



รายงานการวิจัยฉบับสมบูรณ์

ระบบแจ้งเตือนการล้มของผู้สูงอายุผ่านโทรศัพท์เคลื่อนที่

A Human Falling Alert for Elderly People by Using Mobile Telephone

นายเทอดศักดิ์ ลีหาทอง

RCH
ก 6682
2555

12708446

เลขที่บัญชี 138148
วันที่ 18 ก.ย. 2558

ได้รับทุนสนับสนุนงานวิจัยจากเงินรายได้คณะวิศวกรรมศาสตร์ ประจำปีงบประมาณ

2555

คณะวิศวกรรมศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รายงานการวิจัยฉบับสมบูรณ์

ระบบแจ้งเตือนการล้มของผู้สูงอายุผ่านโทรศัพท์เคลื่อนที่

A Human Falling Alert for Elderly People by Using Mobile Telephone

นายเทอดศักดิ์ ลีหาทอง

ได้รับทุนสนับสนุนงานวิจัยจากเงินรายได้คณะวิศวกรรมศาสตร์ ประจำปีงบประมาณ

2555

คณะวิศวกรรมศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ชื่อโครงการ (ภาษาไทย) ระบบแจ้งเตือนการล้มของผู้สูงอายุผ่านโทรศัพท์เคลื่อนที่
 แหล่งเงิน เงินรายได้คณะวิศวกรรมศาสตร์
 ประจำปีงบประมาณ 2555 จำนวนเงินที่ได้รับการสนับสนุน 200,000 บาท
 ระยะเวลาทำการวิจัย 1 ปี ตั้งแต่ 1 ตุลาคม 2554 ถึง 30 กันยายน 2555
 ชื่อ-สกุล หัวหน้าโครงการ และผู้ร่วมโครงการวิจัย พร้อมระบุ หน่วยงานต้นสังกัด
 นายเทอดศักดิ์ ลีวหาทอง

บทคัดย่อ

ปัจจุบันจำนวนผู้สูงอายุในประเทศไทยมีจำนวนเพิ่มขึ้นอย่างต่อเนื่อง และมีการคาดการณ์ว่าจะเข้าสู่สังคมผู้สูงอายุอย่างสมบูรณ์ภายในปี 2570 การล้มเป็นปัญหาสำคัญของผู้สูงอายุ ร้อยละ 30 ของผู้สูงอายุที่มีอายุมากกว่า 65 ปีขึ้นไปมีโอกาสที่จะหกล้มทุกปี จากการศึกษาพบว่าร้อยละ 80 ของการเกิดอุบัติเหตุและร้อยละ 62 ของการเข้ารับการรักษาบาดแผลมาจากการหกล้ม และการตายเนื่องจากการหกล้มมีมากเป็น 2 เท่าของการเกิดอุบัติเหตุบนท้องถนน โครงการวิจัยเป็นการสร้างระบบเตือนการหกล้มของผู้สูงอายุไปยังโรงพยาบาลและญาติที่ใกล้ชิด เพื่อให้ผู้สูงอายุได้รับการรักษาได้อย่างรวดเร็ว ทำให้ลดอัตราการสูญเสียชีวิตหรือพิการให้น้อยลง ระบบแจ้งเตือนการล้มประกอบด้วยเครื่องวัดสัญญาณการเคลื่อนไหวเพื่อใช้ตรวจจับการหกล้มของผู้สูงอายุ Web Application สำหรับรับการแจ้งเตือนการล้ม และโปรแกรมเพื่อให้นำทางรถพยาบาลไปรับผู้สูงอายุ จากการทดลองพบว่าเครื่องวัดสัญญาณการเคลื่อนไหวสามารถตรวจจับการหกล้มได้อย่างมีประสิทธิภาพ ภาพ Web Application สามารถทำงานร่วมกับเครื่องวัดสัญญาณการเคลื่อนไหวเพื่อแจ้งเตือนการล้มได้อย่างถูกต้อง และโปรแกรมนำทางรถพยาบาลสามารถแสดงแผนที่ที่ให้นำทางรถพยาบาลไปรับผู้สูงอายุได้

คำสำคัญ : การตรวจจับการล้มของมนุษย์ เครื่องข่ายประสาทเทียมแบบแพร่ย้อนกลับ

Research Title: A Human Falling Alert for Elderly People by Using Mobile Telephone

Researcher: Mr. Thurdsak Leauhatong

Faculty: Engineering **Department:** Electronics

ABSTRACT

Nowadays, the amount of elderly people in Thailand has been increasing and is anticipated that Thailand will be elderly society in 2027. Falling is the major problem of elderly people. The 30 percent of elderly people who are older than 65 fall every year. From clinical studies, 80 percent of accidents and 62 percent of injury treatments are from falling. Moreover, deaths from falling are double of deaths from car accidents. This research project develops a system to alert human falling in elderly people to hospital and their families. As a result, the elderly people can be cured quickly in order to reduce the rate of deaths or disabled. The system consists of a movement measurement machine which detects the falling of the elderly people, Web application which is used to alert the falling, and a navigation program which can guide an ambulance to get the elderly people. From the experiments, the measurement machine can effectively detect the falling, the Web application can cooperate with the measurement machine to alert the falling, and the navigation program can show the map to guide the ambulance.

Keywords : Human Falling Detection, Back Propagation Neural Network

กิตติกรรมประกาศ

งานวิจัยฉบับนี้สำเร็จลุล่วงไปด้วยดีเนื่องจากผู้วิจัยได้รับความช่วยเหลือ นักศึกษาด้านวิชา
วิศวกรรมอิเล็กทรอนิกส์ ที่ได้ให้ความร่วมมือในการดำเนินการทดลอง

นอกจากนี้ผู้วิจัยยังได้รับกำลังใจจากคุณพ่อ คุณแม่ และเพื่อนๆ ตลอดจนบุคคลต่างๆที่ให้กำลังใจ
และความช่วยเหลืออีกมาก ที่ผู้วิจัยไม่สามารถกล่าวนามได้หมดในที่นี้ ผู้วิจัยรู้สึกซาบซึ้งในความ
กรุณาและความปรารถนาดีของทุกท่านเป็นอย่างยิ่ง จึงกราบขอบพระคุณและขอบคุณไว้ใน โอกาสนี้

การวิจัยครั้งนี้ได้รับทุนสนับสนุนการวิจัยจากสถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหาร
ลาดกระบัง จากแหล่งทุน งบประมาณแผ่นดิน ตามมติคณะรัฐมนตรี ประจำปีงบประมาณ พ.ศ. 2555

เทอดศักดิ์ ลีวาทอง



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	I
บทคัดย่อภาษาอังกฤษ.....	II
กิตติกรรมประกาศ.....	III
สารบัญ.....	IV
สารบัญตาราง.....	VIII
สารบัญภาพ.....	IX
บทที่ 1 บทนำ	1
1.1 ความมุ่งหมายและวัตถุประสงค์ของ โครงการวิจัย.....	1
1.2 สมมุติฐานในการออกแบบขั้นตอนการตรวจจัดการหกล้ม.....	2
1.3 ทฤษฎีหรือแนวความคิดที่ใช้ในการวิจัย.....	2
บทที่ 2 งานวิจัยที่เกี่ยวข้อง	4
2.1 อุปกรณ์สำหรับการตรวจจัดการหกล้มสำหรับมนุษย์และการติดตั้ง.....	4
2.1.1 งานวิจัยที่นำเสนอตัวตรวจจับความเร่งอย่างเดียว.....	5
2.1.2 งานวิจัยที่นำเสนอตัวตรวจจับความเร่งร่วมกับตัวตรวจจับชนิดอื่น ๆ.....	6
2.1.3 งานวิจัยที่นำเสนออุปกรณ์ตรวจจัดการหกล้ม โดยการไม่ใช้ตัวตรวจจับ ความเร่ง.....	8
2.2 อัลกอริทึมสำหรับการตรวจจัดการหกล้มสำหรับมนุษย์.....	8
บทที่ 3 โครงข่ายประสาทเทียม	15
3.1 โครงข่ายประสาทชีวภาพ (Biological Neural Network).....	15
3.2 โครงข่ายประสาทเทียม (Artificial Neural Network).....	20
3.3 โครงข่ายประสาทเทียมอย่างง่าย (Perceptron).....	22
3.4 โครงข่ายประสาทเทียมแบบหลายชั้น (Multi-layer Perceptron).....	30
3.5 โครงสร้างของโครงข่ายประสาทเทียมที่นำเสนอในงานวิจัย.....	32
3.6 การฝึกสอนและการเรียนรู้ของโครงข่ายประสาทเทียม.....	34
3.6.1 การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning).....	34
3.6.2 การเรียนรู้แบบมีผู้สอน (Supervised Learning).....	37

สารบัญ (ต่อ)

	หน้า
3.6.2.1 การเรียนรู้แบบ Gradient Descent.....	38
3.6.2.2 การเรียนรู้แบบ Gradient Descent with Momentum.....	39
3.6.2.3 การเรียนรู้แบบ Variable Learning Rate.....	40
3.6.2.4 การเรียนรู้แบบ Resilient.....	41
3.6.2.5 การเรียนรู้แบบ Fletcher- Reeve Conjugate Gradient.....	42
3.6.2.6 การเรียนรู้แบบ Polak-Ribière Conjugate Gradient.....	43
3.6.2.7 การเรียนรู้แบบ Scaled Conjugate Gradient.....	44
3.6.2.8 การเรียนรู้แบบ Conjugate Gradient with Powell/Beale Restarts.....	44
3.6.2.9 การเรียนรู้แบบ BFGS quasi-Newton.....	45
3.6.2.10 การเรียนรู้แบบ One-Step Secant.....	45
3.6.2.11 การเรียนรู้แบบ Levenberg-Marquardt.....	45
บทที่ 4 ระบบการตรวจจับการหลต้ม	48
4.1 ระบบตรวจวัดสัญญาณการเคลื่อนไหว.....	48
4.1.1 ตัวตรวจจับความเร่ง.....	49
4.1.2 ไมโครคอนโทรลเลอร์.....	51
4.1.3 สื่อจัดเก็บข้อมูล (SD Card).....	52
4.1.4 แบตเตอรี่.....	53
4.2 การหาลักษณะเด่นของสัญญาณการเคลื่อนไหว.....	53
4.3 อัลกอริทึมสำหรับการตรวจจับสัญญาณการหลต้ม.....	62
4.3.1 สัญญาณขาเข้า (Input).....	63
4.3.2 การตรวจจับสัญญาณการเคลื่อนไหวแบบจับปล้น และหลต้ม.....	64
4.3.3 การตัดสัญญาณ.....	64
4.3.4 การตรวจจับการหลต้มด้วยวิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ.....	66
บทที่ 5 การทดลอง	69
5.1 การเตรียมข้อมูลสัญญาณการเคลื่อนไหวประเภทต่างๆ.....	69
5.2 ผลการทดลองการตรวจจับสัญญาณการหลต้ม.....	75
5.2.1 ผลการทดลองการตรวจจับสัญญาณการหลต้มด้วยวิธีการกำหนด.....	77

สารบัญ (ต่อ)

	หน้า
5.2.2 ผลการทดลองการตรวจจับการหกล้มด้วยอัลกอริทึมที่นำเสนอ.....	78
5.2.2.1 ผลการทดลองการตรวจจับการหกล้มด้วยอัลกอริทึม ที่นำเสนอกับการเรียนรู้แบบ Gradient Descent (GD)	78
5.2.2.2 ผลการทดลองการตรวจจับการหกล้มด้วยอัลกอริทึม ที่นำเสนอกับการเรียนรู้ Gradient Descent with Momentum (GDM)	79
5.2.2.3 ผลการทดลองการตรวจจับการหกล้มด้วยอัลกอริทึม ที่นำเสนอกับการเรียนรู้ Variable Learning Rate (GDA)	80
5.2.2.4 ผลการทดลองการตรวจจับการหกล้มด้วยอัลกอริทึม ที่นำเสนอกับการเรียนรู้ Variable Learning Rate with Momentum (GDX)	81
5.2.2.5 ผลการทดลองการตรวจจับการหกล้มด้วยอัลกอริทึม ที่นำเสนอกับการเรียนรู้ Resilient (RP)	82
5.2.2.6 ผลการทดลองการตรวจจับการหกล้มด้วยอัลกอริทึม ที่นำเสนอกับการเรียนรู้ Fletcher-Reeve Conjugate Gradient (CGF)	83
5.2.2.7 ผลการทดลองการตรวจจับการหกล้มด้วยอัลกอริทึม ที่นำเสนอกับการเรียนรู้ Polak-Ribière Conjugate Gradient (CGP)	84
5.2.2.8 ผลการทดลองการตรวจจับการหกล้มด้วยอัลกอริทึม ที่นำเสนอกับการเรียนรู้ Conjugate Gradient with Powell/Beale Restarts (CGB)	85
5.2.2.9 ผลการทดลองการตรวจจับการหกล้มด้วยอัลกอริทึม ที่นำเสนอกับการเรียนรู้ Scaled Conjugate Gradient (SCG)	86
5.2.2.10 ผลการทดลองการตรวจจับการหกล้มด้วยอัลกอริทึม ที่นำเสนอกับการเรียนรู้ One-Step Secant (OSS)	87
5.2.2.11 ผลการทดลองการตรวจจับการหกล้มด้วยอัลกอริทึม ที่นำเสนอกับการเรียนรู้แบบ Variable Learning Rate with Momentum (GDX) เมื่อปรับเปลี่ยนค่าขีดเริ่ม	88
5.3 วิเคราะห์ผลการทดลอง.....	89
บทที่ 6 สรุปผลการทดลอง.....	93

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ (ต่อ)

	หน้า
บทที่ 7 Web Application แจ้างเดือนการลัม.....	97
บทที่ 8 โปรแกรมนำทางรถพยาบาล.....	101
เอกสารอ้างอิง.....	102
ประวัติคณะผู้วิจัย.....	104



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญตาราง

ตารางที่	หน้า
4.1 รายละเอียดของ โครงสร้างภายในสำหรับตัวตรวจจับความเร่ง (MMA7631).....	49
4.2 ย่านของการวัดตัวตรวจจับความเร่ง (MMA7631).....	50
4.3 การกำหนดค่าตัวเลขของเซลล์ประสาทเทียมขาออก (Output Neuron).....	67
5.1 รายละเอียดของการจำลองกิจกรรมต่างๆ.....	72
5.2 ผลการทดลองการตรวจจับสัญญาณการหกล้มด้วยวิธีการกำหนดค่าขีดเริ่ม.....	77
5.3 ผลการทดลองตรวจจับการหกล้มด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้ Gradient Descent.....	78
5.4 ผลการทดลองตรวจจับการหกล้มด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้ Gradient Descent with Momentum.....	79
5.5 ผลการทดลองตรวจจับการหกล้มด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้ Variable Learning Rate.....	80
5.6 ผลการทดลองตรวจจับการหกล้มด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้ Variable Learning Rate with Momentum.....	81
5.7 ผลการทดลองตรวจจับการหกล้มด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้ Resilient.....	82
5.8 ผลการทดลองตรวจจับการหกล้มด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้ Fletcher-Reeve conjugate Gradient.....	83
5.9 ผลการทดลองตรวจจับการหกล้มด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้ Polak-Ribière Conjugate Gradient.....	84
5.10 ผลการทดลองตรวจจับการหกล้มด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้ Conjugate Gradient with Powell/Beale Restarts.....	85
5.11 ผลการทดลองตรวจจับการหกล้มด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้ Scaled Conjugate Gradient.....	86
5.12 ผลการทดลองตรวจจับการหกล้มด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้ One-Step Secant.....	87
5.13 ผลการทดลองตรวจจับการหกล้มด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้ Variable Learning Rate with Momentum (GDX) เมื่อปรับเปลี่ยนค่าขีดเริ่ม.....	88

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญตาราง (ต่อ)

ตารางที่	หน้า
5.14 แสดงผลการทดลองเชิงเปรียบเทียบ.....	92
7.1 ฐานข้อมูลของแพทย์ผู้ดูแลผู้สูงอายุ.....	98
7.2 ฐานข้อมูลของผู้สูงอายุ.....	99



สารบัญภาพ

ภาพที่	หน้า
2.1 ระบบควบคุมดูแลการเคลื่อนไหวประเภทหกล้มของผู้สูงอายุ [3].....	4
2.2 การติดตั้งอุปกรณ์สำหรับการตรวจจับการหกล้ม [7].....	6
2.3 อุปกรณ์สำหรับการตรวจจับสัญญาณการเคลื่อนไหว [2].....	7
2.4 อุปกรณ์สำหรับการตรวจจับการหกล้ม [5].....	7
2.5 ตำแหน่งการวางของอุปกรณ์สำหรับการตรวจจับการหกล้ม [5].....	7
2.6 อุปกรณ์สำหรับการตรวจจับการหกล้ม [9].....	8
2.7 ตัวอย่างของสัญญาณการเคลื่อนไหวประเภทหกล้มของมนุษย์ [11].....	9
2.8 ตำแหน่งของการหกล้มแทนด้วย Θ และติกรอบสำหรับค่าผิดพลาดไว้ [11].....	9
2.9 ตัวอย่างการสัญญาณการหกล้มไปด้านขวา [4].....	11
2.10 โปรแกรมในการคำนวณคาบเวลาของการหกล้ม [4].....	12
2.11 เปรียบเทียบสัญญาณที่มาจากตัวตรวจจับความเร่งแบบสามแกน (เส้นสีน้ำเงิน) และการวิเคราะห์ด้วยการหาความเร็วในแนวแกนตั้ง (เส้นสีแดง) [8]	13
3.1 แผนผังของเซลล์ประสาทชีวภาพ [14].....	15
3.2 ปฏิกริยาของ Synapses บนกิ่งของ Dendrite [14].....	16
3.3 สัญญาณทางไฟฟ้าของระบบประสาท [14].....	17
3.4 แบบจำลองของ Sensory neurons, Motor neurons และ Interneurons [14].....	18
3.5 วงจรเชื่อมต่อสมอง (ของดักลาสและมาร์ตินปี 1990) [14].....	18
3.6 การพิจารณาค่าขีดเริ่มของการส่งสัญญาณทางไฟฟ้าในระบบประสาท.....	19
3.7 แผนผังแนวคิดของเซลล์ประสาทเทียม.....	20
3.8 แผนผังของเซลล์ประสาทชีวภาพและเซลล์ประสาทเทียม [14].....	22
3.9 ฟังก์ชันการถ่ายโอนแบบสองขั้ว.....	25
3.10 ฟังก์ชันถ่ายโอนแบบเชิงเส้น.....	26
3.11 ฟังก์ชันถ่ายโอนแบบลอคซิกมอยด์.....	26
3.12 ฟังก์ชันถ่ายโอนแบบแทนซิกมอยด์.....	27
3.13 ฟังก์ชันถ่ายโอนแบบเชิงเส้นจำกัด.....	27
3.14 การหาว่าความยาวของเวกเตอร์น้ำหนัก [14].....	28
3.15 การเรียนรู้แบบเพอร์เซพตรอนชั้นเดียว [14].....	29

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญภาพ (ต่อ)

ภาพที่	หน้า
3.16 ตัวแบบเพอร์เซพตรอนชั้นเดียว.....	30
3.17 โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN).....	31
3.18 โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN) โดยใช้ Winner-Take-All.....	34
3.19 โครงข่ายประสาทเทียมที่ใช้การเรียนรู้แบบ Oja และ Sanger [14].....	36
3.20 แสดงปัญหาจุดต่ำสุดเทียม (Local Minimum).....	39
4.1 แสดงถึงส่วนประกอบของระบบตรววัดสัญญาณการเคลื่อนไหว.....	48
4.2 โครงสร้างตัวตรวจจับความเร่งแบบสามแกน (ยี่ห้อ Freescale รุ่น MMA7361).....	49
4.3 วงจรของระบบตรววัดการเคลื่อนไหว.....	50
4.4 สัญญาณขาออกของตัวตรวจจับความเร่งแบบสามแกน.....	51
4.5 โครงสร้างของไมโครคอนโทรลเลอร์ยี่ห้อ Microchip รุ่น PIC24FJ128GB110.....	52
4.6 โครงสร้างของ SD Card.....	52
4.7 โครงสร้างของแบตเตอรี่.....	53
4.8 สัญญาณการเคลื่อนไหวประเภทการหกล้มไปด้านหลัง.....	54
4.9 สัญญาณการเคลื่อนไหวประเภทการหกล้มไปด้านหน้า.....	54
4.10 สัญญาณการเคลื่อนไหวประเภทการหกล้มไปข้างซ้าย.....	55
4.11 สัญญาณการเคลื่อนไหวประเภทการหกล้มไปข้างขวา.....	55
4.12 สัญญาณการเคลื่อนไหวประเภทการล้มตัวนอน.....	55
4.13 สัญญาณการเคลื่อนไหวประเภทการลุกจากเตียง.....	56
4.14 สัญญาณการเคลื่อนไหวประเภทการกระโดด.....	56
4.15 สัญญาณการเคลื่อนไหวประเภทการล้มระหว่างการลุกขึ้นยืน.....	56
4.16 ตัวอย่างสัญญาณการเคลื่อนไหวปกติและสัญญาณการเคลื่อนไหวที่ผิดปกติ.....	57
4.17 ความแตกต่างระหว่างสัญญาณแกนตั้ง (เส้นบาง) และสัญญาณผ่านกระบวนการตาม.....	58
สมการ (4.4) ของสัญญาณประเภทหกล้มไปด้านหลัง (เส้นหนา)	
4.18 ความแตกต่างระหว่างสัญญาณแกนตั้ง (เส้นบาง) และสัญญาณผ่านกระบวนการตาม.....	58
สมการ (4.4) ของสัญญาณประเภทหกล้มไปด้านหน้า (เส้นหนา)	
4.19 ความแตกต่างระหว่างสัญญาณแกนตั้ง (เส้นบาง) และสัญญาณผ่านกระบวนการตาม.....	59
สมการ (4.4) ของสัญญาณประเภทหกล้มไปข้างซ้าย (เส้นหนา)	

สารบัญภาพ (ต่อ)

ภาพที่	หน้า
4.20 ความแตกต่างระหว่างสัญญาณแกนตั้ง (เส้นบาง) และสัญญาณผ่านกระบวนการตาม สมการ (4.4) ของสัญญาณประเภทหกล้มไปข้างขวา (เส้นหนา)	59
4.21 ตัวอย่างสัญญาณการเคลื่อนไหวประเภทจับปล้น (การลุดจากที่เตียง)	61
4.22 ตัวอย่างสัญญาณการเคลื่อนไหวประเภทจับปล้น (การกระโดด)	61
4.23 ตัวอย่างสัญญาณการเคลื่อนไหวประเภทหกล้ม	61
4.24 อัลกอริทึมสำหรับการตรวจจับสัญญาณการหกล้ม	62
4.25 สัญญาณขาเข้า (Input)	63
4.26 อัลกอริทึมการตรวจจับสัญญาณการเคลื่อนไหวแบบจับปล้น และหกล้ม	64
4.27 โปรแกรมการตัดสัญญาณ	65
4.28 ตัวอย่างของชุดข้อมูลที่มีการตัดสัญญาณ (การเคลื่อนไหวประเภทจับปล้น)	66
4.29 ตัวอย่างของชุดข้อมูลที่มีการตัดสัญญาณ (การเคลื่อนไหวประเภทหกล้ม)	66
4.30 โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN) โดยใช้วิธีการคิดแบบ Winner-Take- All ที่ใช้ในการจดจำรูปแบบ	68
5.1 ตำแหน่งและทิศทางของการวางระบบตรวจจับสัญญาณการเคลื่อนไหว	69
5.2 ทิศทางของแกน x (แกนที่ตั้งฉากกับพื้นโลก)	70
5.3 ความสัมพันธ์ระหว่างมุมในการจัดวางระบบตรวจจับสัญญาณการเคลื่อนไหวและค่า แรงดันออกของตัวตรวจจับความเร่ง	71
5.4 ข้อมูลสัญญาณของการเคลื่อนไหวประเภทหกล้มไปด้านหลัง	72
5.5 ข้อมูลสัญญาณของการเคลื่อนไหวประเภทหกล้มไปด้านหน้า	73
5.6 ข้อมูลสัญญาณของการเคลื่อนไหวประเภทหกล้มไปด้านซ้าย	73
5.7 ข้อมูลสัญญาณของการเคลื่อนไหวประเภทหกล้มไปด้านขวา	73
5.8 ข้อมูลสัญญาณของการเคลื่อนไหวประเภทการล้มระหว่างการลุกขึ้นยืน	74
5.9 ข้อมูลสัญญาณของการเคลื่อนไหวประเภทลุดจากเตียง	74
5.10 ข้อมูลสัญญาณของการเคลื่อนไหวประเภทล้มตัวนอน	74
5.11 ข้อมูลสัญญาณของการเคลื่อนไหวประเภทการกระโดด	75
5.12 โครงสร้างของโครงข่ายประสาทเทียมสำหรับการทดลอง	76
5.13 แผนภูมิแสดงความถูกต้องในการประมวลผลด้วยวิธีการเรียนรู้ในรูปแบบต่างๆ	90

สารบัญญภาพ (ต่อ)

ภาพที่	หน้า
5.14 แผนภูมิแสดงจำนวนรอบในการประมวลผลด้วยวิธีการเรียนรู้ในรูปแบบต่างๆ.....	90
6.1 ประสิทธิภาพการทำงานของอัลกอริทึมการตรวจจับการหลัดด้วยอัลกอริทึมที่ นำเสนอกับการเรียนรู้แบบ Variable Learning Rate with Momentum (GDX)	95
6.2 ประสิทธิภาพการทำงานของอัลกอริทึมการตรวจจับการหลัดด้วยอัลกอริทึมที่ นำเสนอกับการเรียนรู้แบบ Variable Learning Rate with Momentum (GDX)	95
7.1 โมดูล SIM300CZ.....	97
7.2 โปรแกรมแจ้งเตือนการล้มของผู้สูงอายุ.....	100
8.1 โปรแกรมนำทางรถพยาบาล.....	101



บทที่ 1

บทนำ

จากรายงานของสหประชาชาติ [1] เกี่ยวกับสถานการณ์ของประชากรโลกพบว่า ในปี พ.ศ. 2554 ประชากรผู้สูงอายุที่มีอายุมากกว่า 60 ปีมีจำนวนร้อยละ 11.7 ของประชากรทั้งหมด และมีแนวโน้มเพิ่มขึ้นเป็นร้อยละ 20.2 ภายในปี 2593 จากการที่มีผู้สูงอายุจำนวนมากทำให้ปัญหาสุขภาพของผู้สูงอายุกลายเป็นปัญหาที่ต้องตระหนักเป็นพิเศษ โดยเฉพาะการหกล้มนับเป็นปัญหาอย่างหนึ่งที่ร้ายแรง และอันตรายมากที่สุด เนื่องจากการหกล้มส่งผลทำให้ผู้สูงอายุจำนวนมากต้องตกอยู่ในภาวะทุพพลภาพ หรือบางรายอาจถึงกับเสียชีวิต และในบางครั้งผู้สูงอายุที่เคยหกล้มมาก่อนจะยังมีความกลัวต่อการหกล้ม ทำให้ส่งผลต่อการกระทำกิจกรรมอื่นๆ หรือบางครั้งอาจไม่สามารถอยู่คนเดียวได้ ด้วยสาเหตุดังกล่าว จึงทำให้ระบบควบคุมดูแลผู้สูงอายุที่สามารถตรวจจับการหกล้มและแจ้งเตือนอย่างทันที่นั้นมีความจำเป็นอย่างยิ่งต่อการลดอัตราการสูญเสียชีวิตหรือทุพพลภาพอันเนื่องมาจากการหกล้ม

1.1 ความมุ่งหมายและวัตถุประสงค์ของโครงการวิจัย

โครงการวิจัยนี้ มุ่งเน้นการพัฒนาระบบแจ้งเตือนการล้มของผู้สูงอายุผ่านโทรศัพท์เคลื่อนที่ ซึ่งประกอบด้วย

- 1) เครื่องวัดสัญญาณการเคลื่อนไหว เพื่อใช้ในการตรวจจับการหกล้มของผู้สูงอายุ ตัวเครื่องประกอบด้วยเซนเซอร์วัดความเร่ง (Accelerometer) แบบ 3 แกน เพื่อใช้วัดสัญญาณการเคลื่อนไหวของผู้สูงอายุ และใช้ทฤษฎีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับเพื่อวิเคราะห์สัญญาณการเคลื่อนไหว และตรวจจับการหกล้มของผู้สูงอายุ เมื่อตรวจพบการหกล้มแล้วตัวเครื่องจะส่งสัญญาณ SMS ขอความช่วยเหลือผ่านโมดูล GSM ไปยังโรงพยาบาลและโทรศัพท์ของญาติที่ใกล้ชิด
- 2) Web Application ทำหน้าที่รับสัญญาณ SMS ขอความช่วยเหลือจากเครื่องวัดสัญญาณการเคลื่อนไหว จากนั้นจึงแจ้งเตือนและแสดงแผนที่บ้านของผู้สูงอายุ เพื่อให้โรงพยาบาลสามารถส่งรถพยาบาลไปรับตัวผู้สูงอายุได้อย่างรวดเร็ว
- 3) โปรแกรมนำทางรถพยาบาล เป็นโปรแกรมที่ติดตั้งบนโทรศัพท์ระบบ Android เพื่อแสดงแผนที่ให้กับรถพยาบาลที่จะไปรับตัวผู้สูงอายุ

1.2 สมมุติฐานในการออกแบบขั้นตอนการตรวจจับการหกล้ม

เนื่องจากอัลกอริทึมตรวจจับการหกล้มในอดีตเช่น [2] [4] [8] และ [11] เป็นต้น มีการใช้อัลกอริทึมตรวจจับการหกล้มด้วยการตั้งค่าขีดเริ่ม แต่จากการศึกษาพบว่าอัลกอริทึมนี้ไม่เพียงพอต่อการแยกประเภทสัญญาณการหกล้มและการเคลื่อนไหวแบบฉับพลัน ด้วยข้อดีของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับที่สามารถเรียนรู้รูปแบบสัญญาณใหม่ๆ ได้ง่าย และเป็นอัลกอริทึมที่ใช้ในการจำแนกกลุ่มข้อมูลที่สามารถแบ่งกลุ่มข้อมูลได้อย่างมีประสิทธิภาพ ด้วยการรู้จำรูปแบบ (Pattern Recognition) อีกทั้งยังมีโครงสร้างของระบบที่มีลักษณะเชิงคำนวณสำหรับโปรแกรมคอมพิวเตอร์ จึงน่าจะสามารถนำมาใช้ในการจำแนกประเภทของสัญญาณการหกล้มและสัญญาณการเคลื่อนไหวประเภทอื่นๆ ได้ ดังนั้น โครงการวิจัยนี้จึงนำเสนออัลกอริทึมสำหรับตรวจจับการหกล้มซึ่งประกอบด้วย 3 ขั้นตอนคือ 1) การตรวจจับสัญญาณการเคลื่อนไหวแบบฉับพลัน และหกล้ม, 2) การตัดสัญญาณ และ 3) การตรวจจับการหกล้มด้วยวิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ

