

## การประยุกต์โครงข่ายประสาทเทียมร่วมกับความสัมพันธ์ของโครงข่ายถนนโดยรอบในการทำนายเวลาเดินทางบนถนนในเขตเมือง

### Application of Artificial Neural Networks and Neighboring Sections Relationship in the Short-Term Travel Time Prediction on Urban Roadways

พรเทพ พวงประโคน<sup>1\*</sup> และ สรวิศ นฤปิติ<sup>2</sup>

<sup>1</sup> ภาควิชาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีมหานคร กรุงเทพมหานคร

<sup>2</sup> ภาควิชาวิศวกรรมโยธา คณะเทคโนโลยีวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย กรุงเทพฯ

\*Corresponding author; E-mail address: puangprakhon@gmail.com

#### บทคัดย่อ

เวลาเดินทางบนถนนในเขตเมืองมีลักษณะซับซ้อน มีการเปลี่ยนแปลง และแกว่งตัวสูง เนื่องจากถูกรบกวนจากปัจจัยแวดล้อมหลายประการ อย่างไรก็ตามปัจจุบันวิธีการทำนายเวลาเดินทางล่วงหน้าบนถนนเหล่านี้โดยส่วนใหญ่นิยมใช้วิธีการอย่างง่าย เช่น พิจารณาใช้รูปแบบข้อมูลเวลาเดินทางในอดีตเป็นตัวแทน หรือใช้เวลาการเดินทางปัจจุบันเป็นค่าประมาณการเวลาเดินทางในอนาคต เป็นต้น มิได้มีการพิจารณาแนวโน้มการเปลี่ยนแปลง และความสัมพันธ์ระหว่างสภาพจราจรบนโครงข่ายถนนโดยรอบ ซึ่งมีอิทธิพลต่อสภาพจราจรและเวลาเดินทางบนถนนที่ศึกษา ในการพัฒนาแบบจำลองเพื่อทำนายเวลาเดินทาง บทความนี้นำเสนอกระบวนการประยุกต์โครงข่ายประสาทเทียมร่วมกับความสัมพันธ์ของสภาพจราจรของโครงข่ายถนนโดยรอบ ในการทำนายเวลาเดินทางบนถนนในเขตเมือง ผลการศึกษาจากสภาพจราจรจริงในเขตเมืองกรุงเทพมหานครพบว่าวิธีการที่นำเสนอให้ผลการทำนายเวลาเดินทางแม่นยำกว่าวิธีการพื้นฐานในทุกสถานการณ์ นอกจากนี้ได้นำเสนอแบบจำลองที่สามารถประยุกต์ใช้ได้ ในกรณีที่ไม่มีข้อมูลเวลาเดินทางบนถนนที่ศึกษา เพื่อช่วยแก้ปัญหาการทำนายเวลาเดินทางบนถนนที่ไม่มีข้อมูลในอดีต ซึ่งเป็นจุดอ่อนของวิธีการที่นิยมใช้ในปัจจุบัน

คำสำคัญ: การทำนายเวลาเดินทาง, ถนนในเขตเมือง, โครงข่ายถนน, โครงข่ายประสาทเทียม

#### Abstract

In general, travel times on urban road networks are highly stochastic due to various disturbance factors from surrounding environment. However, most of the existing short-term travel time prediction techniques on these roadways are very simple methods e.g. using the travel time from historical database to expect the forthcoming travel time according to a specified

date and time, or using the current travel time for representing the forecasted travel time of the study section. There was lack of consideration on the forming and dissipating trends of traffic congestion, and the effects from the neighboring road sections which commonly influences the traffic conditions and travel times of the study sections. This study aims to develop the robust travel time prediction models by using Artificial Neural Networks (ANNs) technique together with the integrating of data from neighboring sections as the candidates for model inputs. The testing results from the real field data on urban roadway networks in Bangkok CBD indicated the proposed technique was superior to the baseline models in all testing scenarios. Furthermore, in the case that data from target section was missing, this paper also suggested the model that could address the travel time prediction problem with acceptable results.

Keywords: Travel time prediction, Urban roadways, Neighboring sections, Artificial Neural Networks

#### 1. บทนำ

ข้อมูลจราจรที่เป็นปัจจุบันมีความสำคัญอย่างยิ่งต่อผู้ใช้ถนนและผู้ควบคุมการจราจร โดยช่วยให้ผู้ใช้ข้อมูลสามารถตัดสินใจดำเนินการต่างๆ ได้อย่างมีประสิทธิภาพ นอกจากนี้ข้อมูลจราจรที่เป็นปัจจุบันแล้ว การทราบสภาพจราจรในอนาคตอันใกล้จะยิ่งช่วยเพิ่มประสิทธิภาพในการตัดสินใจให้สูงขึ้น ทั้งในด้านการวางแผนการเดินทางล่วงหน้า และการวางแผนจัดการการจราจรได้อย่างเหมาะสม

วิธีการทำนายสภาพจราจรและเวลาที่ใช้ในการเดินทาง สามารถกระทำได้หลายวิธี ตั้งแต่การใช้วิธีการอย่างง่ายจนถึงกระบวนการที่ซับซ้อน เช่น การใช้สมการถดถอย การใช้อัลกอริทึมแบบต่างๆ การใช้ตัวกรอง

Kalman และการใช้โครงข่ายประสาทเทียม เป็นต้น การศึกษาที่ผ่านมาเกี่ยวกับการทำนายเวลาการเดินทางบนถนนในเขตเมืองซึ่งเป็นถนนประเภทที่มีความซับซ้อนและถูกรบกวนจากปัจจัยแวดล้อมหลายประการพบว่า ในกรณีที่มีข้อมูลในอดีตเพียงพอ การใช้โครงข่ายประสาทเทียมสามารถให้ผลการทำนายที่มีค่าใกล้เคียงกับค่าจริงได้ นอกจากนี้ข้อดีของวิธีโครงข่ายประสาทเทียม คือ เป็นวิธีที่ใช้ข้อมูลขับเคลื่อน (data driven) จึงไม่จำเป็นต้องสร้างแบบจำลองหรือใช้ทฤษฎีจราจรที่มีความซับซ้อนสามารถประยุกต์ใช้ได้สะดวกรวดเร็ว และมีซอฟต์แวร์จำนวนมากที่รองรับการประยุกต์ใช้งานโครงข่ายประสาทเทียมในปัจจุบัน

