

การเข้ารหัสลำดับชั้นดินแบบต่อเนื่อง: กรอบแนวคิดที่ได้แรงบันดาลใจ
จากโมเดลภาษาขนาดใหญ่สำหรับการประเมินการเหลวตัวของดิน
Sequential Encoding of Soil Profiles: A Large Language Model-Inspired
Framework for Liquefaction Assessment

ธิปก กิจกอบสิน^{1*} สมโพธิ อยู่ไว¹ สุทัศน์ สีสาทวิวัฒน์¹ และ พรเกษม จงประดิษฐ์¹

¹กลุ่มวิจัยปัญญาประดิษฐ์ ภาควิชาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี กรุงเทพมหานคร

*Corresponding author; E-mail address: tipok.kitko@kmutt.ac.th

บทคัดย่อ

การศึกษานี้นำเสนอกรอบการเรียนรู้เชิงลึกใหม่สำหรับการทำนายการเหลวตัวของดิน โดยประยุกต์แนวคิดจากการประมวลผลภาษาธรรมชาติ (NLP) ด้วยการมองชั้นดินเป็นลำดับของโทเค็น คล้ายกับที่โมเดลการประมวลผลภาษาธรรมชาติประมวลผลประโยคเป็นลำดับของคำ โดยชั้นดินแต่ละระดับความลึกถูกแปลงเป็นเวกเตอร์ที่รวมข้อมูลคุณสมบัติเฉพาะของพื้นที่ ข้อมูลการจำแนกประเภทดิน พารามิเตอร์การตอบสนองต่อแผ่นดินไหว ค่าทดสอบการเจาะแบบมาตรฐาน (SPT) และข้อมูลตำแหน่งความลึกของชั้นดิน สถาปัตยกรรมของโมเดลใช้กลไกการสนใจตนเอง (Self-attention) เพื่อระบุความสัมพันธ์ที่ซับซ้อนระหว่างชั้นดิน โดยได้รับการฝึกฝนจากกรณีศึกษา 165 ตำแหน่งจากเหตุการณ์แผ่นดินไหวสำคัญ 11 ครั้งที่มีสภาพทางธรณีวิทยาและแผ่นดินไหวที่หลากหลาย ซึ่งให้ความแม่นยำในการทำนายถึง 93.75% ความน่าเชื่อถือของโมเดลได้รับการยืนยันผ่านการทดสอบกับชุดข้อมูลแผ่นดินไหวคาบสมุทรอินโดจีนในปี 2024 และการศึกษาผลกระทบจากการตัดพารามิเตอร์นำเข้า แนวทางนี้แสดงให้เห็นว่าแนวคิดจากการสร้างโมเดลภาษาสามารถนำมาปรับใช้ในการวิเคราะห์ข้อมูลทางธรณีวิทยาแบบต่อเนื่องได้อย่างมีประสิทธิภาพ ช่วยให้เข้าใจพฤติกรรมของดินระหว่างเหตุการณ์แผ่นดินไหวได้ละเอียดยิ่งขึ้น และชี้ให้เห็นโอกาสในการประยุกต์ใช้การเรียนรู้เชิงลึกกับความท้าทายทางวิศวกรรมธรณีเทคนิคในวงกว้าง

คำสำคัญ: ดินเหลว, การเรียนรู้เชิงลึก, สถาปัตยกรรมแบบทรานส์ฟอร์มเมอร์ส, การประเมินอันตรายจากแผ่นดินไหว, วิศวกรรมเทคนิคธรณี

Abstract

This study presents a novel Self-attention-based deep-learning model for predicting soil liquefaction potential. The proposed architecture processes three distinct data streams: spectral seismic encoding, soil stratigraphy tokenization, and site-specific features. The architecture processes data from 165 case histories across 11 major earthquakes, employing Fast Fourier Transform for seismic waveform encoding and transformer architectures for soil layer tokenization. The model achieves 93.75% prediction accuracy on cross-regional validation sets and demonstrates robust performance through sensitivity analysis of ground motion intensity and soil resistance parameters. Notably, validation against previously unseen

ground motion data from the 2024 Noto Peninsula earthquake confirms the model's generalization capabilities and practical utility. This approach establishes a new framework in geotechnical deep learning where sophisticated multi-modal analysis meets practical engineering requirements through quantitative interpretation.

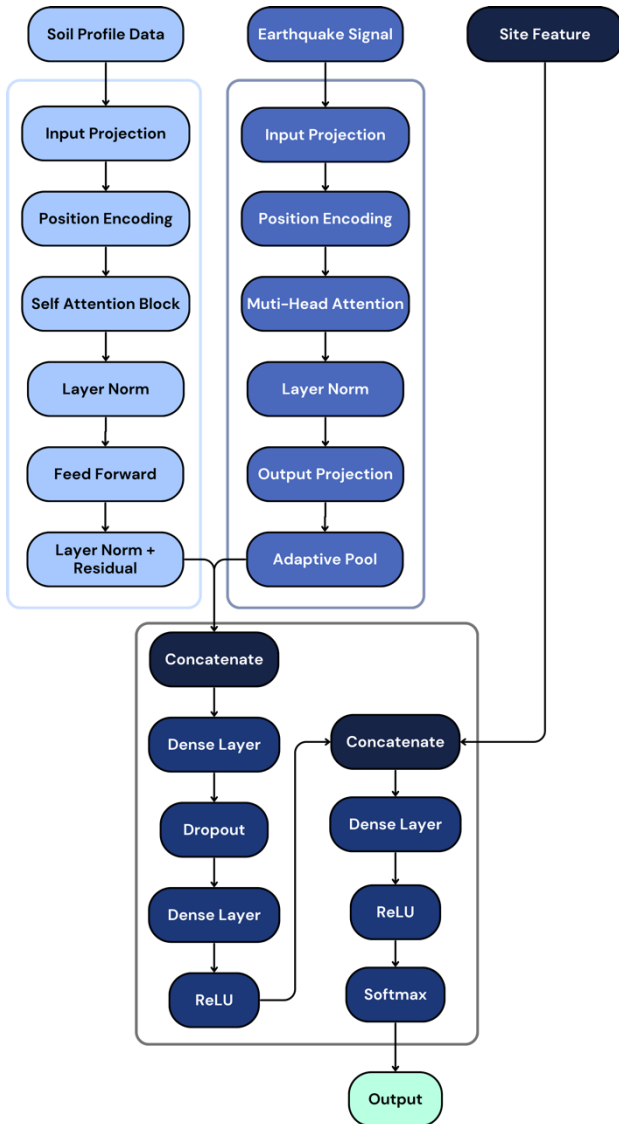
Keywords: Soil liquefaction, Deep-learning, Transformer architecture, Seismic hazard assessment, Geotechnical engineering

1. คำนำ

การเหลวตัวของดินระหว่างเหตุการณ์แผ่นดินไหวเป็นหนึ่งในปรากฏการณ์ที่สำคัญในวิศวกรรมปฐพี เนื่องจากส่งผลกระทบต่อความมั่นคงของโครงสร้างพื้นฐานและความปลอดภัยของมนุษย์ แต่ความสัมพันธ์ที่ซับซ้อนระหว่างคลื่นแผ่นดินไหวและคุณสมบัติของดินที่แปรผันและหลากหลายไปตามแต่ละพื้นที่ ทำให้การทำนายโอกาสการเกิดดินเหลวเป็นสิ่งที่ท้าทายซึ่งจำเป็นต้องการเสริมสร้างความทนทานของโครงสร้างพื้นฐาน

