

การระบุตัวคนขั้บรณโดยใช้ฮีสโทแกรมและโครงข่ายประสาทเทียมจากข้อมูลความเร่ง



นายณัฐฉัญ วิโรจน์บุญเกียรติ

บทคัดย่อและแฟ้มข้อมูลฉบับเต็มของวิทยานิพนธ์ตั้งแต่ปีการศึกษา 2554 ที่ให้บริการในคลังปัญญาจุฬาฯ (CUIR)
เป็นแฟ้มข้อมูลของนิสิตเจ้าของวิทยานิพนธ์ ที่ส่งผ่านทางบัณฑิตวิทยาลัย

The abstract and full text of theses from the academic year 2011 in Chulalongkorn University Intellectual Repository (CUIR)
are the thesis authors' files submitted through the University Graduate School.

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมคอมพิวเตอร์ ภาควิชาวิศวกรรมคอมพิวเตอร์

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

ปีการศึกษา 2560

ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

DRIVER IDENTIFICATION USING HISTOGRAM AND NEURAL NETWORK FROM ACCELERATI
ON DATA



A Thesis Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Engineering Program in Computer Engineering
Department of Computer Engineering
Faculty of Engineering
Chulalongkorn University
Academic Year 2017
Copyright of Chulalongkorn University



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

หัวข้อวิทยานิพนธ์	การระบุตัวคนขับรถโดยใช้ฮิสโทแกรมและโครงข่ายประสาทเทียมจากข้อมูลความเร็ว
โดย	นายณัฐธัญ วิโรจน์บุญเกียรติ
สาขาวิชา	วิศวกรรมคอมพิวเตอร์
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	รองศาสตราจารย์ ดร. กุลธิดา โรจนวิบูลย์ชัย
อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม	ผู้ช่วยศาสตราจารย์ ดร. พีรพล เวทีกุล

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้บัณฑิตวิทยาลัยเป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรบัณฑิต

..... คณบดีคณะวิศวกรรมศาสตร์
(รองศาสตราจารย์ ดร. สุพจน์ เตชวรสินสกุล)

คณะกรรมการสอบวิทยานิพนธ์

..... ประธานกรรมการ
(ผู้ช่วยศาสตราจารย์ ดร. ณัฐวุฒิ หนูไพโรจน์)

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก
(รองศาสตราจารย์ ดร. กุลธิดา โรจนวิบูลย์ชัย)

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม
(ผู้ช่วยศาสตราจารย์ ดร. พีรพล เวทีกุล) วิทยาลัย

..... กรรมการภายนอกมหาวิทยาลัย
(ดร. ภาสกร ประถมบุตร)

ณัฐธัญ วิโรจน์บุญเกียรติ : การระบุตัวตนขับรถโดยใช้ฮิสโทแกรมและโครงข่ายประสาทเทียมจากข้อมูลความเร่ง (DRIVER IDENTIFICATION USING HISTOGRAM AND NEURAL NETWORK FROM ACCELERATION DATA) อ.ที่ปรึกษาวิทยานิพนธ์หลัก: รศ. ดร. กุลธิดา วิจารณ์วิบูลย์ชัย, อ.ที่ปรึกษาวิทยานิพนธ์ร่วม: ผศ. ดร. พีรพล เวทีกุล, หน้า.

จนถึงปัจจุบันจำนวนตัวรับรู้ในรถยนต์มีการเพิ่มขึ้นอย่างต่อเนื่องเพื่อให้เกิดระบบอัจฉริยะต่าง ๆ ภายในรถยนต์ ข้อมูลจำนวนมากที่เกิดขึ้นจากตัวรับรู้เหล่านี้ส่งผลให้เกิดการศึกษาในการพยายามใช้ข้อมูลเหล่านี้ให้เกิดประโยชน์ งานวิจัยอย่างหนึ่งที่ได้รับความสะดวกสนใจเป็นอย่างมากคือ การศึกษาพฤติกรรมการขับรถ เนื่องจากคนขับรถแต่ละคนมีพฤติกรรมต่างกัน การรู้ถึงพฤติกรรมการขับรถจึงทำให้สามารถระบุตัวตนขับรถได้ การทราบถึงบุคคลที่กำลังขับรถทำให้เกิดประโยชน์ทั้งทางตรงและทางอ้อม ไม่ว่าจะเป็นด้านความปลอดภัย การประกันภัย หรือการอำนวยความสะดวก สิ่งนี้เองทำให้มีงานวิจัยเกี่ยวกับการระบุตัวตนขับรถเกิดขึ้นเป็นจำนวนมากเมื่อไม่นานมานี้ งานวิจัยที่ผ่านมามีส่วนมากมักใช้ข้อมูลจากตัวรับรู้จำนวนมากเพื่อระบุตัวตนขับรถและสามารถทำได้โดยมีความแม่นยำสูง อย่างไรก็ตามมีงานวิจัยจำนวนหนึ่งแสดงให้เห็นว่าการระบุตัวตนขับรถสามารถทำได้โดยใช้ตัวรับรู้เพียงตัวเดียว แต่ค่าความแม่นยำของงานเหล่านี้ยังสามารถพัฒนาต่อได้ งานวิจัยนี้ได้เสนอระบบการระบุตัวตนขับรถโดยใช้เพียงข้อมูลจากตัวรับรู้ความเร่ง โดยมีการใช้ฮิสโทแกรมของความเร่งเป็นข้อมูลนำเข้าสู่โครงข่ายประสาทเทียม สถาปัตยกรรมระบบที่น่าเสนอในงานวิจัยนี้สามารถใช้เป็นแนวทางในการพัฒนาระบบระบุตัวตนขับรถอื่นในอนาคต ผลการทดสอบประสิทธิภาพของระบบนี้สามารถระบุตัวตนขับรถได้แม่นยำสูงสุดถึง 99 เปอร์เซ็นต์ นอกจากนี้ในงานวิจัยยังได้ทดสอบประสิทธิภาพในหลายแง่มุมซึ่งที่ผ่านมามีหลายงานวิจัยที่มองข้ามบางแง่มุมไป ดังนั้นการวัดผลในงานวิจัยนี้จึงสามารถใช้เป็นแนวทางในการวัดผลการระบุตัวตนขับรถอื่นในอนาคตได้เช่นกัน

ภาควิชา วิศวกรรมคอมพิวเตอร์

สาขาวิชา วิศวกรรมคอมพิวเตอร์

ปีการศึกษา 2560

ลายมือชื่อนิสิต

ลายมือชื่อ อ.ที่ปรึกษาหลัก

ลายมือชื่อ อ.ที่ปรึกษาร่วม

6070182721 : MAJOR COMPUTER ENGINEERING

KEYWORDS: DRIVER IDENTIFICATION / DRIVER BEHAVIOR / DATA ANALYSIS / MACHINE LEARNING

NUTTUN VIROJBOONKIATE: DRIVER IDENTIFICATION USING HISTOGRAM AND NEURAL NETWORK FROM ACCELERATION DATA. ADVISOR: ASSOC. PROF. KULTIDA ROJVIBOONCHAI, Ph.D., CO-ADVISOR: ASST. PROF. PEERAPON VATEEKUL, Ph.D., pp.

Until now, the number of sensor in vehicles has continuously increase to provide smart system in the vehicle. A lot of data generated from those sensor causes researches which try to utilize those data. One of the researches which was getting attention is the driver behavior analysis. Because drivers have different driving behavior, to be aware of the driver helps identifying drivers. The aware of the current driver provides both direct and indirect benefits such as safety application, insurance, or facility in vehicle. This causes a publish of many driver identification researches recently. Most of the previous researches used multisensory to identify driver and it can be done with high accuracy. However, some previous researches showed that the driver identification can be done using only single sensor. Yet, the accuracy of those work can be improved. This research proposes the driver identification system using only single acceleration sensor. The histogram of acceleration was used as the input to the Neural Network. The proposed system architecture can be used as a guideline for later driver identification system. The performance of the proposed system can achieve up to 99% of accuracy. Moreover, this research perform test in many aspects, some of which were overlooked in some previous works. Thus, the performance evaluation in this research can be used as a guideline for the evaluation of later driver identification system.

Department: Computer Engineering Student's Signature

Field of Study: Computer Engineering Advisor's Signature

Academic Year: 2017 Co-Advisor's Signature

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงได้ด้วยความอนุเคราะห์จากรองศาสตราจารย์ ดร. กุลธิดา โรจน์วิบูลย์ชัย อาจารย์ที่ปรึกษาวิทยานิพนธ์ และผู้ช่วยศาสตราจารย์ ดร. พีรพล เวทีกุล อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม อาจารย์ทั้งสองท่านได้ให้คำปรึกษาและข้อคิดเห็นต่าง ๆ สำหรับพัฒนา งานวิจัย อีกทั้งยังให้คำแนะนำเพื่อช่วยแก้ปัญหาที่เกิดขึ้นระหว่างดำเนินงานวิจัยอีกด้วย

ขอขอบคุณคณะกรรมการสอบวิทยานิพนธ์ ได้แก่ ผู้ช่วยศาสตราจารย์ ดร.ณัฐวุฒิ หนูไพโรจน์ และ ดร.ภาสกร ประถมบุตร ที่ได้ให้คำแนะนำซึ่งเป็นประโยชน์ต่อวิทยานิพนธ์ฉบับนี้

ขอขอบคุณทุนอุดหนุนการศึกษาระดับบัณฑิตศึกษาสำหรับนิสิตเก่าวิศวกรรมศาสตรบัณฑิต สาขาวิศวกรรมคอมพิวเตอร์ จุฬาลงกรณ์มหาวิทยาลัย

ขอขอบคุณ ดร.กฤษณ์ ณ นคร นายเกียรติคุณ กาวิละ นายอัษฎาวุธ ชนะกิจการโชค นายธีรภัทร์ วงศ์สุธีรา นายฉันทวัฒน์ รัตนพงศ์พันธ์ นายสัญญาชัย จักรธีรังกูร นายวิศทัศน์ ดิยिंग และสมาชิกคนอื่นในห้องปฏิบัติการวิศวกรรมระบบสารสนเทศ (ISEL) ที่ได้ให้ความคิดเห็นและข้อเสนอแนะสำหรับการทำวิจัยตลอดระยะเวลาการทำวิจัย

สุดท้ายนี้ขอขอบคุณคุณพ่อ คุณแม่และครอบครัว รวมถึงเพื่อนทุกคนที่เป็นกำลังใจให้ตลอดระยะเวลาที่ทำการวิจัยจนกระทั่งสำเร็จการศึกษา

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ.....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ.....	ช
สารบัญภาพ	ฌ
สารบัญตาราง.....	ฎ
บทที่ 1 บทนำ	1
1.1 ความเป็นมาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของการวิจัย	5
1.3 ขอบเขตของการวิจัย.....	5
1.4 คุณค่าทางวิชาการ	5
1.5 วิธีดำเนินการวิจัย.....	6
1.6 ผลงานตีพิมพ์	6
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง	7
2.1 ทฤษฎีที่เกี่ยวข้อง.....	7
2.1.1 ฮิสโทแกรม	7
2.1.2 การเรียนรู้ของเครื่อง (Machine Learning).....	7
2.1.3 การแบ่งประเภทข้อมูล (Statistical classification)	7
2.1.4 โครงข่ายประสาทเทียม.....	8
2.1.5 อัลกอริทึมการค้นหาเพื่อนบ้านใกล้สุด k ตัว (k-nearest neighbors algorithm)	8
2.1.6 การตรวจสอบไขว้แบบ 10 พับ (10-Fold Cross Validation)	9
2.1.7 ค่าพรีซีชัน รีคอลล และเอฟวัน (precision, recall, and f1 score)	10

2.2 งานวิจัยที่เกี่ยวข้อง.....	11
บทที่ 3 การระบุตัวคนขับรถ.....	13
3.1 ภาพรวมโครงสร้างของระบบ	13
3.2 ส่วนการเก็บข้อมูล.....	15
3.3 ส่วนการเตรียมข้อมูล	16
3.3.1 การศึกษาข้อมูลเบื้องต้น	16
3.3.2 ส่วนการกรองช่วงระยะพัก (Inactive period filtering module).....	19
3.3.3 ส่วนการสกัดฟีเจอร์ (Feature extraction module).....	20
3.4 โมเดลโครงข่ายประสาทเทียม	22
3.5 การระบุผู้ไม่พึงประสงค์	24
บทที่ 4 การวัดประสิทธิภาพของโมเดลและผลการทดลอง	28
4.1 การออกแบบการทดลอง	28
4.2 ประสิทธิภาพของการใช้ส่วนกรองข้อมูลช่วงระยะพัก.....	28
4.3 ประสิทธิภาพของขนาดหน้าต่างเลื่อน และการเหลื่อม	30
4.4 ประสิทธิภาพของระบบระบุตัวคนขับรถ	31
4.5 ประสิทธิภาพของระบบเมื่อเปรียบเทียบกับตัวแยกประเภทแบบอื่น.....	32
4.6 การศึกษาประสิทธิภาพบนจำนวนข้อมูล	33
4.7 การศึกษาประสิทธิภาพต่อลักษณะเส้นทาง	34
4.8 การศึกษาประสิทธิภาพเมื่อใช้ระบบในการระบุผู้ไม่พึงประสงค์	35
บทที่ 5 สรุปผลงานวิจัย.....	38
รายการอ้างอิง	39
ภาคผนวก ก การระบุตัวคนขับรถก่อนมีการกรอกช่วงระยะพัก.....	43
ประวัติผู้เขียนวิทยานิพนธ์	45

สารบัญภาพ

ภาพที่ 2.1 แสดงการแบ่งข้อมูลด้วยวิธีการตรวจสอบไขว้แบบ 10 พับ	9
ภาพที่ 3.1 รถโดยสารภายในจุฬาลงกรณ์มหาวิทยาลัยซึ่งใช้ในงานวิจัยนี้	14
ภาพที่ 3.2 กล่องรวมอุปกรณ์ทั้งหมดซึ่งประกอบด้วย ราวส์เบอร์รี่พาย ตัวรับรู้ความเร่ง	14
ภาพที่ 3.3 ภาพรวมโครงสร้างของระบบ	15
ภาพที่ 3.4 ส่วนเก็บข้อมูล	16
ภาพที่ 3.5 แสดงฮิสโทแกรมของคนขับรถคนเดียวกันในวันต่าง ๆ จำนวน 3 วัน	17
ภาพที่ 3.6 แสดงฮิสโทแกรมของคนขับรถจำนวน 3 คนจากข้อมูลในวันเดียวกัน	17
ภาพที่ 3.7 แสดงตัวอย่างฮิสโทแกรมในกลุ่มต่าง ๆ	18
ภาพที่ 3.8 ตัวอย่างฮิสโทแกรมที่เกิดความผิดพลาด	21
ภาพที่ 3.9 ตัวอย่างฮิสโทแกรมที่แก้ไขความผิดพลาดแล้ว	21
ภาพที่ 3.10 แสดงลักษณะไฟล์ที่ได้จากการทำความสะอาดข้อมูล	22
ภาพที่ 3.11 แสดงผลการทดลองการหาจำนวนปมในชั้นซ่อน	23
ภาพที่ 3.12 แสดงตัวอย่างโมเดลโครงข่ายประสาทเทียม	24
ภาพที่ 3.13 แสดงการแบ่งข้อมูลเพื่อทดสอบการระบุผู้ไม่พึงประสงค์	25
ภาพที่ 4.1 แสดงผลการทดลองการใช้ข้อมูลแกนร่วมที่แตกต่างกันก่อนการกรอกช่วงพัก	29
ภาพที่ 4.2 แสดงผลการทดลองการใช้ข้อมูลแกนร่วมที่แตกต่างกันหลังการกรอกช่วงพัก	29
ภาพที่ 4.3 แสดงผลการทดลองบนขนาดหน้าต่างเลื่อนและการเหลื่อมที่แตกต่างกัน	31
ภาพที่ 4.4 แสดงผลการระบุตัวคนขับรถโดยมีจำนวนคนขับรถในระบบแตกต่างกัน	32
ภาพที่ 4.5 แสดงความแม่นยำเมื่อใช้ตัวแยกประเภทที่แตกต่างกัน	33
ภาพที่ 4.6 แสดงผลการระบุตัวคนขับรถโดยจำกัดปริมาณข้อมูลที่ต่างกัน	34
ภาพที่ 4.7 แสดงความแม่นยำของระบบเมื่อจำกัดข้อมูลคนขับรถจากเส้นทางเดียว	35
ภาพที่ 4.8 แสดงผลการระบุคนขับรถเมื่อมีผู้ไม่พึงประสงค์แอบแฝงเมื่อใช้โครงข่ายประสาทเทียม ..	36

ภาพที่ 4.9 แสดงผลการระบุคนขับรถเมื่อมีผู้ไม่พึงประสงค์แอบแฝงเมื่อใช้อัลกอริทึมการค้นหาเพื่อนบ้านใกล้สุด k ตัว 36



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สารบัญตาราง

ตารางที่ 2.1 แสดงคอนฟิวชันเมทริกซ์พื้นฐาน.....	10
ตารางที่ 2.2 แสดงตารางเปรียบเทียบงานวิจัยที่เกี่ยวข้อง	12
ตารางที่ 3.1 แสดงการตั้งค่าบางส่วนในโปรแกรมสำเร็จ neuralnet.....	24
ตารางที่ 4.1 แสดงชื่อโปรแกรมสำเร็จจาก CRAN ที่ใช้ในการทดลอง	33
ตารางที่ 4.2 แสดงค่าคอนฟิวชันเมทริกซ์ของการระบุผู้ไม่พึงประสงค์	37



บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

ในปัจจุบันการพัฒนาตัวรับรู้ (Sensor) และเทคโนโลยีการสื่อสาร (Information Technology) เป็นไปอย่างก้าวกระโดด ทำให้จำนวนอินเทอร์เน็ตของสรรพสิ่ง (IoT : Internet of Things) เพิ่มขึ้นอย่างรวดเร็ว ในปี ค.ศ. 2020 ที่จะถึงนี้จำนวนอินเทอร์เน็ตของสรรพสิ่งถูกทำนายว่าจะมีมากถึงสองหมื่นล้านชิ้น [1] ยานยนต์เองก็ถือเป็นสรรพสิ่งอย่างหนึ่งที่มีอินเทอร์เน็ตมาเกี่ยวข้อง จนเกิดคำว่าอินเทอร์เน็ตของยานยนต์ (Internet of Vehicle) และได้ถูกคาดการณ์ไว้เช่นกันว่าจะมีรถยนต์ที่สามารถสื่อสารผ่านอินเทอร์เน็ตจำนวนมากถึงสองร้อยห้าสิบล้านคัน [2] อย่างไรก็ตามในปัจจุบันรถยนต์ที่ถูกใช้งานทั่วไปก็มีตัวรับรู้ต่าง ๆ ติดตั้งอยู่เป็นจำนวนมาก ทำให้เกิดเทคโนโลยีใหม่ ๆ ในรถยนต์ ไม่ว่าจะเป็นระบบควบคุมความเร็วอัตโนมัติ (ACC : Adaptive Cruise Control) ซึ่งช่วยควบคุมและปรับเปลี่ยนความเร็วการขับขี่ของรถยนต์ให้เหมาะสมกับสภาพการจราจรอย่างอัตโนมัติ หรือระบบช่วยจอดรถยนต์โดยอัตโนมัติ หรือระบบหยุดรถยนต์โดยอัตโนมัติกรณีฉุกเฉิน เป็นต้น ตัวรับรู้ต่าง ๆ ที่ทำให้เกิดระบบเหล่านี้มานำมาซึ่งผลงานวิจัยจำนวนมากในด้านการคมนาคมและยานยนต์ หนึ่งในหัวข้อที่ได้รับความสนใจอย่างมากคือการวิเคราะห์พฤติกรรมการขับขี่รถยนต์ซึ่งจะใช้ข้อมูลจากตัวรับรู้ต่าง ๆ ภายในรถยนต์มาวิเคราะห์เพื่อจำแนกพฤติกรรมการขับขี่รถยนต์ ทำให้เกิดประโยชน์ในด้านการประหยัดพลังงานและความปลอดภัยในการขับขี่ งานวิจัยในด้านนี้ได้ถูกรวบรวมและวิจารณ์เป็นอย่างดีใน [3] อย่างไรก็ตามหากสามารถทราบถึงพฤติกรรมในการขับขี่รถยนต์และหากคนขับรถยนต์มีพฤติกรรมที่แตกต่างกัน ก็มีความเป็นไปได้สูงที่จะทราบถึงตัวคนขับรถยนต์ได้จากข้อมูลตัวรับรู้เหล่านี้เช่นกัน

