

# การตอบสนองพลวัตเชิงเส้นภายใต้แรงกระทำแบบไม่เสถียรด้วยแบบจำลองเครือข่ายประสาทเทียม Linear Dynamic Responses under Nonstationary Forces with Artificial Neural Network Model

ปวิศ โปษะนันท์<sup>1</sup> ปฏิภาณ จันทรวิชิต<sup>2</sup> Damang Dy<sup>3</sup> และ ยศ สมพรเจริญสุข<sup>4\*</sup>

<sup>1,4</sup> ภาควิชาวิศวกรรมโยธา สถาบันวิศวกรรมศาสตร์และเทคโนโลยีอุตสาหกรรม มหาวิทยาลัยเทคโนโลยีมหานคร จ.กรุงเทพฯ

<sup>2</sup> ภาควิชาวิศวกรรมโยธา คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีราชมงคลกรุงเทพ จ.กรุงเทพฯ

<sup>3</sup> General Department of Immigration, Ministry of Interior, Phnom Penh, Cambodia

\*Corresponding author; E-mail address: syosyos@mut.ac.th

## บทคัดย่อ

วัตถุประสงค์ของบทความนี้คือ เพื่อนำเสนอแบบจำลองเครือข่ายประสาทเทียม (ANN) มาใช้เป็นแบบจำลองตัวแทนสำหรับการหาผลการตอบสนองพลวัตของโครงสร้างโครงสร้างข้อรับแรงเฉือนภายใต้การกระตุ้นแบบไม่เสถียรอันเนื่องมาจากแรงสั่นสะเทือนแผ่นดินไหว เครือข่ายประสาทเทียมแบบป้อนข้อมูลไปข้างหน้าหลายชั้นได้ประยุกต์ใช้ในสถาปัตยกรรมของเครือข่ายประสาทเทียมสำหรับการส่งถ่ายจำนวนของการกระตุ้นแบบไม่เสถียรที่มีจำนวนมากที่ได้รับการสร้างบนพื้นฐานทฤษฎีการประมาณสากลเพื่อเป็นข้อมูลนำเข้าไปสู่ข้อมูลส่งออกของการวิเคราะห์ผลการตอบสนองพลวัตแบบสุ่ม แนวคิดที่นำเสนอและกระบวนการในการคำนวณได้แสดงผ่านการวิเคราะห์ช่วงเวลาของระบบพลวัตเชิงเส้นอย่างง่ายที่มี 3 องศาอิสระและถูกกระทำด้วยการกระตุ้นการเคลื่อนที่ของพื้นดินแบบไม่เสถียรจากผลลัพธ์เชิงตัวเลขที่ได้มาแสดงให้เห็นถึงศักยภาพของระเบียบวิธีการที่นำเสนอในพจน์ของเวลาคำนวณและความแม่นยำ

คำสำคัญ: เครือข่ายประสาทเทียม, ผลการตอบสนองพลวัตเชิงเส้น, การกระตุ้นแบบไม่เสถียร, ทฤษฎีการประมาณสากล, การวิเคราะห์แบบสุ่ม

## Abstract

The objective of this paper is to propose the artificial neural network (ANN) model as a surrogate model for determining the dynamic responses of shear frame structure under nonstationary excitation due to the seismic forces. A multi-layer feed-forward neural network is employed particularly in ANN architecture for mapping a large number of generated non-stationary excitations that based on the universal approximation theorem as input to output of stochastic dynamic responses analysis. The proposed idea and computational procedure is illustrated through a time-domain analysis of the simplified 3-DOF linear dynamic system subjected to non-stationary ground motion excitation. From the obtained numerical results shown the potential of the proposed methodology in terms of computational time and accuracy.

Keywords: artificial neural network, linear dynamic responses, non-stationary excitation, universal approximation theorem, stochastic analysis

## 1. บทนำ

ในการคำนวณผลการตอบสนอง ณ ขณะเวลาใดๆ ที่เฉพาะเจาะจง (At Particular Time Instances) ของระบบพลวัตเชิงเส้น (Linear Dynamic

System) ภายใต้อิทธิพลจากภายนอกของการกระตุ้นแบบไม่เสถียร (Non-stationary Excitations) ซึ่งโดยทั่วไปแล้วมีความเชื่อมโยงและสัมพันธ์กับระเบียบวิธีการวิเคราะห์ความน่าเชื่อถือและความน่าจะเป็น (Reliability and Probabilistic Analysis) [1,2] นอกจากนี้ เมื่อพิจารณาวิธีการจำลองแบบมอนติคาร์โล (Monte Carlo Simulation: MCS) ซึ่งเป็นหนึ่งในวิธีการที่มีความสามารถในการประยุกต์ใช้เพื่อวิเคราะห์ปัญหาในลักษณะนี้ได้ [3] ทั้งนี้ หากความน่าจะเป็นของเหตุการณ์ที่มีโอกาสเกิดขึ้นได้นั้นมีค่าน้อยจึงทำให้มีความต้องการจำนวนของการจำลองที่ใช้ในการวิเคราะห์ที่มีจำนวนมากและส่งผลกระทบต่อใช้เวลาในการคำนวณที่มากเพิ่มขึ้นตามไปด้วยเพื่อให้ได้มาซึ่งผลลัพธ์ที่มีความถูกต้อง (Accurate Results)

สำหรับความฉลาดเชิงการคำนวณ (Computational Intelligence) มีการประยุกต์ในหลากหลายมิติของปัญหา [4-10] โดยหนึ่งในแบบจำลองความฉลาดเชิงการคำนวณที่เป็นที่รู้จักคือ แบบจำลองเครือข่ายประสาทเทียม (ANN Model) ซึ่งมีศักยภาพในการส่งถ่ายข้อมูลนำเข้าและข้อมูลส่งออกเนื่องจากความสามารถของการประมาณฟังก์ชันสากล (Universal Function Approximation) [11,12] สำหรับการประยุกต์ ANN Model เป็นแบบจำลองตัวแทนของฟังก์ชันสมรรถนะสามารถพบได้ในงานวิจัยทั่วไป อาทิเช่น การประเมินสมรรถนะของโครงสร้างในแนวดิ่งภายใต้แรงลมทอร์นาโดแบบไม่เสถียร [13] การจำลองการแพร่ขยายของคลื่น [14,15] การทำนายการตอบสนองของพื้นผิวทาง [16] และการประเมินค่ากำลังอัดประลัยของคอนกรีต [17] เป็นต้น

ในการศึกษาวิจัยนี้ นำเสนอการประยุกต์แบบจำลองเครือข่ายประสาทเทียมในการส่งถ่ายการกระตุ้นแบบไม่เสถียรสู่การหาผลการตอบสนองของการกระจายความน่าจะเป็นแบบสุ่ม (Stochastic Dynamic Responses) ในระบบพลวัตเชิงเส้น

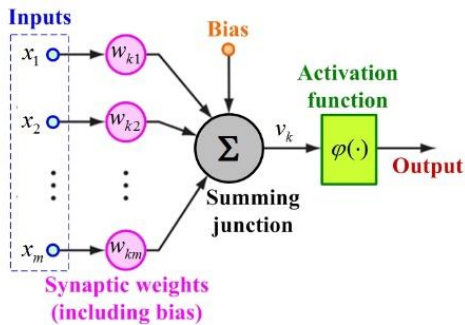
## 2. เครือข่ายประสาทเทียม

ANN เป็นวิธีการหนึ่งในแขนงของเทคนิคปัญญาประดิษฐ์ (Artificial Intelligence: AI) โดยได้แนวคิดจากการออกแบบเครือข่ายคอมพิวเตอร์เพื่อเลียนแบบการทำงานของสมองมนุษย์ [18] ทั้งนี้ ANN ประกอบมาจากหลายหน่วยประมวลผล (Processing Units) โดยแต่ละหน่วยเรียกว่า เซลล์ประสาท ซึ่งสามารถเก็บองค์ความรู้และนำออกมาใช้ในภายหลังได้ ANN ทำหน้าที่เลียนแบบสมองใน 2 ลักษณะคือ (1) ANN รับความรู้ผ่านกระบวนการเรียนรู้ (Learning Processes) และ (2) ความรู้ที่ได้มาถูกจัดเก็บในรูปแบบของค่าน้ำหนักจุดประสานประสาท (Synaptic Weights)

