

Siamtraffic2.0: Traffic pattern search for travel time prediction in Bangkok road network

เกรียงศักดิ์ วนิชชากรพงศ์¹, ณกร อินทร์พุง¹ และ เอกชัย สุมาลี²

¹คณะโลจิสติกส์ มหาวิทยาลัยบูรพา ชลบุรี 20131

²Department of Civil and Structural Engineering, The Hong Kong Polytechnic University, Hong Kong

Emails: kriangsv,nakorn@buu.ac.th, ceasumal@polyu.edu.hk

ABSTRACT – This paper presents the travel time prediction system to support the trip planning in Bangkok road network. The system relies on pattern matching taking spatial and temporal traffic speed correlations into account. The road network is divided into traffic link classified independently by type of day for every 5-min time interval. Traffic pattern is then defined by the speed interval. The objective function of the problem is to find the closest match of the traffic pattern in the historical database, in order to estimate the travel time for a specific traffic link. We evaluate the accuracy of forecast by comparing the predicted travel time with the observed data. Four types of the observed links indicate different behaviors of traffic patterns that affect to the applicability of the prediction system. The results have shown that the free-flow traffic link is greater than 85 percent correctly predicted, and the link types of the interrupted traffic flow indicate 60 – 80 percent in the accuracy of forecast. The efficiency of the algorithm in a computational run-time is less than one second per link in 5-min time interval.


KEYWORDS -- Travel time prediction; Traffic pattern search; Non-parametric forecasting

บทคัดย่อ -- บทความนี้เสนอระบบพยากรณ์ระยะเวลาในการเดินทาง เพื่อช่วยวางแผนการเดินทางภายในโครงข่ายถนนในกรุงเทพฯ โดยอาศัยการค้นหารูปแบบสภาพจราจรที่มีค่าความสัมพันธ์ของสภาพจราจรที่เกิดขึ้นตามช่วงเวลา ทั้งช่วงเวลาที่เกิดขึ้นต่อเนื่องกันและช่วงเวลาใดๆที่เกิดในอดีต รวมทั้งความสัมพันธ์เชิงพื้นที่ที่เกิดขึ้นจากลักษณะทางกายภาพของถนน เส้นทางจะถูกแบ่งเป็นส่วนย่อยๆ ที่เรียกว่า Link ซึ่งเก็บโครงสร้างการเชื่อมต่อของถนนและเก็บข้อมูลจราจรที่เป็นอิสระจากกันในแต่ละ Link โดยแยกตามประเภทของวัน ในทุกช่วงเวลา 5 นาที และแบ่งค่าความเร็วกระแสจราจรออกเป็นช่วง (Speed interval) เพื่อสร้างรูปแบบสภาพจราจร เรากำหนดฟังก์ชันวัตถุประสงค์ของปัญหาเพื่อค้นหารูปแบบสภาพจราจรในอดีตที่มีลักษณะใกล้เคียงกับรูปแบบสภาพจราจรที่เกิดขึ้นในปัจจุบันมากที่สุด เพื่อนำมาพยากรณ์ระยะเวลาเดินทางในเส้นทาง เราประเมินความถูกต้องของการพยากรณ์ โดยเปรียบเทียบกับข้อมูลที่ได้จากการสำรวจจำนวน 4 เส้นทาง ที่มีรูปแบบและพฤติกรรมของการจราจรที่แตกต่างกัน รวมทั้งทดสอบความสามารถในการพยากรณ์ในแต่ละช่วงเวลาล่วงหน้า ในแต่ละช่วงเวลาของวัน ผลการทดสอบ ชี้ให้เห็นว่า เส้นทางที่มีสภาพจราจรในลักษณะ Free flow มีค่าความถูกต้องในการพยากรณ์โดยเฉลี่ยมากกว่าร้อยละ 85 และเส้นทางในเขตชุมชนเมือง Interrupted flow มีค่าความถูกต้องในการพยากรณ์อยู่ในระดับที่ไม่สูงมากนัก ในช่วงร้อยละ 60 – 80 ประสิทธิภาพของอัลกอริทึมในด้านความเร็วเฉลี่ยในการค้นหาคำตอบใช้เวลาไม่น้อยกว่า 1 วินาทีต่อเส้นทาง ต่อช่วงเวลา

คำสำคัญ -- Travel time prediction; Traffic pattern search; Non-parametric forecasting

1. บทนำ

เนื่องจากความต้องการของระบบขนส่งและจราจรอัจฉริยะเพื่อใช้แนะนำเส้นทางและวางแผนก่อนการเดินทาง จำเป็นจะต้องพยากรณ์ระยะเวลาที่จะใช้ในการเดินทาง โดยระยะเวลาเดินทางระหว่างจุดใดๆ สามารถคำนวณจากผลรวมของระยะเวลาในการเดินทางของ Link ภายในโครงข่ายถนนเรียกว่า Path travel time โดยระยะเวลาในการเดินทางแปรผันตามช่วงเวลา (Time dependent) ดังแสดงในรูปที่ 1



รูปที่ 1 Path travel time

การพยากรณ์ระยะเวลาในการเดินทางสามารถกระทำได้หลายวิธี ขึ้นอยู่กับความต้องการของช่วงเวลการพยากรณ์ ข้อมูลที่นำมาใช้ในการพยากรณ์ ลักษณะโครงข่ายของถนน รวมถึงพฤติกรรมของผู้ขับขี่ยานพาหนะภายในพื้นที่นั้นๆ เป็นหลัก โดยทั่วไป แบบจำลองการพยากรณ์สภาพจราจรสามารถแบ่งออกเป็น 2 ประเภท ได้แก่ 1) Parametric และ 2) Non-parametric [7]

