



การประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) โดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) ในการจำแนกเขตภูมิอากาศท้องถิ่น (LCZ) ผ่านการบูรณาการข้อมูล ภูมิศึกษาพื้นที่กรุงเทพมหานครและจังหวัดนครราชสีมา

Deep Learning-Based LCZ Classification Using CNN with Integrated Multi-Source Geospatial Data: A Case Study of Bangkok and Nakhon Ratchasima, Thailand

รังสรรค์ คำคอน¹, นันทิกอร์ กิจรัตน์ภร^{2*}, เธีรววัฒน์ สุวรรณเลิศเจริญ³, พรารถนา ไหลวารินทร์⁴ และ ศิริกุล หุตะเสวี⁵

Rangsan Khamkhon¹, Nuntikorn Kitratporn^{2*}, Teerawat Suwanloetcharoen³, PradthanaRang Laiwarin⁴ and Sirikun hutasavi⁵

^{1,2,3,4,5} สำนักงานพัฒนาเทคโนโลยีอวกาศและภูมิสารสนเทศ (องค์การมหาชน) กรุงเทพมหานคร ประเทศไทย

^{1,2,3,4,5} Geo-Informatics and Space Technology Development Agency (Public Organization), Bangkok, Thailand

* Corresponding author, E-mail: nuntikorn.kit@gistda.or.th

บทคัดย่อ

การจำแนกเขตภูมิอากาศท้องถิ่น (Local Climate Zone: LCZ) ที่มีความถูกต้องแม่นยำถือเป็นพื้นฐานสำคัญสำหรับการศึกษาภูมิอากาศเมืองและการวางแผนพัฒนาเมืองอย่างยั่งยืน อย่างไรก็ตาม ข้อมูล LCZ ในปัจจุบันส่วนใหญ่มักมีความละเอียดเชิงพื้นที่ต่ำ ซึ่งยังไม่เพียงพอต่อการนำไปวิเคราะห์กับงานที่ต้องการความละเอียดสูง เช่น การบริหารจัดการความเสี่ยงจากความร้อนในระดับย่าน และการวิเคราะห์สภาพภูมิอากาศระดับจุลภาค งานวิจัยนี้จึงนำเสนอแนวทางการเรียนรู้เชิงลึก (Deep Learning) โดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network: CNN) เพื่อจำแนก LCZ จากข้อมูลหลายแหล่ง ได้แก่ ข้อมูลภาพถ่ายดาวเทียม Sentinel-2 ข้อมูลความสูงอาคาร ค่ามุมมองท้องฟ้า (SVF) และดัชนีทางชีวฟิสิกส์ (เช่น NDVI, NDWI, NDBI และ Albedo) โดยทำการศึกษาในพื้นที่กรุงเทพมหานครและจังหวัดนครราชสีมา ซึ่งมีลักษณะทางกายภาพแตกต่างกัน ส่งผลให้แบบจำลองเรียนรู้รูปแบบที่หลากหลายเชิงพื้นที่ของ LCZ เพิ่มขึ้น ทั้งยังช่วยให้แบบจำลองมีเสถียรภาพและลดปัญหาความสัมพันธ์กันเองของข้อมูลเชิงพื้นที่ ผลการศึกษาพบว่าโมเดล CNN ที่นำเสนอ มีค่า Overall Accuracy สูงสุดที่ 78.5% และค่า Kappa Coefficient เท่ากับ 0.761 เมื่อใช้การบูรณาการข้อมูลร่วมกับการกำหนดขนาดภาพนำเข้า (Patch Size) ที่ 16x16 พิกเซล นอกจากนี้ การวิเคราะห์ความสำคัญของตัวแปรพบว่า ข้อมูลความสูงอาคารและบริบทเชิงพื้นที่เป็นปัจจัยที่มีอิทธิพลสูงต่อประสิทธิภาพของแบบจำลอง ผลลัพธ์ที่ได้แสดงให้เห็นถึงศักยภาพการบูรณาการข้อมูลที่มีความละเอียดเชิงพื้นที่สูงร่วมกับเทคนิคการเรียนรู้เชิงลึกในการพัฒนาแผนที่ LCZ ที่มีความน่าเชื่อถือเพิ่มขึ้น เพื่อใช้เป็นข้อมูลสารสนเทศสำหรับบริหารจัดการเมืองและภูมิอากาศเมืองต่อไป

คำสำคัญ: เขตภูมิอากาศท้องถิ่น, การเรียนรู้เชิงลึก, โครงข่ายประสาทเทียม, ภูมิอากาศเมือง



Abstract

Accurate Local Climate Zone (LCZ) classification is fundamental for urban climate study and sustainable urban planning. However, existing LCZ data often suffer from low spatial resolution, limiting their applicability for detailed analyses such as district-level microclimate analysis and urban management. This research proposes a Deep Learning approach using Convolutional Neural Networks (CNN) to classify LCZ by integrating multi-source geospatial data, including Sentinel-2 satellite imagery, building height data, Sky View Factor (SVF), and biophysical indices (NDVI, NDWI, NDBI, and Albedo). The study was conducted in Bangkok and Nakhon Ratchasima, representing physically distinct urban environments, to enhance the model's spatial generalization and stability while reducing spatial autocorrelation issues. The results demonstrate that the proposed CNN model achieved the highest Overall Accuracy of 78.5% and a Kappa Coefficient of 0.761 when integrating multi-source data with an input patch size of 16×16 pixels. Feature importance analysis revealed that building height and spatial context significantly influence model performance. These findings highlight the potential of integrating high-resolution geospatial data with Deep Learning techniques to produce reliable LCZ maps for effective urban climate management.

Keywords: Local Climate Zone, Deep Learning, Convolutional Neural Network, Urban Climate

บทนำ

สภาพภูมิอากาศในเขตเมืองมีความผันแปรซับซ้อนทั้งมิติเชิงพื้นที่และเวลา ซึ่งส่งผลโดยตรงต่อการวางผังเมืองและการจัดการสภาพแวดล้อมความร้อน ระบบการจำแนกเขตภูมิอากาศท้องถิ่น (Local Climate Zones: LCZ) ที่พัฒนาโดย Stewart & Oke (2012) จึงถูกนำมาใช้เป็นกรอบแนวคิดมาตรฐานในการระบุลักษณะทางภูมิอากาศและกายภาพ โดยจำแนกพื้นที่เมืองออกเป็น 17 ประเภทตามปัจจัยที่มีอิทธิพลต่อสภาพภูมิอากาศ อาทิ ความหนาแน่นของอาคาร ค่าการสะท้อนรังสี และค่ามุมมองท้องฟ้า เพื่อสร้างมาตรฐานการตรวจวัดข้อมูลและส่งเสริมการแลกเปลี่ยนองค์ความรู้ด้านภูมิอากาศในระดับสากล (Huang, F et al.(2023); Stewart & Oke, 2012) โดยถูกนำไปประยุกต์ใช้อย่างกว้างขวาง ตั้งแต่การกำหนดตำแหน่งสถานีตรวจอากาศ การประเมินสถานะน่าสบายภายนอกอาคาร การสร้างมาตรฐานการรายงานสภาพอากาศ ไปจนถึงการเปรียบเทียบปรากฏการณ์เกาะความร้อนระหว่างเมือง (Zheng, Luo, Li, Gao, & Yang, 2024) นอกจากนี้ LCZ ยังทำหน้าที่เป็นเกณฑ์วัดความรุนแรงของเกาะความร้อนที่เป็นรูปธรรม ซึ่งเอื้อต่อการวิเคราะห์ปัจจัยสาเหตุของปรากฏการณ์ดังกล่าวได้อย่างแม่นยำ (Rahmani & Sharifi, 2023)

แม้ว่ากรอบแนวคิด LCZ จะได้รับการยอมรับและนำไปใช้อย่างแพร่หลาย แต่วิธีการจัดทำแผนที่ LCZ ให้มีความถูกต้องนั้นได้มีวิวัฒนาการอย่างมีนัยสำคัญ โดย Liu and Shi (2020) ; Ching et al.(2018) ได้กล่าวว่า World Urban Database and Access Portal Tools (WUDAPT) ซึ่งอาศัยอัลกอริทึมการเรียนรู้ของเครื่องแบบอิงพิกเซล (Pixel-based machine learning) เช่น Random Forest