อย่างไรก็ตามถึงแม้การศึกษาที่ผ่านมาพบว่าการใช้โครงข่ายประสาทเทียมในการทำนายเวลาที่ใช้ในการเดินทางให้ผลเป็นที่น่าพอใจ แต่การศึกษาส่วนใหญ่เป็นการศึกษาบนถนนที่มีการจำกัดการเข้าถึง เช่น ทางด่วน หรือมอเตอร์เวย์ เป็นต้น โดยพฤติกรรมของถนนเหล่านี้มีความซับซ้อนน้อยกว่าถนนในเขตเมืองอย่างมาก อีกทั้งงานวิจัยจำนวนมากใช้ข้อมูลที่ได้จากแบบจำลองสภาพจราจร (traffic simulation) ซึ่งไม่สามารถสะท้อนพฤติกรรมจราจรจริงได้ครบถ้วน นอกจากนี้แบบจำลองที่พัฒนาขึ้นส่วนใหญ่มักพิจารณาเฉพาะข้อมูลในอดีตของถนนที่ต้องการทำนายเวลาเดินทางเท่านั้น ไม่ได้มีการพิจารณาข้อมูลของโครงข่ายถนนโดยรอบซึ่งมีอิทธิพลต่อสภาพจราจรของถนนที่พิจารณา ดังนั้นหากไม่มีข้อมูลในอดีตของถนนที่พิจารณาจะไม่สามารถทำนายเวลาเดินทางในอนาคตได้


บทความนี้นำเสนอวิธีการทำนายเวลาการเดินทางบนถนนในเขตเมืองโดยประยุกต์ใช้โครงข่ายประสาทเทียม ร่วมกับข้อมูลจราจรของโครงข่ายถนนโดยรอบ เพื่อรวมอิทธิพลของสภาพจราจรโดยรอบในการสร้างแบบจำลอง และแก้ปัญหาการไม่สามารถทำนายได้เมื่อขาดข้อมูลในอดีตของถนนที่พิจารณา

## 2. แนวคิดพื้นฐานเกี่ยวกับการพัฒนาแบบจำลอง

### 2.1 โครงข่ายถนนในการพัฒนาแบบจำลอง

รูปที่ 1 แสดงโครงข่ายถนนในการพัฒนาแบบจำลองเพื่อทำนายเวลาเดินทาง โดยประกอบด้วยถนนทั้งหมดจำนวน 14 ทิศทาง ถนนหมายเลข 1 คือ ถนนที่ต้องการทำนายเวลาเดินทางในอนาคต (Target, T) ถนนหมายเลข 2, 3 และ 4 คือ ถนนต้นทาง (Upstream) ที่ส่งกระแสจราจรมายังถนนหมายเลข 1 ซึ่งในที่นี้แทนด้วยสัญลักษณ์ UD, UL และ UR ตามลำดับ ถนนหมายเลข 5, 6 และ 7 คือ ถนนปลายทาง (Downstream) ที่รับกระแสจราจรจากถนนหมายเลข 1 ซึ่งในที่นี้แทนด้วยสัญลักษณ์ DD, DL และ DR ตามลำดับ ถนนหมายเลข 8, 9 และ 10 คือ ถนนที่ใช้สัญญาณไฟร่วมกับถนนหมายเลข 1 (Signal sharing) ซึ่งในที่นี้แทนด้วยสัญลักษณ์ SD, SL และ SR ตามลำดับ ส่วนถนนหมายเลข 11, 12, 13 และ 14 เป็นถนนที่มีได้มีการรับ ส่ง หรือใช้สัญญาณไฟร่วมกับถนนหมายเลข 1

บทความนี้พิจารณาใช้ข้อมูลจราจรในอดีตของถนนที่พิจารณา (หมายเลข 1) และถนนโดยรอบที่มีอิทธิพลต่อถนนที่พิจารณา (หมายเลข 2 ถึง 10) เป็นข้อมูลนำเข้าในแบบจำลองการทำนายเวลาเดินทางต่อไป



รูปที่ 1 โครงข่ายถนนในเขตเมือง

### 2.2 การทำนายเวลาเดินทางล่วงหน้าโดยโครงข่ายประสาทเทียม

โครงข่ายประสาทเทียม (Artificial Neuron Network : ANN) เป็นศาสตร์แขนงหนึ่งของทางด้านปัญญาประดิษฐ์ มีรูปแบบโครงสร้างและการประมวลผลเหมือนกับสมองของสิ่งมีชีวิตซึ่งมีปรับเปลี่ยนตัวเองต่อการตอบสนองของอินพุตตามกฎของการเรียนรู้ (learning rule) หลังจากที่ได้เรียนรู้รูปร่างที่ต้องการแล้ว โครงข่ายนั้นจะสามารถทำงานที่กำหนดไว้ได้ เช่น มีความสามารถในการเรียนรู้การจดจำรูปแบบ (Pattern Recognition) และการสร้างความรู้ใหม่ (Knowledge Extraction) เป็นต้น

จากการทบทวนวรรณกรรมพบว่า มีการศึกษาหลายชิ้นประยุกต์ใช้โครงข่ายประสาทเทียมรูปแบบต่างๆ ในการทำนายพฤติกรรมจราจรล่วงหน้า เช่น การใช้ multilayer feedforward with back propagation [1-3] การใช้ dynamics time-delayed neural networks [4] การใช้ state-space neural networks [5-7] ในการทำนายเวลาเดินทางและสภาพจราจร อย่างไรก็ตามโครงข่ายประสาทเทียมเป็นแบบจำลองที่สร้างขึ้นโดยเฉพาะสำหรับแต่ละพื้นที่ ไม่สามารถนำโครงข่ายประสาทเทียมสำหรับพื้นที่หนึ่งไปใช้กับอีกพื้นที่ได้โดยตรง

การศึกษานี้ทำการพัฒนาโครงข่ายประสาทเทียมสำหรับทำนายเวลาเดินทางล่วงหน้าบนถนนในเขตเมืองในพื้นที่กรุงเทพมหานคร โดยพิจารณาใช้โครงข่ายประสาทเทียมแบบ multilayer feedforward เป็นโครงสร้างหลักของโครงข่ายประสาทเทียม เนื่องจากเป็นรูปแบบที่ไม่ซับซ้อนยุ่งยากในการพัฒนา สามารถนำเข้าข้อมูลเชิงตำแหน่งและข้อมูลเวลาการเดินทางในอดีตได้สะดวก เป็นแบบจำลองงานวิจัยจำนวนมากในอดีตเลือกใช้โดยให้ผลการทำนายที่แม่นยำ ทั้งจากการศึกษาโดยข้อมูลที่สำรวจได้จริงในสนามและข้อมูลที่ได้จากแบบจำลองสภาพจราจร