วิธีการแบบดั้งเดิมที่อาศัยความสัมพันธ์เชิงประจักษ์และกรอบการวิเคราะห์เชิงง่าย (Empirical correlations and simplified analytical frameworks) [1-5] มักมีข้อจำกัดในการพิจารณาความสัมพันธ์ของความสัมพันธ์ระหว่างดินกับคลื่นแผ่นดินไหว ข้อจำกัดหลักของวิธีการดั้งเดิมคือ การวิเคราะห์แบบแยกส่วน ซึ่งมักประเมินโอกาสการเกิดดินเหลวเฉพาะที่ความลึกของชั้นดินแต่ละชั้นโดยไม่พิจารณาการตอบสนองของชั้นดินโดยรวม นอกจากนี้ วิธีการเหล่านี้ยังลดทอนลักษณะของคลื่นแผ่นดินไหวให้เหลือเพียงพารามิเตอร์เดียว เช่น ค่าขนาดแผ่นดินไหว (Magnitude) ซึ่งไม่สามารถสะท้อนลักษณะเชิงเวลาและเชิงสเปกตรัมของคลื่นแผ่นดินไหวได้อย่างครบถ้วนตามความเป็นจริง และอาจนำไปสู่ความไม่แน่นอนในการประเมินความเสี่ยงจากการเหลวตัวของดินและลดความน่าเชื่อถือของโมเดล

ปัจจุบัน โครงข่ายประสาทเทียม (Artificial Neural Networks: ANNs) เป็นวิธีการหลักในงานวิจัยด้าน AI เพื่อทำนายการเหลวตัวของดิน โดยคิดเป็น 77% ของการศึกษาทั้งหมด [6] แม้ว่าจะได้รับการใช้งานอย่างแพร่หลาย [7-11] แต่โครงข่ายประสาทเทียมยังมีข้อจำกัดที่สำคัญ เช่น ความต้องการชุดข้อมูลขนาดใหญ่สำหรับการฝึกฝน และยังลดทอนลักษณะของคลื่นแผ่นดินไหวให้เหลือเพียงพารามิเตอร์เดียว เช่น ค่าขนาดแผ่นดินไหว (Magnitude) ซึ่งไม่ได้แตกต่างจากวิธีการแบบดั้งเดิมมากนัก



รูปที่ 1 แผนผังการทำงานของโมเดล

2. สถาปัตยกรรมของโมเดล

งานวิจัยนี้นำเสนอแนวทางใหม่ในการทำนายการเหลื่อมตัวของดิน ผ่านโครงข่ายประสาทเทียมแบบกลไกการสนใจตนเอง (Self-attention) ซึ่งสามารถประมวลผลข้อมูลสามประเภท ได้แก่ โปรไฟล์ชั้นดิน คลื่นแผ่นดินไหว และคุณลักษณะเฉพาะของแต่ละพื้นที่ โดยใช้โครงสร้างของทรานส์ฟอร์มเมอร์ (Transformer) เพื่อเรียนรู้ความสัมพันธ์เชิงพื้นที่ภายในชั้นดิน [12] และวิเคราะห์คลื่นไหวแผ่นดินไหวอย่างละเอียด งานวิจัยนี้ใช้ข้อมูลจาก 165 ตำแหน่งทั่วโลกที่ได้รับผลกระทบจาก 11 เหตุการณ์แผ่นดินไหวขนาดใหญ่ เพื่อทดสอบความสามารถของโมเดล โดยให้ความสำคัญกับศักยภาพในการนำไปใช้งานข้ามภูมิภาคและความหลากหลายของข้อมูล

โมเดลที่นำเสนอใช้สถาปัตยกรรมแบบสามส่วน (Tripartite Architecture) เพื่อทำนายการเหลื่อมตัวของดิน อย่างครอบคลุม ดังแสดงในรูปที่ 1 โดยแต่ละส่วนมีหน้าที่ประมวลผลข้อมูลแตกต่างกันเพื่อช่วยในการทำนายที่ถูกต้องและแม่นยำ

2.1 ตัวประมวลผลคลื่นแผ่นดินไหว

ส่วนแรกเป็นการเข้ารหัสของคลื่นแผ่นดินไหว จากข้อมูลความเร็วในโดเมนเวลาจะถูกแปลงเป็นโดเมนความถี่ผ่านการแปลงฟูเรียร์อย่างรวดเร็ว (Fast Fourier Transform: FFT) ตามสมการที่ 1

$$X(f) = F\{x(t)\} = \int_{-\infty}^{\infty} x(t)e^{-2\pi ift} dt \quad (1)$$

โดยที่ $x(t)$ คือสัญญาณความเร็วในโดเมนเวลา และ $X(f)$ คือสเปกตรัมความถี่ที่ได้จากการแปลง จากนั้นสเปกตรัมจะถูกปรับให้เสถียรในการประมวลผลดังสมการที่ 2

$$X_{norm}(f) = \frac{|X(f)|}{\sqrt{\sum_j |X(f)|^2 + \epsilon}} \quad (2)$$

โดยที่ ϵ คือค่าคงที่บวกขนาดเล็ก (โดยทั่วไปใช้ 10^{-9}) เพื่อป้องกันการหารด้วยศูนย์

ข้อมูลที่ผ่านการแปลงแล้วจะถูกป้อนเข้าสู่โมดูล Multi-head self-attention ซึ่งประกอบด้วยการฉายข้อมูลไปยัง เวกเตอร์คำถาม (Queries), เวกเตอร์กุญแจ (Keys), เวกเตอร์ค่า (Values) และตามด้วยการคำนวณคะแนนความสนใจ ดังสมการที่ 3 และ 4

$$Q_h = X_{pos} W_h^Q, K_h = X_{pos} W_h^K, V_h = X_{pos} W_h^V \quad (3)$$

$$Z_h = \text{softmax}\left(\frac{Q_h K_h^T}{\sqrt{d_h}}\right) V_h \quad (4)$$

โดยที่ d_h คือมิติของ Head และ Softmax คือฟังก์ชันที่ปรับคะแนนให้เป็นการกระจายความน่าจะเป็น

