


อัลกอริทึมสำหรับตรวจจับการหกล้มของมนุษย์จากสัญญาณความเร่ง
โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม

AN ALGORITHM FOR DETECTING HUMAN FALL FROM ACCELERATION
SIGNALS USING WAVELET TRANSFORMS AND NEURAL NETWORK



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมชีวการแพทย์

คณะวิศวกรรมศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ.2559

KMITL-2016-EN-M-045-016

อัลกอริทึมสำหรับตรวจจับการหกล้มของมนุษย์จากสัญญาณความเร่ง
โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม

AN ALGORITHM FOR DETECTING HUMAN FALL FROM ACCELERATION SIGNALS USING WAVELET TRANSFORMS AND NEURAL NETWORK



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชาวิศวกรรมชีวการแพทย์
คณะวิศวกรรมศาสตร์
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
พ.ศ. 2559
KMITL-2016-EN-M-045-016

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

AN ALGORITHM FOR DETECTING HUMAN FALL FROM ACCELERATION SIGNALS USING WAVELET TRANSFORMS AND NEURAL NETWORK



**A THESIS SUBMITTED IN PARTIAL FULFILLMENT
OF THE REQUIREMENT FOR THE DEGREE OF
MASTER OF ENGINEERING IN BIOMEDICAL ENGINEERING
FACULTY OF ENGINEERING
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG
2016
KMITL-2016-EN-M-045-016**

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



**COPYRIGHT 2016
FACULTY OF ENGINEERING
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG**

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

คณะวิศวกรรมศาสตร์
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
ใบรับรองวิทยานิพนธ์

หัวข้อวิทยานิพนธ์ อัลกอริทึมสำหรับตรวจจับการหกล้มของมนุษย์จากสัญญาณความเร่งโดยใช้
การแปลงเวฟเลตและโครงข่ายประสาทเทียม
Thesis Title An Algorithm for Detecting Human Fall from Acceleration Signals using
Wavelet Transforms and Neural Network
นักศึกษา นายนิติพัฒน์ ณ์ัฐไทรธนกุล
รหัสประจำตัว 55612714
ปริญญา วิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชา วิศวกรรมชีวการแพทย์
อาจารย์ที่ปรึกษาวิทยานิพนธ์ ดร.เทอดศักดิ์ ลีวาทอง
หมายเลขวิทยานิพนธ์ KMITL-2016-EN-M- 045-016

คณะกรรมการสอบวิทยานิพนธ์		ลายมือชื่อ
ผศ.ดร.กิตติพล	ชิตสกุล	
ดร.สุรเดช	ตรีไตรลักษณะ	
รศ.ดร.มนัส	สังวรศิลป์	
รศ.ดร.สุรพันธุ์	เอื้อไพบูลย์	
ดร.เทอดศักดิ์	ลีวาทอง	

วัน / เดือน / ปี ที่สอบ วันจันทร์ที่ 15 กุมภาพันธ์ พ.ศ. 2559 เวลา 10.00-12.00 น.
สถานที่สอบ ณ อาคาร A ชั้น 5 ห้องประชุม 3

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

คณะวิศวกรรมศาสตร์ รับรองแล้ว



(รองศาสตราจารย์ ดร. คมสัน มาลีสี)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่ออนุญาตให้นำไปเผยแพร่โดยไม่ได้รับอนุญาต
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงชื่อของสถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
วันที่ 15 กุมภาพันธ์ พ.ศ. 2559

หัวข้อวิทยานิพนธ์	อัลกอริทึมสำหรับตรวจจับการหกล้มของมนุษย์จากสัญญาณ ความเร่งโดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม
นักศึกษา	นายนิติพัฒน์ ญัฐไธธนกุล
รหัสประจำตัว	55612714
ปริญญา	วิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชา	วิศวกรรมชีวการแพทย์
พ.ศ.	2559
อาจารย์ที่ปรึกษาวิทยานิพนธ์	ดร.เทอดศักดิ์ ลีวหาทอง

บทคัดย่อ

การหกล้มเป็นปัญหาที่สำคัญที่อาจเกิดขึ้นกับผู้สูงอายุและอาจทำให้เป็นอัมพาต, กระดูก
สะโพกหัก, พิกการ, หรือเสียชีวิตได้ การคัดแยกกิจกรรมต่างๆของมนุษย์จากสัญญาณความเร่งจะเป็น
กระบวนการที่สำคัญในการตรวจจับการหกล้มได้ อัลกอริทึมที่ผสมผสานกันระหว่างการแปลงเวฟเลต
และโครงข่ายประสาทเทียมจะเป็นเครื่องมือที่มีประสิทธิภาพสำหรับการคัดแยกสัญญาณที่มีความ
ซับซ้อนได้ เพื่อเพิ่มประสิทธิภาพการคัดแยก ในวิทยานิพนธ์เล่มนี้มีวัตถุประสงค์เพื่อเปรียบเทียบผล
การดำเนินงานของอัลกอริทึมโดยใช้ความแตกต่างของเวฟเลตแม่และจำนวนโหนดในชั้นซ่อน ในการ
ทดลองประกอบด้วยอาสาสมัคร 5 คนที่มีสุขภาพดี อายุระหว่าง 21 – 25 ปี ได้ขอให้ติดเซ็นเซอร์วัด
ความเร่งไว้ที่เอวด้านขวาแล้วขอร้องให้อาสาสมัครทำกิจวัตรประจำวัน 5 กิจกรรมคือ 1) การเดิน, 2)
ลุกขึ้นจากเก้าอี้, 3) นั่งลงบนเก้าอี้, 4) นอนลงบนที่นอน, 5) ลุกขึ้นจากที่นอน และ ทำการหกล้ม 5
แบบ คือ 1) หกล้มไปด้านหน้า, 2) หกล้มไปด้านหลัง, 3) หกล้มไปด้านขวา, 4) หกล้มไปด้านซ้าย, 5)
หกล้มในขณะที่กำลังยืนขึ้น ในวิทยานิพนธ์เล่มนี้มีการทดลอง 2 การทดลอง ในการทดลองแรก
อัลกอริทึมถูกใช้เพื่อคัดแยกกิจกรรมต่างๆจากสัญญาณความเร่ง ดังนั้นเอาต์พุตของอัลกอริทึมจะมี
ทั้งหมด 10 กิจกรรม จะมีทั้งกิจวัตรประจำวันและการหกล้มแบบต่างๆ ในการทดลองที่สอง
อัลกอริทึมจะถูกใช้ในการตรวจจับการหกล้ม ดังนั้นเอาต์พุตของอัลกอริทึมจะมี 2 เอาต์พุต; เหตุการณ์
การหกล้ม หรือ กิจวัตรประจำวัน เวฟเลตแม่ที่ถูกใช้ในวิทยานิพนธ์เล่มนี้คือ **Daubechies, Coiflets,**
Symlets, และ **Biorthogonals**

Thesis	An Algorithm for Detecting Human Fall from Acceleration Signals Using Wavelet Transforms and Neural Network
Student	Mr. Nitipat Nuttaitanakul
Student ID.	55612714
Degree	Master of Engineering
Program	Biomedical Engineering
Year	2016
Thesis Advisor	Dr. Thursak Leauhatong

ABSTRACT

Falls are major problems that could happen to elderlies, and could cause paralysis, hip fractures, disabilities or accidental deaths. A human activity classification from acceleration signals may be an important process in fall detection. An algorithm which combines the wavelet transforms and the multilayer perceptron neural network is an effective tool for classifying complicate signals. In order to optimize the classification, this thesis aims to compare the performances of the algorithm which uses different mother wavelets and the number of nodes in the hidden layer. In our experiments, 5 healthy volunteers of ages between 21 to 25 year old were asked to attach a tri-axial accelerometer at the right side of their waists. Next, the volunteers were asked to perform 5 daily-life activities: 1) walking, 2) standing up from a chair, 3) sitting down on a chair, 4) lying down on a bed, and 5) getting up from a bed; and 5 falling events: 1) forward falling, 2) backward falling, 3) falling to the right side, 4) falling to the left side, and 5) falling when standing up. In this thesis, 2 experiments are presented. In the first experiment, the algorithm is used to classify the real activity of the acceleration signals. Then the output of the algorithm can be any activity from ten activities both daily life and falling events. In the second experiment, the algorithm is used to detect the falling events. Then the algorithm provides 2 outputs; the falling event or the daily-life activity. The mother wavelets which were used in the thesis were Daubechies, Coiflets, Symlets, and Biorthogonals.

กิตติกรรมประกาศ

วิทยานิพนธ์เล่มนี้สำเร็จได้ด้วยความกรุณาจากอาจารย์ที่ปรึกษา ดร.เทอดศักดิ์ ลีวาทอง ที่ให้ความช่วยเหลือ ให้คำชี้แนะช่วยแก้ปัญหาตลอดจนให้ความรู้ที่ดีแก่ข้าพเจ้า

ขอกราบขอบพระคุณคณาจารย์ภาควิชาวิศวกรรมอิเล็กทรอนิกส์วิชาการแพทย์ คณะวิศวกรรมศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง ทุกๆท่านที่ได้ประสิทธิ์ประสาทวิชาให้กับข้าพเจ้า

ขอขอบคุณ คุณอดุลย์เดช นิมนวล, คุณธีรวัฒน์ นารถอุดม, คุณเบญจวรรณ ประไพ์ชนัง ที่คอยให้คำปรึกษาชี้แนะแนวทางการออกแบบอุปกรณ์และโปรแกรมสำหรับทำการทดลอง

ขอขอบพระคุณ นักศึกษาสถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง ที่มีส่วนร่วมในการทดลอง

สุดท้ายนี้ข้าพเจ้าขอกราบขอบพระคุณ บิดา มารดา และครอบครัวของข้าพเจ้าที่เป็นกำลังใจ และให้การสนับสนุนในทุกๆเรื่องทำให้ข้าพเจ้าสามารถทำวิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงด้วยดี

สำหรับคุณงามความดีอันใดที่เกิดจากวิทยานิพนธ์ฉบับนี้ ข้าพเจ้าขอมอบให้กับบิดามารดา ซึ่งเป็นที่รักและเคารพยิ่ง ตลอดจนครูอาจารย์ที่เคารพทุกท่านที่ได้ประสิทธิ์ประสาทวิชาความรู้และถ่ายทอดประสบการณ์ที่ดีให้แก่ข้าพเจ้า

นิติพัฒน์ ญัฐไธธนกุล

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	I
บทคัดย่อภาษาอังกฤษ.....	II
กิตติกรรมประกาศ.....	III
สารบัญ.....	IV
สารบัญตาราง.....	VII
สารบัญรูป.....	VIII
บทที่ 1 บทนำ.....	1
1.1 ความเป็นมาและความสำคัญของปัญหา.....	1
1.2 ความมุ่งหมายและวัตถุประสงค์ของการศึกษา.....	1
1.3 สมมุติฐานของการศึกษา.....	1
1.4 แนวความคิดที่ใช้ในการวิจัย.....	2
1.5 ขอบเขตการวิจัย.....	3
1.6 คำโครงการวิทยานิพนธ์.....	3
บทที่ 2 งานวิจัยและทฤษฎีที่เกี่ยวข้อง.....	4
2.1 การเปลี่ยนแปลงสุขภาพของผู้สูงอายุ.....	4
2.1.1 ระบบการทำหน้าที่ของหัวใจและหลอดเลือด (Cardiovascular function).....	4
2.1.2 ระบบการทำหน้าที่ทางเดินหายใจ (Respiratory Function).....	5
2.1.3 ระบบกล้ามเนื้อและกระดูก.....	5
2.1.4 ระบบประสาทและต่อมไร้ท่อ.....	7
2.2 การหกล้มในผู้สูงอายุ.....	8
2.2.1 ปัจจัยภายในบุคคล.....	8
2.2.1.1 ปัจจัยที่เกิดจากกระบวนการสูงวัย.....	8
2.2.1.2 ปัจจัยที่เกิดจากกระบวนการเจ็บป่วย.....	9
2.2.2 ปัจจัยภายนอกบุคคล.....	10
2.3 งานวิจัยที่เกี่ยวข้อง.....	11
2.3.1 กลุ่มงานวิจัยที่นำเสนอการตรวจจับการหกล้มโดยใช้เสียง.....	11
2.3.2 กลุ่มงานวิจัยที่นำเสนอการตรวจจับการหกล้มโดยใช้ภาพ.....	12
2.3.3 กลุ่มงานวิจัยที่นำเสนอการตรวจจับการหกล้มโดยใช้เซ็นเซอร์วัดการสั่นสะเทือน.....	13
2.3.4 กลุ่มงานวิจัยที่นำเสนอการตรวจจับการหกล้มโดยใช้เซ็นเซอร์วัดความเร่ง.....	14
2.4 ทฤษฎีที่เกี่ยวข้อง.....	17
2.4.1 ทฤษฎีการแปลงเวฟเลต (Wavelet Transforms).....	17
2.4.1.1 ทฤษฎีการประมาณค่า (Approximation).....	17
2.4.1.2 ตัวอย่างการประมาณสัญญาณดิสครีตทางเวลาโดยฟังก์ชันเดลต้า.....	18
2.4.1.3 การสร้าง Basis โดยการสเกล.....	19

สารบัญ(ต่อ)

	หน้า
2.4.1.4 การวิเคราะห์ Multiresolution.....	21
2.4.1.5 การแปลงดิสครีตเวฟเลต (Discrete Wavelet Transform).....	24
2.4.1.6 การแปลงเวฟเลตแบบเร็ว (Fast Wavelet Transform).....	24
2.4.1.7 Mother Wavelet.....	26
2.4.1.7.1 Haar Mother Wavelet.....	26
2.4.1.7.2 Daubechies Mother Wavelet.....	27
2.4.1.7.3 Symlet Mother Wavelet.....	30
2.2.1.7.4 Coiflet Mother Wavelet.....	32
2.2.1.7.5 Biorthogonal Mother Wavelet.....	34
2.4.2 ทฤษฎีโครงข่ายประสาทเทียม.....	38
2.4.2.1 โครงข่ายประสาทเชิงชีววิทยา (Biological Neural Network).....	38
2.4.2.2 โครงข่ายประสาทเทียม (Artificial Neural Network).....	40
2.4.2.3 โครงข่ายประสาทเทียมอย่างง่าย (Single layer perceptron).....	42
2.4.2.4 โครงข่ายประสาทเทียมแบบหลายชั้น (Multi-layer Perceptron).....	45
2.4.2.5 ฟังก์ชันถ่ายโอน (Activation Function or Transfer Function).....	47
2.4.2.6 กฎการเรียนรู้ (Learning Rule).....	48
2.4.2.6.1 การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning).....	49
2.4.2.6.2 การเรียนรู้แบบมีผู้สอน (Supervised).....	51
2.4.2.7 Back Propagation Neural Network, (BPNN).....	52
บทที่ 3 ขั้นตอนการวิจัยระบบตรวจจับการหลั้ม.....	54
3.1 ระบบวัดสัญญาณความเร่งจากการเคลื่อนไหวและการหลั้ม.....	54
3.1.1 เซ็นเซอร์วัดความเร่ง.....	55
3.1.2 ไมโครคอนโทรลเลอร์.....	56
3.1.3 บลูทูธ.....	57
3.1.4 ลักษณะของสัญญาณความเร่งจากการเคลื่อนไหว.....	57
3.2 อัลกอริทึมที่นำเสนอสำหรับตรวจจับสัญญาณการหลั้ม.....	61
3.2.1 การดึงคุณลักษณะของสัญญาณโดยใช้การแปลงเวฟเลต.....	61
3.2.2 การตัดแยกสัญญาณการเคลื่อนไหวและการหลั้มของมนุษย์โดยใช้โครงข่าย ประสาทเทียมแบบแพร่ย้อนกลับ.....	65
บทที่ 4 การทดลองและผลการทดลอง.....	68
4.1 การวัดสัญญาณความเร่ง.....	68
4.2 การวัดประสิทธิภาพของระบบตรวจจับการหลั้ม.....	69
4.3 การทดลองและผลการทดลอง.....	71
4.3.1 การตัดแยกกิจกรรมของมนุษย์ (Human Activity Classification).....	71
4.3.1.1 ผลการทดลองการตัดแยกกิจกรรมของมนุษย์ด้วยสัญญาณความเร่ง แกน X โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม.....	73

สารบัญ(ต่อ)

	หน้า
4.3.1.2 ผลการทดลองการคัดแยกกิจกรรมของมนุษย์ด้วยสัญญาณความเร่ง แกน Y โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม.....	74
4.3.1.3 ผลการทดลองการคัดแยกกิจกรรมของมนุษย์ด้วยสัญญาณความเร่ง แกน Z โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม.....	75
4.3.1.4 ผลการทดลองการคัดแยกกิจกรรมของมนุษย์ด้วยสัญญาณความเร่ง แกน XYZ โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม.....	76
4.3.1.5 สรุปผลการทดลองการคัดแยกกิจกรรมของมนุษย์ด้วยสัญญาณความเร่งโดย ใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม.....	77
4.3.2 การทดลองการตรวจจับการหกล้มของมนุษย์ (Falling Detection).....	78
4.3.2.1 ผลการทดลองการตรวจจับการหกล้มของมนุษย์ด้วยสัญญาณความเร่ง แกน X โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม.....	80
4.3.2.2 ผลการทดลองการตรวจจับการหกล้มของมนุษย์ด้วยสัญญาณความเร่ง แกน Y โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม.....	81
4.3.2.3 ผลการทดลองการตรวจจับการหกล้มของมนุษย์ด้วยสัญญาณความเร่ง แกน Z โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม.....	82
4.3.2.4 ผลการทดลองการตรวจจับการหกล้มของมนุษย์ด้วยสัญญาณความเร่ง แกน XYZ โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม.....	83
4.3.2.5 สรุปผลการทดลองการตรวจจับการหกล้มของมนุษย์ด้วยสัญญาณความเร่ง โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม.....	84
บทที่ 5 สรุปผลการทดลอง.....	85
เอกสารอ้างอิง.....	86
ภาคผนวก ก ผลงานที่ได้รับการตีพิมพ์.....	90
ประวัติผู้เขียน.....	97

สารบัญตาราง

ตารางที่	หน้า
2.1 ค่าสัมประสิทธิ์สเกลและเวฟเลตฟังก์ชันของ Daubechies Wavelet ตั้งแต่ D2-D20.....	27
2.2 ค่าสัมประสิทธิ์สเกลและเวฟเลตฟังก์ชันของ Symlet Wavelet ตั้งแต่ Sym2-Sym9.....	30
2.3 ค่าสัมประสิทธิ์สเกลและเวฟเลตของฟังก์ชัน Coiflet Wavelet ตั้งแต่ Coif1-Coif5.....	32
2.4 ค่าสัมประสิทธิ์สเกลของฟังก์ชัน Biorthogonal Wavelet ตั้งแต่ Bior1.1-Bior6.8.....	35
2.5 ฟังก์ชันการถ่ายโอนแบบต่างๆ.....	48
3.1 แสดงรายละเอียดโครงสร้างของเซ็นเซอร์วัดความเร่ง (EL-MMA7331L).....	55
3.2 แสดงย่านของการวัดความเร่ง (EL-MMA7331L).....	56
3.3 แสดงการกำหนดค่าตัวเลขของเซลล์ประสาทเทียมขาออก (Output Neuron) ของการคัดแยกสัญญาณการเคลื่อนไหวของมนุษย์.....	66
3.4 แสดงการกำหนดค่าตัวเลขของเซลล์ประสาทเทียมขาออก (Output Neuron) ของการคัดแยกสัญญาณการทก้มของมนุษย์.....	67
4.1 จำนวนครั้งของแต่ละกิจกรรมของอาสาสมัคร รวมทั้งหมด 1,500 สัญญาณ.....	69
4.2 ปัจจัยของการทดลอง.....	69
4.3 แสดงรายละเอียดของจำนวนสัญญาณของการจำลองกิจกรรมต่างๆที่ใช้สำหรับการฝึกสอน และทดสอบของโครงข่ายประสาทเทียมสำหรับการคัดแยกกิจกรรมของมนุษย์.....	72
4.4 แสดงผลการทดลองการคัดแยกกิจกรรมของมนุษย์ด้วยสัญญาณความเร่งแกน X โดยใช้การ แปลงเวฟเลตและโครงข่ายประสาทเทียมที่ให้ค่าความแม่นยำสูงสุด.....	73
4.5 แสดงผลการทดลองการคัดแยกกิจกรรมของมนุษย์ด้วยสัญญาณความเร่งแกน Y โดยใช้การ แปลงเวฟเลตและโครงข่ายประสาทเทียมที่ให้ค่าความแม่นยำสูงสุด.....	74
4.6 แสดงผลการทดลองการคัดแยกกิจกรรมของมนุษย์ด้วยสัญญาณความเร่งแกน Z โดยใช้การ แปลงเวฟเลตและโครงข่ายประสาทเทียมที่ให้ค่าความแม่นยำสูงสุด.....	75
4.7 แสดงผลการทดลองการคัดแยกกิจกรรมของมนุษย์ด้วยสัญญาณความเร่งแกน XYZ โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียมที่ให้ค่าความแม่นยำสูงสุด.....	76
4.8 สรุปผลการทดลองการคัดแยกกิจกรรมของมนุษย์ที่มีค่าความแม่นยำสูงสุด.....	77
4.9 แสดงรายละเอียดของการจำลองกิจกรรมต่างๆที่ใช้สำหรับการฝึกสอนและทดสอบของ โครงข่ายประสาทเทียมของการทดลองสำหรับการตรวจจับการทก้มของมนุษย์.....	78
4.10 แสดงผลทดลองการตรวจจับการทก้มของมนุษย์โดยใช้สัญญาณความเร่งแกน X โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียมที่ให้ค่าความแม่นยำสูงสุด.....	80
4.11 แสดงผลทดลองการตรวจจับการทก้มของมนุษย์โดยใช้สัญญาณความเร่งแกน Y โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียมที่ให้ค่าความแม่นยำสูงสุด.....	81
4.12 แสดงผลทดลองการตรวจจับการทก้มของมนุษย์โดยใช้สัญญาณความเร่งแกน Z โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียมที่ให้ค่าความแม่นยำสูงสุด.....	82
4.13 แสดงผลทดลองการตรวจจับการทก้มของมนุษย์โดยใช้สัญญาณความเร่งแกน XYZ โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียมที่ให้ค่าความแม่นยำสูงสุด.....	83
4.14 สรุปผลการทดลองการตรวจจับการทก้มของมนุษย์ที่มีค่าความแม่นยำสูงสุด.....	84
4.15 สรุปผลการทดลองการตรวจจับการทก้มของมนุษย์ที่มีค่า Pe น้อยที่สุด.....	84

สารบัญรูป

รูปที่	หน้า
2.1 แสดงการสูญเสียมวลกล้ามเนื้อ (Sarcopenia).....	6
2.2 แสดงภาวะการเปลี่ยนแปลงมวลกระดูกผู้สูงอายุ.....	6
2.3 รูปแบบการนำเสนอการตรวจจับการหกล้มของ Yun Li.....	11
2.4 รูปแบบการนำเสนอการตรวจจับการหกล้มของ Mihail Popescu.....	12
2.5 ตัวอย่างภาพการหกล้มและภาพจากกล้องของ M.Kreković.....	12
2.6 แสดงตัวอย่างโมเดลของ Samantha Ng.....	13
2.7 บล็อกไดอะแกรมของการตรวจจับและการตัดแยกการหกล้มของ Yaniv Zigel.....	13
2.8 แสดงสัญญาณและลักษณะการหกล้มของ Boyle	14
2.9 อัลกอริทึมสำหรับการตรวจจับสัญญาณการหกล้มของ Sengto	15
2.10 โครงสร้าง Neural network with weighted fuzzy membership function(NEWFM) ที่นำเสนอโดย Sang-Hong Lee.....	16
2.11 ผลลัพธ์ค่าประมาณของฟังก์ชันเดลต้า.....	19
2.12 รูปสเกลของ Basis ต่างๆ.....	20
2.13 ความสัมพันธ์ระหว่างพื้นที่ของสเกลฟังก์ชันและเวฟเลตฟังก์ชัน.....	22
2.14 ความสัมพันธ์ระหว่างสเกลฟังก์ชันและเวฟเลตฟังก์ชัน.....	23
2.15 บล็อกไดอะแกรมของการแปลงเวฟเลตแบบดิสครีต.....	25
2.16 ตัวอย่างสเกลและเวฟเลตฟังก์ชันของ Harr Wavelet	26
2.17 ตัวอย่างสเกลและเวฟเลตฟังก์ชันของ Daubechies Wavelet Vanishing Moment 10....	29
2.18 ตัวอย่างสเกลและเวฟเลตฟังก์ชันของ Symlet Wavelet	31
2.19 สเกลและเวฟเลตฟังก์ชันของ Coiflet Wavelet	33
2.20 สเกลและเวฟเลตฟังก์ชันของ Biorthogonal Wavelet	37
2.21 รายละเอียดของเซลล์ประสาทชีวภาพ.....	38
2.22 สัญญาณทางไฟฟ้าของระบบประสาท	39
2.23 แบบจำลองของ Sensory neurons, Motor neurons และ Interneurons.....	40
2.24 แผงผังโครงข่ายประสาท.....	41
2.25 แผงผังของเซลล์ประสาทชีวภาพและเซลล์ประสาทเทียม.....	42
2.26 ฟังก์ชันเชิงเส้น, ฟังก์ชันระดับ, ฟังก์ชันซิกมอยด์	44
2.27 ความสัมพันธ์ระหว่างเวกเตอร์น้ำหนัก และเวกเตอร์ขาเข้าของนิวรอน.....	45
2.28 การเรียนรู้แบบเพอร์เซพตรอนชั้นเดียว	45
2.29 โครงข่ายประสาทเทียมแบบหลายชั้น.....	47
2.30 โครงข่ายประสาทเทียมที่มีการเรียนรู้.....	50
2.31 ขั้นตอนการเรียนรู้แบบมีผู้สอน.....	51
2.32 โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN)	52
3.1 ลำดับขั้นตอนการวิจัยระบบตรวจจับการหกล้ม.....	54

สารบัญรูป(ต่อ)

รูปที่	หน้า
3.2 ระบบวัดสัญญาณการเคลื่อนไหว.....	54
3.3 รูปตำแหน่งของการติดระบบตรวจจับการล้ม.....	55
3.4 โครงสร้างเซ็นเซอร์วัดความเร่งแบบสามแกน (EL-MMA7331L).....	55
3.5 ตำแหน่งทิศทางของเซ็นเซอร์วัดความเร่งทั้ง 3 แกน.....	56
3.6 ไมโครคอนโทรลเลอร์ยี่ห้อ MICROCHIP รุ่น PIC32MX460F512L.....	56
3.7 บลูทูธ (BC147).....	57
3.8 สัญญาณการหกล้มไปด้านหน้าในระยะเวลา 2 วินาที.....	58
3.9 แสดงสัญญาณการเคลื่อนไหวประเภทการเดิน.....	58
3.10 แสดงสัญญาณการเคลื่อนไหวประเภทกำลังนั่งลงเก้าอี้.....	58
3.11 แสดงสัญญาณการเคลื่อนไหวประเภทกำลังลุกจากเก้าอี้.....	59
3.12 แสดงสัญญาณการเคลื่อนไหวประเภทกำลังล้มตัวลงนอนบนที่นอน.....	59
3.13 แสดงสัญญาณการเคลื่อนไหวประเภทกำลังลุกจากที่นอน.....	59
3.14 แสดงสัญญาณการเคลื่อนไหวประเภทหกล้มไปด้านหน้า.....	60
3.15 แสดงสัญญาณการเคลื่อนไหวประเภทหกล้มไปด้านหลัง.....	60
3.16 แสดงสัญญาณการเคลื่อนไหวประเภทหกล้มไปด้านซ้าย.....	60
3.17 แสดงสัญญาณการเคลื่อนไหวประเภทหกล้มไปด้านขวา.....	61
3.18 แสดงสัญญาณการเคลื่อนไหวประเภทหกล้มในขณะที่กำลังยืน.....	61
3.19 การแยกองค์ประกอบสัญญาณความเร่งโดยใช้หลักการของพีวเตอร์แบงค์.....	62
3.20 การแปลงแบบเวฟเลทแบบไม่ต่อเนื่องโดยพื้นฐานการวิเคราะห์แบบ multi-resolution....	62
3.21 ลักษณะสัญญาณความเร่งแกน X จากการหกล้มไปด้านหน้าด้วยการแปลงเวฟเลต Daubechies2 ระดับที่ 1.....	63
3.22 ลักษณะสัญญาณความเร่งแกน X จากการหกล้มไปด้านหน้าด้วยการแปลงเวฟเลต Daubechies2 ระดับที่ 2.....	63
3.23 ลักษณะสัญญาณความเร่งแกน X จากการหกล้มไปด้านหน้าด้วยการแปลงเวฟเลต Daubechies2 ระดับที่ 3.....	63
3.24 ลักษณะสัญญาณความเร่งแกน X จากการหกล้มไปด้านหน้าด้วยการแปลงเวฟเลต Coiflet1 ระดับที่ 1.....	63
3.25 ลักษณะสัญญาณความเร่งแกน X จากการหกล้มไปด้านหน้าด้วยการแปลงเวฟเลต Coiflet1 ระดับที่ 2.....	63
3.26 ลักษณะสัญญาณความเร่งแกน X จากการหกล้มไปด้านหน้าด้วยการแปลงเวฟเลต Coiflet1 ระดับที่ 3.....	64
3.27 ลักษณะสัญญาณความเร่งแกน X จากการหกล้มไปด้านหน้าด้วยการแปลงเวฟเลต Symlets2 ระดับที่ 1.....	64
3.28 ลักษณะสัญญาณความเร่งแกน X จากการหกล้มไปด้านหน้าด้วยการแปลงเวฟเลต Symlets2 ระดับที่ 2.....	64

สารบัญรูป(ต่อ)

รูปที่	หน้า
3.29 ลักษณะสัญญาณความเร่งแกน X จากการหกล้มไปด้านหลังด้วยการแปลงเวฟเลต Symlets2 ระดับที่ 3.....	64
3.30 ลักษณะสัญญาณความเร่งแกน X จากการหกล้มไปด้านหลังด้วยการแปลงเวฟเลต Biorthogonal1.1 ระดับที่ 1.....	64
3.31 ลักษณะสัญญาณความเร่งแกน X จากการหกล้มไปด้านหลังด้วยการแปลงเวฟเลต Biorthogonal1.1 ระดับที่ 2.....	65
3.32 ลักษณะสัญญาณความเร่งแกน X จากการหกล้มไปด้านหลังด้วยการแปลงเวฟเลต Biorthogonal1.1 ระดับที่ 3.....	65
3.33 โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN) ที่ใช้ในการจดจำรูปแบบของการคัดแยกสัญญาณการเคลื่อนไหวของมนุษย์.....	66
3.34 โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN) ที่ใช้ในการจดจำรูปแบบของการคัดแยกสัญญาณการหกล้มของมนุษย์.....	67
4.1 ขั้นตอนการทดลอง.....	68
4.2 แสดงการประเมินประสิทธิภาพของระบบที่นำเสนอ.....	71
4.3 แสดงการคัดแยกกิจกรรมของมนุษย์.....	71
4.4 แสดงโครงสร้างของโครงข่ายประสาทเทียมสำหรับการทดลองคัดแยกกิจกรรมของมนุษย์โดยใช้สัญญาณความเร่งแบบแกนเดียว.....	72
4.5 แสดงโครงสร้างของโครงข่ายประสาทเทียมสำหรับการทดลองคัดแยกกิจกรรมของมนุษย์โดยใช้สัญญาณความเร่งแบบสามแกน.....	72
4.6 กราฟแสดงผลการทดลองการคัดแยกกิจกรรมของมนุษย์ด้วยสัญญาณความเร่งแกน X โดยการใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม.....	73
4.7 กราฟแสดงผลการทดลองการคัดแยกกิจกรรมของมนุษย์ด้วยสัญญาณความเร่งแกน Y โดยการใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม.....	74
4.8 กราฟแสดงผลการทดลองการคัดแยกกิจกรรมของมนุษย์ด้วยสัญญาณความเร่งแกน Z โดยการใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม.....	75
4.9 กราฟแสดงผลการทดลองการคัดแยกกิจกรรมของมนุษย์ด้วยสัญญาณความเร่งแกน XYZ โดยการใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม.....	76
4.10 แสดงการตรวจจับการหกล้มของมนุษย์.....	78
4.11 แสดงโครงสร้างของโครงข่ายประสาทเทียมสำหรับการทดลองตรวจจับการหกล้มของมนุษย์ โดยใช้สัญญาณความเร่งแบบแกนเดียว.....	79
4.12 แสดงโครงสร้างของโครงข่ายประสาทเทียมสำหรับการทดลองตรวจจับการหกล้มของมนุษย์ โดยใช้สัญญาณความเร่งแบบสามแกน.....	79
4.13 กราฟแสดงผลการทดลองตรวจจับการหกล้มของมนุษย์ด้วยสัญญาณความเร่งแกน X โดยการใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม.....	80

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญรูป(ต่อ)

รูปที่	หน้า
4.14 กราฟแสดงผลการทดลองตรวจจับการหักมุมของมนุษย์ด้วยสัญญาณความเร่งแกน Y โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม.....	81
4.15 กราฟแสดงผลการทดลองตรวจจับการหักมุมของมนุษย์ด้วยสัญญาณความเร่งแกน Z โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม.....	82
4.16 กราฟแสดงผลการทดลองตรวจจับการหักมุมของมนุษย์ด้วยสัญญาณความเร่งแกน XYZ โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม.....	83



บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

จากรายงานของวิทยาลัยประชากรศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย [1] เกี่ยวกับสถานการณ์ประชากรประเทศไทยพบว่า ในปี พ.ศ. 2553 ประชากรผู้สูงอายุที่มีอายุมากกว่า 60 ปีมีจำนวนร้อยละ 13 ของประชากรทั้งหมด และมีแนวโน้มเพิ่มขึ้นเป็นร้อยละ 32 ภายในปี พ.ศ. 2583 การที่มีผู้สูงอายุจำนวนมากทำให้ปัญหาสุขภาพของผู้สูงอายุกลายเป็นปัญหาที่ตระหนักรู้เป็นพิเศษ โดยเฉพาะการหกล้มนับเป็นปัญหาที่ร้ายแรง และอันตรายมากที่สุด นอกจากนี้การหกล้มยังส่งผลทำให้ผู้สูงอายุที่เคยหกล้มกลัวการหกล้ม ทำให้ส่งผลต่อการทำกิจกรรมอื่นๆ หรือบางครั้งอาจไม่สามารถอยู่คนเดียวได้ ด้วยสาเหตุดังกล่าวจึงทำให้ระบบเฝ้าระวังดูแลผู้สูงอายุที่สามารถตรวจจับการหกล้มและแจ้งเตือนอย่างทันที่นั้นมีความจำเป็นอย่างยิ่งต่อการลดอัตราการสูญเสียชีวิต หรือทุพพลภาพอันเนื่องมาจากการหกล้ม

1.2 ความมุ่งหมายและวัตถุประสงค์ของการศึกษา

วิทยานิพนธ์เล่มนี้มุ่งเน้นศึกษาการประดิษฐ์ระบบตรวจวัดสัญญาณความเร่ง และพัฒนาอัลกอริทึมการตรวจจับการหกล้มที่มีความถูกต้องแม่นยำ และใช้เวลาการประมวลผลที่รวดเร็ว ซึ่งได้นำ การแปลงเวฟเลต (Wavelet transform) และ ทฤษฎีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BackPropagation Neural Network) มาเป็นเครื่องมือในการจำแนกกิจกรรมของการเคลื่อนไหวของสัญญาณความเร่ง โดยผู้วิจัยได้ทำการวัดสัญญาณความเร่งของกิจกรรมในชีวิตประจำวัน 5 แบบคือ เดิน กำลังนั่งลงเก้าอี้ กำลังลุกจากเก้าอี้ กำลังล้มตัวลงนอนบนที่นอน กำลังลุกจากที่นอน และสัญญาณความเร่งของการหกล้ม 5 แบบคือ กำลังหกล้มไปด้านหน้า กำลังหกล้มไปด้านหลัง กำลังหกล้มไปด้านซ้าย กำลังหกล้มไปด้านขวา หกล้มในขณะที่กำลังยืน จากอาสาสมัครสุขภาพดีอายุประมาณ 21-25 ปี จำนวน 5 คน (ผู้ชาย 4 คน และผู้หญิง 1 คน) เพื่อนำสัญญาณความเร่งของแต่ละกิจกรรมมาใช้ทดสอบประสิทธิภาพ

1.3 สมมุติฐานของการศึกษา

เนื่องจากการตรวจจับการหกล้มในอดีตเช่น [2,3] ใช้อัลกอริทึมตรวจจับการหกล้มด้วยการตั้งค่าขีดเริ่ม และการจำแนกกลุ่มข้อมูลที่สามารถแบ่งกลุ่มข้อมูลได้อย่างมีประสิทธิภาพด้วยการจดจำรูปแบบ (Pattern Recognition) โดยใช้โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับที่สามารถเรียนรู้รูปแบบสัญญาณใหม่ๆ แต่จากการศึกษาพบว่าอัลกอริทึมนี้ไม่เพียงพอต่อการแยกประเภทสัญญาณการหกล้มและการเคลื่อนไหว บทความ [4, 5, 6, 18, 19, 20, 21 และ 39] ใช้เวฟเลตเพื่อดึงคุณลักษณะของสัญญาณเพื่อเพิ่มประสิทธิภาพสำหรับการวิเคราะห์สัญญาณโดยเป็นการแยกสัญญาณอินพุตออกเป็นสองส่วน โดยแบ่งออกเป็นส่วนของความถี่ต่ำและส่วนของความถี่สูง ดังนั้นวิทยานิพนธ์เล่มนี้ได้พัฒนาอัลกอริทึมดังกล่าวให้มีประสิทธิภาพสูงขึ้นโดยประกอบด้วย 2 ขั้นตอนคือ 1) การแปลง

เวฟเลต ,และ 2) การจำแนกสัญญาณการเคลื่อนไหว และการหกล้มด้วยวิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ

1.4 แนวความคิดที่ใช้ในการวิจัย

จากการทบทวนงานวิจัยในอดีตพบว่า ระบบตรวจจับการหกล้มของผู้สูงอายุ สามารถแบ่งออกเป็น 4 กลุ่ม ดังนี้ กลุ่มแรกเป็นการตรวจจับการหกล้มโดยใช้เสียง [8, 9] กลุ่มต่อมาได้นำเสนอโดยใช้กล้อง [10, 11] กลุ่มต่อมาใช้เซ็นเซอร์วัดการสั่นสะเทือน[12] และ กลุ่มสุดท้ายได้นำเสนอการเลือกใช้เซ็นเซอร์วัดความเร่ง หรือ เซ็นเซอร์ความเร่งเชิงมุม[2, 3, 4, 13 และ 39] เป็นต้น

