

การประยุกต์การแปลงเวฟเล็ตแบบเต็มหน่วยและโครงข่ายประสาทเทียม  
สำหรับวินิจฉัยสถานะผิดปกติในหม้อแปลงไฟฟ้ากำลัง

APPLICATIONS OF DISCRETE WAVELET TRANSFORM AND  
NEURAL NETWORKS FOR FAULT DIAGNOSIS IN  
POWER TRANSFORMERS

อรรถพล เง่าพิทักษ์กุล  
ATTHAPOL NGAOPITAKKUL

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรบัณฑิต  
สาขาวิชาวิศวกรรมไฟฟ้า  
บัณฑิตวิทยาลัย  
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ. 2550

การประยุกต์การแปลงเวฟเล็ตแบบเต็มหน่วยและโครงข่ายประสาทเทียม  
สำหรับวินิจฉัยสถานะผิดปกติในหม้อแปลงไฟฟ้ากำลัง

**APPLICATIONS OF DISCRETE WAVELET TRANSFORM AND  
NEURAL NETWORKS FOR FAULT DIAGNOSIS IN  
POWER TRANSFORMERS**

อรรถพล เงามพิทักษ์กุล  
ATTHAPOL NGAOPITAKKUL

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรดุษฎีบัณฑิต  
สาขาวิชาวิศวกรรมไฟฟ้า  
บัณฑิตวิทยาลัย  
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง  
พ.ศ. 2550

**APPLICATIONS OF DISCRETE WAVELET TRANSFORM AND NEURAL  
NETWORKS FOR FAULT DIAGNOSIS IN POWER TRANSFORMERS**

**ATTHAPOL NGAOPITAKKUL**

**A THESIS SUBMITTED IN PARTIAL FULFILLMENT  
OF THE REQUIREMENT FOR THE DEGREE OF  
DOCTOR OF ENGINEERING IN ELECTRICAL ENGINEERING  
SCHOOL OF GRADUATE STUDIES  
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG**

**2007**

**COPYRIGHT 2007**

**SCHOOL OF GRADUATE STUDIES**

**KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG**

หัวข้อวิทยานิพนธ์	การประยุกต์การแปลงเวฟเล็ดแบบเต็มหน่วยและโครงข่ายประสาทเทียมสำหรับวินิจฉัยสถานะผิดปกติในหม้อแปลงไฟฟ้ากำลัง
นักศึกษา	นาย อรรถพล เก่าพิทักษ์กุล
รหัสประจำตัว	47060004
ปริญญา	วิศวกรรมศาสตรดุษฎีบัณฑิต
สาขาวิชา	วิศวกรรมไฟฟ้า
พ.ศ.	2550
อาจารย์ผู้ควบคุมวิทยานิพนธ์	รศ. ดร. อานันท์วัฒน์ คุณากร

### บทคัดย่อ

หม้อแปลงไฟฟ้ากำลังเป็นหนึ่งในการเชื่อมโยงที่สำคัญในระบบไฟฟ้า อย่างไรก็ตาม ส่วนใหญ่หม้อแปลงไฟฟ้ากำลังได้รับความเสียหายจากฟอลต์ขดลวดภายในเนื่องจากวัสดุที่ใช้เป็นฉนวนลึมหวด ดังนั้น จึงต้องมีระบบป้องกันหม้อแปลงไฟฟ้ากำลังที่ดีพอสามารถตรวจจับความผิดปกติ (fault) ที่เกิดขึ้นกับหม้อแปลงไฟฟ้ากำลังขณะใช้งาน วิทยานิพนธ์นี้ได้นำเสนอรูปแบบการประยุกต์ใช้การแปลงเวฟเล็ดแบบเต็มหน่วย (DWT) และโครงข่ายประสาทเทียม (ANNs) สำหรับวินิจฉัยฟอลต์ที่เกิดขึ้นภายในหม้อแปลงไฟฟ้ากำลังสามเฟส แบบ 2 ขดลวด ฟอลต์ภายในที่ขดลวดหม้อแปลงไฟฟ้ากำลังถูกตรวจจับและแบ่งประเภท รวมถึงการระบุตำแหน่งของฟอลต์ที่ขดลวดหม้อแปลงไฟฟ้ากำลัง หม้อแปลงไฟฟ้ากำลังเชื่อมโยงกับระบบสายส่งถูกจำลองสถานะฟอลต์โดยใช้โปรแกรม EMTP แบบจำลองความถี่สูงของหม้อแปลงถูกรวมเข้าไว้ในการจำลองและใช้การแปลงเวฟเล็ดแบบเต็มหน่วยเพื่อดึงองค์ประกอบความถี่สูงของสัญญาณกระแสฟอลต์ อัลกอริทึมการตัดสินใจได้ถูกพัฒนาขึ้น โดยอาศัยโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับและการฝึกสอนโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับได้ถูกสร้างโดยใช้โปรแกรม MATLAB/Simulink สัมประสิทธิ์องค์ประกอบความถี่สูงในสเกลแรกของสัญญาณกระแสผลต่างที่จับได้จากหม้อแปลงไฟฟ้าได้ถูกนำมาเป็นข้อมูลอินพุต เพื่อใช้ในการหาค่าตำแหน่งและแบ่งประเภทของฟอลต์ที่เกิดขึ้น กรณีศึกษาจำนวน 864 ตัวอย่างได้นำมาทดสอบเพื่อตรวจสอบอัลกอริทึมที่ได้นำเสนอ จากผลสรุปที่ได้แสดงให้เห็นว่า วิธีการแปลงเวฟเล็ดแบบเต็มหน่วยและโครงข่ายประสาทเทียมที่ได้นำเสนอในวิทยานิพนธ์นี้ให้ผลลัพธ์เป็นที่น่าพอใจ และมีประโยชน์ในการพัฒนาการป้องกันแบบผลต่างแนวใหม่สำหรับหม้อแปลงไฟฟ้ากำลัง

**Thesis Title** Applications of Discrete Wavelet Transform and Neural Networks for Fault Diagnosis in Power Transformers

**Student** Mr. Atthapol Ngaopitakkul

**Student ID.** 47060004

**Degree** Doctor of Engineering

**Program** Electrical Engineering

**Year** 2007

**Thesis Advisor** Assoc. Prof. Dr. Anantawat Kunakorn

### **ABSTRACT**

Power transformer is one of the most important links in a power system. However, they do suffer from internal winding fault due to insulation failure thus it is necessary precise protection scheme to detecting transformer fault. This thesis presents applications of the Discrete Wavelet Transform (DWT) and Artificial Neural Networks (ANNs) in fault diagnosis of three-phase two winding power transformers. The internal faults at windings of the transformers are detected and classified. In addition, the locations of the faults along the windings are identified. The power transformer connected to a transmission line system is simulated fault conditions by using EMTP program. The high frequency modelling of the transformer is incorporated into the simulation. The simulation also involves the modelling of the fault between any turn and the earth and between any two turns of the transformer windings. Discrete Wavelet Transform is employed in order to extract high frequency components of the fault current signals. The decision algorithms are developed based on the back propagation neural networks with training processed being constructed using MATLAB/Simulink. Coefficients detail obtained using DWT in first scale that captured differential current signals of the transformer are used as an input pattern for ANNs. The results obtained from ANNs are used to locate faults, and identify faults. The total number of the case studies are 864, are performed to verify the validity of the algorithm. Results show that that the technique, proposed in the thesis, gives satisfactory results, and will be useful in the development of a new differential protection scheme for power transformers.

## กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้ สำเร็จลุล่วงได้อย่างด้วยดี ด้วยคำแนะนำและคำปรึกษาจากที่มีคุณค่า จาก รศ.ดร. อานันทวัฒน์ คุณากร ซึ่งเป็นอาจารย์ผู้ควบคุมวิทยานิพนธ์ ผู้วิจัยรู้สึกซาบซึ้งในความอนุเคราะห์จากท่านและขอกราบขอบพระคุณเป็นอย่างสูง

ขอขอบพระคุณ รศ. ศุภี บรรจงจิตร, รศ. มณฑล ลีลาจินดาไกรฤกษ์ รวมถึงอาจารย์ในภาควิชาวิศวกรรมไฟฟ้าทุกท่านที่กรุณาให้คำปรึกษาและให้ความอนุเคราะห์แนะนำแนวทางในการทำวิทยานิพนธ์ จนผู้วิจัยรู้สึกซาบซึ้งในความเมตตา ความมีน้ำใจของท่าน

วิทยานิพนธ์ฉบับนี้จะไม่สำเร็จได้ ถ้าขาดบุคคลต่างๆ เหล่านี้ คุณพุทธิขจร บุญมี, คุณสาโรจน์ รัตนสุภา จากการผลิตไฟฟ้าฝ่ายผลิตแห่งประเทศไทยที่ได้เอื้อเฟื้อสำหรับข้อมูลระบบสายส่งและหม้อแปลงไฟฟ้ากำลัง, คุณสิทธิโชค กิตติรักษ์ตระกูล, คุณชายชาญ โพธิสาร และคุณธีรศักดิ์ พัฒนเจริญ สำหรับความช่วยเหลือในการทำทความและรูปเล่มวิทยานิพนธ์ ผู้วิจัยขอขอบพระคุณในความมีน้ำใจและความช่วยเหลือต่างๆ ตลอด 3 ปีที่ผ่านมา

ขอขอบคุณสถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง ที่ได้ให้ทุนสนับสนุนการทำวิทยานิพนธ์ครั้งนี้

สุดท้ายขอกราบเท้า คุณพ่อ วนิชย์ เ่งพิทักษ์กุล และคุณแม่ ทองสุข ปิ่นตะ ผู้เป็นพรหมของลูกที่ให้กำเนิดชีวิต มอบ อดีต ปัจจุบัน และอนาคตให้กับผู้วิจัย ตลอดชีวิตที่ผ่านมาท่านทั้งสองอบรม สั่งสอนและให้กำลังใจในการต่อสู้กับชีวิต รวมถึงทุกคนในครอบครัวสำหรับความช่วยเหลือและกำลังใจที่มีให้กับผู้วิจัยตลอดมา

คุณค่าและประโยชน์อันพึงมีจากวิทยานิพนธ์ฉบับนี้ ผู้วิจัยขอบแต่ผู้มีพระคุณทุกท่าน

อรรถพล เ่งพิทักษ์กุล

# สารบัญ

	หน้า
บทคัดย่อภาษาไทย .....	I
บทคัดย่อภาษาอังกฤษ .....	II
กิตติกรรมประกาศ .....	III
สารบัญ .....	IV
สารบัญตาราง .....	XI
สารบัญรูป .....	XIII
บทที่ 1 บทนำ .....	1
1.1 การพัฒนาเทคโนโลยีของการวิเคราะห์สัญญาณในระบบป้องกัน หม้อแปลงไฟฟ้ากำลัง .....	2
1.2 ความมุ่งหมายและวัตถุประสงค์ของการศึกษา .....	5
1.3 สมมุติฐานของการศึกษา .....	6
1.4 ขอบเขตของการศึกษา .....	6
1.5 ขั้นตอนของการศึกษา .....	7
1.6 ข้อตกลงเบื้องต้นของการศึกษา .....	8
1.7 ประโยชน์ที่คาดว่าจะได้รับ .....	9
บทที่ 2 ระบบป้องกันหม้อแปลงไฟฟ้ากำลัง .....	10
2.1 รีเลย์ป้องกัน (Protective Relay) .....	10
2.2 การตรวจจับฟอลต์เชิงกล (Mechanical Faults Detection) .....	11
2.2.1 บุคโฮลรีเลย์ (Buchholz Relay) .....	12
2.2.2 รีเลย์เปลี่ยนแปลงความดันทันที (Sudden Pressure Relay) .....	14
2.2.3 รีเลย์ความร้อน (Thermal Relay) .....	16
2.3 การตรวจจับฟอลต์เชิงไฟฟ้า (Electrical Faults Detection) .....	16
2.3.1 การป้องกันแบบภาระเกิน (Overload protection) .....	16
2.3.2 การป้องกันแบบกระแสเกิน (Over current protection) .....	16
2.3.3 การป้องกันแบบกระแสดิน (Ground or Earth Fault protection) .....	17
2.3.4 การป้องกันแบบผลต่าง (Differential protection) .....	18

# สารบัญ (ต่อ)

	หน้า
บทที่ 3 การแปลงเวฟเล็ท .....	21
3.1 ประวัติของเวฟเล็ท (History of Wavelets) .....	21
3.2 ทฤษฎีพื้นฐานของการแปลงเวฟเล็ท .....	22
3.2.1 การแปลงฟูเรียร์ (Fourier transform :FT) .....	22
3.2.2 การแปลงกาบอร์ (Gabor Transform :GT) .....	24
3.2.3 การแปลงฟูเรียร์ช่วงเวลาสั้น(Short –Time Fourier Transform :STFT) ...	24
3.3 การแปลงเวฟเล็ท (Wavelet Transform : WT) .....	26
3.3.1 ทฤษฎีเวฟเล็ท (Wavelet Theory) .....	26
3.3.2 การสเกล (Scaling) .....	28
3.3.3 การเลื่อนตำแหน่ง (Translation or shifting) .....	29
3.3.4 การกระจายและรวมกลับของเวฟเล็ท (Decomposition and reconstruction of Wavelet).....	30
3.4 การแปลงเวฟเล็ทแบบต่อเนื่อง (Continuous Wavelet Transform :CWT) .....	31
3.5 การแปลงเวฟเล็ทแบบเต็มหน่วย (Discrete Wavelet Transform :DWT) .....	34
3.5.1 การวิเคราะห์สัญญาณแบบหลายระดับความละเอียด (Multi-Resolution Analysis : MRA).....	34
3.5.1.1 ทฤษฎีของสเปซเวกเตอร์ (Space vector theory) .....	34
3.5.2 การวิเคราะห์ด้วยตัวกรองสัญญาณ (Filter Bank Analysis) .....	40
3.6 เวฟเล็ทแม่ (Mother wavelet) .....	43
3.6.1 Haar Wavelet .....	43
3.6.2 Mexican Hat Wavelet .....	43
3.6.3 Daubechies Wavelet .....	44
3.6.4 Symlets Wavelet .....	45
3.6.5 Coiflets Wavelet .....	45
3.6.6 Morlet Wavelet .....	46
3.6.7 Meyer Wavelet .....	46
3.6.8 Biorthogonal Wavelet .....	47

## สารบัญ (ต่อ)

	หน้า
บทที่ 4 โครงข่ายประสาทเทียม .....	51
4.1 ความเป็นมาของโครงข่ายประสาท .....	51
4.2 โครงข่ายประสาทเทียม .....	53
4.2.1 คุณสมบัติและความสามารถของโครงข่ายประสาทเทียม .....	54
4.2.2 ลักษณะของปัญหาที่เหมาะสมกับโครงข่ายประสาทเทียม .....	54
4.3 โครงสร้างของโครงข่ายประสาทเทียม (Architectures of Neural Networks) .....	55
4.3.1 โครงข่ายประสาทเทียมแบบชั้นเดียว (Single Layer Neural Network) ..	56
4.3.2 โครงข่ายประสาทเทียมแบบหลายชั้น (Multi Layer Neural Network) ..	56
4.3.3 โครงข่ายประสาทเทียมแบบแลตทิซ (Lattice Neural Network) .....	57
4.4 การกำหนดค่าถ่วงน้ำหนัก (Setting the Weights) .....	58
4.4.1 การเรียนรู้แบบควบคุม (Supervised Learning) .....	60
4.4.2 การเรียนรู้แบบอิสระ (Unsupervised Learning) .....	60
4.4.3 การเรียนรู้แบบกำหนดค่าถ่วงน้ำหนัก (Fixed-weight nets) .....	61
4.4.4 กฎการเรียนรู้ (Learning laws) .....	62
4.5 ฟังก์ชันกระตุ้น (Activation function) .....	64
4.6 โครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (Back-propagation NN) .....	68
4.6.1 โครงสร้าง .....	69
4.6.2 แนวคิด .....	70
4.6.3 กฎการเรียนรู้ .....	74
4.6.4 การจัดระเบียบข้อมูล (Normalization) ชุดข้อมูลฝึกสอน.....	76
4.6.5 การไม่จัดระเบียบข้อมูล (Unnormalization) ชุดข้อมูลฝึกสอน.....	77
4.6.6 การเลือกโครงสร้างที่เหมาะสมของโครงข่ายประสาทเทียม.....	79
บทที่ 5 การจำลองพลต์ภายในขดลวดหม้อแปลง .....	81
5.1 แบบจำลองหม้อแปลงไฟฟ้ากำลังในการจำลองสัญญาณพลต์ .....	81
5.1.1 แบบจำลอง BCTRAN ในสภาวะปกติ .....	81
5.1.2 แบบจำลอง BCTRAN ในสภาวะพลต์ภายในขดลวดหม้อแปลง .....	85
5.2 ระบบจำลองพลต์ .....	92

## สารบัญ (ต่อ)

	หน้า
5.2.1 แบบจำลองในการจำลองสัญญาณฟอลต์ .....	92
5.2.2 ผลการทดสอบของหม้อแปลงไฟฟ้ากำลัง .....	93
5.2.3 การปรับเปลี่ยนค่าพารามิเตอร์ .....	93
<b>บทที่ 6 การวิเคราะห์ฟอลต์ภายในหม้อแปลงไฟฟ้ากำลัง .....</b>	<b>100</b>
6.1 การวิเคราะห์ด้วยการแปลงเวฟเล็ต .....	100
6.1.1 พฤติกรรมการเปลี่ยนแปลงของฟอลต์ชนิดลวดลัดวงจรลงดิน .....	103
6.1.2 พฤติกรรมการเปลี่ยนแปลงของฟอลต์ชนิดลวดลัดวงจรระหว่างรอบ .....	106
6.1.3 การตรวจจับฟอลต์ (Fault detection) .....	109
6.1.4 ตัวอย่างการตรวจจับฟอลต์ .....	115
6.2 การวิเคราะห์ด้วยโครงข่ายประสาทเทียม .....	119
6.2.1 การระบุตำแหน่งจุดลวดที่เกิดการลัดวงจร (Fault location) .....	120
6.2.1.1 การระบุตำแหน่งกรณีจุดลวดที่เกิดการลัดวงจรลงดิน .....	121
6.2.1.2 การระบุตำแหน่งกรณีจุดลวดที่เกิดการลัดวงจรระหว่างรอบ .....	124
6.2.2 การระบุประเภทฟอลต์ (Fault Identification) .....	126
6.3 แผนภาพสรุปการประยุกต์ใช้งานการแปลงเวฟเล็ตแบบเต็มหน่วย ร่วมกับโครงข่ายประสาทเทียม .....	128
<b>บทที่ 7 กรณีศึกษาและผลการจำลอง .....</b>	<b>134</b>
7.1 รูปแบบการนำเสนอ .....	134
7.1.1 ประเภทของฟอลต์ .....	134
7.1.2 รูปแสดงการนำเสนอในแต่ละหัวข้อ .....	134
7.1.3 รูปแสดงการสรุปผลลัพธ์ที่ได้ในแต่ละหัวข้อ .....	135
7.2 ผลลัพธ์กรณีฟอลต์ชนิดลวดลัดวงจรลงดิน .....	135
7.2.1 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีจุดลวดที่เกิดการ ลัดวงจรลงดินที่ตำแหน่ง 10 % ของความยาวขดลวดภายในหม้อแปลง ไฟฟ้ากำลัง .....	135

## สารบัญ (ต่อ)

หน้า

7.2.2 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขลวดที่เกิดการ ลัดวงจรลงดินที่ตำแหน่ง 20 % ของความยาวขลวดภายในหม้อแปลง ไฟฟ้ากำลัง .....	139
7.2.3 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขลวดที่เกิดการ ลัดวงจรลงดินที่ตำแหน่ง 30 % ของความยาวขลวดภายในหม้อแปลง ไฟฟ้ากำลัง .....	142
7.2.4 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขลวดที่เกิดการ ลัดวงจรลงดินที่ตำแหน่ง 40 % ของความยาวขลวดภายในหม้อแปลง ไฟฟ้ากำลัง .....	145
7.2.5 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขลวดที่เกิดการ ลัดวงจรลงดินที่ตำแหน่ง 50 % ของความยาวขลวดภายในหม้อแปลง ไฟฟ้ากำลัง .....	148
7.2.6 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขลวดที่เกิดการ ลัดวงจรลงดินที่ตำแหน่ง 60 % ของความยาวขลวดภายในหม้อแปลง ไฟฟ้ากำลัง .....	151
7.2.7 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขลวดที่เกิดการ ลัดวงจรลงดินที่ตำแหน่ง 70 % ของความยาวขลวดภายในหม้อแปลง ไฟฟ้ากำลัง .....	154
7.2.8 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขลวดที่เกิดการ ลัดวงจรลงดินที่ตำแหน่ง 80 % ของความยาวขลวดภายในหม้อแปลง ไฟฟ้ากำลัง .....	157
7.2.9 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขลวดที่เกิดการ ลัดวงจรลงดินที่ตำแหน่ง 90 % ของความยาวขลวดภายในหม้อแปลง ไฟฟ้ากำลัง .....	160
7.3 ผลลัพธ์กรณีฟอลต์ขลวดลัดวงจรระหว่างรอบ .....	163
7.3.1 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขลวดที่เกิดการ ลัดวงจรระหว่างรอบที่ตำแหน่งขลวดย่อย a 10 % ของความยาว ขลวดภายในหม้อแปลงไฟฟ้ากำลัง .....	163

## สารบัญ (ต่อ)

หน้า

7.3.2 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขลวดที่เกิดการ ลัดวงจรระหว่างรอบที่ตำแหน่งขลวดย่อย a 20 % ของความยาว ขลวดภายในหม้อแปลงไฟฟ้ากำลัง .....	171
7.3.3 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขลวดที่เกิดการ ลัดวงจรระหว่างรอบที่ตำแหน่งขลวดย่อย a 30 % ของความยาว ขลวดภายในหม้อแปลงไฟฟ้ากำลัง .....	178
7.3.4 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขลวดที่เกิดการ ลัดวงจรระหว่างรอบที่ตำแหน่งขลวดย่อย a 40 % ของความยาว ขลวดภายในหม้อแปลงไฟฟ้ากำลัง .....	184
7.3.5 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขลวดที่เกิดการ ลัดวงจรระหว่างรอบที่ตำแหน่งขลวดย่อย a 50 % ของความยาว ขลวดภายในหม้อแปลงไฟฟ้ากำลัง .....	190
7.3.6 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขลวดที่เกิดการ ลัดวงจรระหว่างรอบที่ตำแหน่งขลวดย่อย a 60 % ของความยาว ขลวดภายในหม้อแปลงไฟฟ้ากำลัง .....	196
7.3.7 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขลวดที่เกิดการ ลัดวงจรระหว่างรอบที่ตำแหน่งขลวดย่อย a 70 % ของความยาว ขลวดภายในหม้อแปลงไฟฟ้ากำลัง .....	201
7.3.8 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขลวดที่เกิดการ ลัดวงจรระหว่างรอบที่ตำแหน่งขลวดย่อย a 80 % ของความยาว ขลวดภายในหม้อแปลงไฟฟ้ากำลัง .....	205
7.4 สรุปและวิเคราะห์ผลลัพธ์ที่ได้จากกรณีศึกษา .....	209
บทที่ 8 บทสรุปและข้อเสนอแนะ .....	221
เอกสารอ้างอิง .....	226

## สารบัญ (ต่อ)

	หน้า
ภาคผนวก ก .....	230
ภาคผนวก ข .....	254
ภาคผนวก ค .....	262
ภาคผนวก ง .....	269
ประวัติผู้เขียน .....	298

# สารบัญตาราง

ตารางที่	หน้า
3.1 สัมประสิทธิ์ของตัวกรองสัญญาณของเวฟเล็ตตระกูล Daubechies ที่ $N$ มีค่าเป็น 4, 6, 8, 10, 12, 14, 16 และ 20 .....	48
3.2 คุณสมบัติของเวฟเล็ตแต่ละชนิด .....	49
4.1 การวิจัยโครงข่ายประสาทเทียมที่สำคัญในยุคต่างๆ .....	52
4.2 การประยุกต์ใช้โครงข่ายประสาทในปัจจุบัน .....	53
4.3 ชนิดฟังก์ชันกระตุ้น .....	66-67
6.1 การเปลี่ยนแปลงของสัมประสิทธิ์ในสเกลที่ 1 ณ ตำแหน่งขดลวดฟอลต์ต่างๆ .....	104
6.2 การเปลี่ยนแปลงของสัมประสิทธิ์ในสเกลที่ 1 ณ มุมเริ่มเกิดฟอลต์ขดลวด ลัดวงจรลงดินที่มุมต่างๆ .....	105
6.3 การเปลี่ยนแปลงของสัมประสิทธิ์ในสเกลที่ 1 ณ ตำแหน่งฟอลต์ขดลวดย่อย $b$ ต่างๆ .....	107
6.4 การเปลี่ยนแปลงของสัมประสิทธิ์ในสเกลที่ 1 ณ ตำแหน่งฟอลต์ขดลวดย่อย $a$ ต่างๆ .....	108
6.5 การเปลี่ยนแปลงของสัมประสิทธิ์ในสเกลที่ 1 ณ มุมเริ่มเกิดฟอลต์ขดลวด ลัดวงจรระหว่างรอบที่มุมต่างๆ .....	109
6.6 ค่าตรวจสอบการเปลี่ยนแปลงเมื่อพิจารณาสัญญาณตามรูปที่ 6.13 .....	117
6.7 ค่าตรวจสอบการเปลี่ยนแปลงเมื่อพิจารณาสัญญาณตามรูปที่ 6.14 .....	117
6.8 ค่าตรวจสอบการเปลี่ยนแปลงเมื่อพิจารณาสัญญาณตามรูปที่ 6.15 .....	118
6.9 ผลสรุปการวิเคราะห์การตรวจจับฟอลต์เมื่อพิจารณาสัญญาณตามรูปที่ 6.13 .....	118
6.10 ผลสรุปการวิเคราะห์การตรวจจับฟอลต์เมื่อพิจารณาสัญญาณตามรูปที่ 6.14 .....	118
6.11 ผลสรุปการวิเคราะห์การตรวจจับฟอลต์เมื่อพิจารณาสัญญาณตามรูปที่ 6.15 .....	119
6.12 ผลสรุปจากการฝึกสอนเพื่อระบุตำแหน่งขดลวดที่เกิดการลัดวงจร ลงดินทางด้านแรงดันสูง .....	123
6.13 ผลสรุปจากการฝึกสอนเพื่อระบุตำแหน่งขดลวดที่เกิดการลัดวงจร ลงดินทางด้านแรงดันต่ำ .....	123
6.14 ผลสรุปจากการฝึกสอนเพื่อระบุตำแหน่งขดลวดที่เกิดการลัดวงจร ระหว่างรอบทางด้านแรงดันสูง .....	125
6.15 ผลสรุปจากการฝึกสอนเพื่อระบุตำแหน่งขดลวดที่เกิดการลัดวงจร ระหว่างรอบทางด้านแรงดันต่ำ .....	125
6.16 ค่าเอาต์พุตของโครงข่ายประสาทเทียมสำหรับระบุประเภทฟอลต์ .....	127

## สารบัญตาราง (ต่อ)

ตารางที่	หน้า
6.17 ผลสรุปจากการฝึกสอนเพื่อระบุประเภทฟอลต์ .....	128
8.1 จำนวนข้อมูลสำหรับฝึกสอนโครงข่ายประสาทเทียม .....	222
ข1 ค่าเอาต์พุตของโครงข่ายประสาทเทียมชนิดความน่าจะเป็นสำหรับระบุประเภทฟอลต์ .....	255
ข2 ผลสรุปการฝึกสอนโครงข่ายประสาทเทียมชนิดความน่าจะเป็น สำหรับระบุประเภทฟอลต์ .....	257
ข3 ผลสรุปการฝึกสอนโครงข่ายประสาทเทียมชนิดฟังก์ชันฐานรัศมี สำหรับระบุประเภทฟอลต์ .....	260
ข4 การเปรียบเทียบระหว่างโครงข่ายประสาทเทียมสองชนิดสำหรับระบุประเภทฟอลต์ .....	260
ค1 ผลสรุปการฝึกสอนในการปรับเปลี่ยนโครงสร้างโครงข่ายประสาทเทียมสำหรับ ระบุตำแหน่งกรณีขดลวดลัดวงจรลงดิน .....	263
ค2 ฟังก์ชันกระตุ้นในชั้นซ่อนและชั้นเอาต์พุตเพื่อฝึกสอนโครงข่ายประสาทเทียม .....	264
ค3 ผลสรุปการฝึกสอนในการปรับเปลี่ยนฟังก์ชันกระตุ้นในชั้นซ่อนและชั้นเอาต์พุต เพื่อฝึกสอนโครงข่ายประสาทเทียม .....	265
ค4 ผลสรุปจากการทดสอบจากข้อมูล 108 ชุดในการปรับเปลี่ยนฟังก์ชันกระตุ้น .....	267
ค5 แสดงผลสรุปการฝึกสอนในการปรับเปลี่ยนจำนวนการสุ่มค่าเริ่มต้นของ ค่าถ่วงน้ำหนักและค่าไบอัสสำหรับระบุตำแหน่งกรณีขดลวดลัดวงจรลงดิน .....	268
ค6 ผลสรุปจากการทดสอบจากข้อมูล 108 ชุดในการปรับเปลี่ยนจำนวนครั้งที่สุ่มค่าเริ่มต้น .....	268

# สารบัญรูป

รูปที่	หน้า
1.1 การพัฒนาเทคโนโลยีของอุปกรณ์ป้องกันที่ใช้ในระบบไฟฟ้ากำลัง .....	3
1.2 แผนภาพขั้นตอนการศึกษาของวิทยานิพนธ์ .....	8
2.1 การป้องกันหม้อแปลงไฟฟ้ากำลัง .....	11
2.2 ตำแหน่งและลักษณะของการวางบุลโฮลรีเลย์ (Buchholz Relay) ของหม้อแปลง .....	12
2.3 โครงสร้างภายในบุลโฮลรีเลย์ (Buchholz Relay) ของหม้อแปลง .....	13
2.4 ตำแหน่งและลักษณะของการวางรีเลย์เปลี่ยนแปลงความดันทันทีของหม้อแปลง .....	14
2.5 โครงสร้างภายในของรีเลย์เปลี่ยนแปลงความดันทันที (Sudden Pressure Relay) .....	15
2.6 รีเลย์ป้องกันกระแสดิน .....	17
2.7 วงจรของรีเลย์ป้องกันหม้อแปลงที่ใช้หลักการของเปอร์เซ็นต์กระแสผลต่าง .....	18
2.8 เส้นคุณลักษณะของรีเลย์ที่ใช้หลักการเปอร์เซ็นต์กระแสผลต่าง .....	19
3.1 การแปลงฟูเรียร์ (FFT) .....	23
3.2 การแปลงฟูเรียร์ช่วงเวลาสั้น (STFT) .....	25
3.3 ลักษณะของระนาบเวลาและความถี่สำหรับการวิเคราะห์สัญญาณ .....	26
3.4 ลักษณะของคลื่นเวฟเล็ดแบบ Morlet .....	27
3.5 คุณสมบัติการสเกลของสัญญาณชายน์ .....	28
3.6 คุณสมบัติการสเกลของฟังก์ชันเวฟเล็ด .....	29
3.7 คุณสมบัติการเลื่อนตำแหน่งของฟังก์ชันเวฟเล็ด .....	29
3.8 การกระจายสัญญาณด้วยการแปลงเวฟเล็ด .....	30
3.9 การสร้างกลับสัญญาณด้วยการแปลงเวฟเล็ด .....	30
3.10 ขั้นตอนที่ 1 และ 2 ของการแปลงเวฟเล็ด .....	32
3.11 ขั้นตอนที่ 3 ของการแปลงเวฟเล็ด .....	32
3.12 ขั้นตอนที่ 4 ของการแปลงเวฟเล็ด .....	32
3.13 การแปลงเวฟเล็ดแบบต่อเนื่อง (CWT) .....	33
3.14 การเปรียบเทียบลักษณะการกระจาย (decomposition) .....	37
3.15 การแปลงแยกสัญญาณด้วยฟิลเตอร์แบบสองช่องสัญญาณ .....	40
3.16 แปลงกลับสัญญาณด้วยฟิลเตอร์แบบสองช่องสัญญาณ .....	41
3.17 ลักษณะการแปลงเวฟเล็ดโดยใช้หลักการของวิเคราะห์แบบออกเทพฟิลเตอร์แบงค์ .....	41
3.18 การแปลงเวฟเล็ดแบบเต็มหน่วย (DWT) ในสเกลที่ 1-4 .....	42

## สารบัญรูป (ต่อ)

รูปที่	หน้า
3.19 ลักษณะของ Haar Wavelet .....	43
3.20 ลักษณะของ Mexican Hat Wavelet .....	44
3.21 ลักษณะของ Daubechies Wavelet .....	44
3.22 ลักษณะของ Symlets Wavelet .....	45
3.23 ลักษณะของ Coiflets Wavelet .....	45
3.24 ลักษณะของ Morlet Wavelet .....	46
3.25 ลักษณะของ Meyer Wavelet .....	46
3.26 ลักษณะของ Biorthogonal Wavelet .....	47
4.1 โครงสร้างพื้นฐานของโครงข่ายประสาทเทียม .....	54
4.2 โครงสร้างของโครงข่ายประสาทเทียมแบบชั้นเดียว .....	56
4.3 โครงสร้างของโครงข่ายประสาทเทียมแบบหลายชั้น .....	57
4.4 โครงสร้างของโครงข่ายประสาทเทียมแบบแลตทิซ .....	58
4.5 การเปรียบเทียบค่าความผิดพลาดของชุดฝึกสอน ( $e_{train}$ ) กับชุดตรวจสอบ ( $e_{val}$ ) .....	69
4.6 แบบจำลองของโครงข่ายประสาทเทียมที่มี 2 ชั้นซ่อน .....	69
5.1 หม้อแปลงสามเฟส 2 ขดลวด (6 ขดลวด) .....	82
5.2 ขดลวดของหม้อแปลงขณะเกิดการลัดวงจร .....	86
5.3 แบบจำลองหม้อแปลงเฟสเดียวเมื่อต่อตัวเก็บประจุ .....	92
5.4 ระบบจำลองฟอลต์ภายในหม้อแปลงขนาด 50 MVA .....	92
5.5 วงจรในการจำลองฟอลต์ขดลวดลัดวงจรลงดินชนิดเฟส A ลงดิน ที่ 10% ของความยาวขดลวดหม้อแปลง .....	94
5.6 สัญญาณฟอลต์ของแรงดันที่ได้จากการจำลองที่ปลายด้านแรงดันสูง .....	95
5.7 สัญญาณฟอลต์ของกระแสที่ได้จากการจำลองที่ปลายด้านแรงดันสูง .....	95
5.8 สัญญาณฟอลต์ของแรงดันที่ได้จากการจำลองที่ปลายด้านแรงดันต่ำ .....	96
5.9 สัญญาณฟอลต์ของกระแสที่ได้จากการจำลองที่ปลายด้านแรงดันต่ำ .....	96
5.10 วงจรในการจำลองฟอลต์ขดลวดลัดวงจรระหว่างรอบชนิดเฟส A ลงดิน ที่ 10% กับ 20% ของความยาวขดลวดหม้อแปลง .....	97

## สารบัญรูป (ต่อ)

รูปที่	หน้า
5.11 สัญญาณฟลัดต์ของแรงดันที่ได้จากการจำลองที่ปลายด้านแรงดันสูง .....	97
5.12 สัญญาณฟลัดต์ของกระแสที่ได้จากการจำลองที่ปลายด้านแรงดันสูง .....	98
5.13 สัญญาณฟลัดต์ของแรงดันที่ได้จากการจำลองที่ปลายด้านแรงดันต่ำ .....	98
5.14 สัญญาณฟลัดต์ของกระแสที่ได้จากการจำลองที่ปลายด้านแรงดันต่ำ .....	99
6.1 ผลการแปลงเวฟเฟิร์มในแต่ละเฟสของกระแสผลต่างกรณีฟลัดต์ขดลวดลัดวงจรลงดิน .....	101
6.2 ผลการแปลงเวฟเฟิร์มในแต่ละเฟสของกระแสผลต่างกรณีฟลัดต์ ขดลวดลัดวงจรระหว่างรอบ .....	101
6.3 ค่าสัมประสิทธิ์กำลังสองในแต่ละเฟสของกระแสผลต่างกรณีฟลัดต์ ขดลวดลัดวงจรลงดิน .....	102
6.4 ค่าสัมประสิทธิ์กำลังสองในแต่ละเฟสของกระแสผลต่างกรณีฟลัดต์ ขดลวดลัดวงจรระหว่างรอบ .....	103
6.5 การเปลี่ยนแปลงค่าสัมประสิทธิ์กำลังสองในแต่ละเฟสของกระแสผลต่าง .....	103
6.6 ลักษณะการเปลี่ยนแปลงสัมประสิทธิ์องค์ประกอบความถี่สูงในสเกลที่ 1 ของกระแสผลต่าง เฟสที่เกิดฟลัดต์ (Phase A) เมื่อเกิดฟลัดต์ที่ตำแหน่งต่างๆ ในขดลวดของหม้อแปลง .....	104
6.7 ลักษณะการเปลี่ยนแปลงสัมประสิทธิ์องค์ประกอบความถี่สูงในสเกลที่ 1 ของกระแสผลต่าง เฟสที่เกิดฟลัดต์ (Phase A) เมื่อมุมเริ่มเกิดฟลัดต์เปลี่ยนแปลง .....	105
6.8 การเปลี่ยนแปลงค่าสัมประสิทธิ์กำลังสองในแต่ละเฟสของกระแสผลต่าง .....	106
6.9 ลักษณะการเปลี่ยนแปลงสัมประสิทธิ์องค์ประกอบความถี่สูงในสเกลที่ 1 ของกระแสผลต่างเฟสที่เกิดฟลัดต์ (Phase A) เมื่อเกิดฟลัดต์ที่ตำแหน่งต่างๆ ในขดลวดย่อย b ของหม้อแปลง .....	107
6.10 ลักษณะการเปลี่ยนแปลงสัมประสิทธิ์องค์ประกอบความถี่สูงในสเกลที่ 1 ของกระแสผลต่างเฟสที่เกิดฟลัดต์ (Phase A) เมื่อเกิดฟลัดต์ที่ตำแหน่งต่างๆ ในขดลวดย่อย a ของหม้อแปลง .....	108
6.11 ลักษณะการเปลี่ยนแปลงสัมประสิทธิ์องค์ประกอบความถี่สูงในสเกลที่ 1 ของกระแสผลต่าง เฟสที่เกิดฟลัดต์ (Phase A) เมื่อมุมเริ่มเกิดฟลัดต์เปลี่ยนแปลง .....	109
6.12 การแปลงเวฟเฟิร์มของสัญญาณกระแสผลต่างในสภาวะปกติ .....	115
6.13 การแปลงเวฟเฟิร์มของสัญญาณกระแสผลต่างในสภาวะฟลัดต์ภายนอกโซน .....	115

## สารบัญรูป (ต่อ)

รูปที่	หน้า
6.14 การแปลงเวฟเล็ทของสัญญาณกระแสผลต่างในสภาวะ พอลต์ภายใน โชนกรณีพอลต์ขดลวดลัดวงจรลงดิน .....	116
6.15 การแปลงเวฟเล็ทของสัญญาณกระแสผลต่างในสภาวะ พอลต์ภายใน โชนกรณีพอลต์ขดลวดลัดวงจรระหว่างรอบ .....	116
6.16 แบบจำลองของ โครงข่ายประสาทเทียมที่มี 2 ชั้นซ่อน .....	120
6.17 แบบตัวแปรอินพุทสำหรับ โครงข่ายประสาทเทียม .....	121
6.18 แผนภาพการตรวจจับพอลต์ .....	129
6.19 แผนภาพการการแยกระหว่างพอลต์ภายในกับพอลต์ภายนอก .....	130
6.20 แผนภาพการวิเคราะห์พอลต์ด้วย โครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ ตามวิธีที่ได้นำเสนอ (วิธีที่ 1) .....	131
6.21 แผนภาพการวิเคราะห์พอลต์ด้วย โครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ ตามวิธีปกติ (วิธีที่ 2) .....	132
7.1 ค่าเฉลี่ยของความถูกต้องในการตรวจจับพอลต์กรณีขดลวดลัดวงจรลงดิน ที่ตำแหน่ง 10 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง .....	135
7.2 ค่าเฉลี่ยของตำแหน่งพอลต์กรณีขดลวดลัดวงจรลงดิน ที่ตำแหน่ง 10 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง .....	136
7.3 ค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยในการระบุประเภทพอลต์กรณีขดลวดลัดวงจรลงดิน ที่ตำแหน่ง 10 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง .....	136
7.4 ค่าเฉลี่ยของความถูกต้องในการตรวจจับพอลต์กรณีขดลวดลัดวงจรลงดิน ที่ตำแหน่ง 20 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง .....	139
7.5 ค่าเฉลี่ยของตำแหน่งพอลต์กรณีขดลวดลัดวงจรลงดิน ที่ตำแหน่ง 20 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง .....	139
7.6 ค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยในการระบุประเภทพอลต์กรณีขดลวดลัดวงจรลงดิน ที่ตำแหน่ง 20 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง .....	140
7.7 ค่าเฉลี่ยของความถูกต้องในการตรวจจับพอลต์กรณีขดลวดลัดวงจรลงดิน ที่ตำแหน่ง 30 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง .....	142











## สารบัญรูป (ต่อ)

รูปที่	หน้า
7.78 ค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยในการระบุประเภทฟอลต์กรณีขลวดลัดวงจรระหว่างรอบ ที่ตำแหน่งขลวดย่อย a 60 % ของความยาวขลวดภายในหม้อแปลงไฟฟ้ากำลัง .....	198
7.79 ค่าเฉลี่ยของความถูกต้องในการตรวจจับฟอลต์กรณีขลวดลัดวงจรระหว่างรอบ ที่ตำแหน่งขลวดย่อย a 70 % ของความยาวขลวดภายในหม้อแปลงไฟฟ้ากำลัง .....	201
7.80 ค่าเฉลี่ยของตำแหน่งฟอลต์ขลวดย่อย a กรณีขลวดลัดวงจรระหว่างรอบ ที่ตำแหน่งขลวดย่อย a 70 % ของความยาวขลวดภายในหม้อแปลงไฟฟ้ากำลัง .....	201
7.81 ค่าเฉลี่ยของตำแหน่งฟอลต์ขลวดย่อย b กรณีขลวดลัดวงจรระหว่างรอบ ที่ 70% กับ 80% ของความยาวขลวดภายในหม้อแปลงไฟฟ้ากำลัง .....	202
7.82 ค่าเฉลี่ยของตำแหน่งฟอลต์ขลวดย่อย b กรณีขลวดลัดวงจรระหว่างรอบ ที่ 70% กับ 90% ของความยาวขลวดภายในหม้อแปลงไฟฟ้ากำลัง .....	202
7.83 ค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยในการระบุประเภทฟอลต์กรณีขลวดลัดวงจรระหว่างรอบ ที่ตำแหน่งขลวดย่อย a 70 % ของความยาวขลวดภายในหม้อแปลงไฟฟ้ากำลัง .....	203
7.84 ค่าเฉลี่ยของความถูกต้องในการตรวจจับฟอลต์กรณีขลวดลัดวงจรระหว่างรอบ ที่ตำแหน่งขลวดย่อย a 80 % ของความยาวขลวดภายในหม้อแปลงไฟฟ้ากำลัง .....	205
7.85 ค่าเฉลี่ยของตำแหน่งฟอลต์ขลวดย่อย a กรณีขลวดลัดวงจรระหว่างรอบ ที่ตำแหน่งขลวดย่อย a 80 % ของความยาวขลวดภายในหม้อแปลงไฟฟ้ากำลัง .....	206
7.86 ค่าเฉลี่ยของตำแหน่งฟอลต์ขลวดย่อย b กรณีขลวดลัดวงจรระหว่างรอบ ที่ 80% กับ 90% ของความยาวขลวดภายในหม้อแปลงไฟฟ้ากำลัง .....	206
7.87 ค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยในการระบุประเภทฟอลต์กรณีขลวดลัดวงจรระหว่างรอบ ที่ตำแหน่งขลวดย่อย a 80 % ของความยาวขลวดภายในหม้อแปลงไฟฟ้ากำลัง .....	207
7.88 ค่าเฉลี่ยความคลาดเคลื่อนของตำแหน่งฟอลต์แต่ละประเภทฟอลต์ กรณีขลวดลัดวงจรลงดิน .....	209
7.89 ค่าเฉลี่ยความคลาดเคลื่อนของตำแหน่งฟอลต์กรณีขลวดลัดวงจรลงดิน ในแต่ละตำแหน่งของความยาวขลวดภายในหม้อแปลงไฟฟ้ากำลัง .....	210
7.90 ค่าเฉลี่ยความคลาดเคลื่อนของตำแหน่งฟอลต์ขลวดย่อย a แต่ละประเภทฟอลต์ กรณีขลวดลัดวงจรระหว่างรอบ .....	211
7.91 ค่าเฉลี่ยความคลาดเคลื่อนของตำแหน่งฟอลต์ขลวดย่อย b แต่ละประเภทฟอลต์ กรณีขลวดลัดวงจรระหว่างรอบ .....	212

## สารบัญรูป (ต่อ)

รูปที่	หน้า
7.92	ค่าเฉลี่ยความคลาดเคลื่อนของตำแหน่งพอลดีกรีชนิดลวดลัดดวงจรระหว่างรอบ ในแต่ละตำแหน่งของความยาวขดลวดย่อย a ภายในหม้อแปลงไฟฟ้ากำลัง .....213
7.93	ค่าเฉลี่ยความคลาดเคลื่อนของตำแหน่งพอลดีกรีชนิดลวดลัดดวงจรระหว่างรอบ ในแต่ละตำแหน่งของความยาวขดลวดย่อย b ภายในหม้อแปลงไฟฟ้ากำลัง .....214
7.94	ค่าเฉลี่ยความถูกต้องในการระบุประเภทพอลดีแต่ละประเภทในระบบจำลอง .....215
7.95	ค่าเฉลี่ยความถูกต้องของการระบุประเภทพอลดีกรีชนิดลวดลัดดวงจรลงดิน ในแต่ละตำแหน่งของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง .....216
7.96	ค่าเฉลี่ยความถูกต้องของการระบุประเภทพอลดีกรีชนิดลวดลัดดวงจรระหว่างรอบ ในแต่ละตำแหน่งของความยาวขดลวดย่อย a ภายในหม้อแปลงไฟฟ้ากำลัง .....218
7.97	ค่าเฉลี่ยความถูกต้องของการระบุประเภทพอลดีกรีชนิดลวดลัดดวงจรระหว่างรอบ ในแต่ละตำแหน่งของความยาวขดลวดย่อย b ภายในหม้อแปลงไฟฟ้ากำลัง .....219
8.1	ค่าเฉลี่ยความคลาดเคลื่อนของการระบุตำแหน่งพอลดีกรีชนิดลวดลัดดวงจรลงดิน .....223
8.2	ค่าเฉลี่ยความคลาดเคลื่อนของการระบุตำแหน่งพอลดีกรีชนิดลวดลัดดวงจรระหว่างรอบ ...223
8.3	ค่าเฉลี่ยการระบุประเภทพอลดีแต่ละประเภท .....224
ข1	โครงข่ายประสาทเทียมชนิดความน่าจะเป็น .....254
ข2	ขั้นตอนการฝึกสอนโครงข่ายประสาทเทียมชนิดความน่าจะเป็น .....256
ข3	โครงข่ายประสาทเทียมชนิดฟังก์ชันฐานรัศมี .....258
ข4	ขั้นตอนการฝึกสอนโครงข่ายประสาทเทียมชนิดฟังก์ชันฐานรัศมี .....259

# บทที่ 1

## บทนำ

ในปัจจุบันความต้องการพลังงานไฟฟ้าเพิ่มสูงขึ้นจึงมีการเชื่อมโยงโครงข่าย (Network) ของระบบไฟฟ้าเข้าด้วยกัน โดยที่สายส่งเป็นอุปกรณ์หลักที่ทำหน้าที่ในการส่งจ่ายพลังงานไฟฟ้าจากโรงไฟฟ้า (Power plant) ไปยังผู้ใช้โดยผ่านส่วนต่างๆ ที่เกี่ยวข้อง เช่น สถานีไฟฟ้า (Substation) เขตชุมชน เป็นต้น ในขณะที่เดียวกัน หม้อแปลงไฟฟ้ากำลัง (Power transformer) เป็นหนึ่งในการเชื่อมโยงที่สำคัญที่สุดในระบบส่งจ่ายพลังงานไฟฟ้า โดยเฉพาะอย่างยิ่ง ตามสถานีไฟฟ้าต่างๆ มีการใช้หม้อแปลงไฟฟ้ากำลังเป็นจำนวนมาก

ด้วยเหตุที่ หม้อแปลงไฟฟ้ากำลังในระบบส่งจ่ายพลังงานไฟฟ้าถือเป็นอุปกรณ์ที่มีราคาสูงเมื่อเทียบกับอุปกรณ์อย่างอื่นในระบบส่งจ่ายพลังงานไฟฟ้า เมื่อใดก็ตามที่เกิดเหตุขัดข้องกับหม้อแปลงไฟฟ้ากำลังทำให้เกิดความสูญเสียเป็นอย่างมาก ความเสียหายที่หม้อแปลงไฟฟ้ากำลังเป็นความเสียหายที่ไม่พึงปรารถนา เนื่องจากความต่อเนื่องในระบบส่งจ่ายพลังงานไฟฟ้าอาจชะงักรวมไปถึงทำให้ระบบขาดเสถียรภาพการส่งจ่ายพลังงานไฟฟ้า นอกจากนี้การซ่อมแซมหรือนำหม้อแปลงไฟฟ้ากำลังตัวใหม่มาแทนที่ ทำให้สูญเสียเวลาและสิ้นเปลืองค่าใช้จ่ายได้ ด้วยเหตุนี้เอง ถ้ามีระบบป้องกันหม้อแปลงไฟฟ้ากำลังที่ดีพอสามารถตรวจจับความผิดปกติ (fault) ที่เกิดขึ้นกับหม้อแปลงไฟฟ้ากำลังขณะใช้งานจะเป็นการลดความเสียหายที่เกิดขึ้นกับหม้อแปลงไฟฟ้ากำลัง ดังนั้นจึงมีความจำเป็นต้องจัดระบบป้องกันที่แม่นยำ ถูกต้องและรวดเร็ว อีกทั้งถ้าจัดระบบป้องกันที่ดีสามารถแยกแยะว่าฟอลต์ที่เกิดขึ้นเป็นฟอลต์ที่เกิดขึ้นภายในหรือภายนอกจะทำให้อายุการใช้งานของหม้อแปลงไฟฟ้ากำลังยาวนานขึ้น สำคัญอย่างยิ่งถ้าหม้อแปลงไฟฟ้ากำลังดังกล่าวติดตั้งอยู่ในบริเวณของโหลดชนิดต่อเนื่องหรือโหลดที่สำคัญ และมีความเสียหายมาก ถ้าระบบหยุดจ่ายพลังงานไฟฟ้า เนื่องจากสาเหตุอื่นที่ไม่ใช่ฟอลต์จริงๆ ในตัวหม้อแปลงไฟฟ้ากำลัง

ความน่าเชื่อถือของระบบส่งจ่ายพลังงานไฟฟ้ามีความสำคัญมาก เมื่อมีฟอลต์เกิดขึ้นบนอุปกรณ์ในระบบส่งจ่ายพลังงานไฟฟ้า โดยเฉพาะอย่างยิ่งหม้อแปลงไฟฟ้ากำลังซึ่งเป็นส่วนประกอบที่จำเป็นและสำคัญในระบบส่งจ่ายพลังงานไฟฟ้า เนื่องจากหม้อแปลงไฟฟ้ากำลังเป็นตัวเชื่อมโยงที่สำคัญระหว่างเครื่องกำเนิดไฟฟ้าและสายส่ง จึงมีความจำเป็นอย่างยิ่งที่ต้องวิเคราะห์สัญญาณฟอลต์ที่เกิดขึ้น โดยมีประโยชน์คือ ในระบบการป้องกันการตรวจจับหาฟอลต์ที่เกิดขึ้นได้อย่างรวดเร็วและทราบรูปแบบที่ถูกต้อง รวมถึงตำแหน่งของฟอลต์ที่แม่นยำทำให้สามารถกำจัดฟอลต์ได้อย่างรวดเร็วซึ่งจะช่วยลดความเสียหายที่เกิดขึ้น ในส่วนของการซ่อมบำรุงรูปแบบและตำแหน่งที่เกิดฟอลต์จะช่วยทำให้การซ่อมแซมแก้ไขเพื่อให้สามารถนำหม้อแปลงไฟฟ้ากำลังกลับเข้าใช้งานอย่างรวดเร็วมากยิ่งขึ้น

ในปัจจุบัน การป้องกันหม้อแปลงไฟฟ้ากำลังที่มีความน่าเชื่อถือได้และมีความเร็วสูงวิธีหนึ่งก็คือ การใช้รีเลย์ป้องกันแบบผลต่าง (Differential protection relay) เป็นตัวตรวจจับความผิดปกติ (Fault) ที่เกิดขึ้นกับหม้อแปลงไฟฟ้ากำลัง [1-2] อย่างไรก็ตาม หม้อแปลงไฟฟ้ากำลังได้รับความเสียหายจากฟอลต์ภายในขดลวดเนื่องจากส่วนใหญ่ วัสดุที่ใช้เป็นฉนวนลัมเหลว ฟอลต์เหล่านี้ควรตรวจจับอย่างรวดเร็วและถูกต้อง การป้องกันที่เหมาะสมทำให้แยกหม้อแปลงไฟฟ้ากำลังที่มีข้อบกพร่องจากระบบส่งจ่ายพลังงานไฟฟ้า ดังนั้นการวิเคราะห์สัญญาณฟอลต์ที่แม่นยำจะช่วยทำให้ทราบประเภทและตำแหน่งของฟอลต์ที่เกิดขึ้นได้ โดยมีรายละเอียดของการศึกษาดังต่อไปนี้

### 1.1 การพัฒนาเทคโนโลยีของการวิเคราะห์สัญญาณในระบบป้องกันหม้อแปลงไฟฟ้า


การทำงานหลักของอุปกรณ์ป้องกันคือ ตรวจจับการเกิดของฟอลต์และแยกส่วนฟอลต์จากส่วนที่เหลือของระบบไฟฟ้า ฟิวส์ (Fuse) ถูกใช้เหมือนอุปกรณ์ป้องกันในการพัฒนาแรกเริ่มของระบบไฟฟ้า ฟิวส์เป็นอุปกรณ์ที่มีประสิทธิภาพและราคาถูกแต่มีข้อเสียในตัว เช่น ไม่สามารถแยกแยะระหว่างฟอลต์ด้านแหล่งจ่ายและด้านโหลด และทำให้คืนสู่สภาวะปกติหลังจากกำจัดฟอลต์ไปแล้ว การพัฒนาของรีเลย์แม่เหล็กกลไฟฟ้า (Electro-mechanical) [1-2] ให้สิ่งที่เปลี่ยนแปลงในทางที่ดีขึ้นในการป้องกันของระบบไฟฟ้า รีเลย์ให้วิธีสำหรับการควบคุมเวลาการทำงานและความสามารถเพื่อสับวงจรใหม่ ต่อมาในช่วงต้นทศวรรษที่ 1950 รีเลย์โซลิดสเตต (Solid state relay) [1-2] ถูกนำมาใช้ ในช่วงแรก รีเลย์โซลิดสเตตไม่เป็นที่ยอมรับจากผู้ใช้งานเนื่องจากผู้ใช้งานไม่พอใจการออกแบบและอัตราการผิดพลาดที่สูงของส่วนประกอบอิเล็กทรอนิกส์ เนื่องจากส่วนประกอบของรีเลย์โซลิดสเตต เป็นวงจรไฟฟ้าสารกึ่งตัวนำ ดังนั้นจึงไม่อาจทนต่ออุณหภูมิสูง ความชื้นสูง แรงดันเกินและกระแสเกินมากๆ ได้ ด้วยเหตุนี้ รีเลย์โซลิดสเตตรุ่นแรกๆ จึงมีเปอร์เซ็นต์เสียหายสูง แต่จากการพัฒนาอย่างต่อเนื่องมาเป็นเวลากว่ายี่สิบปี ได้ใช้เทคโนโลยีเซมิคอนดักเตอร์และเสนอปรับปรุงออกแบบตัวรีเลย์ จึงทำให้รีเลย์โซลิดสเตตสมัยใหม่มีคุณภาพดี และทำงานได้หลากหลายกว่ารีเลย์แม่เหล็กทางกล รีเลย์แม่เหล็กทางกลและรีเลย์โซลิดสเตตหลายๆ ชนิดจึงถูกใช้ในระบบไฟฟ้าทุกวันนี้

การขยายตัวอย่างรวดเร็วและความซับซ้อนของระบบไฟฟ้าสมัยใหม่ ทำให้มีความต้องการรีเลย์ป้องกันที่มีคุณภาพดี และสามารถทำงานที่ละเอียดซับซ้อนได้ ความต้องการเหล่านี้เป็นไปได้เนื่องจากการพัฒนาสารกึ่งตัวนำและอุปกรณ์ที่เกี่ยวข้องอื่นๆ รวมไปถึงความก้าวหน้าของอุปกรณ์ไอซี (IC) ทำให้เกิดการพัฒนาไมโครโปรเซสเซอร์ ซึ่งการพัฒนาเหล่านี้ทำให้เกิดรีเลย์แบบดิจิทัล (Digital relay) [1-2]

รีเลย์ดิจิทัล (Digital relay) เป็นอุปกรณ์พื้นฐานไมโครโปรเซสเซอร์ซึ่งใช้ซอฟต์แวร์ (software) เพื่อประมวลผลสัญญาณสำหรับนำไปปฏิบัติกับลอจิกรีเลย์ งานวิจัยส่วนใหญ่ในสาขาการป้องกันแบบดิจิทัลเกี่ยวพันกับการพัฒนาหลักการแนวคิดสำหรับการประยุกต์ใช้งานเฉพาะ

รีเลย์ดิจิทัลสามารถปฏิบัติเช่นเดียวกันหรือดีกว่ารีเลย์แม่เหล็กทางกลและรีเลย์โซลิดสเตท รีเลย์ดิจิทัลถูกกระตุ้นอย่างต่อเนื่องและแบบแผนปฏิบัติวินิจัยด้วยตัวเอง ถูกนำไปปฏิบัติบ่อยๆ ตรวจสอบความผิดพลาดเพื่ออนุญาตช่วยแก้ไขการกระทำถูกจังหวะ เหล่านี้ทำให้รีเลย์ดิจิทัลน่าเชื่อถือกว่ารีเลย์แม่เหล็กทางกลและรีเลย์โซลิดสเตท

กล่าวโดยสรุปก็คือ ปัจจุบันเทคโนโลยีของรีเลย์มีการพัฒนาอย่างต่อเนื่องจากระบบ “แม่เหล็กกลไฟฟ้า” (Electro-mechanical) มาสู่ระบบนิวเมอริกอล (Numerical) จนถึงระบบที่มีการนำดิจิทัลคอมพิวเตอร์และไมโครโปรเซสเซอร์มาใช้งาน เพื่อเพิ่มประสิทธิภาพของรีเลย์ให้มีการตอบสนองและความแม่นยำที่สูงขึ้นในลักษณะของรีเลย์ความเร็วสูง (High speed relay) ดังรูปที่ 1.1



รูปที่ 1.1 แสดงการพัฒนาเทคโนโลยีของอุปกรณ์ป้องกันที่ใช้ในระบบไฟฟ้ากำลัง [3]

แต่ไม่ว่าจะมีพัฒนารูปแบบของรีเลย์ไปอย่างไรก็ตามเพียงใดก็ตาม เทคนิคทฤษฎีแบบผลต่างในการวิเคราะห์สัญญาณในหม้อแปลงไฟฟ้ากำลังก็ยังคงใช้การวิเคราะห์การเปลี่ยนแปลงขององค์ประกอบความถี่พื้นฐานเหมือนเดิม กล่าวคือ เปรียบเทียบกระแสในทุกๆ ขั้วของหม้อแปลงโดยคำนวณและตรวจสอบกระแสผลต่าง (ไม่สมมาตร) สัญญาณที่มีค่าไม่เป็นศูนย์ชี้ให้เห็นว่าเป็นฟอลต์ภายใน รีเลย์จะทำงานทันที จากหลักการนี้นำมาใช้ในการตรวจจับฟอลต์และแยกแยะระหว่างฟอลต์ที่เกิดขึ้นภายใน (Internal Fault) หรือฟอลต์ที่เกิดขึ้นภายนอก (External or Non-Internal Fault) ของตัวหม้อแปลงไฟฟ้ากำลัง อย่างไรก็ตาม รีเลย์ที่ใช้หลักการดังกล่าวยังมีข้อผิดพลาด

ในการส่งปลดวงจร เนื่องจากหลักการแนวคิดเหล่านี้ถูกผลกระทบด้วยการอิมพัลส์ของหม้อแปลงกระแส (CT) และสภาวะอัตราส่วนไม่เท่ากัน

จึงกล่าวได้ว่า การประยุกต์ใช้รีเลย์ในปัจจุบัน โดยหลักการพื้นฐานใช้สัญญาณกระแสและถูกกำหนดขอบเขตการวิเคราะห์ด้วยองค์ประกอบความถี่มูลฐานและฮาร์มอนิกอันดับสูงของสัญญาณเหล่านั้น ต่อมาได้มีการนำเสนอทฤษฎีประยุกต์นิวเมอริคอล (advanced numerical principles) โดยใช้ข้อมูลที่มากขึ้นรวมไปถึงสัญญาณแรงดันเช่นเดียวกับสัญญาณลักษณะเด่นอื่นๆที่คล้ายคลึงกับฮาร์มอนิก อย่างไรก็ตามหลักการนี้ยังไม่นำไปปฏิบัติอย่างกว้างๆ ในขณะเดียวกัน ได้มีการพัฒนาเกี่ยวกับแนวความคิดในการนำเทคนิคของปัญญาประดิษฐ์ (Artificial intelligent : AI) มาใช้งาน โดยหลักการนี้มีแนวโน้มที่ใช้ข้อมูลที่มีประโยชน์ทั้งหมด

จากหลักการทั้งสามที่ได้กล่าวมา เป็นหลักการที่ใช้สัญญาณองค์ประกอบความถี่พื้นฐานเป็นหลัก ในบางครั้งการใช้สัญญาณองค์ประกอบความถี่พื้นฐานเพียงอย่างเดียวอาจจะไม่เพียงพอกับการวิเคราะห์สัญญาณพอลต์ รวมทั้งการกำจัดสัญญาณองค์ประกอบความถี่สูงนั้นจะเป็นการทิ้งข้อมูลที่สำคัญของสัญญาณพอลต์ออกไปอีกด้วย

ในช่วงปลายของทศวรรษที่ 90 ได้มีแนวความคิดใหม่เกิดขึ้นมาโดยเปลี่ยนแนวโน้มของการวิเคราะห์สัญญาณองค์ประกอบความถี่พื้นฐานมาสู่การวิเคราะห์สัญญาณองค์ประกอบความถี่สูง เนื่องจากสัญญาณองค์ประกอบความถี่สูงนี้จะให้ข้อมูลเกี่ยวกับสัญญาณพอลต์ที่มีความหลากหลายมากขึ้น จึงทำให้แนวความคิดนี้ได้รับความสนใจและมีการนำมาทำการศึกษาและวิจัยมากขึ้น ด้วยเหตุนี้ ทำให้เทคโนโลยีของอุปกรณ์ป้องกันที่ใช้ในระบบไฟฟ้ากำลังได้รับการพัฒนาอย่างต่อเนื่อง จากการวิเคราะห์สัญญาณองค์ประกอบความถี่พื้นฐาน (50Hz) มาสู่การวิเคราะห์สัญญาณองค์ประกอบความถี่สูงในลักษณะการป้องกันแบบทรานเซียนต์ (Transient based protection) [3] โดยมีจุดประสงค์เพื่อลดช่วงของสัญญาณที่ทำการวิเคราะห์ให้สั้นลง ซึ่งจะส่งผลให้ระบบการวิเคราะห์และตัดสินใจใช้เวลาที่ลดลงตามไปด้วย

วิทยานิพนธ์ฉบับนี้จึงได้ทำการศึกษาถึงรูปแบบของกระบวนการประมวลผลสัญญาณ (Signal-processing) ที่เหมาะสมที่จะนำมาใช้สำหรับการวิเคราะห์การเปลี่ยนแปลงขององค์ประกอบความถี่สูงในสัญญาณพอลต์เกิดขึ้นภายในขดลวดหม้อแปลงไฟฟ้ากำลัง จากการศึกษาพบว่า การวิเคราะห์เวฟเล็ตเป็นวิธีแก้ปัญหาได้ดีมากในกระบวนการประมวลผลสัญญาณ เนื่องจากวิธีดังกล่าวมีความสามารถหลายด้านที่วิเคราะห์ดำเนินการเฉพาะในเวลาและความถี่ นอกจากนี้ยังมีข้อได้เปรียบกว่าการวิเคราะห์ฟูเรียร์ กล่าวคือ สัญญาณทรานเซียนต์เป็นสัญญาณที่มีการเปลี่ยนแปลงไม่คงที่ (Non-stationary signal) ดังนั้น การวิเคราะห์ด้วยการแปลงฟูเรียร์จะมีความผิดพลาดเกิดขึ้นรวมทั้งข้อมูลทางด้านเวลาที่ขาดหายไป ด้วยข้อจำกัดในหลายด้านจึงทำให้การแปลงฟูเรียร์อาจจะไม่เหมาะสมสำหรับการวิเคราะห์สัญญาณทรานเซียนต์ อย่างไรก็ตาม ไม่ได้หมายความว่า การแปลงเวฟเล็ตจะถูกนำมาแทนที่การแปลงฟูเรียร์ในการวิเคราะห์สัญญาณช่วงสถานะคงที่ (Steady state

signals) ด้วย แต่การแปลงเวฟเล็ทเป็นเครื่องมืออีกทางเลือกหนึ่งสำหรับวิเคราะห์สัญญาณที่มีการเปลี่ยนแปลงไม่คงที่ หรือสัญญาณช่วงสภาวะไม่คงที่ (Non-steady state signals)

ในช่วงทศวรรษที่ผ่านมาการแปลงเวฟเล็ทได้มีการนำไปประยุกต์ใช้ประสบความสำเร็จเป็นอย่างมากทางด้านการประมวลผลสัญญาณ ได้มีการเสนอเวฟเล็ทให้เป็นเครื่องมือการวิเคราะห์ทรานเซียนต์ (Transients) ในระบบไฟฟ้ากำลัง [4] ด้วยประการนี้เองข้อเสนอที่น่าสนใจหลายๆ ข้อของการวิเคราะห์เวฟเล็ทในระบบไฟฟ้ากำลังดังนี้คือ การประเมินคุณภาพกำลังไฟฟ้า (Power quality assessment)[5] สถานที่เกิดฟอลต์ (Fault location)[6] เป็นต้น ด้วยเหตุนี้เอง จึงได้มีนักวิจัยบางท่าน ได้ทำการวิจัยโดยนำการแปลงเวฟเล็ทมาประยุกต์ใช้ในการวิเคราะห์ทรานเซียนต์ที่เกี่ยวกับหม้อแปลงไฟฟ้ากำลัง [7-9] ถึงแม้ว่า การแปลงเวฟเล็ทจะมีประสิทธิภาพอย่างมากในการตรวจจับและวิเคราะห์สัญญาณทรานเซียนต์ แต่การแปลงเวฟเล็ทอาจจะไม่มีคุณลักษณะอย่างสมบูรณ์เพียงพอ จึงได้มีแนวคิดที่จะนำโครงข่ายประสาทเทียมเข้ามาช่วยเพื่อเพิ่มประสิทธิภาพให้ดีขึ้นกว่าการประยุกต์ใช้เวฟเล็ทเพียงอย่างเดียว ซึ่งนับได้ว่าเป็นการขยายขอบเขตงานวิจัยและเทคโนโลยีทางด้านวิศวกรรมไฟฟ้ากำลังให้ดีขึ้นด้วย

## 1.2 ความมุ่งหมายและวัตถุประสงค์ของการศึกษา

ระบบป้องกันหม้อแปลงไฟฟ้ากำลังของการไฟฟ้าฝ่ายผลิตแห่งประเทศไทย (EGAT) ที่มีใช้ในปัจจุบันคือ รีเลย์ป้องกันแบบผลต่างซึ่งยังคงใช้การวิเคราะห์องค์ประกอบความถี่พื้นฐาน โดยใช้หลักการเปอร์เซ็นต์กระแสผลต่าง (Percentage Differential Current) สำหรับตรวจสอบสถานะฟอลต์ที่เกิดขึ้นว่าเป็นฟอลต์ที่เกิดขึ้นภายใน (Internal Fault) หรือฟอลต์ที่เกิดขึ้นภายนอก (External or Non-Internal Fault) ของตัวหม้อแปลงไฟฟ้ากำลัง อย่างไรก็ตาม รีเลย์ที่ใช้หลักการดังกล่าวยังมีข้อผิดพลาดในการสั่งปลดวงจรหากรูปคลื่นที่วัดเข้ามาเกิดการผิดเพี้ยน อีกกรณีที่สามารถทำให้เกิดการผิดพลาดในการสั่งปลดวงจรก็คือ กรณีฟอลต์ขาดลงดินภายในหม้อแปลง (Winding to ground fault) บริเวณช่วงปลายๆ ขดลวด นอกจากนี้ยังมีข้อผิดพลาดจากกรณีอื่นๆ อีกด้วย วิทยานิพนธ์นี้ได้ทำการศึกษาแนวทางการประยุกต์ใช้การแปลงเวฟเล็ทแบบเต็มหน่วยร่วมกับโครงข่ายประสาทเทียม เพื่อพัฒนาแผนการป้องกันแบบใหม่สำหรับวิเคราะห์สัญญาณฟอลต์ที่เกิดขึ้นภายในขดลวดหม้อแปลงไฟฟ้ากำลัง และนำผลที่ได้มาใช้ใน 2 ลักษณะด้วยกันคือ

1. ระบุประเภทของฟอลต์ที่เกิดขึ้นว่าเป็นฟอลต์ที่เฟสใด
2. ระบุตำแหน่งของฟอลต์ที่เกิดขึ้นว่าอยู่ที่ตำแหน่งใดบนขดลวดหม้อแปลงไฟฟ้ากำลัง

### 1.3 สมมุติฐานของการศึกษา

รูปแบบเดิมในการวิเคราะห์สัญญาณของรีเลย์แบบผลต่าง (Differential relay) คือ การหาขนาดกระแสผลต่างทางปฐมภูมิ (Primary) และ ทุตติภูมิ (Secondary) ของหม้อแปลงไฟฟ้ากำลัง โดยกำหนดให้โวลต์แอมป์ (VA) ของหม้อแปลงทั้งทางด้านปฐมภูมิและทุติภูมิมีค่าคงที่ อัตราส่วนกระแสทั้งสองด้านจะมีค่าขึ้นกับอัตราส่วนแรงดันทั้งสองด้าน เมื่อทอนกระแสทั้งสองด้านด้วย หม้อแปลงกระแส (CT) เข้ารีเลย์ โดยทิศทางของกระแสตรงกันข้ามกันในสภาวะจ่ายโหลดปกติ ผลต่างของกระแสทั้งสองมีค่าน้อยมาก เมื่อใดก็ตามที่มีความผิดปกติเกิดขึ้น ผลต่างกระแสจะมีค่าเพิ่มขึ้น ถ้าผลต่าง ดังกล่าวมีค่ามากกว่าที่รีเลย์กำหนด (Relay set) ไว้ รีเลย์จะทำงานทันที จากหลักการนี้นำมาใช้ในการตรวจจับฟอลต์และแยกแยะระหว่างฟอลต์ที่เกิดขึ้นภายใน (Internal Fault) หรือฟอลต์ที่เกิดขึ้นภายนอก (External or Non-Internal Fault) ของตัวหม้อแปลงไฟฟ้ากำลัง อย่างไรก็ตาม รีเลย์ที่ใช้หลักการดังกล่าวยังมีข้อผิดพลาดในการส่งปลดวงจร

วิทยานิพนธ์ฉบับนี้ได้ตั้งสมมุติฐานของการศึกษาโดยอ้างอิงจากพฤติกรรมของสัญญาณฟอลต์ คือ เมื่อมีฟอลต์เกิดขึ้นภายในขดลวดหม้อแปลงไฟฟ้ากำลังจะมีการเปลี่ยนแปลงขององค์ประกอบความถี่ต่างๆ เกิดขึ้น ซึ่งการเปลี่ยนแปลงนี้จะมีความสัมพันธ์กับรูปแบบของฟอลต์ โดยเฉพาะการเปลี่ยนแปลงขององค์ประกอบความถี่สูงจะมีค่าสูงขึ้นและยังสามารถให้ข้อมูลที่สำคัญเกี่ยวกับฟอลต์ที่เกิดขึ้น โดยข้อมูลของการเปลี่ยนแปลงนี้เมื่อนำการแปลงเวฟเล็ดแบบเต็มหน่วย (DWT) มาใช้ในการวิเคราะห์สัญญาณฟอลต์ โดยทำการแยกองค์ประกอบความถี่สูง (Detail) พิจารณาการเปลี่ยนแปลงขององค์ประกอบความถี่สูงในหลายสเกลหรือหลายช่วงความถี่ ผลที่ได้จากการวิเคราะห์นี้นำมาใช้ในการตรวจจับฟอลต์ที่เกิดขึ้นภายในขดลวดหม้อแปลงไฟฟ้ากำลัง และนำสัมประสิทธิ์ที่ได้จากสเกลแรกที่เกิดการเปลี่ยนแปลงขององค์ประกอบความถี่สูง นำไปเป็นข้อมูลอินพุตสำหรับใช้ในรูปแบบการฝึกสอน (Training pattern) ซึ่งเป็นส่วนที่ให้โครงข่ายประสาทเทียมเรียนรู้และข้อมูลทดสอบ (Test set) ใช้ในการหาประสิทธิภาพของโครงข่ายประสาทเทียมในการหาคำตอบจากข้อมูลที่ไม่เคยเรียนรู้มาก่อน โดยมีคำตอบที่ต้องการคือ ตำแหน่งฟอลต์หรือตำแหน่งขดลวดฟอลต์เกิดขึ้น และประเภทฟอลต์ที่เกิดขึ้นภายในขดลวดหม้อแปลงไฟฟ้ากำลัง จากนั้นจึงทำการฝึกสอน โครงข่ายประสาทเทียม แล้วนำโครงข่ายที่ผ่านการฝึกสอนที่มีประสิทธิภาพสูงสุดไปใช้งาน ซึ่งคำตอบที่ได้จากโครงข่ายประสาทเทียมจะมีความถูกต้องและแม่นยำอยู่ในเกณฑ์ที่ดี และสอดคล้องกับทิศทางกาพัฒนาของรีเลย์ด้วย

### 1.4 ขอบเขตของการศึกษา

1. ทำการจำลองสัญญาณฟอลต์ภายในขดลวดหม้อแปลงไฟฟ้ากำลังด้วยโปรแกรม ATP/EMTP เพื่อศึกษารูปแบบของสัญญาณฟอลต์ที่แตกต่างกันโดยอาศัยหม้อแปลง


ไฟฟ้ากำลังขนาด 50 MVA ในสถานีไฟฟ้ามหาสารคามเป็นแบบจำลองหลักที่ใช้ในการศึกษา

2. ทำการศึกษารูปแบบของสัญญาณพอลต์ที่ได้จากขั้นตอนที่ 1 โดยใช้การแปลงเวฟเล็ตแบบเต็มหน่วยในสเกลที่ 1-5 ซึ่งจะใช้ Wavelet Toolbox ของโปรแกรม MATLAB เพื่อหาสเกลแรกที่ตรวจจับพอลต์ได้
3. ทำการฝึกสอนและทดสอบโครงข่ายประสาทเทียมด้วยข้อมูลในสเกลแรกที่ได้จากขั้นตอนในข้อที่ 2 โดยอาศัยโปรแกรม Neural Network Toolbox ของโปรแกรม MATLAB เป็นเครื่องมือในฝึกสอนและวิเคราะห์เพื่อระบุตำแหน่งและประเภทพอลต์ที่เกิดขึ้นภายในขดลวดหม้อแปลงไฟฟ้ากำลัง
4. ทำการทดสอบขั้นตอนการวิเคราะห์ตามวัตถุประสงค์ที่ได้กำหนดไว้ ด้วยกรณีศึกษา 864 ตัวอย่างตามขั้นตอนที่นำเสนอ โดยค่าเฉลี่ยความถูกต้องในการวิเคราะห์จะต้องมีค่าไม่ต่ำกว่า 95%

## 1.5 ขั้นตอนของการศึกษา

ขั้นตอนการศึกษาของวิทยานิพนธ์นี้ประกอบไปด้วยขั้นตอนต่างๆ ดังต่อไปนี้

1. การศึกษารูปแบบของการแปลงเวฟเล็ตแบบเต็มหน่วยร่วมกับโครงข่ายประสาทเทียมที่เหมาะสมกับการวิเคราะห์สัญญาณพอลต์ ขณะเดียวกันศึกษาคุณสมบัติของเวฟเล็ตแม่และโครงข่ายประสาทเทียมแต่ละชนิดโดยอาศัยผลการศึกษาจากงานวิจัยที่ผ่านมา
2. ทำการจำลองสัญญาณพอลต์ที่แตกต่างกัน 3240 ตัวอย่างด้วยโปรแกรม ATPDraw แล้วนำสัญญาณพอลต์มาทำการแปลงเวฟเล็ตแบบเต็มหน่วย เพื่อทำการพิจารณาหาสเกลแรกที่ตรวจจับพอลต์ได้ รวมถึงช่วงของข้อมูลที่เหมาะสมที่ควรใช้เป็นข้อมูลในการวิเคราะห์ เพื่อนำมาสรุปเป็นขั้นตอนการวิเคราะห์และตัดสินใจที่จะนำไปเป็นข้อมูลอินพุทในขั้นตอนต่อไป
3. เมื่อได้สเกลและขั้นตอนที่เหมาะสมแล้วจึงนำมาฝึกสอนและทดสอบกับโครงข่ายประสาทเทียมด้วยสัญญาณพอลต์ที่ได้จากระบบที่ได้จำลองไว้ นำผลที่ได้มาสรุปและตรวจสอบค่าเฉลี่ยความถูกต้องของขั้นตอนที่นำเสนอ
4. นำวิธีการที่นำเสนอมาทดสอบกับกรณีศึกษา 864 ตัวอย่าง เพื่อทดสอบความเป็นไปได้ในการนำมาใช้งานในทางปฏิบัติโดยค่าเฉลี่ยความถูกต้องในการวิเคราะห์จะต้องมีค่าไม่ต่ำกว่า 95%
5. วิเคราะห์และสรุปผลการทดลองและเสนอแนวทางการพัฒนาการศึกษาต่อไป ซึ่งขั้นตอนที่กล่าวมาทั้งหมดสามารถแสดงเป็นแผนภาพการทำงานได้ดังรูปที่ 1.2



รูปที่ 1.2 แสดงแผนภาพขั้นตอนการศึกษาของวิทยานิพนธ์

## 1.6 ข้อตกลงเบื้องต้นของการศึกษา

เนื่องจากรูปแบบของการดำเนินงานของวิทยานิพนธ์นี้เป็นการศึกษารูปแบบของฟอลต์ที่เกิดขึ้นภายในขดลวดหม้อแปลงไฟฟ้ากำลัง โดยกำหนดรูปแบบของฟอลต์ให้เป็นเหตุการณ์ของ

ฟอลต์อย่างเฉียวเท่านั้น ไม่มีการพิจารณาผลกระทบจากสัญญาณรบกวนใดๆ เพื่อให้ง่ายต่อการศึกษาในเบื้องต้น ดังนั้น ในการศึกษาครั้งนี้จึงไม่พิจารณาถึงรูปแบบของสัญญาณรบกวนอื่นๆ ที่คล้ายคลึงกันเช่น ฟิวส์ สัญญาณทรานเซียนต์ที่เกิดจากการอิมพัลส์ของหม้อแปลงกระแส สัญญาณเสียงที่เกิดขึ้นภายนอกหม้อแปลง สัญญาณกระแสอินรัชและฟอลต์ที่เกิดจากหม้อแปลงลูกอื่นและการปรับแก้หม้อแปลง เป็นต้น ในส่วนของเวลาที่ใช้ในการวิเคราะห์นั้น เนื่องจากวิทยานิพนธ์นี้ได้มุ่งเน้นไปที่การวิเคราะห์ที่ใช้ช่วงเวลาการวิเคราะห์ที่ลดลงและรูปแบบการตัดสินใจมากกว่าจึงไม่ได้พิจารณาผลจากเวลาที่ใช้ในการวิเคราะห์เท่าใดนัก อนึ่ง โครงข่ายประสาทเทียมที่ใช้ในปัจจุบันมีจำนวนมาก ซึ่งแต่ละชนิดสามารถนำมาวินิจฉัยฟอลต์ภายในหม้อแปลงได้ ในวิทยานิพนธ์นี้ได้เลือกโครงข่ายประสาทเทียมที่มีความถูกต้องมากที่สุดเป็นหลัก โดยไม่ได้พิจารณาช่วงเวลาในการฝึกสอนเป็นหลัก เนื่องจาก การวินิจฉัยฟอลต์ภายในหม้อแปลงเป็นงานที่ต้องการความถูกต้องสูงเพื่อนำไปซ่อมแซมและแก้ไขหม้อแปลงไฟฟ้ากำลังต่อไป

## 1.7 ประโยชน์ที่คาดว่าจะได้รับ

1. สามารถนำการแปลงเวฟเล็ตและโครงข่ายประสาทเทียมไปประยุกต์ใช้ในการวิเคราะห์สัญญาณฟอลต์ หรือ สัญญาณในรูปแบบอื่นๆ ที่เกิดขึ้นในระบบไฟฟ้ากำลังได้
2. สามารถนำรูปแบบของการวิเคราะห์สัญญาณด้วยการแปลงเวฟเล็ตแบบเต็มหน่วยร่วมกับโครงข่ายประสาทเทียมที่นำเสนอไปประยุกต์ใช้กับหลักการของระบบป้องกันแบบต่างๆ เช่น รีเลย์ป้องกันแบบดิจิทัลของหม้อแปลงไฟฟ้ากำลังในปัจจุบัน

## บทที่ 2


# ระบบป้องกันหม้อแปลงไฟฟ้ากำลัง

การมีระบบส่งกำลังไฟฟ้าที่มีประสิทธิภาพสูง จำเป็นต้องอาศัยระบบป้องกันและอุปกรณ์สนับสนุนเป็นจำนวนมาก หม้อแปลงไฟฟ้ากำลังขนาดใหญ่เป็นส่วนหนึ่งของอุปกรณ์ที่มีความสำคัญและมีราคาแพงในระบบไฟฟ้ากำลัง ถ้าหม้อแปลงไฟฟ้ากำลังเกิดฟอลต์ขึ้น จำเป็นต้องปลดหม้อแปลงไฟฟ้ากำลังออกจากระบบส่งจ่ายกำลังไฟฟ้าเพื่อลดความเสียหาย เนื่องจากราคาในการซ่อมแซมจะสัมพันธ์กับความเสียหายของหม้อแปลง ฉะนั้นระบบป้องกัน (Protection System) หม้อแปลงไฟฟ้ากำลังจึงเป็นสิ่งที่ต้องการอย่างมาก ความต้องการรวมไปถึงความน่าเชื่อถือ (ไม่มีการสั่งทำงานผิดพลาด) ความแน่นอนหรือความปลอดภัย (ไม่มีการตัดวงจรผิดพลาด) และความเร็วการทำงาน (เวลาในการเคลียร์ฟอลต์ที่สั้น) อนึ่ง ระบบป้องกันที่ดีนอกจากสามารถทำงานได้สมบูรณ์แล้วต้องใช้งบลงทุนไม่มากเกินไปด้วย ในบทนี้เป็นการกล่าวถึงรีเลย์ป้องกันหม้อแปลงไฟฟ้ากำลังแต่ละชนิดที่สำคัญ ซึ่งนิยมใช้กันอยู่ในปัจจุบัน

### 2.1 รีเลย์ป้องกัน (Protective Relay)

รีเลย์ป้องกัน (Protective Relay) คือ อุปกรณ์หลักในระบบป้องกันเพราะเป็นอุปกรณ์ที่ใช้ในการตรวจจับความผิดปกติที่เกิดกับอุปกรณ์ ไฟฟ้าในระดับแรงดันสูง (High Voltage) และตัดสินใจจะให้ทำงานสั่งปลดอุปกรณ์ไฟฟ้าที่เกิดปัญหาออกจากระบบไฟฟ้า โดยเร็วเพื่อไม่ให้อุปกรณ์เกิดความเสียหาย รีเลย์ป้องกันหม้อแปลงไฟฟ้ากำลังที่ใช้ในปัจจุบันมีอยู่ด้วยกันหลายประเภทซึ่งได้รับการออกแบบและพัฒนามาให้เหมาะสมกับการป้องกันหม้อแปลงไฟฟ้ากำลังในปัจจุบัน ดังนั้นหม้อแปลงไฟฟ้ากำลังที่จะทำการติดตั้งระบบป้องกันนั้นจึงไม่จำเป็นต้องมีอุปกรณ์เหมือนกัน ทั้งนี้ขึ้นอยู่กับความสำคัญและขนาดของหม้อแปลง ซึ่งโดยทั่วไปรีเลย์ส่วนใหญ่ที่มักจะใช้ในการป้องกันหม้อแปลงไฟฟ้ากำลังนั้นสามารถแสดงได้ดังในรูป 2.1