2.2 ตัวเข้ารหัสชั้นดิน

ส่วนที่สองเป็นตัวเข้ารหัสชั้นดิน ซึ่งประมวลผลข้อมูลลำดับของคุณสมบัติดินและการจำแนกประเภทดินผ่านสถาปัตยกรรม Transformer ข้อมูลดินที่เป็นอินพุตถูกแทนด้วยสมการที่ 5

$$X_{soil} = [X_{SPT} || X_{soiltype}] \in R^{n \times d \times 2} \quad (5)$$

โดยที่ X_{SPT} คือค่าการทดสอบการเจาะมาตรฐาน (SPT) ที่ความลึกต่าง ๆ และ $X_{soiltype}$ คือการเข้ารหัสประเภทดินแบบจำแนกประเภท โดยมีการจำแนกประเภทดินเป็น 3 ประเภทหลัก ทราย (1) ทรายปนดินเหนียว (2) และดินเหนียว (3) ซึ่งข้อมูลดินจะถูกฉาย (Projection) ไปยังพื้นที่มิติสูงขึ้นเพื่อการเรียนรู้ที่ดียิ่งขึ้นตามสมการที่ 6 และมีการเพิ่ม Positional Encoding เพื่อรักษาข้อมูลความลึก ตามสมการที่ 7, 8 และ 9

$$X_{proj} = X W_{proj} + b_{proj} \quad (6)$$

$$PE(pos, 2i) = \sin\left(\frac{pos}{10000^{\frac{2i}{64}}}\right) \quad (7)$$

$$PE(pos, 2i + 1) = \cos\left(\frac{pos}{10000^{\frac{2i}{64}}}\right) \quad (8)$$

$$X_{pos} = X_{proj} + PE \quad (9)$$

กลไก Multi-Head Attention แบบ 4 head เพื่อเรียนรู้ความสัมพันธ์ระหว่างชั้นดินตามสมการที่ 10 หลังจากนั้น จะมีการปรับปรุงด้วย Layer Normalization และ Feed-Forward Network ที่ใช้ LeakyReLU ตามสมการที่ 11

$$\text{MutiHead}(X) = \text{Concat}(Z_1, \dots, Z_4)W^o \quad (10)$$

$$\text{FFN}(x) = W_2 \text{LeakyReLU}(W_1 x + b_1) + b_2 \quad (11)$$

โดยที่ LeakyReLU คือ $f(x) = \max(0.01x, x)$

2.3 การประมวลผลคุณลักษณะเฉพาะของพื้นที่

ส่วนที่สามประมวลผลคุณลักษณะเฉพาะของพื้นที่ซึ่งถูกแทนด้วย $X_{site} \in R^{N \times 4}$ ประกอบด้วยข้อมูลสำคัญ 4 ชนิด ความเร็วคลื่นเฉือนที่ความลึก 30 เมตร (V_{s30}), ระยะห่างจากจุดศูนย์กลางแผ่นดินไหว ระดับน้ำใต้ดิน และระยะห่างจากแหล่งน้ำ คุณลักษณะเหล่านี้ถูกปรับให้เป็นมาตรฐานด้วยสมการที่ 12

$$X_{standardized} = \frac{X - \mu}{\sigma} \quad (12)$$

โดยที่ μ คือค่าเฉลี่ยของประชากรและ σ คือค่าเบี่ยงเบนมาตรฐาน

2.4 การหลอมรวมข้อมูลแบบข้ามรูปแบบ

ขั้นตอนสุดท้ายคือการบูรณาการข้อมูลจากทั้งสามส่วนผ่านกลไก Cross-Attention และเครือข่าย Feed-Forward ซึ่งมีขั้นตอนดังนี้

ผลลัพธ์จากส่วนที่หนึ่งและสองถูกรวมกันตามสมการที่ 13 จากนั้นข้อมูลที่รวมกันจะถูกประมวลผลผ่านเครือข่ายหลายชั้นตามสมการที่ 14 พร้อมทั้งรวมผลลัพธ์จากส่วนที่สามตามสมการที่ 15 ในขั้นสุดท้ายทำการจำแนกความเสี่ยงของการเกิดการเหลวตัวของดินตามสมการที่ 16

$$H_{combined} = \text{Concat}[H_{soil}; H_{eq}] \quad (13)$$

$$H_1 = \text{LeakyReLU}(W_1 H_{combined} + b_1) \quad (14)$$

$$H_2 = \text{LeakyReLU}(W_2 \text{Concat}[H_1; X_{site}] + b_2) \quad (15)$$

$$Y_{pred} = \text{softmax}(W_3 H_2 + b_3) \quad (16)$$

โดยที่ $Y_{pred} \in R^{N \times 2}$ เป็นความน่าจะเป็นของการเกิดหรือไม่เกิดการเหลวตัวของดิน

สถาปัตยกรรมนี้ช่วยให้โมเดลสามารถเรียนรู้ความสัมพันธ์ระหว่างคุณสมบัติดินและคลื่นแผ่นดินไหว พร้อมพิจารณาปัจจัยเฉพาะของพื้นที่ทำ

ให้สามารถประเมินความเสี่ยงของการเกิดการเหลวตัวของดินได้อย่างแม่นยำและครอบคลุมในบริบททางธรณีวิทยาและสภาพแผ่นดินไหวที่หลากหลาย

3. เปรียบเทียบวิธีการศึกษา

ในการฝึกฝนและพัฒนาโมเดลการเรียนรู้เชิงลึกสำหรับทำนายโอกาสการเกิดการเหลวตัวของดินจากแผ่นดินไหว การออกแบบกระบวนการฝึกโมเดลที่มีประสิทธิภาพเพื่อเพิ่มความแม่นยำในการทำนาย โดยมีขั้นตอนสำคัญดังต่อไปนี้

3.1 การเตรียมข้อมูลและการขยายชุดข้อมูล

ลักษณะของข้อมูล

การวิจัยครั้งนี้อาศัยข้อมูลจากฐานข้อมูล Next Generation Liquefaction (NGL) ซึ่งประกอบด้วยข้อมูลจาก 11 เหตุการณ์แผ่นดินไหวที่สำคัญระหว่างปี 1980-2020 ส่วนใหญ่เกิดขึ้นบริเวณ วงแหวนแห่งไฟแปซิฟิก (Pacific Ring of Fire) โดยมีศูนย์กลางกระจายอยู่ในหลายภูมิภาค ได้แก่ อเมริกาเหนือ (M_w 6.5-7.2) ยุโรป (M_w 6.0-6.8) เอเชีย โดยเฉพาะในญี่ปุ่น ไต้หวัน (M_w 6.8-7.6) และนิวซีแลนด์ (M_w 6.2-7.1) น่าสนใจที่แม้ว่า วงแหวนแห่งไฟแปซิฟิก (Pacific Ring of Fire) มักเชื่อมโยงกับแผ่นดินไหวในโซนการมุดตัวของเปลือกโลก (Subduction zone) แต่ข้อมูลส่วนใหญ่ในการศึกษานี้เป็นเหตุการณ์จากรอยเลื่อนในชั้นเปลือกโลกที่มีกลไกแบบ Thrust และ Strike-slip ที่ความลึก 10-35 กิโลเมตร

สิ่งจะมีการบันทึกข้อมูลการเกิดการเหลวตัวของดินจากทั่วโลกเป็นจำนวนมาก แต่ฐานข้อมูลส่วนใหญ่ขาดข้อมูลที่สมบูรณ์เกี่ยวกับโครงสร้างดินใต้พื้นผิว ดังนั้นจึงได้คัดเลือกเฉพาะข้อมูลจาก NGL ที่มีผลการทดสอบการเจาะมาตรฐาน (Standard Penetration Test: SPT) หรือการทดสอบการเจาะด้วยกรวยทะลุ (Cone Penetration Test: CPT) อย่างครบถ้วน รวมถึงข้อมูลการจำแนกประเภทดินและลักษณะน้ำใต้ดิน ที่มีรายละเอียดเพียงพอสำหรับการวิเคราะห์