สำหรับระบบตรวจจับการหกล้มของผู้สูงอายุที่ใช้ไมโครโฟนหรือกล้อง (ทั้งที่ใช้ร่วม หรือ ที่ไม่ได้ใช้ร่วมกับเซ็นเซอร์วัดความเร่ง) นั้นนำไปประยุกต์ใช้งานกับอุปกรณ์อื่นได้ยาก และ อาจนำไปสู่ปัญหาบางปัญหา เช่น ระบบที่ใช้กล้องจะต้องติดตั้งในพื้นที่ที่กำหนดจึงทำให้ไม่สะดวกแก่ผู้ใช้นอกจากนี้ก็ยังต้องใช้คอมพิวเตอร์ประสิทธิภาพสูงในการประมวลผล และ ระบบตรวจจับภาพนั้นยังเป็นการละเมิดความเป็นส่วนตัวของผู้ใช้อีกด้วย ในส่วนระบบตรวจจับการหกล้มที่ใช้ไมโครโฟนเป็นระบบที่ง่ายต่อการเกิดสัญญาณรบกวนจากสภาพแวดล้อมเช่น เสียงดังจากการปิดประตู เสียงจากสิ่งมีชีวิต เป็นต้น โดยสัญญาณรบกวนนี้จะทำให้ประสิทธิภาพของการประมวลผลสัญญาณ ในการตรวจจับการหกล้มลดลง ในส่วนระบบตรวจจับการหกล้มที่ใช้เซ็นเซอร์วัดการสั่นสะเทือนก็เป็นระบบที่ง่ายต่อการเกิดสัญญาณรบกวน โดยสภาพแวดล้อมเช่นกัน

เนื่องจากความก้าวหน้าของเทคโนโลยีของเซ็นเซอร์วัดความเร่งในปัจจุบัน ทำให้สามารถสร้างระบบวัดการเคลื่อนไหวที่มีขนาดเล็กและน้ำหนักเบา ซึ่งมีข้อดีคือสามารถติดกับตัวของผู้สูงอายุได้ตลอดเวลา และสัญญาณความเร่งจากการเคลื่อนไหวที่วัดได้จะไม่ถูกรบกวนจากสิ่งรบกวนภายนอกด้วยเหตุนี้ระบบตรวจจับการหกล้มที่ใช้เซ็นเซอร์วัดความเร่ง จึงถือได้ว่าเป็นระบบที่มีความน่าเชื่อถือมากกว่าระบบที่ใช้ไมโครโฟน กล้อง หรือ เซ็นเซอร์วัดการสั่นสะเทือน อีกทั้งยังทำให้ผู้สูงอายุเกิดความสะดวกสบาย เนื่องจากสามารถเคลื่อนไหวไปทุกที่ที่ต้องการ

กลุ่มงานวิจัยที่ใช้สัญญาณจากระบบตรวจวัดสัญญาณการเคลื่อนไหวด้วยเซ็นเซอร์วัดความเร่ง ได้นำเสนออัลกอริทึมตรวจจับการหกล้มที่อยู่บนพื้นฐานของกำหนดค่าขีดเริ่มของขนาดของความเร่ง และ ใช้โครงข่ายประสาทเทียม เช่น Jerene Jacob และ คณะ [2] ,Sengto [3] ได้พัฒนาอัลกอริทึมตรวจจับการหกล้มของมนุษย์ด้วยเซ็นเซอร์วัดความเร่งและความเร่งเชิงมุม

เพื่อที่จะเพิ่มประสิทธิภาพอัลกอริทึมของ Sengto วิทยานิพนธ์ฉบับนี้นำเสนออัลกอริทึมตรวจจับการหกล้มที่ได้ปรับปรุงจากอัลกอริทึมของ Sengto โดยใช้การแปลงเวฟเลต(Wavelet Transform) และ โครงข่ายประสาทเทียม(Neural Network)

ดังนั้นจากงานวิจัยในอดีตที่ผ่านมาจะเห็นได้ว่า องค์ประกอบของระบบตรวจจับการหกล้มมีอยู่ 2 ประการคือ การเลือกใช้ตัวตรวจจับ และอัลกอริทึมตรวจจับการหกล้ม ซึ่งวิทยานิพนธ์เล่มนี้จึงมุ่งเน้นเรื่องการพัฒนาาระบบวัดสัญญาณความเร่งของการเคลื่อนไหวโดยใช้เซ็นเซอร์วัดความเร่งเพียงอย่างเดียว และอัลกอริทึมตรวจจับการเคลื่อนไหวเพื่อแยกสัญญาณการหกล้มออกจากสัญญาณการเคลื่อนไหวประเภทอื่น

1.5 ขอบเขตการวิจัย

ขอบเขตของงานวิจัยชิ้นนี้มีสององค์ประกอบหลักคือ ระบบตรวจวัดสัญญาณความเร่งจากการเคลื่อนไหวและอัลกอริทึมสำหรับการตรวจจับการเคลื่อนไหวและการหกล้ม ซึ่งจะเรียกว่า “ระบบตรวจจับการหกล้ม” โดยที่ระบบตรวจวัดสัญญาณการเคลื่อนไหวมีส่วนประกอบดังนี้ ส่วนแรกคือเซ็นเซอร์วัดความเร่งแบบสามแกน ส่วนที่สองคือ ไมโครคอนโทรลเลอร์ ใช้สำหรับการจัดการข้อมูลของสัญญาณความเร่งจากเซ็นเซอร์วัดความเร่ง และสุดท้าย Computer เป็นส่วนของหน่วยเก็บข้อมูลของค่าสัญญาณความเร่งจากเซ็นเซอร์วัดความเร่ง

สำหรับองค์ประกอบประกอบในส่วนของอัลกอริทึมสำหรับการตรวจจับการเคลื่อนไหวและการหกล้มมีส่วนประกอบดังนี้ อันดับแรกคือการ ดึงคุณลักษณะของสัญญาณความเร่งของแต่ละกิจกรรมโดยใช้การแปลงเวฟเลต และสุดท้ายคือการคัดแยกการเคลื่อนไหวและการหกล้มด้วยวิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ

1.6 เค้าโครงวิทยานิพนธ์

ขั้นตอนการศึกษาของวิทยานิพนธ์เล่มนี้ เริ่มต้นด้วยการคิดค้นและประดิษฐ์ระบบตรวจวัดสัญญาณความเร่งจากการเคลื่อนไหว จากนั้นศึกษาเกี่ยวกับคุณลักษณะของสัญญาณความเร่งของการเคลื่อนไหวที่ได้มาจากการทดลอง ตลอดจนหาวิธีการดึงคุณลักษณะของสัญญาณ และสุดท้ายนำสัญญาณมาจำแนก

วิทยานิพนธ์ฉบับนี้ได้แบ่งเนื้อหาออกเป็น 5 บทด้วยกันคือ

บทที่ 1 กล่าวถึงบทนำ ความเป็นมาและความสำคัญของเนื้อหา ความมุ่งหมายและวัตถุประสงค์ของการศึกษา สมมุติฐานของการศึกษา แนวความคิดที่ใช้ในการวิจัย ขอบเขตการวิจัย และเค้าโครงวิทยานิพนธ์

บทที่ 2 กล่าวถึงงานวิจัยและทฤษฎีเกี่ยวข้องกับงานในวิทยานิพนธ์ฉบับนี้

บทที่ 3 กล่าวถึงขั้นตอนการวิจัยฉบับนี้ซึ่งประกอบด้วย 3 ขั้นตอน ได้แก่ การวัดสัญญาณความเร่งของแต่ละกิจกรรม การดึงคุณลักษณะของสัญญาณ และการจำแนกสัญญาณ

บทที่ 4 การทดลองและผลการทดลองของงานวิจัย

บทที่ 5 สรุปผลงานวิจัย

บทที่ 2

งานวิจัยและทฤษฎีที่เกี่ยวข้อง

เนื้อหาที่จะกล่าวในบทนี้มีดังต่อไปนี้

- หัวข้อที่ 2.1 การเปลี่ยนแปลงสุขภาพผู้สูงอายุ
- หัวข้อที่ 2.2 การหกล้ม และ ปัจจัยการหกล้มในผู้สูงอายุ
- หัวข้อที่ 2.3 งานวิจัยที่เกี่ยวกับการตรวจจับและแยกแยะสัญญาณการหกล้ม
- หัวข้อที่ 2.4 ทฤษฎีที่เกี่ยวข้อง

2.1 การเปลี่ยนแปลงสุขภาพของผู้สูงอายุ

การเคลื่อนไหวร่างกายของมนุษย์ซึ่งเกิดจากการทำงานของกล้ามเนื้อเนื้อมัดใหญ่เป็นพื้นฐานสำคัญอย่างยิ่งสำหรับสุขภาพของบุคคลทุกเพศทุกวัย โดยเฉพาะกลุ่มสูงอายุซึ่งมีการเคลื่อนไหวในชีวิตประจำวันลดลง แต่ขณะเดียวกันมีเวลาอยู่นิ่งเฉย (**Sedentary time**) เพิ่มขึ้นเมื่อเทียบกับกลุ่มประชากรอายุอื่น ผู้สูงอายุจึงเป็นกลุ่มที่ควรให้ความสนใจ และการที่มีผู้สูงอายุจำนวนมากทำให้ปัญหาสุขภาพของผู้สูงอายุกลายเป็นปัญหาที่ตระหนักเป็นพิเศษ โดยเฉพาะการหกล้มนับเป็นปัญหาที่ร้ายแรง และอันตรายมากที่สุด นอกจากนี้การหกล้มยังส่งผลทำให้ผู้สูงอายุที่เคยหกล้มกลัวการหกล้ม ทำให้ส่งผลต่อการทำกิจกรรมอื่นๆ หรือบางครั้งอาจไม่สามารถอยู่คนเดียวได้

เมื่อบุคคลอายุมากขึ้น ประสิทธิภาพในการทำงานของร่างกายของมนุษย์เกือบทุกระบบของร่างกายจะเสื่อมถอยลง รวมถึงผู้สูงอายุมีพฤติกรรมที่มีกิจกรรมทางกายลดลง จะส่งผลให้เกิดภาวะโรคเรื้อรังต่างๆ ขึ้นกับผู้สูงอายุ เช่น โรคหัวใจและหลอดเลือด โรคทางระบบกระดูกและกล้ามเนื้อ โรคอันเกิดจากระบบการเผาผลาญพลังงาน (**Metabolic syndrome**) โรคทางระบบประสาท [22] และบางกรณีโรคจากระบบหนึ่งอาจส่งผลไปยังอีกระบบหนึ่ง ซึ่งจะทำให้ผู้สูงอายุมีภาวะอ่อนแอและเจ็บป่วยมากยิ่งขึ้น การกลไกการทำงานที่ของระบบต่างๆ ในร่างกายผู้สูงอายุ ที่มีการเปลี่ยนแปลง 4 อย่าง ดังนี้

2.1.1 ระบบการทำงานที่ของหัวใจและหลอดเลือด (**Cardiovascular function**)

ความสามารถในการใช้ออกซิเจนและพลังงานเพื่อใช้ในการสร้างพลังงานของกล้ามเนื้อลดลง โดยจะวัดความต้องการใช้ออกซิเจนสูงสุด (**Maximum Oxygen Consumption, VO₂ max**) ซึ่งเป็นปริมาณก๊าซออกซิเจนสูงสุดที่ร่างกายใช้ไปในเวลา 1 นาที ในภาวะที่ร่างกายออกกำลังกายจนถึงจุดที่อัตราการใช้ออกซิเจนสูงสุด เมื่อเกิดกระบวนการแก่ชราของร่างกายความสามารถในการทำงานที่ในการขนส่งออกซิเจนของระบบหัวใจและหลอดเลือดลดลง รวมถึงสมรรถภาพทางกายลดลงด้วย ทั้งนี้เนื่องจากการเคลื่อนไหวของร่างกายของผู้สูงอายุน้อยลง จึงทำให้ความต้องการลดลงตามไปด้วย ปริมาณเลือดที่สูบฉีด

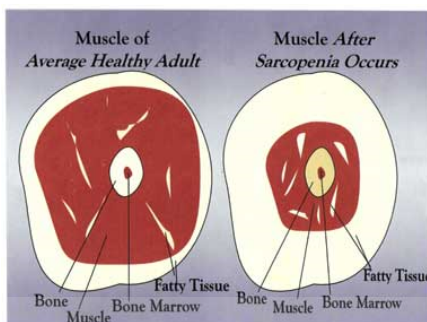
ออกจากหัวใจ (**Maximum cardiac output**) ไปสู่กล้ามเนื้อส่วนต่างๆลดลง นอกจากนี้หลอดเลือดแดงใหญ่จะมีความยืดหยุ่นลดลง ลิ้นหัวใจมีไขมันและหนาขึ้น เส้นเลือดแดงที่ออกมาจากหัวใจจะมีแคลเซียมมาเกาะทำให้หลอดเลือดแข็งตัว และขาดความยืดหยุ่น เรียกว่า **Arteriosclerosis** ภาวะนี้มักจะเกิดขึ้นควบคู่ไปกับการเกาะตัวของคอเลสเตอรอลในผนังหลอดเลือดด้านใน (**Artheclerosis**) ซึ่งส่งผลให้หลอดเลือดตีบแคบ เลือดไหลเวียนไม่สะดวก กล้ามเนื้อหัวใจขาดเลือด และความไวต่อสิ่งเร้าลดลง ส่งผลให้ผู้สูงอายุมีอาการเจ็บหน้าอก (**Angina pectoris**) อัตราการเต้นของหัวใจไม่เป็นจังหวะ และหัวใจวายเฉียบพลันได้ง่าย

2.1.2 ระบบการทำหน้าที่ทางเดินหายใจ (**Respiratory Function**)

เมื่อเข้าวัยสูงอายุ ประสิทธิภาพการทำงานของปอดจะลดลง เนื่องจากการเสื่อมของกล้ามเนื้อในการหายใจและสูญเสียความยืดหยุ่นของปอด ส่งผลให้ปอดมีการยืดขยายและหดตัวได้น้อยลง โดยเฉพาะปริมาณการหายใจสูงสุด (**Maximal voluntary ventilation**) จะลดลงถึง 50% ขณะที่ปริมาตรการค้างค้างของอากาศในปอด (**Residual lung volume**) จะคงค้างมากขึ้นจาก 30% เป็น 50% ซึ่งจะทำให้ความสามารถในการระบายอากาศของปอด (**Ventilation**) ในผู้สูงอายุลดลง จำนวนถุงลมขนาดเล็กจะลดลง และถุงลมที่เหลือจะมีขนาดใหญ่ขึ้นและแตกง่าย [23] นอกจากนี้ประสิทธิภาพในการไหลลงเนื่องจากการแข็งตัวของผนังทรวงอก และการทำงานของกล้ามเนื้อในการหายใจไม่ดี ทั้งหมดนี้ล้วนเป็นปัจจัยให้ผู้สูงอายุต้องพยายามเพิ่มงานในการหายใจ (**Work of breathing**) เพื่อให้อากาศเพียงพอ โดยการหายใจถี่และตื้น [24]

2.1.3 ระบบกล้ามเนื้อและกระดูก


ปกติทั่วไปกล้ามเนื้อในร่างกายมนุษย์จะมีลักษณะเส้นใยการหดตัว 2 แบบ คือ กล้ามเนื้อที่มีการหดตัวระยะเวลาสั้น แต่ให้แรงน้อย (**Type I muscle fibers**) และกล้ามเนื้อที่มีการหดตัวเร็วและให้แรงมาก (**Type II muscle fibers**) นักวิจัยพบว่า กล้ามเนื้อแบบแรกของผู้สูงอายุจะมีการเปลี่ยนแปลงช้า แต่ทว่ากล้ามเนื้อแบบที่สองจะมีการเปลี่ยนแปลงเร็วกว่า จะทำให้ความแข็งแรงและความรวดเร็วในการทำงานของผู้สูงอายุลดลง [25] ปรากฏการณ์ที่เกิดขึ้นกับผู้ที่มีอายุสูงวัย คือ กล้ามเนื้อฝ่อและลีบลง (**Muscle atrophy**) ซึ่งจะมีอาการที่สัมพันธ์กับการสูญเสียมวลกล้ามเนื้อต้นขาด้านหน้า (**Quadriceps**) และกล้ามเนื้อต้นขาด้านหลัง (**Hamstrings**) จะฝ่อและลีบลงเร็วกว่ากล้ามเนื้อส่วนอื่นในช่วงวัยสูงอายุ อาการดังกล่าวเกิดจากปัจจัยต่างๆ อาทิเช่น การใช้กล้ามเนื้อและกระดูกผิดวิธี กรรมพันธุ์ และการขาดการมีกิจกรรมทางกาย [26] และผลที่ตามมาภาวะการสูญเสียมวลกล้ามเนื้อ (**Sarcopenia**)



รูปที่ 2.1 แสดงการสูญเสียมวลกล้ามเนื้อ (Sarcopenia)

ผลจากที่กล้ามเนื้อฝ่อและลีบลง ทำให้พลังกล้ามเนื้อ (Muscle power) และความอดทนของกล้ามเนื้อ (Muscle endurance) ลดลง รวมถึงการลดลงของการผลิตเอนไซม์ในกล้ามเนื้ออีกด้วย จากผลรวมของการเปลี่ยนแปลงต่อกล้ามเนื้อดังกล่าว จะส่งผลในด้านความเร็วในการหดตัวของกล้ามเนื้อเข้า ขึ้น จึงเป็นสาเหตุให้ผู้สูงอายุเคลื่อนไหวช้าลง และ ความสามารถในการออกแรงต้านลดลง [28] เนื่องจากกิจวัตรประจำวันของผู้สูงอายุต้องใช้กำลังกล้ามเนื้อขาในกิจกรรมการเดินทาง การทำงาน และกิจกรรมประจำวันอื่นๆ จึงสังเกตเห็นว่าผู้สูงอายุเดินเขื่องช้า ลูกนั่งลำบาก และลื่นหกล้มได้ง่าย เมื่อบุคคลมีอายุมากขึ้น จะเริ่มสูญเสียมวลกระดูก จะเห็นได้จากพื้นเริ่มสึกหรอ มีการคดงอของแผ่นระหว่างกระดูกสันหลัง (Shrinkage of intervertebral disc) มีการยุบตัวของกระดูกสันหลัง เข้ามีการเสียรูปคือโค้งงอเข้า ทำให้การเดินมีฐานแคบและเดินไม่มั่นคง และกระดูกสันหลังมีการเปลี่ยนแปลงคือ บิดหรือโค้งออก

นอกจากนี้ ผลจากความแก่ชราได้ส่งผลต่อกระบวนการสร้างแคลเซียม และการสร้างเนื้อเยื่อของกระดูกของบุคคลที่จะเริ่มเสื่อมลงแล้ว ผู้สูงอายุหญิงจะสูญเสียมวลกระดูกได้รวดเร็วกว่าผู้สูงอายุชาย มีงานวิจัย ยืนยันว่าผู้สูงอายุหญิงมีภาวะความหนาแน่นของมวลกระดูกน้อยกว่าผู้สูงอายุชาย และจะสูญเสียเร็วมากขึ้นอีก 5 ปี เมื่อเข้าสู่ภาวะหมดประจำเดือนจะสูญเสียไปพร้อมกับมวลไขมันในร่างกาย [29] ซึ่งภาวะกระดูกพรุนยังเป็นสาเหตุสำคัญของโรคและความผิดปกติที่มักพบในวัยสูงอายุ เช่น กระดูกอักเสบ (Osteoarthritis) โรคปวดตามข้อ (Rheumatoid Arthritis) และโรคเกาต์ (Gout) หรือการกระดูกแตกหัก (Fracture) ได้ง่าย



รูปที่ 2.2 แสดงภาวะการเปลี่ยนแปลงมวลกระดูกผู้สูงอายุ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ความยืดหยุ่น (Flexibility) เป็นองค์ประกอบที่มีความสำคัญยิ่งต่อการมีสุขภาพ การเคลื่อนไหว ข้อต่อ (Joint Mobility) ผลของกระบวนการชราภาพจะส่งผลให้เกิดข้อจำกัดของการเคลื่อนไหวของข้อต่อมุ่มแคบลง ปัญหาส่วนใหญ่ที่มักพบในวัยสูงอายุคือ ผังพืด ข้อไหล่ยึดติด เจ็บปวดเป็นระยะเวลาหลายสัปดาห์หรือหลายเดือนเมื่ออาการปวดทุเลาลง จะมีอาการยกแขนไม่ขึ้นตามมา ซึ่งจะรบกวนการทำกิจกรรมในชีวิตประจำวัน เช่น หยิบของจากที่สูง รูดซิปลิเสื้อหรือ กระโปรงด้านหลัง หรือดึงกระเป๋าเงินจากกระเป๋าหลังของกางเกง เป็นต้น

2.1.4 ระบบประสาทและต่อมไร้ท่อ

เซลล์สมองและประสาทจะลดลงเรื่อยๆ ตั้งแต่อายุ 25 ปี ขนาดของสมองลดลง น้ำหนักสมองลดลง ความเร็วในการส่งสัญญาณประสาทลดลง ส่งผลให้ปฏิกิริยาสะท้อนกลับต่างๆ จะเชื่องช้า รวมทั้งการเคลื่อนไหวและความคิดเชื่องช้า ทำให้เกิดอุบัติเหตุง่าย และความสามารถในการจดจำลดลงเมื่อมนุษย์มีอายุมากขึ้น ความจำเสื่อมโดยเฉพาะเรื่องราวใหม่ๆ แต่สามารถจำเรื่องราวเก่าได้แม่นยำ บางครั้งบางความคิดอาจสับสนได้ ความสัมพันธ์ทางความคิดกับร่างกายมักไม่สัมพันธ์กัน แบบแผนการนอนเปลี่ยนแปลงเวลานอนน้อยลง และตื่นบ่อย การรับรู้ของผู้สูงอายุจะเริ่มเปลี่ยนแปลงเมื่ออายุ 65 ปีขึ้นไป ทั้งการรับรู้ และประสาทสัมผัส ระบบประสาทที่มีการเปลี่ยนแปลงมากที่สุด คือ ความสามารถในการรับรู้ (Cognitive abilities) ความจำ (Memory) ความเร็วในการเคลื่อนไหว (Movement speed) ลักษณะท่าทาง (Posture) การทรงตัว (Balance) และท่าทางการเดิน (Gait) [30]

นอกจากนี้ เมื่อเข้าสู่วัยชรา การมองเห็นและการได้ยินจะเปลี่ยนแปลงไปสายตาของผู้สูงอายุจะลึกลง เพราะ ไขมันใต้ตาจะลดลง หนึ่งต่าย้อย รุมาตาเล็ก อาจมาจากม่านตาฝ่อลีบลง มักจะพบตาต่อกระจกในผู้สูงอายุ การมองมูกว้างได้ลดลง การรับรู้ความรู้สึกต่างๆ เริ่มแยกได้ช้าลง สายตายาว มองเห็นในเวลากลางคืนไม่ดี ความสามารถในการปรับการมองเห็นจากที่มืดไปที่สว่างช้าลง หูจะตึง มีความยากลำบากในการเข้าใจคำพูดหากมีเสียงรบกวนหรือพูดเร็ว เสียงพูดของผู้สูงอายุจะเปลี่ยนไป เพราะมีการเสื่อมของกล้ามเนื้อกล่องเสียงและสายเสียงบางลง หลอดเลือดที่ไปเลี้ยงหูชั้นในเกิดภาวะแข็งตัว มีผลทำให้เกิดอาการเวียนศีรษะ การเปลี่ยนแปลงด้านการมองเห็นและการได้ยินจะส่งผลต่อการทรงตัว และการเดินของผู้สูงอายุ

นอกจากการเปลี่ยนแปลงทางสรีรวิทยาดังกล่าวข้างต้นแล้ว ผู้สูงอายุยังมีการเปลี่ยนแปลงทางด้านจิตวิทยาสังคม (Psycho-social Aspects) กล่าวคือ การเปลี่ยนแปลงด้านจิตใจ ส่วนใหญ่จะพัฒนาจิตใจตัวเองไปในทางที่ดีงามมากขึ้น สามารถควบคุมจิตใจได้ดีขึ้น มีความสุขเยือกเย็นเพิ่มขึ้น แต่ผู้สูงอายุบางคนไม่สามารถปรับตัวต่อการเปลี่ยนแปลงที่เกิดขึ้นได้ ลักษณะการเปลี่ยนแปลงด้านจิตใจที่พบในผู้สูงอายุ คือ การแสดงออกทางอารมณ์ ผู้สูงอายุมักท้อแท้และน้อยใจ โดยไม่รู้สึกว่าสังคมให้ความสำคัญต่อตนเองน้อยลงทำให้มีอารมณ์ไม่มั่นคง กระทบทกระเทือนใจง่าย หงุดหงิด ไม่ชอบงานแปลกๆใหม่ๆ ความมั่งหวังในชีวิตลดลง นอกจากนี้ โดยทั่วไปผู้สูงอายุจะมีภาระหน้าที่และบทบาททาง

สังคมลดลง เนื่องจากกฎเกณฑ์ทางสังคมหรือสภาพร่างกายของผู้สูงอายุ ผู้สูงอายุมักขาดความคล่องตัวในการคิดการกระทำ การติดต่อกับบุคคลอื่นๆ ทำให้ห่างจากสังคม

2.2 การหกล้มในผู้สูงอายุ

การหกล้ม หมายถึง การล้มลง ทรวดตัวลงเพราะเสียการทรงตัว [31] ปัจจัยที่มีความสัมพันธ์กับการหกล้มในผู้สูงอายุ สามารถจำแนกได้เป็น 2 ปัจจัย ได้แก่ปัจจัยภายในบุคคล และปัจจัยภายนอกบุคคล ซึ่งสามารถสรุปได้ ดังนี้

2.2.1 ปัจจัยภายในบุคคล

ปัจจัยภายในบุคคล หมายถึง ความสัมพันธ์หรือเป็นสาเหตุชักนำให้เกิดการหกล้มในผู้สูงอายุ แบ่งออกได้เป็น 2 กลุ่ม คือ ปัจจัยที่เกิดจากกระบวนการสูงวัย และ ปัจจัยที่เกิดจากกระบวนการเจ็บป่วย [32, 33] ซึ่งอธิบายได้ดังนี้

2.2.1.1 ปัจจัยที่เกิดจากกระบวนการสูงวัย

กระบวนการสูงวัย (Aging process) เป็นกระบวนการเปลี่ยนแปลงของ เซลล์ต่างๆ ในร่างกาย เริ่มตั้งแต่อยู่ในครรภ์จนเจริญเติบโตเป็นทารก และเข้าสู่วัยผู้ใหญ่ ในช่วงเวลาเหล่านี้ เซลล์จะเปลี่ยนแปลงในทางเสริมสร้างการเจริญเติบโต เมื่อพันวัยผู้ใหญ่แล้วจะมีการสลายเซลล์มากกว่า การสร้าง จึงพบว่าผู้สูงอายุเป็นวัยที่มีการทำงานของอวัยวะต่างๆ ในร่างกายที่เสื่อมลง เกิดพยาธิสภาพ หลายระบบ จึงพบว่าผู้สูงอายุมีพัฒนาการและการเปลี่ยนแปลงแบบเสื่อมถอยทั้งทางด้านร่างกายและจิตใจ ทำให้ผู้สูงอายุเกิดการหกล้มได้ง่าย ดังนี้

2.2.1.1.1 การเปลี่ยนแปลงในระบบสมองและประสาท

การเปลี่ยนแปลงในระบบสมองและระบบประสาท พบว่าความไวของการรับรู้ความรู้สึกลดลงเมื่ออายุมากขึ้น ได้แก่ ความสามารถในการรับรู้ตำแหน่ง ความสามารถในการรับรู้เหตุการณ์ที่เกิดขึ้น และการตอบสนองต่อการเปลี่ยนแปลง [34] นอกจากนี้ยังมีการเปลี่ยนแปลงในระบบประสาทอัตโนมัติ ซึ่งทำหน้าที่ควบคุมร่างกายให้อยู่ในดุลยภาพ (Homeostasis) พบว่ามีการเสื่อมลงในวัยสูงอายุ โดยจำนวนประสาทซิมพาเทติกลดลงถึงร้อยละ 10 - 15 เป็นผลให้ผู้สูงอายุมีปฏิกิริยาต่อสิ่งรบกวน เช่น ความดันโลหิตต่ำขณะเปลี่ยนท่า (Postural hypotension) ทำให้ผู้สูงอายุหน้ามืด วิงเวียน เกิดการหกล้มตามมา ภาวะซึมเศร้าและภาวะสมองไม่สามารถคิดและหาเหตุผลได้ (Cognitive impairment) จะเพิ่มความเสี่ยงต่อการหกล้มได้ราว 2 เท่า ส่วนผู้ป่วยที่มีภาวะสมองเสื่อม (Dementia) จะหกล้มได้ง่ายจากการตัดสินใจที่ไม่ดี การกระชาระยะผิดพลาด ทำให้ผู้ป่วยสูญเสียการทรงตัวได้ง่าย

2.2.1.1.2 การมองเห็น

การมองเห็น จะพบว่าการเปลี่ยนแปลงที่เสื่อมลงของสายตา ได้แก่ เกิดการหนาตัว การขุ่นและแข็งขึ้นของเลนส์ตา มีผลต่อการปรับสายตาเกี่ยวกับความชัดเจน การรับรู้ความตื้นลึกความไวต่อแสง และการปรับตัวต่อความมืดจอตาลดลง [35] สาเหตุของการมองเห็นที่ทำให้หกล้มบ่อยๆ เช่น

ต่อกระจก โรค **Macular degeneration** สายตายาวจากความชรา การใช้แว่นตาที่เสื่อมสมรรถภาพ หรือใช้เลนส์ไม่เหมาะสม หรือการเดินในที่มืด

2.2.1.1.3 การเปลี่ยนแปลงของระบบโครงร่างและกล้ามเนื้อ

การเปลี่ยนแปลงระบบโครงร่างและกล้ามเนื้อ จากการศึกษาพบว่า มวลกล้ามเนื้อ ความแข็งแรง และความสามารถในการประสานงานของกล้ามเนื้อลดลง ร่วมกับมีการเสื่อมของข้อต่อและเอ็นรอบๆข้อ ซึ่งทำให้การเคลื่อนไหวของข้อและความเร็วในการตอบสนองลดลง นอกจากนี้ การเปลี่ยนแปลงของโครงร่างและกล้ามเนื้อยังมีผลต่อท่าทางการเดิน ซึ่งพบว่าผู้สูงอายุส่วนใหญ่ไม่สามารถยกเท้าได้สูงเท่ากับที่เคยทำได้ รวมทั้งการเปลี่ยนแปลงในการเคลื่อนไหวของสะโพกในการรับน้ำหนักของขาขณะที่เดิน โดยเฉพาะผู้สูงอายุหญิงมีลักษณะการเดินคล้ายเป็ด (**Waddling gait**) ซึ่งเป็นสาเหตุให้ผู้สูงอายุมีการสะดุด เมื่อเดินบนทางที่มีพื้นขรุขระหรือต่างระดับ

2.2.1.1.4 ระบบทางเดินปัสสาวะ

กระบวนการสูงวัยมีผลทำให้การทำหน้าที่ของระบบทางเดินปัสสาวะลดลง โดยพบว่าความสามารถบีบตัวของกระเพาะปัสสาวะและความจุในกระเพาะปัสสาวะลดลง กล้ามเนื้อรอบๆท่อปัสสาวะอ่อนกำลังลง และตัวรับการกระตุ้นต่อการยืดขยายในกระเพาะปัสสาวะทำงานลดลง ปัจจัยต่างๆ เหล่านี้ส่งผลให้ผู้สูงอายุมีปัญหา กลั้นปัสสาวะไม่อยู่ (**Urinary incontinence**) ซึ่งเป็นสาเหตุต้องเข้าห้องน้ำบ่อยขึ้นและมีความเร่งรีบเข้าห้องน้ำไม่ทัน ทำให้เสี่ยงต่อการหกล้มได้ง่าย [36]

2.2.1.1.5 การเปลี่ยนแปลงทางด้านจิตสังคม

เมื่อเข้าสู่วัยสูงอายุ บทบาทในสังคมเปลี่ยนไป เช่น การที่ต้องออกจากงาน ทำให้สูญเสียตำแหน่ง รายได้ลดน้อยลง การสูญเสียและพลัดพรากจากสิ่งทีตนเคยรักใคร่ อาจก่อให้เกิดความเครียด ซึ่งจะต้องปรับตัวให้เข้ากับสิ่งที่เปลี่ยนไปให้ได้ ถ้าปรับตัวไม่ได้ก็จะเกิดพฤติกรรมที่เปลี่ยนแปลงไปจากปกติ เช่น อาการเหงา อาการหลงลืม วิดกกังวล และซึมเศร้า ทำให้การตอบสนองต่อสิ่งแวดล้อมช้าลง และการตัดสินใจไม่ดีในเรื่องความปลอดภัยเมื่ออยู่ตามลำพัง [37] ซึ่งทำให้ผู้สูงอายุเสี่ยงต่อการหกล้มได้ง่าย นอกจากนี้ การกลัวการหกล้มมากเกินไปจนไม่ยอมเดินจะทำให้เพิ่มความเสี่ยงต่อการหกล้ม

2.2.1.2 ปัจจัยที่เกิดจากกระบวนการเจ็บป่วย

2.2.1.2.1 ความผิดปกติของหัวใจและระบบไหลเวียนโลหิต

ความผิดปกติของหัวใจและระบบไหลเวียนโลหิต เป็นสาเหตุสำคัญของการหกล้ม ในผู้สูงอายุ ได้แก่ การเกิดกล้ามเนื้อหัวใจตาย ทำให้ปริมาณเลือดที่ออกจากหัวใจลดลง เกิดความดันโลหิตต่ำหรือหัวใจทำงานล้มเหลว [34] และภาวะที่มีคาโรติดไซน์สมิปฏิกริยาไวผิดปกติ (**Carotid sinus syndrome**) เกิดภาวะหัวใจเต้นช้าและความดันโลหิตต่ำ ซึ่งทำให้ปริมาณเลือดไปเลี้ยงสมองลดลง เป็นผลให้เกิดอาการวิงเวียน หน้ามืดเป็นลม ทำให้เสี่ยงต่อการหกล้ม

2.2.1.2.2 พยาธิสภาพในระบบสมองและประสาท

พยาธิสภาพในระบบสมองและประสาท ได้แก่ โรคอัลไซเมอร์ (Alzheimer' disease) สมองเสื่อมจากเนื้อสมองตาย (Multi-infarct dementia) โรคหลอดเลือดในสมอง โรคพาร์กินสัน (Parkinson' disease) และโรคสมองเสื่อม (Dementia) ทำให้ผู้สูงอายุมีท่าเดินผิดปกติและสูญเสียการทรงตัวได้ง่าย ซึ่งเป็นสาเหตุทำให้เกิดการหกล้มตามมา [38] ภาวะซึมเศร้าและภาวะสมองไม่สามารถคิดและหาเหตุผลได้ (Cognitive impairment) จะเพิ่มความเสี่ยงต่อการหกล้มได้ราว 2 เท่า ส่วนผู้ป่วยที่มีภาวะสมองเสื่อม (Dementia) จะหกล้มได้ง่ายจากการตัดสินใจที่ไม่ดี การกระะยะผิดพลาด ทำให้ผู้ป่วยสูญเสียการทรงตัว

2.2.1.2.3 ความผิดปกติของระบบโครงร่างและกล้ามเนื้อ

ความผิดปกติของระบบโครงร่างและกล้ามเนื้อ ทำให้เกิดปัญหาการทรงตัวไม่มั่นคง เช่น การสูญเสียสภาวะจากการที่ร่างกายไม่ได้เคลื่อนไหวเป็นเวลานาน (Deconditioning state) หรือโรคเรื้อรังทางกาย เช่น โรคข้อเสื่อม (Osteoarthritis) โดยเฉพาะข้อเข่าและข้อสะโพก นอกจากนี้อาการผิดปกติและโรคของเท้า เช่น ตาบปลา หูด แผลเป็น หรือโครงสร้างของเท้าผิดปกติ ทำให้เกิดความเจ็บปวดขณะเดินหรือเปลี่ยนท่า ทำให้เกิดการหกล้มตามมาได้ [34]

2.2.1.2.4 ความผิดปกติของสมดุลกรดต่าง

ความผิดปกติของสมดุลกรดต่าง ทำให้กลไกการทรงตัวลดลง ได้แก่ ภาวะน้ำตาลในเลือดต่ำ ทำให้ใจสั่นหรือหน้ามืดเป็นลม เกิดการหกล้มตามมา ระดับโซเดียมที่สูงหรือต่ำกว่าปกติมีผลต่อการทำงานของสมองทำให้เกิดอาการซึมหรือสับสน และระดับโปแตสเซียมที่ต่ำกว่าปกติทำให้เกิดกล้ามเนื้ออ่อนแรง ทำให้ผู้สูงอายุเกิดการหกล้มตามมา [37]

2.2.1.2.5 การใช้ยา

ผู้สูงอายุมักจะได้รับยาหลายชนิด และความผิดพลาดทั้งจากตัวผู้ป่วยและแพทย์ ซึ่งทำให้เกิดปฏิกิริยาต่อกันระหว่างยา และทำให้เกิดผลข้างเคียงหรือพิษของยา ยาจะมีผลต่อกลไกการทรงตัว เช่น ยารักษาภาวะหัวใจเต้นผิดจังหวะ, ยาที่ออกฤทธิ์ ต่อจิตและประสาท ได้แก่ ยานอนหลับ และยาด้านซึมเศร้าซึ่งมีผลทำให้วังงซึม เดินโซเซ กระวนกระวายและสับสน, ยาลดความดันโลหิตและยาขับปัสสาวะ ทำให้เกิดความดันโลหิตต่ำขณะเปลี่ยนท่า (Postural hypotension) หรือปัสสาวะบ่อย [34] สำหรับผู้สูงอายุที่มีปัญหาภาวะกลั้นปัสสาวะไม่อยู่ร่วมกับการได้รับยาขับปัสสาวะ ทำให้มีความเร่งรีบเข้าห้องน้ำ อาจเกิดการลื่นหรือสะดุดล้มตามมาได้ [36]

2.2.2 ปัจจัยภายนอกบุคคล

ปัจจัยภายนอกบุคคล หมายถึง สิ่งแวดล้อมที่ไม่ปลอดภัยทั้งภายในและภายนอกบ้าน [33,37] สิ่งแวดล้อมรอบๆ ตัวบุคคลที่เป็นปัจจัยในการเกิดการหกล้มของผู้สูงอายุ เหตุปัจจัยการหกล้ม ได้แก่ ลักษณะที่พักอาศัย พื้นบ้านเป็นมันลื่น พื้นบ้านต่างระดับที่สังเกตยาก ประตูบ้านที่มีขอบธรณีประตู แสงสว่างภายในบ้านไม่เพียงพอ การจัดเปลี่ยนเฟอร์นิเจอร์บ่อยๆ พรมเช็ดเท้าลื่น บันไดบ้านชันและไม่มีราวบันได ห้องน้ำไม่เหมาะสำหรับผู้สูงอายุ รวมถึงสถานที่ที่ผู้สูงอายุไปเป็นประจำในชุมชน ก็เป็นปัจจัยในการ

