

การทำนายข้อมูลจราจรเชิงพื้นที่และเวลาโดยใช้การฝังข้อมูลอุบัติเหตุร่วมกับนิเวศเน็ตเวิร์กเชิงลึก



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต
สาขาวิชาวิทยาศาสตร์คอมพิวเตอร์ ภาควิชาวิศวกรรมคอมพิวเตอร์
คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย
ปีการศึกษา 2561
ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

Spatial-Temporal Traffic Prediction Using Accident Embedding and Deep Neural
Networks



A Thesis Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Science in Computer Science
Department of Computer Engineering
Faculty of Engineering
Chulalongkorn University
Academic Year 2018
Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	การทำนายข้อมูลจราจรเชิงพื้นที่และเวลาโดยใช้การฝังข้อมูลอุบัติเหตุร่วมกับนิเวศเน็ตเวิร์กเชิงลึก
โดย	น.ส.วนิดา ลียงค์
สาขาวิชา	วิทยาศาสตร์คอมพิวเตอร์
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	ผู้ช่วยศาสตราจารย์ ดร.พีรพล เวทีกุล

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้หัวข้อวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

.....	คณบดีคณะวิศวกรรมศาสตร์
(รองศาสตราจารย์ ดร.สุพจน์ เตชวรสินสกุล)	
คณะกรรมการสอบวิทยานิพนธ์	
.....	ประธานกรรมการ
(ศาสตราจารย์ ดร.บุญเสริม กิจศิริกุล)	
.....	อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก
(ผู้ช่วยศาสตราจารย์ ดร.พีรพล เวทีกุล)	
.....	กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.วีระ เหมืองสิน)	
.....	กรรมการภายนอกมหาวิทยาลัย
(ดร.ธนภัทร ชั่งคะจิตร์)	

วนิดา ลียงค์ : การทำนายข้อมูลจราจรเชิงพื้นที่และเวลาโดยใช้การฝังข้อมูลอุบัติเหตุร่วมกับนิเวรอลเน็ตเวิร์กเชิงลึก. (Spatial-Temporal Traffic Prediction Using Accident Embedding and Deep Neural Networks) อ.ที่ปรึกษาหลัก : ผศ. ดร.พีรพล เวทีกุล

ระบบขนส่งและจราจรอัจฉริยะ (Intelligent Transportation System, ITS) นั้น มีความสำคัญเป็นอย่างมากต่อการดำรงชีวิตในปัจจุบัน และเมื่อไม่นานมานี้ เริ่มมีการนำการเรียนรู้เชิงลึก (Deep Learning) มาใช้ในการทำนายข้อมูลจราจรเพื่อช่วยให้มีความแม่นยำมากยิ่งขึ้น อย่างไรก็ตาม ปัญหาสำคัญของการทำนายข้อมูลจราจรในเครือข่ายขนาดใหญ่คือการทำนายล่วงหน้าในหลาย ๆ ช่วงเวลา และทำนายในตำแหน่งที่แตกต่างกัน นอกจากนี้สำหรับการจราจรแล้ว อุบัติเหตุที่เกิดขึ้นนั้นจะส่งผลกระทบต่อจราจรเสมอ การเรียนรู้ถึงผลกระทบที่เกิดขึ้นของอุบัติเหตุจะช่วยให้การทำนายข้อมูลจราจรมีความแม่นยำขึ้น งานวิจัยนี้ จึงนำเสนอนิเวรอลเน็ตเวิร์กที่เรียนรู้ความสัมพันธ์ในเชิงพื้นที่และเวลาของข้อมูลจราจร โดยใช้นิเวรอลเน็ตเวิร์คแบบคอนโวลูชัน (Convolutional Neural Network, CNN) ร่วมกับหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory, LSTM) เพื่อให้สามารถเรียนรู้และทำนายข้อมูลจราจรได้แม่นยำยิ่งขึ้น อีกทั้งยังมีการนำตัวเข้ารหัสอัตโนมัติ (Autoencoder) มาเรียนรู้ข้อมูลอุบัติเหตุ เพื่อให้สามารถเรียนรู้ถึงผลกระทบที่เกิดขึ้นในช่วงที่เกิดอุบัติเหตุไปพร้อม ๆ กันได้

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สาขาวิชา วิทยาศาสตร์คอมพิวเตอร์
ปีการศึกษา 2561

ลายมือชื่อนิสิต
ลายมือชื่อ อ.ที่ปรึกษาหลัก

6070964121 : MAJOR COMPUTER SCIENCE

KEYWORD: traffic prediction, convolutional neural network (CNN), long short-term memory (LSTM), autoencoder

Wanida Liyong : Spatial-Temporal Traffic Prediction Using Accident Embedding and Deep Neural Networks. Advisor: Asst. Prof. PEERAPON VATEEKUL

Nowadays, the Intelligent Transportation System (ITS) is extremely important. Recently, many studies attempt to predict traffic using deep learning approach. The problem is challenging due to various non-linear temporal, different location and difficulty for longer-step ahead prediction. Both spatial and temporal dependencies provide significant implications for traffic prediction. Hence, we propose a combination of deep learning method architectures which consist of Convolutional Neural Networks (CNN) and Long Short-Term Memory (LSTM) to analyze spatial and temporal features and predict traffic speed in multiple steps. In addition, while most of the previously proposed techniques focus on rush-hour, unexpected accidents that affect local traffic were not considered in these works. To improve the prediction, we employ an autoencoder to learn accident embedding input to detect unexpected accidents and their effects with minimizing the prediction error.

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

Field of Study: Computer Science

Student's Signature

Academic Year: 2018

Advisor's Signature

กิตติกรรมประกาศ

การที่วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงไปได้ด้วยดีนั้น นอกจากตัวผู้วิจัยเองแล้ว ยังมีบุคคลท่านอื่นที่เป็นส่วนสำคัญที่ให้ความช่วยเหลือในการทำวิทยานิพนธ์ฉบับนี้ขึ้นมา ผู้จัดทำมีความรู้สึกซาบซึ้งใจเป็นอย่างมากและต้องขอขอบพระคุณบุคคลเหล่านี้ผู้ซึ่งทำให้เกิดผลสำเร็จได้

ขอขอบพระคุณ ผศ. ดร. พีรพล เวทีกุล อาจารย์ที่ปรึกษาวิทยานิพนธ์ ที่คอยให้ความช่วยเหลือและคำแนะนำต่าง ๆ ในการทำวิทยานิพนธ์ฉบับนี้ให้สำเร็จลุล่วงไปได้

ขอขอบพระคุณคณะกรรมการสอบวิทยานิพนธ์ ศ. ดร.บุญเสริม กิจศิริกุล ผศ. ดร.วีระ เหมืองสิน และดร.ธนภัทร ชังคะจิตร ที่ให้คำแนะนำและเสนอสิ่งที่ควรทำเพิ่มเติมในการวิจัยนี้

ขอขอบพระคุณ "มูลนิธิศูนย์ข้อมูลจรรยาบรรณวิชาชีพไทย" และ บริษัท เมตามิเดีย เทคโนโลยี จำกัด สำหรับความอนุเคราะห์ชุดข้อมูลจรรยาบรรณวิชาชีพไทยที่ใช้ในการทดลองในงานวิจัยนี้

ขอขอบพระคุณอาจารย์ทุกท่านที่ได้สอนวิชาต่าง ๆ ให้เกิดความรู้จนสามารถนำมาประกอบการทำวิทยานิพนธ์ฉบับนี้ให้สำเร็จได้ และ เพื่อน ๆ พี่ ๆ น้อง ๆ ทุกคน ที่ได้ให้ความช่วยเหลือ กำลังใจและคำชี้แนะต่าง ๆ

สุดท้ายนี้ ขอขอบพระคุณคุณแม่และครอบครัวที่การสนับสนุนในการเรียนและทำสิ่งต่าง ๆ มาโดยตลอด กราบขอบพระคุณเป็นอย่างสูง

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

วนิดา ลียงค์

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ค
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ฉ
สารบัญรูปภาพ.....	ฐ
บทที่ 1 บทนำ	1
1.1 ที่มาและความสำคัญ.....	1
1.2 วัตถุประสงค์ของงานวิจัย.....	2
1.3 ขอบเขตการวิจัย	2
1.4 ประโยชน์ที่ได้รับ.....	3
1.5 วิธีดำเนินการวิจัย	3
1.6 ผลงานวิจัยที่ตีพิมพ์.....	3
บทที่ 2 ทฤษฎีที่เกี่ยวข้อง.....	5
2.1 ข้อมูลจรรยาจร	5
2.1.1 คำนิยามด้านการจรรยาจร.....	5
2.2 อุบัติเหตุจรรยาจร	6
2.2.1 สาเหตุของการเกิดอุบัติเหตุจรรยาจร.....	6
2.2.2 ผลกระทบของการเกิดอุบัติเหตุจรรยาจร.....	7
2.3 ทฤษฎีความสัมพันธ์	7
2.4 นวัตกรรมเน็ตเวิร์ก.....	8

2.4.1	นิเวรอลเน็ตเวิร์กแบบป้อนไปข้างหน้า (Feed-Forward Neural Network, FFNN)	8
2.4.2	ฟังก์ชันกระตุ้น (Activation Function).....	9
2.4.3	ฟังก์ชันต้นทุน (Cost Function หรือ Loss Function).....	10
2.4.4	การหาค่าที่เหมาะสมที่สุด (Optimization).....	10
2.4.5	การแพร่กระจายย้อนกลับ (Backpropagation)	11
2.4.6	การดรอปเอาต์ (Dropout).....	12
2.5	นิเวรอลเน็ตเวิร์กเชิงลึก.....	12
2.6	นิเวรอลเน็ตเวิร์กคอนโวลูชัน (CNN).....	13
2.6.1	ชั้นคอนโวลูชัน (Convolutional Layer).....	13
2.6.2	ชั้นการรวม (Pooling Layer).....	14
2.6.3	ชั้นการเชื่อมโยงเต็มรูปแบบ (Fully Connected Layer)	15
2.7	นิเวรอลเน็ตเวิร์กแบบวกกลับ.....	15
2.7.1	นิเวรอลเน็ตเวิร์กแบบความจำระยะสั้นแบบยาว (LSTM).....	16
2.8	ตัวเข้ารหัสอัตโนมัติ.....	17
2.9	กลไกความสนใจ.....	18
2.9.1	ค่าความสนใจแบบบวก (Additive Attention).....	19
2.9.2	ค่าความสนใจแบบคูณ (Multiplicative Attention)	19
2.9.3	ค่าความสนใจส่วนตัว (Self-Attention).....	19
2.9.4	ค่าความสนใจแบบโมโนโทนิก (Monotonic Attention).....	19
บทที่ 3	งานวิจัยที่เกี่ยวข้อง	21
3.1	แบบจำลองที่พิจารณาข้อมูลจราจรในเชิงพื้นที่และเวลา	21
3.1.1	งานวิจัยของ Xiaolei Ma และคณะ ที่ใช้ข้อมูลความเร็วจราจรเฉลี่ย มาพิจารณา เสมือนรูปภาพโดยใช้นิเวรอลเน็ตเวิร์กคอนโวลูชัน	21

3.1.2 งานวิจัยของ Jingqing Zhang ที่นำข้อมูลจราจรมาพิจารณา โดยใช้นิวรอลเน็ตเวิร์ก คอนโวลูชัน ร่วมกับหน่วยความจำระยะสั้นแบบยาว	22
3.2 แบบจำลองที่พิจารณาข้อมูลอุบัติเหตุกับการจราจร	24
3.2.1 งานวิจัยของ Rose Yu และคณะ ที่นำข้อมูลอุบัติเหตุ มาพิจารณา.....	24
3.3 ประเด็นที่พบจากงานวิจัยก่อนหน้าและสิ่งที่น่าสนใจในงานวิจัยนี้	25
3.3.1 การเรียนรู้ความสัมพันธ์ของข้อมูลจราจรในเชิงพื้นที่และเวลา.....	25
3.3.2 การเรียนรู้ผลกระทบของอุบัติเหตุ	26
บทที่ 4 แนวคิดในการดำเนินงานและวิธีการที่นำเสนอ	27
4.1 การประมวลผลข้อมูลเบื้องต้น (Data Preprocessing)	27
4.1.1 การเตรียมข้อมูล.....	27
4.1.2 ข้อมูลนำเข้า ส่วนข้อมูลจราจรเชิงเวลา (Temporal Input)	28
4.1.3 ข้อมูลนำเข้า ส่วนข้อมูลจราจรเชิงพื้นที่ (Spatial Input)	28
4.1.4 ข้อมูลอุบัติเหตุฝังตัว (Accident Embedding).....	29
4.2 แบบจำลองที่นำเสนอ (Temporal and Spatial with Attentional Accident Embedding, TSE-Attn)	30
4.2.1 ส่วนการพิจารณาข้อมูลจราจรเชิงเวลา	30
4.2.2 ส่วนการพิจารณาข้อมูลจราจรเชิงพื้นที่.....	31
4.2.3 ส่วนการพิจารณาข้อมูลอุบัติเหตุ	31
4.2.4 ส่วนการทำนายข้อมูลจราจรในหลายช่วงเวลาล่วงหน้า.....	32
บทที่ 5 การทดลองและผลการทดลอง	33
5.1 ชุดข้อมูลที่ใช้ในการทดลอง.....	33
5.1.1 ชุดข้อมูลทางหลวง ประเทศอังกฤษ (Highways England).....	33
5.1.2 ชุดข้อมูลทางด่วน ประเทศไทย (Expressway Thailand)	34
5.2 การสร้างแบบจำลองเพื่อใช้อ้างอิง	36

5.2.1	แบบจำลอง ARIMA (Autoregressive Integrated Moving Average Model)	36
5.2.2	แบบจำลองที่พิจารณาเพียงข้อมูลความเร็วจราจรเฉลี่ยในเชิงเวลา (Temporal,T)....	36
5.2.3	แบบจำลองที่พิจารณาเพียงข้อมูลความเร็วจราจรเฉลี่ยในเชิงพื้นที่และเวลา (Temporal and Spatial, TS).....	36
5.2.4	แบบจำลองที่พิจารณาเพียงข้อมูลความเร็วจราจรเฉลี่ยในเชิงเวลา และข้อมูลอุบัติเหตุ (Temporal and Accident Embedding, TE).....	37
5.2.5	แบบจำลองที่พิจารณาเพียงข้อมูลความเร็วจราจรเฉลี่ยในเชิงพื้นที่และเวลา และข้อมูล อุบัติเหตุ (Temporal and Accident Embedding, TSE).....	38
5.3	การวัดผล.....	38
5.3.1	ค่าเฉลี่ยของค่าสัมบูรณ์ของเปอร์เซ็นต์ของความคลาดเคลื่อน (Mean absolute percent error, MAPE).....	38
5.4	ระบบที่ใช้ทดลอง.....	39
5.4.1	การแบ่งชุดข้อมูล.....	39
5.4.2	วิธีการสอนนิรอลเน็ตเวิร์ก.....	39
5.5	ผลการทดลอง.....	40
5.5.1	เปรียบเทียบผลการทดลองโดยรวม	40
5.5.2	เปรียบเทียบประสิทธิภาพส่วนข้อมูลจราจรเชิงเวลา.....	41
5.5.3	เปรียบเทียบประสิทธิภาพส่วนข้อมูลจราจรเชิงพื้นที่.....	45
5.5.4	เปรียบเทียบประสิทธิภาพส่วนข้อมูลอุบัติเหตุ	47
บทที่ 6	สรุปผลการวิจัยและแนวทางการวิจัยในขั้นถัดไป.....	51
6.1	สรุปผลการวิจัย.....	51
6.2	แนวทางการวิจัยถัดไป	51
6.2.1	ส่วนการพิจารณาข้อมูลจราจร.....	51
6.2.2	ส่วนการพิจารณาข้อมูลอุบัติเหตุ	52
บรรณานุกรม.....		53

รายการอ้างอิง	54
ภาคผนวก.....	56
ประวัติผู้เขียน.....	61



สารบัญตาราง

	หน้า
ตารางที่ 1 แผนการดำเนินงาน	4
ตารางที่ 2 การแบ่งชุดข้อมูล.....	39
ตารางที่ 3 ผลการทดลองโดยรวม สำหรับชุดข้อมูลอังกฤษ	40
ตารางที่ 4 ผลการทดลองโดยรวม สำหรับชุดข้อมูลไทย	41
ตารางที่ 5 ผลการทดลองเปรียบเทียบ เมื่อไม่ใช้ข้อมูลวันของสัปดาห์ในส่วนข้อมูลเชิงเวลา สำหรับชุดข้อมูลอังกฤษ.....	41
ตารางที่ 6 ผลการทดลองเปรียบเทียบ เมื่อไม่ใช้ข้อมูลวันของสัปดาห์ในส่วนข้อมูลเชิงเวลา สำหรับชุดข้อมูลไทย.....	42
ตารางที่ 7 ผลการทดลองเปรียบเทียบ (MAPE) เมื่อใช้ข้อมูลวันพิเศษแทนวันของสัปดาห์ในส่วนข้อมูลเชิงเวลา สำหรับชุดข้อมูลอังกฤษ.....	42
ตารางที่ 8 ผลการทดลองเปรียบเทียบ (MAPE) เมื่อใช้ข้อมูลวันพิเศษแทนวันของสัปดาห์ในส่วนข้อมูลเชิงเวลา สำหรับชุดข้อมูลไทย.....	43
ตารางที่ 9 ผลการทดลองเปรียบเทียบ (MAPE) เฉพาะวันพิเศษ ระหว่างการใช้วันของสัปดาห์ และวันพิเศษในส่วนข้อมูลเชิงเวลา สำหรับชุดข้อมูลอังกฤษ	43
ตารางที่ 10 ผลการทดลองเปรียบเทียบ (MAPE) เฉพาะวันพิเศษ ระหว่างการใช้วันของสัปดาห์ และวันพิเศษในส่วนข้อมูลเชิงเวลา สำหรับชุดข้อมูลไทย.....	44
ตารางที่ 11 ผลการทดลองเปรียบเทียบ เมื่อใช้ข้อมูลค่าต่ำสุดและค่าสูงสุดในส่วนข้อมูลเชิงเวลา สำหรับชุดข้อมูลไทย.....	45
ตารางที่ 12 ผลการทดลองเมื่อใช้ค่าสัมประสิทธิ์สหสัมพันธ์แบบต่าง ๆ ในส่วนข้อมูลเชิงพื้นที่ สำหรับชุดข้อมูลอังกฤษ.....	46
ตารางที่ 13 ผลการทดลองเมื่อใช้ค่าสัมประสิทธิ์สหสัมพันธ์แบบต่าง ๆ ในส่วนข้อมูลเชิงพื้นที่ สำหรับชุดข้อมูลไทย.....	46
ตารางที่ 14 ผลการทดลองเปรียบเทียบ (MAPE) เฉพาะกรณีเกิดอุบัติเหตุ สำหรับชุดข้อมูลอังกฤษ	48

ตารางที่ 15 ผลการทดลองเปรียบเทียบ (MAPE) เฉพาะกรณีเกิดอุบัติเหตุ สำหรับชุดข้อมูลไทย	48
ตารางที่ 16 ผลการทดลองเมื่อใช้ข้อมูลรายงาน สำหรับชุดข้อมูลอังกฤษ	49
ตารางที่ 17 ผลการทดลองเมื่อใช้กลไกความสนใจ สำหรับข้อมูลประเทศอังกฤษ	50
ตารางที่ 18 ผลการทดลองเมื่อใช้กลไกความสนใจ สำหรับชุดข้อมูลไทย	50
ตารางที่ 19 รายละเอียดของตัวตรวจด้วยรูปแบบทางหลวงของประเทศอังกฤษ 52 โหนด	56
ตารางที่ 20 รายละเอียดของตัวตรวจด้วยรูปแบบทางด่วนของประเทศไทย 45 โหนด	58



สารบัญรูปภาพ

	หน้า
รูปที่ 1 โครงสร้างนิวยอร์กเน็ตเวิร์กแบบป้อนไปข้างหน้า	8
รูปที่ 2 โครงสร้างของนิวยอร์กเน็ตเวิร์กคอนโวลูชัน	13
รูปที่ 3 การทำคอนโวลูชันแบบกว้าง	14
รูปที่ 4 ตัวอย่างขนาดของการก้าวข้ามที่มีค่า 2	14
รูปที่ 5 ขั้นตอนการเลือกค่าที่มากที่สุดในชั้นการรวม	15
รูปที่ 6 โครงสร้างชั้นการเชื่อมโยงเต็มรูปแบบ	15
รูปที่ 7 โครงสร้างนิวยอร์กเน็ตเวิร์กแบบวนกลับ	16
รูปที่ 8 โครงสร้างของหน่วยความจำระยะสั้นแบบยาว	17
รูปที่ 9 โครงสร้างของตัวเข้ารหัสอัตโนมัติ	18
รูปที่ 10 โครงสร้างของกลไกความสนใจแบบโมโนโทนิก	20
รูปที่ 11 เมตริกซ์ 2 มิติ ที่แสดงความสัมพันธ์ในเชิงพื้นที่และเวลาของการจราจร	21
รูปที่ 12 ขั้นตอนการแปลงความเร็วจราจรเฉลี่ยให้เป็นรูปภาพจราจร	22
รูปที่ 13 โครงสร้างของนิวยอร์กเน็ตเวิร์กคอนโวลูชันที่ใช้เรียนรู้ข้อมูลรูปภาพจราจร	22
รูปที่ 14 โครงสร้างของแบบจำลองที่พิจารณาเฉพาะความสัมพันธ์ในเชิงเวลาของข้อมูล	23
รูปที่ 15 โครงสร้างของแบบจำลองที่พิจารณาความสัมพันธ์ของข้อมูลทั้งในเชิงพื้นที่และเวลา	24
รูปที่ 16 โครงสร้างของแบบจำลองหน่วยความจำระยะสั้นแบบยาวร่วมกับตัวเข้ารหัสอัตโนมัติแบบหลายชั้น	24
รูปที่ 17 โครงสร้างของแบบจำลองที่สามารถเรียนรู้ข้อมูลจราจรทั้งในช่วงเวลาปกติและช่วงเวลาที่เกิดอุบัติเหตุไปพร้อม ๆ กันได้	25
รูปที่ 18 ข้อมูลนำเข้า ส่วนข้อมูลจราจรในเชิงเวลา	28
รูปที่ 19 ตัวอย่างค่าสัมประสิทธิ์สหสัมพันธ์ของข้อมูลจราจรแต่ละโหนด เทียบกับโหนดอื่น ๆ ในเครือข่าย	29