### 2.3 อินพุตสำหรับแบบจำลองในการทำนายเวลาเดินทาง

จำนวนอินพุตหรือนิวรอน (neurons) ในโครงข่ายประสาทเทียมมีความสัมพันธ์กับจำนวนตัวแปร (variable) ที่ใช้ในการทำนายเวลาเดินทาง การศึกษานี้พิจารณาตัวแปรที่เป็นไปได้และคาดว่าส่งผลต่อเวลาเดินทางในอนาคตของถนนที่ศึกษาโดยจำแนกเป็นกลุ่มได้ดังนี้

- (1) เวลาเดินทางในอดีตของถนนที่พิจารณา โดยผลการศึกษาที่ผ่านมาบ่งชี้ว่าเวลาเดินทางในอดีตมีผลอย่างมากต่อเวลาเดินทางในอนาคตของถนนที่ศึกษา การศึกษานี้พิจารณาค่าเฉลี่ยเวลาเดินทางในอดีตเมื่อ 15, 30, 45 และ 60 นาที ที่ผ่านมาจากถนน

ที่ศึกษา เป็นตัวแปรที่อาจนำไปใช้ในโครงข่ายประสาทเทียมเพื่อทำนายเวลาเดินทางต่อไป

- (2) เวลาเดินทางในอดีตของถนนต้นทาง ปลายทาง และใช้สัญญาณไฟร่วมกับถนนที่พิจารณา เนื่องจากโดยทั่วไปสภาพจราจรของถนนเหล่านี้มีความสัมพันธ์กับสภาพจราจรของถนนที่พิจารณา และมักจะมีอิทธิพลต่อสภาพจราจรของถนนที่พิจารณา การศึกษานี้พิจารณาค่าเฉลี่ยเวลาเดินทางของถนนแต่ละช่วงในอดีตเมื่อ 15, 30, 45 และ 60 นาที ที่ผ่านมา เป็นตัวแปรที่อาจนำไปใช้ในโครงข่ายประสาทเทียมเพื่อทำนายเวลาเดินทางต่อไป

#### 2.4 การคัดเลือกตัวแปรเพื่อเป็นอินพุตในโครงข่ายประสาทเทียม

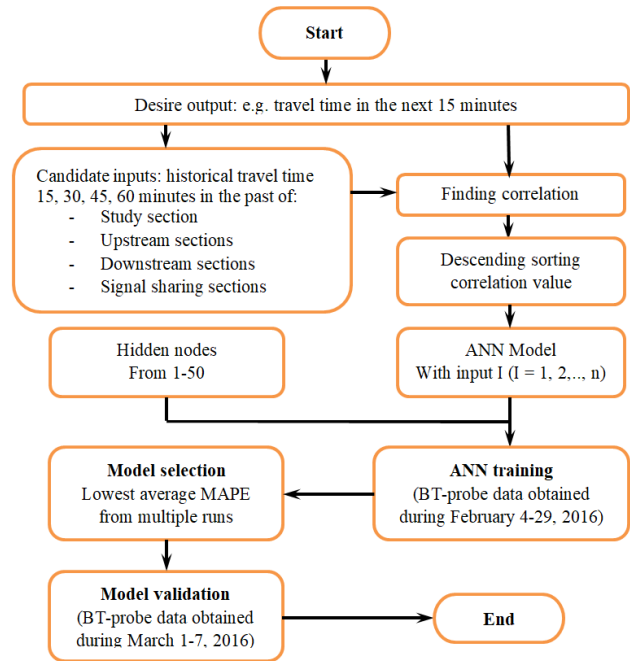
วิธีการเลือกตัวแปร (Input Variable Selection : IVS) เป็นประเด็นที่มีการศึกษาวิจัยอย่างกว้างขวางในงานทางด้านปัญญาประดิษฐ์ โดยทั่วไปแล้วสามารถจำแนกวิธีการเลือกตัวแปรได้เป็น 3 กลุ่มใหญ่ [8, 9] คือ (1) wrapper algorithm คือ การรวมกระบวนการ IVS เข้าไปเป็นส่วนหนึ่งในขั้นตอนการ optimization โครงสร้างของแบบจำลอง (2) embedded algorithm โดย IVS ได้รับการรวมเข้าไปในกระบวนการเรียนรู้ (training) ของโครงข่ายประสาทเทียม และ (3) filtering algorithm ซึ่งแตกต่างจากสองวิธีข้างต้น โดยจะแยก IVS ออกจากกระบวนการเรียนรู้โครงข่ายประสาทเทียม และใช้หลักการทางสถิติในการจำแนกและหาความสัมพันธ์ของตัวแปรแต่ละตัวที่มีต่อผลลัพธ์ ในการศึกษาครั้งนี้พิจารณาใช้ค่าสหสัมพันธ์ (Pearson correlation,  $R$ ) ซึ่งเป็นค่าที่นิยมใช้สำหรับการวิเคราะห์เชิงสถิติและการทำเหมืองข้อมูล [10] เป็นเครื่องมือเบื้องต้นในการคัดเลือกตัวแปร โดยการคำนวณค่า  $R$  แสดงได้ดังสมการ (1)

$$R_{XY} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (1)$$

เมื่อ  $n$  คือ จำนวนตัวอย่าง  $x_i, y_i$  คือ ค่าใดๆของแต่ละตัวแปร ที่เป็นคู่กัน  $\bar{x}, \bar{y}$  คือ ค่าเฉลี่ยของแต่ละตัวแปร

การใช้ค่าสหสัมพันธ์ในการคัดเลือกตัวแปรเป็นหนึ่งในวิธีการที่มีการใช้งานอย่างแพร่หลาย การคัดเลือกตัวแปรสามารถกระทำได้โดยการเรียงลำดับค่าสหสัมพันธ์จากสูงไปต่ำแล้วคัดเลือกตัวแปรที่มีค่าสหสัมพันธ์สูงตามจำนวนที่ต้องการ หรือการเลือกใช้เฉพาะตัวแปรที่มีค่าสหสัมพันธ์เป็นค่าบวก นอกจากนี้อาจใช้หลักพิจารณาอย่างง่าย [10] คือ ในกรณีที่มีจำนวนตัวแปรจำนวนมากให้เลือกใช้ตัวแปรที่มีค่าสหสัมพันธ์สูงกว่า  $2/\sqrt{n}$  เป็นต้น