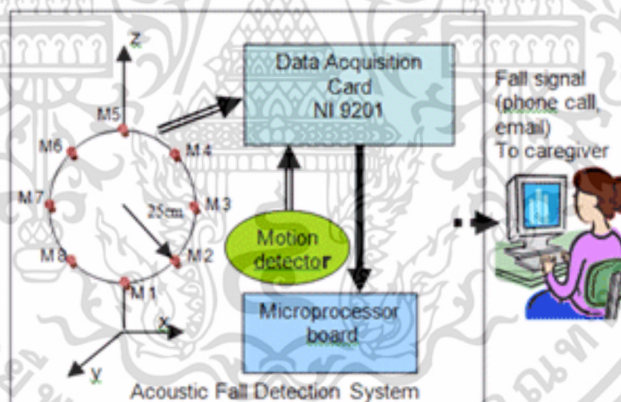
เกิดการหกล้มเช่นกัน ยกตัวอย่างเช่น ถนนในชุมชน ทางชำรุด มีสิ่งกีดขวาง บันไดหินอ่อน สิ่งของที่วางไม่เป็นระเบียบ ทางเดินแคบ พื้นไม่สม่ำเสมอ และ พื้นเปียก และ

2.3 งานวิจัยที่เกี่ยวข้อง

งานวิจัยที่เกี่ยวกับการตรวจจับและแยกแยะสัญญาณการหกล้มสามารถแบ่งออกเป็น 4 กลุ่ม คือ กลุ่มแรกเป็นงานวิจัยใช้เสียง กลุ่มต่อมาได้นำเสนอโดยการใช้อัลตราซาวด์ กลุ่มต่อมาใช้เซ็นเซอร์วัดการสั่นสะเทือน และ กลุ่มสุดท้ายได้นำเสนอการเลือกใช้เซ็นเซอร์วัดความเร่งหรือเซ็นเซอร์ความเร่งเชิงมุม

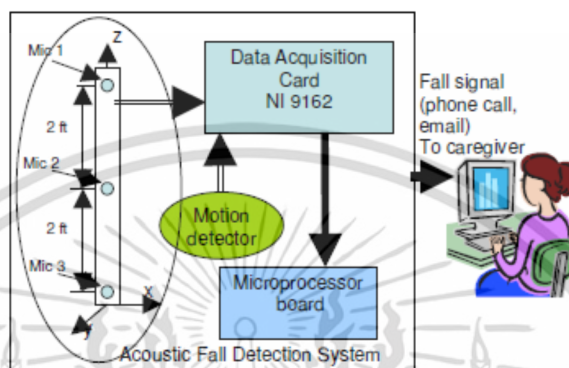
2.3.1 กลุ่มงานวิจัยที่นำเสนอการตรวจจับการหกล้มโดยใช้เสียง

Yun Li และคณะ [8] นำเสนออัลกอริทึมโดยใช้เซ็นเซอร์วัดเสียง ที่ออกแบบมาสำหรับติดตามและตรวจจับการหกล้ม คุณลักษณะที่สำคัญของการออกแบบคือ จำนวนไมโครโฟน และการตั้งวางตำแหน่งของไมโครโฟน โดยงานวิจัยนี้ใช้ไมโครโฟน 8 ตัววางเป็นวงกลมโดยมีเครื่องขยายเสียงขนาดเล็กติดตั้งอยู่ด้วย โดยที่ไมโครโฟนติดตั้งบนกระดานไม้อัดในรูปแบบของวงกลมโดยที่มีรัศมี 25 เซนติเมตร โดยที่ความสูงของไมโครโฟนอยู่ที่ 1.5 เมตรวัดจากระดับพื้น ดังแสดงในรูปที่ 2.3 แต่อย่างไรก็ตามก็ยังมีปัญหาเกี่ยวกับสัญญาณรบกวน เช่น เสียงของโทรทัศน์



รูปที่ 2.3 รูปแบบการนำเสนอการตรวจจับการล้มของ Yun Li

Mihail Popescu และคณะ [9] นำเสนออุปกรณ์สำหรับการตรวจจับการหกล้มโดยการใช้เซ็นเซอร์ตรวจจับเสียง เซ็นเซอร์จับเสียง รุ่น **Cana Kit CK495** โดยกำหนดให้ติดตั้งไว้เป็นแผงตามแนวดิ่งและบอร์ด **NI card NI 9162** สำหรับการบันทึกและนำข้อมูลที่บันทึกไว้ไปประมวลผล ดังแสดงในรูปที่ 2.4



รูปที่ 2.4 รูปแบบการนำเสนอการตรวจจับการล้มของ Mihail Popescu

2.3.2 กลุ่มงานวิจัยที่นำเสนอการตรวจจับการหกล้มโดยซ์ภาพ

M.Kreković และคณะ [10] นำเสนอวิธีการตรวจจับการล้มโดยใช้กล้องวิดีโอ วิธีการนี้ให้ผลที่น่าพอใจและใช้งานค่อนข้างดีในการตรวจสอบตลอดเวลา และสามารถขยายติดตั้งเพิ่มเติมได้เช่นติดกล้องหลายตัวเพื่อที่จะใช้ในห้องพักทุกห้องภายในบ้าน แต่อย่างไรก็ตามปัญหาของการใช้งานระบบนี้คือ ต้องอยู่ในสภาวะที่ควบคุมได้เช่น แสงสว่างภายในห้องทดลอง สีของเสื้อผ้าและพื้นหลังของอาสาสมัครที่ทดสอบ ดังแสดงในรูปที่ 2.5



รูปที่ 2.5 ตัวอย่างภาพการหกล้มและภาพจากกล้องของ M.Kreković

Samantha Ng และคณะ [11] งานวิจัย ได้พัฒนาการตรวจจับการหกล้มโดยวิธีการติดตามด้วยภาพ ซึ่งอุปกรณ์ที่ใช้สำหรับการตรวจจับการเคลื่อนไหวคือ กล้อง **Monocular Vision System** โดยอุปกรณ์ดังกล่าวได้ติดตั้งไว้ที่ตำแหน่งที่สามารถเห็นขาของผู้ทดลอง ดังแสดงในรูปที่ 2.6 เมื่อ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นิยมนำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

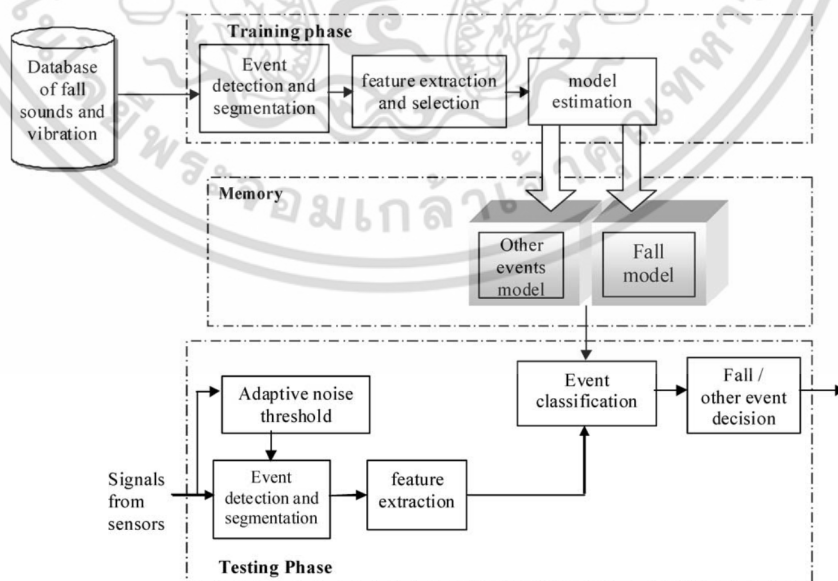
ผู้ทดลองมีการเคลื่อนไหว อุปกรณ์สามารถหาความเร็วจากแต่ละก้าวของการเดิน เพื่อประมวลผลหาการ
ความเป็นไปได้ต่อการเกิดการหกล้ม กล่าวคือ หากผู้ใช้ได้หายไปจากการเคลื่อนไหวในช่วงเวลาใดๆ ก็จะมี
ถือว่ามีอาการหกล้มเกิดขึ้น ณ ช่วงเวลานั้นๆ



รูปที่ 2.6 แสดงตัวอย่างโมเดลของ Samantha Ng

2.3.3 กลุ่มงานวิจัยที่นำเสนอการตรวจจับการหกล้มโดยใช้การเซ็นเซอร์วัดการสั่นสะเทือน

Yaniv Zigel และ คณะ [12] นำเสนอแนวคิดกับระบบการตรวจจับการหกล้มอัตโนมัติสำหรับ
ผู้สูงอายุ ระบบนี้จะขึ้นอยู่กับสั่นสะเทือนของพื้นและเสียง โดยใช้วิธีการจดจำรูปแบบระหว่างการห
กล้มและกิจกรรมอื่นๆ การคัดแยกประเภทจะขึ้นอยู่กับ สัมประสิทธิ์เมลเฟรีเควินซีเซปสตรีม (Mel
Frequency Cestrum Coefficients) ดังแสดงในรูปที่ 2.7 โดยการหกล้มของมนุษย์จำลองโดยการใช้
ตุ๊กตาล้อเลียนมนุษย์ (Rescue Randy) วิธีการที่นำเสนอมีความเป็นเอกลักษณ์โดยที่อัลกอริทึมนี้ไม่ต้อง
สวมใส่อะไรไปกับผู้ทดลองเลย แต่ก็ยังมีข้อจำกัดของระบบคือ ไม่สามารถตรวจจับการหกล้มของมนุษย์ได้
ถ้ามนุษย์หกล้มช้าๆหรือหกล้มไม่แรงพอ

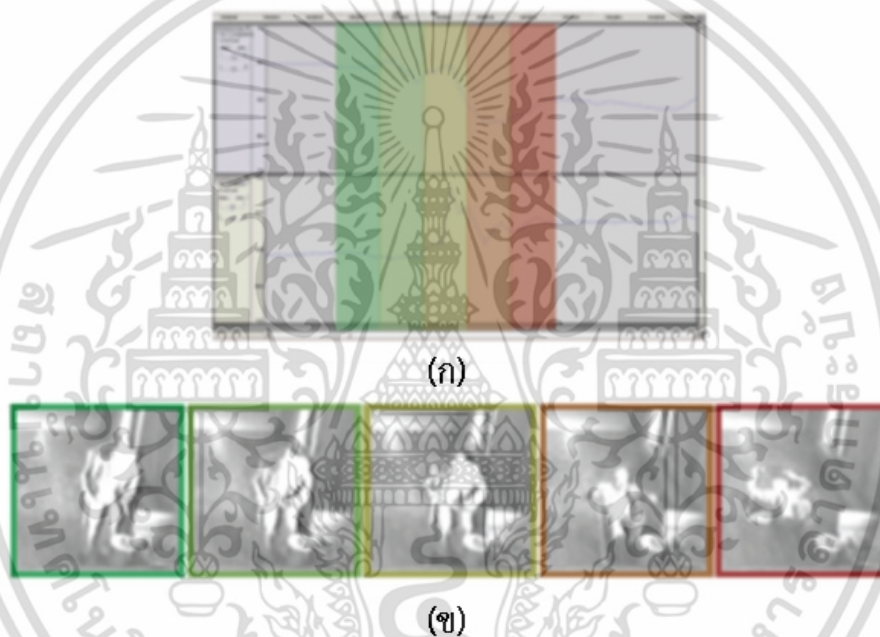


รูปที่ 2.7 บล็อกไดอะแกรมของการตรวจจับและการคัดแยกการหกล้มของ Yaniv Zigel

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.3.4 กลุ่มงานวิจัยที่นำเสนอการตรวจจับการหักมุมโดยใช้เซ็นเซอร์วัดความเร่ง

Boyle และ Karunanithi [13] เป็นกลุ่มนักวิจัยชาวออสเตรเลียได้พัฒนาอัลกอริทึมสำหรับการตรวจจับการหักมุม โดยได้นำเสนออุปกรณ์สำหรับการตรวจจับสัญญาณการหักมุมของผู้สูงอายุโดยการใช้เซ็นเซอร์วัดความเร่ง (ยี่ห้อ PAL Technology) แบบ 2 แกน มีขนาด 35 มม. × 53 มม. × 7 มม. น้ำหนัก 40 กรัม กลุ่มนักวิจัยดังกล่าวได้ใช้สายสะพายเพื่อติดตั้งอุปกรณ์ให้แนบกับเอวของผู้ป่วย และกำหนดทิศของแกนตัวตรวจจับความเร่งให้มีทิศในแกนตั้งและแกนหน้า - หลัง ผลจากการที่ใช้เซ็นเซอร์วัดความเร่งแบบ 2 แกนทำให้การล้มไปด้านข้างทำการตรวจจับได้ยาก รูปที่ 2.8 ก แสดงลักษณะของสัญญาณ, รูปที่ 2.8 ข แสดงลักษณะการหักมุม




รูปที่ 2.8 แสดงสัญญาณและลักษณะการล้มของ Boyle

(ก) สีแสดงช่วงเวลาของการเคลื่อนไหวของรูปที่ 2.8 ข

(ข) ลักษณะการหักมุม


Anda Sengto และคณะ [3] นำเสนออัลกอริทึมสำหรับตรวจจับการหกล้มอย่างมีประสิทธิภาพ ด้วยเซ็นเซอร์วัดความเร่ง โดยอัลกอริทึมที่นำเสนอประกอบด้วย 3 ขั้นตอนคือ 1) การตรวจจับสัญญาณการเคลื่อนไหวแบบฉับพลัน และหกล้ม, 2) การตัดสัญญาณ, และ 3) การตรวจจับการหกล้มโดยใช้โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ ดังแสดงในรูป 2.9 ในการทดลองของ **Sengto** อาสาสมัครสุขภาพดีจำนวน 5 คน (ผู้ชาย 4 ผู้หญิง 1) ถูกขอร้องให้ติดเซ็นเซอร์วัดความเร่งไว้ที่เอวด้านขวา และทำกิจกรรมทั้งหมด 8 กิจกรรม คือ กระโดด ล้มตัวนอน ลูกจากเตียง หกล้มไปด้านหน้า หกล้มไปด้านหลัง หกล้มไปด้านซ้าย หกล้มไปด้านขวา และหกล้มระหว่างการลุกขึ้นยืน เพื่อเก็บสัญญาณความเร่ง จากการทดลองพบว่า อัลกอริทึมของ **Sengto** สามารถตรวจจับสัญญาณประเภทการล้มและไม่ล้ม ได้อย่างแม่นยำ



รูปที่ 2.9 อัลกอริทึมสำหรับการตรวจจับสัญญาณการหกล้มของ Sengto

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Sang-Hong Lee [39] นำเสนออัลกอริทึม สำหรับตรวจจับการหลอมนด้วยเซ็นเซอร์ตรวจวัด ความเร่งติดไว้ที่เอวด้านซ้าย โดยที่อัลกอริทึมที่นำเสนอประกอบไปด้วย การแปลงความเร่งสามแกนให้ เป็นแกนเดียวดังสมการ $S(t) = XY_d(t) + YZ_d(t)$ ก่อนที่จะแปลงเวฟเลต และคัดแยกกิจกรรม ด้วยการใช้ทฤษฎีฟuzzyลอจิกและโครงข่ายประสาทเทียม ซึ่งการคัดแยกกิจกรรมจะประกอบไปด้วย 2 กลุ่ม คือ 1) กลุ่มหลอมน ประกอบด้วย หลอมนระหว่างเดิน หลอมนระหว่างวิ่ง หลอมนขณะที่ลุกขึ้นจากเก้าอี้ หลอมน ขณะที่ลุกขึ้นจากเตียง และ 2) กลุ่มไม่หลอมนคือ เดิน วิ่ง นั่ง นอน ซึ่งการทดลองใช้จำนวนข้อมูลทั้งหมด 800 ข้อมูลที่ได้มาจากอาสาสมัครทั้งหมด 10 คน ซึ่งอัลกอริทึมของ Sang-Hong Lee สามารถตรวจจับ สัญญาณประเภทการหลอมน และ ไม่หลอมน ได้อย่างแม่นยำ



รูปที่ 2.10 โครงสร้าง Neural network with weighted fuzzy membership function(NEWFM) ที่ นำเสนอโดย Sang-Hong Lee

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.4 ทฤษฎีที่เกี่ยวข้อง

วิทยานิพนธ์ฉบับนี้เป็นงานวิจัยเกี่ยวกับระบบตรวจวัดสัญญาณความเร่งจากการเคลื่อนไหวและล้ม ทฤษฎีที่เกี่ยวข้องกับระบบตรวจจัดการหกล้มที่พัฒนาในงานวิทยานิพนธ์ฉบับนี้ประกอบไปด้วย 2 ทฤษฎี คือ

1. ทฤษฎีการแปลงเวฟเลต ซึ่งอธิบายไว้ในหัวข้อที่ 2.4.1
2. ทฤษฎีโครงข่ายประสาทเทียม ซึ่งอธิบายไว้ในหัวข้อที่ 2.4.2

2.4.1 ทฤษฎีการแปลงเวฟเลต (Wavelet Transform)

2.4.1.1 ทฤษฎีการประมาณค่า (Approximation)

จากทฤษฎีพีชคณิตเชิงเส้น ถ้าสัญญาณที่กำลังพิจารณา $f(t)$ เป็นฟังก์ชันในปริภูมิที่ถูก Span โดยฟังก์ชัน Basis [16 และ 17] ดังนั้นเราสามารถที่จะเขียนสัญญาณนั้นให้อยู่ในรูปของผลรวมเชิงเส้นของฟังก์ชัน Basis ได้ดังนี้

$$f(t) = \sum_k a_k \phi_k(t) \quad (2.1)$$

โดยที่ k คือ ดัชนีจำนวนเต็มจำนวนจำกัดหรือไม่จำกัดก็ได้

a_k คือ ค่าสัมประสิทธิ์การขยาย

$\phi_k(t)$ คือ ฟังก์ชันการขยายหรือฟังก์ชัน Basis

ถ้าแทน $\phi_k(t)$ ด้วย $\exp(j2\pi kt/T)$ เราจะได้สมการการแปลงฟูเรียร์ ดังนั้นสมการการแปลงฟูเรียร์จึงเป็นกรณีพิเศษของสมการที่ 2.1 ในกรณีทั่วไป ถ้าเราเลือกฟังก์ชัน Basis ที่เหมาะสม เราสามารถหาเซตของ $\{\phi_k(t)\}$ และ $\{\tilde{\phi}_k(t)\}$ ที่ตั้งฉากซึ่งกันและกัน (Orthonormal) โดยที่สมการ Inner Product ของเซตทั้งสองจะเป็น

$$\langle \phi_i(t), \tilde{\phi}_j(t) \rangle = \int \phi_i(t) \tilde{\phi}_j^*(t) dt = \delta_{ij} \quad (2.2)$$

โดยที่ $\{\tilde{\phi}_k(t)\}$ เรียกว่าเซตของคู่ฟังก์ชันของ $\{\phi_k(t)\}$ จากคุณสมบัติ Orthonormal เราสามารถหาค่าสัมประสิทธิ์ a_k ได้จาก

$$\begin{aligned}
\langle f(t), \tilde{\phi}_k(t) \rangle &= \int f(t) \tilde{\phi}_k^*(t) dt \\
&= \int \left(\sum_{k'} a_{k'} \phi_{k'} \right) \tilde{\phi}_k^*(t) dt \\
&= \sum_{k'} a_{k'} \left(\int \phi_{k'}(t) \tilde{\phi}_k^*(t) dt \right) \\
&= \sum_{k'} a_{k'} \delta_{k'k} \\
&= a_k
\end{aligned} \tag{2.3}$$

เราสามารถเขียนสมการที่ 2.3 ใหม่ได้ดังนี้

$$a_k = \langle f(t), \tilde{\phi}_k(t) \rangle = \int f(t) \tilde{\phi}_k^*(t) dt \tag{2.4}$$

2.4.1.2 ตัวอย่างการประมาณสัญญาณดิคริตทางเวลาโดยฟังก์ชันเดลต้า
พิจารณาสัญญาณดิคริตทางเวลา $x[n]$ ที่มีสมการดังนี้

$$x[n] = \left(\frac{1}{2}\right)^{|n|} \tag{2.5}$$

จากนั้นเลือกใช้เซตของฟังก์ชัน **Basis** เป็น $\{\phi_k[n]\} = \{\delta[n-k]\}$ และ เซตของคู่ฟังก์ชันเป็น $\{\tilde{\phi}_k[n]\} = \{\phi_k[n]\} = \{\delta[n-k]\}$ เพื่อหาสัมประสิทธิ์การขยายของ $x[n]$ ในขั้นแรกต้องตรวจสอบว่าฟังก์ชัน **Basis** ที่ถูกเลือกมีคุณสมบัติ **Orthonormal** หรือไม่ ดังต่อไปนี้


$$\langle \phi_i[n], \tilde{\phi}_j[n] \rangle = \langle \delta[n-i], \delta[n-j] \rangle = \sum_{n=-\infty}^{\infty} \delta[n-i] \delta[n-j] = \delta_{ij} \tag{2.6}$$

จากสมการที่ 2.4 เราสามารถหาค่าสัมประสิทธิ์การขยายได้ดังนี้

$$a_k = \langle x[n], \delta[n-k] \rangle = \sum_{n=-\infty}^{\infty} \left(\frac{1}{2}\right)^{|n|} \delta[n-k] = \left(\frac{1}{2}\right)^{|k|} \tag{2.7}$$

รูปที่ 2.11 แสดงค่าสัมประสิทธิ์ a_k เมื่อ $k \in [K_1, K_2]$

ตัวอย่างนี้เลือกใช้เซตของฟังก์ชัน $\{\delta[n-k]\}$ เป็นฟังก์ชัน **Basis** ในการหาค่าสัมประสิทธิ์ เซตของฟังก์ชัน $\{\delta[n-k]\}$ สามารถแปลได้อีกความหมายหนึ่งคือ เซตของการเลื่อนเดต้าฟังก์ชัน $\delta[n]$ ไปยังตำแหน่ง $n = k$



รูปที่ 2.11 ผลลัพธ์ค่าประมาณของฟังก์ชันเดต้า

ในตัวอย่างนี้เราเลือกบางส่วนของฟังก์ชัน **Basis** $\{\delta[n-k]\}$ เพื่อนำมาหาค่าสัมประสิทธิ์ของตัวเอง ฟังก์ชัน **Basis** นี้ อาจถูกตีความได้หลายลักษณะซึ่งฟังก์ชัน **Basis** อาจแทนเป็นการเลื่อนของฟังก์ชันเดต้า $\delta[n]$ $\delta[n-k]$ จะหมายถึงตำแหน่งของอิมพัลส์ที่ $n = k$ ค่าสัมประสิทธิ์บางส่วนที่ใช้ในสัญญาณคืนกลับคือตำแหน่งที่เราพิจารณา ยกตัวอย่าง ถ้าเราต้องการวิเคราะห์สัญญาณเมื่อ $n \in [-2, 0]$ เราสามารถใช้ a_{-2}, a_{-1} และ a_0 เพื่อใช้หารูปแบบการสร้างสัญญาณคืนกลับได้

2.4.1.3 การสร้าง **Basis** โดยการสเกล

ในหัวข้อก่อนหน้านี้เราสามารถสร้างเซตของฟังก์ชัน **Basis** ได้โดยการเลื่อนฟังก์ชัน **Basis** ต้นแบบ ในหัวข้อนี้เราจะยกตัวอย่างการสร้างเซตของฟังก์ชัน **Basis** โดยการสเกลหรือการขยายขนาดฟังก์ชัน **Basis** ต้นแบบ

กำหนดให้ ฟังก์ชันต่อเนื่อง $\phi(t)$ เป็นฟังก์ชันสี่เหลี่ยม (**Rectangular**) ที่มีจุดศูนย์กลางอยู่ ณ ตำแหน่ง $x = 1/2$ และมีความกว้างเท่ากับ 1 ซึ่งสามารถเขียนเป็นสมการได้ดังนี้

$$\phi(t) = \begin{cases} 1, & 0 \leq t < 1 \\ 0, & \text{Otherwise} \end{cases} \quad (2.8)$$

เราสามารถสเกลขนาดของฟังก์ชัน $\phi(t)$ ได้ดังนี้


$$\phi_s(t) = \phi(st) \quad (2.9)$$

โดยที่ s คือ แฟกเตอร์แบบต่อเนื่องของการสเกล

ถ้า s มีค่าสูงขึ้น ซัพพอร์ตของ **Basis** จะแคบลง ในกรณีที่ใช้ **Basis** แบบดิสครีต เราใช้ $s = 2^n$ เพื่อความง่าย โดยที่ n เป็นเลขจำนวนเต็ม ดังนั้นเราสามารถเขียนสมการที่ 2.9 ใหม่ได้ดังนี้

$$\phi_n(t) = \phi(2^n t) \quad (2.10)$$

โดยที่ n เป็นดัชนีบ่งชี้การสเกล



รูปที่ 2.12 รูปสเกลของ **Basis** ต่างๆ

- (ก) $\phi_n(t) = \phi_0(t)$, (ข) $\phi_n(t) = \phi_1(t)$,
 (ค) $\phi_n(t) = \phi_{-1}(t)$, (ง) $\phi_n(t) = \phi_2(t)$

รูปที่ 2.12 (ก)-(ง) แสดง $\phi_n(t)$ ที่ $n=0, 1, -1$ และ 2 ตามลำดับ การสเกลฟังก์ชัน $\phi(t)$ ให้มีซัพพอร์ตแคบลง จะทำให้ $\phi(t)$ มีองค์ประกอบความถี่สูงขึ้น ดังนั้นเราสามารถที่จะประมาณค่าขององค์ประกอบความถี่สูงได้อย่างแม่นยำโดยกำหนดค่าการสเกลให้สูงขึ้น

คำถามต่อไป คือ แฟมิลีของ $\{\phi_n(t)\}$ เป็นเซตของฟังก์ชันที่ **Orthogonal** ซึ่งกันและกันหรือไม่ เราลองตรวจสอบสองฟังก์ชันสองอันดับแรก คือ $\phi_0(t)$ และ $\phi_1(t)$ ดังต่อไปนี้

$$\langle \phi_0(t), \phi_1(t) \rangle = \int_{-\infty}^{\infty} \phi_0(t) \phi_1(t) dt = \int_0^{1/2} dt = 1/2$$

จะเห็นว่าฟังก์ชันทั้งสองไม่เป็น **Orthogonal** ซึ่งกันและกัน ดังนั้นฟังก์ชันอื่นๆก็เช่นเดียวกัน แต่เราสามารถที่จะใช้กระบวนการของ **Gram-Schmidt** เพื่อสร้างเซตของ **Orthonormal Basis** จาก $\{\phi_n(t)\}$ ที่มีอยู่ ดังต่อไปนี้

$$\begin{aligned}\phi'_0(t) &= \phi_0(t) = \phi(t) \\ \phi'_1(t) &= \phi_1(t) - \frac{\langle \phi_1(t), \phi_0(t) \rangle}{\langle \phi_0(t), \phi_0(t) \rangle} \phi_0(t) \\ &= \begin{cases} 1/2, 0 \leq t < 1/2 \\ -1/2, 1/2 \leq t < 1 \\ 0, \text{Otherwise} \end{cases} \\ &= \psi(t)/2\end{aligned}\tag{2.11}$$

เราสามารถใส่กระบวนการของ **Gram-Schmidt** กับฟังก์ชัน **Basis** อื่นๆ แต่ถ้าเราพิจารณาฟังก์ชัน **Basis** สองตัวแรก และการแปลงฟูเรียร์ของฟังก์ชัน **Basis** สองตัวแรก จากการตรวจสอบ $\phi(t)$ จะมีค่าเฉลี่ยไม่เท่ากับศูนย์ในขณะที่ $\psi(t)$ มีค่าเฉลี่ยเท่ากับศูนย์ ค่าของ $\phi(t)$ มีการกระโดดสองครั้งที่ตำแหน่ง 0 และ 1 ในขณะที่ $\psi(t)$ กระโดดที่ 0, 1/2, 1 ดังนั้นพลังงานของ $\phi(t)$ จะสะสมมากที่ความถี่ต่ำในขณะที่พลังงานของ $\psi(t)$ อยู่ที่ความถี่สูง เราจะเรียก $\phi(t)$ ว่า ฟังก์ชันการสเกล เพื่อคำนวณฟังก์ชันการประมาณค่า (**Approximated Function**) ที่ระดับต่ำกว่า และ $\psi(t)$ ว่าฟังก์ชันเวฟเลตเพื่อคำนวณฟังก์ชันรายละเอียด (**Detail Function**) ที่ระดับต่ำกว่า

2.4.1.4 การวิเคราะห์แบบ **Multi-resolution**

เราสามารถสร้างเซตของฟังก์ชัน **Basis** ที่มีคุณสมบัติ **Orthonormal** จากฟังก์ชันสเกลและฟังก์ชันเวฟเลตโดยใช้พารามิเตอร์ 2 ตัว คือ พารามิเตอร์การขยาย (**Scaling**) และ พารามิเตอร์การเลื่อน (**Translating**) ได้ดังนี้

$$\begin{aligned}\phi_{j,k}(t) &= 2^{j/2} \phi(2^j t - k) \\ \psi_{j,k}(t) &= 2^{j/2} \psi(2^j t - k)\end{aligned}\tag{2.12}$$

โดยที่ j คือ พารามิเตอร์การขยาย หรือ **dilation** และ k คือ พารามิเตอร์เลื่อนหรือตำแหน่ง ในทางปฏิบัติ เราอาจต้องการเห็นถึงข้อมูลทั้งหมดที่ระดับความละเอียด (**Resolution**) ที่ต้องการ นั่นคือ ที่ระดับความละเอียด (**Resolution**) j บางค่าเราจะนิยามปริภูมิย่อย (**Subspace**)

$$\begin{aligned} V_j &= \text{Span}\{\phi_{j,k}(t)\} \\ W_j &= \text{Span}\{\psi_{j,k}(t)\} \end{aligned} \quad (2.13)$$

จากนิยามเหล่านี้ การวิเคราะห์ **Multiresolution** มีข้อกำหนดดังต่อไปนี้


1. ฟังก์ชันสเกลต้องตั้งฉากซึ่งกันและกันสำหรับการเลื่อนไปยังตำแหน่งที่เป็นเลขจำนวนเต็ม
 2. ปริภูมิย่อยที่ถูก **Spanned** โดยฟังก์ชันสเกลที่สเกลระดับต่ำจะถูกทับซ้อนโดยปริภูมิย่อยที่ถูก **Spanned** ที่สเกลระดับสูงกว่า จากรูปที่ 2.12 แสดงให้เห็นว่า $\phi_{-1}(t) = \phi_0(t) + \phi_0(t-1)$ ดังนั้นเราสามารถสรุปได้ว่าปริภูมิย่อย V_j เป็นสับเซตของปริภูมิย่อย V_{j+1}
 3. มีเพียงฟังก์ชันเดียวเท่านั้นที่เป็นฟังก์ชันร่วมของปริภูมิย่อย V_j ทั้งหมด คือ $f(x) = 0$
 4. ฟังก์ชันใดๆ สามารถถูกแสดงที่สเกลระดับใดก็ได้
- ตัวอย่างของข้อกำหนดที่ 2 เป็นดังต่อไปนี้

เราสามารถสร้างสเกลฟังก์ชันของ **Haar** ที่สเกลที่ 0 ตำแหน่งที่ 0 ได้ดังต่อไปนี้

$$\phi(t) = \phi_{0,0}(t) = \frac{1}{\sqrt{2}} \phi_{1,0}(t) + \frac{1}{\sqrt{2}} \phi_{1,1}(t) \quad (2.14)$$

$$V_2 = V_1 \oplus W_1 = V_0 \oplus W_0 \oplus W_1$$

$$V_1 = V_0 \oplus W_0$$



รูปที่ 2.13 ความสัมพันธ์ระหว่างพื้นที่ของสเกลฟังก์ชันและเวฟเลตฟังก์ชัน

หรือ อาจจะเขียนใหม่ให้อยู่รูปสมการคอนโวลูชันใหม่ได้ดังนี้

$$\phi(t) = \sum_n h_\phi[n] \sqrt{2} \phi(2t-n) \quad (2.15)$$

โดยที่ $h_\phi[n] = \{1/\sqrt{2}, 1/\sqrt{2}\}$

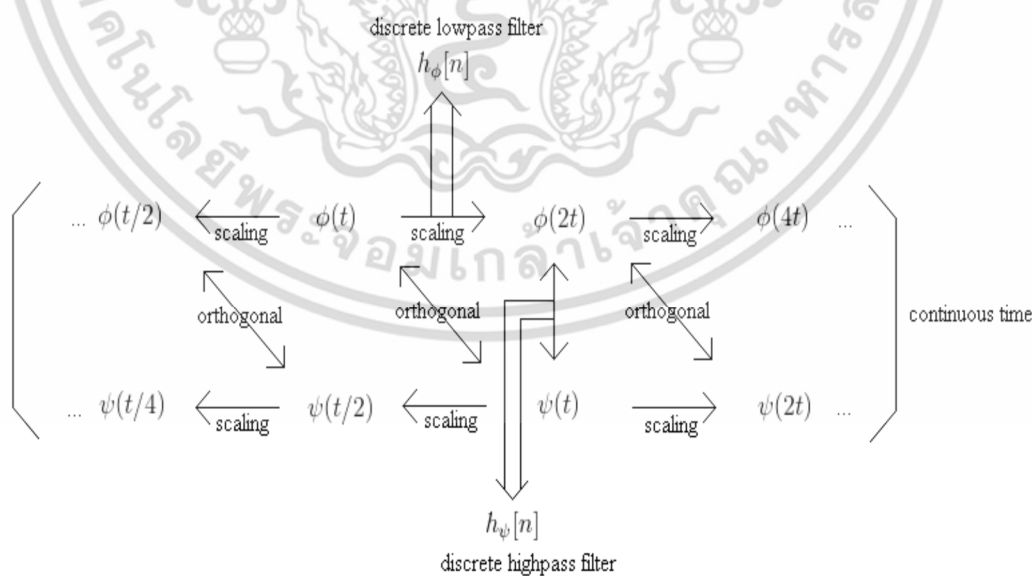
ซึ่งเรียกสมการนี้ว่าสมการ **Refinement**, สมการการวิเคราะห์ **Multiresolution** หรือสมการ **Dilation** สมการ 2.15 มีความหมายทางกายภาพ ดังต่อไปนี้

1. ฟังก์ชัน $\phi(2t)$ เป็นฟังก์ชันที่มีองค์ประกอบความถี่สูงกว่า $\phi(t)$
2. เราสามารถคำนวณหาฟังก์ชัน $\phi(t)$ โดยใช้ตัวกรองความถี่ต่ำ $h_\phi[n]$ ที่เหมาะสม ฟังก์ชันเวฟเลตก็มีความสัมพันธ์แบบเดียวกัน ดังต่อไปนี้

$$\psi(t) = \sum_n h_\psi[n] \sqrt{2} \phi(2t-n) \quad (2.16)$$

โดยที่ $h_\psi[n] = \{1/\sqrt{2}, 1/\sqrt{2}\}$ พิลเตอร์ความถี่ต่ำทั้งสองตัวนี้มีความสัมพันธ์กันดังนี้

$$h_\psi[n] = (-1) h_\phi[1-n] \quad (2.17)$$



รูปที่ 2.14 ความสัมพันธ์ระหว่างสเกลฟังก์ชันและเวฟเลตฟังก์ชัน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.4.1.5 การแปลงดิสครีตเวฟเลต (Discrete Wavelet Transform)

ในหัวข้อก่อนหน้านี้นี้เราได้พูดถึงฟังก์ชันสเกล, ฟังก์ชันเวฟเลต, และคุณสมบัติต่างๆของฟังก์ชันเหล่านี้ เราสามารถประมาณสัญญาณดิสครีตตั้งสมการ 2.18

$$f[n] = \frac{1}{\sqrt{M}} \sum_k W_\phi[j_0, k] \phi_{j_0, k}[n] + \frac{1}{\sqrt{M}} \sum_{j=j_0} W_\psi[j, k] \psi_{j, k}[n] \quad (2.18)$$

ในที่นี้ $f[n]$, $\phi_{j, k}[n]$ และ $\psi_{j, k}[n]$ คือ ดิสครีตฟังก์ชันที่มีค่าอยู่ระหว่าง $[0, M-1]$ เป็นฟังก์ชันดิสครีตจำนวนทั้งหมด M จุด หรือ $n \in [0, M-1]$ เพราะว่าเซตของ $\{\phi_{j, k}[n]\}_{k \in \mathbb{Z}}$ และ $\{\psi_{j, k}[n]\}_{(j, k) \in \mathbb{Z}^2, j \geq j_0}$ ตั้งฉากซึ่งกันและกัน เราสามารถใช้ตัวดำเนินการ Inner Product เพื่อหาสัมประสิทธิ์เวฟเลตดังนี้

$$W_\phi[j_0, k] = \frac{1}{\sqrt{M}} \sum_n f[n] \phi_{j_0, k}[n] \quad (2.19)$$

$$W_\psi[j, k] = \frac{1}{\sqrt{M}} \sum_n f[n] \psi_{j_0, k}[n], j > j_0 \quad (2.20)$$

ค่าสัมประสิทธิ์ $W_\phi[j_0, k]$ และ $W_\psi[j, k]$ ถูกเรียกว่าสัมประสิทธิ์การประมาณ และสัมประสิทธิ์ของรายละเอียด ตามลำดับ

2.4.1.6 การแปลงเวฟเลตแบบเร็ว (Fast Wavelet Transform)

การคำนวณหาค่าสัมประสิทธิ์การประมาณและสัมประสิทธิ์รายละเอียดโดยใช้สมการที่ 2.19 และ 2.20 ที่ค่าสเกล j ระดับต่ำ (สเกลหยาบ) จะใช้เวลานานมาก ดังนั้นเพื่อลดเวลาในการคำนวณวิธีการแปลงเวฟเลตแบบเร็วเป็นวิธีหนึ่งที่ถูกนำเสนอเพื่อใช้สำหรับการแก้ปัญหา การแปลงเวฟเลตแบบเร็วมีการทำงานดังต่อไปนี้ จากสมการ $\phi(t) = \sum_n h_\phi[n] \sqrt{2} \phi(2t-n)$ เราสามารถที่จะคำนวณฟังก์ชันสเกลที่สเกลเท่ากับ j ได้ดังนี้

$$\begin{aligned} \phi_{j, k}[n] &= 2^{j/2} \phi[2^j n - k] \\ &= \sum_{n'} h_\phi[n'] \sqrt{2} \phi[2(2^j n - k) - n'] \end{aligned} \quad (2.21)$$