รีเลย์อาจแยกออกได้หลายประเภทขึ้นอยู่กับประเภทของการแยก ถ้าหากแยกชนิดรีเลย์ตามโครงสร้างสามารถแยกออกได้ 3 ชนิดใหญ่ๆ คือ รีเลย์ชนิดแม่เหล็กกลไฟฟ้า (Electro-mechanical relay) รีเลย์ชนิดโซลิดสเตท (solid state relay) และรีเลย์ชนิดดิจิทัล (Digital relay) ดังที่ได้กล่าวมาแล้ว แต่ถ้าแบ่งตามประเภทของการตรวจจับความผิดปกติที่เกิดขึ้นหรืออินพุทของรีเลย์สามารถแบ่งออกได้ 2 ชนิดใหญ่ๆ คือ รีเลย์ป้องกันเชิงกล (Mechanical Faults Detection Relay) [10] และรีเลย์ป้องกันเชิงไฟฟ้า (Electrical Faults Detection Relay) [10] โดยที่รูปแบบการตรวจจับความผิดปกติแต่ละชนิดนั้นจะมีหลักการและวิธีการที่แตกต่างกันออกไปตามวัตถุประสงค์ในการนำไปใช้งาน ดังจะกล่าวในหัวข้อถัดไป



รูปที่ 2.1 แสดงการป้องกันหม้อแปลงไฟฟ้ากำลัง [10]

## 2.2 การตรวจจับฟอลต์เชิงกล (Mechanical Faults Detection)





การสะสมของแก๊สหรือการเปลี่ยนแปลงของความดันภายในตัวถังหม้อแปลงเป็นตัวระบุที่ดีสำหรับฟอลต์ภายในหม้อแปลง อุปกรณ์ที่ใช้ระบุการเปลี่ยนแปลงเหล่านี้จึงเป็นสิ่งที่ต้องการ เมื่อใดก็ตามที่อุปกรณ์เหล่านี้ได้นำมาใช้ป้องกันหม้อแปลงนับได้ว่า เป็นการเสริมการป้องกันที่สมบูรณ์ การป้องกันเชิงกลนี้มีความไวสม่ำเสมอ ดังนั้น จึงทำงานที่ฟอลต์ภายในที่ไม่รุนแรงที่ซึ่งไม่สามารถตรวจจับด้วยรีเลย์แบบผลต่างหรือรีเลย์ชนิดอื่น อย่างไรก็ตาม ใดๆก็ดี ต้องยอมรับว่า การทำงานเหล่านี้มีข้อจำกัดกับปัญหาภายในตัวถังหม้อแปลง กล่าวคือ การตรวจจับจะไม่ทำงานกับฟอลต์ที่บุชซึ่ง

(Bushings) หรือที่ภายนอกหม้อแปลงกระแส (External CTs) ดังนั้น โชนป้องกันจึงอยู่ภายในถังหม้อแปลงอย่างเดียว

รีเลย์ที่มีการป้องกันเชิงกลส่วนใหญ่จะติดมาพร้อมกับหม้อแปลงไฟฟ้ากำลัง โดยที่รีเลย์เหล่านี้เป็นระบบป้องกันที่อาศัยสัญญาณทางเชิงกล เช่น อาศัยการเปลี่ยนแปลงความดันทันทีที่มีปัญหา (Trouble) เกิดขึ้น หรืออาศัยแก๊สลอยตัวภายในหม้อแปลง หรืออาศัยความร้อน เป็นต้น รีเลย์ที่มีการป้องกันเชิงกลออกแบบไว้สำหรับป้องกันปัญหาที่เกิดขึ้นในตัวหม้อแปลงมีดังนี้

### 2.2.1 บูลโฮลรีเลย์ (Buchholz Relay)



รีเลย์ชนิดตัวสะสมแก๊ส (Gas accumulator relay) หรือบูลโฮลรีเลย์ (Buchholz relay) จะติดตั้งกับหม้อแปลงชนิดที่มีถังเก็บน้ำมัน (Conservator tank) ดังรูปที่ 2.2 จากรูปแสดงถึงตำแหน่งและลักษณะของการวางบูลโฮลรีเลย์ในตัวหม้อแปลงเพื่อให้รีเลย์ทำงานดีที่สุด บูลโฮลรีเลย์ติดตั้งอยู่บนท่อเชื่อมระหว่างถังหม้อแปลงและห้องรองรับน้ำมัน โดยให้ตัวท่อเอียงทำมุมประมาณ  $4-7^{\circ}$  กับแนวราบ



รูปที่ 2.2 แสดงตำแหน่งและลักษณะของการวางบูลโฮลรีเลย์ (Buchholz Relay) ของหม้อแปลง

บูลโฮลรีเลย์นี้เป็นอุปกรณ์ตรวจหาและให้สัญญาณเมื่อมีปัญหาเกิดขึ้นภายในหม้อแปลงด้วยระบบเชิงกล (Mechanical) หลักการทำงานก็คือ เมื่อมี ฟอลต์เกิดขึ้นอย่างช้า ๆ ในหม้อแปลงซึ่งอาจเนื่องมาจากการลัดวงจรของขดลวด (Short turn) และส่งผลให้เกิดการอาร์ก จนเกิดความ

ร้อนสะสมขึ้นตรงบริเวณนั้นและในขดลวดด้วย ความร้อนดังกล่าวอาจสูงถึง  $350^{\circ}\text{C}$  จึงทำให้วัสดุฉนวน (Insulation material) ทั้งแข็งและเหลว เช่น น้ำมันหรือฉนวนกระดาษ เริ่มแตกตัวออกและเกิดเป็นแก๊สติดไฟออกมาได้ เช่น ไฮโดรเจน ไฮโดรคาร์บอน และคาร์บอนมอนอไซด์ หน้าต่างกระจกของบุลโสลรีเลย์ที่เห็นในรูปที่ 2.2 สามารถทำให้ทราบปริมาณแก๊สและคุณภาพรวมไปถึงสีของแก๊สที่เกิดขึ้นได้ แก๊สดังกล่าวนี้จะลอยผ่านน้ำมันหม้อแปลงขึ้นไปสะสมอยู่ตอนบนของหม้อแปลง ในลักษณะนี้จึงใช้บุลโสลรีเลย์เป็นอุปกรณ์ตรวจจับแก๊สที่เกิดขึ้นดังกล่าว แล้วจึงส่งสัญญาณให้แก่สวิตซ์ตัดตอน (Breaker)



รูปที่ 2.3 แสดงโครงสร้างภายในบุลโสลรีเลย์ (Buchholz Relay) ของหม้อแปลง



ในบุลโสลรีเลย์จะมีลูกลอยซึ่งมีสวิตซ์ชนิดปรอท (Mercury switch) ติดอยู่ และมีค้อนน้ำหนัก (Counter balance weight) ถ่วงลูกลอยไว้ อีกด้านหนึ่งดังแสดงในรูปที่ 2.3 อุปกรณ์ทั้งหมดนี้ปกติจะจมอยู่ในน้ำมัน น้ำหนักของลูกลอยจึงน้อย ค้อนน้ำหนักหนักกว่าก็จะกระดกลูกลอยไว้ เมื่อ

ค่อย ๆ มีแก๊สสะสมขึ้นและไปแทนที่น้ำมัน ระดับน้ำมันก็ต่ำลง เนื่องจากความดันของแก๊ส น้ำหนักลูกลอยจะเพิ่มขึ้นจนหนักกว่าตุ้มน้ำหนักอีกด้านหนึ่ง จึงกระดกให้สวิตช์ปรอททำงานและมีสัญญาณเตือน (ALARM) ส่งไปที่ห้องควบคุม (Control room) และศูนย์ควบคุมให้ผู้ควบคุม (Operator) ทราบ โดยทั่วไปปริมาตรของแก๊ส ที่กำหนดสำหรับหม้อแปลง 10 MVA. ขึ้นไปอยู่ระหว่าง 220 – 280 ตร.ม.<sup>3</sup> ในกรณีที่เกิดฟลัดตัวอย่างรุนแรงที่ขดลวดของหม้อแปลงอาร์กที่เกิดขึ้น จะทำให้เกิดแก๊สอย่างมากมาย (มากกว่า 50 ซม.<sup>3</sup>/กิโลวัตต์วินาที) เป็นเสริจด์ (surge) ในน้ำมันเคลื่อนไปดันใบพัด (Vane) กระดกครบวงจรและส่งสัญญาณให้แก่สวิตช์ตัดคอน (Breaker) ของหม้อแปลงไฟฟ้ากำลัง เพื่อปลดหม้อแปลงไฟฟ้ากำลังออกจากระบบส่งจ่ายกำลังไฟฟ้า

จากที่กล่าวมาข้างต้น สามารถสรุปได้ว่า บูลโฮลรีเลย์ทำงานได้สำหรับฟลัดชนิดไม่รุนแรงซึ่งไม่สามารถตรวจพบโดยรีเลย์ผลต่าง (Differential Relay) ได้ ซึ่งได้แก่ ฟลัดระหว่างรอบของขดลวด ฉนวนระหว่างแกนเหล็กกับสลักยึดแกนเหล็กชำรุดเกิดการลัดวงจรระหว่างแผ่นเหล็ก หรือ ขั้วต่อชำรุด เป็นต้น ฟลัดเหล่านี้ไม่จำเป็นต้องตัดวงจรทันทีทันใด อย่างไรก็ตามบูลโฮลรีเลย์สามารถตรวจพบเฉพาะฟลัดที่เกิดได้ระดับน้ำมันเท่านั้น และการกำหนด (Setting) ของบูลโฮลรีเลย์ไม่อาจตั้งให้ความไว (sensitive) เกินไป เพราะบูลโฮลรีเลย์อาจทำงานผิดพลาดเนื่องจากสาเหตุ เช่น การสั่นของหม้อแปลง แผ่นดินไหวและการสะท้อนของท่อน้ำมัน ฯลฯ


### 2.2.2 รีเลย์เปลี่ยนแปลงความดันทันที (Sudden Pressure Relay)

รีเลย์ชนิดนี้เหมาะกับหม้อแปลงชนิดปิดกันสมบูรณ์ (Sealed transformer) ปกติจะติดตั้งอยู่ที่ห้องก๊าซไนโตรเจน (Nitrogen Chamber) ข้างบนถังหม้อแปลงดังแสดงในรูปที่ 2.4 ถ้าเป็นหม้อแปลงชนิดใช้ถุงยาง (Diaphragm type) จะใช้รีเลย์ชนิดที่ทำงานด้วยการเปลี่ยนแปลงแรงดันน้ำมันทันที (Sudden-oil pressure relay)




รูปที่ 2.4 แสดงตำแหน่งและลักษณะของการวางรีเลย์เปลี่ยนแปลงความดันทันทีของหม้อแปลง

รีเลย์เปลี่ยนแปลงความดันทันทีจะทำงานเมื่อมีอัตราการเพิ่มขึ้นของความดันภายในหม้อแปลง กล่าวคือ ขณะหม้อแปลงใช้งานตามปกติ ถ้าความดันภายในหม้อแปลงเปลี่ยนแปลงช้าๆ รีเลย์จะไม่ทำงาน เพราะว่าความดันภายในถัง (Main Tank) ของหม้อแปลงกับความดันภายในตัวรีเลย์จะเท่ากัน โดยอาศัยท่อระบาย (Equalizer hole) ก๊าซไนโตรเจนจึงยังคงถ่ายเทได้สะดวกและน้ำมันยังคงสามารถไหลผ่านเข้าท่อระบาย (Equalizer hole) ได้ปกติ เมื่อเกิดการลัดวงจรภายใน (Internal fault) หม้อแปลงชนิดแห้งน้ำมันขึ้น แก๊สภายในถังหม้อแปลงสูงผิดปกติ แรงต้านทานของท่อระบาย (Equalizer hole) จะเพิ่มมากขึ้น ทำให้น้ำมันหรือแก๊สผ่านได้ช้าเนื่องจากท่อระบาย (Equalizer hole) จะขัดข้องถ่ายเทช้า ความดันภายในถังจะสูงขึ้นอย่างรวดเร็วอันเนื่องจากมีประกายไฟ (Arc) เกิดขึ้นในน้ำมัน ความดันในตัวรีเลย์จะน้อยกว่าความดันในถังหม้อแปลง ตัวสูบลม (Bellow) ดังรูปที่ 2.5(ก) จะขยายตัวดันสวิทช์เล็กๆ (micro-switch) ทำงาน ทำให้เกิดแรงดันที่แผ่นไดอะแฟรม (Diaphragm) ดังรูปที่ 2.5(ข) ปิดวงจรเพื่อสั่งปลดวงจร (Trip) เบรกเกอร์ของหม้อแปลง



(ก)



(ข)

รูปที่ 2.5 แสดงโครงสร้างภายในของรีเลย์เปลี่ยนแปลงความดันทันที (Sudden Pressure Relay)

รีเลย์ชนิดนี้มีโครงสร้างพิเศษกว่ารีเลย์ชนิดอื่นก็คือ ในสภาพปกติ แม้ความดันจะเปลี่ยนแปลงบ้างก็ตาม รีเลย์จะไม่ทำงานจนกว่าจะมีการเปลี่ยนแปลงความดันทันทีซึ่งหมายความว่า ภายในหม้อแปลงจะต้องมีเหตุการณ์ที่ผิดปกติเกิดขึ้นแล้ว นอกจากนี้ รีเลย์ชนิดนี้ยังมีความไวสูงกว่าชนิดอื่นมาก แรงดันที่ทำงานได้ตั้งไว้ที่ความดัน  $0.025 \text{ กก} / \text{ซม}^2$  และอัตราการความเร็วของแรงดันนี้จะเป็น  $0.0056 \text{ กก} / \text{ซม}^2 / \text{วินาที}$

### 2.2.3 รีเลย์ความร้อน (Thermal Relay)

รีเลย์ชนิดนี้ติดตั้งอยู่ด้านข้าง ภายนอกของหม้อแปลงที่มีที่กันสะเทือนและดินฟ้าอากาศ ภายนอกเป็นพิเศษ มีหน้าที่ตรวจจับอุณหภูมิของขดลวดที่ขึ้นไปถึงสูงสุด หรืออุณหภูมิของน้ำมัน หม้อแปลงและให้สัญญาณเตือน (ALARM) แก่ผู้ควบคุมเครื่องหรืออุปกรณ์ตัดตอน (Interrupt) หรือควบคุมเครื่องมีระบายความร้อน (Cooling Device) อย่างอัตโนมัติ ฉะนั้นจึงมีสวิตช์เล็กๆ (micro-switch) หลายตัวเพื่อสะดวกในการตั้ง ปกติจะตั้งที่อุณหภูมิ 63°, 75° และ 110° ถ้าเป็น อุณหภูมิของขดลวด และที่ อุณหภูมิ 55°, 65° และ 80° ถ้าเป็นอุณหภูมิของน้ำมันหม้อแปลง

## 2.3 การตรวจจับฟอลต์เชิงไฟฟ้า (Electrical Faults Detection)

โดยทั่วไปในขณะที่เกิดการลัดวงจรหรือฟอลต์ขึ้น ปริมาณกระแสจะเพิ่มขึ้นและแรงดันจะมี ขนาดลดลง การเปลี่ยนแปลงของกระแสและแรงดันนี้ จะส่งผลให้ปริมาณอื่นเปลี่ยนแปลงตามมา เช่น มุมเฟสของกระแสและแรงดัน ส่วนประกอบฮาร์มอนิกและความถี่ของระบบ เป็นต้น การ ทำงานของรีเลย์ป้องกันเชิงไฟฟ้านั้น จะใช้ปริมาณไฟฟ้าเหล่านี้เป็นสัญญาณที่ป้อนให้แก่รีเลย์ ระบบป้องกันด้านนี้จึงพอสรุปได้ดังนี้

### 2.3.1 การป้องกันแบบภาระเกิน (Overload protection) [10]

ระบบป้องกันชนิดนี้ อาศัยค่ากระแสที่เกินอัตราปกติ ป้อนให้แก่รีเลย์ เพื่อให้รีเลย์ส่งสัญญาณ เตือน (ALARM) หรือปลดวงจรตัดตอนออก ข้อสำคัญจึงมีอยู่ว่า รีเลย์กระแส (Current Relay) ชนิด นี้ จะต้องสามารถแบ่งแยกสัญญาณชนิดไหนเป็นกระแสที่เกิดจากลัดวงจรหรือภาระเกินชั่วขณะ ออกให้ได้ มิฉะนั้นจะได้ยินเสียงสัญญาณเตือนอยู่ตลอดเวลา โดยปกติกำหนด (Setting) ไว้ที่ 150% ของความสามารถสูงสุด (Maximum capacity) ของหม้อแปลง

### 2.3.2 การป้องกันแบบกระแสเกิน (Over current protection) [10]


ระบบป้องกันชนิดนี้มีวิธีป้องกันอยู่ 2 วิธี กล่าวคือ

1. ระบบฟิวส์ (Fuse) เป็นระบบป้องกันที่ใช้กับหม้อแปลงขนาดเล็ก ทุกครั้งที่เลือกใช้ ควร พิจารณาถึงคุณสมบัติของฟิวส์ ระหว่างกระแสที่ผ่านฟิวส์ และเวลาเป็นสัดส่วนผกผันกับ กระแสเหนี่ยวนำฟุ้งจะต้องไม่มีผลต่อฟิวส์
2. รีเลย์กระแสเกิน (Overcurrent Relay) รีเลย์ชนิดนี้มีไว้เพื่อป้องกันการลัดวงจรภายนอก โดยเฉพาะ ถ้าเป็นหม้อแปลงขนาดเล็ก จะใช้รีเลย์ชนิดนี้ป้องกันทั้งกรณีเกิดลัดวงจรภายใน และลัดวงจรภายนอกด้วย ปกติรีเลย์ชนิดนี้ จะทำหน้าที่เป็นเพียงรีเลย์สำรอง (Back up Relay) สำหรับรีเลย์ชนิดกระแสผลต่าง (Differential relay) ในการป้องกันการลัดวงจร ภายในหม้อแปลงของหม้อแปลงตัวใหญ่และเป็นรีเลย์พื้นฐานสำหรับการลัดวงจรภายนอก

โดยปกติกำหนด (Setting) ไว้ที่ 150% ของความสามารถสูงสุด (Maximum capacity) ของหม้อแปลง และมีการหน่วงเวลา (Time delay) เมื่อเกิดฟอลต์ทางด้านแรงดันต่ำเท่ากับ 2 วินาที (seconds) สำหรับรีเลย์กระแสเกินทางด้านแรงดันสูง ในขณะที่รีเลย์กระแสเกินทางด้านแรงดันต่ำมีการหน่วงเวลาเท่ากับ 1.5 วินาที

### 2.3.3 การป้องกันแบบกระแสดิน (Ground or Earth Fault protection) [10]

ในกรณีหม้อแปลงมีจุดนิวตรอน (Neutral) ของขดลวดสตาร์ (Y) ต่อลงดิน ถ้าพึ่งเฉพาะรีเลย์กระแสเกินนั้นยังมีอาจป้องกันการลัดวงจรภายในหม้อแปลงอย่างมีประสิทธิภาพได้ จึงต้องมีรีเลย์ชนิดนี้เพื่อทำหน้าที่คล้ายรีเลย์กระแสผลต่าง (Differential relay) ทำงานทันทีเมื่อเกิดการลัดวงจรของขดลวดภายในหม้อแปลงลงดินลักษณะของวงจรได้แสดงอยู่ในรูปที่ 2.6




รูปที่ 2.6 แสดงรีเลย์ป้องกันกระแสดิน [10]

### 2.3.4 การป้องกันแบบผลต่าง (Differential protection) [10]

เป็นรีเลย์ป้องกันแบบพื้นฐานที่จะต้องติดตั้งเพื่อป้องกันความเสียหายที่จะเกิดขึ้นกับหม้อแปลง (โดยทั่วไปมีขนาดมากกว่า 5 MVA) โดยความเสียหายที่รีเลย์ป้องกันแบบผลต่างต้องทำการป้องกันนั้นคือ ความเสียหายที่เกิดขึ้นในตัวหม้อแปลง หรือในโซน (zone) เท่านั้น ดังนั้นตัวของรีเลย์ป้องกันแบบผลต่างจะต้องแยกแยะระหว่างฟอลต์ที่เกิดขึ้นภายใน (Internal Fault) และฟอลต์ที่เกิดขึ้นภายนอก (External or Non-Internal Fault) ของตัวหม้อแปลงให้ออก โดยที่รีเลย์จะสั่งทริปในทุก ๆ กรณีของฟอลต์ที่เกิดขึ้นภายใน (Internal Fault) และจะต้องไม่ทำงาน (Block) ในกรณีที่ไม่ใช่ฟอลต์ที่เกิดขึ้นภายใน

หลักการการทำงานของรีเลย์ชนิดนี้ คือ ตรวจสอบความแตกต่าง (Different) ของกระแสที่ไหลเข้าและออกจากอุปกรณ์ที่รีเลย์ป้องกันอยู่ ถ้าแตกต่างกันน้อยไม่เกินค่าที่กำหนดไว้ (Setting) ซึ่งมักจะกำหนด (Set) ไว้ประมาณ 30% ของกระแสพิกัด (Rated Current) ของรีเลย์ ซึ่งไม่สูงมากนัก จะถือว่าไม่มีการลัดวงจรในอุปกรณ์นั้น เมื่อนำมาใช้กับหม้อแปลง ก็คือการตรวจจับกระแสทางด้านแรงดันสูงและแรงดันต่ำของหม้อแปลงนั่นเอง เนื่องจากรีเลย์ชนิดนี้นำกระแสมาจากหม้อแปลงกระแส (CT) ทั้ง 2 ด้านของหม้อแปลง ดังนั้นตำแหน่งของหม้อแปลงกระแส (CT) จึงเป็นตัวกำหนดโซน (Zone) และทำงานของรีเลย์ และสิ่งนี้เป็นข้อได้เปรียบของรีเลย์ชนิดนี้ต่อรีเลย์ป้องกันเชิงกล เช่น บูล โสไลรีเลย์ รีเลย์เปลี่ยนแปลงความดันทันที เป็นต้น เนื่องจากรีเลย์ชนิดนี้สามารถตรวจจับการลัดวงจรบริเวณกว้างกว่ารีเลย์ป้องกันเชิงกลที่จะเห็นการลัดวงจรหรือฟอลต์เฉพาะที่เกิดในหม้อแปลงเท่านั้น แต่อย่างไรก็ดี เนื่องจากหลักการการทำงานของรีเลย์ชนิดนี้เป็นการตรวจสอบความแตกต่างของกระแสที่ไหลผ่านหม้อแปลงทั้ง 2 ด้าน ดังนั้น จึงไม่สามารถใช้รีเลย์ชนิดนี้ป้องกันการจ่ายโหลดเกิน (Overload) ของหม้อแปลงได้


รีเลย์ป้องกันหม้อแปลงที่ใช้ในปัจจุบันไม่ว่าจะเป็นรีเลย์ของ ABB Siemens หรือ SEL จะใช้หลักการเปอร์เซ็นต์กระแสผลต่าง (Percentage Differential Current) สำหรับตรวจสอบสถานะฟอลต์ที่เกิดขึ้นว่าเป็นฟอลต์ที่เกิดขึ้นภายในหรือภายนอกบริเวณที่ป้องกัน ซึ่งจะมีวงจรของการทำงานดังรูปที่ 2.7



รูปที่ 2.7 แสดงวงจรของรีเลย์ป้องกันหม้อแปลงที่ใช้หลักการของเปอร์เซ็นต์กระแสผลต่าง

จากรูปที่ 2.7 ในกรณีที่กระแสไหลเข้าหม้อแปลงมีค่าเท่ากับกระแสที่ไหลออกจากหม้อแปลงนั้น หมายความว่า กระแสที่ได้จากหม้อแปลงกระแสที่ต่อต้านปฐมภูมิ ( $I_1$ ) จะมีค่าเท่ากับกระแสที่ได้จากหม้อแปลงกระแสด้านทุติยภูมิ ( $I_2$ ) ดังนั้นกระแสที่ไหลผ่านรีเลย์ป้องกันจะมีค่าเป็นศูนย์ หากกำหนดให้ค่ากระแสผลต่างระหว่างปฐมภูมิและทุติยภูมิมีค่าเป็น  $I_d$  นั้นหมายความว่า  $I_d$  มีค่าเป็นศูนย์ ซึ่งในทางทฤษฎีจะหมายความว่า ไม่มีฟอลต์ภายในเกิดขึ้น

แต่ในทางปฏิบัติ แม้ว่าอยู่ในสถานะที่ไม่ได้เกิดฟอลต์ภายในขึ้นค่ากระแส  $I_d$  อาจมีค่าไม่เท่ากับศูนย์ ทั้งนี้เนื่องจากผลของค่าความผิดพลาดที่ไม่เท่ากันของหม้อแปลงกระแสทั้งสองด้าน (Current Transformer Error) ค่าอัตราส่วนที่ต่างกันของหม้อแปลงกระแสทั้งสองด้าน (Current Transformer Mismatch Ratio) และตำแหน่งของ On-Load Tap Changer ซึ่งจะมีผลให้มีกระแสจำนวนหนึ่งไหลผ่านรีเลย์ป้องกัน ดังนั้น รีเลย์ป้องกันจึงต้องมีคุณสมบัติที่เรียกว่า ความชัน (Slope) ขึ้นมา โดยทั่วไปแล้วรีเลย์ป้องกันหม้อแปลงที่ใช้กันอยู่จะมีการนำค่ากระแสไหลผ่าน (Through Current) หรือกระแสไบอัส (Bias Current) มาเป็นสัดส่วนร่วมในการตัดสินใจในการสั่งปลดวงจร แทนการพิจารณาแต่กระแสผลต่างอย่างเดียว ดังที่ได้แสดงไว้ในรูปที่ 2.8 หลักการตัดสินใจสั่งปลดวงจรดังกล่าวต้องอาศัยการตั้งค่าเซตติง (Setting Values) อัตราส่วนระหว่างกระแสผลต่างต่อกระแสไบอัส รีเลย์จะทำงานก็ต่อเมื่อ ค่าอัตราส่วนระหว่างกระแสผลต่างต่อกระแสไบอัสจริงในขณะนั้นมีค่ามากกว่าค่าที่ได้ตั้งไว้



รูปที่ 2.8 แสดงเส้นคุณลักษณะของรีเลย์ที่ใช้หลักการเปอร์เซ็นต์ กระแสผลต่าง

จากที่กล่าวมา ได้กล่าวถึงวิธีการใช้หลักการของเปอร์เซ็นต์กระแสผลต่างในการตรวจสอบป้องกันฟอลต์ภายในหม้อแปลง อย่างไรก็ตามรีเลย์ที่ใช้หลักการดังกล่าวยังมีข้อผิดพลาดในการสั่งปลดวงจรหากรูปคลื่นที่วัดเข้ามาเกิดการผิดเพี้ยน เช่น ในกรณีที่เกิดฟอลต์ภายนอกพื้นที่ป้องกัน

โดยรูปคลื่นด้านปฐมภูมิของหม้อแปลงที่ทำการป้องกันเกิดการผิเคเพิ่มขึ้นอันเนื่องมาจากการอิ่มตัวของแกนเหล็กไม่ว่าจะเป็นการอิ่มตัวจากผลของกระแสสลับ (AC Saturation) หรืออิ่มตัวจากผลของกระแสตรง (DC Saturation) จนทำให้เกิดค่าอัตราส่วนของกระแสผลต่างต่อกระแสไบอัสเกินกว่าค่าที่กำหนดไว้ (Setting) ไว้จนทำให้รีเลย์สั่งปลดวงจร

อีกกรณีที่สามารถทำให้เกิดการผิดพลาดในการสั่งปลดวงจรก็คือ กรณีเกิดฟอลต์ภายในพื้นที่ป้องกัน ชนิดที่ค่าอิมพีแดนซ์สูง (High Impedance Internal Fault) หรือฟอลต์ขดลวดลงดินภายในหม้อแปลง (Winding to ground fault) บริเวณช่วงปลายๆ ขดลวดหรือเกิดฟอลต์ระหว่างขดลวดภายในหม้อแปลง (Interturn fault) ซึ่งจะมีผลต่างกระแสไม่มากนัก จนมีผลทำให้ไม่สามารถตรวจพบได้ทั้งนี้เนื่องจากการกำหนดค่าที่กำหนดไว้ (Setting) ของค่าอัตราส่วนของกระแสผลต่างต่อกระแสไบอัส จำเป็นต้องเผื่อค่าของอัตราส่วนการแปลงที่ไม่เท่ากันระหว่างหม้อแปลงกระแสที่อยู่ทั้งด้านปฐมภูมิและด้านทุติยภูมิ หรือค่าอัตราส่วนที่ต่างกันของหม้อแปลงกระแสทั้งสองด้าน (Current Transformer Mismatch Ratio) และต้องเผื่อค่าความผิดพลาดที่ไม่เท่ากันของหม้อแปลงกระแสทั้งสองด้าน (Current Transformer Error) รวมทั้งการเปลี่ยนของกระแสด้านปฐมภูมิที่อาจจะสูงขึ้นหรือต่ำลงอันเนื่องมาจากผลของการเปลี่ยนแทปของหม้อแปลง

จากที่กล่าวมาข้างต้น เป็นการกล่าวถึงรูปแบบของการวิเคราะห์สัญญาณบนพื้นฐานของรีเลย์ป้องกันแบบเดิม พบว่าเป็นการวิเคราะห์เพื่อพิจารณาการเปลี่ยนแปลงของนำองค์สัญญาณองค์ประกอบความถี่พื้นฐานมาใช้งานเป็นหลัก นอกจากนี้เมื่อพิจารณาสัญญาณฟอลต์พบว่านอกจากจะมีการเปลี่ยนแปลงขององค์ประกอบความถี่พื้นฐานแล้วยังมีการเปลี่ยนแปลงขององค์ประกอบความถี่ที่สูงกว่ารวมอยู่และยังให้ข้อมูลที่สำคัญเกี่ยวกับฟอลต์อีกด้วย ซึ่งถ้าสามารถนำการเปลี่ยนแปลงขององค์ประกอบความถี่สูงที่เกิดขึ้นมาพิจารณาในวิทยานิพนธ์ฉบับนี้จึงได้มุ่งเน้นการวิเคราะห์สัญญาณฟอลต์บนพื้นฐานขององค์ประกอบความถี่สูง และจากลักษณะของสัญญาณองค์ประกอบความถี่สูงที่มีการเปลี่ยนแปลงที่รวดเร็วจึงสามารถที่จะทำให้ลดช่วงของข้อมูลที่ใช้ในการวิเคราะห์ได้ โดยจะช่วยลดเวลาในการวิเคราะห์และตัดสินใจซึ่งสามารถนำไปสู่แผนการป้องกันแบบใหม่และสอดคล้องกับทิศทางการพัฒนารีเลย์ในรูปแบบใหม่

## บทที่ 3

# การแปลงเวฟเล็ต

ในทุกหนทุกแห่งรอบๆ ตัวเราประกอบไปด้วยสัญญาณต่างๆ มากมายที่มนุษย์นำมาใช้ในการวิเคราะห์ เช่น การสั่นของแผ่นดินไหว เสียงพูดของมนุษย์ การสั่นของเครื่องยนต์ และการจัดสัญญาณรบกวน เป็นต้น การวิเคราะห์สัญญาณต่างๆ เหล่านี้จะใช้ทฤษฎีเวฟเล็ตเป็นเครื่องมือสำหรับอธิบายลักษณะโดยทั่วไปของสัญญาณซึ่งมีความสำคัญต่อสาขาการประมวลผลสัญญาณมาก ในบทนี้เป็นการอธิบายหลักการของเวฟเล็ต โดยจะกล่าวถึงประวัติของเวฟเล็ต ทฤษฎีพื้นฐานของการแปลงเวฟเล็ต เวฟเล็ตแม่ รวมไปถึงคุณสมบัติของการแยกวิเคราะห์แบบหลายระดับความละเอียด (Multi Resolution Analysis : MRA) ของการแปลงเวฟเล็ต ซึ่งทำให้เกิดขบวนการแยกวิเคราะห์ (Decomposition) และการรวมกลับ (Reconstruction) ซึ่งเป็นการนำการแปลงเวฟเล็ตมาประยุกต์ใช้ในการวิจัย

### 3.1 ประวัติของเวฟเล็ต (History of Wavelets)

ตามประวัติศาสตร์การวิเคราะห์เวฟเล็ตเป็นวิธีการใหม่โดยโครงสร้างรากฐานทางคณิตศาสตร์ของเวฟเล็ตมีที่มาจากแปลงฟูเรียร์ซึ่งเป็นผลงานของ Joseph Fourier ในศตวรรษที่ 19 ด้วยเหตุที่ฟูเรียร์อยู่บนพื้นฐานของทฤษฎีการวิเคราะห์ความถี่ จึงทำให้การพิสูจน์มีความสำคัญและมีอิทธิพลเป็นอย่างมากต่อที่มาของการแปลงเวฟเล็ต

บันทึกครั้งแรกที่อ้างถึงเทอม “เวฟเล็ต” คือในปี ค.ศ. 1909 ในงานวิทยานิพนธ์ของ Alfred Harr แนวคิดของเวฟเล็ตในรูปแบบที่แสดงตามทฤษฎี ถูกเสนอขึ้นครั้งแรกโดย Jean Morlet และ คณะที่ Marseille Theoretical Physics Center ที่ทำงานภายใต้ Alex Grossmann ในประเทศฝรั่งเศส

ทฤษฎีของการวิเคราะห์เวฟเล็ตที่ได้ถูกพัฒนาหลักสำคัญโดย Y. Meyer และเพื่อนร่วมงานได้ถูกรับรองโดยทฤษฎีการแพร่ หลักการของทฤษฎีนี้ได้ถูกนำมาประยุกต์ใช้ในงานของ Stephane Mallat ในปี ค.ศ. 1988 จากนั้นมา งานวิจัยเวฟเล็ตจึงได้กลายเป็นระดับประเทศ โดยเฉพาะอย่างยิ่งงานวิจัยในสหรัฐอเมริกา ซึ่งนำทีมโดยงานของนักวิทยาศาสตร์ เช่น Ingrid Daubechies, Ronald Coifman และ Victor Wickerhauser

จากประวัติความเป็นมาของการแปลงเวฟเล็ตโดยสังเขปที่ได้กล่าวมาข้างต้น ในหัวข้อต่อไปนี้จะกล่าวถึงวิวัฒนาการของทฤษฎีพื้นฐานของการวิเคราะห์สัญญาณ ซึ่งก็คือการแปลงฟูเรียร์ จนกระทั่งมาเป็นทฤษฎีการแปลงเวฟเล็ตว่ามีความเป็นมาอย่างไรเกิดปัญหาอะไรจึงต้องมีทฤษฎีเวฟเล็ต

## 3.2 ทฤษฎีพื้นฐานของการแปลงเวฟเล็ท

การแปลงเวฟเล็ทเป็นรูปแบบหนึ่งของกระบวนการประมวลผลสัญญาณ (Signal processing) ที่ได้มีการพัฒนามาจากการแปลงสัญญาณพื้นฐานที่มีอยู่เดิม แต่ได้พัฒนารูปแบบให้มีความเหมาะสมกับการใช้งานเฉพาะทางมากยิ่งขึ้น ในหัวข้อนี้จะเป็นการอธิบายความหมายและความแตกต่างของการแปลงเวฟเล็ทกับการแปลงสัญญาณในแบบอื่นๆ ที่เกี่ยวข้อง เพื่อเป็นพื้นฐานในการทำความเข้าใจและนำไปใช้งานต่อไป

### 3.2.1 การแปลงฟูรีเยร์ (Fourier transform : FT)

เครื่องมือสำหรับการวิเคราะห์สัญญาณซึ่งเป็นที่รู้จักโดยทั่วไปและนิยมใช้กันอย่างแพร่หลาย เป็นการแยกสัญญาณออกเป็นส่วนประกอบของสัญญาณ Sinusoids โดยเป็นการแปลงสัญญาณจากโดเมนเวลา (Time-domain) ไปเป็นโดเมนความถี่ (Frequency-domain) หรือที่เรียกกันโดยทั่วไปว่าเป็นการหาสเปกตรัม (Spectrum) ของสัญญาณนั่นเอง บางครั้งสามารถกล่าวได้ว่าเป็นการวิเคราะห์สัญญาณโดยอาศัยฟังก์ชันพื้นฐาน (basic function) ในรูปของฟังก์ชันเอกซ์โพเนนเชียล ผลการวิเคราะห์จะออกมาในรูปของการแตกองค์ประกอบของสัญญาณใดๆ ให้อยู่ในรูปของฟังก์ชันโคไซน์และไซน์ที่มีขนาดและความถี่ที่แตกต่างกันตลอดย่านความถี่  $-\infty$  ถึง  $\infty$  ดังแสดงในสมการที่ 3.1 [11]

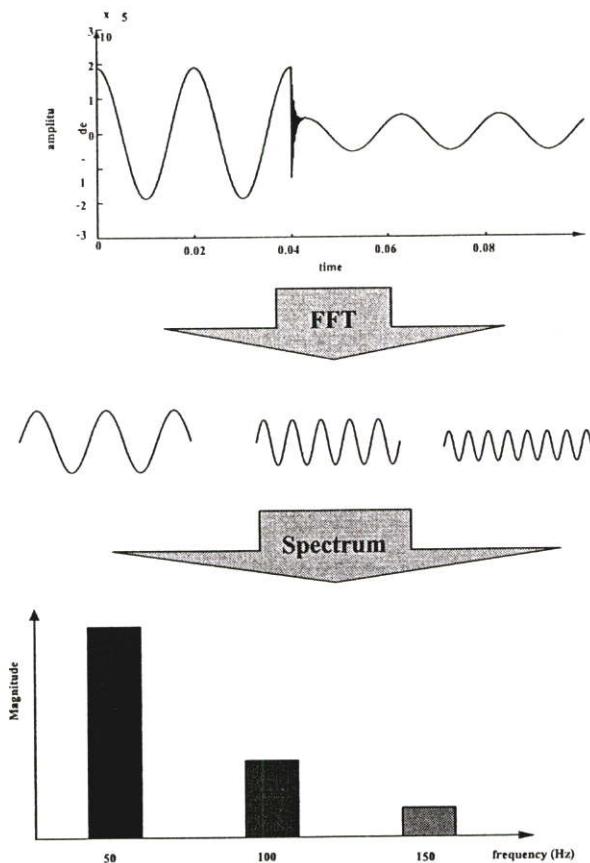
$$F(\omega) = \int_{-\infty}^{\infty} f(t) e^{-j\omega t} dt \quad (3.1)$$

ซึ่งมีสมการในเทอมของการวิเคราะห์ข้อมูลแบบสุ่ม (sampling data) ที่เรียกว่า การแปลงฟูรีเยร์แบบเร็ว (Fast Fourier Transform : FFT) ดังสมการที่ 3.2 [11]

$$F(n) = \sum_{k=0}^{N-1} f(k) \cdot e^{-\left(\frac{j 2\pi kn}{N}\right)} \quad (3.2)$$

เมื่อ  $n = 1, 2, \dots, N$

การวิเคราะห์ฟูรีเยร์ มีข้อเสียที่สำคัญในการเปลี่ยนมาอยู่ในโดเมนของความถี่ ซึ่งจะทำให้รายละเอียดข้อมูลแบบเวลาจะสูญเสียไป เมื่อมองเป็นการแปลงสัญญาณของฟูรีเยร์ ทำให้เป็นไปได้ที่จะบอกว่าเมื่อไร (When) ที่รายละเอียดของเหตุการณ์จะปรากฏขึ้น



รูปที่ 3.1 แสดงการแปลงฟูเรียร์ (FFT)

เนื่องจากการแปลงฟูเรียร์เป็นการแปลงสัญญาณจากโดเมนเวลาไปเป็นโดเมนความถี่ ซึ่งผลลัพธ์ที่ได้จากการแปลงจะมีจำนวนข้อมูลเป็นอนันต์ ดังนั้นเมื่อเกิดการเปลี่ยนแปลงของสัญญาณอินพุทที่ช่วงเวลาใดๆ ก็จะส่งผลทำให้สเปกตรัมของสัญญาณตลอดย่านความถี่เปลี่ยนไป หรือทำให้สัมประสิทธิ์ของการแปลงเปลี่ยนไปนั่นเอง นอกจากนี้การใช้การแปลงฟูเรียร์ยังไม่สามารถเลือกทำการวิเคราะห์สัญญาณเฉพาะช่วงเวลาหรือเฉพาะช่วงความถี่ใดๆ ได้ ดังนั้นการวิเคราะห์ด้วยการแปลงฟูเรียร์จึงเหมาะสมสำหรับวิเคราะห์สัญญาณที่มีลักษณะเป็นคาบเวลาที่แน่นอน (Stationary signal) แต่ข้อจำกัดของการแปลงฟูเรียร์คือ ในกรณีที่สัญญาณมีการเปลี่ยนแปลงไม่คงที่ (Non-stationary signal) เช่น สัญญาณ ทรานเซียนต์รูปแบบต่างๆ ถ้าใช้การแปลงฟูเรียร์จะทำให้สิ้นเปลืองเวลาในการคำนวณเพราะต้องคำนวณใหม่ตลอดทั้งย่าน ข้อมูลจะมีมากเกินไปจนทำให้การคำนวณใหม่ในแต่ละครั้ง ทำให้การวิเคราะห์ด้วยการแปลงฟูเรียร์จะมีความผิดพลาดเกิดขึ้นรวมทั้งข้อมูลทางด้านเวลาที่ขาดหายไป ซึ่งข้อมูลทางด้านเวลาเป็นสิ่งที่สำคัญมากในการวิเคราะห์สัญญาณในลักษณะทรานเซียนต์

### 3.2.2 การแปลงกาบอร์ (Gabor Transform : GT)

เป็นการแปลงสัญญาณที่ได้พัฒนาขึ้นเป็นแบบแรกเพื่อแก้ปัญหาของการแปลงฟูเรียร์ โดยทำการแปลงฟูเรียร์เฉพาะช่วงเวลาและช่วงความถี่ที่กำหนดผ่านฟังก์ชันหน้าต่าง (Windows function) ซึ่งจะเป็นลักษณะของฟังก์ชันแบบเกาส์เซียน (Gaussian function) ซึ่งแสดงอยู่ในสมการที่ 3.3 [12]

$$g_a(t) = \frac{1}{2\sqrt{\pi a}} e^{-\frac{t^2}{4a}} \quad (3.3)$$

ซึ่งมีสมการการแปลงกาบอร์ดังนี้ [11]

$$(G_b^a f)(\omega) = \int_{-\infty}^{\infty} e^{-j\omega t} f(t) g_a(t - b) dt \quad (3.4)$$

จากสมการที่ 3.4 เป็นสมการของการแปลงกาบอร์จะเห็นได้ว่าการแปลงในรูปแบบนี้สามารถเลือกตำแหน่งในการวิเคราะห์ได้โดยการกำหนดพารามิเตอร์  $b$  ซึ่งจะให้ผลของข้อมูลทางเวลา และเลือกช่วงความถี่ด้วยพารามิเตอร์  $a$  แต่เนื่องจากการแปลงกาบอร์ให้ฟังก์ชันหน้าต่างแบบเดียว จึงอาจจะไม่เหมาะสมกับการประยุกต์ใช้งานในการวิเคราะห์สัญญาณในทุกรูปแบบได้

### 3.2.3 การแปลงฟูเรียร์ช่วงเวลาสั้น (Short – Time Fourier Transform : STFT)


จากข้อจำกัดของการแปลงฟูเรียร์และการแปลงกาบอร์ จึงมีการพัฒนารูปแบบการวิเคราะห์สัญญาณมาสู่การแปลงฟูเรียร์ช่วงเวลาสั้น ซึ่งเป็นการวิเคราะห์ที่ใช้ฟังก์ชันหน้าต่างเหมือนการแปลงกาบอร์ แต่สามารถเลือกฟังก์ชันหน้าต่างที่ใช้ได้จึงทำให้มีความยืดหยุ่นในการวิเคราะห์สัญญาณมากยิ่งขึ้น สมการการแปลงฟูเรียร์ช่วงเวลาสั้นสามารถแสดงได้ดังสมการที่ 3.5 [13]

$$STFT(f, \tau) = \int_{-\infty}^{\infty} x(t) w(t - \tau) e^{-j2\pi f t} dt \quad (3.5)$$

เมื่อ

$w(t - \tau)$  = ฟังก์ชันหน้าต่าง (Window function) ที่ใช้ในการวิเคราะห์

โดยที่ตำแหน่งเวลาในการวิเคราะห์ถูกกำหนดโดยค่า  $\tau$  และช่วงความถี่ในการวิเคราะห์กำหนดด้วยความถี่หรือความกว้างของฟังก์ชันหน้าต่างนั้นๆ ผลการวิเคราะห์จะอยู่ในรูปของการแตกองค์ประกอบสัญญาณในลักษณะการแปลงฟูเรียร์ในช่วงเวลาที่ทำการวิเคราะห์ดังแสดงในรูปที่ 3.2

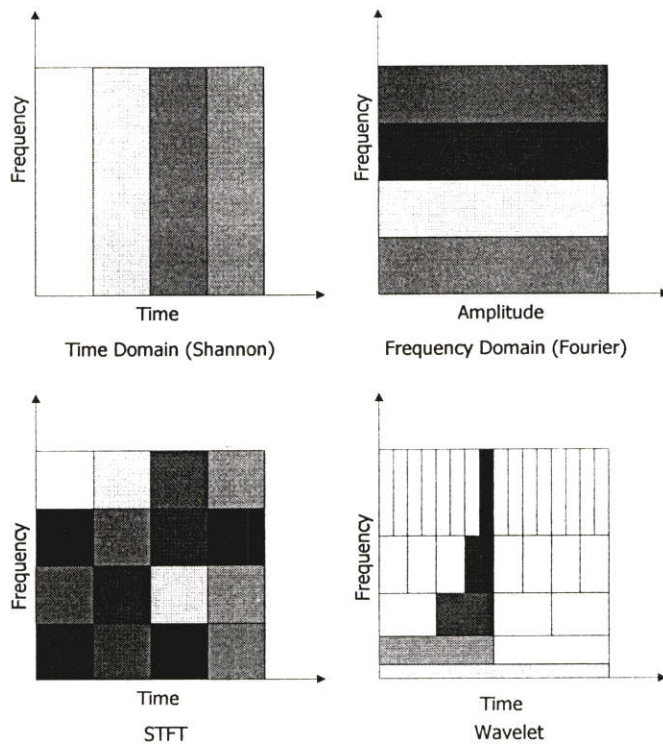


รูปที่ 3.2 แสดงการแปลงฟูเรียร์ช่วงเวลาสั้น (STFT)

การวิเคราะห์ฟูเรียร์ในช่วงเวลาสั้น แสดงชนิดของการผสมกันของการมอดูเลชันในแกนเวลาและความถี่ โดยให้รายละเอียดทั้งเวลาและความถี่ของสัญญาณที่เกิดขึ้น อย่างไรก็ตามจะสังเกตได้ว่า ทั้งการแปลงกabor และการแปลงฟูเรียร์ช่วงเวลาสั้น มีลักษณะของช่วงเวลาการวิเคราะห์ที่คงที่ (Fixed resolution transform) ดังนั้นการใช้ช่วงการวิเคราะห์สัญญาณที่คงที่ในการวิเคราะห์สัญญาณต่างๆ ช่วงความถี่จึงอาจไม่เหมาะสมในทางปฏิบัติ เนื่องจากสัญญาณที่มีความถี่สูงจะมีการเปลี่ยนแปลงที่รวดเร็วกว่าจึงควรจะใช้ช่วงเวลาที่เหมาะสมในการวิเคราะห์ ในขณะที่สัญญาณที่มีความถี่ต่ำจะมีการเปลี่ยนแปลงที่ช้าจึงควรจะใช้ช่วงเวลาที่ยาวกว่าในการวิเคราะห์ เมื่อวิเคราะห์ด้วยการแปลงฟูเรียร์ช่วงเวลาสั้น อาจจะทำให้ข้อมูลที่ได้อาจมีจำนวนมากหรือน้อยเกินไป จากเหตุผลนี้จึงได้มีการพัฒนารูปแบบการวิเคราะห์สัญญาณที่มีการปรับระดับความละเอียดในการวิเคราะห์ซึ่งเรียกว่า “การแปลงเวฟเลต” ซึ่งความหมายและรูปแบบทางทฤษฎีของเวฟเลตนั้นได้แสดงอยู่ในหัวข้อถัดไป

### 3.3 การแปลงเวฟเลต (Wavelet Transform : WT) [14-16]


การแปลงเวฟเลตเป็นรูปแบบหนึ่งของกระบวนการประมวลผลสัญญาณ (Signal processing) ที่ได้มีการพัฒนามาจากการแปลงสัญญาณพื้นฐานที่มีอยู่เดิม (การแปลงฟูเรียร์และการแปลงฟูเรียร์ช่วงสั้น) แต่ได้พัฒนารูปแบบให้มีความเหมาะสมกับการใช้งานเฉพาะทางมากยิ่งขึ้น กล่าวคือ สามารถปรับเปลี่ยนขนาดหน้าต่าง (windows) ได้ หรือกล่าวอีกนัยหนึ่งคือ สามารถปรับเปลี่ยนช่วงเวลาให้เหมาะกับช่วงความถี่ที่จะวิเคราะห์ได้ โดยที่สัญญาณความถี่สูงจะมีช่วงคาบเวลาในการวิเคราะห์ที่น้อยลง ในขณะที่สัญญาณความถี่ต่ำจะมีช่วงคาบเวลาในการวิเคราะห์ที่กว้างขึ้น ดังรูปที่ 3.3 จะเป็นการเปรียบเทียบเวลาและความถี่ของสัญญาณของแต่ละรูปแบบการวิเคราะห์



รูปที่ 3.3 แสดงลักษณะของระนาบเวลาและความถี่สำหรับการวิเคราะห์สัญญาณ [16]

#### 3.3.1 ทฤษฎีเวฟเลต (Wavelet Theory)

ทฤษฎีเวฟเลต (Wavelet Theory) เป็นรูปแบบทางคณิตศาสตร์ที่ใช้อธิบายโครงสร้างของระบบสัญญาณที่ประกอบด้วยกลุ่มของสัญญาณเฉพาะมารวมกันเป็นสัญญาณหนึ่ง โดยสัญญาณเฉพาะนี้จะเป็นคลื่นเล็กๆ ที่เรียกว่า “เวฟเลต” ลักษณะของเวฟเลตจะเป็นคลื่นที่มีการเปลี่ยนแปลงอย่างต่อเนื่อง (Oscillatory) ตามแนวแกนอนและขนาดของคลื่นจะลดลงสู่ศูนย์ทั้งทางด้านบวกและด้านลบอย่างรวดเร็วดังรูปที่ 3.4



รูปที่ 3.4 แสดงลักษณะของคลื่นเวฟเลตแบบ Morlet [15]

ดังนั้นการอธิบายสัญญาณใดๆ ด้วยการแปลงเวฟเลตคือการนำกลุ่มของเวฟเลตที่มีโครงสร้างมาจากฟังก์ชันเดียวกันเป็นตัวอธิบาย ซึ่งฟังก์ชันนี้จะเป็นเวฟเลตต้นกำเนิดที่เรียกว่า “เวฟเลตแม่” (Mother Wavelets) โดยที่คลื่นเวฟเลตแต่ละอันในกลุ่มจะเกิดจากการสเกล (Scaling :  $a$ ) หรือเป็นการยืดหรือหดตัวของเวฟเลตแม่นั้นเอง และการเลื่อนตำแหน่ง (Translation or shifting :  $k$ ) ซึ่งเป็นการเปลี่ยนตำแหน่งบนแกนเวลา

เพื่อให้เกิดความเข้าใจมากยิ่งขึ้น โดยเทียบกับระบบกล้องดูดาว ถ้าให้ท้องฟ้าเป็นสัญญาณอินพุตและเลนส์เป็นเวฟเลตแม่ ในกรณีที่ต้องการดูภาพท้องฟ้าทั้งหมด โดยไม่ต้องมีการเลื่อนตำแหน่งของกล้อง จำเป็นจะต้องใช้โฟกัสที่หยาบมาก เพื่อให้ได้ภาพที่ครอบคลุมท้องฟ้าทั้งหมด ซึ่งภาพที่ได้จะไม่มีรายละเอียดอะไรเลย แต่ถ้าทำการซูม (สเกล) เข้าไป จะทำให้เห็นรายละเอียดต่างๆ ของท้องฟ้ามากขึ้น เช่น กลุ่มดาวกาแล็กซี ฯลฯ แต่ก็เห็นรายละเอียดเป็นบางส่วนของท้องฟ้า ถ้าต้องการเห็นท้องฟ้าทั้งหมดก็ต้องทำการเลื่อนกล้องไปยังตำแหน่งต่างๆ ยิ่งถ้าต้องการรายละเอียดของท้องฟ้ามากขึ้นเท่าไร ก็จะต้องมีการซูมลึกเข้าไป และจะต้องเลื่อนตำแหน่งของกล้องละเอียดมากยิ่งขึ้นจึงจะได้ภาพท้องฟ้าทั้งหมด


ดังนั้นภาพแต่ละภาพก็จะเป็นสัมประสิทธิ์ของการแปลงเวฟเลต ที่พิจารณาผ่านเลนส์ หรือเวฟเลตแม่ที่มีค่าการสเกล (Scaling) (โฟกัส หรือความละเอียด) และตำแหน่งการมองดู (Translation) ในขณะนั้น ถ้านำเซตของภาพทั้งหมดที่ตำแหน่งของ  $a$  และ  $k$  ต่างๆ กันมารวมกันจะเป็นภาพท้องฟ้าได้ (หมายถึงนำสัญญาณเล็กๆ ที่ระดับความละเอียด  $a$  ซึ่งมี  $k$  หลายๆ ตำแหน่งมารวมกัน จะเกิดสัญญาณอินพุตที่ระดับความละเอียดนั้น เมื่อนำสัญญาณอินพุตที่ทุกความละเอียดมารวมกันก็จะได้เป็นสัญญาณอินพุตจริง)

ถ้าให้  $\psi(t)$  เป็นฟังก์ชันเวฟเลตแม่จะสามารถเขียนสมการแสดงความสัมพันธ์ของพจน์ต่างๆ ได้ดังนี้

$\psi(t)$  เป็นฟังก์ชันเวฟเล็ดแม่ที่มีการปรับเปลี่ยนสเกลและตำแหน่งโดยพารามิเตอร์  $a$  และ  $k$  ตามลำดับ โดยที่เวฟเล็ดแม่จะมีการเปลี่ยนแปลงลักษณะไปตามการเปลี่ยนแปลงของค่า  $a$  และ  $k$  แต่ยังคงอยู่ในเซตหรือมีความสัมพันธ์กับเวฟเล็ดแม่เดิมอยู่ดังแสดงในรูปที่ 3.8 และเพื่อให้เวฟเล็ดที่ถูกสเกลไปมีพลังงานเท่ากับเวฟเล็ดแม่จึงต้องทำการนอร์มัลไลซ์ (Normalize) ด้วย  $\frac{1}{\sqrt{a}}$  เสมอ เพื่อให้เห็นภาพจนได้ชัดเจนยิ่งขึ้น จะขออธิบายถึงเวฟเล็ดที่มีการสเกลและเลื่อนตำแหน่งดังนี้


### 3.3.2 การสเกล (Scaling : a)

การวิเคราะห์เวฟเล็ดจะแสดงให้เห็นถึงเวลาและขนาดของสัญญาณ การสเกล (Scaling) จะหมายถึงการหดเข้า (Compressing) หรือการขยายออก (Dilation) ซึ่งเราจะให้ “ $a$ ” แทนด้วยพารามิเตอร์ของการหดหรือขยายซึ่งจะเป็นการเปลี่ยนความถี่ของเวฟเล็ดแม่นั้นเอง หรืออาจเรียก “ $a$ ” ว่าเป็นตัวประกอบขนาด (scale factor) และถ้าพิจารณาสัญญาณไซน์ที่มีตัวประกอบขนาดแตกต่างกันจะมีลักษณะดังแสดงในรูปที่ 3.5



รูปที่ 3.5 แสดง คุณสมบัติการสเกลของสัญญาณไซน์ [15]


ตัวประกอบขนาด ( $a$ ) จะมีผลในทางเดียวกันกับเวฟเล็ด ยิ่งถ้าตัวประกอบขนาดน้อยลงเท่าใด เวฟเล็ดจะถูกบีบอัดมากขึ้นเท่านั้น เมื่อพิจารณาเวฟเล็ดที่มีตัวประกอบแตกต่างกันจะปรากฏลักษณะดังแสดงในรูปที่ 3.6



รูปที่ 3.6 แสดงคุณสมบัติการสเกลของฟังก์ชันเวฟเล็ต [15]

### 3.3.3 การเลื่อนตำแหน่ง (Translation or shifting : k)

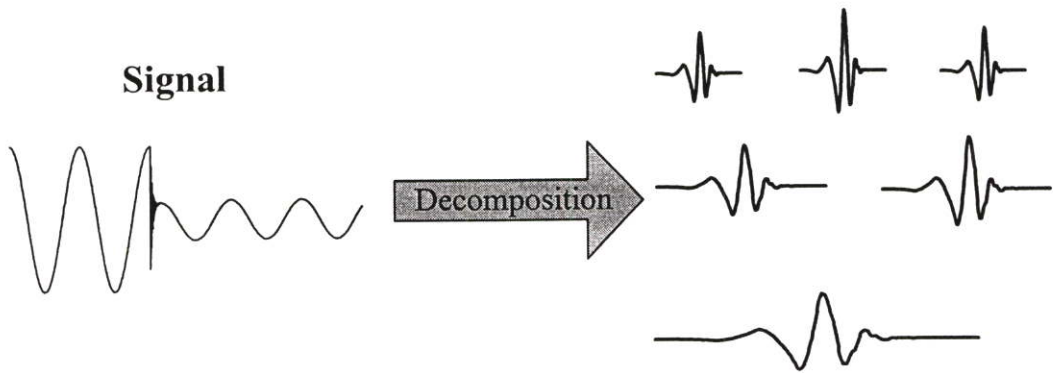
การเลื่อนตำแหน่งของเวฟเล็ตจะมีความหมายง่ายๆ คือ การเลื่อนสัญญาณในทางคณิตศาสตร์ซึ่งการเลื่อนของฟังก์ชัน  $\psi(t)$  ด้วย  $k$  จะแสดงได้โดย  $\psi(t-k)$  การเลื่อนตำแหน่งจะกำหนดโดยพารามิเตอร์ “ $k$ ” ซึ่งจะหมายถึง การเลื่อนตำแหน่งการเกิดคลื่นเวฟเล็ตบนแกน เมื่อพิจารณาเวฟเล็ตที่มีการเลื่อนที่ตำแหน่งใดๆ สามารถพิจารณาได้ดังรูปที่ 3.7




รูปที่ 3.7 แสดงคุณสมบัติการเลื่อนตำแหน่งของฟังก์ชันเวฟเล็ต [15]

### 3.3.4 การกระจายและรวมกลับของเวฟเล็ต (Decomposition and reconstruction of Wavelet)

เมื่อนำสัญญาณใดๆ มาผ่านการแปลงเวฟเล็ตก็เปรียบเสมือนการแตกสัญญาณนั้นออกมาอยู่ในรูปของฟังก์ชันเวฟเล็ตแม่ที่มีตำแหน่งทางเวลาและสเกลที่แตกต่างกันออกไป โดยที่เวฟเล็ตแต่ละตัวจะมีค่าน้ำหนัก (Weight) คูณอยู่ ซึ่งรูปแบบในการแตกกระจายสัญญาณนี้เรียกว่า การกระจายเวฟเล็ต (Wavelet decomposition) ดังแสดงอยู่ในรูปที่ 3.8 ในทางกลับกันการรวมกลุ่มของเวฟเล็ตแต่ละตัวมาประกอบขึ้นเป็นสัญญาณเดิมนั้นเรียกว่า การรวมกลับเวฟเล็ต (Wavelet reconstruction) ซึ่งก็คือการแปลงกลับเวฟเล็ต (Inverse wavelet transform) โดยจะเป็นการนำเอาส่วนประกอบย่อยๆ เหล่านี้มาเรียงต่อกันเพื่อประกอบเป็นสัญญาณเดิม ดังแสดงอยู่ในรูปที่ 3.9



รูปที่ 3.8 แสดงการกระจายสัญญาณด้วยการแปลงเวฟเล็ต [15]



รูปที่ 3.9 แสดงการสร้างกลับสัญญาณด้วยการแปลงเวฟเล็ต [15]

โดยทั่วไปแล้วรูปแบบของการแปลงเวฟเล็ตสามารถแบ่งได้เป็น 2 ประเภทดังจะอธิบายในหัวข้อถัดไป

### 3.4 การแปลงเวฟเลตแบบต่อเนื่อง (Continuous Wavelet Transform :CWT)

จากการวิเคราะห์สัญญาณด้วยการแปลงฟูเรียร์ช่วงสั้น จะสังเกตเห็นว่า หน้าต่างเวลาความถี่ (Time-frequency window) มีพื้นที่ในการวิเคราะห์ที่คงที่เสมอไม่ว่าจะเป็นการพิจารณาที่ความถี่ในช่วงเวลาใดๆ แต่ในทางปฏิบัติความถี่ของสัญญาณเป็นสัดส่วนโดยตรงกับจำนวนไซเคิลต่อหนึ่งหน่วยเวลา ดังนั้นถ้าใช้การแปลงฟูเรียร์ช่วงสั้น และเลือกฟังก์ชันหน้าต่างที่มีช่วงความถี่และช่วงเวลาที่ ไม่เหมาะสม เช่น ช่วงเวลาแคบเกินไปก็ทำให้ต้องมีการทำการแปลงหลายๆครั้ง ที่หลายตำแหน่งเพื่อให้ได้ ข้อมูลในช่วงเวลาทั้งหมดที่ต้องการ ฟังก์ชันหน้าต่างที่ดี ความกว้างของช่วงเวลาและความถี่ต้องมีการเปลี่ยนแปลงเป็นสัดส่วนผกผันที่สัมพันธ์กัน นั่นคือ ควรทำให้หน้าต่างเวลา (Time Window) ที่แคบแต่มี หน้าต่างความถี่ (Frequency Window) ที่กว้าง เมื่อทำการวิเคราะห์สัญญาณที่ความถี่สูงและ หน้าต่างเวลา ที่กว้างแต่มีหน้าต่างความถี่ที่แคบเมื่อทำการวิเคราะห์สัญญาณที่ความถี่ต่ำ ซึ่งทำให้ได้ระดับข่าวสาร ข้อมูลที่ครบถ้วนและใช้ช่วงเวลาในการแปลงน้อยลง

รูปแบบของการแปลงเวฟเลตแบบต่อเนื่องนั้นมีลักษณะการวิเคราะห์สัญญาณโดยอาศัยการ ปรับเปลี่ยนคุณสมบัติของเวฟเลตแม่ที่ใช้ในการวิเคราะห์คือ ช่วงเวลาในการวิเคราะห์ที่แคบในการ วิเคราะห์ห้วงค์ประกอบความถี่สูง และช่วงในการวิเคราะห์ที่กว้างในการวิเคราะห์ห้วงค์ประกอบความถี่ต่ำ ซึ่งก็เป็นการปรับระดับความละเอียดในการวิเคราะห์อย่างต่อเนื่องให้เหมาะสมกับความถี่ที่ทำการ วิเคราะห์ ซึ่งสามารถแสดงสมการสำหรับการวิเคราะห์ได้ดังต่อไปนี้ [17]

$$CWT(a, k) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} f(t) \psi\left(\frac{t-k}{a}\right) dt \quad (3.7)$$

เมื่อ

$f(t)$  = สัญญาณที่ทำการแปลง


$\psi(t)$  = เวฟเลตแม่

$a$  = แฟคเตอร์สเกล (scale)

$k$  = แฟคเตอร์การเลื่อนตำแหน่ง (shifting)

จากสมการที่ 3.7 เมื่อพิจารณาเทอมของ  $\psi(t)$  ซึ่งเป็นเทอมของเวฟเลตแม่ที่เทียบได้กับเทอมของ ฟังก์ชันหน้าต่างในการแปลงฟูเรียร์ช่วงเวลานั้นเอง แต่เมื่อพิจารณาเทอมของ  $\psi(t)$  จะมีการเปลี่ยนแปลงคุณสมบัติไปตามพารามิเตอร์  $a$  และ  $k$  ซึ่งสามารถแสดงลักษณะในการวิเคราะห์ได้ดังนี้ [18]


- นำเวฟเล็ตแม่มาเปรียบเทียบกับส่วนแรกซึ่งเป็นจุดเริ่มต้นของสัญญาณในสเกลแรก



รูปที่ 3.10 แสดงขั้นตอนที่ 1 และ 2 ของการแปลงเวฟเล็ต [18]


- คำนวณสัมประสิทธิ์ (C) ซึ่งผลการวิเคราะห์จะแสดงความสัมพันธ์ระหว่างเวฟเล็ตแม่ในสเกลแรกกับสัญญาณในส่วนแรก ซึ่งค่าสัมประสิทธิ์นี้ขึ้นอยู่กับกรเลือกใช้รูปร่างของเวฟเล็ตแม่ด้วย

- เลื่อนตำแหน่งการวิเคราะห์ไปทางขวาและทำซ้ำในขั้นตอนที่ 1 และ 2 จนกระทั่งครอบคลุมช่วงสัญญาณทั้งหมด ซึ่งจากขั้นตอนที่ 1 - 3 นี้เป็นการแปลงเวฟเล็ตตลอดช่วงสัญญาณในสเกลแรก



รูปที่ 3.11 แสดงขั้นตอนที่ 3 ของการแปลงเวฟเล็ต [18]

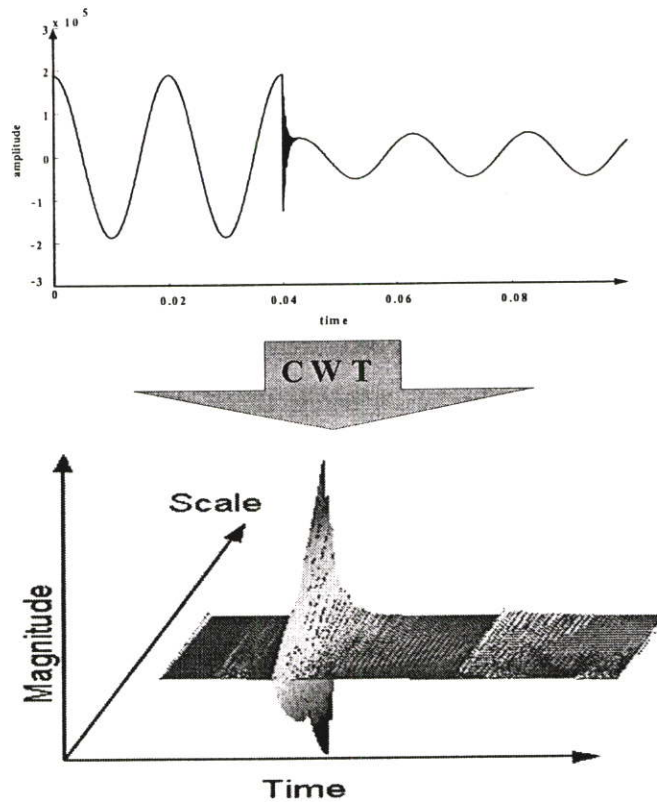
- เปลี่ยนสเกลในการวิเคราะห์โดยการขยายสเกลและทำตามขั้นตอนที่ 1 - 3 ใหม่



รูปที่ 3.12 แสดงขั้นตอนที่ 4 ของการแปลงเวฟเล็ต [18]

### 5. ทำตามขั้นตอนที่ 1 – 4 จนกระทั่งครบทุกสเกล

จากขั้นตอนทั้งหมดผลการวิเคราะห์จะออกมาในรูปสัมประสิทธิ์ที่ได้การวิเคราะห์ของแต่ละสเกลในแต่ละส่วนของสัญญาณ และเนื่องจากการแปลงเป็นไปในลักษณะที่มีการเปลี่ยนแปลงสเกลและการเลื่อนตำแหน่งในการวิเคราะห์อย่างต่อเนื่อง เมื่อนำผลการวิเคราะห์ทั้งหมดมาแสดงรูปแบบความสัมพันธ์ของเวลาและความถี่ (Time - Scale) ได้ดังรูปที่ 3.13



รูปที่ 3.13 แสดงการแปลงเวฟเล็ตแบบต่อเนื่อง (CWT) [15]

จากรูปที่ 3.13 แสดงให้เห็นว่าผลการวิเคราะห์เมื่อนำมาเขียนเป็นกราฟจะออกมาในรูปของพื้นผิวที่ต่อเนื่องกันซึ่งการปรับเปลี่ยนสเกลในการวิเคราะห์ที่ต่อเนื่อง จะให้ความแม่นยำทางด้านเวลาและความถี่ที่ดีแต่จะมีข้อเสียคือ ในการนำไปใช้งานที่ต้องการความรวดเร็วในการวิเคราะห์การแปลงเวฟเล็ตต่อเนื่องอาจจะไม่เหมาะสม เนื่องจากต้องใช้เวลาในการวิเคราะห์ที่ค่อนข้างมากและบางครั้งให้ข้อมูลที่ซ้ำซ้อนมากเกินไปจนเกิดความจำเป็น

จากรูปที่ 3.13 แสดงให้เห็นว่าผลการวิเคราะห์เมื่อนำมาเขียนเป็นกราฟจะออกมาในรูปของพื้นผิวที่ต่อเนื่องกันซึ่งการปรับเปลี่ยนสเกลในการวิเคราะห์ที่ต่อเนื่อง ซึ่งจะทำให้ความแม่นยำทางด้านเวลาและความถี่ที่ดีแต่จะมีข้อเสียคือ ในการนำไปใช้งานที่ต้องการความรวดเร็วในการวิเคราะห์การแปลงเวฟเล็ทต่อเนื่องอาจจะไม่เหมาะสม เนื่องจากต้องใช้เวลาในการวิเคราะห์ที่ค่อนข้างมากและบางครั้งให้ข้อมูลที่ซ้ำซ้อนมากเกินไปจนเกิดความจำเป็น

### 3.5 การแปลงเวฟเล็ทแบบเต็มหน่วย (Discrete Wavelet Transform : DWT) [19]

จากข้อจำกัดของการแปลงเวฟเล็ทแบบต่อเนื่องจึงมีการพัฒนารูปแบบการแปลงเวฟเล็ทมาสู่การแปลงเวฟเล็ทแบบเต็มหน่วย ที่มีลักษณะการวิเคราะห์โดยเปลี่ยนสเกลและการเลื่อนตำแหน่งในลักษณะเป็นช่วงๆ ไม่ต่อเนื่องกัน และก่อนที่จะกล่าวถึงรายละเอียดของการแปลงเวฟเล็ทแบบเต็มหน่วยจำเป็นที่ต้องกล่าวถึงทฤษฎีพื้นฐานที่ใช้ในการอธิบายก่อน

#### 3.5.1 การวิเคราะห์สัญญาณแบบหลายระดับความละเอียด (Multi-Resolution Analysis : MRA)

การวิเคราะห์สัญญาณแบบหลายระดับความละเอียด คือการวิเคราะห์สัญญาณที่สามารถเลือกระดับความละเอียดได้ โดยการนำสัญญาณเล็กๆ ที่ระดับความละเอียด  $a$  ซึ่งมี  $k$  หลายๆ ตำแหน่งมารวมกันให้เกิดเป็นสัญญาณที่ระดับความละเอียดที่เลือกไว้ และเมื่อนำสัญญาณที่ทุกระดับความละเอียดมารวมกันก็จะได้สัญญาณอินพุทจริง ซึ่งหลักการของการวิเคราะห์สัญญาณหลายระดับความละเอียดนั้นสามารถอธิบายได้โดยอาศัยทฤษฎีของสเปซเวกเตอร์

##### 3.5.1.1 ทฤษฎีของปริภูมิเวกเตอร์ (Space vector theory)

ความหมายของปริภูมิของเวกเตอร์ในการวิเคราะห์สัญญาณ คือ ปริภูมิของสัญญาณที่เกิดจากการรวมกันของสัญญาณพื้นฐานย่อยๆ ที่เรียกว่า “ ฟังก์ชันพื้นฐาน (Basic function) ” โดยสมมติว่า  $V$  เป็นปริภูมิเวกเตอร์ที่มี  $j$  แส ดงถึงระดับความละเอียดและจำนวนของฟังก์ชันพื้นฐานที่ประกอบขึ้นเป็นฟังก์ชันนั้น ซึ่งถ้า  $j$  มีค่าสูงขึ้นก็แสดงว่าที่ระดับความละเอียดสูงขึ้นและมีจำนวนฟังก์ชันพื้นฐานมากขึ้น ทำให้สัญญาณที่เกิดขึ้นจากการประกอบกันจากฟังก์ชันมีความละเอียดมากขึ้นด้วย ดังนั้นอาจกล่าวได้ว่า  $j$  เป็นค่าแสดงถึงระดับความละเอียดของสัญญาณนั่นเอง โดยสามารถสรุปคุณสมบัติของการวิเคราะห์สัญญาณที่ระดับความละเอียดต่างๆ ได้ดังนี้

- 1).  $V^{-\infty} \dots \subset V^{-1} \subset V^1 \dots \subset V^{\infty}$
- 2).  $\text{Close}_{L^2}(\bigcup_{j \in \mathbb{Z}} V^j) = L^2(\mathbb{R})$ ;  $\mathbb{R} =$  เซตของจำนวนจริง
- 3).  $\left( \bigcap_{j \in \mathbb{Z}} V^j \right) = \{0\}$

- 1) หมายถึง ปริภูมิของเวกเตอร์ที่มีระดับความละเอียดสูงกว่า จะสามารถพิจารณาให้มีระดับความละเอียดต่ำลงได้ โดยมีความสัมพันธ์กันเป็นโครงข่ายในลักษณะของเซตย่อย ซึ่งจะหมายถึง สัญญาณใดๆ ก็ตามจะสามารถพิจารณาที่ระดับความละเอียดใดๆ ก็ได้โดยที่ยังคงอยู่ภายใต้ สัญญาณเดิมนั่นเอง
- 2) ฟังก์ชันทุกฟังก์ชันใน  $L^2(\mathbb{R})$  สามารถถูกประมาณให้อยู่ในปริภูมิของเวกเตอร์ที่ระดับความละเอียด  $j$  ใดๆ ก็ได้ในลักษณะของการโปรเจกชันสัญญาณ  $f(t)$  ลงใน  $V^j$  การประมาณฟังก์ชันไปที่ระดับ  $j$  ใดๆ จะทำให้ข่าวสารของ  $f(t)$  สูญหายไปตามระดับความละเอียดนั้นๆ แต่ถ้ระดับความละเอียดเพิ่มขึ้นถึงอนันต์สัญญาณที่ประมาณนั้นยังคงอยู่เข้าสู่สัญญาณต้นกำเนิด  $f(t) \in L^2(\mathbb{R})$
- 3) การโปรเจกต์แต่ละครั้งที่ระดับ  $j$  น้อยลงเรื่อยๆ จะทำให้สัญญาณที่ประมาณมีข่าวสารที่สูญหายไปมากขึ้น ดังนั้นรายละเอียดของสัญญาณจะน้อยลงเรื่อยๆ จนเข้าสู่ศูนย์
- 4) การโปรเจกต์สัญญาณจากระดับหนึ่งไปยังระดับหนึ่งที่ต่ำกว่าหนึ่งระดับ จะทำให้ข่าวสารหรือพลังงานของสัญญาณส่วนหนึ่งหายไป หรือ อาจจะมีมองว่าแถบความถี่ของสัญญาณบางส่วนหายไป พลังงานหรือสัญญาณในแบนด์ความถี่ที่หายไปนี้ จะถูกรวมอยู่ใน Complementary Subspace :  $W^j$
- 5) คุณสมบัติของ Two Scale Property จะเป็นการลดระดับความละเอียดของสัญญาณลงมาหนึ่งระดับ ซึ่งหมายถึงว่า สัญญาณที่อยู่ใน  $V^{j+1}$  จะมีความถี่เป็นสองเท่าของสัญญาณใน  $V^j$

จากลักษณะสมบัติทั้ง 5 ข้อ แสดงว่าถ้ากำหนดให้  $f(t) \in L^2(\mathbb{R})$  สัญญาณ  $f(t)$  อันเดียวกัน แต่อยู่ที่ปริภูมิต่างกันจะมีจำนวนของฟังก์ชันพื้นฐานที่ต่างกัน โดยระดับปริภูมิสูง ( $j$  มาก) จะมีจำนวนของฟังก์ชันพื้นฐานมาก ซึ่งหมายถึงสัญญาณมีความละเอียดสูงนั่นเอง ถ้าให้ช่วงเวลาที่ทำการพิจารณาสัญญาณในแต่ละปริภูมิเท่ากัน ก็จะพบว่าเนื่องจากที่ระดับ  $j$  สูงๆ จะมีจำนวนของฟังก์ชันพื้นฐานมาก แต่ต้องบรรจุฟังก์ชันพื้นฐานลงในปริภูมิที่มีช่วงเวลาที่จำกัด ดังนั้นแสดงว่าฟังก์ชันพื้นฐานแต่ละตัวจะมีช่วงเวลาที่แคบ ซึ่งหมายถึงฟังก์ชันพื้นฐานมีความถี่สูงนั่นเอง ในขณะที่ระดับปริภูมิ  $j$  ต่ำกว่าจะมีฟังก์ชันพื้นฐานน้อยกว่าทำให้ช่วงเวลาของฟังก์ชันพื้นฐานแต่ละตัวกว้างขึ้นดังนั้นจึงสรุปได้ว่า ฟังก์ชันพื้นฐานที่ระดับความละเอียด  $j+1$  จะมีความถี่เป็นสองเท่าของระดับความละเอียด  $j$  ตามลักษณะคุณสมบัติข้อที่ 5 ของการวิเคราะห์สัญญาณแบบหลายระดับความละเอียด

จากการที่ฟังก์ชันพื้นฐาน ประกอบกันเป็นสัญญาณที่ระดับความละเอียด  $j$  ภายในสเปซ  $V^j$  จะเรียกฟังก์ชันนี้ว่าเป็น “ฟังก์ชันสเกลลิ่ง (Scaling function :  $\Phi(t)$ )” และฟังก์ชันสเกลลิ่งที่ระดับสูงจะมี

ความถี่สูงและระดับที่ต่ำลงมาจะมีความถี่ที่ต่ำกว่า ตามความสัมพันธ์ที่แสดงในคุณสมบัติข้อที่ 4 : ซึ่งทำให้สามารถเขียนความสัมพันธ์ระหว่างฟังก์ชันสเกลในสเปซใดๆ ได้ดังนี้

$$\Phi_{j,k} = 2^{\frac{j}{2}} \Phi(2^j t - k) ; j, k \in \mathbb{Z} \quad (3.8)$$

จากสมการจะพบว่าถ้าระดับความละเอียดลดลงมาหนึ่งระดับ ฟังก์ชันพื้นฐานจะมีความถี่ลดลงมาครึ่งละ 2 เท่า และอาศัยคุณสมบัติ MRA จะทำให้สามารถทำการประมาณสัญญาณ  $f(t) \in L^2(\mathbb{R})$  ไปอยู่ในปริภูมิที่ระดับความละเอียด  $j$  ใดๆ ได้ดังนี้

$$f_j(t) = \sum_k c_k^j \Phi_{j,k}(t) \quad (3.9)$$

โดย  $c_k^j$  ที่เป็นสัมประสิทธิ์หรือนำหนักที่คูณกับฟังก์ชันสเกลถึงที่ตำแหน่ง  $k$  ใดๆ แล้วประกอบขึ้นเป็น  $f(t)$  ที่ระดับความละเอียด  $j$

จากคุณสมบัติข้อ 4 ของ MRA การวิเคราะห์สัญญาณที่ระดับความละเอียดต่ำลงมาจะทำให้พลังงานหรือสัญญาณบางส่วนหายไปอยู่อีกปริภูมิอีกอันหนึ่งซึ่งเรียกว่า “ ปริภูมิของเวกเตอร์เวฟเล็ต (Wavelet vector space :  $W^j$ ) ” ซึ่งจะประกอบด้วยฟังก์ชันพื้นฐานที่เรียกว่า “ ฟังก์ชันเวฟเล็ต (Wavelet function:  $\psi(t)$ ) ” โดยสามารถเขียนสมการฟังก์ชันเวฟเล็ตได้ดังต่อไปนี้

$$\psi_{j,k}(t) = 2^{\frac{j}{2}} \psi(2^j t - k) \quad (3.10)$$

ถ้ากำหนดให้  $g_j(t)$  เป็นสัญญาณที่เกิดจากฟังก์ชันพื้นฐาน ( $\psi_{j,k}(t)$ ) ภายในปริภูมิเดียวกันมารวมเป็นสัญญาณใดๆ จะได้ว่า

$$g_j(t) = \sum_k d_k^j \psi_{j,k}(t) \quad (3.11)$$


โดยที่  $d_k^j$  เป็นสัมประสิทธิ์หรือนำหนักที่คูณกับฟังก์ชันเวฟเล็ตที่ตำแหน่งนั้นๆ เพื่อเกิดเป็นสัญญาณ  $g(t)$  ดังนั้นจากความสัมพันธ์  $V^j + W^j = V^{j+1}$  จะได้ว่า

$$f_{j+1} = f_j + g_j \tag{3.12}$$

โดยสมมติให้  $f(t) \in V^{j+1}$  จะสามารถแตกกระจายให้  $f(t)$  ให้มีความละเอียดน้อยลงได้จากความสัมพันธ์ของ  $V^j + W^j = V^{j+1}$  ในขณะเดียวกัน  $V^j$  สามารถแตกต่อไปอีกได้เรื่อยๆจนกระทั่ง  $j=0$  ดังนั้นจะได้ความสัมพันธ์ว่า

$$V^{j+1} = V^0 + W^0 + W^1 + \dots + W^j \tag{3.13}$$

ในทำนองเดียวกัน  $f_{j+1} = f_j + g_j$  สามารถแตกกระจายเป็น  $f_j$  และ  $g_j$  ได้ดังรูปที่ 3.14



รูปที่ 3.14 แสดงการเปรียบเทียบลักษณะการกระจาย (decomposition) [19] ของ

- (ก) ปริภูมิของเวกเตอร์
- (ข) สัญญาณที่ความละเอียดต่างๆ

จากรูปที่ 3.14 (ก)  $W^j$  ที่ระดับความละเอียดใดๆ จะมีลักษณะเชิงตั้งฉาก (Orthogonal) ซึ่งกันและกันเสมอ เนื่องจากสัญญาณภายในปริภูมิของเวฟเลตที่ระดับ  $j$  ต่างกันจะไม่มีสัญญาณเกี่ยวข้องกันเลย ดังนั้น จะสามารถเปลี่ยนการบวกกันแบบตรงๆ ของปริภูมิ (Direct sum) เป็นการบวกในลักษณะแบบการบวกเชิงตั้งฉาก (Orthogonal Sum) ซึ่งเป็นความสัมพันธ์ใหม่ได้ดังนี้

จากรูปที่ 3.14 (ก)  $W^j$  ที่ระดับความละเอียดใดๆ จะมีลักษณะเชิงตั้งฉาก (Orthogonal) ซึ่งกันและกันเสมอ เนื่องจากสัญญาณภายในปริภูมิของเวฟเล็ตที่ระดับ  $j$  ต่างกันจะไม่มีสัญญาณเกี่ยวข้องกันเลย ดังนั้น จะสามารถเปลี่ยนการบวกกันแบบตรงๆ ของปริภูมิ (Direct sum) เป็นการบวกในลักษณะแบบการบวกเชิงตั้งฉาก (Orthogonal Sum) ซึ่งเป็นความสัมพันธ์ใหม่ได้ดังนี้

$$V^j = V^0 \oplus W^0 \oplus W^1 \oplus \dots \oplus W^j \quad (3.14)$$

สัญญาณองค์ประกอบย่อยที่อยู่ในปริภูมิของเวฟเล็ตที่ระดับความละเอียดใดๆ ซึ่งเรียกว่า “ฟังก์ชันเวฟเล็ตพื้นฐาน” (Wavelet basis function) จะแบ่งออกเป็น 4 ประเภทใหญ่ ตามลักษณะสมบัติเชิงตั้งฉาก เพื่อเลือกใช้งานได้อย่างเหมาะสมและสะดวกในการสร้างฟังก์ชันเวฟเล็ต

#### (1) Orthogonal Wavelets

หมายถึง ผลคูณภายใน (Inner Product) ของปริภูมิเวฟเล็ต จะเป็นหนึ่งได้เมื่อเป็นฟังก์ชันพื้นฐานเวฟเล็ตที่ระดับความละเอียดเดียวกันและตำแหน่งเดียวกันเท่านั้น

#### (2) Semi orthogonal Wavelets

หมายถึง ผลคูณภายใน (Inner Product) ของเวฟเล็ตจะเป็นศูนย์เสมอ เมื่อเป็นฟังก์ชันพื้นฐานเวฟเล็ตที่ต่างระดับความละเอียดกัน แต่ถ้าเป็นระดับความละเอียดเดียวกันอาจจะเป็นศูนย์หรือหนึ่งก็ได้ ซึ่งจะสังเกตเห็นว่า ทุก Orthogonal Wavelet จะเป็น Semi orthogonal Wavelets เสมอ

#### (3) Non orthogonal Wavelets

หมายถึงเวฟเล็ตที่ไม่เป็น Semi orthogonal Wavelets และไม่มีคุณสมบัติการตั้งฉากกันของสมาชิกฟังก์ชันพื้นฐานภายในสัญญาณ

#### (4) Bi-orthogonal Wavelets

หมายถึง ฟังก์ชันเวฟเล็ต จะมีคุณสมบัติเป็น Orthogonal กับ Dual :  $\tilde{\psi}(t)$  ของฟังก์ชันเวฟเล็ตเอง เท่านั้นถ้าพิจารณาลักษณะสมบัติเชิงตั้งฉาก ด้วย  $\psi(t)$  ด้วยกันจะไม่มีคุณสมบัติเชิงตั้งฉาก

ในการเลือกใช้เวฟเล็ตแม้ที่มีคุณสมบัติของการเป็น Orthogonal แล้วเซตของค่าสัมประสิทธิ์ที่ได้ก็จะไม่มีความซ้ำซ้อนกัน (No redundancy) ทำให้เซตของค่าสัมประสิทธิ์ที่ได้นี้ สามารถแทนสัญญาณได้อย่างมีประสิทธิภาพ ดังนั้นจึงนำเชิงตั้งฉากของการแปลงเวฟเล็ตมาใช้เป็น Multi Resolution Wavelet decomposition