### 2.1 เซลล์ประสาท (Neuron)

สำหรับเซลล์ประสาทคือ หน่วยประมวลผลสารสนเทศ (Information-Processing Unit) และใช้เป็นพื้นฐานสำหรับการดำเนินการของ ANN ซึ่ง

เซลล์ประสาทประกอบไปด้วย 3 องค์ประกอบย่อยที่สำคัญดังนี้คือ (1) จุดประสานประสาท (Synapses) (2) จุดรวมผล (Summing Junction) และ (3) ฟังก์ชันกระตุ้น สำหรับเซลล์ประสาท  $k$  ใดๆ แสดงได้ดังรูปที่ 1



รูปที่ 1 แบบจำลองเซลล์ประสาท

ในที่นี้  $x_j$  คือ ข้อมูลนำเข้าลำดับที่  $j$   $w_{kj}$  คือ ค่าน้ำหนักจุดประสานประสาท  $b_k$  คือ ค่าความโน้มเอียง (Bias)  $v_k$  คือ ผลรวมข้อมูลนำเข้าที่ถูกตัดแปลงจากการประยุกต์ค่าน้ำหนักจุดประสานประสาท  $\varphi(\cdot)$  คือ ฟังก์ชันกระตุ้น สำหรับข้อมูลส่งออก (Output) จากเซลล์ประสาท ( $y_k$ ) สามารถคำนวณได้จาก

$$y_k = \varphi(v_k) \quad (1)$$

และ

$$v_k = \sum_{j=1}^m w_{kj}x_j + b_k \quad (2)$$

### 2.2 ฟังก์ชันกระตุ้น (Activation Function)

ฟังก์ชันกระตุ้นอาจอยู่ในรูปของฟังก์ชันแบบเชิงเส้นหรือแบบไม่เชิงเส้นก็ได้ [11] ทั้งนี้ ฟังก์ชันกระตุ้นที่ใช้โดยทั่วไปได้แก่ (1) ฟังก์ชัน Threshold หรือ ฟังก์ชัน Heaviside และ (2) ฟังก์ชันซิกมอยด์ (Sigmoid Function) หรือ ฟังก์ชันรูปตัวเอส (S-shaped Function) ซึ่งเป็นฟังก์ชันที่นิยมและมีการใช้งานมากที่สุดในสถาปัตยกรรมของเครือข่ายประสาทเทียมและมีรูปแบบสมการทั่วไปคือ

$$\varphi(v) = 1/[1 + \exp(-av)] \quad (3)$$


เมื่อ  $a$  คือ พารามิเตอร์ความชัน และ  $v$  คือ ตัวแปรต้น

### 2.3 สถาปัตยกรรมของเครือข่ายประสาทเทียม (ANN Architecture)

สำหรับสถาปัตยกรรมทั่วไปของเครือข่ายประสาทเทียมมีดังนี้คือ (1) เครือข่ายประสาทเทียมแบบป้อนข้อมูลไปข้างหน้าชั้นเดียว (Single-Layer Feed-Forward ANN) (2) เครือข่ายประสาทเทียมแบบป้อนข้อมูลไปข้างหน้าหลายชั้น (Multi-Layer Feed-Forward ANN) และ (3) เครือข่ายประสาทเทียมแบบป้อนข้อมูลย้อนกลับ (Recurrent ANN)

ในการศึกษานี้ สนใจศึกษาสถาปัตยกรรมของเครือข่ายประสาทเทียมแบบป้อนข้อมูลไปข้างหน้าหลายชั้นดังรูปที่ 2 ซึ่งประกอบไปด้วย (1) ชั้นนำเข้าข้อมูล 1 ชั้น (One Input Layer) (2) ชั้นซ่อนเร้นอย่างน้อย 1 ชั้น (At Least One Hidden Layer) และ (3) ชั้นส่งออกข้อมูล 1 ชั้น (One Output Layer) ซึ่งข้อดีของการพิจารณาเครือข่ายประสาทเทียมแบบป้อนข้อมูลไปข้างหน้าหลายชั้นคือ มีความสามารถในการเป็นตัวแทนของ

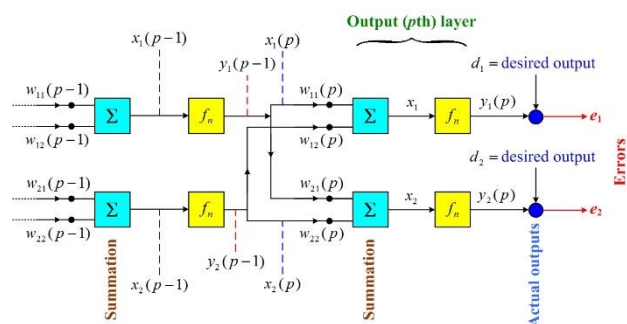
ฟังก์ชันต่อเนื่อง (Continuous Functions) อย่างไรก็ดี ในการหาค่าน้ำหนักจุดประสานประสาท ( $w_{kj}$ ) จำเป็นต้องใช้ความพยายามในการคำนวณที่สูงเมื่อมีจำนวนชั้นซ่อนเร้นและเซลล์ประสาทที่มีจำนวนมาก



รูปที่ 2 การป้อนข้อมูลไปข้างหน้าหลายชั้นใน ANN

### 2.4 การเรียนรู้ของเครือข่ายประสาทเทียม (ANN Learning)

วิธีการเรียนรู้ที่มีประสิทธิภาพในการหาค่าน้ำหนักจุดประสานประสาทคือ ขั้นตอนวิธีการแพร่ย้อนกลับ (Back Propagation Algorithm: BP) ซึ่งเป็นวิธีที่ได้รับการอ้างอิงอย่างมาและมีมีการประยุกต์ใช้ในการเรียนรู้ของ ANN [18] สำหรับ ANN Model ที่ดีจำเป็นต้องมีความสามารถในการลดความคลาดเคลื่อนในการทำนายให้น้อยที่สุด ซึ่งความคลาดเคลื่อนในชั้นส่งออกข้อมูล (Output Layer) ของวิธีการแพร่ย้อนกลับแสดงได้ดังรูปที่ 3