3.1.1 ข้อมูลทางธรณีเทคนิค

ข้อมูลการทดสอบการเจาะ โปรไฟล์ดินที่วิเคราะห์ประกอบด้วย 165 หลุมเจาะ โดยใช้ข้อมูลจากการทดสอบการเจาะมาตรฐาน (SPT) ซึ่งแสดงในหน่วยจำนวนครั้งที่ต้องตอกต่อฟุต (N-value) และข้อมูลการทดสอบการเจาะด้วยกรวย (CPT) ที่ถูกแปลงเป็นค่า SPT [13] ตามสมการที่ 17, 18 และ 19

$$\frac{q_t}{P_a} = AN_{60}^B; P_a = 0.1 \text{ MPa} \quad (17)$$

$$A = 92.728 \times (I_c)^{-2.746} \quad (18)$$

$$B = -0.1185 \times (I_c)^2 + 0.5333 \times (I_c) - 0.0764 \quad (19)$$

โดยที่ q_t คือค่าความต้านทานปลายกรวย P_a คือความดันบรรยากาศ $I_c = 1.7, 2.2, 2.95$ สำหรับทราย ทรายปนดินเหนียว และดินเหนียวตามลำดับ

3.1.2 ข้อมูลคลื่นแผ่นดินไหว

คลื่นแผ่นดินไหวถูกแปลงเป็นโดเมนความถี่โดยใช้การวิเคราะห์ Fast Fourier Transform (FFT) ตามสมการที่ 1 และ 2

3.1.3 คุณสมบัติเฉพาะของพื้นที่

ความเร็วคลื่นเฉือนในช่วง 30 เมตร (V_{s30}) มีค่าระหว่าง 100 ถึง 700 เมตร/วินาที โดยส่วนใหญ่อยู่ระหว่าง 200-300 เมตร/วินาที บ่งชี้ถึงสภาพดินที่มีความหนาแน่นปานกลางถึงสูง

ระยะห่างจากแหล่งน้ำ แตกต่างกันจากสถานที่ที่อยู่ติดกันไปจนถึงระยะประมาณ 35 เมตร โดยส่วนใหญ่ของพื้นที่ตั้งอยู่ใกล้กับแหล่งน้ำ บ่งชี้ถึงความเป็นไปได้ของการเชื่อมต่อทางชลศาสตร์

ระดับน้ำใต้ดิน อยู่ในช่วงตั้งแต่พื้นผิวดินจนถึง 10 เมตรใต้พื้นดิน โดยระดับน้ำใต้ดินตื้นมักสัมพันธ์กับความเสี่ยงการเกิดการเหลวตัวของดินที่เพิ่มขึ้น

ระยะห่างจากจุดศูนย์กลางแผ่นดินไหว มีค่าตั้งแต่ 1 กิโลเมตรถึง 100 กิโลเมตร ให้ช่วงที่ครอบคลุมของสภาพการเกิดแผ่นดินไหว

3.2 การขยายชุดข้อมูล

ชุดข้อมูลเริ่มต้นประกอบด้วยประวัติการเกิดการเหลวตัวของดินจาก 165 สถานที่ทั่วโลก โดย 105 พื้นที่ (64%) แสดงหลักฐานการเกิดการเหลวตัวของดินและ 60 พื้นที่ (36%) ไม่แสดงหลักฐานการเกิดการเหลวตัวของดิน การสำรวจได้พื้นที่ในแต่ละตำแหน่งครอบคลุมความลึกอย่างน้อย 10 เมตร ช่วยให้การจำแนกลักษณะชั้นดินและความเสี่ยงการเกิดการเหลวตัวของดินได้อย่างละเอียด

เพื่อเพิ่มความสามารถของโมเดลในการทำนายร่วมกับระดับความรุนแรงของแผ่นดินไหวที่หลากหลาย ชุดข้อมูลได้รับการขยายโดยการรวมสถานการณ์ไม่เกิดแผ่นดินไหว (null motion) สำหรับแต่ละพื้นที่ การขยายข้อมูลนี้เพิ่มชุดข้อมูลฝึกเป็นสองเท่า รวมเป็น 330 ชุดข้อมูล วิธีการนี้ช่วยแก้ไขอคติ (Bias) ในชุดข้อมูลเดิมที่เน้นเหตุการณ์แผ่นดินไหวขนาดใหญ่ และปรับปรุงความสามารถในการทำนายของโมเดลให้ครอบคลุมระดับความรุนแรงของแผ่นดินไหวที่หลากหลายมากขึ้น

3.3 การประมวลผลข้อมูลเบื้องต้น

กระบวนการประมวลผลข้อมูลเบื้องต้นใช้ สแตนด์ตาร์ดสเกลเลอร์ (Standard Scaler) สำหรับการปรับค่าคุณลักษณะต่างๆ ตามสมการที่ 12 โดยที่ σ คือค่าเบี่ยงเบนมาตรฐานต่อคุณลักษณะ ซึ่งช่วยให้มั่นใจว่าคุณลักษณะทุกตัวมีส่วนร่วมในการฝึกโมเดลอย่างเท่าเทียมกัน

การแปลงคุณลักษณะในโดเมนความถี่โดยการประมวลผล Fast Fourier Transform (FFT) ตามสมการที่ 1 ตามด้วยการทำสเปกตรัมขนาดตามสมการที่ 2 เพื่อให้มั่นใจถึงความเสถียรเชิงตัวเลข และการแปลงนี้จะสังเกตลักษณะความถี่ของคลื่นแผ่นดินไหวได้อย่างมีประสิทธิภาพ และยังคงรักษาความสม่ำเสมอของขนาดคลื่นแผ่นดินไหวในแต่ละชุดข้อมูล

3.4 การพัฒนาโมเดล

โมเดลใช้ Binary cross-entropy loss เป็นฟังก์ชันการสูญเสียในสมการที่ 20

$$\mathcal{L} = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 + y_i) \log(1 - \hat{y}_i)] \quad (20)$$

โดยที่ y_i คือค่าจริงและ \hat{y}_i คือค่าที่ทำนาย ฟังก์ชันการสูญเสียนี้เหมาะสำหรับงานการจำแนกแบบไบนารีในการทำนายการเกิดการเหลวตัวของดิน การหาค่าที่เหมาะสมของโมเดลใช้ อัลกอริทึมการปรับค่าพารามิเตอร์แบบออดัม (Adam optimizer) ที่มีอัตราการเรียนรู้ (Learning rate) 1×10^{-4} และการลดน้ำหนัก (Weight Decay) 1×10^{-3} เพื่อป้องกันการเรียนรู้แบบจำเพาะเจาะจงเกินไปของโมเดล (Overfitting) ในชั้น

การจำแนกสุดท้ายใช้ฟังก์ชันกำหนดความน่าจะเป็นสำหรับคลาสต่างๆ (SoftMax) ตามสมการที่ 21

$$p_i = \frac{e^{x_i}}{\sum_j e^{x_j}} \quad (21)$$

การนำไปใช้ในกรอบงาน PyTorch Lightning ด้วย GPU ผ่าน NVIDIA RTX 4090 ซึ่งช่วยรับประกันประสิทธิภาพในการคำนวณและความสามารถในการทำซ้ำได้ผ่านค่ากำหนดลำดับการสุ่มเพื่อให้ผลลัพธ์สามารถทำซ้ำได้ (Random seed) ความแม่นยำถูกคำนวณตามสมการที่ 22

$$\text{Accuracy} = \frac{1}{N} \sum_{i=1}^N \mathbb{1}(\text{Argmax}(y_i) = \text{Argmax}(\hat{y}_i)) \quad (22)$$

