

การพัฒนาแนวทางการสร้างแบบจำลองการประมาณค่าความยาวแถวคอย
บริเวณทางแยกไฟสัญญาณจราจรด้วยข้อมูลแถบสีแสดงสภาพจราจรของ
Google Maps



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชาวิศวกรรมโยธา ขนส่ง และทรัพยากรธรณี
มหาวิทยาลัยเทคโนโลยีสุรนารี
ปีการศึกษา 2565

THE DEVELOPMENT OF A MODELING PROCESS FOR ESTIMATING
QUEUE LENGTHS AT A SIGNALIZED INTERSECTION WITH COLOR-
CODE TRAFFIC DATA FROM GOOGLE MAPS



PROMPORN SORNSOONGNERN

A Thesis Submitted in Partial Fulfillment of the Requirements for the
Degree of Master of Engineering in Civil, Transportation and
Geo-resources Engineering
Suranaree University of Technology
Academic Year 2022

การพัฒนาแนวทางการสร้างแบบจำลองการประมาณค่าความยาวแฉกคอบริเวณทาง
แยกไฟสัญญาณจราจรด้วยข้อมูลแถบสีแสดงสภาพจราจรของ Google Maps

มหาวิทยาลัยเทคโนโลยีสุรนารี อนุมัติให้บัณฑิตวิทยาลัยฯ เป็นส่วนหนึ่งของการศึกษา
ตามหลักสูตรปริญญาโทบริหารธุรกิจ

คณะกรรมการสอบวิทยานิพนธ์

(อ. ดร.ณัฐภรณ์ เจริญธรรม)

ประธานกรรมการ

(ผศ. ดร.รัฐพล ภูบุบผาพันธ์)

กรรมการ (อาจารย์ที่ปรึกษาวิทยานิพนธ์)

(ศ. ดร.ธเนศ เสถียรนาม)

กรรมการ

(อ. ดร.ไอศูรย์ เรืองรัตนอมพร)

กรรมการ

(อ. ดร.สุธาทิพย์ ภูบุบผาพันธ์)

กรรมการ

(รศ. ดร.ยุพาพร รักสกุลพิวัฒน์)

รองอธิการบดีฝ่ายวิชาการและประกันคุณภาพ

(รศ. ดร.พรศิริ จงกล)

คณบดีสำนักวิชาวิศวกรรมศาสตร์

พรหมพร ศรสูงเนิน : การพัฒนาแนวทางการสร้างแบบจำลองการประมาณค่าความยาว
แถวคอยบริเวณทางแยกไฟสัญญาณจราจรด้วยข้อมูลแถบสีแสดงสภาพจราจรของ Google
Maps (THE DEVELOPMENT OF A MODELING PROCESS FOR ESTIMATING QUEUE
LENGTHS AT A SIGNALIZED INTERSECTION WITH COLOR-CODE TRAFFIC DATA
FROM GOOGLE MAPS)

อาจารย์ที่ปรึกษา : ผู้ช่วยศาสตราจารย์ ดร.รัฐพล ภูบุบผาพันธ์, 96 หน้า.

คำสำคัญ : ระยะเวลาความยาวแถวคอย/Google Maps/Random Forest/Gradient Boosting
Machine/Variable Importance/ทางแยกที่มีไฟสัญญาณจราจร/ระบบไฟสัญญาณจราจรให้สิทธิ
ผ่านทางพิเศษ

ทางแยกที่มีไฟสัญญาณจราจรเป็นเหตุผลสำคัญที่ส่งผลต่อความล่าช้าของรถฉุกเฉิน
(Emergency Vehicle) ในต่างประเทศได้มีการพัฒนาระบบไฟสัญญาณจราจรที่สามารถให้สิทธิพิเศษ
ในการผ่านทางแก่รถฉุกเฉิน โดยข้อมูลนำเข้าที่สำคัญตัวหนึ่งได้แก่ระยะเวลาความยาวของแถวคอยที่
บริเวณทางแยก งานวิจัยในอดีตส่วนใหญ่ที่ทำการศึกษการประมาณค่าความยาวแถวคอยมักจะใช้
ทฤษฎี shock wave ควบคู่กับการใช้ข้อมูลจาก detector อย่างไรก็ตาม การศึกษาในอดีตล่าสุดได้มี
การสร้างแบบจำลองการประมาณค่าความยาวแถวคอยจากข้อมูลแถบสีของ Google Maps โดย
ผลลัพธ์แสดงให้เห็นว่าการใช้ข้อมูลแถบสีของ Google Maps ให้ผลได้ดีในระดับหนึ่ง ดังนั้นการศึกษา
ส่วนแรกของวิทยานิพนธ์ฉบับนี้จึงได้ทำการพัฒนาปรับปรุงแบบจำลองการประมาณความยาว
แถวคอยด้วยการปรับเปลี่ยนรูปแบบของตัวแปรแถบสีใหม่และพิจารณาเปรียบเทียบกับวิธีการสร้าง
แบบจำลองใหม่ ซึ่งได้แก่ วิธี Gradient Boosting Machine ผลลัพธ์ที่ได้จากการศึกษาในส่วนแรกนี้
แสดงให้เห็นว่าตัวแปรรูปแบบใหม่และวิธีการสร้างแบบจำลองวิธีใหม่ ส่งผลให้แบบจำลองประมาณค่า
ความยาวแถวคอยมีประสิทธิภาพการทำนายที่ดีขึ้น โดยแบบจำลองจากข้อมูลแถบสีฝั่งที่ไม่มี
ไฟสัญญาณจราจรก่อนหน้านี้จะมีประสิทธิภาพการทำนายที่ดีกว่าฝั่งที่มีไฟสัญญาณจราจรก่อนหน้านี้
และตัวแปรแถบสีแดงซึ่งสะท้อนสภาพจราจรที่ใช้ความเร็วต่ำนั้นมีความสำคัญต่อการสร้าง
แบบจำลองเป็นอันดับหนึ่ง

อย่างไรก็ตาม ผลการศึกษาพบว่าแบบจำลองการประมาณค่าความยาวแถวคอยจาก
การศึกษาส่วนแรกยังคงมีค่าความคลาดเคลื่อนที่สูง ดังนั้นการศึกษาส่วนที่สองของวิทยานิพนธ์ฉบับนี้
จึงได้ทำการวิเคราะห์เพิ่มเติมเกี่ยวกับผลกระทบของความละเอียดในการประมวลผลเส้นแถบสีต่อ
ประสิทธิภาพการทำนายของแบบจำลอง โดยมุ่งเน้นพิจารณาปัจจัยความละเอียดสองส่วน ได้แก่ 1)
ความละเอียดด้านระยะเวลา (ความล่าช้าในการประมวลผลและแสดงแถบสี) หมายถึง ช่วงระยะเวลา
นับตั้งแต่ระบบได้รับข้อมูลความเร็วของรถบนช่วงถนนจนกระทั่งระบบประมวลผลเสร็จและแสดงเป็น

ข้อมูลแถบสี และ 2) ความละเอียดด้านระยะทาง (การแบ่งระยะความยาวช่วงถนนสำหรับการประมวลผล) หมายถึง ระยะความยาวของช่วงถนนที่ระบบใช้ในการประมวลผลและแสดงแถบสี โดยความยาวของแถบสีที่ระบบแสดงออกมาจะมีระยะความยาวเป็นจำนวนเท่าของระยะการแบ่งช่วงถนนนี้ โดยผลลัพธ์ที่ได้จากการศึกษาส่วนที่สองแสดงให้เห็นว่าการใช้ข้อมูลแถบสีเฉพาะช่วงไฟจราจรสีแดงในกรณีที่ปัจจัยความละเอียดด้านเวลาและระยะทางมีความละเอียดสูงจะส่งผลให้แบบจำลองประมาณค่าความยาวแถวคอยมีประสิทธิภาพการทำนายที่ดีมากยิ่งขึ้น โดยตัวแปรแถบสีแดงเข้มและตัวแปรแถบสีแดงยังคงมีความสำคัญมากเป็นอันดับหนึ่งในการสร้างแบบจำลอง

ผลจากการศึกษาทั้งสองส่วนนี้เป็นการแสดงให้เห็นว่าตัวแปรแถบสีสามารถนำไปใช้ในการสร้างแบบจำลองประมาณค่าความยาวแถวคอยได้ แต่แบบจำลองจะให้ประสิทธิภาพการทำนายแม่นยำในกรณีที่การประมวลผลเพื่อสร้างแถบสีมีความละเอียดด้านเวลาและระยะทางที่สูงมากพอ ซึ่งในอนาคตมีความเป็นไปได้ที่ทางผู้ให้บริการข้อมูลแผนที่และเส้นสีแดงแสดงสภาพจราจร เช่น Google Maps จะสามารถพัฒนาและปรับปรุงประสิทธิภาพในการแสดงผลของข้อมูลแถบสีเหล่านี้ให้รวดเร็วและมีความละเอียดมากขึ้น ดังนั้นวิธีการประมาณค่าระยะความยาวแถวคอย โดยใช้ข้อมูลแถบสีเหล่านี้จะเป็นทางเลือกที่เป็นประโยชน์และสะดวกในอนาคตได้อีกวิธีหนึ่ง



มหาวิทยาลัยเทคโนโลยีสุรนารี

สาขาวิชาวิศวกรรมขนส่ง

ปีการศึกษา 2565

ลายมือชื่อนักศึกษา..... พรทมนธ์

ลายมือชื่ออาจารย์ที่ปรึกษา.....

PROMPORN SORN SOONGNERN : THE DEVELOPMENT OF A MODELING PROCESS FOR ESTIMATING QUEUE LENGTHS AT A SIGNALIZED INTERSECTION WITH COLOR-CODE TRAFFIC DATA FROM GOOGLE MAPS. THESIS ADVISOR : ASST. PROF. RATTAPHOL PUEBOOBPAPHAN, Ph.D., 96 PP.

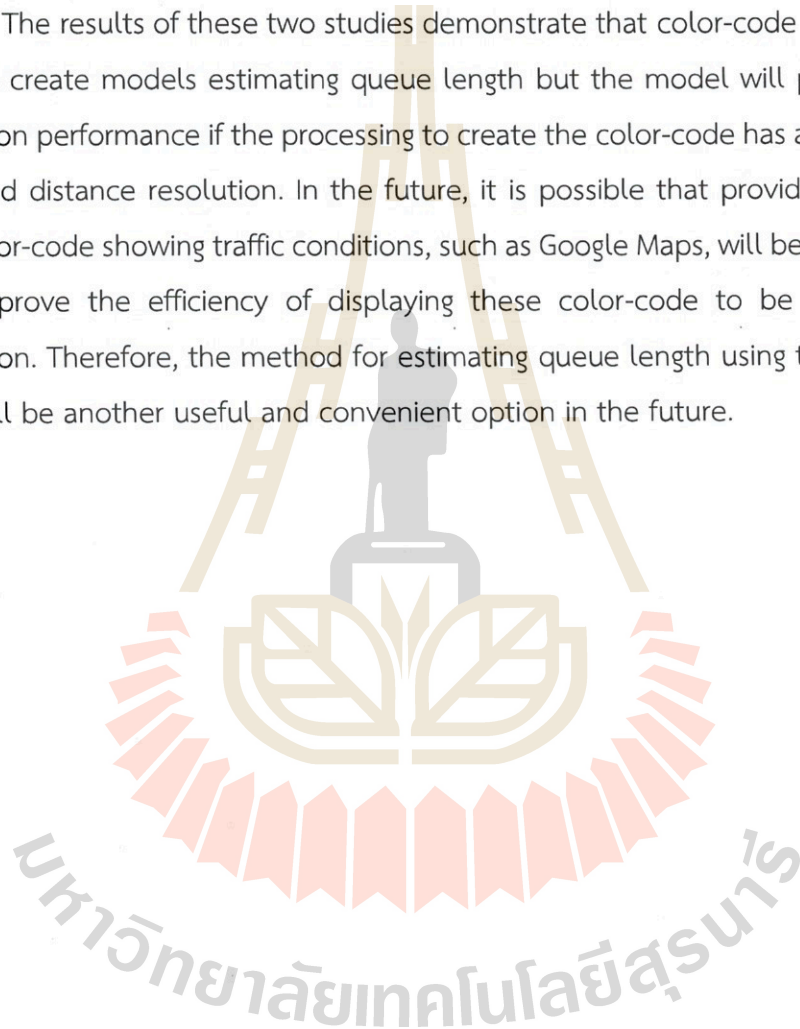
Keyword : QUEUE LENGTH/GOOGLE MAPS/RANDOM FOREST/GRADIENT BOOSTING MACHINE/VARIABLE IMPORTANCE/SIGNALIZED INTERSECTION/TRAFFIC SIGNAL PRIORITY

Signalized intersections are an important reason that affects emergency vehicle delays. In other countries, traffic-signal priority systems have been developed that give special right of way to emergency vehicles. One important input is the queue length at signalized intersections. Most past studies investigating queue length estimation have used shock wave theory along with detector data. However, recent past studies have created models estimating queue lengths from color-code data of Google Maps. The results show that using Google Maps' color-code data has good results to a certain extent. Therefore, the first part of this thesis was to develop and improve the queue length estimation model by modifying the type of the color-code variable and comparing it with a new modeling method, namely the Gradient Boosting Machine method. The results of this first part of the study show that new type variables and new modeling methods result in better prediction performance for the queue length estimation model. The model using color-code data on the direction without a prior signalized intersection has better prediction performance than the direction with a prior signalized intersection. The red code-code, which reflects low-speed traffic conditions, is the number one priority for modeling.

However, the study found that the first part of the queue length estimation model still had high errors. Therefore, the second part of this thesis further analyzed the effect of the color-code processing resolution on the prediction performance of the model. It focuses on considering two resolutions: 1) time resolution (Delay in processing and displaying color-code) refers to the period of time from when the system receives vehicle speed data on a road until the system finishes processing and displaying the color-codes, and 2) distance resolution (Road segment length division for processing) refers to the road segment length that the system uses to process, and

display color-codes. The length of the color-code displayed by the system will be a number of times the distance of this road segmentation. The results from the second study show that using color-code data only during red traffic signals in cases where the time and distance resolution factors are high will result in a better prediction performance for the queue length estimating model. The dark red and red color-code variables are still the most important in modeling.

The results of these two studies demonstrate that color-code variables can be used to create models estimating queue length but the model will provide accurate prediction performance if the processing to create the color-code has a sufficiently high time and distance resolution. In the future, it is possible that providers of map data and color-code showing traffic conditions, such as Google Maps, will be able to develop and improve the efficiency of displaying these color-code to be faster and high resolution. Therefore, the method for estimating queue length using these color-code data will be another useful and convenient option in the future.



School of Transportation Engineering
Academic Year 2022

Student's Signature.....
Advisor's Signature.....

นรพนธ์
[Handwritten signature]

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงด้วยดีอย่างสมบูรณ์ ผู้วิจัยขอกราบขอบพระคุณ บุคคลและกลุ่มบุคคลต่าง ๆ ที่ได้ให้ความเมตตา ช่วยเหลือดูแล ให้คำปรึกษาและคำชี้แนะต่าง ๆ ทั้งในด้านวิชาการและการดำเนินงานวิจัย

ขอกราบขอบพระคุณ ผศ. ดร. รัฐพล ภูบุบผาพันธ์ อาจารย์ที่ปรึกษาวิทยานิพนธ์ ที่ให้ความรู้ทั้งในด้านวิชาการและการดำเนินงานวิจัย คอยให้คำแนะนำและช่วยเหลือในการเขียน การตรวจแก้วิทยานิพนธ์หรือบทความวิจัย และสนับสนุนค่าใช้จ่ายต่าง ๆ ในการวิจัย

ขอกราบขอบพระคุณ ดร. สุชาติพิทย์ ภูบุบผาพันธ์ ที่ช่วยเหลือในการเขียนและตรวจสอบแก้ไขบทความวิจัยจนสามารถส่งตีพิมพ์สำเร็จลุล่วงได้ด้วยดี

ขอกราบขอบพระคุณ ดร. ณัฐภรณ์ เจริญธรรม ศ. ดร. ธเนศ เสถียรนาม ดร. ไอลูรีย์ เรืองรัตน์อัมพร และ ดร. สุชาติพิทย์ ภูบุบผาพันธ์ ที่กรุณามาเป็นกรรมการในการสอบวิทยานิพนธ์ อีกทั้งให้ความรู้และคำแนะนำในการเขียนวิทยานิพนธ์และการดำเนินงานวิจัย

คุณวันเพ็ญ สืบสาย อดีตเลขานุการ สาขาวิศวกรรมขนส่ง มหาวิทยาลัยเทคโนโลยีสุรนารี และคุณปิยธิดา ปัญหาราช เลขานุการคนปัจจุบัน ที่ให้ความช่วยเหลือในการประสานงานด้านเอกสารต่าง ๆ ระหว่างการศึกษาและการจัดทำวิทยานิพนธ์

ขอขอบคุณนายพงศ์พัฒน์ จอดนอก ที่ให้คำปรึกษา คำแนะนำต่าง ๆ และความช่วยเหลือในการทำงานวิจัย

ขอขอบคุณนักศึกษาวิศวกรรมขนส่งปี 4 ที่ได้ให้ความช่วยเหลือในการทำงานวิจัย

สุดท้ายนี้ขอกราบขอบพระคุณ บิดา มารดา ที่ให้การเลี้ยงดู อบรม พร้อมทั้งส่งเสริมการศึกษาเป็นอย่างดีมาตลอด และเป็นกำลังใจให้ข้าพเจ้าจนกระทั่งสามารถดำเนินการทำวิทยานิพนธ์ฉบับนี้จนสำเร็จสมบูรณ์

พรหมพร ศรสูงเนิน

สารบัญ

หน้า

| | |
|-----------------------------------------------------------------------------------------------------|----------|
| บทคัดย่อ (ภาษาไทย)..... | ก |
| บทคัดย่อ (ภาษาอังกฤษ)..... | ค |
| กิตติกรรมประกาศ..... | จ |
| สารบัญ..... | ฉ |
| สารบัญตาราง..... | ณ |
| สารบัญรูป..... | ญ |
| บทที่ | |
| 1 บทนำ | 1 |
| 1.1 ที่มาและความสำคัญของงานวิจัย..... | 1 |
| 1.2 วัตถุประสงค์งานวิจัย..... | 3 |
| 1.3 คำถามงานวิจัย..... | 4 |
| 1.4 ขอบเขตงานวิจัย..... | 4 |
| 1.5 ประโยชน์ที่คาดว่าจะได้รับ..... | 5 |
| 1.6 โครงสร้างของวิทยานิพนธ์..... | 5 |
| 1.7 เอกสารอ้างอิง..... | 6 |
| 2 นวัตกรรมใหม่ของการประมาณค่าระยะความยาวแถวคอยแบบพลวัตโดยใช้ข้อมูลแถบสีของ GOOGLE MAPS | 8 |
| 2.1 บทคัดย่อ..... | 8 |
| 2.2 บทนำ..... | 9 |
| 2.3 การสำรวจและเก็บข้อมูล..... | 11 |
| 2.3.1 การสำรวจเก็บข้อมูลแถบสีจาก Google maps..... | 12 |
| 2.3.2 การสำรวจข้อมูลระยะความยาวแถวคอยจริง..... | 13 |
| 2.3.3 การประมวลผลข้อมูล..... | 14 |
| 2.3.4 การสร้างแบบจำลองการประมาณค่าระยะความยาวแถวคอย..... | 16 |
| 2.4 ผลลัพธ์และการอภิปราย..... | 20 |
| 2.4.1 ประสิทธิภาพของแบบจำลองการประมาณความยาวแถวคอย..... | 20 |

สารบัญ (ต่อ)

หน้า

| | | |
|----------|---------------------------------------------------------------------------------------------------------|-----------|
| 2.4.2 | Variable Importance (VI)..... | 24 |
| 2.5 | สรุป..... | 27 |
| 2.6 | เอกสารอ้างอิง..... | 28 |
| 3 | การวิเคราะห์ผลของปัจจัยความละเอียดด้านเวลาและระยะทางของการประมวลผล | |
| | ข้อมูลแถบสีแสดงสภาพจราจรต่อการประมาณค่าระยะความยาวแถวคอย | 33 |
| 3.1 | บทคัดย่อ | 33 |
| 3.2 | บทนำ | 35 |
| 3.3 | ข้อมูลการศึกษา | 37 |
| 3.3.1 | แบบจำลองจราจร..... | 37 |
| 3.3.2 | การสกัดข้อมูลที่ได้จากโปรแกรม Aimsun..... | 39 |
| 3.3.3 | ตัวแปร..... | 42 |
| 3.4 | การสร้างแบบจำลองประมาณค่าระยะความยาวแถวคอย | 43 |
| 3.5 | ผลของความละเอียดด้านเวลาและระยะทางต่อประสิทธิภาพการทำนายของ แบบจำลองประมาณค่าระยะความยาวแถวคอย | 44 |
| 3.5.1 | Root Mean Square error (RMSE)..... | 44 |
| 3.5.2 | กราฟประมาณค่าระยะความยาวแถวคอยเทียบกับระยะแถวคอยจริง | 45 |
| 3.5.3 | Variable importance (VI)..... | 53 |
| 3.5.4 | การตัดค่า Outlier..... | 57 |
| 3.6 | สรุปผลงานวิจัย..... | 67 |
| 3.7 | เอกสารอ้างอิง..... | 69 |
| 4 | สรุปผลการวิจัยและข้อเสนอแนะ | 74 |
| 4.1 | สรุป..... | 74 |
| 4.1.1 | นวัตกรรมใหม่ของการประมาณค่าระยะความยาวแถวคอยแบบพลวัตโดยใช้ ข้อมูลแถบสีของ Google Maps..... | 74 |

สารบัญ (ต่อ)

หน้า

| | | |
|---------|------------------------------------------------------------------------------------------------------------------------------------------|----|
| 4.1.2 | การวิเคราะห์ผลของปัจจัยความละเอียดด้านเวลาและระยะทางของการ ประมวลผลข้อมูลแถบสีแสดงสภาพจราจรต่อการประมาณค่าระยะความยาว แถวคอย | 75 |
| 4.2 | ข้อเสนอแนะ | 76 |
| ภาคผนวก | | 77 |
| | ภาคผนวก ก บทความวิชาการที่ได้รับการตีพิมพ์เผยแพร่ในระหว่างศึกษา..... | 78 |
| | ประวัติผู้เขียน..... | 96 |

สารบัญตาราง

| ตารางที่ | หน้า |
|---------------------------------------------------------------------|------|
| 2.1 ข้อมูลตัวอย่างที่ได้รับจาก Google Maps..... | 13 |
| 2.2 ตัวแปรแถบสีที่ถูกปรับเปลี่ยนใหม่..... | 15 |
| 2.3 ค่า RMSE และ MAPE ของทุกแบบจำลอง..... | 21 |
| 2.4 ค่า Variable Importance (VI) ของ Scenario 3 ด้วยตัวแปร IV3..... | 24 |
| 3.1 จำนวนตัวแปรแถบสีตามปัจจัยความละเอียดด้านระยะทาง..... | 43 |
| 3.2 ค่า RMSE จากแบบจำลอง..... | 44 |
| 3.3 ค่า RMSE จากแบบจำลองที่ตัดค่า Outlier..... | 58 |

สารบัญรูป

| รูปที่ | หน้า |
|--------|----------------------------------------------------------------------------------------------------------------------------------------------|
| 1.1 | ภาพรวมขั้นตอนการทำงานของวิทยานิพนธ์..... 6 |
| 2.1 | พื้นที่สำรวจ แผนที่พื้นหลังบันทึกจาก maps.google.com เข้าถึงเมื่อวันที่ 10 มกราคม พ.ศ. 2566..... 12 |
| 2.2 | ตัวอย่างการวัดความยาวโดยใช้ข้อมูลแถบสีของ Google Maps แผนที่พื้นหลังบันทึกจาก maps.google.com เข้าถึงเมื่อวันที่ 10 มกราคม พ.ศ. 2566..... 13 |
| 2.3 | การกระจายตัวของผู้สำรวจและกล้องวิดีโอในพื้นที่สำรวจ 14 |
| 2.4 | สมการการตั้งชื่อตัวแปร 15 |
| 2.5 | Scenarios และแบบจำลองที่ใช้ในการประมาณค่าความยาวแฉาคอย..... 17 |
| 2.6 | ขั้นตอนการสร้างแบบจำลองและการวิเคราะห์โดยรวม..... 19 |
| 2.7 | ค่า RMSE สำหรับ IV3 ของแต่ละวิธีและ scenario..... 21 |
| 2.8 | ค่า MAPE สำหรับ IV3 ของแต่ละวิธีและ scenario 22 |
| 2.9 | ผลลัพธ์การประมาณค่าใน scenario 3 ด้วย IV3 โดยใช้วิธี Average..... 22 |
| 2.10 | ผลลัพธ์การประมาณค่าใน scenario 3 ด้วย IV3 โดยใช้วิธี RF..... 23 |
| 2.11 | ผลลัพธ์การประมาณค่าใน scenario 3 ด้วย IV3 โดยใช้วิธี GBM..... 23 |
| 2.12 | ค่า Variable Importance (VI) ของ Model 4, Scenario 3 ด้วยตัวแปร IV3..... 24 |
| 2.13 | ค่า Variable Importance (VI) ของ Model 5, Scenario 3 ด้วยตัวแปร IV3..... 25 |
| 2.14 | ค่า Variable Importance (VI) ของ Model 6, Scenario 3 ด้วยตัวแปร IV3..... 25 |
| 2.15 | ค่า Variable Importance (VI) ของ Model 7, Scenario 3 ด้วยตัวแปร IV3..... 25 |
| 3.1 | แบบจำลองจราจรบนโปรแกรม Aimsun..... 38 |
| 3.2 | ปริมาณจราจรบนโปรแกรม Aimsun 39 |
| 3.3 | ขั้นตอนการสกัดตัวแปรความยาวแฉาคอยจริง..... 41 |
| 3.4 | ขั้นตอนการสกัดตัวแปรความยาวแถบสี..... 42 |
| 3.5 | กราฟความยาวแฉาคอยจริงเปรียบเทียบกับความยาวแฉาคอยที่ได้จากแบบจำลอง กรณีที่ไม่มี ความล่าช้าและความทุก ๆ 25 เมตร 46 |
| 3.6 | กราฟความยาวแฉาคอยจริงกับความยาวแฉาคอยที่ได้จากแบบจำลองเทียบตามเวลา กรณีที่ ไม่มี ความล่าช้าและแบ่งช่วงถนนทุก ๆ 25 เมตร..... 46 |

สารบัญรูป (ต่อ)

| รูปที่ | หน้า |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------|------|
| 3.21 กราฟ Variable importance กรณีปัจจัยความละเอียดด้านเวลา 0 วินาที และความละเอียดด้านระยะทาง 25 เมตร | 54 |
| 3.22 กราฟ Variable importance กรณีปัจจัยความละเอียดด้านเวลา 10 วินาที และความละเอียดด้านระยะทาง 25 เมตร | 54 |
| 3.23 กราฟ Variable importance กรณีปัจจัยความละเอียดด้านเวลา 20 วินาที และความละเอียดด้านระยะทาง 25 เมตร | 55 |
| 3.24 กราฟ Variable importance กรณีปัจจัยความละเอียดด้านเวลา 30 วินาที และความละเอียดด้านระยะทาง 25 เมตร | 55 |
| 3.25 กราฟ Variable importance กรณีปัจจัยความละเอียดด้านเวลา 60 วินาที และความละเอียดด้านระยะทาง 25 เมตร | 56 |
| 3.26 กราฟ Variable importance กรณีปัจจัยความละเอียดด้านเวลา 0 วินาที และความละเอียดด้านระยะทาง 50 เมตร | 56 |
| 3.27 กราฟ Variable importance กรณีปัจจัยความละเอียดด้านเวลา 0 วินาที และความละเอียดด้านระยะทาง 100 เมตร | 57 |
| 3.28 กราฟ Variable importance กรณีปัจจัยความละเอียดด้านเวลา 0 วินาที และความละเอียดด้านระยะทาง 200 เมตร | 57 |
| 3.29 กราฟความยาวแถวคอยจริงเปรียบเทียบกับความยาวแถวคอยที่ได้จากการทดสอบตัดค่า Outlier กรณีที่ไม่มีความล่าช้าและแบ่งช่วงถนนทุก ๆ 25 เมตร | 58 |
| 3.30 กราฟความยาวแถวคอยจริงกับความยาวแถวคอยที่ได้จากแบบจำลองเทียบตามเวลาที่ได้จากการทดสอบตัดค่า Outlier กรณีที่ไม่มีความล่าช้าและแบ่งช่วงถนนทุก ๆ 25 เมตร | 59 |
| 3.31 กราฟความยาวแถวคอยจริงเปรียบเทียบกับความยาวแถวคอยที่ได้จากการทดสอบตัดค่า Outlier กรณีที่มีความล่าช้า 10 วินาทีและแบ่งช่วงถนนทุก ๆ 25 เมตร | 59 |
| 3.32 กราฟความยาวแถวคอยจริงกับความยาวแถวคอยที่ได้จากแบบจำลองเทียบตามเวลาที่ได้จากการทดสอบตัดค่า Outlier กรณีที่มีความล่าช้า 10 วินาทีและแบ่งช่วงถนนทุก ๆ 25 เมตร | 60 |
| 3.33 กราฟความยาวแถวคอยจริงเปรียบเทียบกับความยาวแถวคอยที่ได้จากการทดสอบตัดค่า Outlier กรณีที่มีความล่าช้า 20 วินาทีและแบ่งช่วงถนนทุก ๆ 25 เมตร | 60 |

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญของงานวิจัย

แอมบูแลนซ์บริเวณทางแยกเป็นหนึ่งในปัจจัยที่ส่งผลต่อการจราจรบริเวณทางแยกที่มีไฟสัญญาณจราจร ถ้าสามารถประมาณค่าความยาวแอมบูแลนซ์ได้อย่างแม่นยำและทันการณ์ได้มากเท่าไร จะยิ่งทำให้สามารถทราบและจัดการกับสภาพการจราจรได้ทันท่วงที โดยเฉพาะอย่างยิ่งในกรณีของรถฉุกเฉิน (Emergency Vehicle) ซึ่งเป็นรถที่ใช้ในการเดินทางรับ-ส่งผู้ป่วยฉุกเฉินที่ต้องใช้ความเร็วในการรับผู้ป่วยจากที่เกิดเหตุและนำส่งโรงพยาบาลให้ทันท่วงทีก่อนที่ผู้ป่วยจะมีอาการหนักมากขึ้น ในต่างประเทศมีการพัฒนาระบบไฟสัญญาณจราจรที่สามารถตรวจจับการมาถึงและให้สิทธิพิเศษในการผ่านทางแอมบูแลนซ์ โดยจะมีการปล่อยสัญญาณไฟเขียวล่วงหน้า เพื่อระบายแอมบูแลนซ์และปรับสภาพการจราจรในทิศทางเดียวกันกับรถฉุกเฉินให้คล่องตัวมากขึ้น ให้รถฉุกเฉินสามารถเดินทางได้ราบรื่นโดยไม่ต้องจอดติดอยู่บนถนนเป็นเวลานาน โดยองค์ประกอบที่สำคัญส่วนหนึ่งของระบบดังกล่าวได้แก่ การตรวจวัดความยาวแอมบูแลนซ์ที่บริเวณทางแยก เพื่อวิเคราะห์หาระยะเวลาล่วงหน้าที่เหมาะสมในการเปิดสัญญาณไฟเขียวก่อนที่รถฉุกเฉินจะมาถึง เพื่อระบายรถที่จอดติดอยู่ในแอมบูแลนซ์ไม่ให้เกิดขวางรถฉุกเฉิน

ในอดีตมีงานวิจัยที่ทำการศึกษเกี่ยวกับการประมาณความยาวแอมบูแลนซ์บริเวณทางแยกไฟสัญญาณจราจรอยู่มากมาย ซึ่งวิธีที่มักใช้กันโดยทั่วไปคือการใช้ทฤษฎี shock wave ในการคำนวณความเร็วคลื่นกระแทกร่วมกับการพิจารณาความผันแปรของความยาวแอมบูแลนซ์ โดยใช้ข้อมูลจาก detector ที่ติดตั้งบริเวณทางแยก (Bae, Liu, Han, & Bozdogan, 2019; Noaeen, Mohajerpour, H. Far, & Ramezani, 2021; Yang, Wu, Du, He, & Chen, 2017) อย่างไรก็ตามในประเทศไทยยังไม่ได้มีการติดตั้ง detector ครอบคลุมถนนในทุกพื้นที่ เพราะฉะนั้นการจะใช้ข้อมูลจาก detector ในการประมาณความยาวแอมบูแลนซ์ในประเทศไทยอาจไม่สามารถทำได้ แต่งานวิจัยในปี พ.ศ. 2564 ของพงศ์พัฒน์ จอดนอก และรัฐพล ภูบุบผาพันธ์ (2564) ได้ใช้ข้อมูลแถบสีแสดงสภาพการจราจรซึ่งมี 4 สี ได้แก่ สีแดงเข้ม สีแดง สีส้ม และสีเขียว ของ Google Maps ซึ่งเป็นแหล่งข้อมูลที่สามารถเข้าถึงได้ง่ายและครอบคลุมแทบทุกพื้นที่ในประเทศไทยมาสร้างแบบจำลองเพื่อประมาณค่าระยะความยาวแอมบูแลนซ์ที่บริเวณทางแยกโดยเปรียบเทียบวิธีการที่แตกต่างกัน 3 วิธี ได้แก่ Linear regression, Random Forest Model และวิธีการใช้ค่าเฉลี่ยความยาวแอมบูแลนซ์ในอดีต สร้างแบบจำลองแยกตาม

ช่วงเวลาเร่งด่วนและช่วงเวลาไม่เร่งด่วน โดยพบว่าการประมาณค่าระยะความยาวแถวคอยโดยใช้ข้อมูลแถบสีให้ผลดีในระดับหนึ่งและวิธี Random Forest Model เป็นวิธีที่มีค่าความคลาดเคลื่อนต่ำกว่าวิธีอื่น

ข้อมูลแถบสีจาก Google Maps ถูกนำไปประยุกต์ใช้ในงานวิจัยต่าง ๆ มากมาย เช่น การใช้ข้อมูลแถบสีและเวลาเดินทางจาก Google Maps เพื่อปรับระยะเวลาไฟสัญญาณจราจรให้มีการตอบสนองใกล้เคียงสภาพการจราจรจริงมากที่สุด (Mishra, Bhattacharya, & Gupta, 2018) คาดการณ์สภาพการจราจรสำหรับถนนในเมือง (Rezzouqi, Gryech, Sbihi, Ghogho, & Benbrahim, 2019) กำหนดดัชนีความแออัด (Nair, Gilles, Chand, Saxena, & Dixit, 2019) อย่างไรก็ตาม ถึงแม้ว่าจะมีการนำข้อมูลแถบสีไปใช้บ้างในงานวิจัยแต่ก็ยังเป็นจำนวนน้อย และยังไม่มีการใช้เพื่อประมาณค่าระยะความยาวแถวคอยมาก่อน

