

การศึกษาพฤติกรรมแผ่นดินไหวของประเทศนิวซีแลนด์ด้วยวิธีโคร่งข่ายประสาทเทียม

นางสาวสุนิสา เดียวล้ำ

โครงการนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิทยาศาสตรบัณฑิต

ภาควิชาธรณีวิทยา คณะวิทยาศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

ปีการศึกษา 2559

INVESTIGATION OF EARTHQUAKE ACTIVITIES OF NEW ZEALAND  
USING ARTIFICIAL NEURAL NETWORK

Miss Sunisa Dieoloh

A Project Submitted in Partial Fulfillment of the Requirements  
for the Degree of Bachelor of Science Program in Geology  
Department of Geology, Faculty of Science, Chulalongkorn University  
Academic Year 2016

หัวข้อโครงการ	การศึกษาพฤติกรรมแผ่นดินไหวของประเทศนิวซีแลนด์ ด้วยวิธีโครงข่ายประสาทเทียม
โดย	นางสาวสุนิสา เดียวเลื้อ
สาขาวิชา	ธรณีวิทยา
อาจารย์ที่ปรึกษาโครงการหลัก	รองศาสตราจารย์ ดร.สันติ ภัยหลบลี้
อาจารย์ที่ปรึกษาโครงการร่วม	รองศาสตราจารย์ ดร.ศรีเลิศ โชติพันธรัตน์

---

วันที่ส่ง.....  
วันที่อนุมัติ.....

---

อาจารย์ที่ปรึกษาโครงการหลัก  
(รองศาสตราจารย์ ดร.สันติ ภัยหลบลี้)

---

อาจารย์ที่ปรึกษาโครงการร่วม  
(รองศาสตราจารย์ ดร.ศรีเลิศ โชติพันธรัตน์)

นางสาวสุนิสา เดียวเลื้อ :

การศึกษาพฤติกรรมแผ่นดินไหวของประเทศนิวซีแลนด์ด้วยวิธีโครงข่ายประสาทเทียม.

(INVESTIGATION OF EARTHQUAKE ACTIVITIES OF NEW ZEALAND USING

ARTIFICIAL NEURAL NETWORK) อ.ที่ปรึกษาโครงการหลัก : รศ. ดร. สันติ ภัยหลบลี้, อ.ที่

ปรึกษาโครงการร่วม : รศ.ดร. ศรีเลิศ โชติพันธรัตน์, 163 หน้า

เหตุการณ์แผ่นดินไหวถือเป็นภัยพิบัติทางธรรมชาติที่ก่อให้เกิดผลกระทบทั้งต่อชีวิตและทรัพย์สินแก่ผู้ประสบภัยเป็นอย่างมาก ประเทศนิวซีแลนด์เป็นหนึ่งในประเทศที่มีกิจกรรมแผ่นดินไหวเกิดขึ้นมากเป็นอันดับต้นๆ ของโลก จึงมีข้อมูลการเกิดแผ่นดินไหวที่ถูกบันทึกไว้มากมาย งานวิจัยนี้มีวัตถุประสงค์เพื่อสร้างโครงข่ายประสาทเทียม (Artificial Neural Network) ซึ่งเป็นโมเดลคอมพิวเตอร์ เพื่อใช้ในการศึกษาพฤติกรรมแผ่นดินไหวของประเทศนิวซีแลนด์ โดยใช้ข้อมูลที่ได้จากฐานข้อมูลแผ่นดินไหว ประกอบด้วย ละติจูด ลองจิจูด ความลึกของจุดศูนย์กลางแผ่นดินไหว วัน เดือน ปี เวลาชั่วโมง และนาฬิกา และกำหนดให้โครงข่ายทำการคาดการณ์ขนาดของแผ่นดินไหวที่เกิดขึ้น โครงข่ายที่สร้างขึ้นเป็นโครงข่ายประสาทเทียมแบบหลายชั้น (Multilayer Neural Network) ที่มีการเรียนรู้แบบแพร่ย้อนกลับ (Feedforward Backpropagation Neural Network) ทำการหาฟังก์ชันการเรียนรู้ที่เหมาะสมต่อพฤติกรรมการเกิดแผ่นดินไหวของประเทศนิวซีแลนด์จากทั้งหมด 12 ฟังก์ชันการเรียนรู้ นอกจากนี้ยังทำการปรับปรุงค่าพารามิเตอร์ในแต่ละฟังก์ชัน ปรับจำนวนชั้นซ่อนและจำนวนโหนดในชั้นซ่อน เพื่อให้โครงข่ายประสาทเทียมมีประสิทธิภาพมากยิ่งขึ้น

จากผลการวิจัยพบว่าโครงข่ายประสาทเทียมที่เหมาะสมต่อพฤติกรรมการเกิดแผ่นดินไหวของประเทศนิวซีแลนด์คือโครงข่ายประสาทเทียมที่มีฟังก์ชันการเรียนรู้แบบ Levenberg-Marquardt Backpropagation ที่มีจำนวนโหนดในชั้นแอบแฝงเท่ากับ 17 เป็นโครงข่ายประสาทที่มีประสิทธิภาพมากที่สุดต่อพฤติกรรมแผ่นดินไหวของประเทศนิวซีแลนด์ โดยมีค่าสัมประสิทธิ์การตัดสินใจ ( $R^2$ ) เท่ากับ 0.0889 และ 0.0232 ในข้อมูลชุดฝึกสอนและในข้อมูลชุดทดสอบ ตามลำดับ และพบว่าความหลากหลายของข้อมูลที่ใช้ในการฝึกสอนโครงข่ายมีผลต่อประสิทธิภาพการทำนายโครงข่ายประสาทเทียม

ภาควิชา.....ธรณีวิทยา.....ลายมือชื่อนิสิต.....

สาขาวิชา.....ธรณีวิทยา.....ลายมือชื่อ อ.ที่ปรึกษาหลัก.....

ปีการศึกษา.....2559.....ลายมือชื่อ อ.ที่ปรึกษาร่วม.....

# # 5632745123 : MAJOR GEOLOGY

KEYWORDS : FEEDFORWARD BACKPROPAGATION / MEAN SQUARE ERROR

SUNISA DIEOLOH : INVESTIGATION OF EARTHQUAKE ACTIVITIES OF NEW ZEALAND USING ARTIFICIAL NEURAL NETWORK. ADVISOR : ASSOC. PROF. SANTI PAILOPLEE, Ph.D., CO-ADVISOR: ASSOC PROF. SRILERT CHOTPANTARAT, Ph.D., 47 pp.

Earthquake is natural hazard that effects extremely lives and damages facilities in an area, which is occurred. There are lots of data has been collected due the earthquake activities in New Zealand because New Zealand is one of the country in the world, where Earthquake occurred often. The objective of this study is creating Artificial Neural Network (ANN) and computer model to investigate the earthquake of New Zealand. We use earthquake data from earthquake catalogue, which composes of latitude longitude depth date and time. We specify the ANN to predict the earthquake magnitude. We build the Multilayer Neural Network with feedforward backpropagation for learning earthquake in New Zealand. We generate 12 ANN with 12 transfer functions to find the proper one with New Zealand earthquake activities. Finally, we modify ANN by rectify parameters in the transfer functions, number of hidden layer, and number of node in hidden layer to reach the maximum effective of ANN.

The result showed that the most proper ANN for earthquake activities of New Zealand is the ANN with Levenbarg-Marquardt Backpropagation transfer function together with 17 number of nodes in hidden layer. The accuracy of the prediction and coefficient of determination ( $R^2$ ) in training and testing step are 0.0889 and 0.0232, respectively. Moreover, our study founded that variation of data in training step has significantly influenced on evaluation efficiency of ANN.

Department : ..Geology.....Student's Signature.....  
 Field of Study : ..Geology.....Advisor's Signature.....  
 Academic Year : 2016.....Co-advisor's Signature.....

## กิตติกรรมประกาศ

โครงการวิจัยฉบับนี้ สำเร็จลุล่วงได้ด้วยอาศัยความอนุเคราะห์จากบุคคลหลายฝ่าย ผู้วิจัยขอกราบขอบพระคุณในความอนุเคราะห์ของท่านมา ณ ที่นี้ ขอขอบพระคุณรองศาสตราจารย์ ดร. สันติ ภัยหลบลี้ อาจารย์ที่ปรึกษาโครงการ ซึ่งได้ให้ความรู้เรื่องภัยพิบัติแผ่นดินไหว ตลอดจนคำแนะนำและข้อคิดเห็น อันเป็นประโยชน์ ทั้งยังช่วยแก้ปัญหาที่เกิดขึ้นในระหว่างการทำงานวิจัย จนโครงการวิจัยฉบับนี้สำเร็จลุล่วงไปได้ด้วยดี ขอขอบพระคุณรองศาสตราจารย์ ดร.ศรีเลิศ โชติพันธรัตน์ อาจารย์ที่ปรึกษาโครงการร่วม ซึ่งได้สนับสนุนข้อมูลความรู้เกี่ยวกับโครงข่ายประสาทเทียม การใช้งานและข้อมูลตัวอย่างรูปแบบการส่งงานโปรแกรมคอมพิวเตอร์แมทแลป (Matlab) ซึ่งมีส่วนสำคัญในการดำเนินงานวิจัย ทำให้งานวิจัยสัมฤทธิ์ผลและสำเร็จลุล่วงได้ขอขอบพระคุณในความเอื้อเฟื้อของนาย ธนภัทร คชนวิวงษ์ ที่ได้ให้คำปรึกษาและให้ความช่วยเหลือด้านเอกสารความรู้ ตลอดจนข้อมูลที่เกี่ยวข้องกับการใช้การโปรแกรมคอมพิวเตอร์ กระบวนการทำงานของโครงข่ายประสาทเทียม ทั้งยังช่วยให้คำปรึกษาแก่ผู้วิจัยเมื่อเกิดปัญหา ขอขอบคุณเพื่อน ๆ ชั้นปีที่ 4 และน้อง ๆ ทั้งชั้นปีที่ 3 และชั้นปีที่ 2 ภาควิชาธรณีวิทยา คณะวิทยาศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย ปีการศึกษา 2559 ที่ช่วยเหลือและเป็นกำลังใจแก่ผู้วิจัยมาโดยตลอด นอกจากนี้ขอขอบคุณบริษัท KrisEnergy Limited ที่สนับสนุนทุนการศึกษาแก่ผู้วิจัยตลอด 3 ปีการศึกษา

สุดท้ายนี้ ผู้วิจัยขอกราบขอบพระคุณบิดามารดาและครอบครัว ซึ่งเปิดโอกาสให้ได้รับการศึกษาเล่าเรียน ช่วยเหลือและให้กำลังใจแก่ผู้วิจัยอย่างเสมอมาจนสำเร็จการศึกษา

## สารบัญ

หน้า

บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ.....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ.....	ช
สารบัญภาพ.....	ฌ
สารบัญตาราง.....	ฎ
บทที่ 1 บทนำ.....	1
1.1 ที่มาและความสำคัญ.....	1
1.2 วัตถุประสงค์.....	2
1.3 ผลที่คาดว่าจะได้รับ.....	2
1.4 พื้นที่ศึกษา.....	2
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	4
2.1 ทฤษฎีที่เกี่ยวข้อง.....	4
2.2 งานวิจัยที่เกี่ยวข้อง.....	11
2.3 ลักษณะทั่วไปของพื้นที่ศึกษา.....	13
บทที่ 3 ระเบียบวิธีวิจัย.....	15
3.1 ขั้นตอนการศึกษาวิจัย.....	15
3.2 รวบรวมข้อมูลการเกิดแผ่นดินไหวในพื้นที่ประเทศนิวซีแลนด์.....	16
3.3 ปรับปรุงคุณภาพฐานข้อมูลแผ่นดินไหว.....	18
3.4 วิเคราะห์ข้อมูลด้วยโครงข่ายประสาท.....	29

3.5 การทดสอบประสิทธิภาพโครงข่าย.....	33
บทที่ 4 ผลการศึกษา.....	34
4.1 การวิเคราะห์ข้อมูลด้วยโครงข่ายประสาทเทียมของฟังก์ชันการแปลงทั้ง 12 ฟังก์ชัน....	34
4.2 ผลการปรับปรุงโครงข่าย.....	36
บทที่ 5 อภิปรายและสรุปผลการศึกษา.....	43
5.1 อภิปรายผลการศึกษา.....	43
5.2 สรุปผลการศึกษา.....	45
5.3 ข้อเสนอแนะ.....	45
บรรณานุกรม.....	47



## สารบัญภาพ

หน้า

รูปที่ 1.1 แสดงขอบเขตของพื้นที่ศึกษา ครอบคลุมประเทศนิวซีแลนด์.....	3
รูปที่ 2.1 เปรียบเทียบระหว่างเซลล์ประสาทชีวภาพกับโครงข่ายประสาทเทียม.....	4
รูปที่ 2.2 แสดงส่วนประกอบของโครงข่ายประสาทเทียม.....	5
รูปที่ 2.3 แสดงโครงสร้างโครงข่ายประสาทเทียมแบบชั้นเดียวและหลายชั้น.....	6
รูปที่ 2.4 แสดงรูปแบบการเรียนรู้แบบไม่มีผู้สอนและรูปแบบการเรียนรู้แบบมีผู้สอน.....	7
รูปที่ 2.5 แสดงโครงข่ายประสาทแบบแพร่เดิหน้าและโครงข่ายประสาทแบบแพร่ย้อนกลับ.....	8
รูปที่ 2.6 แสดงฟังก์ชันการแปลงแบบ Linear Transfer function ฟังก์ชันการแปลงแบบ Hard-Limit function และฟังก์ชันการแปลงแบบ Log-Sigmoid function.....	9
รูปที่ 2.7 แสดงรูปความสัมพันธ์ระหว่างค่า $J$ กับ $\theta$ ใน 3 มิติ.....	10
รูปที่ 2.8 แสดงจุดที่เรียกว่า Local minimum และจุด Global minimum.....	11
รูปที่ 2.9 แสดงกราฟความสัมพันธ์ของระยะเวลาในการสันสะเทือนของโครงข่ายประสาทเทียมที่มีข้อมูลเข้าจำนวน 6 ข้อมูล โดย Arjun และ Kumar (2011) .....	12
รูปที่ 2.10 แสดงกราฟความสัมพันธ์ของระยะเวลาในการสันสะเทือนของโครงข่ายประสาทเทียมที่มีข้อมูลเข้าจำนวน 3 ข้อมูล โดย Arjun และ Kumar (2011) .....	13
รูปที่ 2.11 พื้นที่ทวีปซีแลนด์เดียวและแสดงแนวการมุดตัวและการกระจายตัวของรอยเลื่อนมีพลังบริเวณประเทศนิวซีแลนด์.....	14
รูปที่ 3.1 แสดงกราฟความสัมพันธ์ระหว่างขนาดแผ่นดินไหว $M_w - m_b$ , $M_w - M_s$ และ $m_b - M_L$ .....	20
รูปที่ 3.2 แสดงสมมติฐานการคัดเลือกแผ่นดินไหวหลักออกจากแผ่นดินไหวนำและแผ่นดินไหวตามจากกลุ่มวิจัยต่าง ๆ ที่นำเสนอในอดีต.....	22
รูปที่ 3.3 แสดงผลวิเคราะห์การจัดกลุ่มแผ่นดินไหวตามสมมติฐานของ Gardner และKnopoff.....	23
รูปที่ 3.4 แสดงผลสรุปข้อมูลหลังทำการปรับปรุงคุณภาพด้วยการคัดเลือกกลุ่มแผ่นดินไหวหลัก....	23

รูปที่ 3.5 แสดงการกระจายตัวของจุดเหนือศูนย์เกิดแผ่นดินไหวที่ได้จากการรวบรวมข้อมูลแผ่นดินไหวและที่ได้จากการคัดเลือกกลุ่มแผ่นดินไหวหลักแล้ว.....	24
รูปที่ 3.6 แสดงการเปรียบเทียบระหว่างกราฟความถี่สะสมของข้อมูลแผ่นดินไหวก่อนดำเนินการปรับปรุงฐานข้อมูลและข้อมูลแผ่นดินไหวหลังผ่านกระบวนการคัดเลือกกลุ่มแผ่นดินไหวหลัก.....	25
รูปที่ 3.7 แสดงข้อมูลแผ่นดินไหวหลังทำการกำจัดความผิดพลาดที่เกิดจากกิจกรรมการตรวจวัด...	25
รูปที่ 3.8 แสดงการเปรียบเทียบกราฟความถี่สะสมของข้อมูลแผ่นดินไหวระหว่างข้อมูลแผ่นดินไหวหลังผ่านกระบวนการคัดเลือกกลุ่มแผ่นดินไหวหลักและข้อมูลแผ่นดินไหวหลังจากกำจัดผลกระทบจากการกระทำของมนุษย์.....	26
รูปที่ 3.9 แสดงการกระจายตัวของจุดเหนือศูนย์เกิดแผ่นดินไหวที่ได้จากการคัดเลือกกลุ่มแผ่นดินไหวหลักและที่ได้จากการกำจัดความผิดพลาดที่เกิดจากกิจกรรมการตรวจวัด.....	26
รูปที่ 3.10 แสดงการคัดเลือกแผ่นดินไหวที่มีความสมบูรณ์จากเครื่องตรวจวัด.....	28
รูปที่ 3.11 แสดงการกระจายตัวของจุดเหนือศูนย์เกิดแผ่นดินไหวที่ได้จากการกำจัดความผิดพลาดที่เกิดจากกิจกรรมการตรวจวัดและที่ได้จากการคัดเลือกระดับของแผ่นดินไหวที่มีความสมบูรณ์.....	28
รูปที่ 3.12 แสดงหน้าจอพื้นฐานของโปรแกรม Matlab2015a.....	29
รูปที่ 3.13 แสดงตัวอย่างชุดคำสั่งการสร้างโครงข่ายประสาทเทียม.....	31
รูปที่ 3.14 หน้าต่างแสดงการทำงานของโครงข่าย.....	32
รูปที่ 3.15 แสดงหน้าต่างประสิทธิภาพการทำงานของโครงข่าย.....	33
รูปที่ 4.1 ภาพหน้าต่างแสดงประสิทธิภาพการทำงานของโครงข่ายประสาทเทียมที่มีฟังก์ชันการแปลงแบบ trainlm.....	34
รูปที่ 4.2 ภาพหน้าต่างแสดงประสิทธิภาพการทำงานของโครงข่ายประสาทเทียมที่มีฟังก์ชันการแปลงแบบ trainsgd.....	35
รูปที่ 4.3 ภาพหน้าต่างแสดงประสิทธิภาพการทำงานของโครงข่ายประสาทเทียมที่มีฟังก์ชันการแปลงแบบ trainsgdm.....	35
รูปที่ 4.4 ภาพหน้าต่างแสดงประสิทธิภาพการทำงานของโครงข่ายประสาทเทียมที่มีฟังก์ชันการแปลงแบบ trainlm จากการกำหนดตัวแปรตามตาราง 4.1.....	38

รูปที่ 4.5 ภาพหน้าตาแสดงกราฟการถดถอยของจากการเรียนรู้ของโครงข่ายประสาทเทียมที่มีฟังก์ชันการแปลงแบบ trainlm จากการกำหนดตัวแปรตามตาราง 4.1..... 38

รูปที่ 4.6 ภาพหน้าตาแสดงประสิทธิภาพการทำงานของโครงข่ายประสาทเทียมที่มีฟังก์ชันการแปลงแบบ trained จากการศึกษาที่กำหนดตัวแปรตามตาราง 4.2..... 40

รูปที่ 4.7 ภาพหน้าตาแสดงกราฟการถดถอยของจากการเรียนรู้ของโครงข่ายประสาทเทียมที่มีฟังก์ชันการแปลงแบบ trained จากการศึกษาที่กำหนดตัวแปรตามตาราง 4.2..... 40

รูปที่ 4.8 ภาพหน้าตาแสดงประสิทธิภาพการทำงานของโครงข่ายประสาทเทียมที่มีฟังก์ชันการแปลงแบบ trainedm จากการศึกษาที่กำหนดตัวแปรตามตาราง 4.3..... 41

รูปที่ 4.9 ภาพหน้าตาแสดงกราฟการถดถอยของจากการเรียนรู้ของโครงข่ายประสาทเทียมที่มีฟังก์ชันการแปลงแบบ trainedm จากการศึกษาที่กำหนดตัวแปรตามตาราง 4.3..... 42

รูปที่ 5.1 กราฟแสดงความสัมพันธ์ระหว่างลอการิทึมของค่าขนาดแผ่นดินไหวที่ได้จากโครงข่ายประสาทเทียม  $\log(\text{Output})$  กับค่าขนาดแผ่นดินไหวที่ตรวจวัดได้จริง (Target)..... 43

