การพัฒนาแบบจำลองเพื่ออนุมานรูปแบบกิจกรรมของการเดินทาง ร่วมกับข้อมูลการใช้ประโยชน์ที่ดินและอาคาร

วิชา โครงงานทางวิศวกรรมโยธา

Development of Activity Inference Model Using Building and Land Use Data the Civil Engineering Project

พรหมพร ล่ามกิจจา[1] พลอยสวรรค์ กิตติบุญญาทิวากร[2] และ อาจารย์ ดร. พงษ์สันธ์ บัณฑิตสกุลชัย[3]

[1,2,3] ภาควิชาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย จ.กรุงเทพฯ

บทคัดย่อ

การสร้างแบบจำลองทางเลือกรูปแบบการเดินทางนั้นจำเป็นต้องมีการสำรวจข้อมูลการเดินทางในครัวเรือนโดยในอดีตถึงปัจจุบันการสำรวจข้อมูลการเดินทางในครัวเรือนในประเทศไทยที่ได้รับความนิยมแพร่หลาย คือ การสำรวจข้อมูลด้วยแบบสอบถามเนื่องจากข้อมูลที่ได้จากการสำรวจมีความละเอียดสูงและสามารถนำข้อมูลไป วิเคราะห์พฤติกรรมการเดินทางได้อย่างเหมาะสม ซึ่งการสำรวจข้อมูลการเดินทางในครัวเรือนด้วยแบบสอบถามจะ ศึกษาความต้องการการเดินทางและพฤติกรรมการเดินทางด้วยวิธีการสัมภาษณ์โดยใช้คนตามบ้าน การสัมภาษณ์ ทางโทรศัพท์และการให้ทำแบบสำรวจทางออนไลน์ โดยจะเน้นการสำรวจด้วยวิธีใช้คนสัมภาษณ์แล้วนำข้อมูลการ สำรวจสร้างแบบจำลองทางการขนส่งและจราจร หรือแบบจำลองทางสถิติ (machine learning) อย่างไรก็ตาม การสำรวจ ด้วยวิธีเหล่านี้เพื่อทำแบบจำลองมีต้นทุนสูง เนื่องจากต้องจ้างผู้สัมภาษณ์จำนวนมากในการสำรวจ ใช้เวลามาก ในการสำรวจเนื่องจากต้องสัมภาษณ์เป็นรายบุคคลแบบหนึ่งต่อหนึ่ง โครงงานนี้จึงมีวัตถุประสงค์ เพื่อหาวิธีการสำรวจที่ดีกว่าเดิม ประหยัดค่าใช้จ่าย เวลา ทรัพยากรคน และได้ข้อมูลการเคลื่อนไหวตามเวลาจริง ของผู้ถูกสัมภาษณ์จากการสำรวจ และวิธีที่กล่าวมานั้นคือ การสร้างแบบจำลองเนสเต็ดโลจิตจากข้อมูลสัญญาณ โทรศัพท์มือถือจากเครือข่ายสัญญาณโทรศัพท์เคลื่อนที่ซึ่งผ่านกระบวนการจำแนกรูปแบบและวัตถุประสงค์ของการเดินทางมาแล้ว สามารถวิเคราะห์ข้อมูลได้แบบเรียลไทม์ได้ครอบคลุมผู้เดินทางและระยะเวลาการสังเกต พฤติกรรมการเดินทางที่ยาวนานขึ้นโดยเราจะทำการสร้างแบบจำลองด้วยอัลกอริทึม Random Forest (RF)

คำสำคัญ: การพัฒนาแบบจำลอง, รูปแบบการเดินทาง, กิจกรรมการเดินทาง, การใช้ประโยชน์จากที่ดินและอาคาร, ข้อมูลสัญญาณโทรศัพท์มือถือจากเครือข่ายสัญญาณโทรศัพท์เคลื่อนที่

Abstract

Modeling alternative travel patterns more efficiently, a new approach is needed that can save costs, time, and human resources while providing real-time movement data. Currently, the most popular survey method in Thailand is the travel diary questionnaire, which collects high-resolution data through home-based interviews. However, this method is expensive and time-consuming. The proposed solution is to use mobile signal data from a mobile network to create a neural network model that classifies patterns and objectives of travel, allowing for real-time analysis of travel behavior over longer observation periods. Random Forest (RF) will be used in the modeling process

Keywords: Model development, Travel activities, Land use data, Mobile device location data

