้ขับขี่ จึงเป็นหัวข้อที่นักวิจัยทั่วโลกให้ความสนใจในการศึกษาเพื่อหาความเชื่อมโยงกับมูลเหตุสันนิษฐานของการเกิดอุบัติเหตุในแต่ละครั้ง เนื้อหาในส่วนถัดไปจะเป็นการกล่าวถึงวิธีการหาพฤติกรรมของผู้ขับขี่



รูปที่ 2.6 วิธีการหาพฤติกรรมผู้ขับขี่/วิธีการได้มาซึ่งข้อมูลพฤติกรรมผู้ขับขี่

2. วิธีการรวบรวมข้อมูลพฤติกรรมผู้ขับขี่

การหาพฤติกรรมผู้ขับขี่และวิธีการได้มาซึ่งข้อมูลพฤติกรรมผู้ขับขี่สามารถแสดงได้ดังรูปที่ 2.6 ซึ่งประกอบด้วยทั้งหมด 4 กลุ่มวิธี ดังนี้

2.1 กลุ่มวิธีที่ 1 วิธีการสำรวจ (Survey)

ซึ่งแบ่งกลุ่มเป้าหมายในการสำรวจเป็นผู้ขับขี่ ผู้โดยสาร และอื่น ๆ มีการใช้ชุดข้อคำถามมาตรฐานในแต่ละประเด็นเป็นเครื่องมือในการสำรวจ แบบสอบถามเชิงปริมาณ และการสัมภาษณ์กลุ่มเป้าหมาย

2.2 กลุ่มวิธีที่ 2 วิธีการเปรียบเทียบ (Benchmark)

มีการใช้กระบวนการวิเคราะห์ทางสถิติ การแบ่งกลุ่ม การวิเคราะห์ถดถอย และการทำนาย มาใช้เป็นเครื่องมือในการหาพฤติกรรมของผู้ขับขี่

2.3 กลุ่มวิธีที่ 3 วิธีการจำลองแบบ (Simulation)

มีการใช้ชุดโปรแกรมจำลองการขับขี่ โดยยกกรณีตัวอย่างเหตุการณ์ต่าง ๆ บนถนนขึ้นมาเพื่อให้ผู้ขับขี่ที่ใช้ชุดโปรแกรมหาดังกล่าว แสดงพฤติกรรมการขับขี่ที่สอดคล้องกับสถานการณ์ตัวอย่าง เพื่อศึกษาพฤติกรรมผู้ขับขี่จากชุดโปรแกรมหาดังกล่าว

2.4 กลุ่มวิธีที่ 4 วิธีการการได้มาซึ่งข้อมูลที่เป็นปัจจุบัน (Real-time)


แบ่งชุดวิธีการออกเป็น 3 ประเภท ได้แก่

1. ผู้ขับขี่ (Human) ประกอบด้วย การเคลื่อนไหวของสายตา สภาพใบหน้า ความดันโลหิต อัตราการเต้นหัวใจ
2. สภาพถนน (Road) ประกอบด้วย ถนนทาง-ปลายทาง สภาพการจราจร ติดขัด ความกว้างของถนน ความยาวของถนน
3. รถยนต์ (Vehicle) ประกอบด้วย การหลบหลีกสิ่งกีดขวางบนถนน การใช้เบรก การใช้ความเร็ว

ทั้ง 3 ประเภทของชุดข้อมูล สามารถใช้เครื่องมือต่าง ๆ เพื่อให้ได้มาซึ่งชุดข้อมูล โดยแบ่งออกเป็น ชุดข้อมูลจากอุปกรณ์ติดรถ (OBE: On Board Equipment/OBU: On Board Unit) ประกอบด้วย ชุดข้อมูลพิกัด GPS ชุดข้อมูลจากกล่องควบคุม IMU/ECU เป็นต้น และชุดข้อมูลจากอุปกรณ์ข้างทางและอุปกรณ์อื่น ๆ (RSE: Road Side Equipment/RSU: Road Side Unit) ประกอบด้วย ชุดข้อมูลจากดาวเทียม ชุดข้อมูลจากตัวตรวจรู้ต่าง ๆ ชุดข้อมูลจากอุปกรณ์ที่ติดข้างถนน และกล้องวงจรปิดต่าง ๆ เป็นต้น

จากที่กล่าวมาข้างต้น เมื่อพิจารณาถึงสภาพของถนนในประเทศไทย และภาพรวมพฤติกรรมผู้ขับขี่ เป็นที่น่าสนใจเป็นอย่างมากในการศึกษาพฤติกรรมผู้ขับขี่ โดยการได้มาซึ่งข้อมูลแบบ Real-time ที่ได้จากชุดอุปกรณ์ติดรถ (OBU) ดังนั้น ตัวอย่างที่กล่าวถึงในเนื้อหาส่วนถัดไป เป็นการกล่าวถึง

การเชื่อมต่อ OBU เพื่อนำชุดข้อมูลจากรถไปใช้ในการหาพฤติกรรมผู้ขับขี่ โดยที่วัตถุประสงค์หลักในการหาพฤติกรรมผู้ขับขี่ประกอบด้วย 3 วัตถุประสงค์หลัก



รูปที่ 2.7 วัตถุประสงค์ของการศึกษาพฤติกรรมผู้ขับขี่

วัตถุประสงค์ในการหาพฤติกรรมผู้ขับขี่

1. เพื่อประโยชน์ประเด็นด้านความปลอดภัยทางถนน
2. การลดโอกาสการเกิดการชนกันของรถยนต์บนถนน และแก้ปัญหาสภาพการจราจร
3. การเพิ่มการตระหนักรู้ของพฤติกรรมของผู้ขับขี่ให้ปลอดภัย

จะเห็นได้ว่า ความปลอดภัยทางถนน เป็นประเด็นหลักที่สำคัญต่อการศึกษาพฤติกรรมผู้ขับขี่เป็นอย่างยิ่ง เนื้อหาในส่วนนี้เป็นการเน้นการกล่าวถึงการหาพฤติกรรมผู้ขับขี่ผ่าน พอร์ต OBD-II เพื่อประเมินความปลอดภัยของผู้ขับขี่จากข้อมูลจริง

1. วิธีการรวบรวมข้อมูลพฤติกรรมผู้ขับขี่จากรถยนต์ผ่านพอร์ต OBD-II

จากที่กล่าวมาข้างต้น วิธีการได้มาซึ่งข้อมูลปัจจุบันขณะขับรถของผู้ขับขี่ เป็นวิธีการที่ได้มาซึ่งข้อมูลที่แม่นยำ ที่สะท้อนพฤติกรรมของผู้ขับขี่ได้อย่างเป็นปัจจุบันที่สุด ดังนั้น การเชื่อมต่ออุปกรณ์อ่านข้อมูลจากกล่องควบคุมรถ (ECU) จึงเป็นส่วนที่จะกล่าวถึงรายละเอียดการหาพฤติกรรมผู้

ข้อนี้ นอกจากนั้นข้อมูลจากกล่องควบคุมรถ (ECU) ยังถูกส่งผ่านเทคโนโลยี V2N โดยใช้เครือข่าย 4G-LTE เพื่อส่งข้อมูลที่อ่านค่าได้ไปประมวลผลเป็นพฤติกรรมผู้ขับขี่

ซอฟต์แวร์และอุปกรณ์ต่าง ๆ ที่ใช้สำหรับการดึงข้อมูลพฤติกรรมผู้ขับขี่จากกล่อง ECU ในการดึงข้อมูลพฤติกรรมผู้ขับขี่จากกล่อง ECU มีการใช้ ECU เชื่อมต่อกับ พอร์ต OBD-II และหน่วยประมวลผลของรถยนต์ โดยเริ่มจากข้อมูลที่ได้รับเข้ามาจาก ECU ในขั้นตอนแรก เป็นข้อมูลที่ยังไม่ถูกแปลงค่าดังตารางที่ 2.1 มีการนำข้อมูลที่ได้จากกล่อง ECU แปลงค่าผ่านสมการที่เกี่ยวข้อง เพื่อแปลงค่าเป็น ความเร็ว รอบเครื่องยนต์ การทำงานของเครื่องยนต์ การเหยียบคันเร่ง และอุณหภูมิเครื่องยนต์ที่สมบูรณ์ดังตารางที่ 2.2 ทั้งนี้ Can ID คือ ID หรือตำแหน่งของข้อมูลที่ดึงค่ามาจาก ECU ของรถยนต์ เพื่อนำมาใช้ในการวิเคราะห์ ความเร็ว รอบเครื่องยนต์ การเหยียบคันเร่ง การทำงานของเครื่องยนต์ และอุณหภูมิ ซึ่งหน่วยต่าง ๆ ของข้อมูลของแต่ละข้อมูลจะมีการใช้สูตรตามมาตรฐานเพื่อการคำนวณให้ได้ค่าตามจริงของการใช้งาน

ตารางที่ 2.1 ตัวอย่างข้อมูลที่ได้รับจาก ECU

Received CAN ID:7E8 C	4	41	C	B	D4	0	0	0
Received CAN ID:7E8 C	4	41	C	B	D4	0	0	0
Received CAN ID:7E8 D	3	41	D	0	0	0	0	0

ตารางที่ 2.2 พารามิเตอร์ของข้อมูลที่ได้จาก ECU

Can ID	Data byte	ประเภท	หน่วย	สูตร
7E8	3	Temperature	°C	A-40
7E8	1	Engine load	%	A/2.55
7E8	1	Throttle position	%	(100/255)*A
7E8	1	Velocity	Km/h	A
7E8	2	Engine speed	rpm	(A*256+B)/4

2. อุปกรณ์ประกอบการรวบรวมข้อมูลพฤติกรรมผู้ขับขี่

1. OBD II TO DB-9 CABLE

บอร์ด Can-Bus Shield V2 เชื่อมต่อกับระบบและกล่อง ECU ผ่านพอร์ต OBD-II และอ่านค่าพฤติกรรมผู้ขับขี่ที่แสดงออกต่อการขับขี่รถยนต์ผ่านกล่อง ECU เป็นไปตาม มาตรฐาน ของ SAE J1962 / ISO 15031-3 ซึ่งสามารถใช้ได้กับรถทั่วไป โดยรูปที่ 2.8 แสดงสาย OBD II TO DB9 สำหรับการเชื่อมต่อดึงข้อมูลจากกล่อง ECU โดยที่ขาสำหรับการเชื่อมต่อต่าง ๆ สามารถแสดงได้ดังตารางที่ 2.3



รูปที่ 2.8 OBD II TO DB9 CABLE


ตารางที่ 2.3 ขาสำหรับการเชื่อมต่อ OBD II TO DB9 CABLE

Pin Description	OBD II	DB9
Chassis Ground	4	2
J1850 BUS+	2	7
Signal Ground	5	1
CAN High J-2284	6	3
ISO 9141-2 K Line	7	4
J1850 BUS	10	6
CAN Low J-2284	14	5
ISO 9141-2 L Line	15	8
Battery Power	16	9

2. CAN-BUS SHIELD

CAN-BUS SHIELD คือชุดอุปกรณ์ที่ใช้สำหรับข้อมูลที่ส่งมาจาก ECU ของรถยนต์ แสดงได้ดัง รูปที่ 2.13 โดยที่ข้อมูลที่ได้จากกล่อง ECU ที่สอดคล้องกับการศึกษาพฤติกรรมผู้ขับขี่ ได้แก่ การทำงานของ เครื่องยนต์ ความเร็ว รอบเครื่องยนต์ การเหยียบคันเร่ง อุณหภูมิเครื่องยนต์ เป็นต้น คุณสมบัติพื้นฐานของ CAN-BUS SHIELD ได้แก่

1. CAN V2.0B สูงถึง 1 Mb/s
2. อินเทอร์เฟซ SPI ความเร็วสูง 10 MHz
3. ข้อมูลมาตรฐานและขยายเฟรมระยะไกล
4. การเชื่อมต่อ CAN ผ่านขั้วต่อ sub-D 9 ทางมาตรฐาน สายเคเบิลเชื่อมต่อ OBD-II มาตรฐานย่อย 5.9 สายเคเบิลเชื่อมต่อ OBDII มาตรฐาน sub-D




รูปที่ 2.9 CAN-BUS SHIELD

ข้อมูลจากกล่อง ECU ของรถยนต์ได้รับการส่งข้อมูลผ่านทางสาย OBD-II DB9 ที่เชื่อมต่ออยู่กับ Can-Bus shields V2 เมื่อข้อมูลที่ได้จาก ECU เข้าสู่ Arduino Uno R3 จะทำการคำนวณค่าพารามิเตอร์ที่กำหนดไว้ โดยมีสูตรการคำนวณดังตารางที่ 2.4

ตารางที่ 2.4 สูตรการคำนวณพารามิเตอร์ต่าง ๆ จาก ECU

ประเภท	หน่วย	สูตร
Temperature	°C	A-40
Engine load	%	A/2.55
Throttle position	%	(100/255)*A
Velocity	Km/h	A
Engine speed	rpm	(A*256+B)/4




รูปที่ 2.10 โครงสร้างการหาพฤติกรรมผู้ขับขี่โดยใช้เทคโนโลยี V2N

โครงสร้างภาพรวมของการหาพฤติกรรมผู้ขับขี่โดยใช้เทคโนโลยี V2N สามารถแสดงได้ดังรูปที่ 2.10 ซึ่งข้อมูลพฤติกรรมผู้ขับขี่ที่แสดงออกไปยังตัวรถยนต์ จะถูกอ่านค่าโดยดึงข้อมูลจากกล่อง ECU ส่งไปประมวลผลบนเซิร์ฟเวอร์และแสดงผลพฤติกรรมผู้ขับขี่เพื่อนำไปใช้ประโยชน์ด้านอื่น ๆ ต่อไป

2.2.2 การประเมินพฤติกรรมการขับขี่ด้วย Vehicle Data Condition

รอบเครื่องยนต์เป็นหนึ่งในพารามิเตอร์ที่สำคัญในข้อมูลเอาต์พุตของเครื่องยนต์ การขับขี่ที่ดี ที่สุดไม่ใช่ความเร็วของรถที่สูง และรอบเครื่องยนต์ต่ำเท่านั้น การรักษาความเร็วของรถและรอบเครื่องยนต์ให้ สม่่าเสมอ ความเร็วของรถคือการตอบสนองโดยตรงจากการขับขี่ สามารถสะท้อนถึงสภาวะการขับขี่ในปัจจุบันได้โดยตรงไม่ว่าจะเร่งความเร็ว หรือรักษาความปลอดภัย ตำแหน่ง

คันเร่งถูกปรับเพื่อส่งจำนวน เชื้อเพลิงเข้าสู่เครื่องยนต์ การเปิดปีกผีเสื้อที่เหมาะสมเพื่อให้การทำงานของเครื่องยนต์มีประสิทธิภาพ ค่าคันเร่งที่สูงหรือต่ำเกินไปจะทำให้การเผาไหม้เชื้อเพลิง และมลพิษทางอากาศไม่สมบูรณ์



รูปที่ 2.11 Vehicle Data Condition

ภาระเครื่องยนต์เป็นตัวบ่งชี้สภาพแวดล้อมการทำงานของคนขับ การวิ่งเกินพิกัดจะทำให้เครื่องยนต์มีภาระมากเกินไป ทำให้เครื่องยนต์เสียหายได้ง่าย จึงไม่เอื้ออำนวยต่อการขับขี่อย่างปลอดภัย

2.2.3 การประเมินพฤติกรรมคนขับด้วย Geotab Technology

ความปลอดภัยเป็นส่วนสำคัญในการจัดการยานพาหนะ การให้ความสำคัญกับความปลอดภัยสามารถนำไปสู่ผลลัพธ์เชิงบวกอย่างมากในทางธุรกิจ และความสามารถในการทำกำไร ค่าใช้จ่ายทั้งทางตรงและทางอ้อม เนื่องจากพฤติกรรมการขับขี่ที่ไม่ปลอดภัยสามารถหลีกเลี่ยงได้ โดยเฉพาะอย่างยิ่งกับการฝึกให้ผู้ขับมีประสิทธิภาพในการขับ หรืออบรมด้านกฎจราจร และมาตรการด้านความปลอดภัยที่ได้รับการยอมรับอย่างดีด้วยระบบเทคโนโลยี เนื่องจากเราสามารถตรวจจับพฤติกรรมการขับขี่ที่ไม่ปลอดภัยได้ และเครื่องมือที่ใช้ในการวิเคราะห์ และวัดผลคะแนนความปลอดภัยของผู้ขับขี่ถูกรวมเข้ากับสมการของ Geotab เพื่อบันทึกการขับขี่ และข้อมูลความเร็วที่สามารถแปลงเป็นคะแนนความปลอดภัยที่เข้าใจได้ และถูกใช้ในการระบุผู้ขับขี่ที่มีความเสี่ยง หรือ Driver Safety Scorecard และช่วยให้กลุ่มยานยนต์เปลี่ยนพฤติกรรมการขับขี่ที่ไม่ปลอดภัยเป็นการขับขี่แบบปลอดภัยมากขึ้น โดยใช้ประโยชน์จาก Driver Safety Scorecard ที่ได้รับข้อมูลจากยานพาหนะ และแปลงข้อมูลผ่านสมการของ Geotab ได้ ทั้งนี้เพื่อลดอัตราการเกิดอุบัติเหตุ ลดค่าประกันภัยจากการศึกษาพฤติกรรมการขับขี่ โดยเป็นวิธีการให้คะแนนผู้ขับ การประเมินพฤติกรรม

การขับขี่ให้เหมาะสมดังรูปที่ 2.12 ในเทคโนโลยี Geotab งานวิจัยนี้ประเมินพฤติกรรมการขับขี่ตามประเภทความเสี่ยงจะมี 2 รูปแบบ ดังนี้


1. จากระยะทางที่ขับไม่สอดคล้องกับการบังคับใช้กฎหมายในพื้นที่นั้นๆ
2. จากจำนวนครั้งเหตุการณ์ที่ขับไม่สอดคล้องกับการบังคับใช้กฎหมายในพื้นที่นั้นๆ




รูปที่ 2.12 ตัวอย่างการประเมินพฤติกรรมการขับขี่จาก Geotab Technology

2.2.4 การเรียนรู้ของเครื่องและปัญญาประดิษฐ์สำหรับการจำแนกพฤติกรรมการขับขี่

จากการศึกษาปริทรรศน์วรรณกรรมพบว่า ในการจำแนกพฤติกรรมการขับขี่สามารถจำแนกได้ดังรูป ที่ 2.13 โดยประกอบด้วย การขับขี่แบบไม่ปกติ การขับขี่ด้วยอารมณ์ฉุนเฉียว หงุดหงิด และอื่นๆ ซึ่งการจำแนกพฤติกรรมการขับขี่ของรถยนต์ส่วนบุคคลสามารถนำค่าพารามิเตอร์ต่าง ๆ มาใช้ในการ คำนวณและจัดทำ Features ได้ดังรูปที่ 2.14