การศึกษานี้ทำการคัดเลือกตัวแปรเพื่อเป็นอินพุตสำหรับโครงข่ายประสาทเทียม โดยการจัดเรียงตัวแปรแต่ละตัวตามค่าสหสัมพันธ์จากสูงไปต่ำ จากนั้นจึงนำตัวแปรแต่ละตัวเพิ่มเข้าไปเรื่อยๆ ตามลำดับ ในขั้นตอนกระบวนการเรียนรู้ (training) ของโครงข่ายประสาทเทียม ดังรูปที่ 2



รูปที่ 2 กระบวนการพัฒนาแบบจำลองโครงข่ายประสาทเทียมเพื่อทำนายเวลาเดินทาง

#### 2.5 การเลือกจำนวน neuron ในชั้น hidden layer


การศึกษาที่ผ่านมา [11, 12] พบว่าการใช้โครงข่ายประสาทเทียมแบบ multilayer feedforward ที่มี 1 hidden layer เพียงพอต่อการแก้ปัญหาที่มีความซับซ้อนและไม่เป็นเชิงเส้นโดยให้คำตอบที่มีความถูกต้องตามที่ต้องการได้ นอกจากนี้ยังพบว่าผลลัพธ์จากการศึกษาที่ผ่านมาเกี่ยวกับการทำนายเวลาเดินทางโดยใช้โครงข่ายประสาทเทียมประเภทนี้อยู่ในเกณฑ์ที่น่าพอใจเช่นเดียวกัน [13-16] จากเหตุผลข้างต้นการศึกษานี้จึงพิจารณาเลือกใช้โครงข่ายประสาทเทียมแบบ multilayer feedforward ที่มีโครงสร้าง 3 layer โดยประกอบด้วย 1 อินพุตเลเยอร์ 1 hidden layer และ 1 เอาต์พุตเลเยอร์ เป็นโครงสร้างหลักของแบบจำลองในการทำนายเวลาเดินทาง

เนื่องจากไม่มีข้อสรุปที่ชัดเจนในการกำหนดจำนวน neuron ที่เหมาะสมในชั้น hidden layer ของโครงข่ายประสาทเทียม การศึกษานี้ใช้วิธี trial and error ในการกำหนดจำนวน neuron โดยใช้ข้อมูลเวลาเดินทางที่สำรวจได้จริงระหว่างวันที่ 4 ถึง 29 กุมภาพันธ์ 2559 ซึ่งเป็นข้อมูลที่ใช้ในกระบวนการเรียนรู้ของแบบจำลอง (training dataset) มาทำการทดสอบโดยกำหนดจำนวน neuron ในการทดสอบตั้งแต่ 1 ถึง 50 neuron และทำการใส่ค่าตัวแปรที่เรียงลำดับตามกระบวนการในข้อ 2.4 เพิ่มขึ้นทีละตัว ทำการทดสอบด้วยวิธี 5-fold cross validation และทำซ้ำจำนวน 5 ครั้ง จากนั้นเลือกใช้โครงสร้างของแบบจำลอง (จำนวนอินพุตจำนวน hidden neuron และค่าน้ำหนัก) ที่ให้ค่า mean absolute percentage error (MAPE) ต่ำสุด เป็นโครงสร้างของแบบจำลองที่จะนำไปใช้ในกระบวนการทำนายเวลาเดินทางต่อไป

### 3. วิธีการศึกษา

#### 3.1 พื้นที่ศึกษา

พื้นที่ศึกษาประกอบด้วยถนนในเขตเมืองกรุงเทพมหานคร จำนวน 14 ช่วง แต่ละช่วงแบ่งแยกโดยสัญญาณไฟจราจร มีความยาวตั้งแต่ 0.5 ถึง 1.49 กิโลเมตร รายละเอียดของพื้นที่ศึกษาแสดงดังรูปที่ 3 และตารางที่ 1 ถนนที่ต้องการทำนายเวลาเดินทาง คือ ถนนหมายเลข 01-16 (แยกสามย่านถึงแยกปทุมวัน) ทำการเก็บข้อมูลเวลาเดินทางบนถนนทุกช่วงโดยการตรวจจับสัญญาณจากอุปกรณ์บลูทูธที่เคลื่อนตัวผ่านทางแยกต่างๆ และวิเคราะห์เพื่อหาเวลาเดินทางบนถนนแต่ละช่วง [17] รายละเอียดของเวลาเดินทางเฉลี่ยบนถนนแต่ละช่วงรวมทั้งปริมาณที่เกี่ยวกับการเดินทางเฉลี่ยต่อ 15 นาที ที่ตรวจจับได้จากอุปกรณ์บลูทูธหลังผ่านการกรองข้อมูลแล้ว แสดงดังตารางที่ 2 โดยเกี่ยวกับการเดินทางเฉลี่ยที่ตรวจจับได้จากยานพาหนะที่มีอุปกรณ์บลูทูธบนถนนแต่ละช่วง มีค่าตั้งแต่ 1.82 เทียบ/15 นาที บนถนนหมายเลข 15-16 (แยกเจริญผลถึงแยกปทุมวัน) มีค่าสูงสุดเท่ากับ 10/36 เทียบ/15 นาที บนถนนหมายเลข 25-16 (แยกราชเทวีถึงแยกปทุมวัน) และมีค่าเฉลี่ยเท่ากับ 5.81 เทียบ/15 นาที



รูปที่ 3 พื้นที่ศึกษา

ตารางที่ 1 ชื่อและตำแหน่งของแยกต่างๆ ในบริเวณพื้นที่ศึกษา

หมายเลขทางแยก	ชื่อแยก	ละติจูด	ลองจิจูด
1	สามย่าน	13.73292	100.52870
6	เฉลิมเผ่า	13.74538	100.53588
15	เจริญผล	13.74743	100.52387
16	ปทุมวัน	13.74613	100.53082
25	ราชเทวี	13.75351	100.53151
33	สะพานเหลือง	13.73577	100.52155