ควบคู่กับภาพถ่ายดาวเทียมความละเอียดปานกลางอย่าง Landsat มักประสบปัญหาความสับสนทางสเปกตรัม และให้ค่าความถูกต้องที่จำกัดในสภาพแวดล้อมเมืองที่หนาแน่น แม้ในปัจจุบันจะมีแผนที่ LCZ ระดับโลกที่เผยแพร่สู่สาธารณะ เช่น Global LCZ Map ผ่าน Google Earth Engine ซึ่งครอบคลุมพื้นที่เมืองกว่า 50,000 แห่งทั่วโลก แต่ผลิตภัณฑ์ดังกล่าวยังคงมีความละเอียดเชิงพื้นที่ 100 เมตร ซึ่งไม่เพียงพอสำหรับการวิเคราะห์และพัฒนาเมืองในระดับย่าน การศึกษาครั้งนี้จึงมุ่งพัฒนาแนวทางการจำแนก LCZ ในความละเอียด 10 เมตร เพื่อรองรับการประยุกต์ใช้ที่ต้องการความแม่นยำเชิงพื้นที่สูง

การศึกษาครั้งนี้ ได้นำเอาเทคนิคการเรียนรู้เชิงลึก (Deep Learning) โดยการใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks: CNNs) ซึ่งมีความสามารถในการสกัดคุณลักษณะเชิงบริบทและเชิงพื้นที่ในรูปแบบกลุ่มพิกเซล (Patch-based features) ช่วยยกระดับการจำแนกโครงสร้างเมืองที่ซับซ้อนได้อย่างมีประสิทธิภาพ (Chen, Yoo, & Weng, 2024) นอกจากนี้เพื่อแก้ไขข้อจำกัดข้อมูลภาพถ่ายดาวเทียมที่ไม่สามารถให้รายละเอียดโครงสร้างเมืองในแนวตั้งได้ (Fung, Yang, & Niyogi, 2022) จึงมุ่งเน้นไปที่การผสานข้อมูลสเปกตรัมความละเอียดสูง (10x10 เมตร) รวมกับดัชนีทางชีวฟิสิกส์ และข้อมูลความสูงอาคารเข้าด้วยกัน ทำให้แบบจำลอง CNN ชั้นสูงสามารถจัดความคลุมเครือทางสัญญาณวิทยาของพื้นที่เมืองได้อย่างมีประสิทธิภาพ นำไปสู่การสร้างแผนที่ LCZ ที่มีความแม่นยำสูง ซึ่งเป็นรากฐานสำคัญสำหรับการวิเคราะห์สภาพภูมิอากาศระดับจุลภาคภายในเขตเมือง (He, Dong, Guan, Feng, Jin, & Zhang, 2023)

วัตถุประสงค์ของการวิจัย

1. เพื่อจำแนกเขตภูมิอากาศท้องถิ่น (LCZ) ในระดับความละเอียด 10 เมตร ด้วยโครงข่าย CNN โดยบูรณาการข้อมูลภาพถ่ายดาวเทียมและข้อมูลโครงสร้างกายภาพเมือง
2. เพื่อศึกษาผลกระทบของชุดข้อมูลนำเข้าและขนาดพื้นที่บริบทที่มีต่อความแม่นยำในการจำแนก LCZ และทดสอบความสามารถในการนำแบบจำลองไปใช้กับพื้นที่เมืองอื่น

แนวคิด ทฤษฎี กรอบแนวคิด

การทบทวนวรรณกรรมส่วนนี้มุ่งเน้นวิวัฒนาการของการจำแนก LCZ โดยวิเคราะห์ข้อจำกัดของวิธีดั้งเดิม และนำเสนอความก้าวหน้าในการประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) เพื่อยกระดับความแม่นยำของแผนที่ฐานในเขตเมือง

ทฤษฎีเขตภูมิอากาศท้องถิ่น (Local Climate Zones: LCZ) พัฒนาโดย Stewart & Oke (2012) เป็นกรอบแนวคิดที่จำแนกพื้นที่ตามลักษณะทางกายภาพที่ส่งผลต่ออุณหภูมิ ออกเป็น 17 ประเภท (กลุ่มอาคาร 10 ประเภท และกลุ่มธรรมชาติ 7 ประเภท) เพื่อใช้เป็นมาตรฐานในการศึกษาปรากฏการณ์สภาพอากาศในเมือง (Huang et al., 2023; Rahmani & Sharifi, 2023) ดังตารางที่ 3

ทฤษฎีการเรียนรู้เชิงลึก (Deep Learning) ด้วยโครงข่าย CNN เปลี่ยนกระบวนทัศน์จากการวิเคราะห์ภาพถ่ายดาวเทียมแบบ พิจารณาทีละพิกเซล มาเป็นแบบ กลุ่มพิกเซล (Liu & Shi, 2020; Chen et al., 2024; Fung et al., 2022) ทำให้โมเดลสามารถเรียนรู้ บริบทเชิงพื้นที่และสภาพแวดล้อม ซึ่งจำเป็นมากสำหรับการแยกแยะโครงสร้างเมืองที่ซับซ้อน (Chen, Liu, & Zheng, 2023) โดยงานของ Liu & Shi (2020) ถือเป็นหนึ่งในงานบุกเบิกที่แสดงให้เห็นว่า CNN สามารถจำแนก LCZ จากภาพถ่ายดาวเทียม ได้อย่าง



มีประสิทธิภาพ ซึ่งถือเป็นพื้นฐานสำคัญที่ต่อยอดสู่งานวิจัยในเวลาต่อมา รวมถึงการผสมผสาน CNN กับข้อมูลพหุแหล่งเพื่อเพิ่มความแม่นยำในการจำแนก (Chen et al., 2024; Liu & Shi, 2020)

แนวคิดการบูรณาการข้อมูลพหุแหล่ง แนวคิดนี้ตั้งอยู่บนข้อจำกัดที่ว่า ภาพถ่ายดาวเทียมทั่วไปมักเกิดความสับสนทางสเปกตรัม และไม่สามารถบอกความสูงของตึกได้ (Fung et al., 2022; He et al., 2023) จึงเกิดเป็นแนวทางการนำข้อมูลหลายแหล่งมาซ้อนทับกัน ได้แก่ 1) ข้อมูลสเปกตรัมจากภาพถ่ายดาวเทียม 2) ข้อมูลความสูงอาคาร และ 3) ดัชนีทางชีวฟิสิกส์พื้นผิว (เช่น NDVI NDWI และ NDBI) เพื่อให้โมเดลมีข้อมูลประกอบการตัดสินใจที่สมบูรณ์ที่สุด (Wu, Ma, Sui, & Pun, 2024)

วิธีดำเนินการวิจัย

การศึกษานี้มีขั้นตอนการดำเนินงานหลัก 5 ส่วน ได้แก่ การรวบรวมข้อมูล, การเตรียมข้อมูล, การพัฒนาแบบจำลอง, การออกแบบการทดลอง, และการตรวจสอบความถูกต้อง โดยมีรายละเอียดดังนี้

1. การรวบรวมข้อมูล

การวิจัยนี้อาศัยการบูรณาการข้อมูลภูมิสารสนเทศเชิงพื้นที่จากหลายแหล่ง ครอบคลุมพื้นที่กรุงเทพมหานครและจังหวัดนครราชสีมา เพื่อให้แบบจำลองสามารถเรียนรู้ความหลากหลายของบริบทเมืองและภูมิภาคได้ โดยเลือกช่วงวันที่ 1 มีนาคม ถึง 31 พฤษภาคม พ.ศ. 2566 เพื่อให้สอดคล้องทางเวลากับชุดข้อมูล Open Buildings 2.5D และยังเป็นช่วงซึ่งมีเมฆปกคลุมน้อยที่สุดในรอบปี ส่งผลให้ภาพถ่ายดาวเทียม Sentinel-2 มีคุณภาพสูงและครอบคลุมพื้นที่ได้อย่างสมบูรณ์ ทั้งนี้ ข้อมูลนำเข้าประกอบด้วย 3 กลุ่มหลัก ซึ่งทุกชุดข้อมูลถูกจัดทำให้มีความละเอียดเชิงพื้นที่ 10 เมตร ดังตารางที่ 1

ตารางที่ 1 รายละเอียดข้อมูลภูมิสารสนเทศที่ใช้ในการจำแนกเขตภูมิอากาศท้องถิ่น (LCZ)

