

ความเป็นไปได้สำหรับการคาดการณ์แผ่นดินไหวในประเทศไทยด้วยแบบจำลองโครงข่ายประสาทเทียม

Possible Earthquake Prediction In Thailand with Artificial Neural Network models

พรรณปพร บุญแปง^{1,2,*}, ทวี ชัยพิมลผลิน³

Phanpaporn Boonpaeng^{1,2,*}, Tawe Chaipimonplin³

Received: 17 November 2019 ; Revised: 1 April 2020 ; Accepted: 1 May 2020

บทคัดย่อ

ประเทศไทยยังไม่มีการศึกษาการคาดการณ์แผ่นดินไหวด้วยแบบจำลองโครงข่ายประสาทเทียมมาก่อน แต่เมื่อสืบค้นและรวบรวมสิ่งตีพิมพ์ต่างๆ จากฐานข้อมูลนานาชาติ พบว่ามีงานวิจัยในต่างประเทศได้ใช้แบบจำลองโครงข่ายประสาทเทียมสำหรับการคาดการณ์แผ่นดินไหว ดังนั้นบทความนี้จะเป็นการศึกษาความเป็นไปได้สำหรับการประยุกต์ใช้แบบจำลองโครงข่ายประสาทเทียมสำหรับการคาดการณ์แผ่นดินไหวในประเทศไทยโดยมีขอบเขตของการศึกษา 3 ประเด็น คือ รูปแบบการเกิดแผ่นดินไหวของประเทศไทย ศึกษาหาตัวแปรนำเข้าสู่ที่เหมาะสมสำหรับการคาดการณ์แผ่นดินไหวจากการทบทวนวรรณกรรม และศึกษาการออกแบบโครงสร้างของแบบจำลองโครงข่ายที่เหมาะสม ซึ่งพบว่า (1) รูปแบบการเกิดแผ่นดินไหวของประเทศไทยมีสาเหตุหลักจากการเคลื่อนตัวของแนวรอยเลื่อนมีพลัง รวมถึงมีขนาดความรุนแรง และอัตราการเกิดแผ่นดินไหวที่ใกล้เคียงกับงานวิจัยประเทศต่างๆ ที่ได้คาดการณ์แผ่นดินไหวโดยอาศัยโครงข่าย (2) ตัวแปรที่ได้จากสมการความสัมพันธ์ Gutenberg-Richter ถือเป็นตัวแปรนำเข้าสู่แบบจำลองที่มีการศึกษามากที่สุด โดยตัวแปรการคาดการณ์ที่นิยมศึกษามากที่สุด คือ การคาดการณ์ขนาดแผ่นดินไหว และ (3) การออกแบบโครงสร้างของแบบจำลองนิยมใช้โครงข่ายแบบ Feed Forward Neural Network ที่มีการเรียนรู้แบบ Back Propagation โดยจำนวนชั้นซ่อนเร้นที่ทำให้ผลลัพธ์การคาดการณ์แผ่นดินไหวมีความแม่นยำมากที่สุด คือ จำนวน 2 ชั้น สำหรับจำนวนโหนดของชั้นซ่อนเร้นพบว่าขึ้นอยู่กับจำนวนตัวแปรข้อมูลนำเข้าสู่ของแบบจำลองโครงข่าย

คำสำคัญ: แบบจำลองโครงข่ายประสาทเทียม การคาดการณ์แผ่นดินไหว

Abstract

Earthquake prediction with artificial neural network model (ANN) has never been studied in Thailand before. However, after searching research article from an international database, it has been found that there is a possibility of using the ANN model to predict earthquake in other countries. Therefore, this article reports on the possibility of predicting earthquakes with ANN in Thailand and collects earthquake data. The scope of this study includes three additional points; (1) The earthquake pattern in Thailand is mainly caused by the movement of active faults, also the magnitude of the earthquake and the increasing trend of earthquake rate, had a similar pattern of the occurrence in other countries when analyzing earthquake prediction with the artificial neural network model. (2) The input variables were obtained from the Gutenberg-Richter equation, which is the most input variables to be considered. The most popular output variable for earthquake prediction is the earthquake's magnitude. (3) The architectural structure design of the model mainly used Feed Forward Neural Network with Back Propagation learning. The number of hidden nodes with good performance is the ANN model with two hidden layers, also the number of hidden nodes depends on the input variables of ANN.

Keywords: Artificial Neural Network Model, Earthquake Prediction

¹ นักศึกษาปริญญาโท, ภาควิชาภูมิศาสตร์ คณะสังคมศาสตร์ มหาวิทยาลัยเชียงใหม่ 50200, ประเทศไทย

² นักศึกษาปริญญาโท, บัณฑิตวิทยาลัย มหาวิทยาลัยเชียงใหม่ 50200, ประเทศไทย

³ ผู้ช่วยศาสตราจารย์, ภาควิชาภูมิศาสตร์ คณะสังคมศาสตร์ มหาวิทยาลัยเชียงใหม่ 50200, ประเทศไทย

¹ Master degree student, Department of Geography, Faculty of Social Sciences, Chiang Mai University, 50200, Thailand

² Master degree student, Graduate School, Chiang Mai University, 50200, Thailand

³ Assistant Professor, Department of Geography, Faculty of Social Sciences, Chiang Mai University, 50200, Thailand

* Corresponding author: phanpaporn.b@gmail.com, Tel: 091-1435426

บทนำ

แผ่นดินไหวเป็นปรากฏการณ์ธรรมชาติที่เกิดจากการเคลื่อนตัวโดยฉับพลันของแผ่นเปลือกโลก เนื่องจากได้รับพลังงานความร้อนจากแกนโลก และมีการลอยตัวดันเปลือกโลกตลอดเวลาของชั้นหินหลอมละลาย เพื่อลดความเครียดสะสมภายใน ส่งผลให้เปลือกโลกเกิดการเคลื่อนที่ในทิศทางต่างๆ ซึ่งถึงแม้จะเกิดขึ้นไม่บ่อยครั้ง แต่เมื่อเกิดขึ้นแล้วสามารถสร้างความเสียหายต่อโครงสร้างอาคารบ้านเรือน รวมทั้งสร้างความสูญเสียต่อชีวิต และทรัพย์สิน ดังนั้นการเตรียมการก่อนเกิดแผ่นดินไหวจึงเป็นสิ่งสำคัญในการลดความเสียหาย และผลกระทบที่จะเกิดขึ้น

ในช่วงหลายปีที่ผ่านมา การศึกษาการคาดการณ์เหตุการณ์แผ่นดินไหว ถือเป็นประเด็นที่ทำนายต่อนักวิจัยเนื่องจากมีปัจจัย และกระบวนการเกิดที่ซับซ้อน จึงได้มีการพยายามศึกษา และวิเคราะห์เหตุการณ์ผิดปกติต่างๆ ที่เกี่ยวข้องกับการเกิดแผ่นดินไหว เช่น การเปลี่ยนแปลงระดับน้ำใต้ดินความ¹ ผิดปกติของแม่เหล็กไฟฟ้า² ความแปรปรวนของชั้นบรรยากาศ³ ความผิดปกติในการก่อตัวของเมฆ⁴ ความผิดปกติของปริมาณก๊าซเรดอน⁵ ความผิดปกติของพฤติกรรมสัตว์⁶ เป็นต้น รวมถึงการวิเคราะห์ข้อมูลเหตุการณ์แผ่นดินไหวที่เกิดขึ้นในอดีตจากเครื่องมือตรวจวัด เช่น การแจกแจงความน่าจะเป็นแบบปัวซอง⁷ แต่เนื่องจากปัจจัยต่างๆ ที่บ่งบอกถึงศักยภาพในการเกิดแผ่นดินไหวมีความซับซ้อน และมีความสัมพันธ์การเกิดแผ่นดินไหวที่ไม่ชัดเจน ส่งผลให้การศึกษาสัญญาณเตือน (Precursor) ก่อนเกิดแผ่นดินไหว รวมถึงการศึกษาทางคณิตศาสตร์และสถิติ ไม่สามารถวิเคราะห์ถึงสาเหตุและกลไกที่มีความสัมพันธ์แบบไม่เป็นเชิงเส้นได้⁸ จึงมีการเสนอวิธีการศึกษาโดยอาศัยเทคนิคทางด้านปัญญาประดิษฐ์ (Artificial Intelligence: AI)⁹ เนื่องจากมีหลักการทำงานคล้ายกับสมองมนุษย์ เช่น การตัดสินใจ การแก้ปัญหา การเรียนรู้ เป็นต้น โดย AI แบ่งได้เป็น ขั้นตอนวิธีเชิงพันธุกรรม (Genetic Algorithm) ตรรกศาสตร์คลุมเครือ (Fuzzy System) และโครงข่ายประสาทเทียม (Artificial Neural Networks: ANN) ซึ่ง ANN ถือเป็นระบบปัญญาประดิษฐ์ประเภทหนึ่งที่มีการเรียนรู้แบบแพทเทิร์น (pattern) สามารถเรียนรู้ความสัมพันธ์ของข้อมูลต่างๆ ผ่านประสบการณ์ที่ได้รับจากข้อผิดพลาดของผลลัพธ์ อีกทั้งยังสามารถอนุมานรูปแบบและตรวจสอบแนวโน้มการเกิดที่มนุษย์ไม่สามารถรับรู้ได้¹⁰ จึงเป็นวิธีการศึกษาที่เป็นไปได้สำหรับการคาดการณ์แผ่นดินไหว ส่งผลให้การศึกษาด้านปัญญาประดิษฐ์ได้รับความสนใจ และมีการพัฒนาอย่างต่อเนื่อง รวมถึงมีการนำกระบวนการเรียนรู้ประเภทต่างๆ มาศึกษาเปรียบเทียบประสิทธิภาพการคาดการณ์แผ่นดินไหว เช่น ประเทศชิลีได้เปรียบเทียบการคาดการณ์แผ่นดินไหวในแต่ละเมือง โดยใช้ ANN, K-Nearest

Neighbors (KNN), Support Vector Machines (SVM) และ K-means พบว่า ANN มีประสิทธิภาพในการคาดการณ์มากที่สุด โดยมีค่าความถูกต้องในการคาดการณ์แผ่นดินไหวในเมืองตัลกา, ปิซิเลมู, ซานเตียโก และ บัลปารายโซเป็น 49.86%, 78.6%, 65.7% และ 74.7% ตามลำดับ¹¹ เช่นเดียวกับประเทศญี่ปุ่นได้ศึกษาเปรียบเทียบการคาดการณ์ ANN, KNN, SVM, Naive Bayes (NB) และ Decision trees พบว่า ANN ให้ผลลัพธ์ในการคาดการณ์ที่ดีที่สุด โดยมีค่าความถูกต้องมากกว่า 70%¹² จากการศึกษาแสดงให้เห็นว่า ANN มีความแม่นยำในการคาดการณ์มากกว่ากระบวนการเรียนรู้อื่นๆ ซึ่งถือเป็นเครื่องมือสำคัญที่สามารถเข้าใจถึงกระบวนการเกิดแผ่นดินไหวที่มีกลไกและสาเหตุการเกิดที่ซับซ้อน ดังนั้นบทความนี้จึงได้รวบรวมข้อมูล และเอกสารที่เกี่ยวข้องกับการคาดการณ์แผ่นดินไหวด้วย ANN เพื่อหาแนวโน้มความเป็นไปได้ในการคาดการณ์แผ่นดินไหวในประเทศไทย และเพื่อเป็นประโยชน์ในการออกแบบแบบจำลองสำหรับคาดการณ์แผ่นดินไหว โดยไม่ได้เน้นระเบียบวิธีวิจัย และขั้นตอนในการศึกษา

จากการรวบรวมและค้นคว้าการศึกษาการคาดการณ์แผ่นดินไหวโดยอาศัย ANN จากฐานข้อมูลวิทยานิพนธ์ไทย และฐานข้อมูลนานาชาติ (Scienedirect และ Scopus) โดยใช้คำสืบค้น "Artificial Neural Network" และ "Earthquake" ซึ่งสืบค้นได้จากชื่อเรื่อง บทคัดย่อ และคำสำคัญ พบว่าจำนวนงานวิจัยที่เกี่ยวข้องกับการใช้ ANN ในการคาดการณ์แผ่นดินไหว จำนวน 38 บทความ สามารถแบ่งพื้นที่ศึกษาได้ 13 ประเทศ โดยประเทศอินเดียมากที่สุด คือ จำนวน 6 บทความ อันดับรองลงมาคือ ประเทศสหรัฐอเมริกา จำนวน 5 บทความ ประเทศอิหร่าน และจีน จำนวน 4 บทความ ประเทศตุรกี ปากีสถาน ชิลี จำนวน 3 บทความ ส่วนประเทศกรีซ อังกฤษ แคนาดา อังการี อิตาลี ญี่ปุ่น พบเพียง 1 บทความ และเป็นบทความทบทวนวรรณกรรม จำนวน 3 บทความ