1.3 ทฤษฎีหรือแนวความคิดที่ใช้ในการวิจัย

จากการสำรวจงานวิจัยในอดีตที่ผ่านมาพบว่า มีงานวิจัยหลายชิ้นที่ได้นำเสนอการเลือกใช้ตัวตรวจจับความเร่งสำหรับใช้ในระบบตรวจจับการหกล้มของผู้สูงอายุ ซึ่งสามารถแบ่งออกเป็น 3 กลุ่มดังนี้ กลุ่มแรกเป็นงานวิจัยที่ได้นำเสนอการเลือกใช้ตัวตรวจจับความเร่งอย่างเดียวเช่น งานวิจัย [3], [4], [5], [6], [7] และ [11] เป็นต้น ลำดับต่อมาเป็นกลุ่มงานวิจัยที่ได้นำเสนอการเลือกใช้ตัวตรวจจับความเร่งร่วมกับตัวตรวจจับชนิดอื่น ๆ เช่น ใช้ร่วมกับตัวตรวจจับความเร่งเชิงมุม [2, 5] หรืออาจใช้ร่วมกับตัวตรวจจับการเคลื่อนไหวด้วยแสง [8] และกลุ่มสุดท้ายเป็นกลุ่มงานวิจัยที่ไม่ใช้ตัวตรวจจับความเร่งเช่น ใช้ตัวตรวจจับเสียง [9] อย่างเดียว หรือตัวตรวจจับแสง [10] อย่างเดียวเป็นต้น

สำหรับระบบตรวจจับการหกล้มของผู้สูงอายุที่ใช้ตัวตรวจจับเสียงหรือตัวตรวจจับแสง (ทั้งที่ใช้ร่วมกับตัวตรวจจับความเร่งหรือไม่ได้ใช้ร่วมกับตัวตรวจจับความเร่ง) นั้นไม่สามารถนำไปประยุกต์ใช้ในทางปฏิบัติได้ เนื่องจากมีน้ำหนักมาก สิ้นเปลืองพลังงานสูง และต้องติดตั้งในพื้นที่ที่กำหนดเท่านั้น ทำให้ไม่ผู้ใช้เกิดความไม่สะดวก นอกจากนี้การประมวลผลภาพจำเป็นต้องใช้คอมพิวเตอร์ประสิทธิภาพสูงในการประมวลผล และระบบที่มีการตรวจจับภาพนั้นยังเป็นการ

ละเมิดความเป็นส่วนตัวของผู้ใช้อีกด้วย ในส่วนระบบตรวจจับการหกล้มของผู้สูงอายุที่ใช้ตัวเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตรวจจับเสียงเป็นระบบที่ง่ายต่อการเกิดสัญญาณรบกวนโดยสภาพแวดล้อมเช่น เสียงดังจากการปิดประตู เสียงจากสิ่งมีชีวิต เป็นต้น โดยสัญญาณรบกวนนี้จะเข้าไปรบกวนในกระบวนการประมวลผลสัญญาณทำให้ประสิทธิภาพในการตรวจจับการหกล้มลดลง

เนื่องจากความก้าวหน้าของเทคโนโลยีของตัวตรวจจับความเร่ง และตัวตรวจจับความเร่งเชิงมุมในปัจจุบัน ทำให้สามารถสร้างระบบวัดการเคลื่อนไหวที่มีขนาดเล็กและน้ำหนักเบา ซึ่งมีข้อดีคือสามารถติดกับตัวของผู้สูงอายุได้ และสัญญาณของการเคลื่อนไหวที่ได้จากการวัดจะไม่ถูกรบกวนจากสิ่งรบกวนภายนอก ด้วยเหตุนี้ระบบตรวจจับการหกล้มที่ใช้ตัวตรวจจับความเร่งจึงถือได้ว่าเป็นระบบที่มีความน่าเชื่อถือมากกว่าระบบที่ใช้ตัวตรวจจับเสียง หรือที่ใช้ตัวตรวจจับแสง อีกทั้งยังทำให้ผู้สูงอายุเกิดความสะดวกสบาย เนื่องจากสามารถใช้ตรวจจับการหกล้มได้ทุกที่ที่ต้องการ

กลุ่มงานวิจัยที่ใช้สัญญาณจากระบบตรวจวัดสัญญาณการเคลื่อนไหว ด้วยตัวตรวจจับความเร่ง ได้นำเสนออัลกอริทึมตรวจจับการหกล้มที่อยู่บนพื้นฐานของการกำหนดค่าขีดเริ่มของขนาดของความเร่ง หรือความเร็ว เช่น J.T Perry และคณะในงานวิจัย [2] ได้พัฒนาอัลกอริทึมตรวจจับการหกล้มด้วยการใช้ผลรวมของเวกเตอร์จากตัวตรวจจับความเร่งแบบสามแกน และตัวตรวจจับความเร่งเชิงมุมแบบสองแกน

เพื่อที่จะเพิ่มประสิทธิภาพของระบบตรวจจับการหกล้มงานวิจัย [4] ของ C-C. Wang ได้นำเสนอสามเงื่อนไขเพิ่มเติมดังนี้ ลำดับแรกเพื่อที่จะแยกการหกล้มจากกิจกรรมอื่นๆ จึงใช้ผลรวมเวกเตอร์ของระนาบในแนวตั้ง ลำดับต่อมาเพื่อที่จะตรวจจับการหกล้ม จึงมีการบันทึกเวลาของการหกล้มในขณะที่ลำตัวนอนนิ่งกับพื้น และในขณะที่ลำตัวเริ่มกระทบถึงพื้น ลำดับสุดท้ายเพื่อที่จะแยกแยะระหว่างสัญญาณการหกล้มและสัญญาณการเคลื่อนไหวฉบับพลันจึงใช้สมการในการคำนวณค่าความเร็วของการเคลื่อนไหว ณ ขณะนั้น ในงานวิจัย [8] ผู้เขียนได้พัฒนาอัลกอริทึมของ J.T Perry เพื่อเพิ่มประสิทธิภาพให้มากขึ้น

ดังนั้นจากงานวิจัยในอดีตที่ผ่านมาจะเห็นได้ว่า องค์ประกอบของระบบตรวจจับการหกล้มมีอยู่ 2 ประการคือ การเลือกใช้ตัวตรวจจับ และอัลกอริทึมตรวจจับการหกล้ม โครงการวิจัยนี้จึงมุ่งเน้นในเรื่องการพัฒนาระบบวัดสัญญาณการเคลื่อนไหว โดยใช้ตัวตรวจจับความเร่งอย่างเดียว และอัลกอริทึมตรวจจับการหกล้มเพื่อแยกสัญญาณการหกล้ม ออกจากสัญญาณการเคลื่อนไหว

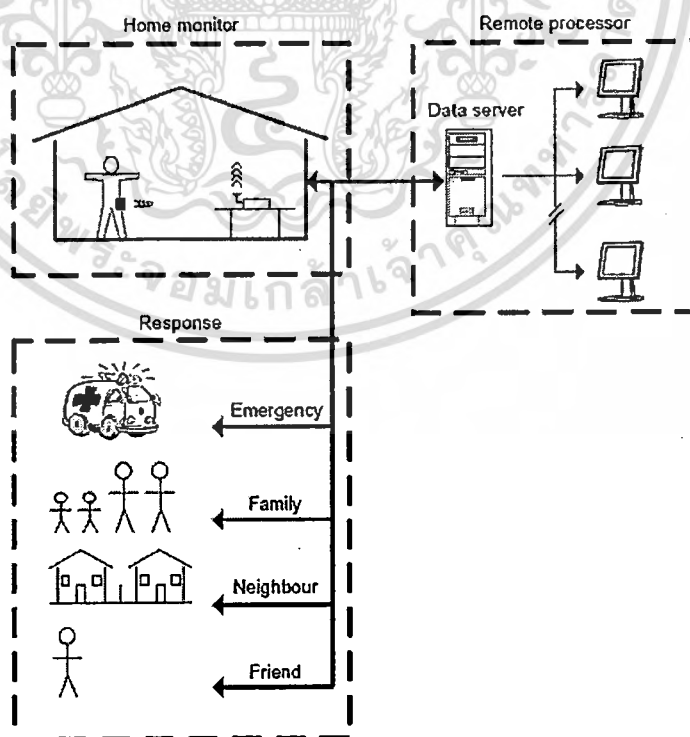
ประเภทอื่นๆ

เอกสารนี้เป็นลิขสิทธิ์ของสถาบันวิจัยและพัฒนาสุขภาพแห่งชาติ (สสวช.) สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 2 งานวิจัยที่เกี่ยวข้อง

2.1 อุปกรณ์สำหรับการตรวจจัดการหกล้มสำหรับมนุษย์และการติดตั้ง

จากการสำรวจงานวิจัยในอดีตที่ผ่านมาจะเห็นได้ว่า องค์ประกอบของระบบตรวจจัดการหกล้มมีอยู่ 2 ประการคือ การเลือกใช้ตัวตรวจจับความเร่งวัดสัญญาณการเคลื่อนไหว และ อัลกอริทึมตรวจจัดการหกล้ม โดยที่มีงานวิจัยหลายชิ้นที่ได้นำเสนอการเลือกใช้ตัวตรวจจับความเร่งสำหรับใช้ในระบบตรวจจัดการหกล้มของผู้สูงอายุ ซึ่งสามารถแบ่งออกเป็น 3 กลุ่มดังนี้ กลุ่มแรกเป็นงานวิจัยที่ได้นำเสนอการเลือกใช้ตัวตรวจจับความเร่งอย่างเดียวเช่น [3], [4], [5], [6], [7] และ [11] เป็นต้น ลำดับต่อมาเป็นกลุ่มงานวิจัยที่ได้นำเสนอการเลือกใช้ตัวตรวจจับความเร่งร่วมกับตัวตรวจจับชนิดอื่น ๆ เช่นใช้ร่วมกับตัวตรวจจับความเร่งเชิงมุม [2, 5] หรืออาจใช้ร่วมกับตัวตรวจจับการเคลื่อนไหวด้วยแสง [8] และกลุ่มสุดท้ายเป็นกลุ่มงานวิจัยที่ไม่ใช้ตัวตรวจจับความเร่งเช่น ใช้ตัวตรวจจับเสียง [9] อย่างเดียว หรือตัวตรวจจับแสง [10] อย่างเดียว เป็นต้น




ภาพที่ 2.1 ระบบควบคุมดูแลการเคลื่อนไหวประเภทหกล้มของผู้สูงอายุ [3]

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์หรือการสงวนสิทธิ์ในบางประการ เมื่อผู้ใช้งานเห็นหรือได้ยินเสียงแจ้งเตือนจากระบบการแจ้งเตือนฉุกเฉินด้านความปลอดภัย ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดลอกเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.1.1 งานวิจัยที่นำเสนอตัวตรวจจับความเร่งอย่างเดียว

กลุ่มนักวิจัยชาวฝรั่งเศส [3] ได้พัฒนาอุปกรณ์สำหรับตรวจจับสัญญาณการเคลื่อนไหวประเภทหกเหลี่ยมของผู้สูงอายุ โดยมีส่วนประกอบหลักสำคัญคือ PFAM (เป็นอุปกรณ์สำหรับใช้ในการตรวจจับการหกเหลี่ยมของผู้สูงอายุโดยการใช้ตัวตรวจจับความเร่งแบบ 3 แกน) และ MiiLink (เป็นอุปกรณ์สำหรับรับคำสั่งสัญญาณ) ดังภาพที่ 2.1 อุปกรณ์ 2 ตัวดังกล่าวสื่อสารกันผ่านทาง Blue-tooth ซึ่งความสามารถของอุปกรณ์ไม่ได้มีแค่การตรวจจับสัญญาณการเคลื่อนไหวประเภทหกเหลี่ยมอย่างเดียว แต่ยังสามารถให้ผู้ใช้งานประเมินการหกเหลี่ยมได้อีกด้วย โดยที่อุปกรณ์ PFAM จะประเมินความเสี่ยงด้วยการหาตัวแปรที่เสี่ยงต่อการหกเหลี่ยม แล้วจำแนกความเสี่ยงต่อการหกเหลี่ยมในเบื้องต้นได้ พร้อมทั้งยังมี MiiLink ที่ติดตั้งตัวส่งสัญญาณโทรศัพท์เพื่อโทรไปยังศูนย์แบบอัตโนมัติในเวลาเกิดเหตุการณ์ฉุกเฉิน ทั้งนี้ขึ้นอยู่กับระดับความรุนแรงของการหกเหลี่ยม ซึ่งอุปกรณ์ MiiLink สามารถช่วยส่งสัญญาณไปยังบุคคลที่เหมาะสมได้ (ตัวอย่างเช่น การหกเหลี่ยมที่มีความรุนแรงน้อยโดยที่ผู้ใช้สามารถยืนขึ้น ระบบก็จะต่อสายไปยังสมาชิกในครอบครัว หรือถ้าบาดเจ็บรุนแรงมากก็ส่งสัญญาณไปยังโรงพยาบาล)

สำหรับงานวิจัยของ Chai-Chi Wang [4] ได้นำเสนออุปกรณ์สำหรับการตรวจจับสัญญาณการเคลื่อนไหวประเภทหกเหลี่ยมของผู้สูงอายุโดยการใช้ตัวตรวจจับความเร่ง ซึ่งได้วางตำแหน่งของตัวตรวจจับความเร่งไว้ที่หัวของผู้ทดลอง ส่วน S.Y.Sim และคณะ [6] ได้นำเสนออุปกรณ์สำหรับตรวจจับการหกเหลี่ยมของผู้สูงอายุโดยการใช้ตัวตรวจจับความเร่ง (ยี่ห้อ Motorola เบอร์ MMA7260Q) แบบ 3 แกน พร้อมด้วยไมโครคอนโทรลเลอร์ (Atmel ATMEGA8) เพื่อการประมวลผล ซึ่งอุปกรณ์ดังกล่าวมีขนาด 50 มม. x 25 มม. x 20 มม. น้ำหนัก 40 กรัม (100 กรัมรวมแบตเตอรี่) และสามารถเปิดใช้งานได้นานถึง 5 ชั่วโมง อุปกรณ์นี้สามารถสื่อสารข้อมูลผ่านระบบมอดูลบลูทูธ (Bluetooth Module) ที่มีระยะห่าง 7 เมตร และได้กำหนดตำแหน่งในการวางของอุปกรณ์สำหรับการตรวจจับการเคลื่อนไหวไว้บนร่องเท้าแต่ละข้าง ส่วน Yan Yang และ Xingqun Zhao [7] ได้ใช้ตัวตรวจจับความเร่งเป็นอุปกรณ์สำหรับตรวจจับการหกเหลี่ยมของผู้สูงอายุ เนื่องจากนักวิจัยได้ให้เหตุผลว่าถ้าติดตั้งอุปกรณ์ไว้ส่วนหัวจะทำให้เกิดการเคลื่อนที่ที่ใช้เวลานานกว่าการติดตั้งไว้ส่วนอื่นๆ ดังนั้นจึงได้ติดตั้งอุปกรณ์ไว้ตำแหน่งดังกล่าวของผู้ทดลองดังภาพที่ 2.2 เพราะฉะนั้นข้อมูลที่ไดมาก็จะมีความละเอียดและสมบูรณ์กว่าการติดตั้งส่วนอื่นๆ



ภาพที่ 2.2 การติดตั้งอุปกรณ์สำหรับการตรวจจับการเคลื่อนไหว [7]

Boyle และ Karunanithi [11] เป็นกลุ่มนักวิจัยชาวออสเตรเลียได้พัฒนาอัลกอริทึมสำหรับการตรวจจับการเคลื่อนไหว โดยได้นำเสนออุปกรณ์สำหรับการตรวจจับสัญญาณการเคลื่อนไหวของผู้สูงอายุโดยการใช้ตัวตรวจจับความเร่ง (ยี่ห้อ PAL Technology) แบบ 2 แกน มีขนาด 35 มม. × 53 มม. × 7 มม. น้ำหนัก 40 กรัม นักวิจัยดังกล่าวได้ใช้สายสะพายเพื่อติดตั้งอุปกรณ์ให้แนบกับเอวของผู้ป่วย และกำหนดทิศของแกนตัวตรวจจับความเร่งให้มีทิศในแกนตั้งและแกนหน้า - หลัง ผลจากการที่ใช้ตัวตรวจจับความเร่งแบบ 2 แกนทำให้การล้มไปด้านข้างยากที่จะตรวจจับได้

2.1.2 งานวิจัยที่นำเสนอตัวตรวจจับความเร่งร่วมกับตัวตรวจจับชนิดอื่น ๆ


Perry และคณะ [2] ได้นำเสนออุปกรณ์ที่มีชื่อว่า BioMOBIUS รุ่น 1 (ผลิตภัณฑ์จากบริษัท Shimmer-Research Inc.) ดังภาพที่ 2.3 เนื่องจากอุปกรณ์ที่นำมาทดสอบนั้นเป็นอุปกรณ์สำเร็จรูปจากบริษัท และมีส่วนประกอบหลักที่สำคัญคือ ตัวตรวจจับความเร่ง (ประกอบด้วยตัวตรวจจับความเร่งและตัวตรวจจับความเร่งเชิงมุม) และมีมอดูลสำหรับการสื่อสารข้อมูล ทำให้อุปกรณ์มีข้อดีและความสามารถหลายอย่าง เช่น ความสามารถในการเชื่อมต่อและตัดการเชื่อมต่อในระหว่างการตรวจวัดสัญญาณ ด้วยขนาดเล็กของอุปกรณ์ทำให้สามารถวางอุปกรณ์ไว้ในกระเป๋าได้ และสามารถเปิดใช้งานในระยะเวลาอันยาวนานได้ อีกทั้งยังมีความปลอดภัยสำหรับผู้ทดลองในระหว่างการทดลองอีกด้วย สำหรับการทดลองนักวิจัยได้กำหนดตำแหน่งการวางอุปกรณ์ไว้ที่สะโพกขวาของผู้ทดลองและรัดด้วยเข็มขัด นักวิจัยได้กำหนดให้แกน X ด้านบวกของตัวตรวจจับความเร่งคือทิศทางแนวตั้ง แกน Y ด้านบวกคือทิศทางด้านหน้า และแกน Z คือทิศทางด้านขวา

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ภาพที่ 2.3 อุปกรณ์สำหรับการตรวจจับสัญญาณการเคลื่อนไหว [2]

Jacob และคณะ [5] ได้นำเสนออุปกรณ์ตรวจจับการหกล้มของผู้สูงอายุโดยการใช้ตัวตรวจจับความเร่ง (ยี่ห้อ Freescale semiconductor เบอร์ MMA7341LC) และตัวตรวจจับความเร่งเชิงมุม (ยี่ห้อ ST Microelectronics เบอร์ LPR530AL สำหรับ 2 แกน และ เบอร์ LY530ALH สำหรับ 1 แกน) จำนวน 2 ตัว ซึ่งอุปกรณ์ดังกล่าวมีขนาด 11 ซม. x 10 ซม. x 13 ซม. น้ำหนัก 181 กรัม ดังภาพที่ 2.4 สำหรับการทดลองนักวิจัยในกำหนดตำแหน่งในการวางตัวตรวจจับความเร่งไว้ที่ส่วนหลังของผู้ทดลองดังภาพที่ 2.5



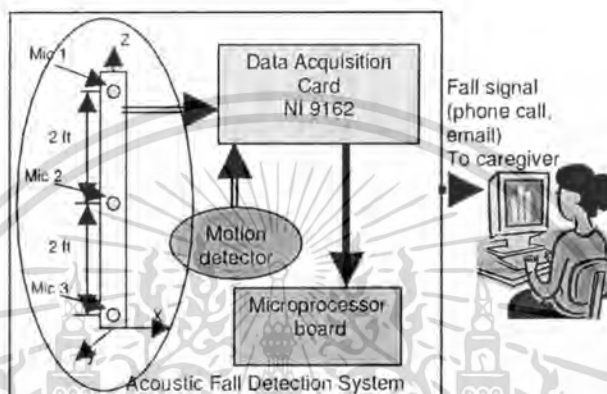
ภาพที่ 2.4 อุปกรณ์สำหรับการตรวจจับการหกล้ม [5]



เอกสารนี้เป็นเอกสารที่ **ภาพที่ 2.5 ตำแหน่งการวางของอุปกรณ์สำหรับการตรวจจับการหกล้ม [5]** ยืนยันด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.1.3 งานวิจัยที่นำเสนออุปกรณ์ตรวจจับการหกล้มโดยการไม่ใช้ตัวตรวจจับความเร่ง

Popescu และคณะ [9] ได้นำเสนออุปกรณ์สำหรับการตรวจจับการหกล้มโดยการใช้อุปกรณ์ตรวจจับเสียง ซึ่งมีส่วนประกอบดังนี้ ตัวตรวจจับเสียง (รุ่น Cana Kit CK495 โดยกำหนดให้ติดตั้งเป็นแผงตามแนวตั้ง) และบอร์ด (NI card NI 9162 สำหรับการบันทึกและนำข้อมูลที่บันทึกไว้ไปประมวลผล) ดังภาพที่ 2.6



ภาพที่ 2.6 อุปกรณ์สำหรับการตรวจจับการหกล้ม [9]

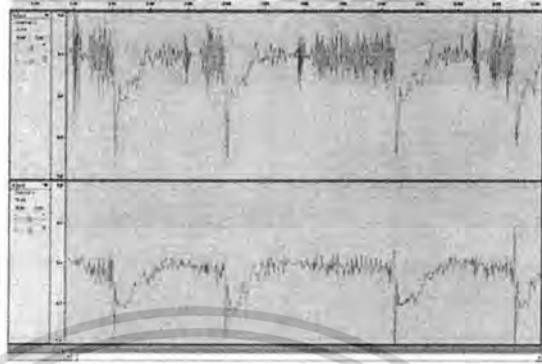
Samantha Ng และคณะ [10] ได้พัฒนาการตรวจจับการหกล้มโดยวิธีการติดตามด้วยภาพ ซึ่งอุปกรณ์ที่ใช้สำหรับการตรวจจับการเคลื่อนไหวคือ กล้อง (Monocular Vision System) โดยอุปกรณ์ดังกล่าวได้ติดตั้งไว้ที่ตำแหน่งขาของผู้ทดลอง เมื่อผู้ทดลองมีการเคลื่อนไหว อุปกรณ์สามารถหาความเร็วจากแต่ละก้าวของการเดิน เพื่อประมวลผลหาการความเป็นไปได้ต่อการเกิดการหกล้ม กล่าวคือ หากผู้ใช้ได้หายไปจากการเคลื่อนไหวในระยะเวลาใดๆ ก็จะต้องมีการหกล้มเกิดขึ้น ณ ช่วงเวลานั้นๆ

2.2 อัลกอริทึมสำหรับการตรวจจับการหกล้มสำหรับมนุษย์

สำหรับองค์ประกอบในส่วนของอัลกอริทึมตรวจจับการหกล้ม ซึ่งใน Boyle และ Karunanithi [11] เป็นกลุ่มนักวิจัยชาวออสเตรเลียได้ที่นำเสนอการพัฒนาอัลกอริทึมสำหรับการตรวจจับการเคลื่อนไหวประเภทหกล้ม โดยนักวิจัยดังกล่าวเก็บข้อมูลในรูปแบบความเร่งจากตัวตรวจจับความเร่งแบบ 2 แกน (อุปกรณ์ที่เป็นสายสะพายแนบกับเอวของผู้สูงอายุ) การจำลอง


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เหตุการณ์ลักษณะการหกล้มของผู้สูงอายุได้กระทำโดยอาสาสมัครหนุ่มสาวสุขภาพดี ซึ่งจากผลการทดลองกลุ่มนักวิจัยได้มีการวิเคราะห์และสรุปสัญญาณการเคลื่อนไหวประเภทหกล้มไว้ดังนี้



ภาพที่ 2.7 ตัวอย่างของสัญญาณการเคลื่อนไหวประเภทหกล้มของมนุษย์ [11]

- ทุกๆ การหกล้มจะมีข้อมูลของความเร่งถึงระดับยอดค่าที่สุดในด้านลบ และมีเพียงแต่ข้อมูลในแกนแนวตั้งเท่านั้นที่ใช้ในการหาค่าขีดเริ่มของการหกล้มดังภาพที่ 2.7
- การหกล้มจะทำให้กราฟของความเร่งพุ่งขึ้นจากค่าบวกไปยังค่าลบ โดยมีความเร็วของการเปลี่ยนแปลงนี้เป็นปัจจัยสำคัญในการตรวจจับการหกล้ม
- ทุกๆครั้งที่อัลกอริทึมตรวจจับว่ามีอาการหกล้มเกิดขึ้น จะต้องเผื่อค่าสำหรับความผิดพลาด ± 4 ตัวอย่าง กล่าวคือถ้าอัลกอริทึมตรวจจับสัญญาณการเคลื่อนไหวตรวจพบการหกล้มที่ตำแหน่ง 1000 ก็จะมีการบวกค่าผิดพลาดไว้ตั้งแต่ 996 ถึง 1004 ดังภาพที่ 2.8



ภาพที่ 2.8 ตำแหน่งของการหกล้มแทนด้วย \oplus และตีกรอบสำหรับค่าผิดพลาดไว้ [11]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ส่วนการพัฒนาอัลกอริทึมสำหรับการตรวจจับการหกล้ม Boyle และ Karunanithi ได้นำเสนออัลกอริทึมด้วยการคำนวณความแตกต่างระหว่างค่าเฉลี่ย 5 ตัวอย่าง (ใช้เวลาในการรวมข้อมูลของสัญญาณความเร่งในรอบเวลา 0.5 วินาที) และเลื่อนข้อมูลทุกๆ รอบเวลานี้ไปตามแกนเวลา และลบกับค่าเฉลี่ยของชุดข้อมูลทั้งหมดแล้วนำมาเปรียบเทียบกับที่ค่าขีดเริ่มที่กำหนดไว้ดังสมการ (2.1)

$$\|\bar{x} - \bar{X}\| \geq \text{fallthresh}, \quad (2.1)$$

กำหนดให้ \bar{x} คือค่าเฉลี่ยของ 5 ตัวอย่าง \bar{X} คือค่าเฉลี่ยของชุดข้อมูลทั้งหมดตามแกนเวลา และ fallthresh คือค่าขีดเริ่มที่กำหนดไว้ เมื่อค่า $\|\bar{x} - \bar{X}\|$ มีค่ามากกว่าค่า fallthresh ก็จะถือว่าเกิดการหกล้ม

สำหรับกลุ่มงานวิจัยที่ใช้สัญญาณจากตัวตรวจจับความเร่งอีกกลุ่มหนึ่ง ได้นำเสนออัลกอริทึมสำหรับตรวจจับการหกล้มที่อยู่บนพื้นฐานการกำหนดค่าขีดเริ่มของขนาดของความเร่งหรือความเร็ว ตัวอย่างเช่น Perry และคณะ [2] ได้พัฒนาอัลกอริทึมสำหรับการตรวจจับการหกล้มด้วยการใช้ผลรวมของเวกเตอร์จากตัวตรวจจับความเร่งแบบสามแกน และตัวตรวจจับความเร่งเชิงมุมแบบสองแกน ซึ่งสามารถคำนวณผลรวมของเวกเตอร์ได้จากสมการ (2.2) และ (2.3)

$$A = \sqrt{a_x^2 + a_y^2 + a_z^2} \quad (2.2)$$

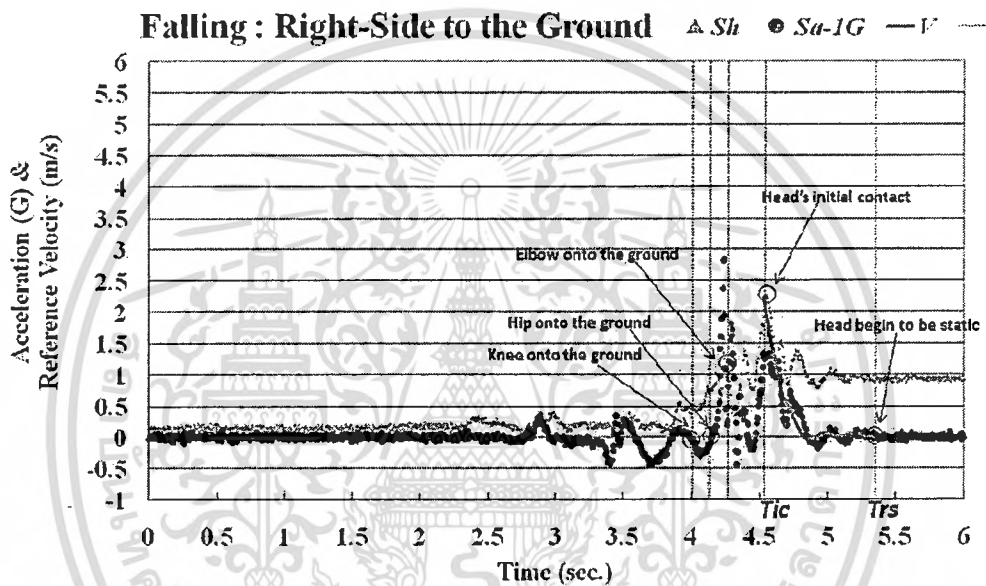
$$G = \sqrt{g_x^2 + g_y^2} \quad (2.3)$$

โดยกำหนดให้ a_x , a_y , และ a_z เป็นสัญญาณจากตัวตรวจจับความเร่งแบบสามแกนตามแกน x, y และ z ตามลำดับ และ g_x และ g_y เป็นสัญญาณจากตัวตรวจจับความเร่งเชิงมุมแบบสองแกนตามแกน x และ y ตามลำดับ ซึ่งนักวิจัยดังกล่าวได้เลือกใช้ค่าสำหรับกำหนดค่าขีดเริ่มของ A และ G คือ $3g$ และ $1g$ ตามลำดับ

จากภาพที่ 2.9 C-C. Wang [4] ได้ใช้การหาผลรวมทั้งสามแกนขององค์ประกอบของความเร่ง (Sa) ดังสมการ (2.4)

$$S_a = \sqrt{a_x^2 + a_y^2 + a_z^2} \tag{2.4}$$

โดย C-C. Wang ได้วิเคราะห์สัญญาณการหกล้มเพิ่มเติมพบว่า ไม่ได้มีเพียงแต่การตรวจจับการหกล้มตามสมการที่ (2.4) เท่านั้น ทางกลุ่มวิจัยได้นำเสนอสามเงื่อนไขเพิ่มเติมดังนี้ ลำดับแรกเพื่อที่จะแยกการหกล้มจากกิจกรรมอื่นๆ จึงคำนวณผลรวมเวกเตอร์ของระนาบในแนวตั้ง (S_h) สามารถคำนวณได้ตามสมการ (2.5)



ภาพที่ 2.9 ตัวอย่างการสัญญาณการหกล้ม ไปด้านขวา [4]

$$S_h = \sqrt{a_x^2 + a_z^2} \tag{2.5}$$

ผลรวมทั้งสามแกนขององค์ประกอบของความเร่ง (S_a) และผลรวมแกน x และแกน z เป็นขององค์ประกอบของความเร่ง (S_h) ทั้งสองตัวแปรนี้ได้ใช้เพื่อหาตัวแปรเพิ่มเติมในขั้นตอนของการตรวจจับการหกล้ม ตัวแปรเหล่านี้จะใช้ในการหาจุดสำคัญของกระบวนการหกล้ม (กล่าวคือ การหาช่วงเวลาของการหกล้ม)

ต่อมาเพื่อที่จะตรวจจับการหกล้ม จึงมีการบันทึกเวลาของการหกล้มในขณะที่ลำตัวนอนนิ่งกับพื้น (T_{rs}) และการบันทึกเวลาของการหกล้มในขณะที่ลำตัวเริ่มกระทบพื้น (T_{tr}) สำหรับ