จากรูปที่ 3.14 (ข) ดังนั้นสามารถแสดงลักษณะของสัญญาณ  $f(t)$  ในรูปของฟังก์ชันสเกลลิงและฟังก์ชันเวฟเล็ต ได้ดังนี้

$$f(t) = f_j + g_j + g_{j+1} + g_{j+2} + \dots + g_\infty \quad (3.15)$$

รูปแบบการแตกกระจายสัญญาณ  $f(t)$  ใดๆ ในสเปซ  $V^0$  ไปจนถึงระดับความละเอียดที่  $j$  ในรูปของสัมประสิทธิ์  $c_j(m)$  และ  $d_j(m)$  นี้เรียกว่า “การแปลงเวฟเล็ตแบบเต็มหน่วย (Discrete Wavelet Transform :DWT)” โดยมีสมการที่ใช้อธิบายดังต่อไปนี้ [18]

$$DWT(m, n) = \frac{1}{\sqrt{a_0^m}} \int_{-\infty}^{\infty} f(t) \psi\left(\frac{t - nb_0 a_0^m}{a_0^m}\right) dt \quad (3.16)$$

โดยที่  $a_0^m$  คือ การสเกล  
 $nb_0 a_0^m$  คือ การเลื่อนตำแหน่ง  
 $m, n$  คือ เลขจำนวนเต็มบวก

และในทางปฏิบัติการนำมาใช้งานจริง สัญญาณที่เข้ามาจะอยู่ในรูปของการสุ่ม (sample) ดังนั้นสมการที่ (3.16) จึงพัฒนามาสู่สมการที่ (3.17) [20]

$$DWT(m, n) = \frac{1}{\sqrt{a_0^m}} \sum_k f(k) \psi\left[\frac{n - kb_0 a_0^m}{a_0^m}\right] \quad (3.17)$$

เมื่อ  $m, n, k$  เป็นเลขจำนวนเต็มโดยที่  
 $n$  คือ จำนวนข้อมูล  
 $m$  คือ เลขแสดงการเปลี่ยนแปลงของสเกล  
 $k$  คือ เลขแสดงการเลื่อนตำแหน่ง

เมื่อพิจารณาในรูปแบบของการวิเคราะห์หลายระดับความละเอียดแล้วโดยมีการเปลี่ยนแปลงสเกลในการวิเคราะห์ให้ลดลงครั้งละ 2 เท่า ( $a_0 = 2; b_0 = 1$ ) แล้วจะได้รูปแบบการแปลงเวฟเล็ตแบบเต็มหน่วย ซึ่งมีชื่อเรียกเฉพาะว่า dyadic wavelet transform ดังสมการต่อไปนี้ [21]

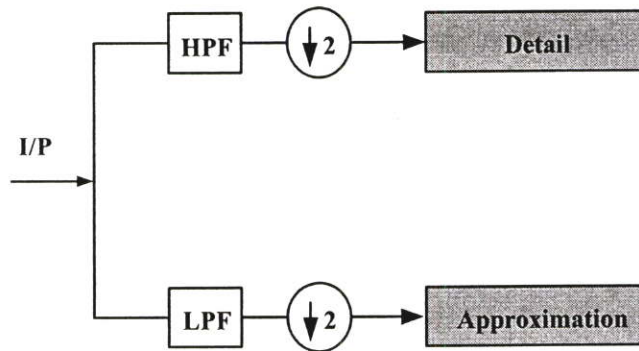
$$DWT(m, n) = \frac{1}{\sqrt{2^m}} \sum_k f(k) \psi\left[\frac{n - k 2^m}{2^m}\right] \quad (3.18)$$

ซึ่งสามารถอธิบายหลักการทำงานได้โดยอาศัยหลักการวิเคราะห์ของฟิลเตอร์แบงก์ดังนี้

### 3.5.2 การวิเคราะห์ด้วยตัวกรองสัญญาณ (Filter Bank Analysis)

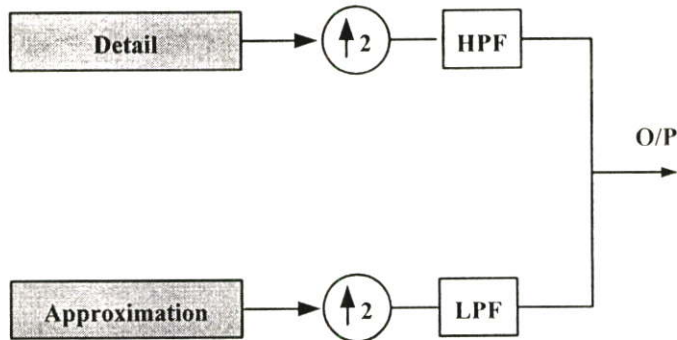
ก่อนที่จะอธิบายการสร้างการแปลงเวฟเลตในลักษณะฟิลเตอร์แบงก์นั้น ขออธิบายหลักการพื้นฐานของฟิลเตอร์แบงก์ก่อนฟิลเตอร์แบบ 2 ช่องสัญญาณ (two channel filter banks) จะเป็นการแยกสัญญาณอินพุตออกเป็น 2 ส่วน คือ ส่วนของความถี่ต่ำและส่วนของความถี่สูง โดยจะถูกวิเคราะห์ด้วยคู่ชุดกรองซึ่งมีการลดความถี่ออกมารั้งหนึ่งดังรูปที่ 3.15 ซึ่งเทอมของ  $\downarrow 2$  แสดงการลดอัตราสุ่มลง (down sampling) ด้วย 2 หรือลดผลการวิเคราะห์จากตัวกรองออกครั้งหนึ่งในแต่ละขั้นตอนของการวิเคราะห์เมื่อนำสัญญาณอินพุตมาผ่านการแปลงเวฟเลตแบบเต็มหน่วยสัญญาณจะถูกแยกองค์ประกอบ (Decomposition) โดยตัวกรองแบบ 2 ช่อง (Two channel filter banks) ซึ่งจะแยกความถี่ในแบนด์ที่ต้องการ ออกเป็น 2 ส่วน คือ

- องค์ประกอบความถี่สูง ซึ่งจะผ่านตัวกรองความถี่สูง (High-Pass Filter : HPF) ที่เรียกว่า “Detail (cD)”
- องค์ประกอบความถี่ต่ำ ซึ่งจะผ่านตัวกรองความถี่ต่ำ (Low-Pass Filter : LPF) ที่เรียกว่า “Approximation (cA)”




รูปที่ 3.15 แสดงการแปลงแยกสัญญาณด้วยฟิลเตอร์แบบสองช่องสัญญาณ [15]

และในทางกลับกันก็สามารถสังเคราะห์เพื่อสร้างกลับฟิลเตอร์แบบสองช่องสัญญาณโดยการนำส่วนของความถี่ต่ำและความถี่สูงมารวมกันเป็นสัญญาณเดิมได้ดังแสดงได้ดังรูปที่ 3.16 จะสังเกตได้ว่าเทอม  $\uparrow 2$  แสดงการเพิ่มอัตราสุ่มขึ้น (Up sampling) เป็น 2 เท่า




รูปที่ 3.16 แสดงการแปลงกลับสัญญาณด้วยฟิลเตอร์แบบสองช่องสัญญาณ [15]

ลักษณะของตัวกรองแบบ 2 ช่องสัญญาณในลักษณะนี้เรียกว่า “Quadrature mirror filters (QMF)” ในลักษณะของ dyadic wavelet transform จะเป็นการนำฟิลเตอร์แบบ 2 ช่องสัญญาณมาเรียงต่อกันในลักษณะโครงสร้างแบบต้นไม้ โดยใช้สัญญาณเอาท์พุทในส่วนความถี่ต่ำมาทำการแยกความถี่ออกอีกครั้งหนึ่ง ซึ่งเป็นลักษณะของการวิเคราะห์แบบออกเทฟฟิลเตอร์แบงก์ (Octave analysis filter banks) โดยที่แต่ละขั้นตอนจะมีการเปลี่ยนแปลงความถี่ในอัตราครึ่งละ 2 เท่า ซึ่งสามารถอธิบายการทำงานได้ดังนี้



รูปที่ 3.17 แสดงลักษณะการแปลงเวฟเลตโดยใช้หลักการวิเคราะห์แบบออกเทฟฟิลเตอร์แบงก์ [22]

จากรูปที่ 3.17 ซึ่งเป็นลักษณะของการแปลงเวฟเล็ดแบบเต็มหน่วยในลักษณะของ dyadic tree structure โดยมีสัญญาณอินพุตซึ่งเป็นสัญญาณที่ถูกสุ่มด้วยความถี่การสุ่ม =  $f_s$  (sampling rate) จะถูกวิเคราะห์ด้วยฟิลเตอร์ 2 ช่องสัญญาณในสเกลที่ 1 ( $2^1$ ) ซึ่งสัญญาณจะถูกแยกออกเป็น 2 ช่วงความถี่ คือส่วนความถี่สูงหรือ detail 1 มีความถี่อยู่ในช่วง  $\frac{f_s}{2} - \frac{f_s}{4}$  Hz และส่วนความถี่ต่ำ หรือ Approximation 1 มีความถี่ในช่วง  $\frac{f_s}{4} - 0$  Hz และในการวิเคราะห์ในสเกลที่ 2 ( $2^2$ ) ก็ทำได้โดยการกรองชุดเดิมมาวิเคราะห์ต่อจาก Approximation 1 ซึ่งผลการวิเคราะห์จะออกมาเป็น ส่วนความถี่สูงสเกลที่ 2 หรือ detail 2 ซึ่งมีความถี่ในช่วง  $\frac{f_s}{4} - \frac{f_s}{8}$  Hz และส่วนความถี่ต่ำสเกลที่ 2 หรือ Approximation 2 มีความถี่อยู่ในช่วง  $\frac{f_s}{8} - 0$  Hz ถ้าทำการวิเคราะห์ต่อในสเกลที่ 3 ก็สามารถทำซ้ำในลักษณะเดิม ในทางกลับกันก็สามารถที่จะรวมสัญญาณที่ทำการกระจายในหลายๆ ช่วงความถี่ให้กลับมาเป็นสัญญาณเดิมได้ ซึ่งผลการแปลงเวฟเล็ดแบบเต็มหน่วยได้แสดงอยู่ในรูปที่ 3.18



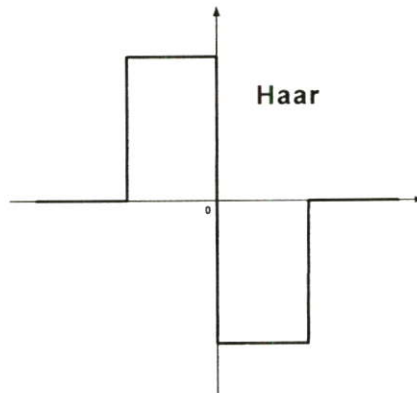
รูปที่ 3.18 แสดงการแปลงเวฟเล็ดแบบเต็มหน่วย (DWT) ในสเกลที่ 1-4 [15]

### 3.6 เวฟเล็ตแม่ (Mother wavelet) [18]

ในการวิเคราะห์สัญญาณใดๆ ก็ตามนอกจากการเลือกรูปแบบในการวิเคราะห์ที่เหมาะสมแล้วยังมีความจำเป็นที่ต้องเลือกลักษณะของตัวกรองสัญญาณนั้นๆ ให้เหมาะสมด้วย สำหรับการแปลงเวฟเล็ตนั้นตัวกรองสัญญาณที่ใช้คือเวฟเล็ตแม่นั้นเอง ซึ่งจะมีอยู่ด้วยกันหลายรูปแบบและแต่ละแบบยังมีชนิดย่อยๆ ลงไปอีก ซึ่งแต่ละตระกูลจะมีค่า Number of Vanishing Moments (NVM) ที่ายชื่อตระกูล เช่น Daubechies 4, 8,..., 20, Symmlet 4, 5, 6,..., 10 เป็นต้น และเนื่องจากรูปแบบของเวฟเล็ตแม่ที่หลากหลายนี้เอง จึงทำให้การแปลงเวฟเล็ตมีความยืดหยุ่นและสามารถนำไปประยุกต์ใช้งาน โดยเลือกเวฟเล็ตแม่ให้เหมาะสมกับสัญญาณที่การวิเคราะห์ ตระกูลของเวฟเล็ตแม่ที่สำคัญและนิยมใช้กันอย่างแพร่หลายในปัจจุบันนี้ได้แก่

#### 3.6.1 Haar Wavelet

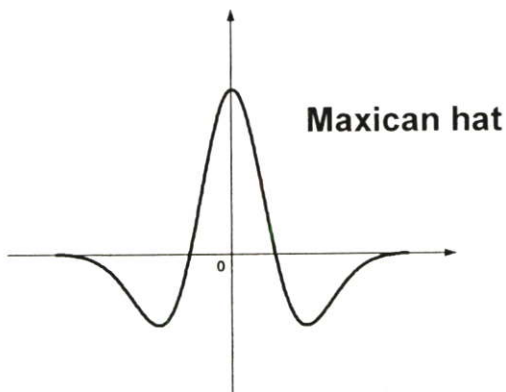
การวิเคราะห์เวฟเล็ตเพื่อนำไปวิเคราะห์สัญญาณในช่วงแรกๆ จะใช้ Haar Wavelet สำหรับการวิเคราะห์ ซึ่ง Haar Wavelet นี้จะเป็นเวฟเล็ตชนิดแรกสุดและง่ายที่สุด ลักษณะของเวฟเล็ตชนิดนี้จะคล้ายกับฟังก์ชันขั้นบันได ซึ่งแสดงดังรูปที่ 3.19



รูปที่ 3.19 แสดงลักษณะของ Haar Wavelet [18]

#### 3.6.2 Mexican Hat Wavelet

เวฟเล็ตชนิดนี้ไม่มีฟังก์ชันการสเกลและมีที่มาจากฟังก์ชันอนุพันธ์อันดับที่สองของฟังก์ชันความหนาแน่นของความน่าจะเป็นเกาส์เซียน (the second derivative function of Gaussian probability density function) ลักษณะของเวฟเล็ตชนิดนี้แสดงดังรูปที่ 3.20




รูปที่ 3.20 แสดงลักษณะของ Maxican Hat Wavelet [18]

### 3.6.3 Daubechies Wavelet

เวฟเลตชนิด Daubechies ได้ถูกคิดค้นโดย Ingrid Daubechies ซึ่งเป็นนักวิจัยทางด้านเวฟเลตที่ประสบความสำเร็จและสำคัญคนหนึ่งของโลก เขาได้สร้างสิ่งที่เรียกว่า “ขอบเขตที่แน่นอนของเวฟเลตเชิงตั้งฉากปกติ” (compactly-subport orthonormal wavelet) ซึ่งเป็นการสร้างการวิเคราะห์เวฟเลตแบบไม่ต่อเนื่องในทางปฏิบัติขึ้นมาได้สำเร็จ และได้กำหนดค่า NVM ของตระกูลเวฟเลตขึ้นมาเพื่อสร้างความหลากหลายในการเลือกใช้งานได้อย่างเหมาะสม ค่า NVM นี้จะกำกับไว้หลังชื่อตระกูลเวฟเลตเช่น Duabechies 4 ก็คือมีค่า NVM เท่ากับ 4

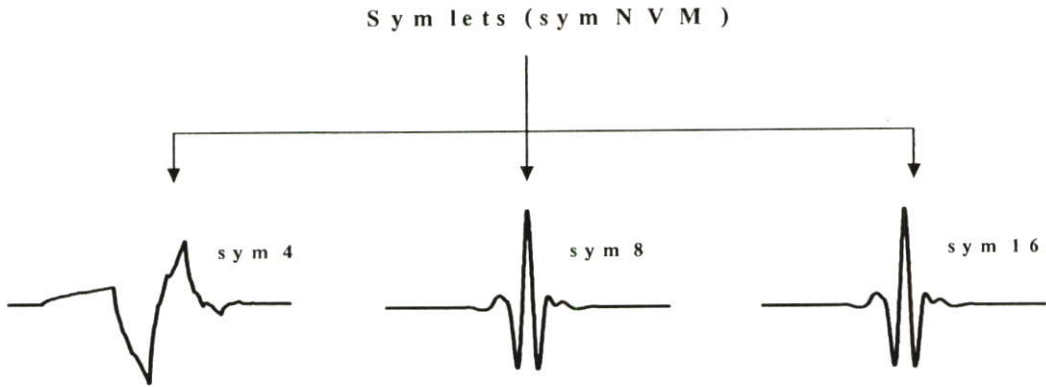
สำหรับเวฟเลตตระกูล Daubechies นี้จะมีฟังก์ชันพื้นฐาน (basis function) ในลักษณะไม่สมมาตร (Asymmetric) ลักษณะดังรูปที่ 3.21 ซึ่งมีหลากหลายรูปแบบตามค่า NVM



รูปที่ 3.21 แสดงลักษณะของ Daubechies Wavelet [18]

### 3.6.4 Symlets Wavelet


เวฟเลตชนิด Symlet จะมีสัดส่วนใกล้เคียงกับเวฟเลตที่ถูกเสนอโดย I. Daubechies ซึ่งได้ปรับปรุงมาจากเวฟเลตตระกูล Daubechies คุณสมบัติของเวฟเลตทั้งสองตระกูลนี้จะคล้ายคลึงกัน โดยจะมีฟังก์ชันพื้นฐาน (basis function) ในลักษณะไม่สมมาตรเล็กน้อย (Least Asymmetric) ลักษณะของเวฟเลตชนิดนี้จะแสดงดังรูปที่ 3.22



รูปที่ 3.22 แสดงลักษณะของ Symlets Wavelet [18]

### 3.6.5 Coiflets Wavelet


เวฟเลตชนิด Coiflet ถูกสร้างขึ้นโดย I. Daubechies ภายหลังจากที่ I. Daubechies ประสบความสำเร็จจากการสร้างเวฟเลตชนิด Daubechies มาแล้ว เวฟเลตชนิดนี้จะมีฟังก์ชันพื้นฐาน (basis function) ในลักษณะเกือบไม่สมมาตร (Nearly Asymmetric) ลักษณะดังรูปที่ 3.23



รูปที่ 3.23 แสดงลักษณะของ Coiflets Wavelet [18]

### 3.6.6 Morlet Wavelet


เวฟเลตชนิดนี้ไม่มีฟังก์ชันการสเกลลิง (Scaling function) แต่จะมีความแน่นอน สามารถพิจารณา ลักษณะของเวฟเลตชนิดนี้ได้ดังรูปที่ 3.24



รูปที่ 3.24 แสดงลักษณะของ Morlet Wavelet [18]

### 3.6.7 Meyer Wavelet


เวฟเลตชนิด Meyer และฟังก์ชันการสเกลลิงได้ถูกกำหนดไว้ในโดเมนความถี่ ซึ่งพิจารณาลักษณะ ของเวฟเลตชนิดนี้ได้จากรูปที่ 3.25



รูปที่ 3.25 แสดงลักษณะของ Meyer Wavelet [18]

### 3.6.8 Biorthogonal Wavelet

กลุ่มของเวฟเล็ตชนิดนี้จะแสดงคุณสมบัติของเฟสเชิงเส้น ซึ่งจำเป็นสำหรับการสร้างสัญญาณและภาพขึ้นใหม่ โดยการใช้เวฟเล็ตสองตัว ตัวหนึ่งสำหรับแยกตัวประกอบ อีกตัวหนึ่งสำหรับการสร้างใหม่แทนอีกตัวหนึ่งที่เหมือนกัน ที่มีคุณสมบัติที่น่าสนใจ ลักษณะของ Biorthogonal Wavelet นี้ แสดงดังรูปที่ 3.26



รูปที่ 3.26 แสดงลักษณะของ Biorthogonal Wavelet [18]

ตารางที่ 3.1 แสดงสัมประสิทธิ์ของตัวกรองสัญญาณของเวฟเล็ตตระกูล Daubechies ที่ N มีค่าเป็น 4, 6, 8, 10, 12, 14, 16 และ 20 [22]

Order	n	Filter coefficients	Order	n	Filter coefficients	Order	n	Filter coefficients
N=4	0	0.4829629131	N=14	0	0.0778520541	N=18	0	0.0380779474
	1	0.8365163037		1	0.3965393195		1	0.2438346746
	2	0.2241438680		2	0.7291320908		2	0.6048231237
	3	-0.1294095226		3	0.4697822874		3	0.6572880781
N=6	0	0.3326705530		4	-0.1439060039		4	0.1331973858
	1	0.8068915093		5	-0.2240361850		5	-0.2932737833
	2	0.4598775021		6	0.0713092193		6	-0.0968407832
	3	-0.1350110200		7	0.0806126092		7	0.1485407493
	4	-0.0854412739		8	-0.0380299369		8	0.0307256815
	5	0.0352262919		9	-0.0165745416		9	-0.0676328291
N=8	0	0.2303778133		10	0.0125509986		10	0.0002509471
	1	0.7148465706		11	0.0004295780		11	0.0223616621
	2	0.6308807679		12	-0.0018016407		12	-0.0047232048
	3	-0.0279837694		13	0.0003537138		13	-0.0042815037
	4	-0.1870348117	N=16	0	0.0544158422		14	0.0018476469
	5	0.0308413818		1	0.3128715909		15	0.0002303858
	6	0.0328830117		2	0.6756307363		16	-0.0002519632
	7	-0.0105974018		3	0.5853546837		17	0.0000393473
N=10	0	0.1601023980		4	-0.0158291053	N=20	0	0.0266700579
	1	0.6038292698		5	-0.2840155430		1	0.1881768001
	2	0.7243085284		6	0.0004724846		2	0.5272011889
	3	0.1384281459		7	0.1287474266		3	0.6884590395
	4	-0.2422948871		8	-0.0173693010		4	0.2811723437
	5	-0.0322448696		9	-0.0440882539		5	-0.2498464243
	6	0.0775714938		10	0.0139810279		6	-0.1959462744
	7	-0.0062414902		11	0.0087460940		7	0.1273693403
	8	-0.0125807520		12	-0.0048703530		8	0.0930573646
	9	0.0033357253		13	-0.0003917404		9	-0.0713941472
N=12	0	0.1115407434		14	0.0006754494		10	-0.0294575368
	1	0.4946238904		15	-0.0001174768		11	0.0332126741
	2	0.7511339080					12	0.0036065536
	3	0.3152503517					13	-0.0107331755
	4	-0.2262646940					14	0.0013953517
	5	-0.1297668676					15	0.0019924053
	6	0.0975016056					16	-0.0006858567
	7	0.0275228655					17	-0.0001164669
	8	-0.0315820393					18	0.0000935887
	9	0.0005538422					19	-0.0000132642
	10	0.0047772575						
	11	-0.0010773011						

จากรูปที่ 3.21 – 3.23 ค่า NVM เป็นตัวเลขจำนวนเต็มที่แสดงถึงลำดับ (Order) ของเวฟเล็ตแม่ชนิดนั้นๆ ในบางครั้งก็ได้มีความจำกัดความว่า NVM เป็นตัวเลขที่ใช้แสดงจำนวนของสัมประสิทธิ์ตัวกรอง (Filter) ของเวฟเล็ตแม่ตัวนั้นๆ และยังแสดงความราบเรียบ (Smooth) ของเวฟเล็ตแม่ตัวนั้นๆ อีกด้วย เช่น db4 หมายถึงเวฟเล็ตแม่แบบ daubechies ที่มีสัมประสิทธิ์การกรอง 4 ตัว, db20 หมายถึงเวฟเล็ตแม่แบบ daubechies ที่มีสัมประสิทธิ์การกรอง 20 ตัว โดยที่ db20 จะมีรูปร่างที่ราบเรียบกว่า db4 ซึ่งค่าของสัมประสิทธิ์ได้แสดงในตารางที่ 3.1

เนื่องจากรูปแบบของเวฟเล็ตแม่ที่มีความหลากหลายนี้เอง โดยแต่ละชนิดมีคุณสมบัติที่คล้ายกันและบางชนิดก็มีคุณสมบัติที่แตกต่าง จึงมีความจำเป็นที่ต้องรู้คุณสมบัติของแต่ละชนิดของเวฟเล็ตแม่ โดยตารางที่ 3.2 แสดงคุณสมบัติของเวฟเล็ตแม่แต่ละชนิด

ตารางที่ 3.2 แสดงคุณสมบัติของเวฟเล็ตแต่ละชนิด [18]

Property	morl	mexth	meyr	haar	db N	sym N	coif N	bior Nr.Nd
Crude	★	★						
Infinitely regular	★	★	★					
Arbitrary regularity					★	★	★	★
Compactly supported orthogonal				★	★	★	★	
Compactly supported biorthogonal								★
Symmetry	★	★	★	★				★
Asymmetry					★			
Near symmetry						★	★	
Arbitrary number of vanishing moments					★	★	★	★
Orthogonal analysis			★	★	★	★	★	
Biorthogonal analysis			★	★	★	★	★	★
Exact reconstruction		★	★	★	★	★	★	★
FIR filters				★	★	★	★	★
Continuous transform	★	★	★	★	★	★	★	★
Discrete transform			★	★	★	★	★	★
Fast algorithm				★	★	★	★	★

ในวิทยานิพนธ์ฉบับนี้ได้้นำการแปลงเวฟเล็ตแบบเต็มหน่วยมาใช้สำหรับการวิเคราะห์สัญญาณพอลต์ที่เกิดขึ้นภายในขดลวดหม้อแปลงไฟฟ้ากำลัง ซึ่งทำการแยกองค์ประกอบความถี่สูงออกมาหลายช่วงความถี่ (สเกล) แล้วพิจารณาข้อมูลที่ได้จากสัมประสิทธิ์เพื่อนำไปวิเคราะห์ต่อไป และสำหรับการเลือกเวฟเล็ตนั้นได้เลือกใช้เป็นแบบ daubechies 4 (db4) เนื่องจากมีความเหมาะสมในการวิเคราะห์สัญญาณในลักษณะทรานเซียนต์ เช่น พอลต์ และให้ความแม่นยำทางเวลาที่ดี [23, 24] เนื่องจากมีสัมประสิทธิ์ที่น้อยเพียง 4 ตัว โดยแบ่งการนำการแปลงเวฟเล็ตมาใช้วิเคราะห์สัญญาณพอลต์ออกเป็น 2 ขั้นตอนด้วยกันคือ

1) การแยกองค์ประกอบของสัญญาณ (Wavelet decomposition)

ในขั้นตอนนี้เป็นการแยกองค์ประกอบความถี่สูงของสัญญาณกระแสผลต่างออกมาในสเกลที่ 1-5 ซึ่งในที่นี้จะเลือกพิจารณาเฉพาะองค์ประกอบความถี่สูง (detail) เท่านั้น

2) การรวมกลับสัญญาณ (Wavelet Reconstruction)

เพื่อทำการเปรียบเทียบข้อมูลให้มีขนาดเดียวกันหรืออยู่บนฐานเวลาเดียวกันจึงต้องทำการรวมกลับสัญญาณในแต่ละสเกลให้มีจำนวนสัมประสิทธิ์เท่ากับสัญญาณต้นแบบที่ทำการวิเคราะห์ และนอกจากนี้เพื่อให้การพิจารณาเห็นความแตกต่างมากขึ้นจึงยกกำลังสองสัมประสิทธิ์ในแต่ละสเกล ซึ่งสัมประสิทธิ์ทั้งหมดก็จะอยู่ในด้านบวก [5] โดยที่รายละเอียดทั้งหมดจะได้กล่าวอยู่ในบทที่ 6

ตารางที่ 4.1 การวิจัยโครงข่ายประสาทเทียมที่สำคัญในยุคต่างๆ [61, 63]

ช่วงเวลา	ผู้คิดค้นวิจัย	งานวิจัย
1940s ยุคเริ่มต้น	- McCulloch and Pitts - Hebb	- McCulloch-Pitts Neurons - Hebbian Learning Rule and Book
1950s & 1960s ยุคทอง	- Rosenblatt - Widrow and Hoff - Minsky and Papert	- Perceptrons and Perceptron Learning Rule - Widrow-Hoff Learning Rule (LMS Algorithm), ADALINE and MADALINE Networks - Perceptrons Books
1970s ยุคเจียบ	- Willshaw and Von Der Malsburg - Anderson et al. - Grossberg - Grossberg and Carpenter - Fukushima	- Self-Organizing Maps - Brain-State-in-a-Box Model - Grossberg Network - Adaptive Resonance Theory - Neocognitron
1980s - ปัจจุบัน ยุคเฟื่องฟู	- Kohonen - Hopfield - Ackley et al. - Rumelhart et al. - Kohonen - Broomhead et al. - Vapnik et al. - Bertsekas and Tsitsiklis	- Self-Organizing Feature Maps and Books - Hopfield Network - Boltzmann Machine - Back-propagation Algorithm and PDP Books - Learning Vector Quantization - Radial Basis Function - Support Vector Machine - Neurodynamic Programming Book

การพัฒนาที่มีความสำคัญในสาขาโครงข่ายประสาทเทียมเพียงพอที่ดึงดูดความสนใจมากมาย ในปัจจุบันโครงข่ายประสาทได้ถูกพัฒนา ค้นคว้า วิจัยและนำไปใช้ในด้านต่างๆมากขึ้น อาทิ การแพทย์ วิทยาศาสตร์ด้านระบบประสาท การเงินการธนาคาร ด้านคณิตศาสตร์ ระบบสื่อสาร รวมไปถึงงานทางด้านวิศวกรรมไฟฟ้าอีกด้วย จึงถือได้ว่าโครงข่ายประสาทเป็นศาสตร์แขนงหนึ่งที่ได้รับ ความสนใจเป็นอย่างมากในช่วงเวลานี้ ดังแสดงในตารางที่ 4.2 โดยจะแสดงการประยุกต์ใช้โครงข่ายประสาทเทียมในปัจจุบัน


ตารางที่ 4.2 แสดงการประยุกต์ใช้โครงข่ายประสาทในปัจจุบัน [26]

	Fault Diagnosis	Fraud Detection	Forecasting	Signal/Image Processing	Pattern detection in databases
Manufacturing	X	X			
Retailing		X	X		X
Finance and Insurance		X	X		X
Engineering	X			X	
Production Control	X		X		
Sale & Marketing			X		X

ในส่วนของระบบไฟฟ้ากำลัง นักวิจัยด้านไฟฟ้ากำลังมีแนวคิดที่ประยุกต์ใช้โครงข่ายประสาทเทียมเข้ามาแก้ปัญหาเกี่ยวกับไฟฟ้ากำลังหลายปัญหาด้วยกัน เช่น ปัญหาโหลดโพลว์ (Load flow) การพยากรณ์ความต้องการใช้ไฟฟ้า (Load forecasting) และปัญหาการจ่ายโหลดอย่างมีประสิทธิภาพ (Economics load dispatch) เป็นต้น ในอนาคต โครงข่ายประสาทเทียมต้องการกลายเป็นส่วนหนึ่งของระบบผสม (Hybrid systems) จากระบบผู้เชี่ยวชาญ (Expert systems) ฟัซซี่โลจิก (Fuzzy logic) และการแปลงเวฟเล็ต (Wavelet transform) เป็นต้น ระบบผสมนี้จะกลายเป็นผู้นำขอบเขตงานวิจัยในยุคระบบเครื่องมือเชาว์ปัญญา (Age of intelligent machines) สามารถกล่าวได้ว่าโครงข่ายประสาทยังคงได้รับการพัฒนาทั้งด้านทฤษฎี การออกแบบการประยุกต์ใช้ อีกต่อไปในอนาคต

#### 4.2 โครงข่ายประสาทเทียม [25, 27]

โครงข่ายประสาทเทียมเป็นการใช้ประโยชน์จากความก้าวหน้าของเทคโนโลยี เป็นระบบการประมวลผลข้อมูลที่มีพฤติกรรมบางอย่างเหมือนกับโครงข่ายประสาทชีวภาพ จึงกล่าวได้ว่าโครงข่ายประสาทเทียม เป็นอัลกอริทึมที่เลียนแบบการเรียนรู้ของสมองมนุษย์ โดยมีองค์ประกอบของโครงสร้างพื้นฐานที่สำคัญดังนี้คือ ยูนิต (Unit) ตัวแปรอินพุต (Input layer) ตัวแปรเอาต์พุต (Output layer) และค่าถ่วงน้ำหนัก (Weighted value) แสดงดังรูปที่ 4.1



รูปที่ 4.1 แสดงโครงสร้างพื้นฐานของโครงข่ายประสาทเทียม [27]

จากรูปที่ 4.1 สามารถสรุปความสัมพันธ์ระหว่างโครงข่ายประสาทชีวภาพกับโครงข่ายประสาทเทียมได้ดังนี้

โครงข่ายประสาทชีวภาพ	โครงข่ายประสาทเทียม
ตัวเซลล์ (Cell Body)	ยูนิต (Unit)
เดนไดรต์ (Dendrites)	ตัวแปรอินพุท (Input layer)
แอกซอน (Axon)	ตัวแปรเอาต์พุท (Output layer)
ไซแนปส์ (Synapse)	ค่าถ่วงน้ำหนัก (Weight value)

#### 4.2.1 คุณสมบัติและความสามารถของโครงข่ายประสาทเทียม

คุณสมบัติและความสามารถของโครงข่ายประสาทเทียม สามารถสรุปได้ดังนี้คือ

1. โครงข่ายประสาทเทียมไม่ใช่โปรแกรมคอมพิวเตอร์แต่โครงข่ายจะเรียนรู้จากตัวอย่าง
2. มีความยืดหยุ่นสูงจนสามารถจำลองกระบวนการของปัญหาใดๆ ได้
3. มีความสามารถในการจำชุดของคู่อินพุท เอาต์พุทที่มีความซับซ้อนมากจนไม่สามารถจำลองแบบในเชิงความน่าจะเป็นได้
4. มีความสามารถในการปรับตัวเข้ากับการเปลี่ยนแปลงของสิ่งแวดล้อม
5. มีความสามารถในการตอบสนองต่อข้อมูลที่ไม่เคยเห็น
6. ความรู้จะกระจายอยู่ทั่วทั้งโครงสร้างของโครงข่ายประสาทเทียม

#### 4.2.2 ลักษณะของปัญหาที่เหมาะสมกับโครงข่ายประสาทเทียม

ลักษณะของปัญหาที่เหมาะสมกับโครงข่ายประสาทเทียมมีดังนี้คือ

1. ตัวอย่างข้อมูลสำหรับการฝึกสอนประกอบด้วยองค์ประกอบหลายๆ ค่า
2. เอาต์พุทที่ต้องการสามารถเป็นค่าจำนวนเต็ม หรือจำนวนจริงหรือเป็นเวกเตอร์ของจำนวนเต็มหรือจำนวนจริงก็ได้
3. ตัวอย่างของข้อมูลสามารถมีความผิดพลาดปะปนอยู่ได้

4. ไม่มีปัญหาเกี่ยวกับขั้นตอนการฝึกหัดซึ่งอาจใช้เวลานานมาก
5. ต้องการประเมินผลเอาต์พุตอย่างรวดเร็ว
6. ไม่ต้องการเข้าใจวิธีการแก้ปัญหา ต้องการให้ปัญหาได้รับการแก้ไขเท่านั้น

บางโครงข่ายประสาทเป็นแบบจำลองของชีวโครงข่ายประสาทและบางชนิดก็ไม่เป็น อย่างไรก็ตาม ก็ดี โครงข่ายประสาทเทียมอาจพิจารณาให้เป็นขั้นตอนวิธีทางคณิตศาสตร์ (Mathematical algorithm) ของโครงข่ายประสาทชีวภาพ โดยตั้งบนพื้นฐานดังนี้

1. หน่วยประมวลผลเรียกว่า นิวรอน การส่งผ่านข้อมูลระหว่างนิวรอนทำได้โดยการเชื่อมโยงระหว่างนิวรอน
2. การเชื่อมโยงแต่ละส่วนจะขึ้นอยู่กับค่าการเชื่อมโยงหรือค่าถ่วงน้ำหนัก
3. ข้อมูลเอาต์พุตถูกกำหนดด้วยฟังก์ชันกระตุ้น (Activation function) ซึ่งปกติ ความสัมพันธ์ระหว่างผลรวมของข้อมูลอินพุตที่คูณด้วยค่าการเชื่อมโยงกับข้อมูลเอาต์พุตเป็นความสัมพันธ์แบบไม่เป็นเชิงเส้น (Non-linear)

คุณสมบัติของโครงข่ายประสาทเทียมจึงถูกกำหนดด้วยองค์ประกอบทั้งสามส่วน นั่นคือ ส่วนแรกในข้อ 1. เป็นรูปแบบการเชื่อมโยงระหว่างนิวรอนเรียกส่วนนี้ว่า โครงสร้างของโครงข่ายประสาทเทียม ส่วนต่อไปในข้อ 2 เป็นการกำหนดค่าของการเชื่อมโยงเรียกส่วนนี้ว่า ขั้นตอนวิธีการฝึกสอนหรือการเรียนรู้ ส่วนสุดท้ายคือข้อ 3 เกี่ยวกับการกำหนดข้อมูลเอาต์พุตโดยฟังก์ชันกระตุ้น


#### 4.3 โครงสร้างของโครงข่ายประสาทเทียม (Architectures of Neural Networks) [25]

ในการสร้างเซลล์ประสาทเพียงหนึ่งเซลล์ โดยใช้แนวความคิดจากเซลล์ประสาทชีวภาพ การจะนำเซลล์ประสาทเทียมมาใช้งานได้นั้น ต้องใช้เซลล์ประสาทเทียมที่มีคุณลักษณะต่างๆ กัน (ค่าถ่วงน้ำหนักจะทำให้คุณสมบัติของเซลล์ประสาทเทียมแต่ละเซลล์มีคุณลักษณะแตกต่างกันไป) มาเชื่อมต่อเซลล์ประสาทหลายๆ ตัวเข้าด้วยกันให้เกิดเป็นลักษณะของโครงข่ายเป็นชั้นๆ หรือที่เรียกว่า ชั้นหรือเลเยอร์ (Layer) ซึ่งเซลล์ประสาทแต่ละตัวที่อยู่ในชั้นเดียวกันจะไม่มี การเชื่อมต่อถึงกัน โดยปกติแล้ว นิวรอนในชั้นเดียวกันมีพฤติกรรมในทางเดียวกัน ดังนั้นตัวตัดสินใจพฤติกรรมของนิวรอนจึงเป็นฟังก์ชันกระตุ้นและรูปแบบการเชื่อมโยงค่าถ่วงน้ำหนักของนิวรอนในชั้นนั้น

การจัดวางนิวรอนเข้าสู่ชั้น (Layer) และการเชื่อมโยงรูปแบบภายในระหว่างชั้นเรียกว่า โครงสร้างโครงข่ายประสาทเทียม ประเภทของโครงสร้างการเชื่อมต่อโครงข่ายประสาทเทียม พอจะแบ่งออกเป็น 3 แบบคือ โครงข่ายประสาทเทียมแบบชั้นเดียว (Single Layer Neural Network) โครงข่ายประสาทเทียมแบบหลายชั้น (Multi Layer Neural Network) และโครงข่ายประสาทเทียมแบบแลตทิซ (Lattice Neural Network) ซึ่งแต่ละชนิดก็มีคุณลักษณะเด่นที่แตกต่างกันไป

### 4.3.1 โครงข่ายประสาทเทียมแบบชั้นเดียว (Single Layer Neural Network)

จะประกอบไปด้วยเซลล์ประสาทที่จัดเรียงตัวอยู่ในชั้นต่างๆ อันได้แก่ ชั้นอินพุต และชั้นเอาต์พุต สาเหตุที่จัดโครงสร้างแบบนี้เป็นแบบชั้นเดียว เนื่องจากเรานับชั้นเอาต์พุตเพียงชั้นเดียวเท่านั้นว่า เป็นชั้นของเซลล์ประสาท สำหรับชั้นอินพุตเราไม่พิจารณาว่าเป็นชั้นของเซลล์ประสาทก็เพราะเป็นชั้นที่ไม่มีกระบวนการใดๆ จะทำหน้าที่เพียงแคร์รับข้อมูลอินพุตเข้ามาและส่งต่อให้กับชั้นถัดไปเท่านั้น รูปที่ 4.2 แสดงโครงสร้างของโครงข่ายประสาทเทียมแบบชั้นเดียว




รูปที่ 4.2 แสดงโครงสร้างของโครงข่ายประสาทเทียมแบบชั้นเดียว

### 4.3.2 โครงข่ายประสาทเทียมแบบหลายชั้น (Multi Layer Neural Network)

สืบเนื่องจากในปี 1969 Minsky และ Seymour Papert ได้พิสูจน์ให้เห็นว่า โครงข่ายประสาทเทียมแบบชั้นเดียวมีข้อจำกัด ไม่สามารถนำมาใช้แก้ปัญหาง่ายๆ ในบางกรณีได้ นักวิจัยจึงได้นำเสนอรูปแบบของโครงข่ายประสาทเทียมแบบหลายชั้น ซึ่งมีโครงสร้างประกอบขึ้นจากการจัดเรียงตัวของเซลล์ประสาทตั้งแต่ 2 ชั้นขึ้นไป (ไม่นับรวมชั้นอินพุต) โดยปกติโครงข่ายประสาทเทียมแบบหลายชั้นจะประกอบด้วยโครงข่ายประสาทเทียมแบบชั้นเดียวหลายๆ ตัวต่ออยู่ในโครงสร้างที่มีลำดับชั้นลดลั่นกันลงไป โดยอยู่ในรูปของการทำงานที่ป้อนไปข้างหน้า (Feedforward) ซึ่งชั้นที่อยู่ระหว่างชั้นอินพุตและชั้นเอาต์พุต เรียกว่า ชั้นซ่อน (Hidden Layer) ซึ่งชั้นซ่อนนี้เองที่เป็นตัวเพิ่มความสามารถให้แก่โครงข่าย ทั้งนี้จำนวนของชั้นซ่อนสามารถมีได้มากกว่า 1 ชั้น จำนวนของชั้นซ่อนและจำนวนของนิวรอนในแต่ละชั้นจะมีค่าไม่คงที่ ซึ่งแต่ละชั้นอาจจะมีจำนวนนิวรอนที่แตกต่างกันขึ้นอยู่กับการประยุกต์ใช้งาน ซึ่งจะเป็นคำถามที่ว่าผู้พัฒนา

จะต้องใช้จำนวนชั้นซ่อนเท่าใด และจำนวนนิวรอนต่อชั้นควรเป็นเท่าใด โดยปกติจะใช้กระบวนการตัดทอนและพิสูจน์ (Cut – and – Try Process) นั่นคือ ใช้นิวรอนให้เยอะๆ ไว้ก่อน แล้วค่อยๆ ลดลง มาจนได้จำนวนน้อยที่สุดที่ โครงข่ายประสาทเทียมยังคงเรียนรู้ได้ โดยเทคนิคนี้จะเรียกว่า การตัดทอน (Pruning)

อีกวิธีหนึ่งที่จะทำให้แน่ใจว่า ตัวอย่างที่ใช้ในกระบวนการฝึกสอนโครงข่ายนั้นพอที่จะครอบคลุมข้อมูลทั้งหมดได้ ก็คือพยายามใช้ตัวอย่างที่มีจำนวนมากในการฝึกสอนโครงข่าย เพื่อให้ทว่าความรู้ที่มากขึ้นจะเป็นข้อมูลในการสร้างผลตอบสนองของโครงข่ายได้ดีขึ้น



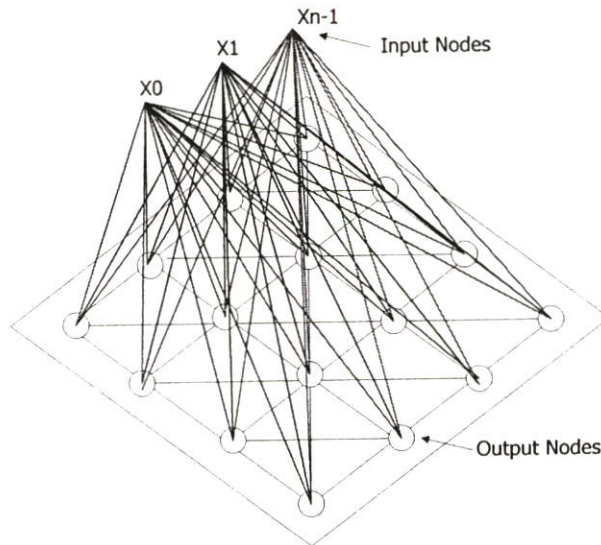
รูปที่ 4.3 แสดง โครงสร้างของโครงข่ายประสาทเทียมแบบหลายชั้น

จากรูปที่ 4.3 ชุดข้อมูลเอาต์พุตที่ได้จากชั้นหนึ่งจะถูกส่งให้เป็นข้อมูลอินพุตสำหรับชั้นต่อไป โดยค่าเอาต์พุตในชั้นสุดท้ายซึ่งก็คือ เอาต์พุตของโครงข่ายประสาทเทียมจะถูกนำไปเปรียบเทียบกับค่าความผิดพลาดกับค่าเอาต์พุตที่ต้องการ (Target Output) ค่าความผิดพลาดที่คำนวณได้จะนำไปใช้ในการปรับค่าถ่วงน้ำหนักของโครงข่ายประสาทเทียมให้เปลี่ยนไปในทางที่ถูกต้องมากขึ้น

#### 4.3.3 โครงข่ายประสาทเทียมแบบแลตทิซ (Lattice Neural Network) [25, 28]

โครงสร้างแบบแลตทิซนี้ อาจจะประกอบด้วยอาร์เรย์ (Array) ของนิวรอนเพียงมิติเดียว (One Dimension) หรือหลายมิติก็ได้ แต่ละนิวรอนจะรับข้อมูลจากโนดอินพุต มิติของโครงสร้างแบบแลตทิซ คือ มิติการจัดเรียงนิวรอน ซึ่งสามารถเปรียบเทียบกับมิติของรูปทรงได้ดังนี้ มิติเดียวสำหรับ โครงสร้างแบบแลตทิซหมายถึง การจัดเรียงนิวรอนในแนวนอนหรือแนวตั้งอย่างใดอย่าง

หนึ่งเพียงแถวเดียว กรณี 2 มิติสำหรับโครงสร้างแลตทิซเป็นการจัดเรียงนิวรอนทั้งในแนวนอนและแนวตั้ง และ 2 มิติสำหรับรูปทรงแสดงว่า รูปทรงนั้นมีทั้งความกว้างและความยาว รูปที่ 4.4 แสดงตัวอย่างโครงสร้างแบบ 2 มิติที่มีขนาดนิวรอน  $4 \times 4$  นิวรอน



รูปที่ 4.4 แสดงโครงสร้างของโครงข่ายประสาทเทียมแบบแลตทิซ

ตัวอย่างของโครงข่ายประสาทเทียมที่มีการจัดเรียงเช่นนี้ คือ โครงข่ายประสาทเทียมชนิด Self Organizing Maps ซึ่งจะมีโหนดคอมแพคทีฟที่พัวเรียงกันระนาบสองมิติ การเชื่อมโยงภายในระหว่างนิวรอนในชั้นคอมแพคทีฟมีการเชื่อมโยงอย่างทั่วถึง เมื่อโหนดคอมแพคทีฟที่รับข้อมูลอินพุตจากชั้นอินพุตแล้ว จะนำข้อมูลไปประมวลผลหาโหนดที่เป็นตัวแทนอินพุต โดยเลือกโหนดที่ค่าอินพุตและค่าถ่วงน้ำหนักที่เชื่อมกับโหนดนั้นแตกต่างกันน้อยที่สุด และเรียกโหนดนี้ว่า โหนดชนะ (winner node) แล้วปรับค่าถ่วงน้ำหนักให้ โหนดชนะและโหนดข้างเคียงที่อยู่ในขอบเขตพื้นที่ข้างเคียงที่กำหนดเท่านั้น

#### 4.4 การกำหนดค่าถ่วงน้ำหนัก (Setting the Weights) [25, 27]

นอกจากโครงสร้างของโครงข่ายประสาทเทียม วิธีกำหนดค่าถ่วงน้ำหนัก (ฝึกสอน) เป็นสิ่งสำคัญที่เห็นความแตกต่างลักษณะเฉพาะของโครงข่ายประสาทเทียมชนิดต่างๆ

ค่าถ่วงน้ำหนัก มีความสัมพันธ์กับอะไร และมีการเปลี่ยนแปลงอย่างไร? นั่นก็เช่นเดียวกันกับเด็กที่คลอออกมา ก็มีสมองแล้วแต่สมองยังไม่เจริญเติบโตเพียงพอและยังไม่ได้รับการฝึกสอนและเรียนรู้ เด็กจึงไม่สามารถทำกิจกรรมใดๆ ได้ด้วยตัวเอง เว้นแต่กิจกรรมที่ธรรมชาติสร้างมาพร้อมกับการกำเนิดที่เรียกว่า “สัญชาตญาณ” ซึ่งธรรมชาติใส่คุณลักษณะบางอย่างให้เซลล์สมองบางส่วน ตั้งแต่ทารกเจริญเติบโตอยู่ครรภ์มารดา เช่น ระบบควบคุมการหายใจ การเรียกร้องเมื่อหิว ความรู้สึก เป็นต้น เด็กจะพัฒนาการเรียนรู้ไปตามขั้นตอน หลังจากนั้น สมองของเขาจะได้รับการ

ฝึกสอน และเจริญเติบโตไปพร้อมกัน เซลล์สมองจะได้รับการปรับคุณลักษณะสอดคล้องกับการฝึกสอน และจะเจริญเติบโตเป็นโครงข่ายสอดคล้องกัน

โครงข่ายประสาทเทียมที่สร้างขึ้นมามีลักษณะเช่นเดียวกัน คือ เมื่อสร้างเสร็จแต่ละเซลล์ประสาทที่สร้างขึ้นมานั้น จะไม่มีคุณลักษณะใดเลย เนื่องจากยังไม่มีกำหนดค่าซินแนปติกส์เวกซ์ที่เหมาะสมกับงานที่ต้องการให้กับมัน จึงต้องมีการฝึกสอนเพื่อให้โครงข่ายประสาทเทียมที่สร้างขึ้นมีคุณลักษณะตามที่ต้องการ การฝึกสอนของโครงข่ายประสาทเทียมจะกระทำโดยการปรับเปลี่ยนค่าซินแนปติกส์เวกซ์เพื่อให้โครงข่ายประสาทเทียมจดจำรูปแบบความสัมพันธ์ระหว่างอินพุตกับเอาต์พุตได้ โดยในขั้นตอนแรกอาจกำหนดเป็นค่าสุ่มใดๆ (Random weight) ก่อนแล้วจึงปรับเปลี่ยนค่าถ่วงน้ำหนักไปตามอัลกอริทึมสมมติฐานหลายๆ รอบจนกว่าจะได้เอาต์พุตของโครงข่ายประสาทเทียม เหมือนกับเอาต์พุตของโครงข่ายประสาทเทียมที่ต้องการ ในเงื่อนไขความผิดพลาดที่ยอมรับได้

เนื่องจากการกำหนดค่าถ่วงน้ำหนักที่เป็นค่าสุ่มใดๆ โครงข่ายประสาทเทียมจึงยังไม่สามารถแสดงคุณลักษณะใดออกมา การฝึกสอนให้โครงข่ายก็คือ การปรับค่าถ่วงน้ำหนักทุกๆ จุดให้สอดคล้องกับอินพุตหลายๆ แบบ เพื่อให้ได้เอาต์พุตตามความต้องการนั่นเอง การฝึกสอนโครงข่ายประสาทเทียมจะต้องบรรลุถึงกระบวนการเข้าใจพื้นฐานเสียก่อน คือ การเรียนรู้ในโครงข่ายประสาทเทียมนั้นก็มีขีดจำกัด ปัญหาต่างๆ ผู้ใช้คงต้องแก้ให้มันก่อน แล้วนำผลนั้นไปอ้างอิงสำหรับการปรับปรุงค่าถ่วงน้ำหนัก หลังจากปรับจนได้ค่าผิดพลาดที่เอาต์พุตเทียบกับเอาต์พุตเป้าหมายน้อยลงเป็นที่พอใจแล้ว โครงข่ายประสาทเทียมนั้นก็พร้อมที่จะวิเคราะห์อินพุตและให้เอาต์พุตตามลักษณะตัวอย่างที่เคยเรียนรู้มา การเรียนรู้จะมีการปรับค่าถ่วงน้ำหนักหลายๆ รอบ จนค่าถ่วงน้ำหนักสอดคล้องกับตัวอย่างหลายๆ ตัวอย่างแล้วจะสามารถให้เอาต์พุตได้ตามต้องการ พบว่าโครงข่ายประสาทเทียมที่ได้ตัวอย่างสำหรับการปรับสอนมากๆ โครงข่ายก็จะมีความแม่นยำสูงขึ้น แต่ก็ใช้เวลาในการปรับสอนเพิ่มขึ้นเช่นกัน

โดยปกติ โครงข่ายประสาทเทียมสามารถแบ่งออกเป็น 2 ประเภทใหญ่ๆ ตามลักษณะการเรียนรู้คือ การเรียนรู้แบบควบคุม (Supervised Learning) และการเรียนรู้แบบอิสระ (Unsupervised Learning) ในจุดนี้มีความคลุมเครือในการเรียกวิธีฝึกสอน เนื่องจากนักวิจัยบางคนค้นพบวิธีที่สามคือ การเรียนรู้แบบกำหนดค่าถ่วงน้ำหนัก (fixed-weight) ซึ่งโครงข่ายประสาทเทียมที่ค่าถ่วงน้ำหนักถูกกำหนดโดยปราศจากขั้นตอนฝึกสอนหลายๆ รอบ นอกจากนี้ ยังมีกฎหลายชนิดที่ใช้ปรับค่าถ่วงน้ำหนักระหว่างการฝึกสอน และกฎการเรียนรู้ได้อธิบายในตอนท้ายหัวข้อนี้

#### 4.4.1 การเรียนรู้แบบควบคุม (Supervised Learning)

การแก้ปัญหาของโครงข่ายประสาทเทียมส่วนใหญ่ถูกฝึกสอนด้วยการควบคุม การเรียนรู้วิธีนี้ จะมีการกำหนดคู่ของการฝึกสอนระหว่างอินพุตกับเอาต์พุตที่ต้องการให้โครงข่ายประสาทเทียมที่ เรียกว่า เทรนนิ่งแพร์ (Training pairs) โครงข่ายประสาทเทียมจะถูกฝึกสอนไปตามจำนวนของคู่ที่ ป้อน (จำนวนคู่ของ อินพุตกับเอาต์พุตที่ต้องการให้โครงข่ายประสาทเทียมรู้จัก) เอาต์พุตที่คำนวณ ได้จากโครงข่ายประสาทเทียมจะถูกเปรียบเทียบให้สอดคล้องกับเป้าหมาย ค่าผิดพลาดที่เกิดขึ้นจะ ถูกป้อนกลับไปยังโครงข่ายประสาทเทียมและเปลี่ยนแปลงค่าถ่วงน้ำหนักให้สอดคล้องกับ อัลกอริทึม ที่ทำให้แนวโน้มของค่าผิดพลาดที่เกิดขึ้นระหว่างเอาต์พุตกับเป้าหมายโดยเฉลี่ยมีค่า ลดต่ำลง การลดลงของค่าผิดพลาดนี้ถูกคำนวณตลอดเวลาโดยการเปลี่ยนแปลงค่าถ่วงน้ำหนักอย่าง ต่อเนื่อง จนกระทั่งถึงค่าความถูกต้องของโครงข่ายที่ยอมรับได้ ขั้นตอนนี้เรียกว่า การฝึกสอนหรือ การเรียนรู้แบบควบคุม

หลังจากฝึกสอน โครงข่ายประสาทเทียมถูกทดสอบด้วยข้อมูลชุดทดสอบ ซึ่งเป็นชุดข้อมูลที่ไม่เคยเห็นมาก่อน กล่าวอีกนัยหนึ่งคือ ชุดข้อมูลที่ไม่อยู่ในชุดฝึกสอนและตรวจสอบ โครงข่าย ประสาทเทียมจะถูกทดสอบโดยให้เฉพาะค่าอินพุต แต่ไม่ให้ค่าเอาต์พุตที่ต้องการ และพิจารณา เอาต์พุตที่ได้จากโครงข่ายประสาทเทียมใกล้เคียงกับค่าเอาต์พุตที่ต้องการหรือไม่ ถ้าโครงข่าย ประสาทเทียมไม่ให้ค่าเอาต์พุตที่เป็นไปตามเหตุผล (ผลตอบสนอง) สำหรับชุดทดสอบนี้ แสดงว่า ระยะเวลาในการฝึกสอนยังไม่เสร็จเรียบร้อย ถ้าโครงข่ายประสาทเทียมไม่สามารถแก้ปัญหาย่าง ง่ายๆ ได้ แสดงว่า ผู้ออกแบบโครงข่ายควรรหาข้อมูลที่ดีที่สุดให้สัมพันธ์กับโครงสร้างของโครงข่าย ประสาทเทียมสำหรับปัญหาดังกล่าว ผู้ออกแบบควรทบทวนข้อมูลอินพุตและเอาต์พุต, จำนวนชั้น ของโครงข่าย, จำนวนนิเวรอนต่อชั้นของโครงข่าย, การเชื่อมโยงหรือฟังก์ชันกระตุ้นระหว่าง ชั้นของโครงข่าย, ฟังก์ชันการฝึกสอนและกำหนดค่าถ่วงน้ำหนักเริ่มต้นรวมไปถึงกฎการเรียนรู้ ยังมีกฎหลายชนิดที่ใช้ดำเนินการป้อนกลับไปให้เหมาะสมเพื่อปรับปรุงค่าถ่วงน้ำหนักระหว่างฝึกสอน

#### 4.4.2 การเรียนรู้แบบอิสระ (Unsupervised Learning)

ถึงแม้ว่า อัลกอริทึมแบบควบคุม สามารถจะประยุกต์ใช้เพื่อปรับคุณลักษณะของโครงข่าย ประสาทเทียมได้สำเร็จ แต่ก็ยังมีข้อด้อยอยู่ คือ มันเป็นไปอย่างแบบชีวภาพไม่ได้ และยากที่จะเชื่อ ได้ว่า กลไกการปรับสอนของสมองที่ต้องการ การเปรียบเทียบระหว่างค่าที่ต้องการกับเอาต์พุตจริง โดยกระบวนการป้อนกลับไปแก้ไขคุณลักษณะของโครงข่ายประสาทเทียม และถ้าสมมุติว่า สมอง มีกลไกเช่นนี้ ต้องมีผู้หาเอาต์พุตที่ต้องการเพื่อนำมาเป็นเป้าหมายตลอดเวลา และจะเอามาจากที่ใด กล่าวโดยสรุปก็คือ ต้องมีผู้คิดเป้าหมายให้กับโครงข่ายประสาทเทียมก่อน โครงข่ายประสาทเทียม

ไม่สามารถคิดและปรับคุณลักษณะได้ก่อนด้วยตนเอง ในทางตรงกันข้ามหากพิจารณาทารกแรกเกิดสมองของทารกสามารถจัดระบบเองได้อย่างไร การปรับสอนแบบอิสระที่สร้างขึ้นยังคงห่างไกลความเป็นไปได้ที่จะมีลักษณะการปรับสอนแบบระบบของสมอง

จนกระทั่งมีการพัฒนาการ ปรับสอนแบบอิสระนี้ขึ้นราวปี 1984 โดยโคโฮเนน (Kohonen) และคณะ ได้เสนอแนวคิดการปรับสอนแบบไม่ต้องการเป้าหมายไม่มีการตัดสินใจด้วยเหตุผลในอุดมคติมาก่อน ชุดของการปรับสอนจะมีเพียงอินพุทเวกเตอร์เท่านั้น แต่ไม่มีค่าเอาต์พุทที่ออกแบบไว้ อัลกอริทึมปรับสอนจะเปลี่ยนแปลงค่าถ่วงน้ำหนักของโครงข่ายประสาทเทียม เพื่อสร้างเอาต์พุทที่มีความมั่นคง ถ้าเอาต์พุทมีการเปลี่ยนแปลงไปเล็กน้อย โครงข่ายประสาทเทียมก็ยังสามารถบอกได้ว่าคือเอาต์พุทตัวเดิม จึงกล่าวได้ว่า การเรียนรู้แบบอิสระเป็นการฝึกสอนโครงข่ายประสาทเทียมที่สำคัญในอนาคต อย่างไรก็ดี ในปัจจุบันการเรียนรู้แบบอิสระยังไม่เป็นที่แพร่หลายมากนัก เนื่องจาก การฝึกสอนวิธีนี้จะไม่สามารถแก้ปัญหาที่ซับซ้อนได้ ดังนั้นจึงนิยมใช้โครงข่ายประสาทเทียมแบบนี้กับงานง่ายๆ ประเภทการเปรียบเทียบเอกลักษณ์รูปแบบที่สัมพันธ์กันระหว่างอินพุทและเอาต์พุท ที่ถูกกำหนดโดยโครงข่ายประสาทเทียม

#### 4.4.3 การเรียนรู้แบบกำหนดค่าถ่วงน้ำหนัก (Fixed-weight nets)

ยังคงมีโครงข่ายประสาทเทียมบางชนิดที่สามารถแก้ปัญหาการหาค่าเหมาะสมที่บีบบังคับ เช่น ปัญหาการเดินทางของพนักงานขาย (traveling salesman problem), ตารางเวลาในร้านค้า (job shop scheduling) เป็นต้น โครงข่ายบางชนิดอาจทำงานสำหรับปัญหาที่ให้ความยุ่งยากเมื่อใช้เทคนิคเดิม เนื่องจาก โครงข่ายประสาทเทียมมีข้อดีแฝงในตัวโครงข่ายเองหลายๆ ข้อมากกว่าเทคนิคเดิมสำหรับบางชนิดปัญหาการหาค่าเหมาะสม โครงข่ายประสาทเทียมชนิด Boltzmann (ปราศจากการเรียนรู้) และโครงข่ายประสาทเทียมชนิด continuous Hopfield สามารถใช้สำหรับปัญหาการหาค่าเหมาะสมที่ถูกจำกัด (constrained optimization problems)

เมื่อโครงข่ายประสาทเทียมเหล่านี้ถูกออกแบบ, แต่ละนิวรอนแสดงสมมุติฐาน โดยที่นิวรอน “ทำงาน” ถ้าสมมุติฐานนั้นเป็นจริง ในทางกลับกัน นิวรอน “ยุติ” ถ้าสมมุติฐานเป็นเท็จ ค่าถ่วงน้ำหนักถูกกำหนดเพื่อแสดงทั้งการจำกัดของปัญหาและฟังก์ชันที่เป็นค่าเหมาะสม การแก้ปัญหาสัมพันธ์กับค่าต่ำสุดของฟังก์ชันความแข็งแรง (minimum of an energy function) หรือค่าสูงสุดของฟังก์ชันเอกฉันท (maximum of a consensus function) สำหรับโครงข่ายประสาทเทียมระดับการกระตุ้นของแต่ละนิวรอนถูกปรับปรุงดังนั้น โครงข่ายประสาทเทียมจะหาค่าสูงสุดหรือต่ำสุดที่ต้องการ

#### 4.4.4 กฎการเรียนรู้ (Learning laws)

ในปัจจุบันมีกฎการเรียนรู้มากมายที่ถูกนำมาใช้งาน โดยส่วนใหญ่กฎเหล่านี้บางชนิดมีการพัฒนาหรือเปลี่ยนแปลงตามกฎการเรียนรู้ที่เก่าแก่และรู้จักกันดี นั่นคือ กฎของ Hebb งานวิจัยนำไปสู่ฟังก์ชันการเรียนรู้ต่างๆ เหมือนแนวความคิดใหม่ปรากฏในสิ่งพิมพ์อย่างต่อเนื่อง นักวิจัยบางท่านมีแบบจำลองการเรียนรู้ชีววิทยาเปรียบเหมือนเป้าหมายหลัก การเรียนรู้เป็นความซับซ้อนกว่าการแสดงให้เห็นง่ายด้วยกฎการเรียนรู้ที่พัฒนาในปัจจุบันอย่างไม่ต้องสงสัย ข้างล่างนี้เป็นกฎที่สำคัญและเป็นที่รู้จักกันดีถูกแสดงเป็นตัวอย่าง

1. **Hebb's Rule:** อย่างแรกเป็นที่รู้จักกันดีโดยไม่ต้องสงสัยว่า กฎการเรียนรู้ชนิดนี้ถูกแนะนำโดย Donald Hebb ในปี 1949 การอธิบายกฎชนิดนี้ได้ปรากฏในหนังสือที่ชื่อว่า “*The Organization of Behavior*” กฎพื้นฐานคือ ถ้านิวรอนได้รับอินพุตจากนิวรอนอื่น และถ้านิวรอนทั้งสองถูกกระตุ้นอย่างรุนแรง (ในทางคณิตศาสตร์ได้รับสัญญาณเหมือนกัน) ค่าถ่วงน้ำหนักระหว่างนิวรอนควรเข้มแข็งขึ้น
2. **Hopfield Law:** กฎการเรียนรู้ชนิดนี้คล้ายกับกฎของ Hebb นอกจาก กฎการเรียนรู้ชนิดนี้ระบุ (กำหนด) ขนาดเข้มแข็งหรืออ่อนแอ กฎการเรียนรู้ชนิดนี้ได้กล่าวว่า ถ้าเอาต์พุตที่ออกแบบและอินพุตถูกกระตุ้นทั้งคู่หรือไม่กระตุ้นทั้งคู่ ค่าถ่วงน้ำหนักที่เชื่อมโยงจะถูกเพิ่มด้วยอัตราการเรียนรู้ ในอีกทางหนึ่ง อัตราการเรียนรู้จะลดค่าถ่วงน้ำหนักด้วย
3. **The Delta Rule:** กฎการเรียนรู้ชนิดนี้เป็นหนึ่งในกฎการเรียนรู้ที่นิยมใช้กัน กฎการเรียนรู้นี้มีพื้นฐานจากความคิดง่ายๆ ของการเปลี่ยนแปลงความเข้มแข็งของการเชื่อมโยงอินพุตอย่างต่อเนื่องเพื่อลดความแตกต่างระหว่างค่าเอาต์พุตที่ออกแบบไว้กับค่าเอาต์พุตที่ได้จากโครงข่ายประสาทเทียม กฎการเรียนรู้นี้เปลี่ยนค่าถ่วงน้ำหนักในแนวทางที่ค่าผิดพลาดกำลังสองเฉลี่ยต่ำสุดของโครงข่ายประสาทเทียม กฎการเรียนรู้นี้ถูกอ้างอิงเหมือนกฎการเรียนรู้ Widrow-Hoff และกฎการเรียนรู้กำลังสองเฉลี่ยน้อยที่สุด (Least Mean Square : LMS)

การทำงานกฎเดลต้าคือ ค่าผิดพลาดผลต่างในชั้นเอาต์พุตถูกแปลงด้วยอนุพันธ์ของฟังก์ชันกระตุ้นและถูกใช้ในชั้นก่อนหน้าเพื่อปรับค่าถ่วงน้ำหนักเชื่อมโยงอินพุต อีกอย่างหนึ่ง ค่าผิดพลาดนี้ถูกแพร่ย้อนกลับเข้าสู่ชั้นก่อนหน้าหนึ่งชั้น ชั้นตอนแพร่ค่าย้อนกลับค่าผิดพลาดต่อเนื่องจนกระทั่งถึงชั้นแรกสุด โครงข่ายประสาทเทียมชนิดนี้เรียกว่า ป้อนไปข้างหน้า, การแพร่ค่าย้อนกลับมีที่มาจากวิธีคำนวณของเทอมค่าผิดพลาดเมื่อใช้กฎเดลต้า เป็นสิ่งสำคัญที่รับประกันว่า ข้อมูลอินพุตถูกสุ่มอย่างทั่วถึง การแสดง

โครงสร้างของชุดฝึกสอนสามารถนำไปสู่โครงข่ายซึ่งไม่สามารถลู่เข้าสู่ความถูกต้องที่ต้องการ ถ้าสิ่งนี้เกิดขึ้นดังนั้นโครงข่ายประสาทเทียมไม่สามารถเรียนรู้ปัญหาได้

4. **The Gradient Descent Rule:** กฎการเรียนรู้ชนิดนี้คล้ายกับกฎเคลด้าตรงที่อนุพันธ์ของฟังก์ชันกระตุ้นยังถูกใช้เพื่อเปลี่ยนแปลงค่าผิดพลาดผลต่างก่อนที่ถูกใช้ประยุกต์กับค่าถ่วงน้ำหนักเชื่อมโยง อย่างไรก็ตาม ค่าคงที่สัดส่วนที่เพิ่มเข้ามาสัมพันธ์กับอัตราการเรียนรู้ที่ถูกเพิ่มเป็นตัวประกอบเปลี่ยนแปลงสุดท้ายทำหน้าที่แทนค่าถ่วงน้ำหนัก กฎการเรียนรู้นี้ถูกใช้โดยทั่วไป ถึงแม้ว่ากฎการเรียนรู้นี้ลู่เข้าสู่จุดเสถียรภาพอย่างช้าๆ

กฎการเรียนรู้ชนิดนี้ถูกแสดงให้เห็นว่าอัตราเรียนรู้ที่แตกต่างกันสำหรับชั้นต่างๆ ของโครงข่ายประสาทเทียมมีส่วนช่วยขั้นตอนการเรียนรู้ลู่เข้าอย่างรวดเร็ว ในการทดสอบเหล่านี้ อัตราการเรียนรู้สำหรับชั้นเหล่านี้ที่ใกล้เอาต์พุตถูกกำหนดช้ากว่าชั้นที่ใกล้อินพุต สิ่งนี้เป็นสิ่งสำคัญเป็นพิเศษสำหรับการประยุกต์ที่ข้อมูลอินพุตไม่ถูกอนุพันธ์จากแบบจำลองที่ซ่อนเร้นความแข็งแรง

5. **Kohonen's Learning Law:** กฎการเรียนรู้ชนิดนี้ถูกคิดค้นโดย Teuvo Kohonen ซึ่งได้รับแรงบันดาลใจโดยเรียนรู้ในระบบชีววิทยา ในขั้นตอนนี้ สมาชิกประมวลผลแข่งขันชิงชัยสำหรับโอกาสเพื่อเรียนรู้หรือปรับปรุงค่าถ่วงน้ำหนักเหล่านี้ สมาชิกประมวลผลซึ่งเอาต์พุตใหญ่ที่สุดถูกประกาศเป็นผู้ชนะและมีความสามารถยับยั้งคู่แข่งรวมทั้ง กระตุ้นสมาชิกประมวลผลข้างเคียงด้วย ผู้ชนะเท่านั้นถูกยอมรับเป็นเอาต์พุต และผู้ชนะรวมทั้งสมาชิกประมวลผลข้างเคียงของผู้ชนะเท่านั้นถูกอนุญาตเพื่อปรับค่าถ่วงน้ำหนักเชื่อมโยงเหล่านี้

นอกจากนี้ ขนาดของที่อยู่ข้างเคียง สามารถเปลี่ยนแปลงระหว่างคาบฝึกสอน เนื่องจากสมาชิกผู้ชนะถูกนิยามให้มีหนึ่งเดียวซึ่งเหมาะสมที่สุดกับรูปแบบอินพุต สิ่งนี้เหมาะสมสำหรับแบบจำลองเชิงสถิติหรือเชิงทอพอโลยีของข้อมูล (topological modeling of the data) และบางครั้งถูกอ้างอิงเหมือนโครงข่ายประสาทเทียมชนิดจัดกลุ่มด้วยตัวเอง (self-organizing maps)

#### 4.5 ฟังก์ชันกระตุ้น (Activation function) [25, 28]

ฟังก์ชันกระตุ้นหรือหนังสือบางเล่มเรียกว่า ฟังก์ชันถ่ายโอน (Transfer function) เป็นตัวกำหนดค่าเอาต์พุต จึงกล่าวได้ว่า การเลือกฟังก์ชันกระตุ้นสามารถเปลี่ยนพฤติกรรมของโครงข่ายประสาทเทียมอย่างมาก ฟังก์ชันกระตุ้นที่ใช้ในการฝึกสอนโครงข่ายประสาทเทียมมีอยู่หลายชนิด ดังแสดงในตารางที่ 4.2 แต่อย่างไรก็ตาม ฟังก์ชันกระตุ้นที่นำมาใช้กับโครงข่ายประสาทเทียมมีเพียง 2-3 ชนิดเท่านั้นที่นิยมใช้กัน ฟังก์ชันกระตุ้นสามารถแบ่งออกได้เป็น 8 ชนิดด้วยกันคือ

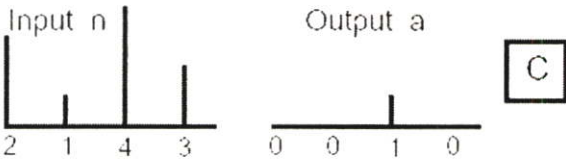
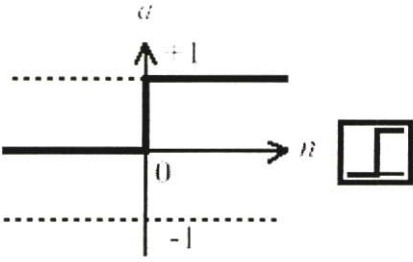
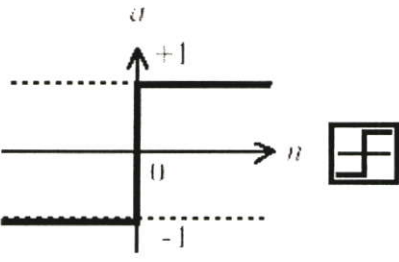
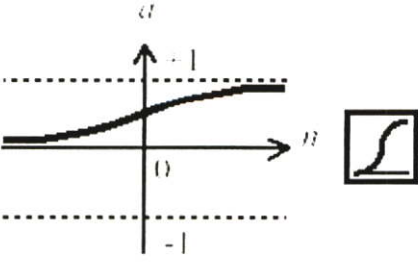
1. **Threshold Function or Hard Limit Function or Step Function** : ฟังก์ชันขั้นบันไดเป็นฟังก์ชันที่ทำงานเหมือนสวิตช์ กล่าวคือ ค่าเอาต์พุตมีค่าเท่ากับ “1” ถ้าอินพุตใหญ่กว่าค่าเริ่มต้น (ค่าที่กำหนดไว้) ในทางกลับกันค่าเอาต์พุตเป็น “0” เมื่ออินพุตมีค่าน้อยกว่าค่าเริ่มต้น
2. **Piecewise-Linear Function or Saturating Linear Function** : ฟังก์ชันเชิงเส้นอิ่มตัวเป็นฟังก์ชันที่คูณกับค่าอินพุตของโครงข่ายประสาทเทียมด้วยค่าคงที่เพื่อค่าเอาต์พุตที่ได้อยู่ภายในขอบเขตเส้นตรงปฏิบัติการ และกำหนดให้เอาต์พุตมีค่าเป็น “1” หรือ ไม่ก็เป็น “0” เมื่ออยู่ภายนอกขอบเขตเส้นตรงปฏิบัติการ
3. **Softmax** : ฟังก์ชันเลขชี้กำลังเป็นผลลัพธ์จากการทำให้เป็นบรรทัดฐาน ดังนั้นผลรวมของการกระตุ้นข้ามชั้นมีค่าเป็น “1” ฟังก์ชันชนิดนี้สามารถนำไปใช้ในชั้นเอาต์พุตของ Perceptron แบบหลายชั้นสำหรับปัญหาการแบ่งประเภท ดังนั้น เอาต์พุตที่ได้สามารถแปลความหมาย (แสดง) เหมือนความน่าจะเป็นของประเภทสมาชิก
4. **Square root** : ฟังก์ชันชนิดนี้ใช้เพื่อแปลงการกระตุ้นระยะห่างกำลังสองในโครงข่ายประสาทเทียมชนิดจัดกลุ่มด้วยตัวเอง (Self-organizing maps network or cluster network) เพื่อให้ได้ระยะห่างที่แท้จริงซึ่งเปรียบเสมือนค่าเอาต์พุต
5. **Identity** : ระดับการกระตุ้นส่งผ่านโดยตรงเหมือนค่าเอาต์พุต ฟังก์ชันชนิดนี้นำไปใช้ในโครงข่ายชนิดต่างๆ รวมทั้งโครงข่ายเชิงเส้น (Linear networks) และชั้นเอาต์พุตของโครงข่ายประสาทเทียมชนิดฟังก์ชันฐานรัศมี (Radial basis function)
6. **Exponential** : ฟังก์ชันเลขชี้กำลังติดลบ ฟังก์ชันชนิดนี้นำไปใช้ชั้นซ่อนหรือชั้นฐานรัศมีของโครงข่ายประสาทเทียมชนิดฟังก์ชันฐานรัศมี (Radial basis layer) การรวมของฟังก์ชันฐานรัศมีและฟังก์ชันกระตุ้นเลขชี้กำลังติดลบทำให้เกิดฟังก์ชันเกาส์เซียน (Gaussian function) หรือฟังก์ชันรูประฆัง (Bell-shaped) ศูนย์กลาง ณ เวกเตอร์ค่าถ่วงน้ำหนัก
7. **Competitive** : การทำบรรทัดฐานเอาต์พุตเพื่อผลรวมเป็น “1” ฟังก์ชันชนิดนี้นำไปใช้ในโครงข่ายประสาทเทียมชนิดความน่าจะเป็น (Probabilistic neural networks) เพื่อให้เอาต์พุตแสดงเหมือนความน่าจะเป็น

8. **Sigmoid Function** : ฟังก์ชันซิกมอยด์ (Sigmoid function) เป็นเส้นโค้งรูปตัว S (S-shaped curve) ฟังก์ชันชนิดนี้เป็นฟังก์ชันที่ได้รับความนิยมนำมาใช้เป็นฟังก์ชันกระตุ้นของโครงข่ายประสาทเทียมกันมาก เนื่องจากเป็นฟังก์ชันที่เพิ่มขึ้นอย่างสม่ำเสมอ (Smoothness) และมีคุณสมบัติเชิงเส้นกำกับ (Asymptotic properties) ฟังก์ชันซิกมอยด์โดยปกติแบ่งออกเป็นฟังก์ชันไฮเพอร์โบลิกแทนเจนต์ (Hyperbolic tangent function) และฟังก์ชันโลจิสติก (logistic function) ฟังก์ชันไฮเพอร์โบลิกแทนเจนต์มีรูปคล้ายกับฟังก์ชันโลจิสติก แต่ค่าถูกกระจายในช่วง  $(-1, 1)$  ส่วนฟังก์ชันโลจิสติกจะกระจายในช่วง  $(0, 1)$  ฟังก์ชันซิกมอยด์ทั้งสองมีคุณลักษณะที่สำคัญ 2 ประการคือ
- ฟังก์ชันไม่เป็นเชิงเส้นอย่างมากสำหรับค่าขนาดใหญ่ของการกระตุ้น ค่าเอาต์พุตถูกจำกัดด้วยฟังก์ชันกระตุ้น
  - ฟังก์ชันมีค่าต่อเนื่องและสามารถหาอนุพันธ์ได้อย่างต่อเนื่อง

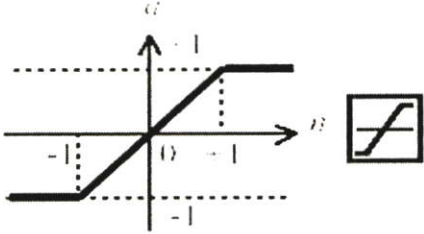
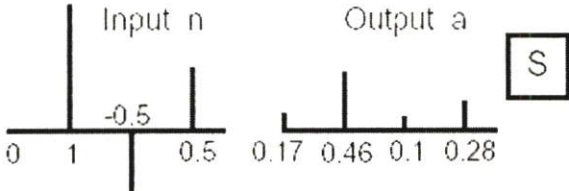
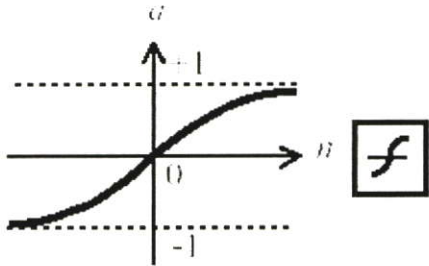
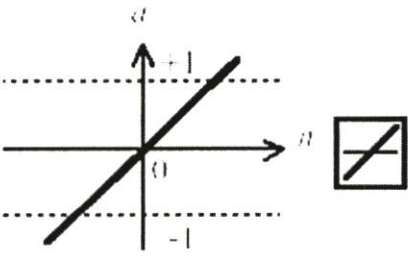
สำหรับการพิจารณาเลือกใช้ฟังก์ชันกระตุ้นแบบใดนั้นนับถึงปัจจุบันยังไม่มีข้อกำหนดที่แน่นอน ถึงแม้ว่าสิ่งนี้ไม่ได้กำหนดไว้ โดยส่วนใหญ่แล้วฟังก์ชันกระตุ้นแบบไม่เชิงเส้นถูกใช้เป็นฟังก์ชันกระตุ้นในชั้นซ่อน [29] ถ้าในชั้นซ่อนไม่มีความเป็นเชิงเส้น ในชั้นซ่อนนั้นไม่สามารถสร้างนิเวรอนให้มีความสามารถซึ่งเปรียบเสมือนโครงข่ายประสาทเทียมชนิด Perceptrons แบบทั่วไปสำหรับชั้นซ่อนแล้ว ฟังก์ชันชนิดซิกมอยด์และเกาส์เซียน (Sigmoid functions and gaussian functions) เป็นฟังก์ชันที่นิยมเลือกนำมาใช้งาน แต่โดยส่วนใหญ่จะเลือกฟังก์ชันซิกมอยด์เป็นฟังก์ชันมาตรฐาน หนึ่งในลักษณะเด่นของฟังก์ชันซิกมอยด์นั้นคือ ฟังก์ชันชนิดนี้สามารถหาอนุพันธ์ได้ ความสามารถนี้เมื่อนำไปใช้ในงานฝึกสอนโครงข่ายที่มีหลายชั้นจะช่วยเพิ่มความสามารถของโครงข่ายอย่างมาก ฟังก์ชันซิกมอยด์เช่น ฟังก์ชันไฮเพอร์โบลิกแทนเจนต์ (tanh) ที่ทำให้เกิดค่าในทั้งบวกและลบ  $(-1, +1)$  มีแนวโน้มที่จะฝึกสอนเร็วกว่าฟังก์ชันที่ทำให้เกิดเฉพาะค่าบวก  $(0, 1)$  เช่น ฟังก์ชันโลจิสติกเนื่องจากเงื่อนไขเชิงตัวเลขดีกว่าและสมมาตรของตัวฟังก์ชัน

สำหรับชั้นเอาต์พุต [29] ควรเลือกฟังก์ชันกระตุ้นให้เหมาะสมกับการกระจายของค่าเอาต์พุตเป้าหมาย เช่น สำหรับค่าเอาต์พุตเป้าหมายต่อเนื่องที่มีช่วงขอบเขต ฟังก์ชันกระตุ้นชนิดไฮเพอร์โบลิกแทนเจนต์สามารถนำไปใช้งาน สำหรับค่าเอาต์พุตเป้าหมายต่อเนื่องที่ไม่ทราบขอบเขต ใช้ฟังก์ชันกระตุ้นชนิดเชิงเส้น (Linear activation function) เป็นต้น กล่าวโดยสรุปก็คือ ในการเลือกฟังก์ชันกระตุ้นของชั้นเอาต์พุตควรทราบขอบเขตที่ต้องการและลักษณะของข้อมูลเอาต์พุต รวมไปถึงความเป็นเชิงเส้น หรือไม่เชิงเส้น

ตารางที่ 4.3 แสดงชนิดฟังก์ชันกระตุ้น [30]

ชนิดฟังก์ชันกระตุ้น	สมการฟังก์ชันกระตุ้น
<p>Competitive activation function</p> 	$a(n_i) = \begin{cases} 1; & i = i^* \\ 0; & i \neq i^* \end{cases}$ <p>when</p> $n_{i^*} \geq n_i, \forall i$ $i^* \leq i, \forall n_i = n_{i^*}$
<p>Hard limit activation function</p> 	$a(n) = \begin{cases} 1 & \text{if } n \geq 0 \\ 0 & \text{if } n < 0 \end{cases}$
<p>Symmetric hard limit activation function</p> 	$a(n) = \begin{cases} 1 & \text{if } n \geq 0 \\ -1 & \text{if } n < 0 \end{cases}$
<p>Log sigmoid activation function</p> 	$a(n) = \frac{1}{1 + e^{-n}}$

ตารางที่ 4.3 (ต่อ)

ชนิดฟังก์ชันกระตุ้น	สมการฟังก์ชันกระตุ้น
	$a(n) = \begin{cases} -1 & n \leq -1 \\ n & \text{if } -1 \leq n \leq 1 \\ 1 & 1 \leq n \end{cases}$
<p>Input n                      Output a</p> 	$a(n) = \frac{e^n}{\sum e^n}$
<p>Hyperbolic tangent sigmoid activation function</p> 	$a(n) = \frac{1 - e^{-2n}}{1 + e^{-2n}}$
<p>Linear activation function</p> 	$a(n) = n$

#### 4.6 โครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (Back-propagation NN)

ในปัจจุบันมีชนิดของโครงข่ายประสาทเทียมเป็นจำนวนมาก [29] ไม่มีใครรู้อย่างแน่นอนว่ามีอยู่จำนวนเท่าไร โครงข่ายประสาทเทียมชนิดใหม่ถูกสร้างขึ้นทุกๆ สัปดาห์ จึงกล่าวได้ว่าโครงข่ายประสาทเทียมในปัจจุบันมีหลากหลายชนิด ซึ่งนำไปใช้ในลักษณะงานที่แตกต่างกัน แต่มีเพียง 2-3 ชนิดที่นำมาในเชิงพาณิชย์ โครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (Back-propagation neural network) เป็นหนึ่งในโครงข่ายประสาทเทียมที่นิยมใช้ เนื่องจากโครงข่ายประสาทเทียมชนิดนี้สามารถใช้แก้ปัญหาได้เกือบทุกประเภท ดังนั้นในวิทยานิพนธ์นี้ได้เลือกใช้โครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับมาใช้งานในวิทยานิพนธ์ฉบับนี้


ก่อนที่จะกล่าวถึงพื้นฐานของโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ มีตัวพารามิเตอร์บางตัวที่ต้องเข้าใจเสียก่อน ในโครงข่ายประสาทเทียม ข้อมูลหรือตัวอย่าง (Sample) ถูกแยกย่อยเสมอเข้าไปในชุด ฝึกสอน (Training set), ชุดตรวจสอบ (Validation set) และชุดทดสอบ (Test set) ความแตกต่างระหว่างชุดย่อยเหล่านี้มีความสำคัญมาก ชุดตรวจสอบ และทดสอบถูกทำให้สับสนบ่อยๆ และในหนังสือของ Bishop [31] ในหน้า 372 ได้ทำการอธิบายและสรุปชุดตัวอย่างได้ตามนี้