รูปที่ 2.13 การจำแนกพฤติกรรมการขับขี่ของรถยนต์ส่วนบุคคล




รูปที่ 2.14 Features สำหรับการจำแนกพฤติกรรมการขับขี่ของรถยนต์ส่วนบุคคล

การนำแบบจำลองทางคณิตศาสตร์ด้านการศึกษาพฤติกรรมการขับขี่ของรถยนต์ส่วนบุคคลมาประยุกต์กับ Machine Learning มีการนำเสนอโมเดลต่างๆ ดังรูปที่ 2.15 โดยที่ SVM: Support Vector Machine เป็นโมเดลที่ได้รับความนิยมในการนำมาจำแนกพฤติกรรมการขับขี่รถยนต์ส่วนบุคคลมากที่สุด ดังนั้น ในการเลือกโมเดลเพื่อใช้ในการจำแนกพฤติกรรมการขับขี่จึงมีการเลือกใช้โมเดล SVM เพื่อการประเมินและจำแนกพฤติกรรมการขับขี่รถยนต์ส่วนบุคคล




รูปที่ 2.15 แบบจำลองด้าน Machine Learning สำหรับการจำแนกพฤติกรรมการขับขี่ของรถยนต์ส่วนบุคคล

2.2.5 วิเคราะห์พฤติกรรมการขับขี่ของผู้ขับขี่ด้วยคุณสมบัติจากชุดข้อมูลหน่วยวัดแรงเฉื่อยของสมาร์ทโฟน



รูปที่ 2. 16 กรอบการทำงานของวิเคราะห์พฤติกรรมของผู้ขับขี่

งานวิจัยนี้ได้นำเสนอการใช้ประโยชน์จากข้อมูล IMU ที่บันทึกโดยใช้สมาร์ทโฟนที่วางอยู่ในรถยนต์ดังรูปที่ 2.16 เพื่อนำมาทำพฤติกรรมของผู้ขับขี่ ด้วยวิธีการทาง Machine Learning ได้แก่ Random Forest, Extra Tree Classifier, Logistic Regression, Support Vector Classifier, และ Extreme Gradient Boosting ด้วยการรวบรวมการเลือกคุณสมบัติทั้ง 6 วิธี พบว่า Random Forest และ Extreme Gradient Boosting มีผลลัพธ์ในด้าน accuracy precision recall และ f1-score ดีที่กว่าวิธีโมเดลอื่นแสดงดังรูปที่ 2.17




รูปที่ 2.17 ผลลัพธ์เปรียบเทียบจากการประเมินผลโมเดลด้วยการรวบรวมการเลือกคุณสมบัติทั้ง 6 วิธี

2.2.6 ปัจจัยด้านมนุษย์ในวงจรการขับขี่: การระบุตัวตนและการยืนยันตัวตนของผู้ขับขี่โดยใช้แนวทางการเรียนรู้เชิงลึกโดยใช้ข้อมูลทางพฤติกรรมทางจิตวิทยา

งานวิจัยต่อมาได้นำเสนอ การระบุตัวตนและการตรวจสอบยืนยันของผู้ขับขี่ผ่านแนวทางการเรียนรู้เชิงลึก (deep learning) เช่น CNN, LSTM, GRU, FCN, LSTM-FCN, Siamese Neural Network (proposed model) โดยใช้ข้อมูลพฤติกรรมทางจิตวิทยา (Psychological Behavioral Data) และข้อมูลส่วนใหญ่อยู่ในรูปแบบอนุกรมเวลา เช่น ข้อมูลการควบคุมยานพาหนะ และข้อมูลการเคลื่อนไหวของดวงตาที่รวบรวมจากเครื่องจำลองการขับขี่และเครื่องติดตามดวงตา พบว่าวิธีที่ถูกลำเสนอที่ได้คิดค้นขึ้นมาให้ผลลัพธ์ค่าความแม่นยำได้ถึง 99.60 % สำหรับการระบุตัวตนของผู้ขับขี่แสดงดังรูปที่ 2.18 และ ค่า accuracy, precision, recall, และ f1-score โดยรวมมากกว่า 70 % ขึ้นไป ของแต่ละผู้ขับขี่สำหรับการตรวจสอบแสดงดังรูปที่ 2.19

Model	Accuracy
CNN [9]	89.44%
LSTM [27]	87.45%
GRU	95.02%
FCN [45]	99.20%
LSTM-FCN [29]	99.00%
Ours	99.60%

รูปที่ 2.18 ผลลัพธ์เปรียบเทียบจากการประเมินผลโมเดลในด้าน accuracy สำหรับการระบุตัวตนของผู้ขับขี่



รูปที่ 2.19 ผลลัพธ์จากการประเมินผลโมเดลในด้าน accuracy สำหรับการตรวจสอบของผู้ขับขี่

2.2.7 การจัดทำโปรไฟล์ผู้ขับขี่โดยใช้ Long Short-Term Memory (LSTM) และ เครือข่ายประสาทเทียมแบบ Convolutional Neural Network (CNN)

การศึกษานี้เป็นการประเมินโปรไฟล์พฤติกรรมของผู้ขับขี่โดยใช้คุณสมบัติที่แตกต่างกัน 12 ตัวที่ได้รับจากระบบสื่อสาร CAN Bus ของยานพาหนะ ด้วยการเรียนรู้เชิงลึก (deep learning) 2 วิธีการได้แก่ CNN และ LSTM แล้วจำแนกพฤติกรรมของผู้ขับเป็น 3 หมวดหมู่ ได้แก่ Aggressive และ Gentle พบว่าผลลัพธ์ของของ CNN นั้นเหนือกว่าในทุกด้านแสดงดังรูปที่ 2.20


CNN							
Number of Layers	Epochs	Validation Loss	Validation Accuracy [%]	Test Accuracy [%]	Test Precision [%]	Test Recall [%]	Test F1 Score
1	200	0.08	97.1	93.2	93.2	93.2	0.93
2	200	0.05	97.7	95.7	95.7	95.7	0.96
3	200	0.03	99.4	96.1	96.1	96.1	0.96
4	200	0.01	99.8	95.3	95.2	95.3	0.95

LSTM								
Number of Layers	Number of Neurons	Epochs	Validation Loss	Validation Accuracy [%]	Test Accuracy [%]	Test Precision [%]	Test Recall [%]	Test F1 Score
1	27	500	0.16	93.7	87.7	88.5	87.7	0.88
2	27	500	0.12	95.4	92.3	92.2	92.3	0.92
3	27	500	0.13	96.0	90.0	91.1	90.6	0.91
4	27	500	0.09	97.1	93.2	93.1	93.2	0.93


รูปที่ 2.20เปรียบเทียบผลลัพธ์ระหว่าง CNN และ LSTM

2.2.8 การทดลองฝึกโมเดล Support Vector Machine (SVM) ด้วยชุดข้อมูล IMU sensors

เมื่อได้ต้นแบบโมเดลแล้ว จึงมีการค้นหาชุดข้อมูลสำเร็จรูปที่จัดเก็บข้อมูลที่เกี่ยวข้องกับการจำแนกพฤติกรรมการขับขี่รถยนต์ส่วนบุคคล โดยมีโครงสร้างการทำงานของระบบดังรูปที่ 2.21




รูปที่ 2.21 การนำแบบจำลองทางคณิตศาสตร์ด้านการศึกษาพฤติกรรมขับขี่ของรถยนต์ส่วนบุคคลมาประยุกต์กับ Machine Learning




รูปที่ 2.22 ผลการจำลองแบบประสิทธิภาพของระบบที่นำเสนอด้วย SVM

จากการจำลองแบบโดยระบบที่นำเสนอ มีผลประสิทธิภาพดังรูปที่ 2.22 พบว่า SVM สามารถใช้ประโยชน์ในการจำแนกพฤติกรรมการขับขี่รถยนต์ส่วนบุคคลได้ แต่เมื่อนำชุดข้อมูลฝึกฝนและทดสอบมาสลับกันทดสอบแสดงผลดังรูปที่ 2.23



รูปที่ 2.23 ผลการจำลองแบบประสิทธิภาพของระบบที่นำเสนอหลังจากสลับชุดข้อมูล

พบว่าผลลัพธ์ที่ได้ด้าน accuracy มีค่าต่ำมาก และไม่เหมาะสมกับการนำไปใช้ เนื่องจากทั้งสองโมเดลไม่สามารถจำแนกได้อย่างแม่นยำ และนำไปใช้ในโลกความเป็นจริงไม่ได้ เนื่องจากข้อมูลจากโลกความจริงเป็นข้อมูลแบบสุ่มก่อนจะเข้าสู่โมเดล ดังนั้น จึงได้นำเสนอโมเดล LSTM ซึ่งมีความซับซ้อนเพิ่มมากขึ้น เพื่อให้สามารถจำแนกข้อมูลที่ได้มาแบบสุ่ม และมีความซับซ้อนเป็นอนุกรมเวลา



Model	Size of model (Kilo Bytes)
LSTM (Long Short-Term Memory)	322
RF (Random Forest)	76,817

รูปที่ 2.24 ขนาดของโมเดลปัญญาประดิษฐ์ที่จะนำไปติดตั้งที่ TCU

อย่างไรก็ตามเมื่อพิจารณาถึงขนาดของโมเดลทางคณิตศาสตร์และโมเดลของปัญญาประดิษฐ์ที่จะนำไปใช้งาน พบว่า SVM มีขนาดของชุดโปรแกรมใหญ่ และ RF (Random Forest) ใช้พื้นที่หน่วยความจำในกล่อง TCU มาก ดังรูปที่ 2.24 จากการทดสอบเพิ่มเติม เพื่อให้แน่ใจที่สุดว่าโมเดลที่ผู้วิจัยนำเสนอมีความเหมาะสมกับชุดข้อมูลที่ได้จากกล่อง ECU และ IMU Sensor จึงได้มีการทดสอบเพิ่มเติม โดยมีการนำเสนอ LSTM เข้ามาช่วยในการจำแนกพฤติกรรมการขับขี่ ซึ่งผลเป็นดังรูปที่ 4.1 พบว่า LSTM มีสมรรถนะที่ดีที่สุดและมีความเหมาะสมในการนำไปใช้งานจริงกับชุดอุปกรณ์

2.2.9 การประเมินประสิทธิภาพและสมรรถนะของการเรียนรู้ของเครื่องและปัญญาประดิษฐ์

Confusion Matrix คือ การประเมินผลลัพธ์การทำนาย (ผลลัพธ์จากโปรแกรม) เปรียบเทียบกับผลลัพธ์จริงที่หาโดยคน และนำไปคำนวณค่า Accuracy Precision Recall และ F1 score

ตารางที่ 2.5 Confusion matrix

	Actually Positive 1	Actually Negative 0
Predicted Positive 1	True Positive TP	False Positives FP
Predicted Negative 0	False Negative FN	True Negative TN

1. เมื่อ TP (True Positive) คือ สิ่งที่ทำนาย ตรงกับสิ่งที่เกิดขึ้นจริง ในกรณี ทำนายว่าจริง และสิ่งที่เกิดขึ้นคือ จริง
2. TN (True Negative) คือ สิ่งที่ทำนายตรงกับสิ่งที่เกิดขึ้น ในกรณี ทำนายว่า ไม่จริง และสิ่งที่เกิดขึ้นคือ ไม่จริง
3. FP (False Positive) คือ สิ่งที่ทำนายไม่ตรงกับสิ่งที่เกิดขึ้น คือทำนายว่า จริง แต่สิ่งที่เกิดขึ้น คือ ไม่จริง
4. FN (False Negative) คือ สิ่งที่ทำนายไม่ตรงกับที่ที่เกิดขึ้นจริง คือทำนายว่าไม่จริง แต่สิ่งที่เกิดขึ้น คือ จริง

โดย TP TN FP และ FN ในตารางจะแทนด้วยค่าความถี่ สามารถใช้ Confusion Matrix มาคำนวณการประเมินประสิทธิภาพการทำนายของแบบจำลองทางคณิตศาสตร์

2.3 ITS (Intelligent Transportation System)

ระบบขนส่งอัจฉริยะ หรือ ITS เป็นระบบขนส่งที่นำเทคโนโลยีในแต่ละองค์ประกอบของระบบ (ยานยนต์ ผู้เดินทาง และระบบกายภาพของการขนส่งและถนน) มาใช้งานร่วมกัน ผสมผสานระหว่าง เทคโนโลยีที่ใช้อยู่ในปัจจุบันเข้ากับเทคโนโลยีที่คิดค้นขึ้นใหม่ เพื่อก่อให้เกิดการใช้งานระบบขนส่งอย่างมีประสิทธิภาพ เทคโนโลยีที่นำมาใช้กับระบบขนส่งประกอบไปด้วย งานประมวลผลข้อมูล ข่าวสาร งานสื่อสารโทรคมนาคม และงานด้านอิเล็กทรอนิกส์ โดยเทคโนโลยีเหล่านี้ถูกติดตั้งใช้งานอยู่บนยานพาหนะ อุปกรณ์ส่วนบุคคล เช่น ติดตั้งอยู่ข้างถนนและ ศูนย์ควบคุม นำมาใช้งานร่วมกัน ทำให้การขับขี่ยานยนต์บนถนน การโดยสารรถสาธารณะ การควบคุมจัดการจราจรหรือรถเชิงพาณิชย์ เกิดความคล่องตัว ปลอดภัย การโดยสารรถสาธารณะเกิดความสะดวกสบาย ระบบขนส่งอัจฉริยะ หรือ ITS ประกอบไปด้วย 4 รูปแบบ คือ 1.Vehicle-to-Vehicle (V2V) 2.Vehicle-to-Infrastructure (V2I) 3.Vehicle-to-Pedestrian (V2P) และ 4.Vehicle-to-Network (V2N) หรือเรียกว่า V2X Technology (Vehicle-to-Everything) ในงานวิจัยนี้ใช้ร่วมกับเทคโนโลยี Vehicle-to-Network (V2N)




รูปที่ 2.25 ภาพรวมรูปแบบการสื่อสารในระบบขนส่งอัจฉริยะ

2.4 V2N Technology (Vehicle-to-Network)

ภาพรวมรูปแบบการสื่อสารในระบบขนส่งอัจฉริยะแสดงได้ดังรูปที่ 2.26 โดยเนื้อหาในส่วนนี้เป็นการกล่าวถึงรูปแบบการสื่อสารแบบ V2N (Vehicle to Network Communication) ซึ่งเป็นการส่งข้อมูลจากรถยนต์ไปยังเซิร์ฟเวอร์ เพื่อทำการประมวลผลข้อมูลที่ถูกกำหนดไว้ และดึงข้อมูลที่ประมวลผลแล้ว ไปแสดงผลดังส่วนต่าง ๆ ที่เซิร์ฟเวอร์ การส่งข้อมูลจากรถยนต์ไปยังเซิร์ฟเวอร์สามารถส่งผ่านเทคโนโลยีการสื่อสารที่สอดคล้องกับระยะครอบคลุมการสื่อสาร อาทิเช่น DSRC, 4G-LTE/5G เป็นต้น เมื่อพิจารณาโครงสร้างของเทคโนโลยี V2N หัวใจสำคัญของการส่งข้อมูลจากรถยนต์

ไปยังระบบจัดเก็บข้อมูลจึงจำเป็นอย่างยิ่งที่จะต้องเลือกใช้ให้สอดคล้องกับสภาพแวดล้อมในการทำงาน



รูปที่ 2.26 ตัวอย่างโครงสร้าง V2N

2.5 บทสรุป

เนื้อหาในบทที่เป็นการกล่าวถึงการนำเทคโนโลยี V2N มาประยุกต์ใช้กับการศึกษาพฤติกรรมผู้ขับขี่ จากการศึกษาปริทัศน์ และวรรณกรรม ปัจจัยที่ส่งผลกระทบต่อการขับขี่มี 5 ประเภท คือ 1. ปัจจัยสภาพแวดล้อม 2. ปัจจัยด้านลักษณะของประชากร 3. ปัจจัยด้านสภาพจิต 4. ปัจจัยด้านสภาพรถ และ 5. ปัจจัยด้านการใช้ชีวิตประจำวัน งานวิจัยนี้สนใจที่ปัจจัยด้านสภาพรถ และปัจจัยด้านการใช้ชีวิตประจำวัน จากการศึกษาพฤติกรรมการขับขี่แบ่งออกเป็น 4 ประเภท งานวิจัยนี้ศึกษาพฤติกรรม การขับขี่ด้วยวิธีการการได้มาซึ่งข้อมูลปัจจุบัน (Real-time) ซึ่งประกอบไปด้วย ผู้ขับขี่ สภาพถนน และรถยนต์ ในการศึกษาพฤติกรรมการขับขี่ซึ่งข้อมูลปัจจุบัน (Real-time) ใช้แบบจำลองทางคณิตศาสตร์ Vehicle Data Condition และการศึกษาพฤติกรรมการขับขี่แบบออฟไลน์ (Off-line) ใช้แบบจำลองทางคณิตศาสตร์ Geotab technology ในระบบแจ้งเตือนแบบเรียลไทม์ ใช้แหล่งข้อมูลจาก เซนเซอร์ของโทรศัพท์ (smartphone sensors) กล้อง ECU และตัวตรวจรู้ความเร็ว และไจโรสโคป 3 แกน เพื่อนำมาทำเป็นชุดข้อมูลสำหรับการฝึกฝนโมเดล ตลอดจนการนำโมเดลปัญญาประดิษฐ์ มาเรียนรู้และฝึกฝนแบบ LSTM นอกจากนี้ยังได้นำโมเดลแบบ LSTM มาเปรียบเทียบกับโมเดลอื่น ด้วยการประเมินผลในด้วย accuracy precision recall และ f1-score สำหรับตัวชี้วัดประสิทธิภาพ

และในด้านขนาดของโมเดล ตลอดจนนำโกลมาติดตั้งกับอุปกรณ์ TCU เพื่อจำแนกพฤติกรรมผู้ขับขี่ผ่าน การนำเข้าคุณสมบัติ ได้แก่ ความเร็วรถยนต์ ตำแหน่งคันเร่ง ความเร่ง 3 แกน และไจโรสโคป 3 แกน และนำส่งข้อมูลไปยัง Dashboard ผ่านเทคโนโลยี V2N และฐานข้อมูลพฤติกรรมผู้ขับขี่แสดงดัง ตารางที่ 2.6

ตารางที่ 2.6 ตารางสรุปผลการเลือกใช้งานจากการศึกษาปริทัศน์วรรณกรรมทั้งหมด

Study Type	Performance Evaluation	Data Source	Feature	Methodology	
Field driving study	1.Accuracy 2.Precision 3.Recall 4.F1-Score	1.Smartphone sensors 2.ECU data 3.Accelerometer 4.Gyroscope	1.Vehicle speed 2.Throttle position 3.Rotation rate/angle 4.Acceleration	1. Support Vector Machine (SVM) 2. Random Forest (RF) 3. Logistic Regression (LR)	1. LSTM 2. CNN