Parametric model เป็นแบบจำลองที่อาศัยค่าพารามิเตอร์และข้อมูลทางสถิติมาใช้ในการพยากรณ์ อาทิเช่น ตัวแบบอนุกรมเวลา และการวิเคราะห์แบบถดถอยเชิงพหุ เพื่อหาความสัมพันธ์ระหว่างตัวแปรอิสระต่างๆ ที่มีผลต่อสภาพการจราจรที่เปลี่ยนแปลง พยากรณ์ระยะเวลาในการเดินทางระยะสั้น ภายในโครงข่ายถนนในเมืองโดยวิธี Improved adaptive exponential smoothing (IAES) ซึ่งเป็นการพยากรณ์ในเงื่อนไขที่สภาพการจราจรไม่ปกติ และเปรียบเทียบกับวิธี IAES กับวิธีการพยากรณ์อื่นๆ ได้แก่ Auto regression integrated moving average (ARIMA), Artificial neural network (ANN) และ Non-parametric regression (NPR) ผลการทดลองพบว่า IAES ให้ผลการพยากรณ์ที่มีค่าความถูกต้องมากที่สุด [2] ใช้วิธี Modified moving average พยากรณ์ระยะเวลาในการเดินทางแบ่งออกเป็น Successive MA (SMA) และ Chain average (CA)

วิธีที่นำเสนอเป็นการแก้ปัญหาการพยากรณ์ของวิธี Moving average แบบปกติ เนื่องจากจุดเริ่มต้นของข้อมูลเพื่อใช้ในการพยากรณ์อาจจะไม่ได้ถูกนำมาเฉลี่ยรวมอยู่ด้วย งานวิจัยได้เปรียบเทียบกับวิธี Naïve Bayesian classification (NBC) และ Linear switching method (SM) โดยใช้ข้อมูล GPS probe car ของเมือง Pusan ในตัวอย่างเส้นทางที่มีระยะทาง 7 กม. ผลการศึกษาพบว่า วิธี SMA และ CA ให้ค่าความถูกต้องในการพยากรณ์สูงกว่าวิธีอื่นๆ [5] ประยุกต์ใช้ Traffic flow simulator พยากรณ์ระยะเวลาในการเดินทางระยะสั้น โดยอาศัยข้อมูลระยะเวลาในการเดินทางจริงที่ได้จาก AVI data และข้อมูลในอดีต (Offline data) เพื่อหาความสัมพันธ์ของระยะเวลาในการเดินทางเชิงเวลาและพื้นที่

เนื่องจากการหาความสัมพันธ์ของตัวแปรต่อสภาพจราจรที่เปลี่ยนแปลง มีความซับซ้อนและอาจไม่สามารถอธิบายพฤติกรรมในรูปแบบความสัมพันธ์เชิงสถิติได้ แบบจำลองการพยากรณ์ประเภท Non-parametric ซึ่งเก็บพฤติกรรมการเปลี่ยนแปลงของสภาพจราจรไว้ในลักษณะ Hidden layer จึงได้ถูกนำมาประยุกต์ใช้ และได้รับความนิยมโดยเฉพาะการพยากรณ์สภาพจราจรในโครงข่ายถนนในเมืองที่มีขนาดใหญ่ และซับซ้อน อาทิเช่น วิธี k -nearest neighbor (k -NN) ระบบผู้เชี่ยวชาญ ระบบโครงข่ายประสาทเทียม และระบบปัญญาประดิษฐ์อื่นๆ เป็นต้น [4] พัฒนาอัลกอริทึม Traffic pattern recognition เพื่อพยากรณ์สภาพการจราจรระยะสั้น โดยใช้ข้อมูล Traffic volume ของถนน Highway ที่เชื่อมต่อเมือง Washington DC วิธีที่นำเสนออาศัยข้อมูลสภาพจราจร ณ เวลาปัจจุบัน และข้อมูลสภาพจราจรในอดีต มาสร้าง Traffic pattern เพื่อใช้พยากรณ์สภาพจราจรในอนาคต ซึ่งผลการพยากรณ์ของวิธีที่นำเสนอให้ค่าความถูกต้องมากกว่าวิธี k -NN ที่ใช้สภาพจราจร ณ เวลาปัจจุบันเพียงอย่างเดียว นอกจากนี้ ผลการทดลองยังพบว่า Traffic pattern size มีผลต่อค่าความถูกต้องของการพยากรณ์ [6] ประมาณความเร็วกระแสจราจรโดยใช้วิธี Fuzzy c-mean สำหรับ Traffic pattern classification จากข้อมูล GPS taxi probe โดยจำแนกความเร็วจราจรออกเป็น 3 กลุ่ม ได้แก่ Low, Middle และ High speed และนำข้อมูลดังกล่าวมาพยากรณ์สภาพจราจรของแต่ละเส้นทาง [10] นำเสนอระบบการตรวจสอบเหตุการณ์ที่เกิดขึ้นในโครงข่ายถนนโดยอัตโนมัติ โดยพยากรณ์ระยะเวลาเดินทางระยะสั้น ระบบดังกล่าวอาศัยข้อมูล AVI ทั้งข้อมูลที่ผ่านมาในอดีตและข้อมูลที่

เกิดขึ้นในปัจจุบันมาพยากรณ์สภาพการติดขัดของถนน อัลกอริทึมที่ประยุกต์ใช้มีความคล้ายคลึงกันกับ k -NN แตกต่างกันคือมีการพิจารณาความแปรปรวนร่วมของข้อมูลที่เกิดขึ้นในช่วงเวลาที่แตกต่างกัน การประยุกต์ใช้ค่าความแปรปรวนร่วมที่เกิดขึ้นในเส้นทางและตามช่วงเวลา ทำให้ อัลกอริทึมสามารถพยากรณ์สภาพจราจรได้อย่างรวดเร็ว ผลการประเมินประสิทธิภาพของการพยากรณ์จำนวน 1 เส้นทาง ที่ระยะทาง 6.23 km มีระดับค่าความถูกต้องไม่น้อยกว่า 95%