ชุดฝึกสอน (Training set) : ชุดของตัวอย่างใช้เพื่อเรียนรู้ว่ามีพารามิเตอร์ (เช่น ค่าถ่วงน้ำหนัก) ของการแบ่งประเภท

ชุดตรวจสอบ (Validation set) : ชุดของตัวอย่างใช้ปรับพารามิเตอร์ (เช่น โครงสร้างไม่ใช่ค่าถ่วงน้ำหนัก) ของการแบ่งประเภท สำหรับตัวอย่างที่เลือกจำนวนของชั้นซ่อนในโครงข่ายประสาทเทียม

ชุดทดสอบ (Test set) : ชุดของตัวอย่างใช้ประเมินการปฏิบัติของการแบ่งประเภทที่ระบุไว้

กล่าวโดยสรุปก็คือ ชุดทดสอบเป็นชุดข้อมูลที่ไม่เคยใช้เพื่อเลือกระหว่าง 2 โครงข่าย ส่วนชุดตรวจสอบเป็นชุดข้อมูลใดๆ ที่ใช้เพื่อตัดสินใจหยุดการฝึกสอนเท่านั้น โดยตรวจสอบค่าผิดพลาดและค่าผิดพลาดของชุดตรวจสอบนี้ที่ได้ ถูกนำไปใช้ในการเลือกโครงสร้างของโครงข่ายประสาทเทียม (จำนวนชั้นซ่อนและจำนวนนิวรอนในชั้นซ่อนของโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ) ยกตัวอย่างเช่น จากรูปข้างล่าง ทำการวาดกราฟเปรียบเทียบระหว่าง ค่าผิดพลาดของชุดตรวจสอบ ( $e_{val}$ ) และฝึกสอน ( $e_{train}$ ) ณ ช่วงสิ้นสุดในแต่ละรอบการฝึกสอน ตามลำดับ ในแต่ละรอบดังแสดงตามรูปที่ 4.5 [26] โดยปกติในการพิจารณาเลือกโครงข่ายที่ดีที่สุด ควรพิจารณากับชุดตรวจสอบ ไม่ควรพิจารณากับชุดทดสอบและชุดฝึกสอน จากรูปข้างล่างนี้ ควรหยุดฝึกสอน ณ ค่าผิดพลาดของชุดตรวจสอบ ( $e_{val}$ ) มีค่าต่ำสุดหรือมีค่าน้อยกว่าค่าที่กำหนดไว้




รูปที่ 4.5 แสดงการเปรียบเทียบค่าความผิดพลาดของชุดฝึกสอน ( $e_{train}$ ) กับชุดตรวจสอบ ( $e_{val}$ )

เมื่อทำความเข้าใจกับพารามิเตอร์เหล่านี้ หัวข้อถัดไปจะขอกกล่าวถึงพื้นฐานของโครงข่ายประสาทเทียมที่ได้ในวิทยานิพนธ์ฉบับนี้ซึ่งเป็นโครงข่ายประสาทเทียมที่มีอยู่ในโปรแกรม MATLAB/ Neural Network Toolbox [25]

#### 4.6.1 โครงสร้าง [25, 30]

โครงสร้างพื้นฐานของโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (Back-propagation neural network : BP) ประกอบด้วยนิวรอนเซลล์ที่เรียงกันอยู่มากกว่า 2 ชั้นกล่าวคือ มีได้ตั้งแต่ 3 ชั้นขึ้นไป ซึ่งประกอบด้วย ชั้นอินพุท (Input layer), ชั้นซ่อน (Hidden layer) และ ชั้นเอาต์พุท (Output layer) ลักษณะของโครงข่ายชนิดนี้เป็นโครงข่ายที่ป้อนไปข้างหน้า โดยมีการเชื่อมโยงในแต่ละชั้นแบบต่อถึงกันหมด นั่นคือ ทุกๆ นิวรอนในชั้นอินพุทจะส่งสัญญาณไปยังทุกๆ นิวรอนในชั้นซ่อนชั้นแรก และทุกๆ นิวรอนในชั้นซ่อนชั้นแรกจะส่งสัญญาณไปยังทุกๆ นิวรอนในชั้นถัดไปจนในที่สุดทุกๆ นิวรอนในชั้นซ่อนสุดท้ายจะส่งสัญญาณไปยังทุกๆ นิวรอนในชั้นเอาต์พุท จากรูปที่ 4.6 แสดงโครงสร้างพื้นฐานของโครงข่ายที่มี 3 ชั้น



รูปที่ 4.6 แสดงแบบจำลองของโครงข่ายประสาทเทียมที่มี 2 ชั้นซ่อน [30]

รูปที่ 4.6 แสดงโครงข่ายประสาทเทียมที่มี 2 ชั้นซ่อน มีอินพุต  $R$  ชุด, นิวรอนในชั้นซ่อนที่ 1 และ 2 เท่ากับ  $S^1$  และ  $S^2$  และมีเอาต์พุต  $S^3$  ชุด สมาชิกของอินพุตเวกเตอร์  $P$  แต่ละตัวจะถูกเชื่อมเข้ากับนิวรอนแต่ละนิวรอนในชั้นซ่อนที่ 1 ด้วยค่าถ่วงน้ำหนัก  $W^1$  (เรียกว่า Input weight,  $IW^{1,1}$ ) ซึ่งเป็นเมตริกซ์ขนาด  $S^1 \times R$  และเวกเตอร์  $a^1$  ซึ่งเป็นผลลัพธ์ของชั้นซ่อนที่ 1 และมีขนาด  $S^1$  จะเป็นอินพุตของชั้นซ่อนที่ 2 สมาชิกแต่ละตัวของเวกเตอร์  $a^1$  ก็จะถูกเชื่อมเข้ากับนิวรอนแต่ละนิวรอนในชั้นซ่อนที่ 2 ด้วยค่าถ่วงน้ำหนัก  $W^2$  (เรียกว่า Layer weight,  $LW^{2,1}$ ) ซึ่งเป็นเมตริกซ์ขนาด  $S^2 \times S^1$  เช่นเดียวกับกับชั้นซ่อนที่ 1 เวกเตอร์  $a^2$  ซึ่งเป็นผลลัพธ์ของชั้นซ่อนที่ 2 และมีขนาด  $S^2$  จะเป็นอินพุตของชั้นข้อมูลเอาต์พุต สมาชิกแต่ละตัวของเวกเตอร์  $a^2$  จะถูกเชื่อมเข้ากับนิวรอนแต่ละตัวในชั้นข้อมูลเอาต์พุตด้วยค่าถ่วงน้ำหนัก  $W^3$  ( $LW^{3,2}$ ) ซึ่งเป็นเมตริกซ์ขนาด  $S^3 \times S^2$  โดยที่เวกเตอร์  $a^3$  ซึ่งเป็นเมตริกซ์ขนาด  $S^3$  จะเป็นผลลัพธ์ของโครงข่ายประสาทเทียม

#### 4.6.2 แนวคิด [25]

ขั้นตอนการฝึกสอนของโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ จะสามารถแบ่งออกเป็น 3 ขั้นตอนด้วยกัน คือ ป้อนข้อมูลอินพุตไปข้างหน้า แพร่ค่าย้อนกลับของค่าผิดพลาดที่เกี่ยวข้อง และปรับค่าถ่วงน้ำหนัก ต่อไปเป็นรายละเอียดของการทำงานในแต่ละขั้นตอน

##### 1. แพร่ค่าป้อนไปข้างหน้า (Forward-propagation)

เมื่อข้อมูลอินพุตปรากฏบนชั้นอินพุต ( $P_{IR}, IR = 1, \dots, R$ ) สัญญาณจากชั้นอินพุตทั้งหมด จะถูกส่งมาตามสายเชื่อมโยงไปยังนิวรอนเซลล์ในชั้นถัดไป แต่ละนิวรอนในชั้นซ่อนที่ 1 ถูกเชื่อมโยงด้วยค่าถ่วงน้ำหนัก ( $iw_{LS^1, IR}^{1,1} = IS^1 = 1, \dots, S^1$ ) จะทำการคำนวณสัญญาณอินพุตของนิวรอนเซลล์ในชั้นซ่อนที่ 1 ได้จากสมการ

$$net_{LS^1} = b_{LS^1}^1 + \sum_{IR=1}^R iw_{LS^1, IR}^{1,1} P_{IR} \quad (4.1)$$

ใช้ฟังก์ชันกระตุ้นเพื่อคำนวณสัญญาณเอาต์พุต ( $a^1$ ) ในชั้นซ่อนที่ 1

$$a^1 = f(net_{LS^1}) \quad (4.2)$$

เมื่อ สัญญาณเอาต์พุต ( $a^1$ ) ในชั้นซ่อนที่ 1 เอาต์พุตที่ได้ส่งต่อไปยังชั้นซ่อนที่ 2 โดยแต่ละนิวรอนในชั้นซ่อนที่ 2 ถูกเชื่อมโยงด้วยค่าถ่วงน้ำหนัก ( $lw_{LS^2, LS^1}^{2,1} = LS^2 = 1, \dots, S^2$ ) จะทำการคำนวณสัญญาณอินพุตของนิวรอนเซลล์ในชั้นซ่อนที่ 2 ได้จากสมการ

$$net_{LS^2} = b_{LS^2}^2 + \sum_{LS^1=1}^{S^1} lw_{LS^2,LS^1}^{2,1} a^1 \quad (4.3)$$

ใช้ฟังก์ชันกระตุ้นเพื่อคำนวณสัญญาณเอาต์พุต ( $a^2$ ) ในชั้นซ่อนที่ 2

$$a^2 = f(net_{LS^2}) \quad (4.4)$$

เมื่อ สัญญาณเอาต์พุต ( $a^2$ ) ในชั้นซ่อนที่ 2 เอาต์พุตที่ได้ส่งต่อไปยังชั้นเอาต์พุต โดยแต่ละนิวรอนในชั้นเอาต์พุต ถูกเชื่อมโยงด้วยค่าถ่วงน้ำหนัก ( $lw_{LS^3,LS^2}^{3,2} = LS^3 = 1, \dots, S^3$ ) จะทำการคำนวณสัญญาณอินพุตของนิวรอนเซลล์ในชั้นเอาต์พุต ได้จากสมการ

$$net_{LS^3} = b_{LS^3}^3 + \sum_{LS^2=1}^{S^2} lw_{LS^3,LS^2}^{3,2} a^2 \quad (4.5)$$

ใช้ฟังก์ชันกระตุ้นเพื่อคำนวณสัญญาณเอาต์พุต ( $a^3$ ) ในชั้นเอาต์พุต

$$a^3 = f(net_{LS^3}) \quad (4.6)$$

## 2. แพร่ค่าย้อนกลับของค่าผิดพลาด (Back-propagation of error)

ในแต่ละนิวรอนของชั้นเอาต์พุต ค่าผิดพลาดของโครงข่ายจะเป็นผลต่างระหว่างเอาต์พุตเป้าหมายกับเอาต์พุตของโครงข่าย ( $t^3 - a^3$ ) ค่าผิดพลาดที่ได้จะถูกส่งกลับเข้ามายังโครงข่ายในรูปของสัญญาณค่าผิดพลาด (error signal) การหาสัญญาณค่าผิดพลาดที่ชั้นเอาต์พุต หาได้จากสมการ

$$\delta^3 = (t^3 - a^3) f'(net_{LS^3}) \quad (4.7)$$

คำนวณค่าถ่วงน้ำหนักที่เกี่ยวข้อง (ใช้เพื่อปรับปรุ้งค่าถ่วงน้ำหนัก  $lw_{LS^3,LS^2}^{3,2}$  หลังจากนี้) โดยที่  $\alpha$  คือ อัตราการเรียนรู้ (Learning rate)

$$\Delta lw_{LS^3,LS^2}^{3,2} = \alpha \delta^3 a^2 \quad (4.8)$$

คำนวณค่าไบอัส (bias) ที่เกี่ยวข้อง (ใช้เพื่อปรับปรุง  $b_{LS^3}^3$  หลังจากนี้)

$$\Delta b_{LS^3}^3 = \alpha \delta^3 \quad (4.9)$$

และส่ง  $\delta^3$  ไปที่ชั้นซ่อนที่ 2

ในแต่ละนิวรอนของชั้นซ่อนที่ 2 การหาสัญญาณค่าผิดพลาดที่ชั้นซ่อนที่ 2 หาได้จากสมการ

$$\delta^2 = \sum_{LS^3=1}^{S^3} \delta^3 w_{LS^3, LS^2}^{3,2} f'(net_{LS^2}) \quad (4.10)$$

คำนวณค่าถ่วงน้ำหนักที่เกี่ยวข้อง (ใช้เพื่อปรับปรุงค่าถ่วงน้ำหนัก  $w_{LS^2, LS^1}^{2,1}$  หลังจากนี้)

$$\Delta w_{LS^2, LS^1}^{2,1} = \alpha \delta^2 a^1 \quad (4.11)$$

คำนวณค่าไบอัส (bias) ที่เกี่ยวข้อง (ใช้เพื่อปรับปรุง  $b_{LS^2}^2$  หลังจากนี้)

$$\Delta b_{LS^2}^2 = \alpha \delta^2 \quad (4.12)$$

และส่ง  $\delta^2$  ไปที่ชั้นซ่อนที่ 1

ในแต่ละนิวรอนของชั้นซ่อนที่ 1 การหาสัญญาณค่าผิดพลาดที่ชั้นซ่อนที่ 1 หาได้จากสมการ

$$\delta^1 = \sum_{LS^2=1}^{S^2} \delta^2 w_{LS^2, LS^1}^{2,1} f'(net_{LS^1}) \quad (4.13)$$

คำนวณค่าถ่วงน้ำหนักที่เกี่ยวข้อง (ใช้เพื่อปรับปรุงค่าถ่วงน้ำหนัก  $w_{LS^1, IR}^{1,1}$  หลังจากนี้)

$$\Delta w_{LS^1, IR}^{1,1} = \alpha \delta^1 P_{IR} \quad (4.14)$$

คำนวณค่าไบอัส (bias) ที่เกี่ยวข้อง (ใช้เพื่อปรับปรุง  $b_{LS^1}^1$  หลังจากนี้)

$$\Delta b_{LS^1}^1 = \alpha \delta^1 \quad (4.15)$$

### 3. ขั้นตอนการปรับค่าถ่วงน้ำหนักและค่าไบแอส

ถ้าหากมีข้อผิดพลาดเกิดขึ้น ค่าผิดพลาดที่คำนวณได้จะถูกนำมาใช้ในการปรับน้ำหนักเพื่อให้โครงข่ายได้ผลลัพธ์ที่ถูกต้อง การปรับน้ำหนักสำหรับแต่ละนิวรอนในชั้นเอาต์พุต คำนวณได้จาก

$$lw_{LS^3, LS^2}^{3,2} (new) = lw_{LS^3, LS^2}^{3,2} (old) + \Delta lw_{LS^3, LS^2}^{3,2} \quad (4.16)$$

ส่วนการปรับน้ำหนักของชั้นซ่อนที่ 2 การทำงานจะเป็นเช่นเดียวกับสมการที่ 4.16 แต่ตัวแปรต่างๆ จะเป็นของชั้นซ่อนอยู่ สำหรับแต่ละนิวรอนในชั้นซ่อนที่ 2 ซึ่งสามารถหาได้จาก

$$lw_{LS^2, LS^1}^{2,1} (new) = lw_{LS^2, LS^1}^{2,1} (old) + \Delta lw_{LS^2, LS^1}^{2,1} \quad (4.17)$$

สำหรับแต่ละนิวรอนในชั้นซ่อนที่ 1

$$iw_{LS^1, IR}^{1,1} (new) = iw_{LS^1, IR}^{1,1} (old) + \Delta iw_{LS^1, IR}^{1,1} \quad (4.18)$$

การปรับค่าถ่วงน้ำหนักจะปรับทีละชั้นจากชั้นเอาต์พุตกลับไปยังชั้นอินพุต เมื่อเสร็จสิ้นก็จะกลับสู่ส่วนของป้อนไปข้างหน้าอีกครั้ง เพื่อหาค่าเอาต์พุตของโครงข่ายใหม่มาเปรียบเทียบกับค่าเอาต์พุตเป้าหมาย และดำเนินการปรับค่าถ่วงน้ำหนักในส่วนของแพร่ค่าย้อนกลับเช่นนี้ สลับกันไป โดยวัฏจักรของการคำนวณหาค่าความผิดพลาดและการปรับน้ำหนักจะคงดำเนินต่อไปจนกระทั่งค่าความผิดพลาดต่ำกว่าที่กำหนดไว้ค่าหนึ่งแล้วจึงหยุดกระบวนการ ค่าถ่วงน้ำหนักที่ได้จะเป็นค่าที่เหมาะสมสำหรับทุกคู่ของอินพุตและค่าเป้าหมาย ในการฝึกสอนโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ การคำนวณหาความผิดพลาดรวมของตัวอย่าง หาได้จากค่าเฉลี่ยของค่าผิดพลาดยกกำลังสอง (Mean-square error, MSE) ระหว่างคำตอบที่แท้จริง ( $t_i^3$ ) กับผลลัพธ์ของโครงข่ายประสาทเทียม ( $a_i^3$ ) ในสมการ (4.19)

$$MSE = \frac{1}{N} \sum_{i=1}^N (t_i^3 - a_i^3)^2 \quad (4.19)$$

โดยที่ N = จำนวนชุดของข้อมูลฝึกสอน

#### 4.6.3 กฎการเรียนรู้ [25, 30]

ในขั้นตอนการปรับน้ำหนักที่กล่าวมาข้างต้น เป็นหลักการพื้นฐานแต่ลำดับขั้นตอนการปรับค่าถ่วงน้ำหนักและค่าไบแอสของการฝึกสอนโครงข่ายประสาทเทียมชนิด Feed-forward Neural Networks โดยใช้ Neural Network Toolbox นั้นมีอยู่หลายวิธี แต่ละวิธีก็จะมีประสิทธิภาพและความรวดเร็วในการฝึกสอนแตกต่างกัน

ปัจจุบันจึงได้มีการพิจารณานำวิธีการของ Standard Numerical Optimization Techniques มาดัดแปลงใช้กับกฎการเรียนรู้แบบแพร่ค่าย้อนกลับแบบดั้งเดิม ได้แก่ Conjugate Gradient, Newton, Quasi-Newton และ Levenberg-Marquardt [30] ซึ่งวิทยานิพนธ์ฉบับนี้ใช้ Levenberg-Marquardt Algorithm เท่านั้น เนื่องจากพบว่าเป็นกฎการเรียนรู้ที่มีประสิทธิภาพและความรวดเร็วในการฝึกสอนสูงที่สุด สามารถฝึกสอนโครงข่ายประสาทเทียมได้รวดเร็วกว่าวิธีการอื่นๆ และเหมาะกับโครงข่ายประสาทเทียมที่มีจำนวนตัวแปรขนาดกลาง

การเรียนรู้แบบ Levenberg-Marquardt Algorithm เป็นการเรียนรู้แบบแพร่ค่าย้อนกลับที่ปรับปรุงมาจากวิธี Gauss-Newton Nonlinear Least Squares Optimization Algorithm โดยโครงข่ายประสาทเทียมปรับค่าถ่วงน้ำหนัก และค่าไบแอส ตามสมการที่ 4.20 ซึ่งเขียนในรูปของเมตริกซ์ดังนี้

$$x_{(new)} = x_{(old)} + \Delta x = x_{(old)} + [J^T \cdot J + \alpha I]^{-1} \cdot J^T \cdot e \quad (4.20)$$

โดยที่	x	คือ ค่าถ่วงน้ำหนัก(w) และค่าไบแอส (b)
	J	คือ จาโคเบียนเมตริกซ์ ( Jacobian matrix ) ของอนุพันธ์ของค่าผิดพลาด(แต่ละค่า) ต่อค่า x (แต่ละค่า)
	J <sup>T</sup>	คือ Transpose matrix ของ J
	e	คือ เมตริกซ์ของค่าผิดพลาด (Error) ระหว่างคำตอบ (Target , t <sup>3</sup> ) กับค่าที่โครงข่ายประสาทเทียมคำนวณได้ (Answer , a <sup>3</sup> )
	$\alpha$	คือ อัตราการเรียนรู้ (Learning rate)
	I	คือ Identity matrix

$$\text{จาโคเบียนเมตริกซ์ของ (w)} \quad J(\mathbf{w}) = \begin{bmatrix} \frac{\partial e_1}{\partial w_{1,1}} & \frac{\partial e_1}{\partial w_{1,2}} & \dots & \frac{\partial e_1}{\partial w_{1,s^2}} \\ \frac{\partial e_2}{\partial w_{2,1}} & \frac{\partial e_2}{\partial w_{2,2}} & \dots & \frac{\partial e_2}{\partial w_{2,s^2}} \\ \vdots & \vdots & \dots & \vdots \\ \frac{\partial e_s}{\partial w_{s^3,1}} & \frac{\partial e_s}{\partial w_{s^3,2}} & \dots & \frac{\partial e_s}{\partial w_{s^3,s^2}} \end{bmatrix} \quad (4.21)$$

$$\text{จาโคเบียนเมตริกซ์ของค่า (b)} \quad J(\mathbf{b}) = \begin{bmatrix} \frac{\partial e_1}{\partial b_1} \\ \frac{\partial e_2}{\partial b_2} \\ \vdots \\ \frac{\partial e_s}{\partial b_{s^3}} \end{bmatrix} \quad (4.22)$$

$$\text{เมตริกซ์ของค่าผิดพลาด} \quad \begin{bmatrix} e_1 \\ e_2 \\ \vdots \\ e_{s^3} \end{bmatrix} = \begin{bmatrix} t_1^3 - a_1^3 \\ t_2^3 - a_2^3 \\ \vdots \\ t_{s^3}^3 - a_{s^3}^3 \end{bmatrix} \quad (4.23)$$

ค่าอัตราการเรียนรู้จะมีค่าเริ่มต้นของการฝึกสอนด้วยค่าน้อยๆ เช่น เท่ากับ 0.001 และปรับเปลี่ยนในช่วงระหว่างกระบวนการฝึกสอน ขณะที่เริ่มกระบวนการฝึกสอนอินพุตทั้งหมดจะเข้าสู่โครงข่ายประสาทเทียม ซึ่งในทุกรอบของการฝึกสอนโครงข่ายประสาทเทียมจะคำนวณค่าผิดพลาดที่เกิดขึ้น และนำมาปรับเปลี่ยนค่าถ่วงน้ำหนักและค่าไบอัส ถ้าค่า E ใหม่น้อยกว่าค่า E เก่า ก็จะปรับลดค่าอัตราการเรียนรู้โดยคูณด้วยตัวคูณลด (Decreased Factor) ที่มีค่าเท่ากับ 0.1 และทำการฝึกสอนต่อไป แต่ถ้าค่า E ใหม่มากกว่าค่า E เก่า ดังนั้นค่า  $\Delta X$  ในสมการที่ 4.20 จะถูกปรับเพิ่มค่าอัตราการเรียนรู้โดยการคูณด้วยตัวคูณเพิ่ม (Increased Factor) ที่มีค่าเท่ากับ 10 จนกระทั่งค่า E มีค่าลดลง การฝึกสอนโครงข่ายประสาทเทียมจึงสิ้นสุดลง ถ้าหากค่าตัวประกอบเกรเดียนต์ (Gradient Factor) (ค่า  $J^T(\mathbf{w}) \cdot \mathbf{e}$  หรือ  $J^T(\mathbf{b}) \cdot \mathbf{e}$ ) มีค่าน้อยกว่าค่าต่ำสุดที่กำหนดไว้ เช่น  $1e^{-10}$  หรือเมื่อค่าอัตราการเรียนรู้ มีค่ามากกว่าค่าสูงสุดที่กำหนดไว้ เช่น  $1e^{10}$

ความแตกต่างระหว่างกฎการเรียนรู้ของ Gradient Descent กับ Levenberg-Marquardt คือ ในกฎการเรียนรู้ของ Levenberg-Marquardt นั้นอินพุตทั้งหมดถูกนำเข้าไปโครงข่ายประสาทเทียมที่เวลาเดียวกันในแต่ละรอบของการฝึกสอน ซึ่งค่าถ่วงน้ำหนักและค่าไบอัสจะถูกปรับเปลี่ยนผ่านสมการที่ 4.20 ส่วนกฎการเรียนรู้ของ Gradient Descent นั้นค่าถ่วงน้ำหนักและค่าไบอัสถูกปรับเปลี่ยนสำหรับแต่ละข้อมูลอินพุตในทุกรอบของการเรียนรู้ ซึ่งในแต่ละรอบการฝึกสอนนั้นกฎการเรียนรู้ของ Levenberg-Marquardt ใช้เวลาในการคำนวณและใช้หน่วยความจำมากกว่ากฎการเรียนรู้ของ Gradient Descent แต่อย่างไรก็ตามกฎการเรียนรู้ของ Levenberg-Marquardt ก็สามารถปรับตัวให้เข้ากับลักษณะของปัญหาและสามารถแก้ปัญหาด้วยจำนวนรอบที่น้อยกว่ากฎการเรียนรู้ของ Gradient Descent

#### 4.6.4 การจัดระเบียบข้อมูล (Normalization) ชุดข้อมูลฝึกสอน [26]

การจัดระเบียบข้อมูล (Normalization) เป็นวิธีการที่นำมาใช้เพิ่มความแม่นยำของเอาต์พุตที่ได้จากโครงข่ายประสาทเทียม และลดเวลาในการเรียนรู้ของโครงข่ายประสาทเทียม การจัดระเบียบข้อมูลนั้น จะต้องทำก่อนกระบวนการเรียนรู้ของโครงข่ายประสาทเทียมเพื่อให้ค่าของข้อมูลมีค่าเฉลี่ยเท่ากับศูนย์ และความแปรปรวนเท่ากับหนึ่ง

สำหรับจำนวนชุดข้อมูลด้านเข้าหรือด้านออกทั้งหมด ถ้าแต่ละชุดข้อมูลด้านเข้าและด้านออกประกอบด้วย “n” ชุดข้อมูล  $(X1_1, X1_2, \dots, X1_n)$  ดังนั้นจะสามารถจัดระเบียบข้อมูลชุดข้อมูลได้ โดยใช้สมการที่ 4.24 และ 4.25 ตามลำดับ

$$\text{ถ้า } X1 = \begin{bmatrix} X1_1 \\ X1_2 \\ \vdots \\ X1_n \end{bmatrix}; \mu_{X1} = \frac{\sum_{i=1}^n X1_i}{n} \text{ และ ถ้า } Y1 = \begin{bmatrix} Y1_1 \\ Y1_2 \\ \vdots \\ Y1_n \end{bmatrix} = \begin{bmatrix} X1_1 - \mu_{X1} \\ X1_2 - \mu_{X1} \\ \vdots \\ X1_n - \mu_{X1} \end{bmatrix}; \mu_Y = 0 \quad (4.24)$$

โดยที่ 
$$\sigma_{Y1} = \sqrt{\frac{\sum_{i=1}^n (Y1_i)^2}{n}}$$

$$\text{ถ้า } Z = \begin{bmatrix} Z_1 \\ Z_2 \\ \vdots \\ Z_n \end{bmatrix} = Y1 \cdot \frac{1}{\sigma_{Y1}} = \begin{bmatrix} (X1_1 - \mu_{X1})/\sigma_{Y1} \\ (X1_2 - \mu_{X1})/\sigma_{Y1} \\ \vdots \\ (X1_n - \mu_{X1})/\sigma_{Y1} \end{bmatrix}; \sigma_Z = 1 \text{ และ } \mu_Z = 0 \quad (4.25)$$

หลังจากข้อมูลทั้งหมด “n” ของชุดด้านเข้า หรือด้านออกได้ทำการจัดระเบียบข้อมูลด้วยสมการที่ 4.24 และ 4.25 แล้ว ก็ควรจะสเกลถึง (Scaling) หรือขอบเขต (Bounding) ข้อมูลให้อยู่ในช่วงของฟังก์ชันกระตุ้นถ่ายโอน โดยใช้สมการที่ 4.26 ถึง 4.30 เพื่อเพิ่มประสิทธิภาพของโครงข่ายประสาทเทียมหลังกระบวนการเรียนรู้ให้ดียิ่งขึ้น

โดยที่

$$\text{Normalized Matrix } [Z] = \begin{bmatrix} Z_1 \\ Z_2 \\ \vdots \\ Z_n \end{bmatrix}$$

c และ d คือ ช่วงของการ Scaling [c, d]

กำหนดให้

$$mx \text{ คือ ค่าสูงสุดของ Normalized Matrix } [Z] \quad (4.26)$$

$$mn \text{ คือ ค่าต่ำสุดของ Normalized Matrix } [Z] \quad (4.27)$$

ซึ่งจะสามารถหาค่าคงที่  $cw$  และ  $dw$  ได้จากสมการที่ 4.28 และ 4.29

$$cw = \frac{(d-c)}{mx - mn} \quad (4.28)$$

$$dw = d - cw \cdot mx \quad (4.29)$$

$$\text{ดังนั้นค่าเอาต์พุทหลังจาก Scaling} = cw \cdot Z_i + dw \text{ สำหรับ } i = 1, 2, \dots, n \quad (4.30)$$

ซึ่งค่าสูงสุดและค่าต่ำสุดของแต่ละสมาชิกใน Normalized Matrix [Z] จะสามารถแสดงได้ในสมการที่ 4.26 และ 4.27 ตามลำดับ ถ้าหากช่วงของการสเกลลิ่งคือ [c, d] ดังนั้นจะสามารถหาค่าคงที่  $cw$  และ  $dw$  ได้ โดยใช้สมการที่ 4.28 และ 4.29 ตามลำดับ จากนั้นแต่ละสมาชิกที่อยู่ภายใน Normalized Matrix [Z] ก็จะใช้ Scaling ด้วยสมการที่ 4.30

#### 4.6.5 การไม่จัดระเบียบข้อมูล (Unnormalization) ชุดข้อมูลฝึกสอน [26]

ในระหว่างกระบวนการฝึกสอนค่าน้ำหนักและค่าไบอัสจะถูกปรับเปลี่ยนในทุกรอบการเรียนรู้ ดังนั้นเพื่อที่จะได้ชุดของค่าน้ำหนัก และค่าไบอัสสุดท้ายที่ดีที่สุด ในระหว่างการฝึกสอนก็จะเลือกค่าน้ำหนัก และค่าไบอัสที่ทำให้ค่า Sum-of-Square Error ที่เกิดขึ้นจากค่าเอาต์พุทเป้าหมาย และข้อมูลด้านนอกของตัวแปรด้านนอกของโครงข่ายประสาทเทียมมีค่าต่ำที่สุด

ถ้าเมตริกซ์ [O] แทนเอาต์พุทของการจัดระเบียบข้อมูลและสเกลลิ่ง ในช่วงการเรียนรู้แต่ละค่า ดังนั้นค่าเอาต์พุทของโครงข่ายประสาทเทียมแต่ละค่าก็สามารถหาค่าจริงได้ด้วยการไม่สเกลลิ่งและไม่จัดระเบียบข้อมูล (Unnormalization) โดยใช้สมการที่ 4.31 และ 4.32 ตามลำดับ

$$[LK] = \begin{bmatrix} O_1/cw - dw/cw \\ O_2/cw - dw/cw \\ \vdots \\ O_n/cw - dw/cw \end{bmatrix} \quad (4.31)$$

$$[Q] = \begin{bmatrix} LK_1 \cdot \sigma_{Y1} + \mu_{X1} \\ LK_2 \cdot \sigma_{Y1} + \mu_{X1} \\ \vdots \\ LK_n \cdot \sigma_{Y1} + \mu_{X1} \end{bmatrix} \quad (4.32)$$

ค่าคงที่  $\mu_{X1}$  และ  $\sigma_{Y1}$  ที่อยู่ในสมการที่ 4.24 และ 4.25 ตามลำดับ ซึ่งเมตริกซ์  $[Q]$  จะแทน “n” ชุดข้อมูลของแต่ละเอาต์พุตที่ได้ของโครงข่ายประสาทเทียมที่จะนำไปเปรียบเทียบกับแต่ละชุดข้อมูลเป้าหมาย ภายหลังจากการเรียนรู้เสร็จสิ้นค่าน้ำหนัก และค่าไบอัสจะถูกเก็บไว้

เมื่อนำข้อมูลชุดใหม่จำนวน “m” ชุด ซึ่งจะต้องเป็นชุดที่โครงข่ายประสาทเทียมไม่เคยเห็นมาก่อนมาทดสอบ โดยชุดข้อมูลใหม่นั้นก็จะต้องทำการจัดระเบียบข้อมูลให้มีค่าเฉลี่ยเท่ากับศูนย์  $\mu = 0$  และค่าความแปรปรวนเท่ากับหนึ่ง  $\sigma = 1$  และสเกลลิงด้วยค่าระหว่าง  $[0.1, 0.9]$  หลังจากนั้นก็จะทำการทดสอบชุดข้อมูลอินพุตใหม่โดยใช้ค่าน้ำหนักและค่าไบอัส ซึ่งเป็นชุดเดียวกับของชุดข้อมูลอินพุตที่ใช้ในการฝึกสอนที่ได้จัดเก็บไว้

ถ้าเมตริกซ์  $[T]$  แทนการจัดระเบียบข้อมูลและสเกลลิงของชุดข้อมูลเอาต์พุตทดสอบแต่ละชุด ดังนั้นเอาต์พุตของโครงข่ายประสาทเทียมแต่ละค่าก็จะสามารถหาค่าจริงได้จากการไม่สเกลลิงและไม่จัดระเบียบข้อมูลโดยใช้สมการที่ 4.33 และ 4.34 ตามลำดับ

$$[RK] = \begin{bmatrix} T_1/cw - dw/cw \\ T_2/cw - dw/cw \\ \vdots \\ T_n/cw - dw/cw \end{bmatrix} \quad (4.33)$$

$$[H] = \begin{bmatrix} RK_1 \cdot \sigma_{Y1} + \mu_{X1} \\ RK_2 \cdot \sigma_{Y1} + \mu_{X1} \\ \vdots \\ RK_n \cdot \sigma_{Y1} + \mu_{X1} \end{bmatrix} \quad (4.34)$$

ซึ่งเมตริกซ์  $[H]$  แทนเอาต์พุตทดสอบแต่ละค่าที่ได้จากโครงข่ายประสาทเทียมจำนวน “m” ชุด ที่จะนำไปเปรียบเทียบกับข้อมูลเอาต์พุตเป้าหมายทดสอบแต่ละชุด โดยค่าคงที่  $cw$ ,  $dw$ ,  $\mu_{X1}$  และ  $\sigma_{Y1}$  ที่อยู่ในสมการที่ 4.33 และ 4.34 นั้น จะเป็นค่าเดียวกันกับค่าคงที่ที่อยู่ในสมการที่ 4.28, 4.29, 4.24 และ 4.25 ตามลำดับ

#### 4.6.6 การเลือกโครงสร้างที่เหมาะสมของโครงข่ายประสาทเทียม

โครงข่ายประสาทเทียมที่ฝึกสอนด้วยกฎการเรียนรู้แบบแพร่ค่าย้อนกลับนั้น จะมีจำนวนนิวรอนในชั้นข้อมูลอินพุต และชั้นข้อมูลเอาต์พุตคงที่ ซึ่งเท่ากับจำนวนของอินพุต และเอาต์พุตของปัญหานั้นเอง ส่วนจำนวนนิวรอนในชั้นซ่อนนั้นสามารถปรับเปลี่ยนได้ตามความเหมาะสม และไม่มีสมการที่เป็นสูตรสำเร็จ ดังนั้นในการฝึกสอนโครงข่ายประสาทเทียมจึงต้องมีการปรับเปลี่ยนจำนวนนิวรอนในชั้นซ่อน เพื่อหาโครงสร้างของโครงข่ายประสาทเทียมที่ให้ค่าผิดพลาดระหว่างระหว่างคำตอบที่แท้จริงกับผลลัพธ์ของโครงข่ายประสาทเทียมต่ำที่สุด (มีประสิทธิภาพสูงที่สุด) จำนวนนิวรอนในชั้นซ่อนนอกจากจะมีผลต่อประสิทธิภาพของโครงข่ายประสาทเทียมแล้ว ยังมีผลต่อระยะเวลาที่ใช้ในการฝึกสอนอีกด้วย โครงข่ายที่มีจำนวนนิวรอนในชั้นซ่อนน้อย จะใช้เวลาในการฝึกสอนน้อยกว่าโครงข่ายที่มีจำนวนนิวรอนในชั้นซ่อนมาก เมื่อฝึกสอนด้วยเงื่อนไขเดียวกัน แต่อย่างไรก็ตาม ไม่สามารถสรุปได้ว่าโครงข่ายประสาทเทียมที่มีจำนวนนิวรอนในชั้นซ่อนมากจะมีประสิทธิภาพสูงกว่าโครงข่ายประสาทเทียมที่มีจำนวนนิวรอนในชั้นซ่อนน้อย

ในปัจจุบันไม่มีข้อกำหนดหรือสมการสำหรับเลือกจำนวนนิวรอนในชั้นซ่อนที่ชัดเจน เนื่องจากจำนวนนิวรอนในชั้นซ่อนขึ้นอยู่กับปัจจัยต่างๆ เช่น จำนวนของนิวรอนอินพุตและเอาต์พุต จำนวนของข้อมูลฝึกสอน ชนิดของฟังก์ชันกระตุ้นในชั้นซ่อน เป็นต้น ซึ่งแนวทางในการเลือกจำนวนนิวรอนในชั้นซ่อนอย่างง่าย ๆ สำหรับปัญหาทั่วไป คือ กฎรูปพีระมิดเรขาคณิต โดยจำนวนนิวรอนในชั้นซ่อนมีรูปร่างเหมือนพีระมิด นั่นคือ จำนวนจะค่อยๆ ลดลงจากชั้นอินพุตไปยังชั้นเอาต์พุต นอกจากวิธีการข้างต้นแล้ว ยังมีวิธีอื่น ที่ใช้ในการคำนวณจำนวนนิวรอนในชั้นซ่อน ส่วนในวิทยานิพนธ์ฉบับนี้ ได้นำเสนอสมการเพื่อคำนวณจำนวนนิวรอนเริ่มต้นในชั้นซ่อนที่ 1 ดังแสดงในสมการที่ 4.35 [16]

$$z = (r + q) * \frac{2}{3} \quad (4.35)$$

เมื่อ  $z$  = จำนวนนิวรอนเริ่มต้นของชั้นซ่อนที่ 1

$r$  = จำนวนนิวรอนของอินพุตหรือจำนวนตัวแปรอินพุต

$q$  = จำนวนนิวรอนของเอาต์พุตหรือจำนวนตัวแปรเอาต์พุต

หลังจากคำนวณจำนวนนิวรอนเริ่มต้นของชั้นซ่อนที่ 1 ในวิทยานิพนธ์ฉบับนี้ได้ กำหนดเกณฑ์ในการหยุดฝึกสอน (Stop training) หรือหยุดเร็วกว่าปกติ (Early stopping) ซึ่งการหยุดเร็วกว่าปกตินี้มีประโยชน์คือ เพื่อที่ไม่ให้โครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับทำการฝึกสอนนานเกินไป ด้วยเหตุนี้เอง จึงได้กำหนดเกณฑ์ตามสมการที่ 4.36

$$z_{st} = z + z1; \quad (4.36)$$

เมื่อ  $z_{st}$  = จำนวนนิเวศของชั้นชอนที่ 1

$$z1 = \begin{cases} 6 & 2 \leq z \leq 6 \\ 4 & \text{ถ้า } 7 \leq z \leq 10 \\ 3 & 11 \leq z \leq 13 \\ 2 & 14 \leq z \end{cases}$$

นอกจากจำนวนนิเวศในชั้นชอนแล้ว ยังมีจำนวนชั้นชอนของโครงข่ายประสาทเทียมที่มีผลต่อประสิทธิภาพของโครงข่ายประสาทเทียม รวมไปถึงเวลาที่ใช้ในการฝึกสอน โดยทั่วไปจำนวนชั้นชอนหนึ่งชั้นก็สามารถใช้แก้ปัญหาที่ซับซ้อนทั่วไปได้ แต่ถ้าหากใช้จำนวนนิเวศในชั้นชอนจนกระทั่งมีจำนวนมากหรือมีขนาดใหญ่มาแล้ว แต่ยังไม่เพียงพอที่ใช้แก้ปัญหาได้ หรือค่าผิดพลาดยังไม่เป็นที่พอใจ ดังนั้นสามารถทำการแก้ไขเบื้องต้นดังนี้

1. เพิ่มจำนวนชั้นชอนเป็นสองชั้น โดยทั่วไปการใช้ชั้นชอนเพียงหนึ่งชั้นก็สามารถแก้ปัญหาที่ซับซ้อนทั่วไปได้ แต่ถ้าหากยังแก้ปัญหามาไม่ได้จะต้องเพิ่มจำนวนของชั้นชอนเป็นสองชั้น
2. เปลี่ยนหรือแปลงข้อมูลอินพุตหรือเอาต์พุตอยู่ในรูปแบบอื่น เพื่อให้โครงข่ายประสาทเทียมง่ายต่อการเรียนรู้ความสัมพันธ์ระหว่างข้อมูลอินพุตหรือเอาต์พุต อาทิเช่น เปลี่ยนข้อมูลอินพุตจากเลขฐานสิบเป็นเลขฐานสอง เป็นต้น
3. เพิ่มตัวแปรอินพุตตัวใหม่ ถ้าหากเลือกตัวแปรอินพุตแล้วยังไม่เพียงพอที่จะแก้ปัญหา จึงควรเพิ่มตัวแปรอินพุตที่มีความสัมพันธ์กับตัวแปรเอาต์พุตนอกเหนือจากตัวแปรอินพุตที่มีอยู่เดิม อย่างไรก็ดี เมื่อเพิ่มตัวแปรอินพุตจะมีส่วนทำให้โครงข่ายประสาทเทียมใช้เวลาในการฝึกสอนมากขึ้น
4. เพิ่มจำนวนข้อมูลฝึกสอน ถ้าหากปริมาณของข้อมูลที่ใช้ฝึกสอนเพิ่มขึ้นจะทำให้โครงข่ายประสาทเทียมสามารถเรียนรู้ และจดจำข้อมูลของปัญหาภายในขอบเขตที่ศึกษาได้ดีขึ้น
5. เปลี่ยนฟังก์ชันกระตุ้นในชั้นชอนหรือชั้นเอาต์พุต ดังที่กล่าวมาแล้วในหัวข้อ 4.5 ว่าฟังก์ชันกระตุ้นเป็นตัวกำหนดค่าเอาต์พุต ดังนั้น จึงควรเปลี่ยนฟังก์ชันกระตุ้นให้เหมาะสมกับค่าเอาต์พุต
6. เปลี่ยนไปใช้โครงข่ายประสาทเทียมชนิดอื่น เมื่อทำการปรับองค์ประกอบแล้ว ยังไม่เพียงพอกับการแก้ปัญหา จึงควรพิจารณาเปลี่ยนชนิดโครงข่ายประสาทเทียมชนิดอื่นที่เหมาะสมกับปัญหาที่ต้องการแก้ไข

## บทที่ 5

# การจำลองฟอลต์ภายในขดลวดหม้อแปลง

เพื่อศึกษาพฤติกรรมของสัญญาณฟอลต์ที่เกิดขึ้นภายในขดลวดหม้อแปลงไฟฟ้ากำลังและตอบสนองความต้องการในการฝึกสอนโครงข่ายประสาทเทียมที่ต้องการข้อมูลจำนวนมาก แต่ฟอลต์เป็นสิ่งที่ผิดปกติในระบบไฟฟ้าในทางปฏิบัติแล้วไม่สามารถทดลองในระบบจริงได้ จึงมีความจำเป็นที่ต้องสร้างแบบจำลองทางไฟฟ้าขึ้นมา ในวิทยานิพนธ์ฉบับนี้จึงได้จำลองปรากฏการณ์การเกิดฟอลต์ภายในขดลวดหม้อแปลง โดยอาศัยโปรแกรม ATPDraw for Windows version 3.65 ที่ได้รับการพัฒนามาจากโปรแกรม ATP/EMTP [33,34] หรือ Alternative Transients Program / Electromagnetic Transients Program ซึ่งช่วยในการสร้างแบบจำลองในระบบไฟฟ้าโดยเฉพาะเพื่อใช้สำหรับการศึกษาพฤติกรรมตอบสนองทางด้านทรานเซียนต์เมื่อคุณสมบัติของระบบจำลองเปลี่ยนไป โปรแกรมนี้มีการใช้งานและได้รับการยอมรับอย่างกว้างขวางว่ามีความเหมาะสมในด้านการจำลองแบบดิจิทัลสำหรับปรากฏการณ์ทรานเซียนต์ของคลื่นแม่เหล็กไฟฟ้า และให้ผลตอบสนองเหมือนกับปรากฏการณ์ทางด้านคลื่นแม่เหล็กไฟฟ้าของจริงในระบบไฟฟ้า

### 5.1 แบบจำลองหม้อแปลงไฟฟ้ากำลังในการจำลองสัญญาณฟอลต์ [35]

ในการศึกษาฟอลต์ที่เกิดภายในขดลวดหม้อแปลงมีความจำเป็นอย่างยิ่งที่ต้องคำนวณพารามิเตอร์ต่างๆ ของหม้อแปลงไฟฟ้ากำลังให้ถูกต้องเพื่อนำไปใช้สำหรับการจำลองฟอลต์ เนื่องจากสัญญาณฟอลต์จะมีการเปลี่ยนแปลงขององค์ประกอบความถี่ที่สูงกว่าความถี่พื้นฐานอยู่มาก ดังนั้นจึงต้องเลือกรูปแบบในการคำนวณให้เหมาะสมด้วย การคำนวณพารามิเตอร์ของหม้อแปลงไฟฟ้ากำลังนั้นมีให้เลือกใช้อยู่ด้วยกันหลายรูปแบบ ได้แก่ BCTRAN, Saturable Transformer, X Transformer และ Ideal Transformer แต่สำหรับการศึกษาสภาวะทรานเซียนต์จะใช้แบบจำลองหม้อแปลงไฟฟ้ากำลัง BCTRAN เพื่อจำลองปรากฏการณ์การเกิดฟอลต์ในงานวิจัยนี้


#### 5.1.1 แบบจำลอง BCTRAN ในสภาวะปกติ [34, 35]

แบบจำลอง BCTRAN เป็นแบบจำลองหม้อแปลงในสภาวะปกติ กล่าวคือ สามารถใช้สำหรับหาจรรยาเทียบเคียงของหม้อแปลงไฟฟ้ากำลังทั้งแบบที่มีแกนเหล็กเป็นชนิด Core และ Shell ทั้ง 2 ขดลวดและ 3 ขดลวด โดยใช้ผลการทดสอบของหม้อแปลงมาเป็นข้อมูลอินพุต ส่วนเอาต์พุตได้จากแบบจำลอง BCTRAN จะอยู่ในรูปของการต่อร่วมกันของค่าความต้านทาน และ ค่าความเหนี่ยวนำชนิดเชิงเส้น (Coupled Linear RL) มาแสดงเป็นวงจรเทียบเคียงของหม้อแปลงในรูปของเวลา (Time domain) โดยแบบจำลองหม้อแปลงถูกสร้างจากความคิดทางฟิสิกส์ของขดลวดที่แสดง

เหมือนขดลวดคู่ร่วม (mutually coupled coils) ซึ่งวิธีนี้หม้อแปลงหลายขดลวดใดๆ ประกอบด้วยขดลวดคู่จำนวน  $n$  คู่ สามารถจำลองทางไฟฟ้าในเทอมของแรงดันและกระแสที่ปลาย ( $V_i$  และ  $i_i$ ) รวมทั้งฟลักซ์เกี่ยวค้ำทั้งหมด  $\lambda_i$  ของขดลวด  $i$  ด้วยดังนี้

$$V_i = R_i i_i + \frac{d\lambda_i}{dt} \quad (5.1)$$

เมื่อ  $i = 1, 2, 3, \dots, n$



รูปที่ 5.1 แสดงหม้อแปลงสามเฟส 2 ขดลวด

เมื่อแม่เหล็กอิ่มตัวถูกนำเข้าสู่การพิจารณา  $\lambda_i$  กลายเป็นฟังก์ชันไม่เชิงเส้นของกระแสขดลวด  $n$  นั่นคือ

$$\lambda_i = \lambda_i(i_1, i_2, i_3, \dots, i_n)$$

สำหรับ ขดลวด  $i$ , สมการที่ 5.1 สามารถขยายโดยใช้กฎลูกโซ่ ดังนี้

$$V_i = R_i i_i + \frac{\partial \lambda_i}{\partial i_1} \frac{di_1}{dt} + \frac{\partial \lambda_i}{\partial i_2} \frac{di_2}{dt} + \dots + \frac{\partial \lambda_i}{\partial i_n} \frac{di_n}{dt} \quad (5.2)$$

อนุพันธ์บางส่วนของฟลักซ์เกี่ยวค้ำ  $\lambda_i$  ในเรื่องกระแสขดลวด ( $k = 1, 2, \dots, n$ ) เป็นตัวเหนี่ยวนำที่เพิ่มขึ้น  $L_i$  และ  $M_{ik}$  นั่นคือ

$$L_i = \frac{\partial \lambda_i}{\partial i_i} \quad (5.3)$$

$$M_{ik} = \frac{\partial \lambda_i}{\partial i_k} \quad (i \neq k) \quad (5.4)$$

ดังนั้น ถ้าหม้อแปลงเป็นหม้อแปลงสามเฟส 2 ขดลวด ดังนั้น แบบจำลองทางคณิตศาสตร์สำหรับหม้อแปลงสามารถแสดง ด้วยความสัมพันธ์เมตริกซ์ดังนี้

$$[V] = [R][i] + [L] \left[ \frac{di}{dt} \right] \quad (5.5)$$

หรือ

$$\left[ \frac{di}{dt} \right] = [L]^{-1} [V] - [L]^{-1} [R][i] \quad (5.6)$$

ในหม้อแปลงเฟสเดียว จำนวนขดลวด N ขด ในช่วงสภาวะ Steady State คือ

$$[V] = [Z][I] \quad (5.7)$$

ค่าของ  $[Z]$  ในแนวทแยงมุม (Diagonal Element) จะสามารถหาได้จากผลการทดสอบแบบจ่ายกระแสกระตุ้น จากความสัมพันธ์ของ

$$Z_{jj} = f(I_{excj}, P_{Fej}) \quad (5.8)$$

โดยที่

$I_{excj}$  คือ ค่ากระแสกระตุ้นที่วัดได้จากการที่จ่ายกระแสให้กับหม้อแปลง ณ ขดลวดที่  $j$  ขณะทำการทดสอบแบบจ่ายกระแสกระตุ้น

$P_{Fej}$  คือ ค่าสูญเสียในแกนเหล็กที่วัดได้จากการที่จ่ายกระแสให้กับหม้อแปลง ณ ขดลวดที่  $j$  ขณะทำการทดสอบแบบจ่ายกระแสกระตุ้น

ส่วนค่าของ  $[Z]$  แนวที่ไม่ใช่แนวทแยงมุม (Off Diagonal Element) สามารถหาได้จากผลการทดสอบแบบลัดวงจร

$$Z_{jk} = f(P_{Cu,jk}, V_{jk}^{short}) \quad (5.9)$$

โดยที่  $(j, k)$  คือ คู่ของขดลวดที่ทำการทดสอบแบบลัดวงจร

$P_{Cu,jk}$  คือ ค่าสูญเสียในขดลวดที่วัดได้ (Copper Loss)

$V_{jk}^{short}$  คือ ค่าแรงดันขณะลัดวงจร (Short Circuit pu Voltage)

ถ้าให้ค่าอิมพีแดนซ์ขณะลัดวงจรเป็น  $Z_{jk}^{short}$  ค่าอิมพีแดนซ์ร่วมสามารถหาได้จาก

$$Z_{jk} = Z_{kj} = \sqrt{(Z_{jj} - Z_{jk}^{short})Z_{kk}} \quad (5.10)$$

ซึ่งค่าเมตริกซ์  $[R]$  และ  $[L]$  ในสมการที่ 5.5 สามารถหาได้จากค่าจริง (Real part) และค่าจินตภาพ (Imaginary part) ของเมตริกซ์  $[Z]$  ในสมการที่ 5.10

ในส่วนของค่า  $[Z]$  ของหม้อแปลงสามเฟสจำนวนขดลวด  $N$  ขด ในช่วงสภาวะ Steady State นั้น ยังคงให้สมการที่ใช้กับหม้อแปลงเฟสเดียวที่ได้กล่าวมาแล้วข้างต้นได้ แต่จะต้องมีการเปลี่ยนค่ากระแส แรงดันและอิมพีแดนซ์ จากค่าที่เป็นสเกลาร์ (Scalar) มาเป็นเมตริกซ์ (Matrices) ดังนี้

$$i_k \rightarrow [i_{kA}, i_{kB}, i_{kC}]^T \quad (5.11)$$

$$v_k \rightarrow [v_{kA}, v_{kB}, v_{kC}]^T \quad (5.12)$$

$$Z_{kj} \rightarrow \begin{bmatrix} Z_{kjs} & Z_{kjm} & Z_{kjm} \\ Z_{kjm} & Z_{kjs} & Z_{kjm} \\ Z_{kjm} & Z_{kjm} & Z_{kjs} \end{bmatrix} \quad (5.13)$$

โดยที่  $A, B, C$  คือ การบ่งบอกถึงเฟส

$Z_{kjs}$  คือ ค่า อิมพีแดนซ์ตัวเองระหว่างขดลวด  $k$  และขดลวด  $j$  ซึ่งก็คือค่า อิมพีแดนซ์ร่วมระหว่างขดลวด 2 ขดในเฟสเดียวกัน

$Z_{kjm}$  คือ ค่า อิมพีแดนซ์ร่วมระหว่างขดลวด  $k$  และขดลวด  $j$  ซึ่งก็คือค่า อิมพีแดนซ์ร่วมระหว่างขดลวด 2 ขดที่ต่างเฟสกัน

ในสมการที่ 5.13 จะใช้สำหรับหาค่าอิมพีแดนซ์ โดยใช้ผลการทดสอบทั้งแบบลำดับศูนย์และลำดับบวก จากนั้นทำการแปลงให้เป็นค่า Self และ อิมพีแดนซ์ร่วมโดยใช้สมการต่อไปนี้

$$Z_s = \frac{1}{3}(Z_0 + 2Z_1), \quad Z_m = \frac{1}{3}(Z_0 - Z_1) \quad (5.14)$$

ดังนั้น เอด์พุทที่ได้จากโปรแกรมย่อย BCTRAN จะอยู่ในรูปของเมตริกซ์ของ  $R$  และ  $L$  ดังสมการที่ 5.15 และ 5.16 โดยมีขนาด  $6 \times 6$  สำหรับหม้อแปลงชนิด 2 ขดลวด ซึ่งสามารถนำเมตริกซ์ที่ได้ดังกล่าวส่งไปให้โปรแกรม ATP/EMTP ในการจำลองระบบไฟฟ้าต่อไป


$$[R]=\begin{bmatrix} R_1 & 0 & 0 & 0 & 0 & 0 \\ 0 & R_2 & 0 & 0 & 0 & 0 \\ 0 & 0 & R_3 & 0 & 0 & 0 \\ 0 & 0 & 0 & R_4 & 0 & 0 \\ 0 & 0 & 0 & 0 & R_5 & 0 \\ 0 & 0 & 0 & 0 & 0 & R_6 \end{bmatrix} \quad (5.15)$$

$$[L]=\begin{bmatrix} L_1 & M_{12} & M_{13} & M_{14} & M_{15} & M_{16} \\ M_{21} & L_2 & M_{14} & M_{24} & M_{25} & M_{26} \\ M_{31} & M_{32} & L_3 & M_{34} & M_{35} & M_{36} \\ M_{41} & M_{42} & M_{43} & L_4 & M_{45} & M_{46} \\ M_{51} & M_{52} & M_{53} & M_{54} & L_5 & M_{56} \\ M_{61} & M_{62} & M_{63} & M_{64} & M_{65} & L_6 \end{bmatrix} \quad (5.16)$$

จากสมการที่ 5.1-5.16 จะเห็นได้ว่า มีการคำนวณอย่างละเอียดด้วยข้อมูลจากผลการทดสอบของหม้อแปลงไฟฟ้ากำลังจากบริษัทที่ผลิตหม้อแปลงไฟฟ้ากำลัง ดังนั้นในหัวข้อถัดไปจะอธิบายสมการสำหรับคำนวณสภาวะฟอลต์ภายในขดลวดหม้อแปลงไฟฟ้ากำลังโดยใช้รูปแบบ BCTRAN ในการสร้างแบบจำลอง

### 5.1.2 แบบจำลอง BCTRANS ในสภาวะฟอลต์ภายในขดลวดหม้อแปลง [36]

จากหัวข้อที่ผ่านมา เป็นการคำนวณค่าเมตริกซ์ของค่าความต้านทานและค่าความเหนี่ยวนำในรูปของ ค่าความเหนี่ยวนำตัวเองและค่าความเหนี่ยวนำร่วม โดยมีขนาด 6x6 สำหรับหม้อแปลงชนิด 2 ขดลวดในสภาวะปกติ แต่ในการจำลองฟอลต์ที่เกิดขึ้นในขดลวดหม้อแปลงสามารถทำได้โดยแบ่งขดลวดที่เกิดการลัดวงจรออกเป็น 2 ขดลวดย่อย (sub-coil) สำหรับกรณีขดลวดลัดวงจรลงดิน (Winding to ground fault) ดังแสดงในรูปที่ 5.2 (ก) โดยแก้ไขเมตริกซ์จาก 6x6 เป็น 7x7 สำหรับหม้อแปลงชนิด 2 ขดลวด ดังสมการที่ 5.17 และ 5.18



(ก) ขดลวดลัดวงจรลงดิน

(winding to ground fault)

(ข) ขดลวดลัดวงจรระหว่างรอบ

(Interturn fault)

รูปที่ 5.2 แสดงขดลวดของหม้อแปลงขณะเกิดการลัดวงจร [36]

$$[R] = \begin{bmatrix} R_a & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & R_b & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & R_2 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & R_3 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & R_4 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & R_5 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & R_6 \end{bmatrix} \quad (5.17)$$

$$[L] = \begin{bmatrix} L_a & M_{ab} & M_{a2} & M_{a3} & M_{a4} & M_{a5} & M_{a6} \\ M_{ba} & L_b & M_{b2} & M_{b3} & M_{b4} & M_{b5} & M_{b6} \\ M_{2a} & M_{2b} & L_2 & M_{23} & M_{24} & M_{25} & M_{26} \\ M_{3a} & M_{3b} & M_{32} & L_3 & M_{34} & M_{35} & M_{36} \\ M_{4a} & M_{4b} & M_{42} & M_{43} & L_4 & M_{45} & M_{46} \\ M_{5a} & M_{5b} & M_{52} & M_{53} & M_{54} & L_5 & M_{56} \\ M_{6a} & M_{6b} & M_{62} & M_{63} & M_{64} & M_{65} & L_6 \end{bmatrix} \quad (5.18)$$

สำหรับการคำนวณค่า ความเหนี่ยวนำตัวเองและค่า ความเหนี่ยวนำร่วมระหว่างขดลวดย่อย a และ b จะต้องคำนึงถึงหลักการ 3 ข้อดังนี้ [36]

**1. ความสอดคล้อง (Consistency) :** เมื่อใช้เมตริกซ์ขนาด  $7 \times 7$  ขดลวดย่อย a และ b ถูกจัดให้อนุกรมปราศจากฟอลต์ใดๆ ผลสรุปเดียวกับที่พบในเมตริกซ์ขนาด  $6 \times 6$  ถ้าตั้งสมมุติฐานว่าขดลวดย่อย a และ b ถูกจัดในอนุกรมและกระแส  $i$  ไหลผ่านขดลวดเหล่านี้ ขดลวดอื่นๆ ทั้งหมดไม่มีไหลคั้งนั้น

$$\begin{aligned}\varphi_a &= (L_a + M_{ab})i \\ \varphi_b &= (L_b + M_{ba})i\end{aligned}\tag{5.19}$$

ในทำนองเดียวกัน

$$\begin{aligned}\varphi_a + \varphi_b &= (L_a + 2M_{ab} + L_b)i \\ \varphi_1 &= (L_1)i\end{aligned}\tag{5.20}$$

ความสัมพันธ์เหล่านี้นำไปสู่สมการของ  $L_1$

$$L_1 = L_a + 2M_{ab} + L_b\tag{5.21}$$

$L_a, L_b$  และ  $M_{ab}$  เป็นสมาชิกของเมตริกซ์ขนาด  $7 \times 7$  ส่วน  $L_1$  เป็นสมาชิกของเมตริกซ์ขนาด  $6 \times 6$

**2. การรั่วไหล (Leakage) :** คำนี้ถึงตัวประกอบการรั่วไหลระหว่างขดลวดย่อย a และ b เป็นจุดสำคัญ ด้วยเหตุที่ กระแสฟอลต์ส่วนใหญ่จะขึ้นอยู่กับ การรั่วไหล ตัวประกอบการรั่วไหลก่อให้เกิด :

$$\sigma_{ab} = 1 - \frac{M_{ab}^2}{L_a L_b}\tag{5.22}$$

ดังนั้นค่า  $\sigma_{ab}$  ซึ่งเป็นค่าการรั่วซึมของสนามแม่เหล็ก (Leakage Factor) สามารถหาได้จากลักษณะทางกายภาพของหม้อแปลง (Winding Geometry data) แต่ในงานวิจัยนี้จะถือว่าตัวประกอบการรั่วไหลจะพิจารณาเหมือนตัวแปรที่ทราบค่าหรือเป็นค่าที่กำหนดขึ้นมา

**3. สัดส่วน (Proportionality) :** เพื่อคำนวณสามตัวแปรที่ไม่ทราบค่า  $L_a, L_b$  และ  $M_{ab}$

$$\frac{L_a}{L_b} = k^2\tag{5.23}$$

เมื่อ  $k = \frac{n_a}{n_b}$

ความสัมพันธ์สมการที่ 5.23 เป็นการประมาณ แสดงให้เห็นว่า  $k$  เป็นอัตราส่วนแรงดันระหว่างขดลวดย่อย a และ b ซึ่งความเป็นจริง ค่าเหล่านี้ไม่มีการรั่วไหล ( $\sigma_{ab} = 0$ ) อย่างไรก็ตาม เมื่อ  $\sigma_{ab}$  เข้าใกล้ศูนย์ การแก้สมการทั้งสาม สำหรับตัวแปรทั้งสามที่ไม่ทราบค่า  $L_a, L_b$  และ  $M_{ab}$  จะให้ผลดังนี้

$$L_a = \frac{L_1}{\frac{1}{k^2} + \frac{2\sqrt{1-\sigma_{ab}}}{k} + 1} \quad (5.24)$$

$$L_b = \frac{L_1}{k^2 + 2k\sqrt{1-\sigma_{ab}} + 1} \quad (5.25)$$

$$M_{ab} = \frac{L_1\sqrt{1-\sigma_{ab}}}{k + \frac{1}{k} + 2\sqrt{1-\sigma_{ab}}} \quad (5.26)$$

และในการคำนวณค่าความเหนี่ยวนำร่วมระหว่างขดลวดย่อย a และขดลวดอื่นๆ  $j$  ยกเว้นขดลวดย่อย b (เช่นเดียวกัน ระหว่างขดลวดย่อย b และขดลวดใดๆ  $j$  ยกเว้นขดลวดย่อย a) ทฤษฎีความสอดคล้องนำไปสู่

$$M_{1j} = M_{aj} + M_{bj} \quad (5.27)$$

จากสมการที่ 5.27 จำเป็นต้องแยกเป็น 2 กรณีคือ

**กรณีที่ 1** เมื่อพิจารณาขดลวด  $j$  ที่พันอยู่บนแกนเหล็กเดียวกับขดลวดย่อย a และ b

$$M_{aj} = M_{1j} \sqrt{\varepsilon} \sqrt{\frac{L_a}{L_1} \sqrt{1 + \frac{1 - \varepsilon L_1 L_j}{\varepsilon M_{1j}^2}}} \quad (5.28)$$

$$M_{bj} = M_{1j} - M_{aj} \quad (5.29)$$

โดยที่  $\varepsilon = \frac{\sigma_{aj}}{\sigma_{1j}}$



$$[L] = \begin{bmatrix} L_a & M_{ab} & M_{ac} & M_{a2} & M_{a3} & M_{a4} & M_{a5} & M_{a6} \\ M_{ba} & L_b & M_{bc} & M_{b2} & M_{b3} & M_{b4} & M_{b5} & M_{b6} \\ M_{ca} & M_{cb} & L_c & M_{c2} & M_{c3} & M_{c4} & M_{c5} & M_{c6} \\ M_{2a} & M_{2b} & M_{2c} & L_2 & M_{23} & M_{24} & M_{25} & M_{26} \\ M_{3a} & M_{3b} & M_{3c} & M_{32} & L_3 & M_{34} & M_{35} & M_{36} \\ M_{4a} & M_{4b} & M_{4c} & M_{42} & M_{43} & L_4 & M_{45} & M_{46} \\ M_{5a} & M_{5b} & M_{5c} & M_{52} & M_{53} & M_{54} & L_5 & M_{56} \\ M_{6a} & M_{6b} & M_{6c} & M_{62} & M_{63} & M_{64} & M_{65} & L_6 \end{bmatrix} \quad (5.34)$$

สำหรับการคำนวณค่าความเหนี่ยวนำตัวเองและค่าความเหนี่ยวนำร่วมระหว่างขดลวดย่อย a และ b จะต้องใช้ความสัมพันธ์ของหลักการทั้ง 3 หลักการมาช่วยดังสมการต่อไปนี้

$$\text{Consistency : } L_a + L_b + L_c + 2(M_{ab} + M_{ac} + M_{bc}) = L_1 \quad (5.35)$$

$$\text{Leakage : } \sigma_{ab} = 1 - \frac{M_{ab}^2}{L_a L_b} \quad (5.36)$$

$$\sigma_{ac} = 1 - \frac{M_{ac}^2}{L_a L_c} \quad (5.37)$$

$$\sigma_{bc} = 1 - \frac{M_{bc}^2}{L_b L_c} \quad (5.38)$$

$$\text{Proportionality : } \frac{L_a}{L_b} = \left( \frac{n_a}{n_b} \right)^2 = k^2 \quad (5.39)$$

$$\frac{L_a}{L_c} = \left( \frac{n_a}{n_c} \right)^2 = k'^2 \quad (5.40)$$

ดังนั้น

$$L_a = L_1 \left( \frac{n_a}{n_1} \right)^2, \quad L_b = L_1 \left( \frac{n_b}{n_1} \right)^2, \quad L_c = L_1 \left( \frac{n_c}{n_1} \right)^2 \quad (5.41)$$

$$M_{ab} = L_1 \left( \frac{n_a n_b}{n_1^2} \right), \quad M_{ac} = L_1 \left( \frac{n_a n_c}{n_1^2} \right), \quad M_{bc} = L_1 \left( \frac{n_b n_c}{n_1^2} \right) \quad (5.42)$$

และในการคำนวณค่าความเหนี่ยวนำร่วมระหว่างขดลวดย่อย a , b และ c กับขดลวดอื่นๆ จำเป็นต้องแยกเป็น 2 กรณีคือ

กรณีที่ 1 เมื่อพิจารณาขดลวด  $j$  ที่พันอยู่บนแกนเหล็กเดียวกับขดลวดย่อย  $a$ ,  $b$  และ  $c$

$$M_{aj} = M_{1j} \sqrt{\varepsilon_1} \sqrt{\frac{L_a}{L_1}} \sqrt{1 + \frac{1 - \varepsilon_1 L_1 L_j}{\varepsilon_1 M_{1j}^2}} \quad (5.43)$$

$$M_{bj} = M_{1j} \sqrt{\varepsilon_2} \sqrt{\frac{L_b}{L_1}} \sqrt{1 + \frac{1 - \varepsilon_2 L_1 L_j}{\varepsilon_2 M_{1j}^2}} \quad (5.44)$$

$$M_{cj} = M_{1j} - M_{aj} - M_{bj} \quad (5.45)$$

โดยที่  $\varepsilon_1 = \frac{\sigma_{aj}}{\sigma_{1j}}$ ,  $\varepsilon_2 = \frac{\sigma_{bj}}{\sigma_{1j}}$

กรณีที่ 2 เมื่อพิจารณาขดลวด  $j$  ที่ไม่ได้พันอยู่บนแกนเหล็กเดียวกับขดลวดย่อย  $a$ ,  $b$  และ  $c$

$$M_{aj} = M_{ja} = \frac{M_{1j}}{1 + \frac{1}{k} + \frac{1}{k'}} \quad (5.46)$$

$$M_{bj} = M_{jb} = \frac{M_{1j}}{1 + k + \frac{k}{k'}} \quad (5.47)$$


$$M_{cj} = M_{jc} = \frac{M_{1j}}{1 + k' + \frac{k'}{k}} \quad (5.48)$$

ในส่วนของค่าความต้านทานนั้นสามารถใช้หลักของสัดส่วน (Proportionality) มาหาค่าความต้านทานของขดลวดย่อยที่ได้สร้างขึ้นได้ดังนี้

$$R_a = \frac{n_a}{n_1} R_1, \quad R_b = \frac{n_b}{n_1} R_1, \quad R_c = \frac{n_c}{n_1} R_1 \quad (5.49)$$

โดยที่  $n_a, n_b, n_c$  คือจำนวนรอบของขดลวดในขดลวดย่อย  $a$ ,  $b$  และ  $c$  ตามลำดับ และ  $n_a + n_b + n_c = n_1$

นอกจากนี้เพื่อศึกษาพฤติกรรมของหม้อแปลงไฟฟ้ากำลังในสภาวะเกิดฟอลต์ภายในขดลวดหม้อแปลง ซึ่งในงานวิจัยนี้ได้ทำการศึกษามุ่งเน้นทางด้านความถี่สูงที่เกิดขึ้นในหม้อแปลง จึงจำเป็นต้องนำตัวเก็บประจุที่เกิดขึ้นในขดลวดทางด้านแรงดันสูง, แรงดันต่ำ (earth capacitance of the HV and LV windings) และตัวเก็บประจุระหว่างขดลวดแรงดันสูงกับแรงดันต่ำ (inter-winding capacitances) มาต่อเพิ่มเข้าไปในแบบจำลองหม้อแปลง BCTRAN [6] ดังรูปที่ 5.3 [37]

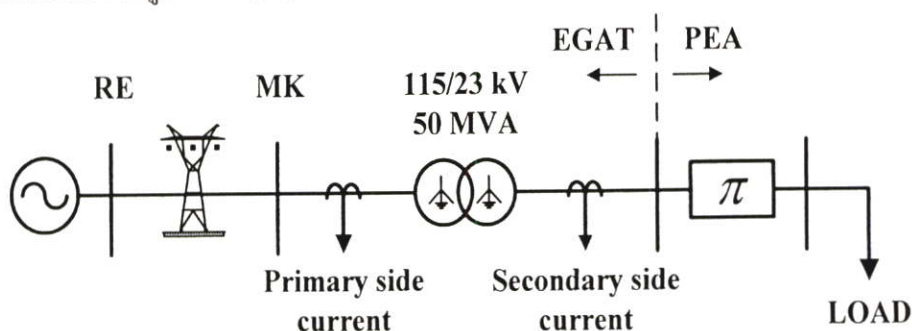


รูปที่ 5.3 แสดงแบบจำลองหม้อแปลงเฟสเดียวเมื่อต่อตัวเก็บประจุ [37]

## 5.2 ระบบจำลองฟอลต์

### 5.2.1 แบบจำลองในการจำลองสัญญาณฟอลต์

เนื่องจากในสภาวะที่เกิดฟอลต์นั้นจะมีการเปลี่ยนแปลงของรูปแบบของเหตุการณ์เกิดขึ้น ดังนั้นเพื่อให้สามารถวิเคราะห์ฟอลต์ได้ครอบคลุมในหลายรูปแบบมากที่สุด จึงทำการสร้างระบบจำลองขึ้นดังแสดงในรูปที่ 5.4 [38]



รูปที่ 5.4 แสดงระบบจำลองฟอลต์ภายในหม้อแปลงขนาด 50 MVA [38]

### 5.2.2 ผลการทดสอบของหม้อแปลงไฟฟ้ากำลัง [39]

ในวิทยานิพนธ์นี้ได้ใช้ระบบจำลองหม้อแปลงไฟฟ้ากำลังขนาด 50 MVA, 115/23 kV ซึ่งเป็นหม้อแปลงไฟฟ้ากำลังที่มีใช้งานจริงที่สถานีไฟฟ้ามหาสารคาม (MK) โดยสามารถแสดงรายละเอียดดังต่อไปนี้


พิกัดแรงดัน ปฐมภูมิ/ทุติยภูมิ	115/23 kV
พิกัดกระแส ปฐมภูมิ/ทุติยภูมิ	251.02/1255.11 kA
การต่อขดลวด	Ynyn0
พิกัดกำลัง	50 MVA
ค่าสูญเสียการกระตุ้นลำดับบวก / ศูนย์ (เปิดวงจรทางด้านแรงดันสูง)	22.18/221 kW
กระแสกระตุ้นลำดับบวก / ศูนย์	0.922/200 A
แรงดันกระตุ้นลำดับบวก / ศูนย์ (จ่ายไฟที่พิกัดแรงดัน)	23/1.993 kV
ค่าสูญเสียการลัดวงจรลำดับบวก / ศูนย์ (ลัดวงจรทางด้านแรงดันต่ำ)	148.10/345 kW
กระแสลัดวงจรลำดับบวก / ศูนย์ (จ่ายไฟที่พิกัดกระแส)	251.07/200.2 A
แรงดันลัดวงจรลำดับบวก / ศูนย์	14.44/3.224 kV
ตัวเก็บประจุที่เกิดขึ้นในขดลวดทางด้านแรงดันสูง	12491.62 pF
ตัวเก็บประจุที่เกิดขึ้นในขดลวดทางด้านแรงดันต่ำ	21795.15 pF
ตัวเก็บประจุระหว่างขดลวดแรงดันสูงกับแรงดันต่ำ	17424.32 pF

### 5.2.3 การปรับเปลี่ยนค่าพารามิเตอร์


ในการจำลองพล็อตนั้นเพื่อศึกษาพล็อตที่แตกต่างกันจึงทำการการปรับเปลี่ยนพารามิเตอร์ที่มีผลเกี่ยวข้องดังต่อไปนี้

- ประเภทของพล็อต 2 ชนิดได้แก่ พล็อตขดลวดลัดวงจรลงดินและขดลวดลัดวงจรระหว่างรอบ
- ชนิดของพล็อตที่เกิดขึ้นทางฝั่งปฐมภูมิและทุติยภูมิของหม้อแปลง
- มุมที่เริ่มเกิดพล็อต  $0^{\circ}$  -  $330^{\circ}$  เมื่อเทียบกับมุมเฟสของแรงดันสูงที่เฟส A (ช่วงละ  $30^{\circ}$ )
- สำหรับกรณีพล็อตขดลวดลัดวงจรลงดิน ตำแหน่งที่ลัดวงจร 10%-90% ของขดลวด (ขดลวดย่อย a เปลี่ยนแปลงช่วงละ 10%)
- สำหรับกรณีพล็อตขดลวดลัดวงจรระหว่างรอบ ตำแหน่งที่ลัดวงจร 10%-80% ของขดลวด (ขดลวดย่อย a เปลี่ยนแปลงช่วงละ 10%)
- สำหรับกรณีพล็อตขดลวดลัดวงจรระหว่างรอบ ตำแหน่งที่ลัดวงจร 10%-80% ของขดลวด (ขดลวดย่อย b เปลี่ยนแปลงช่วงละ 10%)
- ความต้านทานของพล็อต 5 โอห์ม


จากวงจรขณะเกิดฟอลต์ของหม้อแปลงทดสอบในรูปที่ 5.2 (ก) และ 5.2 (ข) เมื่อนำไปสร้างเป็นแบบจำลองการทดสอบในโปรแกรม ATPDraw ได้ดังรูปที่ 5.5 และ 5.10 ตามลำดับ โดยใช้สวิตช์ทำหน้าที่เป็นตัวกำหนดรูปแบบและเวลาของการเกิดฟอลต์ ซึ่งในที่นี้ได้กำหนดให้เริ่มเกิดฟอลต์ที่  $t = 0.04$  วินาที และทำการจำลองสัญญาณทั้งหมด 5 ไซเคิล (0 – 0.1 วินาที) โดยไม่มีการกำจัดฟอลต์ออก ซึ่งสามารถแสดงตัวอย่างของสัญญาณที่ได้จากการจำลองในกรณีฟอลต์ชั่วคราว ลัดวงจรลงดินดังแสดงในรูปที่ 5.6-5.9 และกรณีฟอลต์ชั่วคราวลัดวงจรระหว่างรอบแสดงในรูปที่ 5.11-5.14




รูปที่ 5.5 แสดงวงจรในการจำลองฟอลต์ชั่วคราวลัดวงจรลงดินชนิดเฟส A ลงดินที่ 10% ของความยาวลวดหม้อแปลง




รูปที่ 5.6 แสดงสัญญาณฟอลต์ของแรงดันที่ได้จากการจำลองที่ปลายด้านแรงดันสูง




รูปที่ 5.7 แสดงสัญญาณฟอลต์ของกระแสที่ได้จากการจำลองที่ปลายด้านแรงดันสูง




รูปที่ 5.8 แสดงสัญญาณฟอลต์ของแรงดันที่ได้จากการจำลองที่ปลายด้านแรงดันต่ำ




รูปที่ 5.9 แสดงสัญญาณฟอลต์ของกระแสที่ได้จากการจำลองที่ปลายด้านแรงต่ำ




รูปที่ 5.10 แสดงวงจรในการจำลองฟอลต์ชั่วคราวคลื่นแรงระหว่างรอบชนิดเฟส A ที่ 10% กับ 20% ของความยาวคลื่นความถี่เปลี่ยนแปลง




รูปที่ 5.11 แสดงสัญญาณฟอลต์ของแรงดันที่ได้จากการจำลองที่ปลายด้านแรงสูง



รูปที่ 5.12 แสดงสัญญาณฟอลต์ของกระแสที่ได้จากการจำลองที่ปลายด้านแรงสูง



รูปที่ 5.13 แสดงสัญญาณฟอลต์ของแรงดันที่ได้จากการจำลองที่ปลายด้านแรงต่ำ



รูปที่ 5.14 แสดงสัญญาณฟอลต์ของกระแสที่ได้จากการจำลองที่ปลายด้านแรงต่ำ

จากรูปที่ 5.6 ถึง 5.9 และรูปที่ 5.11 ถึง 5.14 แสดงให้เห็นผลการจำลองของการเปลี่ยนแปลงที่เกิดขึ้นในหม้อแปลงทดสอบ จะพบว่า ลักษณะการเปลี่ยนแปลงของฟอลต์ทั้งสองชนิดมีลักษณะการเปลี่ยนแปลงที่เหมือนกัน จึงยากแก่การแยกประเภทฟอลต์ ด้วยเหตุนี้เอง จึงได้นำการแปลงเวฟเล็ตและโครงข่ายประสาทเทียมมาช่วยในการแยกประเภทฟอลต์ โดยจะอธิบายในบทที่ 6 ต่อไป

## บทที่ 6

# การวิเคราะห์ฟอลต์ภายในหม้อแปลงไฟฟ้ากำลัง


สมมติฐานที่ใช้สำหรับการวิเคราะห์สัญญาณฟอลต์คือ ในสภาวะปกติสัญญาณกระแสและแรงดันจะไม่มีองค์ประกอบความถี่สูงรวมอยู่ แต่ในสภาวะที่มีฟอลต์จะมีการเปลี่ยนแปลงขององค์ประกอบความถี่สูงเกิดขึ้นและควรจะเปลี่ยนแปลงตามรูปแบบของฟอลต์ที่เกิดขึ้นด้วย[40, 41] เช่น มุมที่เริ่มเกิดฟอลต์ ตำแหน่งที่เกิด หรือเฟสที่เกิดฟอลต์ เป็นต้น เนื่องจากการเปลี่ยนแปลงขององค์ประกอบความถี่สูงนั้นมีการเปลี่ยนแปลงที่รวดเร็วกว่าเมื่อเทียบกับองค์ประกอบความถี่พื้นฐาน โดยยังคงข้อมูลที่สำคัญต่างๆ ไว้ ดังนั้นการพิจารณาองค์ประกอบความถี่สูงจึงสามารถที่จะลดขนาดของช่วงข้อมูลที่ใช้ได้ด้วย จากการศึกษานี้ได้กำหนดช่วงของข้อมูลพื้นฐานที่ใช้วิเคราะห์โดยใช้ช่วง  $\frac{1}{4}$  ไซเคิลหลังจากเริ่มเกิดฟอลต์

จากทฤษฎีพื้นฐานของการแปลงเวฟเล็ดและโครงข่ายประสาทเทียมที่กล่าวมาแล้วในบทที่ 3 และ 4 วิทยานิพนธ์นี้จึงได้นำการแปลงเวฟเล็ดแบบเต็มหน่วย (DWT) มาวิเคราะห์สัญญาณฟอลต์ที่เกิดขึ้นภายในหม้อแปลงไฟฟ้ากำลัง โดยทำการวิเคราะห์สัญญาณกระแสผลต่าง (Different current) ของหม้อแปลงไฟฟ้ากำลัง ผลการวิเคราะห์ได้ถูกนำมาเป็นอินพุทให้กับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (Back-propagation neural networks) เพื่อประมวลผลสำหรับการตัดสินใจและแสดงรายละเอียดของสัญญาณฟอลต์ต่อไป


### 6.1 การวิเคราะห์ด้วยการแปลงเวฟเล็ด

ขั้นตอนการวิเคราะห์เวฟเล็ดจะนำสัญญาณกระแสผลต่างที่ได้จากโปรแกรม ATP/EMTP ในแต่ละเฟสของหม้อแปลงไฟฟ้ากำลัง ซึ่งเป็นสัญญาณที่ถูกนำมาวิเคราะห์ด้วยความถี่การสุ่ม (Sampling frequency) 200 kHz มาทำการแปลงเวฟเล็ดแบบเต็มหน่วยโดยใช้เวฟเล็ดแม่ซินิก daubechies4 (db4) [15-16,23-24] เพื่อทำการแยกองค์ประกอบความถี่สูงในสเกลที่ 1-5 ออกมาดังแสดงในรูปที่ 6.1 และ 6.2 ซึ่งแต่ละสเกลจะแสดงค่าของช่วงความถี่ดังนี้

สเกลที่ 1 มีความถี่ในช่วง	50-100	kHz
สเกลที่ 2 มีความถี่ในช่วง	25-50	kHz
สเกลที่ 3 มีความถี่ในช่วง	12.5-25	kHz
สเกลที่ 4 มีความถี่ในช่วง	6.25-12.5	kHz
สเกลที่ 5 มีความถี่ในช่วง	3.125-6.25	kHz




รูปที่ 6.1 แสดงผลการแปลงเวฟที่เกิดในแต่ละเฟสของกระแสผลต่างกรณีฟอลต์ขดลวดลัดวงจรลงดิน




รูปที่ 6.2 แสดงผลการแปลงเวฟที่เกิดในแต่ละเฟสของกระแสผลต่างกรณีฟอลต์ขดลวดลัดวงจรระหว่างรอบ

จากนั้นจึงทำการยกกำลังสองสัมประสิทธิ์ความถี่สูง (cD) ในทุกสเกลด้วยกันเพื่อให้เห็นความแตกต่างที่ชัดเจนดังแสดงในรูปที่ 6.3 และ 6.4 แล้วพิจารณาการเปลี่ยนแปลงของแต่ละช่วงความถี่จากสัมประสิทธิ์ที่ได้ในแต่ละสเกล จากผลการแปลงเวฟเล็ดสามารถสังเกตได้ว่าในสถานะที่เริ่มมีฟอลต์ ( $t \geq 0.04$  sec) พบว่า ค่าของสัมประสิทธิ์ในแต่ละสเกลจะมีค่าสูงขึ้นอย่างรวดเร็วและมากกว่าค่าของสัมประสิทธิ์ในสภาวะก่อนเกิดฟอลต์ ( $t < 0.04$  sec) จากการเปลี่ยนแปลงที่เกิดขึ้นนี้ นำมาใช้ในการตรวจจับฟอลต์ที่เกิดขึ้นและเลือกข้อมูลในสเกลแรกที่ตรวจจับได้นำไปเป็นอินพุตให้กับโครงข่ายประสาทเทียมต่อไป โดยเลือกใช้ข้อมูลในช่วง  $\frac{1}{4}$  ไซเคิลหลังจากที่เริ่มเกิดฟอลต์ ( $t \geq 0.04$  sec) ซึ่งสั้นกว่าเมื่อเทียบกับหลักการเดิมที่ใช้การแปลงฟูเรียร์ที่ต้องใช้ช่วงของข้อมูลในการวิเคราะห์อย่างน้อย 1 ไซเคิล

อย่างไรก็ตาม ก่อนที่ทำการวินิจฉัยสถานะผิดปกติ (ฟอลต์) เพื่อตรวจจับและระบุเฟสรวมไปถึงตำแหน่งขดลวดที่เกิดฟอลต์นั้น จำเป็นต้องเข้าใจในพฤติกรรมของการเปลี่ยนแปลงของสัมประสิทธิ์ที่ได้จากการแปลงเวฟเล็ดแบบเต็มหน่วย ซึ่งมีส่วนทำให้เกิดความเข้าใจในมากขึ้น




รูปที่ 6.3 แสดงค่าสัมประสิทธิ์กำลังสองในแต่ละเฟสของกระแสผลต่างกรณีฟอลต์ขดลวดลัดวงจรลงดิน



รูปที่ 6.4 แสดงค่าสัมประสิทธิ์กำลังสองในแต่ละเฟสของกระแสผลต่างกรณีฟอลต์ชนิดลัดวงจรระหว่างรอบ