รูปที่ 3 ความคลาดเคลื่อนที่ชั้นข้อมูลส่งออก

ความคลาดเคลื่อนระหว่างข้อมูลส่งออกที่คำนวณได้จาก ANN ( $d_k$ ) และข้อมูลส่งออกจากข้อมูลจริง ( $y_k$ ) ในชั้นส่งออกข้อมูลของเซลล์ประสาทที่  $k$  สามารถนิยามได้เป็น

$$\varepsilon = \frac{1}{2} \sum_{k=1}^N e_k^2 \quad (4)$$

เมื่อ

$$e_k = d_k - y_k \quad (5)$$

โดยที่  $\mathcal{E}$  คือ ความคลาดเคลื่อนที่ชั้นส่งออกข้อมูล  $e_k$  คือ ผลต่างระหว่างข้อมูลส่งออกที่คำนวณได้จาก ANN และข้อมูลส่งออกจากข้อมูลจริงของเซลล์ประสาทที่  $k$  และ  $N$  คือ จำนวนของเซลล์ประสาทในชั้นข้อมูลส่งออก กำหนดให้เกรเดียนท์ (Gradient) ของความคลาดเคลื่อนที่ชั้นส่งออกข้อมูลของเซลล์ประสาทที่  $k$  ( $\nabla \mathcal{E}_k$ ) คือ

$$\nabla \mathcal{E}_k = \partial \mathcal{E} / \partial w_{kj} \quad (6)$$

โดยการใช้เทคนิคที่ไม่ซับซ้อนแต่มีประสิทธิภาพที่เรียกว่า วิธีการเคลื่อนตามความชันมากที่สุด (Steepest Descent Method) สำหรับการลุ่มเริ่มต้นใดๆ ในรอบที่  $m$  ของค่าน้ำหนักจุดประสานประสาท ดังนั้น

$$w_{kj}(m+1) = w_{kj}(m) + \Delta w_{kj}(m) \quad (7)$$

เมื่อประยุกต์สมการ (7) ลงในสมการ (6) จะได้

$$\Delta w_{kj} = -\eta \partial \mathcal{E} / \partial w_{kj} \quad (8)$$

โดยที่  $\eta$  คือ พารามิเตอร์อัตราการเรียนรู้ (Learning Rate Parameter) และในกรณีทั่วไปสามารถกำหนดให้มีค่าเท่ากับ 1

สังเกตว่า เครื่องหมายลบในสมการ (8) บ่งชี้ถึงทิศทางที่พุ่งลงเข้าสู่ค่าต่ำสุด จากนิยามของเพอร์เซปตรอน (Perceptron) สามารถคำนวณหาข้อมูลส่งออกของจุดเชื่อมต่อของเพอร์เซปตรอนในเซลล์ประสาทที่  $k$  ( $z_k$ ) ดังนี้

$$z_k = \sum_j w_{kj} x_j \quad (9)$$

และ

$$y_k = F(z_k) \quad (10)$$

เมื่อ  $F$  คือ ฟังก์ชันไม่เชิงเส้น (Nonlinear Function) และมีความต่อเนื่องในการหาอนุพันธ์ได้

จากสมการ (9) และ (10) ทำให้สามารถเขียนสมการ (6) ได้เป็น

$$\partial \mathcal{E} / \partial w_{kj} = (\partial \mathcal{E} / \partial z_k) (\partial z_k / \partial w_{kj}) \quad (11)$$

และ

$$\partial z_k / \partial w_{kj} = x_j(p) = y_j(p-1) \quad (12)$$

โดย  $p$  คือ ชั้นข้อมูลส่งออกและเมื่อแทนสมการ (12) ลงในสมการ (11) ได้

$$\partial \mathcal{E} / \partial w_{kj} = (\partial \mathcal{E} / \partial z_k) x_j(p) = (\partial \mathcal{E} / \partial z_k) y_j(p-1) \quad (13)$$

กำหนดนิยามให้

$$\Phi_k(p) = -\partial \mathcal{E} / \partial z_k(p) \quad (14)$$

ดังนั้น สมการ (13) สามารถเขียนใหม่ได้เป็น

$$\partial \mathcal{E} / \partial w_{kj} = -\Phi_k(p) x_j(p) = -\Phi_k(p) y_j(p-1) \quad (15)$$

และทำการแทนสมการ (15) ลงในสมการ (8)

$$\Delta w_{kj} = \eta \Phi_k(p) x_j(p) = \eta \Phi_k(p) y_j(p-1) \quad (16)$$

นอกจากนี้ เมื่อพิจารณาสมการ (14) ซึ่งสามารถเขียนในรูปของ

$$\Phi_k = -\partial \mathcal{E} / \partial z_k = -(\partial \mathcal{E} / \partial y_k) (\partial y_k / \partial z_k) \quad (17)$$

จากนั้น ให้ทำการหาอนุพันธ์สมการ (4) กับ  $y_k$  หนึ่งครั้งได้

$$\partial \mathcal{E} / \partial y_k = -(d_k - y_k) = y_k - d_k \quad (18)$$

กำหนดให้ฟังก์ชัน  $F$  ที่ปรากฏในสมการ (10) เป็นฟังก์ชันกระตุ้นซิกมอยด์ (Sigmoid Activation Function) ดั่งนิยามในสมการ (3) ดังนั้น

$$y_k = F(z_k) = 1 / [1 + \exp(-z_k)] \quad (19)$$

และ

$$\partial y_k / \partial z_k = y_k (1 - y_k) \quad (20)$$

จากนั้นทำการแทนสมการ (18) และ (20) ลงในสมการ (17) ได้

$$\Phi_k = y_k (1 - y_k) (d_k - y_k) \quad (21)$$

เมื่อพิจารณาที่ชั้นข้อมูลส่งออกของสมการ (8) และใช้สมการ (11) จึงนำไปสู่สมการต่อไปนี้

$$\Delta w_{kj} = -\eta (\partial \mathcal{E} / \partial z_k) (\partial z_k / \partial w_{kj}) \quad (22)$$

และแทนสมการ (12) และ (17) ลงในสมการ (22) ผลลัพธ์ที่ได้คือ

$$\Delta w_{kj}(p) = \eta \Phi_k(p) y_j(p-1) \quad (23)$$

ในที่นี้  $\Phi_k(p)$  นิยามได้ตามสมการ (21)

ในลำดับถัดไป ทำการพิจารณาการแพร่ย้อนกลับที่ชั้นซ่อนเร้นใดๆ ที่  $r^{\text{th}}$  ในลักษณะทำนองเดียวกับสมการ (8) จะได้

$$\Delta w_{ji} = -\eta (\partial \mathcal{E} / \partial w_{ji}) \quad (24)$$

ซึ่งสอดคล้องสำหรับแขนงที่  $i^{\text{th}}$  ในเซลล์ประสาทที่  $j^{\text{th}}$  ของชั้นซ่อนเร้น  $r^{\text{th}}$  เมื่อประยุกต์สมการ (11) ลงในสมการ (24) นำไปสู่สมการ

$$\Delta w_{ji} = -\eta (\partial \mathcal{E} / \partial z_j) (\partial z_j / \partial w_{ji}) \quad (25)$$

จากการสังเกตสมการ (12) และนิยามของ  $\Phi_k$  ในสมการ (17) สามารถลดรูปสมการ (25) ได้ตามลำดับดังต่อไปนี้

$$\Delta w_{ji} = -\eta \left( \frac{\partial \varepsilon}{\partial z_j} \right) y_i(r-1) \quad (26)$$

$$\Delta w_{ji} = -\eta \left[ \frac{\partial \varepsilon}{\partial y_j(r)} \frac{\partial y_j(r)}{\partial z_j} \right] y_i(r-1) \quad (27)$$

และ

$$\frac{\partial \varepsilon}{\partial y_j(r)} = \sum_k \frac{\partial \varepsilon}{\partial z_k(r+1)} \left[ \frac{\partial z_k(r+1)}{\partial y_j(r)} \right] \quad (28)$$

พิจารณานิยาม  $z_k$  จากสมการ (9) ลงในสมการ (28) นำไปสู่

$$\frac{\partial \varepsilon}{\partial y_j(r)} = \sum_k \frac{\partial \varepsilon}{\partial z_k(r+1)} \left[ \frac{\partial}{\partial y_j(r)} \sum_m w_{km}(r+1) y_m(r) \right] \quad (29)$$