การพยากรณ์ระยะเวลาเดินทางในเมืองหลวงที่อาศัยระบบผู้เชี่ยวชาญนำเสนอโดย [6] โดยนำข้อมูลระยะเวลาเดินทางในอดีตมาสร้าง Traffic predictor และใช้เทคนิค Data mining เพื่อสร้างกฎพยากรณ์ในแต่ละเหตุการณ์ และปรับเปลี่ยนค่าน้ำหนักของตัวแปรในการพยากรณ์โดยอัตโนมัติเพื่อเพิ่มความสามารถในการพยากรณ์ให้มีประสิทธิภาพมากยิ่งขึ้น งานวิจัยได้ถูกนำไปใช้พยากรณ์สภาพจราจรภายในเมือง ประเทศไต้หวัน โดยใช้ข้อมูลจาก GPS taxi จำนวน 500 คัน ผลการพยากรณ์ให้ค่าความถูกต้องอยู่ในช่วง 80 – 90%

การพยากรณ์โดยใช้การประมาณค่าทางสถิติและแบบความจำลองความน่าจะเป็นเพื่อจำลองพฤติกรรม การเปลี่ยนแปลงของระยะเวลาเดินทางในแต่ละช่วงที่พิจารณา ยกตัวอย่างเช่น [8] พัฒนาวิธี Least squares support vector machines (LS-SVMs) เพื่อพยากรณ์สภาพจราจรในเมือง โดยเฉพาะในช่วง Non-peak traffic ซึ่งเป็นข้อมูลที่สำคัญในการวางแผนในกรณีที่มีเหตุการณ์ที่ผิดปกติเกิดขึ้น โดยอาศัย State space transition และ Linear least square แบบจำลองพยากรณ์ดังกล่าวมีความสามารถในการรู้เข้าสู่ค่าตอบที่ดีภายในเวลาอันรวดเร็ว ผลการพยากรณ์ได้นำไปเปรียบเทียบกับวิธีอื่นๆ ได้แก่ Mean average, ARMA, Radial basis function neural network (RBF-NN) และ Support vector regress (SVR) โดยใช้ข้อมูลการทดสอบจาก PeMS สามารถเข้าถึงได้จาก <http://pems.eecs.berkeley.edu> ซึ่งเป็นข้อมูลจราจรในโครงข่ายถนน Freeway ของประเทศสหรัฐ ผลการทดลองพบว่า วิธี LS-SVMs มีค่าความถูกต้องในการพยากรณ์สูงกว่าวิธีอื่นๆ [3] พยากรณ์ระยะเวลาในการเดินทางโดยใช้โครงสร้างข้อมูลในรูปแบบโครงข่ายประสาทเทียม และใช้วิธี Bayesian เพื่อกำหนดช่วงความไม่แน่นอนของค่าการพยากรณ์ [9] ใช้

แบบจำลอง Regression ที่ไม่กำหนดรูปแบบการกระจายตัวของข้อมูล (Distribution-free) พยากรณ์ระยะเวลาในการเดินทาง สำหรับการวางแผนขนส่งและโลจิสติกส์ ซึ่งใช้ระยะเวลาในการเดินทางอยู่ในช่วง 1-4 ชั่วโมง จากผลการทดสอบสามารถลดความผิดพลาดของระยะเวลาที่ใช้ในการเดินทางประมาณ 5%

ในงานวิจัยนี้เสนอระบบพยากรณ์ระยะเวลาเดินทางภายในโครงข่ายถนนกรุงเทพฯ โดยวิเคราะห์ Traffic pattern ที่มีลักษณะความสัมพันธ์เชิงพื้นที่และช่วงเวลา โดยกำหนดวัตถุประสงค์ของปัญหาเพื่อค้นหารูปแบบสภาพจราจรในอดีตที่มีลักษณะใกล้เคียงกับรูปแบบสภาพจราจรที่เกิดขึ้นในปัจจุบันมากที่สุด เพื่อใช้เป็นตัวแทนระยะเวลาเดินทางล่วงหน้าในเส้นทาง


2. Travel time prediction

2.1. Traffic pattern definition

ระบบพยากรณ์ระยะเวลาเดินทางอาศัยข้อมูลการจราจรที่เกิดขึ้นในอดีตมาพยากรณ์ระยะเวลาในการเดินทางในอนาคต เนื่องจากแหล่งข้อมูลจราจรที่ได้มาจากยานพาหนะที่ติดตั้งอุปกรณ์ GPS และ RFID เป็นหลัก ทำให้ต้องออกแบบโครงสร้างระบบฐานข้อมูลให้สามารถนำข้อมูลทั้งสองแหล่งนี้มาใช้งานร่วมกันได้อย่างมีประสิทธิภาพ

เราแบ่งเส้นทางออกเป็นส่วนๆ ด้วย Traffic node ซึ่งแต่ละส่วนนั้นจะเรียกว่า Link แต่ละ Link จะเก็บโครงสร้างการเชื่อมต่อของถนนทางกายภาพ โดยแยกตามประเภทของวัน ในทุกช่วงเวลา 5 นาที ดังนั้นการพยากรณ์ระยะเวลาเดินทางจะอ้างอิงจาก Link และช่วงเวลาที่ถูกกล่าวไว้ข้างต้น