รูปที่ 5.2 แสดงสัดส่วนของข้อมูลขนาดแผ่นดินไหวในชุดการเรียนรู้..... 46

## สารบัญตาราง

	หน้า
ตาราง 3.1 แสดงตัวอย่างรายละเอียดการบันทึกฐานข้อมูลแผ่นดินไหว .....	16
ตาราง 3.2 แสดงชุดคำสั่งของฟังก์ชันการแปลงแต่ละชนิดในโปรแกรม Matlab2015a.....	30
ตาราง 4.1 แสดงค่าพารามิเตอร์ต่าง ๆ ในฟังก์ชัน trainlm ที่ให้ประสิทธิภาพที่ดีที่สุด.....	37
ตาราง 4.2 แสดงค่าตัวแปรต่าง ๆ ในฟังก์ชัน trainingd ที่ให้ประสิทธิภาพที่ดีที่สุด.....	39
ตาราง 4.3 แสดงค่าตัวแปรต่าง ๆ ในฟังก์ชัน trainingdm ที่ให้ประสิทธิภาพที่ดีที่สุด.....	41
ตาราง 5.1 แสดงค่าความแม่นยำเป็นเปอร์เซ็นต์ของโครงข่ายประสาทเทียมในการคาดการณ์ค่าขนาดแผ่นดินไหว.....	44

# บทที่ 1

## บทนำ

### 1.1 ที่มาและความสำคัญ

พิบัติภัยแผ่นดินไหวเป็นหนึ่งในภัยพิบัติทางธรรมชาติที่ส่งผลกระทบต่อทั้งชีวิตและทรัพย์สินของมนุษย์เป็นอย่างมาก การเกิดแผ่นดินไหวแต่ละครั้งพลังงานที่ปลดปล่อยออกมาเทียบเท่าหรือมากกว่าพลังงานจากการระเบิดของระเบิดปรมาณูที่ทำลายเมืองฮิโรชิมาและเมืองนางาซากิในช่วงสงครามโลกครั้งที่ 2 ประกอบกับพิบัติภัยแผ่นดินไหวยังไม่สามารถทำนายได้ในปัจจุบัน แผ่นดินไหวจึงจัดเป็นภัยพิบัติอันตรายที่มนุษย์คำนึงถึงและหวาดกลัวอยู่เสมอ การศึกษาทำความเข้าใจเหตุการณ์แผ่นดินไหวที่เคยเกิดขึ้นและถูกบันทึกไว้ มีความสำคัญในการพยายามคาดการณ์ถึงความเสี่ยงของการเกิดแผ่นดินไหว เพื่อนำมาช่วยในการป้องกันและลดผลกระทบจากแผ่นดินไหวในแต่ละบริเวณ การคาดการณ์และทำนายการเกิดแผ่นดินไหวในปัจจุบันมีหลายวิธี สามารถแบ่งได้ตามช่วงเวลาคือ การทำนายระยะยาว (long-term prediction) เช่น การศึกษาช่องว่างแผ่นดินไหว (seismic gap) การศึกษาคาบอุบัติซ้ำ (recurrence Interval) เป็นต้น และ การทำนายระยะสั้น (short-term prediction) เช่น การศึกษาพฤติกรรมความผิดปกติของสัตว์ การศึกษาแสงแผ่นดินไหวเมฆแผ่นดินไหว หรือเหตุการณ์ต่างๆที่เป็นสัญญาณบอกเหตุ (precursor) ที่มักเกิดขึ้นก่อนการเกิดแผ่นดินไหว การทำนายทั้งสองรูปแบบดังที่กล่าวไปแล้วนั้นเป็นลักษณะการทำนายที่กว้างและไม่แน่นอน จึงได้มีการพัฒนาการศึกษาแผ่นดินไหวเพิ่มขึ้นอีกในหลากหลายวิธี ระบบโครงข่ายประสาทเทียม (Artificial Neural Network) เป็นระบบการวิเคราะห์ทางคอมพิวเตอร์ที่ถูกนำมาศึกษาพฤติกรรมการเกิดแผ่นดินไหว เนื่องจากคอมพิวเตอร์มีประสิทธิภาพในการประมวลผลข้อมูลแผ่นดินไหวที่มีการบันทึกไว้เป็นจำนวนมากได้อย่างรวดเร็ว โครงข่ายจะทำการเชื่อมโยงข้อมูลแผ่นดินไหว เพื่อหาและจดจำความสัมพันธ์ของข้อมูลเหล่านั้นไว้ในโครงข่ายที่สร้างขึ้นมา เมื่อโครงข่ายถูกพัฒนาจนมีประสิทธิภาพจะสามารถประมวลผลข้อมูลใหม่ที่โครงข่ายไม่เคยเรียนรู้มาก่อนได้ นอกจากนี้การศึกษาโดยใช้โครงข่ายประสาทเทียมทำให้สามารถคาดการณ์การเกิดแผ่นดินไหวในแต่ละบริเวณได้ทั้งระยะยาวและระยะสั้น เมื่อมีข้อมูลแผ่นดินไหวที่ถูกบันทึกไว้เพียงพอร่วมกับโครงข่ายประสาทเทียมที่พัฒนาให้มีความเหมาะสมตามจุดมุ่งหมายที่ต้องการ

โครงข่ายประสาทเทียมถูกนำมาใช้ศึกษาแผ่นดินไหวในหลายพื้นที่และหลากหลายวัตถุประสงค์ งานวิจัยของ Xie และคณะ (2011) ใช้โครงข่ายประสาทเทียมศึกษาแผ่นดินไหวในจีนตะวันออกโดยการวิเคราะห์ข้อมูลพื้นที่ (ละติจูดและลองจิจูด) เวลา (วัน เดือน ปี) และแมกนิจูดแผ่นดินไหว เพื่อ

ทำนายเวลาในการเกิดแผ่นดินไหวครั้งถัดไป งานวิจัยของ Arjun และ Kumar (2011) ใช้โครงข่ายประสาทเทียมศึกษาข้อมูลแผ่นดินไหวในประเทศญี่ปุ่นโดยใช้ข้อมูลแผ่นดินไหวแบบเดียวกับงานวิจัยของ Xie และคณะ (2011) รวมกับข้อมูลของคลื่นไหวสะเทือน และข้อมูลลักษณะดินในพื้นที่ศึกษา เพื่อทำนายระยะเวลาในการสั่นสะเทือนจากการเกิดแผ่นดินไหว โดยพบว่าประสิทธิภาพการทำงานและความถูกต้องของผลลัพธ์จากโครงข่ายออกมาในช่วงที่ยอมรับได้ ในงานวิจัยนี้จึงต้องการสร้างโมเดลโครงข่ายประสาทเทียมขึ้นมาโดยใช้ข้อมูลแผ่นดินไหวของประเทศนิวซีแลนด์ เนื่องจากประเทศนิวซีแลนด์มีการเกิดแผ่นดินไหวบ่อยครั้ง ข้อมูลแผ่นดินไหวจึงมีมากพอในการพัฒนาโมเดลโครงข่ายประสาทเทียมให้มีประสิทธิภาพเพื่อคาดการณ์สถานการณ์แผ่นดินไหวได้ ทั้งนี้ยังสามารถนำงานวิจัยนี้ไปใช้เป็นต้นแบบในการพัฒนาโครงข่ายประสาทเทียมเพื่อปรับใช้กับพื้นที่อื่น ๆ ได้อีกด้วย

## 1.2 วัตถุประสงค์

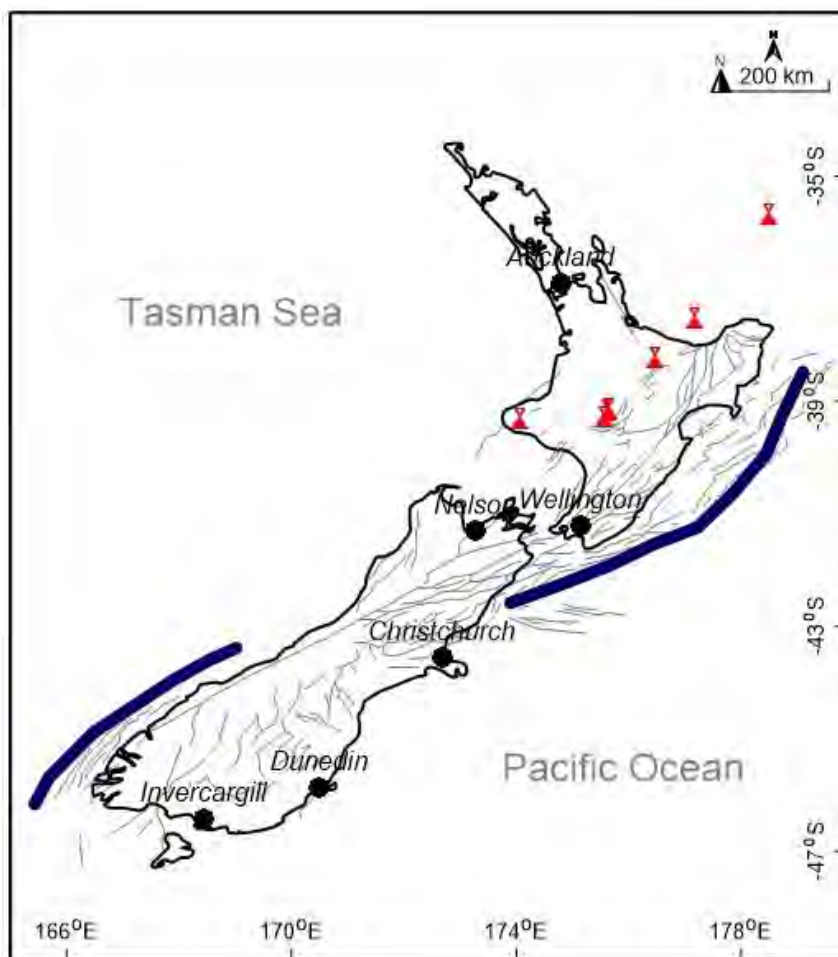
ศึกษาพฤติกรรมการเกิดแผ่นดินไหวในประเทศนิวซีแลนด์โดยใช้โครงข่ายประสาทเทียมและพัฒนาโครงข่ายให้มีประสิทธิภาพในการคาดการณ์สถานการณ์แผ่นดินไหวในประเทศนิวซีแลนด์ได้

## 1.3 ผลที่คาดว่าจะได้รับ

โครงข่ายประสาทเทียมที่มีประสิทธิภาพในการคาดการณ์แผ่นดินไหวของประเทศนิวซีแลนด์ได้อย่างมีประสิทธิภาพ และเป็นงานวิจัยพื้นฐานในการพัฒนาใช้โครงข่ายประสาทเทียมเพื่อประเมินสถานการณ์แผ่นดินไหวในพื้นที่อื่นได้

## 1.4 พื้นที่ศึกษา

พื้นที่ศึกษาตั้งอยู่บริเวณละติจูดที่ 164.998 ถึง 179.875 ลองจิจูด - 48.942 ถึง - 32.093 ครอบคลุมพื้นที่ประเทศนิวซีแลนด์ ดังแสดงในรูปที่ 1.1



รูปที่ 1.1 แสดงขอบเขตของพื้นที่ศึกษา ครอบคลุมประเทศนิวซีแลนด์

## บทที่ 2

### ทฤษฎีและงานวิจัยที่เกี่ยวข้อง


#### 2.1 ทฤษฎีที่เกี่ยวข้อง

##### 2.1.1 โครงข่ายประสาทเทียม

โครงข่ายประสาทเทียม (Artificial Neural Network) คือโมเดลคอมพิวเตอร์ซึ่งเป็นรูปแบบหนึ่งของงานด้านปัญญาประดิษฐ์ (Artificial Intelligence: AI) โดยทำการจำลองรูปแบบการทำงานของสมองมนุษย์ที่เป็นโครงข่ายประสาทชีวภาพ (Biological Network) ประกอบด้วยจุดประสานประสาท (Synapse) ที่ทำหน้าที่ส่งสัญญาณระหว่างเซลล์ประสาท (Neuron) แต่ละเซลล์ โครงข่ายประสาทเทียมสามารถหาความสัมพันธ์ของข้อมูลนำเข้า (input) และข้อมูลส่งออก (output) โดยใช้ฟังก์ชันการแปลง (Transfer function) เป็นตัวกำหนดสัญญาณส่งออก และจำลองตัวเซลล์ประสาทด้วยโหนด (node) ซึ่งมีความสามารถในการรับข้อมูล ประมวลผล และส่งข้อมูลออกสู่โหนดอื่น ๆ ได้ เช่นเดียวกับเซลล์ประสาทของมนุษย์

การทำงานของโครงข่ายประสาทเทียมอาศัยคุณสมบัติของโครงข่ายที่เลียนแบบมาจากพัฒนาการทางด้านสมองของมนุษย์คือ การเรียนรู้ (learning) และการระลึกหรือจดจำ (recall) ในการหาความสัมพันธ์ของข้อมูล เก็บรวมไว้เป็นความรู้ (knowledge) เพื่อปรับใช้กับข้อมูลอื่นที่มีรูปแบบคล้ายกัน

โครงข่ายประสาทเทียมสามารถนำมาวิเคราะห์ข้อมูลเพื่อใช้งานได้หลากหลายวัตถุประสงค์ ซึ่งได้แก่ การคาดเดา (prediction) การจัดลำดับหมวดหมู่ (classification) การเชื่อมโยงข้อมูล (data association) กระบวนการสร้างความคิด (data conceptualization) การกลั่นกรองข้อมูล (data filtering)



รูปที่ 2.1 เปรียบเทียบระหว่างเซลล์ประสาทชีวภาพ (ซ้าย) กับโครงข่ายประสาทเทียม (ขวา)

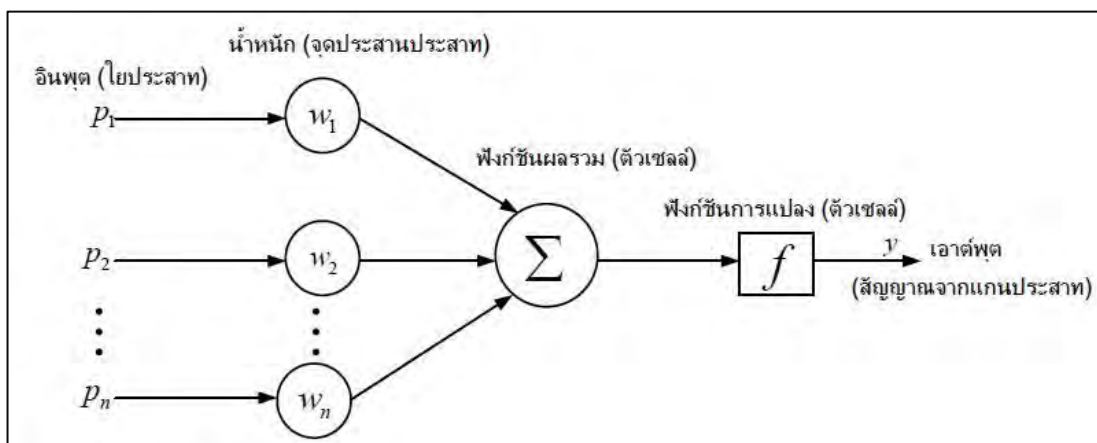
(อำภา สารศิริ, 2016)



### 2.1.2 องค์ประกอบของโครงข่ายประสาทเทียม


องค์ประกอบของโครงข่ายประสาทเทียมมี 5 ส่วนหลัก คือ

1. ข้อมูลป้อนเข้า (input) จำเป็นต้องเป็นข้อมูลตัวเลขเนื่องจากคอมพิวเตอร์ต้องนำปริมาณมาใช้ในการคำนวณ
2. ข้อมูลส่งออก (output) ผลลัพธ์ที่ได้จากการการเรียนรู้ของโครงข่าย
3. ค่าน้ำหนัก (weights) หรือ ค่าความรู้ (knowledge) เป็นค่าความสัมพันธ์ของข้อมูลในแต่ละโหนด โดยค่านี้จะถูกเก็บเป็นค่าทักษะสำหรับโครงข่าย เพื่อใช้ในการวิเคราะห์ข้อมูลอื่นที่เป็นรูปแบบเดียวกัน
4. ฟังก์ชันผลรวม (summation function) ค่าผลรวมของข้อมูลป้อนเข้ากับค่าน้ำหนัก
5. ฟังก์ชันการแปลง (transfer function) ฟังก์ชันการทำงานของโครงข่ายประสาทเทียมทำหน้าที่ในการประสานและแปลงข้อมูลให้พร้อมสำหรับการประมวลผลความสัมพันธ์ของข้อมูล เช่น ฟังก์ชันซิกมอยด์ (sigmoid function) ไฮเพอร์โบลิกแทนเจนต์ฟังก์ชัน (hyperbolic tangent function)



รูปที่ 2.2 แสดงส่วนประกอบของโครงข่ายประสาทเทียม (อำภา สาระศิริ, 2016)

โครงข่ายประสาทเทียมเป็นการเชื่อมโยงข้อมูลระหว่างโหนดจำนวนมากเข้าด้วยกัน โดยสามารถแบ่งการเชื่อมโยงออกเป็นกลุ่มย่อยที่เรียกว่า ชั้น (layer) โดยมี 3 ชั้นหลักคือ ชั้นรับข้อมูลป้อนเข้า (input layer) ชั้นส่งข้อมูลออก (output layer) และชั้นแอบแฝง (hidden layer) เป็นชั้นที่อยู่ระหว่างชั้นข้อมูลป้อนเข้าและชั้นส่งข้อมูลออก ทำให้สามารถแบ่งลักษณะของโครงข่ายประสาทเทียมออกได้เป็น 2 แบบหลัก คือ โครงข่ายแบบชั้นเดียวที่แค่ชั้นรับข้อมูลป้อนเข้าและชั้นส่งข้อมูลออก โดยข้อมูลจะถูกประมวลผลและหาความสัมพันธ์ในชั้นส่งข้อมูลออกเท่านั้นและอีกแบบคือโครงข่ายแบบหลายชั้น ซึ่งนิยมใช้ในการแก้ปัญหาที่มีความซับซ้อนเกินกว่าที่โครงข่ายแบบชั้นเดียวจะแก้ได้ โครงข่ายแบบหลายชั้นประกอบด้วยชั้นรับข้อมูลเข้า ชั้นส่งข้อมูลออก และมีชั้นแอบแฝงตั้งแต่ 1 ชั้นขึ้นไป

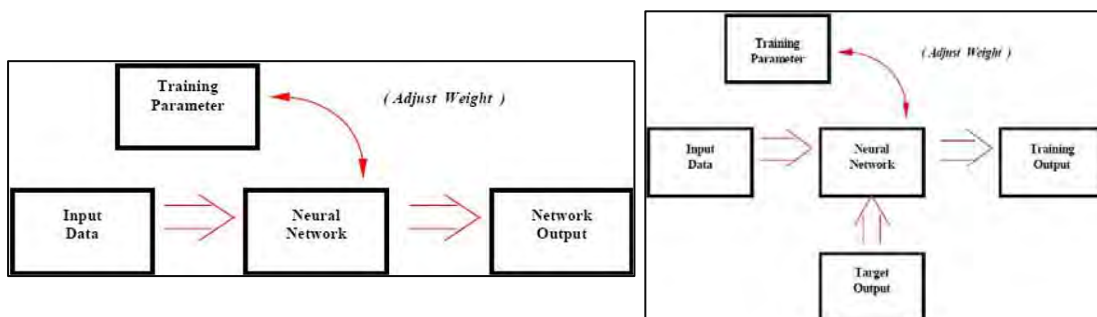


รูปที่ 2.3 แสดงโครงสร้างโครงข่ายประสาทเทียมแบบชั้นเดียว (ซ้าย) และโครงสร้างโครงข่ายประสาทเทียมแบบหลายชั้น (ขวา)

### 2.1.3 การเรียนรู้

กระบวนการเรียนรู้ (learning process) ของโครงข่ายประสาทเทียมมี 2 รูปแบบ คือ การเรียนรู้แบบไม่มีผู้สอน (Unsupervised learning) ข้อมูลที่ใช้สร้างโครงข่ายจะประกอบด้วยข้อมูลป้อนเข้าเพียงอย่างเดียวโดยไม่มีการกำหนดค่าผลลัพธ์ที่ต้องการให้แก่โครงข่าย การปรับค่าน้ำหนักสำหรับข้อมูลใหม่ที่เข้ามาจะทำโดยการเทียบเคียงกับข้อมูลตั้งต้นที่ใช้สร้างโครงข่าย

อีกรูปแบบหนึ่งคือการเรียนรู้แบบมีผู้สอน (Supervised learning) จะประกอบด้วยข้อมูลตั้งต้นที่ต้องการสอนโครงข่ายและข้อมูลผลลัพธ์ที่ต้องการให้โครงข่ายสร้าง เมื่อป้อนข้อมูลตั้งต้นให้แก่โครงข่าย โครงข่ายจะทำการกำหนดค่าผลลัพธ์ให้กับข้อมูลตั้งต้นแต่ละตัว และนำค่าผลลัพธ์ที่ได้จากโครงข่ายมาเปรียบเทียบกับค่าเป้าหมายที่ต้องการ โครงข่ายจะนำค่าผิดพลาดระหว่างค่าผลลัพธ์และค่าเป้าหมายมาปรับใช้เป็นค่าน้ำหนักระหว่างข้อมูลแต่ละตัวเพื่อให้ได้ค่าผลลัพธ์ที่ใกล้เคียงกับค่าเป้าหมายมากที่สุด รูปแบบโครงข่ายแบบนี้ เช่น การแพร่ย้อนกลับ ซึ่งเป็นรูปแบบการเรียนรู้ที่งานวิจัยนี้เลือกใช้



รูปที่ 2.4 แสดงรูปแบบการเรียนรู้แบบไม่มีผู้สอน (ซ้าย) และรูปแบบการเรียนรู้แบบมีผู้สอน (ขวา)  
(ธนาวุฒิ ประกอบผล, 2009)