1. บทนำ

การเดินทางเป็นปัจจัยสำคัญอย่างหนึ่งในการใช้ชีวิตประจำวันของมนุษย์ และมีผลต่อการเข้าถึงและใช้ประโยชน์จากพื้นที่ต่างๆ เช่น อาหาร น้ำ หรือแหล่งพลังงาน หรือการเข้าถึงบริการสาธารณะ เช่น การไปโรงเรียน โรงพยาบาล หรือสถานีรถไฟ การเดินทางยังสร้างโอกาสในการพัฒนาเศรษฐกิจและสังคมของประเทศ การพัฒนาระบบการเดินทางจึงเป็นสิ่งสำคัญในการพัฒนาเศรษฐกิจและสังคมของประเทศในระยะยาว ซึ่งการพัฒนาระบบการเดินทางนั้นจำเป็นต้องมีการศึกษาสำรวจความต้องการการเดินทาง (Travel Demand Survey : TDS) เพื่อเก็บรวบรวมข้อมูลเกี่ยวกับพฤติกรรมการเดินทางของประชากรในพื้นที่นั้น ๆ และนำข้อมูลจากการสำรวจมาสร้างแบบจำลองอนุมานรูปแบบกิจกรรมของการเดินทางร่วมกับข้อมูลการใช้ประโยชน์ที่ดินและอาคาร เพื่อวางแผนการพัฒนาโครงข่ายขนส่งสาธารณะ โครงสร้างพื้นฐาน และการลงทุนในด้านคมนาคมการขนส่งเพื่อให้มีประสิทธิภาพและเกิดประโยชน์สูงสุดในการใช้ชีวิตประจำวันและการพัฒนาเศรษฐกิจของประเทศ.

2. ทบทวนวรรณกรรม

2.1 ศึกษาข้อมูลในปัจจุบัน

2.2.1 Travel Demand Survey โดย สำนักงานนโยบายและแผนการขนส่งและจราจร (สนข.)

เป็นโครงการจากทางภาครัฐเพื่อศึกษาสำรวจความต้องการการเดินทาง (Travel Demand Survey, TDS) และปรับปรุงฐานข้อมูลการเคลื่อนย้ายสินค้าเพื่อการวางแผนระบบขนส่งของประเทศ ซึ่งเป็นข้อมูลหลักสำหรับการพัฒนาแบบจำลองด้านการจราจรและขนส่ง เพื่อเป็นเครื่องมือวิเคราะห์แผนงาน โครงการต่าง ๆ ตามนโยบายรัฐบาลได้อย่างถูกต้อง ทันสมัย สอดคล้องกับสภาวการณ์ทางเศรษฐกิจและสังคมปีล่าสุด โดยมีการสำรวจข้อมูลครัวเรือน (Household Travel Survey, HTS) โดยใช้รูปแบบการสำรวจด้วยวิธีใช้คนสัมภาษณ์ (Personal Interviews) การสัมภาษณ์ทางโทรศัพท์ (Pick up Call) และการสำรวจผ่านทางเว็บไซต์ โดยจะเลือกใช้วิธีการสำรวจโดยรูปแบบหลักเน้นการสำรวจโดยวิธีใช้คนสัมภาษณ์ และอาจใช้วิธีการสำรวจทางโทรศัพท์และการสำรวจบนเว็บไซต์มา ประยุกต์ใช้ในการสำรวจ ซึ่งการสำรวจโดยใช้คนสัมภาษณ์เป็นวิธีที่มีความเหมาะสมกับแบบสอบถามที่ใช้ในโครงการ TDS เนื่องจากข้อมูลในแบบสอบถามเป็นข้อมูลที่มีรายละเอียดค่อนข้างมาก และการสำรวจโดยใช้คนสัมภาษณ์ยังเป็นวิธีที่นิยมใช้มากสุด สามารถอธิบายข้อมูลที่มีรายละเอียดมากได้เข้าใจกว่าวิธีอื่นหากลุ่มเป้าหมายได้ตรงตามวัตถุประสงค์ รวมทั้งเป็นการสำรวจที่ผู้ตอบแบบสอบถามให้ความร่วมมือและเต็มใจในการให้ข้อมูลมากกว่าการสำรวจที่ไม่เห็นผู้สัมภาษณ์ แต่ก็มีข้อเสียในส่วนการสำรวจค่อนข้างใช้เวลานานและค่าใช้จ่ายค่อนข้างสูง ในส่วนวิธีการสำรวจทางโทรศัพท์ จะนำมาประยุกต์ใช้โดยการโทรสอบถามข้อมูล ซึ่งผู้สำรวจจะเป็นคนบันทึกข้อมูลในแบบสอบถามและการสำรวจบนเว็บไซต์ จะทำการสำรวจโดยผ่านเว็บไซต์ของโครงการ TDS ขึ้นมา เพื่อให้ผู้ตอบแบบสอบถามสามารถเข้าไปกรอกข้อมูลได้ ซึ่งเป็นวิธีที่ค่อนข้างรวดเร็วในการจัดเก็บข้อมูล ในขั้นตอนการออกแบบสอบถาม ได้นำแบบสอบถามไปทำการสำรวจ (Pilot Survey) กับกลุ่มตัวอย่างประมาณ 50 ชุด ทำการตรวจสอบข้อมูลเบื้องต้น เพื่อนำปัญหาที่เป็นอุปสรรคในการสำรวจข้อมูลมาปรับปรุงแบบสอบถาม เพื่อให้แบบสอบถามมีความเข้าใจง่ายและผู้ตอบแบบสอบถามให้ความร่วมมือสูงสุด