เมื่อกำหนดให้ $n' = m - 2k$ เราจะได้

$$\phi_{j, k}[n] = \sum_m h_\phi[m - 2k] \sqrt{2} \phi[2^{j+1} n - m] \quad (2.22)$$

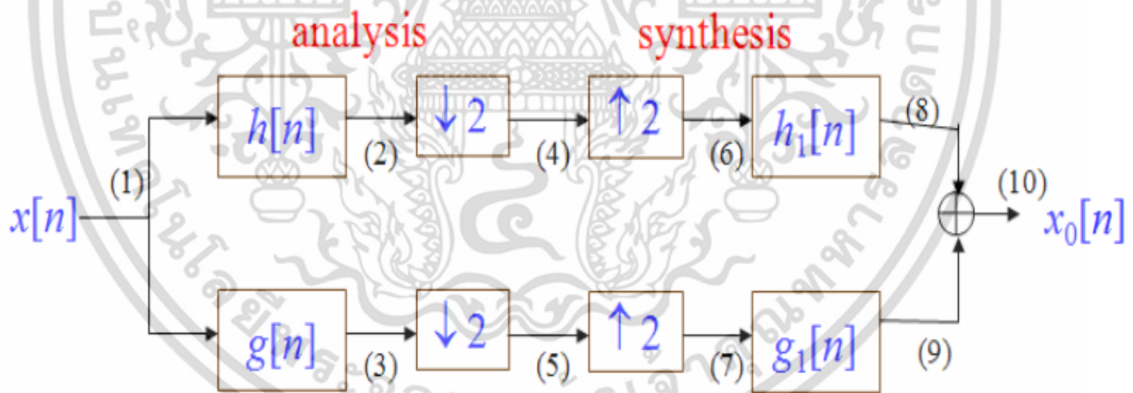
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เมื่อนำสมการที่ 2.22 แทนในสมการที่ 2.19 เราจะได้

$$\begin{aligned}
 W_\phi[j, k] &= \frac{1}{\sqrt{M}} \sum_n f[n] \phi_{j,k}[n] \\
 &= \frac{1}{\sqrt{M}} \sum_n f[n] 2^{j/2} \phi_{j,k}[2^j n - k] \\
 &= \frac{1}{\sqrt{M}} \sum_n f[n] 2^{j/2} \sum_m h_\phi[m - 2k] \sqrt{2} \phi[2^{j+1} n - m] \\
 &= \sum_m h_\phi[m - 2k] \left(\frac{1}{\sqrt{M}} \sum_n f[n] 2^{(j+1)/2} \phi_{j,k}[2^{j+1} n - m] \right) \\
 &= \sum_m h_\phi[m - 2k] W_\phi[j+1, m] \\
 &= h_\phi[-n] * W_\phi[j+1, n] \Big|_{n=2k, k \geq 0}
 \end{aligned} \tag{2.23}$$

เราสามารถคำนวณค่าสัมประสิทธิ์รายละเอียดด้วยวิธีเดียวกันและได้ผลลัพธ์เป็นดังนี้

$$W_\psi[j, k] = h_\psi[-n] * W_\psi[j+1, n] \Big|_{n=2k, k \geq 0} \tag{2.24}$$



รูปที่ 2.15 บล็อกไดอะแกรมของการแปลงเวฟเลตแบบดิสครีต


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.4.1.7 Mother Wavelet

2.4.1.7.1 Haar Mother Wavelet เป็นเวฟเลตตัวแรกที่ถูกพัฒนาขึ้นมาและเป็นแบบง่ายที่สุด ซึ่งมีสมการของสเกลและเวฟเลตฟังก์ชัน ดังต่อไปนี้

$$\phi(x) = \begin{cases} 1, & 0 < x < 1 \\ 0, & \text{Elsewhere} \end{cases} \quad (2.25)$$

$$\psi(t) = \begin{cases} 1, & 0 < t < 1/2 \\ -1, & 1/2 < t < 1 \\ 0, & \text{Otherwise} \end{cases} \quad (2.26)$$



รูปที่ 2.16 ตัวอย่างสเกลและเวฟเลตฟังก์ชันของ Harr Wavelet

ถึงแม้ว่า Haar Wavelet เป็นเวฟเลตที่ง่ายที่สุดแต่ข้อเสียของ Haar Wavelet คือ Haar Wavelet เป็นฟังก์ชันไม่ต่อเนื่องและไม่สามารถหอนูนพันธ์ได้ Haar Wavelet เหมาะสำหรับการวิเคราะห์สัญญาณที่มีการเปลี่ยนแปลงอย่างรวดเร็ว เช่น ใช้ในการวิเคราะห์เสียงการแตกหักของเครื่องจักร เป็นต้น

2.4.1.7.2 Daubechies Mother Wavelet

เป็นเวฟเลตที่มี Vanishing Moment สูงที่สุด จำนวนของ Vanishing Moment เท่ากับ $\frac{N}{2}$ โดยที่ N เท่ากับจำนวนของสัมประสิทธิ์ (Tap) จำนวนของ Vanishing Moment เป็นคุณสมบัติที่สำคัญอันหนึ่งของการแปลงเวฟเลต ในทางทฤษฎีเวฟเลตที่มี Vanishing Moment มาก จะสามารถใช้แสดงสัญญาณที่มีความซับซ้อนได้อย่างแม่นยำ แต่ข้อเสียคือต้องใช้เวลาในการคำนวณนานเนื่องจากมีจำนวนสัมประสิทธิ์มาก ในวิทยานิพนธ์ฉบับนี้ได้เลือกใช้ Daubechies Wavelet ที่มี Vanishing Moment เท่ากับ $2, 4, 6, \dots, 20 (D_2, D_4, D_6, \dots, D_{20})$ ค่าสัมประสิทธิ์ของ สเกลและเวฟเลตฟังก์ชันของ Daubechies Wavelet ถูกแสดงในตารางที่ 2.1

ตารางที่ 2.1 ค่าสัมประสิทธิ์สเกลและเวฟเลตฟังก์ชันของ Daubechies Wavelet ตั้งแต่ D2-D20

DB2		DB4		DB6		DB8	
Scale	Wavelet	Scale	Wavelet	Scale	Wavelet	Scale	Wavelet
-0.12940952	-0.482962913	-0.010597402	-0.230377813	-0.001077301	-0.111540743	-0.000117477	-0.054415842
0.224143868	0.836516304	0.032883012	0.714846571	0.004777258	0.49462389	0.000675449	0.312871591
0.836516304	-0.224143868	0.030841382	-0.630880768	0.000553842	-0.751133908	-0.00039174	-0.675630736
0.482962913	-0.129409523	-0.187034812	-0.027983769	-0.031582039	0.315250352	-0.004870353	0.585354684
		-0.027983769	0.187034812	0.027522866	0.226264694	0.008746094	0.015829105
		0.630880768	0.030841382	0.097501606	-0.129766868	0.013981028	-0.284015543
		0.714846571	-0.032883012	-0.129766868	-0.097501606	-0.044088254	-0.000472485
		0.230377813	-0.010597402	-0.226264694	0.027522866	-0.017369301	0.128747427
				0.315250352	0.031582039	0.128747427	0.017369301
				0.751133908	0.000553842	0.000472485	-0.044088254
				0.49462389	-0.004777258	-0.284015543	-0.013981028
				0.111540743	-0.001077301	-0.015829105	0.008746094
						0.585354684	0.004870353
						0.675630736	-0.00039174
						0.312871591	-0.000675449
						0.054415842	-0.000117477

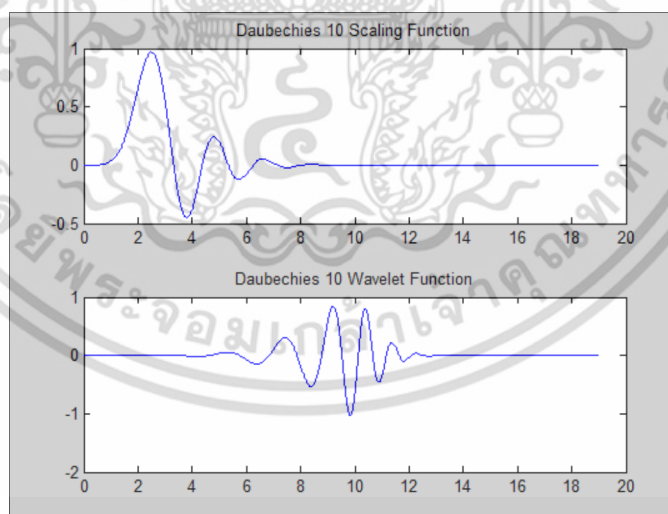
ตารางที่ 2.1 (ต่อ)

DB10		DB10		DB12		DB12	
Scale	Scale(ต่อ)	Wavelet	Wavelet (ต่อ)	Scale	Scale(ต่อ)	Wavelet	Wavelet (ต่อ)
-1.33E-05	-0.071394147	-0.026670058	0.029457537	-1.53E-06	1.08E-02	-0.013112258	-0.041546277
9.35887E-05	0.093057365	0.1881768	0.033212674	1.28E-05	-9.64E-02	0.109566273	-0.012218649
-0.00011647	0.12736934	-0.527201189	-0.003606554	-2.42415E-05	5.36E-03	-0.377355135	0.012840825
-0.00068586	-0.195946274	0.688459039	-0.010733175	-8.85041E-05	0.182478606	0.657198723	0.006711499
0.001992405	-0.249846424	-0.281172344	-0.001395352	0.000388653	-0.023779257	-0.515886478	-0.002248607
0.001395352	0.281172344	-0.249846424	0.001992405	6.54513E-06	-0.316178454	-0.044763886	-0.002179504
-0.01073318	0.688459039	0.195946274	0.000685857	-0.002179504	-0.044763886	0.316178454	-6.54513E-06
0.003606554	0.527201189	0.12736934	-0.000116467	0.002248607	0.515886478	-0.023779257	0.000388653
0.033212674	0.1881768	-0.093057365	-9.35887E-05	0.006711499	0.657198723	-0.182478606	8.85041E-05
-0.02945754	2.67E-02	-7.14E-02	-1.33E-05	-0.012840825	0.377355135	5.36E-03	-2.42415E-05
				-0.012218649	0.109566273	9.64E-02	-1.28E-05
				0.041546277	0.013112258	1.08E-02	-1.53E-06
DB14		DB14		DB16		DB16	
Scale	Scale(ต่อ)	Wavelet	Wavelet (ต่อ)	Scale	Scale(ต่อ)	Wavelet	Wavelet (ต่อ)
-1.79E-07	2.70E-02	-0.006461153	0.030185352	-2.11E-08	-3.69E-02	-0.003189221	-0.01029766
1.72E-06	5.52E-02	0.062364759	-0.00561505	2.31E-07	-7.59E-03	0.034907714	0.013993769
-4.39E-06	-7.15E-02	-0.254850268	-0.012789493	-7.36E-07	7.59E-02	-0.165064283	0.006990015
-1.0337E-05	-0.086748412	0.554305618	-0.000746219	-1.04E-06	-0.006239723	0.430312723	-0.00364428
6.8755E-05	0.139989017	-0.631187849	0.003849639	1.13366E-05	-0.132388306	-0.637356332	-0.003128023
-4.1777E-05	0.138395214	0.218670688	0.001061691	-1.39457E-05	0.027340264	0.440290257	0.000407897
-0.00038683	-0.21803353	0.271688552	-0.000708021	-6.1036E-05	0.211190694	0.089751089	0.000941022
0.000708021	-0.271688552	-0.21803353	-0.000386832	0.000174787	-0.027918208	-0.327063311	0.000114242
0.001061691	0.218670688	-0.138395214	4.17772E-05	0.000114242	-0.327063311	0.027918208	-0.000174787
-0.00384964	0.631187849	0.139989017	6.8755E-05	-0.000941022	-0.089751089	0.211190694	-6.1036E-05
-0.00074622	0.554305618	0.086748412	1.03372E-05	0.000407897	0.440290257	-0.027340264	1.39457E-05
0.012789493	0.254850268	-7.15E-02	-4.39E-06	0.003128023	0.637356332	-0.132388306	1.13366E-05
-0.00561505	0.062364759	-5.52E-02	-1.72E-06	-0.00364428	0.430312723	0.006239723	1.04E-06
-0.03018535	0.006461153	2.70E-02	-1.79E-07	-0.006990015	0.165064283	7.59E-02	-7.36E-07
				0.013993769	0.034907714	7.59E-03	-2.31E-07
				0.01029766	0.003189221	-3.69E-02	-2.11E-08

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 2.1 (ต่อ)

DB18		DB18		DB20		DB20	
Scale	Scale(ต่อ)	Wavelet	Wavelet (ต่อ)	Scale	Scale(ต่อ)	Wavelet	Wavelet (ต่อ)
-2.51E-09	2.67E-02	-0.00157631	-0.006262168	-3.00E-10	-8.79E-03	-0.000779954	0.013810526
3.07E-08	-2.37E-02	0.019288532	-0.013051481	4.06E-09	3.23E-02	0.010549395	0.006721627
-1.18E-07	-4.45E-02	-0.103588466	-0.00011863	-1.81E-08	5.87E-03	-0.06342378	-0.004420542
-7.69E-08	5.71E-02	0.314678941	0.004943344	2.01E-10	-6.17E-02	0.219942114	-0.003581494
1.77E-06	0.064887216	-0.571826808	0.001118733	2.63E-07	5.63E-03	-0.472696185	0.000831562
-3.3326E-06	-0.106752247	0.571801655	-0.001340596	-6.85E-07	0.102291719	0.610493239	0.00139256
-8.5206E-06	-0.092331884	-0.147223112	-0.000628466	-1.01199E-06	-2.47E-02	-0.361502299	5.34976E-05
3.74124E-05	0.167081313	-0.293654041	0.000213582	7.24125E-06	-0.155458751	-0.139212088	-0.000385105
-1.5359E-07	0.149533976	0.216480934	0.000198649	-4.37614E-06	0.039850246	0.3267868	-0.000101533
-0.00019865	-0.216480934	0.149533976	-1.53592E-07	-3.71059E-05	0.228291051	-0.016727088	6.77428E-05
0.000213582	-0.293654041	-0.167081313	-3.74124E-05	6.77428E-05	-0.016727088	-0.228291051	3.71059E-05
0.000628466	0.147223112	-0.092331884	-8.5206E-06	0.000101533	-0.3267868	0.039850246	-4.37614E-06
-0.0013406	0.571801655	0.106752247	3.33263E-06	-0.000385105	-0.139212088	0.155458751	-7.24125E-06
-0.00111873	0.571826808	0.064887216	1.77E-06	-5.34976E-05	0.361502299	-2.47E-02	-1.01199E-06
0.004943344	0.314678941	-5.71E-02	7.69E-08	0.00139256	0.610493239	-0.102291719	6.85E-07
0.00011863	0.103588466	-4.45E-02	-1.18E-07	-0.000831562	0.472696185	5.63E-03	2.63E-07
-0.01305148	0.019288532	2.37E-02	-3.07E-08	-0.003581494	0.219942114	6.17E-02	-2.01E-10
0.006262168	0.00157631	0.026670706	-2.51E-09	0.004420542	0.06342378	5.87E-03	-1.81E-08
				0.006721627	0.010549395	-3.23E-02	-4.06E-09
				-0.013810526	0.000779954	-8.79E-03	-3.00E-10



รูปที่ 2.17 ตัวอย่างสเกลและเวฟเลตฟังก์ชันของ Daubechies Wavelet Vanishing Moment เท่ากับ 10

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.4.1.7.3 Symlet Mother Wavelet

เป็นเวฟเลตที่มีคุณสมบัติที่ดีหลายอย่างคือ ความตั้งฉาก(Orthogonal) และความกระชับ (Compact Support) Symlet Wavelet ถูกพัฒนามาจาก Daubechies Wavelet ให้มีจำนวน Vanishing Moment มากขึ้น นอกจากนี้ Symlet Wavelet ยังเป็นเวฟเลตตั้งฉากที่มีรูปร่างเกือบสมมาตรมากที่สุดหรือมีความอสมมาตรน้อยที่สุด [17] ทำให้สเกลฟังก์ชันมีความเป็น Linear Phase สูง ซึ่งมีข้อดีคือ ทำให้สัมประสิทธิ์เวฟเลตหลังจากผ่านการทำ Sub-Sampling ไม่ขึ้นกับการเลื่อนทางเวลา (Time Shift Invariant) รูปที่ 2.18 ตัวอย่างสเกลและเวฟเลตฟังก์ชันของ Symlet Wavelet

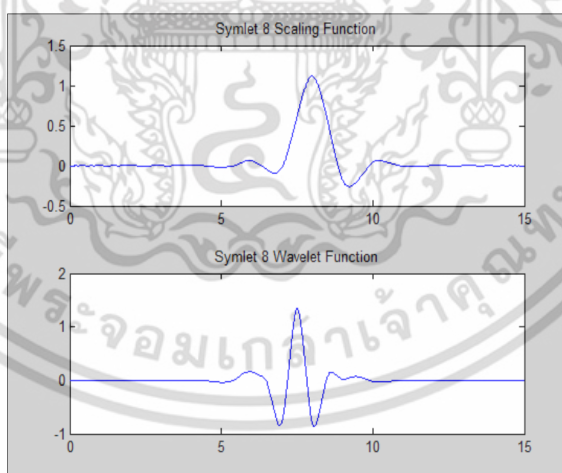
ในวิทยานิพนธ์ฉบับนี้ได้เลือกใช้ Symlet Wavelet ที่มี Vanishing Moment เท่ากับ $2-9$ (Sym2 – Sym9) ค่าสัมประสิทธิ์ของ สเกลและเวฟเลตฟังก์ชันของ Symlet Wavelet ถูกแสดงในตารางที่ 2.2

ตารางที่ 2.2 ค่าสัมประสิทธิ์สเกลและเวฟเลตฟังก์ชันของ Symlet Wavelet ตั้งแต่ Sym2-Sym9

Sym2		Sym3		Sym4		Sym5	
Scale	Wavelet	Scale	Wavelet	Scale	Wavelet	Scale	Wavelet
-0.12940952	-0.482962913	0.035226292	-0.332670553	-0.075765715	-0.032223101	0.027333068	-0.019538883
0.224143868	0.836516304	-0.085441274	0.806891509	-0.029635528	-0.012603967	0.029519491	-0.021101834
0.836516304	-0.224143868	-0.13501102	-0.459877502	0.497618668	0.099219544	-0.039134249	0.17532809
0.482962913	-0.129409523	0.459877502	-0.13501102	0.803738752	0.297857796	0.199397534	0.016602106
		0.806891509	0.085441274	0.297857796	-0.803738752	0.72340769	-0.633978963
		0.332670553	0.035226292	-0.099219544	0.497618668	0.633978963	0.72340769
				-0.012603967	0.029635528	0.016602106	-0.199397534
				0.032223101	-0.075765715	-0.17532809	-0.039134249
						-0.021101834	-0.029519491
						0.019538883	0.027333068

ตารางที่ 2.2 (ต่อ)

Sym6		Sym7		Sym8		Sym9	
Scale	Wavelet	Scale	Wavelet	Scale	Wavelet	Scale	Wavelet
0.015404109	0.007800708	0.002681815	-0.010268177	-0.003382416	-0.00188995	0.001400916	-0.00106949
0.003490712	0.001767712	-0.001047385	0.004010245	-0.000542132	-0.000302921	0.000619781	-0.000473154
-0.11799011	-0.044724902	-0.012636303	0.107808238	0.031695088	0.014952258	-0.013271968	0.010264064
-0.04831174	-0.021060293	0.030515513	-0.14004724	0.007607487	0.003808752	-0.01152821	0.008859267
0.491055942	0.072637523	0.067892694	-0.288629632	-0.143294238	-0.04913718	0.030224879	-0.062077789
0.787641141	0.337929422	-0.049552835	0.767764317	-0.061273359	-0.02721903	0.000583463	-0.018233771
0.337929422	-0.787641141	0.017441255	-0.536101917	0.481359651	0.051945838	-0.054568958	0.191550831
-0.07263752	0.491055942	0.536101917	0.017441255	0.777185752	0.364441895	0.238760915	0.035272488
-0.02106029	0.048311743	0.767764317	0.049552835	0.364441895	-0.777185752	0.717897083	-0.617338449
0.044724902	-0.117990111	0.288629632	0.067892694	-0.051945838	0.481359651	0.617338449	0.717897083
0.001767712	-0.003490712	-0.14004724	-0.030515513	-0.02721903	0.061273359	0.035272488	-0.238760915
-0.00780071	0.015404109	-0.107808238	-0.012636303	0.04913718	-0.143294238	-0.191550831	-0.054568958
		0.004010245	0.001047385	0.003808752	-0.007607487	-0.018233771	-0.000583463
		0.010268177	0.002681815	-0.014952258	0.031695088	0.062077789	0.030224879
				-0.000302921	0.000542132	0.008859267	0.01152821
				0.00188995	-0.003382416	-0.010264064	-0.013271968
						-0.000473154	-0.000619781
						0.00106949	0.001400916



รูปที่ 2.18 ตัวอย่างสเกลและเวฟเลตฟังก์ชันของ Symlet Wavelet

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.4.1.7.4 Coiflet Mother Wavelet


เป็นฟังก์ชันที่มี Vanishing Moment สูง ถูกออกแบบโดย Ingird Daubichies ตามคำแนะนำของ Ronald Coifman จำนวนของ Vanishing Moment ของเวฟเลตฟังก์ชันเท่ากับ $\frac{N}{3}$ โดยที่ N เท่ากับจำนวนของสัมประสิทธิ์ และสเกลฟังก์ชันเท่ากับ $\frac{N}{3}-1$ ในวิทยานิพนธ์ฉบับนี้ได้เลือกใช้ Coiflet Wavelet ที่มี Vanishing Moment เท่ากับ 1-5 (Coif1-Coif5) ค่าสัมประสิทธิ์ของสเกลและเวฟเลตฟังก์ชันของ Coiflet Wavelet ถูกแสดงในตารางที่ 2.3

ตารางที่ 2.3 ค่าสัมประสิทธิ์สเกลและเวฟเลตของฟังก์ชัน Coiflet Wavelet ตั้งแต่ Coif1-Coif5

Coif1		Coif2		Coif3		Coif4	
Scale	Wavelet	Scale	Wavelet	Scale	Wavelet	Scale	Wavelet
-0.01565573	0.07273262	-0.000720549	-0.016387336	-3.46E-05	0.003793513	-1.78E-06	-8.92E-04
-0.07273262	0.337897662	-0.001823209	-0.041464937	-7.10E-05	0.007782596	-3.26E-06	-1.63E-03
0.384864847	-0.85257202	0.005611435	0.067372555	0.000466217	-0.023452696	3.12299E-05	0.007346166
0.85257202	0.384864847	0.023680172	0.386110067	0.001117519	-0.065771911	6.2339E-05	0.016068944
0.337897662	0.07273262	-0.059434419	-0.812723635	-0.002574518	0.06112339	-0.000259975	-0.0266823
-0.07273262	-0.015655728	-0.076488599	0.417005184	-0.009007976	0.405176902	-0.000589021	-0.0812667
		0.417005184	0.076488599	0.015880545	-0.793777223	0.001266562	0.056077313
		0.812723635	-0.059434419	0.034555028	0.428483476	0.003751436	0.415308407
		0.386110067	-0.023680172	-0.082301927	0.071799822	-0.005658287	-0.782238931
		-0.067372555	0.005611435	-0.071799822	-0.082301927	-0.015211732	0.434386056
		-0.041464937	0.001823209	0.428483476	-0.034555028	0.025082262	0.066627474
		0.016387336	-0.000720549	0.793777223	0.015880545	0.039334427	-0.096220442
				0.405176902	0.009007976	-9.62E-02	-3.93E-02
				-0.06112339	-0.002574518	-6.66E-02	2.51E-02
				-0.065771911	-0.001117519	0.434386056	0.015211732
				0.023452696	0.000466217	0.782238931	-0.005658287
				0.007782596	7.10E-05	0.415308407	-0.003751436
				-0.003793513	-3.46E-05	-0.056077313	0.001266562
						-0.0812667	0.000589021
						0.0266823	-0.000259975
						0.016068944	-6.2339E-05
						-0.007346166	3.12299E-05
						-0.001629492	3.25968E-06
						0.000892314	-1.78499E-06

ตารางที่ 2.3 (ต่อ)

Coif5					
Scale	Scale (ต่อ)	Scale (ต่อ)	Wavelet	Wavelet (ต่อ)	Wavelet (ต่อ)
-9.52E-08	2.43E-03	4.22E-01	0.000212081	-0.774289604	0.001662864
-1.67E-07	6.76E-03	-5.20E-02	0.00035859	0.437991626	-0.000638131
2.06376E-06	-0.009164231	-0.091920011	-0.002178236	0.062035964	-0.00030226
3.73466E-06	-0.019761779	0.028168029	-0.004159359	-0.105574209	0.000140541
-2.1315E-05	0.032683574	0.023408157	0.010131118	-0.041289209	4.13404E-05
-4.134E-05	0.041289209	-0.010131118	0.023408157	0.032683574	-2.1315E-05
0.000140541	-0.105574209	-0.004159359	-0.028168029	0.019761779	-3.73466E-06
0.00030226	-0.062035964	0.002178236	-0.091920011	-0.009164231	2.06376E-06
-0.00063813	0.437991626	0.00035859	5.20E-02	-6.76E-03	1.67E-07
-0.00166286	0.774289604	-0.000212081	4.22E-01	2.43E-03	-9.52E-08



รูปที่ 2.19 สเกลและเวฟเลตฟังก์ชันของ Coiflet Wavelet

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.4.1.7.5 Biorthogonal Mother Wavelet

เป็นฟังก์ชันที่ไม่มีคุณสมบัติตั้งฉาก เนื่องจากการออกแบบเวฟเลตฟังก์ชันให้มีคุณสมบัติครบทั้งความตั้งฉาก ความกระชับ และความสมมาตร เป็นไปไม่ได้ นอกจาก Haar Wavelet แล้วไม่มี Wavelet ตั้งฉากใดที่มีสมมาตร ดังนั้นถ้าต้องการ Wavelet ที่มีความสมมาตรเราจำเป็นต้องเลือกใช้ Biorthogonal Wavelet เพื่อให้การแปลง Biorthogonal Wavelet สามารถสร้างคืนสัญญาณเดิมได้อย่างสมบูรณ์ (Perfect Reconstruction) สเกลและเวฟเลตฟังก์ชันของ Biorthogonal Wavelet ทางฝั่ง Reconstruction และ ฝั่ง Decomposition เป็นคนละฟังก์ชันกัน (จึงเป็นที่มาของชื่อ Biorthogonal Wavelet) คู่ของสเกลฟังก์ชัน ($A_w(j)$ และ $\tilde{A}_w(j)$) และคู่ของเวฟเลตฟังก์ชัน ($D_w(j)$ และ $\tilde{D}_w(j)$) ของ Biorthogonal Wavelet มีคุณสมบัติดังนี้

1. มีคุณสมบัติตั้งฉากระหว่างคู่ฟังก์ชัน

$$\langle A_w(t), \tilde{A}_w(t-k) \rangle = \delta k \quad (2.27)$$

$$\langle D_w(t), \tilde{D}_w(t-k) \rangle = \delta k \quad (2.28)$$

2. มีคุณสมบัติตั้งฉากระหว่างสเกลฟังก์ชันและเวฟเลตฟังก์ชัน

$$\langle A_w(t), D_w(t-k) \rangle = 0 \quad (2.29)$$

$$\langle A_w(t), \tilde{D}_w(t-k) \rangle = 0 \quad (2.30)$$

$$\langle D_w(t), \tilde{A}_w(t-k) \rangle = 0 \quad (2.31)$$

$$\langle \tilde{A}_w(t), \tilde{D}_w(t-k) \rangle = 0 \quad (2.32)$$

เราสามารถกำหนด Vanishing Moment ของสเกลและเวฟเลตฟังก์ชันฝั่ง Reconstruction (N_r) และ Vanishing Moment ของสเกลและเวฟเลตฟังก์ชันฝั่ง Decomposition (N_d) ได้อิสระจากกัน โดยที่จำนวนสัมประสิทธิ์สเกลและเวฟเลตฟังก์ชันของฝั่ง Reconstruction เท่ากับ $2N_r + 1$ และจำนวนสัมประสิทธิ์สเกลและเวฟเลตฟังก์ชันของฝั่ง Decomposition เท่ากับ $2N_d + 1$ รูปแบบของการตั้งชื่อของ Biorthogonal Wavelet มีดังนี้คือ Bior $N_r.N_d$ ตารางที่ 2.4 แสดงตารางสัมประสิทธิ์สเกลและเวฟเลตฟังก์ชัน ในวิทยานิพนธ์ฉบับนี้ได้เลือกใช้ Biorthogonal Wavelet ที่มี Vanishing Moment ดังต่อไปนี้ 1.1–6.8 (Bior1.1–Bior6.8)

ตารางที่ 2.4 ค่าสัมประสิทธิ์สเกลของฟังก์ชัน Biorthogonal Wavelet ตั้งแต่ Bior1.1 - Bior6.8

Bior1.1		Bior1.3		Bior1.5		Bior2.2	
Scale	Wavelet	Scale	Wavelet	Scale	Wavelet	Scale	Wavelet
0.707106781	-0.707106781	-0.088388348	0	0.016572815	0	0	0
0.707106781	0.707106781	0.088388348	0	-0.016572815	0	-0.176776695	0.353553391
		0.707106781	-0.707106781	-0.121533978	0	0.353553391	-0.707106781
		0.707106781	0.707106781	0.121533978	0	1.060660172	0.353553391
		0.088388348	0	0.707106781	-0.707106781	0.353553391	0
		-0.088388348	0	0.707106781	0.707106781	-0.176776695	0
				0.121533978	0		
				-0.121533978	0		
				-0.016572815	0		
				0.016572815	0		
Bior2.4		Bior2.6		Bior2.8		Bior3.1	
Scale	Wavelet	Scale	Wavelet	Scale	Wavelet	Scale	Wavelet
0	0	0	0	0	0	-0.353553391	-0.176776695
0.03314563	0	-0.00690534	0	0.001510543	0	1.060660172	0.530330086
-0.06629126	0	0.013810679	0	-0.003021086	0	1.060660172	-0.530330086
-0.1767767	0.353553391	0.04695631	0	-0.012947512	0	-0.353553391	0.176776695
0.419844651	-0.707106781	-0.107723299	0	0.02891611	0		
0.994368911	0.353553391	-0.169871356	0.353553391	0.052998482	0		
0.419844651	0	0.44746601	-0.707106781	-0.134913074	0		
-0.1767767	0	0.966747552	0.353553391	-0.163829183	0.353553391		
-0.06629126	0	0.44746601	0	0.46257144	-0.707106781		
0.03314563	0	-0.169871356	0	0.951642122	0.353553391		
		-0.107723299	0	0.46257144	0		
		0.04695631	0	-0.163829183	0		
		0.013810679	0	-0.134913074	0		
		-0.00690534	0	0.052998482	0		
				0.02891611	0		
				-0.012947512	0		
				-0.003021086	0		
				0.001510543	0		

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


ตารางที่ 2.4 (ต่อ)

Bior3.3		Bior3.5		Bior3.7		Biro3.9	
Scale	Wavelet	Scale	Wavelet	Scale	Wavelet	Scale	Wavelet
0.066291261	0	-0.013810679	0	0.003021086	0	-0.000679744	0
-0.19887378	0	0.041432038	0	-0.009063258	0	0.002039233	0
-0.15467961	-0.176776695	0.052480581	0	-0.016831765	0	0.005060319	0
0.994368911	0.530330086	-0.267927179	0	0.074663985	0	-0.020618913	0
0.994368911	-0.530330086	-0.071815532	-0.176776695	0.031332979	0	-0.014112788	0
-0.15467961	0.176776695	0.966747552	0.530330086	-0.301159126	0	0.099134782	0
-0.19887378	0	0.966747552	-0.530330086	-0.026499241	-0.176776695	0.012300136	0
0.066291261	0	-0.071815532	0.176776695	0.951642122	0.530330086	-0.320191968	0
		-0.267927179	0	0.951642122	-0.530330086	0.002050023	-0.176776695
		0.052480581	0	-0.026499241	0.176776695	0.942125701	0.530330086
		0.041432038	0	-0.301159126	0	0.942125701	-0.530330086
		-0.013810679	0	0.031332979	0	0.002050023	0.176776695
				0.074663985	0	-0.320191968	0
				-0.016831765	0	0.012300136	0
				-0.009063258	0	0.099134782	0
				0.003021086	0	-0.014112788	0
						-0.020618913	0
						0.005060319	0
						0.002039233	0
						-0.000679744	0

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 2.4 (ต่อ)

Bior4.4		Bior5.5		Bior6.8	
Scale	Wavelet	Scale	Wavelet	Scale	Wavelet
0	0	0	-0.013456709	0	0
0.037828456	-0.064538883	0	-0.002694967	0.001908832	0
-0.02384947	0.040689418	0.039687088	0.136706585	-0.001914286	0
-0.1106244	0.418092273	0.007948109	-0.093504697	-0.01699064	0.014426283
0.377402856	-0.788485616	-0.054463788	-0.476803266	0.011934565	-0.014467505
0.852698679	0.418092273	0.345605282	0.89950611	0.049732903	-0.078722001
0.377402856	0.040689418	0.736660181	-0.476803266	-0.077263173	0.040367979
-0.1106244	-0.064538883	0.345605282	-0.093504697	-0.094059203	0.417849109
-0.02384947	0	-0.054463788	0.136706585	0.420796285	-0.758907729
0.037828456	0	0.007948109	-0.002694967	0.825922997	0.417849109
		0.039687088	-0.013456709	0.420796285	0.040367979
		0	0	-0.094059203	-0.078722001
				-0.077263173	-0.014467505
				0.049732903	0.014426283
				0.011934565	0
				-0.01699064	0
				-0.001914286	0
				0.001908832	0



รูปที่ 2.20 สเกลและเวฟเลตฟังก์ชันของ Biorthogonal Wavelet

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


2.4.2 ทฤษฎีโครงข่ายประสาทเทียม

โครงข่ายประสาทเทียม [14,15] เป็นเครือข่ายที่มีโครงสร้างและการประมวลผลเหมือนกับสมอง ในสิ่งมีชีวิตที่มีการปรับเปลี่ยนตัวเองต่อการตอบสนองของอินพุตตามกฎการเรียนรู้ (learning rule) หลังจากที่เครือข่ายได้เรียนรู้สิ่งที่ต้องการแล้ว เครือข่ายนั้นจะสามารถทำงานตามที่กำหนดไว้ได้ เครือข่ายประสาทเทียมได้ถูกพัฒนาคิดค้นจากการทำงานของสมองมนุษย์ โดยสมองมนุษย์ประกอบไปด้วยหน่วยประมวลผลที่เรียกว่านิวรอน (เซลล์ประสาท หรือ neuron) สมองมนุษย์จึงสามารถกล่าวได้ว่าเป็นคอมพิวเตอร์ที่มีการปรับตัว (adaptive) ไม่เป็นเชิงเส้น (nonlinear) และทำงานแบบขนาน (parallel) ในการดูแลจัดการการทำงานร่วมกันของนิวรอนในสมอง การคำนวณเชิงนิวรอนเป็นการคำนวณที่เลียนแบบมาจากการทำงานของสมองมนุษย์นั่นเอง

2.4.2.1 โครงข่ายประสาทเชิงชีววิทยา (Biological Neural Network)

ระบบประสาทเป็นระบบที่ใหญ่และซับซ้อน สมองเป็นศูนย์กลางของระบบประสาทโดยจะเชื่อมต่อกับประสาทสัมผัส เพื่อรับข้อมูลจากภายนอกเข้าสู่ประสาท แล้วทำการประมวลผลเป็นคำสั่งไปยังอวัยวะต่างๆ โดยปกติสมองประกอบไปด้วยนิวรอนจำนวนมากและมีการเชื่อมต่อกันภายในเครือข่ายย่อยเรียกว่านิวเคลียส (nuclei) เครือข่ายย่อยจะทำการแยกและปรับข้อมูลจากประสาทสัมผัสก่อนส่งไปยังเครือข่ายย่อยอื่นๆ และสุดท้ายกลายเป็นรูปแบบของสัญญาณที่ผ่านการประมวลผลเป็นคำสั่งไปยังอวัยวะต่างๆ

ระบบประสาทประกอบด้วยเซลล์ประสาทที่มีการเชื่อมต่อกันดังรูปที่ 2.21 เซลล์ประสาทสื่อสารกันโดยผ่านสัญญาณทางไฟฟ้าที่เคลื่อนที่ในทิศทางเดียวกัน แต่กิ่งก้านไปยังส่วนเซลล์อื่นๆ การเชื่อมต่อระหว่างเซลล์ประสาท ประกอบด้วยส่วนที่มีการแตกแขนงออกไปเป็นที่รู้จักกันในชื่อว่า Dendrites โดย Dendrites ทำหน้าที่รับสัญญาณจากเซลล์ประสาทอื่น ๆ ผ่านส่วนที่เรียกว่า Axon ซึ่ง Axon ถูกสร้างเพื่อการติดต่อระหว่างเซลล์ประสาท และเป็นส่วนที่นำสัญญาณทางไฟฟ้าที่ปล่อยออกมาจากเซลล์ประสาทขาออก ในขณะที่เดียวกันเซลล์ประสาทใดๆ ก็สามารถรับสัญญาณจากเซลล์ประสาทอื่น ๆ