โดยที่ ผลรวมของ  $k$  หาได้จากเซลล์ประสาทต่างๆ ของชั้นถัดไป ( $r+1$ ) ที่เชื่อมต่อกับข้อมูลส่งออก  $y_j(r)$  ขณะที่ ผลรวมของ  $m$  ถูกทำบนข้อมูลนำเข้าทั้งหมดในแต่ละเซลล์ประสาทที่  $k'$  ของชั้นที่ ( $r+1$ )

เมื่อพิจารณานิยามของ  $\Phi_k$  ในสมการ (17) อีกครั้ง ทำให้สมการ (29) เขียนใหม่ได้เป็น

$$\frac{\partial \varepsilon}{\partial y_j(r)} = \sum_k \frac{\partial \varepsilon}{\partial z_k(r+1)} w_{kj} = -\sum_k \Phi_k(r+1) w_{kj}(r+1) \quad (30)$$

ทั้งนี้เนื่องมาจาก  $w_{kj}(r+1)$  ถูกเชื่อมต่อกับ  $y_j(r)$

จากสมการ (17) (18) และ (30) ทำให้ได้สมการดังต่อไปนี้

$$\Phi_j(r) = -\frac{\partial y_j}{\partial z_j} \sum_k \Phi_k(r+1) w_{kj}(r+1) \quad (31)$$

$$\Phi_j(r) = y_j(r) [1 - y_j(r)] \sum_k \Phi_k(r+1) w_{kj}(r+1) \quad (32)$$

และจากสมการ (23) จะได้

$$\Delta w_{ji}(r) = \eta \Phi_j(r) y_i(r-1) \quad (33)$$

เพื่อนำมาใช้หา  $\Delta w_{kj}(r)$  ดังฟังก์ชันของ  $\Phi_k$  และค่าน้ำหนักของชั้นที่ ( $r+1$ ) ในสมการ (30)

### 2.5 ทฤษฎีการประมาณสากล (Universal Approximation Theorem)

ด้วยวิธีการ ANN มีวัตถุประสงค์เพื่อใช้ในการส่งถ่ายและแปลงข้อมูลนำเข้าไปสู่ข้อมูลส่งออกซึ่งสามารถทำได้โดยอาศัยพื้นฐานของทฤษฎีการประมาณสากล [11] ทั้งนี้ ทฤษฎีการประมาณสากลเป็นทฤษฎีที่มีการใช้อยู่จริงและเป็นทฤษฎีที่มีการรองรับการกล่าวอ้างอย่างเป็นเหตุเป็นผลในเชิง

คณิตศาสตร์ (Mathematical Justification) สำหรับการประมาณค่าของฟังก์ชันต่อเนื่องใดๆ [12]

กำหนดให้ฟังก์ชันกระตุ้น  $\varphi(\cdot)$  เป็นฟังก์ชันต่อเนื่องไม่คงที่มีขอบเขต และมีค่าเพิ่มขึ้นทางเดียว (Non-constant, Bounded, Monotonically Increased, and Continuous Function) และนิยามให้  $F(x_1, \dots, x_{m_0})$  เป็นการประมาณของฟังก์ชัน (Approximate Realization of Function) สำหรับทุกค่าของ  $x_1, \dots, x_{m_0}$  ที่อยู่บนปริภูมิข้อมูลนำเข้า (Input Space)

$$F(x_1, \dots, x_{m_0}) = \sum_{i=1}^{m_1} \alpha_i \varphi \left( \sum_{j=1}^{m_0} w_{ij} x_j + b_i \right) \quad (34)$$

เมื่อ  $\alpha_i$  คือ เซตของค่าคงที่จำนวนจริงใดๆ (Set of Real Constants) ส่วน  $i$  และ  $j$  คือ จำนวนเต็มบวก (Positive Integer Numbers)

### 3. การประยุกต์เครือข่ายประสาทเทียม

สำหรับตัวอย่างการประยุกต์ใช้แบบจำลอง ANN ในบทความนี้เริ่มต้นจากการพิจารณาระบบพลวัตเชิงเส้นที่มีพหุองศาอิสระ (Multi-Degree of Freedom: MDOF) และอยู่ภายใต้การกระตุ้นแบบไม่เสถียร โดยที่การกระตุ้นมีลักษณะที่เจาะจงและใช้พิจารณาในการศึกษาคือ การกระตุ้นที่พื้นดินแบบไม่เสถียรและเป็นแบบสุ่ม (Stochastic Non-stationary Ground Excitation:  $A_g(t)$ ) เมื่อ  $A_g(t)$  คือ ค่าอัตราเร่งแบบไม่เสถียรที่ระดับพื้นดินจากการสั่นสะเทือนแผ่นดินไหว (Seismic)

#### 3.1 แบบจำลอง Kanai-Tajimi แบบเสถียร (Stationary Kanai-Tajimi Model)

ฟังก์ชันความหนาแน่นสเปกตรัมกำลัง (Power Spectral Density Function: PSDF) เป็นฟังก์ชันที่ได้จากการกรองการเคลื่อนที่ของพื้นดินในระดัที่รุนแรง (Strong Ground Motion) ซึ่งมีแหล่งต้นกำเนิดที่ชั้นหิน (Bedrock) และแพร่กระจายผ่านชั้นดิน (Soil Layer) ทั้งนี้ ฟังก์ชันความหนาแน่นสเปกตรัมกำลังแบบเสถียร (Stationary PSDF:  $S(\omega)$ ) สามารถนิยามได้ดังนี้ [19,20]

$$S(\omega) = S_0 \frac{\omega_g^4 + 4\eta_g^2 \omega_g^2 \omega^2}{(\omega_g^2 - \omega^2)^2 + 4\eta_g^2 \omega_g^2 \omega^2} \quad (35)$$

โดยที่  $S_0$  คือ ความเข้มข้นของ PSDF ที่ระดับของชั้นหิน  $\eta_g$  คือ ความหน่วงของดิน (Soil Damping)  $\omega$  คือ ความถี่และ  $\omega_g$  คือ ความถี่ธรรมชาติของดิน (Natural Frequency of Soil)

#### 3.2 แบบจำลองวิวัฒนาการและไม่เสถียรของฟังก์ชันความหนาแน่นสเปกตรัมกำลัง (Non-stationary and Evolutionary Models of PSDF)

ฟังก์ชันความหนาแน่นสเปกตรัมกำลังแบบไม่เสถียร (Non-stationary PSDF) ของความเร่งที่ระดับพื้นดิน (Ground Acceleration) หาได้จากการประยุกต์ฟังก์ชันปรับค่า (Modulation Function:  $A(t, \omega)$ ) กับฟังก์ชันความหนาแน่นสเปกตรัมกำลังแบบเสถียร  $S(\omega)$  ซึ่งนิยามได้เป็น

$$S(t, \omega) = |A(t, \omega^2)| S(\omega) \quad (36)$$

โดยที่  $S(t, \omega)$  คือ ฟังก์ชันความหนาแน่นสเปกตรัมกำลังแบบไม่เสถียร  $S(\omega)$  คือ ฟังก์ชันความหนาแน่นสเปกตรัมกำลังที่ให้ไว้ในสมการ (35) และ  $t$  คือ เวลา

เมื่อฟังก์ชันปรับค่า  $A(t, \omega)$  เป็นฟังก์ชันที่สามารถทำการแยกส่วนได้ (Separable Function) ของเวลา (Time) และความถี่ (Frequency) จึงทำให้สมการ (36) สามารถทำการลดรูปไปสู่กระบวนการสุ่มแบบไม่เสถียร ด้วยการปรับค่าอย่างสม่ำเสมอ (Uniformly Modulated Non-stationary Random Process) โดยกระบวนการนี้แสดงถึงคุณลักษณะที่ไม่แปรเปลี่ยนของฟังก์ชันความหนาแน่นสเปกตรัมกำลัง (Invariant PSDF) ที่มีค่าคงที่ทุกขณะเวลา ดังนั้นแล้ว การวิเคราะห์สามารถเป็นไปตามกระบวนการเดียวกันกับกระบวนการสุ่มแบบเสถียร (Stationary Stochastic Process)