รูปที่ 20 ข้อมูลนำเข้า ส่วนข้อมูลจราจรในเชิงพื้นที่	29
รูปที่ 21 ข้อมูลนำเข้า ส่วนข้อมูลอุบัติเหตุ สำหรับส่วนเข้ารหัส (Encoder) ของตัวเข้ารหัสอัตโนมัติ30	
รูปที่ 22 ข้อมูลนำเข้า ส่วนข้อมูลอุบัติเหตุ สำหรับส่วนถอดรหัส (Decoder) ของตัวเข้ารหัสอัตโนมัติ	
.....	30
รูปที่ 23 โครงสร้างส่วนการพิจารณาข้อมูลจราจรเชิงเวลา (Temporal)	30
รูปที่ 24 โครงสร้างส่วนการพิจารณาข้อมูลจราจรเชิงพื้นที่ (Spatial)	31
รูปที่ 25 โครงสร้างส่วนการพิจารณาข้อมูลอุบัติเหตุ (Accident Embedding)	31
รูปที่ 26 โครงสร้างส่วนการพิจารณาข้อมูลอุบัติเหตุร่วมกับกลไกความสนใจ (Attentional Accident Embedding)	32
รูปที่ 27 แบบจำลองที่นำเสนอ (TSE-Attn)	32
รูปที่ 28 โหนดตัวตรวจด้วยลูปที่เลือกใช้ในข้อมูลจราจรบนทางหลวงของประเทศไทย	33
รูปที่ 29 แสดงตัวอย่างการคัดเลือกข้อมูลอุบัติเหตุจากวิดีโอของถนนบนทางหลวงของประเทศไทย	
อังกฤษ	34
รูปที่ 30 โหนดตัวตรวจด้วยลูปที่เลือกใช้ในข้อมูลจราจรบนทางด่วนของประเทศไทย	35
รูปที่ 31 ตัวอย่างข้อมูลอุบัติเหตุที่ได้จากรายงานของชุดข้อมูลทางด่วนประเทศไทย	35
รูปที่ 32 โครงสร้างของแบบจำลองที่พิจารณาเพียงข้อมูลความเร็วจราจรเฉลี่ยในเชิงเวลา (T)	36
รูปที่ 33 โครงสร้างของแบบจำลองที่พิจารณาเพียงข้อมูลความเร็วจราจรเฉลี่ยในเชิงพื้นที่และเวลา (TS)	37
รูปที่ 34 โครงสร้างของแบบจำลองที่พิจารณาเพียงข้อมูลความเร็วจราจรเฉลี่ยในเชิงเวลา และข้อมูลอุบัติเหตุ (TE)	37
รูปที่ 353 โครงสร้างของแบบจำลองที่พิจารณาเพียงข้อมูลความเร็วจราจรเฉลี่ยในเชิงพื้นที่และเวลา และข้อมูลอุบัติเหตุ (TSE)	38
รูปที่ 36 กราฟแสดงผลการทำนาย เมื่อเปรียบเทียบวิธีการเลือกโหนดในส่วนข้อมูลจราจรเชิงพื้นที่	
แบบต่าง ๆ	47
รูปที่ 37 ตัวอย่างข้อมูลโหนดก่อนหน้าและโหนดถัดไปที่ส่งผลต่อแบบจำลอง	47

รูปที่ 38 กราฟแสดงจำนวนอุบัติเหตุที่เกิด เมื่อเปรียบเทียบข้อมูลจากทวิตเตอร์กับข้อมูลจากรายงาน
ของข้อมูลจราจรประเทศไทย 49



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญ

“ความแออัดของการจราจร หมายถึง ปรากฏการณ์ด้านการขนส่งที่เกิดขึ้นเมื่อมีการใช้การขนส่ง เช่น ถนน สะพาน ทางหลวง สนามบิน ท่าเรือ จนใกล้ความจุสูงสุดของพื้นฐานการขนส่งเหล่านั้น” (จุฑา มนัสไพบุลย์ และคณะ, 2537) โดยการเพิ่มขึ้นของยานพาหนะบนท้องถนนอย่างต่อเนื่อง ส่งผลให้สภาพความแออัดของการจราจรในปัจจุบันมีแนวโน้มสูงขึ้น และการทำนายสภาพการจราจรล่วงหน้า กลายเป็นหัวข้อของระบบขนส่งอัจฉริยะ (Intelligent Transport System, ITS) ที่ได้รับความสนใจอย่างมาก การจราจรที่มีความแออัดมาก จะทำให้ต้องใช้เวลาเพิ่มขึ้นในการเดินทาง การทำนายสภาพการจราจรล่วงหน้าได้นั้น จะช่วยให้ผู้ขับขี่และผู้ใช้ถนน สามารถวางแผนการเดินทางเพื่อประหยัดค่าใช้จ่าย ประหยัดเวลาที่ใช้ในการเดินทางลง และพิจารณาความปลอดภัย เพื่อให้การเดินทางนั้นมีประสิทธิภาพมากที่สุดได้

ความเร็วจราจรเฉลี่ย เป็นปัจจัยสำคัญหนึ่งที่ใช้ในระบบขนส่งอัจฉริยะ เช่น ระบบนำทางอัจฉริยะ (Navigation Systems) ระบบการควบคุมและบริหารจัดการจราจร (Advance Traffic Management System, ATMS) และอื่น ๆ เนื่องจากหากเราสามารถทราบความเร็วจราจรเฉลี่ยของถนนในแต่ละพื้นที่แล้วนั้น จะทำให้เราประมาณเวลาที่ใช้ในการเดินทางและคำนวณสภาพความแออัดของการจราจรได้ และสำหรับข้อมูลทางด้านจราจรนั้น ถือเป็นข้อมูลที่อยู่ในระบบสารสนเทศภูมิศาสตร์ เนื่องจากถือเป็นข้อมูลเชิงพื้นที่ (Spatial Data) ที่อ้างอิงด้วยระบบพิกัดทางภูมิศาสตร์ (Geographic Coordinates) เชื่อมโยงเข้ากับข้อมูลเชิงบรรยาย (Attribute Data) ซึ่งมีกระแสการเปลี่ยนแปลงเป็นอนุกรมเวลา (Time Series) ทำให้มีคุณลักษณะสำคัญในเชิงพื้นที่และเวลา โดยเป็นคุณสมบัติเด่นที่ใช้ในการเรียนรู้และช่วยเพิ่มประสิทธิภาพในการทำนายความเร็วจราจรเฉลี่ยได้ แต่นอกเหนือจากคุณลักษณะพิเศษดังกล่าว ปัญหาสำคัญของการทำนายความเร็วจราจรเฉลี่ยที่พบคือ ยังไม่สามารถทำนายได้แม่นยำนักในช่วงเวลาที่เกิดเหตุการณ์พิเศษ เช่น อุบัติเหตุจราจร เนื่องจากอุบัติเหตุเป็นสิ่งที่เกิดขึ้นโดยไม่ได้คาดการณ์ล่วงหน้า แต่กลับส่งผลกระทบต่อสภาพการจราจร ณ ขณะนั้น ให้เกิดการติดขัดได้ [1]

ในปัจจุบัน การทำนายข้อมูลจราจรโดยวิธีการทางด้านการเรียนรู้เชิงลึก (Deep Learning) ซึ่งกำลังเป็นที่นิยมอยู่ในปัจจุบัน เนื่องจากความสามารถในการเรียนรู้และให้ผลลัพธ์ที่ดีขึ้น เช่น หน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory, LSTM) ซึ่งเป็นแบบจำลองสำหรับข้อมูลที่มีลักษณะเป็นอนุกรมเวลา ดังเช่นข้อมูลจราจร โดยมีงานวิจัยก่อนหน้า [2-6] ที่พบว่า ให้ผลลัพธ์ในการทำนายความเร็วจราจรเฉลี่ยได้ผิดพลาดน้อยกว่าวิธีอื่น ๆ หรือ นิวรอลเน็ตเวิร์กคอนโวลูชัน

ชั้น (Convolutional Neural Network, CNN) ที่ใช้ความสัมพันธ์เชิงพื้นที่และเวลาของข้อมูลจราจร มาช่วยในการทำนาย [7] และการใช้ร่วมกันระหว่างนิเวศน์ตเว็ร็กคอนโวลูชันและหน่วยความจำระยะสั้นแบบยาว [8-9] เพื่อเพิ่มประสิทธิภาพในการทำนายข้อมูลจราจร

ดังนั้น ในงานวิจัยฉบับนี้ จะนำเสนอแนวทางในการพัฒนาการใช้วิธีการทางด้านการเรียนรู้เชิงลึก มาวิเคราะห์ข้อมูลจราจร เพื่อให้สามารถทำนายความความเร็วจราจรเฉลี่ยโดยใช้ความสัมพันธ์ในเชิงพื้นที่และเวลา โดยให้สามารถทำนายล่วงหน้าได้หลาย ๆ ช่วงเวลาเพื่อให้เกิดประโยชน์ต่อการใช้งานจริง และนำข้อมูลอุบัติเหตุที่เกิดขึ้นมาพิจารณาเพื่อให้ได้การทำนายที่ผิดพลาดน้อยลง โดยทำนายทั้งในช่วงเวลาจราจรปกติและขณะที่เกิดอุบัติเหตุไปพร้อม ๆ กันได้

1.2 วัตถุประสงค์ของงานวิจัย

เพื่อนำเสนอวิธีการทำนายความเร็วจราจรเฉลี่ยของการจราจร โดยใช้แบบจำลองการเรียนรู้เชิงลึกที่พิจารณาความสัมพันธ์เชิงพื้นที่และเวลาร่วมกับการใช้ข้อมูลอุบัติเหตุ เพื่อลดความผิดพลาดของการทำนาย โดยมุ่งเน้นที่การปรับปรุงแบบจำลองการเรียนรู้เชิงลึกให้สามารถวิเคราะห์และทำนายทั้งช่วงเวลาที่มีการจราจรปกติและเวลาที่เกิดอุบัติเหตุหรือเหตุการณ์ที่ผิดปกติไปพร้อมกันได้ อีกทั้งยังสามารถทำนายล่วงหน้าได้หลาย ๆ ช่วงเวลา

1.3 ขอบเขตการวิจัย

- 1) งานวิจัยฉบับนี้ครอบคลุมการทำนายข้อมูลจราจร เฉพาะการจราจรทางบกเท่านั้น
- 2) งานวิจัยฉบับนี้ครอบคลุมข้อมูลอุบัติเหตุ เฉพาะกรณีที่เกิดอุบัติเหตุและการปิดการจราจรเท่านั้น
- 3) ข้อมูลจราจรที่ใช้ในงานวิจัยนี้ คือ ข้อมูลความเร็วจราจรเฉลี่ย ซึ่งมาจากทางหลวงของประเทศอังกฤษ และทางด่วนของประเทศไทย
- 4) ข้อมูลอุบัติเหตุที่ใช้งานวิจัยนี้ คือ ข้อมูลข้อความจากทวีตเตอร์ ซึ่งแสดงอุบัติเหตุบนทางหลวงของประเทศอังกฤษ และรายงานข้อความอุบัติเหตุบนทางด่วนของประเทศไทย
- 5) ทำการวัดประสิทธิภาพแบบจำลอง โดยการพิจารณาค่าความคลาดเคลื่อนเฉลี่ยจากการทำนายในแต่ละช่วงเวลาล่วงหน้า
- 6) เปรียบเทียบประสิทธิภาพของแบบจำลอง โดยใช้การเปรียบเทียบผลลัพธ์จากการพิจารณาข้อมูลในเชิงพื้นที่ หรือเชิงเวลาเพียงอย่างเดียว และการใช้ข้อมูลในเชิงพื้นที่และเวลาร่วมกับข้อมูลอุบัติเหตุร่วมกัน

1.4 ประโยชน์ที่ได้รับ

- 1) ลดความคลาดเคลื่อนของการทำนายข้อมูลจราจรได้
- 2) สามารถพิจารณาข้อมูลจราจรทั้งในเชิงพื้นที่และเวลา
- 3) สามารถพิจารณาข้อมูลจราจรทั้งในเวลาที่เกิดการจราจรปกติ และขณะที่เกิดอุบัติเหตุไปพร้อมกันได้
- 4) สามารถนำกรอบงานวิจัยนี้ไปประยุกต์ใช้กับข้อมูลอื่น ๆ ที่มีความสัมพันธ์ในเชิงพื้นที่และเวลา เช่นเดียวกับข้อมูลจราจรได้

1.5 วิธีดำเนินการวิจัย

- 1) ศึกษาเกี่ยวกับข้อมูลจราจรและอุบัติเหตุ
- 2) ศึกษาทฤษฎีและงานวิจัยที่เกี่ยวข้อง
- 3) ศึกษาเกี่ยวกับโครงข่ายประสาทเทียมและการเรียนรู้เชิงลึกที่ใช้ในการทำนายข้อมูล
- 4) เก็บรวบรวมข้อมูลและออกแบบการทดลอง
- 5) ทดลองตามสิ่งที่น่าสนใจ และสรุปผลการทดลองทั้งหมด
- 6) เขียนบทความเพื่อตีพิมพ์ผลงานทางวิชาการ
- 7) สอบหัวข้อวิทยานิพนธ์
- 8) สรุปผลและเรียบเรียงวิทยานิพนธ์
- 9) สอบวิทยานิพนธ์

1.6 ผลงานวิจัยที่ตีพิมพ์ จุฬาลงกรณ์มหาวิทยาลัย

“Improve Traffic Prediction Using Accident Embedding on Ensemble Deep Neural Networks” โดย วนิตา ลียงค์ และ พีรพล เวทีกุล ในงานประชุมวิชาการ “The 2019 - 11th International Conference on Knowledge and Smart Technology (KST-2019)” ซึ่งจัดขึ้น ณ โรงแรมโนโวเทล ภูเก็ต วินเทจ ปาร์ค จังหวัดภูเก็ต ประเทศไทย ระหว่างวันที่ 23 -26 มกราคม 2562

“Traffic Prediction Using Attentional Spatial-Temporal Deep Learning with Accident Embedding” โดย วนิตา ลียงค์ และ พีรพล เวทีกุล ในงานประชุมวิชาการ “2019 the 4th International Conference on Computational Intelligence and Applications (ICCIA 2019)” ซึ่งจัดขึ้น ณ มหาวิทยาลัยหนานชาง มณฑลเจียงซี ประเทศจีน ระหว่างวันที่ 21 -23 มิถุนายน 2562

ตารางที่ 1 แผนการดำเนินงาน

การดำเนินงาน	2561												2562							
	1	2	3	4	5	6	7	8	9	10	11	12	1	2	3	4	5	6	7	
1. ศึกษาเกี่ยวกับข้อมูลจราจรและอุบัติเหตุ																				
2. ศึกษาทฤษฎีและงานวิจัยที่เกี่ยวข้อง																				
3. ศึกษาเกี่ยวกับโครงข่ายประสาทเทียมและการเรียนรู้เชิงลึกที่ใช้ในการทำข้อมูล																				
4. เก็บรวบรวมข้อมูลและออกแบบการทดลอง																				
5. ทดลองตามสิ่งที่นำเสนอ และสรุปผลการทดลองทั้งหมด																				
6. เขียนบทความเพื่อตีพิมพ์ผลงานทางวิชาการ																				
7. สอบวิทยานิพนธ์																				
8. สรุปผลและเขียนเรียงวิทยานิพนธ์																				
9. สอบวิทยานิพนธ์																				

บทที่ 2

ทฤษฎีที่เกี่ยวข้อง

ทฤษฎีที่เกี่ยวข้องกับงานวิจัยชิ้นนี้แบ่งออกได้เป็น 5 หัวข้อได้แก่ ข้อมูลจราจร อุบัติเหตุจราจร ทฤษฎีความสัมพันธ์ นิวรอลเน็ตเวิร์ก และนิวรอลเน็ตเวิร์กเชิงลึก

2.1 ข้อมูลจราจร

ข้อมูลจราจร ถือเป็นข้อมูลที่อยู่ในระบบสารสนเทศภูมิศาสตร์ เนื่องจากถือเป็นข้อมูลเชิงพื้นที่ (Spatial Data) ที่อ้างอิงด้วยระบบพิกัดทางภูมิศาสตร์ (Geographic Coordinates) เชื่อมโยงเข้ากับคุณลักษณะ หรือข้อมูลเชิงบรรยาย (Attribute Data) เพื่อประโยชน์ในการวิเคราะห์ข้อมูลและนำเสนอข้อมูลเชิงพื้นที่หรือการถ่ายทอดความรู้เกี่ยวกับพื้นผิวโลกในรูปแบบของแผนที่ (Map) ตามวัตถุประสงค์ของผู้ใช้งานในด้านต่าง ๆ เช่น แผนที่ภูมิประเทศ แผนที่ภูมิอากาศ เป็นต้น โดยมีค่านิยามต่าง ๆ ดังต่อไปนี้

2.1.1 คำนิยามด้านการจราจร

ก) ระยะเวลาการเดินทาง (Travel-time)

ระยะเวลาที่รถใช้ในการเคลื่อนที่จากจุดหนึ่งไปยังอีกจุดหนึ่งบนถนน

ข) ความเร็วเฉลี่ย (Time-mean speed)

ความเร็วเฉลี่ย $\bar{\mu}_t$ ของรถต่าง ๆ ที่จุดหนึ่งบนถนน ณ ช่วงเวลาหนึ่ง ซึ่งความเร็วเฉลี่ยนี้มักได้มาจากการวัดความเร็วรถที่วิ่งผ่านจุดคงที่บนถนน จึงสัมพันธ์กับจุด ๆ หนึ่งบนถนน ซึ่งสามารถคำนวณได้จากสมการ

$$\bar{\mu}_t = \frac{\sum v_i}{n} \quad (2.1)$$

เมื่อ v_i คือ ความเร็วเฉพาะจุดของรถคันที่ i

n คือ จำนวนรถของ ณ จุดที่ทำการวัดความเร็ว

ค) ความเร็วเฉลี่ยบนช่วงถนน (Space-mean speed)

ความเร็วเฉลี่ยของรถในการเดินทางบนช่วงถนนช่วงหนึ่ง ความเร็วเฉลี่ยบนช่วงถนน $\bar{\mu}_s$ จะได้มาจากการจับเวลาในการเดินทางระหว่างจุดสองจุดของรถต่าง ๆ ด้วย Loop Detector โดยสามารถคำนวณได้จาก

$$\bar{\mu}_s = \frac{d}{\frac{\sum t_i}{n}} \quad (2.2)$$

เมื่อ d คือ ความยาวของถนน

t_i คือ เวลาการเดินทางบนช่วงถนนของรถคันที่ i

2.2 อุบัติเหตุจราจร

“อุบัติเหตุ” หมายถึงเหตุการณ์ที่เกิดขึ้นอย่างไม่คาดหวังและไม่ตั้งใจในเวลาและสถานที่แห่งหนึ่ง โดยไม่มีสิ่งบอกเหตุล่วงหน้า แต่มีสาเหตุและส่งผลกระทบต่อที่สามารถชีวิตได้ โดยเป็นผลเชิงลบของความเป็นไปได้บางอย่างหนึ่ง ซึ่งควรจะหลีกเลี่ยงหรือป้องกันไว้ตั้งแต่แรก โดยพิจารณาจากปัจจัยสาเหตุต่าง ๆ อันจะนำไปสู่การเกิดอุบัติเหตุ สำหรับ “อุบัติเหตุจราจร” นั้น หมายถึงรวมถึงการขับชนกันระหว่างยานพาหนะ ซึ่งทำให้เกิดความเสียหายในชีวิตและทรัพย์สิน อันนำไปสู่ความเจ็บ พิการ และเสียชีวิตได้

2.2.1 สาเหตุของการเกิดอุบัติเหตุจราจร

องค์ประกอบของการเกิดอุบัติเหตุจราจร มีปัจจัยประกอบกันทั้งหมด 4 ส่วน คือ คน ยานพาหนะ ถนน และสิ่งแวดล้อม ซึ่งองค์ประกอบแต่ละส่วนมีปัจจัยที่ส่งผลให้เกิดอุบัติเหตุโดยตรง และในบางส่วนเกิดจากปัจจัยที่เกิดขึ้นร่วมกัน ดังรายละเอียดต่อไปนี้

1) องค์ประกอบด้านคน

องค์ประกอบด้านคนหรือผู้ใช้ถนน ประกอบด้วยผู้ขับขี่และคนเดินเท้า ซึ่งผู้ขับขี่มีส่วนเกี่ยวข้องกับการเกิดอุบัติเหตุโดยตรง เพราะเป็นผู้ควบคุมยานพาหนะในสถานการณ์ต่าง ๆ รวมถึงการบังคับรถเพื่อหลีกเลี่ยงการเกิดอุบัติเหตุและการเป็นสาเหตุของการเกิดอุบัติเหตุเพราะการขาดวินัยจราจร การขับชี่ยานพาหนะขณะมีเม้าหรือง่วงนอน และการขับรถเร็ว สำหรับคนเดินเท้านั้น คือผู้อาศัยถนนและทางเท้าในการสัญจรไปมา การเกิดอุบัติเหตุกับคนเดินเท้านั้น ส่วนใหญ่มักเกิดจากการขาดวินัย โดยยึดถือความสะดวกสบายในการใช้ถนนเป็นสำคัญ

2) องค์ประกอบด้านยานพาหนะ

เป็นองค์ประกอบที่สำคัญที่มีผลต่อการเกิดอุบัติเหตุโดยตรง โดยเฉพาะยานพาหนะที่ไม่ได้มาตรฐาน ไม่มีอุปกรณ์ด้านความปลอดภัยที่ดี และยานพาหนะที่มีสภาพชำรุดบกพร่อง ขาดการบำรุงรักษาที่ดีก่อนการใช้งาน

3) องค์ประกอบด้านถนน

ถนนที่อยู่ในสภาพที่ดี ไม่ชำรุด และถูกออกแบบมาอย่างปลอดภัย จะช่วยให้ผู้ใช้ถนนมีความปลอดภัย แต่หากเป็นสภาวะการณ์ที่ถนนมีความบกพร่องไป เช่น มีจุดตัดแยกที่ไม่เหมาะสม มีหลุมบ่อ หรือผิวถนนลื่น มีการบดบังจากป้ายข้างทาง เป็นต้น สาเหตุเหล่านี้ มักส่งผลต่อการเกิดอุบัติเหตุได้โดยตรง

4) องค์ประกอบด้านสิ่งแวดล้อม

เป็นองค์ประกอบสำคัญที่ส่งผลต่อการเกิดอุบัติเหตุ โดยส่วนใหญ่แล้วจะเกิดจากปัจจัยทางธรรมชาติเป็นสำคัญ เช่น ลักษณะทางภูมิศาสตร์ของแต่ละพื้นที่ สภาพดินฟ้าอากาศ นอกจากนี้อาจจะมีสาเหตุมาจากการกระทำของมนุษย์ได้อีกด้วย เช่น การเผาไฟ การสร้างสิ่งปลูกสร้างบดบังสายตา เป็นต้น

2.2.2 ผลกระทบของการเกิดอุบัติเหตุจราจร

ผลกระทบหลักของอุบัติเหตุจราจร คือ ความสูญเสียที่มีต่อทั้งชีวิตและทรัพย์สิน รวมถึงความสูญเสียโอกาสทางเศรษฐกิจจากการเสียเวลาในการเดินทางเนื่องจากการจราจรติดขัดในช่วงเวลาที่เกิดอุบัติเหตุ

2.3 ทฤษฎีความสัมพันธ์

สำหรับตัวแปร 2 ตัวแปรที่เป็นตัวแปรเชิงปริมาณ ถ้าหากตัวแปรเชิงปริมาณทั้งคู่มีความสัมพันธ์กันเชิงเส้นตรง ซึ่งจะใช้การวัดความสัมพันธ์ระหว่าง 2 ตัวแปร ด้วยค่าสัมประสิทธิ์สหสัมพันธ์ โดยวิธีที่เป็นที่นิยมนำไปใช้มากที่สุดคือ การคำนวณหาสัมประสิทธิ์สหสัมพันธ์แบบเพียร์สัน (Pearson correlation coefficient, R) ซึ่งสามารถคำนวณได้จากสมการดังต่อไปนี้

$$R = \frac{n(\sum X_i Y_i) - (\sum X_i)(\sum Y_i)}{\sqrt{(n(\sum X_i^2) - (\sum X_i)^2)(n(\sum Y_i^2) - (\sum Y_i)^2)}} \quad (2.3)$$