การหกล้มที่เป็นแบบปกติ ค่าของ S_a จะเกิน 6g และค่าของ S_h จะต่ำกว่า 2g การหกล้มจะถูกเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไมอนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตรวจจับได้เมื่อค่าของทั้งสองนั้นสูงกว่าค่าขีดเริ่ม ถ้าหากค่าของ Sa ไม่เกินค่าขีดเริ่มและค่าของ Sh เกินค่าขีดเริ่ม จะต้องมีการคำนวณเพิ่มเติมเพื่อหาว่าเป็นการหกล้มหรือไม่ ทั้ง T_{rs} และ T_{ic} ใช้เพื่อ ความคำนวณค่าความเร็วระหว่างการตกกระทบ Tic ตั้งค่าเวลาเมื่อ Sh เกินค่าขีดเริ่ม และ Trs จะตั้ง ค่าเวลาเมื่อ Sa มีค่ากลับไปที 1g และถัดไป 60 ตัวอย่างของ Sa จะเหมือนกัน เมื่อความเร็วสูงสุดใน ระหว่างการหกล้มมีค่ามากกว่าหรือเท่ากับ 2 เมตรต่อวินาทีจะถือเป็นการหกล้ม ซึ่งการหา T_{rs} และ T_{ic} สามารถเขียนภาษาโปรแกรมดังภาพที่ 2.10

```

int j = i, F = 1;
for(j ≤ i ≤ 400; i++) && (F = 1)
    while (0.5 < Ai < 1.5)
        for(int n = 1; n ≤ 60; n++)
            if(|Ai - Ai+n| ≥ 0.13)
                k = i + n;
                i = i + k;
                n = 1;
            else if (n = 60)
                Trs = i, Tic = j, F = 0;
            endif
        endif
    endif
endfor
endwhile
endfor

```

ภาพที่ 2.10 โปรแกรมในการคำนวณคาบเวลาของการหกล้ม [4]

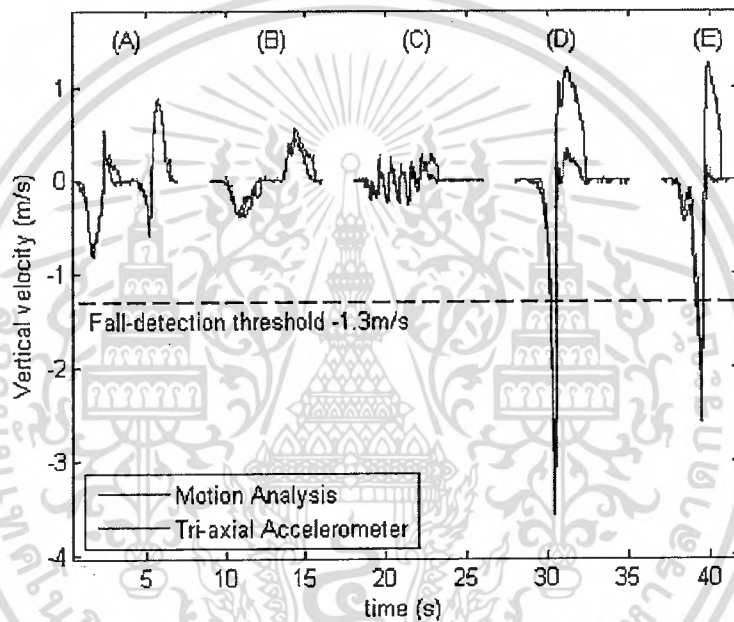
สุดท้าย เพื่อที่จะแยกระหว่างสัญญาณการหกล้มและสัญญาณการเคลื่อนไหวฉบับพลัน สามารถใช้การคำนวณค่าความเร็วโดยการอินทิกรัลดังสมการ (2.6)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$V_{\max} = \int_{T_{rs}}^{T_{ic}} [S_a(t) - 1] dt \quad (2.6)$$

Bourke [8] ได้ดัดแปลงสมการที่ (2.4) เพื่อคำนวณหาความเร็วในการเคลื่อนไหวได้ดังสมการ (2.7) ซึ่งมีผลการทดลองดังภาพที่ 2.11

$$v = \int \left(\sqrt{a_x^2 + a_y^2 + a_z^2} - 9.81 \text{ m/s}^2 \right) dt \quad (2.7)$$



ภาพที่ 2.11 เปรียบเทียบสัญญาณที่มาจากตัวตรวจจับความเร่งแบบสามแกน (เส้นสีน้ำเงิน) และการวิเคราะห์ด้วยการหาความเร็วในแนวแกนตั้ง (เส้นสีแดง) [8]

Yang และ Zhao [7] ได้นำเสนอวิธีการตรวจจับสัญญาณการหกล้มโดยการกำหนดค่าขีดเริ่มซึ่งคำนวณตามสมการ (2.8) ถึงสมการ (2.12)

$$S_a = \sqrt{a_x^2 + a_y^2 + a_z^2} \quad (2.8)$$

$$x_delta = ax_max - ax_min \quad (2.9)$$

$$y_delta = ay_max - ay_min \quad (2.10)$$

$$z_delta = az_max - az_min \quad (2.11)$$

เอกสารนี้เป็นเอกสารที่ $\max(x_delta, y_delta, z_delta)$ ศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ในการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดยกำหนดให้ x_{Δ} y_{Δ} และ z_{Δ} คือค่าความแตกต่างระหว่างค่าสูงสุดและค่าต่ำสุดของค่าความเร่งในแกน x y และ z ตามลำดับ $a_{x_{\max}}$ $a_{y_{\max}}$ และ $a_{z_{\max}}$ คือค่าสูงสุดของค่าความเร่งในแกน x y และ z ตามลำดับ และ $a_{x_{\min}}$ $a_{y_{\min}}$ และ $a_{z_{\min}}$ คือค่าต่ำสุดของค่าความเร่งในแกน x y และ z ตามลำดับ โดย Yang และ Zhao ได้นำเสนอว่าการหกล้มจะเกิดขึ้นเมื่อค่า S_a มากกว่า 2.5g และค่าความแตกต่างในแกนใดแกนหนึ่ง (x_{Δ} y_{Δ} และ z_{Δ}) ของความเร่งมีค่ามากกว่า 3.0g


จากการศึกษาพบว่าอัลกอริทึมตรวจจับการหกล้มด้วยการตั้งค่าขีดเริ่มไม่เพียงพอต่อการแยกประเภทสัญญาณการหกล้มและการเคลื่อนไหวแบบฉับพลัน ด้วยข้อดีของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับที่สามารถเรียนรู้รูปแบบสัญญาณใหม่ๆ ได้ง่าย และเป็นอัลกอริทึมที่ใช้ในการจำแนกกลุ่มข้อมูลที่สามารถแบ่งกลุ่มข้อมูลได้อย่างมีประสิทธิภาพด้วยการรู้จำรูปแบบ (Pattern Recognition) อีกทั้งยังมีโครงสร้างของระบบที่มีลักษณะเชิงคำนวณสำหรับโปรแกรมคอมพิวเตอร์ ดังนั้นโครงการวิจัยนี้เสนออัลกอริทึมสำหรับตรวจจับการหกล้มซึ่งประกอบด้วย 3 ขั้นตอนคือ 1) การตรวจจับสัญญาณการเคลื่อนไหวแบบฉับพลัน และหกล้ม 2) การตัดสัญญาณ และ 3) การตรวจจับการหกล้มด้วยวิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ

บทที่ 3

โครงข่ายประสาทเทียม

3.1 โครงข่ายประสาทชีวภาพ (Biological Neural Network)

ระบบประสาทประกอบด้วยเซลล์ประสาท (Neuron) ที่มีการเชื่อมต่อกันอย่างเป็นระบบ ดังภาพที่ 3.1 เซลล์ประสาทสื่อสารกันโดยผ่านสัญญาณทางไฟฟ้าที่เคลื่อนที่ในทิศทางเดียวกัน แดกถึงกันไปยังส่วนเซลล์อื่นๆ การเชื่อมต่อระหว่างเซลล์ประสาทประกอบด้วยส่วนที่มีการแตกแขนงออกไปเป็นที่รู้จักกันในชื่อว่า Dendrites โดยที่ Dendrites ทำหน้าที่รับสัญญาณจากเซลล์ประสาทอื่น ๆ ผ่านส่วนที่เรียกว่า Axon ซึ่ง Axon ถูกสร้างเพื่อการติดต่อระหว่างเซลล์ประสาท และเป็นส่วนที่นำสัญญาณทางไฟฟ้าที่ปล่อยออกออกมาจากเซลล์ประสาทขาออก ในขณะที่เดียวกันเซลล์ประสาทใดๆ ก็สามารถรับสัญญาณจากเซลล์ประสาทอื่น ๆ ได้อีกด้วย

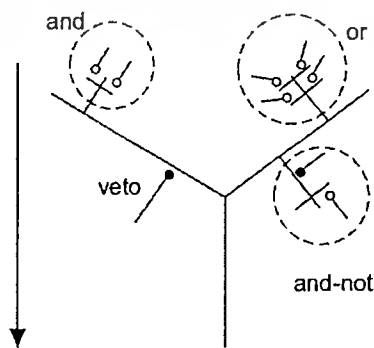


ภาพที่ 3.1 แผนผังของเซลล์ประสาทชีวภาพ [14]

การส่งสัญญาณทางไฟฟ้าระหว่างเซลล์ประสาทใดๆ ใช้อุปกรณ์ทางไฟฟ้าชีวภาพที่เรียกว่า Synapses เป็นสื่อกลาง โดยที่ Synapses จะพบอยู่บริเวณจุดต่อระหว่าง Axon และ Dendrites สัญญาณทางไฟฟ้าที่เข้ามายังจุดนี้จะทำให้ Synapses ถูกกระตุ้นให้เกิดการปล่อยสารเคมีที่เรียกว่า เอกสารนี้เป็นเอกสารที่ส่งวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


สารสื่อประสาท (Neurotransmitter) ซึ่งสารสื่อประสาทจะกระตุ้นโมเลกุลที่อยู่บน Dendrites ทำให้อุณหภูมิเกิดประจุไฟฟ้าเรียกว่าไอออน (ion) โดยไอออนเหล่านี้จะสร้างแรงดันไฟฟ้าขึ้นระหว่างเยื่อหุ้มเซลล์ที่เดินทางจาก Dendrites ไปยังส่วนของ Axon เพราะฉะนั้นความแตกต่างระหว่างแรงดันไฟฟ้าภายในของตัวเซลล์ประสาทและสภาพแวดล้อมภายนอก มีผลต่อการทำงานของระบบเซลล์ประสาท ซึ่งเป็นที่รู้จักกันในชื่อว่า “ระดับการเปิดใช้งานหรือระดับศักยภาพของเซลล์ประสาท” เซลล์ที่มีการส่งและการรับเซลล์สัญญาณจากประสาทอื่นจะเรียกเซลล์ประสาทนั้นว่า Presynaptic และ Postsynaptic ตามลำดับ

เพื่อให้ง่ายต่อความเข้าใจ ส่วนใหญ่แบบจำลองการคำนวณทางคณิตศาสตร์จะตั้งอยู่บนสมมติฐานที่ว่า ความแตกต่างของแรงดันไฟฟ้าที่สร้างโดย Synapses ถูกรวมขึ้นเมื่อสัญญาณมาบรรจบกันที่กิ่งของ Dendrite (จุดต่อระหว่าง Dendrite และ Axon) แต่อย่างไรก็ตาม สัญญาณที่เข้ามาสามารถนำมารวมและแปลงให้อยู่ในรูปแบบอื่น ๆ ซึ่งสามารถอธิบายได้ด้วยฟังก์ชันตรรกะบูลีน ดังภาพที่ 3.2 ตัวอย่างเช่น เมื่อมีสัญญาณเข้ามาส่วน Inhibitory Synapses มีแนวโน้มที่จะปิดกั้นสัญญาณที่เดินทางมาจากส่วน Dendrite ที่อยู่ตำแหน่งสูงกว่า และจะถือว่าเป็นฟังก์ชันตรรกะที่เรียกว่า “NOT” จากรูปจะแสดงถึงปฏิกิริยาของ Synapse บน Dendrite ซึ่งวงกลมที่ไม่ได้แรเงาแทนด้วย Excitatory Synapses และวงกลมที่บดแทนด้วย Inhibitory Synapses โดยที่ Inhibitory Synapses สามารถปิดกั้นสัญญาณทั้งหมดก่อนที่จะเดินทางมาจากจุด Synaptic เช่น “AND” จะมี Synapses ทั้งสองเป็นสัญญาณที่สามารถส่งผ่านได้ ส่วน “OR” จะมี Synapses เพียงอย่างใดอย่างหนึ่งก็พอที่จะส่งผ่านสัญญาณ และ “AND-NOT” เป็น Excitatory Synapses ที่สามารถส่งสัญญาณเฉพาะในกรณีที่มี Inhibitory Synapses ไม่ทำงานเท่านั้น



เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ของสถาบันวิจัยและพัฒนาสุขภาพเด็ก มหิดลวิทยานุสรณ์ ซึ่งใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เซลล์ประสาทจะแพร่สัญญาณไฟฟ้าไปตาม Axon และเมื่อความแตกต่างของแรงดันไฟฟ้าระหว่างเยื่อหุ้มเซลล์ และบริเวณสิ่งแวดล้อมภายนอกมีขนาดใหญ่กว่าค่าขีดเริ่มที่กำหนดไว้ดังภาพที่ 3.3 ที่แสดงตัวอย่างของสัญญาณที่เกิดขึ้นในระบบประสาท เช่นสภาพปกติของแรงดันไฟฟ้าของเซลล์ประสาทของเยื่อหุ้มสมองของสัตว์เลี้ยงลูกด้วยนมจะอยู่ที่ประมาณ -65 mV เมื่อมีการรับสัญญาณเข้ามาทำให้เกิดระดับแรงดันไฟฟ้าที่กระตุ้นมีค่าเป็นบวก ซึ่งเมื่อแรงดันไฟฟ้าเพิ่มขึ้นถึงค่าขีดเริ่มที่ -55 mV ส่งผลทำให้เกิดระดับการทำงานที่เรียกว่า Action Potential ซึ่งเป็นการเคลื่อนตัวจาก Axon ใหญ่ไปยังเซลล์ประสาท Postsynaptic โดยกระบวนการของ Action Potential จะเป็นไปตามขั้นตอนของ Hyperpolarization ซึ่งทำให้เซลล์ประสาทจะกลับไปค่าลบอีกครั้ง คือระดับแรงดันไฟฟ้า -65 mV (วัฏจักรพื้นฐานที่ถูกค้นพบเป็นครั้งแรกโดย Hodgkin และ Huxley ในปี 1952) เป็นสาเหตุให้เกิดการไหลเข้าและออกของไอออน โดยไอออนจะไหลผ่านเยื่อหุ้มเซลล์ และสามารถอยู่ได้ระหว่าง 3 ถึง 50 วินาที ทั้งนี้จะขึ้นอยู่กับชนิดของการไหลของไอออน สุดท้ายผลลัพธ์ที่ออกมาจากกระบวนการดังกล่าวคือสัญญาณพัลส์หรือบางทีก็เรียกว่าชีพจร (Spike)




ภาพที่ 3.3 สัญญาณทางไฟฟ้าของระบบประสาท [14]

โดยที่เซลล์ประสาทส่วนใหญ่สามารถแผ่คลื่นถึง 250 - 300 พัลส์ต่อวินาที และแม้กระทั่งในกรณีที่ไม่มีการเข้ามา สัญญาณจะอยู่ในสถานะกิจกรรมพักก่อนจะมีคลื่นประมาณ 10 พัลส์ต่อวินาทีสมองจึงแสดงกิจกรรมที่เกิดขึ้นเองแม้กระทั่งในกรณีที่ไม่มีสิ่งเร้าจากภายนอก ชนิดของเซลล์ประสาทสามารถแบ่งออกเป็น 3 ชนิด ดังภาพที่ 3.4 ซึ่งมีรายละเอียดดังนี้

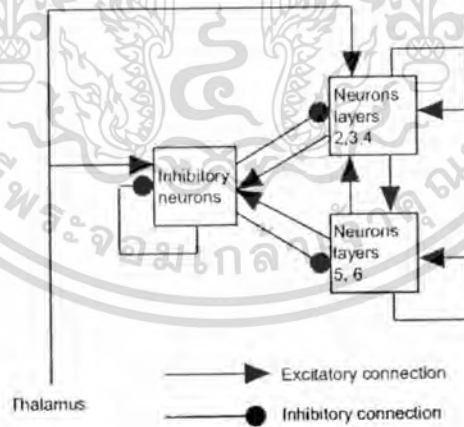
- Sensory neurons คือเซลล์ประสาทเป็นเสมือนอุปกรณ์ต่อพ่วงที่มีตรวจจับการป้อนข้อมูลเมื่อสัมผัสกับสภาพแวดล้อมภายนอก การเชื่อมต่อผลลัพธ์ที่สามารถแยกออกจากกันจะทำให้การติดต่อกับเซลล์ประสาทอื่น ๆ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- Motor neurons เป็นเซลล์ประสาทที่ทำหน้าที่รับการป้อนข้อมูลจากเซลล์ประสาทหรือจากเซลล์ประสาทอื่น ๆ ในระบบ ช่วยให้ควบคุมสัญญาณมาบรรจบกันจากแหล่งต่าง ๆ ก่อนที่จะถูกส่งไปส่วนอื่น ๆ
- Interneurons เป็นเซลล์ประสาทที่สร้างการเชื่อมต่อกับเซลล์ประสาทอื่นๆ แต่ไม่ได้เชื่อมต่อโดยตรงกับสภาพแวดล้อม




ภาพที่ 3.4 แบบจำลองของ Sensory neurons, Motor neurons และ Interneurons [14]



ภาพที่ 3.5 วงจรเชื่อมหุ้มสมอง (ของดักลาสและมาร์ตินปี 1990) [14]

วงจรเชื่อมหุ้มสมองที่ถูกจำลองแบบโดย Douglas และ Martin ขึ้นในปี 1990 ดังภาพที่ 3.5 ภายในบล็อกระบุถึงจำนวนชั้นของเชื่อมหุ้มสมอง 2, 3, และ 4 ชั้นอยู่ใกล้กะโหลก ที่ 5 และ 6 อยู่ใกล้กับศูนย์กลางของสมอง ระบบประสาทได้ทำให้อวัยวะมีความสามารถในการปรับตัวให้เข้ากับเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สภาพแวดล้อมในช่วงเวลาการมีชีวิต ซึ่งในที่นี้เรากำหนดการปรับตัวคือ ชุดของการปรับเปลี่ยนที่เกิดขึ้นในช่วงการมีปฏิสัมพันธ์ระหว่างอวัยวะและสภาพแวดล้อมที่มีการทำงานเพื่อเพิ่มความน่าจะเป็นของการอยู่รอด ที่ระดับ Macroscopic (ระดับพฤติกรรม) การปรับตัวได้หลายรูปแบบ (การทำให้เกิดความเคยชิน) การก่อตัวเป็นกลุ่ม การจัดจํารายการและสถานที่ ส่วนการเรียนรู้เสริมจะไม่ค่อยได้กล่าวถึง ที่ระดับโมเลกุล (neurophysiological) การปรับตัวให้ส่วนใหญ่ด้วยกระบวนการที่มีผลให้เกิดการเชื่อมต่อระหว่างเซลล์ประสาท synaptic ที่แข็งแกร่งขึ้นกระบวนการนี้ยังเป็นที่รู้จักกันในชื่อว่า Synaptic Plasticity




ภาพที่ 3.6 การพิจารณาค่าขีดเริ่มของการส่งสัญญาณทางไฟฟ้าในระบบประสาท

จากภาพที่ 3.6 จัดทำขึ้นโดย Gerstner และ Kistler ในปี 2002 ที่นำเอาข้อมูลจาก Bi และ Poo ที่จัดทำขึ้นเมื่อปี 2001 อัตราร้อยละของ Synapse ที่ปรับเปลี่ยนจะขึ้นอยู่กับความแตกต่างระหว่างแถบ Presynaptic และ Postsynaptic ($t_j^{pre} - t_i^{post}$) กล่าวคือ ความแตกต่างชั่วขณะที่อยู่ในช่วงระหว่าง -100 ถึง 100 วินาที และเมื่ออิงเซลล์ประสาท Postsynaptic หลังจากการเข้ามาของพัลส์จาก Presynaptic ทำให้ได้ความแตกต่างในเชิงบวก ซึ่งที่รู้จักกันในชื่อว่ามีคุณสมบัติเชิงสาเหตุ น้ำหนักของ Synaptic จะเพิ่มขึ้น แต่เมื่ออิงเซลล์ประสาท Postsynaptic ก่อนการเข้ามาของพัลส์จาก Presynaptic ทำให้ได้ความแตกต่างในเชิงลบ ซึ่งที่รู้จักกันในชื่อว่า ความสัมพันธ์ไม่เป็นเชิงสาเหตุ และน้ำหนักของ Synaptic จะลดลงด้วย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.2 โครงข่ายประสาทเทียม (Artificial Neural Network)

โครงข่ายประสาทเทียมเป็นรูปแบบการจำลองของการคำนวณที่ดำเนินการ โดยซอฟต์แวร์ หรือสร้างอุปกรณ์ฮาร์ดแวร์เพื่อพยายามที่เลียนแบบพฤติกรรม และคุณลักษณะการปรับตัวของ ระบบประสาทชีววิทยา โครงข่ายประสาทเทียมประกอบด้วยหน่วยที่เชื่อมต่อกันหลายๆ หน่วยหรือ เซลล์ประสาทหลายเซลล์ดังภาพที่ 3.7 ซึ่งบางส่วนของหน่วยเหล่านี้ได้รับข้อมูลโดยตรงจากสภาพ แวดล้อม หรือบางหน่วยก็รับข้อมูลจากผลกระทบจากปฏิกิริยาของสภาพแวดล้อม วัตถุประสงค์ ของการสร้างโครงข่ายประสาทเทียมคือ ให้มีความสามารถในการเรียนรู้การจดจำรูปแบบ (Pattern Recognition) และการสร้างความรู้ใหม่ (Knowledge Extraction) เช่นเดียวกับความสามารถที่มีใน สมองมนุษย์ แนวคิดเริ่มต้นของเทคนิคนี้ได้มาจากการศึกษาโครงข่ายไฟฟ้าชีวภาพ (Bioelectric Network) ในสมองซึ่งประกอบด้วย เซลล์ประสาท (Neurons) และ จุดประสานประสาท (Synapses) เป็นเสมือนชั้นขาเข้า (Input Layer) ในแต่ละเซลล์ประสาทประกอบด้วยปลายในการรับกระแส ประสาท เรียกว่า Dendrite เป็นเสมือนฟังก์ชันที่ใช้ในการคำนวณเพื่อตัดสินใจ และปลายในการส่ง กระแสประสาทเรียกว่า Axon ซึ่งเป็นเหมือนส่วนชั้นขาออก (Output) ของเซลล์ ดังที่ได้กล่าวไว้ แล้วในข้างต้น เซลล์เหล่านี้ทำงานด้วยปฏิกิริยาไฟฟ้าเคมี เมื่อมีการกระตุ้นด้วยสิ่งเร้าภายนอกหรือ กระตุ้นด้วยเซลล์ด้วยกัน กระแสประสาทจะวิ่งผ่าน Dendrite เข้าสู่นิวเคลียสซึ่งจะเป็นตัวตัดสินใจ ว่า ต้องกระตุ้นเซลล์อื่น ๆ ต่อหรือไม่ ถ้ากระแสประสาทแรงพอ นิวเคลียสก็จะกระตุ้นเซลล์อื่น ๆ ต่อไปผ่านทาง Axon ของมัน



ภาพที่ 3.7 แผนผังแนวคิดของเซลล์ประสาทเทียม

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับใช้ประโยชน์เพื่อการศึกษาเท่านั้น เมื่ออนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เมื่อหน่วยของเซลล์ประสาทเทียมได้รับการกระตุ้นจากสิ่งแวดลอม โครงข่ายประสาทเทียม เรียนรู้โดยการปรับเปลี่ยนของค่าความแรงของ Synapses ซึ่งปกติแล้วการเรียนรู้ต้องผ่านการ นำเสนอผลการทดลองการทำซ้ำหลายชุดของรูปแบบการป้อนข้อมูล การเรียนรู้จะมีฟังก์ชันหลาย ประเภทซึ่งแต่ละฟังก์ชันการทำงานจะเฉพาะเจาะจง และจะใช้กับสถาปัตยกรรมเฉพาะ โดยปกติ ทุกการเชื่อมต่อภายใน Synapses จะปรับเปลี่ยนไปตามกฎการเรียนรู้เดียวกัน นอกเหนือจาก ความสามารถในการเรียนรู้โดยอธิบายถึงตัวอย่าง (การเรียนรู้โดยการสาธิต) โครงข่ายประสาท เทียมเป็นที่นิยมมักจะอยู่ในการประยุกต์ทางวิศวกรรมที่มีคุณสมบัติดังต่อไปนี้

- Robustness โครงข่ายประสาทเทียมจะต้องมีประสิทธิภาพต่อภาวะของการลดทอนทาง สัญญาณ เช่น สัญญาณรบกวนของสัญญาณขาเข้า (Input) หรือการทำงานที่ผิดปกติของการ เชื่อมต่อ และการดำเนินงานของหน่วยในฮาร์ดแวร์ เมื่อระดับสัญญาณรบกวนมีปริมาณที่ เพิ่มขึ้น โครงข่ายประสาทจะแสดงผลลัพธ์ โดยการเพิ่มอัตราความผิดพลาดขึ้น หรือโดย การทำข้อผิดพลาดสำหรับรูปแบบการป้อนข้อมูล ในขณะที่ยังคงรักษาความถูกต้องของ การแสดงผลลัพธ์สำหรับรูปแบบอื่น ๆ ทั้งหมด นอกจากนี้โครงข่ายประสาทเทียมจะถูก ฝึกสอนแบบค่อยเป็นค่อยไปเพื่อชดเชยสัญญาณรบกวน หรือความเสียหายของ ส่วนประกอบอื่นๆ อีกด้วย
- Flexibility โครงข่ายประสาทเทียมจะไม่เฉพาะเจาะจงในโดเมนใดๆ โดยรูปแบบของ ระบบประสาทสามารถนำไปใช้หลายประเภทของปัญหา (อย่างไรก็ตามก็ไม่ได้หมายความว่า สามารถนำไปใช้ได้กับทุกปัญหาได้) โครงข่ายประสาทเทียมสามารถนำมาใช้เพื่อจัดการ กับปัญหาที่ไม่สามารถหาคำตอบได้ในเชิงการวิเคราะห์
- Generalization โครงข่ายประสาทเทียมที่ถูกฝึกอบรมในจำนวนครั้งที่จำกัด ความสามารถ นี้มาจากความจริงที่ว่าโครงข่ายประสาทเทียมเก็บข้อมูลของความสัมพันธ์ Input และ Output จำนวนมาก และมากกว่าจำนวนของน้ำหนัก
- Content-based retrieval โครงข่ายประสาทเทียมจะเรียกความทรงจำโดยการจับคู่เนื้อหา และสามารถทำได้แม้ในขณะที่รูปแบบการป้อนข้อมูลไม่ครบถ้วน จากความเสียหายจาก สัญญาณรบกวน ในแบบจำลองของระบบประสาทบางชนิดเช่นที่มาจากทฤษฎีคลื่น ปรับตัว (Grossberg 1987) กล่าวคือ ใช้การดึงลักษณะวิธีที่มนุษย์ทำงานแทนจะใช้ระบบ

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์หรือการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.3 โครงข่ายประสาทเทียมอย่างง่าย (Perceptron)

สำหรับในการจำลองโครงข่ายประสาทเทียมด้วยคอมพิวเตอร์ เซลล์ประสาทเทียม (Neurons) จะประกอบด้วยชั้นขาเข้า (Input) และ ชั้นขาออก (output) โดยจำลองให้ชั้นขาเข้าแต่ละอันมีน้ำหนักเป็นตัวกำหนดขนาดของชั้นขาเข้า มีเซลล์แต่ละหน่วยจะมีค่าขีดเริ่มเป็นตัวกำหนดว่า น้ำหนักรวมของชั้นขาเข้าต้องมากขนาดไหนจึงจะสามารถส่งชั้นขาออกไปยังเซลล์ตัวอื่นได้ เมื่อนำเซลล์แต่ละหน่วยมาต่อกันให้ทำงานร่วมกัน การทำงานนี้ในทางตรรกะแล้วก็จะเหมือนกับปฏิกิริยาเคมีที่เกิดในสมอง เพียงแต่ในคอมพิวเตอร์ทุกอย่างเป็นตัวเลขเท่านั้นเองดังภาพที่ 3.8



ภาพที่ 3.8 แผนผังของเซลล์ประสาทชีวภาพและเซลล์ประสาทเทียม [14]

เซลล์ประสาทเทียมถูกกำหนดโดยคุณลักษณะของชุดของเซลล์ประสาทเทียม (Neuron) โดยที่แต่ละเซลล์ที่มีขนาดมากพอที่จะส่งสัญญาณไปยังชั้นขาออก ผ่านค่าขีดเริ่มที่กำหนดด้วยฟังก์ชันการถ่ายโอนดังภาพที่ 3.9 ถึง 3.14 ถ้าเราไม่สนใจความล่าช้าของการส่งข้อมูล ผลลัพธ์ของสัญญาณที่ออกมาจากเซลล์ประสาทเทียม ของ \bar{x} บนเซลล์ประสาท Postsynaptic เท่ากับผลการคูณของ $\bar{w} \cdot \bar{x}$ โดยกำหนดให้ \bar{w} คือน้ำหนัก Synapses และสามารถเป็นค่าใดๆ ไม่ว่าจะเป็นค่าลบหรือค่าบวก โดยผลลัพธ์สามารถหาได้ตามสมการดังนี้

$$a_h = \sum_{i=1}^n x_i v_{ih} \quad (3.1)$$

โดยในแต่ละเซลล์ประสาทเทียมจะประกอบด้วยผลจากคูณข้างต้นแล้วผ่านฟังก์ชันการถ่ายโอนตามสมการ

$$y_h = f\left(\sum_{i=1}^n x_i v_{ih} - b_i\right) \quad (3.2)$$

ฟังก์ชันการถ่ายโอน $f(\bullet)$ จะอธิบายรายละเอียดการตอบสนองของเซลล์ประสาทและสามารถใช้รูปแบบที่แตกต่างกันหลายรูปแบบ โดยในรูปแบบดั้งเดิมที่จัดทำโดย McCulloch และ Pitts ขึ้นในปี 1943 เซลล์ประสาทเทียมแต่ละตัวมีผลลัพธ์แบบไบนารี (0 หรือ 1) ดังสมการ (3.3) ทำให้ค่าขีดเริ่มที่ใช้เป็นตัวกำหนดเขตยากที่จะบอกว่าเซลล์ประสาทส่งสัญญาณหรือไม่

$$f(a_h) = \begin{cases} 1: \sum_{i=1}^n x_i v_{ih} - b_i \\ 0: \text{Otherwise} \end{cases} \quad (3.3)$$

และรูปแบบของฟังก์ชันการถ่ายโอนแบบสองขั้ว

$$f(a_h) = \begin{cases} 1: \sum_{i=1}^n x_i v_{ih} > b_i \\ -1: \text{Otherwise} \end{cases} \quad (3.4)$$