ประเภทการคาดการณ์แผ่นดินไหว

โดยทั่วไปเป้าหมายหลักในการคาดการณ์แผ่นดินไหว แบ่งได้เป็น 3 ประเภท คือ เวลา (จะเกิดแผ่นดินไหวเมื่อเวลาใด) สถานที่ (ตำแหน่งพิกัดที่คาดว่าจะเกิดแผ่นดินไหว) และขนาดแผ่นดินไหว (ขนาดความรุนแรงของระดับแผ่นดินไหวที่จะเกิดขึ้น) ดังนั้นการคาดการณ์แผ่นดินไหวจึงขึ้นอยู่กับข้อมูลที่นำมาวิเคราะห์ประกอบด้วยข้อมูลสัญญาณผิดปกติ ก่อนเกิดแผ่นดินไหว รวมถึงข้อมูลเหตุการณ์แผ่นดินไหวที่เกิดขึ้นในอดีต ซึ่งในปัจจุบันสามารถแบ่งวิธีการคาดการณ์แผ่นดินไหวได้เป็น 3 ประเภท¹³ ดังนี้

การศึกษาสัญญาณเตือนก่อนเกิดแผ่นดินไหว

เป็นการคาดการณ์เหตุการณ์แผ่นดินไหวโดยอาศัยการสังเกต และวิเคราะห์ความสัมพันธ์ของการเปลี่ยนแปลง

ทางธรณีฟิสิกส์ทางกายภาพ เนื่องจากช่วงเวลาก่อนเกิดแผ่นดินไหว มักมีรายงานการเกิดปรากฏการณ์ รวมถึงความผิดปกติต่างๆ เช่น ความผิดปกติของสนามแม่เหล็กไฟฟ้าในประเทศจีน ได้มีการออกแบบฮาร์ดแวร์ของเครื่องตรวจวัดแผ่นดินไหวให้มีโปรแกรมเตรียมข้อมูลก่อนประมวลผลซึ่งเป็นส่วนสำคัญ รวมถึงมีการใช้เข็มทิศอิเล็กทรอนิกส์ในการวิเคราะห์ผลการศึกษาแสดงให้เห็นว่ามอเซอิมูทบริเวณจุดศูนย์กลางของสนามแม่เหล็กมีความผิดปกติในช่วงเวลาไม่กี่นาทีจนถึงหลายวันก่อนเกิดแผ่นดินไหวขนาด 5 แมกนิจูดขึ้นไป⁵ และการศึกษาการรบกวนของชั้นไอโอโนสเฟียร์ ซึ่งถือเป็นชั้นบรรยากาศของโลกที่ไอออนและอิเล็กตรอนอิสระมีความเข้มข้นสูง โดยใช้เครื่องส่งสัญญาณ VLF (Very Low Frequency) พบว่าชั้นบรรยากาศไอโอโนสเฟียร์ จะลดลงในช่วงก่อนเกิดแผ่นดินไหว เนื่องจากมีการเปลี่ยนแปลงช่วงความกว้างของคลื่น และความยาวของทางเดินแสง ดังนั้นความแปรปรวนของชั้นบรรยากาศ ไอโอโนสเฟียร์ถือเป็นสัญญาณผิดปกติก่อนเกิดแผ่นดินไหว ซึ่งมีความสัมพันธ์กับแผ่นดินไหวขนาดใหญ่ และเป็นแผ่นดินไหวระดับตื้น (มีจุดกำเนิดอยู่ลึกไม่เกิน 70 กิโลเมตร)³ และการศึกษาความผิดปกติของเมฆในประเทศอิตาลี จากการสังเกตการก่อตัวของเมฆในระยะเวลา 4 ปี รวมถึงวิเคราะห์จากภาพดาวเทียมทุกๆ 1 ชั่วโมง เพื่อตรวจสอบการเคลื่อนไหวของเมฆ โดยความผิดปกติของเมฆมักแสดงรูปแบบเชิงเส้น และไม่เคลื่อนที่ไปตามลมเป็นเวลาหลายชั่วโมง โดยคาดการณ์แผ่นดินไหวขนาด 5.5-6.0 แมกนิจูด ผลการศึกษาพบว่าไม่สามารถคาดการณ์ตำแหน่งจุดศูนย์กลางแผ่นดินไหวได้ เนื่องจากพื้นที่ความผิดปกติของเมฆมีขนาดใหญ่ (200 กิโลเมตร) จึงจำเป็นต้องรวบรวมข้อมูลอื่นๆ เพิ่มเติมในการวิเคราะห์ ได้แก่ ข้อมูลธรณีฟิสิกส์ ข้อมูลน้ำใต้ดิน และก๊าซเรดอน เพื่อเพิ่มความแม่นยำในการคาดการณ์⁴

นอกจากนี้มีการศึกษาความสัมพันธ์ระหว่างก๊าซเรดอนในช่วงก่อนเกิดแผ่นดินไหวบริเวณทางตอนเหนือของประเทศปากีสถาน พบแผ่นดินไหว 5 เหตุการณ์ในพื้นที่ศึกษา โดยมีเพียง 2 เหตุการณ์ (ขนาด 5.5 แมกนิจูด) ที่มีความสัมพันธ์กับผลกระทบของการแปรสัณฐานของก๊าซเรดอน โดยความแปรปรวนเกิดขึ้นในช่วงสองเดือนสุดท้ายของการศึกษาจากการวิเคราะห์แสดงให้เห็นว่าก๊าซเรดอนมีความสัมพันธ์เชิงบวกกับความดันอากาศ ในขณะที่มีความสัมพันธ์เชิงลบกับอุณหภูมิ⁶ และการศึกษาพฤติกรรมสัตว์ในประเทศญี่ปุ่น ได้สำรวจพฤติกรรมสัตว์ก่อนแผ่นดินไหวขนาด 9.0 แมกนิจูดในปี ค.ศ. 2011 จากแบบสอบถาม พบว่าไม่กี่ชั่วโมงก่อนเกิดแผ่นดินไหวสัตว์เลี้ยงมีพฤติกรรมผิดปกติ โดยเฉพาะบริเวณที่อยู่ใกล้จุดศูนย์กลางแผ่นดินไหวสัตว์จะแสดงพฤติกรรมที่ผิดปกติชัดเจนมากขึ้น เช่นเดียวกับการสำรวจบริเวณโรงรีดนมวัวซึ่งอยู่ห่างจากจุดศูนย์กลางแผ่นดินไหว 340 กิโลเมตร

พบว่าผลผลิตนมวัวลดลงประมาณหนึ่งสัปดาห์ก่อนเกิดแผ่นดินไหว เนื่องจากการเปลี่ยนแปลงทางกายภาพหรือทางเคมีส่งผลให้สัตว์เกิดความเครียดหรือมีอาการกลัวเกิดขึ้น แล้วจึงแสดงพฤติกรรมที่ผิดปกติออกมา⁷

การศึกษาโดยวิธีทางคณิตศาสตร์และสถิติ

การวิเคราะห์แบบจำลองทางคณิตศาสตร์จากข้อมูลแผ่นดินไหวที่บันทึกจากสถานีตรวจวัดในช่วงเวลา 20 ปี ของพื้นที่ศึกษา ได้แก่ แคลิฟอร์เนีย อเมริกากลาง สหรัฐอเมริกา ฮาวาย ตุรกี และญี่ปุ่น ประกอบด้วยข้อมูลละติจูด ลองจิจูด และขนาดแผ่นดินไหว โดยการใช้การแจกแจงความน่าจะเป็นแบบปัวซอง (Poisson distribution) และแบบจำลองการเชื่อมโยงเชิงพื้นที่ เพื่อเพิ่มประสิทธิภาพในการคาดการณ์ตำแหน่งที่เกิดแผ่นดินไหว พบว่าในแคลิฟอร์เนียผลการคาดการณ์ห่างจากตำแหน่งแผ่นดินไหวจริง 60 กิโลเมตร ในอเมริกากลางห่างจากแผ่นดินไหวจริง 100 กิโลเมตร ส่วนการคาดการณ์แผ่นดินไหวในญี่ปุ่น และตุรกีอยู่ห่างจากแผ่นดินไหวจริง 20 และ 6 กิโลเมตร ตามลำดับ⁷

นอกจากนี้ได้มีการพัฒนาวิธีการ PI (Pattern Informatics) เพื่อลดข้อผิดพลาดการคาดการณ์ตำแหน่งของแผ่นดินไหวที่มีขนาด ≥ 5 แมกนิจูด ในช่วงปี ค.ศ.2000-2009 บริเวณตอนกลางของประเทศญี่ปุ่น โดยกำหนดให้ค่า IP สูงบริเวณตำแหน่งที่เป็นไปได้ในการเกิดแผ่นดินไหว และลดค่า PI ในบริเวณที่ไม่สอดคล้องในการเกิดแผ่นดินไหว จากการทดสอบค่าสถิติ 3 วิธี ได้แก่ แผนภาพ Molchan แผนภาพ ROC และ log-likelihood พบว่ามีผลการคาดการณ์มีประสิทธิภาพมากขึ้น¹⁴

การศึกษาโดยอาศัยเทคนิคทาง ด้านปัญญาประดิษฐ์ (Artificial Intelligence: AI)

1. ขั้นตอนวิธีเชิงพันธุกรรม (Genetic Algorithm)

ศึกษา Particle Swarm Optimization (PSO) ร่วมกับ Back Propagation (BP) เพื่อเพิ่มประสิทธิภาพในการคาดการณ์ขนาดของแผ่นดินไหว โดยใช้ตัวแปรนำเข้า (Input) ได้แก่ ความถี่การเกิดแผ่นดินไหว, รอยแยก, การปล่อยพลังงาน, ค่า b ตัวบ่งชี้เพื่อวัดระดับกิจกรรมแผ่นดินไหวในพื้นที่ที่กำหนด, การสั่นสะเทือน, ค่า η ตัวบ่งชี้เพื่อตัดสินค่าความเบี่ยงเบนของตัวเลขจริงและสมการ Gutenberg- Richter (G-R) และชั้นผลลัพธ์ (Output) คือ ขนาดของแผ่นดินไหว ผลการเปรียบเทียบผลลัพธ์ที่ได้จากการคาดการณ์ และค่าความคลาดเคลื่อนสัมบูรณ์พบว่า PSO ที่ได้ปรับให้เหมาะสมนั้นสามารถเพิ่มความเร็วในการฝึก ซึ่งมีการฝึกซ้ำประมาณ 51 รอบ ในขณะที่ BPNN ทำงานได้ช้ากว่า ต้องมีการฝึกซ้ำประมาณ 120 รอบ จนกว่าจะถึงค่าเฉลี่ยของกำลังสองของความคลาดเคลื่อน (Mean Square Error, MSE)¹⁵

การศึกษา Artificial Bee Colony (ABC) algorithm เป็นการเลียนแบบพฤติกรรมกรการจับเหยื่อที่ชาญฉลาดของฝูงผึ้ง เพื่อเพิ่มประสิทธิภาพการคาดการณ์ของ Multilayer Perceptron (MLP) ที่มีการเรียนรู้แบบ BP ซึ่งปัญหาสำคัญของ BP คือ การปรับค่าน้ำหนัก (Weight) และ อคติแอมแปง (Bias) เพื่อให้เกิดผลลัพธ์ที่ถูกต้องตามที่เรียนรู้ไม่เหมาะสม ดังนั้นค่าน้ำหนักของอัลกอริทึมที่เหมาะสมควรเพิ่มความเร็วและช่วยปรับปรุงความแม่นยำในการคาดการณ์ ผลการคาดการณ์แสดงให้เห็นว่า MLP ที่ได้เรียนรู้โดยอัลกอริทึม ABC มีความแม่นยำกว่าการใช้ BP¹⁶

และการศึกษาโดยใช้ Ant-colony clustering algorithm เพื่อวิเคราะห์ความสัมพันธ์แบบไม่เป็นเชิงเส้นระหว่างขนาดแผ่นดินไหวในอนาคต เวลาที่เกิด และความผิดปกติต่างๆ ก่อนเกิดแผ่นดินไหว เนื่องจากมีฟังก์ชันในการจัดกลุ่มข้อมูล หรือลดมิติข้อมูล เพื่อหาลักษณะเด่นของข้อมูล โดยนำมาใช้ร่วมกับ k-means clustering algorithm พบว่าสามารถเพิ่มประสิทธิภาพการคาดการณ์แผ่นดินไหวมากขึ้น¹⁷

