

ปัจจัยที่มีอิทธิพลต่อการเลือกรูปแบบการเดินทางของผู้สูงอายุ
ในเมืองภูมิภาคของประเทศไทย



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมโยธา ขนส่ง และทรัพยากรธรณี

มหาวิทยาลัยเทคโนโลยีสุรนารี

ปีการศึกษา 2567

FACTORS INFLUENCING THE CHOICE OF TRANSPORTATION MODE
OF THE ELDERLY IN REGIONAL CITIES OF THAILAND



A Thesis Submitted in Partial Fulfillment of the Requirements for the Degree of
Master of Engineering in Civil Transportation and Geo-resources Engineering

Suranaree University of Technology

Academic Year 2024

ปัจจัยที่มีอิทธิพลต่อการเลือกรูปแบบการเดินทางของผู้สูงอายุในเมืองภูมิภาคของ
ประเทศไทย

มหาวิทยาลัยเทคโนโลยีสุรนารี อนุมัติให้นับวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษา
ตามหลักสูตรปริญญาวิทยาศาสตรบัณฑิต

คณะกรรมการสอบวิทยานิพนธ์



(ศ. ดร.ธเนศ เสถียรนาม)

ประธานกรรมการ



(รศ. ดร.สัจจากาจ จอมโนนเขวา)

กรรมการ (อาจารย์ที่ปรึกษาวิทยานิพนธ์)



(ศ. ดร.วิฒนวงศ์ รัตนวรราช)

กรรมการ



(รศ. ดร.ยุพาพร รักสกุลพิวัฒน์)

รองอธิการบดีฝ่ายวิชาการและประกันคุณภาพ



(รศ. ดร.พรศิริ จงกล)

คณบดีสำนักวิชาวิศวกรรมศาสตร์

อนันตญา พิสิก: ปัจจัยที่มีอิทธิพลต่อการเลือกรูปแบบการเดินทางของผู้สูงอายุในเมือง
ภูมิภาคของประเทศไทย (FACTORS INFLUENCING THE CHOICE OF TRANSPORTATION
MODE OF THE ELDERLY IN REGIONAL CITIES OF THAILAND)

อาจารย์ที่ปรึกษา: รองศาสตราจารย์ ดร.สังจากจ จอมโนนเขวา, 104 หน้า

คำสำคัญ: ผู้สูงอายุ, การเลือกโหมดการเดินทาง, ขนส่งสาธารณะ, เมืองภูมิภาค, ทฤษฎีพฤติกรรมตาม
แผน, การเรียนรู้ของเครื่อง, ประเทศไทย

การเพิ่มขึ้นของประชากรสูงอายุในประเทศไทยทำให้เกิดความต้องการในการพัฒนาระบบ
ขนส่งสาธารณะที่เหมาะสมและปลอดภัยสำหรับผู้สูงอายุ การศึกษานี้มีวัตถุประสงค์เพื่อพัฒนา
แบบจำลองปัจจัยที่มีอิทธิพลต่อความตั้งใจของผู้สูงอายุในการใช้บริการขนส่งสาธารณะในเมือง
ภูมิภาค และวิเคราะห์การเลือกรูปแบบการเดินทางของกลุ่มผู้สูงอายุ โดยอิงจากกรอบแนวคิดทฤษฎี
พฤติกรรมตามแผน (Theory of Planned Behavior: TPB) ร่วมกับเทคนิค Machine Learning
เพื่อเพิ่มประสิทธิภาพในการจำแนกพฤติกรรมการเดินทาง กลุ่มตัวอย่างประกอบด้วยผู้สูงอายุอายุ 60
ปีขึ้นไป จำนวน 1,000 คน จาก 4 ภูมิภาคหลักของประเทศไทย โดยใช้แบบสอบถามซึ่งครอบคลุมข้อมูล
ทั่วไป ปัจจัยด้านพฤติกรรม และแบบบันทึกการเดินทาง (Travel Diary) ข้อมูลถูกวิเคราะห์ด้วยการ
ถดถอยโลจิสติกพหุกลุ่ม (MLR), แบบจำลองโครงสร้าง (SEM) และเปรียบเทียบกับโมเดล Machine
Learning ได้แก่ Random Forest, XGBoost และ CatBoost ผลการวิจัยพบว่า ทักษะคิด บรรทัด
ฐานกลุ่มอ้างอิง และการรับรู้การควบคุมพฤติกรรม ส่งผลเชิงบวกต่อความตั้งใจของผู้สูงอายุในการใช้
บริการขนส่งสาธารณะ โมเดล CatBoost แสดงความแม่นยำสูงสุดในชุดทดสอบ (94%) ส่วน
Random Forest ให้ผลดีที่สุดในชุดข้อมูลรวม (99.83%) ปัจจัยสำคัญที่มีอิทธิพลต่อการเลือกโหมด
การเดินทาง ได้แก่ ค่าใช้จ่าย รายได้ ระยะทาง และความสะดวกในการเข้าถึงระบบขนส่ง ผลลัพธ์จาก
SHAP ช่วยให้เข้าใจความสัมพันธ์ของปัจจัยต่าง ๆ ที่ซับซ้อนมากขึ้น ข้อมูลจากงานวิจัยนี้สามารถ
ประยุกต์ใช้เพื่อออกแบบระบบขนส่งที่เหมาะสมกับกลุ่มผู้สูงอายุ และสนับสนุนการกำหนดนโยบาย
ขนส่งอย่างยั่งยืนในระยะยาว

สาขาวิชา วิศวกรรมขนส่ง
ปีการศึกษา 2567

ลายมือชื่อนักศึกษา.....อนันตญา พิสิก.....
ลายมือชื่ออาจารย์ที่ปรึกษา.....

ANANTAYA PELUCK: FACTORS INFLUENCING THE CHOICE OF
TRANSPORTATION MODE OF THE ELDERLY IN REGIONAL CITIES OF THAILAND
THESIS ADVISOR: ASSOC. PROF. DR. SAJJAKAJ JOMNOKWAO, Ph.D., 104 PP.

Keyword: elderly, travel mode choice, public transportation, regional cities, theory of planned behavior, machine learning, Thailand

The rising number of elderly people in Thailand has increased the demand for a public transportation system that is both appropriate and safe for older adults. This study aims to develop a model identifying the factors influencing the elderly's intention to use public transportation in regional cities and to analyze their travel mode choices. The analysis is based on the Theory of Planned Behavior (TPB) and incorporates Machine Learning techniques to enhance the accuracy of travel behavior prediction. The sample comprised 1,000 elderly individuals aged 60 and above, selected from four main regions of Thailand. A structured questionnaire was employed, covering general information, behavioral factors, and travel diary data. The data were analyzed using Multinomial Logistic Regression (MLR), Structural Equation Modeling (SEM), and compared with Machine Learning models including Random Forest, XGBoost, and CatBoost. The findings revealed that attitude, subjective norm, and perceived behavioral control significantly and positively influenced the intention to use public transportation. Among the ML models, CatBoost achieved the highest accuracy on the test dataset (94%), while Random Forest showed the best overall performance on the full dataset (99.83%). Key factors affecting mode choice included travel cost, income, distance, and accessibility. SHAP results provided deeper insights into complex relationships among variables, highlighting the potential of this research to inform the design of elderly-friendly transportation systems and support sustainable transportation policy planning.

School of Transportation Engineering
Academic Year 2024

Student's Signature.....อนันตยา เปลลัค.....
Advisor's Signature.....Assoc. Prof. Dr. Sajjakaj Jomnokwao.....

กิตติกรรมประกาศ

ข้าพเจ้าขอขอบคุณอาจารย์ที่ปรึกษา รองศาสตราจารย์ ดร.สัจจาจาก จอมโนนเขวา ที่ได้ให้คำแนะนำต่อเนื่องตลอดระยะเวลาของการดำเนินงานวิจัยจนสำเร็จ

ข้าพเจ้าขอขอบคุณคณะกรรมการสอบวิทยานิพนธ์ทุกท่าน โดยเฉพาะอย่างยิ่ง ศาสตราจารย์ ดร.วัฒนวงศ์ รัตนวรราช และ ศาสตราจารย์ ดร.ธเนศ เสถียรนาม ที่กรุณาใช้เวลาให้ข้อเสนอแนะแก่ข้าพเจ้าด้วยความละเอียดรอบคอบ เพื่อยกระดับคุณภาพของงานให้แล้วเสร็จสมบูรณ์

นอกจากนี้ ข้าพเจ้าขอขอบคุณเจ้าหน้าที่และบุคลากรจากสำนักวิชาวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีสุรนารี สำหรับการสนับสนุนด้านเอกสาร วิชาการ และในกระบวนการต่าง ๆ

ขอขอบคุณเพื่อนร่วมรุ่นและผู้ร่วมเก็บข้อมูลทุกท่าน รวมถึงกลุ่มตัวอย่างจากทั้ง 4 ภูมิภาคของประเทศไทย ที่ให้ความร่วมมือและสละเวลาอย่างเต็มใจช่วยให้งานนี้สำเร็จได้

ท้ายที่สุด ข้าพเจ้าขอแสดงความซาบซึ้งใจต่อครอบครัวอันเป็นที่รัก ที่คอยเป็นแรงสนับสนุนและพลังใจสำคัญตลอดเส้นทางของการศึกษา การสนับสนุนทั้งทางด้านจิตใจและความเข้าใจอย่างไม่มีเงื่อนไขจากครอบครัว เป็นแรงผลักดันที่ทำให้ก้าวผ่านทุกอุปสรรคจนสามารถสำเร็จลุล่วงได้อย่างสมบูรณ์

อนันตญา พิลีก



สารบัญ

หน้า

บทคัดย่อ (ภาษาไทย).....	ก
บทคัดย่อ (ภาษาอังกฤษ).....	ข
กิตติกรรมประกาศ.....	ค
สารบัญ.....	ง
สารบัญตาราง.....	ช
สารบัญรูป.....	ซ
บทที่	
1 บทนำ	1
1.1 ความสำคัญและที่มาของปัญหา.....	1
1.2 วัตถุประสงค์งานวิจัย.....	3
1.3 ขอบเขตของงานวิจัย.....	3
1.4 คำถามงานวิจัย.....	3
1.5 ประโยชน์ที่คาดว่าจะได้รับ.....	3
2 ทบทวนวรรณกรรมและงานวิจัยที่เกี่ยวข้อง	4
2.1 การเลือกรูปแบบการเดินทาง.....	4
2.2 แนวคิดและทฤษฎีที่เกี่ยวข้องกับทฤษฎีพฤติกรรมตามแผน (Theory of planned behavior).....	5
2.3 การทดสอบความเที่ยงตรงของเครื่องมือการวิจัย.....	6
2.4 การวิจัยการวิเคราะห์ห่อหุ้มประกอบเชิงยืนยัน.....	7
2.5 การวิเคราะห์การถดถอยโลจิสติกพหุกลุ่ม (Multinomial logistic regression analysis).....	10
2.6 การประยุกต์ใช้ Machine Learning ในการเลือกโหมดการเดินทาง.....	11
2.6.1 เทคนิคนิยมในงานเลือกโหมดเดินทาง.....	11
2.6.2 การตีความผลจาก ML ด้วย SHAP.....	11
2.7 งานวิจัยที่เกี่ยวข้อง.....	12
3 วิธีดำเนินการวิจัย	17
3.1 ขั้นตอนการทำวิจัย.....	17
3.2 เครื่องมือที่ใช้ในการวิจัย.....	19

สารบัญ (ต่อ)

หน้า

3.3	การเก็บรวบรวมข้อมูล.....	19
3.3.1	การกำหนดขนาดตัวอย่างสำหรับการวิเคราะห์ SEM ตามทฤษฎี TPB.....	19
3.3.2	การกำหนดขนาดตัวอย่างสำหรับการวิเคราะห์ MLR.....	19
3.4	กรอบแนวคิดการวิจัย.....	21
3.4.1	กรอบแนวคิด SEM ตามทฤษฎี TPB.....	21
3.4.2	สมมติฐานของดัชนีความพร้อมทางเทคโนโลยี	23
3.5	การวิเคราะห์ข้อมูล.....	24
3.5.1	การสร้างแบบจำลองสมการโครงสร้าง (SEM).....	24
3.5.2	การวิเคราะห์ด้วยการถดถอยโลจิสติกพหุกลุ่ม (MLR)	24
3.5.3	การใช้ Machine Learning (RF, XGBoost, CatBoost).....	24
4	ผลการวิเคราะห์ข้อมูล	27
4.1	ข้อมูลทั่วไปและพฤติกรรมทางการเดินทางของผู้ตอบแบบสอบถาม	27
4.2	ผลการวิเคราะห์สถิติเบื้องต้นของแบบสอบถามการวิเคราะห์ความสำคัญ (Important) ของผู้ตอบแบบสอบถาม	30
4.3	ค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างตัวแปรอิสระในแบบจำลอง	32
4.4	ผลการวิเคราะห์องค์ประกอบเชิงยืนยัน (Confirmatory Factor Analysis)	35
4.4.1	โครงสร้างโมเดลการวัด (Measurement Model)	35
4.4.2	ค่าความเหมาะสมของโมเดล (Model Fit Indices).....	35
4.4.3	ค่าความเชื่อมั่นของตัวแปรแฝง (Standardized Factor Loadings)	36
4.5	การวิเคราะห์แบบจำลองสมการโครงสร้าง (Structural Equation Modeling).....	38
4.5.1	การตรวจสอบความสอดคล้องของแบบจำลองโครงสร้างความตั้งใจแสดงพฤติกรรมการใช้บริการขนส่งสาธารณะสำหรับผู้สูงอายุ	38
4.5.2	การวิเคราะห์เส้นทางความสัมพันธ์และการทดสอบสมมติฐาน.....	38
4.6	การวิเคราะห์ถดถอยโลจิสติกพหุกลุ่ม (MLR).....	40
4.6.1	การประมาณค่าพารามิเตอร์ของแบบจำลอง (Parameter Estimates).....	41
4.6.2	การทดสอบอิทธิพลของตัวแปรโดยใช้ Likelihood Ratio Tests	43
4.6.3	การทดสอบสำหรับตรวจสอบความแม่นยำของโมเดลในการจำแนกหมวดหมู่ โหมดการเดินทาง (Confusion Matrix)	44

สารบัญ (ต่อ)

หน้า

4.7	การเปรียบเทียบประสิทธิภาพของแบบจำลอง Machine Learning	45
4.7.1	การเปรียบเทียบผลบนชุดข้อมูลทดสอบและข้อมูลทั้งหมด	45
4.7.2	การวิเคราะห์ความสำคัญของตัวแปร (Feature Importance Analysis).....	47
4.7.3	การวิเคราะห์ SHAP เพื่อการตีความผลของโมเดล.....	48
4.8	การเปรียบเทียบการวิเคราะห์ทางสถิติกับ Machine Learning	52
5	สรุปผลการวิจัย อภิปรายผล และข้อเสนอแนะ.....	55
5.1	สรุปผลการศึกษา	55
5.1.1	ปัจจัยกำหนดการเลือกรูปแบบการเดินทางของผู้สูงอายุ	55
5.1.2	การเปรียบเทียบวิธีการวิเคราะห์.....	56
5.2	การเปรียบเทียบกับงานวิจัยที่ผ่านมา	57
5.3	ข้อเสนอเชิงระเบียบวิธี: การเปรียบเทียบระหว่าง MNL และ Machine Learning .	58
5.4	ข้อเสนอเชิงระเบียบวิธี: การประยุกต์ใช้ CFA และ SEM	59
5.5	ข้อเสนอเชิงนโยบายสำหรับระบบขนส่งของผู้สูงอายุ	61
5.5.1	ความสามารถในการเข้าถึงในมิติด้านเศรษฐกิจ.....	61
5.5.2	มิติทางสังคมของการเดินทาง.....	61
5.5.3	การพัฒนาเฉพาะโหมดการเดินทาง	62
5.5.4	การออกแบบโครงสร้างพื้นฐานและบริการ	62
5.6	ข้อจำกัดของการศึกษาและแนวทางการวิจัยในอนาคต.....	63
	รายการอ้างอิง	65
	ภาคผนวก.....	70
	ภาคผนวก ก แบบสอบถามของโครงการวิจัยเรื่อง ปัจจัยที่มีอิทธิพลต่อการเลือกรูปแบบการ เดินทางของผู้สูงอายุในเมืองภูมิภาคของประเทศไทย	71
	ภาคผนวก ข บทความวิชาการที่ได้รับการตีพิมพ์เผยแพร่ในระหว่างศึกษา	77
	ประวัติผู้เขียน.....	104

สารบัญตาราง

ตารางที่	หน้า
2.1	เกณฑ์การพิจารณาที่เป็นจุดตัดของค่าดัชนีวัดความกลมกลืนที่ยอมรับได้..... 9
2.2	ตารางการระบุช่องว่างในการวิจัย (Research Gaps)..... 16
3.1	เกณฑ์การพิจารณาที่เป็นจุดตัดของค่าดัชนีวัดความกลมกลืนที่ยอมรับได้..... 23
4.1	การแจกแจงข้อมูลทั่วไปและลักษณะทางสังคมและเศรษฐกิจของกลุ่มตัวอย่าง..... 28
4.2	พฤติกรรมการเดินทางระบบขนส่งสาธารณะของผู้ตอบแบบสอบถาม..... 29
4.3	การวิเคราะห์สถิติเบื้องต้นของแบบสอบถามการวิเคราะห์ความสำคัญ (Important)..... 31
4.4	ค่าสัมประสิทธิ์สหสัมพันธ์ของตัวแปรปัจจัยที่มีต่อความตั้งใจของผู้สูงอายุในการใช้บริการขนส่งสาธารณะ 34
4.5	ตารางแสดงความเหมาะสมของโมเดล (Model Fit Indices)..... 35
4.6	แสดงผลการวิเคราะห์องค์ประกอบเชิงยืนยัน (CFA) ของแบบจำลอง..... 36
4.7	ตารางแสดงผลการทดสอบสมมติฐานจากการวิเคราะห์แบบจำลองสมการโครงสร้าง 39
4.8	ความเหมาะสมของแบบจำลองและค่า Pseudo R-Square..... 40
4.9	ค่าสัมประสิทธิ์ถดถอย (B), ค่า Exp(B) และค่าความมีนัยสำคัญทางสถิติ..... 41
4.10	การประมาณค่าพารามิเตอร์ของแบบจำลอง (Parameter Estimates) 41
4.11	Likelihood Ratio Tests 43
4.12	ตารางแสดงความถูกต้องของการจำแนกกลุ่ม (Confusion Matrix)..... 45
4.13	ผลลัพธ์จาก Test Data (30% ของข้อมูลทั้งหมด) 46
4.14	ผลลัพธ์จาก Real Data (100% ของข้อมูลทั้งหมด)..... 46
4.15	แสดงผลการวิเคราะห์ความสำคัญของตัวแปรจากแต่ละโมเดล 47
4.16	Confusion Matrix..... 52
4.17	การเปรียบเทียบ Accuracy ของแต่ละโมเดล..... 53

สารบัญรูป


รูปที่	หน้า
1.1	การเปลี่ยนแปลงโครงสร้างประชากรของโลก 1
2.1	ทฤษฎีพฤติกรรมตามแผน (Theory of planned behavior - TPB)..... 6
3.1	ขั้นตอนการทำวิจัย 18
3.2	ขั้นตอนการทำวิจัยในส่วนของการวิเคราะห์ MNL และ ML 19
3.3	พื้นที่ที่ทำการศึกษา 21
3.4	กรอบแนวคิด SEM ตามทฤษฎี TPB..... 23
3.5	กรอบแนวคิดของ MLR และ ML 24
4.1	แบบจำลองสมการโครงสร้างปัจจัยที่มีอิทธิพลต่อการเลือกรูปแบบการเดินทางของผู้สูงอายุใน เมืองภูมิภาคของประเทศไทย 40
4.2	Feature Importance of CatBoost..... 49
4.3	SHAP Interaction Plot..... 49
4.4	SHAP Contribution by Mode – Car..... 50
4.5	SHAP Contribution by Mode - Bus 50
4.6	SHAP Contribution by Mode – Rail 51
4.7	SHAP Contribution by Mode - Paratransit..... 51

บทที่ 1

บทนำ

1.1 ความสำคัญและที่มาของปัญหา

กระแสการเปลี่ยนแปลงกำลังส่งผลกระทบต่อสังคมโลกในปัจจุบันในหลายมิติกำลังก่อตัวขึ้นเป็นแนวโน้มสำคัญในอนาคต ซึ่งหนึ่งในแนวโน้มที่หลีกเลี่ยงได้ยาก คือ การเพิ่มขึ้นของประชากรสูงวัยทั่วโลก โดยผลพวงจากเหตุการณ์ดังกล่าวก่อให้เกิดการเปลี่ยนผ่านในระบบสังคม เสถียรภาพด้านเศรษฐกิจและการดำเนินงานด้านโครงสร้างพื้นฐานที่ดำเนินโดยภาครัฐ ทำให้เกิดความจำเป็นที่เร่งด่วนและจำเป็นต้องมีการกำหนดแนวทาง ในการเตรียมการในด้านอื่น ๆ อย่างละเอียดเพื่อรองรับการเปลี่ยนแปลงทางประชากรอย่างมีระบบและประสิทธิภาพ ในปี 2562 ประชากรโลก มีจำนวนทั้งหมด 7,713 ล้านคน และได้เพิ่มเป็น 9,700 ล้านคน ในปี 2050 โดยมีประชากรอายุ 60 ปี เป็นสัดส่วนร้อยละ 13 (หรือประมาณ 1,000 ล้านคน) และคาดการณ์ว่าภายในปี ค.ศ. 2050 ประชากรที่อายุมากกว่า 65 ปี จะเพิ่มขึ้นเป็นสองเท่า จากปี 2019 (คาดว่าจะมีผู้สูงอายุที่อายุเกิน 65 ปี มากกว่า 1,500 ล้านคน) สำหรับภูมิภาคอาเซียน ในปี 2562 มีประเทศที่เป็นสังคมสูงวัยแล้ว 4 ประเทศ ได้แก่ ไทย สิงคโปร์ เวียดนาม และมาเลเซีย โดยในไทยเป็นประเทศที่ถือว่าสัดส่วนผู้สูงอายุกำลังขยายตัวเพิ่มมากขึ้นในระยะเวลาไม่นาน อย่างไรก็ตามการเพิ่มของประชากรสูงวัย ทำให้ความต้องการของสินค้าและบริการจำเป็นที่ต้องตอบสนองต่อสังคมสูงวัยมากขึ้น ดังนั้นจึงเป็นโอกาสสำหรับการพัฒนาอุตสาหกรรมที่เกิดขึ้นเพื่อรองรับตลาดสังคมสูงวัยที่มีแนวโน้มการเติบโตอย่างต่อเนื่อง เช่น กิจกรรมที่ให้บริการด้านสุขภาพ ศูนย์บริการดูแล บริการทางการแพทย์ รวมถึงระบบขนส่งสาธารณะที่รองรับต่อสังคมสูงวัย (สำนักงานสภาพัฒนาการเศรษฐกิจและสังคมแห่งชาติ, 2022)



รูปที่ 1.1 การเปลี่ยนแปลงโครงสร้างประชากรของโลก

หมายเหตุ จาก WHO (World Health Organization) (2015)

ปัจจุบันในประเทศไทยผู้สูงอายุที่ยังสุขภาพดียังสามารถใช้ชีวิตประจำวันร่วมกับกิจกรรมทางสังคม พบแพทย์ตามบ้าน หรือท่องเที่ยวด้วยตนเอง โดยการเดินทางของผู้สูงอายุจะเลือกใช้ทั้งรถส่วนบุคคลและใช้บริการขนส่งมวลชน จึงเป็นสิ่งที่น่าสนใจว่าประเทศไทยมุ่งเน้นการพัฒนาด้านการบริการขนส่งมวลชน โดยข้อดีของผู้สูงอายุ คือ การมีเวลาท่องเที่ยวมากกว่าวัยอื่น ๆ หากประชากรสูงวัยที่ไม่มีความเจ็บป่วย มีภาวะสุขภาพที่ดี ประชากรสูงวัยในสังคมไทยจะไม่อยากเดินทางโดยลำพัง เพียงแต่ระบบขนส่งมวลชนในปัจจุบันไม่ค่อยเอื้ออำนวยและขาดความปลอดภัยต่อประชากรสูงวัยเท่าที่ควร หากมีระบบขนส่งมวลชนที่ปลอดภัย จะสามารถเห็นประชากรสูงวัยสามารถเดินทางคนเดียวได้อย่างมั่นใจมากขึ้น เมื่อพิจารณาถึงระบบขนส่งมวลชนของไทยยังขาดการสนับสนุนการบริการคนกลุ่มนี้ที่จะก้าวขึ้นมาเป็นประชากรกลุ่มใหญ่ในอนาคต จึงเป็นเรื่องที่หลายฝ่ายต้องวางแผนและสนับสนุนให้ทั่วถึงเพื่อพัฒนาคุณภาพชีวิตผู้สูงอายุ (อารียา สุขโต, 2021)

ประชากรสูงวัยยังคงมองว่าระบบขนส่งในตอนนี้ยังไม่เอื้อกับการใช้งานอย่างแท้จริง ทำให้การเดินทางในชีวิตปกติเป็นเรื่องยากลำบาก และส่งผลให้คุณภาพชีวิตถดถอยลงในหลายมิติ ทั้งด้านสุขภาพกาย และการมีปฏิสัมพันธ์ในบริบทของสังคม ดังนั้นการปรับปรุงระบบขนส่งสาธารณะด้วยคุณภาพการบริการและความปลอดภัยที่ดีขึ้นจะช่วยดึงดูดลูกค้าสูงอายุและปรับปรุงคุณภาพชีวิต การเลือกรูปแบบการขนส่งเป็นสิ่งที่เอื้อต่อการเดินทางถึงจุดหมายอย่างมีประสิทธิภาพ โดยทั่วไปโหมดของผู้ใช้หรือการเลือกเส้นทางจะขึ้นอยู่กับความเหมาะสม เช่น ราคา เวลาเดินทางทั้งหมดต่อโหมด ความสะดวกหรือคุณภาพ การเลือกใช้บริการขนส่งในประเทศไทยนั้นจะมีหลายประเภท ทั้งรถจักรยานยนต์ รถยนต์ รถบัส รถไฟ และระบบขนส่งทางน้ำ จากการศึกษาพบว่า ลักษณะหรือแนวโน้มการใช้บริการขนส่งสาธารณะประเภทต่างๆ ของประชากรสูงวัยมีลักษณะที่ต่างกันในภูมิภาคของประเทศไทย ซึ่งเกิดจากระดับบริการที่ได้รับในแต่ละพื้นที่ ผู้สูงอายุจำนวนมากยึดติดกับรูปแบบการขนส่งเดียวกันและไม่ชอบการเปลี่ยนแปลงเนื่องจากความคุ้นเคยนิสัยหรือข้อจำกัดบางประการ อย่างไรก็ตามในประเทศที่พัฒนาแล้ว การขยายทางเลือกของรูปแบบการเดินทางทำให้การแข่งขันในหมู่ผู้ให้บริการทวีความรุนแรงขึ้น เพื่อเสริมสร้างคุณภาพของบริการขนส่ง และสนับสนุนให้ประชากรสูงวัยสามารถเข้าถึงทางเลือกสำหรับการเดินทางที่ตอบโจทย์ ซึ่งจะก่อให้เกิดการส่งเสริมคุณภาพชีวิตในอนาคต การศึกษานี้จึงมีจุดมุ่งหมายเพื่อหาปัจจัยที่มีอิทธิพลต่อความตั้งใจของประชากรสูงวัยด้านการใช้บริการขนส่งมวลชนระดับภูมิภาค การเปรียบเทียบโหมดที่เลือก ตัวเลือกโหมดทางเลือก (เช่น รถยนต์ รถบัส รถไฟหรือรถขนส่งกึ่งสาธารณะ) จะเปิดเผยบทบาทสำคัญของประเด็นสำคัญ เช่น เวลาต้นทุนการเดินทาง ความสะดวกในการใช้บริการ และมาตรการความปลอดภัยของแต่ละโหมด โดยผู้ที่มีอายุมากกว่าอาจมีวัตถุประสงค์หรือเหตุผลในการใช้โหมดที่แตกต่างกัน ผลลัพธ์ของแบบจำลองอาจช่วยส่งเสริมแก่ผู้ให้บริการในการปรับปรุงบริการของตนสำหรับส่วนแบ่งการตลาดที่แข่งขันกัน

1.2 วัตถุประสงค์งานวิจัย

- 1) เพื่อพัฒนาแบบจำลองสมการโครงสร้างปัจจัยที่มีอิทธิพลต่อความตั้งใจของผู้สูงอายุในการใช้บริการขนส่งสาธารณะในเมืองภูมิภาคตามกรอบทฤษฎีพฤติกรรมตามแบบแผน
- 2) เพื่อเปรียบเทียบพัฒนาแบบจำลองการเลือกรูปแบบการเดินทางของผู้สูงอายุในเมืองภูมิภาคด้วยวิธีการวิเคราะห์ความถดถอยโลจิสติกพหุกลุ่ม (Multinomial Logistic Regression) และการเรียนรู้ของเครื่อง (Machine Learning)

1.3 ขอบเขตของงานวิจัย

จะศึกษาการให้บริการขนส่งมวลชนของกลุ่มประชากรสูงวัย โดยเน้นกลุ่มตัวอย่างบุคคลอายุ 60 ปีขึ้นไปในประเทศไทย การสำรวจจะครอบคลุมพื้นที่ใน 4 ภูมิภาคหลักของประเทศไทย ดังนี้ 1. ภาคเหนือมีจังหวัดหลักได้แก่ จังหวัดเชียงราย เชียงใหม่ สุโขทัยและพิษณุโลก 2.ภาคตะวันออกเฉียงเหนือมีจังหวัดหลักได้แก่ จังหวัดนครราชสีมา ขอนแก่น อุบลราชธานีและอุดรธานี 3. ภาคกลางมีจังหวัดหลักได้แก่ จังหวัดชลบุรี นครสวรรค์ อุทัยและประจวบคีรีขันธ์ 4.ภาคใต้มีจังหวัดหลักได้แก่ จังหวัดนครศรีธรรมราช สงขลา สุราษฎร์ธานีและภูเก็ต เป็นต้น โดยแบ่งเก็บข้อมูล 4 ภาค เก็บภาคละ 250 ตัวอย่าง ดังนั้นชุดตัวอย่างทั่วทั้งประเทศไทย จึงทำการเก็บข้อมูล $250 \times 4 = 1,000$ ตัวอย่าง

1.4 คำถามงานวิจัย

- 1) ปัจจัยใดบ้างที่มีอิทธิพลต่อความตั้งใจของผู้สูงอายุในการใช้บริการขนส่งสาธารณะในเมืองภูมิภาคตามกรอบทฤษฎีพฤติกรรมตามแบบแผน
- 2) ปัจจัยใดบ้างที่มีอิทธิพลต่อการเลือกรูปแบบการเดินทางของผู้สูงอายุในเมืองภูมิภาค

1.5 ประโยชน์ที่คาดว่าจะได้รับ

- 1) แผนนโยบายในการบริการขนส่งสาธารณะสำหรับประชากรสูงอายุสามารถแสดงให้เห็นถึงปัจจัยที่สำคัญและให้การสนับสนุนแก่ผู้ให้บริการเพื่อเสริมสร้างมาตรฐานการให้บริการและมาตรการความปลอดภัยให้กับผู้โดยสารสูงอายุ
- 2) ความแตกต่างระหว่างรูปแบบการเดินทางสภาพแวดล้อม นโยบายการขนส่ง และกลยุทธ์ธุรกิจในพื้นที่มีความแตกต่างกันอย่างสังเกตเห็นได้ ด้วยเหตุนี้การระบุปัจจัยที่มีบทบาทต่อความตั้งใจของประชากรสูงวัยอาจเผยให้เห็นถึงข้อมูลสำคัญบางประการ
- 3) การระบุทัศนคติของประชากรสูงวัยต่อการใช้บริการขนส่งสาธารณะที่ยั่งยืน เพื่อช่วยเสริมสร้างประสิทธิภาพขององค์กรที่เกี่ยวข้องในการมีข้อมูลอ้างอิงสำหรับการบริหารนโยบายพร้อมทั้งให้คำแนะนำสำหรับการส่งเสริมพัฒนาบริการขนส่งที่ยั่งยืน

บทที่ 2

ทบทวนวรรณกรรมและงานวิจัยที่เกี่ยวข้อง

บทที่ 2 ครอบคลุมการรวบรวมองค์ความรู้จากแนวคิด องค์ความรู้จากทฤษฎีและวรรณกรรม ก่อนหน้าที่คล้ายกัน เพื่อสร้างรากฐานทางวิชาการที่ชัดเจนในการออกแบบการศึกษา โดยมุ่งพัฒนา แบบจำลองที่ตรงกับเป้าประสงค์ในงานนี้และสอดคล้องกับหลักวิชาการ

2.1 การเลือกรูปแบบการเดินทาง

การเลือกโหมดการเดินทาง คือกระบวนการที่ใช้พิจารณาทางเลือกด้านการคมนาคมจากจาก ต้นทางถึงปลายทาง โดย “วิธีการเดินทาง” สามารถสื่อถึงประเภทของการเดินทางต่าง ๆ อาทิ การใช้ รถส่วนบุคคล ระบบขนส่งมวลชน การสัญจรทางเท้า การใช้จักรยานในการสัญจร หรือรูปแบบอื่น ๆ ทั้งนี้ความนิยมในแต่ละโหมดสามารถดูได้จากลักษณะขององค์ประกอบพื้นฐานที่เอื้ออำนวยต่อการคมนาคมเป็นหลัก เมื่อมีการระบุเส้นทางของการเดินทางไว้อย่างชัดเจน ตัวเลือกของโหมดที่ใช้เป็นผล จากรูปแบบของการคมนาคมนั้น ๆ ซึ่งมีต้นทางและปลายทางที่กำหนดไว้แล้ว (Rossi & Bhat, 2014) ปัจจัยที่เกี่ยวกับทางเลือกวิธีการคมนาคมสามารถจำแนกได้เป็นสองกลุ่มหลัก ได้แก่ ปัจจัยด้านผู้ เดินทาง เช่น ลักษณะส่วนบุคคลกับสถานภาพทางสังคม และปัจจัยด้านการเดินทาง เช่น ลักษณะเฉพาะของโหมดที่เลือกใช้สามารถเข้าถึงได้โดยง่าย

ลักษณะผู้เดินทาง (สังคม-ประชากร ทัศนคติ การรับรู้ รูปแบบการใช้ชีวิต) โดยลักษณะของ นักเดินทางแต่ละคนส่งผลต่อแนวโน้มการเลือกประเภทการเดินทางของผู้ใช้บริการ ซึ่งรวมถึงลักษณะ ที่สังเกตได้ เช่น อายุ เพศ สถานะใบขับขี่ หรือสถานะของพนักงานหรือนักเรียน และลักษณะที่ไม่ได้ รับการสังเกต เช่น ความตระหนักในทางเลือกของการขนส่ง การพิจารณารูปแบบเฉพาะ ทัศนคติ และความชอบส่วนบุคคล ลักษณะครัวเรือนของนักเดินทาง เช่น ฐานะฐานะทางการเงินและความ พร้อมของยานพาหนะ อาจมีบทบาทต่อการเลือกโหมด

ความพร้อมใช้งานและลักษณะเฉพาะของรูปแบบการเดินทาง ซึ่งแน่นอนว่าสำหรับโหมดที่ จะเลือกนั้น นักเดินทางจะต้องสามารถใช้ได้ ความพร้อมใช้งานอาจไม่สามารถกำหนดได้ชัดเจนเสมอ ไป ตัวอย่างเช่น โดยทั่วไปโหมดคนขับอัตโนมัติจะไม่สามารถใช้ได้สำหรับเด็กเล็ก แต่อาจไม่สามารถ ใช้ได้กับผู้พิการ ผู้ที่ไม่มีใบขับขี่หรือบุคคลที่ไม่มียานพาหนะ บางครั้งลักษณะเหล่านี้ อาจไม่สามารถ สังเกตได้ เช่น บุคคลที่ไม่มีรถยนต์ในครัวเรือนอาจยังสามารถยืมหรือเช่ารถยนต์หรือใช้บริการรถร่วม ได้ โดยทั่วไป ไม่มีข้อจำกัดสำหรับนักเดินทางในการเป็นผู้โดยสารรถยนต์ โหมดผู้ขับขี่อัตโนมัติอาจถูก

จำกัดไว้เฉพาะผู้ที่มีสิทธิ์ขับขี่ได้ เช่น บุคคลที่อายุเกินกฎหมายในการขับขี่ และบางที่อาจเป็นผู้ที่ถือใบอนุญาตขับขี่ หากคุณลักษณะดังกล่าวได้รับการจำลองในโมเดล มีแนวโน้มที่จะส่งผลมากกว่าที่คุณลักษณะนี้จะเป็นที่รู้จักในแบบจำลองตามกิจกรรมแบบแยกส่วนมากกว่าแบบจำลองแบบรวมตามครัวเรือน

อย่างไรก็ตามแล้วจะไม่มีจำกัดความพร้อมใช้งานของรูปแบบการขนส่งสาธารณะ อย่างไรก็ตาม อาจไม่มีเส้นทางการขนส่งสาธารณะที่เหมาะสมสำหรับการผสมผสานระหว่างต้นทางและปลายทาง เป็นเรื่องปกติที่จะแยกโหมดการขนส่งสาธารณะออกเป็นโหมดที่มีทางเข้าแบบเดินเท้า/ทางออกที่ฝั่งบ้าน และประเภทที่มีทางเข้า/ออกอัตโนมัติ โหมดการเข้าถึงแบบเดินเท้ามักประสบกับข้อจำกัดความยาวการเดินทางสูงสุด คล้ายกับที่ใช้สำหรับโหมดการเดิน และดังนั้นจึงอาจมีการผสมผสานระหว่างต้นทางและปลายทางที่ไม่มีเส้นทางการขนส่งสาธารณะที่ถูกต้อง (เช่น หากต้นทางไม่อยู่ภายในความยาวสูงสุด ระยะเดินเท้าจากป้ายขนส่งสาธารณะ) ตามทฤษฎีแล้ว ไม่มีการจำกัดระยะการเข้าถึงอัตโนมัติ อย่างไรก็ตาม อาจมีอุปสรรคในการปฏิบัติที่กำหนดไว้ในบางรุ่น โดยทั่วไปโหมดการขนส่งสาธารณะจะถือว่าพร้อมใช้งานหาก กระบวนการ สร้างเส้นทางการขนส่งสาธารณะสามารถค้นหาเส้นทางที่ถูกต้องจากต้นทางไปยังปลายทางได้

2.2 ทฤษฎีพฤติกรรมตามแผน (Theory of planned behavior)

ทฤษฎีพฤติกรรมตามแผน (Theory of planned behavior - TPB) เป็นทฤษฎีใช้ทำนายพฤติกรรม ได้รับความนิยมในงานวิจัยด้านพฤติกรรม (Ajzen, 1991); (Armitage & Conner, 2001) อ้างถึงใน : Judge, Warren-Myers และ Paladino, 2019) ตามแนวคิดทฤษฎีพฤติกรรม ความตั้งใจในการกระทำเป็นปัจจัยที่สะท้อนการกระทำจริงได้ใกล้เคียงที่สุด (Judge, et al., 2019) ทำให้ทฤษฎีนี้เป็นประโยชน์ต่อการพยากรณ์และอธิบายความตั้งใจกับแสดงพฤติกรรมจริงช่วยให้เข้าใจตัวกำหนดจิตใจของมนุษย์และการแสดงพฤติกรรมของมนุษย์ (P. Vanichkitpisan, C. Temiyasathit, 2017)

การแสดงพฤติกรรมของบุคคลมักเกิดขึ้นภายใต้กระบวนการวางแผนล่วงหน้า ซึ่งแสดงออกผ่าน “ความตั้งใจ” อันเป็นการตระหนักถึงโอกาสของการกระทำหรือไม่กระทำพฤติกรรมนั้นในอนาคต ความตั้งใจจึงถือเป็นการแสดงถึงความพร้อมของบุคคลในการกระทำพฤติกรรมใดพฤติกรรมหนึ่ง ก่อนพฤติกรรมจริงเกิดขึ้น โดยรวมแล้ว ‘ความตั้งใจ’ มีบทบาทอย่างยิ่งในการกำหนดการแสดงพฤติกรรมของบุคคล (ปริยาภรณ์ ประยงค์กุล และสุจรรยา โลหาชีวะ, 2563) (ทรรศนันทน์ ทิมทอง, 2022) ทั้งนี้ ความตั้งใจสามารถทำนายได้จากปัจจัยสำคัญ 3 ประการ ตามแนวคิด TPB ซึ่งแสดงในภาพที่ 2.1 ประกอบด้วย

1) ทศคติที่มีต่อพฤติกรรม (Attitude Toward the Behavior)


Ajzen (1991) อธิบายว่า ทศคติที่มีต่อพฤติกรรม หมายถึง การรับรู้และการประเมินของบุคคลต่อพฤติกรรมหนึ่ง ๆ ว่าตนมีความชอบหรือไม่ชอบเพียงใด หรือเป็นการประเมินคุณค่าและผลกระทบของพฤติกรรมดังกล่าว ซึ่งทศคติในเชิงบวกหรือเชิงลบต่อพฤติกรรมจะส่งผลต่อความตั้งใจที่จะลงมือกระทำ

2) การคล้อยตามกลุ่มอ้างอิง (Subjective Norm)

Ajzen (1991) อธิบายว่า การคล้อยตามกลุ่มอ้างอิงว่า หมายถึง การรับรู้ของบุคคลถึงแรงกดดันทางสังคม ที่ส่งผลต่อการแสดงหรือไม่แสดงพฤติกรรมใดพฤติกรรมหนึ่ง กล่าวคือ บุคคลจะพิจารณาว่าคนรอบข้างที่ตนให้ความสำคัญ เช่น ครอบครัว เพื่อน หรือสังคมโดยรวม คาดหวังให้ตนกระทำหรือหลีกเลี่ยงพฤติกรรมนั้นหรือไม่ ซึ่งความคาดหวังนี้ส่งผลโดยตรงต่อความตั้งใจของบุคคลในการเลือกแสดงพฤติกรรม

3) การรับรู้ถึงการควบคุมพฤติกรรมของตนเอง (Perceived Behavioral Control)

Ajzen (1991) อธิบายว่า การรับรู้ถึงการควบคุมพฤติกรรมของตนเอง หมายถึง ระดับการรับรู้ของบุคคลเกี่ยวกับศักยภาพหรือข้อจำกัดของตนเองในการดำเนินพฤติกรรมใดพฤติกรรมหนึ่ง โดยการรับรู้นี้อาจได้รับอิทธิพลจากพฤติกรรมที่ผ่านมา รวมถึงปัจจัยที่อำนวยความสะดวกต่อการกระทำพฤติกรรม การตระหนักว่าตนเองมีศักยภาพหรือทรัพยากรเพียงพอในการควบคุมพฤติกรรม ซึ่งมีผลต่อความตั้งใจและสามารถทำนายถึงความเป็นไปได้ในการแสดงพฤติกรรมได้อย่างชัดเจน



รูปที่ 2.1 รูปแบบจำลองทฤษฎีการยอมรับนวัตกรรมและเทคโนโลยี

หมายเหตุ จาก Ajzen (1991)

2.3 การทดสอบความเที่ยงตรงของเครื่องมือการวิจัย

ความเที่ยงตรงของเครื่องมือการวิจัยสามารถตรวจสอบได้จากความเชื่อมั่นของปัจจัย (Construct Reliability: CR) และค่าเฉลี่ยของความแปรปรวนที่ถูกสกัดได้ (Variance Extracted score: AVE) สามารถคำนวณได้จาก สมการ (1) และ (2) ตามลำดับ

ค่าความเชื่อมั่นองค์ประกอบ (Composite Reliability: CR) สามารถเขียนในรูปสมการ ดังนี้ (Fornell & Larcker, 1981)

$$CR = \frac{(\sum_{i=1}^n \beta_i)^2}{(\sum_{i=1}^n \beta_i)^2 + (\sum_{i=1}^n \delta_i)^2} \quad 2-1$$

เมื่อ β คือ ค่าน้ำหนักองค์ประกอบ (factor loading)

δ คือ ค่าความแปรปรวนจากความคลาดเคลื่อน (error variance)

โดยค่าความเชื่อมั่นของปัจจัย (CR) ที่มากกว่า 0.7 ขึ้นไปแสดงว่ามีความเชื่อมั่นที่ยอมรับได้ (HAIR JUNIOR et al., 1998)

ค่าเฉลี่ยของความแปรปรวนที่ถูกสกัดได้ (Average Variance Extracted: AVE) สามารถเขียนในรูปสมการ ดังนี้ (Fornell & Larcker, 1981)

$$AVE = \frac{(\sum_{i=1}^n \beta_i)^2}{n} \quad 2-2$$

เมื่อ β คือ ค่าน้ำหนักองค์ประกอบ (factor loading)