จากสมการ (3.4) ข้างต้นเซลล์ประสาทสามารถมีสถานะได้เพียงหนึ่งในสองสถานะเท่านั้น และสามารถส่งค่าสัญญาณเพียงหนึ่งบิตของข้อมูลเท่านั้น ในกรณีสำหรับฟังก์ชันการถ่ายโอนแบบต่อเนื่องก็จะทำให้เซลล์ประสาทสามารถอยู่ได้หลายสถานะ เช่นผลลัพธ์ของฟังก์ชันการถ่ายโอนแบบต่อเนื่องซึ่งจะเป็นจำนวนจริง ในด้านชีวภาพจำนวนที่ต่อเนื่องนี้ บ่งชี้ได้ว่าไม่ว่าจะเป็นอัตราการกระตุ้นของเซลล์ประสาทจะมีค่ามากกว่าช่วงเวลาสั้นหรือเป็นผลรวมของผล excitatory และ Inhibitory ของผลลัพธ์ของจำนวนของเซลล์ประสาททั้งหมดฟังก์ชันแบบต่อเนื่องอย่างง่ายสามารถทำแบบจำลองเชิงเส้นดังสมการ

$$f(a_h) = k a_h \quad (3.5)$$

โดยกำหนดให้ค่า k เป็นค่าคงที่ใดๆ ในสถานการณ์ที่ไม่อาจคาดเดา ค่าผลลัพธ์ของเซลล์ประสาทจะเพิ่มขึ้นไปเรื่อย ๆ จึงกำหนดขอบเขตของฟังก์ชันกระตุ้นนี้ให้อยู่ภายในช่วงเช่น $[0, 1]$ หรือ $[-1, 1]$ นอกจากนี้ยังมีฟังก์ชันถ่ายโอนแบบต่อเนื่อง และไม่เชิงเส้นที่ใช้กับสถาปัตยกรรมของระบบประสาทที่ซับซ้อน และหนึ่งในฟังก์ชันที่พบมากที่สุดคือฟังก์ชันซิกมอยด์ (Sigmoid) ดังสมการ (3.6)

$$f(a_h) = \frac{1}{1 + e^{-ka_h}} \quad (3.6)$$

โดยที่กำหนดให้ k เป็นปัจจัยสำหรับการปรับขนาดของความลาดเอียงแสดงในภาพที่ (สำหรับ $K \rightarrow 0$ ฟังก์ชันถ่ายโอนก็จะกลายเป็นฟังก์ชันเชิงเส้น และสำหรับ $K \rightarrow \infty$ ฟังก์ชันถ่ายโอนก็กลายเป็นฟังก์ชันสองระดับ) ฟังก์ชันซิกมอยด์ มีแนวโน้มจะเป็นฟังก์ชันแบบแบบต่อเนื่องจาก 0 ถึง 1 โดยมีฟังก์ชันที่คล้ายๆ กันคือ

$$f(a_h) = \tanh(kA) \quad (3.7)$$


และฟังก์ชันถ่ายโอนมีอยู่มากมายหลาย ๆ ชนิดด้วยกัน เช่น ฟังก์ชันถ่ายโอนแบบสองขั้ว (hard-limit) ฟังก์ชันถ่ายโอนแบบสองขั้วสมมาตร (Symmetric hard-limit) ฟังก์ชันถ่ายโอนแบบเชิงเส้น (linear) ฟังก์ชันถ่ายโอนแบบลอการิทึมซิกมอยด์ (Logarithmic sigmoid) ฟังก์ชันถ่ายโอนแบบไฮเพอร์บอริกแทนเจนต์ซิกมอยด์ หรือแทนเจนต์ซิกมอยด์ (Hyperbolic tangent sigmoid) และฟังก์ชันถ่ายโอนแบบเชิงเส้นจำกัดดังสมการ

$$f(a_h) = \begin{cases} -1 & : h \leq -1 \\ h & : -1 < h < 1 \\ 1 & : h \geq 1 \end{cases} \quad (3.8)$$

$$f(a_h) = \begin{cases} 0 & : h \leq 0 \\ h & : 0 < h < 1 \\ 1 & : h \geq 1 \end{cases}$$


ตัวอย่างลักษณะของแผนภูมิของฟังก์ชันถ่ายโอนมีดังนี้

ฟังก์ชันการถ่ายโอนแบบสองขั้ว




ภาพที่ 3.9 ฟังก์ชันการถ่ายโอนแบบสองขั้ว

ฟังก์ชันถ่ายโอนแบบเชิงเส้น



ภาพที่ 3.10 ฟังก์ชันถ่ายโอนแบบเชิงเส้น


ฟังก์ชันถ่ายโอนแบบลอกซิกมอยด์



ภาพที่ 3.11 ฟังก์ชันถ่ายโอนแบบลอกซิกมอยด์


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ฟังก์ชันถ้ายโอนแบบแทนซิกมอยด์



ภาพที่ 3.12 ฟังก์ชันถ้ายโอนแบบแทนซิกมอยด์

ฟังก์ชันถ้ายโอนแบบเชิงเส้นจำกัด



ภาพที่ 3.13 ฟังก์ชันถ้ายโอนแบบเชิงเส้นจำกัด

กระตุ้นการทำงานของเซลล์ประสาทเทียม จะแปรผันตรงกับความคล้ายคลึงกันระหว่าง
 เวกเตอร์นำหนัก w_i และเวกเตอร์อินพุต x_i ดังภาพที่ 3.14 โดยที่สามารถอธิบายเงื่อนไขได้ด้วย
 ฟังก์ชันเชิงเส้นถึงความคล้ายคลึงกันระหว่างเวกเตอร์ทั้งสองด้วยโคไซน์ของมุม θ ระหว่าง
 เวกเตอร์


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$\cos \beta = \frac{\vec{w} \cdot \vec{x}}{\|\vec{w}\| \|\vec{x}\|}, 0 \leq \beta \leq \pi \quad (3.9)$$

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

$$y = \vec{w} \cdot \vec{x} = \|\vec{w}\| \|\vec{x}\| \cos \beta \quad (3.10)$$


กล่าวคือหากว่าความยาวของเวกเตอร์ทั้งสอง (เวกเตอร์น้ำหนัก w และเวกเตอร์อินพุต x) มีค่าคงที่ ผลลัพธ์ของการเปลี่ยนแปลงเซลล์ประสาทเทียมคือมุมโคไซน์ระหว่างทั้งสองเวกเตอร์ ขนาดของมุมโคไซน์คือสัดส่วนผกผันกับระยะทางเชิงมุมระหว่างชั้นขาเข้า และเวกเตอร์น้ำหนักที่อยู่ในด้านเดียวกัน ซึ่งชั้นขาออกจะมีขนาดเล็กที่สุดเมื่อทั้งสองเวกเตอร์ตั้งฉาก ($\cos 90^\circ = 0$) และจะมีขนาดใหญ่ที่สุดเมื่อทั้งสองเวกเตอร์ในแนวเดียวกัน ($\cos 0^\circ = 1$) โดยในระบบโครงข่ายประสาทเทียมที่มีชั้นขาออกหลายเซลล์ ระดับของการเปิดใช้งานจะเป็นกำหนดว่า เซลล์ประสาทเทียมเซลล์ไหนมีน้ำหนักใกล้เคียงกับรูปแบบของเวกเตอร์ในชั้นขาเข้า (ซึ่งต้องมีความยาวเวกเตอร์เท่ากัน) ถ้าสมมุติให้ฟังก์ชันการเปิดใช้งานเป็นแบบไปนารี ดังนั้นในเซลล์ชั้นขาออก สามารถใช้ในการแยกแยะระหว่างสองชั้นของเวกเตอร์ชั้นขาเข้า ซึ่งจะขึ้นอยู่กับระยะทางเชิงมุมว่ามีขนาดเล็กกว่า 90 องศาหรือระยะทางเชิงมุมว่ามีขนาดใหญ่กว่า 90 องศา ระหว่างเวกเตอร์ชั้นขาเข้าเวกเตอร์น้ำหนักในแต่ละเซลล์ดังภาพที่ 3.14




ภาพที่ 3.14 การหาว่าความยาวของเวกเตอร์น้ำหนัก [14]

จากภาพที่ 3.15 เส้นการแบ่ง (สายหนา) ของพื้นที่ชั้นขาเข้าโดยเซลล์ประสาทเทียมมีสองชั้นขาออก เอกสารนี้ (โดยทั้งสองชุดตั้งค่าขีดเริ่มไว้ที่ 1) มักจะตั้งฉากกับเวกเตอร์น้ำหนักของเซลล์ประสาทเทียมส่วนนี้ ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เส้นบางๆ คือตัวอย่างที่แสดงให้เห็นถึงการกระจายของจุดข้อมูล ซึ่งเซลล์ประสาทเทียมจะเห็นความแตกต่าง โดยการตอบสนองที่แตกต่างกันขึ้นอยู่กับชั้นขาเข้าว่า จะอยู่เหนือหรือใต้เส้นแบ่งข้อมูล โดยรูป a มีค่าขีดเริ่มกำหนดให้ 1 และรูป b มีค่าขีดเริ่มกำหนดให้เป็น 0 เรียกรูปแบบเซลล์นี้ว่า linearly separable โดยทั่วไปมักใช้กับเพอร์เซพตรอนชั้นเดียว ซึ่งเพอร์เซพตรอนชั้นเดียว (Single layer perceptron) ดังภาพที่ 3.16 ประกอบไปด้วยเซลล์ประสาท 1 เซลล์มีฟังก์ชันถ่ายโอนแบบสองขั้วด้วยการตั้งค่าขีดเริ่ม (Threshold) และค่าผลลัพธ์แบบไบนารีในชั้นขาออก โดยที่โครงสร้างการทำงานคือ เซลล์แต่ละตัวจะคำนวณผลรวมถ่วงน้ำหนักจากชั้นขาเข้า ซึ่งก็คือผลรวมของผลคูณระหว่างค่าข้อมูลในชั้นขาเข้ากับค่าน้ำหนักที่เชื่อมโยงไปยังเซลล์แต่ละตัว ถ้าค่าที่ได้จากการคำนวณนี้มีค่ามากกว่าเส้นของค่าขีดเริ่ม (Threshold) เซลล์ประสาทเทียมก็จะให้ค่าเอาต์พุตเท่ากับ 1 ถ้าน้อยกว่าก็จะให้ค่า 0 เพื่อให้ง่ายจึงมักจะกำหนดให้ขีดแบ่ง เป็นค่าน้ำหนักตัวหนึ่งของชั้นขาเข้าเป็นค่าคงที่ โดยฟังก์ชันค่าขีดแบ่งจะมีศูนย์กลางและทำการแบ่งแยกเชิงเส้นเพื่อทำการแบ่งพื้นที่ออกเป็นสองส่วนหรือสองกลุ่ม การปรับค่าน้ำหนัก ส่วนใหญ่ถูกใช้งานสำหรับแก้ปัญหาในการจำแนกประเภทตามรูปแบบ (Pattern Classification) การสอนข่ายงานเพอร์เซพตรอนชั้นเดียวสามารถทำให้เกิดการตัดสินใจแบบเส้นตรง หรือ Hyper plane ที่รอยต่อระหว่างกลุ่มสองกลุ่มที่ทำให้กลุ่มทั้งสองกลุ่มนั้นแยกออกจากกัน เรียกว่า two linearly separable classes โดยที่ข้อจำกัดของเพอร์เซพตรอนชั้นเดียวคือ ไม่สามารถจำแนกกลุ่ม (classes) ครั้งละมากกว่าสองกลุ่มได้



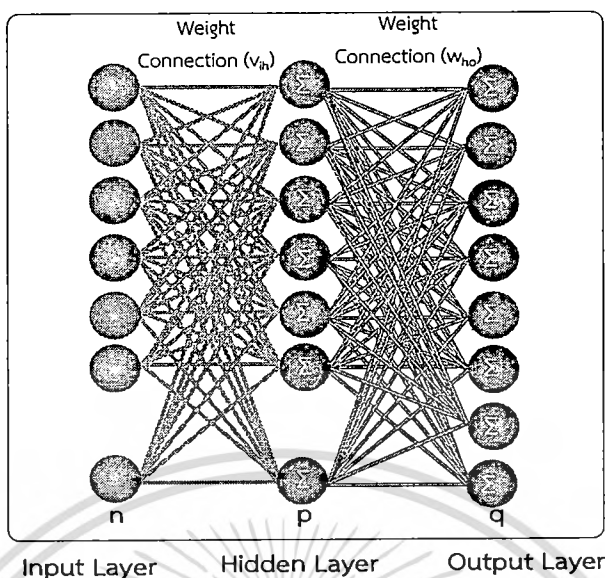
ภาพที่ 3.15 การเรียนรู้แบบเพอร์เซพตรอนชั้นเดียว [14]



ภาพที่ 3.16 ตัวแบบเพอร์เซพตรอนชั้นเดียว

3.4 โครงข่ายประสาทเทียมแบบหลายชั้น (Multi-layer Perceptron)

โครงข่ายประสาทเทียมแบบ Multi-layer Perceptron เป็นรูปแบบหนึ่งของโครงข่ายประสาทเทียมที่มีโครงสร้างเป็นแบบหลายๆชั้น ดังภาพที่ 3.17 ใช้สำหรับงานที่มีความซับซ้อนได้ผลเป็นอย่างดี โดยมีกระบวนการฝึกฝนเป็นแบบมีผู้สอน (Supervise) และโครงข่ายประสาทเทียมมี 2 ขั้นตอนการทำงานหลัก ๆ คือ การป้อนไปข้างหน้า (Feed Forward) และการแพร่ย้อนกลับ (BackPropagate) สำหรับการป้อนไปข้างหน้า ข้อมูลจะผ่านเข้าโครงข่ายประสาทเทียมที่ชั้นขาเข้า และจะส่งผ่านจากอีกชั้นหนึ่งไปสู่อีกชั้นหนึ่งจนกระทั่งถึงชั้นขาออก ส่วนการแพร่ย้อนกลับค่านำหน้าการเชื่อมต่อจะถูกปรับเปลี่ยนให้สอดคล้องกับกฎการแก้ข้อผิดพลาด (Error-Correction) คือผลต่างของผลตอบที่แท้จริง (Actual Response) กับผลตอบเป้าหมาย (Target Response) เกิดเป็นสัญญาณผิดพลาด (Error Signal) ซึ่งสัญญาณผิดพลาดนี้จะถูกส่งย้อนกลับเข้าสู่โครงข่ายประสาทเทียมเรียกว่ากระบวนการแพร่ย้อนกลับ (BackPropagate) ในทิศทางตรงกันข้ามกับการเชื่อมต่อและค่านำหน้าของการเชื่อมต่อจะถูกปรับจนกระทั่งผลตอบที่แท้จริงเข้าใกล้ผลตอบเป้าหมาย



ภาพที่ 3.17 โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN)

สัญญาณที่มีโครงข่ายประสาทเทียมแบบหลายชั้นมี 2 ประเภทคือ Function Signal และ Error

Signal

- Function Signal เป็นสัญญาณเข้าที่มาจากนิวรอนในชั้นก่อนหน้า และจะส่งผ่านไปข้างหน้าจากนิวรอนหนึ่งไปสู่อีกนิวรอนหนึ่ง
- Error Signal เป็นสัญญาณย้อนกลับที่เกิดขึ้นที่นิวรอนในชั้นข้อมูลออกของโครงข่ายประสาทเทียม และถูกส่งผ่านย้อนกลับจากชั้นหนึ่งไปสู่อีกชั้นหนึ่ง

หลักการทำงานของโครงข่ายประสาทเทียมแบบหลายชั้นคือ ในแต่ละชั้นของชั้นซ่อนตัว (Hidden Layer) จะมีฟังก์ชันสำหรับคำนวณเมื่อได้รับสัญญาณ (Output) จากนิวรอนในชั้นก่อนหน้า นี้ เรียกว่า Activation Function โดยในแต่ละชั้นไม่จำเป็นต้องเป็นฟังก์ชันเดียวกันก็ได้ ชั้นซ่อนตัวนั้นมีหน้าที่สำคัญคือ จะพยายามแปลงข้อมูลที่เข้ามาในชั้น (Layer) นั้น ๆ ให้สามารถแยกแยะความแตกต่างโดยใช้เส้นตรงเส้นเดียว (Linearly Separable) และก่อนที่ข้อมูลจะถูกส่งไปถึงชั้นข้อมูลออก (Output Layer) ในบางครั้งอาจจำเป็นต้องใช้ชั้นซ่อนตัวมากกว่า 1 ชั้นในการแปลงข้อมูลให้อยู่ในรูป Linearly Separable

ในการคำนวณหาผลลัพธ์ของปัญหาการจำแนกทำได้โดยการใส่ข้อมูลชั้นขาเข้า ไปในโครงข่ายประสาทเทียมที่เราได้ทำการหาไว้แล้ว จากนั้นให้ทำการเปรียบเทียบค่าของผลลัพธ์ในชั้น

เอกสารนี้ขาออก และให้ทำการเลือกค่าของผลลัพธ์ที่มีค่าสูงกว่า (เซลล์ประสาทเทียมที่มีค่าสูงกว่า) และทำไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การรับค่าของพยากรณ์ที่ตรงกับเซลล์ที่เลือก และให้นำค่าของผลลัพธ์มาเปรียบเทียบกับค่าที่ยอมรับได้ หากค่าของอยู่ในช่วงที่รับได้ (Error น้อยกว่า Error ที่เรากำหนด) ก็ให้ทำการรับข้อมูลชุดถัดไป แต่หากค่าของผลลัพธ์มากกว่าค่าที่ยอมรับได้ ให้ทำการปรับค่าน้ำหนักตามขั้นตอนที่ได้กล่าวไว้ข้างต้น เมื่อทำการปรับน้ำหนักเรียบร้อยแล้ว ให้ทำการรับข้อมูลชุดถัดไปและทำตามขั้นตอนซ้ำอีกรอบจนกระทั่งถึงข้อมูลชุดสุดท้าย และเมื่อทำข้อมูลชุดสุดท้ายเสร็จจะนับเป็น 1 รอบของการคำนวณ (1 Epoch) จากนั้นจะทำการหาค่าผิดพลาดรวมเฉลี่ย จากค่าเฉลี่ยของ ที่ได้เก็บค่าเอาไว้เพื่อใช้ในการตรวจสอบว่าค่า โดยเฉลี่ยในการจำแนกนั้น มีค่าน้อยกว่าค่าผิดพลาดที่ยอมรับได้หรือไม่ ถ้าใช่แสดงว่าโครงข่ายประสาทเทียมที่สร้างขึ้นนั้นสามารถให้ผลลัพธ์ที่ถูกต้องของทุกๆข้อมูลแล้ว จึงทำการจบการเรียนรู้ได้ แต่ถ้าไม่ใช่ ให้กลับไปทำตามขั้นตอนแรก โดยเริ่มรับข้อมูลชุดที่ 1 ใหม่

3.5 โครงสร้างของโครงข่ายประสาทเทียมที่นำเสนอในงานวิจัย

พื้นฐานโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (Back Propagation Neural Network, BPNN) เป็นระบบคณิตศาสตร์ที่ใช้ต้นแบบจากโครงข่ายประสาทของสิ่งมีชีวิต โดยมีการเชื่อมกันระหว่างเซลล์ประสาทเทียม (Neuron) โครงสร้างของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN) ที่ใช้ในโครงการวิจัยนี้ประกอบด้วยสามชั้นดังนี้ ชั้นขาเข้า (Input Layer) ชั้นซ่อน (Hidden Layer) และชั้นขาออก (Output Layer) ดังแสดงในภาพที่ 3.17 และทุกชั้นจะประกอบด้วยเซลล์ประสาทเทียมหลายตัว โดยกำหนดให้ n , p และ q เป็นจำนวนเซลล์ของชั้นขาเข้า ชั้นซ่อน และชั้นขาออก ตามลำดับ ในที่นี้ n เป็นจำนวนข้อมูลของสัญญาณการเคลื่อนไหว และ q เป็นจำนวนรูปแบบของสัญญาณที่ต้องจดจำ ประสิทธิภาพของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับนี้จะขึ้นอยู่กับ การเลือกจำนวนเซลล์ประสาทเทียมของชั้นซ่อน (p) ถ้า p มีจำนวนน้อยจะทำให้เกิดปัญหาที่เรียกว่า Under Fitting ซึ่งเป็นปัญหาที่เกิดขึ้นเมื่อจำนวนเซลล์ในชั้นซ่อนมีค่าน้อยและไม่พอเพียงที่จะตรวจจับรูปแบบสัญญาณที่มีความซับซ้อนของสัญญาณขาเข้าได้ ในทางตรงข้ามหากจำนวน p มีค่ามากก็อาจนำไปสู่ปัญหาใหญ่สองประการคือ โครงข่ายประสาทเทียมจะใช้เวลาในการเรียนรู้จดจำรูปแบบของสัญญาณนานมาก ประการต่อมาจะเกิดปัญหาที่เรียกว่า Over Fitting ซึ่งปัญหานี้จะเกิดขึ้นเมื่อ โครงข่ายประสาทเทียมใช้หน่วยความจำมากเพื่อการประมวลผลสัญญาณ แต่ไม่มีสัญญาณเพียงพอที่จะสอนเซลล์ทุกตัวในชั้นซ่อนได้

ในแต่ละเซลล์ประสาทเทียมของแต่ละชั้น ในโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN) จะถูกเชื่อมซึ่งกันและกัน แต่ละเส้นเชื่อมมีน้ำหนักเป็นตัวกำหนดขนาด โดยน้ำหนักในแต่ละเส้นเชื่อมจะถูกเก็บในหน่วยความจำของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN) โดยโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN) มี 2 ขั้นตอนการทำงานหลักๆ ดังนี้ การป้อนไปข้างหน้า (Feed Forward) แพร่ย้อนกลับ (BackPropagate)

ในขั้นตอนของการป้อนไปข้างหน้า (Feed Forward) คุณลักษณะของ n จะถูกป้อนเข้าไปในชั้นของชั้นขาเข้า จากนั้นผลลัพธ์ของชั้นซ่อนและชั้นของขาออกสามารถคำนวณได้ดังสมการ (3.11) และ (3.12)

$$y_h = f_{\text{sig}} \left(\sum_{i=1}^n x_i v_{ih} \right), \quad (3.11)$$

$$z_o = f_{\text{sig}} \left(\sum_{h=1}^p y_h w_{ho} \right), \quad (3.12)$$

ตามลำดับ กำหนดให้ $f_{\text{sig}}(x) = (1 + e^{-x})^{-1}$ 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} และ ชั้นเซลล์ของชั้นขาออก ลำดับที่ o^{th} และสุดท้าย z_o คือค่าเซลล์ของชั้นขาออก

น้ำหนักของเส้นเชื่อมต่อทุกเส้นสามารถปรับ โดยอาศัยการแพร่ย้อนกลับจากชั้นขาออกไปยังชั้นขาเข้าเพื่อให้ได้ค่าผิดพลาด (Error) ที่กำหนดไว้ดังสมการ (3.13), (3.14), (3.15) และ (3.16)

$$w_{ho}^{\text{new}} = w_{ho}^{\text{old}} + \eta \sum \delta_o y_h, \quad (3.13)$$

$$\delta_o = z_o (1 - z_o)(b_o - z_o), \quad (3.14)$$


$$v_{ih}^{\text{new}} = v_{ih}^{\text{old}} + \eta \sum \delta_h x_i, \quad (3.15)$$

$$\delta_h = y_h (1 - y_h) \sum_{h=1}^q w_{ho} \delta_o, \quad (3.16)$$

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

กระบวนการคิดแบบ Winner-Take-All

การฝึกสอนโครงข่ายประสาทเทียมเพื่อให้เซลล์ประสาทเทียม จัดจำรูปแบบของสัญญาณรูปแบบตามสัญญาณชั้นขาเข้า โดยกำหนดให้ชั้นขาออกเป็น 1 (เปิดใช้งาน) ที่เหลือเป็น 0 (ปิดใช้งาน) (โดยสมมุติให้ชั้นขาออกประกอบด้วย 2 เซลล์) เป็นตัวแทนของรูปแบบที่ใช้ในการจดจำ ในขณะที่เซลล์ชั้นขาออกตัวไหนเป็น 1 ก็จะได้ว่าเป็นการกำหนดให้เป็นรูปแบบนั้นๆ ตามรูปแบบของสัญญาณชั้นขาเข้า จึงเรียกรูปแบบนี้ว่า “Winner-Take-All” ตัวอย่างโครงสร้างของกระบวนการคิดแบบ Winner-Take-All ดังภาพที่ 3.18



ภาพที่ 3.18 โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN) โดยใช้ Winner-Take-All

3.6 การฝึกสอนและการเรียนรู้ของโครงข่ายประสาทเทียม

3.6.1 การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning)

โครงข่ายประสาทเทียมที่ใช้การเรียนรู้แบบไม่มีผู้สอน จะเริ่มด้วยการเรียนรู้คุณสมบัติบางอย่างของการกระจายของรูปแบบอินพุตโดยไม่ได้ส่งค่าตอบสนองกลับใด ๆ จากผู้ใช้ ซึ่งโดยทั่วไปแล้วการเรียนรู้แบบไม่มีผู้สอนจะประกอบด้วยหลักสำคัญดังนี้

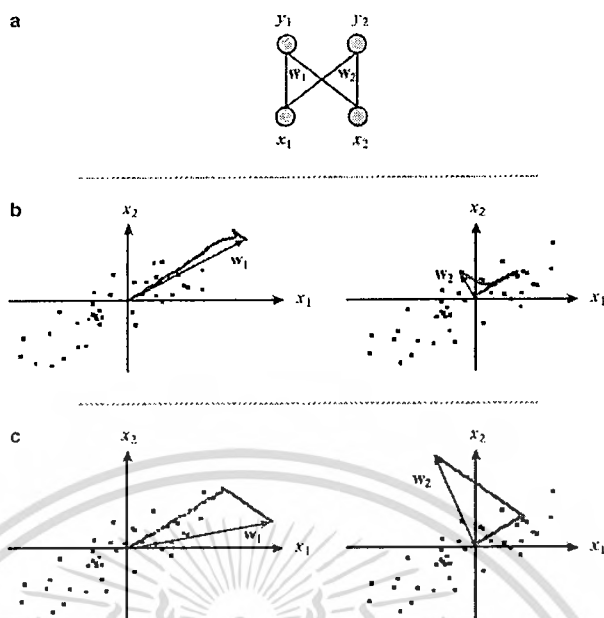
- การสกัดของข้อมูล เช่นการตรวจสอบคุณสมบัติทั่วไปหรือคุณสมบัติที่โดดเด่นที่

เอกสารนี้เป็นเอกสารที่ช่วยให้โครงข่ายจำแนกรูปแบบของชั้นขาเข้า ซึ่งจากแบบจำลองทางคณิตศาสตร์ ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ของการเรียนรู้แบบไม่มีผู้สอนจะใช้หลักสถิติ เช่นการคำนวณของความสัมพันธ์
 ดัชนีประมาณค่าพารามิเตอร์ของฟังก์ชันความหนาแน่นของความน่าจะเป็น จาก
 รูปแบบของการป้อนข้อมูลและการวิเคราะห์องค์ประกอบหลัก เพื่อที่จะทำให้การ
 ดำเนินการเหล่านั้นแจ่มแจ้งรูปแบบของชั้นขาเข้าให้มีประสิทธิภาพ ชั้นขาเข้า
 จะต้องมีความซ้ำซ้อนของข้อมูลเพื่อให้ในการตรวจสอบของโครงสร้างให้ดีขึ้น การ
 แยกองค์ประกอบหลักเป็นความสำคัญลำดับแรกของการพิจารณาการกระจายดัง
 สมการ (3.17)

$$\Delta w_{ij} = \eta y_i (x_j - \sum_{k=1}^N w_{kj} y_k), \quad (3.17)$$

โดยกำหนดให้ i และ k คือดัชนีที่ชี้ไปยังส่วนเอาต์พุตทั้งสอง ส่วนพจน์
 $\sum_{k=1}^N w_{kj} y_k$ นี้จะพิจารณาถึงน้ำหนักทั้งหมดของโครงข่าย ซึ่งจากภาพที่ 3.20 การ
 สกัดคุณลักษณะเด่นขององค์ประกอบหลักของการกระจายรูปแบบของชั้นขาเข้าด้วย
 สองชั้นขาออก โดยที่ภาพ (a) แสดงถึงโครงข่ายประสาท ส่วนภาพ (b) และ (c)
 แสดงถึงการปรับเปลี่ยนของน้ำหนักเวกเตอร์ของโครงข่ายประสาทเทียม โดยที่ภาพ
 (b) จะแสดงถึงอินพุตที่ได้ผ่านการฝึกสอนด้วยกฎ Oja สำหรับ N เอาต์พุตดังสมการ
 ส่วน (c) แสดงถึงแสดงถึงการปรับเปลี่ยนของน้ำหนักเวกเตอร์ของอินพุตที่ได้ผ่าน
 การฝึกสอนด้วยกฎ Sanger สำหรับ N เอาต์พุตดังสมการ



ภาพที่ 3.19 โครงข่ายประสาทเทียมที่ใช้การเรียนรู้แบบ Oja และ Sanger [14]

- การสกัดของข้อมูลแบบหลายชั้น สถาปัตยกรรมประยุกต์ของรูปแบบหลายชั้นโดย Linsker แต่ละชั้นจะถูกจัดเป็นเมทริกซ์ 2D ของเซลล์ประสาทเทียมที่มีการเชื่อมต่อด้วยความน่าจะเป็นของ Neurons ชั้นก่อนหน้านี้จะอธิบายโดยการกระจายของแบบ Gaussian 2D สมการ (3.18)

$$y_i = k_1 \sum_j w_{ij} x_j, \quad (3.18)$$

และใช้สมการของกระบวนการเรียนรู้ดังสมการ (3.19)

$$\Delta w_{ij} = k_2 y_i x_j + k_3 x_j + k_4 y_i + k_5, \quad (3.19)$$

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

3.6.2 การเรียนรู้แบบมีผู้สอน (Supervised Learning)

เป็นการเรียนรู้แบบที่มีการตรวจคำตอบเพื่อให้โครงข่ายประสาทเทียมปรับตัว ชุดข้อมูลที่ ใช้สอน โครงข่ายประสาทเทียมจะมีคำตอบไว้คอยตรวจดูว่าโครงข่ายประสาทเทียมให้คำตอบที่ ถูก หรือไม่ ถ้าตอบไม่ถูก โครงข่ายประสาทเทียมก็จะปรับตัวเองเพื่อให้ได้คำตอบที่ดีขึ้น (เปรียบเทียบ กับ โจทย์ทางคณิตศาสตร์ ที่มีการเฉลยคำตอบเพื่อให้ผู้ทำให้เปรียบเทียบว่าถูกต้องหรือไม่)

กำหนดให้ b_{k_o} และ z_{k_o} เป็นค่ากำหนดและค่าที่ได้จริงของเซลล์ประสาทเทียมในชั้นขาออก ตามลำดับ สำหรับการตรวจสอบค่าที่สอนนั้นจะตรวจสอบค่าตามสมการ (3.20) โดยกำหนดให้ k คือลำดับของกิจกรรมในชั้นขาออก $b_{k_o} = 1$ ที่ค่า $k = o$ และนอกเหนือจากนี้ให้ $b_{k_o} = 0$ ค่าผิดพลาด ของชั้นตอนป้อนไปข้างหน้า (Feed Forward) ของรูปแบบที่ k^{th} ได้ตามสมการ (3.20)

$$E_k = 0.5 \sum_{o=1}^q (b_{k_o} - z_{k_o})^2, \quad (3.20)$$

กำหนดให้ k เป็นค่าที่อยู่ในช่วง $\{1, 2, \dots, q\}$

ในขั้นตอนการเรียนรู้ ลำดับแรกน้ำหนักทุกตัวจะถูกสุ่มเพื่อกำหนดค่าเริ่มต้น z_{k_o} จะถูก คำนวณจากชั้นตอนของกระบวนการป้อนไปข้างหน้า (Feed Forward) และค่าผิดพลาดของแต่ละ รูปแบบก็จะคำนวณจากสมการที่ 3.20 ลำดับต่อมา ทุกตัวของน้ำหนักจะถูกปรับจนกว่าค่าของค่า ผิดพลาดจะเข้าสู่ศูนย์หรือเข้าค่าที่กำหนด โดยใช้กระบวนการแพร่ย้อนกลับ (BackPropagate)