ประเภทข้อมูล	ตัวแปร / รายการ	ความละเอียด (m ²)	แหล่งข้อมูล / วิธีการได้มา
1. ข้อมูลภาพถ่ายดาวเทียม (Satellite Imagery)	แบนด์การสะท้อนคลื่นแม่เหล็กไฟฟ้า Blue, Green, Red, NIR	10	ดาวเทียม Sentinel-2 (ESA) ดาวน์โหลดผ่าน Google Earth Engine
	แบนด์การสะท้อนคลื่นอินฟราเรดคลื่นสั้น (SWIR1, SWIR2)	20 → 10*	ดาวเทียม Sentinel-2 (ESA) ผ่าน Google Earth Engine
2. ข้อมูลเชิงโครงสร้างกายภาพ (Physical Structure)	ความสูงอาคาร (Building Height)	0.5	Open Buildings 2.5D Temporal Dataset (Google) ดาวน์โหลดผ่าน Google Earth Engine
	ค่ามุมมองท้องฟ้า (Sky View Factor: SVF)	10	คำนวณด้วย Relief Visualization Toolbox (RVT) จาก FABDEM (DEM) + ความสูงอาคาร + ความสูงเรือนยอดไม้ (CHM)
	อัตราส่วนความสูงต่อความกว้างถนน (Aspect Ratio: H/W)	10	คำนวณจากความสูงอาคาร (Building Height) และความกว้างถนน (OpenStreetMap)
3. ดัชนีชีวฟิสิกส์และสิ่งแวดล้อม (Biophysical & Environmental)	ดัชนีพืชพรรณ (NDVI) = $(\text{NIR} - \text{Red}) / (\text{NIR} + \text{Red})$	10	ประมวลผลจากแบนด์ NIR (B8) และ Red (B4) ของดาวเทียม Sentinel-2
	ดัชนีน้ำ (NDWI) = $(\text{Green} - \text{NIR}) / (\text{Green} + \text{NIR})$	10	ประมวลผลจากแบนด์ Green (B3) และ NIR (B4) ของดาวเทียม Sentinel-2



ประเภทข้อมูล	ตัวแปร / รายการ	ความละเอียด (m ²)	แหล่งข้อมูล / วิธีการได้มา
Environmental Indices)	(Green + NIR)		(B8) ของดาวเทียม Sentinel-2
	ดัชนีพื้นที่สิ่งปลูกสร้าง (NDBI) = $(SWIR - NIR) / (SWIR + NIR)$	10	ประมวลผลจากแบนด์ SWIR1 (B11) และ NIR (B8) ของดาวเทียม Sentinel-2
	ค่าอัตราส่วนรังสีสะท้อน (Mean Albedo)	10	ประมวลผลตามวิธีการของ He, Zhang, Li, & Liang, (2022) จากแบนด์ของ Sentinel-2
	สัดส่วนพื้นผิวสิ่งก่อสร้าง Built-up Surface Fraction (GHSL)	10	เป็นผลิตภัณฑ์ข้อมูลเชิงพื้นที่จากโครงการของ คณะกรรมาธิการยุโรป (European Commission, Joint Research Centre)

*Canopy Height Model (CHM) *Forest And Buildings removed Copernicus (FABDEM)

2. การเตรียมข้อมูล

เพื่อให้แบบจำลองสามารถประมวลผลข้อมูลที่มีความหลากหลายได้อย่างมีประสิทธิภาพ จึงดำเนินการเตรียมข้อมูลดังนี้:

การกำหนดพื้นที่ตัวอย่าง (Training Areas) สำหรับการจำแนก LCZ มีขั้นตอนและหลักเกณฑ์สากลตามมาตรฐานของ WUDAPT (Ching et al., 2018) โดยพิจารณาการเลือกพื้นที่ตัวอย่างจากความสม่ำเสมอ โดยจะเลือกพื้นที่ที่มีลักษณะสิ่งปลูกสร้างหรือสิ่งปกคลุมดินประเภทเดียวกันอย่างชัดเจน ขนาดและรูปร่าง ควรมีพื้นที่กว้างกว่า 200 เมตร ในจุดที่แคบที่สุด และมีขนาดรวมมากกว่า 1 ตารางกิโลเมตร เพื่อให้สอดคล้องกับความละเอียดของภาพถ่ายดาวเทียม (เช่น Landsat หรือ Sentinel) และระยะห่าง ควรเว้นระยะห่างประมาณ 100 เมตร จากขอบเขตของ LCZ ประเภทอื่น เพื่อป้องกันค่าพิกเซลที่ปนกัน ในการวิจัยนี้ใช้ภาพถ่ายดาวเทียมจาก Google Maps และ Google Street View ในช่วงปี พ.ศ. 2566 หรือใกล้เคียง เป็นข้อมูลอ้างอิงภาคพื้นดิน (Ground Reference) ประกอบการตัดสินใจกำหนดพื้นที่ตัวอย่าง

การปรับบรรทัดฐานข้อมูล (Data Normalization) ปรับช่วงค่าของข้อมูลทุกตัวแปรให้อยู่ในสัดส่วนมาตรฐานเดียวกัน (ระหว่าง 0 ถึง 1) เพื่อลดความแปรปรวนและเพิ่มประสิทธิภาพในการบรรจบ (Convergence) ของแบบจำลอง

การสกัดข้อมูลเชิงพื้นที่ (Patch Extraction) สกัดข้อมูลภาพเป็นตารางกริดย่อย สองขนาด ได้แก่ 10×10 และ 16×16 พิกเซล ซึ่งเป็นขนาดที่ครอบคลุมบริบทเชิงพื้นที่ที่เหมาะสมแก่การพิจารณาข้อมูลที่มีความละเอียดเชิงพื้นที่สูง พร้อมทั้งสุ่มตัวอย่างให้มีความสมดุล จำนวน 1,500 ตัวอย่างต่อประเภท เพื่อช่วยป้องกันปัญหาความไม่สมดุลของข้อมูล (Class Imbalance) ที่อาจทำให้แบบจำลองเอนเอียงไปเรียนรู้เฉพาะประเภทที่มีพื้นที่ครอบคลุมมากกว่า ทั้งนี้จำนวนดังกล่าวสอดคล้องกับแนวทางของ WUDAPT ที่แนะนำให้มตัวอย่างฝึกสอนหลักพื้นที่ต่อประเภทสำหรับการจำแนก LCZ ด้วยโครงข่ายประสาทเทียม (Ching et al., 2018)

การแบ่งชุดข้อมูล (Data Splitting) แบ่งข้อมูลออกเป็นชุดข้อมูลสอน (Training Set) ร้อยละ 70 และชุดข้อมูลทดสอบ (Testing Set) ร้อยละ 30 โดยใช้เทคนิคการแบ่งตามขอบเขตพื้นที่ย่อย (Polygon-based Split) เพื่อป้องกันปัญหาการรั่วไหลของข้อมูล ระหว่างกระบวนการฝึกสอนและทดสอบ และความไม่สมดุลของประเภท โดยจำกัดจำนวนตัวอย่างสูงสุดที่ 1,500 แพตช์ ต่อประเภทต่อพื้นที่ศึกษา รวม 2 พื้นที่ศึกษาจะอยู่ที่ประมาณ 3,000 แพตช์ต่อประเภท



3. เทคนิคการเรียนรู้เชิงลึก (Deep Learning)

งานวิจัยนี้ใช้โครงข่าย CNN ที่ประกอบด้วย Convolutional Blocks 3 ชั้น (ขนาดฟิลเตอร์ 32, 64, 128) ร่วมกับ Batch Normalization และ Max Pooling สำหรับสกัดคุณลักษณะเชิงพื้นที่ ตามด้วย Global Average Pooling, Dense Layer (256 โหนด, Dropout 0.5) และ Softmax สำหรับจำแนก LCZ 16 ประเภท โดยใช้ Adam Optimizer ในการปรับค่าน้ำหนักของโมเดลระหว่างการฝึกสอน และ Categorical Crossentropy เป็นฟังก์ชันวัดความผิดพลาดในการจำแนกหลายประเภท

4. การออกแบบการทดลอง 6 รูปแบบ

เพื่อตอบวัตถุประสงค์การวิจัยในการวิเคราะห์หาปัจจัยที่มีอิทธิพลต่อความแม่นยำของการจำแนก LCZ การศึกษานี้จึงได้ออกแบบเงื่อนไขการทดลอง (Scenarios) ออกเป็น 6 รูปแบบ ดังนี้:

รูปแบบที่ 1 (Baseline / Full Integration) ใช้ข้อมูลแบบบูรณาการครบถ้วน ประกอบด้วย ภาพถ่ายดาวเทียม, ข้อมูลความสูงอาคาร และดัชนีทางชีวฟิสิกส์และสิ่งแวดล้อม (Patch Size 10x10 พิกเซล) เพื่อใช้เป็นเกณฑ์มาตรฐานของพื้นที่เมืองที่มีความซับซ้อน

รูปแบบที่ 2 (No Height) ตัดข้อมูลที่เกี่ยวข้องกับโครงสร้าง 3 มิติ (ข้อมูลเชิงโครงสร้างกายภาพ (ความสูงอาคาร และค่ามุมมองท้องฟ้า) ออกทั้งหมด เหลือเพียงข้อมูลการสะท้อนเชิงคลื่นจากภาพถ่ายดาวเทียม Sentinel-2 และดัชนีสิ่งแวดล้อม เพื่อทดสอบถึงความจำเป็นของข้อมูลโครงสร้างเมือง

รูปแบบที่ 3 (Spectral Only) ใช้ข้อมูลเชิงคลื่นจากภาพถ่ายดาวเทียม Sentinel-2 เพียงอย่างเดียว เพื่อประเมินขีดความสามารถพื้นฐานของข้อมูลดาวเทียมแบบดั้งเดิม

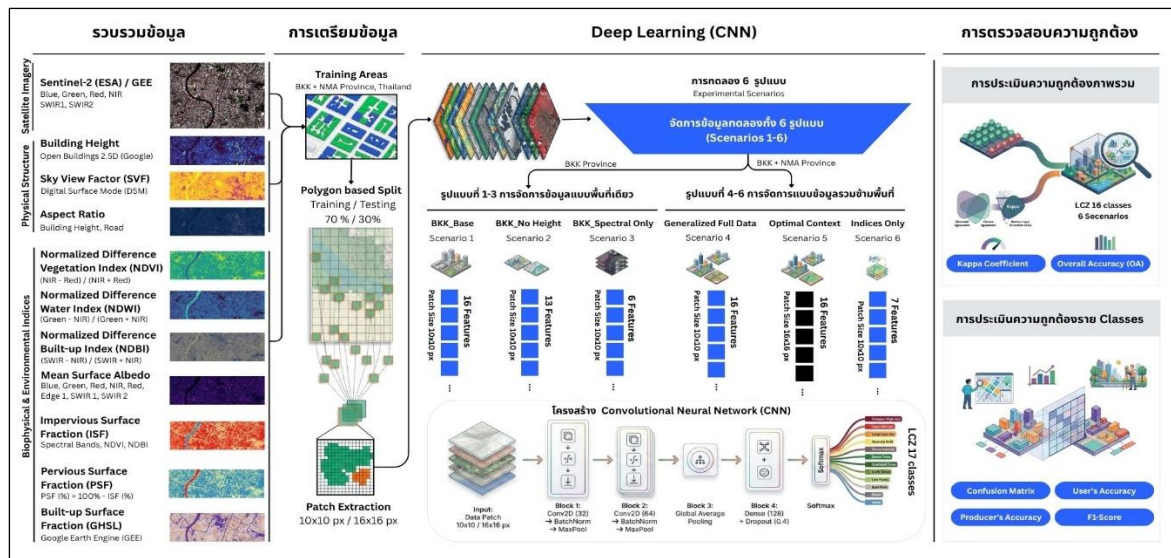
รูปแบบที่ 4 (Generalized Full Data) บูรณาการข้อมูลครบถ้วนจากทั้งสองพื้นที่ศึกษา (Patch Size 10x10 พิกเซล) เพื่อทดสอบเสถียรภาพแบบจำลองเมื่อต้องเรียนรู้ข้ามพื้นที่ (Cross-city Learning)

รูปแบบที่ 5 (Optimal Context) ใช้ข้อมูลบูรณาการครบถ้วนจากทั้งสองพื้นที่ศึกษาเช่นเดียวกับรูปแบบที่ 4 แต่ทำการขยายขนาดภาพนำเข้า (Patch Size) จาก 10x10 เป็น 16x16 พิกเซล

รูปแบบที่ 6 (Indices Only) ใช้ข้อมูลจากทั้งสองพื้นที่ศึกษา โดยป้อนเฉพาะตัวแปรดัชนีทางชีวฟิสิกส์และชั้นข้อมูล GHSL (ตัดภาพดาวเทียมดิบและความสูงอาคารออก) เพื่อทดสอบว่าดัชนีสังเคราะห์เพียงอย่างเดียวเพียงพอต่อการจำแนก LCZ หรือไม่

5. การตรวจสอบความถูกต้อง

การประเมินประสิทธิภาพของแบบจำลอง จะดำเนินการโดยนำผลลัพธ์ที่ได้จากการทำนายชุดข้อมูลทดสอบ มาเปรียบเทียบกับข้อมูลอ้างอิง ผ่าน Confusion Matrix โดยคำนวณค่าสถิติหลัก ได้แก่ ความถูกต้องโดยรวม (Overall Accuracy: OA) เพื่อประเมินสัดส่วนการจำแนกที่ถูกต้องทั้งหมดของแบบจำลอง ค่า Kappa Coefficient เพื่อประเมินระดับความสอดคล้องของการจำแนกโดยขจัดความบังเอิญทางสถิติออกไป และความถูกต้องรายประเภท ได้แก่ ความถูกต้องของผู้ผลิต (Producer's Accuracy: PA) ความถูกต้องของผู้ใช้ (User's Accuracy: UA) และค่า F1-Score เพื่อวิเคราะห์ความแม่นยำในการจำแนก LCZ เชิงลึกในแต่ละประเภท ซึ่งเป็นตัวชี้วัดมาตรฐานที่นิยมใช้ในงานจำแนกข้อมูลภาพระยะไกล (Congalton & Green, 2019) นอกจากนี้ยังใช้เทคนิค Permutation Feature Importance เพื่อวิเคราะห์ว่าข้อมูลนำเข้าสู่ชุดใดมีอิทธิพลสูงสุดต่อความแม่นยำของแบบจำลอง



ภาพที่ 1 แผนผังขั้นตอนการดำเนินงานของการจำแนก LCZ ด้วย CNN

ผลการวิจัย

การศึกษานี้ได้ประเมินประสิทธิภาพของแบบจำลอง CNN ในการจำแนกเขตภูมิอากาศท้องถิ่น (LCZ) ภายใต้เงื่อนไขการทดลองทั้งสิ้น 6 รูปแบบ โดยมีรายละเอียดผลทดลอง ดังแสดงในตารางที่ 2 เพื่อวิเคราะห์อิทธิพลของประเภทข้อมูลนำเข้า ความหลากหลายของพื้นที่ศึกษา และขนาดภาพนำเข้า ทั้งนี้ในระหว่างการกำหนดพื้นที่ตัวอย่าง พบว่า พื้นที่ศึกษาในประเทศไทยไม่ปรากฏลักษณะของ LCZ 4 ประเภทตึกสูงแบบเปิด (Open High-rise) อย่างชัดเจนเพียงพอที่จะกำหนดเป็นพื้นที่ตัวอย่างได้ จึงดำเนินการจำแนกเพียง 16 ประเภท

ตารางที่ 2 เปรียบเทียบประสิทธิภาพของแบบจำลองในการจำแนก LCZ ทั้ง 6 รูปแบบการทดลอง

รูปแบบการทดลอง (Scenario)	ชุดข้อมูลนำเข้า (Input Features)	พื้นที่ศึกษา	ขนาดภาพ (Patch Size)	ความถูกต้องโดยรวม (OA)	ค่าสัมประสิทธิ์ (Kappa)
1. BKK Base (ข้อมูลครบถ้วน)	ภาพถ่ายเทียม + ข้อมูลเชิงโครงสร้าง + ดัชนี	กรุงเทพมหานคร	10x10	70.84%	0.6882
2. No Height (ตัดความสูง)	ภาพถ่ายเทียม + ดัชนี (ไม่มีข้อมูลเชิงโครงสร้าง)	กรุงเทพมหานคร	10x10	56.64%	0.5363
3. Spectral Only (ภาพถ่ายเทียม)	ภาพถ่ายเทียม Sentinel-2 เท่านั้น	กรุงเทพมหานคร	10x10	64.41%	0.6193
4. Generalized (รวมพื้นที่)	ภาพถ่ายเทียม + ข้อมูลเชิงโครงสร้าง + ดัชนี	กรุงเทพมหานคร และ นครราชสีมา	10x10	72.15%	0.7024