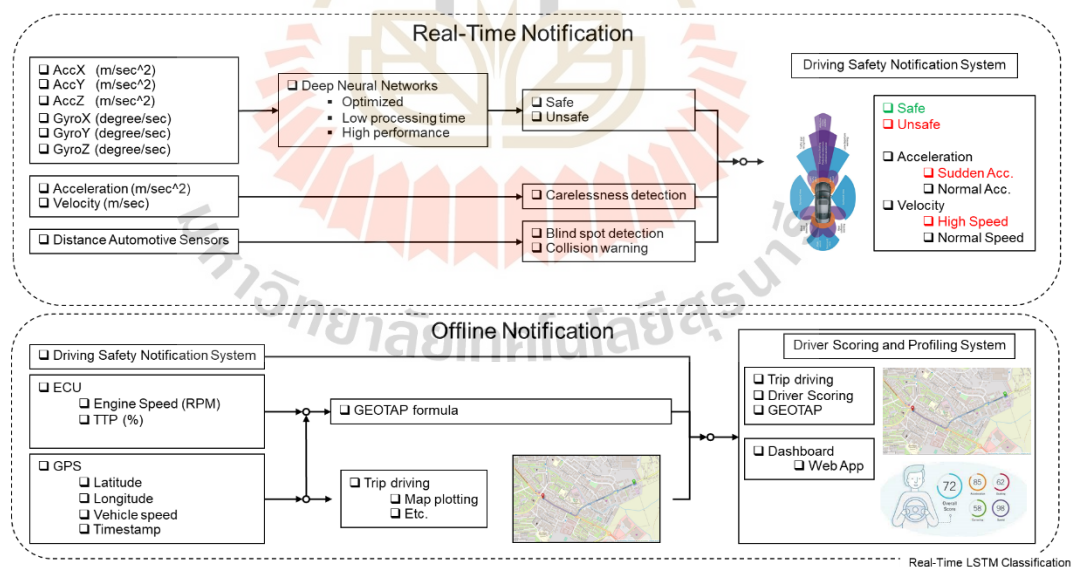
บทที่ 3

วิธีดำเนินการวิจัย

ในบทนี้ได้นำเสนอวิธีการดำเนินการวิจัยและเนื้อหาสำคัญประกอบไปด้วย 4 หัวข้อหลักได้แก่ วัสดุที่ใช้ในการวิจัย วิธีดำเนินการวิจัย การสร้างโมเดลปัญญาประดิษฐ์ที่เกี่ยวข้อง และการออกแบบระบบเทเลเมติกส์ โดยมีรายละเอียดดังนี้

3.1 วัสดุที่ใช้ในการวิจัย


วัสดุที่ใช้ในการวิจัยประกอบด้วยอุปกรณ์ติดรถ ที่ติดตั้งกับกล่อง TCU เพื่อดึงค่าพารามิเตอร์ต่างๆที่เกี่ยวข้องจากกล่อง ECU ส่งไปประมวลผลพฤติกรรมการขับขี่ โดยระบบที่นำเสนอเป็นไปดังรูปที่ 3.1 ประกอบไปด้วยส่วน Realtime dashboard ที่สามารถแจ้งเตือนผู้ขับขี่เมื่อมีพฤติกรรมการขับขี่ที่ไม่พึงประสงค์ได้ และเมื่อมีการขับขี่แล้วเสร็จ สามารถนำผลการบันทึกข้อมูลเข้ามาใช้เพื่อปรับปรุงพฤติกรรมการขับขี่ของตนเองให้เกิดความปลอดภัยต่อตนเองและผู้อื่น ซึ่งเป็นการเสริมความปลอดภัยในการใช้ถนน



รูปที่ 3.1 ระบบที่นำเสนอ

3.2 วิธีการดำเนินการวิจัย

การเลือกโมเดลปัญญาประดิษฐ์ที่เหมาะสมสำหรับการจำแนกพฤติกรรมการขับขี่ ทางผู้วิจัยได้นำชุดข้อมูลการขับขี่จากฐานข้อมูลที่น่าเชื่อถือ [Kaggle] เพื่อนำชุดข้อมูลดังกล่าวมาทำการประมวลผลล่วงหน้า (preprocessing data) ด้วย Google Colab โดยมีลำดับการทำงาน ได้แก่ data visualization, feature selection, feature scaling, data splitting, model creation, และ model evaluation ดังรูปที่ 3.2




รูปที่ 3.2 ขั้นตอนการคัดแยกข้อมูล

3.2.1 Data visualization

ก่อนนำชุดข้อมูลไปฝึกฝนหรือใช้งานควรตรวจสอบความพร้อมของข้อมูลชุดให้ดีขึ้น ในกระบวนการนี้เป็นกระบวนการ visualization ข้อมูลด้วย 2 วิธีการ เพื่อตรวจสอบความสัมพันธ์ระหว่างคุณลักษณะ และการกระจายตัวของข้อมูล โดยมีรายละเอียดดังนี้

1. การตรวจสอบความสัมพันธ์ระหว่างคุณลักษณะของชุดข้อมูลด้วยการพล็อตกราฟแบบอนุกรมเวลา


จากรูปที่ 3.3 คุณลักษณะจากชุดข้อมูลถูกพล็อตแบบอนุกรมเวลาประกอบด้วย 12 คุณลักษณะ ได้แก่ ความเร่งในแนวแกน x, y, และ z ไจโรสโคปในแนวแกน x, y, และ z ความเร็วรถยนต์ ลองจิจูด ละติจูด เฮดดิ้ง ระยะทาง และป้ายกำกับ จากการวิเคราะห์พบว่า ความเร่งในแนวแกน x, y, และ z (Acc_X, Acc_Y, และ Acc_Z) ไจโรสโคปในแนวแกน x, y, และ z (Gyro_X, Gyro_Y, และ Gyro_Z) และความเร็วรถยนต์นั้นมีความสัมพันธ์กันในแต่ละช่วง เมื่อช่วงที่มีความเร็วของรถสูง ความเร่งในแนวแกน x, y, และ z ไจโรสโคปในแนวแกน x, y, และ z มักจะมีการแกว่งของกราฟสูงด้วยเช่นกันสังเกตได้จากสีแดง และสีเขียวจากกราฟ โดยที่สีแดงหมายถึงการขับขี่แบบไม่ปลอดภัย และสีเขียวหมายถึงการขับขี่แบบปลอดภัย ที่มีความสอดคล้องกับค่าของป้ายกำกับ (Label) หรือค่าเป้าหมาย และค่าของป้ายกำกับ หรือค่าเป้าหมายจะถูกนำไปเป็นค่าผลเฉลยสำหรับการฝึกฝนโมเดลภายหลัง



รูปที่ 3.3 Visualization ข้อมูลด้วยกราฟอนุกรมเวลา

2. การตรวจสอบการกระจายข้อมูลของแต่ละคุณลักษณะของชุดข้อมูลด้วยการพลอตกราฟแบบฮิสโทแกรม

จากการพลอตแบบอนุกรมเวลา ทำให้ทราบความสัมพันธ์ระหว่างคุณลักษณะพบว่าจากรูปที่ 3.3 คุณลักษณะจากชุดข้อมูลถูกพลอตแบบฮิสโทแกรม (histogram) พบว่าความเร่งในแนวนอน x, y, และ z ไจโรสโคปในแนวนอน x, y, และ z และความเร็วยนต์มีความสัมพันธ์กัน ดังนั้นในการพลอตสำหรับฮิสโทแกรม จะถูกพลอตเฉพาะ 7 คุณลักษณะที่มีความสัมพันธ์กันดังรูปที่ 3.4



รูปที่ 3.4 Visualization ข้อมูลด้วยกราฟฮิสโทแกรม

จากรูปที่ 3.4 เมื่อคุณลักษณะทั้ง 7 ถูกพลอตแบบฮิสโทแกรมพบว่า ความเร่งในแนวแกน x, y, และ z ไจโรสโคปในแนวแกน x, y, และ z มีการกระจายแบบปกติ (normal distribution) แต่ความเร็วรถยนต์มีการกระจายที่ไม่แน่ชัด ดังนั้นความเร่งในแนวแกน x, y, และ z ไจโรสโคปในแนวแกน x, y, และ z จะถูกนำไปใช้งานต่อในขั้นตอนถัดไปเพื่อเป็นคุณลักษณะและชุดข้อมูลการฝึกฝนสำหรับโมเดล แต่ความเร็วรถยนต์จะไม่ถูกนำไปใช้งานต่อ

3.2.2 การปรับขนาดคุณลักษณะ (Feature Scaling)

จากหัวข้อก่อนหน้านี้ได้นำข้อมูลมา visualization ทราบลักษณะ ภาพรวมของข้อมูล และคุณลักษณะที่จะถูกนำไปใช้งานต่อ ในหัวข้อนี้คุณลักษณะที่ถูกเลือกจะถูกนำไปปรับขนาด เพื่อให้ช่วงของข้อมูลในแต่ละคุณลักษณะมีช่วงที่ใกล้เคียงกัน เพื่อไม่ให้ค่าบางจุดสูงหรือต่ำเกินคุณลักษณะตัวอื่น

จากรูปที่ 3.5 เป็นโครงสร้างการนำเข้าคุณลักษณะเพื่อปรับขนาดให้เท่ากันด้วยเทคนิค Standardization (Z-score Normalization) เนื่องจากมีการกระจายแบบปกติคุณลักษณะแต่ละตัวจะถูกป้อนเข้าสู่สมการที่ 3


$$Z = \frac{x - \text{Mean}}{\text{Standard Deviation}} \quad (3)$$

โดยที่ Z คือ ค่าผลลัพธ์จากการปรับขนาดของแต่ละจุดข้อมูล

x คือ ค่าของแต่ละจุดข้อมูล

Mean คือ ค่าเฉลี่ยของคุณลักษณะนั้นๆ

$\text{Standard Deviation}$ คือ ค่าส่วนเบี่ยงเบนมาตรฐาน




รูปที่ 3.5 การคัดแยกข้อมูลและการกระจายตัวของชุดข้อมูล

เมื่อข้อมูลดังกล่าวผ่านการปรับขนาดแล้ว ทำให้ได้ค่าส่วนเบี่ยงเบนมาตรฐานประมาณ 1 ดังนั้นข้อมูลของแต่ละคุณลักษณะมีความเหมาะสมกันและมีการกระจายคล้ายกัน จึงสามารถนำไปใช้งานต่อในขั้นตอนถัดไปได้

3.2.3 การแยกข้อมูล (Data Splitting)


ก่อนจะนำข้อมูลไปฝึกฝนโมเดล ต้องแยกข้อมูลออกเป็นสัดส่วนก่อน ข้อมูลที่ถูกปรับขนาดแล้วจะถูกแบ่งส่วนออกเป็น 3 ส่วน ได้แก่ ชุดข้อมูลฝึกฝน (training set) ตรวจสอบ (Validation set) และทดสอบ (Test set) เป็นสัดส่วน 70% 20% และ 10% ตามลำดับ ในส่วนของข้อมูลชุดฝึกฝน และชุดตรวจสอบ จะนำไปให้โมเดลฝึกฝนด้วยข้อมูลชุดฝึกฝน และปรับแก้ด้วยชุดข้อมูลตรวจสอบ ในส่วนชุดข้อมูลทดสอบ จะถูกแยกออกมาไว้สำหรับประเมินประสิทธิภาพโมเดล โดยข้อมูลทดสอบเป็นข้อมูลที่โมเดลไม่เคยเห็นมาก่อน สัดส่วนโครงสร้างการแบ่งชุดข้อมูลแสดงดังรูปที่ 3.6



รูปที่ 3.6 การแบ่งชุดข้อมูลเพื่อใช้ในการฝึกฝนโมเดล การทดสอบโมเดล

3.2.4 การสร้างโมเดล (Model Creation)

จากการแยกข้อมูลในส่วนชุดข้อมูลฝึกฝน 70% และข้อมูลชุดตรวจสอบจะถูกนำไปให้โมเดลเรียนรู้และปรับแก้ด้วยโมเดลแบบ LSTM (Long Short-Term Memory) เมื่อโมเดลถูกฝึกฝนเสร็จ ตัวโมเดลจะได้ค่าพารามิเตอร์ต่างๆ เช่น ค่าเวท (weight) และไบแอส (bias) เป็นต้น และถูกจดจำไว้ในตัวโมเดลพร้อมสำหรับการนำไปใช้งาน และสามารถจำแนกพฤติกรรมการขับขี่ได้แบบปลอดภัย และแบบไม่ปลอดภัย สำหรับโครงสร้างการนำเข้า และโครงข่ายประสาทเทียมของโมเดลแสดงดังรูปที่ 3.7 และพารามิเตอร์สำหรับโครงข่ายประสาทเทียมที่ถูกกำหนดแสดงดังตารางที่ 3.1



รูปที่ 3.7 การสร้างโมเดลและผลผลิตของโมเดลในการจำแนกพฤติกรรมการขับขี่

ตารางที่ 3.1 การกำหนดพารามิเตอร์ของโครงข่ายประสาทเทียมแบบ LSTM

Parameter	Values	Comments
Batch size	32	
Timestep	100	
Features	6	
Epochs	200	
Learning rate	0.05	Implement on ADAM optimization
Loss function		Binary cross entropy
neural network parameters		
Dense layer	Shape: (None, 100, 6)	Input layer
LSTM layer	Shape: (None, 100, 64)	Hidden layer
Dense_1	Shape: (None, 100, 1)	Output layer

จากรูปที่ 3.7 ในส่วนรายละเอียดโครงสร้างของโมเดลประกอบไปด้วย 3 ส่วนหลัก ได้แก่ ชั้นนำเข้าข้อมูล ชั้นที่ซ่อนอยู่ และชั้นเอาต์พุต โดยมีรายละเอียดดังนี้


1. ชั้นนำเข้าชุดข้อมูล (Input layer)

ในส่วนของโครงสร้างชั้นนำเข้าข้อมูล คือ LSTM input layer ประกอบไปด้วย พารามิเตอร์ดังนี้

1.1 Input unit คือการกำหนดขนาดของการนำเข้าข้อมูลที่เรียนรู้และทำนายผลในโมเดลมีขนาดเท่ากับ 6 units นั่นคือโมเดลสามารถนำเข้าข้อมูลได้ 6 ประเภทที่สอดคล้องกับ IMU data ที่ประกอบด้วยข้อมูล Ax, Ay, Az, Gx, Gy และ Gz

1.2 Input shape คือขนาดหรือมิติของข้อมูลที่ถูกนำเข้า ในโมเดลมีมิติของข้อมูลนำเข้า

เป็น 1 แถว 1 คอลัมน์ และ 100 แถวซ้อน 6 คอลัมน์ ภายในประกอบด้วย IMU data ดังรูปที่ 3.8



รูปที่ 3.8 มิติของการนำเข้าสู่ข้อมูล


2. ชั้นที่ซ่อนอยู่ (Hidden layer)

จากชั้นนำเข้าสู่ข้อมูลมีการส่งต่อไปยังชั้นภายในคือชั้นที่ซ่อนอยู่ประกอบด้วยพารามิเตอร์ดังนี้

2.1 Input units คือขนาดหรือมิติของข้อมูลที่ถูกนำเข้าสู่จากชั้นก่อนหน้า ในชั้นนี้มีขนาดของ units เท่ากับ 64

2.2 Activation function คือฟังก์ชันที่รับผลรวมการประมวลผลทั้งหมด จากทุก Input ของชั้นก่อนหน้า แล้วพิจารณาผ่านฟังก์ชันว่าจะส่งต่อเป็น output เท่าไร ในชั้นนี้ tanh function ได้ถูกกำหนดเป็น activation function

2.3 Recurrent activation function คือฟังก์ชันที่รับผลรวมการประมวลผลทั้งหมด จาก input ของการคำนวณลำดับก่อนหน้า แล้วส่งผ่านฟังก์ชันไปเป็น output ให้กับ unit ถัดไปดังรูปที่ 3.9 ในชั้นนี้ tanh function ได้ถูกกำหนดเป็น recurrent activation function



รูปที่ 3.9 มิติของการนำเข้าสู่ข้อมูล

3. ชั้นเอาต์พุต (Output layer)


ในลำดับสุดท้ายของโครงสร้างโมเดลคือชั้นเอาต์พุต เป็นชั้นสำหรับทำนายหรือจำแนกประเภทของข้อมูล ในโมเดลนี้ได้กำหนด unit เป็น 1 unit เนื่องจากโมเดลควรจะสามารถ

จำแนกข้อมูลผู้ขับชื้อออกเป็นแบบปลอดภัย และแบบไม่ปลอดภัย หรือ 0 และ 1 การจำแนกลักษณะนี้ ถูกเรียกว่าการจำแนกแบบไบนารี (Binary Classification) นอกจากนี้ยังได้กำหนด activation function เป็น sigmoid function อีกด้วย เนื่องจากฟังก์ชันนี้สามารถให้ผลลัพธ์อยู่ระหว่าง 0 – 1 จึงเหมาะที่จะถูกใช้ในงานที่ต้องการ output เป็นความน่าจะเป็น หรือใช้เป็น output ว่า 0 = แบบ ปลอดภัย และ 1 = แบบไม่ปลอดภัย กราฟจากการคำนวณผ่าน sigmoid function ดังสมการที่ 4 และมีลักษณะเป็น S curve แสดงดังรูปที่ 3.10

$$\sigma(x) = \frac{1}{1+e^{-x}} \quad (4)$$

โดยที่ $\sigma(x)$ คือค่าของฟังก์ชัน sigmoid มีช่วงระหว่าง 0 ถึง 1 และมีจุดตัดสนใจอยู่ที่ 0.5


x คือค่าจากการทำนายของโมเดลชั้นเอาต์พุต



รูปที่ 3.10 ลักษณะกราฟของ sigmoid function ที่ผ่านการคำนวณ

3.3 การออกแบบระบบтелеเมติกส์

การออกแบบระบบтелеเมติกส์ควรมีความเหมาะสมในส่วนของอุปกรณ์ ระบบสื่อสาร V2N ระบบจ่ายไฟ และระบบการประมวลผล ในหัวนี้ก็จะถึงละเอียดในการออกแบบระบบส่วนต่าง ๆ ดังนี้



รูปที่ 3.11 โครงสร้างพื้นฐานระบบтелеเมติกส์

จากรูปที่ 3.11 คือโครงสร้างพื้นฐานของระบบтелеเมติกส์ที่ถูกออกแบบ ประกอบด้วย 5 ส่วนหลัก ได้แก่ ระบบจ่ายไฟ ระบบสั่งการจากโทรศัพท์ กล้อง ECU ระบบประมวลผล และระบบแสดงผลและเก็บข้อมูล

3.3.1 ระบบจ่ายไฟ


รถยนต์ส่วนบุคคลสามารถเชื่อมต่อระบบไฟฟ้าจากแบตเตอรี่ได้ และถูกแปลงจาก 12 โวลต์ เป็น 5 โวลต์ ด้วยอุปกรณ์แปลงไฟเพื่อจ่ายไฟกระแสตรงให้กับอุปกรณ์телеเมติกส์ผ่าน USB-C interface ด้วยแรงดันไฟฟ้ากระแสตรง 5 โวลต์ และ 2 แอมแปร์

