การวิเคราะห์ปัจจัยที่มีผลต่อความเหนียวของจุดต่อพื้น-เสาของระบบโครงสร้างแผ่นพื้นไร้คาน ภายใต้แผ่นดินไหวด้วยการเรียนรู้ของเครื่อง

เอกนรา จันดา[1*], คณิต อกนิษฐ์[2], เกษรินทร์ ชาวเกวียน[3] และ สุทัศน์ ลีลาทวีวัฒน์[2]

[1]สาขาวิชาวิศวกรรมโยธา คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏนครปฐม
[2]ภาควิชาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี
[3]สาขาวิชาครุศาสตร์อุตสาหกรรม คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏนครปฐม
*eknara@webmail.npru.ac.th

บทคัดย่อ

สมรรถนะต้านทานแผ่นดินไหวของระบบโครงสร้างแผ่นพื้นไร้คาน (Flat Plate Systems) ขึ้นอยู่กับพฤติกรรมของจุดต่อระหว่างพื้นและเสาเป็นหลัก แม้ว่าระบบโครงสร้างนี้จะมีข้อได้เปรียบในเชิงสถาปัตยกรรม แต่ความเปราะบางต่อการวิบัติจากแรงเฉือนทะลุ (Brittle Punching Shear Failure) ก็นำมาซึ่งความเสี่ยงที่สำคัญขณะเกิดแผ่นดินไหว การทำความเข้าใจปัจจัยที่มีผลต่อความสามารถในการเหนียว (Displacement Ductility Capacity) ของจุดต่อเหล่านี้ จึงมีความจำเป็นอย่างยิ่งต่อการออกแบบโครงสร้างให้ปลอดภัย การศึกษานี้ใช้เทคนิคการเรียนรู้ของเครื่อง (Machine Learning - ML) เพื่อตรวจสอบความสัมพันธ์แบบไม่เชิงเส้นที่ซับซ้อนระหว่างพารามิเตอร์ทางโครงสร้างต่างๆ กับความเหนียวของจุดต่อพื้น-เสา โดยมีการรวบรวมฐานข้อมูลที่ครอบคลุมจากผลการทดลองในอดีต นอกจากนี้ ยังได้ใช้วิธีการคัดเลือกคุณลักษณะ (Feature Selection) หลายรูปแบบ เพื่อระบุชุดตัวแปรที่มีอิทธิพลต่อความเหนียวมากที่สุด ผลลัพธ์จากการศึกษาให้ข้อมูลเชิงลึกเกี่ยวกับปัจจัยที่มีผลต่อความเปราะบาง (Fragility) เชิงแผ่นดินไหวของโครงสร้างพื้นไร้คานในปัจจุบัน และเป็นแนวทางในการเพิ่มประสิทธิภาพการออกแบบจุดต่อพื้น-เสาให้มีความเหนียวสำหรับโครงสร้างที่จะก่อสร้างใหม่ในอนาคต

คำสำคัญ: ระบบพื้นไร้คาน แผ่นดินไหว จุดต่อพื้น-เสา ความเหนียว การเรียนรู้ของเครื่อง

Machine Learning-Based Analysis of Factors Influencing the Ductility of Slab-Column Connections in Flat Slab Systems Under Seismic Loading

Eknara Junda[1*], Kanit Akanit[2], Ketsarin Chawgien[3] and Sutat Leelataviwat[2]

[1]Program of Civil Engineering, Faculty of Science and Technology, Nakhon Pathom Rajabhat University
[2]Department of Civil Engineering, Faculty of Engineering, King Mongkut's University of Technology Thonburi
[3]Program of Industrial Education, Faculty of Science and Technology, Nakhon Pathom Rajabhat University
*eknara@webmail.npru.ac.th

Abstract

The seismic performance of flat plate structural systems is primarily governed by the behavior of slab-column connections. While these systems offer architectural advantages, their susceptibility to brittle punching shear failure poses a significant risk during earthquake events. Understanding the factors that influence the displacement ductility capacity of these connections is essential for resilient structural design. This study utilizes Machine Learning (ML) techniques to investigate the complex, non-linear relationships between various structural parameters and the ductility of slab-column joints. A comprehensive database of experimental results was compiled. Several ML-based feature selection methods were used to inform the most influential features. The findings offer insight into the features that affect the seismic vulnerability of existing flat-plate structures and how to optimize the design of new ductile slab-column assemblies.