δ คือ ค่าความแปรปรวนจากความคลาดเคลื่อน (error variance)

n คือ จำนวนองค์ประกอบที่พิจารณา

โดยค่าเฉลี่ยของความแปรปรวนที่ถูกสกัดได้ (AVE) ควรมากกว่า 0.5 (HAIR JUNIOR et al., 1998) และค่า AVE ที่มากกว่า R^2 สามารถตรวจสอบความถูกต้องของแบบจำลองการวัดได้ (Fornell & Larcker, 1981)

2.4 การวิเคราะห์การวิเคราะห์องค์ประกอบเชิงยืนยัน

การวิเคราะห์ CFA การประมาณค่าแบบ maximum likelihood (ML) ถูกนำมาเพื่อทดสอบความเหมาะสมของแบบจำลองกับตัวชี้วัดความเหมาะสมของแบบจำลองในการวิเคราะห์ปัจจัยยืนยัน (Goodness of fit indices in CFA models) ของปัจจัยต่าง ๆ ที่ถูกนำมาทดสอบ ประกอบด้วย ดังนี้

ค่าสถิติไค-สแควร์ (Chi-Square Statistics: χ^2) เป็นค่าดัชนีที่ใช้ตรวจสอบความสอดคล้องกลมกลืนระหว่างแบบจำลองกับข้อมูลเชิงประจักษ์ในภาพรวม สามารถคำนวณได้จากสมการ 2-3

$$\chi^2 = (N - 1)(s - \Sigma\theta) \quad 2-3$$

โดยที่ กำหนดให้ N คือ จำนวนของตัวแปร

s คือ เมทริกซ์ความแปรปรวนร่วมของตัวแปรสังเกตได้ (observed covariance matrices)

$\Sigma\theta$ คือ เมทริกซ์ความแปรปรวนร่วมของการประมาณค่า (estimated covariance matrices)

ค่าองศาอิสระ (Degree of freedom: df) เป็นข้อมูลทางคณิตศาสตร์ที่แสดงถึงการประมาณค่าพารามิเตอร์ โดยค่า df สามารถคำนวณได้จากสมการ 2-4

$$df = \frac{N(N+1)}{2} - NP \quad 2-4$$

โดยที่ กำหนดให้ N คือ จำนวนตัวแปรสังเกตได้ในแบบจำลอง

NP คือ จำนวนพารามิเตอร์ที่ต้องประมาณค่า

ค่าอัตราส่วนไคสแควร์กับองศาอิสระ (chi-square/degree of freedom: χ^2/df) (Normed Chi-square หรือ Relative Chi-square) เป็นการนำค่าไคสแควร์หารด้วยองศาอิสระ ($\frac{\chi^2}{df}$) เป็นการวัดระดับความสอดคล้องระหว่างแบบจำลองกับข้อมูลเชิงประจักษ์ ควรน้อยกว่า 5 (Wheaton, 1977)

ค่าดัชนีรากที่สองของส่วนเหลือกำลังสองเฉลี่ยมาตรฐาน (Standardized Root Mean Square Residual: SRMR) เป็นดัชนีที่ใช้เปรียบเทียบระดับความกลมกลืนกับข้อมูลเชิงประจักษ์ (เฉพาะกรณีที่เป็นการเปรียบเทียบโดยใช้ข้อมูลชุดเดียวกัน) มีค่าอยู่ระหว่าง 0 ถึง 1 ยิ่งเข้าใกล้ศูนย์ แสดงว่าแบบจำลองมีความกลมกลืนกับข้อมูลเชิงประจักษ์ หากค่า SRMR ต่ำกว่า 0.08 ลงไป นั้นหมายความว่า แบบจำลองมีความกลมกลืนกับข้อมูลเชิงประจักษ์ (Steiger, 2007)

ค่าดัชนีรากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยโดยประมาณ (Root Mean Square Error of Approximation: RMSEA) เป็นการวัดความแตกต่างต่อหน่วยขององศาอิสระ โดยที่ Tabachnick et al. (2013) เสนอว่าค่า RMSEA ควรน้อยกว่าหรือเท่ากับ 0.08 แสดงว่าแบบจำลองมีความสอดคล้องกับข้อมูลเชิงประจักษ์ สามารถคำนวณได้จากสมการ 2-5

$$RMSEA = \sqrt{\frac{(\chi^2 - df)}{N - 1}} \quad 2-5$$

ค่าดัชนีทักเกอร์-ลูวิส (Tucker-Lewis Index: TLI) แสดงสัดส่วนความแตกต่างระหว่าง χ^2 สำหรับแบบจำลองเฉพาะ (specific model) และแบบจำลองเริ่มต้น (null model) ซึ่งถูกหารด้วยค่า χ^2 ของแบบจำลองเริ่มต้น TLI มีค่าระหว่าง 1 ถึง 0 โดยค่า TLI ที่มากกว่า 0.8 ขึ้นไปเป็นค่าที่ยอมรับได้ว่าแบบจำลองเป้าหมายมีความกลมกลืนดีกว่าแบบจำลองเริ่มต้น (D Hooper et al., 2008) สามารถคำนวณได้จากสมการ 2-6

$$TLI = \frac{\left(\frac{\chi_B^2}{df_B}\right) - \left(\frac{\chi_T^2}{df_T}\right)}{\left(\frac{\chi_B^2}{df_B}\right) - 1} \quad 2-6$$

โดยที่ df_B และ df_T คือ degrees of freedom สำหรับแบบจำลองเริ่มต้น (Based model) และ สมมติฐานของแบบจำลองเป้าหมาย (Target model) ตามลำดับ

ค่าดัชนีวัดระดับความกลมกลืนเปรียบเทียบ (Comparative Fit Index: CFI) คล้ายกับ TLI คือ เป็นการเปรียบเทียบระหว่างเมทริกซ์ความแปรปรวน ความแปรปรวนร่วมของแบบจำลองที่ทุกตัวแปรไม่สัมพันธ์กันกับเมทริกซ์ความแปรปรวน ความแปรปรวนร่วมของแบบจำลองเป้าหมายซึ่ง CFI มีค่าระหว่าง 0 ถึง 1 โดยที่ (L. t. Hu & P. M. Bentler, 1999) เสนอไว้ว่าหากค่า CFI มากกว่า 0.95 ขึ้นไป แสดงว่าแบบจำลองนั้น ๆ มีความกลมกลืนที่ยอมรับได้ CFI สามารถคำนวณได้จากสมการ 2-7

$$CFI = \frac{\max[(x_T^2 - df_T), 0]}{\max[(x_T^2 - df_T), (x_B^2 - df_B), 0]} \quad 2-7$$

ในงานวิจัยนี้ตรวจสอบความกลมกลืนระหว่างทฤษฎีกับข้อมูลเชิงประจักษ์จากค่าสถิติที่กล่าวมาข้างต้น ได้แก่ ค่าอัตราส่วนไคสแควร์กับองศาอิสระ (χ^2/df) ค่าดัชนีรากที่สองของส่วนเหลือกำลังสองเฉลี่ยมาตรฐาน (SRMR) ค่าดัชนีรากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ยโดยประมาณ (RMSEA) ค่าดัชนีทักเกอร์-ลูวิส (TLI) และค่าดัชนีวัดระดับความกลมกลืนเปรียบเทียบ (CFI) สามารถสรุปเกณฑ์การพิจารณาที่เป็นจุดตัด (cutoff-value) ของค่าดัชนีวัดความกลมกลืนที่ยอมรับได้ ดังแสดงในตารางที่ 2.1

ตารางที่ 2.1 เกณฑ์การพิจารณาที่เป็นจุดตัดของค่าดัชนีวัดความกลมกลืนที่ยอมรับได้

ค่าดัชนี	Cutoff-value	ที่มา
chi-square/degree of freedom (χ^2/df)	< 5	(Wheaton, 1977)
Standardized Root Mean Square Residual (SRMR)	≤ 0.08	(Steiger, 2007)
Root Mean Square Error of Approximation (RMSEA)	≤ 0.08	(Tabachnick et al., 2013)
Tucker-Lewis Index (TLI)	≥ 0.8	(D Hooper et al., 2008)
Comparative Fit Index (CFI)	≥ 0.95	(L. t. Hu & P. M. Bentler, 1999)

จากตารางที่ 2.1 แสดงเกณฑ์ที่ใช้ในการพิจารณาความสอดคล้องของแบบจำลองตามสมมติฐานกับข้อมูลเชิงประจักษ์ ในการวิเคราะห์หองค์ประกอบเชิงยืนยัน (Confirmatory Factor Analysis: CFA) โดยพิจารณาจากตัวชี้วัดดังนี้ อัตราส่วนไคสแควร์ต่อองศาอิสระ (χ^2/df : χ^2/df) ควรมีค่าน้อยกว่า 5 (Wheaton et al., 1977) ดัชนีเปรียบเทียบความกลมกลืน (Comparative Fit Index :CFI) ควรมีค่ามากกว่า 0.95 (L.-t. Hu & P. M. Bentler, 1999) ดัชนี Tucker-Lewis Index (TLI) ควรมีค่ามากกว่า 0.80 (D Hooper et al., 2008) ดัชนีรากที่สองของค่าเฉลี่ยกำลังสองของการประมาณค่าความคลาดเคลื่อน (Root Mean Square Error of

Approximation: RMSEA) ควรมีค่าน้อยกว่าหรือเท่ากับ 0.08 (Tabachnick et al., 2013) และดัชนีรากของค่าเฉลี่ยกำลังสองของส่วนเหลือมาตรฐาน (Standardized Root Mean Square Residual: SRMR) ควรมีค่าน้อยกว่าหรือเท่ากับ 0.08 (Steiger, 2007)

2.5 การวิเคราะห์การถดถอยโลจิสติกพหุกลุ่ม (Multinomial logistic regression analysis)

การวิเคราะห์นี้เป็นเครื่องมือทางสถิติใช้สำหรับพยากรณ์โอกาสของการเกิดเหตุการณ์ใด เหตุการณ์หนึ่งในกรณีที่ตัวแปรตามเป็นตัวแปรเชิงจัดประเภท (categorical) ที่มีมากกว่าสองกลุ่ม โดยจะวิเคราะห์ความสัมพันธ์ระหว่างตัวแปรตามกับตัวแปรอิสระ เพื่อคำนวณความน่าจะเป็นของผลลัพธ์แต่ละกลุ่ม เมื่อมีการกำหนดค่าตัวแปรทำนายไว้ล่วงหน้า ประเภทของการถดถอยที่เกี่ยวข้องกับข้อมูลลักษณะนี้สามารถจำแนกได้ 3 ลักษณะ ได้แก่

- 1) Binary Logistic Regression สำหรับกรณีที่ตัวแปรตามมีเพียงสองค่า
- 2) Ordinal Logistic Regression เมื่อข้อมูลมีการจัดลำดับได้
- 3) Multinomial Logistic Regression สำหรับข้อมูลหลายกลุ่มโดยไม่มีลำดับ

การประยุกต์ใช้ MLR มีข้อกำหนดเบื้องต้นที่สำคัญ ได้แก่

1) ตัวแปรตามควรเป็นตัวแปรเชิงคุณภาพในระดับมาตรา Nominal ซึ่งมีจำนวนหมวดหมู่มากกว่าสองค่า โดยลักษณะของกลุ่มอาจแตกต่างกันตามวัตถุประสงค์ของแต่ละการศึกษา เช่น แบ่งออกเป็น 3 กลุ่ม 5 กลุ่ม หรือ 7 กลุ่ม สำหรับการศึกษาครั้งนี้แบ่งตัวแปรตามออกเป็น 7 กลุ่ม

2) ตัวแปรทำนาย(X) ควรอยู่ในรูปของตัวแปรเชิงปริมาณชนิดต่อเนื่อง (Continuous Variable) เพื่อให้สอดคล้องกับการวิเคราะห์ด้วยโมเดลถดถอย อย่างไรก็ตาม หากตัวแปรอิสระบางรายการเป็นตัวแปรจัดประเภท (Categorical Variable) จำเป็นต้องเปลี่ยนให้อยู่ในรูปตัวแปรจำลอง หรือ Dummy Variable ก่อนนำเข้าสู่การวิเคราะห์ การใช้ตัวแปรอิสระต้องอยู่ภายใต้เงื่อนไขที่สำคัญคือ ความสัมพันธ์ระหว่างตัวแปรไม่ควรเกินระดับที่ทำให้เกิดปัญหา Multicollinearity โดยทั่วไปนิยมใช้เกณฑ์ค่าสหสัมพันธ์ (r) ไม่เกิน .80 ตามข้อเสนอของ Stevens (2002) เพื่อหลีกเลี่ยงการรบกวนกันระหว่างตัวแปร นอกจากนี้ ขนาดของกลุ่มตัวอย่างที่เหมาะสมควรเท่ากับ 30 เท่าขึ้นไปของจำนวนตัวแปรอิสระทั้งหมด ($n \geq 30P$) ซึ่ง P หมายถึงจำนวนตัวแปรทำนาย ทั้งนี้เพื่อให้การประมาณค่าพารามิเตอร์ในโมเดลมีความแม่นยำเพียงพอ (กัลยา วาณิชย์บัญชา, 2015)

3) การประเมินคุณภาพแบบจำลองใน MLR สามารถทำได้โดยการวิเคราะห์ค่าความน่าจะเป็นของการเกิดผลลัพธ์ตามตัวแปรตาม (Y) ผ่านการคำนวณด้วยฟังก์ชันลอการิทึมของค่าความน่าจะเป็น (Log-Likelihood: LL) ซึ่งค่านี้มีความเชื่อมโยงกับค่าความคลาดเคลื่อนของตัวแปรที่คาดการณ์ (Residuals) กล่าวคือ ค่าที่ต่ำของ LL บ่งชี้ถึงแบบจำลองมีความสอดคล้องกับข้อมูลเชิงประจักษ์ได้ดีในระดับที่ยอมรับได้ (Kaiyawan, 2012)

4) ใช้ค่าความน่าจะเป็นของการเกิดเหตุการณ์ (Odds Ratio) ในการแปลผลเป็นหลักหรือค่า EXP(B) โดยมีหลักว่า (Nizami et al., 2017)

4.1) ถ้าOdds Ratio =1 แสดงว่าการเปลี่ยนแปลงของ X ไม่มีผลต่อ Y

4.2) ถ้าOdds Ratio > 1 หมายถึงเมื่อ X เพิ่มขึ้นทำให้โอกาสของระดับความคิดเห็นเพิ่มมากขึ้น(พิจารณาจากค่าร้อยละ) เมื่อเทียบกับค่าเดิมของ X (สัมประสิทธิ์มีค่าเป็นบวก) โดยร้อยละของค่าOdds

$$a. \quad Ratio = \frac{EXP(B)}{1+EXP(B)} \times 100 \quad 2-8$$

4.3) ถ้าOdds Ratio < 1 หมายถึงเมื่อX เพิ่มขึ้นทำให้โอกาสของระดับความคิดเห็นน้อยลง(พิจารณาจากค่าร้อยละ) เมื่อเทียบกับค่าเดิมของX (สัมประสิทธิ์มีค่าเป็นลบ) โดยร้อยละของค่าOdds Ratio = (EXP(B) -1) x 100

2.6 การประยุกต์ใช้ Machine Learning ในการเลือกโหมดการเดินทาง

การเลือกใช้ Machine Learning (ML) ในงานวิเคราะห์การเลือกรูปแบบการเดินทางเพิ่มขึ้นในช่วงหลัง เนื่องจาก ML สามารถจับ ความสัมพันธ์ที่ซับซ้อนและไม่เชิงเส้น (non-linear) ระหว่างตัวแปรจำนวนมากได้อย่างมีประสิทธิภาพกว่าโมเดลเชิงเศรษฐมิติแบบดั้งเดิม เช่น Multinomial Logit (MNL) ที่มีสมมติฐานเชิงเส้นและข้อจำกัดด้าน Structure ก่อนล่วงหน้า การศึกษาโดย Martín-Baos et al. (2023) เปรียบเทียบ MNL กับ XGBoost และ Random Forest พบว่า ML ให้ผลการทำนายระดับรายบุคคล (disaggregate predictive accuracy) สูงกว่า MNL อย่างมีนัยสำคัญ แต่กลับมีตัวบ่งชี้เชิงพฤติกรรม (behavioral indicators) และการประมาณตลาดรวม (aggregate mode shares) ต่ำกว่า งานจาก Wang and Ross (2018) พบว่าเมื่อเทียบ XGBoost กับ MNL บนข้อมูล Delaware Valley XGBoost ให้ความแม่นยำสูงกว่าอย่างชัดเจน (โดยเฉพาะเมื่อข้อมูลไม่ unbalanced) และกว่าในหลายโหมด แม้โมเดล MNL ยังคงความน่าเชื่อถือเชิงสถิติได้ดี ซึ่งสอดคล้องกับข้อดีของ ML ในแง่ predictive capability และความยืดหยุ่นในการใช้ข้อมูล

2.6.1 เทคนิคนิยมในงานเลือกโหมดเดินทาง

โมเดล tree-based ensemble เช่น Random Forest, XGBoost, CatBoost ถูกใช้อย่างแพร่หลาย เนื่องจากจัดการข้อมูล mixed types, missing values หรือ outliers ได้ดี และให้ผลที่เสถียร (Dahmen et al., 2024; Wang & Ross, 2018) นักวิจัยรับรองว่าการรวมผลแบบ ensemble ช่วยลด variance และ overfitting (Breiman, 2001) ในขณะที่ CatBoost สามารถจัดการกับตัวแปรเชิงหมวดหมู่จำนวนมากได้โดยตรง (Prokhorenkova et al., 2018)

2.6.2 การตีความผลจาก ML ด้วย SHAP

ในการวิเคราะห์แบบ Machine Learning การทำความเข้าใจว่าแต่ละตัวแปรมีอิทธิพลอย่างไรต่อผลลัพธ์ของโมเดลนับเป็นสิ่งสำคัญ โดยเฉพาะอย่างยิ่งในกรณีที่ต้องการตีความ

ผลลัพธ์ให้สามารถใช้เป็นแนวทางในการกำหนดนโยบายหรือออกแบบบริการต่าง ๆ ได้อย่างมีประสิทธิภาพ เทคนิค SHAP (SHapley Additive exPlanations) ซึ่งพัฒนาขึ้นโดย Lundberg and Lee (2017) เป็นเทคนิคที่ได้รับความนิยมมากที่สุดสำหรับการอธิบายผลของโมเดล Machine Learning ที่ซับซ้อน โดย SHAP ใช้แนวคิดจากทฤษฎีเกมเพื่อแจกแจง “ค่าคุณสมบัตินี้” หรือ “มูลค่า” ที่ตัวแปรแต่ละตัวมีต่อการทำนายของโมเดล

SHAP มีข้อได้เปรียบที่สำคัญคือสามารถอธิบายผลลัพธ์ของโมเดลแบบ “global” (โดยรวม) และ “local” (ระดับรายบุคคล) ได้อย่างชัดเจน เช่น การวิเคราะห์ SHAP summary plot จะแสดงให้เห็นว่าตัวแปรใดมีผลกระทบสูงสุดต่อการทำนายในภาพรวม และการแสดงค่า SHAP รายบุคคลช่วยให้เข้าใจว่าทำไมโมเดลจึงทำนายค่าหนึ่ง ๆ ให้กับตัวอย่างนั้น

การใช้ SHAP ในการศึกษาช่วยให้เห็นว่า ปัจจัยเช่นค่าใช้จ่ายในการเดินทาง รายได้ และระยะทางมีอิทธิพลอย่างมีนัยสำคัญต่อการเลือกโหมดการเดินทางของผู้สูงอายุ นอกจากนี้ SHAP interaction plot ยังช่วยวิเคราะห์ปฏิสัมพันธ์ระหว่างตัวแปร เช่น รายได้ที่ต่ำเมื่อประกอบกับค่าใช้จ่ายที่สูงส่งผลต่อโอกาสในการใช้บริการขนส่งสาธารณะอย่างไร ซึ่งความสามารถของ SHAP ถือเป็นจุดแข็งในการวิเคราะห์ที่โมเดลสถิติเชิงเส้นอย่าง MNL ไม่สามารถจับความสัมพันธ์ที่ซับซ้อนเช่นนี้ได้อย่างชัดเจน

2.7 งานวิจัยที่เกี่ยวข้อง

Abdullah et al. (2022) ได้ทำการสำรวจปัจจัยที่มีอิทธิพลต่อการเลือกโหมดการเดินทางในช่วงก่อนและระหว่างเกิดการระบาดของโควิด-19 โดยใช้แบบสำรวจซึ่งมี 3 ส่วนหลัก อาทิเช่น (1) ลักษณะทางสังคมและประชากร (2) ปัจจัยที่ส่งผลต่อการเลือกโหมดช่วงก่อนและช่วงระหว่างเกิดเหตุการณ์ ประเภท Likert 5 คะแนน ที่ส่งผลต่อการเลือกโหมดก่อนและช่วงระหว่างเกิดเหตุการณ์ และ (3) การเลือกรูปแบบช่วงเวลาก่อนเกิดและช่วงระหว่างเกิด โดยมีคำถามเกี่ยวกับการเลือกโหมดสำหรับระยะทางที่สั้นกว่า (<5 กม.) และยาวกว่า (>5 กม.) ก่อนและช่วงที่เกิดเหตุการณ์ระบาด โดยใช้การวิเคราะห์ Multinomial logit models ผลชี้ให้เห็นถึงการใชัระบบขนส่งมวลชนลดลงขณะเดียวกันการเดินทาง การปั่นจักรยานในช่วงโควิดมีการเพิ่มขึ้นเล็กน้อย กลุ่มตัวอย่างให้ความสำคัญกับมาตรการความปลอดภัย ความปลอดภัยโรค ความสะดวกสบาย สถานะทางสังคมส่วนบุคคล ความพร้อมของเจลล้างมือ การรอ และการจ่ายเงินมากขึ้นสำหรับยานพาหนะที่แออัดน้อยลงในช่วงการแพร่ระบาด รายได้ต่อเดือนของครัวเรือนและปัจจัยเชิงสาเหตุที่เกี่ยวข้องกับการแพร่ระบาดครั้งใหญ่เป็นตัวพยากรณ์ที่ส่งผลต่อการเลือกโหมดสำหรับระยะที่สั้นกว่า (เช่น < 5 กม.) ในระหว่างการระบาดใหญ่ ในขณะที่เพศ การเป็นเจ้าของรถยนต์ และรายได้ต่อเดือนของครัวเรือนเป็นตัวทำนายสำหรับการเลือกโหมดสำหรับระยะที่ไกลกว่า (เช่น > 5 กม.) ในช่วงที่เกิดโรคระบาด

Ahmed et al. (2021) การวิจัยจะเน้นการศึกษากระบวนการในการเลือกประเภทการเดินทางของบุคคลมีอายุช่วง 18-25 ปี การเดินทางเพื่อทำงานและเข้าเรียนจะเน้นการเปรียบเทียบการใช้รถส่วนบุคคลและระบบขนส่งสาธารณะ โดยใช้ทฤษฎี TPB ในการศึกษาการเลือกรูปแบบ โดยเฉพาะจากมุมมองด้านสังคม-จิตวิทยา ข้อมูลการเดินทางที่ถูกแยกแยะถูกเก็บรวบรวมจากการ

สำรวจลึกลับของนักเดินทางอายุอยู่ในช่วง 18-25 ปี ($n = 3171$) อาศัยอยู่ในเมลเบิร์นชั้นในและมหานคร ประเทศออสเตรเลีย แบบสอบถามถูกออกแบบเพื่อสำรวจข้อมูลเกี่ยวกับทัศนคติของนักเดินทางที่อายุช่วง 18-25 ปี โดยพิจารณาจากรูปแบบการเดินทาง บริบททางสังคมและรูปแบบพฤติกรรมการเดินทาง การใช้ทั้งถดถอยเชิงเส้นและโลจิสติกแบบไบนารีร่วมกันได้รับการใช้เป็นเครื่องมือในการพยากรณ์ความตั้งใจในการเลือกโหมดและการเลือกจริง การศึกษาพบว่า ผู้เดินทางที่ใช้รถส่วนบุคคลมีมุมมองที่เชื่อมั่นต่อโหมดดังกล่าว ในระหว่างที่ผู้ใช้รถบริการขนส่งมวลชนมีความเชื่อว่าการขนส่งสาธารณะมั่นคงมากกว่า แต่พวกเขาไม่เห็นด้วยว่าการขนส่งสาธารณะมีความมั่นคงปลอดภัย

Chang et al. (2019) ได้นำเสนอแนวทางการใช้วิธี Machine Learning เพื่อให้เกิดความเข้าใจมากยิ่งขึ้นที่ส่งผลต่อการเลือกโหมด ซึ่ง Logit Model เป็นวิธีที่ใช้อย่างแพร่หลาย มีข้อจำกัดเนื่องจากต้องพึ่งพาสสมมติฐานที่ว่าสิ่งที่ส่งผลต่อการพิจารณาวิธีการเดินทางเป็นอิสระต่อกัน ซึ่งอาจทำให้เกิดการประมาณค่าพารามิเตอร์ที่ขาดความสอดคล้องและการคาดการณ์ที่มีอคติ เพื่อยกระดับความแม่นยำของการทำนายการพิจารณาทางเลือก ดังนั้นบทความนี้ใช้โมเดลการรวมข้อมูล (Data Fusion Model) ที่อิงตามกลยุทธ์การซ้อน (Stacking Strategy) และเสนอโมเดลแบบผสมที่รวมโมเดลการเรียนรู้แบบไม่มีผู้ควบคุม (Unsupervised) Denoising Autoencoder (DAE) กับการเรียนรู้แบบมีผู้ควบคุม (Supervised) Random Forest (RF) นอกจากนี้ยังได้ทำการจัดอันดับและคัดเลือกคุณลักษณะ (Features) ที่อาจมีผลต่อพฤติกรรมพิจารณาทางเลือกในการเดินทางด้วยวิธีคัดเลือกคุณลักษณะโมเดลที่เสนอ ซึ่งมีความสามารถและประสิทธิภาพสูงในการวิเคราะห์พฤติกรรมเลือกโหมด และมีประสิทธิภาพมากกว่าโมเดลจำแนกประเภทอื่น ๆ ผลการศึกษาอาจประยุกต์ใช้เพื่อทำความเข้าใจและสร้างแบบจำลองการเลือกโหมดการเดินทางได้อย่างเต็มที่

Du et al. (2020) งานนี้ศึกษาปัจจัยที่ส่งผลต่อการเลือกโหมดของสังคมสูงวัยในการเข้าถึงบริการสุขภาพ โดยเปรียบเทียบระหว่างพื้นที่ศูนย์กลางและชานเมือง ของเมืองฝูโจว ประเทศจีน ในปี 2017 งานวิจัยดำเนินการวิเคราะห์โดยการถดถอยโลจิสติกพหุกลุ่ม พบว่า ผู้สูงอายุในชานเมืองพึ่งพารถยนต์มากกว่าเนื่องจากต้องเดินทางไกลและเข้าถึงบริการขนส่งสาธารณะได้ยาก ส่วนผู้สูงอายุในศูนย์กลางมักใช้การเดินทางหรือรถบัส ผลแสดงให้เห็นว่าปัจจัยทางเศรษฐกิจและการอยู่ร่วมกับครอบครัวมีบทบาทอย่างยิ่งในการเลือกโหมด

Kaye et al. (2020) ใช้วิธีวิเคราะห์เชิงปริมาณโดยประยุกต์ใช้เทคนิค Machine Learning โดยเฉพาะ Random Forest และ Support Vector Machine เพื่อทำนายรูปแบบการเดินทางของประชากรสูงวัยในสหรัฐอเมริกา โดยอิงจากข้อมูลแบบสอบถามเชิงพฤติกรรม การศึกษาพบว่า ตัวแปรสำคัญที่มีอิทธิพลที่ส่งผลต่อการตัดสินใจเลือกวิธีการเดินทาง จะมี อายุ รายได้ ระดับความมั่นใจต่อการเดินทาง รวมถึงประสบการณ์ที่ผ่านมา ในการใช้วิธีเทคนิคเรียนรู้ช่วยให้สามารถจำแนกกลุ่มพฤติกรรมได้แม่นยำกว่าการวิเคราะห์เชิงเส้นแบบเดิม

Kim (2021) บทความนี้นำเสนอการใช้ Machine Learning (ML) เพื่อวิเคราะห์พฤติกรรมการเลือกใช้รูปแบบการเดินทางในกรุงโซล โดยใช้โมเดล Extreme Gradient Boosting (XGB) ซึ่งมีประสิทธิภาพดีกว่าโมเดลอื่นๆ นอกจากนี้ยังใช้วิธีการตีความผลลัพธ์ของ ML เช่น การพิจารณาความสำคัญของตัวแปรร่วมกับการวิเคราะห์ปฏิสัมพันธ์ ทำให้เข้าใจองค์ประกอบสำคัญต่อการ

ตัดสินใจเลือกโหมดได้อย่างลึกซึ้ง โดยพบว่าอายุและความถี่ในการเดินทางเป็นตัวแปรสำคัญ ซึ่งสามารถเผยให้เห็นข้อมูลเชิงลึกที่ไม่สามารถเห็นได้ในโมเดลดั้งเดิม

Pellicer-Chenoll et al. (2021) นักวิจัยดำเนินการวิเคราะห์แบบ SEM เพื่อศึกษาความสัมพันธ์ระหว่างองค์ประกอบทางสิ่งแวดล้อม รวมถึงองค์ประกอบด้านสังคมกับพฤติกรรมการเดินทางของสังคมสูงวัยในเขตเมืองของบังกลาเทศ ดำเนินการเก็บข้อมูลของกลุ่มตัวอย่างผ่านแบบสอบถามจำนวน 300 ราย ผลลัพธ์ชี้ว่า องค์ประกอบทางกายภาพ เช่น พื้นทางเดินและทางลาด รวมถึงการเข้าถึงจุดจอดรถ มีผลต่อการเดินทางอย่างชัดเจน ขณะที่ความรู้สึกมั่นใจ การสนับสนุนจากครอบครัวถูกนิยามให้เป็นตัวแปรแฝงที่มีอิทธิพลทางอ้อมต่อพฤติกรรมการเดินทาง

Scheiner and Holz-Rau (2007) ผลงานนี้นำเสนอข้อพิจารณาทางทฤษฎีเกี่ยวกับความเชื่อมโยงระหว่างสถานการณ์ชีวิตวิถีชีวิตการเลือกสถานที่พักอาศัยและพฤติกรรมการเดินทาง ตลอดจนผลลัพธ์เชิงประจักษ์ของแบบจำลองสมการโครงสร้าง การวิเคราะห์ขึ้นอยู่กับข้อมูลที่รวบรวมมาจากการสำรวจในพื้นที่การศึกษาเจ็ดแห่งในภูมิภาคโคโลญ งานวิจัยแสดงให้เห็นว่า วิถีชีวิตมีบทบาทต่อการเลือกโหมด แม้ว่าขนาดเล็กน้อยแม้ว่าสถานการณ์ชีวิตจะถูกควบคุมก็ตาม อิทธิพลของสถานการณ์ชีวิตต่อการเลือกโหมดเกินอิทธิพลของวิถีชีวิต อิทธิพลที่วิถีชีวิตและสถานการณ์ชีวิตส่วนหนึ่งมีต่อการเลือกโหมดนั้นส่วนใหญ่เป็นสื่อกลางโดยทัศนคติของสถานที่เฉพาะและการกำหนดสถานที่เป้าหมายมีผลต่อการเลือกโหมดที่ตามมา ทั้งนี้เงื่อนไขเชิงพื้นที่ที่วัตถุประสงค์เช่นเดียวกับทัศนคติของตำแหน่งอสังหาริมทรัพย์มีความสำคัญ

Soza-Parra et al. (2019) ใช้วิธี Multinomial Logistic Regression วิเคราะห์ข้อมูลจากแบบสอบถามในกลุ่มประชากรสูงวัยในเขตเมืองของกรุงปักกิ่ง ประเทศจีน โดยมีประเมิณว่าตัวแปรลักษณะทางประชากร อาทิ อายุ รายได้ และระดับการศึกษา รวมถึงองค์ประกอบของระบบขนส่ง เช่น ความเข้าใจในการใช้งานบัตรโดยสาร ความถี่ของการใช้บริการ และความปลอดภัย ตัวแปรใดมีความสำคัญต่อการเลือกโหมดมากที่สุด ผลของงานวิจัยนี้พบว่า ความเข้าใจและความมั่นใจต่อการใช้บริการขนส่งสาธารณะมีอิทธิพลสูงสุด

Uddin et al. (2023) บทความนี้เน้นศึกษาผลกระทบของความพึงพอใจต่อการพฤติกรรมการเดินทาง โดยมีการสำรวจองค์ประกอบทางสังคมและสิ่งแวดล้อมที่มีความหมายต่อการเลือกโหมดของผู้ที่มีข้อจำกัดในการใช้งานระบบขนส่ง โดยได้ข้อมูลการสำรวจการเดินทางในครัวเรือนแห่งชาติประจำปี 2017 ของรัฐนิวยอร์ก ซึ่งรวมถึงข้อมูลเกี่ยวกับผู้ตอบแบบสำรวจที่มีความทุพพลภาพจำกัดการเดินทาง นอกจากนี้ ข้อมูลสภาพภูมิอากาศจากองค์การบริหารมหาสมุทรและบรรยากาศแห่งชาติยังถูกรวมเข้าเป็นตัวแปรอธิบายเพิ่มเติมในกระบวนการสร้างแบบจำลอง วิเคราะห์โดยใช้แบบจำลอง Random Parameters Logit เพื่อระบุปัจจัยส่วนบุคคล การเดินทาง และสภาพแวดล้อมที่ส่งผลต่อการเลือกโหมดของผู้พิการที่มีข้อจำกัดในการเดินทาง ในกลุ่มผู้มีข้อจำกัดด้านการเดินทางอาจมีแนวโน้มที่จะเดินทางไกลกว่าโดยการเดินเท้าในสถานการณ์ที่ขาดสิ่งอำนวยความสะดวกที่เหมาะสม สภาพอากาศส่งผลอย่างชัดเจนต่อการเลือกโหมด โดยที่ผู้คนมีแนวโน้มที่น้อยลงที่จะเดินทางเป็นระยะในช่วงฤดูร้อนและหนาว บุคคลที่มีรายรับน้อยพร้อมทั้งมีข้อจำกัดในการเดินทางมีแนวโน้มใช้บริการขนส่งสาธารณะหรือการสัญจรทางเท้ามากกว่า

จากการทบทวนวรรณกรรมที่เกี่ยวข้องในตารางที่ 2.2 สามารถระบุช่องว่างขององค์ความรู้ในด้านการศึกษาพฤติกรรมการเดินทางของผู้สูงอายุได้อย่างชัดเจน โดยเฉพาะในบริบทของประเทศไทย ซึ่งยังขาดการศึกษาเชิงลึกในหลายมิติ แม้ว่างานวิจัยต่างประเทศจะมีจำนวนมากที่เกี่ยวข้องกับพฤติกรรมการเดินทางของประชาชนทั่วไป แต่การมุ่งศึกษาไปยังกลุ่มผู้สูงอายุโดยเฉพาะในประเทศไทย ยังปรากฏอยู่อย่างจำกัด ประการแรก งานวิจัยส่วนใหญ่ที่มีอยู่ในระดับนานาชาติยังคงให้ความสำคัญกับกลุ่มประชากรทั่วไป หรือกลุ่มเฉพาะที่แตกต่างจากกลุ่มผู้สูงอายุในประเทศไทย เช่น กลุ่มวัยรุ่น หรือกลุ่มผู้ที่มีข้อจำกัดทางร่างกาย (Ahmed et al., 2021; Uddin et al., 2023) ขณะที่กลุ่มผู้สูงอายุในประเทศไทยมีบริบททางสังคม เศรษฐกิจ และวัฒนธรรมที่แตกต่างอย่างมีนัยสำคัญ การศึกษานี้จึงเป็นหนึ่งในงานวิจัยที่มุ่งตอบโจทย์ช่องว่างดังกล่าวโดยเฉพาะ

ประการที่สอง งานวิจัยในระดับนานาชาติมักศึกษาในบริบทของเมืองขนาดใหญ่ เช่น เมลเบิร์น หรือโซล ซึ่งเป็นเมืองที่มีระบบโครงสร้างพื้นฐานด้านคมนาคมที่พัฒนาแล้ว และอาจไม่สะท้อนปัญหาในเมืองระดับภูมิภาคของประเทศกำลังพัฒนาอย่างประเทศไทย งานวิจัยนี้จึงเลือกศึกษาใน “เมืองภูมิภาค” ซึ่งมีความเฉพาะตัวด้านปัจจัยแวดล้อม ระบบขนส่ง และพฤติกรรมของประชากรที่ยังไม่ได้รับความสนใจมากนักในวงวิชาการระดับโลก

ประการที่สาม งานวิจัยส่วนใหญ่มักใช้เพียงเครื่องมือทางสถิติแบบดั้งเดิม หรือเทคนิค Machine Learning เพียงอย่างเดียวในการวิเคราะห์ข้อมูลพฤติกรรมการเดินทาง (Chang et al., 2019; Kim, 2021) ขณะที่งานวิจัยฉบับนี้ได้นำกรอบทฤษฎีทางจิตวิทยาพฤติกรรม คือ ทฤษฎีพฤติกรรมตามแผน (Theory of Planned Behavior: TPB) มาเชื่อมโยงกับการวิเคราะห์สมการโครงสร้าง (Structural Equation Modeling: SEM) เพื่อศึกษาปัจจัยที่ส่งผลต่อความตั้งใจของผู้สูงอายุในการใช้บริการขนส่งสาธารณะ ร่วมกับการประยุกต์ใช้เทคนิค Machine Learning เช่น CatBoost, XGBoost และ Random Forest เพื่อเปรียบเทียบความแม่นยำในการจำแนกรูปแบบพฤติกรรม

ประการสุดท้าย แม้ว่าการศึกษาของ Du et al. (2020) จะศึกษาเกี่ยวกับพฤติกรรมการเดินทางของผู้สูงอายุในประเทศจีนซึ่งมีลักษณะบางประการคล้ายคลึงกับประเทศไทย แต่พื้นที่ศึกษากลับเน้นเปรียบเทียบระหว่างเขตเมืองและชนเมืองในจีน ซึ่งบริบททางสังคมและเศรษฐกิจมีความแตกต่างจากเมืองภูมิภาคของไทย งานวิจัยฉบับนี้จึงเน้นการศึกษาแบบเจาะจงในบริบทของประเทศไทย โดยเฉพาะ ซึ่งถือเป็นการเติมเต็มองค์ความรู้ในเชิงพื้นที่ที่ยังขาดอยู่ในงานวิจัยระดับนานาชาติ ด้วยเหตุผลเหล่านี้ งานวิจัยฉบับนี้จึงสามารถระบุได้ว่าเป็นการวิจัยที่มีความจำเป็นและมีคุณค่าในเชิงวิชาการ โดยเฉพาะในการสร้างองค์ความรู้ใหม่สำหรับการวางแผนพัฒนาระบบขนส่งสาธารณะที่เหมาะสมกับผู้สูงอายุในบริบทของเมืองภูมิภาคในประเทศไทย และสนับสนุนการกำหนดนโยบายขนส่งอย่างยั่งยืนเพื่อรองรับสังคมสูงวัยในอนาคต

ตารางที่ 2.2 ตารางการระบุช่องว่างในการวิจัย (Research Gaps)

ลำดับ	งานวิจัย ต่างประเทศ	กลุ่มประชากร	เทคนิคการวิเคราะห์	บริบทภูมิศาสตร์	กลุ่มเฉพาะ (ผู้สูงอายุ)	ปัจจัยเฉพาะ (ประเทศไทย)
1	Abdullah et al. (2022)	กลุ่มประชากร ทั่วไป	Multinomial Logit Models	ปากีสถาน	✗	✗
2	Ahmed et al. (2021)	18-25 ปี	Linear Regression, Binary Logistic Regression	เมลเบิร์น, ออสเตรเลีย	✗	✗
3	Chang et al. (2019)	กลุ่มประชากร ทั่วไป	Machine Learning, Data Fusion Model, Stacking Strategy	เมืองคาร์ลสรูเออ และเมืองฮัลเลอ, เยอรมัน	✗	✗
4	Kim (2021)	กลุ่มประชากร ทั่วไป	Extreme Gradient Boosting (XGB)	กรุงโซล, เกาหลี ใต้	✗	✗
5	Scheiner and Holz-Rau (2007)	กลุ่มประชากร ทั่วไป	Structural Equation Modeling (SEM)	ภูมิภาคโคโลญ, เยอรมนี	✗	✗
6	Uddin et al. (2023)	ผู้ที่มีความพิการ	Random Parameters Logit Model	นิวยอร์ก, สหรัฐอเมริกา	✗	✗
7	Du et al. (2020)	บุคคลสูงวัย (60 ปีขึ้นไป)	Descriptive Analysis, Multinomial Logistic Regression	ศูนย์กลางและ ชานเมืองของ เมืองฝูโจว, จีน	✓	✗
8	This thesis	บุคคลสูงวัย (60 ปีขึ้นไป)	Theory of Planned Behavior (TPB), Structural Equation Modeling (SEM), Multinomial Logistic Regression, Machine Learning เช่น CatBoost, XGBoost และ Random Forest	เมืองภูมิภาคใน ประเทศไทย (เช่น เชียงใหม่, ขอนแก่น, ชลบุรี, ภูเก็ต)	✓	✓

บทที่ 3

วิธีดำเนินการวิจัย

ในบทนี้อธิบายกระบวนการวางแผนการสำรวจข้อมูล เพื่อให้เกิดการศึกษาแบบจำลองปัจจัยที่มีอิทธิพลต่อการเลือกรูปแบบการเดินทางของประชากรผู้สูงอายุในการใช้บริการขนส่งสาธารณะในเมืองภูมิภาค เพื่อพัฒนาแบบจำลอง และนำเสนอขั้นตอนทั้งหมดของการวิจัยนี้

3.1 ขั้นตอนการทำวิจัย

งานนี้ประกอบด้วยขั้นตอนการดำเนินงานวิจัยซึ่งแสดงดังรูปที่ 3.1 โดยสรุปได้ดังนี้


- 1) กำหนดปัญหาวิจัยและวัตถุประสงค์ ระบุปัญหาหรือคำถามที่ต้องการหาคำตอบ กำหนดวัตถุประสงค์หลักและรองของการวิจัย
- 2) การทบทวนวรรณกรรม ศึกษางานวิจัยที่เกี่ยวข้องกับปัจจัยที่มีอิทธิพลต่อการเดินทางของสังคมผู้สูงอายุในระดับประเทศและนานาชาติ โดยมุ่งแนวคิด ทฤษฎี และปัจจัยที่ควรนำมาพิจารณา
- 3) การออกแบบการวิจัย กำหนดกลุ่มเป้าหมายเป็นประชากรสูงอายุที่อาศัยในเมืองภูมิภาคของประเทศไทย เลือกวิธีสุ่มกลุ่มตัวอย่าง และทำการออกแบบแบบสอบถามโดยให้ครอบคลุมไปถึงปัจจัยที่อาจส่งผลต่อกลุ่มเป้าหมาย อาทิ สภาพเศรษฐกิจ สภาพร่างกาย ความพร้อมในการเดินทาง ความสะดวกในการเข้าถึงการบริการของระบบขนส่ง และพฤติกรรมการเดินทาง
- 4) การตรวจสอบว่าแบบสอบถามหรือเครื่องมือที่ใช้ในการวิจัยนั้นคุณภาพดีพอหรือยัง
- 5) การเก็บรวบรวมข้อมูล แจกจ่ายแบบสอบถามไปยังกลุ่มตัวอย่างที่เลือก ติดตามผลและเก็บรวบรวมข้อมูลจากผู้ตอบแบบสอบถาม
- 6) การวิเคราะห์ข้อมูล โดยเริ่มต้นจากการวิเคราะห์สถิติเชิงพรรณนา (Descriptive Statistics) เพื่ออธิบายลักษณะของกลุ่มตัวอย่าง จากนั้นวิเคราะห์สถิติเชิงอนุมาน (Inferential Statistics) ต่อมา ทำการวิเคราะห์การเลือกรูปแบบการเดินทางของประชากรสูงอายุโดยใช้ทั้งการถดถอยโลจิสติกพหุกลุ่ม (Multinomial Logistic Regression: MLR) ซึ่งสามารถตีความเชิงเศรษฐกิจผ่านค่า Odds Ratio และนัยสำคัญทางสถิติ และนำมาเปรียบเทียบกับวิธี Machine Learning (ML) ได้แก่ Random Forest (RF), Extreme Gradient Boosting (XGBoost), และ CatBoost เพื่อประเมินความสามารถในการจำแนกการเลือกโหมดการเดินทาง ทั้ง MNL และ ML จะถูกประเมินประสิทธิภาพโดยใช้ดัชนีวัดผล เช่น Accuracy, Precision, Recall, F1-score, AUC และใช้ k-fold cross-validation เพื่อประเมินความเสถียรของโมเดล พร้อมทั้งนำ SHAP (SHapley Additive exPlanations) มาวิเคราะห์ความสำคัญของตัวแปรในแต่ละโมเดล ML ขั้นตอนการวิเคราะห์นี้จะแสดงดังรูปที่ 3.2 อีกทั้งดำเนินการวิเคราะห์สมการโครงสร้าง (SEM) ตามแนวคิดของทฤษฎีพฤติกรรมตาม