#### 2.1.4 การแพร่ย้อนกลับ (Back propagation algorithm)

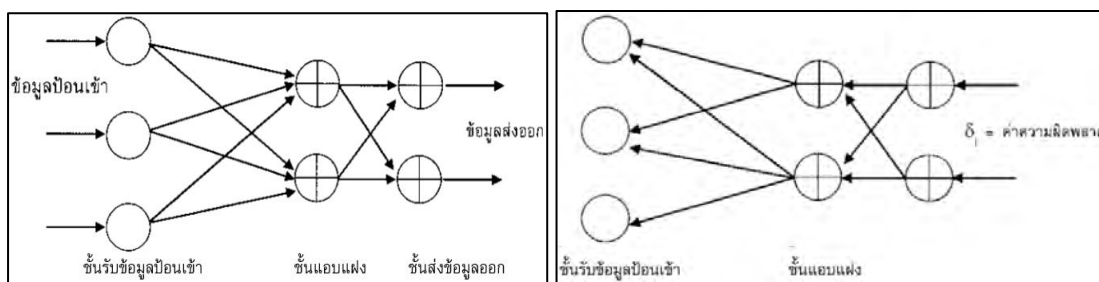
เป็นรูปแบบหนึ่งในการเรียนรู้แบบมีผู้สอน เป็นอัลกอริทึมที่นิยมใช้เพื่อปรับค่าน้ำหนักระหว่างแต่ละโหนดให้เหมาะสม ค่าที่ทำการปรับจะขึ้นกับความแตกต่างของค่าผลลัพธ์ที่ได้จากโครงข่ายกับค่าเป้าหมายที่ต้องการ ค่าน้ำหนักจะถูกปรับให้มีความถูกต้องมากขึ้นในแต่ละครั้งที่ทำการสอนจนกว่าค่าความผิดพลาดจะน้อยที่สุดหรืออยู่ในเกณฑ์ที่ยอมรับได้ ค่าน้ำหนักจะถูกปรับจากชั้นข้อมูลท้ายสุดคือ ชั้นส่งข้อมูลออก ชั้นแอบแฝง (ถ้ามี) และไปยังชั้นรับข้อมูลเข้า ตามลำดับ ขั้นตอนการแพร่ย้อนกลับแบ่งได้เป็น 2 ขั้นตอน ดังนี้

##### 1) การแพร่เดินหน้า (Forward propagation)

ข้อมูลจะถูกส่งเข้าสู่ชั้นข้อมูลป้อนเข้า โดยจะถูกนำไปคูณกับค่าน้ำหนักที่ได้จากการสุ่ม และส่งเข้าสู่ฟังก์ชันผลรวม และถูกแปลงเข้าสู่ฟังก์ชันการแปลงเพื่อหาความสัมพันธ์ของข้อมูลที่ส่งเข้าไป และความสัมพันธ์จะถูกส่งออกไปยังชั้นส่งข้อมูลออกเพื่อแปลงข้อมูลกลับเป็นค่าผลลัพธ์ตามที่โครงข่ายคำนวณได้

##### 2) การแพร่ย้อนกลับ (Backward propagation)

เกิดขึ้นเมื่อชั้นส่งข้อมูลออกทำการคำนวณความผิดพลาดระหว่างค่าผลลัพธ์ที่ได้จากโครงข่ายกับค่าเป้าหมายที่ต้องการ แล้วโครงข่ายจะทำการปรับค่าน้ำหนักระหว่างชั้นข้อมูลแต่ละชั้นกลับไปจากชั้นสุดท้ายจนถึงชั้นรับข้อมูลเข้า เพื่อให้ได้ค่าผลลัพธ์ที่ใกล้เคียงกับค่าเป้าหมายและมีความผิดพลาดน้อยที่สุด



รูปที่ 2.5 แสดงโครงข่ายประสาทแบบแพร่เดินทาง (ซ้าย)

และโครงข่ายประสาทแบบแพร่ย้อนกลับ(ขวา) (ธนาวุฒิ ประกอบผล, 2009)

### 2.1.5 ฟังก์ชันการแปลง (Transfer function)

เป็นตัวกำหนดขอบเขตการบีบค่าข้อมูลเข้าสู่การประมวลผลและเป็นตัวกำหนดขอบเขตข้อมูลที่ออกจากเครือข่าย ฟังก์ชันการแปลงแบ่งได้เป็น 2 ประเภทคือ ฟังก์ชันการแปลงเชิงเส้น (Linear Transfer Function) และฟังก์ชันการแปลงที่ไม่ใช่เชิงเส้น (Nonlinear Transfer Function)

#### 1) ฟังก์ชันการแปลงเชิงเส้น

ใช้ได้ในกรณีที่ข้อมูลป้อนเข้าและข้อมูลส่งออกมีความสัมพันธ์กันในแบบเชิงเส้นเท่านั้น

#### 2) ฟังก์ชันการแปลงที่ไม่ใช่เชิงเส้น

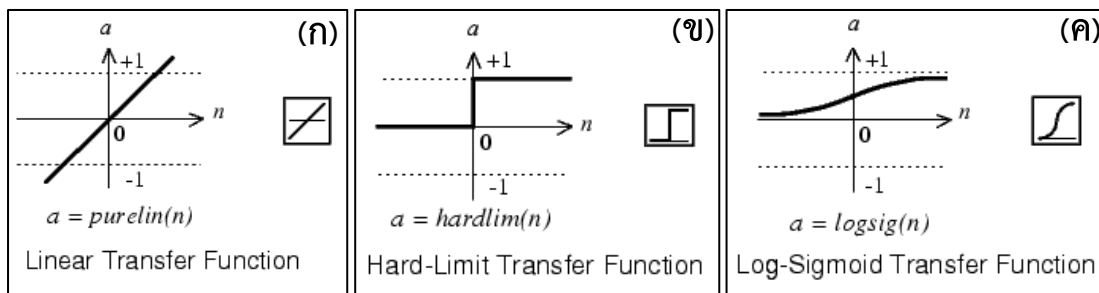
เมื่อข้อมูลป้อนเข้าและข้อมูลส่งออกไม่ได้แสดงความสัมพันธ์เชิงเส้น ฟังก์ชันการแปลงที่เลือกใช้จะขึ้นอยู่กัลักษณะของข้อมูลส่งออก

ถ้าข้อมูลส่งออกที่ต้องการ เป็นแค่คำตอบว่า “ใช่” หรือ “ไม่ใช่” จะใช้ Hard-limit function หรือ Threshold function

$$f(x) = \begin{cases} 1; & x \geq T \\ 0; & x < T \end{cases}$$

ถ้าข้อมูลส่งออกที่ต้องการเป็นค่าตัวเลขที่ต่อเนื่อง จะต้องใช้เป็นฟังก์ชันต่อเนื่อง เช่น ฟังก์ชันซิกมอยด์ (Sigmoid function) หากค่าข้อมูลส่งออกอยู่ในช่วง 0 ถึง 1 จะใช้ Log-Sigmoid Function แต่หากค่าข้อมูลอยู่ในช่วง -1 ถึง 1 Hyperbolic Tangent Sigmoid function

$$f(x) = \frac{1}{(1+e^{-x})} \quad , \quad f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$



รูปที่ 2.6 แสดงฟังก์ชันการแปลงแบบ Linear Transfer function (ก) ฟังก์ชันการแปลงแบบ Hard-Limit function (ข) และฟังก์ชันการแปลงแบบ Log-Sigmoid function (ค)  
(Demuth และ Beale, 2000)

### 2.1.6 Gradient descent algorithm

เป็นหนึ่งในอัลกอริทึมที่ใช้ในการหาค่าที่เหมาะสม (Optimization algorithm) โดยอาศัยหลักการการหาค่าสูงสุดหรือค่าต่ำสุดของฟังก์ชันที่มาจากวิชาแคลคูลัส ทำได้โดยการหาความชัน (slope) ของจุดที่เราอยู่ แล้วเดินไปตามพื้นผิวของความชันเพื่อไปยังจุดที่ให้ค่าเราต้องการ Gradient descent method มักถูกนำมาใช้ในขั้นตอนการแพร่ย้อนกลับ เพื่อให้ค่าความผิดพลาดระหว่างค่าผลลัพธ์กับค่าเป้าหมายมีค่าน้อยที่สุด เช่น


ให้  $h$  คือสมการแสดงความสัมพันธ์ของข้อมูลจากโครงข่ายประสาทเทียม

$$h(\theta) = \theta_0 + \theta_1 x$$

ให้  $J$  คือสมการแสดงค่าความแปรปรวนภายในกลุ่ม (Sum Square Error)

$$J(\theta_0, \theta_1) = \frac{1}{2m} \sum_{i=1}^m (h_{\theta}(x^i) - y^i)^2$$

จะได้ความสัมพันธ์ระหว่างค่า  $J$  กับ  $\theta$  ใน 3 มิติดังนี้



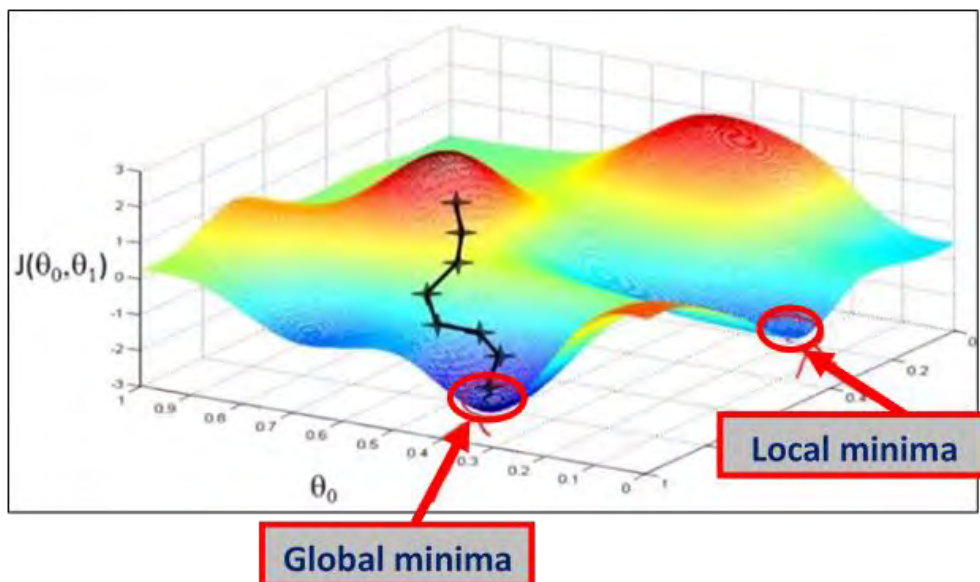
รูปที่ 2.7 แสดงรูปความสัมพันธ์ระหว่างค่า  $J$  กับ  $\theta$  ใน 3 มิติ (Korkeat W., 2016)

ในการสร้างโครงข่ายประสาทเทียม เราต้องการให้ความผิดพลาดออกมามีค่าน้อยที่สุด นั่นคือฟังก์ชัน  $J$  ออกมามีค่าน้อยที่สุด  $(\theta_0, \theta_1)$  จุดที่ต่ำที่สุดในกราฟ เราจะเรียกจุดนั้นว่า Global Minimum

ขั้นตอนการหาจุด Global minimum ของฟังก์ชัน  $J$  ด้วยวิธี Gradient descent method ทำได้โดยการหาอนุพันธ์ของฟังก์ชัน  $J$  และเนื่องจากการทำงานของอัลกอริทึม Gradient descent เป็นการอัลกอริทึมที่จะทำการวนซ้ำจนกว่าจะเข้าสู่จุดรวม (repeat until convergence) ทำให้ได้

$$\text{สมการอนุพันธ์ดังนี้} \quad \theta_j := \theta_j - \alpha \frac{\partial J(\theta)}{\partial \theta}$$

จากสมการอนุพันธ์จะเห็นว่ามีความเร็ว  $\alpha$  (alpha) เพิ่มขึ้นมา ซึ่งจะเรียกว่า ค่าการเรียนรู้ (Learning rate) เป็นค่าคงที่ที่กำหนดว่าแต่ละรอบจะขยับค่า gradient ของฟังก์ชันที่ละเท่าไร ถ้า  $\alpha$  น้อยไปการคำนวณ gradient เพื่อเข้าสู่จุดต่ำสุดของฟังก์ชันก็จะช้า แต่หาก  $\alpha$  มากเกินไปจะทำให้เกิดการ overshoot คือค่าความผิดพลาดที่ได้จากฟังก์ชัน  $J$  ไม่ได้ลดลงตามที่เราต้องการหรืออาจทำให้โครงข่ายวนอยู่ในจุดที่ไม่ใช่จุดต่ำสุดจริง แต่เป็นบริเวณที่เราเรียกว่า Local minimum ในกรณีที่พื้นผิวของฟังก์ชันไม่ได้ราบเรียบทั้งหมดเช่นในภาพที่ 2.8 แสดงการเปรียบเทียบระหว่างพื้นที่ในวงกลมสีแดงสองวงในบริเวณพื้นผิวสีน้ำเงินสองบริเวณ พื้นผิวสีน้ำเงินแสดงว่าบริเวณนั้นเป็นพื้นที่ที่มีค่าผลลัพธ์ของฟังก์ชัน  $J$  ต่ำ วงกลมด้านขวาเป็นบริเวณที่เรียกว่า Local minimum ส่วนวงกลมด้านซ้ายคือ Global minimum ที่แท้จริง เพราะเป็นจุดที่ต่ำกว่า (มีสีน้ำเงินเข้มกว่า) ดังแสดงในรูปที่ 2.8



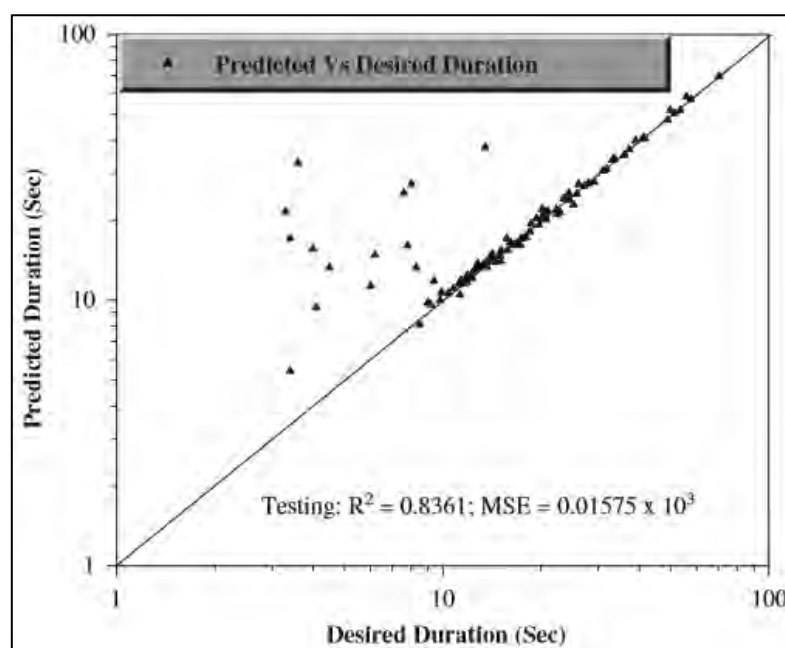
รูปที่ 2.8 แสดงจุดที่เรียกว่า Local minimum (ซ้าย) และจุด Global minimum (ขวา)  
(Korkeat W., 2016)

## 2.2 งานวิจัยที่เกี่ยวข้อง

Abdulrahman และคณะ (2012) นำข้อมูลแผ่นดินไหวซึ่งประกอบด้วย วัน เดือน ปี เวลา ละติจูด ลองจิจูด แมกนิจูด และความลึกของจุดศูนย์กลางการเกิดแผ่นดินไหวบริเวณด้านเหนือของทะเลแดงมาทำการศึกษาและพยายามคาดการณ์ค่าแมกนิจูดที่อาจเกิดขึ้นในอนาคต การวิจัยทำการเปรียบเทียบผลการคาดการณ์ที่ได้จากโครงข่ายประสาทเทียมแบบ feed forward neural network model with multi-hidden layers กับการคาดการณ์วิธีการทางสถิติอื่น ๆ ได้แก่ Normal distributed random predictor, Uniformly distributed random predictor, Moving average predictor, Curve fitting methods จากผลการวิจัยพบว่า ผลการคาดการณ์ที่ได้จากโครงข่ายประสาทเทียมมีความถูกต้องมากกว่าการคาดการณ์ด้วยกระบวนการทางสถิติอื่น ๆ อย่างน้อย 32% ซึ่งแสดงให้เห็นว่า โครงข่ายประสาทเทียมมีความเหมาะสมในการวิเคราะห์ความสัมพันธ์ของข้อมูลที่ข้อมูลผลลัพธ์และข้อมูลตั้งต้นไม่ได้แสดงความสัมพันธ์กันเชิงเส้น (non-linear relationship)

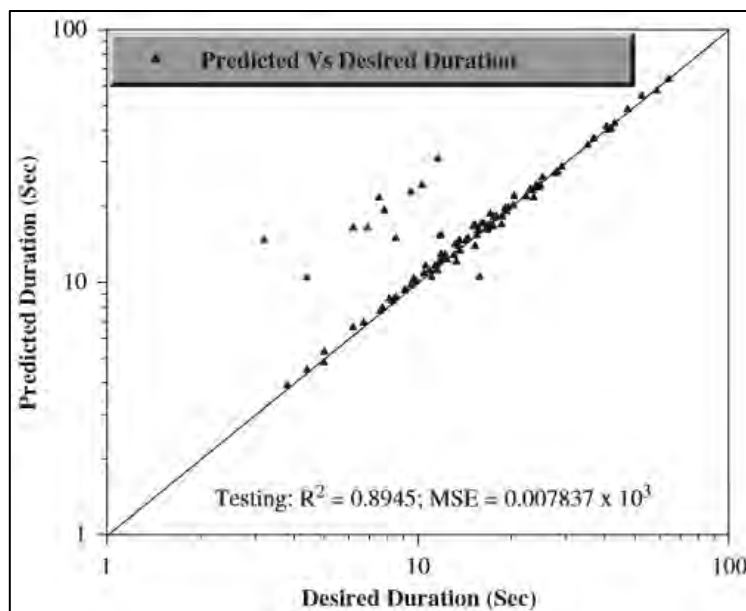
Xie และคณะ (2011) ได้ทำการศึกษาแผ่นดินไหวในประเทศจีนด้านตะวันออกเพื่อทำนายช่วงเวลาในการเกิดแผ่นดินไหวครั้งถัดไป โดยใช้ข้อมูลแผ่นดินไหวจาก China Earthquake Network Center (CENC) ซึ่งประกอบด้วย ข้อมูล พื้นที่ (latitude, longitude) และเวลา โดยใช้โครงข่ายประสาทเทียมแบบ Non-Linear Neural Network ร่วมกับการเรียนรู้แบบย้อนกลับ (Back propagation)

Arjun และ Kumar (2011) ใช้โครงข่ายประสาทเทียมแบบ multi-layer feedforward neural networks โดยใช้การเรียนรู้แบบแพร่ย้อนกลับ (Error backpropagation algorithm) ในกระบวนการเรียนรู้และปรับค่าน้ำหนัก (training and weight adaption) งานวิจัยทำการศึกษาข้อมูลแผ่นดินไหวในประเทศญี่ปุ่นเพื่อทำนายระยะเวลาในการสั่นสะเทือนจากการเกิดแผ่นดินไหว โดยแบ่งการวิจัยออกเป็น 2 ส่วนตามข้อมูลที่นำเข้าเป็นข้อมูลตั้งต้นคือ ส่วนที่ใช้ข้อมูลเข้า 6 ข้อมูล ซึ่งประกอบด้วย ขนาดแผ่นดินไหว(magnitude of earthquake) ระยะห่างจากจุดศูนย์กลางการเกิดแผ่นดินไหว (hypocentral distance) ค่าความแข็งแรงเฉลี่ยของชั้นดิน (average SPT blow count) อัตราเฉลี่ยของคลื่นปฐมภูมิ (average primary wave velocity) อัตราเร็วเฉลี่ยของคลื่นทุติยภูมิ (average shear velocity) และค่าความหนาแน่นเฉลี่ยของชั้นดิน (average density of soil) กับ ส่วนที่ใช้ข้อมูลเข้า 3 ข้อมูล ซึ่งประกอบด้วย ขนาดแผ่นดินไหว ระยะห่างจากจุดศูนย์กลางการเกิดแผ่นดินไหว และอัตราเร็วเฉลี่ยของคลื่นทุติยภูมิ พบว่าประสิทธิภาพความแม่นยำ (ความผิดพลาดน้อยกว่า 3%) ในการทำนายระยะเวลาการสั่นสะเทือนของโครงข่าย จากทั้งส่วนที่มีข้อมูลเข้า 6 ข้อมูลและส่วนที่มีข้อมูลเข้า 3 ข้อมูล มีค่าเท่ากับ 55% และ 61% ตามลำดับ ผลการวิจัยแสดงเป็นกราฟความสัมพันธ์ระหว่างระยะเวลาในการสั่นสะเทือนที่ได้จากโครงข่าย (predicted duration) กับระยะเวลาในการสั่นสะเทือนที่ตรวจวัดได้จริง (desired duration) ของโครงข่ายประสาทเทียมที่มีข้อมูลเข้า 6 ข้อมูล และโครงข่ายประสาทเทียมที่มีข้อมูลเข้า 3 ข้อมูล ซึ่งแสดงในรูปที่ 2.9 และ 2.10 ตามลำดับ โดยแกนตั้งคือค่าที่ได้จากโครงข่ายประสาทเทียม แกนนอนคือค่าที่ตรวจวัดได้จริง



