

การพัฒนาแบบจำลองสภาพจราจรแบบทันกาลบนทางพิเศษ Real Time Traffic Simulation Development on Expressway

สุริย โทมะ¹, ทักษิณา กรโกร², ศิวัช ปัญญาชัยวัฒนากุล³ และ รัฐพงศ์ มีสิทธิ์^{4*}

^{1,2,3} กองวิจัยและนวัตกรรม ฝ่ายดิจิทัล 1 การทางพิเศษแห่งประเทศไทย กรุงเทพมหานคร

⁴ ภาควิชาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์ มหาวิทยาลัยบูรพา จ.ชลบุรี

*Corresponding author; E-mail address: Ratthaphong.me@eng.buu.ac.th

บทคัดย่อ

ความต้องการใช้ทางพิเศษที่เพิ่มขึ้นได้สร้างความท้าทายสำคัญในการจัดการจราจรและตอบสนองต่อเหตุการณ์ต่าง ๆ อย่างมีประสิทธิภาพ การศึกษานี้มีจุดประสงค์เพื่อพัฒนาแบบจำลองสภาพจราจรแบบทันกาล โดยใช้โปรแกรม Aimsun Live สำหรับโครงข่ายทางพิเศษ ซึ่งดำเนินการในระดับเมโซสโคปิก (Mesoscopic) เพื่อสร้างสมดุลระหว่างความเร็วในการคำนวณ ความแม่นยำในการพยากรณ์ และความสามารถในการขยายขอบเขตในอนาคต แบบจำลองนี้ผสานข้อมูลแบบทันกาลจากอุปกรณ์ตรวจวัดการจราจรต่าง ๆ การจดจำรูปแบบการจราจรด้วยการเรียนรู้ของเครื่อง (Machine learning) และโมดูลการประเมินสถานการณ์เพื่อสนับสนุนการบริหารจัดการจราจรแบบไดนามิก นอกจากนี้ แบบจำลองยังคำนึงถึงปัจจัยสำคัญต่าง ๆ เช่น ข้อจำกัดความเร็ว การกำหนดช่องจราจร การจำกัดประเภทของยานพาหนะ และรูปแบบของด่านเก็บค่าผ่านทาง การพัฒนานี้ช่วยลดผลกระทบจากปัญหาการจราจร เพิ่มความสะดวกสบายให้กับผู้ใช้ทาง และยกระดับการจัดการโครงข่ายทางพิเศษสู่มาตรฐานสากล

คำสำคัญ: แบบจำลองสภาพจราจรแบบทันกาล, การบริหารจัดการจราจรแบบไดนามิก, ปัญหาการติดขัด

Abstract

The increasing demand for expressway usage has created significant challenges in managing traffic flow and responding effectively to incidents in real time. This study focuses on the development and implementation of a real-time traffic simulation model using Aimsun Live for the expressway network. The simulation operates at the mesoscopic level to balance computational efficiency, forecasting accuracy, and scalability for future expansions. The model integrates real-time data from detectors, machine learning-based traffic pattern recognition, and scenario evaluation modules to support dynamic traffic management. The simulation considers critical parameters such as speed limits, lane configurations, vehicle restrictions, and toll plaza layouts. This development reduces the impact of traffic congestion, enhances the convenience for road users, and elevates the management of the expressway network to international standards.

Keywords: Real Time Traffic Simulation, Dynamic Traffic Management, Traffic Congestion

1. ที่มาและความสำคัญ

ปัญหาการจราจรติดขัดเป็นหนึ่งในปัญหาหลักของเมืองใหญ่ทั่วโลก รวมถึงประเทศไทยที่มีการขยายตัวของเมืองอย่างรวดเร็ว [1] ส่งผลให้ปริมาณยานพาหนะบนทางพิเศษเพิ่มขึ้นอย่างต่อเนื่อง ระบบขนส่งสาธารณะและโครงสร้างพื้นฐานด้านคมนาคมจำเป็นต้องพัฒนาให้สอดคล้องกับความต้องการของประชาชน อย่างไรก็ตาม การเพิ่มขยายถนนหรือโครงสร้างพื้นฐานอาจไม่สามารถแก้ไขปัญหาการจราจรได้อย่างมีประสิทธิภาพเพียงพอ [2] จากความต้องการใช้ทางพิเศษที่มีเพิ่มมากขึ้นในปัจจุบัน กทพ. จึงมีแนวคิดในการดำเนินการพัฒนาและปรับปรุงระบบบริหารจัดการจราจรบนทางพิเศษโดยนำเทคโนโลยีอัจฉริยะมาใช้ ทั้งนี้ เพื่อลดความแออัด เพิ่มความสะดวกในการเดินทาง และยกระดับคุณภาพโครงสร้างพื้นฐานด้านคมนาคมของประเทศไทยให้มีประสิทธิภาพ เกิดประโยชน์สูงสุดต่อพนักงานและผู้ใช้ทาง

ปัจจุบันเทคโนโลยีมีบทบาทสำคัญอย่างมากในการบริหารจัดการจราจร โดยสามารถช่วยลดปัญหาการจราจรติดขัดและเพิ่มความปลอดภัยบนท้องถนนได้ เช่น ปัญญาประดิษฐ์ (AI) [3] เป็นต้น และการเรียนรู้ของเครื่อง (Machine Learning) ใช้สำหรับวิเคราะห์ข้อมูลจราจรแบบเรียลไทม์ คาดการณ์ปัญหาการจราจร และปรับปรุงระบบการจัดการจราจรอัตโนมัติ อินเทอร์เน็ตของสรรพสิ่ง (IoT) และเซ็นเซอร์อัจฉริยะ ใช้ในการตรวจจับข้อมูลเกี่ยวกับปริมาณการจราจร ความเร็วของยานพาหนะ และสภาพแวดล้อมการจราจร เพื่อนำมาประมวลผลและปรับปรุงระบบสัญญาณไฟจราจร [4]

อย่างไรก็ตาม การนำข้อมูลแบบเรียลไทม์มาใช้ประโยชน์อย่างเต็มประสิทธิภาพนั้น จำเป็นต้องอาศัยแบบจำลองการจำลองสภาพจราจรที่สามารถรองรับความเปลี่ยนแปลงของข้อมูลได้ทันที ซึ่งแตกต่างจากแนวทางดั้งเดิมที่อิงกับข้อมูลย้อนหลังหรือรูปแบบการจราจรในอดีตที่มีลักษณะคงที่ การพัฒนาแบบจำลองสภาพจราจรแบบทันกาลจึงมีความสำคัญอย่างยิ่ง เพราะสามารถประมวลผลข้อมูลจากหลายแหล่งในเวลาจริง เช่น เซ็นเซอร์ภาคสนาม กล้องวงจรปิด และข้อมูลจากผู้ใช้งาน ช่วยให้การคาดการณ์สภาพจราจรในอนาคตอันใกล้มีความแม่นยำสูง สามารถตอบสนองต่อเหตุการณ์ฉุกเฉินได้รวดเร็ว ลดความล่าช้าในการบริหารจัดการ และเพิ่มประสิทธิภาพในการใช้ทรัพยากรอย่างเหมาะสม อันเป็นการยกระดับระบบบริหารจราจรจากการตอบสนองเชิงรับแบบเดิม ไปสู่การบริหารเชิงรุกที่มีประสิทธิภาพสูงกว่าอย่างชัดเจน