ส่วนที่สนใจ คือ วัตถุประสงค์การเดินทางของกลุ่มตัวอย่างส่วนใหญ่ เป็นการเดินทางเพื่อไปทำงาน คิดเป็นร้อยละ 63 ของกลุ่มตัวอย่างทั้งหมด ซึ่งมีผู้ที่ไม่เดินทาง คิดเป็นร้อยละ 8.0

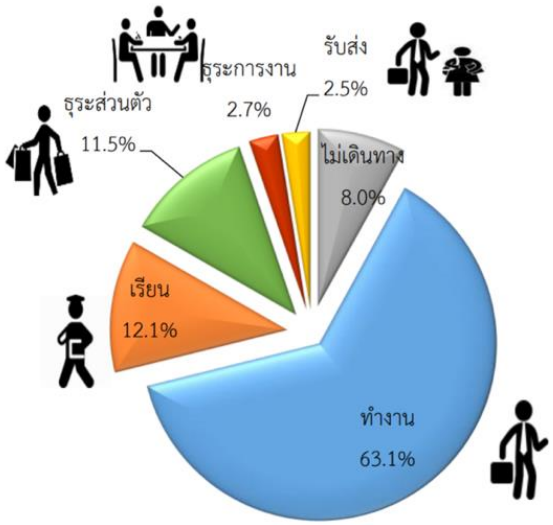

รูปที่ 1 วัตถุประสงค์การเดินทาง

2.2.2 โครงการศึกษาการพัฒนานวัตกรรม ระบบวิเคราะห์ฐานข้อมูลขนาดใหญ่ เพื่อการขนส่งสินค้าด้วยรถบรรทุกและการเดินทางของคนในเขตกรุงเทพมหานครและปริมณฑล ของสำนักงานนโยบายและแผนการขนส่งและจราจร (สนข.)

โครงการนี้เน้นการวิเคราะห์ฐานข้อมูลขนาดใหญ่เพื่อหาข้อมูลพฤติกรรมการขนส่งและการเดินทางของคน แล้วนำไปปรับปรุงโครงสร้างพื้นฐานด้านคมนาคมและเพิ่มความสามารถในการแข่งขันของประเทศ ข้อมูลเดินทางนำเข้าจากหลายแหล่งเช่นพิกัดโทรศัพท์เคลื่อนที่และแอปพลิเคชันสำรวจข้อมูล

ส่วนที่สนใจ คือการระบุกิจกรรมการเดินทางด้วย Decision Tree ผ่านแนวคิด ดังนี้

จุดหยุดการเดินทางของคนส่วนใหญ่ใช้ประโยชน์ตามการใช้สอยของพื้นที่นั้น เช่น ห้างสรรพสินค้าหรือสถานที่ท่องเที่ยว

เวลาที่มาถึงจุดหยุดเดินทางมีผลต่อกิจกรรมที่ทำในจุดนั้น เช่น มาเยือนห้างสรรพสินค้าหลังเวลา 10 โมงก่อนจะมีโอกาสที่จะมาทำงาน

ช่วงเวลาที่อยู่ในจุดหยุดเดินทางมีผลต่อกิจกรรมที่ทำในจุดนั้น เช่น อยู่ในห้างสรรพสินค้ามากกว่า 8 ชั่วโมงมีโอกาสจะมาเพื่อทำงาน