วิทยานิพนธ์เล่มนี้ต่อยอดจากงานวิจัยของพงศ์พัฒน์ จอดนอก และรัฐพล ภูบุบผาพันธ์ (2564) และวิทยานิพนธ์ของพงศ์พัฒน์ จอดนอก (2563) การทดสอบเปรียบเทียบประสิทธิภาพการใช้ข้อมูลแถบสีของ Google Maps จึงเป็นเป้าหมายประการแรกของวิทยานิพนธ์เล่มนี้ โดยทำการสกัดข้อมูลจากแถบสีของ Google Maps ในรูปแบบใหม่ เพื่อสร้างตัวแปรใหม่ สำหรับนำเข้าไปแบบจำลองด้วยวิธีการใหม่ ซึ่งสามารถทำได้หลากหลายแนวทาง และอาจทำให้ได้ผลของการทดสอบประสิทธิภาพที่แตกต่างกัน จากการสังเกตข้อมูลแถบสี Google Maps ในระหว่างการจับภาพบนหน้าจอคอมพิวเตอร์นั้นพบว่า จำนวนครั้งที่ Google Maps แสดงแถบสีแดงเข้ม และแถบสีแดงมีจำนวนน้อยอย่างมีนัยสำคัญเมื่อเทียบกับสีอื่น ๆ ดังนั้นจึงมีการพิจารณาเปรียบเทียบแนวทางการสกัดข้อมูลในรูปแบบอื่นเพิ่มเติม ซึ่งได้รูปแบบของตัวแปรแถบสี 3 รูปแบบ ได้แก่ 1) แบบดั้งเดิมที่มีจำนวน 4 สี ได้แก่ สีแดงเข้ม สีแดง สีส้ม และสีเขียว, 2) แบบรวมตัวแปรแถบสีแดงเข้ม และสีแดงเข้าด้วยกัน เปรียบเสมือนเป็นสีเดียวกัน เพื่อเป็นตัวแทนแสดงถึงสภาพจราจรที่ติดขัดเพียงสีเดียว, และ 3) แบบรวมตัวแปรแถบสีแดงเข้ม และสีแดง รวมทั้งพิจารณาตัดตัวแปรแถบสีเขียวออกโดยพิจารณาเสมือนสีเขียวเป็นสีอ้างอิง นอกเหนือจากการสกัดข้อมูลตัวแปรแถบสีใหม่ ยังมีการพิจารณาวิธีการสร้างแบบจำลองด้วย Machine learning วิธีอื่น ได้แก่ Gradient Boosting Machine (GBM) ซึ่งม้งานวิจัยจำนวนมากที่พบว่าให้ผลการทำนายที่ดีกว่าเมื่อเปรียบเทียบกับวิธีอื่น (Navarro-Espinoza et al., 2022; Xu et al., 2022) และ GBM ยังสามารถคำนวณหาค่า Variable Importance เพื่อเปรียบเทียบตัวแปรที่มีความสำคัญต่อการสร้างแบบจำลองได้ ทั้งนี้เพื่อให้ได้รูปแบบการสกัดข้อมูลและวิธีการที่เหมาะสมและมีประสิทธิภาพต่อไป แบบจำลองในงานวิจัยนี้จะทำการสร้างแบบจำลองโดยแบ่งพิจารณาตามฝั่งที่มี/ไม่มีไฟสัญญาณจราจรก่อนหน้า และแบ่งย่อยพิจารณาตามช่วงเวลาเร่งด่วนและไม่เร่งด่วนอีกด้วย

อย่างไรก็ตาม เนื่องจากข้อมูลที่มีการเปิดเผยจากทาง Google Maps นั้นระบุรายละเอียดเพียงคร่าว ๆ ว่าได้ทำการเก็บข้อมูลความเร็วของยานพาหนะที่อยู่บนถนนจากการที่ผู้ขับขี่เปิด GPS แล้วนำไปประมวลผลและแสดงแถบสีที่เป็นตัวแทนของค่าเฉลี่ยความเร็วออกมาตามช่วงถนนนั้น ๆ แต่ไม่มีการเปิดเผยว่า Google Maps กำหนดความเร็วของแต่ละแถบสีอยู่ที่ช่วงใดมีค่าเท่าไร และความเร็วในการประมวลผลจนกระทั่งแสดงผลใช้ระยะเวลาานานเท่าใด เกิดความล่าช้านับจากเวลาที่รวบรวมข้อมูลไปนานเท่าใด ความละเอียดด้านระยะทางแสดงได้ละเอียดมากที่สุดเท่าไร ซึ่งประเด็นด้านการแบ่งความยาวช่วงถนน (ความละเอียดด้านระยะทาง) และความล่าช้าในการประมวลผลและแสดงผล (ความละเอียดด้านเวลา) นั้น อาจส่งผลต่อความสามารถในการประมาณค่าระยะความยาวของแถวคอยแบบพันการณได้ โดยในอนาคตประเด็นเรื่องความละเอียดในการแสดงผลดังกล่าว อาจเปลี่ยนแปลงไปจากเดิมเนื่องจากเทคโนโลยีในการประมวลผลและความเร็วของอินเทอร์เน็ตที่น่าจะมีประสิทธิภาพเพิ่มขึ้นอย่างรวดเร็ว ดังนั้นเป้าหมายประการที่สองของวิทยานิพนธ์เล่มนี้จึงต้องการวิเคราะห์และประเมินศักยภาพของอนาคตในการประยุกต์ใช้ข้อมูลแถบสีจาก Google Maps สำหรับการประมาณค่าระยะความยาวแถวคอย โดยคำนึงถึงความละเอียดของข้อมูลแถบสีจาก Google Maps ที่อาจมีความแตกต่างด้านระยะเวลาและระยะทาง โดยพบว่ายังไม่มีงานวิจัยในอดีตที่ทำการศึกษาในประเด็นดังกล่าวมาก่อน ดังนั้น การศึกษาในส่วนนี้จะทำการจำลองสถานการณ์และประมวลผลข้อมูลแถบสีโดยมีการแปรผันค่าความละเอียดด้านเวลาและความละเอียดด้านระยะทางแตกต่างกันจากสูงไปต่ำ โดยที่ตัวแปรแถบสีจะใช้ตัวแปร 4 แถบสีเหมือนกับ Google Maps แต่จะใช้วิธีการสร้างแบบจำลองที่ดีที่สุดที่สรุปได้จากผลการศึกษาในส่วนแรก เพื่อนำมาประยุกต์ใช้ในส่วนนี้ต่อไป

1.2 วัตถุประสงค์งานวิจัย

1.2.1 เพื่อทดสอบและเปรียบเทียบประสิทธิภาพของแบบจำลองการประมาณค่าระยะความยาวแถวคอยด้วยข้อมูลตัวแปรแถบสีแบบดั้งเดิมจำนวน 4 แถบสีตามรูปแบบ Google Maps ได้แก่ สีแดงเข้ม สีแดง สีส้ม และสีเขียว กับแนวทางในการสกัดข้อมูลตัวแปรแถบสีแบบใหม่

1.2.2 เพื่อทดสอบและเปรียบเทียบประสิทธิภาพของแบบจำลองการประมาณค่าระยะความยาวแถวคอยด้วยการแบ่งการสร้างแบบจำลองตามฝั่งที่มี/ไม่มีไฟสัญญาณจราจรก่อนหน้า และตามช่วงเวลาเร่งด่วน/ไม่เร่งด่วน และการใช้วิธี Gradient boosting ในการประมาณระยะความยาวแถวคอยจากข้อมูลแถบสีของ Google Maps

1.2.3 เพื่อวิเคราะห์และประเมินผลของปัจจัยความละเอียดด้านเวลาและความละเอียดด้านระยะทางของ Google Maps ที่อาจส่งผลต่อประสิทธิภาพของแบบจำลองการประมาณค่าความยาวแถวคอย

1.3 คำถามงานวิจัย

1.3.1 การจัดรูปแบบตัวแปรข้อมูลจากแถบสีของ Google maps รูปแบบใดที่มีความเหมาะสมทำให้แบบจำลองการประมาณค่าความยาวแถวคอยมีประสิทธิภาพมากที่สุด

1.3.2 วิธี Machine learning วิธีใดที่มีประสิทธิภาพการทำนายดีที่สุด สำหรับแบบจำลองการประมาณค่าความยาวแถวคอย

1.3.3 การทดสอบเปรียบเทียบประสิทธิภาพของแบบจำลองการประมาณค่าความยาวแถวคอยสามารถทำได้อย่างไร

1.3.4 ปัจจัยความละเอียดด้านเวลาและความละเอียดด้านระยะทางของแถบสีส่งผลต่อการประมาณความยาวแถวคอยหรือไม่

1.3.5 การสร้างแบบจำลองทางแยกที่มีไฟสัญญาณจราจร เพื่อสร้างชุดข้อมูลแถบสีจะใช้ปัจจัยควบคุมใดบ้าง และมีทั้งหมดกี่ Scenario

1.3.6 การถอดข้อมูลจากแบบจำลองทางแยกที่สร้างโดยโปรแกรม Aimsun จะสามารถถอดข้อมูลให้มีลักษณะเหมือนกับของ Google Maps ได้อย่างไร

1.4 ขอบเขตงานวิจัย

1.4.1 จัดกลุ่มตัวแปรข้อมูลแถบสีของ Google Maps ใหม่ โดยแบ่งรูปแบบของตัวแปรแถบสีเพิ่มอีก 2 กรณีรวมกับรูปแบบแถบสีแบบดั้งเดิมจำนวน 4 แถบสี ได้ดังนี้ 1) แบบดั้งเดิมที่มีจำนวน 4 สี ได้แก่ สีแดงเข้ม สีแดง สีส้ม และสีเขียว, 2) แบบรวมตัวแปรแถบสีแดงเข้ม และสีแดงเข้าด้วยกันเปรียบเสมือนเป็นสีเดียวกัน เพื่อเป็นตัวแทนแสดงถึงสภาพจราจรที่ติดขัดเพียงสีเขียว, และ 3) แบบรวมตัวแปรแถบสีแดงเข้ม และสีแดง รวมทั้งพิจารณาตัดตัวแปรแถบสีเขียวออกโดยพิจารณาเสมือนสีเขียวเป็นสีอ้างอิง

1.4.2 การวิเคราะห์และประเมินผลปัจจัยความละเอียดด้านเวลา และระยะทางของ Google Maps ใช้ข้อมูลแถบสีที่ได้จากการจำลองสภาพจราจรแบบจุดภาคที่บริเวณทางแยกที่มีไฟสัญญาณจราจรโดยโปรแกรม Aimsun เพื่อสร้างชุดข้อมูลความยาวของแถวคอย และข้อมูลแถบสีที่มีลักษณะคล้ายกับของ Google Maps

1.4.3 การทดสอบปัจจัยความละเอียดด้านเวลาถูกแบ่งไว้ที่ 5 ระดับ ได้แก่ 0, 10, 20, 30 และ 60 วินาที และความละเอียดด้านระยะทางของแถบสีถูกแบ่งไว้ที่ 4 ระดับ ได้แก่ 25, 50, 100 และ 200 เมตร

1.5 ประโยชน์ที่คาดว่าจะได้รับ

สามารถประมาณความยาวของแฉกคอยบริเวณทางแยกที่มีไฟสัญญาณจราจรได้แม่นยำและทันการณ์มากขึ้น นอกจากนี้ยังสามารถนำไปประยุกต์ใช้กับเครื่องควบคุมไฟสัญญาณจราจร เพื่อรองรับรถฉุกเฉินได้อย่างมีประสิทธิภาพมากขึ้นในอนาคต

1.6 โครงสร้างของวิทยานิพนธ์


วิทยานิพนธ์ฉบับนี้ทำการศึกษาเกี่ยวกับการใช้ข้อมูลตัวแปรแถบสีแสดงสภาพการจราจรในการสร้างแบบจำลองการประมาณค่าระยะความยาวของแฉกคอย โดยเป็นการวิเคราะห์ปรับปรุงและประเมินความเป็นไปได้ของแบบจำลองจากข้อมูลตัวแปรแถบสี เพื่อเป็นการต่อบัณฑิตวุฒิปริญญาโทและคำถามงานวิจัย วิทยานิพนธ์ฉบับนี้จึงประกอบด้วย 4 บท โดยมีรายละเอียดดังนี้

บทที่ 1: บทนำ ในบทนี้จะกล่าวถึงที่มาและความสำคัญของงานวิจัย, วัตถุประสงค์งานวิจัย, ขอบเขตงานวิจัย และประโยชน์ที่คาดว่าจะได้รับ

บทที่ 2: นวัตกรรมใหม่ของการประมาณค่าระยะความยาวแฉกคอยแบบพลวัตที่ใช้ข้อมูลแถบสีของ Google Maps บทนี้จัดทำขึ้นเพื่อทดสอบและปรับปรุงการสร้างแบบจำลองการประมาณค่าความยาวแฉกคอยด้วยการสกัดและจัดรูปแบบตัวแปรแถบสีใหม่ รวมทั้งการสร้างแบบจำลองตามฝั่งที่มี/ไม่มีไฟสัญญาณจราจรก่อนหน้านี้ และตามช่วงเวลาเร่งด่วน/ไม่เร่งด่วน นอกจากนี้ยังนำเสนอวิธี Machine learning ที่อาจส่งผลทำให้แบบจำลองมีประสิทธิภาพการทำนายที่ดีขึ้น เป็นการจัดทำขึ้นเพื่อต่อบัณฑิตวุฒิปริญญาโท 1.2.1 - 1.2.2 และตอบคำถามวิจัยข้อ 1.3.1 - 1.3.3

บทที่ 3: การวิเคราะห์ผลของปัจจัยความละเอียดด้านเวลาและระยะทางของการประมวลผลข้อมูลแถบสีแสดงสภาพการจราจรต่อการประมาณค่าระยะความยาวแฉกคอย บทนี้จะเป็นงานวิจัยต่อยอดจากบทที่ 2 ด้วยข้อสันนิษฐานที่ว่าปัจจัยความละเอียดด้านเวลา และความละเอียดด้านระยะทางที่ไม่ทราบแน่ชัดของ Google Maps อาจส่งผลให้ประสิทธิภาพการทำนายของแบบจำลองดีขึ้น ดังนั้นในบทนี้จะทำการวิเคราะห์และประเมินผลการประมาณค่าความยาวแฉกคอยของแบบจำลองด้วยข้อมูลตัวแปรแถบสีที่ลักษณะเหมือนกับของ Google Maps ด้วยข้อมูลแถบสีที่ได้จากแบบจำลองจราจรในโปรแกรม Aimsun กรณีที่มีความละเอียดด้านเวลา และความละเอียดด้านระยะทางแตกต่างกัน เพื่อต่อบัณฑิตวุฒิปริญญาโท 1.2.3 และตอบคำถามงานวิจัยข้อ 1.3.4 - 1.3.6

บทที่ 4: สรุปและข้อเสนอแนะ ผลสรุปการศึกษาในบทที่ 2 และบทที่ 3 เกี่ยวกับการใช้ตัวแปรแถบสีแสดงสภาพการจราจรสร้างแบบจำลองการประมาณค่าระยะความยาวแฉกคอย และข้อเสนอแนะของการนำข้อมูลแถบสีไปประยุกต์ใช้งาน โดยภาพรวมของการศึกษาวิทยานิพนธ์เล่มนี้แสดงดังรูปที่ 1.1



รูปที่ 1.1 ภาพรวมขั้นตอนการทำงานของวิทยานิพนธ์

1.7 เอกสารอ้างอิง

- พงศ์พัฒน์ จอดนอก. (2563). การประมาณความยาวแถวคอยบริเวณทางแยกสัญญาณไฟจราจร โดยใช้ข้อมูลแถบสี่แสดงสภาพจราจรจาก Google Maps. (วิศวกรรมศาสตรมหาบัณฑิต). มหาวิทยาลัยเทคโนโลยีสุรนารี, สาขาวิชาวิศวกรรมขนส่ง สำนักวิชาวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีสุรนารี.
- Bae, B., Liu, Y., Han, L. D., & Bozdogan, H. (2019). Spatio-temporal traffic queue detection for uninterrupted flows. *Transportation Research Part B: Methodological*, 129, 20-34. doi:<https://doi.org/10.1016/j.trb.2019.09.001>
- Mishra, S., Bhattacharya, D., & Gupta, A. (2018). Congestion Adaptive Traffic Light Control and Notification Architecture Using Google Maps APIs. *Data*, 3(4), 67. Retrieved from <https://www.mdpi.com/2306-5729/3/4/67>

- Nair, D. J., Gilles, F., Chand, S., Saxena, N., & Dixit, V. (2019). Characterizing multicity urban traffic conditions using crowdsourced data. *PLOS ONE*, 14(3), e0212845. doi:10.1371/journal.pone.0212845
- Navarro-Espinoza, A., López-Bonilla, O. R., García-Guerrero, E. E., Tlelo-Cuautle, E., López-Mancilla, D., Hernández-Mejía, C., & Inzunza-González, E. (2022). Traffic Flow Prediction for Smart Traffic Lights Using Machine Learning Algorithms. *Technologies*, 10(1), 5. Retrieved from <https://www.mdpi.com/2227-7080/10/1/5>
- Noaen, M., Mohajerpoor, R., H. Far, B., & Ramezani, M. (2021). Real-time decentralized traffic signal control for congested urban networks considering queue spillbacks. *Transportation Research Part C: Emerging Technologies*, 133, 103407. doi:<https://doi.org/10.1016/j.trc.2021.103407>
- Rezzouqi, H., Gryech, I., Sbihi, N., Ghogho, M., & Benbrahim, H. (2019, 2019//). *Analyzing the Accuracy of Historical Average for Urban Traffic Forecasting Using Google Maps*. Paper presented at the Intelligent Systems and Applications, Cham.
- Yang, S., Wu, J., Du, Y., He, Y., & Chen, X. (2017). Ensemble Learning for Short-Term Traffic Prediction Based on Gradient Boosting Machine. *Journal of Sensors*, พงศ์พัฒน์ จอดนอก และรัฐพล ภูบุบผาพันธ์. (2564). การประมาณความยาวของแถวคอยแบบแปรผันตามเวลาบริเวณทางแยกสัญญาณไฟจราจรโดยใช้ข้อมูลแถบสีจาก Google Maps. วารสารวิชาการ วิศวกรรมศาสตร์ ม. อบ.(Vol. 14 No. 4 (2021)).

บทที่ 2

นวัตกรรมใหม่ของการประมาณค่าระยะความยาวแถวคอยแบบพลวัตโดยใช้ข้อมูลแถบสีของ Google Maps

2.1 บทคัดย่อ

ความยาวแถวคอยเป็นหนึ่งในข้อมูลนำเข้าสำคัญสำหรับระบบไฟสัญญาณจราจรให้สิทธิผ่านทางพิเศษแก่รถฉุกเฉิน เพื่อทดแทนการใช้ detector บทความนี้จึงทำการตรวจสอบความเป็นไปได้ในการประมาณค่าระยะความยาวแถวคอยจากข้อมูลแถบสีแสดงสภาพจราจรของ Google Maps โดยใช้วิธี Random Forest (RF) และ Gradient Boosting Machine (GBM) นอกจากนี้ตัวแปรแถบสีรูปแบบใหม่ที่ได้จากการจัดรูปแบบข้อมูลแถบสีจาก Google Maps ยังถูกนำไปใช้เพื่อทำการเปรียบเทียบกับรูปแบบเดิม ในการสร้างแบบจำลองยังมีการจำแนกตามช่วงเวลาเร่งด่วน หรือไม่เร่งด่วน และยังมีการแยกตามประเภทของทิศทางที่มุ่งเข้าสู่ทางแยกว่ามีหรือไม่มีไฟสัญญาณจราจร ก่อนหน้าอยู่ในบริเวณใกล้เคียง ผลที่ได้จากการศึกษาพบว่าประสิทธิภาพการทำนายของวิธี RF และ GBM นั้นใกล้เคียงกันมากในทุกกรณี ถึงแม้ค่า error ของทั้งสองวิธีจะยังคงค่อนข้างสูงแต่ก็น้อยกว่าค่อนข้างมากเมื่อเทียบกับการประมาณโดยใช้ข้อมูลระยะความยาวแถวคอยในอดีต และในส่วนของผลลัพธ์ที่ได้จากการวิเคราะห์ค่า Variable Importance แสดงให้เห็นว่าแถบสีแดงที่อยู่ใกล้กับทางแยกจะมีความสำคัญมากกว่าแถบสีอื่นในทิศทางที่ไม่มีไฟสัญญาณจราจรก่อนหน้า แต่ในทิศทางที่มีไฟสัญญาณจราจรก่อนหน้า ค่า Variable Importance จะขึ้นอยู่กับช่วงเวลาเร่งด่วนหรือไม่เร่งด่วน เนื่องจากข้อมูล Google Maps ซึ่งเป็นข้อมูลที่มีอยู่แล้วและยังครอบคลุมทางแยกส่วนใหญ่ในโลกด้วยวิธีการที่นำเสนอจึงเป็นทางเลือกที่คุ้มค่าสำหรับเมืองที่ยังไม่มีการติดตั้ง detector

คำสำคัญ: ความยาวแถวคอย Google Maps Random Forest Gradient-Boosting Machine Variable Importance ทางแยกที่มีไฟสัญญาณจราจร ระบบสัญญาณไฟจราจรให้สิทธิผ่านทางพิเศษ

2.2 บทนำ

การบริหารจัดการจราจรบริเวณทางแยกโดยใช้ไฟสัญญาณจราจรเป็นทางเลือกที่ช่วยลดจุดขัดแย้งและทำให้การเคลื่อนที่ผ่านทางแยกเป็นระเบียบเรียบร้อย เนื่องจากยานพาหนะทุกประเภทต้องหยุดในขณะที่ไฟจราจรสีแดง จึงทำให้เกิดความล่าช้าในการจราจรอย่างหลีกเลี่ยงไม่ได้ อย่างไรก็ตาม ในกรณีของรถฉุกเฉิน (Emergency Vehicle) การลดความล่าช้าในช่วงระยะเวลาที่ต้องจอดติดสัญญาณไฟแดงนั้นเป็นเพียงช่วงเวลาสั้น ๆ ก็อาจส่งผลกระทบต่อความปลอดภัยของผู้ป่วยได้ ในปัจจุบันได้มีการพัฒนาระบบไฟสัญญาณจราจรที่สามารถตรวจจับและให้สิทธิพิเศษในการผ่านทางแยกรถฉุกเฉินบริเวณทางแยก (Agarwal & Rai, 2022; Chuo et al., 2022; Venkat, Arulananth, & Baskar, 2019) โดยข้อมูลนำเข้าที่สำคัญส่วนหนึ่งของระบบดังกล่าวได้แก่ ระยะเวลาของแถวคอยที่บริเวณทางแยก ซึ่งจะถูกใช้เป็นข้อมูลในการวิเคราะห์หาระยะเวลาที่เหมาะสมในการเปิดสัญญาณไฟเขียวล่วงหน้า เพื่อระบายแถวคอยดังกล่าวออกจากทางแยกก่อนที่รถฉุกเฉินจะมาถึง

การศึกษาส่วนใหญ่ใช้ข้อมูลจาก detector ในการประมาณค่าระยะเวลาของแถวคอยบริเวณทางแยก ร่วมกับการใช้ทฤษฎี shockwave โดยงานวิจัยในปีใหม่ ๆ จะเน้นการปรับปรุงประสิทธิภาพการประมาณค่าระยะเวลาของแถวคอยที่ได้จาก detector ให้มีความทันสมัยมากขึ้น และมีความละเอียดมากขึ้น ซึ่งข้อมูลการประมาณค่าระยะเวลาของแถวคอยนี้สามารถนำไปใช้กับการตั้งระยะเวลาไฟสัญญาณจราจรได้ หรือเพื่อจัดการกับปัญหาการติดขัดของการจราจรก็สามารถทำได้ด้วยเช่นกัน (An, Wu, Xia, & Huang, 2018; Bae et al., 2019; Lee, Wong, & Li, 2015; Yao & Tang, 2019) อย่างไรก็ตาม เนื่องจากทางแยกแทบจะทุกแห่งในประเทศไทยยังไม่ได้มีการติดตั้ง detector ในทางปฏิบัติ จึงไม่สามารถทำการประมาณค่าระยะเวลาของแถวคอยด้วยวิธีการดังกล่าวได้ ด้วยข้อจำกัดดังกล่าว พงศ์พัฒน์ จอดนอก และรัฐพล ภูบุบผาพันธ์ (2564) ได้ประยุกต์ใช้ Linear regression analysis และ Random forest (RF) เพื่อประมาณค่าระยะเวลาของแถวคอยบริเวณทางแยกที่มีไฟสัญญาณจราจร โดยการใช้ข้อมูลของแถบสีที่แสดงสภาพจราจรบน Google Maps ในการสร้างแบบจำลองแยกตามช่วงเวลาเร่งด่วนและไม่เร่งด่วน ผลการศึกษาพบว่า การประมาณค่าระยะเวลาของแถวคอยโดยใช้ข้อมูลแถบสีจาก Google Maps ให้ผลดีในระดับหนึ่งและวิธี RF เป็นวิธีที่มีค่าความคลาดเคลื่อนต่ำกว่าวิธีอื่น

มีนักวิจัยหลายคนที่ใช้ข้อมูลจาก Google Maps เพื่อทำงานวิจัย เช่น ข้อมูลเวลาเดินทางและระยะทางจาก Google Maps ถูกใช้เพื่อระบุตำแหน่งที่เหมาะสมที่สุดสำหรับการติดตั้งสถานีชาร์จ (Keawthong, Muangsin, & Gowanit, 2022) การกำหนดปริมาณจราจรและความเร็วของยานพาหนะ เพื่อตรวจสอบความแออัดบนถนน (Anjaneyulu & Kubendiran, 2023; Asgharizadeh, Jooybar, Mahdiraji, & Garza-Reyes, 2022) มลพิษทางอากาศ (Moon, Hong, & Park, 2022; Naiudomthum, Winijkul, & Sirisubtawee, 2022) หรือการเข้าถึงโรงพยาบาล

(Dumitrache, Nae, Simion, & Taloş, 2020) นอกจากนี้ยังใช้ข้อมูลเส้นทางการเดินทางจาก Google Maps เพื่อกำหนดเส้นทางขนส่งสินค้าและยานพาหนะฉุกเฉินอีกด้วย (Rahman et al., 2021; Tan et al., 2017; Wu, Ke, & Lai, 2022) ข้อมูลแถบสีและเวลาเดินทางจาก Google Maps ถูกนำมาใช้ เพื่อปรับเวลาสัญญาณไฟจราจรให้ตอบสนองใกล้เคียงสภาพการจราจรจริง (Mishra et al., 2018) ข้อมูลแถบสียังใช้เพื่อคาดการณ์สภาพการจราจรสำหรับถนนในเมืองโดยใช้ข้อมูลค่าเฉลี่ยในอดีต (Rezzouqi et al., 2019) ข้อมูลความเร็วการจราจรจาก Google Maps ถูกนำมาใช้เพื่อกำหนดดัชนีความแออัด (Nair et al., 2019) อย่างไรก็ตาม ยังขาดการวิจัยเกี่ยวกับการใช้ข้อมูลแถบสีจาก Google Maps เพื่อประมาณค่าความยาวแถวคอยบริเวณทางแยกที่มีไฟสัญญาณจราจร

Google Maps แสดง 4 สีที่เป็นไปได้ ได้แก่ สีแดงเข้ม สีแดง สีส้ม และสีเขียว สีเหล่านี้แสดงแทนสภาพจราจรตามความเร็วของช่วงถนนจากความเร็วต่ำมากไปจนถึงความเร็วสูง ตามลำดับ (Alex, 2022; Google Maps, 2022) อย่างไรก็ตาม (พงศ์พัฒน์ จอดนอก และรัฐพล ภูบุบผาพันธ์, 2564) ได้ทำการสังเกตเส้นสีบริเวณทางแยกโดยทำการ capture ภาพหน้าจอของ Google Maps บริเวณทางแยกทุก ๆ หนึ่งนาที พบว่าความถี่ที่พบแถบสีแดงเข้มและสีแดงนั้นค่อนข้างน้อยกว่าแถบสีอื่นอย่างมีนัยสำคัญ นำไปสู่คำถามงานวิจัยที่ว่าควรพิจารณาสองแถบสีนี้เสมือนเป็นแถบสีเดียวกันหรือไม่

บางงานวิจัยในด้านสาขาขนส่งได้ใช้เทคนิค RF (Navarro-Espinoza et al., 2022; Sihag, Parida, & Kumar, 2022; Xu et al., 2022) อย่างไรก็ตาม Machine-learning อื่น ๆ นอกเหนือจาก RF ก็ถูกนำมาใช้เช่นกัน ตัวอย่างเช่น มีการใช้เทคนิค gradient-boosting machine (GBM) เมื่อความสัมพันธ์ระหว่างตัวแปรตามและตัวแปรอิสระไม่เป็นเชิงเส้น เทคนิค GBM ถูกนำไปประยุกต์ใช้ในการคาดคะเนเวลาเดินทาง (Li & Bai, 2016) การคาดคะเนเวลาเคลียร์เหตุการณ์ (Ma, Ding, Luan, & Wang, 2017) และการคาดคะเนปริมาณจราจรในช่วงเวลาระยะสั้น (Yang et al., 2017) ซึ่งพบว่า GBM ให้ผลการทำนายที่ดีกว่าเมื่อเปรียบเทียบกับวิธีอื่น (Ma et al., 2017; Yang et al., 2017) นอกจากนี้งานวิจัยใหม่ ๆ ยังพบว่าวิธี GBM สามารถคำนวณค่า Variable Importance (VI) ซึ่งช่วยให้เข้าใจถึงระดับความสำคัญของตัวแปรอิสระแต่ละตัวว่าส่งผลต่อตัวแปรตามมากน้อยเพียงใด เป็นการช่วยเสริมศักยภาพแก่วิธี GBM ซึ่งเคยถูกมองว่าเป็นวิธี Black-box ข้อได้เปรียบในจุดนี้ทำให้สามารถเข้าใจเกี่ยวกับความสัมพันธ์ระหว่างตัวแปรตามและตัวแปรอิสระได้ดีกว่าเมื่อเทียบกับวิธีอื่น (Cheng, Li, & Chen, 2019)


เป้าหมายของบทความนี้จะเป็นการศึกษาต่อยอดจาก พงศ์พัฒน์ จอดนอก และรัฐพล ภูบุบผาพันธ์ (2564) โดยนอกเหนือจากการสร้างแบบจำลองแยกตามช่วงเวลาเร่งด่วน/ไม่เร่งด่วนแล้ว เรายังได้ทำการพิจารณาสร้างแบบจำลองแยกตามประเภทของทิศทางที่มุ่งเข้าสู่ทางแยกว่ามีหรือไม่มีไฟสัญญาณจราจรก่อนหน้านี้ภายในบริเวณใกล้เคียง นอกจากนี้ยังมีการพิจารณาทางเลือกในการ

กำหนดตัวแปรอิสระเพิ่มเติม เช่น การรวมตัวแปรแถบสีแดงเข้มและสีแดงเข้าด้วยกันโดยเปรียบเทียบเป็นสีเดียวกัน และการใช้ตัวแปรแถบสีเขียวเป็นตัวแปรอ้างอิง ยังมีการพิจารณาเปรียบเทียบผลการพยากรณ์ระหว่างวิธี RF และ GBM กับข้อมูลความยาวแถวคอยในอดีต รวมถึงนำผลของ Variable Importance (VI) เพื่อมาวิเคราะห์และทำความเข้าใจถึงปัจจัยที่ส่งผลต่อการทำนายความยาวแถวคอยโดยใช้แถบสีจาก Google Maps ด้วย วัตถุประสงค์ของงานวิจัยนี้เพื่อประเมินความเป็นไปได้ และข้อจำกัดในการพัฒนาวิธีการประมาณค่าระยะความยาวแถวคอยจากข้อมูลแถบสีแสดงสภาพจราจรของ Google Maps ซึ่งจะเป็นทางเลือกในการพัฒนาสำหรับพื้นที่ที่ไม่ได้มีการติดตั้ง detector บริเวณทางแยกที่มีไฟสัญญาณจราจรบนโครงข่ายถนน

ในหัวข้อถัดไปจะกล่าวถึงการเก็บรวบรวมและสำรวจข้อมูล มีการอธิบายรายละเอียดทั้งในส่วนของ การเก็บข้อมูลแถบสีจาก Google Maps และข้อมูลระยะความยาวแถวคอยจริงจากภาคสนามเป็นตัวแปรอิสระและตัวแปรตาม ตามลำดับ จากนั้นจะเป็นรายละเอียดของการสร้างแบบจำลอง ตามด้วยผลลัพธ์ที่ได้จากแบบจำลองและค่า Variable Importance (VI) ปิดท้ายด้วยบทสรุปและข้อเสนอแนะ

2.3 การสำรวจและเก็บข้อมูล


งานวิจัยนี้ได้ใช้ข้อมูลชุดเดียวกันกับ พงศ์พัฒน์ จอดนอก และรัฐพล ภูบุบผาพันธ์ (2564) ซึ่งได้ทำการสำรวจและเก็บข้อมูลทั้งลักษณะการเปลี่ยนแปลงของระยะความยาวและสีของแถบสีบน Google Maps พร้อมกับบันทึกระยะความยาวของแถวคอยจริงในพื้นที่ศึกษาไปพร้อมกัน โดยพื้นที่ศึกษาคือบริเวณทางแยกไฟสัญญาณจราจรบนถนนเส้นหลักกลางเมืองนครราชสีมา ประเทศไทย ซึ่งเป็นบริเวณที่มีการจราจรหนาแน่นและเกิดปัญหาจราจรติดขัดเป็นประจำ มีจำนวน 4 ช่องจราจร รูปที่ 2.1 แสดงพื้นที่สำรวจ โดยในทิศทางขาเข้าเมืองระยะใกล้เคียงจะไม่มีไฟสัญญาณจราจรอยู่ก่อนหน้า แต่สำหรับทิศขาออกเมืองจะมีไฟสัญญาณจราจรอยู่ก่อนหน้าห่างออกไปเป็นระยะทาง 930 เมตร การสำรวจและเก็บข้อมูลเริ่มตั้งแต่เวลา 07.00 น. ถึง 19.00 น. เพื่อให้ครอบคลุมช่วงเวลาเร่งด่วนและไม่เร่งด่วน โดยทำการสำรวจในช่วงวันธรรมดาจำนวน 3 วัน และวันหยุดสุดสัปดาห์อีกจำนวน 2 วัน



รูปที่ 2.1 พื้นที่สำรวจ แผนที่พื้นหลังบันทึกจาก maps.google.com เข้าถึงเมื่อวันที่ 10 มกราคม พ.ศ. 2566