### 6.1.1 พฤติกรรมการเปลี่ยนแปลงของฟอลต์ชนิดลัดวงจรลงดิน

ฟอลต์ชนิดลัดวงจรลงดินนั้นเป็นฟอลต์ที่เกิดขึ้นภายในหม้อแปลงและสามารถเกิดฟอลต์ได้ทั้งทางด้านแรงดันสูงและแรงดันต่ำ ดังนั้นจึงจำเป็นต้องทำความเข้าใจในพฤติกรรมการเปลี่ยนแปลงของสัมประสิทธิ์ความถี่สูงที่ได้จากการแปลงเวฟเลิตแบบเต็มหน่วยของกระแสผลต่างในแต่ละเฟสรวมทั้งกระแสองค์ประกอบลำดับศูนย์ โดยมีรูปแบบการเปลี่ยนแปลงดังแสดงในรูปที่ 6.5



(ก) แรงดันสูง


(ข) แรงดันต่ำ

รูปที่ 6.5 แสดงการเปลี่ยนแปลงค่าสัมประสิทธิ์กำลังสองในแต่ละเฟสของกระแสผลต่าง


ทำการเปลี่ยนแปลงตำแหน่งขดลวดที่เกิดฟอลต์ภายในหม้อแปลงไฟฟ้ากำลังทั้งทางด้านแรงดันสูงและแรงดันต่ำของหม้อแปลงไฟฟ้ากำลัง โดยกำหนดให้มุมเริ่มเกิดฟอลต์มีค่าคงที่ พบว่าเมื่อตำแหน่งขดลวดที่เกิดฟอลต์มีค่าเพิ่มขึ้น ค่าสัมประสิทธิ์ที่ได้ของกระแสผลต่างทั้งสามเฟสมีค่าลดลง เพื่อให้เห็นความชัดเจนมากขึ้น จึงได้ทำการเปลี่ยนแปลงตำแหน่งฟอลต์ที่เฟส A โดยให้มุมเริ่มเกิดฟอลต์คงที่ 60 องศา ดังแสดงในตารางที่ 6.1 และรูปที่ 6.6

ตารางที่ 6.1 แสดงการเปลี่ยนแปลงของสัมประสิทธิ์ในสเกลที่ 1 ณ ตำแหน่งขดลวดฟอลต์ต่างๆ

สัมประสิทธิ์ องค์ประกอบความถี่สูง ของกระแสผลต่าง		เกิดฟอลต์ที่เฟส A มุมเริ่มเกิดฟอลต์ 60 องศา ณ ตำแหน่ง							
		แรงดันสูง (High Voltage winding)				แรงดันต่ำ (Low Voltage winding)			
		10%	30%	50%	70%	10%	30%	50%	70%
Phase A	ก่อนเกิดฟอลต์	2.63E-04	2.24E-04	2.99E-04	2.99E-04	2.24E-04	2.57E-04	2.05E-04	2.19E-04
	หลังเกิดฟอลต์	165.87	161.05	155.56	149.48	2.7050	1.7999	1.3676	0.8650
Phase B	ก่อนเกิดฟอลต์	2.87E-04	2.87E-04	2.87E-04	2.87E-04	2.72E-04	2.78E-04	1.99E-04	2.72E-04
	หลังเกิดฟอลต์	3.82	3.70	3.56	3.41	0.2245	0.1514	0.1090	0.0635
Phase C	ก่อนเกิดฟอลต์	2.24E-04	2.24E-04	2.24E-04	2.24E-04	2.24E-04	2.43E-04	2.43E-04	2.43E-04
	หลังเกิดฟอลต์	3.82	3.70	3.56	3.40	0.2308	0.1431	0.1121	0.0641
Zero sequence	ก่อนเกิดฟอลต์	9.03E-05	9.03E-05	8.96E-05	9.03E-05	7.79E-05	8.32E-05	7.64E-05	7.72E-05
	หลังเกิดฟอลต์	26.82	26.06	25.23	24.28	0.1583	0.1099	0.0818	0.0601



(ก) แรงดันสูง




(ข) แรงดันต่ำ

รูปที่ 6.6 แสดงลักษณะการเปลี่ยนแปลงสัมประสิทธิ์องค์ประกอบความถี่สูงในสเกลที่ 1 ของกระแสผลต่างเฟสที่เกิดฟอลต์ (Phase A) เมื่อเกิดฟอลต์ที่ตำแหน่งต่างๆ ในขดลวดของหม้อแปลง


เมื่อทำการเปลี่ยนแปลงมุมเริ่มเกิดฟอลต์ในหม้อแปลง โดยกำหนดให้ตำแหน่งฟอลต์มีค่าคงที่ ดังแสดงในตารางที่ 6.2 พบว่า เมื่อมุมเริ่มเกิดฟอลต์มีการเปลี่ยนแปลงในลักษณะลูกคลื่นไซน์ (Sinusoidal wave) ค่าสัมประสิทธิ์ความถี่สูงที่ได้มีค่าเปลี่ยนแปลงตามมุมหรือองศาของลูกคลื่นไซน์ กล่าวคือ เมื่อลูกคลื่นไซน์ค่อยๆ มีองศาเพิ่มขึ้นจนกระทั่งอยู่ที่ 90 องศา ค่าสัมประสิทธิ์ที่ได้มีค่าเปลี่ยนแปลงในลักษณะที่ค่อยๆ เพิ่มขึ้น จนกระทั่งค่าสัมประสิทธิ์สูงสุดอยู่ที่ 90 องศา และจะมีค่าค่อยๆ ลดลงตามการเปลี่ยนแปลงของลูกคลื่นไซน์เมื่อเลขมุม 90 องศา แต่พอลูกคลื่นไซน์เลย 180 องศา ค่าสัมประสิทธิ์ที่ได้รับจะมีค่าเป็นบวกเนื่องจากได้ทำการยกกำลังสองในตอนแรก

ตารางที่ 6.2 แสดงการเปลี่ยนแปลงของสัมประสิทธิ์ในสเกลที่ 1 ณ มุมเริ่มเกิดฟอลต์ชัดเจน ลัดวงจรลงดินที่มุมต่างๆ

สัมประสิทธิ์ องค์ประกอบความถี่สูง ของกระแสผลต่าง		เกิดฟอลต์ที่เฟส A ณ ตำแหน่งชัดเจน 10% ณ มุมเริ่มเกิดฟอลต์							
		แรงดันสูง (High Voltage winding)				แรงดันต่ำ (Low Voltage winding)			
		90	120	150	180	90	120	150	180
Phase A	ก่อนเกิดฟอลต์	2.43E-04	3.44E-04	3.61E-04	2.24E-04	2.78E-04	2.52E-04	2.52E-04	8.28E-05
	หลังเกิดฟอลต์	220.76	165.14	54.69	0.0052	4.1417	3.5219	1.4598	0.0514
Phase B	ก่อนเกิดฟอลต์	2.24E-04	4.36E-04	2.60E-04	2.63E-04	2.83E-04	3.37E-04	2.47E-04	1.01E-04
	หลังเกิดฟอลต์	5.07	3.80	1.25	3.87E-05	0.3531	0.2981	0.1231	0.0044
Phase C	ก่อนเกิดฟอลต์	2.58E-04	3.09E-04	3.78E-04	2.87E-04	2.24E-04	2.61E-04	3.72E-04	8.76E-05
	หลังเกิดฟอลต์	5.11	3.79	1.28	0.000171	0.3565	0.3015	0.1225	0.0056
Zero sequence	ก่อนเกิดฟอลต์	7.37E-05	1.17E-04	9.19E-05	9.03E-05	3.21E-04	2.38E-04	4.55E-04	9.56E-05
	หลังเกิดฟอลต์	35.68	26.73	8.82	0.0015	0.2373	0.2036	0.0858	0.0028



(ก) แรงดันสูง




(ข) แรงดันต่ำ

รูปที่ 6.7 แสดงลักษณะการเปลี่ยนแปลงสัมประสิทธิ์องค์ประกอบความถี่สูงในสเกลที่ 1 ของกระแสผลต่างเฟสที่เกิดฟอลต์ (Phase A) เมื่อมุมเริ่มเกิดฟอลต์เปลี่ยนแปลง

### 6.1.2 พฤติกรรมการเปลี่ยนแปลงของฟอลต์ชั่วคราวลัดวงจรระหว่างรอบ

ในการพิจารณาสัมประสิทธิ์ที่ได้จากการแปลงเวฟเส้นแบบเต็มหน่วยในกรณีเกิดฟอลต์ชั่วคราวลัดวงจรระหว่างรอบนั้นสามารถพิจารณาเช่นเดียวกับในหัวข้อ 6.1.1 โดยมีรูปแบบการเปลี่ยนแปลงดังแสดงในรูปที่ 6.8



(ก) แรงดันสูง

(ข) แรงดันต่ำ


รูปที่ 6.8 แสดงการเปลี่ยนแปลงค่าสัมประสิทธิ์กำลังสองในแต่ละเฟสของกระแสผลต่าง

ทำการเปลี่ยนแปลงตำแหน่งฟอลต์ที่เกิดระหว่างขดลวดข้อย a และ b ภายในหม้อแปลงไฟฟ้ากำลังทั้งทางด้านแรงดันสูงและแรงดันต่ำ (ให้ขดลวดข้อย a คงที่ เปลี่ยนแปลงตำแหน่งขดลวดข้อย b) โดยกำหนดให้มุมเริ่มเกิดฟอลต์มีค่าคงที่ พบว่า เมื่อตำแหน่งขดลวดข้อย b ที่เกิดฟอลต์มีค่าเพิ่มขึ้น ค่าสัมประสิทธิ์ความถี่สูงที่ได้ของกระแสผลต่างทั้งสามเฟสมีค่าเพิ่มขึ้น เพื่อให้เห็นความชัดเจนมากขึ้น จึงได้ทำการเปลี่ยนแปลงตำแหน่งฟอลต์ที่เฟส A โดยให้มุมเริ่มเกิดฟอลต์คงที่ 60 องศา ดังแสดงในตารางที่ 6.3 และรูปที่ 6.9


ในทางกลับกันทำการเปลี่ยนแปลงตำแหน่งฟอลต์ที่เกิดระหว่างขดลวดข้อย a และ b ภายในหม้อแปลงไฟฟ้ากำลังทั้งทางด้านแรงดันสูงและต่ำ (ให้ขดลวดข้อย b คงที่ เปลี่ยนแปลงตำแหน่งขดลวดข้อย a) โดยกำหนดให้มุมเริ่มเกิดฟอลต์มีค่าคงที่ พบว่า เมื่อตำแหน่งขดลวดข้อย a ที่เกิดฟอลต์มีค่าเพิ่มขึ้น ค่าสัมประสิทธิ์ความถี่สูงที่ได้ของกระแสผลต่างทั้งสามเฟสมีค่าคงที่ไม่เปลี่ยนแปลงตามตำแหน่งฟอลต์ขดลวดข้อย a ที่เพิ่มขึ้น (ถ้าเปลี่ยนแปลงก็เปลี่ยนแปลงน้อยมาก) ดังแสดงในตารางที่ 6.4 และรูปที่ 6.10

ตารางที่ 6.3 แสดงการเปลี่ยนแปลงของสัมประสิทธิ์ในสเกลที่ 1 ณ ตำแหน่งฟอลต์ชนิดลวดย่อย b  
ต่างๆ

สัมประสิทธิ์ องค์ประกอบความถี่สูง ของกระแสผลต่าง		เกิดฟอลต์ที่เฟส A มุมเริ่มเกิดฟอลต์ 60 องศา ณ ตำแหน่งขดลวด (a-b)							
		แรงดันสูง (High Voltage winding)				แรงดันต่ำ (Low Voltage winding)			
		10-20	10-40	10-60	10-80	10-20	10-40	10-60	10-80
Phase A	ก่อนเกิดฟอลต์	2.63E-04	2.99E-04	3.15E-04	2.99E-04	2.24E-04	2.43E-04	2.32E-04	1.88E-04
	หลังเกิดฟอลต์	170.88	175.93	176.97	177.41	2.975	3.029	3.0691	3.092
Phase B	ก่อนเกิดฟอลต์	2.87E-04	2.87E-04	2.87E-04	2.87E-04	2.87E-04	2.87E-04	2.87E-04	2.72E-04
	หลังเกิดฟอลต์	3.95	4.10	4.14	4.14	0.2909	0.2956	0.3026	0.3026
Phase C	ก่อนเกิดฟอลต์	2.24E-04	2.24E-04	2.24E-04	2.24E-04	2.24E-04	2.43E-04	2.43E-04	2.43E-04
	หลังเกิดฟอลต์	3.95	4.09	4.12	4.13	0.2911	0.2933	0.2976	0.297
Zero sequence	ก่อนเกิดฟอลต์	9.03E-05	8.96E-05	8.96E-05	8.96E-05	8.96E-05	8.42E-05	9.35E-05	8.53E-05
	หลังเกิดฟอลต์	27.57	28.31	28.45	28.53	0.1391	0.143	0.1435	0.1466



(ก) แรงดันสูง




(ข) แรงดันต่ำ


รูปที่ 6.9 แสดงลักษณะการเปลี่ยนแปลงสัมประสิทธิ์องค์ประกอบความถี่สูงในสเกลที่ 1 ของกระแสผลต่างเฟสที่เกิดฟอลต์ (Phase A) เมื่อเกิดฟอลต์ที่ตำแหน่งต่างๆ ในขดลวดย่อย b ของหม้อแปลง

ตารางที่ 6.4 แสดงการเปลี่ยนแปลงของสัมประสิทธิ์ในสเกลที่ 1 ณ ตำแหน่งฟอลต์ชนิดลวดย่อย a ต่างๆ

สัมประสิทธิ์ องค์ประกอบความถี่สูง ของกระแสผลต่าง		เกิดฟอลต์ที่เฟส A มุมเริ่มเกิดฟอลต์ 60 องศา ณ ตำแหน่งขดลวด (a-b)							
		แรงดันสูง (High Voltage winding)				แรงดันต่ำ (Low Voltage winding)			
		10-20	30-40	50-60	70-80	10-20	30-40	50-60	70-80
Phase A	ก่อนเกิดฟอลต์	2.63E-04	2.63E-04	3.15E-04	2.99E-04	2.24E-04	2.52E-04	2.32E-04	2.52E-04
	หลังเกิดฟอลต์	170.88	170.88	170.88	170.88	2.975	2.9747	2.9747	2.9748
Phase B	ก่อนเกิดฟอลต์	2.87E-04	2.87E-04	2.87E-04	2.87E-04	2.87E-04	2.87E-04	2.87E-04	2.87E-04
	หลังเกิดฟอลต์	3.95	3.95	3.95	3.95	0.2909	0.2909	0.2909	0.2909
Phase C	ก่อนเกิดฟอลต์	2.24E-04	2.24E-04	2.24E-04	2.24E-04	2.24E-04	2.24E-04	2.24E-04	2.24E-04
	หลังเกิดฟอลต์	3.95	3.95	3.95	3.95	0.2911	0.2911	0.2911	0.2911
Zero sequence	ก่อนเกิดฟอลต์	9.03E-05	9.03E-05	8.96E-05	8.96E-05	8.96E-05	9.30E-05	9.30E-05	9.30E-05
	หลังเกิดฟอลต์	27.57	27.57	27.57	27.57	0.1391	0.139	0.139	0.139



(ก) แรงดันสูง




(ข) แรงดันต่ำ

รูปที่ 6.10 แสดงลักษณะการเปลี่ยนแปลงสัมประสิทธิ์องค์ประกอบความถี่สูงในสเกลที่ 1 ของกระแสผลต่างเฟสที่เกิดฟอลต์ (Phase A) เมื่อเกิดฟอลต์ที่ตำแหน่งต่างๆ ในขดลวดย่อย a ของหม้อแปลง


นอกจากนี้ทำการเปลี่ยนแปลงมุมเริ่มเกิดฟอลต์ทั้งทางด้านแรงดันสูงและแรงดันต่ำของหม้อแปลงไฟฟ้ากำลัง โดยกำหนดให้ตำแหน่งฟอลต์มีค่าคงที่ พบว่า เมื่อมุมเริ่มเกิดฟอลต์มีการเปลี่ยนแปลงในลักษณะลูกคลื่นไซน์ (Sinusoidal wave) ค่าสัมประสิทธิ์ความถี่สูงที่ได้ของกระแสผลต่างมีค่าเปลี่ยนแปลงตามมุมหรือองศาของลูกคลื่นไซน์ดังแสดงในตารางที่ 6.5 และรูปที่ 6.11

ตารางที่ 6.5 แสดงการเปลี่ยนแปลงของสัมประสิทธิ์ในสเกลที่ 1 ณ มุมเริ่มเกิดฟอลต์ชั่วคราว ระหว่างรอบที่มุมต่างๆ

สัมประสิทธิ์ องค์ประกอบความถี่สูง ของกระแสผลต่าง		เกิดฟอลต์ที่เฟส A ระหว่างขดลวด 10%-20% ณ มุมเริ่มเกิดฟอลต์							
		แรงดันสูง (High Voltage winding)				แรงดันต่ำ (Low Voltage winding)			
		90	120	150	180	90	120	150	180
Phase A	ก่อนเกิดฟอลต์	2.43E-04	3.44E-04	3.61E-04	2.24E-04	2.43E-04	2.14E-04	2.43E-04	2.24E-04
	หลังเกิดฟอลต์	227.45	170.13	56.33	0.0052	4.5198	3.8185	1.561	0.0497
Phase B	ก่อนเกิดฟอลต์	2.24E-04	4.36E-04	2.60E-04	2.63E-04	2.24E-04	4.36E-04	2.60E-04	2.63E-04
	หลังเกิดฟอลต์	5.21	3.94	1.30	0.000033	0.4381	0.3732	0.151	0.0049
Phase C	ก่อนเกิดฟอลต์	2.58E-04	3.09E-04	3.78E-04	2.87E-04	2.58E-04	3.09E-04	3.78E-04	2.87E-04
	หลังเกิดฟอลต์	5.28	3.92	1.32	0.000223	0.4452	0.3713	0.1574	0.0045
Zero sequence	ก่อนเกิดฟอลต์	7.37E-05	1.17E-04	9.19E-05	9.03E-05	8.29E-05	9.18E-05	9.19E-05	9.03E-05
	หลังเกิดฟอลต์	36.74	27.47	9.08	0.0018	0.2116	0.1795	0.0718	0.0025



(ก) แรงดันสูง



(ข) แรงดันต่ำ

รูปที่ 6.11 แสดงลักษณะการเปลี่ยนแปลงสัมประสิทธิ์องค์ประกอบความถี่สูงในสเกลที่ 1 ของกระแสผลต่างเฟสที่เกิดฟอลต์ (Phase A) เมื่อมุมเริ่มเกิดฟอลต์เปลี่ยนแปลง

### 6.1.3 การตรวจจับฟอลต์ (Fault detection)

ในส่วนขั้นตอนการตรวจจับฟอลต์เป็นขั้นตอนสำคัญเพราะจะต้องเลือกใช้ข้อมูลในสเกลแรกๆ ที่ตรวจจับฟอลต์ได้นำไปเป็นอินพุทให้กับโครงข่ายประสาทเทียม เนื่องจากลักษณะของฟอลต์แต่ละประเภทจะมีรูปแบบการเปลี่ยนแปลงของกระแสผลต่างที่แตกต่างกัน แต่ในสภาวะที่มีฟอลต์จะมีการเปลี่ยนแปลงขององค์ประกอบความถี่สูงเกิดขึ้นและควรจะเปลี่ยนแปลงตามรูปแบบของฟอลต์ที่เกิดขึ้นด้วย ด้วยเหตุนี้เองจึงได้นำสัมประสิทธิ์การแปลงเวฟเล็ดในทุกสเกลมาพิจารณาการเปลี่ยนแปลงของกระแสผลต่างที่เกิดขึ้นในแต่ละเฟส

ในขั้นตอนนี้ ได้แบ่งออกเป็น 2 ขั้นตอนคือ การตรวจจับการเปลี่ยนแปลงที่เกิดขึ้น และการแบ่งแยกระหว่างฟอลต์ภายในขดลวดหม้อแปลงกับฟอลต์ที่เกิดขึ้นภายนอกหม้อแปลง โดยขั้นตอนทั้งสองส่วนนี้ได้ทำการวิเคราะห์ในลักษณะเปรียบเทียบสัมประสิทธิ์ความถี่สูงที่ได้จากการแปลงเวฟเล็ดของกระแสผลต่างในแต่ละเฟสของหม้อแปลงไฟฟ้ากำลัง และเนื่องจากขั้นตอนทั้งหมดเป็นลักษณะการเปรียบเทียบของค่าต่างๆ บางครั้งการอธิบายด้วยลักษณะของคำพูดนั้น อาจทำให้เข้าใจยาก ดังนั้นจึงใช้ลักษณะการอธิบายเชิงบรรยายรวมกับการอธิบายด้วยลักษณะของการเขียนโปรแกรมคอมพิวเตอร์ในแบบสากลคือ if ... then ...else ... end ซึ่งจะช่วยให้สามารถทำความเข้าใจได้ง่ายมากยิ่งขึ้น เพื่อสะดวกในการอธิบายขั้นตอนทั้งหมดจึงทำการกำหนดตัวแปรต่างๆ ดังต่อไปนี้

$L$  = สเกลของการแปลงเวฟเล็ด

$(A_{(t+5\mu s)}^{diff})^L$  = ค่าสัมประสิทธิ์จากการแปลงเวฟเล็ดของกระแสผลต่างเฟส A ณ เวลา  $t+5\mu\text{sec}$  ที่สเกล  $L$

$(B_{(t+5\mu s)}^{diff})^L$  = ค่าสัมประสิทธิ์จากการแปลงเวฟเล็ดของกระแสผลต่างเฟส B ณ เวลา  $t+5\mu\text{sec}$  ที่สเกล  $L$

$(C_{(t+5\mu s)}^{diff})^L$  = ค่าสัมประสิทธิ์จากการแปลงเวฟเล็ดของกระแสผลต่างเฟส C ณ เวลา  $t+5\mu\text{sec}$  ที่สเกล  $L$

$(A_{\max(0 \rightarrow t)}^{diff})^L$  = ค่าสัมประสิทธิ์สูงสุดจากการแปลงเวฟเล็ดของกระแสผลต่างเฟส A ณ เวลาตั้งแต่ 0 จนถึง  $t$  ที่สเกล  $L$

$(B_{\max(0 \rightarrow t)}^{diff})^L$  = ค่าสัมประสิทธิ์สูงสุดจากการแปลงเวฟเล็ดของกระแสผลต่างเฟส B ณ เวลาตั้งแต่ 0 จนถึง  $t$  ที่สเกล  $L$

$(C_{\max(0 \rightarrow t)}^{diff})^L$  = ค่าสัมประสิทธิ์สูงสุดจากการแปลงเวฟเล็ดของกระแสผลต่างเฟส C ณ เวลาตั้งแต่ 0 จนถึง  $t$  ที่สเกล  $L$

$(A_{chk(post)}^{diff})^L$  = ค่าตรวจสอบการเปลี่ยนแปลงของสัมประสิทธิ์จากการแปลงเวฟเล็ดของกระแสผลต่างเฟส A ระหว่างก่อนเกิดฟอลต์และหลังเกิดฟอลต์ ซึ่งจะมีค่าเท่ากับ 1 หรือ 0 เท่านั้น

$(B_{chk(post)}^{diff})^L$  = ค่าตรวจสอบการเปลี่ยนแปลงของสัมประสิทธิ์จากการแปลงเวฟเล็ดของกระแสผลต่างเฟส B ระหว่างก่อนเกิดฟอลต์และหลังเกิดฟอลต์ ซึ่งจะมีค่าเท่ากับ 1 หรือ 0 เท่านั้น

$(C_{chk(post)}^{diff})^L$  = ค่าตรวจสอบการเปลี่ยนแปลงของสัมประสิทธิ์จากการแปลงเวฟเล็ดของกระแสผลต่างเฟส C ระหว่างก่อนเกิดฟอลต์และหลังเกิดฟอลต์ ซึ่งจะมีค่าเท่ากับ 1 หรือ 0 เท่านั้น

$(A_{chk(pre)}^{diff})^L$  = ค่าตรวจสอบการเปลี่ยนแปลงของสัมประสิทธิ์จากการแปลงเวฟเล็ดของ  
กระแสผลต่างเฟส A ระหว่างก่อนเกิดฟอลต์และหลังเกิดฟอลต์ ซึ่งจะมี  
ค่าเท่ากับ 1 หรือ 0 เท่านั้น

$(B_{chk(pre)}^{diff})^L$  = ค่าตรวจสอบการเปลี่ยนแปลงของสัมประสิทธิ์จากการแปลงเวฟเล็ดของ  
กระแสผลต่างเฟส B ระหว่างก่อนเกิดฟอลต์และหลังเกิดฟอลต์ ซึ่งจะมี  
ค่าเท่ากับ 1 หรือ 0 เท่านั้น

$(C_{chk(pre)}^{diff})^L$  = ค่าตรวจสอบการเปลี่ยนแปลงของสัมประสิทธิ์จากการแปลงเวฟเล็ดของ  
กระแสผลต่างเฟส C ระหว่างก่อนเกิดฟอลต์และหลังเกิดฟอลต์ ซึ่งจะมี  
ค่าเท่ากับ 1 หรือ 0 เท่านั้น

$Sum_{chk(post)}^L$  = ผลรวมของค่าตรวจสอบการเปลี่ยนแปลงของสัมประสิทธิ์จากการแปลง  
เวฟเล็ดของกระแสผลต่างหลังเกิดฟอลต์

$Sum_{chk(pre)}^L$  = ผลรวมของค่าตรวจสอบการเปลี่ยนแปลงของสัมประสิทธิ์จากการแปลง  
เวฟเล็ดของกระแสผลต่างก่อนเกิดฟอลต์

$X_{max(post)}^{diff}$  = ค่าสูงสุดของสัมประสิทธิ์จากการแปลงเวฟเล็ดขององค์ประกอบที่เฟส X  
ในช่วง  $\frac{1}{4}$  ไซเคิลหลังเกิดฟอลต์กระแสผลต่างในสเกลแรกที่ตรวจจับฟอลต์

ได้ (X จะแทนเฟส A, B และ C ตามลำดับ) เมื่อ  $X_{com}^{diff} = \frac{X_{max(post)}^{diff}}{Z_{max(post)}^{diff}}$

$Z_{max(post)}^{diff}$  = ค่าสูงสุดของสัมประสิทธิ์จากการแปลงเวฟเล็ดขององค์ประกอบลำดับศูนย์  
ในช่วง  $\frac{1}{4}$  ไซเคิลหลังเกิดฟอลต์กระแสผลต่างในสเกลแรก  
ที่ตรวจจับฟอลต์ได้

$Z_{max(pre)}^{diff}$  = ค่าสูงสุดของสัมประสิทธิ์จากการแปลงเวฟเล็ดขององค์ประกอบลำดับศูนย์  
ในช่วงก่อนเกิดฟอลต์กระแสผลต่างในสเกลแรก  
ที่ตรวจจับฟอลต์ได้

$Ph_{max}^{diff}$  = ค่าสูงที่สุดของค่าเปรียบเทียบทั้ง 3 เฟส ( $A_{com}^{diff}$ ,  $B_{com}^{diff}$  และ  $C_{com}^{diff}$ ) ในสเกลแรก  
ที่ตรวจจับฟอลต์ได้

$Ph_{min}^{diff}$  = ค่าต่ำที่สุดของค่าเปรียบเทียบทั้ง 3 เฟส ( $A_{com}^{diff}$ ,  $B_{com}^{diff}$  และ  $C_{com}^{diff}$ ) ในสเกลแรก  
ที่ตรวจจับฟอลต์ได้

สำหรับการตรวจจับการเปลี่ยนแปลงที่เกิดขึ้นนั้น จะเห็นได้จากรูปที่ 6.3 และ 6.4 ว่า ค่าสัมประสิทธิ์ความถี่สูงในสภาวะที่เริ่มมีฟอลต์ ( $t \geq 0.04$  sec) แต่ละสเกลจะมีค่าสูงขึ้นอย่างรวดเร็ว และมากกว่าค่าสัมประสิทธิ์ความถี่สูงในสภาวะก่อนเกิดฟอลต์ ( $t < 0.04$  sec) ด้วยเหตุนี้เอง ในวิทยานิพนธ์จึงตั้งสมมติฐานสำหรับการตรวจจับการเปลี่ยนแปลงที่เกิดขึ้นไว้ว่า “ณ ตำแหน่งซึ่ง

สัมประสิทธิ์กระแสผลต่างในสัญญาณองค์ประกอบความถี่สูง (Detail) สเกลที่กำลังพิจารณาตรวจจับ มีการเปลี่ยนแปลงสูงมากกว่า 5 เท่าของขนาดสูงสุดสัมประสิทธิ์การแปลงเวฟเลตในสถานะเดิม ให้ถือว่า ณ ตำแหน่งนั้น หม้อแปลงเกิดการเปลี่ยนแปลงเนื่องจากฟอลต์” นอกจากนี้เพื่อให้ตำแหน่งเวลาที่ตรวจจับมีเพียงตำแหน่งเดียว จึงกำหนดให้ “ตำแหน่งการเปลี่ยนแปลงที่ตรวจจับได้ในแต่ละเฟส หากเฟสใดสามารถตรวจจับการเปลี่ยนแปลงได้รวดเร็วที่สุด ให้ถือว่าตำแหน่งการเปลี่ยนแปลงดังกล่าวเป็นจุดเริ่มต้นของการเปลี่ยนแปลงที่เกิดขึ้นในหม้อแปลง” โดยสามารถแสดงรูปแบบการวิเคราะห์ [42] ได้ดังนี้

for L = 1:5

for t = 0.000005 : 0.000005 : 0.1

if  $\{(A_{chk(post)}^{diff})^L = 0 \text{ and } (A_{chk(pre)}^{diff})^L = 0\}$

then if  $\{(A_{(t+5us)}^{diff})^L \geq 5 * (A_{\max(0 \rightarrow t)}^{diff})^L\}$

then

$$(A_{chk(post)}^{diff})^L = 1$$

$$(A_{chk(pre)}^{diff})^L = 0$$

else

$$(A_{chk(post)}^{diff})^L = 0$$

$$(A_{chk(pre)}^{diff})^L = 1$$

end (จบเงื่อนไขของการตรวจจับการเปลี่ยนแปลงเฟส A)

end

if  $\{(B_{chk(post)}^{diff})^L = 0 \text{ and } (B_{chk(pre)}^{diff})^L = 0\}$

then if  $\{(B_{(t+5us)}^{diff})^L \geq 5 * (B_{\max(0 \rightarrow t)}^{diff})^L\}$

then

$$(B_{chk(post)}^{diff})^L = 1$$

$$(B_{chk(pre)}^{diff})^L = 0$$

else

$$(B_{chk(post)}^{diff})^L = 0$$

$$(B_{chk(pre)}^{diff})^L = 1$$

end (จบเงื่อนไขของการตรวจจับการเปลี่ยนแปลงเฟส B)

end

if  $\{(C_{chk(post)}^{diff})^L = 0 \text{ and } (C_{chk(pre)}^{diff})^L = 0\}$

then if  $\{(C_{(t+5us)}^{diff})^L \geq 5 * (C_{\max(0 \rightarrow t)}^{diff})^L\}$

then

$$(C_{chk(post)}^{diff})^L = 1$$

$$(C_{chk(pre)}^{diff})^L = 0$$

else

$$(C_{chk(post)}^{diff})^L = 0$$

$$(C_{chk(pre)}^{diff})^L = 1$$

end (จบเงื่อนไขของการตรวจจับการเปลี่ยนแปลงเฟส C)

end

end (จบเงื่อนไขของการเปลี่ยนแปลงเวลา)

end (จบเงื่อนไขของการเปลี่ยนแปลงสเกล)

$$Sum_{(post)}^L = (A_{chk(post)}^{diff})^L + (B_{chk(post)}^{diff})^L + (C_{chk(post)}^{diff})^L$$

$$Sum_{(pre)}^L = (A_{chk(pre)}^{diff})^L + (B_{chk(pre)}^{diff})^L + (C_{chk(pre)}^{diff})^L$$

if  $\{Sum_{(post)}^L \geq Sum_{(pre)}^L \text{ and } Sum_{(post)}^L \geq 2\}$

then

Fault condition

else

Normal condition

end (จบเงื่อนไขของการตรวจจับการเปลี่ยนแปลง)

เมื่อทำตามขั้นตอนที่กล่าวมาข้างต้นจนครบทุกสเกลแล้ว ขั้นตอนสุดท้ายคือการสรุปข้อมูลจากสเกลที่ 1-5 ดังต่อไปนี้

1. ถ้าสามารถตรวจจับฟอลต์ในสเกลใด สามารถสรุปได้ว่า เกิดฟอลต์ขึ้นในระบบและนำข้อมูลในสเกลแรกที่สามารถตรวจจับการเปลี่ยนแปลงได้ฟอลต์ได้เป็นข้อมูลอินพุตให้กับโครงข่ายประสาทเทียมต่อไป
2. ถ้าไม่สามารถตรวจจับฟอลต์ในสเกลใด สามารถสรุปได้ว่า ไม่มีฟอลต์เกิดขึ้นในระบบ

ในส่วนการแบ่งแยกระหว่างฟอลต์ภายในขดลวดหม้อแปลงกับฟอลต์ที่เกิดขึ้นภายนอกหม้อแปลงจะอาศัยการพิจารณาต่อเนื่องจากการตรวจจับการเปลี่ยนแปลงในสัมประสิทธิ์องค์ประกอบความถี่สูง ในขั้นตอนนี้เป็นการนำสัญญาณของกระแสผลต่าง (Differential current) ในแต่ละเฟสรวมทั้งกระแสองค์ประกอบลำดับศูนย์ในสเกลแรกที่สามารถตรวจจับฟอลต์ได้มาร่วมพิจารณาด้วย โดยรูปแบบการวิเคราะห์ที่อาศัยพิจารณาการเปลี่ยนแปลงอัตราส่วนสัมประสิทธิ์องค์ประกอบความถี่สูง (Detail) ในแต่ละเฟสกับสัมประสิทธิ์ความถี่สูงขององค์ประกอบลำดับศูนย์และเพื่อให้ ข้อมูลที่จะนำไปวิเคราะห์มีรูปแบบที่ชัดเจน โดยสามารถแสดงรูปแบบการพิจารณาได้ดังนี้

```

if [(5 ≤  $\frac{Z_{\max(post)}^{diff}}{Z_{\max(pre)}^{diff}} < 10000$ ) and ( $A_{chk}^{diff} + B_{chk}^{diff} + C_{chk}^{diff} \geq 2$ )]
    then if [(10 <  $Ph_{\max}^{diff} < 50$ ) and ( $Ph_{\min}^{diff} < 10$ )]
        then fault in transformer at low voltage side
        else then fault in transmission lines at low voltage transformer side
    end (จบเงื่อนไขของการแบ่งแยกฟอลต์ทางด้านแรงดันต่ำ)
else if [( $\frac{Z_{\max(post)}^{diff}}{Z_{\max(pre)}^{diff}} \geq 10000$ ) and ( $A_{chk}^{diff} + B_{chk}^{diff} + C_{chk}^{diff} \geq 2$ )]
    then if [(5 <  $Ph_{\max}^{diff} < 7$ ) and ( $0.05 < Ph_{\min}^{diff} < 1$ )]
        then fault in transformer at high voltage side
        else then fault in transmission lines at high voltage transformer side
    end (จบเงื่อนไขการแบ่งแยกฟอลต์ทางด้านแรงดันสูง)
end


```

ดังที่ได้กล่าวมาในข้างต้น ซึ่งได้กำหนดเกณฑ์ที่จะเลือกสเกลที่จะเป็นข้อมูลอินพุทให้กับโครงข่ายประสาทเทียมไว้โดยใช้ข้อมูลในสเกลแรกที่พบการเปลี่ยนแปลงของสัมประสิทธิ์มากกว่า 5 เท่า จากสภาวะปกติของกระแสผลต่าง ในบางครั้ง อาจจะไม่พบในสเกลที่ 1 หรือมีการเปลี่ยนแปลงไม่เป็นไปตามสมมุติฐานก็จะเลื่อนไปใช้ในสเกลที่สูงกว่า (2, 3, 4 และ 5) ได้


จากที่กล่าวมาข้างต้นเพื่อแสดงขั้นตอนการตรวจจับฟอลต์ที่ชัดเจน จึงขอยกตัวอย่างการตรวจจับสัญญาณฟอลต์ด้วยเทคนิคเปรียบเทียบสัมประสิทธิ์ความถี่สูงที่ได้จากการแปลงเวฟเฟ็ดในหัวข้อถัดไป

### 6.1.4 ตัวอย่างการตรวจจับฟอลต์


ในส่วนขั้นตอนการตรวจจับฟอลต์เป็นขั้นตอนสำคัญเพื่อให้เห็นขั้นตอนการวิเคราะห์ที่ชัดเจน ในหัวข้อนี้จึงได้ยกตัวอย่างสัญญาณฟอลต์ทั้งภายในโซนและภายนอกโซนรวมถึงสัญญาณในสถานะปกติ โดยสามารถแสดงการวิเคราะห์ได้ดังนี้




รูปที่ 6.12 แสดงการแปลงเวฟเล็ตของสัญญาณกระแสผลต่างในสถานะปกติ



รูปที่ 6.13 แสดงการแปลงเวฟเล็ตของสัญญาณกระแสผลต่างในสถานะฟอลต์ภายนอกโซน



รูปที่ 6.14 แสดงการแปลงเวฟเล็ทของสัญญาณกระแสผลต่างในสภาวะฟอลต์ภายในโซนกรณี ฟอลต์ขัดลวดลัดวงจรลงดิน



รูปที่ 6.15 แสดงการแปลงเวฟเล็ทของสัญญาณกระแสผลต่างในสภาวะฟอลต์ภายในโซนกรณี ฟอลต์ขัดลวดลัดวงจรระหว่างรอบ

จากรูปที่ 6.12 จะเห็นได้ว่า ค่าสัมประสิทธิ์ความถี่สูงที่ได้จากการแปลงเวฟเล็ตในแต่ละเฟสมีขนาดใกล้เคียงกันตลอดช่วงสัญญาณ เมื่อพิจารณาในแต่ละสเกลจะเห็นได้ว่า ค่าสัมประสิทธิ์ความถี่สูงไม่มีการเปลี่ยนแปลงมากกว่า 5 เท่าทั้งสามเฟส ดังนั้นจึงสรุปได้ว่า ในขณะนี้หม้อแปลงอยู่ในสภาวะปกติ ด้วยเหตุนี้จึงไม่มีความจำเป็นต้องนำสัมประสิทธิ์ความถี่สูงในแต่ละเฟสมาทำการวิเคราะห์ต่อไป

จากรูปที่ 6.13-6.15 จะเห็นได้ว่า ค่าสัมประสิทธิ์ความถี่สูงที่ได้จากการแปลงเวฟเล็ตในแต่ละเฟสและในแต่ละเฟสมีการเปลี่ยนแปลงมากกว่า 5 เท่าดังแสดงในตารางที่ 6.6-6.8 ตามลำดับ ดังนั้นจึงต้องนำสัมประสิทธิ์ความถี่สูงในแต่ละเฟสมาทำการวิเคราะห์และเปรียบเทียบเพื่อสั่งให้รีเลย์ทำงานหรือไม่ทำงาน

ตารางที่ 6.6 แสดงค่าตรวจสอบการเปลี่ยนแปลงเมื่อพิจารณาสัญญาณตามรูปที่ 6.13

Wavelet Scale	Differential Current												Result		
	Phase A				Phase B				Phase C						
	Max (pre)	Max (post)	A <sub>Chk</sub> (pre)	A <sub>Chk</sub> (post)	Max (pre)	Max (post)	B <sub>Chk</sub> (pre)	B <sub>Chk</sub> (post)	Max (pre)	Max (post)	C <sub>Chk</sub> (pre)	C <sub>Chk</sub> (post)	Sum (pre)	Sum (post)	
1	0.0003	5835	0	1	0.0003	3.359	0	1	0.0002	3.369	0	1	0	3	Fault
2	0.006	20111	0	1	0.0043	18.233	0	1	0.0014	16.953	0	1	0	3	Fault
3	0.0225	9293	0	1	0.0155	83.152	0	1	0.0097	82.374	0	1	0	3	Fault
4	0.0152	580	0	1	0.0157	98.938	0	1	0.0027	100.198	0	1	0	3	Fault
5	11.61	171	0	1	0.0455	10.534	0	1	0.0471	11.101	0	1	0	3	Fault

ตารางที่ 6.7 แสดงค่าตรวจสอบการเปลี่ยนแปลงเมื่อพิจารณาสัญญาณตามรูปที่ 6.14

Wavelet Scale	Differential Current												Result		
	Phase A				Phase B				Phase C						
	Max (pre)	Max (post)	A <sub>Chk</sub> (pre)	A <sub>Chk</sub> (post)	Max (pre)	Max (post)	B <sub>Chk</sub> (pre)	B <sub>Chk</sub> (post)	Max (pre)	Max (post)	C <sub>Chk</sub> (pre)	C <sub>Chk</sub> (post)	Sum (pre)	Sum (post)	
1	0.0003	165.09	0	1	0.0004	3.82	0	1	0.0003	3.80	0	1	0	3	Fault
2	0.0019	99.99	0	1	0.0018	22.40	0	1	0.0014	14.80	0	1	0	3	Fault
3	0.0102	386.61	0	1	0.0078	99.86	0	1	0.0084	95.05	0	1	0	3	Fault
4	0.0235	3714	0	1	0.0095	254.76	0	1	0.0052	203.26	0	1	0	3	Fault
5	0.8549	17651	0	1	0.2025	29.89	0	1	0.2056	27.67	0	1	0	3	Fault

ตารางที่ 6.8 แสดงค่าตรวจสอบการเปลี่ยนแปลงเมื่อพิจารณาสัญญาณตามรูปที่ 6.15

Wavelet Scale	Differential Current												Result		
	Phase A				Phase B				Phase C						
	Max (pre)	Max (post)	A <sub>Chk</sub> (pre)	A <sub>Chk</sub> (post)	Max (pre)	Max (post)	B <sub>Chk</sub> (pre)	B <sub>Chk</sub> (post)	Max (pre)	Max (post)	C <sub>Chk</sub> (pre)	C <sub>Chk</sub> (post)	Sum (pre)	Sum (post)	
1	0.0003	170.88	0	1	0.0003	3.95	0	1	0.0002	3.95	0	1	0	3	Fault
2	0.0019	103.15	0	1	0.0021	22.66	0	1	0.0014	14.96	0	1	0	3	Fault
3	0.0111	394.97	0	1	0.0085	100.58	0	1	0.0102	95.78	0	1	0	3	Fault
4	0.0242	3852	0	1	0.0109	258.49	0	1	0.0037	206.95	0	1	0	3	Fault
5	0.8865	18900	0	1	0.2059	30.61	0	1	0.2106	28.28	0	1	0	3	Fault

ในส่วนการแบ่งแยกระหว่างฟอลต์ภายในขดลวดหม้อแปลงกับฟอลต์ที่เกิดขึ้นภายนอกหม้อแปลงจะอาศัยการพิจารณาต่อเนื่องจากตารางที่ 6.7-6.9 ตามลำดับ ส่วนผลสรุปแสดงในตารางที่ 6.9-6.11 ตามลำดับ

ตารางที่ 6.9 แสดงผลสรุปการวิเคราะห์การตรวจจับฟอลต์เมื่อพิจารณาสัญญาณตามรูปที่ 6.13

Phase A		Phase B		Phase C		Zero sequence			Ph <sub>max</sub>	Ph <sub>min</sub>	Result	
Max (post)	A <sub>com</sub>	Max (post)	B <sub>com</sub>	Max (post)	C <sub>com</sub>	Max (pre)	Max (post)	Ratio Z <sub>ma</sub>			Zone	Status
5835	3.2359	3.359	0.0019	3.369	0.0019	0.0001	1803.2	18032000	3.2359	0.0019	External	No Trip

ตารางที่ 6.10 แสดงผลสรุปการวิเคราะห์การตรวจจับฟอลต์เมื่อพิจารณาสัญญาณตามรูปที่ 6.14

Phase A		Phase B		Phase C		Zero sequence			Ph <sub>max</sub>	Ph <sub>min</sub>	Result	
Max (post)	A <sub>com</sub>	Max (post)	B <sub>com</sub>	Max (post)	C <sub>com</sub>	Max (pre)	Max (post)	Ratio Z <sub>ma</sub>			Zone	Status
165.09	6.19	3.82	0.1432	3.80	0.1425	0.0001	26.67	266700	6.19	0.1425	Internal	Trip

ตารางที่ 6.11 แสดงผลสรุปการวิเคราะห์การตรวจจับฟอลต์เมื่อพิจารณาสัญญาณตามรูปที่ 6.15

Phase A		Phase B		Phase C		Zero sequence			Ph <sub>max</sub>	Ph <sub>min</sub>	Result	
Max (post)	A <sub>com</sub>	Max (post)	B <sub>com</sub>	Max (post)	C <sub>com</sub>	Max (pre)	Max (post)	Ratio Z <sub>ma</sub>			Zone	Status
170.88	6.1984	3.95	0.1433	3.95	0.1433	0.0001	27.57	275700	6.1984	0.1433	Internal	Trip


จากรูปที่ 6.12-6.15 และตารางที่ 6.6 – 6.11 พบว่าเมื่อพิจารณาการเปลี่ยนแปลงของสัมประสิทธิ์การแปลงเวฟสี่ตจากกระแสผลต่างในแต่ละเฟสของหม้อแปลงไฟฟ้ากำลังแล้วสามารถระบุได้ว่ามีฟอลต์เกิดขึ้นและตรวจจับฟอลต์ได้โดยใช้สเกลที่ 1 พร้อมทั้งสามารถนำไปเป็นเกณฑ์ตัดสินใจในการนำข้อมูลในสเกลที่ 1 นำไปเป็นอินพุทให้กับโครงข่ายประสาทเทียม

## 6.2 การวิเคราะห์ด้วยโครงข่ายประสาทเทียม

ในปัจจุบันมีชนิดของโครงข่ายประสาทเทียมเป็นจำนวนมาก ด้วยเหตุที่มีโครงข่ายประสาทเทียมหลากหลายชนิดจึงสามารถนำไปใช้ในลักษณะงานที่แตกต่างกัน เช่น การพยากรณ์ การแบ่งประเภท และการจดจำข้อมูล เป็นต้น สำหรับการแบ่งประเภทนั้นได้มีโครงข่ายประสาทเทียมหลายชนิดด้วยกันที่สามารถนำมาใช้ในงานทางด้านแบ่งประเภทเช่น โครงข่ายประสาทเทียมชนิดความน่าจะเป็น (Probabilistic neural network : PNN) โครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (Back-propagation neural network : BPNN) เป็นต้น อย่างไรก็ตาม โครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับเป็นหนึ่งในโครงข่ายประสาทเทียมที่นิยมใช้ เนื่องจากโครงข่ายประสาทเทียมชนิดนี้สามารถใช้แก้ปัญหาได้เกือบทุกประเภท [27, 29] ในวิทยานิพนธ์นี้ได้เลือกใช้โครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ เนื่องจาก ในวิทยานิพนธ์นี้มุ่งเน้นที่ค่าความถูกต้องเป็นหลัก ไม่ได้พิจารณาที่เวลาในการฝึกสอน ดังนั้น เพื่อให้เห็นภาพชัดเจนจึงได้นำโครงข่ายประสาทเทียมชนิดความน่าจะเป็นมาเปรียบเทียบ เพื่อให้เห็นว่า โครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับมีความสามารถในการแบ่งประเภทฟอลต์ภายในหม้อแปลงไฟฟ้ากำลังได้ดีกว่าโครงข่ายประสาทเทียมชนิดความน่าจะเป็น (แสดงในภาคผนวก ข)

เนื่องจากการฝึกสอนโครงข่ายประสาทเทียมในวิทยานิพนธ์จะใช้ Neural Network Toolbox [30] ของโปรแกรม MATLAB และทำการทดสอบโดยใช้เครื่องคอมพิวเตอร์ส่วนบุคคลที่ติดตั้ง CPU Pentium 4 ความเร็ว 2.4 GHz หน่วยความจำ 512 MB ฝึกสอนโครงข่ายประสาทเทียมซึ่งได้แสดงในรูปที่ 6.16 (เอาต์พุทของโครงข่ายประสาทเทียมสามารถหาได้ตามสมการที่ 6.1) ดังนั้นองค์ประกอบบางชนิดที่มีผลต่อการเรียนรู้ของโครงข่ายประสาทเทียม โปรแกรม MATLAB ได้ทำการกำหนดไว้แล้ว ยกเว้น องค์ประกอบบางชนิดเช่น กลุ่มของรูปแบบอินพุทและเอาต์พุท จำนวนของข้อมูล

ฝึกสอนและข้อมูลทดสอบ เป็นต้น ซึ่งตัวผู้ฝึกสอนจะเป็นผู้กำหนดเอง ในเบื้องต้นได้ทำการเปลี่ยนแปลงค่าฟังก์ชันกระตุ้นทั้งหมด 12 กรณี สามารถสรุปได้ว่า ฟังก์ชันกระตุ้นที่อยู่ในชั้นซ่อนที่ 1 และ 2 จะใช้ชนิดแทนเจนท์ซิกมอยด์ (Tan-sigmoid) ส่วนชั้นเอาต์พุทจะใช้ฟังก์ชันกระตุ้นชนิดเชิงเส้น (Linear) ให้ประสิทธิภาพดีที่สุด



รูปที่ 6.16 แบบจำลองของโครงข่ายประสาทเทียมที่มี 2 ชั้นซ่อน [30]

$$o/p_{ANN} = f^3(LW^{3,2} * f^2(LW^{2,1} * f^1(IW^{1,1} * P + b^1) + b^2) + b^3) \quad (6.1)$$

โดยที่  $IW^{1,1}$  คือ ค่าถ่วงน้ำหนักที่เชื่อมระหว่างชั้นข้อมูลอินพุทกับชั้นซ่อนที่ 1

$LW^{2,1}$  คือ ค่าถ่วงน้ำหนักที่เชื่อมระหว่างชั้นซ่อนที่ 1 กับชั้นซ่อนที่ 2

$LW^{3,2}$  คือ ค่าถ่วงน้ำหนักที่เชื่อมระหว่างชั้นซ่อนที่ 2 กับชั้นเอาต์พุท

$b^1, b^2$  คือ ค่าไบแอสในชั้นซ่อนที่ 1 และ 2

$b^3$  คือ ค่าไบแอสในชั้นเอาต์พุท

$f^1, f^2$ , คือ ฟังก์ชันกระตุ้นชนิดแทนเจนท์ซิกมอยด์ (Tan-sigmoid)

$f^3$  คือ ฟังก์ชันกระตุ้นชนิดเชิงเส้น (Linear)

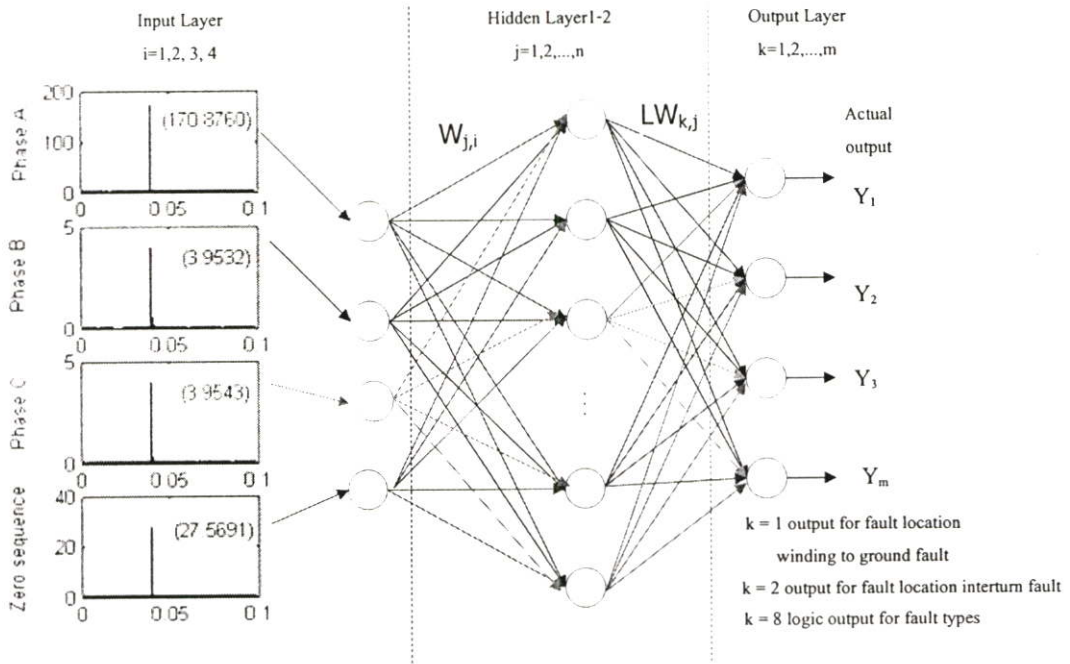
$P = [P_1, P_2, \dots, P_R]$  คือ เวกเตอร์อินพุทของโครงข่าย

จุดมุ่งหมายการฝึกสอนโครงข่ายประสาทเทียมในวิทยานิพนธ์คือ ฝึกสอนเพื่อให้ได้เอาต์พุทที่ต้องการคือ ตำแหน่งขดลวดที่เกิดการลัดวงจร (ฟอลต์) และประเภทฟอลต์ที่เกิดขึ้น ซึ่งจะมีขั้นตอนการฝึกสอนและการวิเคราะห์ดังนี้

### 6.2.1 การระบุตำแหน่งขดลวดที่เกิดการลัดวงจร (Fault location)

ในวิทยานิพนธ์ฉบับนี้ได้ทำการเลือกตัวแปรอินพุทในส่วนของ การระบุตำแหน่งขดลวดที่เกิดการลัดวงจร (ฟอลต์) โดยใช้ค่าสูงสุดของสัมประสิทธิ์จากการแปลงเวฟเล็ดในสเกลแรกนี้

ตรวจจับพอลต์ได้ของกระแสผลต่างจากเฟส A, B, C และองค์ประกอบลำดับศูนย์ในช่วง  $\frac{1}{4}$  ไซเคิล หลังเกิดพอลต์ตามลำดับ ดังแสดงในรูปที่ 6.17 เนื่องจากตัวแปรอินพุททั้ง 4 ค่า มีความสัมพันธ์กับ ตำแหน่งขดลวดที่เกิดการลัดวงจรดังแสดงในตารางที่ 6.1 ในส่วนตัวแปรเอาต์พุทจะมีค่าจะมีค่า เปลี่ยนแปลงอยู่ระหว่าง '0.1' ถึง '0.9' ซึ่งสัมพันธ์กับระยะทางหรือตำแหน่งขดลวดที่เกิดการ ลัดวงจรภายในหม้อแปลงไฟฟ้ากำลัง



รูปที่ 6.17 แสดงตัวแปรอินพุทสำหรับโครงข่ายประสาทเทียม

### 6.2.1.1 การระบุตำแหน่งกรณีขดลวดที่เกิดการลัดวงจรลงดิน

ก่อนที่จะทำการฝึกสอนโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ จำนวนชุดข้อมูล ฝึกสอนกับจำนวนชุดข้อมูลตรวจสอบสำหรับระบุตำแหน่งขดลวดที่เกิดการลัดวงจรลงดินทางด้าน แรงดันสูงจะมีจำนวน 216 ชุดและ 108 ชุด ตามลำดับ จะถูกจัดระเบียบข้อมูล (Normalization)[26] ให้มีค่าเฉลี่ย (Mean) เท่ากับศูนย์ และค่าเบี่ยงเบนมาตรฐาน (Variance) เท่ากับหนึ่ง และสเกลลิง (Scaling) เพื่อทำให้ข้อมูลอยู่ในช่วงของฟังก์ชันกระตุ้น ก่อนที่นำมาฝึกสอนและทดสอบกับ โครงข่ายประสาทเทียม จากนั้น ทำการคำนวณจำนวนนิวรอนเริ่มต้นและนิวรอนสุดท้ายในชั้นซ่อน ที่ 1 ดังแสดงในสมการที่ 4.35 โครงสร้างก่อนฝึกสอนจะประกอบไปด้วยจำนวนนิวรอนในแต่ละ ชั้นดังนี้ ในชั้นอินพุทมี 4 นิวรอน ในชั้นซ่อนที่ 1 และ 2 มี 4 และ 3 นิวรอน (คำนวณตามสมการที่ 4.35) ตามลำดับ และในชั้นเอาต์พุทมี 1 นิวรอน ( $k=1$  ดังแสดงในรูปที่ 6.17) ซึ่งมีค่าเอาต์พุทของ โครงข่ายประสาทเทียมอยู่ระหว่าง 0.1 ถึง 0.9 โดยจะมีค่าสัมพันธ์กับตำแหน่งขดลวดที่เกิดการ ลัดวงจรลงดินทางด้านแรงดันสูง ดังที่ได้กล่าวมาแล้วข้างต้น ในส่วนของฟังก์ชันกระตุ้นที่อยู่ในชั้น ซ่อนที่ 1 และ 2 จะใช้ชนิด แทนเจนท์ซิกมอยด์ (Tan-sigmoid) ส่วนชั้นเอาต์พุทจะใช้ฟังก์ชันกระตุ้น ชนิดเชิงเส้น (Linear)

ระหว่างการฝึกสอนโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ จะเริ่มต้นด้วยการสุ่มค่าถ่วงน้ำหนักและค่าไบแอสเพียงครั้งเดียว (Random initial weight and biases) ให้กับโครงสร้างเริ่มต้นของโครงข่ายประสาทเทียมดังที่ได้กล่าวมาแล้วในข้างต้น หนึ่งรอบการฝึกสอนจะแบ่งออกเป็น 3 ชั้นตอน : ป้อนค่าอินพุตที่ได้รับจากชั้นอินพุตมาคำนวณหาค่าตอบหรือเอาต์พุตของโครงข่ายประสาทเทียมตามสมการที่ 6.1 สำหรับแต่ละรูปแบบข้อมูลที่ป้อนให้ จากนั้น แพร่ค่าย้อนกลับของค่าผิดพลาดระหว่างเอาต์พุตของโครงข่ายประสาทเทียมกับเอาต์พุตเป้าหมายและทำการปรับเปลี่ยนค่าถ่วงน้ำหนักและค่าไบแอสด้วย Levenberg - Maquardt algorithm (trainlm)[30] ซึ่งค่าถ่วงน้ำหนักและค่าไบแอสจะเปลี่ยนไปมากหรือน้อยขึ้นอยู่กับปริมาณของค่าความผิดพลาดที่ได้รับ กระบวนการจะกลับไปทำซ้ำในชั้นตอนแรกเป็นจำนวน 20,000 ครั้ง (Iteration) เพื่อคำนวณหาค่าเปอร์เซ็นต์ผิดพลาดเฉลี่ยสัมบูรณ์ (MAPE) ของชุดข้อมูลตรวจสอบที่ดีที่สุด ดังสมการที่ 6.2 จากนั้นทำการเพิ่มจำนวนนิวรอนในชั้นซ่อนที่ 1 และ 2 เพิ่มขึ้นทีละ 1 จนครบ 6 (เพื่อหาโครงสร้างของโครงข่ายประสาทเทียมที่มีประสิทธิภาพสูงที่สุด) หรือจนกว่าค่า MAPE ต่ำกว่า 0.5% แล้วหยุดฝึกสอน

$$MAPE = \frac{1}{n} * \sum_{i=1}^n \left| \frac{o/p_{ANNi} - o/p_{TARGETi}}{o/p_{TARGETi}} \right| * 100\% \quad (6.2)$$

โดยที่  $o/p_{ANN}$  คือ เอาต์พุตที่เป็นคำตอบของโครงข่ายประสาทเทียม

$o/p_{TARGET}$  คือ เอาต์พุตที่เป็นคำตอบที่ต้องการ

$n$  คือ จำนวนชุดข้อมูลตรวจสอบ

หลังจากฝึกสอนโครงข่ายประสาทเทียมเสร็จสิ้น โดยจะใช้เวลาในการฝึกสอนที่ดีที่สุดประมาณ 7.46 นาที และจำนวนนิวรอนในชั้นซ่อนที่ 1- 2 และชั้นเอาต์พุตเป็น 8, 7 และ 1 นิวรอนตามลำดับ ผลสรุปของการฝึกสอนเพื่อระบุตำแหน่งขดลวดที่เกิดการลัดวงจรลงดินทางด้านแรงดันสูงได้แสดงในตารางที่ 6.12 อนึ่ง เพื่อให้เห็นความชัดเจนมากขึ้น เมื่อนำสมการที่ 4.24 มาช่วยในการลดเวลาฝึกสอน จึงได้ทำการฝึกสอนตามวิธีที่ 2 โดยผลสรุปการฝึกสอนได้แสดงในตารางที่ 6.12 (วิธีที่ 2) จากนั้นจึงนำค่าถ่วงน้ำหนักและค่าไบแอสที่ทำให้โครงข่ายประสาทเทียมมีประสิทธิภาพสูงที่สุด (ชุดที่มีค่า MAPE ของชุดตรวจสอบดีที่สุด) มาทดสอบกับข้อมูลทดสอบจำนวน 108 ชุด โดยให้เพียงเฉพาะค่าอินพุตเช่นเดียวกับการทดสอบไม่มีค่าเอาต์พุตเป้าหมายและพิจารณาค่าตอบที่ได้ว่าใกล้เคียงกับค่าเอาต์พุตเป้าหมายที่ถูกต้องหรือไม่ (ผลสรุปการทดสอบได้แสดงในบทถัดไป) ส่วนการฝึกสอนเพื่อระบุตำแหน่งขดลวดที่เกิดการลัดวงจรลงดินทางด้าน

แรงดันต่ำได้ทำการฝึกสอนเหมือนกับทางด้านแรงดันสูง ซึ่งผลสรุปการฝึกสอนได้แสดงในตารางที่ 6.13

ตารางที่ 6.12 แสดงผลสรุปจากการฝึกสอนเพื่อระบุตำแหน่งขดลวดที่เกิดการลัดวงจรลงดินทางด้านแรงดันสูง

จำนวนนิวรอนในชั้นซ่อนที่ 1-2		2-1	3-2	4-3	5-4	6-5	7-6	8-7	9-8	10-9	11-10
วิธีที่ 1	MAPE ชุดตรวจสอบ(%)	-	-	0.86	0.79	0.74	0.75	<b>0.70</b>	0.73	-	-
	เวลาที่ใช้ในการฝึกสอนในแต่ละรอบ (นาที)	-	-	3.41	4.25	5.16	6.35	<b>7.46</b>	10.46	-	-
	เวลาทั้งหมดในการฝึกสอน (นาที)	38.29									
วิธีที่ 2	MAPE ชุดตรวจสอบ(%)	7.92	1.14	0.87	0.77	0.70	0.73	0.70	0.74	0.76	<b>0.64</b>
	เวลาที่ใช้ในการฝึกสอนในแต่ละรอบ (นาที)	2.07	3.40	4.01	4.37	5.36	7.19	8.37	11.09	13.31	<b>16.51</b>
	เวลาทั้งหมดในการฝึกสอน (นาที)	77.27									

ตารางที่ 6.13 แสดงผลสรุปจากการฝึกสอนเพื่อระบุตำแหน่งขดลวดที่เกิดการลัดวงจรลงดินทางด้านแรงดันต่ำ

จำนวนนิวรอนในชั้นซ่อนที่ 1-2		2-1	3-2	4-3	5-4	6-5	7-6	8-7	9-8	10-9	11-10
วิธีที่ 1	MAPE ชุดตรวจสอบ(%)	-	-	4.19	2.70	<b>2.32</b>	2.72	2.97	2.84	-	-
	เวลาที่ใช้ในการฝึกสอนในแต่ละรอบ (นาที)	-	-	3.57	4.27	<b>5.36</b>	6.45	8.34	10.44	-	-
	เวลาทั้งหมดในการฝึกสอน (นาที)	40.03									
วิธีที่ 2	MAPE ชุดตรวจสอบ(%)	4.93	4.37	3.91	3.05	2.87	2.97	<b>1.77</b>	3.10	3.07	2.91
	เวลาที่ใช้ในการฝึกสอนในแต่ละรอบ (นาที)	2.30	2.32	3.34	4.18	5.24	6.23	<b>7.40</b>	10.33	12.46	16.46
	เวลาทั้งหมดในการฝึกสอน (นาที)	72.26									

### 6.2.1.2 การระบุตำแหน่งกรณีขดลวดที่เกิดการลัดวงจรระหว่างรอบ

ก่อนที่จะทำการฝึกสอน โครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ จำนวนชุดข้อมูลฝึกสอนกับจำนวนชุดข้อมูลตรวจสอบสำหรับระบุตำแหน่งขดลวดที่เกิดการลัดวงจรระหว่างรอบทางด้านแรงดันสูงจะมีจำนวน 648 ชุดและ 324 ชุด ตามลำดับ จะถูกจัดระเบียบข้อมูล (Normalization)[26] เช่นเดียวกับการระบุตำแหน่งกรณีขดลวดลัดวงจรลงดิน จากนั้น ทำการคำนวณจำนวนนิวรอนเริ่มต้นและนิวรอนสุดท้ายในชั้นซ่อนที่ 1 ดังแสดงในสมการที่ 4.35 โครงสร้างก่อนฝึกสอนจะประกอบไปด้วยจำนวนนิวรอนในแต่ละชั้นดังนี้ ในชั้นอินพุทมี 4 นิวรอน (ค่าสูงสุดของสัมประสิทธิ์จากการแปลงเวฟเล็ดในสเกลแรกที่ตรวจจับฟอลต์ได้ของกระแสผลต่างเฟส A, B, C และองค์ประกอบลำดับศูนย์ในช่วง  $\frac{1}{4}$  ไซเคิลหลังเกิดฟอลต์ตามลำดับ ดังรูปที่ 6.17 เนื่องจากตัวแปรอินพุททั้ง 4 ค่า มีการเปลี่ยนแปลงสัมพันธ์กับตำแหน่งขดลวดที่เกิดการลัดวงจรดังแสดงในตารางที่ 6.3-6.4) ในชั้นซ่อนที่ 1 และ 2 มี 4 และ 3 นิวรอน (คำนวณตามสมการที่ 4.35) ตามลำดับ และในชั้นเอาต์พุทมี 2 นิวรอน ( $k=2$  ดังแสดงในรูปที่ 6.17) ซึ่งมีค่าเอาต์พุทของโครงข่ายประสาทเทียมอยู่ระหว่าง 0.1 ถึง 0.9 โดยจะมีค่าสัมพันธ์กับตำแหน่งขดลวดย่อย a และ b ที่เกิดการลัดวงจรระหว่างรอบทางด้านแรงดันสูง ในส่วนของฟังก์ชันกระตุ้นที่อยู่ในชั้นซ่อนที่ 1 และ 2 จะใช้ชนิดแทนเจนต์ซิกมอยด์ (tan-sigmoid) ส่วนชั้นเอาต์พุทจะใช้ฟังก์ชันกระตุ้นชนิดเชิงเส้น (linear)

ระหว่างการฝึกสอน โครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ จะเริ่มต้นด้วยการสุ่มค่าถ่วงน้ำหนักและค่าไบแอสเพียงครั้งเดียว (Random initial weight and biases) ให้กับโครงสร้างเริ่มต้นของโครงข่ายประสาทเทียมดังที่ได้กล่าวมาแล้วในข้างต้น หนึ่งรอบการฝึกสอนจะแบ่งออกเป็น 3 ขั้นตอน (เช่นเดียวกับการระบุตำแหน่งขดลวดที่เกิดฟอลต์) โดยจะมีการปรับค่าถ่วงน้ำหนักและค่าไบแอสด้วย Levenberg - Maquardt algorithm (trainlm)[30] เป็นจำนวน 20,000 ครั้ง (Iteration) เพื่อคำนวณหาค่าเปอร์เซ็นต์ผิดพลาดเฉลี่ยสัมบูรณ์ (MAPE) ของชุดข้อมูลตรวจสอบที่ดีที่สุด ดังสมการที่ 6.2 จากนั้นทำการเพิ่มจำนวนนิวรอนในชั้นซ่อนที่ 1 และ 2 เพิ่มขึ้นทีละ 1 จนครบ 6 (เพื่อหาโครงสร้างของโครงข่ายประสาทเทียมที่มีประสิทธิภาพสูงที่สุด) หรือจนกว่าค่า MAPE ต่ำกว่า 0.5% แล้วหยุดฝึกสอน

หลังจากฝึกสอนโครงข่ายประสาทเทียมเสร็จสิ้น โดยจะใช้เวลาในการฝึกสอนที่ดีที่สุดประมาณ 44.13 นาที และจำนวนนิวรอนในชั้นซ่อนที่ 1-2 และชั้นเอาต์พุทเป็น 9, 8 และ 2 นิวรอนตามลำดับ ผลสรุปของการฝึกสอนเพื่อระบุตำแหน่งขดลวดที่เกิดการลัดวงจรระหว่างรอบทางด้านแรงดันสูงได้แสดงในตารางที่ 6.14 อนึ่ง เพื่อให้เห็นความชัดเจนมากขึ้น เมื่อนำสมการที่ 4.24 มาช่วยในการลดเวลาฝึกสอน จึงได้ทำการฝึกสอนตามวิธีที่ 2 โดยผลสรุปการฝึกสอนได้แสดงในตารางที่ 6.14 (วิธีที่ 2) จากนั้นจึงนำค่าถ่วงน้ำหนักและค่าไบแอสที่ทำให้โครงข่ายประสาทเทียมมีประสิทธิภาพสูงที่สุด (ชุดที่มีค่า MAPE ของชุดตรวจสอบดีที่สุด) มาทดสอบกับข้อมูลทดสอบจำนวน 324 ชุด โดยให้เพียงเฉพาะค่าอินพุทเช่นเดียวกับการทดสอบไม่มีค่าเอาต์พุทเป้าหมายและ

พิจารณาคำตอบที่ได้ว่าใกล้เคียงกับค่าเอาต์พุตเป้าหมายที่ถูกต้องหรือไม่ (ผลสรุปการทดสอบได้แสดงในบทถัดไป) ส่วนการฝึกสอนเพื่อระบุตำแหน่งขดลวดที่เกิดการลัดวงจรระหว่างรอบทางด้านแรงดันต่ำได้ทำการฝึกสอนเหมือนกับทางด้านแรงดันสูง ซึ่งผลสรุปการฝึกสอนได้แสดงในตารางที่ 6.15

ตารางที่ 6.14 แสดงผลสรุปจากการฝึกสอนเพื่อระบุตำแหน่งขดลวดที่เกิดการลัดวงจรระหว่างรอบทางด้านแรงดันสูง

จำนวนนิวรอนในชั้นซ่อนที่ 1-2		2-1	3-2	4-3	5-4	6-5	7-6	8-7	9-8	10-9	11-10
วิธีที่ 1	MAPE ชุดตรวจสอบ(%)			1.166	1.196	1.153	1.207	1.122	<b>1.06</b>		
	เวลาที่ใช้ในการฝึกสอน ในแต่ละรอบ (นาทึ)			12.21	16.11	20.20	26.23	34.44	<b>44.13</b>		
	เวลาทั้งหมดในการฝึกสอน (นาทึ)	154.12									
วิธีที่ 2	MAPE ชุดตรวจสอบ(%)	2.04	1.57	1.244	1.17	1.115	1.122	1.106	1.142	1.08	<b>1.078</b>
	เวลาที่ใช้ในการฝึกสอน ในแต่ละรอบ (นาทึ)	5.48	8.06	10.36	13.58	17.27	22.25	28.42	36.09	49.13	<b>56.17</b>
	เวลาทั้งหมดในการฝึกสอน (นาทึ)	248.41									

ตารางที่ 6.15 แสดงผลสรุปจากการฝึกสอนเพื่อระบุตำแหน่งขดลวดที่เกิดการลัดวงจรระหว่างรอบทางด้านแรงดันต่ำ

จำนวนนิวรอนในชั้นซ่อนที่ 1-2		2-1	3-2	4-3	5-4	6-5	7-6	8-7	9-8	10-9	11-10
วิธีที่ 1	MAPE ชุดตรวจสอบ(%)			1.53	1.558	<b>1.458</b>	1.544	1.495	1.515		
	เวลาที่ใช้ในการฝึกสอน ในแต่ละรอบ (นาทึ)			12.1	16.12	<b>20.19</b>	26.17	35.31	43.30		
	เวลาทั้งหมดในการฝึกสอน (นาทึ)	153.59									
วิธีที่ 2	MAPE ชุดตรวจสอบ(%)	1.80	1.54	1.49	1.554	1.541	1.512	<b>1.469</b>	1.505	1.496	1.529
	เวลาที่ใช้ในการฝึกสอน ในแต่ละรอบ (นาทึ)	5.42	7.37	11.4	16.1	21.43	29.55	<b>41.09</b>	53.46	63.17	66.11
	เวลาทั้งหมดในการฝึกสอน (นาทึ)	317.1									

### 6.2.2 การระบุประเภทฟอลต์ (Fault Identification)

ในวิทยานิพนธ์นี้ได้ทำการเลือกตัวแปรอินพุทในส่วนของกระบวนการระบุประเภทฟอลต์ โดยใช้ค่าสูงสุดของสัมประสิทธิ์จากการแปลงเวฟเล็ตในสเกลแรกที่ตรวจจับฟอลต์ได้ของกระแสผลต่างเฟส A, B, C และองค์ประกอบลำดับศูนย์ในช่วง  $\frac{1}{4}$  ไซเคิลหลังเกิดฟอลต์ตามลำดับ ดังรูปที่ 6.17 ซึ่งเป็นกลุ่มตัวแปรอินพุทชนิดเดียวกับที่ใช้ในการระบุตำแหน่งขดลวดที่เกิดฟอลต์ เนื่องจากตัวแปรอินพุททั้ง 4 ค่า มีการเปลี่ยนแปลงสัมพันธ์กับประเภทฟอลต์ที่เกิดขึ้นดังแสดงในตารางที่ 6.1-6.5 ในส่วนตัวแปรเอาต์พุทจะมีค่าเปลี่ยนแปลงอยู่ระหว่าง '0' กับ '1' ซึ่งสัมพันธ์กับเฟส (A, B, C) และกราวด์ (G) ทางด้านแรงดันสูงและแรงดันต่ำของหม้อแปลงไฟฟ้ากำลัง ตามลำดับ หรือชนิดฟอลต์ที่เกิดขึ้นภายในขดลวดหม้อแปลงไฟฟ้ากำลัง กล่าวคือ ถ้าคำตอบของโครงข่ายประสาทเทียมต่ำกว่า 0.5 แสดงว่าเฟสนั้นไม่เกิดฟอลต์ ในทางกลับกันถ้าคำตอบของโครงข่ายประสาทเทียมมากกว่าหรือเท่ากับ 0.5 แสดงว่าเฟสนั้นเกิดฟอลต์ ดังในตารางที่ 6.16

ก่อนที่จะทำการฝึกสอนโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ จำนวนชุดข้อมูลฝึกสอนกับจำนวนชุดข้อมูลตรวจสอบจะมีจำนวน 1620 ชุดและ 810 ชุด ตามลำดับ จะถูกจัดระเบียบข้อมูล (Normalization)[26] ให้มีค่าเฉลี่ย (Mean) เท่ากับศูนย์ และค่าเบี่ยงเบนมาตรฐาน (Variance) เท่ากับหนึ่ง และสเกลลิง (Scaling) เพื่อให้ข้อมูลอยู่ในช่วงของฟังก์ชันกระตุ้น ก่อนที่นำมาฝึกสอนและทดสอบกับโครงข่ายประสาทเทียม จากนั้น ทำการคำนวณจำนวนนิวรอนเริ่มต้นและนิวรอนสุดท้ายในชั้นซ่อนที่ 1 ดังแสดงในสมการที่ 4.35 โครงสร้างก่อนฝึกสอนจะประกอบไปด้วยจำนวนนิวรอนในแต่ละชั้นดังนี้ ในชั้นอินพุทมี 4 นิวรอน ในชั้นซ่อนที่ 1 และ 2 มี 8 และ 7 นิวรอน (คำนวณตามสมการที่ 4.35) ตามลำดับ และในชั้นเอาต์พุทมี 8 นิวรอน ( $k=8$  ดังแสดงในรูปที่ 6.17) ในส่วนของฟังก์ชันกระตุ้นที่อยู่ในชั้นซ่อนที่ 1 และ 2 จะใช้ชนิดแทนเจนต์ซิกมอยด์ (tan-sigmoid) ส่วนชั้นเอาต์พุทจะใช้ฟังก์ชันกระตุ้นชนิดเชิงเส้น (linear)

ระหว่างการฝึกสอนโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ จะเริ่มต้นด้วยการสุ่มค่าถ่วงน้ำหนักและค่าไบแอสเพียงครั้งเดียว (Random initial weight and biases) ให้กับโครงสร้างเริ่มต้นของโครงข่ายประสาทเทียมดังที่ได้กล่าวมาแล้วในข้างต้น หนึ่งรอบการฝึกสอนจะแบ่งออกเป็น 3 ขั้นตอน (เช่นเดียวกับการระบุตำแหน่งขดลวดที่เกิดฟอลต์) โดยจะมีการปรับค่าถ่วงน้ำหนักและค่าไบแอสด้วย Levenberg - Maquardt algorithm (trainlm)[30] เป็นจำนวน 20,000 ครั้ง (Iteration) เพื่อคำนวณหาค่าเปอร์เซ็นต์ผิดพลาดเฉลี่ยสัมบูรณ์ (MAPE) ของชุดข้อมูลตรวจสอบที่ดีที่สุด ดังสมการที่ 6.2 จากนั้นทำการเพิ่มจำนวนนิวรอนในชั้นซ่อนที่ 1 และ 2 เพิ่มขึ้นทีละ 1 จนครบ 4 (เพื่อหาโครงสร้างของโครงข่ายประสาทเทียมที่มีประสิทธิภาพสูงสุด) หรือจนกว่าค่า MAPE ต่ำกว่า 0.5% แล้วหยุดฝึกสอน

ตารางที่ 6.16 แสดงค่าเอาต์พุตของโครงข่ายประสาทเทียมสำหรับระบุประเภทฟอลต์

ประเภทของฟอลต์	A1	B1	C1	G1	A2	B2	C2	G2
ฟอลต์ชนิดลวดเฟส A ถัดวงจรลงดินทางด้านแรงดันสูง (AGHV)	1	0	0	1	0	0	0	0
ฟอลต์ชนิดลวดเฟส B ถัดวงจรลงดินทางด้านแรงดันสูง (BGHV)	0	1	0	1	0	0	0	0
ฟอลต์ชนิดลวดเฟส C ถัดวงจรลงดินทางด้านแรงดันสูง (CGHV)	0	0	1	1	0	0	0	0
ฟอลต์ชนิดลวดเฟส A ถัดวงจรลงดินทางด้านแรงดันต่ำ (AGLV)	0	0	0	0	1	0	0	1
ฟอลต์ชนิดลวดเฟส B ถัดวงจรลงดินทางด้านแรงดันต่ำ (BGLV)	0	0	0	0	0	1	0	1
ฟอลต์ชนิดลวดเฟส C ถัดวงจรลงดินทางด้านแรงดันต่ำ (CGLV)	0	0	0	0	0	0	1	1
ฟอลต์ชนิดลวดเฟส A ถัดวงจรระหว่างรอบ ทางด้านแรงดันสูง (AHV)	1	0	0	0	0	0	0	0
ฟอลต์ชนิดลวดเฟส B ถัดวงจรระหว่างรอบ ทางด้านแรงดันสูง (BHV)	0	1	0	0	0	0	0	0
ฟอลต์ชนิดลวดเฟส C ถัดวงจรระหว่างรอบ ทางด้านแรงดันสูง (CHV)	0	0	1	0	0	0	0	0
ฟอลต์ชนิดลวดเฟส A ถัดวงจรระหว่างรอบ ทางด้านแรงดันต่ำ (ALV)	0	0	0	0	1	0	0	0
ฟอลต์ชนิดลวดเฟส B ถัดวงจรระหว่างรอบ ทางด้านแรงดันต่ำ (BLV)	0	0	0	0	0	1	0	0
ฟอลต์ชนิดลวดเฟส C ถัดวงจรระหว่างรอบ ทางด้านแรงดันต่ำ (CLV)	0	0	0	0	0	0	1	0

หลังจากฝึกสอนโครงข่ายประสาทเทียมเสร็จสิ้น โดยจะใช้เวลาในการฝึกสอนที่ดีที่สุดประมาณ 768 นาที และจำนวนนิวรอนในชั้นซ่อนที่ 1- 2 และชั้นเอาต์พุตเป็น 9, 8 และ 8 นิวรอนตามลำดับ ผลสรุปของการฝึกสอนได้แสดงในตารางที่ 6.17 อนึ่ง เพื่อให้เห็นความชัดเจนมากขึ้น เมื่อนำสมการที่ 4.24 มาช่วยในการลดเวลาฝึกสอน จึงได้ทำการฝึกสอนตามวิธีที่ 2 โดยผลสรุปการฝึกสอนได้แสดงในตารางที่ 6.17 (วิธีที่ 2)


ตารางที่ 6.17 แสดงผลสรุปจากการฝึกสอนเพื่อระบุประเภทฟอลต์

จำนวนนิวรอนในชั้นซ่อนที่ 1-2		2-1	3-2	4-3	5-4	6-5	7-6	8-7	9-8	10-9	11-10
วิธีที่ 1	MAPE ชุดตรวจสอบ(%)	-	-	-	-	-	-	1.42	<b>0.47</b>	-	-
	เวลาที่ใช้ในการฝึกสอน ในแต่ละรอบ (นาที)	-	-	-	-	-	-	594	<b>768</b>	-	-
	เวลาทั้งหมดในการฝึกสอน (นาที)	1362									
วิธีที่ 2	MAPE ชุดตรวจสอบ(%)	16.67	16.84	16.68	12.69	12.12	11.85	4.99	3.39	1.46	<b>1.04</b>
	เวลาที่ใช้ในการฝึกสอน ในแต่ละรอบ (นาที)	61	124	188	269	358	471	594	769	953	<b>1169</b>
	เวลาทั้งหมดในการฝึกสอน (นาที)	4959									


จากนั้นจึงนำค่าถ่วงน้ำหนักและค่าไบแอสที่ทำให้โครงข่ายประสาทเทียมมีประสิทธิภาพสูงที่สุด (ชุดที่มีค่า MAPE ของชุดตรวจสอบดีที่สุด) มาทดสอบกับข้อมูลทดสอบจำนวน 864 ชุด โดยให้เพียงเฉพาะค่าอินพุตเช่นเดียวกับการทดสอบ โดยใช้โครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับสำหรับระบุตำแหน่งขดลวดที่เกิดฟอลต์ (ผลสรุปการทดสอบได้แสดงในบทถัดไป)

### 6.3 แผนภาพสรุปการประยุกต์ใช้งานการแปลงเวฟเล็ตแบบเต็มหน่วยร่วมกับโครงข่ายประสาทเทียม


จากรูปแบบและวิธีการที่ได้นำเสนอนั้นสามารถแสดงสรุปเป็นแผนภาพ (Flow chart) การทำงานได้ดังรูปที่ 6.18 – 6.21




รูปที่ 6.18 แสดงแผนภาพการตรวจจับฟอลต์



รูปที่ 6.19 แสดงแผนภาพการแยกระหว่างพอลต์ภายในกับพอลต์ภายนอก



รูปที่ 6.20 แสดงแผนภาพการวิเคราะห์ฟอลต์ด้วยโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับตามวิธีที่ 1



รูปที่ 6.21 แสดงแผนภาพการวิเคราะห์ฟลอคต์ด้วยโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ  
ตามวิธีที่ 2

จากขั้นตอนการวิเคราะห์สัญญาณฟอลต์ด้วยการพิจารณาผลจากการแปลงเวฟเล็ตแบบเต็มหน่วยร่วมกับโครงข่ายประสาทเทียมที่ได้อธิบายมาแล้วข้างต้น และเพื่อทดสอบถึงสมมติฐานของวิธีการดังกล่าวจึงทำการทดสอบสัญญาณฟอลต์ที่มีลักษณะที่แตกต่างกัน ผลการทดสอบและเปรียบเทียบได้แสดงไว้ในบทถัดไป

## บทที่ 7

### กรณีศึกษาและผลการจำลอง

บทนี้เป็นนำเสนอผลลัพธ์ซึ่งได้จากการวิเคราะห์สัญญาณฟอลต์ที่ได้จากการจำลองด้วยโปรแกรม ATP/EMTP ตามรูปแบบและวิธีการที่นำเสนอในบทที่ 6 ซึ่งตัวอย่างที่ใช้ในการทดสอบนี้จะไม่ถูกนำไปใช้ในการฝึกสอนโครงข่ายประสาทดัดเทียม ทำให้โครงข่ายประสาทดัดเทียมไม่เคยเห็นข้อมูลนี้มาก่อน เพื่อทดสอบการทำงาน โดยผลการทดสอบและรูปแบบในการนำเสนอจะออกมาดังต่อไปนี้

#### 7.1 รูปแบบการนำเสนอ

##### 7.1.1 ประเภทของฟอลต์ ซึ่งแบ่งออกเป็น 2 ประเภทดังนี้

1. ฟอลต์ชนิดลวดลัดวงจรลงดิน แสดงอยู่หัวข้อที่ 7.2.1-7.2.9 และรูปที่ 7.1-7.27
2. ฟอลต์ชนิดลวดลัดวงจรระหว่างรอบ แสดงอยู่ในหัวข้อที่ 7.3.1-7.3.8 และรูปที่ 7.28-7.87

##### 7.1.2 รูปแบบการนำเสนอในแต่ละหัวข้อ

การแสดงผลจะเรียงตามตำแหน่งที่เกิดฟอลต์คือ 10% - 90% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง ซึ่งรายละเอียดของแต่ละตารางจะประกอบไปด้วย


1. สเกลแรกที่สามารถตรวจจับฟอลต์ได้ของการวิเคราะห์ด้วยผลการแปลงเวฟเล็ดแบบเต็มหน่วย
2. ตำแหน่งขดลวดที่เกิดการลัดวงจรที่ได้จากการคำนวณและความคลาดเคลื่อน (Error) ที่เกิดขึ้นจากการวิเคราะห์ด้วยผลการแปลงเวฟเล็ดแบบเต็มหน่วยร่วมกับโครงข่ายประสาทดัดเทียมชนิดแพร่ค่าย้อนกลับ (BP) ทั้งวิธีที่ 1 (Method 1) และวิธีที่ 2 (Method 2)
3. การระบุประเภทของฟอลต์จากการวิเคราะห์ผลการแปลงเวฟเล็ดแบบเต็มหน่วยร่วมกับโครงข่ายประสาทดัดเทียมชนิดแพร่ค่าย้อนกลับ (BP) ทั้งวิธีที่ 1 (Method 1) และวิธีที่ 2 (Method 2)
4. การเรียงลำดับจะเรียงตามประเภท, เฟสของฟอลต์และด้านแรงดันที่เกิดฟอลต์ ดังแสดงในตารางที่ 6.16 กล่าวคือ ฟอลต์ชนิดลวดลัดวงจรลงดินจะเรียงดังนี้ AGHV, BGHV, CGHV, AGLV, BGLV และ CGLV ตามลำดับ ส่วนฟอลต์ชนิดลวดลัดวงจรระหว่างรอบจะเรียงดังนี้ AHV, BHV, CHV, ALV, BLV และ CLV ตามลำดับ