ดังนั้นงานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาการพัฒนาแบบจำลองสภาพจราจรบนทางพิเศษแบบทันกาล (Real Time Traffic Simulation Development on Expressway) ที่สามารถคาดการณ์สภาพจราจรในอนาคตอันใกล้ได้อย่างใกล้เคียงความจริง คาดการณ์สภาพจราจรล่วงหน้าที่เกิดจากเหตุฉุกเฉิน และคาดการณ์สภาพจราจรล่วงหน้าที่เกิดจากความต้องการเดินทางหรือความไม่เพียงพอของความจุถนน เพื่อใช้เป็นเครื่องมือในการบริหารจัดการทางพิเศษให้มีประสิทธิภาพสูงสุด ตอบสนองวิสัยทัศน์ใหม่ของ กทพ. (ปี 2566 - 2570) ที่ว่า “องค์กรนวัตกรรมเพื่อการเดินทางและคุณภาพชีวิตที่ดีขึ้น (Innovation for Better Drive and Better Life)” เพื่อให้ กทพ. ก้าวเข้าสู่องค์กรแห่งนวัตกรรมอย่างยั่งยืนต่อไป

2. ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 ทบทวนวรรณกรรมเกี่ยวกับแบบจำลองสภาพการจราจรแบบทันกาล

2.1.1 แบบจำลองสภาพการจราจร

แบบจำลองสภาพการจราจร (Traffic models) หมายถึง การจำลองสภาพการจราจรบนโครงข่ายถนนที่เกิดขึ้นในโลกความเป็นจริง เพื่อใช้ในการประเมินผลกระทบของสถานการณ์ มาตรการ หรือ นโยบายต่าง ๆ ทั้งในด้านลบและด้านบวกก่อนจะถูกนำไปใช้จริง ดังนั้นการดำเนินการในแบบจำลองการจราจรจึงเป็นทางเลือกที่ทำให้เกิดประโยชน์สูงสุดทั้งในแง่ของผลลัพธ์ที่สามารถใช้ประกอบการตัดสินใจที่ถูกต้องของผู้มีส่วนเกี่ยวข้องและการประหยัดทรัพยากรในการดำเนินการประเมินการจราจรในสภาพแวดล้อมจริง ในรายละเอียดแบบจำลองสภาพการจราจรมีความสำคัญและทำให้เกิดประโยชน์ในด้านต่าง ๆ [5]

2.1.2 นิยามของ Real-time traffic simulation

การจำลองการจราจรแบบทันกาลหรือแบบเรียลไทม์หมายถึงการใช้โมเดลคอมพิวเตอร์ และอัลกอริทึมเพื่อจำลองและทำนายสภาวะการจราจรในเวลาเรียลไทม์หรือใกล้เคียงกับเรียลไทม์ การจำลองเหล่านี้ให้การแสดงผลเกี่ยวกับการไหลของรถจราจร การติดขัด และปัจจัยที่เกี่ยวข้องอื่น ๆ บนโครงข่ายถนนที่สามารถเปลี่ยนไปได้ตลอดเวลา เพื่อให้ผู้ทำงานด้านการขนส่งสามารถตัดสินใจโดยมีข้อมูลและปรับแก้กลยุทธ์การจัดการการจราจรได้อย่างมีประสิทธิภาพ [6] โดยทั่วไปคุณสมบัติสำคัญของการจำลองการจราจรแบบเรียลไทม์ประกอบด้วยด้านต่าง ๆ ดังต่อไปนี้

- การรวมข้อมูล (Data Integration):
- โมเดลสามารถเปลี่ยนแปลงได้ (Dynamic Modeling):
- การจัดการการจราจร (Traffic Management):
- การวิเคราะห์สถานการณ์ (Scenario Analysis):
- การสนับสนุนในการตัดสินใจ (Decision Support):
- การพยากรณ์การจราจร (Traffic Prediction):
- การเผยแพร่ข้อมูลสาธารณะ (Public Information):

โดยสรุป การจำลองการจราจรแบบเรียลไทม์มีบทบาทสำคัญในการจัดการการจราจรติดขัดในเมือง ลดระยะเวลาการเดินทางของผู้ใช้ทาง ส่งเสริมความปลอดภัย และเพิ่มประสิทธิภาพในการขนส่งในภาพรวม ดังนั้นหน่วยงานด้านการขนส่ง (โดยเฉพาะอย่างยิ่งในเขตเมือง) ควรพิจารณานำแบบจำลองประเภทนี้ไปประยุกต์ใช้เพื่อแก้ไข

ปัญหาการจราจรและการเดินทางในยุคปัจจุบัน (Modern urban mobility)

2.2 ทบทวนวรรณกรรมเกี่ยวกับการคาดการณ์สภาพจราจรในอนาคตอันใกล้


2.2.1 นิยามของการคาดการณ์สภาพจราจรในอนาคตอันใกล้

การคาดการณ์สภาพจราจรในอนาคตอันใกล้เป็นความสามารถของแบบจำลองในการทำนายสภาพจราจรได้อย่างถูกต้องภายในขอบเขตความผิดพลาดและช่วงระยะเวลาที่กำหนด ดังนั้นโดยทั่วไปค่าของตัวชี้วัดการจราจรที่ได้จากการคาดการณ์จะมาพร้อมกับค่าความผิดพลาดเสมอ [13] ซึ่งทำให้ความแม่นยำในการคาดการณ์การสภาพการจราจรขึ้นอยู่กับว่าแบบจำลองจะสามารถทำนายส่วนที่ไม่แน่นอน (Uncertainty) ของการจราจรได้มากน้อยเพียงใด ดังแสดงในรูปที่ 1 โดยปกติความไม่แน่นอนของการจราจรนั้นขึ้นอยู่กับหลายปัจจัย เช่น สภาพอากาศ วันของสัปดาห์ อุบัติเหตุ งานก่อสร้างถนน สภาพแสงสว่าง เป็นต้น ดังนั้นปัจจัยเหล่านี้ควรได้รับการพิจารณาในแบบจำลองเพื่อลดความคลาดเคลื่อนในการทำนายและเพิ่มส่วนที่สามารถคาดการณ์ได้ของความไม่แน่นอน นอกจากนี้ความสามารถในการทำนายสภาพการจราจรยังมีความเชื่อมโยงโดยตรงกับระยะเวลาในการทำนาย นั่นคือความแม่นยำในการทำนายจะลดลงเมื่อระยะเวลาในการทำนายเพิ่มขึ้น และการคาดการณ์สภาพการจราจรอาจไม่ได้ผลในกรณีที่รูปแบบการจราจรขณะนั้นมีความแตกต่างอย่างมีนัยสำคัญกับข้อมูลในอดีตที่ผ่านมา [7]

2.2.2 แบบจำลองในการคาดการณ์สภาพจราจร

การจัดกลุ่มแบบจำลองในการคาดการณ์สภาพจราจรที่ถูกใช้ในเมืองอัจฉริยะ (Smart cities) ออกเป็น 3 กลุ่มหลัก คือ Naive models, Parametric models และ Non-parametric models ซึ่งแต่ละกลุ่มมีรายละเอียดดังต่อไปนี้ [9]

1) Naive models เป็นแบบจำลองที่ง่ายที่สุดในการคาดการณ์สภาพการจราจร วิธีนี้ใช้สมมติฐานทางสถิติอย่างง่าย เช่น ค่าเฉลี่ย (Average) และไม่ได้พิจารณาถึงปัจจัยภายนอกอื่น ๆ ที่อาจส่งผลให้เกิดความไม่แน่นอนขึ้น แบบจำลองกลุ่มนี้จึงได้รับความนิยมค่อนข้างมากในการทำงานจริงเนื่องจากเป็นวิธีที่ง่าย ไม่ซับซ้อน



รูปที่ 1 ส่วนประกอบในการคาดการณ์สภาพจราจร [8]

