

การประยุกต์ใช้ข้อมูลฝนเรดาร์เพื่อเพิ่มประสิทธิภาพในการคาดการณ์สภาพจราจร ด้วยเทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชัน

Application of Radar Rainfall Data to Enhance Traffic Prediction Accuracy Using Convolutional Neural Network Technique

ศุภณัฐ มะเปี่ยม¹, ลัดดาวัลย์ สุวรรณโชติ¹, และ มณฑล เมธาประยูร^{2*}

¹ โรงเรียนสาธิตแห่งมหาวิทยาลัยเกษตรศาสตร์ ศูนย์วิจัยและพัฒนาการศึกษา มหาวิทยาลัยเกษตรศาสตร์ จ.กรุงเทพมหานคร

² ภาควิชาวิศวกรรมทรัพยากรน้ำ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเกษตรศาสตร์ จ.กรุงเทพมหานคร

*Corresponding author; E-mail address: monton.me@ku.th

บทคัดย่อ

ปริมาณฝนตกหนักไม่เพียงแต่เป็นปัจจัยสำคัญที่ส่งผลกระทบต่อภัยพิบัติทางธรรมชาติ เช่น น้ำท่วมฉับพลันและดินถล่ม แต่ยังส่งผลกระทบต่อเนื่องสู่ภาวะการจราจรติดขัด ซึ่งเป็นปัญหาด้านเศรษฐกิจและสังคมที่สำคัญ หากสามารถตรวจจับพฤติกรรมฝนได้อย่างแม่นยำย่อมนำไปสู่การพัฒนาเครื่องมือสำหรับการคาดการณ์สภาพการจราจรที่มีประสิทธิภาพตามมา การศึกษานี้ มีวัตถุประสงค์เพื่อต้องการบูรณาการข้อมูลฝนเรดาร์ร่วมกับข้อมูลสภาพจราจรเพื่อนำไปสู่การเพิ่มประสิทธิภาพในการคาดการณ์สภาพจราจรด้วยเทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) โดยความท้าทายของการวิจัยนี้คือการนำข้อมูลเรดาร์ตรวจอากาศซึ่งให้ข้อมูลฝนความละเอียดสูงระดับพิกเซล ในทุก 10 นาที มาใช้ในการติดตามพฤติกรรมของฝนในอดีต ในขั้นตอนการศึกษา ได้เลือกใช้ถนนพหลโยธินในขอบเขตมหาวิทยาลัยเกษตรศาสตร์สำหรับการคาดการณ์การจราจร และเลือกใช้เทคนิค CNN เป็นเครื่องมือในการพัฒนาแบบจำลองคาดการณ์สภาพจราจรล่วงหน้า ข้อมูลฝนเรดาร์จากสถานีเรดาร์สี่ทบและข้อมูลสภาพจราจรจาก Google Traffic ที่ครอบคลุมพื้นที่ศึกษาจะถูกรวบรวมและวิเคราะห์ผลเพื่อสร้างเป็นชุดข้อมูลนำเข้าให้แบบจำลอง CNN ผลการศึกษาแสดงให้เห็นว่า เมื่อนำข้อมูลน้ำฝนจากเรดาร์ร่วมกับข้อมูลการจราจร สามารถคาดการณ์สถานการณ์ของการจราจรล่วงหน้า 30 นาที ได้แม่นยำกว่าการใช้ข้อมูลการจราจรย้อนหลังเพียงอย่างเดียวอย่างชัดเจนในช่วงเวลาฝนตกหนัก ผลลัพธ์ที่ได้นี้แสดงให้เห็นถึงศักยภาพของข้อมูลความละเอียดสูงจากเรดาร์ในการเพิ่มประสิทธิภาพของระบบคาดการณ์การจราจรแบบตามเวลาจริงได้ต่อไป

คำสำคัญ: ฝนเรดาร์, ฝนสถานี, การคาดการณ์จราจร, เทคนิค Neural Networks

Abstract

Heavy rainfall is a key factor not only in triggering natural disasters such as flash floods and landslides, but also in worsening traffic congestion, which is a significant economic and social issue. Accurate detection of rainfall behaviour can enhance the development of effective traffic prediction tools. This study aims to integrate radar rainfall with traffic condition to enhance traffic prediction performance using Convolution Neural Networks (CNN) techniques. The challenge of this

research is utilizing weather radar data, which provides high-resolution, pixel-based rainfall data at a 10-minute temporal resolution to track past rainfall behaviour. In this study, Phahonyothin Road within the area of Kasetsart University was selected as the study area for traffic prediction. CNN techniques were employed to develop a traffic prediction model. Radar data from Sattahip radar and traffic data from Google Traffic, covering the study area, were collected and analyzed to generate the input dataset for the CNN model. The results indicate that integrating radar rainfall data with traffic data significantly improves the model's accuracy in predicting traffic conditions 30 minutes in advance, compared to models using only past traffic conditions, particularly in heavy rainfall events. This highlights the potential of high-resolution radar data in enhancing real-time traffic forecasting.

Keywords: radar rainfall, rain gauge rainfall, traffic predictions, Neural Networks technique

1. คำนำ

ปัญหาการจราจรติดขัดในเขตชุมชนเมืองแออัดนับเป็นปัญหาเรื้อรังที่ส่งผลกระทบต่อทั้งด้านเศรษฐกิจ สังคม และสิ่งแวดล้อม โดยเฉพาะอย่างยิ่งในพื้นที่กรุงเทพมหานคร ซึ่งมีความหนาแน่นของประชากรและปริมาณยานพาหนะสูง โดยปัจจัยที่ส่งผลกระทบต่อปัญหาการจราจรที่มีความซับซ้อนและหลากหลาย เช่น การเติบโตของประชากรเมือง ผังเมือง/การออกแบบถนนไม่เหมาะสม กฎหมายการจราจรเพื่อบังคับใช้ไม่เข้มแข็งและจริงจัง รวมถึงฝนตกหนักที่เป็นที่แน่ชัดว่าเป็นหนึ่งในปัจจัยที่สำคัญมากต่อคุณภาพชีวิตบนท้องถนน ข้อมูลจากกรมอุตุนิยมวิทยาพบว่า ปริมาณฝนรายปีเฉลี่ยของจังหวัดกรุงเทพมหานคร มีฝนตกเฉลี่ยปีละ 1,400 – 1,600 มม. โดยส่วนใหญ่เป็นฝนพายุความร้อน (convective rainfall) ที่ก่อตัวอย่างรวดเร็วและตกหนักในบริเวณจำกัดในระยะเวลาสั้น หากฝนตกหนักด้วยความเข้มฝนเกินกว่า 60 มม./ชม. ซึ่งเกินกว่าศักยภาพของระบบระบายน้ำที่ออกแบบไว้จะรองรับได้ จะนำไปสู่การเกิดน้ำท่วมขังในบริเวณดังกล่าว งานวิจัยในอดีตชี้ให้เห็นว่าปริมาณฝนที่ตกลงสู่พื้นที่ส่งผลกระทบต่อความจุของถนนและความเร็วของการขับขี่ ฝนที่ตกหนักจะทำให้ความจุของท้องถนน