2.3.1 การสำรวจเก็บข้อมูลแถบสี่จาก Google maps

การเก็บข้อมูลจาก Google Maps ใช้การถ่ายภาพหน้าจอคอมพิวเตอร์ (Screenshot) ที่เปิดใช้งาน Google Maps บริเวณที่ทำการสำรวจข้อมูล โดยบันทึกทุก ๆ 1 นาที และในขณะเดียวกันบนหน้าเว็บไซต์ของ Google Maps ก็จะถูกตั้งระบบให้มีการ Refresh หน้าเว็บไซต์ตลอดเวลาโดยใช้โปรแกรม Auto Refresh เพื่อให้เห็นถึงการเปลี่ยนแปลงลักษณะของแถบสี่อย่างต่อเนื่อง ในกรณีของพื้นที่ศึกษาฝั่งที่ไม่มีทางแยกอยู่ก่อนหน้าพบว่าแถบสี่เขียวจะเป็นแถบสี่สุดท้ายเสมอ รูปที่ 2.2 แสดงตัวอย่างแถบสี่ที่ได้รับจาก Google Maps โดยแสดงแถบสี่ 4 แถบ ได้แก่ แถบที่ 1 จากเส้นหยุดคือสีแดงเข้มที่มีความยาว 120 เมตร แถบที่ 2 แถบสีแดงมีความยาว 120 เมตร แถบที่ 3 แถบสีส้มมีความยาว 220 เมตร และแถบสุดท้ายแถบสีเขียวซึ่งเป็นแถบสี่สุดท้ายจะยาวต่อเนื่องไปอีกเป็นระยะทางไกล จึงระบุระยะทางของแถบสุดท้ายเป็น 9999 ตัวอย่างของการกรอกข้อมูลระยะความยาวจากการสำรวจของ Google Maps แสดงดังตารางที่ 2.1



รูปที่ 2.2 ตัวอย่างการวัดความยาวโดยใช้ข้อมูลแถบสีของ Google Maps แผนที่พื้นหลังบันทึกจาก maps.google.com เข้าถึงเมื่อวันที่ 10 มกราคม พ.ศ. 2566


ตารางที่ 2.1 ข้อมูลตัวอย่างที่ได้รับจาก Google Maps

| แถบสี | สี | ความยาว |
|------------------------|-----------|---------|
| แถบสีที่ 1 จากเส้นหยุด | สีแดงเข้ม | 120 ม. |
| แถบสีที่ 2 จากเส้นหยุด | สีแดง | 120 ม. |
| แถบสีที่ 3 จากเส้นหยุด | สีส้ม | 220 ม. |
| แถบสีที่ 4 จากเส้นหยุด | สีเขียว | 9999 ม. |

2.3.2 การสำรวจข้อมูลระยะความยาวแฉกคอยจริง

การสำรวจระยะความยาวแฉกคอยจริงบนพื้นที่สำรวจได้จากการสังเกตของผู้สำรวจ โดยจะมีการทำเครื่องหมายชั่วคราวไว้บริเวณไหล่ทางหรือบนพื้นที่พุดบาทด้วยเทปสะท้อนแสงทุก ๆ ระยะ 20 เมตรจากเส้นหยุด เครื่องหมายชั่วคราวเหล่านี้จะถูกใช้เพื่อช่วยในการประมาณระยะทางจากเส้นหยุดจนถึงส่วนท้ายยานพาหนะของแฉกคอย พร้อมทั้งจัดทำแผนที่บริเวณพื้นที่ศึกษาโดยระบุระยะความยาวจากเส้นหยุดไปยังจุดสังเกตต่าง ๆ เช่น ตึก/อาคาร เสาไฟ ป้ายโฆษณา และสิ่งก่อสร้างอื่นที่มองเห็นได้ง่ายในระยะไกลเพื่อใช้เป็นตัวช่วยในการเก็บระยะความยาวแฉกคอยจริง อย่างไรก็ตาม ระยะความยาวแฉกคอยของแต่ละช่องจราจรอาจจะไม่เท่ากัน แต่โดยส่วนใหญ่แล้วจะมีค่าใกล้เคียงกัน ดังนั้น งานวิจัยนี้จึงเลือกใช้ค่าเฉลี่ยของระยะความยาวแฉกคอยของถนนทั้ง 4 ช่องจราจร เพื่อเป็นตัวแทนของความยาวแฉกคอยที่จะนำไปใช้สำหรับเป็นตัวแปรตามในแบบจำลอง ในการ

สำรวจใช้ศึกษาระดับปริญญาตรี ชั้นปีที่ 4 จำนวน 7 คน และนักศึกษาระดับบัณฑิตศึกษา 1 คน จากสำนักวิชาวิศวกรรมขนส่ง มหาวิทยาลัยเทคโนโลยีสุรนารี นักศึกษาสองคนจะประจำตำแหน่งทุก 200 เมตร โดยนักศึกษา 1 คนจะเก็บข้อมูลจาก 2 ช่องจราจรที่แตกต่างกัน ดังนั้น นักศึกษาทั้ง 6 คน จะเก็บข้อมูลครอบคลุมถึงระยะ 600 ม. จากทั้ง 4 ช่องจราจร ซึ่งเพียงพอในกรณีศึกษาของงานวิจัยนี้ นักศึกษาที่เหลืออีก 2 คนต้องเตรียมตัวรอเปลี่ยนตัวกับนักศึกษาคนอื่นขณะที่เฝ้าดูกล้องที่ใช้บันทึกปริมาณจราจรและไฟสัญญาณจราจรไปด้วย ผู้สำรวจจะใช้วิทยุสื่อสาร เพื่อบอกเกี่ยวกับตำแหน่งปัจจุบันของแถวคอยและจะต้องติดตามทางของแถวคอยหากอยู่ในระยะที่รับผิดชอบ ผู้สำรวจต้องจดบันทึกระยะเวลาความยาวแถวคอยจริงทุก ๆ 1 นาที (ช่วงเวลาเช่นเดียวกันกับการจับภาพหน้าจอจาก Google Maps) ความเร็วของยานพาหนะในแถวคอยต้องไม่เกิน 10 กม./ชม. จึงจะนับว่าอยู่ในแถวคอย นอกจากนี้ ยังมีการเก็บข้อมูลแยกตามทิศทางที่วิ่งเข้าสู่ทางแยกและแยกระหว่างช่วงเวลาเร่งด่วนและไม่เร่งด่วน อย่างไรก็ตาม หากอยู่ในช่วงเวลาไฟเขียวที่รถสามารถเคลื่อนที่ได้ทำให้ไม่มีแถวคอยเกิดขึ้นก็จะทำการระบุระยะความยาวแถวคอยเป็นศูนย์ รูปที่ 2.3 แสดงการกระจายตัวของผู้สำรวจและกล้องวิดีโอในพื้นที่สำรวจในแต่ละวัน



รูปที่ 2.3 การกระจายตัวของผู้สำรวจและกล้องวิดีโอในพื้นที่สำรวจ

2.3.3 การประมวลผลข้อมูล

ผลการวิจัยจาก พงศ์พัฒน์ จอดนอก และรัฐพล ภู่บุบผาพันธ์ (2564) พบว่าบนช่วงถนนที่ทำการสำรวจนั้นมีจำนวนแถบสีนับจากเส้นหยุดต่อเนื่องกันที่สูงที่สุดจำนวน 6 แถบสี โดยนับลำดับแถบสีจากแถบสีที่ใกล้ทางแยกมากที่สุดเป็นแถบสีลำดับแรกไปยังแถบสีที่ไกลทางแยกมากที่สุดเป็นลำดับสุดท้าย อย่างไรก็ตาม ยังพบอีกว่าการใช้ข้อมูลจาก 3 แถบสีแรกที่อยู่ติดกับเส้นหยุดก็

เพียงพอและให้ผลที่ดีที่สุดเทียบเท่ากับการใช้ข้อมูลจากทั้ง 6 แถบสี ในงานวิจัยนี้จึงจะใช้ข้อมูลจาก 3 แถบสีแรกที่อยู่ติดกับเส้นหยุดเพื่อนำมาสร้างตัวแปรอิสระ และได้ทดลองปรับเปลี่ยนตัวแปรเกี่ยวกับ แถบสีหรือตัวแปรอิสระรวมทั้งสิ้น 3 รูปแบบ ดังต่อไปนี้

(1) พิจารณา 4 สีตาม Google Map เช่นเดียวกับ (พงศ์พัฒน์ จอดนอก และรัฐพล ภูบุบผาพันธ์, 2564) (Independent variable set 1: IV1)

(2) พิจารณาสีแดงเข้มและสีแดงเสมือนว่าเป็นสีเดียวกัน (Independent variable set 2: IV2)

(3) ลักษณะตัวแปรเหมือนกับแบบที่ (2) แต่พิจารณาสีเขียวเป็น reference และตัดตัวแปรสีเขียวออก (Independent variable set 3: IV3)

การตั้งชื่อตัวแปรที่ใช้ในแบบจำลองจะแสดงดังตารางที่ 2.2 โดยค่าที่บันทึกของตัวแปรอิสระแต่ละตัวจะขึ้นอยู่กับว่าแถบสีที่ปรากฏจริงนั้นตรงกับสีของตัวแปรตามในรูปที่ 2.4 หรือไม่ หากสีที่ปรากฏจริงของแถบสี i เป็นสีเดียวกับตัวแปร j_i ความยาวของแถบสี i ในหน่วยเมตรจะถูกบันทึก มิฉะนั้น ตัวแปร j_i จะเป็นศูนย์

ตารางที่ 2.2 ตัวแปรแถบสีที่ถูกปรับเปลี่ยนใหม่

| รูปแบบตัวแปรอิสระ (IV) | สี | ชื่อตัวแปรอิสระ | | |
|------------------------|---------|-----------------|------------|------------|
| | | แถบสีที่ 1 | แถบสีที่ 2 | แถบสีที่ 3 |
| IV1 | แดงเข้ม | DARKRED_1 | DARKRED_2 | DARKRED_3 |
| | แดง | RED_1 | RED_2 | RED_3 |
| | ส้ม | ORANGE_1 | ORANGE_2 | ORANGE_3 |
| | เขียว | GREEN_1 | GREEN_2 | GREEN_3 |
| IV2 | รวมแดง | C_RED_1 | C_RED_2 | C_RED_3 |
| | ส้ม | ORANGE_1 | ORANGE_2 | ORANGE_3 |
| | เขียว | GREEN_1 | GREEN_2 | GREEN_3 |
| IV3 | รวมแดง | C_RED_1 | C_RED_2 | C_RED_3 |
| | ส้ม | ORANGE_1 | ORANGE_2 | ORANGE_3 |

$$j_i = \begin{cases} \text{length of band } i, & \text{if actual color of band } i \text{ is } j \\ 0, & \text{otherwise} \end{cases}$$


รูปที่ 2.4 การตั้งชื่อตัวแปร

2.3.4 การสร้างแบบจำลองการประมาณค่าระยะความยาวแถวคอย

ในบทความนี้ มีการใช้เทคนิค Machine-learning สองวิธี ได้แก่ RF และ GBM เทคนิค Random Forest (RF) เป็นวิธีการแบบ ensemble decision-tree หลักการของ RF คือการสร้างต้นไม้ตัดสินใจหลายรายการ โดยที่แต่ละต้นไม้ใช้อัลกอริทึมเดียวกัน แต่จะมีเงื่อนไขที่แตกต่างกัน ข้อมูลที่ใช้ในการสร้างต้นไม้แต่ละต้นจะถูกสุ่มเลือกจากฐานข้อมูลเดียวกัน เมื่อสร้างต้นไม้ตัดสินใจเสร็จสมบูรณ์หนึ่งต้น ข้อมูลจะถูกส่งกลับไปยังฐานข้อมูลเดิม และข้อมูลชุดใหม่จะถูกสุ่มเลือกเพื่อสร้างต้นไม้ตัดสินใจใหม่ (Biau & Scornet, 2016) สำหรับเทคนิค GBM เป็นเทคนิคที่ได้รับการพัฒนามาจากเทคนิค RF เทคนิค GBM จะทำการสร้าง weak classifier ขึ้นมาก่อนเป็นอันดับแรกจากนั้นจึงทำการคำนวณค่า error ที่เกิดขึ้น โดยที่ GBM นั้นจะเรียนรู้รูปแบบของการเกิดค่า error แล้วนำไปปรับปรุงและสร้างเป็นแบบจำลองใหม่ขึ้นมา ดังนั้น แบบจำลองใหม่ที่ได้ก็จะมีค่า error ที่น้อยกว่าแบบจำลองก่อนหน้า ซึ่ง GBM จะทำการสร้างแบบจำลองตามลำดับไปเรื่อย ๆ จนกว่าจะไม่สามารถเรียนรู้การเกิดค่า error ได้ แล้วก็จะหยุดการสร้างแบบจำลอง (Natekin & Knoll, 2013)

นอกจากเทคนิค RF และ GBM ในบทความนี้ยังได้ทำการพิจารณาวิธีการประมาณแบบง่าย naïve method ซึ่งจะใช้ค่าเฉลี่ยของความยาวแถวคอยในอดีตแยกตามทิศทางและแยกตามช่วงเวลาเป็นตัวแทนของค่าประมาณของระยะความยาวแถวคอยในแต่ละกรณี (ซึ่งจะขอเรียกว่าวิธี Average) เพื่อเป็น Benchmark อ้างอิงและเป็นตัวแทนแสดงถึงการประมาณค่าอย่างง่ายที่สุดที่เป็นไปได้โดยการใช้เพียงข้อมูลระยะความยาวแถวคอยในอดีต ผลลัพธ์ที่ได้จากวิธีนี้จะถูกใช้เป็นเกณฑ์มาตรฐาน เพื่อเปรียบเทียบกับผลลัพธ์ที่ได้จากวิธี RF และ GBM

โดยทั่วไป ลักษณะสภาพจราจรและการเกิดแถวคอยอาจจะมี ความแตกต่างกันระหว่างฝั่งขาที่มีหรือไม่มีทางแยกก่อนหน้าอยู่ในบริเวณใกล้เคียง รวมถึงอาจมีความแตกต่างในช่วงเวลาเร่งด่วนหรือไม่เร่งด่วน ในบทความนี้จึงได้ทำการพิจารณาสร้างแบบจำลองที่แตกต่างกันตามปัจจัยที่กล่าวมาข้างต้น ซึ่งแสดงดังรูปที่ 2.5 โดยรายละเอียดการสร้างแบบจำลองย่อยทั้ง 7 แบบจำลอง มีดังนี้



รูปที่ 2.5 Scenarios และแบบจำลองที่ใช้ในการประมาณค่าความยาวแถวคอย

แบบจำลองที่ 1 (M1): แบบจำลองที่ไม่แยกทิศทางและไม่แยกช่วงเวลา

แบบจำลองที่ 2 (M2): แบบจำลองเฉพาะฝั่งที่ไม่มีไฟสัญญาณจราจรก่อนหน้าและไม่แยกช่วงเวลา

แบบจำลองที่ 3 (M3): แบบจำลองเฉพาะฝั่งที่มีไฟสัญญาณจราจรก่อนหน้าและไม่แยกช่วงเวลา

แบบจำลองที่ 4 (M4): แบบจำลองเฉพาะฝั่งที่ไม่มีไฟสัญญาณจราจรก่อนหน้าและเฉพาะในช่วงเวลาเร่งด่วน

แบบจำลองที่ 5 (M5): แบบจำลองเฉพาะฝั่งที่ไม่มีไฟสัญญาณจราจรก่อนหน้าและเฉพาะในช่วงเวลาที่ไม่เร่งด่วน

แบบจำลองที่ 6 (M6): แบบจำลองเฉพาะฝั่งที่มีไฟสัญญาณจราจรก่อนหน้าและเฉพาะในช่วงเวลาเร่งด่วน

แบบจำลองที่ 7 (M7) : แบบจำลองเฉพาะฝั่งที่มีไฟสัญญาณจราจรก่อนหน้าและเฉพาะในช่วงเวลาที่ไม่เร่งด่วน

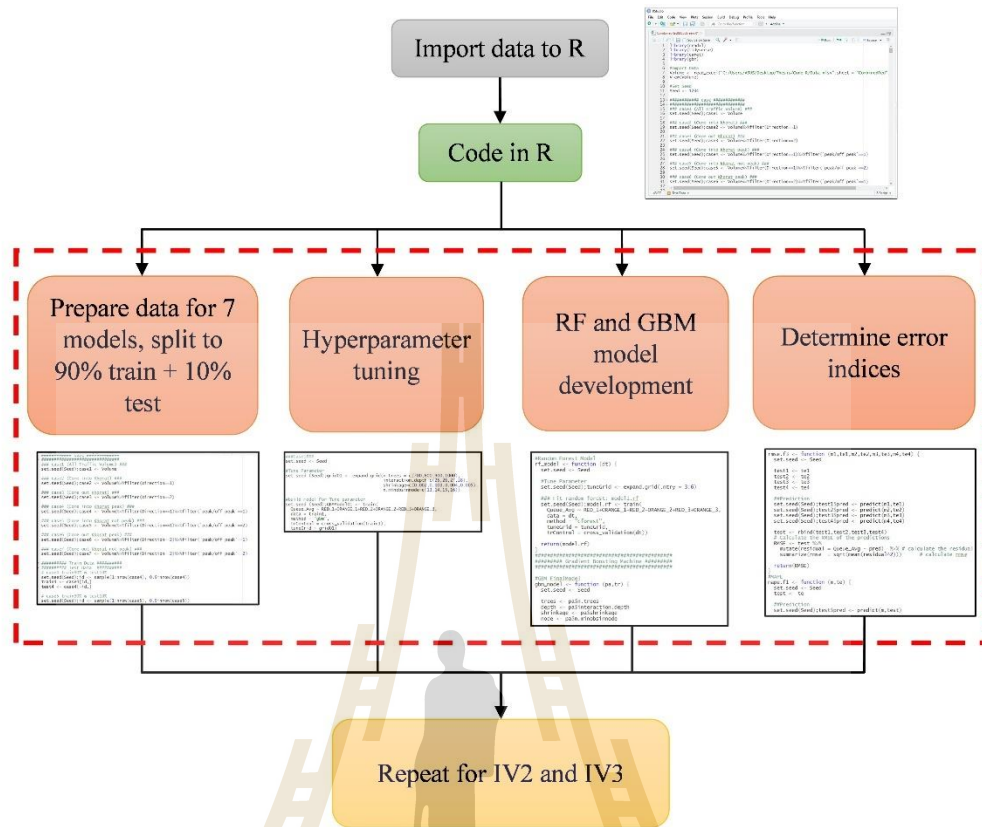
จากแบบจำลองย่อยทั้ง 7 แบบจำลองข้างต้นจะถูกนำไปพิจารณา scenarios ในการประมาณค่าความยาวแถวคอยทั้งหมด 3 scenarios ดังนี้

Scenario 1: ใช้แบบจำลองย่อยที่ 1 (Model1) ในการพยากรณ์ความยาวแถวคอยในทุกสถานการณ์โดยไม่แยกทิศทางและไม่แยกช่วงเวลา

Scenario 2: ใช้แบบจำลองย่อยที่ 2 เพื่อพยากรณ์ความยาวแถวคอยในทิศทางที่ไม่มีไฟสัญญาณจราจรก่อนหน้า และใช้แบบจำลองย่อยที่ 3 เพื่อพยากรณ์ความยาวแถวคอยในทิศทางที่มีไฟสัญญาณจราจรก่อนหน้า

Scenario 3: ใช้แบบจำลองย่อยที่ 4 และ 5 เพื่อพยากรณ์ระยะความยาวแถวคอยในทิศทางที่ไม่มีไฟสัญญาณจราจรก่อนหน้าในช่วงเวลาเร่งด่วน และไม่เร่งด่วน ตามลำดับ ใช้แบบจำลองย่อยที่ 6 และ 7 เพื่อพยากรณ์ความยาวแถวคอยในทิศทางที่มีไฟสัญญาณจราจรก่อนหน้าในช่วงเวลาเร่งด่วนและไม่เร่งด่วน ตามลำดับ

ในงานวิจัยนี้ได้ทำการสร้างแบบจำลองการประมาณค่าความยาวแถวคอยบริเวณทางแยกตามที่กล่าวมาข้างต้นโดยใช้เทคนิค RF และ GBM จาก package โปรแกรม R (R Core Team, 2022) คือ caret (Kuhn, 2022) และ gbm (Greenwell, Boehmke, Cunningham, & Developers, 2022) ตามลำดับ โดยเทคนิค RF ใช้ method cforest ของ package caret ในการ tune parameter mtry ซึ่งเป็นจำนวนของตัวทำนายที่เลือกแบบสุ่ม ถูกปรับในช่วง 3-12 และในส่วนของเทคนิค GBM ก็ยังใช้ caret สำหรับการ tune parameter เช่นกัน ซึ่ง parameter มีดังนี้ n.trees, interaction.depth, shrinkage และ n.minobsinnode ชุดข้อมูลทั้งหมดจะถูกแบ่งออกเป็นสองส่วน ชุดข้อมูล 90% แรกจากทั้งหมดใช้สำหรับการ train และสร้างแบบจำลองโดยใช้หลักการ 5-fold Cross-Validation และข้อมูลที่เหลืออีก 10% จะใช้สำหรับทดสอบประสิทธิภาพการพยากรณ์และค่าความผิดพลาดที่เกิดขึ้น (test) โดยใช้ค่า Root Mean Square error (RMSE) และ Mean Absolute Percentage Error (MAPE) รูปที่ 2.6 แสดงขั้นตอนการสร้างแบบจำลองและการวิเคราะห์โดยรวมสรุปขั้นตอนได้ดังนี้



รูปที่ 2.6 ขั้นตอนการสร้างแบบจำลองและการวิเคราะห์โดยรวม

1. นำเข้าข้อมูลระยะเวลาความยาวแถวคอยจริงและความยาวแถบสีลงในโปรแกรม R
2. สร้างชุดข้อมูลแยกสำหรับ 7 แบบจำลอง
3. แบ่งแต่ละชุดข้อมูลเป็น ชุด train 90% และ ชุด test 10%
4. สำหรับชุดข้อมูลตัวแปรอิสระแต่ละชุด ชุดข้อมูล train จะใช้สำหรับการ tune hyperparameter ในแบบจำลอง เทคนิค GBM ใช้ package caret เพื่อ tune parameter ซึ่งมี 4 พารามิเตอร์ ได้แก่ n.trees, interaction.depth, shrinkage และ n.minobsinnode ในตอนแรกของการ tune parameter จะใช้ช่วงค่าที่กว้างที่แตกต่างกันมาก แล้วจึงปรับให้ค่าค่อย ๆ แคบลงเข้าใกล้ค่าพารามิเตอร์ที่ดีที่สุด
5. เมื่อวิธี GBM ได้ค่าพารามิเตอร์ที่เหมาะสมแล้วจะนำพารามิเตอร์ที่เหมาะสมนั้นไปสร้างแบบจำลองด้วย package gbm เพื่อให้สามารถวิเคราะห์ค่า VI ได้ สำหรับวิธี RF การ tune parameter และการสร้างแบบจำลองจะถูกดำเนินการพร้อมกัน โดย package caret

6. แบบจำลองที่ถูกพัฒนาขึ้นจะถูกนำไปใช้เพื่อทดสอบกับข้อมูลชุด test เพื่อประมาณค่าความยาวของแถวคอยเปรียบเทียบกับความยาวแถวคอยจริง และกำหนดดัชนีข้อผิดพลาด (RMSE และ MAPE)

7. ทำซ้ำขั้นตอนที่ 4-6 สำหรับตัวแปรอิสระชุดอื่น ๆ


2.4 ผลลัพธ์และการอภิปราย

2.4.1 ประสิทธิภาพของแบบจำลองการประมาณความยาวแถวคอย

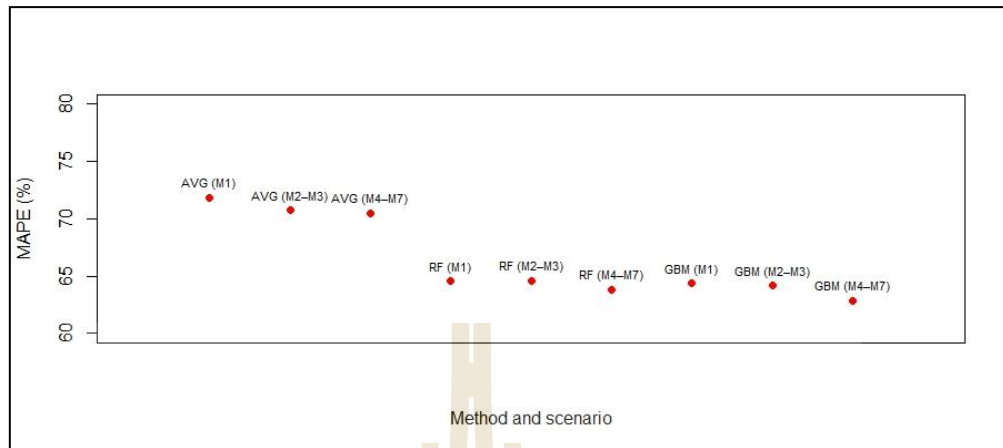
ประสิทธิภาพการทำนายของแบบจำลองการประมาณค่าความยาวแถวคอยที่ได้จากข้อมูลแถบสีโดยใช้วิธี RF, GBM และ Average จะถูกนำเสนอและเปรียบเทียบในหัวข้อนี้ ตารางที่ 2.3 แสดงค่า RMSE และ MAPE จากทั้งหมดสาม scenarios และสามชุดตัวแปรอิสระ ในขณะที่รูปที่ 2.7 - 2.8 แสดงเฉพาะค่าจาก IV3 ของแต่ละ scenarios และวิธี ผลลัพธ์แสดงให้เห็นว่าค่า RMSE และ MAPE ที่ต่ำที่สุดได้จากแบบจำลอง scenario 3 ด้วยชุดตัวแปร IV3 (รวมตัวแปรสีแดง และใช้ตัวแปรสีเขียวเป็นข้อมูลอ้างอิง) จากวิธี RF และ GBM ตามลำดับ อย่างไรก็ตาม เมื่อเปรียบเทียบค่า RMSE และ MAPE ใน scenario 3 กับค่าที่อยู่ใน scenario 1 และ 2 หรือ IV3 เทียบกับ IV1 และ IV2 จะไม่พบความแตกต่างที่มีนัยสำคัญ ค่าความผิดพลาดเกือบจะเท่ากันในทุก scenario และทุกรูปแบบของตัวแปรอิสระ ดังนั้นจึงไม่สามารถพูดถึงความแตกต่างระหว่างวิธี RF และ GBM ได้อย่างชัดเจน แต่อย่างไรก็ตาม ค่า RMSE และ MAPE ของทั้งสองวิธีนั้นยังต่ำกว่าค่าที่ได้จากวิธี Average ในทุกกรณี

ตารางที่ 2.3 ค่า RMSE และ MAPE ของทุกแบบจำลอง

| รูปแบบของตัวแปร | Random Forest | | Gradient Boosting | | Average | |
|-----------------|---------------|----------|-------------------|----------|-------------|----------|
| | RMSE (เมตร) | MAPE (%) | RMSE (เมตร) | MAPE (%) | RMSE (เมตร) | MAPE (%) |
| Scenario 1 | | | | | | |
| - IV1 | 71.8337 | 63.6274 | 72.7679 | 63.4070 | 83.9077 | 71.8533 |
| - IV2 | 72.6153 | 64.5514 | 72.0657 | 64.0463 | 83.9077 | 71.8533 |
| - IV3 | 72.5919 | 64.5336 | 72.6746 | 64.3501 | 83.9077 | 71.8533 |
| Scenario 2 | | | | | | |
| - IV1 | 72.1760 | 63.4921 | 72.7062 | 63.7009 | 81.8285 | 70.7399 |
| - IV2 | 71.8395 | 63.9266 | 72.2615 | 63.3056 | 81.8285 | 70.7399 |
| - IV3 | 71.9597 | 64.5817 | 73.2521 | 64.1587 | 81.8285 | 70.7399 |
| Scenario 3 | | | | | | |
| - IV1 | 72.0496 | 63.4174 | 72.5952 | 62.8423 | 81.6131 | 70.4689 |
| - IV2 | 72.2144 | 63.8694 | 71.9686 | 62.9886 | 81.6131 | 70.4689 |
| - IV3 | 71.6170 | 63.8278 | 72.3546 | 62.8304 | 81.6131 | 70.4689 |




รูปที่ 2.7 ค่า RMSE สำหรับ IV3 ของแต่ละวิธีและ scenario

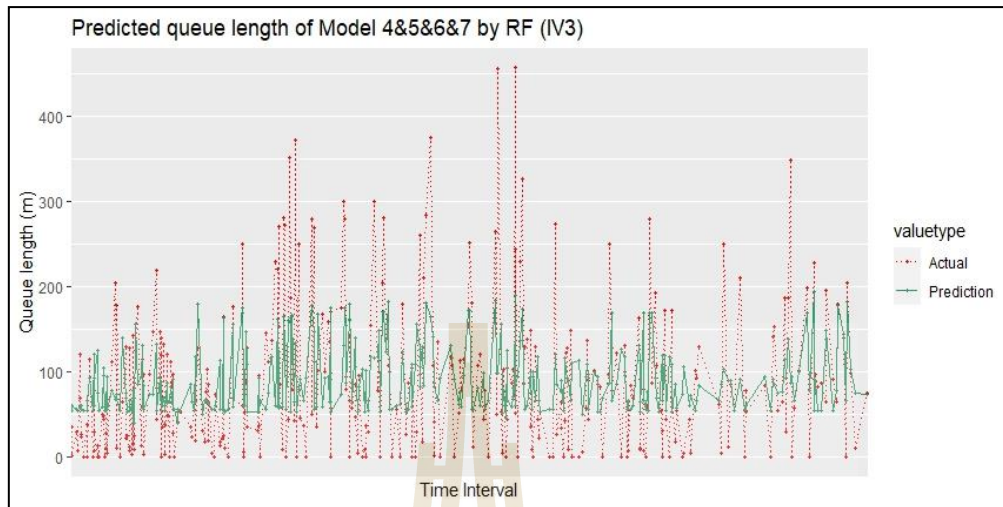


รูปที่ 2.8 ค่า MAPE สำหรับ IV3 ของแต่ละวิธีและ scenario


ตารางด้านบนแสดงให้เห็นว่าการประมาณค่าความยาวแถวคอยโดยใช้วิธี RF และ GBM นั้นดีกว่าการใช้วิธี Average อย่างมีนัยสำคัญ รูปที่ 2.9 – 2.11 แสดงความยาวแถวคอยจริงที่ได้รับจากชุดข้อมูล test เทียบกับความยาวแถวคอยที่มาจากการประมาณค่า ซึ่งได้มาโดยวิธีต่าง ๆ scenario 3 กับ IV3 แม้ว่าความยาวแถวคอยที่มาจากการประมาณค่าโดยวิธีการเฉลี่ยอาจแตกต่างกันเล็กน้อยขึ้นอยู่กับทิศทางและช่วงเวลา แต่ไม่สามารถติดตามการเปลี่ยนแปลงแบบไดนามิกของความยาวแถวคอยจริงได้ ในทางกลับกัน ความยาวแถวคอยที่ได้รับโดยวิธี RF และ GBM สามารถติดตามการเปลี่ยนแปลงแบบไดนามิกของความยาวแถวคอยจริงได้อย่างเพียงพอ แม้ว่าค่าความยาวแถวคอยที่ได้จากทั้งสองวิธีจะยังแตกต่างจากค่าจริงอยู่มาก แต่ความสามารถในการจับภาพการเปลี่ยนแปลงของความยาวแถวคอยจริงนั้นก็ยิ่งดีกว่าวิธี Average มาก



รูปที่ 2.9 ผลลัพธ์การประมาณค่าใน scenario 3 ด้วย IV3 โดยใช้วิธี Average



รูปที่ 2.10 ผลลัพธ์การประมาณค่าใน scenario 3 ด้วย IV3 โดยใช้วิธี RF



รูปที่ 2.11 ผลลัพธ์การประมาณค่าใน scenario 3 ด้วย IV3 โดยใช้วิธี GBM

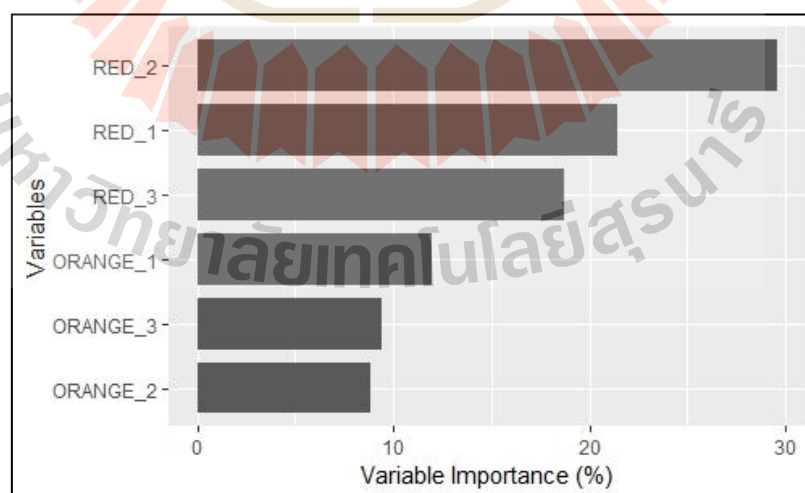
เป็นที่น่าสังเกตว่าข้อมูลการจราจรจาก Google Maps เป็นข้อมูลย้อนหลังตามการวัดครั้งก่อน การใช้ข้อมูลเหล่านี้สำหรับการควบคุมการจราจร โดยเฉพาะอย่างยิ่งในการให้สิทธิพิเศษผ่านทางอาจยังเป็นที่ยกเถียงกัน เนื่องจากการควบคุม ณ เวลาใดเวลาหนึ่งต้องปรับให้เข้ากับความยาวของแถวคอยในปัจจุบัน จากความแม่นยำในการประมาณค่าที่แสดงในตารางที่ 2.3 และรูปที่ 2.7 - 2.11 วิธีการที่น่าเสนออาจไม่เพียงพอสำหรับการดำเนินการในส่วนของการควบคุมการทำงาน แต่อาจมีประโยชน์สำหรับการออกแบบ เช่น การกำหนดความยาวของช่องจราจรเพิ่มเติมที่จะเลี้ยวบริเวณทางแยก

2.4.2 Variable Importance (VI)


เพื่อให้เกิดความเข้าใจมากขึ้นถึงระดับความสำคัญด้านลำดับของแถบสีและความยาวของแต่ละแถบสีส่งผลต่อความยาวของแถวค้อยอย่างไรและระดับความสำคัญดังกล่าวมีความแตกต่างกันหรือไม่ภายใต้กรณีที่แตกต่างกัน โดยเป็นการพิจารณาค่าระดับความสำคัญของตัวแปร (Variable Importance: VI) ที่ได้จากแบบจำลอง GBM Scenario 3 (M4-M7) และใช้รูปแบบของตัวแปรอิสระ IV3 ในการนำเสนอ โดยถ้าตัวแปรใดมีค่า Variable Importance สูงนั้นหมายความว่าตัวแปรนั้นจะมีความสำคัญและส่งผลต่อการประมาณค่าความยาวแถวค้อยสูงตามไปด้วย ผลการวิเคราะห์ค่า VI จะแสดงเป็นค่าเปอร์เซ็นต์เรียงลำดับจากมากไปน้อยในแต่ละแบบจำลอง ซึ่งแสดงดังตารางที่ 2.4 และรูปที่ 2.12 - 2.15