เนื่องจากรถยนต์มักจะถูกขับโดยหลายบุคคลไม่ว่าจะเป็นรถโดยสารประจำทาง รถโดยสารในบริษัท หรือแม้กระทั่งรถโดยสารส่วนบุคคล การทราบถึงบุคคลที่กำลังขับรถยนต์จึงมีประโยชน์อย่างมากในหลายด้าน จากอดีตถึงปัจจุบันการบันทึกบุคคลที่เป็นคนขับรถยนต์อาจใช้วิธีง่าย ๆ เช่น การจดบันทึกด้วยมือหรือการใช้บัตรประจำตัวเพื่อยืนยันตัวตน จนถึงการใช้วิธีที่ซับซ้อนมากขึ้น เช่น การใช้เครื่องบันทึกลายนิ้วมือหรือการระบุใบหน้าด้วยการวิเคราะห์ข้อมูลวิดิทัศน์จากกล้อง อย่างไรก็ตามด้วยการวิเคราะห์ข้อมูลจากตัวรับรู้ การระบุตัวคนขับรถสามารถทำได้โดยทันทีและอัตโนมัติในขณะที่คนขับรถกำลังขับอยู่ ซึ่งวิธีการนี้อาจใช้ทดแทนหรือใช้งานควบคู่กับระบบเดิมก็ได้ เนื่องจากระบบเดิมมีจุดอ่อนที่แตกต่างกันอยู่ เช่น ในการใช้บัตรประจำตัวเพื่อยืนยันหรือการใช้เครื่องบันทึกลายนิ้วมือ คนขับรถสามารถยืมบัตรประจำตัวหรือบันทึกลายนิ้วมือก่อนเริ่มขับรถและให้ผู้อื่นขับแทน

หรือการระบุใบหน้าด้วยการวิเคราะห์ข้อมูลวิทัศน์จากกล้องอาจทำให้คนขับรถรู้สึกว่าคุณละเมิดสิทธิส่วนบุคคลได้ นอกจากนี้การใช้ข้อมูลจากตัวรับรู้วิเคราะห์ถึงพฤติกรรมในการขับรถนั้นสามารถปลอมแปลงได้ยากเพราะข้อมูลมีการปรับปรุงให้สดใหม่อยู่ตลอดเวลาและการลอกเลียนพฤติกรรมในการขับรถของผู้อื่นซึ่งแตกต่างกันในแต่ละบุคคลตลอดเวลานั้นทำได้ยากมาก ตรงจุดนี้เองที่ระบบดังกล่าวสามารถช่วยภาครัฐหรือบริษัทเจ้าของรถโดยสารได้ทราบถึงคนขับรถที่กำลังขับรถอยู่จริง ๆ ตัวอย่างเช่น หากมีการสลับคนขับรถที่ไม่มีใบอนุญาตก็จะทำให้เกิดปัญหาตามมาโดยเฉพาะปัญหาด้านความปลอดภัย นอกจากการทราบถึงบุคคลที่กำลังขับรถอยู่แล้วการระบุตัวคนขับรถสามารถประยุกต์เป็นระบบตรวจจับโจรขโมยรถหรือตรวจจับการจี้รถได้ เนื่องจากตัวรับรู้มีขนาดเล็กและถูกซ่อนไว้ในรถยนต์ผู้ร้ายจะไม่รู้ตัวว่าตนกำลังถูกตรวจสอบ และหากระบบระบุได้ว่าไม่ใช่ผู้ใช้รถที่ได้รับอนุญาต ก็จะมีการส่งสัญญาณไปยังเจ้าของที่ได้รับอนุญาตโดยอาจใช้การระบุตำแหน่ง (GPS : Global Positioning System) ในการระบุตำแหน่งรถยนต์แบบทันที ประโยชน์อีกอย่างหนึ่งจากการระบุตัวคนขับรถคือการประยุกต์ใช้กับธุรกิจประกันภัยเนื่องจากผู้ขับขี่แต่ละคนมีพฤติกรรมการขับรถที่แตกต่างกัน ส่งผลต่อความเสี่ยงในการประสบอุบัติเหตุที่แตกต่างกันด้วย การทราบถึงบุคคลที่กำลังขับรถทำให้เจ้าของธุรกิจประกันภัยสามารถปรับเบี้ยประกันให้เหมาะสมกับพฤติกรรมการขับรถของแต่ละคนได้อย่างทันที นอกจากนี้ระบบระบุตัวคนขับรถอาจใช้ในการปรับระบบภายในรถยนต์ตามบุคคลที่กำลังขับรถอย่างอัตโนมัติ เช่น การปรับอุณหภูมิ ตำแหน่งกระจก หรือสื่อต่าง ๆ ภายในรถยนต์ตามที่ได้ตั้งค่าไว้ล่วงหน้าตามแต่ละบุคคล

จากเหตุผลหลายข้อที่กล่าวมาข้างต้นทั้งหมดทำให้เกิดงานวิจัยเกี่ยวกับการระบุตัวคนขับรถอยู่เป็นจำนวนมาก [4-20] งานวิจัยแต่ละชิ้นมีข้อดีข้อเสียที่แตกต่างกันและได้นำเสนอวิธีในการระบุตัวคนขับรถที่แตกต่างกันออกไปเนื่องจากจุดประสงค์นั้นมีส่วนที่ต่างกัน งานวิจัยเรื่องการระบุตัวคนขับรถนั้นเกิดขึ้นเป็นระยะเวลานานแล้ว แต่ในเร็ว ๆ กลับเพิ่มขึ้นอย่างรวดเร็ว การระบุตัวคนขับรถโดยมากจะใช้ข้อมูลจากตัวรับรู้หลายตัวที่ติดตั้งไว้ในรถ แต่ก็ม้งานวิจัยที่พยายามใช้ข้อมูลจากตัวรับรู้เพียงตัวเดียวหรือจำนวนน้อยเพื่อให้ได้ผลลัพธ์ที่เท่าเทียมกัน

สำหรับงานวิจัยที่ใช้ตัวรับรู้จำนวนมากและน่าสนใจ [5, 7, 11-13, 15-17, 19-21] จะขออธิบายรายละเอียดโดยสังเขปสำหรับแต่ละงานดังนี้ งานวิจัย [5] ได้เสนอการระบุตัวคนขับรถโดยใช้ทั้งข้อมูลจำลองการขับรถและข้อมูลการขับรถจริง โดยข้อมูลทั้งหมดมีคนขับรถถึง 276 คน และมีตัวรับรู้สิ่งต่าง ๆ มากมายอาทิเช่น เสียง วิทัศน์ ตำแหน่ง แรงกระทำต่อคันเร่ง แรงกระทำต่อคันเหยียบเบรก อัตราเร็ว มุมของพวงมาลัย ความเร็วเครื่องยนต์ เป็นต้น อย่างไรก็ตามในงานวิจัยนี้จะใช้การวิเคราะห์ลักษณะระยะการติดตามรถ (car following pattern) อัตราเร็ว และลักษณะการเหยียบคันเร่งและเบรก ประกอบกับการใช้การวิเคราะห์สเปกตรัม (Spectral Analysis) และแบบจำลองการผสมของเกาส์เซียน (GMM : Gaussian Mixture Model) ซึ่งในงานวิจัยนี้ได้ผลความ

แม่นยำที่ 76.8 เปอร์เซ็นต์สำหรับข้อมูลการขับรถจริง ในงานวิจัย [21] ได้มีการใช้ตัวรับรู้หลายตัว เช่นกันซึ่งในที่นี้คือแรงดันของคันเร่งและคันเหยียบเบรกเพื่อระบุตัวคนขับรถ โดยใช้โครงข่ายประสาทเทียมแบบคลุมเครือ (Fuzzy Neural Network) ทำให้ได้ความแม่นยำถึง 95 เปอร์เซ็นต์ คล้ายกับงานวิจัย [7] ซึ่งได้ใช้การวิเคราะห์สเปกตรัมของคันเร่งและคันเหยียบเบรกเพื่อเป็นข้อมูลขาเข้าสู่โครงข่ายประสาทเทียม และได้ทำการพัฒนาจริงบนเอฟพีจีเอ (FPGA : Field Programmable Gate Arrays) เพื่อทดลองประสิทธิภาพจริงเมื่อนำไปติดตั้งในรถยนต์ แต่ด้วยข้อเด่นของเอฟพีจีเอที่ประหยัดพลังงานมากกว่าและมีความซับซ้อนต่ำกว่าคอมพิวเตอร์ ทำให้มีทำให้งานวิจัยนี้ทำความแม่นยำได้ที่ 84.6 เปอร์เซ็นต์

หลังจากแคน (CAN : Controller Area Network) ได้เป็นมาตรฐานการส่งข้อมูลในรถยนต์ งานวิจัยหลังจากนี้จำนวนมากพยายามจะนำข้อมูลในรถยนต์ผ่านมาตรฐานแคนเพื่อนำมาใช้ระบุตัวคนขับรถ [11-13, 15, 16, 19, 20] ในงานวิจัย [11] ได้มีการใช้ข้อมูลการขับรถจากอาสาสมัคร 15 คนซึ่งบันทึกจากรถคันเดียวกัน ในงานวิจัยนี้ได้ควบคุมตัวแปรหลายอย่าง ทั้งการคัดเลือกอาสาสมัคร เวลาในการขับรถ และสถานีวิทยุที่เปิดภายในรถ นอกจากนี้ยังมีการใช้เทคนิคหน้าต่างเลื่อนและการเหลื่อมกันด้วย (sliding window and overlapping technique) โดยในงานวิจัยนี้ใช้ฟีเจอร์ (feature) มากถึง 48 ฟีเจอร์ ประกอบไปด้วยฟีเจอร์ทางสถิติ (statistical features) ฟีเจอร์เชิงพรรณนา (descriptive features) และฟีเจอร์เชิงความถี่ (frequency feature) นอกจากนี้ยังมีการวิเคราะห์อัลกอริทึมที่ดีที่สุดประกอบกับการวิเคราะห์ตัวรับรู้และฟีเจอร์ที่ดีที่สุดด้วย โดยในงานวิจัยนี้แม้จะทำความแม่นยำได้สูงสุดถึง 100 เปอร์เซ็นต์ แต่งานวิจัยนี้ใช้ข้อมูลตัวรับรู้ถึง 15 ตัวและยังใช้การสกัดฟีเจอร์จำนวนมากอีกด้วย ทำให้เปลืองทรัพยากรในการคำนวณเพื่อระบุตัวคนขับรถเป็นอย่างมาก นอกจากนี้ยังใช้ข้อมูลเป็นระยะเวลาราว 3 ชั่วโมงต่อคนเท่านั้น ในงานวิจัย [12] ได้มีการเสนอวิธีการที่น่าสนใจเนื่องจากสามารถระบุตัวคนขับรถจากการเลี้ยวรถเพียงครั้งเดียวเท่านั้น งานวิจัยนี้ได้ใช้ข้อมูลจากคนขับรถหลายคนที่ใช้รถเพียงคันเดียวร่วมกัน จากข้อมูลวิจัย มีการแบ่งประเภทถนนที่มีการเลี้ยวไว้เป็น 12 ประเภท และทำการทดลองบนแต่ละประเภทแยกจากกัน ด้วยการใช้ข้อมูลตัวรับรู้ 12 ตัวจากแคน ทำให้งานวิจัยนี้สามารถระบุตัวคนขับรถได้ที่ความแม่นยำ 76.9 เปอร์เซ็นต์ สำหรับจำนวนคนขับรถ 2 คน และที่ความแม่นยำ 50.1 เปอร์เซ็นต์สำหรับจำนวนคนขับรถ 5 คน ในงานวิจัย [13] ได้มีการพูดถึงการระบุผู้ไม่พึงประสงค์ โดยในงานวิจัยนี้ได้ใช้การเรียนรู้ของเรื่องสุดขีด (Extreme Machine Learning) ในการระบุคนขับรถและผู้ไม่พึงประสงค์ ข้อมูลขาเข้านั้นมีจำนวน 8 ตัวซึ่งได้มาจากแคนประกอบกับตัวรับรู้อื่น สำหรับการระบุตัวคนขับรถนั้น งานวิจัยนี้สามารถทำความแม่นยำได้มากกว่า 80 เปอร์เซ็นต์ในทุกเงื่อนไข ทั้งยังทำความแม่นยำได้มากกว่า 90 เปอร์เซ็นต์สำหรับจำนวนคนขับรถ 2-3 คนอีกด้วย สำหรับการระบุผู้ไม่พึงประสงค์นั้นสามารถทำความแม่นยำได้มากกว่า 80 เปอร์เซ็นต์สำหรับสถานการณ์ที่มีคนขับรถแท้จริงคนเดียว แต่ค่าความแม่นยำนั้นลดลง

ถึงค่ามากกว่า 50 เปอร์เซนต์เมื่อจำนวนคนขับรถแท็กซี่จริงมีมากขึ้น ในงานวิจัย [15] ได้มีการเสนอให้ใช้ข้อมูลเฉพาะช่วงที่เกิดเหตุการณ์เร่งหรือหน่วงซึ่งมีการอธิบายวิธีการระบุช่วงดังกล่าวก่อนที่จะใช้ข้อมูลจากตัวรับรู้ในช่วงเวลานั้นในการวิเคราะห์ ซึ่งประกอบไปด้วย ระยะเวลาของเหตุการณ์ ความเร็ว ความเร่ง เจริค และเส้นทาง ข้อมูลทางสถิติเหล่านี้จะถูกนำไปสกัดพีเจอร์เพื่อใช้ในการวิเคราะห์จำแนกประเภทเส้นตรง (LDA : Linear Discriminant Analysis) โดยมีความแม่นยำในการระบุตัวคนขับรถที่มากกว่า 80 เปอร์เซนต์ ในงานวิจัย [20] ได้มีการทำการทดลองระบุตัวคนขับรถจากข้อมูลแค่นและได้ความแม่นยำมากถึง 99 เปอร์เซนต์ อย่างไรก็ตามในงานวิจัยนี้ไม่ได้กล่าวรายละเอียดเกี่ยวกับการสกัดพีเจอร์และใช้ข้อมูลการขับรถเพียง 23 ชั่วโมงเท่านั้น งานวิจัย [19] ใช้ข้อมูลเปิดจำนวน 3 กลุ่มข้อมูลเพื่อทำการทดสอบการระบุตัวคนขับรถ และมีการทดสอบเวลาในการฝึกฝนและทดสอบเพื่อให้ได้ความแม่นยำที่น่าพอใจอีกด้วย นอกเหนือจากการใช้ข้อมูลจากแค่นแล้วยังมีงานวิจัยที่เสนอการระบุตัวคนขับรถโดยใช้ลักษณะข้อมูลที่แตกต่างออกไป [17] โดยแทนที่จะใช้ข้อมูลเชิงเวลา งานวิจัยนี้ได้ใช้ข้อมูลซึ่งขึ้นกับการเดินทางที่เก็บข้อมูลจากตัวเก็บข้อมูลภายในรถ (In-Vehicle Data Recorder) ตัวอย่างข้อมูลการเดินทางที่ใช้ เช่น วัน เวลาออกเดินทาง เวลาที่ใช้ในการเดินทาง จำนวนผู้โดยสาร จำนวนเหตุการณ์ เป็นต้น งานวิจัยนี้ได้ใช้การเรียนรู้ของเครื่องแบบสายท่อ (Machine Learning Pipeline) ทำให้ได้ความแม่นยำถึง 88 เปอร์เซนต์

จะเห็นได้ว่าการใช้ข้อมูลจากแค่นซึ่งมีหลายตัวรู้นั้นสามารถให้ค่าความแม่นยำที่สูงได้ อย่างไรก็ตามยังมีรถจำนวนมากที่ไม่สามารถดึงข้อมูลตัวรับรู้ผ่านระบบแค่นได้ เพื่อให้กระบวนการพัฒนาและนำไปใช้งานจริงทำได้ง่าย การใช้ตัวรู้น้อยแต่ได้ความแม่นยำสูงจึงเป็นที่น่าสนใจ ที่ผ่านมาก็มีงานวิจัยที่พยายามจะใช้ข้อมูลจากตัวรับรู้เพียงตัวเดียว [8, 18] สำหรับงานวิจัย [8] ได้นำเสนอการระบุตัวคนขับรถโดยใช้เพียงข้อมูลจากตัวรับรู้ความเร่งในสมาร์ตโฟนโดยสามารถทำความแม่นยำได้สูงสุดถึง 100 เปอร์เซนต์ สำหรับงานวิจัย [18] ได้เสนอวิธีการระบุตัวคนขับรถโดยใช้เพียงข้อมูลจากตัวรับรู้ตำแหน่งในสมาร์ตโฟนและทำความแม่นยำได้ประมาณ 82.3 เปอร์เซนต์ แต่เนื่องจากทั้งสองงานนี้เกี่ยวข้องโดยตรงกับงานวิจัยของผู้เขียน เนื่องจากใช้ข้อมูลจากตัวรับรู้เพียงตัวเดียวเหมือนกัน รายละเอียดของงานทั้งสองนี้จะขอกกล่าวโดยละเอียดอีกครั้งในส่วนงานวิจัยที่เกี่ยวข้อง (หัวข้อ 2.2)

ในงานวิจัยนี้ ผู้เขียนได้เสนอระบบการระบุตัวคนขับรถโดยใช้ข้อมูลจากตัวรับรู้ความเร่งเพียงอย่างเดียวโดยใช้ฮิสโทแกรมเป็นพีเจอร์และเป็นข้อมูลขาเข้าสู่โครงข่ายประสาทเทียม การใช้ตัวรับรู้เพียงตัวเดียวและระบบที่ไม่ซับซ้อนนี้ทำให้สามารถนำไปติดตั้งในรถยนต์ชนิดใดก็ได้โดยง่าย นอกจากนี้ยังมีการเสนอการกรองข้อมูลช่วงระยะพักของรถออกซึ่งส่งผลต่อประสิทธิภาพเป็นอย่างมากสำหรับการใช้งานในรถโดยสารสาธารณะที่มีการหยุดรถบ่อย ๆ อันเป็นผลมาจากการที่ข้อมูลในช่วงที่รถหยุดนิ่งไม่ได้แสดงถึงพฤติกรรมในการขับรถ ระบบที่นำเสนอสามารถระบุคนขับรถด้วย

ความแม่นยำสูงสุดถึง 99 เปอร์เซ็นต์ทั้งนี้ค่าความแม่นยำนั้นขึ้นกับตัวแปรและการตั้งค่าหลายอย่าง งานวิจัยนี้ได้วัดประสิทธิภาพของระบบอย่างรอบด้านไม่ว่าจะเป็นการวัดประสิทธิภาพของการกรองข้อมูลระยะพัก ประสิทธิภาพของค่าหน้าต่างเลื่อนและการเลื่อน ประสิทธิภาพของการระบุคนขับรถที่จำนวนคนต่างกัน ประสิทธิภาพของตัวแยกประเภท ประสิทธิภาพของจำนวนข้อมูลที่ต่างกัน และรวมถึงประสิทธิภาพของระบบเมื่อใช้กับการระบุผู้ไม่พึงประสงค์อีกด้วย