2) Parametric models เป็นแบบจำลองที่ขึ้นอยู่กับชุดข้อมูลที่แน่นอนที่จะนำมาใช้ในการทำนายสภาพการจราจรในอนาคต ข้อดีของแบบจำลองกลุ่มนี้คือจะมีความต้องการของข้อมูลในการประมวลผลที่น้อยกว่าแบบ Non-parametric models แต่ในทางกลับกันนี้อาจเป็นข้อเสียเนื่องจากการใช้ข้อมูลที่มีขอบเขตอาจทำให้ผลการคาดการณ์มีความผิดพลาดมากขึ้น ตัวอย่างแบบจำลองในกลุ่มนี้ได้แก่ Traffic simulation models, Time series models และ Kalman filters

3) Non-parametric models คือวิธีการทางสถิติที่ไม่ต้องสมมติรูปแบบการกระจายตัวของข้อมูลในการประมาณค่า โมเดลเหล่านี้ไม่จำกัดตัวแปรพารามิเตอร์และมีความยืดหยุ่นในการปรับตามข้อมูลโดยไม่ต้องกำหนดข้อจำกัดที่ต่าง ๆ โดยทั่วไปการประมาณค่าแบบ Non-parametric อาจต้องการข้อมูลมากกว่าการแบบ Parametric อย่างไรก็ตามแบบจำลองประเภทนี้จะมีประสิทธิภาพในการทำนายเพิ่มขึ้นเมื่อมีข้อมูลมากขึ้น ดังนั้น Non-parametric models จึงเหมาะสำหรับการจัดการกับข้อมูลที่ไม่แน่นอนและซับซ้อน โดยเฉพาะการพยากรณ์สภาพจราจรในโครงข่ายถนนในเมืองที่มีขนาดใหญ่ อัลกอริทึมที่ได้รับความนิยมในกลุ่มนี้ อาทิเช่น k-nearest neighbor (k-NN) ระบบโครงข่ายประสาทเทียม (Neural networks) และระบบเรียนรู้ของเครื่องจักรและปัญญาประดิษฐ์อื่น ๆ เป็นต้น [10]

ตัวอย่างการนำอัลกอริทึมเหล่านี้ไปใช้ในการคาดการณ์สภาพจราจร เช่น [11] พัฒนาแบบจำลองเพื่อทำนายการไหลของการจราจรในช่วงเวลาระยะสั้นบนทางพิเศษในประเทศจีนโดยใช้วิธี k-NN ซึ่งผลการศึกษาพบว่าวิธีที่พัฒนาขึ้นให้ผลการทำนายที่แม่นยำกว่า 90 % [12] สร้างระบบโครงข่ายประสาทเทียมโดยประยุกต์ใช้ข้อมูลการจราจรในอดีตและแบบเรียลไทม์เข้าด้วยกัน โดยการศึกษาครั้งนี้มุ่งเน้นไปที่การทำนายปริมาณการจราจร (Traffic volume) ใน 2 ช่วง ระยะเวลา คือ ระยะสั้นทุก 15 นาที และระยะกลางทุก 1 ชั่วโมงของวันที่กำหนดตัวแปรที่ถูกพิจารณาในแบบจำลองได้แก่ วันที่ วันในสัปดาห์ วันหยุดฤดูกาล เดือน เทศกาล กิจกรรมต่าง ๆ และ ปี ซึ่งผลการทำนายเหล่านี้มีประโยชน์ในการประยุกต์ใช้งานการจัดการจราจรแบบ Dynamic เช่น การควบคุมสัญญาณไฟจราจร การจัดการจราจรติดขัด และการทำนายระยะเวลาเดินทาง เป็นต้น สุดท้ายเป็นตัวอย่างการประยุกต์ใช้ระบบผสมผสานระหว่าง Online micro-traffic simulation กับ Machine learning (Pattern recognition) เพื่อคาดการณ์สภาพจราจรในอนาคตและบริหารจัดการการจราจรแบบเรียลไทม์โดยโปรแกรม Aimsun วิธีนี้จะทำให้ผู้ใช้งานสามารถนำผลการทำนาย รวมทั้งการประเมินผลกระทบของมาตรการต่าง ๆ ไปประกอบการตัดสินใจแก้ไขปัญหาจราจรได้อย่างมีประสิทธิภาพ อย่างไรก็ตามความสามารถเหล่านี้ก็ต้องแลกมากับความต้องการข้อมูลที่มีความละเอียดมากขึ้นเพื่อเป็น Input ให้แก่ระบบ กรอบแนวคิดของระบบนี้ [13]

2.3 โปรแกรมคอมพิวเตอร์สำหรับการจำลองสภาพจราจรแบบทันกาล และการคาดการณ์สภาพจราจรในอนาคตอันใกล้

โปรแกรมคอมพิวเตอร์สำหรับการจำลองสภาพจราจรแบบทันกาล และการคาดการณ์สภาพจราจรในอนาคตอันใกล้มีข้อดีและข้อจำกัดแตกต่างกันไป FreeSim ถือเป็นแบบจำลองยุคเริ่มต้นที่ได้มีการนำแนวคิดการจำลองสภาพจราจรแบบทันกาลมาใช้ อย่างไรก็ตามรูปแบบแบบจำลองยังเน้นไปที่ระดับ Macroscopic และในเรื่องของความต่อเนื่องในการพัฒนาและการเข้าถึงการใช้งานอาจยังทำได้ยากกว่าโปรแกรมอื่น ๆ [14] ถัดมาคือโปรแกรม SUMO ที่เป็น Open-source simulation เป็นโปรแกรมฟรีที่สามารถเข้าถึงได้ง่าย สร้างแบบจำลองได้ถึงระดับ Microscopic and continuous multi-modal traffic simulation และรองรับโครงข่ายถนนขนาดใหญ่ ในส่วนของข้อจำกัดเนื่องจากโปรแกรมนี้อยู่ในรูปแบบ Open-source ดังนั้นบางฟังก์ชันถ้าต้องการใช้งานอาจต้องอาศัยการเขียนโค้ดเพิ่มเข้าไปซึ่งอาจมีความยากในการใช้งานเพิ่มขึ้นเล็กน้อย [15]

ถัดมาเป็นโปรแกรม PTV Flows และ Aimsun Predict ทั้งสองโปรแกรมมีลักษณะคล้ายคลึงกันมากซึ่งอยู่ในกลุ่มของ Web-based application ที่สามารถใช้ในการติดตาม แสดงผลสภาพจราจรปัจจุบัน และทำนายสภาพจราจรในอนาคตอันใกล้ได้ โปรแกรม PTV Flows มีข้อดีตรงที่สามารถใช้ข้อมูลการจราจรจากภายนอก (TomTom) โดยไม่ต้องพึ่งพาอุปกรณ์ต่าง ๆ บนสายทาง [16] อย่างไรก็ตามเรื่องความแม่นยำอาจไม่เท่ากับการใช้ข้อมูลที่ได้จากอุปกรณ์ตรวจวัดบนสายทางโดยตรงอย่างใน Aimsun Predict แต่อาจจะต้องแลกมาด้วยค่าใช้จ่ายที่เพิ่มขึ้น [17]

สุดท้ายคือโปรแกรมด้านการบริหารจัดการการจราจรแบบทันกาล และการคาดการณ์สภาพจราจรในอนาคตอันใกล้แบบเต็มรูปแบบ คือ PTV Optima และ Aimsun Live ทั้งสองโปรแกรมมีฟังก์ชันในการใช้งานความคล้ายคลึงกันมาก เช่น ในเรื่องของจัดการข้อมูล การแสดงผลสภาพการจราจร การจำลองและประเมินสถานการณ์ในระดับ Microscopic และระบบการแจ้งเตือนผู้ใช้งาน เป็นต้น [18,19] อย่างไรก็ตามในการศึกษาครั้งนี้ผู้วิจัยเลือกใช้โปรแกรม Aimsun Live ที่สามารถใช้ฟังก์ชันของโปรแกรม Offline simulation (Aimsun Next) ได้อย่างเต็มรูปแบบ เช่น การจำลองพฤติกรรมของยานพาหนะแบบคันต่อคัน และเป็น Lane-based simulation นอกจากนี้โปรแกรม Aimsun Live ยังมีความสามารถในการจำลองโครงข่ายถนนในทุกระดับชั้นของแบบจำลอง (Integrated all-in-one application) และยังสามารถสร้างแบบจำลองแบบ Hybrid micro-mesoscopic simulation ซึ่งเป็นข้อดีที่ทำให้แบบจำลองประมวลผลได้เร็วขึ้น เป็นต้น