ตารางที่ 2.4 ค่า Variable Importance (VI) ของ Scenario 3 ด้วยตัวแปร IV3

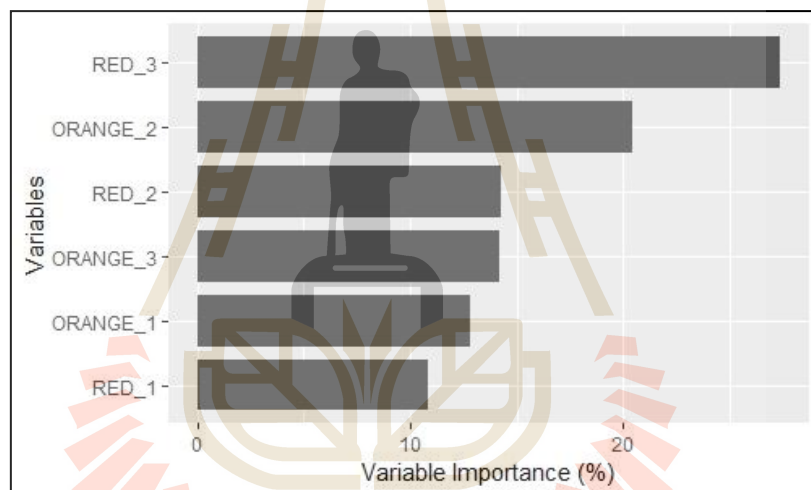
| แบบจำลองที่ 4 | | แบบจำลองที่ 5 | | แบบจำลองที่ 6 | | แบบจำลองที่ 7 | |
|---------------|----------|---------------|----------|---------------|----------|---------------|----------|
| ตัวแปร | VI (%) | ตัวแปร | VI (%) | ตัวแปร | VI (%) | ตัวแปร | VI (%) |
| C_RED_2 | 29.61612 | C_RED_2 | 26.47239 | C_RED_3 | 27.39859 | ORANGE_2 | 20.7503 |
| C_RED_1 | 21.44862 | C_RED_1 | 25.2194 | ORANGE_2 | 20.46706 | ORANGE_1 | 19.2972 |
| C_RED_3 | 18.73094 | ORANGE_2 | 17.23395 | C_RED_2 | 14.2542 | C_RED_1 | 16.48298 |
| ORANGE_1 | 11.94835 | C_RED_3 | 11.45329 | ORANGE_3 | 14.22236 | C_RED_3 | 16.19269 |
| ORANGE_3 | 9.398509 | ORANGE_3 | 11.24489 | ORANGE_1 | 12.81316 | ORANGE_3 | 14.51765 |
| ORANGE_2 | 8.857461 | ORANGE_1 | 8.376085 | C_RED_1 | 10.84463 | C_RED_2 | 12.75917 |



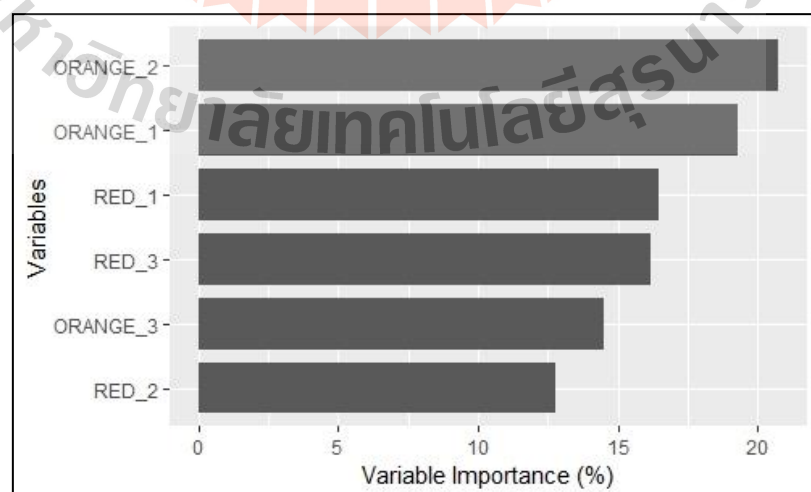
รูปที่ 2.12 ค่า Variable Importance (VI) ของ Model 4, Scenario 3 ด้วยตัวแปร IV3



รูปที่ 2.13 ค่า Variable Importance (VI) ของ Model 5, Scenario 3 ด้วยตัวแปร IV3



รูปที่ 2.14 ค่า Variable Importance (VI) ของ Model 6, Scenario 3 ด้วยตัวแปร IV3



รูปที่ 2.15 ค่า Variable Importance (VI) ของ Model 7, Scenario 3 ด้วยตัวแปร IV3

ผลของการวิเคราะห์ค่า VI ในกรณีของแบบจำลองที่ 4 และ 5 ซึ่งเป็นกรณีของฝั่งที่ไม่มีไฟสัญญาณจราจรก่อนหน้า จะสังเกตเห็นว่าตัวแปรระยะความยาวของแถบสีแดงที่อยู่ใกล้กับทางแยกจะมีความสำคัญมากแตกต่างจากตัวแปรอื่นอย่างเห็นได้ชัด โดยพบว่าตัวแปรที่มีค่า Variable Importance สูงที่สุดสองลำดับแรกได้แก่ C_RED_2 รองลงมาคือ C_RED_1 โดยในช่วงเวลาเร่งด่วน (Model 4) จะพบว่าระดับความสำคัญของแถบสี C_RED_2 ซึ่งมีความสำคัญสูงที่สุดนั้นจะมีค่าสูงแตกต่างจากลำดับที่รองลงมาอย่างเห็นได้ชัด (29.61 of C_RED_2 vs. 21.45 of C_RED_1) ซึ่งจะแตกต่างจากกรณีช่วงเวลาไม่เร่งด่วนที่ค่าระดับความสำคัญของตัวแปรที่มีความสำคัญที่สูงที่สุดนั้นจะไม่ค่อยแตกต่างจากตัวแปรที่มีความสำคัญในลำดับรองลงมา (26.47 of C_RED_2 vs. 25.22 of C_RED_1)

เมื่อพิจารณาเปรียบเทียบระหว่างช่วงเวลาเร่งด่วนและไม่เร่งด่วนของในฝั่งที่มีไฟสัญญาณจราจรก่อนหน้า (แบบจำลองที่ 6 และ 7) จะพบแนวโน้มทั้งที่มีความคล้ายกันและแตกต่างกันกับกรณีของฝั่งที่ไม่มีสัญญาณไฟก่อนหน้า (แบบจำลองที่ 4 และ 5) โดยในส่วนของแนวโน้มที่คล้ายกันนั้นจะพบว่าในกรณีช่วงเวลาเร่งด่วนนั้น ตัวแปรที่มีความสำคัญสูงที่สุดเป็นลำดับแรกนั้นจะมีค่าระดับความสำคัญแตกต่างจากลำดับที่สองอย่างเห็นได้ชัด (27.39 of C_RED_3 vs. 20.46 of ORANGE_2) และในช่วงเวลาไม่เร่งด่วนนั้นตัวแปรที่มีความสำคัญสูงที่สุดจะไม่ค่อยแตกต่างจากตัวแปรที่มีความสำคัญในลำดับรองลงมา (20.75 of ORANGE_2 vs. 19.29 of ORANGE_1) โดยเฉพาะใน Model 7 จะพบว่าค่าระดับความสำคัญของทุกตัวแปรจะไม่ค่อยแตกต่างกันมากนัก ซึ่งหมายความว่าแบบจำลองสามารถบันทึกการเปลี่ยนแปลงแบบไดนามิกของความยาวแถวคอยจริงได้เพียงบางส่วนเท่านั้น อย่างไรก็ตาม ในส่วนของแนวโน้มที่มีความแตกต่างจากฝั่งที่ไม่มีสัญญาณไฟก่อนหน้านั้นจะเป็นในเรื่องของลำดับความสำคัญของแถบสีซึ่งพบว่า C_RED_2 กับ C_RED_1 ไม่ใช่ตัวแปรที่มีความสำคัญสูงที่สุดสองลำดับแรกอีกต่อไป โดยพบว่าแถบสี C_RED_3 กับ ORANGE_2 หรือ ORANGE_1 กลับกลายเป็นแถบสีที่มีความสำคัญมากกว่า ทั้งนี้อาจจะเนื่องจากช่วงเวลาในการอัปเดตและแสดงแถบสีของ Google Maps ที่ไม่ได้เป็นแบบ real time โดยมีความล่าช้ากว่าการเปลี่ยนแปลงของสภาพจราจรจริง ทำให้แถบสีที่แสดงบน Google Maps ไม่ตรงกับระยะความยาวแถวคอยจริงที่ได้จากการสำรวจ โดยอาจมีลักษณะของ time-lag ประกอบกับลักษณะการกระจายตัวของปริมาณจราจรที่วิ่งเข้าสู่ทางแยกของฝั่งที่ไม่มีสัญญาณไฟก่อนหน้าที่มีลักษณะเป็นแบบสุ่มและมาอย่างต่อเนื่อง ซึ่งแตกต่างจากของฝั่งที่มีสัญญาณไฟก่อนหน้าที่มีลักษณะเป็นแบบกลุ่มก้อนสลับกับการเว้นว่างตามสัญญาณไฟเขียวหรือแดงของทางแยกก่อนหน้า ด้วยลักษณะดังกล่าวทำให้สภาพจราจรและแถวคอยในฝั่งที่มีสัญญาณไฟก่อนหน้ามีการแปรผันที่ค่อนข้างสูงกว่าฝั่งที่ไม่มีสัญญาณไฟก่อนหน้า ทำให้การแสดงผลแถบสีจาก Google Maps ในฝั่งที่มีสัญญาณไฟก่อนหน้านั้น

อาจจะไม่สามารถสะท้อนการเปลี่ยนแปลงของแถวคอยได้ดีเมื่อเทียบกับกรณีที่ไม่มีสัญญาณไฟก่อนหน้า

2.5 สรุป

วัตถุประสงค์ของบทความนี้คือการประมาณค่าความยาวแถวคอยบริเวณทางแยกที่มีไฟสัญญาณจราจรโดยใช้แหล่งข้อมูลใหม่ โดยเฉพาะข้อมูลจากข้อมูลแถบสีแสดงสภาพจราจรของ Google Maps โดยใช้แบบจำลอง Random Forest และ Gradient Boosting Machine เปรียบเทียบกับวิธีการประมาณแบบง่ายที่ใช้เพียงข้อมูลระยะความยาวแถวคอยเฉลี่ยในอดีต (วิธี Average) มีการทดลองปรับเปลี่ยนการจัดกลุ่มของตัวแปรแถบสีแตกต่างกัน 3 รูปแบบ โดยรูปแบบแรกใช้ข้อมูลแถบสีทั้ง 4 สีตามที่แสดงใน Google maps รูปแบบที่สองพิจารณาแถบสีแดงเข้มและสีแดงเป็นสีเดียวกัน และรูปแบบที่สามจะคล้ายกับรูปแบบที่สองแต่จะตัดตัวแปรแถบสีเขียวออกโดยเปรียบเทียบเป็นตัวแปรอ้างอิง งานวิจัยนี้แสดงให้เห็นว่าการสร้างแบบจำลองด้วยวิธี RF และ GBM ให้ประสิทธิภาพการทำนายที่ใกล้เคียงกันในทุก scenario และรูปแบบตัวแปรอิสระ และก็ยังดีกว่าแตกต่างจากวิธี Average อย่างเห็นได้ชัด

ผลการวิเคราะห์ค่า VI สำหรับฝั่งที่ไม่มีไฟสัญญาณจราจรก่อนหน้านี้พบว่าตัวแปรระยะความยาวของแถบสีแดงที่อยู่ใกล้กับทางแยกจะมีความสำคัญมาก ๆ แตกต่างจากตัวแปรอื่นอย่างเห็นได้ชัด อย่างไรก็ตามในฝั่งที่มีสัญญาณไฟก่อนหน้านี้พบว่าแถบสีที่มีความสำคัญจะแตกต่างกันขึ้นอยู่กับว่าเป็นช่วงเวลาเร่งด่วนหรือไม่เร่งด่วน โดยแถบสีแดงที่อยู่ใกล้กับทางแยกจะไม่ได้มีความสำคัญมากที่สุด แตกต่างจากกรณีของฝั่งที่ไม่มีสัญญาณไฟก่อนหน้านี้ และหากเป็นช่วงเวลาไม่เร่งด่วนจะพบว่าความสำคัญของตัวแปรแถบสีจะไม่ค่อยแตกต่างกันเท่าใดนัก ส่วนของลำดับแถบสีก็ยังคงมีความแตกต่างกันทั้งสองทิศทาง ทั้งนี้อาจจะเนื่องจากช่วงเวลาในการอัปเดตและแสดงแถบสีของ Google Maps ที่ไม่ได้เป็นแบบ real time ทำให้แถบสีที่แสดงบน Google Maps ไม่ตรงกับระยะความยาวแถวคอยจริงที่ได้จากการสำรวจ ประกอบกับความแตกต่างกันระหว่างลักษณะการกระจายตัวของปริมาณจราจรที่วิ่งเข้าสู่ทางแยกของฝั่งที่มีและไม่มีสัญญาณไฟก่อนหน้านี้ ส่งผลให้ฝั่งที่มีสัญญาณไฟก่อนหน้านี้ไม่สามารถจับภาพการเปลี่ยนแปลงความยาวแถวคอยจริงที่มีการเปลี่ยนแปลงแบบไดนามิกสูงได้ ดังนั้น จึงเป็นการยากที่แบบจำลองจะสามารถประมาณค่าระยะความยาวแถวคอยด้วยข้อมูลจากแถบสีได้

งานวิจัยนี้เป็นจุดเริ่มต้นของความเป็นไปได้ในการสร้างแบบจำลองประมาณค่าความยาวแถวคอยด้วยข้อมูลแถบสีจาก Google Maps และเป็นทางเลือกสำหรับทดแทนการใช้ข้อมูล detector ซึ่งสรุปได้ว่าแบบจำลองที่สร้างขึ้นในงานวิจัยนี้สามารถประมาณค่าความยาวแถวคอยได้แค่ส่วนหนึ่งเท่านั้น เนื่องจากค่า error จากการประมาณค่าที่ได้นี้ยังมีค่าค่อนข้างสูงแต่ก็ดีกว่าการใช้เพียงข้อมูลความยาวแถวคอยในอดีต โดยอาจเกิดจากหลายสาเหตุ โดยเฉพาะในเรื่องของความ

ละเอียดยของข้อมูลเส้นแถบสีจาก Google Maps อาทิเช่น การปรับปรุงและแสดงข้อมูลแถบสีของ Google Maps ที่อาจจะไม่ได้เป็นแบบ real-time ทำให้แถบสีที่แสดงไม่สามารถสะท้อนระยะความยาวแถวคอยที่มีการเปลี่ยนแปลงได้อย่างทันที่ นอกจากนั้น ความละเอียดของการแสดงผลความยาวแถบสีของ Google Maps ที่มักจะมีควมยาวปรับเปลี่ยนเป็นลำดับขั้นก็อาจจะส่งผลกระทบต่อการประมาณค่าระยะความยาวแถวคอยด้วยเช่นกัน ทิศทางการวิจัยในอนาคตคือการตรวจสอบว่าความแม่นยำในการประมาณความยาวแถวคอยตามเวลาจริงสามารถเพิ่มขึ้นได้อีกหรือไม่โดยการจัดหาเทคโนโลยีการประมวลผลข้อมูลทางอินเทอร์เน็ตที่มีความสามารถเพิ่มเติม เช่น การแสดงข้อมูลแถบสีแบบทันสมัย และความละเอียดในการแสดงผลที่ดีขึ้นของความยาวแถบสี หรือเทคนิค Machine-learning อื่น ๆ เช่น โครงข่ายประสาทเทียม (neural network) support vector machines และการเรียนรู้เชิงลึก (deep learning) จะถูกนำมาใช้และเปรียบเทียบ เพื่อปรับปรุงความแม่นยำในการทำนาย จุดสนใจอีกจุดหนึ่งคือการตรวจสอบและประเมินเวลาล่าช้าของการอัปเดต Google Maps และพัฒนาวิธีการรวมเวลาล่าช้าดังกล่าวเข้ากับขั้นตอนการประมาณค่าความยาวแถวคอย

2.6 เอกสารอ้างอิง

- พงศ์พัฒน์ จอดนอก และรัฐพล ภูบุบผาพันธ์. (2564). การประมาณความยาวของแถวคอยแบบแปรผันตามเวลาบริเวณทางแยกสัญญาณไฟจราจรโดยใช้ข้อมูลแถบสีจาก Google Maps. วารสารวิชาการ วิศวกรรมศาสตร์ ม. อบ.(Vol. 14 No. 4 (2021)).
- Agarwal, H., & Rai, J. (2022, 16-18 March 2022). *Traffic Control System based on Density with Emergency Priority Mechanism*. Paper presented at the 2022 International Conference on Electronics and Renewable Systems (ICEARS).
- Alex. (2022). Google Maps Traffic Color Legend – The 4 Colors Explained. Retrieved from <https://stereoupgrade.com/google-maps-traffic-color-legend/>
- An, C., Wu, Y., Xia, J., & Huang, W. (2018). Real-time queue length estimation using event-based advance detector data. *Journal of Intelligent Transportation Systems*, 22(4), 277-290. doi:10.1080/15472450.2017.1299011
- Anjaneyulu, M., & Kubendiran, M. (2023). Short-Term Traffic Congestion Prediction Using Hybrid Deep Learning Technique. *Sustainability*, 15(1), 74. Retrieved from <https://www.mdpi.com/2071-1050/15/1/74>
- Asgharizadeh, E., Jooybar, S., Mahdiraji, H. A., & Garza-Reyes, J. A. (2022). A Novel Travel Time Estimation Model for Modeling a Green Time-Dependent Vehicle

- Routing Problem in Food Supply Chain. *Sustainability*, 14(14), 8633. Retrieved from <https://www.mdpi.com/2071-1050/14/14/8633>
- Bae, B., Liu, Y., Han, L. D., & Bozdogan, H. (2019). Spatio-temporal traffic queue detection for uninterrupted flows. *Transportation Research Part B: Methodological*, 129, 20-34. doi:<https://doi.org/10.1016/j.trb.2019.09.001>
- Biau, G., & Scornet, E. (2016). A random forest guided tour. *TEST*, 25(2), 197-227. doi:10.1007/s11749-016-0481-7
- Cheng, J., Li, G., & Chen, X. (2019). Research on Travel Time Prediction Model of Freeway Based on Gradient Boosting Decision Tree. *IEEE Access*, 7, 7466-7480. doi:10.1109/ACCESS.2018.2886549
- Chuo, H., Seah, Y., Tan, K., Lim, K., Liau, C., & Kin Teo, K. (2022, 13-15 Sept. 2022). *On-Demand Priority Traffic Optimizer with Fuzzy Logic Microcontroller*. Paper presented at the 2022 IEEE International Conference on Artificial Intelligence in Engineering and Technology (IICAIET).
- Dumitrache, L., Nae, M., Simion, G., & Taloş, A.-M. (2020). Modelling Potential Geographical Access of the Population to Public Hospitals and Quality Health Care in Romania. *International Journal of Environmental Research and Public Health*, 17(22), 8487. Retrieved from <https://www.mdpi.com/1660-4601/17/22/8487>
- Google Maps. (2022). Use layers to find places, traffic, terrain, biking & transit. Retrieved from
- Greenwell, B., Boehmke, B., Cunningham, J., & Developers, G. B. M. (2022). gbm: Generalized Boosted Regression Models. Retrieved from <https://CRAN.R-project.org/package=gbm>
- Keawthong, P., Muangsin, V., & Gowanit, C. (2022). Location Selection of Charging Stations for Electric Taxis: A Bangkok Case. *Sustainability*, 14(17), 11033. Retrieved from <https://www.mdpi.com/2071-1050/14/17/11033>
- Kuhn, M. (2022). caret: Classification and Regression Training. Retrieved from <https://CRAN.R-project.org/package=caret>


- Lee, S., Wong, S. C., & Li, Y. C. (2015). Real-time estimation of lane-based queue lengths at isolated signalized junctions. *Transportation Research Part C: Emerging Technologies*, 56, 1-17. doi:<https://doi.org/10.1016/j.trc.2015.03.019>
- Li, X., & Bai, R. (2016, 18-20 Dec. 2016). *Freight Vehicle Travel Time Prediction Using Gradient Boosting Regression Tree*. Paper presented at the 2016 15th IEEE International Conference on Machine Learning and Applications (ICMLA).
- Ma, X., Ding, C., Luan, S., & Wang, Y. (2017). Prioritizing Influential Factors for Freeway Incident Clearance Time Prediction Using the Gradient Boosting Decision Trees Method. *IEEE Transactions on Intelligent Transportation Systems*, 18(9), 2303-2310. doi:10.1109/TITS.2016.2635719
- Mishra, S., Bhattacharya, D., & Gupta, A. (2018). Congestion Adaptive Traffic Light Control and Notification Architecture Using Google Maps APIs. *Data*, 3(4), 67. Retrieved from <https://www.mdpi.com/2306-5729/3/4/67>
- Moon, J., Hong, J., & Park, T. (2022). A Novel Method for Traffic Estimation and Air Quality Assessment in California. *Sustainability*, 14(15), 9169. Retrieved from <https://www.mdpi.com/2071-1050/14/15/9169>
- Nair, D. J., Gilles, F., Chand, S., Saxena, N., & Dixit, V. (2019). Characterizing multicity urban traffic conditions using crowdsourced data. *PLOS ONE*, 14(3), e0212845. doi:10.1371/journal.pone.0212845
- Naiudomthum, S., Winijkul, E., & Sirisubtawee, S. (2022). Near Real-Time Spatial and Temporal Distribution of Traffic Emissions in Bangkok Using Google Maps Application Program Interface. *Atmosphere*, 13(11), 1803. Retrieved from <https://www.mdpi.com/2073-4433/13/11/1803>
- Natekin, A., & Knoll, A. (2013). Gradient boosting machines, a tutorial. *Frontiers in Neurorobotics*, 7. doi:10.3389/fnbot.2013.00021
- Navarro-Espinoza, A., López-Bonilla, O. R., García-Guerrero, E. E., Tlelo-Cuautle, E., López-Mancilla, D., Hernández-Mejía, C., & Inzunza-González, E. (2022). Traffic Flow Prediction for Smart Traffic Lights Using Machine Learning Algorithms. *Technologies*, 10(1), 5. Retrieved from <https://www.mdpi.com/2227-7080/10/1/5>

- R Core Team. (2022). R: A Language and Environment for Statistical Computing. Vienna, Austria: R Foundation for Statistical Computing. Retrieved from <https://www.R-project.org/>
- Rahman, M. A., Hossain, A.-A., Debnath, B., Zefat, Z. M., Morshed, M. S., & Adnan, Z. H. (2021). Intelligent Vehicle Scheduling and Routing for a Chain of Retail Stores: A Case Study of Dhaka, Bangladesh. *Logistics*, 5(3), 63. Retrieved from <https://www.mdpi.com/2305-6290/5/3/63>
- Rezzouqi, H., Gryech, I., Sbihi, N., Ghogho, M., & Benbrahim, H. (2019, 2019//). *Analyzing the Accuracy of Historical Average for Urban Traffic Forecasting Using Google Maps*. Paper presented at the Intelligent Systems and Applications, Cham.
- Sihag, G., Parida, M., & Kumar, P. (2022). Travel Time Prediction for Traveler Information System in Heterogeneous Disordered Traffic Conditions Using GPS Trajectories. *Sustainability*, 14(16), 10070. Retrieved from <https://www.mdpi.com/2071-1050/14/16/10070>
- Tan, T.-H., Gochoo, M., Chen, Y.-F., Hu, J.-J., Chiang, J. Y., Chang, C.-S., . . . Hsu, J.-C. (2017). Ubiquitous Emergency Medical Service System Based on Wireless Biosensors, Traffic Information, and Wireless Communication Technologies: Development and Evaluation. *Sensors*, 17(1), 202. Retrieved from <https://www.mdpi.com/1424-8220/17/1/202>
- Venkat, G., Arulananth, T. S., & Baskar, M. (2019). Density based traffic controller with emergency override using CCTV camera. *International Journal of Recent Technology and Engineering*, 8(2 Special issue 3), 866-869. doi:10.35940/ijrte.B1162.0782S319
- Wu, M., Ke, C., & Lai, S. (2022). Optimizing the Routing of Urban Logistics by Context-Based Social Network and Multi-Criteria Decision Analysis. *Symmetry*, 14(9), 1811. Retrieved from <https://www.mdpi.com/2073-8994/14/9/1811>
- Xu, N., Xu, Y., Yan, Y., Guo, Z., Wang, B., & Zhou, X. (2022). Evaluating Road Lighting Quality Using High-Resolution JL1-3B Nighttime Light Remote Sensing Data: A Case Study in Nanjing, China. *Remote Sensing*, 14(18), 4497. Retrieved from <https://www.mdpi.com/2072-4292/14/18/4497>

Yang, S., Wu, J., Du, Y., He, Y., & Chen, X. (2017). Ensemble Learning for Short-Term Traffic Prediction Based on Gradient Boosting Machine. *Journal of Sensors*, 2017, 1-15. doi:10.1155/2017/7074143

Yao, J., & Tang, K. (2019). Cycle-based queue length estimation considering spillover conditions based on low-resolution point detector data. *Transportation Research Part C: Emerging Technologies*, 109, 1-18.

doi:<https://doi.org/10.1016/j.trc.2019.10.003>



บทที่ 3

การวิเคราะห์ผลของปัจจัยความละเอียดด้านเวลาและระยะทางของการประมวลผลข้อมูลแถบสีแสดงสภาพจราจรต่อการประมาณค่าระยะความยาว

แถวคอย

3.1 บทคัดย่อ

ระยะความยาวแถวคอยเป็นหนึ่งในข้อมูลสำคัญสำหรับการบริหารจัดการทางแยกที่มีไฟสัญญาณจราจร งานวิจัยของ พงศ์พัฒน์ จอดนอก และรัฐพล ภูบุบผาพันธ์ (2564) และ Sornsoongnern, Pueboobpaphan, and Pueboobpaphan (2023) รวมทั้งวิทยานิพนธ์ของ พงศ์พัฒน์ จอดนอก (2563) ได้ทำการประมาณค่าระยะความยาวแถวคอยจากการใช้ข้อมูลแถบสีของ Google Maps แต่ประสิทธิภาพการทำนายของวิธีการดังกล่าวยังให้ผลการทำนายที่ไม่ดีนัก ด้วยข้อสันนิษฐานที่ว่าอาจเป็นเพราะปัจจัยความละเอียดด้านเวลาและความละเอียดด้านระยะทางของข้อมูลแถบสีที่ได้รับมาจาก Google Maps โดยความละเอียดด้านเวลาในที่นี้หมายถึง ความล่าช้าในการประมวลผลและแสดงแถบสี โดยเริ่มนับตั้งแต่เวลาที่ระบบได้รับข้อมูลความเร็วของรถบนช่วงถนน จนกระทั่งระบบประมวลผลเสร็จและแสดงผลของแถบสีบน Google Maps และความละเอียดด้านระยะทาง หมายถึง การแบ่งระยะความยาวของช่วงถนนสำหรับประมวลผลและแสดงแถบสี ซึ่งจะเป็ระยะความยาวของแถบสีที่สั้นที่สุดที่เป็นไปได้ และความยาวของแถบสีที่ระบบแสดงผลออกมาจะมีระยะความยาวเป็นจำนวนเท่าของการแบ่งช่วงนี้ ดังนั้นงานวิจัยนี้จึงทำการวิเคราะห์และประเมินผลเกี่ยวกับปัจจัยความละเอียดด้านเวลาและความละเอียดด้านระยะทางที่อาจส่งผลต่อการประมาณค่าระยะความยาวแถวคอยบริเวณทางแยกที่มีไฟสัญญาณจราจร โดยมีการสร้างแบบจำลองจราจรแล้วนำข้อมูลการเคลื่อนที่ของยานรายคัน (Trajectory data) มาสกัดเป็นข้อมูลระยะความยาวแถวคอย นอกจากนั้นยังทำการประมวลผลเพื่อสร้างข้อมูลแถบสีจากความเร็วของยานรายคันให้มีคุณลักษณะคล้ายกับแถบสีของ Google Maps ซึ่งข้อมูลเหล่านั้นจะมีปัจจัยความละเอียดด้านเวลาและความละเอียดด้านระยะทางที่ต่างกัน และใช้วิธี Gradient Boosting Machine ในการสร้างแบบจำลองการประมาณค่าระยะความยาวแถวคอย ผลจากการศึกษาพบว่าแบบจำลองการประมาณค่าระยะความยาวแถวคอยจากชุดข้อมูลเฉพาะในช่วงไฟจราจรสีแดงและจากปัจจัยความละเอียดด้านเวลาและความละเอียดด้านระยะทางที่มีค่าละเอียดมากที่สุดส่งผลให้แบบจำลองมีประสิทธิภาพดีที่สุด และปัจจัยด้านความละเอียดด้านเวลาและความละเอียดด้านระยะทางที่ละเอียด

ที่สุดทำให้การตรวจจับแฉกคอยสามารถทำได้ทันเวลาและลดข้อผิดพลาดได้มากกว่าเมื่อเปรียบเทียบกับค่าความละเอียดด้านเวลาและความละเอียดด้านระยะทางที่ค่าอื่น นอกจากนี้ค่า Variable Importance (VI) ยังแสดงให้เห็นว่าตัวแปรแถบสีแดงเข้มและแถบสีแดงมีความสำคัญต่อการประมาณค่าระยะความยาวแฉกคอยมากที่สุด แต่ถึงแม้ว่าประสิทธิภาพการทำนายจะให้ผลลัพธ์ที่ค่อนข้างดีแต่ก็ยังมีค่า error เกิดขึ้น ซึ่งสันนิษฐานได้ว่าอาจเกิดจากปัจจัยอื่น ๆ เพิ่มเติม ยกตัวอย่าง เช่น ปัจจัยทางด้านกายภาพของถนน, ระยะเวลาสัญญาณไฟจราจร หรือวิธีที่นำมาใช้ในการสร้างแบบจำลองการทำนาย เป็นต้น ซึ่งในงานวิจัยนี้จะเป็นประโยชน์อย่างมาก ถ้าหากในอนาคต Google Maps หรือแพลตฟอร์มที่มีข้อมูลแถบสีแสดงสภาพการจราจรต่าง ๆ สามารถปรับปรุงประสิทธิภาพการประมวลผลและแสดงผลข้อมูลให้มีความละเอียดและรวดเร็วยิ่งขึ้นแล้ว จะทำให้สามารถใช้ข้อมูลแถบสีจาก Google Maps หรือแพลตฟอร์มนั้น ๆ ในการประมาณค่าระยะความยาวแฉกคอยได้ดียิ่งขึ้น ซึ่งจะเป็นอีกหนึ่งทางเลือกในการใช้งานข้อมูลทดแทนการใช้ข้อมูลจาก detector หรือเทคโนโลยีอุปกรณ์ราคาแพงต่าง ๆ



คำสำคัญ: ระยะความยาวแฉกคอย, Google Maps, Gradient Boosting Machine, Variable Importance, ทางแยกที่มีไฟสัญญาณจราจร, แบบจำลองจราจร, Aimsun

3.2 บทนำ

การจัดการกับแฉกคอบริเวณทางแยกที่มีไฟสัญญาณจราจรจะช่วยให้การจราจรมีสภาพที่คล่องตัวและเดินทางได้รวดเร็วมากขึ้น นอกจากนี้ในปัจจุบันได้มีระบบไฟสัญญาณจราจรที่จะทำการตรวจจับแฉกคอบด้วยอุปกรณ์ต่าง ๆ และนำเข้าข้อมูลแฉกคอบไปประมวลผล เพื่อบริหารจัดการให้สิทธิพิเศษแก่รถฉุกเฉินที่ต้องเดินทางผ่านทางแยกด้วยความรวดเร็ว (Agarwal & Rai, 2022) (Chuo et al., 2022) (Vishnu, Sarma, Yashumithaa, Kr, & Gv, 2022) (Venkat et al., 2019) งานวิจัยส่วนใหญ่จะใช้ข้อมูลจราจรที่ได้จาก detector ร่วมกับการใช้ทฤษฎี shockwave สร้างวิธีการประมาณค่าระยะความยาวแฉกคอบหรือการตรวจสอบประสิทธิภาพของวิธีการเหล่านั้น โดยพบว่าสามารถประมาณค่าระยะความยาวแฉกคอบได้อย่างมีประสิทธิภาพ และยังสามารถนำข้อมูลความยาวแฉกคอบไปใช้ร่วมกับการบริหารจัดการไฟสัญญาณจราจรได้ (An et al., 2018) (Bae et al., 2019) (Lee et al., 2015)

เนื่องจากข้อจำกัดที่ว่าบริเวณทางแยกของประเทศไทยแทบทุกพื้นที่ที่ยังไม่ได้มีการติดตั้ง detector ดังนั้นในงานวิจัยของ พงศ์พัฒน์ จอดนอก และรัฐพล ภูบุบผาพันธ์ (2564) ที่ทำการศึกษาการประมาณค่าระยะความยาวแฉกคอบบริเวณทางแยกในประเทศไทย จึงทำการประยุกต์ใช้แถบสีแสดงสภาพการจราจรบน Google Maps มาใช้ในการสร้างแบบจำลองการประมาณค่าระยะความยาวแฉกคอบ โดยแถบสีจาก Google Maps จะแสดงทั้งหมด 4 แถบสี ได้แก่ สีแดงเข้ม, สีแดง, สีส้ม และสีเขียว ซึ่งแสดงสภาพการไหลของการจราจรบนช่วงถนนจากสภาพการไหลน้อยไปสภาพการไหลมาก ตามลำดับ ข้อมูลแถบสีที่ถูกนำมาใช้ในการแสดงสภาพการจราจรของ Google Maps จะถูกเก็บจากผู้ใช้งานบนท้องถนนที่เปิด GPS บนโทรศัพท์ ซึ่งเป็นการเก็บข้อมูลความเร็วในการเดินทางของยานพาหนะแต่ละคันในช่วงพื้นที่หนึ่งแล้วนำไปคำนวณเป็นค่าเฉลี่ยความเร็วของยานพาหนะทั้งหมดที่อยู่บนถนนช่วงนั้น (Google Maps, 2022) ตัวแปรแถบสีเหล่านั้นถูกนำมาใช้สร้างแบบจำลองด้วยวิธี Linear regression analysis และ Random forest (RF) โดยแบ่งแบบจำลองตามช่วงเวลาเร่งด่วนและช่วงเวลาไม่เร่งด่วน ผลลัพธ์ที่ได้พบว่าการใช้แถบสีจาก Google Maps ให้ผลการประมาณค่าระยะความยาวแฉกคอบได้ดีในระดับหนึ่ง แต่ยังมีค่า error ที่สูง ดังนั้นในงานวิจัยของ Sornsoongnern et al. (2023) จึงทำการศึกษาเพื่อพัฒนาและปรับปรุงแนวทางการใช้งานข้อมูลแถบสีต่อยอดงานวิจัยดังกล่าว โดยนำข้อมูลแถบสีจาก Google Maps มาสกัดรูปแบบของตัวแปรใหม่และทำการเปรียบเทียบกับรูปแบบเดิม ได้แก่ IV1: ใช้ตัวแปรแถบสีแบบเดิมทั้งหมด 4 สี, IV2: รวมตัวแปรแถบสีแดงเข้มกับตัวแปรแถบสีแดงและ IV3: รวมตัวแปรแถบสีแดงเข้มกับตัวแปรสีแถบแดงและให้ตัวแปรแถบสีเขียวเป็นตัวแปรอ้างอิง รวมทั้งการเพิ่มแบบจำลองเป็น 3 Scenarios ที่แบ่งตามทิศทางที่มีหรือไม่มีไฟสัญญาณจราจรก่อนหน้าและแบ่งตามช่วงเวลาเร่งด่วนหรือไม่เร่งด่วน นอกจากนี้ยังเพิ่มวิธี Gradient boosting machine (GBM) สำหรับการสร้างแบบจำลองประมาณค่า