รูปแบบการทดลอง (Scenario)	ชุดข้อมูลนำเข้า (Input Features)	พื้นที่ศึกษา	ขนาดภาพ (Patch Size)	ความถูกต้องโดยรวม (OA)	ค่าสัมประสิทธิ์ (Kappa)
5. Optimal Context (ขยายภาพ)	ภาพถ่ายเทียม + ข้อมูลเชิงโครงสร้าง + ดัชนี	กรุงเทพมหานคร และ นครราชสีมา	16x16	78.5%	0.761
รูปแบบการทดลอง (Scenario)	ชุดข้อมูลนำเข้า (Input Features)	พื้นที่ศึกษา	ขนาดภาพ (Patch Size)	ความถูกต้องโดยรวม (OA)	ค่าสัมประสิทธิ์ (Kappa)
6. Indices Only (ใช้เฉพาะดัชนี)	เฉพาะดัชนีชีวฟิสิกส์ และสิ่งแวดล้อม	กรุงเทพมหานคร และ นครราชสีมา	10x10	66.00%	0.6371

1. อิทธิพลของประเภทข้อมูลนำเข้า

จากการเปรียบเทียบผลการทดลองในพื้นที่กรุงเทพมหานคร พบว่ารูปแบบที่ 1 ซึ่งบูรณาการข้อมูลครบถ้วนทุกมิติ มีความถูกต้องโดยรวม OA ที่ร้อยละ 70.84 ในขณะที่รูปแบบที่ 2 ซึ่งตัดข้อมูลความสูงอาคารและค่ามุมมองท้องฟ้าออก มีค่า OA ลดลงอย่างมีนัยสำคัญเหลือเพียงร้อยละ 56.64 สะท้อนให้เห็นว่าข้อมูลเชิงโครงสร้าง 3 มิติเป็นปัจจัยที่ส่งผลกระทบต่อความแม่นยำในการแยกแยะประเภทสิ่งปลูกสร้างในเขตเมือง นอกจากนี้ รูปแบบที่ 3 ซึ่งใช้เพียงข้อมูลภาพถ่ายเทียม Sentinel-2 ให้ค่า OA ร้อยละ 64.41 ซึ่งสูงกว่ารูปแบบที่ 2 แม้จะใช้ข้อมูลน้อยกว่า แสดงให้เห็นว่าข้อมูลสเปกตรัลมีความสามารถในการจำแนกประเภทได้ดีกว่าการใช้ดัชนีสังเคราะห์ที่ขาดข้อมูลโครงสร้าง สอดคล้องกับรูปแบบที่ 6 ซึ่งใช้เฉพาะดัชนีชีวฟิสิกส์และสิ่งแวดล้อม จากทั้งสองพื้นที่ศึกษา ให้ค่า OA ร้อยละ 66.00 แม้จะมีความได้เปรียบด้านขนาดข้อมูลที่มากกว่ารูปแบบที่ 3 แต่กลับให้ผลที่ใกล้เคียงกัน สะท้อนให้เห็นว่าดัชนีชีวฟิสิกส์และสิ่งแวดล้อม เพียงอย่างเดียวมีขีดจำกัดในการจำแนก LCZ หากขาดข้อมูลสเปกตรัลและโครงสร้างเมือง

2. อิทธิพลของการบูรณาการพื้นที่และขนาดภาพนำเข้า

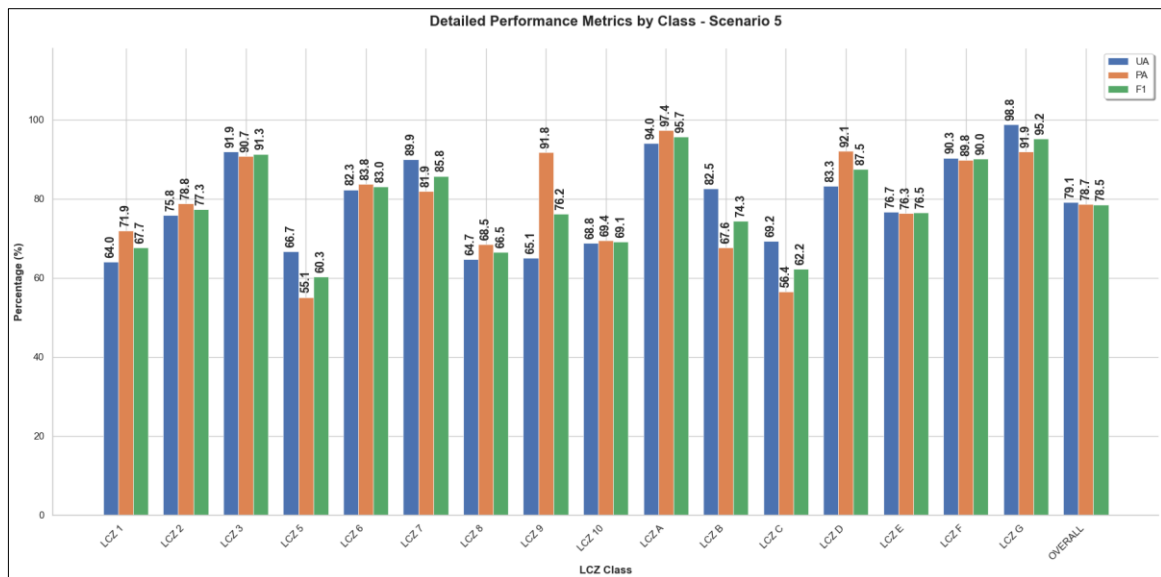
เมื่อนำข้อมูลจากพื้นที่กรุงเทพมหานครและจังหวัดนครราชสีมามารวมกันเพื่อฝึกสอนแบบจำลอง รูปแบบที่ 4 พบว่าค่าความถูกต้องโดยรวมเพิ่มขึ้นเป็นร้อยละ 72.15 แสดงให้เห็นว่าการเพิ่มความหลากหลายของข้อมูลช่วยลดปัญหา Overfitting และยกระดับความเป็นสากลของแบบจำลองได้อย่างมีประสิทธิภาพ ยิ่งไปกว่านั้น เมื่อทำการขยายขนาดภาพนำเข้าจาก 10x10 เป็น 16x16 พิกเซลใน รูปแบบที่ 5 ส่งผลให้แบบจำลองมีประสิทธิภาพสูงสุดในการศึกษานี้ โดยมีค่า OA สูงถึงร้อยละ 78.5 และค่าสัมประสิทธิ์แคปปาที่ 0.761 ซึ่งบ่งชี้ว่าการเพิ่มบริบทเชิงพื้นที่ช่วยให้โครงข่าย CNN สามารถสกัดคุณลักษณะแวดล้อมเพื่อจำแนกประเภท LCZ ที่มีความซับซ้อนได้อย่างถูกต้องมากขึ้น

3. การวิเคราะห์ความถูกต้องรายประเภท


จากภาพที่ 2 พบว่าแบบจำลองสามารถจำแนก LCZ กลุ่มธรรมชาติได้แม่นยำสูงสุด โดยแหล่งน้ำ (LCZ G) มีค่า F1-Score สูงที่สุดที่ร้อยละ 96.2 รองลงมา คือ ต้นไม้หนาแน่น (LCZ A) ที่ร้อยละ 95.7 เนื่องจากทั้งสองประเภทมีลักษณะการสะท้อนคลื่นแสงที่เด่นชัดและแตกต่างจากประเภทอื่นอย่างชัดเจน นอกจากนี้ประเภทอาคารเตี้ยแออัด (LCZ 3, F1 = 91.3%) ดินเปล่า (LCZ F, F1 = 90.0%) โครงสร้างเบาเตี้ย (LCZ 7, F1 = 88.8%) และพืชเตี้ย (LCZ D, F1 = 87.5%) ก็มีค่าความแม่นยำสูงเช่นกัน สำหรับ