สำหรับฟังก์ชันปรับค่าที่มีการประยุกต์ใช้กันอย่างกว้างขวางมีรูปแบบดังต่อไปนี้

$$A(t, \omega) = A_0 \left[ e^{-\alpha t} - e^{\beta t} \right] e^{-r\omega/\omega_m t_m} \quad (37)$$

เมื่อ  $A_0, \alpha, \beta, r, \omega_m, t_m$  เป็นค่าคงที่และจากสมการ (37) สามารถสังเกตได้ว่าเป็นฟังก์ชันที่แปรเปลี่ยนตามเวลา (Time Variant)

ในการศึกษานี้ ได้ทำการประยุกต์ใช้ฟังก์ชันความหนาแน่นสเปกตรัมกำลังดังแสดงในสมการ (35) และ (36) ร่วมกับการใช้ฟังก์ชันปรับค่าที่ได้จากสมการ (37) มาสร้างกระบวนการสุ่มแบบไม่เสถียร (Non-stationary Stochastic Process)

### 3.3 การจำลองกระบวนการเคลื่อนที่ของพื้นดินแบบไม่เสถียร (Simulation of Non-stationary Ground Motion Processes)

ระเบียบวิธีในการจำลองกระบวนการเคลื่อนที่ของพื้นดินสามารถสรุปได้ดังนี้คือ

#### 3.3.1 การแทนสเปกตรัมของกระบวนการสุ่มแบบไม่เสถียร (Spectral Representation of Non-stationary Stochastic Process)

โดยอาศัยพื้นฐานการแทนสเปกตรัมวิวัฒนาการของกระบวนการสุ่มแบบไม่เสถียรตามทฤษฎีของ Priestley [21,22] สำหรับกรณีของตัวแปรเดียวใน 1 มิติ (Uni-variate and One Dimension) ทำให้สามารถหาตัวแทนอนุกรมเวลา (Time Series Representation) ได้เป็น

$$f_0(t) = \sqrt{2} \sum_{k=0}^{\infty} \sqrt{2S_{f_0 f_0}(t, \omega_k) \Delta\omega} \cos(\omega_k t + \phi_k) \quad (38)$$

#### 3.3.2 การจำลองกระบวนการสุ่มแบบไม่เสถียร (Simulation of Non-stationary Stochastic Process)

เมื่อพิจารณาตัวแทนอนุกรมอนันต์ (Infinite Series Representation) ของเวลาในสมการ (38) ที่ได้จากกระบวนการสุ่มแบบไม่เสถียรสามารถทำการจำลองได้ด้วยสูตร

$$f(t) = \sqrt{2} \sum_{n=0}^{N-1} \sqrt{2S_{f_0 f_0}(t, \omega_n) \Delta\omega} \cos(\omega_n t + \phi_n) \quad (39)$$

$$\omega_n = n\Delta\omega; \quad n = 0, 1, \dots, N-1 \quad (40)$$

และ

$$\Delta\omega = \omega_u / N \quad (41)$$

ทั้งนี้  $\omega_u$  เป็นตัวแทนของการตัดค่าความถี่ด้านบน (Upper Cut-off Frequency) ซึ่งหาค่ามาได้ตามข้อกำหนดของความแม่นยำ (Precision Requirement) และเมื่อความถี่พ้นค่าของ  $\omega_u$  ดังกล่าวไปแล้วทำให้ฟังก์ชันความหนาแน่นสเปกตรัมกำลังวิวัฒนาการ (Evolutionary Power Spectral Density Function) สามารถสมมติให้มีค่าเท่ากับศูนย์

$$S_{f_0 f_0}(t, \omega) = 0 \quad (42)$$

ดังตัวอย่างเช่น กำหนดให้  $\omega_u$  ในสมการ (41) มีค่าคงที่ ดังนั้นแล้ว  $\Delta\omega$  มีค่าเข้าใกล้ศูนย์ ( $\Delta\omega \rightarrow 0$ ) เมื่อ  $N$  เข้าใกล้ค่าอนันต์ ( $N \rightarrow \infty$ ) สำหรับค่าของ  $\phi_n$  คือ ค่ามุมที่กำหนดตำแหน่งบนคลื่นขณะเคลื่อนที่แบบสุ่ม (Random Phase Angles) และกระจายสม่ำเสมออยู่ในช่วง  $[0, 2\pi]$

### 3.4 โครงสร้างในระนาบ 2 มิติ ภายใต้แรงแผ่นดินไหว

บนหลักการพื้นฐานของทฤษฎีการประมาณสากล้น ANN ทำหน้าที่เป็นฟังก์ชันการส่งถ่าย (Mapping Function) ของการกระตุ้นที่พื้นดินแบบไม่เสถียรและเป็นแบบสุ่มจากเวลา  $t_0$  ไปสู่เวลา  $t_n$  เพื่อใช้ในการทำนายผลการตอบสนองพลวัต (Dynamic Response) อาทิเช่น การเปลี่ยนแปลงตำแหน่งหรือการกระจัด (Displacement) ณ เวลา  $t_n$  ใดๆ ดังนี้

$$X(t_n) = ANN(A_g(t_0), A_g(t_1), \dots, A_g(t_n)) \quad (43)$$

เมื่อ  $ANN(\cdot)$  คือ แบบจำลองของเครือข่ายประสาทเทียมซึ่งทำหน้าที่เป็นฟังก์ชันการส่งถ่ายชุดข้อมูลนำเข้าต่างๆ  $\{A_g(t_0), A_g(t_1), \dots, A_g(t_n)\}$  ไปสู่ข้อมูลส่งออก  $X(t_n)$

สำหรับการประยุกต์เครือข่ายประสาทเทียมมาเป็นแบบจำลองตัวแทน (Surrogate Model) สามารถได้รับจากขั้นตอนต่างๆ ดังต่อไปนี้

- (1) กำหนดสถาปัตยกรรมของเครือข่ายประสาทเทียม โดยการศึกษาใช้เครือข่ายประสาทเทียมแบบป้อนข้อมูลไปข้างหน้า 3 ชั้น (Three-Layer Feed-Forward ANN) ประกอบไปด้วย ชั้นข้อมูลนำเข้า ชั้นข้อมูลซ่อนเร้น และชั้นข้อมูลส่งออก ทั้งนี้ จำนวนของชั้นข้อมูลซ่อนเร้นจำกัดให้มีค่าเท่ากับ 1 ชั้น และให้จำนวนของเซลล์ประสาทในชั้นซ่อนเร้นนี้มีค่าเท่ากับ  $N_h$
- (2) สร้างการกระตุ้นที่ระดับพื้นดินแบบสุ่มจำนวน  $N$  ตัวอย่างที่มีความสอดคล้องตามกรรมวิธีที่ได้อธิบายไว้ในหัวข้อที่ 3.1 ถึงหัวข้อที่ 3.3
- (3) นำเข้าข้อมูลจากการสร้างการกระตุ้นที่มีจำนวน  $N$  ตัวอย่าง เข้าสู่แบบจำลองไฟไนท์เอลเมนต์ (FE Model) เพื่อคำนวณหาผลการตอบสนองพลวัตที่ต้องการ (Desired Dynamic Responses) ในที่นี้ จำนวนของผลการตอบสนองทั้งหมดมีจำนวนเท่ากับ  $N$
- (4) แบ่งการกระตุ้นที่สร้างมาแล้วจำนวน  $N$  ตัวอย่างและมีความสอดคล้องตามผลการตอบสนองออกเป็น 2 กลุ่ม โดยกลุ่มแรกประกอบไปด้วยกลุ่มตัวอย่างที่ได้รับการฝึกสอน  $N_{train}$  ตัวอย่าง จากการสร้างการกระตุ้นและสอดคล้องตามผลการตอบสนองซึ่งกลุ่มนี้เรียกว่า กลุ่มที่ได้รับการฝึกสอน (Training Group) อีกกลุ่มคือ กลุ่มทดสอบ (Testing Group) ประกอบไปด้วยการสร้างการกระตุ้นจำนวน  $N_{test}$  ตัวอย่าง และสอดคล้องตามผลการตอบสนองเช่นกัน โดยที่  $N_{train} + N_{test} = N$
- (5) ใช้ชุดตัวอย่างที่ได้รับการฝึกสอนจำนวน  $N_{train}$  ตัวอย่างและสอดคล้องตามผลการตอบสนองพลวัตจาก FE Model มาเป็นข้อมูลนำเข้าและข้อมูล