นอกจากนี้ เราเก็บข้อมูลความเร็วกระแสจราจรของแต่ละ Link ในรูปแบบขั้นบันได โดยจะแบ่ง (Mod) ค่าความเร็วกระแสจราจรออกเป็นช่วงของความเร็ว (Speed interval) กำหนดให้ $v'_{a,b} = \lfloor v_{a,b} / s \rfloor$ โดย $v'_{a,b}$ คือ ลำดับขั้นความเร็วของ Link ที่เดินทางจาก a ไป b , $v_{a,b}$ คือ ความเร็วของ Link ที่เดินทางจาก a ไป b และ s คือ ความกว้างของลำดับขั้นความเร็ว ยกตัวอย่างเช่น Link ab , $v_{a,b}$ มีค่า 18 Kph และกำหนดให้ s เท่ากับ 5 Kph จะได้ $v'_{a,b}$ มีค่าเท่ากับ 3 เป็นต้น ค่า $v'_{a,b}$ ดังกล่าวนี้จะถูกเก็บไว้ในฐานข้อมูลสำหรับเปรียบเทียบ Traffic pattern โดยการเก็บข้อมูลมีลักษณะดังแสดงในรูปที่ 2



รูปที่ 2 Spatial link correlation

รูปที่ 2 แสดงลักษณะการเชื่อมต่อกันของ Link และการเก็บข้อมูลความเร็วแบบขั้นบันได โดยตัวอย่างเช่น รูปที่ 2 (a) แสดง Intersection ประกอบด้วย Link ab, bc, bd และ be โดยมีลำดับขั้นความเร็วคือ 1, 5, 2 และ 3 และ Link speed มีความสัมพันธ์กันเชิงพื้นที่ โดยความสัมพันธ์กันเชิงพื้นที่นั้นจะแบ่งความสัมพันธ์ออกเป็นลำดับขั้น (Level) ที่เชื่อมต่อมายัง Link ที่พิจารณาอยู่ ดังแสดงใน รูปที่ 2 (c) นั่นคือ Link bc, bd, be มี Level, $i = 1$ และ Link cg, cf, df, dh, ej, ek มี Level, $i = 2$


นอกจากความสัมพันธ์กันเชิงพื้นที่แล้ว Link speed ยังมีความสัมพันธ์กันเชิงเวลา ดังแสดงในรูปที่ 3 โดยข้อมูล Link speed ที่ย้อนหลังไปในแต่ละช่วงเวลา $t - j$ รวมทั้งข้อมูล Link speed ที่ย้อนหลังไปในแต่ละวัน $k - i$



รูปที่ 3 Temporal link correlation

2.2. Traffic pattern matching

เราเสนอระบบพยากรณ์ระยะเวลาเดินทาง โดยอาศัยการค้นหารูปแบบสภาพจราจรในอดีตที่มีลักษณะใกล้เคียงกับรูปแบบสภาพจราจรที่เกิดขึ้นในปัจจุบันมากที่สุด ภายในโครงข่ายถนนที่มีข้อมูลจราจรที่มีความสัมพันธ์กันเชิงพื้นที่และตามช่วงเวลา ดังแสดงในรูปที่ 4



รูปที่ 4 Spatial and temporal link correlations

เนื่องจากจำนวน Link ที่เชื่อมโยงในโครงข่ายถนนกรุงเทพมหานครนั้นมีจำนวนมาก อัลกอริทึมที่ออกแบบจึงต้องมีความสามารถในการประมวลผลที่รวดเร็ว เรากำหนดวัตถุประสงค์ของปัญหาการค้นหารูปแบบสภาพจราจร โดยกำหนดค่าความคลาดเคลื่อน Mismatch, m ของรูปแบบสภาพการจราจรปัจจุบัน เปรียบเทียบกับรูปแบบสภาพการจราจรที่เกิดขึ้นในอดีต ซึ่งจะได้รูปแบบสภาพการจราจรในอดีตที่มีความใกล้เคียงกับสภาพการจราจรในปัจจุบันมากที่สุด ค่า Mismatch, m สามารถคำนวณได้จากสมการที่ 1

$$m_{b,c}^{k'} = \sum_{p \in P} \sum_{i \in I} \sum_{l \in L_i^{b,c}} |v_{l,t-p}^{k'} - v_{l,t-p}^n| \quad \forall k' \in K' \quad (1)$$

กำหนดให้ $m_{b,c}^{k'}$ คือ ค่า Mismatch ของ Link ที่เดินทางจาก b ไป c ในช่วงเวลาเดียวกันของวันที่ k' , n คือ วันปัจจุบัน, K' คือ เซตของวันที่ย้อนกลับไปในอดีต, P คือ เซตของช่วงเวลาที่ย้อนหลังที่มีความสัมพันธ์กันเชิงเวลา, I คือ เซตของ Level ความสัมพันธ์เชิงพื้นที่, $L_i^{b,c}$ คือ เซตของ Link ทั้งหมดใน Level i ที่เชื่อมต่อออกจาก Link b, c และ $v_{l,t-p}^{k'}$ คือ ความเร็วแบบขั้นบันไดของ Link l ในช่วงเวลาที่ $t - p$ ของวันที่ k' ซึ่งในงานวิจัยนี้เราทำการทดลองโดยกำหนด K' สองแบบคือ 1) $K' = \{n-7, n-14, n-21, \dots, n-K\}$ คือ เซตของวันที่มีประเภทวันเดียวกันย้อนหลัง และ 2) $K' = \{n-1, n-2, n-3, \dots, n-K\}$ คือ เซตของวันย้อนหลังโดยไม่แยกตามประเภทวัน

เราสามารถเขียนวัตถุประสงค์และเงื่อนไขของปัญหาในรูปแบบจำลองทางคณิตศาสตร์ได้ดังนี้


$$\min \sum_{k' \in K'} x_l^{k'} m_l^{k'} \quad \forall l \in L \quad (2)$$

$$\sum_{k' \in K'} x_i^{k'} = 1 \quad (3)$$

กำหนดให้ L คือ เซตของ Link ทั้งหมด, $x_i^{k'} = 1$ เมื่อเลือก $v_i^{k'}$ ในการพยากรณ์ และ $x_i^{k'} = 0$ ในกรณีอื่นๆ, $m_i^{k'}$ คือ ค่า Mismatch ของ Link i ในวันที่ k'