3.3.2 ระบบสั่งการจากโทรศัพท์

เนื่องจากอุปกรณ์телеเมติกส์จำเป็นต้องมีการส่งและเก็บข้อมูลจากกล่อง ECU เพื่อนำไปประมวลผล ด้วยเหตุนี้จึงต้องมีตัวควบคุมการส่งข้อมูลจากกล่อง ECU ออกมา ในส่วนนี้ได้ใช้โทรศัพท์มือถือ และแอปพลิเคชันสั่งการไปยัง OBD-II Scanner ผ่าน Bluetooth ที่ต่ออยู่ระหว่างกล่อง ECU ผ่าน OBD-II interface นอกจากนี้ยังใช้ค่าจากแอปพลิเคชันที่วัดได้จะถูกนำไปเปรียบเทียบกับผลลัพธ์ที่ออกมาจากกล่อง ECU ไปยังกล่อง TCU เพื่อตรวจสอบค่าที่วัดได้ให้ใกล้เคียงกัน

3.3.3 กล่อง ECU (Electronics Control Unit)

กล่อง ECU คืออุปกรณ์อิเล็กทรอนิกส์ ทำหน้าที่ควบคุมระบบการทำงานต่าง ๆ ของรถยนต์ เป็นเสมือนคอมพิวเตอร์ที่ถูกติดตั้งบนรถยนต์ สำหรับรถยนต์แต่ละยี่ห้อจะมีกล่อง ECU เฉพาะตัว ในงานวิจัยนี้ได้ใช้กล่อง ECU ของรถยนต์ Chevrolet Cruze 1.6 Model 2011




รูปที่ 3.12 Chevrolet Cruze 1.6 Model 2011

3.3.4 ระบบประมวลผล

ในส่วนนี้ประกอบไปด้วยส่วนของการรับค่าจากกล่อง ECU และ sensor และระบบประมวลผลและส่งข้อมูล โดยมีรายละเอียดดังนี้

ข้อมูลจากกล่อง ECU ถูกไหลผ่าน OBD-II interface ไปยัง OBD-II Shield ที่ถูกต่ออยู่กับ Arduino UNO R3 ที่ถูกโปรแกรมให้รับค่าอุปกรณ์ภายในรถที่ถูกจัดเก็บในกล่อง ECU จากนั้นได้ส่งต่อให้กับ Raspberry Pi 4 model B ผ่าน USB Serial port ด้วย baud rate เท่ากับ 115200 bps เพื่อนำส่งไปยัง software ที่ถูกพัฒนาขึ้นด้วยภาษา Python version 3 จากนั้น software ได้ทำการประมวลผลด้วยอัลกอริทึมทางคณิตศาสตร์ และปัญญาประดิษฐ์ดังรูปที่ 3.13



รูปที่ 3.13 โครงสร้างของระบบ software

3.3.5 ระบบแสดงผลและเก็บข้อมูล

ในส่วนนี้เป็นส่วนแสดงผลหลังจากการจำแนกผ่านอัลกอริทึมของ software จะถูกแสดงผลด้วย 7 inch HDMI Screen Display ที่ต่ออยู่กับ Raspberry Pi 4 model B ผ่านสาย HDMI ดังรูปที่ 3.14



รูปที่ 3.14 รูปแบบการแจ้งเตือนด้วย In-vehicle Display System

นอกจากนี้ยังมีการส่งข้อมูลผ่านเครือข่าย V2N ด้วย เทคโนโลยี 4G ผ่าน MQTT protocol ไปยัง Thingsboard และจัดเก็บข้อมูลไว้ใน Thingsboard และ log files ที่ถูกจัดเก็บภายใน Raspberry Pi 4 model B อีกด้วย เพื่อนำไปประมวลผลและแสดงผลย้อนหลัง หรือ Offline Notification ผ่านการ visualization บน Google Colab ในลำดับต่อไป

บทที่ 4

ผลการวิจัย

ในบทนี้จะกล่าวถึงผลการทดสอบทั้งผลการทดสอบการประเมินประสิทธิภาพโมเดลที่ถูกสร้างขึ้นด้วย Confusion metrics อีกทั้งยังเปรียบเทียบกับโมเดลอื่น ๆ ด้วย นอกจากนี้ยังกล่าวถึงการติดตั้งชุดอุปกรณ์ทดสอบ การทดสอบคุณภาพสัญญาณ 4G/5G สำหรับ V2N และการทดสอบเก็บผลจากการขับรถยนต์ส่วนบุคคลจริงเพื่อจำแนกพฤติกรรมการขับขี่ โดยมีรายละเอียดดังนี้

4.1 การประเมินประสิทธิภาพโมเดลที่ถูกสร้างขึ้นด้วย Confusion metrics

classification) ค่าจาก Confusion metrics ประกอบด้วย *TPs* (True Positive) *TNs* (True Negative) *FPs* (False Positive) และ *FNs* (False Negative) ค่าเหล่านี้สามารถคำนวณหาพารามิเตอร์ประสิทธิภาพด้าน accuracy precision recall และ f1-score ได้ โดยแต่ละพารามิเตอร์มีความหมายดังนี้

4.1.1 Accuracy (ความถูกต้อง)

ความถูกต้อง หมายความว่าความถูกต้องที่โมเดลจำแนกได้ตรงกับสิ่งที่เกิดขึ้นจริง หรือกล่าวได้ว่า ผลรวมของตัวเลขบนเส้นทแยงมุมในตาราง Confusion Matrixหารด้วยจำนวนที่สังเกตทั้งหมดดังสมการที่ 5

$$Accuracy = \frac{(TPs+TNs)}{(TPs+TNs+FPs+FNs)} \quad (5)$$

4.1.2 Precision (ความแม่นยำ)

ความแม่นยำ หมายถึงโมเดลสามารถจำแนกได้เป็นแบบปลอดภัย หรือแบบไม่ปลอดภัยได้บ่อยครั้ง (แต่ไม่จำเป็นต้องถูกต้องเสมอไป) หรือเป็นการเปรียบเทียบการจำแนกที่ถูกต้องว่าจริง และเกิดขึ้นจริง (TP) กับการจำแนกว่าจริง แต่สิ่งที่เกิดขึ้นคือ ไม่จริง (FP) แสดงดังสมการที่ 6

$$Precision = \frac{(TPs)}{(TPs+FPs)} \quad (6)$$

4.1.3 Sensitivity or Recall (ความไว)

ความไว หมายถึงโมเดลสามารถจำแนกได้เป็นแบบปลอดภัย หรือแบบไม่ปลอดภัยได้ถูกต้องหรือจำแนกได้ตรงกับผลเฉลยมากเพียงใด หรือความถูกต้องของการจำแนกว่าเป็นจริงเทียบกับจำนวนครั้งของเหตุการณ์ที่จำแนก และเกิดขึ้นเป็นจริง แสดงดังสมการที่ 7

$$Recall = \frac{(TPs)}{(TPs+FNs)} \quad (7)$$


4.1.4 F1-Score (ค่าเฉลี่ยระหว่าง precision และ recall)

ค่าเฉลี่ยระหว่าง precision และ recall หรือค่าเฉลี่ยแบบฮาร์โมนิก (Harmonic mean) เป็นพารามิเตอร์สำหรับวัดความสามารถของโมเดลโดยรวม (Single metric) จากการเปรียบเทียบ 2 พารามิเตอร์ ประกอบด้วยความแม่นยำ และค่าความไว สามารถคำนวณได้ดังสมการที่ 8

$$F1 - Score = 2 \times \frac{(Precision \times Recall)}{(Precision + Recall)} \quad (8)$$

จากการพารามิเตอร์ และสมการดังกล่าว สามารถประเมินประสิทธิภาพโมเดลได้ดังรูปที่ 4.1 โมเดลที่ถูกวัดประสิทธิภาพได้แก่ Support Vector Machine (SVM) Logistic Regression (LR) Random Forest (RF) Decision Tree (DT) และ Long Short Term Memory (LSTM) โดยมีผลการประเมินในด้านต่าง ๆ ดังนี้

1. SVM ให้ผลประสิทธิภาพด้าน accuracy precision recall และ f1-score เท่ากับ 0.47, 0.49, 0.48 และ 0.41 หรือคิดเป็น 47%, 49%, 48% และ 41% ตามลำดับ
2. LR ให้ผลประสิทธิภาพด้าน accuracy precision recall และ f1-score เท่ากับ 0.38, 0.59, 0.62 และ 0.35 หรือคิดเป็น 38%, 59%, 62% และ 35% ตามลำดับ
3. RF ให้ผลประสิทธิภาพด้าน accuracy precision recall และ f1-score เท่ากับ 0.89, 0.78, 0.89 และ 0.82 หรือคิดเป็น 89%, 78%, 89% และ 82% ตามลำดับ
4. DT ให้ผลประสิทธิภาพด้าน accuracy precision recall และ f1-score เท่ากับ 0.74, 0.66, 0.79 และ 0.67 หรือคิดเป็น 74%, 66%, 79% และ 67% ตามลำดับ
5. LSTM ให้ผลประสิทธิภาพด้าน accuracy precision recall และ f1-score เท่ากับ 0.94, 0.85, 0.77 และ 0.81 หรือคิดเป็น 94%, 85%, 77% และ 81% ตามลำดับ



รูปที่ 4.1 ผลการจำลองแบบ

จากรูปที่ 4.1 พบว่า LSTM และ RF มีผลลัพธ์ดีกว่าโมเดลอื่นๆ เมื่อเปรียบเทียบระหว่าง 2 โมเดลดังกล่าว พบว่า LSTM ให้ผลลัพธ์ด้าน accuracy และ precision มากที่สุด ในขณะที่ RF ให้


ผลลัพธ์ด้าน recall และ f1-score ดีที่สุด ดังนั้น LSTM เป็นโมเดลปัญญาประดิษฐ์ที่เหมาะสมสำหรับการใช้จำแนกพฤติกรรมการขับขี่รถยนต์ส่วนบุคคลมากที่สุด พบว่า LSTM ให้สมรรถนะสูงสุดในด้าน accuracy และ precision และมีความเหมาะสมกับงาน safety application ที่สุดเนื่องจากมี accuracy สูงสุด

4.2 การติดตั้งชุดอุปกรณ์ทดสอบ


อุปกรณ์ที่จะนำมาติดตั้งเพื่อประกอบเป็นกล่อง TCU ประกอบด้วยอุปกรณ์ดังนี้

1. Raspberry Pi 4 Model B
2. Quectel RM502Q-AE
3. RM502Q-AE HAT
4. 7 Inch Display
5. CAN-BUS Shield
6. Arduino UNO R3
7. IMU (Inertial Measurement Unit) sensors
8. Antenna จำนวน 3 ต้น


สำหรับรายละเอียดการติดตั้ง Quectel RM502Q-AE คือชิป cellular จะถูกเสียบใส่ slot M.2 interface ของ Quectel RM502Q-AE หรือ cellular module และสามารถใส่สายอากาศได้มากที่สุด 4 ต้น ในชุดอุปกรณ์นี้จะใส่เพียง 3 ต้นที่ถูก attached on top อยู่บน Raspberry Pi 4 Model B แสดงดังรูปที่ 4.2 ฝั่งด้านซ้าย และถูกต่ออยู่กับ Arduino UNO R3 ผ่าน USB serial ที่ถูก attached on top ด้วย CAN-BUS Shield แสดงดังรูปที่ 4.2 ฝั่งด้านขวา ต่อมาในส่วนของ IMU sensors ถูกวางอยู่ด้านหน้าของ Raspberry Pi 4 Model B บนกล่อง และเชื่อมต่อกับ Arduino UNO R3 ผ่าน SPI Interface และขนาดของกล่องโดยรวมมีขนาดความกว้าง ความยาว และความสูง ประมาณ 144.0, 148.0 และ 57.2 มิลลิเมตร ตามลำดับ แสดงดังรูปที่ 4.3 รูปที่ 4.4 และรูปที่ 4.5 เป็นภาพประกอบเมื่อกล่องถูกประกอบสำเร็จแล้ว



รูปที่ 4.2 ภาพจำลองสัปดาห์การจัดวางชุดอุปกรณ์ที่นำเสนอ



รูปที่ 4.3 ภาพจำลองขนาดชุดอุปกรณ์ที่นำเสนอ



รูปที่ 4.4 ภาพจำลองชุดอุปกรณ์ที่นำเสนอชุดสมบูรณ์




รูปที่ 4.5 ภาพชุดอุปกรณ์ที่นำเสนอ

4.3 การทดสอบคุณภาพสัญญาณ 4G/5G สำหรับ V2N

เทคโนโลยี V2N อาศัยการใช้ประโยชน์จากโครงข่ายระบบโทรศัพท์เคลื่อนที่ 4G/5G สำหรับการส่งข้อมูลจากกล่อง TCU ไปยัง Database ซึ่งเรียกระบบ Telematics ข้อมูลจากกล่อง TCU จะถูกเก็บบันทึกผลไว้ใน Database และนำไปประมวลผลพฤติกรรมรถขับขี่ เพื่อแจ้งเตือนผู้ขับขี่ในระหว่างขับรถ และสามารถตรวจสอบข้อมูลย้อนหลังจากฐานข้อมูล เพื่อวิเคราะห์พฤติกรรมรถขับขี่อย่างละเอียด ผู้วิจัยได้ทำการตรวจสอบคุณภาพสัญญาณ 4G/5G ทั้งด้าน Radio parameters และ


ด้าน End Parameters ซึ่งสมรรถนะของโครงข่ายมีผลอย่างยิ่งต่อการรับ-ส่งข้อมูลด้วยเทคโนโลยี V2N และ Telematics



รูปที่ 4.6 แผนภาพการทดสอบคุณภาพสัญญาณ 5G




รูปที่ 4.7 พื้นที่การทดสอบคุณภาพสัญญาณ 4G และ 5G



รูปที่ 4.8 ผลการทดสอบคุณภาพสัญญาณ 5G ด้าน End Parameters

ตารางที่ 4.1 ตารางแสดงผลการทดสอบคุณภาพสัญญาณ 5G ด้าน End Parameters

5G SA Band n41				
No.	Download (Mbps)	Upload (Mbps)	Jitter (ms)	RTT (ms)
1	223.26	31.77	0.51	19.9
2	370.69	64.65	0.54	25
3	412.83	28.19	0.5	24.9
4	352.67	61.41	2.91	19.8
5	209.71	36.02	3.08	23.4
Average	313.83	44.41	1.51	22.6



รูปที่ 4.9 ผลการทดสอบคุณภาพสัญญาณ 5G ด้าน Radios Parameters

ตารางที่ 4.2 ตารางแสดงผลการทดสอบคุณภาพสัญญาณ 5G ด้าน Radio Parameters

5G SA Band n41		
Radio parameters	Our DUT	Test phone
SS-RSRP (dBm)	-68	-71
SS-RSRQ (dB)	-12	-12
SS-SINR (dB)	4	5

โดยสรุป การส่งข้อมูลพฤติกรรม การขับขี่จากรถยนต์ส่วนบุคคลไปยัง Dashboard ผ่านเทคโนโลยี V2N อาศัยโครงข่ายโทรคมนาคมแบบเคลื่อนที่ โดยผลการวิจัยพบว่า โครงข่าย 5G สามารถรับ-ส่งข้อมูลได้อย่างรวดเร็วดังตารางที่ 4.1 และตารางที่ 4.2 แสดงผลให้เห็นว่าคุณภาพสัญญาณด้าน Radio parameters ของอุปกรณ์ที่นำเสนออยู่ใกล้เคียงโทรศัพท์เคลื่อนที่ที่มีในท้องตลาด

4.4 การทดสอบเก็บผลจากการขับขี่รถยนต์ส่วนบุคคลจริงเพื่อจำแนกพฤติกรรม การขับขี่

การทดสอบเก็บผลจากการขับขี่รถยนต์ส่วนบุคคลจริงเพื่อจำแนกพฤติกรรม การขับขี่จะถูกแบ่งเป็น 2 ได้แก่ การทดสอบเก็บผลจากการขับขี่รถยนต์ส่วนบุคคลจริงแบบผสม และแบบแยก

สถานการณ์แบบปลอดภัย และแบบไม่ปลอดภัย สำหรับรถยนต์ส่วนบุคคลในการทดสอบจะใช้รถ Chevrolet Cruze 1.6 Model 2011 ดังรูปที่ 4.10




รูปที่ 4.10 Chevrolet Cruze 1.6 Model 2011


4.4.1 การทดสอบเก็บผลจากการขับรถยนต์ส่วนบุคคลจริงแบบผสม

การทดสอบเก็บข้อมูลพฤติกรรมการขับขี่รถยนต์ส่วนบุคคลแบบผสม จะขับขี่ทั้งแบบปลอดภัยและแบบไม่ปลอดภัยผสมกัน เพื่อหาพฤติกรรมการขับขี่โดยรวมทางจัดทำเป็นคะแนนผู้ขับขี่ต่อการขับขี่ 1 ครั้ง โดยรถยนต์ส่วนบุคคลมีการติดตั้งชุดอุปกรณ์ที่นำเสนอโดยเชื่อมต่อกับกล่อง ECU ของรถยนต์ส่วนบุคคลผ่าน OBD-II Port จากนั้นข้อมูลดังกล่าวจะถูกนำไปประมวลผลด้วยโมเดลปัญญาประดิษฐ์ (LSTM) ที่เหมาะสมและประมวลผลข้อมูลแบบ Real-time ได้ โดยรูปที่ 4.9 แสดงผลการนำข้อมูลจากการขับขี่รถยนต์ส่วนบุคคลป้อนเป็นข้อมูลเข้าให้กับงานวิจัยที่นำเสนอ ซึ่งประกอบด้วยข้อมูลจาก IMU ซึ่งถูกนำเข้าเป็นข้อมูลเข้า จากนั้น LSTM ที่นำเสนอจะประมวลผลข้อมูลและทำนายพฤติกรรมการขับขี่เป็นดังรูปที่ 4.10 โดยพบว่า การขับขี่รถยนต์ส่วนบุคคลดังกล่าวมีความไม่ปลอดภัยถึง 72.8% นั้นหมายถึงโอกาสการเกิดอุบัติเหตุจากผู้ขับขี่คนดังกล่าวมีโอกาสูงและมีความเสี่ยงต่อการใช้ถนนร่วมกับบุคคลอื่น


เมื่อพิจารณาข้อมูล ECU features ดังรูปที่ 4.11 พบว่า สามารถจำแนกพฤติกรรมการขับขี่ของผู้ขับขี่คนเดียวกันนั้น กว่า 79.4% แสดงถึงสถานการณ์ขับขี่แบบไม่ปลอดภัย ดังรูปที่ 4.12 โดย 0 หมายถึงสถานการณ์ขับขี่แบบไม่ปลอดภัยและ 1 หมายถึงการขับขี่แบบปลอดภัยซึ่งเป็นสถานะที่จำแนกพฤติกรรมการขับขี่ด้วยโมเดลที่นำเสนอ