2. ตรรกศาสตร์คลุมเครือ (Fuzzy System) หรือระบบฟัซซี (Fuzzy System) หรือฟัซซีลอจิก (Fuzzy Logic)

การศึกษาการเปลี่ยนแปลงเชิงพื้นที่การเกิดแผ่นดินไหวทางอิหร่านตอนใต้ โดยจำแนกข้อมูลด้วยโครงข่าย Radial Basis Function (RBF) และ ใช้ระบบอนุมานฟัซซีโครงข่ายปรับตัวได้ (ANFIS) เพื่อวิเคราะห์รูปแบบการเกิดแผ่นดินไหวที่ไม่เป็นเชิงเส้น จากการการคำนวณตัวแปรของการเกิดคลื่นไหวสะเทือนเพื่อวิเคราะห์รูปแบบการเกิดแผ่นดินไหว สำหรับขั้นตอนการเตรียมข้อมูลได้ใช้วิธี Normalization และ Principal Components Analysis (PCA) เพื่อช่วยวิเคราะห์หาความซ้ำซ้อนของข้อมูล และเพิ่มประสิทธิภาพในการคาดการณ์ ผลการศึกษาแสดงให้เห็นว่าโครงข่าย RBF และระบบ ANFIS เป็นเครื่องมือที่เหมาะสมสำหรับการคาดการณ์ตำแหน่ง และเวลาการเกิดแผ่นดินไหวในอนาคต ซึ่งถึงแม้ว่าความแม่นยำของทั้ง 2 เครื่องมือจะมีความถูกต้องในการคาดการณ์ใกล้เคียงกัน แต่โครงข่าย RBF มีประสิทธิภาพในการ คาดการณ์แผ่นดินไหวในปี ค.ศ.2008 ได้ดีกว่าระบบ ANFIS¹⁸

3. โครงข่ายประสาทเทียม (Artificial Neural Networks)

รูปแบบโครงสร้างทางสถาปัตยกรรมของ ANN ในการคาดการณ์แผ่นดินไหว พบว่ามีการกำหนดวิธีการของโครงข่ายยัดนี้ การใช้ตัวแปรนำเข้าไปเพื่อคาดเดาผลลัพธ์ (prediction) เช่น การศึกษาความสัมพันธ์ระหว่างก๊าซเรดอนและการเกิดขนาดแผ่นดินไหวบริเวณทางตะวันตกของทวีปเอเชียของ ANN โดยใช้กระบวนการเรียนรู้แบบ Levenberg-Marquardt (LM) พบว่ามีความคลาดเคลื่อนสัมพันธ์ระหว่างค่าผลลัพธ์ที่ต้องการ และค่าผลลัพธ์จริงประมาณ 2.3 % และ

จากการป้อนจำนวนข้อมูลให้มากที่สุดเท่าที่เป็นไปได้ของแบบจำลองสำหรับการเรียนรู้และทดสอบ พบว่าช่วยเพิ่มความน่าเชื่อถือของค่าผลลัพธ์ที่ได้จากแบบจำลอง¹⁹ และการใช้ Recurrent Neural Network (RNN) คาดการณ์เวลา และตำแหน่งการเกิดแผ่นดินไหวขนาดใหญ่ (≥ 6.0 แมกนิจูด) ของรัฐแคลิฟอร์เนีย ประเทศสหรัฐอเมริกา โดยวิเคราะห์ความสัมพันธ์ระหว่างตำแหน่ง (ละติจูด ลองจิจูด) และเวลาการเกิดแผ่นดินไหว โดยแบ่งพื้นที่ศึกษาขนาดใหญ่ให้เป็นพื้นที่ย่อยๆ และแบ่งช่วงเวลาของข้อมูลเหตุการณ์แผ่นดินไหว ซึ่งแต่ละช่วงเวลาที่ถูกแบ่งนั้น ได้กำหนดให้เป็นเวลาระหว่างเกิดแผ่นดินไหวขนาดใหญ่ ผลการวิเคราะห์แสดงให้เห็นว่าRNN มีความแม่นยำมากขึ้นเมื่อเพิ่มจำนวนวันสำหรับคาดการณ์เป็น 15 วัน²⁰ สำหรับการนำค่าตัวแปรนำเข้าไปเพื่อกำหนดการจับหมวดหมู่ (Classification) ได้แก่ การศึกษาบริเวณซานฟรานซิสโก ในรัฐแคลิฟอร์เนียมีการคาดการณ์โดย Probabilistic Neural Network (PNN) โดยแบ่งแผ่นดินไหวขนาด 4.0-6.0 แมกนิจูด เป็น 7 ชั้น และได้กำหนดข้อมูลนำเข้าไปประกอบด้วย ตัวแปรที่พิจารณาจากความสัมพันธ์ G-R ละติจูด ลองจิจูดของศูนย์กลางแผ่นดินไหว และเวลาที่เกิดขึ้นของแผ่นดินไหว ผลการศึกษาแสดงให้เห็นว่าสองในสี่ของพื้นที่ทั้งหมดสามารถคาดการณ์ได้ถูกต้อง²¹ รวมถึงการวิเคราะห์ตัวแปรนำเข้าไปเพื่อการจัดกลุ่ม (Data Conceptualization) ได้แก่ การคาดการณ์ความเข้มข้นและแนวโน้มการเกิดอาฟเตอร์ช็อคของแผ่นดินไหวที่เกิดขึ้นวันที่ 12 พฤษภาคม ค.ศ. 2008 ในเมืองเจนิตู มณฑลเสฉวน จึงมีการจำกลุ่มตัวแปรนำเข้าไปแบบจำลอง รวมถึงจัดจากรูปแบบการสันสะเทือนของแผ่นดินไหว โดยอาศัย Kohonen Artificial Neural Network ที่มีกระบวนการเรียนรู้ self-organizing feature map (SOFM) ช่วยในการจัดเรียงข้อมูลนำเข้าไป โดยจัดข้อมูลที่คล้ายกันหรือใกล้เคียงให้อยู่ในกลุ่มเดียวกัน ผลลัพธ์จากแบบจำลองแสดงให้เห็นว่า อาฟเตอร์ช็อคจะเกิดขึ้นภายใน 2 วันถัดไปหลังจากเกิดเหตุการณ์แผ่นดินไหวหลัก²²

ตัวแปรข้อมูลนำเข้าไป และประเภทการคาดการณ์แผ่นดินไหว

การคาดการณ์แผ่นดินไหวสิ่งสำคัญในการศึกษา คือ การกำหนดระยะเวลา ขนาดแผ่นดินไหว และพื้นที่ศึกษาให้ชัดเจน เพื่อง่ายต่อการทำความเข้าใจ และสามารถให้คำตอบเกี่ยวกับผลลัพธ์ที่เกิดขึ้นว่าการคาดการณ์ประสบความสำเร็จหรือล้มเหลว²³ ดังนั้นในงานวิจัยคาดการณ์แผ่นดินไหวโดยอาศัย ANN จึงได้มีการกำหนดระยะเวลา ขนาดแผ่นดินไหว และพื้นที่ศึกษา โดยพบว่ามีการกำหนดพื้นที่ศึกษานั้นควรพิจารณาจากเหตุการณ์แผ่นดินไหวที่เกิดขึ้นเนื่องจากการเคลื่อนที่ของเปลือกโลก ซึ่งเกี่ยวข้องกับรอยเลื่อนหรือรอยแตกในหินที่แสดงการเลื่อนของแผ่นเปลือกโลก รวมถึงพิจารณา

พื้นที่ที่เกิดแผ่นดินไหวครั้งสำคัญ และมีความถี่ในการเกิดสูง ส่วนการพิจารณาระยะเวลา และขนาดแผ่นดินไหว พบว่าขึ้นอยู่กับข้อกำหนดของผู้วิจัย โดยจำเป็นต้องคำนึงถึงปริมาณข้อมูลแผ่นดินไหวที่ได้กำหนด ซึ่งปริมาณข้อมูลควรเพียงพอต่อการเรียนรู้และทดสอบ เช่น การศึกษาแผ่นดินไหวทางตะวันออกเฉียงเหนือของประเทศจีน เนื่องจากตั้งแต่ปี ค.ศ. 2013 พื้นที่บริเวณนี้มีการเกิดแผ่นดินไหวขนาด 5.0-5.9 แมกนิจูด ซึ่งได้รับอิทธิพลจากการมุดตัวของแผ่นเปลือกโลก และมีการเกิดขนาดใหญ่สุด คือ 6.3 แมกนิจูด ดังนั้นในการศึกษาจึงพิจารณาเหตุการณ์แผ่นดินไหวขนาด 5.0-5.9 แมกนิจูด ในปี ค.ศ.1970-2013⁸ การศึกษาบริเวณเทือกเขาหิมาลัย พบว่าเคยเกิดแผ่นดินไหวขนาดใหญ่ มากกว่า 9.0-10 แมกนิจูด ซึ่งมักเกิดขึ้นบริเวณโซนมุดตัวของแผ่นเปลือกโลก จากการรวบรวมข้อมูลปี ค.ศ. 1887-2015 มีขนาดแผ่นดินไหวเฉลี่ยอยู่ในช่วง 2.5 แมกนิจูด ดังนั้นในการศึกษาจึงคัดเลือกแผ่นดินไหวขนาด ≥ 2.5 แมกนิจูด ในปี ค.ศ.1887-2015 (128 ปี) มีการเกิดแผ่นดินไหวจำนวน 191 เหตุการณ์²⁴

การคัดเลือกตัวแปรข้อมูลนำเข้าตัวแปรนำเข้าในการคาดการณ์แผ่นดินไหว แบ่งได้เป็น 3 รูปแบบ ดังนี้

1. พิจารณาจากฐานข้อมูลแผ่นดินไหวที่บันทึกได้จากเครื่องตรวจวัดแผ่นดินไหว ประกอบด้วย เวลา (วัน เดือน ปี ชั่วโมง) ตำแหน่ง (ละติจูด ลองจิจูด) ขนาดความรุนแรง (แมกนิจูด) และความลึก (กิโลเมตร)

2. พิจารณาจากความสัมพันธ์ของการเปลี่ยนแปลงทางธรณีฟิสิกส์ทางกายภาพ และเหตุการณ์ผิดปกติต่างๆ ในเวลาก่อนเกิดแผ่นดินไหว ได้แก่ ก๊าซเรดอน ความดันของไอน้ำ อุณหภูมิของดิน คลื่นไหวสะเทือน เป็นต้น

3. พิจารณาจากความสัมพันธ์ Gutenberg-Richter (G-R) เป็นการวิเคราะห์ความสัมพันธ์ระหว่างขนาด และจำนวนครั้งในการเกิดแผ่นดินไหวโดยมีค่า Completeness Magnitude (Mc) เท่ากับ 2.5 หมายถึง สามารถหาจุดศูนย์กลาง และขนาดของแผ่นดินไหวตั้งแต่ 2.5 แมกนิจูดเป็นต้นไปตามสมการ

$$\log_{10}(N) = a - bM \quad (1)$$

โดย M คือความถี่สะสมของแผ่นดินไหวที่มีขนาดมากกว่า Mc ส่วน a และ b เป็นค่าคงที่ เพื่อวิเคราะห์ความสัมพันธ์ระหว่างขนาดแผ่นดินไหว และความถี่ของการเกิดแผ่นดินไหว²⁵ สามารถคำนวณได้โดยใช้การวิเคราะห์การถดถอยกำลังสองน้อยที่สุดดังสมการที่ (2) และ (3) ดังนี้

$$b = \frac{(n \sum M_i \log N_i) - \sum M_i \sum \log N_i}{((\sum M_i)^2 - n \sum M_i^2)} \quad (2)$$

$$a = \frac{\sum (\log_{10} N_i + b M_i)}{n} \quad (3)$$

โดยที่ M_i คือ ขนาดแผ่นดินไหวของเหตุการณ์ i และ N_i คือ จำนวนของเหตุการณ์แผ่นดินไหวที่มีขนาดมากกว่าหรือเท่ากับ ขนาด M

นอกจากมีการคำนวณตัวชี้วัดการเกิดแผ่นดินไหวที่เกี่ยวข้องกับความสัมพันธ์ (G-R) สำหรับเป็นตัวแปรสำหรับนำเข้าแบบจำลอง²⁶ ดังนี้