สมการ (2) แสดงผลรวม Mismatch ที่มีค่าน้อยที่สุด และเงื่อนไข (3) กำหนดให้ อัลกอริทึมเลือก $v_i^{k'}$ เพียงค่าเดียวภายในวันที่ย้อนกลับไปที่ค้นหาทั้งหมด

สังเกตได้ว่า รูปแบบจำลองที่นำเสนอมีความยืดหยุ่นในจำนวน หรือการเพิ่มเงื่อนไขในการตัดสินใจของปัญหาได้ โดยง่าย ยกตัวอย่างเช่น การกำหนดเงื่อนไขของค่าตอบ Speed interval ให้มีค่าอยู่ระหว่างช่วงที่กำหนด $v_i^{k'} \in [1, 3]$ เป็นต้น รูปที่ 5 แสดงขั้นตอนการค้นหารูปแบบสภาพจราจร




รูปที่ 5 Traffic pattern search

จากรูปที่ 5 อัลกอริทึมค้นหารูปแบบสภาพจราจรโดยเริ่มจาก k' ที่มีค่าน้อยไปหามาก หรือกล่าวอีกนัยหนึ่ง ค้นหาจากข้อมูลใหม่กว่าไปยังข้อมูลเก่ากว่า ในกรณีคำนวณค่าความคลาดเคลื่อนได้ค่าเป็นศูนย์ อัลกอริทึมจะหยุดการค้นหาและจะได้ผลลัพธ์ $v_i^{k'}$ นั่นคือ สภาพจราจรที่เคยมีรูปแบบการเกิดขึ้นเหมือนกับในอดีตที่ผ่านมา

ในกรณีที่ค่าความคลาดเคลื่อนมีค่ามากกว่าศูนย์ อัลกอริทึมจะเก็บค่าความคลาดเคลื่อนไว้ในเซต M_i และค้นหาต่อจนครบรอบกระทำซ้ำ K' ที่กำหนด จากนั้นเปรียบเทียบเพื่อหาค่าความคลาดเคลื่อนที่น้อยที่สุด และในกรณีที่มิใช่รูปแบบการจราจรที่มีค่าความคลาดเคลื่อนที่น้อยที่สุดหลายรูปแบบคือ M_0 จะทำการสุ่มรูปแบบใดรูปแบบหนึ่งในจำนวนนั้นขึ้นมาจะได้ rnd เพื่อได้ค่าความเร็ว v_i^{rnd} ของรูปแบบที่สุ่มได้

2.3. Architecture of travel time prediction

เนื่องจากระบบการพยากรณ์ระยะเวลาเดินทางในกรุงเทพมหานครครอบคลุมโครงข่ายถนนขนาดใหญ่ มากกว่า 3,000 เส้นทาง ดังนั้น ประสิทธิภาพของระบบพยากรณ์จึงไม่ได้ขึ้นอยู่กับความเร็วของอัลกอริทึมในการประมวลผลเพียงอย่างเดียว แต่ยังขึ้นอยู่กับประสิทธิภาพในการจัดการระบบเชื่อมต่อฐานข้อมูลด้วย รูปที่ 6 แสดงสถาปัตยกรรมของระบบ



รูปที่ 6 Architecture of travel time prediction system

จากรูปที่ 6 แสดงสถาปัตยกรรมของระบบพยากรณ์ระยะเวลาเดินทาง โดยระบบเริ่มจากเก็บข้อมูลจราจร (Raw traffic data) จากอุปกรณ์ต่างๆ อาทิเช่น GPS, AVI (RFID) และ Sensors โดยข้อมูลจากแต่ละแหล่งจะผ่านวิธีการคัดกรองข้อมูลที่แตกต่างกัน จากนั้นข้อมูลที่ผ่านขั้นตอนการคัดกรองจากแหล่งต่างๆ จะถูกนำมารวมกัน (Fusion process) และได้ผลลัพธ์เป็นข้อมูลความเร็วกระแสจราจร (Traffic info) ในแต่ละเส้นทาง ในการพยากรณ์ระยะเวลาเดินทางนั้น ระบบจะนำ

ข้อมูลสภาพการจราจร ณ เวลาปัจจุบันมาสร้างโครงสร้างการเชื่อมต่อของถนนเพื่อหา Traffic pattern ที่เหมือนหรือใกล้เคียงกับฐานข้อมูลในอดีตเพื่อพยากรณ์ระยะเวลาเดินทางของเส้นทาง

3. Empirical study


ในการทดสอบและประเมินค่าความถูกต้องในการพยากรณ์ เราคัดเลือกช่วงถนน (Link) โดยแบ่งออกเป็น 4 กลุ่ม เพื่อประเมินประสิทธิภาพของอัลกอริทึมในการพยากรณ์ภายใต้สถานการณ์ที่แตกต่างกัน Link A: เป็นถนนที่มีสภาพการจราจรลักษณะ Free flow ในช่วงเส้นทางด่วนพิเศษแบบอิสระไม่มีจุดเปลี่ยนทิศทางการจราจร (Weaving) และทางเชื่อมขึ้นลง Link B: เป็นช่วงถนนที่มีสภาพการจราจรลักษณะ Free flow และมี Local road ด้านข้างเชื่อมต่อเข้าเขตชุมชน Link C: เป็นถนนสายหลักที่เชื่อมโยงระหว่างพื้นที่สำคัญๆ และมีสัญญาณไฟจราจรเพื่อควบคุมและเปลี่ยนทิศทางการไหลของการจราจร และ Link D: เป็นถนนในย่านธุรกิจ หรือชุมชน มีจุดกลับรถ และสัญญาณไฟเป็นช่วงๆ ดังแสดงในตารางที่ 1 เส้นทางที่ศึกษา

