

การเพิ่มประสิทธิภาพของการประเมินราคาบ้านพักอาศัย โดยใช้ ข้อมูลเชิงพื้นที่ และรูปภาพ

ENHANCING HOUSE PRICE ESTIMATION USING SPATIAL INFORMATION AND IMAGES

วรกร เล็กอาราม¹

ดร.ชนภัทร มั่งคะจิตร²

บทคัดย่อ

การประเมินราคาบ้านพักอาศัยมีส่วนสำคัญในการพัฒนาอสังหาริมทรัพย์ โดยเป็นเครื่องมือที่ช่วยในการตัดสินใจในการซื้อขายทั้งผู้พัฒนาอสังหาริมทรัพย์และผู้ซื้อ โดยทั่วไปการประเมินราคามีค่าใช้จ่ายที่สูงและมีขั้นตอนการดำเนินการที่ใช้เวลา เนื่องจากผู้ประเมินต้องลงพื้นที่เพื่อเก็บข้อมูล ดังนั้นหลายงานวิจัยมีการนำเสนอการประยุกต์ใช้เทคนิคจักรกลเรียนรู้ในการประเมินราคาบ้านพักอาศัยที่ให้ความแม่นยำค่อนข้างสูง เป็นที่รู้กันว่าข้อมูลที่เกี่ยวข้องกับบ้าน และข้อมูลเชิงพื้นที่ซึ่งบ่งบอกถึงทำเลที่ตั้งของบ้าน เป็นปัจจัยสำคัญในการประเมินราคาบ้าน เช่นเดียวกันกับสภาพบ้าน ดังนั้นงานวิจัยนี้จึงนำเสนอการเพิ่มประสิทธิภาพการประเมินราคาบ้านพักอาศัยโดยใช้ข้อมูล 1) สภาพของบ้าน 2) ข้อมูลเชิงพื้นที่ และ 3) ข้อมูลที่เกี่ยวข้องกับบ้าน ร่วมกันในการประเมินราคา โดยงานวิจัยนี้เสนอวิธีการสกัดตัวแทนสภาพบ้านจากรูปภาพบ้านด้านหน้าโดยใช้เทคนิคการเรียนรู้เชิงลึก เริ่มจากรูปภาพบ้านด้านหน้าจะถูกคัดเลือกมาใช้งานด้วย AutoEncoder หลังจากนั้นจะนำรูปภาพด้านหน้าไปสร้างแบบจำลองโดยใช้อัลกอริทึม CNN-based model (ResNet50) เพื่อจำแนกประเภทราคาบ้านเป็นราคาต่ำหรือราคาสูง แล้วจึงนำแบบจำลองที่ได้ตัดส่วนปลายทิ้งไปเพื่อใช้เป็นตัวแทนของปัจจัยรูปภาพบ้านด้านหน้า แล้วจึงนำมาใช้เป็นปัจจัยร่วมกับข้อมูลบ้านและข้อมูลเชิงพื้นที่ในการทำนายราคาประเมินบ้านโดยใช้แบบจำลอง XGBoost Regression ข้อมูลที่นำมาใช้เป็นข้อมูลบ้านพักอาศัยในเขตปทุมธานีในช่วงเดือนพฤษภาคมถึงเดือนมิถุนายน ปี พ.ศ. 2566 ที่ประกาศขายใน www.baania.com ผลการศึกษาพบว่าแบบจำลองที่นำเสนอให้ประสิทธิภาพในการประเมินที่แม่นยำมากกว่าแบบจำลองที่ใช้เพียงข้อมูลบ้านเพียงอย่างเดียว

¹ นักศึกษาหลักสูตรวิศวกรรมศาสตรมหาบัณฑิต สาขาวิศวกรรมข้อมูลขนาดใหญ่

² ที่ปรึกษาสารนิพนธ์หลัก

อย่างไรก็ตามปัจจัยสภาพบ้านไม่ได้เพิ่มประสิทธิภาพในการอย่างมีนัยสำคัญ ดังนั้นรูปภาพบ้านด้านหน้าอาจจะยังไม่เพียงพอที่จะเป็นตัวแทนแสดงถึงสภาพของบ้าน ดังนั้นควรมีการเพิ่มรูปภาพห้องต่างๆในบ้านซึ่งจะช่วยบอกถึงสภาพของบ้านได้อย่างละเอียดและทำให้การประเมินราคามีประสิทธิภาพยิ่งขึ้น

คำสำคัญ : การประเมินราคาบ้าน, รูปภาพบ้านด้านหน้า, สภาพของบ้าน, การเรียนรู้เชิงลึก, เทคนิคจักรกลเรียนรู้, ข้อมูลเชิงพื้นที่