ลดลง 17-25% และรถยนต์สามารถใช้ความเร็วในการขับที่ลดลง 3-9 % [1] ดังนั้นจึงส่งผลกระทบต่อสภาพจราจรที่วิกฤติเพิ่มขึ้นอย่างหลีกเลี่ยงไม่ได้

การพัฒนาระบบขนส่งอัจฉริยะ (Intelligent Transport Systems - ITS) ได้รับการพัฒนามาอย่างต่อเนื่องสำหรับนำไปใช้เป็นเครื่องมือในการลดผลกระทบและการเพิ่มประสิทธิภาพในการจัดการจราจร โดยได้มีการนำปัจจัยที่เกี่ยวข้องกับการจราจรต่างๆ มาวิเคราะห์และประมวลผลด้วยอัลกอริทึมอัจฉริยะ (Intelligent Algorithms) เพื่อคาดการณ์การจราจรล่วงหน้าได้ โดยเทคนิค machine learning และ deep learning ได้รับความนิยมในการนำมาใช้อย่างต่อเนื่องโดยการเพิ่มความซับซ้อนของการจำลองขึ้นตามลำดับ [2] อย่างไรก็ตาม เนื่องจากปัจจัยที่เกี่ยวข้องที่ส่งผลกระทบต่อจราจรมีจำนวนมากและยากต่อการคาดเดา การสร้างแบบจำลองพยากรณ์การจราจรจึงมีความท้าทาย งานวิจัยส่วนมากได้พิสูจน์ว่าปัจจัยทางด้านสภาพอากาศ โดยเฉพาะอย่างยิ่งข้อมูลฝน มีความสำคัญต่อการคาดการณ์สภาพจราจรเป็นอย่างมาก โดยข้อมูลฝนที่ถูกนำมาใช้งานเป็นพื้นฐานคือข้อมูลฝนจากสถานีตรวจวัดแบบรายวัน หรือรายชั่วโมง [3-4] ทั้งนี้ ด้วยข้อจำกัดของตำแหน่งติดตั้งและความถี่ในการเก็บข้อมูล ส่งผลให้ข้อมูลสถานีวัดน้ำฝนไม่สามารถนำมาใช้คาดการณ์พฤติกรรมฝนที่เปลี่ยนแปลงสูงทั้งเชิงพื้นที่และเวลาได้ เป็นเหตุให้นักวิจัยเริ่มนำข้อได้เปรียบของเทคโนโลยีเรดาร์ตรวจ ซึ่งสามารถประเมินฝนความละเอียดสูง (ในระดับ 1 ตร.กม. และในทุก 15 นาที เป็นอย่างน้อย) และคาดการณ์ฝนล่วงหน้าระยะสั้นได้แม่นยำ 1-2 ชั่วโมงล่วงหน้า มาใช้เป็นข้อมูลในการคาดการณ์สภาพจราจร แต่การทำวิจัยดังกล่าวยังไม่แพร่หลาย [5] และไม่เคยถูกนำมาทดสอบในประเทศไทยมาก่อน อันเนื่องมาจากการเข้าถึงข้อมูลและความซับซ้อนของการวิเคราะห์ข้อมูลฝนเรดาร์

งานวิจัยนี้จึงมุ่งเน้นการพัฒนาแบบจำลองคาดการณ์สภาพจราจรในประเทศไทยโดยใช้เทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks: CNN) บูรณาการร่วมกับข้อมูลฝนพยากรณ์ความละเอียดสูงจากเรดาร์ตรวจอากาศและสภาพจราจรจาก Google Traffic ในเขตชุมชนเมืองแออัดเข้าด้วยกัน เพื่อพิสูจน์ทราบว่าการแบบจำลองที่พัฒนาขึ้นมีประสิทธิภาพและลดผลกระทบของการจราจรได้มากน้อยเพียงใดภายใต้อิทธิพลของฝนตกหนักที่มีพฤติกรรมแตกต่างกัน สำหรับใช้ในการพัฒนาแบบจำลองการคาดการณ์สภาพจราจรล่วงหน้าในพื้นที่ศึกษา เพื่อให้ได้เครื่องมือที่เป็นประโยชน์ต่อการวางแผนการเดินทางเพื่อหลีกเลี่ยงปัญหาการจราจรในพื้นที่เป้าหมายและนำไปสู่การลดผลกระทบจากปัญหาการจราจรได้ต่อไป

2. พื้นที่ศึกษา

มหาวิทยาลัยเกษตรศาสตร์ ซึ่งเป็นเขตชุมชนที่มีสถานศึกษา มหาวิทยาลัย โรงเรียนขนาดใหญ่ และสถานที่ราชการตั้งอยู่ในพื้นที่ ได้รับการล้อมรอบด้วยถนนสายสำคัญจำนวน 3 เส้นคือ ถนนพหลโยธิน ถนนงามวงศ์วาน และถนนวิภาวดีรังสิต หากเกิดปัญหาฝนตกหนักซ้ำเติมสภาพจราจรเดิมจะส่งผลกระทบต่อสภาพจราจรที่วิกฤติขึ้นอย่างหลีกเลี่ยงไม่ได้ ในการศึกษาครั้งนี้ได้คัดเลือกถนนพหลโยธินที่ตั้งอยู่ทางด้านทิศตะวันออกของมหาวิทยาลัยเกษตรศาสตร์มาทดสอบแบบจำลองการคาดการณ์ โดยพิจารณาเฉพาะช่องจราจรขาออกซึ่งมีระยะทางประมาณ 2.2 กม. มีขอบเขตตั้งแต่สี่แยกเกษตรผ่านมหาวิทยาลัยเกษตรศาสตร์จนถึงถนนบางเขน (แยกบางบัว) ดังแสดงเส้นทางที่คัดเลือกในรูปที่ 1



รูปที่ 1 แนวเส้นทางพหลโยธินที่ผ่านมหาวิทยาลัยเกษตรศาสตร์ จากสี่แยกเกษตรจนถึง ถนนบางเขน (แยกบางบัว)

3. ทฤษฎีที่เกี่ยวข้อง

3.1 การประเมินฝนเรดาร์และการปรับแก้ความคลาดเคลื่อนด้วยสถานีวัดน้ำฝน

โดยทั่วไปในการประเมินน้ำฝนเริ่มต้นด้วยการแปลงค่าการสะท้อนกลับที่ตรวจวัดได้ให้เป็นความเข้มของฝนหรือปริมาณฝน ด้วยความสัมพันธ์ Z-R ซึ่งอยู่ในรูปสมการเลขยกกำลังดังแสดงในสมการที่ (1)

$$Z = AR^b \quad (1)$$

เมื่อ Z คือ ค่าการสะท้อนกลับ (มิลลิเมตร⁶ เมตร-3), A และ b คือ พารามิเตอร์ของสมการความสัมพันธ์ Z-R อย่างไรก็ตาม เนื่องจากความสัมพันธ์ Z-R มีการเปลี่ยนแปลงอย่างสูงทั้งเชิงพื้นที่และเวลา ดังนั้นจึงต้องปรับแก้ความคลาดเคลื่อนในการประเมินน้ำฝนจากเรดาร์ร่วมกับข้อมูลน้ำฝนจากสถานีด้วยเทคนิค bias adjustment [6] ดังแสดงในสมการที่ (2)

$$(G/R)_t = \frac{\sum_{i=1}^N G_i}{\sum_{i=1}^N R_i} \quad (2)$$

โดยที่ $(G/R)_t$ คือ แฟกเตอร์ปรับแก้ปริมาณน้ำฝนจากเรดาร์ที่เวลา t (รายชั่วโมง), G_i คือ ปริมาณน้ำฝนจากสถานีวัดน้ำฝน i ที่เวลาสะสม t (มม./ชม.), R_i คือ ปริมาณน้ำฝนจากเรดาร์ที่คำนวณโดยความสัมพันธ์ Z-R ที่ตำแหน่งพิกเซลเดียวกันกับสถานีวัดน้ำฝน i ที่ช่วงเวลาสะสม t (มม./ชม.), N คือ จำนวนสถานีวัดน้ำฝนทั้งหมดที่ใช้ในการคำนวณ