1. ระยะเวลาในการเกิดแผ่นดินไหวครั้งถัดไป (T value) ที่มีขนาดแผ่นดินไหวใหญ่กว่าขนาดที่กำหนด สามารถคำนวณได้จากสมการที่ (4)

$$T = t_n - t_1 \quad (4)$$

โดยที่ t_n คือ เวลาที่เกิดขึ้นของเหตุการณ์ n และ t_1 คือ เวลาในการเกิดแผ่นดินไหวของเหตุการณ์ที่ 1

2. ค่าเฉลี่ยขนาดของแผ่นดินไหว n เหตุการณ์ (The Mean Magnitude) เพื่อวัดความถี่ของแผ่นดินไหวหน้า ดังสมการที่ (5)

$$M_{\text{mean}} = \frac{\sum M_i}{n} \quad (5)$$

โดยที่ M_i คือ ขนาดแผ่นดินไหว และ n คือ จำนวนเหตุการณ์แผ่นดินไหว

3. รากที่สองของการปลดปล่อยพลังงานของคลื่นสั้นสะเทือน (The rate of square root of seismic energy released) สามารถคำนวณได้จากสมการที่ (6) ดังนี้

$$dE^{1/2} = \frac{\sum E^{1/2}}{T} \quad (6)$$

โดยที่ $E^{1/2}$ คือ รากที่สองของการปลดปล่อยพลังงานของคลื่นสั้นสะเทือน (Energy E) ซึ่งได้จากการคำนวณของสมการที่ (7)

$$E = 10^{(11.8+1.5M)} \text{ergs} \quad (7)$$

4. ค่าเฉลี่ยกำลังสองของการถดถอยของสมการความสัมพันธ์ G-R (η value) สามารถคำนวณได้จากสมการที่ (8)

$$\eta = \frac{\sum (\log_{10} N_i - (a - bM_i))^2}{(n - 1)} \quad (8)$$

โดยที่ M_i คือ ขนาดแผ่นดินไหวของเหตุการณ์ i และ N_i คือ จำนวนของเหตุการณ์แผ่นดินไหวที่มีขนาดมากกว่าหรือเท่ากับ ขนาด M

5. ความแตกต่างระหว่างขนาดของแผ่นดินไหวที่สังเกตได้ที่ใหญ่ที่สุดและขนาดที่คาดการณ์จากสมการความสัมพันธ์ ดังสมการที่ (9)

$$\Delta M = M_{observed} - M_{expected} \quad (9)$$

โดยที่ $M_{observed}$ คือ ขนาดแผ่นดินไหวสูงสุดของเหตุการณ์ n ล่าสุด $M_{expected}$ คือ ขนาดแผ่นดินไหวสูงสุดของเหตุการณ์ n ล่าสุดจากสมการความสัมพันธ์ G-R ซึ่งคำนวณได้จากสมการที่ (10)

$$M_{expected} = a/b \quad (10)$$

6. ระยะเวลาเฉลี่ยระหว่างเหตุการณ์แผ่นดินไหว (μ value) ดังสมการที่ (11)

$$\mu = \frac{\sum (t_i \text{ characteristic})}{n \text{ characteristic}} \quad (11)$$

โดยที่ t_i คือ ระยะเวลาระหว่างเหตุการณ์ที่มีขนาด M และ $n_{\text{characteristic}}$ คือ จำนวนเหตุการณ์ทั้งหมดของเหตุการณ์ขนาด M

7. สัมประสิทธิ์การแปรผันของเวลาเฉลี่ยระหว่างเหตุการณ์ (c value) ดังสมการที่ (12)

$$c = \frac{\text{standard deviation of the observed}}{\mu} \quad (12)$$

โดย μ คือ ระยะเวลาเฉลี่ยระหว่างเหตุการณ์แผ่นดินไหว คำนวณได้จากสมการ (11)

8. พลังงานคลื่นไหวสะเทือน (Energy J) คำนวณจากสมการที่ (13)

$$\log_{10} J = 9 + 1.8M \quad (13)$$

โดยที่ M คือ ขนาดของแผ่นดินไหว

สำหรับตัวแปรการคาดการณ์แผ่นดินไหว สามารถแบ่งประเภทการคาดการณ์ได้ดังนี้ (Table 1)

1. คาดการณ์ตำแหน่งแผ่นดินไหว คือ ละติจูด และลองจิจูด พบการศึกษาของพื้นที่รัฐแคลิฟอร์เนีย ประเทศสหรัฐอเมริกา ได้คัดเลือกตัวแปรที่วิเคราะห์จากความสัมพันธ์ G-R ประกอบด้วย ค่า b , T , M_{mean} , $dE^{1/2}$, Energy E , η , ΔM , μ , C , และ Energy J ซึ่งได้การคำนวณในสมการที่ (2) ถึง (13) สำหรับคาดการณ์ตำแหน่งการเกิดแผ่นดินไหวในเดือนถัดไป²⁶

2. คาดการณ์เวลา เช่น การคาดการณ์ความถี่ในการเกิดแผ่นดินไหวของเดือนถัดไป โดยตัวแปรข้อมูลนำเข้าที่ได้คัดเลือกของการศึกษาในประเทศอินเดีย คือ ลำดับเวลาของข้อมูลความถี่รายเดือน²⁷ และการคาดการณ์ช่วงเวลาที่เกิดแผ่นดินไหวขนาด ≥ 6.0 แมกนิจูดของพื้นที่ศึกษาบริเวณเทือกเขาคาร์เพเทียน และที่ราบพันโนเนีย ประเทศฮังการี ได้คัดเลือกตัวแปรนำเข้าข้อมูล คือ อัตราการเกิดแผ่นดินไหวในช่วงเวลาระหว่างเกิดแผ่นดินไหวขนาด ≥ 6.0 แมกนิจูด²⁸

3. คาดการณ์ขนาด ได้มีการกำหนดช่วงเวลาการคาดการณ์ร่วมด้วย เช่น การคาดการณ์ขนาดแผ่นดินไหวที่จะเกิดขึ้นในครั้งถัดไป สำหรับประเทศอินเดียตัวแปรข้อมูลนำเข้าที่ใช้ประกอบด้วย ข้อมูลตำแหน่ง (ละติจูด ลองจิจูด) และช่วงเวลาระหว่างเหตุการณ์แผ่นดินไหว 2 เหตุการณ์²⁹ การคาดการณ์ขนาดแผ่นดินไหวในเดือนถัดไปของประเทศจีน โดยตัวแปรข้อมูลนำเข้าที่ใช้วิเคราะห์จากความสัมพันธ์ G-R ประกอบด้วย ค่า b , T , M_{mean} , $dE^{1/2}$, η , ΔM , μ , C ที่ได้จากสมการที่ (2) ถึง (12) และ ขนาดสูงสุดที่บันทึกได้ในช่วงสัปดาห์ที่ผ่านมาของพื้นที่ศึกษา, ความน่าจะเป็นในการบันทึกเหตุการณ์แผ่นดินไหวที่มีขนาดมากกว่าหรือเท่ากับ 6 แมกนิจูด นอกจากนี้มีการศึกษาการคาดการณ์ขนาดแผ่นดินไหวที่จะเกิดขึ้นในปีถัดไป โดยตัวแปรข้อมูลนำเข้าประกอบด้วย ข้อมูลตำแหน่ง (ละติจูด ลองจิจูด) และตัวแปรที่เกี่ยวข้องกับความสัมพันธ์ G-R ได้แก่ ค่า b , M_{mean} , Energy E , C , Energy J ซึ่งได้จากการคำนวณในสมการที่ (2), (5), (7), (12) และ (13) ตามลำดับ²⁴

4. คาดการณ์ความน่าจะเป็นในการเกิดแผ่นดินไหว เช่น การคาดการณ์การเกิดแผ่นดินไหวขนาดใหญ่ (≥ 4 แมกนิจูด) 5 วันถัดไป ได้กำหนดตัวแปรนำเข้าแบบจำลอง 7 ตัวแปร โดยตัวแปรที่ 1 ถึง 5 ได้จากการคำนวณค่า b ซึ่ง

พิจารณาจากความสัมพันธ์ G-Ri ดังสมการที่ (14) ถึง (19) ดังนี้¹¹

$$b_i = \frac{\log(e)}{\left(\frac{1}{50}\right)\sum_{j=0}^n M_{i-j}=3} \tag{14}$$

จากนั้นคำนวณการเพิ่มขึ้นของค่า **b** ดังนี้

$$\Delta b_{1i} = b_i - b_{i-4} = x_1 \tag{15}$$

$$\Delta b_{2i} = b_{i-4} - b_{i-8} = x_2 \tag{16}$$

$$\Delta b_{2i} = b_{i-8} - b_{i-12} = x_3 \tag{17}$$

$$\Delta b_{2i} = b_{i-12} - b_{i-16} = x_4 \tag{18}$$

$$\Delta b_{2i} = b_{i-16} - b_{i-20} = x_5 \tag{19}$$

ตัวแปรที่ 6 เป็นการคำนวณขนาดสูงสุดที่บันทึกได้ในช่วงสัปดาห์ที่ผ่านมาของพื้นที่ศึกษาจากสมการดังนี้

$$x_6 = \max\{M_s\} \tag{20}$$

และตัวแปรที่ 7 คือความน่าจะเป็นในการบันทึกเหตุการณ์แผ่นดินไหวที่มีขนาดมากกว่าหรือเท่ากับ 6.0 แมกนิจูด ที่ได้จากการคำนวณสมการที่ (21)

$$x_7 = \max\{M_t\} \tag{21}$$

และการศึกษาคาดการณ์ความน่าจะเป็นในการเกิดแผ่นดินไหวในวันถัดไป ได้คัดเลือกตัวแปรข้อมูลนำเข้า 15 ตัวแปร ประกอบด้วย $b, a, T, M_{mean}, dE^{1/2}, \eta, \Delta M, \mu, C$ จากสมการที่ (2) ถึง(12) และ $x_1, x_2, x_3, x_4, x_5, x_6, x_7$ จากสมการที่ (14) ถึง (21)³⁰

จากการกำหนดตัวแปรข้อมูลนำเข้า และตัวแปรสำหรับการคาดการณ์ พบว่าความสัมพันธ์ G-R มีความสำคัญต่อการวิเคราะห์ตัวแปรข้อมูลนำเข้า โดยเฉพาะค่า b ซึ่งถือเป็นตัวแปรที่มีอิทธิพลอย่างมากต่อผลลัพธ์การคาดการณ์แผ่นดินไหว โดยได้มีการวิเคราะห์พฤติกรรมแผ่นดินไหวในพื้นที่ศึกษา ซึ่งสะท้อนให้เห็นถึงการแปรสัณฐาน รวมถึงคุณสมบัติทางธรณีฟิสิกส์ของหิน หากค่า b น้อยแสดงให้เห็นว่าพื้นที่บริเวณนั้นมีศักยภาพที่จะทำให้เกิดแผ่นดินไหวขนาดใหญ่ได้ แต่ถ้าค่า b มาก แสดงว่าพื้นที่บริเวณนั้นมีกิจกรรมแผ่นดินไหวขนาดเล็กและเกิดขึ้นบ่อยครั้ง ดังนั้นความแตกต่างของค่า b จึงเป็นตัวชี้วัดที่สำคัญในการวิเคราะห์ตัวแปรข้อมูลนำเข้าของโครงข่าย³⁰

เนื่องจากสามารถวิเคราะห์ความแปรปรวน และความไม่เป็นเชิงเส้นของพฤติกรรมการเกิดแผ่นดินไหวได้^{31, 32}

Table 1 ANN models for earthquake prediction based on structured earthquake catalogues

Ref.	Architectural Structure	Input Variables						Output Variables			
		Time	Location	Magnitude	Deep	Gutenberg-Richter	Other Evidence	Time	Location	Magnitude	Possibility
[8]	RNN						✓	✓		✓	
[11]	FFNN						✓				✓
[20]	RNN					✓		✓	✓		
[24]	FFNN		✓			✓				✓	
[26]	FFNN,RBF,RNN					✓				✓	
[27]	FFNN	✓					✓	✓			
[28]	FFNN	✓						✓			
[29]	FFNN	✓	✓				✓			✓	
[33]	FFNN,RNN						✓			✓	
[35]	FFNN					✓					✓
[37]	FFNN,RNN					✓					✓
[39]	FFNN			✓			✓			✓	