ABSTRACT

House Price Estimation plays a crucial role in real estate development as a decision-making tool for both developers and customers. Generally, it is an expensive and time-consuming task since the appraisers need the collected data from the field. Therefore, several machine learning techniques are utilized and produce relatively high predictive performance. Indeed, house information and spatial information are the essential features to estimate house price as well as the house's condition. In this work, we propose an approach to enhance house price estimation by incorporating the house condition, spatial information, and house information. To extract the house's condition, we take the house front images into account. Initially, only the house-front pictures are selected using AutoEncoder. Then, the CNN-based model (ResNet50) is trained on those house front images to classify them as high or low price. To represent house condition features, the last layer of the trained CNN model is removed. Therefore, the final input features are generated from those features combined with the house information and spatial information. Finally, the regression model (XGBoostRegression) is built to predict house prices. The experimental data are the houses for sale in Pathum Thani province during May and June 2023 collected from www.baania.com. The experimental results showed that the predictive performance of our model outperforms the based-line model using only house information. However, the house condition features seem not to increase predictive performance immensely. Hence the house front pictures are insufficient to represent the house's condition. Thus, the images of different rooms in the house are further determined to obtain a better predictive performance of house price estimation.

Keywords: House Price Estimation, House Front Image, House Condition, Deep Learning, Machine Learning, Spatial Information

บทนำ

การทำนายราคามีส่วนช่วยในการตัดสินใจซื้อขายทั้งกับผู้พัฒนาอสังหาริมทรัพย์และผู้ซื้อผู้พัฒนาอสังหาริมทรัพย์และผู้ซื้อสามารถเปรียบเทียบได้ว่าเป็นราคาที่เหมาะสมหรือไม่ในการซื้อขาย อีกทั้งราคาอสังหาริมทรัพย์ยังแสดงถึงสภาพเศรษฐกิจของประเทศได้อย่างหนึ่ง ซึ่งโดยทั่วไปการประเมินราคาบ้านต้องใช้ผู้เชี่ยวชาญในการลงพื้นที่ เพื่อไปเก็บข้อมูลและประเมินราคา มีขั้นตอนและค่าใช้จ่ายในการดำเนินงานเวลาที่ใช้ดำเนินการค่อนข้างนาน ทั้งนี้เพื่อลดเวลา และลดค่าใช้จ่ายในการดำเนินงานโดยผู้เชี่ยวชาญ ทั้งเพื่อเพิ่มความรวดเร็วในการตัดสินใจในการซื้อขายอสังหาริมทรัพย์ ทำให้การพัฒนาแบบจำลองเพื่อทำนายราคาบ้านเป็นที่น่าสนใจ

งานวิจัยนี้มีวัตถุประสงค์เพื่อปรับปรุงประสิทธิภาพของแบบจำลองที่ใช้ในการประเมินราคาบ้านมือสอง โดยใช้ข้อมูลเชิงพื้นที่ และข้อมูลรูปภาพบ้าน มาเพื่อเพิ่มประสิทธิภาพในการประเมินราคา ผลการทดลองบนข้อมูลบ้านมือสองในจังหวัดปทุมธานี พบว่า การใช้ข้อมูลเชิงพื้นที่ และรูปภาพด้านหน้าบ้าน สามารถเพิ่มประสิทธิภาพการประเมินราคาบ้านได้

วัตถุประสงค์ของงานวิจัย

เพื่อเพิ่มประสิทธิภาพในการประเมินราคาบ้านมือสอง โดยใช้ปัจจัย 1) ข้อมูลบ้าน 2) ข้อมูลเชิงพื้นที่ 3) รูปภาพบ้าน

ขอบเขตงานวิจัย

1. ข้อมูลบ้านมือสองที่มีการลงประกาศขาย ในเดือนพฤษภาคมถึงเดือนมิถุนายน ปี พ.ศ. 2566 บนเว็บไซต์ประกาศขายบ้าน <https://www.baania.com> จากการทำ web scrapping ข้อมูลในจังหวัดปทุมธานีซึ่งเป็นจังหวัดหนึ่งในเขตปริมณฑล ประเทศไทย ในช่วงราคาไม่เกิน 10 ล้านบาท

2. ข้อมูล POIs ในจังหวัดปทุมธานี ได้แก่ โรงเรียน, สถานีบริการพลังงาน, ร้านสะดวกซื้อ, ไฮเปอร์มาร์เก็ต, ธนาคาร, บริการสาธารณสุข, มหาวิทยาลัย, ร้านกาแฟ, ร้านขายยา, ศูนย์การค้า, สถานีรถไฟฟ้า BTS