เมื่อ R คือ สัมประสิทธิ์สหสัมพันธ์แบบเพียร์สันระหว่าง X และ Y ของตัวอย่าง

n คือ จำนวนคู่ของตัวอย่าง

X_i คือ ตัวแปรอิสระค่าที่ i

Y_i คือ ตัวแปรตามค่าที่ i

การคำนวณหาสัมประสิทธิ์สหสัมพันธ์แบบเพียร์สัน หรือบางครั้งเรียกว่า สหสัมพันธ์อย่างง่าย (Simple correlation) โดยการหาความสัมพันธ์ระหว่างตัวแปรนั้น มักจะใช้สัญลักษณ์ของตัวแปรเป็นตัวแปร X กับ Y โดยค่าสัมประสิทธิ์สหสัมพันธ์แบบเพียร์สัน จะมีคุณสมบัติดังนี้

- เป็นการวัดความสัมพันธ์เชิงเส้น โดยจะมีค่าอยู่ระหว่าง -1 ถึง 1
- มีลักษณะเหมือนความชันของเส้นการถดถอย
- ค่าสัมประสิทธิ์สหสัมพันธ์จะไม่เปลี่ยนแปลง เมื่อตัวแปรอิสระและตัวแปรตามเปลี่ยนแปลงแบบเดียวกัน
- ค่าสัมประสิทธิ์สหสัมพันธ์จะไม่เปลี่ยนแปลง ถ้าค่าสเกลของตัวแปรใดตัวแปรหนึ่งเปลี่ยนแปลงไป

- มีการแจกแจงแบบเดียวกันกับแบบที (T distribution)

และค่าสัมประสิทธิ์สหสัมพันธ์จะมีทิศทางของความสัมพันธ์อยู่ด้วยกัน 3 แบบ คือ

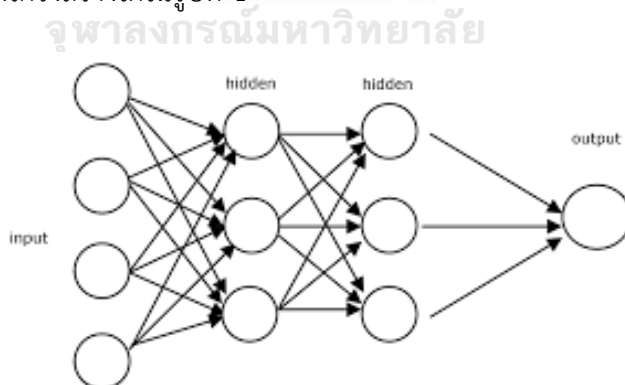
- 1) สหสัมพันธ์ทางบวก (Positive Correlations) ซึ่งหมายถึง เมื่อตัวแปรใดตัวแปรหนึ่งเพิ่มขึ้นหรือลดลง อีกตัวแปรหนึ่งจะเพิ่มขึ้นหรือลดลงไปด้วย
- 2) สหสัมพันธ์ทางลบ (Negative Correlations) ซึ่งหมายถึง เมื่อตัวแปรใดตัวแปรหนึ่งเพิ่มขึ้นหรือลดลง อีกตัวแปรหนึ่งจะเพิ่มขึ้นหรือลดลงตรงข้ามเสมอ
- 3) สหสัมพันธ์เป็นศูนย์ (Zero Correlations) ซึ่งหมายถึง ตัวแปรทั้งสองตัว ไม่มีความสัมพันธ์ซึ่งกันและกัน

2.4 นิวรอลเน็ตเวิร์ก

แบบจำลองโครงข่ายประสาทเทียมที่เป็นการจำลองการทำงานของสมองมนุษย์ โดยสามารถเรียนรู้ข้อมูลจากชุดข้อมูลที่มีอยู่แล้วในชุดข้อมูลฝึกสอน เพื่อใช้ทำนายข้อมูลในลักษณะเดียวกันในชุดข้อมูลทดสอบ โดยมีรายละเอียดในส่วนต่าง ๆ ดังนี้

2.4.1 นิวรอลเน็ตเวิร์กแบบป้อนไปข้างหน้า (Feed-Forward Neural Network, FFNN)

นิวรอลเน็ตเวิร์กประเภทนี้ จะมีลำดับในการคำนวณและส่งต่อข้อมูลไปในทิศทางเดียว โดยโครงสร้างจะแบ่งออกเป็นลำดับชั้น โดยในแต่ละชั้นจะมีเพอร์เซ็ปตรอนจำนวนหนึ่งซึ่งไม่มีเส้นเชื่อมถึงกันภายในชั้นเดียวกัน แต่จะมีเส้นเชื่อมถึงเพอร์เซ็ปตรอนตัวอื่น ๆ ที่อยู่ในลำดับชั้นที่ติดกันทั้งหมด โดยข้อมูลส่งออกของเพอร์เซ็ปตรอนในชั้นก่อนหน้า จะเป็นข้อมูลรับเข้าของเพอร์เซ็ปตรอนในชั้นปัจจุบัน ดังแสดงโครงสร้างได้ในรูปที่ 1



รูปที่ 1 โครงสร้างนิวรอลเน็ตเวิร์กแบบป้อนไปข้างหน้า

และสามารถคำนวณหาค่าของผลลัพธ์ในชั้นถัดไป ได้จากสมการดังต่อไปนี้

$$Z_j^l = \sum_{k=1}^n w_{jk}^l a_k^{l-1} + b_j^l \quad (2.4)$$

$$a_j^l = g(z_j^l) \quad (2.5)$$

เมื่อ a_k^{l-1} คือ ผลลัพธ์ของเพอร์เซ็ปตรอนตัวที่ k ในลำดับชั้นที่ $l - 1$
 w_{jk}^l คือ น้ำหนักสำหรับเพอร์เซ็ปตรอนตัวที่ j ในลำดับชั้นที่ l ที่มีเส้นเชื่อมมาจาก
 เพอร์เซ็ปตรอนตัวที่ k ในลำดับชั้นก่อนหน้า

2.4.2 ฟังก์ชันกระตุ้น (Activation Function)

สำหรับข้อมูลการส่งออกของแต่ละเพอร์เซ็ปตรอน จะมีการใช้ฟังก์ชันกระตุ้น $g(z)$ ที่มีลักษณะแบบไม่ใช่ฟังก์ชันเชิงเส้น (Non-linear) เพื่อให้โครงข่ายประสาทเทียมมีความซับซ้อนและสามารถแก้ปัญหาได้หลากหลายมากยิ่งขึ้น โดยฟังก์ชันกระตุ้นที่นิยมใช้กัน มีดังต่อไปนี้

1) ฟังก์ชันซิกมอยด์ (Sigmoid Function)

เป็นฟังก์ชันที่ให้ค่าผลลัพธ์ออกมาอยู่ในช่วง 0 ถึง 1 ฟังก์ชันซิกมอยด์สามารถเขียนแทนด้วย σ ซึ่งคำนวณได้จากสมการต่อไปนี้

$$\sigma(z) = \frac{1}{1 + e^{-z}} \quad (2.6)$$

2) ฟังก์ชันแทนเจนต์ไฮเพอร์โบลิก (Hyperbolic Tangent Function, tanh)

เป็นฟังก์ชันที่ให้ค่าผลลัพธ์ออกมาอยู่ในช่วง -1 ถึง 1 ฟังก์ชันแทนเจนต์ไฮเพอร์โบลิกสามารถเขียนแทนด้วย \tanh ซึ่งคำนวณได้จากสมการต่อไปนี้

$$\tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (2.7)$$

3) ฟังก์ชันเรกทิไฟด์เชิงเส้น (Rectified Linear Unit Function, ReLU)

เป็นฟังก์ชันที่เปลี่ยนค่าติดลบที่เข้ามาให้เป็น 0 ส่วนค่าอื่น ๆ คงเดิม ซึ่งคำนวณได้จากสมการต่อไปนี้

$$f(z) = \begin{cases} 0, & \text{if } z \leq 0 \\ z, & \text{if } z > 0 \end{cases} \quad (2.8)$$

4) ฟังก์ชันค่าสูงสุดอย่างอ่อน (Softmax Function)

เป็นฟังก์ชันที่ให้ค่าผลลัพธ์ออกมาอยู่ในช่วง 0 ถึง 1 ซึ่งเป็นค่าที่แสดงความน่าจะเป็นของค่าที่นำเข้ามาแต่ละตัว โดยผลรวมของความน่าจะเป็นที่ได้จะมีค่าเป็น 1 ดังสมการต่อไปนี้

$$f(z) = \frac{e^{z_j}}{\sum_{i=1}^k e^{z_j}} \quad (2.9)$$

2.4.3 ฟังก์ชันต้นทุน (Cost Function หรือ Loss Function)

เป็นฟังก์ชันที่แสดงถึงต้นทุนของนิเวรอลเน็ตเวิร์ก กล่าวคือ ในกระบวนการเรียนรู้ของนิเวรอลเน็ตเวิร์กนั้น จะทำการปรับค่าน้ำหนักเพื่อที่จะลดค่าของฟังก์ชันต้นทุนเพื่อให้เข้าใกล้กับค่า 0 มากที่สุด ฟังก์ชันต้นทุนที่เป็นที่นิยม มีดังต่อไปนี้ โดยจะกำหนดให้ J แทนฟังก์ชันต้นทุน n คือจำนวนข้อมูลทั้งหมดที่ใช้ในการเรียนรู้ y_i แทนผลลัพธ์จริงที่ได้จากชุดข้อมูลที่ i และ \hat{y}_i แทนผลลัพธ์ที่ได้จากการทำนายข้อมูลชุดที่ i

- 1) ค่าเฉลี่ยความผิดพลาดกำลังสอง (Mean Square Error, MSE)

$$J = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (2.10)$$

- 2) ค่าเฉลี่ยครอสเอนโทรปีแบบทวิภาค (Binary Cross-entropy)

$$J = -\frac{1}{n} \sum_{i=1}^n y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i) \quad (2.11)$$

- 3) ค่าติดลบลอการิธึมของความเป็นไปได้ (Negative Log Likelihood)

$$J = -\frac{1}{n} \sum_{i=1}^n y_i \log(\hat{y}_i) \quad (2.12)$$

2.4.4 การหาค่าที่เหมาะสมที่สุด (Optimization)

เป็นวิธีการปรับปรุงอัตราการเรียนรู้ เพื่อให้สามารถลดค่าจากฟังก์ชันต้นทุนได้มากที่สุดในแต่ละรอบ เพื่อเพิ่มโอกาสไปยังจุดต่ำสุดทั้งหมด โดยใช้วิธีปรับค่าน้ำหนักของเส้นเชื่อมในนิเวรอลเน็ตเวิร์ก วิธีการปรับค่าน้ำหนักที่ได้รับความนิยม มีดังต่อไปนี้

- 1) สโตแคสติกเกรเดียนเตสเซนซ์ (Stochastic Gradient Descent หรือ SGD)

เมื่อกำหนดให้ w แทนค่าพารามิเตอร์ ซึ่งเป็นน้ำหนักที่ต้องการจะปรับค่า α คืออัตราการเรียนรู้ และ $\frac{\partial J_t}{\partial w}$ คือ เกรเดียนฟังก์ชันของต้นทุนเทียบกับ w โดยจะทำการปรับค่าด้วยสมการดังต่อไปนี้

$$w_t = w_{t-1} - \alpha \frac{\partial J_t}{\partial w} \quad (2.13)$$

ปัญหาที่อาจจะเจอในระหว่างการเรียนรู้ คือ การติดอยู่ในโลคอลออปติมา (Local Optima) ดังนั้นจึงมีการนำโมเมนตัม (Momentum) มาใช้ โดยมีจุดประสงค์เพื่อทำให้การเรียนรู้มีการลู่ออกที่ถี่ขึ้นและหลีกเลี่ยงการติดอยู่ในโลคอลออปติมา โดยกำหนดให้ v แทนค่าความเร็ว

ซึ่งมีการปรับค่าพร้อมกับ w และ γ แทนค่าสัมประสิทธิ์ของโมเมนตัม (Momentum Coefficient) สามารถแสดงการเรียนรู้ดังสมการต่อไปนี้

$$v_t = \gamma v_{t-1} + \alpha \frac{\partial J_t}{\partial w} \quad (2.14)$$

$$w_t = w_{t-1} - v_t \quad (2.15)$$

2) วิธีเกรเดียนที่ปรับตัวได้ (Adaptive Gradient Method หรือ AdaGrad)

เป็นวิธีที่จะมีการปรับอัตราการเรียนรู้ได้ด้วยตัวเองจากค่าเริ่มต้นที่กำหนด โดยการปรับค่าของอัตราการเรียนรู้นั้นจะมีการนำค่าเกรเดียนในอดีตมาใช้ กำหนดให้ g_t แทนเกรเดียนที่เวลา t สามารถแสดงการเรียนรู้ดังสมการต่อไปนี้

$$g_t = \frac{\partial J_t}{\partial w} \quad (2.16)$$

$$w_t = w_{t-1} - \frac{\alpha}{\sqrt{\sum_{k=1}^t g_k^2}} g_t \quad (2.17)$$

3) อาร์เอ็มเอสพรอป (RMSProp)

เป็นวิธีการที่มีการเก็บค่าเกรเดียนของครั้งก่อนหน้าไว้เพื่อที่จะนำมาใช้ในรอบการเรียนรู้ปัจจุบัน โดยนำไปปรับปรุงอัตราส่วนของอัตราการเรียนรู้ โดยนอกเหนือจากการใช้ g_t แล้ว ยังมีการใช้ $MeanSquare_t$ สำหรับเก็บค่าเฉลี่ยของเกรเดียน และให้ ν แทนอัตราการใช้เกรเดียนของอดีตในการเรียนรู้ ซึ่งโดยปกติแล้วจะใช้ค่านี้ที่ 0.9 สามารถแสดงการเรียนรู้ดังสมการต่อไปนี้

$$g_t = \frac{\partial J_t}{\partial w} \quad (2.18)$$

$$MeanSquare_t = \gamma MeanSquare_{t-1} + (1 - \gamma) g_t^2 \quad (2.19)$$

$$w_t = w_{t-1} - \frac{\alpha}{\sqrt{MeanSquare_t}} g_t \quad (2.20)$$

2.4.5 การแพร่กระจายย้อนกลับ (Backpropagation)

เนื่องจากเกรเดียนที่ได้จากการหาค่าความผิดพลาดสุดท้ายจากฟังก์ชันต้นทุนนั้น มีไว้ให้ลำดับชั้นสุดท้ายในนิเวศน์เน็ตเวิร์กเท่านั้น ดังนั้น หากต้องการจะทำการหาค่าเกรเดียนสำหรับปรับค่าของ w ของเพอร์เซ็ปตรอนในลำดับชั้นก่อนหน้า จะต้องการแพร่กระจายย้อนกลับ โดยจะสามารถเขียนสมการของความผิดพลาดได้เป็น

$$\delta_j^l = \frac{\partial J}{\partial z_j^l} = \frac{\partial J}{\partial a_j^l} \frac{\partial a_j^l}{\partial z_j^l} = \frac{\partial J}{\partial a_j^l} g'(z_j^l) \quad (2.21)$$

เมื่อ δ_j^l คือ ค่าความผิดพลาดของเพอร์เซ็ปตรอนตัวที่ j ในลำดับชั้นที่ l
 J คือ ฟังก์ชันต้นทุน
 z คือ ค่าที่คำนวณได้ก่อนผ่านฟังก์ชันกระตุ้น g

สำหรับการหาค่า $\frac{\partial J}{\partial a_j^l}$ นั้น ในลำดับชั้นสุดท้ายสามารถคำนวณหาได้โดยตรงจากฟังก์ชันต้นทุนที่เลือกใช้ ส่วนในลำดับชั้นก่อนหน้าจะต้องหาโดยวิธีการแพร่กระจายย้อนกลับ โดยจะคล้ายกับการป้อนไปข้างหน้า เพียงแต่เป็นการกลับทิศทางกันเท่านั้น กำหนด m คือ จำนวนเพอร์เซ็ปตรอนในลำดับชั้นที่ $l + 1$ สามารถคำนวณได้จากสมการดังต่อไปนี้

$$\frac{\partial J}{\partial a_j^l} = \sum_{k=1}^m \frac{\partial J}{\partial z_j^{l+1}} \frac{\partial z_j^{l+1}}{\partial a_j^l} = \sum_{k=1}^m \delta_k^{l+1} w_{kj}^{l+1} \quad (2.22)$$

จากนั้น เมื่อคำนวณค่าความผิดพลาดของแต่ละระดับชั้นได้ ก็สามารถหาค่าผิดพลาดเทียบกับน้ำหนักและค่าไบแอสใด ๆ ได้จากสามารถคำนวณได้จากสมการดังต่อไปนี้

$$\frac{\partial J}{\partial w_{jk}^l} = \frac{\partial J}{\partial z_j^l} \frac{\partial z_j^l}{\partial w_{jk}^l} = \delta_j^l a_k^{l-1} \quad (2.23)$$

$$\delta_j^l = \frac{\partial J}{\partial z_j^l} = \frac{\partial J}{\partial a_j^l} \frac{\partial a_j^l}{\partial z_j^l} = \frac{\partial J}{\partial a_j^l} g'(z_j^l) \quad (2.24)$$

ในกรณีที่ใช้สโตแคสติกเกรเดียนต์เดสเซนท์ การปรับปรุงค่าน้ำหนัก w_{jk}^l จะทำโดย

$$w_{jk,t}^l = w_{jk,t-1}^l - \alpha a_{k,t}^{l-1} \delta_{j,t}^l \quad (2.25)$$

2.4.6 การดรอปเอาต์ (Dropout)

การดรอปเอาต์ เป็นวิธีที่ป้องกันตัวโมเดล ไม่ให้ยึดติดกับข้อมูลที่นำมาใช้เรียนรู้มากเกินไป (overfitting) โดยใช้วิธีการสุ่มตัดเส้นเชื่อมของเน็ตเวิร์กในระหว่างการเรียนรู้ การสุ่มจะทำให้ขึ้นใหม่ในทุกรอบของการเรียนรู้ของข้อมูลแต่ละรายการ โดยที่ในระหว่างการทดสอบ จะไม่มีการใช้ดรอปเอาต์


2.5 นิเวรอลเน็ตเวิร์กเชิงลึก

นิเวรอลเน็ตเวิร์กที่มีชั้นซ่อน (Hidden Layer) จำนวนหลาย ๆ ชั้น จุดเด่นของนิเวรอลเน็ตเวิร์กเชิงลึกคือความสามารถในการเรียนรู้คุณลักษณะหรือฟีเจอร์ (Feature) ที่ซ่อนอยู่ในข้อมูล

รับเข้าได้ดี ต่างกับนิเวศน์ตเว็ร็กทัวไปที่ต้งเลือกข้อมูลรับเข้าให้เหมาะสม (Feature Selection) ทัวข้อถัดไปจะอธิบายนิเวศน์ตเว็ร็กเชิงลึกที่ใช้ในงานวิจัยนี้

2.6 นิเวศน์ตเว็ร็กคอนโวลูชัน (CNN)

นิเวศน์ตเว็ร็กเชิงลึกที่มีจุดเริ่มต้นมาจากงานวิจัยทางด้านภาพตัวอักษร โดยมักจะใช้ข้อมูลเข้าเป็นเมตริกซ์ โครงสร้างของนิเวศน์ตเว็ร็กคอนโวลูชันเกิดจากการนำชั้นของนิเวศน์ตเว็ร็กหลาย ๆ ประเภท มาประกอบเข้าด้วยกัน ดังรูปที่ 2 และมีส่วนประกอบดังต่อไปนี้



รูปที่ 2 โครงสร้างของนิเวศน์ตเว็ร็กคอนโวลูชัน

2.6.1 ชั้นคอนโวลูชัน (Convolutional Layer)

เป็นชั้นที่ทำการหาพีเจอร์จากกลุ่มของข้อมูลรับเข้าที่อยู่ใกล้ ๆ กัน โดยใช้ผลคูณเชิงสเกลาร์ (dot product) เมตริกซ์กับตัวกรอง (filter) โดยที่น้ำหนักของตัวกรองนั้นจะเป็นน้ำหนักที่มีการใช้ร่วมกันในทุก ๆ การทำคอนโวลูชันของข้อมูลรับเข้า ซึ่งในชั้นคอนโวลูชันนี้ มีองค์ประกอบที่ต้องคำนึงถึงดังต่อไปนี้

1) ขนาดของตัวกรอง (Filter size)

ความกว้างและความสูงของตัวกรองที่นำมาใช้


2) ชนิดของการทำคอนโวลูชัน

- คอนโวลูชันแบบแคบ (Narrow Convolution)

โดยทั่วไป การทำคอนโวลูชันมักจะเป็นแบบแคบ ซึ่งในการทำคอนโวลูชันตัวกรองที่นำมากระทำจะไม่มีกรกระทำเลยขอบเมตริกซ์ข้อมูลรับเข้า

- คอนโวลูชันแบบกว้าง (Wide Convolution)


เป็นการทำคอนโวลูชัน ตัวกรองที่นำมากระทำเลยขอบเมตริกซ์ข้อมูลรับเข้าออกไปยังขอบ โดยพื้นที่ส่วนที่เกินออกไปนั้น จะถูกแทนค่าด้วย 0 ซึ่งจะเรียกว่า การเสริมเติม (Padding) ดังแสดงตัวอย่างในรูปที่ 3



รูปที่ 3 การทำคอนโวลูชันแบบกว้าง

3) ขนาดของการก้าวข้าม (Stride size)

จำนวนช่องของข้อมูลรับเข้าที่จะทำการเลื่อนไป เมื่อทำการผลลัพธ์ของคอนโวลูชันในแต่ละช่อง โดยทั่วไปมักจะมีค่าเป็น 1 หรือ 2 ดังแสดงตัวอย่างในรูปที่ 4



รูปที่ 4 ตัวอย่างขนาดของการก้าวข้ามที่มีค่า 2

4) จำนวนตัวกรอง (Number of filter)


ในการทำคอนโวลูชันแต่ละชั้น สามารถมีตัวกรองได้มากกว่า 1 ตัว และน้ำหนักของแต่ละตัวกรองอาจแตกต่างกันได้ ซึ่งการกำหนดจำนวนตัวกรองในชั้นปัจจุบัน จะเป็นการกำหนดจำนวนช่องสัญญาณในชั้นถัดไป

5) จำนวนช่องสัญญาณ (Number of channel)

จำนวนช่องสัญญาณหรือความลึกของข้อมูลรับเข้า

2.6.2 ชั้นการรวม (Pooling Layer)


ทำหน้าที่ลดขนาดของข้อมูลเพื่อให้เหลือเฉพาะข้อมูลที่สำคัญ ๆ เท่านั้น ซึ่งมักจะนิยมนำมาต่อจากชั้นคอนโวลูชัน โดยทั่วไปนิยมใช้การเลือกข้อมูลที่มีค่ามากที่สุด (Max Pooling) หรือค่าเฉลี่ย (Average Pooling) จากแต่ละช่วงของเมตริกซ์ เพื่อสร้างเป็นเมตริกซ์ที่มีขนาดเล็ก ดังแสดงในรูปที่ 5



รูปที่ 5 ขั้นตอนการเลือกค่าที่มากที่สุดในการรวม

2.6.3 ชั้นการเชื่อมโยงเต็มรูปแบบ (Fully Connected Layer)