สำหรับปริมาณฝนเรดาร์หลังการปรับแก้สามารถคำนวณได้โดยการนำค่าแฟกเตอร์การปรับแก้จากสมการที่ (2) คูณด้วยปริมาณฝนเรดาร์ก่อนปรับแก้ที่ได้จากสมการที่ (1)

3.2 เทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks, CNN)


โครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) เป็นโครงข่ายประสาทเทียมเชิงลึก (Deep Learning) ที่มีประสิทธิภาพสูงในการประมวลผลข้อมูลที่มีโครงสร้างเชิงพื้นที่ (spatial structure) เช่น ภาพ โดยหัวใจสำคัญในกระบวนการทำงานของ CNN คือ Convolutional Layer ซึ่งทำหน้าที่เรียนรู้คุณลักษณะ (features) ของข้อมูลนำเข้าโดยอัตโนมัติผ่านการใช้อัตรา (filter) หรือ kernel ขนาดเล็กเลื่อนไปทั่วข้อมูล (sliding window)

ฟิลเตอร์เหล่านี้จะตรวจจับรูปแบบต่างๆ เช่น ขอบ, มุม, หรือพื้นผิว ในข้อมูลนำเข้า โดยทั่วไป ภาพสัณฐานมักประกอบด้วยสามช่องสัญญาณสี (Red, Green, Blue) ซึ่ง CNN สามารถประมวลผลแต่ละช่องสัญญาณเหล่านี้เพื่อเรียนรู้คุณลักษณะที่ซับซ้อนยิ่งขึ้น นอกจากนี้ Convolutional Layer แล้ว CNN มักประกอบด้วยเลเยอร์อื่นๆ เช่น Pooling Layer เพื่อลดขนาดข้อมูลและเพิ่มความทนทานต่อการเปลี่ยนแปลงตำแหน่งของวัตถุในภาพ รวมถึง Fully Connected Layer ในชั้นสุดท้ายเพื่อทำการจำแนกหรือพยากรณ์สำหรับสถาปัตยกรรม CNN สามารถปรับแต่งได้โดยการปรับ hyperparameters ต่างๆ เช่น ขนาดฟิลเตอร์, จำนวนฟิลเตอร์, และประเภทของ activation function เพื่อให้เหมาะสมกับงานเฉพาะนั้นๆ [7-8]

3.3 ฟังก์ชัน Cross Entropy Loss และ Argmax สำหรับการจำแนกประเภท

ในการจำแนกประเภทข้อมูล (classification) ซึ่งเป็นเป้าหมายหลักของการคาดการณ์สภาพจราจรในงานวิจัยนี้ ฟังก์ชัน Cross Entropy Loss และการดำเนินการ Argmax มีบทบาทสำคัญในการฝึกสอนและใช้งานแบบจำลองโครงข่ายประสาทเทียม (Neural Networks) กล่าวคือ Cross Entropy Loss หรือที่เรียกว่า Log Loss เป็นฟังก์ชันค่าสูญเสีย (loss function) ที่ใช้ประเมินความแตกต่างระหว่างการกระจายความน่าจะเป็นที่แบบจำลองทำนาย กับการกระจายความน่าจะเป็นที่แท้จริงของข้อมูล [9] ฟังก์ชันนี้มีความเหมาะสมอย่างยิ่งสำหรับการจำแนกประเภทแบบหลายคลาส (multi-class classification) ซึ่งในกรณีศึกษาของเราคือการจำแนกสภาพจราจรออกเป็นหลายระดับ (ได้แก่สภาพจราจรคล่องตัว หนาแน่นปานกลาง หนาแน่นมาก และ วิกฤต) ค่า Cross Entropy Loss จะคำนวณจากความน่าจะเป็นที่แบบจำลองทำนายสำหรับแต่ละคลาส โดยค่าที่ต่ำกว่าแสดงถึงความสอดคล้องที่มากขึ้นระหว่างการทำนายของแบบจำลองกับการกระจายความน่าจะเป็นที่แท้จริง ซึ่งบ่งชี้ถึงประสิทธิภาพในการจำแนกประเภทที่สูงขึ้น

สำหรับในบทความนี้ เป็นการสร้างแบบจำลองการคาดการณ์สภาพจราจรในเวลา 30 นาที ข้างหน้า ในพื้นที่ ม.เกษตรศาสตร์ ด้วยการกำหนดข้อมูลชั้นนำเข้า (Input Layer) จาก 2 ชุดข้อมูลคือ 1) ข้อมูลสภาพการจราจรในช่วงเวลา 60 นาทีก่อนหน้านี้ และ 2) ข้อมูลฝนเรดาร์สำหรับช่วงเวลา 60 นาที ก่อนหน้า สำหรับ Output Layer คือข้อมูลสภาพจราจรในอนาคต 30 นาที ข้างหน้า โดยแผนผังของการจำลองด้วยเทคนิคโครงข่ายประสาทเทียมแสดงดังรูปที่ 2




รูปที่ 2 ชั้นโครงสร้างพื้นฐานของโครงข่ายประสาทเทียม

4. วิธีการศึกษา

4.1 การรวบรวมข้อมูล

4.1.1 ข้อมูลฝนจากเรดาร์ตรวจอากาศ

ดำเนินการรวบรวมข้อมูลฝนเรดาร์ ในฤดูฝนของปี 2567 จาก Application Radar4Flood2023 ที่พัฒนาโดยมหาวิทยาลัยเกษตรศาสตร์ (2567) ภายใต้การสนับสนุนทุนวิจัยจากสำนักงานพัฒนาการวิจัยการเกษตร (องค์การมหาชน) หรือ สวก. ซึ่งเป็นข้อมูลฝนเรดาร์แบบ grid-based ขนาด 600 เมตร x 600 เมตร เผยแพร่ทุก 10 นาที ในขอบเขตที่ครอบคลุมพื้นที่ที่ศึกษาระหว่างเดือนกันยายนถึงเดือนพฤศจิกายน พ.ศ. 2567 ดังแสดงตัวอย่างข้อมูลเรดาร์ที่ครอบคลุมพื้นที่มหาวิทยาลัยเกษตรศาสตร์ (บางเขน) ดังรูปที่ 3




รูปที่ 3 ตัวอย่างข้อมูลฝนเรดาร์ที่ครอบคลุมพื้นที่ ม.เกษตรศาสตร์ วันที่ 29 กรกฎาคม 2567 เวลา 18.00 น.