แผน (TPB) เพื่อวิเคราะห์ปัจจัยที่มีอิทธิพลต่อความตั้งใจของประชากรสูงวัยในการใช้บริการขนส่งสาธารณะในเมืองภูมิภาคของประเทศไทย


7) การสรุปผลและการเสนอแนะ โดยเน้นที่ปัจจัยที่มีอิทธิพลต่อความตั้งใจในการใช้บริการขนส่งสาธารณะและการเลือกรูปแบบการเดินทางของประชากรสูงวัย เสนอแนะพัฒนาและปรับปรุงบริการขนส่งหรือวางแผนการเดินทางให้สอดคล้องกับความต้องการของประชากรสูงวัยในเมืองภูมิภาค

8) การเขียนรายงานวิจัย รวบรวมผลการวิจัยและเขียนรายงานในรูปแบบที่เป็นมาตรฐาน

9) การเผยแพร่ผลการวิจัยโดยการตีพิมพ์ในวารสารวิชาการหรือการนำเสนอในการประชุมวิชาการ เพื่อให้เกิดประโยชน์ต่อสาธารณะและหน่วยงานที่เกี่ยวข้อง



รูปที่ 3.1 ขั้นตอนการทำวิจัย



รูปที่ 3.2 ขั้นตอนการทำวิจัยในส่วนของการวิเคราะห์ MNL และ ML

3.2 เครื่องมือที่ใช้ในการวิจัย

เครื่องมือที่ใช้ในแบบจำลองปัจจัยที่มีอิทธิพลต่อความตั้งใจในการใช้บริการขนส่งสาธารณะและการเลือกรูปแบบการเดินทางของประชากรสูงวัย การวิจัยครั้งนี้ใช้การบันทึกข้อมูลด้วยแบบสอบถามชนิดกรอกด้วยตนเองแสดงไว้ในภาคผนวก ก โดยแบ่งออกเป็น 3 ส่วน ประกอบด้วย

ส่วนที่ 1 เป็นข้อมูลทั่วไปและพฤติกรรมการเดินทางของผู้ตอบแบบสอบถาม เช่น เพศ อายุ อาชีพ รายได้เฉลี่ยส่วนบุคคล โรคประจำตัว ความบกพร่องทางร่างกาย สถานภาพ สถานะการอยู่อาศัย จำนวนสมาชิกในครอบครัว ระดับการศึกษาสูงสุด อาชีพปัจจุบัน เขตที่พักอาศัย ยานพาหนะในการครอบครอง บัตรอนุญาตขับขี่ที่ถือครอง ความถี่ในการเดินทางโดยระบบขนส่งสาธารณะ วัตถุประสงค์ของการเดินทางด้วยระบบขนส่งสาธารณะ ประเภทระบบขนส่งสาธารณะที่ผู้เดินทางเลือกใช้อย่างน้อยที่สุด จำนวนผู้ติดตามในการเดินทางโดยรถโดยสารสาธารณะ ระดับความไว้วางใจเมื่อใช้บริการระบบขนส่งสาธารณะ เหตุผลที่เดินทางด้วยระบบขนส่งสาธารณะ และช่วงเวลาที่ใช้เดินทางของท่านโดยรถสาธารณะ

ส่วนที่ 2 เป็นการประเมินปัจจัยที่มีอิทธิพลต่อความตั้งใจของประชากรสูงวัยในการใช้บริการขนส่งสาธารณะในประเทศไทย ซึ่งประกอบด้วย 4 ปัจจัย ได้แก่ ปัจจัยด้านการรับรู้ในการควบคุมพฤติกรรมของตนเอง (Perceived Behavioral Control) ปัจจัยด้านทัศนคติ (Attitude) ปัจจัยด้านความตั้งใจ (Intention) และปัจจัยด้านบรรทัดฐานสังคม (Subjective Norms) แบบสอบถามใช้มาตราส่วนการประเมินแบบ 7 ระดับ (Rating Scale) สำหรับการตอบคำถาม (ระดับ 1 ไม่เห็นด้วยอย่างยิ่ง, ระดับ 2 ไม่เห็นด้วยอย่างมาก, ระดับ 3 ไม่เห็นด้วยปานกลาง, ระดับ 4 ไม่เห็นด้วยเล็กน้อย, ระดับ 5 เห็นด้วยเล็กน้อย, ระดับ 6 เห็นด้วยปานกลางและ ระดับ 7 เห็นด้วยอย่างยิ่ง)

ส่วนที่ 3 เป็นการสำรวจการเดินทาง จากการบันทึกการเดินทาง (Travel Diary) ซึ่งประกอบด้วย เพศ อายุ รายได้เฉลี่ยส่วนบุคคล อาชีพ ยานพาหนะที่ใช้ ลำดับการเดินทาง เป้าหมายของการเดินทาง เวลาเริ่มต้นการเดินทาง เวลาที่ถึงปลายทาง สถานที่ต้นทาง สถานที่ปลายทาง จำนวนผู้ร่วมเดินทาง ประเภทของการเดินทาง ระยะเวลาการเดินทาง ระยะทางโดยประมาณ อัตราค่าโดยสาร และปัจจัยการเลือกโหมดการเดินทางหลัก

3.3 การเก็บรวบรวมข้อมูล

การเก็บรวบรวมแบบจำลองปัจจัยที่มีอิทธิพลต่อความตั้งใจของผู้สูงอายุในการใช้บริการขนส่งสาธารณะในเมืองภูมิภาค ในการวิจัยส่วนนี้ได้ทำการเก็บข้อมูลกลุ่มตัวอย่างที่ใช้ในการศึกษาครั้งนี้โดยการเก็บรวบรวมข้อมูลจะกำหนดขนาดตัวอย่าง โดยจะแบ่งเป็น 2 Model ดังนี้

3.3.1 การกำหนดขนาดตัวอย่างสำหรับการวิเคราะห์ SEM ตามทฤษฎี TPB

โดยจำนวนข้อมูลที่เก็บ ได้แนวคิดมาจากการวิเคราะห์สมการโครงสร้าง เสนอแนะจำนวนตัวอย่างที่เหมาะสมไว้ว่า จำนวนตัวอย่างสำหรับการประมาณค่าสูงสุดความน่าจะเป็น (Maximum Likelihood) ควรมีอย่างน้อย 10 เท่าของจำนวนตัวแปรสังเกตได้ (Stevens, 1996) ดังนั้น จำนวนตัวอย่างข้อมูลที่จะลงสำรวจภาคสนามเพื่อสุ่มเก็บและได้ทำการเผื่อข้อมูลไว้ +10 เพื่อป้องกันข้อมูลเสียหายหรือใช้ไม่ได้ เท่ากับ $24 \text{ ตัวแปรสังเกตได้} \times 10 = 240$ ตัวอย่าง ทำการเก็บป้องกันความผิดพลาดเป็น 250 ชุดตัวอย่างต่อภูมิภาค จึงทำการเก็บข้อมูล $250 \times 4 = 1,000$ ตัวอย่าง


3.3.2 การกำหนดขนาดตัวอย่างสำหรับการวิเคราะห์ MLR

การกำหนดขนาดกลุ่มตัวอย่างการวิจัยจะมีผลโดยตรงต่อความน่าเชื่อถือของการสรุปจากตัวอย่างไป อ้างอิงกลุ่มประชากร นักวิจัยสามารถกำหนดขนาดตัวอย่างจากการเปิดตาราง สูตรคำนวณ หรือการใช้โปรแกรมคอมพิวเตอร์ในการช่วยคำนวณขนาดตัวอย่าง โดยในงานวิจัยนี้จะใช้โปรแกรม G*Power ซึ่งสามารถกำหนดขนาดตัวอย่างได้อย่างเหมาะสม (นิพิฐพนธ์ สนิทเหลือ, 2022) โดยการประมาณค่าขนาดอิทธิพล (Effect Size) จะเลือกใช้ ขนาด Medium=0.25 , $\alpha=0.05$, Power=0.95 , Ho=0.2 และค่า odd ratio = 1.4 ดังนั้น ค่า Sample Size ที่ได้คือ 967 ตัวอย่าง แต่ทำการเก็บเพื่อป้องกันความผิดพลาด เป็น 1,000 ชุดตัวอย่าง

เนื่องจากทั้งสองการวิเคราะห์ ได้ทำการในแบบสอบถามชุดเดียวกัน ดังนั้นจึงเก็บแบบสอบถามทั้งหมด 1,000 ชุดตัวอย่างทั่วประเทศไทย โดยเก็บภาคละ 250 ชุดตัวอย่างและทำการเก็บข้อมูลเฉพาะกลุ่มประชากรสูงวัยที่อายุเท่ากับหรือมากกว่า 60 ปีในไทย ซึ่งสุ่มตัวอย่างโดยวิธีการแบบชั้นภูมิ (Stratified Random Sampling) การดำเนินการในงานนี้ประกอบด้วย 5 ประการหลัก ดังนี้:

- 1) การแบ่งชั้นภูมิ (Stratification) แบ่งประชากรผู้สูงอายุออกเป็น 4 ชั้นภูมิตามภูมิภาค ประกอบด้วยภาคเหนือ ภาคตะวันออกเฉียงเหนือ ภาคกลาง และภาคใต้ ในทุกภูมิภาคมีจังหวัดที่กำหนดไว้ (เชียงใหม่ เชียงราย สุโขทัย พิษณุโลก, นครราชสีมา ขอนแก่น อุบลราชธานี อุตรธานี, ชลบุรี นครสวรรค์ อยุธยา ประจวบคีรีขันธ์, นครศรีธรรมราช สงขลา สุราษฎร์ธานี ภูเก็ต) ดังรูปที่ 3.3
- 2) การกำหนดขนาดตัวอย่างในแต่ละชั้นภูมิ (Determining Sample Size within Strata) กำหนดจำนวนตัวอย่างที่ต้องการเก็บจากแต่ละภูมิภาค โดยในกรณีนี้กำหนดเก็บข้อมูลภาคละ 250 ตัวอย่าง ซึ่งรวมทั้งสิ้น 1,000 ตัวอย่างทั่วประเทศ
- 3) การสุ่มตัวอย่างภายในแต่ละชั้นภูมิ (Random Sampling within Strata) ภายในทุกภูมิภาค (หรือชั้นภูมิ) จะทำการสุ่มตัวอย่างจากประชากรผู้สูงอายุ โดยใช้วิธีแบบการสุ่มอย่างง่าย (Simple Random Sampling) หรือสุ่มแบบเป็นระบบ (Systematic Sampling) จากแต่ละจังหวัดในภูมิภาคนั้นๆ
- 4) การรวบรวมกลุ่มตัวอย่างจากแต่ละชั้นภูมิ (Combining Samples across Strata) รวมกลุ่มตัวอย่างที่ได้จากแต่ละภูมิภาค เพื่อสร้างกลุ่มตัวอย่างทั้งหมด 1,000 ตัวอย่าง
- 5) การตรวจสอบความสมดุลและการเป็นตัวแทน (Ensuring Representation and Balance) ตรวจสอบว่ากลุ่มตัวอย่างจากแต่ละภูมิภาคมีความสมดุลและเป็นตัวแทนที่ดีของประชากรสูงวัยในทุกภูมิภาคตามสัดส่วนที่ตั้งใจไว้

ขั้นตอนเหล่านี้จะช่วยให้การสุ่มกลุ่มตัวอย่างแบบชั้นภูมิเป็นไปอย่างมีระบบ และทำให้ประชากรตัวอย่างที่ได้มีความเป็นตัวแทนที่ดีของประชากรสูงวัยในทุกภูมิภาคของประเทศไทย ซึ่งเหมาะสมในการนำไปวิเคราะห์แบบจำลองปัจจัยที่มีอิทธิพลต่อความตั้งใจของประชากรสูงวัยสำหรับการใช้บริการขนส่งสาธารณะในเมืองภูมิภาคของประเทศไทย เพื่อพัฒนาแบบจำลองปัจจัยที่มีอิทธิพลต่อความตั้งใจของประชากรสูงวัยในการใช้บริการขนส่งสาธารณะในเมืองภูมิภาค



รูปที่ 3.3 พื้นที่ที่ทำการศึกษา

3.4 กรอบแนวคิดการวิจัย


3.4.1 กรอบแนวคิด SEM ตามทฤษฎี TPB

การวิจัยนี้ใช้กรอบแนวคิดตามทฤษฎีพฤติกรรมตามแผน (Theory of Planned Behavior: TPB) ของ Ajzen (1991) ซึ่งเป็นหนึ่งในแนวคิดสำคัญที่ใช้ในการอธิบายพฤติกรรมของมนุษย์ โดยเฉพาะพฤติกรรมที่มีความตั้งใจ (intention) เป็นตัวแปรสำคัญในการพยากรณ์การกระทำในอนาคต TPB มี 3 ปัจจัยหลักที่ส่งผลต่อ เจตนาพฤติกรรม (Behavioral Intention) ได้แก่

- 1) ทศนคติ (Attitude Toward Behavior)
- 2) อิทธิพลจากกลุ่มสังคม (Subjective Norms)
- 3) การรับรู้การควบคุมพฤติกรรม (Perceived Behavioral Control)

บริบทของการเดินทางโดยระบบขนส่งสาธารณะ จึงได้มีการประยุกต์ใช้กรอบแนวคิดนี้ในการดำเนินการศึกษาความตั้งใจของผู้สูงอายุในการใช้บริการขนส่งสาธารณะ ดังแสดงในรูปที่ 3.4 และรายละเอียดของตัวแปรที่ใช้ในการวิเคราะห์ SEM แสดงในตารางที่ 3.1 โดยกรอบแนวคิดของการวิจัยนี้ประกอบด้วยตัวแปรอิสระ 3 ตัวแปร และตัวแปรตาม 1 ตัวแปรหลัก ดังนี้

- 1) Attitude Toward Using Public Transport ทศนคติในเชิงบวกหรือลบต่อการใช้บริการขนส่งสาธารณะ
- 2) Subjective Norms ความคาดหวังทางสังคมและแรงกดดันจากคนรอบข้างในการใช้ระบบขนส่ง
- 3) Perceived Behavioral Control การรับรู้ความสามารถหรืออุปสรรคของตนเองในการใช้บริการ
- 4) Behavioral Intention to Use Public Transport ความตั้งใจของประชากรสูงวัยที่จะใช้บริการขนส่งสาธารณะในอนาคต




รูปที่ 3.4 กรอบแนวคิด SEM ตามทฤษฎี TPB

ตารางที่ 1.1 ประเภทของตัวแปรที่ใช้ในการวิเคราะห์ SEM

ตัวแปร	ชื่อเต็ม	ประเภทตัวแปร	ค่าที่ใช้ในโมเดล
Gender	เพศ	ตัวแปรสังเกตได้	0 = ชาย
			1 = หญิง
Age	อายุ	ตัวแปรสังเกตได้	0 = ≥ 70 ปี
			1 = 60-69 ปี
Salary	รายได้เฉลี่ย	ตัวแปรสังเกตได้	0 = $\leq 10,000$ บาท
			1 = $> 10,000$ บาท
Area	เขตที่อยู่อาศัย	ตัวแปรสังเกตได้	0 = ในเมือง
			1 = นอกเมือง
ATT	ทัศนคติ	ตัวแปรแฝง	Likert scale 1-5
SN	บรรทัดฐานกลุ่มอ้างอิง	ตัวแปรแฝง	
PBC	การรับรู้การควบคุมพฤติกรรม	ตัวแปรแฝง	
INT	เจตนาใช้บริการขนส่ง	ตัวแปรแฝง (ตัวแปรตาม)	

3.4.2 สมมติฐานของดัชนีความพร้อมทางเทคโนโลยี

นอกเหนือจากการวิเคราะห์เจตนาในการใช้ระบบขนส่งสาธารณะผ่านกรอบทฤษฎี TPB แล้ว งานวิจัยนี้ยังต้องการศึกษาปัจจัยที่มีอิทธิพลต่อการเลือกโหมด (Travel Mode) ของผู้สูงอายุ ในบริบทจริง โดยใช้วิธีการวิเคราะห์ถดถอยโลจิสติกพหุกลุ่ม (Multinomial Logistic Regression) และการวิเคราะห์ Machine Learning ซึ่งเหมาะสมกับตัวแปรตามที่เป็นข้อมูลเชิงกลุ่มหลายประเภท (categorical outcomes) ตัวแปรอิสระที่ใช้ในการวิเคราะห์เพื่อคาดการณ์การเลือกโหมดการเดินทาง ได้แก่ เพศ (Gender), อายุ (Age), รายได้เฉลี่ย (Salary), อาชีพ (Occupation), วัตถุประสงค์การเดินทาง (Travel Purpose), จำนวนผู้ร่วมเดินทาง (Number of Traveling Participants), เวลาที่ใช้ในการเดินทาง (Travel Time) และระยะทาง (Distance) โดยมีตัวแปรตาม คือ รูปแบบการเดินทาง (Travel Mode) เช่น รถยนต์ (Car), รถบัส (Bus), รถไฟ (Rail), และขนส่งสาธารณะ (Paratransit) เป็นต้น การวิเคราะห์ในส่วนนี้จะช่วยเสริมความเข้าใจพฤติกรรมการเดินทางจริงของกลุ่มตัวอย่าง และใช้ประกอบกับผลการวิเคราะห์จากโมเดล TPB เพื่อให้ได้มุมมองเชิงพฤติกรรมที่ครอบคลุมทั้งเจตนา และพฤติกรรมจริง การวิเคราะห์แบบจำลองที่มีผลกระทบต่อการเลือกโหมดการเดินทางของประชากร สูงวัยในประเทศไทย โดยการประยุกต์ใช้แบบจำลองทางคณิตศาสตร์ด้วยการใช้แบบจำลองถดถอยโลจิสติกพหุกลุ่ม (MLR) และการวิเคราะห์ Machine Learning เพื่อวิเคราะห์ข้อมูล ซึ่งรายละเอียดของ กรอบแสดงดังรูปที่ 3.5



รูปที่ 3.5 กรอบแนวคิดของ MLR และ ML

3.5 การวิเคราะห์ข้อมูล

3.5.1 การสร้างแบบจำลองสมการโครงสร้าง (SEM)

การประยุกต์ใช้การวิเคราะห์ปัจจัยยืนยัน (CFA) เพื่อพัฒนาแบบจำลองการวัดในกระบวนการสร้าง SEM เป็นขั้นตอนสำคัญของงานวิจัย เนื่องจากแบบจำลองการวัดจะประเมินความสัมพันธ์ระหว่างตัวแปรที่สังเกตได้ (Indicators) และปัจจัยแฝง (Latent Factors) สำหรับเกณฑ์ค่าความพอดี (Goodness of fit) ที่แนะนำในการพิจารณาความสอดคล้องของแบบจำลองตามสมมติฐานกับข้อมูลเชิงประจักษ์ของการวิเคราะห์องค์ประกอบเชิงยืนยัน Confirmatory factor analysis) มีค่าดังต่อไปนี้ ค่าอัตราส่วนไคสแควร์กับองศาอิสระ (χ^2/df) ควรน้อยกว่า 5 (Wheaton et al., 1977) ค่าดัชนีวัดระดับความกลมกลืนเปรียบเทียบ (Comparative Fit Index :CFI) ควรมากกว่า 0.95 (L.-t. Hu & P. M. Bentler, 1999) ค่าดัชนี Tucker-Lewis Index (TLI) ควรมากกว่า 0.8 (Daire Hooper et al., 2008) ค่าดัชนีรากที่สองของค่าเฉลี่ยกำลังสองของการประมาณค่าความคลาดเคลื่อน (Root Mean Square Error of Approximation: RMSEA) ควรน้อยกว่าหรือเท่ากับ 0.08 (Browne & Cudeck, 1993) และค่าดัชนี SRMR (Standardized Root Mean Square Residual) (L.-t. Hu & P. M. Bentler, 1999) แนะนำว่าควรน้อยกว่าหรือเท่ากับ 0.08 และสำหรับค่าจากนั้นตรวจสอบความเที่ยงตรงของเครื่องมือการวิจัย (Reliability) โดยความเชื่อมั่นของปัจจัย (Construct Reliability: CR) เป็นเครื่องมือในการตรวจสอบ และค่าเฉลี่ยของความแปรปรวนที่ถูกสกัดได้ (Variance Extracted score: AVE) โดยค่า AVE ที่มากกว่า 0.5 ถือเป็นเกณฑ์มาตรฐานที่แสดงว่าปัจจัยมีความน่าเชื่อถือในระดับที่ยอมรับได้ (Fornell & Larcker, 1981) และค่า AVE ที่มากกว่า squared correlations สามารถตรวจสอบความถูกต้องของแบบจำลองการวัดได้ (Fornell & Larcker, 1981) เมื่อแบบจำลองการวัดผ่านการตรวจสอบแล้ว ก็สามารถรวมแบบจำลองการวัดของแต่ละปัจจัยเข้ากับแบบจำลองโครงสร้างได้

3.5.2 การวิเคราะห์ด้วยการถดถอยโลจิสติกพหุกลุ่ม (MLR)

สถิติอนุमान เป็นการศึกษาปัจจัยที่มีอิทธิพลต่อความตั้งใจของประชากรสูงวัยในการใช้บริการขนส่งสาธารณะในภูมิภาคของประเทศไทย วิเคราะห์ด้วยการถดถอยโลจิสติกพหุกลุ่ม (MLR) การทดสอบความเหมาะสมของสมการถดถอยโลจิสติกวิธีการตรวจสอบประกอบด้วย การประเมินค่าความเป็นไปได้ (likelihood value) และการทดสอบ Hosmer and Lemeshow รายละเอียดประกอบด้วย ดังนี้

- 1) พิจารณาความเป็นไปได้ (likelihood value) ในการประเมินความเหมาะสมของสมการโลจิสติก จะใช้ค่า $-2LL$ ($-2 \log \text{likelihood}$) เป็นเกณฑ์ หากค่านี้มีค่าน้อย แสดงว่าสมการโลจิสติกมีความเหมาะสมกับข้อมูลมากขึ้น นอกจากนี้ยังใช้การทดสอบนัยสำคัญทางสถิติเพื่อตรวจสอบความสัมพันธ์ของตัวแปรในสมการ

- 2) พิจารณาสถิติทดสอบความเหมาะสมของ Hosmer and Lemeshow จะใช้ทดสอบความเหมาะสม model ในการทดสอบ χ^2 ไม่มีนัยสำคัญทางสถิติหรือยอมรับ H_0 แสดงว่า model มีความเหมาะสม

สถิติทดสอบระดับความสัมพันธ์ ค่าสัมประสิทธิ์การพยากรณ์ (R^2) ในสมการถดถอยโลจิสติก คือ ค่าความแปรปรวนของตัวแปรตามที่สามารถอธิบายได้โดยตัวแปรอิสระ ซึ่งมีสถิติที่ทดสอบระดับความสัมพันธ์หลายค่า ได้แก่ Cox & Snell R Square และ Nagelkerke R square แสดงรายละเอียดดังนี้ (Kaiyawan, 2012)

- 1) สถิติทดสอบ Cox & Snell R Square เป็นการตรวจสอบความสอดคล้องของโมเดล หรือเปอร์เซ็นต์ที่สามารถอธิบายความแปรปรวนในการวิเคราะห์ความถดถอยโลจิสติก ซึ่ง Cox & Snell R Square มีค่าน้อยกว่า 1 เสมอ (กัลยา วาณิชยบัญชา, 2015)
- 2) สถิติทดสอบ Nagelkerke R square ค่าสถิติของ Nagelkerke R square จะมีลักษณะเหมือนกับ Cox & Snell R Square แต่จะมีค่ามากกว่าเสมอค่า R^2 จาก Cox & Snell R Square และ Nagelkerke R square สามารถคิดเป็นเปอร์เซ็นต์ได้จากการนำไปคูณด้วย 100 เป็นค่า R^2 เทียม หรือเรียกว่า Pseudo R^2 ซึ่งเป็นเปอร์เซ็นต์ที่อธิบายความแปรปรวนในโมเดลการถดถอยโลจิสติกทุกกลุ่ม

3.5.3 การใช้ Machine Learning (RF, XGBoost, CatBoost)

เพื่อปรับปรุงความแม่นยำในการวิเคราะห์ปัจจัยที่มีผลต่อการเลือกรูปแบบการเดินทางเทคนิค Machine Learning ได้ถูกนำมาใช้เป็นอีกแนวทางในการวิเคราะห์ข้อมูล โดยการศึกษานี้ได้ใช้ Random Forest (RF), Extreme Gradient Boosting (XGBoost) และ CatBoost ซึ่งเป็นอัลกอริธึมที่ได้รับความนิยมในการจำแนกและทำนายข้อมูลที่ซับซ้อน (Abdulazeez et al., 2023)

การเลือกใช้อัลกอริธึม ML

- 1) Random Forest (RF) เป็นอัลกอริธึมแบบ ensemble learning ที่ใช้ Decision Trees หลายต้น เพื่อเพิ่มความแม่นยำ (Khan et al., 2024) และใช้หลัก Bootstrap Aggregation (Bagging) เพื่อลดปัญหา overfitting (Mohamed et al., 2025) ใช้หลัก Bootstrap Aggregation (Bagging) เพื่อสร้างแบบจำลองย่อยที่แตกต่างกัน
- 2) Extreme Gradient Boosting (XGBoost) ใช้ Gradient Boosting Decision Trees (GBDT) เพื่อเพิ่มประสิทธิภาพของการทำนาย (Li et al., 2024) และมีการใช้ Regularization (L1/L2 Penalty) เพื่อป้องกัน overfitting (Chuang et al., 2022) ถูกออกแบบมาให้ทำงานได้เร็วกว่า Random Forest และให้ผลลัพธ์ที่แม่นยำกว่า
- 3) CatBoost ออกแบบมาเพื่อจัดการกับ ข้อมูลที่ไม่สมดุล (Imbalanced Data) ได้ดีกว่า XGBoost (Sun et al., 2023) และใช้เทคนิค Ordered Boosting เพื่อลดปัญหา overfitting (Mohamed et al., 2025)

บทที่ 4

ผลการวิเคราะห์ข้อมูล

การศึกษานี้มุ่งเน้นวิเคราะห์ปัจจัยที่มีอิทธิพลต่อการเลือกรูปแบบการเดินทางของประชากรสูงวัยโดยประยุกต์ใช้ทั้ง แบบจำลองการถดถอยโลจิสติกแบบพหุกลุ่ม (Multinomial Logistic Regression: MNL) และ เทคนิค Machine Learning (ML) ได้แก่ Random Forest (RF), Extreme Gradient Boosting (XGBoost) และ CatBoost เพื่อเปรียบเทียบความสามารถในการจำแนกและทำนายรูปแบบการเดินทาง และเพื่อให้สามารถระบุปัจจัยสำคัญที่ส่งผลต่อการเลือกโหมดการเดินทางได้อย่างมีประสิทธิภาพยิ่งขึ้น นอกจากนี้เพื่อศึกษาปัจจัยที่มีอิทธิพลต่อความตั้งใจของประชากรสูงวัยในการใช้บริการขนส่งสาธารณะในเมืองภูมิภาคของประเทศไทย โดยใช้แบบจำลองสมการโครงสร้าง (Structural Equation Modeling: SEM) ในการวิเคราะห์ ตามแนวคิดของทฤษฎีพฤติกรรมตามแผน (Theory of planned behavior) ผลการวิเคราะห์ถูกแบ่งออกเป็น 6 ตอน ตามวัตถุประสงค์ของการวิจัย ดังนี้

- ตอนที่ 1 ผลการวิเคราะห์การแจกแจงข้อมูลทั่วไป และคุณลักษณะทางสังคมและเศรษฐกิจของกลุ่มตัวอย่างประชากรสูงวัย
- ตอนที่ 2 ผลการวิเคราะห์สถิติเบื้องต้นเกี่ยวกับความสำคัญ (Importance) ที่ผู้ตอบแบบสอบถามให้ไว้ในแบบสอบถาม
- ตอนที่ 3 ผลการวิเคราะห์ค่าสัมประสิทธิ์สหสัมพันธ์เพียร์สัน
- ตอนที่ 4 ผลการวิเคราะห์หองค์ประกอบเชิงยืนยัน (Confirmatory Factor Analysis)
- ตอนที่ 5 ผลการวิเคราะห์แบบจำลองสมการโครงสร้าง (Structural Equation Modeling)
- ตอนที่ 6 ผลการวิเคราะห์ถดถอยโลจิสติกพหุกลุ่ม (Multinomial logistic regression)
- ตอนที่ 7 ผลการเปรียบเทียบประสิทธิภาพของแบบจำลอง Machine Learning
- ตอนที่ 8 ผลการเปรียบเทียบการวิเคราะห์ทางสถิติกับ Machine Learning

4.1 ข้อมูลทั่วไปและพฤติกรรมทางการเดินทางของผู้ตอบแบบสอบถาม

ผลการวิเคราะห์ของประชากรสูงวัยในประเทศไทย จำนวน 1,000 คน ผลการศึกษาแสดงให้เห็นว่าประชากรกลุ่มตัวอย่างส่วนใหญ่เป็นเพศหญิง จำนวน 543 คน (ร้อยละ 54.3) ส่วนใหญ่อยู่ในช่วงอายุ 60 ถึง 69 ปี จำนวน 785 คน (ร้อยละ 78.5) ส่วนใหญ่สถานะสมรส จำนวน 697 คน (ร้อยละ 69.7) สถานะการอยู่อาศัยส่วนใหญ่จะอยู่กับครอบครัว/ผู้ดูแล จำนวน 949 คน (ร้อยละ 94.9) ในด้านการศึกษาส่วนใหญ่ต่ำกว่าปริญญาตรี จำนวน 860 คน (ร้อยละ 86) ผู้ตอบแบบสอบถามส่วนใหญ่มีรายได้ส่วนบุคคลต่ำกว่า 10,000 บาทต่อเดือน จำนวน 787 คน (ร้อยละ 78.7) รูปแบบ

การทำงานส่วนใหญ่ของประชากรสูงอายุจะยังทำงานอยู่และทำงานนอกบ้าน จำนวน 412 คน (ร้อยละ 41.2) สถานะการครอบครองยานพาหนะส่วนใหญ่มีการถือครองยานพาหนะ จำนวน 803 คน (ร้อยละ 80.3) และสถานะใบอนุญาตขับขี่ส่วนใหญ่จะไม่มี จำนวน 563 คน (ร้อยละ 56.3) ข้อมูลแสดงในตารางที่ 4.1

ด้านของสุขภาพของประชากรสูงวัย โดยส่วนใหญ่มีโรคประจำตัว จำนวน 732 คน (ร้อยละ 73.2) โดยจะเป็นโรคความดันโลหิตสูง โรคเบาหวานและโรคไขมันในเลือดสูงตามลำดับ และด้านของบกพร่องทางร่างกาย โดยส่วนใหญ่จะไม่ได้มีความบกพร่องทางร่างกาย 590 คน (ร้อยละ 59) และมีความบกพร่องทางร่างกาย 410 คน (ร้อยละ 41) แต่จะมีความบกพร่องทางการเคลื่อนไหว มีปัญหาในการมองเห็น และการได้ยินตามลำดับ รายละเอียดแสดงในตารางที่ 4.1

ด้านพฤติกรรมการเดินทางของระบบขนส่งสาธารณะของประชากรสูงวัยที่ตอบแบบสอบถามพบว่าผู้ตอบส่วนใหญ่ใช้บริการขนส่งสาธารณะบ่อยรายสัปดาห์หรือมากกว่า จำนวน 361 คน (ร้อยละ 36.1) จุดมุ่งหมายของการเดินทางด้วยขนส่งมวลชนส่วนใหญ่ คือ เพื่อเดินทางไปซื้อของ จำนวน 346 คน (ร้อยละ 34.6) โดยระบบขนส่งสาธารณะที่ใช้กันบ่อยในผู้ตอบแบบสอบถามส่วนใหญ่ใช้บริการรถบัสเป็นหลัก จำนวน 329 คน (ร้อยละ 32.9) ผู้ตอบแบบสอบถามส่วนใหญ่ที่ใช้ระบบขนส่งสาธารณะเดินทางเพียงลำพัง จำนวน 524 คน (ร้อยละ 52.4) ความไว้วางใจของผู้ตอบแบบสอบถามส่วนใหญ่จะไว้วางใจปานกลางในการใช้บริการระบบขนส่งสาธารณะ จำนวน 691 คน (ร้อยละ 69.1) ซึ่งเหตุผลที่เลือกของผู้ตอบจะคำนึงถึงราคาถูก มีความสะดวกในการเข้าถึง และระยะเวลาเดินทางไม่นานตามลำดับ และช่วงเวลาที่ผู้ตอบแบบสอบถามใช้บริการรถโดยสารสาธารณะ จะใช้บริการช่วงเช้ามืดถึงเช้า (04:00-09:59 น.) จำนวน 644 คน (ร้อยละ 64.4) เป็นส่วนใหญ่ ข้อมูลแสดงในตารางที่ 4.2

ตารางที่ 4.1 การแจกแจงข้อมูลทั่วไปและลักษณะทางสังคมและเศรษฐกิจของกลุ่มตัวอย่าง

ตัวแปร	คำอธิบาย	จำนวน 1,000 คน	
		ความถี่	%
เพศ	ชาย	457	45.70
	หญิง	543	54.30
อายุ	60-69 ปี	785	78.5
	70-79 ปี	199	19.9
	มากกว่า 80 ปี	16	1.6
สถานะ	โสด	68	6.80
	สมรส	697	69.70
	หม้าย/หย่า/แยกกันอยู่	235	23.50
สถานะการอยู่อาศัย	อยู่ลำพัง	51	5.1
	อยู่กับครอบครัว/ผู้ดูแล	949	94.9
ระดับการศึกษา	ต่ำกว่าปริญญาตรี	860	86.00
	ปริญญาตรี หรือสูงกว่า	96	9.60
	อื่นๆ	44	4.40

ตารางที่ 4.2 การแจกแจงข้อมูลทั่วไปและลักษณะทางสังคมและเศรษฐกิจของกลุ่มตัวอย่าง (ต่อ)

ตัวแปร	คำอธิบาย	จำนวน 1,000 คน	
		ความถี่	%
รายได้ (บาทต่อเดือน)	ต่ำกว่า 10,000	787	78.70
	10,000–19,999	106	10.60
	20,000–29,999	60	6.00
	30,000 หรือสูงกว่า	47	4.70
รูปแบบการทำงาน	ทำงานนอกบ้าน	412	41.20
	ทำงานที่บ้าน	255	25.50
	ไม่ทำงาน/อยู่บ้าน	333	33.30
สถานะการครอบครองยานพาหนะ	มียานพาหนะในการครอบครอง	803	80.30
	ไม่มียานพาหนะในการครอบครอง	197	19.70
สถานะใบอนุญาตขับขี่	มีใบอนุญาตขับขี่	437	43.70
	ไม่มีใบอนุญาตขับขี่	563	56.30
โรคประจำตัว	มีโรคประจำตัว	732	73.20
	ไม่มีโรคประจำตัว	268	26.80
ความบกพร่อง	มีความบกพร่อง	410	41.00
	ไม่มีความบกพร่อง	590	59.00

ตารางที่ 4.3 พฤติกรรมการเดินทางระบบขนส่งสาธารณะของผู้ตอบแบบสอบถาม

ตัวแปร	คำอธิบาย	จำนวน 1,000 คน	
		ความถี่	%
ใช้บริการระบบขนส่งสาธารณะบ่อยแค่ไหน	ผู้ใช้บ่อย (รายสัปดาห์หรือมากกว่า)	361	36.10
	ผู้ใช้เป็นครั้งคราว (รายเดือน)	347	34.70
	ผู้ใช้ไม่บ่อย (น้อยกว่าหนึ่งครั้งต่อเดือน)	285	28.50
	ไม่เคยใช้บริการ	7	0.70
วัตถุประสงค์ของการเดินทางด้วยระบบขนส่งสาธารณะ	เพื่อไปทำงาน	84	8.40
	เพื่อพักผ่อน/ท่องเที่ยว	235	23.50
	เพื่อเดินทางไปซื้อของ	346	34.60
	เพื่อกิจกรรมกีฬา (การชุมนุม)	50	5.00
	อื่น ๆ	285	28.50
ระบบขนส่งสาธารณะที่ใช้กันบ่อย	รถตู้	265	26.50
	รถบัส	329	32.90
	รถไฟ	238	23.80
	ไม่เคยใช้บริการทั้ง 3 แบบ	168	16.80

ตารางที่ 4.4 พฤติกรรมการเดินทางระบบขนส่งสาธารณะของผู้ตอบแบบสอบถาม (ต่อ)

ตัวแปร	คำอธิบาย	จำนวน 1,000 คน	
		ความถี่	%
จำนวนผู้ติดตามในการเดินทางโดยรถโดยสารสาธารณะ	เดินทางเองคนเดียว	524	52.40
	ผู้ร่วมเดินทางด้วย 1 คน	351	35.10
	ผู้ร่วมเดินทางด้วยมากกว่า 2 คน	125	12.50
ความไว้วางใจในการใช้บริการระบบขนส่งสาธารณะ	ไม่ไว้วางใจ	8	0.80
	ไว้วางใจเล็กน้อย	91	9.10
	ไว้วางใจปานกลาง	691	69.10
	ไว้วางใจมาก	179	17.90
	ไว้วางใจมากที่สุด	31	3.10
เหตุผลที่เดินทางด้วยระบบขนส่งสาธารณะ	ไม่มีทางเลือก	135	13.50
	ราคาถูก	661	66.10
	ตรงต่อเวลา	305	30.50
	ประทับใจในบริการ	143	14.30
	ใช้เวลาเดินทางไม่นาน	374	37.40
	ลดปัญหามลพิษ	113	11.30
	สะดวก สามารถเข้าถึงได้ง่าย	457	45.70
	มีความปลอดภัยในการเดินทาง	361	36.10
	อื่นๆ	8	0.80
ช่วงเวลาที่ใช้รถโดยสารสาธารณะ	ช่วงเช้ามืด - เช้า (04:00-09:59 น.)	644	64.40
	ช่วงสาย - ปาย (10:00-15:59 น.)	310	31.00
	ช่วงเย็น - ค่ำ (16:00-21:59 น.)	44	4.40
	ช่วงดึก (22:00-00:59 น.)	2	0.20

4.2 ผลการวิเคราะห์สถิติเบื้องต้นของแบบสอบถามการวิเคราะห์ความสำคัญ (Important) ของผู้ตอบแบบสอบถาม

สถิติเบื้องต้นของข้อคำถามเกี่ยวกับปัจจัยการวิเคราะห์ความสำคัญและผลการปฏิบัติงาน (Important Performance Analysis: IPA) การพิจารณาค่าสถิติพื้นฐานของตัวชี้วัดเพื่อนำไปวิเคราะห์องค์ประกอบเชิงยืนยัน และสมการโครงสร้างโดยพิจารณาตัวแปรทั้งหมด 24 ตัวแปร จาก 4 ปัจจัย ได้แก่ ด้านการรับรู้ในการควบคุมพฤติกรรมของตนเอง (Perceived Behavioral Control) ด้านทัศนคติ (Attitude) ด้านความตั้งใจ (Intention) และ ด้านบรรทัดฐานสังคม (Subjective

Norms) ตารางที่ 4.3 แสดงสถิติเบื้องต้นของข้อคำถามความสำคัญ (Important) ทั้งหมดที่ได้กล่าวถึงข้างต้น โดยสถิติเบื้องต้นจะประกอบด้วย ค่าเฉลี่ย (mean) ส่วนเบี่ยงเบนมาตรฐาน (standard deviation) ความเบ้ (skewness) และความโด่ง (kurtosis) ดังนี้

ตารางที่ 4.5 การวิเคราะห์สถิติเบื้องต้นของแบบสอบถามการวิเคราะห์ความสำคัญ (Important)

ตัวแปร	คำอธิบาย	1,000 ตัวอย่าง			
		Mean	SD	SK	KU
	ด้านการรับรู้ในการควบคุมพฤติกรรมของตนเอง (Perceived Behavioral Control) Cronbach's Alpha = 0.834				
PBC1	ฉันคิดว่าระบบขนส่งที่มีความถี่ในการให้บริการมาก ทำให้ง่ายต่อการเดินทาง	6.40	0.867	-1.706	3.512
PBC2	ฉันคิดว่าระบบขนส่งที่มีความตรงต่อเวลาของรถโดยสาร ทำให้ง่ายต่อการเดินทาง	6.30	0.889	-1.617	3.494
PBC3	ฉันคิดว่าระบบขนส่งที่มีความสะอาดสบายมาก ทำให้ง่ายต่อการเดินทาง	6.22	0.907	-1.191	1.374
PBC4	ฉันคิดว่าระบบขนส่งที่มีค่าเดินทางที่ถูกขึ้น ทำให้ง่ายต่อการเดินทาง	6.30	0.908	-1.476	2.866
PBC5	ฉันคิดว่าระบบขนส่งที่มีการเข้าถึงในการใช้บริการได้ทั่วถึง ทำให้ง่ายต่อการเดินทาง	6.21	0.928	-1.259	1.790
PBC6	ฉันคิดว่าระบบขนส่งที่มีความปลอดภัยมาก ทำให้ง่ายต่อการเดินทาง	6.23	0.913	-1.293	1.980
	ด้านทัศนคติ (Attitude) Cronbach's Alpha = 0.907				
A1	ฉันชอบใช้ระบบขนส่งสาธารณะ หากความถี่ในการให้บริการดีขึ้น	6.17	0.907	-1.372	2.928
A2	ฉันชอบใช้ระบบขนส่งสาธารณะ หากเวลาในการเดินทางลดลง	6.14	0.954	-1.393	2.723
A3	ฉันชอบใช้ระบบขนส่งสาธารณะ หากความสะอาดสบายมากขึ้น	6.17	0.927	-1.104	1.017
A4	ฉันชอบใช้ระบบขนส่งสาธารณะ หากค่าเดินทางถูกลง	6.30	0.891	-1.297	1.565
A5	ฉันชอบใช้ระบบขนส่งสาธารณะ หากการเข้าถึงในการใช้บริการได้ง่ายมากยิ่งขึ้น	6.15	0.886	-0.970	0.632
A6	ฉันชอบใช้ระบบขนส่งสาธารณะ หากความปลอดภัยเพิ่มสูงขึ้น	6.23	0.900	-1.193	1.399
	ด้านความตั้งใจ (Intention) Cronbach's Alpha = 0.890				
I1	ฉันจะใช้ระบบขนส่งสาธารณะ เพราะเชื่อว่าความถี่ในการให้บริการส่งผลต่อความตั้งใจในการใช้บริการของฉัน	6.08	0.924	-1.136	1.851
I2	ฉันจะใช้ระบบขนส่งสาธารณะ เพราะเชื่อว่าเวลาในการเดินทางส่งผลต่อความตั้งใจในการใช้บริการของฉัน	6.05	0.953	-1.162	1.706
I3	ฉันจะใช้ระบบขนส่งสาธารณะ เพราะเชื่อว่าความสะอาดสบายส่งผลต่อความตั้งใจในการใช้บริการ	6.14	0.945	-1.022	0.639

ตารางที่ 4.6 การวิเคราะห์สถิติเบื้องต้นของแบบสอบถามการวิเคราะห์ความสำคัญ (Important)
(ต่อ)

ตัวแปร	คำอธิบาย	1,000 ตัวอย่าง			
		Mean	SD	SK	KU
I4	ฉันจะใช้ระบบขนส่งสาธารณะ เพราะเชื่อว่าค่าเดินทางส่งผลต่อความตั้งใจในการใช้บริการ	6.20	0.938	-1.095	0.687
I5	ฉันจะใช้ระบบขนส่งสาธารณะ เพราะเชื่อว่าการเข้าถึงสถานที่ทำงานและที่อยู่อาศัยส่งผลต่อความตั้งใจในการใช้บริการ	6.12	0.918	-0.973	0.564
I6	ฉันจะใช้ระบบขนส่งสาธารณะ เพราะเชื่อว่าความปลอดภัยส่งผลต่อความตั้งใจในการใช้บริการ	6.19	0.956	-1.314	2.075
	ด้านบรรทัดฐานสังคม (Subjective Norms) Cronbach's Alpha = 0.846				
SN1	ฉันชอบใช้บริการขนส่งสาธารณะเพราะทำให้ท่านรู้สึกความทันสมัย	5.86	1.062	-1.148	1.928
SN2	ฉันชอบใช้บริการขนส่งสาธารณะเพราะจะช่วยลดต้นทุนการเดินทาง	5.75	1.162	-1.229	2.026
SN3	ฉันชอบใช้บริการขนส่งสาธารณะเพราะความสะดวกสบายในการเดินทาง	5.78	1.166	-1.201	2.054
SN4	ฉันชอบใช้บริการขนส่งสาธารณะเพราะช่วยลดปัญหาหมอกพิษ	5.75	1.192	-1.077	1.392
SN5	ฉันชอบใช้บริการขนส่งสาธารณะเพราะเป็นเรื่องปกติของสังคม	5.74	1.220	-1.055	1.160
SN6	ฉันชอบใช้ระบบขนส่งสาธารณะตามที่คนรอบข้างหรือเพื่อนแนะนำ	5.75	1.221	-0.857	0.243

หมายเหตุ: SD หมายถึง standard deviation; SK หมายถึง skewness; KU หมายถึง kurtosis.