### 7.1.3 รูปแสดงการสรุปผลลัพธ์ที่ได้ในแต่ละหัวข้อ


เป็นการแสดงค่าเฉลี่ยของผลลัพธ์ที่ได้ในแต่ละตำแหน่งที่เกิดฟอลต์ตามประเภทของฟอลต์ และมีการวิเคราะห์ผลลัพธ์ที่ได้ทั้งหมด

## 7.2 ผลลัพธ์กรณีฟอลต์ขดลวดลัดวงจรลงดิน


### 7.2.1 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขดลวดที่เกิดการลัดวงจรลงดินที่ตำแหน่ง 10 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



**รูปที่ 7.1** แสดงค่าเฉลี่ยของความถูกต้องในการตรวจจับฟอลต์กรณีขดลวดลัดวงจรลงดินที่ตำแหน่ง 10 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



**รูปที่ 7.2** แสดงค่าเฉลี่ยของตำแหน่งฟอลต์กรณีขดลวดลัดวงจรลงดินที่ตำแหน่ง 10 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



**รูปที่ 7.3** แสดงค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยในการระบุประเภทฟอลต์กรณีขดลวดลัดวงจรลงดินที่ตำแหน่ง 10 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง

จากผลลัพธ์ในรูปที่ 7.1-7.3 สามารถวิเคราะห์ผลได้ดังนี้

### การตรวจจับฟอลต์

สามารถตรวจจับฟอลต์โดยใช้เพียงข้อมูล จากสัมประสิทธิ์การแปลงเวฟเล็ตของกระแสผลต่าง ในสเกลที่ 1 ได้ถูกต้อง 100% ดังแสดงในรูปที่ 7.1

**การหาตำแหน่งฟอลต์** (ตำแหน่ง 10 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)

1. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 สามารถหาตำแหน่งฟอลต์ทั้งหมด จากรูปที่ 7.2 ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.1109% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0109% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.1045% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0045% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.1178% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0178% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)
2. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 สามารถหาตำแหน่งฟอลต์ทั้งหมด จากรูปที่ 7.2 ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.1123% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0123% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.1013% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0013% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.1198% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0198% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)


เมื่อเปรียบเทียบเฉลี่ยจากรูปที่ 7.2 พบว่า ผลการหาตำแหน่งฟอลต์ด้วยการแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าที่ใกล้เคียงกับตำแหน่งจริงมากกว่าผลการหาตำแหน่งฟอลต์ด้วยวิธีที่ 2

### การระบุประเภทของฟอลต์


1. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 สามารถระบุประเภทของฟอลต์ ซึ่งจากรูปที่ 7.3 จะเห็นได้ว่า สามารถระบุประเภทของฟอลต์ทั้งหมดมีความถูกต้องเฉลี่ย 83.33% โดยสามารถระบุประเภทของฟอลต์ในแต่ละชนิดได้ดังนี้ ระบุประเภทของฟอลต์ชนิด AGLV, BGLV และ CGLV มีความถูกต้องเฉลี่ยสูงถึง 100% ในขณะที่ระบุประเภทของฟอลต์ชนิด AGHV และ CGHV สามารถระบุประเภทได้ถูกต้องเฉลี่ย 75% ส่วนฟอลต์ชนิด BGHV สามารถระบุประเภทได้ถูกต้องเฉลี่ย 50%
2. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 สามารถระบุประเภทของฟอลต์ ซึ่งจากรูปที่ 7.3 จะเห็นได้ว่า สามารถระบุประเภทของฟอลต์ทั้งหมดมีความถูกต้องเฉลี่ย 70.83% โดยสามารถระบุประเภทของฟอลต์ในแต่ละชนิดได้ดังนี้ ระบุประเภทของฟอลต์ชนิด AGLV, BGLV และ CGLV มีความถูกต้องเฉลี่ยสูงถึง 100% ในขณะที่ระบุประเภทของฟอลต์ชนิด CGHV สามารถระบุประเภทได้ถูกต้องเฉลี่ย 75% ส่วนฟอลต์ชนิด AGHV และ BGHV สามารถระบุประเภทได้ถูกต้องเฉลี่ย 25%

เมื่อเปรียบเทียบเฉลี่ยจากรูปที่ 7.3 พบว่า ผลการระบุประเภทของฟอลต์ด้วยการแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยดีกว่าผลการระบุประเภทฟอลต์ด้วยวิธีที่ 2


7.2.2 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขดลวดที่เกิดการลัดวงจรลงดินที่ตำแหน่ง 20 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



รูปที่ 7.4 แสดงค่าเฉลี่ยของความถูกต้องในการตรวจจับฟอลต์กรณีขดลวดลัดวงจรลงดินที่ตำแหน่ง 20 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



รูปที่ 7.5 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์กรณีขดลวดลัดวงจรลงดินที่ตำแหน่ง 20 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



รูปที่ 7.6 แสดงค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยในการระบุประเภทฟอลต์กรณีขดลวดลัดวงจรลงดินที่ตำแหน่ง 20 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง

จากผลลัพธ์ในรูปที่ 7.4-7.6 สามารถวิเคราะห์ผลได้ดังนี้

#### การตรวจจับฟอลต์

สามารถตรวจจับฟอลต์โดยใช้เพียงข้อมูล จากสัมประสิทธิ์การแปลงเวฟเล็ตของกระแสผลต่างในสเกลที่ 1 ได้ถูกต้อง 100% ดังแสดงในรูปที่ 7.4

**การหาตำแหน่งฟอลต์** (ตำแหน่ง 20% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)

1. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 สามารถหาตำแหน่งฟอลต์ทั้งหมด จากรูปที่ 7.5 ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.2099% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0099% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.2027% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0027% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.2175% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0175% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)

2. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทดัดเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 สามารถหาดำแหน่งพอลต์ทั้งหมด จากรูปที่ 7.5 ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.2023% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0023% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.1906% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0094% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.2063% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0063% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)


เมื่อเปรียบค่าเฉลี่ยจากรูปที่ 7.5 พบว่า ผลการหาดำแหน่งพอลต์ด้วยการแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทดัดเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 2 จะให้ค่าที่ใกล้เคียงกับตำแหน่งจริงมากกว่าผลการหาดำแหน่งพอลต์ด้วยวิธีที่ 1

#### การระบุประเภทของพอลต์


1. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทดัดเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 ซึ่งจากรูปที่ 7.6 จะเห็นได้ว่า สามารถระบุประเภทของพอลต์ทั้งหมดมีความถูกต้องเฉลี่ย 95.83% โดยสามารถระบุประเภทของพอลต์ในแต่ละชนิดได้ดังนี้ ระบุประเภทของพอลต์ชนิด AGHV, CGHV, AGLV, BGLV และ CGLV มีความถูกต้องเฉลี่ยสูงถึง 100% ในขณะที่ระบุประเภทของพอลต์ชนิด BGHV สามารถระบุประเภทได้ถูกต้องเฉลี่ย 75%
2. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทดัดเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 ซึ่งจากรูปที่ 7.6 จะเห็นได้ว่า สามารถระบุประเภทของพอลต์ทั้งหมดมีความถูกต้องเฉลี่ย 95.83% โดยสามารถระบุประเภทของพอลต์ในแต่ละชนิดได้ดังนี้ ระบุประเภทของพอลต์ชนิด BGHV, CGHV, AGLV, BGLV และ CGLV มีความถูกต้องเฉลี่ยสูงถึง 100% ในขณะที่ระบุประเภทของพอลต์ชนิด AGHV สามารถระบุประเภทได้ถูกต้องเฉลี่ย 75%

เมื่อเปรียบค่าเฉลี่ยจากรูปที่ 7.6 พบว่า ผลการระบุประเภทของพอลต์ด้วยการแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทดัดเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยเท่ากับผลการระบุประเภทพอลต์ด้วยวิธีที่ 2


### 7.2.3 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขดลวดที่เกิดการลัดวงจรลงดินที่ตำแหน่ง 30 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



### รูปที่ 7.7 แสดงค่าเฉลี่ยของความถูกต้องในการตรวจจับฟอลต์กรณีขดลวดลัดวงจรลงดินที่ตำแหน่ง 30 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



### รูปที่ 7.8 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์กรณีขดลวดลัดวงจรลงดินที่ตำแหน่ง 30 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



**รูปที่ 7.9** แสดงค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยในการระบุประเภทฟอลต์กรณีขดลวดลัดวงจรลงดินที่ตำแหน่ง 30 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง

จากผลลัพธ์ในรูปที่ 7.7-7.9 สามารถวิเคราะห์ผลได้ดังนี้

### การตรวจจับฟอลต์

สามารถตรวจจับฟอลต์โดยใช้เพียงข้อมูล จากสัมประสิทธิ์การแปลงเวฟเล็ดของกระแสผลต่างในสเกลที่ 1 ได้ถูกต้อง 100% ดังแสดงในรูปที่ 7.7

**การหาดำแหน่งฟอลต์** (ตำแหน่ง 30% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)

1. การแปลงเวฟเล็ดร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 สามารถหาดำแหน่งฟอลต์ทั้งหมด จากรูปที่ 7.8 ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.3014% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0014% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.2955% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0045% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.3066% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0066% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)

2. การแปลงเวฟเล็ดร่วมนกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 สามารถหาดำแหน่งฟอลต์ทั้งหมด จากรูปที่ 7.8 ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.2974% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0026% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.2877% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0123% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.3067% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0067% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)


เมื่อเปรียบเทียบเฉลี่ยจากรูปที่ 7.8 พบว่า ผลการหาดำแหน่งฟอลต์ด้วยการแปลงเวฟเล็ดร่วมนกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าที่ใกล้เคียงกับตำแหน่งจริงมากกว่าผลการหาดำแหน่งฟอลต์ด้วยวิธีที่ 2

#### การระบุประเภทของฟอลต์


1. การแปลงเวฟเล็ดร่วมนกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 ซึ่งจากรูปที่ 7.9 จะเห็นได้ว่า สามารถระบุประเภทของฟอลต์ทุกประเภทได้ถูกต้อง 100%
2. การแปลงเวฟเล็ดร่วมนกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 ซึ่งจากรูปที่ 7.9 จะเห็นได้ว่า สามารถระบุประเภทของฟอลต์ทุกประเภทได้ถูกต้อง 100%

เมื่อเปรียบเทียบเฉลี่ยจากรูปที่ 7.9 พบว่า ผลการระบุประเภทของฟอลต์ด้วยการแปลงเวฟเล็ดร่วมนกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยเท่ากับผลการระบุประเภทฟอลต์ด้วยวิธีที่ 2


### 7.2.4 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขดลวดที่เกิดการลัดวงจรลงดินที่ตำแหน่ง 40 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



### รูปที่ 7.10 แสดงค่าเฉลี่ยของความถูกต้องในการตรวจจับฟอลต์กรณีขดลวดลัดวงจรลงดินที่ตำแหน่ง 40 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



### รูปที่ 7.11 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์กรณีขดลวดลัดวงจรลงดินที่ตำแหน่ง 40 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



**รูปที่ 7.12** แสดงค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยในการระบุประเภทฟอลต์กรณีขดลวดลัดวงจรลงดินที่ตำแหน่ง 40 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง

จากผลลัพธ์ในรูปที่ 7.10-7.12 สามารถวิเคราะห์ผลได้ดังนี้

### การตรวจจับฟอลต์

สามารถตรวจจับฟอลต์โดยใช้เพียงข้อมูล จากสัมประสิทธิ์การแปลงเวฟเล็ดของกระแสผลต่างในสเกลที่ 1 ได้ถูกต้อง 100% ดังแสดงในรูปที่ 7.10

**การหาดำแหน่งฟอลต์** (ตำแหน่ง 40% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)

1. การแปลงเวฟเล็ดร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 สามารถหาดำแหน่งฟอลต์ทั้งหมด จากรูปที่ 7.11 ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.4118% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0118% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.4097% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0097% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.4141% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0141% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)

2. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 สามารถหาดำแหน่งพอลต์ทั้งหมด จากรูปที่ 7.11 ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.4060% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0060% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.4033% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0033% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.4083% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0083% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)


เมื่อเปรียบเทียบค่าเฉลี่ยจากรูปที่ 7.11 พบว่า ผลการหาดำแหน่งพอลต์ด้วยการแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 2 จะให้ค่าที่ใกล้เคียงกับตำแหน่งจริงมากกว่าผลการหาดำแหน่งพอลต์ด้วยวิธีที่ 1

#### การระบุประเภทของพอลต์


1. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 ซึ่งจากรูปที่ 7.12 จะเห็นได้ว่า สามารถระบุประเภทของพอลต์ทุกประเภทได้ถูกต้อง 100%
2. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 ซึ่งจากรูปที่ 7.12 จะเห็นได้ว่า สามารถระบุประเภทของพอลต์ทุกประเภทได้ถูกต้อง 100%

เมื่อเปรียบเทียบค่าเฉลี่ยจากรูปที่ 7.12 พบว่า ผลการระบุประเภทของพอลต์ด้วยการแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยเท่ากับผลการระบุประเภทพอลต์ด้วยวิธีที่ 2


7.2.5 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขดลวดที่เกิดการลัดวงจรลงดินที่ตำแหน่ง 50 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



รูปที่ 7.13 แสดงค่าเฉลี่ยของความถูกต้องในการตรวจจับฟอลต์กรณีขดลวดลัดวงจรลงดินที่ตำแหน่ง 50 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



รูปที่ 7.14 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์กรณีขดลวดลัดวงจรลงดินที่ตำแหน่ง 50 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



**รูปที่ 7.15** แสดงค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยในการระบุประเภทฟอลต์กรณีขดลวดลัดวงจรลงดินที่ตำแหน่ง 50 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง

จากผลลัพธ์ในรูปที่ 7.13-7.15 สามารถวิเคราะห์ผลได้ดังนี้

#### การตรวจจับฟอลต์

สามารถตรวจจับฟอลต์โดยใช้เพียงข้อมูล จากสัมประสิทธิ์การแปลงเวฟเล็ดของกระแสผลต่างในสเกลที่ 1 ได้ถูกต้อง 100% ดังแสดงในรูปที่ 7.13

**การหาตำแหน่งฟอลต์** (ตำแหน่ง 50% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)

1. การแปลงเวฟเล็ดร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 สามารถหาตำแหน่งฟอลต์ทั้งหมด จากรูปที่ 7.14 ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.5070% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0070% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.5018% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0018% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.5126% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0126% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)

2. การแปลงเวฟเล็ดร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 สามารถหาดำแหน่งฟอลต์ทั้งหมด จากรูปที่ 7.14 ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.5093% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0093% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.5018% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0018% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.5160% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0160% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)


เมื่อเปรียบเทียบเฉลี่ยจากรูปที่ 7.14 พบว่า ผลการหาดำแหน่งฟอลต์ด้วยการแปลงเวฟเล็ดร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าที่ใกล้เคียงกับตำแหน่งจริงมากกว่าผลการหาดำแหน่งฟอลต์ด้วยวิธีที่ 2

#### การระบุประเภทของฟอลต์


1. การแปลงเวฟเล็ดร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 ซึ่งจากรูปที่ 7.15 จะเห็นได้ว่า สามารถระบุประเภทของฟอลต์ทุกประเภทได้ถูกต้อง 100%
2. การแปลงเวฟเล็ดร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 ซึ่งจากรูปที่ 7.15 จะเห็นได้ว่า สามารถระบุประเภทของฟอลต์ทุกประเภทได้ถูกต้อง 100%

เมื่อเปรียบเทียบเฉลี่ยจากรูปที่ 7.15 พบว่า ผลการระบุประเภทของฟอลต์ด้วยการแปลงเวฟเล็ดร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยเท่ากับผลการระบุประเภทฟอลต์ด้วยวิธีที่ 2


### 7.2.6 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขดลวดที่เกิดการลัดวงจรลงดินที่ตำแหน่ง 60 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



รูปที่ 7.16 แสดงค่าเฉลี่ยของความถูกต้องในการตรวจจับฟอลต์กรณีขดลวดลัดวงจรลงดินที่ตำแหน่ง 60 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



รูปที่ 7.17 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์กรณีขดลวดลัดวงจรลงดินที่ตำแหน่ง 60 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



**รูปที่ 7.18** แสดงค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยในการระบุประเภทฟอลต์กรณีขดลวดลัดวงจรลงดินที่ตำแหน่ง 60 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง

จากผลลัพธ์ในรูปที่ 7.16-7.18 สามารถวิเคราะห์ผลได้ดังนี้

#### การตรวจจับฟอลต์

สามารถตรวจจับฟอลต์โดยใช้เพียงข้อมูล จากสัมประสิทธิ์การแปลงเวฟเล็ทของกระแสผลต่างในสเกลที่ 1 ได้ถูกต้อง 100% ดังแสดงในรูปที่ 7.16

**การหาดำแหน่งฟอลต์** (ตำแหน่ง 60% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)

1. การแปลงเวฟเล็ทร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 สามารถหาดำแหน่งฟอลต์ทั้งหมด จากรูปที่ 7.17 ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.5967% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0033% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.5881% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0119% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.6048% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0048% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)

2. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 สามารถหาดำแหน่งพอลต์ทั้งหมด จากรูปที่ 7.17 ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.5991% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0009% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.5934% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0066% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.6123% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0123% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)


เมื่อเปรียบเทียบเฉลี่ยจากรูปที่ 7.17 พบว่า ผลการหาดำแหน่งพอลต์ด้วยการแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 2 จะให้ค่าที่ใกล้เคียงกับตำแหน่งจริงมากกว่าผลการหาดำแหน่งพอลต์ด้วยวิธีที่ 1

#### การระบุประเภทของพอลต์


1. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 ซึ่งจากรูปที่ 7.18 จะเห็นได้ว่า สามารถระบุประเภทของพอลต์ทุกประเภทได้ถูกต้อง 100%
2. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 ซึ่งจากรูปที่ 7.18 จะเห็นได้ว่า สามารถระบุประเภทของพอลต์ทุกประเภทได้ถูกต้อง 100%

เมื่อเปรียบเทียบเฉลี่ยจากรูปที่ 7.18 พบว่า ผลการระบุประเภทของพอลต์ด้วยการแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยเท่ากับผลการระบุประเภทพอลต์ด้วยวิธีที่ 2

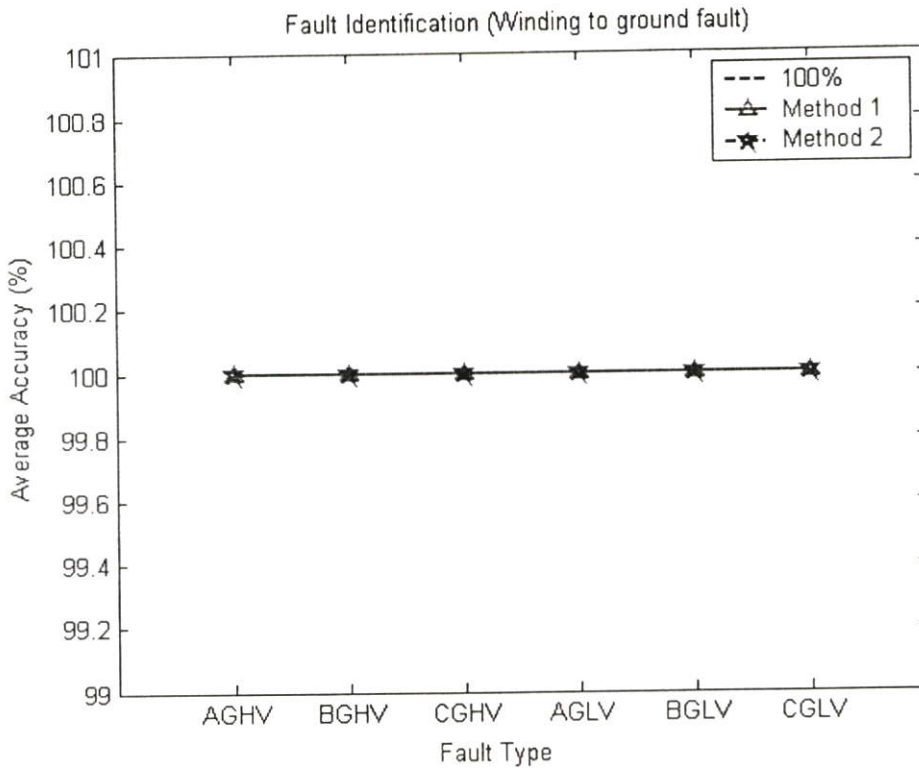
7.2.7 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขดลวดที่เกิดการลัดวงจรลงดินที่ตำแหน่ง 70 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



รูปที่ 7.19 แสดงค่าเฉลี่ยของความถูกต้องในการตรวจจับฟอลต์กรณีขดลวดลัดวงจรลงดินที่ตำแหน่ง 70 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



รูปที่ 7.20 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์กรณีขดลวดลัดวงจรลงดินที่ตำแหน่ง 70 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



รูปที่ 7.21 แสดงค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยในการระบุประเภทฟอลต์กรณีขดลวดลัดวงจรลงดินที่ตำแหน่ง 70 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง

จากผลลัพธ์ในรูปที่ 7.19-7.21 สามารถวิเคราะห์ผลได้ดังนี้

#### การตรวจจับฟอลต์

สามารถตรวจจับฟอลต์โดยใช้เพียงข้อมูล จากสัมประสิทธิ์การแปลงเวฟเล็ดของกระแสผลต่างในสเกลที่ 1 ได้ถูกต้อง 100% ดังแสดงในรูปที่ 7.19

**การหาดำแหน่งฟอลต์** (ตำแหน่ง 70% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)

1. การแปลงเวฟเล็ดร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 สามารถหาดำแหน่งฟอลต์ทั้งหมด จากรูปที่ 7.20 ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.7088% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0088% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.7058% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0058% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.7132% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0132% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)

2. การแปลงเวฟเล็ดร่วมนกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 สามารถหาดำแหน่งพอลต์ทั้งหมด จากรูปที่ 7.20 ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.7091% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0091% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.7013% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0013% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.7124% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0124% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)


เมื่อเปรียบเทียบค่าเฉลี่ยจากรูปที่ 7.20 พบว่า ผลการหาดำแหน่งพอลต์ด้วยการแปลงเวฟเล็ดร่วมนกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าที่ใกล้เคียงกับตำแหน่งจริงมากกว่าผลการหาดำแหน่งพอลต์ด้วยวิธีที่ 2

#### การระบุประเภทของพอลต์


1. การแปลงเวฟเล็ดร่วมนกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 ซึ่งจากรูปที่ 7.21 จะเห็นได้ว่า สามารถระบุประเภทของพอลต์ทุกประเภทได้ถูกต้อง 100%
2. การแปลงเวฟเล็ดร่วมนกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 ซึ่งจากรูปที่ 7.21 จะเห็นได้ว่า สามารถระบุประเภทของพอลต์ทุกประเภทได้ถูกต้อง 100%

เมื่อเปรียบเทียบค่าเฉลี่ยจากรูปที่ 7.21 พบว่า ผลการระบุประเภทของพอลต์ด้วยการแปลงเวฟเล็ดร่วมนกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยเท่ากับผลการระบุประเภทพอลต์ด้วยวิธีที่ 2


### 7.2.8 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขดลวดที่เกิดการลัดวงจรลงดินที่ตำแหน่ง 80 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



รูปที่ 7.22 แสดงค่าเฉลี่ยของความถูกต้องในการตรวจจับฟอลต์กรณีขดลวดลัดวงจรลงดินที่ตำแหน่ง 80 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



รูปที่ 7.23 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์กรณีขดลวดลัดวงจรลงดินที่ตำแหน่ง 80 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



**รูปที่ 7.24** แสดงค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยในการระบุประเภทฟอลต์กรณีขดลวดลัดวงจรลงดินที่ตำแหน่ง 80 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง

จากผลลัพธ์ในรูปที่ 7.22-7.24 สามารถวิเคราะห์ผลได้ดังนี้

#### การตรวจจับฟอลต์

สามารถตรวจจับฟอลต์โดยใช้เพียงข้อมูล จากสัมประสิทธิ์การแปลงเวฟเล็ดของกระแสผลต่างในสเกลที่ 1 ได้ถูกต้อง 100% ดังแสดงในรูปที่ 7.22

**การหาตำแหน่งฟอลต์** (ตำแหน่ง 80% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)

1. การแปลงเวฟเล็ดร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 สามารถหาตำแหน่งฟอลต์ทั้งหมด จากรูปที่ 7.23 ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.8024% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0024% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.7946% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0054% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.8110% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0110% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)

2. การแปลงเวฟเล็ดร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 สามารถหาดำแหน่งพอลต์ทั้งหมด จากรูปที่ 7.23 ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.8012% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0012% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.7938% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0062% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.8080% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0080% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)


เมื่อเปรียบค่าเฉลี่ยจากรูปที่ 7.23 พบว่า ผลการหาดำแหน่งพอลต์ด้วยการแปลงเวฟเล็ดร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 2 จะให้ค่าที่ใกล้เคียงกับตำแหน่งจริงมากกว่าผลการหาดำแหน่งพอลต์ด้วยวิธีที่ 1

#### การระบุประเภทของพอลต์


1. การแปลงเวฟเล็ดร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 ซึ่งจากรูปที่ 7.24 จะเห็นได้ว่า สามารถระบุประเภทของพอลต์ทุกประเภทได้ถูกต้อง 100%
2. การแปลงเวฟเล็ดร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 ซึ่งจากรูปที่ 7.24 จะเห็นได้ว่า สามารถระบุประเภทของพอลต์ทุกประเภทได้ถูกต้อง 100%

เมื่อเปรียบค่าเฉลี่ยจากรูปที่ 7.24 พบว่า ผลการระบุประเภทของพอลต์ด้วยการแปลงเวฟเล็ดร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยเท่ากับผลการระบุประเภทพอลต์ด้วยวิธีที่ 2


### 7.2.9 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขดลวดที่เกิดการลัดวงจรลงดินที่ตำแหน่ง 90 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



### รูปที่ 7.25 แสดงค่าเฉลี่ยของความถูกต้องในการตรวจจับฟอลต์กรณีขดลวดลัดวงจรลงดินที่ตำแหน่ง 90 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



### รูปที่ 7.26 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์กรณีขดลวดลัดวงจรลงดินที่ตำแหน่ง 90 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



**รูปที่ 7.27** แสดงค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยในการระบุประเภทฟอลต์กรณีขดลวดลัดวงจรลงดินที่ตำแหน่ง 90 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง

จากผลลัพธ์ในรูปที่ 7.25-7.27 สามารถวิเคราะห์ผลได้ดังนี้

### การตรวจจับฟอลต์

สามารถตรวจจับฟอลต์โดยใช้เพียงข้อมูล จากสัมประสิทธิ์การแปลงเวฟเล็ตของกระแสผลต่างในสเกลที่ 1 ได้ถูกต้อง 100% ดังแสดงในรูปที่ 7.25

**การหาตำแหน่งฟอลต์** (ตำแหน่ง 90% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)

1. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 สามารถหาตำแหน่งฟอลต์ทั้งหมด จากรูปที่ 7.26 ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.9024% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0024% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.8999% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0001% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.9063% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0063% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)

2. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 สามารถหาค่าแห่งพอลต์ทั้งหมด จากรูปที่ 7.26 ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.9086% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0086% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.9021% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0021% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.9120% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0120% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)

เมื่อเปรียบเทียบเฉลี่ยจากรูปที่ 7.26 พบว่า ผลการหาค่าแห่งพอลต์ด้วยการแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าที่ใกล้เคียงกับตำแหน่งจริงมากกว่าผลการหาค่าแห่งพอลต์ด้วยวิธีที่ 2


#### การระบุประเภทของพอลต์

1. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 ซึ่งจากรูปที่ 7.27 จะเห็นได้ว่า สามารถระบุประเภทของพอลต์ทุกประเภทได้ถูกต้อง 100%
2. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 ซึ่งจากรูปที่ 7.27 จะเห็นได้ว่า สามารถระบุประเภทของพอลต์ทุกประเภทได้ถูกต้อง 100%


เมื่อเปรียบเทียบเฉลี่ยจากรูปที่ 7.27 พบว่า ผลการระบุประเภทของพอลต์ด้วยการแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยเท่ากับผลการระบุประเภทพอลต์ด้วยวิธีที่ 2

### 7.3 ผลลัพธ์กรณีฟอลต์ชนิดลวดลัดวงจรระหว่างรอบ


#### 7.3.1 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีชนิดลวดที่เกิดการลัดวงจรระหว่างรอบ ที่ตำแหน่งลวดด้วย $\alpha$ 10 % ของความยาวลวดภายในหม้อแปลงไฟฟ้ากำลัง




รูปที่ 7.28 แสดงค่าเฉลี่ยของความถูกต้องในการตรวจจับฟอลต์กรณีชนิดลวดลัดวงจรระหว่างรอบที่ตำแหน่งลวดด้วย  $\alpha$  10 % ของความยาวลวดภายในหม้อแปลงไฟฟ้ากำลัง




**รูปที่ 7.29** แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย a กรณีขดลวดลัดวงจรระหว่างรอบที่ตำแหน่งขดลวดย่อย a 10% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




**รูปที่ 7.30** แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 10% กับ 20% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




**รูปที่ 7.31** แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ชนิดลวดย่อย b กรณีขดลวดคล้ดวจระหว่างรอบที่ 10% กับ 30% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




**รูปที่ 7.32** แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ชนิดลวดย่อย b กรณีขดลวดคล้ดวจระหว่างรอบที่ 10% กับ 40% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




**รูปที่ 7.33** แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ชนิดลวดย่อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 10% กับ 50% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




**รูปที่ 7.34** แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ชนิดลวดย่อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 10% กับ 60% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




**รูปที่ 7.35** แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 10% กับ 70% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



**รูปที่ 7.36** แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 10% กับ 80% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



รูปที่ 7.37 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 10% กับ 90% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



รูปที่ 7.38 แสดงค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยในการระบุประเภทฟอลต์กรณีขดลวดลัดวงจรระหว่างรอบที่ตำแหน่งขดลวดย่อย a 10% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง

จากผลลัพธ์ในรูปที่ 7.28-7.38 สามารถวิเคราะห์ผลได้ดังนี้

### การตรวจจับฟอลต์

สามารถตรวจจับฟอลต์โดยใช้เพียงข้อมูล จากสัมประสิทธิ์การแปลงเวฟเล็ตของกระแสผลต่าง ในสเกลที่ 1 ได้ถูกต้อง 100% ดังแสดงในรูปที่ 7.28

**การหาตำแหน่งฟอลต์** (ขดลวดย่อย a 10% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)

1. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 สามารถหาตำแหน่งฟอลต์ทั้งหมด และจากรูปที่ 7.29 จะเห็นได้ว่า ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.0944% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0056% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.0886% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0114% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.1019% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0019% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และค่าความคลาดเคลื่อนเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย a ที่คำนวณได้คือ 0.0237% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง จากรูปที่ 7.30-7.37 จะเห็นได้ว่า ค่าความคลาดเคลื่อนเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย b ที่คำนวณได้คือ 0.02% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง
2. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 สามารถหาตำแหน่งฟอลต์ทั้งหมด จากรูปที่ 7.29 ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.0974% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0026% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.0935% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0065% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.1050% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0050% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และค่าความคลาดเคลื่อนเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย a ที่คำนวณได้คือ 0.0252% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง จากรูปที่ 7.30-7.37 จะเห็นได้ว่า ค่าความคลาดเคลื่อนเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย b ที่คำนวณได้คือ 0.0232% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง


เมื่อเปรียบเทียบค่าเฉลี่ยจากรูปที่ 7.29-7.37 พบว่า ผลการหาตำแหน่งฟอลต์ด้วยการแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าที่ใกล้เคียงกับตำแหน่งจริงมากกว่าผลการหาตำแหน่งฟอลต์ด้วยวิธีที่ 2

#### การระบุประเภทของฟอลต์


1. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 สามารถระบุประเภทของฟอลต์ ซึ่งจากรูปที่ 7.38 จะเห็นได้ว่า สามารถระบุประเภทของฟอลต์ทั้งหมดมีความถูกต้องเฉลี่ย 99.30% โดยสามารถระบุประเภทของฟอลต์ในแต่ละชนิดได้ดังนี้ ระบุประเภทของฟอลต์ชนิด AHV, BHV, ALV, BLV และ CLV มีความถูกต้องเฉลี่ยสูงถึง 100% ในขณะที่ระบุประเภทของฟอลต์ชนิด CHV สามารถระบุประเภทได้ถูกต้องเฉลี่ย 96%
2. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 สามารถระบุประเภทของฟอลต์ ซึ่งจากรูปที่ 7.38 จะเห็นได้ว่า สามารถระบุประเภทของฟอลต์ทั้งหมดมีความถูกต้องเฉลี่ย 98.61% โดยสามารถระบุประเภทของฟอลต์ในแต่ละชนิดได้ดังนี้ ระบุประเภทของฟอลต์ชนิด AHV, ALV, BLV และ CLV มีความถูกต้องเฉลี่ยสูงถึง 100% ในขณะที่ระบุประเภทของฟอลต์ชนิด BHV และ CHV สามารถระบุประเภทได้ถูกต้องเฉลี่ย 96%

เมื่อเปรียบเทียบค่าเฉลี่ยจากรูปที่ 7.38 พบว่า ผลการระบุประเภทของฟอลต์ด้วยการแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยดีกว่าผลการระบุประเภทฟอลต์ด้วยวิธีที่ 2


7.3.2 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขดลวดที่เกิดการลัดวงจรระหว่างรอบที่ตำแหน่งขดลวดย่อย a 20 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




รูปที่ 7.39 แสดงค่าเฉลี่ยของความถูกต้องในการตรวจจับฟอลต์กรณีขดลวดลัดวงจรระหว่างรอบที่ตำแหน่งขดลวดย่อย a 20 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




รูปที่ 7.40 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย a กรณีขดลวดลัดวงจรระหว่างรอบที่ตำแหน่งขดลวดย่อย a 20% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




**รูปที่ 7.41** แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ชนิดลวดข้อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 20% กับ 30% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




**รูปที่ 7.42** แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ชนิดลวดข้อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 20% กับ 40% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




รูปที่ 7.43 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ชนิดลวดย่อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 20% กับ 50% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




รูปที่ 7.44 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ชนิดลวดย่อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 20% กับ 60% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




รูปที่ 7.45 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 20% กับ 70% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



รูปที่ 7.46 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 20% กับ 80% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



รูปที่ 7.47 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 20% กับ 90% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



รูปที่ 7.48 แสดงค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยในการระบุประเภทฟอลต์กรณีขดลวดลัดวงจรระหว่างรอบที่ตำแหน่งขดลวดย่อย a 20% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง

จากผลลัพธ์ในรูปแบบที่ 7.39-7.48 สามารถวิเคราะห์ผลได้ดังนี้

### การตรวจจับฟอลต์

สามารถตรวจจับฟอลต์โดยใช้เพียงข้อมูล จากสัมประสิทธิ์การแปลงเวฟเล็ตของกระแสผลต่าง ในสเกลที่ 1 ได้ถูกต้อง 100% ดังแสดงในรูปแบบที่ 7.39

**การหาตำแหน่งฟอลต์** (ขดลวดย่อย a 20% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)

1. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 สามารถหาตำแหน่งฟอลต์ทั้งหมด และจากรูปที่ 7.40 จะเห็นได้ว่า ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.196% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.004% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.1896% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0104% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.2000% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และค่าความคลาดเคลื่อนเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย a ที่คำนวณได้คือ 0.0232% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง จากรูปที่ 7.41-7.47 จะเห็นได้ว่า ค่าความคลาดเคลื่อนเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย b ที่คำนวณได้คือ 0.0204% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง
2. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 สามารถหาตำแหน่งฟอลต์ทั้งหมด จากรูปที่ 7.40 ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.2008% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0008% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.1912% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0088% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.2096% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0096% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และค่าความคลาดเคลื่อนเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย a ที่คำนวณได้คือ 0.0245% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง จากรูปที่ 7.41-7.47 จะเห็นได้ว่า ค่าความคลาดเคลื่อนเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย b ที่คำนวณได้คือ 0.0235% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง


เมื่อเปรียบเทียบค่าเฉลี่ยจากรูปที่ 7.40-7.47 พบว่า ผลการหาตำแหน่งฟอลต์ด้วยการแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าที่ใกล้เคียงกับตำแหน่งจริงมากกว่าผลการหาตำแหน่งฟอลต์ด้วยวิธีที่ 2

#### การระบุประเภทของฟอลต์


1. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 สามารถระบุประเภทของฟอลต์ ซึ่งจากรูปที่ 7.48 จะเห็นได้ว่า สามารถระบุประเภทของฟอลต์ทั้งหมดมีความถูกต้องเฉลี่ย 99.30% โดยสามารถระบุประเภทของฟอลต์ในแต่ละชนิดได้ดังนี้ ระบุประเภทของฟอลต์ชนิด AHV, BHV, ALV, BLV และ CLV มีความถูกต้องเฉลี่ยสูงถึง 100% ในขณะที่ระบุประเภทของฟอลต์ชนิด CHV สามารถระบุประเภทได้ถูกต้องเฉลี่ย 96%
2. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 สามารถระบุประเภทของฟอลต์ ซึ่งจากรูปที่ 7.48 จะเห็นได้ว่า สามารถระบุประเภทของฟอลต์ทั้งหมดมีความถูกต้องเฉลี่ย 98.61% โดยสามารถระบุประเภทของฟอลต์ในแต่ละชนิดได้ดังนี้ ระบุประเภทของฟอลต์ชนิด AHV, ALV, BLV และ CLV มีความถูกต้องเฉลี่ยสูงถึง 100% ในขณะที่ระบุประเภทของฟอลต์ชนิด BHV และ CHV สามารถระบุประเภทได้ถูกต้องเฉลี่ย 96%

เมื่อเปรียบเทียบค่าเฉลี่ยจากรูปที่ 7.48 พบว่า ผลการระบุประเภทของฟอลต์ด้วยการแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยดีกว่าผลการระบุประเภทฟอลต์ด้วยวิธีที่ 2


### 7.3.3 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขดลวดที่เกิดการลัดวงจรระหว่างรอบที่ตำแหน่งขดลวดย่อย a 30 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




รูปที่ 7.49 แสดงค่าเฉลี่ยของความถูกต้องในการตรวจจับฟอลต์กรณีขดลวดลัดวงจรระหว่างรอบที่ตำแหน่งขดลวดย่อย a 30 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




รูปที่ 7.50 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย a กรณีขดลวดลัดวงจรระหว่างรอบที่ตำแหน่งขดลวดย่อย a 30% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




รูปที่ 7.51 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 30% กับ 40% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




รูปที่ 7.52 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 30% กับ 50% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




**รูปที่ 7.53** แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 30% กับ 60% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




**รูปที่ 7.54** แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 30% กับ 70% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



รูปที่ 7.55 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ชนิดลวดย่อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 30% กับ 80% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



รูปที่ 7.56 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ชนิดลวดย่อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 30% กับ 90% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



**รูปที่ 7.57** แสดงค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยในการระบุประเภทฟอลต์กรณีขาดขดลวดวงจรระหว่างรอบที่ตำแหน่งขดลวดย่อย a 30% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง

จากผลลัพธ์ในรูปที่ 7.49-7.57 สามารถวิเคราะห์ผลได้ดังนี้

### การตรวจจับฟอลต์

สามารถตรวจจับฟอลต์โดยใช้เพียงข้อมูล จากสัมประสิทธิ์การแปลงเวฟเส้นของกระแสผลต่างในสเกลที่ 1 ได้ถูกต้อง 100% ดังแสดงในรูปที่ 7.49

**การหาดำแหน่งฟอลต์** (ขาดขดลวดย่อย a 30% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)

1. การแปลงเวฟเส้นร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 สามารถหาดำแหน่งฟอลต์ทั้งหมด และจากรูปที่ 7.50 จะเห็นได้ว่า ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.2966% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.034% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.2849% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0151% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.3131% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0131% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และค่าความคาดเคลื่อนเฉลี่ยของตำแหน่งฟอลต์ขาดขดลวดย่อย a ที่คำนวณได้คือ 0.0245% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้า

กำลัง จากรูปที่ 7.51-7.56 จะเห็นได้ว่า ค่าความคาดเคลื่อนเฉลี่ยของตำแหน่งพอลต์ขดลวดย่อย b ที่คำนวณได้คือ 0.0219% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง

2. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 สามารถหาตำแหน่งพอลต์ทั้งหมด จากรูปที่ 7.50 ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.2969% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0031% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.2878% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0122% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.3090% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0090% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และค่าความคาดเคลื่อนเฉลี่ยของตำแหน่งพอลต์ขดลวดย่อย a ที่คำนวณได้คือ 0.0233% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง จากรูปที่ 7.51-7.56 จะเห็นได้ว่า ค่าความคาดเคลื่อนเฉลี่ยของตำแหน่งพอลต์ขดลวดย่อย b ที่คำนวณได้คือ 0.0228% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง


เมื่อเปรียบเทียบค่าเฉลี่ยจากรูปที่ 7.50-7.56 พบว่า ผลการหาตำแหน่งพอลต์ด้วยการแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าที่ใกล้เคียงกับตำแหน่งจริงมากกว่าผลการหาตำแหน่งพอลต์ด้วยวิธีที่ 2

#### การระบุประเภทของพอลต์


1. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 สามารถระบุประเภทของพอลต์ ซึ่งจากรูปที่ 7.57 จะเห็นได้ว่า สามารถระบุประเภทของพอลต์ทั้งหมดมีความถูกต้องเฉลี่ย 99.30% โดยสามารถระบุประเภทของพอลต์ในแต่ละชนิดได้ดังนี้ ระบุประเภทของพอลต์ชนิด AHV, BHV, ALV, BLV และ CLV มีความถูกต้องเฉลี่ยสูงถึง 100% ในขณะที่ระบุประเภทของพอลต์ชนิด CHV สามารถระบุประเภทได้ถูกต้องเฉลี่ย 96%
2. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 สามารถระบุประเภทของพอลต์ ซึ่งจากรูปที่ 7.57 จะเห็นได้ว่า สามารถระบุประเภทของพอลต์ทั้งหมดมีความถูกต้องเฉลี่ย 98.61% โดยสามารถระบุประเภทของพอลต์ในแต่ละชนิดได้ดังนี้ ระบุประเภทของพอลต์ชนิด AHV, ALV, BLV และ CLV มีความถูกต้องเฉลี่ยสูงถึง 100% ในขณะที่ระบุประเภทของพอลต์ชนิด BHV และ CHV สามารถระบุประเภทได้ถูกต้องเฉลี่ย 96%

เมื่อเปรียบเทียบค่าเฉลี่ยจากรูปที่ 7.57 พบว่า ผลการระบุประเภทของฟอลต์ด้วยการแปลงเวฟเส้นร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยดีกว่าผลการระบุประเภทฟอลต์ด้วยวิธีที่ 2


#### 7.3.4 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขดลวดที่เกิดการลัดวงจรระหว่างรอบที่ตำแหน่งขดลวดย่อย a 40 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




รูปที่ 7.58 แสดงค่าเฉลี่ยของความถูกต้องในการตรวจจับฟอลต์กรณีขดลวดลัดวงจรระหว่างรอบที่ตำแหน่งขดลวดย่อย a 40 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




รูปที่ 7.59 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ชนิดลวดย่อย a กรณีชนิดลวดลัดวงจรระหว่างรอบที่ตำแหน่งลวดย่อย a 40% ของความยาวลวดภายในหม้อแปลงไฟฟ้ากำลัง




รูปที่ 7.60 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ชนิดลวดย่อย b กรณีชนิดลวดลัดวงจรระหว่างรอบที่ 40% กับ 50% ของความยาวลวดภายในหม้อแปลงไฟฟ้ากำลัง




**รูปที่ 7.61** แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 40% กับ 60% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




**รูปที่ 7.62** แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 40% กับ 70% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



**รูปที่ 7.63** แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 40% กับ 80% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



**รูปที่ 7.64** แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 40% กับ 90% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



**รูปที่ 7.65** แสดงค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยในการระบุประเภทฟอลต์กรณีขดลวดลัดวงจรระหว่างรอบที่ตำแหน่งขดลวดย่อย a 40% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง

จากผลลัพธ์ในรูปที่ 7.58-7.65 สามารถวิเคราะห์ผลได้ดังนี้

### การตรวจจับฟอลต์

สามารถตรวจจับฟอลต์โดยใช้เพียงข้อมูล จากสัมประสิทธิ์การแปลงเวฟเล็ดของกระแสผลต่างในสเกลที่ 1 ได้ถูกต้อง 100% ดังแสดงในรูปที่ 7.58

**การหาตำแหน่งฟอลต์** (ขดลวดย่อย a 40% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)

1. การแปลงเวฟเล็ดร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 สามารถหาตำแหน่งฟอลต์ทั้งหมด และจากรูปที่ 7.59 จะเห็นได้ว่า ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.3989% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0011% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.3931% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0069% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.4110% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.011% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และค่าความคลาดเคลื่อนเฉลี่ยของตำแหน่ง

- ฟอลต์ชนิดลวดย่อย a ที่คำนวณได้คือ 0.0240% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง จากรูปที่ 7.60-7.64 จะเห็นได้ว่า ค่าความคาดเคลื่อนเฉลี่ยของตำแหน่งฟอลต์ชนิดลวดย่อย b ที่คำนวณได้คือ 0.0208% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง
2. การแปลงเวฟเส้นร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 สามารถหาตำแหน่งฟอลต์ทั้งหมด จากรูปที่ 7.59 ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.4001% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0001% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.3892% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0108% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.4152% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0152% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และค่าความคาดเคลื่อนเฉลี่ยของตำแหน่งฟอลต์ชนิดลวดย่อย a ที่คำนวณได้คือ 0.0235% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง จากรูปที่ 7.60-7.64 จะเห็นได้ว่า ค่าความคาดเคลื่อนเฉลี่ยของตำแหน่งฟอลต์ชนิดลวดย่อย b ที่คำนวณได้คือ 0.0225% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง


เมื่อเปรียบเทียบค่าเฉลี่ยจากรูปที่ 7.59-7.64 พบว่า ผลการหาตำแหน่งฟอลต์ด้วยการแปลงเวฟเส้นร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าที่ใกล้เคียงกับตำแหน่งจริงมากกว่าผลการหาตำแหน่งฟอลต์ด้วยวิธีที่ 2

### การระบุประเภทของฟอลต์


1. การแปลงเวฟเส้นร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 สามารถระบุประเภทของฟอลต์ ซึ่งจากรูปที่ 7.65 จะเห็นได้ว่า สามารถระบุประเภทของฟอลต์ทั้งหมดมีความถูกต้องเฉลี่ย 99.30% โดยสามารถระบุประเภทของฟอลต์ในแต่ละชนิดได้ดังนี้ ระบุประเภทของฟอลต์ชนิด AHV, BHV, ALV, BLV และ CLV มีความถูกต้องเฉลี่ยสูงถึง 100% ในขณะที่ระบุประเภทของฟอลต์ชนิด CHV สามารถระบุประเภทได้ถูกต้องเฉลี่ย 96%
2. การแปลงเวฟเส้นร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 สามารถระบุประเภทของฟอลต์ ซึ่งจากรูปที่ 7.65 จะเห็นได้ว่า สามารถระบุประเภทของฟอลต์ทั้งหมดมีความถูกต้องเฉลี่ย 98.61% โดยสามารถระบุประเภทของฟอลต์ในแต่ละชนิดได้ดังนี้ ระบุประเภทของฟอลต์ชนิด AHV, ALV, BLV และ CLV มีความถูกต้องเฉลี่ยสูงถึง 100% ในขณะที่ระบุประเภทของฟอลต์ชนิด BHV และ CHV สามารถระบุประเภทได้ถูกต้องเฉลี่ย 96%

เมื่อเปรียบเทียบค่าเฉลี่ยจากรูปที่ 7.48 พบว่า ผลการระบุประเภทของฟอลต์ด้วยการแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยดีกว่าผลการระบุประเภทฟอลต์ด้วยวิธีที่ 2


### 7.3.5 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขดลวดที่เกิดการลัดวงจรระหว่างรอบที่ตำแหน่งขดลวดย่อย a 50 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




รูปที่ 7.66 แสดงค่าเฉลี่ยของความถูกต้องในการตรวจจับฟอลต์กรณีขดลวดลัดวงจรระหว่างรอบที่ตำแหน่งขดลวดย่อย a 50 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




รูปที่ 7.67 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย a กรณีขดลวดลัดวงจรระหว่างรอบที่ตำแหน่งขดลวดย่อย a 50% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




รูปที่ 7.68 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 50% กับ 60% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




**รูปที่ 7.69** แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 50% กับ 70% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



**รูปที่ 7.70** แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 50% กับ 80% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



รูปที่ 7.71 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 50% กับ 90% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



รูปที่ 7.72 แสดงค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยในการระบุประเภทฟอลต์กรณีขดลวดลัดวงจรระหว่างรอบที่ตำแหน่งขดลวดย่อย a 50% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง

จากผลลัพธ์ในรูปที่ 7.66-7.72 สามารถวิเคราะห์ผลได้ดังนี้

### การตรวจจับฟอลต์

สามารถตรวจจับฟอลต์โดยใช้เพียงข้อมูล จากสัมประสิทธิ์การแปลงเวฟเล็ทของกระแสผลต่าง ในสเกลที่ 1 ได้ถูกต้อง 100% ดังแสดงในรูปที่ 7.66

**การหาตำแหน่งฟอลต์** (ขดลวดย่อย a 50% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)

1. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 สามารถหาตำแหน่งฟอลต์ทั้งหมด และจากรูปที่ 7.67 จะเห็นได้ว่า ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.4991% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0009% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.4931% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0069% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.5129% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0129% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และค่าความคาดเคลื่อนเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย a ที่คำนวณได้คือ 0.0229% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง จากรูปที่ 7.68-7.71 จะเห็นได้ว่า ค่าความคาดเคลื่อนเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย b ที่คำนวณได้คือ 0.0200% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง
2. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 สามารถหาตำแหน่งฟอลต์ทั้งหมด จากรูปที่ 7.67 ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.5052% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0052% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.4911% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0089% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.5176% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0176% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และค่าความคาดเคลื่อนเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย a ที่คำนวณได้คือ 0.0227% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง จากรูปที่ 7.68-7.71 จะเห็นได้ว่า ค่าความคาดเคลื่อนเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย b ที่คำนวณได้คือ 0.0221% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง


เมื่อเปรียบเทียบค่าเฉลี่ยจากรูปที่ 7.67-7.71 พบว่า ผลการหาตำแหน่งฟอลต์ด้วยการแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าที่ใกล้เคียงกับตำแหน่งจริงมากกว่าผลการหาตำแหน่งฟอลต์ด้วยวิธีที่ 2

#### การระบุประเภทของฟอลต์


1. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 สามารถระบุประเภทของฟอลต์ ซึ่งจากรูปที่ 7.72 จะเห็นได้ว่า สามารถระบุประเภทของฟอลต์ทั้งหมดมีความถูกต้องเฉลี่ย 99.30% โดยสามารถระบุประเภทของฟอลต์ในแต่ละชนิดได้ดังนี้ ระบุประเภทของฟอลต์ชนิด AHV, BHV, ALV, BLV และ CLV มีความถูกต้องเฉลี่ยสูงถึง 100% ในขณะที่ระบุประเภทของฟอลต์ชนิด CHV สามารถระบุประเภทได้ถูกต้องเฉลี่ย 96%
2. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 สามารถระบุประเภทของฟอลต์ ซึ่งจากรูปที่ 7.72 จะเห็นได้ว่า สามารถระบุประเภทของฟอลต์ทั้งหมดมีความถูกต้องเฉลี่ย 98.61% โดยสามารถระบุประเภทของฟอลต์ในแต่ละชนิดได้ดังนี้ ระบุประเภทของฟอลต์ชนิด AHV, ALV, BLV และ CLV มีความถูกต้องเฉลี่ยสูงถึง 100% ในขณะที่ระบุประเภทของฟอลต์ชนิด BHV และ CHV สามารถระบุประเภทได้ถูกต้องเฉลี่ย 96%

เมื่อเปรียบเทียบค่าเฉลี่ยจากรูปที่ 7.72 พบว่า ผลการระบุประเภทของฟอลต์ด้วยการแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยดีกว่าผลการระบุประเภทฟอลต์ด้วยวิธีที่ 2


7.3.6 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขดลวดที่เกิดการลัดวงจรระหว่างรอบ  
ที่ตำแหน่งขดลวดย่อย a 60 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




รูปที่ 7.73 แสดงค่าเฉลี่ยของความถูกต้องในการตรวจจับฟอลต์กรณีขดลวดลัดวงจรระหว่างรอบที่ตำแหน่งขดลวดย่อย a 60 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




รูปที่ 7.74 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย a กรณีขดลวดลัดวงจรระหว่างรอบที่ตำแหน่งขดลวดย่อย a 60% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




รูปที่ 7.75 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ขาดลวดย่อย b กรณีขาดลวดลัดวงจรระหว่างรอบที่ 60% กับ 70% ของความยาวขาดลวดภายในหม้อแปลงไฟฟ้ากำลัง



รูปที่ 7.76 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ขาดลวดย่อย b กรณีขาดลวดลัดวงจรระหว่างรอบที่ 60% กับ 80% ของความยาวขาดลวดภายในหม้อแปลงไฟฟ้ากำลัง



รูปที่ 7.77 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ชนิดลวดย่อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 60% กับ 90% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



รูปที่ 7.78 แสดงค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยในการระบุประเภทฟอลต์กรณีขดลวดลัดวงจรระหว่างรอบที่ตำแหน่งขดลวดย่อย a 60% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง

จากผลลัพธ์ในรูปที่ 7.73-7.78 สามารถวิเคราะห์ผลได้ดังนี้

### การตรวจจับฟอลต์

สามารถตรวจจับฟอลต์โดยใช้เพียงข้อมูล จากสัมประสิทธิ์การแปลงเวฟเล็ตของกระแสผลต่าง ในสเกลที่ 1 ได้ถูกต้อง 100% ดังแสดงในรูปที่ 7.73

**การหาตำแหน่งฟอลต์** (ขดลวดย่อย a 60% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)

1. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 สามารถหาตำแหน่งฟอลต์ทั้งหมด และจากรูปที่ 7.74 จะเห็นได้ว่า ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.5977% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0023% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.5864% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0136% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.6119% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0119% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และค่าความคลาดเคลื่อนเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย a ที่คำนวณได้คือ 0.0247% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง จากรูปที่ 7.75-7.77 จะเห็นได้ว่า ค่าความคลาดเคลื่อนเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย b ที่คำนวณได้คือ 0.0208% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง
2. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 สามารถหาตำแหน่งฟอลต์ทั้งหมด จากรูปที่ 7.74 ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.5989% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0011% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.5814% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0186% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.6108% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0108% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และค่าความคลาดเคลื่อนเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย a ที่คำนวณได้คือ 0.0263% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง จากรูปที่ 7.75-7.77 จะเห็นได้ว่า ค่าความคลาดเคลื่อนเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย b ที่คำนวณได้คือ 0.0217% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง


เมื่อเปรียบเทียบเฉลี่ยจากรูปที่ 7.74-7.77 พบว่า ผลการหาดำแหน่งฟอลต์ด้วยการแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าที่ใกล้เคียงกับตำแหน่งจริงมากกว่าผลการหาดำแหน่งฟอลต์ด้วยวิธีที่ 2

#### การระบุประเภทของฟอลต์


1. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 สามารถระบุประเภทของฟอลต์ ซึ่งจากรูปที่ 7.78 จะเห็นได้ว่า สามารถระบุประเภทของฟอลต์ทั้งหมดมีความถูกต้องเฉลี่ย 99.30% โดยสามารถระบุประเภทของฟอลต์ในแต่ละชนิดได้ดังนี้ ระบุประเภทของฟอลต์ชนิด AHV, BHV, ALV, BLV และ CLV มีความถูกต้องเฉลี่ยสูงถึง 100% ในขณะที่ระบุประเภทของฟอลต์ชนิด CHV สามารถระบุประเภทได้ถูกต้องเฉลี่ย 96%
2. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 สามารถระบุประเภทของฟอลต์ ซึ่งจากรูปที่ 7.78 จะเห็นได้ว่า สามารถระบุประเภทของฟอลต์ทั้งหมดมีความถูกต้องเฉลี่ย 98.61% โดยสามารถระบุประเภทของฟอลต์ในแต่ละชนิดได้ดังนี้ ระบุประเภทของฟอลต์ชนิด AHV, ALV, BLV และ CLV มีความถูกต้องเฉลี่ยสูงถึง 100% ในขณะที่ระบุประเภทของฟอลต์ชนิด BHV และ CHV สามารถระบุประเภทได้ถูกต้องเฉลี่ย 96%

เมื่อเปรียบเทียบเฉลี่ยจากรูปที่ 7.78 พบว่า ผลการระบุประเภทของฟอลต์ด้วยการแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยดีกว่าผลการระบุประเภทฟอลต์ด้วยวิธีที่ 2


7.3.7 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขดลวดที่เกิดการลัดวงจรระหว่างรอบที่ตำแหน่งขดลวดย่อย a 70 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




รูปที่ 7.79 แสดงค่าเฉลี่ยของความถูกต้องในการตรวจจับฟอลต์กรณีขดลวดลัดวงจรระหว่างรอบที่ตำแหน่งขดลวดย่อย a 70 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




รูปที่ 7.80 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย a กรณีขดลวดลัดวงจรระหว่างรอบที่ตำแหน่งขดลวดย่อย a 70% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



**รูปที่ 7.81** แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ชนิดลวดย่อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 70% กับ 80% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



**รูปที่ 7.82** แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ชนิดลวดย่อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 70% กับ 90% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



**รูปที่ 7.83** แสดงค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยในการระบุประเภทฟอลต์กรณีขดลวดลัดวงจรระหว่างรอบที่ตำแหน่งขดลวดย่อย a 70% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง

จากผลลัพธ์ในรูปที่ 7.79-7.83 สามารถวิเคราะห์ผลได้ดังนี้

#### การตรวจจับฟอลต์

สามารถตรวจจับฟอลต์โดยใช้เพียงข้อมูล จากสัมประสิทธิ์การแปลงเวฟสี่ตัวของกระแสผลต่างในสเกลที่ 1 ได้ถูกต้อง 100% ดังแสดงในรูปที่ 7.79

**การหาตำแหน่งฟอลต์** (ขดลวดย่อย a 70% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)

1. การแปลงเวฟสี่ตัวร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 สามารถหาตำแหน่งฟอลต์ทั้งหมด และจากรูปที่ 7.80 จะเห็นได้ว่า ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.6974% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0026% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.6805% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0195% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.7096% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0096% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และค่าความคาดเคลื่อนเฉลี่ยของตำแหน่ง

ฟอลต์ชนิดลวดย่อย a ที่คำนวณได้คือ 0.0218% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง จากรูปที่ 7.81-7.82 จะเห็นได้ว่า ค่าความคาดเคลื่อนเฉลี่ยของตำแหน่งฟอลต์ชนิดลวดย่อย b ที่คำนวณได้คือ 0.0207% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง

2. การแปลงเวฟเส้นตรงกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 สามารถหาตำแหน่งฟอลต์ทั้งหมด จากรูปที่ 7.80 ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.7002% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0002% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.6866% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0134% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.7168% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0168% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และค่าความคาดเคลื่อนเฉลี่ยของตำแหน่งฟอลต์ชนิดลวดย่อย a ที่คำนวณได้คือ 0.023% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง จากรูปที่ 7.81-7.82 จะเห็นได้ว่า ค่าความคาดเคลื่อนเฉลี่ยของตำแหน่งฟอลต์ชนิดลวดย่อย b ที่คำนวณได้คือ 0.0245% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง


เมื่อเปรียบเทียบค่าเฉลี่ยจากรูปที่ 7.40-7.47 พบว่า ผลการหาตำแหน่งฟอลต์ด้วยการแปลงเวฟเส้นตรงกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าที่ใกล้เคียงกับตำแหน่งจริงมากกว่าผลการหาตำแหน่งฟอลต์ด้วยวิธีที่ 2

### การระบุประเภทของฟอลต์


1. การแปลงเวฟเส้นตรงกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 สามารถระบุประเภทของฟอลต์ ซึ่งจากรูปที่ 7.83 จะเห็นได้ว่า สามารถระบุประเภทของฟอลต์ทั้งหมดมีความถูกต้องเฉลี่ย 99.30% โดยสามารถระบุประเภทของฟอลต์ในแต่ละชนิดได้ดังนี้ ระบุประเภทของฟอลต์ชนิด AHV, BHV, ALV, BLV และ CLV มีความถูกต้องเฉลี่ยสูงถึง 100% ในขณะที่ระบุประเภทของฟอลต์ชนิด CHV สามารถระบุประเภทได้ถูกต้องเฉลี่ย 96%
2. การแปลงเวฟเส้นตรงกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 สามารถระบุประเภทของฟอลต์ ซึ่งจากรูปที่ 7.83 จะเห็นได้ว่า สามารถระบุประเภทของฟอลต์ทั้งหมดมีความถูกต้องเฉลี่ย 98.61% โดยสามารถระบุประเภทของฟอลต์ในแต่ละชนิดได้ดังนี้ ระบุประเภทของฟอลต์ชนิด AHV, ALV, BLV และ CLV มีความถูกต้องเฉลี่ยสูงถึง 100% ในขณะที่ระบุประเภทของฟอลต์ชนิด BHV และ CHV สามารถระบุประเภทได้ถูกต้องเฉลี่ย 96%

เมื่อเปรียบเทียบเฉลี่ยจากรูปที่ 7.83 พบว่า ผลการระบุประเภทของฟอลต์ด้วยการแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยดีกว่าผลการระบุประเภทฟอลต์ด้วยวิธีที่ 2


### 7.3.8 ผลการวิเคราะห์สัญญาณฟอลต์ เมื่อเกิดฟอลต์กรณีขดลวดที่เกิดการลัดวงจรระหว่างรอบที่ตำแหน่งขดลวดย่อย a 80 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง




รูปที่ 7.84 แสดงค่าเฉลี่ยของความถูกต้องในการตรวจจับฟอลต์กรณีขดลวดลัดวงจรระหว่างรอบที่ตำแหน่งขดลวดย่อย a 80 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



รูปที่ 7.85 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย a กรณีขดลวดลัดวงจรระหว่างรอบที่ตำแหน่งขดลวดย่อย a 80% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



รูปที่ 7.86 แสดงค่าเฉลี่ยของตำแหน่งฟอลต์ขดลวดย่อย b กรณีขดลวดลัดวงจรระหว่างรอบที่ 80% กับ 90% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง



**รูปที่ 7.87** แสดงค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยในการระบุประเภทฟอลต์กรณีขดลวดลัดวงจรระหว่างรอบที่ตำแหน่งขดลวดย่อย  $\alpha$  80% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง

จากผลลัพธ์ในรูปที่ 7.84-7.87 สามารถวิเคราะห์ผลได้ดังนี้

#### การตรวจจับฟอลต์

สามารถตรวจจับฟอลต์โดยใช้เพียงข้อมูล จากสัมประสิทธิ์การแปลงเวฟเส้นของกระแสผลต่างในสเกลที่ 1 ได้ถูกต้อง 100% ดังแสดงในรูปที่ 7.84

**การหาตำแหน่งฟอลต์** (ขดลวดย่อย  $\alpha$  80% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง)

1. การแปลงเวฟเส้นร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 สามารถหาตำแหน่งฟอลต์ทั้งหมด และจากรูปที่ 7.85 จะเห็นได้ว่า ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.7939% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0061% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.7842% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0158% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.8118% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0118% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และค่าความคาดเคลื่อนเฉลี่ยของตำแหน่ง

ฟอลต์ชนิดลวดย่อย a ที่คำนวณได้คือ 0.0252% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง จากรูปที่ 7.86 จะเห็นได้ว่า ค่าความคาดเคลื่อนเฉลี่ยของตำแหน่งฟอลต์ชนิดลวดย่อย b ที่คำนวณได้คือ 0.0118% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง

2. การแปลงเวฟเส้นร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 สามารถหาตำแหน่งฟอลต์ทั้งหมด จากรูปที่ 7.85 ตำแหน่งเฉลี่ยที่คำนวณได้คือ 0.7991% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0009% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยต่ำสุดที่คำนวณได้คือ 0.7833% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0164% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง), ตำแหน่งเฉลี่ยสูงสุดที่คำนวณได้คือ 0.8099% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง (คลาดเคลื่อน 0.0099% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง) และค่าความคาดเคลื่อนเฉลี่ยของตำแหน่งฟอลต์ชนิดลวดย่อย a ที่คำนวณได้คือ 0.0275% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง จากรูปที่ 7.86 จะเห็นได้ว่า ค่าความคาดเคลื่อนเฉลี่ยของตำแหน่งฟอลต์ชนิดลวดย่อย b ที่คำนวณได้คือ 0.0168% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง


เมื่อเปรียบเทียบเฉลี่ยจากรูปที่ 7.85-7.86 พบว่า ผลการหาตำแหน่งฟอลต์ด้วยการแปลงเวฟเส้นร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าที่ใกล้เคียงกับตำแหน่งจริงมากกว่าผลการหาตำแหน่งฟอลต์ด้วยวิธีที่ 2

### การระบุประเภทของฟอลต์

1. การแปลงเวฟเส้นร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 1 สามารถระบุประเภทของฟอลต์ ซึ่งจากรูปที่ 7.87 จะเห็นได้ว่า สามารถระบุประเภทของฟอลต์ทั้งหมดมีความถูกต้องเฉลี่ย 99.30% โดยสามารถระบุประเภทของฟอลต์ในแต่ละชนิดได้ดังนี้ ระบุประเภทของฟอลต์ชนิด AHV, BHV, ALV, BLV และ CLV มีความถูกต้องเฉลี่ยสูงถึง 100% ในขณะที่ระบุประเภทของฟอลต์ชนิด CHV สามารถระบุประเภทได้ถูกต้องเฉลี่ย 96%
2. การแปลงเวฟเส้นร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ (BP) ในวิธีที่ 2 สามารถระบุประเภทของฟอลต์ ซึ่งจากรูปที่ 7.87 จะเห็นได้ว่า สามารถระบุประเภทของฟอลต์ทั้งหมดมีความถูกต้องเฉลี่ย 98.61% โดยสามารถระบุประเภทของฟอลต์ในแต่ละชนิดได้ดังนี้ ระบุประเภทของฟอลต์ชนิด AHV, ALV, BLV และ CLV มีความถูกต้องเฉลี่ยสูงถึง 100% ในขณะที่ระบุประเภทของฟอลต์ชนิด BHV และ CHV สามารถระบุประเภทได้ถูกต้องเฉลี่ย 96%







เมื่อเปรียบเทียบค่าเฉลี่ยจากรูปที่ 7.87 พบว่า ผลการระบุประเภทของฟอลต์ด้วยการแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิธีที่ 1 จะให้ค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยดีกว่าผลการระบุประเภทฟอลต์ด้วยวิธีที่ 2

#### 7.4 สรุปและวิเคราะห์ผลลัพธ์ที่ได้จากกรณีศึกษา



รูปที่ 7.88 แสดงค่าเฉลี่ยความคลาดเคลื่อนของตำแหน่งฟอลต์แต่ละประเภทฟอลต์กรณีขดลวดลัดวงจรลงดิน

จากรูปที่ 7.88 เมื่อพิจารณาค่าเฉลี่ยของความคลาดเคลื่อนในการระบุตำแหน่งฟอลต์เทียบกับประเภทของฟอลต์กรณีขดลวดลัดวงจรลงดินพบว่า ค่าเฉลี่ยของความคลาดเคลื่อนของทั้งวิธีที่ 1 (Method 1) และวิธีที่ 2 (Method 2) อยู่ในช่วง 0.0075-0.0022 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง และ ค่าเฉลี่ยความคลาดเคลื่อนในการระบุตำแหน่งฟอลต์ทั้งวิธีที่ 1 (Method 1) และวิธีที่ 2 (Method 2) ทางด้านแรงดันสูงจะมีค่าเฉลี่ยน้อยกว่าทางด้านแรงดันต่ำ




(ก) ทางด้านขดลวดแรงดันสูง

(ข) ทางด้านขดลวดแรงดันต่ำ


รูปที่ 7.89 แสดงค่าเฉลี่ยความคลาดเคลื่อนของตำแหน่งพอลต์กรณิขดลวดตัววงจรลงดินในแต่ละตำแหน่งของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง

จากรูปที่ 7.89 เมื่อพิจารณาค่าเฉลี่ยความคลาดเคลื่อนในการการระบุตำแหน่งฟอลต์กรณีขดลวดลัดวงจรลงดินเทียบกับตำแหน่งที่เกิดฟอลต์ต่างๆ พบว่า

1. ค่าเฉลี่ยความคลาดเคลื่อนในการระบุตำแหน่งฟอลต์ทั้งสองวิธีทางด้านแรงดันสูงจะมีค่าเฉลี่ยน้อยกว่าทางด้านแรงดันต่ำ ซึ่งอยู่ในช่วง 0-0.02% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง
2. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมทั้งสองวิธี ที่ตำแหน่งฟอลต์ 10% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลังจะมีค่าเฉลี่ยความคลาดเคลื่อนสูงกว่าตำแหน่งอื่นๆ ยกเว้นวิธีที่ 2 ทางด้านแรงดันต่ำจะมีค่าเฉลี่ยลดลง
3. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมในวิธีที่ 2 จะให้ค่าเฉลี่ยความคลาดเคลื่อนสูงกว่าวิธีที่ 1 ยกเว้นฟอลต์ทางด้านแรงดันสูงเฟส C
4. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมในวิธีที่ 1 โดยส่วนใหญ่ที่ตำแหน่งฟอลต์ 10% ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลังจะมีค่าเฉลี่ยความคลาดเคลื่อนสูงทุกประเภทฟอลต์









รูปที่ 7.90 แสดงค่าเฉลี่ยความคลาดเคลื่อนของตำแหน่งฟอลต์ขดลวดย่อย a แต่ละประเภทฟอลต์กรณีขดลวดลัดวงจรระหว่างรอบ



**รูปที่ 7.91** แสดงค่าเฉลี่ยความคลาดเคลื่อนของตำแหน่งฟอลต์ขดลวดย่อย b แต่ละประเภทฟอลต์กรณีขดลวดลัดวงจรระหว่างรอบ







จากรูปที่ 7.90-7.91 เมื่อพิจารณาค่าเฉลี่ยของความคลาดเคลื่อนในการระบุตำแหน่งฟอลต์เทียบกับประเภทของฟอลต์กรณีขดลวดลัดวงจรระหว่างรอบพบว่า ค่าเฉลี่ยของความคลาดเคลื่อนของทั้งวิธีที่ 1 (Method 1) และวิธีที่ 2 (Method 2) อยู่ในช่วง 0.014-0.032 % ของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง และเป็นที่น่าสนใจว่า โดยส่วนใหญ่ค่าเฉลี่ยความคลาดเคลื่อนในวิธีที่ 2 จะมีค่าเฉลี่ยความคลาดเคลื่อนมากกว่าวิธีที่ 1



(ก) ทางด้านขดลวดแรงดันสูง

(ข) ทางด้านขดลวดแรงดันต่ำ

รูปที่ 7.92 แสดงค่าเฉลี่ยความคลาดเคลื่อนของตำแหน่งฟลด์กรณิขดลวดลัดวงจรระหว่างรอบในแต่ละตำแหน่งของความยาวขดลวดย่อย a ภายในหม้อแปลงไฟฟ้ากำลัง




(ก) ทางด้านขดลวดแรงดันสูง

(ข) ทางด้านขดลวดแรงดันต่ำ







รูปที่ 7.93 แสดงค่าเฉลี่ยความคลาดเคลื่อนของตำแหน่งฟลัดด์กรณีขดลวดลัดวงจรระหว่างรอบในแต่ละตำแหน่งของความยาวขดลวดย่อย b ภายในหม้อแปลงไฟฟ้ากำลัง

จากรูปที่ 7.92 เมื่อพิจารณาค่าเฉลี่ยความคลาดเคลื่อนในการหาดำแหน่งพอลต์เทียบกับระยะทางที่เกิดพอลต์พบว่า

1. ค่าเฉลี่ยความคลาดเคลื่อนในการระบุตำแหน่งพอลต์ทั้งวิธีที่ 1 (Method 1) และวิธีที่ 2 (Method 2) ทางด้านแรงดันสูงจะมีค่าเฉลี่ยมากกว่าทางด้านแรงดันต่ำ ซึ่งอยู่ในช่วง 0.015-0.045% ของความยาวขดลวดย่อย a ภายในหม้อแปลงไฟฟ้ากำลัง ในขณะที่ขดลวดย่อย b มีค่าเฉลี่ยอยู่ในช่วง 0.0005-0.045% ของความยาวขดลวดย่อย b ภายในหม้อแปลงไฟฟ้ากำลัง
2. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมทั้งวิธีที่ 1 (Method 1) และวิธีที่ 2 (Method 2) ที่ตำแหน่งพอลต์ 80% ของความยาวขดลวดย่อย a ภายในหม้อแปลงไฟฟ้ากำลังทางด้านแรงดันสูงจะมีค่าเฉลี่ยความคลาดเคลื่อนสูงกว่าตำแหน่งอื่นๆ ยกเว้นวิธีที่ 1 ทางด้านแรงดันสูงเฟส C จะมีค่าเฉลี่ยลดลง
3. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมทั้งวิธีที่ 1 (Method 1) และวิธีที่ 2 (Method 2) ที่ตำแหน่งพอลต์ 80% ของความยาวขดลวดย่อย a ภายในหม้อแปลงไฟฟ้ากำลังทางด้านแรงดันต่ำจะมีค่าเฉลี่ยความคลาดเคลื่อนต่ำกว่าตำแหน่งอื่นๆ ยกเว้นทางด้านแรงดันต่ำเฟส A
4. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมในวิธีที่ 2 จะให้ค่าเฉลี่ยความคลาดเคลื่อนสูงกว่าวิธีที่ 1 ยกเว้นพอลต์ทางด้านแรงดันต่ำเฟส C จะมีค่าเฉลี่ยความคลาดเคลื่อนต่ำกว่าวิธีที่ 1 อย่างเห็นได้ชัด



รูปที่ 7.94 แสดงค่าเฉลี่ยความถูกต้องในการระบุประเภทพอลต์แต่ละประเภทในระบบจำลอง



(ก) ทางด้านขดลวดแรงดันสูง

(ข) ทางด้านขดลวดแรงดันต่ำ







รูปที่ 7.95 แสดงค่าเฉลี่ยความถูกต้องของการระบุประเภทฟอลต์กรณีขดลวดลัดวงจรลงดินในแต่ละตำแหน่งของความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลัง

จากรูปที่ 7.94 เมื่อพิจารณาค่าเฉลี่ยความถูกต้องในการระบุประเภทฟอลต์กรณีขดลวด ลัดวงจรลงดินเทียบกับประเภทของฟอลต์พบว่า

1. การแปลงเวฟเส้นร่วมกับโครงข่ายประสาทเทียมทั้งวิธีที่ 1 (Method 1) และวิธีที่ 2 (Method 2) สามารถระบุประเภทของฟอลต์ได้ถูกต้องเฉลี่ยมากกว่า 85%
2. การแปลงเวฟเส้นร่วมกับโครงข่ายประสาทเทียมในวิธีที่ 1 สามารถระบุประเภทฟอลต์ได้ถูกต้องเฉลี่ยดีกว่าวิธีที่ 2
3. การแปลงเวฟเส้นร่วมกับโครงข่ายประสาทเทียมทั้งวิธีที่ 1 (Method 1) และวิธีที่ 2 (Method 2) สามารถระบุประเภทฟอลต์ที่เกิดทางด้านแรงดันต่ำได้ถูกต้อง 100%

จากรูปที่ 7.95 เมื่อพิจารณาค่าเฉลี่ยความถูกต้องในการระบุประเภทฟอลต์กรณีขดลวด ลัดวงจรลงดินเทียบกับตำแหน่งฟอลต์ พบว่า







1. การแปลงเวฟเส้นร่วมกับโครงข่ายประสาทเทียมในวิธีที่ 1 สามารถระบุประเภทฟอลต์ได้ถูกต้องเฉลี่ยดีกว่าวิธีที่ 2
2. การแปลงเวฟเส้นร่วมกับโครงข่ายประสาทเทียมทั้งวิธีที่ 1 (Method 1) และวิธีที่ 2 (Method 2) สามารถระบุประเภทฟอลต์ที่เกิดทางด้านแรงดันต่ำได้ถูกต้อง 100%
3. การแปลงเวฟเส้นร่วมกับโครงข่ายประสาทเทียมทั้งวิธีที่ 1 (Method 1) และวิธีที่ 2 (Method 2) สามารถระบุประเภทฟอลต์ที่เกิดทางด้านแรงดันสูงในช่วง 30-90% ของ ความยาวขดลวดภายในหม้อแปลงไฟฟ้ากำลังได้ถูกต้องทั้งหมด (100%)



(ก) ทางค้ำขนาดลวดแรงดันสูง

(ข) ทางค้ำขนาดลวดแรงดันต่ำ

รูปที่ 7.96 แสดงค่าเฉลี่ยความถูกต้องของการระบุประเภทฟอลต์กรณีขลวดลัดวงจรระหว่างรอบ  
ในแต่ละตำแหน่งของความยาวขลวดย่อย a ภายในหม้อแปลงไฟฟ้ากำลัง



(ก) ทางด้านขดลวดแรงดันสูง

(ข) ทางด้านขดลวดแรงดันต่ำ

รูปที่ 7.97 แสดงค่าเฉลี่ยความถูกต้องของการระบุประเภทฟอลต์กรณีขดลวดลัดวงจรระหว่างรอบ  
ในแต่ละตำแหน่งของความยาวขดลวดย่อย b ภายในหม้อแปลงไฟฟ้ากำลัง

จากรูปที่ 7.96 และ 7.97 เมื่อพิจารณาค่าเฉลี่ยความถูกต้องในการระบุประเภทฟอลต์กรณี ขดลวดลัดวงจรลงดินเทียบกับตำแหน่งฟอลต์ พบว่า

1. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมในวิธีที่ 1 สามารถระบุประเภทฟอลต์ได้ถูกต้องเฉลี่ยดีกว่าวิธีที่ 2
2. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมทั้งวิธีที่ 1 (Method 1) และวิธีที่ 2 (Method 2) สามารถระบุประเภทฟอลต์ที่เกิดทางด้านแรงดันต่ำได้ถูกต้อง 100%
3. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมวิธีที่ 1 สามารถระบุประเภทฟอลต์ที่เกิดทางด้านแรงดันสูงเฟส A และ B ได้ถูกต้อง 100% ในขณะที่เฟส C ได้ถูกต้อง 96%
4. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมวิธีที่ 2 สามารถระบุประเภทฟอลต์ที่เกิดทางด้านแรงดันสูงเฟส A ได้ถูกต้อง 100% ในขณะที่เฟส B และ C ได้ถูกต้อง 96%
5. การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมทั้งวิธีที่ 1 (Method 1) และวิธีที่ 2 (Method 2) สามารถระบุประเภทฟอลต์ที่เกิดทางด้านแรงดันสูงในช่วง 20-80% ของความยาวขดลวดย่อย b ภายในหม้อแปลงไฟฟ้ากำลังได้ถูกต้องทั้งหมด (100%)

## บทที่ 8

# บทสรุปและข้อเสนอแนะ

ความเสียหายที่เกิดขึ้นกับขดลวดภายในหม้อแปลงไฟฟ้ากำลังเป็นเรื่องที่ต้องให้ความสำคัญอย่างยิ่ง ความเสียหายส่วนหนึ่งมาจากการเกิดการลัดวงจร (Faults) ของฉนวนที่กั้นระหว่างขดลวด ส่วนใหญ่การเกิดการลัดวงจรนี้จะเกิดที่ส่วนปลายของขดลวด ส่วนการเกิดการลัดวงจรของฉนวนระหว่างขดลวดจะเกิดขึ้นเนื่องจากมีแรงดัน Steep-fronted Transients ซึ่งแรงดันนี้จะทำให้เกิดความเครียดระหว่างขดลวดมากเกินไปจึงทำให้ฉนวนทนไม่ได้ เมื่อเกิดการลัดวงจรเกิดขึ้นจึงมีความจำเป็นต้องหาสาเหตุความผิดปกตินั้นเพื่อที่จะแก้ไขให้สามารถนำหม้อแปลงไฟฟ้ากำลังเชื่อมต่อเข้ากับระบบได้อีกครั้ง ดังนั้น ในวิทยานิพนธ์ฉบับนี้ได้นำเสนอรูปแบบการวิเคราะห์สัญญาณฟอลต์ด้วยการแปลงเวฟเล็ตแบบเต็มหน่วยร่วมกับโครงข่ายประสาทเทียม และนำผลที่ได้มาประมวลผลตามขั้นตอนที่ได้นำเสนอมาแล้วนั้นสามารถสรุปได้ดังต่อไปนี้

1. รูปแบบการวิเคราะห์อาศัยการพิจารณาการเปลี่ยนแปลงขององค์ประกอบความถี่สูงที่อยู่ในสัญญาณฟอลต์ โดยสัญญาณฟอลต์ที่ใช้ในการศึกษาในวิทยานิพนธ์นี้ได้มาจากการจำลองด้วยโปรแกรม ATP/EMTP ซึ่งอาศัยแบบจำลองหม้อแปลงไฟฟ้ากำลังที่สถานีไฟฟ้ามหาสารคาม (MK) เป็นหม้อแปลงไฟฟ้ากำลังที่ใช้ในการศึกษา โดยทำการจำลองด้วยการปรับเปลี่ยนพารามิเตอร์ต่างๆ เพื่อศึกษาลักษณะของฟอลต์ในหลายรูปแบบที่อัตราการสุ่ม 200 kHz

2. การแปลงเวฟเล็ตแบบเต็มหน่วยโดยใช้เวฟเล็ตแม่ชนิด Daubechies 4 (db4) ถูกนำมาใช้ในการวิเคราะห์สัญญาณฟอลต์ โดยทำวิเคราะห์และพิจารณาการเปลี่ยนแปลงขององค์ประกอบความถี่สูงที่อยู่ในสัญญาณฟอลต์ จากนั้นทำการแยกองค์ประกอบความถี่สูงออกมาในสเกลที่ 1-5 หรือช่วงความถี่ต่อไปนี้

สเกลที่ 1 แสดงสัญญาณที่มีความถี่ในช่วง 50-100 kHz

สเกลที่ 2 แสดงสัญญาณที่มีความถี่ในช่วง 25-50 kHz

สเกลที่ 3 แสดงสัญญาณที่มีความถี่ในช่วง 12.5-25 kHz

สเกลที่ 4 แสดงสัญญาณที่มีความถี่ในช่วง 6.25-12.5 kHz

สเกลที่ 5 แสดงสัญญาณที่มีความถี่ในช่วง 3.125-6.25 kHz

และผลการวิเคราะห์ที่ได้ก็นำมาประมวลผลเพื่อใช้ในการตรวจจับฟอลต์ที่เกิดขึ้นภายในขดลวดหม้อแปลงไฟฟ้ากำลัง

3. รูปแบบการวิเคราะห์เพื่อตัดสินใจในการตรวจจับฟอลต์ที่เกิดขึ้นภายในขดลวดหม้อแปลงไฟฟ้ากำลังนั้นทำได้โดยเปรียบเทียบการเปลี่ยนแปลงของสัมประสิทธิ์การแปลงเวฟเล็ตแบบเต็มหน่วยกระแสผลต่างในแต่ละเฟสระหว่างก่อนและหลังเกิดฟอลต์ (ในช่วง  $\frac{1}{4}$  ไซเคิลหลังจากเกิด

ฟอลต์) โดยเป็นการเปรียบเทียบในสเกลที่ 1-5 และนำข้อมูลขององค์ประกอบความถี่สูงในสเกลแรกที่สามารถตรวจจับฟอลต์ได้ นำไปเป็นข้อมูลอินพุตให้กับโครงข่ายประสาทเทียมต่อไป เพื่อนำไปวิเคราะห์ในการระบุตำแหน่งขดลวดและประเภทฟอลต์ต่อไป

4. รูปแบบการวิเคราะห์ด้วยโครงข่ายประสาทเทียมอาศัยค่าสูงสุดของสัมประสิทธิ์การแปลงเวฟเล็ดแบบเต็มหน่วยในสเกลแรกที่ตรวจจับฟอลต์ได้ของกระแสผลต่างในเฟส A, B, C และองค์ประกอบลำดับศูนย์ในช่วง  $\frac{1}{4}$  ไซเคิลหลังเกิดฟอลต์ ตามลำดับ ซึ่งจะถูกนำมาเป็นข้อมูลอินพุตสำหรับฝึกสอนให้กับโครงข่ายประสาทเทียม ในขณะที่ตัวแปรเอาต์พุตมีค่าสัมพันธ์กับตำแหน่งฟอลต์และสัมพันธ์กับเฟส (A, B, C) และกราวด์ (G) หรือชนิดฟอลต์ที่เกิดขึ้น เพื่อใช้สำหรับตัดสินใจในการระบุตำแหน่งและประเภทฟอลต์ที่เกิดขึ้นภายในขดลวดหม้อแปลงไฟฟ้ากำลัง ตามลำดับ


5. การฝึกสอนโครงข่ายประสาทเทียม เป็นการป้อนชุดอินพุตให้โครงข่ายและพยายามปรับค่าถ่วงน้ำหนักทุกๆ จุดให้สอดคล้องกับอินพุตหลายๆ แบบ เพื่อให้ได้เอาต์พุตเป้าหมายตามที่ต้องการ ในวิทยานิพนธ์ฉบับนี้ได้ทำการฝึกสอนโครงข่ายประสาทเทียมโดยแบ่งออกเป็น 2 ส่วนคือการฝึกสอนเพื่อระบุตำแหน่งขดลวดที่เกิดฟอลต์และฝึกสอนอีกส่วนเพื่อระบุประเภทของฟอลต์ภายในขดลวดหม้อแปลงไฟฟ้ากำลัง หลังจากฝึกสอนโครงข่ายประสาทเทียม จะนำค่าถ่วงน้ำหนักและค่าไบแอสที่ทำให้โครงข่ายประสาทเทียมมีประสิทธิภาพสูงที่สุดมาทดสอบกับกรณีศึกษาจำนวน 864 ตัวอย่างดังแสดงในตารางที่ 8.1 โดยให้เพียงเฉพาะค่าอินพุต ไม่มีค่าเอาต์พุตที่ต้องการในขณะเดียวกันได้ การฝึกสอนโครงข่ายประสาทเทียมตามวิธีปกติก็นำมาเปรียบเทียบกับขั้นตอนที่ได้นำเสนอ เพื่อให้เห็นว่า ขั้นตอนที่ได้นำเสนอมีประสิทธิภาพที่ดีกว่าและช่วยลดเวลาในการฝึกสอน ซึ่งสามารถสรุปผลการทดลองได้ดังต่อไปนี้

ตารางที่ 8.1 แสดงจำนวนข้อมูลสำหรับฝึกสอนโครงข่ายประสาทเทียม


จำนวนชุดข้อมูล	ระบุประเภทฟอลต์ (Fault Type)	ระบุตำแหน่งขดลวด ลัดวงจรระหว่างรอบ (Interturn fault)		ระบุตำแหน่งขดลวด ลัดวงจรลงดิน (Winding to ground fault)	
		HV	LV	HV	LV
ฝึกสอน (Training)	1620	648	648	216	216
ตรวจสอบ (Validation)	864	324	324	108	108
กรณีศึกษา (Case Studies)	864	324	324	108	108

### 5.1 การระบุตำแหน่งขดลวดที่เกิดฟอลต์

ผลการระบุตำแหน่งขดลวดที่เกิดฟอลต์ด้วยวิธีที่ 1 มีค่าเฉลี่ยความคลาดเคลื่อนอยู่ในช่วง 0-0.028 % ของความยาวขดลวด โดยที่การแปลงเวฟสี่ตร่วมกับโครงข่ายประสาทเทียมตามวิธีที่ 2 จะมีค่าความคลาดเคลื่อนเฉลี่ยมากกว่าวิธีที่ 1 ยกเว้นเมื่อเกิดฟอลต์กรณีขดลวดลัดวงจรลงดินทางด้านแรงดันต่ำ ดังแสดงในรูปที่ 8.1 และเมื่อเปรียบเทียบค่าความคลาดเคลื่อนเฉลี่ยในการหาตำแหน่งฟอลต์ตามรูปที่ 8.1 และ 8.2 พบว่า การแปลงเวฟสี่ตร่วมกับโครงข่ายประสาทเทียมตามวิธีที่ 1 ให้ผลการวิเคราะห์ที่ดีกว่า




รูปที่ 8.1 แสดงค่าเฉลี่ยความคลาดเคลื่อนของการระบุตำแหน่งฟอลต์กรณีขดลวดลัดวงจรลงดิน



รูปที่ 8.2 แสดงค่าเฉลี่ยความคลาดเคลื่อนของการระบุตำแหน่งฟอลต์กรณีขดลวดลัดวงจรระหว่างรอบ

## 5.2 การระบุประเภทของฟอลต์

จากรูปที่ 8.3 เมื่อพิจารณาผลการระบุประเภทของฟอลต์ พบว่าการแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมตามวิธีที่ 1 ให้ความถูกต้องมากกว่า 95% ทุกประเภทฟอลต์ ในขณะที่การแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมตามวิธีที่ 2 สามารถระบุประเภทฟอลต์มากกว่า 95% ยกเว้นฟอลต์กรณีขลวดลัดวงจรลงดินทางด้านแรงดันสูงจะค่าเฉลี่ยความถูกต้องสูงกว่า 93%



รูปที่ 8.3 แสดงค่าเฉลี่ยการระบุประเภทฟอลต์แต่ละประเภท

เมื่อพิจารณาจากภาพรวมของการประยุกต์ใช้การแปลงเวฟเล็ตแบบเต็มหน่วย (DWT) ร่วมกับโครงข่ายประสาทเทียม เพื่อวิเคราะห์เปลี่ยนแปลงขององค์ประกอบความถี่สูงที่เกิดขึ้นในสัญญาณฟอลต์ โดยใช้ช่วงของข้อมูลในช่วง  $\frac{1}{4}$  ไซเคิล ผลการศึกษาที่ได้แสดงให้เห็นว่า องค์ประกอบความถี่สูงนั้นสามารถให้ข้อมูลที่สำคัญเกี่ยวกับสัญญาณฟอลต์ได้อย่างถูกต้องและลดจำนวนข้อมูลที่ใช้สำหรับวิเคราะห์ ดังนั้น วิธีที่นำเสนอนี้สามารถนำไปประยุกต์ใช้สำหรับการพัฒนารูปแบบการวิเคราะห์สัญญาณที่ใช้กับระบบป้องกันหม้อแปลงไฟฟ้ากำลังเช่น อุปกรณ์รีเลย์ ซึ่งรูปแบบของวิธีการที่นำเสนอนี้ยังสอดคล้องกับแนวโน้มของเทคโนโลยีที่กำลังดำเนินการอยู่ในปัจจุบันได้ นอกจากนี้ยังสามารถนำการแปลงเวฟเล็ตร่วมกับโครงข่ายประสาทเทียมไปประยุกต์ใช้ในทางวิศวกรรมไฟฟ้ากำลังได้อีกหลายอย่างด้วยกัน เช่น การวิเคราะห์สัญญาณฟอลต์ในสายส่งแบบโครงข่าย และวิเคราะห์และแยกความแตกต่างระหว่างสัญญาณกระแสอินรัชกับสัญญาณ

พอลต์ในหม้อแปลงเมื่อเกิดการลัดวงจรภายใน เป็นต้น ซึ่งเป็นการขยายขอบเขตของงานวิจัยและพัฒนาเทคโนโลยีทางด้านไฟฟ้ากำลังให้ดียิ่งขึ้น

## 6. สิ่งที่ควรได้รับการพัฒนาต่อไป

6.1 พัฒนารูปแบบการตรวจจับพอลต์ในกรณีเกิดซิมพาเทติก (Sympathetic) ซึ่งอาจจะส่งผลต่อการวินิจฉัยสัญญาณพอลต์ โดยพิจารณาลักษณะของสัมประสิทธิ์ความถี่สูงที่เกิดขึ้น เพื่อให้สามารถตรวจจับการเปลี่ยนแปลงได้มีประสิทธิภาพสูงมากยิ่งขึ้น

6.2 เนื่องจากรูปแบบของการดำเนินงานของวิทยานิพนธ์นี้เป็นการศึกษาลักษณะของพอลต์ที่เกิดขึ้นภายในขดลวดหม้อแปลงไฟฟ้ากำลัง โดย ไม่มีการพิจารณาผลกระทบจากสัญญาณรบกวนใดๆ เพื่อให้ง่ายต่อการศึกษาในเบื้องต้น แต่อย่างไรก็ดี ในทางปฏิบัติแล้ว มีสัญญาณรบกวนต่างๆ ที่เกิดขึ้นมากมาย ซึ่งทั้งหมดนี้ได้ทำให้มีการเปลี่ยนแปลงขององค์ประกอบความถี่สูงเช่นเดียวกับรูปแบบของสัญญาณพอลต์ จึงจำเป็นที่ต้องมีการศึกษาหาแนวทางใหม่เพิ่มเติมเพื่อให้ครอบคลุมกรณีต่างเพิ่มมากขึ้น

6.3 รูปแบบของวิธีที่ได้นำเสนอไม่ว่าจะเป็นการวิเคราะห์ด้วยการแปลงเวฟเล็ต การนำค่าองค์ประกอบลำดับศูนย์ (Zero sequence) มาใช้งานหรือการเลือกตัวแปรอินพุทของโครงข่ายประสาทเทียมอาจจะไม่ใช่รูปแบบที่ดีที่สุด แต่สิ่งที่จะต้องนำเสนอเป็นเพียงอีกหนึ่งแนวคิดที่สามารถนำมาใช้วิเคราะห์สัญญาณพอลต์แล้วให้ผลการทดลองตามที่ต้องการ ดังนั้น จึงควรพัฒนาการวินิจฉัยสถานะผิดปกติให้มีความเหมาะสม

6.4 พัฒนาขั้นตอนการฝึกสอนให้มีความรวดเร็วขึ้น เนื่องจากเวลาที่ใช้ในการฝึกสอนเป็นข้อด้อยของโครงข่ายประสาทเทียม ถึงแม้ว่าโครงข่ายประสาทเทียมที่ผ่านการฝึกสอนแล้วจะใช้เวลาในการคำนวณหาคำตอบน้อยมากก็ตาม

6.5 ปรับปรุงโครงข่ายประสาทเทียมให้สามารถระบุตำแหน่งขดลวดที่เกิดพอลต์ภายในหม้อแปลงไฟฟ้ากำลัง โดยให้มีความแม่นยำมากขึ้น

6.6 พัฒนาตัวแปรอินพุทให้มีความเหมาะสมและจำนวนข้อมูลที่ใช้ในการฝึกสอนให้มีจำนวนน้อยลง แต่ความถูกต้องไม่ลดลง เนื่องจากเมื่อพิจารณานำไปประยุกต์ใช้งานจะพบว่า การต่อขดลวดหม้อแปลงจะมีลักษณะการต่อขดลวดที่หลากหลาย ทำให้การวินิจฉัยสัญญาณพอลต์มีความยุ่งยากมากขึ้น จึงต้องใช้ตัวแปรอินพุทที่พิจารณาและข้อมูลฝึกสอนเป็นจำนวนมาก ทำให้ต้องใช้เวลาในการฝึกสอนมากตามไปด้วย

## เอกสารอ้างอิง

- [1] S. H. Horowitz and A. G. Phadke. **Power system relaying**. John Wiley & Sons, Inc. 1992.
- [2] J. Lewis Blackburn. **Protective relaying : principles and applications**. Second Edition. Marcel Dekker, Inc. 1998.
- [3] Z. Q. Bo, F. Jiang, Z. Chen, X. Z. Dong, G. Weller, M.A. Redfern, “**Transient based protection for power transmission systems.**” IEEE Power Engineering Society Winter Meeting, vol. 3, 2000, pp. 1832 –1837.
- [4] P. F. Ribeiro. “Wavelet Transform: An Advanced Tool for Analyzing Non-Stationary Harmonic Distortions in Power Systems.” IEEE ICHPS VI. Bologna, Italy, September 1994, pp. 365-369.
- [5] S. Santoso, E.J. Powers, W.M. Grady and P. Hofmann. “Power Quality Assessment Via Wavelet Transform Analysis.” IEEE Transaction on Power Delivery, vol. 11, no. 2, April 1996, pp. 924-930.
- [6] H. F. Magnago and Ali Abur. “Fault Location Using Wavelets.” IEEE Transactions on Power Delivery, vol. 13, no. 4, October 1998, pp. 1475-1480.
- [7] Z. Yang, J.Z. Liu, D. Xinzhou, F. Jiang, Z.Q. Bo, N.F. Chin, “A new technique for power transformer protection using discrete dyadic wavelet transform.” Developments in Power System Protection, 2001, Seventh International Conference on (IEE), 9-12 April 2001, pp. 383 – 386.
- [8] O.A.S. Youssef, “A wavelet-based technique for discrimination between faults and magnetizing inrush currents in transformers.” IEEE Transactions on Power Delivery, vol. 18, no. 1, Jan 2003, pp. 170 – 176.
- [9] S. Y. Hon and W. Qin, “A wavelet-based method to discriminate between inrush current and internal fault.” Power System Technology, 2000. Proceedings. PowerCon 2000. International Conference on, vol. 2, 4-7 Dec. 2000, pp. 927 – 931.
- [10] ANSI/IEEE C37.91-1985. “**IEEE Guide for Protection Relay Applications to Power Transformers**” March 1985.