46	อังรีตุนัง	13.73090	100.53359
48	มหานคร-สีพระยา	13.73063	100.51816

ตารางที่ 2 ข้อมูลจราจรที่สำรวจได้จากพื้นที่ศึกษา

ถนน	ความยาว (กม.)	ข้อมูลที่ตรวจจับได้จากอุปกรณ์บลูทูธ		
		จำนวนเที่ยวที่สำรวจได้/15 นาที	เวลาเดินทางเฉลี่ย (วินาที)	ความเร็วเฉลี่ย (กม./ชม.)
01-16*	1.491	3.18	537.47	9.99
16-01	1.491	5.51	349.29	15.37
01-33	0.841	10.20	198.32	15.26
33-01	0.841	5.23	252.58	11.98
01-46	0.568	6.81	202.51	10.10
46-01	0.568	8.57	160.32	12.75
01-48	1.173	1.42	1161.37	3.64
48-01	1.173	5.30	340.98	12.39
06-16	0.551	6.84	230.03	8.63
16-06	0.551	1.89	317.48	6.25
15-16	0.761	1.82	499.36	5.49
16-15	0.761	9.53	149.78	18.30
16-25	0.794	4.71	431.41	6.62
25-16	0.794	10.36	179.69	15.90
เฉลี่ย		5.81	357.90	10.91

หมายเหตุ ข้อมูลช่วง 06:00-21:00 น. ระหว่างวันที่ 4 กุมภาพันธ์ - 7 มีนาคม 2559

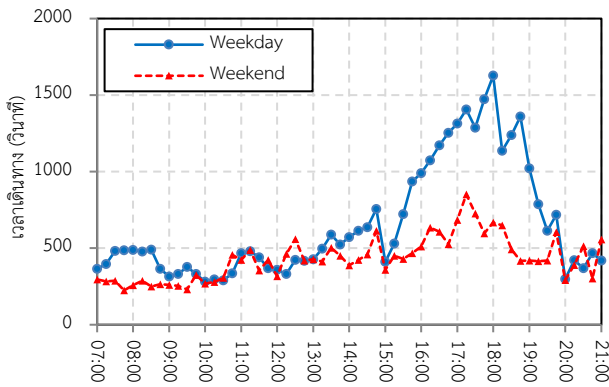
\*ถนนเป้าหมายที่ต้องการทำนายเวลาเดินทาง

รูปที่ 4 แสดงเวลาเดินทางเฉลี่ยแต่ละช่วงเวลาในวันทำงานและวันหยุด บนถนนหมายเลข 01-16 ซึ่งเป็นถนนเป้าหมายที่จะทำการทำนายเวลาเดินทาง พบว่าเวลาเดินทางเฉลี่ยในช่วงที่การจราจรไม่ติดขัดมีค่าประมาณ 200 วินาที เกิดขึ้นในวันหยุดช่วงเวลาประมาณ 7:45 ถึง 9:30 น.

เวลาเดินทางในวันทำงานและวันหยุดมีความแตกต่างกันอย่างเห็นได้ชัด โดยในวันทำงานช่วงชั่วโมงเร่งด่วนเช้าระหว่าง 7:30-8:30 มีเวลาเดินทางสูงสุดประมาณ 500 วินาที (ประมาณ 2.5 เท่าของช่วงที่การจราจรไม่ติดขัด) ส่วนในช่วงเย็นเริ่มตรวจพบการก่อตัวของจราจรติดขัดตั้งแต่เวลาประมาณ 15:00 น. โดยพบเวลาเดินทางสูงสุดประมาณ 1600 วินาที (ประมาณ 8 เท่าของช่วงที่การจราจรไม่ติดขัด) ที่ช่วงเวลาประมาณ 18:00 น. จากนั้นสภาพจราจรติดขัดจึงเริ่มสลายตัวและกลับเข้าสู่สภาวะปกติที่เวลาประมาณ 20:00 น.

ในช่วงวันหยุด สภาพจราจรในช่วงเช้าไม่ติดขัด ไม่พบช่วงเร่งด่วนเช้า ในช่วงเย็นตรวจพบเวลาเดินทางสูงขึ้น โดยมีค่าสูงสุดประมาณ 800 วินาที (ประมาณ 4 เท่าของช่วงที่การจราจรไม่ติดขัด) ที่เวลา 17:45 น. และเริ่มกลับเข้าสู่สภาวะปกติหลังจากเวลาประมาณ 18:45 น.





รูปที่ 4 เวลาเดินทางเฉลี่ยในช่วงเวลาต่างๆ ของถนนหมายเลข 01-16

### 3.2 ข้อมูลที่ใช้ในการพัฒนาและตรวจสอบความถูกต้องของแบบจำลอง

ข้อมูลเวลาเดินทางที่ใช้ในการศึกษานี้ได้จากการเก็บข้อมูลตลอด 24 ชั่วโมง เป็นเวลา 33 วัน ระหว่างวันที่ 4 กุมภาพันธ์ ถึง 7 มีนาคม 2559 จากนั้นจึงคัดเลือกเฉพาะข้อมูลระหว่างช่วงเวลา 06:00-21:00 น. มาเพื่อใช้ในการศึกษา ทั้งนี้เนื่องจากเป็นช่วงที่สภาพจราจรและเวลาเดินทางมีความเปลี่ยนแปลงสูงคาดการณ์ได้ยากกว่าเมื่อเทียบกับช่วงเวลากลางคืน อีกทั้งปริมาณข้อมูลที่สำรวจได้ช่วงกลางวันมีจำนวนมากกว่าทำให้ได้ค่าที่น่าเชื่อถือกว่าข้อมูลที่สำรวจได้ช่วงกลางคืน

จากข้อมูลทั้งหมดที่ทำการสำรวจจำนวน 33 วัน ข้อมูลจะถูกแบ่งเป็น 2 ชุด ข้อมูลชุดแรกประกอบด้วยข้อมูล 26 วัน (วันที่ 4-29 กุมภาพันธ์ 2559) ใช้ในกระบวนการเรียนรู้ (training and learning process) และพัฒนาแบบจำลองโครงข่ายประสาทเทียม ข้อมูลชุดที่สอง ประกอบด้วยข้อมูล 7 วัน (วันที่ 1-7 มีนาคม 2559) ใช้ในการตรวจสอบความถูกต้องในการทำนายเวลาเดินทางของแบบจำลองโครงข่ายประสาทเทียมที่ได้พัฒนาขึ้น