รูปที่ 4.11 IMU Features



รูปที่ 4.12 IMU Driver State




รูปที่ 4.13 ECU Features



รูปที่ 4.14 ECU Driver State

ผลการวิจัยพบว่า พฤติกรรมการขับขี่รถยนต์ส่วนบุคคลสามารถส่งข้อมูลจากรถยนต์โดยกล่อง TCU ไปยังฐานข้อมูลและ Realtime database ได้เป็นอย่างดีผ่านเทคโนโลยี V2N ด้วยโครงข่ายโทรคมนาคมเคลื่อนที่ในยุคที่ 5 โดยสรุปเป็นฐานข้อมูลและ Realtime dashboard ดังรูปที่ 4.13 โดยจะเห็นได้ว่า ผู้ขับขี่คนดังกล่าว ภาพรวมกว่า 70% มีพฤติกรรมการขับขี่ที่ไม่เหมาะสม ซึ่งส่งผลกระทบต่อการใช้รถใช้ถนนร่วมกับผู้อื่นตลอดจนเกิดความรู้สึกห่อหุ้มของรถยนต์ที่เกิดจากการขับขี่ที่ไม่เหมาะสม อย่างไรก็ตามระบบที่นำเสนอเป็นเพียงระบบแจ้งเตือนตัวผู้ขับขี่เอง หากมีการพัฒนาต่อไปด้วยการส่งข้อมูลแจ้งเตือนไปยังรถยนต์คันอื่นๆ หรือ ส่งข้อมูลเข้าสู่ระบบฐานข้อมูลการประกันภัย จะส่งผลให้เกิดความเป็นธรรมในการคำนวณเบี้ยประกันภัยรถยนต์จากผู้ขับขี่โดยตรง



รูปที่ 4.15 Driver behavior Realtime dashboard

4.4.2 การทดสอบเก็บผลจากการขับรถยนต์ส่วนบุคคลจริงแบบแยก

การทดสอบเก็บข้อมูลพฤติกรรมการขับขี่รถยนต์ส่วนบุคคลแบบแยก จะขับขี่ทั้งแบบปลอดภัยและแบบไม่ปลอดภัย แต่จะแยกการขับออกเป็นช่วง เพื่อหาพฤติกรรมการขับขี่เฉพาะด้านใดด้านหนึ่ง ได้แก่ การขับแบบปลอดภัย และไม่ปลอดภัย จากนั้นจะหาพฤติกรรมการขับขี่โดยรวมจากการจัดทำเป็นคะแนนผู้ขับขี่ต่อการขับขี่ 1 ครั้ง ในการขับขี่จะถูกแบ่งออกเป็น 2 สถานการณ์ ได้แก่ การขับแบบปลอดภัย และการขับแบบไม่ปลอดภัย ผู้ขับขี่มี 2 ผู้ขับขี่ ได้แก่ นักศึกษาปริญญาตรี 1 คน และอาจารย์ที่ปรึกษา 1 คน โดยนักศึกษาปริญญาตรีจะขับแบบปลอดภัย และอาจารย์ที่ปรึกษาจะขับแบบไม่ปลอดภัย เนื่องจากงานนี้คำนึงถึงความปลอดภัยเป็นหลัก ผู้ขับขี่แสดงดังรูปที่ 4.14 และ 4.15

Safe driving




รูปที่ 4.16 การขับขี่แบบปลอดภัยโดยนักศึกษาปริญญาตรี

Unsafe driving




รูปที่ 4.17 การขับขี่แบบไม่ปลอดภัยโดยอาจารย์ที่ปรึกษา

จากการทดสอบการขับขี่แบบแยกสถานการณ์ถูกแบ่งออกเป็นการขับขี่แบบปลอดภัย และแบบไม่ปลอดภัย พบว่าค่าที่แสดงผลบนระบบ Invehicle Display มีความสอดคล้องกับสถานการณ์การขับขี่จริง จากรูปที่ 4.20 แสดงผลการทดสอบการขับขี่จริงเมื่อเริ่มขับ ณ ช่วงเวลาประมาณ 16.14 น. ถึง 16.24 น. พบว่าเมื่อเริ่มขับความเร็วรถยนต์ (VHS) เริ่มเพิ่มขึ้นพร้อมกับการทดสอบการขับขี่แบบไม่ปลอดภัย (Unsafe driving) ณ ช่วงเวลาเริ่มประมาณ 16.15 น. ถึง 16.20 น. และกราฟมีการกระเพื่อมตามจังหวะการขับ แบบไม่ปลอดภัย โดยจะกำหนดให้ขับแบบหักเลี้ยวกะทันหัน เหยียบคันเร่งกะทันหัน และเบรกกะทันหัน ที่สอดคล้องกันตามจังหวะการขับเป็นจำนวนทั้งหมด 5 ครั้ง จากพฤติกรรมขับขี่เห็นอย่างได้ชัดเจนว่ากราฟมีการขยับตามสถานการณ์ โดยกราฟที่มีส่วนเกี่ยวข้องมากที่สุดได้แก่ AccX (ความเร่งในแนวแกน X) AccY (ความเร่งในแนวแกน Y) GyroZ (ความเร็วเชิงมุมรอบแกน Z) TTP (ตำแหน่งคันเร่ง) EGS (รอบเครื่องยนต์) และ VHS (ความเร็วรถยนต์) ซึ่งแต่ละกราฟมีความสัมพันธ์กันอย่างเห็นได้ชัด และมีบางจุดที่สไปค์ (spike) หรือพุ่งลง และขึ้นตามการขับแบบกะทันหัน ต่อมาเป็นสถานการณ์ที่รถไม่ได้ขับตัวจะเป็นสถานการณ์ที่รถหยุดนิ่ง (Idle) และสุดท้ายเป็นการขับขี่แบบปลอดภัย พบว่ากราฟมีการขยับไม่มาก หรือกระเพื่อมน้อย และไม่มีสไปค์ที่สอดคล้องกับการทดสอบการขับขี่แบบปลอดภัยตามสถานการณ์จริง ณ ช่วงเวลาประมาณ 16.21 น. ถึง 16.24 น. กราฟผลการทดสอบแสดงดังรูปที่ 4.18 4.19 และ 4.20




รูปที่ 4.18 ผลการทดสอบการขี่แบบแยกสถานการณ์

จากรูปที่ 4.18 พบว่าความเร่งในแกน x (กราฟ AccX) y (กราฟ AccY) และ z (กราฟ AccZ) มีความสัมพันธ์กัน ในแต่ละช่วงเวลาจากที่กล่าวก่อนหน้านี้ ก่อนสถานะรถหยุดนิ่ง (Idle state) เป็นการขี่แบบไม่ปลอดภัย หรือการขี่แบบเลี้ยวกะทันหัน กราฟมีการแกว่งมากกว่าหลังสถานะรถหยุดนิ่งหรือการขี่แบบไม่ปลอดภัย ที่สอดคล้องกับสถานการณ์ขี่จริง เช่นเดียวกับรูปที่ 4.19 กราฟ GyroZ



รูปที่ 4.19 ผลการทดสอบการขับเคลื่อนแบบแยกสถานการณ์

จากรูปที่ 4.19 พบว่า กราฟ GyroX และ GyroY ไม่ได้แกว่งมาก ช่วงก่อนและสถานะรถหยุดนิ่งการแกว่งของกราฟมีลักษณะคล้ายกัน ดังนั้นกราฟทั้ง 2 ไม่ได้มีผลมากกับพฤติกรรมขับเคลื่อนการขับเคลื่อนที่ถูกจำแนกเป็นการขับเคลื่อนแบบไม่ปลอดภัย และการขับเคลื่อนแบบปลอดภัย เมื่อเทียบกับกราฟ GyroZ ที่มีการแกว่งที่สัมพันธ์กันกับกราฟจากรูปที่ 4.18 และรูปที่ 4.20



รูปที่ 4.20 ผลการทดสอบการขับขี่แบบแยกสถานการณ์

จากรูปที่ 4.20 พบว่า กราฟตำแหน่งคันเร่ง (TTP) ความเร็วรอบเครื่องยนต์ (EGS) และความเร็วรถยนต์ (VHS) พบว่ามีความสัมพันธ์กับทั้ง 3 กราฟ และสัมพันธ์กับสถานการณ์การขับขี่จริง เช่นเดียวกับกราฟจากรูปที่ 4.18 และกราฟ GyroZ จากรูปที่ 4.19 แต่กราฟความเร็วรอบเครื่องยนต์ (EGS) จะมีขนาดเล็กเนื่องจากขนาดของบางค่าในช่วงก่อนการทดสอบการขับขี่จริงมีค่าที่สูงเกินแต่ใน

รูปจะไม่พบ เพราะได้ถูกตัดออกไป โดยกราฟจากรูปที่ 4.18 และ 4.19 เป็นค่าที่ได้จาก IMU sensors กราฟจากรูปที่ 4.20 เป็นค่าที่ได้จากกล่อง ECU ที่พบว่าค่าจากอุปกรณ์ทั้ง 2 มีความสอดคล้องกัน และมีผลกับพฤติกรรมรถที่ขับขี่ ยกเว้นกราฟ GyroX และ GyroY จากรูปที่ 4.19 แต่ 2 กราฟนี้สามารถนำไปใช้ประยุกต์ในงาน Automotive SOS ได้ในอนาคต

4.4.3 การทดสอบเก็บผลจากการขับรถยนต์ส่วนบุคคลจริงแบบแยกสถานการณ์

จากผลการขับขี่แบบแยกสถานการณ์ สามารถสรุปผลการขับขี่โดยรวมได้ดังตารางที่ 4.3 และดังรูปที่ 4.17

ตารางที่ 4.3 สรุปผลการขับขี่โดยรวมการขับขี่แยกสถานการณ์ของการขับขี่แบบปลอดภัย

	Safe count	Unsafe count	Safe rate (%)	Unsafe rate (%)
IMU Sensors	45	0	100	0
TTP/EGS ratio	43	2	95.56	4.44
VHS/EGS ratio	10	35	22.22	77.78

จากตารางที่ 4.3 พบว่าโมเดลที่นำเสนอ (LSTM model) หรือตามแถว IMU Sensors มีการทำนาย safe rate เท่ากับ 100% และ unsafe rate เท่ากับ 0% โมเดลทางคณิตศาสตร์ตัวที่ 1 หรือตามแถว TTP/EGS ratio (The relative ratio of the Throttle position and Engine speed) มีการทำนาย safe rate เท่ากับ 95.56% และ unsafe rate เท่ากับ 4.44% และโมเดลทางคณิตศาสตร์ตัวที่ 2 หรือตามแถว VHS/EGS ratio (The relative ratio of the Vehicle speed and Engine speed) มีการทำนาย safe rate เท่ากับ 22.22% และ unsafe rate เท่ากับ 77.78% ดังนั้นสรุปได้ว่าโมเดลที่นำเสนอมีความสัมพันธ์กับโมเดลทางคณิตศาสตร์ตัวที่ 1 หรือ TTP/EGS ratio แต่โมเดลทางคณิตศาสตร์ตัวที่ 2 ยังจำแนกพฤติกรรมผู้ขับขี่ไม่สอดคล้องกับโมเดลอื่น และตามสถานการณ์จริง เนื่องจากการขับแบบปลอดภัยนั้นเป็นการทดสอบในระยะทางที่ไม่ได้ยาวมาก แต่เป็นการทดสอบการขับขี่แบบเลี้ยวเป็นส่วนใหญ่จึงใช้ความเร็วไม่มากนักแต่รอบจะสูงอาจทำให้ผลการคำนวณและการตัดสินใจอยู่ในขอบเขตของการขับขี่แบบไม่ปลอดภัยเป็นส่วนใหญ่ หรือช่วงที่ต่ำกว่า 0.9 ดังที่กล่าวในบทที่ 3 รูปที่ 3.13 และแสดงผลการขับขี่โดยรวมจากการขับขี่แบบแยกสถานการณ์ของการขับขี่แบบปลอดภัยดังรูปที่ 4.21



รูปที่ 4.21 แสดงผลการแจ้งเตือนจากสถานการณ์การขับขี่แบบปลอดภัย

ตารางที่ 4.4 สรุปผลการขับขี่โดยรวมการขับขี่แบบแยกสถานการณ์การขับขี่ไม่แบบปลอดภัย

	Safe count	Unsafe count	Safe rate (%)	Unsafe rate (%)
IMU Sensors	74	77	49.01	50.99
TTP/EGS ratio	98	53	64.90	35.10
VHS/EGS ratio	36	115	23.84	76.16

จากตารางที่ 4.4 พบว่าโมเดลที่นำเสนอ (LSTM model) หรือตามแถว IMU Sensors มีการทำนาย safe rate เท่ากับ 49.01% และ unsafe rate เท่ากับ 50.99% โมเดลทางคณิตศาสตร์ตัวที่ 1 หรือตามแถว TTP/EGS ratio (The relative ratio of the Throttle position and Engine speed) มีการทำนาย safe rate เท่ากับ 64.90% และ unsafe rate เท่ากับ 35.10% และโมเดลทางคณิตศาสตร์ตัวที่ 2 หรือตามแถว VHS/EGS ratio (The relative ratio of the Vehicle speed and Engine speed) มีการทำนาย safe rate เท่ากับ 23.84% และ unsafe rate เท่ากับ 76.16% ดังนั้นสรุปได้ว่าโมเดลที่นำเสนอมีความสัมพันธ์กันกับโมเดลทางคณิตศาสตร์ตัวที่ 2 หรือ TTP/EGS ratio แต่โมเดลทางคณิตศาสตร์ตัวที่ 1 ยังจำแนกพฤติกรรมผู้ขับขี่ไม่สอดคล้องกับโมเดลอื่น และตามสถานการณ์จริง เนื่องจากการขับขี่แบบไม่ปลอดภัยใช้สถานที่เป็นกับการขับขี่แบบปลอดภัย และใช้ระยะทางสั้น ทำให้มีโอกาสบางจังหวะเหยียบคันเร่งเยอะและน้อย และทำให้รอบเครื่องยนต์สูงและต่ำสลับกันไป อาจทำให้ค่าทั้ง 2 มีความสัมพันธ์กันโดยไม่มีค่าใดค่าหนึ่งห่างกันมาก ดังนั้นอาจทำให้ผลการคำนวณและการตัดสินใจอยู่ในขอบเขตของการขับขี่แบบปลอดภัยเป็นส่วนใหญ่ หรือช่วงระหว่าง 0.9 ถึง 1.3 ดังที่กล่าวในบทที่ 3 รูปที่ 3.13 และแสดงผลการขับขี่โดยรวมจากการขับขี่แบบแยกสถานการณ์ของการขับขี่แบบไม่ปลอดภัยดังรูปที่ 4.22



รูปที่ 4.22 แสดงผลการแจ้งเตือนจากสถานการณ์การขับขี่แบบปลอดภัย

สรุปผลการทดสอบจากการขับขี่จริงตามสถานการณ์ต่าง ๆ จากระบบ และกล่อง TCU ที่ถูกสร้างขึ้น พบว่าโมเดลภายในระบบสามารถจำแนกพฤติกรรมการขับขี่แบบปลอดภัย และแบบไม่ปลอดภัยได้จริง และมารถเก็บผลการทดสอบส่งไปยังฐานข้อมูลพฤติกรรมการขับขี่รถยนต์ส่วนบุคคลได้จริงตามระบบที่ได้ออกแบบมาและการนำไปใช้ดังรูปที่ 4.23



รูปที่ 4.23 การนำระบบและกล่อง TCU ไปใช้งานจริง

4.5 การทดสอบเวลาการประมวลผลของระบบ

การทดสอบเวลาการประมวลผลของระบบถูกแบ่งออกเป็น 2 ส่วน ได้แก่ เวลาโดยรวมการประมวลผลที่กล่อง TCU และเวลาโดยรวมการนำส่งข้อมูลผ่านเครือข่าย โดยมีผลดังนี้

4.5.1 เวลาโดยรวมการประมวลผลที่กล่อง TCU

เวลาโดยรวมจากการประมวลผลที่กล่อง TCU ถูกวัดจากเวลาเริ่มต้นการประมวลผลจนกระทั่งจบการประมวลผลของซอฟต์แวร์ จากนั้นนำเวลามาหาส่วนต่างกันทั้งหมด 30 ค่า พบว่าเวลาเฉลี่ยจากการประมวลผลที่กล่อง TCU (Execute time) เท่ากับ 1.6559 วินาที แสดงดังตารางที่ 4.5

ตารางที่ 4.5 ผลลัพธ์จากการประมวลผลที่กล่อง TCU

No.	Executed time (second)
1	1.6599
2	1.6717
3	1.6580
4	1.6539
5	1.6622
6	1.6636
7	1.6589
8	1.6721
9	1.6579
10	1.6723
11	1.6626
12	1.6677
13	1.6672
14	1.6638
15	1.6686
16	1.6676
17	1.6904
18	1.6780
19	1.6640

ตารางที่ 4.5 ผลลัพธ์จากการประมวลผลที่กล่อง TCU (ต่อ)

No.	Executed time (second)
20	1.6776
21	1.6673
22	1.6745
23	1.6735
24	1.6624
25	1.6751
26	1.6638
27	1.6683
28	1.6781
29	1.6751
30	1.6864
เวลาเฉลี่ย	1.6599

4.5.2 เวลาโดยรวมจากการนำส่งข้อมูลผ่านเครือข่าย V2N

เวลาโดยรวมจากการนำส่งข้อมูลผ่านเครือข่าย V2N ถูกวัดจากข้อมูลวันและเวลาของกล่อง TCU และ timestamp ของ dashboard เมื่อข้อมูลมาถึง จากนั้นนำวันและเวลาทั้งสองมาแปลงเป็น Unix timestamp แล้วนำมาหาส่วนต่างทั้งหมด 30 ค่า พบว่าเวลาเฉลี่ยจากการนำส่งข้อมูลผ่านเครือข่าย V2N เท่ากับ 0.2 วินาที แสดงดังตารางที่ 4.6

ตารางที่ 4.6 เวลาโดยรวมจากการนำส่งข้อมูลผ่านเครือข่าย V2N ไปยัง dashboard

Datetime of dashboard	Datetime of TCU box	Unix timestamp of dashboard (second)	Unix timestamp of TCU box (second)	Total delay (second)
10/8/2024 17:57:38	10/8/2024 17:57:38	1723312658	1723312658	0
10/8/2024 17:57:41	10/8/2024 17:57:41	1723312661	1723312661	0

ตารางที่ 4.6 เวลาโดยรวมจากการนำส่งข้อมูลผ่านเครือข่าย V2N ไปยัง dashboard (ต่อ)

Datetime of dashboard	Datetime of TCU box	Unix timestamp of dashboard (second)	Unix timestamp of TCU box (second)	Total delay (second)
10/8/2024 17:57:43	10/8/2024 17:57:43	1723312663	1723312663	0
10/8/2024 17:57:45	10/8/2024 17:57:45	1723312665	1723312665	0
10/8/2024 17:57:47	10/8/2024 17:57:47	1723312667	1723312667	0
10/8/2024 17:57:50	10/8/2024 17:57:49	1723312670	1723312669	1
10/8/2024 17:57:52	10/8/2024 17:57:52	1723312672	1723312672	0
10/8/2024 17:57:54	10/8/2024 17:57:54	1723312674	1723312674	0
10/8/2024 17:57:57	10/8/2024 17:57:57	1723312677	1723312677	0
10/8/2024 17:58:00	10/8/2024 17:57:59	1723312680	1723312679	1
10/8/2024 17:58:02	10/8/2024 17:58:02	1723312682	1723312682	0
10/8/2024 17:58:04	10/8/2024 17:58:04	1723312684	1723312684	0
10/8/2024 17:58:06	10/8/2024 17:58:06	1723312686	1723312686	0
10/8/2024 17:58:09	10/8/2024 17:58:08	1723312689	1723312688	1