- [11] J. Driesen, T. V. Craenenbroeck, R. Reekmans and D. V. Dommelen. “**Analysing time-varying power system harmonics using wavelet transform.**” Proc. IEEE Instrumentation and Measurement Technology Conference, Quality Measurements : The Indispensable Bridge between Theory and Reality., vol. 1, June 1996. pp. 474 -479.
- [12] N. Lazzaroni, E. Ragaini. “**Gabor-like transforms for transient analysis in electrical systems.**” Proc. IEEE Instrumentation and Measurement Technology Conference, Quality Measurements: The Indispensable Bridge between Theory and Reality., vol. 2, June 1996. pp. 885 –890.
- [13] D. C. Robertson, O. I. Camps, J. S. Mayer and W. B. Gish. “**Wavelets and electromagnetic power system transients.**” IEEE Transactions on Power Delivery, vol. 11, no. 2, April 1996, pp. 1050–1058.
- [14] A. Cohen and J. Kovacevic. “Wavelet: The Mathematical Background.” Proc. IEEE. vol. 84, no. 4, April 1996. pp. 514-522.
- [15] พงษ์ศักดิ์ มากมีง. “การวิเคราะห์ฟอลต์ในสายส่งด้วยการแปลงเวฟเล็ต.” วิทยานิพนธ์วิศวกรรมศาสตรมหาบัณฑิต สาขาวิศวกรรมไฟฟ้า บัณฑิตวิทยาลัย, สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง. 2545.
- [16] อรรถพล เ่งพิทักษ์กุล. “การแปลงเวฟเล็ตและโครงข่ายประสาทเทียมสำหรับวิเคราะห์ฟอลต์ในสายส่ง.” วิทยานิพนธ์วิศวกรรมศาสตรมหาบัณฑิต สาขาวิศวกรรมไฟฟ้า บัณฑิตวิทยาลัย, สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง. 2547.
- [17] V. L. Pham and K. P. Wong. “**Wavelet-transform-based algorithm for harmonic analysis of power system waveforms.**” Proc. IEE Generation Transmission and Distribution., vol. 146, no. 3, May 1999, pp. 249 –254.
- [18] M. Misiti, Y. Misiti, G. Oppenheim and J. M. Poggi. **Wavelet Toolbox User’s Guide Version 2.1.** First Printing, MathWorks, Inc. March 1996.
- [19] วรรัตน์ ภัทรอมรกุล, รศ. ดร. มนัส สัจจวรศิลป์. **คู่มือการใช้ MATLAB ฉบับสมบูรณ์.** พิมพ์ครั้งที่ 1. สำนักพิมพ์ Info press, เมษายน 2543.
- [20] C. H. Kim and R. Aggarwal, “ Wavelet transforms in power systems: Part. I General introduction to the wavelet transform.” Proc. IEEE Power Engineering Journal. 2000. pp. 81-87.

- [21] S. Santoso, E. J. Powers and W. M. Grady. **“Power quality disturbance data compression using wavelet transform methods.”** IEEE Transaction on Power Delivery. vol. 12, no. 3, July 1997, pp. 1250-1257.
- [22] C. Sidney Burrus, Ramesh A. Gopinath and Haitao Guo. **Introduction to Wavelets and Wavelet Transforms.** New Jersey : Prentice-Hall, Inc. 1998.
- [23] N. S. D. Brito, B. A. Souza and F. A. C. Pires. **“Daubechies wavelets in quality of electrical power.”** Proc. IEEE /PES 8th International Conference on Harmonics and Quality of Power., vol. 1, 1998. pp. 511-515.
- [24] L. L. Lai, E. Vaseekar, H. Subasinghe, N. Rajkumar. **“Wavelet Transform and Neural Networks for Fault Location of a Teed-network.”** IEEE Power System Technology. 2000. pp. 807– 811.
- [25] Fausett Laurene. **Fundamentals of Neural Networks.** Englewood Cliffs, New Jersey : Prentice Hall International, Inc. 1994.
- [26] สมชาติ จีรวินาทร. **“Generalization of NNs” เอกสารคำสอนวิชา Neural Network Applications.** กรุงเทพฯ : ภาควิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง. 2546.
- [27] The Data and Analysis center for Software (DACS). **“Artificial Neural Networks Technology.”** [Online]. Available :   
<http://www.dacs.dtic.mil/techs/neural/neural.title.html>. 1992.
- [28] R. Aggarwal and Y. Song. **“Artificial Neural Networks in power system Part I General introduction to neural computing.”** POWR ENGINEERING JOURNAL, 1997. pp. 129-134.
- [29] Prof. Leslie Smith. **“Neural Network Frequently Asked Questions.”** [Online]. Available : <ftp://ftp.sas.com/pub/neural/FAQ.html>. 1996.
- [30] H. Demuth and M. Beale. **Neural Network Toolbox User’s Guide.** The Math Works, Inc. March 2001.
- [31] C. M. Bishop. **Neural Networks for Pattern Recognition.** Oxford : Oxford University Press. 1995.
- [32] B. D. Ripley. **Pattern Recognition and Neural Networks.** Cambridge : Cambridge University Press. 1996.

- [33] L. Prikler and H. Kr. Holdalen. **ATPdraw for Windows 3.1/95/NT version 1.0 User's Manual**. Release 1.0.1. Nov 1998.
- [34] D. Van. **Alternative Transient Program Rule Book**. U. Leuven EMTP Center. Belgium. 1991.
- [35] H. W. Dommel. **Electromagnetic Transients Program (EMTP) Theory Book**. University of British Columbia, Vancouver Canada. August 1986.
- [36] P. Bastard, P. Bertrand, M. Meunier, "A transformer model for winding fault studies." IEEE Transactions on Power Delivery, vol. 9, no. 2, April 1994, pp. 690 – 699.
- [37] Report Prepared by the Switching Transients Task Force of the IEEE Modeling and Analysis of System Transients Working Group, "Modeling Guidelines for Switching Transients,," pp. 12-13.
- [38] EGAT(1999). Switching and Transmission Line Diagram, EGAT Press.
- [39] ABB Thailand, Test report no. 56039.
- [40] IEEE Std 1159-1995. "Recommended practice for monitoring electric power quality." November 1995.
- [41] J. Arrillaga, N. R. Watson and S. Chen. **Power System Quality Assessment**. Singapore : John Wiley & Sons, Inc. 2000. pp. 120-130.
- [42] A. Ngaopitakkul, A.Kunakorn and I.Ngamroo, "Discrimination between External Short Circuits and Internal Faults in Transformer Windings using Discrete Wavelet Transforms," IEEE Industries Application Society Annual Conference 40<sup>th</sup> , Hongkong, October 2005.

ภาคผนวก ก.

**รายงานการทดสอบหม้อแปลงไฟฟ้ากำลัง (Test Report )**

**ขนาด 50 MVA Serial No. 56039**

# ABB

## 3 PHASE TRANSFORMER

50 MVA

115.0/23.0 KV.

251.02/1255.11 A

YNyn0

50 Hz

ONAN

SERIAL No. : 56039

CUSTOMER : EGAT

PERFORMED AND APPROVED TESTS :  
ROUTINE TESTS

APPLIED STANDARDS :  
IEC-76

I hereby certify this is a true report based on factory tests made in accordance with the latest transformer test code.

*Jadsada Koonmee*

Test Department



TEST REPORT  
WINDING RESISTANCE

232

SERIAL No:56039

TAP CHANGER POSITION	RESISTANCE (mOhms) AT 30.40 °C			AVERAGE RESISTANCE AT 30.40 °C (mOhms/phase)	AVERAGE RESISTANCE AT 80.0 °C (mOhms/phase)
	H1-H0	H2-H0	H3-H0		
7L	366.737	367.703	367.082	367.174	435.924
6L	355.377	360.319	359.736	359.811	427.182
5L	352.734	353.725	353.115	353.191	419.323
4L	345.381	346.305	345.708	345.798	410.545
3L	338.072	338.878	338.294	338.415	401.780
2L	330.694	331.505	330.944	331.048	393.033
1L	323.366	324.138	323.540	323.681	384.288
N	315.933	316.711	316.217	316.287	375.509
1R	308.599	309.354	308.828	308.927	366.771
2R	300.309	301.530	300.623	300.821	357.146
3R	307.931	308.880	308.216	308.342	366.076
4R	315.294	316.259	315.733	315.762	374.885
5R	321.984	322.900	322.428	322.437	382.811
6R	329.429	330.254	329.850	329.844	391.605
7R	336.792	337.528	337.116	337.145	400.273
8R	344.078	344.870	344.403	344.450	408.945
9R	351.485	352.286	351.751	351.841	417.719
10R	358.784	359.547	359.079	359.137	426.382

X1 - X0	X2 -X0	X3 -X0
---------	--------	--------

0                      9.464                      9.662                      9.520                      9.548                      11.336



# TEST REPORT

## VOLTAGE RATIO

233

SERIAL NO. 56039

TAP CHANGER POSITION		VOLTAGE (kV)		CALCULATED RATIO	MEASURED RATIO					
HV	LV	HV	LV		% ERROR					
					H1-H0 X1-X0	% ERROR	H2-H0 X2-X0	% ERROR	H3-H0 X3-X0	% ERROR
7L	-	127.075	23.0	5.525	5.531	0.11	5.530	0.09	5.532	0.13
6L	-	125.350	23.0	5.450	5.453	0.06	5.453	0.06	5.455	0.09
5L	-	123.625	23.0	5.375	5.385	0.19	5.384	0.17	5.386	0.20
4L	-	121.900	23.0	5.300	5.309	0.17	5.308	0.15	5.310	0.19
3L	-	120.175	23.0	5.225	5.232	0.13	5.232	0.13	5.233	0.15
2L	-	118.450	23.0	5.150	5.156	0.12	5.155	0.10	5.158	0.16
1L	-	116.725	23.0	5.075	5.080	0.10	5.079	0.08	5.081	0.12
N	-	115.000	23.0	5.000	5.002	0.04	5.002	0.04	5.004	0.08
1R	-	113.275	23.0	4.925	4.926	0.02	4.927	0.04	4.927	0.04
2R	-	111.550	23.0	4.850	4.849	-0.02	4.849	-0.02	4.850	0.00
3R	-	109.825	23.0	4.775	4.781	0.13	4.780	0.10	4.782	0.15
4R	-	108.100	23.0	4.700	4.704	0.09	4.704	0.09	4.705	0.11
5R	-	106.375	23.0	4.625	4.635	0.22	4.635	0.22	4.636	0.24
6R	-	104.650	23.0	4.550	4.559	0.20	4.559	0.20	4.560	0.22
7R	-	102.925	23.0	4.475	4.482	0.16	4.482	0.16	4.483	0.18
8R	-	101.200	23.0	4.400	4.406	0.14	4.406	0.14	4.407	0.16
9R	-	99.475	23.0	4.325	4.329	0.09	4.329	0.09	4.330	0.12
10R	-	97.750	23.0	4.250	4.253	0.07	4.252	0.05	4.254	0.09

Check of voltage vector relationship : YNyn0



# TEST REPORT

234

SERIAL No:56039

## NO LOAD LOSSES & EXCITATION CURRENT

### BEFORE IMPULSE TEST

RATED VOLTAGE : 23.000 kV  
 RATED CAPACITY : 50 MVA  
 TEST AT TAP POSITION : N  
 TEMP. AT NO LOAD LOSS MEASU. : 30.7 C  
 DIFFERENT BETWEEN TOP OIL AND BOTTOM OIL TEMP : < 5 C

VOLTAGE			CURRENT					LOSSES (kW)			
(%)	MEAN (kV) Ea	RMS. (kV) Er	MEASURED					GUARA. (%)	MEAS .Pm	CORR. @ 20 C. Pc	GUARA. @ 20 C
			X1 (A)	X2 (A)	X3 (A)	AVG.(A)	(%) 50 MVA base				
10	3.191	3.176	0.126	0.076	0.132	0.111	0.009		0.474	0.480	
20	4.599	4.579	0.163	0.101	0.175	0.146	0.012		0.961	0.972	
30	6.900	6.869	0.218	0.138	0.238	0.198	0.016		2.071	2.095	
40	9.202	9.163	0.262	0.172	0.290	0.241	0.019		3.505	3.544	
50	11.490	11.440	0.305	0.205	0.340	0.283	0.023		5.249	5.308	
60	13.800	13.740	0.351	0.241	0.391	0.328	0.026		7.354	7.435	
70	16.100	16.040	0.408	0.279	0.447	0.378	0.030		9.888	9.997	
80	18.410	18.340	0.489	0.327	0.520	0.445	0.035		13.000	13.141	
90	20.690	20.620	0.620	0.409	0.629	0.553	0.044		16.760	16.937	
100	23.000	22.970	1.031	0.733	1.002	0.922	0.073		22.180	22.364	24.000
110	25.320	25.730	5.400	4.554	5.271	5.075	0.404		34.930	34.609	



## TEST REPORT

SERIAL No:56039

## LOAD LOSSES AND IMPEDANCE

## 50 MVA

Temp. at resistance meas : 30.40 C  
 Temp. at loss meas : 30.50 C  
 Referent temperature : 80.0 C

TAP CHANGER POSITION		RATED VOLTAGE (kV)		RATED CURRENT (A)	MEASU. CURRENT (A)	MEAS. LOSSES (kW)	CORR LOSSES @ Irated (kW)	COPPER LOSSES @ 30.5 C (kW)	LOAD LOSSES @ 80 C (kW)	IMPEDANCE (%)	
WIN 1	WIN 2	HV	LV	(A)	(A)	(kW)	(kW)	(kW)	(kW)	MEASU. VOLTAGE (kV)	%Z 50 MVA BASED

7L	0	127.075	23.0	227.17	227.06	149.90	150.05	102.01	161.42	16.75	13.19
6L	0	125.350	23.0	230.30	230.36	149.80	149.71	102.41	161.47	16.40	13.08
5L	0	123.625	23.0	233.51	233.54	149.80	149.76	102.94	161.65	16.11	13.03
4L	0	121.900	23.0	236.81	236.73	149.40	149.50	103.34	161.45	15.75	12.93
3L	0	120.175	23.0	240.21	240.30	149.30	149.20	103.75	161.51	15.43	12.84
2L	0	118.450	23.0	243.71	243.82	149.10	148.97	104.15	161.48	15.10	12.74
1L	0	116.725	23.0	247.31	247.22	148.50	148.61	104.56	161.11	14.75	12.64
N	0	115.000	23.0	251.02	251.07	148.10	148.04	104.96	160.91	14.44	12.56
1R	0	113.275	23.0	251.02	251.10	143.60	143.51	103.56	156.64	13.91	12.46
2R	0	111.550	23.0	251.02	250.92	138.70	138.82	102.03	151.99	13.39	12.38
3R	0	109.825	23.0	251.02	251.11	138.40	138.31	103.45	152.22	12.95	12.34
4R	0	108.100	23.0	251.02	251.09	137.00	136.93	104.86	151.53	12.47	12.27
5R	0	106.375	23.0	251.02	250.96	135.50	135.57	106.08	150.68	12.05	12.25
6R	0	104.650	23.0	251.02	251.03	134.30	134.29	107.98	150.33	11.61	12.19
7R	0	102.925	23.0	251.02	250.91	132.90	133.02	109.36	149.62	11.18	12.14
8R	0	101.200	23.0	251.02	251.14	132.10	131.98	110.75	149.43	10.78	12.10
9R	0	99.475	23.0	251.02	251.00	130.90	130.93	112.14	148.89	10.38	12.06
10R	0	97.750	23.0	251.02	251.08	130.00	129.94	112.99	148.43	10.00	12.03



TEST REPORT  
ON-LOAD TAP-CHANGERS

SERIAL No:56039

TEST ON ON-LOAD TAP-CHANGERS

OPERATION TEST

The test perform with 100% of the rated auxiliary supply voltage (exception of item b).

- a) 8 complete operating cycles with transformer not energized ;
- b) 1 complete operating cycles with the transformer not energized, with 85 % of the rate auxiliary supply voltage ;
- c) 1 complete operating cycles with the transformer energized at rate voltage and frequency at no-load ;
- d) 10 tap-change operation with  $\pm 2$  steps on either side of the principal tapping with as far as possible the rate current of the transformer, with one winding short-circuit.

**Result :** No sign of abnormal function



TEST REPORT  
ZERO ZEQUENCE IMPEDANCE

237

SERIAL No:56039

REFERENCE POWER 50 MVA

CONNECTION	TAP POS.	VOLTAGE (kV)	CURRENT (amps)	WATT (kW)	IMPEDANCE (ohms/ph)	%
H1H2H3-H0 (SHORT LV SIDE) TEMP 34.19 C.	7L	3.696	200.0	379.0	55.440	9.91
	N	3.224	200.2	345.0	48.312	6.09
	2R	3.116	200.2	337.0	46.693	6.07
	10R	2.763	200.1	309.0	41.424	6.14
H1H2H3-H0 (OPEN LV SIDE) TEMP 34.36 C.	7L	5.179	200.0	485.0	77.685	13.89
	N	4.399	200.0	432.0	65.985	8.31
	2R	4.200	199.9	418.0	63.032	8.19
	10R	3.551	199.9	371.0	53.292	7.90
X1X2X3 - X0 (OPEN HV SIDE) TEMP 33.87 C.	N	1.993	200.3	221.0	29.850	4.42









Er = Rated phase-to-neutral voltage of excited winding

Ir = Rated current per phase of excited windings

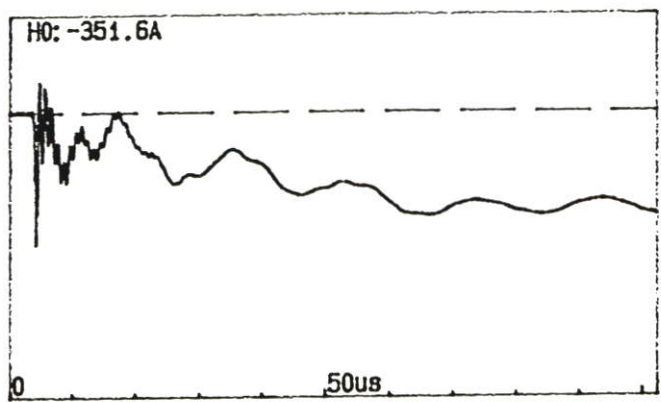







E = Measured excitation voltage

I = Measured total input current flowing in the three parallel-connected phases

$$Z_0 (\%) = 300 * ((E/Er) * (Ir/I))$$



TPL/PICHAJ C. 7  
1 JUL 97



TPL/PICHAU C.  
1 JUL 97













ABB TRANSFORMERS LIMITED

TPL-97-07-01



Page:

S.nbr: 56039



No: 36 Lightning impulse 60%



No: 37 Lightning impulse 100%









No: 38 Lightning impulse 100%











TPL/PICHA1 C.

1 JUL 97











TPL/PICHAU C.  
1 JUL. 97











TPL/PICHA C.

1 JUL 97



TPL/PICAM C 13  
1 JUL 97





# TEST REPORT

## APPLIED VOLTAGE TEST

246

SERIAL No:56039

### Applied voltage test

Frequency : 50 Hz

Tested system	Ground system	U / kV	Time / s
HV,N	LV , N , TV	34	60
LV , N	HV , N , TV	34	60
TV	HV , N , LV , N	34	60

**Result****Withstood**



# TEST REPORT

247

SERIAL No:56039

## INDUCED VOLTAGE TEST AND PD MEASUREMENT

INDUCED VOLTAGE TEST ( PARTIAL DISCHARGE MEASUREMENT )

TEST METHOD : ERA METHOD ( BAND 3 : 40-400 kHz )

THREE-PHASE TEST AT 200 Hz, NEUTRAL H0X0 GROUNDED. TEST IN POSITION 4L

ENHANCED VOLTAGE : ON H1H2H3; 120 kV , ON X1X2X3; 22.64 kV

ONE HOUR VOLTAGE ; ON H1H2H3; 105 kV , ON X1X2X3; 19.80 kV

TESTED PHASE	H1		H2		H3		REMARK
CAL CHANEL	GAIN	pC	GAIN	pC	GAIN	pC	Amplifier setting , Fine 0
50 PC	40	50	40	50	40	48	
100 PC	40	99	40	99	40	96	
200 PC	40	187	40	187	40	181	
MEASUREMENT VOLTAGE ( kV )	pC		pC		pC		TIME DURATION
0	16		38		19		BACKGROUND
34.31	36		47		28		0 MIN.
34.31	27		41		26		5 MIN.
39.22	24		50		31		36 SEC.
34.31	30		44		35		0 MIN.
34.31	29		47		25		5 MIN.
34.31	36		47		30		10 MIN.
34.31	21		44		21		15 MIN.
34.31	19		40		21		20 MIN.
34.31	20		40		20		25 MIN.
34.31	18		39		20		30 MIN.
34.31	18		39		20		35 MIN.
34.31	18		39		20		40 MIN.
34.31	18		38		19		45 MIN.
34.31	20		39		22		50 MIN.
34.31	18		38		20		55 MIN.
34.31	18		38		20		60 MIN.
0	16		38		19		BACKGROUND



## TEST REPORT

SERIAL No:56039

NO LOAD LOSSES &amp; EXCITATION CURRENT

AFTER IMPULSE TEST

RATED VOLTAGE : 23.000 kV  
 RATED CAPACITY : 50 MVA  
 TEST AT TAP POSITION : N  
 TEMP. AT NO LOAD LOSS MEASU. : 32.8 C  
 DIFFERENT BETWEEN TOP OIL AND BOTTOM OIL TEMP. : < 5 C

VOLTAGE			CURRENT					LOSSES (kW)			
(%)	MEAN (kV) Ea	RMS. (kV) Er	MEASURED					GUARA. (%)	MEAS .Pm	CORR. @ 20 C. Pc	GUARA. @ 20 C
			X1 (A)	X2 (A)	X3 (A)	AVG.(A)	(%) 50 MVA base				
10	2.380	2.354	0.083	0.053	0.091	0.076	0.006	0.229	0.233		
20	4.599	4.574	0.137	0.089	0.153	0.126	0.010	0.828	0.839		
30	6.908	6.876	0.185	0.123	0.210	0.173	0.014	1.815	1.839		
40	9.205	9.163	0.230	0.156	0.264	0.217	0.017	3.164	3.204		
50	11.500	11.430	0.277	0.192	0.318	0.262	0.021	4.869	4.938		
60	13.790	13.720	0.329	0.229	0.374	0.311	0.025	7.012	7.102		
70	16.100	16.030	0.390	0.269	0.436	0.365	0.029	9.581	9.701		
80	18.410	18.330	0.470	0.316	0.509	0.432	0.034	12.660	12.816		
90	20.710	20.640	0.606	0.401	0.627	0.545	0.043	16.510	16.708		
100	23.000	22.970	1.013	0.729	1.013	0.918	0.073	21.940	22.153	24.000	
110	25.310	25.740	5.560	4.760	5.420	5.247	0.418	34.940	34.637		



TEST REPORT  
SINGLE PHASE IMPEDANCE

249

SERIAL No:56039

SINGLE PHASE IMPEDANCE

1) MEASURE VOLTAGE BETWEEN HV TO HV , AND SHORT CIRCUIT LV ( PHASE BY PHASE )

TAP POS.	CURRENT			VOLTAGE		
	H1-H0 ( amps )	H2-H0 ( amps )	H3-H0 ( amps )	H1-H0 ( volts )	H2-H0 ( volts )	H3-H0 ( volts )
7L	2.999	3.001	2.999	125.1	124.4	126.9
6L	3.000	3.000	3.001	120.9	120.2	122.6
5L	3.000	3.000	3.000	117.1	116.4	118.8
4L	3.001	3.001	2.999	113.0	112.5	114.6
3L	3.000	3.002	3.002	109.1	108.5	110.7
2L	3.002	2.999	3.000	105.2	104.6	106.7
1L	3.001	3.000	2.999	101.5	100.9	102.8
N	2.999	3.001	3.002	97.7	97.3	99.2
1R	3.002	3.000	3.002	94.3	93.8	95.6
2R	3.001	3.001	3.001	90.8	90.4	92.0
3R	3.001	2.999	2.999	87.8	87.4	89.6
4R	3.002	2.999	3.000	84.6	84.3	85.9
5R	3.002	3.001	2.999	81.9	81.6	83.1
6R	3.001	3.001	3.000	78.9	78.8	80.1
7R	3.002	3.000	3.001	76.0	75.8	77.2
8R	2.999	3.001	3.000	73.4	73.2	74.3
9R	3.002	2.999	3.000	70.6	70.5	71.6
10R	3.002	2.999	3.001	68.1	67.9	69.0

ABB - Asea Brown Boveri

97/07/02

date

Witness

Test leader

Page:

18



## TEST REPORT

SERIAL No:56039

## MEASUREMENTS OF INSULATION RESISTANCE

TIME	TEST CONNECTION AT 2.5 KV						
	HV/LV+TV+G	LV/HV+TV+G	TV/HV+LV+G	HV+LV/TV+G	HV+TV/LV+G	LV+TV/HV+G	HV+LV+TV+G
	MEGA OHM	MEGA OHM	MEGA OHM	MEGA OHM	MEGA OHM	MEGA OHM	MEGA OHM
1 min	1750	1500	2500	2000	1200	1550	1900
2 min	2500	2500	4300	2700	1900	2500	2700
3 min	3200	3300	5700	3000	2500	3200	3000
4 min	40000	4000	6800	3300	2800	3900	3400
5 min	4600	4700	7800	3600	3200	4500	3700
6 min	5000	5100	8500	3900	3700	5000	4000
7 min	5400	5500	9000	4000	3900	5500	4200
8 min	5800	5800	10000	4100	4100	5800	4500
9 min	6000	6100	11000	4300	4400	60000	4700
10 min	6100	6500	12000	4500	4600	6500	4900
PI	3.49	4.33	4.80	2.25	3.83	4.19	2.58

TIME	TEST CONNECTION AT 5 KV						
	HV/LV+TV+G	LV/HV+TV+G	TV/HV+LV+G	HV+LV/TV+G	HV+TV/LV+G	LV+TV/HV+G	HV+LV+TV+G
	MEGA OHM	MEGA OHM	MEGA OHM	MEGA OHM	MEGA OHM	MEGA OHM	MEGA OHM
1 min	1700	1950	2400	2200	1500	1800	2000
2 min	2400	2700	4300	2600	2000	2500	25000
3 min	2900	3200	5200	2800	2500	3000	2800
4 min	3300	3800	5600	3000	2700	3300	3000
5 min	3800	4100	5300	3200	2900	3800	3200
6 min	4100	4500	6900	3400	3100	4000	3500
7 min	4500	4900	7200	3600	3300	4200	3700
8 min	4700	5100	7500	3700	3500	4500	3900
9 min	5000	5200	8000	3800	3700	4700	4000
10 min	5000	5400	8100	3900	3800	4900	4000
PI	2.94	2.77	3.38	1.77	2.53	2.72	2.00

TEMP. 30 c.

HUMIDITY 64 %

ABB - Asea Brown Boveri

97/06/30

date

Witness

Test leader

Page:

19



# TEST REPORT

SERIAL No:56039

MEASUREMENTS OF INSULATION RESISTANCE  
OF CORE TO GROUND

AMBIENT TEMP. 30 C.

HUMIDITY 62 %

INSULATION RESISTANCE OF CORE TO GROUND 400 MOHM. AT 2.5 KV 1 MINUTE



## TEST REPORT

SERIAL No: 56039

## INSULATION DISSIPATION FACTOR TEST

After Dielectric Test

TERMINALS	CAPACITANCE ( PF )	DISSIPATION FACTOR	
		(%) AT 32.5 ° C	(%) AT 20 ° C
H/L+T+G	12491.62	0.318	0.240
L/H+T+G	21795.15	0.201	0.152
T/H+L+G	23320.32	0.246	0.186
H+L/T+G	17424.32	0.213	0.160
H+T/L+G	35600.40	0.225	0.169
L+T/H+G	24810.07	0.246	0.186
H+L+T/G	20171.59	0.274	0.207

H : high voltage side

L : low voltage side

T : tertiary voltage side

G : transformer tank to ground

The dissipation factor test used 10 kV source.

Fp 20 °C. = Fp 32.5 °C./K

K = 1.325



TEST REPORT  
VACUUM AND PRESSURE TEST

SERIAL No:56039

**VACUUM TEST ON TRANSFORMER TANK**

THE TRANSFORMER TANK WAS CARRIED OUT LESS THAN 10 mmHg FOR 30 MINUTES.  
THE DEFORMATION WAS CHECKED. THE RESULT WAS SATISFACTORY.

**PRESSURE AND LEAKAGE TEST ON TRANSFORMER TANK**

THE PRESSURE OF 1 kg/cm<sup>2</sup> WAS SUPPLIED FOR 30 MINUTES. THE LEAKAGE WAS CHECKED.  
THE RESULT WAS SATISFACTORY.

**PRESSURE AND LEAKAGE TEST ON ASSEMBLED TRANSFORMER**


THE PRESSURE OF 1 kg/cm<sup>2</sup> AT THE TANK BOTTOM WAS SUPPLIED FOR 12 HOURS.  
THE LEAKAGE WAS CHECKED. THE RESULT WAS SATISFACTORY.

## ภาคผนวก ข.

## โครงข่ายประสาทเทียมชนิดความน่าจะเป็นและโครงข่ายประสาทเทียมชนิดฐานรัศมี

ในปัจจุบันมีชนิดของโครงข่ายประสาทเทียมเป็นจำนวนมาก ด้วยเหตุที่มีโครงข่ายประสาทเทียมหลากหลายชนิดในปัจจุบัน ซึ่งนำไปใช้ในลักษณะงานที่แตกต่างกัน โครงข่ายประสาทเทียมชนิดความน่าจะเป็น (Probabilistic neural network : PNN) เป็นโครงข่ายประสาทเทียมที่มีโครงสร้างโดยใช้ความคิดจากทฤษฎีความน่าจะเป็นการแบ่งประเภท (Classical probability theory) เช่น การแบ่งประเภทของบายเซียน (Bayesian) และ ตัววิเคราะห์แบ่งประเภทสำหรับฟังก์ชันความหนาแน่นของความน่าจะเป็น (probability density functions : PDFs) เพื่อทำเป็นรูปแบบให้กับโครงข่ายประสาทเทียมสำหรับรูปแบบการแบ่งประเภท โครงข่ายประสาทเทียมชนิดความน่าจะเป็นถูกใช้อย่างประสบความสำเร็จเกี่ยวกับการแก้ปัญหาหลากหลายกลุ่มของปัญหาการแบ่งประเภท ถึงแม้ว่า โครงข่ายประสาทเทียมชนิดความน่าจะเป็นยังไม่เคยเปรียบเทียบกับโครงข่ายประสาทเทียมชนิดอื่น ถ้าโครงข่ายประสาทเทียมชนิดนี้ปฏิบัติตามคุณสมบัติ โครงข่ายประสาทเทียมชนิดความน่าจะเป็นอาจจะเป็นอีกหนึ่งทางเลือกสำหรับการระบุประเภทพอลต์ภายในหม้อแปลงไฟฟ้ากำลัง ในภาคผนวกได้แสดงผลสรุปการฝึกสอนในการเปรียบเทียบโครงข่ายประสาทเทียมทั้งหมด 3 ชนิดด้วยกันคือ โครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ ชนิดความน่าจะเป็นและชนิดฟังก์ชันฐานรัศมีสำหรับระบุประเภทพอลต์ที่เกิดขึ้นภายในหม้อแปลงไฟฟ้ากำลัง เพื่อแสดงให้เห็นว่า โครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับที่ได้เลือกใช้ในวิทยานิพนธ์ฉบับนี้ เป็นโครงข่ายประสาทเทียมที่เหมาะสมที่สุด

โครงสร้างของโครงข่ายประสาทเทียมชนิดความน่าจะเป็นประกอบด้วย 3 ชั้น ได้แก่ ชั้นอินพุต (Input layer), ชั้นฐานรัศมี (Radial basis layer) และชั้นคอมแพติทีฟ (Competitive layer) ดังแสดงในรูปที่ ข1



รูปที่ ข1 โครงข่ายประสาทเทียมชนิดความน่าจะเป็น [16, 30]


ตารางที่ ข1 แสดงค่าเอาต์พุตของ โครงข่ายประสาทเทียมชนิดความน่าจะเป็นสำหรับระบุประเภท  
พอลดี

ประเภทของพอลดี	เอาต์พุตของ โครงข่ายประสาทเทียม
พอลดีชนิดลวดเฟส A ลัดวงจรลงดินทางด้านแรงดันสูง (AGHV)	1
พอลดีชนิดลวดเฟส A ลัดวงจรลงดินทางด้านแรงดันต่ำ (AGLV)	2
พอลดีชนิดลวดเฟส B ลัดวงจรลงดินทางด้านแรงดันสูง (BGHV)	3
พอลดีชนิดลวดเฟส B ลัดวงจรลงดินทางด้านแรงดันต่ำ (BGLV)	4
พอลดีชนิดลวดเฟส C ลัดวงจรลงดินทางด้านแรงดันสูง (CGHV)	5
พอลดีชนิดลวดเฟส C ลัดวงจรลงดินทางด้านแรงดันต่ำ (CGLV)	6
พอลดีชนิดลวดเฟส A ลัดวงจรระหว่างรอบทางด้านแรงดันสูง (AHV)	7
พอลดีชนิดลวดเฟส A ลัดวงจรระหว่างรอบทางด้านแรงดันต่ำ (ALV)	8
พอลดีชนิดลวดเฟส B ลัดวงจรระหว่างรอบทางด้านแรงดันสูง (BHV)	9
พอลดีชนิดลวดเฟส B ลัดวงจรระหว่างรอบทางด้านแรงดันต่ำ (BLV)	10
พอลดีชนิดลวดเฟส C ลัดวงจรระหว่างรอบทางด้านแรงดันสูง (CHV)	11
พอลดีชนิดลวดเฟส C ลัดวงจรระหว่างรอบทางด้านแรงดันต่ำ (CLV)	12

โครงสร้างของโครงข่ายประสาทเทียมชนิดความน่าจะเป็นจะประกอบด้วย 4 อินพุตซึ่งเป็น  
กลุ่มตัวแปรอินพุตชนิดเดียวกับที่ใช้ในการระบุประเภทพอลดีโดยใช้โครงข่ายประสาทเทียมชนิด

แพร่ค่าย้อนกลับและ 1 เอคต์พุท ในขณะที่จำนวนนิวรอนในชั้นฐานรัศมีมีจำนวน 1620 นิวรอน ส่วนค่าเอาต์พุทของโครงข่ายประสาทเทียมมีค่าเช่นเดียวกับตารางที่ ข1

ระหว่างฝึกสอน โครงข่ายประสาทเทียมชนิดความน่าจะเป็นเริ่มต้นด้วยการสุ่มค่าถ่วงน้ำหนัก เริ่มต้นเพียงครั้งเดียวและเพิ่มค่ากระจายค่าคงที่ (Spread) ในชั้นฐานรัศมี ซึ่งสัมพันธ์กับค่าไบอัส ( $b = \frac{0.8326}{Spread}$ ) [30] โดยเริ่มต้นที่ 0.0001 และจะเพิ่มขึ้นครั้งละ 0.0001 เพื่อหาจำนวนชุดทดสอบที่แบ่งประเภทผิดพลาดน้อยที่สุด กระบวนการฝึกสอนจะทำซ้ำไปจนกระทั่งจำนวนชุดทดสอบที่แบ่งประเภทผิดพลาดมีค่าเท่ากับศูนย์ หรือค่ากระจายค่าคงที่มีค่าเท่ากับ 0.1 ขั้นตอนการฝึกสอนดังแสดงในรูปที่ ข2 และผลสรุปการฝึกสอนในตารางที่ ข2



รูปที่ ข2 ขั้นตอนการฝึกสอน โครงข่ายประสาทเทียมชนิดความน่าจะเป็น


ตารางที่ ข2 แสดงผลสรุปการฝึกสอน โครงข่ายประสาทเทียมชนิดความน่าจะเป็นสำหรับระบุ  
ประเภทโฟลต์

Spread	จำนวนชุดฝึกสอนที่ ผิดพลาด	จำนวนชุดตรวจสอบที่ ผิดพลาด	เวลาที่ใช้ในการฝึกสอนใน แต่ละรอบ (นาที)
0.0001	73	991	0.03
0.0002	86	404	0.04
0.0003	95	285	0.12
0.0004	109	267	0.18
0.0005	109	258	0.21
0.0006	109	258	0.24
0.0007	109	258	0.28
0.0008	109	258	0.32
0.0009	109	258	0.36
0.001	109	258	0.41
0.0011	109	258	0.46
0.0012	109	258	0.51
0.0013	109	258	0.55
0.0014	109	258	1
0.0015	109	258	1.04
0.0016	109	258	1.07
0.0017	109	258	1.13
0.0018	109	258	1.18
0.0019	109	258	1.21
0.002	109	258	1.25

จากตารางที่ ข2 จะสังเกตเห็นว่า จำนวนชุดตรวจสอบที่ผิดพลาดน้อยที่สุดอยู่ที่ 258 ณ ตำแหน่งค่า MAPE ที่ดีที่สุดของชุดตรวจสอบอยู่ที่ค่ากระจายค่าคงที่ (Spread) เป็น 0.0005 ในขณะที่ค่ากระจายค่าคงที่ (Spread) ตั้งแต่ 0.0006 จนถึง 0.1 จะมีจำนวนชุดตรวจสอบที่ผิดพลาดน้อยที่สุดเท่ากับ 258


โครงสร้างพื้นฐานของโครงข่ายประสาทเทียมชนิดฟังก์ชันฐานรัศมี (Radial basis function : RBF) ซึ่งได้แสดงในรูปที่ ข3 โครงสร้างของโครงข่ายประสาทเทียมชนิดฟังก์ชันฐานรัศมีจะเป็นจะ

ประกอบด้วย 4 อินพุตและ 1 เอาต์พุตซึ่งเป็นกลุ่มตัวแปรอินพุตชนิดเดียวกับที่ใช้ในการระบุประเภทฟอลต์โดยใช้โครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ ในชั้นซ่อนไม่สามารถกำหนดจำนวนนิวรอนเริ่มต้นได้ ซึ่งจำนวนนิวรอนในชั้นซ่อนจะถูกกำหนดด้วยกระบวนการเรียนรู้ OLS (Orthogonal Least Squares : OLS) [16ม 30] และฟังก์ชันกระตุ้นที่อยู่ในชั้นซ่อนจะใช้ชนิดฐานรัศมี (Radial basis) ส่วนชั้นเอาต์พุตจะใช้ฟังก์ชันกระตุ้นชนิดเชิงเส้น (Linear)



รูปที่ ข3 โครงข่ายประสาทเทียมชนิดฟังก์ชันฐานรัศมี [16, 30]

ระหว่างการฝึกสอนโครงข่ายประสาทเทียมชนิดฟังก์ชันฐานรัศมี, จะเริ่มต้นด้วยการสุ่มค่าถ่วงน้ำหนัก (Random initial weight) และเพิ่มค่ากระจายค่าคงที่ (Increase spread) ซึ่งจะสัมพันธ์กับค่าไบอัส ( $b = \frac{0.8326}{Spread}$ ) [16, 30] และ กำหนดค่าผิดพลาดเป้าหมายให้เท่ากับ 0.1 หนึ่งรอบการฝึกสอนกระบวนการเรียนรู้ OLS จำนวนนิวรอนในชั้นซ่อนจะถูกเพิ่มขึ้นเท่ากับจำนวนครั้งที่คำนวณค่าเปอร์เซ็นต์ผิดพลาดเฉลี่ยสัมบูรณ์ ขบวนการนี้จะทำซ้ำจนกระทั่งค่าผิดพลาดเป้าหมายถูกพบหรือจำนวนสูงสุดของนิวรอนในชั้นซ่อนถูกพบ (จะเท่ากับจำนวนชุดฝึกสอน) การปรับเปลี่ยนค่าถ่วงน้ำหนักค่ากระจายค่าคงที่โดยเริ่มต้นที่ 0.0001 เพื่อคำนวณหาค่าเปอร์เซ็นต์ผิดพลาดเฉลี่ยสัมบูรณ์ (MAPE) ของชุดข้อมูลทดสอบที่ดีที่สุด จากนั้นทำการเพิ่มค่ากระจายค่าคงที่ในชั้นซ่อนที่ 1 เพิ่มขึ้นครั้งละ 0.0001 จนถึง 0.0005 (เพื่อหาโครงสร้างของโครงข่ายประสาทเทียมที่มีประสิทธิภาพสูงสุด) หรือจนกว่าค่าเปอร์เซ็นต์ผิดพลาดเฉลี่ยสัมบูรณ์ เท่ากับ 0 แล้วหยุดการฝึกสอน ขั้นตอนการฝึกสอนดังแสดงในรูปที่ ข4 และผลสรุปการฝึกสอนในตารางที่ ข3



รูปที่ ข4 ขั้นตอนการฝึกสอนโครงข่ายประสาทเทียมชนิดฟังก์ชันฐานรัศมี

ตารางที่ ข3 แสดงผลสรุปการฝึกสอนโครงข่ายประสาทเทียมชนิดฟังก์ชันฐานรัศมีสำหรับระบุประเภทฟอลต์

ค่ากระจายค่าคงที่ (Spread)	0.0001	0.0002	0.0003	0.0004	0.0005
MAPE ของ ชุดทดสอบ	23.895	23.895	23.895	23.895	23.895
เวลาที่ใช้ในแต่ละ รอบ (นาที)	59.24	60.36	60.28	61.46	60.56

หลังจากฝึกสอนโครงข่ายประสาทเทียมชนิดความน่าจะเป็นและฟังก์ชันฐานรัศมีเสร็จสิ้นจากนั้นได้ทำการเปรียบเทียบกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับทั้งสองวิธีที่ได้นำเสนอ ผลสรุปได้แสดงในตารางที่ ข4

ตารางที่ ข4 แสดงการเปรียบเทียบระหว่างโครงข่ายประสาทเทียมสองชนิดสำหรับระบุประเภทฟอลต์

ระบุประเภทฟอลต์	จำนวนข้อมูล กรณีศึกษา	ค่าเฉลี่ยความถูกต้อง (%)			
		ชนิดฟังก์ชัน ฐานรัศมี	ชนิดความ น่าจะเป็น	ชนิดแพร่ค่าย้อนกลับ	
				วิธีที่ 1	วิธีที่ 2
ขดลวดลัดวงจรลงดิน ทางด้านแรงดันสูง	108	0%	99.07%	95.36%	92.58%
ขดลวดลัดวงจรลงดิน ทางด้านแรงดันต่ำ	108	16.67%	100%	100%	100%
ขดลวด ลัดวงจรระหว่างรอบ ทางด้านแรงดันสูง	324	0%	90.1%	98.66%	97.33%
ขดลวด ลัดวงจรระหว่างรอบ ทางด้านแรงดันต่ำ	324	61.42%	100%	100%	100%
ค่าเฉลี่ย	-	25.11%	97.29%	98.5%	97.47%

จากตารางที่ ข4 จะเห็นได้ว่า คำตอบที่ได้จากโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับจะมากกว่าโครงข่ายประสาทเทียมชนิดความน่าจะเป็น ยกเว้นกรณีขดลวดลัดวงจรลงดินทางด้านแรงดันสูง ทั้งนี้เนื่องจากการแบ่งประเภทฟอลต์ของโครงข่ายประสาทเทียมชนิดความน่าจะเป็นนั้น เกิดความผิดพลาดในการแบ่งประเภทระหว่างขดลวดลัดวงจรลงดินทางด้านแรงดันสูงกับขดลวดลัดวงจรระหว่างรอบทางด้านแรงดันสูง จึงทำให้ค่าความถูกต้องเฉลี่ยในกรณีขดลวดลัดวงจรระหว่างรอบทางด้านแรงดันสูงมีค่าต่ำที่สุดเมื่อวิเคราะห์ด้วยโครงข่ายประสาทเทียมชนิดความน่าจะเป็น ส่วนโครงข่ายประสาทเทียมชนิดฟังก์ชันฐานรัศมีนั้นมีความถูกต้องน้อยที่สุด ทั้งนี้เนื่องจาก ข้อมูลที่ใช้ในการฝึกสอนและทดสอบโครงข่ายประสาทเทียมชนิดฟังก์ชันฐานรัศมีมีจำนวนมาก (จำนวนสูงสุดของนิเวรอนในชั้นซ่อนจะเท่ากับจำนวนข้อมูลฝึกสอน) จึงทำให้ใช้เวลาในการฝึกสอนในแต่ละรอบนานขึ้น ดังนั้น การเพิ่มค่ากระจายค่าคงที่ (Increase spread) เพื่อหาโครงสร้างของโครงข่ายประสาทเทียมชนิดฟังก์ชันฐานรัศมีที่มีประสิทธิภาพดีที่สุดไม่สามารถได้ทำการเพิ่มค่ากระจายค่าคงที่ให้กระจายเท่าที่ควร จึงทำให้ได้โครงสร้างของโครงข่ายประสาทเทียมชนิดฟังก์ชันฐานรัศมีเป็น โครงสร้างที่ให้ประสิทธิภาพต่ำกว่าที่ควรจะเป็นรวมไปถึงค่าเปอร์เซ็นต์ผิดพลาดเฉลี่ยสมบูรณ์ (MAPE) ที่ได้รับมีค่าสูง กล่าวโดยสรุป โครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับทั้งสองวิธีให้ค่าเฉลี่ยความถูกต้องมากกว่าโครงข่ายประสาทเทียมชนิดความน่าจะเป็นและชนิดฟังก์ชันฐานรัศมี อย่างไรก็ตาม งานวิจัยนี้มุ่งที่ความถูกต้องเป็นหลักสำคัญ ไม่ได้มุ่งที่เวลาในการฝึกสอนเป็นหลัก เนื่องจากการแบ่งประเภทฟอลต์ที่ถูกต้องนำไปสู่การบำรุงรักษาและซ่อมแซมที่ถูกต้องด้วย ส่วนการระบุตำแหน่งขดลวดที่เกิดการลัดวงจรนั้น เป็นงานลักษณะพยากรณ์หรือทำนายตำแหน่ง ดังนั้นจึงไม่สามารถนำโครงข่ายประสาทเทียมชนิดความน่าจะเป็นมาเปรียบเทียบกับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับได้

## ภาคผนวก ค.

# การเลือกโครงสร้างและฟังก์ชันกระตุ้นสำหรับโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับ

ในปัจจุบันมีชนิดของโครงข่ายประสาทเทียมเป็นจำนวนมาก บางโครงข่ายประสาทเทียมเป็นแบบจำลองของชีวโครงข่ายประสาทและบางชนิดก็ไม่เป็น อย่างไรก็ตาม โครงข่ายประสาทเทียมอาจพิจารณาให้เป็นขั้นตอนวิธีทางคณิตศาสตร์ (Mathematical algorithm) ของโครงข่ายประสาทชีวภาพ โดยตั้งบนพื้นฐานองค์ประกอบทั้งสามส่วน นั่นคือ

1. เป็นรูปแบบการเชื่อมโยงระหว่างนิวรอนเรียกส่วนนี้ว่า โครงสร้างของโครงข่ายประสาทเทียม
2. เป็นการกำหนดค่าของการเชื่อมโยงเรียกส่วนนี้ว่า ขั้นตอนวิธีการฝึกสอนหรือการเรียนรู้
3. เกี่ยวกับการกำหนดข้อมูลเอาต์พุตโดยฟังก์ชันกระตุ้น (Activation function)

การประยุกต์ใช้งานจึงควรคำนึงถึงองค์ประกอบทั้ง 3 ส่วนนี้เป็นสำคัญและประยุกต์ให้เหมาะสม เนื่องจากการฝึกสอนโครงข่ายประสาทเทียมชนิดแพร่ค่าย้อนกลับในวิทยานิพนธ์จะใช้ Neural Network Toolbox [30] ของโปรแกรม MATLAB ดังนั้น ผู้ฝึกสอนจำเป็นต้องกำหนดองค์ประกอบเอง โดยในวิทยานิพนธ์ได้กำหนดจำนวนครั้งในการสุ่มค่าเริ่มต้นของค่าถ่วงน้ำหนักเพียงครั้งเดียวและใช้ Levenberg-Marquardt Algorithm สำหรับฝึกสอนเพื่อปรับเปลี่ยนค่าถ่วงน้ำหนักและค่าไบแอส ดังที่ได้กล่าวมา ในส่วนของการพิจารณาเลือกโครงสร้างของโครงข่ายประสาทเทียมและฟังก์ชันกระตุ้นนั้น ผู้วิจัยเองได้ทำการปรับเปลี่ยนโครงสร้างและฟังก์ชันกระตุ้นหลายวิธีเพื่อเลือกโครงสร้างและฟังก์ชันกระตุ้นที่ดีที่สุด ในภาคผนวกได้แสดงผลสรุปการฝึกสอนในการปรับเปลี่ยนโครงสร้างและฟังก์ชันกระตุ้นสำหรับระบุตำแหน่งกรณีขาดดวงจรลงดิน รวมถึงไปถึงการกำหนดจำนวนครั้งที่สุ่มค่าเริ่มต้นของค่าถ่วงน้ำหนักและค่าไบแอส เพื่อแสดงให้เห็นว่าโครงสร้างของโครงข่ายประสาทเทียมและฟังก์ชันกระตุ้นและจำนวนครั้งที่สุ่มค่าเริ่มต้นที่ได้เลือกใช้ ในวิทยานิพนธ์ฉบับนี้ มีประสิทธิภาพดีที่สุด จึงได้เลือกนำมาใช้ในงานวิจัย โดยขั้นตอนการปรับเปลี่ยนโครงสร้างของโครงข่ายประสาทเทียมได้แบ่งออกมาเป็น 3 กรณีคือ

1. จำนวนนิวรอนในชั้นซ่อนที่ 1 และ 2 แตกต่างกันอยู่ 1 นิวรอน
2. จำนวนนิวรอนในชั้นซ่อนที่ 1 และ 2 แตกต่างกันอยู่ 2 นิวรอน
3. จำนวนนิวรอนในชั้นซ่อนที่ 1 และ 2 แตกต่างกันอยู่ 3 นิวรอน

สำหรับข้อมูลอินพุทจะประกอบด้วย 4 อินพุทโดยใช้ค่าสูงสุดของสัมประสิทธิ์จากการแปลงเวฟเล็ตในสเกลแรกที่เราตรวจสอบได้ของกระแสผลต่างจากเฟส A, B, C และองค์ประกอบลำดับศูนย์ในช่วง  $\frac{1}{4}$  ไซเคิลหลังเกิดฟอลต์ตามลำดับ และข้อมูลเอาต์พุทประกอบด้วย 1 เอาต์พุทซึ่งมีค่าเอาต์พุทของโครงข่ายประสาทเทียมอยู่ระหว่าง 0.1 ถึง 0.9 โดยจะมีค่าสัมพันธ์กับตำแหน่งขดลวดที่เกิดการลัดวงจรลงดินทางด้านแรงดันสูง สำหรับขั้นตอนการฝึกสอนจะมีวิธีการฝึกสอนเหมือนกับหัวข้อ 6.2.1.1 ผลสรุปที่ได้จากการฝึกสอนจะแสดงในตารางที่ ก1

ตารางที่ ก1 แสดงผลสรุปการฝึกสอนในการปรับเปลี่ยนโครงสร้างโครงข่ายประสาทเทียมสำหรับระบบตำแหน่งกรณีขดลวดลัดวงจรลงดิน

จำนวนนิวรอนในชั้นซ่อนที่ 1-2	4-3	5-4	6-5	7-6	8-7	9-8
MAPE ชุดตรวจสอบ(%)	0.86	0.79	0.74	0.75	<b>0.7</b>	0.73
เวลาที่ใช้ในการฝึกสอนในแต่ละรอบ (นาท)	3.41	4.25	5.16	6.35	<b>7.46</b>	10.46
จำนวนนิวรอนในชั้นซ่อนที่ 1-2	4-2	5-3	6-4	7-5	8-6	9-7
MAPE ชุดตรวจสอบ(%)	0.95	0.89	0.84	0.76	0.75	<b>0.71</b>
เวลาที่ใช้ในการฝึกสอนในแต่ละรอบ (นาท)	3.37	4.21	5.06	6.21	7.52	<b>9.31</b>
จำนวนนิวรอนในชั้นซ่อนที่ 1-2	4-1	5-2	6-3	7-4	8-5	9-6
MAPE ชุดตรวจสอบ(%)	0.96	0.88	0.86	0.81	0.75	<b>0.72</b>
เวลาที่ใช้ในการฝึกสอนในแต่ละรอบ (นาท)	2.48	3.52	4.31	5.26	6.43	<b>8.30</b>

จากตารางที่ ก1 จะสังเกตเห็นว่า จำนวนนิวรอนในชั้นซ่อนที่ 1 และ 2 ที่มีความแตกต่างกันอยู่ 1 นิวรอนจะให้ประสิทธิภาพที่ดีกว่าอีก 2 กรณี ด้วยเหตุนี้เอง ในวิทยานิพนธ์จึงได้เลือกนิวรอนในชั้นซ่อนที่ 1 และ 2 ให้มีความแตกต่างกันอยู่ 1 นิวรอน

สำหรับการเลือกใช้ฟังก์ชันกระตุ้นนั้น ในภาคผนวกนี้ได้ทำการปรับเปลี่ยนฟังก์ชันกระตุ้นในแต่ละชั้นซ่อนและชั้นเอาต์พุททั้งหมด 12 กรณีด้วยกัน ดังแสดงในตารางที่ ก2 เพื่อแสดงให้เห็นถึงความสำคัญในการเลือกใช้ฟังก์ชันกระตุ้นให้เหมาะสม

ตารางที่ ค2 แสดงฟังก์ชันกระตุ้นในชั้นซ่อนและชั้นเอาต์พุตเพื่อฝึกสอนโครงข่ายประสาทเทียม

ฟังก์ชันกระตุ้น		
ชั้นซ่อนที่ 1	ชั้นซ่อนที่ 2	ชั้นเอาต์พุต
Hyperbolic tangent sigmoid function	Logistic sigmoid function	Linear function
		Logistic sigmoid
		Hyperbolic Tangent sigmoid
	Hyperbolic tangent sigmoid function	Linear function
		Logistic sigmoid
		Hyperbolic Tangent sigmoid
Logistic sigmoid function	Logistic sigmoid function	Linear function
		Logistic sigmoid
		Hyperbolic Tangent sigmoid
	Hyperbolic tangent sigmoid function	Linear function
		Logistic sigmoid
		Hyperbolic Tangent sigmoid

จากตารางที่ ค3 จะสังเกตเห็นว่า มีเพียงฟังก์ชันกระตุ้น 4 กรณีด้วยกันที่มีค่าเปอร์เซ็นต์ผิดพลาดเฉลี่ยสัมบูรณ์ (MAPE) ที่ใกล้เคียงคือ

1. Hyperbolic tangent – Logistic – Linear
2. Hyperbolic tangent – Hyperbolic tangent – Linear
3. Logistic – Logistic – Linear
4. Logistic – Hyperbolic tangent – Linear

ดังนั้น จึงได้นำกรณีศึกษาจำนวน 108 ข้อมูลมาทำการทดสอบเพื่อหาฟังก์ชันกระตุ้นที่เหมาะสมต่อไป ดังแสดงในตารางที่ ค4

ตารางที่ ค3 แสดงผลสรุปการฝึกสอนในการปรับเปลี่ยนฟังก์ชันกระตุ้นในชั้นซ่อนและชั้นเอาต์พุต เพื่อฝึกสอน โครงข่ายประสาทเทียม

ฟังก์ชันกระตุ้น			MAPE (%) และ เวลา ฝึกสอน (นาที)	จำนวนนิเวรอนในชั้นซ่อนที่ 1 และ 2					
ชั้นซ่อนที่ 1	ชั้นซ่อนที่ 2	ชั้นเอาต์พุต		4-3	5-4	6-5	7-6	8-7	9-8
Hyperbolic tangent sigmoid function	Logistic sigmoid function	Linear function	MAPE Test	0.91	0.83	0.75	<b>0.71</b>	0.71	0.73
			เวลา	4.21	4.44	5.48	<b>7.63</b>	9.26	11.35
		Logistic sigmoid function	MAPE Test	12.32	11.51	12.51	<b>10.69</b>	11.53	11.39
			เวลา	3.16	2.46	4.07	<b>6.09</b>	7.25	8.15
		Hyperbolic Tangent sigmoid function	MAPE Test	3.94	3.47	<b>3.33</b>	3.38	3.34	3.34
			เวลา	3.40	4.48	<b>5.47</b>	6.42	7.43	10.42
	Hyperbolic tangent sigmoid function	Linear function	MAPE Test	0.86	0.79	0.74	0.75	<b>0.7</b>	0.73
			เวลา	3.41	4.25	5.16	6.35	<b>7.46</b>	10.46
		Logistic sigmoid function	MAPE Test	12.76	12.45	11.83	11.44	11.42	<b>10.70</b>
			เวลา	2.22	2.29	4.46	4.55	6.04	<b>7.42</b>
		Hyperbolic Tangent sigmoid function	MAPE Test	4.20	3.55	3.47	3.39	3.38	<b>3.34</b>
			เวลา	6.30	8.28	10.36	12.42	15.50	<b>28.34</b>

ตารางที่ ค3 (ต่อ)

ฟังก์ชันกระตุ้น			MAPE (%) และ เวลา ฝึกสอน (นาที)	จำนวนนิรอนในชั้นซ่อนที่ 1 และ 2					
ชั้นซ่อนที่ 1	ชั้นซ่อนที่ 2	ชั้นเอาต์พุต		4-3	5-4	6-5	7-6	8-7	9-8
Logistic sigmoid function	Logistic sigmoid function	Linear function	MAPE Test	0.78	0.79	0.72	0.71	0.75	<b>0.71</b>
			เวลา	4.04	4.45	5.43	7.29	8.43	<b>11.5</b>
		Logistic sigmoid function	MAPE Test	12.65	11.84	12.71	11.79	<b>11.39</b>	11.82
			เวลา	2.15	3.55	3.48	5.54	<b>5.26</b>	7.35
		Hyperbolic Tangent sigmoid function	MAPE Test	3.58	3.4	3.38	3.37	<b>3.33</b>	3.34
			เวลา	3.38	4.3	5.3	6.43	<b>8.15</b>	10.35
	Hyperbolic tangent sigmoid function	Linear function	MAPE Test	0.88	0.77	0.75	<b>0.72</b>	0.74	0.72
			เวลา	4.16	4.43	6.13	<b>7.41</b>	9.26	11.43
		Logistic sigmoid function	MAPE Test	12.81	11.84	<b>11.51</b>	11.81	11.53	11.89
			เวลา	2.51	3.34	<b>5</b>	5.52	7.11	8.39
		Hyperbolic Tangent sigmoid function	MAPE Test	3.45	3.46	3.4	<b>3.29</b>	3.36	3.37
			เวลา	3.43	5.36	10.04	<b>11.45</b>	13.45	15.56

จากตารางที่ ค4 จะเป็นการแสดงค่าความคลาดเคลื่อนสูงสุด ต่ำสุดและค่าเฉลี่ย โดยจะเห็นได้ว่าฟังก์ชันกระตุ้นกรณี Hyperbolic tangent – Hyperbolic tangent – Linear จะให้ค่าความคลาดเคลื่อนสูงสุดและค่าเฉลี่ยทางด้านแรงดันสูงอยู่ที่ 3.22%, 0.89% ตามลำดับ ด้วยเหตุนี้เอง ในวิทยานิพนธ์จึง

ได้เลือกฟังก์ชันกระตุ้นที่อยู่ในชั้นซ่อนที่ 1 และ 2 จะใช้ชนิด แทนเจนต์ซิกมอยด์ (Tan-sigmoid) ส่วนชั้นเอาต์พุตจะใช้ฟังก์ชันกระตุ้นชนิดเชิงเส้น (Linear)

ตารางที่ ค4 ผลสรุปจากการทดสอบจากข้อมูล 108 ชุดในการปรับเปลี่ยนฟังก์ชันกระตุ้น

ฟังก์ชันกระตุ้น ในชั้นซ่อนที่ 1	ฟังก์ชันกระตุ้นใน ชั้นซ่อนที่ 2	ฟังก์ชัน กระตุ้นในชั้น เอาต์พุต	ความคลาด เคลื่อนสูงสุด	ความคลาดเคลื่อน ต่ำสุด	ความคลาด เคลื่อนเฉลี่ย
Hyperbolic tangent sigmoid function	Logistic sigmoid function	Linear function	0.0414	0.0000	0.0099
Hyperbolic tangent sigmoid function	Hyperbolic tangent sigmoid function	Linear function	0.0322	0.0001	0.0089
Logistic sigmoid function	Logistic sigmoid function	Linear function	0.0497	0.0000	0.0094
Logistic sigmoid function	Hyperbolic tangent sigmoid function	Linear function	0.0483	0.0001	0.0098

จากผลสรุปการฝึกสอนในตารางที่ ค1 และ ค4 จะเป็นการปรับเปลี่ยน โครงสร้างและฟังก์ชัน  
กระตุ้นสำหรับระบุตำแหน่งกรณีขดลวดลัดวงจรลงดิน ซึ่งจะเห็นได้ว่า จำนวนนิวรอนในชั้นซ่อนที่  
1 และ 2 ที่มีความแตกต่างกันอยู่ 1 นิวรอนจะให้ประสิทธิภาพที่ดีกว่าและฟังก์ชันกระตุ้นกรณี  
Hyperbolic tangent – Hyperbolic tangent – Linear จะให้ค่าความคลาดเคลื่อนต่ำที่สุด อย่างไรก็ตาม  
ยังมีปัจจัยอื่นๆ ที่อยู่นอกเหนือจากองค์ประกอบทั้ง 3 ส่วน อาทิเช่น การเริ่มต้นของค่าถ่วงน้ำหนัก  
และค่าไบอัส รวมไปถึงอัลกอริทึมที่ใช้ในการปรับค่าถ่วงน้ำหนักและค่าไบอัส

สำหรับการเลือกใช้จำนวนครั้งในการสุ่มค่าเริ่มต้นของค่าถ่วงน้ำหนักและค่าไบอัส ใน  
ภาคผนวกนี้ได้ทำการเลือกสุ่มค่าเริ่มต้นของค่าถ่วงน้ำหนักและค่าไบอัสเพียงครั้งเดียวแล้วทำการ  
เปรียบเทียบกับค่าถ่วงน้ำหนักจำนวน 3 ครั้งและ 5 ครั้ง ผลสรุปการฝึกสอนได้แสดงใน  
ตารางที่ ค5 จากนั้น จึงได้นำกรณีศึกษาจำนวน 108 ข้อมูลมาทำการทดสอบ ผลสรุปการทดสอบได้  
แสดงในตารางที่ ค6

ตารางที่ ๑๕ แสดงผลสรุปการฝึกสอนในการปรับเปลี่ยนจำนวนการสู่มค่าเริ่มต้นของค่าถ่วงน้ำหนัก และค่าไบอัสสำหรับระบุตำแหน่งกรณีขลวดลัดวงจรลงดิน

สู่มค่าเริ่มต้นจำนวน 1 ครั้ง	4-3	5-4	6-5	7-6	8-7	9-8
MAPE ชุดตรวจสอบ (%)	0.86	0.79	0.74	0.75	<b>0.7</b>	0.73
เวลาที่ใช้ในการฝึกสอน ในแต่ละรอบ (นาทีก)	3.41	4.25	5.16	6.35	<b>7.46</b>	10.46
สู่มค่าเริ่มต้นจำนวน 3 ครั้ง	4-3	5-4	6-5	7-6	8-7	9-8
MAPE ชุดตรวจสอบ (%)	0.86	0.81	<b>0.68</b>	0.68	0.72	0.73
เวลาที่ใช้ในการฝึกสอน ในแต่ละรอบ (นาทีก)	15.55	19.34	<b>24.08</b>	30.27	34.49	42.09
สู่มค่าเริ่มต้นจำนวน 5 ครั้ง	4-3	5-4	6-5	7-6	8-7	9-8
MAPE ชุดตรวจสอบ (%)	0.79	0.79	0.72	<b>0.67</b>	0.73	0.72
เวลาที่ใช้ในการฝึกสอน ในแต่ละรอบ (นาทีก)	24.12	30.11	38.11	<b>48.25</b>	69.26	83.1

ตารางที่ ๑๖ ผลสรุปจากการทดสอบจากข้อมูล 108 ชุดในการปรับเปลี่ยนจำนวนครั้งที่สู่มค่าเริ่มต้น

จำนวนครั้งที่สู่ม ค่าเริ่มต้น	ความคลาด เคลื่อนสูงสุด	ความคลาด เคลื่อนต่ำสุด	ความคลาดเคลื่อนเฉลี่ย
1	0.0322	0.0001	0.0089
3	0.0533	0	0.0096
5	0.0338	0.0001	0.0095

จากผลสรุปที่ได้จากตารางที่ ๑๖ จะเห็นได้ว่า จำนวนครั้งที่ทำการสู่มค่าเริ่มต้นของค่าถ่วงน้ำหนักและค่าไบอัสทั้ง 3 กรณีจะให้ค่าความคลาดเคลื่อนเฉลี่ยที่ใกล้เคียงกัน โดยที่จำนวนครั้งที่สู่มค่าเริ่มของค่าถ่วงน้ำหนักและค่าไบอัสเพียงครั้งเดียวจะให้ประสิทธิภาพที่ดีกว่า

## ภาคผนวก ง.

## ผลงานวิจัยที่ได้รับการตีพิมพ์

1. A. Ngaopitakkul, A. Kunakorn and S. Bunjongjit, "Discrete Wavelet Transform and Probabilistic Neural Networks Algorithm for Identification of Fault Locations on Transmission Systems," *The 2004 International Conference on Power System Technology (POWERCON2004)*, Singapore, November 2004.
2. A. Ngaopitakkul, A. Kunakorn and I. Ngamroo, "Discrimination between External Short Circuits and Internal Faults in Transformer Windings using Discrete Wavelet Transforms," *IEEE Industries Application Society Annual Conference 40<sup>th</sup> (IAS2005)*, Hongkong, October 2005.
3. A. Ngaopitakkul and A. Kunakorn, "Internal Fault Classification in Transformer Windings using Combination of Discrete Wavelet Transforms and Back-propagation Neural Networks," *International Journal of Control, Automation, and Systems (IJCAS)*, Vol. 4, No. 3, pp. 365-371, June 2006.
4. A. Ngaopitakkul and A. Kunakorn, "Detecting Winding to Ground Fault Locations in Power Transformers using Back-propagation Neural Networks," *The 7<sup>th</sup> International Conference on Advances in Power System Control, Operation and Management (APSCOM2006)*, Hongkong, October 2006.
5. A. Ngaopitakkul and A. Kunakorn, "Transformer Differential Protection Schemes with Internal Faults Detection Algorithms using Neural Networks," *The 2006 International Conference on Electrical Machines and System (ICEMS2006)*, Nagasaki Japan, November 2006.

# Discrete Wavelet Transform and Probabilistic Neural Networks Algorithm for Identification of Fault Locations on Transmission Systems

A. Ngaopitakkul, A. Kunakorn and S. Bunjongjit  
Department of Electrical Engineering, Faculty of Engineering  
King Mongkut's Institute of Technology Ladkrabang, Bangkok 10520 Thailand

**Abstract**—This paper proposes a new algorithm for detecting faults in an electric power transmission system. The Discrete Wavelet Transform (DWT) and probabilistic neural network (PNN) are used in order to detect the high frequency components and to identify fault locations on the transmission system. Simulations and the training process for the neural network are performed using ATP/EMTP and MATLAB. It is found that the proposed algorithm gives satisfactory results, and will be very useful in the development of a power system protection scheme.

**Index Terms**—ATP/EMTP, Discrete Wavelet Transform, Fault, Probabilistic neural network

## I. INTRODUCTION

Nowadays, electric energy systems have become more complicated with a large number of transmission lines connected as a grid due to the high demand of electric power. To ensure the extreme level for the reliability of the systems, the precision protection schemes have to be developed, particularly in fault location and fault identification on the transmission lines. The development in the algorithm for detecting the faults on the transmission lines has been progressed, and results in transient based techniques [1]. In such methods, the fault detection and classification employ high frequency components in the fault signals. In order that the transient based protection can be accurately successful in operation, the applications of wavelet transform and artificial neural networks (ANNs) are used [2,3,4]. This is due to that the wavelet transform is very effective in detecting transient signals generated by the faults while artificial neural networks are useful tools for solving and selecting a precision algorithm for a protection unit.

In several research papers, the fault current signals are decomposed in to various scales of the wavelet transforms, and by considering the pattern of the spectra, the fault diagnosis can be achieved. The location of the fault is normally calculated using traveling wave approach while the fault classification can be obtained from employing trial and error method [4] or from the artificial intelligent decision algorithms [3]. Normally, the algorithm uses neural networks to indicate the proper decision. It should be interesting to investigate an appropriate neural network for being included in newly-developed protection systems.

This paper is aimed to propose a combination of wavelet transforms and neural networks to detect the faults on transmission systems. The fault conditions are simulated using ATP/EMTP [5]. Fault signals in each case are extracted to several scales on the wavelet transforms, and then are used as an input for a training process on the neural networks[6,7]. The probabilistic neural network (PNN) is selected in the algorithm since the PNN uses less training data and time compared with back propagation neural networks (BP), which is normally employed in previous research work. A new technique to identify fault locations on the transmission lines is discussed. In addition, results obtained based on data in Thailand electrical transmission systems are presented.

## II. WAVELET TRANSFORMS AND PROBABILISTIC NEURAL NETWORK

### A. Wavelet transform

Wavelet transform is a mathematical technique used in signal analysis. A wavelet is a small-localized wave of a particular shape and finite duration that has an average value of zero. The wavelet transform is a tool that cuts up data or functions or operators into different frequency components, and then studies each component with a resolution matched to its scale. The advantage of the transform is that the band of analysis can be fine adjusted so that high frequency components and low frequency components can be detected precisely. Results from the wavelet transform are shown on both the time domain and the frequency domain. The wavelet transform, which has a change in the analysis scaled by the factor of two, is called discrete wavelet transform (DWT) as in Equation 1 [1].

$$DWT(m, n) = \frac{1}{\sqrt{2^m}} \sum_k f(k) \psi \left[ \frac{n - k2^m}{2^m} \right] \quad (1)$$

where,

$$\psi \left[ \frac{n - k2^m}{2^m} \right] = \text{mother wavelet}$$

(In this paper, Daubechies 4 is selected as a mother wavelet).

### B. Probabilistic neural network (PNN)

Probabilistic neural network (PNN) was developed by Donald Specht, to perform pattern classification using Gaussian potential functions and Bayes decision theory [8]. PNN have been used successfully to solve a diverse group of classification problems. Although the PNN has not yet been fully evaluated compared with Back-propagation The PNN approach offers major advantages such as rapid training, added or deleted data from training set without lengthy retaining etc. The PNN neural network consists of three layer of neurons (Input, radial basis layer, competitive layer) interconnected by weights as illustrated in Fig 1.




Fig 1. Probabilistic neural network [2]

Training of a network involves two stages as follows [7]:

1. Input values are propagated to each neurons in the first layer. The radial basis layer computes distances from the input vector to weight vector, and produces output in radial basis layer as in Equation 2.

$$\varphi(p) = \exp\left(-\frac{\|p - IW_{1,j}\|^2}{\sigma_j^2}\right) \quad (2)$$

where,

$p$  = input pattern vector

$IW_{1,j}$  = center vector of radial basis layer

$\sigma$  = spread constant for radial basis layer (smoothing parameter)

$\varphi(p)$  = output of radial basis layer

2. Each neuron in the competitive layer receives all radial basis layer outputs associated with a given class, and produces as its net output a vector of probabilities. Finally, a competitive activation function on the output of the competitive layer picks the maximum of these probabilities, and produces a 1 for that class and a 0 for the other classes as in Equation 3 [2].

$$\sigma / P_{ANN} = f^2(LW_{2,j} * \varphi(p)) \quad (3)$$

where,

$LW_{2,j}$  = weight vector between radial basis layer and competitive layer

$f^2$  = competitive activation function

### III. SIMULATIONS

Artificial neural networks are an attempt to simulate the human brain's nonlinear and parallel processing capability for applications. ANNs, therefore, have necessitated learn relationships between cause and effect of data into orderly and informative patterns. As a result, PNN requires fault signal samples from simulations to training and test processes. The ATP/EMTP [5] was used to simulated fault signals, at a sampling rate 200 kHz. The fault locations were chosen based on the Thailand transmission system as shown in Fig 2. Fault patterns in the simulations were varied as follows:

- Fault types were single line to ground (SLG), double lines to ground (DLG), line to line (L-L) and three-phase fault (3-P).
- Fault locations were from 10% to 90% (each step = 10%) of the transmission line length measured from the bus MM3.
- Inception angle on a voltage waveform  $0^\circ$ - $330^\circ$  (step  $30^\circ$ ), phase A was used as a reference.
- Fault resistance was equal to  $10\Omega$ .




Fig 2. The system used in simulation fault [9]

The fault signals generated using ATP/EMTP are interfaced to the MATLAB in order to analyse the transient high frequency components using wavelet toolbox [5]. The example of fault signals obtained in each phase at the sending end (MM3) of the transmission lines are illustrate in Figure 3. The Clark's transformation matrix is employed for calculating the positive sequence and zero sequence of voltages and currents.




Fig 3. Example of simulated fault signals for ABG fault

Fault detection decision is processed using the positive sequence voltage and current signals. The mother wavelet daubechies4 (db4) is employed to decompose high frequency components from the signals. Coefficients obtained using DWT of signals, then, are squared so that the abrupt change in the spectra can be clearly found, and it is clearly seen that the coefficients of high frequency components, when fault occurs, have a sudden change compared with those before an occurrence of the faults as shown in Fig 4 and Table 1. It has been proposed that if coefficients of any scales are change around five times before an occurrence of the faults, there are faults occurring on transmission lines [4].




Fig 4 Wavelet transform from scale 1 to 5 for the positive sequence of voltage and current signals shown in Fig 3.