ตารางที่ 1. แสดง Observed links

Link	From /To	Direction	Connected Links	Distance (Km)
A	Bang Khun Thian - Bang Khru	Inbound	2	5.7
B	Bangkok Univ. - Tollway Rangsit	Inbound	4	2.9
C	MRT Ratchada - The Emerald	Inbound	6	2.6
D	Pratumnam - Ratchatawee	Outbound	7	1.1


สังเกตได้ว่า Links ภายในโครงข่ายถนนในกรุงเทพฯ มีความสัมพันธ์เชิงพื้นที่ที่ซับซ้อน ซึ่งจุดเริ่มต้นและจุดปลายทางของ Link อาจจะเชื่อมต่อกับทางยกระดับ ทางขึ้นลงทางด่วน ทางเชื่อมถนนชุมชน ยกตัวอย่างเช่น Link D: Pratunam - Ratchatawee ในทิศทางออกเมือง ระยะทาง 1.1 Km มี Link ที่เชื่อมต่อจำนวน 7 Links ดังแสดงในรูปที่ 7

จากรูปที่ 7 แสดงความสัมพันธ์ของ Link D หรือ ab ในเชิงพื้นที่ นั่นคือ Link ที่มีการไหลของกระแสจราจรในทิศทางที่เชื่อมโยงกัน โดยลักษณะ Link ที่เชื่อมโยงอาจมีหลายประเภท อาทิเช่น ef เป็นทางยกระดับข้ามทางแยก เป็นต้น จำนวน 7 Links ที่เชื่อมกับ ab จะถูกกำหนดเป็น Traffic pattern โดยมีระดับชั้นความสัมพันธ์ (Level) $i = 1$



รูปที่ 7 Spatial link correlation in Link D

เพื่อแสดงให้เห็นความแปรผันของรูปแบบสภาพจราจร เราคำนวณหาค่าความคลาดเคลื่อน Mismatch, m (จากสมการ (1)) ณ เวลาปัจจุบันของ Link D ที่ช่วงเวลา 9:20 เปรียบเทียบกับรูปแบบสภาพการจราจรที่เกิดขึ้นในอดีตย้อนหลัง 52 สัปดาห์



รูปที่ 8 Traffic pattern variation at time interval 9:20

จากรูปที่ 8 จะเห็นได้ว่า ค่า m ในช่วงเวลา 9:20 ย้อนหลัง 52 สัปดาห์มีความแปรผันอยู่ในช่วง 30 – 50 ซึ่งมีค่าใกล้เคียงกับค่า m ณ เวลาปัจจุบัน ซึ่งมีค่าประมาณ 30 การทำงานของอัลกอริทึมจะค้นหาค่า m ในอดีตที่ใกล้เคียงกับค่า m เวลาปัจจุบันมากที่สุด เพื่อนำไปใช้ประมาณค่าความเร็วจราจรและพยากรณ์ระยะเวลาในการเดินทางล่วงหน้าในช่วงเวลานั้น

ตารางที่ 2 ทดสอบความอ่อนไหวค่าของพารามิเตอร์ที่ใช้ในการพยากรณ์โดยวิธีการค้นหารูปแบบจราจรของ Link D, Set คือ ชุดสถานการณ์และค่าพารามิเตอร์ที่ต้องการทดสอบ ค่าร้อยละความคลาดเคลื่อน (MAPE) คำนวณจากระยะเวลาเดินทางที่ได้จากการพยากรณ์เปรียบเทียบกับระยะเวลาในการเดินทางที่ได้จากการสังเกต (Observed data) ของวันจันทร์ ที่เวลา 9:00 น. เป็นจำนวน 10 ชุดข้อมูล และเวลาที่อัลกอริทึมใช้ในการค้นหาคำตอบ (CPU) มีหน่วยเป็น วินาที โดยอัลกอริทึมเขียนด้วยภาษา Java และใช้เครื่องคอมพิวเตอร์ Quad core ใน

การทดสอบ ความถี่ในการประมวลผล 3.2 GHz ทำงานอยู่ภายใต้ระบบปฏิบัติการ Linux

ตารางที่ 2 แสดง Parameters testing in traffic pattern search for Link D

Set	t			k			Level		MAPE	CPU
	1	3	5	12	24	48	1	2		
1	●			●			●		21.71	20.3
2		●		●			●		20.06	22.4
3			●	●			●		22.18	25.7
4		●			●		●		19.26	31.4
5		●				●	●		17.13	41.3
6		●				●		●	17.40	56.4

จากตารางที่ 2 จะเห็นได้ว่า ค่าความคลาดเคลื่อนในการพยากรณ์มีแนวโน้มลดลง เมื่อค่า t และ k มีค่าเพิ่มขึ้น หรือกล่าวอีกนัยหนึ่ง เมื่อพื้นที่ในการค้นหาคำตอบ (Search space) มีขนาดใหญ่ขึ้น อย่างไรก็ตาม ระดับขั้นความสัมพันธ์ที่เพิ่มมากขึ้น (Level = 2) ไม่ได้ส่งผลให้ค่าความคลาดเคลื่อนเปลี่ยนแปลงมากนัก แต่อัลกอริทึมใช้เวลาในการค้นหาคำตอบเพิ่มขึ้นค่อนข้างมาก ทั้งนี้อาจเป็นผลจากความสัมพันธ์ในเชิงพื้นที่ที่เพิ่มมากขึ้นส่งผลให้เกิดค่าความไม่แน่นอนของระยะเวลาในการเดินทางของแต่ละ Link ในโครงข่ายเพิ่มมากขึ้นด้วย