4.1.2 ข้อมูลฝนจากสถานีวัดน้ำฝนแบบอัตโนมัติ

รวบรวมข้อมูลฝนจากสถานีวัดน้ำฝนแบบอัตโนมัติที่ติดตั้งโดยรอบมหาวิทยาลัยเกษตรศาสตร์จาก สำนักการระบายน้ำกรุงเทพมหานคร และสถาบันสารสนเทศทรัพยากรน้ำ (องค์การมหาชน) สำหรับช่วงเวลาที่สอดคล้องกับข้อมูลเรดาร์ระหว่างเดือนกันยายน ถึงเดือนพฤศจิกายน พ.ศ. 2567 และนำมาปรับแก้ความคลาดเคลื่อนฝนเรดาร์

4.1.3 ข้อมูลสภาพจราจรตามเวลาจริง (real-time) จาก Google Traffic

ผู้วิจัยได้พัฒนาเครื่องมือ ด้วยภาษา Python เพื่อทำการ capture ภาพจาก Google Traffic พัฒนาในรูปแบบ image file สำหรับทุก 10 นาที ระหว่างเดือน กันยายน ถึง พฤศจิกายน ปี พ.ศ. 2567 ที่ครอบคลุมพื้นที่ ม.เกษตรศาสตร์ และบริเวณข้างเคียง ประกอบด้วยภาพถ่ายจำนวน 15 ภาพ จากนั้นนำภาพมา merge กันด้วยเทคนิค Image Stitching เพื่อให้ได้ภาพครอบคลุมขอบเขตพื้นที่ที่ศึกษาที่พิจารณา ดังแสดงตัวอย่างแผนที่สภาพจราจรในวันที่ 18 ตุลาคม เวลา 18.00 น. ในรูปที่ 4



รูปที่ 4 ตัวอย่างแผนที่สภาพจราจรจาก Google Traffic ในวันที่ 18 ตุลาคม เวลา 18.00 น. ในขอบเขตพื้นที่มหาวิทยาลัยเกษตรศาสตร์

4.2 การจัดเตรียมข้อมูลสำหรับนำเข้าแบบจำลอง CNN

4.2.1 ข้อมูลการจราจรจาก Google Traffic

การพัฒนาเครื่องมือเพื่อแปลงข้อมูลภาพการจราจรตามเส้นถนน พหุโยธินที่คัดเลือกให้เป็นข้อมูลเชิงตัวเลข (Digital Data) โดยแบ่งข้อมูล เป็น 4 class ย่อย ตามสีของ google traffic ที่จัดการจราจรเป็น 4 ระดับ กล่าวคือ 1) สีเขียว 2) สีส้ม 3) สีแดง และ 4) สีแดงเข้ม แทนสภาพจราจร คล่องตัว การจราจรหนาแน่นปานกลาง การจราจรหนาแน่นมาก และการจราจรหนาแน่นวิกฤต ตามลำดับ โดยโปรแกรมที่พัฒนาขึ้นจะทำการ อ่านภาพสีตามแนวเส้นถนนพหุโยธินราย pixel และแปลงค่าสีที่อ่านได้ให้เป็นตัวเลขแสดงค่า class ต่างๆ ที่สอดคล้องกัน จากนั้นจึงบันทึกข้อมูลให้อยู่ในรูปแบบ csv file ตามขนาดของขอบเขตถนนที่พิจารณา ซึ่งมีขนาด ความกว้างถนน x ความยาวถนนคือ 19 x 2391 พิกเซล สำหรับการดึง ข้อมูลการจราจรเป็นข้อมูลเชิงตัวเลข

4.2.2 ข้อมูลฝนเรดาร์ตามเส้นถนนพหุโยธิน

การพัฒนาเครื่องมือเพื่อดึงค่าข้อมูลฝนเรดาร์ที่ปรับแก้ความ คลาดเคลื่อนจากฝนสถานีด้วยเทคนิค bias adjustment เรียบร้อยแล้ว จาก application Radar4Flood โดยดึงข้อมูลเรดาร์เฉพาะ pixel ที่ตรงกับ เส้นถนนพหุโยธิน ข้อมูลฝนเรดาร์ที่ดึงข้อมูลมาจะอยู่ในหน่วย มม./ชม. จากนั้นทำการแปลง ข้อมูลความเข้มฝนดังกล่าวให้อยู่ในรูปแบบ class ของ ข้อมูลจำนวน 5 class ย่อย ซึ่งเป็นตัวแทนของ ฝนไม่ตก ฝนอ่อน ฝนปาน กลาง ฝนหนัก และฝนหนักมาก ตามลำดับ สำหรับเกณฑ์ที่ใช้ในการแบ่ง ข้อมูลฝนตาม class ต่างๆ แสดงในตารางที่ 1 จากนั้นจึงบันทึกข้อมูลให้อยู่ ในรูปแบบ csv file ตามขนาดของขอบเขตถนนที่พิจารณา ซึ่งมีขนาดความ กว้างถนน 10 ม. ความยาวถนนคือ 19 x 2391 พิกเซล สอดคล้องกับข้อมูล การจราจร

ตารางที่ 1 เกณฑ์ที่ใช้ในการแบ่งข้อมูลฝนตาม class ต่างๆ

Class	ความเข้มฝน (มม./ชม.)	ประเภทฝน
1	0	ฝนไม่ตก
2	0.1 - 5	ฝนอ่อน
3	5 - 25	ฝนปานกลาง
4	25 - 50	ฝนหนัก
5	> 50	ฝนหนักมาก

4.2.3 การทำ Data Filtering เพื่อจัดการชุดข้อมูลการจราจรและ ข้อมูลฝนเรดาร์ในทุก 10 นาที สำหรับ scale ดันฉบับที่ ความกว้าง x ความยาวถนน ที่ 19 x 2391 pixel ให้มีขนาดเล็กลงให้อยู่ใน scale ความ กว้าง x ความยาวถนน ที่ 1 x 240 pixel สำหรับการศึกษานี้ได้เลือก function numpy.max จาก library ของ NumPy (Numeric Python)

ในภาษา Python โดยมีเป้าหมายเพื่อเดิมข้อมูลที่อาจขาดหายไปจากการ ทำ image processing จากการแปลงข้อมูลภาพจราจร และเพิ่มความ สมเหตุสมผลของข้อมูลการจราจรใน pixel ติดกันให้มากขึ้นหากมีความ คลาดเคลื่อนจากภาพสีต้นฉบับ นอกจากนั้นแล้วจะช่วยลดขนาดข้อมูล มี ขนาดเล็กลงเพื่อต่อการ train แบบจำลอง CNN อีกด้วย

4.3 การพัฒนาแบบจำลองการคาดการณ์สภาพจราจรด้วย เทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks, CNN)