4. วิเคราะห์ผลและการอภิปรายผล

4.1 ผลการฝึกฝนและการประเมินประสิทธิภาพโมเดล

การทดสอบโมเดลที่พัฒนาขึ้นสำหรับการทำนายการเหลวตัวของดินแสดงให้เห็นประสิทธิภาพที่น่าพอใจอย่างมาก โดยมีค่าความแม่นยำ (Accuracy) สูงถึง 93.75% ซึ่งหมายความว่าโมเดลสามารถทำนายผลลัพธ์ได้อย่างถูกต้องถึง 15 จาก 16 พื้นที่ นอกจากนี้ ค่า F1 Score ที่ 0.9307 แสดงถึงความสมดุลที่ดีระหว่างความแม่นยำและความครอบคลุมในการทำนาย

ผลการวิเคราะห์ความสามารถของโมเดลพบว่ามีค่า Precision ที่ 0.9167 ซึ่งบ่งชี้ว่าเมื่อโมเดลทำนายว่าจะเกิดการเหลวตัวของดิน (คลาส 1) โมเดลจะทำนายถูกต้องประมาณ 91.67% ที่น่าสนใจอย่างยิ่งคือค่า Recall ที่สูงถึง 0.9545 แสดงว่าโมเดลสามารถตรวจจับเหตุการณ์การเหลวตัวของดิน ได้เกือบทั้งหมดที่เกิดขึ้นจริง ซึ่งเป็นคุณสมบัติที่สำคัญอย่างยิ่งสำหรับแบบจำลองที่ใช้ในการประเมินความเสี่ยงทางเทคนิคธรณี

การวิเคราะห์ Confusion Matrix ยืนยันประสิทธิภาพของโมเดล โดยแสดงให้เห็นว่าโมเดลสามารถระบุกรณีที่ไม่เกิดการเหลวตัวของดิน (True Negative) ได้ถูกต้อง 10 กรณี และระบุกรณีที่เกิดการเหลวตัวของดิน (True Positive) ได้ถูกต้อง 5 กรณี มีเพียงหนึ่งกรณีเท่านั้นที่โมเดลทำนายผิดพลาด โดยทำนายว่าจะเกิดการเหลวตัวของดิน ทั้งที่ความเป็นจริงไม่เกิด (False Positive) และที่สำคัญคือไม่มีกรณี False Negative เลย ซึ่งหมายความว่าโมเดลไม่พลาดการตรวจจับกรณีที่เกิดการเหลวตัวของดินจริง ซึ่งในส่วนของกรณีที่ไม่เกิดการทำนายผิดพลาดเมื่อทำการตรวจสอบรายละเอียดแล้วจะพบได้ว่าเป็นพื้นที่ที่ชั้นดินเป็นทรายทั้งหมด มีค่า SPT เท่ากับ 6 ในช่วง 9-10 เมตร และมีค่า SPT อยู่ช่วง 10-18 ในช่วง 4-8 เมตร ซึ่งโมเดลอาจมองว่าโอกาสการเกิดการเหลวตัวของดินสูงจากการที่มีชั้นดินเป็นทรายทั้งหมดและมีค่า SPT ต่ำมากที่ระดับความลึก 9-10 เมตร โมเดลจึงตัดสินใจว่ามีโอกาสเกิดการเหลวตัวของดินสูง

ความสามารถในการตรวจจับกรณีการเหลวตัวของดินที่เกิดขึ้นจริงอย่างแม่นยำนี้มีความสำคัญอย่างยิ่งในบริบทของการออกแบบโครงสร้างพื้นฐานและการประเมินความเสี่ยงในพื้นที่เสี่ยงแผ่นดินไหว เพราะการไม่สามารถระบุความเสี่ยงการเกิดการเหลวตัวของดินอาจนำไปสู่ความเสียหายทั้งต่อโครงสร้างและชีวิตมนุษย์ แม้จะมีข้อผิดพลาดในการทำนายเป็นบวกลวงอยู่หนึ่งกรณี แต่ในแง่ของความปลอดภัย การประเมินความเสี่ยงเกินจริงเล็กน้อยยังคงเป็นทางเลือกที่ปลอดภัยกว่าการประเมินต่ำกว่าความเป็นจริง

4.2 การตรวจสอบความถูกต้องและการประเมินโมเดล

กรอบการตรวจสอบความถูกต้องแบบครอบคลุมที่รวมวิธีตรวจสอบความถูกต้องของโมเดลแบบแบ่งกลุ่ม (K-fold cross-validation) และการ

แบ่งชุดข้อมูลฝึกอบรม/ทดสอบแบบแบ่งชั้น ถูกนำมาใช้เพื่อปรับสถาปัตยกรรมเครือข่ายประสาทเทียมให้เหมาะสมที่สุด วิธีการฝึกจัดการกับความกังวลเกี่ยวกับความเพียงพอของข้อมูลและการทำให้เป็นกรณีทั่วไปผ่านกระบวนการสองขั้นตอน

ในขั้นแรก กระบวนการตรวจสอบความถูกต้องแบบ 10-fold ได้แบ่งชุดข้อมูลออกเป็นสิบส่วนอย่างเป็นระบบ โดยใช้เก้าส่วนสำหรับการฝึกและหนึ่งส่วนสำหรับการตรวจสอบในแต่ละรอบการทำซ้ำ โพรโตคอลการฝึกใช้ 500 รอบ (Epochs) ด้วยชุดข้อมูลย่อยในการฝึกโมเดล (Batch) ขนาด 20 ซึ่งเป็นการปรับให้เหมาะสมสำหรับแต่ละส่วน การตรวจสอบความถูกต้องแบบแบ่งกลุ่มนี้ แสดงให้เห็นถึงประสิทธิภาพที่แข็งแกร่งด้วยความแม่นยำเฉลี่ย 80% ($\sigma < 7\%$) ซึ่งบ่งชี้ถึงความสามารถของโมเดลในการจำแนกข้อมูลได้อย่างเหมาะสม การวิเคราะห์เสถียรภาพโมเดลแสดงค่าเบี่ยงเบนมาตรฐานที่ 0.0707 ซึ่งบ่งชี้ว่าโมเดลมีความเสถียรในระดับปานกลาง [14]

ต่อมา ชุดข้อมูลได้รับการแบ่งแบบ 95%/5% สำหรับการฝึกอบรม-การตรวจสอบ (Train/Test) เพื่อปรับโมเดลขั้นสุดท้ายให้เหมาะสม ซึ่งใช้ 500 รอบ (Epochs) ด้วยชุดข้อมูลย่อยในการฝึกโมเดล (Batch) ขนาด 20 เช่นกัน ประสิทธิภาพของโมเดลถูกประเมินผ่าน Binary cross-entropy loss และความแม่นยำการจำแนก (Accuracy)