2.2.3 ข้อมูลการใช้ประโยชน์ที่ดินและอาคารในปัจจุบัน

เป็นส่วนของข้อมูลที่ได้มาจาก โครงการจัดเก็บข้อมูลอาคารในพื้นที่กรุงเทพมหานครเพื่อการปรับปรุงแผนที่การใช้ประโยชน์ที่ดินมาตราส่วน 1:4000 ในระบบสารสนเทศภูมิศาสตร์ โดยจากโครงการนี้มีการจัดเก็บข้อมูลด้วยกัน 3 ประเภท ได้แก่

ชื่อประเภทข้อมูล		ชื่อแฟ้มข้อมูล	Feature type
ชื่อไทย	ชื่ออังกฤษ		
อาคาร และการใช้สอยอาคาร	Building	BLDG	Polygon
สิ่งก่อสร้าง	Structure	STRUCT	Line
การใช้ประโยชน์ที่ดินปัจจุบันโดยรวม	Computed Major Use	CMPMJU	Polygon

ตารางที่ 1 ประเภทและการจัดเก็บข้อมูลของโครงการ

2.2 ทฤษฎีที่เกี่ยวข้องภายในงานวิจัย

Random Forest (RF)

เป็นอัลกอริทึมที่พัฒนามาจาก Decision Tree การใช้ Random Forest ได้รับความนิยมอย่างมากในการทำ Machine Learning โดยสามารถนำไปใช้กับงานที่ต้องการทำนายหรือจัดกลุ่มข้อมูลได้หลากหลาย

การใช้ RF ในการแก้ปัญหาเป็นการใช้ mean squared error (MSE) ในแต่ละโหนด

$$MSE = \frac{1}{N}\sum_{i=1}^{N}(f_i - y_i)^2$$

ซึ่งสมการนี้เป็นการคำนวณระยะทางของแต่ละโหนดจากการทำนายจากข้อมูล เพื่อช่วยในการตัดสินใจว่าเส้นทางไหนดีที่สุด โดยที่ y_i คือค่าจุดของข้อมูลที่นำมาทดสอบ และ f_i คือข้อมูลที่คืนออกมาจาก decision tree

3. ระเบียบวิธีวิจัย

3.1 ขอบข่ายการวิเคราะห์ข้อมูล

ขอบข่ายของการทำงานเริ่มจากการนำข้อมูลที่ได้มา มาทำการคัดกรองข้อมูล และนำข้อมูลการเดินทางมาเชื่อมโยงกับข้อมูลการใช้ประโยชน์อาคารและที่ดิน และจัดการให้ข้อมูลเป็นไปตามที่อัลกอริทึมต้องการ ทำการเรียนรู้และทดสอบข้อมูล ในส่วนข้างต้นจะเป็นส่วนของการพัฒนาแบบจำลอง และเพื่อทำความเข้าใจพฤติกรรมการเดินทางมากขึ้น จะจัดทำรูปแบบกิจกรรมการเดินทางจากข้อมูลที่ได้อีกด้วย

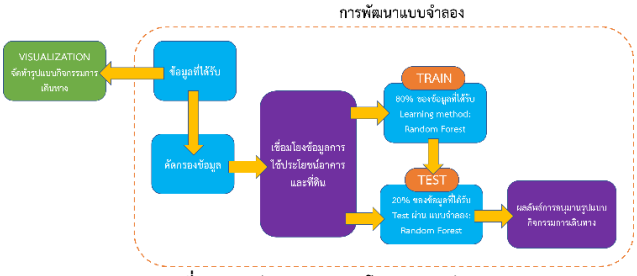

รูปที่ 1 ขอบข่ายการทำงานโครงการวิจัย

3.2 อัลกอริทึมที่ใช้ในการพัฒนาแบบจำลอง

อัลกอริทึมที่ใช้ในการพัฒนาแบบจำลอง คือ Random Forest (RF) ซึ่ง แบบจำลอง RF ประกอบด้วย classification and regression trees (CART) จำนวนหนึ่ง ซึ่งการศึกษานี้จะฝึกฝนข้อมูลผ่านการใช้โปรแกรม R และโปรแกรม Microsoft Excel ด้วยข้อมูลจากโครงการ... แล้วนำมาแบ่งข้อมูลเป็นสองส่วน คือส่วนของข้อมูลสำหรับให้แบบจำลองเรียนรู้ 80% ของข้อมูลที่ได้ และข้อมูลสำหรับการทดสอบ 20% ของข้อมูลที่ได้ โดยประมาณการตัวแปรตอบสนองผ่าน CART tree ทั้งหมด