Keywords: Flat Slab System, Earthquake, Slab-Column Connection, Ductility, Machine Learning

1. บทนำ

ระบบโครงสร้างแผ่นพื้นไร้คาน (Flat Slab Systems) ได้รับความนิยมและนำมาใช้งานอย่างแพร่หลายในการก่อสร้างอาคารสมัยใหม่ โครงสร้างระบบนี้ประกอบด้วยแผ่นพื้นคอนกรีตและเสารองรับโดยไม่มีคาน ส่งผลให้สามารถเพิ่มพื้นที่ใช้สอยภายในอาคารได้อย่างมีประสิทธิภาพสูงสุด ลดความสูงรวมระหว่างชั้น (Floor-to-floor height) และช่วยประหยัดเวลาตลอดจนต้นทุนในการก่อสร้างได้อย่างมีนัยสำคัญ อย่างไรก็ตาม กลไกการถ่ายเทน้ำหนักบรรทุกและโมเมนต์ดัดจากแผ่นพื้นจะถูกส่งตรงเข้าสู่เสารองรับโดยไม่มีตัวคานมาช่วยกระจายแรง ลักษณะการถ่ายแรงเช่นนี้ทำให้โครงสร้างแผ่นพื้นไร้คานมีความอ่อนไหวสูงมากต่อการเกิดระยะเคลื่อนตัว (Displacement) และหน่วยแรงเฉือน (Shear Stresses) ในพื้นที่รอบจุดต่อเสา ดังนั้น จุดต่อระหว่างแผ่นพื้นและเสาจึงจำเป็นต้องได้รับการออกแบบอย่างเหมาะสมเพื่อให้มีกำลัง (Strength) และความสามารถในการเหนียว (Ductility) ที่เพียงพอต่อการรับแรง [1-2]

ความท้าทายที่วิศวกรโครงสร้างต้องเผชิญคือ การรับประกันว่าจุดต่อพื้น-เสามีกำลังรับแรงเฉือนและความเหนียวที่เพียงพอ โดยเฉพาะเมื่อต้องนำระบบโครงสร้างนี้ไปประยุกต์ใช้ในอาคารที่ตั้งอยู่ในพื้นที่เสี่ยงภัยแผ่นดินไหว (Seismic Hazard Zones) เช่น จังหวัดในภาคเหนือของประเทศไทย แรงสั่นสะเทือนในแนวราบเนื่องจากแผ่นดินไหวจะก่อให้เกิดการเคลื่อนตัว

ทางข้าง (Lateral Drift) และสร้างหน่วยแรงเฉือนในบริเวณจุดต่อพื้น-เสาเพิ่มขึ้นอย่างมหาศาล แรงเหล่านี้ส่งผลให้เกิดรอยร้าวลามรอบผิวเสา และนำไปสู่ การวิบัติจากแรงเฉือนทะลุ (Punching Shear Failure) ซึ่งเป็นการวิบัติในรูปแบบเปราะ (Brittle Fracture) ที่เกิดขึ้นอย่างเฉียบพลัน รูปแบบการพังทลายดังกล่าวไม่มีสัญญาณเตือนล่วงหน้า จึงสร้างความเสี่ยงและอันตรายร้ายแรงต่อชีวิตของผู้ใช้งานอาคารรวมถึงทรัพย์สินภายในโครงสร้าง [3-6]