ความยาวแถวคอย พบว่าเมื่อมีการจัดรูปแบบของแถบสีและแบบจำลองใหม่ส่งผลทำให้แบบจำลองมีประสิทธิภาพการทำนายที่ดีขึ้น และฝั่งที่ไม่มีไฟสัญญาณจราจรก่อนหน้านี้มีประสิทธิภาพในการเป็นข้อมูลที่ใช้สร้างแบบจำลองที่ดีกว่าฝั่งที่มีไฟสัญญาณจราจรก่อนหน้านี้ นอกจากนี้ค่า Variable Importance (VI) ยังแสดงให้เห็นว่าตัวแปรแถบสีแดงมีความสำคัญต่อการสร้างแบบจำลองมากกว่าตัวแปรแถบสีอื่น ผลลัพธ์จากทั้งสองงานวิจัย พงศ์พัฒน์ จอดนอก และรัฐพล ภูบุบผาพันธ์ (2564) และ Sornsoongnern et al. (2023) แสดงให้เห็นว่าข้อมูลแถบสีที่ได้จาก Google Maps มีศักยภาพในการประมาณค่าความยาวแถวคอย แต่เนื่องจากค่า error ที่สูง งานวิจัยของ Sornsoongnern et al. (2023) จึงมีข้อสันนิษฐานว่าอาจเกิดจากการที่ข้อมูลแถบสีของ Google Maps ไม่ได้มีการอัปเดตแบบทันทีและมีความละเอียดด้านระยะทาง (การแบ่งความยาวช่วงถนน) ขั้นต่ำที่แสดงแถบสีหนึ่ง ๆ อาจจะยาวเกินไป ดังนั้นปัจจัยเหล่านี้จึงอาจส่งผลทำให้ค่า error ที่ได้จากแบบจำลองมีค่าที่สูง

งานวิจัยนี้จึงจัดทำขึ้นเพื่อทดสอบข้อสันนิษฐานจากงานของ Sornsoongnern et al. (2023) ที่กล่าวมาเบื้องต้น โดยข้อมูลตัวแปรแถบสีจะได้มาจากการสร้างแบบจำลองจราจรบนโปรแกรม Aimsun และสกัดข้อมูลที่คล้ายกันกับข้อมูลแถบสีของ Google Maps มีการกำหนดค่าปัจจัยความละเอียดด้านเวลาและความละเอียดด้านระยะทางที่ค่าแตกต่างกันตั้งแต่ค่าที่มีความละเอียดสูงไปยังค่าที่มีความละเอียดต่ำ เพื่อทำการวิเคราะห์และเปรียบเทียบผลที่ได้ โดยข้อมูลที่ใช้จะเป็นข้อมูลในกรณีที่ไม่มีสัญญาณไฟจราจรก่อนหน้านี้เนื่องจากงานวิจัย Sornsoongnern et al. (2023) พบว่าข้อมูลจากถนนที่ไม่มีไฟสัญญาณจราจรก่อนหน้านี้ให้ผลการทำนายที่มีความสมเหตุสมผลมากกว่าข้อมูลจากถนนที่มีไฟสัญญาณจราจรก่อนหน้านี้ และใช้วิธี Gradient Boosting Machine (GBM) ในการสร้างแบบจำลองการประมาณค่าระยะความยาวแถวคอย เนื่องจากเป็นวิธีที่พบว่าให้ผลลัพธ์ในการทำนายที่ดี (Sornsoongnern et al., 2023) นอกจากนี้ในงานวิจัยอื่นที่เกี่ยวข้องกับวิศวกรรมขนส่งและการจราจร เช่น การพยากรณ์ปริมาณจราจรในช่วงระยะเวลาสั้น ๆ (Moon et al., 2022) และการคาดการณ์เวลาในการจัดการกับสถานการณ์จราจรต่าง ๆ ที่เกิดขึ้น (Dumitrache et al., 2020) ต่างก็พบว่าวิธี GBM ให้ผลลัพธ์การทำนายที่ดีกว่าวิธีการสร้างแบบจำลองวิธีอื่น นอกเหนือจากการที่ GBM สามารถสร้างแบบจำลองที่มีประสิทธิภาพสูงได้แล้วนั้น วิธี GBM ยังสามารถวิเคราะห์และแสดงค่า Variable Importance (VI) ได้อีกด้วย ซึ่งค่า VI นี้จะทำให้สามารถตรวจสอบได้ว่าตัวแปรใดที่มีความสำคัญและมีความสัมพันธ์กับระยะความยาวแถวคอยมากที่สุด หรืออีกนัยหนึ่งก็คือสามารถอธิบายได้ว่าตัวแปรอิสระแต่ละตัวส่งผลต่อตัวแปรตามมากน้อยแตกต่างกันอย่างไร (Wu et al., 2022)

ในหัวข้อถัดไปจะกล่าวถึงรายละเอียดการสร้างข้อมูลแถบสีทั้งในส่วนของการสร้างแบบจำลองจราจร ซึ่งจะมีการกำหนดค่าพารามิเตอร์แบบจำลองจราจรบนโปรแกรม Aimsun และรายละเอียดการสกัดข้อมูลที่ได้จากแบบจำลองจราจรให้มีคุณลักษณะคล้ายกับแถบสีจาก Google

Maps ตามปัจจัยความละเอียดด้านเวลาและความละเอียดด้านระยะทางที่กำหนดไว้ จากนั้นจึงกล่าวถึงการสร้างแบบจำลองประมาณค่าความยาวแฉกด้วยวิธี GBM โดยมีการปรับค่าพารามิเตอร์ของแบบจำลองทางสถิติให้มีความเหมาะสม เพื่อให้ได้แบบจำลองที่ดีที่สุด และการวิเคราะห์ประสิทธิภาพในการทำนายของแบบจำลองและความสำคัญของตัวแปร ปิดท้ายด้วยบทสรุปและข้อเสนอแนะ

3.3 ข้อมูลการศึกษา

3.3.1 แบบจำลองจราจร

ในส่วนนี้จะกล่าวถึงการสร้างแบบจำลองจราจรบนโปรแกรม Aimsun และการปรับแก้ค่าพารามิเตอร์ที่เกี่ยวกับการสร้างแบบจำลองจราจรบนโปรแกรม Aimsun งานวิจัยนี้ทำการสร้างแบบจำลองจราจรของถนนสายหนึ่งบนโปรแกรม Aimsun เป็นการจำลองสภาพการจราจรบริเวณถนนที่มีไฟสัญญาณจราจร ระยะเวลาในแบบจำลองทั้งหมด 9 ชั่วโมง 10 นาที (warm-up 10 นาที) ดังนั้นข้อมูลที่ใช้ในงานวิจัยนี้จะได้ข้อมูลเป็นระยะเวลาทั้งหมด 9 ชั่วโมง หรือ 32,400 วินาที บนแบบจำลองบนโปรแกรม Aimsun แสดงดังรูปที่ 3.1 ซึ่งในงานวิจัยนี้จะสร้างแบบจำลองจราจรภายใต้สถานการณ์ดังต่อไปนี้

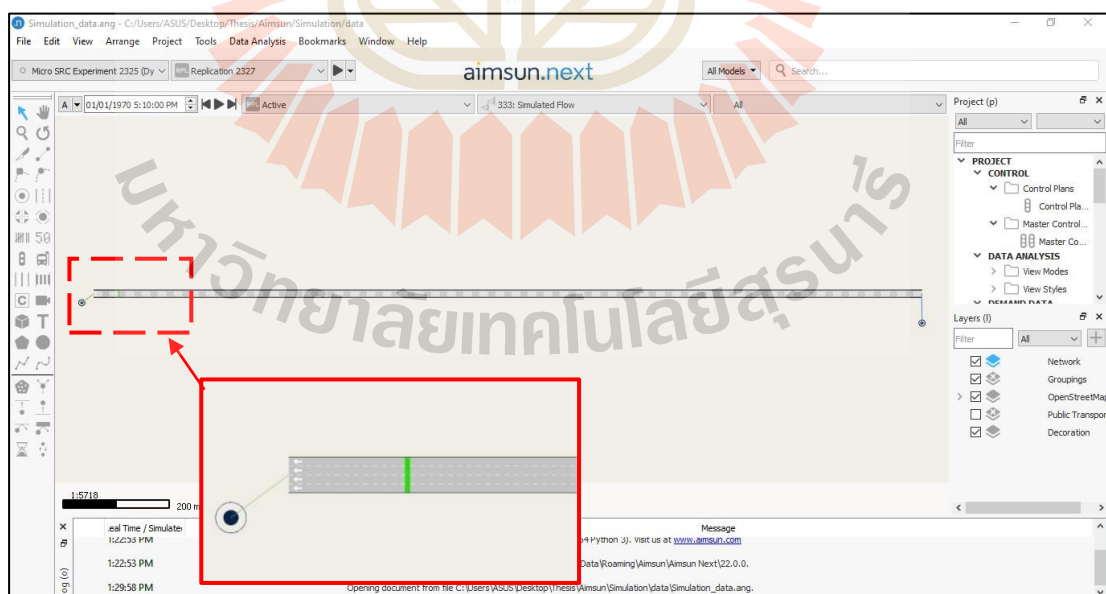
1) ปัจจัยทางกายภาพถนน: ลักษณะของแบบจำลองจราจรเป็นถนนหนึ่งเส้นที่เป็นลักษณะเส้นตรงยาว มีขนาดความยาวประมาณ 2,000 เมตร มีจำนวน 4 ช่องจราจร โดยทั้ง 4 ช่องจราจรมีทิศทางการเดินทางเดียวกันคือ วิ่งเข้าสู่ไฟสัญญาณจราจร (จากทางขวาของรูปภาพไปยังทางซ้ายของรูปภาพ) ขนาดของ 1 ช่องจราจรเท่ากับ 3.5 เมตร โดยลักษณะของแบบจำลองจราจรจะคล้ายกับลักษณะทางกายภาพของถนนในพื้นที่ศึกษาของ พงศ์พัฒน์ จอดนอก และรัฐพล ภูบุงผาพันธ์ (2564) และ Sornsoongnern et al. (2023) ที่ทำการสำรวจและเก็บข้อมูลงานวิจัยจากการลงสำรวจในพื้นที่จริงบนถนนทางหลวงหมายเลข 2 ตำบลในเมือง อำเภอเมือง จังหวัดนครราชสีมา ประเทศไทย

2) ระยะเวลาไฟสัญญาณจราจร: มีการปรับค่าระยะเวลาไฟสัญญาณจราจร โดยอ้างอิงจากการลงสำรวจในพื้นที่การศึกษาจริงจากพื้นที่การสำรวจเดียวกันกับงานวิจัยของ พงศ์พัฒน์ จอดนอก และรัฐพล ภูบุงผาพันธ์ (2564) และ Sornsoongnern et al. (2023) ซึ่งมีรอบเวลาสัญญาณไฟจราจร (Cycle Length) เท่ากับ 220 วินาที (ไฟจราจรสีเขียว 105 วินาที, สีเหลือง 3 วินาที และสีแดง 112 วินาที)

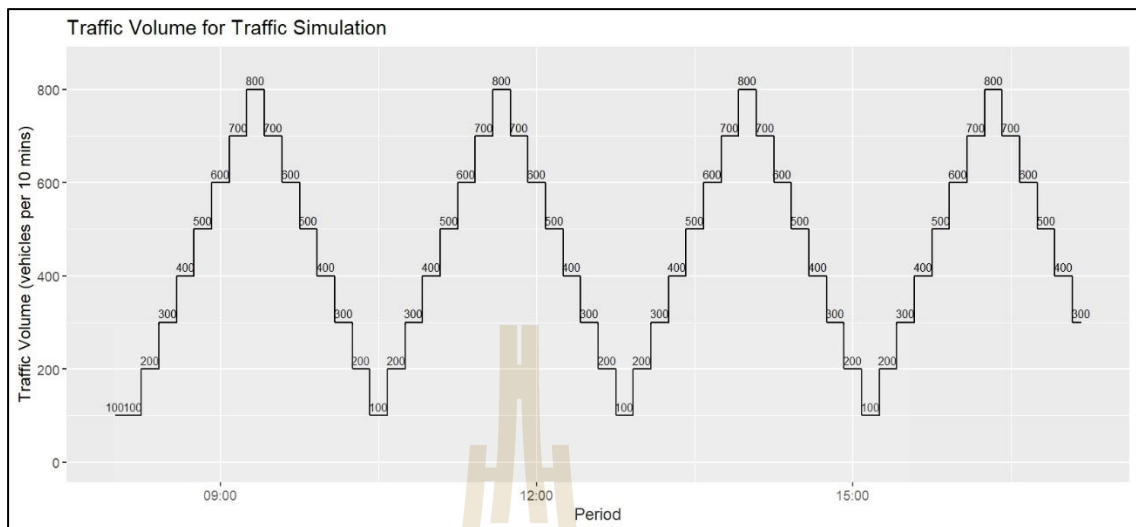
3) ค่าพารามิเตอร์เกี่ยวกับคุณลักษณะพฤติกรรมจราจรที่ในงานวิจัยนี้ได้ทำการปรับค่าต่าง ๆ ที่เกี่ยวข้องกับคุณลักษณะพฤติกรรมจราจรของผู้ขับขี่ในลักษณะเดียวกับแบบจำลองจราจรในงานปริญญาบัตรของกฤติพร พึ่งสมบัติ et al. (2564) นักศึกษาวิศวกรรมขนส่ง ซึ่งใน

งานวิจัยดังกล่าวได้มีการทดสอบและตรวจสอบการตั้งค่าที่เกี่ยวข้องกับคุณลักษณะพฤติกรรมการขับที่ไว้อย่างดีแล้ว โดยลักษณะของพื้นที่การศึกษาในงานวิจัยดังกล่าวมีความคล้ายคลึงและสามารถนำมาประยุกต์ใช้ในงานวิจัยขั้นนี้ได้ และเพื่อเป็นการควบคุมปัจจัยภายนอกอื่น ๆ ในแบบจำลองจราจรของงานวิจัยนี้ได้กำหนดประเภทของยานพาหนะบนถนนเป็นประเภทรถยนต์ส่วนบุคคลเท่านั้น

4) ปริมาณจราจร: จากการสังเกตแบบจำลองจราจรบนโปรแกรม Aimsun พบว่ากรณีที่กำหนดให้รถวิ่งเข้ามาในแบบจำลองจราจรที่ 900 คันต่อ 10 นาที รถที่วิ่งเข้ามาในแบบจำลองจะเกิดแถวคอยสะสมที่มีความยาวของแถวคอยยาวเกินความยาวของถนนที่ได้กำหนดไว้ (2,000 เมตร) จึงมีการทดลองหาค่าสูงสุดที่สามารถสร้างแถวคอยได้โดยที่ความยาวแถวคอยนั้นต้องไม่เกินความยาวของถนนในแบบจำลองจราจร ซึ่งจากการทดลองได้ค่าที่ 800 คันต่อ 10 นาที ในงานวิจัยนี้จึงพิจารณาการป้อนข้อมูลปริมาณจราจรแบบแปรผันทุก ๆ 10 นาที และให้มีค่าที่ครอบคลุมค่าต่ำสุดและสูงสุดของปริมาณจราจร เพื่อให้การสร้างข้อมูลด้วยแบบจำลองจราจรสามารถครอบคลุมในกรณีที่ระยะความยาวแถวคอยมีระยะที่สั้นและยาว ซึ่งปริมาณจราจรที่ใช้ในแบบจำลองจราจรแสดงดังรูปที่ 3.2 โดยเริ่มต้นปริมาณจราจรช่วงเวลา warm-up ที่ 100 คันต่อ 10 นาที จากนั้นในช่วงของการเริ่มเก็บข้อมูล ปริมาณจราจรจะเริ่มต้นที่ 100 คันต่อ 10 นาที และเพิ่มขึ้น 100 คันต่อ 10 นาที ในทุก ๆ 10 นาที จนถึงปริมาณจราจรสูงสุดที่กำหนดไว้คือ 800 คันต่อ 10 นาที จากนั้นปริมาณจราจรก็จะลดลงทุก ๆ 10 นาทีจนถึง 100 คันและเพิ่มขึ้นใหม่อีกครั้ง เพิ่มและลดลงซ้ำในลักษณะเดียวกันจนครบระยะเวลา 9 ชั่วโมง 20 นาที



รูปที่ 3.1 แบบจำลองจราจรบนโปรแกรม Aimsun



รูปที่ 3.2 ปริมาณจราจรบนโปรแกรม Aimsun

ข้อมูลที่ได้จาก Aimsun จะเป็นข้อมูล Vehicle trajectory จำนวน 1 ชุดข้อมูล ซึ่งข้อมูล Vehicle trajectories คือข้อมูลที่โปรแกรม Aimsun ทำการติดตามบันทึกการเดินทางของยานพาหนะทุกคันในทุก ๆ 1 วินาที ตั้งแต่ที่เริ่มวิ่งเข้าสู่ถนนจนออกจากแบบจำลองจราจรไป โดยข้อมูล Vehicle trajectory ส่วนที่ถูกใช้ในงานวิจัยนี้ ได้แก่ ข้อมูลด้านเวลา (stationaryTime), ข้อมูลความเร็วของยานพาหนะ ณ เวลาขณะหนึ่ง (speed), ตำแหน่งของรถบนช่องทางจราจร (laneIndex) และ ข้อมูลตำแหน่งพิกัดของยานพาหนะ ณ เวลาขณะหนึ่ง (xCoord, yCoord)

3.3.2 การสกัดข้อมูลที่ได้จากโปรแกรม Aimsun

ในส่วนนี้จะกล่าวถึงการนำข้อมูล Vehicle trajectory (.sqlite) ไปสกัดให้กลายเป็นข้อมูลตัวแปรแถบสีและตัวแปรความยาวแถบคอยจริงโดยใช้โปรแกรม R ซึ่งในการสกัดข้อมูลตัวแปรแถบสีนั้น เนื่องจากจุดประสงค์ของงานวิจัยนี้คือการวิเคราะห์และประเมินผลของความละเอียดด้านเวลาและความละเอียดด้านระยะทาง ดังนั้น จึงได้มีการกำหนดความละเอียดด้านเวลาและความละเอียดด้านระยะทางที่แตกต่างกันไว้ดังนี้

1) ความละเอียดทางด้านเวลา: ในงานวิจัยนี้ได้พิจารณาความละเอียดด้านเวลา โดยอ้างอิงจากระยะเวลาความล่าช้าที่เกิดขึ้นซึ่งเริ่มต้นจากระบบ ที่ทำการดึงข้อมูลความเร็วและตำแหน่งของรถในแต่ละช่วงถนน จนกระทั่งระบบทำการประมวลผลความเร็วเฉลี่ยในแต่ละช่วงถนนและแสดงแถบสีที่เหมาะสมตามความเร็วเฉลี่ยของช่วงถนนนั้น ๆ ซึ่งในที่นี้พิจารณาความล่าช้าไว้ที่ 5 ระดับ ได้แก่ 0, 10, 20, 30 และ 60 วินาที

2) ความละเอียดด้านระยะทาง: ในงานวิจัยนี้ได้พิจารณาความละเอียดด้านระยะทาง ซึ่งเป็นความยาวช่วงถนนที่สั้นที่สุดที่ระบบจะทำการประมวลผลความเร็วเฉลี่ยบนระยะทางดังกล่าว

และเป็นความยาวที่สั้นที่สุดที่เป็นไปได้ของแถบสีหนึ่ง ๆ ในที่นี้พิจารณาความละเอียดด้านระยะทางที่ 4 ระดับ ได้แก่ 25, 50, 100 และ 200 เมตร

เนื่องจากงานวิจัยนี้ทำการสร้างแบบจำลองทางแยกที่มีไฟสัญญาณจราจร เพื่อสร้างข้อมูลแถบสีแสดงสภาพจราจรเลียนแบบแถบสีแสดงสภาพจราจรบน Google Maps ทำให้ต้องมีการศึกษาค่าต่าง ๆ ของ Google Maps ให้ได้ค่าที่ถูกต้องหรือมีความใกล้เคียงกับการแสดงผลของ Google Maps มากที่สุด แต่เนื่องจากทาง Google Maps ไม่ได้ทำการเปิดเผยข้อมูลที่เกี่ยวข้องมาก ทำให้ไม่สามารถค้นหาข้อมูลบางส่วนที่เกี่ยวกับแถบสีแสดงสภาพการจราจรได้ จากการสืบค้นทำให้ทราบเพียงว่า Google จะเก็บรวบรวมข้อมูลความเร็วของยานพาหนะทุกคันที่เปิด GPS นำมาเฉลี่ยหาความเร็วต่อช่วงพื้นที่ถนนแล้วแสดงผลบน Google Maps เท่านั้น (Google Maps, 2022) โดยไม่ทราบเกณฑ์การแบ่งช่วงความเร็วของแต่ละแถบสีของ Google Maps ดังนั้นงานวิจัยนี้จึงได้ทำการกำหนดความเร็วที่เป็นตัวแทนของแถบสี ให้สอดคล้องกับสภาพความเป็นจริงของการจราจรภายในเมือง ดังนี้


1. แถบสีแดงเข้ม แทนความเร็วเฉลี่ยไม่เกิน 10 กม./ชม.
2. แถบสีแดง แทนความเร็วเฉลี่ยที่มากกว่า 10 กม./ชม. แต่ไม่เกิน 40 กม./ชม.
3. แถบสีส้ม แทนความเร็วเฉลี่ยที่มากกว่า 40 กม./ชม. แต่ไม่เกิน 60 กม./ชม.
4. แถบสีเขียว แทนความเร็วเฉลี่ยที่มากกว่า 60 กม./ชม.

อย่างไรก็ตาม หากในอนาคตพบว่ามี การเผยแพร่ข้อมูลเกณฑ์การแบ่งช่วงชั้นความเร็วของแต่ละแถบสี งานวิจัยในอนาคตสามารถนำเกณฑ์ดังกล่าวมาปรับใช้ เพื่อทำการสร้างชุดข้อมูลแถบสีใหม่ตามเกณฑ์ดังกล่าวโดยไม่จำเป็นต้องปรับปรุงกระบวนการอื่น ๆ โดยมีขั้นตอนการสกัดข้อมูลตัวแปรความยาวแถวคอยจริงและตัวแปรความยาวแถบสีแสดงดังรูปที่ 3.3 และ 3.4 รายละเอียดมีดังนี้

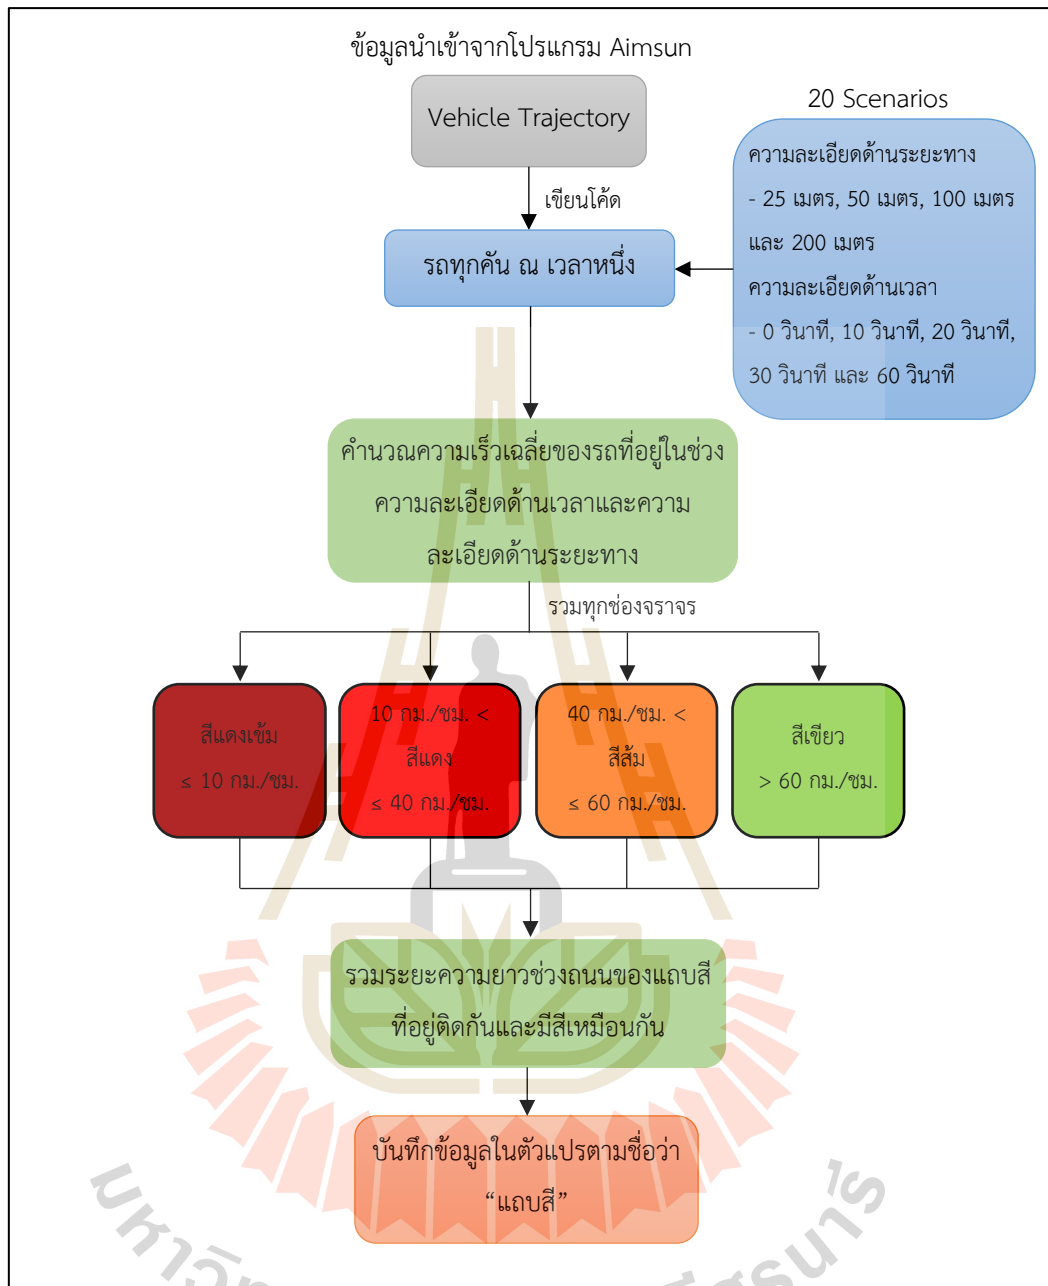
1. นำเข้าข้อมูล Vehicle trajectory สกูลไฟล์ .sqlite ที่ได้จากการสร้างและรันแบบจำลองจราจรบนโปรแกรม Aimsun เข้าในโปรแกรม R
2. สำหรับข้อมูลความยาวแถวคอยจริง ให้เขียนโค้ดดึงข้อมูลตำแหน่งของยานพาหนะที่อยู่ห่างจากทางแยกมากที่สุดที่มีความเร็วต่ำกว่า 10 km/h ณ เวลาหนึ่ง แล้วนำค่าตำแหน่งดังกล่าวไปลบกับตำแหน่งของไฟสัญญาณจราจรที่เป็นตำแหน่งของหัวแถวของแถวคอย เก็บไว้ในตัวแปรของระยะความยาวแถวคอยจริง จะทำให้ได้ระยะความยาวแถวคอยจากรถคันแรกจนถึงคันสุดท้ายที่หยุดจอด ณ เวลาหนึ่ง
3. สำหรับข้อมูลแถบสีแสดงสภาพจราจร ทำการเขียนโค้ดดึงข้อมูลของรถทุกคัน ณ เวลาหนึ่ง โดยให้เสียดึงข้อมูลตามกรณีของความละเอียดด้านเวลาและความละเอียดด้านระยะทางที่กำหนด จากนั้นนำความเร็ว ณ ช่วงเวลานั้นของรถที่ดึงข้อมูลมาหา

ค่าเฉลี่ย แล้วจัดกลุ่มความเร็วเฉลี่ยว่าอยู่ในเกณฑ์ของสีใด แล้วให้แสดงผลเป็นสีนั้นแทนค่าความเร็วเฉลี่ยที่คำนวณได้ แล้วจึงรวมแถบสีที่มีสีเดียวกันและอยู่ติดกันให้เป็นแถบสีเดียว แล้วคิดตามความละเอียดด้านระยะทางที่กำหนด เช่น เวลา 9:00 น. ที่ความละเอียดด้านระยะทางทุก ๆ 25 เมตร พบว่าในตอนเริ่มต้นมีแถบสีแดงเข้มอยู่ติดกันจำนวน 3 แถบและถัดไปเป็นแถบสีแดงอยู่ติดกันจำนวน 2 แถบ ดังนั้น เมื่อรวมแล้วจะได้ แถบสีแดงเข้ม 1 แถบที่ระยะ 75 เมตร และแถบสีแดง 1 แถบที่ระยะ 50 เมตร เป็นต้น

4. ข้อมูลในแต่ละปัจจัยความละเอียดด้านเวลาและความละเอียดด้านระยะทางจะถูกแบ่งเป็น 2 ชุดข้อมูล คือ ข้อมูลชุดที่ 1 ข้อมูลแถบสีที่อยู่ในช่วงไฟจราจรสีเขียวและสีแดง (GreenRed) และข้อมูลชุดที่ 2 ข้อมูลแถบสีที่อยู่ในช่วงไฟจราจรสีแดง (Red) โดยทั้งสองชุดข้อมูลจะตัดแถวข้อมูลแถบสีที่เป็นสีเขียวล้วนออก เนื่องจากข้อมูลแถบสีที่เป็นสีเขียวล้วนแสดงถึงสภาพการจราจรที่ไม่ติดขัด รถสามารถวิ่งได้ด้วยความเร็วเฉลี่ยที่มากกว่า 60 กม./ชม. ดังนั้นจึงไม่ใช้ตัวแปรที่ดีในการนำมาใช้สร้างแบบจำลองการประมาณค่าระยะความยาวแถวคอย



รูปที่ 3.3 ขั้นตอนการสกัดตัวแปรความยาวแถวคอยจริง



รูปที่ 3.4 ขั้นตอนการสกัดตัวแปรความยาวแถบสี

3.3.3 ตัวแปร

งานวิจัยนี้ทำการสร้างแบบจำลองการประมาณค่าระยะความยาวแฉกคอยจากตัวแปรความยาวแถบสีเทียบกับระยะความยาวแฉกคอยจริง โดยที่ลักษณะของตัวแปรแถบสีจะมีลักษณะคล้ายกับตัวแปร Dummy คือระยะความยาวของแต่ละแถบสีที่ถูกบันทึกลงในช่องข้อมูลของสีที่ปรากฏ ณ ช่วงเวลาหนึ่งในขณะที่สีอื่น ๆ ในช่วงถนนและช่วงเวลาเดียวกันจะถูกบันทึกค่าว่าเป็น 0 และตัวแปรระยะความยาวแฉกคอยคือ ตัวแปรค่าเฉลี่ยของระยะความยาวแฉกคอยใน 4 ช่องจราจร

งานวิจัยนี้ใช้ตัวแปรแถบสีทั้งหมด 4 สี ได้แก่ สีแดงเข้ม, สีแดง, สีส้ม และสีเขียว เพื่อทำการวิเคราะห์และประเมินผลเทียบกับแถบสีของ Google Maps ซึ่งข้อมูลตัวแปรแถบสีจะได้จากข้อมูลของรถทุกคันในพื้นที่ 1,000 เมตร แต่เนื่องจากความละเอียดด้านระยะทางที่แตกต่างกันส่งผลทำให้จำนวนตัวแปรแถบสีมีจำนวนที่แตกต่างกัน ตัวอย่างการคำนวณจำนวนตัวแปรแถบสีเช่น ที่ความละเอียดด้านระยะทางทุก ๆ 25 เมตรจากความยาวช่วงถนน 1,000 เมตร จะได้จำนวนตัวแปรตามความละเอียดด้านระยะทางดังนี้ $1,000/25 = 40$ ตัวแปร แต่เนื่องจากในช่วงถนนหนึ่ง ๆ มีแถบสีทั้งหมด 4 สี ซึ่งแสดงเป็นตัวแปรทั้งหมด ดังนั้น จำนวนตัวแปรทั้งหมดที่ความละเอียดด้านระยะทางทุก ๆ 25 เมตร จึงสามารถคำนวณได้เป็น $40*4 = 160$ ตัวแปรแถบสี เป็นต้น โดยจำนวนตัวแปรแถบสีที่ความละเอียดด้านระยะทางอื่น ๆ แสดงดังตารางที่ 3.1

ตารางที่ 3.1 จำนวนตัวแปรแถบสีตามปัจจัยความละเอียดด้านระยะทาง

| ปัจจัยความละเอียดด้านระยะทาง | 25 เมตร | 50 เมตร | 100 เมตร | 200 เมตร |
|------------------------------|---------|---------|----------|----------|
| จำนวนตัวแปรแถบสี | 160 | 80 | 40 | 20 |

3.4 การสร้างแบบจำลองประมาณค่าระยะความยาวแฉกค้อย

การสร้างแบบจำลองประมาณค่าระยะความยาวแฉกค้อยใช้วิธี Gradient Boosting Machine (GBM) ซึ่งวิธีนี้เป็นวิธีที่คล้ายกับวิธี Random Forest เพียงแต่วิธี GBM จะเป็นวิธีที่เริ่มจากการสร้างแบบจำลองจาก weak classifier ขึ้นมาเป็นแบบจำลองแรก เรียนรู้ลักษณะรูปแบบการเกิดของ error นำไปปรับปรุง และพัฒนาการสร้างแบบจำลองในคราวถัดไป จนไม่สามารถเรียนรู้การเกิด error ได้แล้วจึงจะหยุดการสร้างแบบจำลอง แบบจำลองสุดท้ายจึงเป็นแบบจำลองที่มีค่า error น้อยที่สุดและมีประสิทธิภาพการทำนายที่ดีที่สุด (Rezzouqi et al., 2019) (Natekin & Knoll, 2013)