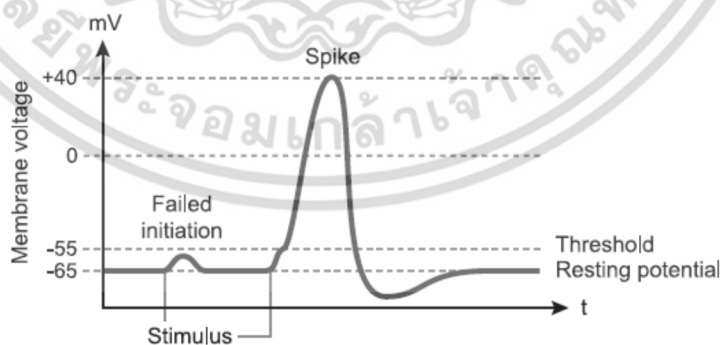


รูป 2.21 รายละเอียดของเซลล์ประสาทชีวภาพ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้คัดลอกเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การส่งสัญญาณทางไฟฟ้าระหว่างเซลล์ประสาทใดๆใช้อุปกรณ์ทางไฟฟ้าชีวภาพ ที่เรียกว่า **Synapses** เป็นสื่อกลาง โดยที่ **Synapses** จะพบอยู่บริเวณจุดต่อระหว่าง **Axon** และ **Dendrites** สัญญาณทางไฟฟ้าที่เข้ามายังจุดนี้จะทำให้ **Synapses** ถูกกระตุ้นให้เกิดการปล่อยสารเคมีที่เรียกว่าสารสื่อประสาท (**Neurotransmitter**) ซึ่งสารสื่อประสาทจะกระตุ้นโมเลกุลที่อยู่บน **Dendrites** ทำให้ไอออนเกิดประจุไฟฟ้าเรียกว่าไอออน (**ion**) โดยไอออนเหล่านี้จะสร้างแรงดันไฟฟ้าขึ้นระหว่างเยื่อหุ้มเซลล์ที่เดินทางจาก **Dendrites** ไปยังส่วนของ **Axon** เพราะฉะนั้นความแตกต่างระหว่างแรงดันไฟฟ้าภายในของตัวเซลล์ประสาทและสภาพแวดล้อมภายนอก มีผลต่อการทำงานของระบบเซลล์ประสาท ซึ่งเป็นที่รู้จักกันในชื่อว่า “ระดับการเปิดใช้งานหรือระดับศักยภาพของเซลล์ประสาท” เซลล์ที่มีการส่งและการรับเซลล์สัญญาณจากประสาทอื่นจะเรียกเซลล์ประสาทนั้นว่า **Presynaptic** และ **Postsynaptic** ตามลำดับ

เซลล์ประสาทจะแพร่สัญญาณไฟฟ้าไปตาม **Axon** และเมื่อความแตกต่างของแรงดันไฟฟ้าระหว่างเยื่อหุ้มเซลล์และบริเวณสิ่งแวดล้อมภายนอกมีขนาดใหญ่มากกว่าค่าขีดเริ่มที่กำหนดไว้ดังรูปที่ 2.22 ที่แสดงตัวอย่างของสัญญาณที่เกิดขึ้นในระบบประสาท เช่นในสภาพปกติแรงดันไฟฟ้าของเซลล์ประสาทของเยื่อหุ้มสมองของสัตว์เลี้ยงลูกด้วยนมจะอยู่ที่ประมาณ -65 mV เมื่อมีการรับสัญญาณเข้ามาทำให้เกิดระดับแรงดันไฟฟ้าที่กระตุ้นมีค่าเป็นบวก ซึ่งเมื่อแรงดันไฟฟ้าเพิ่มขึ้นถึงค่าขีดเริ่มที่ -55 mV ส่งผลทำให้เกิดระดับการทำงานที่เรียกว่า **Action Potential** ซึ่งเป็นการเคลื่อนตัวจาก **Axon** ไหลไปยังเซลล์ประสาท **Postsynaptic** โดยกระบวนการของ **Action Potential** จะเป็นไปตามขั้นตอนของ **Hyperpolarization** ซึ่งทำให้เซลล์ประสาทจะกลับไปทีค่าลบอีกครั้ง คือระดับแรงดันไฟฟ้า -65 mV (วัฏจักรพื้นฐานที่ถูกค้นพบเป็นครั้งแรกโดย **Hodgkin** และ **Huxley** ในปี 1952) เป็นสาเหตุให้เกิดการไหลเข้าและออกของไอออน โดยไอออนจะไหลผ่านเยื่อหุ้มเซลล์ และสามารถอยู่ได้ระหว่าง 3 ถึง 50 วินาที ทั้งนี้จะขึ้นอยู่กับชนิดของการไหลของไอออน สุดท้ายผลลัพธ์ที่ออกมาจากกระบวนการดังกล่าวคือสัญญาณพัลส์หรือบางทีก็เรียกว่าชีพจร (**Spike**)




รูปที่ 2.22 สัญญาณทางไฟฟ้าของระบบประสาท

โดยที่เซลล์ประสาทส่วนใหญ่สามารถแผ่คลื่นถึง 250 - 300 พัลส์ต่อวินาที และแม้กระทั่งในกรณีที่ไม่มี อินพุตเข้ามา สัญญาณจะอยู่ในสถานะกิจกรรมพักผ่อนจะมีคลื่นประมาณ 10 พัลส์ต่อวินาทีสมองจึงแสดง กิจกรรมที่เกิดขึ้นเองแม้กระทั่งในกรณีที่ไม่มีตัวกระตุ้น ชนิดของเซลล์ประสาทสามารถแบ่งออกเป็น 3 ชนิด ดังรูปที่ 2.23 ซึ่งมีรายละเอียดดังนี้

- **Sensory neurons** คือเซลล์ประสาทรับสัมผัสเป็นเสมือนอุปกรณ์ต่อพ่วงที่มีตรวจจับการ ป้อนข้อมูลเมื่อสัมผัสกับสภาพแวดล้อมภายนอก การเชื่อมต่อผลลัพธ์ที่สามารถแยกออกจากกันจะทำให้ การติดต่อกับเซลล์ประสาทอื่น ๆ

- **Interneurons** เป็นเซลล์ประสาทที่สร้างการเชื่อมต่อกับเซลล์ประสาทอื่นๆ แต่ไม่ได้เชื่อมต่อ โดยตรงกับสภาพแวดล้อม

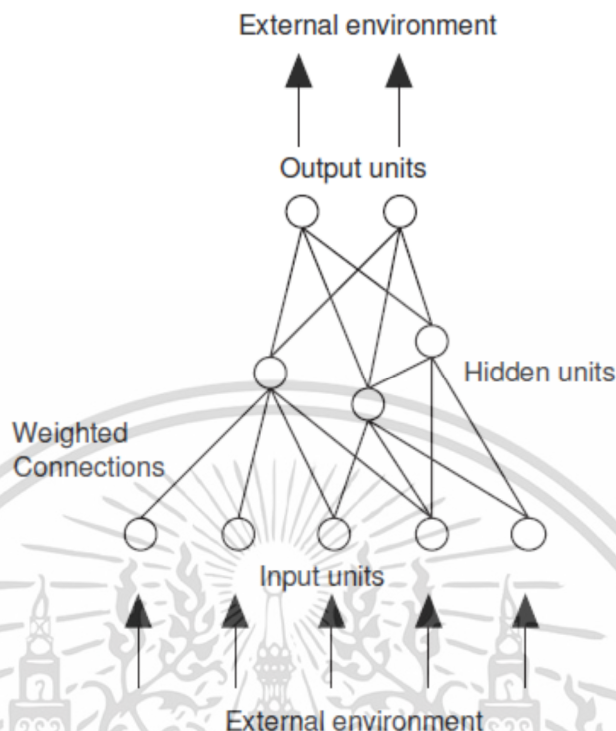
- **Motor neurons** เป็นเซลล์ประสาทที่ทำหน้าที่รับการป้อนข้อมูลจากเซลล์ประสาทหรือจาก เซลล์ประสาทอื่น ๆ ในระบบ ช่วยให้ควบคุมสัญญาณมาบรรจบกันจากแหล่งต่าง ๆ ก่อนที่จะถูกส่งไปส่วน อื่น ๆ



รูปที่ 2.23 แบบจำลองของ Sensory neurons, Motor neurons และ Interneurons

2.4.2.2 โครงข่ายประสาทเทียม (Artificial Neural Network)

โครงข่ายประสาทเทียมเป็นการจำลองของการคำนวณที่ดำเนินการโดยซอฟต์แวร์ หรือ สร้าง อุปกรณ์ฮาร์ดแวร์เพื่อพยายามที่เลียนแบบพฤติกรรม และคุณลักษณะการปรับตัวของระบบประสาททาง ชีวภาพ โครงข่ายประสาทเทียมประกอบด้วยหน่วย (units) ที่เชื่อมต่อกันหลายๆ หน่วยหรือเซลล์ ประสาทหลายเซลล์ (neurons) ดังรูปที่ 2.24 ซึ่งบางส่วนของหน่วยเหล่านี้ได้รับข้อมูลโดยตรงจาก สภาพแวดล้อม หรือบางหน่วยก็รับข้อมูลจากผลกระทบจากปฏิกิริยาของสภาพแวดล้อม (input units) บางหน่วยก็ได้รับผลกระทบโดยตรงจากสิ่งแวดล้อม (output units) และการติดต่อกันจะอยู่ใน โครงข่าย (internal, hidden, units)



รูปที่ 2.24 แผงผังโครงข่ายประสาท

วัตถุประสงค์ของการสร้างโครงข่ายประสาทเทียมคือ การทำเครื่องจักรให้มีความสามารถในการเรียนรู้การจดจำรูปแบบ (Pattern Recognition) และการสร้างความรู้ใหม่ (Knowledge Extraction) เช่นเดียวกับความสามารถที่มีในสมองมนุษย์ แนวคิดเริ่มต้นของเทคนิคนี้ได้มาจากการศึกษาโครงข่ายไฟฟ้าชีวภาพ (Bioelectric Network) ในสมองซึ่งประกอบด้วย เซลล์ประสาท (Neurons) และจุดประสานประสาท (Synapses) เป็นเสมือนชั้นขาเข้า (Input Layer) ในแต่ละเซลล์ประสาทประกอบด้วยปลายในการรับกระแสประสาท เรียกว่า Dendrite เป็นเสมือนฟังก์ชันที่ใช้ในการคำนวณเพื่อตัดสินใจ และปลายในการส่งกระแสประสาทเรียกว่า Axon ซึ่งเป็นเหมือนส่วนชั้นขาออก (Output) ของเซลล์ ดังที่ได้กล่าวไว้แล้วในข้างต้น เซลล์เหล่านี้ทำงานด้วยปฏิกิริยาไฟฟ้าเคมี เมื่อมีการกระตุ้นด้วยสิ่งเร้าภายนอกหรือกระตุ้นด้วยเซลล์ด้วยกัน กระแสประสาทจะวิ่งผ่าน Dendrite เข้าสู่นิวเคลียสซึ่งจะเป็นตัวตัดสินใจว่าต้องกระตุ้นเซลล์อื่น ๆ ต่อหรือไม่ ถ้ากระแสประสาทแรงพอ นิวเคลียสก็จะกระตุ้นเซลล์อื่น ๆ ต่อไปผ่านทาง Axon ของมัน

เมื่อหน่วยของเซลล์ประสาทเทียมได้รับการกระตุ้นจากสิ่งแวดล้อม โครงข่ายประสาทเทียมเรียนรู้ โดยการปรับเปลี่ยนของค่าความแรงของ Synapses ซึ่งปกติแล้วการเรียนรู้ต้องผ่านการนำเสนอผลการทดลองการทำซ้ำหลายชุดของรูปแบบการป้อนข้อมูล การเรียนรู้จะมีฟังก์ชันหลายประเภทซึ่งแต่ละฟังก์ชันการทำงานจะเฉพาะเจาะจง และจะใช้กับสถาปัตยกรรมเฉพาะ โดยปกติทุกการเชื่อมต่อภายใน Synapses จะปรับเปลี่ยนไปตามกฎการเรียนรู้เดียวกัน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.4.2.3 โครงข่ายประสาทเทียมอย่างง่าย (Single layer perceptron)

การจำลองโครงข่ายประสาทเทียมด้วยคอมพิวเตอร์ เซลล์ประสาทเทียม (Neurons) จะประกอบด้วยชั้นขาเข้า (Input) และ ชั้นขาออก (output) โดยจำลองให้ชั้นขาเข้าแต่ละอันมีน้ำหนักเป็นตัวกำหนดขนาดของชั้นขาเข้า มีเซลล์แต่ละหน่วยจะมีค่าขีดเริ่มเป็นตัวกำหนดว่าน้ำหนักรวมของชั้นขาเข้า ต้องมากขนาดไหนจึงจะสามารถส่งชั้นขาออกไปยังเซลล์ตัวอื่นได้ เมื่อนำเซลล์แต่ละหน่วยมาต่อกันให้ทำงานร่วมกัน การทำงานนี้ในทางตรรกะแล้วก็จะเหมือนกับปฏิกิริยาเคมีที่เกิดขึ้นในสมอง เพียงแต่ในคอมพิวเตอร์ทุกอย่างแต่เป็นตัวเลขเท่านั้นดังรูปที่ 2.25



รูปที่ 2.25 แผนผังของเซลล์ประสาทชีวภาพและเซลล์ประสาทเทียม

เซลล์ประสาทเทียมถูกกำหนดโดยคุณลักษณะของชุดของเซลล์ประสาทเทียม (Neuron) โดยที่แต่ละเซลล์ที่มีขนาดมากพอที่จะส่งสัญญาณไปยังชั้นขาออก ผ่านค่าขีดเริ่มที่กำหนดด้วยฟังก์ชันการถ่ายโอน ถ้าเราไม่สนใจความล่าช้าของการส่งข้อมูล ผลลัพธ์ของสัญญาณที่ออกมาจากเซลล์ประสาทเทียมของสัญญาณขาเข้า \vec{x} บนเซลล์ประสาท Postsynaptic เท่ากับผลการคูณของ $\vec{w} \cdot \vec{x}$ โดยกำหนดให้ \vec{w} คือน้ำหนัก Synapses และสามารถเป็นค่าใดๆ ไม่ว่าจะจะเป็นค่าลบหรือค่าบวก โดยผลลัพธ์สามารถหาได้ตามสมการ 2.33

$$a_i = \sum_{j=1}^N w_{ij} x_j \quad (2.33)$$

โดยในแต่ละเซลล์ประสาทเทียมจะประกอบด้วยผลจากคูณข้างต้นแล้วผ่านฟังก์ชันการถ่ายโอนตามสมการ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$y_i = \Phi(a_i) = \Phi\left(\sum_{j=1}^N w_{ij}x_j - \theta_i\right) \quad (2.34)$$

ฟังก์ชันการถ่ายโอน $\Phi(\bullet)$ จะอธิบายรายละเอียดการตอบสนองของเซลล์ประสาทและสามารถใช้รูปแบบที่แตกต่างกันหลายรูปแบบ โดยในรูปแบบดั้งเดิมที่จัดทำโดย McCulloch และ Pitts ขึ้นในปี 1943 เซลล์ประสาทเทียมแต่ละตัวมีผลลัพธ์แบบไบนารี (0 หรือ 1) ดังสมการ (2.35) ทำให้ค่าขีดเริ่มที่ใช้เป็นตัวกำหนดเขตยากที่จะบอกว่าเซลล์ประสาทส่งสัญญาณหรือไม่

$$\Phi(a_i) = \begin{cases} 1: \sum_{j=1}^N w_{ij}x_j > \theta_i \\ 0: \text{Otherwise} \end{cases} \quad (2.35)$$

และรูปแบบของฟังก์ชันการถ่ายโอนแบบสองขั้ว (bipolar activation)

$$\Phi(a_i) = \begin{cases} 1: \sum_{j=1}^N w_{ij}x_j > \theta_i \\ -1: \text{Otherwise} \end{cases} \quad (2.36)$$

จากสมการ (2.36) ขั้วต้นเซลล์ประสาทสามารถมีสถานะได้เพียงหนึ่งในสองสถานะเท่านั้น และสามารถส่งค่าสัญญาณเพียงหนึ่งบิตของข้อมูลเท่านั้น ในกรณีสำหรับฟังก์ชันการถ่ายโอนแบบต่อเนื่องก็จะทำให้เซลล์ประสาทสามารถอยู่ได้หลายสถานะ เช่นผลลัพธ์ของฟังก์ชันการถ่ายโอนแบบต่อเนื่องซึ่งจะเป็นจำนวนจริง ในด้านชีวภาพจำนวนที่ต่อเนื่องนี้ บ่งชี้ได้ว่าไม่ว่าจะเป็นอัตราการกระตุ้นของเซลล์ประสาทจะมีค่ามากกว่าช่วงเวลาสั้นหรือเป็นผลรวมของผล excitatory และ Inhibitory ของผลลัพธ์ของจำนวนของเซลล์ประสาททั้งหมดฟังก์ชันแบบต่อเนื่องอย่างง่ายสามารถทำแบบจำลองเชิงเส้นดังสมการ


$$\Phi(a_i) = ka_i \quad (2.37)$$

โดยกำหนดให้ค่า k เป็นค่าคงที่ใดๆ ในสถานการณ์ที่ไม่อาจคาดเดา ค่าผลลัพธ์ของเซลล์ประสาทจะเพิ่มขึ้นไปเรื่อยๆ จึงกำหนดขอบเขตของฟังก์ชันกระตุ้นนี้ให้อยู่ภายในช่วงเช่น $[0, 1]$ หรือ $[-1, 1]$ นอกจากนี้ยังมีฟังก์ชันถ่ายโอนแบบต่อเนื่องและไม่เชิงเส้นที่ใช้กับสถาปัตยกรรมของระบบประสาทที่ซับซ้อน และหนึ่งในฟังก์ชันที่พบมากที่สุดคือฟังก์ชันซิกมอยด์ (Sigmoid) ดังสมการ (2.38)

$$\Phi(a_i) = \frac{1}{1 + e^{-ka_i}} \quad (2.38)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นิยมนำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดยที่กำหนดให้ k เป็นปัจจัยสำหรับการปรับขนาดของความลาดเอียงแสดงในรูปที่ (สำหรับ $K \rightarrow 0$ ฟังก์ชันถ่ายโอนก็จะกลายเป็นฟังก์ชันเชิงเส้น และสำหรับ $K \rightarrow \infty$ ฟังก์ชันถ่ายโอนก็จะกลายเป็นฟังก์ชันสองระดับ) ฟังก์ชันซิกมอยด์ มีแนวโน้มจะเป็นฟังก์ชันแบบแบบต่อเนื่องจาก 0 ถึง 1 โดยมีฟังก์ชันที่คล้ายๆ กันคือ $\tanh(kA)$ ซึ่งเป็นฟังก์ชันแบบต่อเนื่องจาก -1 ถึง 1



รูปที่ 2.26 (ก) ฟังก์ชันเชิงเส้น(linear function) $k = 1$

(ข) ฟังก์ชันระดับ(step function) $g = 0$

(ค) ฟังก์ชันซิกมอยด์(sigmoid function) $k = 1$

กระตุ้นการทำงานของเซลล์ประสาทเทียมจะแปรผันตรงกับความสัมพันธ์กันระหว่างเวกเตอร์น้ำหนัก \vec{w} และเวกเตอร์อินพุต \vec{x} ดังรูปที่ 2.27 โดยที่สามารถอธิบายเงื่อนไขด้วยพีชคณิตเชิงเส้นถึงความคล้ายคลึงกันระหว่างเวกเตอร์ทั้งสองด้วยโคไซน์ของมุม α ระหว่างเวกเตอร์

$$\cos \alpha = \frac{\vec{w} \cdot \vec{x}}{\|\vec{w}\| \|\vec{x}\|}, \quad 0 \leq \alpha \leq \pi \quad (2.39)$$


โดยกำหนดให้ $\|\vec{w}\|$ เป็นความยาวของเวกเตอร์ \vec{w} ดังนั้นเราสามารถแสดงผลลัพธ์ของเซลล์ประสาทเทียมได้ดังนี้

$$y = \vec{w} \cdot \vec{x} = \|\vec{w}\| \|\vec{x}\| \cos \alpha \quad (2.40)$$

กล่าวคือหากว่าความยาวของเวกเตอร์ทั้งสอง (เวกเตอร์น้ำหนัก \vec{w} และเวกเตอร์อินพุต \vec{x}) มีค่าคงที่ ผลลัพธ์ของการเปลี่ยนแปลงเซลล์ประสาทเทียมขึ้นกับมุมโคไซน์ระหว่างทั้งสองเวกเตอร์ ขนาดของมุมโคไซน์คือสัดส่วนผกผันกับระยะทางเชิงมุมระหว่างชั้นขาเข้าและเวกเตอร์น้ำหนักที่อยู่ในด้านเดียวกัน ซึ่งชั้นขาออกจะมีขนาดเล็กที่สุดเมื่อทั้งสองเวกเตอร์ตั้งฉาก ($\cos 90^\circ = 0$) และจะมีขนาดใหญ่ที่สุดเมื่อทั้งสองเวกเตอร์ในแนวเดียวกัน ($\cos 0^\circ = 1$) โดยในระบบโครงข่ายประสาทเทียมที่มีชั้นขาออกหลายเซลล์ระดับของการเปิดใช้งานจะเป็นกำหนดว่า เซลล์ประสาทเทียมเซลล์ไหนมีน้ำหนักใกล้เคียงกับรูปแบบของเวกเตอร์ในชั้นขาเข้า (ซึ่งต้องมีความยาวเวกเตอร์เท่ากัน) ถ้าสมมุติให้ฟังก์ชันการเปิดใช้งานเป็นแบบไบ


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

นารี ดังนั้นในเซลล์ชั้นขาออก สามารถใช้ในการแยกแยะระหว่างสองชั้นของเวกเตอร์ชั้นขาเข้า ซึ่งจะขึ้นอยู่กับระยะทางเชิงมุมว่ามีขนาดเล็กกว่า 90 องศาหรือระยะทางเชิงมุมว่ามีขนาดใหญ่กว่า 90 องศา ระหว่างเวกเตอร์ชั้นขาเข้าเวกเตอร์น้ำหนักในแต่ละเซลล์ดังรูปที่ 2.27



รูปที่ 2.27 (ก-ข) ความสัมพันธ์ระหว่างเวกเตอร์น้ำหนัก และเวกเตอร์ขาเข้าของนิวรอน

จากรูปที่ 2.28 เส้นการแบ่ง (สายหนา) ของพื้นที่ที่ชั้นขาเข้าโดยเซลล์ประสาทเทียมมีสองชั้นขาออก (โดยทั้งสองชุดตั้งค่าขีดเริ่มไว้ที่ 1) มักจะตั้งฉากกับเวกเตอร์น้ำหนักของเซลล์ประสาทเทียมส่วนเส้นบางๆ คือตัวอย่างที่แสดงให้เห็นถึงการกระจายของจุดข้อมูล ซึ่งเซลล์ประสาทเทียมจะเห็นความแตกต่างโดยการตอบสนองที่ต่างกันอย่างขึ้นอยู่กับการจะอยู่เหนือหรือใต้เส้นแบ่งข้อมูล โดยรูป ก มีค่าขีดเริ่มกำหนดให้ 1 และรูป ข มีค่าขีดเริ่มกำหนดให้เป็น 0 เรียกรูปแบบเซลล์นี้ว่า **linearly separable** โดยทั่วไปมักใช้กับเพอร์เซพตรอนชั้นเดียว



รูปที่ 2.28 (ก) การเรียนรู้แบบเพอร์เซพตรอนชั้นเดียว ค่าขีดเริ่มต้นเท่ากับ 1
(ข) การเรียนรู้แบบเพอร์เซพตรอนชั้นเดียว ค่าขีดเริ่มต้นเท่ากับ 0

2.2.2.4 โครงข่ายประสาทเทียมแบบหลายชั้น (Multi-layer Perceptron)

โครงข่ายประสาทเทียมแบบ **Multi-layer Perceptron** เป็นรูปแบบหนึ่งของโครงข่ายประสาทเทียมที่มีโครงสร้างเป็นแบบหลายๆชั้น ดังรูปที่ 2.29 ใช้สำหรับงานที่มีความซับซ้อนได้ผลเป็นอย่างดีโดยมีกระบวนการฝึกฝนเป็นแบบมีผู้สอน (**Supervise**) และโครงข่ายประสาทเทียมมี 2 ชั้นตอนการทำงาน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หลักๆ ดังนี้ การป้อนไปข้างหน้า (Feed Forward) แพร่ย้อนกลับ (BackPropagate) สำหรับการส่งผ่านไปข้างหน้า ข้อมูลจะผ่านเข้าโครงข่ายประสาทเทียมที่ชั้นขาเข้า และจะส่งผ่านจากอีกชั้นหนึ่งไปสู่อีกชั้นหนึ่งจนกระทั่งถึงชั้นขาออก ส่วนการส่งผ่านย้อนกลับค่าน้ำหนักการเชื่อมต่อจะถูกปรับเปลี่ยนให้สอดคล้องกับกฎการแก้ข้อผิดพลาด (Error-Correction) คือผลต่างของผลตอบที่แท้จริง (Actual Response) กับผลตอบเป้าหมาย (Target Response) เกิดเป็นสัญญาณผิดพลาด (Error Signal) ซึ่งสัญญาณผิดพลาดนี้จะถูกส่งย้อนกลับเข้าสู่โครงข่ายประสาทเทียมเรียกว่ากระบวนการแพร่ย้อนกลับ (BackPropagate) ในทิศทางตรงกันข้ามกับการเชื่อมต่อ และค่าน้ำหนักของการเชื่อมต่อจะถูกปรับจนกระทั่งผลตอบที่แท้จริงเข้าใกล้ผลตอบเป้าหมายสัญญาณที่มีโครงข่ายประสาทเทียมแบบหลายชั้นมี 2 ประเภทคือ Function Signal และ Error Signal

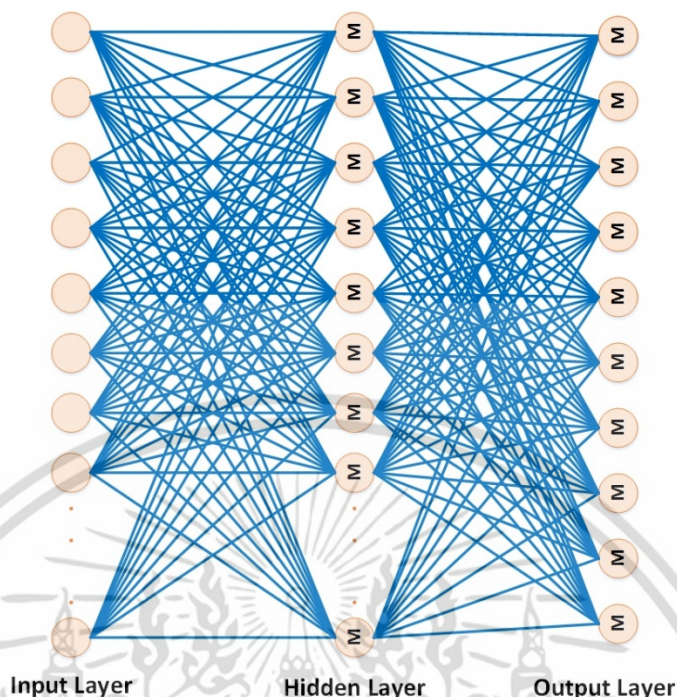
- **Function Signal** เป็นสัญญาณเข้าที่มาจากนิวรอนในชั้นก่อนหน้า และจะส่งผ่านไปข้างหน้าจากนิวรอนหนึ่งไปสู่อีกนิวรอนหนึ่ง

- **Error Signal** เป็นสัญญาณย้อนกลับที่เกิดขึ้นที่นิวรอนในชั้นข้อมูลออกของโครงข่ายประสาทเทียม และถูกส่งผ่านย้อนกลับจากชั้นหนึ่งไปสู่อีกชั้นหนึ่ง

หลักการดำเนินงานของโครงข่ายประสาทเทียมแบบหลายชั้นคือ ในแต่ละชั้นของชั้นซ่อนตัว (Hidden Layer) จะมีฟังก์ชันสำหรับคำนวณเมื่อได้รับสัญญาณ (Output) จากนิวรอนในชั้นก่อนหน้านี้นี้เรียกว่า **Activation Function** โดยในแต่ละชั้นไม่จำเป็นต้องเป็นฟังก์ชันเดียวกันก็ได้ ชั้นซ่อนตัวนั้นมีหน้าที่สำคัญคือ จะพยายามแปลงข้อมูลที่เข้ามาในชั้น (Layer) นั้นๆ ให้สามารถแยกแยะความแตกต่างโดยใช้เส้นตรงเส้นเดียว (Linearly Separable) และก่อนที่ข้อมูลจะถูกส่งไปถึงชั้นข้อมูลออก (Output Layer) ในบางครั้งอาจจำเป็นต้องใช้ชั้นซ่อนตัวมากกว่า 1 ชั้นในการแปลงข้อมูลให้อยู่ในรูป Linearly Separable

ในการคำนวณหาผลลัพธ์ของปัญหาการจำแนกทำได้โดยการใส่ข้อมูลชั้นขาเข้า ไปในโครงข่ายประสาทเทียมที่เราได้ทำการหาไว้แล้ว จากนั้นให้ทำการเปรียบเทียบค่าของผลลัพธ์ในชั้นขาออก และให้ทำการเลือกค่าของผลลัพธ์ที่มีค่าสูงกว่า (เซลล์ประสาทเทียมที่มีค่าสูงกว่า) และทำการรับค่าของพยากรณ์ที่ตรงกับเซลล์ที่เลือก และให้นำค่าของผลลัพธ์มาเปรียบเทียบกับค่าที่ยอมรับได้ หากค่าของอยู่ในช่วงที่รับได้ (Error น้อยกว่า Error ที่เรากำหนด) ก็ให้ทำการรับข้อมูลชุดถัดไป แต่หากค่าของผลลัพธ์มากกว่าค่าที่ยอมรับได้ ให้ทำการปรับค่าน้ำหนักตามขั้นตอนที่ได้กล่าวไว้ข้างต้น เมื่อทำการปรับน้ำหนักเรียบร้อยแล้ว ให้ทำการรับข้อมูลชุดถัดไปและทำตามขั้นตอนซ้ำอีกรอบจนกระทั่งถึงข้อมูลชุดสุดท้าย และเมื่อทำข้อมูลชุดสุดท้ายเสร็จจะนับเป็น 1 รอบของการคำนวณ (1 Epoch) จากนั้นจะทำการหาค่าผิดพลาดรวมเฉลี่ยจากค่าเฉลี่ยของ ที่ได้เก็บค่าเอาไว้ เพื่อใช้ในการตรวจสอบว่าค่า โดยเฉลี่ยในการจำแนกนั้น มีค่าน้อยกว่าค่าผิดพลาดที่ยอมรับได้หรือไม่ ถ้าใช่แสดงว่าโครงข่ายประสาทเทียมที่สร้างขึ้นนั้นสามารถให้ผลลัพธ์ที่ต้องการของทุกข้อมูลแล้ว จึงทำการจบการเรียนรู้ได้ แต่ถ้าไม่ใช่ ให้กลับไปทำตามขั้นตอนแรก โดยเริ่มรับข้อมูลชุดที่ 1 ใหม่

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้คัดลอกเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


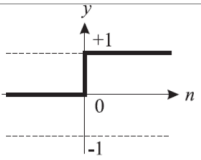

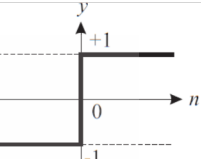

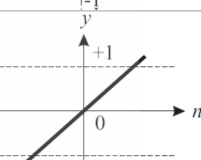

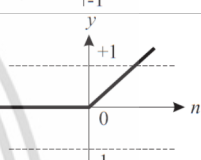

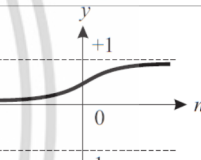

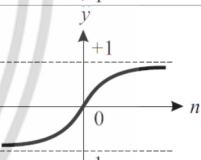

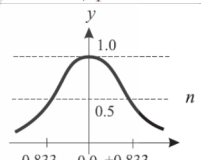


รูป 2.29 โครงข่ายประสาทเทียมแบบหลายชั้น

2.2.2.5 ฟังก์ชันถ่ายโอน (Activation Function or Transfer Function)

ฟังก์ชันการถ่ายโอนเป็นส่วนที่ทำหน้าที่รวมค่าเชิงตัวเลขจากเอาต์พุตของนิวรอน แล้วทำการตัดสินใจว่าให้เอาต์พุตออกไปในรูปแบบใด ฟังก์ชันถ่ายโอนสามารถเป็นได้ทั้งแบบเชิงเส้น หรือไม่เชิงเส้น การเลือกใช้ฟังก์ชันถ่ายโอนจะขึ้นอยู่กับลักษณะของระบบที่นำเอาเครือข่ายประสาทเทียมไปประยุกต์ใช้ ฟังก์ชันถ่ายโอนมีหลายแบบ เช่นฟังก์ชันถ่ายโอนแบบขั้นบันได (Hard-limit) ฟังก์ชันถ่ายโอนแบบบันไดสมมาตร (Symmetrical Hard-limit) ฟังก์ชันถ่ายโอนแบบเชิงเส้น (Linear) ฟังก์ชันถ่ายโอนแบบลอจิสติกมอยด์ (Logarithmic sigmoid) ฟังก์ชันการถ่ายโอนแบบไฮเพอร์บอริกแทนเจนต์ซิกมอยด์ หรือแทนซิกมอยด์ (Hyperbolic tangent sigmoid) และอื่นๆ ซึ่งฟังก์ชันถ่ายโอนแต่ละชนิดมีรายละเอียดดังตารางที่ 2.5

ตารางที่ 2.5 ฟังก์ชันถ่ายโอนแบบต่างๆ

ชื่อฟังก์ชันถ่ายโอน	สมการความสัมพันธ์	สัญลักษณ์	กราฟความสัมพันธ์
Hard limit	$y = 0$ ถ้า $n < 0$ $y = 1$ ถ้า $n \geq 0$		
Symmetrical hard limit	$y = -1$ ถ้า $n < 0$ $y = +1$ ถ้า $n \geq 0$		
Linear	$y = n$		
Positive linear	$y = 0$ ถ้า $n < 0$ $y = n$ ถ้า $n \geq 0$		
Log-sigmoid	$y = \frac{1}{1+e^{-n}}$		
Hyperbolic tangent sigmoid	$y = \frac{e^n - e^{-n}}{e^n + e^{-n}}$		
Radial basis function	$y = e^{-n^2}$		

2.2.2.6 กฎการเรียนรู้ (Learning Rule)

การเรียนรู้ของเครือข่ายประสาทเทียมเปรียบได้กับการเรียนรู้ในระบบประสาทของมนุษย์ การเรียนรู้คือวิถีทางที่สิ่งมีชีวิตจะสามารถได้รับข้อมูลความรู้จากสภาวะแวดล้อม ซึ่งมีผลต่อพฤติกรรมของสิ่งมีชีวิตนั้นๆ การเรียนรู้ทำให้สิ่งมีชีวิตสามารถเก็บและเรียกคืนข้อมูลความรู้ได้ ซึ่งสิ่งนี้รวมแล้วเรียกว่าเป็นความทรงจำ (memory) ในระบบประสาทของมนุษย์ การเรียนรู้เป็นการปรับในส่วนจุดประสานประสาท (synapse) ในลักษณะเดียวกันกับการเรียนรู้ของเครือข่ายประสาทเทียม ที่ซึ่งเป็นกรรมวิธีในการปรับค่าน้ำหนักประสาท (weight) ของเครือข่าย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ในการออกแบบสร้างเครือข่ายประสาทเทียม หลังจากได้ทำการเลือกโครงสร้างของเครือข่าย เช่น จำนวนอินพุต จำนวนเอาต์พุต จำนวนชั้นของเครือข่าย จำนวนนิวรอนในแต่ละชั้น ชนิดของฟังก์ชันการถ่ายโอน ฯลฯ ขั้นตอนต่อไปก็คือการหาพารามิเตอร์ของเครือข่าย อันได้แก่ค่าน้ำหนักประสาท (weight) และไบอัส (bias) ขั้นตอนการปรับค่าพารามิเตอร์เหล่านี้เรียกว่ากฎการเรียนรู้ของเครือข่าย (learning rule หรือ training algorithm) จุดประสงค์ของการเรียนรู้ก็เพื่อฝึกสอนให้เครือข่ายทำงานตามที่ต้องการได้ โดยทั่วไปแล้วกฎการเรียนรู้แบ่งเป็นกลุ่มใหญ่ๆ ได้ 2 กลุ่ม คือ การเรียนรู้แบบไม่มีผู้สอน (unsupervised) การเรียนรู้แบบมีผู้สอน (supervised)

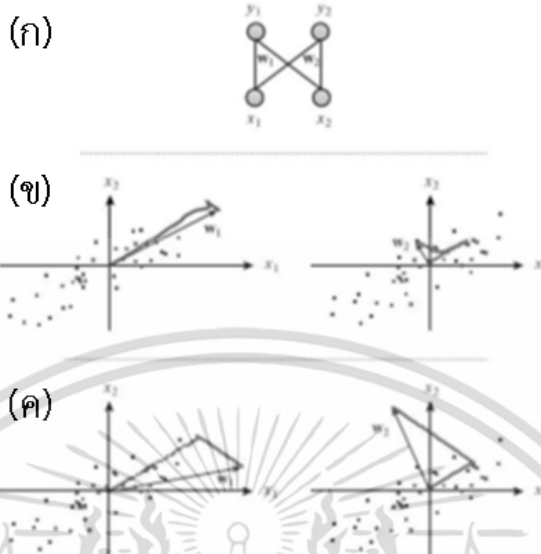
2.2.2.6.1 การเรียนรู้แบบไม่มีผู้สอน (unsupervised learning)

เป็นการเรียนรู้ที่ต้องการเฉพาะข้อมูลอินพุตป้อนเข้าสู่โครงข่าย โดยไม่มีเป้าหมาย (Target) ทางด้านเอาต์พุตและภายในโครงข่ายจะมีจุดร่วมเอาต์พุตอยู่หลายจุดร่วมด้วยกัน โดยแต่ละจุดร่วมจะแทนกลุ่มของข้อมูลที่มีคุณสมบัติเหมือนกัน และเมื่อป้อนอินพุตเข้าสู่โครงข่าย โครงข่ายก็จะทำการคำนวณค่าความสัมพันธ์ที่มีอยู่ภายในเซตของอินพุต โดยอาศัยค่าถ่วงน้ำหนักเป็นตัวแยกความแตกต่างของอินพุตไปเก็บไว้ในจุดร่วมเอาต์พุตของโครงข่าย ซึ่งส่วนใหญ่จะนำมาใช้กับการจำแนกกลุ่ม ข้อดีของการฝึกสอนแบบนี้คือ มีความใกล้เคียงกับโครงข่ายประสาทชีวภาพ แต่ไม่สามารถแก้ปัญหาที่ซับซ้อนมากๆ ได้

- **การสกัดของข้อมูล (Feature Detection)** เช่นการตรวจสอบคุณสมบัติทั่วไปหรือคุณสมบัติที่โดดเด่นที่ช่วยให้โครงข่ายจำแนกรูปแบบของชั้นขาเข้า ซึ่งจากแบบจำลองทางคณิตศาสตร์ของการเรียนรู้แบบไม่มีผู้สอนจะใช้หลักสถิติ เช่นการคำนวณของความสัมพันธ์ ดัชนีประมาณค่าพารามิเตอร์ของฟังก์ชันความหนาแน่นของความน่าจะเป็น จากรูปแบบของการป้อนข้อมูลและการวิเคราะห์องค์ประกอบหลัก เพื่อที่จะทำให้การดำเนินการเหล่านั้นแจ่มแจ้งรูปแบบของชั้นขาเข้าให้มีประสิทธิภาพ ชั้นขาเข้าจะต้องมีความซ้ำซ้อนของข้อมูลเพื่อให้ในการตรวจสอบของโครงสร้างให้ดีขึ้น การแยกองค์ประกอบหลักเป็นความสำคัญลำดับแรกของการพิจารณาการกระจายตั้งสมการ (2.41)

$$\Delta w_{ij} = \eta y_i \left(x_j - \sum_{k=1}^N w_{kj} y_k \right), \quad (2.41)$$