### 3.3 สถานการณ์ที่ใช้พัฒนาและทดสอบแบบจำลองโครงข่ายประสาทเทียม

การศึกษานี้แบ่งสถานการณ์ที่ใช้พัฒนาและตรวจสอบความถูกต้องของโครงข่ายประสาทเทียมในการทำนายเวลาเดินทางออกเป็น 3 สถานการณ์ดังต่อไปนี้

สถานการณ์ที่ 1 เมื่อทราบเฉพาะข้อมูลเวลาเดินทางในอดีตของถนนที่ต้องการทำนายเวลาเดินทางเท่านั้น ในกรณีนี้กระบวนการพัฒนาโครงข่ายประสาทเทียมจะใช้เฉพาะข้อมูลในอดีตจากถนนที่พิจารณาเท่านั้น แบบจำลองโครงข่ายประสาทเทียมลักษณะนี้เป็นรูปแบบที่พบได้เป็นส่วนใหญ่ในงานศึกษาวิจัยที่ผ่านมา

สถานการณ์ที่ 2 เมื่อทราบข้อมูลเวลาเดินทางในอดีตของถนนที่ต้องการทำนายเวลาเดินทางและโครงข่ายถนนโดยรอบทุกทิศทาง ในกรณีนี้กระบวนการพัฒนาโครงข่ายประสาทเทียมจะใช้ข้อมูลในอดีตจากถนนที่พิจารณาและโครงข่ายถนนโดยรอบ

สถานการณ์ที่ 3 เมื่อไม่ทราบข้อมูลเวลาเดินทางในอดีตของถนนที่ต้องการทำนายเวลาเดินทาง แต่ทราบข้อมูลเวลาเดินทางในอดีตของ

โครงข่ายถนนโดยรอบทุกทิศทาง ในกรณีนี้กระบวนการพัฒนาโครงข่ายประสาทเทียมจะใช้เฉพาะข้อมูลในอดีตจากโครงข่ายถนนโดยรอบเท่านั้น (ไม่ใช้ข้อมูลในอดีตของถนนที่ต้องการทำนายเวลาเดินทางในการพัฒนาโครงข่ายประสาทเทียม)

โครงข่ายประสาทเทียมจะได้รับการพัฒนาขึ้นตามสถานการณ์จำลองทั้ง 3 สถานการณ์ข้างต้น เพื่อใช้ทำนายเวลาเดินทางของถนนที่ศึกษา (ถนนหมายเลข 01-16) ล่วงหน้า 15, 30, 45 และ 60 นาที โดยชื่อของโครงข่ายประสาทเทียมที่พัฒนาขึ้นตามสถานการณ์ที่ 1, 2 และ 3 คือ ANN (Target) ANN (All) และ ANN (Miss) ตามลำดับ

## 4. ผลการศึกษา

ผลการคัดเลือกอินพุตสำหรับโครงข่ายประสาทเทียมเพื่อใช้ทำนายเวลาเดินทางล่วงหน้าในช่วงเวลาต่างๆ โดยใช้ข้อมูลเวลาเดินทางที่สำรวจได้ระหว่างวันที่ 4-29 กุมภาพันธ์ 2559 แสดงดังตารางที่ 3

ตารางที่ 3 ผลการคัดเลือกอินพุตสำหรับโครงข่ายประสาทเทียม

ช่วงเวลาทำนาย	สถานการณ์ที่ 1 ANN (Target)		สถานการณ์ที่ 2 ANN (All)		สถานการณ์ที่ 3 ANN (Miss)	
	อินพุต	MAPE	อินพุต	MAPE	อินพุต	MAPE
ล่วงหน้า 15 นาที	T15	31.07	T15 T30 DD15 DD30	30.58	DD15 DD30 DD45 DD60 UL15 UL30 UL45	32.73
ล่วงหน้า 30 นาที	T15	37.73	T15 T30 DD15 DD30	36.39	DD15 DD30	33.89
ล่วงหน้า 45 นาที	T15 T30 T45 T60	38.45	T15 T30 DD15	36.35	DD15	34.59
ล่วงหน้า 60 นาที	T15 T30	34.59	T15 T30 T45 DD15 DD30 DD45 UL15	34.49	DD15 DD30 DD45 DD60 UL15 UL30 UD15 DL15	34.88

โครงข่ายประสาทเทียมแบ่งออกเป็น 3 สถานการณ์ ดังที่กล่าวไว้ในหัวข้อ 3.3 และแบ่งช่วงเวลาก่อนหน้าออกเป็น 4 ช่วง คือ ทำนายเวลาเดินทางล่วงหน้า 15, 30, 45 และ 60 นาที ค่า MAPE ที่แสดงในตารางที่ 3 คือค่า MAPE ของแบบจำลองให้ผลการทำนายแม่นยำที่สุดในขั้นตอนการพัฒนาแบบจำลองซึ่งใช้กระบวนการ 5-fold cross validation

ตัวอย่างคำอธิบายความหมายของค่าในตาราง เช่น ในการทำนายเวลาล่วงหน้า 15 นาที โดยพิจารณาโครงข่ายประสาทเทียมตามสถานการณ์ที่ 2 จะได้อินพุตที่เหมาะสม 4 ตัว คือ ข้อมูลเวลาเดินทางย้อนหลัง 15 นาที ที่ผ่านมาของถนนที่ศึกษา (T15), ข้อมูลเวลาเดินทางย้อนหลัง 30 นาที ที่ผ่านมาของถนนที่ศึกษา (T30), ข้อมูลเวลาเดินทางย้อนหลัง 15 นาที ที่ผ่านมาของถนนปลายทางในทิศทางตรง (DD15), และข้อมูลเวลาเดินทางย้อนหลัง 30 นาที ที่ผ่านมาของถนนปลายทางในทิศทางตรง (DD30) โดยในกระบวนการพัฒนาแบบจำลองพบว่าโครงสร้างนี้ให้ค่า MAPE ในการทำนายผลเท่ากับร้อยละ 30.58