เพื่อลดความเสี่ยงต่อการเกิดการจำเพาะเจาะจงเกินไปของโมเดล (Overfitting) กลไกการเช็คพอยต์ได้ถูกใช้เพื่อเก็บรักษาสถานะโมเดลที่เหมาะสมที่สุดตามจุดสูงสุดของความแม่นยำการตรวจสอบ (Test Accuracy) โดยบรรณเมตริกประสิทธิภาพ (Confusion Matrix) ที่สำคัญด้วยค่าความแม่นยำ (Accuracy) 93.75% และอัตราการดึงคืน (Recal) 95.45% ในชุดการตรวจสอบ ค่าความแม่นยำ (Accuracy) และ อัตราการดึงคืน (Recal) ที่สูงนี้แสดงให้เห็นถึงความสามารถที่ดีของโมเดลในทำนายการเกิดและไม่เกิดการหลุดตัวของดินได้อย่างถูกต้อง

การตรวจสอบวิธีการแบบสองทางนี้ช่วยรักษาเสถียรภาพของโมเดลในสภาพทางธรณีวิทยาที่หลากหลาย ดังเห็นได้จากเมตริกประสิทธิภาพ (Confusion Matrix) ที่สอดคล้องกันในการตรวจสอบความถูกต้องและการทดสอบขั้นสุดท้าย กรอบการประเมินที่ครอบคลุมและเมตริกประสิทธิภาพ (Confusion Matrix) ที่ได้สนับสนุนการประยุกต์ใช้โมเดลในการประเมินการเกิดการหลุดตัวของดินใหม่ ๆ โดยเฉพาะภายในบริบททางธรณีวิทยาและแผ่นดินไหวที่หลากหลาย ซึ่งแสดงให้เห็นถึงการทำให้เป็นกรณีทั่วไปที่เชื่อถือได้สำหรับกรณีที่ไม่เกิดมาก่อน

4.3 การศึกษาผลกระทบของการตัดองค์ประกอบออกจากโมเดล (Ablation Study)

การวิเคราะห์ผลกระทบจากการตัดองค์ประกอบของโมเดล ได้ให้ข้อมูลเชิงลึกที่มีค่าเกี่ยวกับการทำงานร่วมกันของส่วนประกอบต่าง ๆ และประสิทธิภาพโดยรวมของการทำนายการหลุดตัวของดิน การทดสอบอย่างเป็นระบบนี้ช่วยให้สามารถระบุโครงสร้างสถาปัตยกรรมที่เหมาะสมที่สุด โดยคำนึงถึงทั้งความแม่นยำในการทำนายและการใช้ทรัพยากรการคำนวณ

เมื่อทำการทดสอบโดยการตัดองค์ประกอบหลักออกจากโมเดล พบว่าการตัดองค์ประกอบข้อมูลแผ่นดินไหวทำให้ ความแม่นยำลดลงอย่างมีนัยสำคัญจาก 93.75% เหลือเพียง 75.00% การตัดองค์ประกอบข้อมูลพื้นที่ทำให้ความแม่นยำลดลงเหลือ 78.79% ทั้งสองกรณีนั้น ยังคงใช้ทรัพยากรการคำนวณเท่าเดิมที่ 3.305 GFLOPs และพารามิเตอร์ 1,797,060 ตัว ความแตกต่างของผลกระทบนี้ชี้ให้เห็นว่า แม้ทั้งสององค์ประกอบจะมีความสำคัญ แต่ข้อมูลคลื่นแผ่นดินไหวมีอิทธิพลต่อความแม่นยำของโมเดลมากกว่า

ตารางที่ 1 ผลการศึกษาผลกระทบของการตัดองค์ประกอบออกจากโมเดล

| โมเดล | ค่าความแม่นยำ (%) | FLOP (G) | Total Parameter |
|-----------------------------------|-------------------|----------|-----------------|
| การตัดองค์ประกอบข้อมูลแผ่นดินไหว | 75.00 | 3.305 | 1,797,060 |
| การตัดองค์ประกอบข้อมูลพื้นที่ | 78.79 | 3.305 | 1,797,060 |
| ตัวเข้ารหัสโปรไฟล์ดิน | | | |
| - 8 Attention head | 93.75 | 3.306 | 1,907,204 |
| - 4 Loops of Attention head | 93.75 | 3.306 | 1,797,060 |
| - 1 Attention head | 69.70 | 3.305 | 1,772,804 |
| ตัวประมวลผลคลื่นแผ่นดินไหว | | | |
| - 8 Attention head | 93.75 | 6.773 | 1,851,204 |
| - 1 Attention head | 63.64 | 1.627 | 1,749,380 |
| โครงสร้างที่ปรับให้เหมาะสม | | | |
| ตัวเข้ารหัสโปรไฟล์ดิน | | | |
| - 4 Attention head | | | |
| - 2 Loops of Attention head | 93.75 | 3.305 | 1,797,060 |
| ตัวประมวลผลคลื่นแผ่นดินไหว | | | |
| - 2 Attention head | | | |

ในส่วนของการปรับแต่งกลไกความสนใจ (Attention Heads) สำหรับตัวเข้ารหัสโปรไฟล์ดิน แสดงให้เห็นว่า เมื่อมีการปรับแต่งเป็น 8 Attention head ทำให้ความแม่นยำเท่าเดิมที่ 93.75% โดยใช้ทรัพยากรการคำนวณใกล้เคียงเดิมที่ 3.306G FLOPs และมีพารามิเตอร์เพิ่มขึ้นเป็น 1,907,204 ตัว ในส่วนของการวน Attention head 4 รอบ มีความแม่นยำที่ 93.75% และใช้พารามิเตอร์ 1,797,060 ตัว สุดท้าย 1 Attention head ทำให้ความแม่นยำลดลงอย่างมากเหลือเพียง 69.70% และมีพารามิเตอร์ 1,749,380 ตัว การลดลงอย่างมีนัยสำคัญเมื่อใช้ Attention head เพียงตัวเดียวแสดงให้เห็นถึงความสำคัญของการมี Attention head หลายตัวในการจับความสัมพันธ์ที่ซับซ้อนภายในชั้นดิน นอกจากนี้ ผลการทดสอบยังพบว่าการใช้ 4 รอบวนซ้ำ (loops) สำหรับความสนใจชั้นดิน สามารถคงประสิทธิภาพสูงสุดได้ ในส่วนของตัวประมวลผลคลื่นแผ่นดินไหว แสดงความอ่อนไหวต่อการกำหนดค่าความสนใจที่ชัดเจนยิ่งขึ้น สำหรับ 8 Attention head มีความแม่นยำที่ 93.75% แต่ต้องใช้ทรัพยากรการคำนวณสูงถึง 6.773 GFLOPs และมีพารามิเตอร์ 1,851,204 ตัว หากลด Attention head ลงเหลือเพียง 1 Attention head แม้จะช่วยลดทรัพยากรการคำนวณเหลือ 1.627 GFLOPs และพารามิเตอร์ 1,749,380 ตัว แต่ประสิทธิภาพของโมเดลก็ลดลงอย่างมากเหลือเพียง 63.64% ซึ่งสามารถสรุป การตัดองค์ประกอบ, ความแม่นยำ และการใช้ทรัพยากรได้ตามตารางที่ 1