การออกแบบโครงสร้างแบบจำลองโครงข่ายประสาทเทียม

การออกแบบโครงสร้างโครงข่ายประสาทเทียม มีการใช้โครงสร้าง Feed Forward Neural Network (FFNN) ซึ่งพบจำนวน 18 บทความ ในการคาดการณ์แผ่นดินไหว เป็นโครงข่ายแบบป้อนไปข้างหน้า ที่ประมวลผลข้อมูลในทิศทางเดียวกัน โดยรับข้อมูลจากชั้นข้อมูลนำเข้า (Input layer) จากนั้นสร้างค่าน้ำหนัก แล้วประมวลผลผ่านชั้นผลลัพธ์ (Output layer) และพบ 5 บทความ ได้คาดการณ์แผ่นดินไหวโดยอาศัยโครงสร้าง RNN เป็นโครงข่ายประสาทเทียมที่มีการป้อนกลับข้อมูลไปยังโครงข่ายหลายครั้งจนกระทั่งได้คำตอบ โดยการนำผลลัพธ์ที่ได้ก่อนหน้าช่วยในการตัดสินใจคำตอบ ซึ่งมักใช้กับการวิเคราะห์ข้อมูลที่เป็นอนุกรมเวลา หรือข้อมูลที่มีการบันทึกไว้อย่างต่อเนื่อง โดยข้อมูลเหตุการณ์ก่อนหน้ามีการเชื่อมโยงและมีผลต่อเหตุการณ์ที่จะเกิดต่อไปในอนาคต²⁰ เช่น ตัวแปรข้อมูลนำเข้าที่วิเคราะห์ได้จากความสัมพันธ์ G-R^{8, 20, 26, 30} และมีการใช้ Radial basis function neural network (RBFNN) เพื่อแก้ปัญหาการจัดประเภท (Classification) และการคาดการณ์ เนื่องจากสามารถจำแนกข้อมูลที่เป็นเชิงเส้น และไม่เป็นเชิงเส้นได้ โดยมีลักษณะเป็นโครงข่ายแบบ FFNN แต่จะมีจำนวนโหนดมากกว่า โดย RBFNN จะให้ผลลัพธ์ที่ดีขึ้นเมื่อปริมาณชุดข้อมูลเรียนรู้มีจำนวนมาก²⁶ จาก Table 1 แสดงการกำหนดตัวแปรนำเข้า ตัวแปรสำหรับการคาดการณ์แผ่นดินไหว และโครงสร้างของ ANN พบว่ามีการเลือกใช้การเรียนรู้แบบ BP มากที่สุด เนื่องจากการเรียนรู้แบบมีผู้สอนที่สามารถประมาณความสัมพันธ์แบบไม่เป็นเชิงเส้นระหว่างชั้นข้อมูลนำเข้า และชั้นผลลัพธ์โดยพิจารณาจากความผิดพลาดแล้วย้อนกลับมาที่ชั้นข้อมูลนำเข้า โดยทำหน้าที่ปรับค่าน้ำหนักอีกครั้งโดยดูจากค่าความผิดพลาดที่เกิดขึ้นในแต่ละนิวรอน ซึ่งจะปรับจนกว่าค่าผิดพลาดน้อยลง หรืออยู่ในเกณฑ์ที่ยอมรับ ทำให้ผลลัพธ์ที่ได้ในครั้งถัดไปมีความถูกต้องมากขึ้น นอกจากนี้มีการใช้การเรียนรู้แบบ LM สำหรับการเรียนรู้ของโครงข่ายข้อดีของการเรียนรู้ประเภทนี้คือ ใช้เวลาประมวลผลน้อย เนื่องจากลดเวลาการเรียนรู้และช่วยเพิ่มอัตราการตรวจสอบ^{19, 33} และการใช้ Long Short-Term Memory (LSTM) สำหรับเรียนรู้ค่าน้ำหนักของแต่ละโหนด ซึ่งถูกออกแบบมาสำหรับการประมวลผลข้อมูลลำดับ (sequence) ข้อมูลประเภทอนุกรมเวลา โดยช่วยแก้ปัญหาการจดจำข้อมูลระยะยาวของ RNN³⁴ และ Genetic algorithm เป็นเทคนิคการเรียนรู้สำหรับค้นหาผลลัพธ์ หรือคำตอบโดยประมาณ อีกทั้งช่วยเพิ่มประสิทธิภาพการคาดการณ์โดยกำหนดของค่าน้ำหนัก และเกณฑ์การเชื่อมโยงของโครงข่ายให้ดีขึ้น³⁵

การกำหนดจำนวนชั้นซ่อนเร้น และจำนวนโหนดในชั้นซ่อนเร้น พบว่าชั้นซ่อนเร้นจำนวน 1 ชั้นมีการกำหนด

มากที่สุดซึ่งพบ 18 บทความ กำหนด 2 ชั้นซ่อนเร้น จำนวน 4 บทความ และมีเพียง 1 บทความที่ได้กำหนด 3 ชั้นซ่อนเร้น

จากการศึกษา พบว่า แบบจำลองมีประสิทธิภาพในการคาดการณ์มากขึ้นเมื่อกำหนดชั้นซ่อนเร้นจำนวน 2 ชั้น เช่น การเปรียบเทียบผลการคาดการณ์แผ่นดินไหวบริเวณพื้นที่รัฐแคลิฟอร์เนีย ประเทศอเมริกา ของแบบจำลองที่กำหนดจำนวนชั้นซ่อนเร้น 1 และ 2 ชั้น พบว่าแบบจำลองที่มีจำนวนชั้นซ่อนเร้น 2 ชั้น มีความแม่นยำในการคาดการณ์มากกว่าแบบ 1 ชั้น โดยมีค่าความคลาดเคลื่อนต่ำสุดในการคาดการณ์ตำแหน่ง และจำนวนวันในการเกิดแผ่นดินไหวครั้งถัดไป (ขนาด ≥ 5.5 แมกนิจูด) คือ 15.2 ไมล์ และ 5 วัน ตามลำดับ²⁰ เช่นเดียวกับผลการคาดการณ์ขนาดแผ่นดินไหวบริเวณทางตอนเหนือของทะเลแดง ที่ได้กำหนดจำนวนชั้นซ่อนเร้น 2 และ 3 ชั้น พบว่ามีค่าผิดพลาดรวมเฉลี่ยน้อยที่สุด (MSE) คือ 0.115 และ 0.122 ตามลำดับ³⁶

สำหรับการกำหนดจำนวนโหนดของชั้นซ่อนเร้น พบว่าขึ้นอยู่กับความซับซ้อนของข้อมูล และการกำหนดของผู้วิจัยเองเนื่องจากไม่มีคำตอบที่แน่ชัด เช่น การกำหนดจำนวนโหนดชั้นซ่อนเร้นจาก $2n+2$ ซึ่งอ้างอิงจากทฤษฎี Kolmogomov และ Hecht-Nielsen¹¹ หรือจาก (จำนวนตัวแปรนำเข้า+จำนวนชั้นของแบบจำลอง)/2¹² ดังนั้นจึงสังเกตได้ว่าการกำหนดจำนวนโหนดของชั้นซ่อนเร้นมักขึ้นอยู่กับจำนวนตัวแปรข้อมูลนำเข้า ซึ่งสามารถแบ่งการกำหนดได้เป็น 3 รูปแบบ คือ 1. กำหนดให้มีจำนวนน้อยกว่าหรือเท่ากับจำนวนข้อมูลนำเข้า เช่น การคาดการณ์ขนาดแผ่นดินไหวบริเวณรัฐแคลิฟอร์เนีย ประเทศอเมริกา ผลการศึกษาพบว่ามีค่าสัมประสิทธิ์สหสัมพันธ์อยู่ในช่วง 0-0.16³⁷ 2. กำหนดให้มีจำนวนมากกว่าจำนวนข้อมูลนำเข้า เช่น การคาดการณ์แผ่นดินไหวบริเวณตะวันออกเฉียงเหนือของจีน ผลการคาดการณ์พบว่ามีค่าความถูกต้องมากที่สุด 53.81%⁸ การคาดการณ์แผ่นดินไหวบริเวณตะวันออกเฉียงเหนือของประเทศอินเดีย พบว่ามีค่าสัมประสิทธิ์สหสัมพันธ์อยู่ในช่วง 0.4-0.5²⁷ และการคาดการณ์แผ่นดินไหวในประเทศตุรกี พบว่ามีค่าความคลาดเคลื่อนสัมพัทธ์ 0-6.25%³³ และ 3. กำหนดให้มีจำนวน 50% ของข้อมูลนำเข้า เช่น การคาดการณ์แผ่นดินไหวในประเทศญี่ปุ่น ผลการคาดการณ์พบว่ามีค่าความถูกต้องมากกว่า 70%¹² และการคาดการณ์แผ่นดินไหวในประเทศอินเดีย พบว่ามีค่าสัมประสิทธิ์สหสัมพันธ์อยู่ในช่วง 0.84-0.91 แสดงให้เห็นว่าผลที่ได้จากการคาดการณ์และค่าจากเหตุการณ์จริงมีความสัมพันธ์กันในระดับสูง²⁹ ดังนั้นเมื่อวิเคราะห์เปรียบเทียบผลการคาดการณ์ของแบบจำลองที่กำหนดจำนวนชั้นซ่อนเร้น 3 รูปแบบ จึงสามารถสรุปได้ว่าแบบจำลองที่กำหนดจำนวน 50% ของข้อมูลนำเข้ามีความถูกต้อง และค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างค่าจริงและค่าที่ได้จากการคาดการณ์มากที่สุด

การกำหนดตัวชี้วัดความถูกต้องสำหรับประเมินประสิทธิภาพของ ANN สามารถแบ่งได้เป็น 2 ประเภท ดังนี้

1. ตัวชี้วัดความถูกต้องสำหรับการคาดการณ์ขนาด เวลา และตำแหน่ง ได้แก่ การคำนวณค่าผิดพลาดรวมเฉลี่ย (Mean Squared Error: MSE)^{36, 38} ค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error: MAE)^{36, 39} ค่ารากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (Root mean Squared Error: RMSE)^{34, 40} ค่าความคลาดเคลื่อนสัมพัทธ์ (Relative Errors)^{33, 35} และค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation Coefficient: r) เป็นค่าที่แสดงความสัมพันธ์ของทิศทางของข้อมูล 2 กลุ่ม โดย r คือ ค่าสัมประสิทธิ์สหสัมพันธ์ และ r^2 คือ ค่าสัมประสิทธิ์สหสัมพันธ์ยกกำลังสอง หากยังมีค่าเข้าใกล้ 1 หมายถึงจะมีความแม่นยำมากยิ่งขึ้น^{27, 29}

2. ตัวชี้วัดความถูกต้องสำหรับความน่าจะเป็นในการเกิดแผ่นดินไหว ประกอบด้วยตัวแปรที่สำคัญ ดังนี้ Double true (DT) คือ จำนวนครั้งที่แบบจำลองคาดการณ์ขนาด และเวลาได้ถูกต้อง, Magnitude true (MT) คือ จำนวนครั้งที่แบบจำลองคาดการณ์ขนาดแผ่นดินไหวถูกต้อง, Time true (TT) คือ จำนวนครั้งที่แบบจำลองคาดการณ์เวลาถูกต้อง และ Double false (DF) คือ จำนวนครั้งที่แบบจำลองคาดการณ์ไม่ถูกต้องทั้งขนาดแผ่นดินไหว และเวลา⁹ เช่นเดียวกับตัวชี้วัดความถูกต้อง ประกอบด้วยตัวแปร True positives (TP) คือ จำนวนครั้งที่แบบจำลองคาดการณ์ถูกต้อง, True negatives (TN) คือ จำนวนครั้งที่ผลการคาดการณ์ไม่ตรงกับเหตุการณ์จริง False positives (FP) คือจำนวนครั้งที่แบบจำลองคาดการณ์ไม่ถูกต้อง และ False negatives (FN) คือ จำนวนครั้งที่แบบจำลองคาดการณ์ว่าไม่เกิดแผ่นดินไหว แต่เหตุการณ์จริงเกิดขึ้น^{11, 12, 30, 37}