ภาพที่ 1 การวิบัติจากแรงเฉือนทะลุ

ในการวิเคราะห์พฤติกรรมที่ไม่เชิงเส้น (Inelastic Behavior) ของจุดต่อพื้น-เสาในอดีต นักวิจัยมักอาศัยการทดลองในห้องปฏิบัติการ (Experimental Testing) ร่วมกับการสร้างแบบจำลองทางคณิตศาสตร์ด้วยวิธีไฟไนต์เอลิเมนต์ (Finite Element Analysis - FEA) แม้ว่าวิธีเหล่านี้จะช่วยให้เข้าใจพฤติกรรมโครงสร้างได้ดีขึ้น แต่การทดลองจริงในห้องปฏิบัติการมีข้อจำกัดด้านงบประมาณที่สูงมาก ขณะที่แบบจำลอง FEA ก็ต้องพึ่งพาทรัพยากรคอมพิวเตอร์ชั้นสูงและใช้เวลาในการประมวลผลคำนวณค่อนข้างนาน ปัจจุบัน เทคโนโลยีการเรียนรู้ของเครื่อง (Machine Learning - ML) ได้ก้าวเข้ามามีบทบาทสำคัญในวิศวกรรมโครงสร้าง Model [7-10] แบบจำลองที่ขับเคลื่อนด้วยข้อมูลสามารถจับคู่ความสัมพันธ์ที่ซับซ้อนและมีความเป็นไม่เชิงเส้นสูงระว่างพารามิเตอร์นำเข้า (Input Features) เช่น คุณสมบัติของวัสดุและขนาดทางเรขาคณิต เข้ากับตัวแปรเป้าหมายได้โดยตรงโดยไม่จำเป็นต้องอาศัยสมการคณิตศาสตร์ที่ตายตัว การศึกษานี้จึงมีวัตถุประสงค์เพื่อประยุกต์ใช้ระเบียบวิธีเรียนรู้ของเครื่องในการวิเคราะห์ปัจจัยที่มีผลต่อขีดจำกัดการเคลื่อนตัวทางข้าง (Drift Limit) ของจุดต่อพื้น-เสา ซึ่งเป็นตัวชี้วัดสำคัญของความเหนียวในจุดต่อพื้น-เสาภายใต้แผ่นดินไหว

2. วิธีการดำเนินการวิจัย

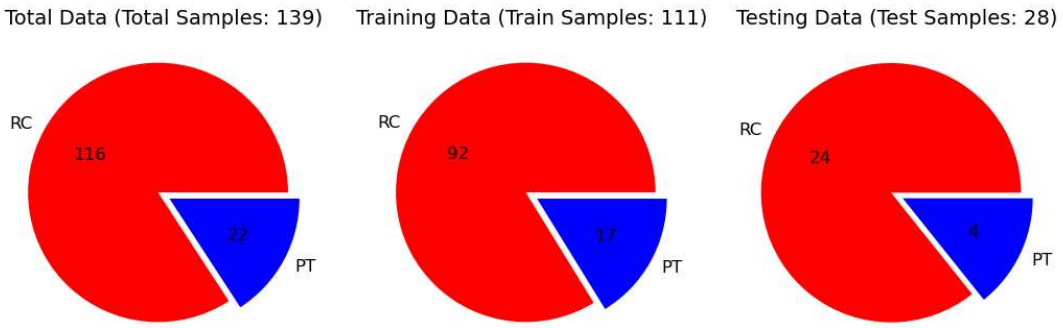
2.1 ฐานข้อมูลและการเตรียมข้อมูลขั้นต้น

งานวิจัยนี้ทำการรวบรวมฐานข้อมูลผลการทดลองการรับแรงทางข้างของจุดต่อแผ่นพื้นไร้คานภายในอาคาร (Interior Slab-Column Connections) จากวรรณกรรมวิจัยในอดีตตั้งแต่ปี ค.ศ. 1968 ถึง ค.ศ. 2021 รวมทั้งสิ้น 139 ชุดตัวอย่าง ฐานข้อมูลครอบคลุมทั้งกรณีโครงสร้างคอนกรีตเสริมเหล็กดั้งเดิม (Reinforced Concrete - RC) จำนวน 116 ตัวอย่าง และโครงสร้างคอนกรีตอัดแรงภายหลัง (Post-Tensioned Concrete - PT) จำนวน 22 ตัวอย่าง ข้อมูลทั้งหมดผ่านกระบวนการทำความสะอาดข้อมูล (Data Cleaning) เพื่อขจัดข้อผิดพลาดและค่าที่สูญหาย

พารามิเตอร์นำเข้า (Input Features) ทั้งหมด 15 ตัวแปรที่ถูกจัดเก็บประกอบด้วยพารามิเตอร์ทางเรขาคณิต คุณสมบัติวัสดุ และเงื่อนไขการทดลอง ดังนี้