ส่งออกใน ANN เพื่อใช้ในการฝึกสอนด้วยขั้นตอนการแพร่ย้อนกลับ (BP Algorithm)

(6) นำเข้าข้อมูลจากการกระตุ้นจำนวน  $N_{test}$  ตัวอย่าง เข้าสู่ ANN ที่ได้รับการฝึกสอนและคำนวณหาผลการตอบสนองจาก ANN


(7) คำนวณค่าความคลาดเคลื่อนสัมพัทธ์สัมบูรณ์ (Absolute Relative Error:  $\varepsilon$ ) จากสมการ

$$\varepsilon = \frac{1}{N_{test}} \sum_{i=1}^{N_{test}} \left| \frac{X_{FEM,i} - X_{ANN,i}}{X_{ANN,i}} \right| \quad (44)$$

โดยที่  $X_{FEM,i}$  คือ การเปลี่ยนตำแหน่งที่ได้จากวิธีการไฟไนท์เอลเมนต์รอบที่  $i$  และ  $X_{ANN,i}$  คือ การเปลี่ยนตำแหน่งที่ได้จาก ANN รอบที่  $i$

(8) ทำการแปรเปลี่ยนจำนวนของ  $N_h$  และเลือกจำนวนของ  $N_h$  ที่มีค่า  $\varepsilon$  น้อยที่สุด

สำหรับตัวอย่างการประยุกต์ใช้แบบจำลอง ANN และการคำนวณเชิงตัวเลขเริ่มจากพิจารณาระบบพลวัตเชิงเส้นของโครงสร้างโครงข้อแข็งรับแรงเฉือน (Linear Dynamic System of Shear Frame Structure) ที่อยู่ภายใต้ผลของการกระตุ้นแบบไม่เสถียร ดังแสดงในรูปที่ 4 (ซ้าย)



รูปที่ 4 โครงสร้างโครงข้อแข็งรับแรงเฉือน

โครงข้อแข็งในรูปที่ 4 เมื่ออยู่ภายใต้ผลของการสั่นสะเทือนแผ่นดินไหว ส่งผลทำให้เกิดการกระตุ้นด้วยอัตราเร่งในแนวราบที่ระดับพื้นดินแบบไม่เสถียรและเป็นแบบสุ่ม  $A_g(t)$  และกระทำที่ฐานของโครงสร้าง ดังนั้นจึงพิจารณาสมดุลพลวัตเชิงเส้นเป็นแบบง่ายที่มี 3 องศาอิสระ (Simplified 3-DOF Linear Dynamic Equilibrium) ดังแสดงในรูปที่ 4 (ขวา) และสมการของการเคลื่อนที่ (Equation of Motion) ของระบบคือ

$$\mathbf{M}\ddot{\mathbf{X}} + \mathbf{C}\dot{\mathbf{X}} + \mathbf{K}\mathbf{X} = -\mathbf{A}_g\mathbf{M}\mathbf{\Gamma} \quad (45)$$

เมื่อ  $\mathbf{M}$  คือ แมทริกซ์มวล (Mass Matrix)  $\mathbf{C}$  คือ แมทริกซ์ความหน่วง (Damping Matrix)  $\mathbf{K}$  คือ แมทริกซ์ความแกร่ง (Stiffness Matrix)  $\mathbf{X}$  คือ แมทริกซ์การกระจัด (Displacement Matrix)  $\dot{\mathbf{X}}$  คือ แมทริกซ์ความเร็ว (Velocity Matrix) และ  $\ddot{\mathbf{X}}$  คือ แมทริกซ์ความเร่ง (Acceleration Matrix) สำหรับพจน์ของแมทริกซ์  $\mathbf{\Gamma}$  นิยามได้เป็น

$$\mathbf{\Gamma} = [1 \quad 1 \quad 1]^T \quad (46)$$

ในส่วนของคุณค่าแมทริกซ์  $\mathbf{M}$   $\mathbf{C}$  และ  $\mathbf{K}$  ที่ปรากฏในสมการ (45) และใช้ในการศึกษานี้คือ

$$\mathbf{M} = \begin{bmatrix} 100 & 0 & 0 \\ 0 & 100 & 0 \\ 0 & 0 & 100 \end{bmatrix} \quad (47)$$


$$\mathbf{C} = \begin{bmatrix} 2500 & -2500 & 0 \\ -2500 & 3500 & -1000 \\ 0 & -1000 & 3000 \end{bmatrix} \quad (48)$$

$$\mathbf{K} = \begin{bmatrix} 1.0e7 & -1.0e7 & 0 \\ -1.0e7 & 1.5e7 & -0.5e7 \\ 0 & -0.5e7 & 1.0e7 \end{bmatrix} \quad (49)$$


ทั้งนี้ สมการ (45) คือ สมการไฟไนท์เอลเมนต์ในสมดุลของแรงพลวัต (Dynamic Force Equilibrium Finite Element Equation) ที่สอดคล้องตามแบบจำลองแบบง่าย (Simplified Model) ดังในรูปที่ 4 (ขวา) โดยมีองค์ประกอบของแมทริกซ์ต่างๆ ตามนิยามไว้ในสมการ (46) ถึงสมการ (49) ที่ได้มาจากการใช้เอลเมนต์เชิงเส้นใน 1 มิติอย่างง่าย (Simple 1-D Linear Element) ที่มีจำนวน 3 เอลเมนต์เป็นตัวแทนในแบบจำลองโครงสร้างจริงในรูปที่ 4 (ขวา) โดยใน 1 เอลเมนต์ มี 2 จุดขั้ว (2 Nodes) ที่ปลายของเอลเมนต์และในแต่ละจุดขั้ว มี 1 องศาอิสระ (1-DOF) ที่อยู่ในแนวตั้งฉากกับแนวแกนของเอลเมนต์

พิจารณาพจน์  $A_g$  ทางขวามือในสมการ (45) ซึ่งสามารถคำนวณหาได้จากการกำหนดค่าพารามิเตอร์เริ่มต้นต่างๆ ตามสมการที่ได้ให้ไว้ในหัวข้อย่อยที่ 3.1 ถึงหัวข้อที่ 3.3 ในที่นี้  $S_0 = 0.001$ ,  $\omega_g = 15$ ,  $\eta_g = 0.25$ ,  $A_0 = 2.87$ ,  $\alpha = 0.13$ ,  $\beta = 0.35$ ,  $r = 1.0$ ,  $\omega_m = 1000$ ,  $t_m = 5$  และ  $\omega_n = 1000$