ในขั้นสุดท้ายของนิวรอลเน็ตเวิร์กคอนโวลูชัน มักจะเป็นการเชื่อมโยงเต็มรูปแบบ นั่นคือ ในชั้นนี้จะประกอบไปด้วยชั้นย่อย ๆ ที่มีเพอร์เซ็ปตรอนอยู่จำนวนหนึ่ง โดยที่เพอร์เซ็ปตรอนแต่ละตัวจะมีเส้นเชื่อมกับเพอร์เซ็ปตรอนทุกตัวในชั้นก่อนหน้าและทุกตัวในชั้นถัดไป ดังแสดงโครงสร้างในรูปที่ 6



รูปที่ 6 โครงสร้างชั้นการเชื่อมโยงเต็มรูปแบบ

2.7 นิวรอลเน็ตเวิร์กแบบวนกลับ

นิวรอลเน็ตเวิร์กที่ถูกรอกแบบมาสำหรับข้อมูลที่มีลำดับ (Sequential) ซึ่งจะมีการส่งผ่านผลการประมวลผลในช่วงก่อนหน้าไปยังช่วงถัดไป ดังแสดงโครงสร้างในรูปที่ 7



รูปที่ 7 โครงสร้างนิรอลเน็ตเวิร์กแบบวงกลับ

สมการสำหรับการคำนวณของนิรอลเน็ตเวิร์กแบบวงกลับ สามารถคำนวณได้จาก


$$s_t = \sigma(Ws_{t-1} + Ux_t + b) \quad (2.26)$$

- เมื่อ s_t คือ ค่าของชั้นซ่อนที่ช่วงเวลา t
 W คือ ค่าของน้ำหนักที่ใช้คูณกับข้อมูลจากชั้นซ่อนที่ช่วงเวลา $t - 1$
 U คือ ค่าของน้ำหนักที่ใช้คูณกับข้อมูลนำเข้าที่ช่วงเวลา t
 x_t คือ ค่าข้อมูลนำเข้าที่ช่วงเวลา t
 σ คือ ฟังก์ชันกระตุ้น
 b คือ ไบแอส

การฝึกสอนนิรอลเน็ตเวิร์กแบบวงกลับ จะใช้วิธีการแพร่กระจายกลับตามเวลา (Back Propagation Through Time, BPTT) เพื่อปรับน้ำหนักต่าง ๆ ของนิรอลเน็ตเวิร์ก ซึ่งวิธีการนี้อาจจะทำให้เกิดปัญหา หากความยาวของข้อมูลรับเข้ามีมากเกินไป เนื่องจากค่า W ซึ่งแทนค่าน้ำหนักจะถูกส่งไปยังชั้นซ่อนถัด ๆ ไป การแพร่กระจายย้อนกลับซึ่งอาศัยกฎลูกโซ่ (Chain Rule) เพื่อใช้ในการปรับน้ำหนักอาจจะทำให้เกิดปัญหาได้ เนื่องจากเกรเดียนต์ที่เกิดจากการคำนวณกันของลำดับก่อนหน้า จะส่งผลให้ค่าที่ได้มีค่าเป็น 0 (Vanishing Gradient) ได้ ทำให้เกิดการลดหายหรือเพิ่มมากเกินไปของเกรเดียนต์ได้


2.7.1 นิรอลเน็ตเวิร์กแบบความจำระยะสั้นแบบยาว (LSTM)

นิรอลเน็ตเวิร์กแบบวงกลับที่ถูกพัฒนาขึ้น เพื่อแก้ปัญหาลดหายหรือเพิ่มมากขึ้นของเกรเดียนต์ (Vanishing Gradient) หากความยาวของข้อมูลรับเข้ามีมากเกินไป โดยนำเอาแนวคิดการเลือกจำข้อมูลมีโครงสร้างดังรูปที่ 8



The repeating module in an LSTM contains four interacting layers.

Don't worry about the details of what's going on. We'll walk through the LSTM diagram step by step later. For now, let's just try to get comfortable with the notation we'll be using.



รูปที่ 8 โครงสร้างของหน่วยความจำระยะสั้นแบบยาว

หน่วยความจำระยะสั้นแบบยาวประกอบด้วยหน่วยจำ (cell) แทนด้วย c ประตูลำดับสัญญาณสำหรับรับเข้า (input gate) แทนด้วย i ประตูลำดับสัญญาณสำหรับการลืม (forget gate) แทนด้วย f ประตูลำดับสัญญาณสำหรับผลลัพธ์แทนด้วย o และผลคูณแบบฮาดามาร์ด (Hadamard product) แทนด้วย \circ สมการสำหรับสร้างพีเจอร์ผลลัพธ์ มีดังนี้

$$f_t = \sigma(W_f s_{t-1} + U_f x_t + b_f) \quad (2.27)$$

$$i_t = \sigma(W_i s_{t-1} + U_i x_t + b_i) \quad (2.28)$$

$$o_t = \sigma(W_o s_{t-1} + U_o x_t + b_o) \quad (2.28)$$


$$c_t = f_t \circ c_{t-1} + (i_t \circ (W_c s_{t-1} + U_c x_t + b_c)) \quad (2.30)$$

$$s_t = o_t \circ \sigma(c_t) \quad (2.31)$$

2.8 ตัวเข้ารหัสอัตโนมัติ

ตัวเข้ารหัสอัตโนมัติ [10] คือ ขั้นตอนวิธีพื้นฐานสำหรับนำไปประกอบเพื่อสร้างนิเวศเน็ตเวิร์กเชิงลึก การใช้งานตัวเข้ารหัสอัตโนมัติจะมีลักษณะคล้ายคลึงกับโครงข่ายประสาทเทียม (Artificial Neural Network) ทั่วไป ที่มีชั้นขาเข้า (Input Layer) ชั้นซ่อน (Hidden Layer) และชั้นขาออก (Output Layer) โดยที่แตกต่างไปคือโครงข่ายประสาทเทียมคือจะเป็นการเรียนรู้แบบชี้แนะ (Supervised Learning) แต่ตัวเข้ารหัสอัตโนมัติจะเป็นการเรียนรู้แบบไม่ชี้แนะ (Unsupervised

Learning) กล่าวคือ เป็นเพียงการเรียนรู้ที่ต้องการให้ข้อมูลขาออก มีลักษณะใกล้เคียงกับข้อมูลขาเข้า จึงเหมือนกับเป็นการฝึกข้อมูลขาเข้าให้เข้ารหัส (Encode) เพื่อให้ได้ชั้นซ่อน และสามารถถอดรหัส (Decode) ออกเป็นข้อมูลขาเข้า ดังแสดงโครงสร้างในรูปที่ 9



รูปที่ 9 โครงสร้างของตัวเข้ารหัสอัตโนมัติ

2.9 กลไกความสนใจ

กลไกความสนใจ [11] มักนำไปใช้ในนิรอรอลเน็ตเวิร์กแบบลำดับต่อลำดับ (Sequence-to-Sequence Model) โดยการสร้างค่าความสนใจ $\alpha_1 \dots \alpha_n$ ให้กับแต่ละลำดับของข้อมูล ค่าความสนใจจะถูกนำไปคูณกับค่าของข้อมูลเพื่อสร้างเป็นเวกเตอร์ผลลัพธ์ที่จะถูกนำไปใช้ต่อ โดยการหาค่าความสนใจ α ทำได้โดยดูจากลำดับชั้นลับในเน็ตเวิร์กแบบวนกลับ $s_1 \dots s_n$ ร่วมกับลำดับชั้นลับ h_t ดังนี้

$$\alpha_i = \text{softmax}(f_{\text{attn}}(h_t, s_i)) \quad (2.32)$$

โดยที่ f_{attn} เป็นฟังก์ชันที่ใช้สำหรับคำนวณค่าความสนใจ มีอยู่หลายประเภท ได้แก่ กำหนดให้

h_t คือ ค่าของชั้นลับ (hidden layer) ในลำดับชุดที่ 1 ที่ช่วงเวลา t

s_i คือ ค่าของชั้นลับ (hidden layer) ในลำดับชุดที่ 2 ที่ช่วงเวลา i

W_1 คือ ค่าของน้ำหนักที่ใช้คูณกับข้อมูลจากชั้นลับในลำดับชุด 1

W_2 คือ ค่าของน้ำหนักที่ใช้คูณกับข้อมูลจากชั้นลับในลำดับชุด 2

W_α คือ ค่าของน้ำหนักที่ใช้คูณกับข้อมูลจากชั้นลับในลำดับชุด 1 และลำดับชุด 2

v_α คือ ค่าของเวกเตอร์ของน้ำหนักที่ใช้หาค่าความสนใจ

2.9.1 ค่าความสนใจแบบบวก (Additive Attention)

การหาค่าความสนใจแบบบวก เป็นวิธีการหาค่าความสนใจที่ใช้นิรลเน็คเวิร์กแบบป้อนไปข้างหน้าในการหาค่าความสนใจระหว่างข้อมูลสองลำดับ ดังนี้

$$f_{attn}(h_t, s_i) = v_\alpha^T \tanh(W_1 h_t + W_2 s_i) \quad (2.33)$$

2.9.2 ค่าความสนใจแบบคูณ (Multiplicative Attention)

การหาค่าความสนใจแบบคูณ เป็นวิธีการหาค่าความสนใจที่ใช้การคูณด้วยค่าน้ำหนัก โดยมีสมการดังนี้

$$f_{attn}(h_t, s_i) = h_\alpha^T W_\alpha s_i \quad (2.34)$$

2.9.3 ค่าความสนใจส่วนตัว (Self-Attention)

โดยปกติแล้วการหาค่าความสนใจ จะเป็นการหาจากการเทียบเคียงระหว่างลำดับ 2 ลำดับ การหาค่าความสนใจส่วนตัวจึงเป็นการหาค่าความสนใจของข้อมูลเพียงลำดับเดียว ดังนั้น จึงแบ่งตามวิธีมาตรฐานได้ โดยมีสมการดังนี้

- การหาค่าความสนใจแบบบวก


$$f_{attn}(h_t, s_i) = v_\alpha^T \tanh(W_\alpha h_t) \quad (2.35)$$

- การหาค่าความสนใจแบบคูณ

$$f_{attn}(h_t, s_i) = h_\alpha^T W_\alpha h_t \quad (2.36)$$

2.9.4 ค่าความสนใจแบบโมนโทนิค (Monotonic Attention)

กลไกความสนใจแบบโมนโทนิค [12] เป็นกลไกความสนใจที่มีลักษณะเด่นในการให้ค่าความสนใจลำดับต่อลำดับแบบจัดแถวจากซ้ายไปขวา โดยจะไม่ย้อนกลับมาพิจารณาค่าน้ำหนักใหม่ตั้งแต่ลำดับแรก



รูปที่ 10 โครงสร้างของกลไกความสนใจแบบโมนอทอนิก



บทที่ 3

งานวิจัยที่เกี่ยวข้อง

งานวิจัยที่เกี่ยวข้องกับวิทยานิพนธ์ฉบับนี้ คืองานวิจัยที่ใช้แบบจำลองการเรียนรู้เชิงลึก งานวิจัยแต่ละชิ้นจะมีข้อมูลที่ได้รับเข้ามาเพื่อพิจารณารวมทั้งโครงสร้างนิเวศเน็ตเวิร์กที่แตกต่างกัน โดยจะแบ่งงานวิจัยออกเป็น 2 กลุ่ม ได้แก่ 1) แบบจำลองที่พิจารณาข้อมูลจราจรในเชิงพื้นที่และเวลา และ 2) แบบจำลองที่พิจารณาข้อมูลอุบัติเหตุกับการจราจร

3.1 แบบจำลองที่พิจารณาข้อมูลจราจรในเชิงพื้นที่และเวลา

งานวิจัยในหัวข้อนี้ เป็นงานวิจัยที่ใช้นิเวศเน็ตเวิร์กเชิงลึก เพื่อพิจารณาความสัมพันธ์ของ ข้อมูลจราจรที่มีความเกี่ยวข้องกันทั้งในเชิงพื้นที่และในเชิงเวลา


3.1.1 งานวิจัยของ Xiaolei Ma และคณะ ที่ใช้ข้อมูลความเร็วจราจรเฉลี่ย มาพิจารณา เสมือนรูปภาพโดยใช้นิเวศเน็ตเวิร์กคอนโวลูชัน

เป็นงานวิจัยที่เริ่มในปี 2017 ซึ่งใช้ทำนายความเร็วจราจรเฉลี่ยในเครือข่ายขนาดใหญ่ โดย ทดสอบกับถนนในเมืองปักกิ่ง ประเทศจีน งานวิจัยนี้ [7] มีการนำข้อมูลค่าเฉลี่ยความเร็วของจราจร ในแต่ละจุดและแต่ละช่วงเวลา มาจัดเรียงให้อยู่ในรูปของเมตริกซ์ 2 มิติ ที่แสดงความสัมพันธ์กันใน เชิงพื้นที่และเวลา ดังแสดงในรูปที่ 11

$$M = \begin{bmatrix} m_{11}, m_{12}, \dots, m_{1N} \\ m_{21}, m_{22}, \dots, m_{2N} \\ \vdots \\ m_{Q1}, m_{Q2}, \dots, m_{QN} \end{bmatrix}$$


รูปที่ 11 เมตริกซ์ 2 มิติ ที่แสดงความสัมพันธ์ในเชิงพื้นที่และเวลาของการจราจร

โดยที่ตัวแปร N แสดงถึงจำนวนช่วงเวลาย้อนหลังที่ต้องการใช้เป็นข้อมูลเข้า และ Q หมายถึงความยาวของถนนหรือแต่ละจุดข้อมูล ซึ่งในแต่ละคอลัมน์แสดงความเร็วจราจรเฉลี่ยของแต่ละ เวลา และแต่ละแถวแสดงความเร็วจราจรเฉลี่ยของแต่ละจุดข้อมูลที่เวลาเท่ากัน ขั้นตอนการ จัดเรียงข้อมูลเป็นรูปภาพจราจรทั้งหมด ดังแสดงในรูปที่ 12



รูปที่ 12 ขั้นตอนการแปลงความเร็วจราจรเฉลี่ยให้เป็นรูปภาพจราจร

เมื่อจัดเรียงข้อมูลให้เป็นเมตริกซ์ 2 มิติ และแปลงเป็นข้อมูลรูปภาพจราจรเสร็จเรียบร้อยแล้ว ก็จะใช้นิรอลเน็ตเวิร์กคอนโวลูชันมาพิจารณารูปแบบของความเร็วจราจรเฉลี่ยที่เกิดขึ้น โดยใช้ความสามารถในการคัดเลือกข้อมูลเข้าให้เหมาะสม (Feature Selection) ของคอนโวลูชัน จากนั้นนำเข้าชั้นซ่อน (Hidden Layer) และทำนายค่า ดังแสดงโครงสร้างของคอนโวลูชันในรูปที่ 13 ซึ่งผลลัพธ์ที่ได้พบว่า นิรอลเน็ตเวิร์กคอนโวลูชัน มีความสามารถในการเรียนรู้ความสัมพันธ์ในเชิงพื้นที่ และเวลาของข้อมูลจราจรได้ดีกว่าแบบจำลองอื่น ๆ



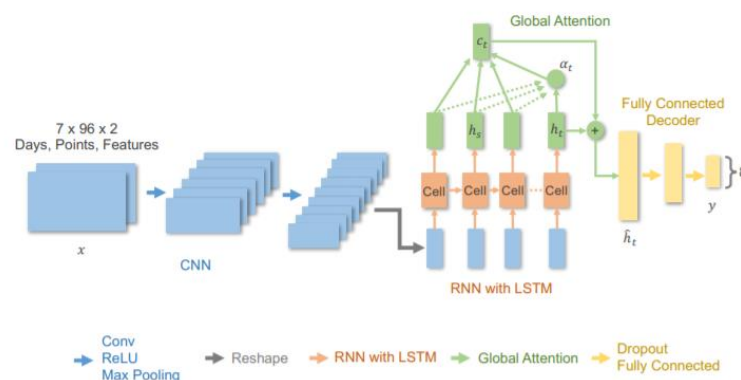
รูปที่ 13 โครงสร้างของนิรอลเน็ตเวิร์กคอนโวลูชันที่ใช้เรียนรู้ข้อมูลรูปภาพจราจร

3.1.2 งานวิจัยของ Jingqing Zhang ที่นำข้อมูลจราจรมาพิจารณา โดยใช้นิรอลเน็ตเวิร์กคอนโวลูชัน ร่วมกับหน่วยความจำระยะสั้นแบบยาว

งานวิจัยชิ้นนี้ [13] เป็นงานวิจัยที่ใช้ข้อมูลปริมาณจราจรบนถนนทางหลวงของประเทศอังกฤษมาพิจารณา และทำนายค่าออกเป็นหลาย ๆ ช่วงเวลาล่วงหน้า โดยแบ่งงานทดลองออกเป็น 2 ส่วนด้วยกัน คือ

- 1) แบบจำลองที่พิจารณาเฉพาะความสัมพันธ์ในเชิงเวลาของข้อมูล

ซึ่งจะนำเอานิเวรอลเน็ตเวิร์กเชิงลึกมาใช้ร่วมกันคือ นิเวรอลเน็ตเวิร์กคอนโวลูชัน หน่วยความจำระยะสั้นแบบยาว และกลไกความสนใจ เริ่มต้นจากการใช้นิเวรอลเน็ตเวิร์กคอนโวลูชัน ในการเรียนรู้รูปแบบความสัมพันธ์เชิงเวลาของข้อมูลจราจรในอดีตของแต่ละโหนด ซึ่งจะใช้เวลา ย้อนหลังไป 1 สัปดาห์ จากนั้นส่งผลลัพธ์ที่ได้จากการเรียนรู้ด้วยคอนโวลูชันไปที่หน่วยความจำระยะ สั้นแบบยาวที่เป็นนิเวรอลเน็ตเวิร์กที่นิยมใช้กับข้อมูลแบบอนุกรมเวลา มาเรียนรู้ต่อ จากนั้นจึงส่ง ข้อมูลต่อไปยังกลไกความสนใจเพื่อเรียนรู้ข้อมูลสำคัญของอนุกรมเวลาที่ได้ สุดท้ายจึงส่งข้อมูลต่อไป ยังชั้นซ่อน (Hidden Layer) และทำนายค่าออกมา ดังแสดงโครงสร้างในรูปที่ 14

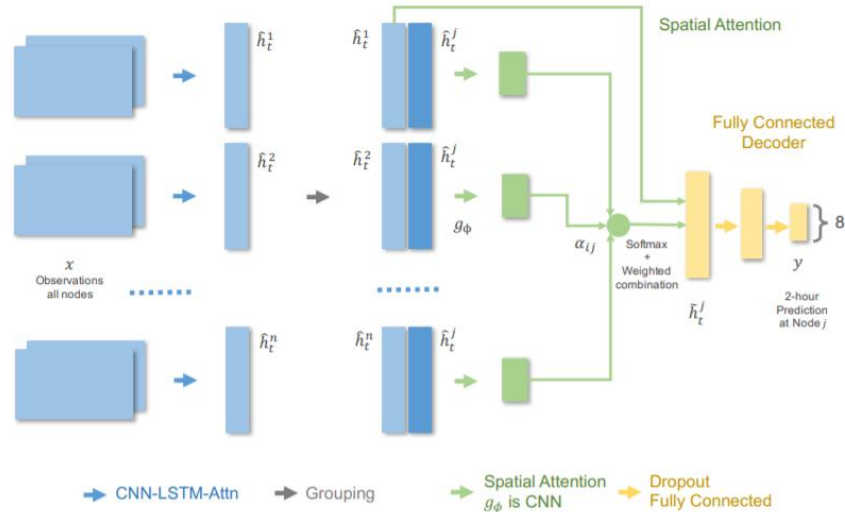


รูปที่ 14 โครงสร้างของแบบจำลองที่พิจารณาเฉพาะความสัมพันธ์ในเชิงเวลาของข้อมูล

2) แบบจำลองที่พิจารณาความสัมพันธ์ของข้อมูลทั้งในเชิงพื้นที่และเวลา

ซึ่งจะนำผลลัพธ์จากการเรียนรู้ด้วยนิเวรอลเน็ตเวิร์กคอนโวลูชัน หน่วยความจำระยะ สั้นแบบยาว และกลไกความสนใจ จากข้อมูลจราจรทุกโหนด ที่ได้จากส่วนที่ 1 ข้างต้น มาพิจารณา ความสัมพันธ์ในเชิงพื้นที่และหาความสัมพันธ์ที่ใกล้เคียงที่สุดด้วยนิเวรอลเน็ตเวิร์กคอนโวลูชัน ก่อนที่ จะทำการส่งต่อไปยังชั้นซ่อน (Hidden Layer) และทำนายค่าออกมา ดังแสดงโครงสร้างในรูปที่ 15

ซึ่งเมื่อทดลองด้วยแบบจำลองทั้งสองเสร็จและนำผลลัพธ์ที่ได้ไปเปรียบเทียบกับ แบบจำลองอื่น ๆ พบว่า แบบจำลองที่พิจารณาเฉพาะความสัมพันธ์ในเชิงเวลาของข้อมูลให้ผลลัพธ์ที่ ดีที่สุด เนื่องจากการใช้นิเวรอลเน็ตเวิร์กคอนโวลูชันในการหาความสัมพันธ์เชิงพื้นที่ของข้อมูลจราจรใน เครือข่ายขนาดใหญ่บนถนนทางหลวง ซึ่งมีจุดการจราจรที่ไม่ต่อเนื่องกันเยอะเกินไป จะทำให้แบบจำลอง ได้ผลลัพธ์ที่ไม่ดีนัก




รูปที่ 15 โครงสร้างของแบบจำลองที่พิจารณาความสัมพันธ์ของข้อมูลทั้งในเชิงพื้นที่และเวลา

3.2 แบบจำลองที่พิจารณาข้อมูลอุบัติเหตุกับการจราจร

งานวิจัยในหัวข้อนี้ เป็นงานวิจัยที่ใช้นิวรอลเน็ตเวิร์กในการพิจารณาผลกระทบของข้อมูลอุบัติเหตุที่มีต่อข้อมูลจราจร

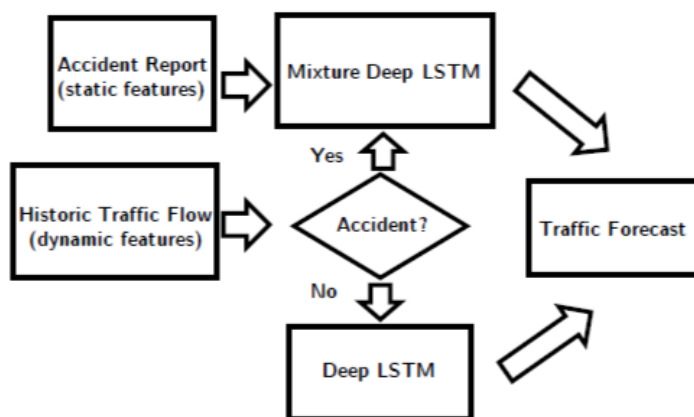
3.2.1 งานวิจัยของ Rose Yu และคณะ ที่นำข้อมูลอุบัติเหตุ มาพิจารณา

งานวิจัยชิ้นนี้ [14] นำข้อมูลอุบัติเหตุมาพิจารณาเพื่อวิเคราะห์ผลกระทบที่มีต่อการทำนายความเร็วจราจรเฉลี่ยในเมืองลอสแอนเจลิส ประเทศสหรัฐอเมริกา โดยสร้างแบบจำลองที่นำข้อมูลจราจรมาเรียนรู้ในเชิงเวลาเพียงอย่างเดียวด้วยหน่วยความจำระยะสั้นแบบยาวเพื่อทำนายความเร็วจราจรเฉลี่ย ซึ่งเป็นข้อมูลแบบอนุกรมเวลา จากนั้นนำข้อมูลอุบัติเหตุมาเรียนรู้ด้วยตัวเข้ารหัสอัตโนมัติแบบหลายชั้นเพื่อให้สามารถวิเคราะห์และเรียนรู้ผลกระทบที่ส่งต่อข้อมูลจราจร ดังแสดงโครงสร้างในรูปที่ 16