4.3 ค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างตัวแปรอิสระในแบบจำลอง

วิเคราะห์ค่าสัมประสิทธิ์สหสัมพันธ์เพียร์สันระหว่างตัวแปรสังเกตในแบบจำลองปัจจัยที่เกี่ยวข้องกับความตั้งใจของประชากรสูงวัยในการใช้บริการขนส่งสาธารณะ เพื่อวิเคราะห์ความสัมพันธ์ระหว่างตัวแปรสองตัว ค่าสัมประสิทธิ์ที่เป็นบวก หมายความว่าเมื่อตัวแปรตัวหนึ่งเพิ่มขึ้นหรือลดลง อีกตัวแปรหนึ่งก็จะเพิ่มขึ้นหรือลดลงตามไปด้วย ส่วนค่าสัมประสิทธิ์ที่เป็นลบ หมายความว่าเมื่อตัวแปรตัวหนึ่งเพิ่มขึ้นหรือลดลง อีกตัวแปรหนึ่งจะมีค่าเพิ่มขึ้นหรือลดลงในทิศทางตรงกันข้าม ระดับนัยสำคัญของการทดสอบระบุด้วยเครื่องหมาย (*) และ (**) ซึ่งแทนค่านัยสำคัญทางสถิติที่ระดับ 0.05 และ 0.01 ตามลำดับ (* $p < 0.05$, ** $p < 0.01$) ผลการวิเคราะห์ความสัมพันธ์ระหว่างตัวแปรทั้ง 24 ตัวในแบบจำลองแต่ละปัจจัย พบว่าค่าสัมประสิทธิ์มีค่าระหว่าง 0.193 ถึง 0.757 เมื่อพิจารณาผลการทดสอบสมมติฐานว่า เมทริกซ์สหสัมพันธ์เอกลักษณ์ (Identity Matrix) หรือไม่ พบว่าได้ค่า $\chi^2 = 14373.538$ ($df = 276$, $p < 0.001$) ซึ่งมีค่าแตกต่างจากศูนย์อย่างมีนัยสำคัญทางสถิติที่ระดับ 0.01 และสอดคล้องกับผลการวิเคราะห์ค่าดัชนี Kaiser-Meyer-Olkin (KMO) ซึ่งมีค่าเท่ากับ 0.940 ซึ่งมีค่าเข้าใกล้ 1 แสดงให้เห็นว่าเมทริกซ์สหสัมพันธ์ของตัวแปรสังเกตได้นี้ไม่เป็นเมทริกซ์

เอกลักษณ์ และมีความสัมพันธ์กันระหว่างตัวแปรมากพอที่จะนำมาวิเคราะห์องค์ประกอบในสมการ
โครงสร้างได้ดังตารางที่ 4.4



ตารางที่ 4.4 ค่าสัมประสิทธิ์สหสัมพันธ์ของตัวแปรปัจจัยที่มีความตั้งใจของผู้สูงอายุในการใช้บริการขนส่งสาธารณะ

ตัวแปร	PBC1	PBC2	PBC3	PBC4	PBC5	PBC6	A1	A2	A3	A4	A5	A6	I1	I2	I3	I4	I5	I6	SN1	SN2	SN3	SN4	SN5	SN6
PBC1	1																							
PBC2	.728**	1																						
PBC3	.586**	.626**	1																					
PBC4	.573**	.536**	.585**	1																				
PBC5	.563**	.556**	.564**	.656**	1																			
PBC6	.541**	.556**	.586**	.569**	.641**	1																		
A1	.456**	.464**	.460**	.432**	.430**	.523**	1																	
A2	.381**	.368**	.339**	.343**	.396**	.375**	.505**	1																
A3	.383**	.389**	.410**	.386**	.398**	.420**	.391**	.629**	1															
A4	.398**	.400**	.426**	.502**	.486**	.458**	.448**	.393**	.491**	1														
A5	.301**	.355**	.350**	.375**	.406**	.365**	.422**	.495**	.492**	.473**	1													
A6	.389**	.409**	.436**	.428**	.490**	.516**	.480**	.391**	.443**	.498**	.507**	1												
I1	.374**	.378**	.384**	.355**	.404**	.371**	.432**	.370**	.318**	.364**	.330**	.454**	1											
I2	.366**	.365**	.338**	.303**	.317**	.332**	.334**	.513**	.415**	.345**	.430**	.361**	.600**	1										
I3	.329**	.341**	.332**	.290**	.309**	.313**	.290**	.409**	.464**	.327**	.427**	.336**	.427**	.637**	1									
I4	.349**	.367**	.400**	.419**	.438**	.424**	.372**	.333**	.374**	.472**	.343**	.442**	.487**	.396**	.504**	1								
I5	.336**	.363**	.374**	.421**	.392**	.405**	.383**	.379**	.392**	.421**	.408**	.385**	.452**	.487**	.493**	.555**	1							
I6	.360**	.381**	.399**	.409**	.435**	.450**	.384**	.340**	.353**	.435**	.373**	.490**	.439**	.398**	.451**	.525**	.522**	1						
SN1	.364**	.358**	.398**	.363**	.335**	.375**	.374**	.289**	.270**	.327**	.250**	.349**	.442**	.337**	.319**	.393**	.393**	.472**	1					
SN2	.382**	.409**	.413**	.338**	.368**	.371**	.326**	.310**	.314**	.308**	.256**	.352**	.365**	.316**	.280**	.365**	.334**	.434**	.614**	1				
SN3	.433**	.421**	.429**	.386**	.396**	.402**	.354**	.299**	.342**	.317**	.237**	.383**	.383**	.300**	.307**	.367**	.323**	.464**	.588**	.757**	1			
SN4	.403**	.391**	.431**	.387**	.376**	.417**	.356**	.254**	.317**	.355**	.276**	.388**	.374**	.266**	.308**	.352**	.311**	.435**	.572**	.653**	.754**	1		
SN5	.351**	.379**	.375**	.325**	.323**	.385**	.306**	.199**	.301**	.297**	.234**	.359**	.300**	.207**	.290**	.378**	.314**	.362**	.513**	.602**	.643**	.736**	1	
SN6	.339**	.341**	.347**	.338**	.351**	.395**	.341**	.193**	.272**	.347**	.277**	.395**	.326**	.202**	.284**	.393**	.365**	.433**	.485**	.508**	.580**	.661**	.711**	1

หมายเหตุ: * $p < 0.05$, ** $p < 0.01$ หมายถึง มีนัยสำคัญทางสถิติที่ระดับ 0.05 และ 0.01 ตามลำดับ

4.4 ผลการวิเคราะห์องค์ประกอบเชิงยืนยัน (Confirmatory Factor Analysis)

4.4.1 โครงสร้างโมเดลการวัด (Measurement Model)

การวิเคราะห์องค์ประกอบเชิงยืนยัน (CFA) ถูกใช้เพื่อประเมินความเหมาะสมของโครงสร้างโมเดลการวัดที่พัฒนาขึ้นบนพื้นฐานของทฤษฎีพฤติกรรมตามแผน (Theory of Planned Behavior: TPB) โดยมี 4 ตัวแปรแฝงหลัก ได้แก่

- 1) ทศนคติ (Attitude) วัดโดย ATT1-ATT6
- 2) บรรทัดฐานส่วนบุคคล (Subjective Norms) วัดโดย SN1-SN6
- 3) การควบคุมพฤติกรรมที่รับรู้ (Perceived Behavioral Control: PBC) วัดโดย PBC1 – PBC6
- 4) เจตนาในการใช้บริการ (Behavioral Intention: INT) วัดโดย INT1 – INT6

แม้ว่าตัวชี้วัดบางรายการ เช่น ATT2, ATT3, SN2 และ SN3 จะมีน้ำหนักองค์ประกอบ (factor loading) ต่ำกว่าเกณฑ์ที่แนะนำ (< 0.6) แต่ยังอยู่ในระดับที่สามารถยอมรับได้ตามข้อเสนอของ Hair et al. (2013) และ Byrne (2013) โดยเมื่อค่าความเชื่อมั่นรวม CR อยู่ในระดับสูง และค่า AVE อยู่ในระดับใกล้เคียงหรือมากกว่า 0.5 ซึ่งสะท้อนถึงคุณภาพการวัดที่เพียงพอของโมเดล

4.4.2 ค่าความเหมาะสมของโมเดล (Model Fit Indices)

ผลการวิเคราะห์ CFA ด้วยวิธี Maximum Likelihood Estimation ให้ค่าดัชนีความสอดคล้องของโมเดล ดังนี้

ตารางที่ 4.5 ตารางแสดงความเหมาะสมของโมเดล (Model Fit Indices)

ดัชนีชี้วัด	ค่าโมเดล	เกณฑ์การยอมรับ
Chi-square / df	1601.425 / 353 $\approx$ 4.54	< 5.00 (พอใช้ได้)
RMSEA	0.057	≤ 0.08 (ดี), ≤ 0.05 (ดีมาก)
CFI	0.918	≥ 0.90 (ดี), ≥ 0.95 (ดีมาก)
TLI	0.907	≥ 0.90
SRMR	0.042	≤ 0.08

จากผลการวิเคราะห์องค์ประกอบเชิงยืนยัน (CFA) พบว่าโมเดลการวัดมีความสอดคล้องกับข้อมูลในระดับ “ดีถึงดีมาก” เมื่อพิจารณาจากดัชนีความสอดคล้องของโมเดล (Model Fit Indices) ดังนี้ Chi-square / df = 4.54 ซึ่งน้อยกว่าเกณฑ์ < 5.0 ที่ยอมรับได้ (Wheaton et al., 1977) RMSEA = 0.057 พร้อมช่วงความเชื่อมั่น 90% CI (0.054–0.059) อยู่ในเกณฑ์ “เหมาะสมมาก” (< 0.06) ตามข้อเสนอของ Hu and Bentler (1999) CFI = 0.918 และ TLI

= 0.907 ซึ่งมากกว่าเกณฑ์ ≥ 0.90 แสดงว่าโมเดลมีความสอดคล้องดี (Bentler, 1990) SRMR = 0.042 น้อยกว่าค่าเกณฑ์ 0.08 ที่กำหนดโดย Kline (2023) ผลรวมของดัชนีเหล่านี้ชี้ให้เห็นว่าแบบจำลองการวัดมีความสอดคล้องและเหมาะสมกับข้อมูลที่เก็บจากกลุ่มตัวอย่าง และสามารถใช้ในการวิเคราะห์โมเดลสมการโครงสร้าง (SEM) ได้ต่อไป

4.4.3 ค่าความเชื่อมั่นของตัวแปรแฝง (Standardized Factor Loadings)

ค่าการถ่วงน้ำหนักของตัวแปรสังเกต (Standardized Factor Loadings) อยู่ระหว่าง 0.616 – 0.873 ซึ่ง สูงกว่าเกณฑ์ขั้นต่ำที่ยอมรับได้ (≥ 0.50) ตามข้อเสนอของ Brown (2015) และมีนัยสำคัญทางสถิติทั้งหมด ($p < 0.001$) แสดงให้เห็นว่าตัวแปรสังเกตสามารถอธิบายความแปรปรวนของตัวแปรแฝงได้อย่างเหมาะสม

ตารางที่ 4.6 แสดงผลการวิเคราะห์องค์ประกอบเชิงยืนยัน (CFA) ของแบบจำลอง

ตัวแปร	STDYX	S.E.	p-value	CR	AVE
Attitude				0.993	0.464
ATT1	0.672	0.019	<0.001		
ATT2	0.637	0.021	<0.001		
ATT3	0.642	0.020	<0.001		
ATT4	0.713	0.018	<0.001		
ATT5	0.715	0.018	<0.001		
ATT6	0.702	0.018	<0.001		
Perceived Behavioral Control				0.996	0.555
PBC1	0.719	0.017	<0.001		
PBC2	0.730	0.016	<0.001		
PBC3	0.747	0.015	<0.001		
PBC4	0.748	0.015	<0.001		
PBC5	0.778	0.014	<0.001		
PBC6	0.770	0.014	<0.001		
Subjective Norms				0.993	0.439
SN1	0.664	0.019	<0.001		
SN2	0.619	0.021	<0.001		
SN3	0.640	0.020	<0.001		
SN4	0.651	0.018	<0.001		

ตารางที่ 4.6 แสดงผลการวิเคราะห์องค์ประกอบเชิงยืนยัน (CFA) ของแบบจำลอง (ต่อ)

ตัวแปร	STDYX	S.E.	p-value	CR	AVE
SN5	0.651	0.020	<0.001		
SN6	0.707	0.018	<0.001		
Intention to use Public Transport				0.996	0.621
INT1	0.675	0.018	<0.001		
INT2	0.747	0.015	<0.001		
INT3	0.822	0.012	<0.001		
INT4	0.875	0.009	<0.001		
INT5	0.826	0.012	<0.001		
INT6	0.768	0.014	<0.001		

หมายเหตุ: STDYX หมายถึง Standardized

S.E. หมายถึง Standard Error

AVE หมายถึง Average variance extracted

CR หมายถึง Construct reliability

จากตารางแสดงผลการวิเคราะห์องค์ประกอบเชิงยืนยัน (CFA) พบว่าโมเดลการวัดที่ใช้ในการศึกษานี้มีความเหมาะสมและความสอดคล้องภายในที่ดีในทุก factor ได้แก่ Attitude, Perceived Behavioral Control (PBC), Subjective Norms (SN) และ Intention to use Public Transport (INT) โดยพิจารณาจากค่าการถ่วงน้ำหนักของตัวแปรสังเกต (Standardized Factor Loadings: STDYX), ค่าความเที่ยงตรงรวม (CR) และค่าอธิบายความแปรปรวนเฉลี่ย (AVE) ดังนี้

- 1) Attitude ค่า STDYX อยู่ระหว่าง 0.637 – 0.715 โดยทุกตัวแปร มีค่า $p < 0.001$ แสดงว่ามีนัยสำคัญทางสถิติ ค่า CR = 0.993 แสดงถึงความเชื่อมั่นภายในที่ดีเยี่ยม ค่า AVE = 0.464 ต่ำกว่าเกณฑ์ที่ยอมรับ (≥ 0.50) เล็กน้อย อย่างไรก็ตามเนื่องจากค่า CR สูงมาก จึงสามารถพิจารณาว่า factor นี้มีความเที่ยงตรงรวมที่ยอมรับได้ (Fornell & Larcker, 1981)
- 2) Perceived Behavioral Control (PBC) ค่า STDYX อยู่ในช่วง 0.719 – 0.778 และมีนัยสำคัญทางสถิติทั้งหมด ($p < 0.001$) ค่า CR = 0.996, AVE = 0.555 ซึ่งทั้งสองค่าผ่านเกณฑ์มาตรฐาน ($CR \geq 0.70$ และ $AVE \geq 0.50$) สะท้อนว่า factor นี้มีทั้งความสอดคล้องภายในและความสามารถในการอธิบายตัวแปรแฝงได้ดี
- 3) Subjective Norms (SN) ค่า STDYX อยู่ในช่วง 0.619 – 0.707 และทุกค่ามีนัยสำคัญทางสถิติ ค่า CR = 0.993 สูงมาก แต่ AVE = 0.439 ยังต่ำกว่าเกณฑ์เล็กน้อย แม้ว่า AVE จะต่ำ แต่การที่ CR สูงเกิน 0.90 ทำให้ยังถือว่า factor นี้สามารถใช้ได้ภายใต้การพิจารณาเชิงทฤษฎี (Hair et al., 2013)
- 4) Intention to use Public Transport ค่า STDYX อยู่ระหว่าง 0.675 – 0.875 ซึ่งถือว่าสูงมาก และมีนัยสำคัญทางสถิติทั้งหมด ค่า CR = 0.996, AVE = 0.621 ผ่านเกณฑ์

ชัดเจนเป็น factor มีค่าความเชื่อมั่นและความตรงเชิงโครงสร้างสูงที่สุดในแบบจำลองการวิจัย

4.5 การวิเคราะห์แบบจำลองสมการโครงสร้าง (Structural Equation Modeling)

การวิเคราะห์แบบจำลองสมการโครงสร้าง (Structural Equation Modeling: SEM) เป็นขั้นตอนสำคัญในการตรวจสอบความสัมพันธ์เชิงสาเหตุระหว่างตัวแปรแฝง ตามกรอบแนวคิดของทฤษฎีแผนพฤติกรรม (Theory of Planned Behavior: TPB) กับความตั้งใจใช้บริการขนส่งสาธารณะของประชากรสูงอายุ โดยประเมินผ่านค่าความสอดคล้องของโมเดลและค่าสัมประสิทธิ์เส้นทางระหว่างตัวแปร

4.5.1 การตรวจสอบความสอดคล้องของแบบจำลองโครงสร้างความตั้งใจแสดงพฤติกรรมการใช้บริการขนส่งสาธารณะสำหรับผู้สูงอายุ

จากผลการวิเคราะห์ SEM ด้วยวิธี Maximum Likelihood Estimation ผลการวิเคราะห์ชี้ให้เห็นว่าโมเดลมีความสอดคล้องกับข้อมูลเชิงประจักษ์ในระดับที่น่าเชื่อถือ โดยสามารถอ้างอิงจากค่าความสอดคล้องของโมเดลที่แสดงไว้แล้วใน ตารางที่ 4.10 ดังนี้ $\text{Chi-square} / \text{df} = 1549.216 / 337 \approx 4.597 (< 5.00: \text{พอใช้ได้})$ $\text{RMSEA} = 0.057 (\leq 0.08: \text{ดี})$ $\text{CFI} = 0.920 (\geq 0.90: \text{ดี})$ $\text{TLI} = 0.911 (\geq 0.90: \text{ดี})$ และ $\text{SRMR} = 0.047 (\leq 0.08: \text{ดีมาก})$ ค่าดัชนีทั้งหมดอยู่ในเกณฑ์ที่สามารถยอมรับได้ตามข้อเสนอของ Hair et al. (2013), Hu and Bentler (1999) และ Byrne (2013) แสดงว่าโมเดล SEM ที่สร้างขึ้นมีความเหมาะสมในการอธิบายโครงสร้างข้อมูลในงานวิจัยนี้

4.5.2 การวิเคราะห์เส้นทางความสัมพันธ์และการทดสอบสมมติฐาน

จากการวิเคราะห์แบบจำลองสมการโครงสร้าง (Structural Equation Modeling: SEM) ดังตารางที่ 4.7 และ รูปที่ 4.1 พบว่าปัจจัยหลายประการมีอิทธิพลอย่างมีนัยสำคัญทางสถิติต่อความตั้งใจในการใช้บริการขนส่งสาธารณะของประชากรสูงอายุ (Behavioral Intention) ทั้งจากปัจจัยทางจิตวิทยา (ตามกรอบ TPB) และปัจจัยด้านประชากรศาสตร์ โดยสามารถแปลผลสมมติฐานทั้ง 7 ข้อได้ดังนี้

สมมติฐานที่ 1 (H1) ทศนคติต่อการใช้บริการขนส่งสาธารณะ (Attitude toward use) มีอิทธิพลทางบวกต่อความตั้งใจในการใช้บริการขนส่งสาธารณะ ผลการศึกษาพบว่า ทศนคติมีอิทธิพลเชิงบวกอย่างมีนัยสำคัญทางสถิติ ($\beta = 0.322, p < 0.001$) สะท้อนว่าสังคมสูงวัยที่มีมุมมองเชิงบวก เช่น การมองว่าบริการขนส่งสะดวก ประหยัด ปลอดภัย จะมีแนวโน้มตั้งใจใช้บริการมากกว่าผู้ที่ไม่มีทัศนคติไม่ชัดเจน

สมมติฐานที่ 2 (H2) บรรทัดฐานส่วนบุคคล (Subjective Norms) ส่งผลในเชิงบวกต่อความตั้งใจในการใช้บริการขนส่ง พบว่า มีค่าสัมประสิทธิ์มาตรฐาน $\beta = 0.059$ และมีนัยสำคัญทาง

สถิติ ($p < 0.001$) แสดงว่าแรงกดดันจากบุคคลรอบข้าง อาทิ สมาชิกในครอบครัว เพื่อน หรือชุมชน มีอิทธิพลต่อพฤติกรรมของประชากรสูงวัย

สมมติฐานที่ 3 (H3) การรับรู้การควบคุมพฤติกรรมตนเอง (Perceived Behavioral Control) มีอิทธิพลทางบวกต่อความตั้งใจใช้บริการ ผลการศึกษาพบว่า มีค่าสัมประสิทธิ์มาตรฐานสูงที่สุดในโมเดล ($\beta = 0.334$, $p < 0.001$) บ่งชี้ว่าหากประชากรสูงวัยรู้สึกว่าจะสามารถเข้าถึงหรือใช้งานระบบขนส่งได้ด้วยตนเอง เช่น การเดินทางไม่ลำบากหรือมีบริการอำนวยความสะดวก จะมีแนวโน้มตั้งใจใช้บริการมากขึ้น

สมมติฐานที่ 4 (H4) เพศ (Gender) มีผลกระทบต่อความตั้งใจใช้บริการ ผลการศึกษาไม่พบอิทธิพลอย่างมีนัยสำคัญทางสถิติ ($\beta = -0.001$, $p = 0.970$) แสดงว่าเพศไม่ใช่ปัจจัยสำคัญที่มีผลต่อการตัดสินใจใช้บริการขนส่งของประชากรสูงวัยในบริบทนี้

สมมติฐานที่ 5 (H5) อายุ (Age) มีอิทธิพลต่อความตั้งใจ ผลการศึกษาพบว่า อายุมีอิทธิพลในเชิงบวกต่อความตั้งใจในการใช้บริการขนส่งสาธารณะอย่างมีนัยสำคัญทางสถิติ ($\beta = 0.040$, $p < 0.001$) โดยค่าพารามิเตอร์ที่เป็นบวกและมีนัยสำคัญนี้ บ่งชี้ว่า กลุ่มผู้สูงอายุที่มีอายุน้อยกว่า (60–69 ปี) มีแนวโน้มที่จะมีความตั้งใจในการใช้บริการขนส่งสาธารณะมากกว่าผู้ที่มีอายุมากกว่า (70 ปีขึ้นไป) ซึ่งอาจสะท้อนถึงความสามารถในการเคลื่อนไหว สุขภาพร่างกาย หรือความมั่นใจในการใช้บริการระบบขนส่งที่ยังอยู่ในระดับดี


สมมติฐานที่ 6 (H6) รายได้ (Salary) มีอิทธิพลต่อความตั้งใจ ผลการศึกษามีค่าสัมประสิทธิ์ $\beta = 0.073$ ($p = 0.003$) แสดงว่ากลุ่มที่มีรายรับสูงกว่ามีแนวโน้มที่จะเลือกใช้บริการขนส่งสาธารณะมากกว่า สะท้อนถึงเงื่อนไขทางเศรษฐกิจที่มีบทบาทในการเลือกใช้บริการขนส่งสาธารณะ

สมมติฐานที่ 7 (H7) พื้นที่อยู่อาศัย (Area) ส่งผลต่อความตั้งใจ ผลการศึกษาค่าสัมประสิทธิ์ $\beta = 0.048$ ($p < 0.001$) บ่งชี้ว่าพื้นที่อยู่อาศัย เช่น ในเมืองหรือนอกเมือง มีผลกระทบต่อพฤติกรรมการใช้บริการขนส่ง เช่น การเข้าถึงและคุณภาพบริการ

ตารางที่ 4.7 ตารางแสดงผลการทดสอบสมมติฐานจากการวิเคราะห์แบบจำลองสมการโครงสร้าง

สมมติฐาน	ความสัมพันธ์	Standardized Estimate	S.E.	t-value	p-value	สรุปผล
H1	ATT → INT	0.322***	0.044	7.319	<0.001	ยอมรับ
H2	SN → INT	0.059***	0.003	22.454	<0.001	ยอมรับ
H3	PBC → INT	0.334***	0.043	7.729	<0.001	ยอมรับ
H4	Gender → INT	-0.001	0.025	-0.038	0.970	ไม่ยอมรับ
H5	Age → INT	0.040***	0.001	28.564	<0.001	ยอมรับ
H6	Salary → INT	0.073**	0.025	2.947	0.003	ยอมรับ
H7	Area → INT	0.048***	0.002	28.552	<0.001	ยอมรับ

หมายเหตุ : *** $p < 0.001$, ** $p < 0.01$, * $p < 0.05$



รูปที่ 4.1 แบบจำลองสมการโครงสร้างปัจจัยที่มีอิทธิพลต่อการเลือกรูปแบบการเดินทางของผู้สูงอายุ
ในเมืองภูมิภาคของประเทศไทย

4.6 การวิเคราะห์ถดถอยโลจิสติกพหุกลุ่ม (MLR)

การศึกษานี้ใช้การวิเคราะห์ทางสถิติด้วยวิธีการถดถอยโลจิสติกพหุกลุ่ม (MLR) เพื่อศึกษาปัจจัยที่มีอิทธิพลต่อการเลือกรูปแบบการเดินทางของประชากรผู้สูงอายุในเมืองภูมิภาคของประเทศไทย ได้ทำการวิเคราะห์ข้อมูลโดยใช้เทคนิค MLR โดยเริ่มจากการประเมินความสอดคล้อง

ตารางที่ 4.8 ความเหมาะสมของแบบจำลองและค่า Pseudo R-Square

Model	Model Fitting Criteria	Likelihood Ratio Tests		
	-2 Log Likelihood	Chi-Square	df	Sig.
Intercept Only	4940.585			
Final	2561.661	2378.924	42	0.000

จากการตรวจสอบความเหมาะสมของโมเดล พบว่าโมเดล MLR มีค่า -2 Log Likelihood ของโมเดลสุดท้ายอยู่ที่ 2,561.661 ซึ่งลดลงจากโมเดลที่ไม่มีตัวแปรอิสระอย่างมีนัยสำคัญ (Chi-square = 2,378.924, df = 42, p < 0.001) แสดงว่าโมเดลที่พัฒนาขึ้นสามารถทำนายการเลือก

โหมดได้อย่างมีประสิทธิภาพและดีกว่าแบบจำลองพื้นฐานอย่างชัดเจน จากนั้นจึงวิเคราะห์ผลสัมประสิทธิ์ของตัวแปรอิสระแต่ละตัว ดังแสดงในตารางถัดไป

ตารางที่ 4.9 ค่าสัมประสิทธิ์ถดถอย (B), ค่า Exp(B) และค่าความมีนัยสำคัญทางสถิติ

Index	ค่า
Cox & Snell	0.690
Nagelkerke	0.756
McFadden	0.481

ค่าดัชนี Pseudo R-Square ที่ได้ ได้แก่ Cox & Snell = 0.690, McFadden = 0.481 และ Nagelkerke = 0.756 ซึ่งค่า Nagelkerke ที่สูงถึง 0.756 บ่งชี้ว่าโมเดลมีความสามารถในการอธิบายความแปรปรวนของพฤติกรรมทางเลือกโหมดของประชากรสูงวัยได้ถึง 75.6% จัดอยู่ในระดับสูงมาก และมีความน่าเชื่อถือ

4.6.1 การประมาณค่าพารามิเตอร์ของแบบจำลอง (Parameter Estimates)

Multinomial Logit Model (MNL) ถูกนำมาใช้เพื่อวิเคราะห์ปัจจัยที่มีผลต่อการเลือกโหมดของประชากรสูงวัย โดยมี "รถยนต์ส่วนตัว (Car)" เป็นหมวดอ้างอิง (Reference Category) และเปรียบเทียบกับโหมดการเดินทางอื่น ๆ ได้แก่ รถบัส (Bus), รถไฟ (Rail), และขนส่งกึ่งสาธารณะ (Paratransit)

ตารางที่ 4.10 การประมาณค่าพารามิเตอร์ของแบบจำลอง (Parameter Estimates)

Mode Choice		B	Std. Error	Sig.	Exp(B)
Bus	Intercept	6.064	1.748	0.001	
	อายุ (ปี)	-0.020	0.019	0.276	0.980
	รายได้เฉลี่ย (พันบาท)	-0.168	0.014	0.000	0.846
	ระยะเวลาเดินทาง (นาที)	0.080	0.015	0.000	1.083
	ระยะทางในการเดินทาง (กิโลเมตร)	0.025	0.019	0.179	1.025
	ค่าใช้จ่ายในการเดินทาง	-0.120	0.007	0.000	0.887
	เพศ ชาย=0, หญิง=1	0.085	0.173	0.623	1.089
	ไม่มีผู้ติดตาม=0, มีผู้ติดตาม=1	2.278	0.192	0.000	9.754
	ไปทำงาน	-0.131	0.525	0.804	0.878
	พักผ่อน/ท่องเที่ยว	-0.540	0.345	0.118	0.583
	ไปซื้อของ	-0.648	0.315	0.040	0.523
	กิจกรรมกีฬา (การชุมนุม)	0.380	0.443	0.390	1.463
	เดินทางกลับบ้าน	-0.537	0.279	0.055	0.584
	ทำงานนอกบ้าน	-0.165	0.224	0.461	0.848
	ไม่ทำงาน/อยู่บ้าน	-0.411	0.232	0.077	0.663

ตารางที่ 4.10 การประมาณค่าพารามิเตอร์ของแบบจำลอง (Parameter Estimates) (ต่อ)

Mode Choice		B	Std. Error	Sig.	Exp(B)
Rail	Intercept	6.981	6.362	0.272	
	อายุ (ปี)	0.044	0.063	0.489	1.045
	รายได้เฉลี่ย (พันบาท)	-0.272	0.078	0.000	0.762
	ระยะเวลาเดินทาง (นาที)	0.276	0.065	0.000	1.318
	ระยะทางในการเดินทาง (กิโลเมตร)	0.122	0.061	0.046	1.130
	ค่าใช้จ่ายในการเดินทาง	-1.085	0.143	0.000	0.338
	เพศ ชาย=0, หญิง=1	-0.768	0.639	0.230	0.464
	ไม่มีผู้ติดตาม=0, มีผู้ติดตาม=1	-0.175	0.827	0.832	0.839
	ไปทำงาน	-2.097	1.567	0.181	0.123
	พักผ่อน/ท่องเที่ยว	-1.919	1.419	0.176	0.147
	ไปซื้อของ	-2.130	1.176	0.070	0.119
	กิจกรรมกีฬา (การช้อปปิ้ง)	4.186	1.862	0.025	65.751
	เดินทางกลับบ้าน	-1.664	1.022	0.103	0.189
	ทำงานนอกบ้าน	-0.295	0.926	0.751	0.745
	ไม่ทำงาน/อยู่บ้าน	0.593	0.930	0.524	1.810
Paratransit	Intercept	8.743	1.726	0.000	
	อายุ (ปี)	-0.058	0.018	0.002	0.944
	รายได้เฉลี่ย (พันบาท)	-0.111	0.012	0.000	0.895
	ระยะเวลาเดินทาง (นาที)	-0.025	0.013	0.062	0.975
	ระยะทางในการเดินทาง (กิโลเมตร)	0.046	0.017	0.008	1.047
	ค่าใช้จ่ายในการเดินทาง	-0.016	0.003	0.000	0.984
	เพศ ชาย=0, หญิง=1	-0.181	0.167	0.278	0.834
	ไม่มีผู้ติดตาม=0, มีผู้ติดตาม=1	2.123	0.185	0.000	8.357
	ไปทำงาน	-1.223	0.524	0.020	0.294
	พักผ่อน/ท่องเที่ยว	-1.154	0.345	0.001	0.316
	ไปซื้อของ	-1.096	0.322	0.001	0.334
	กิจกรรมกีฬา (การช้อปปิ้ง)	-0.366	0.419	0.383	0.694
	เดินทางกลับบ้าน	-1.035	0.286	0.000	0.355
	ทำงานนอกบ้าน	0.526	0.218	0.016	1.692
	ไม่ทำงาน/อยู่บ้าน	-0.258	0.219	0.237	0.772

จากตาราง Parameter Estimates แสดงถึงปัจจัยที่มีผลต่อการเลือกโหมดการเดินทางของประชากรสูงวัย โดยผลลัพธ์ที่สำคัญสามารถสรุปได้ดังนี้ ระยะเวลาเดินทางมีอิทธิพลเชิงบวกต่อการเลือกใช้รถบัส (Bus) และรถไฟ (Rail) (Sig = 0.000) ซึ่งหมายความว่า ยิ่งระยะเวลาเดินทางเพิ่มขึ้น โอกาสที่ผู้สูงวัยเลือกใช้รถบัสหรือรถไฟก็เพิ่มขึ้น ค่า $\text{Exp}(B) > 1$ ยืนยันว่าระยะเวลาเดินทางที่นานขึ้นช่วยเพิ่มโอกาสในการเลือกใช้ระบบขนส่งสาธารณะ ค่าใช้จ่ายในการเดินทางมีอิทธิพลเชิงลบต่อการเลือกใช้รถบัส, รถไฟ และขนส่งสาธารณะ (Sig = 0.000) หมายความว่า หากค่าใช้จ่ายในการเดินทางเพิ่มขึ้นโอกาสที่ประชากรสูงวัยจะเลือกใช้ขนส่งสาธารณะลดลง ค่า $\text{Exp}(B) < 1$ สำหรับทุกโหมดการเดินทางที่ไม่ใช่รถยนต์ แสดงว่าประชากรสูงวัยหลีกเลี่ยงการใช้รูปแบบการเดินทางที่รายจ่ายสูง รายได้เฉลี่ยไม่มีผลอย่างมีนัยสำคัญต่อการเลือกโหมดการเดินทาง (Sig = 1.000) หมายความว่า ประชากรสูงวัยที่มีรายได้แตกต่างกัน ไม่ได้มีพฤติกรรมการเดินทางที่แตกต่างกันอย่างมีนัยสำคัญ บ่งชี้ว่าปัจจัยด้านรายได้ไม่ได้เป็นตัวกำหนดหลักในการเลือกโหมดการเดินทางของประชากรสูงวัย ผู้ที่เดินทางคนเดียวมีแนวโน้มเลือกใช้รถบัสและขนส่งสาธารณะมากกว่ารถยนต์ส่วนตัว ค่า $\text{Exp}(B) = 9.754$ สำหรับรถบัส และ 8.357 สำหรับขนส่งสาธารณะ แสดงให้เห็นว่าประชากรสูงวัยที่เดินทางคนเดียวมีแนวโน้มเลือกใช้ระบบขนส่งสาธารณะมากกว่าผู้ที่เดินทางเป็นกลุ่ม เป็นไปได้ว่า การเดินทางคนเดียวช่วยให้ประชากรสูงวัยมีความยืดหยุ่นในการเลือกใช้ขนส่งสาธารณะมากขึ้น กิจกรรมกีฬา (การชุมนุม) เป็นปัจจัยสำคัญที่ส่งผลต่อการเลือกใช้รถไฟมากที่สุด ($\text{Exp}(B) = 65.751$) หมายความว่า ประชากรสูงวัยที่เดินทางเพื่อเข้าร่วมกิจกรรมชุมชน เช่น กีฬา หรือการชุมนุม มีโอกาสเลือกใช้รถไฟมากกว่าถึง 65 เท่า เมื่อเปรียบเทียบกับการใช้รถยนต์ส่วนบุคคล แสดงให้เห็นถึงบทบาทสำคัญของกิจกรรมทางสังคมในการกำหนดพฤติกรรมการเดินทางของประชากรสูงวัย สรุปผลการวิเคราะห์ค่าใช้จ่ายสำหรับการเดินทางเป็นปัจจัยสำคัญที่ส่งผลต่อการเลือกใช้ขนส่งสาธารณะมากที่สุด ผู้ที่เดินทางคนเดียวมีแนวโน้มใช้ขนส่งสาธารณะมากกว่าผู้ที่เดินทางเป็นกลุ่ม กิจกรรมกีฬา (การชุมนุม) เป็นปัจจัยที่มีผลต่อการเลือกรถไฟมากที่สุด โดยประชากรสูงวัยที่เข้าร่วมกิจกรรมชุมชนมีแนวโน้มใช้รถไฟมากกว่าโหมดการเดินทางอื่นๆ

4.6.2 การทดสอบอิทธิพลของตัวแปรโดยใช้ Likelihood Ratio Tests

Likelihood Ratio Tests ถูกใช้เพื่อตรวจสอบว่าสมการที่มีตัวแปรต่าง ๆ นั้นมีความเหมาะสมมากกว่าการไม่มีตัวแปรนั้นหรือไม่ โดยเปรียบเทียบค่าของ Chi-Square (χ^2 Value) และ P-Value ของแต่ละตัวแปร

ตารางที่ 4.11 Likelihood Ratio Tests

Factors influencing mode choice	χ^2 Value	P-Value
Intercept	0.000	
อายุ	13.042	0.005
รายได้เฉลี่ย	202.805	0.000

ตารางที่ 4.11 Likelihood Ratio Tests (ต่อ)

Factors influencing mode choice	X^2 Value	P-Value
ระยะทาง	11.370	0.010
ค่าใช้จ่ายในการเดินทาง	1347.140	0.000
เพศ	5.938	0.115
จำนวนผู้ติดตาม	203.299	0.000
ไปทำงาน	11.155	0.011
พักผ่อน/ท่องเที่ยว	13.123	0.004
ไปซื้อของ	13.680	0.003
กิจกรรมกีฬา (การช้อปปิ้ง)	7.467	0.058
อื่นๆ	15.047	0.002
ทำงานนอกบ้าน	17.174	0.001
ไม่ทำงาน/อยู่บ้าน	4.330	0.228

จากตาราง Likelihood Ratio Tests พบว่าค่าใช้จ่ายสำหรับการเดินทางมีค่าความแตกต่างของ $-2 \text{ Log Likelihood}$ สูงสุด ($\chi^2 = 1347.140$, Sig = 0.000) สะท้อนให้เห็นว่าปัจจัยที่มีผลกระทบต่อการเลือกโหมดการเดินทางมากที่สุด รายได้เฉลี่ย มีค่า χ^2 สูงถึง 202.805 (Sig = 0.000) แสดงว่าประชากรสูงวัยที่มีความแตกต่างของระดับรายได้มีแนวโน้มเลือกโหมดการเดินทางที่ต่างจากกัน ระยะเวลาเดินทางมีผลสำคัญต่อการเลือกโหมดการเดินทาง ($\chi^2 = 88.436$, Sig = 0.000) จำนวนผู้ติดตามเป็นอีกปัจจัยที่มีอิทธิพลสูงต่อการเลือกใช้ขนส่งสาธารณะ ($\chi^2 = 203.299$, Sig = 0.000) เพศไม่มีผลต่อการเลือกรูปแบบการเดินทาง ($\chi^2 = 5.938$, Sig = 0.115) แสดงว่าพฤติกรรมการเดินทางของผู้ชายและผู้หญิงไม่ได้แตกต่างกันอย่างมีนัยสำคัญ สรุปได้ว่าค่าใช้จ่ายในการเดินทางเป็นปัจจัยที่มีผลต่อการเลือกโหมดการเดินทางมากที่สุด รายได้, ระยะเวลาเดินทาง และจำนวนผู้ติดตามมีผลอย่างมีนัยสำคัญต่อพฤติกรรมการเดินทางของผู้สูงอายุ และเพศไม่มีอิทธิพลต่อการเลือกรูปแบบการเดินทาง

4.6.3 การทดสอบสำหรับตรวจสอบความแม่นยำของโมเดลในการจำแนกหมวดหมู่โหมดการเดินทาง (Confusion Matrix)

ใช้แสดงผลการคาดการณ์ของแบบจำลองถดถอยโลจิสติกพหุกลุ่ม (Multinomial Logistic Regression) โดยแสดงสัดส่วน (ร้อยละ) ของจำนวนผู้ตอบที่โมเดลทำนายได้ถูกต้องและทำนายผิดเปรียบเทียบกับค่าจริงของการเลือกโหมด

ตารางที่ 4.12 ตารางแสดงความถูกต้องของการจำแนกกลุ่ม (Confusion Matrix)

		Actual			
		Car	Bus	Rail	Paratransit
Predicted	Car	65.60	1.83	0.00	12.06
	Bus	25.31	91.27	1.24	38.67
	Rail	0.00	0.30	98.76	0.42
	Paratransit	9.09	6.60	0.00	48.86
	Total	100.00	100.00	100.00	100.00

จากตาราง Classification Accuracy พบว่า โมเดลการถดถอยโลจิสติกพหุกลุ่ม (Multinomial Logistic Regression) มีความสามารถในการจำแนกรูปแบบการเดินทางของผู้สูงอายุในแต่ละประเภทได้ในระดับที่หลากหลาย โดยสามารถอธิบายผลการจำแนกของแต่ละโหมดได้ดังนี้ ผู้ที่ใช้รถไฟ (Rail) โมเดลสามารถจำแนกได้ถูกต้องมากที่สุด คิดเป็นร้อยละ 98.76 บ่งชี้ว่าประชากรสูงวัยที่เลือกเดินทางด้วยรถไฟมีลักษณะหรือปัจจัยเฉพาะที่จำแนกได้ชัดเจน ผู้ที่ใช้รถโดยสารประจำทาง (Bus) ถูกจำแนกได้ถูกต้องถึงร้อยละ 91.27 ซึ่งถือว่ามีความแม่นยำสูง แสดงว่าโมเดลสามารถจับลักษณะของกลุ่มนี้ได้อย่างมีประสิทธิภาพ ผู้ที่ใช้รถยนต์ส่วนตัว (Car) ถูกจำแนกได้ถูกต้องร้อยละ 65.60 แม้จะมีความแม่นยำในระดับปานกลาง แต่ยังมีการจำแนกผิดไปเป็น Bus และ Paratransit คิดเป็นร้อยละ 25.31 และร้อยละ 9.09 ตามลำดับ ซึ่งอาจเกิดจากลักษณะพฤติกรรมการเดินทางที่คล้ายคลึงกันบางบริบท ผู้ที่ใช้บริการขนส่งสาธารณะ (Paratransit) เช่น วินมอเตอร์ไซด์หรือรถสองแถว มีความแม่นยำในการจำแนกต่ำที่สุดที่ร้อยละ 48.86 ขณะที่อีกร้อยละ 38.67 ของกลุ่มนี้ถูกจำแนกผิดไปเป็นผู้ใช้รถโดยสารประจำทาง สะท้อนให้เห็นว่าการจำแนกนั้นไม่ถ่วงน้ำหนักกลุ่มผู้ใช้งาน Paratransit และความจำเป็นในการพิจารณาตัวแปรเพิ่มเติมในการวิเคราะห์ โดยภาพรวม โมเดลมีความแม่นยำสูงมากสำหรับโหมดที่มีลักษณะเฉพาะเด่นชัด เช่น Rail และ Bus ถึงแม้ว่าจะมีข้อจำกัดอยู่บ้างในความสามารถแยกแยะผู้ใช้โหมด Paratransit ซึ่งควรมีการปรับปรุงแบบจำลอง เช่น การเพิ่มตัวแปรที่สะท้อนถึงความสะดวกในการเข้าถึง เส้นทางท้องถิ่น หรือความถี่ในการเดินทาง เพื่อเพิ่มความแม่นยำในการคาดการณ์ในอนาคต

4.7 การเปรียบเทียบประสิทธิภาพของแบบจำลอง Machine Learning

เทคนิค Machine Learning (ML) ที่ใช้งานวิจัยนี้ ประกอบด้วย XGBoost, Random Forest และ CatBoost

4.7.1 การเปรียบเทียบผลบนชุดข้อมูลทดสอบและข้อมูลทั้งหมด

การเปรียบเทียบผลบนชุดข้อมูลทดสอบเพื่อให้ได้ผลลัพธ์ที่มีความแม่นยำและสามารถนำไปใช้ในทางปฏิบัติได้ มีการแบ่งข้อมูลเป็น 2 กลุ่ม ได้แก่ Test Data (30% ของข้อมูล

ทั้งหมด) ใช้ตรวจสอบความแม่นยำของแบบจำลอง และ Real Data (100% ของข้อมูลทั้งหมด) ใช้พยากรณ์แนวโน้มการเดินทางของผู้สูงอายุ โดยเราจะใช้ ค่าความแม่นยำ (Accuracy), Precision, Recall และ F1-Score ในการเปรียบเทียบผลลัพธ์ของชุดข้อมูล เพื่อประเมินประสิทธิภาพของแต่ละโมเดล

ตารางที่ 4.13 ผลลัพธ์จาก Test Data (30% ของข้อมูลทั้งหมด)