1.2 วัตถุประสงค์ของการวิจัย

- 1) เพื่อพัฒนาระบบการระบุตัวคนขับรถโดยใช้ข้อมูลจากตัวรับรู้ความเร่ง
- 2) เพื่อศึกษาการใช้ฮิสโทแกรม (Histogram) ของความเร่งในการแสดงถึงพฤติกรรมคนขับรถที่แตกต่างกันในแต่ละบุคคล
- 3) เพื่อพัฒนาโครงข่ายประสาทเทียมในการทำนายคนขับรถจากฮิสโทแกรมของความเร่ง
- 4) เพื่อศึกษาประสิทธิภาพของระบบตามตัวแปรที่มีความสำคัญต่อการระบุตัวคนขับรถด้วยวิธีการใช้ฮิสโทแกรม

1.3 ขอบเขตของการวิจัย

- 1) การระบุคนขับรถคือการเลือกคนขับรถหนึ่งคนจากกลุ่มคนขับรถ 13 คนหรือน้อยกว่า
- 2) ข้อมูลในการทำวิจัยมาจากตัวรับรู้ที่ถูกติดตั้งบนรถโดยสารภายในจุฬาลงกรณ์มหาวิทยาลัย
- 3) ข้อมูลในการทำวิจัยเป็นข้อมูลจากรถซึ่งอยู่บนถนนบริเวณรอบ ๆ มหาวิทยาลัยเท่านั้น
- 4) รถโดยสารที่ทำการติดตั้งตัวรับรู้แต่ละคันมีคนขับรถประจำอยู่คนเดียว จึงอนุมานได้ว่าข้อมูลจากรถคันหนึ่ง ๆ มาจากคนขับคนเดียว
- 5) ข้อมูลในงานวิจัยประกอบด้วยเส้นทางการเดินทาง 3 เส้นทาง และมีคนขับรถ 13 คนกระจายกันประจำอยู่ในแต่ละเส้นทาง ไม่เคยเปลี่ยนเส้นทางของตนเอง
- 6) งานวิจัยไม่ได้ควบคุมตัวแปรเกี่ยวกับสภาพการจราจร ข้อมูลที่ทำการศึกษาจึงเป็นข้อมูลจากสภาพการจราจรที่แท้จริง
- 7) สร้างชุดคำสั่งเพื่อทดลองและวัดประสิทธิภาพด้วยภาษา R

1.4 คุณค่าทางวิชาการ

- 1) ระบบระบุตัวคนขับรถซึ่งใช้ข้อมูลจากตัวรับรู้ความเร่งเพียงอย่างเดียว สามารถพัฒนาเพื่อใช้งานจริงในรถโดยสารสาธารณะเพื่อใช้เป็นช่องทางการยืนยันตัวตนคนขับรถ

- 2) ระบบระบุตัวคนขับรถสามารถประยุกต์ใช้กับการตรวจจับโจรขโมยรถหรือการจี้รถได้
- 3) การระบุตัวคนขับรถสามารถนำไปประยุกต์ใช้ในเชิงธุรกิจประกันภัยได้
- 4) การระบุตัวคนขับรถสามารถนำไปประยุกต์ใช้เพื่อปรับแต่งคุณสมบัติต่าง ๆ ของรถยนต์โดยอัตโนมัติสำหรับรถยนต์ที่มีการใช้งานร่วมกันหลายคน
- 5) การวัดประสิทธิภาพของระบบในแง่มุมที่นำเสนอสามารถนำไปใช้เป็นแนวทางในการวัดประสิทธิภาพของระบบระบุตัวคนขับรถจริงหรืองานวิจัยในอนาคต

1.5 วิธีดำเนินการวิจัย

- 1) ศึกษาการระบุตัวคนขับรถด้วยการใช้ข้อมูลจากตัวรับรู้ภายในรถยนต์
- 2) ศึกษาตัวรับรู้สำหรับติดตั้งในรถยนต์
- 3) ออกแบบและสร้างอุปกรณ์สำหรับเก็บข้อมูลความเร่ง
- 4) ออกแบบและสร้างระบบสำหรับเก็บข้อมูล
- 5) ติดตั้งอุปกรณ์ภายในรถโดยสารประจำทางภายในจุฬาลงกรณ์มหาวิทยาลัย
- 6) ดำเนินการเก็บข้อมูล
- 7) ศึกษาลักษณะข้อมูลที่ได้รับ
- 8) ทำความสะอาดข้อมูล
- 9) ศึกษาความเป็นไปได้ในการใช้ฮิสโทแกรมของข้อมูลความเร่งเพื่อแยกแยะความแตกต่างพฤติกรรมในแต่ละบุคคล
- 10) สร้างโมเดลโครงข่ายประสาทเทียมเพื่อระบุตัวคนขับรถจากฮิสโทแกรมความเร่ง
- 11) ศึกษาตัวแปรที่มีความสำคัญต่อการระบุตัวคนขับรถ
- 12) สรุปผลการวิจัย

1.6 ผลงานตีพิมพ์

บทความชื่อ “Driver Identification Using Histogram and Neural Network from Acceleration Data” โดย Nuttun Virojboonkiate, Peerapon Vateekul และ Kultida Rojviboonchai ตีพิมพ์และนำเสนอในงานประชุมวิชาการชื่อ “2017 17th IEEE International Conference on Communication Technology (IEEE-ICCT 2017)”

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 ทฤษฎีที่เกี่ยวข้อง

2.1.1 ฮิสโทแกรม

เป็นแผนภาพที่แสดงให้เห็นถึงการกระจายตัวของข้อมูลโดยจะแสดงความถี่ของข้อมูลในแต่ละชนิดข้อมูลหรือช่วงข้อมูล โดยในแกนนอนจะแสดงถึงชนิดข้อมูลหรือช่วงของข้อมูล และแกนตั้งจะแสดงถึงความถี่หรือความถี่สัมพัทธ์ โดยความถี่สัมพัทธ์ (RF) สำหรับแต่ละชนิดข้อมูลหรือช่วงข้อมูลสามารถคำนวณดังแสดงในสมการที่ 2.1

$$RF = \frac{f}{n}$$

สมการที่ 2.1

เมื่อ RF คือ ความถี่สัมพัทธ์
f คือ ความถี่ในช่วง
n คือ จำนวนข้อมูล

2.1.2 การเรียนรู้ของเครื่อง (Machine Learning)

การเรียนรู้ของเครื่องคือการให้ชุดคำสั่งในคอมพิวเตอร์ทำงานเพื่อเรียนรู้บางสิ่งด้วยตัวเอง การเรียนรู้ของเครื่องอาจแบ่งกว้าง ๆ ได้เป็น 2 ลักษณะคือ การเรียนรู้แบบมีผู้สอน และการเรียนรู้แบบไม่มีผู้สอน สำหรับการเรียนรู้แบบมีผู้สอนจะต้องมีการให้ข้อมูลตัวอย่างเป็นข้อมูลขาเข้าและผลลัพธ์ของข้อมูลตัวอย่างนั้นเป็นข้อมูลขาออก และใช้ชุดคำสั่งบางอย่างเพื่อหาความสัมพันธ์ระหว่างข้อมูลขาเข้ากับข้อมูลขาออก ซึ่งวิธีโครงข่ายประสาทเทียมที่ใช้ในงานวิจัยนี้จะเป็นการเรียนรู้ของเครื่องแบบมีผู้สอน สำหรับการเรียนรู้ของเครื่องแบบไม่มีผู้สอนจะเป็นการหาความสัมพันธ์ระหว่างข้อมูลตัวอย่างเพื่อจัดกลุ่มข้อมูล ซึ่งจะมีการกล่าวถึงในงานวิจัยนี้เช่นกัน

2.1.3 การแบ่งประเภทข้อมูล (Statistical classification)

การแบ่งประเภทข้อมูลนั้นจัดเป็นการเรียนรู้ของเครื่องแบบมีผู้สอน ซึ่งอาจแบ่งได้เป็น 2 แบบคือ แบบทวิภาค (Binary classification) และแบบหลายประเภท (Multi-class classification) เนื่องจากคนขับรถในงานวิจัยนี้เปรียบได้กับประเภทข้อมูล และในงานวิจัยนี้มีคนขับรถมากกว่าสอง

คน ดังนั้นงานวิจัยนี้จึงจัดเป็นการแบ่งประเภทข้อมูลหลายประเภทซึ่งคือการระบุว่าข้อมูลที่เข้ามานั้น เป็นข้อมูลของคนขับรถคนใดนั่นเอง สำหรับวิธีการแบ่งประเภทข้อมูลหลายประเภทนั้นสามารถทำได้หลายวิธี เช่น ต้นไม้ตัดสินใจ โครงข่ายประสาทเทียม ซัพพอร์ตเวกเตอร์แมชชีน เป็นต้น

2.1.4 โครงข่ายประสาทเทียม

โครงข่ายประสาทเทียมเป็นวิธีการหนึ่งที่สามารถใช้แก้ปัญหาการแบ่งประเภทข้อมูลหลายประเภทได้ ชื่อของโครงข่ายประสาทเทียมนั้นมาจากการเลียนแบบลักษณะการทำงานของโครงข่ายประสาทในสมองมนุษย์ซึ่งมีปมประสาทจำนวนมากสื่อสารกัน โครงข่ายประสาทเทียมโดยทั่วไปมักจะประกอบด้วยชั้นขาเข้า (Input Layer) ชั้นซ่อน (Hidden Layer) และชั้นขาออก (Output Layer) ในแต่ละชั้นจะมีปม (Node) อยู่จำนวนหนึ่งซึ่งในแต่ละชั้นอาจมีจำนวนเท่ากันหรือแตกต่างกันก็ได้ แต่ละปมจะมีเส้นเชื่อมไปยังทุก ๆ ปมในชั้นที่ติดกัน เส้นเชื่อมเหล่านี้จะมีค่าประจำตัวอยู่ ซึ่งจะถูกเปลี่ยนไปเรื่อย ๆ เมื่อทำการป้อนข้อมูลฝึกฝน ค่าประจำเส้นเชื่อมจะถูกเปลี่ยนไปเพื่อให้ผลลัพธ์ตรงกับข้อมูลขาออกที่ต้องการมากที่สุด

2.1.5 อัลกอริทึมการค้นหาเพื่อนบ้านใกล้สุด k ตัว (k -nearest neighbors algorithm)

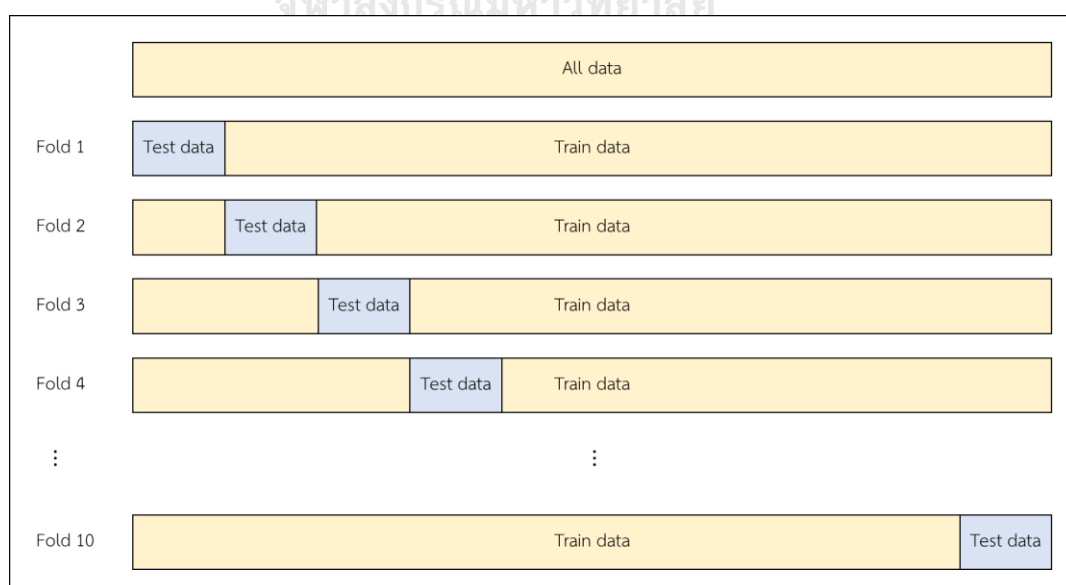
เป็นอีกวิธีการหนึ่งที่สามารถใช้แก้ปัญหาการแบ่งประเภทข้อมูลหลายประเภทได้ โดยมีหลักการทำงานที่มาสารถเข้าใจได้ง่าย กล่าวคือ สำหรับทุกแถวข้อมูลในข้อมูลฝึกฝน ทำการหา ระยะทางไปยังแถวข้อมูลที่ต้องการหาคำตอบ โดยในการหาระยะทางนั้นมีหลายวิธี เช่น ระยะทางแบบยูคลิด โคซายน์ หรือ มินคอฟสกี เป็นต้น เมื่อได้ระยะทางแล้วให้พิจารณาเฉพาะแถวข้อมูลที่มี ระยะทางใกล้สุด k ตัวเท่านั้นเรียกว่าเพื่อนบ้านใกล้สุด k ตัว ทดท้ายให้เลือกคำตอบจากชนิดของ ข้อมูลที่มีจำนวนมากที่สุดในเพื่อนบ้านที่ใกล้สุด k ตัวนั้น

อัลกอริทึม 2.1 การค้นหาเพื่อนบ้านใกล้สุด k ตัว

Input:	train data <i>train</i> test observation <i>test</i> variable k of kNN k
Output:	for each <i>train_obsv</i> in <i>train</i> do:
1:	<i>dist_list</i> \leftarrow find distance from <i>test</i> to <i>train_obsv</i>
2:	end for
3:	<i>knn_list</i> \leftarrow find k minimum in <i>dist_list</i>
4:	return majority type in <i>knn_list</i>

2.1.6 การตรวจสอบไขว้แบบ 10 พับ (10-Fold Cross Validation)

เป็นวิธีการแบ่งข้อมูลสำหรับใช้ในการฝึกฝนและทดสอบระบบวิธีหนึ่ง โดยจะแบ่งข้อมูลทั้งหมดเป็น 10 ส่วนสำหรับทดสอบทั้งหมด 10 ครั้ง โดยหนึ่งส่วนจะเป็นข้อมูลสำหรับทดสอบ ที่เหลืออีก 9 ส่วนจะเป็นข้อมูลสำหรับฝึกฝน ในการตรวจสอบแต่ละครั้งจะใช้ข้อมูลทดสอบเปลี่ยนไปเรื่อย ๆ เป็นจำนวน 10 ครั้ง ทำให้สามารถบริหารข้อมูลทั้งหมดไว้สำหรับทดสอบได้โดยไม่มีข้อมูลทดสอบและข้อมูลฝึกฝนทับซ้อนกัน ภาพที่ 2.1 แสดงลักษณะการแบ่งข้อมูลด้วยวิธีการตรวจสอบไขว้แบบ 10 พับ



ภาพที่ 2.1 แสดงการแบ่งข้อมูลด้วยวิธีการตรวจสอบไขว้แบบ 10 พับ

2.1.7 ค่าพรีซีชัน รีคอล และเอฟวัน (precision, recall, and f1 score)

ในการวัดประสิทธิภาพของการแบ่งประเภทข้อมูล นอกจากมาตรวัดที่รู้จักกันโดยทั่วไปอย่างค่าความแม่นยำแล้ว ยังมีมาตรวัดสำคัญอีก 3 ค่าคือ ค่าพรีซีชัน รีคอล และเอฟวัน โดยทั้ง 3 ค่าจะเป็นค่าที่วัดประจำประเภทของข้อมูล เพื่อให้เข้าใจถึงการคำนวณของแต่ละมาตรวัด ผู้เขียนขอแสดงคอนฟิวชันเมทริกซ์ซึ่งเป็นตารางแสดงถึงความสัมพันธ์ของจำนวนข้อมูลที่ถูกทำนายในแต่ละประเภทกับค่าตอบจริงของข้อมูลในแต่ละประเภท ในตารางที่ 2.1 เมื่อเข้าใจถึงคอนฟิวชันเมทริกซ์แล้วจะทำให้เข้าใจค่าพรีซีชันได้ดีขึ้นซึ่งสามารถคำนวณดังสมการที่ 2.2 เช่นเดียวกับรีคอลซึ่งสามารถคำนวณได้ดังสมการที่ 2.3 และค่าเอฟวันได้แสดงวิธีคำนวณในสมการที่ 2.4 มาตรวัดทั้ง 3 ค่านี้ทำให้ทราบถึงประสิทธิภาพในการทำนายโดยเฉพาะสำหรับแต่ละประเภทข้อมูลซึ่งมีความสำคัญอย่างมากสำหรับการระบุตัวผู้ไม่พึงประสงค์ เนื่องจากหากพิจารณาประสิทธิภาพในทุกประเภทร่วมกันอาจได้ผลดี ในขณะที่ประเภทของผู้ไม่พึงประสงค์นั้นอาจได้ผลไม่ดีนัก

ตารางที่ 2.1 แสดงคอนฟิวชันเมทริกซ์พื้นฐาน

Total population		True condition	
		Condition positive	Condition negative
Predicted condition	Predicted condition positive	True positive	False positive
	Predicted condition negative	False negative	True negative

CHULALONGKORN UNIVERSITY

$$Precision = \frac{\Sigma \text{ True positive}}{\Sigma \text{ Predicted condition positive}} \quad \text{สมการที่ 2.2}$$

เมื่อ Precision คือ ค่าพรีซีชัน
 True positive คือ ข้อมูลที่ทำนายถูกในประเภานั้น
 Predicted condition positive คือ ข้อมูลที่ทำนายในประเภานั้น

$$Recall = \frac{\Sigma \text{ True positive}}{\Sigma \text{ Condition positive}} \quad \text{สมการที่ 2.3}$$

เมื่อ Recall คือ ค่ารีคอล
 True positive คือ ข้อมูลที่ทำนายถูกในประเภานั้น
 Condition positive คือ ข้อมูลในประเภานั้น

$$F1 \text{ score} = \frac{2}{\frac{1}{\text{Precision}} + \frac{1}{\text{Recall}}}$$

สมการที่ 2.4

เมื่อ	F1 score	คือ ค่าเอฟวัน
	Precision	คือ ค่าพรีซีชัน
	Recall	คือ ค่ารีคอลล

2.2 งานวิจัยที่เกี่ยวข้อง

ในหัวข้อนี้จะขออธิบายอย่างละเอียดเกี่ยวกับงานวิจัยที่ใช้ข้อมูลจากตัวรับรู้เพียงตัวเดียวเพื่อระบุตัวคนขับรถ เนื่องจากเป็นงานวิจัยที่เกี่ยวข้องกับงานวิจัยนี้โดยตรง ในงานวิจัย [18] ได้มีการนำข้อมูลจากสมาร์ทโฟนมาใช้ในการระบุตัวคนขับรถ โดยข้อมูลที่นำมาใช้นั้นเป็นข้อมูลจากตัวรับรู้ตำแหน่งเพียงอย่างเดียวเท่านั้น อย่างไรก็ตามข้อมูลจากตัวรับรู้ตำแหน่งนี้ได้ถูกใช้เพื่อคำนวณค่าอื่น ๆ เช่น ความเร็ว ความเร่ง เจริค และความเร็วเชิงมุม เป็นต้น จากนั้นข้อมูลทั้งหลายเหล่านี้จะถูกนำไปสกัดฟีเจอร์ โดยฟีเจอร์ที่ถูกใช้ในงานวิจัยนี้เป็นข้อมูลเชิงสถิติจากค่าเหล่านั้นเช่น ค่าเฉลี่ย มัชฐาน ความเบ้ ความโด่ง ค่าเบี่ยงเบนมาตรฐาน ค่ามากที่สุด ค่าน้อยสุด และ เปอร์เซ็นไทล์ที่บางค่า เป็นต้น จากนั้นใช้การวิเคราะห์ความแปรปรวน (ANOVA : Analysis of Variance) เพื่อตัดฟีเจอร์บางอย่างที่ไม่สำคัญออก หลังการวิเคราะห์แล้วมีการใช้ฟีเจอร์ทั้งหมด 137 ฟีเจอร์เพื่อเป็นข้อมูลขาเข้าสู่การแบ่งประเภทข้อมูลด้วยป่าสุ่ม (Random Forest) การทดลองนี้มีคนขับรถทั้งหมด 38 คน แต่มีการแบ่งคนขับรถตามตำแหน่งที่ขับรถและเวลาที่ขับรถเพื่อลดตัวแปรภายนอก เช่น สภาพการจราจร เป็นต้น ในงานวิจัยนี้ยังได้พูดถึงการใช้หน้าต่างเลื่อนและการเหลื่อมกันด้วย ซึ่งค่าความแม่นยำโดยเฉลี่ยในงานวิจัยนี้สามารถทำได้ที่ 82.3 เปอร์เซ็นต์สำหรับการระบุตัวคนขับรถที่มีจำนวนคนขับรถ 5 คน นอกจากนี้งานวิจัยนี้ยังมีการวิเคราะห์ทักษะและความก้าวร้าวในการขับรถที่มีผลต่อความแม่นยำในการระบุตัวคนขับรถ ทำให้ได้ข้อสรุปว่าคนขับรถที่มีทักษะสูงมักจะทำให้สามารถทำนายตัวคนขับรถคนนั้นได้แม่นยำมากขึ้น