งานวิจัยนี้ใช้โปรแกรม R ในการสร้างแบบจำลองด้วยวิธี GBM โดยใช้ package ที่มีชื่อว่า gbm และ caret สำหรับ caret package จะถูกใช้เพื่อทำการ tune parameter (n.trees, interaction.depth, shrinkage และ n.minobsinnode) ให้มีค่าที่เหมาะสมมากที่สุด ส่วน gbm package จะถูกใช้สำหรับการสร้างแบบจำลองและหาค่า Variables Importance (VI) การแบ่งชุดข้อมูลจะแบ่งด้วยอัตราส่วน 9:1 โดยเป็นข้อมูล train จำนวน 90% และเป็นข้อมูล test จำนวน 10% จากข้อมูลทั้งหมด และยังสร้างแบบจำลองโดยใช้หลักการ 5-fold Cross-Validation สำหรับการตรวจสอบและเปรียบเทียบประสิทธิภาพการพยากรณ์จะใช้ค่า Root Mean Square error (RMSE) เป็นตัวชี้วัด

3.5 ผลของความละเอียดด้านเวลาและระยะทางต่อประสิทธิภาพการทำนายของแบบจำลองประมาณค่าระยะความยาวแฉกคอย

3.5.1 Root Mean Square error (RMSE)

งานวิจัยนี้ทำการเปรียบเทียบประสิทธิภาพของแบบจำลองที่ถูกสร้างขึ้นด้วยวิธี GBM ในกรณีที่มีข้อมูลแถบสีมีปัจจัยความละเอียดด้านเวลาและความละเอียดด้านระยะทางที่ต่างกัน ซึ่งผลลัพธ์แสดงดังตารางที่ 3.2 โดยพบว่าความละเอียดด้านระยะทางที่ 25 เมตร และความละเอียดด้านเวลาที่ 0 วินาที (เป็นค่าที่มีความละเอียดมากที่สุดของทั้งสองปัจจัย) ให้ค่า RMSE น้อยที่สุด จึงส่งผลให้มีประสิทธิภาพการทำนายที่ดีที่สุด และยังพบอีกว่าข้อมูลแถบสีเฉพาะช่วงไฟจราจรสีแดงให้ผลแนวโน้มของการทำนายได้ดีกว่าข้อมูลแถบสีที่อยู่ในช่วงไฟจราจรสีเขียวรวมกับไฟจราจรสีแดง

ตารางที่ 3.2 ค่า RMSE จากแบบจำลอง

| RMSE | 25 เมตร | | 50 เมตร | | 100 เมตร | | 200 เมตร | |
|-----------|-----------|--------|-----------|--------|-----------|--------|-----------|--------|
| | ช่วงไฟ | ช่วงไฟ | ช่วงไฟ | ช่วงไฟ | ช่วงไฟ | ช่วงไฟ | ช่วงไฟ | ช่วงไฟ |
| | เขียว-แดง | แดง | เขียว-แดง | แดง | เขียว-แดง | แดง | เขียว-แดง | แดง |
| 0 วินาที | 77.197 | 24.102 | 37.744 | 46.060 | 86.075 | 40.597 | 65.159 | 55.152 |
| 10 วินาที | 37.977 | 35.684 | 45.073 | 29.440 | 90.227 | 48.996 | 43.157 | 61.673 |
| 20 วินาที | 80.844 | 32.723 | 30.951 | 49.412 | 28.910 | 37.160 | 73.141 | 60.499 |
| 30 วินาที | 34.759 | 58.090 | 100.317 | 56.398 | 44.955 | 59.036 | 81.541 | 83.351 |
| 60 วินาที | 59.371 | 78.609 | 56.885 | 52.550 | 67.2520 | 85.651 | 74.385 | 90.063 |

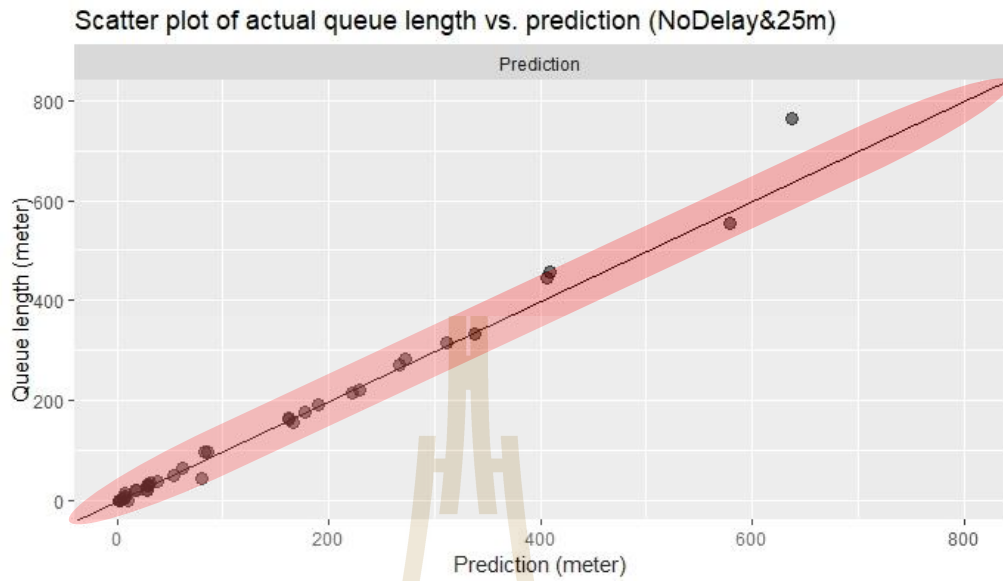
ผลลัพธ์ที่ได้จากการสร้างแบบจำลองแสดงให้เห็นว่าความละเอียดด้านเวลาที่ 0 วินาที (ไม่มีความล่าช้า) ให้ค่า RMSE (24.102) น้อยกว่าความละเอียดด้านเวลาและความละเอียดด้านระยะทางอื่น ๆ ซึ่งแสดงให้เห็นว่าข้อมูลแถบสีที่มีความละเอียดด้านเวลาและระยะทางที่สูง (การประมวลผลมีความล่าช้าน้อยและแบ่งช่วงถนนสั้น) จะส่งผลให้ประสิทธิภาพการประมาณค่าระยะความยาวของแฉกคอยสูงกว่าข้อมูลแถบสีที่มีความละเอียดด้านเวลาและระยะทางน้อย (การประมวลผลมีความล่าช้ามากและแบ่งช่วงถนนยาว) โดยอาจเป็นสาเหตุเนื่องมาจากข้อมูลที่มีความละเอียดด้านระยะทางที่สั้น อาจส่งผลทำให้สามารถตรวจจับยานพาหนะได้ละเอียดมากกว่า มีการจับความเร็วของรถได้แม่นยำมากกว่า เพราะในความละเอียดด้านระยะทางที่สั้นจะทำให้พบรถที่อยู่ในช่วงถนนน้อยกว่าความละเอียดด้านระยะทางที่ยาว ดังนั้นการหาความเร็วเฉลี่ยรถบนช่วงถนนที่สั้นจึงครอบคลุมความเร็วของรถแต่ละคันได้ดีกว่าการหาความเร็วเฉลี่ยรถบนความละเอียดด้านระยะทาง

ที่ยาว เช่นเดียวกับในกรณีของความละเอียดด้านเวลาหากไม่มีความล่าช้าในการรับ-ส่ง ประมวลผล และแสดงข้อมูล ก็จะส่งผลให้สามารถแสดงผลได้แบบทันทีการณ หรืออีกนัยหนึ่งคือเมื่อไหร่ที่มีการเปลี่ยนแปลงแถวคอย เมื่อนั้นแถบสีก็จะเปลี่ยนแปลงตามทันที เพราะฉะนั้นค่า error ที่เกิดขึ้นจึงมีค่าที่น้อยมากเมื่อเทียบกับในกรณีที่ค่าความละเอียดด้านเวลาน้อย เพราะมีความล่าช้าเกิดขึ้น ดังนั้นกว่าที่จะทำการคำนวณเสร็จและแสดงผลออกมาสภาพการจราจรจริงอาจมีการเปลี่ยนแปลงแตกต่างจากที่คำนวณไปแล้ว ส่งผลให้แถบสีไม่สามารถสะท้อนสภาพการจราจรจริง ณ ตอนนั้นได้


เมื่อมองภาพรวมของค่า RMSE ทั้งหมด จะพบว่าความละเอียดด้านเวลาและความละเอียดด้านระยะทางที่น้อย ไม่ได้มีแนวโน้มส่งผลทำให้ประสิทธิภาพการทำนายของแบบจำลองประมาณค่าระยะความยาวแถวคอยดีขึ้นอย่างชัดเจน เช่น ที่ความละเอียดด้านระยะทางทุก ๆ 50 เมตร ในกรณีที่ความละเอียดด้านเวลา เท่ากับ 0 วินาที (46.060) และ 10 วินาที (29.440) จะพบว่าที่ความละเอียดด้านเวลา เท่ากับ 0 วินาทีที่มีความละเอียดของเวลาที่สูงกว่าที่ความละเอียดด้านเวลา เท่ากับ 10 วินาทีค่า RMSE มีค่าสูงกว่า เป็นต้น

3.5.2 กราฟประมาณค่าระยะความยาวแถวคอยเทียบกับระยะแถวคอยจริง


เนื่องจากการดูค่า RMSE ทำให้ไม่สามารถทราบแนวโน้มของข้อมูลที่แน่ชัดได้ว่า ยิ่งค่าละเอียดมากขึ้นจะยิ่งส่งผลให้ประสิทธิภาพการทำนายดีขึ้น ดังนั้น งานวิจัยนี้จึงทำการสร้างกราฟเพื่อเปรียบเทียบค่าระยะความยาวแถวคอยจริงกับค่าระยะความยาวแถวคอยที่ได้จากแบบจำลอง ในกรณีที่ความละเอียดด้านระยะทาง เท่ากับ 25 เมตร แต่ความละเอียดด้านเวลามีค่าที่แตกต่างกันแสดงดังรูปที่ 3.5 - 3.14 จากรูปที่ 3.5, 3.7, 3.9, 3.11, 3.13 จะเห็นค่าของระยะความยาวแถวคอยจริงกับค่าระยะความยาวแถวคอยที่ได้จากแบบจำลอง (จุดสีดำ) ที่อยู่ในพื้นที่สีแดงมีแนวโน้มไปในทิศทางที่ว่ายิ่งความละเอียดด้านเวลาสูงจะยิ่งทำให้ค่าประสิทธิภาพการทำนายของแบบจำลองประมาณค่าระยะความยาวแถวคอยดีขึ้น ซึ่งเช่นเดียวกันกับรูปที่ 3.6, 3.8, 3.10, 3.12, 3.14 ที่แสดงให้เห็นเส้นกราฟ 2 เส้น โดยที่เส้นสีเขียวเป็นเส้นกราฟของระยะแถวคอยจริงเทียบกับเส้นสีส้มที่เป็นเส้นกราฟของระยะแถวคอยที่ได้จากการประมาณค่า จะพบว่าเส้นกราฟสีเขียวและสีส้มแทบจะทับกันได้สนิท ยกเว้นในบางจุด ค่าที่ทำนายกับค่าจริงแทบจะเป็นค่าเดียวกัน นั้นหมายความว่าแบบจำลองมีประสิทธิภาพการทำนายที่ดี และนอกจากนี้หากสังเกตโดยภาพรวมก็จะพบว่า ยิ่งความละเอียดด้านเวลาสูงจะยิ่งทำให้เส้นทั้งสองแนบสนิทใกล้เคียงกันมากยิ่งขึ้น หากไม่นับรวมในกรณีที่เส้นทั้งสองไม่ใกล้เคียงกันก็จะมีค่าแตกต่างกันมากในบางจุด ซึ่งสามารถตีความได้ว่ายิ่งความละเอียดด้านเวลาสูงจะยิ่งทำให้ค่าประสิทธิภาพการทำนายของแบบจำลองประมาณค่าระยะความยาวแถวคอยดีขึ้น




รูปที่ 3.5 กราฟความยาวแถวคอยจริงเปรียบเทียบกับความยาวแถวคอยที่ได้จากแบบจำลอง กรณีที่ไม่มีความล่าช้าและความทุก ๆ 25 เมตร




รูปที่ 3.6 กราฟความยาวแถวคอยจริงกับความยาวแถวคอยที่ได้จากแบบจำลองเทียบตามเวลา กรณีที่ไม่มีความล่าช้าและแบ่งช่วงถนนทุก ๆ 25 เมตร




รูปที่ 3.7 กราฟความยาวแถวคอยจริงเปรียบเทียบกับความยาวแถวคอยที่ได้จากแบบจำลอง กรณีที่มีความล่าช้า 10 วินาทีและแบ่งช่วงถนนทุก ๆ 25 เมตร




รูปที่ 3.8 กราฟความยาวแถวคอยจริงกับความยาวแถวคอยที่ได้จากแบบจำลองเทียบตามเวลา กรณีที่มีความล่าช้า 10 วินาทีและแบ่งช่วงถนนทุก ๆ 25 เมตร




รูปที่ 3.9 กราฟความยาวแถวคอยจริงเปรียบเทียบกับความยาวแถวคอยที่ได้จากแบบจำลอง กรณีที่มีความล่าช้า 20 วินาทีและแบ่งช่วงถนนทุก ๆ 25 เมตร




รูปที่ 3.10 กราฟความยาวแถวคอยจริงกับความยาวแถวคอยที่ได้จากแบบจำลองเทียบตามเวลา กรณีที่มีความล่าช้า 20 วินาทีและแบ่งช่วงถนนทุก ๆ 25 เมตร




รูปที่ 3.11 กราฟความยาวแถวคอยจริงเปรียบเทียบกับความยาวแถวคอยที่ได้จากแบบจำลอง กรณีที่มีความล่าช้า 30 วินาทีและแบ่งช่วงถนนทุก ๆ 25 เมตร



รูปที่ 3.12 กราฟความยาวแถวคอยจริงกับความยาวแถวคอยที่ได้จากแบบจำลองเทียบตามเวลา กรณีที่มีความล่าช้า 30 วินาทีและแบ่งช่วงถนนทุก ๆ 25 เมตร



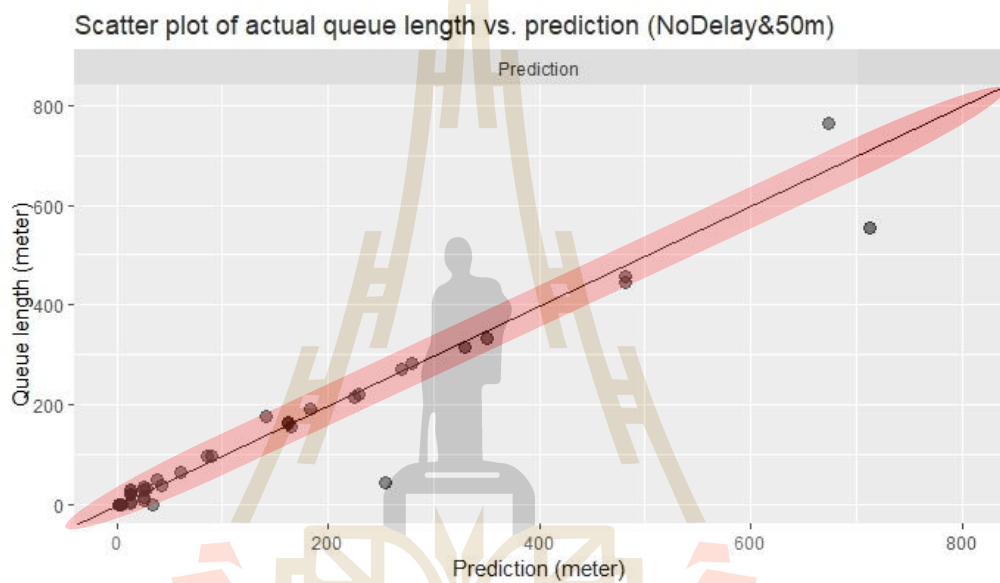
รูปที่ 3.13 กราฟความยาวแถวคอยจริงเปรียบเทียบกับความยาวแถวคอยที่ได้จากแบบจำลอง กรณีที่มีความล่าช้า 60 วินาทีและแบ่งช่วงถนนทุก ๆ 25 เมตร




รูปที่ 3.14 กราฟความยาวแถวคอยจริงกับความยาวแถวคอยที่ได้จากแบบจำลองเทียบตามเวลา กรณีที่มีความล่าช้า 60 วินาทีและแบ่งช่วงถนนทุก ๆ 25 เมตร

นอกจากปัจจัยความละเอียดด้านเวลา ยังมีการสร้างกราฟเพื่อเปรียบเทียบค่าระยะความยาวแถวคอยจริงกับค่าระยะความยาวแถวคอยที่ได้จากแบบจำลอง ในกรณีที่ความละเอียดด้านระยะทางมีค่าแตกต่างกัน ซึ่งแสดงดังรูปที่ 3.15 - 3.20 เป็นกรณีที่ความละเอียดด้านเวลา เท่ากับ 0 วินาที (ไม่มีความล่าช้า) และความละเอียดด้านระยะทางมีค่าแตกต่างกัน รูปที่ 3.15, 3.17, 3.19 จะเห็นค่าของระยะความยาวแถวคอยจริงกับค่าระยะความยาวแถวคอยที่ได้จากแบบจำลอง ที่อยู่ในพื้นที่สีแดงมีแนวโน้มไปในทิศทางที่ว่ายิ่งความละเอียดด้านระยะทางสั้นจะยิ่งทำให้ค่าประสิทธิภาพการ


ทำนายของแบบจำลองประมาณค่าระยะความยาวแถวคอยดีขึ้น ซึ่งเช่นเดียวกับรูปที่ 3.16, 3.18, 3.20 ที่พบว่าเส้นกราฟของค่าจริงและเส้นกราฟของค่าที่ได้จากแบบจำลองแทบจะทับกันได้สนิท ยกเว้นในบางจุด ค่าที่ทำนายกับค่าจริงแทบจะเป็นค่าเดียวกัน หมายความว่าแบบจำลองมีประสิทธิภาพการทำนายที่ดี และหากสังเกตโดยภาพรวมจะคล้ายกับกรณีของปัจจัยความละเอียดด้านเวลาที่ว่า ยิ่งความละเอียดด้านระยะทางสั้นยิ่งทำให้ค่าประสิทธิภาพการทำนายของแบบจำลองประมาณค่าระยะความยาวแถวคอยดีขึ้น




รูปที่ 3.15 กราฟความยาวแถวคอยจริงเปรียบเทียบกับความยาวแถวคอยที่ได้จากแบบจำลอง กรณีที่ไม่มีความล่าช้าและแบ่งช่วงถนนทุก ๆ 50 เมตร




รูปที่ 3.16 กราฟความยาวแถวคอยจริงกับความยาวแถวคอยที่ได้จากแบบจำลองเทียบตามเวลา กรณีที่ไม่มีความล่าช้าและแบ่งช่วงถนนทุก ๆ 50 เมตร




รูปที่ 3.17 กราฟความยาวแถวคอยจริงเปรียบเทียบกับความยาวแถวคอยที่ได้จากแบบจำลอง กรณีที่ไม่มีความล่าช้าและแบ่งช่วงถนนทุก ๆ 100 เมตร



รูปที่ 3.18 กราฟความยาวแถวคอยจริงกับความยาวแถวคอยที่ได้จากแบบจำลองเทียบตามเวลา กรณีที่ไม่มีความล่าช้าและแบ่งช่วงถนนทุก ๆ 100 เมตร



รูปที่ 3.19 กราฟความยาวแถวคอยจริงเปรียบเทียบกับความยาวแถวคอยที่ได้จากแบบจำลอง กรณีที่ไม่มีความล่าช้าและแบ่งช่วงถนนทุก ๆ 200 เมตร




รูปที่ 3.20 กราฟความยาวแถวคอยจริงกับความยาวแถวคอยที่ได้จากแบบจำลองเทียบตามเวลา กรณีที่ไม่มีความล่าช้าและแบ่งช่วงถนนทุก ๆ 200 เมตร


3.5.3 Variable importance (VI)

เพื่อให้สามารถทำความเข้าใจกับตัวแปรแถบสีได้มากขึ้น งานวิจัยนี้จึงทำการตรวจสอบความสำคัญของตัวแปรต่อการสร้างแบบจำลองการประมาณค่าระยะความยาวของแถวคอยหรือค่า VI ดังรูปที่ 3.21 - 3.28 จากกราฟจะพบว่าตัวแปรแถบสีแดงเข้มและตัวแปรแถบสีแดงมีค่า VI สูง ซึ่งหมายความว่าแถบสีแดงเข้มและสีแดงเป็นตัวแปรแถบสีที่สำคัญต่อการสร้างแบบจำลองมากที่สุด โดยที่ทั้งสองสีที่กล่าวมานั้นเป็นสีที่แสดงถึงสภาพการจราจรที่ค่อนข้างติดขัด สภาพการไหลของ


การจราจรเคลื่อนตัวได้ช้าหรือหยุดจอต ทำให้สามารถสะท้อนระยะความยาวของแถวคอยออกมาได้ดีกว่าสีส้มและสีเขียว นอกเหนือจากนั้นลำดับของตัวแปรแถบสีที่มีความสำคัญมากที่สุดยังอยู่ในช่วงถนนที่ติดกับไฟสัญญาณจราจรมากที่สุดอีกด้วย ถือเป็นช่วงถนนที่ถ้าหากมีแถวคอยเกิดขึ้นต้องมีรถส่วนใหญ่มาติดในช่วงลำดับแถบสีเหล่านั้นอย่างแน่นอน เพราะเป็นแถบสีที่อยู่หน้าสุดหรือเป็นหัวแถวของแถวคอย




รูปที่ 3.21 กราฟ Variable importance กรณีปัจจัยความละเอียดด้านเวลา 0 วินาที และความละเอียดด้านระยะทาง 25 เมตร




รูปที่ 3.22 กราฟ Variable importance กรณีปัจจัยความละเอียดด้านเวลา 10 วินาที และความละเอียดด้านระยะทาง 25 เมตร




รูปที่ 3.23 กราฟ Variable importance กรณีปัจจัยความละเอียดด้านเวลา 20 วินาที และความละเอียดด้านระยะทาง 25 เมตร




รูปที่ 3.24 กราฟ Variable importance กรณีปัจจัยความละเอียดด้านเวลา 30 วินาที และความละเอียดด้านระยะทาง 25 เมตร




รูปที่ 3.25 กราฟ Variable importance กรณีปัจจัยความละเอียดด้านเวลา 60 วินาที และความละเอียดด้านระยะทาง 25 เมตร



รูปที่ 3.26 กราฟ Variable importance กรณีปัจจัยความละเอียดด้านเวลา 0 วินาที และความละเอียดด้านระยะทาง 50 เมตร



รูปที่ 3.27 กราฟ Variable importance กรณีปัจจัยความละเอียดด้านเวลา 0 วินาที และความละเอียดด้านระยะทาง 100 เมตร



รูปที่ 3.28 กราฟ Variable importance กรณีปัจจัยความละเอียดด้านเวลา 0 วินาที และความละเอียดด้านระยะทาง 200 เมตร


3.5.4 การตัดค่า Outlier

จากหัวข้อที่ผ่านมา ทำให้ทราบว่าค่าระยะความยาวแกวคยจากแบบจำลองเทียบกับระยะแกวคยจริงจากการสังเกตกราฟมีแนวโน้มที่ยิ่งความละเอียดด้านเวลาและความละเอียดด้านระยะทาง ละเอียดมากเท่าไรยิ่งส่งผลให้ประสิทธิภาพการทำนายยิ่งดีขึ้นเท่านั้น โดยจากการสังเกตในกราฟที่ผ่านมาจะพบว่ามีค่า Outlier อยู่บางจุดในกราฟ ถึงแม้ Outlier จะไม่ได้มีจำนวนมาก แต่บางจุดก็มีค่าที่ค่อนข้างสูง จึงมีความเป็นไปได้ที่อาจจะส่งผลทำให้แบบจำลองประมาณค่าระยะความยาวแกวคยประสิทธิภาพลดลง งานวิจัยนี้จึงทดลองตัด Outlier ออก โดยใช้


การพิจารณาจากค่า Standardized residuals ในกรณีที่ค่า Standardized residuals มีค่ามากกว่า 3 ขึ้นไป ข้อมูลแถวนั้นจะถูกลบออกทันที ซึ่งจากการตัดค่า Outlier ไป ทำให้ได้ข้อมูลชุดใหม่ และนำข้อมูลชุดนั้นไปทำการหาค่า RMSE ซึ่งเป็นข้อมูลในกรณีไฟสัญญาณจราจรเป็นสีแดงแสดงดังตารางที่ 3.3 พบว่าค่า RMSE ส่วนใหญ่มีแนวโน้มที่ดี หมายความว่ายิ่งละเอียดมากเท่าไรยิ่งส่งผลให้ประสิทธิภาพการทำนายยิ่งดีขึ้น ยกเว้นในกรณีของความละเอียดด้านเวลา 10 วินาที และ 20 วินาที กับ ความละเอียดด้านระยะทางที่ 50 เมตร และ 100 เมตร ที่อาจมีบางค่าที่แนวโน้มยังไม่ชัดเจน นอกจากนี้การตัดค่า Outlier ยังส่งผลให้ค่า RMSE มีค่าลดลงและเพิ่มประสิทธิภาพการทำนายของแบบจำลองให้ดีขึ้นอีกด้วย โดยจะเห็นได้ชัดจากกราฟระยะความยาวแถวคอยจากแบบจำลองเทียบกับระยะแถวคอยจริง ซึ่งแสดงดังรูปที่ 3.29 - 3.38 เป็นกรณีที่ความละเอียดด้านระยะทางเท่ากับ 25 เมตรคงที่ และความละเอียดด้านเวลามีค่าที่แตกต่างกัน และรูปที่ 3.39 - 3.44 กรณีที่ความละเอียดด้านเวลาเท่ากับ 0 เมตรคงที่ และความละเอียดด้านระยะทางมีค่าที่แตกต่างกัน

ตารางที่ 3.3 ค่า RMSE จากแบบจำลองที่ตัดค่า Outlier


| RMSE | 25 เมตร | 50 เมตร | 100 เมตร | 200 เมตร |
|-----------|---------|---------|----------|----------|
| 0 วินาที | 26.382 | 38.888 | 41.633 | 51.142 |
| 10 วินาที | 26.512 | 49.224 | 45.427 | 63.983 |
| 20 วินาที | 27.360 | 33.981 | 42.328 | 61.735 |
| 30 วินาที | 45.654 | 43.709 | 40.121 | 58.841 |
| 60 วินาที | 69.852 | 49.384 | 47.145 | 60.993 |




รูปที่ 3.29 กราฟความยาวแถวคอยจริงเปรียบเทียบกับความยาวแถวคอยที่ได้จากการทดสอบตัดค่า Outlier กรณีที่ไม่มีค่าล่าช้าและแบ่งช่วงถนนทุก ๆ 25 เมตร




รูปที่ 3.30 กราฟความยาวแถวคอยจริงกับความยาวแถวคอยที่ได้จากแบบจำลองเทียบตามเวลาที่ได้จากการทดสอบตัดค่า Outlier กรณีที่ไม่มีความล่าช้าและแบ่งช่วงถนนทุก ๆ 25 เมตร




รูปที่ 3.31 กราฟความยาวแถวคอยจริงเปรียบเทียบกับความยาวแถวคอยที่ได้จากการทดสอบตัดค่า Outlier กรณีที่มีความล่าช้า 10 วินาทีและแบ่งช่วงถนนทุก ๆ 25 เมตร




รูปที่ 3.32 กราฟความยาวแถวคอยจริงกับความยาวแถวคอยที่ได้จากแบบจำลองเทียบตามเวลาที่ได้จากการทดสอบตัดค่า Outlier กรณีที่มีความล่าช้า 10 วินาทีและแบ่งช่วงถนนทุก ๆ 25 เมตร




รูปที่ 3.33 กราฟความยาวแถวคอยจริงเปรียบเทียบกับความยาวแถวคอยที่ได้จากการทดสอบตัดค่า Outlier กรณีที่มีความล่าช้า 20 วินาทีและแบ่งช่วงถนนทุก ๆ 25 เมตร




รูปที่ 3.34 กราฟความยาวแถวคอยจริงกับความยาวแถวคอยที่ได้จากแบบจำลองเทียบตามเวลาที่ได้จากการทดสอบตัดค่า Outlier กรณีที่มีความล่าช้า 20 วินาทีและแบ่งช่วงถนนทุก ๆ 25 เมตร



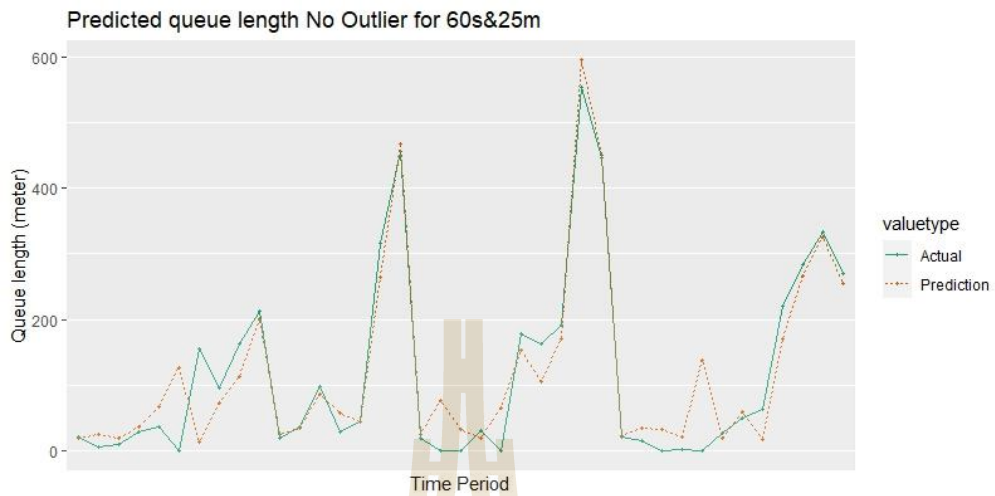
รูปที่ 3.35 กราฟความยาวแถวคอยจริงเปรียบเทียบกับความยาวแถวคอยที่ได้จากการทดสอบตัดค่า Outlier กรณีที่มีความล่าช้า 30 วินาทีและแบ่งช่วงถนนทุก ๆ 25 เมตร




รูปที่ 3.36 กราฟความยาวแถวคอยจริงกับความยาวแถวคอยที่ได้จากแบบจำลองเทียบตามเวลาที่ได้จากการทดสอบตัดค่า Outlier กรณีที่มีความล่าช้า 30 วินาทีและแบ่งช่วงถนนทุก ๆ 25 เมตร




รูปที่ 3.37 กราฟความยาวแถวคอยจริงเปรียบเทียบกับความยาวแถวคอยที่ได้จากการทดสอบตัดค่า Outlier กรณีที่มีความล่าช้า 60 วินาทีและแบ่งช่วงถนนทุก ๆ 25 เมตร




รูปที่ 3.38 กราฟความยาวแถวคอยจริงกับความยาวแถวคอยที่ได้จากแบบจำลองเทียบตามเวลาที่ได้จากการทดสอบตัดค่า Outlier กรณีที่มีความล่าช้า 60 วินาทีและแบ่งช่วงถนนทุก ๆ 25 เมตร




รูปที่ 3.39 กราฟความยาวแถวคอยจริงเปรียบเทียบกับความยาวแถวคอยที่ได้จากการทดสอบตัดค่า Outlier กรณีที่ไม่มีความล่าช้าและแบ่งช่วงถนนทุก ๆ 50 เมตร




รูปที่ 3.40 กราฟความยาวแถวคอยจริงกับความยาวแถวคอยที่ได้จากแบบจำลองเทียบตามเวลาที่ได้จากการทดสอบตัดค่า Outlier กรณีที่ไม่มีควมล่าช้าและแบ่งช่วงถนนทุก ๆ 50 เมตร




รูปที่ 3.41 กราฟความยาวแถวคอยจริงเปรียบเทียบกับความยาวแถวคอยที่ได้จากการทดสอบตัดค่า Outlier กรณีที่ไม่มีควมล่าช้าและแบ่งช่วงถนนทุก ๆ 100 เมตร



รูปที่ 3.42 กราฟความยาวแถวคอยจริงกับความยาวแถวคอยที่ได้จากแบบจำลองเทียบตามเวลาที่ได้จากการทดสอบตัดค่า Outlier กรณีที่ไม่มีควมล่าช้าและแบ่งช่วงถนนทุก ๆ 100 เมตร




รูปที่ 3.43 กราฟความยาวแถวคอยจริงเปรียบเทียบกับความยาวแถวคอยที่ได้จากการทดสอบตัดค่า Outlier กรณีที่ไม่มีควมล่าช้าและแบ่งช่วงถนนทุก ๆ 200 เมตร



รูปที่ 3.44 กราฟความยาวแถวคอยจริงกับความยาวแถวคอยที่ได้จากแบบจำลองเทียบตามเวลาที่ได้จากการทดสอบตัดค่า Outlier กรณีที่ไม่มีความล่าช้าและแบ่งช่วงถนนทุก ๆ 200 เมตร

เพื่อให้สามารถเห็นภาพรวมแนวโน้มประสิทธิภาพการทำนายของแบบจำลองการประมาณค่าระยะความยาวแถวคอยได้ชัดเจนยิ่งขึ้น ในงานวิจัยนี้จึงทำการพล็อตกราฟในลักษณะของกราฟ 3 มิติ ที่แสดงค่า RMSE ในมิติของความละเอียดด้านเวลาและความละเอียดด้านระยะทางพร้อมกัน โดยพล็อตกราฟจำนวน 2 กราฟกรณีที่มีค่า RMSE ไม่มีการตัด Outlier เทียบกับกรณีที่มีค่า RMSE มีการตัด Outlier ซึ่งแสดงดังรูปที่ 3.45-3.46 พบว่าภาพรวมของกราฟทั้งสองไม่ได้มีความแตกต่างกันมาก แต่รูปที่ 3.46 จะแสดงให้เห็นถึงแนวโน้มการลดลงของค่าคลาดเคลื่อนที่ชัดเจนกว่ารูปที่ 3.45 กราฟมีลักษณะเป็นทางลาดชันมีหลุมบ่อบ้างในบางจุด แต่โดยรวมแสดงให้เห็นว่าจุดสูงสุดของกราฟคือจุดที่ความละเอียดด้านเวลาและความละเอียดด้านระยะทางมีค่าที่ค่อนข้างหยาบเมื่อเทียบกับจุดที่เป็นจุดต่ำสุดของกราฟที่ความละเอียดด้านเวลาและความละเอียดด้านระยะทางมีค่าที่ค่อนข้างละเอียด ภาพรวมของกราฟแสดงออกมาในทิศทางที่ว่ากราฟสูงที่สุดจากค่าความละเอียดด้านเวลาและความละเอียดด้านระยะทางที่ค่อนข้างหยาบไล่ระดับลงมาถึงจุดต่ำสุดที่ความละเอียดด้านเวลาและความละเอียดด้านระยะทางค่อนข้างมีความละเอียด