2.4 การตรวจสอบความถูกต้อง

การตรวจสอบความถูกต้องนี้จะบ่งบอกความแม่นยำในการคาดการณ์การไหลของการจราจรในอนาคตและสามารถนำไปใช้ใน Aimsun Live ได้อย่างเหมาะสม โดยการตรวจสอบจะใช้ค่าทางสถิติ GEH ซึ่งเป็นสูตรเชิงประจักษ์ และเป็นตัวชี้วัดทั่วไปในการตรวจสอบความถูกต้องของปริมาณจราจรในการพัฒนาแบบจำลอง โดย GEH static มีสมการดัง (1)

$$GEH = \sqrt{\frac{2(M - C)^2}{M + C}} \quad (1)$$

โดยที่ M คือปริมาณจราจรต่อชั่วโมงที่ได้จากการจำลอง

C คือปริมาณจราจรต่อชั่วโมงที่ได้จากการสำรวจจริง

GEH ที่มีค่าน้อยจะบ่งบอกถึงความถูกต้องของแบบจำลอง

3. การพัฒนาแบบจำลอง


3.1 พื้นที่ศึกษา

การพัฒนาแบบจำลองครอบคลุม 3 เส้นทาง ได้แก่ ทางพิเศษเฉลิมมหานคร ทางพิเศษฉลองรัช และ ทางพิเศษสายทางศรีรัช เส้นทางทางเลือก ซึ่งการสร้างแบบจำลองนั้น เริ่มจากการกำหนดขอบเขตของโครงข่าย (A - G) โดยที่แต่ละจุดจะถูกพิจารณาเป็นพื้นที่ Generation and Attraction ของกระแสจราจร นอกจากจุด A ที่มีการพิจารณาตำแหน่ง Generation and Attraction แยกกันเป็น A_{in} และ A_{out} จากนั้นจะเป็นการขึ้นรูปแบบจำลองตามข้อมูลโครงข่ายถนนที่ได้รับแบบออฟไลน์ในโปรแกรม Aimsun Next ซึ่งจะสามารถเชื่อมต่อไปยัง Aimsun Live ดังแสดงในรูปที่ 2 นอกจากนี้แบบจำลองยังครอบคลุม


เส้นทางทางเลือก 10 เส้นทาง (ไป-กลับ) ที่ขนานกับทางพิเศษสายหลัก เพื่อรองรับการเบี่ยงจราจรในกรณีที่เกิดเหตุการณ์บนทางพิเศษ ดังแสดงในรูปที่ 3

3.2 ขั้นตอนการสร้างแบบจำลอง Aimsun Live

โปรแกรม Aimsun Live ถูกนำมาประยุกต์ใช้ในการพัฒนาแบบจำลองสภาพจราจรบนทางพิเศษแบบทันกาล เพื่อรายงานผลสภาพจราจรในช่วงเวลาต่าง ๆ แบบอัตโนมัติ รวมถึงทำนายสภาพจราจรที่จะเกิดขึ้นในอนาคตอันใกล้ เป็นประโยชน์ในการวางแผนและวิเคราะห์กลยุทธ์ต่าง ๆ ในการเพิ่มประสิทธิภาพหรือแก้ไขสถานการณ์ที่อาจเกิดขึ้นบนทางพิเศษ ขั้นตอนการสร้างแบบจำลองโดยสรุปมีดังนี้ ขั้นตอนแรกคือ การนำเข้าลักษณะทางเรขาคณิต (Geometry) ของทางพิเศษ และรวมเข้ากับลักษณะทางเรขาคณิตของ ถนนระดับพื้นดินจาก OpenStreetmap เพื่อพัฒนาโครงข่ายถนนในแบบจำลอง



รูปที่ 2 แผนที่ขอบเขตของโครงข่ายในแบบจำลอง



รูปที่ 3 แผนที่ขอบเขตของโครงข่ายในแบบจำลอง

จากนั้นลักษณะทางเรขาคณิตของถนนจะถูก ตรวจสอบ และแก้ไข การเชื่อมต่อในจุดที่มีข้อผิดพลาดหรือขาดหายไป จำนวนช่องจราจรที่ไม่ถูกต้อง และข้อผิดพลาดอื่น ๆ เป็นต้น ขั้นตอนถัดไปคือการเพิ่มข้อมูลตำแหน่งของ ด่านเก็บค่าผ่านทางและเซ็นเซอร์จราจร ทั้งหมดลงใน

แบบจำลอง ลำดับต่อมาคือการระบุและตั้งค่าจุดต้นทาง และปลายทาง (Origins and Destinations Zones หรือ Centroids) ซึ่งทำหน้าที่เป็นจุดที่การจราจรสามารถเข้าสู่และออกจากแบบ จำลองได้


จากนั้นจึงมีการตั้งค่าแบบจำลองเบื้องต้น และเพิ่มข้อมูลสำคัญต่าง ๆ เช่น ข้อจำกัด ความเร็ว ประเภทของถนน ความจุของถนน ประเภทของยานพาหนะ และสัดส่วนของยาน พาหนะบนทางพิเศษ ตำแหน่งการใช้ไหล่ทาง บนทางพิเศษ เป็นต้น

3.3 การพัฒนาระบบฐานข้อมูลจราจรสำหรับแบบจำลอง

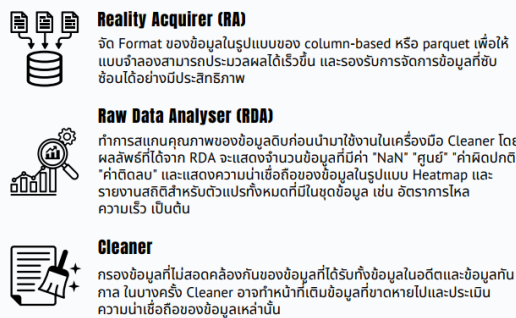
สถาปัตยกรรมของระบบฐานข้อมูลสำหรับแบบจำลอง ดังแสดงในรูปที่ 4 โดยข้อมูลที่สำคัญในการพัฒนาแบบจำลองแบบทันกาลและการคาดการณ์สภาพจราจรในอนาคตอันใกล้สามารถแบ่งได้เป็น 2 กลุ่ม ได้แก่ ข้อมูลการจราจรแบบออฟไลน์ (Offline data): ข้อมูลโครงข่ายถนน ข้อมูลเกี่ยวกับสัญญาณไฟจราจร ถนน ทางแยก และข้อมูลการจราจรในอดีต เช่น ปริมาณจราจร ข้อมูลจุดต้นทางปลายทาง ข้อมูลความเร็ว ข้อมูลอุบัติเหตุ เป็นต้น และข้อมูลแบบเรียลไทม์ (Real time data): ข้อมูลปริมาณจราจรแยกตามประเภทยานพาหนะ ข้อมูลความเร็วของรถบนสายทาง และข้อมูลการเกิดอุบัติเหตุและวิธีการแก้ไข