ประเภทที่มีความท้าทาย พบว่า อาคารกลางโปร่ง (LCZ 5) มีค่า F1-Score ต่ำที่สุดที่ร้อยละ 60.3 โดยมีค่า PA เพียงร้อยละ 55 บ่งชี้ว่าแบบจำลองตรวจจับประเภทนี้ได้น้อยกว่าความเป็นจริงเนื่องจากมีโครงสร้างคล้ายคลึงกับ LCZ 2 และ LCZ 6 ในทางตรงกันข้าม ประเภทสิ่งปลูกสร้างกระจัดกระจาย (LCZ 9) มีค่า PA สูงถึงร้อยละ 91.8 แต่ค่า UA เพียงร้อยละ 65.1 บ่งชี้ว่าแบบจำลองทำนายประเภทนี้เกินจริง กล่าวคือจำแนกพื้นที่ของประเภทอื่นเข้ามาในประเภทนี้มากเกินไป ประเภทพุ่มไม้ (LCZ C, F1 = 62.7%) ก็มีความท้าทายสูงเนื่องจากสเปกตรัมซ้อนทับกับ LCZ A และ LCZ D

เมื่อพิจารณา Confusion Matrix จากภาพที่ 3 พบการสับสนระหว่างประเภทใน 3 กลุ่มหลัก ได้แก่ (1) LCZ 1 ถูกจำแนกผิดเป็น LCZ 2 ร้อยละ 24 เนื่องจากทั้งสองประเภทมีสเปกตรัมคล้ายกัน แตกต่างกันเพียงระดับความสูงอาคาร (2) LCZ 8 และ LCZ 10 สับสนกันร้อยละ 14-17 เพราะมีหลังคาขนาดใหญ่และพื้นผิวแข็งคล้ายกัน และ (3) LCZ B ถูกจำแนกผิดเป็น LCZ C ถึงร้อยละ 28 สะท้อนว่า NDVI เพียงอย่างเดียวไม่เพียงพอในการแยกพืชพรรณต่างชนิด ผลดังกล่าวยืนยันว่าข้อมูลโครงสร้างกายภาพ ได้แก่ ความสูงอาคารและ SVF มีความจำเป็นอย่างยิ่งในการจำแนกประเภทสิ่งปลูกสร้างที่มีความซับซ้อนสูง




ภาพที่ 2 ประสิทธิภาพการจำแนกรายประเภท จากแบบจำลอง รูปแบบที่ 5



ภาพที่ 3 Confusion Matrix จากแบบจำลอง รูปแบบที่ 5

4. วิเคราะห์ความสำคัญแต่ละตัวแปร

จากการวิเคราะห์ Permutation Feature Importance ของแบบจำลอง รูปแบบที่ 5 ดังภาพที่ 4 พบว่าข้อมูล Red Edge มีอิทธิพลสูงสุด โดย RedEdge1 ($B5 = 0.380$) เป็นตัวแปรที่ส่งผลมากที่สุด ในขณะที่ Aspect Ratio มีอิทธิพลต่ำที่สุด (0.045) แม้จะเป็นตัวแปรสำคัญตามทฤษฎี LCZ ซึ่งอาจเกิดจาก SVF ที่สัมพันธ์กันทางฟิสิกส์ได้ทำหน้าที่แทนตัวแปรนี้ไปแล้ว



ภาพที่ 4 ผลการวิเคราะห์ Permutation Feature Importance จากแบบจำลอง รูปแบบที่ 5

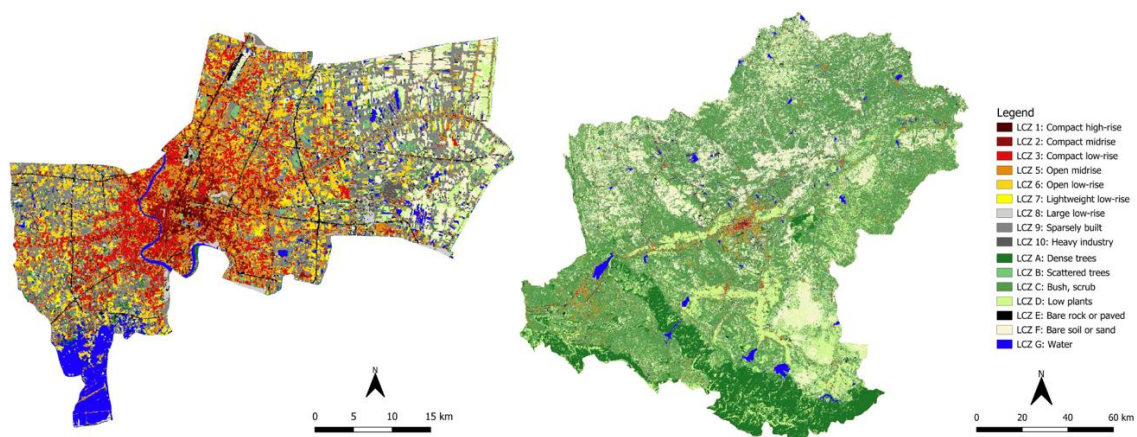
5. การวิเคราะห์การกระจายเชิงพื้นที่ของ LCZ

จากผลการจำแนกเขตภูมิอากาศท้องถิ่น (LCZ) ด้วยแบบจำลอง CNN ที่ดีที่สุด (รูปแบบที่ 5) พบว่า พื้นที่กรุงเทพมหานครและจังหวัดนครราชสีมา มีลักษณะการกระจายเชิงพื้นที่ของ LCZ ที่แตกต่างกันอย่างชัดเจน สะท้อนถึงความแตกต่างของโครงสร้างเมืองและบริบทการใช้ประโยชน์ที่ดิน ดังแสดงในตารางที่ 3 และภาพที่ 5

ตารางที่ 3 การกระจายเนื้อที่ LCZ ในพื้นที่กรุงเทพมหานครและจังหวัดนครราชสีมา

รหัส LCZ	ชื่อประเภท	กรุงเทพมหานคร (ตร.กม.)	กรุงเทพมหานคร (%)	นครราชสีมา (ตร.กม.)	นครราชสีมา (%)
1	อาคารสูงแออัด	9.65	0.61	-	-
2	อาคารกลางแออัด	77.53	4.92	16.90	0.08
3	อาคารเตี้ยแออัด	151.78	9.63	72.59	0.35
4	ตึกสูงแบบเปิด	-	-	-	-
5	อาคารกลางโปร่ง	193.17	12.26	491.30	2.36
6	อาคารเตี้ยโปร่ง	175.25	11.12	25.68	0.12
7	โครงสร้างเบาเตี้ย	38.33	2.43	51.40	0.25

รหัส LCZ	ชื่อประเภท	กรุงเทพมหานคร (ตร.กม.)	กรุงเทพมหานคร (%)	นครราชสีมา (ตร.กม.)	นครราชสีมา (%)
8	อาคารขนาดใหญ่เตี้ย	60.77	3.86	26.40	0.13
9	สิ่งปลูกสร้างกระจัดกระจาย	360.18	22.86	410.25	1.97
10	อุตสาหกรรมหนัก	89.48	5.68	233.43	1.12
A	ต้นไม้หนาแน่น	19.11	1.21	2,031.77	9.77
B	ต้นไม้กระจัดกระจาย	17.10	1.09	771.34	3.71
C	พุ่มไม้/ไม้พุ่ม	35.63	2.26	9,090.65	43.73
D	พืชเตี้ย	87.18	5.53	3,274.55	15.75
E	หิน/ลาดยาง	60.10	3.81	257.01	1.24
F	ดินเปล่า	104.66	6.64	3,777.33	18.17
G	แหล่งน้ำ	95.64	6.07	256.90	1.24
รวม		1,575.56	100.00	20,787.50	100.00