3.3 การจัดทำรูปแบบการเดินทาง

การจัดทำรูปแบบการเดินทางนั้น ทำไปเพื่อดูแนวโน้มกิจกรรมการเดินทางไปในแต่ละที่ และการทำกิจกรรมในที่ ๆ นั้น เพราะจากการพัฒนาแบบจำลอง ช่วยในการสันนิษฐานถึงกิจกรรมหนึ่ง ๆ ที่ทำไปในแต่ละที่เพียงเท่านั้น หากมองเห็นการเดินทางในภาพรวมของการเดินทางในแต่ละเที่ยว ย่อมส่งผลให้เข้าใจถึงพฤติกรรมของบุคคลในบริเวณที่เก็บข้อมูลได้มากขึ้น

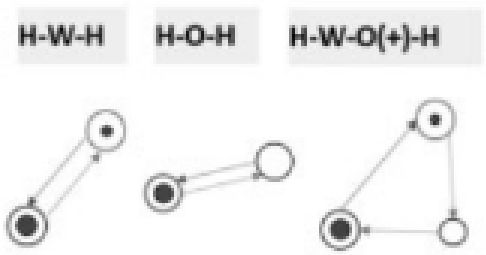

รูปที่ 2 ตัวอย่างแสดงรูปแบบกิจกรรมการเดินทาง

3.4 การดูประสิทธิภาพของอัลกอริทึม

การดูประสิทธิภาพนั้นใช้วิธี fivefold cross-validation โดยแบ่งชุดข้อมูล HTS เป็นห้ากลุ่มย่อย และทำการตรวจสอบซ้ำห้าครั้ง โดยในแต่ละครั้งนั้น จะมีสี่กลุ่มที่ใช้ในการประมาณการ และอีกหนึ่งกลุ่มที่เหลือใช้เพื่อการตรวจสอบ ค่าเฉลี่ยของความไว (sensitivity) และความแม่นยำ (precision) ของการตรวจสอบนั้น จะถูกคำนวณสำหรับแต่ละแบบจำลองและแต่ละประเภทกิจกรรม โดย ความไว คำนวณจากอัตราส่วนของกรณีที่ถูกต้องต่อกรณีทั้งหมดของประเภทกิจกรรมนั้น ในส่วนของ ความแม่นยำ คือ อัตราการคาดการณ์เชิงบวก ซึ่งแสดงถึงอัตราส่วนของกรณีที่จัดประเภทอย่างถูกต้องต่อทุกกรณีที่ถูกจำแนกตามกิจกรรมประเภทนี้ตามแบบจำลอง

4. การดำเนินงาน บทสรุปและข้อเสนอแนะ

4.1 การพัฒนาแบบจำลอง

ในส่วนนี้คือการพัฒนาแบบจำลองเพื่อช่วยในการอนุมานกิจกรรมจากข้อมูลที่เก็บได้ โดยทำการเลือกตัวแปรที่ต้องการใช้ในการตัดสินใจภายใต้แบบจำลอง ซึ่งตัวแปรที่เลือกมีดังนี้

หัวข้อ	other	
ตัวแปรตอบสนอง	activity_type	ประเภทกิจกรรมการเดินทาง ซึ่งประกอบไปด้วย rest, work ,home, other
ตัวแปรที่ใช้ในการตัดสินใจ	time_hr	ข้อมูลเวลาการเดินทาง โดยนับเพียงชั่วโมงเท่านั้น
	time_m	ข้อมูลเวลาที่ใช้ในการเดินทาง
	mode	ประเภทการเดินทาง
	zone928_id_o	เขตภายในกรุงเทพมหานคร ที่เป็นจุดเริ่มต้น
	zone928_id_d	เขตภายในหรุงเทพมหานครที่เป็นปลายทาง
	lat_o	ละติจูดของจุดเริ่มต้น
	lon_o	ลองจิจูดของจุดเริ่มต้น
	lat_d	ละติจูดของปลายทาง
	lon_d	ลองจิจูดของปลายทาง
	price	ค่าใช้จ่ายในการเดินทาง
	dist_m	ระยะทางในการเดินทาง ในหน่วยเมตร
	running_id	ลำดับกิจกรรมที่เกิดขึ้นในทริปนั้น ๆ