การประยุกต์ใช้เทคนิค CNN ในการศึกษาครั้งนี้ ได้กำหนดข้อมูลชั้นนำเข้า (Input Layer) ออกเป็น 2 กรณีศึกษา สำหรับการคาดการณ์ข้อมูลภาพ จราจรในอนาคต 30 นาที ข้างหน้า โดยได้ประยุกต์ใช้ไลบรารี TensorFlow และ Keras ซึ่งเป็นซอฟต์แวร์ Deep Learning ที่ถูกพัฒนาขึ้นโดย Google สำหรับการกำหนดโครงสร้างของโมเดล ANN การคาดการณ์จราจรล่วงหน้า สำหรับรายละเอียดของ 2 กรณีศึกษาที่ใช้ในการ train และ test model แสดงดังตารางที่ 2

ตารางที่ 2 กรณีศึกษาที่ใช้ในการจำลองการคาดการณ์สภาพจราจร

กรณีศึกษา	ข้อมูลนำเข้า	ข้อมูลจริง (Ground Truth)
1. แบบจำลอง Traffic	1. ข้อมูล traffic ย้อนหลัง 60 นาที	ข้อมูลการจราจรที่ 60 นาที ล่วงหน้า
2. แบบจำลอง Traffic + Radar	1. ข้อมูล traffic ย้อนหลัง 60 นาที 2. ข้อมูลฝน radar ย้อนหลัง 60 นาที	ข้อมูลการจราจรที่ 60 นาที ล่วงหน้า

ชุดข้อมูลสภาพจราจรและข้อมูลฝนเรดาร์ที่รวบรวมมาระหว่างเดือน กันยายนถึงเดือนพฤศจิกายน พ.ศ. 2567 จะถูกแบ่งออกเป็น 3 ชุดแบบสุ่ม (Random sampling) คือ ข้อมูลสำหรับการเรียนรู้ (training set) ข้อมูล สำหรับการตรวจสอบ (Validation set) และข้อมูลสำหรับการทดสอบ (Testing set) โดยมีสัดส่วนในการแบ่งชุดข้อมูลเป็น 64: 16: 20 เปอร์เซ็นต์ ตามลำดับของจำนวนข้อมูลทั้งหมด

การฝึกสอนแบบจำลอง CNN ในงานศึกษานี้มุ่งเน้นไปที่การปรับปรุง ค่าน้ำหนัก (weights) ภายในโครงข่ายฯ อย่างเหมาะสม เพื่อให้แบบจำลอง สามารถสร้างการทำนายที่แม่นยำจากข้อมูลนำเข้า การเรียนรู้ของ แบบจำลองเกิดขึ้นผ่านการป้อนชุดข้อมูลฝึกสอน (training dataset) และการปรับปรุงพารามิเตอร์ภายในอย่างเป็นระบบ สำหรับขั้นตอนการฝึกสอน แบบจำลองที่สำคัญมีดังนี้

1) กระบวนการก่อนเริ่มการฝึกสอน ต้องทำการกำหนดค่า องค์ประกอบสำคัญสำหรับการเรียนรู้ คือฟังก์ชันค่าสูญเสีย (Loss Function): Sparse Categorical Cross Entropy (SCCE) โดยฟังก์ชันนี้ ถูกเลือกเพื่อประเมินความแตกต่างระหว่างการกระจายความน่าจะเป็นของ การทำนายและค่าความจริง ในงานจำแนกประเภทแบบหลายคลาส. SCCE มีความเหมาะสมกับข้อมูลป้ายกำกับที่เป็นค่าจำนวนเต็ม (integer) ซึ่ง สอดคล้องกับลักษณะข้อมูลสภาพจราจรในงานวิจัยนี้

2) การเข้ารหัสป้ายกำกับข้อมูลในรูปแบบ One-Hot Encoding. ใน งานจำแนกประเภทแบบหลายคลาส วิธีการทั่วไปในการแทนค่าป้ายกำกับ ข้อมูล (labels) คือ One-Hot Encoding. ในรูปแบบนี้ แต่ละคลาสจะถูก แทนด้วยเวกเตอร์ที่มีค่าเป็น 0 ทั้งหมด ยกเว้นตำแหน่งที่สอดคล้องกับคลาส นั้นๆ ที่มีค่าเป็น 1. ตัวอย่างเช่น หากมี 4 คลาส (สมมติเป็น คลาส 0, 1, 2, 3) ป้ายกำกับสำหรับข้อมูลที่อยู่ในคลาส 2 จะถูกแทนด้วยเวกเตอร์ [0, 0, 1, 0]. อย่างไรก็ตาม ฟังก์ชัน SCCE ได้รับการออกแบบมาให้ทำงานได้โดยตรง

กับป้ายกำกับข้อมูลที่เป็นค่าจำนวนเต็ม (เช่น 0, 1, 2, 3) โดยไม่จำเป็นต้องแปลงเป็น One-Hot Vector ก่อน

3) ตัวปรับแต่ง (Optimizer): Adam ทั้งนี้อัลกอริทึม Adam ถูกนำมาใช้เพื่อปรับปรุงค่าน้ำหนักของโครงข่าย CNN อย่างมีประสิทธิภาพ โดย Adam เป็นวิธีการปรับปรุงแบบ Stochastic Optimization ที่คำนึงถึง adaptive learning rates สำหรับแต่ละพารามิเตอร์ ช่วยให้การฝึกสอนลู่เข้าสู่ค่าสูญเสียที่ต่ำกว่าได้รวดเร็วและมีเสถียรภาพมากขึ้น

4) กระบวนการฝึกสอนแบบจำลองตามรอบที่กำหนด (epochs) ซึ่งในแต่ละ epochs ชุดข้อมูลฝึกสอนทั้งหมดจะถูกนำเสนอต่อแบบจำลอง ในระหว่าง epochs แต่ละรอบแบบจำลองจะดำเนินการโดยเริ่มต้นจากการส่งผ่านไปข้างหน้า (Forward Pass) จากข้อมูลนำเข้า และทำการคำนวณผ่านชั้นต่างๆ ของโครงข่ายฯ จนกระทั่งได้ผลลัพธ์ทำนาย จากนั้นทำการคำนวณค่าสูญเสีย (Loss Calculation) ด้วยฟังก์ชัน SCCE ลำดับต่อมาคือการส่งผ่านย้อนกลับ (Backward Pass) เพื่อนำค่าสูญเสียที่คำนวณได้ไปคำนวณ gradient ของค่าสูญเสียเทียบกับค่าน้ำหนักของโครงข่ายฯ เพื่อบ่งชี้ถึงทิศทางที่ควรปรับค่าน้ำหนักเพื่อลดค่าสูญเสีย ลำดับสุดท้ายคือการปรับปรุงค่าน้ำหนัก (Weight Update) ด้วยอัลกอริทึม Adam โดยอิงตาม gradient ที่คำนวณได้เพื่อลดค่าสูญเสียในการทำนายรอบถัดไป

5) กระบวนการทำซ้ำตามจำนวน epochs ที่กำหนดไว้ หรือจนกว่าจะบรรลุเกณฑ์การหยุดการฝึกสอน (stopping criteria) ที่เหมาะสม เช่น การที่ค่าสูญเสียบนชุดข้อมูลตรวจสอบ (validation dataset) ไม่ลดลงอีกต่อไป การใช้ชุดข้อมูลตรวจสอบเป็นส่วนหนึ่งของกระบวนการฝึกสอน เพื่อประเมินประสิทธิภาพของแบบจำลองและป้องกันปัญหา Overfitting นอกจากนี้ ชุดข้อมูลทดสอบ (testing dataset) จะถูกใช้ในขั้นตอนสุดท้ายเพื่อประเมินประสิทธิภาพของแบบจำลองบนข้อมูลที่ไม่เคยถูกใช้ในการฝึกสอนมาก่อน