Table 1 Results for fault detection from signals shown in Fig 4

Wavelet scale	Voltages		Currents		Results
	Max (pre)	Max (post)	Max (pre)	Max (post)	
1	2.155E+05	6.8050E+08	0.0461	6.2426	Fault
2	1.637E+05	1.4258E+09	0.0101	26.4708	Fault
3	2.959E+05	2.0768E+09	0.1120	78.6149	Fault
4	1.852E+05	2.5557E+09	0.7007	143.1983	Fault
5	9.013E+05	2.8526E+09	3.4694	389.5590	Fault

#### IV. PNN ALGORITHMS AND RESULTS

From the simulated signals, the coefficients of scale 1 obtained using the wavelet transforms are used for training and test processes of the PNN. Input data sets are normalized and divided into 720 sets for training and 360 sets for tests. Before the training process, PNN structure consists of 8 neurons input and 1 neurons output while the number of neurons in radial basis layer are 720 neurons (due to that number of neurons is always equal to the number of training sets). Input patterns for the training process are obtained from maximum values of DWT at  $\frac{1}{4}$  cycle of phase A, B, C and zero sequence for post-fault voltage and current waveforms.

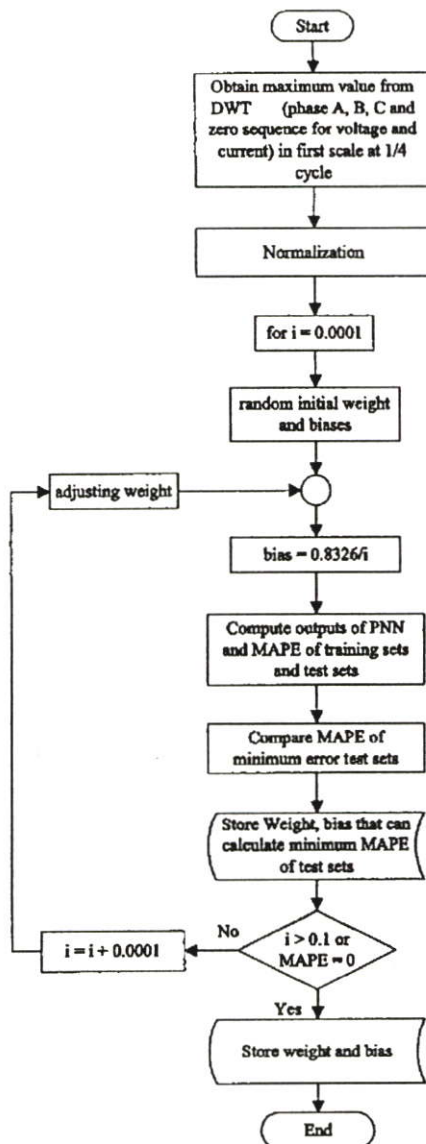


Fig 6. Process of training

Fig 6 shows an algorithm used in the training process for the PNN. During the training, PNN begins with the random initial weight and increasing spread in radial basis layer which corresponds to bias value ( $b = \frac{0.8326}{Spread}$ ) from 0.0001 until 0.1, it is increased step at 0.0001 to computes minimum MAPE as shown in Equation 4. This procedure is repeated until the maximum number of spread is reached or MAPE equally 0 then stop training. Results are shown in Tables 3.

$$MAPE = \frac{1}{n} \cdot \sum_{i=1}^n \left| \frac{O/P_{ANN} - O/P_{TARGET}}{O/P_{TARGET}} \right| \cdot 100\% \quad (4)$$

where,

n = number of test set

Table 3 Results and MAPE

Spread	MAPE of Training	MAPE of Test	Training time (second)
0.0001	0	44.184	126
0.0002	0	26.832	82
0.0003	0	21.071	82
0.0004	0	14.661	77
0.0005	0.017	8.245	89
0.0006	0.052	1.182	78
0.0007	0.052	1.182	62
0.0008	0.052	0.701	62
0.0009	0.08	0.26	63
0.001	0.08	0.26	64
0.0011	0.08	0.26	65
0.0012	0.08	0.26	64
0.0013	0.08	0.26	62
0.0014	0.08	0.26	65
0.0015	0.1	0.26	63
0.0016	0.1	0.13	62
0.0017	0.1	0.13	64
0.0018	0.1	0.13	64
0.0019	0.1	0.13	64
0.002	0.1	0.13	64

From Table 3, it is noticed that the best MAPE of test sets is 0.13% at spread values from 0.0016 to 0.002. After training, PNN is tested by weight and bias that able to compute MAPE with minimum error, and stored to computes with only input values, not target output and calculated close to the correct target output.

After the training process, the algorithm was employed in order to locate fault positions on a transmission system. Case studies were varied so that the algorithm capability can be verified. The system under consideration has been shown in Fig.2. The fault location is defined at the distance between 10 % and 90% of the transmission length measured from the

MM3 end. Case studies were performed with various types of fault at each location on the transmission lines. The total number of the case studies was 360. The results obtained from the algorithm proposed in this paper are shown in Table 4. It can be seen that the accuracy from the PNN algorithm is highly satisfactory. This is an improvement of the fault location which is detected using the traveling wave technique developed by Markming et al [4]

Table 4 Accuracy of fault location from the proposed algorithm

Fault location (Distance measured from the MM3 end)	Test cases	Accuracy
10%	40	100%
20%	40	100%
30%	40	100%
40%	40	100%
50%	40	100%
60%	40	100%
70%	40	97.5%
80%	40	97.5%
90%	40	100%

## V. CONCLUSIONS

In this paper, a technique using discrete wavelet transform combined with probabilistic neural networks in order to identify fault locations on a single circuit transmission lines has been proposed. The discrete wavelet transform has been employed to decompose high frequency components from fault signals. Coefficients of positive sequence voltage and current signals are calculated. The maximum values from the first scale at  $\frac{1}{4}$  cycle of phase A, B, C and zero sequence of post-fault voltage and current signals obtained by the wavelet transforms have been used as an input for the training process of a neural network in a decision algorithm. Probabilistic neural network (PNN) has been selected in the decision algorithm. Various case studies have been studied including the variation of fault inception angles and fault types. It has been shown that the PNN is able to give satisfactory results with less training time compared with other types of neural networks, such as back propagation. The results have illustrated that the proposed algorithm can identify the fault locations on transmission systems with the accuracy higher than 97.5%. The further work will be the investigation of the appropriate neural network for using in the classification of fault types. In addition, effects of other transmission line configurations, for instance loop circuits or double circuits, will be taken into account for the development of the practical protection system.

## VI REFERENCES

- [1] C. H. Kim and R. Aggarwal, "Wavelet transforms in power systems: Part. 1 General introduction to the wavelet transform," IEE Power Engineering Journal, April 2000, pp. 81-87
- [2] N. S. D. Brito, B. A. Souza and F. A. C. Pires, "Daubechies wavelets in Quality of Electrical Power," Proc. IEEE International Conference on Harmonics and Quality of Power, October 1998, pp. 511-515
- [3] L. L. Lai, E. Vaseekar, H. Subasinghe and N. Rajkumar, "Wavelet Transform and Neural Networks for Fault Location of a Teed-network," IEEE Conference on Power System Technology, December 2000, pp.807 - 811
- [4] P.Makming, S. Bunjongjit, A.Kunakorn, S. Jiriwibhakorn and M. Kando 'Fault diagnosis in transmission lines using wavelet transforms' IEEE Transmission and Distribution Conference, Yokohama, Japan, October 2002, pp. 2246-2250
- [5] D. Van Dommelen, Alternative Transient Program Rule Book, Leuven EMTP Center, Belgium, 1991.
- [6] M. Misiti, Y. Misiti, G. Oppenheim and J. M. Poggi, Wavelet Toolbox User's Guide, The Math Work, Inc., June 2001.
- [7] H. Demuth and M. Beale, Neural Network Toolbox User's Guide, The Math Work, Inc., March 2001.
- [8] S. Haykin "Neural networks: A Comprehensive Foundation", Prentice-Hall 1999
- [9] "Switching and Transmission Line Diagram", Electricity Generation Authorisation Thailand (EGAT)

## VII BIOGRAPHIES

Athapol Ngsopitakkul graduated with B.Eng and M.Eng in electrical engineering from King Mongkut's Institute of Technology Ladkrabang, Bangkok, Thailand in 2002 and 2004 respectively. He is currently a Ph.D. candidate at the department of electrical engineering, King Mongkut's Institute of Technology Ladkrabang. His research interests are on the applications of wavelet transform and neural networks in power system analysis.



Anantawat Kunakorn graduated with B.Eng (Hons) in electrical engineering from King Mongkut's Institute of Technology Ladkrabang, Bangkok, Thailand in 1992. He received his M.Sc in electrical power engineering from UMIST, Manchester, UK and Ph.D. in electrical engineering and electronics from Heriot-Watt University, Scotland, UK. He is currently an assistant professor at the department of electrical engineering, King Mongkut's Institute of Technology Ladkrabang, Bangkok, Thailand. He is a member of IEE and IEE. His research interest is electromagnetic transients in power systems.



Sulee Bunjongjit is currently an associate professor at the department of electrical engineering, King Mongkut's Institute of Technology Ladkrabang, Bangkok, Thailand. His research interests are on power systems, grounding systems and illumination engineering.



# Discrimination between External Short Circuits and Internal Faults in Transformer Windings using Discrete Wavelet Transforms

A. Ngaopitakkul and A. Kunakorn

Department of Electrical Engineering,  
Faculty of Engineering,  
King Mongkut's Institute of Technology Ladkrabang,  
Bangkok 10520, Thailand

I. Ngamroo

Sirindhorn International Institute of Technology  
Bangkadi, Pathum Thani 12000, Thailand

**Abstract**— In this paper, a technique for separation between internal faults in a two-winding three-phase transformer and external short circuits is presented. The fault detection algorithm is constructed on the basis of coefficient comparison from signals decomposed from Discrete Wavelet Transform. Computer simulations are performed using ATP/EMTP as well as MATLAB/Simulink. Various cases and fault types are studied to verify the validity of the algorithm. It is found that the proposed method gives a satisfactory accuracy, and will be particularly useful in a development of a modern differential relay for a transformer protection scheme.

**Keywords**- internal faults; external short circuits; transformer windings; Discrete Wavelet Transform

## I. INTRODUCTION

Power transformers are important devices in an electrical energy system for supplying electricity. In order to obtain a high reliability level from an operation of the power transformer, a precise protection scheme is required. Generally, the transformers can be protected by overcurrent relays, pressure relays and differential relays depending on purposes [1]. For differential protection, the differential current, which is generated by a comparison between the primary current and the secondary current detected via current transformers, is required. The differential protection is aimed at detecting internal faults in transformer windings. In a normal operation or in a fault condition due to the external short circuits, the differential current is relatively small, and the differential relay should not function [1]. However, there are some factors that can cause a needless operation of the differential protection. To avoid the malfunction, the discrimination between internal faults, magnetizing inrush current and external short circuit current is required [1,2,3]. Several transformer models and decision algorithms have been proposed and discussed for such a task [4,5,6]. Recently, with the advance of signal processing technologies, the development of Wavelet transforms which is a mathematical tool in an analysis of transient signals has been introduced [7]. The applications of the Wavelet transforms in power system technologies have been adopted including the studies of transformer fault diagnosis [8,9,10].

This paper presents an application of Wavelet transform and a decision algorithm in order to detect the internal faults at the windings of a two-winding transformer, and the external short circuit current due to faults at transmission lines or cables connected with the transformer. The transformer model with the stray capacitances is used so that internal fault signals with high frequency components can be calculated. The simulations and analysis are performed using ATP/EMTP and MATLAB. The current waveforms obtained from ATP/EMTP are extracted to several scales with the Wavelet transform, and the coefficients of the first scale from the Wavelet transformer are investigated. The comparison of the coefficients is investigated and used in the construction of the decision algorithm

## II. WAVELET TRANSFORM

Wavelet transform is a mathematical technique used in signal analysis. A wavelet is a small-localized wave of a particular shape and finite duration that has an average value of zero. The wavelet transform is a tool that cuts up data or functions or operators into different frequency components, and then studies each component with a resolution matched to its scale. The advantage of the transform is that the band of analysis can be fine adjusted so that high frequency components and low frequency components can be detected precisely. Results from the wavelet transform are shown on both the time domain and the frequency domain. The wavelet transform, which has a change in the analysis scaled by the factor of two, is called discrete wavelet transform (DWT) as in (1).

$$\text{DWT}(m, n) = \frac{1}{\sqrt{2^m}} \sum_k f(k) \psi \left[ \frac{n - k2^m}{2^m} \right] \quad (1)$$

where,

$$\psi \left[ \frac{n - k2^m}{2^m} \right] = \text{mother wavelet}$$

(In this paper, Daubechies 4 is selected as a mother wavelet).

### III. TRANSFORMER WINDING MODELS

For a two-winding three-phase transformer, Bastard et al [4] proposed a modification of the BCTRAN, which is a well-known subroutine for a transformer model on ATP/EMTP, for studying internal faults of the transformer. Normally, the BCTRAN uses a matrix of inductances with a size of 6x6 to represent a transformer, but with the internal faults the matrix is adjusted to be a size of 7x7 for winding to ground faults and of 8x8 for interturn faults [4]. In the research work of Bastard et al [4], the model was proved to be valid and accurate due to a comparison with measurement results. Recently, the application of transient based protection using high frequency components for locating faults on transmission lines has been proposed [11,12]. Islam and Ledwich [5] described the characteristics of high frequency responses of a transformer due to various faults. It has been shown that the fault types and fault positions have an effect of the frequency responses of the transformer [5]. As a result, in this paper the combination of the transformer models proposed by Bastard et al [1] as shown in Fig. 1, with the high frequency model including capacitances of the transformer recommended by IEEE working group [13] as shown in Fig. 2, are used for all case studies. From Fig. 1, for the phase winding of the transformer with internal faults, the winding is divided into two parts in the case of winding to ground faults, and three parts in the case of interturn faults. In addition, the capacitances shown in Fig. 2 are as follows:

$C_{hg}$  = stray capacitance between the high voltage winding and ground

$C_{lg}$  = stray capacitance between the low voltage winding and ground

$C_{hl}$  = stray capacitance between the high voltage winding and the low voltage winding.




Figure 2. A two-winding transformer with the effects of stray capacitances

### IV. CASE STUDIES

A 50 MVA, 115/23 kV two-winding three-phase transformer was employed in simulations with all parameters and configuration provided by a manufacturer [14]. The system under investigations is a part of Thailand electricity transmission system as depicted in Fig. 3. It can be seen that the transformer as a step down transformer is connected between two subtransmission sections. The primary and secondary current waveforms, them, can be simulated using ATP/EMTP, and these waveforms are brought into MATLAB for further investigations.




Figure 3. The system used in simulations studies

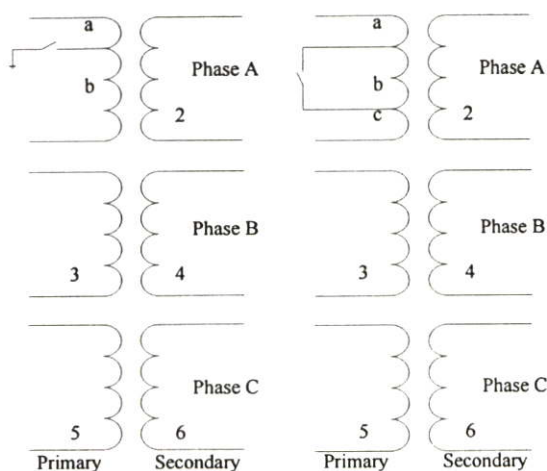


Figure 1. The modification on ATP/EMTP model for a two-winding transformer with internal faults

To implement the transformer model, simulations were performed with various changes in system parameters as follows:

- The angles on phase A voltage waveform for the faults were  $30^\circ$  and  $210^\circ$ .
- Two types for internal faults at the transformer windings, winding to ground faults and interturn faults, were investigated.
- For the winding to ground faults, the fault positions were designated on any phases of the transformer windings at the length of 10%, 20%, 30%, 40%, 50%, 60%, 70%, 80% and 90%.
- For the interturn faults, the position of point a on the transformer winding, as shown in Fig. 1, was varied at the length of 10%, 20%, 30%, 40%, 50%, 60%, 70% and 80%.
- Fault resistance was  $5 \Omega$ .

For simulations of external faults occurring at the transmission lines at both sides of the transformer, case studies were varied as follows:

- The angles on phase A voltage waveform for the faults were  $30^\circ$  and  $210^\circ$ .

- Types of faults were single line to ground, double lines to ground, line to line and three-phase faults (AG, BG, CG, ABG, BCG, CAG, AB, BC, CA, ABC).
- The fault locations on the transmission lines were at the length of 10%, 20%, 30%, 40%, 50%, 60%, 70%, 80% and 90%.
- Fault resistance was 5 Ω.

V. SIMULATION RESULTS AND DECISION ALGORITHM

Fault signals are simulated using ATP/EMTP with various conditions stated in the previous section. The fault signals obtained from the simulations, then, are imported to MATLAB. The differential currents, which are a deduction between the primary current and the secondary current in all three phases as well as the zero sequence, are calculated, and the resultant current signals are extracted using the Wavelet transform. The coefficients of the signals obtained from the Wavelet transform are squared for a more explicit comparison. Fig.4, Fig. 5, Fig.6 and Fig. 7 illustrate examples of extraction using Wavelet transform for the differential currents and zero sequence current from scale1 to scale 5.




Figure 4. Wavelet transform of differential currents in a normal operation




Figure 5. Wavelet transform of differential currents for a fault between a transformer winding and ground ( a quarter cycle after fault inception)




Figure 6. Wavelet transform of differential currents for an interturn fault in a transformer winding ( a quarter cycle after fault inception)




Figure 7. Wavelet transform of differential currents for an external fault( a quarter cycle after fault inception)

After applying the Wavelet transform to the differential currents, the comparison of the coefficients from each scale is considered so that the fault classifications and fault locations can be analysed. In case of internal faults and external faults Wavelet transform is applied to the quarter cycle of current waveforms after the fault inception. With several trial and error processes, the decision algorithm on the basis of computer programming technique is constructed. The decision algorithm is divided into two parts, phase detection and fault type classifications, concluded as follows:

For detecting the phase with a fault condition,

$$\text{if } (X_{(t+1)}^{\text{diff}} \geq 5 * X_{\max(0 \rightarrow t)}^{\text{diff}})$$

$$\text{then } X_{\text{chk}}^{\text{diff}} = 1$$

else

$$X_{chk}^{diff} = 0$$

end

where,

$X_{(t+t1)}^{diff}$  = coefficient from Wavelet transform for the differential current detected from phase X at the time of t+t1

$X_{max(0 \rightarrow t)}^{diff}$  = coefficient from Wavelet transform for the differential current detected from phase X at the time from t =0 to t = t

$X_{chk}^{diff}$  = comparison indicator for a change in coefficient from Wavelet transform ( $A_{check}^{diff}, B_{check}^{diff}, C_{check}^{diff}$ ), used for separation between normal conditions and faults

t1 = 5 μsec (depending on the sampling time used in ATP/EMTP)

For detecting types of faults,

if  $[(5 \leq \frac{Z_{max(post)}^{diff}}{Z_{max(pre)}^{diff}} < 10000) \text{ and } (A_{chk}^{diff} + B_{chk}^{diff} + C_{chk}^{diff} \geq 2)]$

then if  $[(10 < Ph_{max}^{diff} < 50) \text{ and } (Ph_{min}^{diff} < 10)]$

then if  $[(A_{com}^{diff} > (0.7 * Ph_{max}^{diff}))]$

then phase A fault at low voltage side

else if  $[(B_{com}^{diff} > (0.7 * Ph_{max}^{diff}))]$

then phase B fault at low voltage side

else if  $[(C_{com}^{diff} > (0.7 * Ph_{max}^{diff}))]$

then phase C fault at low voltage side

end

else then fault at transmission lines connected to the low voltage side of the transformer

end

else if  $[(\frac{Z_{max(post)}^{diff}}{Z_{max(pre)}^{diff}} \geq 10000) \text{ and } (A_{chk}^{diff} + B_{chk}^{diff} + C_{chk}^{diff} \geq 2)]$

then if  $[(5 < Ph_{max}^{diff} < 7) \text{ and } (0.05 < Ph_{min}^{diff} < 1)]$

then if  $[(A_{com}^{diff} > (0.7 * Ph_{max}^{diff}))]$

then phase A fault at high voltage side

else if  $[(B_{com}^{diff} > (0.7 * Ph_{max}^{diff}))]$

then phase B fault at high voltage side

else if  $[(C_{com}^{diff} > (0.7 * Ph_{max}^{diff}))]$

then phase C fault at high voltage side

end

else then fault at transmission lines connected to the high voltage side of the transformer

end

else if  $(A_{chk}^{diff} + B_{chk}^{diff} + C_{chk}^{diff} < 2)$

then "Normal condition"

end

where,

$$X_{com}^{diff} = \frac{X_{max(post)}^{diff}}{Z_{max(post)}^{diff}}$$

$X_{max(post)}^{diff}$  = maximum value of coefficient from Wavelet transform of differential current for phase X at the time of ¼ cycles after detecting faults

$Z_{max(post)}^{diff}$  = maximum value of coefficient from Wavelet transform of zero sequence current at the time of ¼ cycles after detecting faults

$Z_{max(pre)}^{diff}$  = maximum value of coefficient from Wavelet transform of zero sequence current at the time of ¼ cycles before the inception of faults

$Ph_{max}^{diff}$  = maximum value of comparison indicators ( $A_{com}^{diff}, B_{com}^{diff}, C_{com}^{diff}$ ) used in detecting the phase with fault appearance

$Ph_{min}^{diff}$  = minimum value of comparison indicators ( $A_{com}^{diff}, B_{com}^{diff}, C_{com}^{diff}$ ) used in detecting the phase with fault appearance

From the differential current of all three phases and zero sequence current, coefficients from each scale of Wavelet transform are considered and employed in the decision algorithm, and it is found that the coefficients from scale 1 are sufficient to indicate the difference between the internal faults of transformer windings and external short circuits as summarised in Tables 1,2 and 3. For locating the phase with fault appearance, the coefficient from scale1 of Wavelet transform for differential current and zero sequence current waveforms is used in the decision algorithm. The results are shown as Tables 4,5 and 6

TABLE 1 RESULTS FOR WINDING TO GROUND FAULTS

Wavelet Scale	Differential Current								Results
	Phase A		Phase B		Phase C		Zero sequence		
	Max (pre)	Max (post)	Max (pre)	Max (post)	Max (pre)	Max (post)	Max (pre)	Max (post)	
1	0.0003	52.2	0.0003	1.18	0.0002	1.19	0.0001	8.5	Fault
2	0.006	31.8	0.0043	6.44	0.0014	6.36	0.0001	10.3	Fault
3	0.0225	132.7	0.0155	31.15	0.0097	30.94	0.0001	171.2	Fault
4	0.0152	1257.1	0.0157	80.96	0.0027	80.53	0.0006	740.1	Fault
5	0.3853	5913.1	0.0598	8.97	0.0592	8.93	0.4095	1675.9	Fault

TABLE 2 RESULTS FOR INTERTURN FAULTS

Wavelet Scale	Differential Current								Results
	Phase A		Phase B		Phase C		Zero sequence		
	Max (pre)	Max (post)	Max (pre)	Max (post)	Max (pre)	Max (post)	Max (pre)	Max (post)	
1	0.0003	56.40	0.0003	1.2952	0.0002	1.3008	0.0001	9.10	Fault
2	0.006	34.00	0.0043	6.563	0.0014	6.4811	0.0001	10.50	Fault
3	0.0225	138.20	0.0155	31.4075	0.0097	31.352	0.0001	175.50	Fault
4	0.0152	1360.40	0.0157	85.1272	0.0027	84.5599	0.0006	784.40	Fault
5	0.4174	6911.50	0.0611	9.3568	0.0604	9.3264	0.4324	1977.20	Fault

TABLE 3 RESULTS FOR EXTERNAL FAULTS

Wavelet Scale	Differential Current								Results
	Phase A		Phase B		Phase C		Zero sequence		
	Max (pre)	Max (post)	Max (pre)	Max (post)	Max (pre)	Max (post)	Max (pre)	Max (post)	
1	0.0003	5835	0.0003	3.3588	0.0002	3.3689	0.0001	1803.2	Fault
2	0.006	20111	0.0043	18.2325	0.0014	16.9528	0.0001	6096.5	Fault
3	0.0225	9293	0.0155	83.1524	0.0097	82.3744	0.0001	2593.7	Fault
4	0.0152	580	0.0157	98.9381	0.0027	100.1975	0.0006	296.9	Fault
5	11.61	171	0.0455	10.5343	0.0471	11.1006	4.9082	86.1	Fault

TABLE 4 RESULTS OF LOCATING PHASE FOR WINDING TO GROUND FAULTS

Wavelet Scale	Differential Current							Results	
	$A_{com}$	$B_{com}$	$C_{com}$	$Z_{com}$	$Ph_{max}$	$Ph_{min}$	$0.7*Ph_{max}$	position	phase
Scale 1	6.1506	0.1391	0.1406	1	6.1506	0.1391	4.30542	HV side	A

TABLE 5 RESULTS OF LOCATING PHASE FOR INTERTURN FAULTS

Wavelet Scale	Differential Current							Results	
	$A_{com}$	$B_{com}$	$C_{com}$	$Z_{com}$	$Ph_{max}$	$Ph_{min}$	$0.7*Ph_{max}$	position	phase
Scale 1	6.1857	0.1422	0.1428	1	6.1857	0.1422	4.33	HV side	A

TABLE 6 RESULTS OF LOCATING PHASE FOR EXTERNAL FAULTS

Wavelet Scale	Differential Current							Results	
	$A_{com}$	$B_{com}$	$C_{com}$	$Z_{com}$	$Ph_{max}$	$Ph_{min}$	$0.7*Ph_{max}$	position	phase
Scale 1	3.2359	0.0019	0.0019	1	3.2359	0.0019	2.26513	lines	A

Results illustrated from Tables 1 to 6 are obtained from one case of each type of faults. When all conditions as stated in the section IV are applied, the total number of case studies is 108 for winding to ground faults, 532 for interturn faults, 360 for external faults and 6 for normal condition. The accuracy of the proposed decision algorithm for all case studies is shown in Table 7.

TABLE 7 SUMMARY OF RESULTS FROM ALL SIMULATIONS

Fault types	Winding to ground faults		Interturn faults		External faults	Normal condition
	HV side	LV side	HV side	LV side		
Number of study cases	54	54	216	216	360	6
Detection accuracy	100%	100%	100%	100%	98.89%	100%

## VI. CONCLUSIONS

Studies on the discrimination between external short circuits and internal faults in transformer winding have been investigated. The Wavelet transform has been employed to extract high frequency components superimposed on fault signals simulated using ATP/EMTP. The coefficients obtained from the Wavelet transform are used in constructing a decision algorithm. Various cases have been investigated so that the algorithm can be implemented. It is found that the proposed method can indicate the external short circuits and internal faults with satisfactory accuracy. It has been shown that the proposed technique uses data of the differential current with a time of a quarter cycles under the analysis, which is less than that employed in a conventional protection scheme. This will be useful for a precise operation of differential relays in transformer protective systems.

## REFERENCES

- [1] S.H. Horowitz and A.G. Phadke "Power System Relaying" John Wiley & Sons, 1992
- [2] A.G. Phadke and J.S. Thorp "A new computer-based flux restrained current-differential relay for power transformer protection" IEEE Transactions on Power Apparatus and System, November 1983, pp.3624-3629
- [3] T.S. Sidhu and M.S. Sachdev "On-line identification of magnetizing inrush current and internal faults in three-phase transformers" IEEE Transactions on Power Delivery, October 1992, pp. 1885-1891
- [4] P. Bastard, P. Bertrand and M. Meunier "A transformer model for winding fault studies" IEEE Transactions on Power Delivery, April 1994, pp. 690-699
- [5] S. M. Islam and G. Ledwich "Locating transformer faults through sensitivity analysis of high frequency modeling using transfer function approach" IEEE International Symposium on Electrical Insulation, June 1996, pp. 38-41
- [6] H. Wang and K.L. Butler "Modeling transformers with internal incipient faults" IEEE Transactions on Power Delivery, April 2002, pp. 500-509
- [7] I. Daubechies "The wavelet transform, time-frequency localization and signal analysis" IEEE Transactions of Information Theory, September 1990, pp. 961-1005
- [8] C.H. Kim and R. Aggarwal, "Wavelet transforms in power systems: Part I. General introduction to the wavelet transforms" IEE Power Engineering Journal, April 2000, pp. 81-87
- [9] O.A.S. Youssef "A wavelet-base technique for discrimination between faults and magnetizing inrush currents in transformers" IEEE Transactions on Power Delivery, January 2003, pp. 170-176
- [10] P. Purkait and S. Chakravorti "Wavelet transform-based impulse fault pattern recognition in distribution transformers" IEEE Transactions on Power Delivery, October 2003, pp. 1588-1589
- [11] Z. Q. Bo, M. A. Redfern and G. C. Weller, "Positional Protection of Transmission Line Using Fault Generated High Frequency Transient Signals" IEEE Transactions on Power Delivery, July 2000, pp.888-894
- [12] P.Makming, S. Bunjongjit, A.Kunakorn, S. Jiriwibhakorn and M. Kando "Fault diagnosis in transmission lines using wavelet transforms" IEEE Transmission and Distribution Conference, Yokohama, Japan, October 2002, pp. 2246-2250
- [13] IEEE working group 15.08.09 "Modeling and analysis of system transients using digital programs" IEEE PES special publication
- [14] ABB Thailand "Test report no. 56039"

# Internal Fault Classification in Transformer Windings using Combination of Discrete Wavelet Transforms and Back-propagation Neural Networks

Atthapol Ngaopitakkul and Anantawat Kunakorn\*

**Abstract:** This paper presents an algorithm based on a combination of Discrete Wavelet Transforms and neural networks for detection and classification of internal faults in a two-winding three-phase transformer. Fault conditions of the transformer are simulated using ATP/EMTP in order to obtain current signals. The training process for the neural network and fault diagnosis decision are implemented using toolboxes on MATLAB/Simulink. Various cases and fault types based on Thailand electricity transmission and distribution systems are studied to verify the validity of the algorithm. It is found that the proposed method gives a satisfactory accuracy, and will be particularly useful in a development of a modern differential relay for a transformer protection scheme.

**Keywords:** Discrete wavelet transforms, internal faults, neural network, transformer windings.

## 1. INTRODUCTION

Protective devices are an important part for detecting fault conditions in a power system. The appropriate protection scheme must be selected to ensure the safety of power apparatus and reliability of the system. Generally, power transformers can be protected by overcurrent relays, pressure relays and differential relays depending on purposes [1]. For differential protection, the differential current, which is generated by a comparison between the primary current and the secondary current detected via current transformers, is required. The differential protection is aimed at detecting internal faults in transformer windings. In a normal operation or in a fault condition due to the external short circuits, the differential current is relatively small, and the differential relay should not function [1,2]. However, there are some factors that can cause a needless operation of the differential protection such as effects from magnetizing inrush current. To avoid the malfunction of the differential relay, the discrimination between internal faults, magnetizing inrush current and external short circuit current is required [1-3]. Several transformer models and decision algorithms have been proposed and discussed for such a task [4-6]. Recently, with the advance of signal processing technologies

and artificial intelligent tools, the development of more sophisticated protection systems as well as fault diagnosis for the power transformer has been progressed with the applications of wavelet transform (WT) and artificial neural networks (ANNs) [7-10].

This paper presents an application of Wavelet transform and a decision algorithm based on back propagation neural networks in order to detect the internal faults at the windings of a two-winding transformer. The transformer model with the stray capacitances is used so that internal fault signals with high frequency components can be calculated. The simulations, analysis and diagnosis are performed using ATP/EMTP and MATLAB. The current waveforms obtained from ATP/EMTP are extracted to several scales with the Wavelet transform, and the coefficients of the first scale from the Wavelet transformer are investigated. The comparison of the coefficients is performed and used as an input for training processes of the neural networks. The construction of the decision algorithm is detailed and implemented with various case studies based on Thailand electricity transmission and distribution systems.

## 2. WAVELET TRANSFORMS

Normally, the traditional method of signal analysis is based on Fourier transforms. Fourier transform is a process of multiplying a signal by a sinusoid in order to determine frequency contents of a signal. The output of the Fourier transform is sinusoids of different frequencies. It is found that Fourier transform is not appropriate to analyse faults in a power system with transient based protection methods,

Manuscript received August 30, 2005; accepted February 7, 2006. Recommended by Editorial Board member Yuan Fang Zheng under the direction of Editor Jin Young Choi.

Atthapol Ngaopitakkul and Anantawat Kunakorn are with Department of Electrical Engineering, Faculty of Engineering, King Mongkut's Institute of Technology Ladkrabang, Bangkok 10520, Thailand (e-mail: kkananta@kmitl.ac.th).

\* Corresponding author.

because in such a system the desirable information may be located in both the frequency domain and the time domain. Due to the limits of Fourier transforms in applications with transient signals, Wavelet transforms has been proposed as an alternative tool in signal analysis. A wavelet is a small-localized wave of a particular shape and finite duration that has an average value of zero. The wavelet transform is a tool that cuts up data or functions or operators into different frequency components, and then studies each component with a resolution matched to its scale [11, 12]. The advantage of the transform is that the band of analysis can be fine adjusted so that high frequency components and low frequency components are detected precisely. Results from the wavelet transform are shown on both the time domain and the frequency domain. The wavelet transform can expand signals in term of using a shift in time or translation as well as compression in time or dilation of a fixed wavelet function named as the mother wavelet [9]. The wavelet transform, which has a change in the analysis scaled by the factor of two, is called discrete wavelet transform (DWT) as in (1).

$$DWT(m, n) = \frac{1}{\sqrt{2^m}} \sum_k f(k) \psi \left[ \frac{n - k2^m}{2^m} \right], \quad (1)$$

where  $\psi \left[ \frac{n - k2^m}{2^m} \right]$  = mother wavelet (in this paper, Daubechies 4 is selected as a mother wavelet.)

**3. TRANSFORMER WINDING MODELS**

For a computer model of a two-winding three-phase transformer having primary and secondary windings in each phase, BCTRAN is a well-known subroutine on ATP/EMTP. To study internal faults of the transformer, Bastard et al proposed modification of the BCTRAN subroutine. Normally, the BCTRAN uses a matrix of inductances with a size of 6x6 to represent a transformer, but with the internal fault conditions the matrix is adjusted to be a size of 7x7 for winding to ground faults and of 8x8 for interturn faults [4]. In the research work of Bastard et al [4], the model was proved to be validate and accurate due to a comparison with measurement results. However, the effects of high frequency components which may occur during the faults are not included in such a model. Islam and Ledwich [5] described the characteristics of high frequency responses of a transformer due to various faults. It has been shown that the fault types and fault locations have an influence on the frequency responses of the transformer [5]. In addition, it has been proved that transient based protections using high frequency components in fault currents can be applicable in

locating and classifying faults on transmission lines [13,14]. It is, therefore, useful to investigate the high frequency components superimposed on the fault current signals for a development of a transient based protection for a transformer. As a result, in this paper the combination of the transformer models proposed by Bastard et al [4] as shown in Fig. 1, with the high frequency model including capacitances of the transformer recommended by IEEE working group [15] as shown in Fig. 2, are used for simulations of internal faults at the transformer windings.

From Fig. 1, for the phase winding of the transformer with internal faults, the winding is divided into two parts in the case of winding to ground faults, and three parts in the case of interturn faults.

The capacitances shown in Fig. 2 are as follows:

$C_{hg}$  = stray capacitance between the high voltage winding and ground

$C_{lg}$  = stray capacitance between the low voltage winding and ground

$C_{hl}$  = stray capacitance between the high voltage winding and the low voltage winding.




Fig. 1. The modification on ATP/EMTP model for a three-phase transformer with internal faults[4].

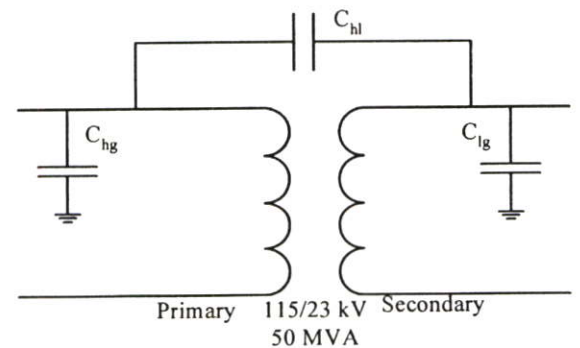


Fig. 2. A two-winding transformer with the effects of stray capacitances[15].

#### 4. CASE STUDIES AND FAULT DETECTION ALGORITHMS

A 50 MVA, 115/23 kV two-winding three-phase transformer was employed in simulations with all parameters and configuration provided by a manufacturer [16]. The scheme under investigations is a part of Thailand electricity transmission and distribution system as depicted in Fig. 3. It can be seen that the transformer as a step down transformer is connected between two subtransmission sections. The primary and secondary current waveforms, then, can be simulated using ATP/EMTP, and these waveforms are imported into MATLAB/Simulink for a construction of fault diagnosis process.

To implement the transformer model and cover all regions of operating conditions training and testing data were simulated with various changes in system parameters as follows:

- The angles on phase A voltage waveform for the instants of fault inception were  $30^\circ$  and  $210^\circ$ .
- Two types for internal faults at the transformer windings (both primary and secondary) which are winding to ground faults and interturn faults, were investigated.
- For the winding to ground faults, the fault locations were designated on any phases of the transformer windings (both primary and secondary) at the length of 10%, 20%, 30%, 40%, 50%, 60%, 70%, 80% and 90% measured from the line end of the windings.
- For the interturn faults, the position of point a on the transformer winding, as shown in Fig. 1, was varied at the length of 10%, 20%, 30%, 40%, 50%, 60%, 70% and 80% measured from the line end of the windings.
- For the interturn faults, the position of point b on the transformer winding, as shown in Fig. 1, was varied at the length of 10%, 20%, 30%, 40%, 50%, 60%, 70% and 80% measured from the line end of the windings.
- Fault resistance was  $5 \Omega$ .

With fault signals obtained from the simulations, the differential currents, which are a deduction between the primary current and the secondary current in all three phases as well as the zero sequence, are calculated, and the resultant current signals are extracted using the Wavelet transform. The coefficients of the signals obtained from the Wavelet transform are squared for a more explicit comparison. Fig. 4 illustrates an example of an extraction using Wavelet transform for the differential currents and zero sequence current from scale1 to scale 5 for a case of phase A to ground fault at 40% in length of the high voltage winding.

After applying the Wavelet transform to the differential currents, the comparison of the coefficients from each scale is considered so that the fault classifications can be analysed. In case of internal faults and external faults Wavelet transform is




Fig. 3. The system used in simulations studies.




Fig. 4. Wavelet transform of differential currents (Turn to ground fault at 40% in length of the high voltage winding).

applied to the quarter cycle of current waveforms after the fault inception. With several trial and error processes, the decision algorithm on the basis of computer programming technique is constructed. The most appropriate algorithm for the decision with all results from the case studies of the system under the investigations can be concluded as follows[17]:

For detecting the phase with a fault condition, for  $td = 0.000005 : 0.000005 : 0.1$

$$\text{if } (X_{(td+t1)}^{diff} \geq 5 * X_{\max(0 \rightarrow td)}^{diff})$$

$$\text{then } X_{chk}^{diff} = 1$$

else

$$X_{chk}^{diff} = 0$$

end

end

where

$t1 = 5 \mu\text{sec}$  (depending on the sampling time used in ATP/EMTP),

$X_{(td+t1)}^{diff} =$  coefficient from Wavelet transform for the differential current detected from phase X at the time of  $td+t1$ ,

$X_{\max(0 \rightarrow t)}^{diff} =$  coefficient from Wavelet transform for the

differential current detected from phase X at the time from  $t = 0$  to  $t = td$ ,

$X_{chk}^{diff}$  = comparison indicator for a change in coefficient from Wavelet transform ( $A_{check}^{diff}, B_{check}^{diff}, C_{check}^{diff}$ ), used for separation between normal conditions and faults.

By performing many simulations, it has been found that when applying the previously detailed algorithm for detecting internal faults at the transformer winding, the coefficient in scale 1 from DWT seems enough to indicate the internal fault inception of the transformer. As a result, it is unnecessary to use other coefficients from higher scales in this algorithm, and the coefficients in scale 1 from DWT are used in training processes for the neural networks later.

**5. NEURAL NETWORK DECISION ALGORITHM AND SIMULATION RESULTS**

Artificial neural networks are an attempt to simulate the human brain’s non-linear and parallel processing capabilities. Although there are many types of neural networks, only a few of neuron-based structures are being used commercially. One particular structure, a back-propagation neural network, is the most popular tool for applications such as pattern recognition fault classification etc. A structure of a back propagation neural network consists of three layers which are an input layer, at least one hidden layer and an output layer. Each layer is connected with weights and bias. In this paper, a three-layer back propagation neural network with one input layer, two hidden layers and one output layer is employed as shown in Fig. 5.

Hyperbolic tangent sigmoid functions are used as an activation function in all hidden layers while linear function is used as an activation function in output layers. In addition, there are many adjustment weight and bias in the neural network toolbox such as quasi-

Newton algorithm, Levenberg-Maquardt algorithm, Resilient Backpropagation, Conjugate Gradient algorithm etc. Each method has difference efficiency and training time. A comparison of the various training algorithms has been mentioned, and it is shown that Levenberg-Marquardt algorithm has the fastest convergence [18]. As a result, Levenberg-Marquardt algorithm is selected as adjustment weight and bias in this paper. A training process for the back propagation neural network can be divided into three parts as follows [18]:

- 1) The feedforward input pattern, which has a propagation of data from the input layer to the hidden layer and finally to the output layer for calculating responses from input patterns illustrated in (2) and (3).

$$a^2 = f^2(iw^{2,1} * f^1(iw^{1,1} * p + b^1) + b^2), \tag{2}$$

$$o/p_{ANN} = f^3(iw^{3,2} * a^2 + b^3), \tag{3}$$

where

- $p$  = input vector of ANNs,
- $iw^{1,1}$  = weights between input and the first hidden layer,
- $iw^{2,1}$  = weights between the first and the second hidden layers,
- $iw^{3,2}$  = weights between the second hidden layer and output layers,
- $b^1, b^2$  = bias in the first and the second hidden layers respectively,
- $b^3$  = bias in output layers,
- $f^1, f^2$  = activation function(Hyperbolic tangent sigmoid function : tanh),
- $f^3$  = activation function(Linear function).

- 2) The back-propagation for the associated error between outputs of neural networks and target outputs; The error is fed to all neurons in the next lower layer, and also used to an adjustment of weights and bias.




Fig. 5. Back propagation with two hidden layers [18].

3) The adjustment of the weights and bias by Levenberg-Marquardt (trainlm). This process is aimed at trying to match between the calculated outputs and the target outputs. Mean absolute percentage error (MAPE) as an index for efficiency determination of the back-propagation neural networks is computed in (4).

$$MAPE = \frac{1}{n} * \sum_{i=1}^n \left| \frac{o/P_{ANNi} - o/P_{TARGETi}}{o/P_{TARGETi}} \right| * 100\%, \quad (4)$$

where n = number of test sets.

A training process was performed using neural network toolboxes in MATLAB [18]. A structure of the back propagation neural network consists of 4 neuron inputs and 8 neuron outputs. The inputs are the maximum coefficients of the differential currents and zero sequence current as mentioned in the previous section. In this paper, there are 360 sets for training. The output variables of the neural networks are designated as either 0 or 1 with various types of faults as shown in Table 1.

Before starting the training process, a number of neurons in each hidden layer have to be fixed according to various factors such as: number of input

Table 1. Output patterns from neural networks for various fault types.

Classifications of Fault	A1	B1	C1	G1	A2	B2	C2	G2
Winding to ground phase A (HV)	1	0	0	1	0	0	0	0
Winding to ground phase A (LV)	0	0	0	0	1	0	0	1
Interturn phase A (HV)	1	0	0	0	0	0	0	0
Interturn phase A (LV)	0	0	0	0	1	0	0	0
Winding to ground phase B (HV)	0	1	0	1	0	0	0	0
Winding to ground phase B (LV)	0	0	0	0	0	1	0	1
Interturn phase B (HV)	0	1	0	0	0	0	0	0
Interturn phase B (LV)	0	0	0	0	0	1	0	0
Winding to ground phase C (HV)	0	0	1	1	0	0	0	0
Winding to ground phase C (LV)	0	0	0	0	0	0	1	1
Interturn phase C (HV)	0	0	1	0	0	0	0	0
Interturn phase C (LV)	0	0	0	0	0	0	1	0

and output neurons, number of training cases and the type of activation function in hidden layer etc. The initial number of neurons for the first hidden layer can be calculated as shown in (5).

$$z = \frac{2}{3}(r + q), \quad (5)$$

where

z = Initial number of neurons in the first hidden layer,

r = Number of neurons input,

q = Number of neurons output.

When the initial number of neurons in the first hidden layer had been determined, the final number of the neurons in the same layer had to be calculated in order to stop the training process. The final number can be obtained from:

$$z_{st} = z + z1, \quad (6)$$

where

z<sub>st</sub> = the final number for the neurons in the first hidden layer,

$$z1 = \begin{cases} 5 & 2 \leq z \leq 6 \\ 4 & \text{if } 7 \leq z \leq 10 \\ 3 & 11 \leq z \leq 13 \\ 2 & 14 \leq z. \end{cases}$$

During the training process, the weight and biases were adjusted, and there were 20,000 iterations in order to compute the best value of MAPE. The number of neurons in both hidden layers was increased before repeating the cycle of the training process. The training procedure was stopped when reaching the final number of neurons for the first hidden layer or the MAPE of test sets was less than 0.5%. The training process can be summarized as a flowchart shown in Fig. 6 while various results from the training process can be shown in Table 2 with the initial number of neurons for the first hidden layer obtained from (5).

Table 2. Results from the training process (Performed on a PC with Pentium IV 2.4GHz CPU, with 512 MB RAM).

Number of neurons in the first hidden layer	MAPE of Test set (%)	Time used in training process (minute)
8	0.55556961	100.59
9	0.5555649	141.28
10	0.59023954	178.32
11	0.5678628	221.12

Table 3. Outputs from the neural network for the simulation case shown in Fig. 4.

A1	B1	C1	G1	A2	B2	C2	G2
1	0	0	1	0	0	0	0

Table 4. Accuracy of fault classification from the proposed algorithm.

Types of faults	Number of case studies	Accuracy
Winding to ground fault at the high voltage side	18	100%
Winding to ground fault at the low voltage side	18	100%
Interturn fault at the high voltage side	72	98.61%
Interturn fault at the low voltage side	72	100%

From Table 3, it can be seen that the index value at A1 is 1 and that at G1 is also 1 while others are 0. This means that there is an internal fault occurring at the high voltage side, and the internal fault is classified as a winding to ground fault, which is correlative to the condition of the transformer used in simulations of Fig. 4.

In addition, when all case studies are tested with various types of internal faults and different locations on both primary windings and secondary windings at the three-phase transformer, the accuracy of the results obtained from the prediction from the neural network is illustrated in Table 4.

6. CONCLUSIONS

A technique using discrete wavelet transform in combination with back propagation neural networks in order to classify internal fault types of a three-phase transformer has been proposed. The maximum values from the first scale at 1/4 cycle of phase A, B, and C of post-fault differential current signals and zero sequence current obtained by the wavelet transform have been used as an input for the training process of a neural network in a decision algorithm with a use of the back propagation neural networks. Various case studies have been studied including the variation of fault inception angles, fault types and fault locations. The results have illustrated that the proposed algorithm is able to predict the internal faults at windings of a transformer with an accuracy of higher than 98%. This technique should be useful in the differential protection scheme for the transformer. The further work will be the improvement of the algorithm so that fault locations on the windings of the transformer can be identified.




Fig. 6. Flowchart for the training process.

The decision algorithm based on the neural network, then, is tested with 180 case studies. The internal fault conditions in the windings of the transformer are simulated on ATP/EMTP. In order to explain the verification of the neural network algorithm, the simulation results shown in Fig. 4 are used as an example. For this case, when applying the decision algorithm for a prediction, the output obtained from neural network is as shown in Table 3.

## REFERENCES

- [1] S. H. Horowitz and A. G. Phadke, *Power System Relaying*, John Wiley & Sons, Inc, 1992.
- [2] A. G. Phadke and J. S. Thorp, "A new computer-based flux restrained current-differential relay for power transformer protection," *IEEE Trans. on Power Apparatus and System*, vol. PAS-102, no. 11, pp. 3624-3629, November 1983.
- [3] T. S. Sidhu and M. S. Sachdev, "On-line identification of magnetizing inrush current and internal faults in three-phase transformers," *IEEE Trans. on Power Delivery*, vol. 7, no. 4, pp. 1885-1891, October 1992.
- [4] P. Bastard, P. Bertrand, and M. Meunier, "A transformer model for winding fault studies," *IEEE Trans. on Power Delivery*, vol. 9, no. 2, pp. 690-699, April 1994.
- [5] S. M. Islam and G. Ledwich, "Locating transformer faults through sensitivity analysis of high frequency modeling using transfer function approach," *Proc. of IEEE International Symposium on Electrical Insulation*, pp. 38-41, June 1996.
- [6] H. Wang and K. L. Butler, "Modeling transformers with internal incipient faults," *IEEE Trans. on Power Delivery*, vol. 17, no. 2, pp. 500-509, April 2002.
- [7] Y. Zhang, X. Ding, Y. Liu, and P. J. Griffin, "An artificial neural network approach to transformer fault diagnosis," *IEEE Trans. on Power Delivery*, vol. 11, no. 4, pp. 1836-1841, October 1996.
- [8] M. G. Morante and D. W. Nocoletti, "A wavelet-based differential transformer protection," *IEEE Trans. on Power Delivery*, vol. 14, no. 4, pp. 1352-1358, October 1999.
- [9] O. A. S. Youssef, "A wavelet-base technique for discrimination between faults and magnetizing inrush currents in transformers," *IEEE Trans. on Power Delivery*, vol. 18, no. 1, pp. 170-176, January 2003.
- [10] P. Purkait and S. Chakravorti, "Wavelet transform-based impulse fault pattern recognition in distribution transformers," *IEEE Trans. on Power Delivery*, vol. 18, no. 4, pp. 1588-1589, October 2003.
- [11] I. Daubechies, "The wavelet transform, time-frequency localization and signal analysis," *IEEE Trans. on Information Theory*, vol. 36, no. 5, pp. 961-1005, September 1990.
- [12] C. H. Kim and R. Aggarwal, "Wavelet transforms in power systems: Part I. General introduction to the wavelet transforms," *IEE Power Engineering Journal*, pp. 81-87, April 2000.
- [13] Z. Q. Bo, M. A. Redfern, and G. C. Weller, "Positional protection of transmission line using fault generated high frequency transient signals," *IEEE Trans. on Power Delivery*, vol. 15, no. 3, pp. 888-894, July 2000.
- [14] P. Makming, S. Bunjongjit, A. Kunakorn, S. Jiriwibhakorn, and M. Kando, "Fault diagnosis in transmission lines using wavelet transforms," *Proc. of IEEE Transmission and Distribution Conference*, Yokohama, Japan, pp. 2246-2250, October 2002.
- [15] IEEE working group 15.08.09 "Modeling and analysis of system transients using digital programs," *IEEE PES special publication*.
- [16] ABB Thailand, Test report no. 56039.
- [17] A. Ngaopitakkul, A. Kunakorn, and I. Ngamroo, "Discrimination between external short circuits and internal faults in transformer windings using discrete wavelet transforms," *Proc. of 40th IEEE Industries Application Society Annual Conference*, Hongkong, October 2005.
- [18] H. Demuth and M. Beale, *Neural Network Toolbox User's Guide*, The Math Work, March 2001.



**Atthapol Ngaopitakkul** graduated with B.Eng and M.Eng in electrical engineering from King Mongkut's Institute of Technology Ladkrabang, Bangkok, Thailand in 2002 and 2004 respectively. He is currently a Ph.D. candidate at the department of Electrical Engineering, King Mongkut's Institute of Technology Ladkrabang.

His research interests are on the applications of wavelet transform and neural networks in power system analysis.



**Anantawat Kunakorn** graduated with B.Eng (Hons) in electrical engineering from King Mongkut's Institute of Technology Ladkrabang, Bangkok, Thailand in 1992. He received his M.Sc in Electrical Power Engineering from University of Manchester Institute of Science and Technology, UK in 1996, and Ph.D. in Electrical

Engineering from Heriot-Watt University, Scotland, UK in 2000. He is currently an Associate Professor at the Department of Electrical Engineering, King Mongkut's Institute of Technology Ladkrabang, Bangkok, Thailand. He is a Member of IEEE and IEE. His research interest is electromagnetic transients in power systems.

# Detecting Winding to Ground Fault Locations in Power Transformers Using Back-propagation Neural Networks

A. Ngaopitakkul and A. Kunakorn

**Abstract**-- This paper presents an algorithm based on a combination of Discrete Wavelet Transforms and neural networks for detecting locations of winding to ground faults in a two-winding three-phase transformer. The fault conditions of the transformer are simulated using ATP/EMTP in order to obtain fault current signals used as an input for a training process of a back-propagation neural network. The training process and fault diagnosis decision algorithm are implemented using toolboxes on MATLAB/Simulink. Various cases studies based on Thailand electricity transmission and distribution systems are performed to verify the validity of the algorithm. It is found that the proposed method gives a satisfactory accuracy, and will be particularly useful in a fault diagnosis process for a transformer manufacturer.

**Index Terms**-- Internal faults, Transformer windings, Discrete Wavelet Transforms.

## I. INTRODUCTION

In a protection scheme for power transformers, Overcurrent relays or pressure relays or differential relays are employed depending on purposes [1]. When faults occur at the power transformer, the detection of fault is very necessary in order that the protection devices can function precisely so that the power transformer can be prevented from damage due to such a fault. In case of internal faults, it is also important to seek out fault locations in transformer windings at the power transformer for accurate maintenance processes. Conventional methods for the fault diagnosis of the power transformers employed in most electricity generating utilities, are Dissolved Gas Analysis (DGA) method and winding impedance measurements. During the course of recent years, the development of the fault diagnosis for the power transformers has been progressed with the applications of signal processing techniques and artificial neural networks. However, the research works have mainly considered in the separation between magnetizing inrush current and internal faults as well as fault

classifications[2-6]. It should be very useful if the fault positions along transformer windings can be detected.

This paper presents an application of Wavelet transform and a decision algorithm based on back propagation neural networks in order to locate the fault positions along the transformer windings due to turn to ground faults of a two-winding transformer. The transformer model with the stray capacitances is used so that internal fault signals with high frequency components can be obtained. The simulations, analysis and diagnosis are performed using ATP/EMTP and MATLAB/Simulink. The current waveforms obtained from ATP/EMTP are extracted to several scales with the Wavelet transform, and the coefficients of the first scale from the Wavelet Transform are investigated. The comparison of the coefficients is performed and used as an input for training processes of the neural networks. The construction of the decision algorithm is detailed and implemented with various case studies based on Thailand electricity transmission and distribution systems.

## II. SIMULATIONS OF WINDING TO GROUND FAULTS IN POWER TRANSFORMERS

### A. Transformer Winding models

For a computer model of a two-winding three-phase transformer having primary and secondary windings in each phase, BCTRAN is a well-known subroutine on ATP/EMTP. To study internal faults of the transformer, Bastard et al [7] proposed modification of the BCTRAN subroutine. Normally, the BCTRAN uses a matrix of inductances with a size of 6x6 to represent a transformer, but with the internal fault conditions the matrix is adjusted to be a size of 7x7 for winding to ground faults

However, the effects of high frequency components which may occur during the faults are not included in such a model. In this paper the combination of the transformer models proposed by Bastard et al [7] as depicted in Fig. 1, with the high frequency model including capacitances of the transformer recommended by IEEE working group [8] are used for simulations of internal faults at the transformer windings as depicted in Fig. 2.

---

A. Ngaopitakkul and A. Kunakorn are with Department of Electrical Engineering, Faculty of Engineering, King Mongkut's Institute of Technology Ladkrabang, Bangkok 10520, Thailand. (e-mail: kkananta@kmitl.ac.th).




Fig. 1. The modification on ATP/EMTP model for a three-phase transformer with internal faults.




Fig. 2. A two-winding transformer with the effects of stray capacitances

The capacitances shown in Fig. 2 are as follows:

$C_{hg}$  = stray capacitance between the high voltage winding and ground

$C_{lg}$  = stray capacitance between the low voltage winding and ground

$C_{hl}$  = stray capacitance between the high voltage winding and the low voltage winding.

The process for simulating winding to ground faults based on the BCTRAN routine of EMTP, can be summarized as follows:

1<sup>st</sup> step: Compute matrices  $[R]$  and  $[L]$  of the power transformer from manufacture test data [9] without considering the winding to ground faults[7]

$$[R] = \begin{bmatrix} R_1 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & R_6 \end{bmatrix} \quad (1)$$

$$[L] = \begin{bmatrix} L_1 & L_{12} & \cdots & L_{16} \\ L_{21} & L_2 & \cdots & L_{26} \\ \vdots & \vdots & \ddots & \vdots \\ L_{61} & L_{62} & \cdots & L_6 \end{bmatrix} \quad (2)$$

2<sup>nd</sup> step: Modify Equations 1 and 2 to obtain the new internal winding fault matrices  $[R]^*$  and  $[L]^*$  as illustrated in Equations 3-4 [7].

$$[R]^* = \begin{bmatrix} R_a & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & R_b & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & R_2 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & R_3 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & R_4 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & R_5 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & R_6 \end{bmatrix} \quad (3)$$

$$[L]^* = \begin{bmatrix} L_a & M_{ab} & M_{a2} & M_{a3} & M_{a4} & M_{a5} & M_{a6} \\ M_{ba} & L_b & M_{b2} & M_{b3} & M_{b4} & M_{b5} & M_{b6} \\ M_{2a} & M_{2b} & L_2 & M_{23} & M_{24} & M_{25} & M_{26} \\ M_{3a} & M_{3b} & M_{32} & L_3 & M_{34} & M_{35} & M_{36} \\ M_{4a} & M_{4b} & M_{42} & M_{43} & L_4 & M_{45} & M_{46} \\ M_{5a} & M_{5b} & M_{52} & M_{53} & M_{54} & L_5 & M_{56} \\ M_{6a} & M_{6b} & M_{62} & M_{63} & M_{64} & M_{65} & L_6 \end{bmatrix} \quad (4)$$

3<sup>rd</sup> step: The inter-winding capacitances and earth capacitances of the HV and LV windings can be simulated by adding lumped capacitances connected to the terminals of the transformer.

### B. Winding to Ground Fault Simulations

A 50 MVA, 115/23 kV two-winding three-phase transformer was employed in simulations with all parameters and configuration provided by a manufacturer [9]. The scheme under investigations is a part of Thailand electricity transmission and distribution system as depicted in Fig. 3. It can be seen that the transformer as a step down transformer is connected between two subtransmission sections. To implement the transformer model, simulations were performed with various changes in system parameters as follows:

- The angles on phase A voltage waveform for the instants of fault inception were  $0^\circ$ - $330^\circ$  (each step is  $30^\circ$ ).
- Internal faults type at the transformer windings (both primary and secondary) which is winding to ground faults was investigated.
- The fault position were designated on any phases of the transformer windings (both primary and secondary), was varied at the length of 10%, 20%, 30%, 40%, 50%, 60%, 70%, 80% and 90% measured from the line end of the windings.
- Fault resistance was  $5 \Omega$ .




Fig. 3. The system used in simulations studies.

The primary and secondary current waveforms, then, can be simulated using ATP/EMTP, and these waveforms are interfaced to MATLAB/Simulink for a construction of fault diagnosis process. With fault signals obtained from the simulations, the differential currents, which are a deduction between the primary current and the secondary current in all three phases as well as the zero sequence, are calculated, and the resultant current signals are extracted using the Wavelet transform. The coefficients of the signals obtained from the Wavelet transform are squared for a more explicit comparison. Fig. 4. illustrates an example of an extraction using Wavelet transform for the differential currents and zero sequence current from scale 1 to scale 5 for a case of phase A to ground fault at 10% in length of the high voltage winding.




Fig. 4. Wavelet transform of differential currents (Winding to ground fault at 10% in length of the high voltage winding)

After applying the Wavelet transform to the differential currents, the comparison of the coefficients from each scale is considered. Wavelet transform is applied to the quarter cycle of current waveforms after the fault inception. With several trial and error processes, the decision algorithm on the basis of computer programming technique is constructed. By performing many simulations [10], it has been found that the coefficient in scale 1 from DWT seems enough to indicate the internal fault inception of the transformer. As a result, it is unnecessary to use other coefficients from higher scales in this algorithm, and the coefficients in scale 1 from DWT are used in training processes for the neural networks later.

### III. BACK PROPAGATION NEURAL NETWORKS

A structure of a back propagation neural network consists of three layers which are an input layer, at least one hidden layer and an output layer. Each layer is fully connected with weights and bias. In this paper, a three-layer back propagation neural network with one input layer, two hidden layers and one output layer is employed as shown in Fig.5. Tan-sigmoid is activation function or transfer function for hidden layer 1-2 and linear is used as activation function for output layer.




Fig 5. Back propagation with two hidden layers .

A training process for the back propagation neural network can be divided into three parts as follows [11-12]:

1 The feedforward input pattern, which has a propagation of data from the input layer to each neurons in the next upper layer until the output layer is reached in order to calculated responses (output) of neural networks as illustrated in Equations 5-6. This process are collectively known as the forward pass since information is flowing forward.

$$a^2 = f^2(iw^{2,1} * f^1(iw^{1,1} * p + b^1) + b^2) \quad (5)$$

$$o / p_{ANN} = f^3(iw^{3,2} * a^2 + b^3) \quad (6)$$

where,

$p$  = input vector of ANNs

$iw^{1,1}$  = weights between input and the first hidden layer

$iw^{2,1}$  = weights between the first and the second hidden layers

$iw^{3,2}$  = weights between the second hidden layer and output layers

$b^1, b^2$  = bias in the first and the second hidden layers respectively

$b^3$  = bias in output layers

$f^1, f^2$  = activation function in the first and the second hidden layers respectively

$f^3$  = activation function in the output layers

2 The back-propagation for the associated error between outputs of neural networks and target outputs; The error is fed to all neurons in the next lower layer, and also used to an adjustment of weights and bias.

This process are collectively known as the backward pass.

3 The adjustment of the weights and bias by Levenberg-Marquardt (trainlm) [11-12]. This process is aimed at trying to match between the calculated outputs and the target outputs. The adjustment to the weight and bias is based on error between output of back-propagation neural network and target output and modified by the derivative of the activation function. Mean absolute percentage error (MAPE) as an index for efficiency determination of the back-propagation neural networks is computed as in Equation 7.

$$MAPE = \frac{1}{n} * \sum_{i=1}^n \left| \frac{o / P_{ANNi} - o / P_{TARGETi}}{o / P_{TARGETi}} \right| * 100\% \quad (7)$$

where, n = number of test sets

#### IV. RESULTS

A training process was performed using neural network toolboxes in MATLAB [12]. Before the training process, a structure of the back propagation neural network consists of 4 neuron inputs and 1 neuron outputs. The inputs pattern are the maximum coefficients details (cD1) in scale 1 at ¼ cycle of phase A, B, C and zero sequence for post-fault differential currents as mentioned in the previous section. The output variables of the neural networks are designated as values range 0.1 to 0.9 which corresponding to length of the winding that fault occurs.

Input data sets are normalized and divided into 216 sets for training and 108 sets for tests. During the training process, the weight and biases were adjusted, and there were 20,000 iterations in order to compute the best value of MAPE. The number of neurons in both hidden layers was increased before repeating the cycle of the training process. The training procedure was stopped when reaching the final number of neurons for the first hidden layer or the MAPE of test sets was less than 0.5%. The results from the training process can be summarized in Table 1.

TABLE 1. RESULTS FROM THE TRAINING PROCESS IN CASE OF WINDING TO GROUND FAULT.

Number of neurons in the first hidden layer	High Voltage Winding		Low Voltage Winding	
	MAPE of Test set (%)	Time used in training process (minute)	MAPE of Test set (%)	Time used in training process (minute)
2	7.92	2.07	4.93	2.3
3	1.14	3.4	4.37	2.32
4	0.87	4.01	3.91	3.34
5	0.77	4.37	3.05	4.18
6	0.7	5.36	2.87	5.24
7	0.73	7.19	2.97	6.23
8	0.7	8.37	1.77	7.4
9	0.74	11.09	3.1	10.33
10	0.76	13.31	3.07	12.46
11	0.64	16.51	2.91	16.46

After the training process, the algorithm was employed in order to locate fault positions in the winding transformer. Case studies were varied so that the algorithm capability can be verified. Case studies were performed with various types of fault at each position in the transformer. The total number of the case studies was 216. The comparison of the average error from the results due to the algorithm proposed in this paper is shown in Fig.6 as well as Table 2. From Tables 3-6, it is shown that when the case studies are tested with various fault inception angles and different fault positions on both high voltage and low voltage windings of the three-phase transformer, the accuracy of fault locations from the prediction of the algorithm is highly satisfactory.




Fig. 6. Comparison average error of fault position at various length of the winding among phase that fault occur.

TABLE 2. THE RESULTS FROM TEST PROCESS. (NUMBER OF CASE STUDIES HAVE 108 CASE BOTH HIGH VOLTAGE WINDING AND LOW VOLTAGE WINDING)

	Maximum error	Minimum error	Average error
High voltage winding	0.0322	0.0001	0.0089
Low voltage winding	0.0621	0.0001	0.0211

TABLE 3. RESULTS OF PHASE A TO GROUND FAULT AT HIGH VOLTAGE WINDING WHEN VARIOUS INCEPTION ANGLE (FAULT POSITION AT 10% OF LENGTH OF THE WINDING).

Fault Type	Inception angle	Real position (%)	High voltage winding	
			Output	Error
Phase A to ground fault	90	0.1	0.1125	0.0125
	150	0.1	0.1243	0.0243
	240	0.1	0.1121	0.0121
	300	0.1	0.1169	0.0169

TABLE 4. RESULTS OF PHASE A TO GROUND FAULT AT HIGH VOLTAGE WINDING WHEN VARIOUS LENGTH OF THE WINDING (INCEPTION ANGLE IS 240°).

Fault Type	Inception angle	Real position (%)	High voltage winding	
			Output	Error
Phase A to ground fault	240	0.2	0.2005	0.0005
	240	0.4	0.4054	0.0054
	240	0.6	0.6042	0.0042
	240	0.8	0.8025	0.0025

TABLE 5. RESULTS OF PHASE A TO GROUND FAULT AT LOW VOLTAGE WINDING WHEN VARIOUS INCEPTION ANGLE (FAULT POSITION AT 10% OF LENGTH OF THE WINDING).

Fault Type	Inception angle	Real position (%)	Low voltage winding	
			Output	Error
Phase A to ground fault	60	0.1	0.0886	0.0114
	120	0.1	0.136	0.036
	210	0.1	0.1386	0.0386
	330	0.1	0.0568	0.0432

TABLE 6. RESULTS OF PHASE A TO GROUND FAULT AT LOW VOLTAGE WINDING WHEN VARIOUS LENGTH OF THE WINDING (INCEPTION ANGLE IS 210°).

Fault Type	Inception angle	Real position (%)	Low voltage winding	
			Output	Error
Phase A to ground fault	210	0.2	0.1943	0.0057
	210	0.4	0.4265	0.0265
	210	0.6	0.5871	0.0129
	210	0.8	0.7968	0.0032

## V. CONCLUSIONS

In this paper, a technique using discrete wavelet transform in combination with back propagation neural networks in order to locate winding to ground fault positions of a three-phase transformer has been proposed. The maximum coefficient from the first scale at  $\frac{1}{4}$  cycle of phase A, B, and C of post-fault differential current signals and zero sequence current obtained by the wavelet transform have been used as an input for the training process of a neural network in a decision algorithm with a use of the back propagation neural networks. Many case studies have been studied including the variation of fault inception angles and fault locations. The results have illustrated that the proposed algorithm is able to identify locate position of the internal faults of a transformer with an average error of 2.11% as presented in Table 2. This technique should be useful in checking and repairing the transformer when winding to ground faults occur. The further work will be the improvement of the algorithm so that positions of interturn fault along the windings of the transformer can be identified.

## VI. REFERENCES

- [1] S.H. Horowitz and A.G. Phadke, Power system relaying, John Wiley & Sons INC, 1992.
- [2] A.G. Phadke and J.S. Thorp, "A new computer-based flux restrained current-differential relay for power transformer protection," *IEEE Transactions on Power Apparatus and System*, pp.3624-3629, November 1983.
- [3] Y.Zhang, X.Ding, Y.Liu and P.J. Griffin, "An artificial neural network approach to transformer fault diagnosis," *IEEE Transactions on Power Delivery*, pp. 1836-1841, October 1996.
- [4] M.G. Morante and D.W. Nocoletti, "A wavelet-based differential transformer protection," *IEEE Transactions on Power Delivery*, pp.1352-1358, October 1999.
- [5] O.A.S. Youssef, "A wavelet-base technique for discrimination between faults and magnetizing inrush currents in transformers," *IEEE Transactions on Power Delivery*, pp. 170-176, January 2003.
- [6] P. Purkait and S. Chakravorti, "Wavelet transform-based impulse fault pattern recognition in distribution transformers," *IEEE Transactions on Power Delivery*, pp. 1588-1589, October 2003.
- [7] P. Bastard, P. Bertrand and M. Meunier, "A transformer model for winding fault studies," *IEEE Transactions on Power Delivery*, pp. 690-699, April 1994.
- [8] IEEE working group 15.08.09 "Modeling and analysis of system transients using digital programs," *IEEE PES special publication*
- [9] ABB Thailand, *Test report no. 56039*.
- [10] A. Ngaopitakkul, A.Kunakorn and I.Ngamroo, "Discrimination between External Short Circuits and Internal Faults in Transformer Windings using Discrete Wavelet Transforms," *40<sup>th</sup> IEEE Industries Application Society Annual Conference*, Hongkong, October 2005.
- [11] F.Laurene, *Fundamentals of Neural Networks*. Englewood Cliffs, New Jersey : Prentice Hall International, Inc. 1994.
- [12] H. Demuth and M. Beale, *Neural Network Toolbox User's Guide*, The Math Work, March 2001.

# Transformer Differential Protection Schemes with Internal Faults Detection Algorithms Using Neural Networks

A. Ngaopitakkul and A. Kunakorn

Department of Electrical Engineering, Faculty of Engineering  
King Mongkut's Institute of Technology Ladkrabang, Bangkok 10520, Thailand

**Abstract**— The major function of protective devices is to detect the occurrence of faults and to isolate the faulted sections from the rest of the power system. The differential protection is aimed at detecting internal faults in transformer windings. This paper presents an algorithm based on a combination of Discrete Wavelet Transforms and neural networks for detection and classification of internal faults in a two-winding three-phase transformer. Fault conditions of the transformer are simulated using ATP/EMTP in order to obtain current signals. The training process for the neural network and fault diagnosis decision are implemented using toolboxes on MATLAB/Simulink. Various cases and fault types based on Thailand electricity transmission and distribution systems are studied to verify the validity of the algorithm. It is found that the proposed method gives a satisfactory accuracy, and will be particularly useful in a development of a modern differential relay for a transformer protection scheme.

**Index Terms**— Discrete Wavelet Transforms, Internal faults, Neural networks, Transformer windings,

## I. INTRODUCTION

Occurrence of faults in a power system, can cause damage to the electrical power equipment which leads to an interruption of an electrical power system. In the fault detecting process, a protective relay is an important device for activating the operation of circuit breakers for isolating the faulted components from the rest of the power system. Differential relays are one of the common-used protective devices for a power transformer. The principle of the differential protection scheme for the power transformer can be described with Fig.1. The levels of currents on the primary and secondary sides of the power transformer are reduced by current transformers. The output of the current transformers is compared. The operating coil of the differential relay is connected to the secondary windings of the two current transformers in such a way that the net current is equal to the difference between the secondary currents obtained from the current transformer located at the two sides of the power transformer. The net current flowing through the operating coil of differential relay should be zero for normal operations and external faults. However, if there is a fault occurring in the protection zone, the balance of the outputs from the two current transformers is changed, and this causes a current to flow in the relay's operating coil as shown in Fig.1[1,2].




Fig.1. Basic differential protection scheme for (a) normal condition and (b) internal fault conditions of a power transformer.

There are many factors that can lead to the malfunction of the differential relays such as the saturation of the current transformers or the large inrush current due to switching on the power transformer. In order to prevent false tripping in these cases, the precise discrimination between internal faults, magnetizing inrush current and external short circuit current is required. Several transformer models and decision algorithms have been proposed and discussed for such a task [2,3,4,5]. In case of internal faults, it is also important to identify fault locations in transformer windings at the power transformer for accurate maintenance processes. Conventional methods for the fault diagnosis of the power transformers employed in most electricity generating utilities, are Dissolved Gas Analysis (DGA) method, Frequency Response Analysis (FRA) and winding impedance measurements. With the application of signal processing technologies and artificial intelligent tools, some decision algorithms employed in the transformer differential protection scheme, based on the use of neural networks and Wavelet Transforms have

been developed as an alternative or improvement to the existing protective relaying functions in order to detect the internal faults at the transformer windings [2,3,6,7,8,9]. This paper presents a novel differential protection scheme for a power transformer with an application of Wavelet transform and a decision algorithm based on back propagation neural networks in order to detect and classify the internal faults at the windings of a two-winding transformer. The schematic diagram is shown as Fig.2.




Fig. 2. A schematic diagram of the proposed differential protection

In the simulation studies, the transformer model with the stray capacitances is used so that internal fault signals with high frequency components can be calculated. The simulations, analysis and diagnosis are performed using ATP/EMTP and MATLAB. The current waveforms obtained from ATP/EMTP are extracted to several scales with the Wavelet Transform, and the coefficients of the first scale from the Wavelet transformer are investigated. The comparison of the coefficients is performed and used as an input for training processes of the neural networks. The construction of the decision algorithm is detailed and implemented with various case studies.

## II. SIMULATIONS OF INTERNAL FAULTS IN POWER TRANSFORMERS

A 50 MVA, 115/23 kV two-winding three-phase transformer as a step down transformer connected between two subtransmission systems was employed in simulations with all parameters and configuration provided by a manufacturer [10]. The scheme under investigations is a part of Thailand electricity transmission and distribution system as depicted in Fig. 3.




Fig. 3. The system used in simulations studies.

For a computer model of a two-winding three-phase transformer having primary and secondary windings in each phase, BCTRAN is a well-known subroutine on ATP/EMTP. To study internal faults of the transformer, Bastard et al [4] proposed the modification of the BCTRAN subroutine. However, the effects of high frequency components which may occur during the faults are not included in such a model. Studies of the internal faults in at the transformer winding with the high frequency model including capacitances of the transformer have been performed [9]. In this paper such a model of the transformer is used in all case studies.




Fig. 4. A two-winding transformer with the effects of stray capacitances

The capacitances shown in Fig. 4 are as follows:

$C_{hg}$  = stray capacitance between the high voltage winding and ground

$C_{lg}$  = stray capacitance between the low voltage winding and ground

$C_{hl}$  = stray capacitance between the high voltage winding and the low voltage winding.

### A. Winding to Ground Fault Simulations

Simulations were performed with various changes in system parameters as follows:

- The angles on phase A voltage waveform for the instants of fault inception were  $0^\circ$ - $330^\circ$  (each step is  $30^\circ$ ).
- For the winding to ground faults, the fault positions as shown in Fig. 5, were designated on any phases of the transformer windings (both primary and secondary) at the length of 10%, 20%, 30%, 40%, 50%, 60%, 70%, 80% and 90% measured from the line end of the windings.




Fig. 5. The modification on ATP/EMTP model for a three-phase transformer with winding to ground faults[4].




Fig. 6. Primary and secondary currents for a case of phase A to ground fault at 10% in length of the high voltage winding.

With fault signals obtained from the simulations shown as an example in Fig.6, the differential currents, which are a deduction between the primary current and the secondary current in all three phases as well as the zero sequence, are calculated, and the resultant current signals are extracted using the Wavelet transform. The coefficients of the signals obtained from the Wavelet transform are squared for a more explicit comparison. Fig. 7. illustrates an example of an extraction using Wavelet transform for the differential currents and zero sequence current from scale1 to scale 5 for a case of phase A to ground fault at 10% in length of the high voltage winding.




Fig. 7. Wavelet transform of differential currents (Winding to ground fault at 10% in length of the high voltage winding)

**B. Interturn Fault Simulations**

Simulations were performed with various changes as follows:

- For the interturn faults, the position of point a on the transformer winding, as shown in Fig. 8, was varied at the length of 10%, 20%, 30%, 40%, 50%, 60%, 70% and 80% measured from the line end of the windings.

- For the interturn faults, the position of point b on the transformer winding, as shown in Fig. 8, was varied at the length of 10%, 20%, 30%, 40%, 50%, 60%, 70% and 80% measured from the line end of the windings.




Fig.8. The modification on ATP/EMTP model for a three-phase transformer with interturn faults [4].




Fig. 9. Primary and secondary currents for a case of interturn phase A fault between 10% and 20% in length of the high voltage winding.

Fig. 9 shows the primary and secondary current waveforms obtained when interturn phase A fault occurred at high voltage winding Fig. 10. illustrates an example of an extraction using Wavelet transform for the differential currents and zero sequence current from scale1 to scale 5 for an interturn fault at phase A.




Fig. 10. Wavelet transform of differential currents (Interturn fault between 10% and 20% in length of the high voltage winding)

Wavelet transform is applied to the quarter cycle of current waveforms after the fault inception. The current signals have a coefficient in each scale obtained from the Wavelet transform. With several trial and error processes, it has been found that the coefficient in scale 1 from DWT seems enough to indicate the internal fault inception of the transformer [9]. As a result, it is unnecessary to use other coefficients from higher scales in this algorithm, and the coefficients in scale 1 from DWT are used in training processes for the neural networks later.

### III. RESULTS

A training process was performed using neural network toolboxes in MATLAB [11]. In this paper, there are 1620, 648 and 216 sets for the training process in purpose of classification of fault types, locating interturn fault positions and detecting winding to ground fault positions respectively. For the test process, there are 810, 324 and 108 sets for classification fault types, locating interturn fault positions and detecting winding to ground fault positions.

Before the training process, a structure of the back propagation neural network consists of 4 neuron inputs that are the maximum coefficients details (cD1) in scale 1 at  $\frac{1}{4}$  cycle of phase A, B, C and zero sequence for post-fault differential currents as mentioned in the previous section. The output variables of the neural networks are designated as either 0 or 1 with various types of faults for training to identify fault types, while the output variables of the neural networks for training to detect fault locations are designated as values with a range of 0.1 to 0.9 corresponding to the length of the winding that fault occurs. Hyperbolic tangent sigmoid functions are used as an activation function in all hidden layers while the linear function is used as an activation function in output layers.

During the training process, the weight and biases were adjusted, and there were 20,000 iterations in order to compute the best value of MAPE. The number of neurons in both hidden layers was increased before repeating the cycle of the training process. The training procedure was stopped when reaching the final number of neurons for the first hidden layer or the MAPE of test sets was less than 0.5%. The training process can be summarized as a flowchart shown in Fig. 11 while the results from the training process can be summarized in Tables 1-3.

After the training process, the decision algorithm based on the neural network, then, is tested with various types of internal faults, different inception angles of fault and different locations on both primary windings and secondary windings at the three-phase transformer, and the accuracy of the results obtained from the prediction from the neural network is illustrated from Fig. 12 to Fig.14 and Tables 4-6.




Fig. 11. Flowchart for the training process (Using a PC with Pentium IV 2.4 GHz CPU and 512 MB RAM)

TABLE I. RESULTS FROM THE TRAINING PROCESS IN CASE OF CLASSIFYING FAULT TYPES.

Number of neuron in the first hidden layer	MAPE of Test set (%)	Time used in training process (minute)
2	16.67	61
3	16.84	124
4	16.68	188
5	12.69	269
6	12.12	358
7	11.85	471
8	4.99	594
9	3.39	769
10	1.46	953
11	1.04	1169

TABLE 2. RESULTS FROM THE TRAINING PROCESS IN CASE OF WINDING TO GROUND FAULTS

Number of neurons in the first hidden layer	High Voltage Winding		Low Voltage Winding	
	MAPE of Test set (%)	Time used in training process (minute)	MAPE of Test set (%)	Time used in training process (minute)
2	7.92	2.07	4.93	2.3
3	1.14	3.4	4.37	2.32
4	0.87	4.01	3.91	3.34
5	0.77	4.37	3.05	4.18
6	0.7	5.36	2.87	5.24
7	0.73	7.19	2.97	6.23
8	0.7	8.37	1.77	7.4
9	0.74	11.09	3.1	10.33
10	0.76	13.31	3.07	12.46
11	0.64	16.51	2.91	16.46

TABLE 3. RESULTS FROM THE TRAINING PROCESS IN CASE OF INTERTURN FAULTS

Number of neurons in the first hidden layer	High Voltage Winding		Low Voltage Winding	
	MAPE of Test set (%)	Time used in training process (minute)	MAPE of Test set (%)	Time used in training process (minute)
2	2.039	5.48	1.803	5.42
3	1.573	8.06	1.541	7.37
4	1.244	10.36	1.492	11.40
5	1.170	13.58	1.554	16.10
6	1.115	17.27	1.541	21.43
7	1.122	22.25	1.512	29.55
8	1.106	28.42	1.469	41.09
9	1.142	36.09	1.505	53.46
10	1.080	49.13	1.496	63.17
11	1.078	56.17	1.529	66.11




Fig. 12. Comparison an average accuracy of winding to ground faults at various lengths of the winding (subcoil a as shown in Fig. 4) among the phase that faults occur




Fig. 13. Comparison an average accuracy of interturn faults at various lengths of the winding (subcoil a as shown in Fig. 7) among the phase that faults occur




Fig. 14. Comparison an average accuracy of interturn faults at various lengths of the winding (subcoil b as shown in Fig. 7) among the phase that faults occur

TABLE 4. THE RESULTS FROM TEST PROCESS FOR CLASSIFYING FAULT TYPES

Types of faults	Number of case studies	Accuracy
Winding to ground fault at the high voltage side	81	91.36%
Winding to ground fault at the low voltage side	81	100%
Interturn fault at the high voltage side	324	95.06%
Interturn fault at the low voltage side	324	99.38%

TABLE 5. THE RESULTS FROM TEST PROCESS FOR FAULT POSITIONS OF WINDING TO GROUND FAULTS

Winding to ground fault	Maximum error	Minimum error	Average error
High voltage winding	0.0322	0.0001	0.0089
Low voltage winding	0.0621	0.0001	0.0211

TABLE 6. THE RESULTS FROM TEST PROCESS FOR FAULT POSITIONS OF INTERTURN FAULTS

Interturn fault	Maximum error	Minimum error	Average error
High voltage winding	0.0524	0.0024	0.0258
Low voltage winding	0.05	0.0001	0.0227

#### IV. CONCLUSIONS

A novel differential protective scheme for a power transformer has been proposed. The technique employs the discrete wavelet transform in combination with back propagation neural networks in order to identify types of faults, to locate the phase which faults occur and to detect the fault positions along the transformer windings. The maximum coefficient from the first scale at  $\frac{1}{4}$  cycle of phase A, B, and C of post-fault differential current signals and zero sequence current obtained by the wavelet transform have been used as an input for the training process of a neural network in a decision algorithm with a use of the back propagation neural networks. Many case studies have been studied including the variation of fault inception angles and fault locations. The results have illustrated that the proposed algorithm gives a satisfactory accuracy as presented in Tables 4-6.

#### REFERENCES

- [1] S.H. Horowitz and A.G. Phadke, *Power System Relaying*, John Wiley & Sons INC, 1992.
- [2] A.G. Phadke and J.S. Thorp, "A new computer-based flux restrained current-differential relay for power transformer protection," *IEEE Transactions on Power Apparatus and System*, pp.3624-3629, November 1983.
- [3] T.S. Sidhu and M.S. Sachdev, "On-line identification of magnetizing inrush current and internal faults in three-phase transformers," *IEEE Transactions on Power Delivery*, pp. 1885-1891, October 1992.
- [4] P. Bastard, P. Bertrand and M. Meunier, "A transformer model for winding fault studies," *IEEE Transactions on Power Delivery*, pp. 690-699, April 1994.
- [5] H. Wang and K.L. Butler, "Modeling transformers with internal incipient faults," *IEEE Transactions on Power Delivery*, pp. 500-509, April 2002.
- [6] M.G. Morante and D.W. Nocoletti, "A wavelet-based differential transformer protection," *IEEE Transactions on Power Delivery*, pp.1352-1358, October 1999.
- [7] O.A.S. Youssef, "A wavelet-base technique for discrimination between faults and magnetizing inrush currents in transformers," *IEEE Transactions on Power Delivery*, pp. 170-176, January 2003.
- [8] P. Purkait and S. Chakravorti, "Wavelet transform-based impulse fault pattern recognition in distribution transformers," *IEEE Transactions on Power Delivery*, pp. 1588-1589, October 2003.
- [9] A. Ngaopitakkul, A.Kunakorn and I.Ngamroo, "Discrimination between External Short Circuits and Internal Faults in Transformer Windings using Discrete Wavelet Transforms," *40<sup>th</sup> IEEE Industries Application Society Annual Conference*, Hongkong, October 2005.
- [10] ABB Thailand, *Test report no. 56039*.
- [11] H. Demuth and M. Beale, *Neural Network Toolbox User's Guide*, The Math Work, March 2001.

## ประวัติผู้เขียน

ชื่อ-นามสกุล	นาย อรรถพล เก่าพิทักษ์กุล
วัน เดือน ปีเกิด	28 สิงหาคม 2521 ที่จังหวัดสุราษฎร์ธานี
ที่อยู่	448/46 ถนนตลาดใหม่ ตำบลตลาด อำเภอเมืองสุราษฎร์ธานี 84000
ประวัติการศึกษา	2545 วิศวกรรมศาสตรบัณฑิต สาขาวิชาวิศวกรรมไฟฟ้ากำลัง สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง 2547 วิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมไฟฟ้ากำลัง สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
ผลงานวิจัย	ผลงานวิชาการที่ได้รับการตีพิมพ์ในการประชุมวิชาการและ วารสารวิชาการระดับนานาชาติทางด้านวิศวกรรมไฟฟ้าระหว่างศึกษา ปริญญาเอก 5 บทความ