ตารางที่ 2 ตัวแปรที่นำมาใช้ในการตัดสินใจของแบบจำลอง

จากนั้นเมื่อทำการให้แบบจำลองอนุมานกิจกรรม จะได้ผลลัพธ์ ดังตัวอย่างนี้

541	545	570	571	581	584	617
other	other	rest	other	work	other	other
648	656	657	660	670	676	680
other	work	rest	rest	work	other	rest
751	757	758	759	776	778	779
rest	rest	rest	other	other	rest	other
837	838	839	845	846	854	856
other	work	rest	other	rest	other	work
925	930	943	952	953	955	984
other	rest	other	rest	rest	rest	other

รูปที่ 3 ตัวอย่างผลลัพธ์การอนุมานกิจกรรมบนหน้าจอคอมพิวเตอร์

และทำการดูประสิทธิภาพจาก sensitivity และ Precision ซึ่งได้ค่าดังต่อไปนี้

หัวข้อ	other	rest	transit	work
Sensitivity	0.9930	0.9907	1.0000	0.9907
Precision	09985	0.9996	0.8703	1.0000

ตารางที่ 2 ค่า Sensitivity และ Precision ในแต่ละกิจกรรม

นำ sensitivity และ Precision มาคิดร่วมกันผ่านค่า F1 score โดยคำนวณ ดังต่อไปนี้

$$F1\ score = \frac{2 \times (Precision \times Sensitivity)}{Precision + Sensitivity}$$

พบว่าได้ค่า F1 score ดังนี้

หัวข้อ	other	rest	transit	work
F1 score	0.9957	0.9951	0.9307	0.9953

ตารางที่ 3 ค่า F1 score ในแต่ละกิจกรรม

จากตารางพบว่า F1 score ที่สูงกว่า 0.7 แสดงให้เห็นว่า แบบจำลองนั้นถือว่าดีสำหรับการใช้งานจริง

4.2 การจัดทำรูปแบบกิจกรรมการเดินทาง

เพื่อเป็นการทำความเข้าใจพฤติกรรมการเดินทางในภาพรวมของบุคคลที่อยู่ในบริเวณที่ได้เก็บข้อมูลให้มากขึ้น การจัดทำรูปแบบการเดินทางทำผ่าน Microsoft Excel โดยจะทำการรันหมายเลขการเดินทาง แล้วนำกิจกรรมที่ทำบนหมายเลขการเดินทางนั้น ๆ มาต่อกันเพื่อให้เห็นรูปแบบการเดินทาง ตัวอักษรแต่และตัวจะแทนกิจกรรมต่าง ๆ ดังนี้

ชื่อกิจกรรมที่ทำ	ตัวอักษรที่ใช้แทนกิจกรรม
Rest	r
Work	w
Other	o

ตารางที่ 4 ชื่อย่อแทนแต่ละกิจกรรม

จากข้อมูลที่ได้นำมาศึกษานั้นพบว่า มีรูปแบบการเดินทาง แบ่งเป็นร้อยละจากจำนวนกิจกรรมได้ทั้งหมดดังนี้

ชื่อกิจกรรมที่ทำ	ตัวอักษรที่ใช้แทนกิจกรรม(%)
Work-Rest	15.05
Rest-Work	15.00
Rest-Other	11.92
Other-Rest	11.67
Other-Other	7.73
Work-Work	5.55
Other-Work	1.83
Work-Other	1.63
Other-Other-Rest	0.92

ตารางที่ 5 ร้อยละรูปแบบการเดินทาง ที่พบเป็นส่วนใหญ่

นำรูปแบบการเดินทางส่วนมากมาจัดทำได้ ดังนี้

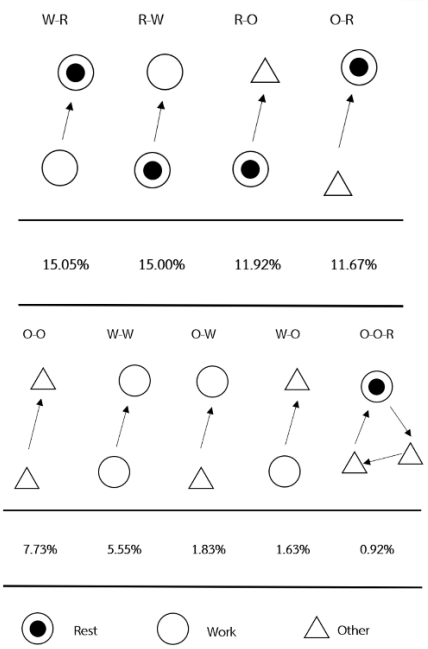

รูปที่ 5 รูปแบบกิจกรรมการเดินทางที่พบเป็นส่วนใหญ่

4.3 สรุปและข้อเสนอแนะ

จากการดำเนินงานในส่วนข้างต้น พบว่า ส่วนของการพัฒนาแบบจำลองได้ค่า F1 score ดังต่อไปนี้