รูปที่ 2.9 แสดงกราฟความสัมพันธ์ของระยะเวลาในการสั่นสะเทือนของโครงข่ายประสาทเทียมที่มีข้อมูลเข้าจำนวน 6 ข้อมูล (Arjun และ Kumar, 2011)





รูปที่ 2.10 แสดงกราฟความสัมพันธ์ของระยะเวลาในการสั้นสะท้อนของโครงข่ายประสาทเทียมที่มีข้อมูลเข้าจำนวน 3 ข้อมูล (Arjun และ Kumar, 2011)

## 2.3 ลักษณะทั่วไปของพื้นที่ศึกษา

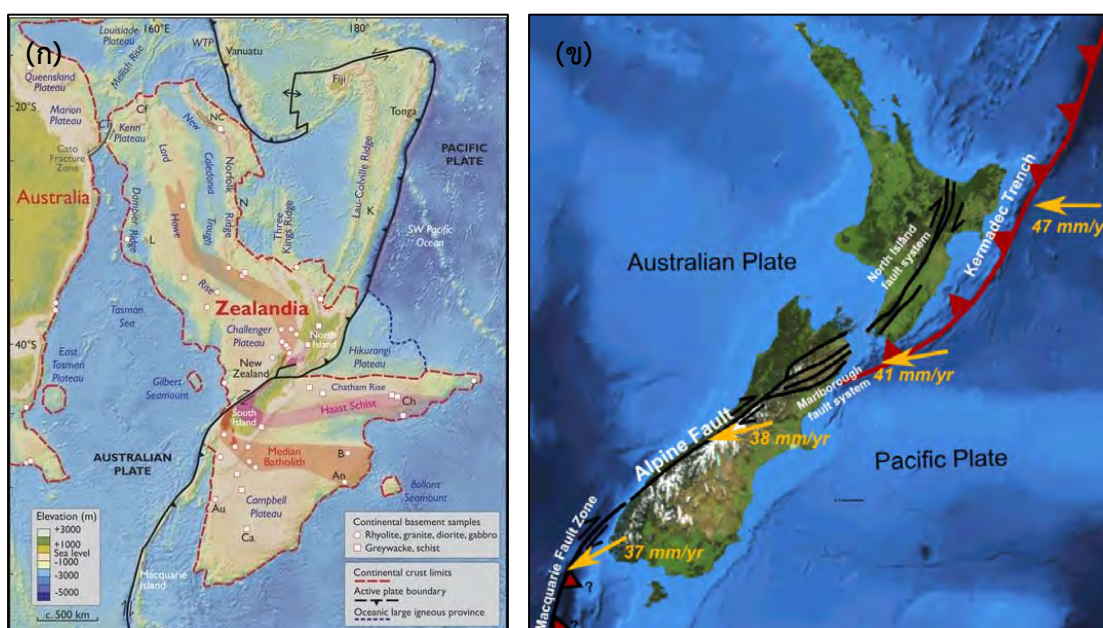
### 2.3.1 ที่ตั้งและอาณาเขต

ประเทศนิวซีแลนด์ ตั้งอยู่บริเวณตะวันตกเฉียงใต้ของมหาสมุทรแปซิฟิก บริเวณที่เรียกว่า “วงแหวนไฟ” (Ring of fire) ลักษณะประเทศเป็นหมู่เกาะ พื้นที่หลักของประเทศ ประกอบด้วยเกาะใหญ่ 2 เกาะ คือ เกาะเหนือ (North Island) เกาะใต้ (South Island) ถูกแบ่งโดยช่องแคบคุกซึ่งมีความกว้าง 20 กิโลเมตร ถูกจัดเป็นจุดที่แคบที่สุดของเกาะ ปริมาณพื้นที่ของประเทศคือ 268,680 ตารางกิโลเมตร และเกาะสจวร์ต (Stewart Island) ที่ตั้งอยู่บริเวณปลายสุดของเกาะใต้ ล้อมรอบด้วยไหล่ทวีปที่จมอยู่ใต้ทะเลลึกประมาณ 200 เมตร ซึ่งเมื่อก่อนอาจเคยเป็นพื้นบกมาก่อน ซึ่งเมื่อรวมเอาพื้นที่เกาะของประเทศนิวซีแลนด์รวมกับบริเวณไหล่ทวีปที่จมอยู่นี้เข้าไว้ด้วยกัน ทำให้ได้เป็นพื้นที่ทวีปใหม่ชื่อว่า “ซีแลนด์เดีย” (Zealandia) ซึ่งครอบคลุมพื้นที่กว่า 4.9 ล้านตารางกิโลเมตร (รูปที่ 2.11ก) ครอบคลุมพื้นที่ตั้งแต่ประเทศนิวซีแลนด์ถึงประเทศนิวคาลิโดเนีย

### 2.3.2 ลักษณะทางธรณีวิทยา (Geological setting)

ประเทศนิวซีแลนด์ตั้งอยู่บริเวณรอยต่อของแผ่นเปลือกโลกสองแผ่นคือ แผ่นเปลือกโลกมหาสมุทรแปซิฟิก (Pacific plate) และแผ่นเปลือกโลกทวีปออสเตรเลีย (Australian plate) ซึ่งแผ่นเปลือกโลกทั้งสองกำลังเคลื่อนที่เข้าหากัน (Convergence) ทำให้แผ่นที่มีความหนาแน่นมากกว่าจะเกิดการมุดตัว (Subduction) ลงใต้แผ่นที่มีความหนาแน่นน้อยกว่า ซึ่งบริเวณด้านเหนือและด้าน

ตะวันออกเฉียงเหนือของเกาะเหนือ แผ่นเปลือกโลกมหาสมุทรแปซิฟิกมีการมุดตัวลงใต้แผ่นเปลือกโลกทวีปออสเตรเลีย ส่วนทางด้านใต้ของประเทศแผ่นเปลือกโลกทวีปออสเตรเลียเกิดการมุดตัวลงใต้แผ่นเปลือกโลกมหาสมุทรแปซิฟิก กระบวนการนี้ทำให้เกิดกิจกรรมของภูเขาไฟบริเวณเกาะเหนือของประเทศ และทำให้เกิดรอยเลื่อนแนวระดับขนาดใหญ่ตัดผ่านบริเวณเกาะใต้ของประเทศชื่อว่า “รอยเลื่อนอัลไพน์” (Alpine fault) จากการปรากฏของรอยเลื่อนมีพลังขนาดใหญ่บริเวณกลางประเทศ และมีแนวมุดตัวเกิดขึ้นโดยรอบของประเทศ จึงทำให้ประเทศนิวซีแลนด์มีการเกิดเหตุการณ์แผ่นดินไหวบ่อยครั้งมากที่สุดประเทศหนึ่งในโลก



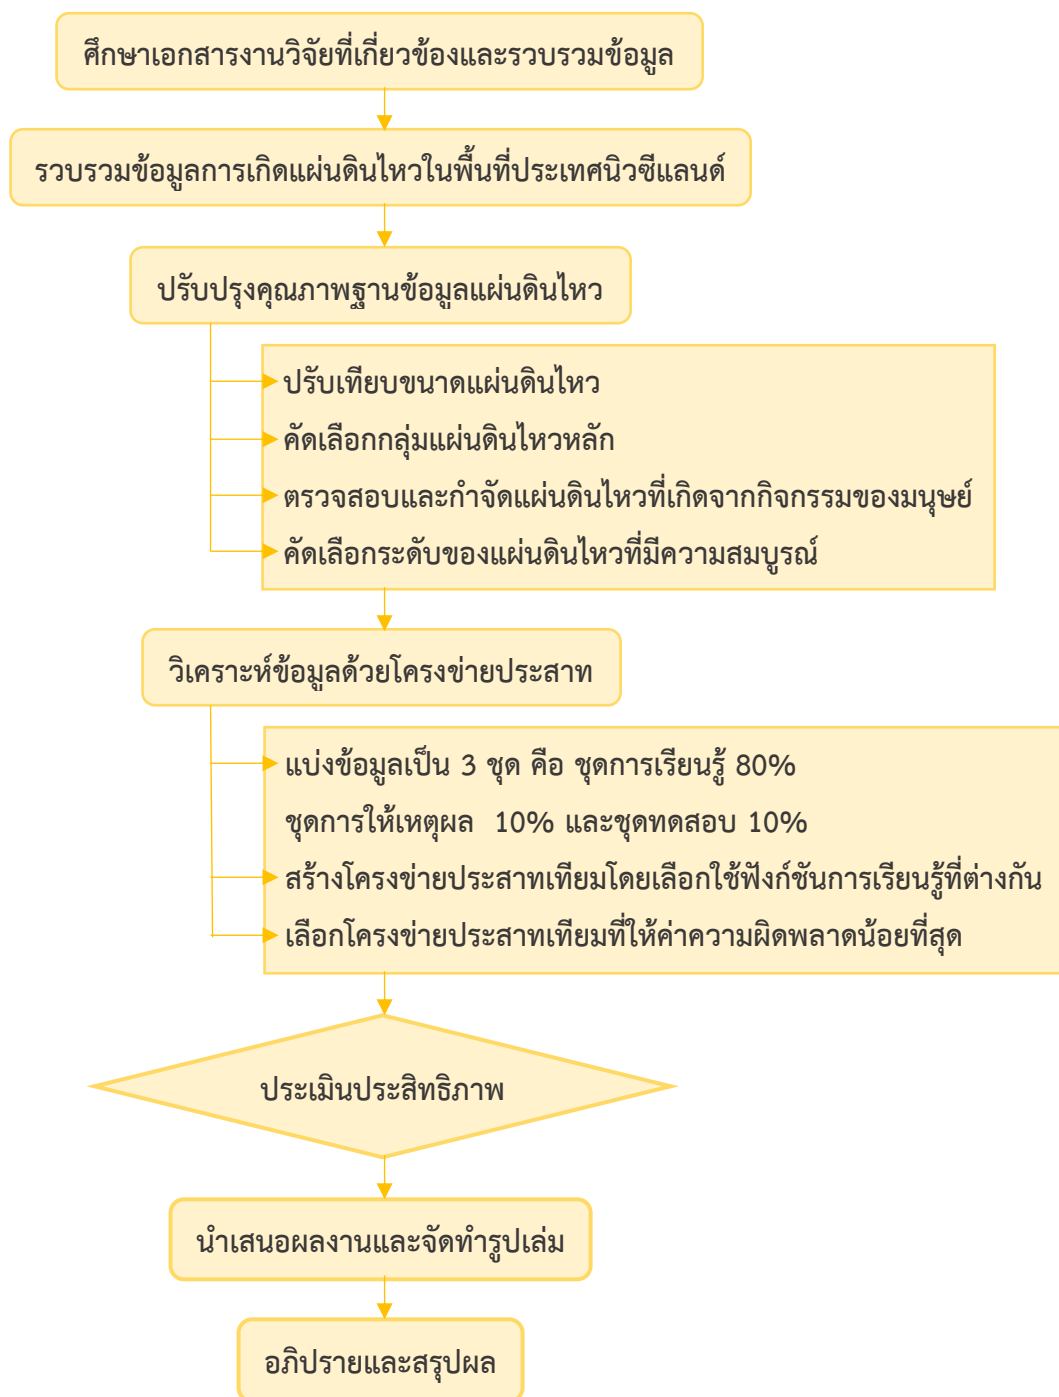
รูปที่ 2.11 (ก) แสดงพื้นที่ทวีปซีแลนด์เดี่ยว (GSA Today, 2017) และ (ข) แสดงแนวการมุดตัวและการกระจายตัวของรอยเลื่อนมีพลัง บริเวณประเทศนิวซีแลนด์

(Wikipedia/ File:NZ\_faults.png, 2010)

## บทที่ 3

### ระเบียบวิธีวิจัย

#### 3.1 ขั้นตอนการศึกษาวิจัย



### 3.2 รวบรวมข้อมูลการเกิดแผ่นดินไหวในพื้นที่ประเทศนิวซีแลนด์

ฐานข้อมูลแผ่นดินไหว (Earthquake Catalogue) คือชุดของข้อมูลเชิงตัวเลขจากเครื่องมือตรวจวัดแผ่นดินไหว ที่ผ่านกระบวนการวิเคราะห์ทางคณิตศาสตร์และวิทยาศาสตร์มาแล้ว ชุดข้อมูลเหล่านี้ได้จากเครื่องมือตรวจวัดแผ่นดินไหวที่กระจายตัวอยู่ทั่วโลก ซึ่งถูกควบคุมและดูแลจากหลากหลายหน่วยงาน ข้อมูลแผ่นดินไหวเหล่านี้มีการเผยแพร่อย่างสาธารณะบนฐานข้อมูลทางอินเทอร์เน็ต

ฐานข้อมูลแผ่นดินไหวถูกบันทึกด้วยรายละเอียดดังต่อไปนี้

1. ระบบพิกัดแสดงเป็นระบบละติจูด (Latitude) ลองจิจูด (Longitude) ของจุดเหนือศูนย์กลางแผ่นดินไหว (Epicenter)
2. วันที่เกิดเหตุการณ์แผ่นดินไหว รายงานในระบบ วัน (Day) เดือน (Month) ปี (Year)
3. เวลาที่เกิดเหตุการณ์แผ่นดินไหว รายงานในระบบ ชั่วโมง (Hour) นาที (Min) และอาลละเอียดถึงวินาที (Second)
4. ขนาดและมาตราตรวจวัดขนาดแผ่นดินไหว (magnitude and magnitude scale) เป็นตัวแปรที่ขึ้นอยู่กับเครื่องมือตรวจวัดแผ่นดินไหว ซึ่งเครื่องมือตรวจวัดแผ่นดินไหวแต่ละชนิดตรวจรับคลื่นแผ่นดินไหวต่างประเภทกัน ซึ่งข้อมูลของแต่ละคลื่นจะถูกแสดงในหัวข้อการปรับเทียบมาตรฐานการตรวจวัดแผ่นดินไหว (magnitude conversion) ต่อไป

ตาราง 3.1 แสดงตัวอย่างรายละเอียดการบันทึกฐานข้อมูลแผ่นดินไหว

Lon	Lat	Year	Month	Day	Depth	Hour	Min	Sec	$M_w$	$m_b$	$M_s$	$M_L$
172.743	-43.53	2011	12	23	6.9	2	18	3	5.9	5.7	5.6	6
172.7498	-43.5245	2011	12	23	7.5	2	18	3	5.9			6.1
172.743	-43.53	2011	12	23	6.9	2	18	3	5.8	5.7	5.6	
172.58	-43.55	2011	12	23	12	2	18	2	5.8			
172.7917	-43.5296	2011	12	23	9.3	1	30	27	4.4			4.7
172.69	-43.61	2011	12	23	12	1	6	27	5.4			
172.841	-43.473	2011	12	23	10	1	6	25	5.4	5.3		5.3

โครงการวิจัยนี้ใช้ข้อมูลจาก 3 ฐานข้อมูลแผ่นดินไหว ได้แก่ ฐานข้อมูลแผ่นดินไหวโดย Global CMT Catalogue (GCMT) ฐานข้อมูลแผ่นดินไหวโดย National Earthquake Information (NEIC) และฐานข้อมูลแผ่นดินไหวโดย International Seismological Center (ISC) โดยมีการกำหนดข้อมูลในการคัดลอกฐานข้อมูลแผ่นดินไหว ดังนี้

- กรอบละติจูดที่ -48.941854 ถึง -32.092959 องศาใต้ ลองจิจูดที่ 164.998041 ถึง 179.874724 องศาตะวันออก ขอบเขตการศึกษาครอบคลุมพื้นที่ทั้งหมดของประเทศนิวซีแลนด์

- ขนาดแผ่นดินไหวที่ต้องการศึกษาตั้งแต่ 0.1-10.0 ริกเตอร์ ความลึกของการเกิดแผ่นดินไหวตั้งแต่ 0-1,000 เมตร และระยะเวลาตั้งแต่ปี ค.ศ. 1900-2016

### 3.2.1 ฐานข้อมูลแผ่นดินไหว National Earthquake Information (NEIC)

จัดตั้งขึ้นในปี ค.ศ. 1940 อยู่ในการกำกับดูแลของกรมทรัพยากรธรณี สหรัฐอเมริกา (U.S. Geological Survey, USGS) มีการรายงานแผ่นดินไหวที่เกิดขึ้นทั่วโลกอย่างทันทีทันใดหลังการเกิดแผ่นดินไหว (Sipkin และคณะ, 2000) และถือได้ว่าเป็นฐานข้อมูลที่มีการรายงานที่ทันสมัยที่สุดในปัจจุบัน

### 3.2.2 ฐานข้อมูลแผ่นดินไหว International Seismological Center (ISC)

เป็นอีกหนึ่งฐานข้อมูลที่อยู่ในการดูแลของหน่วยงาน USGS มีวัตถุประสงค์หลักเพื่อจัดทำฐานข้อมูลแผ่นดินไหวที่แม่นยำมากขึ้น ฐานข้อมูล ISC เกิดจากการนำฐานข้อมูล NEIC มาคำนวณใหม่ (International Seismological Centre, 2001) เพื่อความถูกต้องแม่นยำของข้อมูลตลอดจนรายงานข้อมูลในเชิงลึกอื่นๆ ที่อาจจำเป็นต่อการวิจัยเชิงลึกด้านแผ่นดินไหววิทยา โดยบางเหตุการณ์ที่เกิดขึ้นล่าสุด ฐานข้อมูล ISC จะยังไม่มีรายงาน แต่โดยภาพรวมข้อมูลจากฐานข้อมูล ISC จะมีความถูกต้องมากกว่าฐานข้อมูล NEIC

### 3.2.3 ฐานข้อมูลแผ่นดินไหว Global Centroid Moment Tensor Catalogue (GCMT)

ฐานข้อมูล Global CMT Catalogue (GCMT) มีภารกิจหลักในการวิเคราะห์และรายงานค่าโมเมนต์เทนเซอร์ (Centroid moment tensor, CMT) ของเหตุการณ์แผ่นดินไหวที่มีขนาดมากกว่า 5.5 ริกเตอร์ นับตั้งแต่ ปี ค.ศ. 1976 (Dziewonski และคณะ, 1981; Ekström และคณะ, 2005) โดยฐานข้อมูลจะมีการวิเคราะห์ตัวแปรด้านแผ่นดินไหวอย่างละเอียด ตลอดจนมีการรายงานผลการวิเคราะห์กลไกการเกิดแผ่นดินไหว (focal mechanism) เพื่อเป็นข้อมูลพื้นฐานในการศึกษาวิจัยกระบวนการเกิดแผ่นดินไหวในเชิงลึก อย่างไรก็ตามเนื่องจากเป็นฐานข้อมูลที่มีรายละเอียดมาก ดังนั้นในแต่ละเหตุการณ์แผ่นดินไหวจึงต้องใช้เวลาในการวิเคราะห์ผลนานกว่าฐานข้อมูลแผ่นดินไหวอื่น

### 3.3 ปรับปรุงคุณภาพฐานข้อมูลแผ่นดินไหว

#### 3.3.1 การปรับเทียบมาตรฐานขนาดแผ่นดินไหว (Earthquake Magnitude Conversion)

จากการรวบรวมข้อมูลแผ่นดินไหว พบว่าข้อมูลจากฐานข้อมูลแผ่นดินไหวจะมีการรายงานขนาดของแผ่นดินไหวด้วยมาตราวัดที่แตกต่างกัน การตรวจวัดแผ่นดินไหวแต่ละครั้งสามารถให้ค่าขนาดแผ่นดินไหวได้หลายหน่วย ขึ้นกับประเภทของคลื่นที่ตรวจวัด โดยหน่วยวัดขนาดแผ่นดินไหวมีดังนี้

1.  $M_L$  (Local Magnitude) คือ การรายงานขนาดแผ่นดินไหวที่เกิดในท้องถิ่น มีความแม่นยำมากหากวัดภายในบริเวณที่ใกล้จุดเกิดแผ่นดินไหว แต่จะมีความคลาดเคลื่อนของข้อมูลมากขึ้นเมื่ออยู่ไกลจากจุดเกิดแผ่นดินไหวออกไป หน่วยวัดแผ่นดินไหวแบบ  $M_L$  นิยมใช้ในการประเมินแผ่นดินไหวเพื่อวิเคราะห์ความเสียหายที่เกิดกับสิ่งปลูกสร้าง เช่น เหมือง เขื่อน อาคารสูง ในบริเวณที่อยู่ห่างจากจุดเกิดแผ่นดินไหวในระยะไม่เกิน 650 กิโลเมตร

2.  $m_b$  (Body-Wave Magnitude) ในการเกิดแผ่นดินไหวแต่ละครั้งคลื่นที่จะเกิดพร้อมกับเหตุการณ์แผ่นดินไหวเสมอคือคลื่นเนื้อโลก สามารถแบ่ง 2 แบบคือ คลื่นปฐมภูมิ (P-Wave) และคลื่นทุติยภูมิ (S-Wave) จำนวนการตรวจวัดจึงมากกว่าขนาดแผ่นดินไหวชนิดอื่น ๆ นิยมใช้ในการวัดแผ่นดินไหวระดับลึก ซึ่งอาศัยการวัดความสูงแอมพลิจูดของคลื่นปฐมภูมิ