จากการวิเคราะห์ผลกระทบของการตัดองค์ประกอบออกจากโมเดล โดยละเอียด โมเดลที่เหมาะสมที่สุดคือ ตัวเข้ารหัสโปรไฟล์ดิน 4 Attention head 2 Loops of Attention head และ ตัวประมวลผลสัญญาณแผ่นดินไหว 2 Attention head

โครงสร้างที่ปรับให้เหมาะสมนี้สามารถรักษาความแม่นยำสูงสุดที่ 93.75% ในขณะที่ใช้ทรัพยากรการคำนวณที่มีประสิทธิภาพ (3.305G FLOPs และพารามิเตอร์ 1,797,060 ตัว)

ผลการศึกษาชี้ให้เห็นว่า แม้จะเพิ่มกลไกความสนใจ (Attention Heads) ให้มากขึ้น และเพิ่มรอบการประมวลผล (Loops of Attention head) จะมีความสำคัญ แต่ต้องปรับแก้จนถึง "จุดสมดุล (Sweet spot)" ที่การเพิ่มความซับซ้อนไม่ได้ช่วยเพิ่มประสิทธิภาพอย่างมีนัยสำคัญ จุดสมดุลนี้

ช่วยจับความสัมพันธ์ของตัวแปรที่จำเป็นสำหรับการทำนายการเหลื่อมตัวของดินได้อย่างแม่นยำ พร้อมกับรักษาประสิทธิภาพการคำนวณให้เหมาะสมกับการใช้งานจริง พร้อมทั้งเสนอแนวทางที่เป็นประโยชน์สำหรับการออกแบบโมเดลการเรียนรู้เชิงลึกสำหรับงานวิศวกรรมเทคนิคธรณีอีกด้วย

4.4 การประยุกต์ใช้กับกรณีศึกษาจริง

จากเหตุการณ์เหตุการณ์แผ่นดินไหวคาบสมุทรโนโตะ เมื่อวันที่ 1 มกราคม 2567 (M_w 7.5, MJMA 7.6) ในญี่ปุ่น เหตุการณ์นี้มีศูนย์กลางที่พิกัด 37.5°N, 137.2°E ห่างจากเมืองซูซุ จังหวัดอิชิคาวะ ประมาณ 6 กิโลเมตร ทางทิศตะวันออกเฉียงเหนือ แผ่นดินไหวครั้งนี้สร้างการสั่นสะเทือนรุนแรง วัดได้สูงสุดที่ระดับ 7 บนมาตราชินโดของ JMA และระดับ X-XI บนมาตรา MMI สามารถนำมาใช้ในการตรวจสอบความถูกต้องของโมเดลกับเหตุการณ์นี้ได้ เนื่องจากเหตุการณ์นี้ไม่ได้รวมอยู่ใน 165 กรณีที่นำมาฝึกฝน จึงเป็นข้อมูลทดสอบอิสระที่สมบูรณ์แบบสำหรับประเมินประสิทธิภาพในสภาวะแผ่นดินไหวรุนแรงที่ไม่มีในชุดข้อมูลฝึกอบรวม


การวิเคราะห์พื้นที่ภาคสนามจากกรณีศึกษา ISK002 (37.4413°N, 137.2908°E) ในโนโตะ พบการเปลี่ยนแปลงของพื้นดินอย่างกว้างขวางจากการเหลื่อมตัวของดิน พื้นที่นี้มีโครงสร้างใต้ผิวดินที่หลากหลาย ประกอบด้วย ชั้นบนสุดเป็นดินเหนียว/ตะกอนทราย ชั้นทรายหลักที่ความลึกถึงประมาณ 9 เมตร ชั้นล่างเป็นตะกอนทรายปนทราย การทดสอบ SPT แสดงความแปรผันของความหนาแน่นดินในแนวดิ่ง โดยค่า N-values มีตั้งแต่ประมาณ 8 ที่ผิวดินไปจนถึง 39 blows/ft ที่ความลึก 4 เมตร ซึ่งแสดงตามรูปที่ 2

4.5 การศึกษาผลกระทบของพารามิเตอร์ (Parametric Study)

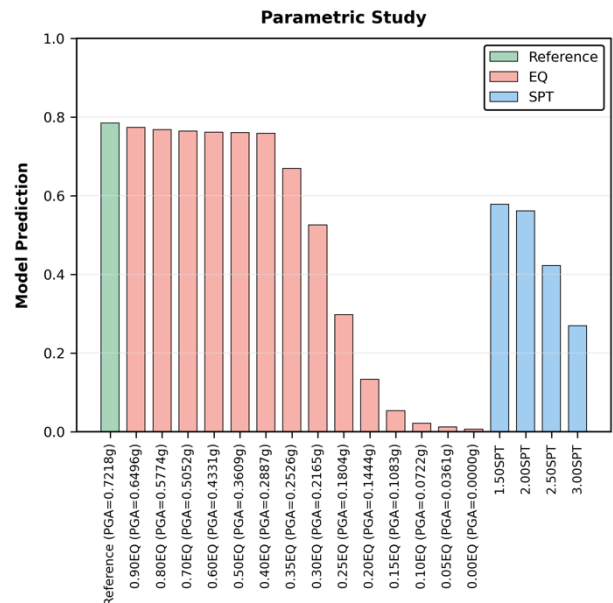
ในพื้นที่ ISK002 โมเดลที่พัฒนาขึ้นให้ค่าความน่าจะเป็นของการเกิดการเหลื่อมตัวของดินที่ 0.785 ซึ่งผลการทำนายนี้สอดคล้องกับรูปแบบความเสียหายที่พบจริง โดยเฉพาะในพื้นที่ใกล้โครงสร้างอาคาร

จากเหตุการณ์แผ่นดินไหวคาบสมุทรโนโตะกรณีศึกษา ISK002 สามารถนำข้อมูลคลื่นแผ่นดินไหว และผลการทดสอบการเจาะมาตรฐาน (SPT) มาวิเคราะห์ความอ่อนไหวเพื่อแสดงว่าโมเดลตอบสนองต่อพารามิเตอร์ต่าง ๆ อย่างไรจากการลดทอน หรือเพิ่มขึ้นของค่าความเร่งสูงสุดของแผ่นดินไหว (Peak Ground Acceleration: PGA) และค่า SPT โดยผลกระทบของ PGA ที่ PGA สูง (0.50-0.70g) ความน่าจะเป็นของการเหลื่อมตัว > 0.75 เกิดการเปลี่ยนแปลงสำคัญที่ ~0.25g ความน่าจะเป็นลดลงเหลือ 0.67 จุดวิกฤติที่ ~0.18g ความน่าจะเป็นลดลงต่ำกว่า 0.5 (เกณฑ์ระหว่างการเกิดและไม่เกิดการเหลื่อมตัวของดิน) ในส่วนของผลกระทบของค่า SPT พบว่ามีความสัมพันธ์ผกผันชัดเจนระหว่างค่า SPT และความน่าจะเป็นของการเหลื่อมตัวของดิน เมื่อเพิ่มค่า SPT เป็นสองเท่าครั้ง (2.5xSPT) ความน่าจะเป็นลดลงต่ำกว่า 0.5 แสดงถึงการลดความเสี่ยงอย่างมีประสิทธิภาพ ซึ่งแสดงดังรูปที่ 3 การวิเคราะห์ความอ่อนไหวนี้มีประโยชน์อย่างยิ่งสำหรับงานวิศวกรรม เนื่องจากให้ข้อมูลเชิงปริมาณเกี่ยวกับระดับการปรับปรุงคุณภาพดินที่จำเป็นเพื่อลดความเสี่ยงการเหลื่อมตัวให้อยู่ในระดับที่ยอมรับได้ นอกจากนี้ข้อมูลหลุมเจาะอื่น ๆ ที่เกิดการเหลื่อมตัวของดิน จากเหตุการณ์แผ่นดินไหวที่คาบสมุทรโนโตะ โมเดลนี้ก็สามารถทำนายได้อย่างถูกต้องและแม่นยำ