งานวิจัยนี้พัฒนาระบบเชื่อมต่อและรวบรวมข้อมูลของ กทพ. ทั้งฐานข้อมูลเก่าและใหม่ เพื่อให้สามารถนำข้อมูลทั้งแบบออฟไลน์และเรียลไทม์ มาผสมผสานใช้งานได้ การนำเข้าข้อมูลแบบออฟไลน์จะเพิ่มประสิทธิภาพในขั้นตอนการสร้างแบบจำลองและการวิเคราะห์รูปแบบการไหลของการจราจรได้อย่างแม่นยำ ในส่วนของข้อมูลแบบเรียลไทม์ ข้อมูลจากเซ็นเซอร์จะถูกส่งเข้ามาในระบบทุก 2 นาที ในขณะที่ข้อมูลจากด่านเก็บค่าผ่านทางจะถูกนำเข้ามาในช่วงเวลาทุก 5 นาทีและผ่านกระบวนการดังแสดงในรูปที่ 5

ระบบ Reality Acquirer (RA) มีหน้าที่จัด Format ของข้อมูลในรูปแบบของ column-based หรือ parquet เพื่อให้แบบจำลองสามารถประมวลผลได้เร็วขึ้น และรองรับการจัดการข้อมูลที่ซับซ้อนได้อย่างมีประสิทธิภาพ หลังจากนั้น Aimsun Live จะมีระบบ Raw Data Analyser (RDA) ที่จะทำการสแกนคุณภาพของข้อมูลดิบก่อนนำมาใช้งานในเครื่องมือ Cleaner โดยผลลัพธ์ที่ได้จาก RDA จะแสดงจำนวนข้อมูลที่มีค่า "NaN" "ศูนย์" "ค่าผิดปกติ" "ค่าติดลบ" และแสดงความน่าเชื่อถือของข้อมูลในรูปแบบ Heatmap และรายงานสถิติสำหรับตัวแปรทั้งหมดที่มีในชุดข้อมูล เช่น อัตราการไหล ความเร็ว เป็นต้น ระบบสุดท้าย คือ Cleaner มีวัตถุประสงค์หลักคือกรองข้อมูลที่ไม่สอดคล้องกันของข้อมูลที่ได้รับทั้งข้อมูลในอดีตและข้อมูลทันกาล ในบางครั้ง Cleaner อาจทำหน้าที่เดิมข้อมูลที่ขาดหายไปและประเมินความน่าเชื่อถือของข้อมูลเหล่านั้น การกรองและการเติมข้อมูลขึ้นอยู่กับคุณภาพของข้อมูลที่ได้รับ การเปิดและปิดการทำงานของ Cleaner สามารถทำได้ตลอดเวลาหากผู้ควบคุมระบบต้องการ



รูปที่ 4 Data Flow Architecture



รูปที่ 5 กระบวนการในขณะที่ยังข้อมูลจากด้านเก็บค่าผ่านทางจะถูกนำเข้า

3.4 การเปรียบเทียบแบบจำลอง

การเปรียบเทียบแบบจำลอง Static ใช้ชุดข้อมูลปริมาณจราจร 24 ชั่วโมงของวันปกติในการเปรียบเทียบ ข้อมูลเมทริกซ์จุดต้นทางและปลายทาง (O-D Matrix) ในเดือนสิงหาคม กันยายน และตุลาคม พ.ศ. 2566 ถูกใช้เป็นข้อมูลต้นฉบับในการพัฒนาชุดเมทริกซ์ของปริมาณจราจร

3.4.1 Static Model Results

ในรายละเอียดข้อมูล O-D matrix สามารถแบ่งออกเป็น 5 ช่วงเวลา ตลอด 24 ชั่วโมงของวัน ได้แก่ 00.00 น. – 06.00 น./ 06.00 น. – 10.00 น./10.00 น. – 15.00 น./ 15.00 น. – 19.00 น./ 19.00 น. – 00.00 น. ซึ่งบ่งบอกถึงช่วงเวลาการจราจรหนาแน่นและช่วงเวลาการจราจรเบาบางบนโครงข่ายทางพิเศษ ช่วงเวลาเหล่านี้ได้รับการพิจารณาในการเปรียบเทียบและตรวจสอบความถูกต้องของแบบจำลอง

การตรวจสอบความถูกต้องนี้จะบ่งบอกความแม่นยำในการคาดการณ์การไหลของการจราจรในอนาคต และสามารถนำไปใช้ใน Aimsun Live ได้อย่างเหมาะสม โดยการตรวจสอบจะใช้ค่าสถิติ GEH โดยเป้าหมายคือ การคาดการณ์ปริมาณจราจรให้มีค่า GEH ต่ำกว่า 5 ใน 85% ของกรณี และค่า GEH ต่ำกว่า 10 ใน 55% ของกรณี ดังตารางที่ 1 ผลการเปรียบเทียบพบว่าแบบจำลอง Static ในทุกช่วงเวลาให้ค่าใกล้เคียงกับเกณฑ์ GEH ที่กำหนด ซึ่งบ่งชี้ว่าแบบจำลอง Static สามารถใช้เป็นตัวแทนที่ใกล้เคียงกับการเลือกเส้นทางในระดับมหภาค และพฤติกรรมของการไหลของการจราจรบนทางพิเศษทั้งสามสายทางได้เป็นอย่างดี

ตารางที่ 1 ผลการเปรียบเทียบค่า GEH ในแบบจำลอง Static

Time period	GEH < 5	GEH < 10
Pre AM (12am - 6am)	100.00%	100.00%
AM (6am - 10am)	85.23%	94.32%
Interpeak (10am - 3pm)	96.59%	100.00%
PM (3pm - 7pm)	98.86%	100.00%
Post PM (7pm - 12am)	94.32%	96.59%

3.4.2 Dynamic Model Results

การใช้งานแบบจำลองสภาพจราจรแบบทันกาลจำเป็นต้องมีการจำลอง Dynamic ในระดับ Mesoscopic ที่ได้รับการปรับเทียบและตรวจสอบความถูกต้อง แบบจำลอง Dynamic จะจำลองพฤติกรรมและการโต้ตอบระหว่างยานพาหนะช่วยให้สามารถทำนายสภาพการจราจรในระบบ Aimsun Live ได้อย่างมีประสิทธิภาพ โดยทั่วไปเป้าหมายในการตรวจสอบความถูกต้องของแบบจำลอง Mesoscopic คือ การคาดการณ์การไหลของการจราจรที่มีค่า GEH ต่ำกว่า 5 ใน 75% ของกรณี และต่ำกว่า 10 ใน 90% ของกรณี ดังแสดงไว้ในตารางที่ 2

ตารางที่ 2 การเปรียบเทียบค่า GEH ของแบบจำลอง Dynamic ในระดับ Mesoscopic

Time period	Hour	GEH < 5	GEH < 10
Pre AM (12am - 6am)	00:00 - 01:00	100.00%	100.00%
	01:00 - 02:00	100.00%	100.00%
	02:00 - 03:00	100.00%	100.00%
	03:00 - 04:00	100.00%	100.00%
	04:00 - 05:00	100.00%	100.00%
AM (6am - 10am)	05:00 - 06:00	98.86%	100.00%
	06:00 - 07:00	92.05%	96.59%
	07:00 - 08:00	85.23%	89.77%
	08:00 - 09:00	82.95%	96.59%
	09:00 - 10:00	90.91%	95.45%
Interpeak (10am - 3pm)	10:00 - 11:00	97.73%	98.86%
	11:00 - 12:00	97.73%	98.86%
	12:00 - 13:00	97.73%	97.73%
	13:00 - 14:00	96.59%	98.86%
	14:00 - 15:00	96.59%	98.86%
PM (3pm - 7pm)	15:00 - 16:00	88.64%	96.59%
	16:00 - 17:00	93.18%	96.59%
	17:00 - 18:00	94.32%	97.73%
	18:00 - 19:00	93.18%	97.73%
Post PM (7pm - 12am)	19:00 - 20:00	92.05%	94.32%
	20:00 - 21:00	89.77%	95.45%