3.  $M_S$  (Surface-Wave Magnitude) คือคลื่นที่เกิดหลังจากคลื่นเนื้อโลกเคลื่อนที่มาถึงผิวโลก จะให้กำเนิดคลื่นผิวโลกตามมา โดยทั่วไปของการตรวจวัดในระดับทั่วโลก (global scale) ในการที่จะวัดคลื่นแผ่นดินไหวระยะไกลหรือแผ่นดินไหวที่มีขนาดรุนแรงจะวัดความสูงแอมพลิจูดของคลื่นผิวโลก ข้อมูลจึงมีความสมบูรณ์มากกว่า ซึ่งจำนวนที่สามารถวัดได้จะน้อยกว่า  $m_b$

4.  $M_W$  (Moment Magnitude) เป็นการวัดแผ่นดินไหวจากโมเมนต์แผ่นดินไหว (seismic moment) ซึ่งขนาดแผ่นดินไหวชนิดนี้จะไม่ขึ้นกับชนิดของเครื่องมือวัด แต่เป็นค่าความสัมพันธ์ที่คิดจากระยะการเลื่อนตัวของรอยเลื่อน พื้นที่การเลื่อนตัว ตลอดจนค่าสัมประสิทธิ์ความแข็งของหินในพื้นที่ ถือเป็นชนิดของขนาดแผ่นดินไหวที่ดีที่สุด

เนื่องจากข้อมูลแผ่นดินไหวที่ได้จากฐานข้อมูลในแต่ละที่นั้นจะมีการรายงานชนิดของขนาดแผ่นดินไหวหลากหลายมาตราวัด ทั้ง  $m_b$   $M_S$   $M_W$  หรือ  $M_L$  เพื่อความสะดวกและความเป็นมาตรฐานในการวิเคราะห์จึงจำเป็นต้องปรับฐานข้อมูลแผ่นดินไหวที่รวบรวมมาให้อยู่ในหน่วยเดียวกันทั้งหมดก่อนจะนำไปดำเนินการต่อ ซึ่งในปัจจุบันหน่วยมาตราวัดที่นิยมนำมาใช้วิเคราะห์ข้อมูลเชิงสถิติและมีความน่าเชื่อถือมากที่สุด คือ มาตราวัดขนาดแผ่นดินไหวโมเมนต์ ( $M_W$ ) ซึ่งโครงการวิจัยนี้ให้ความสนใจกับแผ่นดินไหวขนาดใหญ่เป็นหลัก เนื่องจากมีโอกาสที่จะทำให้เกิดการเคลื่อนตัวของแผ่นเปลือก

โลกในแนวดิ่ง และก่อให้เกิดผลกระทบได้มากกว่า จึงประเมินว่ามาตรวัดขนาดแผ่นดินไหวในหน่วย  $M_w$  มีความเหมาะสมมากที่สุด โดยเริ่มต้นจากการหาสมการความสัมพันธ์ระหว่างมาตรวัดขนาดแผ่นดินไหวที่แตกต่างกัน ความสัมพันธ์จะมีค่าเฉพาะตัวและแตกต่างกันออกไปตามพื้นที่ จากนั้นจะต้องเลือกคู่สมการความสัมพันธ์ที่ดีที่สุด เพื่อนำไปใช้แปลงหน่วยฐานข้อมูล โดยจะทำการวิเคราะห์ในรูปแบบของกราฟความสัมพันธ์ระหว่างแต่ละคู่ในการแปลงมาตรวัด โดยความเหมาะสมของสมการสามารถพิจารณาจากค่า  $R^2$  ซึ่งเป็นค่าที่แสดงถึงความน่าเชื่อถือของความสัมพันธ์ โดยหากค่า  $R^2$  ยังมีค่าใกล้เคียง 1 หมายถึงสมการดังกล่าวมีความน่าเชื่อถือสูง ซึ่งในที่นี้สามารถเลือกคู่ความสัมพันธ์ได้ดังนี้

### 3.3.1.1 ขนาดแผ่นดินไหวโมเมนต์ ( $M_w$ ) และขนาดแผ่นดินไหวจากคลื่นเนื้อโลก ( $m_b$ )

สมการความสัมพันธ์ระหว่างขนาดแผ่นดินไหวโมเมนต์ ( $M_w$ ) และขนาดแผ่นดินไหวจากคลื่นเนื้อโลก ( $m_b$ ) ดังสมการ (3.1) สามารถวิเคราะห์ออกมาในรูปแบบกราฟความสัมพันธ์ ดังรูปที่ 3.1ก

$$M_w = 0.1612m_b^2 - 0.5454m_b + 3.8253 \quad \text{สมการ (3.1)}$$

### 3.3.1.2 ขนาดแผ่นดินไหวโมเมนต์ ( $M_w$ ) และขนาดแผ่นดินไหวจากคลื่นผิวโลก ( $M_s$ )

สมการความสัมพันธ์ระหว่างขนาดแผ่นดินไหวโมเมนต์ ( $M_w$ ) และขนาดแผ่นดินไหวจากคลื่นผิวโลก ( $M_s$ ) ดังสมการ (3.2) สามารถวิเคราะห์ออกมาในรูปแบบกราฟความสัมพันธ์ ดังรูปที่ 3.1ข

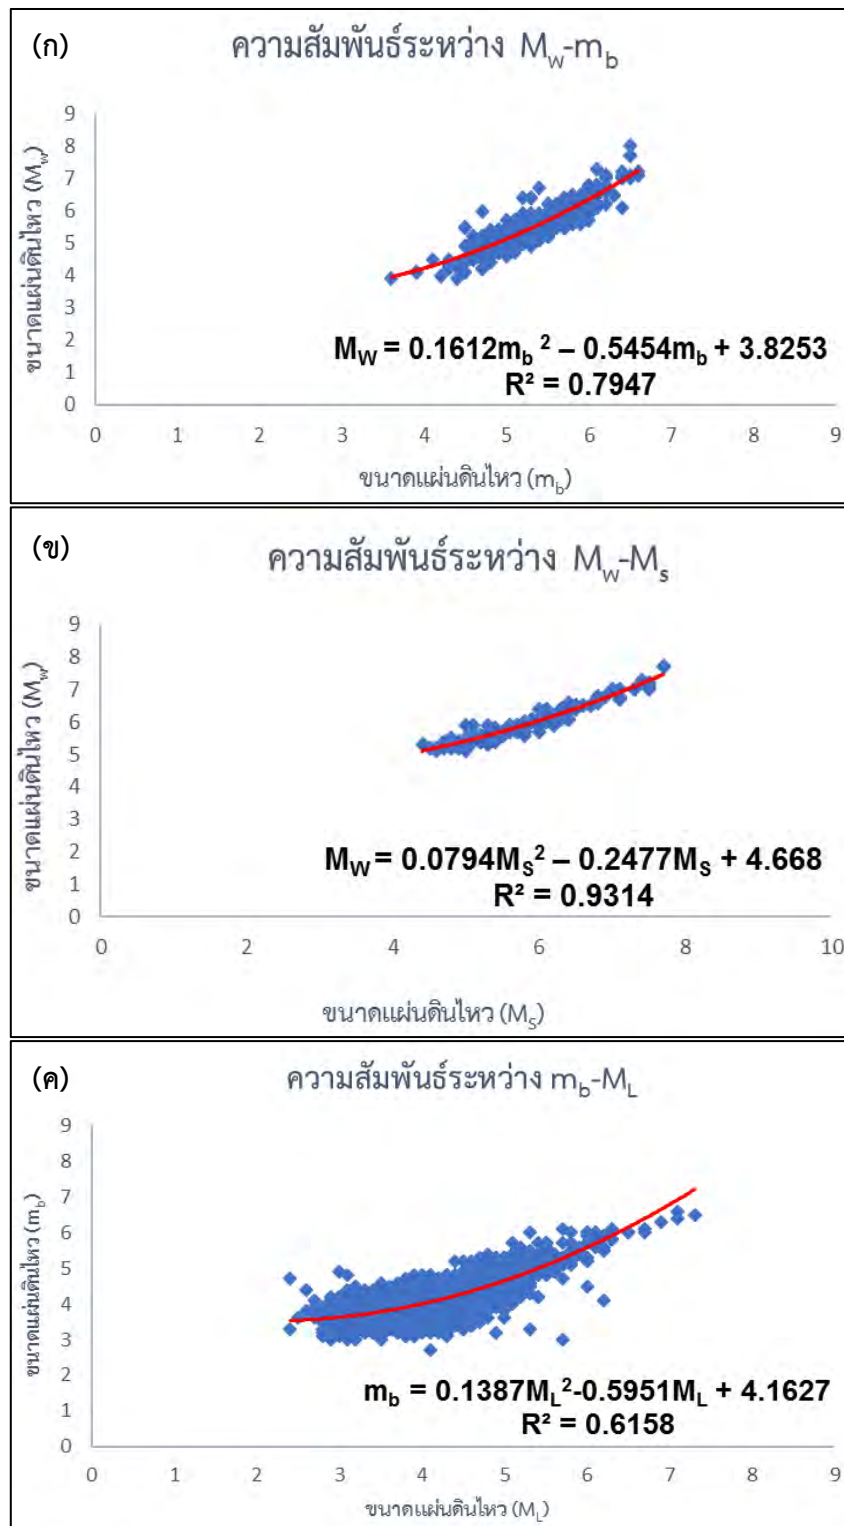
$$M_w = 0.0794M_s^2 - 0.2477M_s + 4.668 \quad \text{สมการ (3.2)}$$

### 3.3.1.3 ขนาดแผ่นดินไหวจากคลื่นเนื้อโลก ( $m_b$ ) และขนาดแผ่นดินไหวท้องถิ่น ( $M_L$ )

สมการความสัมพันธ์ระหว่างขนาดแผ่นดินไหวจากคลื่นเนื้อโลก ( $m_b$ ) และขนาดแผ่นดินไหวท้องถิ่น ( $M_L$ ) เป็นดังสมการ (3.3) สามารถวิเคราะห์ออกมาในรูปแบบกราฟความสัมพันธ์ ดังรูปที่ 3.1ค

$$m_b = 0.1387M_L^2 - 0.5951M_L + 4.1627 \quad \text{สมการ (3.3)}$$

เดิมเรามีจุดประสงค์ที่จะแปลงหน่วยทุกหน่วยให้เป็น  $M_w$  แต่จะเห็นว่ามียังมีสองคู่สมการที่สามารถแปลงมาตรวัดในหน่วย  $m_b$  และ  $M_s$  ให้เป็น  $M_w$  ได้โดยตรง ดังสมการ (3.1) และสมการ (3.2) ตามลำดับ เหลือเพียงหน่วย  $M_L$  ที่ไม่สามารถแปลงเป็น  $M_w$  ได้โดยตรง ซึ่งจากสมการ (3.3) และสมการ (3.4) จะเห็นว่าเราต้องแปลงหน่วย  $M_L$  เป็น  $m_b$  จากนั้นจึงทำการแปลงหน่วย  $m_b$  ที่ได้ไปเป็นหน่วยมาตรวัด  $M_w$  ด้วยสมการ (3.1)



รูปที่ 3.1 แสดงกราฟความสัมพันธ์ระหว่างขนาดแผ่นดินไหว

(ก)  $M_w - m_b$  (ข)  $M_w - M_s$  (ค)  $m_b - M_L$



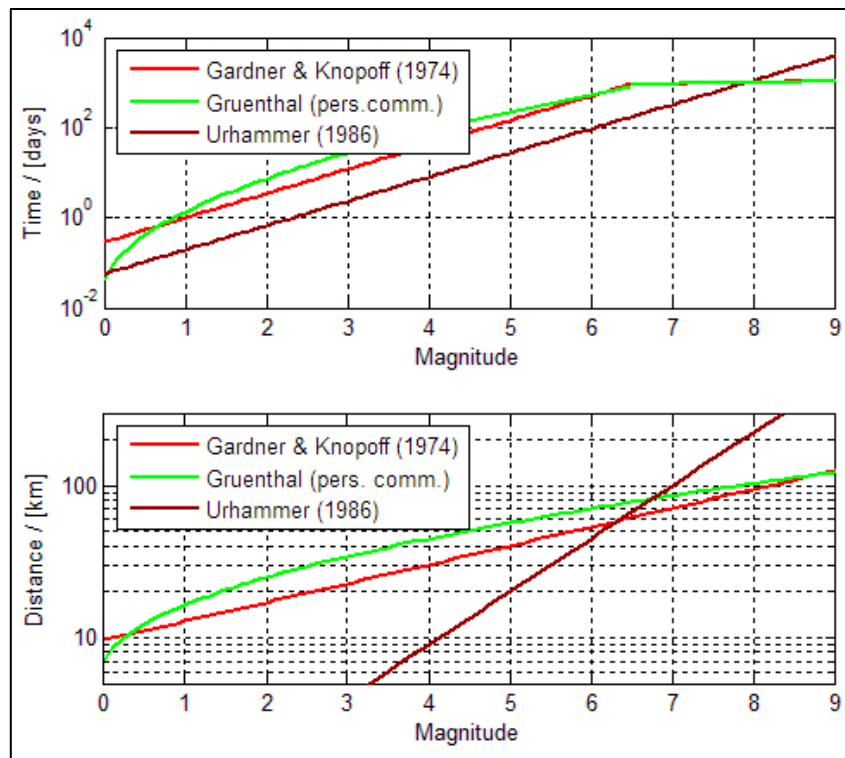
### 3.3.2 การคัดเลือกกลุ่มแผ่นดินไหวหลัก (Earthquake Declustering)

โดยปกติการเกิดแผ่นดินไหวครั้งหนึ่ง ๆ จะประกอบไปด้วยแผ่นดินไหว 3 เหตุการณ์ย่อยด้วยกันคือ แผ่นดินไหวนำ (foreshock), แผ่นดินไหวหลัก (main shock) และแผ่นดินไหวตาม (aftershock) โดยแผ่นดินไหวหลักเกิดจากแรงเค้น (stress) อันเนื่องมาจากการกระทำทางธรณีแปรสัณฐานโดยตรง ในขณะที่แผ่นดินไหวนำและแผ่นดินไหวตามนั้นเกิดจากแรงเครียด (strain) อันเนื่องมาจากการกระบวนการเกิดแผ่นดินไหวหลักในแต่ละเหตุการณ์ โดยแผ่นดินไหวนำเกิดจากการเตรียมตัวก่อนการเกิดแผ่นดินไหวหลัก ในขณะที่แผ่นดินไหวตามเป็นผลมาจากการเคลื่อนตัวของพื้นที่หรือรอยเลื่อนบริเวณนั้นเพื่อปรับสภาพให้พื้นที่รอยเลื่อนกลับสู่สภาวะสมดุลที่สุดหลังการเกิดแผ่นดินไหวหลัก

ดังนั้นหากต้องการเหตุการณ์ที่สื่อถึงพฤติกรรมของการเกิดแผ่นดินไหวโดยแท้จริงที่เกี่ยวข้องกับธรณีแปรสัณฐาน จึงต้องเลือกเหตุการณ์แผ่นดินไหวหลักเพียงอย่างเดียวมาใช้ในการวิเคราะห์ข้อมูลเชิงลึก แต่เนื่องจากฐานข้อมูลแผ่นดินไหวจะมีการบันทึกทั้งแผ่นดินไหวนำ แผ่นดินไหวหลัก และแผ่นดินไหวตาม ที่เคยเกิดขึ้นไว้ทั้งหมด ดังนั้นจึงต้องอาศัยขั้นตอนการคัดเลือกแผ่นดินไหว เพื่อตัดแผ่นดินไหวนำ และแผ่นดินไหวตามออกไป โดยอาศัยหลักการของความสัมพันธ์ระหว่าง

1. ขนาดความรุนแรงของแผ่นดินไหว
2. ระยะทางระหว่างเหตุการณ์แผ่นดินไหวที่พิจารณา
3. ช่วงเวลาที่เกิดขึ้น


โดยวิธีการคัดเลือกแผ่นดินไหวถูกนำเสนอด้วยกัน 3 แนวคิด ได้แก่ Gardner และ Knopoff (1974) Grunenthal และ Urhammer (1986) ดังแสดงในรูปที่ 3.2 ซึ่งในโครงการนี้ผู้วิจัยเลือกใช้แนวคิดของ Gardner และ Knopoff (1974) โดยมีใจความสำคัญของแนวคิดว่าหากเกิดแผ่นดินไหวหลักขนาดเล็ก พื้นที่ความเสียหายที่เกิดจากแผ่นดินไหวนำและแผ่นดินไหวตามจะไม่กว้างหรือจะครอบคลุมเพียงพื้นที่เล็กๆ และระยะเวลาที่เกิดแผ่นดินไหวตามนั้นก็สั้น ในทางตรงกันข้ามการเกิดแผ่นดินไหวขนาดใหญ่ พื้นที่ความเสียหายที่เกิดจากแผ่นดินไหวนำและแผ่นดินไหวตามก็จะกว้างขึ้น ระยะเวลาของการปรับตัวของแผ่นดินไหวตามก็จะยาวนานขึ้น เนื่องจากพื้นที่ที่ได้รับผลกระทบจากการเคลื่อนตัวของแผ่นดินไหวมีพื้นที่กว้าง จึงต้องใช้เวลาในการปรับให้เข้าสู่สมดุลเป็นเวลานานมากขึ้นนั่นเอง



รูปที่ 3.2 แสดงสมมติฐานการคัดเลือกแผ่นดินไหวหลักออกจากแผ่นดินไหวนำและแผ่นดินไหวตาม จากกลุ่มวิจัยต่าง ๆ ที่นำเสนอในอดีต (Wiemer, 2001)

นอกจากนี้การบันทึกเหตุการณ์แผ่นดินไหวในแต่ละครั้งในแต่ละสถานีตรวจวัดอาจมีการบันทึกข้อมูลแผ่นดินไหวซ้ำกัน ก็จำเป็นจะต้องกำจัดข้อมูลแผ่นดินไหวที่ซ้ำซ้อนกันออกตามแนวทางของ Gardner และ Knopoff (1974) ซึ่งแสดงผลการวิเคราะห์ออกมาเป็นกราฟความสัมพันธ์ระหว่างขนาดแผ่นดินไหว เวลาที่เกิด และระยะทางหรือความลึกของเหตุการณ์แผ่นดินไหว เส้นสีแดงคือ กรอบระยะทางและเวลาของเหตุการณ์แผ่นดินไหวที่ขนาดใดๆ เหตุการณ์แผ่นดินไหวที่มีระยะทางไกล (ต่ำกว่าเส้นสีแดงในกราฟระยะทาง) และระยะเวลาของการเกิดแผ่นดินไหวเกิดภายใน (ต่ำกว่าเส้นสีแดงในกราฟระยะเวลา) ถือเป็นแผ่นดินไหวเหตุการณ์เดียวกัน ดังแสดงในรูปที่ 3.3

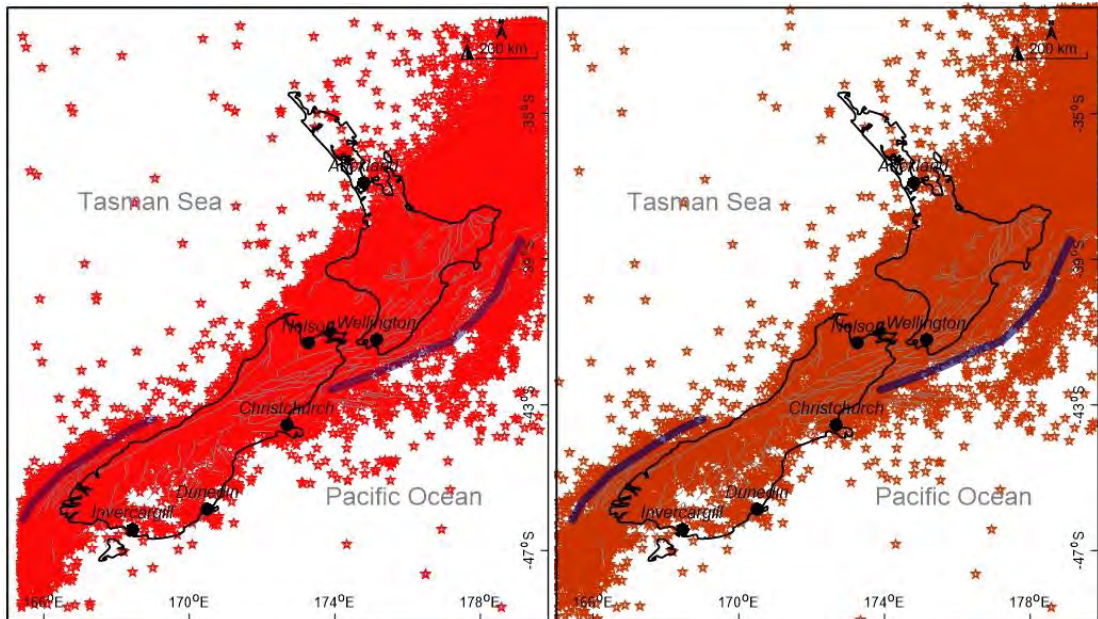
ผลจากการวิเคราะห์สามารถจัดกลุ่มแผ่นดินไหวได้ 13,500 กลุ่มแผ่นดินไหว (earthquake cluster) ซึ่งประกอบด้วยแผ่นดินไหวจำนวน 154,253 เหตุการณ์จากทั้งหมด 182,986 เหตุการณ์ (ซึ่งคิดเป็น 84.2977% จากเหตุการณ์ทั้งหมด) จากผลการวิเคราะห์ดังกล่าวสามารถจำแนกเป็นแผ่นดินไหวหลักทั้งสิ้น 28,733 เหตุการณ์ ในระหว่างปี ค.ศ. 1964-2016 และมีขนาดแผ่นดินไหวตั้งแต่ 1.4-8.0  $M_w$  ด้วยความลึก 0-722.5 กิโลเมตร ซึ่งแสดงผลวิเคราะห์ ดังแสดงในรูปที่ 3.4