ทฤษฎี และผลงานที่เกี่ยวข้อง

1. ทฤษฎี

Spatial Information ข้อมูลเชิงพื้นที่ เป็นข้อมูลที่เกี่ยวข้องกับตำแหน่งทางภูมิศาสตร์ของวัตถุหรือเหตุการณ์ในโลก ซึ่งสามารถอธิบายลักษณะเชิงพื้นที่ของวัตถุได้ เช่น พิกัดทางภูมิศาสตร์ (geographic coordinates) เช่น ละติจูดและลองจิจูด รูปร่างและขอบเขตทางภูมิศาสตร์ และความสัมพันธ์กับวัตถุหรือเหตุการณ์อื่นๆ ในพื้นที่เดียวกันหรือบริเวณใกล้เคียง

AutoEncoder เป็นโครงข่ายประสาทเทียมที่ออกแบบขึ้นเพื่อเรียนรู้การเข้ารหัส (encoding) และการถอดรหัส (decoding) ข้อมูล เพื่อสร้างภาพรวม (representation) ที่มีความสามารถในการรักษาข้อมูลต้นฉบับโดยใช้มาตรการการบีบอัด (compression) และการนำความหมาย (meaning) ออกมาจากข้อมูลโดยมีลักษณะโครงสร้างหลักประกอบไปด้วยส่วนของ Encoder, Latent layer และส่วนของ Decoder มักถูกนำมาใช้ในการตรวจจับข้อมูลแปลกปลอม เนื่องจากถ้าเป็นข้อมูลแปลกปลอมหลังจาก Decoder จะได้ข้อมูลแตกต่างไปจากเดิมมาก (Hinton, G.E. & Zemel, R.S., 1993)

ResNet50 เป็นแบบจำลองสำหรับการเรียนรู้ของโครงข่ายประสาทเชิงลึก (deep neural network) ที่ถูกพัฒนาขึ้นโดยทีมวิจัยจาก Microsoft Research ในปี 2015 โดยมีชื่อเต็มว่า "Residual Network 50 layers" (ResNet50) แบบจำลองนี้ได้รับความนิยมและนำมาใช้ในงานประมวลผลภาพหลากหลายเช่นการจดจำใบหน้า (facial recognition) การตรวจจับวัตถุ (object detection) และการจำแนกภาพ (image classification) ซึ่งมีการนำไปประยุกต์ใช้ในหลายๆ งานที่เกี่ยวข้องกับการประมวลผลภาพ (He, K. et al., 2016)

XGboost (Extreme Gradient Boosting) เป็นตัวจัดการเรียนรู้แบบมีผู้สอน (supervised learning) ที่เป็นแบบอัลกอริทึม (algorithm) สำหรับการจัดการกับปัญหาการจำแนก (classification) และการทำนาย (regression) ในข้อมูลที่มีลักษณะตาราง (tabular data) โดย XGBoost ใช้เทคนิคต่อเติมต้นแบบ (boosting) เพื่อปรับปรุงแบบจำลองให้มีความแม่นยำสูงขึ้น XGBoost มีคุณสมบัติที่น่าสนใจเช่น การจัดการกับความหนาแน่นของข้อมูลได้ดี การทำงานแบบการกระจาย (distributed computing) เพื่อประมวลผลข้อมูลได้รวดเร็ว และการตรวจสอบคุณลักษณะที่สำคัญในการทำนาย (feature importance) เพื่อวิเคราะห์และตรวจสอบคุณลักษณะที่มีผลกระทบสูงสุดในการตัดสินใจของแบบจำลอง (Chen, T. & Guestrin, C., 2016)

2. งานวิจัยที่เกี่ยวข้อง

Srirutchataboon, G. et al. Stacking Ensemble Learning for Housing Price Prediction: a Case Study in Thailand (2021) นำเสนอการใช้ CNN ทำการสกัด features จากรูปภาพบ้าน โดยทำการเทรนแบบจำลอง เพื่อทำการจำแนกหรือแบ่งกลุ่มข้อมูลช่วงราคาบ้านจากรูปภาพ โดยแบ่งออกเป็น 3 ช่วง (1) ราคาต่ำกว่า 3 ล้านบาท