รูปที่ 16 โครงสร้างของแบบจำลองหน่วยความจำระยะสั้นแบบยาวร่วมกับตัวเข้ารหัสอัตโนมัติแบบหลายชั้น

เนื่องจากอุบัติเหตุที่เกิดขึ้นนั้น ถือเป็นส่วนน้อยมากเมื่อเทียบกับการข้อมูลที่เกิดตลอดเวลา ส่งผลให้แบบจำลองนี้ สามารถเรียนรู้ข้อมูลจราจรในช่วงเวลาที่เกิดอุบัติเหตุและผลกระทบต่ออุบัติเหตุได้ดีเมื่อเทียบกับแบบจำลองอื่น แต่ไม่สามารถเรียนรู้ข้อมูลจราจรทั้งในช่วงเวลาปกติและช่วงเวลาที่เกิดอุบัติเหตุไปพร้อม ๆ กันได้ Rose Yu และคณะ จึงได้สร้างแบบจำลองที่แก้ไขปัญหานี้ โดยสามารถเรียนรู้ข้อมูลจราจรได้ทั้งช่วงเวลาปกติและช่วงเวลาที่เกิดอุบัติเหตุ โดยในเวลาที่เกิดอุบัติเหตุ จะใช้แบบจำลองข้างต้นมาพิจารณาข้อมูลจราจร และช่วงเวลาอื่น ๆ จะใช้หน่วยความจำระยะสั้นแบบยาวมาพิจารณาข้อมูลจราจร ดังแสดงโครงสร้างในรูปที่ 17 ซึ่งจากผลการศึกษาพบว่าแบบจำลองนี้ ให้ผลลัพธ์ที่ดีกว่าแบบจำลองอื่น และเรียนรู้ข้อมูลจราจรทั้งในช่วงเวลาปกติและช่วงเวลาที่เกิดอุบัติเหตุไปพร้อม ๆ กันได้



รูปที่ 17 โครงสร้างของแบบจำลองที่สามารถเรียนรู้ข้อมูลจราจรทั้งในช่วงเวลาปกติและช่วงเวลาที่เกิดอุบัติเหตุไปพร้อม ๆ กันได้

3.3 ประเด็นที่พบจากงานวิจัยก่อนหน้าและสิ่งนำมาปรับปรุงในงานวิจัยนี้

หัวข้อนี้จะกล่าวถึงประเด็นที่พบจากการศึกษางานวิจัยก่อนหน้า รวมทั้งแนวทางในการพัฒนาต่อ โดยมีรายละเอียดดังนี้ต่อไป

3.3.1 การเรียนรู้ความสัมพันธ์ของข้อมูลจราจรในเชิงพื้นที่และเวลา

สำหรับงานวิจัยในหัวข้อจราจร แบบจำลองที่สำคัญและขาดไม่ได้ในการเรียนรู้คือ หน่วยความจำระยะสั้นแบบยาว [4-6] เนื่องจากเป็นแบบจำลองสำหรับข้อมูลที่มีลำดับหรือเป็นอนุกรมเวลา แต่เนื่องจากข้อมูลจราจรนั้น มีความสัมพันธ์กันในเชิงพื้นที่ด้วย จึงทำให้การใช้หน่วยความจำระยะสั้นแบบยาวเพียงอย่างเดียวในการเรียนรู้ข้อมูลในมิติเดียว อาจจะทำให้ยังไม่ได้

ผลลัพธ์ที่ดีที่สุด ซึ่งผลการศึกษาที่ผ่านมามีพบว่า การนำนิรอรเน็ตเวิร์กแบบคอนโวชันมาใช้เรียนรู้คุณลักษณะเพิ่มเติม ช่วยให้สามารถทำนายข้อมูลจรรยาจรได้แม่นยำยิ่งขึ้น มีความคลาดเคลื่อนน้อยลง แต่สำหรับผลลัพธ์ที่ได้จากงานวิจัยของ Jingqing Zhang ที่แสดงให้เห็นว่า การใช้กลไกความสนใจในการเรียนรู้ความสัมพันธ์เชิงพื้นที่ของเครือข่ายจรรยาจรที่มีขนาดใหญ่และไม่เชื่อมต่อกันมากเกินไป จะทำให้เกิดข้อผิดพลาดได้

3.3.2 การเรียนรู้ผลกระทบของอุบัติเหตุ

ข้อมูลอุบัติเหตุ เมื่อนำมาเรียนรู้ร่วมกับข้อมูลจรรยาจรด้วยนิรอรเน็ตเวิร์กหน่วยความจำระยะสั้นแบบยาวร่วมกับตัวเข้ารหัสอัตโนมัติแบบหลายขั้นนั้น แบบจำลองสามารถเรียนรู้ถึงผลที่กระทบต่อการจรรยาจร ณ เวลาที่เกิดอุบัติเหตุได้เป็นอย่างดี แต่อย่างไรก็ตาม เนื่องจากอุบัติเหตุที่เกิดขึ้นนั้นเกิดขึ้นจำนวนน้อยมากเมื่อเทียบกับการจรรยาจรทั้งหมด จึงทำให้แบบจำลองเดียวไม่สามารถเรียนรู้ข้อมูลจรรยาจรได้ดีในทุกช่วงเวลา อีกทั้งในแบบจำลองนี้ ยังเป็นการเรียนรู้ข้อมูลจรรยาจรในเชิงเวลาเพียงอย่างเดียว ซึ่งในความเป็นจริงแล้ว เมื่อเกิดอุบัติเหตุขึ้นนั้น ย่อมส่งผลกระทบต่อพื้นที่จรรยาจรที่อยู่ใกล้เคียงกันด้วย

บทที่ 4

แนวคิดในการดำเนินงานและวิธีการที่นำเสนอ

ในบทนี้ นำเสนอวิธีการเรียนรู้เชิงลึกเพื่อใช้ในการทำนายความเร็วจราจรล่วงหน้า โดยจะเน้นพิจารณาองค์ประกอบหลัก ทั้งหมด 3 องค์ประกอบด้วยกันคือ ส่วนข้อมูลจราจร ซึ่งแบ่งออกเป็นข้อมูลในเชิงเวลา และข้อมูลในเชิงพื้นที่ และส่วนข้อมูลอุบัติเหตุ โดยนำเอาจุดเด่นในงานวิจัยของ Zhang [13] ซึ่งใช้ข้อมูลจราจรในเชิงเวลาของ ตัวตรวจด้วยลูป (Inductive Loop Detector) แต่ละเครื่อง (โหนด) มาแปลงเป็นข้อมูลนำเข้าแบบรูปภาพ เพื่อให้เรียนรู้และทำนายโดยนิรอรเน็ตเวิร์กคอนโวลูชัน ร่วมกับหน่วยความจำระยะสั้นแบบยาว และมีการพัฒนาข้อจำกัดของงานวิจัยดังกล่าว โดยการพัฒนาให้สามารถเรียนรู้ข้อมูลจราจรทั้งในเชิงพื้นที่และเชิงเวลาไปในแบบจำลองเดียวกันได้ จึงได้มีการนำนิรอรเน็ตเวิร์กคอนโวลูชันมาช่วยในเรียนรู้ จากการคัดเลือกข้อมูลเชิงพื้นที่ด้วยค่าสัมประสิทธิ์สหสัมพันธ์แบบเพียร์สัน นอกจากนี้ ยังนำเอาจุดเด่นของงานวิจัยของ Yu [14] ซึ่งใช้ข้อมูลเหตุการณ์พิเศษหรืออุบัติเหตุ มาเรียนรู้ผลกระทบที่ส่งต่อการจราจร โดยใช้ตัวเข้ารหัสอัตโนมัติในการเรียนรู้ หัวข้อนี้จะกล่าวถึงการคัดเลือกข้อมูล การประมวลผลข้อมูลเบื้องต้น เพื่อนำไปใช้เป็นข้อมูลรับเข้าของแบบจำลองที่ใช้ในการทำนายข้อมูลจราจร โดยมีรายละเอียดดังต่อไปนี้

4.1 การประมวลผลข้อมูลเบื้องต้น (Data Preprocessing)

4.1.1 การเตรียมข้อมูล

ข้อมูลที่นำมาใช้ในงานวิจัยนี้ จะแบ่งออกเป็น 2 ข้อมูลด้วยกันคือ ข้อมูลจราจร และข้อมูลอุบัติเหตุ โดย

4.1.1.1. ข้อมูลจราจร


ข้อมูลจราจรที่นำมาใช้ในการทดลองคือ “ความเร็วจราจรเฉลี่ย” และ “วันของสัปดาห์” ของข้อมูลในแต่ละโหนด โดยจะทำการนอร์มอลไลซ์ และแบ่งข้อมูลทั้งสอง ออกเป็นช่วงเวลา ช่วงละ 15 นาที และใช้ทำนายความเร็วจราจรเฉลี่ย 4 ระดับล่วงหน้า คือ 15, 30, 45 และ 60 นาที

4.1.1.2. ข้อมูลอุบัติเหตุ

ข้อมูลอุบัติเหตุเป็นข้อมูลที่ได้จากแอปพลิเคชันทวิตเตอร์ เป็นข้อความรายงานเหตุการณ์ต่าง ๆ บนถนน หรือข้อมูลจากรายงาน โดยจะทำการประมวลผลเพื่อหาช่วงเวลาตั้งแต่ระยะช่วงที่เกิดอุบัติเหตุ

4.1.2 ข้อมูลนำเข้า ส่วนข้อมูลจราจรในเชิงเวลา (Temporal Input)


ข้อมูลเข้าในส่วนนี้จะป็นข้อมูลรูปภาพ ซึ่งมี 2 ช่องสัญญาณ (channel) โดยในแต่ละช่องสัญญาณ จะแสดงคุณลักษณะที่แตกต่างกัน สำหรับข้อมูลจราจรในเชิงเวลานั้น นำคุณลักษณะของข้อมูลจราจรมา 2 คุณลักษณะ คือ ความเร็วจราจรเฉลี่ยและวันของสัปดาห์ โดยใช้ข้อมูลย้อนหลัง 1 สัปดาห์ มาแปลงให้เป็นข้อมูลรูปภาพ สำหรับแต่ละคุณลักษณะ จะนำมาจัดเรียงในรูปแบบของเมตริกซ์ ขนาด 7×96 โดย 96 คือข้อมูลช่วงเวลาใน 1 วันย้อนหลัง โดยในแต่ละแถวจะแสดงข้อมูลย้อนหลังในแต่ละวัน และในแต่ละคอลัมน์ จะแสดงข้อมูลย้อนหลังในช่วงเวลาเดียวกันของแต่ละวัน เมื่อทำการนอร์มอลไลซ์เสร็จเรียบร้อยแล้ว จะนำข้อมูลทั้งสอง มาวางซ้อนทับช่องสัญญาณกัน จะได้รูปภาพที่มีมิติ $7 \times 96 \times 2$ ซึ่งแบ่งเป็นข้อมูลความเร็วจราจรเฉลี่ย 1 ช่องสัญญาณ และข้อมูลวันในสัปดาห์ที่แปลงเป็นเวกเตอร์วันฮอต 1 ช่องสัญญาณ ดังแสดงตัวอย่างในรูปที่ 18



รูปที่ 18 ข้อมูลนำเข้า ส่วนข้อมูลจราจรในเชิงเวลา


4.1.3 ข้อมูลนำเข้า ส่วนข้อมูลจราจรในเชิงพื้นที่ (Spatial Input)

สำหรับข้อมูลเข้าในส่วนนี้จะป็นข้อมูลรูปภาพ ซึ่งมีเพียง 1 ช่องสัญญาณ (channel) โดยจะนำเฉพาะข้อมูลความเร็วจราจรเฉลี่ยของโหนดรอบข้างมาใช้ โดยจะเลือกโหนดที่มีค่าความสัมพันธ์ใกล้เคียงกับโหนดปัจจุบันมากที่สุด วัดความใกล้เคียงจากค่าสัมประสิทธิ์สหสัมพันธ์เพียร์สันของข้อมูลที่โหนดปัจจุบันเทียบกับโหนดอื่น ๆ ดังแสดงตัวอย่างข้อมูลที่ได้ในรูปที่ 19 ซึ่งจะทำการเลือกจำนวนโหนดขั้นต่ำตามค่าสัมประสิทธิ์ที่มีทิศทางความสัมพันธ์เป็นสหสัมพันธ์ทางบวกและเลือกโหนดที่มีค่าสัมประสิทธิ์สหสัมพันธ์มากที่สุด เนื่องจากถือว่าเป็นโหนดที่มีความสัมพันธ์เป็นไปในทิศทางเดียวกัน ซึ่งโดยส่วนมากแล้ว มักจะเป็นโหนดที่อยู่ติดกัน จากนั้นนำมาจัดเรียงต่อกันเป็นแถว ในแต่ละแถวแทนค่าโหนดรอบข้าง 1 โหนด โดยยกตัวอย่างให้โหนด A แทนโหนดที่มีค่าสัมประสิทธิ์สหสัมพันธ์เพียร์สันมากที่สุด รองลงมาเป็นโหนด B โหนด C และโหนดอื่น ๆ ตามลำดับ ดังแสดงโครงสร้างในรูปที่ 20



รูปที่ 19 ตัวอย่างค่าสัมประสิทธิ์สหสัมพันธ์ของข้อมูลจราจรแต่ละโหนด เทียบกับโหนดอื่น ๆ ใน


เครือข่าย




รูปที่ 20 ข้อมูลนำเข้า ส่วนข้อมูลจราจรในเชิงพื้นที่

4.1.4 ข้อมูลอุบัติเหตุฝังตัว (Accident Embedding)

ข้อมูลอุบัติเหตุที่นำมาใช้ในการทดลอง โดยจะใช้ข้อมูลอุบัติเหตุเป็นส่วนเข้ารหัส (Encoder) จากการนำข้อมูลซึ่งมีลักษณะเป็นข้อความมาคัดกรองเฉพาะรายงานที่แจ้งว่ามีอุบัติเหตุเกิดขึ้น จากนั้นทำการวิเคราะห์รายละเอียดหาโหนดตัวตรวจจับด้วยรูปที่ใกล้เคียงที่สุด และจะใช้ข้อมูลย้อนหลัง 3 ชั่วโมงของโหนดนั้นมาฝังด้วยการแสดงแบบเวกเตอร์ ซึ่งแสดงการเกิดอุบัติเหตุที่โหนดปัจจุบันในแต่ละช่วงเวลา จากนั้นใช้ '1' แทนค่าในเวลาที่เกิดอุบัติเหตุ และ '0' แทนค่าในช่่วงเวลาปกติ ดังแสดงตัวอย่างเมื่อเกิดอุบัติเหตุที่เวลา $t - 1$ ในรูปที่ 21 จากนั้นนำข้อมูลความเร็วจราจรเฉลี่ยมาใช้เป็นส่วนถอดรหัส (Decoder) ซึ่งจะใช้ข้อมูลย้อนหลัง 3 ชั่วโมงเช่นกัน ทำการฝังด้วยการแสดงแบบเวกเตอร์ปกติ ดังแสดงตัวอย่าง ในรูปที่ 22



รูปที่ 21 ข้อมูลนำเข้า ส่วนข้อมูลอุบัติเหตุ สำหรับส่วนเข้ารหัส (Encoder) ของตัวเข้ารหัสอัตโนมัติ



รูปที่ 22 ข้อมูลนำเข้า ส่วนข้อมูลอุบัติเหตุ สำหรับส่วนถอดรหัส (Decoder) ของตัวเข้ารหัสอัตโนมัติ


4.2 แบบจำลองที่นำเสนอ (Temporal and Spatial with Attention Accident

Embedding, TSE-Attn)

งานวิจัยนี้ได้ทำการปรับปรุงแบบจำลองที่นำเสนอในงานวิจัย [13] โดยเน้นไปที่การพิจารณาข้อมูลจราจรทั้งในเชิงพื้นที่และเวลา และยังแก้ปัญหาของแบบจำลองดังกล่าวในเรื่องการทำนายจราจร ณ ขณะที่เกิดอุบัติเหตุขึ้นด้วย โดยจะใช้ข้อมูลความเร็วจราจรเฉลี่ยและข้อมูลอุบัติเหตุมาพิจารณาร่วมกัน แบบจำลองการเรียนรู้เชิงลึกที่เลือกใช้สำหรับการเรียนรู้ข้อมูลจราจร ได้แก่ หน่วยความจำระยะสั้นแบบยาวเพื่อใช้เรียนรู้ข้อมูลแบบอนุกรมเวลา และนิเวศน์เน็ตเวิร์กคอนโวลูชันเพื่อเรียนรู้คุณลักษณะเชิงพื้นที่ของข้อมูลจราจรในแต่ละจุดร่วมกับจุดที่อยู่รอบข้าง และสำหรับข้อมูลอุบัติเหตุ นั้น จะใช้ตัวเข้ารหัสแบบหลายชั้นร่วมกับกลไกความสนใจแบบโมโนโทนิค เพื่อดักจับความผิดปกติที่เกิดขึ้นและผลกระทบที่ส่งไปยังข้อมูลจราจรในช่วงอื่น ๆ ด้วย ซึ่งโครงสร้างของแบบจำลองเชิงลึกที่ใช้ จะแบ่งเป็น 3 ส่วน ได้แก่

4.2.1 ส่วนการพิจารณาข้อมูลจราจรเชิงเวลา


นำข้อมูลความเร็วจราจรเฉลี่ยมาแปลงเป็นรูปภาพเพื่อเรียนรู้คุณลักษณะสำคัญของข้อมูลในอดีตของโหนดหรือพื้นที่จราจรปัจจุบันด้วยนิเวศน์เน็ตเวิร์กคอนโวลูชันจากนั้นส่งต่อไปเรียนรู้คุณลักษณะในเชิงเวลาด้วยหน่วยความจำระยะสั้นแบบยาว ดังแสดงโครงสร้างในรูปที่ 23



รูปที่ 23 โครงสร้างส่วนการพิจารณาข้อมูลจราจรเชิงเวลา (Temporal)

4.2.2 ส่วนการพิจารณาข้อมูลจราจรเชิงพื้นที่

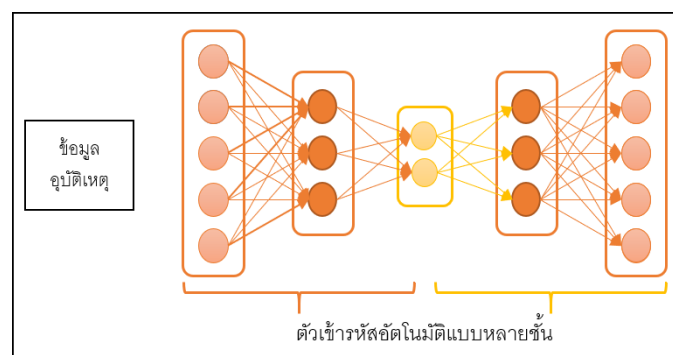
นำข้อมูลความเร็วจราจรเฉลี่ยในอดีตของโหนดหรือพื้นที่จราจรรอบข้างที่ผ่านการคัดเลือก จากค่าสัมประสิทธิ์สหสัมพันธ์เพียร์สันมาพิจารณาคูณลักษณะในเชิงพื้นที่รอบข้างด้วยนิเวศเน็ตเวิร์กคอนโวลูชัน ดังแสดงโครงสร้างในรูปที่ 24



รูปที่ 24 โครงสร้างส่วนการพิจารณาข้อมูลจราจรเชิงพื้นที่ (Spatial)

4.2.3 ส่วนการพิจารณาข้อมูลอุบัติเหตุ

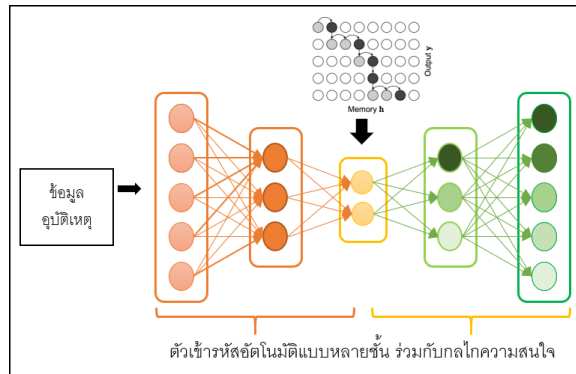
นำข้อมูลอุบัติเหตุฝั่งตัวมาแปลงเป็นเวกเตอร์ด้วยตัวเข้ารหัสแบบหลายชั้นเพื่อเรียนรู้การเกิดอุบัติเหตุโดยดักจับความผิดปกติและผลกระทบที่เกิดขึ้น โดยใช้ข้อมูลอุบัติเหตุเป็นส่วนตัวเข้ารหัส (Encoder) และใช้ข้อมูลความเร็วจราจรเป็นตัวถอดรหัส (Decoder) ดังแสดงโครงสร้างในรูปที่ 25 ตัวเข้ารหัสอัตโนมัติจะทำการบีบอัดส่วนเข้ารหัสให้กลายเป็นเวกเตอร์เข้ารหัสที่เรียนรู้ข้อมูลอุบัติเหตุ จากนั้นจะทำการขยายเวกเตอร์เข้ารหัสที่ได้ เพื่อถอดรหัสเวกเตอร์ที่ได้จนกลายเป็นข้อมูลความเร็วจราจรเฉลี่ย



รูปที่ 25 โครงสร้างส่วนการพิจารณาข้อมูลอุบัติเหตุ (Accident Embedding)

สำหรับการใส่กลไกความสนใจในตัวเข้ารหัสเพื่อเรียนรู้ข้อมูลอุบัติเหตุ นั้น จะเลือกใช้กลไกความสนใจแบบโมนโทนิกเพื่อเรียนรู้ข้อมูลอุบัติเหตุไล่ลำดับตามช่วงเวลา ดังแสดงโครงสร้างในรูปที่


26



รูปที่ 26 โครงสร้างส่วนการพิจารณาข้อมูลอุบัติเหตุร่วมกับกลไกความสนใจ (Attentional Accident Embedding)

4.2.4 ส่วนการทำนายข้อมูลจราจรในหลายช่วงเวลาล่วงหน้า

นำผลลัพธ์ที่ได้จากข้อ 4.2.1 – 4.2.3 ทั้ง 3 ส่วนมาเชื่อมต่อกันและป้อนเข้าสู่การเรียนรู้ในชั้นการเชื่อมโยงเต็มรูปแบบ (Fully Connected Layer) ซึ่งเป็นขั้นสุดท้ายของแบบจำลองและทำนายค่าความเร็วจราจรเฉลี่ยล่วงหน้าออกเป็นหลาย ๆ ช่วงเวลา ดังแสดงโครงสร้างในรูปที่ 27



รูปที่ 27 แบบจำลองที่นำเสนอ (TSE-Attn)

บทที่ 5

การทดลองและผลการทดลอง


หัวข้อนี้จะกล่าวถึง ชุดข้อมูลที่ใช้ในการทดลอง แบบจำลองอื่น ๆ ที่ถูกสร้างขึ้นเพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองที่นำเสนอ วิธีการวัดผล และผลการทดลองต่าง ๆ โดยมีรายละเอียด ดังต่อไปนี้