ถึงแม้วิธีการที่กล่าวข้างต้นจะใช้เพียงข้อมูลจากตัวรับรู้ตำแหน่งเพียงอย่างเดียว แต่ยังมีการคำนวณค่าอื่นซึ่งเปรียบได้กับการใช้ตัวรับรู้อื่นอีกหลายตัว มิงงานวิจัยที่เสนอถึงการระบุตัวคนขับรถโดยใช้เพียงข้อมูลจากตัวรับรู้ความเร่งในสมาร์ทโฟนเพียงอย่างเดียว [8] ข้อมูลจากงานวิจัยนี้ถูกเก็บเป็นเวลา 3 เดือน โดยมีคนขับรถทั้งหมด 5 คน ข้อมูลความเร่งทั้งในแกนด้านหน้าและแกนด้านข้างถูกนำมาสรุปเป็นข้อมูลทางสถิติหลายค่า เช่น ค่าเฉลี่ย ค่าเบี่ยงเบนมาตรฐาน ค่าอนุพันธ์ และ สหสัมพันธ์ เป็นต้น ค่าทางสถิติของความเร่งเหล่านี้ถูกนำมาวิเคราะห์โดยการวิเคราะห์ตัวประกอบ

สำคัญ (PCA : Principle Component Analysis) เพื่อหาเฉพาะตัวแปรที่เหมาะสม ด้วยเกณฑ์ในการคัดเลือกตัวแปรที่แตกต่างกันและด้วยตัวแปรที่แตกต่างกัน มีบางวิธีที่สามารถทำนายคนขับรถได้ถูกต้องทั้ง 5 คน ผลจากงานวิจัยนี้แสดงถึงความเป็นไปได้ที่จะใช้เฉพาะข้อมูลความเร่งในการสร้างระบบระบุตัวคนขับรถ

นอกจากงานสองงานวิจัยนี้ ยังมีงานวิจัยที่ใช้ตัวรับรู้จากแค่นในการระบุตัวคนขับรถ ที่ได้อภิปรายถึงการใช้ตัวรับรู้ที่ดีที่สุดเพียงตัวเดียวเพื่อระบุตัวคนขับรถ ข้อมูลจากตัวรับรู้ นั่นคือข้อมูลตำแหน่งของคันเหยียบเบรกซึ่งเป็นข้อมูลที่แสดงถึงความเร่งได้ โดยได้ผลการทดลองว่าด้วยข้อมูลของตำแหน่งคันเหยียบเบรกเพียงอย่างเดียวก็สามารถระบุคนขับรถได้แม่นยำถึง 88.7 เปอร์เซ็นต์สำหรับข้อมูลการขับรถช่วงแรกและ 100 เปอร์เซ็นต์สำหรับข้อมูลการขับรถช่วงที่สอง รายละเอียดอื่น ๆ ของงานวิจัยชิ้นนี้ได้อธิบายแล้วในบทที่ 1.1 หัวข้อความเป็นมาและความสำคัญของปัญหา

เพื่อแสดงให้เห็นถึงความแตกต่างในแต่ละงานวิจัยที่ได้กล่าวมา รวมถึงความแตกต่างกับระบบที่เสนอในงานวิจัยนี้ ผู้เขียนได้แสดงตารางเปรียบเทียบไว้ใน

ตารางที่ 2.2 แสดงตารางเปรียบเทียบงานวิจัยที่เกี่ยวข้อง

งานวิจัย	ตัวรับรู้	เวลาในการเก็บข้อมูล	จำนวนคนขับรถ	ฟีเจอร์	การกรอกข้อมูลช่วงพัก	ตัวแปรประเภท	ความแม่นยำ (%)
งานวิจัยนี้	ความเร่งรถ	10 เดือน	3-13	ฮิสโทแกรมของความเร่ง	มี	NN	94-99
[8]	ความเร่งรถ	3 เดือน	5	ค่าทางสถิติของความเร่ง	ไม่มี	-	60-100
[18]	ตำแหน่งรถ	2 เดือน (1223 ชั่วโมง)	4-5	ค่าทางสถิติของตำแหน่ง ความเร็ว ความเร่ง และอื่น ๆ	ไม่มี	RF	~ 82.3
[11]	ตำแหน่งคันเบรก	ประมาณ 3 ชั่วโมงต่อคน	15	ฟีเจอร์ทางสถิติ ฟีเจอร์เชิงพรรณนา และฟีเจอร์เชิงความถี่	ไม่มี	RF	87-100

บทที่ 3


การระบุตัวคนขับรถ

3.1 ภาพรวมโครงสร้างของระบบ

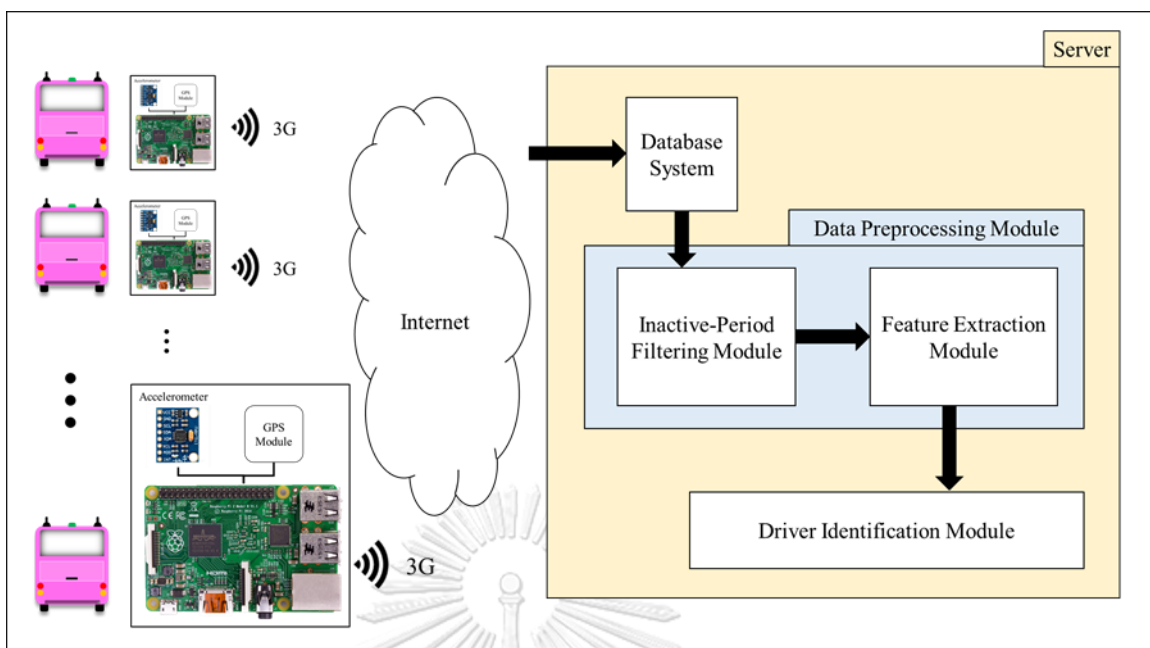
ระบบที่ใช้ในงานวิจัยนี้ประกอบจากอุปกรณ์หลายชิ้นจัดรวมกันเป็นกล่องเดียวเพื่อติดตั้งในรถโดยสารภายในมหาวิทยาลัย ทางผู้วิจัยได้ติดต่อกับบริษัทผู้จัดการรถโดยสารภายในจุฬาลงกรณ์มหาวิทยาลัยเพื่อติดตั้งอุปกรณ์เพื่อใช้ในงานวิจัยจำนวน 13 คัน ดังภาพที่ 3.1 โดยแรกเริ่มนั้นระบบนี้เกิดจากการศึกษาการสื่อสารระหว่างรถยนต์ (Vehicle to Vehicle Communication) ผ่านระบบการสื่อสารแบบ IEEE 802.11p ซึ่งจำเป็นต้องใช้อุปกรณ์สื่อสารของ Denso โดยระบบนี้มีราสพ์เบอร์รี่พาย (Raspberry Pi) เป็นศูนย์กลางของระบบที่คอยประมวลผลและสั่งการชุดคำสั่งต่าง ๆ นอกจากนี้ระบบยังมีแอคเซสพอยต์ไร้สาย (Wireless Access Point) และตัวแปลงสัญญาณ 3G สำหรับติดต่อสื่อสารแบบไร้สาย (Wireless Communication) สำหรับตัวรับรู้ที่ถูกติดตั้งในระบบทั้งหมดประกอบด้วย ตัวรับรู้ความเร่ง ตัวรับรู้อุณหภูมิ ตัวรับรู้แสง และตัวรับรู้ตำแหน่ง (GPS : Global Positioning System) ระบบทั้งหมดที่รวบรวมในกล่องซึ่งถูกติดตั้งในรถโดยสารแสดงในภาพที่ 3.2 อย่างไรก็ตามระบบที่ใช้สำหรับงานวิจัยนี้จะใช้เพียงบางส่วนของระบบดังกล่าว สำหรับโครงสร้างภาพรวมของระบบที่ใช้ในงานวิจัยนี้แสดงในภาพที่ 3.3 ซึ่งอาจแบ่งได้เป็น 3 ส่วนใหญ่คือ ส่วนการเก็บข้อมูล (Data collection module) ส่วนการเตรียมข้อมูล (Data preprocessing module) และส่วนการระบุตัวคนขับรถ (Driver identification module) ซึ่งทั้ง 3 ส่วนจะกล่าวถึงในหัวข้อถัดไปต่อไปนี้



ภาพที่ 3.1 รถโดยสารภายในจุฬาลงกรณ์มหาวิทยาลัยซึ่งใช้ในงานวิจัยนี้




ภาพที่ 3.2 กล่องรวมอุปกรณ์ทั้งหมดซึ่งประกอบด้วย ราสพ์เบอร์รี่พาย ตัวรับรู้ความเร่ง



ภาพที่ 3.3 ภาพรวมโครงสร้างของระบบ

3.2 ส่วนการเก็บข้อมูล

ส่วนการเก็บข้อมูลถูกแสดงในภาพที่ 3.4 ประกอบด้วยส่วนสำคัญคือ รางสพเบอร์รี่พาย ตัวรับรู้ความเร่ง ตัวรับรู้ตำแหน่ง และอุปกรณ์สำหรับสื่อสารแบบไร้สาย สำหรับตัวรับรู้ความเร่งในงานวิจัยนี้ใช้แผงวงจรอิเล็กทรอนิกส์ MPU-6050 ที่สามารถรับรู้ความเร่งได้ตั้งแต่ $-2g$ ถึง $2g$ โดยมีความรับรู้ที่ระดับ 16384 LSB/g ตัวรับรู้ตำแหน่งทำให้ทราบตำแหน่งของรถอย่างทันที โดยในงานวิจัยนี้จะใช้ตัวรับรู้ตำแหน่งในการเตรียมข้อมูลเท่านั้น เนื่องจากในการระบุตัวคนขับรถจะใช้เพียงข้อมูลจากตัวรับรู้ความเร่ง ตัวรับรู้ทั้งสองจะถูกประมวลผลโดยรางสพเบอร์รี่พายและถูกจำกัดความถี่ไว้ที่ 90 เฮิรตซ์ ซึ่งเป็นความถี่สูงสุดที่อุปกรณ์ทั้งหมดสามารถทำงานได้ปกติ ข้อมูลทุกอย่างจะถูกส่งโดยใช้สัญญาณ 3G ไปยังเครื่องแม่ข่าย (Server) โดยจะเก็บข้อมูลลงบนฐานข้อมูลมาเรีย (MariaDB)

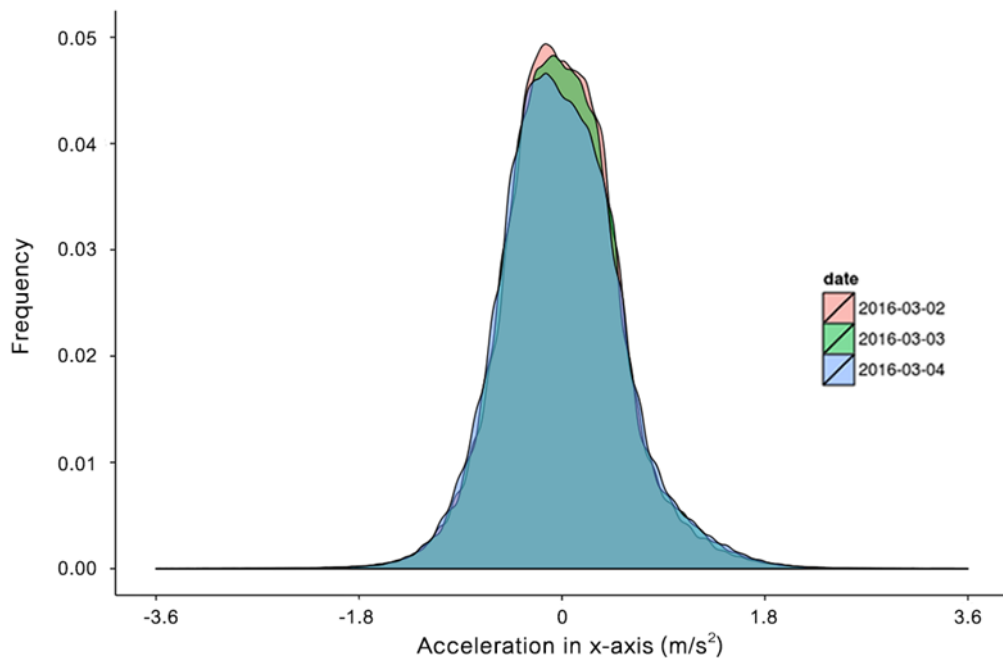


ภาพที่ 3.4 ส่วนเก็บข้อมูล


3.3 ส่วนการเตรียมข้อมูล

3.3.1 การศึกษาข้อมูลเบื้องต้น

มีงานวิจัยที่พูดถึงพฤติกรรมในการเร่งเครื่องยนต์ขณะขับรถที่แตกต่างกันในแต่ละบุคคล [22] โดยในช่วงเวลาหนึ่งบุคคลหนึ่งมักใช้ความเร็วในช่วงที่แตกต่างกันเป็นระยะเวลาโดยเฉลี่ยไม่เท่ากัน เพื่อให้ง่ายต่อความเข้าใจและเพื่อเป็นการยืนยันข้อเท็จจริงดังกล่าว ผู้เขียนได้ทดลองใช้ข้อมูลความเร็วบางส่วนมาสร้างฮิสโทแกรม โดยมีทั้งข้อมูลจากวันที่แตกต่างกันและข้อมูลจากคนขับรถคนที่แตกต่างกัน อย่างไรก็ตามข้อมูลความเร็วนั้นมีทั้งในแกนด้านหน้า ด้านข้าง และด้านบน ในเบื้องต้นนี้ ผู้เขียนจะอธิบายเฉพาะความเร็วในแกนด้านหน้าซึ่งเป็นแกนที่สำคัญที่สุดและน่าจะแสดงถึงพฤติกรรมในการขับรถมากที่สุด ฮิสโทแกรมในขั้นตอนนี้หนึ่งกราฟสร้างจากข้อมูลความเร็วจำนวนสองชั่วโมงในวันเดียวกันของคนขับรถหนึ่งคน ภาพที่ 3.5 แสดงถึงฮิสโทแกรมของข้อมูลความเร็วดังกล่าวจำนวน 3 กราฟซ้อนกันซึ่งมาจากคนละวันหากแต่เป็นคนขับรถคนเดิม จากภาพที่ 3.5 จะเห็นว่ากราฟทั้ง 3 ที่ซ้อนกันมีลักษณะคล้ายกัน แตกต่างจากภาพที่ 3.6 ซึ่งเป็นฮิสโทแกรมของคนขับรถต่างคนกัน ถึงแม้จะมาจากข้อมูลวันเดียวกันก็ยังคงมีความแตกต่างกันอย่างเห็นได้ชัด ภาพทั้งสองนี้แสดงให้เห็นว่าฮิสโทแกรมของข้อมูลความเร็วมีแนวโน้มจะแยกแยะพฤติกรรมในการขับรถที่แตกต่างกันในแต่ละบุคคลได้ ซึ่งผู้เขียนจะใช้ข้อมูลฮิสโทแกรมของความเร็วนี้ในการสร้างระบบระบุคนขับรถต่อไป



ภาพที่ 3.5 แสดงฮิสโทแกรมของคนขับรถคนเดียวกันในวันต่าง ๆ จำนวน 3 วัน




ภาพที่ 3.6 แสดงฮิสโทแกรมของคนขับรถจำนวน 3 คนจากข้อมูลในวันเดียวกัน


นอกจากฮิสโทแกรมจะบ่งบอกถึงความแตกต่างของพฤติกรรมในการขับรถแล้ว ฮิสโทแกรมยังสามารถสื่อถึงความก้าวร้าวหรือความรุนแรงในการขับรถได้อีกด้วย จากภาพที่ 3.6 จะเห็นว่าคนขับรถหมายเลข 1 นั้นมีความถี่สูงในช่วงกลางของกราฟซึ่งเป็นช่วงที่มีความเร่งต่ำหรืออาจกล่าวได้ว่า

ว่ามีความเร็วค่อนข้างสม่ำเสมอ นอกจากนี้ยังมีความถี่น้อยกว่าคนขับรถคนอื่นในช่วงที่มีความเร่งสูงหรือต่ำมาก (ช่วงปลายทั้งสองของกราฟ) ซึ่งหมายถึงมีการเร่งเครื่องหรือเบรกอย่างรุนแรง ดังนั้นอาจกล่าวได้ว่าคนขับรถหมายเลข 1 นี้มีพฤติกรรมการขับรถที่รุนแรงน้อยกว่าคนอื่น