(2) ราคาในช่วง 3-7 ล้านบาท (3) ราคาตั้งแต่ 7 ล้านบาทขึ้นไป โดยใช้ VGG19 ที่มีการตัดส่วนสุดท้ายออกและเพิ่มชั้นโครงข่ายประสาทเทียม 5 จุด และชั้นสำหรับแบ่งกลุ่ม 3 กลุ่ม และนำตัวแปรที่ได้จากรูปภาพ ซึ่งได้จากชั้นโครงข่ายประสาทเทียม 5 จุด ไปใช้ร่วมกับข้อมูลบ้านเพื่อสร้างแบบจำลองทำนายราคาด้วย XGBoost ซึ่งผลการทดสอบให้ MAPE 17.83% บนข้อมูลบ้านในเขตจังหวัดกรุงเทพมหานครและปริมณฑล


Wang, P. et al. Deep Learning Model for House Price Prediction Using Heterogeneous Data Analysis Along With Joint Self-Attention Mechanism (2021) นำเสนอการใช้ข้อมูลสิ่งอำนวยความสะดวกส่วนกลางสาธารณะ (Public Facilities Data) ภาพถ่ายดาวเทียม (Google Satellite Image) และข้อมูลบ้าน (House Transaction Data) ในการใช้ร่วมกันทำนายราคาบ้าน ซึ่งสามารถปรับปรุงประสิทธิภาพการทำนายราคาบ้านได้ ในส่วนของข้อมูลสิ่งอำนวยความสะดวกสาธารณะที่ถูกนำมาใช้ ได้แก่ ร้านค้า (Stores) สวนสาธารณะ (Park) รถไฟฟ้าขนส่งมวลชน (MRT) โรงพยาบาล (Hospital) โดยมีการคำนวณหาระยะทางต่างที่กำหนด ระหว่างบ้าน และสิ่งอำนวยความสะดวกเหล่านั้น

Chow, J. K., et al. Anomaly detection of defects on concrete structures with the convolutional autoencoder (2020) นำเสนอการใช้ Convolution AutoEncoder ในการตรวจจับการแตกร้าวของโครงสร้างคอนกรีต โดยใช้การเทรนแบบจำลองด้วยภาพคอนกรีตที่มีสภาพปกติและไม่แตก เมื่อนำแบบจำลองดังกล่าวไปทดสอบกับภาพคอนกรีตที่มีรอยแตกร้าวหรือไม่ปกติจะมีค่า ภาพที่ได้จะมีค่า reconstruction error ที่สูงทำให้สามารถตรวจจับภาพแตกร้าวได้ เป็นการเรียนรู้โดยที่ไม่ต้องมีการ label ภาพคอนกรีตที่แตกให้กับตัวข้อมูล

ระเบียบวิธีวิจัย

งานวิจัยนี้นำเสนอการปรับปรุงประสิทธิภาพในการประเมินราคาบ้านพักอาศัยโดยใช้ข้อมูลเชิงพื้นที่ และรูปภาพ โดยทำการศึกษาปัจจัย ได้แก่ (1) ตัวแปรข้อมูลบ้าน ได้แก่ จำนวนห้องนอน จำนวนห้องน้ำ พื้นที่ดิน (2) ตัวแปรเชิงพื้นที่ ได้แก่ ละติจูด ลองจิจูด ของทรัพย์สิน จำนวน POIs ในระยะ 1 กิโลเมตร 3 กิโลเมตร 5 กิโลเมตร และระยะทางใกล้สุดจากบ้านไปยัง POIs (3) รูปภาพด้านหน้าบ้าน

ภาพสรุปแนวคิดวิธีวิจัย เป็นดังภาพต่อไปนี้



ภาพที่ 1 ภาพสรุปแนวคิดวิธีวิจัย

1. การเตรียมข้อมูล

1.1 รวบรวมข้อมูลโดยการทำ web scrapping บนเว็บไซต์ <https://www.baania.com> ข้อมูลที่ทำการรวบรวม เป็นข้อมูลบ้านในจังหวัดปทุมธานี ที่ประกาศขายในเดือนพฤษภาคมถึงมิถุนายน ปี พ.ศ. 2566

ตารางที่ 1 ตารางแสดงตัวอย่างข้อมูลที่ได้จากเว็บไซต์

	Name	price	latlong	pic	stair	bed	bath	space	area_ usable	parking	kitchen	living	maid
0	ขาย บ้านเดี่ยว ราคา คุ้มสุด เวนิว ดิวา นนท์-รังสิต 175 ตรม. 50 ตร.วา SC ASSET Brand	6,790,000 THB	"https://www.google .com/maps/search/?a pi=1&query=13.963, 100.495"	https://cdn.baania.com /b20/listings/6373b862 b53b839c18e3fd1c/ma in/original/main.jpeg	2 ชั้น	3 ห้อง นอน	3 ห้อง น้ำ	50 ตร.ว.	175 ตร.ม.	NaN	NaN	NaN	NaN