ประเทศไทยกับการคาดการณ์แผ่นดินไหว

เหตุการณ์แผ่นดินไหวที่เกิดขึ้นในประเทศไทยส่วนใหญ่มักเกิดจากจากแนวรอยเลื่อนมีพลังจำนวน 14 รอยเลื่อนที่พาดผ่านในประเทศไทย โดยภาคเหนือพบรอยเลื่อนมีพลังมากที่สุด ได้แก่ รอยเลื่อนแม่จัน รอยเลื่อนแม่เมือง รอยเลื่อนแม่ฮ่องสอน รอยเลื่อนแม่ทา รอยเลื่อนพะเยา รอยเลื่อนปัว รอยเลื่อนเมย รอยเลื่อนเถิน รอยเลื่อนเพชรบูรณ์ และรอยเลื่อนอุตรดิตถ์ ส่วนทางภาคตะวันตกของประเทศ พบ 2 รอยเลื่อน คือ รอยเลื่อนศรีสวัสดิ์และรอยเลื่อนเจดีย์สามองค์ และทางภาคใต้ พบรอยเลื่อนมีพลัง 2 รอยเลื่อน คือ รอยเลื่อนระนอง และรอยเลื่อนคลองมะรุ่ย ส่วนพื้นที่ที่ไม่มีรอยเลื่อนมีพลังพาดผ่าน ได้แก่ บริเวณภาคกลาง ภาคตะวันออก และภาคตะวันออกเฉียงเหนือ⁴¹

จากการรวบรวมเหตุการณ์แผ่นดินไหวในประเทศไทยและประเทศใกล้เคียง ที่ตรวจวัดจากระบบ

ตรวจวัดแผ่นดินไหวของกรมอุตุนิยมวิทยา ทั้งหมด 41 สถานี ในปี ค.ศ. 2007-2018 มีเหตุการณ์แผ่นดินไหวที่เกิดขึ้นจำนวน 2,169 เหตุการณ์ จากการวิเคราะห์ความสัมพันธ์ระหว่างขนาดแผ่นดินไหวและช่วงเวลาที่เกิดขึ้น (ปี) โดยจำแนกขนาดแผ่นดินไหวตาม USGS (U.S. Geological Survey) พบว่าแต่ละปีมีการเกิดแผ่นดินไหวขนาดเล็กมาก มีช่วงขนาดน้อยกว่า 3.0 แมกนิจูด จนถึงขนาดค่อนข้างใหญ่ ที่มีช่วงขนาด 6.0-6.9 แมกนิจูด (Figure 1) และพบว่าโดยเฉลี่ยแล้วขนาดแผ่นดินไหวสูงสุดที่เกิดขึ้นในแต่ละปีอยู่ในระดับ 4.0-4.9 แมกนิจูด (ขนาดค่อนข้างเล็ก) อีกทั้งมีแนวโน้มการเกิดเพิ่มขึ้นทุกปีโดยเฉพาะปี ค.ศ.2014 ที่มีการเกิดแผ่นดินไหวสูงสุดจำนวน 933 เหตุการณ์ และถือเป็นปีที่มีการเกิดแผ่นดินไหวรุนแรงที่สุด คือ 6.3 แมกนิจูด⁴²

โดยหลังจากปี ค.ศ. 2014 ประเทศไทยมีอัตราการเกิดแผ่นดินไหวมากกว่า 200 เหตุการณ์ต่อปี ซึ่งสอดคล้องกับผลการศึกษาของโชติ เนื่องนันท์ และคณะ (2561) ที่ได้ศึกษาแนวโน้มการเกิดแผ่นดินไหวในประเทศไทยและประเทศพม่า โดยพบว่าการเกิดแผ่นดินไหวในรอบ 10 ปี แผ่นดินไหวในประเทศไทยมีอัตราการเกิดเพิ่มขึ้น และขนาดแผ่นดินไหวมีแนวโน้มเฉลี่ยอยู่ในระดับ 4.0-4.9 แมกนิจูด⁴³




Figure 1 Earthquakes magnitude range (difference between maximum and minimum magnitude) from 2007 to 2018

สำหรับการพิจารณาบริเวณที่เกิดแผ่นดินไหวที่มีสาเหตุการเกิดจากแนวรอยเลื่อนมีพลังในประเทศไทย พบว่าจังหวัดเชียงรายถือเป็นจังหวัดที่มีการเกิดแผ่นดินไหวมากที่สุดพบจำนวน 1,233 เหตุการณ์ เนื่องจากมีรอยเลื่อนแม่จัน รอยเลื่อนแม่ทา และรอยเลื่อนพะเยาพาดผ่าน โดยเฉพาะรอยเลื่อนพะเยา ที่ประกอบด้วยรอยเลื่อนย่อย 2 ส่วน ได้แก่ รอยเลื่อนย่อยส่วนเหนือที่มักเกิดแผ่นดินไหวขนาดเล็กถึงขนาดปานกลางบ่อยครั้ง และรอยเลื่อนย่อยส่วนใต้ มีลักษณะเป็นผารอยเลื่อนที่มีทางน้ำสาขาต่างๆ ตัดผ่าน แสดงให้เห็นรอยกัดเซาะลงไปแนวตั้งที่ลึกมากจนถึงชั้นหิน และบริเวณฐานผา

รอยเลื่อนที่มีความชันมากจนเห็นได้ชัด แสดงให้เห็นว่ายังคงมีพลังไม่หยุดนิ่ง จึงสอดคล้องกับการเกิดแผ่นดินไหวขนาด 5.2 แมกนิจูด ในวันที่ 11 กันยายน ค.ศ.1994 ที่มีศูนย์กลางเกิดแผ่นดินไหวอยู่ในเขตอำเภอพาน จังหวัดเชียงราย และเกิดขนาด 6.3 แมกนิจูด ในวันที่ 5 พฤษภาคม ค.ศ. 2014⁴⁴

จากการค้นคว้าและสืบค้นงานวิจัยที่เกี่ยวข้องกับการคาดการณ์แผ่นดินไหวในประเทศไทย พบการประเมินระดับอันตรายจากแผ่นดินไหวในประเทศไทยจากแนวคิดความน่าจะเป็น ซึ่งเป็นการศึกษาการเปลี่ยนแปลงรูปแบบไหวสะเทือน⁴⁵ ผลการศึกษาพบว่ายากต่อการวิเคราะห์ เนื่องจากกระบวนการเกิดแผ่นดินไหวมีความซับซ้อนมาก และข้อมูลการเกิดแผ่นดินไหวขนาดใหญ่ของพื้นที่ศึกษาบ่อย เช่นเดียวกับการศึกษาตรวจวัดความเข้มข้นของก๊าซเรดอนตามแนวรอยเลื่อนมีพลังคลองมะรุ่ย สำหรับจัดทำแผนที่รอยเลื่อนเพื่อเฝ้าระวังในระยะยาวของการคาดการณ์แผ่นดินไหวล่วงหน้าในประเทศไทย ผลการตรวจวัดปริมาณก๊าซเรดอนพบว่าสามารถระบุตำแหน่งของแนวรอยเลื่อนที่พาดผ่านพื้นที่ได้ โดยตำแหน่งของรอยเลื่อนให้ค่าปริมาณก๊าซเรดอนที่ตรวจวัดได้มากกว่าค่าปกติเฉลี่ยในพื้นที่ประมาณ 2 ถึง 6 เท่า ถึงแม้ว่าการศึกษาสามารถให้รายละเอียดความไม่ต่อเนื่องทางธรณี แต่วิธีการวัดก๊าซเรดอนยังมีข้อจำกัด คือ สภาพทางภูมิอากาศ (อุณหภูมิ และความชื้น) ซึ่งมีผลต่อการสำรวจหรือคำนวณของก๊าซเรดอน⁴⁶ จากปัญหาความแปรปรวน และความยุ่งยากในการศึกษารูปแบบกลไกการเกิดของแผ่นดินไหวดังกล่าว ผู้วิจัยจึงสนใจศึกษาแนวทางและความเป็นไปได้ในการคาดการณ์แผ่นดินไหวในประเทศไทยโดยอาศัย ANN ดังที่จะกล่าวในหัวข้อถัดไป

แนวทางการคาดการณ์แผ่นดินไหวโดยอาศัยโครงข่ายประสาทเทียมในประเทศไทย

1. จากการรวบรวมข้อมูลแผ่นดินไหวของสถานีตรวจวัดของกรมชลประทาน, การไฟฟ้าฝ่ายผลิตแห่งประเทศไทย, กรมอุตุนิยมวิทยา และกรมทรัพยากรธรณี พบว่า ฐานข้อมูลเหตุการณ์แผ่นดินไหวในประเทศไทย จากสถานีตรวจวัดของสำนักเฝ้าระวังแผ่นดินไหว กรมอุตุนิยมวิทยาได้มีการปรับปรุงและพัฒนาระบบเครือข่ายตรวจแผ่นดินไหวแบบดิจิทัลให้มีมาตรฐานเพิ่มขึ้น และมีการติดตั้งสถานีตรวจวัดบริเวณชุมชนเป็นหลัก จำนวน 41 สถานี ซึ่งครอบคลุมรอยเลื่อนทางภาคเหนือ ภาคตะวันตก และภาคใต้ของประเทศไทย ทำให้สามารถรายงานขนาดแผ่นดินไหวที่เกิดขึ้นรายวัน และค่าความเร่งของพื้นดินที่มีผลกระทบต่อชุมชน อีกทั้งสามารถตรวจวัดและบันทึกเหตุการณ์แผ่นดินไหวขนาดเล็กๆ ที่เกิดขึ้นภายในประเทศไทยได้ ซึ่งแตกต่างจากฐานข้อมูลแผ่นดินไหวอื่นๆ ที่สามารถตรวจวัดและบันทึกเหตุการณ์แผ่นดินไหวขนาดกลางและขนาดใหญ่ (มากกว่า 4 แมกนิจูด) บริเวณเหนือ⁴⁷ ดังนั้นฐานข้อมูลจากสถานีตรวจวัดกรมอุตุนิยมวิทยาที่สามารถบันทึกเหตุการณ์แผ่นดินไหวขนาดเล็กได้ จึงมีประโยชน์อย่างมากในการศึกษาวิจัยทางด้านแผ่นดินไหวเพื่อใช้อธิบายเหตุการณ์แผ่นดินไหวที่เกิดขึ้น เช่นแผ่นดินไหวนำ (Foreshock) แผ่นดินไหวหลัก (Main shock) และแผ่นดินไหวตาม (Aftershock) รวมถึงใช้สำหรับเป็นตัวแปรข้อมูลนำเข้าของ ANN

2. ในการกำหนดพื้นที่ศึกษาสำหรับคาดการณ์แผ่นดินไหวในประเทศไทยนั้น จำเป็นต้องคำนึงถึงปริมาณข้อมูลที่ใช้ในการวิเคราะห์ ซึ่งจากการรวบรวมข้อมูลเหตุการณ์แผ่นดินไหวในประเทศไทยและประเทศใกล้เคียงของสถานีตรวจวัดกรมอุตุนิยมวิทยาในช่วงปี ค.ศ. 2007-2018 จำนวน 2,169 เหตุการณ์ โดยพบเหตุการณ์แผ่นดินไหวขนาดน้อยกว่า 3.0 แมกนิจูด 1,587 ครั้ง ขนาด 3.0-3.9 แมกนิจูด 487 ครั้ง ขนาด 4.0-4.9 แมกนิจูด 78 ครั้ง ขนาด 5.0-5.9 แมกนิจูด 16 ครั้ง และ ขนาดมากกว่า 6.0 ขึ้นไป 1 ครั้ง⁴² ซึ่งถือว่าข้อมูลมีความพร้อม และมีปริมาณเพียงพอต่อการเรียนรู้และทดสอบแบบจำลอง เนื่องจากมีการบันทึกขนาดแผ่นดินไหวตั้งแต่ขนาดเล็กน้อย ทำให้สามารถวิเคราะห์รูปแบบการเกิดแผ่นดินไหวสำหรับพิจารณาตัวแปรนำเข้าแบบจำลอง

นอกจากนี้พบว่า การแบ่งพื้นที่ศึกษาให้มีขนาดเล็กลงจะช่วยลดสิ่งรบกวน และลดปัจจัยที่มีอิทธิพลการเกิดแผ่นดินไหว เช่น ปัจจัยด้านธรณีวิทยา ลักษณะภูมิประเทศ เป็นต้น⁸ โดยเฉพาะบริเวณที่มีรอยเลื่อนพาดผ่าน ซึ่งถือเป็นปัจจัยสำคัญในการพิจารณาเป็นพื้นที่ศึกษา ดังนั้นเพื่อเพิ่มประสิทธิภาพในการคาดการณ์ การกำหนดพื้นที่ศึกษาบริเวณรอยเลื่อนพะเยา จึงถือเป็นพื้นที่เหมาะสมในการศึกษาเช่นเดียวกันเนื่องจากมีอัตราการเกิดสูง โดยพบว่ามีแผ่นดินไหวในช่วงตั้งแต่ปี ค.ศ. 2007-2018 จำนวน 1,295 เหตุการณ์ ประกอบด้วย เหตุการณ์แผ่นดินไหวขนาดน้อยกว่า 3.0 แมกนิจูด 981 ครั้ง ขนาด 3.0-3.9 แมกนิจูด 256 ครั้ง ขนาด 4.0-4.9 แมกนิจูด 49 ครั้ง ขนาด 5.0-5.9 แมกนิจูด 8 ครั้ง และ ขนาดมากกว่า 6.0 ขึ้นไป 1 ครั้ง⁴² ดังนั้นการแบ่งพื้นที่ศึกษาสำหรับคาดการณ์แผ่นดินไหวเป็นขนาดเล็กจึงถือเป็นอีกหนึ่งแนวทางที่สำคัญในการเพิ่มความเป็นไปได้ในการคาดการณ์แผ่นดินไหว และเพิ่มประสิทธิภาพในการคาดการณ์ของแบบจำลอง