โครงการวิจัยนี้ได้ใช้วิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับด้วยชั้นซ่อนจำนวน 1 ชั้น และได้นำเสนอการเรียนรู้อในการจดจำในรูปแบบต่างๆ ของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับเพื่อหาการเรียนรู้อที่เหมาะสมที่สุดและใช้เวลาในการประมวลผลเร็วที่สุด ซึ่งมีดังต่อไปนี้

1. Gradient Descent
2. Gradient Descent with Momentum
3. Variable Learning Rate Backpropagation algorithm
4. Variable Learning Rate with Momentum Backpropagation algorithm
5. Resilient Backpropagation algorithm
6. Fletcher-Reeve Conjugate Gradient algorithm

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

7. Polak-Ribière Conjugate Gradient algorithm
8. Scaled Conjugate Gradient algorithm
9. Conjugate Gradient with Powell/Beale Restarts algorithm
10. BFGS Quasi-Newton algorithm
11. One-Step Secant algorithm
12. Levenberg-Marquardt algorithm

โดยแต่ละวิธีการเรียนรู้ก็จะมีข้อดีข้อเสียแตกต่างกันไปตามแต่ลักษณะการใช้งานซึ่งมีรายละเอียดดังนี้

3.6.2.1 การเรียนรู้แบบ Gradient Descent

การเรียนรู้แบบ Gradient Descent จะมีการปรับน้ำหนักทุก ๆ ครั้งเมื่อทศของ Gradient เป็นลบ โดยจะต้องตั้งค่าเริ่มต้นให้โครงข่ายประสาทเทียมมีการเรียนรู้ดังนี้

- จำนวนรอบของการปรับน้ำหนัก
- ค่าสัญญาณขาออกเป้าหมาย
- ค่าต่ำสุดของ Gradient
- อัตราการเรียนรู้เริ่มต้น

และมีสมการในการปรับค่าน้ำหนักในแต่ละรอบของการคำนวณดังนี้

$$w_{ho}^{new} = w_{ho}^{old} + \eta \sum \delta_o y_h, \quad (3.21)$$

$$\delta_o = z_o (1 - z_o) (b_o - z_o), \quad (3.22)$$

$$v_{ih}^{new} = v_{ih}^{old} + \eta \sum \delta_h x_i, \quad (3.23)$$

$$\delta_h = y_h (1 - y_h) \sum_{h=1}^q w_{ho} \delta_o, \quad (3.24)$$

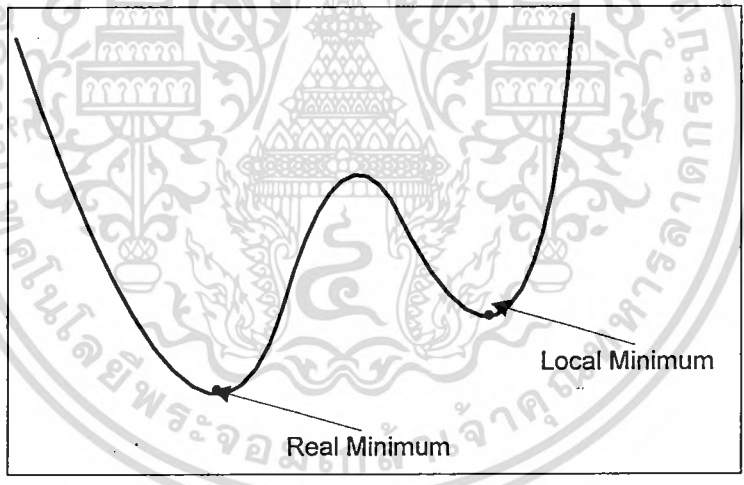
โดยกำหนดให้ w_{ho}^{new} และ v_{ih}^{new} คือค่าน้ำหนักใหม่ที่ถูกปรับในแต่ละรอบของการเรียนรู้ของโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับในชั้นซ่อนและชั้นของขาออกตามลำดับ และ

เอกสารนี้ w_{ho}^{old} และ v_{ih}^{old} คือค่าน้ำหนักในแต่ละรอบก่อนหน้านั้นในชั้นซ่อนและชั้นของขาออกตามลำดับ δ_o ค่า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

และ δ_n เป็นค่า Gradient ในชั้นซ่อนและชั้นของขาออกตามลำดับ และ η เป็นค่าอัตราการเรียนรู้ซึ่งปกติแล้วมีค่าอยู่ระหว่าง 0 ถึง 1 ซึ่งอัตราการเรียนรู้จะเป็นตัวบ่งชี้ระดับการปรับเปลี่ยนว่าจะเข้าสู่คำตอบเป็นอย่างไร ซึ่งอาจจะทำให้โครงข่ายประสาทเทียมเกิดไม่เสถียรขึ้น ถ้าหากมีการตั้งค่าอัตราการเรียนรู้ที่สูงเกินไป และโครงข่ายประสาทเทียมอาจจะต้องใช้เวลาในการประมวลผลนาน หากตั้งค่าอัตราการเรียนรู้ต่ำเกินไป

3.6.2.2 การเรียนรู้แบบ Gradient Descent with Momentum

ข้อเสียของการเรียนรู้แบบ Gradient Descent คืออาจจะเจอปัญหาที่เรียกว่า Local minimum ดังภาพที่ 3.20 ซึ่งเป็นตำแหน่งของค่าความผิดพลาด (Error) ต่ำสุดเทียม เพราะฉะนั้นเพื่อขจัดปัญหาดังกล่าวจึงใช้ Momentum ซึ่งสามารถเพิ่มการเรียนรู้ให้โครงข่ายประสาทเทียมมีประสิทธิภาพเพิ่มมากขึ้นด้วยการตรวจสอบการเปลี่ยนแปลงของค่าน้ำหนัก



ภาพที่ 3.20 แสดงปัญหาจุดต่ำสุดเทียม (Local Minimum)

การตรวจสอบการเปลี่ยนแปลงของค่าน้ำหนักในรอบการคำนวณในปัจจุบันและรอบการคำนวณก่อนหน้า Δw_{ho}^{old} ว่ามีการเปลี่ยนแปลงเท่าไรนั้นสามารถบ่งชี้ถึงการปรับปรุงค่าน้ำหนักใหม่ (α)ว่าจะอยู่ในทิศทางไหน ซึ่งปกติแล้วจะใช้ค่าคงที่ (สามารถกำหนดค่าเริ่มต้นของ α อยู่ในช่วง 0 ถึง 1) มาคูณกับค่าการเปลี่ยนแปลงของน้ำหนักเพื่อใช้ในการปรับปรุงค่าน้ำหนักใหม่ ซึ่งสมการในการปรับค่าน้ำหนักในแต่ละรอบของการคำนวณจึงมีการเพิ่มเติมจากเดิมดังนี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$w_{ho}^{new} = w_{ho}^{old} + \eta \sum \delta_o y_h + \alpha \Delta w_{ho}^{old}, \quad (3.25)$$

$$\delta_o = z_o (1 - z_o)(b_o - z_o), \quad (3.26)$$

$$v_{ih}^{new} = v_{ih}^{old} + \eta \sum \delta_h x_i + \alpha \Delta v_{ih}^{old}, \quad (3.27)$$

$$\delta_h = y_h (1 - y_h) \sum_{h=1}^q w_{ho} \delta_o, \quad (3.28)$$

3.6.2.3 การเรียนรู้แบบ Variable Learning Rate

เป็นอัลกอริทึมที่ผลลัพธ์มีการเปลี่ยนแปลงอย่างมาก ต่อการตั้งค่าเริ่มต้นของอัตราการเรียนรู้ กล่าวคือหากตั้งค่าอัตราการเรียนรู้สูงเกินไปจะทำให้ผลลัพธ์เบนออกไปจากความถูกต้องและท้ายสุดไม่สามารถหาคำตอบได้ แต่หากตั้งค่าอัตราการเรียนรู้ต่ำเกินไปจะทำให้ใช้เวลาในการหาผลลัพธ์ที่ถูกต้องนานเกินไป ซึ่งในทางปฏิบัติไม่สามารถหาค่าที่เหมาะสมสำหรับการทดลองได้ เว้นแต่ว่าจะต้องทำการทดลองป้อนอินพุตให้กับระบบโดยใช้สมการดังนี้ (ใช้สมการแบบไม่มี Momentum)

$$w_{ho}^{new} = w_{ho}^{old} + \beta \sum \delta_o y_h, \quad (3.29)$$

$$v_{ih}^{new} = v_{ih}^{old} + \beta \sum \delta_h x_i, \quad (3.30)$$

$$\beta = \mu \times \eta \quad (3.31)$$

และใช้สมการแบบมี Momentum

$$w_{ho}^{new} = w_{ho}^{old} + \beta \sum \delta_o y_h + \alpha \Delta w_{ho}^{old}, \quad (3.32)$$

$$v_{ih}^{new} = v_{ih}^{old} + \beta \sum \delta_h x_i + \alpha \Delta v_{ih}^{old}, \quad (3.33)$$

$$\beta \equiv \mu \times \eta, \quad (3.34)$$

โดยกำหนดให้ β คือ ค่าคงที่ (μ) คูณด้วยอัตราการเรียนรู้ (η) ซึ่งในแต่ละรอบจะมีการปรับเปลี่ยนตามความเหมาะสม กล่าวคือถ้าหากว่าค่าอัตราการเรียนรู้ของรอบปัจจุบันของการเรียนรู้ (Learning) ทำให้ความผิดพลาด (Error) มากกว่ารอบที่แล้ว โดยส่วนใหญ่แล้วจะมากกว่าค่าเดิมที่ (1.04 เท่าของ Error เดิม) ระบบก็จะทำการยกเลิกน้ำหนักที่ปรับไปในรอบนั้นไป และจะทำการทดลองใหม่โดยการปรับลดค่าอัตราการเรียนรู้ใหม่ (โดยทั่วไปแล้วจะคูณด้วย 0.7) และในทางกลับกันถ้าหากค่าอัตราการเรียนรู้ทำให้ค่าความผิดพลาด (Error) น้อยกว่ารอบที่แล้ว ระบบจะเก็บค่าน้ำหนักและผลลัพธ์ที่ได้ และทำการเพิ่มค่าอัตราการเรียนรู้ขึ้น (โดยทั่วไปแล้วจะคูณด้วย 1.05) และต่อเนื่องไปจนถึงได้ค่าความผิดพลาด (Error) ที่น้อยที่สุดตามที่ตั้งไว้ โดยทั้งนี้ให้ทดลองก่อนและค่อยๆ เรียนรู้และปรับค่าอัตราการเรียนรู้ (η) ที่เหมาะสมไปเรื่อยๆ จนกว่าจะได้ค่าที่เหมาะสมที่สุด ซึ่งระบบจะเก็บค่าอัตราการเรียนรู้ในแต่ละรอบของการเรียนรู้ (Training) ก่อนหน้านั้นเพื่อวิเคราะห์ว่าจะเปลี่ยนค่าอัตราการเรียนรู้ที่เหมาะสมไปในทิศทางไหน โดยวิเคราะห์จากผลลัพธ์ที่ได้ว่ามีทิศทางเข้าสู่ค่าความผิดพลาด (Error) ที่ตั้งไว้เป็นอย่างไร

3.6.2.4 การเรียนรู้แบบ Resilient

การเรียนรู้แบบ Resilient Backpropagation บางครั้งก็เรียกว่า “squashing” เนื่องจากกระบวนการเรียนรู้จะเป็นการบีบอัดให้โครงข่ายประสาทเทียมที่รองรับจำนวนชั้นขาเข้า (Input) ที่ไม่จำกัดให้ได้ชั้นขาออก (Output) จำนวนที่จำกัด โดยทั่วไปแล้วโครงข่ายประสาทเทียมโดยใช้ฟังก์ชันซิกมอยด์ (Sigmoid) เพื่อการถ่ายโอนผลลัพธ์ที่ได้จากโครงข่ายประสาทเทียมในชั้นนั้นๆ ก่อนที่จะส่งค่าไปยังนิรวัลของชั้นต่อไป ซึ่งจะได้ค่าความชันเข้าใกล้ศูนย์เมื่ออินพุตมีขนาดใหญ่ นี่คือนิวตันอย่างหนึ่งของการใช้วิธีการ Steepest Descent ในการเรียนรู้ของโครงข่ายประสาทเทียม เมื่อใช้ฟังก์ชันถ่ายโอนแบบซิกมอยด์ จึงเป็นเหตุให้โครงข่ายประสาทเทียมมีการปรับขนาดของน้ำหนักที่น้อย ถึงแม้ว่านิรวัลจะมีค่าความผิดพลาด (Error) ที่ห่างจากค่าที่ตั้งไว้มากก็ตามซึ่งมีสมการในการปรับค่าน้ำหนักดังสมการ (3.35) และ (3.36)

$$w_{ho}^{new} = w_{ho}^{old} + \Delta w, \quad (3.35)$$

$$\Delta w = -\text{sign}\left(\frac{\Delta E_o}{\Delta w_o}\right) \Delta_o \quad (3.36)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ทางการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การเรียนรู้แบบ Resilient Backpropagation มีจุดประสงค์เพื่อขจัดผลกระทบที่ผิดพลาดของค่าขนาดของอนุพันธ์ย่อยนั้นๆ ซึ่งทิศทางของการปรับน้ำหนักจะขึ้นอยู่กับเครื่องหมายลบหรือบวกที่อยู่หน้าอนุพันธ์เท่านั้น โดยที่ขนาดของอนุพันธ์ไม่มีผลใดๆ ต่อการปรับน้ำหนักเลย ขนาดของการเปลี่ยนแปลงในการปรับน้ำหนักจะถูกหาโดยการแยกค่าที่ปรับไว้ ค่าที่ปรับได้ในแต่ละค่าน้ำหนักจะถูกเพิ่มโดยค่าคงที่ที่ตรงเท่ากับที่อนุพันธ์ของฟังก์ชันในส่วนของน้ำหนักของนิเวศในชั้นนั้นๆ มีเครื่องหมายที่เหมือนกันกับการคำนวณรอบก่อนหน้านี้ ค่าที่ปรับได้ในแต่ละค่าน้ำหนักจะถูกลดโดยค่าคงที่ที่ตรงเท่ากับที่อนุพันธ์ของฟังก์ชันในส่วนของน้ำหนักของนิเวศในชั้นนั้นๆ มีเครื่องหมายที่ตรงข้ามกันกับการคำนวณรอบก่อนหน้านี้ แต่ถ้าหากค่าขนาดของอนุพันธ์มีค่าเท่ากับศูนย์ ก็ให้ใช้ค่าน้ำหนักเดิม และถ้าเครื่องหมายไม่มีการเปลี่ยนแปลงเลยในหลายรอบของการคำนวณ ก็ให้ปรับค่าน้ำหนักเพิ่มขึ้น การใช้การเรียนรู้แบบ Resilient Backpropagation มีความรวดเร็วกว่าการเรียนรู้แบบ Steepest Descent ทัวไปมาก อีกทั้งยังใช้พื้นที่หน่วยความจำในการเก็บข้อมูลเท่าๆ กัน

3.6.2.5 การเรียนรู้แบบ Fletcher- Reeve Conjugate Gradient

การเรียนรู้แบบ Conjugate Gradient จะเริ่มต้นด้วยการค้นหาทิศทางของ Steepest Descent ซึ่งในรอบการคำนวณที่หนึ่งจะมีทิศทางตามสมการ (3.37)

$$p_0 = -g_0, \quad (3.37)$$

ระบบจะค้นหาระยะห่างที่เหมาะสมเพื่อขยับตามทิศทางของ Gradient ในรอบปัจจุบันตามสมการ (3.38)

$$x_{k+1} = x_k + \alpha_k p_k, \quad (3.38)$$

การค้นหาทิศทางของ Conjugate Gradient ในรอบต่อไป ซึ่งโดยทัวจะค้นหาโดยการผสมผสานทิศทางในรอบก่อนหน้ากับทิศทางในรอบใหม่ตามสมการ (3.39)

เอกสารนี้เป็นเอกสารที่ส่ง $p_k = -g_k + \beta_k p_{k-1}$ เพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ทางการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ดังนั้นค่า β_k ที่ใช้ปรับค่านำหนักดังสมการ (3.40)

$$\beta_k = \frac{\mathbf{g}_k^T \mathbf{g}_k}{\mathbf{g}_{k-1}^T \mathbf{g}_{k-1}}, \quad (3.40)$$

ซึ่งค่า β_k คือค่าอัตราส่วนของค่า norm ของ Gradient ในรอบปัจจุบันเมื่อเปรียบเทียบกับค่าของ norm ของ Gradient ในรอบก่อนหน้านั้น การเรียนรู้แบบ Fletcher- Reeve Conjugate Gradient algorithm มีความสามารถในการประมวลผลได้อย่างรวดเร็ว และยังใช้พื้นที่หน่วยความจำที่น้อย จึงเหมาะสมกับงานที่ใช้จำนวนชั้นขาเข้า (Input) ที่มาก

3.6.2.6 การเรียนรู้แบบ Polak-Ribière Conjugate Gradient

เป็นการเรียนรู้อีกแบบหนึ่งสำหรับอัลกอริทึม Conjugate Gradient ที่นำเสนอโดย Polak และ Ribiere โดยได้ใช้สมการเหมือนกันกับ การเรียนรู้แบบ Fletcher- Reeve Conjugate Gradient algorithm ที่ใช้ในการค้นหาทิศทางในแต่ละรอบของโครงข่ายประสาทเทียมดังสมการ (3.41)

$$\mathbf{p}_k = -\mathbf{g}_k + \beta_k \mathbf{p}_{k-1}, \quad (3.41)$$

เพียงแต่การปรับค่าของ ค่าคงที่ β_k จะใช้ดังสมการ (3.42)

$$\beta_k = \frac{\Delta \mathbf{g}_{k-1}^T \mathbf{g}_k}{\mathbf{g}_{k-1}^T \mathbf{g}_{k-1}}, \quad (3.42)$$

โดยสมการนี้เป็นการ Inner Product ของการเปลี่ยนแปลงก่อนหน้าของ Gradient กับ Gradient ปัจจุบันที่หารด้วยรากของ norm ของ Gradient ในรอบก่อนหน้านี

3.6.2.7 การเรียนรู้แบบ Scaled Conjugate Gradient

หลักการทั่วไปของการเรียนรู้ด้วยวิธีการ Steepest Descent คือการค่อยๆ ปรับน้ำหนักไปตามทิศทางของการคำนวณในแต่ละรอบ ซึ่งการเรียนรู้แบบ Conjugate Gradient algorithm จะมีความรวดเร็วในการประมวลผลได้ดีกว่า โดยที่การเรียนรู้แบบ Scaled Conjugate Gradient algorithm ก็เป็นหนึ่งในกระบวนการเรียนรู้แบบ Conjugate Gradient algorithm ซึ่งได้ถูกพัฒนาขึ้นโดย Moller โดยได้ออกแบบขจัดปัญหาเกี่ยวกับการใช้ในการประมวลผลที่ช้า การเรียนรู้แบบ Scaled Conjugate Gradient algorithm เป็นอัลกอริทึมที่ใช้การผสมผสานการเรียนรู้แบบ Levenberg-Marquardt algorithm กับ Conjugate Gradient algorithm เข้าด้วยกันจึงเป็นอัลกอริทึมที่มีความซับซ้อน และใช้รอบในการลู่เข้าสู่ค่าความผิดพลาด (Error) ที่มากกว่าการเรียนรู้แบบ Conjugate Gradient algorithm แต่ในแต่ละรอบของการปรับน้ำหนักจะมีผลต่อการลู่เข้า และใช้พื้นที่หน่วยความจำพอๆ กับวิธีการเรียนรู้แบบ Fletcher-Reeves

3.6.2.8 การเรียนรู้แบบ Conjugate Gradient with Powell/Beale Restarts

สำหรับการเรียนรู้แบบ Conjugate Gradient จะตั้งค่าของทิศทางของ Gradient ให้ติดลบในแต่ละรอบของการเริ่มการคำนวณ และการตั้งค่าใหม่ทุกครั้งนั้นจะสอดคล้องกับจำนวนรอบในแต่ละครั้งของการคำนวณเพื่อปรับน้ำหนักของโครงข่ายประสาทเทียม แต่สำหรับการเรียนรู้แบบ Conjugate Gradient with Powell/Beale Restarts algorithm นี้จะเป็นการพิจารณาในเรื่องของการตั้งฉากกันของ Gradient ปัจจุบัน และ Gradient ในรอบที่ผ่านมา ซึ่งใช้สมการดัง (3.43)

$$|g_{k-1}^T g_k| \geq 0.2 \|g_k\|^2, \quad (3.43)$$

กำหนดให้ g เป็น Gradient โดยถ้าหากเงื่อนไขเป็นไปตามสมการข้างต้นทิศทางของการค้นหาคำตอบก็จะทำการตั้งค่าใหม่ให้เป็น Negative Gradient ความเร็วในการลู่เข้าสู่ค่าความผิดพลาด (Error) จะเร็วกว่าการเรียนรู้แบบ Polak-Ribiere Conjugate Gradient algorithm แต่จะใช้พื้นที่หน่วยความจำมากกว่า

3.6.2.9 การเรียนรู้แบบ BFGS quasi-Newton

การเรียนรู้แบบ quasi-Newton เป็นการเรียนรู้ที่คล้ายๆ กับวิธีการของ Conjugate Gradient โดยมีนักวิจัย Broyden, Fletcher, Goldfarb, and Shanno (BFGS) เราจึงเรียกวิธีการนี้ว่า BFGS quasi-Newton algorithm เพื่อให้ได้การเรียนรู้ของโครงข่ายประสาทเทียมมีความรวดเร็วขึ้น ซึ่งมีสมการ (3.44)

$$x_{k+1} = x_k - A_k^{-1}g_k, \quad (3.44)$$

เมื่อกำหนดให้ A_k เป็นเมทริกซ์ Hessian (อนุพันธ์อันดับสองของเมทริกซ์) ของค่าน้ำหนักในโครงข่ายประสาทเทียมแต่ละชั้นของปัจจุบัน g_k คือ Gradient ของฟังก์ชัน และ x คือค่าน้ำหนักของโครงข่ายประสาทเทียม ซึ่งโดยทั่วไปแล้ววิธีการ Quasi-Newton จะมีความสามารถในประมวลผลได้เร็วกว่าวิธีการ Conjugate Gradient เพียงแต่ว่าวิธีการของ Quasi-Newton มีความซับซ้อนมากในการคำนวณส่วนกระบวนการ Feed Forward ของโครงข่ายประสาทเทียม วิธีการนี้จะทำการปรับค่าน้ำหนักโดยใช้เมทริกซ์ Hessian ในแต่ละรอบของการเรียนรู้ซึ่งอยู่ในรูปแบบของค่า Gradient

3.6.2.10 การเรียนรู้แบบ One-Step Secant

เนื่องจากการเรียนรู้แบบ BFGS quasi-Newton algorithm มีการประมวลผลที่นาน และต้องใช้พื้นที่หน่วยความจำที่มากที่สุดในการบรรดาอัลกอริทึมของ Conjugate Gradient การเรียนรู้แบบ One-Step Secant จึงได้พัฒนาวิธีการเพื่อลดข้อเสียตรงนี้โดยการผสมผสานการเรียนรู้แบบ Conjugate Gradient ธรรมดากับการเรียนรู้แบบ Quasi-Newton algorithm ซึ่งจะเป็นการใช้ อัลกอริทึมโดยไม่ต้องเก็บค่าคำนวณของ เมทริกซ์ Hessian ทั้งหมดในแต่ละรอบของการคำนวณ แต่จะเก็บในรูปแบบของเมทริกซ์แทนซึ่งเป็นข้อดีที่สามารถคำนวณหาผลลัพธ์โดยไม่ต้องมาคำนวณเมทริกซ์ผกผันของ Hessian

3.6.2.11 การเรียนรู้แบบ Levenberg-Marquardt

การเรียนรู้แบบนี้คล้ายกับการเรียนรู้แบบ quasi-Newton Algorithm โดยจะออกแบบ เพื่อให้ได้ความเร็วที่เพิ่มขึ้น โดยใช้หลักการเดียวกัน ซึ่งในการเรียนรู้จะใช้วิธีการของอนุพันธ์อันดับ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สองที่ไม่ต้องใช้เมทริกซ์ Hessian ฟังก์ชันสร้างขึ้นจากผลรวมในรูปแบบเมทริกซ์จตุรัส ซึ่งโดยทั่วไปแล้วจะอยู่ในส่วนของการคำนวณในขั้นตอน Feedforward โดยสามารถประมาณการเมทริกซ์ Hessian ได้ดังสมการ (3.45)

$$H = J^T J, \quad (3.45)$$

และสามารถคำนวณค่า Gradient ได้เป็น (3.46)

$$g = J^T e, \quad (3.46)$$

เมื่อกำหนดให้ J เป็นเมทริกซ์ Jacobian ที่ประกอบด้วยอนุพันธ์อันดับหนึ่งของค่าผิดพลาดโครงข่ายประสาทเทียม (First Derivative Network Errors) ที่เกี่ยวข้องกับน้ำหนัก และ e คือเวกเตอร์ของค่าผิดพลาดโครงข่ายประสาทเทียม (Vector of Network Errors) ดังนั้นเมทริกซ์ Jacobian จะสามารถคำนวณได้ตามวิธีการของ Backpropagation ซึ่งจะมีความซับซ้อนน้อยกว่าการคำนวณแบบเมทริกซ์ Hessian สมการที่ใช้สำหรับปรับค่าน้ำหนักดังสมการ (3.47)

$$x_{k+1} = x_k - [J^T J + \mu I]^{-1} J^T e, \quad (3.47)$$

เมื่อกำหนดให้ μ เป็นศูนย์ สมการนี้ก็จะกลายเป็นการเรียนรู้แบบ Newton ซึ่งจะใช้ค่า เมทริกซ์ Hessian แต่ถ้าหากค่า μ มีค่ามากก็จะกลายเป็นการเรียนรู้แบบ Gradient Descent ที่มีการปรับระดับค่าอัตราการเรียนรู้ค่า วิธีการเรียนรู้แบบ Newton จะมีความสามารถในการประมวลผลที่เร็วและถูกต้อง ดังนั้นจุดมุ่งหมายคือการเปลี่ยนแปลงไปสู่วิธีการของ Newton เพราะฉะนั้นแล้วค่า μ จะลดลงหลังจากที่สิ้นสุดในแต่ละรอบ และจะเพิ่มขึ้นเมื่อรอบของการคำนวณเพิ่มขึ้นเท่านั้น ในทางเดียวกันประสิทธิภาพของฟังก์ชันก็จะลดไปตามในแต่ละรอบ การเรียนรู้แบบ Levenberg-Marquardt algorithm มีความสามารถในการประมวลผลที่เร็วมากสำหรับการประยุกต์ใช้กับโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (แต่จะรองรับจำนวนนิวรัลได้ไม่เกิน 100 ตัวน้ำหนัก)

เอกสารนี้แต่ข้อเสียเปรียบของการเรียนรู้แบบ Levenberg-Marquardt algorithm คือต้องใช้พื้นที่หน่วยความจำ
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

มาก กล่าวคือ ขนาดของเมทริกซ์ Jacobian จะมีขนาด $Q \times n$ โดยกำหนดให้ Q คือจำนวนชุดข้อมูลสำหรับการเรียนรู้ และ n คือจำนวนน้ำหนักของโครงข่ายประสาทเทียม แต่กลับกลายเป็นว่าเมทริกซ์นี้ไม่ต้องคำนวณและเก็บข้อมูลทั้งหมดในเวลาเดียวกัน ตัวอย่างเช่น ถ้าหากว่าทำการแบ่งเมทริกซ์ Jacobian ให้เป็น 2 เมทริกซ์ ควรจะต้องคำนวณด้วยค่าประมาณของเมทริกซ์ Hessian ดังสมการ (3.48)

$$H = J^T J = \begin{bmatrix} J_1^T & J_2^T \end{bmatrix} \begin{bmatrix} J_1 \\ J_2 \end{bmatrix} = J_1^T J_1 + J_2^T J_2, \quad (3.48)$$

เพราะฉะนั้นแล้วเมทริกซ์ Jacobian แบบสมมาตรจะไม่ใช่ในเวลาเดียวกัน และเมทริกซ์ Hessian จะถูกคำนวณด้วยการรวมของอนุกรมย่อยๆ เมื่อใดก็ตามหนึ่งในเมทริกซ์ย่อยได้ถูกคำนวณ ผลที่ตามมาคือเมทริกซ์ย่อยของ Jacobian จะสามารถลบไปได้ เมื่อใช้การเรียนรู้แบบ Levenberg-Marquardt algorithm จะต้องกำหนดจำนวนแถวของเมทริกซ์ Jacobian ที่จะต้องคำนวณในแต่ละเมทริกซ์ย่อย ถ้ากำหนดให้เป็น 1 แถว คือการใช้เมทริกซ์ Jacobian แบบสมมาตรก็จะถูกคำนวณโดยจะไม่ใช่การลดพื้นที่หน่วยความจำเลย แต่ถ้าหากกำหนดให้เป็น 2 เมทริกซ์ก็จะถูกคำนวณเพียงแค่ครั้งเดียวเท่านั้น และพื้นที่หน่วยความจำที่ใช้ก็จะใช้แค่ครั้งหนึ่งเท่านั้น เป็นการประหยัดพื้นที่หน่วยความจำ มีข้อเสียของการลดพื้นที่หน่วยความจำของการใช้การเรียนรู้แบบ Levenberg-Marquardt algorithm จะเกี่ยวกับการคำนวณของเมทริกซ์ Jacobian กล่าวคือถ้าหากว่าโครงข่ายประสาทเทียมที่นำมาใช้ มีขนาดเพียงพอต่อหน่วยความจำของคอมพิวเตอร์ก็กำหนดจำนวนแถวของเมทริกซ์ Jacobian ให้เป็น 1 ได้เลย แต่ถ้าหากว่าชุดข้อมูลของการเรียนรู้ใหญ่มากก็ค่อยเพิ่มจำนวนของแถวให้มากขึ้นจนกว่าจะสามารถคำนวณเมทริกซ์ Jacobian ย่อยได้


บทที่ 4

ระบบการตรวจจัดการหกล้ม

ระบบการตรวจจัดการหกล้มประกอบด้วย 2 ประการดังนี้ ประการแรกระบบตรวจวัดสัญญาณการเคลื่อนไหวซึ่งต้องมีลักษณะที่เหมาะสมสำหรับพกพาหรือติดกับตัวผู้ใช้ และสามารถสำรองข้อมูลของสัญญาณการเคลื่อนไหวได้ ประการที่สองอัลกอริทึมสำหรับการตรวจจัดการหกล้มซึ่งจะต้องมีความสามารถในการตรวจจับสัญญาณการหกล้มหรือไม่ใช่สัญญาณการหกล้มให้ถูกต้อง และแม่นยำ

4.1 ระบบตรวจวัดสัญญาณการเคลื่อนไหว

ระบบตรวจวัดสัญญาณการเคลื่อนไหวดังภาพที่ 4.1 ประกอบด้วย 4 ส่วนดังนี้ ส่วนแรกคือตัวตรวจจับความเร่งแบบสามแกน (ยี่ห้อ Freescale รุ่น MMA7361) ใช้สำหรับการวัดสัญญาณความเร่งในขณะเคลื่อนไหวของผู้สูงอายุ ต่อมาคือไมโครคอนโทรลเลอร์ (ยี่ห้อ Microchip รุ่น PIC24FJ128GB110) ใช้สำหรับการจัดการสัญญาณความเร่งจากตัวตรวจจับความเร่ง และ SD Card เป็นส่วนของหน่วยเก็บข้อมูลของค่าสัญญาณความเร่งจากตัวตรวจจับความเร่ง สุดท้ายคือแบตเตอรี่ ใช้สำหรับเป็นแหล่งจ่ายพลังงาน