Model	Accuracy	Macro Precision	Macro Recall	Macro F1-Score
XGBoost	91%	0.93	0.92	0.92
Random Forest	93%	0.96	0.93	0.94
CatBoost	94%	0.95	0.95	0.95

จากตารางที่ 4.13 แสดงค่าตัวชี้วัดประสิทธิภาพของโมเดลการเรียนรู้ของ Machine Learning ทั้งสามแบบบนชุดข้อมูลทดสอบ (คิดเป็น 30% ของข้อมูลทั้งหมด) โดยพบว่า CatBoost มีความแม่นยำ (Accuracy) สูงสุดที่ 94% รองลงมาคือ Random Forest (93%) และ XGBoost (91%) ผลลัพธ์ที่มีประสิทธิภาพสูงในทั้งสามโมเดลนี้แสดงให้เห็นว่าเทคนิค Machine Learning มีความเหมาะสมอย่างยิ่งในการทำนายรูปแบบการเดินทางของประชากรสูงอายุ ในด้านค่า macro precision พบว่า Random Forest ให้ค่าดีที่สุด (0.96) รองลงมาคือ CatBoost (0.95) และ XGBoost (0.93) โดย precision คือสัดส่วนของการจำแนกที่เป็นบวกแล้วถูกต้องจริง ซึ่งสะท้อนว่า Random Forest มีอัตราการเกิดค่าบวกเทียม (false positives) ต่ำที่สุด สำหรับค่า macro recall ซึ่งวัดความสามารถในการตรวจจับข้อมูลบวกที่มีอยู่จริง พบว่า CatBoost มีค่า recall สูงที่สุด (0.95) เมื่อเทียบกับ Random Forest (0.93) และ XGBoost (0.92) ซึ่งแสดงให้เห็นว่า CatBoost สามารถลดการพลาดกรณีบวกจริง (false negatives) ได้ดีที่สุด สุดท้ายในแง่ของ macro F1-score ซึ่งเป็นค่าเฉลี่ยฮาร์โมนิกระหว่าง precision และ recall พบว่า CatBoost มีค่า F1-score สูงสุดที่ 0.95 รองลงมาคือ Random Forest (0.94) และ XGBoost (0.92) ซึ่งสะท้อนว่า CatBoost ให้ผลลัพธ์โดยรวมดีที่สุดบนชุดข้อมูลทดสอบ โดยสามารถรักษาสสมดุลระหว่าง precision และ recall ได้อย่างมีประสิทธิภาพ

ตารางที่ 4.14 ผลลัพธ์จาก Real Data (100% ของข้อมูลทั้งหมด)

Model	Accuracy	Macro Precision	Macro Recall	Macro F1-Score
XGBoost	98.73%	99.32%	98.62%	98.96%
Random Forest	99.83%	99.84%	99.83%	99.83%
CatBoost	99.83%	99.83%	99.83%	99.83%

ตารางที่ 4.14 แสดงค่าตัวชี้วัดประสิทธิภาพของโมเดลบนชุดข้อมูลทั้งหมด (100% ของข้อมูล) พบว่า Random Forest ให้ความแม่นยำ (Accuracy) สูงสุดที่ 99.83% ตามมาด้วย CatBoost (99.83%) และ XGBoost (98.73%) ซึ่งแตกต่างจากผลบนชุดข้อมูลทดสอบที่ CatBoost

ทำผลงานได้ดีที่สุด ความแตกต่างนี้อาจสะท้อนถึงความสามารถของ Random Forest ในการจับรูปแบบจากชุดข้อมูลขนาดใหญ่ได้ดีกว่า หรือเกิดจากลักษณะเฉพาะของการแบ่งข้อมูลฝึกทดสอบ

นอกจากนี้ Random Forest ยังมีค่า macro precision สูงสุด (99.84%), macro recall (99.83%) และ macro F1-score (99.83%) บนชุดข้อมูลทั้งหมด ขณะที่ CatBoost มีค่าตัวชี้วัดใกล้เคียงกับ Random Forest ในทุกตัวชี้วัด ส่วน XGBoost มีค่าต่ำกว่าเล็กน้อย ประสิทธิภาพที่สูงของทั้งสามโมเดลบนชุดข้อมูลทั้งหมด ยืนยันว่าโมเดลเหล่านี้มีความสามารถในการทำนายรูปแบบการเดินทางของประชากรสูงวัยได้อย่างมีประสิทธิภาพ และมีแนวโน้มที่จะถ่ายทอดผลได้ดีเมื่อประยุกต์ใช้กับข้อมูลใหม่

4.7.2 การวิเคราะห์ความสำคัญของตัวแปร (Feature Importance Analysis)

ตารางที่ 4.15 แสดงผลการวิเคราะห์ความสำคัญของตัวแปรจากแต่ละโมเดล


Variable	XGBoost	Random Forest	CatBoost
Travel cost	0.37	0.41	0.39
Income	0.29	0.34	0.32
Convenience in accessing public transportation	0.23	0.28	0.26
Age	0.18	0.21	0.20

จากตารางที่ 4.15 แสดงผลการวิเคราะห์ความสำคัญของตัวแปรจากแต่ละโมเดล Machine Learning เพื่อระบุปัจจัยที่ส่งผลต่อการเลือกรูปแบบการเดินทางของประชากรสูงวัย โดยพบว่า “ค่าใช้จ่ายในการเดินทาง” (Travel cost) เป็นปัจจัยที่สำคัญที่สุดในทั้งสามโมเดล โดยมีค่าความสำคัญเท่ากับ 0.37 สำหรับ XGBoost, 0.41 สำหรับ Random Forest และ 0.39 สำหรับ CatBoost ซึ่งผลลัพธ์ที่มีความสอดคล้องกันนี้ยืนยันถึงความสำคัญของปัจจัยด้านเศรษฐกิจต่อการตัดสินใจเดินทางของผู้สูงอายุ และยังสอดคล้องกับผลการวิเคราะห์จากแบบจำลอง MNL ที่แสดงให้เห็นว่าค่าใช้จ่ายมีผลเชิงลบอย่างมีนัยสำคัญต่อทุกโหมดการเดินทาง ตัวแปรที่สำคัญรองลงมาคือ “รายได้” (Income) โดยมีค่าความสำคัญอยู่ที่ 0.29 (XGBoost), 0.34 (Random Forest) และ 0.32 (CatBoost) ตามด้วย “ความสะดวกในการเข้าถึงระบบขนส่งสาธารณะ” และ “อายุ” ซึ่งพบว่ามีค่าความสำคัญในลำดับรอง ผลลัพธ์นี้สะท้อนถึงความสำคัญของมิติทางเศรษฐกิจในการเลือกโหมดการเดินทางของผู้สูงอายุ ขณะเดียวกันความสะดวกในการเข้าถึงแสดงให้เห็นถึงมิติด้านกายภาพที่มีผลต่อการตัดสินใจเช่นกัน การจัดอันดับความสำคัญของปัจจัยที่มีความสอดคล้องกันในทุกโมเดลแสดงถึงความน่าเชื่อถือของผลการวิเคราะห์ และแนะนำว่าปัจจัยเหล่านี้ควรถูกนำมาพิจารณาอย่างจริงจังในการกำหนดนโยบายหรือวางแผนระบบขนส่งสาธารณะสำหรับผู้สูงอายุ โดยเฉพาะเมื่อพบว่า “อายุ” มีความสำคัญน้อยกว่าปัจจัยด้านเศรษฐกิจ ซึ่งอาจหมายความว่าข้อจำกัดหรือความชอบที่เกี่ยวข้องกับอายุมีอิทธิพลน้อยกว่าความสามารถในการจ่ายค่าเดินทาง


4.7.3 การวิเคราะห์ SHAP เพื่อการตีความผลของโมเดล

การวิเคราะห์ด้วย SHAP (Shapley Additive Explanations) ช่วยให้เข้าใจเชิงลึกยิ่งขึ้นว่าแต่ละปัจจัยส่งผลอย่างไรต่อการตัดสินใจเลือกรูปแบบการเดินทาง รูปที่ 4.2 แสดงค่าความสำคัญของตัวแปรในโมเดล CatBoost โดยพบว่าปัจจัยที่สำคัญ ได้แก่ ค่าใช้จ่ายในการเดินทาง, ระยะทาง, รายได้, เวลาเดินทาง, อายุ, และจำนวนผู้ร่วมเดินทาง ซึ่งยืนยันผลลัพธ์จากการวิเคราะห์ตัวแปรสำคัญในแต่ละโมเดล และให้มุมมองเชิงเปรียบเทียบที่ลึกขึ้น รูปที่ 4.3 แสดง แผนภาพปฏิสัมพันธ์ของ SHAP ซึ่งแสดงความสัมพันธ์ที่ซับซ้อนระหว่างตัวแปรต่าง ๆ โดยพบว่าปัจจัยบางอย่างมีอิทธิพลร่วมกันต่อการตัดสินใจ เช่น ความสัมพันธ์ระหว่าง รายได้กับค่าใช้จ่ายในการเดินทาง ซึ่งพบว่า ผู้สูงอายุที่มีรายได้น้อยมีความอ่อนไหวต่อค่าใช้จ่ายในการเดินทางมากกว่า ผู้ที่มีรายได้สูง รูปที่ 4.4–4.7 แสดงการมีส่วนร่วมของตัวแปรในแต่ละโหมดการเดินทาง ได้แก่ รถยนต์ส่วนตัว, รถโดยสาร, รถไฟ, และรถขนส่งสาธารณะ ดังนี้: รูปที่ 4.4 (โหมดรถยนต์ส่วนตัว): รายได้ที่สูงและค่าใช้จ่ายในการเดินทางที่สูง มีแนวโน้มที่จะเลือกใช้รถยนต์ส่วนบุคคลมากกว่า ขณะที่การมีผู้ร่วมเดินทางกลับลดโอกาสดังกล่าว ซึ่งอาจสะท้อนถึงข้อได้เปรียบทางเศรษฐกิจในการเดินทางร่วมกัน โดยระบบขนส่งสาธารณะ รูปที่ 4.5 (โหมดรถโดยสาร): รายได้ต่ำ ค่าเดินทางต่ำ และการมีผู้ร่วมเดินทาง เพิ่มความเป็นไปได้ที่จะเลือกใช้รถโดยสาร ซึ่งสอดคล้องกับทฤษฎีเศรษฐศาสตร์และผลลัพธ์จากแบบจำลอง MNL ว่าผู้สูงอายุที่คำนึงถึงค่าใช้จ่ายมักเลือกใช้บริการรถโดยสารเป็นหลัก รูปที่ 4.6 (โหมดรถไฟ): เวลาเดินทางนาน ระยะทางไกล และค่าใช้จ่ายต่ำ ส่งผลให้มีแนวโน้มเลือกเดินทางโดยรถไฟมากขึ้น แสดงให้เห็นว่ารถไฟเป็นทางเลือกที่เหมาะสมสำหรับการเดินทางระยะไกล ซึ่งประหยัดและสะดวกสบายมากกว่าทางเลือกอื่น ๆ และรูปที่ 4.7 (โหมดรถขนส่งสาธารณะ): การมีผู้ร่วมเดินทาง เวลาเดินทางสั้น และระดับรายได้ปานกลาง เพิ่มโอกาสในการเลือกใช้รถขนส่งสาธารณะ ซึ่งอาจแสดงถึงความนิยมของการเดินทางแบบกลุ่มหรือเดินทางระยะสั้นที่ต้องการความยืดหยุ่นและบริการถึงที่


การวิเคราะห์ SHAP เหล่านี้ช่วยให้เข้าใจเชิงลึกถึงกระบวนการตัดสินใจของผู้สูงอายุ โดยสามารถระบุความสัมพันธ์ที่ไม่เป็นเชิงเส้น (non-linear) และปฏิสัมพันธ์ระหว่างตัวแปรที่แบบจำลองทางสถิติทั่วไปอาจไม่สามารถจับได้ จึงมีประโยชน์อย่างยิ่งต่อการออกแบบนโยบายและบริการขนส่งที่ตอบโจทย์กลุ่มผู้สูงอายุได้อย่างตรงจุด




รูปที่ 4.2 Feature Importance of CatBoost




รูปที่ 4.3 SHAP Interaction Plot




รูปที่ 4.4 SHAP Contribution by Mode – Car



รูปที่ 4.5 SHAP Contribution by Mode - Bus



รูปที่ 4.6 SHAP Contribution by Mode – Rail



รูปที่ 4.7 SHAP Contribution by Mode - Paratransit

4.8 การเปรียบเทียบการวิเคราะห์ทางสถิติกับ Machine Learning

การศึกษานี้ใช้ 2 แนวทางหลัก ในการวิเคราะห์ปัจจัยที่มีผลต่อการเลือกรูปแบบการเดินทางของผู้สูงอายุ ได้แก่ 1.แบบจำลองสถิติ Multinomial Logit (MNL) ซึ่งใช้กันอย่างแพร่หลายในการศึกษาพฤติกรรมทางเลือกของบุคคล และ 2.เทคนิค Machine Learning (ML) ซึ่งประกอบด้วย XGBoost, Random Forest และ CatBoost

ตารางที่ 4.16 Confusion Matrix

Methode	Predicted	Actual			
		Car	Bus	Rail	Paratransit
Random Forest	Car	396.00	2.00	0.00	9.00
	Bus	1.00	973.00	0.00	11.00
	Rail	0.00	2.00	159.00	0.00
	Paratransit	5.00	20.00	0.00	456.00
	Total	402.00	997.00	159.00	476.00
XGBoost	Car	403.00	0.00	0.00	4.00
	Bus	0.00	968.00	0.00	17.00
	Rail	0.00	2.00	159.00	0.00
	Paratransit	3.00	9.00	0.00	469.00
	Total	406.00	979.00	159.00	490.00
CatBoost	Car	363.00	15.00	0.00	29.00
	Bus	5.00	943.00	0.00	37.00
	Rail	0.00	2.00	159.00	0.00
	Paratransit	20.00	84.00	2.00	375.00
	Total	388.00	1044.00	161.00	441.00
MNL	Car	267.00	18.00	0.00	58.00
	Bus	103.00	899.00	2.00	186.00
	Rail	0.00	3.00	159.00	2.00
	Paratransit	37.00	65.00	0.00	235.00
	Total	407.00	985.00	161.00	481.00

ตารางที่ 4.16 แสดงผลลัพธ์จาก Confusion Matrix ของแต่ละโมเดล โดยให้รายละเอียดเกี่ยวกับจำนวนที่จำแนกถูกต้องและผิดพลาดของแต่ละโหมดการเดินทาง โดยเฉพาะในกลุ่มผู้สูงอายุ ในกลุ่มของโมเดล Machine Learning นั้น XGBoost แสดงความแม่นยำสูงสุด โดยสามารถจำแนกผู้ใช้ รถยนต์ส่วนตัวได้ถูกต้องถึง 99.26%, รถโดยสาร 98.88%, รถไฟ 100% และ รถขนส่งสาธารณะ 95.71% ขณะที่ Random Forest ทำผลงานรองลงมาโดยจำแนกถูกต้องที่ รถยนต์ 98.51%, รถโดยสาร 97.59%, รถไฟ 100%, และ รถขนส่งสาธารณะ 95.80% โดยข้อผิดพลาด

หลักของทั้งสองโมเดลเกิดในหมวด รถขนส่งสาธารณะ ซึ่งมีการจำแนกผิดเป็น รถโดยสาร อยู่บ้าง (2.31% สำหรับ Random Forest และ 3.47% สำหรับ XGBoost) ซึ่งถือว่าน้อยมาก แสดงให้เห็นว่าโมเดลทั้งสองสามารถจับรูปแบบข้อมูลที่ซับซ้อนได้อย่างมีประสิทธิภาพและสามารถแยกแยะโหมดการเดินทางได้ดี ความสามารถในการจำแนก โหมดรถไฟได้อย่างสมบูรณ์ (100%) ในทั้ง XGBoost และ Random Forest สะท้อนว่าโหมดรถไฟในประเทศไทยมีลักษณะที่โดดเด่น เช่น ใช้ระยะทางไกล และมีเส้นทางเฉพาะเจาะจง ซึ่งเอื้อต่อการจำแนกจากโหมดอื่น CatBoost มีความแม่นยำต่ำกว่าเล็กน้อยแต่ยังถือว่าอยู่ในเกณฑ์ดี โดยสามารถจำแนก รถยนต์ 93.56%, รถโดยสาร 90.33%, รถไฟ 98.76%, และ รถขนส่งสาธารณะ 85.03% ความผิดพลาดส่วนใหญ่เกิดจากการจำแนกผิดระหว่างรถโดยสารกับรถขนส่งสาธารณะ โดยพบว่า 8.05% ของผู้ใช้รถขนส่งสาธารณะจริงถูกจำแนกเป็นรถโดยสาร, และ 8.39% ของผู้ใช้รถโดยสารจริงถูกจำแนกเป็นรถขนส่งสาธารณะ ซึ่งบ่งชี้ว่าโหมดขนส่งสาธารณะที่มีลักษณะแชร์การใช้บริการ (เช่น รถโดยสารและรถขนส่งสาธารณะ) อาจมีคุณลักษณะซ้อนทับกัน จึงท้าทายต่อการจำแนกที่ชัดเจน ในทางตรงกันข้าม โมเดล MNL (Multinomial Logit) มีความแม่นยำต่ำกว่าชัดเจนในหลายโหมด โดยจำแนกได้ถูกต้องเพียง 65.60% สำหรับรถยนต์, 91.27% สำหรับรถโดยสาร, 98.76% สำหรับรถไฟ, และเพียง 48.86% สำหรับรถขนส่งสาธารณะ โดยเฉพาะในโหมดรถยนต์และรถขนส่งสาธารณะที่จำแนกผิดเป็นรถโดยสารสูงถึง 25.31% และ 38.67% ตามลำดับ ผลลัพธ์นี้สะท้อนถึง ความเอนเอียงของโมเดล MNL ที่มักจะทำนายว่าเป็น "รถโดยสาร" แม้ในกรณีที่ไม่ใช่ ซึ่งเป็นผลจากข้อจำกัดของโมเดล MNL ที่ไม่สามารถจับความสัมพันธ์ที่ไม่เป็นเชิงเส้นหรือการปฏิสัมพันธ์ระหว่างตัวแปรได้ดีเท่ากับโมเดล ML ที่น่าสังเกตคือทุกรูปแบบของโมเดลสามารถจำแนกรถไฟได้แม่นยำมาก (98.76%-100%) ซึ่งตอกย้ำว่าการเดินทางด้วยรถไฟมีลักษณะเฉพาะตัวที่ชัดเจน อย่างไรก็ตาม ความแตกต่างอย่างชัดเจนระหว่าง ความแม่นยำสูงของโมเดล Machine Learning กับ ผลลัพธ์ที่ต่ำกว่าของโมเดล MNL ชี้ให้เห็นถึง ข้อได้เปรียบของ ML ที่สามารถเรียนรู้ความสัมพันธ์ที่ซับซ้อนโดยไม่ต้องกำหนดสมการล่วงหน้า ทำให้เหมาะสมอย่างยิ่งในการใช้เพื่อทำนายพฤติกรรมทางเลือกโหมดเดินทางของผู้สูงวัยในบริบทที่มีปัจจัยหลายมิติร่วมกัน

ตารางที่ 4.17 การเปรียบเทียบ Accuracy ของแต่ละโมเดล

Model	Overall Accuracy	Predicted			
		Car	Bus	Rail	Paratransit
Random Forest	97.54%	98.51%	97.59%	100.00%	95.80%
XGBoost	98.28%	99.26%	98.88%	100.00%	95.71%
CatBoost	90.46%	93.56%	90.33%	98.76%	85.03%
MNL	76.70%	65.60%	91.27%	98.76%	48.86%

จากตารางที่ 4.17 แสดงการเปรียบเทียบความแม่นยำในการทำนายโหมดการเดินทางของผู้สูงอายุจากการใช้โมเดลต่าง ๆ ได้แก่ Random Forest, XGBoost, CatBoost และ Multinomial

Logistic Regression (MNL) โดยแบ่งการทำนายออกเป็นโหมดต่าง ๆ ได้แก่ รถยนต์ (Car), รถประจำทาง (Bus), รถไฟ (Rail) และรถขนส่งสาธารณะ (Paratransit) ผลลัพธ์ที่ได้จากตารางนี้พบว่า XGBoost เป็นโมเดลที่ให้ผลลัพธ์ที่ดีที่สุดในด้านความแม่นยำโดยรวมและการทำนายแต่ละโหมดการเดินทาง ขณะที่ Random Forest เป็นตัวเลือกที่ดีเช่นกัน โดยเฉพาะในโหมดรถยนต์และรถขนส่งสาธารณะ ส่วน CatBoost และ MNL แสดงผลการทำนายที่ต่ำกว่า โดยเฉพาะในบางโหมดเช่น รถยนต์และรถขนส่งสาธารณะ



บทที่ 5

สรุปผลการวิจัย อภิปรายผล และข้อเสนอแนะ

การวิจัยนี้เผยให้เห็นข้อค้นพบที่สำคัญหลายประการเกี่ยวกับพฤติกรรมการเดินทางของผู้สูงอายุในประเทศไทย และแสดงให้เห็นถึงความแตกต่างในประสิทธิภาพระหว่างวิธีทางสถิติแบบดั้งเดิมกับวิธีการเรียนรู้ของเครื่อง (Machine Learning) ในการวิเคราะห์การเลือกรูปแบบการเดินทาง ผลการศึกษาเน้นให้เห็นถึงความสัมพันธ์ที่ซับซ้อนระหว่างปัจจัยทางเศรษฐกิจ สังคม และปัจจัยด้านความสะดวกที่มีอิทธิพลต่อการตัดสินใจด้านการเดินทางของประชากรสูงอายุ และผลของปัจจัยที่มีอิทธิพลต่อพฤติกรรมการเดินทางของประชากรสูงอายุของเมืองภูมิภาคในประเทศไทย โดยใช้แนวคิดจากทฤษฎีพฤติกรรมตามแผน (TPB) เป็นพื้นฐานในการวิเคราะห์ และการวิเคราะห์เชิงปริมาณ ได้แก่ การวิเคราะห์โครงสร้างปัจจัยโดยใช้เทคนิค CFA, การวิเคราะห์ด้วยแบบจำลองสมการโครงสร้าง (SEM)

5.1 สรุปผลการศึกษา

5.1.1 ปัจจัยกำหนดการเลือกรูปแบบการเดินทางของผู้สูงอายุ

ผลการวิเคราะห์ของเราชี้ให้เห็นอย่างต่อนื่องว่า "ค่าใช้จ่ายในการเดินทาง" เป็นปัจจัยที่มีอิทธิพลมากที่สุดต่อการเลือกรูปแบบการเดินทางของผู้สูงอายุในทุกวิธีการวิเคราะห์ ทั้งในแบบจำลองถดถอยโลจิสติกพหุกลุ่ม (Multinomial Logit: MNL) ซึ่งแสดงค่าสัมประสิทธิ์เชิงลบอย่างมีนัยสำคัญในทุกรูปแบบทางเลือก และในแบบจำลอง Machine Learning ที่การวิเคราะห์ความสำคัญของตัวแปรจัดอันดับให้ "ค่าใช้จ่าย" เป็นตัวแปรสำคัญสูงสุด ความอ่อนไหวต่อค่าใช้จ่ายนี้อาจสะท้อนถึงรายได้ที่ค่อนข้างต่ำของผู้สูงอายุ โดย 78.7% ของผู้ตอบแบบสอบถามมีรายได้ต่ำกว่า 10,000 บาทต่อเดือน ซึ่งความเปราะบางทางเศรษฐกิจนี้ทำให้ประเด็นด้านค่าใช้จ่ายกลายเป็นปัจจัยสำคัญในการตัดสินใจเลือกวิธีเดินทาง

"รายได้" ปรากฏเป็นปัจจัยที่มีอิทธิพลอันดับสอง โดยผู้สูงอายุที่มีรายได้สูงมีแนวโน้มจะเลือกใช้รถยนต์ส่วนตัวมากกว่าการใช้ขนส่งสาธารณะ ความสัมพันธ์ระหว่างรายได้กับการเลือกโหมดการเดินทางนี้สอดคล้องกับทฤษฎีเศรษฐศาสตร์ ซึ่งชี้ว่า ผู้ที่มีรายได้สูงสามารถให้ความสำคัญกับความสะดวกสบายมากกว่าค่าใช้จ่าย ทั้งนี้แบบจำลอง MNL พบค่าสัมประสิทธิ์เชิงลบที่มีนัยสำคัญของรายได้ในทุกโหมดขนส่งสาธารณะ (รถโดยสาร รถไฟ และพาราแท็กซี่) เมื่อเปรียบเทียบกับการใช้รถยนต์ส่วนตัว ซึ่งยืนยันข้อสังเกตดังกล่าว

การมีเพื่อนร่วมเดินทางมีอิทธิพลต่อการเลือกรูปแบบการเดินทางอย่างมีนัยสำคัญ โดยเฉพาะในกรณีของรถโดยสารและพาราแท็กซี่ ซึ่งค่าสัมประสิทธิ์ในแบบจำลอง MNL มีค่าเป็นบวก อย่างชัดเจน ($OR = 9.754$ สำหรับรถโดยสาร และ $OR = 8.357$ สำหรับพาราแท็กซี่) แสดงให้เห็นว่า เมื่อมีผู้ร่วมเดินทาง ความน่าจะเป็นที่จะเลือกโหมดเหล่านี้เพิ่มขึ้นอย่างมากเมื่อเทียบกับรถยนต์ส่วนตัว ข้อค้นพบนี้ขัดแย้งกับสมมติฐานที่ว่าผู้สูงอายุมักชอบใช้รถยนต์ส่วนตัว และสะท้อนให้เห็นว่า ขนส่งสาธารณะอาจเป็นทางเลือกที่น่าสนใจสำหรับการเดินทางแบบกลุ่ม โดยเฉพาะเมื่อมีการแบ่งปัน ค่าใช้จ่ายหรือมีแรงจูงใจด้านสังคม

เวลาเดินทางและระยะทางมีผลกระทบที่แตกต่างกันตามรูปแบบการเดินทาง โดยเฉพาะในกรณีของรถไฟ ทั้งสองปัจจัยมีค่าสัมประสิทธิ์เป็นบวก แสดงว่าเมื่อระยะทางและเวลาเดินทางเพิ่มขึ้น ผู้สูงอายุมีแนวโน้มเลือกใช้รถไฟมากขึ้น เนื่องจากข้อได้เปรียบด้านความเร็วและความ สะดวก ในทางกลับกัน พาราแท็กซี่มีค่าสัมประสิทธิ์เชิงลบในเรื่องเวลาเดินทาง ซึ่งบ่งชี้ว่ารูปแบบนี้ เป็นที่นิยมสำหรับการเดินทางระยะสั้น อาจเนื่องมาจากต้นทุนต่อระยะทางที่สูงกว่ารูปแบบขนส่ง สาธารณะอื่น ๆ

5.1.2 การเปรียบเทียบวิธีการวิเคราะห์

การเปรียบเทียบประสิทธิภาพระหว่างการใช้แบบจำลองทางสถิติแบบดั้งเดิมกับ เทคนิคการเรียนรู้ของเครื่อง (Machine Learning) พบความแตกต่างที่น่าสนใจ โดยวิธีการของ Machine Learning แสดงประสิทธิภาพที่เหนือกว่าแบบจำลอง MNL อย่างต่อเนื่องในด้านความ แม่นยำในการพยากรณ์ โดยเฉพาะโมเดลที่มีประสิทธิภาพสูงสุดอย่าง CatBoost ที่สามารถทำนายได้ อย่างแม่นยำถึง 94% ในชุดข้อมูลทดสอบ เมื่อเทียบกับแบบจำลอง MNL ซึ่งมีความแม่นยำต่ำกว่า อย่างชัดเจน โดยเฉพาะในโหมดการเดินทางด้วยรถยนต์ส่วนตัว (65.60%) และพาราแท็กซี่ (48.86%)

การวิเคราะห์เมทริกซ์ความสับสน (Confusion Matrix) เผยให้เห็นว่ามีอคติในเชิง ระบบของแบบจำลอง MNL ที่มักคาดการณ์ให้ผู้โดยสารและพาราแท็กซี่เป็นผู้โดยสารรถโดยสาร สาธารณะผิดพลาดในสัดส่วนที่สูง ข้อจำกัดนี้สะท้อนว่า แม้แบบจำลอง MNL จะมีพื้นฐานทางทฤษฎี ที่มั่นคงและข้อได้เปรียบด้านความเข้าใจง่ายในการตีความ แต่ก็อาจไม่สามารถจับความสัมพันธ์ที่ ซับซ้อนและไม่เป็นเชิงเส้นระหว่างตัวแปรที่จำแนกโหมดการเดินทางต่าง ๆ ได้อย่างครบถ้วน

ในบรรดาเทคนิค Machine Learning นั้น CatBoost แสดงประสิทธิภาพสูงสุดใน ชุดข้อมูลทดสอบ โดยมีความแม่นยำ 94% ขณะที่ Random Forest ทำผลงานดีที่สุดในการรวม ทั้งหมด ด้วยความแม่นยำสูงถึง 99.83% ความแตกต่างนี้เน้นให้เห็นถึงความสำคัญของการเลือก โมเดลให้เหมาะสมกับลักษณะของข้อมูลและเป้าหมายการวิเคราะห์ นอกจากนี้ การวิเคราะห์ด้วย SHAP ยังช่วยให้เข้าใจความสัมพันธ์ที่ซับซ้อนระหว่างปัจจัยต่าง ๆ กับการเลือกรูปแบบการเดินทางได้ อย่างลึกซึ้ง ซึ่งเป็นสิ่งที่เสริมจากการตีความแบบตรงไปตรงมาของ MNL

นอกจากผลการพยากรณ์ที่เปรียบเทียบระหว่าง MNL และ Machine Learning แล้ว การวิเคราะห์ด้วย การวิเคราะห์องค์ประกอบเชิงยืนยัน (CFA) และ การวิเคราะห์แบบจำลองโครงสร้าง (SEM) ยังถูกนำมาใช้เพื่อตรวจสอบความถูกต้องของโครงสร้างทฤษฎี และกลไกเชิงพฤติกรรมที่อยู่เบื้องหลังความตั้งใจของผู้สูงอายุในการใช้บริการขนส่งสาธารณะ โดยใช้กรอบแนวคิด ทฤษฎีพฤติกรรมตามแผน (Theory of Planned Behavior: TPB)

ผลการวิเคราะห์ CFA แสดงให้เห็นว่า ตัวแปรแฝง ได้แก่ ทศนคติ (Attitude), บรรทัดฐานกลุ่มอ้างอิง (Subjective Norm) และ การรับรู้การควบคุมพฤติกรรม (Perceived Behavioral Control) มีค่า factor loading มากกว่า 0.60 และมีค่าดัชนีความพอดีของโมเดลในระดับที่ยอมรับได้ (เช่น CFI > 0.95 และ RMSEA < 0.06) บ่งชี้ว่าโครงสร้างของ TPB มีความถูกต้อง และเหมาะสมกับการศึกษา

ในส่วนของ SEM ผลการวิเคราะห์แสดงให้เห็นว่า ตัวแปรแฝงทั้งสามมีอิทธิพลอย่างมีนัยสำคัญต่อความตั้งใจในการใช้ขนส่งสาธารณะ โดย ทศนคติ ($\beta = 0.321, p < 0.001$), บรรทัดฐานกลุ่มอ้างอิง ($\beta = 0.060, p < 0.001$) และ การรับรู้การควบคุมพฤติกรรม ($\beta = 0.346, p < 0.001$) ล้วนมีผลในเชิงบวกต่อพฤติกรรม และแบบจำลองสามารถอธิบายความแปรปรวนของความตั้งใจได้ถึง 71.5% ($R^2 = 0.715$) ซึ่งถือว่าสูงมาก

ผลลัพธ์จาก SEM นี้ช่วยเสริมความเข้าใจเกี่ยวกับบทบาทของปัจจัยทางจิตวิทยา และสังคมในการตัดสินใจของผู้สูงอายุ ซึ่งอาจไม่ปรากฏชัดใน MNL หรือ Machine Learning ที่มุ่งวิเคราะห์ตัวแปรที่สังเกตได้เป็นหลัก

โดยสรุป การใช้วิธีวิเคราะห์ที่หลากหลาย ทั้ง MNL, Machine Learning, CFA และ SEM ทำให้เกิดความเข้าใจเชิงลึกและรอบด้านต่อพฤติกรรมการเดินทางของผู้สูงอายุ โดยแต่ละวิธีมีจุดแข็งเฉพาะตัว ได้แก่ Machine Learning สำหรับการพยากรณ์ที่แม่นยำ, MNL สำหรับการตีความเชิงนโยบาย และ SEM สำหรับการอธิบายกลไกทางพฤติกรรมในระดับทฤษฎี การบูรณาการระหว่างวิธีเชิงปริมาณและทฤษฎีเชิงพฤติกรรมนี้จึงเป็นแนวทางที่มีประสิทธิภาพในการศึกษาปัญหาการเดินทางของประชากรสูงอายุอย่างครบถ้วน

5.2 การเปรียบเทียบกับงานวิจัยที่ผ่านมา

ผลการศึกษาโดยรวมมีความสอดคล้องกับงานวิจัยก่อนหน้าเกี่ยวกับพฤติกรรมการเดินทางของผู้สูงอายุ พร้อมทั้งให้ข้อมูลเชิงลึกใหม่ในบริบทของประเทศไทย โดยเฉพาะปัจจัยด้านเศรษฐกิจ เช่น ค่าใช้จ่ายในการเดินทางและรายได้ ซึ่งมีอิทธิพลอย่างมีนัยสำคัญต่อการตัดสินใจของผู้สูงอายุในประเทศไทย ผลลัพธ์นี้สอดคล้องกับงานของ Lui et al. (2018) ที่ระบุว่าข้อจำกัดทางการเงินเป็นปัจจัยสำคัญในการเลือกโหมดการเดินทางของผู้สูงอายุ นอกจากนี้ การที่เวลาในการเดินทางส่งผลต่อ

การเลือกโหนด โดยเฉพาะในกรณีของรถไฟ ก็สอดคล้องกับ Holmes et al. (2024) ที่พบว่าผู้สูงอายุบางกลุ่มให้ความสำคัญกับระยะเวลาการเดินทางมากกว่าค่าใช้จ่าย

ผลการเปรียบเทียบประสิทธิภาพระหว่างโมเดล Machine Learning กับวิธีการทางสถิติแบบดั้งเดิม ยังสอดคล้องกับงานของ Huang et al. (2024) ซึ่งระบุว่า Machine Learning มีความแม่นยำสูงกว่า (94.30%) เมื่อใช้พยากรณ์รูปแบบการเดินทางของผู้สูงอายุในการเข้ารับบริการทางการแพทย์ในประเทศจีน โดยงานวิจัยนี้ขยายขอบเขตของข้อค้นพบดังกล่าวไปสู่พฤติกรรมการเดินทางทั่วไปในบริบทของประเทศไทย ซึ่งแสดงระดับความแม่นยำที่ใกล้เคียงกัน (CatBoost 94% บนชุดทดสอบ และ Random Forest 99.83% บนชุดข้อมูลรวม)

อย่างไรก็ตาม การใช้บริการรถโดยสารในกลุ่มผู้สูงอายุไทยในระดับสูง (48.4%) มีความแตกต่างจากผลการศึกษาในเขตเมืองของจีนโดย Wei et al. (2024) ซึ่งสะท้อนถึงความแตกต่างด้านโครงสร้างพื้นฐานการคมนาคมและรูปแบบการพัฒนาเมืองระหว่างทั้งสองประเทศ ขณะเดียวกัน อิทธิพลของความสามารถทางกายภาพต่อการเลือกโหมดการเดินทางก็สอดคล้องกับงานของ Shi et al. (2024) ที่ระบุว่าลักษณะทางกายภาพเป็นปัจจัยสำคัญในการกำหนดรูปแบบการเดินทางของผู้สูงอายุ

นอกจากนี้ ข้อค้นพบที่ว่า การมีเพื่อนร่วมเดินทางส่งผลต่อการเลือกใช้ระบบขนส่งสาธารณะ ยังถือเป็นมุมมองที่แตกต่างจากงานของ Zhang et al. (2024) ซึ่งศึกษาความแตกต่างของพฤติกรรมการเดินทางระหว่างผู้สูงอายุในเขตเมืองและชนบทของญี่ปุ่น แม้ว่าการวิจัยนี้จะไม่ได้เปรียบเทียบโดยตรงระหว่างเขตเมืองกับชนบท แต่ผลที่แสดงถึงอิทธิพลของปัจจัยทางสังคมอย่างชัดเจนชี้ให้เห็นว่าองค์ประกอบทางสังคมอาจมีอิทธิพลต่อพฤติกรรมการเดินทางของผู้สูงอายุในทุกบริบทภูมิศาสตร์

สุดท้าย ความแม่นยำของโมเดล Random Forest ในการวิเคราะห์ข้อมูลชุดเต็มที่สูงถึง 99.83% มีความสอดคล้องกับผลการศึกษาของ Hong et al. (2024) ในเกาหลีใต้ ซึ่งใช้เทคนิคเดียวกันและได้ความแม่นยำที่ 92.30% และงานของ Champahom et al. (2025) ในประเทศไทยที่ใช้แบบจำลองลอจิสติกและได้ความแม่นยำที่ 94.20% ความสอดคล้องในประสิทธิภาพของโมเดลในบริบทเอเชียที่หลากหลายนี้ แสดงให้เห็นว่าวิธีวิเคราะห์ขั้นสูงสามารถจับรูปแบบการเดินทางของผู้สูงอายุได้อย่างแม่นยำ แม้จะมีความแตกต่างด้านวัฒนธรรมและโครงสร้างพื้นฐานก็ตาม

5.3 ข้อเสนอเชิงระเบียบวิธี: การเปรียบเทียบระหว่าง MNL และ Machine Learning

การวิเคราะห์เชิงเปรียบเทียบระหว่างวิธีการทางสถิติแบบดั้งเดิมกับวิธีการเรียนรู้ของเครื่อง (Machine Learning) ในงานวิจัยนี้ นำเสนอข้อเสนอเชิงระเบียบวิธีที่สำคัญสำหรับการศึกษาด้านการขนส่ง แม้ว่าแบบจำลองลอจิสติกทุกกลุ่ม (MNL) จะมีพื้นฐานทางทฤษฎีที่ชัดเจนจากแนวคิดการเพิ่ม

อรรถประโยชน์ (Utility Maximization) และสามารถตีความค่าสัมประสิทธิ์ได้โดยตรง แต่ข้อจำกัดด้านความแม่นยำในการพยากรณ์ชี้ให้เห็นว่าแบบจำลองนี้อาจไม่สามารถสะท้อนความซับซ้อนของกระบวนการตัดสินใจด้านการเดินทางของผู้สูงอายุได้อย่างครบถ้วน

ในทางกลับกัน วิธีการแบบ Machine Learning แสดงให้เห็นถึงประสิทธิภาพในการพยากรณ์ที่เหนือกว่า โดยทั้งสามอัลกอริธึม (XGBoost, Random Forest และ CatBoost) มีความแม่นยำเกินกว่า 90% ข้อได้เปรียบนี้มีแนวโน้มที่จะเกิดจากความสามารถของโมเดลในการตรวจจับความสัมพันธ์แบบไม่เป็นเชิงเส้นและปฏิสัมพันธ์ระหว่างตัวแปรที่ซับซ้อน โดยไม่จำเป็นต้องกำหนดไว้ล่วงหน้า ซึ่งแตกต่างจากแบบจำลอง MNL ที่ต้องระบุปฏิสัมพันธ์ระหว่างตัวแปรล่วงหน้าตามสมมติฐานทางทฤษฎี

อย่างไรก็ตาม ข้อวิจารณ์ที่พบโดยทั่วไปต่อ Machine Learning ในฐานะที่เป็น “กล่องดำ” (black box) ที่ตีความได้ยากนั้น ถูกบรรเทาลงบางส่วนในงานวิจัยนี้ผ่านการวิเคราะห์ความสำคัญของตัวแปร (Feature Importance) และ SHAP ซึ่งช่วยให้เข้าใจถึงลำดับความสำคัญและผลกระทบเฉพาะของแต่ละตัวแปรต่อโหมดการเดินทางแต่ละประเภท เพิ่มระดับความเข้าใจและความโปร่งใสในผลลัพธ์ของ Machine Learning นอกจากนี้ ความสอดคล้องของลำดับความสำคัญของปัจจัยจากทั้งสามโมเดล Machine Learning ยังเป็นหลักฐานที่น่าเชื่อถือว่าปัจจัยเหล่านี้มีบทบาทสำคัญต่อพฤติกรรมการเดินทางของผู้สูงอายุ

จากข้อค้นพบดังกล่าว แสดงให้เห็นว่าทั้งวิธีการทางสถิติแบบดั้งเดิมและ Machine Learning ต่างมีจุดแข็งในแบบของตน การใช้แบบจำลอง MNL ช่วยให้เข้าใจโครงสร้างพฤติกรรมการเดินทางบนพื้นฐานทฤษฎี ขณะที่ Machine Learning ให้ความแม่นยำสูงกว่าในการพยากรณ์ และสามารถค้นหาความสัมพันธ์เชิงลึกที่อาจมองไม่เห็นในการวิเคราะห์แบบดั้งเดิม การผสมผสานทั้งสองแนวทางจึงสามารถให้ข้อค้นพบที่ครอบคลุมและลึกซึ้งมากกว่าการใช้วิธีใดวิธีหนึ่งเพียงลำพัง

5.4 ข้อเสนอเชิงระเบียบวิธี: การประยุกต์ใช้ CFA และ SEM

การประยุกต์ใช้การวิเคราะห์องค์ประกอบเชิงยืนยัน (Confirmatory Factor Analysis: CFA) และแบบจำลองสมการโครงสร้าง (Structural Equation Modeling: SEM) ในการศึกษาช่วยให้เกิดข้อเสนอเชิงระเบียบวิธีที่สำคัญในการทำความเข้าใจเจตนาพฤติกรรมของผู้สูงอายุในการใช้บริการขนส่งสาธารณะ โดยอิงตามกรอบแนวคิดของทฤษฎีพฤติกรรมตามแผน (Theory of Planned Behavior: TPB) ซึ่งเป็นกรอบแนวคิดเชิงทฤษฎีที่ชัดเจนและสามารถนำมาวิเคราะห์ความสัมพันธ์ระหว่างตัวแปรแฝงได้อย่างมีประสิทธิภาพ

ในขั้นแรก CFA ถูกนำมาใช้เพื่อยืนยันว่า ตัวแปรที่สังเกตได้สามารถแทนค่าตัวแปรแฝง ได้แก่ ทัศนคติ (Attitude toward Behavior: ATT), บรรทัดฐานกลุ่มอ้างอิง (Subjective Norm: SN) และ

การรับรู้การควบคุมพฤติกรรม (Perceived Behavioral Control: PBC) ได้อย่างถูกต้อง โดยผลการวิเคราะห์แสดงให้เห็นว่าแต่ละตัวแปรมีค่าน้ำหนักองค์ประกอบที่สูง และค่าดัชนีความสอดคล้องของโมเดล (Model Fit Indices) อยู่ในระดับที่น่าพึงพอใจ สะท้อนถึงความเชื่อถือได้ของแบบจำลองการวัด

ต่อจากนั้น SEM ถูกนำมาใช้เพื่อทดสอบความสัมพันธ์เชิงโครงสร้างระหว่างตัวแปรแฝง โดยผลการวิเคราะห์ชี้ให้เห็นว่า ATT, SN และ PBC ส่งผลเชิงบวกและมีนัยสำคัญต่อเจตนาของผู้สูงอายุในการใช้บริการขนส่งสาธารณะ ซึ่งสอดคล้องกับงานวิจัยก่อนหน้านี้ที่ใช้ TPB เป็นกรอบวิเคราะห์ และแสดงให้เห็นถึงความเหมาะสมของ SEM ในการอธิบายความสัมพันธ์ของตัวแปรทางจิตวิทยาที่ซับซ้อน

นอกจากนี้ การประยุกต์ใช้ SEM ยังสามารถรวมตัวแปรประชากรศาสตร์ เช่น อายุ รายได้ เพศ และพื้นที่อาศัย เข้าไปในแบบจำลองได้อย่างยืดหยุ่น เพื่อวิเคราะห์อิทธิพลของปัจจัยภายนอกเหล่านี้ต่อพฤติกรรมการเดินทางของผู้สูงอายุได้อย่างเป็นระบบ ซึ่งในการศึกษานี้พบว่า อายุและรายได้มีอิทธิพลเชิงบวกและมีนัยสำคัญทางสถิติต่อความตั้งใจในการใช้บริการขนส่งสาธารณะ โดยกลุ่มผู้สูงอายุช่วงวัย 60–69 ปี และผู้ที่มีรายได้เฉลี่ยสูงกว่ามีแนวโน้มที่จะใช้บริการขนส่งสาธารณะมากกว่ากลุ่มอายุ 70 ปีขึ้นไปหรือผู้ที่มีรายได้น้อยกว่า การรวมตัวแปรประชากรศาสตร์ไว้ในโมเดล SEM จึงเป็นแนวทางสำคัญที่ช่วยให้การวิเคราะห์ครอบคลุมทั้งมิติทางพฤติกรรมและมิติทางเศรษฐกิจสังคมอย่างมีประสิทธิภาพ