1. ขนาดมิติของเสาในแนวตั้งฉากกับทิศทางแรง (C1)
2. ขนาดมิติของเสาในแนวขนานกับทิศทางแรง (C2)
3. ความกว้างประสิทธิผลของแผ่นพื้น (w)
4. ความลึกประสิทธิผลของเหล็กเสริมรับแรงดัด (d)
5. ความลึกประสิทธิผลของลวดรับแรงดึงอัดแรง (dp)
6. กำลังรับแรงอัดของคอนกรีต (fc')
7. หน่วยแรงกดในคอนกรีตเนื่องจากการอัดแรง (f_{pc})
8. กำลังรับแรงดึงคราวด์ของเหล็กเสริมรับแรงดัด (f_y)
9. กำลังรับแรงดึงคราวด์ของเหล็กเสริมรับแรงเฉือน ((f_{yv})
10. กำลังรับแรงดึงคราวด์ของลวดอัดแรง (f_{py})
11. อัตราส่วนเหล็กเสริมรับแรงดัดดึง (ρ)
12. อัตราส่วนเหล็กเสริมรับแรงอัด (ρ')
13. อัตราส่วนเหล็กเสริมรับแรงเฉือน (ρ_v)
14. อัตราส่วนลวดรับแรงดึงอัดแรง (ρ_p)
15. อัตราส่วนแรงเฉือนเนื่องจากน้ำหนักบรรทุกคงที่ (V_g/V_c หรือ GSR)

ก่อนนำข้อมูลไปฝึกฝน ข้อมูลคุณลักษณะที่มีลักษณะการกระจายตัวแบบไม่ปกติ (Non-normal Distribution) จะถูกปรับเปลี่ยนโครงสร้างทางคณิตศาสตร์ด้วยวิธี Yeo-Johnson Power Transformation เพื่อลดความเบ้ (Skewness) และเพิ่มความเสถียรในการคำนวณของอัลกอริทึม สำหรับข้อมูลที่เป็นปัจจัยเชิงคุณภาพ (Categorical Data) เช่น ประเภทของเหล็กเสริมรับแรงเฉือน จะถูกแปลงให้อยู่ในรูปตัวเลขผ่านระเบียบวิธี One-Hot Encoding ข้อมูลทั้งหมดจะถูกแบ่งออกเป็น 2 ส่วน คือ ข้อมูลสำหรับฝึกฝนแบบจำลอง (Training Set) จำนวน 111 ตัวอย่าง (คิดเป็นร้อยละ 80) และข้อมูลสำหรับทดสอบ (Testing Set) จำนวน 28 ตัวอย่าง (คิดเป็นร้อยละ 20) โดยใช้วิธีสุ่มแบบแบ่งชั้นภูมิ (Stratified Sampling) เพื่อรักษาสัดส่วนของตัวอย่าง RC และ PT ให้เท่ากันในทุกชุดข้อมูล



ภาพที่ 2 สัดส่วนของข้อมูล

2.2 ระเบียบวิธีคัดเลือกคุณลักษณะ

เนื่องจากพารามิเตอร์นำเข้ามีจำนวนมากและบางตัวแปรอาจส่งผลกระทบเชิงลบต่อสมรรถนะของ Model ก่อให้เกิดปัญหา Overfitting งานวิจัยนี้จึงเปรียบเทียบระเบียบวิธีคัดเลือกคุณลักษณะที่มีประสิทธิภาพ 3 รูปแบบ เพื่อค้นหาปัจจัยวิกฤตที่มีผลกระทบสูงสุดต่อตัวแปรเป้าหมายขีดจำกัดการเคลื่อนตัวทางข้าง (DR)

2.2.1 Sequential Forward Floating Selection (SFFS)

เป็นอัลกอริทึมแบบโลภ (Greedy Algorithm) ที่เริ่มต้นจากชุดข้อมูลว่าง จากนั้นจะทำการคัดเลือกพารามิเตอร์นำเข้าที่ช่วยลดค่าความคลาดเคลื่อนเฉลี่ยกำลังสอง (Mean Squared Error - MSE) ของแบบจำลองเพิ่มเข้ามาทีละตัวแปร (Forward Step) และในทุกๆ รอบการทำงานจะมีการตรวจสอบย้อนกลับ (Backward Step) ว่าหากถอดถอนตัวแปรที่เคยเลือกไว้ก่อนหน้าออกไปแล้ว จะช่วยเพิ่มสมรรถนะรวมของ Model หรือไม่ กระบวนการนี้จะดำเนินไปอย่างต่อเนื่องจนกว่าจะได้ชุดพารามิเตอร์ที่เหมาะสมที่สุด