Time period	Hour	GEH < 5	GEH < 10
	21:00 - 22:00	95.45%	95.45%
	22:00 - 23:00	93.18%	95.45%
	23:00 - 24:00	94.32%	95.45%

3.5 การคาดการณ์สภาพจราจรในอนาคตอันใกล้


หลังจากการรวบรวมข้อมูลในอดีต (Historical data) ทั้งหมดย้อนหลัง 1 ปี จากระบบฐานข้อมูลของทาง กทพ. ข้อมูลทั้งหมดถูกนำมาผ่านกระบวนการทำความสะอาด (Cleaning) และกรองข้อมูล (Filtering) จากนั้นจะได้ชุดฐานข้อมูลชุดใหม่ ซึ่งเป็นฐานข้อมูลที่ "สะอาด" (Cleaned historical data) ฐานข้อมูลใหม่นี้ถูกใช้สำหรับขั้นตอนการฝึกแบบจำลอง (Model training)

จากการวิเคราะห์ข้อมูลของเซ็นเซอร์จราจรและด่านเก็บค่าผ่านทางสามารถระบุรูปแบบการจราจรบนโครงข่ายทางพิเศษได้จำนวน 20 รูปแบบ โดยได้สร้าง "ชุดข้อมูลจริง" (Real Data Sets) สำหรับแต่ละรูปแบบการจราจร ซึ่งแสดงถึงการไหลของการจราจรที่เกิดขึ้นทั่วไปในแต่ละด่านเก็บค่าผ่านทางและเซ็นเซอร์จราจรตลอด 24 ชั่วโมง รูปแบบการจราจรประจำวันบนทางพิเศษแสดงดังในรูปที่ 6 และสัดส่วนของแต่ละรูปแบบการจราจรแยกตามวัน โดยอิงจากการวิเคราะห์ชุดข้อมูลในอดีต ดังแสดงในรูปที่ 7


ในรายละเอียด Pattern Matcher ใน Aimsun Live จะทำการเปรียบเทียบปริมาณการจราจรล่าสุดของแต่ละ Detector กับรูปแบบการจราจรประจำวันเตรียมไว้ล่วงหน้า หลังจากกระบวนการแรกแล้วเสร็จ ข้อมูลรูปแบบการจราจรจะถูกส่งต่อไปยัง 2 โมดูลหลัก คือ Aimsun Live Predictive Module (APM) และ Response Plans Evaluation Module (RPEM) สำหรับในส่วนแรก APM ประกอบไปด้วย 2 โมเดลย่อย คือ Analytical Prediction Model และ Simulation-based Forecasting Model โมเดลแรกคือโมเดลทางคณิตศาสตร์ที่ขึ้นตรงต่อข้อมูลในอดีตและข้อมูลแบบทันกาลเพื่อทำนายการไหลของการจราจรทุก ๆ 5 นาที ในช่วง 15, 30, 45 และ 60 นาที ส่วนโมเดลที่สองจะรับทุก ๆ 5 นาที ขึ้นอยู่กับข้อมูลความต้องการการเดินทางจาก Pattern Matcher เพื่อทำนายการไหลของการจราจรในเวลา 1 ชม. ข้างหน้า (+15, +30, +45 และ +60 นาที) ดังแสดงในรูปที่ 8 ดังนั้น การจำลองโดยใช้ข้อมูลเรียลไทม์จึงมีความสำคัญอย่างมากในความถูกต้องของผลลัพธ์ของแบบจำลอง



รูปที่ 6 รูปแบบการจราจร (Traffic pattern) บนทางพิเศษ



รูปที่ 7 สัดส่วนของแต่ละรูปแบบการจราจรแยกตามวัน




รูปที่ 8 ตัวอย่างผลการคาดการณ์ในแต่ละช่วงเวลา สำหรับเซ็นเซอร์ ITS-SS20

4. ตัวอย่างการใช้งานแบบจำลอง

แบบจำลองที่พัฒนาขึ้นมีโหมดการทำงาน 3 โหมด ได้แก่ การตรวจสอบและการติดตาม การวิเคราะห์ และการจัดการอุบัติการณ์ ซึ่งแต่ละโหมดมีหน้าที่ที่แตกต่างกันดังนี้


4.1 การตรวจสอบและการติดตาม (Monitor Mode)

โหมดแรกเป็นโหมดที่ใช้สำหรับตรวจสอบสถานะปัจจุบันของโครงข่ายและการเปลี่ยนแปลงในระยะสั้น เพื่อเข้าใจว่ามีเหตุการณ์ใดที่อาจต้องให้ความสนใจหรือการแทรกแซงจากผู้ปฏิบัติงานหรือไม่ เนื่องจากเป็นสถานะที่ผู้ใช้งานจะใช้เวลาอยู่ในโหมดนี้เป็นส่วนใหญ่ จึงเป็นโหมดเริ่มต้นที่ถูกเปิดใช้งานเมื่อเข้าสู่ระบบ ดังแสดงในรูปที่ 9



รูปที่ 9 การตรวจสอบและการติดตาม (Monitor Mode)

อุปกรณ์ตรวจวัดเซ็นเซอร์ ตัวเลื่อนการคาดการณ์ (Prediction slider) ที่ด้านบนของหน้าจอจะช่วยให้เข้าถึงสถานะที่คาดการณ์ไว้ที่ T+15, T+30, T+45 และ T+60 นาทีจากเวลา ณ ขณะนั้น (T) ระบบจะแสดงทั้ง สถานะปกติ และ สถานะผิดปกติ อย่างต่อเนื่องและอัตโนมัติผ่าน Time Series Viewer เมื่อเลือกสถานีตรวจจับเซ็นเซอร์ หน้าต่าง Time Series Viewer จะปรากฏขึ้นเพื่อแสดงข้อมูลดังแสดงในรูปที่ 10




รูปที่ 10 การติดตามและคาดการณ์การจราจรแบบเรียลไทม์

ผู้ใช้งานยังสามารถตรวจสอบได้ว่าข้อมูลจริง (Real data) ถูกอ่านโดยระบบหรือไม่ รูปแบบ (Patterns) ที่ใช้แสดงสภาพที่สังเกตเห็นนั้นตรงตามความเป็นจริงหรือไม่ และคุณภาพของการคาดการณ์ (Quality of the prediction) ซึ่งจะแสดงโดยเปอร์เซ็นต์ของตำแหน่งที่มีค่า GEH ต่ำกว่า 5 นอกจากนี้ยังมีตัวเลือกในการแสดงผลข้อมูล เช่น Heatmaps ตาราง และ กราฟ เพื่อให้ผู้ใช้งานสามารถเลือกดูข้อมูลได้ตามความต้องการ ดังแสดงในรูปที่ 11 แสดงตัวอย่าง Heatmap ที่แสดงคุณภาพของข้อมูลการไหลจากเซ็นเซอร์ โดยเปรียบเทียบระหว่างการพยากรณ์แบบเชิงวิเคราะห์ (Analytical Prediction) กับข้อมูลจริง โดยจะเห็นว่าการจราจรช่วงวันที่ 20-27 มิถุนายน 2567 แบบจำลองสามารถทำนายการจราจรล่วงหน้า 1 ชั่วโมง ใน Interval 15 นาที ได้ถูกต้องเกิน 85% เมื่อเทียบกับข้อมูลจริงของอุปกรณ์ตรวจวัดการจราจรในตำแหน่งต่าง ๆ อย่างไรก็ตามอาจมีบางช่วงเวลาที่ทำนายโดยวิธี Analytical Prediction (สีส้มแดงในรูปที่ 11) อาจมีความแม่นยำน้อย ซึ่งอาจเนื่องมาจากการที่สภาพจราจรในเวลานั้นไม่ได้เกิดในรูปแบบเกิดซ้ำ ดังนั้นผู้ใช้งานจึงจำเป็นต้องตรวจสอบผลลัพธ์การทำนายและทำการเปรียบเทียบกับผลด้วยวิธี Simulation เพื่อนำไปใช้ในสถานการณ์ต่าง ๆ อย่างเหมาะสม