โดยกำหนดให้ i และ k คือดัชนีที่ชี้ไปยังส่วนเอาต์พุตทั้งสอง ส่วนพจน์ $\sum_{k=1}^N w_{kj} y_k$ นี้จะพิจารณาถึงน้ำหนักทั้งหมดของโครงข่าย ซึ่งจากรูปที่ 2.30 การสกัดคุณลักษณะเด่นขององค์ประกอบหลักของการกระจายรูปแบบของชั้นขาเข้าด้วยสองชั้นขาออก โดยที่ภาพ (ก) แสดงถึงโครงข่ายประสาท ส่วนภาพ (ข) และ (ค) แสดงถึงการปรับเปลี่ยนของน้ำหนักเวกเตอร์ของโครงข่ายประสาทเทียม โดยที่ภาพ (ข) จะแสดงถึงอินพุตที่ได้ผ่านการฝึกสอนด้วยกฎ Oja สำหรับ N เอาต์พุต ส่วน (ค) แสดงถึงแสดงถึงการปรับเปลี่ยนของน้ำหนักเวกเตอร์ของอินพุตที่ได้ผ่านการฝึกสอนด้วยกฎ Sanger สำหรับ N เอาต์พุต



รูปที่ 2.30 (ก) โครงข่ายประสาทเทียม

(ข) โครงข่ายประสาทเทียมที่ใช้การเรียนรู้แบบ Oja

(ค) โครงข่ายประสาทเทียมที่ใช้การเรียนรู้แบบ Sanger

- การสกัดของข้อมูลแบบหลายชั้น (**multilateral Feature Detection**) สถาปัตยกรรมประยุกต์ของรูปแบบหลายชั้นโดย **Linsker** แต่ละชั้นจะถูกจัดเป็นเมทริกซ์ 2D ของเซลล์ประสาทเทียมที่มีการเชื่อมต่อด้วยความน่าจะเป็นของ **Neurons** ชั้นก่อนหน้าจะอธิบายโดยการกระจายของแบบ **Gaussian 2D** สมการ (2.42)

$$y_i = k_i \sum_j w_{ij} x_j, \quad (2.42)$$

และใช้สมการของกระบวนการเรียนรู้ดังสมการ (2.43)

$$\Delta w_{ij} = k_2 y_i x_j + k_3 x_j + k_4 y_j + k_5, \quad (2.43)$$

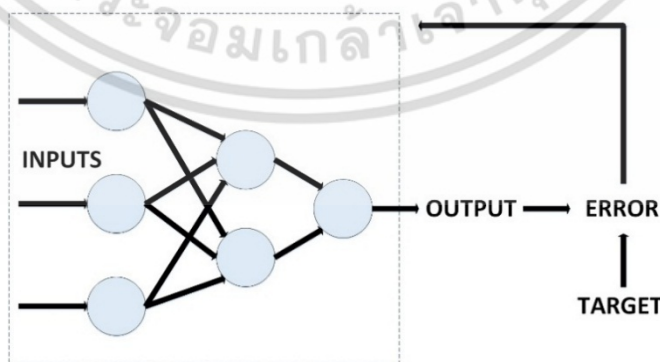
โดยกำหนดให้ k_{1-5} คือค่าคงที่และ $k_2 > 0$ น้ำหนักจะถูกตัดไปให้อยู่ในช่วง $[w_{ij}^+, w_{ij}^-]$ เพื่อหลีกเลี่ยงการปรับน้ำหนักแบบไม่มีที่สิ้นสุด

2.4.2.6.2 การเรียนรู้แบบมีผู้สอน (supervised)

การเรียนรู้โดยวิธีนี้จะกำหนดเซตของการสอนให้กับโครงข่าย ซึ่งภายในเซตประกอบด้วยข้อมูลอินพุตและเอาต์พุตที่ต้องการ เรียกว่า คู่ของการฝึกสอน (Training pairs) เมื่อทำการป้อนอินพุตให้กับโครงข่าย โครงข่ายก็จะทำการประมวลผลจนได้คำตอบ ซึ่งคำตอบที่ได้จากโครงข่ายนี้จะถูกนำมาคำนวณค่าความผิดพลาด (Error) คือ ค่าความแตกต่างระหว่างคำตอบที่ได้จากโครงข่ายกับคำตอบเป้าหมายของอินพุตชุดเดียวกัน ว่ามีค่าน้อยเท่าไร ถ้ายังมีค่าความผิดพลาดสูงกว่าที่กำหนด ก็จะทำให้การฝึกสอนรอบใหม่ให้กับโครงข่าย เพื่อทำการปรับค่าถ่วงน้ำหนัก และทำการฝึกสอนต่อไปจนกระทั่งค่าความผิดพลาดระหว่างคำตอบที่ได้จากโครงข่ายกับคำตอบเป้าหมายของอินพุตชุดเดียวกันก็มีค่าน้อยพอที่จะยอมรับได้ จึงหยุดทำการฝึกสอนโครงข่ายดังรูปที่ 2.31 อธิบายได้ดังสมการ 2.44 กำหนดให้ b_{ko} และ z_{ko} เป็นค่ากำหนดและค่าที่ได้จริงของเซลล์ประสาทเทียมในชั้นขาออกตามลำดับ สำหรับการตรวจสอบค่าที่สอนนั้นจะตรวจสอบค่าตามสมการ 2.44 โดยกำหนดให้ k คือลำดับของกิจกรรมในชั้นขาออก $b_{ko} = 1$ ที่ค่า $k = 0$ และนอกเหนือจากนี้ให้ $b_{ko} = 0$ ค่าผิดพลาดของชั้นตอนป้อนไปข้างหน้า (Feed Forward) ของรูปแบบที่ k^{th} ได้ตามสมการ (2.44)

$$E_k = 0.5 \sum_{o=1}^q (b_{ko} - z_{ko})^2, \quad (2.44)$$

กำหนดให้ k เป็นค่าที่อยู่ในช่วง $\{1, 2, \dots, q\}$ ในขั้นตอนการเรียนรู้ ลำดับแรกน้ำหนักทุกตัวจะถูกสุ่มเพื่อหาค่าเริ่มต้น z_{ko} จะถูกคำนวณจากชั้นตอนของกระบวนการป้อนไปข้างหน้า (Feed Forward) และค่าผิดพลาดของแต่ละรูปแบบก็จะคำนวณจากสมการที่ 2.44 ลำดับต่อมา ทุกตัวของน้ำหนักจะถูกปรับจนกว่าค่าของค่าผิดพลาดจะเข้าสู่ศูนย์หรือเข้าค่าที่กำหนดโดยใช้กระบวนการแพร่ย้อนกลับ (BackPropagate)




รูปที่ 2.31 ขั้นตอนการเรียนรู้แบบมีผู้สอน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.4.2.7 Back Propagation Neural Network, BPNN

พื้นฐานโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (Back Propagation Neural Network, BPNN) เป็นระบบคณิตศาสตร์ที่ใช้ต้นแบบจากโครงข่ายประสาทของสิ่งมีชีวิตโดยมีการเชื่อมกันระหว่างเซลล์ประสาทเทียม (Neuron) โครงสร้างของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN) ที่ใช้ในวิทยานิพนธ์เล่มนี้ประกอบด้วยสามชั้นดังนี้ ชั้นขาเข้า (Input Layer) ชั้นซ่อน (Hidden Layer) และชั้นขาออก (Output Layer) ดังแสดงในรูปที่ 2.32 และทุกชั้นจะประกอบด้วยเซลล์ประสาทเทียมหลายตัว โดยกำหนดให้ I , H และ O เป็นจำนวนเซลล์ของชั้นขาเข้า ชั้นซ่อน และชั้นขาออก ตามลำดับ



ในที่นี้ I เป็นจำนวนข้อมูลของสัญญาณการเคลื่อนไหว และ O เป็นจำนวนรูปแบบของสัญญาณที่ต้องจดจำ ประสิทธิภาพของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับนี้จะขึ้นอยู่กับ การเลือกจำนวนเซลล์ประสาทเทียมของชั้นซ่อน (H) ถ้า I มีจำนวนน้อยจะทำให้เกิดปัญหาที่เรียกว่า **Under Fitting** ซึ่งเป็นปัญหาที่เกิดขึ้นเมื่อจำนวนเซลล์ในชั้นซ่อนมีค่าน้อยและไม่พอเพียงที่จะตรวจจับรูปแบบสัญญาณที่มีความซับซ้อนของสัญญาณขาเข้าได้ ในทางตรงข้ามหากจำนวน H มีค่ามากก็อาจนำไปสู่ปัญหาใหญ่สองประการคือ โครงข่ายประสาทเทียมจะใช้เวลาในการเรียนรู้จดจำรูปแบบของสัญญาณนานมาก ประการต่อมาจะเกิดปัญหาที่เรียกว่า **Over Fitting** ซึ่งปัญหานี้จะเกิดขึ้นเมื่อโครงข่ายประสาทเทียมใช้หน่วยความจำมากเพื่อการประมวลผลสัญญาณ แต่ไม่มีสัญญาณเพียงพอที่จะสอนเซลล์ทุกตัวในชั้นซ่อนได้

ในแต่ละเซลล์ประสาทเทียมของแต่ละชั้น ในโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN) จะถูกเชื่อมซึ่งกันและกัน แต่ละเส้นเชื่อมมีน้ำหนักเป็นตัวกำหนดขนาด โดยน้ำหนักในแต่ละเส้นเชื่อมต่อ

จะถูกเก็บในหน่วยความจำของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN) โดยโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN) มี 2 ขั้นตอนการทำงานหลักๆ ดังนี้ การป้อนไปข้างหน้า (Feed Forward) แพร่ย้อนกลับ (BackPropagate)

ในขั้นตอนของการป้อนไปข้างหน้า (Feed Forward) คุณลักษณะของ n จะถูกป้อนเข้าไปในชั้นของชั้นขาเข้า จากนั้นผลลัพธ์ของชั้นซ่อนและชั้นของขาออกสามารถคำนวณได้ดังสมการ (2.45) และ (2.46)

$$y_h = f_{sig} \left(\sum_{i=1}^n x_i v_{ih} \right), \quad (2.45)$$

$$z_o = f_{sig} \left(\sum_{h=1}^p y_h w_{ho} \right) \quad (2.46)$$

ตามลำดับ กำหนดให้ $f_{sig}(x) = (1 + e^{-x})^{-1}$ โดย x_i คือค่าของสัญญาณในชั้นขาเข้าในลำดับที่ i^{th} ส่วน v_{ih} คือน้ำหนักของเส้นเชื่อมต่อระหว่างชั้นเซลล์ของชั้นขาเข้าลำดับที่ i^{th} และ ชั้นเซลล์ของชั้นซ่อนลำดับที่ h^{th} ส่วน y_h คือค่าของเซลล์ในชั้นซ่อนลำดับที่ h^{th} และส่วน w_{ho} คือน้ำหนักของเส้นเชื่อมต่อระหว่างชั้นเซลล์ของชั้นซ่อนลำดับที่ h^{th} และชั้นเซลล์ของชั้นขาออก ลำดับที่ o^{th} และสุดท้าย z_o คือค่าเซลล์ของชั้นขาออก

น้ำหนักของเส้นเชื่อมต่อทุกเส้นสามารถปรับโดยอาศัยการแพร่ย้อนกลับจากชั้นขาออกไปยังชั้นขาเข้าเพื่อให้ได้ค่าผิดพลาด (Error) ที่กำหนดไว้ดังสมการ (2.47), (2.48), (2.49) และ (2.50)

$$w_{ho}^{new} = w_{ho}^{old} + \eta \sum \delta_o y_h, \quad (2.47)$$

$$\delta_o = z_o (1 - z_o) (b_o - z_o), \quad (2.48)$$

$$v_{ih}^{new} = v_{ih}^{old} + \eta \sum \delta_h x_i, \quad (2.49)$$

$$\delta_h = y_h (1 - y_h) \sum_{o=1}^q w_{oh} \delta_o \quad (2.50)$$

โดยกำหนดให้ w_{ho}^{new} และ v_{ih}^{new} คือค่าน้ำหนักใหม่ที่ถูกรับปรับในแต่ละรอบของการเรียนรู้ของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับในชั้นซ่อนและชั้นของขาออกตามลำดับ และ w_{ho}^{old} และ v_{ih}^{old} คือค่าน้ำหนักในแต่ละรอบก่อนหน้านั้นในชั้นซ่อนและชั้นของขาออกตามลำดับ δ_o และ δ_h เป็นค่า Gradient ในชั้นซ่อนและชั้นของขาออกตามลำดับและ η เป็นค่าอัตราการเรียนรู้ซึ่งปกติแล้วมีค่าอยู่ระหว่าง 0 ถึง 1

บทที่ 3

ขั้นตอนการวิจัยระบบตรวจจับการหกล้ม


วิทยานิพนธ์ฉบับนี้นำเสนอระบบตรวจจับการหกล้มซึ่งมีขั้นตอนการทำงาน 2 ขั้นตอนดังรูปที่ 3.1 ขั้นตอนแรกคือระบบตรวจวัดสัญญาณความเร่งจากการเคลื่อนไหว (Signal Acquisition) ซึ่งต้องมีลักษณะที่เหมาะสมสำหรับพกพาหรือติดกับตัวผู้ใช้ และสามารถส่งข้อมูลสัญญาณการเคลื่อนไหวได้ ขั้นตอนที่สองคืออัลกอริทึมสำหรับการตรวจจับการหกล้ม ซึ่งจะต้องมีความสามารถในการตรวจจับสัญญาณการหกล้มหรือสัญญาณการเคลื่อนไหวอื่นๆ ไม่ใช่สัญญาณการหกล้ม โดยอัลกอริทึมที่ใช้คือ การดึงคุณลักษณะของสัญญาณโดยการแปลงเวฟเลต (Feature Extraction) และการตัดแยกสัญญาณโดยโครงข่ายประสาทเทียม (Activity Classification)



รูปที่ 3.1 ลำดับขั้นตอนการวิจัยระบบตรวจจับการหกล้ม


3.1 ระบบวัดสัญญาณความเร่งจากการเคลื่อนไหวและการหกล้ม

ระบบวัดสัญญาณความเร่งแสดงดังรูปที่ 3.2 ประกอบไปด้วย 3 ส่วนดังนี้ ส่วนแรกคือเซ็นเซอร์วัดความเร่งแบบสามแกน (ET-MMA7331L) ใช้สำหรับการวัดสัญญาณความเร่งในขณะที่อาสาสมัครเคลื่อนไหว ต่อมาคือไมโครคอนโทรลเลอร์ (PIC32MX460F512L) ใช้สำหรับรับสัญญาณจากเซ็นเซอร์วัดความเร่งแล้วส่งข้อมูลที่รับจากเซ็นเซอร์วัดความเร่งไปเข้าคอมพิวเตอร์เพื่อเก็บสัญญาณโดยใช้บลูทูธเป็นตัวส่งสัญญาณ โดยที่ติระบบตรวจวัดสัญญาณการเคลื่อนไหวไว้ที่เอวด้านขวา ดังรูปที่ 3.3



รูปที่ 3.2 ระบบวัดสัญญาณการเคลื่อนไหว


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.3 รูปตำแหน่งของการติดตั้งระบบตรวจจับการหกล้ม

3.1.1 เซ็นเซอร์วัดความเร่ง

เซ็นเซอร์วัดความเร่งแบบสามแกนมีโครงสร้างดังรูปที่ 3.4 และรายละเอียดของขาสัญญาณแสดงในตารางที่ 3.1 โดยเซ็นเซอร์วัดความเร่ง (ET-MMA7331L) มีขนาดเล็ก เบา ใช้พลังงานต่ำ และสามารถกำหนดความละเอียดของการวัดความเร่งได้ 2 ย่าน $\pm 4g$ และ $\pm 12g$



รูปที่ 3.4 โครงสร้างเซ็นเซอร์วัดความเร่งแบบสามแกน (EL-MMA7331L)

การใช้งานของเซ็นเซอร์วัดความเร่งแบบสามแกนสามารถเลือกโหมดการทำงานได้ 3 โหมด ดังนี้ โหมดพัก (Sleep) โหมดทดสอบ (Self-Test) และโหมดวัดสัญญาณความเร่ง (Measurement) ซึ่งในวิทยานิพนธ์เล่มนี้ได้เลือกใช้โหมดการวัดสัญญาณความเร่ง โดยมีลักษณะการทำงานคือ เซ็นเซอร์จะวัดสัญญาณค่าแรงโน้มถ่วง (g) ในแกน X, Y, และ Z โดยต้องกำหนดขาสัญญาณในส่วน ของ Self-Test และ Sleep เป็น 0 และ 1 ตามลำดับ สำหรับขาสัญญาณ g-Select เป็นขาสัญญาณเลือกย่านวัดความเร่งซึ่งมีรายละเอียดดังตารางที่ 3.2

ตารางที่ 3.1 แสดงรายละเอียดโครงสร้างของเซ็นเซอร์วัดความเร่ง (EL-MMA7331L)

ลำดับขา	ชื่อของขา	รายละเอียด
1	VDD	ขาจ่ายไฟเลี้ยง 2.2V - 3.6V
2	XOUT	ขาสัญญาณแรงดัน Output ในแนวแกน X (Analog)
3	YOUT	ขาสัญญาณแรงดัน Output ในแนวแกน Y (Analog)
4	ZOUT	ขาสัญญาณแรงดัน Output ในแนวแกน Z (Analog)
5	VSS	ขาสัญญาณ Ground
6	SLEEP	ขาสัญญาณ เลือก Sleep Mode ทำงานที่ logic '0'
7	g-Select	ขาสัญญาณ สำหรับเลือกย่านการวัด '0' = Rang 4-g ; '1' = Rang 12-g
8	Self Test	ขาสัญญาณสำหรับเลือก Self Test Mode ทำงานที่ logic '1'

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


ตารางที่ 3.2 แสดงย่านของการวัดความเร่ง (EL-MMA7331L)

g-Select	g-Range	Sensitivity
0	4g	308mV/g
1	12g	83.6mV/g

การทำงานของเซ็นเซอร์วัดความเร่งในหมวดการวัดสัญญาณความเร่ง จะทำงานโดยใช้ทิศทางของเซ็นเซอร์วัดความเร่งเป็นตัวกำหนดขาสัญญาณออก (Output X, Y, และ Z) ดังรูปที่ 3.5 ซึ่งการคำนวณขนาดแรงดันของขาสัญญาณในแกน X, Y, และ Z ได้ดังสมการ (3.1)

$$V_{out(analog)} = V_{offset} + (Sensitivity \times g) \quad (3.1)$$


โดยกำหนดให้ $V_{out(analog)}$ คือขนาดแรงดันที่วัดได้จากขาของเซ็นเซอร์วัดความเร่งแกน X, Y, และ Z ส่วน V_{offset} คือค่าครึ่งหนึ่งของแรงดันไฟเลี้ยงที่จ่ายให้กับตัวเซ็นเซอร์วัดความเร่ง และค่า $Sensitivity$ คือค่าจากตารางย่านของการวัดความเร่ง



รูปที่ 3.5 ตำแหน่งทิศทางของเซ็นเซอร์วัดความเร่งทั้ง 3 แกน

3.1.2 ไมโครคอนโทรลเลอร์

ไมโครคอนโทรลเลอร์ (PIC32MX460F512L) แสดงดังรูป 3.6 ใช้สำหรับประมวลผลสัญญาณความเร่งจากเซ็นเซอร์วัดความเร่ง เช่น อ่านค่าสัญญาณและประมวลผล ข้อดีของการใช้ไมโครคอนโทรลเลอร์รุ่นนี้มีหลายประการดังเช่น ใช้พลังงานต่ำ สามารถแปลงสัญญาณอนาล็อกเป็นสัญญาณดิจิทัล 10 บิตข้อมูล จึงทำให้สามารถประมวลผลสัญญาณความเร่งได้อย่างถูกต้องและมีประสิทธิภาพ




รูปที่ 3.6 ไมโครคอนโทรลเลอร์ยี่ห้อ MICROCHIP รุ่น PIC32MX460F512L

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.1.3 บลูทูธ

บลูทูธ คือ เทคโนโลยีการสื่อสารไร้สายระยะใกล้แบบเครือข่ายไร้สายส่วนบุคคลเป็นมาตรฐานที่ถูกออกแบบมาเพื่อใช้ในการเชื่อมต่ออุปกรณ์ไร้สายขนาดเล็ก ซึ่งในวิทยานิพนธ์เล่มนี้ทางผู้วิจัยได้ใช้ บลูทูธ (BC147) ดังรูปที่ 3.7 เป็นตัวสื่อสาร ระหว่าง ไมโครคอนโทรลเลอร์กับคอมพิวเตอร์



รูปที่ 3.7 บลูทูธ (BC147)

3.1.4 ลักษณะของสัญญาณความเร่งจากการเคลื่อนไหว


ในการเตรียมข้อมูลของสัญญาณการเคลื่อนไหวต่างๆ เริ่มต้นด้วยการกำหนดให้ระบบการตรวจวัดสัญญาณการเคลื่อนไหวมีความถี่ในการวัดสัญญาณที่ 200 เฮิร์ต (Hz) ซึ่งสัญญาณที่วัดด้วยเซ็นเซอร์วัดความเร่งจะอยู่ในรูปแบบของอนาล็อกและจะแปลงเป็นสัญญาณดิจิทัลดังสมการ (3.2) และ (3.3) จากนั้นสัญญาณจะถูกส่งผ่านทางบลูทูธเพื่อไปบันทึกด้วยคอมพิวเตอร์

$$g = \frac{(V_{ADC} \times R_{ADC}) - V_{DD}/2}{Sensitivity}, \quad (3.2)$$

$$R_{ADC} = \frac{V_{DD}}{2^n - 1} \quad (3.3)$$


โดยกำหนดให้ค่า g คือสัญญาณความเร่งในหน่วย m/s^2 , V_{ADC} คือค่าสัญญาณที่บันทึกไว้, V_{DD} ค่าแรงดันที่จ่ายให้กับเซ็นเซอร์วัดความเร่งแบบสามแกน, n คือจำนวนบิต (BIT) ของการแปลงสัญญาณอนาล็อกเป็นสัญญาณดิจิทัล ($n=10$), $Sensitivity$ คือค่าความละเอียดที่กำหนดให้กับเซ็นเซอร์วัดความเร่งแบบสามแกนในการตรวจวัดสัญญาณการเคลื่อนไหวซึ่งในงานวิจัยนี้กำหนดไว้ที่ 308 mV/g

จากการสังเกตของผู้วิจัย พบว่าสัญญาณความเร่งจากการหกล้ม สามารถแบ่งได้ 3 ส่วนดังรูปที่ 3.8 ส่วนแรกคือสัญญาณความเร่งที่ได้มาจากสาเหตุของการหกล้มเช่น ลื่น, สะดุด และอื่นๆ ซึ่งในส่วนนี้จะใช้เวลาประมาณ 1 วินาที ส่วนที่สองคือสัญญาณความเร่งที่เกิดขึ้นเมื่อบางส่วนของร่างกายกระทบกับพื้นเช่น สะโพก มือ เข่า หรือ หัว เนื่องจากผลกระทบทำให้เกิดการเปลี่ยนแปลงอย่างรวดเร็วของร่างกายทำให้เกิดสัญญาณความเร่งที่มีค่าสูงสุด ซึ่งระยะเวลาที่เกิดขึ้นจะเกิดขึ้นประมาณ 100-200 มิลลิวินาที และส่วนสุดท้าย คือ สัญญาณความเร่งของกิจกรรมบางอย่างที่เกิดขึ้นหลังจากที่กระทบที่พื้น เช่น การม้วนตัว หรือ การไหลของร่างกาย ซึ่งในส่วนนี้จะใช้เวลา น้อยกว่า 1 วินาที ดังนั้นผู้วิจัยจึงประมาณสัญญาณความเร่งของการหกล้มไว้ที่ประมาณ 2 วินาที จึงทำให้ผู้วิจัยเก็บบันทึกสัญญาณความเร่งการเคลื่อนไหวประเภทต่างๆ ใช้เวลาประมาณ 2 วินาทีด้วย




รูปที่ 3.8 สัญญาณการหกล้มไปด้านหน้าในระยะเวลา 2 วินาที

ตัวอย่างของสัญญาณการเคลื่อนไหว 10 รูปแบบจะประกอบไปด้วย 1)เดิน 2)กำลังนั่งลงเก้าอี้ 3)กำลังลุกจากเก้าอี้ 4)กำลังล้มตัวลงนอนบนที่นอน 5)กำลังลุกจากที่นอน, 6)กำลังหกล้มไปด้านหน้า 7)กำลังหกล้มไปด้านหลัง 8)กำลังหกล้มไปด้านซ้าย 9)กำลังหกล้มไปด้านขวา และ 10)หกล้มในขณะที่กำลังยืน ของแกน X, Y, และ Z ดังแสดงในรูปที่ 3.9 – 3.18 ตามลำดับ

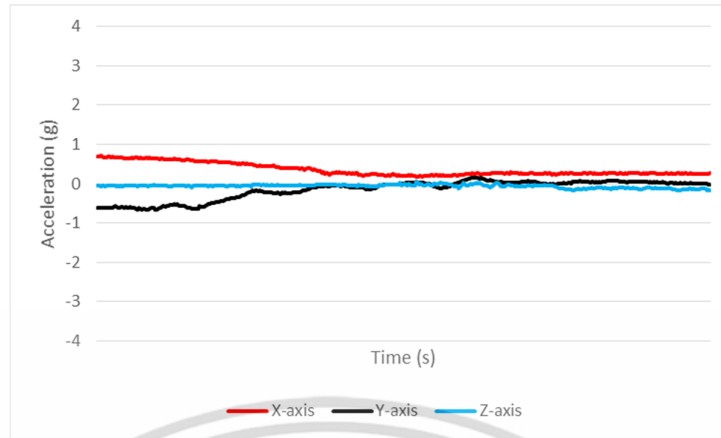


รูปที่ 3.9 แสดงสัญญาณการเคลื่อนไหวประเภทการเดิน




รูปที่ 3.10 แสดงสัญญาณการเคลื่อนไหวประเภทกำลังนั่งลงเก้าอี้


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.11 แสดงสัญญาณการเคลื่อนไหวประเภทกำลังลูกจากเก้าอี้




รูปที่ 3.12 แสดงสัญญาณการเคลื่อนไหวประเภทกำลังล้มตัวลงนอนบนที่นอน



รูปที่ 3.13 แสดงสัญญาณการเคลื่อนไหวประเภทกำลังลูกจากที่นอน


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.14 แสดงสัญญาณการเคลื่อนไหวประเภทหกล้มไปด้านหน้า




รูปที่ 3.15 แสดงสัญญาณการเคลื่อนไหวประเภทหกล้มไปด้านหลัง




รูปที่ 3.16 แสดงสัญญาณการเคลื่อนไหวประเภทหกล้มไปด้านซ้าย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.17 แสดงสัญญาณการเคลื่อนไหวประเภทหกล้มไปด้านขวา



รูปที่ 3.18 แสดงสัญญาณการเคลื่อนไหวประเภทหกล้มในขณะที่กำลังยืน

3.2 อัลกอริทึมที่นำเสนอสำหรับตรวจจับสัญญาณการหกล้ม


วิทยานิพนธ์เล่มนี้นำเสนออัลกอริทึมสำหรับการตรวจจับสัญญาณการหกล้มซึ่งมี 2 ขั้นตอน ดังนี้

1. การดึงคุณลักษณะของสัญญาณความเร่งจากการเคลื่อนไหวโดยใช้การแปลงเวฟเลต (Wavelet Transform)
2. การคัดแยกสัญญาณความเร่งจากการเคลื่อนไหวและการหกล้มของมนุษย์โดยใช้โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (Neural network)

3.2.1 การดึงคุณลักษณะของสัญญาณโดยใช้การแปลงเวฟเลต (Wavelet transform)

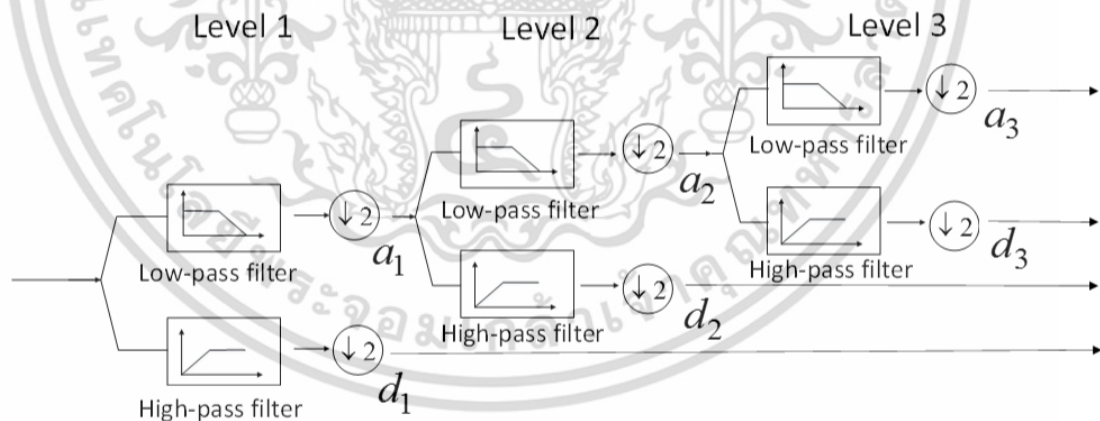
ในวิทยานิพนธ์ฉบับนี้ได้นำเวฟเลตมาประยุกต์ใช้กับสัญญาณความเร่ง ซึ่งสามารถทำการแปลงได้ดังรูป 3.19 โดยจากรูปนั้นสามารถอธิบายได้ว่าการแปลงเวฟเลตของสัญญาณความเร่งจะแปลงเป็นแนวแกนนอน ตามจำนวนตัวอย่าง (Sample) ของสัญญาณความเร่ง ซึ่งทำให้สัญญาณความเร่งแบ่งออกเป็น 2 สับแบนด์ ซึ่งเป็นการแปลงเวฟเลตระดับเดียว (Single level) โดยที่สับแบนด์แรก (Sb1) เป็นส่วนของสัญญาณความเร่งที่ผ่านตัวกรองความถี่ต่ำผ่าน ซึ่งแทนด้วย a และสับแบนด์ที่สอง (Sb2) จะเป็นส่วนของสัญญาณความเร่งที่ผ่านตัวกรองความถี่สูงผ่าน ซึ่งแทนด้วย d

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.19 การแยกองค์ประกอบสัญญาณความเร่งโดยใช้หลักการของพิวเตอร์แบงค์


ผลจากการแปลงเวฟเลต ข้อมูลในสับแบนด์ที่ 1 จะเป็นข้อมูลที่เป็นสัมประสิทธิ์ความถี่ต่ำ และแสดงรายละเอียดของสัญญาณความเร่งในสับแบนด์ที่ 2 ถ้านำเอาสับแบนด์ที่ 1 ไปผ่านการแปลงเวฟเลตต่อไปอีกจะทำให้สามารถแยกสัญญาณความเร่งออกได้เป็นหลายสับแบนด์ เรียกว่าการแปลงเวฟเลตหลายระดับ (Multilevel Wavelet Transform) ดังรูปที่ 3.20 โดยในงานวิจัยนี้ได้เลือกใช้ Mother Wavelet ทั้งหมด 4 ชนิดคือ Daubechies Wavelet(DB), Symlet Wavelet(Sym), Coiflet Wavelet(Coif) และ Biorthogonal Wavelet(Bior) และ เลือกใช้การแปลงเวฟเลตแบบไม่ต่อเนื่อง 1 - 3 ระดับ เพื่อที่จะนำไปวิเคราะห์เปรียบเทียบว่าสัญญาณความเร่งจากการแปลงเวฟเลตว่าเวฟเลตแบบไหนเหมาะสมที่สุดโดยการเปรียบเทียบทั้ง 3 ระดับ ตัวอย่างการแปลงเวฟเลตของสัญญาณความเร่งของการทกล้มไปข้างหน้าแสดงดังรูป 3.21 - 3.32



รูปที่ 3.20 การแปลงแบบเวฟเลตแบบไม่ต่อเนื่องโดยพื้นฐานการวิเคราะห์แบบ multi-resolution




รูปที่ 3.21 ลักษณะสัญญาณความถี่แกน X จากการทหกล้มไปด้านหน้าใช้การแปลงเวฟเลต Daubechies2 ระดับที่ 1




รูปที่ 3.22 ลักษณะสัญญาณความถี่แกน X จากการทหกล้มไปด้านหน้าใช้การแปลงเวฟเลต Daubechies2 ระดับที่ 2




รูปที่ 3.23 ลักษณะสัญญาณความถี่แกน X จากการทหกล้มไปด้านหน้าใช้การแปลงเวฟเลต Daubechies2 ระดับที่ 3




รูปที่ 3.24 ลักษณะสัญญาณความถี่แกน X จากการทหกล้มไปด้านหน้าใช้การแปลงเวฟเลต Coiflet1 ระดับที่ 1




รูปที่ 3.25 ลักษณะสัญญาณความถี่แกน X จากการทหกล้มไปด้านหน้าใช้การแปลงเวฟเลต Coiflet1 ระดับที่ 2




รูปที่ 3.26 ลักษณะสัญญาณความถี่แแกน X จากการหกล้มไปด้านหน้าใช้การแปลงเวฟเลต Coiflet1 ระดับที่ 3




รูปที่ 3.27 ลักษณะสัญญาณความถี่แแกน X จากการหกล้มไปด้านหน้าใช้การแปลงเวฟเลต Symlet2 ระดับที่ 1



รูปที่ 3.28 ลักษณะสัญญาณความถี่แแกน X จากการหกล้มไปด้านหน้าใช้การแปลงเวฟเลต Symlet2 ระดับที่ 2




รูปที่ 3.29 ลักษณะสัญญาณความถี่แแกน X จากการหกล้มไปด้านหน้าใช้การแปลงเวฟเลต Symlet2 ระดับที่ 3



รูปที่ 3.30 ลักษณะสัญญาณความถี่แแกน X จากการหกล้มไปด้านหน้าใช้การแปลงเวฟเลต Biorthogonal1.1 ระดับที่ 1



รูปที่ 3.31 ลักษณะสัญญาณความเร่งแกน X จากการหกล้มไปด้านหลังใช้การแปลงเวฟเลต Biorthogonal1.1 ระดับที่ 2



รูปที่ 3.32 ลักษณะสัญญาณความเร่งแกน X จากการหกล้มไปด้านหน้าใช้การแปลงเวฟเลต Biorthogonal1.1 ระดับที่ 3

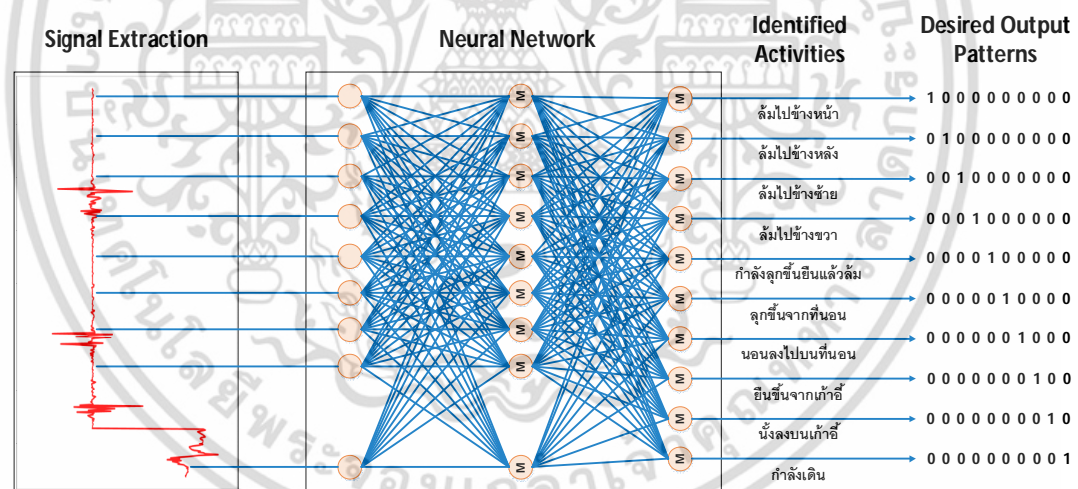
3.2.2 การคัดแยกสัญญาณการเคลื่อนไหวและการหกล้มของมนุษย์โดยใช้โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (Neural Network)

ในทางปฏิบัติการเคลื่อนไหวหลายชนิดเช่น หกล้มไปด้านหน้า หกล้มไปด้านหลัง หกล้มไปด้านขวา หกล้มไปด้านซ้าย หกล้มในขณะที่กำลังยืน จะมีรูปแบบสัญญาณที่มีความซับซ้อนและมีความคล้ายคลึงกันมาก ผลที่ตามมาคือเกิดความยากในการใช้สมการคำนวณหรือเขียนโปรแกรมเพื่อคัดแยกสัญญาณ แต่อย่างไรก็ตามด้วยความก้าวหน้าของเทคโนโลยี จึงมีความเป็นไปได้ที่จะออกแบบอัลกอริทึมสำหรับการจัดจํารูปแบบสัญญาณ ซึ่งงานวิจัยในครั้งนี้ได้ใช้วิธีที่เรียกว่า “โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ” เพื่อจําจํารูปแบบสัญญาณแล้วคัดแยกสัญญาณ ซึ่งโครงข่ายประสาทเทียมจะประกอบไปด้วย 3 ชั้นคือ ชั้นขาเข้า (Input neuron) ชั้นซ่อน (Hidden layer) ชั้นขาออก (Output layer) ซึ่งใช้ Activation function ในชั้นซ่อน และ ชั้นขาออก เป็น ฟังก์ชัน log sigmoidal ดังสมการ 3.4 จำนวนเซลล์ประสาทในชั้นขาเข้าจะเท่ากับขนาดของสัญญาณความเร่งที่ผ่านการดึงคุณลักษณะจากการแปลงเวฟเลต (ดูในหัวข้อ 3.2.1) และในชั้นขาออกจะมีเซลล์ประสาทตามจำนวนการคัดแยกสัญญาณ โดยค่าตัวเลขของสัญญาณขาออกเป้าหมาย (Desired Output) จะออกเป็น 1 ยกตัวอย่างเช่น การคัดแยกสัญญาณการเคลื่อนไหวของมนุษย์ดังแสดงในตารางที่ 3.3 และ การคัดแยกการหกล้มดังแสดงในตารางที่ 3.4 ตามลำดับ

$$f(x) = \frac{1}{1 + \exp(-x)} \quad (3.4)$$

ตารางที่ 3.3 แสดงการกำหนดค่าตัวเลขของเซลล์ประสาทเทียมขาออก (Output Neuron) ของการคัดแยกสัญญาณการเคลื่อนไหวของมนุษย์