ตารางที่ 4.6 เวลาโดยรวมจากการนำส่งข้อมูลผ่านเครือข่าย V2N ไปยัง dashboard (ต่อ)

Datetime of dashboard	Datetime of TCU box	Unix timestamp of dashboard (second)	Unix timestamp of TCU box (second)	Total delay (second)
10/8/2024 17:58:11	10/8/2024 17:58:11	1723312691	1723312691	0
10/8/2024 17:58:13	10/8/2024 17:58:13	1723312693	1723312693	0
10/8/2024 17:58:16	10/8/2024 17:58:15	1723312696	1723312695	1
10/8/2024 17:58:18	10/8/2024 17:58:18	1723312698	1723312698	0
10/8/2024 17:58:20	10/8/2024 17:58:20	1723312700	1723312700	0
10/8/2024 17:58:22	10/8/2024 17:58:22	1723312702	1723312702	0
10/8/2024 17:58:25	10/8/2024 17:58:24	1723312705	1723312704	1
10/8/2024 17:58:27	10/8/2024 17:58:27	1723312707	1723312707	0
10/8/2024 17:58:29	10/8/2024 17:58:29	1723312709	1723312709	0
10/8/2024 17:58:31	10/8/2024 17:58:31	1723312711	1723312711	0
10/8/2024 17:58:34	10/8/2024 17:58:33	1723312714	1723312713	1
10/8/2024 17:58:36	10/8/2024 17:58:36	1723312716	1723312716	0

ตารางที่ 4.6 เวลาโดยรวมจากการนำส่งข้อมูลผ่านเครือข่าย V2N ไปยัง dashboard (ต่อ)

Datetime of dashboard	Datetime of TCU box	Unix timestamp of dashboard (second)	Unix timestamp of TCU box (second)	Total delay (second)
10/8/2024 17:58:38	10/8/2024 17:58:38	1723312718	1723312718	0
10/8/2024 17:58:40	10/8/2024 17:58:40	1723312720	1723312720	0
10/8/2024 17:58:42	10/8/2024 17:58:42	1723312722	1723312722	0
10/8/2024 17:58:45	10/8/2024 17:58:45	1723312725	1723312725	0
เวลาเฉลี่ย		1723312692	1723312692	0.2

จากผลลัพธ์เวลาเฉลี่ยของทั้ง 2 การประมวลผล เมื่อนำมารวมกับจะเท่ากับ 1.8599 วินาที เมื่อนำมาเทียบเวลาการตอบสนองของผู้ขับขี่ จาก [14] เวลาตอบสนองของผู้ขับขี่อยู่ที่ 1 วินาที หรือต่ำกว่านั้น สำหรับผู้ขับขี่ที่ชำนาญ และสถานการณ์วิกฤติ เวลาตอบสนองของผู้ขับขี่โดยเฉลี่ยทั่วไปอยู่ที่ 1.5 วินาที และเวลาตอบสนองของผู้ขับขี่โดยเฉลี่ยสำหรับผู้ส่วงวัย และผู้ที่ยังไม่ชำนาญอยู่ที่ 2.5 วินาที ดังนั้นนำมาเมื่อเทียบกัน พบว่าเวลาของระบบที่นำเสนอยังไม่สามารถเร็วพอที่จะแจ้งผู้ขับขี่ที่ชำนาญและผู้ขับขี่โดยทั่วไปได้ แต่สามารถช่วยแจ้งเตือนผู้ขับขี่ที่ไม่ชำนาญหรือผู้ส่วงวัยได้ ดังนั้นในอนาคตมีโอกาสนพัฒนาระบบ เพื่อให้สามารถแจ้งเตือนผู้ขับขี่ให้ทันที่ได้ภายใน 1 วินาที ด้วยการลดความซับซ้อนของโมเดล แจ้งเตือนให้กับผู้ขับโดยไม่ผ่านเครือข่าย และเพิ่มประสิทธิภาพของซอฟต์แวร์มากขึ้น

บทที่ 5

สรุปผลการวิจัย อภิปรายผล และข้อเสนอแนะ

5.1 สรุปผลการวิจัย

จากการดำเนินการวิจัยสามารถสรุปได้ว่า พฤติกรรมการขับขี่รถยนต์ส่วนบุคคลเป็นสิ่งสำคัญ และเป็นปัจจัยที่เป็นส่วนหนึ่งของการเกิดอุบัติเหตุ ดังนั้น การติดตั้งกล่อง TCU ร่วมกับกล่อง ECU นับเป็นเครื่องมืออย่างหนึ่งในการนำข้อมูลพฤติกรรมการขับขี่ไปประมวลผลผ่านเทคโนโลยี V2N ซึ่งทำให้สามารถจำแนกพฤติกรรมการขับขี่ให้แม่นยำได้ผ่านโมเดลปัญญาประดิษฐ์แบบ LSTM ซึ่งผลการวิจัยส่งผลให้ผู้ขับขี่มีการเตือนตนเองผ่านทาง Realtime dashboard ส่งผลให้สามารถลดโอกาสการเกิดอุบัติเหตุได้

5.2 ข้อเสนอแนะ

1. ควรมีการติดตั้งระบบที่นำเสนอภัยอันตรายให้มากขึ้น และนำข้อมูลมาสรุปเป็นชุดข้อมูลมาตรฐาน ในการนำไปจำแนกพฤติกรรมการขับขี่
2. โครงข่ายโทรคมนาคมแบบเคลื่อนที่ ยุคที่ 5 เหมาะสมกับการนำมาใช้ทำ V2N อย่างไรก็ดี ยังจำเป็นต้องได้รับการสนับสนุนแพ็คเกจที่ราคาเป็นธรรมต่อผู้บริโภคอย่างยุติธรรม
3. การทดสอบส่วนใหญ่เป็นการทดสอบแบบเหยียบคันเร่ง เบรก และหักเลี้ยวกะทันหัน เป็นส่วนใหญ่ ทำให้เหมาะแก่การตรวจจับดังกล่าว แต่อาจไม่ได้ครอบคลุมถึงสถานการณ์อื่น ๆ ที่ปลอดภัย และไม่ปลอดภัย ดังนั้นควรเพิ่มสถานการณ์การทดสอบให้มากขึ้นในอนาคต เช่น การเร่งแซง เป็นต้น

เอกสารอ้างอิง

- [1] K. Kanwal, F. Rustam, R. Chaganti, A. D. Jurcut and I. Ashraf, "Smartphone Inertial Measurement Unit Data Features for Analyzing Driver Driving Behavior," in IEEE Sensors Journal, vol. 23, no. 11, pp. 11308-11323, 1 June1, 2023, doi: 10.1109/JSEN.2023.3256000.
- [2] R. Ghandour, A. J. Potams, I. Boulkaibet, B. Neji, Z. A. Barakeh and A. S. Karar, "Machine learning methods for driver behaviour classification," 2021 4th International Conference on Bio-Engineering for Smart Technologies (BioSMART), Paris / Créteil, France, 2021, pp. 1-4, doi: 10.1109/BioSMART54244.2021.9677801.
- [3] M. A. Khan, T. Nawaz, U. S. Khan, A. Hamza and N. Rashid, "IoT-Based Non-Intrusive Automated Driver Drowsiness Monitoring Framework for Logistics and Public Transport Applications to Enhance Road Safety," in IEEE Access, vol. 11, pp. 14385-14397, 2023, doi: 10.1109/ACCESS.2023.3244008.
- [4] M. H. Baccour, F. Driewer, T. Schäck and E. Kasneci, "Comparative Analysis of Vehicle-Based and Driver-Based Features for Driver Drowsiness Monitoring by Support Vector Machines," in IEEE Transactions on Intelligent Transportation Systems, vol. 23, no. 12, pp. 23164-23178, Dec. 2022, doi: 10.1109/TITS.2022.3207965.
- [5] A. E. Abdelrahman, H. S. Hassanein and N. Abu-Ati, "Robust Data-Driven Framework for Driver NETWORKS(COMSNETS), Bangalore, India, 2022, pp. 700-706, doi: 10.1109/COMSNETS53615.2022.9668532.
- [6] A. Jaafer, G. Nilsson and G. Como, "Data Augmentation of IMU Signals and Evaluation via a Semi-Supervised Classification of Driving Behavior," 2020 IEEE 23rd International Conference on Intelligent Transportation Systems (ITSC), Rhodes, Greece, 2020, pp. 1-6, doi: 10.1109/ITSC45102.2020.9294496.
- [7] E. Türk and M. Challenger, "An android-based IoT system for vehicle monitoring and diagnostic," 2018 26th Signal Processing and Communications Applications Conference (SIU), Izmir, Turkey, 2018, pp. 1-4, doi: 10.1109/SIU.2018.8404378.

- [8] S. Ionut-Cristian, "A Brief Review of Using the Inertial Sensor to Determine the Driver Head Posture," 2021 International Conference on e-Health and Bioengineering (EHB), Iasi, Romania, 2021, pp. 1-4, doi: 10.1109/EHB52898.2021.9657575.
- [9] F. J. Bruwer and M. J. Booysen, "Comparison of GPS and MEMS Support for Smartphone-Based Driver Behavior Monitoring," 2015 IEEE Symposium Series on Computational Intelligence, Cape Town, South Africa, 2015, pp. 434-441, doi: 10.1109/SSCI.2015.71.
- [10] Nazirkar. (2021). Phone sensor data while driving a car [Online]. Available: <https://www.kaggle.com/datasets>
- [11] Behavior Profiling Using Supervised Machine Learning," in IEEE Transactions on Intelligent Transportation Systems, vol. 23, no. 4, pp. 3336-3350, April 2022, doi: 10.1109/TITS.2020.3035700.
- [12] J. Carmona, M. A. de Miguel, D. Martin, F. Garcia and A. de la Escalera, "Embedded system for driver behavior analysis based on GMM," 2016 IEEE Intelligent Vehicles Symposium (IV), Gothenburg, Sweden, 2016, pp. 61-65, doi: 10.1109/IVS.2016.7535365.
- [13] A. Agnoor, P. Atmakuri and R. Sivanandan, "Analysis of Driving Behaviour through Instrumented Vehicles," 2022 14th International Conference on communication Systems
- [14] Summala, Heikki. (2000). Brake Reaction Times and Driver Behavior Analysis. Transportation Human Factors. 2. 217-226. 10.1207/STHF0203_2.



ภาคผนวก

บทความวิจัยระดับนานาชาติที่ได้รับการตีพิมพ์

บทความวิจัยระดับนานาชาติที่ได้รับการตีพิมพ์

1. S. Thongsri, P. Phoynok, C. Luecha, T. Khayan, P. Kijphitayarit and S. Poochaya, **"Development of 5G Standalone QOS Tester Device for CAV Communication,"** 2024 12th International Electrical Engineering Congress (IEECON), Pattaya, Thailand, 2024, pp. 1-5, doi: 10.1109/IEECON60677.2024.10537859

2. S. Thongsri, K. Bunchen and S. Poochaya, **"Enhancing Thailand Road Safety through Personal Driving Style Classification using Machine Learning Model"**

The 2024 International Conference on Power, Energy and Innovations (ICPEI 2024) to be held in Korat, Thailand from 16-18 October 2024.



มหาวิทยาลัยเทคโนโลยีสุรนารี

1. S. Thongsri, P. Phoynok, C. Luecha, T. Khayan, P. Kijphitayarit and S. Poochaya, "Development of 5G Standalone QOS Tester Device for CAV Communication," 2024 12th International Electrical Engineering Congress (IEEECON), Pattaya, Thailand, 2024, pp. 1-5, doi: 10.1109/IEEECON60677.2024.10537859



The poster for IEEECON 2024 features a background image of a coastal city with a large blue speech bubble containing the dates '6-8 March 2024'. At the top, it lists co-hosted organizations (including the Ministry of Higher Education and Scientific Research, UTM, EEFRT, ICTA, and RDI) and technical sponsors (IEEE Thailand Section and IEEE PES Thailand Chapter). The main title 'iEECON 2024' is in large blue letters, followed by the location 'Pattaya, Chonburi, Thailand' and the theme 'Smart Factory and Intelligent Technology for Tomorrow'. Two circular insets show a smart factory and a smart city. The bottom section lists conference topics in four categories: Communications, Power & Energy, Electronics & Control, and Digital Signal Processing. A 'Computer & IT' section is also present, featuring a screenshot of a code editor.

Co-hosted by :

Technical Sponsors :

12th International Electrical Engineering Congress

iEECON 2024

Pattaya, Chonburi, Thailand

Smart Factory

and Intelligent Technology for Tomorrow

6-8 March 2024

Conference Topics

COMMUNICATIONS

Communication Theory, Antennas and Propagation Optical Communications, Microwaves, Wireless Communications, Signal Processing for Communication, Channel Coding, Multimedia Communication, Remote Sensing and Applications, Metamaterials, etc.

POWER & ENERGY

Smart Grid Technology, Planning, Management Operation, and Control; Electric Power Systems : Generation Transmission and Distribution, Electrical Machines, Energy Conversions, Renewable Energy Sources, Power Electronics, Energy Systems, Power Quality, High Voltage Engineering, Insulation and Materials, Piezoelectric ceramic and thin films, Energy storage materials and technology, energy harvesting and energy storage designs, Advanced characterization and properties of ferroelectric materials etc.

ELECTRONICS & CONTROL

Analog Circuits, Filters and Data Conversion, Analog and Mixed Signal Processing, Embedded Computer System, Robotics, VLSI Design, Biomedical Electronics, Industrial Electronics and automation, Adaptive Control, Electric Circuit Technology, Fault Tolerance and Detection, Semiconductor Materials, Magnetic Materials, Thermoelectric materials and devices, Sensor, Organic Electronics and Printed Electronic etc.

DIGITAL SIGNAL PROCESSING

Image and Video Processing, Audio and Speech Processing, Pattern Recognition, Biomedical Signal Processing, Computer Vision and Pattern Recognition, Adaptive Signal Processing, Machine Learning for Signal Processing, etc.

COMPUTER & IT

Computer Networks, Cloud Computing, Artificial Intelligence, Computer Security, Web Services, Human Computer Interaction

INDUSTRIAL TECHNOLOGY

Applied Sciences, Technology, Engineering, and Management Sciences

Development of 5G Standalone QOS Tester Device for CAV Communication

Sithisak Thongsri, Palakorn Phoynok, Chanapa Luecha, Tatiya Khayan, Pannatorn Kijphitayarit and Settawit Poochaya

School of Telecommunication Engineering,
Suranaree University of Technology Muang, NakhonRatchasima, Thailand 30000
Email: settawit@sut.ac.th

Abstract—Focus on Connected-Autonomous-Shared-Electric Vehicle (CASE), Connected and Autonomous Vehicle Technologies are a famous topic in the world. CAV requires high performance of communication links. 5G communication is a high-performance communication system in Thailand. The service area of 5G mobile communication in standalone mode increases every year. Quality of Service (QoS) in 5G for CAV is important. Commercial 5G QOS tester device is expensive. Then, the developing of 5G QOS Tester and QOS parameters in terms of radio and end parameters: SS-RSRP, SS-SINR, SS-RSRQ, RTT, Upload, Download, Jitter of 5G standalone for CAV are presented in this work. Our results confirm that 5G standalone is a high-performance communication link for CAV data transmission.

Keywords—V2N, 5G, NR, SA, and ITS

I. INTRODUCTION

Nowadays, information and communication technology are developing rapidly. As a result, automotive technology has made traveling more comfortable, safe, and environmentally friendly, resulting in autonomous and connected vehicle technology (CAV) including vehicles that connect to various things. Vehicles with the ability to drive autonomously, car sharing, and the use of electric vehicles (CASE), which is a smart vehicle technology. Modern technologies that help in driving include the Advance Driver Assistance System (ADAS). Autonomous driving technology and vehicle-to-everything (V2X) technology. Our work focuses on testing and developing devices that help vehicles connect to the network through vehicle communications networks or vehicle-to-networks communication (V2N) to measure signal quality and appropriate area before deploying modern smart vehicle technology. In the intricate receiving telemetry and transmitting telecommands and collecting enormous amounts of data transmission. The functionality of Connected and Autonomous Vehicles (CAV), and the integrity of the system infrastructure stand as a linchpin for ensuring seamless operations. At the heart of this infrastructure lies the critical need for a high-performance communication link, a fundamental requirement for the transmission of data from the vehicle up to the cloud with 5G NR V2X technology that provides mobility management for V2N communication [1].

Connected and autonomous vehicles operate within an ecosystem where real-time data exchange is not merely a convenience but a necessity. To enable functionalities such

as remote monitoring, over-the-air updates, and data-driven decision-making, CAVs rely on a robust communication link that facilitates the bidirectional flow of information between the vehicle and the cloud. This paper shows that 5G can support advanced V2X services by using V2N communication to send data to the cloud [2]. To achieve the desired level of performance in the communication link, various QOS parameters come into play. Synchronization Signal Reference Signal Received Power (SS-RSRP), Secondary Synchronization Signal Signal-to-Noise and Interference Ratio (SS-SINR), Synchronization Signal Reference Signal Received Quality (SS-RSRQ), and End parameters such as Average Upload (UL) and Average Download (DL) throughput, Round-Trip Time (RTT), and Jitter collectively define the quality of the communication link [3]. Finally, results present a 5G QOS tester device measuring V2X communication link performance in terms of radio and end parameters that supported the CAV communication link.



Fig. 1. Proposed 5G QOS Tester for CAV

II. SYSTEM INFRASTRUCTURE AND 5G NR PERFORMANCE METRICS

5G NR Performance parameters

Figure 1 shows the proposed system infrastructure. The Device Under Test (DUT) was produced with RP4 and RM502Q-AE radio HAT (hardware attached on top). DUT was installed inside the experimental vehicle. 5G NR performance parameters are separated into two types: Radio parameters and End parameters.

Radio Parameters

SS-RSRP is the reference signal power value of the synchronization signal received in a wireless network

or telecommunications system. The SS-RSRP value can be used to estimate the signal strength level in measuring and evaluating signal quality and connection in the mobile phone network system for connections and communications to work correctly and with maximum efficiency, the unit is dBm.

SS-SINR is the value used to measure signal quality in mobile or wireless telephone network systems is employed to identify the quality of signals and interference in the system. It indicates the ratio between the signal strength from the serving cell and the level of interference and noise in the network. This is done to evaluate the efficiency of connections and communication between mobile phones and service cells in the cellular network system or other wireless systems, ensuring optimal efficiency in connectivity and communication. The unit of measurement is in decibels (dB).

SS-RSRQ is the indicator of overall signal quality. Which is used to consider Handover to consider and change signal antennas. When the SS-RSRQ value is high, it indicates good channel quality. The unit is dB or Decibel, calculated as in Eq. (1), where N is the Physical Resource Blocks value.

$$SS-RSRQ = \frac{N \times SS-RSRP}{SS-SINR} \quad (1)$$

End Parameters

Average Upload, or the average data transmission speed, is the rate at which data is uploaded on average over a specified period. It can be measured in bits per second (bps), bytes per second (Bps), kilobits per second (Kbps), or megabits per second (Mbps). The average upload speed is calculated by the internet system or device in use, and this value is provided to users. The average upload speed refers to the rate at which data is sent from the user's device to the server or the internet network. It is a crucial metric for assessing the performance of data upload.