ตารางที่ 3 แสดงค่า MAPE จากการเปรียบเทียบผลการพยากรณ์กับระยะเวลาเดินทางที่ได้จากการสังเกต ของวันจันทร์ที่เวลา 9:00 น. เป็นจำนวน 10 ชุดข้อมูล ในแต่ละช่วง


Forecasting time horizon โดยกำหนดค่าพารามิเตอร์ $t = 3$, $k = 48$ และ Level = 1 นอกจากนี้ ยังเปรียบเทียบประสิทธิภาพของวิธีพยากรณ์ที่ขึ้นอยู่กับความสัมพันธ์ระหว่างระยะเวลาเดินทางและช่วงเวลาที่ต่อเนื่องกันเพียงอย่างเดียว (3-moving average) และการค้นหารูปแบบจราจรที่อาศัยความสัมพันธ์เชิงเวลาและเชิงพื้นที่ร่วมกัน

จากตารางที่ 3 แสดงให้เห็นว่า ค่า MAPE มีแนวโน้มเพิ่มขึ้น เมื่อช่วงเวลาในการพยากรณ์มีค่ามากขึ้น อย่างไรก็ตาม วิธี TPS มีความอ่อนไหวต่อช่วงเวลาในการพยากรณ์น้อยกว่าวิธี MA ที่อาศัยเพียงความสัมพันธ์ของช่วงเวลาที่ต่อเนื่องกันเพียงอย่างเดียว เนื่องจาก วิธี TPS ใช้การหารูปแบบที่ใกล้เคียงรูปแบบจราจรตามช่วงเวลาที่เกิดขึ้นต่อเนื่องกัน (Consecutive time series) และรูปแบบจราจรที่เคยเกิดในอดีตโดยอิสระร่วมกัน


เพื่อให้เห็นถึงการกระจายตัวของระยะเวลาเดินทาง และค่าพยากรณ์ในแต่ละช่วงเวลาของวัน รูปที่ 9 แสดงผลการพยากรณ์ของ 4 เส้นทาง ในแต่ละช่วงเวลา 5 นาทีล่วงหน้า ของวันจันทร์ที่ 26 ธ.ค. 2554 ตั้งแต่เวลา 6:00 – 24:00 น. และรูปที่ 10 แสดงค่าสัมประสิทธิ์การพยากรณ์ R^2 ในแต่ละช่วงเวลาของวัน AM Peak (9:00 น.) Inter-Peak (14:00 น.) และ PM Peak (18:00 น.) โดยใช้ข้อมูลระยะเวลาเดินทางในอดีต ณ แต่ละช่วงเวลาที่กำหนด 30 ชุดย้อนหลัง กำหนดค่าพารามิเตอร์ของอัลกอริทึมเพื่อใช้ในการค้นหา Traffic pattern, $t = 3$, $k = 48$ และ Level = 1

ตารางที่ 3. แสดง Accuracy of forecast in different forecasting time horizon


Link	Moving average (MA)					Traffic Pattern Search (TPS)				
	1	2	3	4	5	1	2	3	4	5
A	12.85	14.55	16.03	21.20	22.45	13.21	12.10	13.85	14.61	14.20
B	12.90	12.17	15.46	19.25	21.10	14.50	15.22	13.92	14.68	15.32
C	15.41	20.94	23.88	25.42	29.57	16.18	16.39	16.45	17.46	15.84
D	22.45	26.40	32.10	30.56	34.20	18.20	19.23	18.69	21.40	20.22




(a)



(b)




(c)



(d)

รูปที่ 9 Predicted travel times during times of the day



รูปที่ 10 Performance of the travel time prediction

จากรูปที่ 9 และ 10 แสดงผลการพยากรณ์ระยะเวลาเดินทางในแต่ละช่วงเวลาล่วงหน้า 5-min forecasting time horizon, Link A และ B มีสภาพการจราจรในลักษณะ free flow ทำให้สามารถพยากรณ์ได้ถูกต้องโดยเฉลี่ยมากกว่าร้อยละ 85 การกระจายตัวของระยะเวลาในการเดินทางมีค่าแตกต่างกันค่อนข้างชัดเจนระหว่างช่วง Peak และ Inter-Peak สำหรับ Link C และ D มีค่าความถูกต้องในการพยากรณ์อยู่ในระดับไม่สูงมากนัก อยู่ในช่วงร้อยละ 60 – 80

สังเกตได้ว่า สำหรับ Link C และ D การพยากรณ์ระยะเวลาในการเดินทางในช่วง Peak มีค่าความถูกต้องมากกว่าช่วง Inter-Peak ซึ่งอาจจะเกิดจากช่วง Peak มีสภาพการจราจรติดขัดและมีรูปแบบค่อนข้างแน่นอน เกิดความต้องการเดินทางไปทำงาน และ AM Peak มีค่าความถูกต้องในการพยากรณ์มากกว่า PM Peak เล็กน้อย เนื่องจากมีเวลาเริ่มต้นทำงานในช่วงเวลาใกล้เคียงกัน แต่เวลาเดินทางกลับจากที่ทำงานแต่ละคนอาจจะมีแผนในการเดินทางที่แตกต่างกัน และในช่วงเวลา Inter-Peak ความต้องการเดินทางในรูปแบบอื่น อาจจะขึ้นอยู่กับเหตุการณ์ของแต่ละวัน ซึ่งอาจมีความไม่แน่นอน โดยผลที่ได้จากการ

พยากรณ์ดังกล่าวมีความสอดคล้องกับค่าความแปรปรวนของระยะเวลาในการเดินทางของ Link ในแต่ละช่วงเวลา