รูปที่ 3.3 แสดงผลวิเคราะห์การจัดกลุ่มแผ่นดินไหวตามสมมติฐานของ Gardner และ Knopoff (1974)

<b>EQs in catalog:</b>	28733
<b>Plot Big Events with</b>	7.9
<b>Bin Length in days</b>	14
<b>Beginning year:</b>	1964.0121
<b>Ending year:</b>	2016.8822
<b>Minimum Magnitud</b>	0
<b>Maximum Magnitud</b>	8.1
<b>Min Depth</b>	0
<b>Max Depth</b>	722.5
<b>Info</b>	<b>Go</b>
<b>cancel</b>	

รูปที่ 3.4 แสดงผลสรุปข้อมูลหลังทำการปรับปรุงคุณภาพข้อมูลด้วยการคัดเลือกกลุ่มแผ่นดินไหวหลัก

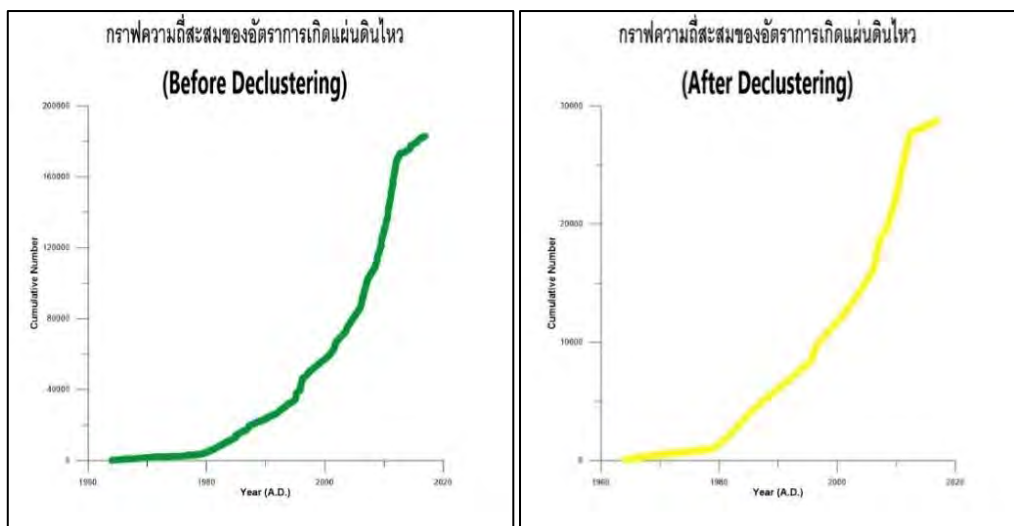


รูปที่ 3.5 แสดงการกระจายตัวของจุดเหนือศูนย์เกิดแผ่นดินไหวที่ได้จากการรวบรวมข้อมูลแผ่นดินไหว (ซ้าย) และที่ได้จากการคัดเลือกกลุ่มแผ่นดินไหวหลักแล้ว (ขวา)

### 3.3.3 การกำจัดความผิดพลาดของข้อมูลแผ่นดินไหวที่เกิดจากกิจกรรมการตรวจวัด (Man-made Seismicity)

ในทางทฤษฎี นักแผ่นดินไหววิทยาเชื่อว่ากลไกหลักของการเกิดแผ่นดินไหวของกระบวนการทางธรณีแปรสัณฐาน เช่น ความเร็วหรือทิศทางของการเคลื่อนที่ของแผ่นเปลือกโลก ไม่สามารถเปลี่ยนแปลงได้อย่างทันทีทันใดในระยะเวลาอันสั้น ดังนั้นอัตราการเกิดแผ่นดินไหวโดยรวมในช่วงระยะเวลาไม่เกิน 100 ปีของฐานข้อมูลแผ่นดินไหวจึงควรมีอัตราการเกิดที่สม่ำเสมอ หรืออีกนัยหนึ่งหากพิจารณาในเชิงจำนวนแผ่นดินไหวตามเวลาของการบันทึก ในรูปแบบของกราฟความสัมพันธ์ดังกล่าวนี้ควรให้ผลเป็นกราฟเส้นตรง

ดังนั้นจึงนำข้อมูลที่ได้หลังจากการคัดเลือกกลุ่มแผ่นดินไหวหลักมาพิจารณาในรูปแบบของกราฟความสัมพันธ์ พบว่ากราฟความสัมพันธ์ของข้อมูลแผ่นดินไหวหลังการคัดเลือกกลุ่มแผ่นดินไหวหลัก มีความเป็นเส้นตรงมากขึ้นกว่าข้อมูลแผ่นดินไหวเดิมที่ยังไม่ได้ทำการปรับปรุงข้อมูล ดังแสดงในรูปที่ 3.6 แต่ก็ยังไม่ถือว่าเป็นเส้นตรงสมบูรณ์ตามหลักการ จึงเป็นผลว่าข้อมูลแผ่นดินไหวที่ผ่านการคัดเลือกกลุ่มแผ่นดินไหวหลักนี้ก็ยังไม่สมบูรณ์ 100% จึงต้องนำข้อมูลแผ่นดินไหวไปปรับปรุงคุณภาพอีกในขั้นตอนถัดไป

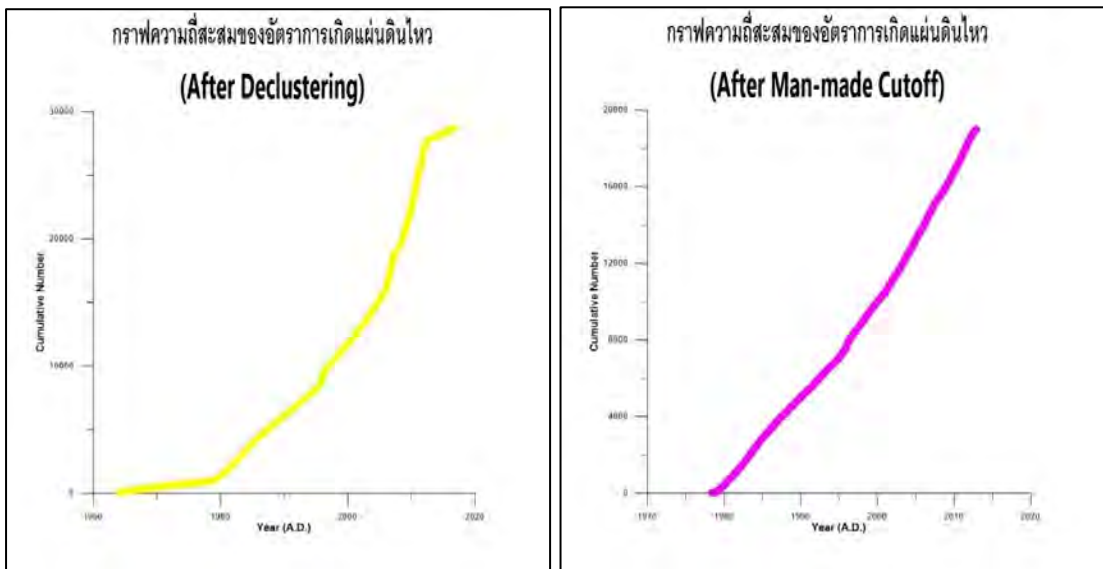


รูปที่ 3.6 แสดงการเปรียบเทียบกราฟความถี่สะสมระหว่างข้อมูลแผ่นดินไหวก่อนดำเนินการปรับปรุงฐานข้อมูล (ซ้าย) และข้อมูลแผ่นดินไหวหลังผ่านกระบวนการคัดเลือกกลุ่มแผ่นดินไหวหลัก (ขวา)


เมื่อทำการกำจัดแผ่นดินไหวที่เกิดจากการกระทำของมนุษย์ พบว่าเหลือข้อมูลแผ่นดินไหวที่เหมาะสมจำนวน 19,012 เหตุการณ์ ที่เกิดขึ้นในช่วงปี ค.ศ. 1978-2012 มีขนาดตั้งแต่ 3.3-8.1  $M_w$  ดังข้อมูลที่แสดงในรูปที่ 3.7 จากนั้นนำมาตรวจสอบความสมบูรณ์ของข้อมูลแผ่นดินไหวในรูปแบบของกราฟความสัมพันธ์ดังกล่าวข้างต้น พบว่ากราฟความถี่สะสมมีลักษณะเป็นเส้นตรงมากยิ่งขึ้น ดังแสดงในรูปที่ 3.8 แสดงถึงข้อมูลแผ่นดินไหวที่มีความสมบูรณ์มากขึ้นนั่นเอง

<b>EQs in catalog:</b>	19012
<b>Plot Big Events with</b>	7.9
<b>Bin Length in days</b>	14
<b>Beginning year:</b>	1978.4001
<b>Ending year:</b>	2012.958
<b>Minimum Magnitude</b>	3.3
<b>Maximum Magnitude</b>	8.1
<b>Min Depth</b>	0
<b>Max Depth</b>	722.5
<b>Info</b>	<b>Go</b>
<b>cancel</b>	

รูปที่ 3.7 แสดงข้อมูลแผ่นดินไหวหลังทำการกำจัดความผิดพลาดที่เกิดจากกิจกรรมการตรวจวัด



รูปที่ 3.8 แสดงการเปรียบเทียบกราฟความถี่สะสมของข้อมูลแผ่นดินไหวระหว่างข้อมูลแผ่นดินไหวหลังผ่านกระบวนการคัดเลือกกลุ่มแผ่นดินไหวหลัก (ซ้าย) และ ข้อมูลแผ่นดินไหวหลังจากกำจัดผลกระทบจากการกระทำของมนุษย์ (ขวา)



รูปที่ 3.9 แสดงการกระจายตัวของจุดเหนือศูนย์เกิดแผ่นดินไหวที่ได้จากการคัดเลือกกลุ่มแผ่นดินไหวหลัก (ซ้าย) และที่ได้จากการกำจัดความผิดพลาดที่เกิดจากกิจกรรมการตรวจวัด (ขวา)

### 3.3.4 การคัดเลือกระดับของแผ่นดินไหวที่มีความสมบูรณ์ (Magnitude of Completeness)


จากการศึกษาในอดีต นักแผ่นดินไหววิทยาพบว่ามีความไม่สมบูรณ์ของการตรวจวัดแผ่นดินไหวอันเนื่องมาจากประสิทธิภาพและความไวต่อสัญญาณคลื่นแผ่นดินไหวของเครื่องมือตรวจวัด เช่นในกรณีแผ่นดินไหวที่มีขนาดเล็ก แรงสั่นสะเทือนบางส่วนไม่สามารถตรวจจับได้ด้วยเครื่องมือทั้งที่มีการเกิดแผ่นดินไหวขึ้นจริง

ด้วยเหตุนี้จึงมีการกำหนดขนาดแผ่นดินไหวต่ำสุดที่มีความสมบูรณ์ที่ตรวจวัดได้จากเครื่องมือเรียกขนาดแผ่นดินไหวนี้ว่า Magnitude of completeness หรือ  $M_c$  (Woessner และ Wiemer, 2005) โดยค่า  $M_c$  หมายถึง ระดับขนาดแผ่นดินไหวที่เครือข่ายสามารถตรวจวัดได้ทุกเหตุการณ์ที่แผ่นดินไหวเกิดขึ้น ในขณะที่แผ่นดินไหวขนาดเล็กกว่า  $M_c$  นั้นบางเครือข่ายไม่สามารถตรวจวัดได้ ดังนั้นการกำหนดค่า  $M_c$  ให้ถูกต้องจึงส่งผลต่อการวิเคราะห์พฤติกรรมการเกิดแผ่นดินไหวได้อย่างถูกต้องและมีความน่าเชื่อถือมากยิ่งขึ้น

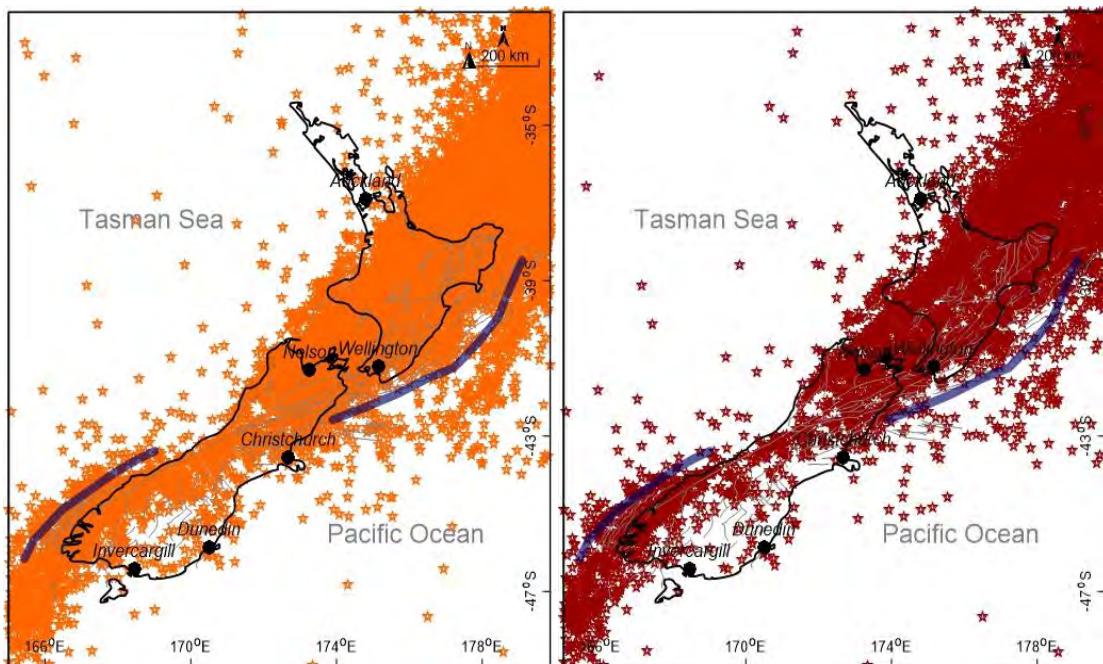
เมื่อได้วิเคราะห์ข้อมูลแผ่นดินไหวเพื่อคัดเลือกขนาดแผ่นดินไหวต่ำสุดที่มีความสมบูรณ์ในรูปแบบของกราฟความสัมพันธ์ระหว่างความถี่สะสมของการเกิดแผ่นดินไหวและขนาดแผ่นดินไหว จึงมีการกำหนดค่า  $M_c = 4.0$  ดังรูป 3.10 ซึ่งหมายความว่า ข้อมูลแผ่นดินไหวต่ำสุดที่มีความสมบูรณ์คือแผ่นดินไหวที่มีขนาด  $4.0 M_w$  ขึ้นไป

หลังจากทำการปรับปรุงคุณภาพข้อมูลแผ่นดินไหวผ่านกระบวนการทางสถิติทั้งหมดข้างต้นถือว่าฐานข้อมูลที่ได้นั้นมีคุณภาพและมีความสมบูรณ์มากพอที่สามารถนำไปวิเคราะห์พฤติกรรมการเกิดแผ่นดินไหวได้อย่างถูกต้องและแม่นยำ ซึ่งข้อมูลแผ่นดินไหวสุทธิบริเวณละติจูดที่ 164.998 ถึง 179.875 ลองจิจูด - 48.942 ถึง - 32.093 มีจำนวนทั้งหมด 5,710 เหตุการณ์ เกิดขึ้นในช่วงปี ค.ศ. 1978-2012 โดยมีขนาดแผ่นดินไหวตั้งแต่ 4.0-7.9  $M_w$  ขึ้นไป





รูปที่ 3.10 แสดงการคัดเลือกแผ่นดินไหวที่มีความสมบูรณ์จากเครื่องตรวจวัด



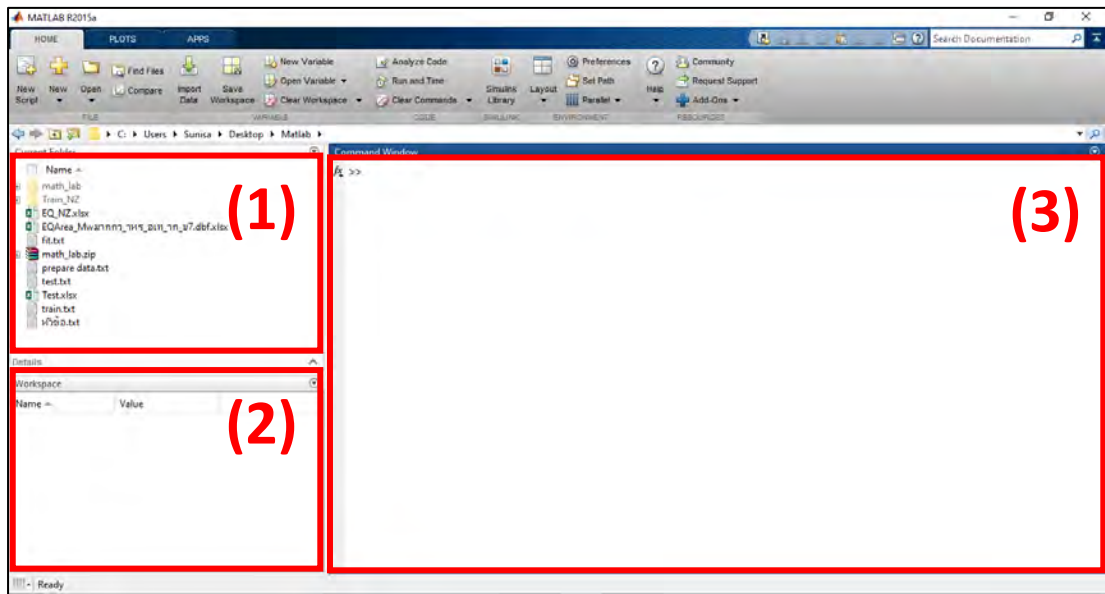
รูปที่ 3.11 แสดงการกระจายตัวของจุดเหนือศูนย์เกิดแผ่นดินไหวที่ได้จากการกำจัดความผิดพลาดที่เกิดจากกิจกรรมการตรวจวัด (ซ้าย) และที่ได้จากการคัดเลือกระดับของแผ่นดินไหวที่มีความสมบูรณ์

(ขวา)



### 3.4 วิเคราะห์ข้อมูลด้วยโครงข่ายประสาท

งานวิจัยนี้ทำการสร้างโครงข่ายประสาทเทียมผ่านฟังก์ชันของโปรแกรม Matlab R2015a โดยสามารถเรียกใช้งานฟังก์ชันโครงข่ายประสาทเทียมได้ 2 วิธีคือเรียกใช้งานผ่าน Neural Network Toolbox หรือทำการสร้างจากการป้อนชุดคำสั่งผ่านหน้าจอคำสั่ง



รูปที่ 3.12 แสดงหน้าจอพื้นฐานของโปรแกรม Matlab2015a

- (1) แสดงพื้นที่จัดเก็บข้อมูลที่โปรแกรมเชื่อมต่ออยู่
- (2) แสดงข้อมูลตัวแปรที่ถูกป้อนเข้า ตัวแปรที่ถูกจัดเก็บในระหว่างการทำงานของโครงข่าย ซึ่งพร้อมสำหรับการใช้งาน
- (3) พื้นที่สำหรับป้อนคำสั่งการทำงานให้แก่โปรแกรม

จากที่กล่าวไปแล้วในบทที่ 2 ว่าโครงข่ายประสาทเทียมเป็นการทำงานเลียนแบบรูปแบบความคิดเรียนรู้และจดจำข้อมูลของสมองมนุษย์ งานวิจัยนี้มีความต้องการสร้างโครงข่ายประสาทเทียมที่เหมาะสมต่อพฤติกรรมแผ่นดินไหวของประเทศนิวซีแลนด์เพื่อให้โครงข่ายสามารถคาดการณ์ขนาดแผ่นดินไหวในช่วงเวลาที่กำหนดในอนาคตได้ จึงต้องมีการนำข้อมูลที่สื่อถึงพฤติกรรมแผ่นดินไหวที่ได้ทำการรวบรวมมาแล้วในหัวข้อข้างต้น มาให้โครงข่ายทำการศึกษาค้นคว้า โดยข้อมูลต้นตอที่จะใส่ในชั้นข้อมูลป้อนเข้าของโครงข่ายคือ ละติจูด ลองจิจูด วัน เดือน ปี เวลาเป็น ชั่วโมงและนาที จาก 5,710 เหตุการณ์ โดยมีข้อมูลขนาดแผ่นดินไหวในมาตราโมเมนต์ ( $M_w$ ) เป็นข้อมูลในชั้นข้อมูลส่งออก