เพื่อแสดงให้เห็นถึงความแตกต่างของพฤติกรรมดังกล่าว ผู้เขียนพยายามจะแบ่งกลุ่มคนขับรถโดยใช้การแบ่งกลุ่มข้อมูลแบบเคมีน (k-means clustering) โดยใช้ฮิสโทแกรมเป็นพีเจอร์จากการใช้ค่า k ที่แตกต่างกันพบว่าค่า k ที่เหมาะสมคือค่า k เท่ากับ 4 เนื่องจากเมื่อใช้ค่าที่น้อยลงทำให้แบ่งกลุ่มคนขับรถได้น้อยลง เช่นค่า k เท่ากับ 3 จะสามารถแบ่งกลุ่มได้ 2 กลุ่มเท่านั้น และการใช้ค่า k ที่มากขึ้นพบว่าจะสามารถแบ่งกลุ่มคนขับรถได้ 3 กลุ่มเสมอ ดังนั้นผู้เขียนจึงเลือกใช้ค่า k เป็น 4 และสามารถแบ่งคนขับรถได้ 3 กลุ่ม ส่วนอีกกลุ่มนั้นมีฮิสโทแกรมอยู่บ้างแต่ไม่ได้เป็นจำนวนส่วนมากของคนขับรถคนใด ตัวอย่างฮิสโทแกรมในแต่ละกลุ่มแสดงในภาพที่ 3.7 จากภาพจะเห็นว่ากลุ่ม 1 นั้นเป็นการขับรถที่มีพฤติกรรมรุนแรงน้อยที่สุด เนื่องจากมีค่าความเร่งที่ใกล้ศูนย์เป็นความถี่จำนวนมาก ส่วนกลุ่ม 2 นั้นเป็นการขับรถที่มีพฤติกรรมรุนแรงมากขึ้น และกลุ่ม 3 นั้นเป็นกลุ่มที่มีพฤติกรรมรุนแรงมากที่สุด ส่วนฮิสโทแกรมในกลุ่ม 4 นั้นมีจำนวนน้อยและเป็นฮิสโทแกรมซึ่งสื่อถึงพฤติกรรมการขับรถที่รุนแรงมาก เป็นไปได้ว่าในแต่ละวันหรือแต่ละช่วงเวลาคนขับรถคนเดิมอาจมีพฤติกรรมที่ต่างไปจากปกติซึ่งอาจเป็นผลมาจากอารมณ์หรือสภาพการจราจร ในกรณีที่การขับรถมีพฤติกรรมรุนแรงมากอาจทำให้ฮิสโทแกรมนั้นถูกจัดกลุ่มอยู่ในกลุ่มที่ 4




(ก) กลุ่มที่ 1



(ข) กลุ่มที่ 2



(ค) กลุ่มที่ 3



(ง) กลุ่มที่ 4

ภาพที่ 3.7 แสดงตัวอย่างฮิสโทแกรมในกลุ่มต่าง ๆ

3.3.2 ส่วนการกรองช่วงระยะพัก (Inactive period filtering module)

ขณะเริ่มทำการวิจัยข้อมูลจากตัวรับรู้ถูกเก็บมาเป็นเวลากว่า 10 เดือน ในช่วงแรกของการสร้างระบบระบุตัวคนขับรถยังไม่มีการใช้งานส่วนการกรองช่วงพัก การออกแบบการทดลองและผลสำเร็จของการทดลองในช่วงแรกแสดงในภาคผนวก ก เพื่อเพิ่มประสิทธิภาพของระบบ หลังจากการตรวจสอบข้อมูลในเชิงเวลา ผู้เขียนพบว่ามีข้อมูลจำนวนมากที่ถูกบันทึกขณะที่ตำแหน่งของรถยนต์ไม่มีการเปลี่ยนแปลงซึ่งอาจเกิดจากการจอดรถรับผู้โดยสารหรืออาจเกิดจากสภาพการจราจรที่ย่ำแย่ ไม่ว่าจะเกิดจากกรณีใดก็ตามข้อมูลในช่วงนี้เป็นข้อมูลที่คนขับรถไม่ได้แสดงพฤติกรรมใด ๆ ผ่านข้อมูลความเร่งเลยจึงไม่ควรนำมาวิเคราะห์ด้วยเช่นกัน ด้วยเหตุนี้ผู้เขียนจึงกรองข้อมูลโดยพิจารณาข้อมูลตำแหน่งของรถยนต์ที่ไม่มีการเปลี่ยนแปลงเป็นระยะเวลาหนึ่งเพื่อทิ้งข้อมูลความเร่งในช่วงนี้ สำหรับข้อมูลในงานวิจัยนี้ ระยะเวลาที่เหมาะสมคือประมาณห้าวินาทีซึ่งได้มาจากการพิจารณาการกระจายตัวของจำนวนข้อมูลที่ตำแหน่งรถไม่เปลี่ยนแปลง รายละเอียดวิธีละทิ้งข้อมูลช่วงระยะพักแสดงในอัลกอริทึม 3.1 การกรองนี้ทำให้เกิดการลบข้อมูลออกถึง 70 เปอร์เซ็นต์ ข้อมูลการขับรถหลังจากการละทิ้งข้อมูลส่วนนี้แล้วผู้เขียนขอเรียกว่าเป็นข้อมูลการขับรถอย่างกระตือรือร้น (Active Driving Data)

อัลกอริทึม 3.1 แสดงวิธีการกรองข้อมูลช่วงระยะพัก

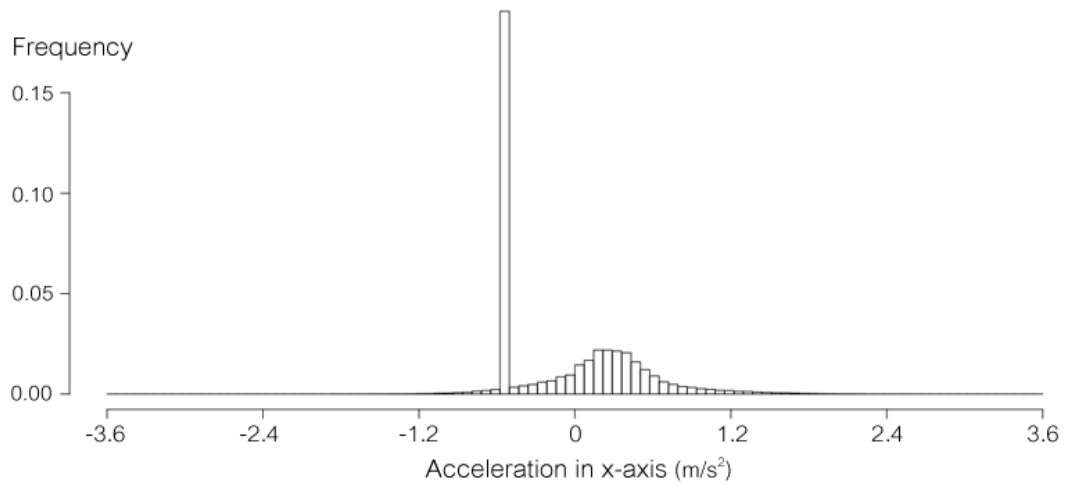
Input:	acceleration <i>acc_raw</i> , latitude <i>lat</i> , longitude <i>lng</i>
Output:	acceleration (without inactive period) <i>acc</i>
1:	for each <i>acc_raw</i> do :
2:	Initialize <i>next_lat</i> to next five-second of <i>lat</i>
3:	Initialize <i>roc_lat</i> to $(next_lat - lat) / lat$
4:	Initialize <i>next_lng</i> to next five-second of <i>lng</i>
5:	Initialize <i>roc_lng</i> to $(next_lng - lng) / lng$
6:	if <i>roc_lat</i> is zero and <i>roc_lng</i> is zero do :
7:	remove <i>acc_raw</i>
8:	end if
9:	end for
10:	return <i>acc_raw</i> as <i>acc</i>

3.3.3 ส่วนการสกัดฟีเจอร์ (Feature extraction module)

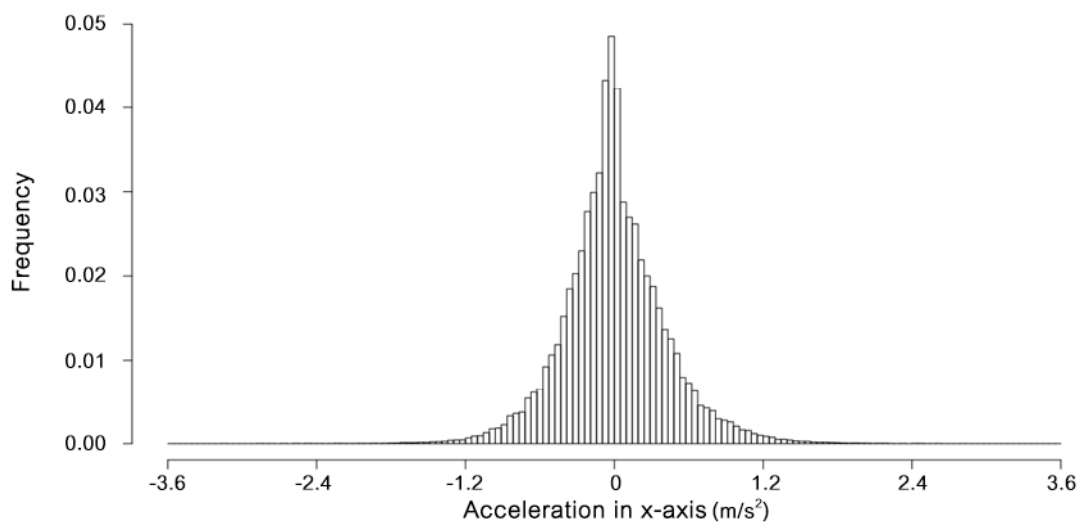
เนื่องจากข้อมูลการขับรถเป็นข้อมูลเชิงเวลา แต่ฮิสโทแกรมนั้นเป็นข้อมูลเชิงสถิติ การเลือกช่วงเวลาในการขับรถมาสร้างเป็นฮิสโทแกรมจึงเป็นสิ่งที่ควรคำนึงถึง ในที่นี้ก็คือขนาดของหน้าต่างเลื่อน (Sliding Window Size) และการเหลื่อม (Overlapping) โดยขนาดหน้าต่างเลื่อนควรมีขนาดที่เหมาะสมทั้งต่อผลการทดลองและต่อการใช้งานจริง ในงานวิจัยนี้มีการทดลองเพื่อหาขนาดหน้าต่างเลื่อนที่เหมาะสมตั้งแต่ 15 นาทีถึง 2 ชั่วโมง รวมถึงใช้ช่วงเวลาการเหลื่อมที่แตกต่างกันด้วย รายละเอียดและผลการทดลองของขนาดหน้าต่างเลื่อนและการเหลื่อมจะกล่าวโดยละเอียดอีกครั้งในบทที่ 4 กระบวนการทั้งหมดนี้ควรทำก่อนการสร้างฮิสโทแกรมเพื่อให้สามารถควบคุมตัวแปรเกี่ยวกับระยะเวลาในการขับรถได้ง่ายขึ้น

สำหรับฮิสโทแกรมจะต้องมีการตั้งค่าที่แน่นอนเพื่อให้ฮิสโทแกรมทุกกราฟสามารถเปรียบเทียบกันได้อย่างเท่าเทียม ผู้เขียนได้ตั้งค่าฮิสโทแกรมไว้ที่ 100 แห่ง โดยกำหนดค่าต่ำสุดและสูงสุดไว้ที่ -3.6 m/s^2 ถึง 3.6 m/s^2 ตามลำดับ การตั้งค่าเช่นนี้จะทำให้ได้เส้นแนวโน้มที่ไม่หยابจนเกินไปและไม่บริโภครทรัพยากรในการคำนวณของคอมพิวเตอร์จนเกินควร การเลือกค่าต่ำสุดและสูงสุดดังกล่าวเป็นค่าขอบสูงสุดและต่ำสุดเฉลี่ยโดยประมาณของข้อมูลโดยรวม นอกจากนี้ฮิสโทแกรมจะถูกปรับให้มีค่าความถี่รวมเป็นค่าที่เท่ากันในแต่ละฮิสโทแกรมโดยค่าในแต่ละแห่งของฮิสโทแกรมจะเป็นค่าที่คำนวณจากสัดส่วนของค่าในแห่งนั้นต่อผลรวมจากทุกแห่ง กล่าวอีกนัยหนึ่งคือเป็นการเปลี่ยนจากหน่วยความถี่เป็นหน่วยความหนาแน่นทำให้ผลรวมของค่าในทุก ๆ แห่งของ ทุก ๆ ฮิสโทแกรมมีค่าเป็นหนึ่งเสมอ การตั้งค่าฮิสโทแกรมไม่จำเป็นต้องทำตามนี้เสมอไปเพียงแต่จะต้องมีการตั้งค่าที่แน่นอนเพื่อให้สามารถเปรียบเทียบได้อย่างเท่าเทียม

เมื่อสุ่มพิจารณาฮิสโทแกรมบางส่วนที่สร้างขึ้น ผู้เขียนพบว่าฮิสโทแกรมจำนวนหนึ่งที่เกิดความผิดพลาดขึ้นดังภาพที่ 3.8 ซึ่งจะเห็นได้ว่าในฮิสโทแกรมนี้มีบางช่วงความเร่งที่มีความถี่สูงกว่าปกติมาก ในข้อนี้ผู้เขียนสันนิษฐานว่าเกิดจากตัวรับรู้หรือหน่วยประมวลผลมีปัญหาทำให้ข้อมูลเกิดค้างและบันทึกค่าเดิมซ้ำเป็นเวลานาน ไม่ว่าจะเกิดจากปัญหาใดก็ตามฮิสโทแกรมนี้ไม่ควรนำมาวิเคราะห์ร่วม แต่เพื่อเป็นการรักษาจำนวนข้อมูลไว้ให้ได้มากที่สุด ผู้เขียนใช้วิธีการลบเฉพาะค่าความเร่งที่มีการบันทึกซ้ำเป็นเวลานานออกแทน เมื่อทำตามขั้นตอนนี้แล้วจะได้ฮิสโทแกรมดังภาพที่ 3.9 ซึ่งสามารถนำไปใช้ในการวิเคราะห์ต่อได้



ภาพที่ 3.8 ตัวอย่างฮิสโทแกรมที่เกิดความผิดพลาด



ภาพที่ 3.9 ตัวอย่างฮิสโทแกรมที่แก้ไขความผิดพลาดแล้ว

สำหรับข้อมูลทั้งหมดเป็นเวลากว่า 10 เดือน สามารถแปลงเป็นฮิสโทแกรมได้จำนวนกว่าหมื่นกราฟในแต่ละแกน (ขึ้นกับขนาดหน้าต่างเคลื่อนและการเหลื่อม) เพื่อให้เห็นภาพของข้อมูลที่ชัดเจนมากขึ้น ผู้เขียนได้แสดงลักษณะของไฟล์ที่ได้จากการทำความสะอาดข้อมูลดังที่กล่าวมาดังภาพที่ 3.10 ซึ่งประกอบไปด้วยค่าในแต่ละแห่งของฮิสโทแกรมและป้ายชื่อเพื่อบอกคนขับรถที่เป็นเจ้าของฮิสโทแกรม ณ ช่วงเวลานั้น

	Bin 1	Bin 2	Bin 3	Bin 4	Bin 5	...	Bin 99	Bin 100	Driver
Histogram 1									
Histogram 2									
Histogram 3									
Histogram 4						...			
Histogram 5									
Histogram 6									
Histogram 7									

(13 Class)


ภาพที่ 3.10 แสดงลักษณะไฟล์ที่ได้จากการทำความสะอาดข้อมูล

3.4 โมเดลโครงข่ายประสาทเทียม

ฮิสโทแกรมที่ได้หลังจากการเตรียมข้อมูลในหัวข้อที่แล้วจะถูกใช้เป็นข้อมูลนำเข้าของชุดคำสั่งการเรียนรู้ของเครื่องซึ่งในที่นี้จะใช้โครงข่ายประสาทเทียม อย่างไรก็ตามยังมีการเรียนรู้ของเครื่องแบบอื่นอีกที่สามารถใช้งานกับข้อมูลการขับรถได้เช่นกัน ดังนั้นควรมีการทดสอบเพื่อเลือกการเรียนรู้ของเครื่องที่เหมาะสม โดยรายละเอียดและผลการทดสอบจะกล่าวอีกครั้งในบทที่ 4

สำหรับโมเดลโครงข่ายประสาทเทียมที่ใช้ในงานวิจัยนี้มี 3 ชั้นคือ ชั้นขาเข้า ชั้นซ่อน และชั้นขาออก สำหรับการตั้งค่าในแต่ละชั้นมีดังนี้

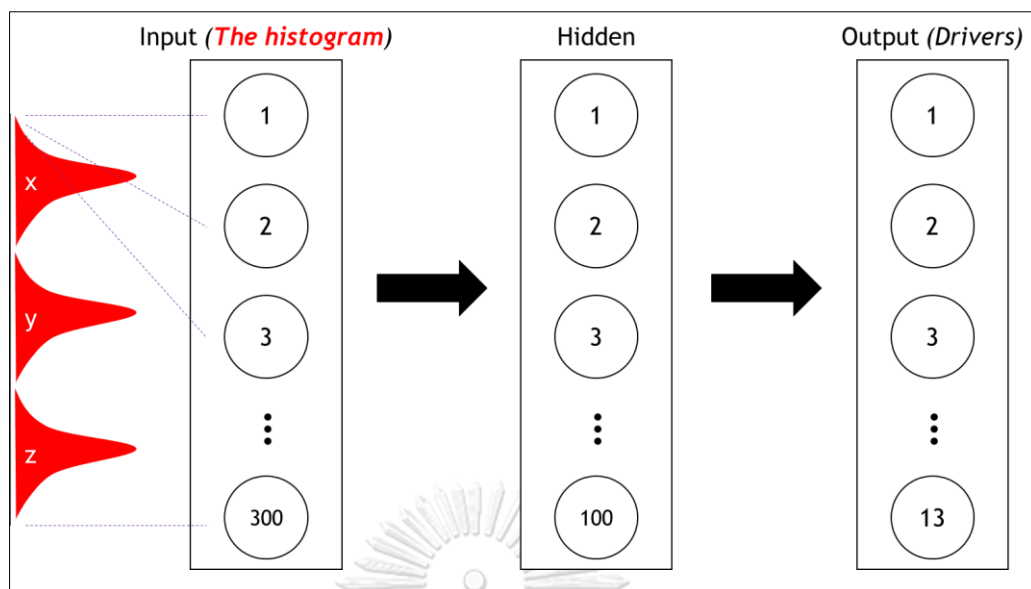
- ชั้นขาเข้ามีจำนวนปมทั้งหมดเท่ากับจำนวนแห่งของฮิสโทแกรม นั่นคือ 100 ปมสำหรับการใช้ข้อมูลความเร่งแกนเดียว และจะมีจำนวนปมเป็น 200 และ 300 หากใช้จำนวนแกนความเร่ง 2 แกน และ 3 แกนตามลำดับ
- ชั้นซ่อนมีเพียง 1 ชั้น เนื่องจากในการทดลองการตั้งค่าชั้นซ่อนตั้งแต่ไม่มีชั้นซ่อนเลยจนถึงใช้ชั้นซ่อน 4 ชั้นก็ไม่พบว่ามีผลแตกต่างของค่าความแม่นยำของโมเดล ยกเว้นเมื่อไม่มีชั้นซ่อนที่ให้ผลความแม่นยำต่ำ ในชั้นซ่อนเพียงชั้นเดียวนี้ จากการทดลองพบว่าจำนวนปมที่เหมาะสมคือประมาณหนึ่งในสามของจำนวนปมในชั้นขาเข้า เนื่องจากจำนวนปมที่มากกว่านี้ไม่ทำให้ผลความแม่นยำเปลี่ยนแปลงไปมาก ภาพที่ 3.11 แสดงผลการทดลองการหาจำนวนปมในชั้นซ่อนสำหรับการใช้ความเร่งทั้ง 3 แกน
- ชั้นขาออกมีจำนวนปมทั้งหมดเท่ากับจำนวนคนขับรถ ปมขาออกทุกปมจะมีค่าระหว่างศูนย์ถึงหนึ่งเท่านั้น คนขับรถจะถูกระบุจากปมของขาออกที่มีค่าใกล้เคียงหนึ่งมากที่สุด