1.2 จากข้อมูลที่ได้จากเว็บไซต์จำนวน 1,551 ข้อมูล ทำการเลือกข้อมูลช่วงช่วงราคาไม่เกิน 10 ล้านบาท ทำการตัดข้อมูล missing และข้อมูลซ้ำอันเนื่องมาจากมีผู้ลงประกาศขายบ้านหลังเดียวกันซ้ำหลายเพจ เหลือข้อมูลที่นำมาพิจารณาต่อ 1,228 ข้อมูล

1.3 ทำการแปลงข้อมูล ละติจูด ลองจิจูด เป็นจุด POINT ข้อมูลเชิงพื้นที่ด้วยไลบรารี geopandas


1.4 นำเข้าข้อมูล POIs (Point of Interests) จำนวน 11 ประเภท ในจังหวัดปทุมธานี ได้แก่ โรงเรียน, สถานีบริการพลังงาน, ร้านสะดวกซื้อ, ไฮเปอร์มาร์เก็ต, ธนาคาร, บริการสาธารณสุข, มหาวิทยาลัย, ร้านกาแฟ, ร้านขายยา, ศูนย์การค้า, สถานีรถไฟฟ้า BTS

1.5 สร้างตัวแปรจาก POIs กับบ้าน ได้แก่ ระยะทางที่ใกล้ที่สุดของแต่ละ POIs จำนวน POI ในระยะ 1 กิโลเมตร จำนวน POI ในระยะ 3 กิโลเมตร และจำนวน POI ในระยะ 5 กิโลเมตร

2. การสร้างแบบจำลองเพื่อจัดแยกหมู่บ้าน

เนื่องจากข้อมูลรูปภาพที่ได้จากเว็บไซต์ มีผู้ประกาศขายลงรูปที่ไม่ใช่รูปภาพด้านข้างหน้าบ้าน เช่น รูปภาพภายในบ้าน รูปป้าย เป็นต้น ในสารนิพนธ์นี้ต้องการใช้รูปภาพหน้าด้านหน้าบ้าน เป็นปัจจัยในการทำนายราคาบ้าน จึงต้องการที่คัดเลือกข้อมูลรูปภาพที่ไม่ใช่รูปด้านหน้าบ้านออกไป

2.1 ทำการสร้างแบบจำลอง AutoEncoder อ้างอิงจาก Rosebrock (2020) และนำรูปภาพบ้านเป็นข้อมูลสำหรับการเทรนแบบจำลอง



ภาพที่ 2 โครงสร้างแบบจำลอง AutoEncoder

2.2 หลังจากการเทรนแบบจำลอง นำแบบจำลองที่ได้ ไปใช้หา reconstruction error ของแต่ละภาพ

2.3 ภาพที่ไม่ใช่ภาพบ้านจะมีค่า reconstruction error ที่สูง ภาพที่มี reconstruction error เกินค่า threshold 75% จะถูกตัดออก ดังภาพที่ 3 ทำให้เหลือข้อมูลที่ใช้ในการศึกษา 923 ข้อมูล



ภาพที่ 3 ภาพที่ถูกคัดออก (รูปที่ 1-3) และภาพบ้านที่ถูกนำไปใช้ต่อ (รูปที่ 4-6)

3. การสร้างแบบจำลองเพื่อสกัดตัวแปรจากภาพ

เพื่อนำไปสู่การสกัดตัวแปรที่เป็นตัวแทนลักษณะสำคัญของรูปภาพด้านหน้าบ้าน ได้มีการสร้างแบบจำลองจาก ResNet50 ที่มีการปรับปรุงส่วนปลายเพื่อใช้ทำนายช่วงของราคาบ้าน มีขั้นตอนดังต่อไปนี้


3.1 ทำการแบ่งกลุ่มข้อมูลตามช่วงราคา ซึ่งในการทดลองมีการแบ่งกลุ่ม 3 รูปแบบ

รูปแบบที่ 1 แบ่ง 3 กลุ่ม (1) ราคาต่ำกว่า 3 ล้านบาท (2) ราคาในช่วง 3-7 ล้านบาท (3) ราคา 7 ล้านบาทขึ้นไป รูปแบบที่ 2 แบ่ง 2 กลุ่ม (1) ราคาต่ำกว่า 4 ล้านบาท (2) ราคา 4 ล้านบาทขึ้นไป รูปแบบที่ 3 แบ่ง 2 กลุ่ม (1) ราคาต่ำกว่า 5 ล้านบาท (2) ราคา 5 ล้านบาทขึ้นไป