3. การกำหนดตัวแปรนำเข้าและตัวแปรสำหรับการคาดการณ์ พบว่าการคาดการณ์แผ่นดินไหวที่มีการศึกษามากที่สุด คือ การคาดการณ์ขนาดแผ่นดินไหว รองลงมาคือ ความน่าจะเป็นในการเกิดแผ่นดินไหว ส่วนการคาดการณ์ตำแหน่งและเวลา มีการศึกษาน้อยที่สุด เนื่องจากแผ่นดินไหวมีปัจจัย

การกำหนดตัวแปรนำเข้าและตัวแปรสำหรับการคาดการณ์ พบว่าการคาดการณ์แผ่นดินไหวที่มีการศึกษามากที่สุด คือ การคาดการณ์ขนาดแผ่นดินไหว รองลงมาคือ ความน่าจะเป็นในการเกิดแผ่นดินไหว ส่วนการคาดการณ์ตำแหน่งและเวลา มีการศึกษาน้อยที่สุด เนื่องจากแผ่นดินไหวมีปัจจัย

ต่าง ๆ ที่มีลักษณะไม่เป็นเชิงเส้น มีกลไกการเกิดที่ไม่แน่นอน ทำให้ยากต่อการศึกษาหาความสัมพันธ์ของตำแหน่ง และเวลา การเกิดแผ่นดินไหว

สำหรับตัวแปรข้อมูลนำเข้าแบบจำลอง นอกจากการพิจารณาคุณภาพและปริมาณที่เพียงพอต่อการเรียนรู้และทดสอบ ซึ่งขึ้นอยู่กับวิธีการคัดเลือกช่วงปีและขนาดแผ่นดินไหวของผู้วิจัยแล้ว การกำหนดตัวแปรนำเข้าแบบจำลองยังเชื่อมโยงกับฐานข้อมูลแผ่นดินไหวที่ได้จากสถานีตรวจวัดของกรมอุตุนิยมวิทยา ซึ่งประกอบด้วย ข้อมูลตำแหน่ง (ละติจูด ลองจิจูด) เวลา (วัน เดือน ปี) ขนาดแผ่นดินไหว ตำแหน่งศูนย์กลางแผ่นดินไหว โดยจากการศึกษาพบว่าตัวแปรนำเข้าจากสมการความสัมพันธ์ G-R ถือเป็นตัวแปรที่เหมาะสมในการนำเข้าแบบจำลองมากที่สุดเนื่องจากสามารถวิเคราะห์กลไกการเกิดแผ่นดินไหวที่ซับซ้อนและวิเคราะห์ความสัมพันธ์ระหว่างขนาดแผ่นดินไหวและจำนวนครั้งที่เกิดขึ้นได้ โดยการกำหนดตัวแปรข้อมูลนำเข้าแบบจำลองนั้น จะคำนวณจากค่าสถิติของข้อมูลสถานีตรวจวัด ซึ่งตัวแปรที่ได้เหล่านี้จะเป็นตัวบ่งชี้การเกิดแผ่นดินไหว และประเมินการเกิดแผ่นดินไหวของพื้นที่ศึกษา

4. การออกแบบโครงสร้างสถาปัตยกรรมพบว่ามีการใช้โครงสร้าง FFNN มากที่สุดเนื่องจากมีรูปแบบโครงสร้างที่ง่าย และไม่ซับซ้อน โดยการเรียนรู้ที่ใช้ ได้แก่ BP, LM และ LSTM โดยพบว่า BP เป็นการเรียนรู้ที่มีการใช้สำหรับคาดการณ์แผ่นดินไหวมากที่สุดเนื่องจากสามารถประมาณความสัมพันธ์แบบไม่เป็นเชิงเส้น และพิจารณาค่าความผิดพลาดย้อนกลับ จนได้ผลลัพธ์ที่อยู่ในเกณฑ์ที่ยอมรับ และความถูกต้องมากขึ้น

สำหรับการกำหนดจำนวนชั้นซ่อนเร้น มักขึ้นอยู่กับจำนวนตัวแปรข้อมูลนำเข้า และความซับซ้อนของงานวิจัย โดยยังมีจำนวนโหนดมาก แบบจำลองจะมีความซับซ้อนมากขึ้น โดยพบว่ากำหนดชั้นซ่อนเร้นจำนวน 2 ชั้นมีประสิทธิภาพในการคาดการณ์มากขึ้น ส่วนการกำหนดจำนวนโหนดของชั้นซ่อนเร้นพบว่ายังไม่มีความชัดเจนที่ตายตัวที่แน่ชัด ดังนั้น “การลองผิดลองถูก” ถือเป็นวิธีที่เหมาะสมที่สุดในการกำหนดจำนวนชั้น และจำนวนโหนดของชั้นซ่อนเร้น⁴⁸ ซึ่งหากมีจำนวนมากเกินไปจะทำให้ระยะเวลาในการเรียนรู้นาน แต่หากมีจำนวนน้อยเกินไปส่งผลให้ผลการเรียนรู้ของแบบจำลองมีความคลาดเคลื่อนและไม่มีประสิทธิภาพ ดังนั้น การศึกษาเปรียบเทียบจำนวนชั้น และการสุ่มจำนวนโหนดของชั้นซ่อนเร้นที่เหมาะสม เป็นสิ่งสำคัญในการเพิ่มประสิทธิภาพความแม่นยำการคาดการณ์การเกิด

การคัดเลือกตัวชี้วัดความถูกต้องของคาดการณ์ เพื่อหาค่าความคลาดเคลื่อนจากการคาดการณ์สามารถแบ่ง

ได้เป็น 2 ประเภทขึ้นอยู่กับตัวแปรสำหรับคาดการณ์แผ่นดินไหวในประเทศไทย คือ ตัวชี้วัดความถูกต้องที่ใช้สำหรับการคาดการณ์ขนาด เวลา และตำแหน่ง ได้แก่ MSE RMSE และ ส่วนตัวชี้วัดความถูกต้องของความน่าจะเป็นในการเกิดแผ่นดินไหว ประกอบด้วยตัวแปรที่บอกถึงจำนวนครั้งที่แบบจำลองสามารถคาดการณ์ได้ถูกต้อง และไม่ถูกต้อง

สรุปผลการศึกษา

จากการรวบรวมและวิเคราะห์การศึกษาคาดการณ์แผ่นดินไหวโดยอาศัย ANN มีจุดประสงค์เพื่อศึกษาแนวทางความเป็นไปได้ในการศึกษาของประเทศไทย สามารถสรุปได้ 3 ประเด็น ดังนี้

ประเด็นที่ 1 พบว่าลักษณะการเกิดแผ่นดินไหวของงานวิจัยที่รวบรวมได้นั้น มีสาเหตุจากการเคลื่อนที่ของแผ่นเปลือกโลก ซึ่งเกี่ยวข้องกับแนวรอยเลื่อนหรือรอยแตกในหิน แสดงให้เห็นถึงการเกิดแผ่นดินไหวที่มีความไม่สม่ำเสมอของพื้นที่ และเวลาการเกิด อีกทั้งมีแนวโน้มในการเกิดแผ่นดินไหวเพิ่มมากขึ้น โดยการคัดเลือกพื้นที่ศึกษาของแต่ละงานวิจัยพบว่าได้พิจารณาพื้นที่ที่เกิดแผ่นดินไหวขนาดรุนแรงที่สุดที่เคยเกิดขึ้น อีกทั้งมีการเกิดแผ่นดินไหวอย่างต่อเนื่องและอัตราการเกิดแผ่นดินไหวเพิ่มมากขึ้น โดยเฉพาะหลังจากการเกิดแผ่นดินไหวครั้งใหญ่ ส่วนลักษณะการเกิดแผ่นดินไหวของประเทศไทยส่วนใหญ่ พบว่าแผ่นดินไหวที่เกิดขึ้นภายในประเทศไทยมักเกิดจากแนวรอยเลื่อนที่มีพลัง จากข้อมูลการเกิดแผ่นดินไหวในปี ค.ศ. 2007-2018 แสดงให้เห็นว่ามีการเกิดแผ่นดินไหวเพิ่มขึ้นทุกปี หลังจากเกิดแผ่นดินไหวครั้งใหญ่ขนาด 6.3 แมกนิจูด แสดงให้เห็นว่าลักษณะการเกิดแผ่นดินไหว ขนาดแผ่นดินไหว รวมถึงอัตราการเกิดที่มีแนวโน้มเพิ่มสูงขึ้นนั้น มีรูปแบบข้อมูลใกล้เคียงกับงานวิจัยที่ได้ศึกษา จึงมีความเป็นไปได้ในการศึกษาการคาดการณ์แผ่นดินไหวในประเทศไทย

ประเด็นที่ 2 การพิจารณาตัวแปรข้อมูลนำเข้าของ ANN ปัจจัยที่สำคัญ คือ จำนวนข้อมูลที่ใช้สำหรับคาดการณ์ จำเป็นต้องมีปริมาณข้อมูลที่เพียงพอต่อการเรียนรู้และทดสอบ โดยตัวแปรข้อมูลนำเข้าที่เป็นไปได้สำหรับการคาดการณ์แผ่นดินไหวประเทศไทย คือ ตัวแปรที่ได้จากสมการความสัมพันธ์ G-R เนื่องจากสามารถวิเคราะห์ถึงพฤติกรรมแผ่นดินไหว และสะท้อนให้เห็นถึงการแปรสัณฐาน และวิเคราะห์ความสัมพันธ์ระหว่างขนาดแผ่นดินไหว และจำนวนครั้งที่เกิดขึ้นได้ โดยการคาดการณ์ขนาดแผ่นดินไหว และความน่าจะเป็นในการเกิด มีความเป็นไปได้ในการศึกษามากกว่าการคาดการณ์ตำแหน่งและเวลา

ประเด็นที่ 3 การออกแบบโครงสร้างสถาปัตยกรรมที่เหมาะสม พบว่าโครงสร้าง FFNN ที่มีการเรียนรู้แบบ BP

มีการใช้มากที่สุด เนื่องจากมีรูปแบบโครงสร้างที่ง่าย และไม่ซับซ้อน อีกทั้งยังพิจารณาค่าความผิดพลาดย้อนกลับ จนได้ผลลัพธ์ที่อยู่ในเกณฑ์ที่ยอมรับและมีความถูกต้องมากขึ้น

สำหรับการกำหนดจำนวนชั้นซ่อนเร้นและจำนวนโหนดของชั้นซ่อนเร้นนั้น ถือเป็นปัจจัยสำคัญที่ช่วยเพิ่มความแม่นยำในการคาดการณ์ของแบบจำลอง ซึ่งผลจากการเปรียบเทียบผลคาดการณ์แบบจำลองที่กำหนดจำนวนชั้นซ่อนเร้น 1, 2 และ 3 แสดงให้เห็นว่าแบบจำลองที่กำหนดจำนวนชั้นซ่อนเร้นจำนวน 2 ชั้น มีประสิทธิภาพในการคาดการณ์มากที่สุด โดยมีค่าความคลาดเคลื่อนต่ำสุดในการคาดการณ์ตำแหน่งและจำนวนวันในการเกิดแผ่นดินไหวครั้งถัดไปบริเวณพื้นที่รัฐแคลิฟอร์เนีย ประเทศอเมริกา 15.2 ไมล์ และ 5 วัน ตามลำดับ และมีค่าผิดพลาดรวมเฉลี่ยในการคาดการณ์แผ่นดินไหวบริเวณทางตอนเหนือของทะเลแดงเพียง 0.115 ส่วนจำนวนโหนดของชั้นซ่อนเร้น มีการกำหนด 3 รูปแบบ คือ มีจำนวนน้อยกว่าหรือเท่ากับจำนวนข้อมูลนำเข้า, มีจำนวนมากกว่าจำนวนข้อมูลนำเข้า และ มีจำนวน 50% ของข้อมูลนำเข้า ซึ่งจากการเปรียบเทียบผลการคาดการณ์ พบว่าแบบจำลองที่มีจำนวนโหนดของชั้นซ่อนเร้นเป็น 50% ของข้อมูลนำเข้า จะมีประสิทธิภาพในการคาดการณ์มากที่สุด โดยพบว่ามีค่าถูกต้องในการคาดการณ์มากกว่า 70% จากการคาดการณ์แผ่นดินไหวในประเทศญี่ปุ่น และมีค่าสัมประสิทธิ์สหสัมพันธ์อยู่ในช่วง 0.84-0.91 จากการคาดการณ์แผ่นดินไหวในประเทศอินเดียซึ่งแสดงให้เห็นถึงความสัมพันธ์ระหว่างค่าที่ได้จากการคาดการณ์กับค่าจริงในทิศทางเดียวกันระดับสูง