Average Download, or the average data transfer speed, is the rate at which data is downloaded on average over a specified period. The download speed reflects the efficiency of receiving data from the network and is crucial for measuring and monitoring the speed of internet connections, especially in applications that require fast data transmission. The average download speed can be measured in units such as bits per second (bps), bytes per second (Bps), kilobits per second (Kbps), or megabits per second (Mbps).

RTT, or Round-Trip Time, is the duration measured from a ping operation, expressed in milliseconds (ms). Ping is a connectivity and responsiveness test for both the network and the destination host. It is a command on a computer that operates by sending an "echo request" of the Internet Control Message Protocol (ICMP) type to the target host and waiting for the corresponding "echo response" data. The measured duration is referred to as "RTT," and this RTT value indicates the status of the connection and the responsiveness of the target host. Assessing RTT

values is a way to evaluate the network's and target host's connectivity and responsiveness.

Jitter is the variability in the time it takes for data to be transmitted from the source to the destination. This can affect the stability of real-time communication. Low jitter values contribute to smooth communication, while high jitter values indicate significant fluctuations in Round Trip Time (RTT), impacting the quality of real-time interactions and responsiveness.

Path Loss

Path Loss is the reduction in signal strength that occurs because of natural phenomena, occurring as the distance between the transmitting and receiving ends increases. It is categorized into three environmental types: urban, suburban, and rural. Simulation of all three environmental conditions is achieved by considering the distance between the transmitting and receiving devices, with the distance acting as a determinant of the environmental conditions [4].

There are three fundamental types of large-scale path loss models designed to forecast signal strength over distance for expansive areas. In the past, omnidirectional path loss models, also known as ABG models, were developed [5]. The alpha-beta-gamma (ABG) model is a significant multifrequency path loss model. Typically, multifrequency path loss models are necessary to standardize the path loss models, ensuring coverage across a wide spectrum of frequencies [6], as shown in Eq. (2).

$$PL^{ABG}(f, d) [dB] = 10 \log_{10} \left(\frac{d}{d_0} \right) + \beta + 10\gamma \log_{10} \left(\frac{f}{f_0} \right) + X_{\sigma}^{ABG} \quad (2)$$

In the given expression, α and β represent the path loss coefficients defining distance and frequency dependency, respectively. γ indicates the optimized offset for path loss, f denotes the operational frequency (in GHz), f_0 represents a fixed reference frequency, and X_{σ}^{ABG} symbolizes the large-scale signal variabilities received concerning the distance in the direct path.

The Close-In (CI) free-space path loss model is a widely recognized path loss model [7]. Generally, this path loss model is utilized to illustrate the effects of the channel induced due to the surrounding environment. The Close-In (CI) free-space path loss model is shown in Eq. (3).

$$PL^{CI}(f, d) [dB] = FSPL(f, d) + 10n \log_{10} \left(\frac{d}{d_0} \right) + X_{\sigma}^{CI} \quad (3)$$

In the provided context, n represents the Path Loss Exponent (PLE), X_{σ}^{CI} signifies a Gaussian random variable, σ symbolizes the standard deviation in decibels (dB), and d_0 indicates the physical reference distance ($d_0 = 1m$), $FSPL(f, d)$ is the free space path loss ($FSPL(f, d)$ in dB), which is dependent on carrier frequency (f in GHz), and the distance between transmitter and receiver antennas are represented in d (in meter). The $FSPL(f, d)$ can be calculated in Eq. (4).

$$FSPL(f, d) = 10 \log_{10} \left(\frac{4\pi d_0}{\lambda} \right)^2 \quad (4)$$

Where λ is wavelength of 5G NR n41 band.

III. PROPOSED SYSTEM

Hardware and software development are explained in this section.

Hardware development

For hardware development, a Device Under Test (DUT) consisting of Raspberry Pi4 Model B has a Broadcom BCM2711, Quad-core Cortex-A72 (ARM v8) 64-bit SoC @ 1.8GHz with memory 4GB, RM502Q-AE 5G HAT (hardware attached on top) module is a device with various features. It supports connections with 4G and 5G networks and a 7-inch LCD Display for Raspberry Pi. A connection between a Raspberry Pi4 Model B and RM502Q-AE 5G HAT module is connected via a serial interface, and the connection between a Device Under Test (DUT) and a 7-inch LCD Display is connected via a USB port that is shown in Figure 1.

Software development

The software development of Device Under Test (DUT) is developed separately, but they will work together, with the software development being separated into 2 parts: software of radio parameters and software of end parameters, they are developed with Python, then the InfluxDB which is a database is retrieval parameters that is collected in comma separated values (CSV) file into Grafana dashboard. The software operation of both is shown in pseudocode algorithm as shown in Figures 2 and 3.

```

Algorithm 1 Radio Parameters Software
1: Start
2: While (True)
3:   Select the testing mode to measure radio parameters
4:   Request and get radio parameters from the base station
5:   Input are parameters SS-RSRP and SS-SINR
6:   If (SS-RSRP >= -95, SS-SINR >= 16)
7:     Show green color on the terminal display of each parameter
8:   Else if (-105 <= SS-RSRP < -95, 10 <= SS-SINR < 16)
9:     Show yellow color on the terminal display of each parameter
10:  Else
11:    Show red color on the terminal display of each parameter
12:  End If
13:  Store radio parameters in a CSV file
14:  Query radio parameters and parameters are related from a CSV file to the Grafana dashboard
15:  All parameters are displayed on the Grafana dashboard, on the terminal display
16: End
  
```

Fig. 2. Algorithm of radio parameters software operation

```

Algorithm 2 End Parameters Software
1: Start
2: While (True)
3:   Select the testing mode to measure end parameters
4:   Request and get end parameters from the base station
5:   Input are parameters RTT, Upload, Download
6:   If (RTT < 110, Upload > 1.25, Download > 5)
7:     Show green color on the terminal display of each parameter
8:   Else if (110 <= RTT < 150, 0.5 <= Upload <= 1.25, 2.5 <= Download <= 4.9)
9:     Show yellow color on the terminal display of each parameter
10:  Else
11:    Show red color on the terminal display of each parameter
12:  End If
13:  Store end parameters in a CSV file
14:  Query end parameters and parameters are related from a CSV file to the Grafana dashboard
15:  All parameters are displayed on the Grafana dashboard, on the terminal display
16: End
  
```

Fig. 3. Algorithm of end parameters software operation

IV. RESULT

DUT was developed set of equipment and software for measuring 5G Quality Of Services (QoS), both radio parameters and end parameters, by measuring in the n41 band at the frequency range 2496 – 2690 MHz in the Advanced Smart City area inside the Suranaree University of Technology Science Park as shown in Figure 4, scale in meter. By testing a total of 20 points and divided into static

and dynamic signal quality tests, the Next-Generation Node B is represented by green circles. In addition, our developed system and commercially available system measuring instruments were compared.



Fig. 4. Advanced Smart City area or Suranaree University of Technology Science Park area

Static Signal Quality Testing

In the case of Static signal quality testing, it will be used to test the signal for 1 minute. The test results can be seen in Figures 5, 6, and TABLE 1.

From the results of the 5G static signal quality tests on Band n41 across all 20 test points and plotting the average values in Figure 7, it is evident that the SS-RSRQ signal in the Advanced Smart City area exhibits relatively stable signal quality. However, the SS-RSRP and SS-SINR signals show fluctuations corresponding to different conditions and end parameters, according to Table 1, which illustrates the telecommunications service quality of the 5G SA Band n41 signal in the Advanced Smart City area, there is good quality of telecommunications services. The test results meet the telecommunications service quality standards as per the NBTC's measurement guidelines [8].




Fig. 5. Average value of 5G SA Band n41 static signal quality test results

TABLE 1. RESULTS OF QUALITY-OF-SERVICE TESTING IN 5G SA BAND N41

Points	5G SA Band n41			
	Download (Mbps)	Upload (Mbps)	Jitter (ms)	RTT (ms)
1	460.69	54.41	1.10	22.17
2	471.13	74.06	1.10	23.47
3	455.53	95.24	0.88	23.37

Points	5G SA Band n41			
	Download (Mbps)	Upload (Mbps)	Jitter (ms)	RTT (ms)
4	332.51	48.18	0.52	23.30
5	239.50	55.73	0.45	22.10
6	147.04	32.29	1.48	21.13
7	278.73	63.61	2.29	21.00
8	285.86	65.63	0.15	23.30
9	322.60	71.28	2.29	19.10
10	480.86	91.58	1.40	20.47
11	488.76	87.21	0.75	22.63
12	419.34	92.73	0.15	23.13
13	275.74	68.82	0.81	19.60
14	271.95	60.42	1.31	20.90
15	273.33	61.97	2.31	20.33
16	214.26	56.33	0.73	21.64
17	356.22	49.64	0.62	19.97
18	442.05	81.59	0.82	20.47
19	354.73	64.57	3.56	21.13
20	459.78	71.54	1.53	21.97
Average	351.53	67.34	1.21	21.56

From static signal quality testing, end parameters were plotted on the Advanced Smart City map, then compared with the NBTC's telecommunications service quality standards by dividing the range of service standards region color, as shown in Figure 8.

Dynamic Signal Quality Testing

Dynamic signal quality test case, testing from the beginning to the end. The test results can be seen in Figures 7, 8, 9, and Table II.



Fig. 6. Overview of the Quality of Service of the 5G Band n41 signal

From the results of the 5G dynamic signal quality tests on Band n41, then plotting the values in Figure 7. They also plotted the points on the map showing that the overall signal quality of 5G SA Band n41 in the Advance Smart City area has good signal quality shown in Figure 8, and end parameters, which the result of the test of the quality of telecommunications services in the Advance Smart City area, which has the average test results in the test shown in Table II.




Fig. 7. The value of 5G SA Band n41 dynamic signal quality test results



Fig. 8. Overview of 5G SA Band n41 radio parameters dynamic signal quality in the Advance Smart City area.

Results on average Quality-of-Service for dynamic signal quality testing, end parameters were plotted on the Advanced Smart City map, then compared with the NBTC's telecommunications service quality standards by dividing the range of service standards region color, as shown in Figure 9.

TABLE II THE AVERAGE QUALITY-OF-SERVICE TESTING RESULTS FOR 5G SA BAND N41.

Time	5G SA Band n41			
	Download (Mbps)	Upload (Mbps)	Jitter (ms)	RTT (ms)
10/12/2023 8:41	223.26	31.77	0.51	19.9
10/12/2023 8:42	370.69	64.65	0.54	25
10/12/2023 8:43	412.83	28.19	0.5	24.9
10/12/2023 8:44	352.67	61.41	2.91	19.8
10/12/2023 8:45	209.71	36.02	3.08	23.4
Average	313.83	44.41	1.51	22.6




Fig. 9. Overview of the average Quality-of-Service testing results for 5G SA Band n41.

TABLE III. COMPARISON OF RADIO PARAMETERS BETWEEN OUR DUT AND TEST PHONE

5G SA Band n41		
Radio parameters	Our DUT	Test phone
SS-RSRP (dBm)	-68	-71
SS-RSRQ (dB)	-12	-12
SS-SINR (dB)	4	5

TABLE IV. COMPARISON OF END PARAMETERS BETWEEN OUR DUT AND TEST PHONE

5G SA Band n41		
Radio parameters	Our DUT	Test phone
Download (Mbps)	181.70	153
Upload (Mbps)	31.12	27.6
Jitter (ms)	2.99	3
RTT, Ping (ms)	19.94	26

Proposed System and Commercial Test Phone

Measuring the actual 5G signal quality by Device Under Test (DUT) found that the radio parameters obtained from the signal test and the actual signal quality test by phone were similar trend with same Physical Cell ID (PCI) according to table III. Speed test application was selected for measuring internet speed test. Results are presented in table IV the Device Under Test (DUT) used for testing is effective enough to be used in testing telecommunications service quality standards for 5G n41 band.

V. CONCLUSION

In conclusion, the system infrastructure of Connected and Autonomous Vehicles pivots on the robustness of the CAV communication link. Our results enhance the efficiency and

reliability of data transmission and play a pivotal role in shaping the capabilities and limitations of autonomous vehicles.

In summary, the use of the 5G QOS Tester is crucial for evaluating the performance of 5G connections to provide efficient services for Connected and Autonomous Vehicles (CAV) in the context of Connected-Autonomous-Share-Electric Vehicles (CASE) systems. The testing has demonstrated the suitability of 5G Standalone (5G SA) New Radio (NR) in delivering high-performance and seamless services in this context. This work has conducted and presented test results to verify the suitability of 5G SA NR in the CAV service scenario for CASE, representing a crucial step in the experimentation and development of efficient and reliable autonomous vehicle systems.

ACKNOWLEDGMENT

This work was supported by (i) Suranaree University of Technology, (ii) Thailand Science Research and Innovation (TSRI), (iii) National Science Research and Innovation Fund (NSRF-FF7-709-66-12-79(S)), and Advanced Wireless Network Company Limited (AWN).

REFERENCES

- [1] M. H. C. Garcia et al., "A Tutorial on 5G NR V2X Communications," in *IEEE Communications Surveys & Tutorials*, vol. 23, no. 3, pp. 1972–2026, thirdquarter 2021, doi: 10.1109/COMST.2021.3057017.
- [2] M. C. Lucas-Esteban et al., "An Analytical Latency Model and Evaluation of the Capacity of 5G NR to Support V2X Services Using V2N2V Communications," in *IEEE Transactions on Vehicular Technology*, vol. 72, no. 2, pp. 2293–2306, Feb. 2023, doi: 10.1109/TVT.2022.3208306.
- [3] M. C. Lucas-Esteban and J. Gozalvez, "Sensing-Based Grant-Free Scheduling for Ultra Reliable Low Latency and Deterministic Beyond 5G Networks," in *IEEE Transactions on Vehicular Technology*, vol. 71, no. 4, pp. 4171–4183, April 2022, doi: 10.1109/TVT.2021.3136725.
- [4] T. S. Rappaport, Y. Xing, G. R. MacCartney, A. F. Molisch, E. Melios and J. Zhang, "Overview of Millimeter Wave Communications for Fifth-Generation (5G) Wireless Networks—With a Focus on Propagation Models," in *IEEE Transactions on Antennas and Propagation*, vol. 65, no. 12, pp. 6213–6230, Dec. 2017, doi: 10.1109/TAP.2017.2734243.
- [5] S. Sun et al., "Propagation Path Loss Models for 5G Urban Micro- and Macro-Cellular Scenarios," 2016 IEEE 83rd Vehicular Technology Conference (VTC Spring), Nanjing, China, 2016, pp. 1–6, doi: 10.1109/VTCSpring.2016.7504435.
- [6] Majed, Mohammed Bahjat, et al., "Channel characterization and path loss modeling in indoor environment at 4, 5, 28, and 38 GHz for 5G cellular networks," *International Journal of Antennas and Propagation* 2018 (2018).
- [7] Hindia, M. N., et al., "Enabling remote health-caring utilizing IoT concept over LTE-femtocell networks," *PloS one* 11.5 (2016): e0155077.
- [8] NBTC 2023, *Office of The National Broadcasting and Telecommunications Commission*, Thailand government, accessed 28 July 2023, <https://standard1.nbt.go.th/>.

2. S. Thongsri, K. Bunchen and S. Poochaya, “Enhancing Thailand Road Safety through Personal Driving Style Classification using Machine Learning Model”

The 2024 International Conference on Power, Energy and Innovations (ICPEI 2024) to be held in Korat, Thailand from 16-18 October 2024.





www.rmuti.ac.th

RMUTI

ราชภัฏเทคโนโลยีสารสนเทศ นครราชสีมา

ICPEI 2024



CALL FOR PAPERS

The 2024 International Conference on Power, Energy and Innovations

16-18 October 2024 KORAT, THAILAND

<https://www.icpei.net/2024/>

The 2024 International Conference on Power, Energy and Innovations (ICPEI 2024), organized by Electrical Engineering Academic Associations (Thailand) EEAAT and All Departments of Electrical Engineering in Rajamangala University of Technology Isan (RMUTI), technical support by IEEE Thailand Section and IEEE PES-Thailand Chapter. ICPEI is the conference of the Power, Energy and Innovations and provides a forum for researchers and engineers involved in electric power and energy engineering to share ideas and results.



Topics of interest for submission include, but are not limited to :

Power:

- Power quality
- Smart grid technologies
- High voltage engineering
- Power system management
- Modeling, analysis and operation
- Motor drives and motion control
- Power transmission and distribution
- Switch-mode power supplies and UPS
- Lightning protection of power systems
- Planning and operation of Power systems
- Power system dynamics, stability and control
- FACTS
- Others related topics

Innovation:

- IT and IoT innovation
- Nano technology
- Material engineering
- Information engineering
- Technology for big data
- Technological innovation
- Innovation in power system
- Technology-enhanced learning
- E-Car and Motorcycle conversion
- Communication technology

Energy:

- Wind energy
- Energy issues
- Biogas and biomass
- Solar electricity and PV applications
- Hydrogen and fuel cells
- Hybrid energy systems
- Solar thermal applications
- Renewable energy technologies
- Energy policy, planning and management
- Analysis and design of electrical machines
- Power electronics in traction and automotive
- Modelling and simulation in power electronics
- Modelling and simulation in electrical machine
- Energy conversions
- Battery and energy storage technology
- Advances in sustainable buildings sustainable cities
- Other related topics

Important Dates

Submission Deadline for Full Manuscript: **July 15, 2024**
 Notification of Acceptance: **July 31, 2024**
 Camera-ready Submission Deadline: **August 18, 2024**
 Conference Dates: **16-18 October, 2024**

Contact:

Asst' Prof. Dr.Yuttana Kongjeen

E-mail: icpei2024@gmail.com



ICPEI 2024 : Notification of Acceptance: Paper Code P05842 - SETTAWIT POOCHAYA - Outlook - Work - Microsoft Edge

about:blank

Delete Archive Report Reply Reply all Forward Zoom Read / Unread Categorize Flag / Unflag Print ...

ICPEI 2024 : Notification of Acceptance: Paper Code P05842

EEAAT Submission System <eeaatconf.noreply4@gmail.com>
To: SETTAWIT POOCHAYA
Mon 8/5/2024 10:28 PM

You forwarded this message on Mon 8/5/2024 10:58 PM

Dear Sir/Madam,

Congratulations !

Your paper number **P05842** entitled

Enhancing Thailand Road Safety through Personal Driving Style Classification using Machine Learning Model

has been **Accepted** for oral presentation at the **The 2024 International Conference on Power, Energy and Innovations (ICPEI 2024)** to be held in Korat, Thailand from 16-18 October 2024.

Please note that you must make registration payment and present your paper at the conference otherwise your paper will be excluded from the conference program.

Please revise your paper according to the comment of the reviewers (if any) following this message and uploading the paper as a camera-ready to the online system again.