2.2.2 Least Absolute Shrinkage and Selection Operator (LASSO)

LASSO เป็นรูปแบบหนึ่งของการวิเคราะห์การถดถอยที่มีการเพิ่มเงื่อนไขปรับโทษ (L1 Regularization Penalty Term) เข้าไปในสมการปรับค่าสัมประสิทธิ์ โดยความสัมพันธ์ทางคณิตศาสตร์สามารถแสดงพารามิเตอร์ควบคุมน้ำหนักของการปรับโทษ (Penalty Magnitude) อัลกอริทึม LASSO จะบีบอัดค่าสัมประสิทธิ์ของตัวแปรนำเข้าที่ไม่ส่งผลกระทบหรือมีความสำคัญน้อยให้มีค่าลดลงจนเป็นศูนย์อย่างสมบูรณ์ ซึ่งเป็นการคัดเลือกคุณลักษณะเด่นออกจากแบบจำลองโดยอัตโนมัติ

2.2.3 Feature Importance ใน Random Forest (RF)

ระเบียบวิธีนี้อาศัยโครงสร้างของ Random Forest ซึ่งเป็นตัวแบบเชิงประกอบ (Ensemble Model) ที่สร้างขึ้นจากต้นไม้ตัดสินใจ (Decision Trees) จำนวนมาก คะแนนความสำคัญของพารามิเตอร์นำเข้าแต่ละตัวจะถูกคำนวณจากความสามารถในการลดความไม่แน่นอนหรือลดค่าความคลาดเคลื่อนตกค้างกำลังสอง (Residual Sum of Squares) ณ จุดแยกของโหนดต้นไม้ ผลรวมคะแนนความสำคัญของคุณลักษณะทั้งหมดในโมเดลจะมีค่ารวมเท่ากับ 1.0 โดยคุณลักษณะที่มีค่าคะแนนสูงกว่าจะแสดงถึงอิทธิพลที่มากกว่าต่อการคาดการณ์ขีดจำกัดการเคลื่อนตัวทางข้าง

3. ผลการวิจัยและอภิปรายผล

3.1 ผลการคัดเลือกคุณลักษณะและนัยสำคัญเชิงวิศวกรรม

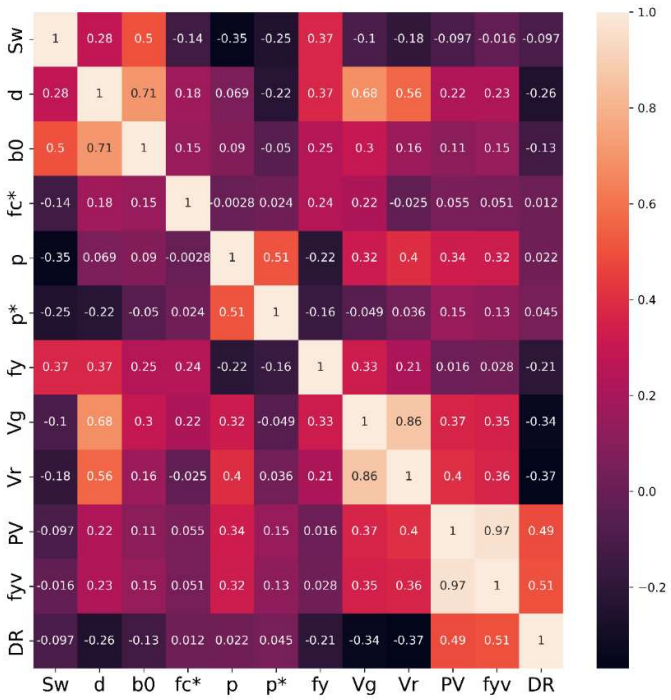
จากผลการดำเนินงานวิเคราะห์ด้วยระเบียบวิธีคัดเลือกคุณลักษณะทั้ง 3 รูปแบบ แบบจำลองพบว่าแต่ละวิธีสามารถคัดกรองตัวแปรเด่นที่มีประสิทธิภาพในการอธิบายพฤติกรรมความเหนียวได้แตกต่างกัน โดยเปรียบเทียบค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (MSE) ซึ่งหาจากค่าเฉลี่ยของผลต่างระหว่าง ค่าจริง กับ ค่าที่ทำนายได้ แล้วยกกำลังสองแสดงดังตารางที่ 2