ภาพที่ 4.1 ส่วนประกอบของระบบตรวจวัดสัญญาณการเคลื่อนไหว

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.1.1 ตัวตรวจจับความเร่ง

ตัวตรวจจับความเร่งแบบสามแกนมีโครงสร้างดังภาพที่ 4.2 และรายละเอียดของขาสัญญาณดังตารางที่ 4.1 โดยตัวตรวจจับความเร่งที่เลือกใช้นั้นมีขนาดเล็ก เบา ใช้พลังงานต่ำ และสามารถกำหนดความละเอียดของการตรวจจับสัญญาณอยู่ 2 ย่านคือ $\pm 4g$ และ $\pm 12g$



ภาพที่ 4.2 โครงสร้างตัวตรวจจับความเร่งแบบสามแกน (ยี่ห้อ Freescale รุ่น MMA7361)

ตารางที่ 4.1 รายละเอียดของโครงสร้างภายในสำหรับตัวตรวจจับความเร่ง (MMA7631)

ลำดับขา	ชื่อของขา	รายละเอียด
1	VDD	ขาจ่ายไฟเลี้ยงวงจร 2.2 – 3.6 โวลต์
2	XOUT	ขาสัญญาณแรงดันออก (Output) ในแกน X (Analog)
3	YOUT	ขาสัญญาณแรงดันออก (Output) ในแกน Y (Analog)
4	ZOUT	ขาสัญญาณแรงดันออก (Output) ในแกน Z (Analog)
5	VSS	ขาสัญญาณสายดิน (Ground)
6	SLEEP	ขาสัญญาณเลือกโหมด Sleep ทำงานที่โลจิก 0
7	g-Select	ขาสัญญาณสำหรับเลือกย่านความละเอียดของการวัด
8	Self-Test	ขาสัญญาณสำหรับเลือกโหมด Self-Test ทำงานที่โลจิก 1

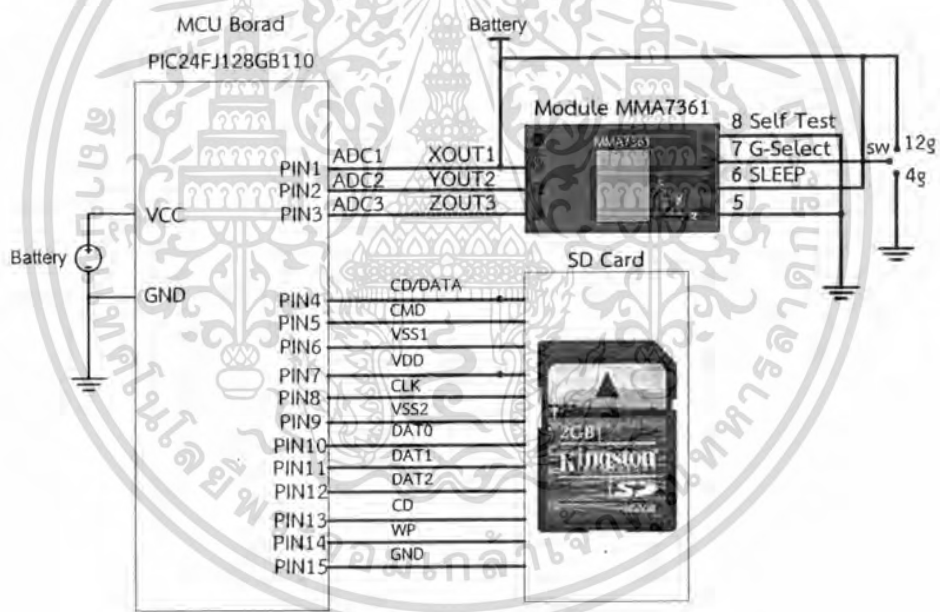
ลักษณะการใช้งานของตัวตรวจจับความเร่งแบบสามแกน สามารถเลือกโหมดการทำงาน 3 โหมดดังนี้ โหมดพัก (Sleep) โหมดทดสอบ (Self-Test) และโหมดการตรวจวัดสัญญาณการเคลื่อนไหว (Measurement) ซึ่งในโครงการวิจัยนี้ได้เลือกใช้โหมดการตรวจวัดสัญญาณการเคลื่อนไหว โดยมีลักษณะการทำงานคือ วงจรจะตรวจวัดสัญญาณค่าแรงโน้มถ่วง (g) ในแกน X Y Z และต้องกำหนดขาสัญญาณในส่วน of Self-Test และ Sleep เป็น 0 และ 1 ตามลำดับ สำหรับ

เอกสารนี้ขาสัญญาณ g-Select เป็นขาสัญญาณสำหรับเลือกย่านของการวัดซึ่งมีรายละเอียดดังตารางที่ 4.2 การค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.2 ย่านของการวัดตัวตรวจจับความเร่ง (MMA7631)

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

เมื่อกำหนดค่าสัญญาณของตัวตรวจจับความเร่งแล้ว จะใช้แรงดันขาออก (Output) ของวงจรตัวตรวจจับความเร่ง ไปต่อกับวงจรไมโครคอนโทรลเลอร์ (ซึ่งจะกล่าวรายละเอียดไมโครคอนโทรลเลอร์ในหัวข้อต่อไป) เพื่ออ่านค่าของสัญญาณที่วัดออกมาจากตัวตรวจจับความเร่ง ดังภาพที่ 4.3



ภาพที่ 4.3 วงจรของระบบตรวจวัดการเคลื่อนไหว

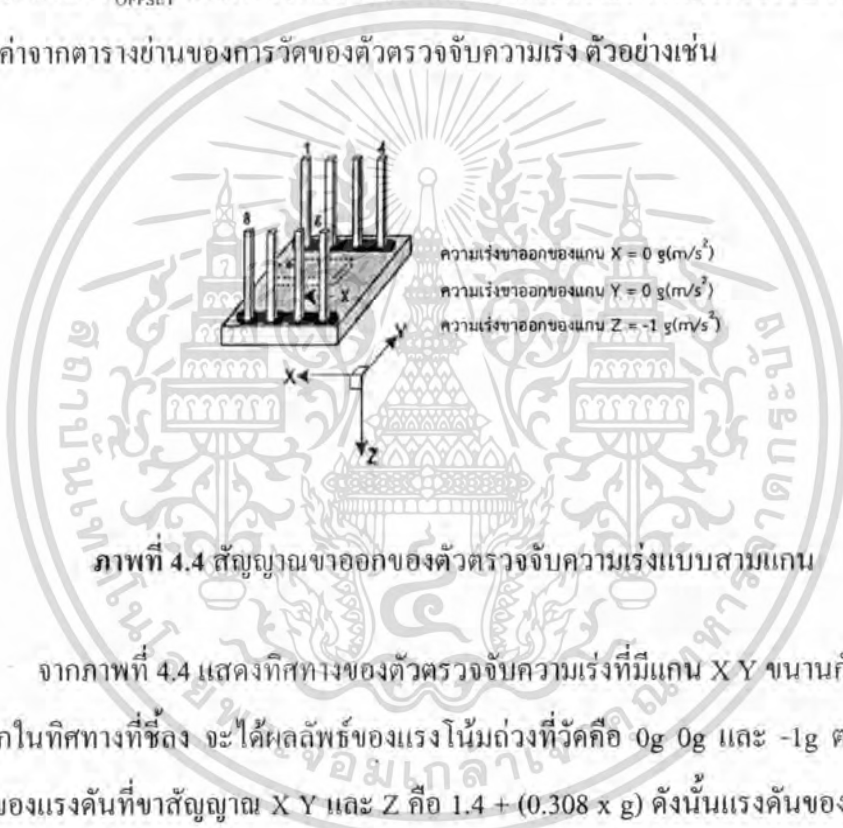
การทำงานของตัวตรวจจับความเร่งในโหมดการตรวจวัดสัญญาณการเคลื่อนไหว จะทำงานโดยใช้ทิศทางของตัวตรวจจับความเร่งเป็นตัวกำหนดค่าสัญญาณออก (Output X Y และ Z) ซึ่งถ้าทิศทางของแกนใดแกนหนึ่งของตัวตรวจจับความเร่ง ขนานกับแกนของโลกค่าสัญญาณออก จะเท่ากับ 0 g (m/s^2) และถ้าทิศทางของแกนใดแกนหนึ่งของตัวตรวจจับความเร่งตั้งฉากกับพื้นโลก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ขาสัญญาณออกจะเท่ากับ $\pm 1 \text{ g (m/s}^2\text{)}$ ซึ่งการคำนวณขนาดแรงดันของขาสัญญาณออกในแกน X Y และ Z ได้ดังสมการ (4.1)

$$V_{\text{OUT(analog)}} = V_{\text{OFFSET}} + \text{SEN} \times g, \quad (4.1)$$

โดยกำหนดให้ $V_{\text{OUT(analog)}}$ คือค่าขนาดแรงดันที่วัดได้จากขาสัญญาณของตัวตรวจจับความเร่งแกน X Y และ Z ส่วน V_{OFFSET} คือค่าครึ่งหนึ่งของแรงดันไฟเลี้ยงที่จ่ายให้กับตัวตรวจจับความเร่ง และค่า SEN คือค่าจากตารางย่านของการวัดของตัวตรวจจับความเร่ง ตัวอย่างเช่น



ภาพที่ 4.4 สัญญาณขาออกของตัวตรวจจับความเร่งแบบสามแกน

จากภาพที่ 4.4 แสดงทิศทางของตัวตรวจจับความเร่งที่มีแกน X Y ขนานกับพื้นโลกและ Z ตั้งฉากในทิศทางที่ชี้ลง จะได้ผลลัพธ์ของแรงโน้มถ่วงที่วัดคือ 0g 0g และ -1g ตามลำดับ และผลลัพธ์ของแรงดันที่ขาสัญญาณ X Y และ Z คือ $1.4 + (0.308 \times g)$ ดังนั้นแรงดันของขาสัญญาณ X Y และ Z ก็มีค่าเท่ากับ 1.4 โวลต์ 1.4 โวลต์ และ 1.092 โวลต์ตามลำดับ (โดยกำหนดย่านความละเอียดของการวัดที่ 308 mV/g และไฟเลี้ยงของตัวตรวจจับความเร่งเป็น 2.8 โวลต์)

4.1.2 ไมโครคอนโทรลเลอร์

ไมโครคอนโทรลเลอร์ (ยี่ห้อ Microchip รุ่น PIC24FJ128GB110) ดังภาพที่ 4.5 ใช้สำหรับการจัดการสัญญาณความเร่งจากตัวตรวจจับความเร่งเช่น อ่านค่าสัญญาณและประมวลผล เป็นต้น ข้อดีของการใช้ไมโครคอนโทรลเลอร์รุ่นนี้มีหลายประการดังนี้ ใช้พลังงานต่ำ ทำงานที่ 16

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บิตข้อมูล และสามารถแปลงสัญญาณแอนะล็อกเป็นสัญญาณดิจิทัลที่ 10 บิตข้อมูล จึงทำให้สามารถประมวลผลสัญญาณความเร่งเป็นไปอย่างถูกต้องและมีประสิทธิภาพ



ภาพที่ 4.5 โครงสร้างของไมโครคอนโทรลเลอร์ชื่อ Microchip รุ่น PIC24FJ128GB110

4.1.3 สื่อจัดเก็บข้อมูล (SD Card)

SD Card หรือ Secure Digital Card เป็นสื่อจัดเก็บข้อมูลแบบ Nand Flash Memory เป็นส่วนของหน่วยเก็บข้อมูลของค่าสัญญาณความเร่งจากตัวตรวจจับความเร่งดังภาพที่ 4.6 ซึ่งมีข้อดีหลายประการเช่น ราคาถูก ทนทานต่อการตกหล่น ใช้พลังงานต่ำ สามารถใช้บรรจุข้อมูลได้ในปริมาณมาก มีอายุการใช้งานได้นาน รวมถึงการมีระบบความปลอดภัยโดยกรล๊อคที่ตัวการ์ดไม่ให้มีการเขียนทับ โดยทั่วไป SD Card แบ่งได้ 3 รูปแบบคือ การ์ด SD ความจุมาตรฐาน , SDHC หรือ High-Capacity, SDXC หรือ Extended-capacity ซึ่งการ์ดแต่ละรูปแบบจะมี Class เป็นตัวบ่งบอกความเร็วในการอ่านและเขียนข้อมูลของการ์ด โดยที่ Class สามารถแบ่งออกเป็น 4 ระดับดังนี้ Class 2 Class 4 Class 6 และ Class 10 โดยมีความเร็วในการอ่านและเขียนข้อมูลเป็น 2 MBต่อวินาที 4 MBต่อวินาที 6 MBต่อวินาที และ 10 MBต่อวินาที ตามลำดับ



ภาพที่ 4.6 โครงสร้างของ SD Card

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้ในเพื่อการศึกษาเท่านั้น เมื่ออนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.1.4 แบตเตอรี่

เนื่องจากในโครงการวิจัยนี้มีความประสงค์จะประดิษฐ์ระบบตรวจวัดสัญญาณการเคลื่อนไหวที่สามารถพกพาหรือติดกับตัวผู้ใช้งาน (ผู้สูงอายุ) เพื่อให้ผู้ใช้งานสามารถทำกิจกรรมต่างๆ ของชีวิตประจำวันได้อย่างเป็นปกติ ทางผู้วิจัยจึงได้นำแบตเตอรี่ที่ใช้ในเครื่องโทรศัพท์มือถือดังภาพที่ 4.7 ไว้สำหรับเป็นแหล่งจ่ายไฟให้ระบบตรวจวัดสัญญาณการเคลื่อนไหว แบตเตอรี่มีข้อดีดังนี้ น้ำหนักเบา ความจุของพลังงานไฟฟ้าสูง ใช้เวลาในการชาร์จสั้น และผลกระทบจาก Memory Effect น้อยมากหรือแทบจะไม่มีเลย เป็นต้น



ภาพที่ 4.7 โครงสร้างของแบตเตอรี่

4.2 การหาลักษณะเด่นของสัญญาณการเคลื่อนไหว


ในการเตรียมข้อมูลของสัญญาณการเคลื่อนไหวประเภทต่างๆ เริ่มต้นด้วยการกำหนดให้ระบบการตรวจวัดสัญญาณการเคลื่อนไหวมีความถี่ในการตรวจวัดสัญญาณที่ 60 เฮิร์ต (Hz) ซึ่งสัญญาณที่ตรวจวัดด้วยตัวตรวจจับความเร่งจะอยู่ในรูปแอนะล็อกและจะแปลงเป็นสัญญาณดิจิทัลดังสมการ (4.2) และ (4.3) จากนั้นสัญญาณจะถูกบันทึกโดย SD Card

$$g = \frac{(V_{ADC} \times R_{ADC}) - V_{DD}/2}{SEN}, \quad (4.2)$$


$$R_{ADC} = \frac{V_{DD}}{2^n - 1}, \quad (4.3)$$

โดยกำหนดให้ค่า g คือสัญญาณความเร่งในหน่วย m/s^2 V_{ADC} คือค่าสัญญาณที่บันทึกไว้ V_{DD} คือค่าแรงดันที่จ่ายให้กับตัวตรวจจับความเร่งแบบสามแกน n คือจำนวนบิต (Bit) ของการแปลงเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


สัญญาณแอนะล็อกเป็นสัญญาณดิจิทัล ($n = 10$) SEN คือค่าความละเอียดที่กำหนดให้กับตัวตรวจจับ ความเร่งแบบสามแกนในการตรวจจับสัญญาณการเคลื่อนไหว (SEN = 308 mV/g สำหรับรุ่น MMA7361) ซึ่งตัวอย่างของสัญญาณการเคลื่อนไหวในรูปแบบต่างๆ ดังภาพที่ 4.8 ถึง 4.15




ภาพที่ 4.8 สัญญาณการเคลื่อนไหวประเภทการหกล้มไปด้านหลัง




ภาพที่ 4.9 สัญญาณการเคลื่อนไหวประเภทการหกล้มไปด้านหน้า




ภาพที่ 4.10 สัญญาณการเคลื่อนไหวประเภทการหกล้มไปข้างซ้าย



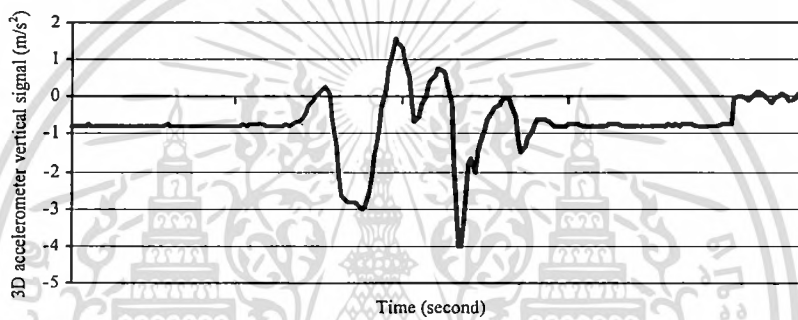
ภาพที่ 4.11 สัญญาณการเคลื่อนไหวประเภทการหกล้มไปข้างขวา




ภาพที่ 4.12 สัญญาณการเคลื่อนไหวประเภทการล้มตัวนอน




ภาพที่ 4.13 สัญญาณการเคลื่อนไหวประเภทการลุดจากเตียง



ภาพที่ 4.14 สัญญาณการเคลื่อนไหวประเภทการกระโดด



ภาพที่ 4.15 สัญญาณการเคลื่อนไหวประเภทการล้มระหว่างการลุกขึ้นยืน




ภาพที่ 4.16 ตัวอย่างสัญญาณการเคลื่อนไหวปกติและสัญญาณการเคลื่อนไหวที่ผิดปกติ

จากตัวอย่างสัญญาณการเคลื่อนไหวประเภทต่างๆ ข้างต้นที่ได้มาจากตัวตรวจจับความเร่งแบบสามแกนซึ่งกำหนดให้แกน x เป็นแกนตั้ง แกน z เป็นแกนไปข้างหน้าของลำตัว และแกน y เป็นแกนไปด้านข้างลำตัว ซึ่งแต่ละตัวอย่างประกอบด้วยลักษณะของสัญญาณการเคลื่อนไหวปกติ (การเคลื่อนไหวประเภทกิจกรรมประจำวัน) และสัญญาณที่บ่งชี้ถึงจุดเด่นของความผิดปกติ (สัญญาณที่สงสัยว่าเป็นการหกล้ม) ดังภาพที่ 4.16


เนื่องจากสัญญาณจากตัวตรวจจับความเร่งทั้งสามแกนของการเคลื่อนไหวประเภทต่างๆ มีลักษณะที่ใกล้เคียงกัน และจากการสังเกตจะเห็นได้ว่าสัญญาณที่มีนัยสำคัญต่อสัญญาณการหกล้มมากที่สุดคือ สัญญาณในแนวแกนตั้ง โดยจากการทดลองของโครงการวิจัยนี้ ถ้าหากใช้ค่าสัมบูรณ์ของขนาดความเร่งแบบสามแกนดังสมการ (4.4)

$$A = \sqrt{a_x^2 + a_y^2 + a_z^2}, \quad (4.4)$$


กำหนดให้ a_x , a_y และ a_z เป็นสัญญาณจากตัวตรวจจับความเร่งแบบสามแกนตามแนวแกน x , y และ z ตามลำดับ ค่าสัมบูรณ์ของขนาดความเร่ง (A) ที่ได้มาจะถูกลดลักษณะเด่นบางจุดของข้อมูล อีกทั้งยังเพิ่มขึ้นตอนการประมวลผลของสัญญาณ ตัวอย่างสัญญาณที่นำเฉพาะแกนแนวตั้งและสัญญาณที่ผ่านกระบวนการตามสมการ (4.4) ดังภาพที่ 4.17 ถึง 4.20




ภาพที่ 4.17 ความแตกต่างระหว่างสัญญาณแกนนตั้ง (เส้นบาง) และสัญญาณผ่านกระบวนการตามสมการ (4.4) ของสัญญาณประเภทหกล้มไปด้านหลัง (เส้นหนา)



ภาพที่ 4.18 ความแตกต่างระหว่างสัญญาณแกนนตั้ง (เส้นบาง) และสัญญาณผ่านกระบวนการตามสมการ (4.4) ของสัญญาณประเภทหกล้มไปด้านหน้า (เส้นหนา)



ภาพที่ 4.19 ความแตกต่างระหว่างสัญญาณแกนตั้ง (เส้นบาง) และสัญญาณผ่านกระบวนการตามสมการ (4.4) ของสัญญาณประเภทหกล้มไปข้างซ้าย (เส้นหนา)




ภาพที่ 4.20 ความแตกต่างระหว่างสัญญาณแกนตั้ง (เส้นบาง) และสัญญาณผ่านกระบวนการตามสมการ (4.4) ของสัญญาณประเภทหกล้มไปข้างขวา (เส้นหนา)

จากรูปข้างต้นแสดงถึงค่าสัมบูรณ์ของขนาดสัญญาณความเร่ง (เส้นหนา) ตามการคำนวณจากสมการ (4.4) ทำให้สัญญาณถูกลดจุดเด่นลงอย่างมากจึงทำให้ยากต่อการตรวจจับสัญญาณการหกล้ม ดังนั้นจากเหตุผลดังกล่าวในโครงการวิจัยนี้จึงนำเฉพาะแกนตั้งเท่านั้น เพื่อนำมาใช้เป็นข้อมูลในการทดลองต่อไป


จากการศึกษาตัวอย่างของสัญญาณความเร่งของการเคลื่อนไหวประเภทต่างๆ สามารถแบ่งออกเป็น 3 กลุ่มหลักดังนี้ 1) การเคลื่อนไหวประเภทการหกล้ม เช่น การหกล้มไปด้านหลัง การหกล้มไปด้านหน้า การหกล้มไปข้างซ้าย เป็นต้น 2) การเคลื่อนไหวประเภทปกติ เช่น การเดิน การนั่ง การนอน เป็นต้น 3) การเคลื่อนไหวประเภทยับยั้ง เช่น การกระโดด การวิ่ง การถูกจากเตียง เป็นต้น เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ต้น ตัวอย่างของสัญญาณการเคลื่อนไหวทั้ง 3 กลุ่มสามารถแสดงสัญญาณแกนตั้งดังภาพที่ 4.21 ถึง 4.23 คุณลักษณะเด่นของสัญญาณการเคลื่อนไหวแบบจับปล้นและสัญญาณการหกล้มสามารถแยกออกจากสัญญาณการเคลื่อนไหวประเภทปกติได้ดังนี้


- ขนาดสูงสุดของค่าสัญญาณการเคลื่อนไหวประเภทปกติจะมีขนาดต่ำกว่าสัญญาณการเคลื่อนไหวประเภทจับปล้นและประเภทหกล้ม
- รูปแบบของสัญญาณการเคลื่อนไหวประเภทหกล้มจะมีจุดยอดใกล้เคียงกับสัญญาณการเคลื่อนไหวประเภทจับปล้น ซึ่งสัญญาณการเคลื่อนไหวประเภทหกล้มจะมีค่าจุดยอดสูงสุดทั้งในด้านบวกและ/หรือด้านลบเพียงจุดยอดเดียวหรือสองจุดขึ้นอยู่กับลักษณะของประเภทการหกล้ม ในทางเดียวกันรูปแบบของสัญญาณการเคลื่อนไหวประเภทจับปล้นมีจุดยอดที่ซับซ้อนและหลากหลายกว่า ตัวอย่างเช่น สัญญาณการกระโดดมีจุดยอดสูงสุดของสัญญาณอยู่ 2 หรือ 3 ตำแหน่ง สัญญาณการวิ่งก็จะเป็นแบบคาบ เป็นต้น
- หากพิจารณาในแกนนอน (แกนของเวลา) จะพบว่าสัญญาณการเคลื่อนไหวประเภทจับปล้นและการเคลื่อนไหวประเภทหกล้มจะมีช่วงเวลาของการเคลื่อนไหวที่สั้นกว่าสัญญาณการเคลื่อนไหวประเภทปกติ
- ระยะเวลาที่ใช้ในการเคลื่อนไหวแต่ละประเภทจะส่งผลถึงการพิจารณาในเรื่องของจำนวนข้อมูลที่จะนำมาใช้ในการวิเคราะห์ ดังนั้นจำนวนข้อมูลที่กำหนดจะต้องครอบคลุมทุกประเภทกิจกรรมของการเคลื่อนไหว
- เนื่องจากระบบโครงข่ายประสาทเทียมจะต้องมีจำนวนเซลล์ประสาทเทียมขาเข้า (Input Neuron) คงที่ และจำนวนข้อมูลหรือช่วงเวลาของการกำหนดในแต่ละประเภทของการเคลื่อนไหวจะเป็นตัวกำหนดจำนวนเซลล์ประสาทเทียมขาเข้าที่จะป้อนให้กับระบบโครงข่ายประสาทเทียมเพื่อตรวจจับการหกล้ม โดยจำนวนข้อมูลจะต้องไม่มากเกินไปจนทำให้การประมวลผลเกิดความล่าช้า



ภาพที่ 4.21 ตัวอย่างสัญญาณการเคลื่อนไหวประเภทนับปล้น (การถูกรุกจากที่เตียง)



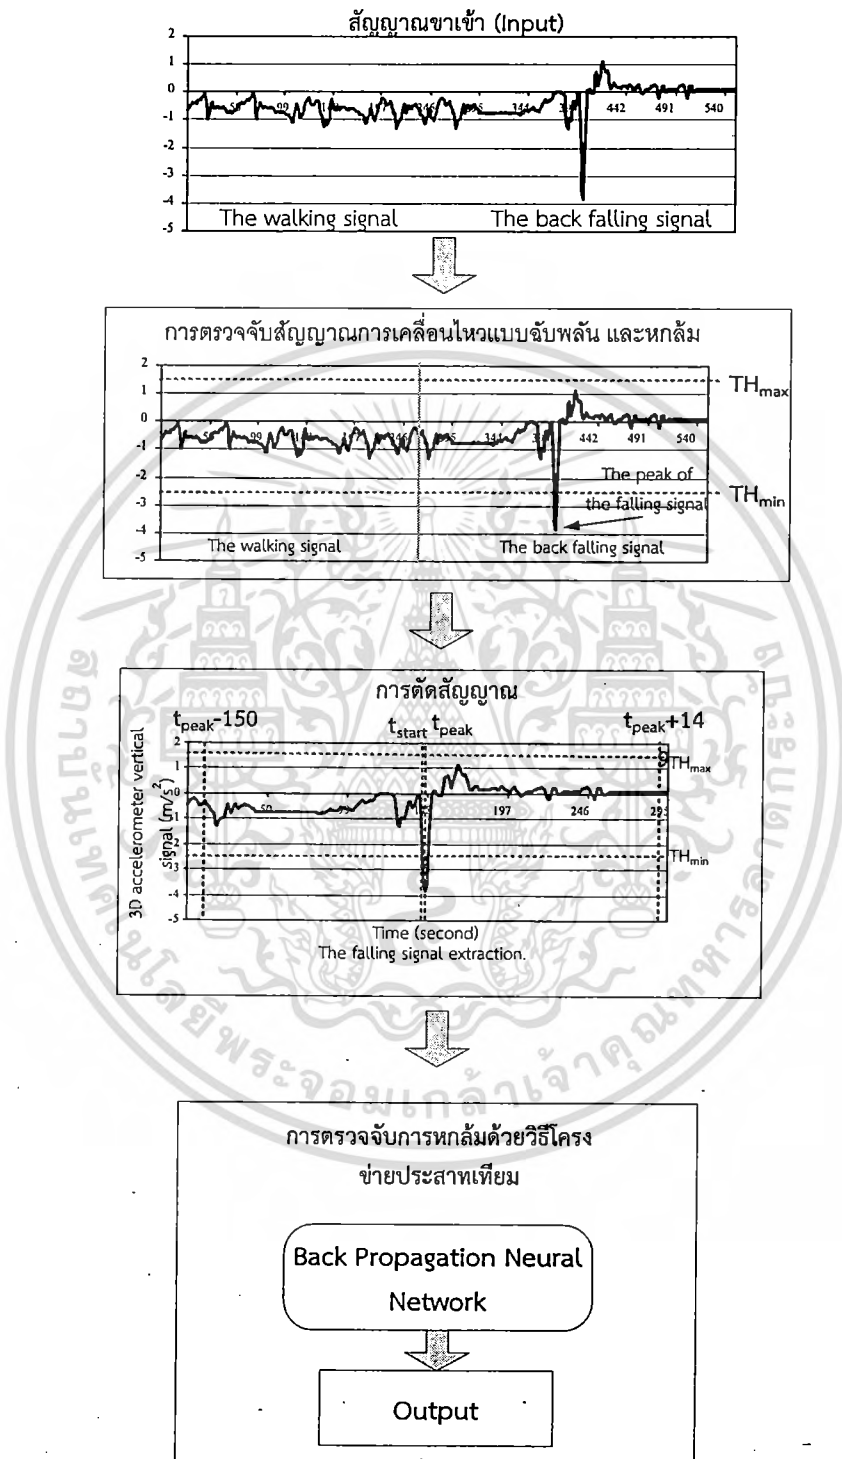
ภาพที่ 4.22 ตัวอย่างสัญญาณการเคลื่อนไหวประเภทนับปล้น (การกระโดด)



ภาพที่ 4.23 ตัวอย่างสัญญาณการเคลื่อนไหวประเภทหกล้ม

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.3 อัลกอริทึมสำหรับการตรวจจับสัญญาณการหกล้ม




ภาพที่ 4.24 อัลกอริทึมสำหรับการตรวจจับสัญญาณการหกล้ม

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากการศึกษาและวิเคราะห์คุณลักษณะเด่นของสัญญาณที่กล่าวมาข้างต้นสำหรับการตรวจจับการหกล้มให้มีประสิทธิภาพ ดังนั้นโครงการวิจัยนี้นำเสนออัลกอริทึมสำหรับการตรวจจับสัญญาณการหกล้มที่มี 3 ขั้นตอนดังนี้ 1) การตรวจจับสัญญาณการเคลื่อนไหวเพื่อแยกสัญญาณการเคลื่อนไหวประเภทปกติออกจากการเคลื่อนไหวประเภทล้มปัดและการหกล้ม 2) การตัดสัญญาณและ 3) การตรวจจับการหกล้มด้วยวิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ ซึ่งรายละเอียดดังภาพที่ 4.24

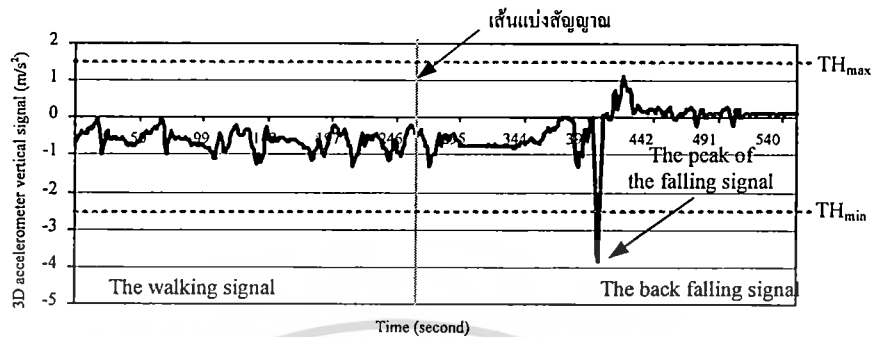
4.3.1 สัญญาณขาเข้า (Input)

สัญญาณขาเข้า (Input) ดังภาพที่ 4.25 คือสัญญาณที่ได้มาจากระบบตรวจวัดสัญญาณการเคลื่อนไหว โดยระบบตรวจวัดสัญญาณการเคลื่อนไหวได้บันทึกสัญญาณการเคลื่อนไหวในรูปแบบของความเร่งด้วยหน่วยความจำ (SD card) และสัญญาณการเคลื่อนไหวที่บันทึกไว้จะอยู่ในรูปแบบตัวเลขที่ถูกแปลงให้เป็นหน่วยแรงโน้มถ่วง g (m/s^2)