4.4 การทดสอบประสิทธิภาพของแบบจำลอง CNN

เพื่อทดสอบประสิทธิภาพของการคาดการณ์สภาพพายุระยะสั้น 30 นาทีล่วงหน้า ผลลัพธ์ของการพยากรณ์สภาพพายุจะถูกลำเลียงมาเปรียบเทียบกับข้อมูลการตรวจวัดจริง (Ground Truth) ณ เวลาช่วงเวลาที่สอดคล้องกับช่วงเวลาการพยากรณ์ โดยใช้ชุดข้อมูลทดสอบ (test data) สำหรับการศึกษาเลือกใช้ Multiclass Confusion Matrix เป็นดัชนีในการชี้วัดโดยตาราง Multiclass Confusion Matrix แสดงในรูปที่ 5 โดยมีรายละเอียดดังนี้

		Predicted Class			
		C ₁	C ₂	...	C _N
Actual Class	C ₁	C _{1,1}	FP	...	C _{1,N}
	C ₂	FN	TP	...	FN
	...	...	...	...	...
	C _N	C _{N,1}	FP	...	C _{N,N}

รูปที่ 5 ตารางแสดง Multiclass Confusion Matrix ของข้อมูลพยากรณ์และข้อมูลตรวจวัดจริง

• True Positive (TP) บ่งชี้ว่า ข้อมูลที่ทำนายตรงกับข้อมูลที่เกิดขึ้นจริงให้ค่าจริงทั้งคู่ เช่นทำนายว่าฝนตกตรงกับฝนตกจริง หรือทำนายว่าการจราจรติดขัดตรงกับข้อมูลจริง

• True Negative (TN) บ่งชี้ว่า ข้อมูลที่ทำนายตรงกับข้อมูลที่ตรวจวัดโดยให้ค่าเท็จทั้งคู่ เช่นทำนายว่าฝนไม่ตกตรงกับฝนไม่ตกจริง หรือทำนายว่าการจราจรไม่ติดขัดตรงกับข้อมูลจริง

• False Positive (FP) บ่งชี้ว่า ข้อมูลที่ทำนายไม่ตรงกับสิ่งที่เกิดขึ้นจริงโดยทำนายว่าจริงแต่สิ่งที่เกิดขึ้นคือไม่จริง

• False Negative (FN) บ่งชี้ว่า ข้อมูลที่ทำนายไม่ตรงกับสิ่งที่เกิดขึ้นจริงโดยทำนายว่าไม่จริงแต่สิ่งที่เกิดขึ้นคือจริง

สำหรับการประเมินความถูกต้อง (accuracy) และความแม่นยำ (precision) เพื่อบ่งชี้ประสิทธิภาพของการทำนายสามารถวิเคราะห์ได้จากตารางที่ 3


ตารางที่ 3 ดัชนีที่ใช้ประเมินความแม่นยำของการพยากรณ์เชิงคุณภาพ

ดัชนี	สูตรการคำนวณ	ช่วงของดัชนี	ค่าที่ดีที่สุด
Accuracy	$(TP+TN)/(TP+TN+FP+FN)$	0-1	1
Precision	$TP/(TP+FP)$	0-1	1

5. ผลการศึกษาและการอภิปรายผล


5.1 ผลการปรับแก้ความคลาดเคลื่อนของเรดาร์ด้วยข้อมูลฝนจากสถานี

ผลการเปรียบเทียบประสิทธิภาพเทคนิคการปรับแก้แบบรวมทุกเหตุการณ์แสดงรูปกราฟการกระจายตัว (Scatter plot) ของข้อมูลปริมาณน้ำฝนจากสถานีกับปริมาณน้ำฝนเรดาร์ดังรูป พบว่าฝนเรดาร์ก่อนปรับแก้มีการกระจายตัวส่วนมากในทิศทางที่ฝนเรดาร์ประเมินได้ต่ำกว่าฝนจากสถานีวัดน้ำฝน โดยหลังการปรับแก้ด้วยวิธี Mean Field Bias ข้อมูลมีการกระจายตัวเข้าใกล้เส้น 1:1 มากขึ้น สามารถประเมินค่า RMSE ของปริมาณฝนก่อนปรับแก้และหลังปรับแก้ได้ประมาณ 3.85 และ 2.62 มม./ชม. ตามลำดับ คิดเป็นเปอร์เซ็นต์ความถูกต้องที่เพิ่มขึ้นประมาณ 32 เปอร์เซ็นต์



รูปที่ 6 กราฟกระจายตัวระหว่างปริมาณฝนเรดาร์และสถานีวัดน้ำฝนรายชั่วโมง (ก) ฝนเรดาร์ก่อนปรับแก้ และ (ข) ฝนเรดาร์หลังปรับแก้ด้วยวิธี MFB


สำหรับตัวอย่างภาพการกระจายตัวเชิงพื้นที่ของฝนเรดาร์ในช่วงเวลา 10 ต.ค. 2567 เวลา 18:30 น. เทียบกับฝนสถานีดังแสดงในรูปที่ 7 พบว่าในตำแหน่งที่ตั้งเดียวกันกับสถานีวัดน้ำฝน ฝนเรดาร์มีค่าใกล้เคียงกับฝนสถานี อย่างไรก็ตาม ฝนเรดาร์แสดงประสิทธิภาพในการตรวจจับฝนเชิงพื้นที่ที่มีความละเอียดสูงกว่าได้อย่างชัดเจน โดยเรดาร์สามารถตรวจจับฝนตกหนักได้ในตำแหน่งที่ไม่มีสถานีวัดน้ำฝนตั้งอยู่




รูปที่ 7 ปริมาณฝนเชิงพื้นที่ของเรดาร์และฝนสถานีสำหรับเหตุการณ์ฝนสะสมรายชั่วโมง วันที่ 10 ต.ค. 2567 18:30 น.

5.2 ผลการการจัดทำ Data Processing ของข้อมูลให้อยู่ในรูป csv file

จากการการพัฒนาเครื่องมือเพื่อแปลงข้อมูลภาพการจราจรตามเส้นถนนพหลโยธินที่คัดเลือกให้เป็นข้อมูลเชิงตัวเลข (Digital Data) โดยแบ่งข้อมูลเป็น 4 class ย่อย ตามสีของ google traffic ที่จัดการจราจรเป็น 4 ระดับ กล่าวคือ 1) สีเขียว 2) สีส้ม 3) สีแดง และ 4) สีแดงเข้ม แทนสภาพจราจรคล่องตัว การจราจรหนาแน่นปานกลาง การจราจรหนาแน่นมาก และการจราจรหนาแน่นวิกฤต ได้ผลลัพธ์อยู่ในรูป csv file ดังแสดงในตัวอย่างในรูปที่ 8 และรูปที่ 9



รูปที่ 8 ตัวอย่าง csv file ใน scale 19x2391 ของข้อมูลการจราจร ในวันที่ 24 กันยายน 2567 เวลา 19:50 น.