รูปที่ 11 การแสดงผลคุณภาพของการคาดการณ์ Quality Manager


สถานการณ์การจราจรผิดปกติ (เช่น การลดลงอย่างรวดเร็วของการไหลและความเร็ว) จะถูกตรวจจับโดย Incident Detection Module (IDM) ในระบบ Aimsun Live เมื่อเหตุการณ์เหล่านี้เกิดขึ้น ไอคอนแจ้งเตือนจะปรากฏบนแผนที่ในโหมด Monitor และปุ่ม "Events Detected" จะแสดงในเมนูด้านซ้ายดังที่แสดงในรูปที่ 12 เพื่อดึงดูดความสนใจของผู้ควบคุมให้ตรวจสอบและยืนยันสาเหตุของสถานการณ์ผิดปกติ



รูปที่ 12 ตัวอย่างการตรวจจับสถานการณ์การจราจรผิดปกติ

4.2 การวิเคราะห์ (Analyse Mode)

โหมดการวิเคราะห์ใช้สำหรับการเข้าถึงข้อมูลและการคำนวณทั้งในปัจจุบันและอดีตอย่างละเอียด นอกจากนี้ยังเป็นพื้นที่สำหรับเข้าถึงเพื่อบันทึกเหตุการณ์ที่ตรวจพบ (Event Logs) และรายงานประจำวัน (Daily Reports) ดังแสดงในรูปที่ 13



รูปที่ 13 โหมด Analyze

4.3 การจัดการ (Manage Mode)

โหมดการจัดการใช้เพื่อเพิ่มเหตุการณ์ที่ระบบไม่ได้รับอัตโนมัติ และใช้เพื่อออกแบบและทดสอบแผนการตอบสนองสำหรับเหตุการณ์ที่เกิดขึ้นในปัจจุบัน เช่น อุบัติเหตุ เป็นต้น แสดงในรูปที่ 14




รูปที่ 14 Manage mode

ผู้ใช้งานสามารถใช้โหมดนี้ในการประเมินผลกระทบของอุบัติเหตุหรืออุบัติเหตุที่เกิดขึ้นบนทางพิเศษและสามารถจำลองการจราจรต่าง ๆ เพื่อแก้ไข บรรเทาสถานการณ์ที่เกิดขึ้นได้ สามารถสรุปได้เป็น 4 ขั้นตอน ได้แก่

4.3.1 การสร้างเหตุการณ์ใหม่ (Creating new event)

ผู้ใช้งานสามารถสร้างเหตุการณ์ (หรือ อุบัติการณ์) ใน UI ของ Aimsun Live โดยการคลิกที่แท็บเหตุการณ์ (Event tab) แสดงในรูปที่ 15




รูปที่ 15 การสร้างเหตุการณ์ (อุบัติเหตุหรืออุบัติเหตุ)

รูปที่ 16

4.3.2 การสร้างการดำเนินการ (Creating an action)

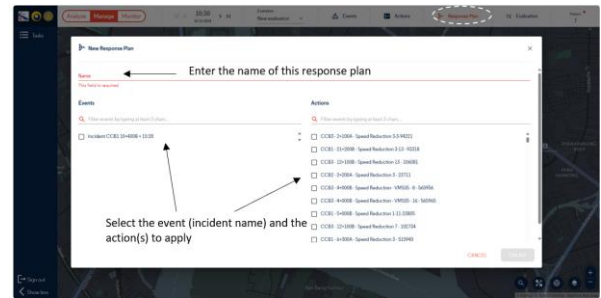
เมื่อคลิกเลือกที่แท็บการดำเนินการ (Action tab) ผู้ใช้จะเข้าสู่หน้าจอที่ให้กรอกข้อมูลการดำเนินการที่ผู้ใช้งานต้องการที่จะดำเนินการ การเพื่อที่จะจัดการกับเหตุการณ์หรืออุบัติเหตุที่เกิดขึ้น แสดงในรูปที่ 16



รูปที่ 17 การสร้างการดำเนินการเบี่ยงเส้นทาง (Creating a rerouting action)

4.3.3 การสร้างและเลือกแผนตอบสนอง (Creating and selecting response plans)


เมื่อคลิกเลือกที่แผนตอบสนอง (Response plan tab) ผู้ใช้งานสามารถเลือกเหตุการณ์และการดำเนินการที่เกี่ยวข้อง (Corresponding actions) ที่ได้สร้างไว้ก่อนหน้านี้โดยการกรอกชื่อของแผนตอบสนอง เพื่อใช้ในการประเมินผลและการจำลองในลำดับถัดไป แสดงในรูปที่ 17



รูปที่ 18 การสร้างแผนตอบสนอง (Creating a response plan)

4.3.4 การประเมินผล (Creating new evaluation)

ผู้ใช้งานสามารถเลือกแผนตอบสนอง (Response Plan) ที่เกี่ยวข้องจากรายการแบบเลื่อนลง (Drop-Down List) เพื่อเริ่มการประเมินและ ผู้ใช้งานสามารถสร้างไอคอน KPIs เพื่อแสดงผลของตัวชี้วัดประสิทธิภาพได้ทั้งในระดับภาพรวม (Global) หรือในระดับเฉพาะจุด (Local) ซึ่งช่วยให้ผู้ปฏิบัติงานสามารถเปรียบเทียบผลกระทบของแต่ละแผนตอบสนอง เพื่อสนับสนุนการตัดสินใจในการจัดการจราจรอย่างมีประสิทธิภาพ แสดงในรูปที่ 18




รูปที่ 19 ผลการประเมินผลแผนตอบสนอง

4.3.5 ตัวชี้วัดประสิทธิภาพการจราจร

ตัวชี้วัดประสิทธิภาพแบบภาพรวม (Global KPIs) ถูกใช้เพื่อสะท้อนสภาพการจราจรในโครงข่ายทั้งหมด ได้แก่ 1) ตัวชี้วัดการติดขัด (Congestion Indicator) วิเคราะห์จากค่าความหนาแน่นที่ตรวจวัดได้ในแต่ละช่วงเวลา 15 นาที (เฉพาะช่วงถนน (Sections) ที่มีการติดตั้งอุปกรณ์ตรวจวัด (detectors)) โดยสามารถคำนวณได้เมื่อการจำลองทั้งหมดเสร็จสิ้น 2) ความคล่องตัวภาพรวมบนโครงข่าย (Global fluidity) แสดงค่าความล่าช้าในภาพรวมของโครงข่ายโดยความล่าช้า (Delay) คือ ความแตกต่างระหว่างเวลาการเดินทางในแบบจำลอง ซึ่งสามารถคำนวณได้เมื่อการจำลองทั้งหมดเสร็จสมบูรณ์