จุดแข็งของวิธีการ CFA และ SEM ได้แก่ การวิเคราะห์ตัวแปรแฝงที่ไม่สามารถวัดได้โดยตรง แต่สามารถประเมินผ่านตัวแปรสังเกตได้ ความสามารถในการวิเคราะห์ความสัมพันธ์ของหลายตัวแปรพร้อมกันในแบบจำลองเดียว และการประเมินความพอดีของโมเดลโดยรวม ซึ่งช่วยให้สามารถตรวจสอบความเหมาะสมของสมมติฐานทั้งหมดได้ในเชิงโครงสร้าง

อย่างไรก็ตาม วิธีการ SEM จำเป็นต้องให้ความสำคัญกับข้อสมมติบางประการ เช่น ขนาดตัวอย่างที่เพียงพอ ความเป็นปกติของข้อมูล และการระบุโมเดลที่ถูกต้อง ซึ่งในงานวิจัยนี้ได้ใช้กลุ่มตัวอย่างจำนวน 1,000 คน ซึ่งมีขนาดเพียงพอต่อการวิเคราะห์ที่มีความซับซ้อนของโมเดล SEM ได้อย่างเหมาะสมตามแนวทางของ Stevens (1996)

โดยสรุป การประยุกต์ใช้ CFA และ SEM ในการศึกษาช่วยให้สามารถตรวจสอบเจตนาพฤติกรรมของผู้สูงอายุได้อย่างเป็นระบบและสอดคล้องตามแนวคิดทางทฤษฎี ขณะเดียวกันก็สามารถประเมินผลของปัจจัยประชากรศาสตร์ในบริบททางสังคมที่แท้จริงได้อย่างมีนัยสำคัญ ในขณะที่วิธีการด้าน Machine Learning มุ่งเน้นความแม่นยำในการทำนายพลังของ SEM อยู่ในการอธิบายและตีความพฤติกรรมเชิงจิตวิทยาอย่างมีโครงสร้าง ซึ่งสะท้อนถึงความสำคัญของการผสานระหว่าง

กรอบแนวคิดทางทฤษฎีกับการวิเคราะห์เชิงสถิติที่เข้มแข็งในการศึกษาวิจัยด้านการขนส่งสาธารณะในกลุ่มผู้สูงอายุ

5.5 ข้อเสนอเชิงนโยบายสำหรับระบบขนส่งของผู้สูงอายุ

ผลการศึกษานี้ก่อให้เกิดข้อเสนอเชิงนโยบายที่สำคัญหลายประการสำหรับการวางแผนระบบขนส่งที่ตอบสนองต่อความต้องการของประชากรผู้สูงอายุในประเทศไทย โดยปัจจัยที่มีอิทธิพลต่อการเลือกรูปแบบการเดินทางที่พบในงานวิจัยนี้สามารถขึ้นนำการออกแบบมาตรการเฉพาะด้าน เพื่อส่งเสริมความคล่องตัวในการเดินทางและยกระดับคุณภาพชีวิตของผู้สูงอายุ

5.5.1 ความสามารถในการเข้าถึงในมิติด้านเศรษฐกิจ

การที่ปัจจัยด้านค่าใช้จ่ายในการเดินทางและรายได้มีบทบาทสำคัญต่อการตัดสินใจเดินทางของผู้สูงอายุ แสดงให้เห็นถึงความจำเป็นในการจัดหาทางเลือกที่มีต้นทุนเหมาะสม โดยสามารถดำเนินนโยบายในรูปแบบต่าง ๆ ได้แก่

- 1) เงินอุดหนุนเฉพาะกลุ่ม: การจัดทำหรือขยายโครงการลดค่าโดยสารเฉพาะสำหรับผู้สูงอายุ โดยเฉพาะกลุ่มที่มีรายได้น้อย จะช่วยเพิ่มการใช้บริการขนส่งสาธารณะในกลุ่มประชากรนี้
- 2) โครงสร้างค่าโดยสารตามรายได้: การออกแบบระบบค่าโดยสารแบบแยกตามระดับรายได้ อาจช่วยให้บริการขนส่งมีความเป็นธรรมและเข้าถึงกลุ่มเปราะบางทางเศรษฐกิจมากขึ้น โดยยังคงรักษาความยั่งยืนทางการเงินของระบบไว้ได้
- 3) ระบบตั๋วร่วม (Integrated ticketing): การพัฒนาระบบการชำระเงินที่สามารถใช้งานร่วมกันได้หลายรูปแบบ เช่น รถเมล์-รถไฟ จะช่วยลดต้นทุนรวมของการเดินทางโดยเฉพาะในกรณีที่ต้องเปลี่ยนหลายโหมดในหนึ่งเที่ยว

5.5.2 มิติทางสังคมของการเดินทาง

การที่การมีเพื่อนร่วมทางส่งผลต่อการเลือกใช้บริการขนส่งสะท้อนถึงมิติทางสังคมของการเดินทางในกลุ่มผู้สูงอายุ จึงสามารถส่งเสริมผ่านนโยบายที่สอดคล้องได้ เช่น

- 1) แรงจูงใจสำหรับการเดินทางเป็นกลุ่ม: การเสนอส่วนลดหรือบริการพิเศษแก่ผู้สูงอายุที่เดินทางเป็นกลุ่ม จะช่วยกระตุ้นให้มีการใช้บริการขนส่งสาธารณะเพิ่มขึ้น และส่งเสริมปฏิสัมพันธ์ทางสังคม
- 2) โครงการขนส่งโดยชุมชน: การจัดตั้งระบบขนส่งชุมชนสำหรับกิจกรรมจำเป็น เช่น การไปตลาด โรงพยาบาล หรือกิจกรรมสันทนาการ จะช่วยเพิ่มทางเลือกในการเดินทาง และลดความโดดเดี่ยวของผู้สูงอายุ

- 3) ระบบเพื่อนร่วมทางอาสา (Travel buddy system): การจัดตั้งโครงการอาสาสมัครที่จับคู่ผู้สูงอายุที่มีข้อจำกัดในการเดินทางกับผู้ช่วย จะช่วยเพิ่มความมั่นใจในการใช้ขนส่งสาธารณะ

5.5.3 การพัฒนาเฉพาะโหมดการเดินทาง

จากรูปแบบการเลือกใช้บริการที่แตกต่างกันของแต่ละโหมด พบว่ามีโอกาสในการปรับปรุงที่เฉพาะเจาะจง ได้แก่

- 1) รถโดยสารประจำทาง: เนื่องจากเป็นโหมดที่ผู้สูงอายุใช้งานสูงถึง 48.4% จึงควรปรับปรุงระบบให้เหมาะสม เช่น การเพิ่มสิ่งอำนวยความสะดวก การขยายเส้นทางในพื้นที่ที่มีประชากรผู้สูงอายุหนาแน่น และปรับปรุงความสะดวกสบาย
- 2) รถไฟ: ความนิยมในกลุ่มผู้เดินทางระยะไกลแสดงให้เห็นว่า รถไฟมีศักยภาพในการเชื่อมต่อสถานพยาบาล ห้างสรรพสินค้า หรือแหล่งนันทนาการที่ผู้สูงอายุนิยมไป
- 3) รถขนส่งกิจสาธารณะ (Paratransit): อัตราการใช้สูงถึง 23.6% สะท้อนถึงความต้องการบริการที่ยืดหยุ่นแบบ door-to-door ควรพิจารณาจัดตั้งระบบอย่างเป็นทางการ พร้อมควบคุมคุณภาพและความปลอดภัยโดยยังคงจุดเด่นเรื่องความยืดหยุ่นไว้

5.5.4 การออกแบบโครงสร้างพื้นฐานและบริการ

จากรูปแบบและช่วงเวลาการเดินทางของผู้สูงอายุ พบประเด็นสำคัญต่อการออกแบบระบบ ได้แก่

- 1) การวางแผนด้านเวลา (Temporal planning): เนื่องจากผู้สูงอายุร้อยละ 64.4 นิยมเดินทางช่วงเช้า การจัดการความถี่และความจุของบริการควรมุ่งเน้นช่วงเวลาดังกล่าว
- 2) การออกแบบเพื่อความเข้าถึง (Accessibility): จากการที่ 41% ของผู้ตอบแบบสอบถามระบุว่ามีความบกพร่องทางร่างกาย ควรมีการนำแนวคิด Universal Design มาใช้กับทั้งโครงสร้างพื้นฐานและยานพาหนะ
- 3) ระบบข้อมูลที่ชัดเจน: การพัฒนาระบบข้อมูลที่ใช้งานง่าย เช่น เส้นทางตารางเวลา และราคาค่าโดยสาร จะช่วยลดความไม่แน่นอน และเพิ่มความมั่นใจในการใช้บริการขนส่งสาธารณะของผู้สูงอายุ

นโยบายเหล่านี้สามารถปรับใช้เพื่อส่งเสริมความเท่าเทียมในการเข้าถึงระบบขนส่งของผู้สูงอายุ และเป็นแนวทางในการวางแผนขนส่งสาธารณะที่ยั่งยืนในบริบทของสังคมผู้สูงวัยในประเทศไทย

5.6 ข้อจำกัดของการศึกษาและแนวทางการวิจัยในอนาคต

แม้ว่างานวิจัยนี้จะนำเสนอข้อค้นพบที่มีคุณค่าเกี่ยวกับพฤติกรรมการเดินทางของผู้สูงอายุ และวิธีการวิเคราะห์เชิงระเบียบวิธี แต่ก็ยังมีข้อจำกัดบางประการที่ควรกล่าวถึง ดังนี้

ประการแรก ลักษณะของข้อมูลเป็นแบบภาคตัดขวาง (cross-sectional) ซึ่งสะท้อนพฤติกรรมการเดินทางในช่วงเวลาใดเวลาหนึ่งเท่านั้น และไม่สามารถอธิบายการเปลี่ยนแปลงของพฤติกรรมในระยะยาวหรือผลกระทบตามฤดูกาลได้ การศึกษาในอนาคตควรใช้รูปแบบการศึกษาติดตาม (longitudinal study) เพื่อเก็บข้อมูลพฤติกรรมการเดินทางของผู้สูงอายุในช่วงเวลาที่ต่อเนื่อง ซึ่งจะช่วยให้เข้าใจการเปลี่ยนแปลงของพฤติกรรมตามวัยหรือสถานการณ์ที่เปลี่ยนแปลงไปได้ดียิ่งขึ้น

ประการที่สอง แม้ว่ากลุ่มตัวอย่างจะมีความหลากหลายทางภูมิศาสตร์ แต่ก็อาจไม่ครอบคลุมประชากรผู้สูงอายุในทุกกลุ่ม โดยเฉพาะกลุ่มที่มีข้อจำกัดทางการเคลื่อนไหวอย่างรุนแรง ซึ่งมักไม่ปรากฏในพื้นที่สาธารณะที่ใช้สำหรับการสุ่มตัวอย่าง การศึกษาในอนาคตควรวางแผนการสุ่มตัวอย่างที่มุ่งเน้นไปยังผู้สูงอายุที่อยู่บ้านหรือมีภาวะพึ่งพิง เพื่อให้ได้ข้อมูลที่ครอบคลุมกลุ่มประชากรเหล่านี้ได้อย่างแท้จริง

ประการที่สาม แม้จะงานวิจัยนี้จะใช้ทั้งวิธีวิเคราะห์ทางสถิติแบบดั้งเดิมและเทคนิค Machine Learning ที่ทันสมัย แต่ยังขาดการใช้วิธีการเชิงคุณภาพ ซึ่งอาจช่วยให้เข้าใจลึกซึ้งถึงกระบวนการตัดสินใจและประสบการณ์ส่วนบุคคลของผู้สูงอายุ การศึกษาในอนาคตควรผสมผสานวิธีการเชิงปริมาณและเชิงคุณภาพ เช่น การสัมภาษณ์เชิงลึกหรือการสนทนากลุ่ม เพื่อให้ได้ข้อมูลเชิงจิตวิทยาและสังคมมากยิ่งขึ้น

แนวทางการวิจัยในอนาคตที่ควรพิจารณา ได้แก่:

- 1) การวิเคราะห์แยกตามกลุ่มช่วงอายุ: เพื่อศึกษาความแตกต่างของพฤติกรรมการเดินทางระหว่างกลุ่มอายุที่แตกต่างกันในกลุ่มผู้สูงอายุ ซึ่งจะช่วยให้เห็นแนวโน้มการเปลี่ยนแปลงของพฤติกรรมเมื่อกลุ่มวัยกลางคนปัจจุบันเปลี่ยนผ่านเข้าสู่วัยสูงอายุในอนาคต
- 2) การศึกษาการใช้เทคโนโลยีใหม่: เช่น การใช้แอปพลิเคชันเรียกรถ การชำระเงินผ่านมือถือ และระบบติดตามแบบเรียลไทม์ เพื่อพัฒนาบริการขนส่งดิจิทัลที่เข้าถึงได้สำหรับผู้สูงอายุ
- 3) บริบทด้านภูมิอากาศ: การศึกษาว่าภูมิอากาศแบบเขตร้อนของประเทศไทยส่งผลต่อรูปแบบการเดินทางของผู้สูงอายุอย่างไร เช่น ความถี่ในการเดินทางในช่วงฤดูฝนหรืออุณหภูมิสูง

- 4) การวิเคราะห์เปรียบเทียบ: การขยายขอบเขตการศึกษาเพื่อเปรียบเทียบผลของวิธีการ Machine Learning ที่หลากหลายมากขึ้น เช่น Neural Networks หรือ Support Vector Machines เพื่อทำความเข้าใจข้อได้เปรียบเชิงเปรียบเทียบของแต่ละวิธี
- 5) การประยุกต์ GIS: การใช้ระบบสารสนเทศภูมิศาสตร์ (GIS) เพื่อวิเคราะห์การเข้าถึงระบบขนส่งในแต่ละพื้นที่ และศึกษาผลของปัจจัยทางภูมิศาสตร์ต่อพฤติกรรมการเดินทางของผู้สูงอายุ

แม้ว่าการวิเคราะห์โดยใช้ Machine Learning ในการศึกษาจะให้ผลการพยากรณ์ที่แม่นยำสูง แต่ก็มีข้อจำกัดที่ต้องพิจารณา เช่น ความยากในการตีความผลลัพธ์ (interpretability) และความเสี่ยงจากการ overfitting โดยเฉพาะเมื่อฝึกโมเดลด้วยชุดข้อมูลเฉพาะโดยไม่ได้อัดสอบความสามารถในการทั่วไป (generalization) งานวิจัยในอนาคตควรใช้เทคนิคเพิ่มเติม เช่น การตรวจสอบข้าม (cross-validation), การถ่วงน้ำหนัก (regularization) และการวิเคราะห์ด้วย Explainable AI (XAI) เพื่อเพิ่มความโปร่งใสในการนำไปใช้กับการกำหนดนโยบายด้านขนส่ง

นอกจากนี้ แม้ว่ากลุ่มตัวอย่างในประเทศไทยจะมีความหลากหลายทางภูมิศาสตร์ แต่ผลลัพธ์อาจไม่สามารถสรุปโดยทั่วไปไปยังประเทศอื่น ๆ ที่มีโครงสร้างพื้นฐานทางคมนาคม บริบททางวัฒนธรรม หรือระบบการดูแลสุขภาพที่แตกต่างกันได้ การศึกษาในอนาคตควรขยายขอบเขตเพื่อเปรียบเทียบระดับภูมิภาคอาเซียนหรือระดับโลก เพื่อเสริมความน่าเชื่อถือของข้อค้นพบ

แม้ว่าการศึกษานี้จะรวมข้อมูลสุขภาพเบื้องต้น เช่น โรคเรื้อรังและความบกพร่องทางกายภาพ แต่ยังไม่มีการวิเคราะห์เชิงลึกถึงอิทธิพลของปัจจัยสุขภาพเหล่านี้ต่อการเลือกโหมดการเดินทาง การศึกษาในอนาคตควรวิเคราะห์เชิงลึกถึงความต้องการด้านการเข้าถึงและความปลอดภัยของผู้สูงอายุที่มีความบกพร่องทางร่างกาย

อีกทั้ง การเก็บข้อมูลโดยใช้แบบสอบถามแบบพบหน้า อาจทำให้กลุ่มผู้สูงอายุที่อยู่บ้านหรือมีข้อจำกัดทางการเคลื่อนไหวรุนแรงไม่ได้รับการคัดเลือกเข้าสู่กลุ่มตัวอย่าง ส่งผลให้เกิดอคติในการสุ่มตัวอย่าง การศึกษาในอนาคตควรพิจารณาวิธีการเก็บข้อมูลแบบทางโทรศัพท์ แบบสอบถามออนไลน์ หรือการสัมภาษณ์ที่บ้าน

สุดท้ายนี้ แม้ว่าการศึกษานี้จะเน้นที่ปัจจัยด้านเศรษฐกิจและกายภาพแล้ว แต่บริบททางสังคมที่กว้างขึ้น เช่น บทบาทของผู้ดูแลในครอบครัว ผลของความโดดเดี่ยวทางสังคม และระบบสนับสนุนของชุมชน ก็มีบทบาทสำคัญต่อพฤติกรรมการเดินทางของผู้สูงอายุ ปัจจัยด้านสิ่งแวดล้อม เช่น คุณภาพโครงสร้างพื้นฐานและสภาพภูมิอากาศ ก็ยังเป็นมิติสำคัญที่ควรได้รับการศึกษาเพิ่มเติม เพื่อพัฒนาระบบขนส่งที่ครอบคลุมและยั่งยืนสำหรับสังคมสูงวัย

รายการอ้างอิง


- Abdulazeez, M. U., Khan, W., & Abdullah, K. A. (2023). Predicting child occupant crash injury severity in the United Arab Emirates using machine learning models for imbalanced dataset. *IATSS research*, 47(2), 134-159.
- Abdullah, M., Ali, N., Aslam, A. B., Javid, M. A., & Hussain, S. A. (2022). Factors affecting the mode choice behavior before and during COVID-19 pandemic in Pakistan. *International journal of transportation science and technology*, 11(1), 174-186.
- Ahmed, F., Catchpole, J., & Edirisinghe, T. (2021). Understanding young commuters' mode choice decision to use private car or public transport from an extended theory of planned behavior. *Transportation Research Record*, 2675(3), 200-211.
- Ajzen, I. (1991). The theory of planned behavior. *Organizational behavior and human decision processes*, 50(2), 179-211.
- Armitage, C. J., & Conner, M. (2001). Efficacy of the theory of planned behaviour: A meta-analytic review. *British journal of social psychology*, 40(4), 471-499.
- Bentler, P. M. (1990). Comparative fit indexes in structural models. *Psychological bulletin*, 107(2), 238.
- Breiman, L. (2001, 2001/10/01). Random Forests. *Machine Learning*, 45(1), 5-32. <https://doi.org/10.1023/A:1010933404324>
- Browne, M. W., & Cudeck, R. (1993). Alternative ways of assessing model fit. *Testing structural equation models / Kenneth A. Bollen, J. Scott Long editors*.
- Byrne, B. M. (2013). *Structural equation modeling with Mplus: Basic concepts, applications, and programming*. routledge.
- Champahom, T., Chonsalasin, D., Dangbut, A., Watcharamaisakul, F., Jomnonkwao, S., & Ratanavaraha, V. (2025). Elderly travelers' expectations of high-speed railway services in Thailand: A comparative study of leisure and other purposes. *Travel Behaviour and Society*, 39, 100984.
- Chang, X., Wu, J., Liu, H., Yan, X., Sun, H., & Qu, Y. (2019). Travel mode choice: a data fusion model using machine learning methods and evidence from travel diary survey data. *Transportmetrica A: Transport Science*, 15(2), 1587-1612.


- Chuang, P.-C., Chang, Y.-I., & Li, C.-E. (2022). Performance Analysis of Machine Learning and Statistical Models in Predicting Outcomes of Carbon Monoxide Poisoning: A Multicenter Retrospective Study.
- Dahmen, V., Weikl, S., & Bogenberger, K. (2024). Interpretable Machine Learning for Mode Choice Modeling on Tracking-Based Revealed Preference Data. *Transportation Research Record*, 2678(11), 2075-2091. <https://doi.org/10.1177/03611981241246973>
- Du, M., Cheng, L., Li, X., & Yang, J. (2020). Factors affecting the travel mode choice of the urban elderly in healthcare activity: comparison between core area and suburban area. *Sustainable cities and society*, 52, 101868.
- Fornell, C., & Larcker, D. F. (1981). Evaluating structural equation models with unobservable variables and measurement error. *Journal of marketing research*, 18(1), 39-50.
- Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2013). *Multivariate Data Analysis*. Pearson Education Limited. <https://books.google.co.th/books?id=VvXZnQEACAAJ>
- HAIR JUNIOR, J. F., Black, W. C., Babin, B. J., Anderson, R. E., & Tatham, R. L. (1998). Multivariate data analysis. *New Jersey*, 5(3), 207-219.
- Holmes, E., Arkesteijn, M., Knowles, K., McKinney, T., Mizen, A., & Purcell, C. (2024). Understanding the interactions that children and young people have with their natural and built environments: A survey to identify targets for active travel behaviour change in Wales. *Plos one*, 19(10), e0311498.
- Hong, S.-Y., Cho, S.-H., & Park, H.-C. (2024). Behavioral differences between young adults and elderly travelers concerning the crowding effect on public transit after the COVID-19 pandemic. *Research in Transportation Economics*, 106, 101463.
- Hooper, D., Coughlan, J., & R. Mullen, M. (2008). Structural Equation Modeling: Guidelines for Determining Model Fit. *Electronic Journal on Business Research Methods*, 6(1), 53-60. <https://doi.org/doi:10.21427/D7CF7R>
- Hu, L.-t., & Bentler, P. M. (1999). Cutoff criteria for fit indexes in covariance structure analysis: Conventional criteria versus new alternatives. *Structural Equation Modeling*, 6(1), 1-55. <https://doi.org/10.1080/10705519909540118>
- Huang, P., Gong, L., Lei, T., Wang, J., Zhu, C., & Zhang, Z. (2024). A Comparative Study of MNL and Machine Learning Methods for Travel Mode Choice of Medical Travel. *International Conference on Traffic and Transportation Studies*,

- Kaiyawan, Y. (2012). หลักการและการใช้การวิเคราะห์ การถดถอยโลจิสติกสำหรับการวิจัย.
- Kaye, S.-A., Lewis, I., Buckley, L., & Rakotonirainy, A. (2020, 2020/10/01/). Assessing the feasibility of the theory of planned behaviour in predicting drivers' intentions to operate conditional and full automated vehicles. *Transportation Research Part F: Traffic Psychology and Behaviour*, 74, 173-183. <https://doi.org/https://doi.org/10.1016/j.trf.2020.08.015>
- Khan, N., Mohmand, M. I., Rehman, S. u., Ullah, Z., Khan, Z., & Boulila, W. (2024). Advancements in intrusion detection: A lightweight hybrid RNN-RF model. *Plos one*, 19(6), e0299666.
- Kim, E.-J. (2021). Analysis of travel mode choice in Seoul using an interpretable machine learning approach. *Journal of Advanced Transportation*, 2021(1), 6685004.
- Kline, R. B. (2023). *Principles and practice of structural equation modeling*. Guilford publications.
- Li, X., Shi, L., Shi, Y., Tang, J., Zhao, P., Wang, Y., & Chen, J. (2024). Exploring interactive and nonlinear effects of key factors on intercity travel mode choice using XGBoost. *Applied Geography*, 166, 103264.
- Luiu, C., Tight, M., & Burrow, M. (2018). Factors preventing the use of alternative transport modes to the car in later life. *Sustainability*, 10(6), 1982.
- Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. *Advances in neural information processing systems*, 30.
- Martín-Baos, J. Á., López-Gómez, J. A., Rodríguez-Benitez, L., Hillel, T., & García-Ródenas, R. (2023). A prediction and behavioural analysis of machine learning methods for modelling travel mode choice. *Transportation research part C: emerging technologies*, 156, 104318.
- Mohamed, A. G., Alqahtani, F. K., Ismail, E. R., & Nabawy, M. (2025). Synergizing GIS and genetic algorithms to enhance road management and fund allocation with a comprehensive case study approach. *Scientific Reports*, 15(1), 4634.
- Nizami, N., Prasad, N., Nizami, N., & Prasad, N. (2017). Multinomial Logistic Regression Analysis. *Decent Work: Concept, Theory and Measurement*, 315-319.
- Pellicer-Chenoll, M., Pans, M., Seifert, R., López-Cañada, E., García-Massó, X., Devís-Devís, J., & González, L.-M. (2021, 2021/02/01/). Gender differences in bicycle sharing system usage in the city of Valencia. *Sustainable cities and society*, 65, 102556. <https://doi.org/https://doi.org/10.1016/j.scs.2020.102556>

- Prokhorenkova, L., Gusev, G., Vorobev, A., Dorogush, A. V., & Gulin, A. (2018). CatBoost: unbiased boosting with categorical features. *Advances in neural information processing systems*, 31.
- Rossi, T., & Bhat, C. R. (2014). *Guide for travel model transfer*.
- Scheiner, J., & Holz-Rau, C. (2007). Travel mode choice: affected by objective or subjective determinants? *Transportation*, 34, 487-511.
- Shi, Z., Zhou, C., Cheng, L., He, M., & Liu, Y. (2024). Examining Spatial Variations in Walking Activity Among Older Adults Considering the Impact of Topographical Characteristics. *Transportation Research Record*, 03611981241302339.
- Soza-Parra, J., Raveau, S., Muñoz, J. C., & Cats, O. (2019, 2019/08/01/). The underlying effect of public transport reliability on users' satisfaction. *Transportation Research Part A: Policy and Practice*, 126, 83-93.
<https://doi.org/https://doi.org/10.1016/j.tra.2019.06.004>
- Steiger, J. H. (2007). Understanding the limitations of global fit assessment in structural equation modeling. *Personality and Individual differences*, 42(5), 893-898.
- Stevens, J. (2002). *Applied multivariate statistics for the social sciences* (Vol. 4). Lawrence Erlbaum Associates Mahwah, NJ.
- Stevens, W. (1996). *Letters of Wallace Stevens*. Univ of California Press.
- Sun, Z., Wang, D., Gu, X., Abdel-Aty, M., Xing, Y., Wang, J., Lu, H., & Chen, Y. (2023). A hybrid approach of random forest and random parameters logit model of injury severity modeling of vulnerable road users involved crashes. *Accident Analysis & Prevention*, 192, 107235.
- Tabachnick, B. G., Fidell, L. S., & Ullman, J. B. (2013). *Using multivariate statistics* (Vol. 6). pearson Boston, MA.
- Uddin, M., Pan, M. M., & Hwang, H.-L. (2023). Factors influencing mode choice of adults with travel-limiting disability. *Journal of Transport & Health*, 33, 101714.
- Wang, F., & Ross, C. (2018, 05/14). Machine Learning Travel Mode Choices: Comparing the Performance of an Extreme Gradient Boosting Model with a Multinomial Logit Model. *Transportation Research Record: Journal of the Transportation Research Board*, 2672, 036119811877355.
<https://doi.org/10.1177/0361198118773556>

- Wei, Q., Zhang, N., Gao, Y., Chen, C., Wang, L., & Yang, J. (2024). Bus Network Adjustment Pre-Evaluation Based on Biometric Recognition and Travel Spatio-Temporal Deduction. *Algorithms*, 17(11), 513. <https://www.mdpi.com/1999-4893/17/11/513>
- Wheaton, B., Muthén, B., Alwin, D. F., & Summers, G. F. (1977). Assessing Reliability and Stability in Panel Models. *Sociological Methodology*, 8, 84-136. <https://doi.org/https://doi.org/10.2307/270754>
- WHO (World Health Organization). (2015). *World health statistics 2015*. W. H. Organization. http://www.who.int/gho/publications/world_health_statistics/2015/en/
- Zhang, G., Wang, D., Cai, Z., & Zeng, J. (2024, 2024/01/01/). Competitiveness of public transit considering travel time reliability: A case study for commuter trips in Hangzhou, China. *Journal of Transport Geography*, 114, 103768. <https://doi.org/https://doi.org/10.1016/j.jtrangeo.2023.103768>
- กัลยา วานิชย์บัญชา. (2015). การวิเคราะห์สถิติขั้นสูงด้วย *SPSS for Windows*. บริษัท ธรรมสาร จำกัด. <https://books.google.co.th/books?id=xBY7YAAACAAJ>
- ทรงศน์มน ทิมทอง. (2022). การประยุกต์ ใช้ทฤษฎีพฤติกรรมตามแผนเพื่อศึกษาความตั้งใจซื้อที่อยู่อาศัยแบบยั่งยืนของผู้บริโภคในประเทศไทย มหาวิทยาลัยมหิดล].
- นิพิฐพนธ์ สนิทเหลือ. (2022). SAMPLE SIZE CALCULATION USING G*POWER PROGRAM. วารสารวิชาการ สถาบันเทคโนโลยีแห่งสุวรรณภูมิ.
- สำนักงานสภาพัฒนาการเศรษฐกิจและสังคมแห่งชาติ. (2022). แผนพัฒนาประชากรเพื่อการพัฒนาประเทศระยะยาว (พ.ศ. 2565 - 2580). https://www.nesdc.go.th/ewt_dl_link.php?nid=13502
- อารียา สุขโต. (2021). รูปแบบการเดินทางและขนส่งสาธารณะกับสังคมผู้สูงอายุ. https://www.parliament.go.th/ewtadmin/ewt/parliament_parcy/download/article/article_20210423152404.pdf





ภาคผนวก ก
แบบสอบถามของโครงการวิจัยเรื่อง ปัจจัยที่มีอิทธิพลต่อการเลือกรูปแบบการ
เดินทางของผู้สูงอายุในเมืองภูมิภาคของประเทศไทย

มหาวิทยาลัยเทคโนโลยีสุรนารี

แบบสอบถามของโครงการวิจัย
เรื่อง ปัจจัยที่มีอิทธิพลต่อการเลือกรูปแบบการเดินทางของผู้สูงอายุ
ในเมืองภูมิภาคของประเทศไทย

หน้า 1/6

รหัสแบบสอบถาม:.....
จังหวัด.....
อำเภอ.....
ตำบล.....

สาขาวิชาวิศวกรรมขนส่ง สำนักวิชาวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีสุรนารี

วัตถุประสงค์ : แบบสอบถามนี้มีวัตถุประสงค์เพื่อศึกษาพัฒนาแบบจำลองปัจจัยที่มีอิทธิพลต่อความตั้งใจของผู้สูงอายุในการใช้บริการขนส่งสาธารณะในเมืองภูมิภาค และเพื่อพัฒนาแบบจำลองการเลือกรูปแบบการเดินทางในเมืองภูมิภาค แล้วจึงนำผลการวิเคราะห์ที่ได้ไปเป็นแนวทางให้แก่หน่วยงานที่เกี่ยวข้อง เช่น ผู้ให้บริการ ผู้พัฒนานโยบาย ในการกำหนดนโยบาย และพัฒนากลยุทธ์ทางธุรกิจในการยกระดับระบบขนส่งให้มีคุณภาพและความยั่งยืนตอบสนองต่อสังคมผู้สูงอายุ

แบบสอบถาม แบ่งเป็น 3 ตอน จำนวน 6 หน้า ได้แก่

ตอนที่ 1 ข้อมูลทั่วไปพฤติกรรมการเดินทาง

ตอนที่ 2 การประเมินปัจจัยที่มีอิทธิพลต่อความตั้งใจของผู้สูงอายุในการใช้บริการขนส่งสาธารณะ

ตอนที่ 3 การสำรวจการเดินทาง จากการบันทึกการเดินทาง (Travel Diary)

ข้าพเจ้ายินยอมร่วมตอบแบบสอบถาม

☐ ยินดีร่วม ☐ ไม่ยินดีร่วม

ตอนที่ 1 ข้อมูลทั่วไปพฤติกรรมการเดินทาง

คำชี้แจง: โปรดทำเครื่องหมาย ✓ หน้าคำตอบที่ตรงกับความเป็นจริง

- 1.1) เพศ ☐ 1) ชาย ☐ 2) หญิง ☐ 3) ไม่ระบุ
- 1.2) อายุ _____ ปี (ข้อมูลมีความสำคัญกับการวิเคราะห์ผล กรุณาให้ข้อมูลและข้อมูลนี้เป็นข้อมูลปกปิด)
- 1.3) รายได้เฉลี่ยส่วนบุคคล (นับรวมรายได้จากลูกหลานหรือผู้ดูแล/สวัสดิการของรัฐ) _____ บาท/เดือน
- 1.4) โรคประจำตัว ☐ 1) ไม่มีโรคประจำตัว ☐ 2) ความดันโลหิตสูง ☐ 3) ไช้มันในเลือดสูง
ตอบได้มากกว่า 1 ข้อ ☐ 4) โรคเบาหวาน ☐ 5) โรคหัวใจและหลอดเลือด ☐ 6) โรคเมร็ง
☐ 7) โรคไต ☐ 8) โรคปอดอุดกั้นเรื้อรัง
☐ 9) อื่น ๆ (โปรดระบุ) _____
- 1.5) ความบกพร่องทางร่างกาย ☐ 1) ไม่มีความบกพร่อง ☐ 2) มีปัญหาด้านการเคลื่อนไหว
ตอบได้มากกว่า 1 ข้อ ☐ 3) มีปัญหาด้านการมองเห็น ☐ 4) มีปัญหาด้านการได้ยิน
☐ 5) มีปัญหาด้านการพูด ☐ 6) มีปัญหาด้านความจำ
☐ 7) มีปัญหาด้านอื่น ๆ (โปรดระบุ) _____
- 1.6) สถานภาพ ☐ 1) โสด ☐ 2) สมรส ☐ 3) หม้าย/หย่า/แยกกันอยู่
- 1.7) สถานะการอยู่อาศัย ☐ 1) อยู่ลำพัง ☐ 2) อยู่กับครอบครัว/ผู้ดูแล (โปรดระบุ) _____
- 1.8) ในครอบครัวของท่านมีสมาชิกทั้งหมด (โปรดระบุ) _____ คน (รวมทั้งตัวท่าน)
- 1.9) ระดับการศึกษาสูงสุด ☐ 1) ประถม ☐ 2) มัธยมต้น ☐ 3) มัธยมปลาย/ปวช. ☐ 4) อนุปริญญา/ปวส.
☐ 5) ปริญญาตรี ☐ 6) ปริญญาโท ☐ 7) ปริญญาเอก ☐ 8) อื่น ๆ (โปรดระบุ) _____
- 1.10) อาชีพ (ปัจจุบัน) ☐ 1) เกษียณอายุ ☐ 2) ราชการ/รัฐวิสาหกิจ ☐ 3) บริษัทเอกชน ☐ 4) ธุรกิจส่วนตัว/ค้าขาย
☐ 5) เกษตรกร ☐ 6) รับจ้างทั่วไป ☐ 7) พ่อ-แม่บ้าน ☐ 8) อื่น ๆ (โปรดระบุ) _____
- 1.11) เขตที่พักอาศัย ☐ 1) ในเมือง ☐ 2) นอกเมือง ☐ 3) ชานเมือง
- 1.12) ยานพาหนะในการครอบครอง ☐ 1) ไม่มี ☐ 2) รถจักรยานยนต์ _____ คัน
ตอบได้มากกว่า 1 ข้อ ☐ 3) รถจักรยานยนต์ _____ คัน ☐ 4) รถยนต์ _____ คัน
☐ 5) อื่น ๆ (โปรดระบุ) _____
- 1.13) บัตรอนุญาตขับขี่ที่ถือครอง ☐ 1) ไม่มี ☐ 2) บัตรอนุญาตขับขี่รถจักรยานยนต์
ตอบได้มากกว่า 1 ข้อ ☐ 3) บัตรอนุญาตขับขี่รถยนต์ ☐ 4) บัตรอนุญาตขับขี่รถประเภทอื่น (โปรดระบุ) _____

- 1.14) ท่านใช้บริการระบบขนส่งสาธารณะบ่อยแค่ไหน (1 ครั้ง หมายถึง ไป-กลับ)
- ☐ 1) ทุกวัน (วันทำงาน) ☐ 2) สัปดาห์ละ 3-4 ครั้ง ☐ 3) สัปดาห์ละ 2 ครั้ง ☐ 4) สัปดาห์ละ 1 ครั้ง
- ☐ 5) เดือนละ 2 ครั้ง ☐ 6) เดือนละ 1 ครั้ง ☐ 7) สองเดือน 1 ครั้ง ☐ 8) ปีละ 2 ครั้ง
- ☐ 9) ปีละ 1 ครั้ง ☐ 10) น้อยกว่าปีละ 1 ครั้ง ☐ 11) ไม่เคยใช้บริการ
- 1.15) วัตถุประสงค์ของการเดินทางด้วยระบบขนส่งสาธารณะ (ส่วนใหญ่)
- ☐ 1) เพื่อไปเรียน/ไปทำงาน ☐ 2) เพื่อพักผ่อน/ท่องเที่ยว ☐ 3) เพื่อเดินทางไปซื้อของ
- ☐ 4) เพื่อกิจกรรมกีฬา (การชุมนุม) ☐ 5) อื่น ๆ (โปรดระบุ) _____
- 1.16) การเดินทางโดยระบบขนส่งสาธารณะท่านเดินทางโดยวิธีการใดบ่อยที่สุด
- ☐ 1) รถตู้ ☐ 2) รถบัส ☐ 3) รถไฟ ☐ 4) ไม่เคยใช้บริการทั้ง 3 แบบ
- 1.17) จำนวนผู้ติดตามของท่านในการเดินทางโดยรถโดยสารสาธารณะ (ส่วนใหญ่)
- ☐ 1) ไม่ไว้ใจ ☐ 2) ไว้ใจเล็กน้อย
- 1.18) เมื่อท่านใช้บริการระบบขนส่งสาธารณะ ท่านมีความไว้ใจในการรับมือกับสถานการณ์ต่าง ๆ ของผู้ให้บริการในระดับใด
- ☐ 1) ไม่ไว้ใจ ☐ 2) ไว้ใจเล็กน้อย ☐ 3) ไว้ใจปานกลาง ☐ 3) ไว้ใจมาก ☐ 4) ไว้ใจมากที่สุด
- 1.19) เหตุผลที่เดินทางด้วยระบบขนส่งสาธารณะ (ตอบได้มากกว่า 1 ข้อ)
- ☐ 1) ไม่มีทางเลือกอื่น ☐ 2) มีราคาถูก ☐ 3) ตรงต่อเวลา ☐ 4) ประทับใจในบริการ
- ☐ 5) ใช้เวลาเดินทางไม่นาน ☐ 6) ลดปัญหามลพิษ ☐ 7) สะดวก สามารถเข้าถึงได้ง่าย
- ☐ 8) มีความปลอดภัยในการเดินทาง ☐ 9) อื่น ๆ (โปรดระบุ) _____
- 1.20) ช่วงเวลาในการเดินทางของท่านโดยรถโดยสารสาธารณะ (ส่วนใหญ่)
- ☐ 1) 04:00 - 06:59 น. ☐ 2) 07:00 - 09:59 น. ☐ 3) 10:00 - 12:59 น.
- ☐ 4) 13:00 - 15:59 น. ☐ 5) 16:00 - 18:59 น. ☐ 6) 19:00 - 21:59 น.
- ☐ 7) 22:00 - 05:59 น. ☐ 7) 01:00 - 03:59 น.


ตอนที่ 2 การประเมินปัจจัยที่มีอิทธิพลต่อความตั้งใจของผู้สูงอายุในการใช้บริการขนส่งสาธารณะ

คำชี้แจง: โปรดทำเครื่องหมาย ✓ หน้าคำตอบที่ตรงกับความเป็นจริงที่มีอิทธิพลต่อความตั้งใจใช้บริการขนส่งของท่านมากที่สุด (โดยที่ 7=เห็นด้วยมากที่สุด จนถึง 1=ไม่เห็นด้วยเลย)

2.1) ปัจจัยที่มีอิทธิพลต่อความตั้งใจของผู้สูงอายุในการใช้บริการขนส่งสาธารณะ

ที่	การประเมินปัจจัยที่มีอิทธิพลต่อความตั้งใจของผู้สูงอายุในการใช้บริการขนส่งสาธารณะ	เห็นด้วยมากที่สุด<->ไม่เห็นด้วยเลย						
		7	6	5	4	3	2	1
	ด้านการรับรู้ในการควบคุมพฤติกรรมของตนเอง (Perceived Behavioral Control)							
2.1	ฉันคิดว่าระบบขนส่งที่มีความถี่ในการให้บริการมาก ทำให้ง่ายต่อการเดินทาง	7	6	5	4	3	2	1
2.2	ฉันคิดว่าระบบขนส่งที่มีความตรงต่อเวลาของรถบร ทำให้ง่ายต่อการเดินทาง	7	6	5	4	3	2	1
2.3	ฉันคิดว่าระบบขนส่งที่มีความสะดวกสบายมาก ทำให้ง่ายต่อการเดินทาง	7	6	5	4	3	2	1
2.4	ฉันคิดว่าระบบขนส่งที่มีค่าเดินทางที่ถูกขึ้น ทำให้ง่ายต่อการเดินทาง	7	6	5	4	3	2	1
2.5	ฉันคิดว่าระบบขนส่งที่มีการเข้าถึงในการใช้บริการได้ทั่วถึง ทำให้ง่ายต่อการเดินทาง	7	6	5	4	3	2	1
2.6	ฉันคิดว่าระบบขนส่งที่มีความปลอดภัยมาก ทำให้ง่ายต่อการเดินทาง	7	6	5	4	3	2	1
	ด้านทัศนคติ (Attitude)							
2.7	ฉันชอบใช้ระบบขนส่งสาธารณะ หากความถี่ในการให้บริการดีขึ้น	7	6	5	4	3	2	1
2.8	ฉันชอบใช้ระบบขนส่งสาธารณะ หากเวลาในการเดินทางลดลง	7	6	5	4	3	2	1
2.9	ฉันชอบใช้ระบบขนส่งสาธารณะ หากความสะดวกสบายมากขึ้น	7	6	5	4	3	2	1
2.10	ฉันชอบใช้ระบบขนส่งสาธารณะ หากค่าเดินทางถูกลง	7	6	5	4	3	2	1
2.11	ฉันชอบใช้ระบบขนส่งสาธารณะ หากการเข้าถึงในการใช้บริการได้ง่ายมากยิ่งขึ้น	7	6	5	4	3	2	1
2.12	ฉันชอบใช้ระบบขนส่งสาธารณะ หากความปลอดภัยเพิ่มสูงขึ้น	7	6	5	4	3	2	1
	ด้านความตั้งใจ (Intention)							
2.13	ฉันจะใช้ระบบขนส่งสาธารณะ เพราะเชื่อว่ามีค่าที่คุ้มค่า	7	6	5	4	3	2	1
2.14	ฉันจะใช้ระบบขนส่งสาธารณะ เพราะเชื่อว่าจะประหยัดเวลาในการเดินทาง	7	6	5	4	3	2	1
2.15	ฉันจะใช้ระบบขนส่งสาธารณะ มีความสะดวกสบาย	7	6	5	4	3	2	1
2.16	ฉันจะใช้ระบบขนส่งสาธารณะ เพราะมีค่าเดินทางที่เหมาะสม	7	6	5	4	3	2	1
2.17	ฉันจะใช้ระบบขนส่งสาธารณะ เพราะสามารถเข้าถึงได้ง่าย	7	6	5	4	3	2	1
2.18	ฉันจะใช้ระบบขนส่งสาธารณะ เพราะเชื่อว่ามีความปลอดภัยสูง	7	6	5	4	3	2	1
	ด้านบรรทัดฐานสังคม (Subjective Norms)							
2.19	ฉันชอบใช้บริการขนส่งสาธารณะเพราะเป็นเรื่องปกติของสังคม	7	6	5	4	3	2	1
2.20	ฉันเลือกใช้ระบบขนส่งสาธารณะตามที่คนรอบข้างหรือเพื่อนแนะนำ	7	6	5	4	3	2	1
2.21	ฉันคิดว่าคำแนะนำจากครอบครัวมีอิทธิพลต่อการเลือกใช้บริการขนส่งสาธารณะ	7	6	5	4	3	2	1
2.22	ฉันคิดว่าความเห็นของคนรอบข้างมีน้ำหนักมากในการตัดสินใจในการเลือกใช้บริการขนส่งสาธารณะ	7	6	5	4	3	2	1
2.23	ฉันคิดว่าคำแนะนำจากคนรอบข้างเกี่ยวกับการลดการใช้รถส่วนตัวเพื่อสุขภาพสิ่งแวดล้อมมีอิทธิพลต่อการเลือกใช้บริการขนส่งสาธารณะ	7	6	5	4	3	2	1
2.24	การประชาสัมพันธ์ผ่านสื่อต่างๆ เช่น โทรทัศน์ สื่อออนไลน์ เพิ่มความน่าสนใจในการเลือกใช้ระบบขนส่งสาธารณะ	7	6	5	4	3	2	1

Version 1.0 (วันที่ 1 เมษายน 2567)



ภาคผนวก ข
บทความวิชาการที่ได้รับการตีพิมพ์เผยแพร่ในระหว่างศึกษา

มหาวิทยาลัยเทคโนโลยีสุรนารี

รายชื่อบทความวิชาการที่ได้รับการตีพิมพ์เผยแพร่ ในระหว่างศึกษา

Philuek, A., Wisutwattanasak, P., Watcharamaisakul, F., Banyong, C., Chantaratang, A., Champahom, T., . . . Jomnonkwao, S. (2025). Elderly travel mode choice in Thailand-evaluating MNL and machine learning models. *Frontiers in Built Environment, Volume 11 - 2025*. doi:10.3389/fbuil.2025.1601754





OPEN ACCESS

EDITED BY
Nishant Mukund Pawar,
National Institute of Technology Calicut, India

REVIEWED BY
Harikrishna Madhavan,
National Institute of Technology Calicut, India
Malik Muneeb Abid,
University of Sargodha, Pakistan

*CORRESPONDENCE
Sajjakaj Jomnonkwao,
✉ sajjakaj@sut.ac.th

RECEIVED 28 March 2025
ACCEPTED 30 May 2025
PUBLISHED 12 June 2025

CITATION
Philuek A, Wisutwattanasak P,
Watcharamaisakul F, Banyong C,
Chantaratang A, Champahom T,
Ratanavaraha V and Jomnonkwao S (2025)
Elderly travel mode choice in
Thailand-evaluating MNL and machine
learning models.
Front. Built Environ. 11:1601754.
doi: 10.3389/fbuilt.2025.1601754

COPYRIGHT
© 2025 Philuek, Wisutwattanasak,
Watcharamaisakul, Banyong, Chantaratang,
Champahom, Ratanavaraha and
Jomnonkwao. This is an open-access article
distributed under the terms of the [Creative
Commons Attribution License \(CC BY\)](#). The
use, distribution or reproduction in other
forums is permitted, provided the original
author(s) and the copyright owner(s) are
credited and that the original publication in
this journal is cited, in accordance with
accepted academic practice. No use,
distribution or reproduction is permitted
which does not comply with these terms.