เมื่อได้โครงสร้างแบบจำลองที่เหมาะสมดังตารางที่ 3 แล้ว จึงทำการตรวจสอบความแม่นยำของโครงข่ายประสาทเทียมที่พัฒนาขึ้นใน โดยเปรียบเทียบกับวิธีการพื้นฐานต่างๆ ที่นิยมใช้ในการทำนายและให้ข้อมูลเวลาเดินทาง 3 วิธีประกอบด้วย การใช้ข้อมูลจากฐานข้อมูลในอดีตเป็นตัวแทนของเวลาในอนาคต (Database) การใช้เวลาเดินทางที่ประมาณได้ในปัจจุบันเป็นตัวแทนของเวลาในอนาคต (Current TT) และการใช้ค่าเฉลี่ยเคลื่อนที่ลำดับต่างๆ (moving average, MA)

ค่าเฉลี่ยเคลื่อนที่ คือ ค่าเฉลี่ยของจำนวน N จำนวน ที่ผ่านมา สามารถคำนวณได้ดังสมการที่ (2)

$$SMA_t(N) = \frac{(T_t + T_{t-1} + \dots + T_{t-N+1})}{N} \quad (2)$$

เมื่อ SMA คือ ค่าเฉลี่ยเคลื่อนที่ของเวลาเดินทาง, N คือ จำนวนของช่วงเวลาที่ต้องการหาค่าเฉลี่ย, T<sub>t</sub> คือ เวลาเดินทางเฉลี่ยของถนนที่พิจารณาในช่วงเวลา t (ในการศึกษานี้แบ่งช่วงเวลาเท่ากับ 15 นาที ดังนั้นใน 1 วัน จะมีช่วงเวลาทั้งหมด 96 ช่วง)

การทำนายเวลาเดินทาง ณ ช่วงเวลาต่างๆ ในอนาคต ( $\hat{T}_{T+\tau}$ ) กำหนดให้เท่ากับค่าเฉลี่ยเคลื่อนที่ของเวลาเดินทางที่ประมาณได้ ดังนั้นสมการสำหรับทำนายเวลาเดินทางโดยใช้ค่าเฉลี่ยเคลื่อนที่สามารอธิบายได้ดังสมการที่ (3)

$$\hat{T}_{T+\tau} = SMA_t \quad \text{for } \tau = 1, 2, \dots \quad (3)$$

การตรวจสอบความถูกต้องของโครงข่ายประสาทเทียมที่พัฒนาขึ้นรวมทั้งแบบจำลองพื้นฐานต่างๆ ที่นำมาเปรียบเทียบ ในการทำนายเวลาเดินทางล่วงหน้า ใช้ข้อมูลเวลาเดินทางที่สำรวจได้ระหว่างวันที่ 1-7 มีนาคม 2559 ซึ่งเป็นข้อมูลคนละชุดกับข้อมูลที่ใช้ในการพัฒนาแบบจำลอง โดยทำการทดสอบซ้ำจำนวน 5 ครั้ง ผลการทดสอบแสดงดังตารางที่ 4

ตารางที่ 4 MAPE จากการทำนายเวลาเดินทางล่วงหน้าบนถนนหมายเลข 01-16 ของแบบจำลองที่นำเสนอและวิธีการพื้นฐานต่างๆ

แบบจำลอง	เวลาที่ทำนายล่วงหน้า (นาที)			
	15	30	45	60
Database	55.64	57.47	61.66	60.85

Current TT	37.69	52.89	56.01	59.52
MA(2)	42.95	52.00	55.11	60.12
MA(3)	44.70	51.82	55.99	61.31
MA(4)	46.51	52.22	56.76	60.99
ANN (Target)	32.77	37.16	50.05	60.01
ANN (All)	29.27*	35.58	40.92*	53.37*
ANN (Miss)	33.59	33.20*	49.97	54.03

หมายเหตุ เวลาเดินทางเฉลี่ยของถนน 01-16 เท่ากับ 537.47 วินาที (ประมาณ 9 นาที)

ผลการทำนายเวลาเดินทางล่วงหน้าบนถนนหมายเลข 01-16 โดยทดสอบด้วยข้อมูลระหว่างวันที่ 1-7 มีนาคม 2559 พบว่าโครงข่ายประสาทเทียมที่ใช้ข้อมูลในอดีตของถนนที่ศึกษาร่วมกับโครงข่ายโดยรอบ (ANN All) ให้ผลการทำนายเวลาล่วงหน้าที่ 15, 45 และ 60 นาที แม่นยำที่สุดเมื่อเทียบกับแบบจำลองอื่นๆ โดยมีค่า MAPE เท่ากับร้อยละ 29.27, 40.92 และ 53.37 ตามลำดับ สำหรับการการทำนายเวลาเดินทางล่วงหน้า 30 นาที พบว่าโครงข่ายประสาทเทียมที่ใช้เฉพาะข้อมูลในอดีตจากโครงข่ายถนนโดยรอบเท่านั้นให้ผลการทำนายแม่นยำที่สุด โดยมี MAPE เท่ากับร้อยละ 33.20 นอกจากนี้พบว่าแบบจำลองต่างๆ ที่นำมาทำการเปรียบเทียบซึ่งประกอบด้วยการใช้ฐานข้อมูล การใช้เวลาเดินทางปัจจุบันเป็นตัวแทนเวลาในอนาคต และการใช้ค่าเฉลี่ยเคลื่อนที่ลำดับต่างๆ ให้ผลการทำนายเวลาเดินทางแม่นยำน้อยกว่าการใช้โครงข่ายประสาทเทียมอย่างเห็นได้ชัด

ในกรณีที่ไม่ใช่ข้อมูลเวลาเดินทางในอดีตของถนนที่ทำการศึกษาพบว่าโครงข่ายประสาทเทียมแบบ ANN (Miss) สามารถทำนายเวลาเดินทางของถนนที่ศึกษาได้โดยให้ผลการทำนายที่มีความแม่นยำ ในขณะที่แบบจำลองอื่นรวมทั้งวิธีการพื้นฐานที่นำมาเปรียบเทียบจะไม่สามารถทำนายเวลาเดินทางล่วงหน้าได้เมื่อไม่มีข้อมูลในอดีตของถนนที่ศึกษา บ่งชี้ให้เห็นถึงศักยภาพของการใช้ข้อมูลจากโครงข่ายโดยรอบในการประมาณและทำนายเวลาเดินทาง โดยสามารถนำไปประยุกต์ใช้ในพื้นที่ที่มีปริมาณข้อมูลจราจรไม่มาก พื้นที่ที่เกิดปัญหาข้อมูลขาดหายไปจากสาเหตุต่างๆ และยังช่วยลดงบประมาณในการตรวจวัดเวลาการเดินทางได้โดยการวางแผนติดตั้งอุปกรณ์เฉพาะถนนที่จำเป็นเท่านั้น