รูปแบบสัญญาณขาเข้า	ค่าตัวเลขของสัญญาณขาออกเป้าหมาย (Desired Output) สำหรับโครงข่ายประสาทเทียม
หกล้มไปด้านหน้า	1 0 0 0 0 0 0 0 0 0
หกล้มไปด้านหลัง	0 1 0 0 0 0 0 0 0 0
หกล้มไปด้านซ้าย	0 0 1 0 0 0 0 0 0 0
หกล้มไปด้านขวา	0 0 0 1 0 0 0 0 0 0
หกล้มในขณะที่กำลังยืน	0 0 0 0 1 0 0 0 0 0
เดิน	0 0 0 0 0 1 0 0 0 0
ลุกขึ้นจากที่นอน	0 0 0 0 0 0 1 0 0 0
ล้มตัวลงนอนบนที่นอน	0 0 0 0 0 0 0 1 0 0
ลุกขึ้นจากเก้าอี้	0 0 0 0 0 0 0 0 1 0
นั่งลงบนเก้าอี้	0 0 0 0 0 0 0 0 0 1

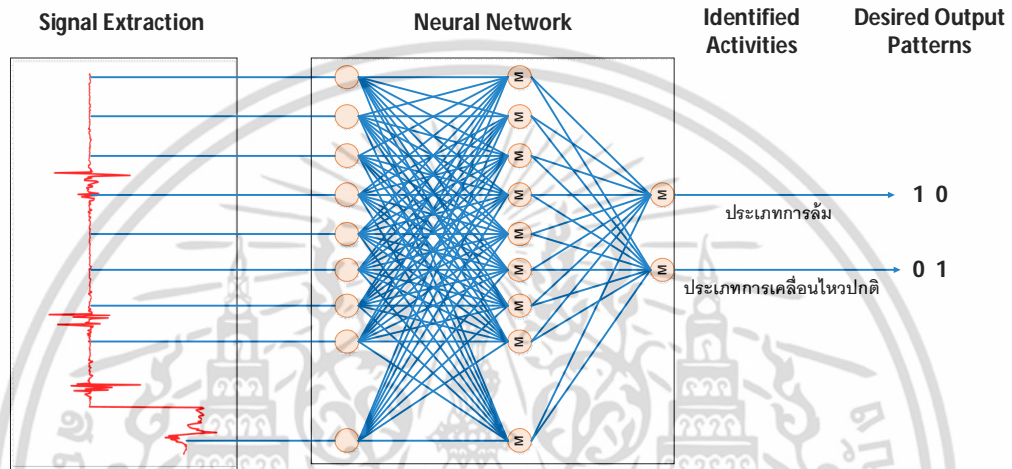


รูปที่ 3.33 โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN) ที่ใช้ในการจัดจำรูปแบบของการคัดแยกสัญญาณการเคลื่อนไหวของมนุษย์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.4 แสดงการกำหนดค่าตัวเลขของเซลล์ประสาทเทียมขาออก (Output Neuron) ของการคัดแยกสัญญาณการทกล้มของมนุษย์

รูปแบบสัญญาณขาเข้า	ค่าตัวเลขของสัญญาณขาออกเป้าหมาย (Desired Output) สำหรับโครงข่ายประสาทเทียม
ประเภทการทกล้ม	1 0
ประเภทการเคลื่อนไหวปกติ	0 1




รูปที่ 3.34 โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN) ที่ใช้ในการจัดจำรูปแบบของการคัดแยกสัญญาณการทกล้มของมนุษย์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 4

การทดลองและผลการทดลอง

การทดลองสำหรับงานวิทยานิพนธ์ฉบับนี้จะประกอบด้วย สองการทดลองคือ 1) คัดแยกกิจกรรมของมนุษย์โดยใช้โครงข่ายประสาทเทียม (Human Activity Classification) และ 2) ตรวจสอบการหกล้มของมนุษย์โดยใช้โครงข่ายประสาทเทียม (Falling Detection) ซึ่งสัญญาณที่ใช้ในการทดลองได้มาจากการวัดความเร่งจากการเคลื่อนไหวของอาสาสมัครที่ติดระบบตรวจวัดความเร่ง (Signal Acquisition) ไว้ที่เอวด้านขวา สัญญาณความเร่งที่วัดได้จะถูกดึงคุณลักษณะโดยการแปลงเวฟเลต (Wavelet Transform) ก่อนที่จะถูกคัดแยกโดยใช้โครงข่ายประสาทเทียม (Neural Network) ดังรูป 4.1



รูปที่ 4.1 ขั้นตอนการทดลอง

เนื้อหาที่จะกล่าวถึงในบทนี้มีดังต่อไปนี้

หัวข้อที่ 4.1 การวัดสัญญาณความเร่ง

หัวข้อที่ 4.2 การวัดประสิทธิภาพของระบบตรวจจับการหกล้ม

หัวข้อที่ 4.3 การทดลองและผลการทดลอง

1. การคัดแยกกิจกรรมของมนุษย์ (Human Activity Classification)
2. การตรวจจับการหกล้มของมนุษย์ (Falling Detection)

4.1 การวัดสัญญาณความเร่ง

การทดลองสำหรับงานวิจัยนี้ ใช้อาสาสมัครที่สุขภาพดี 5 คน อายุระหว่าง 21-25 ปี ประกอบด้วยผู้ชายจำนวน 4 คนและผู้หญิงจำนวน 1 คน โดยติดระบบตรวจจับการหกล้มไว้ที่เอวด้านขวา วัดสัญญาณความเร่งของแต่ละกิจกรรมซึ่งจะประกอบไปด้วยสัญญาณ 2 ประเภท คือ ประเภทสัญญาณการเคลื่อนไหวในชีวิตประจำวัน ประกอบไปด้วย 1)เดิน 2)ลุกขึ้นจากเก้าอี้ 3)นั่งลงบนเก้าอี้ 4)นอนลงบนที่นอน 5)ลุกขึ้นจากที่นอน และ สัญญาณประเภทการหกล้ม คือ 1)หกล้มไปด้านหน้า 2)หกล้มไปด้านหลัง 3)หกล้มไปด้านขวา 4)หกล้มไปด้านซ้าย 5)หกล้มในขณะที่กำลังยืน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดยที่อาสาสมัครแต่ละคนทำกิจกรรมละ 30 ครั้ง ดังนั้นจำนวนสัญญาณความแรงของแต่ละกิจกรรม จะมี 150 สัญญาณ จะได้สัญญาณความแรงจากกิจกรรมทั้งหมด 1,500 สัญญาณดังตารางที่ 4.1

ตารางที่ 4.1 จำนวนครั้งของแต่ละกิจกรรมของอาสาสมัคร รวมทั้งหมด 1500 สัญญาณ

กิจกรรม	อาสาสมัคร 1 (จำนวนครั้ง)	อาสาสมัคร 2 (จำนวนครั้ง)	อาสาสมัคร 3 (จำนวนครั้ง)	อาสาสมัคร 4 (จำนวนครั้ง)	อาสาสมัคร 5 (จำนวนครั้ง)
เดิน	30	30	30	30	30
ลุกขึ้นจากเก้าอี้	30	30	30	30	30
นั่งลงบนเก้าอี้	30	30	30	30	30
นอนลงบนที่นอน	30	30	30	30	30
ลุกขึ้นจากที่นอน	30	30	30	30	30
หกล้มไปด้านหน้า	30	30	30	30	30
หกล้มไปด้านหลัง	30	30	30	30	30
หกล้มไปด้านขวา	30	30	30	30	30
หกล้มไปด้านซ้าย	30	30	30	30	30
หกล้มในขณะที่กำลังยืน	30	30	30	30	30

4.2 การวัดประสิทธิภาพของระบบตรวจจับการหกล้ม

ประสิทธิภาพของการอัลกอริทึมที่นำเสนอขึ้นอยู่กับ 4 ปัจจัย 1) แกนของสัญญาณความแรง 2) ความกว้างฟิลเตอร์เวฟเลต 3) ระดับของเวฟเลต และ 4) จำนวนนิวรอนในชั้นซ่อน ซึ่งแสดงอยู่ในตารางที่ 4.2

ตารางที่ 4.2 ปัจจัยของการทดลอง

Factors	Selected Setting
Axes	X-axis, Y-axis, Z-axis, and XYZ-axis
Wavelets (Filter length)	'db2', 'db4', 'db6', ... , 'db20', 'coif1', 'coif2' ... , 'coif5', 'sym2', 'sym3' ... , 'sym8', 'bior1.1', 'bior1.3', 'bior1.5', 'bior2.2', 'bior2.4', 'bior2.6', 'bior2.8', 'bior3.1', 'bior3.3', 'bior3.5', 'bior3.7', 'bior3.9', 'bior4.4', 'bior5.5', 'bior6.8'
Decomposition level	1, 2, and 3
Neuron in hidden layer	1, 2, 3, ... , and 40

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การวัดค่าประสิทธิภาพส่วนใหญ่ที่ใช้สำหรับงานตรวจจับการหลั้มจะเป็นค่าทางสถิติ ซึ่งในหลายบทความ นิยมใช้ค่า ความแม่นยำ (Precision : Pr) ในการวัดประสิทธิภาพซึ่งสามารถคำนวณได้ดังสมการที่ 4.1

$$\text{Pr}(c) = \frac{TP}{TP + FP} \quad (4.1)$$

กำหนดให้ c คือสัญญาณของกิจกรรม , True Positives (TP) คือ จำนวนของสัญญาณความเร่งที่ถูกต้องที่ได้มาจากการคัดแยกของกิจกรรม c , และ False Positives (FP) จำนวนสัญญาณความเร่งที่ไม่ถูกต้องที่ได้มาจากการคัดแยกของกิจกรรม c

สำหรับวิทยานิพนธ์ฉบับนี้ใช้ เปอร์เซ็นของความแม่นยำเฉลี่ย (Percent of Average Precision : %Pr) และ เปอร์เซ็นของการคำนวณ (Percent of Operators : %Op) และเพื่อที่จะวัดประสิทธิภาพของระบบ นอกจากนี้เราเสนอการประเมินการวัดประสิทธิภาพของอัลกอริทึมโดยนำเสนอ (Pe : Evaluate the performance of the proposed algorithm)

เปอร์เซ็นต์ของความแม่นยำเฉลี่ย (Percent of Average Precision : %Pr) คือค่าเฉลี่ยของความแม่นยำของทุกกิจกรรมซึ่งสามารถคำนวณได้ดังสมการที่ 4.2

$$\%Pr = \frac{\sum_{i=c}^C \text{Pr}(c_i)}{C} \times 100 \quad (4.2)$$

กำหนดให้ c_i หมายถึงลำดับ i^{th} ของกิจกรรม และ C คือจำนวนกิจกรรมทั้งหมด %Pr จึงเป็นเปอร์เซ็นต์ของค่าความแม่นยำของอัลกอริทึมที่นำเสนอสำหรับการคัดแยกกิจกรรมที่ถูกต้อง


เปอร์เซ็นต์ของการคำนวณ (Percent of Operators : %Op) สามารถคำนวณได้จากจำนวนการบวกและการคูณของการคำนวณการแปลงเวฟเลตและโครงข่ายประสาทเทียมของอัลกอริทึมที่นำเสนอ ซึ่งอธิบายได้ดังสมการที่ 4.3

$$\%Op = \frac{(4 \times \text{Input} \times \text{Filter length} \times \text{Level decomposition}) + (2 \times (\text{Input} \times \text{Hidden node}) + 2 \times (\text{Hidden node} \times \text{Target}))}{\text{Operation}_{\max}} \quad (4.3)$$

ระบบของอัลกอริทึมที่ดีต้องให้ความแม่นยำ (Precision) สูง และ ใช้เวลาในการคำนวณ (Operator) น้อย จึงสรุปออกมาได้ดังรูปที่ 4.2 ซึ่ง High effectiveness หมายความว่าความแม่นยำสูง และ High efficiency หมายถึงการคำนวณที่รวดเร็ว เพื่อที่ประเมินการวัดประสิทธิภาพ (Pe : Evaluate the performance of the proposed algorithm) สามารถคำนวณได้จาก %Pr และ %Op ดังสมการที่ 4.4

$$\text{Pe} = \sqrt{(100 - \%Pr)^2 + (\%Op)^2} \quad (4.4)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.2 แสดงการประเมินประสิทธิภาพของระบบที่นำเสนอ

4.3 การทดลองและผลการทดลอง

4.3.1 การตัดแยกกิจกรรมของมนุษย์ (Human Activity Classification)

การทดลองการตัดแยกกิจกรรมของมนุษย์ มีวัตถุประสงค์เพื่อประเมินผลการทำงานของอัลกอริทึมที่นำเสนอเกี่ยวกับการแบ่งประเภทของสัญญาณความเร่งทั้งหมด 10 กิจกรรมอย่างถูกต้อง ซึ่งประกอบไปด้วย 1) เดิน 2) ลุกขึ้นจากเก้าอี้ 3) นั่งลงบนเก้าอี้ 4) กำลังนอนลงบนที่นอน 5) กำลังลุกจากที่นอน 6) หก้มไปด้านหน้า 7) หก้มไปด้านหลัง 8) หก้มไปด้านขวา 9) หก้มไปด้านซ้าย และ 10) หก้มในขณะที่กำลังยืนขึ้น ดังรูปที่ 4.3



รูปที่ 4.3 แสดงการตัดแยกกิจกรรมของมนุษย์


สำหรับการทดลองนี้ใช้สัญญาณ 75 สัญญาณจาก 150 สัญญาณของแต่ละกิจกรรมสำหรับการฝึกสอนโครงข่ายประสาทเทียมและใช้ 75 สัญญาณจาก 150 สัญญาณของแต่ละกิจกรรมสำหรับการทดลอง ดังตารางที่ 4.3

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


ตารางที่ 4.3 แสดงรายละเอียดของจำนวนสัญญาณของการจำลองกิจกรรมต่างๆที่ใช้สำหรับการฝึกสอนและทดสอบของโครงข่ายประสาทเทียมสำหรับการคัดแยกกิจกรรมของมนุษย์

รายละเอียด	จำนวนตัวอย่าง	สำหรับการฝึกสอน	สำหรับการทดสอบ
การเดิน	150	75	75
ลุกขึ้นจากเก้าอี้	150	75	75
นั่งลงบนเก้าอี้	150	75	75
กำลังนอนลงบนที่นอน	150	75	75
กำลังลุกจากที่นอน	150	75	75
หกล้มไปด้านหน้า	150	75	75
หกล้มไปด้านหลัง	150	75	75
หกล้มไปด้านขวา	150	75	75
หกล้มไปด้านซ้าย	150	75	75
หกล้มในขณะที่กำลังยืนขึ้น	150	75	75

ในกรณีของการใช้สัญญาณความเร่งแบบแกนเดียวที่ผ่านการแปลงเวฟเลตแล้วในระดับต่างๆมี 416 จุด จึงต้องกำหนดจำนวนโหนดในชั้นขาเข้าในโครงข่ายประสาทเทียมเท่ากับ 416 โหนด แล้วถ้าใช้สัญญาณความเร่งแบบสามแกนก็จะทำให้จำนวนโหนดของโครงข่ายประสาทเทียมในชั้นขาเข้าเท่ากับ $416 \times 3 = 1,248$ โหนด และในชั้นขาออกจะมีค่าเท่ากับจำนวนกิจกรรมที่ทำการคัดแยกซึ่งในการทดลองนี้มี 10 กิจกรรมก็ต้องกำหนดจำนวนโหนดในชั้นขาออกมีค่าเท่ากับ 10 โหนด ดังแสดงในรูป 4.4 และ 4.5 ตามลำดับ



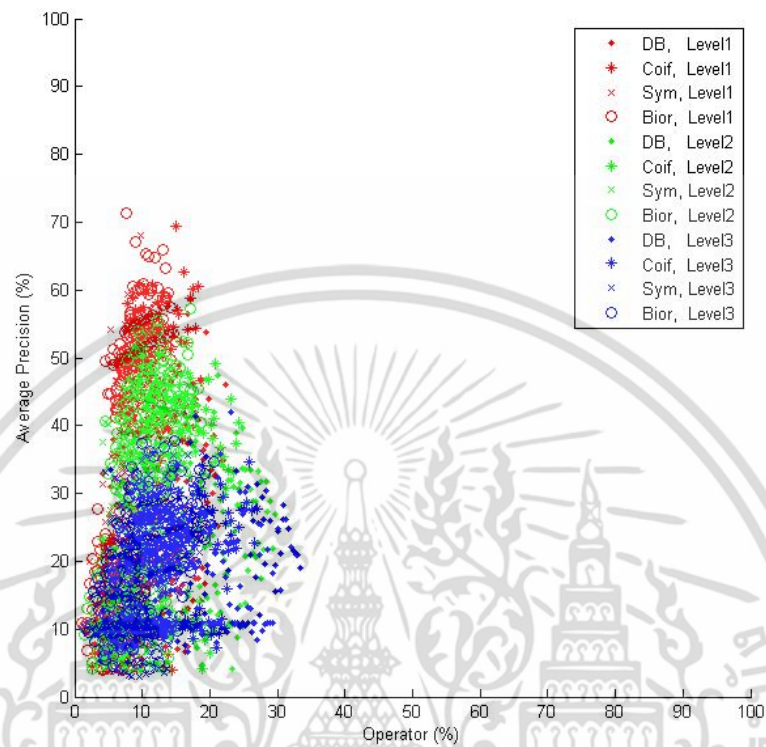
รูปที่ 4.4 แสดงโครงสร้างของโครงข่ายประสาทเทียมสำหรับการทดลองคัดแยกกิจกรรมของมนุษย์โดยใช้สัญญาณความเร่งแบบแกนเดียว



รูปที่ 4.5 แสดงโครงสร้างของโครงข่ายประสาทเทียมสำหรับการทดลองคัดแยกกิจกรรมของมนุษย์โดยใช้สัญญาณความเร่งแบบสามแกน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.3.1.1 ผลการทดลองการคัดแยกกิจกรรมของมนุษย์ด้วยสัญญาณความเร่งแกน X โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม




รูปที่ 4.6 กราฟแสดงผลการทดลองการคัดแยกกิจกรรมของมนุษย์ด้วยสัญญาณความเร่งแกน X โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม

ตารางที่ 4.4 แสดงผลการทดลองการคัดแยกกิจกรรมของมนุษย์ด้วยสัญญาณความเร่งแกน X โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียมที่ให้ค่าความแม่นยำสูงสุด

Wavelet	Decomposition Level	โครงสร้างโครงข่ายประสาทเทียม (Input-Hidden-Output)	%Precision	%Operation	Pe
DB10	1	416-34-10	57.70	13.83	44.50
Coif4	1	416-32-10	69.36	14.93	34.08
Sym3	1	416-40-10	68.00	9.79	33.46
Bior1.1	1	416-36-10	71.39	7.55	29.59
DB8	2	416-36-10	47.41	15.69	54.88
Coif1	2	416-30-10	51.58	9.01	49.25
Sym4	2	416-34-10	53.84	10.87	47.42
Bior2.8	2	416-38-10	57.17	17.18	46.14
DB8	3	416-40-10	41.48	17.92	61.20
Coif2	3	416-38-10	34.09	14.96	67.59
Sym4	3	416-36-10	36.30	11.99	64.81
Bior1.3	3	416-32-10	37.34	9.94	63.45

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.3.1.2 ผลการทดลองการคัดแยกกิจกรรมของมนุษย์ด้วยสัญญาณความเร่งแกน Y โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม




รูปที่ 4.7 กราฟแสดงผลการทดลองการคัดแยกกิจกรรมของมนุษย์ด้วยสัญญาณความเร่งแกน Y โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม

ตารางที่ 4.5 แสดงผลการทดลองการคัดแยกกิจกรรมของมนุษย์ด้วยสัญญาณความเร่งแกน Y โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียมที่ให้ค่าความแม่นยำสูงสุด

Wavelet	Decomposition Level	โครงสร้างโครงข่ายประสาทเทียม (Input-Hidden-Output)	%Precision	%Operation	Pe
DB8	1	416-38-10	54.68	13.11	47.18
Coif5	1	416-40-10	71.66	18.66	33.93
Sym7	1	416-32-10	71.44	11.23	30.69
Bior2.4	1	416-36-10	65.26	10.51	36.29
DB4	2	416-34-10	41.56	10.87	59.44
Coif1	2	416-36-10	53.04	10.14	48.04
Sym6	2	416-40-10	63.67	14.23	39.01
Bior1.1	2	416-20-10	51.45	4.90	48.80
DB6	3	416-32-10	34.80	13.82	66.65
Coif2	3	416-40-10	38.4	15.34	63.48
Sym7	3	416-38-10	38.23	16.25	63.87
Bior1.1	3	416-40-10	47.82	8.87	52.93

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.3.1.3 ผลการทดลองการคัดแยกกิจกรรมของมนุษย์ด้วยสัญญาณความเร่งแกน Z โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม



รูปที่ 4.8 กราฟแสดงผลการทดลองการคัดแยกกิจกรรมของมนุษย์ด้วยสัญญาณความเร่งแกน Z โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม


ตารางที่ 4.6 แสดงผลการทดลองการคัดแยกกิจกรรมของมนุษย์ด้วยสัญญาณความเร่งแกน Z โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียมที่ให้ค่าความแม่นยำสูงสุด

Wavelet	Decomposition Level	โครงสร้างโครงข่ายประสาทเทียม (Input-Hidden-Output)	%Precision	%Operation	Pe
DB10	1	416-30-10	42.73	13.07	58.75
Coif1	1	416-36-10	42.39	9.03	58.31
Sym4	1	416-40-10	46.04	10.53	54.98
Bior2.4	1	416-32-10	42.98	9.75	57.85
DB20	2	416-40-10	39.90	29.75	67.06
Coif1	2	416-26-10	32.56	8.25	67.94
Sym4	2	416-28-10	33.35	9.74	67.35
Bior1.3	2	416-30-10	34.70	9.01	65.92
DB4	3	416-40-10	30.43	12.75	70.73
Coif1	3	416-32-10	33.65	9.94	67.09
Sym9	3	416-32-10	34.48	17.70	67.87
Bior3.9	3	416-38-10	36.55	20.13	66.57

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.3.1.4 ผลการทดลองการคัดแยกกิจกรรมของมนุษย์ด้วยสัญญาณความเร่งแกน XYZ

โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม



รูปที่ 4.9 กราฟแสดงผลการทดลองการคัดแยกกิจกรรมของมนุษย์ด้วยสัญญาณความเร่งแกน XYZ

โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม

ตารางที่ 4.7 แสดงผลการทดลองการคัดแยกกิจกรรมของมนุษย์ด้วยสัญญาณความเร่งแกน XYZ โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียมที่ให้ค่าความแม่นยำสูงสุด

Wavelet	Decomposition Level	โครงสร้างโครงข่ายประสาทเทียม (Input-Hidden-Output)	%Precision	%Operation	Pe
DB2	1	1248-26-10	78.52	18.97	28.66
Coif2	1	1248-22-10	79.34	25.61	32.90
Sym2	1	1248-30-10	81.72	21.21	28.00
Bior2.2	1	1248-32-10	88.84	24.54	26.96
DB2	2	1248-26-10	74.11	21.19	33.45
Coif1	2	1248-22-10	61.01	22.28	44.91
Sym3	2	1248-40-10	62.02	32.34	49.88
Bior1.1	2	1248-36-10	72.15	23.45	36.41
DB4	3	1248-22-10	67.78	27.83	42.57
Coif2	3	1248-38-10	64.22	44.53	57.13
Sym3	3	1248-40-10	50.62	34.01	59.96
Bior1.3	3	1248-34-10	68.90	30.65	43.67

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.3.1.5 สรุปการทดลองการคัดแยกกิจกรรมของมนุษย์ด้วยสัญญาณความเร่งโดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม

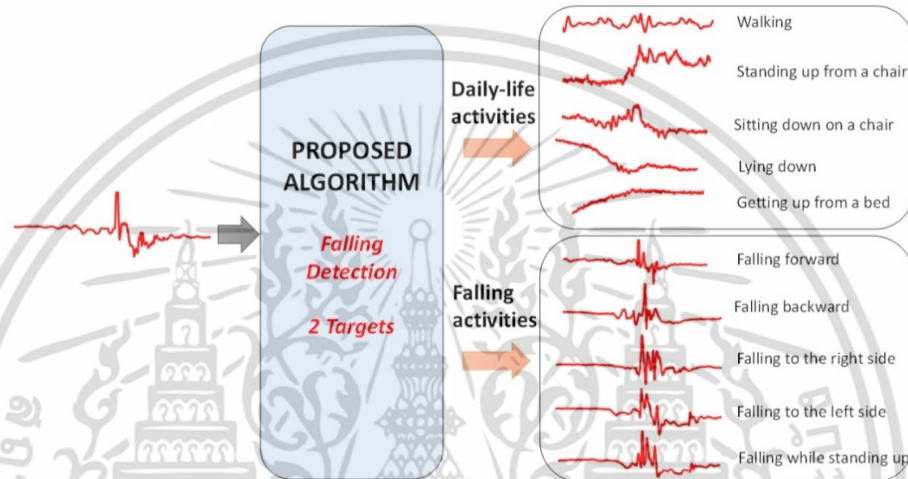
ตารางที่ 4.8 สรุปผลการทดลองการคัดแยกกิจกรรมของมนุษย์ที่มีค่าความแม่นยำสูงที่สุด

Acceleration signals	Wavelet	Decomposition Level	โครงสร้าง โครงข่ายประสาทเทียม (Input-Hidden-Output)	%Precision	%Operation	Pe
XYZ	DB2	1	1248-26-10	78.52	18.97	28.66
XYZ	Coif2	1	1248-22-10	79.34	25.61	32.90
XYZ	Sym2	1	1248-30-10	81.72	21.21	28.00
XYZ	Bior2.2	1	1248-32-10	88.84	24.54	26.96

การทดลองคัดแยกกิจกรรมของมนุษย์ด้วยสัญญาณความเร่ง สรุปได้ว่าสัญญาณความเร่งแบบสามแกน (XYZ) ที่ถูกดึงคุณลักษณะด้วยการแปลงเวฟเลต Bior2.2 ระดับที่ 1 และคัดแยกสัญญาณโดยใช้โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ ซึ่งประกอบด้วยจำนวนโหนดในชั้นซ่อนเท่ากับ 32 โหนดจะให้ค่าความแม่นยำสูงที่สุดสำหรับการทดลองการคัดแยกกิจกรรมของมนุษย์เท่ากับ 88.84% และยังให้ค่า Pe ต่ำสุดเท่ากับ 26.96

4.3.2 การทดลองการตรวจจับการหกล้มของมนุษย์ (Falling Detection)

การทดลองการตรวจจับการหกล้มของมนุษย์ผู้วิจัยมีความสนใจในการคัดแยกเหตุการณ์การหกล้มออกจากกิจกรรมต่างๆในกิจวัตรประจำวัน ดังนั้นกิจกรรมทั้งหมดออกเป็น 2 ประเภท คือ ประเภทการเคลื่อนไหวปกติในชีวิตประจำวัน ได้แก่ เดิน ลุกขึ้นจากเก้าอี้ นั่งลงบนเก้าอี้ กำลังนอนลงบนที่นอน และกำลังลุกจากที่นอน ประเภทการล้ม ได้แก่ หกล้มไปด้านหน้า หกล้มไปด้านหลัง หกล้มไปด้านขวา หกล้มไปด้านซ้าย และหกล้มในขณะที่กำลังยืนขึ้น ดังรูปที่ 4.10



รูปที่ 4.10 แสดงการตรวจจับการหกล้มของมนุษย์


สำหรับการทดลองนี้แบ่งสัญญาณออกเป็น 2 กลุ่ม โดยที่แต่ละกลุ่มจะประกอบด้วย 5 กิจกรรม โดยที่แต่ละกิจกรรมใช้สัญญาณ 75 สัญญาณจาก 150 สัญญาณสำหรับการฝึกสอนโครงข่ายประสาทเทียม และใช้ 75 สัญญาณจาก 150 สัญญาณสำหรับการทดลองจำแนกสัญญาณของโครงข่ายประสาทเทียม ดังตารางที่ 4.9

ตารางที่ 4.9 แสดงรายละเอียดของการจำลองกิจกรรมต่างๆที่ใช้สำหรับการฝึกสอนและทดสอบของโครงข่ายประสาทเทียมของการทดลองสำหรับตรวจจับการหกล้มของมนุษย์


	รายละเอียด	จำนวนตัวอย่าง	สำหรับการฝึกสอน	สำหรับการทดลอง
กิจวัตรประจำวัน	เดิน	150	75	75
	ลุกขึ้นจากเก้าอี้	150	75	75
	นั่งลงบนเก้าอี้	150	75	75
	กำลังนอนลงบนที่นอน	150	75	75
	กำลังลุกจากที่นอน	150	75	75
การหกล้ม	หกล้มไปด้านหน้า	150	75	75
	หกล้มไปด้านหลัง	150	75	75
	หกล้มไปด้านขวา	150	75	75
	หกล้มไปด้านซ้าย	150	75	75
	หกล้มในขณะที่กำลังยืนขึ้น	150	75	75

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

นอกจากนี้ในกรณีของการใช้สัญญาณความถี่แบบแกนเดียวที่ผ่านการแปลงเวฟเลตแล้วในระดับต่างๆจะมี 416 จุด จึงต้องกำหนดจำนวนโหนดในชั้นขาเข้าในโครงข่ายประสาทเทียมเท่ากับ 416 โหนด แล้วถ้าใช้สัญญาณความถี่แบบสามแกนก็จะทำให้จำนวนโหนดของโครงข่ายประสาทเทียมในชั้นขาเข้าเท่ากับ $416 \times 3 = 1,248$ โหนด และในชั้นขาออกจะมีค่าเท่ากับจำนวนกลุ่มที่ทำการคัดแยกซึ่งในการทดลองนี้มี 2 กลุ่มก็ต้องกำหนดจำนวนโหนดในชั้นขาออกมีค่าเท่ากับ 2 โหนด ดังแสดงในรูป 4.11 และ 4.12 ตามลำดับ




รูปที่ 4.11 แสดงโครงสร้างของโครงข่ายประสาทเทียมสำหรับการทดลองตรวจจับการหลั่งของมนุษย์ โดยใช้สัญญาณความถี่แบบแกนเดียว



รูปที่ 4.12 แสดงโครงสร้างของโครงข่ายประสาทเทียมสำหรับการทดลองตรวจจับการหลั่งของมนุษย์ โดยใช้สัญญาณความถี่แบบสามแกน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.3.2.1 ผลการทดลองการตรวจจับการหกซึมของมนุษย์ด้วยสัญญาณความเร่งแกน X โดย ใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม



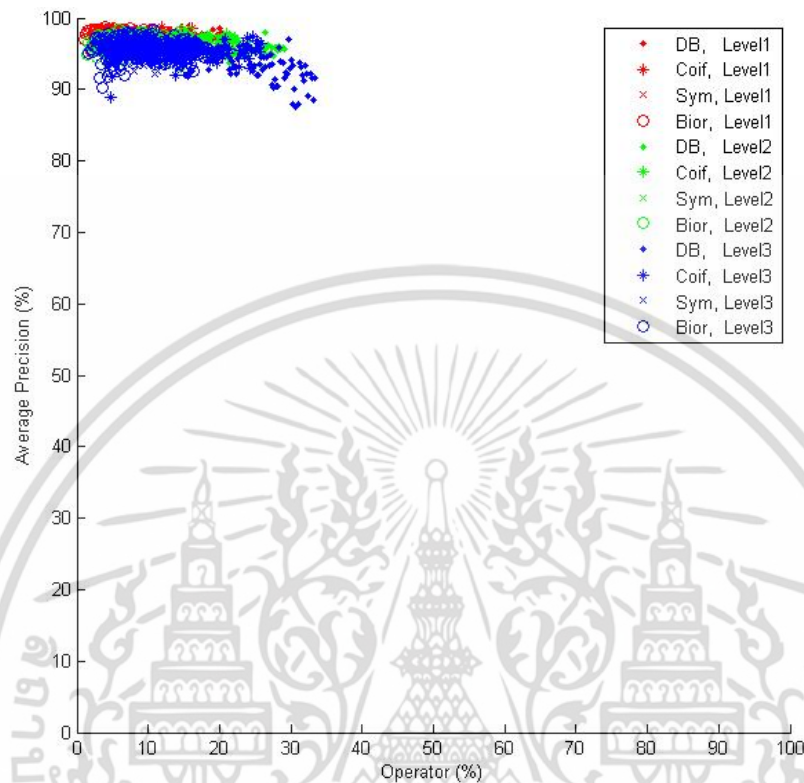
รูปที่ 4.13 กราฟแสดงผลการทดลองตรวจจับการหกซึมของมนุษย์ด้วยสัญญาณความเร่งแกน X โดย
ใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม

ตารางที่ 4.10 แสดงผลทดลองการตรวจจับการหกซึมของมนุษย์ด้วยสัญญาณความเร่งแกน X โดยใช้
การแปลงเวฟเลตและโครงข่ายประสาทเทียมที่ให้ค่าความแม่นยำสูงสุด

Wavelet	Decomposition Level	โครงสร้างโครงข่ายประสาทเทียม (Input-Hidden-Output)	%Precision	%Operation	Pe
DB2	1	416-2-2	98.20	2.15	2.81
Coif1	1	416-2-2	99.34	3.01	3.08
Sym2	1	416-5-2	99.34	2.80	2.88
Bior1.1	1	416-3-2	98.67	1.51	2.01
DB2	2	416-3-2	98.80	3.23	3.44
Coif1	2	416-5-2	98.14	4.95	5.29
Sym2	2	416-5-2	98.69	3.66	3.89
Bior1.1	2	416-4-2	99.08	2.15	2.34
DB2	3	416-2-2	97.90	3.44	4.03
Coif1	3	416-1-2	97.47	4.73	5.37
Sym2	3	416-4-2	97.20	3.87	4.22
Bior1.1	3	416-2-2	97.95	1.94	2.82

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.3.2.2 ผลการทดลองการตรวจจับการหกซึมของมนุษย์ด้วยสัญญาณความเร่งแกน Y โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม




รูปที่ 4.14 กราฟแสดงผลการทดลองตรวจจับการหกซึมของมนุษย์ด้วยสัญญาณความเร่งแกน Y โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม

ตารางที่ 4.11 แสดงผลทดลองการตรวจจับการหกซึมของมนุษย์ด้วยสัญญาณความเร่งแกน Y โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียมที่ให้ค่าความแม่นยำสูงสุด

Wavelet	Decomposition Level	โครงสร้างโครงข่ายประสาทเทียม (Input-Hidden-Output)	%Precision	%Operation	Pe
DB2	1	416-2-2	97.67	2.15	3.17
Coif1	1	416-2-2	97.67	3.01	3.81
Sym2	1	416-5-2	98.54	2.80	3.16
Bior1.1	1	416-3-2	98.08	1.51	2.44
DB2	2	416-1-2	96.64	2.80	4.37
Coif1	2	416-1-2	96.29	4.09	5.04
Sym2	2	416-2-2	95.92	3.01	4.87
Bior1.1	2	416-2-2	96.69	1.72	3.73
DB2	3	416-2-2	96.52	3.44	4.90
Coif1	3	416-5-2	96.25	5.60	6.73
Sym2	3	416-1-2	96.55	3.23	4.72
Bior1.1	3	416-5-2	97.28	2.59	3.76

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.3.2.3 ผลการทดลองการตรวจจับการหกล้มของมนุษย์ด้วยสัญญาณความเร่งแกน Z โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม



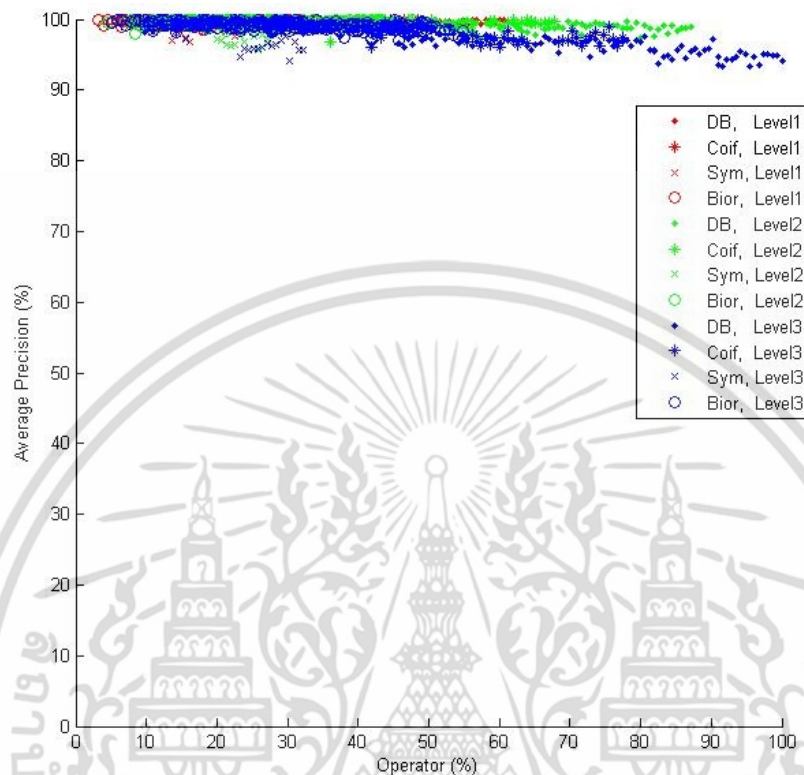
รูปที่ 4.15 กราฟแสดงผลการทดลองตรวจจับการหกล้มของมนุษย์ด้วยสัญญาณความเร่งแกน Z โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม

ตารางที่ 4.12 แสดงผลทดลองการตรวจจับการหกล้มของมนุษย์ด้วยสัญญาณความเร่งแกน Z โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียมที่ให้ค่าความแม่นยำสูงสุด

Wavelet	Decomposition Level	โครงสร้างโครงข่ายประสาทเทียม (Input-Hidden-Output)	%Precision	%Operation	Pe
DB2	1	416-3-2	96.84	2.37	3.95
Coif1	1	416-2-2	96.89	3.01	4.33
Sym2	1	416-7-2	96.31	3.23	4.90
Bior1.1	1	416-6-2	96.57	2.16	4.05
DB2	2	416-4-2	96.01	3.44	5.27
Coif1	2	416-4-2	95.75	4.73	6.37
Sym2	2	416-10-2	96.94	4.74	5.64
Bior1.1	2	416-4-2	95.84	2.15	4.69
DB2	3	416-9-2	96.67	4.95	5.97
Coif1	3	416-4-2	96.35	5.38	6.50
Sym2	3	416-8-2	95.35	4.74	6.64
Bior1.1	3	416-6-2	95.37	2.80	5.41

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.3.2.4 ผลการทดลองการตรวจจับการหกล้มของมนุษย์ด้วยสัญญาณความเร่งแกน XYZ โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม



รูปที่ 4.16 กราฟแสดงผลการทดลองตรวจจับการหกล้มของมนุษย์ด้วยสัญญาณความเร่งแกน XYZ โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม

ตารางที่ 4.13 แสดงผลทดลองการตรวจจับการหกล้มของมนุษย์ด้วยสัญญาณความเร่งแกน XYZ โดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียมที่ให้ค่าความแม่นยำสูงสุด

Wavelet	Decomposition Level	โครงสร้างโครงข่ายประสาทเทียม (Input-Hidden-Output)	%Precision	%Operation	Pe
DB2	1	1248-1-2	99.87	5.81	5.81
Coif1	1	1248-1-2	99.47	8.39	8.40
Sym2	1	1248-1-2	99.87	5.81	5.81
Bior1.1	1	1248-1-2	100.00	3.23	3.23
DB2	2	1248-1-2	99.73	8.39	8.39
Coif1	2	1248-1-2	99.87	12.26	12.26
Sym2	2	1248-1-2	99.73	8.39	8.39
Bior1.1	2	1248-1-2	99.47	4.52	4.55
DB2	3	1248-1-2	98.14	9.68	9.85
Coif1	3	1248-1-2	98.45	14.19	14.28
Sym2	3	1248-1-2	98.58	9.68	9.70
Bior1.1	3	1248-1-2	99.60	5.16	5.18

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.3.2.5 สรุปการทดลองการตรวจจับการหกล้มของมนุษย์ด้วยสัญญาณความเร่งโดยใช้การแปลงเวฟเลตและโครงข่ายประสาทเทียม

ตารางที่ 4.14 สรุปผลทดลองการตรวจจับการหกล้มของมนุษย์ที่มีค่าความแม่นยำสูงสุด

Acceleration signals	Wavelet	Decomposition Level	โครงสร้างโครงข่ายประสาทเทียม (Input-Hidden-Output)	%Precision	%Operation	Pe
XYZ	DB6	1	1248-1-2	100	16.13	16.13
XYZ	Coif2	1	1248-1-2	100	16.13	16.13
XYZ	Sym3	1	1248-1-2	100	8.39	8.39
XYZ	Bior1.1	1	1248-1-2	100	3.23	3.23

ตารางที่ 4.15 สรุปผลทดลองการตรวจจับการหกล้มของมนุษย์ที่มีค่า Pe น้อยที่สุด

Acceleration signals	Wavelet	Decomposition Level	โครงสร้างโครงข่ายประสาทเทียม (Input-Hidden-Output)	%Precision	%Operation	Pe
X	DB2	1	416-2-2	98.20	2.15	2.81
X	Coif1	1	416-2-2	99.34	3.01	3.08
X	Sym2	1	416-5-2	99.34	2.8	2.88
X	Bior1.1	1	416-3-2	98.67	1.51	2.01

การทดลองตรวจจับการหกล้มของมนุษย์ด้วยสัญญาณความเร่งสรุปได้ว่า สัญญาณความเร่งแบบสามแกน (XYZ) ที่ถูกดึงคุณลักษณะด้วยการแปลงเวฟเลต Bior1.1 ระดับที่ 1 ก่อนคัดแยกสัญญาณโดยโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ ซึ่งประกอบด้วยจำนวนโหนดในชั้นซ่อนเท่ากับ 1 โหนด มีค่าความแม่นยำสูงสุดสำหรับการทดลองการตรวจจับการหกล้มของมนุษย์เท่ากับ 100% แต่มีค่า Pe เท่ากับ 3.23 ซึ่งไม่ใช่ค่าที่ต่ำที่สุดสำหรับการทดลองตรวจจับการหกล้มของมนุษย์สำหรับสัญญาณความเร่งแบบแกนเดียว (X) ที่ถูกดึงคุณลักษณะด้วยการแปลงเวฟเลต Bior1.1 ระดับที่ 1 ก่อนคัดแยกสัญญาณโดยโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ มีจำนวนโหนดในชั้นซ่อนเท่ากับ 3 มีความแม่นยำเท่ากับ 98.67% จะมีค่า Pe ต่ำที่สุดสำหรับการทดลองตรวจจับการหกล้มของมนุษย์เท่ากับ 2.01

บทที่ 5

สรุปผลการทดลอง

วิทยานิพนธ์ฉบับนี้ นำเสนออัลกอริทึมซึ่งสามารถคัดแยกการเคลื่อนไหวของมนุษย์ได้ 10 กิจกรรม และสามารถคัดแยกการหกล้มได้อย่างมีประสิทธิภาพ โดยใช้เซ็นเซอร์วัดความเร่งแบบสามแกน เริ่มต้นด้วยขั้นตอนการประดิษฐ์ระบบตรวจวัดความเร่งของการเคลื่อนไหวของมนุษย์ ต่อมาเป็นขั้นตอนของการพัฒนาอัลกอริทึมตรวจจับการเคลื่อนไหวของมนุษย์และการหกล้มของมนุษย์ สำหรับข้อมูลของสัญญาณความเร่งผู้วิจัยได้ทำการทดลองจากอาสาสมัครสุขภาพดีอายุ 21 - 25 ปีจำนวน 5 คน (ผู้ชาย 4 คน และ ผู้หญิง 1 คน) เพื่อนำสัญญาณความเร่งการใช้ทดสอบกับอัลกอริทึมที่นำเสนอเบื้องต้นได้ให้ความสนใจกิจกรรมการเคลื่อนไหว 10 กิจกรรมได้แก่ การเดิน นั่งเก้าอี้ ลุกขึ้นจากเก้าอี้นอนลงบนเตียง ลุกขึ้นจากเตียง หกล้มไปด้านหน้า หกล้มไปด้านซ้าย หกล้มไปด้านขวา หกล้มไปด้านหลัง หกล้มในขณะที่กำลังยืนขึ้น สำหรับอัลกอริทึมประกอบด้วย 2 ขั้นตอนคือ 1)แปลงเวฟเลต 2)โครงข่ายประสาทเทียม การทดลองแบ่งออกเป็น 2 การทดลองคือ การทดลองคัดแยกกิจกรรมของมนุษย์ (Human Activity Classification) และการทดลองตรวจจับการล้มของมนุษย์ (Falling Detection)

จากผลการทดลองการคัดแยกการเคลื่อนไหวของมนุษย์ (Human Activity Classification) ในตารางที่ 4.4 - 4.8 ในหัวข้อ 4.3.1. สรุปได้ว่าวิธีการคัดแยกที่ใช้สัญญาณความเร่งแบบสามแกน, การแปลงเวฟเลต Biorthogonals2.2 ระดับที่ 1 และโครงข่ายประสาทเทียมที่มีจำนวนโหนดในชั้นซ่อนเท่ากับ 32 โหนด ให้ค่าความแม่นยำสูงสุดเท่ากับ 88.84% และยังให้ค่า P_e ต่ำสุดเท่ากับ 26.96 ซึ่งจำนวน O_p เพียงแค่ 24.54 เมื่อเทียบกับวิธีการคัดแยกแบบอื่นๆ ดังนั้นจึงสรุปได้ว่า วิธีการดังกล่าวเป็นวิธีการคัดแยกการเคลื่อนไหวของมนุษย์ที่ดีที่สุด

จากผลการทดลองการตรวจจับการหกล้มของมนุษย์ (Falling Detection) ในตารางที่ 4.10 - 4.15 ในหัวข้อ 4.3.2 ปรากฏว่าวิธีการตรวจจับการหกล้มที่ให้ค่าความแม่นยำสูงสุด กับ วิธีที่ให้ค่า P_e ต่ำสุด เป็นคนละวิธีคือ ถ้าต้องการให้ค่าความแม่นยำสูงสุดต้องใช้สัญญาณความเร่งแบบสามแกนแปลงเวฟเลต Biorthogonals1.1 ระดับที่ 1 และโครงข่ายประสาทเทียมที่มีจำนวนโหนดในชั้นซ่อนเท่ากับ 1 โหนด ให้ค่าความแม่นยำเท่ากับ 100.00% และให้ค่า P_e เท่ากับ 3.23 หรือต้องใช้จำนวน O_p เท่ากับ 3.23 แต่ถ้าต้องการวิธีที่ให้ค่า P_e ต่ำสุด ต้องใช้สัญญาณความเร่งแบบแกนเดียว (แกน X) แปลงเวฟเลต Biorthogonals1.1 ระดับที่ 1 และโครงข่ายประสาทเทียมที่มีจำนวนโหนดในชั้นซ่อนเท่ากับ 3 โหนด ให้ค่าความแม่นยำเท่ากับ 98.67% และให้ค่า P_e เท่ากับ 2.01 หรือต้องใช้จำนวน O_p เท่ากับ 1.51 ซึ่งเมื่อเปรียบเทียบทั้งสองวิธีแล้ว ปรากฏว่าวิธีแรกมีค่าความแม่นยำกว่าวิธีที่สองเท่ากับ 1.35% แต่จำนวน O_p ของวิธีแรกมากกว่าวิธีที่สองถึง 113.91% ทำให้สรุปได้ว่าวิธีการตรวจจับการหกล้มที่ดีที่สุดคือวิธีที่สอง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เอกสารอ้างอิง

- [1] Worawet Suwanrada, Ph.D. Dean of College of Population Studies and Associate Professor of Economics Chulalongkorn University, "**National experiences from Thailand regarding long-term care of older persons**"
- [2] Jacob, J.; Nguyen, T.; Lie, D.Y.C.; Zupancic, S.; Bishara, J.; Dentino, A.; Banister, R.E., "**A fall detection study on the sensors placement location and a rule-based multi-thresholds algorithm using both accelerometer and gyroscopes**," Fuzzy Systems (FUZZ), 2011 IEEE International Conference on , vol., no., pp.666-671, 27-30 June 2011
- [3] Sengto, A.; Leauhatong, T., "**Human falling detection algorithm using back propagation neural network**," Biomedical Engineering International Conference (BMEiCON), 2012, pp 1-5, 5-7 Dec. 2012.
- [4] Birsel Ayrulu-Erdem.; Billur Barshan., "**Leg Motion Classification with Articulation Neural Networks Using Wavelet-Based Features of Gyroscope Signals**" Sensors 2011, 11, 1721-1743; doi:10.3390/5110201721 , 28 January 2011
- [5] J.Saraswathy.; M.Hariharan.; Thiyagar Nadarajaw.; Wan Khairunizam.; Sazali Yaacob., "**Optimal selection of mother wavelet for accurate infant cry classification**" Australasian Physical & Engineering Scienc in Medicine June 2014, Volume 37, Issue 2, pp 439-456 , DOI 10.1007/s13246-014-0264-y
- [6] Mingwei ZHANG, Takashi SASAOKA, Hideki SHIMADA, "**Comparison of Optimal Basis Function for the Underground Microseismic Wave Processing in Wavelet Packet Transform**" Memoirs of the Faculty of Engineering, Kyushu University, Vol.73, No.3, December 2013
- [7] Mallat, S.G.; "**A theory for multiresolution signal decomposition: the wavelet representation**" Pattern Analysis and Machine Intelligence, IEEE Transactions on (Volume:11 , Issue: 7), pp. 674-693 , Jul 1989

เอกสารอ้างอิง (ต่อ)

- [8] Yun Li, Zhiling Zeng ; Popescu, M. ; Ho, K.C., **“Acoustic fall detection using a circular microphone array,”** Engineering in Medicine and Biology Society (EMBC), 2010 Annual International Conference of the IEEE, pp. 2242-2245, Aug. 31 2010-Sept. 4 2010
- [9] Mihail Popescu, Yun Li; Marjorie Skubic; Marilyn Rantz, **“An acoustic fall detector system that uses sound height information to reduce the false alarm rate”** Engineering in Medicine and Biology Society, 2008. EMBS 2008. 30th Annual International Conference of the IEEE 20-25 Aug. 2008 Page(s):4628 – 4631.
- [10] Kreković, M. Cerić, P. ; Dominko, T. ; Ilijas, M. ; Ivancic, K. ; Skolan, V. ; Sarlija, J., **“A method for real-time detection of human fall from video”** MIPRO, 2012 Proceedings of the 35th International Convention, pp. 1709-1712 , 21-25 May 2012
- [11] Samantha Ng; Adel Fakih; Adam Fourney; Pascal Poupart; John Zelek, **“Towards a Mobility Diagnostic Tool: Tracking Rollator Users’ Leg Pose With a Monocular Vision System”**, 31st Annual International Conference of the IEEE EMBS, Minneapolis, MN USA. Sept. 2-6, 2009.
- [12] Y.Zigel; D.Litvak; I.Gannot, **“A Method for Automatic Fall Detection of Elderly People Using Floor Vibrations and Sound—Proof of Concept on Human Mimicking Doll Falls,”** Biomedical Engineering, IEEE Transactions on, vol. 56, pp. 2858-2867, December 2009
- [13] J. Boyle; M. Karunanithi, **“Simulated Fall Detection via Accelerometers”**, Int. IEEE-EMBS, Vancouver, August 20-24, 2008
- [14] Bio-Inspired Artificial Intelligence Theories, Methods, and Technologies, Dario Floreano Claudio Mattiussi The MIT Press Cambridge, Massachusetts London, England, 2008
- [15] ผศ.ดร.อาทิตย์ ศรีแก้ว **“ปัญญาเชิงคำนวณ COMPUTATIONAL INTELLIGENCE”**
- [16] Chun-Lin, Liu, **“A Tutorial of the Wavelet Transform”**, <http://disp.ee.ntu.edu.tw/tutorial/WaveletTutorial.pdf>
- [17] R.J.E. Merry, **“Wavelet Tutorial and Applications a literature study”**, <http://www.mate.tue.nl/mate/pdfs/5500.pdf>

เอกสารอ้างอิง (ต่อ)

- [18] Nakaram, P.; Leauhatong, T. **“A New Content-Based Medical Image Retrieval System Based on Wavelet Transform and Multidimensional Wald-Wolfowitz Runs Test”** Biomedical Engineering International Conference (BMEiCON), 2012, pp. 1-8, 5-7 Dec. 2012
- [19] P.S. Bhowmik, P. Purkait, K. Bhattacharya.; **“A novel wavelet transform aided neural network based transmission line fault analysis method”** Electrical Power and Energy Systems 31 (2009) 213–219
- [20] Prochazka, A.; Kukal, J. ; Vysata, O., **“Wavelet transform use for feature extraction and EEG signal segments classification”** Communications, Control and Signal Processing, 2008. ISCCSP 2008. 3rd International Symposium on, pp. 719-722, 12-14 March 2008.
- [21] Kim, J.; **“Discrete Wavelet Transform-based Feature Extraction of Experiment Voltage Signal for Li-Ion Cells Consistency”** Vehicular Technology, IEEE Transactions on (Volume:PP, Issue: 99), 27 April 2015
- [22] Masoro, E.J. (2001). **Physiology of aging. International Journal of Sport Nutrition and Exercise Metabolism**, 11, S218-S222.
- [23] Daley, M.J. & Spinks, W.L. (2000). **Exercise, Mobility and Aging**. Sports Medicine. 29(1): 1-12.
- [24] Sharma, G. & Goodwin, J. (2006). **Effect of aging on respiratory system physiology system physiology and immunology**. Clin Interv Aging. 1(3): 253-60.
- [25] Lexell, J. and Downham, D. (1992). **What is the effect of aging on Type II muscle fiber**. J Neuro Sci. 107: 250-251.
- [26] American College of Sport Medicine. (2006). **ACSM’s Guidelines for Exercise Testing and Prescription**. 7th ed. Philadelphia: Lippincott Williams & Wilkins.
- [28] Krivickas et al. (2001). **Age and gender related differences in maximum shortening velocity of skeletal muscle fibers**. American Journal of Physical Medicine & Rehabilitation. 80: 447-455.
- [29] Drinkwater, B.L. (1994). **Does physical activity play a role in preventing osteoporosis?** Research Quarterly for Exercise and Sport. 65: 197-206.

เอกสารอ้างอิง (ต่อ)

- [30] Alexander, N. (1994). **Postural control in older adults**. Journal of the American Geriatrics Society. 42: 92 – 108.
- [31] พจนานุกรม ฉบับราชบัณฑิตยสถาน พ.ศ. 2554
- [32] ศิริพร พรพุทธษา. **ความรู้ ทักษะ และพฤติกรรมในการป้องกันการหกล้มในผู้สูงอายุ**. (วิทยานิพนธ์). เชียงใหม่: มหาวิทยาลัยเชียงใหม่; 2542.
- [33] นงรุช วรโธสง. **ปัจจัยที่เกี่ยวข้องกับการหกล้มในผู้สูงอายุกลุ่มเสี่ยงที่อาศัยอยู่ในชุมชน**. (วิทยานิพนธ์). ขอนแก่น: มหาวิทยาลัยขอนแก่น; 2551
- [34] สุทธิชัย จิตะพันธ์กุล. **หลักสำคัญของเวชศาสตร์ผู้สูงอายุ**. กรุงเทพฯ: โรงพิมพ์แห่งจุฬาลงกรณ์มหาวิทยาลัย; 2544.
- [35] ลิวรรณ อุนนาภิรักษ์. **การพยาบาลผู้สูงอายุ: ปัญหาระบบประสาทและอื่นๆ**. กรุงเทพฯ: บุญศิริการพิมพ์; 2547.
- [36] ชุติ ภูทอง. **ผลของโปรแกรมการลดความเสี่ยงต่อพฤติกรรมป้องกันการหกล้มของผู้สูงอายุที่บ้าน**. (วิทยานิพนธ์). กรุงเทพฯ: จุฬาลงกรณ์มหาวิทยาลัย; 2545.
- [37] ประเสริฐ อัสสันตชัย, รุ่งนรินทร์ ประดิษฐ์สุวรรณ, วิษณุ ธรรมลิขิต. **โครงการส่งเสริมสุขภาพและการป้องกันภาวะหกล้ม และผลแทรกซ้อนในผู้สูงอายุโดยแพทย์เวชศาสตร์ผู้สูงอายุ**. กรุงเทพฯ: สำนักงานคณะกรรมการวิจัยแห่งชาติ; 2544.
- [38] Lyons S, Adam S, Tittler M. **Evidence-based protocol fall prevention for older adults**. Journal of Gerontology Nursing. 2005; 31(11):9-14.
- [39] Sang-Hong Lee, **Fall Detection Using Wavelet Transform and Neural Network**, International Journal of Computer Science and Electronics Engineering (IJCSS), Volume 2, Issue 2 (2014) ISSN 2320-4028.

ภาคผนวก ก
ผลงานวิจัยที่ได้รับการตีพิมพ์

1. Nuttainakul, N.;Leauhatong, T., " **A Novel Algorithm for Detection Human Falling From Accelerometer Signal Using Wavelet Transform and Neural Network**,"2015 7th International Conference on Information Technology and Electrical Engineering (ICITEE), pp. 215-220 Oct. 2015



ICITEE2015

The 7th International Conference on
 Information Technology and Electrical Engineering

PROGRAM AND ABSTRACT BOOK

"Envisioning the Trend of Computer,
 Information and Engineering"



Le Méridien Chiang Mai Hotel, Thailand
 29-30 October 2015



Organized by
 Faculty of Information Technology
 King Mongkut's Institute of Technology Ladkrabang, THAILAND



Co-organized by
 Department of Electrical Engineering and Information Technology
 Universitas Gadjah Mada, INDONESIA

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

A Novel Algorithm for Detection Human Falling From Accelerometer Signal Using Wavelet Transform and Neural Network

Mr. Nitipat Nuttitanakul
Faculty of Engineering
King Mongkut's Institute of Technology Ladkrabang
Ladkrabang, Bangkok, Thailand 10520
s5612714@kmitl.ac.th

Dr. Thursak Leauhatong
Faculty of Engineering
King Mongkut's Institute of Technology Ladkrabang
Ladkrabang, Bangkok, Thailand 10520
klthurds@kmitl.ac.th

Abstract – Falls are major problems that could have happened to elderly, and could cause paralysis, hip fractures, or could lead to disabilities or accidental deaths. An algorithm for accurately detecting the falls is necessary in order to decrease the rate of disabilities or accidental deaths. In this paper, a new algorithm to detect the falls from the acceleration signal using the wavelet transform and multilayer perceptron neural network is proposed. In our experiments, 5 volunteers who were healthy with the ages between 21 to 25 year old were asked to attach a tri-axial accelerometer at the right side of their waists. The orientation of the accelerometer was vertical direction. Next, the volunteers were asked to perform 5 daily-life activities: 1) walking 2) standing up from a chair 3) sitting down on a chair 4) lying down on a bed and 5) getting up from a bed; and 5 falling activities: 1) falling forward 2) falling backward 3) falling to the right side 4) falling to the left side and 5) falling while standing up. The experimental results of the human activity classification that the proposed algorithm gave the maximum precision value (0.856). Moreover, it can be seen from the experiments of the falling detection that the proposed algorithm gave the maximum precision value (1.000).

Keyword – falls; falling detection; wavelet transform; neural network;

I. INTRODUCTION

Falls in elderly people may be caused from poor health, bone or muscle declining function, balance problem, vision problem, environmental hazard and so on. Moreover, the falls are more likely to result in hip fractures or cerebral hemorrhage that can increase the risk of disabilities or accidental deaths [1]. In USA from 1999 to 2010, the elderly mortality due to fall-related injury was reached up to 186,029 [2].

In order to decrease the rate of disabilities or accidental deaths, it is necessary to develop an accurate fall detection system. From our lateral reviews, there are 4 types of sensors that were used in the fall detection systems; 1) microphones, 2) cameras, 3) vibration sensor, and 4) wearable sensors. The advantages and disadvantages of these sensors can be mentioned as follows.

In 2010, Li et al. [3] used circular microphone array to capture the motion sounds and the Mel Frequency Cepstral Coefficient were used to recognize the fall evidences. Their experiments showed that the system could separate the falls from false alarm effectively. However, more realistic experiments such as fall in presence of noise are real

challenges. In 2012, Krekovic et al. [4] used a single camera to capture human motion and body orientation images for falls detection. Their experiments showed an efficiency of 90% that the system could classify falls from other activities. Unfortunately, they found that it had space and color limitations that had been configured before used their system. In 2009, Zigel et al. [5] used floor vibrations and sound to classify human's fall on the floor. Their experiments showed that the sensitivity and specificity of system were 97.5% and 98.6% respectively. Nevertheless, the system could not detect the falls, if the falls were not hard enough. In 2011, Jacob et al. [6] used accelerometer and 2 gyroscopes on three different positions and a multi-thresholds algorithm was used to detect the falls. The experiments showed that the effectiveness could be increased, if more threshold values were used. However, it was difficult to find the appropriate threshold values. Recently, Sengto and Leauhatong [7] used the back propagation neural network to detect the falls from signals of a tri-axial accelerometer which was attached at the waist of the subjects. The experimental results showed that the proposed algorithm can potentially distinguish the falling activities from the other daily-life activities.

In this paper, we propose a novel algorithm to detect the falls from signal of a tri-axial accelerometer. The algorithm consists of 3 steps; 1) signal acquisition, 2) wavelet transform, and 3) activity classification. Firstly our signal acquisition device consists of a tri-axial accelerometer and a microcontroller. The wavelet transform is used to extract feature from the acceleration signals. Then the multi-layer perceptron neural network is used to classify the activity of the signals. The organization of the paper is following. In section II, the fundamental theories of the wavelet transform and the multi-layer perceptron neural network. Section III presents the proposed algorithm. The experiment are given in section IV. Finally, conclusions and future work are discussed in section V.

II. FUNDAMENTAL THEORY

A. Wavelet Transform Theory

In the wavelet transform theory, a signal can be constructed from its approximation and details as follows [8]:

$$x(t) = \sum_{k=0}^{2^j-1} a_{t,k} 2^{-\frac{j}{2}} \phi(2^{-j}t-k) + \sum_{j=1}^L \sum_{k=0}^{2^j-1} d_{t,k} 2^{-\frac{j}{2}} \psi(2^{-j}t-k), \quad (1)$$

where ϕ and ψ are scaling and wavelet functions respectively. a and d are approximate and detailed coefficients of ϕ and ψ functions respectively. j and k are integer values which represent dilation and translation parameters of the transform. a and d coefficients can be calculated as follows:

$$a_{j,k} = \langle x(t), \phi_{j,k}(t) \rangle = \sum_n h(n-2k) a_{j-1,n}, \quad (2)$$

$$d_{j,k} = \langle x(t), \psi_{j,k}(t) \rangle = \sum_n g(n-2k) a_{j-1,n}, \quad (3)$$

where $h(n)$ is the low-pass filter of scaling function, and $g(n)$ is the high-pass filter of wavelet function. These filters are constructed from the selected wavelet function and its corresponding scaling function as follows:

$$\phi_{j,k}(t) = \sqrt{2} \sum_n h(n) \phi(2t-n), \quad (4)$$

$$\psi_{j,k}(t) = \sqrt{2} \sum_n g(n) \phi(2t-n). \quad (5)$$

B. Feature Extraction Using Wavelet Transform

Wavelet transform is a common and effectively mathematical tool for extracting signal features [9, 10, 11, and 12]. In feature extraction, the regularity of wavelet and the number of vanishing moment are important properties. The regularity is the number of continuous derivatives which indicates how smooth the wavelet is. The localization capability of the wavelet in the frequency domain is directly related to the regularity such that the larger the regularity, the sharper the Fourier transform of the wavelet in the frequency domain. The number of vanishing moments relates to the order of function that can be approximated by corresponding wavelet. For the analysis of highly transient signals with high complexity, wavelets with more vanishing moments are more suitable as they result in a more compact representation of the signals. As a result to obtain efficient features, both of the regularity and the number of vanishing moments of the used wavelet function should be large.

In this paper, the Daubechies wavelets are used to extract the features from the acceleration signals. The number of vanishing moments of the Daubechies wavelets equals to $N/2$, where N is the filter length. In [11, and 13], Daubechies proved that the order of regularity increases linearly with the support width. Then increasing the support width leads to increasing both of the regularity and the number of vanishing moment.

C. Multi-layer Perceptron Neural Network And Back Propagation Algorithm

A neural network is a mathematical system which models a biological neural network by interconnecting several

neurons. The fundamental component of the network is a neuron as shown in Fig. 1. x_1, \dots, x_n are inputs of the neuron, w_{ij} is a weight between the i^{th} input and the j^{th} neuron, and $f(\cdot)$ is an activation function of the neuron. The value of the j^{th} neuron, y_j , can be computed as follows:

$$y_j = f\left(\sum_{i=1}^n x_i w_{ij}\right). \quad (6)$$




Fig. 1. The fundamental component of the network

A Multi-Layer Perceptron (MLP) neural network is a very popular neural network for classification problems. Fig. 2 shows an example of 2-layer perceptron neural network. Let y_h be the values of the h^{th} neuron in the hidden layer, and z_o be the values of the o^{th} neuron in the output layer. y_h and z_o can be computed as follows:

$$y_h = f\left(\sum_{i=1}^I x_i v_{ih}\right), \quad (7)$$

$$z_o = f\left(\sum_{h=1}^H y_h w_{ho}\right), \quad (8)$$

where I is the number of the inputs of the network, and x_i is the i^{th} input of the network. y_h is the h^{th} output of the hidden layer, and v_{ih} is the weight between x_i and y_h . z_o is the o^{th} output of the output layer, and w_{ho} is the weight between y_h and z_o .




Fig. 2. Multi-layer neural network structure

All of the MLP neural networks use some forms of learning rules to modify their weights. A Back Propagation (BP) algorithm is one of the most popular learning rule [7, 13, and 14]. In the BP algorithm, the weights of the network can be iteratively modified as follows:

$$w_{ho}^{new} = w_{ho}^{old} + \eta \sum \delta_o y_h + \alpha \Delta w_{ho}^{old}, \quad (9)$$

$$\delta_o = z_o (1 - z_o) (b_o - z_o), \quad (10)$$

$$v_{th}^{new} = v_{th}^{old} + \eta \sum \delta_h x_i + \alpha \Delta v_{th}^{old}, \quad (11)$$

$$\delta_h = y_h (1 - y_h) \sum_{k=1}^O w_{ho} \delta_o, \quad (12)$$

where w_{ho}^{new} and w_{ho}^{old} are the new and old weight values respectively, and v_{th}^{new} and v_{th}^{old} are the new and old weight values respectively. δ_o is the error signal between output and hidden layer, and δ_h is the error signal between hidden and input layer. η is the learning rate parameter. α is the momentum factor. Let b_o be the desired value of the o^{th} neuron of output layer. The total error of the network, E , can be computed as follows:

$$E_o = \frac{1}{2} \sum_{o=1}^O (b_o - z_o)^2. \quad (13)$$

III. THE PROPOSED ALGORITHM

The proposed algorithm consists of 3 steps: 1) signal acquisition, 2) wavelet transform, and 3) activity classification. The block diagram of the proposed algorithm is shown in Fig. 3. The details of each step are explained as follows.



Fig. 3. Block diagram of the proposed algorithm.

A. Signal Acquisition

Our signal acquisition device consists of a tri-axial accelerometer (MMA7331L) and a microcontroller (PIC32MX460F512L) with a 10-bit analog-to-digital converter. The acquisition device is attached to the right side of the waist of the volunteer subjects, and the orientation of the three axes is arranged as shown in Fig. 4.

From our observations, the frequency range of signals of all human activities that are measured from the three axes of the accelerometer are from 4 to 100 Hz. As a result, the sampling rate of X-, Y-, and Z-axis signals are set to 200 Hz. According

to the experiments of Sengto and Leauhatong [7], a full-scaled affection of the accelerometer is set to $\pm 4G$ (where G represents acceleration due to gravity: 9.81 m/s^2).




Fig. 4. The orientation of the three axes of the accelerometer

From our observations, all of the falling signals can be separated into three parts. The first part is the acceleration signal of some activities that cause the fall such as slip, stumble, sway, and etc. Usually, this part takes one second. The second part is the acceleration signal that is occurred when some parts of body, such as hand, hip, knee, or head, impact the ground. Since the impacts usually cause rapid change of the acceleration of the body, most of the impact signals have one or two peaks in 100-200 milliseconds. The third part is the signal of some activities that occur after the impact such as roll or bounce of the body. This part usually takes less than one second. Then we assume that most of the falling activities take 2 seconds.

Since the sampling rate of the acquisition device is 200 Hz, the acceleration signals were sampled 216 samples before the first peak and 200 samples after the first peak. Fig. 5 shows an example of the acceleration signals of X-, Y-, and Z- axes of a forward falling.




Fig. 5. An example of the acceleration signals of X-, Y-, and Z-axes of a forward falling.

B. Wavelet Transform

The Daubechies wavelet is used to decompose the acceleration signals into j levels. Fig. 6 shows an example of 3-level wavelet transform using Mallat's algorithm [15]. Fig. 7, 8, and 9 showed details (d_1, d_2 , and d_3) and approximation (a_3) decomposition of the X-, Y-, and Z-axis acceleration signals from Fig. 5 respectively.




Fig. 6. Mallat's algorithm.




Fig. 7. 3 level decomposition using Daubechies2 wavelet of forward falling signal X axis




Fig. 8. 3 level decomposition using Daubechies2 wavelet of forward falling signal Y axis




Fig. 9. 3 level decomposition using Daubechies2 wavelet of forward falling signal Z axis

C. Activity Classification

The MLP neural network is used to classify the activities of the decomposition signals. The neural network consists of 3 layers, input, hidden, and output layers. The activation function used by the neurons of the hidden and output layers are the log sigmoidal, $f(x) = 1/(1 + \exp(-x))$. The values of the input layer are d_1, d_2, d_3 , and a_3 coefficients. The number of the neurons in the hidden layer is defined by experiments (see in Section IV). The number of the neurons in the output layer equals to the number of classified activities. Then the value of the o^{th} neuron of the output layer, z_o , should be 1, if the acceleration signal belong to the o^{th} activity. The value equals to 0, if otherwise.

IV. EXPERIMENT.

In our experiments, 5 volunteers who were healthy with the ages between 21 to 25 year old were asked to attach our acquisition device at the right side of their waists as shown in

Fig. 4. Next in order to measure the human activity signals, all of the volunteers were asked to perform 5 daily-life activities: 1) walking 2) standing up from a chair 3) sitting down on a chair 4) lying down on a bed and 5) getting up from a bed; and 5 falling activities: 1) falling forward 2) falling backward 3) falling to the right side 4) falling to the left side and 5) falling while standing up. Each volunteer was asked to perform each activity 30 times. Then the total number of the acceleration signals of each activity is 150 times.

1.) Performance Evaluation

In order to evaluate the performance of the proposed algorithm, the precision (Pr) [16] is used. The precision can be calculated as follows:

$$\text{Pr}(c) = \frac{TP}{TP + FP}, \quad (14)$$

where c refers to the evaluated activity. The number of true positives (TP) is the number of the acceleration signals of the c activity that were correctly classified to belong to the c activity. The number of false positives (FP) is the number of the acceleration signals of the other activities that were incorrectly classified to belong to the c activity.

The average precision ($\overline{\text{Pr}}$) of all activities can be calculated as follows:

$$\overline{\text{Pr}} = \frac{\sum_{i=C}^c \text{Pr}(c_i)}{C}, \quad (15)$$

where c_i refers to the i^{th} activity, and C is the total number of the activities. As a result, $\overline{\text{Pr}}$ is probability that the proposed algorithm can classify the activities of the acceleration signals correctly.

The performance of the proposed algorithm depends on its 4 factors: 1) the axis of the acceleration signals, 2) the filter length of the Daubechies wavelet (see explanation in Sec 2.B), 3) the number of level of wavelet decomposition, and 4) the number of neurons in the hidden layer. In order to optimize the performance, the average precisions of the algorithm which has different setting of the factors must be compared. Table 1. shows all of the selected setting of the factors used in this paper.

TABLE I. THE SELECTED SETTING OF THE FACTORS

Factors	Selected Setting
Axes	X-axis, Y-axis, Z-axis, and XYZ-axis
Filter length	4, 8, 12, 16, 20, 24, 28, 32, 36, and 40
Decomposition level	1, 2, and 3
Neuron in hidden layer	1, 2, 3, ..., 40

REFERENCES

- [1] Noury, N., "A smart sensor for the remote follow up of activity and fall detection of the elderly," *Microtechnologies in Medicine & Biology 2nd Annual International IEEE-FMB Special Topic Conference on*, pp. 314-317, 2-4 May 2002.
- [2] Centers for Disease Control and Prevention, National Center for Injury Prevention and Control, 2013. Web-based Injury Statistics Query and Reporting System (WISQARS). Available at: <http://webappa.cdc.gov/> [Accessed March 4, 2013].
- [3] Yun Li, Zhiling Zeng ; Popescu, M. ; Ho, K.C., "Acoustic fall detection using a circular microphone array," *Engineering in Medicine and Biology Society (EMBC), 2010 Annual International Conference of the IEEE*, pp. 2242-2245, Aug. 31 2010-Sept. 4 2010
- [4] Krekovic, M. Ceric, P. ; Dominko, T. ; Hijas, M. ; Ivancic, K. ; Skolan, V. ; Sarlija, J., "A method for real-time detection of human fall from video," *MIPRO, 2012 Proceedings of the 35th International Convention*, pp. 1709-1712, 21-25 May 2012.
- [5] Zigel, Y., Litvak, D. ; Gannot, Israel, "A Method for Automatic Fall Detection of Elderly People Using Floor Vibrations and Sound—Proof of Concept on Human Mimicking Doll Falls," *Biomedical Engineering, IEEE Transactions on*, vol. 56, pp. 2858-2867, December 2009
- [6] Jacob, J.; Tam Nguyen ; Lie, D.Y.C. ; Zupancic, S. ; Bishara, J. ; Dentino, A. ; Banister, R.E. "A fall detection study on the sensors placement location and a rule-based multi-thresholds algorithm using both accelerometer and gyroscopes" *Fuzzy Systems (FUZZ)*, 2011 IEEE International Conference on, pp. 666-671, 27-30 June 2011
- [7] Sengto, A.; Leauhatong, T.; "Human falling detection algorithm using back propagation neural network," *Biomedical Engineering International Conference (BMEICON), 2012*, pp 1-5, 5-7 Dec. 2012
- [8] Kim, J.; "Discrete Wavelet Transform-based Feature Extraction of Experiment Voltage Signal for Li-Ion Cells Consistency" *Vehicular Technology, IEEE Transactions on (Volume:PP, Issue: 99)*, 27 April 2015
- [9] A. Phinyomark, C. Limsakul, P. Phukpattaranont, "Application of Wavelet Analysis in EMG Feature Extraction for Pattern Classification" *MEASUREMENT SCIENCE REVIEW*, Volume 11, No. 2, 2011
- [10] Salem, M.A.-M., "On the selection of the proper wavelet for moving object detection" *Computer Engineering & Systems (ICCES), 2011 International Conference on*, pp. 207-212, Nov. 29 2011-Dec. 1 2011
- [11] S. Patilkulkarni, PhD, Li: H C Vijay Lakshmi., "Vanishing Moments of a Wavelet System and Feature Set in Face Detection Problem for Color Images" *International Journal of Computer Applications (0975 – 8887)*, Volume 66– No.16, March 2013
- [12] Prochazka, A.; Kukul, J. ; Vysata, O., "Wavelet transform use for feature extraction and EEG signal segments classification" *Communications, Control and Signal Processing, 2008. ISCCSP 2008. 3rd International Symposium on*, pp. 719-722, 12-14 March 2008
- [13] Ankara, Turkey: "Leg Motion Classification with Artificial Neural Networks Using Wavelet-Based Features of Gyroscope Signals" *Sensors* 2011, 11, 1721-1743; doi:10.3390/s110201721
- [14] P.S. Bhowmik, P. Purkait, K. Bhattacharya.; "A novel wavelet transform aided neural network based transmission line fault analysis method" *Electrical Power and Energy Systems* 31 (2009) 213–219
- [15] Mallat, S.G. "A theory for multiresolution signal decomposition: the wavelet representation" *Pattern Analysis and Machine Intelligence, IEEE Transactions on (Volume:11, Issue: 7)*, pp. 674-693, Jul 1989
- [16] Nakaram, P.; Leauhatong, T.: "A New Content-Based Medical Image Retrieval System Based on Wavelet Transform and Multidimensional Wald-Wolfowitz Runs Test" *Biomedical Engineering International Conference (BMEICON), 2012*, pp. 1-8, 5-7 Dec. 2012

ประวัติผู้เขียน

ชื่อ-นามสกุล นายนิติพัฒน์ ธีฐ์ไทรนกุล
วัน เดือน ปีเกิด 9 กันยายน 2532 ที่กรุงเทพมหานคร
ที่อยู่ 724 ซ.ม.พุดตาน ถ.มาเจริญ แขวงหนองแขม เขตหนองแขม กรุงเทพมหานคร 10160
ประวัติการศึกษา ปี พ.ศ 2554 จบการศึกษาวិชาการกรรมศาสตรบัณฑิต สาขาวิชา อิเล็กทรอนิกส์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้