สำหรับฟังก์ชันการแปลงในโปรแกรม Matlab2015a จะมีคำสั่งการทำงานที่มีความสมบูรณ์อยู่แล้วในตัวโปรแกรมและสามารถเรียกใช้ได้ตาม Neural Network Toolbox โดยใช้คำสั่ง 'trainFcn' ฟังก์ชันการแปลงมีทั้งหมด 12 ฟังก์ชันดังแสดงในตาราง 3.2

ตาราง 3.2 แสดงชุดคำสั่งของฟังก์ชันการแปลงแต่ละชนิดในโปรแกรม Matlab2015a

Function	Algorithm
trainlm	Levenberg-Marquardt
trainbr	Bayesian Regularization
trainbfg	BFGS Quasi-Newton
trainrp	Resilient Backpropagation
trainscg	Scaled Conjugate Gradient
traincgb	Conjugate Gradient with Powell/Beale Restarts
traincgf	Fletcher-Powell Conjugate Gradient
traincgp	Polak-Ribière Conjugate Gradient
trainoss	One Step Secant
traingdx	Variable Learning Rate Gradient Descent
traingdm	Gradient Descent with Momentum
traingd	Gradient Descent

### 3.4.1 การสร้างโครงข่าย

ขั้นตอนการสร้างโครงข่ายประสาทเทียมมีดังนี้

#### 3.4.1.1 การแบ่งข้อมูล

ข้อมูลแผ่นดินไหวทั้ง 5,710 ข้อมูล จะถูกแบ่งออกเป็น 3 ชุดข้อมูล โดยใช้การแบ่งสุ่ม (random) จากคำสั่ง 'dividerand' ป้อนเข้าสู่หน้าจอป้อนคำสั่งพร้อมกันกับคำสั่งอื่นในขั้นตอนการสร้างโครงข่าย

ข้อมูล 3 ชุดข้อมูล ประกอบด้วย

- ชุดเรียนรู้ (Learning set) 80% ไว้สำหรับฝึกสอนโครงข่ายให้ทำความรู้จักพฤติกรรมแผ่นดินไหวและสร้างความสัมพันธ์ของข้อมูลป้อนเข้าและข้อมูลส่งออกให้ได้ค่าของข้อมูลส่งออกใกล้เคียงกับค่าที่กำหนดมากที่สุด

- ชุดการให้เหตุผล (Validation set) 10% เป็นชุดข้อมูลที่ใช้ในการตรวจสอบความสามารถในการเรียนรู้ของโครงข่ายว่ามีการเรียนรู้เกิดขึ้นจริง
- ชุดทดสอบ (Testing set) 10% เป็นชุดข้อมูลที่โครงข่ายไม่เคยเรียนรู้มาก่อน มีไว้เพื่อทดสอบโครงข่ายโดยดูแนวโน้มการลดลงของความผิดพลาดของค่าที่ได้จากการทำนายโครงข่ายกับค่าข้อมูลจริง

### 3.4.1.2 การสร้างโครงข่าย

- สร้างโครงข่ายโดยใช้คำสั่ง `net = feedforwardnet(hiddenSizes,'trainFcn')`
- ฝึกสอนโครงข่ายโดยใช้ข้อมูลและคำสั่งที่กำหนด โดยใช้ฟังก์ชันการแปลงทั้ง 12 ฟังก์ชันโดยใช้ค่าตัวแปรในฟังก์ชันตามค่าเริ่มต้น (default) ของแต่ละฟังก์ชัน

The screenshot shows the MATLAB Neural Network Training interface. On the left, the Command Window contains the following code:

```
>> net = fitnet(hiddenSizes,'trainlm');
% Setup Division of Data for Training, Validation, Testing
% For a list of all data division functions type: help nn
net.divideFcn = 'dividerand'; % Divide data randomly
net.divideMode = 'sample'; % Divide up every sample
net.divideParam.trainRatio = 80/100;
net.divideParam.valRatio = 10/100;
net.divideParam.testRatio = 10/100;
>> net = train(net,input,target);
fx >>
```

On the right, the Neural Network Training window (ntraintool) displays the following information:

**Neural Network**

Input → Hidden 1 (17) → Hidden 2 (10) → Output (1)

**Algorithms**

Data Division: Random (dividerand)  
 Training: Levenberg-Marquardt (trainlm)  
 Performance: Mean Squared Error (mse)  
 Calculations: MATLAB

**Progress**

Epoch:	0	8 iterations	1000
Time:		0:00:05	
Performance:	3.24	0.217	0.00
Gradient:	16.3	0.0900	1.00e-07
Mu:	0.00100	0.000100	1.00e+10
Validation Checks:	0	6	6

**Plots**

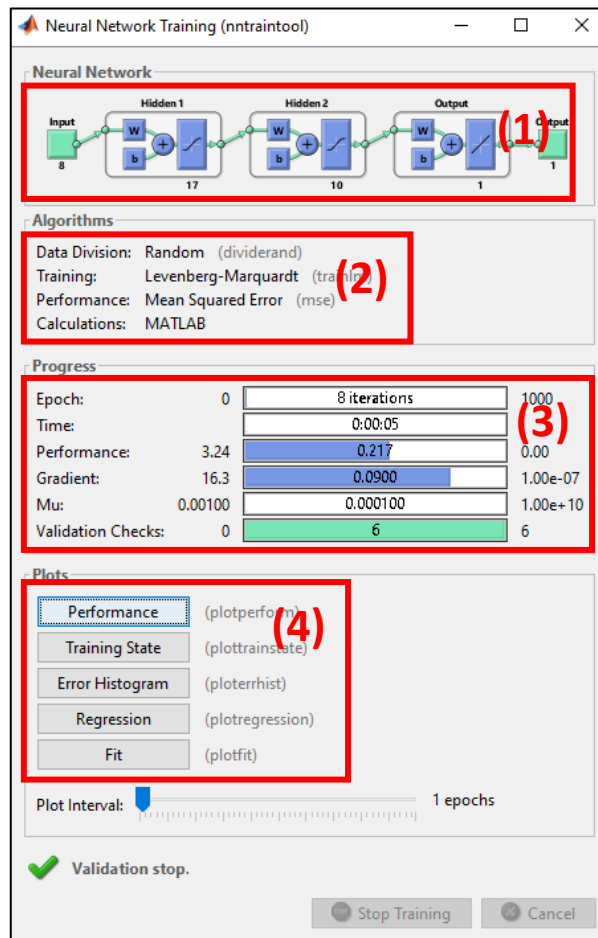
Performance (plotperform)  
 Training State (plottrainstate)  
 Error Histogram (ploterrhist)  
 Regression (plotregression)  
 Fit (plotfit)

Plot Interval: 1 epochs

Validation stop.

Buttons: Stop Training, Cancel

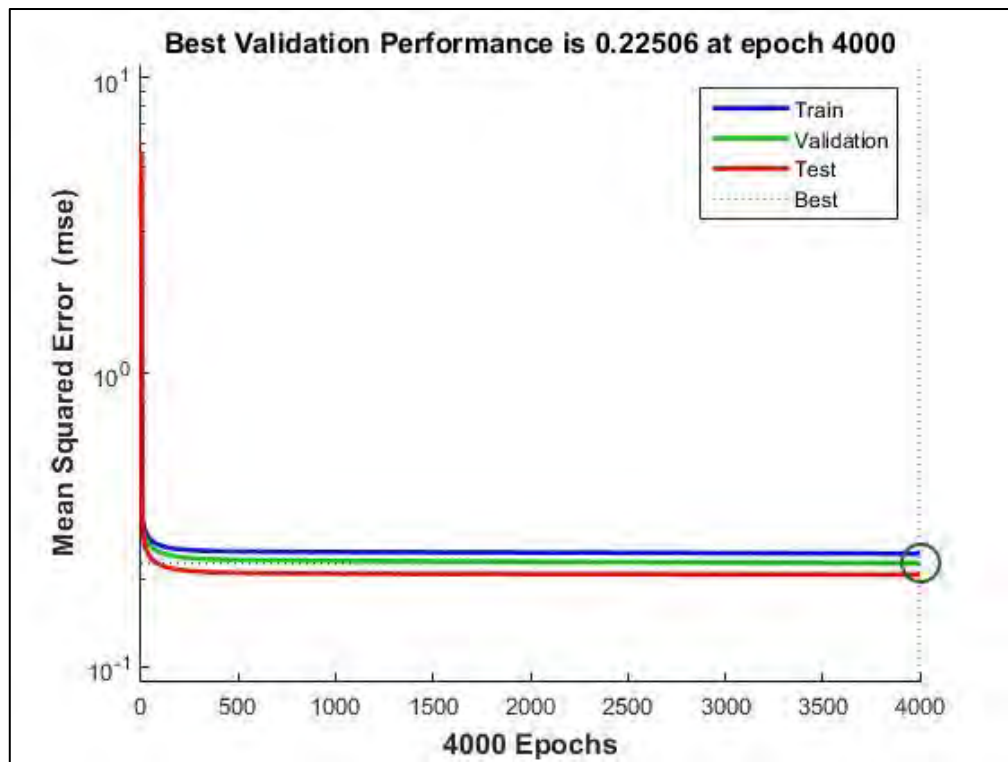
รูปที่ 3.13 แสดงตัวอย่างชุดคำสั่ง (สีเหลี่ยมสีแดง) การสร้างโครงข่ายประสาทเทียมโดยมีฟังก์ชันการแปลงแบบ trainlm



รูปที่ 3.14 หน้าต่างแสดงการทำงานของโครงข่าย (1) ส่วนประกอบของโครงข่าย (2) อัลกอริทึมที่ใช้ในโครงข่าย (3) ความคืบหน้าการเรียนรู้ของโครงข่าย (4) หน้าต่างแสดงผลต่าง ๆ ของโครงข่าย

### 3.4.2 การคัดเลือกและปรับปรุงโครงข่าย

การคัดเลือกโครงข่ายที่เหมาะสมทำได้โดยการประเมินจากค่าเฉลี่ยความผิดพลาด (Mean Square Error, MSE) ของค่าผลลัพธ์ที่ได้จากโครงข่ายกับค่าเป้าหมาย (target) โดยจะคัดเลือกโครงข่ายที่ให้ค่าเฉลี่ยความผิดพลาดน้อยที่สุดมาทำการปรับแก้ค่าตัวแปรในฟังก์ชันการแปลงให้ได้ค่าผลลัพธ์จากโครงข่ายใกล้เคียงกับค่าเป้าหมายมากยิ่งขึ้น ค่าเฉลี่ยความผิดพลาดสามารถดูได้จากหน้าต่างแสดงประสิทธิภาพ (performance) ของโครงข่าย ดังแสดงในรูปที่ 3.15



รูปที่ 3.15 แสดงหน้าต่างประสิทธิภาพการทำงานของโครงข่าย แสดงความสัมพันธ์ระหว่างค่าเฉลี่ยความผิดพลาด (mse) กับจำนวนการวนซ้ำ (Epochs)

### 3.5 การทดสอบประสิทธิภาพโครงข่าย

ใช้ชุดข้อมูลแผ่นดินไหวในปี 2013-2016 จำนวน 316 ข้อมูล เพื่อเป็นตัวทดสอบประสิทธิภาพโครงข่ายที่ปรับปรุงแล้ว และแสดงค่าประสิทธิภาพของโครงข่ายออกมาในรูปแบบของ

1. ค่าเฉลี่ยความผิดพลาด (Mean Square Error)

$$MSE = \frac{1}{n} \sum_{i=1}^n error_i^2$$


## บทที่ 4

### ผลการศึกษา


#### 4.1 การวิเคราะห์ข้อมูลด้วยโครงข่ายประสาทเทียมของฟังก์ชันการแปลงทั้ง 12 ฟังก์ชัน

การสร้างโครงข่ายประสาทเทียมทั้ง 12 ฟังก์ชันการแปลงพบว่า ฟังก์ชันการแปลงที่ทำให้โครงข่ายประสาทเทียมมีประสิทธิภาพการทำงานที่ดีที่สุดคือ trainlm (Levenberg-Marquardt backpropagation), trainingd (Gradient descent backpropagation) และ trainingdm (Gradient descent with momentum backpropagation) โดยมีค่าเฉลี่ยความคลาดเคลื่อนเท่ากับ 0.23542, 0.2402 และ 0.24113 ตามลำดับ ซึ่งแสดงประสิทธิภาพของโครงข่ายออกมาเป็นกราฟความสัมพันธ์ระหว่างค่าความคลาดเคลื่อนเฉลี่ยกับจำนวนครั้งในการวนซ้ำ ดังแสดงในรูปที่ 4.1, 4.2 และ 4.3

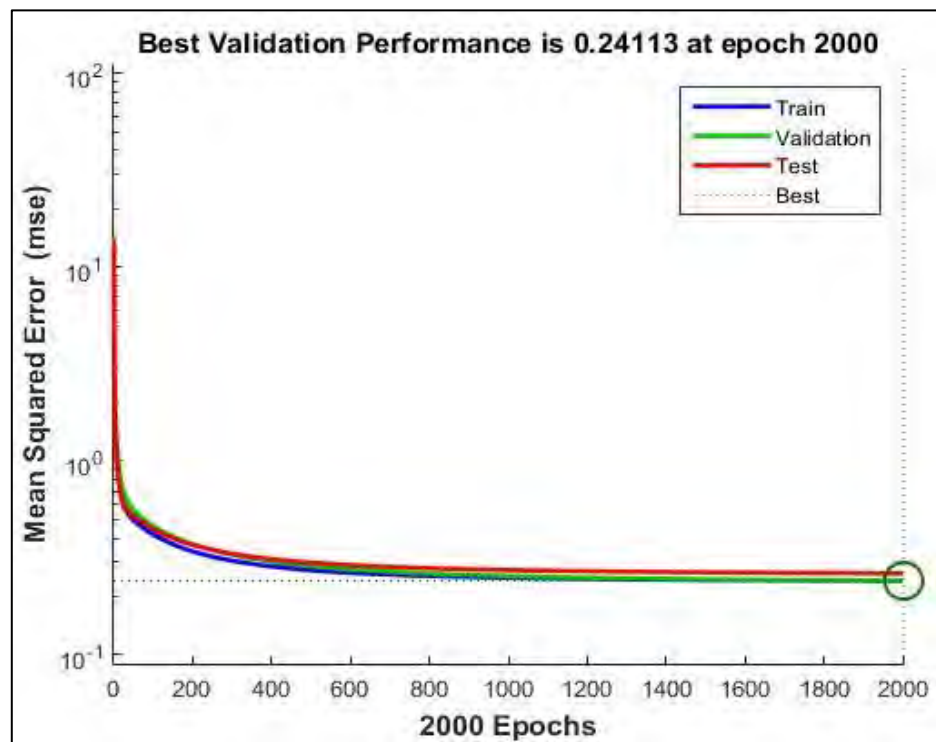
ดังนั้น ผู้วิจัยจึงได้เลือกเอาโครงข่ายทั้ง 3 นี้มาทำการปรับเปลี่ยนพารามิเตอร์ที่เกี่ยวข้องและมีผลต่อการเรียนรู้ของโครงข่ายเพิ่มเติม เพื่อให้โครงข่ายมีประสิทธิภาพที่ดีขึ้น



รูปที่ 4.1 ภาพหน้าต่างแสดงประสิทธิภาพการทำงานของโครงข่ายประสาทเทียมที่มีฟังก์ชันการแปลงแบบ trainlm



รูปที่ 4.2 ภาพหน้าต่างแสดงประสิทธิภาพการทำงานของโครงข่ายประสาทเทียมที่มีฟังก์ชันการแปลงแบบ traingd



รูปที่ 4.3 ภาพหน้าต่างแสดงประสิทธิภาพการทำงานของโครงข่ายประสาทเทียมที่มีฟังก์ชันการแปลงแบบ traingdm

## 4.2 ผลการปรับปรุงโครงข่าย

ทำการปรับค่าพารามิเตอร์ในฟังก์ชันการแปลงซึ่งมีผลต่อประสิทธิภาพของโครงข่าย เนื่องจากเป็นตัวแปรเหล่านี้เป็นตัวกำหนดรายละเอียดการเรียนรู้ของโครงข่าย เช่น จำนวนชั้นซ่อน (Number of hidden layer) จำนวนโหนดในชั้นแอบแฝง (Number of node in hidden layer) ค่าอัตราการเรียนรู้ (Learning rate) ค่าโมเมนตัม (Momentum) และอื่น ๆ

จำนวนชั้นซ่อนและจำนวนโหนดในชั้นซ่อนมีผลต่อการวิเคราะห์ข้อมูลของโครงข่าย โดยปกติโครงข่ายประสาทเทียมที่มีจำนวนชั้นซ่อนหลายชั้นจะช่วยให้การแก้ปัญหาที่มีความซับซ้อนได้ดีขึ้น ในแต่ละชั้นซ่อนจะมีโหนด ซึ่งเปรียบเสมือนเซลล์ประสาทหนึ่งเซลล์ที่มีการทำงานทั้งรับข้อมูลประมวลผล และส่งออก ทั้งระบบได้ภายในเซลล์เดียว ดังนั้นจำนวนโหนดในชั้นซ่อนที่เหมาะสมจึงทำให้โครงข่ายมีประสิทธิภาพดีขึ้น แต่หากมีจำนวนโหนดในชั้นซ่อนมากเกินไปจะทำให้โครงข่ายมีความจำเพาะต่อข้อมูลมากเกินไป (Overfitting) ทำให้โครงข่ายไม่เกิดการเรียนรู้ที่เหมาะสม ประสิทธิภาพของโครงข่ายที่นำไปทดสอบกับข้อมูลใหม่จึงมีค่าน้อย งานวิจัยของ Reyes และคณะ (2012) พบว่าจำนวนโหนดที่เหมาะสมในชั้นซ่อนมีค่าเท่ากับ  $2n+1$  โดยที่  $n$  คือข้อมูลในชั้นรับข้อมูลเข้า

อัตราการเรียนรู้และโมเมนตัมมีผลต่อประสิทธิภาพและการเรียนรู้ของโครงข่าย อัตราการเรียนรู้คือตัวแปรใน Gradient descent algorithm ที่กำหนดให้โครงข่ายเกิดการเรียนรู้และจดจำค่าน้ำหนัก (weight) ที่ทำให้ค่าความผิดพลาดมีค่าต่ำที่สุดจากค่าน้ำหนักเริ่มต้น แต่หากค่าการเรียนรู้มีมากเกินไปจะทำให้โครงข่ายไม่เกิดการเรียนรู้ และเกิดการวนซ้ำอยู่ในจุดที่เรียกว่า Local minimum (บทที่ 2) โมเมนตัมคือตัวแปรใน Gradient descent algorithm with momentum เป็นตัวแปรที่บังคับให้โครงข่ายมีการเปลี่ยนแปลงค่าน้ำหนัก (weight change) ในการวนซ้ำครั้งถัดไป (iteration ที่  $n+1$ ) ช่วยให้โครงข่ายไม่ติดอยู่ในจุด Local minimum งานวิจัยของ Bodri (2001) ค่าการเรียนรู้และโมเมนตัมที่เหมาะสมต่อการศึกษาแผ่นดินไหวคือ 0.5 และ 0.9 ตามลำดับ




เมื่อทำการปรับเปลี่ยนค่าพารามิเตอร์ในฟังก์ชันการแปลง พบว่าโครงข่ายมีประสิทธิภาพที่ดีขึ้น ดังนี้

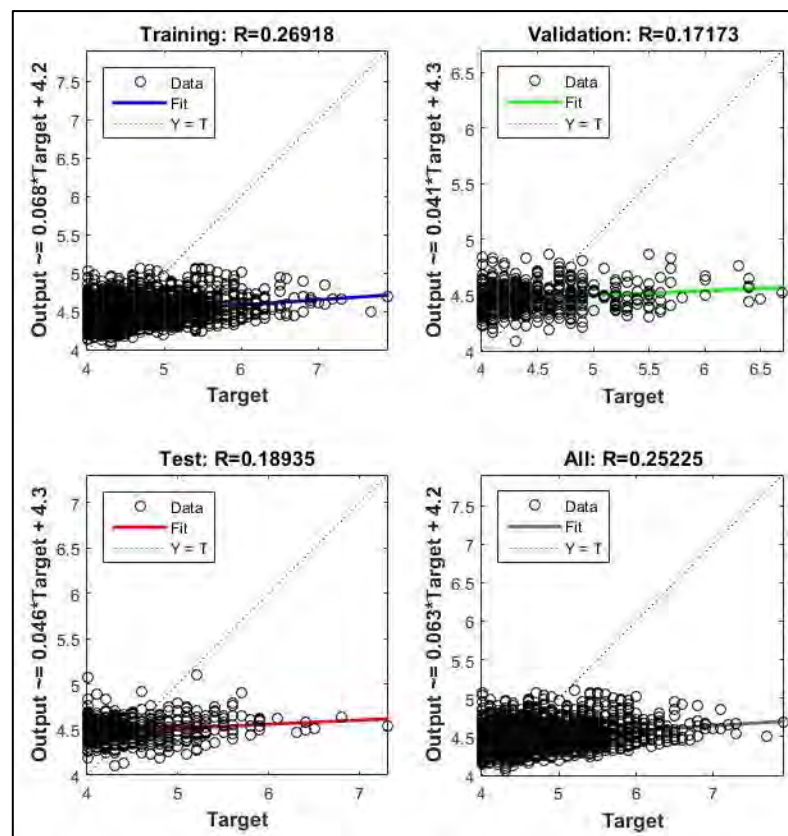
#### 4.2.1 โครงข่ายประสาทเทียมที่มีฟังก์ชันการแปลงเป็น `trainlm`