## 5. สรุปผลการศึกษา

บทความนี้นำเสนอการใช้โครงข่ายประสาทเทียมในการทำนายเวลาเดินทางบนถนนในเขตเมือง โดยเป็นโครงข่ายประสาทเทียมแบบ multilayer feedforward ที่มี 1 hidden เลเยอร์ พิจารณาใช้ข้อมูลเวลาเดินทางในอดีตจากถนนที่ศึกษาและโครงข่ายถนนโดยรอบตัวแปรในกระบวนการคัดเลือกอินพุตของแบบจำลอง

ในกระบวนการเรียนรู้และพัฒนาแบบจำลองโครงข่ายประสาทเทียม ใช้การเรียงลำดับตัวแปรตามค่าสหสัมพันธ์จากสูงไปต่ำ จากนั้นทำการเพิ่มตัวแปรแต่ละตัวเข้าไปเรื่อยๆ ตามลำดับ เพื่อคัดเลือกโครงสร้างแบบจำลอง

ที่ให้ผลการทำนายที่ดีที่สุด โดยประกอบด้วยจำนวนและข้อมูลอินพุต จำนวน hidden neuron และค่าน้ำหนักต่างๆ ภายในโครงข่ายประสาทเทียม

ผลการทดสอบความแม่นยำในการทำนายเวลาเดินทางจากข้อมูลที่สำรวจได้จริงบนถนนในเขตกรุงเทพมหานคร พบว่าแบบจำลองโครงข่ายประสาทเทียมที่นำเสนอให้ผลการทำนายแม่นยำกว่าวิธีการพื้นฐานที่นิยมใช้ในปัจจุบันอย่างเห็นได้ชัด นอกจากนี้พบว่าในกรณีที่ไม่มีข้อมูลเวลาเดินทางในอดีตของถนนที่ศึกษา โครงข่ายประสาทเทียมแบบ ANN (Miss) ซึ่งเป็นแบบจำลองที่ไม่ต้องการข้อมูลในอดีตของถนนที่ศึกษา สามารถทำนายเวลาเดินทางได้โดยให้ผลการทำนายที่มีความแม่นยำ ในขณะที่แบบจำลองอื่นรวมทั้งวิธีการพื้นฐานที่นำมาเปรียบเทียบไม่สามารถทำนายเวลาเดินทางล่วงหน้าได้ บ่งชี้ให้เห็นถึงศักยภาพของการใช้ข้อมูลจากโครงข่ายโดยรอบในการประมาณและทำนายเวลาเดินทาง โดยสามารถนำไปประยุกต์ใช้กับพื้นที่ที่มีปัญหาการเก็บข้อมูลเวลาเดินทาง และใช้ในการวางแผนการเก็บข้อมูลเวลาเดินทางได้

### เอกสารอ้างอิง

- [1] Park, D. J. and Rilett, L. R. (1999). Forecasting freeway section travel times with a multilayer feed-forward neural network. *Computer Aided Civil and Infrastructure Engineering*, vol.14 (5), pp.357-367.
- [2] Kisgyorgy, L. and Rilett, L. R. (2002). Travel Time Prediction by Advanced Neural Network. *Periodica Polytechnica Civil Engineering*, vol.46(1), pp.15-32.
- [3] Huisken, G. and Van Berkum, E. C. (2003). A Comparative Analysis of Short- Range Travel Time Prediction Methods. *Transportation Research Record*, In Proceedings 82<sup>nd</sup> Annual Meeting, Washington, D.C.
- [4] Shen, L. and Huang, M. (2011). Assessing dynamic neural networks for travel time prediction. *Communications in Computer and Information Science*, vol.224, pp.469-477.
- [5] Van Lint, J. W. C., et al. (2002). Freeway travel time prediction with state-space neural networks-modeling state-space dynamics with recurrent neural networks. *Transportation Research Record*, vol.1811, pp.30-39.
- [6] Van Lint, J. W. C., et al. (2005). Accurate freeway travel time prediction with state-space neural networks under missing data. *Transportation Research Part C: Emerging Technologies*, vol.13 (5-6), pp.347-369.
- [7] Abu-Lebdeh, G. and Singh, A. K. (2011). Modeling arterial travel time with limited traffic variables using conditional independence graphs & state-space neural networks. In Proceedings 6<sup>th</sup> Int. Symposium on Highway Capacity and Quality of Service, Stockholm, Sweden.
- [8] Blum, A. and Langley, P. (1997). Selection of relevant features and examples in machine learning. *Artificial Intelligence*, vol.97 (1-2), pp.245-271.
- [9] Guyon, I. and Elisseeff, A. (2003). An introduction to variable and feature selection. *The Journal of Machine Learning Research*, vol.3, pp.1157-1182.
- [10] May, R., et al. (2011). *Review of input variable selection methods for artificial neural networks*, in Artificial Neural Networks - Methodological Advances and Biomedical Applications.
- [11] Cybenko, G. (1989). Approximation by superimposition of a sigmoidal function. *Mathematical Control Signals Systems*, vol.2, pp.303-314.
- [12] Hornik, K., et al. (1989). Multilayer feed forward networks are universal approximators. *Neural Networks*, vol.2, pp. 359-366
- [13] Faghri, A. and J. Hua. (1992). Evaluation of Artificial Neural Network Applications in Transportation Engineering. *Journal of Transportation Research Board*, vol.1358, pp.71-80.
- [14] Dougherty, M. (1995). A review of neural networks applied to transport. *Transportation Research Part C*, vol.3(4), pp.247-260.
- [15] Vanajakshi, L. D. and Rilett, L. R. (2004). Loop Detector Data Diagnostics Based on Conservation-of-Vehicles Principle. *Transportation Research Record*, vol.1870, pp.162-169.
- [16] Naik, B. (2010). A Generalized Non-parametric Approach for Uncertainty Evaluation in Travel Time Prediction Models. University of Nebraska – Lincoln. Ph.D study.
- [17] Puangprakhon, P. and Narupiti, S. (2019), "Travel Time Information on Urban Roadways for Advanced Travelers Information System Using Data from Bluetooth MAC Scanners", *Journal of the Eastern Asia Society of Transportation Studies*, Vol.13, pp. 1835-1852.