ภาพที่ 4.25 สัญญาณขาเข้า (Input)

4.3.2 การตรวจจับสัญญาณการเคลื่อนไหวแบบจับพัตน์ และหลัด้ม



ภาพที่ 4.26 อัลกอริทึมการตรวจจับสัญญาณการเคลื่อนไหวแบบจับพัตน์ และหลัด้ม

จากภาพที่ 4.26 แสดงตัวอย่างสัญญาณการเคลื่อนไหวของมนุษย์ ซึ่งจากการศึกษาพบว่าสัญญาณที่อยู่ทางด้านซ้ายของเส้นแบ่งสัญญาณมีค่าอยู่ระหว่าง $0g$ ถึง $-1g$ ซึ่งเป็นตัวอย่างของสัญญาณประเภทปกติ และเมื่อมีการหลัด้มเกิดขึ้นสัญญาณจะมีค่าพุ่งไปด้านลบชั่วขณะและจะกลับเข้าสู่ค่า $0g$ (ซึ่งค่านี้จะเป็นลักษณะของผู้ใช้ที่อยู่ในท่านอน) ดังภาพที่ 4.26 (สัญญาณที่อยู่ทางด้านขวาของเส้นแบ่งสัญญาณ) ด้วยข้อสังเกตดังกล่าว โครงการวิจัยนี้จึงได้กำหนดค่าขีดเริ่มของสัญญาณที่จะมีความเสี่ยงต่อการเกิดภาวะการเคลื่อนไหวที่ผิดปกติ (อาจจะเป็นการเคลื่อนไหวประเภทจับพัตน์หรือการหลัด้ม) ด้วยการกำหนดค่าขีดเริ่มสำหรับการตรวจสอบสัญญาณการเคลื่อนไหวแบบ 2 ระดับ (TH_{MIN} และ TH_{MAX}) เพื่อแยกสัญญาณการเคลื่อนไหวประเภทจับพัตน์และการหลัด้มออกจากสัญญาณการเคลื่อนไหวประเภทอื่น ๆ โดยที่กำหนดให้ TH_{MIN} คือค่าขีดเริ่มของค่าขนาดสัญญาณการเคลื่อนไหวที่มีความเสี่ยงต่อการเคลื่อนไหวที่ผิดปกติขอบล่าง และ TH_{MAX} คือค่าขีดเริ่มของขนาดสัญญาณการเคลื่อนไหวที่มีความเสี่ยงต่อการเคลื่อนไหวที่ผิดปกติขอบบน ดังนั้นเป็นที่ชัดเจนว่าสัญญาณการเคลื่อนไหวประเภทปกติจะมีค่าความเร่งอยู่ในช่วงของ TH_{MIN} และ TH_{MAX} และขนาดสูงสุดของสัญญาณประเภทหลัด้มจะมีค่าความเร่งอยู่นอกช่วงของค่าขีดเริ่ม

4.3.3 การตัดสัญญาณ

จากการศึกษาพบว่า สัญญาณการหกล้มจะปรากฏก่อนจุดยอดสูงสุดประมาณ 2.5 วินาที และสิ้นสุดหลังจากจุดยอดสูงสุดประมาณ 2.5 วินาที ดังนั้นในการตัดสัญญาณจะต้องค้นหาตำแหน่งจุดยอดสูงสุด (t_{peak}) ของสัญญาณ เริ่มต้นโดยการใช้อัลกอริทึมที่มองหาตำแหน่งของสัญญาณที่มีค่าความเร่งอยู่นอกช่วงของ TH_{MIN} และ TH_{MAX} เพื่อกำหนดตำแหน่งของจุดเริ่มต้น (t_{start}) ในการค้นหาจุดยอดสูงสุด (t_{peak}) เนื่องจากระบบตรวจจับสัญญาณการเคลื่อนไหวนั้นมีความถี่ในการตรวจจับที่ 60 ตัวอย่างต่อ 1 วินาทีและช่วงเวลาของการเกิดการหกล้มมีระยะเวลา 5 วินาที ดังนั้นในแต่ละรอบของการตรวจสอบสัญญาณว่ามีการหกล้มหรือไม่ควรที่จะสิ้นสุดที่ $t_{start} + 5$ วินาทีของชุดข้อมูล (จากตำแหน่งเริ่มต้น (t_{start}) ต้องค้นหาจุดยอดสูงสุดไปอีก 300 จุด) กล่าวคือเมื่อป้อนสัญญาณการเคลื่อนไหวประเภทต่างๆ เข้าไปในโปรแกรมการตัดสัญญาณ จากนั้นโปรแกรมจะตรวจหาค่าขนาดว่ามีค่าสัญญาณความเร่งน้อยกว่าค่า TH_{MIN} และมากกว่าค่า TH_{MAX} หรือไม่ หากเป็นไปตามนั้นโปรแกรมก็จะกำหนดตำแหน่งขึ้นมาเพื่อเป็นจุดเริ่มต้น (t_{start}) ของการหาจุดยอดสูงสุดของสัญญาณ (t_{peak}) ซึ่งอยู่ในช่วง ($t_{start} + 299$ ตัวอย่าง) เมื่อพบตำแหน่งของจุดยอดสูงสุดของสัญญาณ (t_{peak}) แล้ว โปรแกรมจะกำหนดให้ช่วงเวลาของการเกิดสัญญาณประเภทการหกล้มอยู่ในช่วง $t_{peak} - 150$ ตัวอย่าง ถึง $t_{peak} + 149$ ตัวอย่างเพื่อให้ครอบคลุมต่อหนึ่งครั้งของการเคลื่อนไหวประเภทต่างๆ ตัวอย่างของการเขียนภาษาโปรแกรมเพื่อตัดสัญญาณการเคลื่อนไหวประเภทต่างดังภาพที่ 4.27

```

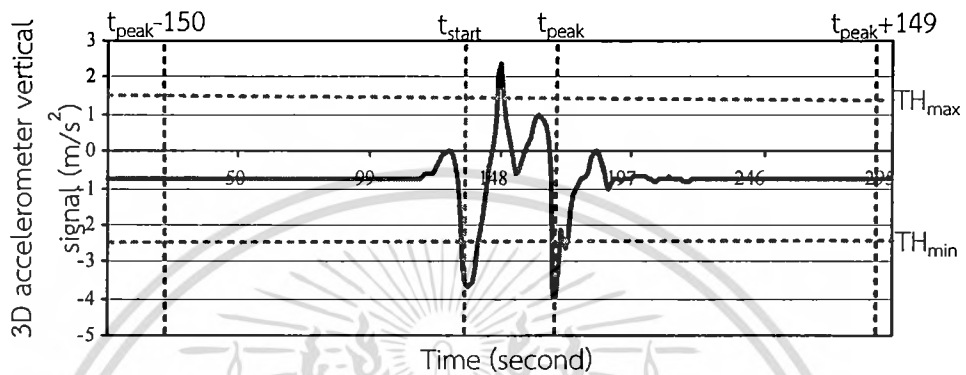
for (t = 0 ; t < CaptureLength - 1; t++){
    if (x[t] > TH_MAX || x[t] < TH_MIN){
        for (j = t+1 ; j < t + 300; j++){
            if (abs(x[j]) > abs(x[j-1]))
                t_PEAK = j;}
        }
    X = {x[t_PEAK-150],..., x[t_PEAK],..., x[t_PEAK+149]};}

```


ภาพที่ 4.27 โปรแกรมการตัดสัญญาณ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เมื่อกำหนดให้ CaptureLength คือความยาวของสัญญาณการเคลื่อนไหว x คือสัญญาณการเคลื่อนไหว X คือผลลัพธ์ของชุดข้อมูลที่มีการตัดสัญญาณ ตัวอย่างของชุดข้อมูลที่มีการตัดสัญญาณดังภาพที่ 4.28 และ ภาพที่ 4.29



ภาพที่ 4.28 ตัวอย่างของชุดข้อมูลที่มีการตัดสัญญาณ (การเคลื่อนไหวประเภทนับปล้น)



ภาพที่ 4.29 ตัวอย่างของชุดข้อมูลที่มีการตัดสัญญาณ (การเคลื่อนไหวประเภทหกล้ม)

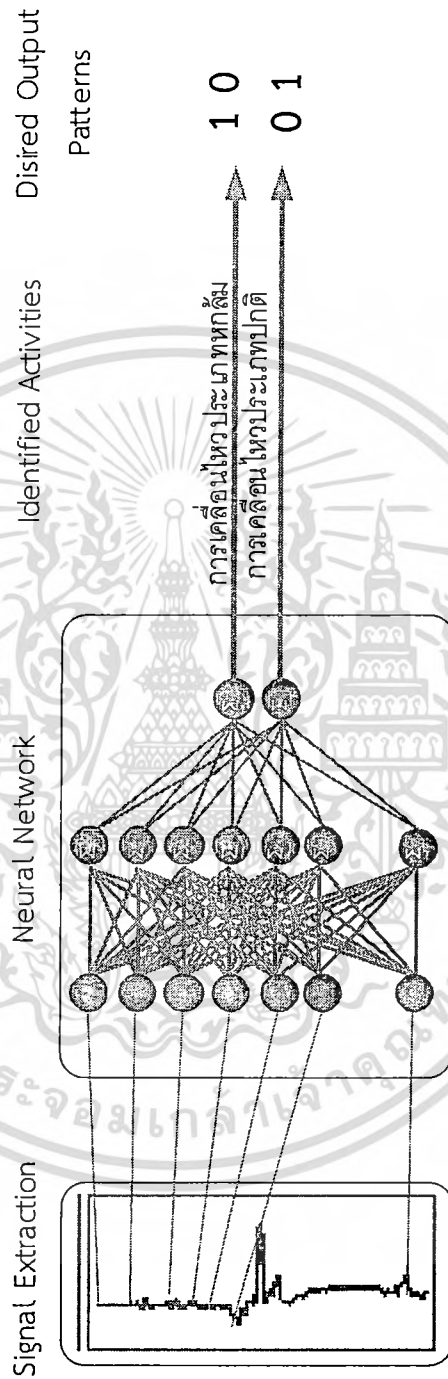
4.3.4 การตรวจจับการหกล้มด้วยวิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ

ในทางปฏิบัติการเคลื่อนไหวประเภทนับปล้นมีหลายชนิดเช่น การกระโดด การวิ่ง เป็นต้น ซึ่งส่วนใหญ่แล้วสัญญาณจะมีรูปแบบที่ซับซ้อนและบางรูปแบบของสัญญาณการเคลื่อนไหวแบบนับปล้นมีความคล้ายคลึงกับสัญญาณการเคลื่อนไหวประเภทหกล้ม ผลที่ตามมาคือเกิดความยากในการใช้สมการเพื่อคำนวณหรือใช้การเขียนโปรแกรมเพื่อคัดแยกสัญญาณ แต่อย่างไรก็ตาม เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ด้วยความก้าวหน้าของเทคโนโลยี จึงมีความเป็นไปได้ที่จะออกแบบอัลกอริทึมสำหรับการจดจำรูปแบบสัญญาณ ซึ่งงานวิจัยในครั้งนี้ได้ใช้วิธีที่เรียกว่า “โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ” เพื่อจดจำรูปแบบสัญญาณการหกล้มและสัญญาณนับปล้นอื่นๆ เมื่อได้ชุดข้อมูลของสัญญาณที่มีการตัดสัญญาณ จากนั้นนำสัญญาณดังกล่าวมาเข้าสู่กระบวนการจดจำรูปแบบ ซึ่งในโครงการวิจัยนี้ได้ใช้จำนวนเซลล์ประสาทเทียมในชั้นขาเข้า (Input Neuron) ที่คัดมามี 300 เซลล์ จำนวนเซลล์ประสาทเทียมในชั้นขาออก (Output Neuron) 2 เซลล์ (ซึ่งถูกกำหนดมาจากรูปแบบของสัญญาณการเคลื่อนไหวประเภทหกล้มและปกติ) ดังภาพที่ 4.30 ซึ่งจะกำหนดค่าตัวเลขของเซลล์ประสาทเทียมขาออกที่ต้องการของระบบจดจำรูปแบบตามตารางที่ 4.3

ตารางที่ 4.3 การกำหนดค่าตัวเลขของเซลล์ประสาทเทียมขาออก (Output Neuron)

รูปแบบสัญญาณขาเข้า (Input)	ค่าตัวเลขของสัญญาณขาออกเป้าหมาย (Desired Output) สำหรับโครงข่ายประสาทเทียม
สัญญาณการเคลื่อนไหวประเภทหกล้ม	1 0
สัญญาณการเคลื่อนไหวประเภทปกติ	0 1



ภาพที่ 4.30 โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (BPNN) โดยใช้วิธีคิดแบบ Winner-Take-

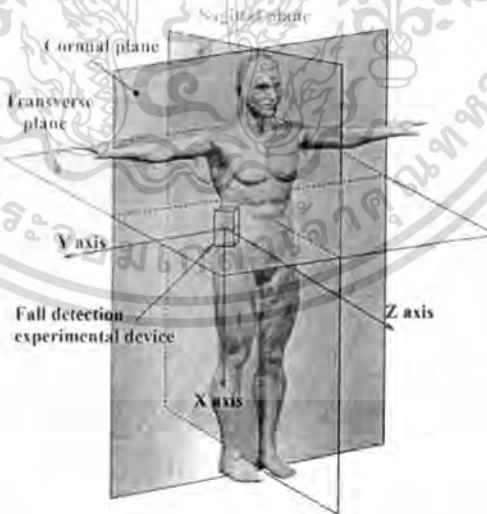
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้ All ที่ใช้ในการจดจำรูปแบบ และอนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 5

การทดลอง

5.1 การเตรียมข้อมูลสัญญาณการเคลื่อนไหวประเภทต่างๆ

Boyle และ Karunanithi [11] เป็นกลุ่มนักวิจัยชาวออสเตรเลียที่วิจัยเกี่ยวกับการพัฒนาอัลกอริทึมสำหรับตรวจจับการหกล้มโดยใช้ข้อมูลจากตัวตรวจจับความเร่งแบบ 2 แกน โดยกลุ่มนักวิจัยดังกล่าวได้ใช้ระบบตรวจวัดสัญญาณการเคลื่อนไหวสำหรับตรวจจับการหกล้มแบบกับเอวของผู้ใช้ (ในที่นี้ผู้ใช้เป็นผู้ป่วยสูงอายุซึ่งมีความเสี่ยงต่อการหกล้ม) และมีทิศทางของตัวตรวจจับความเร่งคือ แกนที่หนึ่งเป็นแกนตั้ง ส่วนแกนที่สองกำหนดให้เป็นแกนหน้า-หลัง สำหรับการทดลองของนักวิจัยดังกล่าวได้ใช้ผู้ป่วยสูงอายุจำนวน 15 คน มีระยะเวลาของการทดลองทั้งสิ้น 309 วันผู้ป่วย และค่าเฉลี่ยของจำนวนครั้งที่ผู้ป่วยสวมระบบตรวจวัดสัญญาณการเคลื่อนไหวคือ 18 วัน ผลการทดลองปรากฏว่ามีการหกล้มเกิดขึ้นจำนวนเพียง 4 ครั้งเท่านั้น เนื่องจากผลการทดลองดังกล่าวจะเห็นว่าจำนวนของการหกล้มที่เกิดขึ้นมีจำนวนน้อยมาก ดังนั้นข้อมูลที่บันทึกไว้ไม่เพียงพอที่จะสร้างอัลกอริทึมสำหรับตรวจจับการหกล้มได้



ภาพที่ 5.1 ตำแหน่งและทิศทางของการวางระบบตรวจจับสัญญาณการเคลื่อนไหว

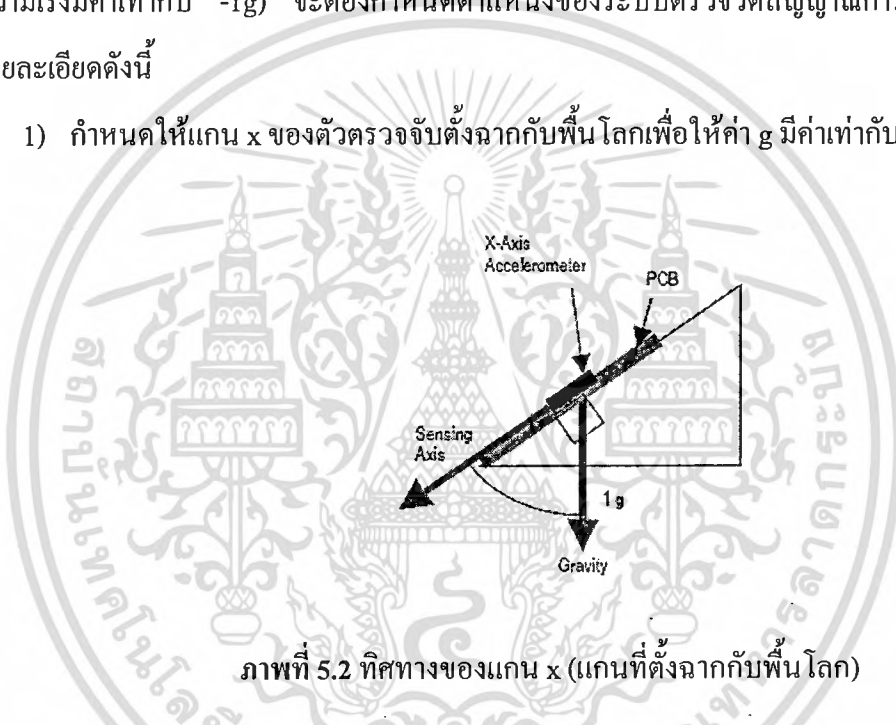
ด้วยเหตุผลข้างต้นการทดลองของงานวิจัยในครั้งนี้จึงเลือกที่จะใช้อาสาสมัครวัยรุ่นสุขภาพดี

5 คนเป็นผู้ชายจำนวน 4 คน และหญิงจำนวน 1 คนอายุประมาณ 18 – 22 ปีเพื่อจำลองกิจกรรมการ
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปเผยแพร่ในวงการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เคลื่อนไหวทั้งหมด 8 กิจกรรมได้แก่ การกระโดด การล้มตัวนอน การลุกจากเตียง การหกล้มไปด้านหน้า การหกล้มไปด้านหลัง การหกล้มไปข้างซ้าย การหกล้มไปข้างขวา และการล้มระหว่าง การลุกขึ้นยืน โดยให้อาสาสมัครทั้งหมดสวมระบบตรวจวัดสัญญาณการเคลื่อนไหวไว้ที่เอว และมีทิศทางของตัวตรวจจับความเร่งคือ แกน x เป็นแกนตั้งหรือแนวตั้งฉากกับพื้นโลก (Vertical axis) ดังภาพที่ 5.1

เพื่อให้การเก็บข้อมูลเป็นไปอย่างถูกต้องโดยไม่มีค่าออฟเซต (แกน x ของตัวตรวจจับความเร่งมีค่าเท่ากับ $-1g$) จะต้องกำหนดตำแหน่งของระบบตรวจวัดสัญญาณการเคลื่อนไหวตามรายละเอียดดังนี้

- 1) กำหนดให้แกน x ของตัวตรวจจับตั้งฉากกับพื้นโลกเพื่อให้ค่า g มีค่าเท่ากับ $\pm 1g$ ดังรูป



ภาพที่ 5.2 ทิศทางของแกน x (แกนที่ตั้งฉากกับพื้นโลก)

- 2) กำหนดให้โปรแกรมในคอนโทรลเลอร์ตรวจสอบความถูกต้องของทิศทางในการวางระบบตรวจวัดสัญญาณการเคลื่อนไหวที่ติดกับเอวของผู้ใช้ก่อนการจำลองทุกครั้ง โดยมุมของการวางระบบตรวจวัดสัญญาณการเคลื่อนไหว (θ) ต้องมีค่าเท่ากับ 0 องศา ซึ่งสามารถใช้สมการดังนี้

$$\theta = \arcsin\left(\frac{V_{OUT} - V_{OFFSET}}{SEN}\right), \quad (5.1)$$


กำหนดให้ V_{OUT} คือแรงดันไฟฟ้าที่ออกจากตัวตรวจจับความเร่ง V_{OFFSET} คือค่าครึ่งหนึ่งของ

แหล่งจ่ายไฟของตัวตรวจจับความเร่ง และ SEN คือค่าความละเอียดที่ตั้งให้กับตัวตรวจจับ

เอกสารนี้เป็นเอกสารลิขสิทธิ์สงวนไว้สำหรับใช้ในการเรียนการสอนเท่านั้น ไม่อนุญาตให้นำไปเผยแพร่ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ความเร่งแบบสามแกนในการตรวจจับสัญญาณการเคลื่อนไหว (SEN = 308 mV/g สำหรับรุ่น MMA7631) จากสมการ (5.1) จะเห็นได้ว่า ค่าผลลัพธ์ของตัวตรวจจับความเร่งจะมีเท่ากับ 1g ก็ต่อเมื่อค่าแรงดันจากตัวตรวจจับความเร่งมีค่าเท่ากับครึ่งหนึ่งของแรงดันไฟฟ้าจากแหล่งจ่ายไฟของตัวตรวจจับความเร่ง ซึ่งเมื่อนำสมการดังกล่าวมาสร้างกราฟเพื่อพิจารณาถึงความเอียงของระบบตรวจจับการหกล้มจะได้ดังภาพที่ 5.3 ซึ่งจะแสดงถึงความสัมพันธ์ระหว่างมุมในการจัดวางระบบตรวจวัดสัญญาณการเคลื่อนไหวและค่าแรงดันออกจากตัวตรวจจับความเร่ง



ตำแหน่งแกน x ของอุปกรณ์ (องศา)

ภาพที่ 5.3 ความสัมพันธ์ระหว่างมุมในการจัดวางระบบตรวจวัดสัญญาณการเคลื่อนไหวและค่าแรงดันออกของตัวตรวจจับความเร่ง

รายละเอียดของจำนวนครั้ง และระยะเวลาของแต่ละการจำลองกิจกรรมต่าง ๆ ได้แสดงไว้ตามตารางที่ 5.1 โดยที่สัญญาณที่บันทึกจากระบบตรวจจับการเคลื่อนไหวของมนุษย์สามารถแบ่งออกเป็น 2 กลุ่มดังนี้


- 1) กลุ่มสัญญาณสำหรับการฝึกสอนซึ่งเป็นสัญญาณตั้งไว้เป็นต้นแบบของระบบโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ
- 2) กลุ่มสัญญาณสำหรับการทดลองซึ่งเป็นสัญญาณที่จัดทำขึ้นสำหรับตรวจจับว่าสัญญาณนั้นเป็นสัญญาณของการเคลื่อนไหวประเภทหกล้มหรือไม่

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 5.1 รายละเอียดของการจำลองกิจกรรมต่าง ๆ


รายละเอียด	จำนวน ตัวอย่าง	สำหรับ ฝึกสอน	สำหรับการ ทดลอง	ระยะเวลา (วินาที)
การหกล้มไปข้างหลัง	25	5	20	10
การหกล้มไปข้างหน้า	25	5	20	10
การหกล้มไปข้างซ้าย	25	5	20	10
การหกล้มไปข้างขวา	25	5	20	10
การล้มระหว่างการลุกขึ้นยืน	25	5	20	10
การล้มตัวนอน	105	5	100	10
การลุกจากเตียง	105	5	100	10
การกระโดด	105	5	100	10

การเก็บตัวอย่างของข้อมูลสัญญาณการเคลื่อนไหวประเภทต่างๆ จะเก็บด้วยวิธีการจำลองพฤติกรรมแบบต่อเนื่องโดยมีระยะเวลาไว้ จากบทที่ 4 เราทราบว่าเวลาที่ใช้ในการหกล้มประมาณ 5 วินาที ดังนั้นทุกครั้ง que เก็บสัญญาณการเคลื่อนไหวประเภทการหกล้มก็จะจำลองพฤติกรรมการหกล้ม โดยเริ่มต้นจากการยืนนิ่งประมาณ 3 - 5 วินาที จากนั้นให้ผู้ทดลองล้มตัวลง (ต้องแสดงให้เห็นเหมือนการหกล้มจริง) เมื่อล้มจนกระทั่งพื้นก็ให้นอนนิ่งประมาณ 3 - 5 วินาที เช่นกัน จากนั้นให้ลุกขึ้นยืนนิ่งอีกครั้ง และก็เริ่มต้นจำลองพฤติกรรมต่อไปเรื่อยๆ จนกระทั่งครบตามจำนวนที่ต้องการ และสำหรับการจำลองพฤติกรรมอื่นๆ ก็ให้ทำในทำนองเดียวกัน ตัวอย่างของสัญญาณจากการทดลองดังภาพที่ 5.4 ถึง 5.11




ภาพที่ 5.4 ข้อมูลสัญญาณของการเคลื่อนไหวประเภทหกล้มไปด้านหลัง


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปเผยแพร่หรือนำไปใช้ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ภาพที่ 5.5 ข้อมูลสัญญาณของการเคลื่อนไหวประเภทหกล้มไปด้านหน้า




ภาพที่ 5.6 ข้อมูลสัญญาณของการเคลื่อนไหวประเภทหกล้มไปด้านซ้าย




ภาพที่ 5.7 ข้อมูลสัญญาณของการเคลื่อนไหวประเภทหกล้มไปด้านขวา


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ภาพที่ 5.8 ข้อมูลสัญญาณของการเคลื่อนไหวประเภทการล้มระหว่างการลุกขึ้นยืน




ภาพที่ 5.9 ข้อมูลสัญญาณของการเคลื่อนไหวประเภทลุกจากเตียง



ภาพที่ 5.10 ข้อมูลสัญญาณของการเคลื่อนไหวประเภทล้มตัวนอน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ภาพที่ 5.11 ข้อมูลสัญญาณของการเคลื่อนไหวประเภทการกระโดด

5.2 ผลการทดลองการตรวจจับสัญญาณการหกล้ม

ส่วนใหญ่งานวิจัยเช่น [2], [5], [8], [11] และ [12] ใช้การพิจารณาเพื่อหาประสิทธิภาพการทำงานของอัลกอริทึมสำหรับการตรวจจับการหกล้มของมนุษย์ด้วยวิธีการต่างๆ นั้นจะแสดงอยู่ในรูปของค่า sensitivity และ specificity ซึ่งมีรายละเอียดดังสมการ (5.2) และ (5.3)

$$\text{Sensitivity} = \frac{\text{TruePositives}}{\text{TruePositives} + \text{FalseNegatives}} \quad (5.2)$$

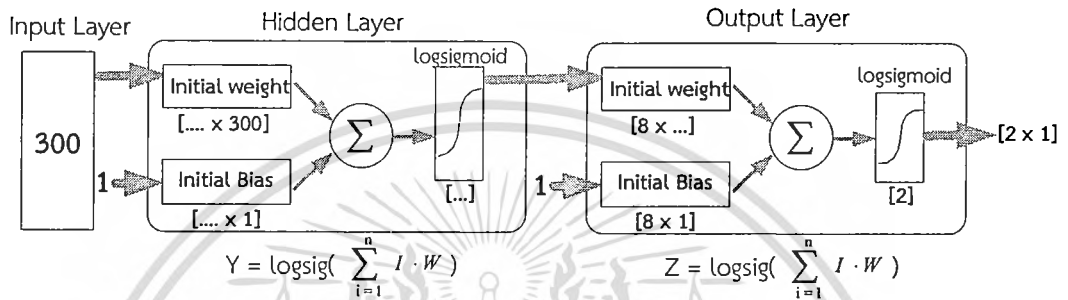
$$\text{Specificity} = \frac{\text{TrueNegatives}}{\text{TrueNegatives} + \text{FalsePositives}} \quad (5.3)$$

เมื่อกำหนดให้ TruePositives คือ จำนวนครั้งของสัญญาณการหกล้มที่ถูกระบุว่าเป็นการหกล้ม FalseNegatives คือ จำนวนครั้งของสัญญาณการหกล้มที่ถูกระบุว่าเป็นการเคลื่อนไหวปกติ TrueNegatives คือ จำนวนครั้งของสัญญาณการเคลื่อนไหวปกติที่ถูกระบุว่าเป็นการเคลื่อนไหวปกติ และสุดท้าย FalsePositives คือ จำนวนครั้งของสัญญาณการเคลื่อนไหวปกติที่ถูกระบุว่าเป็นการหกล้ม

สำหรับการทดลองมีดังนี้ ส่วนแรกเป็นการนำเสนอผลการทดลองการตรวจจับสัญญาณการหกล้มด้วยการใช้ค่าขีดเริ่มอย่างเดียว (ตรวจสอบด้วยค่าขีดเริ่มขอบบน (TH_{MAX}) และค่าขีดเริ่มขอบล่าง (TH_{MIN}) อย่างเดียว) ประสิทธิภาพของอัลกอริทึมสำหรับการตรวจจับการหกล้มแสดงด้วยค่า sensitivity และ specificity ดังตารางผลการทดลองที่ 5.2 ต่อมาเพื่อที่จะตรวจจับสัญญาณการหกล้มให้มีประสิทธิภาพมากขึ้น จึงได้เพิ่มกระบวนการจดจำรูปแบบด้วยโครงข่าย

ประสาทเทียมแบบแพร่ย้อนกลับ ซึ่งในการใช้โครงข่ายประสาทเทียมสามารถใช้วิธีการเรียนรู้ในเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นอนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

แบบต่างๆ เช่น Gradient Descent, Gradient Descent with Momentum และ Variable Learning Rate เป็นต้น โดยในเบื้องต้นจะต้องกำหนดโครงสร้างของโครงข่ายประสาทเทียมแบบ 3 ชั้นให้มีเซลล์ประสาทเทียม (Neuron) ในชั้นขาเข้า (Input) จำนวน 300 เซลล์ และในชั้นขาออก (Output) จำนวน 2 เซลล์ดังภาพที่ 5.12 ส่วนจำนวนเซลล์ประสาทเทียมในชั้นซ่อน (Hidden) จะต้องค้นหาจำนวนเซลล์ที่เหมาะสมโดยการทดสอบ ซึ่งผลการทดลองสามารถดูได้ดังตารางในหัวข้อ 5.2.2



ภาพที่ 5.12 โครงสร้างของโครงข่ายประสาทเทียมสำหรับการทดลอง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

5.2.1 ผลการทดลองการตรวจจับสัญญาณการหลั่งด้วยวิธีการกำหนดค่าขีดเริ่ม

ตารางที่ 5.2 ผลการทดลองการตรวจจับสัญญาณการหลั่งด้วยวิธีการกำหนดค่าขีดเริ่ม

ค่าขีดเริ่มสำหรับตรวจจับการหลั่ง	Sensitivity (%)	Specificity (%)
$TH_{MIN} = -1.5g, TH_{MAX} = 1.0g$	100.00	42.25
$TH_{MIN} = -1.5g, TH_{MAX} = 1.5g$	100.00	46.75
$TH_{MIN} = -1.5g, TH_{MAX} = 2.0g$	100.00	42.25
$TH_{MIN} = -1.5g, TH_{MAX} = 2.5g$	100.00	47.50
$TH_{MIN} = -1.5g, TH_{MAX} = 3.0g$	100.00	42.25
$TH_{MIN} = -2.0g, TH_{MAX} = 1.0g$	100.00	61.25
$TH_{MIN} = -2.0g, TH_{MAX} = 1.5g$	98.00	71.00
$TH_{MIN} = -2.0g, TH_{MAX} = 2.0g$	98.00	71.00
$TH_{MIN} = -2.0g, TH_{MAX} = 2.5g$	98.00	71.00
$TH_{MIN} = -2.0g, TH_{MAX} = 3.0g$	100.00	61.25
$TH_{MIN} = -2.5g, TH_{MAX} = 1.0g$	98.00	63.25
$TH_{MIN} = -2.5g, TH_{MAX} = 1.5g$	96.00	73.25
$TH_{MIN} = -2.5g, TH_{MAX} = 2.0g$	96.00	73.25
$TH_{MIN} = -2.5g, TH_{MAX} = 2.5g$	96.00	73.25
$TH_{MIN} = -2.5g, TH_{MAX} = 3.0g$	96.00	73.25
$TH_{MIN} = -3.0g, TH_{MAX} = 1.0g$	98.00	63.25
$TH_{MIN} = -3.0g, TH_{MAX} = 1.5g$	96.00	73.25
$TH_{MIN} = -3.0g, TH_{MAX} = 2.0g$	96.00	73.25
$TH_{MIN} = -3.0g, TH_{MAX} = 2.5g$	96.00	73.25
$TH_{MIN} = -3.0g, TH_{MAX} = 3.0g$	96.00	73.25