หัวข้อ	Other	rest	transit	work
F1 score	0.9957	0.9951	0.9307	0.9953

ตารางที่ 6 สรุปค่า F1 score ในแต่ละกิจกรรม

จะเห็นได้ว่า F1 score มีค่าสูงกว่า 0.7 ดังนั้น แบบจำลองนี้ถือว่าดีสำหรับการใช้งานจริง

และจากการศึกษาพบว่ารูปแบบกิจกรรมการเดินทางโดยส่วนใหญ่เป็นไป ดังนี้

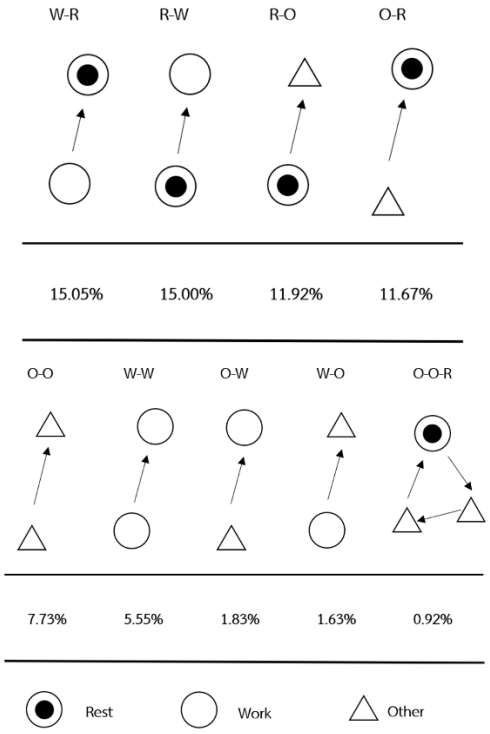

รูปที่ 6 สรุปรูปแบบกิจกรรมการเดินทางที่พบเป็นส่วนใหญ่

อย่างไรก็ตามจากการพัฒนาแบบจำลองนั้นมีการอนุมานด้วยกิจกรรมไม่กี่อย่างเท่านั้น จึงอาจยากต่อการนำไปใช้ต่อ เพราะระบุกิจกรรมได้ไม่ชัดเจนมากนัก แต่อาจสามารถนำจุดนี้ไปพัฒนาต่อสำหรับข้อมูลที่มีกิจกรรมมากขึ้น และในความจริงอัลกอริทึมสำหรับแบบจำลองนั้นยังมีอีกมาก จึงอาจนำไปพัฒนาต่อด้วยการเปลี่ยน อัลกอริทึม เช่น Conditional Random Fields ,Gradient Boosting เป็นต้น

เอกสารอ้างอิง

[1] Minh Hieu Nguyen, Jimmy Armoogum, Jean-Loup Madre, Cédric Garcia, (2020). Reviewing trip purpose imputation in GPS-based travel surveys, Journal of Traffic and Transportation Engineering (English Edition), 7(4), 395-412

[2] Feng, T., & Timmermans, H. J. (2015). Detecting activity type from GPS traces using spatial and temporal information. European Journal of Transport and Infrastructure Research, 15(4)

[3] Xin Hu, Yanfei Yang, Siru Zhu, Lanhua Chen. (2020). Research on a Hybrid Prediction Model for Purchase Behavior Based on Logistic Regression and Support Vector Machine, 2020 3rd International Conference on Artificial Intelligence and Big Data (ICAIBD), Chengdu, China, 200-204

[4] Ermagun, Alireza & Levinson, David. (2016). Public Transit, Active Travel, and the Journey to School: A Cross-nested Logit Analysis. Transportmetrica A: Transport Science. 13. 1-16.

[5] Liao, Lin & Choudhury, Tanzeem & Fox, Dieter & Kautz, Henry. (2007). Training Conditional Random Fields Using Virtual Evidence Boosting.. 2530-2535.