ดังนั้น ในการศึกษาคาดการณ์แผ่นดินไหวจึงควรกำหนดแบบจำลองให้มีจำนวนชั้น และจำนวนโหนดชั้นซ่อนเร้นที่แตกต่างกันออกไป เพื่อหาโครงสร้างสถาปัตยกรรมของแบบจำลองที่เหมาะสม และเพื่อเพิ่มประสิทธิภาพในการคาดการณ์ของแบบจำลอง

กิตติกรรมประกาศ

ขอขอบพระคุณ ทูสนับสนุนการทำวิจัย จากบัณฑิตวิทยาลัยมหาวิทยาลัยเชียงใหม่ และขอบพระคุณ กองเฝ้าระวังแผ่นดินไหว กรมอุตุนิยมวิทยา ที่อนุเคราะห์ข้อมูลเหตุการณ์แผ่นดินไหวในประเทศไทย

เอกสารอ้างอิง

1. Shimizu I, Osawa H, Seo T, Yasuike S, Sasaki S. Earthquake-related ground motion and groundwater pressure change at the Kamaishi Mine. *Engineering Geology* 1996;43(2):107-18.

2. Jiang M. Easily magnetic anomalies earthquake prediction. *MATEC Web of Conferences* 2016;63:1-5.
3. Hayakawa M. Electromagnetic phenomena related with earthquakes (earthquake prediction). *The International Workshop on Modern Science and Technology* 2008:393-8.
4. Guo G, Jie Y. Three Attempts of Earthquake Prediction with Satellite Cloud Images. *Natural Hazards and Earth System Sciences* 2013;13:91-5.
5. Jilani Z, Mehmood T, Alam A, Awais M, Iqbal T. Monitoring and descriptive analysis of radon in relation to seismic activity of Northern Pakistan. *Journal of Environmental Radioactivity* 2017;172:43-51.
6. Yamauchi H, Uchiyama H, Ohtani N, Ohta M. Unusual Animal Behavior Preceding the 2011 Earthquake off the Pacific Coast of Tohoku, Japan: A Way to Predict the Approach of Large Earthquakes. *Animals* 2014;4(2):131-45.
7. Kannan S. Innovative Mathematical Model for Earthquake Prediction. *Engineering Failure Analysis* 2014;41:89-95.
8. Sheng J, Mu D, Zhang H, Lv H. Seismotectonics Considered Artificial Neural Network Earthquake Prediction in Northeast Seismic Region of China. *The Open Civil Engineering Journal* 2015;9:522-8.
9. Sriram A, Rahanamayan S, Bourennani F. Artificial Neural Networks for Earthquake Anomaly Detection. *Journal of Advanced Computational Intelligence and Intelligent Informatics* 2014;18(5):701-13.
10. Emilio Florido, José L. Aznarte, Antonio Morales-Esteban, Martínez-Álvarez F. Earthquake magnitude prediction based on artificial neural networks: A survey. *Croatian Operational Research*. 2016;7:159-69.
11. Reyes J, Morales-Esteban A, Martínez-Álvarez F. Neural networks to predict earthquakes in Chile. *Applied Soft Computing* 2013;13(2):1314-28.
12. Cortés G, Martínez-Álvarez F, Troncoso A, Morales-Esteban A. Medium-large earthquake magnitude prediction in Tokyo with artificial neural networks. *Neural Comput & Applic* 2017:1043-55.
13. Wang Q, Guo Y, Yu L, Li P. Earthquake Prediction based on Spatio-Temporal Data Mining: An LSTM Network Approach. *IEEE Transactions on Emerging Topics in Computing* 2019:1-11.

14. Nanjo K, Holliday J, Chen C-C, Rundle J, Turcotte DL. Application of a modified pattern informatics method to forecasting the locations of future large earthquakes in the central Japan. *Tectonophysics* 2006;424:351-66.
15. Li C, Liu X. An improved PSO-BP neural network and its application to earthquake prediction. In *Proceedings of the Chinese Control and Decision Conference 2016*:3434-8.
16. Shah H, Ghazali R, Mohd Nawi N. Using Artificial Bee Colony Algorithm for MLP Training on Earthquake Time Series Data Prediction. *Second International Conference on Genetic and Evolutionary Computing 2011*:128-31.
17. Shao X, Li X, Li L, Hu X. The Application of Ant-Colony Clustering Algorithm to Earthquake Prediction. *Advances in Electronic Engineering, Communication and Management 2012*:145-50.
18. Zamani A, Sorbi M, Safavi AA. Application of neural network and ANFIS model for earthquake occurrence in Iran. *Earth Sci Inform 2013*:71-85.
19. Külahcı F, Inceöz M, Dogru M, Aksoy E, Baykara O. Artificial neural network model for earthquake prediction with radon monitoring. *Applied radiation and isotopes: including data, instrumentation and methods for use in agriculture. industry and medicine 2008*;67:212-9.
20. Panakkat A, Adeli H. Recurrent Neural Network for Approximate Earthquake Time and Location Prediction Using Multiple Seismicity Indicators. *Computer-Aided Civil and Infrastructure Engineering 2009*;24:280-92.
21. Adeli H, Panakkat A. A probabilistic neural network for earthquake magnitude prediction. *Neural Networks. 2009*;22(7):1018-24.
22. Madahizadeh R, Allamehzadeh M. Prediction of Aftershocks Distribution Using Artificial Neural Networks and Its Application on the May 12, 2008 Sichuan Earthquake. *Journal of Seismology and Earthquake Engineering. 2009*;11:111-20.
23. Spall H. Clarence Allen talks about the responsibilities in earthquake prediction. *Earthquake Information Bulletin (USGS) 1978*;10(4):116-9.
24. Narayanakumar S, Raja K. A BP Artificial Neural Network Model for Earthquake Magnitude Prediction in Himalayas, India. *Circuits and Systems 2016*; 7(11): 3456-68.
25. Abraham A, V R. A Particle Swarm Optimization-Backpropagation (PSO-BP) Model for the Prediction of Earthquake in Japan. In: Shetty NR et al (ed) *Emerging Research in Computing, Information, Communication and Applications. Advances in Intelligent Systems and Computing 2009*;882:435-41.
26. Panakkat A, Adeli H. Neural Network Models for earthquake Magnitude Prediction Using Multiple Seismicity Indicators. *International Journal of Neural Systems 2007*;17(01):13-33.
27. Sunkara S, Tiwari RK. Model dissection from earthquake time series: A comparative analysis using modern non-linear forecasting and artificial neural network approaches 2009:191-204.
28. Bodri B. A neural network model for earthquake occurrence. *Journal of Geodynamics 2001* ; 32(3): 289-310.
29. Sil A, Zarola A. Artificial neural networks (ANN) and stochastic techniques to estimate earthquake occurrences in Northeast region of India. *Annals of Geophysics 2017*:1-37.
30. Morales-Esteban A, Martínez-Álvarez F, Reyes J. Earthquake prediction in seismogenic areas of the Iberian Peninsula based on computational intelligence. *Tectonophysics 2013*;593:121-34.
31. Zollo A, Marzocchi W, Capuano P, Lomax A, Iannaccone G. Space and time behavior of seismic activity at Mt. Vesuvius volcano, Southern Italy 2002:625-40.
32. Shi Y, Bolt. The standard error of the Magnitude-frequency b value. *Bulletin of the Seismological Society of America 1982*;72(5):1677-87.
33. Niksarlioglu S, Kulahci F. An Artificial Neural Network Model for Earthquake Prediction and Relations between Environmental Parameters and Earthquakes. *WAS Engineering and Technology 2013* ; 7(2): 87-92.
34. Bhatia A, Pasari S, Mehta A. Earthquake Forecasting Using Artificial Neural Networks. *International Archives of the Photogrammetry, Remote Sensing & Spatial Information Sciences 2018*:823-7.

35. Zhang Q, Wang C. Using Genetic Algorithm to Optimize Artificial Neural Network: A Case Study on Earthquake Prediction. *IEEE* 2008:128-31.
36. Alarifi ASN, Alarifi NSN, Al-Humidan S. Earthquakes magnitude predication using artificial neural network in northern Red Sea area. *Journal of King Saud University-Science* 2012;24(4):301-13.
37. Martínez-Álvarez F, Reyes J, Morales-Esteban A, Rubio-Escudero C. Determining the best set of seismicity indicators to predict earthquakes. Two case studies: Chile and the Iberian Peninsula. *Knowledge-Based Systems* 2013;50:198-210.
38. Soleimani Zakeri NS, Pashazadeh S. Application of Neural Network Based on Genetic Algorithm in Predicting Magnitude of Earthquake in North Tabriz Fault (NW Iran) 2015;109(9):1715-22.
39. Moustira M, Avraamides M, Christodoulou C. Artificial neural networks for earthquake prediction using time series magnitude data or Seismic Electric Signals. *Expert Systems with Applications* 2011;38(12):15032-9.
40. Buscema M, Massini G, Maurelli G. Artificial Adaptive Systems to predict the magnitude of earthquakes. *Bollettino di Geofisica Teorica ed Applicata* 2015;56(2):227-56.
41. กรมอุตุนิยมวิทยา. สำนักเฝ้าระวังแผ่นดินไหว. รายงานการเกิดแผ่นดินไหวบริเวณประเทศไทย และพื้นที่ใกล้เคียง เดือนธันวาคม พ.ศ. 2561. กรุงเทพฯ. 2562.
42. กรมอุตุนิยมวิทยา. สำนักเฝ้าระวังแผ่นดินไหว. เหตุการณ์แผ่นดินไหวในประเทศไทยและใกล้เคียง. [สืบค้นเมื่อ 16 มกราคม 2562]; จาก: <https://earthquake.tmd.go.th/inside.htm>
43. โชติ เนื่องนันท์ นิคม ผึ้งคำ สมยศ ศรีคงรักษ์ ดวงกมล มา มีชัย และพลรัตน์ ทองเพิ่ม. แนวโน้มการเกิดแผ่นดินไหวในประเทศไทยและประเทศพม่า. *วารสารมหาวิทยาลัยทักษิณ*. 2561. 21(3): 167-173.
44. กรมอุตุนิยมวิทยา. สำนักเฝ้าระวังแผ่นดินไหว. รายงานการเกิดแผ่นดินไหวบริเวณจังหวัดเชียงราย. กรุงเทพฯ. 2557.
45. กรมอุตุนิยมวิทยา. สำนักเฝ้าระวังแผ่นดินไหว. ลักษณะเฉพาะของรูปแบบไหวสะเทือนบริเวณชายแดนประเทศไทย-ลาว-พม่า. กรุงเทพฯ. 2560.
46. Negarestani A, Setayeshi S, Ghannadi-Maragheh M, Akashe B. Layered neural networks based analysis of radon concentration and environmental parameters in earthquake prediction. *Journal of Environmental Radioactivity* 2002;62(3):225-33.
47. กรมชลประทาน. สำนักสำรวจด้านวิศวกรรมและธรณีวิทยา.(2560) สถานีตรวจวัดคลื่นสั่นสะเทือนพื้นดินในประเทศไทย.[สืบค้นเมื่อ 7 เมษายน 2563]; จาก: <http://survey.rid.go.th/th/index.php/2016-02-10-08-53-11/108-2016-03-02-03-11-0816/>
48. Plumb AP, Rowe RC, York P, Brown M. Optimisation of the predictive ability of artificial neural network (ANN) models: a comparison of three ANN programs and four classes of training algorithm. *Eur J Pharm Sci* 2005;25 (4-5):395-405.