ภาพที่ 3.11 แสดงผลการทดลองการหาจำนวนปมในชั้นซ่อน

เพื่อให้ผู้อ่านเข้าใจได้ง่ายขึ้น ผู้เขียนได้แสดงตัวอย่างโมเดลโครงข่ายประสาทเทียมเมื่อใช้ข้อมูลความเร่งทั้ง 3 แกนเพื่อระบุคนขับรถจากทั้งหมด 13 คนในภาพที่ 3.12 จะเห็นว่าในชั้นแรกเป็นการนำค่าของฮิสโทแกรมทั้งสามแกนเข้า แต่ละแกนมี 100 ค่าดังนั้นจึงมีปมที่เข้าทั้งหมด 300 ปม สำหรับชั้นกลางจะมีปมเป็นหนึ่งในสามส่วนของจำนวนปมขาเข้าคือ 100 ปม และจำนวนปมขาออกเท่ากับ 13 ปมซึ่งเท่ากับจำนวนคนขับรถทั้งหมดในการทดลอง

ในงานวิจัยนี้จะใช้ภาษาอาร์ (R language) ในการสร้างชุดคำสั่ง โดยใช้โปรแกรมสำเร็จ (package) จาก CRAN (The Comprehensive R Archive Network) ที่มีชื่อว่า *neuralnet* สำหรับสร้าง ฝึกฝน และทดสอบโครงข่ายประสาทเทียม การตั้งค่าในโปรแกรมสำเร็จดังกล่าวสำหรับโครงข่ายประสาทเทียมที่ใช้ในงานวิจัยนี้แสดงในตารางที่ 3.1 สำหรับค่าอื่นที่ไม่ได้กล่าวถึงใช้เป็นค่าเริ่มต้นของโปรแกรมสำเร็จ



ภาพที่ 3.12 แสดงตัวอย่างโมเดลโครงข่ายประสาทเทียม

ตารางที่ 3.1 แสดงการตั้งค่าบางส่วนในโปรแกรมสำเร็จ neuralnet

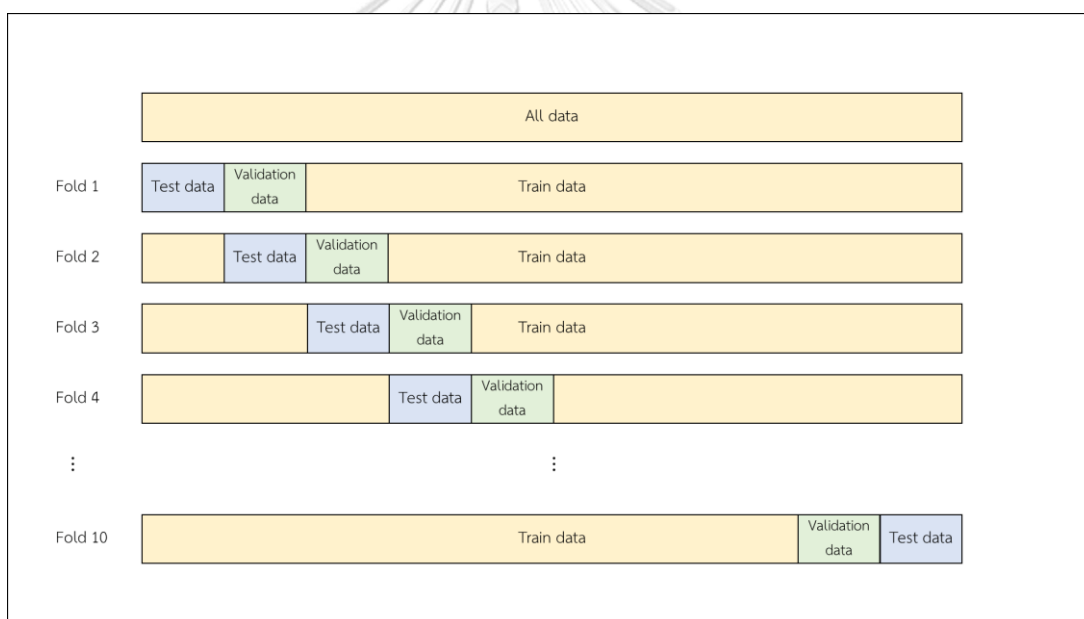
Parameter	Value
threshold	0.05
stepmax	100000
rep	1
algorithm	'rprop+'
act.fct	'logistic'
linear.output	FALSE

3.5 การระบุผู้ไม่พึงประสงค์

งานวิจัยเกี่ยวกับการระบุตัวคนขับรถนั้นมักจะพิจารณาเฉพาะการระบุตัวคนขับรถภายในกลุ่มคนขับรถที่รู้จักอยู่ก่อน หากเป็นระบบดังกล่าวเมื่อมีผู้ไม่พึงประสงค์มาขับรถ ระบบจะทำนายผู้ไม่พึงประสงค์ดังกล่าวตามคนขับรถในระบบที่มีพฤติกรรมใกล้เคียงมากที่สุด เนื่องจากผู้ทำระบบไม่อาจมีข้อมูลของผู้ไม่พึงประสงค์มาใช้ในการฝึกฝนระบบก่อนได้ จุดนี้เองเป็นสิ่งที่ทำให้การระบุตัวผู้ไม่พึงประสงค์นั้นมีความสำคัญ หากระบบสามารถระบุผู้ไม่พึงประสงค์ได้ก็จะสามารถนำไปใช้ในการระบุโจรขโมยรถหรือการจี้รถได้ อย่างไรก็ตามระบบที่ใช้ในงานวิจัยนี้โดยพื้นฐานแล้วไม่สามารถใช้ระบุตัวผู้

ไม่พึงประสงค์ได้ เพื่อเพิ่มความสามารถของระบบ ผู้เขียนได้เพิ่มส่วนการทำงานเพื่อให้สามารถระบุผู้ไม่พึงประสงค์ได้

ในการที่จะสามารถวัดผลผู้ไม่พึงประสงค์ได้จำเป็นต้องมีข้อมูลตัวอย่างของผู้ไม่พึงประสงค์ ดังนั้นข้อมูลคนขับรถบางคนจะถูกดึงออกมาเพื่อใช้สำหรับทดสอบและข้อมูลของคนขับรถเหล่านี้จะไม่ถูกใช้เป็นข้อมูลฝึกฝน สำหรับข้อมูลฝึกฝนจะต้องถูกแบ่งข้อมูลจำนวนหนึ่งไว้เพื่อใช้ในการหาขีดแบ่ง (threshold) ซึ่งขึ้นอยู่กับแต่ละคนขับรถ ตัวอย่างการแบ่งข้อมูลสำหรับการสร้างระบบนี้แสดงไว้ในภาพที่ 3.13 สถานการณ์ปกติ ข้อมูลขาออกจากโครงข่ายประสาทเทียมจะถูกเปรียบเทียบกันและจะระบุคนขับรถจากปมที่มีค่ามากที่สุด แต่เพื่อให้ระบุผู้ไม่พึงประสงค์ได้ ค่าขีดแบ่งต้องถูกคำนวณเพื่อจะแบ่งค่าของผู้ไม่พึงประสงค์จากค่าของคนขับรถในระบบ จากการทดลองหลากหลายแบบ วิธีการคำนวณที่ได้ค่าที่ดีที่สุดคือการใช้ค่าที่มากกว่าเปอร์เซ็นต์ไทล์ที่ 20 ของค่าจากปมที่ทำนายได้ถูกต้อง หรือมีค่าในปมมากกว่า 0.999 จะถือว่าเป็นคนขับรถในระบบ



ภาพที่ 3.13 แสดงการแบ่งข้อมูลเพื่อทดสอบการระบุผู้ไม่พึงประสงค์

อย่างไรก็ตามผลการทดลองยังไม่ได้ค่าที่น่าพึงพอใจนัก ซึ่งอาจเป็นผลมาจากการใช้ค่าของปมขาออกในโครงข่ายประสาทเทียมเพื่อคำนวณหาขีดแบ่ง ในขณะที่ค่าของปมขาออกนั้นไม่ได้สื่อถึงความแตกต่างของพฤติกรรมของคนขับรถแต่อย่างใด เพื่อให้การคำนวณค่าขีดแบ่งทำได้ดีขึ้น ผู้เขียนจึงเลือกใช้อัลกอริทึมการค้นหาเพื่อนบ้านใกล้สุด k ตัวซึ่งมีส่วนที่สามารถคำนวณความแตกต่างของฮิสโตแกรมได้โดยตรง สำหรับข้อมูลที่น่ามาทดสอบด้วยวิธีนี้เป็นข้อมูลลักษณะเดียวกับข้อมูลในย่อหน้าที่แล้วทั้งหมด และยังใช้การแบ่งข้อมูลสำหรับฝึกฝนและทดสอบในลักษณะเดียวกัน โดย

เริ่มต้น ฮิสโทแกรมทุกกราฟของข้อมูลตรวจสอบจะถูกใช้เพื่อหาระยะทางแบบยูคลิด (Euclidian distance) กับฮิสโทแกรมทั้งหมดในข้อมูลฝึกฝนเพื่อจะหาเพื่อนบ้านที่ใกล้ที่สุด k ตัว โดยค่า k ได้ถูกวิเคราะห์แล้วว่าจะเหมาะสมที่สุดที่ค่า k เท่ากับ 17 จากนั้นการหาขีดแบ่งจะถูกคำนวณจากค่าเฉลี่ยของระยะทางที่มากที่สุดนในเพื่อนบ้านของข้อมูลตรวจสอบ ซึ่งค่าขีดแบ่งนี้เป็นค่าประจำของแต่ละคนขับรถในระบบ จากนั้นในขั้นตอนการทดสอบจะต้องมีการหาเพื่อนบ้านที่ใกล้ที่สุด 17 ตัวเช่นกัน โดยจำนวนฮิสโทแกรมของคนขับรถที่มากที่สุดนในเพื่อนบ้านนั้นจะเป็นคนขับรถที่ถูกระบุ แต่ถ้าระยะทางแบบยูคลิดที่สั้นที่สุดในเพื่อนบ้านไม่ผ่านค่าขีดแบ่งประจำตัวของคนขับรถนั้น ฮิสโทแกรมดังกล่าวจะถูกระบุเป็นผู้ไม่พึงประสงค์ เพื่อให้ผู้อ่านเข้าใจมากขึ้น จากวิธีที่ได้กล่าวมาอาจแบ่งได้เป็นสองส่วนคืออัลกอริทึม 3.2 สำหรับหาค่าขีดแบ่งของคนขับรถแต่ละคน และอัลกอริทึม 3.3 สำหรับการระบุตัวคนขับรถหรือผู้ไม่พึงประสงค์จากฮิสโทแกรมหนึ่ง ๆ ในข้อมูลทดสอบ

อัลกอริทึม 3.2 สำหรับหาค่าขีดแบ่งของคนขับรถแต่ละคน

Input:	k constant in KNN k validation data $validateData$ training data $trainData$
Output:	threshold for each driver $threshold_d$
1:	for each driver d do:
2:	$validateData_d = validateData$ which keep only driver d
3:	for each $validateData_d$ do:
4:	$kList_d =$ find k nearest neighbor in $trainData$
5:	$topkList_d =$ keep maximum distance from $kList_d$
6:	end for
7:	$threshold_d =$ average distance in $topkList_d$
8:	end for

อัลกอริทึม 3.3 สำหรับการระบุตัวคนขับรถหรือผู้ไม่พึงประสงค์จากฮิสโทแกรมหนึ่ง ๆ ในข้อมูลทดสอบ เมื่อมีค่าขีดแบ่งสำหรับแต่ละคนขับรถแล้ว

Input:	testing histogram $testData$ training data $trainData$ k constant in KNN k threshold for driver d $threshold_d$
Output:	identification result (driver label or impostor) $result$
1:	$kList_d$ = from $testData$ find k nearest neighbor in $trainData$
2:	$nearest$ = minimum distance in $kList_d$
3:	$predictedDriver$ = driver label which is the majority in $kList_d$
4:	if $nearest$ is more than $threshold_{predictedDriver}$ do:
5:	$result$ = "impostor"
6:	else do:
7:	$result$ = $predictedDriver$

บทที่ 4

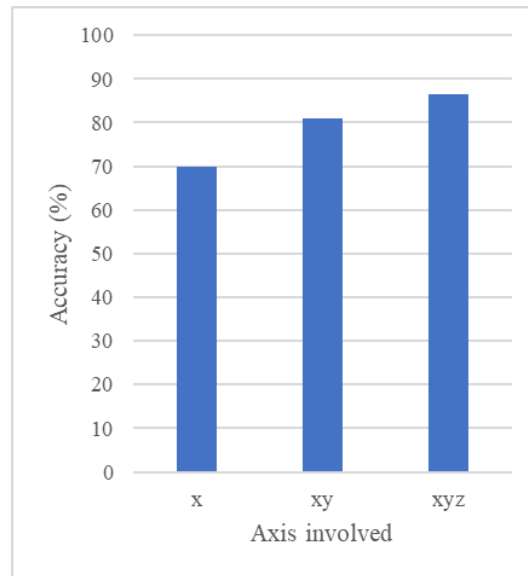
การวัดประสิทธิภาพของโมเดลและผลการทดลอง

4.1 การออกแบบการทดลอง

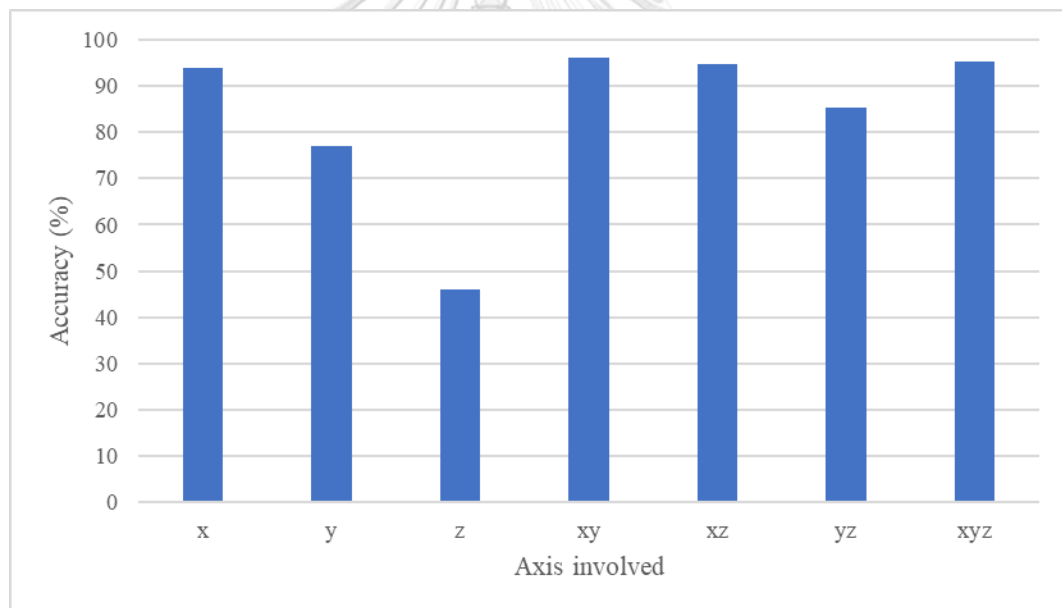
ในการใช้งานโมเดลโครงข่ายประสาทเทียมจะต้องมีการแบ่งข้อมูลส่วนหนึ่งไว้เป็นข้อมูลสำหรับฝึกโมเดล (Training Data) และเพื่อให้ทราบถึงประสิทธิภาพของโมเดลจึงต้องมีการแบ่งข้อมูลอีกส่วนไว้เป็นข้อมูลสำหรับทดสอบ (Testing Data) การทดสอบโมเดลจะใกล้เคียงค่าจริงมากขึ้นหากมีการทดลองทำได้หลายครั้งมากขึ้น จึงเป็นที่มาของการใช้การตรวจสอบไขว้แบบ 10 พับ (10-Fold Cross Validation) อย่างไรก็ตามเมื่อใช้การทดสอบแบบไขว้และหากฮิสโทแกรมที่เตรียมไว้มีการเหลื่อมกัน จะต้องลบฮิสโทแกรมบางส่วนออกเพื่อไม่ให้ข้อมูลสำหรับฝึกและข้อมูลสำหรับทดสอบมีส่วนที่นำมาจากข้อมูลเดียวกัน มิเช่นนั้นจะนำไปสู่ผลการทดลองที่มีความลำเอียงได้

4.2 ประสิทธิภาพของการใช้ส่วนกรองข้อมูลช่วงระยะพัก

ในการแสดงประสิทธิภาพของส่วนกรองข้อมูลช่วงระยะพักผู้เขียนขอเสนอในรูปแบบของแกนร่วมที่ใช้ในระบบเนื่องจากข้อมูลความเร่งที่ใช้สำหรับงานวิจัยนี้มีทั้ง 3 แกนคือ แกนด้านหน้า (Longitudinal Axis) แกนด้านข้าง (Lateral Axis) และแกนด้านบน (Vertical Axis) สำหรับแกนด้านหน้าจะสื่อถึงการขับรถในทิศทางเดินทางหรือถอยหลังซึ่งเป็นทิศทางที่รถมีการเปลี่ยนแปลงความเร่งอยู่เสมอจึงเป็นแกนที่สำคัญที่สุดเพราะสื่อถึงพฤติกรรมการขับรถโดยตรง สำหรับแกนด้านข้างจะสื่อถึงการขับรถขณะเปลี่ยนช่องทางการจราจร การเลี้ยวที่ทางโค้ง หรือการกลับรถซึ่งจะมีการเปลี่ยนแปลงความเร่งในแกนนี้น้อยกว่าแกนด้านหน้าจึงมีความสำคัญน้อยกว่า สำหรับแกนสุดท้ายคือแกนด้านบนจะสื่อถึงการขับรถเมื่อมีการขึ้นเนิน ขึ้นสะพาน ขึ้นลูกระนาดชะลอความเร็ว หรือเหตุการณ์ใด ๆ ที่ทำให้เปลี่ยนตำแหน่งในแกนด้านบน เหตุการณ์ส่วนนี้เกิดขึ้นน้อยจึงมีความสำคัญน้อยที่สุด สำหรับประสิทธิภาพก่อนการใช้ส่วนกรองข้อมูลช่วงระยะพักแสดงในภาพที่ 4.1 ซึ่งจะเห็นว่าการใช้ข้อมูลแกนร่วมเพิ่มขึ้นนั้นทำให้ประสิทธิภาพเพิ่มมากขึ้น อย่างไรก็ตามเมื่อใช้ส่วนกรองข้อมูลช่วงระยะพักแล้วประสิทธิภาพโดยรวมดีขึ้นกว่าเดิมสูงสุดถึง 30 เปอร์เซ็นต์ดังที่แสดงในภาพที่ 4.2 นอกจากนี้ผู้เขียนยังได้ทดสอบแกนร่วมอื่น ๆ อย่างครบถ้วนมากขึ้นในการทดลองนี้ เมื่อใช้การกรองดังกล่าวแล้วถึงแม้จะใช้ข้อมูลในแกนด้านหน้าเพียงอย่างเดียวก็สามารถระบุตัวคนขับรถได้แม่นยำมากกว่า 90 เปอร์เซ็นต์