รูปที่ 9 ตัวอย่าง csv file ใน scale 19x2391 ของข้อมูลเรดาร์ในวันที่ 24 กันยายน 2567 เวลา 19:50 น.

5.3 ประสิทธิภาพของการฝึกสอน (Training) แบบจำลอง CNN

การปรับค่า Hyperparameters ที่เหมาะสมเป็นขั้นตอนสำคัญในการสร้างแบบจำลอง CNN ที่มีประสิทธิภาพและแม่นยำ ในกระบวนการวิเคราะห์ ชุดข้อมูลสำหรับการเรียนรู้ และชุดข้อมูลสำหรับการตรวจพิสูจน์ จะถูกนำไปทดสอบประสิทธิภาพของชุด Hyperparameters ที่กำหนดโดยชุด Hyperparameters ที่เหมาะสมที่สุดจะให้ค่า Loss ที่ต่ำที่สุดสำหรับชุดข้อมูลการเรียนรู้และชุดข้อมูลการตรวจพิสูจน์ สำหรับผล


การศึกษาในรูปที่ 10 พบว่า เมื่อจำนวนรอบในการเรียนรู้ (Epoch) เพิ่มขึ้น ค่า Loss จะต่ำลงเรื่อยๆ ทั้งสองชุดข้อมูล จากกราฟจะเห็นได้ว่าค่า loss มีการเปลี่ยนแปลงเพียงเล็กน้อยเมื่อเข้าสู่รอบที่ 50 โดยค่า loss ที่ดีที่สุดมีค่าประมาณ 0.61 และ 0.60 สำหรับข้อมูลฝึกสอนและข้อมูลตรวจพิสูจน์ตามลำดับ




รูปที่ 10 ค่าการสูญเสียที่เปลี่ยนแปลงไปตามรอบการเรียนรู้ที่เพิ่มขึ้นในกระบวนการฝึกสอนแบบจำลอง

5.4 ประสิทธิภาพของการทดสอบ (Testing) แบบจำลอง CNN ที่พัฒนาขึ้น

เพื่อให้เห็นประสิทธิภาพของแบบจำลองคาดการณ์สภาพจราจรทั้ง 2 แบบจำลองที่พัฒนาขึ้น ได้นำแบบจำลองที่ผ่านการ Train มาทดสอบกับชุดข้อมูลทดสอบ (test data) โดยผลของการเปรียบเทียบค่า Accuracy และค่า Precision ของทั้งสองแบบจำลอง แสดงในรูปที่ 11 และ รูปที่ 12 ตามลำดับ




รูปที่ 11 การเปรียบเทียบค่า Accuracy ระหว่าง 1) แบบจำลองที่นำเข้าข้อมูลการจราจร และ 2) แบบจำลองที่นำเข้าข้อมูลการจราจรและข้อมูลฝนเรดาร์




รูปที่ 12 การเปรียบเทียบค่า Precision ระหว่าง 1) แบบจำลองที่นำเข้าข้อมูลการจราจร และ 2) แบบจำลองที่นำเข้าข้อมูลการจราจรและข้อมูลฝนเรดาร์

ผลจากการศึกษาแสดงให้เห็นว่าค่า Accuracy และ Precision โดยรวมของแบบจำลอง CNN ที่นำเข้าจากข้อมูลที่ต่างกันจะส่งผลต่อการคาดการณ์สถานการณ์การจราจรที่ต่างกัน โดยการนำเข้าข้อมูลที่บูรณาการระหว่างข้อมูลฝนเรดาร์และข้อมูลการจราจรในอดีต 60 นาทีย้อนหลัง (แบบจำลอง Traffic + Radar) ให้ผลของ Accuracy และ Precision เฉลี่ยของทุกช่วงเวลาทดสอบให้ค่าประมาณ 0.70 และ 0.71 ซึ่งให้ผลที่ดีกว่าการใช้ข้อมูลการจราจรในอดีตย้อนหลัง 60 นาทีเพียงอย่างเดียว (แบบจำลอง Traffic) ซึ่งให้ผลของ Accuracy และ Precision เฉลี่ยของทุกช่วงเวลาทดสอบให้ค่าประมาณ 0.61 และ 0.68 และเมื่อพิจารณาว่า Accuracy and Precision ที่เปลี่ยนแปลงไปตามเวลาพบว่า หลายช่วงเวลาที่การบูรณาการข้อมูลเรดาร์เข้าไปช่วยเพิ่มความแม่นยำในการคาดการณ์การจราจรล่วงหน้าอย่างเห็นได้ชัด ทั้งนี้เมื่อได้ศึกษาสาเหตุในช่วงเวลาดังกล่าว ดังตัวอย่าง showcase ณ วันที่ 10 ต.ค. 67 เวลา 18.30 น. (ดูรูปที่ 11 และ 12) พบว่าชุดข้อมูลที่ใช้ในการเรียนรู้ก่อนการพยากรณ์มีฝนตกหนักและข้อมูลการจราจรในช่วงเวลาต่อมาเกิดรถติดมากยิ่งขึ้น ดังนั้นเมื่อนำข้อมูลฝนเรดาร์มาใช้ร่วมกับข้อมูลจราจรจึงสนับสนุนผลการคาดการณ์ที่แม่นยำสูงอย่างชัดเจน นอกจากนี้แล้ว เมื่อพิจารณา ผลการวิเคราะห์ Multiclass Confusion Matrix ของผลการพยากรณ์สำหรับเหตุการณ์วันที่ 10 ต.ค. 2567 เวลา 18.30 น. ในรูปที่ 13 ยืนยันว่าแบบจำลอง Traffic + Radar สามารถพยากรณ์ระดับสภาพการจราจรคล่องตัว (สีเขียว) ได้มีความถูกต้องแม่นยำได้มากกว่าแบบจำลอง Traffic เพียงอย่างเดียว โดยมีความโดดเด่นในการพยากรณ์การจราจรระดับความหนาแน่นวิกฤต (สีแดงเข้ม) ด้วยความถูกต้องในระดับสูงเหนือกว่าแบบจำลอง Traffic อย่างมีนัยสำคัญ



รูปที่ 13 Multiclass Confusion Matrix สำหรับเหตุการณ์วันที่ 10 ต.ค. 2567 เวลา 18.30 น. (ก) การนำเข้าข้อมูลการจราจร และ 2) การนำเข้าข้อมูลการจราจรและข้อมูลฝนเรดาร์

เพื่อให้ทราบถึงประสิทธิภาพในการคาดการณ์การจราจร สำหรับเหตุการณ์วันที่ 10 ต.ค. 2567 เวลา 18.30 น. ตามแนวนถนนพหลโยธินในขอบเขตพื้นที่ศึกษา รูปที่ 14 แสดงให้เห็นชัดเจนว่าในเหตุการณ์ดังกล่าว ข้อมูลสภาพจราจรจริง (Ground Truth) จาก Google Traffic อยู่ในระดับสีเขียว สีแดง และสีแดงเข้มเป็นส่วนใหญ่ ซึ่งแบบจำลอง Traffic + Radar คาดการณ์การจราจรตามแนวนอนได้ใกล้เคียงกับข้อมูลสภาพจราจรจริง (Ground Truth) มากกว่าแบบจำลอง Traffic ซึ่งคาดการณ์สภาพจราจรเป็นสีเหลืองเป็นส่วนใหญ่