ในขณะที่ Local KPIs มุ่งเน้นไปที่พื้นที่ที่ได้รับผลกระทบจากเหตุการณ์ (Incident) และแผนตอบสนอง (Response Plans) ที่เกี่ยวข้อง ได้แก่ 1) Total Travel (Journey) Time: วัดเวลารวมที่ยานพาหนะใช้ในการเดินทางบนส่วนถนนที่กำหนดไว้ล่วงหน้า ช่วยประเมินประสิทธิภาพของการไหลของการจราจรและระบุจุดที่อาจเกิดความหนาแน่น และ 2) Average Speed: วัดความเร็วเฉลี่ยบนส่วนถนนที่กำหนดไว้ล่วงหน้า เป็นตัวบ่งชี้สำคัญถึงประสิทธิภาพของการจราจรในพื้นที่เฉพาะที่สามารถเคลื่อนตัวได้อย่างราบรื่นหรือเกิดความล่าช้า ส่วนถนนสำหรับ Local KPIs และชื่อที่เกี่ยวข้องถูกกำหนดขึ้นดังแสดงในรูปที่ 19



รูปที่ 20 ชื่อและตำแหน่งของ Local KPIs

5. สรุปผลการศึกษา

ผลการศึกษาการพัฒนาแบบจำลองสภาพจราจรแบบทันกาลบนทางพิเศษโดยใช้โปรแกรม Aimsun Live พบว่าแบบจำลองที่พัฒนาขึ้นสามารถจำลองและคาดการณ์สภาพจราจรได้อย่างแม่นยำและมีประสิทธิภาพสูง โดยพัฒนาในระดับเมซโอสโคปเพื่อสร้างสมดุลระหว่างความเร็วในการประมวลผล ความแม่นยำในการคาดการณ์ และความสามารถในการขยายขอบเขตในอนาคต แบบจำลองผสมข้อมูลจราจรแบบเรียลไทม์จากเซ็นเซอร์บนทางพิเศษร่วมกับข้อมูลจราจรในอดีต การเรียนรู้ของเครื่อง (Machine Learning) และโมดูลการประเมินสถานการณ์ (Scenario Evaluation Module) เพื่อนำไปสู่การบริหารจัดการจราจรแบบไดนามิก (Dynamic Traffic Management) ที่สามารถตอบสนองต่อสถานการณ์ที่เกิดขึ้นได้อย่างทันท่วงที การเปรียบเทียบแบบจำลองทั้งแบบ Static และ Dynamic ให้ผลลัพธ์ที่สอดคล้องกับเกณฑ์ GEH ที่ยอมรับได้ในระดับสูง ซึ่งให้เห็นว่าแบบจำลองสามารถใช้แทนพฤติกรรมจราจรจริงบนทางพิเศษทั้งสามสายทาง ได้แก่ ทางพิเศษเฉลิมมหานคร ทางพิเศษฉลองรัช และทางพิเศษศรีรัช ได้อย่างมีประสิทธิภาพ นอกจากนี้ยังสามารถใช้งานในโหมดต่าง ๆ เช่น โหมดตรวจสอบ โหมดวิเคราะห์ และโหมดจัดการเหตุการณ์ เพื่อช่วยให้ผู้ปฏิบัติงานสามารถติดตามสถานการณ์จริง คาดการณ์ปัญหาที่จะเกิดขึ้น และวางแผนตอบสนองต่อเหตุการณ์ได้อย่างแม่นยำและเป็นระบบ ช่วยเพิ่มความคล่องตัวในการเดินทาง ลดปัญหาความแออัด และยกระดับระบบการบริหารจัดการโครงข่ายทางพิเศษของประเทศไทยให้ก้าวสู่มาตรฐานระดับสากลอย่างยั่งยืน

กิตติกรรมประกาศ

ผู้วิจัยขอขอบคุณพนักงานและลูกจ้างทางพิเศษแห่งประเทศไทย ผู้เชี่ยวชาญสาขาต่าง ๆ และผู้ที่มีส่วนเกี่ยวข้องในการพัฒนาแบบจำลองสภาพจราจรบนทางพิเศษแบบทันกาล (Real Time Traffic Simulation Development on Expressway) รวมถึงการให้ข้อมูลอำนวยความสะดวก และให้ความช่วยเหลือในงานวิจัยครั้งนี้

เอกสารอ้างอิง

- [1] สปร. และ บ.ดิวันโอวัน เปอร์เซ็นต์ จำกัด (2558). การขยายตัวของความเป็นเมือง (Urbanization). รายงานผลการสำรวจและศึกษาวิจัย ซีรีส์ความรู้ ส่อง โอกาส สร้าง อาชีพ เรือง.

- [2] Duranton, G., & Turner, M. A. (2011). The Fundamental Law of Road Congestion: Evidence from US cities. *American Economic Review*, 101(6), 2616-2652.
- [3] ITS Thailand. (2022). การประยุกต์ใช้เทคโนโลยีอัจฉริยะเพื่อการจัดการจราจรในประเทศไทย.
- [4] Zhao, Z., Chen, W., Wu, X., Chen, P. C. Y., & Liu, J. (2019). LSTM network: A deep learning approach for short-term traffic forecast. *IET Intelligent Transport Systems*, 13(2), 143-150
- [5] Barceló, J. (2010). *Fundamentals of traffic simulation*. Springer. <https://doi.org/10.1007/978-1-4419-6142-6>
- [6] Pell, A., Meingast, A., Schauer, O., (2017). Trends in Real-time Traffic Simulation. In: *Transportation Research Procedia*. Elsevier B.V., pp. 1477-1484.
- [7] Wang, J., Mao, Y., Li, J., Xiong, Z., Wang, W.X., 2015. Predictability of road traffic and congestion in urban areas. *PLoS One* 10.
- [8] Yue, Y., Yeh, A.G.O., Zhuang, Y., 2007. Prediction Time Horizon and Effectiveness of Real-time Data on Short-term Traffic Predictability. In: *Proceedings of the 2007*
- [9] Nagy, A.M., Simon, V., (2018). Survey on traffic prediction in smart cities. *Pervasive Mob Comput.*
- [10] เกรียงศักดิ์ วัฒนชากรพงศ์, ณกร อินทร์พุง, เอกชัย สุมาลี, (2556). Siamtraffic2.0: Traffic pattern search for travel time prediction in Bangkok road network. *Journal of Information Science and Technology* 4, 1-10.
- [11] Zhang, J., Liu, Y., Dai, H., & Wang, L. (2013). Real-time traffic flow forecasting using a deep learning model. *Neurocomputing*, 217, 376-386. <https://doi.org/10.1016/j.neucom.2016.08.095>
- [12] Nuli, S., Khan, M. A., Nam, Y., & Park, D. (2022). Real-time traffic flow prediction using a hybrid deep learning model integrating historical and real-time data. *IEEE Transactions on Intelligent Transportation Systems*, 23(8), 12345-12356. <https://doi.org/10.1109/TITS.2022.3156789>
- [13] Barceló, J. (2010). *Fundamentals of traffic simulation*. Springer. <https://doi.org/10.1007/978-1-4419-6142-6>
- [14] Dowling, R. G., Skabardonis, A., Halkias, J., McHale, G., & Zammit, G. (2004). *Traffic analysis toolbox volume III: Guidelines for applying traffic microsimulation modeling software* (No. FHWA-HRT-04-040). Federal Highway Administration.
- [15] Krajzewicz, D., Erdmann, J., Behrisch, M., & Bieker, L. (2012). Recent development and applications of SUMO - Simulation of Urban MObility. *International Journal on Advances in Systems and Measurements*, 5(3-4), 128-138.

- [16] PTV Group, 2023b. PTV OPTIMA: Real-time traffic management software for multimodal networks [WWW Document].
- [17] Aimsun. (n.d.). Aimsun Predict: Real-time traffic forecasting. Retrieved April 9, 2025, from <https://www.aimsun.com/aimsun-predict/>
- [18] PTV Group. (n.d.). PTV Optima – Real-time traffic management and forecasting. Retrieved April 9, 2025, from <https://www.ptvgroup.com/en/solutions/products/ptv-optima/>