ตาราง 4.1 แสดงค่าพารามิเตอร์ต่าง ๆ ในฟังก์ชัน `trainlm` ที่ให้ประสิทธิภาพที่ดีที่สุด

คำสั่ง	ค่า	ความหมาย
<code>net.trainParam.epochs</code>	4000	Maximum number of epochs to train
<code>net.trainParam.goal</code>	0	Performance goal
<code>net.trainParam.max_fail</code>	6	Maximum validation failures
<code>net.trainParam.min_grad</code>	1e-5	Minimum performance gradient
<code>net.trainParam.mu</code>	0.001	Initial mu
<code>net.trainParam.mu_dec</code>	0.1	mu decrease factor
<code>net.trainParam.mu_inc</code>	10	mu increase factor
<code>net.trainParam.mu_max</code>	1e10	Maximum mu
<code>net.trainParam.show</code>	25	Epochs between displays (NaN for no displays)
<code>net.trainParam.showCommandLine</code>	false	Generate command-line output
<code>net.trainParam.showWindow</code>	true	Show training GUI
<code>net.trainParam.time</code>	inf	Maximum time to train in seconds
<code>hiddenSizes(17)</code>	17	Number of node in hidden layer



รูปที่ 4.4 ภาพหน้าต่างแสดงประสิทธิภาพการทำงานของโครงข่ายประสาทเทียมที่มีฟังก์ชันการแปลงแบบ trainlm จากการกำหนดตัวแปรตามตาราง 4.1

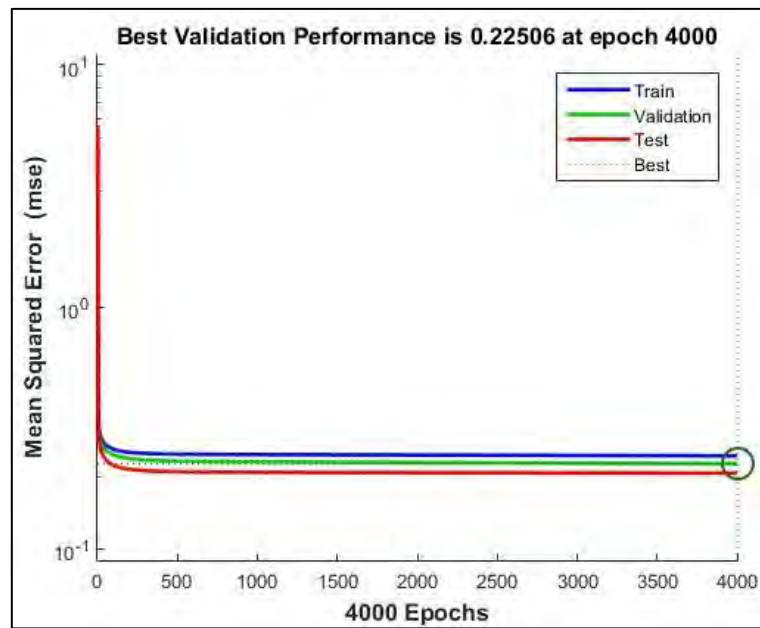


รูปที่ 4.5 ภาพหน้าต่างแสดงกราฟการถดถอยของจากการเรียนรู้ของโครงข่ายประสาทเทียมที่มีฟังก์ชันการแปลงแบบ trainlm จากการกำหนดตัวแปรตามตาราง 4.1

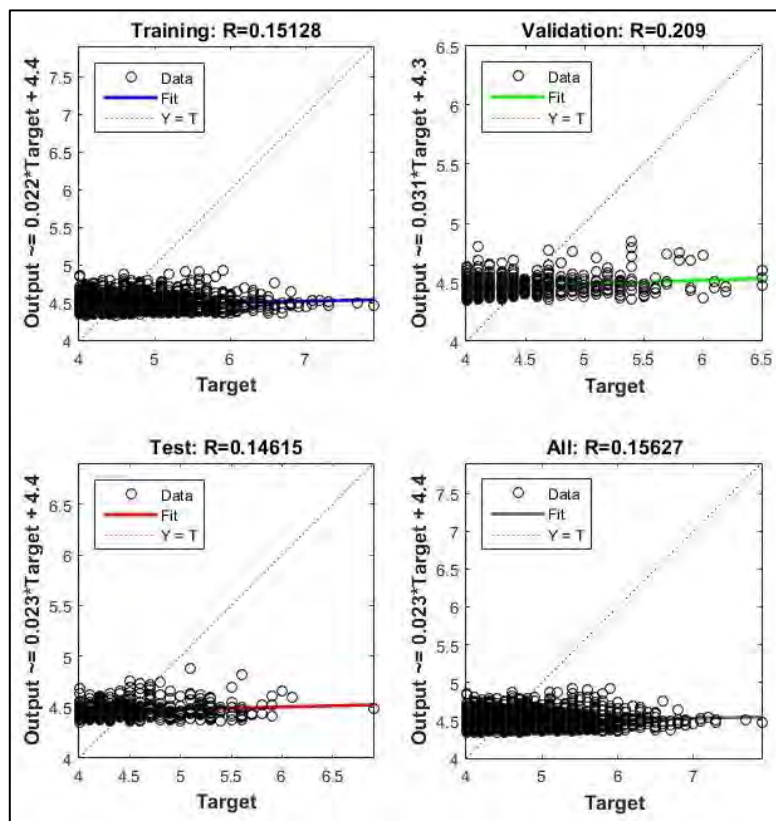
#### 4.2.2 โครงข่ายประสาทเทียมที่มีฟังก์ชันการแปลงเป็น `traingd`

ตาราง 4.2 แสดงค่าตัวแปรต่าง ๆ ในฟังก์ชัน `traingd` ที่ให้ประสิทธิภาพที่ดีที่สุด

คำสั่ง	ค่า	ความหมาย
<code>net.trainParam.epochs</code>	4000	Maximum number of epochs to train
<code>net.trainParam.goal</code>	0	Performance goal
<code>net.trainParam.showCommandLine</code>	false	Generate command-line output
<code>net.trainParam.showWindow</code>	true	Show training GUI
<code>net.trainParam.lr</code>	0.04	Learning rate
<code>net.trainParam.max_fail</code>	6	Maximum validation failures
<code>net.trainParam.min_grad</code>	1e-7	Minimum performance gradient
<code>net.trainParam.show</code>	25	Epochs between displays (NaN for no displays)
<code>net.trainParam.time</code>	inf	Maximum time to train in seconds
HiddenSizes [17,10]	2	Number of hidden layer
	17,10	Number of node in hidden layer



รูปที่ 4.6 ภาพหน้าต่างแสดงประสิทธิภาพการทำงานของโครงข่ายประสาทเทียมที่มีฟังก์ชันการแปลงแบบ trained จากการทำหนดตัวแปรตามตาราง 4.2




รูปที่ 4.7 ภาพหน้าต่างแสดงกราฟการถดถอยของจากการเรียนรู้ของโครงข่ายประสาทเทียมที่มีฟังก์ชันการแปลงแบบ trained จากการทำหนดตัวแปรตามตาราง 4.2

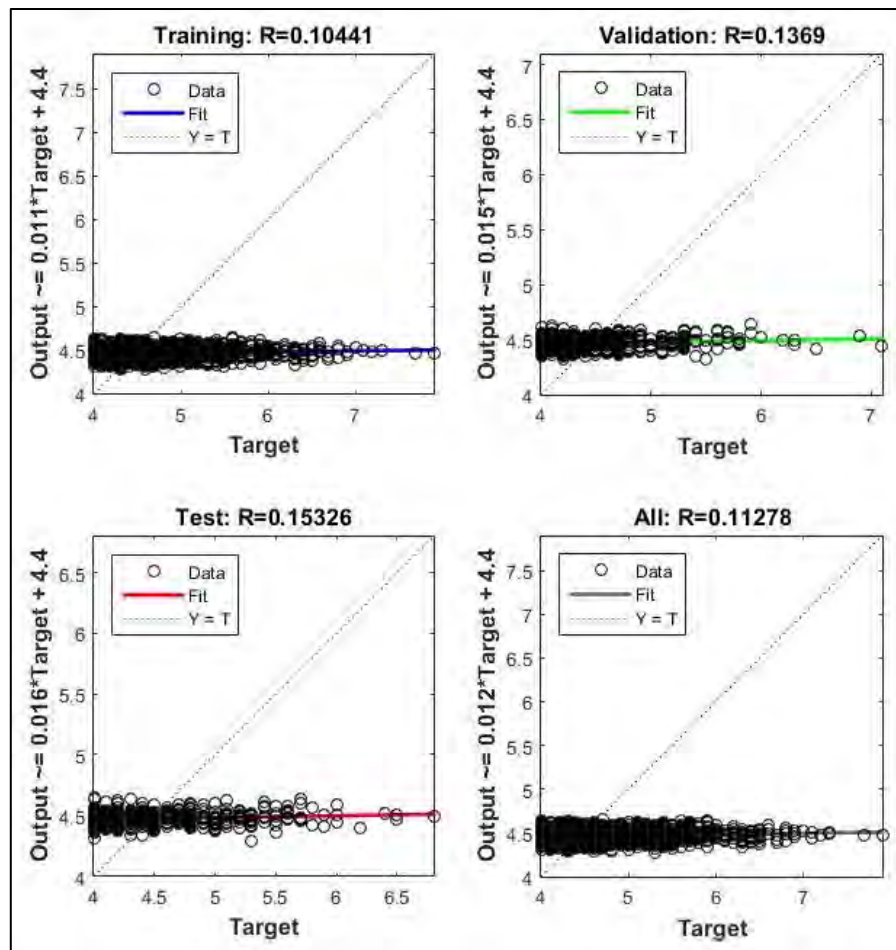
### 4.2.3 โครงข่ายประสาทเทียมที่มีฟังก์ชันการแปลงเป็น traingdm

ตาราง 4.3 แสดงค่าตัวแปรต่าง ๆ ในฟังก์ชัน traingdm ที่ให้ประสิทธิภาพที่ดีที่สุด

คำสั่ง	ค่า	ความหมาย
net.trainParam.epochs	4000	Maximum number of epochs to train
net.trainParam.goal	0	Performance goal
net.trainParam.lr	0.04	Learning rate
net.trainParam.max_fail	6	Maximum validation failures
net.trainParam.mc	0.7	Momentum constant
net.trainParam.min_grad	1e-7	Minimum performance gradient
net.trainParam.show	25	Epochs between showing progress
net.trainParam.showCommandLine	false	Generate command-line output
net.trainParam.showWindow	true	Show training GUI
net.trainParam.time	inf	Maximum time to train in seconds



รูปที่ 4.8 ภาพหน้าต่างแสดงประสิทธิภาพการทำงานของโครงข่ายประสาทเทียมที่มีฟังก์ชันการแปลงแบบ traingdm จากการกำหนดตัวแปรตามตาราง 4.3



รูปที่ 4.9 ภาพหน้าต่างแสดงกราฟการถดถอยของจากการเรียนรู้ของโครงข่ายประสาทเทียมที่มี

ฟังก์ชันการแปลงแบบ `trainsgdm` จากการกำหนดตัวแปรตามตาราง 4.3


## บทที่ 5

### อภิปรายและสรุปผลการศึกษา

#### 5.1 อภิปรายผลการศึกษา

จากผลการปรับปรุงโครงข่ายพบว่า โครงข่ายที่มีประสิทธิภาพมากที่สุดคือโครงข่ายประสาทเทียมที่มีฟังก์ชันการแปลงแบบ trainlm (Levenberg-Marquardt backpropagation) โดยมีค่าเฉลี่ยความคลาดเคลื่อนเท่ากับ 0.22651 และมีค่าสัมประสิทธิ์การถดถอย (Regression Coefficient) ประมาณ 0.25225

นำโครงข่ายประสาทเทียมที่มีฟังก์ชันการแปลงแบบ trainlm (Levenberg-Marquardt backpropagation) มาทำการทดสอบประสิทธิภาพโดยให้โครงข่ายวิเคราะห์ชุดข้อมูลแผ่นดินไหวในปี 2013-2016 จำนวน 316 ข้อมูล เพื่อให้โครงข่ายคาดการณ์ขนาดแผ่นดินไหวที่เกิดขึ้นช่วงเวลาดังกล่าว ได้ผลดังแสดงในรูปที่ 5.1



รูปที่ 5.1 กราฟแสดงความสัมพันธ์ระหว่างลอการิทึมของค่าขนาดแผ่นดินไหวที่ได้จากโครงข่ายประสาทเทียม  $\log(\text{Output})$  กับค่าขนาดแผ่นดินไหวที่ตรวจวัดได้จริง (Target)

จากกราฟความสัมพันธ์ดังที่แสดงไปแล้วข้างต้น พบว่าความสัมพันธ์ระหว่างลอการิทึมของค่าขนาดแผ่นดินไหวที่ได้จากโครงข่ายประสาทเทียม  $\log(\text{Output})$  กับค่าขนาดแผ่นดินไหวที่ตรวจวัดได้จริง (Target) มีความสัมพันธ์ดังสมการ 5.1

$$\text{Target} = 167.59(\text{Log}(\text{Output}))^2 - 223.45(\text{Log}(\text{Output})) + 78.95 \quad \text{สมการ (5.1)}$$

โดยมีค่าสัมประสิทธิ์ของการตัดสินใจ (Coefficient of Determination,  $R^2$ ) เท่ากับ 0.0232 และมีค่าคลาดเคลื่อนกำลังสองเฉลี่ย (MSE) เท่ากับ 0.329585

นำผลการวิจัยมาทำการเปรียบเทียบค่า percentage error ซึ่งคำนวณได้จากสมการ 5.2

$$\text{Percentage Error} = \left( \frac{|\text{Output} - \text{Target}|}{|\text{Output}|} \right) \times 100 \quad \text{สมการ (5.2)}$$

เพื่อประเมินความแม่นยำของการคาดการณ์ค่าขนาดแผ่นดินไหวของโครงข่ายประสาทเทียม อ้างอิงจากงานวิจัยของ Arjun และ Kumar (2011) โดยหนดให้ ข้อมูลที่มีค่า percentage error น้อยกว่า 3% , 3%-5% และ 5%-10% เป็นข้อมูลที่มีความถูกต้อง (Accurate), มีความถูกต้องอย่างมีนัยสำคัญ (Substantially accurate) และ มีความถูกต้องในระดับปานกลาง (Moderately Accurate) ตามลำดับ และถือว่าข้อมูลที่มีค่า percentage error มากกว่า 10% ถือว่ามีความไม่ถูกต้อง (Incorrect) พบว่า ผลที่ได้จากการคาดการณ์ด้วยโครงข่ายประสาทเทียมจำนวน 316 ข้อมูล ดังแสดงในตาราง 5.1

**ตาราง 5.1** แสดงค่าความแม่นยำเป็นเปอร์เซ็นต์ของโครงข่ายประสาทเทียมในการคาดการณ์ค่าขนาดแผ่นดินไหว

Percentage Error	Efficiency	Percentage
Less than 3 %	Accurate	29.75
3-5%	Substantially accurate	14.56
5-10%	Moderately Accurate	31.65
More than 10%	Incorrect	24.05




## 5.2 สรุปผลการศึกษา

งานวิจัยนี้พบว่าโครงข่ายประสาทเทียมมีความสามารถในการศึกษาพฤติกรรมแผ่นดินไหวของประเทศนิวซีแลนด์ ซึ่งโครงข่ายประสาทเทียมสามารถเรียนรู้และหาความสัมพันธ์ของข้อมูลการเกิดแผ่นดินไหวได้ โดยใช้ค่าค่าเฉลี่ยความคลาดเคลื่อนในการประเมินประสิทธิภาพ พบว่ามีค่าค่าเฉลี่ยความคลาดเคลื่อนเท่ากับ 0.22651 และ 0.329585 ในขั้นตอนการเรียนรู้และขั้นตอนการทดสอบ ตามลำดับ งานวิจัยนี้พบว่า ประสิทธิภาพการเรียนรู้ของโครงข่ายขึ้นอยู่กับจำนวนและความหลากหลายของข้อมูลที่โครงข่ายได้รับในขั้นตอนการเรียนรู้ หากข้อมูลในขั้นตอนการเรียนรู้มีความไม่หลากหลาย จะทำให้ค่าที่ได้จากการคาดการณ์ของโครงข่ายมีค่าจำกัด นอกจากนี้ยังพบว่าจำนวนโหนดในชั้นซ่อนมีผลต่อการเรียนรู้ของโครงข่ายจำนวนโหนดที่มากขึ้นจะทำให้โครงข่ายมีการประมวลผลที่ดีขึ้น ซึ่งพบว่าจำนวนโหนดที่เหมาะสมต่อพฤติกรรมแผ่นดินไหวของประเทศนิวซีแลนด์มีค่าเท่ากับ 17 และพบว่าจำนวนชั้นซ่อนไม่ได้มีผลต่อความแม่นยำในการคาดการณ์ค่าของโครงข่าย

## 5.3 ข้อเสนอแนะ

1. ข้อมูลพฤติกรรมแผ่นดินไหวในประเทศนิวซีแลนด์โดยเฉพาะข้อมูลของขนาดแผ่นดินไหวมีความหลากหลายของข้อมูลน้อย ดังแสดงในรูปที่ 5.2 จะเห็นว่าข้อมูลขนาดของแผ่นดินไหวอยู่ในช่วง 4.0 – 5.0 มากถึง 85% ของข้อมูลทั้งหมด 5710 ข้อมูลในชุดการเรียนรู้ ทำให้ข้อมูลขนาดแผ่นดินไหวที่ได้จากการคาดการณ์ของโครงข่ายมีค่าจำกัดอยู่ในช่วง 4 -5 จึงมีผลให้เกิดความคลาดเคลื่อนสูงกับขนาดของแผ่นดินไหวที่สูงกว่า 5
2. เนื่องจากข้อมูลขนาดของแผ่นดินไหวในประเทศนิวซีแลนด์มีค่าอยู่ในช่วง 4.0 – 5.0 เป็นจำนวนมากดังที่กล่าวไปแล้วในข้อ 1. และในขั้นตอนการสร้างและฝึกสอนโครงข่ายไม่สามารถตัดข้อมูลนี้ทิ้งให้น้อยลงได้เนื่องจากข้อมูลนี้เป็นข้อมูลที่แสดงพฤติกรรมแผ่นดินไหวของประเทศนิวซีแลนด์จริง ดังนั้นอาจทำการพัฒนาโครงข่ายประสาทเทียมให้ดีขึ้นโดยการแบ่งโครงข่ายให้มีการเรียนรู้เจาะจงเหตุการณ์แผ่นดินไหวในแต่ละขนาดต่าง ๆ กัน เพื่อนำไปคาดการณ์ข้อมูลอื่น เช่น ช่วงเวลาในการเกิด หรือสถานที่เกิด เป็นต้น



รูปที่ 5.2 แสดงสัดส่วนของข้อมูลขนาดแผ่นดินไหวในชุดการเรียนรู้

## บรรณานุกรม

ชนาวุฒิ ประกอบผล. โครงข่ายประสาทเทียม. 2552. วารสาร มฉก. วิชาการ. 24 (มกราคม-มิถุนายน): 73-87.

อำภา สารระศิริ. เทคนิคการเรียนรู้พื้นฐานโครงข่ายประสาทเทียม. [ออนไลน์]. 2559. แหล่งที่มา: [http://www.eng.mut.ac.th/article\\_detail.php?id=118](http://www.eng.mut.ac.th/article_detail.php?id=118) [2 กุมภาพันธ์ 2560].

Abdulrahman, S.N.A., Nassir S.N. A., and Saad A. Earthquakes Magnitude Predication Using Artificial Neural Network in Northern Red Sea Area. Journal of King Saud University - Science 24.4 (2012): 301-313.

Bodri, B. A Neural-Network Model for Earthquake Occurrence. Journal of Geodynamics 32.3 (2001): 289-310.

Arjun, C.R. and Kumar, A. 2011. Neural network estimation of duration of strong ground motion using Japanese earthquake records. Department of Earthquake Engineering, IITRoorkee, India. Journal of Soil Dynamics and Earthquake Engineering 31(2011) 866-872.

Demuth, H. and Beale, M.H. Neural Network Toolbox For Use With Matlab. 6th ed. Natick: The Math Works, 2000.

Khasathan, K. 2016. Gredient Descent [Online]. Available from: <https://khasathan.in.th/archives/1335> [2017, Feb 2].

Reyes J., Morales-Esteban A., and Martínez-Álvarez F. Neural Networks to Predict Earthquakes In Chile. Applied Soft Computing 13.2 (2013): 1314-1328.

Xie J., Qiu JF., Li W., Wang JW. The Application of Neural Network Model in Earthquake Prediction in East China. In: Jin D., Lin S. (eds) Advances in Computer Science, Intelligent System and Environment. Advances in Intelligent and Soft Computing, vol 106. Springer, Berlin, Heidelberg.