[6] Zhu, Yi. (2021). Inference of activity patterns from urban sensing data using conditional random fields. Environment and Planning B: Urban Analytics and City Science. 49.

[7] Statistics, L.B. & Breiman, L.. (2001). Random forests. Machine Learning. 5-32.

[8] Ermagun, Alireza & Fan, Yingling & Wolfson, Julian & Adomavicius, Gediminas & Das, Kirti. (2017). Real-time trip purpose prediction using online location-based search and discovery services. Transportation Research Part C: Emerging Technologies. 77. 96-112.

[9] Diao, Mi & Zhu, Yi & Ferreira, Joseph & Ratti, Carlo. (2015). Inferring individual daily activities from mobile phone traces: A Boston example. Environment and Planning B: Planning and Design. 43.

[10] Simas Oliveira, Marcelo & Vovsha, Peter & Wolf, Jean & Mitchell, Michael. (2014). Evaluation of Two Methods for Identifying Trip Purpose in GPS-Based Household Travel Surveys. Transportation Research Record: Journal of the Transportation Research Board. 2405. 33-41.

[11] Travel Demand Survey โดย สำนักงานนโยบายและแผนการขนส่งและจราจร (สนข.) สำนักงานนโยบายและแผนการขนส่งจราจร. (2560). โครงการศึกษาและสำรวจความต้องการการเดินทางและปรับปรุงฐานข้อมูลการเคลื่อนย้ายสินค้าเพื่อการวางแผนระบบขนส่งของประเทศ. สืบค้น 29 มกราคม 2566, จาก https://www.facebook.com/traveldemandsurveyOTP/

[12] สำนักงานนโยบายและแผนการขนส่งจราจร. (2564). โครงการศึกษาการพัฒนานวัตกรรม ระบบวิเคราะห์ฐานข้อมูลขนาดใหญ่ เพื่อการขนส่งสินค้าด้วยรถบรรทุกและการเดินทางของคนในเขตกรุงเทพมหานครและปริมณฑล. สืบค้น 29 มกราคม 2566, จาก https://www.bigdata-otp.com/

[13] Bishop, Christopher M. (2006). Pattern recognition and machine learning. New York :Springer,

[14] Feng, Tao & Timmermans, Harry. (2014). Multi-Week Travel Surveys Using GPS Devices: Experiences in The Netherlands. 104-118.

[15] Chung, Eui-Hwan & Shalaby, Amer. (2005). A Trip Reconstruction Tool for GPS-based Personal Travel Surveys. Transportation Planning and Technology. 28. 381-401.

[16] Zhu, Yi. (2020). Estimating the activity types of transit travelers using smart card transaction data: a case study of Singapore. Transportation. 47.

[17] Hoberg, Thorsten & Rottensteiner, Franz & Heipke, Christian. (2010). Classification of multitemporal remote sensing data using Conditional Random Fields. 2010 IAPR Workshop on Pattern Recognition in Remote Sensing, PRRS 2010. 1-4.

[18] Reumers, Sofie & Liu, Feng & Janssens, Davy & Cools, Mario & Wets, Geert. (2013). Semantic Annotation of Global Positioning System Traces: Activity Type Inference. Transportation Research Record: Journal of the Transportation Research Board. 2383.

[19] Hadjidimitriou, Natalia & Cantelmo, Guido & Antoniou, Constantinos. (2022). Machine learning for activity pattern detection. Journal of Intelligent Transportation Systems. 1-15.

[20] Gao, Qinggang & Molloy, Joseph & Axhausen, Kay. (2021). Trip Purpose Imputation Using GPS Trajectories with Machine Learning. ISPRS International Journal of Geo-Information. 10. 775.

[21] Nguyen, Minh Hieu. (2020). Deriving trip's modes and trip's purposes from GPS-based travel surveys.

[22] Tran, Yen & Hashimoto, Naohisa & Ando, Takafumi & Sato, Toshihisa & Konishi, Naoki & Takeda, Yuji & Akamatsu, Motoyuki. (2022). Activity-Based Model using GPS Data and Google APIs. 1723-1729.

[23] Montini, Lara & Rieser-Schüssler, Nadine & Horni, Andreas & Axhausen, Kay. (2014). Trip Purpose Identification from GPS Tracks. Transportation Research Record: Journal of the Transportation Research Board. 2405.