Elderly travel mode choice in Thailand-evaluating MNL and machine learning models

Anantaya Philuek¹, Panuwat Wisutwattanasak²,
Fareeda Watcharamaisakul², Chinnakrit Banyong³,
Anon Chantaratang⁴, Thanapong Champahom⁵,
Vatanavongs Ratanavaraha¹ and Sajjakaj Jomnonkwao^{1*}

¹School of Transportation Engineering, Institute of Engineering, Suranaree University of Technology, Nakhon Ratchasima, Thailand, ²Institute of Research and Development, Suranaree University of Technology, Nakhon Ratchasima, Thailand, ³Industrial and Logistics Management Engineering, Suranaree University of Technology, Nakhon Ratchasima, Thailand, ⁴Logistics Technology Program, Faculty of Sciences and Liberal Arts, Rajamangala University of Technology Isan, Nakhon Ratchasima, Thailand, ⁵Department of Management, Faculty of Business Administration, Rajamangala University of Technology Isan, Nakhon Ratchasima, Thailand

This investigation analyzes the determinants of transportation mode selection among elderly populations in Thailand through a comparative approach utilizing both traditional statistical modeling and contemporary machine learning techniques. The research compares the predictive effectiveness of the Multinomial Logistics Regression (MNL) model against advanced algorithmic approaches including Random Forest (RF), Extreme Gradient Boosting (XGBoost), and Categorical Boosting (CatBoost) in forecasting elderly travel behavior. The research utilizes a dataset comprising 1,000 elderly participants distributed across Thailand's four geographical regions, with data collection conducted via structured questionnaires encompassing demographic factors, journey purposes, frequency of travel, expenditure considerations, and modal preferences. Results indicate that the Random Forest algorithms achieved the highest predictive performance on the comprehensive dataset (99.83% accuracy), while CatBoost demonstrated excellent performance on test data (94%). Shapley Additive Explanations (SHAP) analysis identified transportation expenditure, travel party size, temporal considerations, and economic status as the predominant variables influencing modal selection decisions, with lower-income elderly individuals showing a greater tendency for public transportation utilization relative to their more affluent counterparts. The MNL model revealed transportation cost as the most statistically significant predictor of public transit usage ($p < 0.001$), indicating that elderly individuals confronted with elevated travel expenses tend to substitute public transportation with private vehicle alternatives. Concurrently, machine learning methodologies demonstrated enhanced capacity to capture complex relationships between predictive factors and exhibited superior predictive accuracy compared to conventional MNL modeling. These findings offer important implications for the formulation of age-sensitive public transportation policies, particularly emphasizing cost reduction strategies and infrastructure enhancements

designed to accommodate the specific mobility requirements of elderly populations.

KEYWORDS

elderly, travel mode choice, multinomial logit, machine learning, CatBoost, shap, XGBoost, random forest

1 Introduction

Demographic transitions represent inevitable future trends that require strategic preparation and adaptation. A particularly significant shift is the global aging phenomenon. As of 2019, the world population totaled 7,713 million and is projected to reach 9,700 million by 2050 (United Nations, 2019), with individuals aged 60 and above constituting 13% (1,000 million) of the total population. By 2050, the population over 65 years is anticipated to double from 2019 levels (estimated to exceed 1,500 million). Within the ASEAN region, four countries had transitioned to aging societies by 2019: Singapore, Thailand, Vietnam, and Malaysia. Thailand specifically is undergoing an accelerated demographic transformation with its elderly population doubling within a comparatively brief timeframe. This expanding elderly demographic is redirecting consumer demand toward goods and services that address the needs of older adults, creating substantial opportunities for emerging businesses in this growing market sector, including healthcare services, medical facilities, elderly care establishments, and the development of age-friendly transportation infrastructure (Office of the National Economic and Social Development Council, 2022).

In contemporary Thailand, many active elderly individuals maintain independent daily activities, such as social engagement, medical appointments, and recreational travel. Elderly mobility encompasses both utilization of public transportation systems and operation of private vehicles. This raises critical questions regarding Thailand's emphasis on public transportation services. One notable advantage for elderly individuals is their increased leisure time availability compared to other age demographics, assuming adequate health status without mobility-limiting conditions. Thai elderly generally prefer accompanied travel rather than solo journeys; however, the existing public transportation infrastructure does not adequately accommodate or ensure safety for this population segment. Enhanced safety features in mass transit systems could potentially encourage more elderly individuals to travel independently. Assessment of Thailand's current mass transit systems reveals insufficient accommodation for this demographic group that will constitute a significant proportion of the future population. This issue necessitates strategic planning and comprehensive support mechanisms to enhance quality of life for elderly citizens (Prasertsapakij and Nitivattananon, 2012; Sukto, 2021).

Within the transportation context, elderly individuals require not only safety and accessibility in public transportation systems but also autonomy in their daily activities, which significantly influences their modal choices (Zhang et al., 2025). Developing responsive policies and designing age-appropriate transportation systems is therefore essential for enhancing quality of life among this population segment.

From the elderly perspective, current transportation systems demonstrate inadequate alignment with their specific requirements, resulting in diminished quality of life and restricted mobility options (Elias et al., 2013). Enhancing public transportation systems through improved service quality and safety protocols represents a crucial factor in attracting elderly ridership and providing suitable travel alternatives aligned with their lifestyle preferences and needs (Luiu et al., 2017). Factors influencing elderly travel mode selection include financial considerations (many elderly operate within limited budgets and evaluate expenses when selecting transportation services) (Luiu et al., 2017); temporal efficiency (certain elderly groups prioritize journey duration over cost factors, selecting more expedient and convenient travel options) (Holmes et al., 2024); accessibility (transportation systems accommodating specific elderly requirements, such as ramp access and wheelchair-compatible vehicles, influence service utilization) (Du et al., 2020); and service standards (cleanliness, safety measures, and service frequency impact elderly travel decisions) (Cheng L. et al., 2019).

2 Literature review

Table 1 synthesizes recent research on elderly travel behavior, examining influential factors, methodological approaches, regional variations, and existing research gaps. The literature review is organized into four subsections that highlight key developments in understanding elderly mobility patterns.

2.1 Factors affecting elderly travel behavior

Several factors have been identified as significant influencers of elderly travel behavior across multiple studies. Sukkasem and Soratana. (2024) emphasized the importance of psychological factors, particularly attitudes and travel confidence, among elderly air travelers in Bangkok. Their findings connect with (Zhu et al., 2025), who discovered that personality traits significantly influence risky driving behaviors among elderly drivers in China. Both studies highlight the critical role of psychological dimensions in elderly mobility decisions.

Physical capabilities emerge as another crucial factor, as demonstrated by Shi et al. (2024), who found that physical characteristics significantly impact elderly walking behavior in China. This finding complements the work of (Champahom et al., 2025), who noted that comfort preferences strongly influence elderly travelers' choice of high-speed rail for leisure and medical trips in Thailand.

External factors also shape elderly travel behavior. Zhang et al., 2025 revealed how epidemic risks alter elderly travel patterns

TABLE 1 Summary of related research.

Authors	Country	Methodology	Data used	Key findings	Accuracy (%)
Sukkasem and Soratana. (2024)	Thailand	MNL, Machine Learning	Elderly survey data	Attitudes and travel confidence among elderly air travelers in Bangkok	89.40%
Zhang et al. (2025)	China	Agent-Based Modeling	Epidemic and travel behavior data	Elderly travel behavior changes based on epidemic risks	91.20%
Wei et al. (2024)	China	Random Forest	Bus ridership data	Elderly passengers' travel behavior influences route selection	87.60%
Bakhshi and Atri. (2025)	Iran	Logistic Regression	Tourism preference survey	Key factors influencing elderly tourist destination choices	85.30%
Zamprogno and Esztergár-Kiss. (2024)	Hungary	K-Means	Demographic and travel frequency data	Elderly public transport users categorized into distinct travel behavior groups	88.50%
Huang et al. (2024)	China	XGBoost, Random Forest	Elderly medical travel data	Machine Learning provides superior accuracy over MNL in predicting travel choices	94.30%
Zhang and Maruyama. (2024)	Japan	Latent Class Model	Elderly urban and rural travel data	Urban and rural elderly travelers exhibit distinct mobility patterns	90.70%
Shi et al. (2024)	China	SVM, Random Forest	Elderly walking activity data	Physical characteristics significantly impact elderly walking behavior	89.90%
Asare-Duah. (2024)	Ghana	Time-Series Analysis	Longitudinal travel behavior data	Comparison of rural and urban elderly travel patterns	86.40%
Hong et al. (2024)	South Korea	XGBoost, Gradient Boosting	Public transit ridership data	Elderly transit use patterns shifted significantly post-pandemic	92.30%
Champahom et al. (2025)	Thailand	Logit Model Approach	Survey on high-speed rail preferences	Elderly travelers prefer high-speed rail for leisure and medical trips	94.20%
Zhu et al. (2025)	China	Mixed Logit Model and Random Effects Model	Driver behavior monitoring data	Personality traits influence risky driving behaviors among elderly drivers	91.80%

in China, while Hong et al. (2024) documented significant shifts in elderly transit use following the pandemic in South Korea. These studies collectively demonstrate how health concerns and major disruptive events modify mobility patterns among older adults.

Travel purpose represents another significant determinant, with Champahom et al. (2025) noting distinct preferences for high-speed rail among elderly travelers for specific purposes like leisure and medical trips. This finding aligns with Wei et al. (2024), who

observed how elderly passengers' travel behaviors influence route selection for bus services in China.

2.2 Models used to analyze elderly travel behavior

Research methodologies for analyzing elderly travel behavior have evolved from traditional statistical approaches to advanced

machine learning techniques. Traditional statistical models, such as the Multinomial Logit (MNL) model employed by [Sukkasem and Soratana. \(2024\)](#) and the Logit Model approach used by [Champahom et al. \(2025\)](#), have provided valuable insights into elderly travel preferences in Thailand. Similarly, [Zhu et al. \(2025\)](#) utilized a Mixed Logit Model combined with Random Effects to analyze driver behavior in China, while [Bakhshi and Atri. \(2025\)](#) applied Logistic Regression to study tourism preferences among elderly in Iran.

A notable trend in recent research is the increased application of machine learning techniques. [Huang et al. \(2024\)](#) directly compared XGBoost and Random Forest algorithms with traditional MNL models, demonstrating superior accuracy of machine learning methods (94.30%) in predicting elderly medical travel choices in China. This methodological advancement connects with [Hong et al. \(2024\)](#), who similarly employed XGBoost and Gradient Boosting to analyze public transit ridership data in South Korea with high accuracy (92.30%).

Other researchers have explored specialized analytical approaches. [Zamprogno and Esztergár-Kiss. \(2024\)](#) utilized K-Means clustering to categorize elderly public transport users in Hungary, while [Zhang et al. \(2024\)](#) applied a Latent Class Model to distinguish between urban and rural elderly travel patterns in Japan. These diverse methodological approaches reflect the complexity of elderly travel behavior and the need for sophisticated analytical tools.

2.3 Regional studies

Research on elderly travel behavior reveals significant regional variations across different countries. In Asia, several studies have provided valuable insights into elderly mobility patterns. In Thailand, [Sukkasem and Soratana. \(2024\)](#) examined elderly air travelers in Bangkok, while [Champahom et al. \(2025\)](#) focused on high-speed rail preferences among Thai elderly. These Thailand-based studies connect with research from neighboring countries, such as China, where [Zhang et al., 2025](#), [Wei et al. \(2024\)](#), [Shi et al. \(2024\)](#) have examined various aspects of elderly mobility patterns, from epidemic-related behavior changes to walking activities and bus route preferences.

The Japanese context has been explored by [Zhang et al. \(2025\)](#), who identified distinct mobility patterns between urban and rural elderly travelers. This connects with findings from South Korea, where [Hong et al. \(2024\)](#) documented post-pandemic shifts in elderly transit use patterns. Together, these East Asian studies reveal both similarities and differences in elderly travel behavior across the region.

Beyond Asia, research in other regions offers additional perspectives. In Europe, [Zamprogno and Esztergár-Kiss. \(2024\)](#) categorized elderly public transport users in Hungary into distinct travel behavior groups. In the Middle East, [Bakhshi and Atri. \(2025\)](#) examined elderly tourism preferences in Iran. In Africa, [Asare-Duah. \(2024\)](#) compared rural and urban elderly travel patterns in Ghana, highlighting the importance of geographical context in mobility behavior.

These regional studies collectively demonstrate that while certain factors universally affect elderly travel behavior, regional

contexts significantly shape specific mobility patterns and preferences, necessitating locally tailored transportation solutions.

2.4 Research gaps and current study

Despite the growing body of research on elderly travel behavior, several important gaps remain. First, while machine learning approaches have demonstrated superior predictive accuracy in some contexts, as shown by [Huang et al. \(2024\)](#), [Hong et al. \(2024\)](#), comprehensive comparisons between multiple machine learning algorithms and traditional statistical models remain limited, particularly in the context of elderly travel mode choice. Second, most studies have focused on a single methodological approach rather than comparing multiple techniques. For instance, [Wei et al. \(2024\)](#) used only Random Forest, while [Champahom et al. \(2025\)](#) employed only a Logit Model approach. This limits understanding of which methodological approaches might be most effective for analyzing different aspects of elderly travel behavior. Third, while studies have been conducted across various regions, comparative studies within Southeast Asia remain limited. Thailand's rapidly aging population makes it a particularly important context for understanding elderly travel behavior, yet comprehensive studies examining multiple factors and utilizing comparative methodological approaches are scarce.

The current study addresses these gaps by comparing the MNL model with three advanced machine learning techniques (XGBoost, Random Forest, and CatBoost) using elderly travel behavior survey data from Thailand. This research builds upon previous Thailand-based studies by [Sukkasem and Soratana. \(2024\)](#), [Champahom et al. \(2025\)](#) while adopting the comparative methodological approach demonstrated by [Huang et al. \(2024\)](#). By identifying which factors most significantly influence elderly travel mode choices and determining which models provide the most accurate predictions, this study aims to contribute valuable insights for developing age-friendly transportation policies in Thailand and similar contexts.

3 Materials and methods

3.1 Research framework

The investigation commenced with an extensive review of existing literature to identify key determinants of travel mode selection among elderly populations and to establish appropriate methodological approaches. Survey instruments were deployed to capture demographic characteristics, economic factors, and travel patterns of elderly respondents ([Train, 2009](#)). The acquired data underwent systematic organization and classification based on fundamental travel attributes.

For the analysis of factors influencing travel mode preferences, the study implemented a dual methodological approach combining conventional statistical techniques with contemporary machine learning algorithms. The Multinomial Logit (MNL) framework was employed to estimate selection probabilities across various transportation modes ([Ben-Akiva and Lerman, 1985](#); [Train, 2009](#)). Concurrently, three advanced machine learning approaches—Random Forest (RF), Extreme Gradient Boosting

(XGBoost), and CatBoost—were utilized to enhance predictive capabilities (Breiman, 2001; Prokhorenkova et al., 2018; Tianqi and Carlos, 2016).

Model effectiveness was evaluated through comparative analysis of performance metrics including Accuracy, Precision, Recall, and F1-score to determine optimal analytical approaches. Further examination employed SHAP (Shapley Additive Explanations) methodology to elucidate the relative importance of variables affecting transportation decisions among elderly individuals (Powers, 2020).

The concluding phase involved comprehensive interpretation and discussion of findings, with particular emphasis on the highest-performing analytical model and identification of critical factors shaping elderly mobility patterns (Zhang et al., 2023). This analysis informed the development of policy recommendations designed to enhance transportation systems responsive to the specific needs of aging populations (Du et al., 2020; Liu et al., 2017).

This research addresses a notable gap in existing scholarship by examining elderly travel behavior through multiple analytical lenses, comparing traditional statistical frameworks with machine learning approaches to generate insights for transportation policy development. The investigation aims to overcome limitations of previous studies by focusing specifically on infrastructure and transportation policy development appropriate for Thailand's elderly population and offering concrete recommendations to facilitate mobility among older adults.

3.2 Questionnaire development and data collection

3.2.1 Questionnaire development

The study utilized a Revealed Preference (RP) survey instrument (Creswell and Creswell, 2017) to explore transportation mode preferences among Thailand's elderly population, facilitating analysis through both Multinomial Logit (MNL) modeling and advanced machine learning techniques including Random Forest (RF), Extreme Gradient Boosting (XGBoost), and CatBoost. The questionnaire design prioritized the collection of quantitative information amenable to robust statistical analysis. The survey structure incorporated a combination of fixed-response and open-ended inquiries (Revealed Preference - RP Survey) and was structured around two primary components:

3.2.1.1 Section 1: General information and travel behavior.

This section collected demographic and travel behavior data, including gender, age, income, health conditions, physical impairments, marital status, household composition, education level, occupation, residential area type (urban/suburban), vehicle ownership, frequency of public transport use, and trip purposes. The collected data served multiple purposes: (1) to establish a preliminary understanding of the respondents' demographic characteristics; (2) to assess the representativeness and distribution of the sample; and (3) to provide essential control variables and contextual background for subsequent descriptive statistics and predictive modeling processes.

3.2.1.2 Section 2: Travel diary data.

This section recorded detailed trip-level information based on respondents' most recent travel activities. It included the travel mode used, trip purpose, origin and destination points, distance traveled, travel time, number of companions, travel cost, and key factors influencing the travel mode choice (e.g., cost, convenience, time, safety, comfort). These two sections provided the necessary empirical data to investigate the actual travel mode choices and behaviors of elderly travelers. The information collected was directly used to build the variables for the descriptive analysis and for the predictive modeling processes presented in this study. Figure 1 shows a sample of a travel diary section.

3.2.2 Data collection

1. Sample Composition and Size: The research population encompassed individuals aged 60 and above residing across Thailand's four principal geographical regions:

- Northern Thailand: Chiang Mai, Chiang Rai, Sukhothai, Phitsanulok
- Northeastern Thailand: Nakhon Ratchasima, Khon Kaen, Ubon Ratchathani, Udon Thani
- Central Thailand: Chonburi, Nakhon Sawan, Ayutthaya, Prachuap Khiri Khan
- Southern Thailand: Nakhon Si Thammarat, Songkhla, Surat Thani, Phuket

The sampling methodology employed stratified random selection to establish a total sample of 1,000 participants, with equal regional distribution of 250 individuals per geographic area.

2. Survey Implementation: Data acquisition occurred between January and March 2024 at locations commonly frequented by elderly individuals, including marketplaces, healthcare facilities, and senior service centers. Paper-based questionnaires were selected to accommodate participants with limited technological proficiency. In-person interviews were conducted by research personnel and trained assistants. Quality enhancement measures included linguistically accessible questionnaire design calibrated to elderly comprehension levels and provision of assistance for respondents with literacy limitations. A preliminary study involving 50 participants preceded the main data collection to refine the survey instrument.

3. Data Validation Procedures: Data integrity was verified through questionnaire validity and reliability assessment (Creswell and Creswell, 2017), including application of Cronbach's Alpha coefficients. Partial responses were excluded from analysis, and atypical response patterns underwent verification. Random sampling of completed questionnaires was conducted to identify potential recording inaccuracies. The data management protocol incorporated digital transcription to facilitate analysis and encryption procedures to safeguard participant confidentiality.

3.2.3 Description of variables

The explanatory variables utilized in the modeling process were selected based on their relevance to elderly mobility behaviors and

Section 2: Travel Information and Individual Trip Details
(for individuals aged 60 years and older)

Date of Survey: Monday / Tuesday / Wednesday / Thursday / Friday
(Please specify the most recent weekday visit)

Province/District/Set of: _____

Person: Gender: ☐ 1) Male ☐ 2) Female Age: _____ years Monthly Income: _____ Baht Survey ID Code: _____

Occupation: ☐ 1) Working outside home ☐ 2) Working at home ☐ 3) Not working / Staying at home

Please provide information only for trips with a travel distance greater than 500 meters.

Primary Mode of Transportation Used:

☐ 1) Private Vehicles ☐ 2) Public Transport

Code Mode Choice

1) Private car (driver) 2) Private car (passenger) 3) Motorcycle (driver) 4) Motorcycle (passenger) 5) MET/BTS/MRT, (Urban Rail Systems) 6) Tuk-tuk 7) Minibus 8) Passenger van 9) Taxi 10) Motorcycle taxi 11) Bicycle/Walking 12) Boat/Ferry 13) Bus 14) Train 15) Others (please specify): _____

Trip Number	Purpose of Trip	Departure Time	Arrival Time	Origin	Destination	Number of Trips (including independent)	Travel Time (minutes)	Travel Distance (kilometers)	Travel Cost (Baht)
1	☐ 1) Working ☐ 2) Hospital ☐ 3) Shopping ☐ 4) social gatherings ☐ 5) Home ☐ 6) Other			☐ 1) Home ☐ 2) Work ☐ 3) Hospital ☐ 4) Other places	Name of place: _____ Sol: _____ Road: _____ Sub-district: _____ District: _____ Province: _____				
2	☐ 1) Working ☐ 2) Hospital ☐ 3) Shopping ☐ 4) social gatherings ☐ 5) Home ☐ 6) Other			☐ 1) Home ☐ 2) Work ☐ 3) Hospital ☐ 4) Other places	Name of place: _____ Sol: _____ Road: _____ Sub-district: _____ District: _____ Province: _____				
3	☐ 1) Working ☐ 2) Hospital ☐ 3) Shopping ☐ 4) social gatherings ☐ 5) Home ☐ 6) Other			☐ 1) Home ☐ 2) Work ☐ 3) Hospital ☐ 4) Other places	Name of place: _____ Sol: _____ Road: _____ Sub-district: _____ District: _____ Province: _____				
4	☐ 1) Working ☐ 2) Hospital ☐ 3) Shopping ☐ 4) social gatherings ☐ 5) Home ☐ 6) Other			☐ 1) Home ☐ 2) Work ☐ 3) Hospital ☐ 4) Other places	Name of place: _____ Sol: _____ Road: _____ Sub-district: _____ District: _____ Province: _____				
5	☐ 1) Working ☐ 2) Hospital ☐ 3) Shopping ☐ 4) social gatherings ☐ 5) Home ☐ 6) Other			☐ 1) Home ☐ 2) Work ☐ 3) Hospital ☐ 4) Other places	Name of place: _____ Sol: _____ Road: _____ Sub-district: _____ District: _____ Province: _____				
6	☐ 1) Working ☐ 2) Hospital ☐ 3) Shopping ☐ 4) social gatherings ☐ 5) Home ☐ 6) Other			☐ 1) Home ☐ 2) Work ☐ 3) Hospital ☐ 4) Other places	Name of place: _____ Sol: _____ Road: _____ Sub-district: _____ District: _____ Province: _____				

Factors influencing mode choice (Rank 1-5): 1) Most important, 3) least important

☐ Travel time ☐ Cost ☐ Convenience ☐ Safety ☐ Sit comfortably ☐ Have privacy

Note: If there are additional trips beyond the six provided, please continue on a new form.

FIGURE 1
Sample of travel diary section.

their availability in the collected dataset. These variables included travel cost (THB), travel time (minutes), travel distance (kilometers), household income (monthly, THB), vehicle ownership (private vehicle possession), gender, age, and the presence of mobility limitations.

Behavioral factors such as comfort, convenience, and safety were indirectly captured through these variables. Specifically, access time reflects travel convenience; travel cost reflects financial comfort and affordability; trust in public transport services reflects perceived safety; and travel time reflects both the perceived burden and overall ease of the journey. By integrating these variables into the modeling framework, the study accounted for critical behavioral dimensions influencing travel mode selection among elderly individuals.

3.3 Methodological comparison of statistical and machine learning approaches

This investigation employs a comparative analytical framework to evaluate the relative efficacy of traditional statistical modeling (Multinomial Logit) against contemporary algorithmic approaches (Random Forest, Extreme Gradient Boosting, and Categorical

Boosting) in elucidating determinants of transportation mode selection among elderly populations. The methodological comparison facilitates comprehensive assessment of predictive performance across diverse analytical paradigms while identifying complementary insights derived from contrasting analytical techniques (Karlaftis and Vlahogianni, 2011). Comparative Analysis of MNL and machine learning Approaches are summarized in Table 2.

3.3.1 Multinomial Logit (MNL) model

The Multinomial Logit model represents a cornerstone of discrete choice analysis in transportation research, grounded in random utility maximization theory (McFadden, 1973). This approach posits that individuals select transportation alternatives that maximize their perceived utility, with utility functions comprising both observable and unobservable components (Train, 2009). The MNL model calculates the probability of an individual selecting a particular transportation mode from a set of available alternatives based on the relative utility of each option. In this study, the implementation of MNL involves specifying utility functions for each transportation mode available to elderly travelers, incorporating variables such as travel cost, travel time, income level, physical limitations, and trip purpose. Parameter estimation

TABLE 2 Comparative analysis of MNL and machine learning approaches.

Characteristics	Multinomial logit (MNL)	Random forest (RF)	XGBoost	CatBoost
Theoretical Foundation	Utility maximization theory	Ensemble of decision trees	Gradient boosting framework	Gradient boosting with categorical features
Handling Non-linear Relationships	Limited without manual transformation	Strong capability through tree-based structure	Excellent with gradient optimization	Superior with ordered boosting
Interpretability	High - direct coefficient interpretation	Moderate - feature importance metrics	Moderate - gain and split counts	Moderate - SHAP values integration
Computational Efficiency	Low computational demands	Moderate - parallelizable	High with regularization techniques	Optimized for categorical data
Variable Interactions	Limited to specified interactions	Automatically captured in tree structure	Dynamically learned during training	Advanced handling with combinatorial features
Model Assumptions	IIA assumption, error distribution assumptions	Minimal statistical assumptions	Minimal statistical assumptions	Minimal statistical assumptions
Predictive Accuracy	Lower compared to ML methods	Good with sufficient trees	Superior for structured data	Excellent for mixed data types

Note: IIA, independence of irrelevant alternatives.

employs maximum likelihood techniques to identify coefficient values that maximize the probability of observed mode choices within the dataset (Train, 2009).

The MNL model offers distinct advantages in interpretability and theoretical foundation, as coefficients directly represent the influence of each variable on travel mode selection. However, it is constrained by several assumptions, most notably the Independence of Irrelevant Alternatives (IIA) property. This assumption stipulates that the ratio of selection probabilities between two alternatives remains unaffected by the introduction or modification of additional options—a condition that may be violated in complex transportation choice scenarios (Ben-Akiva and Lerman, 1985; McFadden, 1973).

3.3.2 Random Forest (RF)

Random Forest represents an ensemble learning method that generates multiple decision trees and aggregates their predictions to enhance model robustness and accuracy (Breiman, 2001). The algorithm constructs individual trees using bootstrap samples from the training data and incorporates random feature selection at each node, thereby reducing correlation between trees and mitigating overfitting risks (Karlaftis and Vlahogianni, 2011).

In the context of elderly travel mode choice, the Random Forest implementation in this study incorporates all relevant predictors including demographic variables, trip characteristics, and contextual factors. The algorithm autonomously identifies complex, non-linear relationships between predictor variables and transportation outcomes without requiring explicit specification of interaction terms (Hagenauer and Helbich, 2017).

Random Forest offers several advantages in transportation analysis, including robust performance with high-dimensional data, automatic handling of variable interactions, and built-in measures of variable importance. The method provides relative feature importance metrics calculated through mean decrease

impurity or mean decrease accuracy, enabling identification of critical determinants in elderly travel behavior (Cheng L. et al., 2019; Ali et al., 2022; Yan et al., 2020). However, the approach presents limitations in computational efficiency for very large datasets and may be less interpretable than parametric models like MNL (Karlaftis and Vlahogianni, 2011).

3.3.3 Extreme Gradient Boosting (XGBoost)

Extreme Gradient Boosting (XGBoost) represents an advanced implementation of the gradient boosting framework that sequentially constructs an ensemble of weak learners to minimize a differentiable loss function. Unlike Random Forest, which builds independent trees in parallel, XGBoost develops trees sequentially, with each new tree correcting errors made by the existing ensemble (Chen and Guestrin, 2016).

In application to elderly travel mode choice, XGBoost implementation involves calibrating multiple hyperparameters including learning rate, maximum tree depth, subsample ratio, and regularization parameters to optimize predictive performance. The algorithm's architecture facilitates handling of mixed data types prevalent in transportation research, including categorical variables (e.g., trip purpose, gender) and continuous measures (e.g., travel time, income) (Wang and Ross, 2018; Huang et al., 2024; Lee, 2022).

XGBoost offers superior predictive accuracy for structured data compared to traditional methods, incorporating built-in mechanisms for handling missing values, and providing efficient computational performance through parallelization and cache optimization. The method's limitations include potential overfitting with inappropriate hyperparameter selection and reduced interpretability relative to parametric approaches, although feature importance metrics and SHAP values can partially address interpretational challenges (Chen and Guestrin, 2016; Lundberg and Su-In, 2017).

3.3.4 Categorical Boosting (CatBoost)

Categorical Boosting (CatBoost) represents a gradient boosting implementation specifically optimized for efficient processing of categorical features, a prevalent characteristic in transportation data. The algorithm addresses two critical challenges in gradient boosting: prediction shift caused by target leakage in classical gradient boosting and effective handling of categorical variables without extensive preprocessing (Dorogush, Ershov, and Gulin, 2018; Prokhorenkova et al., 2018).

In the context of elderly travel mode choice, CatBoost implementation benefits from automatic handling of categorical variables such as gender, education level, trip purpose, and transportation alternatives without requiring preliminary encoding transformations. The algorithm's architecture is particularly suited to the mixed data types characteristic of transportation research (Banyong et al., 2024; Banyong et al., 2025).

CatBoost offers distinct advantages including superior performance with categorical features, built-in mechanisms to reduce overfitting, and automatic handling of missing values. The method provides integrated interpretability tools including feature importance metrics and native compatibility with SHAP (Shapley Additive Explanations) for explaining model predictions. Limitations include relatively recent adoption in transportation research compared to established methods and computational demands that may exceed those of traditional approaches for very large datasets (Prokhorenkova et al., 2018).

4 Results

4.1 Descriptive analysis

4.1.1 Demographic characteristics of the sample

Table 3 presents the demographic characteristics of the 1,000 elderly respondents in this study. The sample comprised 54.3% females and 45.7% males, with the majority (78.5%) aged between 60–69 years, followed by 19.9% aged 70–79 years, and only 1.6% over 80 years. This age distribution reflects Thailand's current elderly demographic profile, with a higher proportion of “young elderly” (60–69 years) compared to older age groups. Most respondents were married (69.7%), with 23.5% widowed, divorced, or separated, and 6.8% single. The vast majority (94.9%) lived with family or caregivers, which is consistent with traditional Thai family structures where elderly typically reside with their children or relatives, while only 5.1% lived alone.

Regarding education, 86% of respondents had below a bachelor's degree, 9.6% had a bachelor's degree or higher, and 4.4% had other educational qualifications. This educational profile reflects the limited educational opportunities available to the current elderly generation in Thailand, particularly in rural areas. The income distribution showed that most respondents (78.7%) had a monthly income below 10,000 Baht, while 10.6% earned between 10,000–19,999 Baht, 6% earned between 20,000–29,999 Baht, and 4.7% earned 30,000 Baht or higher. This income distribution highlights the economic vulnerability of many elderly in Thailand, with the majority living on limited incomes below the national average.

In terms of work patterns, 41.2% worked outside the home, 25.5% worked at home, and 33.3% were not working or staying at home. The high percentage of elderly still engaged in work (66.7% total) reflects both economic necessity and cultural factors in Thailand, where many elderly continue working well past traditional retirement age. Vehicle ownership was high (80.3%), though only 43.7% held a driver's license, indicating that while many households have access to private vehicles, the elderly themselves may not be the primary drivers. The majority of respondents (73.2%) reported having at least one chronic disease, and 41% reported having some form of physical disability, highlighting the health challenges facing this population and their potential impact on mobility and transportation choices.

4.1.2 Elderly travel mode patterns

As shown in Table 4, the most frequently used travel mode by the elderly was the bus (48.4%), followed by paratransit (23.6%), private cars (20.0%), and trains (7.9%). This indicates that public transportation (buses and trains) was the preferred choice for the majority of elderly travelers, accounting for 56.3% of all travel. The high usage of bus services reflects their widespread availability throughout Thailand, including in rural areas, as well as their relatively low cost, making them accessible to elderly on limited incomes. The substantial use of paratransit (including songthaews, motorcycle taxis, and tuk-tuks) highlights the importance of flexible, on-demand transportation options that can provide door-to-door service for elderly with limited mobility.

The relatively low usage of private cars (20%) despite high household vehicle ownership (80.3%) suggests that many elderly rely on family members for private vehicle transportation rather than driving themselves. This is consistent with the lower proportion of elderly holding driver's licenses (43.7%) and may also reflect concerns about safety, comfort, and physical limitations that prevent some elderly from driving. The lowest usage was for train services (7.9%), likely due to the limited rail network in Thailand, which primarily connects major cities and does not serve many rural or suburban areas where elderly may reside.

4.1.3 Analysis of factors affecting travel behavior

Table 5 provides detailed information about elderly public transportation usage patterns. Regarding frequency of public transportation use, 36.1% were frequent users (weekly or more), 34.7% were occasional users (monthly), 28.5% were infrequent users (less than once per month), and only 0.7% never used public transportation. This high overall usage rate (99.3% using public transportation at least occasionally) demonstrates the critical importance of public transportation systems for elderly mobility in Thailand.

The primary purposes for using public transportation included shopping (34.6%), followed by “other” purposes (28.5%), leisure/tourism (23.5%), work (8.4%), and sports activities (5%). This distribution reflects the daily activities and priorities of elderly, with essential activities like shopping dominating transportation needs. The relatively low proportion of work-related travel (8.4%) is consistent with the retirement status of many respondents, though it contrasts somewhat with the 66.7% who reported some form of work activity, suggesting that many may work from or near their homes.

TABLE 3 General information of sample.

Variable	Description	Frequency (n = 1,000)	%
Gender	Male	457	45.7
	Female	543	54.3
Age	60–69 years	785	78.5
	70–79 years	199	19.9
	Over 80 years	16	1.6
Marital Status	Single	68	6.8
	Married	697	69.7
	Widowed/Divorced/Separated	235	23.5
Living Arrangement	Living alone	51	5.1
	Living with family/caregiver	949	94.9
Education Level	Below bachelor's degree	860	86.0
	Bachelor's degree or higher	96	9.6
	Other	44	4.4
Income (Baht per month)	Below 10,000	787	78.7
	10,000–19,999	106	10.6
	20,000–29,999	60	6.0
	30,000 or higher	47	4.7
Work Pattern	Working outside home	412	41.2
	Working at home	255	25.5
	Not working/staying at home	333	33.3
Vehicle Ownership	Owns a vehicle	803	80.3
	Does not own a vehicle	197	19.7
Driver's License Status	Has a driver's license	437	43.7
	Does not have a driver's license	563	56.3
Chronic Disease	Has chronic disease	732	73.2
	Does not have chronic disease	268	26.8
Physical Disability	Has physical disability	410	41.0
	Does not have physical disability	590	59.0

The most frequently used public transportation types were buses (32.9%), vans (26.5%), and trains (23.8%), while 16.8% never used any of these three types. The higher usage of buses compared to vans likely reflects their lower cost and more extensive route network, while vans may be preferred for specific routes or for

their higher comfort level and faster service. The relatively high train usage reported here (23.8%) compared to the overall mode share (7.9%) suggests that while fewer elderly use trains as their primary mode, a significant number use them occasionally for specific trips.

TABLE 4 Most frequently used travel modes.

Travel mode	Average (%)
Private Car	20.00%
Bus	48.40%
Train	7.90%
Paratransit	23.60%

Most elderly traveled alone (52.4%), while 35.1% traveled with one companion, and 12.5% traveled with more than two companions. This finding challenges the common assumption that all elderly prefer or require accompanied travel and highlights the desire for independence among many Thai elderly. However, the substantial proportion traveling with companions (47.6% total) underscores the importance of social support and assistance for many elderly travelers.

Regarding trust in public transportation, the majority expressed moderate trust (69.1%), followed by high trust (17.9%), little trust (9.1%), highest trust (3.1%), and no trust (0.8%). This generally positive perception (90.1% expressing moderate to highest trust) suggests that safety and reliability concerns are not major barriers to public transportation use for most elderly, though there remains room for improvement to increase trust levels.

The most important reasons for choosing public transportation were low cost (25.9%), convenience and easy access (17.9%), short travel time (14.6%), travel safety (14.1%), punctuality (11.9%), no alternative (5.3%), service satisfaction (5.6%), reducing pollution (4.4%), and other reasons (0.3%). This ranking highlights the critical importance of economic factors (cost) as well as practical considerations (convenience, travel time) in elderly transportation decisions. The relatively low percentage citing “no alternative” (5.3%) suggests that most elderly use public transportation by choice rather than necessity, despite having other options available.

Most elderly used public transportation during early morning to morning hours (64.4%), followed by late morning to afternoon (31%), evening to night (4.4%), and very few during late night (0.2%). This temporal pattern aligns with safety concerns and lifestyle preferences of elderly, who typically avoid traveling after dark and prefer to conduct activities during daylight hours. The concentration of travel in morning hours may also reflect efforts to avoid peak congestion periods and higher temperatures later in the day.

4.1.4 Descriptive statistics of key variables

Table 6 presents descriptive statistics for key variables in the analysis. The average age of respondents was 66.08 years (SD = 4.90), reflecting the predominance of “young elderly” in the sample. The average travel time was 28.25 min per trip (SD = 28.46), indicating a wide variation in trip durations. The relatively high standard deviation suggests that while many elderly make short trips, a substantial number undertake longer journeys. Similarly, the average travel distance was 19.65 km (SD = 23.15), with considerable variation around this mean.

The average travel cost was 39.42 Baht per trip (SD = 43.36), which is relatively modest given the average travel distance. This reflects the affordability of public transportation in Thailand, particularly government-subsidized services. The high standard deviation indicates substantial variation in transportation costs, likely reflecting differences in travel modes and distances.

Variables with high positive skewness included travel distance (2.377) and travel costs (3.101), indicating rightward data dispersion with some values significantly higher than the average. This pattern suggests that while most elderly trips are relatively short and inexpensive, a small proportion of trips involve substantially longer distances and higher costs. Variables with high kurtosis, such as work travel (21.859) and travel for social gatherings (16.964), indicate concentrated distributions where most values cluster tightly around the mean with few outliers.

Travel purpose variables showed that traveling home was the most common (mean = 0.469), followed by shopping (mean = 0.207), hospital visits (mean = 0.125), and visiting relatives or other places (mean = 0.116). Work-related travel (mean = 0.037) and social gatherings (mean = 0.046) were less common. These patterns reflect the daily activities and priorities of elderly, with essential activities like returning home and shopping dominating travel purposes.

4.2 Multinomial Logit model results

The Multinomial Logit (MNL) model results are presented in Table 7, with private car serving as the reference category. The model identified several significant factors affecting elderly travel mode choices, providing insights into the decision-making processes of elderly travelers.

4.2.1 Factors affecting bus travel choice

For bus travel, the significant factors ($p < 0.05$) included average income ($\beta = -0.168$, $p < 0.001$), travel time ($\beta = 0.080$, $p < 0.001$), travel cost ($\beta = -0.120$, $p < 0.001$), having companions ($\beta = 2.278$, $p < 0.001$), and shopping as travel purpose ($\beta = -0.648$, $p = 0.040$).

The negative coefficient for income ($\beta = -0.168$) suggests that as income increases, elderly are less likely to choose bus transportation compared to private cars. For each unit increase in income category, the odds of choosing bus transportation decrease by 15.4% (OR = 0.846). This finding is consistent with economic theory, which suggests that higher-income individuals tend to value comfort and convenience more highly and can better afford private transportation.

The positive coefficient for travel time ($\beta = 0.080$) indicates a higher propensity to use buses for longer trips. For each additional minute of travel time, the odds of choosing bus transportation increase by 8.3% (OR = 1.083). This somewhat counterintuitive finding may reflect the relatively low cost of bus travel for longer distances compared to private vehicles or other modes.

The negative coefficient for travel cost ($\beta = -0.120$) confirms the importance of economic considerations in mode choice. For each additional baht in travel cost, the odds of choosing bus transportation decrease by 11.3% (OR = 0.887), indicating high price sensitivity among elderly bus users.

Having companions dramatically increases the likelihood of choosing buses ($\beta = 2.278$, OR = 9.754), suggesting that bus travel

TABLE 5 Public transportation travel behavior of respondents.

Variable	Description	Frequency (n = 1,000)	%
How often do you use public transportation?	Frequent users (weekly or more)	361	36.1
	Occasional users (monthly)	347	34.7
	Infrequent users (less than once per month)	285	28.5
	Never use	7	0.7
Purpose of travel by public transport	Work	84	8.4
	Leisure/tourism	235	23.5
	Shopping	346	34.6
	Sports activities (gatherings)	50	5.0
	Other	285	28.5
Frequently used public transportation	Van	265	26.5
	Bus	329	32.9
	Train	238	23.8
	Never use any of the 3 types	168	16.8
Number of companions when traveling by public transport	Traveling alone	524	52.4
	Traveling with 1 companion	351	35.1
	Traveling with more than 2 companions	125	12.5
Trust in using public transportation	No trust	8	0.8
	Little trust	91	9.1
	Moderate trust	691	69.1
	High trust	179	17.9
	Highest trust	31	3.1
Reasons for traveling by public transport	No alternative	135	5.3
	Low cost	661	25.9
	Punctuality	305	11.9
	Service satisfaction	143	5.6
	Short travel time	374	14.6
	Reducing pollution	113	4.4
	Convenience, easy access	457	17.9
	Travel safety	361	14.1
	Other	8	0.3
Time periods using public transport	Early morning - Morning (04:00–09:59)	644	64.4
	Late morning - Afternoon (10:00–15:59)	310	31.0
	Evening - Night (16:00–21:59)	44	4.4
	Late night (22:00–00:59)	2	0.2

TABLE 6 Descriptive statistics for MNL

Variable	Mean	Std. Deviation	Skewness	Kurtosis
Age (Years)	66.081	4.902	1.086	1.134
Average income (Thousand THB)	1.274	0.585	2.008	2.779
Travel time (Minutes)	28.252	28.462	2.268	5.897
Travel distance (Kilometers)	19.653	23.149	2.377	6.323
Travel cost (THB)	39.424	43.360	3.101	11.297

is strongly preferred for group travel. This may reflect both practical considerations (sharing costs) and social factors (companionship during the journey).