ตารางที่ 1 ความแม่นยำแบบจำลอง

Methodology	Feature names	MSE (%)
SFFS	V_g/V_c, fc', f_{yv}, S_w, ρ', ρ_v	1.59
LASSO	V_g/V_c, d, fc', f_{yv}	1.75
Random forest	V_g/V_c, f_{yv}, ρ_v, fc', ρ	1.31

จากข้อมูลนตารางที่ 1 อัลกอริทึม Random Forest Feature Importance ให้ค่าความคลาดเคลื่อน MSE ต่ำที่สุดเท่ากับ 1.31 จึงเป็นชุดคุณลักษณะที่มีประสิทธิภาพความแม่นยำสูงสุดในการนำไปสร้าง Model คาดการณ์ ข้อมูลผลลัพธ์แสดงให้เห็นว่าตัวแปรดั้งเดิม 3 ตัวแปรที่ถูกเลือกตรงกันจากทั้ง 3 ระเบียบวิธี ได้แก่ แรงเฉือนเนื่องจากน้ำหนักบรรทุกคงที่

(V_g/V_c), กำลังรับแรงดึงคราวด์ของเหล็กเสริมรับแรงเฉือน (f_{yv}) และกำลังรับแรงอัดของคอนกรีต (fc') สหสัมพันธ์ของตัวแปรต่างๆได้รับการตรวจสอบในภาพที่ 3



ภาพที่ 3 สหสัมพันธ์ของตัวแปร

เมื่อพิจารณาในแง่วิศวกรรมโครงสร้างและแผ่นดินไหว พารามิเตอร์เหล่านี้สอดคล้องกับทฤษฎีกลศาสตร์อย่างเด่นชัด โดยค่า V_g/V_c หรือสัดส่วนแรงเฉือนแนวดิ่ง (Gravity Shear Ratio) เป็นตัวแปรควบคุมที่สำคัญที่สุด เพราะหากจุดต่อรับน้ำหนักแนวดิ่งอยู่สูง หน่วยแรงเฉือนเริ่มต้นจะประชิดขีดจำกัดกำลังของคอนกรีต ส่งผลให้เมื่อได้รับแรงดัดสลับตัวทางข้างจากแผ่นดินไหว จุดต่อจะเกิดรอยร้าวเฉือนและพังทลายลงอย่างกะทันหันในพฤติกรรมแบบเปราะ ทำให้ความเหนียวหรือระยะ Drift Capacity ลดลงอย่างรวดเร็ว ในขณะที่ f_{yv} และ ρ_v (อัตราส่วนเหล็กเสริมรับแรงเฉือน) จะทำหน้าที่ควบคุมและหน่วงการขยายตัวของรอยร้าวเฉือนทะลุ ช่วยเปลี่ยนรูปแบบการวิบัติจากแบบเปราะให้มีความเป็นเหนียวและสามารถซึมซับพลังงานแผ่นดินไหวได้มากขึ้น