8

รูปที่ 3.46 กราฟ 3 มิติกรณีที่ค่า RMSE มีการตัด Outlier

3.6 สรุปผลงานวิจัย

งานวิจัยนี้ทำการวิเคราะห์และประเมินข้อมูลแถบสีต่อการประมาณค่าระยะความยาว แถวคอยในกรณีที่มีความละเอียดด้านเวลาและความละเอียดด้านระยะทางมีความละเอียดมากขึ้นหรือน้อยลง โดยใช้แบบจำลองจรรยาจากโปรแกรม Aimsun ในการสร้างชุดข้อมูลและนำเข้าข้อมูลเข้าไป

ในโปรแกรม R เพื่อทำการสกัดข้อมูลแถบสีให้อยู่ในลักษณะของแถบสีแสดงสภาพการจราจร เหมือนกับของ Google Maps และข้อมูลระยะความยาวแถวคอยจริง และใช้วิธี Gradient Boosting Machine เพื่อสร้างแบบจำลองประมาณค่าระยะความยาวแถวคอยและเปรียบเทียบผลลัพธ์ที่ได้จากแบบจำลองในกรณีความละเอียดด้านเวลาและความละเอียดด้านระยะทางมีค่าที่แตกต่างกัน สำหรับตัวแปรแถบสีนั้นจะถูกใช้ทั้งหมด 4 สีคือ สีแดงเข้ม สีแดง สีส้ม และสีเขียว ตามลักษณะแถบสีบน Google Maps

ผลลัพธ์จากแบบจำลองแสดงให้เห็นว่าแบบจำลองการประมาณค่าระยะความยาวแถวคอยที่ได้จากข้อมูลเฉพาะในช่วงเวลาไฟจราจรสีแดง ที่มีปัจจัยความละเอียดด้านเวลาที่ 0 วินาที และความละเอียดด้านระยะทางที่ 25 เมตร มีความละเอียดมากที่สุด จึงให้ผลการทำนายที่มีประสิทธิภาพดีที่สุดในแง่ของข้อมูลที่มีความละเอียดด้านระยะทางมากส่งผลทำให้การตรวจจ็บระยะความยาวแถวคอยมีความละเอียดและครอบคลุมทุกพื้นที่ช่วงถนนมากกว่า และโดยเฉพาะอย่างยิ่งเมื่อรวมกับความละเอียดด้านเวลาการแสดงผลข้อมูลแถบสีแบบไม่มีความล่าช้า เมื่อเกิดการเปลี่ยนแปลงของการจราจรปัจจัยเหล่านี้จะส่งผลทำให้แถบสีมีการเปลี่ยนแปลงตามอย่างแม่นยำในทันที กล่าวคือลักษณะแถบสีจะแสดงตรงกับสภาพการจราจรจริงที่เกิดขึ้น ทำให้แบบจำลองสามารถทำนายผลได้ดียิ่งขึ้น เช่นเดียวกับการใช้ข้อมูลช่วงไฟจราจรสีแดงที่เป็นช่วงที่เกิดแถวคอยส่งผลให้แสดงแนวโน้มและประสิทธิภาพของการทำนายดีกว่าการใช้ข้อมูลที่มีช่วงไฟจราจรสีเขียวร่วมด้วย นอกจากการตรวจสอบค่า RMSE แล้ว ยังมีการพิจารณากราฟเพื่อเปรียบเทียบระยะความยาวแถวคอยจริงกับระยะความยาวแถวคอยที่ได้จากแบบจำลอง พบว่าโดยภาพรวมของกราฟมีลักษณะแนวโน้มที่ยังความละเอียดด้านเวลาและระยะทางมีความละเอียดมากขึ้น จะยิ่งส่งผลให้แบบจำลองสามารถทำนายได้มีประสิทธิภาพมากยิ่งขึ้น ซึ่งหากทำการตัดค่า Outlier ออก จะพบแนวโน้มที่ชัดเจนขึ้นโดยหากปัจจัยความละเอียดด้านเวลาและระยะทางมีค่าที่ละเอียดยิ่งขึ้นจะส่งผลให้แบบจำลองทำนายได้ดียิ่งขึ้น นอกจากนี้ยังมีการวิเคราะห์ค่า Variable Importance ซึ่งแสดงให้เห็นว่าตัวแปรแถบสีแดงและสีแดงเข้มมีความสำคัญต่อการสร้างแบบจำลองมากที่สุด เพราะเป็นแถบสีที่แสดงสภาพการจราจรที่ติดขัดและเกิดแถวคอย นอกจากเรื่องของสีตัวแปรแล้วลำดับของตัวแปรก็ยังคงมีความสมเหตุสมผล เพราะเป็นลำดับตัวแปรที่อยู่ติดกับไฟสัญญาณจราจรมากที่สุด เปรียบได้กับหัวแถวของแถวคอย ตัวแปรเหล่านี้จึงมีความสำคัญต่อการสร้างแบบจำลองมากที่สุด

งานวิจัยนี้จัดทำขึ้นเพื่อสนับสนุนแนวทางใหม่ในการประมาณค่าความยาวแถวคอยนอกจากการใช้ detector ซึ่งในบางพื้นที่หรือบางประเทศอาจยังไม่ได้มีการติดตั้ง detector ให้ครอบคลุมทั่วพื้นที่ และเป็นการตรวจสอบและประเมินว่าหากในอนาคต Google Maps สามารถเพิ่มความละเอียดด้านระยะทางและเวลาได้มากขึ้นกว่าในปัจจุบันก็จะส่งผลทำให้ข้อมูลที่ได้มีความถูกต้องแม่นยำและมีประโยชน์สามารถนำไปใช้ต่อยอดการวิเคราะห์การประมาณค่าความยาวแถวคอยได้จริงและสามารถ

นำข้อมูลเหล่านี้ไปใช้ร่วมกับการปรับรอบเวลาไฟสัญญาณจราจรได้อย่างแม่นยำมากยิ่งขึ้น เพื่อให้สามารถบริหารจัดการกับทางแยกที่มีไฟสัญญาณจราจรได้ โดยเฉพาะอย่างยิ่งในกรณีของรถฉุกเฉินที่ต้องการความรวดเร็วในการรับส่งคนไข้ให้ถึงโรงพยาบาล งานวิจัยนี้ยังมีข้อจำกัดในด้านของการศึกษา ปัจจัยอื่นที่อาจส่งผลต่อการประมาณค่าระยะความยาวแถวคอยเพิ่มอีกหลากหลายอย่าง เช่น ระยะเวลาสัญญาณไฟจราจร, ลักษณะทางกายภาพของถนน, ประเภทของยานพาหนะ หรือปริมาณจราจร เป็นต้น และอาจเป็นส่วนหนึ่งของวิธีการสร้างแบบจำลองที่สามารถทดลองใช้วิธีการอื่น ๆ เพิ่มเติมได้ เช่น การใช้ Neural Network ในส่วนของการนำไปประยุกต์ใช้ในงานวิจัยนี้อาจเหมาะสมกับในกรณีของรถยนต์ส่วนบุคคลที่วิ่งบนถนนหลักในเมือง เนื่องจากการจำลองจราจรบนโปรแกรม Aimsun ที่มีลักษณะทางกายภาพที่เป็นถนนมาตรฐานของถนนหลักในเมืองและการจำลองจราจรในกรณีที่มีเฉพาะรถยนต์ส่วนบุคคล

3.7 เอกสารอ้างอิง

- Agarwal, H., & Rai, J. (2022, 16-18 March 2022). *Traffic Control System based on Density with Emergency Priority Mechanism*. Paper presented at the 2022 International Conference on Electronics and Renewable Systems (ICEARS).
- Alex. (2022). Google Maps Traffic Color Legend – The 4 Colors Explained. Retrieved from <https://stereoupgrade.com/google-maps-traffic-color-legend/>
- An, C., Wu, Y., Xia, J., & Huang, W. (2018). Real-time queue length estimation using event-based advance detector data. *Journal of Intelligent Transportation Systems*, 22(4), 277-290. doi:10.1080/15472450.2017.1299011
- Anjaneyulu, M., & Kubendiran, M. (2023). Short-Term Traffic Congestion Prediction Using Hybrid Deep Learning Technique. *Sustainability*, 15(1), 74. Retrieved from <https://www.mdpi.com/2071-1050/15/1/74>
- Asgharizadeh, E., Jooybar, S., Mahdiraji, H. A., & Garza-Reyes, J. A. (2022). A Novel Travel Time Estimation Model for Modeling a Green Time-Dependent Vehicle Routing Problem in Food Supply Chain. *Sustainability*, 14(14), 8633. Retrieved from <https://www.mdpi.com/2071-1050/14/14/8633>
- Bae, B., Liu, Y., Han, L. D., & Bozdogan, H. (2019). Spatio-temporal traffic queue detection for uninterrupted flows. *Transportation Research Part B: Methodological*, 129, 20-34. doi:<https://doi.org/10.1016/j.trb.2019.09.001>

- Biau, G., & Scornet, E. (2016). A random forest guided tour. *TEST*, 25(2), 197-227. doi:10.1007/s11749-016-0481-7
- Cheng, J., Li, G., & Chen, X. (2019). Research on Travel Time Prediction Model of Freeway Based on Gradient Boosting Decision Tree. *IEEE Access*, 7, 7466-7480. doi:10.1109/ACCESS.2018.2886549
- Chuo, H., Seah, Y., Tan, K., Lim, K., Liao, C., & Kin Teo, K. (2022, 13-15 Sept. 2022). *On-Demand Priority Traffic Optimizer with Fuzzy Logic Microcontroller*. Paper presented at the 2022 IEEE International Conference on Artificial Intelligence in Engineering and Technology (IICAIET).
- Dumitrache, L., Nae, M., Simion, G., & Talos, A.-M. (2020). Modelling Potential Geographical Access of the Population to Public Hospitals and Quality Health Care in Romania. *International Journal of Environmental Research and Public Health*, 17(22), 8487. Retrieved from <https://www.mdpi.com/1660-4601/17/22/8487>
- Google Maps. (2022). Use layers to find places, traffic, terrain, biking & transit. Retrieved from <https://support.google.com/maps/answer/3092439?hl=en&co=GENIE.Platform%3DDesktop#zippy=%2Ctraffic>
- Greenwell, B., Boehmke, B., Cunningham, J., & Developers, G. B. M. (2022). gbm: Generalized Boosted Regression Models. Retrieved from <https://CRAN.R-project.org/package=gbm>
- Keawthong, P., Muangsin, V., & Gowanit, C. (2022). Location Selection of Charging Stations for Electric Taxis: A Bangkok Case. *Sustainability*, 14(17), 11033. Retrieved from <https://www.mdpi.com/2071-1050/14/17/11033>
- Kuhn, M. (2022). caret: Classification and Regression Training. Retrieved from <https://CRAN.R-project.org/package=caret>
- Lee, S., Wong, S. C., & Li, Y. C. (2015). Real-time estimation of lane-based queue lengths at isolated signalized junctions. *Transportation Research Part C: Emerging Technologies*, 56, 1-17. doi:<https://doi.org/10.1016/j.trc.2015.03.019>

- Li, x., & Bai, R. (2016, 18-20 Dec. 2016). *Freight Vehicle Travel Time Prediction Using Gradient Boosting Regression Tree*. Paper presented at the 2016 15th IEEE International Conference on Machine Learning and Applications (ICMLA).
- Ma, x., Ding, c., Luan, s., & Wang, y. (2017). Prioritizing Influential Factors for Freeway Incident Clearance Time Prediction Using the Gradient Boosting Decision Trees Method. *IEEE Transactions on Intelligent Transportation Systems*, 18(9), 2303-2310. doi:10.1109/TITS.2016.2635719
- Mishra, S., Bhattacharya, D., & Gupta, A. (2018). Congestion Adaptive Traffic Light Control and Notification Architecture Using Google Maps APIs. *Data*, 3(4), 67. Retrieved from <https://www.mdpi.com/2306-5729/3/4/67>
- Moon, J., Hong, J., & Park, T. (2022). A Novel Method for Traffic Estimation and Air Quality Assessment in California. *Sustainability*, 14(15), 9169. Retrieved from <https://www.mdpi.com/2071-1050/14/15/9169>
- Nair, D. J., Gilles, F., Chand, S., Saxena, N., & Dixit, V. (2019). Characterizing multicity urban traffic conditions using crowdsourced data. *PLOS ONE*, 14(3), e0212845. doi:10.1371/journal.pone.0212845
- Naiudomthum, S., Winijkul, E., & Sirisubtawee, S. (2022). Near Real-Time Spatial and Temporal Distribution of Traffic Emissions in Bangkok Using Google Maps Application Program Interface. *Atmosphere*, 13(11), 1803. Retrieved from <https://www.mdpi.com/2073-4433/13/11/1803>
- Natekin, A., & Knoll, A. (2013). Gradient boosting machines, a tutorial. *Frontiers in Neurorobotics*, 7. doi:10.3389/fnbot.2013.00021
- Navarro-Espinoza, A., López-Bonilla, O. R., García-Guerrero, E. E., Tlelo-Cuautle, E., López-Mancilla, D., Hernández-Mejía, C., & Inzunza-González, E. (2022). Traffic Flow Prediction for Smart Traffic Lights Using Machine Learning Algorithms. *Technologies*, 10(1), 5. Retrieved from <https://www.mdpi.com/2227-7080/10/1/5>
- Noaen, M., Mohajerpoor, R., H. Far, B., & Ramezani, M. (2021). Real-time decentralized traffic signal control for congested urban networks considering queue spillbacks. *Transportation Research Part C: Emerging Technologies*, 133, 103407. doi:<https://doi.org/10.1016/j.trc.2021.103407>

- R Core Team. (2022). R: A Language and Environment for Statistical Computing. Vienna, Austria: R Foundation for Statistical Computing. Retrieved from <https://www.R-project.org/>
- Rahman, M. A., Hossain, A.-A., Debnath, B., Zefat, Z. M., Morshed, M. S., & Adnan, Z. H. (2021). Intelligent Vehicle Scheduling and Routing for a Chain of Retail Stores: A Case Study of Dhaka, Bangladesh. *Logistics*, 5(3), 63. Retrieved from <https://www.mdpi.com/2305-6290/5/3/63>
- Rezzouqi, H., Gryech, I., Sbihi, N., Ghogho, M., & Benbrahim, H. (2019, 2019//). *Analyzing the Accuracy of Historical Average for Urban Traffic Forecasting Using Google Maps*. Paper presented at the Intelligent Systems and Applications, Cham.
- Sihag, G., Parida, M., & Kumar, P. (2022). Travel Time Prediction for Traveler Information System in Heterogeneous Disordered Traffic Conditions Using GPS Trajectories. *Sustainability*, 14(16), 10070. Retrieved from <https://www.mdpi.com/2071-1050/14/16/10070>
- Sornsoongnern, P., Pueboobpaphan, R., & Pueboobpaphan, S. (2023). Innovative Dynamic Queue-Length Estimation Using Google Maps Color-Code Data. *Sustainability*, 15, 3466. doi:10.3390/su15043466
- Tan, T.-H., Gochoo, M., Chen, Y.-F., Hu, J.-J., Chiang, J. Y., Chang, C.-S., . . . Hsu, J.-C. (2017). Ubiquitous Emergency Medical Service System Based on Wireless Biosensors, Traffic Information, and Wireless Communication Technologies: Development and Evaluation. *Sensors*, 17(1), 202. Retrieved from <https://www.mdpi.com/1424-8220/17/1/202>
- Venkat, G., Arulananth, T. S., & Baskar, M. (2019). Density based traffic controller with emergency override using CCTV camera. *International Journal of Recent Technology and Engineering*, 8(2 Special issue 3), 866-869. doi:10.35940/ijrte.B1162.0782S319
- Vishnu, U., Sarma, S., Yashumithaa, M., Kr, S., & Gv, V. (2022, 8-10 July 2022). *CNN Based Intelligent Traffic Control System to Support Emergency Vehicles*. Paper presented at the 2022 IEEE International Conference on Electronics, Computing and Communication Technologies (CONECCT).

- Wu, M., Ke, C., & Lai, S. (2022). Optimizing the Routing of Urban Logistics by Context-Based Social Network and Multi-Criteria Decision Analysis. *Symmetry*, 14(9), 1811. Retrieved from <https://www.mdpi.com/2073-8994/14/9/1811>
- Xu, N., Xu, Y., Yan, Y., Guo, Z., Wang, B., & Zhou, X. (2022). Evaluating Road Lighting Quality Using High-Resolution JL1-3B Nighttime Light Remote Sensing Data: A Case Study in Nanjing, China. *Remote Sensing*, 14(18), 4497. Retrieved from <https://www.mdpi.com/2072-4292/14/18/4497>
- Yang, S., Wu, J., Du, Y., He, Y., & Chen, X. (2017). Ensemble Learning for Short-Term Traffic Prediction Based on Gradient Boosting Machine. *Journal of Sensors*, 2017, 1-15. doi:10.1155/2017/7074143
- Yao, J., & Tang, K. (2019). Cycle-based queue length estimation considering spillover conditions based on low-resolution point detector data. *Transportation Research Part C: Emerging Technologies*, 109, 1-18. doi:<https://doi.org/10.1016/j.trc.2019.10.003>
- กฤติพร พึ่งสมบัติ, ณัฐกฤตา ธารทรัพย์, วรณวิสา นามขุนทด, ปณิษฐา สานุกิษย์, นายณัฐพงศ์ สุวรรณมุกต์, & กฤตยชญ์ ต่อโคกสูง. (2564). การประเมินผลของระยะห่างระหว่างทางแยกต่อประสิทธิภาพการประมาณค่าระยะความยาวแถวคอยจากแถบสีแสดงสภาพจราจร. (ปริญญาตรี). มหาวิทยาลัยเทคโนโลยีสุรนารี, มหาวิทยาลัยเทคโนโลยีสุรนารี.
- พงศ์พัฒน์ จอดนอก. (2563). การประมาณความยาวแถวคอยบริเวณทางแยกสัญญาณไฟจราจร โดยใช้ข้อมูลแถบสีแสดงสภาพจราจรจาก *Google Maps*. (วิศวกรรมศาสตรมหาบัณฑิต). มหาวิทยาลัยเทคโนโลยีสุรนารี, สาขาวิชาวิศวกรรมขนส่ง สำนักวิชาวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีสุรนารี.
- พงศ์พัฒน์ จอดนอก และรัฐพล ภูบุงผาพันธ์. (2564). การประมาณความยาวของแถวคอยแบบแปรผันตามเวลาบริเวณทางแยกสัญญาณไฟจราจรโดยใช้ข้อมูลแถบสีจาก *Google Maps*. วารสารวิชาการ วิศวกรรมศาสตร์ ม. อบ.(Vol. 14 No. 4 (2021)).

บทที่ 4

สรุปผลการวิจัยและข้อเสนอแนะ

4.1 สรุป

เนื่องจากแถวค้อยบริเวณทางแยกเป็นหนึ่งในปัจจัยที่ส่งผลต่อการจราจรบริเวณทางแยกที่มีไฟสัญญาณจราจร เพื่อช่วยให้สามารถจัดการบริหารบริเวณทางแยกที่มีไฟสัญญาณจราจรได้อย่างมีประสิทธิภาพและให้รถฉุกเฉินไม่ต้องจอดติดบริเวณทางแยกนาน ดังนั้น งานวิทยานิพนธ์นี้จึงทำการศึกษาความเป็นไปได้ของการใช้ข้อมูลแถบสีจาก Google Maps ในการประมาณค่าความยาวแถวค้อย ทั้งการทดสอบและเปรียบเทียบประสิทธิภาพของแบบจำลอง และการวิเคราะห์และประเมินผลความเป็นไปได้ในการพัฒนาแบบจำลองให้มีประสิทธิภาพที่สูงขึ้น วิทยานิพนธ์เล่มนี้จึงแบ่งเป้าหมายการศึกษาออกเป็นสองส่วน โดยทั้งสองส่วนจะมีความเกี่ยวข้องกับการสร้างแบบจำลองการประมาณค่าระยะความยาวแถวค้อยบริเวณทางแยกที่มีไฟสัญญาณจราจรด้วยการใช้ข้อมูลแถบสีที่แสดงสภาพการจราจรจาก Google Maps โดยมีการสร้างแบบจำลองด้วย Machine-learning และเปรียบเทียบผลลัพธ์ที่ได้กับวิธีการประมาณค่าความยาวแถวค้อยในอดีต สามารถสรุปเป้าหมายการศึกษาทั้งสองส่วนได้ดังนี้

4.1.1 นวัตกรรมใหม่ของการประมาณค่าระยะความยาวแถวค้อยแบบพลวัตโดยใช้

ข้อมูลแถบสีของ Google Maps

เป้าหมายประการแรกถูกจัดทำขึ้นเพื่อพัฒนาและทดสอบเปรียบเทียบประสิทธิภาพของแบบจำลองประมาณค่าระยะความยาวแถวค้อยด้วยข้อมูลตัวแปรแถบสีแบบดั้งเดิม (จำนวน 4 แถบสีตามแบบ Google Maps) กับแนวทางในการสกัดข้อมูลตัวแปรแถบสีแบบใหม่ และการแบ่งการสร้างแบบจำลองตามฝั่งที่มี/ไม่มีไฟสัญญาณจราจรก่อนหน้า และตามช่วงเวลาเร่งด่วน/ไม่เร่งด่วน นอกจากนี้ยังใช้วิธี Random Forest (RF) และ Gradient Boosting Machine (GBM) ในการประมาณระยะความยาวแถวค้อยจากข้อมูลแถบสีของ Google Maps ผลจากการดำเนินงานวิจัยพบว่าวิธี RF และ GBM ให้ค่า RMSE และ ค่า MAPE ที่ไม่แตกต่างกันอย่างมีนัยสำคัญ แต่ให้ผลที่แตกต่างและดีกว่ามากหากเปรียบเทียบกับวิธี Average ที่ใช้ค่าเฉลี่ยของความยาวแถวค้อยในอดีตมาเป็นค่าพยากรณ์ระยะความยาวของแถวค้อย และนอกจากการเปรียบเทียบประสิทธิภาพการทำนายจากทั้งสองวิธีนั้นแล้ว ยังมีการศึกษาเพิ่มเติมเกี่ยวกับค่า Variable Importance (VI) โดยวิเคราะห์ค่า

VI จากแบบจำลองที่ดีที่สุด ให้ผลว่าตัวแปรแถบสีแดงจะมีความสำคัญต่อการสร้างแบบจำลองที่สุดในกรณีที่เป็นฝั่งที่ไม่มีไฟสัญญาณจราจรก่อนหน้านี้ และในกรณีฝั่งที่มีไฟสัญญาณจราจรก่อนหน้านี้จะขึ้นกับว่าเป็นช่วงเร่งด่วนหรือไม่เร่งด่วน ถ้าเป็นช่วงเวลาเร่งด่วนตัวแปรแถบสีจะยังคงมีความสำคัญอยู่ แต่ลำดับของตัวแปรแถบสีจะเปลี่ยนไปและในช่วงเวลาไม่เร่งด่วนตัวแปรแถบสีแดงจะไม่มีผลสำคัญสูงสุด ในงานวิจัยนี้ทำให้ได้ทราบว่าถึงแม้ข้อมูลแถบสีจาก Google Maps จะสามารถประมาณค่าระยะความยาวแถวคอยได้ในระดับหนึ่ง แต่ก็ยังคงมีค่า error ที่สูง สาเหตุอาจเป็นเพราะว่า การอัปเดตของ Google Maps ที่ไม่ได้เป็นแบบทันทีทันใดและความละเอียดด้านระยะทางที่ไม่ได้แสดงผลได้ละเอียดพอทำให้ประสิทธิภาพการทำนายของแบบจำลองยังไม่มีดีพอ

4.1.2 การวิเคราะห์ผลของปัจจัยความละเอียดด้านเวลาและระยะทางของการ

ประมวลผลข้อมูลแถบสีแสดงสภาพจราจรต่อการประมาณค่าระยะความยาวแถวคอย


เป้าหมายประการที่สองต่อเนื่องมาจากเป้าหมายประการแรก จัดทำขึ้นเพื่อเป็นการพัฒนาและยืนยันแนวทางประสิทธิภาพการใช้ข้อมูลแถบสีแสดงสภาพการจราจรในการประมาณค่าระยะความยาวแถวคอย ในงานนี้จึงได้มีการวิเคราะห์และประเมินผลว่าปัจจัยความละเอียดด้านเวลาและความละเอียดด้านระยะทางส่งผลต่อการประมาณค่าระยะความยาวแถวคอยหรือไม่ โดยข้อมูลตัวแปรแถบสีจะได้รับการสร้างแบบจำลองจราจรบนโปรแกรม Aimsun นำมาถอดข้อมูลให้มีลักษณะคล้ายกับแถบสีจาก Google Maps ให้ได้มากที่สุดเท่าที่สามารถรวบรวมข้อมูลของ Google Maps ได้ ลักษณะของตัวแปรแถบสีที่ใช้จะใช้ลักษณะเดียวกันกับของ Google Maps คือมีทั้งหมด 4 แถบสี เนื่องจากการทำเพื่อเปรียบเทียบกับแถบสีของ Google Maps จึงถอดข้อมูลให้มีความคล้ายมากที่สุด วิธีการสร้างแบบจำลองจะใช้วิธี GBM ซึ่งเป็นวิธีการสร้างแบบจำลองที่ดีและเร็วที่สุดจากเป้าหมายการศึกษาประการแรก ในกรณีของปัจจัยความละเอียดด้านเวลาและความละเอียดด้านระยะทางจะถูกกำหนดตามความเหมาะสม โดยให้มีค่าสูงที่สุดครอบคลุมไปถึงค่าน้อยที่สุดที่สามารถยอมรับได้ ผลจากการดำเนินงานแสดงให้เห็นว่าปัจจัยความละเอียดด้านเวลาและความละเอียดด้านระยะทางที่มีความละเอียดมากที่สุดจะส่งผลให้แบบจำลองมีประสิทธิภาพการทำนายที่ดีที่สุด ซึ่งดีกว่าเป้าหมายการศึกษาประการแรก โดยแนวโน้มในภาพรวมของแบบจำลองพบว่ายิ่งความละเอียดด้านเวลาและระยะทางมีค่าที่ละเอียดเท่าไรยิ่งส่งผลให้ค่า error เกิดขึ้นน้อยลงเท่านั้น ส่งผลให้แบบจำลองมีประสิทธิภาพการทำนายที่ดีในสภาพที่ปัจจัยความละเอียดด้านเวลาและความละเอียดด้านระยะทางมีค่าที่ค่อนข้างละเอียด

เป้าหมายการศึกษาทั้งสองส่วนนี้เป็นตัวช่วยประเมินความเป็นไปได้และสนับสนุนการนำตัวแปรแถบสีแสดงสภาพการจราจรไปใช้ในการวิเคราะห์ประมาณค่าหาระยะความยาวแถวคอย โดยที่

ไม่ต้องใช้ detector หรือติดตั้งอุปกรณ์ราคาแพงต่าง ๆ ที่ซึ่งในบางประเทศอาจยังไม่ได้มีการติดตั้งอุปกรณ์เหล่านี้หรือยังติดตั้งได้ไม่ครอบคลุมทุกพื้นที่ และยิ่งถ้าหากในอนาคต Google Maps สามารถพัฒนาการแสดงผลของแถบสีแสดงสภาพการจราจรให้มีความละเอียดมากขึ้น ก็คงส่งผลทำให้ข้อมูลแถบสีเหล่านี้มีความแม่นยำ และสามารถนำไปใช้ให้เกิดประโยชน์ได้ในหลาย ๆ ด้านมากยิ่งขึ้น

4.2 ข้อเสนอแนะ

ข้อมูลแถบสีแสดงสภาพการจราจรจาก Google Maps เป็นข้อมูลที่เข้าถึงได้ง่าย สามารถใช้งานกันได้ทุกคน โดยในงานวิจัยนี้ได้แสดงให้เห็นแล้วว่าข้อมูลแถบสีสามารถนำไปใช้ในการประมาณค่าระยะความยาวแถวคอยได้ดีในระดับหนึ่ง ซึ่งอาจยังไม่เหมาะสมกับการนำไปประยุกต์ใช้กับระบบไฟสัญญาณจราจรเนื่องจากความแม่นยำในการทำนายยังไม่สูงพอ แต่สามารถนำไปช่วยในการออกแบบทางกายภาพถนน หรือการออกแบบความยาวของช่องจราจรถนนได้ เป็นต้น หากต้องการนำข้อมูลแถบสีไปใช้ประมาณค่าระยะความยาวแถวคอยจำเป็นจะต้องมีการศึกษา พัฒนาและปรับปรุงการใช้งานข้อมูลแถบสีเพิ่มเติม





ภาคผนวก ก

บทความวิชาการที่ได้รับการตีพิมพ์เผยแพร่ในระหว่างศึกษา

รายชื่อบทความวิชาการที่ได้รับการตีพิมพ์เผยแพร่ในระหว่างศึกษา

Sornsoongnern, P., et al. (2023). "Innovative Dynamic Queue-Length Estimation Using Google Maps Color-Code Data." *Sustainability* 15(4): 3466.



Article

Innovative Dynamic Queue-Length Estimation Using Google Maps Color-Code Data

Promporn Sornsoongnern , Suthatip Pueboobpaphan and Rattaphol Pueboobpaphan *

School of Transportation Engineering, Institute of Engineering, Suranaree University of Technology, Nakhon Ratchasima 30000, Thailand

* Correspondence: rattaphol@sut.ac.th

Abstract: Queue length is an important parameter for traffic-signal priority systems for emergency vehicles. Instead of using conventional detector data, this paper investigates the feasibility of queue-length estimation using Google Maps color-code data via random forest (RF) and gradient-boosting machine (GBM) methods. Alternative ways of specifying independent variables from color-code data are also investigated. Additionally, the models are separated by peak or off-peak periods and by the presence or absence of adjacent upstream signalized intersections. The results show that the performance predicted by the RF and GBM methods is similar in all cases. Although the error values of both methods are relatively high, they are considerably lower than those obtained from estimates using historical queue-length data. The results obtained using variable-importance analysis show that the importance of the red band near an intersection is significantly higher than that of other variables for a direction without a prior signalized intersection. For a direction with a prior signalized intersection, the importance varies, depending on the period (peak or off-peak). Since Google Maps data are available and cover most of the world intersections, the proposed approach provides a cost-effective option for cities with no detectors installed.

Keywords: queue length; Google Maps; random forest; gradient-boosting machine; variable importance; signalized intersection; traffic signal priority



Citation: Sornsoongnern, P.; Pueboobpaphan, S.; Pueboobpaphan, R. Innovative Dynamic Queue-Length Estimation Using Google Maps Color-Code Data. *Sustainability* **2023**, *15*, 3466. <https://doi.org/10.3390/su15043466>

Academic Editors: Javier Alonso Ruiz and Angel Llamazares

Received: 30 December 2022

Revised: 1 February 2023

Accepted: 8 February 2023

Published: 14 February 2023



Copyright: © 2023 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

Traffic signaling is an effective way of managing traffic at intersections by reducing the conflict points and keeping the traffic through intersections in order. All vehicles must compulsorily stop at a red traffic light; this, unavoidably, causes traffic delays. However, for emergency vehicles, reducing the delays caused by red-light stops by just a few seconds is essential when the lives of patients are in danger. Current traffic-signal priority systems can detect and assign priority to emergency vehicles at signalized intersections [1–4]. An important parameter in such a system is the length of the vehicle queue at that intersection and at that time. This parameter is used to analyze the optimal timing interval required to activate the green signal in advance and to clear the queue from the intersection before emergency vehicles arrive.

In most studies, data from detectors employing the shockwave theory have been used to estimate queue lengths at signalized intersections. Recent studies have attempted to improve the efficiency of queue-length estimation by focusing on the aspects of real time and high accuracy. Queue-length data can also be used to adjust traffic signals and manage traffic congestion [5–9]. However, in almost every intersection in Thailand, no detectors have yet been installed. Therefore, in practice, it is not possible to estimate the queue length using this method. With this limitation in mind, Jodnok and Pueboobpaphan [10] applied linear regression analysis and random forest (RF) analysis to estimate the queue length at signalized intersections during peak and off-peak periods using color-code traffic data obtained from Google Maps. The results showed that the queue-length estimation using

these data was sufficient to some extent, and the RF method exhibited lower errors than those exhibited by other methods.

Many researchers have used Google Maps data in their studies. Travel time and distance data from Google Maps were used to determine the optimal location for installing a charging station [11]. The data were also used to determine the traffic volume and vehicle speed to investigate road congestion [12,13], air pollution [14,15], or accessibility to hospitals [16]. Travel-route data from Google Maps were also used to route cargo and emergency vehicles [17–19]. Color-code and travel-time data from Google Maps were used to adjust the traffic-signal timings in response to near-real-time traffic conditions [20]. The color-code data were also used to forecast traffic conditions for urban roads using historical averages [21]. Traffic-speed data from Google Maps were used to determine the congestion index [22]. However, there is a lack of research on using color-code data from Google Maps to estimate the queue length at signalized intersections.

Google Maps display four possible colors: dark red, red, orange, and green. These colors represent traffic conditions according to vehicle speed, ranging from very low to high speed [23,24]. Jodnok [25] observed color codes by capturing Google Maps screenshots around a signalized intersection every 1 min. He found that the dark red and red bands appeared less frequently than other bands, leading to the question of whether these two colors should be considered, as they had the same color in the model.

Some works have reported the use of the RF technique in various areas of transportation research [26–28]. However, other machine-learning techniques besides RF have also been applied. For instance, the gradient-boosting machine (GBM) technique has been applied when the relationship between dependent and independent variables is nonlinear. GBM applications include travel-time prediction [29], incident-clearance-time prediction [30], and short-term traffic-volume prediction [31]. The GBM technique was found to provide better predictions than other methods [30,31]. Moreover, new studies have shown that the GBM method can calculate the variable importance (VI), which helps understand how important each independent variable is to a dependent variable. This is an added advantage of the GBM method, which was previously considered a black-box method, because of its ability to provide better information about the relationships between dependent and independent variables compared with other methods [32].

This paper extends the study by Jodnok and Pueboobpaphan [10]. In addition to peak/off-peak periods, we consider modeling, which is based on directions with or without an upstream signalized intersection in the vicinity. Furthermore, we consider alternative ways of modeling independent variables using color-code traffic data. Specifically, we consider dark red and red as being the same color and green as a reference color. The predicted results obtained using the RF and GBM methods are compared with those estimated by the historical averages, and VI analysis is performed to understand the factors affecting the prediction of queue length using color codes from Google Maps. The objective is to assess the feasibility and limitations of developing a method for estimating the queue length from the color-code traffic data obtained from Google Maps. This method will provide an alternative for those areas where no detectors are installed at signalized intersections on a road network.

In the next section, the data collection and survey are briefly explained. Details of how color-code data from Google Maps and actual queue-length data from the field were collected and processed as independent and dependent variables, respectively, are described. Details on modeling scenarios are then provided, followed by modeling results and the variable importance (VI) analysis. The conclusions and recommendations complete the paper.