รูปที่ 14 ตัวอย่างผลการคาดการณ์การจราจร สำหรับเหตุการณ์วันที่ 10 ต.ค. 2567 เวลา 18.30 น. ตามแนวนถนนพหลโยธินในพื้นที่ศึกษา จากแบบจำลอง Traffic และแบบจำลอง Traffic + Radar เทียบกับข้อมูลสภาพจราจรจริง (Ground Truth)

6. สรุปผลการศึกษา

1) ข้อมูลฝนความละเอียดสูงจากเรดาร์ให้ความละเอียดของข้อมูลตามเวลาในทุก 10 นาที และความละเอียดเชิงพื้นที่ในขนาด 600 ม. * 600 ม. ซึ่งได้รับการยอมรับจากงานวิจัยระดับสากลว่าเป็นข้อมูลที่มีคุณภาพและความแม่นยำสูงที่สุดในการนำมาใช้ประเมินฝนความละเอียดสูง อย่างไรก็ตาม ข้อมูลเรดาร์มีความคลาดเคลื่อนได้ในระดับสูงหากไม่ทำการปรับแก้ความคลาดเคลื่อนก่อนนำไปใช้งาน จากผลการศึกษาแสดงให้เห็นว่าเมื่อปรับความคลาดเคลื่อนของเรดาร์ด้วยข้อมูลฝนจากสถานีตรวจวัดภาคพื้นดินแล้ว สามารถเพิ่มความแม่นยำข้อมูลได้สูงถึง 32 เปอร์เซ็นต์ ดังนั้นจึงมีความจำเป็นที่จะต้องทำการควบคุมคุณภาพของข้อมูลฝนเรดาร์ก่อนการนำไปใช้งานเพื่อสนับสนุนกับงานที่เกี่ยวข้องที่ต้องอาศัยปัจจัยจากฝนตกหนักในการพิจารณาพร้อมด้วย ซึ่งจะสามารถส่งเสริมต่อความแม่นยำของการศึกษาต่อเนื่องได้มีประสิทธิภาพเพิ่มขึ้นได้ต่อไป

2) เทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชัน เป็นเทคนิคที่มีประสิทธิภาพสำหรับนำมาใช้ในการคาดการณ์สภาพการจราจรได้ โดยมีความละเอียดของข้อมูลอยู่ที่ 1 พิกเซล/10 เมตร ทั้งนี้การสร้างแบบจำลองที่เหมาะสมทั้งในเรื่องของการกำหนดประเภทและชุดข้อมูลนำเข้า การเตรียมข้อมูลเพื่อนำเข้าสู่แบบจำลอง การสร้างแบบจำลองด้วยการกำหนด Hyperparameters ที่เหมาะสมล้วนมีความสำคัญ เพื่อนำไปสู่การ training และ การ testing แบบจำลองที่มีประสิทธิภาพได้ สำหรับการศึกษาครั้งนี้ได้ค้นพบว่าข้อมูลนำเข้าฝนจากเรดาร์เป็นข้อมูลที่สามารถอธิบายพฤติกรรมของฝนตกหนักได้ตามจริงและเมื่อนำเข้าสู่แบบจำลอง CNN ร่วมกับข้อมูลการจราจรแล้ว สามารถคาดการณ์สถานการณ์ของการจราจรล่วงหน้า 30 นาที ได้แม่นยำกว่าการใช้ข้อมูลนำเข้าจากข้อมูลการจราจรย้อนหลังเพียงอย่างเดียวอย่างชัดเจน ซึ่งแสดงให้เห็นถึงความสอดคล้องของปัจจัยฝนตกหนักที่ส่งผลต่อสภาพการจราจรที่วิกฤตขึ้นได้ อย่างไรก็ตาม การปรับแต่งข้อมูล CNN ให้เหมาะสมกับกระบวนการเรียนรู้ต้องอาศัยชุดข้อมูลจำนวนมากเพื่อนำไปสู่ความแม่นยำที่เพิ่มมากขึ้นและมีความเสถียรเพื่อไปสู่การ

พัฒนาเครื่องมือสำหรับการคาดการณ์สภาพจราจรล่วงหน้าได้ตามเวลาจริงต่อไป

กิตติกรรมประกาศ

ผู้วิจัยขอขอบคุณกรมฝนหลวงและการบินเกษตรที่สนับสนุนข้อมูลเรดาร์ ขอขอบคุณกรมอุตุนิยมวิทยา สถาบันสารสนเทศทรัพยากรน้ำ (องค์การมหาชน) (สสน.) ในการสนับสนุนข้อมูลฝนจากสถานีวัดน้ำฝน ขอขอบคุณ นายศุภกฤษฎ์ เกรียงขจร และนายภาณุรักษ์ จิวรัตน์ ในการให้คำปรึกษา ชี้แนะแนวทางการดำเนินงานวิจัย

เอกสารอ้างอิง

- [1] Lee, J., B. Hong, K. Lee and Y. -J. Jang, (2015), A Prediction Model of Traffic Congestion Using Weather Data, *IEEE International Conference on Data Science and Data Intensive Systems*, Sydney, NSW, Australia, 2015, pp. 81-88, doi: 10.1109/DSDIS.2015.96.
- [2] Medina-Salgado, B., Sanchez-DelaCruz, E., Pozos-Parra, P., & Sierra, J. E. (2022). Urban traffic flow prediction techniques: A review. *Sustainable Computing: Informatics and Systems*, 2022, 35, 100739.
- [3] Jia, Y., J. Wu, Y. Du, G. Qi, (2014) Impacts of rainfall weather on urban traffic in Beijing: analysis and modeling, arXiv preprint arXiv:1407.4522.
- [4] Jia, Y., J. Wu, and M. Xu. Traffic Flow Prediction with Rainfall Impact Using a Deep Learning Method. (2017). *Journal of Advanced Transportation*, Vol. 2017.
- [5] Braz, F.J.; Ferreira, J.; Gonçalves, F.; Weege, K.; Almeida, J.; Baldo, F.; Gonçalves, P. (2022). Road Traffic Forecast Based on Meteorological Information through Deep Learning Methods. *Sensors*, 22, 4485.
- [6] Mapiam, P. P., Sakulnurak, S., Methaprayun, M., Makmee, C., and Marjang, N. (2023). Downscaling the Z-R relationship and bias correction solution for flash flood assessment in a data-scarce basin, Thailand, *Water Science & Technology* Vol. 87 No. 5, 1259-1272.
- [7] Krizhevsky A., Sutskever I. and Hilton G.E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Advances in neural information processing systems*, 25.
- [8] พิมพ์ วิชาประกอบกิจ (2562). การปรับปรุงประสิทธิภาพในการจำแนกภาพด้วยโครงข่ายประสาทแบบคอนโวลูชันโดยใช้เทคนิคการเพิ่มภาพ. *TNI Journal of Engineering and Technology*. Vol. 7 No. 1.
- [9] Conor R., Dearle A., Claydon B. and Vadicamo L. (2024). Correlations of Cross-Entropy Loss in Machine Learning, *entropy*, 26, 491.