ภาพที่ 4.1 แสดงผลการทดลองการใช้ข้อมูลแกนร่วมที่แตกต่างกันก่อนการกรอกช่วงพัก

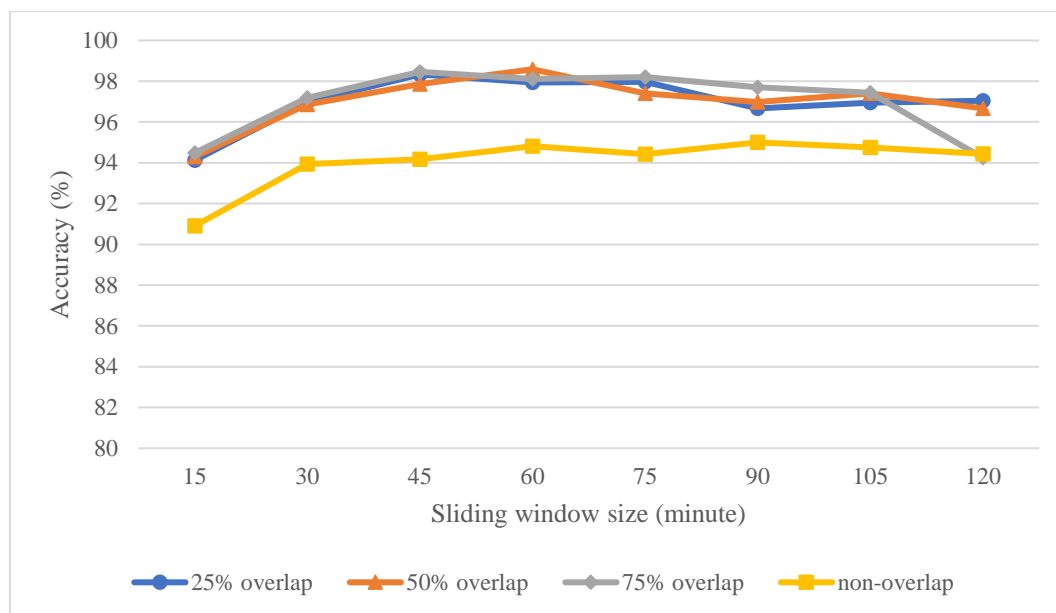


ภาพที่ 4.2 แสดงผลการทดลองการใช้ข้อมูลแกนร่วมที่แตกต่างกันหลังการกรอกช่วงพัก

อย่างไรก็ตามการใช้ข้อมูลในหลายแกนนั้นไม่ได้เฉพาะเจาะจงกับข้อมูลความเร่งเท่านั้น ในระบบการระบุตัวคนขับรถอื่น ๆ อาจใช้ข้อมูลที่แตกต่างกันซึ่งมีหลายแกน เช่น ความเร็ว หรือเจิร์ค (jerk) เป็นต้น หากข้อมูลนั้นมีหลายแกนก็ควรทดสอบการใช้ข้อมูลหลายแกนร่วมกันเพื่อให้ได้ผลลัพธ์ที่ดีที่สุด

4.3 ประสิทธิภาพของขนาดหน้าต่างเลื่อน และการเหลื่อม


การสกัดข้อมูลจากข้อมูลเชิงเวลาโดยส่วนมากแล้วต้องมีการกำหนดขนาดหน้าต่างเลื่อน การสร้างฮิสโทแกรมเองก็เช่นกัน ในการระบุตัวคนขับรถ ขนาดของหน้าต่างเลื่อนมีผลต่อความแม่นยำในการระบุและยังมีผลต่อการใช้งานจริงด้วย ในการสร้างฮิสโทแกรม การกำหนดขนาดหน้าต่างเลื่อนควรมีขนาดเวลาพอสมควรเพื่อให้ฮิสโทแกรมของความเร็วนั้นสื่อถึงพฤติกรรมในการขับรถได้ ในงานวิจัยนี้ผู้เขียนได้ทดลองใช้ขนาดหน้าต่างเลื่อนตั้งแต่ 15 นาทีจนถึง 120 นาที นอกจากนี้ยังได้ทดสอบเรื่องการเหลื่อมด้วย ผลการทดลองด้วยโมเดลโครงข่ายประสาทเทียมเปรียบเทียบขนาดหน้าต่างเลื่อนและการเหลื่อมแสดงในภาพที่ 4.3 สังเกตว่าแกนตั้งมีค่าเริ่มต้นที่ 80 เพื่อให้สามารถเห็นถึงความแตกต่างของแต่ละผลการทดลองได้อย่างชัดเจนมากขึ้น จากผลการทดลองจะสังเกตได้ว่าการใช้ค่าการเหลื่อมที่แตกต่างกันไม่ทำให้ความแม่นยำแตกต่างกันมากนัก แต่ไม่ว่าจะใช้การเหลื่อมเท่าใดก็ยังไม่ให้ผลที่ดีกว่าผลที่ไม่ใช้การเหลื่อมอย่างเห็นได้ชัด สำหรับขนาดหน้าต่างเลื่อนที่เหมาะสมจากการทดลองนี้คือค่าประมาณ 45-60 นาที อย่างไรก็ตามขนาดของหน้าต่างเลื่อนมีผลต่อเวลาในการระบุตัวคนขับรถ เพื่อให้เห็นภาพชัดเจนขึ้น จะขอยกตัวอย่างการใช้ขนาดหน้าต่างเลื่อนที่ 60 นาที และใช้การเหลื่อมที่ 75 เปอร์เซ็นต์ ด้วยการตั้งค่านี้ระบบจะสามารถระบุคนขับรถได้ทุก 15 นาที อย่างไรก็ตามการรอถึง 15 นาทีนั้นอาจจะนานเกินไปสำหรับการใช้งานจริงบางประเภท หากต้องการให้ระบุคนขับรถได้รวดเร็วมากขึ้นอาจใช้ขนาดหน้าต่างเลื่อนที่น้อยลงหรือการเหลื่อมกันที่มากขึ้น ตัวอย่างเช่น หากใช้ขนาดหน้าต่างเลื่อนที่ 15 นาทีประกอบกับการเหลื่อมที่ 75 เปอร์เซ็นต์ จะทำให้ระบบสามารถระบุตัวคนขับรถได้เร็วขึ้นเป็นทุก ๆ 3 นาที 15 วินาที อย่างไรก็ตามการใช้ขนาดหน้าต่างเลื่อนที่น้อยเกินไปอาจทำให้ฮิสโทแกรมของความเร็วมไม่สามารถรวบรวมพฤติกรรมการขับรถได้มากเท่าที่ควรทำให้ต้องแลกมาซึ่งค่าความแม่นยำที่ลดลงเล็กน้อย



ภาพที่ 4.3 แสดงผลการทดลองบนขนาดหน้าต่างต่างเลื้อนและการเหลื่อมที่แตกต่างกัน

4.4 ประสิทธิภาพของระบบระบุตัวคนขับรถ

เนื่องจากการระบุตัวคนขับรถเป็นปัญหาการแบ่งประเภทแบบหลายประเภท (Multi-class classification problem) อย่างหนึ่งซึ่งจำนวนของประเภทนั้นมีผลต่อความแม่นยำในการทำนายอย่างมาก สำหรับการระบุตัวคนขับรถนั้นจำนวนคนขับรถก็คือจำนวนประเภทนั่นเอง ดังนั้นการวัดประสิทธิภาพของระบบการระบุตัวคนขับรถนั้นควรแสดงถึงจำนวนคนขับรถด้วย ทั้งนี้ขึ้นกับการนำไปใช้งานจริงว่าโดยทั่วไปนั้นระบบมีคนขับรถมากเท่าใด สำหรับในงานวิจัยนี้ เพื่อเป็นการแสดงถึงประสิทธิภาพของระบบระบุตัวคนขับรถ ผู้เขียนได้ทดลองจำกัดจำนวนคนขับรถในระบบตั้งแต่ 3-13 คนเพื่อทดสอบระบบ โดยในการทดลองนี้จะใช้ขนาดหน้าต่างที่ 45 นาที เหลื่อมกัน 75 เปอร์เซ็นต์ และใช้ข้อมูลจากแกดด้านหน้าเพียงแกดเดียว ผลของการระบุตัวคนขับรถแสดงในภาพที่ 4.4 สังเกตว่าค่าในแกดตั้งเริ่มที่ 90 เพื่อให้เห็นความแตกต่างชัดเจน ซึ่งจะสังเกตได้ว่าเมื่อคนขับรถในระบบมีจำนวนมากขึ้นผลการระบุตัวคนขับรถจะมีความแม่นยำลดลง โดยหากมีคนขับรถในระบบจำนวน 3 คน ระบบการระบุตัวคนขับรถนี้จะมีความแม่นยำถึง 99.3 เปอร์เซ็นต์ อย่างไรก็ตามแม้จะมีจำนวนคนขับรถในระบบมากถึง 13 คน ระบบนี้ก็ยังสามารถรักษาความแม่นยำไว้ได้มากกว่า 90 เปอร์เซ็นต์



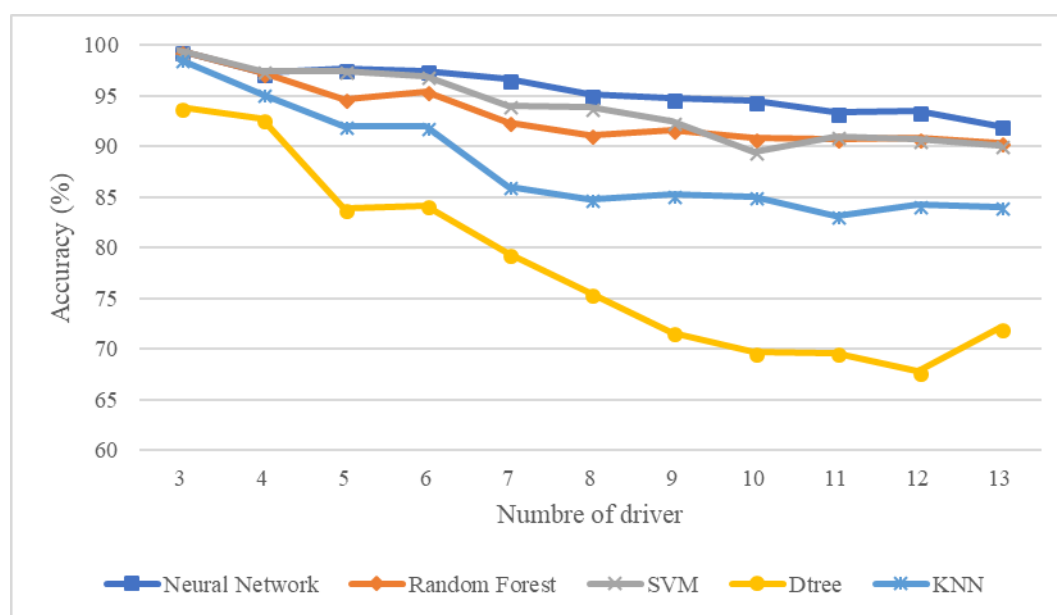
ภาพที่ 4.4 แสดงผลการระบุตัวคนขับรถโดยมีจำนวนคนขับรถในระบบแตกต่างกัน

4.5 ประสิทธิภาพของระบบเมื่อเปรียบเทียบกับตัวแยกประเภทแบบอื่น

ในการทำระบบแยกประเภทนั้นสามารถเลือกตัวแยกประเภทได้หลากหลาย ตัวแยกประเภทแต่ละตัวล้วนมีความแตกต่างกันและทำงานได้ดีในสภาพข้อมูลที่แตกต่างกัน ในงานวิจัยนี้เบื้องต้นได้ทำโดยใช้โครงข่ายประสาทเทียม อย่างไรก็ตามผู้เขียนได้แสดงถึงผลการทดลองการระบุตัวคนขับรถโดยใช้วิธีโปรแกรมแบบเดียวกันบนตัวแยกประเภทอื่น ๆ ที่มีชื่อเสียง ได้แก่ ต้นไม้ตัดสินใจ (Decision tree) ซัพพอร์ตเวกเตอร์แมชชีน (support vector machines) ป่าแบบสุ่ม (Random forest) และอัลกอริทึมการค้นหาเพื่อนบ้านใกล้สุด k ตัว โดยทุกตัวแยกประเภทใช้โปรแกรมสำเร็จจาก CRAN ดังที่แสดงในตารางที่ 4.1 โดยแต่ละโปรแกรมสำเร็จใช้การตั้งค่าพื้นฐาน ยกเว้นอัลกอริทึมการค้นหาเพื่อนบ้านที่ใกล้สุด k ตัวซึ่งเขียนชุดคำสั่งขึ้นเองและใช้วิธีการและการตั้งค่าตามการทดลองการระบุผู้ไม่พึงประสงค์ในหัวข้อที่ 3.5 สำหรับผลการทดลองแสดงในภาพที่ 4.5 สังเกตว่าค่าในแกนตั้งเริ่มต้นที่ 60 เพื่อให้เห็นความแตกต่างชัดเจนขึ้น จากผลการทดลองจะเห็นว่าตัวแยกประเภทแบบอื่นนั้นล้วนมีประสิทธิภาพต่ำกว่าโครงข่ายประสาทเทียมทั้งหมดสำหรับทุกจำนวนคนขับรถ อย่างไรก็ตามโครงข่ายประสาทเทียมนั้นมีความซับซ้อนสูงและใช้เวลาในการฝึกฝนเป็นเวลานานเมื่อเทียบกับตัวแยกประเภทอื่นแต่เวลาในการระบุตัวคนขับรถนั้นไม่ได้แตกต่างกันมาก ในการใช้งานจริงผู้ใช้อาจเลือกที่จะสละความแม่นยำลงเล็กน้อยเพื่อแลกกับเวลาในการฝึกฝนที่สั้นลง

ตารางที่ 4.1 แสดงชื่อโปรแกรมสำเร็จจาก CRAN ที่ใช้ในการทดลอง

ตัวแยกประเภท	ชื่อโปรแกรมสำเร็จ
ต้นไม้ตัดสินใจ	dtree
ซัพพอร์ตเวกเตอร์แมชชีน	e1071
ป่าแบบสุ่ม	randomForest
การหาเพื่อนบ้านที่ใกล้สุด k ตัว	-



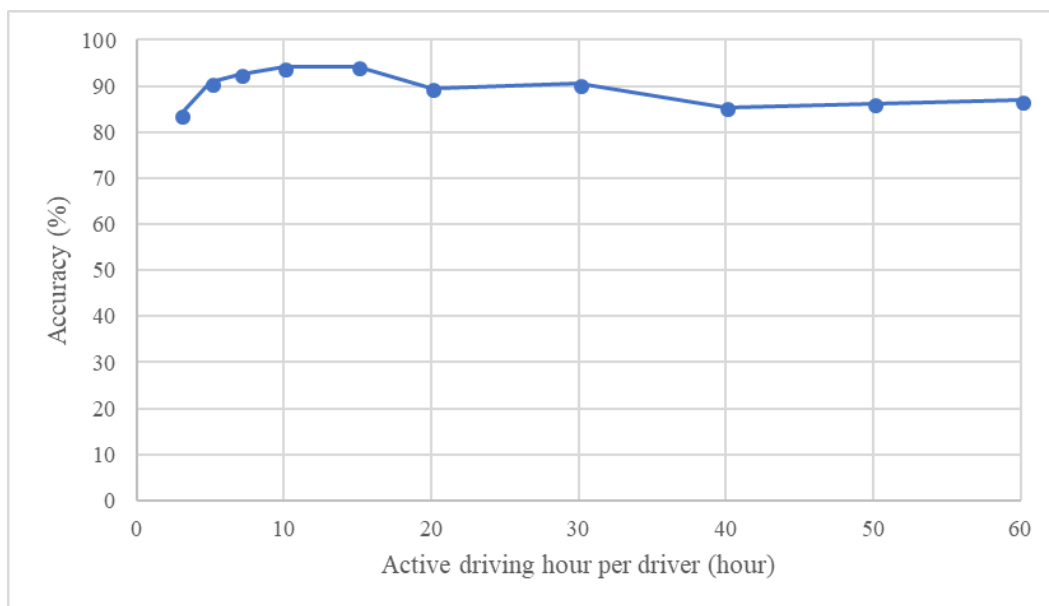
ภาพที่ 4.5 แสดงความแม่นยำเมื่อใช้ตัวแยกประเภทที่แตกต่างกัน

จุฬาลงกรณ์มหาวิทยาลัย

4.6 การศึกษาประสิทธิภาพบนจำนวนข้อมูล

จำนวนข้อมูลนั้นมีความสำคัญทั้งต่อผลความแม่นยำและการใช้งานจริง โดยเฉพาะจำนวนข้อมูลฝึกฝนซึ่งสื่อถึงชั่วโมงการขับรถที่ต้องเก็บเมื่อนำไปใช้งานจริง จำนวนข้อมูลฝึกฝนไม่ควรจะมากหรือน้อยเกินไป หากมากเกินไปจะทำให้เสียเวลาเก็บข้อมูลนานเมื่อนำไปใช้งานจริง แต่หากข้อมูลฝึกฝนน้อยเกินไปอาจทำให้ข้อมูลฝึกฝนนั้นไม่สื่อถึงพฤติกรรมที่มากพอจะใช้ได้ในระยะยาว เช่น ข้อมูลที่น้อยอาจไม่ครอบคลุมสภาพการจราจรที่มากพอ นอกจากข้อมูลฝึกฝนแล้วข้อมูลทดสอบก็มีความสำคัญเช่นกัน หากข้อมูลทดสอบมีน้อยเกินไป (เช่น น้อยกว่าหนึ่งชั่วโมง) อาจทำให้ได้เฉพาะสภาพการจราจรที่เฉพาะเจาะจง ซึ่งจะส่งผลให้การทดสอบมีความลำเอียงได้ เพื่อเป็นการพิสูจน์สมมติฐานดังกล่าว และเพื่อเป็นการแสดงถึงประสิทธิภาพของระบบในการใช้จำนวนข้อมูลที่แตกต่างกัน ผู้เขียนจึงทำการทดลองการระบุตัวคนขับรถโดยจำกัดปริมาณข้อมูลไว้ตั้งแต่ 1 ชั่วโมงต่อคนจนถึง

60 ชั่วโมงต่อคน ผลการทดลองแสดงในภาพที่ 4.6 จากผลการทดลองพบว่าช่วงเวลาที่เหมาะสมที่สุดคือประมาณ 10 ชั่วโมง การฝึกฝนและทดสอบบนข้อมูลที่มากเกินไปนั้นอาจทำให้ค่าความแม่นยำลดลงเนื่องจากพฤติกรรมของคนนั้นอาจมีการเปลี่ยนแปลงได้เมื่อผ่านไปเป็นระยะเวลาานาน