2. Materials and Methods

This paper uses the same data as those used by Jodnok and Pueboobpaphan [10], who surveyed and collected data of colors and lengths of each consecutive color band from Google Maps. They also simultaneously recorded the actual queue lengths. The area of

study was a T-signalized intersection on the main arterial road in the Nakhon Ratchasima province, Thailand. The intersection is located in an area with heavy traffic and frequent traffic jams. There are four lanes in each direction. Figure 1 shows the area of study, where a prior traffic signal is absent in the inbound direction, but present in the outbound direction at a distance of 930 m upstream from the studied intersection. The survey and data collection was started at 7:00 a.m. and completed at 7:00 p.m. to cover the peak and off-peak periods. The survey was conducted for three days during weekdays and for two days during weekends.




Figure 1. Area of study. The background map was captured from maps.google.com, accessed on 10 January 2023.

2.1. Collection of Color-Code Data from Google Maps

A screenshot of Google Maps, which covers the entire area of investigation, was captured every 1 min. The Google Maps website was continually refreshed using the Auto-Refresh program to illustrate the change in the color-code data continuously. It was observed that in the direction without a prior signalized intersection, the last band shown on the edge of the screen was always a green-color band. Figure 2 shows an example of the color-code data obtained from Google Maps, where four color bands are displayed; the 1st band from the stop line is dark red with a length of 120 m, followed by a 120 m red band, a 220 m orange band, and finally, a green band, which extends beyond the screen. The length of the last band was specified as 9999 m. An example of the data extraction from the Google Maps screenshot (shown in Figure 2) is presented in Table 1.

Table 1. Sample data obtained from Google Maps.

| Items | Color | Length (m) |
|--------------------------|----------|------------|
| 1st color from stop line | Dark red | 120 |
| 2nd color from stop line | Red | 120 |
| 3rd color from stop line | Orange | 220 |
| 4th color from stop line | Green | 9999 |




Figure 2. Example of length measurement using the Google Maps color-code data. The background map was captured from maps.google.com, accessed on 10 January 2023.

2.2. Survey of the Actual Queue-Length Data

The actual queue lengths were surveyed by observers in the field. The curb was temporarily marked with a reflective tape every 20 m from the stop line. These marks were viewed against the tails of the queuing vehicles for measuring the queue length. In addition, a detailed map indicating the distance to various landmarks, such as buildings, light poles, billboards, and other structures that can be easily seen from a distance, was prepared to assist the observers in measuring the queue lengths. Generally, the queue lengths of the lanes may not be the same, but in our case, they are not much different. Therefore, the average of the queue lengths obtained from all four lanes was used to represent the queue length that was used as a dependent variable in the model. Seven fourth-year undergraduate students and one graduate student from the School of Transportation Engineering, Suranaree University of Technology, were recruited for field observation. Every two students had to cover a 200 m segment for two different lanes. Six students, thus, covered a total distance of 600 m of a four-lane road segment, which was sufficient in our case study. The remaining two students had to stand-by at the site for replacing their friends while also monitoring video cameras used to record traffic volume and traffic signals. The observers used radio communication to communicate about the current position of the queue tail. They were asked to follow the queue tail, if it is in the segment for which they were responsible, to record the actual queue length every 1 min (the same interval of capturing as the Google Maps screen). A speed threshold of less than 10 km/h was used to identify approaching vehicles as being in the queue. The direction and time were also recorded to identify whether the queue length was observed during peak or off-peak periods and whether there was a prior signalized intersection. When all vehicles were moving during the green signal and no queue occurred, the queue length was recorded as zero. Figure 3 illustrates the distribution of the observers and video cameras in the study area. Note that the inbound and outbound directions were observed independently on different days.




Figure 3. Distribution of observers and cameras in the study area.

2.3. Data Processing

Jodnok and Pueboobpaphan [10] found that the highest number of bands counting from the stop line was six on the surveyed road section. The color bands were defined so that the band closest to the intersection was assigned as the first band, and the band furthest from the intersection was assigned as the last band. They also found that using data from the first three bands adjacent to the stop line was sufficient and produced equivalent performance to that of using data from all six bands. Therefore, in this paper, data from only the first three bands adjacent to the stop line were used to create independent variables. In addition, the following alternative ways of processing color-code data as independent variables were attempted:

Independent variable set 1 (IV1): consider all four original colors of Google Maps as in [10].

Independent variable set 2 (IV2): consider dark red and red as if they were the same color.

Independent variable set 3 (IV3): similar to IV2, but the green variable is also considered as a reference color and is dropped.

The name of the independent variables used in the model is shown in Table 2. The recorded value of each independent variable depends on whether the actual color from Google Maps matches the color of the variable as indicated by Equation (1). If the actual color of band i is the same color as the variable j , then the length of band i in meters is recorded. Otherwise, variable j will be zero.

$$j_i = \begin{cases} \text{length of band } i, & \text{if actual color of band } i \text{ is } j \\ 0, & \text{otherwise} \end{cases} \quad (1)$$

Table 2. New modified color-code variables.

| Set of Independent Variables (IV) | Color | Name of Independent Variable | | |
|-----------------------------------|--------------|------------------------------|-----------|-----------|
| | | 1st Band | 2nd Band | 3rd Band |
| IV1 | Dark red | DARKRED_1 | DARKRED_2 | DARKRED_3 |
| | Red | RED_1 | RED_2 | RED_3 |
| | Orange | ORANGE_1 | ORANGE_2 | ORANGE_3 |
| | Green | GREEN_1 | GREEN_2 | GREEN_3 |
| IV2 | Combined red | C_RED_1 | C_RED_2 | C_RED_3 |
| | Orange | ORANGE_1 | ORANGE_2 | ORANGE_3 |
| | Green | GREEN_1 | GREEN_2 | GREEN_3 |
| IV3 | Combined red | C_RED_1 | C_RED_2 | C_RED_3 |
| | Orange | ORANGE_1 | ORANGE_2 | ORANGE_3 |

2.4. Modeling

In this paper, two machine-learning techniques, namely, the RF and GBM, are applied. The RF is an ensemble decision-tree method. The principle of RF is to create multiple decision trees, where each employs the same algorithm, but has different features. The data used to construct each tree are randomly selected from the same database. When a decision tree is completed, the data are returned to the original database, and a new set of data is randomly selected to create a new decision tree [33]. The GBM technique is an improved technique based on the RF technique. GBM is considered an ensemble learning technique. Initially, GBM creates a weak classifier and then calculates the error values. GBM learns the pattern of error values, improves to reduce the error, and builds a new model. Thus, the error in the new model is less than that of the previous one. GBM continues the modeling sequentially, until the error cannot be learned. Then, model building is stopped [34].

In addition to the RF and GBM techniques, a simple estimation method is considered in this paper. This method uses the average of historical queue lengths, which are separated by the direction and by the period, as the estimate of the queue length in each case. This is later called the Average method. It represents the simplest possible estimation, which does not require any other input, except for the historical queue-length data. The results obtained using the Average method were used as a benchmark for comparison with the results obtained from the RF and GBM methods.

In general, traffic and queue patterns may differ between directions with and without a prior signalized intersection as well as between peak and off-peak periods. In this paper, seven different models based on these factors are considered. These models are described below and illustrated in Figure 4.




Figure 4. Scenarios and models used for estimating the queue length.

Model 1 (M1): Model with no separation of the direction and period

Model 2 (M2): Model for a direction without a prior signalized intersection and no separation of the period

Model 3 (M3): Model for a direction with a prior signalized intersection and no separation of the period

Model 4 (M4): Model for a direction without a prior signalized intersection and a peak period

Model 5 (M5): Model for a direction without a prior signalized intersection and an off-peak period

Model 6 (M6): Model for a direction with a prior signalized intersection and a peak period

Model 7 (M7): Model for a direction with a prior signalized intersection and an off-peak period

Based on the models described above, the following three equivalent scenarios were considered in the queue-length estimation:

Scenario 1: Model 1 was used to predict queue lengths in all cases with no separation of the direction and period.

Scenario 2: Model 2 was used to predict the queue length in a direction without a prior signalized intersection, and Model 3 was used to predict the queue length in a direction with a prior signalized intersection.

Scenario 3: Models 4 and 5 were used to predict queue lengths in a direction without a prior signalized intersection during peak and off-peak periods, respectively. Models 6 and 7 were used to predict queue lengths in a direction with a prior signalized intersection during peak and off-peak periods, respectively.

In this paper, the queue-length estimation models were constructed using RF and GBM from the packages in R [35], namely, caret [36] and gbm [37], respectively. To perform RF modeling using the caret package, the cforest method was used, and the tuning parameter of this method, mtry, which is the number of randomly selected predictors, was tuned in the 3–12 range. In GBM, caret was also used for parameter tuning. The GBM parameters were n.trees, interaction.depth, shrinkage, and n.minobsinnode. The entire dataset was divided into two subsets. The first 90% of data were used for training and modeling using a five-fold cross-validation method. The remaining 10% of data were used to test the prediction performance based on the root mean square error (RMSE) and the mean absolute percentage error (MAPE).

Figure 5 shows the overall modeling and analysis procedures. The procedures are summarized as follows:

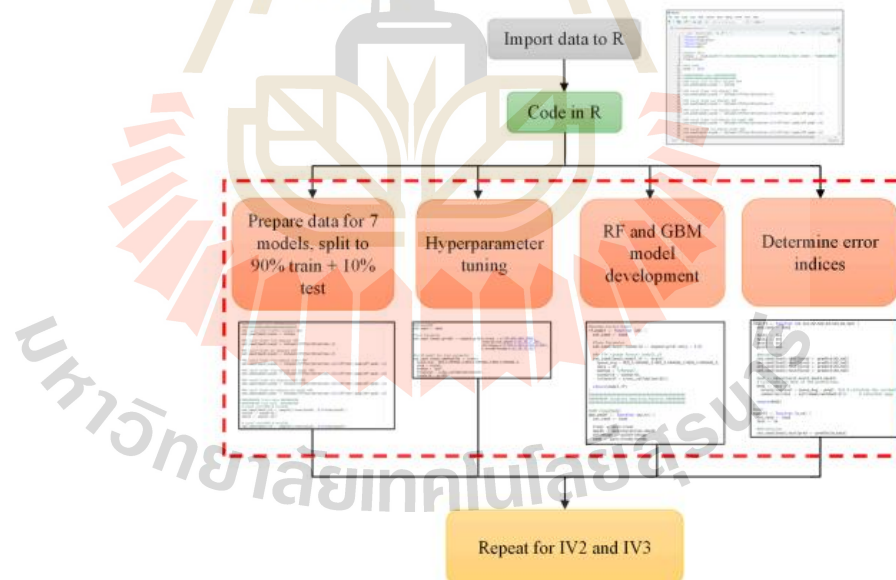


Figure 5. Overall modeling and analysis procedures.

1. Import actual queue length and color-code length data into the R program.
2. Create a separate dataset for each of the seven models.
3. Divide each dataset into 90% for training and 10% for testing.
4. For each of the independent variable sets, the training dataset is used for tuning the hyperparameters of the models. The GBM method uses package caret to tune the parameters. There are four parameters to tune: n.trees, interaction.depth, shrinkage, and n.minobsinnode. At first, a wide range of the parameter values were used for tuning. Subsequently, it is adjusted to a narrower range to fine-tune and seek the best value.
5. Once the optimum parameters are obtained, the GBM model is developed using the gbm package so that VI analysis can be performed. For the RF method, parameter tuning and modeling are performed simultaneously by the caret package.
6. The developed models are applied to the test dataset to predict the queue length, compare it with the actual queue length, and determine the error indices (RMSE and MAPE).
7. Repeat step 4–6 for other sets of independent variables.

3. Results and Discussion

3.1. Performance of the Queue-Length Estimation Models

The prediction performances of the queue-length estimation models obtained from color-code data using the RF, GBM, and Average methods are presented and compared. Table 3 shows the RMSE and MAPE from all three scenarios and three sets of independent variables, whereas Figures 6 and 7 show only the values from IV3 of each scenario and method. The results show that the lowest values of RMSE and MAPE are obtained in Scenario 3 with IV3 (combined red; green is used as a reference) using the RF and GBM methods, respectively. However, when comparing the RMSE and MAPE values in Scenario 3 vs. those in Scenarios 1 and 2, or IV3 vs. IV1 and IV2, no significant difference is observed. The error values are quite similar in all scenarios and all sets of the independent variables. Therefore, it is not possible to clearly discuss the differences between the RF and GBM methods. Nevertheless, the RMSE and MAPE values in both methods are significantly lower than those obtained using the Average method in all cases.

Table 3. RMSE and MAPE values of all models.

| Type of Variable | Random Forest | | Gradient Boosting | | Average | |
|------------------|---------------|----------|-------------------|----------|---------------|----------|
| | RMSE (Meters) | MAPE (%) | RMSE (Meters) | MAPE (%) | RMSE (Meters) | MAPE (%) |
| Scenario 1 | | | | | | |
| - IV1 | 71.8337 | 63.6274 | 72.7679 | 63.4070 | 83.9077 | 71.8533 |
| - IV2 | 72.6153 | 64.5514 | 72.0657 | 64.0463 | 83.9077 | 71.8533 |
| - IV3 | 72.5919 | 64.5336 | 72.6746 | 64.3501 | 83.9077 | 71.8533 |
| Scenario 2 | | | | | | |
| - IV1 | 72.1760 | 63.4921 | 72.7062 | 63.7009 | 81.8285 | 70.7399 |
| - IV2 | 71.8395 | 63.9266 | 72.2615 | 63.3056 | 81.8285 | 70.7399 |
| - IV3 | 71.9597 | 64.5817 | 73.2521 | 64.1587 | 81.8285 | 70.7399 |
| Scenario 3 | | | | | | |
| - IV1 | 72.0496 | 63.4174 | 72.5952 | 62.8423 | 81.6131 | 70.4689 |
| - IV2 | 72.2144 | 63.8694 | 71.9686 | 62.9886 | 81.6131 | 70.4689 |
| - IV3 | 71.6170 | 63.8278 | 72.3546 | 62.8304 | 81.6131 | 70.4689 |

The above table shows that the queue-length predictions obtained using the RF and GBM methods are significantly better than those obtained using the Average method. Figures 8–10 show the actual queue lengths obtained from the test dataset against the predicted queue lengths obtained using different methods in Scenario 3 with IV3. Although the predicted lengths obtained using the Average method can vary slightly depending on the direction and period, they cannot follow the dynamic change of the actual queue lengths. On the other hand, the lengths obtained using the RF and GBM methods can sufficiently follow the dynamic change of the actual queue lengths. Although the values

obtained from both models still differ considerably from the actual values, their ability to capture the variations of the actual queue length is significantly better than that of the Average method.




Figure 6. RMSE values for IV3 of each method and scenario.




Figure 7. MAPE values for IV3 of each method and scenario.

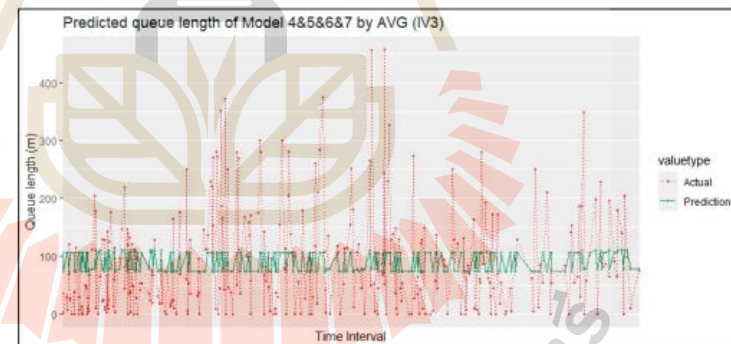


Figure 8. Predicted results in Scenario 3 with IV3 using the Average method.

It is worth noting that the traffic data from Google Maps is historical data based on previous measurements. The use of these data for traffic control, particularly with priority, may be debatable, as control at any given time must be adapted to the current length of the queue. Based on the prediction accuracy shown in Table 3 and Figures 8–10, the proposed approach might not be sufficient for control operation, but it might be useful for design purposes, such as determining the length of additional lanes to turn at an intersection.




Figure 9. Predicted results in Scenario 3 with IV3 using the RF method.




Figure 10. Predicted results in Scenario 3 with IV3 using the GBM method.

3.2. Variable Importance (VI) Analysis

To better understand how the importance of the color band and its length affect the queue length and whether this importance differs between cases, the variable importance (VI) analysis results obtained using the GBM method in Scenario 3 (Models 4–7) with IV3 are presented. A variable with a high VI value is considered very important and highly affects the queue-length estimation. The VI analysis results (in percentage and in descending order) for each model are shown in Table 4 and Figures 11–14.

Table 4. Variable importance (VI) analysis of Scenario 3 with IV3.

| M4 | | M5 | | M6 | | M7 | |
|----------|--------|----------|--------|----------|--------|----------|--------|
| Variable | VI (%) | Variable | VI (%) | Variable | VI (%) | Variable | VI (%) |
| C_RED_2 | 29.616 | C_RED_2 | 26.472 | C_RED_3 | 27.398 | ORANGE_2 | 20.750 |
| C_RED_1 | 21.448 | C_RED_1 | 25.219 | ORANGE_2 | 20.467 | ORANGE_1 | 19.297 |
| C_RED_3 | 18.730 | ORANGE_2 | 17.233 | C_RED_2 | 14.254 | C_RED_1 | 16.482 |
| ORANGE_1 | 11.948 | C_RED_3 | 11.453 | ORANGE_3 | 14.222 | C_RED_3 | 16.192 |
| ORANGE_3 | 9.398 | ORANGE_3 | 11.244 | ORANGE_1 | 12.813 | ORANGE_3 | 14.517 |
| ORANGE_2 | 8.857 | ORANGE_1 | 8.376 | C_RED_1 | 10.844 | C_RED_2 | 12.759 |




Figure 11. Variable importance (VI) analysis of Model 4, Scenario 3 with IV3.




Figure 12. Variable importance (VI) analysis of Model 5, Scenario 3 with IV3.




Figure 13. Variable importance (VI) analysis of Model 6, Scenario 3 with IV3.




Figure 14. Variable importance (VI) analysis of Model 7, Scenario 3 with IV3.

The VI analysis results for Models 4 and 5, which correspond to the cases for a direction without a prior signalized intersection, show that the importance of the red band near the intersection is significantly higher than that of the other variables. The first two variables with the highest VI values are C_RED_2 and C_RED_1. During peak hours (Model 4), the importance level of the most important variable is significantly different from that of the second most important variable (29.61% for C_RED_2 vs. 21.45% for C_RED_1). This is different from the off-peak period, where the importance level of the most important variable is not significantly different from that of the second most important variable (26.47% for C_RED_2 vs. 25.22% for C_RED_1).

Comparisons between peak and off-peak periods for the direction with a prior signalized intersection (Models 6 and 7, respectively), indicate similar and different trends to those for the direction without a prior signalized intersection (Models 4 and 5). Regarding the same trends, during peak hours, the importance level of the most important variable is significantly different from that of the second most important variable (27.39% for C_RED_3 vs. 20.46% for ORANGE_2). During off-peak hours, the importance level of the most important variable is not significantly different from that of the second most important variable (20.75% for ORANGE_2 vs. 19.29% of ORANGE_1). Especially in Model 7, the importance level of each variable is not much different. This implies that the model can only partly capture the dynamic change of the actual queue lengths. However, the trend that differs from the direction without a prior signalized intersection is in the order of the variables, where C_RED_2 and C_RED_1 are no longer the top two most important variables. C_RED_3 and ORANGE_2 or ORANGE_1 are the most important variables in this case. This may be due to the updating and displaying of the Google Maps traffic color-code data, which are not real-time data, causing the traffic color-code display on Google Maps to be inconsistent with the actual queue length obtained from the survey. In addition, there is a difference in the distribution pattern of the arriving vehicles when a prior signalized intersection is absent or present. The arrival process for the direction without a prior signalized intersection is random, where vehicles arrive regularly, as opposed to the cluster-like pattern for the direction with a prior signalized intersection, where vehicles arrive in a platoon during the green, alternating with gaps during the red of the prior signal. With such characteristics, the traffic and queue for the direction with a prior signalized intersection are expected to show a relatively higher variation than that for the direction without a prior signalized intersection. As a result, the Google Maps color-code data in the direction with a prior signalized intersection may not be able to reflect well the changes in the traffic queue compared to those in the direction without a prior signalized intersection.

4. Conclusions

The objective of this paper was the estimation of traffic-queue lengths at signalized intersections using a new data source, specifically traffic color-code data obtained from Google Maps. The RF and GBM methods were employed and compared with a simple estimation method that uses only historical average queue-length data (i.e., the Average method). The original color-code data were processed to construct three different alternatives of independent variable specifications: (i) considering the colors as actually displayed on Google Maps, (ii) considering the dark red and red as if they were the same color, and (iii) using the green as a reference color. This study showed that the RF and GBM methods achieve similar prediction performance in all scenarios and provide independent variable specifications. Also, they perform significantly better than the Average method.

The VI analysis for a direction without a prior signalized intersection showed that the importance of the red band near the intersection is significantly higher than that of other variables. For a direction with a prior signalized intersection, the importance varies, depending on the period (peak or off-peak period), and the red band near the intersection is no longer the most important parameter. The off-peak period model showed that the importance of the color-code variable is not very different among all variables. The order of color bands based on their importance also differs between the two directions. This may

be due to the updating frequency of the Google Maps data, which are not displayed in real time, causing the color-code data displayed on Google Maps to be inconsistent with the actual queue length obtained from the survey. Such non-real-time updates along with the cluster-like vehicle arrival pattern for a direction with a prior signalized intersection, cannot capture the relatively high dynamic changes in the traffic and the actual queue lengths. Thus, it is difficult for the model to capture information from the color-code data to estimate the queue length.

This study is a starting point for the feasibility of estimating queue lengths using color-code data obtained from Google Maps and provides an alternative to conventional approaches that use detector data. The proposed approach was able to estimate the queue length well only to a certain extent. Although the error of the proposed approach is still relatively high, it is far better than the error obtained using only historical queue-length data. This error can be attributed to several reasons, especially the non-real-time update of Google Maps. In addition, the display resolution of the Google Maps color bands, where the lengths are often displayed in a hierarchical order, may also affect the estimation of the queue length. Future research direction will be to investigate if the prediction accuracy of real-time queue-length estimation can be further increased by providing internet data processing technologies with additional capabilities such as the real-time display of color-code information and a better display resolution of color-band lengths. Other machine-learning techniques, such as neural network, support vector machines, and deep learning, will be adopted and compared to improve prediction accuracy. Another area of focus is to investigate and estimate the delay time of Google Maps updates, and develop methods to incorporate such delay time into the estimation procedure.

Author Contributions: Conceptualization, R.P. and S.P.; methodology, R.P. and P.S.; software, R.P. and P.S.; validation, R.P., P.S. and S.P.; formal analysis, R.P. and P.S.; investigation, R.P. and P.S.; data curation, P.S.; writing—original draft preparation, R.P. and P.S.; writing—review and editing, R.P., P.S. and S.P.; visualization, P.S.; supervision, R.P.; project administration, S.P. All authors have read and agreed to the published version of the manuscript.

Funding: This research received no external funding.

Institutional Review Board Statement: Not applicable.

Informed Consent Statement: Not applicable.

Data Availability Statement: Not applicable.

Conflicts of Interest: The authors declare no conflict of interest.

References


1. Venkat, G.; Arulananth, T.S.; Baskar, M. Density Based Traffic Controller with Emergency Override using CCTV Camera. *Int. J. Recent Technol. Eng.* **2019**, *8*, 866–869. [\[CrossRef\]](#)
2. Chuo, H.; Seah, Y.; Tan, K.; Lim, K.; Liao, C.; Kin Teo, K. On-Demand Priority Traffic Optimizer with Fuzzy Logic Microcontroller. In Proceedings of the 2022 IEEE International Conference on Artificial Intelligence in Engineering and Technology (IICAIET), Kota Kinabalu, Malaysia, 13–15 September 2022; pp. 1–6.
3. Agarwal, H.; Rai, J. Traffic Control System Based on Density with Emergency Priority Mechanism. In Proceedings of the 2022 International Conference on Electronics and Renewable Systems (ICEARS), Tuticorin, India, 16–18 March 2022; pp. 192–197.
4. Vishnu, U.; Sarma, S.; Yashumithaa, M.; Kr, S.; Gv, V. CNN Based Intelligent Traffic Control System to Support Emergency Vehicles. In Proceedings of the 2022 IEEE International Conference on Electronics, Computing and Communication Technologies (CONECCT), Bangalore, India, 8–10 July 2022; pp. 1–5.
5. Lee, S.; Wong, S.C.; Li, Y.C. Real-Time Estimation of Lane-Based Queue Lengths at Isolated Signalized Junctions. *Transp. Res. Part. C Emerg. Technol.* **2015**, *56*, 1–17. [\[CrossRef\]](#)
6. An, C.; Wu, Y.; Xia, J.; Huang, W. Real-Time Queue Length Estimation Using Event-Based Advance Detector Data. *J. Intell. Transp. Syst.* **2018**, *22*, 277–290. [\[CrossRef\]](#)
7. Bae, B.; Liu, Y.; Han, L.D.; Bozdogan, H. Spatio-temporal Traffic Queue Detection for Uninterrupted Flows. *Transp. Res. B Methodol.* **2019**, *129*, 20–34. [\[CrossRef\]](#)
8. Yao, J.; Tang, K. Cycle-Based Queue Length Estimation Considering Spillover Conditions Based on Low-Resolution Point Detector Data. *Transp. Res. Part. C Emerg. Technol.* **2019**, *109*, 1–18. [\[CrossRef\]](#)

9. Noaean, M.; Mohajerpoor, R.; Far, B.H.; Ramezani, M. Real-Time Decentralized Traffic Signal Control for Congested Urban Networks Considering Queue Spillbacks. *Transp. Res. Part. C Emerg. Technol.* **2021**, *133*, 103407. [CrossRef]
10. Jodnok, P.; Pueboobpaphan, R. Estimating Time-Varying Queue Length at Signalized Intersection by Using Color-Coded Traffic on Google Maps. *UBU Eng. J.* **2021**, *14*, 48–60.
11. Keawthong, P.; Muangsin, V.; Gowanit, C. Location Selection of Charging Stations for Electric Taxis: A Bangkok Case. *Sustainability* **2022**, *14*, 11033. [CrossRef]
12. Asgharizadeh, E.; Jooybar, S.; Mahdiraji, H.A.; Garza-Reyes, J.A. A Novel Travel Time Estimation Model for Modeling a Green Time-Dependent Vehicle Routing Problem in Food Supply Chain. *Sustainability* **2022**, *14*, 8633. [CrossRef]
13. Anjaneyulu, M.; Kubendiran, M. Short-Term Traffic Congestion Prediction Using Hybrid Deep Learning Technique. *Sustainability* **2023**, *15*, 74. [CrossRef]
14. Naiudomthum, S.; Winijkul, E.; Sirisubtawee, S. Near Real-Time Spatial and Temporal Distribution of Traffic Emissions in Bangkok Using Google Maps Application Program Interface. *Atmosphere* **2022**, *13*, 1803. [CrossRef]
15. Moon, J.; Hong, J.; Park, T. A Novel Method for Traffic Estimation and Air Quality Assessment in California. *Sustainability* **2022**, *14*, 9169. [CrossRef]
16. Dumitrache, L.; Nae, M.; Simion, G.; Talos, A.M. Modelling Potential Geographical Access of the Population to Public Hospitals and Quality Health Care in Romania. *Int. J. Environ. Res. Public Health* **2020**, *17*, 8487. [CrossRef] [PubMed]
17. Wu, M.; Ke, C.; Lai, S. Optimizing the Routing of Urban Logistics by Context-Based Social Network and Multi-Criteria Decision Analysis. *Symmetry* **2022**, *14*, 1811. [CrossRef]
18. Rahman, M.A.; Hossain, A.A.; Debnath, B.; Zefat, Z.M.; Morshed, M.S.; Adnan, Z.H. Intelligent Vehicle Scheduling and Routing for a Chain of Retail Stores: A Case Study of Dhaka, Bangladesh. *Logistics* **2021**, *5*, 63. [CrossRef]
19. Tan, T.H.; Gochoo, M.; Chen, Y.F.; Hu, J.J.; Chiang, J.Y.; Chang, C.S.; Lee, M.H.; Hsu, Y.N.; Hsu, J.C. Ubiquitous Emergency Medical Service System Based on Wireless Biosensors, Traffic Information, and Wireless Communication Technologies: Development and Evaluation. *Sensors* **2017**, *17*, 202. [CrossRef]
20. Mishra, S.; Bhattacharya, D.; Gupta, A. Congestion Adaptive Traffic Light Control and Notification Architecture Using Google Maps APIs. *Data* **2018**, *3*, 67. [CrossRef]
21. Rezzouqi, H.; Gryech, I.; Sbihi, N.; Ghogho, M.; Benbrahim, H. Analyzing the Accuracy of Historical Average for Urban Traffic Forecasting Using Google Maps. In *Intelligent Systems and Applications*; Springer: Cham, Switzerland, 2019; pp. 1145–1156. [CrossRef]
22. Nair, D.J.; Gilles, F.; Chand, S.; Saxena, N.; Dixit, V. Characterizing Multicity Urban Traffic Conditions Using Crowdsourced Data. *PLoS ONE* **2019**, *14*, e0212845. [CrossRef]
23. Maps, G. Use Layers to Find Places, Traffic, Terrain, Biking & Transit. Available online: <https://support.google.com/maps/answer/3092439?hl=en&co=GENIE.Platform%3DDesktop#zippy=%2Ctraffic> (accessed on 10 November 2022).
24. Alex. Google Maps Traffic Color Legend—The 4 Colors Explained. Available online: <https://stereoupgrade.com/google-maps-traffic-color-legend/> (accessed on 10 November 2022).
25. Jodnok, P. *Estimation of Queue Lengths at a Signalized Intersection Using Google Maps' Color-Code Traffic Information*; Suranaree University of Technology: Nakhonratchasima, Thailand, 2020.
26. Xu, N.; Xu, Y.; Yan, Y.; Guo, Z.; Wang, B.; Zhou, X. Evaluating Road Lighting Quality Using High-Resolution JL1-3B Nighttime Light Remote Sensing Data: A Case Study in Nanjing, China. *Remote Sens.* **2022**, *14*, 4497. [CrossRef]
27. Navarro-Espinoza, A.; López-Bonilla, O.R.; García-Guerrero, E.E.; Tlelo-Cuautle, E.; López-Mancilla, D.; Hernández-Mejía, C.; Inzunza-González, E. Traffic Flow Prediction for Smart Traffic Lights Using Machine Learning Algorithms. *Technologies* **2022**, *10*, 5. [CrossRef]
28. Sihag, G.; Parida, M.; Kumar, P. Travel Time Prediction for Traveler Information System in Heterogeneous Disordered Traffic Conditions Using GPS Trajectories. *Sustainability* **2022**, *14*, 10070. [CrossRef]
29. Li, X.; Bai, R. Freight Vehicle Travel Time Prediction Using Gradient Boosting Regression Tree. In Proceedings of the 2016 15th IEEE International Conference on Machine Learning and Applications (ICMLA), Anaheim, CA, USA, 18–20 December 2016; pp. 1010–1015.
30. Ma, X.; Ding, C.; Luan, S.; Wang, Y. Prioritizing Influential Factors for Freeway Incident Clearance Time Prediction Using the Gradient Boosting Decision Trees Method. *IEEE Trans. Intell. Transp. Syst.* **2017**, *18*, 2303–2310. [CrossRef]
31. Yang, S.; Wu, J.; Du, Y.; He, Y.; Chen, X. Ensemble Learning for Short-Term Traffic Prediction Based on Gradient Boosting Machine. *J. Sens.* **2017**, *2017*, 7074143. [CrossRef]
32. Cheng, J.; Li, G.; Chen, X. Research on Travel Time Prediction Model of Freeway Based on Gradient Boosting Decision Tree. *IEEE Access* **2019**, *7*, 7466–7480. [CrossRef]
33. Biau, G.; Scornet, E. A Random Forest Guided Tour. *TEST* **2016**, *25*, 197–227. [CrossRef]
34. Natekin, A.; Knoll, A. Gradient Boosting Machines, A Tutorial. *Front. Neurobot.* **2013**, *7*, 21. [CrossRef]
35. R Core Team. *R: A Language and Environment for Statistical Computing*; R Foundation for Statistical Computing: Vienna, Austria, 2022.

36. Kuhn, M. Caret: Classification and Regression Training. 2022. Available online: <https://cran.r-project.org/web/packages/caret/caret.pdf> (accessed on 10 January 2023).
37. Greenwell, B.; Boehmke, B.; Cunningham, J.; Developers, G.B.M. gbm: Generalized Boosted Regression Models. 2022. Available online: <https://cran.r-project.org/web/packages/gbm/gbm.pdf> (accessed on 10 January 2023).

Disclaimer/Publisher's Note: The statements, opinions and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of MDPI and/or the editor(s). MDPI and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions or products referred to in the content.





ประวัติผู้เขียน

นางสาวพรหมพร ทรสูงเนิน เกิดเมื่อวันที่ 2 มีนาคม พ.ศ. 2541 สำเร็จการศึกษาระดับประถมศึกษาจากโรงเรียนมารีย์รักษ์ ในปีการศึกษา 2552 สำเร็จการศึกษาระดับชั้นมัธยมศึกษาตอนต้นจากโรงเรียนรวมมิตรวิทยา ในปีการศึกษา 2555 สำเร็จการศึกษาระดับชั้นมัธยมศึกษาตอนปลายจากโรงเรียนบุญวัฒนา ในปีการศึกษา 2558 และสำเร็จการศึกษาระดับปริญญาตรีจากสำนักวิศวกรรมศาสตร์ สาขาวิชาวิศวกรรมขนส่ง มหาวิทยาลัยเทคโนโลยีสุรนารี ในปีการศึกษา 2562 จากนั้นศึกษาต่อในระดับปริญญาโท สำนักวิศวกรรมศาสตร์ สาขาวิชาวิศวกรรมขนส่ง หลักสูตรวิศวกรรมโยธา ขนส่ง และทรัพยากรธรณี ในปีการศึกษา 2562 และสำเร็จการศึกษา ในปีการศึกษา 2565 ในขณะที่ศึกษาอยู่ได้ทำหน้าที่ผู้ช่วยสอนในสาขาวิชาวิศวกรรมขนส่ง มหาวิทยาลัยเทคโนโลยีสุรนารี และเข้าร่วมงานวิจัยต่าง ๆ

ผลงานวิจัย: ได้ส่งบทความเพื่อทำการตีพิมพ์ระดับนานาชาติไปยังวารสาร Sustainability เรื่องนวัตกรรมใหม่ของการประมาณค่าระยะความยาวแถวคอยแบบพลวัตโดยใช้ข้อมูลแถบสีของ Google Maps (Innovative Dynamic Queue-Length Estimation Using Google Maps Color-Code Data)

มหาวิทยาลัยเทคโนโลยีสุรนารี