5.1 ชุดข้อมูลที่ใช้ในการทดลอง

ชุดข้อมูลที่ใช้ในการทดลองนี้ จะประกอบไปด้วย 2 ชุดข้อมูล และแต่ละชุดข้อมูลจะประกอบไปด้วยข้อมูลจราจร ซึ่งเป็นข้อมูลความเร็วจราจรเฉลี่ยที่รวบรวมค่าได้จากตัวตรวจด้วยลูป (Inductive Loop Detector) และจากแหล่งอื่น ๆ ซึ่งนำมาประมวลผลร่วมกัน โดยมีหน่วยเป็น กิโลเมตรต่อชั่วโมง (km/h) และข้อมูลอุบัติเหตุที่เป็นข้อมูลรายงานสถานการณ์ที่เกิดขึ้นบนท้องถนน

5.1.1 ชุดข้อมูลทางหลวง ประเทศอังกฤษ (Highways England)


เป็นชุดข้อมูลจราจรบนทางหลวงของประเทศอังกฤษ [15] ที่ครอบคลุมเมืองสำคัญ ๆ เช่น ลอนดอน เบอริงมิงแฮม และแมนเชสเตอร์ ซึ่งมีทำการคัดเลือกตัวตรวจด้วยลูป แต่ละโหนดที่จะใช้เรียนรู้ข้อมูลและทำนายความเร็วจราจรเฉลี่ยทั้งหมด 52 โหนด โดยเป็นโหนดที่อยู่ในถนน 3 สาย ได้แก่ ถนนทางด่วน 'M4' ถนนทางด่วน 'M25' และถนนสายหลัก 'A' เพื่อให้ครอบคลุมประเทศอังกฤษ ซึ่งข้อมูลที่ใช้ในการทดลองนี้จะอยู่ระหว่างวันที่ 1 มกราคม ค.ศ. 2016 ถึงวันที่ 30 มิถุนายน ค.ศ. 2017 ซึ่งสามารถแสดงโหนดที่เลือกด้วยหมุดและพื้นที่ที่ครอบคลุมได้ดังรูปที่ 28



รูปที่ 28 โหนดตัวตรวจด้วยลูปที่เลือกใช้ในข้อมูลจราจรบนทางหลวงของประเทศอังกฤษ

ในส่วนของคุณข้อมูลอุบัติเหตุ จะรวบรวมจากทวีตเตอร์ ซึ่งเป็นบัญชีอัตโนมัติที่ผูกเข้ากับกล้องวงจรปิด (Closed-Circuit Television, CCTV) บนถนน ที่จะทวีตข้อความรายงานสถานการณ์ที่เกิดขึ้นทุก ๆ 5 นาที และรายงานตลอด 24 ชั่วโมงของถนนทางหลวงในประเทศไทย [16-17] ดังแสดงตัวอย่างในรูปที่ 29 และมีข้อมูลอุบัติเหตุที่เกิดขึ้น 1040 เหตุการณ์ คิดเป็น 0.15 เปอร์เซ็นต์ของช่วงเวลาข้อมูลจราจรทั้งหมด โดยสำหรับการคัดแยกข้อมูลอุบัติเหตุที่เกิดในแต่ละโหนดจากข้อความจากทวีตเตอร์ มีหลักเกณฑ์การคัดแยก ดังต่อไปนี้


- 1) ทำการคัดแยกเฉพาะข้อความจากทวีตเตอร์ ซึ่งมีการใช้คำที่แสดงถึงการเกิดอุบัติเหตุ เช่น Accident, Broken, Delay เป็นต้น ดังแสดงตัวอย่างในกรอบสีแดง
- 2) ทำการคัดแยกถนนที่เกิดอุบัติเหตุ โดยใช้แฮชแท็ก (Hashtag) ที่แสดงถึงชื่อถนน เช่น #M4, #M25 เป็นต้น
- 3) ทำการคัดแยก โหนดที่เกิดอุบัติเหตุจากคำที่แสดงตำแหน่งที่เกิดอุบัติเหตุ ซึ่งจะบอกถึงรายละเอียดของกล้องวงจรปิด ดังแสดงตัวอย่างในกรอบสีเขียว



รูปที่ 29 แสดงตัวอย่างการคัดเลือกข้อมูลอุบัติเหตุจากทวีตเตอร์ของถนนบนทางหลวงของประเทศ
อังกฤษ

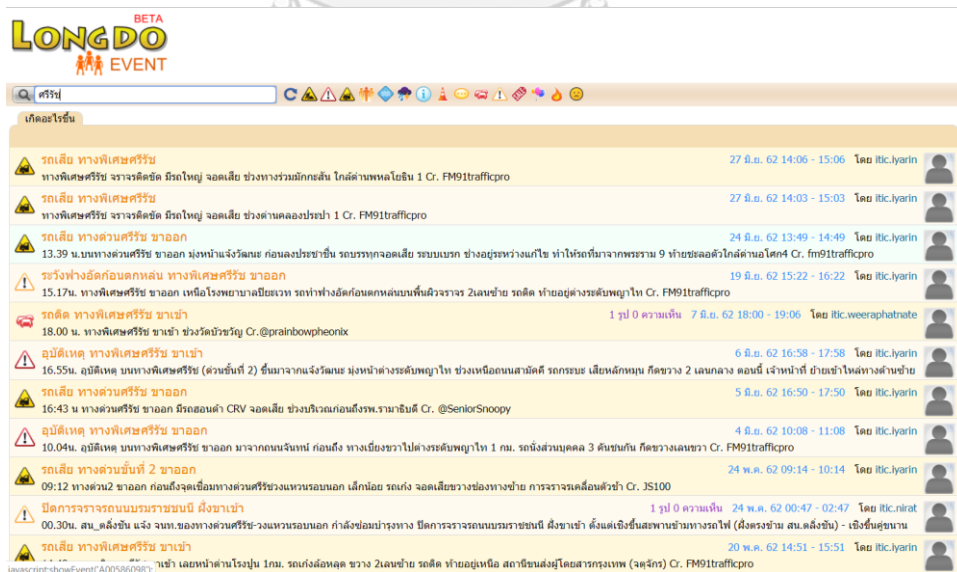
5.1.2 ชุดข้อมูลทางด่วน ประเทศไทย (Expressway Thailand)

เป็นชุดข้อมูลจราจรของประเทศไทย [18] ที่มูลนิธิศูนย์จราจรอัจฉริยะไทย (The Intelligent Traffic Information Center Foundation, iTIC) ได้เก็บรวบรวมไว้ โดยมีข้อมูลความเร็วจราจร รวมทั้งข้อมูลอุบัติเหตุ หรือเหตุการณ์ต่าง ๆ ที่เกิดขึ้นทั้งหมด โหนดที่จะใช้เรียนรู้ข้อมูลและทำนายความเร็วจราจรเฉลี่ยทั้งหมด 45 โหนด โดยเป็นโหนดที่อยู่ในทางด่วน 3 สายหลัก ได้แก่ ทางด่วนศรีรัช ทางด่วนฉลองรัช และทางด่วนเฉลิมมหานคร ซึ่งข้อมูลที่ใช้ในการทดลองนี้จะอยู่ระหว่างวันที่ 1 มกราคม ค.ศ. 2017 ถึงวันที่ 31 ธันวาคม ค.ศ. 2017 ซึ่งสามารถแสดงโหนดที่เลือกด้วยหมุดและพื้นที่ที่ครอบคลุมได้ดังรูปที่ 30



รูปที่ 30 โหนดตัวตรวจด้วยลูปที่เลือกใช้ในข้อมูลจราจรบนทางด่วนของประเทศไทย

สำหรับข้อมูลอุบัติเหตุที่ [19] มูลนิธิศูนย์จราจรอัจฉริยะไทย จะทำการเก็บรวบรวมข้อมูลที่เกิดขึ้น โดยส่วนหนึ่งจะนำมาจากข้อมูลรายงานการเกิดอุบัติเหตุ ที่ได้ข้อมูลจากมูลนิธิศูนย์จราจรอัจฉริยะไทย ข้อมูลจาก บริษัท กลางคุ้มครองผู้ประสบภัยจากรถ จำกัด หรือที่เรียกกันว่า ประกันภัย “พ.ร.บ.” ซึ่งเป็นบริษัทประกันภัยชั้นพื้นฐาน และข้อมูลจากแหล่งอื่น ๆ ดังแสดงตัวอย่างในรูปที่ 31 และมีข้อมูลอุบัติเหตุที่เกิดขึ้น 260 เหตุการณ์ คิดเป็น 0.07 เปอร์เซนต์ ของช่วงเวลาข้อมูลจราจรไทยทั้งหมด



รูปที่ 31 ตัวอย่างข้อมูลอุบัติเหตุที่ได้จากรายงานของชุดข้อมูลทางด่วนประเทศไทย


5.2 การสร้างแบบจำลองเพื่อใช้อ้างอิง

5.2.1 แบบจำลอง ARIMA (Autoregressive Integrated Moving Average Model)

แบบจำลองพื้นฐานสำหรับการทำนายข้อมูลที่เป็นอนุกรมเวลา โดยใช้ข้อมูลอนุกรมเวลาในอดีตเพื่อคาดการณ์ตัวแปรในอนาคต

5.2.2 แบบจำลองที่พิจารณาเพียงข้อมูลความเร็วจราจรเฉลี่ยในเชิงเวลา (Temporal, T)

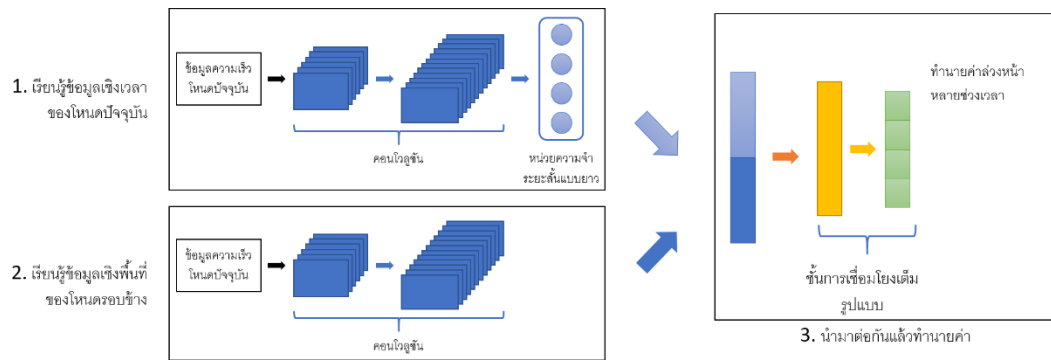
คือ แบบจำลองที่ดัดแปลงจากงานวิจัยของ Jingqing Zhang [13] ที่ใช้ข้อมูลเข้าของข้อมูลปริมาณจราจร โดยเปลี่ยนมาใช้ข้อมูลความเร็วจราจรเฉลี่ย ซึ่งใช้ข้อมูลความเร็วเฉลี่ยและข้อมูลวันของสัปดาห์ในแต่ละโหนดเป็นข้อมูลเข้าแบบรูปภาพ หลังจากนั้นจึงป้อนเข้าสู่นิเวศเว็กรูปแบบคอนโวลูชันเพื่อเรียนรู้รูปแบบของความเร็วจราจรเฉลี่ยที่เกิดขึ้นใน 1 สัปดาห์ที่ผ่านมาของในแต่ละวันและในแต่ละช่วงเวลา และนำผลลัพธ์ที่ได้มาเรียนรู้ต่อด้วยหน่วยความจำระยะสั้นแบบยาว เนื่องจากเป็นแบบจำลองที่เหมาะสมกับข้อมูลที่เป็นอนุกรมเวลา หลังจากนั้น นำผลลัพธ์ที่ได้ป้อนเข้าชั้นซ่อนเพื่อทำนายความเร็วจราจรเฉลี่ยในอีก 4 ระดับล่วงหน้า คือ 15 นาที 30 นาที 45 นาที และ 1 ชั่วโมงล่วงหน้า โครงสร้างของแบบจำลองนี้ แสดงดังรูปที่ 32



รูปที่ 32 โครงสร้างของแบบจำลองที่พิจารณาเพียงข้อมูลความเร็วจราจรเฉลี่ยในเชิงเวลา (T)

5.2.3 แบบจำลองที่พิจารณาเพียงข้อมูลความเร็วจราจรเฉลี่ยในเชิงพื้นที่และเวลา (Temporal and Spatial, TS)

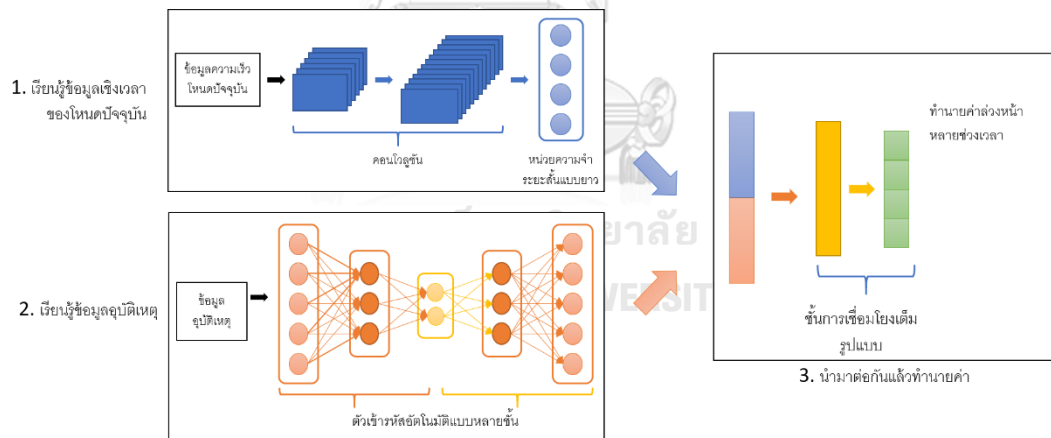
แบบจำลองนี้ ถูกดัดแปลงมาจากแบบจำลองในหัวข้อที่ 5.2.2 โดยใช้ข้อมูลความเร็วจราจรเฉลี่ยของโหนดรอบข้างเป็นข้อมูลเข้าเพิ่มเติม โดยนำข้อมูลจราจรของโหนดรอบข้างมาเรียนรู้ความสัมพันธ์เชิงพื้นที่ด้วยนิเวศเว็กรูปแบบคอนโวลูชัน ดังแสดงโครงสร้างในรูปที่ 33



รูปที่ 33 โครงสร้างของแบบจำลองที่พิจารณาเพียงข้อมูลความเร็วจราจรเฉลี่ยในเชิงพื้นที่และเวลา (TS)

5.2.4 แบบจำลองที่พิจารณาเพียงข้อมูลความเร็วจราจรเฉลี่ยในเชิงเวลา และข้อมูลอุบัติเหตุ (Temporal and Accident Embedding, TE)


แบบจำลองนี้ ถูกดัดแปลงมาจากแบบจำลองในหัวข้อที่ 5.2.2 โดยใช้ข้อมูลอุบัติเหตุเป็นข้อมูลเข้าเพิ่มเติม โดยนำข้อมูลอุบัติเหตุมาเรียนรู้เพื่อวิเคราะห์ผลกระทบของอุบัติเหตุที่มีต่อข้อมูลจราจร ดังแสดงโครงสร้างในรูปที่ 34



รูปที่ 34 โครงสร้างของแบบจำลองที่พิจารณาเพียงข้อมูลความเร็วจราจรเฉลี่ยในเชิงเวลา และข้อมูลอุบัติเหตุ (TE)

5.2.5 แบบจำลองที่พิจารณาเพียงข้อมูลความเร็วจราจรเฉลี่ยในเชิงพื้นที่และเวลา และข้อมูลอุบัติเหตุ (Temporal and Accident Embedding, TSE)

แบบจำลองนี้ ถูกดัดแปลงมาจากแบบจำลองในหัวข้อที่ 5.2.3 โดยใช้ข้อมูลอุบัติเหตุเป็นข้อมูลเข้าเพิ่มเติม โดยนำข้อมูลอุบัติเหตุมาเรียนรู้เพื่อวิเคราะห์ผลกระทบของอุบัติเหตุที่มีต่อข้อมูลจราจร ดังแสดงโครงสร้างในรูปที่ 35



รูปที่ 353 โครงสร้างของแบบจำลองที่พิจารณาเพียงข้อมูลความเร็วจราจรเฉลี่ยในเชิงพื้นที่และเวลา และข้อมูลอุบัติเหตุ (TSE)

5.3 การวัดผล

แบบจำลองในงานวิจัยนี้ จะถูกวัดประสิทธิภาพด้วยวิธีการดังต่อไปนี้

5.3.1 ค่าเฉลี่ยของค่าสัมบูรณ์ของเปอร์เซ็นต์ของความคลาดเคลื่อน (Mean absolute percent error, MAPE)

ทำการวัดว่า แบบจำลองทำนายค่าผิดพลาดจากข้อมูลจริงเป็นร้อยละเท่าใดจากการทำนายทั้งหมด ค่าความผิดพลาดสามารถคำนวณได้จากสมการดังต่อไปนี้

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \frac{|\hat{y}_i - y_i|}{y_i} \quad (5.1)$$

เมื่อ y คือ ค่าจริงที่เกิดขึ้น \hat{y} คือ ค่าที่ทำนาย

ซึ่งในการทำนายความเร็วจราจรเฉลี่ยล่วงหน้า จะมีการทำนายที่ระดับ 15 นาที 30 นาที 45 นาที และ 1 ชั่วโมง (60 นาที) ล่วงหน้า จากนั้นนำค่าความผิดพลาดที่ได้มาหาค่าเฉลี่ยของแต่ละแบบจำลอง

5.4 ระบบที่ใช้ทดลอง

ในส่วนนี้จะอธิบายถึงสภาพแวดล้อมที่ใช้ในการทดลอง ได้แก่ การแบ่งชุดข้อมูล และวิธีการสอนนิรอลเน็ตเวิร์กเชิงลึก

5.4.1 การแบ่งชุดข้อมูล

ชุดข้อมูลทั้งสอง จะถูกแบ่งออกเป็น 3 ส่วนคือ Training, Validation และ Test และจะถูกป้อนเข้าแบบจำลองนิรอลเน็ตเวิร์ก โดยที่แบบจำลองจะถูกสอนโดยใช้ข้อมูลสอน (Training Data) หลังจากนั้นจึงเลือกแบบจำลองที่มีความแม่นยำสูงสุดเมื่อทดสอบบนข้อมูลตรวจสอบ (Validation Data) มาใช้ แล้วจึงทำการวัดประสิทธิภาพบนข้อมูลทดสอบ (Test Data) โดยมีช่วงระยะเวลาในการแบ่งชุดข้อมูล แสดงรายละเอียดในตารางที่ 2

ตารางที่ 2 การแบ่งชุดข้อมูล

	ชุดข้อมูลอังกฤษ	ชุดข้อมูลไทย
ข้อมูลฝึกสอน	1 มกราคม ค.ศ. 2016 – 30 กันยายน ค.ศ. 2016	1 มกราคม ค.ศ. 2017 – 30 มิถุนายน ค.ศ. 2017
ข้อมูลตรวจสอบ	1 ตุลาคม ค.ศ. 2016 – 31 ธันวาคม ค.ศ. 2016	1 กรกฎาคม ค.ศ. 2017 – 30 กันยายน ค.ศ. 2017
ข้อมูลทดสอบ	1 มกราคม ค.ศ. 2017 – 30 มิถุนายน ค.ศ. 2017	1 ตุลาคม ค.ศ. 2017 – 31 ธันวาคม ค.ศ. 2017

5.4.2 วิธีการสอนนิรอลเน็ตเวิร์ก

ระบบมีการนำเข้าข้อมูลฝึกสอนพร้อมกันทั้งหมด 64 ชุด (batch size) โดยมีอัตราการเรียนรู้คือ 0.002 ในการฝึกสอนจะใช้ Adam เป็นตัวช่วยปรับค่าเกรเดียนในการเรียนรู้ และมีการใช้ดรอปเอาต์เพื่อป้องกันการยึดติดกับชุดข้อมูลฝึกสอน หรือ overfitting ที่ระดับ 20 เปอร์เซ็นต์

5.5 ผลการทดลอง

5.5.1 เปรียบเทียบผลการทดลองโดยรวม

การทดลองนี้ จะทำการทดลองแบบจำลองที่นำเสนอ (TSE) และแบบจำลองอื่น ๆ ทั้งหมด โดยเปรียบเทียบผลการทดลองที่ได้ของแบบจำลองที่นำเสนอกับแบบจำลองอื่น ๆ

จากผลการทดลองที่แสดงในตารางที่ 3 และ 4 จะพบว่า การนำนิรอลเน็ตเวิร์ก หรือแบบจำลองการเรียนรู้เชิงลึก ให้ผลลัพธ์การทำนายที่ผิดพลาดน้อยกว่า การคำนวณด้วยแบบจำลองพื้นฐาน ARIMA โดยเมื่อพิจารณาเฉพาะแบบจำลองนิรอลเน็ตเวิร์ก จะพบว่า เมื่อพิจารณาเฉพาะข้อมูลจราจรในเชิงเวลาเพียงอย่างเดียว จะให้ผลลัพธ์การทำนายที่ดีกว่าการนำข้อมูลอุบัติเหตุมาเรียนรู้ด้วย เนื่องจากว่า ข้อมูลอุบัติเหตุที่เกิดขึ้นนั้น มีส่วนน้อยมาก เมื่อนำมาเรียนรู้ด้วยตัวเข้ารหัส จะยังไม่สามารถเรียนรู้และทำนายอุบัติเหตุได้อย่างแม่นยำ อย่างไรก็ตาม เมื่อมีการข้อมูลจราจรในเชิงพื้นที่มาพิจารณาด้วย จะพบว่า ข้อมูลจราจรในเชิงพื้นที่ให้ผลลัพธ์การทำนายที่ดีขึ้น โดยให้ค่าผิดพลาดน้อยกว่าไม่ว่าจะพิจารณาข้อมูลอุบัติเหตุด้วยหรือไม่ เนื่องจากข้อมูลจราจรในเชิงพื้นที่นั้น เป็นการนำข้อมูลจราจรในโหนดที่มีความสัมพันธ์ไปในทิศทางเดียวกันมาพิจารณาร่วมด้วย จึงส่งผลให้แบบจำลองสามารถเรียนรู้ได้ดียิ่งขึ้น และยังพบว่า การนำข้อมูลจราจร ทั้งในเชิงพื้นที่และเชิงเวลา มาพิจารณาร่วมกับข้อมูลอุบัติเหตุ ทั้ง 3 ส่วนประกอบนี้ตามแบบจำลองที่นำเสนอ ให้ค่าผลลัพธ์การทำนายผิดพลาดน้อยที่สุด

ตารางที่ 3 ผลการทดลองโดยรวม สำหรับชุดข้อมูลอังกฤษ

MAPE	ARIMA	T	TS	TE	TSE	TSE-Attn
15 นาที	5.98	4.95	4.88	4.91	4.71	4.70
30 นาที	7.92	6.40	6.26	6.61	6.14	6.06
45 นาที	9.87	7.43	7.33	7.91	7.10	7.01
60 นาที	11.48	8.19	8.08	8.56	7.77	7.69
เฉลี่ย	8.81	6.74	6.64	7.00	6.43	6.37