จำนวนตัวอย่างที่ใช้ในการสร้าง (Generation)  $A_g$  คือ 1000 ตัวอย่าง เป็นไปตามขั้นตอนที่ได้อธิบายไว้ก่อนหน้านี้ โดยในแต่ละตัวอย่างของการสร้าง  $A_g$  เริ่มต้นด้วยการพิจารณาจากเวลา  $t = 0$  ถึง  $t = 15$  sec ที่มีขนาดของขั้นเวลาเรื่อยๆ (Time Step Size) มีค่าเป็น  $dt = 0.05$  sec และกำหนดให้  $X_1(15)$ ,  $X_2(15)$  และ  $X_3(15)$  คือ ผลการตอบสนองที่กำลังให้ความสนใจ สำหรับรูปที่ 5 แสดงตัวอย่างหนึ่งของ  $A_g$  ที่ได้ทำการสร้างขึ้นมา (A Generated Realization of  $A_g$ )



รูปที่ 5 อัตราเร่งแบบไม่เสถียรที่ผิวดิน



รูปที่ 6 แบบจำลองตัวแทน ANN สำหรับการทำนายค่า  $X_i$  ( $i = 1, 2, 3$ )

เมื่อทำการสร้างตัวอย่างของ  $A_g$  ขึ้นมาแล้ว 1000 ตัวอย่าง จำนวนชุดของ  $A_g$  ที่มีจำนวน 700 ตัวอย่างได้ถูกนำมาใช้ในการฝึกสอน (Training ANN) ดังนั้นแล้วจึงใช้เป็นข้อมูลนำเข้าใน FE Model เพื่อใช้ในการหาผลการตอบสนองของ  $X_1(15)$ ,  $X_2(15)$  และ  $X_3(15)$  เช่นนี้แล้ว จำนวน 700 ตัวอย่างของ  $A_g$  ที่มีความสอดคล้องกับผลการตอบสนอง  $X_i(15)$  เมื่อ  $i = 1, 2, 3$  ที่ได้จาก FE Model จึงถูกนำกลับมาใช้เป็นข้อมูลนำเข้าและข้อมูลส่งออกในการวิเคราะห์ ANN โดยสถาปัตยกรรมทั่วไปของ ANN แสดงในรูปที่ 6 ซึ่งการคำนวณผลการตอบสนอง  $X_1(15)$ ,  $X_2(15)$  และ  $X_3(15)$  มีความแตกต่างกันไปเฉพาะตัวตามจำนวนของเซลล์ประสาทในชั้นซ่อนเร้น จำนวนตัวอย่าง  $A_g$  ที่เหลือ 300 ตัวอย่างจะใช้เป็นข้อมูลนำเข้าสู่ FE Model และ ANN และทำการคำนวณหาผลการตอบสนองที่สอดคล้องกันคือ  $X_1(15)$ ,  $X_2(15)$  และ  $X_3(15)$  ซึ่งตัวอย่าง  $A_g$  ทั้ง 300 ตัวอย่างนี้เรียกว่า ชุดตัวอย่างทดสอบ (Test Samples)

### 3.5 ผลการวิเคราะห์และอภิปรายผล

ผลลัพธ์ของผลการตอบสนองที่ได้มาคือ ผลจาก FE Model และผลจาก ANN Model ด้วยการใช้จำนวนเซลล์ประสาทในชั้นซ่อนเร้นเป็นจำนวน  $N_h$  ที่ให้ค่าความคลาดเคลื่อนสัมพัทธ์ที่น้อยที่สุด (Least Relative Error:  $\epsilon$ ) สำหรับในแต่ละผลการตอบสนองได้แสดงไว้ในตารางที่ 1 ทั้งนี้ ANN ที่มีจำนวนเซลล์ประสาทเท่ากับ  $N_h$  และมีความคลาดเคลื่อนสัมพัทธ์น้อยที่สุด ( $\epsilon$ ) นั้นได้รับการอ้างอิงให้เป็นเครือข่ายประสาทเทียมที่ดีที่สุด (Best ANN) ของชุดตัวอย่างที่ใช้ในการทดสอบ

เมื่อได้เครือข่ายประสาทเทียมที่ดีที่สุดสำหรับแต่ละผลการตอบสนอง  $X_i(15)$  โดยที่  $i = 1, 2, 3$  มาแล้วจะถูกนำมาใช้สำหรับการวิเคราะห์แบบสุ่ม (Stochastic Analysis) ด้วยวิธีการจำลองมอนติคาร์โล (MCS) ดังนั้นแบบจำลองมอนติคาร์โลได้ทำการประยุกต์ใช้กับตัวอย่างจำนวน 1000 ตัวอย่างของการสร้าง  $A_g$  ที่เป็นไปตามค่าพารามิเตอร์ที่ได้ระบุไว้ก่อนหน้านี้ โดยที่ตัวอย่างทั้งหมดได้นำเข้าสู่ FE Model และ ANN Model ที่ดีที่สุดเพื่อใช้ในการคำนวณหาค่าของแต่ละผลการตอบสนองเชิงพลวัตคือ  $X_1(15)$ ,  $X_2(15)$  และ  $X_3(15)$  สำหรับค่าความคลาดเคลื่อนสัมพัทธ์เฉลี่ย (Average Relative Error) จากผลการทำนายด้วย ANN เมื่อทำการเปรียบเทียบกับ FE Model แสดงไว้ในตารางที่ 2 นอกจากนี้ เนื่องจาก FE Model เป็นเครื่องมือมาตรฐานทั่วไปที่ใช้สำหรับการวิเคราะห์พลศาสตร์เชิงโครงสร้าง (Structural Dynamic Analysis) และใช้ในการเปรียบเทียบกับผลลัพธ์ที่ได้จาก ANN ในการศึกษาครั้งนี้ ดังนั้น ตารางที่ 3 แสดงผลการเปรียบเทียบเวลาที่ใช้ในการคำนวณผลการตอบสนองระหว่าง FE Model [23] และจาก ANN Model โดยเครื่องคำนวณที่ใช้มีศักยภาพดังนี้คือ 8GB

Ram with 9<sup>th</sup> Gen Intel<sup>®</sup> Core<sup>™</sup> i7 พบว่า เวลาที่ใช้ในการคำนวณจาก ANN Model ใช้เวลาน้อยกว่า FE Model ประมาณ 90 ถึง 170 เท่า นอกจากนี้ ได้มีการเปรียบเทียบผลการตอบสนองที่ได้จากแบบจำลองทั้งสองดังแสดงในรูปที่ 7 ถึง รูปที่ 9

ตารางที่ 1 จำนวนเซลล์ประสาทในชั้นซ่อนเร้นที่ให้ค่าความคลาดเคลื่อนสัมพัทธ์น้อยที่สุดสำหรับแต่ละผลการตอบสนองที่ได้จากชุดตัวอย่างทดสอบ


ผลการตอบสนอง	$N_h$	$\epsilon$
$X_1(15)$	6	0.005598
$X_2(15)$	8	0.008171
$X_3(15)$	9	0.004429

ตารางที่ 2 ความแม่นยำของเครือข่ายประสาทเทียมในการทำนายผลการตอบสนองแบบสุ่ม


ผลการตอบสนอง	ความคลาดเคลื่อนสัมพัทธ์เฉลี่ยจากการทำนาย
$X_1(15)$	0.008168
$X_2(15)$	0.005565
$X_3(15)$	0.038273

ตารางที่ 3 เวลาที่ใช้คำนวณโดยแบบจำลองไฟไนต์เอลิเมนต์ (FE Model) และแบบจำลองเครือข่ายประสาทเทียม (ANN Model)