3.2 สร้างแบบจำลองเพื่อทำการจำแนกแบ่งกลุ่มของช่วงราคาบ้านจากรูปภาพ โดยใช้แบบจำลอง ResNet50 Pre-trained model ใช้ weight เป็น ImageNet ที่มีการนำชั้นด้านบนออก เพิ่มชั้นโครงข่ายประสาทเทียม 256 จุด เพิ่มชั้นโครงข่ายประสาทเทียม 50 จุด และเพิ่มชั้นสุดท้ายเพื่อจำแนกแบ่งกลุ่ม 2 จุด หรือ 3 จุด ขึ้นอยู่กับจำนวนกลุ่มช่วงราคาที่เป็นแบ่ง ดังภาพที่ 4

3.3 ทำการเตรียมภาพเพื่อนำเข้าแบบจำลอง โดยแปลงเป็นขนาด 224x224 สำหรับขาเข้าของ ResNet50 และทำการทำ augmentation รูปภาพเพื่อลด overfitting

3.4 ให้แบบจำลองเรียนรู้ และทำการบันทึกค่าน้ำหนักที่ดีที่สุด และนำแบบจำลองที่ได้ตัดส่วนชั้นสุดท้ายที่มีการแยกกลุ่มออก และนำมาสร้าง 50 ตัวแปร จากรูปภาพทั้งหมดเพื่อใช้เป็นตัวแปรจากรูปภาพ



ภาพที่ 4 โครงสร้างแบบจำลอง RestNet50 ที่ทำการปรับปรุงส่วนปลาย

4. การสร้างแบบจำลองประเมินราคาบ้าน

4.1 สร้างแบบจำลองสำหรับประเมินราคาบ้าน โดยใช้แบบจำลอง XGBoost

4.2 นำข้อมูลบ้าน 3 ตัวแปร ข้อมูลเชิงพื้นที่ 46 ตัวแปร และตัวแปรที่สกัดได้จากรูปภาพที่ได้จากการเรียนรู้ในขั้นตอนที่ 3 ทั้ง 50 ตัวแปร ทำการเรียงต่อข้อมูลเพื่อเข้าสู่แบบจำลอง

4.3 นำข้อมูลมาทำการ normalization ทำการแบ่งข้อมูลออกเป็น train : test 75 : 25 ตามลำดับ และนำเข้าแบบจำลองเพื่อเรียนรู้

ผลการศึกษา

1. ผลการวัดประสิทธิภาพของแบบจำลองในการทำนายช่วงราคาบ้านจากรูปภาพ

เพื่อนำไปสู่การสกัดตัวแปรที่เป็นตัวแทนลักษณะสำคัญของรูปภาพ ได้มีสร้างแบบจำลองจาก ResNet50 ที่มีการปรับปรุงส่วนปลายเพื่อใช้ทำนายช่วงกลุ่มของราคาบ้านจากข้อมูลรูปภาพ มีการแบ่งกลุ่มของราคาบ้าน 3 รูปแบบและทำการทดสอบ (ดังแสดงในตารางที่ 2)

ในการทดลองแบ่งกลุ่มราคาออกเป็น 3 ช่วง นั่นคือในช่วงราคาต่ำกว่า 3 ล้านบาท (Class0) ราคาในช่วง 3 – 7 ล้านบาท (Class1) ราคา 7 ล้านบาทขึ้นไป (Class2) อ้างอิงการแบ่งช่วงราคาตามงานวิจัย Srirutchataboon, G. (2021) ทำนายโดยการใช้ loss เป็น categorical_crossentropy ผลการทดลองที่ได้ แบบจำลองทำนาย ราคาในช่วง 3 – 7 ล้านบาท (Class1) เพียงอย่างเดียว เนื่องจากจำนวนข้อมูลของ Class1 ที่มีจำนวนมาก ดังภาพที่ 5(a)

เทคนิค under-sampling OneSideSelection ถูกพิจารณานำมาใช้ เนื่องจากข้อมูลมีจำนวนแตกต่างกันมาก จากการ under-sampling ผลการทดลองที่ได้ แบบจำลองยังคงทำนาย ราคาในช่วง 3 – 7 ล้านบาท (Class1) เพียงอย่างเดียว ดังภาพที่ 5(b)

เนื่องจากจำนวนในแต่ละกลุ่มมีจำนวนที่แตกต่างกันมาก เมื่อตรวจสอบจากการกระจายตัวของข้อมูล การแบ่งข้อมูลออกเป็น 2 กลุ่ม ดังต่อไปนี้ ราคาต่ำกว่า 4 ล้านบาท (Class0) ราคา 4 ล้านบาทขึ้นไป (Class1) ทำให้ข้อมูลมีขนาดใกล้เคียงกัน และผลที่ได้จากการทดลอง แบบจำลองสามารถแยกกลุ่มราคาจากรูปภาพได้ ดังภาพที่ 5(c)