Shopping as a travel purpose reduced the likelihood of choosing bus transportation ($\beta = -0.648$, OR = 0.523). This may reflect the practical challenges of carrying shopping items on buses or the convenience of private vehicles for shopping trips that may involve multiple stops.

4.2.2 Factors affecting rail travel choice

For rail travel, significant factors included average income ($\beta = -0.272$, $p < 0.001$), travel time ($\beta = 0.276$, $p < 0.001$), travel distance ($\beta = 0.122$, $p = 0.046$), travel cost ($\beta = -1.085$, $p < 0.001$), and sports activities as travel purpose ($\beta = 4.186$, $p = 0.025$).

The strongly negative coefficient for income ($\beta = -0.272$) indicates that lower-income elderly are more likely to choose rail travel compared to private cars, with each unit increase in income category decreasing the odds of rail travel by 23.8% (OR = 0.762).

Travel time showed a strong positive effect ($\beta = 0.276$), with each additional minute increasing the odds of choosing rail by 31.8% (OR = 1.318). Similarly, travel distance showed a positive effect ($\beta = 0.122$), with each additional kilometer increasing the odds by 13% (OR = 1.130). These findings suggest that rail is particularly preferred for longer journeys, where its speed and comfort advantages may outweigh other considerations.

The strongly negative coefficient for travel cost ($\beta = -1.085$) indicates that cost is a particularly important factor in rail mode choice, with higher costs substantially reducing the likelihood of choosing rail transportation. For each additional baht, the odds decrease by 66.2% (OR = 0.338), suggesting extremely high price sensitivity for rail travel.

Interestingly, sports activities as a travel purpose dramatically increased the likelihood of choosing rail ($\beta = 4.186$, OR = 65.751). This strong effect may reflect the location of sports venues near rail stations or scheduled group activities that utilize rail transportation.

4.2.3 Factors affecting paratransit travel choice

For paratransit, significant factors included age ($\beta = -0.058$, $p = 0.002$), average income ($\beta = -0.111$, $p < 0.001$), travel distance ($\beta = 0.046$, $p = 0.008$), travel cost ($\beta = -0.016$, $p < 0.001$), having companions ($\beta = 2.123$, $p < 0.001$), several travel purposes including work ($\beta = -1.223$, $p = 0.020$), leisure/tourism ($\beta = -1.154$, $p = 0.001$), shopping ($\beta = -1.096$, $p = 0.001$), and return home ($\beta = -1.035$, $p < 0.001$), and working outside home ($\beta = 0.526$, $p = 0.016$).

The negative coefficient for age ($\beta = -0.058$) suggests that older elderly are less likely to use paratransit, with each additional year of age decreasing the odds by 5.6% (OR = 0.944). This may reflect increased physical limitations or safety concerns among older individuals that make paratransit less accessible or desirable.

Income showed a negative effect ($\beta = -0.111$), with each unit increase in income category decreasing the odds by 10.5% (OR = 0.895). Travel distance had a positive effect ($\beta = 0.046$), with each additional kilometer increasing the odds by 4.7% (OR = 1.047), suggesting paratransit is preferred for somewhat longer trips, perhaps due to its flexibility and door-to-door service.

Travel cost had a negative but relatively modest effect ($\beta = -0.016$), with each additional baht decreasing the odds by only 1.6% (OR = 0.984). This lower price sensitivity compared to bus and rail may reflect the perceived value of the convenience and flexibility offered by paratransit.

Having companions significantly increased the likelihood of using paratransit ($\beta = 2.123$, OR = 8.357), similar to the effect observed for bus travel. This strong effect suggests that paratransit is particularly valued for group travel, perhaps due to the ability to share costs and the convenience of door-to-door service for groups.

All specific travel purposes (work, leisure/tourism, shopping, return home) showed negative effects compared to the reference category ("other purposes"), suggesting that paratransit is particularly preferred for miscellaneous trips not covered by the main categories. Working outside the home increased the likelihood of using paratransit ($\beta = 0.526$, OR = 1.692), possibly due to its flexibility for commuting to workplaces not well-served by regular public transportation.

4.3 Multinomial Logit model results

4.3.1 Comparison on test dataset

Table 8 presents the performance metrics of the three machine learning models on the test dataset (30% of the total data). CatBoost achieved the highest accuracy at 94%, followed by Random Forest (93%) and XGBoost (91%). This high performance across all three models indicates that machine learning approaches are well-suited to predicting elderly travel mode choices.

In terms of macro precision, Random Forest performed best (0.96), followed by CatBoost (0.95) and XGBoost (0.93). Precision measures the proportion of positive identifications that were actually correct, suggesting that Random Forest had the lowest rate of false

TABLE 7 Parameter estimates of MNL.

Mode choice	Parameter	β	Std. Error	Sig	OR
Bus	Intercept	6.064	1.748	0.001	
	Age (Years)	-0.020	0.019	0.276	0.980
	Average income (Thousand THB)	-0.168	0.014	0.000	0.846
	Travel time (Minutes)	0.080	0.015	0.000	1.083
	Travel distance (Kilometers)	0.025	0.019	0.179	1.025
	Travel cost (THB)	-0.120	0.007	0.000	0.887
	Gender [0 = male; 1 = female]	0.085	0.173	0.623	1.089
	Companions (1 if has companions, 0 if not)	2.278	0.192	0.000	9.754
	Traveling to work (No = 0, Yes = 1)	-0.131	0.525	0.804	0.878
	Traveling to hospital (No = 0, Yes = 1)	-0.540	0.345	0.118	0.583
	Traveling for shopping (No = 0, Yes = 1)	-0.648	0.315	0.040	0.523
	Traveling for social gatherings (No = 0, Yes = 1)	0.380	0.443	0.390	1.463
	Traveling home (No = 0, Yes = 1)	-0.537	0.279	0.055	0.584
	Working outside home (No = 0, Yes = 1)	-0.165	0.224	0.461	0.848
	Not working/staying at home (No = 0, Yes = 1)	-0.411	0.232	0.077	0.663
Rail	Intercept	6.981	6.362	0.272	
	Age (Years)	0.044	0.063	0.489	1.045
	Average income (Thousand THB)	-0.272	0.078	0.000	0.762
	Travel time (Minutes)	0.276	0.065	0.000	1.318
	Travel distance (Kilometers)	0.122	0.061	0.046	1.130
	Travel cost (THB)	-1.085	0.143	0.000	0.338
	Gender [0 = male; 1 = female]	-0.768	0.639	0.230	0.464
	Companions (1 if has companions, 0 if not)	-0.175	0.827	0.832	0.839
	Traveling to work (No = 0, Yes = 1)	-2.097	1.567	0.181	0.123
	Traveling to hospital (No = 0, Yes = 1)	-1.919	1.419	0.176	0.147
	Traveling for shopping (No = 0, Yes = 1)	-2.130	1.176	0.070	0.119
	Traveling for social gatherings (No = 0, Yes = 1)	4.186	1.862	0.025	65.751
	Traveling home (No = 0, Yes = 1)	-1.664	1.022	0.103	0.189
	Working outside home (No = 0, Yes = 1)	-0.295	0.926	0.751	0.745
	Not working/staying at home (No = 0, Yes = 1)	0.593	0.930	0.524	1.810
Paratransit	Intercept	8.743	1.726	0.000	
	Age (Years)	-0.058	0.018	0.002	0.944

(Continued on the following page)

TABLE 7 (Continued) Parameter estimates of MNL.

Mode choice	Parameter	β	Std. Error	Sig.	OR
	Average income (Thousand THB)	-0.111	0.012	0.000	0.895
	Travel time (Minutes)	-0.025	0.013	0.062	0.975
	Travel distance (Kilometers)	0.046	0.017	0.008	1.047
	Travel cost (THB)	-0.016	0.003	0.000	0.984
	Gender [0 = male; 1 = female]	-0.181	0.167	0.278	0.834
	Companions (1 if has companions, 0 if not)	2.123	0.185	0.000	8.357
	Traveling to work (No = 0, Yes = 1)	-1.223	0.524	0.020	0.294
	Traveling to hospital (No = 0, Yes = 1)	-1.154	0.345	0.001	0.316
	Traveling for shopping (No = 0, Yes = 1)	-1.096	0.322	0.001	0.334
	Traveling for social gatherings (No = 0, Yes = 1)	-0.366	0.419	0.383	0.694
	Traveling home (No = 0, Yes = 1)	-1.035	0.286	0.000	0.355
	Working outside home (No = 0, Yes = 1)	0.526	0.218	0.016	1.692
	Not working/staying at home (No = 0, Yes = 1)	-0.258	0.219	0.237	0.772

The reference category is Car, (Chi-Square = 2378.924, df = 42, $p < 0.001$), Cox and Snell R-Square = 0.690, Nagelkerke R-Square = 0.756, McFadden R-Square = 0.481.

TABLE 8 Comparison Results from Test Data (30% of data).

Model	Accuracy	Macro precision	Macro recall	Macro F1-Score
XGBoost	91%	0.93	0.92	0.92
Random Forest	93%	0.96	0.93	0.94
CatBoost	94%	0.95	0.95	0.95

positives. For macro recall, CatBoost outperformed the other models with a value of 0.95, compared to 0.93 for Random Forest and 0.92 for XGBoost. Recall measures the proportion of actual positives that were correctly identified, indicating that CatBoost was better at avoiding false negatives.

The macro F1-score, which represents the harmonic mean of precision and recall, was highest for CatBoost (0.95), followed by Random Forest (0.94) and XGBoost (0.92). This balanced measure suggests that CatBoost provided the best overall performance on the test dataset, effectively balancing the trade-off between precision and recall.

4.3.2 Comparison on full dataset

The performance metrics on the full dataset (100% of the data) are presented in Table 9. Interestingly, Random Forest performed best on the full dataset with an accuracy of 99.83%, followed by CatBoost (99.83%) and XGBoost (98.73%). This contrasts with the results on the test dataset, where CatBoost performed best. The difference may reflect Random Forest's ability to better capture

patterns in larger datasets or specific characteristics of the training-test split.

Random Forest also achieved the highest macro precision (99.84%), macro recall (99.83%), and macro F1-score (99.83%) on the full dataset. CatBoost performed similarly to Random Forest across all metrics, while XGBoost showed slightly lower values. The high performance of all three models on the full dataset confirms their effectiveness for elderly travel mode prediction and suggests that they can generalize well to new data.

4.3.3 Confusion matrix analysis

Table 10 presents the confusion matrix results for all models, providing a detailed breakdown of correct and incorrect classifications for each travel mode. Among the machine learning models, XGBoost demonstrated the highest accuracy, correctly classifying 99.26% of car users, 98.88% of bus users, 100% of rail users, and 95.71% of paratransit users. Random Forest followed closely, achieving 98.51% accuracy for car users, 97.59% for bus users, 100% for rail users, and 95.80% for paratransit users. Misclassifications in these models were minimal, with the largest

TABLE 9 Comparison Results from Real Data (100% of data).

Model	Accuracy	Macro precision	Macro recall	Macro F1-Score
XGBoost	98.73%	99.32%	98.62%	98.96%
Random Forest	99.83%	99.84%	99.83%	99.83%
CatBoost	99.83%	99.83%	99.83%	99.83%

TABLE 10 Confusion matrix.

Methods		Actual				
		Predicted	Car	Bus	Rail	Paratransit
Random Forest	Car	98.51	0.20	0.00	1.89	
	Bus	0.25	97.59	0.00	2.31	
	Rail	0.00	0.20	100.00	0.00	
	Paratransit	1.24	2.01	0.00	95.80	
	Total	100.00	100.00	100.00	100.00	
XGBoost	Car	99.26	0.00	0.00	0.82	
	Bus	0.00	98.88	0.00	3.47	
	Rail	0.00	0.20	100.00	0.00	
	Paratransit	0.74	0.92	0.00	95.71	
	Total	100.00	100.00	100.00	100.00	
CatBoost	Car	93.56	1.44	0.00	6.58	
	Bus	1.29	90.33	0.00	8.39	
	Rail	0.00	0.19	98.76	0.00	
	Paratransit	5.15	8.05	1.24	85.03	
	Total	100.00	100.00	100.00	100.00	
MNL	Car	65.60	1.83	0.00	12.06	
	Bus	25.31	91.27	1.24	38.67	
	Rail	0.00	0.30	98.76	0.42	
	Paratransit	9.09	6.60	0.00	48.86	
	Total	100.00	100.00	100.00	100.00	

Bold values indicate the total percentage of predictions for each actual travel mode category. Each column's total adds up to 100%, confirming that the confusion matrix values are expressed as percentages of actual class distributions.

error occurring in the paratransit category, where a small proportion of bus users (2.31% for Random Forest and 3.47% for XGBoost) were incorrectly classified. These high accuracy rates suggest that both models effectively capture complex patterns and can distinguish between different travel modes based on the provided variables.

The perfect classification of rail users in both XGBoost and Random Forest likely reflects the distinct characteristics of rail travel in Thailand, such as longer distances and specific geographic corridors, making it easier to differentiate from other modes.

TABLE 11 Comparison of accuracy of each model.

Model	Predicted				
	Overall accuracy	Car	Bus	Rail	Paratransit
Random Forest	97.54%	98.51%	97.59%	100.00%	95.80%
XGBoost	98.28%	99.26%	98.88%	100.00%	95.71%
CatBoost	90.46%	93.56%	90.33%	98.76%	85.03%
MNL	76.70%	65.60%	91.27%	98.76%	48.86%

CatBoost exhibited slightly lower accuracy but still performed well, correctly classifying 93.56% of car users, 90.33% of bus users, 98.76% of rail users, and 85.03% of paratransit users. Misclassification primarily occurred between bus and paratransit users, where 8.05% of actual paratransit users were misclassified as bus users and 8.39% of actual bus users were misclassified as paratransit users. This pattern suggests that shared public transportation services, such as buses and paratransit, may exhibit overlapping features that pose a challenge for precise classification.

In contrast, the Multinomial Logit (MNL) model demonstrated substantially lower accuracy across most travel modes, correctly classifying only 65.60% of car users, 91.27% of bus users, 98.76% of rail users, and 48.86% of paratransit users. The model particularly struggled with car and paratransit modes, where 25.31% of actual car users were misclassified as bus users, and 38.67% of actual paratransit users were misclassified as bus users. This systematic bias toward predicting bus usage suggests that the MNL model may have limitations in capturing complex, non-linear relationships inherent in the data.

Interestingly, all models achieved high accuracy in classifying rail users (98.76%–100%), reinforcing the notion that rail travel has distinct characteristics. However, the stark contrast between the superior accuracy of machine learning models and the lower performance of the MNL model highlights the advantages of machine learning approaches. Machine learning models can better capture intricate variable interactions without requiring explicit specification, making them particularly suitable for predicting elderly travel mode choices.

Table 11 presents a comparison of prediction accuracy for elderly travel mode choice using different models, including Random Forest, XGBoost, CatBoost, and Multinomial Logistic Regression (MNL). The prediction is divided into different modes: Car, Bus, Rail, and Paratransit. The results from this table show that XGBoost is the best model, providing the highest overall accuracy as well as the best predictions for each travel mode. Random Forest is also a good option, especially for predicting Car and Paratransit modes. On the other hand, CatBoost and MNL show lower prediction performance, particularly for Car and Paratransit modes.

4.4 Feature importance analysis

4.4.1 Variable importance across models

Table 12 presents the feature importance analysis for each machine learning model, identifying the most influential factors in elderly travel mode decisions. Across all three models, travel cost emerged as the most important factor affecting elderly travel mode choices, with impact values of 0.37 for XGBoost, 0.41 for Random Forest, and 0.39 for CatBoost. This consistent finding across models confirms the critical importance of economic considerations in elderly travel decisions and aligns with the MNL results, which showed significant negative effects of travel cost across all modes.

Income was the second most important factor (XGBoost: 0.29, Random Forest: 0.34, CatBoost: 0.32), followed by convenience in accessing public transportation (XGBoost: 0.23, Random Forest: 0.28, CatBoost: 0.26), and age (XGBoost: 0.18, Random Forest: 0.21, CatBoost: 0.20). The high importance of income reinforces the economic dimension of travel mode choices, while the significance of convenience highlights the practical considerations that influence elderly mobility.

The consistent ranking of these factors across all three models confirms the robustness of these findings and suggests that these variables should be prioritized in transportation policy and planning for elderly populations. The relatively lower importance of age compared to economic factors suggests that financial considerations may outweigh age-related preferences or limitations in determining travel mode choices.


4.4.2 SHAP analysis for model interpretability

The SHAP (Shapley Additive Explanations) analysis provided deeper insights into how each factor influences specific travel mode choices. Figure 2 shows the feature importance of the CatBoost model, with travel cost, distance, income, travel time, age, and number of companions emerging as the most important factors. This visualization confirms the results from the variable importance analysis and provides a more nuanced understanding of the relative importance of different factors.

Figure 3 presents the SHAP interaction plot, illustrating the complex relationships between different variables. This analysis reveals how factors interact to influence travel mode choices, capturing relationships that may not be apparent in simpler analyses.

TABLE 12 Feature importance analysis in each model.

Variable	XGBoost	Random forest	CatBoost
Travel cost	0.37	0.41	0.39
Income	0.29	0.34	0.32
Convenience in accessing public transportation	0.23	0.28	0.26
Age	0.18	0.21	0.20



For example, the interaction between income and travel cost may be particularly important, with lower-income elderly being more sensitive to travel costs than higher-income individuals.

Figures 4–7 show the SHAP contribution by mode for car, bus, rail, and paratransit respectively, revealing how each factor increases or decreases the likelihood of selecting a particular mode. These visualizations provide detailed insights into the decision-making process for each travel mode.

For car mode (Figure 4), higher income and higher travel costs increased the likelihood of choosing a private car, while having companions decreased this likelihood. The positive effect of travel cost may seem counterintuitive but may reflect the willingness of car users to pay more for the convenience and comfort of private transportation. The negative effect of having companions may reflect the economic advantages of sharing costs on public transportation for group travel.


For bus mode (Figure 5), lower income, lower travel costs, and having companions increased the probability of selecting buses. These findings align with the MNL results and economic theory, suggesting that buses are preferred by more price-sensitive elderly and those traveling in groups. The importance of travel cost and

income reinforces the economic dimension of bus travel, which is often chosen for its affordability.

For rail mode (Figure 6), longer travel time, longer travel distance, and lower travel costs were associated with increased rail usage. This pattern suggests that rail is particularly preferred for longer journeys where its speed and comfort advantages may outweigh other considerations, particularly when it offers cost savings compared to alternative modes. The importance of travel distance aligns with the MNL results, which showed a significant positive effect of distance on rail choice.

For paratransit (Figure 7), having companions, shorter travel time, and medium income levels increased the likelihood of choosing this mode. The importance of having companions aligns with the MNL results and suggests that paratransit is particularly valued for group travel, perhaps due to its flexibility and door-to-door service. The preference for shorter travel times may reflect the higher cost per distance of paratransit compared to other public transportation options, making it more economical for shorter trips.

These SHAP analyses provide nuanced insights that complement the MNL model results, capturing complex, non-linear relationships and interactions between variables that traditional statistical



approaches might miss. They offer a more detailed understanding of the decision-making processes of elderly travelers and can inform more targeted transportation policies and services.

5 Discussion

5.1 Key findings and interpretation

This research reveals several important insights into elderly travel behavior in Thailand and demonstrates the comparative effectiveness of traditional statistical methods versus machine learning approaches in analyzing travel mode choices. The findings highlight the complex interplay of economic, social, and practical factors that influence transportation decisions among the elderly population.

5.1.1 Determinants of elderly travel mode choice

Our results consistently identified travel cost as the most influential factor affecting elderly travel mode decisions across all analytical approaches. This finding was evident in both the Multinomial Logit (MNL) model, which showed significant negative coefficients for travel cost across all alternative modes, and the machine learning models, where feature importance analyses ranked travel cost as the primary determinant. The high sensitivity to travel

costs among elderly travelers likely reflects their predominantly lower income levels, with 78.7% of respondents earning less than 10,000 Baht monthly. This economic vulnerability makes cost considerations paramount in transportation decisions.

Income emerged as the second most influential factor, with higher-income elderly more likely to choose private vehicles over public transportation. This relationship between income and mode choice aligns with economic theory and reflects the ability of higher-income individuals to prioritize comfort and convenience over cost. The significant negative coefficients for income in the MNL model for all public transportation modes (bus, rail, and paratransit) compared to private cars reinforces this interpretation.

The presence of travel companions significantly influenced mode choices, particularly for bus and paratransit options. The strongly positive coefficients in the MNL model (OR = 9.754 for bus and OR = 8.357 for paratransit) indicate that accompanied travel substantially increases the likelihood of choosing these modes over private cars. This finding challenges the assumption that elderly travelers inherently prefer private transportation and suggests that public options can be attractive for group travel, possibly due to cost-sharing opportunities and social factors.

Travel time and distance demonstrated different effects across transportation modes. For rail travel, both factors showed positive coefficients, indicating that rail is preferred for longer journeys where its speed advantages become more valuable. In contrast, travel




FIGURE 4
SHAP contribution by mode-car.

time showed negative effects for paratransit, suggesting this mode is preferred for shorter trips, likely due to its higher cost per distance compared to other public options.

5.1.2 Comparison of analytical methods

The performance comparison between traditional statistical modeling and machine learning approaches revealed compelling differences. Machine learning methods consistently outperformed the MNL model in prediction accuracy, with the best-performing ML model (CatBoost) achieving 94% accuracy on test data compared to substantially lower accuracy for the MNL model, particularly for car (65.60%) and paratransit (48.86%) modes.

The confusion matrix analysis revealed a systematic bias in the MNL model toward predicting bus usage, with substantial misclassifications of car and paratransit users as bus users. This limitation suggests that the MNL model, despite its theoretical foundation and interpretability advantages, may fail to capture complex, non-linear relationships and interactions that distinguish different travel modes.


Among machine learning approaches, CatBoost demonstrated superior performance on test data, achieving 94% accuracy, while Random Forest performed best on the full dataset

with an accuracy of 99.83%. This variation highlights the importance of model selection based on specific data characteristics and analytical objectives. The SHAP analysis provided valuable insights into how factors influence specific travel modes, capturing nuanced relationships that complement the more straightforward interpretations from the MNL model.

5.2 Comparison with previous research

Our findings broadly align with previous research on elderly travel behavior while providing new insights specific to the Thai context. The importance of economic factors (travel cost and income) in elderly travel decisions is consistent with Lui et al. (2018), who identified financial considerations as critical determinants of elderly travel mode choices. Similarly, our finding that travel time significantly influences mode selection, particularly for rail travel, aligns with Holmes et al. (2024), who noted that certain elderly groups prioritize journey duration over cost factors.

The superior performance of machine learning methods over traditional statistical approaches mirrors the results of Huang et al.



(2024), who found that machine learning provided greater accuracy (94.30%) than MNL models in predicting elderly medical travel choices in China. Our study extends this finding to general travel behavior in Thailand, with similar accuracy levels (94% for CatBoost on test data and Random Forest on full data).

The high usage of bus services (48.4%) among Thai elderly contrasts somewhat with findings from urban China by Wei et al. (2024), likely reflecting differences in transportation infrastructure and urban development patterns between the two countries. However, the influence of physical capabilities on travel choices is consistent with Shi et al. (2024), who identified physical characteristics as significant determinants of elderly mobility patterns.

Our findings regarding the importance of having companions for public transportation use provide an interesting counterpoint to Zhang et al. (2024) identification of distinct mobility patterns between urban and rural elderly in Japan. While our study did not specifically compare urban and rural populations, the strong effect of companions suggests social factors may transcend geographical contexts in influencing elderly travel behaviors.


The high accuracy of our Random Forest model (99.83% on full data) is comparable to Hong et al. (2024) achievement of 92.30% accuracy using similar techniques in South

Korea, and Champahom et al. (2025) 94.20% accuracy using the Logit Model approach in Thailand. This consistency in model performance across different Asian contexts suggests that advanced analytical methods can reliably capture elderly travel patterns despite cultural and infrastructural differences.

5.3 Methodological implications: MNL vs. machine learning

The comparative analysis of traditional statistical and machine learning approaches provides important methodological insights for transportation research. While the MNL model offers theoretical grounding in utility maximization principles and readily interpretable coefficients, its predictive limitations suggest that it may not fully capture the complexity of elderly travel decision-making processes.

Machine learning methods demonstrated superior predictive performance, with all three algorithms (XGBoost, Random Forest, and CatBoost) achieving accuracy rates exceeding 90%. This advantage likely stems from their ability to identify non-linear relationships and complex interactions without requiring explicit specification. The automatic handling of variable interactions in



tree-based models represents a significant advantage over the MNL approach, where interactions must be manually specified based on prior theoretical assumptions.

However, the traditional criticism of machine learning as a “black box” approach with limited interpretability was partially addressed in this study through feature importance and SHAP analyses. These techniques provided insights into the relative importance of different factors and their specific effects on each travel mode, enhancing the interpretability of machine learning results. The consistency in feature importance rankings across all three machine learning models provides robust evidence regarding the key determinants of elderly travel behavior.

The complementary strengths of traditional statistical and machine learning approaches suggest value in employing both methodologies. The MNL model offers a theoretically grounded framework for understanding travel behavior, while machine learning provides superior predictive accuracy and can identify complex patterns that might be missed in traditional analyses. This dual approach can provide more comprehensive insights than either methodology alone.


6 Policy implications for elderly transportation

The findings of this study have several important implications for transportation policy and planning for elderly populations in Thailand. The identified determinants of travel mode choices suggest specific areas for intervention to enhance elderly mobility and quality of life.

6.1 Economic accessibility

The paramount importance of travel cost and income in elderly travel decisions underscores the need for affordable transportation options. Policy measures could include:

- Targeted subsidies: Implementing or expanding fare reduction programs specifically for elderly passengers could significantly increase public transportation usage among this population, particularly for lower-income individuals.



- **Income-based fare structures:** Developing differentiated fare systems based on income levels could make public transportation more accessible to economically vulnerable elderly while maintaining financial sustainability.

Integrated ticketing systems: Creating seamless payment systems across different transportation modes could reduce overall travel costs for elderly who use multiple modes for a single journey.

6.2 Social dimension of travel

The significant influence of travel companions on mode choices highlights the social dimension of elderly transportation. Policy interventions could include:

- **Group travel incentives:** Offering discounts or special services for elderly traveling in groups could encourage public transportation use and support social connectivity.
- **Community transportation programs:** Developing community-based transportation initiatives that facilitate group travel for shopping, healthcare visits, or social activities could enhance mobility while addressing social isolation.

Travel buddy systems: Establishing volunteer programs pairing mobility-limited elderly with travel companions could increase confidence in using public transportation.

6.3 Mode-specific enhancements

The distinct patterns identified for different transportation modes suggest targeted improvement opportunities:

- **Bus services:** Given their high usage rate (48.4%), enhancing accessibility features, increasing route coverage in areas with high elderly populations, and improving comfort could further increase utilization.
 - **Rail services:** The preference for rail among longer-distance travelers suggests potential for expanding services connecting major healthcare facilities, shopping centers, and recreational destinations frequented by elderly.
- Paratransit:** The significant use of paratransit options (23.6%) indicates demand for flexible, door-to-door services. Formalizing and regulating these services could improve safety and reliability while maintaining their flexibility advantages.

6.4 Infrastructure and service design

The identified travel patterns and preferences suggest specific infrastructure and service design considerations:

- **Temporal planning:** With 64.4% of elderly using public transportation during early morning to morning hours, service frequency and capacity planning should prioritize these periods.
- **Accessibility enhancements:** Given that 41% of respondents reported physical disabilities, universal design principles should be incorporated into all transportation infrastructure and vehicles.

Information systems: Developing clear, accessible information systems about routes, schedules, and fares could address uncertainty that may discourage elderly from using public transportation.

7 Limitations and future research directions

While this study provides valuable insights into elderly travel behavior and methodological approaches, several limitations should be acknowledged. First, the cross-sectional nature of the data captures travel patterns at a specific point in time and does not account for potential changes over time or seasonal variations. Longitudinal studies tracking elderly mobility patterns over extended periods could provide more comprehensive understanding of how travel behaviors evolve with age and changing circumstances.

Second, the sample, while geographically diverse, may not fully represent all elderly population segments, particularly those with severe mobility limitations who may be underrepresented in public spaces where recruitment occurred. Future research should employ sampling strategies specifically targeting homebound elderly to understand their transportation challenges and needs.

Third, while the study employed both traditional and advanced analytical methods, it did not incorporate qualitative approaches that could provide deeper insights into decision-making processes and subjective experiences. Mixed-methods studies combining quantitative analysis with in-depth interviews or focus groups could enhance understanding of the psychological and social dimensions of elderly travel behavior. Future research directions could include:

- **Cohort analysis:** Examining differences between age cohorts within the elderly population could identify how travel preferences and behaviors might change as current middle-aged adults transition into older age with potentially different technological proficiency and transportation expectations.
- **Technology adoption:** Investigating elderly adoption of emerging transportation technologies, including ride-sharing applications, mobile payment systems, and real-time tracking, could inform the design of more accessible digital transportation services.
- **Climate considerations:** Exploring how Thailand's tropical climate affects elderly travel patterns and mode choices could identify seasonal variations and inform climate-adaptive transportation planning.

- **Comparative analysis:** Extending the methodological comparison to include additional machine learning approaches, such as neural networks or support vector machines, could further advance understanding of their relative strengths for transportation analysis.
- **Geographic information system (GIS) integration:** Incorporating spatial analysis to examine how transportation accessibility varies across different regions and how geographical factors influence elderly travel choices could enhance the contextual understanding of mobility patterns.

Despite the strong predictive performance of machine learning models in this study, potential limitations must be acknowledged. Machine learning approaches, including Random Forest, XGBoost, and CatBoost, are often criticized for challenges in interpretability and the risk of overfitting, particularly when the models are trained on specific datasets without sufficient generalization testing. Future studies should incorporate techniques such as cross-validation, regularization, and explainable AI methods to mitigate these risks and enhance transparency for transportation policy applications.

Furthermore, while the sample is geographically diverse within Thailand, the findings may not fully generalize to other countries with different transportation infrastructures, cultural contexts, and elderly care systems. Expanding future studies to include multi-country comparisons within the ASEAN region or globally could enhance the external validity of the findings.

While health-related factors, including chronic diseases and physical disabilities, were incorporated into the survey and descriptive analysis, the study did not conduct an in-depth examination of how these specific conditions directly influenced travel mode choices. Future research could further investigate the relationships between various health limitations and transportation behaviors, particularly focusing on the accessibility requirements and safety concerns of elderly individuals with mobility impairments.

Additionally, the face-to-face survey method may have inadvertently excluded elderly individuals who are homebound or severely mobility impaired, potentially introducing sample bias. Future research could address this limitation by incorporating telephone surveys, online surveys, or home-based interviews.

Lastly, while this study touched upon economic and physical factors, the broader social context such as the role of family caregivers, the effects of social isolation, and community support systems also plays a crucial role in elderly transportation choices. Environmental factors such as infrastructure quality and climate conditions remain important dimensions that merit further investigation, particularly in developing inclusive transportation systems for aging societies.

In conclusion, this study provides valuable insights into the factors influencing elderly travel mode choices in Thailand and demonstrates the complementary value of traditional statistical and machine learning approaches. The findings suggest that economic accessibility, social dimensions of travel, and tailored mode-specific enhancements should be prioritized in transportation planning for aging populations. By addressing the identified determinants of elderly travel behavior, policymakers can develop more inclusive, accessible transportation systems that enhance mobility and quality of life for this growing demographic group.

Data availability statement

The data analyzed in this study is subject to the following licenses/restrictions: The authors do not have permission to share the dataset. Requests to access these datasets should be directed to sajjakaj@sut.ac.th.

Ethics statement

The studies involving humans were approved by Ethics Committee of Suranaree University of Technology. The study was conducted according to the guidelines of the Declaration of Helsinki, and approved by the Ethics Committee of Suranaree University of Technology (COE No. 57/2567, 3 May 2023). Furthermore, verbal consent was secured from the volunteers and a detailed explanation of the questionnaire was provided prior to data collection. The studies were conducted in accordance with the local legislation and institutional requirements. Written informed consent for participation was not required from the participants or the participants' legal guardians/next of kin in accordance with the national legislation and institutional requirements.

Author contributions

AP: Formal Analysis, Writing – review and editing, Writing – original draft, Conceptualization, Data curation, Methodology. PW: Conceptualization, Writing – review and editing, Methodology. FW: Writing – review and editing, Data curation, Formal Analysis. CB: Formal Analysis, Writing – review and editing, Methodology. AC: Formal Analysis, Writing – review and editing, Data curation. TC: Validation, Writing – review and editing. VR: Writing – review and editing, Supervision, Software. SJ: Writing – review and editing, Visualization, Conceptualization, Supervision.

References

- Ali, M., Fahriza, N., Sadullah, A. E. M., Abdul Majeed, A. P. P., Razman, M. A. M., and Musa, R. M. (2022). He identification of significant features towards travel mode choice and its prediction via optimised random forest classifier: an evaluation for active commuting behavior. *J. Transp. Health* 25: 101362. doi:10.1016/j.jth.2022.101362
- Asare-Duah, S. (2024). *A temporal analysis of travel by the urban and rural elderly and their implications for transportation planning*. Cookeville, TN: Tennessee Technological University.
- Bakhshi, H., and Atri, F. (2025). Relationship between destination image and satisfaction in inbound tourists of Isfahan. *J. Urban Tour.* doi:10.22059/jut.2025.368727.1173
- Banyong, C., Hantanong, N., Wisutwattanasak, P., Champahom, T., Theerathitchaipa, K., Kasemsri, R., et al. (2025). Analyzing high-speed rail's transformative impact on public transport in Thailand using machine learning. *Infrastructures* 10 (3), 57. doi:10.3390/infrastructures10030057
- Banyong, C., Hantanong, N., Wisutwattanasak, P., Champahom, T., Theerathitchaipa, K., Seefong, M., et al. (2024). A machine learning comparison of transportation mode changes from high-speed railway promotion in Thailand. *Results Eng.* 24: 103110. doi:10.1016/j.rineng.2024.103110
- Ben-Akiva, M., and Lerman, S. R. (1985). *Discrete choice analysis: theory and application to travel demand*. MIT Press.
- Breiman, L. (2001). Random forests. *Mach. Learn.* 45 (1), 5–32. doi:10.1023/A:1010933404324
- Champahom, T., Chomsalasit, D., Dangbut, A., Watcharamaisakul, F., Jomnonkwa, S., and Ratanavara, V. (2025). Elderly travelers' expectations of high-speed railway services in Thailand: a comparative study of leisure and other purposes. *Travel Behav. Soc.* 39, 100984. doi:10.1016/j.tbs.2025.100984
- Chen, T., and Guestrin, C. (2016). XGBoost: a scalable tree boosting system. in Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 785–794. doi:10.1145/2939672.2939785
- Cheng, L., Chen, X., Yang, S., Cao, Z., De Vos, J., and Witlox, F. (2019a). Active travel for active ageing in China: the role of built environment. *J. Transp. Geogr.* 76, 142–152. doi:10.1016/j.jtrangeo.2019.03.010
- Cheng, L., De Vos, J., Shi, K., Yang, M., Chen, X., and Witlox, F. (2019b). Do residential location effects on travel behavior differ between the elderly and younger adults? *Transp. Res. Part D Transp. Environ.* 73, 367–380. doi:10.1016/j.trd.2019.07.015
- Creswell, J. W., and Creswell, J. D. (2017). *Research design: qualitative, quantitative, and mixed methods approaches*. Thousand Oaks, CA: Sage Publications.
- Dorogush, A. V., Ershov, V., and Gulin, A. (2018). CatBoost: gradient boosting with categorical features support.

Funding

The author(s) declare that financial support was received for the research and/or publication of this article. This project is funded by National Research Council of Thailand (NRCT) and Suranaree University of Technology (SUT), grant number are N42A660429 and 2/2566-NRCT.

Acknowledgments

The authors express their gratitude to the Suranaree University of Technology (SUT), Thailand Science Research and Innovation (TSRI), and National Research Council of Thailand (NRCT) for their support in undertaking this research.

Conflict of interest

The authors declare that the research was conducted in the absence of any commercial or financial relationships that could be construed as a potential conflict of interest.

Generative AI statement

The author(s) declare that no Generative AI was used in the creation of this manuscript.

Publisher's note

All claims expressed in this article are solely those of the authors and do not necessarily represent those of their affiliated organizations, or those of the publisher, the editors and the reviewers. Any product that may be evaluated in this article, or claim that may be made by its manufacturer, is not guaranteed or endorsed by the publisher.

- Du, M., Lin, C., Li, X., and Yang, J. (2020). Factors affecting the travel mode choice of the urban elderly in healthcare activity: comparison between core area and suburban area. *Sustain. Cities Soc.* 52, 101868. doi:10.1016/j.scs.2019.101868
- Elias, W., Albert, G., and Shiftan, Y. (2013). Travel behavior in the face of surface transportation terror threats. *Transp. Policy* 28: 114–122. doi:10.1016/j.tranpol.2012.08.005
- Hagenauer, J., and Helbich, M. (2017). A comparative study of machine learning classifiers for modeling travel mode choice. *Expert Syst. Appl.* 78, 273–282. doi:10.1016/j.eswa.2017.01.057
- Holmes, E., Arksteijn, M., Knowles, K., McKinney, T., Mizen, A., and Purcell, C. (2024). Understanding the interactions that children and young people have with their natural and built environments: a survey to identify targets for active travel behaviour change in Wales. *PLoS One* 19 (10), e0311498. doi:10.1371/journal.pone.0311498
- Hong, S.-Y., Cho, S.-H., and Park, H.-C. (2024). Behavioral differences between young adults and elderly travelers concerning the crowding effect on public transit after the COVID-19 pandemic. *Res. Transp. Econ.* 106, 101463. doi:10.1016/j.retrec.2024.101463
- Huang, P., Gong, L., Lei, T., Wang, J., Zhu, C., and Zhang, Z. (2024). "A comparative study of MNL and machine learning methods for travel mode choice of medical travel," in *International conference on traffic and transportation studies*. Springer, 305–313.
- Karlatfis, M. G., and Vlahogianni, E. I. (2011). Statistical methods versus neural networks in transportation research: differences, similarities and some insights. *Transp. Res. Part C Emerg. Technol.* 19 (3): 387–399. doi:10.1016/j.trc.2010.10.004
- Tee, E. H. (2022). Exploring transit use during COVID-19 based on XGB and SHAP using smart card data. *J. Adv. Transp.* 2022 (1), 6458371. doi:10.1155/2022/6458371
- Luiti, C., Tight, M., and Burrow, M. (2017). The unmet travel needs of the older population: a review of the literature. *Transp. Rev.* 37 (4), 488–506. doi:10.1080/01441647.2016.1252447
- Luiti, C., Tight, M., and Burrow, M. (2018). Factors preventing the use of alternative transport modes to the car in later life. *Sustainability* 10 (6), 1982. doi:10.3390/su10061982
- Lundberg, S. M., and Su-In, I. (2017). "A unified approach to interpreting model predictions," in *Proceedings of the 31st international conference on neural information processing systems*. Long Beach, California, USA: ACM, 4768–4777.
- McFadden, D. (1973). "Conditional logit analysis of qualitative choice behavior," in *Frontiers in econometrics*. Editor P. Zarembka (Academic Press), 105–142.
- Office of the National Economic and Social Development Council (2022). *Population development plan for long-term national development (2022–2037)*. Bangkok, Thailand: Office of the National Economic and Social Development Council. Available online at: https://www.nesdc.go.th/ewt_dl_link.php?nid=13502.
- Powers, D. M. W. (2020). *Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation*. arXiv Prepr. arXiv:2010.16061.
- Prasertsubpakij, D., and Nitivattananon, V. (2012). Evaluating accessibility to Bangkok Metro Systems using multi-dimensional criteria across user groups. *IATSS Res.* 36 (1): 56–65. doi:10.1016/j.iatssr.2012.02.003
- Prokhorenkova, L., Gusev, G., Vorobev, A., Dorogush, A. V., and Gulin, A. (2018). CatBoost: unbiased boosting with categorical features. *Adv. Neural Inf. Process. Syst.* 31, 10.48550/arXiv.1706.09516
- Shi, Z., Zhou, C., Cheng, L., He, M., and Liu, Y. (2024). Examining spatial variations in walking activity among older adults considering the impact of topographical characteristics. *Transp. Res. Rec.* 03611981241302339. doi:10.1177/03611981241302339
- Sukkasem, A., and Soratana, K. (2024). Life Cycle Assessment of Incentive Travel: a case of Phitsanulok Province. *J. Int. Thai Tour.* 20 (2). Available online at: <https://so02.tci-thaijo.org/index.php/jitt/article/view/267806>
- Sukto, A. (2021). *Travel patterns and public transportation for aging society (in Thai)*. National Assembly of Thailand. Available online at: https://www.parliament.go.th/ewtdadmin/ewtd/parliament_parcy/download/article/article_20210423152404.pdf.
- Tianqi, C., and Carlos, G. (2016). "XGBoost: a scalable tree boosting system," in *Proceedings of the 22nd ACM sigkdd international conference on knowledge discovery and data mining*. ACM 785–794.
- Train, K. E. (2009). *Discrete choice methods with simulation*. Cambridge University Press.
- United Nations (2019). *World population prospects 2019: highlights*. Available online at: <https://population.un.org/wpp/>.
- Wang, F., and Ross, C. L. (2018). Machine learning travel mode choices: comparing the performance of an Extreme gradient boosting model with a multinomial logit model. *Transp. Res. Rec.* 2672 (47), 35–45. doi:10.1177/0361198118773556
- Wei, Q., Zhang, N., Gao, Y., Chen, C., Wang, Li, and Yang, J. (2024). Bus network adjustment pre-evaluation based on biometric recognition and travel spatio-temporal deduction. *Algorithms* 17 (11), 513. doi:10.3390/a17110513
- Yan, X., Liu, X., and Zhao, X. (2020). Using machine learning for direct demand modeling of ridesourcing services in Chicago. *J. Transp. Geogr.* 83: 102661. doi:10.1016/j.jtrangeo.2020.102661
- Zamprognio, M. M., and Esztergar-Kiss, D. (2024). Applying cluster analysis for the investigation of travel behavior and user profiles. *Period. Polytech. Transp. Eng.* 52 (4), 362–371. doi:10.3311/pptr.25663
- Zhang, G., Wang, D., Cai, Z., and Zeng, J. (2024). Competitiveness of public transit considering travel time reliability: a case study for commuter trips in Hangzhou, China. *J. Transp. Geogr.* 114: 103768. doi:10.1016/j.jtrangeo.2023.103768
- Zhang, H., Zhang, Li, Liu, Y., and Zhang, L. (2023). Understanding travel mode choice behavior: influencing factors analysis and prediction with machine learning method. *Sustainability* 15 (14), 11414. doi:10.3390/su151411414
- Zhang, Z., Jalali, M. S., and Ghaffarzadeegan, N. (2025). Behavioral dynamics of epidemic trajectories and vaccination strategies: a simulation-based analysis. *J. Artif. Soc. Simul.* 28 (1), 1–3. doi:10.18564/jasss.5583
- Zhang, Z., and Maruyama, T. (2024). "Exploring the heterogeneity of the travel behavior of the elderly in the kumamoto metropolitan area based on latent Class analysis," in *24th COTA International Conference of Transportation Professionals*. Shenzhen, China, 23 07, 2024–26 07, 2024, ASCE 955–964.
- Zhu, Y., Jiang, M., and Yamamoto, T. (2025). Personality, functional performance, and travel patterns related to older drivers' risky driving behavior: a naturalistic driving study. *Accid. Analysis Prev.* 209, 107833. doi:10.1016/j.aap.2024.107833

ประวัติผู้เขียน

นางสาวอนันตญา พิลีก เกิดวันที่ 18 เมษายน พ.ศ. 2541 สำเร็จการศึกษาระดับประถมศึกษาจากโรงเรียนยอแซฟพิจิตร ในปีการศึกษา 2552 สำเร็จการศึกษาระดับมัธยมศึกษาจากโรงเรียนพิจิตรพิทยาคม ในปีการศึกษา 2558 และสำเร็จการศึกษาระดับปริญญาตรีจากสำนักวิศวกรรมศาสตร์ สาขาวิชาวิศวกรรมขนส่ง มหาวิทยาลัยเทคโนโลยีสุรนารี ในปีการศึกษา 2562 จากนั้นได้เข้าทำงานที่บริษัทเอกชัย ดิสทริบิวชั่น จำกัด ศูนย์กระจายสินค้าวังน้อย ในตำแหน่ง Graduate Option Trainee ในปีพ.ศ. 2564-2566 เป็นเวลา 2 ปี จากนั้นกลับมาศึกษาต่อในระดับปริญญาโท สำนักวิศวกรรมศาสตร์ สาขาวิชาวิศวกรรมขนส่ง หลักสูตรวิศวกรรมโยธา ขนส่ง และทรัพยากรธรณี (พ.ศ. 2563) มหาวิทยาลัยเทคโนโลยีสุรนารี ในปี พ.ศ. 2566