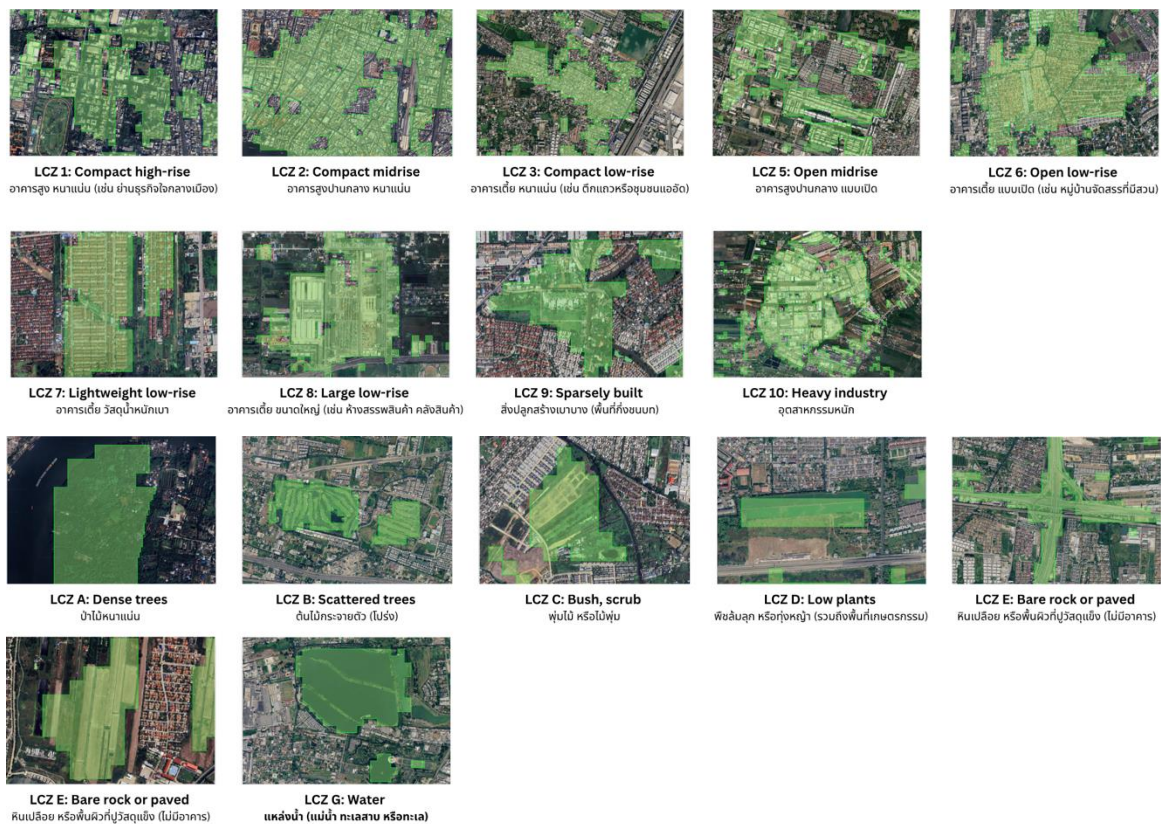
ภาพที่ 5 แผนที่ LCZ (Local Climate Zone Map) (ด้านซ้าย) กรุงเทพมหานคร และ (ด้านขวา) จังหวัดนครราชสีมา จากแบบจำลอง รูปแบบที่ 5

พื้นที่กรุงเทพมหานคร (~1,576 ตร.กม.) มีประเภทอาคารและสิ่งปลูกสร้าง (LCZ 1-10) รวมร้อยละ 73.4 โดย LCZ 9 (สิ่งปลูกสร้างกระจัดกระจาย) ครอบคลุมพื้นที่มากที่สุดที่ร้อยละ 22.86 รองลงมา คือ LCZ 5 (อาคารกลางโปร่ง) ร้อยละ 12.26 และ LCZ 6 (อาคารเตี้ยโปร่ง) ร้อยละ 11.12 สะท้อนลักษณะของเมืองขนาดใหญ่ที่มีการขยายตัวของพื้นที่เขตเมืองอย่างต่อเนื่องและหลากหลายรูปแบบ ในขณะที่จังหวัดนครราชสีมา (~20,788 ตร.กม.) มีลักษณะแตกต่างกันอย่างสิ้นเชิง โดยพื้นที่ส่วนใหญ่เป็นสิ่งปกคลุมดินตามธรรมชาติ (LCZ A-G) รวมกันสูงถึงร้อยละ 93.6 โดยเฉพาะ LCZ C (พุ่มไม้/ไม้พุ่ม) ร้อยละ 43.73 และ LCZ F (ดินเปล่า) ร้อยละ 18.17



สรุปและอภิปรายผล

งานวิจัยนี้พัฒนาแบบจำลอง CNN สำหรับจำแนกเขตภูมิอากาศท้องถิ่น (LCZ) โดยบูรณาการข้อมูลจากหลายแหล่งในความละเอียดเชิงพื้นที่ 10 เมตร จากการทดลองทั้ง 6 รูปแบบ แบบจำลองที่ดีที่สุด คือ รูปแบบที่ 5 ซึ่งได้ค่า OA ร้อยละ 78.5 และ Kappa 0.761 ผลดังกล่าวอยู่ในระดับใกล้เคียงกับงานวิจัย CNN สำหรับจำแนก LCZ ในระดับนานาชาติที่รายงานค่า OA ในช่วงร้อยละ 67–88 อย่างไรก็ตาม การเปรียบเทียบดังกล่าวจำเป็นต้องพิจารณาบริบทของแต่ละงานวิจัยประกอบ Liu and Shi (2020) บรรลุค่า OA สูงถึงร้อยละ 88.61 บนข้อมูล Sentinel-2 จาก 15 เมืองในประเทศจีน โดยพิสูจน์ว่าการใช้ขนาด Patch 32×32 พิกเซลให้ความแม่นยำสูงกว่าขนาดที่เล็กกว่าถึงร้อยละ 7.5 ซึ่งสอดคล้องกับผลการศึกษานี้ที่พบว่า การขยาย Patch จาก 10×10 เป็น 16×16 พิกเซลช่วยเพิ่ม OA ได้อย่างชัดเจนและบ่งชี้ว่าการทดลองขยาย Patch ให้ใหญ่ขึ้นอีกมีศักยภาพที่จะปรับปรุงความแม่นยำได้เพิ่มเติม ในทางตรงกันข้าม He et al. (2023) ซึ่งผสมผสานข้อมูล SAR (Sentinel-1) และ Multispectral (Sentinel-2) บนชุดข้อมูลมาตรฐาน So2Sat LCZ42 ที่ครอบคลุม 42 เมืองทั่วโลก ได้ค่า OA เพียงร้อยละ 67.87 ต่ำกว่าผลที่ได้ในงานวิจัยนี้ ซึ่งชี้ให้เห็นว่าการบูรณาการข้อมูลเชิงโครงสร้าง 3 มิติและดัชนีชีวฟิสิกส์ในความละเอียด 10 เมตรสามารถชดเชยข้อจำกัดด้านขนาดชุดข้อมูลและจำนวนพื้นที่ที่ศึกษาได้อย่างมีประสิทธิภาพ ทั้งนี้ผลการจำแนกยังแสดงให้เห็นว่าแบบจำลองสามารถกำหนดขอบเขตเขตภูมิอากาศท้องถิ่นได้อย่างชัดเจนในทุกประเภท ทั้งกลุ่มพื้นที่สิ่งปลูกสร้าง ได้แก่ LCZ 1–10 และกลุ่มพื้นที่ธรรมชาติ ได้แก่ LCZ A–G ดังแสดงในภาพที่ 6



ภาพที่ 6 ผลการจำแนกเขตภูมิอากาศท้องถิ่น (LCZ) แต่ละประเภทจากแบบจำลอง CNN



1. ความสำคัญระดับวิกฤตของข้อมูลโครงสร้างกายภาพ

ผลการศึกษานี้ให้เห็นอย่างชัดเจนว่าข้อมูลโครงสร้างกายภาพมีบทบาทสำคัญต่อความแม่นยำของแบบจำลอง เมื่อตัดข้อมูลความสูงอาคารและค่ามุมมองท้องฟ้า (SVF) ออกทั้งหมด (รูปแบบที่ 2) ค่า OA ลดลงจากร้อยละ 70.84 เหลือเพียงร้อยละ 56.64 ซึ่งลดลงร้อยละ 14.2 เป็นการลดลงมากที่สุดในทุกรูปแบบการทดลอง อย่างไรก็ตาม ผลการวิเคราะห์ Permutation Feature Importance ให้มุมมองเพิ่มเติมที่น่าสนใจ โดยพบว่าตัวแปรที่มีอิทธิพลสูงสุด เมื่อพิจารณารายตัว คือ แบนด์สเปกตรัลกลุ่ม Red Edge ได้แก่ B5 (0.380) และ B6 (0.360) ส่วน SVF มีอิทธิพลอยู่ในอันดับ 3-4 ร่วมกับ Green (B3) ที่ค่า 0.330 และความสูงอาคาร (Building Height) อยู่ในอันดับ 5 ที่ 0.285 สะท้อนว่าแม้แบนด์สเปกตรัลจะมีอิทธิพลสูงสุดในเชิงรายตัว แต่ข้อมูลโครงสร้างกายภาพในฐานะกลุ่มมีความสำคัญอย่างมีนัยสำคัญ เนื่องจากข้อมูลสเปกตรัลเพียงอย่างเดียวไม่สามารถแยกแยะวัตถุที่มีสมบัติเชิงคลื่นคล้ายคลึงกันแต่มีความสูงต่างกันได้ เช่น หลังคาตึกแถวกับหลังคาอาคารสูง (Stewart & Oke, 2012) ในขณะที่ Aspect Ratio ซึ่งเป็นตัวแปรเชิงโครงสร้างเช่นกันกลับมีอิทธิพลต่ำที่สุดในบรรดาตัวแปรทั้งหมด (0.045) ซึ่งอาจเกิดจากความสัมพันธ์ทางฟิสิกส์ที่ทับซ้อนกับ SVF ทำให้ข้อมูลส่วนนี้ถูกแทนที่ไปแล้ว