สำหรับรูปบ้านที่มีราคาสูงกว่า 4 ล้านบาท แต่แบบจำลองทำนายต่ำกว่า 4 ล้านบาท (44%) พบว่า อาจเกิดจาก ข้อมูลภาพบ้านราคา 4 ถึง 5 ล้านมีปริมาณใกล้เคียงกัน ดังนั้นจึงทดลองปรับเป็น 2 ช่วงคือ (1) ราคาต่ำกว่า 5 ล้านบาท และ (2) 5 ล้านบาทขึ้นไป โดยมีสมมติฐานว่าจะทำนายแม่นยำขึ้น ทำการแบ่งกลุ่มข้อมูลออกเป็นราคาต่ำกว่า 5 ล้านบาท (Class0) ราคา 5 ล้านบาทขึ้นไป (Class1) ผลการทดลองที่ได้ แบบจำลองทำนายรูปภาพส่วนใหญ่เป็น Class0 ดังภาพที่ 5(d) เนื่องจากข้อมูลที่ใช้เทรน Class0 มีจำนวนมาก

BinaryFocalCrossentropy เป็น loss ที่ถูกพิจารณาใช้เมื่อข้อมูลมีจำนวนที่แตกต่างกัน อย่างไรก็ตาม ผลการทดลองที่ได้ แบบจำลองทำนายรูปภาพส่วนใหญ่เป็น Class0 ดังภาพที่ 5(e)

ท้ายที่สุด แบบจำลองที่เกิดการเรียนรู้โดยแบ่งข้อมูลเป็น 2 กลุ่ม โดยที่แบ่งเป็น (1) ต่ำกว่าราคา 4 ล้านบาท (2) ราคาตั้งแต่ 4 ล้านบาทขึ้นไป ให้ความแม่นยำมากที่สุดในการทำนายช่วงราคาจากรูปภาพ แบบจำลองนี้ถูกนำมาใช้ในการสกัดข้อมูลสำคัญของรูปภาพออกมาเป็นจำนวน 50 ตัวแปร ในการใช้เป็นตัวแปร ตัวแทนของรูปภาพ เพื่อนำมารวมกับ ข้อมูลบ้าน และข้อมูลเชิงพื้นที่ ในการสร้าง Regression แบบจำลองต่อไป

ตารางที่ 2 แสดงประสิทธิภาพการทำนายช่วงราคาบ้านจากรูปภาพ

No.	Number of Classes / สัดส่วนรูปภาพแต่ละ class	Description	loss	Validation accuracy	Validation loss
1	3 Class0 : Class1 : Class2 174 : 642 : 107	Class0: ต่ำกว่า 3 ล้านบาท Class1: ระหว่าง 3-7 ล้านบาท Class2: 7 ล้านบาทขึ้นไป	categorical_crossentropy	0.6667	0.8400
2	3 และ under-sampling Class0 : Class1 : Class2 174 : 258 : 107	Class0: ต่ำกว่า 3 ล้านบาท Class1: ระหว่าง 3-7 ล้านบาท Class2: 7 ล้านบาทขึ้นไป	categorical_crossentropy	0.6977	0.8561
3	2 Class0 : Class1 442 : 481	Class0: ต่ำกว่า 4 ล้านบาท Class1: 4 ล้านบาทขึ้นไป	categorical_crossentropy	0.6433	0.6277
4	2 Class 0 : Class 1 625 : 298	Class0: ต่ำกว่า 5 ล้านบาท Class1: 5 ล้านบาทขึ้นไป	categorical_crossentropy	0.6926	0.6027
5	2 Class 0 : Class 1 625 : 298	Class0: ต่ำกว่า 5 ล้านบาท Class1: 5 ล้านบาทขึ้นไป	BinaryFocalCrossentropy	0.7013	0.1486



ภาพที่ 5 แสดง confusion matrix ของการทดสอบการทำนายช่วงราคาบ้านจากรูปภาพ

2. ผลการวัดประสิทธิภาพของแบบจำลองของการประเมินราคา

ผลการประเมินราคาบ้านโดยใช้แบบจำลอง XGBoost ในการทำนาย โดยใช้ปัจจัย ได้แก่ (1) ข้อมูลบ้าน (2) ข้อมูลเชิงพื้นที่ (3) ข้อมูลตัวแปรที่สกัดได้จากรูปภาพ ให้ผลการทดสอบแสดงดัง ตารางที่ 3 โดยที่ การใช้ข้อมูลบ้านร่วมกับข้อมูลเชิงพื้นที่ทำให้แบบจำลองมีความแม่นยำมากขึ้นจากการประเมินราคาบ้านโดยใช้ข้อมูลบ้านอย่างเดียว และการใช้ข้อมูลรูปภาพด้านหน้าบ้านร่วมกับข้อมูลเชิงพื้นที่และข้อมูลบ้าน ให้แบบจำลองที่แม่นยำมากที่สุด