ตารางที่ 4 ผลการทดลองโดยรวม สำหรับชุดข้อมูลไทย

MAPE	ARIMA	T	TS	TE	TSE	TSE-Attn
15 นาที	11.65	10.26	10.11	10.15	9.97	9.95
30 นาที	14.73	10.94	10.50	10.69	10.23	10.09
45 นาที	15.63	11.25	11.20	11.72	11.16	11.08
60 นาที	16.02	11.45	11.31	12.00	11.27	11.22
เฉลี่ย	14.51	10.98	10.78	11.14	10.66	10.58

5.5.2 เปรียบเทียบประสิทธิภาพส่วนข้อมูลจราจรเชิงเวลา

5.5.2.1. ประสิทธิภาพของการใช้ข้อมูลวันของสัปดาห์ต่อแบบจำลอง

คุณลักษณะสำคัญของข้อมูลจราจร นอกเหนือจากความเร็วจราจรเฉลี่ยที่ต้องการทำนายแล้ว นั้น วันของสัปดาห์ถือเป็นคุณลักษณะสำคัญที่ส่งผลต่อแบบจำลองที่ใช้ การทดลองนี้ จึงเป็นการทดลองประสิทธิภาพของคุณลักษณะวันของสัปดาห์ที่ส่งผลต่อแบบจำลอง เนื่องจากในข้อมูลเข้าและส่วนการพิจารณาข้อมูลจราจรเชิงเวลานั้น จะใช้วันของสัปดาห์เป็นคุณลักษณะที่แสดงถึงความเป็นช่วงเวลาหรืออนุกรมเวลาของข้อมูล

การทดลองนี้ จะเปรียบเทียบประสิทธิภาพระหว่างการใช่และไม่ใช้ข้อมูลวันของสัปดาห์ จึงทำให้ในส่วนข้อมูลนำเข้าของข้อมูลจราจรในเชิงเวลาที่ไม่ใช่วันของสัปดาห์ จะมีเพียงแค่ 1 ช่องสัญญาณ ซึ่งก็คือค่าความเร็วเฉลี่ย และจากผลลัพธ์ในตารางที่ 5 และ 6 จะพบว่า ข้อมูลวันของสัปดาห์ ถือเป็นคุณลักษณะที่ส่งผลต่อแบบจำลอง โดยการใส่วันของสัปดาห์ จะช่วยให้ได้ผลลัพธ์การทำนายที่ดีกว่าการไม่ใส่วันของสัปดาห์

ตารางที่ 5 ผลการทดลองเปรียบเทียบ เมื่อไม่ใช้ข้อมูลวันของสัปดาห์ในส่วนข้อมูลเชิงเวลา สำหรับชุดข้อมูลอังกฤษ

MAPE	T		TS		TE		TSE	
	ไม่ใช่	ใช่	ไม่ใช่	ใช่	ไม่ใช่	ใช่	ไม่ใช่	ใช่
15 นาที	5.01	4.95	4.91	4.88	4.94	4.91	4.71	4.71
30 นาที	6.44	6.40	6.28	6.26	6.64	6.61	6.15	6.14
45 นาที	7.48	7.43	7.36	7.33	7.95	7.91	7.12	7.10
60 นาที	8.23	8.19	8.10	8.08	8.61	8.56	7.89	7.77
เฉลี่ย	6.79	6.74	6.66	6.64	7.04	7.00	6.44	6.43

ตารางที่ 6 ผลการทดลองเปรียบเทียบ เมื่อไม่ใช้ข้อมูลวันของสัปดาห์ในส่วนข้อมูลเชิงเวลา สำหรับชุดข้อมูลไทย

MAPE	T		TS		TE		TSE	
	ไม่ใช้	ใช้	ไม่ใช้	ใช้	ไม่ใช้	ใช้	ไม่ใช้	ใช้
15 นาที	10.35	10.26	10.16	10.11	10.23	10.15	10.00	9.97
30 นาที	10.99	10.94	10.54	10.50	10.77	10.69	10.26	10.23
45 นาที	11.27	11.25	11.23	11.20	11.77	11.72	11.18	11.16
60 นาที	11.48	11.45	11.32	11.31	12.04	12.00	11.28	11.27
เฉลี่ย	11.02	10.98	10.81	10.78	11.20	11.14	10.68	10.66

5.5.2.2. ประสิทธิภาพของการใช้ข้อมูลวันพิเศษต่อแบบจำลอง

จากข้อ 5.5.2.1 ที่พบว่า คุณลักษณะวันของสัปดาห์ ส่งผลต่อการทำนายผลลัพธ์ของแบบจำลอง สำหรับการจราจรนั้น วันพิเศษต่าง ๆ เช่น วันหยุดนักขัตฤกษ์ ถือเป็นวันที่มีการจราจรแตกต่างจากวันปกติ การทดลองนี้ จึงเป็นการทดลองประสิทธิภาพของคุณลักษณะวันพิเศษที่ส่งผลต่อแบบจำลอง เพื่อเปรียบเทียบประสิทธิภาพระหว่างการใส่วันของสัปดาห์และวันพิเศษ โดยปกติแล้ว การใส่วันของสัปดาห์ เมื่อแทนด้วยตัวเลขแล้วนั้น จะมีค่าอยู่ระหว่าง 0-6 แทนช่วงเวลาวันอาทิตย์ถึงวันเสาร์ การเปรียบเทียบการใส่วันพิเศษ จึงเป็นการใส่ค่า 7 แทนวันพิเศษที่เกิดขึ้น ดังผลลัพธ์ในตารางที่ 7 และ 8 ซึ่งแสดงผลการทำนายทุกระดับเฉลี่ยกัน จะเห็นได้ว่า ข้อมูลวันพิเศษเป็นคุณลักษณะที่ส่งผลต่อแบบจำลอง โดยการใส่วันพิเศษ จะช่วยให้ได้ผลลัพธ์การทำนายที่ดีกว่าการใส่เพียงวันของสัปดาห์เพียงเล็กน้อยเท่านั้น

ตารางที่ 7 ผลการทดลองเปรียบเทียบ (MAPE) เมื่อใช้ข้อมูลวันพิเศษแทนวันของสัปดาห์ในส่วนข้อมูลเชิงเวลา สำหรับชุดข้อมูลอังกฤษ

แบบจำลอง	วันของสัปดาห์	วันพิเศษ
T	6.7405	6.7397
TS	6.6411	6.6409
TE	7.0002	6.9998
TSE	6.4331	6.4330

ตารางที่ 8 ผลการทดลองเปรียบเทียบ (MAPE) เมื่อใช้ข้อมูลวันพิเศษแทนวันของสัปดาห์ในส่วนข้อมูล
เชิงเวลา สำหรับชุดข้อมูลไทย

แบบจำลอง	วันของสัปดาห์	วันพิเศษ
T	10.9815	10.9807
TS	10.7843	10.7842
TE	11.1432	11.1429
TSE	10.6649	10.6647

ซึ่งเมื่อพิจารณาเฉพาะวันพิเศษ หรือวันหยุด สำหรับชุดข้อมูลอังกฤษ จำนวน 34 วัน และชุดข้อมูลไทย จำนวน 26 วัน จากข้อมูลทั้งหมด เมื่อทดสอบด้วยข้อมูลชุดทดสอบจะพบว่า การใช้ข้อมูลวันพิเศษ ช่วยให้การทำนายในช่วงวันพิเศษมีค่าความผิดพลาดลดลงเมื่อเทียบกับการใช้วันของสัปดาห์ ดังแสดงผลในตารางที่ 9 และ 10

ตารางที่ 9 ผลการทดลองเปรียบเทียบ (MAPE) เฉพาะวันพิเศษ ระหว่างการใช้วันของสัปดาห์ และวันพิเศษในส่วนข้อมูลเชิงเวลา สำหรับชุดข้อมูลอังกฤษ

MAPE	T		TS	
	วันของสัปดาห์	วันพิเศษ	วันของสัปดาห์	วันพิเศษ
15 นาที	9.65	9.57	9.56	9.42
30 นาที	9.93	9.87	9.63	9.56
45 นาที	10.27	10.01	9.93	9.77
60 นาที	10.78	10.56	10.34	10.26
เฉลี่ย	10.16	10.00	9.87	9.75

ตารางที่ 10 ผลการทดลองเปรียบเทียบ (MAPE) เฉพาะวันพิเศษ ระหว่างการใช้วันของสัปดาห์ และ วันพิเศษในส่วนข้อมูลเชิงเวลา สำหรับชุดข้อมูลไทย

MAPE	T		TS	
	วันของสัปดาห์	วันพิเศษ	วันของสัปดาห์	วันพิเศษ
15 นาที	8.94	8.07	8.78	8.01
30 นาที	9.23	8.82	9.12	8.68
45 นาที	9.56	9.05	9.36	8.81
60 นาที	10.02	9.23	9.82	9.05
เฉลี่ย	9.44	8.79	9.27	8.64

5.5.2.1. ประสิทธิภาพของการใช้ข้อมูลค่าต่ำสุดและค่าสูงสุดต่อแบบจำลอง

สำหรับการทดลองที่ผ่านมา จะใช้ข้อมูลความเร็วจราจรเฉลี่ยการประมวลผลช่วงเวลาในทุก ๆ 15 นาที อย่างไรก็ตาม ช่วงเวลาดังกล่าว อาจจะมีระยะเวลาที่ยาวนานเกินไป การทดลองนี้ จะทำการทดลองถึงประสิทธิภาพของข้อมูลความเร็วที่เกิดขึ้นในช่วง 15 นาที เพื่อหาค่าความเร็วต่ำสุดและความเร็วสูงสุด มาใส่เป็นข้อมูลเพิ่มเติม สำหรับข้อมูลนำเข้าในส่วนการพิจารณาข้อมูลเชิงเวลา ซึ่งจะ ทำให้แบบจำลองที่พิจารณาข้อมูลเพิ่มเติมนั้น มีข้อมูลนำเข้าที่มีทั้งหมด 4 ช่องสัญญาณด้วยกันคือ ค่าความเร็วเฉลี่ย ค่าความเร็วต่ำสุด ค่าความเร็วสูงสุด และวันของสัปดาห์

โดยการทดลองดังกล่าว มีข้อจำกัดคือ เนื่องจากชุดข้อมูลทางพิเศษของประเทศอังกฤษ เป็นข้อมูลที่ผ่านการประมวลผลเพื่อหาค่าเฉลี่ยทุก 15 นาทีแล้ว จึงทำให้ไม่สามารถนำค่าต่ำสุดหรือค่าสูงสุดจากข้อมูลดังกล่าวมาใช้ได้ การทดลองนี้ จึงดำเนินการเพียงแคในส่วนของชุดข้อมูลทางด่วนของประเทศไทย ซึ่งได้แสดงผลลัพธ์ที่ในตารางที่ 11 โดยจากผลการทดลองพบว่า การนำข้อมูลค่าต่ำสุดและค่าสูงสุดมาใช้ ทำให้ทำนายได้ผิดพลาดมากขึ้นเมื่อเปรียบเทียบผลลัพธ์ทุกระดับการทำนาย ตั้งแต่ 15 นาที ไปจนถึง 60 นาที แต่เมื่อพิจารณาที่ระดับ จะพบว่า ที่การทำนายใน 15 นาที ล่วงหน้านั้น แบบจำลองส่วนใหญ่ ให้ค่าทำนายที่ผิดพลาดลดลงเล็กน้อย ในขณะที่แบบจำลองที่พิจารณาข้อมูลจราจรในเชิงเวลาและข้อมูลอุบัติเหตุรวมกัน (TE) ให้ค่าทำนายที่ผิดพลาดที่เพิ่มขึ้นเล็กน้อยเช่นกัน ในขณะที่เมื่อพิจารณาที่ผลลัพธ์การทำนายที่ระดับ 30 นาทีล่วงหน้า จะพบว่าแบบจำลองที่พิจารณาข้อมูลอุบัติเหตุทั้ง TE และ TSE ให้ค่าทำนายที่ผิดพลาดที่เพิ่มขึ้นเล็กน้อย ตรงข้ามกับแบบจำลองที่ไม่พิจารณาข้อมูลอุบัติเหตุ และที่ระดับการทำนายที่ 45-60 นาที จะพบว่า ทุกแบบจำลอง ให้ค่าทำนายที่ผิดพลาดที่เพิ่มขึ้น

ตารางที่ 11 ผลการทดลองเปรียบเทียบ เมื่อใช้ข้อมูลค่าต่ำสุดและค่าสูงสุดในส่วนข้อมูลเชิงเวลา
สำหรับชุดข้อมูลไทย

MAPE	T		TS		TE		TSE	
	ค่าเฉลี่ย	ต่ำสุด- สูงสุด	ค่าเฉลี่ย	ต่ำสุด- สูงสุด	ค่าเฉลี่ย	ต่ำสุด- สูงสุด	ค่าเฉลี่ย	ต่ำสุด- สูงสุด
15 นาที	10.26	10.25	10.11	10.10	10.15	10.16	9.97	9.96
30 นาที	10.94	10.93	10.50	10.49	10.69	10.70	10.23	10.24
45 นาที	11.25	11.29	11.20	11.22	11.72	11.75	11.16	11.23
60 นาที	11.45	11.51	11.31	11.35	12.00	12.05	11.27	11.31
เฉลี่ย	10.98	11.00	10.78	10.78	11.14	11.16	10.66	10.68

5.5.3 เปรียบเทียบประสิทธิภาพส่วนข้อมูลจราจรเชิงพื้นที่

5.5.3.1. ประสิทธิภาพของแบบจำลองเมื่อใช้ค่าสัมประสิทธิ์สหสัมพันธ์แบบต่าง ๆ ในส่วนข้อมูลเชิงพื้นที่

สำหรับการพิจารณาข้อมูลจราจรเชิงพื้นที่ โหนดที่จะถูกเลือก เพื่อนำข้อมูลมาใช้พิจารณาก็เป็นส่วนที่สำคัญ เนื่องจากหากโหนดที่เลือกมาไม่มีความสัมพันธ์ไม่สอดคล้องกับโหนดปัจจุบันที่ต้องการทำนาย จะทำให้ได้ผลลัพธ์ที่ผิดพลาดมากยิ่งขึ้น

สำหรับการทดลองก่อนหน้านี้ จะใช้ค่าสัมประสิทธิ์สหสัมพันธ์แบบเพียร์สันที่เป็นค่าบวก เพื่อช่วยให้นิวรอลเน็ตเวิร์กคอนโวลูชันสามารถเรียนรู้รูปแบบที่เป็นไปในทางเดียวกันได้ง่ายยิ่งขึ้น อย่างไรก็ตามสำหรับค่าสัมประสิทธิ์สหสัมพันธ์แบบเพียร์สันที่เป็นค่าลบ ก็ถือว่ามีความสำคัญต่อการพิจารณา เนื่องจากถือเป็นความสัมพันธ์ที่สอดคล้องกันในทิศทางตรงกันข้าม การทดลองนี้ จึงจะเปรียบเทียบการเลือกใช้ค่าความสัมพันธ์ในแบบต่าง ๆ มาเพื่อใช้เลือกโหนดสำหรับส่วนพิจารณาข้อมูลเชิงพื้นที่ ซึ่งจะประกอบไปด้วยแบบต่าง ๆ ดังนี้

- 1) เลือกเฉพาะโหนดที่มีค่าสัมประสิทธิ์สหสัมพันธ์แบบเพียร์สันที่เป็นบวก
- 2) เลือกโหนดที่มีค่าสัมประสิทธิ์สหสัมพันธ์แบบเพียร์สันที่เป็นบวกและลบ
- 3) เลือกโหนดข้างเคียง คือโหนดก่อนหน้า และโหนดถัดไป

สำหรับการเลือกโหนดก่อนหน้า จะเป็นการเลือกโหนดที่รถยนต์จะวิ่งผ่านก่อนจะมาถึงโหนดปัจจุบัน และโหนดถัดไปคือโหนดที่รถยนต์จากโหนดปัจจุบันจะวิ่งไปถึง ดังแสดงผลการทดลองในตารางที่ 12 และ 13


ตารางที่ 12 ผลการทดลองเมื่อใช้ค่าสัมประสิทธิ์สหสัมพันธ์แบบต่าง ๆ ในส่วนข้อมูลเชิงพื้นที่ สำหรับชุดข้อมูลอังกฤษ

MAPE	TS			TSE		
	แบบเดิม	Pearson +/-	โหนดข้างเคียง	แบบเดิม	Pearson +/-	โหนดข้างเคียง
15 นาที	4.88	4.82	4.95	4.71	4.67	4.74
30 นาที	6.26	6.18	6.28	6.14	6.11	6.18
45 นาที	7.33	7.22	7.61	7.10	7.05	7.15
60 นาที	8.08	8.03	8.47	7.77	7.72	7.81
เฉลี่ย	6.64	6.56	6.82	6.43	6.39	6.47


ตารางที่ 13 ผลการทดลองเมื่อใช้ค่าสัมประสิทธิ์สหสัมพันธ์แบบต่าง ๆ ในส่วนข้อมูลเชิงพื้นที่ สำหรับชุดข้อมูลไทย

MAPE	TS			TSE		
	แบบเดิม	Pearson +/-	โหนดข้างเคียง	แบบเดิม	Pearson +/-	โหนดข้างเคียง
15 นาที	10.11	10.07	10.16	9.97	9.96	10.00
30 นาที	10.50	10.47	10.59	10.23	10.21	10.27
45 นาที	11.20	11.18	11.32	11.16	11.13	11.21
60 นาที	11.31	11.29	11.39	11.27	11.27	11.32
เฉลี่ย	10.78	10.75	10.86	10.66	10.64	10.70

จากผลการทดลองจะพบว่า การเลือกโหนดข้างเคียงมาพิจารณาจะให้ผลลัพธ์ที่แย่ที่สุด ซึ่งเมื่อพิจารณาผลลัพธ์จากการทำนายที่ละโหนดในเครือข่าย จะพบว่า โหนดที่ทำนายได้ผลลัพธ์แย่งคือ โหนดที่อยู่ตรงริมสุดของเครือข่าย ซึ่งจะมีปัญหาเกี่ยวกับการวิเคราะห์ข้อมูลของโหนดก่อนหน้าและโหนดถัดไป ดังแสดงตัวอย่างในรูปที่ 36 และ 37 และผลการทดลองยังพบว่า การเลือกโหนดที่มีค่าสัมประสิทธิ์สหสัมพันธ์แบบเพียร์สันที่เป็นทางบวกและทางลบมาเพื่อพิจารณา จะให้ผลลัพธ์ที่ดีที่สุด เนื่องจากนิเวศน์เน็ตเวิร์กคอนโวลูชันที่ใช้เรียนรู้ข้อมูลจราจรเชิงพื้นที่สามารถเรียนรู้ทิศทางของข้อมูลจราจรได้ง่ายยิ่งขึ้น



รูปที่ 36 กราฟแสดงผลการทำนาย เมื่อเปรียบเทียบวิธีการเลือกโหนดในส่วนข้อมูลจราจรเชิงพื้นที่แบบต่างๆ



รูปที่ 37 ตัวอย่างข้อมูลโหนดก่อนหน้าและโหนดถัดไปที่มีผลต่อแบบจำลอง

5.5.4 เปรียบเทียบประสิทธิภาพส่วนข้อมูลอุบัติเหตุ

5.5.4.1. ประสิทธิภาพของการทำนายในส่วนกรณีเกิดอุบัติเหตุ

สำหรับการพิจารณาข้อมูลอุบัติเหตุ นั้น เมื่อพิจารณาเฉพาะช่วงเวลาที่เกิดอุบัติเหตุขึ้น และผลกระทบของอุบัติเหตุที่มีผลต่อการจราจรในช่วงเวลาหลังจากนั้น จะพบว่า การใช้เพียงข้อมูลอุบัติเหตุในการทำนายข้อมูลจราจรล่วงหน้า สามารถทำนายข้อมูลจราจรล่วงหน้าได้ดีขึ้นในช่วง 15-30 นาทีล่วงหน้า แต่เมื่อพิจารณาที่ระดับ 45-60 นาทีล่วงหน้า นั้น การใช้แบบจำลองที่พิจารณาเพียง

ข้อมูลความเร็วจราจรเฉลี่ยในเชิงเวลา และข้อมูลอุบัติเหตุ (TE) ยังไม่สามารถทำนายได้ดี เทียบเท่ากับแบบจำลองที่พิจารณาเพียงข้อมูลความเร็วจราจรเฉลี่ยในเชิงเวลา (T) อย่างไรก็ตาม แบบจำลองที่พิจารณาข้อมูลจราจรทั้งในเชิงพื้นที่และเวลาร่วมกับข้อมูลอุบัติเหตุที่ใช้กลไกความสนใจร่วมด้วยนั้น ให้ผลลัพธ์การทำนายที่ดีขึ้นในทุกระดับ ดังแสดงผลลัพธ์ในตารางที่ 14 และ 15

ตารางที่ 14 ผลการทดลองเปรียบเทียบ (MAPE) เฉพาะกรณีเกิดอุบัติเหตุ สำหรับชุดข้อมูลอังกฤษ

MAPE	T	TE	TSE-Attn
15 นาที	10.37	7.79	7.75
30 นาที	12.08	10.12	10.07
45 นาที	12.34	13.93	12.28
60 นาที	13.67	14.58	13.50
เฉลี่ย	12.12	11.61	10.90

ตารางที่ 15 ผลการทดลองเปรียบเทียบ (MAPE) เฉพาะกรณีเกิดอุบัติเหตุ สำหรับชุดข้อมูลไทย


MAPE	T	TE	TSE-Attn
15 นาที	10.56	9.87	9.87
30 นาที	11.74	11.53	11.45
45 นาที	13.15	14.10	12.89
60 นาที	13.93	15.89	13.74
เฉลี่ย	12.34	12.84	11.99

5.5.4.2. ประสิทธิภาพของข้อมูลอุบัติเหตุจากรายงานที่ส่งผลต่อแบบจำลอง

ในส่วนของชุดข้อมูลจราจรประเทศอังกฤษ การทดลองที่ผ่านมาได้ใช้ข้อมูลจากบัญชีทวีตเตอร์ ซึ่งเป็นข้อมูลที่เข้าถึงได้ง่าย แต่ก็ยังมีข้อเสียคือ ไม่สามารถยืนยันได้ว่า เป็นข้อมูลที่ได้รับการรับรองความถูกต้องหรือไม่

สำหรับการทดลองนี้ จึงได้มีการใช้ข้อมูลอุบัติเหตุที่ได้จากรายงานของระบบ โดยมีการรวบรวมตำแหน่งที่เกิดอุบัติเหตุขึ้นในชื่อ “Road Safety Data” [20] ที่เก็บรวบรวมข้อมูลเหตุการณ์ต่าง ๆ ที่เกิดขึ้นในตำแหน่งต่าง ๆ ไว้ ดังแสดงตัวอย่างหน้าเว็บไซต์ในรูปที่ 36 ซึ่งการทดลองนี้จะได้เลือกใช้อุบัติเหตุจากตำแหน่งที่ใกล้แต่ละโหนดมากที่สุด โดยเลือกในระยะไม่เกิน 500 เมตร

จากการทดลองประสิทธิภาพ เมื่อเทียบข้อมูลที่ได้จากทวิตเตอร์และข้อมูลที่ได้จากรายงาน พบว่า สำหรับชุดข้อมูลอังกฤษนั้น ข้อมูลอุบัติเหตุที่ได้ทวิตเตอร์ ซึ่งมีจำนวนมากกว่าข้อมูลจากรายงานถึง 3-4 เท่า ส่งผลให้แบบจำลองที่ได้จากข้อมูลทวิตเตอร์มีความแม่นยำในการทำนายมากกว่า ดังแสดงผลในตารางที่ 14