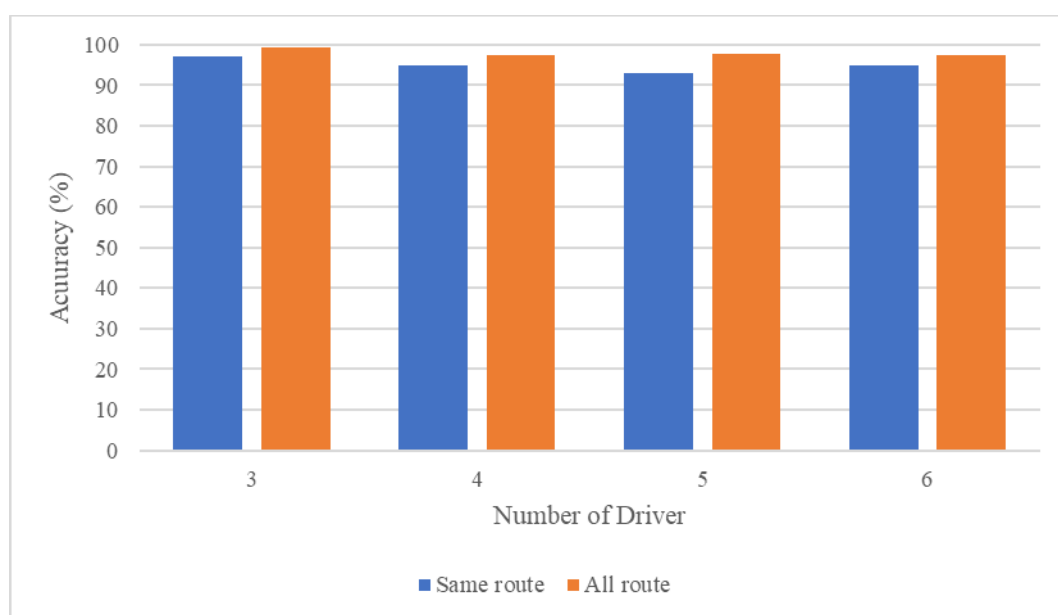


ภาพที่ 4.6 แสดงผลการระบุตัวคนขับรถโดยจำกัดปริมาณข้อมูลที่ต่างกัน

4.7 การศึกษาประสิทธิภาพต่อลักษณะเส้นทาง

เนื่องจากข้อมูลในงานวิจัยนี้เป็นข้อมูลที่ได้มาจากรถโดยสารภายในมหาวิทยาลัย ทำให้เส้นทางการเดินทางรถถูกจำกัด กล่าวคือจากคนขับรถทั้งหมด 13 คนแบ่งได้เป็น 3 เส้นทางการเดินทาง เส้นทางแรกมีจำนวน 6 คน เส้นทางที่สองมีจำนวน 4 คน และเส้นทางสุดท้ายมีจำนวน 3 คน ผู้เขียนตั้งข้อสันนิษฐานว่าเส้นทางการเดินทางอาจส่งผลต่อข้อมูลความเร่งที่นำมาใช้ระบุคนขับรถได้ กล่าวคือเนื่องจากคนขับรถคนเดิมจะใช้เส้นทางการเดินทางเดิมเสมอ ดังนั้นโครงข่ายประสาทเทียมอาจใช้พฤติกรรมของเส้นทางประกอบกับพฤติกรรมของคนขับรถทำให้การระบุตัวคนขับรถมีความแม่นยำขึ้นได้ อย่างไรก็ตามสำหรับการใช้งานจริงในระบบขนส่งสาธารณะ ควรมีการแบ่งระบบตามเส้นทางการเดินทางเป็นระบบย่อยแยกจากกันเพื่อให้มีคนขับรถในระบบน้อยลงและส่งผลให้ความแม่นยำดีกว่าระบบใหญ่ที่มีคนขับรถจำนวนมาก เพื่อเป็นการศึกษาความแม่นยำของระบบตามสถานการณ์ที่ได้กล่าวมา ผู้เขียนจึงทดสอบประสิทธิภาพของระบบโดยจำกัดข้อมูลของคนขับรถเฉพาะเส้นทางการเดินทางแรกเพื่อเปรียบเทียบกับประสิทธิภาพเมื่อใช้ข้อมูลคนขับรถจากหลายเส้นทางรวมกัน ได้ผลการทดลองดังภาพที่ 4.7 จากภาพจะเห็นได้ว่าเมื่อใช้ข้อมูลคนขับรถบนเส้นทางเดียวกัน ความแม่นยำใน


การระบุตัวคนขับรถนั้นลดลงเล็กน้อยเมื่อเทียบกับการใช้ข้อมูลจากคนขับรถในหลายเส้นทางร่วมกัน ตามที่ได้ตั้งข้อสันนิษฐานไว้ อย่างไรก็ตามความแม่นยำในการทำนายยังคงสูงกว่า 90 เปอร์เซ็นต์ ทั้งนี้ ผู้เขียนไม่สามารถทดสอบประสิทธิภาพของระบบเมื่อใช้ข้อมูลจากคนขับรถในเส้นทางเดียวกันมากกว่า 6 คนได้ เนื่องจากข้อมูลที่นำมาใช้ในงานวิจัยนี้จำกัดจำนวนคนขับรถบนเส้นทางเดียวกันมากที่สุด 6 คนเท่านั้นซึ่งเป็นข้อมูลที่มาจากเส้นทางแรกดังที่ได้กล่าวไว้ข้างต้น



ภาพที่ 4.7 แสดงความแม่นยำของระบบเมื่อจำกัดข้อมูลคนขับรถจากเส้นทางเดียว


4.8 การศึกษาประสิทธิภาพเมื่อใช้ระบบในการระบุผู้ไม่พึงประสงค์

การวัดผลการระบุผู้ไม่พึงประสงค์ในงานวิจัยนี้จะกำหนดตัวอย่างสถานการณ์โดยกำหนดให้มีคนขับรถในระบบทั้งหมด 3 คนโดยสุ่มเลือกจากข้อมูลคนขับรถทั้งหมด 13 คน ข้อมูลคนขับรถที่เหลืออีก 10 คนจะถูกสุ่มโดยคละกันเพื่อใช้เป็นข้อมูลของผู้ไม่พึงประสงค์ ข้อมูลคนขับรถเหล่านี้จะไม่ถูกนำไปใช้ในการฝึกฝนโครงข่ายประสาทเทียม แต่จะใช้ในขั้นตอนการทดสอบระบบโดยจะนำคนขับรถเหล่านี้ไปคละกับข้อมูลทดสอบในสถานการณ์ปกติ ผลการระบุคนขับรถโดยมีผู้ไม่พึงประสงค์แอบแฝงแสดงในภาพที่ 4.8 ซึ่งจะแสดงด้วยค่าพรีซิชั่น รีคอล และเอฟวัน แทนที่จะใช้เพียงค่าความแม่นยำเหมือนในหัวข้อก่อนหน้า เนื่องจากในการทดลองนี้ค่าความผิดพลาดชนิดที่ 1 และ 2 มีความสำคัญถึงแม้ค่าเอฟวันโดยรวมจะมีค่า 0.72 แต่หากพิจารณาเฉพาะผลของผู้ไม่พึงประสงค์พบว่าค่าเอฟวันอยู่ที่ 0.56 เท่านั้น ซึ่งเกิดจากค่าพรีซิชั่นที่น้อยถึง 0.46 เนื่องจากระบบระบุผู้ไม่พึงประสงค์ผิดไปเป็นคนขับรถในระบบคนอื่นจำนวนมาก



ภาพที่ 4.8 แสดงผลการระบุคนชั่วกรณเมื่อมีผู้ไม่พึงประสงค์แอบแฝงเมื่อใช้โครงข่ายประสาทเทียม

เนื่องจากผลการทดลองที่ไม่ดีนัก ผู้เขียนจึงทดลองใช้อัลกอริทึมการค้นหาเพื่อนบ้านใกล้สุดแทนโครงข่ายประสาทเทียมตามที่ได้อธิบายไว้ในหัวข้อที่ 3.4 ผลจากการใช้อัลกอริทึมดังกล่าวแสดงในภาพที่ 4.9 ซึ่งมีค่าที่น่าพึงพอใจมากขึ้น ค่าเอพวันโดยรวมเพิ่มขึ้นเป็น 0.87 และแม้จะพิจารณาเฉพาะประสิทธิภาพของผู้ไม่พึงประสงค์ ค่าเอพวันก็ยังคงมากถึง 0.76 เช่นเดียวกับค่าพรีซีชันและรีคอลซึ่งได้ 0.74 และ 0.78 ตามลำดับ เพื่อให้ผู้อ่านเข้าใจถึงผลการทดสอบมากขึ้น ผู้เขียนได้แสดงตารางคอนฟิวชันเมตริกไว้ดังตารางที่ 4.2



ภาพที่ 4.9 แสดงผลการระบุคนชั่วกรณเมื่อมีผู้ไม่พึงประสงค์แอบแฝงเมื่อใช้อัลกอริทึมการค้นหาเพื่อนบ้านใกล้สุด k ตัว

ตารางที่ 4.2 แสดงค่าคอนฟิวชันเมตริกของการระบุผู้ไม่พึงประสงค์

		True Driver			
		Impostor	Driver A	Driver B	Driver C
Predicted Driver	Impostor	153	21	14	20
	Driver A	20	169	1	0
	Driver B	0	0	175	0
	Driver C	23	0	0	170



บทที่ 5

สรุปผลงานวิจัย

งานวิจัยนี้ได้เสนอระบบการระบุตัวตนขับรถโดยใช้เพียงข้อมูลความเร็วเพียงอย่างเดียว โดยมีการเสนอฮิสโทแกรมของความเร็วเป็นพีเจอร์สำคัญและเป็นข้อมูลขาเข้าสู่โครงข่ายประสาทเทียม ฮิสโทแกรมของความเร็วได้ถูกอธิบายอย่างชัดเจนว่าสามารถแสดงถึงพฤติกรรมที่แตกต่างกันในแต่ละบุคคลได้ งานวิจัยนี้ยังได้นำเสนอการกรองข้อมูลช่วงระยะพักและการเตรียมข้อมูลอื่นอีกหลายอย่าง จุดสำคัญอีกอย่างหนึ่งของงานวิจัยนี้คือการวัดประสิทธิภาพของระบบ เนื่องจากการระบุตัวตนขับรถควรมีการวัดผลในหลากหลายแง่มุมเป็นอย่างมาก เช่น ผลจากการระบุคนขับรถโดยมีจำนวนคนขับรถที่ต่างกัน ผลจากการระบุคนขับรถโดยใช้ตัวแยกประเภทแบบอื่น ผลจากการเปลี่ยนจำนวนข้อมูล ผลจากเส้นทาง และผลจากการระบุผู้ไม่พึงประสงค์ เป็นต้น ประสิทธิภาพของระบบในงานวิจัยนี้วัดผลด้วยค่าความแม่นยำเป็นหลัก แต่มีการวัดผลด้วยค่าเอฟวัน พรีซีชัน และรีคอลด้วย ประสิทธิภาพของระบบมีความแม่นยำสูงสุดถึง 99 เปอร์เซ็นต์ อย่างไรก็ตามความแม่นยำควรพิจารณาตามแง่มุมต่าง ๆ ที่ได้นำเสนอไป งานวิจัยนี้นอกจากจะเสนอระบบในการระบุตัวตนขับรถและการวัดประสิทธิภาพดังที่ได้กล่าวมาแล้ว งานวิจัยนี้ยังอาจใช้เป็นแนวทางในการพัฒนาและวัดผลของงานวิจัยเพื่อการระบุตัวตนขับรถที่จะมีการพัฒนาต่อไปในอนาคต

รายการอ้างอิง

- [1] Gartner. (2017, 28 March 2018). *Gartner Says 8.4 Billion Connected "Things" Will Be in Use in 2017, Up 31 Percent From 2016*. Available: <https://www.gartner.com/newsroom/id/3598917>
- [2] Gartner. (2015, 28 March 2018). *Gartner Says By 2020, a Quarter Billion Connected Vehicles Will Enable New In-Vehicle Services and Automated Driving Capabilities*. Available: <https://www.gartner.com/newsroom/id/2970017>
- [3] C. M. Martinez, M. Heucke, F. Y. Wang, B. Gao, and D. Cao, "Driving Style Recognition for Intelligent Vehicle Control and Advanced Driver Assistance: A Survey," *IEEE Transactions on Intelligent Transportation Systems*, vol. 19, no. 3, pp. 666-676, 2018.
- [4] C. Miyajima, Y. Nishiwaki, K. Ozawa, T. Wakita, K. Itou, and K. Takeda, "Cepstral Analysis of Driving Behavioral Signals for Driver Identification," in *2006 IEEE International Conference on Acoustics Speech and Signal Processing Proceedings*, 2006, vol. 5, pp. V-V.
- [5] C. Miyajima *et al.*, "Driver Modeling Based on Driving Behavior and Its Evaluation in Driver Identification," *Proceedings of the IEEE*, vol. 95, no. 2, pp. 427-437, 2007.
- [6] D. Zhang, S. Inagaki, and T. Suzuki, "Robust human motion modeling strategy and its application on driver identification and gait recognition," in *The SICE Annual Conference 2013*, 2013, pp. 1274-1281.
- [7] I. d. Campo, R. Finker, M. V. Martinez, J. Echanobe, and F. Doctor, "A real-time driver identification system based on artificial neural networks and cepstral analysis," in *2014 International Joint Conference on Neural Networks (IJCNN)*, 2014, pp. 1848-1855.
- [8] P. Phumphuang, P. Wuttidittachotti, and C. Saiprasert, "Driver identification using variance of the acceleration data," in *Computer Science and Engineering Conference (ICSEC), 2015 International*, 2015, pp. 1-6: IEEE.

- [9] C. Saiprasert and S. Thajchayapong, "Remote Driver Identification Using Minimal Sensory Data," *IEEE Communications Letters*, vol. 19, no. 10, pp. 1706-1709, 2015.
- [10] A. Burton *et al.*, "Driver identification and authentication with active behavior modeling," in *2016 12th International Conference on Network and Service Management (CNSM)*, 2016, pp. 388-393.
- [11] M. Enev, A. Takakuwa, K. Koscher, and T. Kohno, "Automobile Driver Fingerprinting," *Proceedings on Privacy Enhancing Technologies*, vol. 2016, no. 1, 2016.
- [12] D. Hallac *et al.*, "Driver identification using automobile sensor data from a single turn," in *2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC)*, 2016, pp. 953-958.
- [13] M. V. Martínez, J. Echanobe, and I. d. Campo, "Driver identification and impostor detection based on driving behavior signals," in *2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC)*, 2016, pp. 372-378.
- [14] C. H. Yang, D. Liang, and C. C. Chang, "A novel driver identification method using wearables," in *2016 13th IEEE Annual Consumer Communications & Networking Conference (CCNC)*, 2016, pp. 1-5.
- [15] N. C. Fung *et al.*, "Driver identification using vehicle acceleration and deceleration events from naturalistic driving of older drivers," in *Medical Measurements and Applications (MeMeA), 2017 IEEE International Symposium on*, 2017, pp. 33-38: IEEE.
- [16] S. Jafarnejad, G. Castignani, and T. Engel, "Towards a real-time driver identification mechanism based on driving sensing data," in *2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC)*, 2017, pp. 1-7.
- [17] L. Moreira-Matias and H. Farah, "On Developing a Driver Identification Methodology Using In-Vehicle Data Recorders," *IEEE Transactions on Intelligent Transportation Systems*, vol. 18, no. 9, pp. 2387-2396, 2017.
- [18] A. Chowdhury, T. Chakravarty, A. Ghose, T. Banerjee, and P. Balamuralidhar, "Investigations on Driver Unique Identification from Smartphone's GPS Data

- Alone," *Journal of Advanced Transportation*, vol. 2018, p. 11, 2018, Art. no. 9702730.
- [19] S. Ezzini, I. Berrada, and M. Ghogho, "Who is behind the wheel? Driver identification and fingerprinting," *Journal of Big Data*, vol. 5, no. 1, p. 9, 2018/02/27 2018.
- [20] F. Martinelli, F. Mercaldo, A. Orlando, V. Nardone, A. Santone, and A. K. Sangaiah, "Human behavior characterization for driving style recognition in vehicle system," *Computers & Electrical Engineering*, 2018.
- [21] A. Wahab, C. Quek, C. K. Tan, and K. Takeda, "Driving profile modeling and recognition based on soft computing approach," *IEEE transactions on neural networks*, vol. 20, no. 4, pp. 563-582, 2009.
- [22] T. Banerjee, A. Chowdhury, and T. Chakravarty, "MyDrive: Drive behavior analytics method and platform," in *Proceedings of the 3rd International on Workshop on Physical Analytics*, 2016, pp. 7-12: ACM.



ภาคผนวก

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

ภาคผนวก ก

การระบุตัวคนขับรถก่อนมีการกรอกช่วงระยะพัก

ระบบระบุตัวคนขับรถที่ได้พัฒนาก่อนการมีการกรอกช่วงระยะพักเป็นระบบที่พัฒนาขึ้นในช่วงแรกของงานวิจัย การออกแบบการทดลองมีความแตกต่างจากงานวิจัยที่ได้เสนอไปแล้วเนื่องจากงานวิจัยในช่วงหลังมีการเตรียมข้อมูล และได้ทำการทดลองในมุมมองต่าง ๆ มากกว่าเดิม

ในขั้นตอนการเตรียมข้อมูลนั้น ได้มีการสร้างฮิสโทแกรมโดยการกำหนดค่าต่ำสุด สูงสุด และจำนวนแท่งเช่นกัน โดยใช้ค่าเหมือนกันทั้งหมด แต่ขนาดหน้าตาต่างเลื่อนของฮิสโทแกรมจะกำหนดเป็นระยะเวลาในแต่ละวันคือ ช่วงแรก 7:30 น. ถึง 9:30 น. ช่วงที่สอง 9:00 น. ถึง 12:00 น. ช่วงที่สาม 12:00 น. ถึง 15:00 น. และช่วงสุดท้าย 15:00 น. ถึง 18:00 น. โดยการทดลองจะทำในแต่ละช่วงแยกจากกันเพื่อเป็นการลดผลจากสภาพการจราจร อย่างไรก็ตามภายหลังจากใช้การกรอกช่วงระยะพักพบว่าค่าความแม่นยำเพิ่มขึ้นอย่างมาก จึงไม่มีความจำเป็นจะต้องจำกัดสภาพการจราจรเพื่อให้ระบบสามารถใช้งานได้จริงในทุกสถานการณ์ นอกจากนี้ยังมีส่วนของการลบค่าในฮิสโทแกรมที่มีความผิดพลาดออกซึ่งได้อธิบายในหัวข้อที่ 3.3.3 ส่วนการสกัดพีเจอร์

ในส่วนของโครงข่ายประสาทเทียม ส่วนของชั้นขาเข้าและชั้นขาออกมีโครงสร้างเหมือนกัน เว้นแต่ชั้นซ่อนที่เดิมใช้จำนวนปมเท่ากับค่าเฉลี่ยของผลรวมจำนวนปมในชั้นขาเข้าและชั้นขาออก การวัดประสิทธิภาพของระบบทำโดยใช้การตรวจสอบไขว้แบบ 10 พับเช่นกัน ซึ่งได้ผลดังตารางภาคผนวกที่ 1 โดยประสิทธิภาพของระบบนั้นวัดจากแต่ละช่วงเวลาแยกจากกันดังที่ได้กล่าวไปแล้ว และแสดงค่าความแม่นยำเฉลี่ยของทุกช่วงเวลา นอกจากนั้นยังมีการพิจารณาการใช้จำนวนแกนความเร่งเพิ่มขึ้นอีกด้วย ซึ่งจะเห็นได้ว่าเมื่อใช้แกนความเร่งเพิ่มมากขึ้นส่งผลให้ความแม่นยำเพิ่มขึ้นตามไปด้วย

ตารางภาคผนวกที่ 1 แสดงการผลความแม่นยำ (ในหน่วยเปอร์เซ็นต์) สำหรับการทดลองก่อนใช้การ
กรองช่วงระยะพัก

Time domain	Axis of accelerometer		
	x	x, y	x, y, z
07:30-09:30	72.381	78.780	85.610
09:00-12:00	74.292	85.306	90.408
12:00-15:00	78.400	82.553	88.936
15:00-18:00	75.818	81.961	88.824
Average	75.228	82.150	88.445

ประวัติผู้เขียนวิทยานิพนธ์

นาย ณัฐธัญ วิโรจน์บุญเกียรติ ผู้เขียนวิทยานิพนธ์ เกิดเมื่อวันที่ 9 มกราคม พ.ศ. 2538 ณ จังหวัดกรุงเทพมหานคร สำเร็จการศึกษาระดับมัธยมศึกษาจากโรงเรียน สาธิต มหาวิทยาลัยศรีนครินทรวิโรฒ ประสานมิตร (ฝ่ายมัธยม) สำเร็จการศึกษาระดับปริญญาวิศวกรรมศาสตรบัณฑิต สาขาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย เมื่อปีการศึกษา 2559 ด้วยเกียรตินิยมอันดับสอง ปัจจุบันกำลังศึกษาในหลักสูตรวิศวกรรมศาสตรบัณฑิต สาขาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย โดยได้รับทุนอุดหนุน การศึกษาระดับบัณฑิตศึกษาสำหรับนิสิตเก่าวิศวกรรมศาสตรบัณฑิต สาขาวิศวกรรมคอมพิวเตอร์ จุฬาลงกรณ์มหาวิทยาลัย