ตารางที่ 3 ผลการเปรียบเทียบประสิทธิภาพของแบบจำลองการประเมินราคาบ้าน

Features หน่วยวัด	House Info.	House Info. + POIs	House Info. + POI + Image
MAE	0.09848	0.07672	0.07444
MAPE	0.24538	0.18758	0.18190
RMSE	0.13445	0.10821	0.10777
R2	0.49239	0.67122	0.67386
STD	34.09 %	24.37 %	21.81%

สรุปและอภิปรายผลการวิจัย

ในสารนิพนธ์นี้เสนอแนวทางในการเพิ่มความแม่นยำในการประเมินราคาบ้านโดยใช้ปัจจัย 1) ข้อมูลบ้าน (House Info) 2) ข้อมูลเชิงพื้นที่ (Spatial Info) 3) ข้อมูลภาพบ้านด้านหน้า (Front) โดยทำการเสนอแนวทางในการสกัดปัจจัยจากข้อมูลรูปภาพบ้าน (Front) ดังขั้นตอนดังนี้ 1) กำจัดรูปภาพที่ไม่ใช่ภาพบ้าน (Front) โดยใช้ AutoEncoder 2) สร้าง Classifier สำหรับแบ่งข้อมูลออกเป็น 2 ช่วงราคา คือ ราคาต่ำกว่า 4 ล้านบาท และมากกว่าหรือเท่ากับ 4 ล้านบาท (ทั้งนี้ขึ้นกับการกระจายตัวของราคาบ้านที่นำมาสร้างแบบจำลอง) อย่างไรก็ตามการใช้ Features จากรูปภาพบ้าน (Front) มีการเพิ่มความแม่นยำในการทำนายราคาบ้านให้แบบจำลอง แต่ยังไม่ส่งผลอย่างมีนัยสำคัญ เนื่องจากรูปภาพบ้าน (Front) เพียงอย่างเดียวไม่อาจจะแยกความแตกต่างของราคาบ้านได้

ข้อเสนอแนะ

ในการศึกษานี้ทำการศึกษาเพียงจังหวัดเดียวปทุมธานี เพื่อให้ขอบเขตการศึกษากว้างขึ้น และเพิ่มโอกาสในการปรับปรุงประสิทธิภาพในการประเมินราคา จึงมีข้อเสนอแนะดังต่อไปนี้

1. สร้างแบบจำลองทำนายแยกแต่ละจังหวัด

2. เปรียบแบบจำลองแต่ละจังหวัด กับ แบบจำลองกลางที่รวมทุกจังหวัด
3. เพิ่มข้อมูลภาพถ่ายดาวเทียม และภาพการตกแต่งภายในตัวบ้าน

บรรณานุกรม

- Hinton, G. E., & Zemel, R. (1993). Autoencoders, minimum description length and Helmholtz free energy. *Advances in neural information processing systems*, 6.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- Chen, T., & Guestrin, C. (2016). Xgboost: A scalable tree boosting system. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*; August 13, 2016; San Francisco, California, USA, 785-794.
- Srirutchataboon, G., Prasertthum, S., Chuangsuwanich, E., Pratanwanich, P. N., & Ratanamahatana, C. (2021, January). Stacking ensemble learning for housing price prediction: a case study in Thailand. In *2021 13th International Conference on Knowledge and Smart Technology (KST)* (pp. 73-77). IEEE.
- Wang, P. Y., Chen, C. T., Su, J. W., Wang, T. Y., & Huang, S. H. (2021). Deep learning model for house price prediction using heterogeneous data analysis along with joint self-attention mechanism. *IEEE Access*, 9, 55244-55259.
- Chow, J. K., Su, Z., Wu, J., Tan, P. S., Mao, X., & Wang, Y. H. (2020). Anomaly detection of defects on concrete structures with the convolutional autoencoder. *Advanced Engineering Informatics*, 45, 101105.
- Rosebrock, A. (2020, March 2). Anomaly detection with Keras, TensorFlow, and Deep Learning. *PyImageSearch*. <https://pyimagesearch.com/2020/03/02/anomaly-detection-with-keras-tensorflow-and-deep-learning/>