โดยสรุป การตรวจสอบความถูกต้องของโมเดลกับเหตุการณ์แผ่นดินไหวคาบสมุทรโนโตะแสดงให้เห็นว่า โมเดลสามารถประเมินความเสี่ยงการเหลื่อมตัวได้แม่นยำ ทำให้โมเดลนี้เป็นเครื่องมือที่มีคุณค่าสำหรับการประเมินความเสี่ยงการเหลื่อมตัวของดินในบริบทของแผ่นดินไหว



รูปที่ 2 กราฟแสดงค่า SPT และประเภทดินของ ISK002



รูปที่ 3 กราฟแสดงผลวิเคราะห์ความอ่อนไหว

5. บทสรุป

งานวิจัยนี้ได้พัฒนาโมเดลสำหรับการทำนายการเหลวตัวของดินจากแผ่นดินไหว โดยอาศัยการประมวลผลแบบขนานจากข้อมูลสามส่วนที่แตกต่างกันประกอบด้วยข้อมูลชั้นดินตามความลึก ซึ่งได้ใช้ข้อมูล การทดสอบการเจาะมาตรฐาน (SPT) และชนิดของดินชั้นนั้น ๆ ตั้งแต่ระดับความลึก 1-10 เมตร ลักษณะเฉพาะของพื้นที่รวมทั้งระยะห่างจากศูนย์กลาง แผ่นดินไหว ระยะห่างจากแหล่งน้ำ ระดับน้ำใต้ดินและ ความเร็วคลื่นเฉือน ในช่วง 30 เมตร (V_{s30}) รวมทั้งคลื่นแผ่นดินไหวที่ผ่านการแปลงข้อมูลด้วยการแปลงฟูเรียร์อย่างรวดเร็วให้เป็นโดเมนของเวลาเพื่อทำให้สามารถวิเคราะห์ คลื่นแผ่นดินไหวได้ละเอียดมากขึ้น โดยการสถาปัตยกรรมการเรียนรู้เชิงลึก แบบ Self-attention นี้มีระดับความแม่นยำในการทำนายถึง 93.75% ในสภาพทางธรณีวิทยาที่หลากหลาย ทำให้การพัฒนาโมเดลนี้สามารถช่วยให้ ประเมินความเสี่ยงต่อการเกิดการเหลวตัวของดินจากแผ่นดินไหว ได้อย่าง ครอบคลุมมากกว่าวิธีการแบบดั้งเดิม ซึ่งโมเดลนี้ได้รับการทดสอบโดยใช้ ข้อมูลแผ่นดินไหวที่คาบสมุทรไอนโตส ในเดือนมกราคม 2024 ซึ่งเป็นข้อมูล ใหม่ที่ไม่ได้ใช้สำหรับการฝึกฝนโมเดล แต่โมเดลสามารถทำนายการเหลวตัว ของดินจากแผ่นดินไหวจากข้อมูล 7 พื้นที่ในเหตุการณ์นี้ได้ถูกต้องและ แม่นยำ

เอกสารอ้างอิง

- [1] Youd, T.L., Idriss, I.M., Andrus, R.D., Arango, I., Castro, G., Christian, J.T., Dobry, R., Finn, W.D.L., Harder Jr, L.F., Hynes, M.E., Ishihara, K., Koester, J.P., Liao, S.S.C., Marcuson Iii, W.F., Martin, G.R., Mitchell, J.K., Moriwaki, Y., Power, M.S., Robertson, P.K., Seed, R.B., and Stokoe Ii, K.H. (2001). Liquefaction Resistance of Soils: Summary Report from the 1996 NCEER and 1998 NCEER/NSF Workshops on Evaluation of Liquefaction Resistance of Soils. *Journal of Geotechnical and Geoenvironmental Engineering*, 127(10), pp.817-833.
- [2] Boulanger, R.W. and Idriss, I.M. (2016). CPT-Based Liquefaction Triggering Procedure. *Journal of Geotechnical and Geoenvironmental Engineering*, 142(2).
- [3] Cetin, K.O., Seed, R.B., Kayen, R.E., Moss, R.E.S., Bilge, H.T., Ilgac, M., and Chowdhury, K. (2018). SPT-based probabilistic and deterministic assessment of seismic soil liquefaction triggering hazard. *Soil Dynamics and Earthquake Engineering*, 115, pp.698-709.
- [4] Robertson, P.K. and Wride, C.E. (1998). Evaluating cyclic liquefaction potential using the cone penetration test. *Canadian Geotechnical Journal*, 35(3), pp.442-459.
- [5] Seed, H.B. and Idriss, I.M. (1970). A Simplified Procedure for Evaluating Soil Liquefaction Potential.
- [6] Maurer, B.W. and Sanger, M.D. (2023). Why “AI” models for predicting soil liquefaction have been ignored, plus some that shouldn’t be. *Earthquake Spectra*, 39(3), pp.1883-1910.
- [7] Abbaszadeh Shahri, A. (2016). Assessment and Prediction of Liquefaction Potential Using Different Artificial Neural Network Models: A Case Study. *Geotechnical and Geological Engineering*, 34(3), pp.807-815.
- [8] Fahim, A.K.F., Rahman, M.Z., Hossain, M.S., and Kamal, A.S.M.M. (2022). Liquefaction resistance evaluation of soils using artificial neural network for Dhaka City, Bangladesh. *Natural Hazards*, 113(2), pp.933-963.
- [9] Hanna, A.M., Ural, D., and Saygili, G. (2007). Neural network model for liquefaction potential in soil deposits using Turkey and Taiwan earthquake data. *Soil Dynamics and Earthquake Engineering*, 27(6), pp.521-540.
- [10] Juang, C.H. and Chen, C.J. (1999). CPT-Based Liquefaction Evaluation Using Artificial Neural Networks. *Computer-Aided Civil and Infrastructure Engineering*, 14(3), pp.221-229.
- [11] Kurup, P.U. and Garg, A. (2005). Evaluation of Liquefaction Potential Using Neural Networks Based on Adaptive Resonance Theory. *Transportation Research Record: Journal of the Transportation Research Board*, 1936, pp.192-200.
- [12] Youwai, S. and Detchewee, S. (2025). Predicting rapid impact compaction of soil using a parallel transformer and long short-term memory architecture for sequential soil profile encoding. *Engineering Applications of Artificial Intelligence*, 139.
- [13] Bol, E. (2023). A new approach to the correlation of SPT-CPT depending on the soil behavior type index. *Engineering Geology*, 314.
- [14] Varoquaux, G. (2018). Cross-validation failure: Small sample sizes lead to large error bars. *Neuroimage*, 180(Pt A), pp.68-77.