Reviewer 1 Comment:
Should provide the comparison results with others. Please also check the Equation format and style.

Reviewer 2 Comment:
- ในการทดสอบความถูกต้องของระบบควรใช้ค่าเฉลี่ยจาก K-Fold Cross Validation มานำเสนอ - ในการปรับ parameter ของ SVM นั้น ค่า C ,gamma ควร เลือกเป็นช่วง เพราะมีผลต่อการคำนวณค่าความถูกต้อง อาจอ้างอิงค่า C ,gamma ที่ให้ค่า accuracy ที่ถูกต้องมากที่สุด

Reviewer 3 Comment:
This paper is interesting well. However, please carefully follow the format and template of the conference, especially in Figure Labels, Equations, and Reference.

Reviewer 4 Comment:
good paper

Reviewer 5 Comment:
1. The text in the image is too small.

Your plagiarism result is 19%.
You can download this result via web site https://www.eeaat-conf.com/conferences/file/plagiar/35_5842_240622104900.pdf

มหาวิทยาลัยเทคโนโลยีสุรนารี

2024 International Conference on Power, Energy and Innovations (ICPEI 2024)
October 16-18, 2024, Nakhon Ratchasima (Korat), THAILAND

Enhancing Thailand Road Safety through Personal Driving Style Classification using Machine Learning Model

Sittisak Thongsri
School of Telecommunication
Engineering
Suranaree University of Technology
Muang, NakhonRatchasima,
Thailand
m6502560@gsut.ac.th

Kriengkri Bunchen
School of Telecommunication
Engineering
Suranaree University of Technology
Muang, NakhonRatchasima,
Thailand
kriengkri.b@gmail.com

Settawit Poochaya
School of Telecommunication
Engineering
Suranaree University of Technology
Muang, NakhonRatchasima,
Thailand
settawit@sut.ac.th

Abstract—In Thailand, road safety remains a critical concern due to various factors, including diverse driving styles. To address this issue, this study proposes an approach utilizing machine learning models to classify personal driving styles, aiming to enhance road safety measures. By analyzing driving behavior data collected from Inertial Measurement Unit sensors (IMU), which is a telematics device. This study presents the simulation of a driver behavior dataset to determine the appropriate machine learning model. Then analyzes the dataset, selects features suitable for feature scaling, and trains models using machine learning algorithms, including Support Vector Machine (SVM), Logistic Regression (LR), Random Forest (RF), and Decision Tree (DT). Our results reveal that the Random Forest algorithm outperforms others, achieving an accuracy of 89%, precision of 78%, recall of 89%, and an f1-score of 82%. This highlights the effectiveness of the proposed approach in accurately driver behavior, which is classified as safety driving and unsafety driving, the study lays the foundation for the development of tailored road safety initiatives aimed at reducing accidents and promoting responsible driving practices in Thailand.

Keywords—telematics, machine learning, driver behavior, data visualization, and IMU data

I. INTRODUCTION

Road safety is a paramount concern in Thailand, where diverse driving styles intersect with complex traffic dynamics, presenting ongoing challenges for ensuring public safety and well-being. Despite concerted efforts and campaigns, road accidents continue to pose significant risks to motorists, pedestrians, and other road users. In response to this pressing issue, this study endeavors to pioneer an innovative approach utilizing machine learning methodologies to classify personal driving styles, with the overarching goal of advancing road safety measures nationwide. The increment of telematics devices, particularly Inertial Measurement Unit sensors (IMU), has revolutionized the landscape of data collection in the transportation sector. These devices offer granular insights into driver behavior, capturing various metrics such as acceleration, braking patterns, and vehicle trajectory. By harnessing data sourced from platforms like Kaggle and IMU sensors

as in work [1], many papers proposed methodologies for driver behavior classification with machine learning algorithms, such as Logistic Regression Classifier, Gradient Boosting, and Random Forests, according to [2], in works on driver drowsiness detection for logistics and public transport applications to enhance road safety and comparative analysis of vehicle-based proposed support vector machine (SVM), detect driver drowsiness with IoT-based [3], [4]. In addition, driver behavior profiling indicate advantages driver behavior and driving style classification [5]. In the embedded world of driver behavior analysis, data are obtained by the in-vehicle sensors, such as Inertial Measurement Unit (IMU), Controller Area Network bus (CAN bus), and a GPS [6], [7], [8]. In IMU, CAN bus, and GPS features, the driving performance and driving characteristics were used for vehicle monitoring and diagnostic [9]. Driver behavior notify driver with posture based-inertial sensor, such as accelerometer and gyroscope, in terms of monitoring, and telematics using MEMS sensors, such as accelerometer, gyroscope, and magnetometer are features driver behavior monitoring [10]. This research seeks to analyze and categorize driving styles based on individual behaviors. Key to the success of this endeavor is the meticulous curation of feature sets that encapsulate the nuances of driving behavior. Through rigorous pre-processing and feature engineering techniques, the dataset is refined to facilitate the training of machine learning algorithms. These algorithms, ranging from classical methods like Support Vector Machine and Logistic Regression to more sophisticated ensemble techniques such as Random Forest and Gradient Boosting were deployed to discern patterns within the driving data. Moreover, the findings of this research extend beyond academic inquiry, offering practical applications in domains such as driver scoring and insurance. The classification of personal driving styles enables the establishment of driver scoring mechanisms, wherein individuals are assessed based on their adherence to safe driving practices. Such scoring systems can inform insurance premiums, with safer drivers being rewarded with lower rates, thereby incentivizing responsible behavior on the roads. In summary, this

study represents a significant step forward in leveraging machine learning to enhance road safety in Thailand. By harnessing the power of data-driven insights, it offers a pathway toward mitigating the multifaceted challenges posed by diverse driving styles, ultimately fostering a safer and more sustainable transportation environment for all while simultaneously offering tangible benefits in driver scoring and insurance practices.

II. DATASET DESCRIPTION

This paper presents a detailed overview of a unique driver behavior dataset, specifically designed to facilitate research on driver behavior analysis. The dataset encompasses phone sensor data collected during various driving sessions, providing valuable insights into the dynamics of driver actions and vehicle movements. Through the integration of smartphone sensors, including accelerometers, gyroscopes, and GPS modules, the dataset offers a comprehensive perspective on driving behavior in real-world scenarios.

A. Dataset Overview

The "Phone Sensor Data While Driving a Car" dataset available on Kaggle contains data collected from smartphone sensors while the phone is in a moving vehicle. This dataset was designed to help analyze driving behavior and identify patterns or anomalies in driving styles, the "Phone Sensor Data While Driving a Car" dataset [2] consists of multiple sensor readings captured during driving sessions.

Key sensors include:

- Accelerometer: Captures linear acceleration in three dimensions (X, Y, Z).
- Gyroscope: Measures angular velocity around the X, Y, and Z axes.
- GPS: Provides geospatial data, including latitude, longitude, speed, heading, and distance.

B. Processing Steps

Prior to driver behavior classification, the dataset undergoes rigorous preprocessing steps to ensure data quality and consistency. First, dataset visualization is performed to analyze the relationship of each individual feature. Then, appropriate features are selected and undergo feature scaling to resize them to be similar. The data is split into three parts using data splitting: the train set, validation set, and test set. Parts of the train and validation sets are integrated into



Figure 1. Processing Steps

the training process, while the test set is used for evaluating machine learning algorithms. Google Colab




Figure 2. IMU-Smartphone sensors dataset visualization in time series plotting

Data Visualization

In this part, the dataset from Kaggle, which is IMU sensors or smartphone sensors dataset were visualized




Figure 3. IMU-Smartphone sensors dataset visualization in histogram plotting

will be used for all processes, and the processing steps are illustrated in Figure 1.

III. METHODOLOGY

In this section, processing steps will be described further regarding data preprocessing, machine learning algorithms, and performance evaluation. Since the dataset from Kaggle did not clearly indicate the distribution or relationships between features, data visualization techniques were employed to explore the shape of the dataset and examine the relationships between the features and to observe the distribution of the data. In this visualization, Twelve features were utilized: accelerometer X, accelerometer Y, accelerometer Z, gyroscope X, gyroscope Y, gyroscope Z, speed, heading, latitude, longitude, distance, and label, the visualization is presented in Figure 2, and Figure 3. According to Figure 2, features exhibiting correlations include accelerometer X, accelerometer Y, accelerometer Z, gyroscope X, gyroscope Y, gyroscope Z, speed, and label. Subsequently, the label was used as the target variable. The correlated features were plotted in the form of histograms to observe their distributions, as depicted in Figure 3. Analysis of Figure 3 indicates that accelerometer X, accelerometer Y, accelerometer Z, gyroscope X, gyroscope Y, and gyroscope Z follow a normal distribution pattern.

Feature Selection

In this part, based on data visualization, the appropriate dataset will be selected for the next step of processing. The features considered appropriate include accelerometer X, accelerometer Y, accelerometer Z, gyroscope X, gyroscope Y, and gyroscope Z.

Feature Scaling

In this part, that appropriated features will be scaled in same range of each feature, standardization or z-score normalization technique will be used to scaling features, due to features have normal distribution, standardization equation shown as equation (1).

$$z = \frac{x - \text{mean}}{SD} \quad (1)$$

Where z is a sample of feature that scaled, x is a sample data that has not been scaled, mean is a average of features, according to the equation (2), SD is a standard deviation, according to equation (3).

$$\text{mean} = \frac{\sum_{i=0}^n x_i}{n} \quad (2)$$

Where, x_i is sample data that index i, and n is the all-sample data number of feature.

$$SD = \sqrt{\frac{\sum_{i=0}^n (x_i - \text{mean})^2}{n - 1}} \quad (3)$$




Figure 4. The training process of machine learning models

Data Splitting

In this part, the scaled features of the dataset will be split into three main parts: the train set (70%), validation set (20%), and test set (10%). The train and validation sets were used in the training process and for fine-tuning the machine learning algorithms, while parts of the test set were used for evaluating the models of machine learning.


Model Creation

Dataset that split in train and validation sets will be taken in training process of machine learning algorithms, in this work, Support Vector Machine (SVM), Logistic Regression (LR), Random Forest (RF), and Decision Tree (DT), which are machine learning algorithms will be trained via Google COLAB, and then will be compared into the next section, this process shown as Figure 4. The train set, comprising 70% of the dataset (9975 samples), and the validation set, comprising 20% of the dataset (2849 samples), will be inputted into the training process with machine learning algorithms. Parameters for each algorithm will be tuned as follows:

- SVM parameters tuning: kernel is sigmoid function, C = 1000, gamma = auto, max iterations = -1, and random state = 109.
- LR parameters tuning: solver is limited-memory Royden-Fletcher-Goldfarb-Shanno (lbfgs), C = 0.5, random state = 1.
- RF parameters tuning: max depth = 1000, random state = 1, number of trees = 300.
- RF parameters tuning: criterion is Gini, max depth = 1000, random state = 1.

IV. RESULTS AND EVALUATIONS

Proposed model according to the model creation process will be evaluated with 4 main equations such as accuracy, precision, recall, and f1-score, as follow in equation (4), (5), (6), and (7), respectively. Where TPs is number of true positives, TNs is number of true negatives, FPs is number of false positives, FNs is number of false negatives. According to model evaluation results are shown in Figures 5. It is evident that the evaluation outcomes across various models exhibit a spectrum of performance, ranging from favorable to suboptimal. The detailed assessment is as follows:



Figures 5. The model evaluation results

$$\text{accuracy} = \frac{TPs + TNs}{TPs + TNs + FPs + FNs} \quad (4)$$

$$\text{precision} = \frac{TPs}{TPs + FPs} \quad (5)$$

$$\text{recall} = \frac{TPs}{TPs + FNs} \quad (6)$$

$$f1 - \text{score} = \frac{2 \times (\text{precision} \times \text{recall})}{\text{precision} + \text{recall}} \quad (7)$$

- SVM evaluation results: accuracy is 0.47 or 47%, precision is 0.49 or 49%, recall is 0.48 or 48%, and f1-score is 0.41 or 41%.
- LR evaluation results: accuracy is 0.36 or 36%, precision is 0.59 or 59%, recall is 0.62 or 62%, and f1-score is 0.35 or 35%.
- RF evaluation results: accuracy is 0.89 or 89%, precision is 0.78 or 78%, recall is 0.89 or 89%, and f1-score is 0.82 or 82%.
- DT evaluation results: accuracy is 0.74 or 74%, precision is 0.66 or 66%, recall is 0.79 or 79%, and f1-score is 0.67 or 67%.

Based on the model evaluation results, Random Forest (RF) outperforms Support Vector Machine (SVM), Logistic Regression (LR), and Decision Tree (DT), achieving the highest accuracy at 89% and the highest f1-score at 82%. On the other hand, Logistic Regression (LR) exhibits the lowest performance, with an accuracy of 36% and an f1-score of 35%. However, it's important to note that these assessments may vary depending on specific criteria and use cases. Additionally, the choice of model should consider the nature of the data and the problem being addressed.

V. CONCLUSION

Conclusively, our study demonstrates the effectiveness of utilizing machine learning models to classify individual driving styles, aiming to enhance road safety measures in Thailand. With the Random

Forest algorithm achieving an accuracy of 89%, precision of 78%, recall of 89%, and an f1-score of 82%, our proposed methodology provides a robust framework for accurately discerning safe and unsafe driving behaviors. This research contributes by introducing a novel approach leveraging machine learning techniques and analyzing data from IMU sensors. By offering insights into driving behavior classification, our study lays the groundwork for tailored road safety initiatives and promotes responsible driving practices nationwide.

ACKNOWLEDGMENT

This work was supported by (i) Suranaree University of Technology, (ii) Thailand Science Research and Innovation (TSRI), (iii) National Science Research and Innovation Fund (NSRF.FF7.709.66.12.79.S), and Advanced Wireless Network Company Limited (AWN).

REFERENCES

- [1] K. Kanwal, F. Rustam, R. Chaganti, A. D. Jurcut and I. Ashraf, "Smartphone Inertial Measurement Unit Data Features for Analyzing Driver Driving Behavior," in *IEEE Sensors Journal*, vol. 23, no. 11, pp. 11308-11323, 1 June 2023, doi: 10.1109/JSEN.2023.3256000.
- [2] R. Ghandour, A. J. Potams, I. Boulkaibet, B. Neji, Z. A. Barakeh and A. S. Karar, "Machine learning methods for driver behaviour classification," 2021 4th International Conference on Bio-Engineering for Smart Technologies (BioSMART), Paris / Créteil, France, 2021, pp. 1-4, doi: 10.1109/BioSMART54244.2021.9677801.
- [3] M. A. Khan, T. Nawaz, U. S. Khan, A. Hamza and N. Rashid, "IoT-Based Non-Intrusive Automated Driver Drowsiness Monitoring Framework for

2024 International Conference on Power, Energy and Innovations (ICPEI 2024)
October 16-18, 2024, Nakhon Ratchasima (Korat), THAILAND

Logistics and Public Transport Applications to Enhance Road Safety," in IEEE Access, vol. 11, pp. 14385-14397, 2023, doi: 10.1109/ACCESS.2023.3244008.

[4] M. H. Baccour, F. Driewer, T. Schäck and E. Kasneci, "Comparative Analysis of Vehicle-Based and Driver-Based Features for Driver Drowsiness Monitoring by Support Vector Machines," in IEEE Transactions on Intelligent Transportation Systems, vol. 23, no. 12, pp. 23164-23178, Dec. 2022, doi: 10.1109/TITS.2022.3207965.

[5] A. E. Abdelrahman, H. S. Hassanein and N. Abu-Ali, "Robust Data-Driven Framework for Driver NETWORKS(COMSNETS), Bangalore, India, 2022, pp. 700-706, doi: 10.1109/COMSNETS53615.2022.9668532.

[6] A. Jaafer, G. Nilsson and G. Como, "Data Augmentation of IMU Signals and Evaluation via a Semi-Supervised Classification of Driving Behavior," 2020 IEEE 23rd International Conference on Intelligent Transportation Systems (ITSC), Rhodes, Greece, 2020, pp. 1-6, doi: 10.1109/ITSC45102.2020.9294496.

[7] E. Türk and M. Challenger, "An android-based IoT system for vehicle monitoring and diagnostic," 2018 26th Signal Processing and Communications Applications Conference (SIU), Izmir, Turkey, 2018, pp. 1-4, doi: 10.1109/SIU.2018.8404378.

[8] S. Ionut-Cristian, "A Brief Review of Using the Inertial Sensor to Determine the Driver Head Posture," 2021 International Conference on e-Health and Bioengineering (EHB), Iasi, Romania, 2021, pp. 1-4, doi: 10.1109/EHB52898.2021.9657575.

[9] F. J. Bruwer and M. J. Booysen, "Comparison of GPS and MEMS Support for Smartphone-Based Driver Behavior Monitoring," 2015 IEEE Symposium Series on Computational Intelligence, Cape Town, South Africa, 2015, pp. 434-441, doi: 10.1109/SSCI.2015.71.

[10] Nazirkar.)2021(. Phone sensor data while driving a car [Online]. Available: <https://www.kaggle.com/datasets>

[11] Behavior Profiling Using Supervised Machine Learning," in IEEE Transactions on Intelligent Transportation Systems, vol. 23, no. 4, pp. 3336-3350, April 2022, doi: 10.1109/TITS.2020.3035700.

[12] J. Carmona, M. A. de Miguel, D. Martin, F. Garcia and A. de la Escalera, "Embedded system for driver behavior analysis based on GMM," 2016 IEEE Intelligent Vehicles Symposium (IV), Gothenburg, Sweden, 2016, pp. 61-65, doi: 10.1109/IVS.2016.7535365.

[13] A. Agnoor, P. Atmakuri and R. Sivanandan, "Analysis of Driving Behaviour through Instrumented Vehicles," 2022 14th International Conference on communication Systems &

ประวัติผู้เขียน

นายสิทธิศักดิ์ ทองศรี เกิดเมื่อวันที่ 10 มิถุนายน พุทธศักราช 2543 สำเร็จการศึกษาระดับมัธยมศึกษาปีที่ 6 จากโรงเรียนวีรวัฒน์โยธิน จังหวัดสุรินทร์ และสำเร็จการศึกษาปริญญาตรี สาขาวิชาวิศวกรรมโทรคมนาคม สำนักวิชาวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีสุรนารี จากนั้นศึกษาต่อในปริญญาโท สาขาวิชาวิศวกรรมโทรคมนาคมและคอมพิวเตอร์ มหาวิทยาลัยเทคโนโลยีสุรนารี

ระหว่างศึกษาได้นำเสนอบทความเข้าร่วมประชุมในงานประชุมนานาชาติ 12th International Electrical Engineering Congress (iEECON 2024) ครั้งที่ 12 ณ โรงแรม The Zign Pattaya จังหวัดชลบุรี วันที่ 6-8 มีนาคม พ.ศ. 2567

การประชุมในงานประชุมนานาชาติ The 2024 International Conference on Power, Energy and Innovations วันที่ 16-18 ตุลาคม 2567 ณ มหาวิทยาลัยเทคโนโลยีราชมงคลอีสาน อำเภอเมือง จังหวัดนครราชสีมา