รูปที่ 38 กราฟแสดงจำนวนอุบัติเหตุที่เกิดขึ้น เมื่อเปรียบเทียบข้อมูลจากทวิตเตอร์กับข้อมูลจากรายงานของข้อมูลจราจรประเทศอังกฤษ

ตารางที่ 16 ผลการทดลองเมื่อใช้ข้อมูลรายงาน สำหรับชุดข้อมูลอังกฤษ

MAPE	แบบจำลอง TS		แบบจำลอง TSE	
	แบบเดิม (ทวิตเตอร์)	รายงาน	แบบเดิม (ทวิตเตอร์)	รายงาน
15 นาที	4.91	5.06	4.71	4.80
30 นาที	6.61	6.80	6.14	6.22
45 นาที	7.91	8.01	7.10	7.19
60 นาที	8.56	8.70	7.77	7.85
เฉลี่ย	7.00	7.14	6.43	6.51

5.5.4.3. ประสิทธิภาพของกลไกความสนใจที่ส่งผลต่อแบบจำลอง

ในส่วนข้อมูลอุบัติเหตุ เนื่องจากเป็นข้อมูลที่เกิดขึ้นน้อยมาก เพียงไม่ถึง 5 เปอร์เซ็นต์ของข้อมูลทั้งหมด การทดลองนี้จึงได้มีการนำกลไกความสนใจมาใช้เพื่อเพิ่มประสิทธิภาพของตัวเข้ารหัสอัตโนมัติเพื่อให้ค่าความสนใจแก่อุบัติเหตุที่เกิดขึ้น ดังแสดงผลในตารางที่ 17 และ 18 โดยจากการทดลองพบว่า การใส่กลไกความสนใจนั้น ให้ผลลัพธ์การทำนายที่ผิดพลาดน้อยลง

ตารางที่ 17 ผลการทดลองเมื่อใช้กลไกความสนใจ สำหรับข้อมูลประเทศอังกฤษ

MAPE	TE		TSE	
	แบบเต็ม (ไม่ใช้)	ใช้	แบบเต็ม (ไม่ใช้)	ใช้
15 นาที	4.91	4.87	4.71	4.70
30 นาที	6.61	6.27	6.14	6.06
45 นาที	7.91	7.29	7.10	7.01
60 นาที	8.56	8.07	7.77	7.69
เฉลี่ย	7.00	6.63	6.43	6.37

ตารางที่ 18 ผลการทดลองเมื่อใช้กลไกความสนใจ สำหรับชุดข้อมูลไทย

MAPE	TE		TSE	
	แบบเต็ม (ไม่ใช้)	ใช้	แบบเต็ม (ไม่ใช้)	ใช้
15 นาที	10.15	10.10	9.97	9.95
30 นาที	10.69	10.43	10.23	10.09
45 นาที	11.72	11.53	11.16	11.08
60 นาที	12.00	11.89	11.27	11.22
เฉลี่ย	11.14	10.99	10.66	10.58

บทที่ 6

สรุปผลการวิจัยและแนวทางการวิจัยในขั้นถัดไป

6.1 สรุปผลการวิจัย

วิทยานิพนธ์ฉบับนี้ ได้นำเสนอแนวคิดและแบบจำลองที่ใช้ในการทำนายข้อมูลอุบัติเหตุจราจร โดยใช้แบบจำลองการเรียนรู้เชิงลึกที่รับข้อมูลเข้า 3 ส่วนประกอบคือ ส่วนข้อมูลจราจรที่มีทั้งข้อมูลจราจรเชิงเวลาและข้อมูลจราจรเชิงพื้นที่ รวมทั้งข้อมูลอุบัติเหตุ เพื่อให้สามารถพิจารณาข้อมูลจราจรและทำนายในหลาย ๆ ช่วงเวลาล่วงหน้า ให้มีค่าความผิดพลาดน้อยที่สุด

จากการทดลองพบว่า การนำนิเวรอลเน็ตเวิร์กมาใช้เพื่อทำนายความเร็วจราจรเฉลี่ย จะให้ผลลัพธ์ที่ดีกว่าการใช้แบบจำลอง ARIMA ซึ่งเป็นแบบจำลองพื้นที่ และให้ผลการทำนายที่ผิดพลาดน้อยที่สุด เมื่อมีการนำข้อมูลเข้าเพื่อพิจารณาครบทั้ง 3 ส่วน คือ ส่วนข้อมูลจราจรในเชิงเวลา ส่วนข้อมูลจราจรในเชิงพื้นที่ และส่วนข้อมูลอุบัติเหตุ โดยข้อมูลจราจรนั้น จะสามารถเรียนรู้รูปแบบได้ดี จากการใช้นิเวรอลเน็ตเวิร์กแบบคอนโวลูชันเพื่อเรียนรู้รูปแบบของข้อมูล ร่วมกับการใช้หน่วยความจำระยะสั้นแบบยาวเพื่อเรียนรู้ลำดับของข้อมูล เนื่องจากข้อมูลจราจรเป็นข้อมูลอนุกรมเวลา ซึ่งเมื่อทดสอบถึงประสิทธิภาพของข้อมูลที่ทำนายแล้วจะพบว่า ข้อมูลวันของสัปดาห์ ซึ่งเป็นคุณลักษณะที่ใช้บอกช่วงเวลานั้น ช่วยให้นิเวรอลเน็ตเวิร์กแบบคอนโวลูชันสามารถเรียนรู้ได้ดียิ่งขึ้น มีความสำคัญกับแบบจำลองอย่างมีนัยยะ เนื่องจากสามารถลดค่าความผิดพลาดจากการทำนายลงได้ และยังพบว่า สำหรับข้อมูลจราจรในเชิงพื้นที่นั้น การคัดเลือกโหนดที่มีค่าความสัมพันธ์กันมาเพื่อนิเวรอลเน็ตเวิร์กแบบคอนโวลูชันเรียนรู้รูปแบบของข้อมูลจราจรนั้น ส่งผลต่อประสิทธิภาพของแบบจำลอง โดยการเลือกโหนดที่มีค่าสัมพันธ์กันทั้งทางบวกและทางลบ ช่วยลดความผิดพลาดในการทำนาย อีกทั้งการใช้ตัวเข้ารหัสอัตโนมัติเพื่อเรียนรู้ข้อมูลอุบัติเหตุที่เกิดขึ้นอย่างไม่มีรูปแบบนั้น สามารถช่วยเพิ่มประสิทธิภาพในการทำนายให้แม่นยำยิ่งขึ้นได้ โดยเฉพาะเมื่อมีการใส่ค่าความสนใจเข้าไปเพื่อช่วยให้ตัวเข้ารหัสสามารถดักจับผลกระทบที่เกิดขึ้นเมื่อมีอุบัติเหตุ และจำนวนข้อมูลอุบัติเหตุที่ป้อนเข้าสู่แบบจำลองนั้น ส่งผลต่อแบบจำลองอย่างเป็นนัยยะสำคัญ

6.2 แนวทางการวิจัยถัดไป

สำหรับแนวทางในการวิจัยในอนาคต สามารถแบ่งได้ ดังต่อไปนี้

6.2.1 ส่วนการพิจารณาข้อมูลจราจร

การทำนายจราจรล่วงหน้าได้นานขึ้น โดยไม่ลดความแม่นยำในการทำนาย ตัวอย่างเช่น การทำนายในระดับ 1 ชั่วโมงล่วงหน้า ให้มีความแม่นยำใกล้เคียงกับการทำนายในระดับ 15 นาทีล่วงหน้า

จะสามารถนำไปใช้ชีวิตประจำวันได้มีประโยชน์มากยิ่งขึ้น เนื่องจากจะทำให้การวางแผนต่าง ๆ ได้มากขึ้น

6.2.2 ส่วนการพิจารณาข้อมูลอุบัติเหตุ

อุบัติเหตุที่เกิดขึ้นแต่ละครั้ง ซึ่งจะมีความแตกต่างกันในทั้งตำแหน่งและช่วงเวลา จึงส่งผลต่อการจราจรในระยะเวลาไม่เท่ากัน หากสามารถสร้างแบบจำลองการเรียนรู้เพื่อให้แบบจำลองสามารถวิเคราะห์ได้ว่า อุบัติเหตุที่เกิดขึ้นในแต่ละตำแหน่งนั้น ส่งผลต่อการจราจรเป็นระยะเวลาเท่าใดต่อการจราจร ณ ขณะนั้น จะช่วยให้ได้ผลลัพธ์การทำนายที่ดียิ่งขึ้น



บรรณานุกรม



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

รายการอ้างอิง

1. Dias, C., Miska, M., Kuwahara, M., & Warita, H. (2009, November). Relationship between congestion and traffic accidents on expressways: an investigation with Bayesian belief networks. In Proceedings of 40th Annual Meeting of Infrastructure Planning (JSCE).
2. Lv, Y., Duan, Y., Kang, W., Li, Z., & Wang, F. Y. (2015). Traffic flow prediction with big data: A deep learning approach. *IEEE Trans. Intelligent Transportation Systems*, 16(2), 865-873.
3. Polson, N. G., & Sokolov, V. O. (2017). Deep learning for short-term traffic flow prediction. *Transportation Research Part C: Emerging Technologies*, 79, 1-17.
4. Ma, X., Tao, Z., Wang, Y., Yu, H., & Wang, Y. (2015). Long short-term memory neural network for traffic speed prediction using remote microwave sensor data. *Transportation Research Part C: Emerging Technologies*, 54, 187-197.
5. Tian, Y., & Pan, L. (2015, December). Predicting short-term traffic flow by long short-term memory recurrent neural network. In Smart City/SocialCom/SustainCom (SmartCity), 2015 IEEE International Conference on (pp. 153-158). IEEE.
6. Fu, R., Zhang, Z., & Li, L. (2016, November). Using LSTM and GRU neural network methods for traffic flow prediction. In Chinese Association of Automation (YAC), Youth Academic Annual Conference of (pp. 324-328). IEEE.
7. Ma, X., Dai, Z., He, Z., Ma, J., Wang, Y., & Wang, Y. (2017). Learning traffic as images: a deep convolutional neural network for large-scale transportation network speed prediction. *Sensors*, 17(4), 818.
8. Wu, Y., Tan, H., Qin, L., Ran, B., & Jiang, Z. (2018). A hybrid deep learning based traffic flow prediction method and its understanding. *Transportation Research Part C: Emerging Technologies*, 90, 166-180.
9. Yu, H., Wu, Z., Wang, S., Wang, Y., & Ma, X. (2017). Spatiotemporal recurrent convolutional networks for traffic prediction in transportation networks. *Sensors*, 17(7), 1501.

10. Bengio, Y., Lamblin, P., Popovici, D., & Larochelle, H. (2007). Greedy layer-wise training of deep networks. In Advances in neural information processing systems (pp. 153-160).
11. Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., ... & Polosukhin, I. (2017). Attention is all you need. In Advances in neural information processing systems (pp. 5998-6008).
12. Raffel, C., Luong, M. T., Liu, P. J., Weiss, R. J., & Eck, D. (2017, August). Online and linear-time attention by enforcing monotonic alignments. In Proceedings of the 34th International Conference on Machine Learning-Volume 70 (pp. 2837-2846). JMLR. org
13. Zhang, J. "Short-Term Traffic Prediction: Modelling Temporal-Spatial Features in Local Highway Networks with Deep Neural Networks." Unpublished
14. Yu, R., Li, Y., Shahabi, C., Demiryurek, U., & Liu, Y. (2017, June). Deep learning: A generic approach for extreme condition traffic forecasting. In Proceedings of the 2017 SIAM International Conference on Data Mining (pp. 777-785). Society for Industrial and Applied Mathematics.
15. Highways England network journey time and traffic flow data. Available: <http://tris.highwaysengland.co.uk/detail/trafficflowdata>
16. M4 traffic information by @MotorwayCameras. Available: https://twitter.com/Traffic_M4
17. M25 traffic information by @MotorwayCameras. Available: https://twitter.com/Traffic_M25
18. iTIC Open Data Archives, Available: <https://www.iticfoundation.org/data/>
19. Longdo Event, Available: <http://event.longdo.com>
20. Road Safety Data, Available: <https://data.gov.uk/dataset/cb7ae6f0-4be6-4935-9277-47e5ce24a11f/road-safety-data>

ภาคผนวก

ข้อมูลความเร็วจราจรเฉลี่ย เป็นข้อมูลจราจรที่รวบรวมค่าได้จากตัวตรวจด้วยลูป (Inductive Loop Detector) และจากแหล่งอื่น ๆ ซึ่งนำมาประมวลผลร่วมกัน โดยรหัสโหนด ชื่อโหนด คำอธิบายถนนที่ตัวตรวจด้วยลูปใช้ตรวจจับ และพิกัดของตัวตรวจด้วยลูปแต่ละเครื่อง ที่ถูกเลือกมาใช้ในการเรียนรู้ในงานวิจัย แสดงรายละเอียดได้ดังต่อไปนี้

ตารางที่ 19 รายละเอียดของตัวตรวจด้วยลูปบนทางหลวงของประเทศอังกฤษ 52 โหนด

รหัสโหนด	ชื่อโหนดและคำอธิบาย	พิกัด (ละติจูดม ลองจิจูด)
1017	จุดไมดาส (MIDAS) ที่ถนน M4/2259A	51.4948, -0.4695
1109	จุดไมดาส (MIDAS) ที่ถนน M4/2178B	51.4932, -0.3588
1138	จุดไมดาส (MIDAS) ที่ถนน M4/2240A	51.4941, -0.4365
121	จุดไมดาส (MIDAS) ที่ถนน M4/2302B	51.4933, -0.5305
1364	จุดไมดาส (MIDAS) ที่ถนน M4/2388A	51.5080, -0.6393
1400	จุดไมดาส (MIDAS) ที่ถนน M4/2248A	51.4955, -0.4518
1449	จุดไมดาส (MIDAS) ที่ถนน M4/2227A	51.4930, -0.4207
1506	จุดไมดาส (MIDAS) ที่ถนน M25/4888B	51.4438, -0.5297
2163	จุดไมดาส (MIDAS) ที่ถนน M25/5010B	51.5479, -0.5177
2209	จุดไมดาส (MIDAS) ที่ถนน M25/5010A	51.5475, -0.5172
2243	จุดไมดาส (MIDAS) ที่ถนน M4/2210B	51.4899, -0.3989
2291	จุดไมดาส (MIDAS) ที่ถนน M4/2257B	51.4956, -0.4652
2598	จุดไมดาส (MIDAS) ที่ถนน M4/2210A	51.4897, -0.3989
279	จุดไมดาส (MIDAS) ที่ถนน M25/4909A	51.4598, -0.5178
2806	จุดไมดาส (MIDAS) ที่ถนน M4/2240B	51.4943, -0.4364
2848	จุดไมดาส (MIDAS) ที่ถนน M25/4949A	51.4927, -0.4947
2933	จุดไมดาส (MIDAS) ที่ถนน M25/4936A	51.4826, -0.5019
2935	จุดไมดาส (MIDAS) ที่ถนน M4/2262L	51.4952, -0.4710

รหัสโหนด	ชื่อโหนดและคำอธิบาย	พิกัด (ละติจูดม ลองจิจูด)
3031	จุดไมดาส (MIDAS) ที่ถนน M25/4938B	51.4839, -0.5003
308	จุดไมดาส (MIDAS) ที่ถนน M25/4976A	51.5188, -0.4992
3375	จุดไมดาส (MIDAS) ที่ถนน M25/4879B	51.4360, -0.5361
3396	จุดไมดาส (MIDAS) ที่ถนน M4/2262B	51.4952, -0.4710
345	จุดไมดาส (MIDAS) ที่ถนน M4/2193A	51.4890, -0.3753
3452	จุดไมดาส (MIDAS) ที่ถนน M4/2264A	51.4944, -0.4766
3470	จุดไมดาส (MIDAS) ที่ถนน M4/2227B	51.4932, -0.4220
3600	จุดไมดาส (MIDAS) ที่ถนน M25/4993A	51.5357, -0.5005
3678	จุดไมดาส (MIDAS) ที่ถนน M4/2178A	51.4931, -0.3586
3705	จุดไมดาส (MIDAS) ที่ถนน M4/2264M	51.4943, -0.4766
3931	จุดไมดาส (MIDAS) ที่ถนน M25/4963B	51.5063, -0.5003
4121	จุดไมดาส (MIDAS) ที่ถนน M4/2301A	51.4932, -0.5291
4354	จุดไมดาส (MIDAS) ที่ถนน M25/4887A	51.4444, -0.5295
496	จุดไมดาส (MIDAS) ที่ถนน M25/4943B	51.4878, -0.4965
5146	จุดไมดาส (MIDAS) ที่ถนน M4/2193B	51.4892, -0.3755
5209	จุดไมดาส (MIDAS) ที่ถนน M4/2388B	51.5082, -0.6397
5211	จุดไมดาส (MIDAS) ที่ถนน M25/4949B	51.4926, -0.4944
5245	จุดไมดาส (MIDAS) ที่ถนน M25/4879A	51.4361, -0.5366
5399	จุดไมดาส (MIDAS) ที่ถนน M25/4909B	51.4597, -0.5174
5487	จุดไมดาส (MIDAS) ที่ถนน M4/2336A	51.4883, -0.5764
6156-1	จุดทีเอ็มยู (TMU) ที่ถนน M4 ทางเหนือ	51.4927, -0.4538
6157-1	จุดทีเอ็มยู (TMU) ที่ถนน M4 ทางใต้	51.4932, -0.4535
6178-1	จุดทีเอ็มยู (TMU) ที่ถนน A30 ทางตะวันออก	51.4398, -0.5079
6179-1	จุดทีเอ็มยู (TMU) ที่ถนน A30 ทางตะวันตก	51.4396, -0.5073

รหัสโหนด	ชื่อโหนดและคำอธิบาย	พิกัด (ละติจูดม ลองจิจูด)
6209	จุดไมดาส (MIDAS) ที่ถนน M4/2156B	51.4928, -0.3252
6222	จุดไมดาส (MIDAS) ที่ถนน M4/2156A	51.4927, -0.3253
6232	จุดไมดาส (MIDAS) ที่ถนน M4/2248B	51.4957, -0.4518
653	จุดไมดาส (MIDAS) ที่ถนน M25/4976B	51.5188, -0.4989
697	จุดไมดาส (MIDAS) ที่ถนน M25/4993B	51.5358, -0.5003
7044-1	จุดทีเอ็มยู (TMU) ที่ถนน A3113 ทาง ตะวันออก	51.4669, -0.4986
7045-1	จุดทีเอ็มยู (TMU) ที่ถนน A3113 ทางตะวันตก	51.4668, -0.4987
807	จุดไมดาส (MIDAS) ที่ถนน M25/4963A	51.5062, -0.5006
866	จุดไมดาส (MIDAS) ที่ถนน M4/2336B	51.4886, -0.5765
936	จุดไมดาส (MIDAS) ที่ถนน M25/4941A	51.4864, -0.4981

ตารางที่ 20 รายละเอียดของตัวตรวจด้วยหุ่นทางด่วนของประเทศไทย 45 โหนด

รหัสโหนด	ทางด่วนที่ตรวจจับ	พิกัด (ละติจูดม ลองจิจูด)
11058	ทางด่วนเฉลิมมหานคร	13.70865, 100.58418
11062	ทางด่วนเฉลิมมหานคร	13.71182, 100.56819
11063	ทางด่วนเฉลิมมหานคร	13.71182, 100.56819
11066	ทางด่วนเฉลิมมหานคร	13.71584, 100.55713
11070	ทางด่วนเฉลิมมหานคร	13.7085, 100.54976
11071	ทางด่วนเฉลิมมหานคร	13.70031, 100.54185
11073	ทางด่วนเฉลิมมหานคร	13.69804, 100.54028
11074	ทางด่วนเฉลิมมหานคร	13.6937, 100.5305
11079	ทางด่วนเฉลิมมหานคร	13.68555, 100.52076
11082	ทางด่วนเฉลิมมหานคร	13.67081, 100.49443

รหัสโหนด	ทางด่วนที่ตรวจจับ	พิกัด (ละติจูดม ลองจิจูด)
11084	ทางด่วนเฉลิมมหานคร	13.6782, 100.47744
11091	ทางด่วนเฉลิมมหานคร	13.67161, 100.50759
11093	ทางด่วนเฉลิมมหานคร	13.76228, 100.54714
11118	ทางด่วนเฉลิมมหานคร	13.74533, 100.55012
11119	ทางด่วนเฉลิมมหานคร	13.75215, 100.54839
11122	ทางด่วนเฉลิมมหานคร	13.69683, 100.59431
11128	ทางด่วนเฉลิมมหานคร	13.71584, 100.55713
12026	ทางด่วนศรีรัช	13.7588, 100.54845
12029	ทางด่วนศรีรัช	13.75446, 100.56019
12052	ทางด่วนศรีรัช	13.76488, 100.5274
12060	ทางด่วนศรีรัช	13.75374, 100.5232
12065	ทางด่วนศรีรัช	13.73134, 100.51796
12067	ทางด่วนศรีรัช	13.72615, 100.51811
12073	ทางด่วนศรีรัช	13.72615, 100.51811
12085	ทางด่วนศรีรัช	13.69585, 100.52404
12114	ทางด่วนศรีรัช	13.8026, 100.54239
12118	ทางด่วนศรีรัช	13.82732, 100.54344
13034	ทางด่วนศรีรัช	13.84206, 100.53338
13061	ทางด่วนศรีรัช	13.85143, 100.53356
13063	ทางด่วนศรีรัช	13.84208, 100.53437
13066	ทางด่วนศรีรัช	13.86465, 100.5366
13067	ทางด่วนศรีรัช	13.85293, 100.5343
14015	ทางด่วนฉลองรัช	13.75969, 100.59647
14058	ทางด่วนฉลองรัช	13.81467, 100.62214

รหัสโหนด	ทางด่วนที่ตรวจจับ	พิกัด (ละติจูดม ลองจิจูด)
20028	ทางด่วนฉลองรัช	13.71104, 100.56373
20089	ทางด่วนฉลองรัช	13.75374, 100.5232
20097	ทางด่วนฉลองรัช	13.70774, 100.51986
45943	ทางด่วนเฉลิมมหานคร	13.71257, 100.57698
45944	ทางด่วนเฉลิมมหานคร	13.70912, 100.58456
45962	ทางด่วนศรีรัช	13.75335, 100.5745
45967	ทางด่วนศรีรัช	13.75372, 100.58802
45970	ทางด่วนศรีรัช	13.75181, 100.59336
45972	ทางด่วนศรีรัช	13.74869, 100.6041
46124	ทางด่วนเฉลิมมหานคร	13.75629, 100.54483
46125	ทางด่วนเฉลิมมหานคร	13.69378, 100.52771

ประวัติผู้เขียน

ชื่อ-สกุล	นางสาววนิดา ลียงค์
วัน เดือน ปี เกิด	10 กันยายน พ.ศ. 2535
สถานที่เกิด	กรุงเทพมหานคร
วุฒิการศึกษา	วท.บ (เกียรตินิยมอันดับหนึ่ง) วิชาวิทยาการคอมพิวเตอร์
ผลงานตีพิมพ์	W. Liyong and P. Vateekul, "Improve Traffic Prediction Using Accident Embedding on Ensemble Deep Neural Networks", The 2019 - 11th International Conference on Knowledge and Smart Technology (KST - 2019) W. Liyong and P. Vateekul, "Traffic Prediction Using Attentional Spatial-Temporal Deep Learning with Accident Embedding", 2019 the 4th International Conference on Computational Intelligence and Applications (ICCIA 2019)