2. ความสามารถในการสร้างความเป็นสากลของแบบจำลอง

การนำข้อมูลจากสองพื้นที่ที่มีบริบทแตกต่างกันอย่างสิ้นเชิงมาฝึกสอนร่วมกัน (รูปแบบที่ 4) ส่งผลให้ค่า OA เพิ่มขึ้นเป็นร้อยละ 72.15 สูงกว่าการใช้ข้อมูลเฉพาะกรุงเทพมหานครแห่งเดียว แสดงให้เห็นว่าการเพิ่มความหลากหลายของชุดข้อมูลช่วยลดปัญหา Overfitting และยกระดับความสามารถในการสรุปผลเชิงพื้นที่ (Spatial Generalization) ของแบบจำลองได้อย่างมีประสิทธิภาพ ซึ่งเป็นคุณสมบัติสำคัญสำหรับการนำแบบจำลองไปประยุกต์ใช้กับพื้นที่อื่นที่ยังไม่เคยฝึกสอน

3. อิทธิพลของขนาดพื้นที่สังเกตการณ์ต่อความแม่นยำแบบจำลอง

การขยายขนาดภาพนำเข้าจาก 10×10 เป็น 16×16 พิกเซลในรูปแบบที่ 5 ส่งผลให้แบบจำลองมีประสิทธิภาพสูงสุดในการศึกษานี้ โดยมีค่า OA ร้อยละ 78.5 และค่า Kappa 0.761 การขยายขอบเขตการรับรู้ ช่วยให้โครงข่าย CNN สามารถพิจารณาบริบทเชิงพื้นที่ของสภาพแวดล้อมโดยรอบได้กว้างขึ้น ซึ่งจำเป็นอย่างยิ่งสำหรับการจำแนก LCZ บางประเภทที่ต้องอาศัยรูปแบบการกระจายตัวของสิ่งปลูกสร้างประกอบการตัดสินใจ เช่น การแยกอาคารเดี่ยวแอดออกจากอาคารเดี่ยวโปร่ง ผลนี้สอดคล้องกับข้อค้นพบของ Liu and Shi (2020) ที่พิสูจน์ว่าการขยาย Patch เป็น 32×32 พิกเซลช่วยเพิ่มความแม่นยำได้ถึงร้อยละ 7.5 เมื่อเทียบกับขนาด 10×10 พิกเซล

4. ข้อจำกัดของแบบจำลองรายประเภท

แม้ภาพรวมจะมีประสิทธิภาพสูง แต่ประเภทที่มีโครงสร้างใกล้เคียงกันยังคงเป็นความท้าทาย โดยเฉพาะ LCZ 5 (อาคารกลางโปร่ง) ที่มีค่า F1-Score ต่ำที่สุด (60.3%) เนื่องจากมีลักษณะทับซ้อนกับ LCZ 2 และ LCZ 6 ส่วน LCZ C (พุ่มไม้) มี F1-Score เพียง 62.7% เนื่องจากสเปกตรัมซ้อนทับกับ LCZ A และ LCZ D นอกจากนี้ LCZ 10 (อุตสาหกรรมหนัก) ยังมีข้อจำกัดด้านการหาพื้นที่ตัวอย่างที่มีคุณภาพ เนื่องจากพื้นที่นิคมอุตสาหกรรมในพื้นที่ศึกษามีการกระจายตัวไม่ต่อเนื่องและปะปนกับการใช้ประโยชน์ที่ดินประเภทอื่น ทำให้หาพื้นที่ที่มีความสม่ำเสมอเพียงพอ



ข้อเสนอแนะ

การวิจัยในอนาคตควรทดลองขยายขนาด Patch เป็น 32×32 และ 48×48 พิกเซล เพื่อประเมินผลของบริบทเชิงพื้นที่ที่กว้างขึ้น และพิจารณาแทนที่ข้อมูลความสูงอาคาร Open Buildings 2.5D ด้วยข้อมูล LiDAR เพื่อลดความคลาดเคลื่อนในพื้นที่ที่ข้อมูลไม่สมบูรณ์ สำหรับประเภทที่จำแนกยาก ได้แก่ LCZ 5, LCZ C และ LCZ 10 ควรเพิ่มความหลากหลายของพื้นที่ตัวอย่างและใช้เทคนิค weighted loss function ในระยะยาวควรขยายพื้นที่ศึกษาไปยังเมืองหลักอื่น ๆ เพื่อจัดทำแผนที่ LCZ ระดับประเทศ นำข้อมูล LST มาวิเคราะห์ร่วมเพื่อประเมินปรากฏการณ์ UHI และทดสอบสถาปัตยกรรม Deep Learning ขั้นสูง เช่น ResNet หรือ Vision Transformers (ViT)

เอกสารอ้างอิง

- Chen, H., Yoo, C., & Weng, Q. (2024). Comparisons of deep learning models for dynamic local climate zone mapping. In Q. Wu (Ed.), *Handbook of Geospatial Approaches to Sustainable Cities* (pp. 12-24). Boca Raton, FL: CRC Press.
- Chen, Z., Liu, Y., & Zheng, B. (2023). Multi-scale contextual awareness in convolutional neural networks for accurate local climate zone classification. *ISPRS Journal of Photogrammetry and Remote Sensing*, 200, 150-165.
- Ching, J., Mills, G., Bechtel, B., See, L., Feddema, J., Wang, X., ... Theeuwes, N. (2018). WUDAPT: An urban weather, climate, and environmental modeling infrastructure for the Anthropocene. *Bulletin of the American Meteorological Society*, 99(9), 1907-1924.
- Congalton, R. G., & Green, K. (2019). *Assessing the Accuracy of Remotely Sensed Data: Principles and Practices* (3rd ed.). Boca Raton, FL: CRC Press.
- Fung, K. Y., Yang, Z.-L., & Niyogi, D. (2022). Improving the local climate zone classification with building height, imperviousness, and machine learning for urban models. *Computational Urban Science*, 2(1), 16.
- He, G., Dong, Z., Guan, J., Feng, P., Jin, S., & Zhang, X. (2023). SAR and multi-spectral data fusion for local climate zone classification with multi-branch convolutional neural network. *Remote Sensing*, 15(2), 434.
- He, T., Zhang, X., Li, W., & Liang, S. (2022). Estimating 10-m land surface albedo from Sentinel-2 satellite observations using a direct estimation approach with Google Earth Engine. *Remote Sensing of Environment*, 281, 113264.
- Huang, F., Jiang, S., Zhan, W., Bechtel, B., Liu, Z., Demuzere, M., ... Chen, J. (2023). Mapping local climate zones for cities: A large review. *Remote Sensing of Environment*, 292, 113576.
- Liu, S., & Shi, Q. (2020). Local climate zone mapping as remote sensing scene classification using deep learning: A case study of metropolitan China. *ISPRS Journal of Photogrammetry and Remote Sensing*, 164, 229-242.



- Rahmani, N., & Sharifi, A. (2023). Comparative analysis of the surface urban heat island (SUHI) phenomenon in various local climate zones (LCZs). *Climate*, 11(7), 142.
- Stewart, I. D., & Oke, T. R. (2012). Local climate zones for urban temperature studies. *Bulletin of the American Meteorological Society*, 93(12), 1879-1900.
- Wu, Q., Ma, X., Sui, J., & Pun, M.-O. (2024). DF4LCZ: Dual-stream fusion framework for local climate zone classification. *arXiv preprint arXiv:2403.09367*.
- Zheng, Z., Luo, F., Li, N., Gao, H., & Yang, Y. (2024). Impact of local climate zones on the urban heat and dry islands in Beijing: Spatial heterogeneity and relative contributions. *Journal of Meteorological Research*, 38(1), 1-15.