4. Conclusions and further work

บทความนี้เป็นผลงานวิจัยที่พัฒนาต่อเนื่องจากระบบ Siamtraffic1.0: Real-time travel time estimation [1] เพื่อใช้พยากรณ์ระยะเวลาในการเดินทางล่วงหน้า และช่วยในการวางแผนการเดินทาง ขนส่งและกระจายสินค้าภายในโครงข่ายถนนในกรุงเทพฯ การพยากรณ์ระยะเวลาในการเดินทางอาศัยการค้นหารูปแบบสภาพจราจรที่มีค่าความสัมพันธ์ของสภาพจราจรที่เกิดขึ้นตามช่วงเวลาและเชิงพื้นที่ โดยกำหนดฟังก์ชันวัตถุประสงค์ของปัญหาเพื่อค้นหารูปแบบสภาพจราจรในอดีตที่มีลักษณะใกล้เคียงกับรูปแบบสภาพจราจรที่เกิดขึ้นในปัจจุบันมากที่สุด

ผลการทดสอบกับโครงข่ายถนนในกรุงเทพฯ จำนวน 4 เส้นทาง แสดงให้เห็นว่า เส้นทางที่มีสภาพจราจรในลักษณะ Free flow (Link A และ B) มีค่าความถูกต้องในการพยากรณ์โดยเฉลี่ยมากกว่าร้อยละ 85 และเส้นทางในเขตชุมชนเมือง

Interrupted flow (Link C และ D) ซึ่งมีเส้นทางที่เชื่อมต่อที่มีความสัมพันธ์ในเชิงพื้นที่ในจำนวนค่อนข้างมาก มีค่าความถูกต้องในการพยากรณ์อยู่ในระดับที่ไม่สูงมากนัก ในช่วงร้อยละ 60 – 80 ประสิทธิภาพของอัลกอริทึมในด้านความเร็วเฉลี่ยในการค้นหาคำตอบใช้เวลาน้อยกว่า 1 วินาทีต่อเส้นทาง ต่อช่วงเวลา

งานวิจัยในส่วนต่อไป จะเน้นในส่วนการทำ Multi-threaded computing เพื่อลดระยะเวลาในการประมวลผล ให้สามารถพยากรณ์ระยะเวลาเดินทางครอบคลุมโครงข่ายถนนกรุงเทพฯมากกว่า 3,000 เส้นทาง ในแต่ละรอบการให้บริการข้อมูล 5-min interval สำหรับพยากรณ์ระยะเวลาเดินทาง 1-2 ชั่วโมงล่วงหน้า นอกจากนี้ จะพัฒนาระบบ Traffic data fusion โดยเพิ่มข้อมูลประเภท Vehicle flow และพิจารณาโครงข่ายถนนในลักษณะ Zone based network flow โดยเฉพาะเส้นทางในเขตชุมชนเมืองเพื่อเพิ่มค่าความถูกต้องและประสิทธิภาพในการพยากรณ์ให้มากยิ่งขึ้น

4. Acknowledgements

ขอขอบคุณ บริษัท เซ้าท์อีสเอเชียเทคโนโลยี จำกัด บริษัท เดอะโลจิสติกส์ จำกัด และศูนย์แท็กซี่ 1681 ที่ให้การสนับสนุนในด้านข้อมูลจราจร รวมทั้ง สำนักงานพัฒนาวิทยาศาสตร์และเทคโนโลยีแห่งชาติ (สวทช.) โครงการปริญญาเอกกาญจนาภิเษก คปก.-อุตสาหกรรม สำนักงานกองทุนสนับสนุนการวิจัย (สกว.) ที่ช่วยสนับสนุนทุนการค้นคว้าวิจัย และส่งเสริมงานวิจัยเพื่อเชื่อมโยงระหว่างภาคการศึกษาและอุตสาหกรรม

เอกสารอ้างอิง

[1] Siamtraffic1.0: Real-time travel time estimation, Available from: <http://www.trafficeyes.net/>. Nov. 2011.
[2] N.K. Chowdhury, R.P. Nath, H. Lee, and J. Chang, "Development of an effective travel time prediction method using modified moving average approach" in 13th International Conference on Knowledge-Based and Intelligent Information & Engineering Systems, Santiago, Chile, Sep. 2009, pp. 130 – 138.

[3] A. Khosravi, E. Mazlouni, S. Nahavandi, D. Creighton, and J.W.C. Lint, "Prediction intervals to account for uncertainties in travel time prediction," IEEE Trans. Intelligent Transportation Systems, vol. 12, pp. 537 – 547, June 2011.
[4] T. Kim, H. Kim, and D.J. Lovell "Traffic flow forecasting: overcoming memory-less property in nearest neighbor non-parametric regression," in Proceedings of the 8th International Conference on Intelligent Transport Systems, Vienna, Sept. 2005, pp. 965 – 969.
[5] W.H.K Lam, K. Chan, M. Tam, and W. Shi, "Short-term travel time forecasts for transport information system in Hong Kong," Journal of Advanced Transportation, vol. 39, pp. 289-306, Autumn (Fall) 2005.
[6] W. Lee, S. Tseng, and S. Tsai, "A knowledge based real-time travel time prediction system for urban network," Expert Systems with Applications, vol. 36, pp. 4239-4247, April 2009.
[7] H.E. Lin, M.A.P Taylor, and R. Zito, "A review of travel time prediction in transport and logistics," in Proceedings of Eastern Asia Society Transportation Studies. Bangkok, Thailand, Sept. 2005, pp. 1433 – 1448.
[8] Y. Liu and Y. Zhang, "Comparison of parametric and non-parametric techniques for non-peak traffic forecasting," in World Academy of Science and Technology, March 2009, issue 27, pp. 8 – 14.
[9] A. Simroth and H. Zahle, "Travel time prediction using floating car data applied to logistics planning," IEEE Trans. Intelligent Transportation Systems, vol. 12, pp. 243- 253, March 2011.
[10] Sumalee, A. (2009) "Incident detection based on short-term travel time forecasting," Research report: Department of Civil and Structural Engineering, Hong Kong Polytechnic University.