4. บทสรุป

งานวิจัยนี้ประสบความสำเร็จในการประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่องเพื่อวิเคราะห์ปัจจัยและคาดการณ์ขีดจำกัดความเหนียว (Displacement Ductility) ของจุดต่อพื้น-เสาในระบบแผ่นพื้นไร้คานภายใต้ภัยแผ่นดินไหว จากการศึกษาเปรียบเทียบระเบียบวิธีคัดเลือกคุณลักษณะ 3 รูปแบบ พบว่าแบบจำลอง Random Forest สามารถคัดกรองพารามิเตอร์วิกฤต 5 ตัวแปร (V_g/V_c, f_{yv}, ρ_v, f_c', ρ) ที่ให้ความแม่นยำสูงสุดและมีค่าความคลาดเคลื่อนต่ำที่สุด (MSE = 1.31) ขณะที่ 3 ตัวแปร ที่ได้รับเลือกซ้ำกันมากที่สุดคือ V_g/V_c, f_{yv}, f_c' ผลลัพธ์ดังกล่าวพิสูจน์ว่า ระเบียบวิธีเรียนรู้ของเครื่องสามารถจับคู่ความสัมพันธ์ไม่เชิงเส้นที่ซับซ้อนของโครงสร้างวิศวกรรมโยธาได้อย่างมีประสิทธิภาพเหนือกว่าสมารการเชิงประจักษ์แบบดั้งเดิม องค์ความรู้และเครื่องมือที่ได้จากการศึกษานี้จะสามารถนำไปใช้เป็นแนวทางและเกณฑ์การตัดสินใจสำหรับวิศวกรในการประเมินความปลอดภัยเชิงโครงสร้าง ตลอดจนการออกแบบจุดต่อพื้น-เสาในอาคารสร้างใหม่ให้มีความเหนียวที่เหมาะสมสอดรับกับมาตรฐานการต้านทานแผ่นดินไหวในอนาคต

5. กิตติกรรมประกาศ

คณะผู้จัดทำขอขอบพระคุณสาขาวิชาวิศวกรรมโยธา คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏนครปฐม และ ภาควิชาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี ที่ได้ให้การสนับสนุนงานวิจัย นอกจากนี้ ขอขอบคุณผู้เชี่ยวชาญและนักวิจัยในอดีตทุกท่านเจ้าของฐานข้อมูลการทดลองโครงสร้าง ซึ่งช่วยให้งานวิจัยนี้ได้รับการพัฒนาและตรวจสอบความถูกต้องได้อย่างสมบูรณ์

6. เอกสารอ้างอิง

[1] Henderson, N. (2015). Enhancing the whole life structural performance of multi storey car parks. In *Recommendations for the Inspection Maintenance and Management of Car Park Structures* (pp.1-7).

[2] Isufi, B., Pinho Ramos, A., & Lúcio, V. (2018). Reversed horizontal cyclic loading tests of flat slab specimens with studs as shear reinforcement. *Structural Concrete*, 20(1), 330-347.

[3] Isufi, B., Rossi, M., & Ramos, A. P. (2021). Influence of flexural reinforcement on the seismic performance of flat slab – column connections. *Engineering Structures*, 242.

[4] Almeida, A. F. O., Ramos, A. P., Lúcio, V., & Marreiros, R. (2019). Behavior of Rc flat slabs with shear bolts under reversed horizontal cyclic loading. *Structural Concrete*, 21(2), 501-516.

[5] Almeida, A. F. O., Alcobia, B., Ornelas, M., Marreiros, R., & Ramos, A. P. (2020). Behaviour of reinforced-concrete flat slabs with stirrups under reversed horizontal cyclic loading. *Magazine of Concrete Research*, 72(7), 339-356.

[6] Kenea, G., Feyissa, A., & Liu, J. L. (2022). Cyclic behavior of reinforced concrete slab-column connection using numerical simulation. *Advances in Civil Engineering*, 2022, 1-14.

[7] Flah, M., Nunez, I., Ben Chaabene, W., & Nehdi, M. L. (2021). Machine learning algorithms in civil structural health monitoring: A systematic review. *Archives of Computational Methods in Engineering*, 28(4), 2621-2643.

[8] Wang, C., Song, L. H., Yuan, Z., & Fan, J. S. (2023). State-of-the-art AI-based computational analysis in civil engineering. *Journal of Industrial Information Integration*, 33, 100470.

[9] Panahi, H., & Genikomsou, A. S. (2023). A machine-learning-based model for seismic performance assessment of interior slab-column connections. *Soil Dynamics and Earthquake Engineering*, 171, 107943.

[10] Fawzy, K., Mahmoud, H. A. K., Selim, M., & Kotb, K. F. (2024). Overview of the punching capacity of the flat slab under reversed cyclic loading and methods of improvement. *Asian Journal of Civil Engineering*, 25(3), 2641-2652.