ผลการตอบสนอง	FE Model (sec)	ANN Model (sec)	$t_{FE}/t_{ANN}$
$X_1(15)$	12.19565	0.07233	168.6112263
$X_2(15)$	12.07804	0.08031	150.3927282
$X_3(15)$	12.34142	0.13430	91.8944154



รูปที่ 7 การเปรียบเทียบค่า  $X_1(15)$  ที่ได้ระหว่างวิธี FEM และ ANN ที่ดีที่สุด



รูปที่ 8 การเปรียบเทียบค่า  $X_2(15)$  ที่ได้ระหว่างวิธี FEM และ ANN ที่ดีที่สุด



รูปที่ 9 การเปรียบเทียบค่า  $X_3(15)$  ที่ได้ระหว่างวิธี FEM และ ANN ที่ดีที่สุด

#### 4. บทสรุป

แบบจำลองเครือข่ายประสาทเทียมแบบป้อนข้อมูลไปข้างหน้าหลายชั้นได้รับการพัฒนาและเสนอเป็นแบบจำลองตัวแทนสำหรับการวิเคราะห์ระบบภายใต้การกระตุ้นแบบไม่เสถียร โดยการเรียนรู้ของเครือข่ายประสาทเทียมใช้ขั้นตอนของการแพร่ความคลาดเคลื่อนแบบย้อนกลับ ตัวอย่างของการคำนวณเชิงตัวเลขเป็นการประยุกต์กับระบบพลวัตเชิงเส้นที่มี 3 องศาอิสระ การกระตุ้นแบบไม่เสถียรเป็นการกระตุ้นที่พื้นดินในรูปแบบของคาอัตราร่างแบบไม่เสถียรและเป็นแบบสุ่มอันเนื่องจากผลของการสั่นสะเทือนแผ่นดินไหวซึ่งถูกจำลองด้วยแบบจำลองวิวัฒนาการและไม่เสถียรของฟังก์ชันความหนาแน่นสเปกตรัมกำลังโดยการใช้ออกุกรมเวลา ผลการตอบสนองแสดงในรูปแบบของการเปลี่ยนตำแหน่งของระบบ ณ เวลาใดๆ จากผลการศึกษาแสดงให้เห็นว่า เครือข่ายประสาทเทียมสามารถใช้วิเคราะห์ระบบพลวัตเชิงเส้นภายใต้การกระตุ้นแบบไม่เสถียรได้โดยให้ความแม่นยำในการคำนวณเทียบเท่ากับแบบจำลองไฟไนท์เอลเมนต์แต่มีประสิทธิภาพในเชิงเวลาของการคำนวณที่สูงกว่าอย่างมีนัยสำคัญ

#### เอกสารอ้างอิง

- [1] Nowak, A.S. and Collins, K.R. (2000). *Reliability of Structures*. McGraw-Hill, Boston.
- [2] Melchers, R.E. and Beck, A.Y. (2018). *Structural Reliability Analysis and Prediction*. 3<sup>rd</sup> Ed., John Wiley & Sons Ltd., Chennai.
- [3] Cardoso, J.B., de Almeida, J.R., Dias, J.M. and Coelho, P.G. (2008). Structural reliability analysis using Monte Carlo simulation and neural networks. *Advances in Engineering Software*, 39, pp. 505-513.
- [4] Harnpornchai, N., Chakpitak, N., Chandarasupsang, T., Chaikijjosi, T.A. and Dahal, K. (2007). Dynamic adjustment of age distribution in human resource management by genetic algorithms. *2007 IEEE Congress on Evolutionary Computation*, Singapore, 25-28 September 2007, pp. 1234-1239.
- [5] Paokanta, P., Harnpornchai, N. and Chakpitak, N. (2011). The classification performance of binomial logistic regression based on classical and Bayesian statistics for screening P-Thalassemia. *The 3<sup>rd</sup> International Conference on Data Mining*

- and Intelligent Information Technology Applications, IEEE (2011)*, Macao, China, 24-26 October 2011, 12443439.
- [6] Paokanta, P., Ceccarelli, M., Harnpornchai, N., Chakpitak, N. and Srichairatanakool, S. (2012). Rule induction for screening Thalassemia using machine learning techniques: C5.0 and CART. *ICIC Express Letters*, 6, pp. 301-306.
- [7] Paokanta, P. and Harnpornchai, N. (2012). Risk analysis of Thalassemia using knowledge representation model: diagnostic Bayesian networks. *Proceedings - IEEE-EMBS International Conference on Biomedical and Health Informatics: Global Grand Challenge of Health Informatics, BHI 2012*, Hong Kong, China, 5-7 January 2012, pp. 155-158.
- [8] Paokanta, P., Harnpornchai, N., Chakpitak, N., Srichairatanakool, S. and Ceccarelli, M. (2013). Knowledge and data engineering: Fuzzy approach and genetic algorithms for clustering  $\beta$  - Thalassemia of knowledge based diagnosis decision support system. *ICIC Express Letters*, 7, pp. 479-484.
- [9] Harnpornchai, N. and Wonggattaleekam, W. (2021). An application of neutrosophic set to relative importance assignment in AHP. *Mathematics*, 9, math9202636.
- [10] Harnpornchai, N. and Wonggattaleekam, W. (2022). A Nikaido Isoda-based hybrid genetic algorithm and relaxation method for finding Nash equilibrium. *Mathematics*, 10, math10010081.
- [11] Hornik, K. (1989). Multilayer feedforward networks are universal approximators. *Neural Networks*, 2, pp. 358-366.
- [12] Hornik, K. (1991). Approximation capabilities of multilayer feedforward networks. *Neural Networks*, 4, pp. 251-257.
- [13] Le, V. and Caracoglia, L. (2020). A neural network surrogate model for the performance assessment of a vertical structure subjected to non-stationary, tornadic wind loads. *Computers and Structures*, 231, 106208.
- [14] Cheng, X., Zhang, Z.-Y. and Shao, W. (2020). A surrogate model based on artificial neural networks for wave propagation in uncertain media. *IEEE Access*, 8, pp. 218323-218330.
- [15] Cheng, X., Shao, W., Wang, K. and Wang, B.Z. (2021). An ANN-based surrogate model for wave propagation in uncertain media. *Waves in Random and Complex Media*, <https://doi.org/10.1080/17455030.2021.1880669>.
- [16] Ziyadi, M. and Al-Qadi, I.L. (2017). Efficient surrogate method for predicting pavement response to various tire configurations. *Neural Computing and Applications*, 28, pp. 1355-1367.
- [17] Asteris, P.G. and Kolovos, K.G. (2019). Self-compacting concrete strength prediction using surrogate models. *Neural Computing and Applications*, 31, pp. 409-424.
- [18] Haykin, S. (2009). *Neural Networks and Learning Machines*. 3<sup>rd</sup> Edition. Pearson Education, Inc., Upper Saddle River, New Jersey.



- [19] Kanai, K. (1957). Semi-empirical formula for the seismic characteristics of the ground. *Bulletin of the Earthquake Research Institute*, 35, pp. 309-325.
- [20] Tajimi, H. (1960). A statistical method of determining the maximum response of a building during earthquake. *Proceedings of the 2<sup>nd</sup> World Conference on Earthquake Engineering*, Tokyo, Japan, 11-18 July 1960, 2, pp. 781-798.
- [21] Priestley, M.B. (1965). Evolutionary spectra and non-stationary processes. *Journal of the Royal Statistical Society: Series B (Methodological)*, 27, pp. 204-229.
- [22] Priestley, M.B. (1967). Power spectral analysis of non-stationary random processes. *Journal of Sound and Vibration*, 6, pp. 86-97.
- [23] Newmark, N.M. (1959). A method of computation for structural dynamics. *Journal of the Engineering Mechanics Division*, 85, pp. 67-94.