จากผลการทดลองด้วยวิธีการกำหนดค่าขีดเริ่มอย่างเดียว (การใช้ค่าขีดเริ่มขอบบนแทนด้วย TH_{MAX} และค่าขีดเริ่มขอบล่างแทนด้วย TH_{MIN}) ผลการทดลองปรากฏว่าค่า Sensitivity และ Specificity ที่ดีที่สุดคือ 100% และ 73.25% เมื่อกำหนดค่าขอบล่าง (TH_{MIN}) เท่ากับ -2.5g ส่วนค่าเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นอนุญาตให้นำไปเผยแพร่บนสื่อออนไลน์ การคัดลอกหรือทำซ้ำโดยไม่ได้รับอนุญาตถือว่าผิดกฎหมาย และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ขอบบน (TH_{MAX}) เท่ากับ 1.5g ดังนั้นจึงใช้ค่าขีดเริ่มนี้เป็นค่าขีดเริ่มสำหรับการทดลองในหัวข้อ 5.2.2 ต่อไป

5.2.2 ผลการทดลองการตรวจจับการหลั่งด้วยอัลกอริทึมที่นำเสนอ

5.2.2.1 ผลการทดลองการตรวจจับการหลั่งด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้

แบบ Gradient Descent (GD)

ตารางที่ 5.3 ผลการทดลองตรวจจับการหลั่งด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้

Gradient Descent

โครงสร้างโครงข่ายประสาทเทียม (Input-Hidden-Output)	จำนวนรอบการฝึกสอน	เวลาการฝึกสอน (วินาที)	Sensitivity (%)	Specificity (%)
300 – 80 – 2	5000	57.37	92.00	99.25
300 – 83 – 2	5000	58.20	93.00	98.25
300 – 86 – 2	5000	64.07	92.00	99.50
300 – 89 – 2	5000	59.98	95.00	98.25
300 – 92 – 2	5000	63.47	93.00	98.00
300 – 95 – 2	5000	65.84	93.00	99.50
300 – 98 – 2	5000	63.77	93.00	98.50
300 – 101 – 2	5000	63.38	92.00	98.75

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

5.2.2.2 ผลการทดลองการตรวจจัดการหกล้มด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้

Gradient Descent with Momentum (GDM)

ตารางที่ 5.4 ผลการทดลองการตรวจจัดการหกล้มด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้

Gradient Descent with Momentum

โครงสร้างโครงข่าย ประสาทเทียม (Input-Hidden-Output)	จำนวน รอบการ ฝึกสอน	เวลาการ ฝึกสอน (วินาที)	Sensitivity (%)	Specificity (%)
300 – 80 - 2	5000	66.28	96.00	73.25
300 – 86 - 2	5000	59.88	95.00	98.50
300 – 92 - 2	5000	62.36	95.00	98.50
300 – 98 - 2	5000	69.82	69.00	100.00
300 – 104 - 2	5000	61.92	96.00	73.25
300 – 110 - 2	5000	64.93	88.00	99.50
300 – 116 - 2	5000	66.73	75.00	83.00
300 – 119 - 2	5000	70.43	60.00	99.50

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

5.2.2.3 ผลการทดลองการตรวจจับการหลัดด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้

Variable Learning Rate (GDA)

ตารางที่ 5.5 ผลการทดลองการตรวจจับการหลัดด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้

Variable Learning Rate

โครงสร้างโครงข่าย ประสาทเทียม (Input-Hidden-Output)	จำนวน รอบการ ฝึกสอน	เวลาการ ฝึกสอน (วินาที)	Sensitivity (%)	Specificity (%)
300 – 93 – 2	338	3.74	91.00	99.25
300 – 99 – 2	334	3.95	92.00	98.25
300 – 102 – 2	334	4.18	94.00	99.75
300 – 111 – 2	374	4.95	93.00	99.50
300 – 114 – 2	367	4.88	94.00	98.00
300 – 123 – 2	373	5.39	95.00	98.25
300 – 126 – 2	336	4.85	93.00	98.50
300 – 129 – 2	370	5.39	91.00	98.00

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

5.2.2.4 ผลการทดลองการตรวจจัดการหกล้มด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้

Variable Learning Rate with Momentum (GDX)

ตารางที่ 5.6 ผลการทดลองการตรวจจัดการหกล้มด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้

Variable Learning Rate with Momentum

โครงสร้างโครงข่าย ประสาทเทียม (Input-Hidden-Output)	จำนวน รอบการ ฝึกสอน	เวลาการ ฝึกสอน (วินาที)	Sensitivity (%)	Specificity (%)
300 – 84 - 2	1216	13.55	95.00	99.75
300 – 88 - 2	272	3.97	91.00	99.75
300 – 90 - 2	1185	13.82	94.00	99.50
300 – 100 - 2	1744	21.40	93.00	99.00
300 – 102 - 2	1499	17.69	96.00	99.25
300 – 112 - 2	1519	19.43	94.00	98.75
300 – 122 - 2	1699	22.29	94.00	98.75
300 – 138 - 2	2070	30.26	95.00	99.25

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

5.2.2.5 ผลการทดลองการตรวจจับการหลัดด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้

Resilient (RP)

ตารางที่ 5.7 ผลการทดลองการตรวจจับการหลัดด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้

Resilient

โครงสร้างโครงข่าย ประสาทเทียม (Input-Hidden-Output)	จำนวน รอบการ ฝึกสอน	เวลาการ ฝึกสอน (วินาที)	Sensitivity (%)	Specificity (%)
300 – 82 - 2	27	0.81	90.00	99.50
300 – 86 - 2	27	0.72	90.00	99.25
300 – 90 - 2	34	0.85	94.00	98.50
300 – 94 - 2	30	0.79	91.00	99.00
300 – 102 - 2	26	0.82	89.00	99.25
300 – 114 - 2	29	2.59	92.00	74.00
300 – 122 - 2	27	0.78	90.00	98.75
300 – 124 - 2	31	1.03	90.00	99.25

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

5.2.2.6 ผลการทดลองการตรวจจับการหล่มด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้

Fletcher-Reeve Conjugate Gradient (CGF)

ตารางที่ 5.8 ผลการทดลองการตรวจจับการหล่มด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้

Fletcher-Reeve conjugate Gradient

โครงสร้างโครงข่าย ประสาทเทียม (Input-Hidden-Output)	จำนวน รอบการ ฝึกสอน	เวลาการ ฝึกสอน (วินาที)	Sensitivity (%)	Specificity (%)
300 – 80 - 2	257	5.94	96.00	73.25
300 – 88 - 2	114	3.84	91.00	98.75
300 – 94 - 2	90	3.41	88.00	99.75
300 – 104 - 2	121	3.20	94.00	98.00
300 – 106 - 2	22	1.05	94.00	99.00
300 – 108 - 2	241	5.96	92.00	97.75
300 – 130 - 2	16	1.05	96.00	77.00
300 – 140 - 2	56	2.10	92.00	100.00

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

5.2.2.7 ผลการทดลองการตรวจจับการหลั่งด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้

Polak-Ribière Conjugate Gradient (CGP)

ตารางที่ 5.9 แสดงผลการทดลองการตรวจจับการหลั่งด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้

Polak-Ribière Conjugate Gradient

โครงสร้างโครงข่ายประสาทเทียม (Input-Hidden-Output)	จำนวนรอบการฝึกสอน	เวลาการฝึกสอน (วินาที)	Sensitivity (%)	Specificity (%)
300 – 84 - 2	34	1.50	93.00	99.50
300 – 88 - 2	58	2.89	84.00	99.75
300 – 92 - 2	28	1.16	93.00	98.25
300 – 94 - 2	38	1.44	93.00	99.50
300 – 96 - 2	35	1.43	94.00	98.25
300 – 106 - 2	43	1.45	93.00	99.50
300 – 108 - 2	25	1.01	75.00	99.00
300 – 110 - 2	48	1.90	94.00	99.25

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

5.2.2.8 ผลการทดลองการตรวจจับการหลัดด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้

Conjugate Gradient with Powell/Beale Restarts (CGB)

ตารางที่ 5.10 แสดงผลการทดลองการตรวจจับการหลัดด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้ Conjugate Gradient with Powell/Beale Restarts

โครงสร้างโครงข่ายประสาทเทียม (Input-Hidden-Output)	จำนวนรอบการฝึกสอน	เวลาการฝึกสอน (วินาที)	Sensitivity (%)	Specificity (%)
300 – 80 – 2	22	0.90	88.00	99.50
300 – 94 – 2	35	1.18	94.00	99.50
300 – 96 – 2	36	1.79	91.00	99.75
300 – 102 – 2	35	1.26	93.00	99.50
300 – 126 – 2	41	2.48	79.00	99.50
300 – 130 – 2	72	3.68	92.00	99.00
300 – 132 – 2	24	1.36	95.00	99.00
300 – 140 – 2	42	2.65	94.00	99.00

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

5.2.2.9 ผลการทดลองการตรวจจับการหลัดด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้

Scaled Conjugate Gradient (SCG)

ตารางที่ 5.11 แสดงผลการทดลองการตรวจจับการหลัดด้วยอัลกอริทึมที่นำเสนอกับวิธีการเรียนรู้ Scaled Conjugate Gradient

โครงสร้างโครงข่าย ประสาทเทียม (Input-Hidden-Output)	จำนวน รอบการ ฝึกสอน	เวลาการ ฝึกสอน (วินาที)	Sensitivity (%)	Specificity (%)
300 - 80 - 2	57	1.63	93.00	98.25
300 - 94 - 2	218	6.04	90.00	99.25
300 - 96 - 2	1	0.31	96.00	73.25
300 - 102 - 2	113	3.77	92.00	99.50
300 - 126 - 2	90	3.59	94.00	98.75
300 - 130 - 2	99	2.84	93.00	97.75
300 - 132 - 2	98	2.78	94.00	99.50
300 - 140 - 2	1	132.19	96.00	73.50

5.2.2.10 ผลการทดลองด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้ One-Step Secant (OSS)

ตารางที่ 5.12 แสดงผลการทดลองการตรวจจับการหลัดด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้ One-Step Secant

โครงสร้างโครงข่ายประสาทเทียม (Input-Hidden-Output)	จำนวนรอบการฝึกสอน	เวลาการฝึกสอน (วินาที)	Sensitivity (%)	Specificity (%)
300 – 82 – 2	2216	74.80	96.00	73.25
300 – 86 – 2	1	0.33	96.00	73.25
300 – 88 – 2	630	60.50	96.00	73.25
300 – 92 – 2	2	0.35	11.00	99.25
300 – 94 – 2	1	0.30	96.00	73.25
300 – 96 – 2	99	4.23	96.00	73.25
300 – 112 – 2	779	70.99	96.00	73.25
300 – 134 – 2	1	0.33	9.00	100.00

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

5.2.3 ผลการทดลองการตรวจจับการหลัดด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้แบบ
Variable Learning Rate with Momentum (GDX) เมื่อปรับเปลี่ยนค่าขีดเริ่ม

ตารางที่ 5.13 แสดงผลการทดลองการตรวจจับการหลัดด้วยวิธีการเรียนรู้ Variable Learning
Rate with Momentum (GDX) เมื่อปรับเปลี่ยนค่าขีดเริ่ม

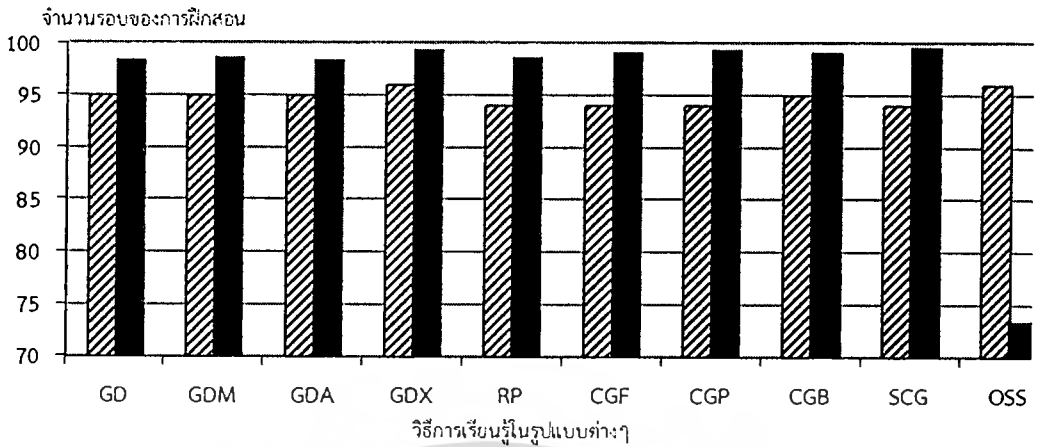
ค่าขีดเริ่มสำหรับตรวจจับการหลัด	Sensitivity (%)	Specificity (%)
$TH_{MIN} = -1.5g, TH_{MAX} = 1.0g$	100.00	93.50
$TH_{MIN} = -1.5g, TH_{MAX} = 1.5g$	100.00	94.75
$TH_{MIN} = -1.5g, TH_{MAX} = 2.0g$	100.00	94.75
$TH_{MIN} = -1.5g, TH_{MAX} = 2.5g$	96.00	95.00
$TH_{MIN} = -1.5g, TH_{MAX} = 3.0g$	96.00	95.00
$TH_{MIN} = -2.0g, TH_{MAX} = 1.0g$	100.00	96.00
$TH_{MIN} = -2.0g, TH_{MAX} = 1.5g$	98.00	98.75
$TH_{MIN} = -2.0g, TH_{MAX} = 2.0g$	96.00	98.75
$TH_{MIN} = -2.0g, TH_{MAX} = 2.5g$	82.00	99.00
$TH_{MIN} = -2.0g, TH_{MAX} = 3.0g$	79.00	99.00
$TH_{MIN} = -2.5g, TH_{MAX} = 1.0g$	98.00	96.50
$TH_{MIN} = -2.5g, TH_{MAX} = 1.5g$	96.00	99.25
$TH_{MIN} = -2.5g, TH_{MAX} = 2.0g$	94.00	99.25
$TH_{MIN} = -2.5g, TH_{MAX} = 2.5g$	79.00	99.50
$TH_{MIN} = -2.5g, TH_{MAX} = 3.0g$	75.00	99.50
$TH_{MIN} = -3.0g, TH_{MAX} = 1.0g$	95.00	96.50
$TH_{MIN} = -3.0g, TH_{MAX} = 1.5g$	92.00	99.25
$TH_{MIN} = -3.0g, TH_{MAX} = 2.0g$	90.00	99.25
$TH_{MIN} = -3.0g, TH_{MAX} = 2.5g$	75.00	99.50
$TH_{MIN} = -3.0g, TH_{MAX} = 3.0g$	69.00	99.50

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

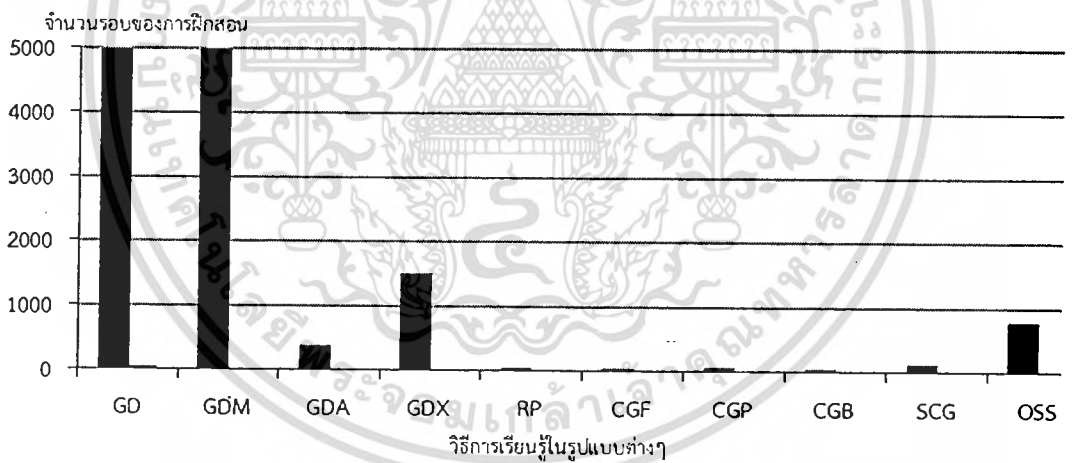
5.3 วิเคราะห์ผลการทดลอง

จากผลการทดลองในหัวข้อที่ 5.2 ส่วนแรกเป็นการทดลองด้วยการวิธีการกำหนดค่าขีดเริ่มอย่างเดียว (การใช้ค่าขีดเริ่มขอบบนแทนด้วย TH_{MAX} และค่าขีดเริ่มขอบล่างแทนด้วย TH_{MIN}) ซึ่งผลการทดลองการตรวจจับการหกล้มด้วยวิธีการกำหนดค่าขีดเริ่มอย่างเดียวยุติปรากฏว่า เมื่อกำหนดค่าขีดเริ่มขอบล่าง (TH_{MIN}) สูงๆ จะทำให้ค่า sensitivity ให้ค่าความถูกต้อง 100% แต่ในทางตรงข้ามค่า specificity ให้ค่าความถูกต้องน้อย เนื่องจากการเคลื่อนไหวของการหกล้มส่วนใหญ่จะให้ค่าความเร่งจากตัวตรวจจับความเร่งต่ำกว่า $-1.5g$ ส่วนการเคลื่อนไหวปกติส่วนใหญ่มีค่าความเร่งสูงกว่า $-1.5g$ โดยเฉพาะอย่างยิ่งการเคลื่อนไหวประเภทจับพัต และเมื่อลดค่าขีดเริ่มขอบล่าง (TH_{MIN}) ให้ต่ำกว่า $-2.0g$ จะทำให้ค่าความถูกต้อง sensitivity ลดลงเล็กน้อยเนื่องจากสัญญาณการหกล้มบางครั้งที่ทำให้ค่าความเร่งจากตัวตรวจจับความเร่งมีค่าสูงกว่า $-2.0g$ และ specificity เพิ่มขึ้น เนื่องจากการเคลื่อนไหวปกติส่วนใหญ่ (นอกจากการเคลื่อนไหวประเภทการโดด) มีค่าความเร่งจากตัวตรวจจับความเร่งไม่ต่ำกว่า $-2.0g$ และไม่สูงกว่า $1.0g$ จึงทำให้ค่า specificity มีค่าเพิ่มขึ้น หากพิจารณาผลการทดลองทั้งหมดแล้วค่าขีดเริ่มขอบล่าง (TH_{MIN}) และขอบบน (TH_{MAX}) เท่ากับ $-2.5g$ $1.5g$ ตามลำดับ ที่ให้ค่าผลการทดลองที่ดีที่สุดคือ Sensitivity และ Specificity 96.00 % เท่ากับ 73.25% ตามลำดับ ดังนั้นเบื้องต้นได้เลือกใช้ค่าขอบล่าง (TH_{MIN}) เท่ากับ $-2.5g$ และค่าขอบบน (TH_{MAX}) เท่ากับ $1.5g$ เพื่อตรวจจับสัญญาณการหกล้ม

ต่อมาเพื่อที่จะเพิ่มประสิทธิภาพของอัลกอริทึมสำหรับตรวจจับการหกล้ม จึงได้นำอัลกอริทึมสำหรับการจดจำรูปแบบ โดยงานวิจัยครั้งนี้ได้ใช้โครงข่ายประสาทเทียมแบบแพร่ย้อนกลับโดยอาศัยการเรียนรู้แบบต่างๆ เพื่อเปรียบเทียบความเร็วในการฝึกสอนได้แก่ Gradient Descent Backpropagation algorithm, Gradient Descent with Momentum Backpropagation algorithm, Variable Learning Rate Backpropagation algorithm เป็นต้น ซึ่งสามารถดูรายละเอียดดังต่อไปนี้



ภาพที่ 5.13 แผนภูมิแสดงความถูกต้องในการประมวลผลด้วยวิธีการเรียนรู้ในรูปแบบต่างๆ (แผนภูมิแท่งซ้ายแสดงถึงความถูกต้องของการตรวจจับการเคลื่อนไหวประเภทปกติ ส่วนแผนภูมิแท่งที่บแสดงถึงความถูกต้องของการตรวจจับการเคลื่อนไหวประเภทหลั้มว่าเป็นการหลั้ม)



ภาพที่ 5.14 แผนภูมิแสดงจำนวนรอบในการประมวลผลด้วยวิธีการเรียนรู้ในรูปแบบต่างๆ

สำหรับผลการทดลองของการใช้อัลกอริทึมที่นำเสนอ (วิธีผสมระหว่างกำหนดค่าขีดเริ่มและโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับด้วยการเรียนรู้ในรูปแบบต่างๆ) ซึ่งผลการทดลองได้แสดงดังตารางที่ 5.3 ถึงตารางที่ 5.12 โดยกำหนดค่าขีดเริ่มขอล่าง (TH_{MIN}) เท่ากับ $-2.5g$ และค่าขีดเริ่มขอบบน (TH_{MAX}) เท่ากับ $1.5g$ และใช้โครงสร้างของโครงข่ายประสาทเทียมแบบ 3 ชั้นดังภาพที่ 5.12 ซึ่งจะต้องหาจำนวนนิวรัลในชั้นซ่อน (Hidden Layer) ที่เหมาะสม จากตารางผลการ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ทดลองในแต่ละแถวได้แสดงจำนวนนิวรัลของชั้นซ่อน (Hidden Layer) และค่าความถูกต้องในรูปของค่า Sensitivity และ Specificity ซึ่งโครงการวิจัยนี้ได้นำเสนอเฉพาะจำนวนนิวรัลที่ให้ความถูกต้องหรือประสิทธิภาพมากเป็นอันดับต้นๆ จำนวน 8 ตัวอย่างเท่านั้น (สำหรับการทดลองในครั้งนี้ได้ทดลองเปลี่ยนจำนวนนิวรัลในชั้นซ่อนไปจนกว่าจะพบจำนวนนิวรัลที่เหมาะสม และนำเฉพาะส่วนที่มีค่าความถูกต้องสูงสุดเป็นอันดับต้นๆ) แต่ละโครงสร้างที่มีจำนวนนิวรัลในชั้นซ่อนที่แตกต่างกันจะทำให้ค่าความถูกต้องที่แตกต่างกันด้วย นอกจากนี้แล้วตารางผลการทดลองดังกล่าวยังแสดงจำนวนรอบของการฝึกสอน และเวลาของการฝึกสอน สำหรับร้อยละของค่าความถูกต้อง (ค่า Sensitivity และ Specificity) ทั้งหมดที่ได้แสดงจะเป็นตัวแปรสำคัญของการพิจารณาในการเลือกจำนวนนิวรัลที่เหมาะสมสำหรับโครงข่ายประสาทเทียมแบบแพร่ย้อน แต่ถ้าในกรณีมีความถูกต้องเท่ากันก็ต้องมาพิจารณาในเรื่องของจำนวนนิวรัลของชั้นซ่อนที่น้อยที่สุด เนื่องจากจำนวนนิวรัลยิ่งน้อยก็เป็นการประหยัดหน่วยความจำและจะทำให้ความเร็วในการประมวลผลเร็วขึ้น ซึ่งในแต่ละวิธีการเรียนรู้ในรูปแบบต่างๆ ที่มีจำนวนนิวรัลที่แตกต่างกัน จะให้ค่าความถูกต้องที่แตกต่างกันด้วยดังแสดงดังภาพที่ 5.13 ที่แสดงถึงค่าร้อยละของ Sensitivity และ Specificity ในแต่ละวิธีการเรียนรู้แบบต่างๆ ซึ่งจากการทดลองพบว่าวิธีการเรียนรู้แบบ Variable Learning Rate with Momentum (GDX) ที่ให้ค่า Sensitivity และ Specificity มากที่สุด คือมีค่าความถูกต้องถึง 96.00% และ 99.25% ตามลำดับ

ต่อมาเมื่อนำโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับกับการเรียนรู้แบบ Variable Learning Rate with Momentum Backpropagation algorithm (GDX) มาทดลองปรับเปลี่ยนค่าขีดเริ่มขอบล่าง (TH_{MIN}) และขอบบน (TH_{MAX}) ดังการทดลองในหัวข้อ 5.2.4 ผลการทดลองปรากฏว่าจากค่าขีดเริ่มที่ทำให้ค่า Sensitivity และ Specificity ที่ดีที่สุดคือ 100% และ 96% ตามลำดับซึ่งมีค่าขีดเริ่มขอบล่าง (TH_{MIN}) และขอบบน (TH_{MAX}) เท่ากับ -2.0g 1.0g ดังตารางผลการทดลองที่ 5.36

เมื่อนำผลการทดลองมาเปรียบเทียบกับอัลกอริทึมในอดีตที่ผ่านมา (Boyle และ Karunanithi [11] Perry และคณะ [2] C-C. Wang [4] และ Yang และ Zhao [7]) โดยใช้กลุ่มตัวอย่างกลุ่มเดียวกันกับการทดลองในครั้งนี้จำนวน 20 ตัวอย่าง ผลการทดลองพบว่าอัลกอริทึมที่กำหนดค่าขีดเริ่มอย่างเดี่ยวไม่สามารถแยกการเคลื่อนไหวแบบฉับพลันและการหกล้มได้อย่างมีประสิทธิภาพดังตารางผลการทดลองที่ 5.14

ตารางที่ 5.14 แสดงผลการทดลองเชิงเปรียบเทียบ

อัลกอริทึมที่ใช้ค่าขีดเริ่ม	Sensitivity (%)	Specificity (%)
Perry และคณะ [2]	91.00%	78.75%
C-C. Wang [4]	95.00%	73.75%
Yang และ Zhao [7]	96.25%	73.75%
Boyle และ Karunanithi [11]	96.25%	75.00%
อัลกอริทึมที่นำเสนอ	100.00%	96.00%

จากตารางที่ 5.14 ผลการทดลองเชิงเปรียบเทียบพบว่า อัลกอริทึมที่ใช้ค่าขีดเริ่มอย่างเดียวนั้น Boyle และ Karunanithi [11] Perry และคณะ และ [2] C-C. Wang [4] เป็นต้น มีประสิทธิภาพที่ใกล้เคียงกันคือ มีค่า Sensitivity อยู่ระหว่าง 91.00% – 96.00% และมีค่า Specificity อยู่ระหว่าง 73.75% – 78.75% ซึ่งมีประสิทธิภาพด้อยกว่าเมื่อเปรียบเทียบกับผลการทดลองในโครงการวิจัยนี้แล้ว เนื่องจากสถานการณ์การเคลื่อนไหวแบบฉับพลันมีจุดยอดของความเร่งที่ใกล้เคียงกับจุดยอดของสถานการณ์หักล้ม แต่เมื่ออัลกอริทึมที่นำเสนอได้เพิ่มกระบวนการจดจำรูปแบบของสัญญาณด้วยโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับทำให้อัลกอริทึมมีความสามารถในการแยกสัญญาณโดยการจดจำรูปแบบได้ จึงทำให้อัลกอริทึมที่นำเสนอมีประสิทธิภาพมากขึ้นเมื่อเทียบอัลกอริทึมที่ใช้การกำหนดค่าขีดเริ่มอย่างเดียว ซึ่งมีค่า Sensitivity และ Specificity 100% และ 96% ตามลำดับ

บทที่ 6

สรุปผลการทดลอง

ในการศึกษาอัลกอริทึมสำหรับการตรวจจับการหกล้มของผู้สูงอายุด้วยตัวตรวจจับความเร่ง แขนเดียวเริ่มต้นด้วยขั้นตอนการประดิษฐ์ระบบตรวจวัดสัญญาณการเคลื่อนไหว ต่อมาเป็นขั้นตอนของพัฒนาอัลกอริทึมการตรวจจับการหกล้มของผู้สูงอายุ สำหรับข้อมูลของสัญญาณการเคลื่อนไหว ผู้วิจัยได้ทำการจำลองขึ้นจากอาสาสมัครสุขภาพดีอายุประมาณ 18 – 22 ปีจำนวน 5 คน (หญิง 1 คน และชาย 4 คน) เพื่อนำสัญญาณการเคลื่อนไหวมาใช้ทดสอบกับอัลกอริทึมที่นำเสนอ เบื้องต้นได้ให้ความสนใจกิจกรรมการเคลื่อนไหว 8 กิจกรรมได้แก่ การกระโดด การล้มตัวนอน การลุกจากเตียง การหกล้มไปด้านหน้า การหกล้มไปด้านหลัง การหกล้มไปข้างซ้าย การหกล้มไปข้างขวา และการล้มระหว่างการลุกขึ้นยืนดังแสดงรายละเอียดในตารางที่ 5.1 ระบบตรวจจับการเคลื่อนไหวจะบันทึกสัญญาณการเคลื่อนไหวออกมาในรูปของสัญญาณความเร่งด้วยตัวตรวจจับความเร่ง และบันทึกลงใน SD card สัญญาณทั้งหมดถูกแบ่งออกเป็น 2 ส่วน ส่วนแรกสำหรับใช้ในการฝึกสอน และส่วนที่ใช้ในการทดลอง สำหรับอัลกอริทึมการตรวจจับการหกล้มประกอบด้วย 3 ขั้นตอนคือ

- 1) การตรวจจับสัญญาณการเคลื่อนไหวแบบฉับพลันและหกล้มด้วยการกำหนดค่าขีดเริ่ม
- 2) การตัดสัญญาณ
- 3) การตรวจจับการหกล้มด้วยวิธีโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ กล่าวคือ อัลกอริทึมเริ่มต้นด้วยการป้อนสัญญาณการเคลื่อนไหวประเภทต่าง ๆ เข้าไประบบการตรวจจับการหกล้มที่มีการกำหนดค่าขีดเริ่มเพื่อตรวจจับว่าเป็นสัญญาณการเคลื่อนไหวแบบฉับพลันและการหกล้ม โดยระบบจะตรวจหาค่าขนาดความเร่งว่ามีค่าสัญญาณอยู่นอกช่วงค่าขีดเริ่ม (น้อยกว่าค่า TH_{MIN} และมากกว่าค่า TH_{MAX}) หรือไม่ หากเป็นไปตามนั้นระบบจะกำหนดตำแหน่งขึ้นมาเพื่อเป็นจุดเริ่มต้น (t_{start}) ของการหาจุดยอดสูงสุดของสัญญาณ (t_{peak}) ซึ่งอยู่ในช่วง $t_{start} + 299$ ตัวอย่าง เมื่อพบตำแหน่งของจุดยอดสูงสุดของสัญญาณ (t_{peak}) แล้วระบบจะตัดสัญญาณภายในช่วง $t_{peak} - 150$ ตัวอย่าง ถึง $t_{peak} + 149$ ตัวอย่าง โดยนำสัญญาณที่ตัดมาได้ส่งไปยังโครงข่ายประสาทเทียมเพื่อจำแนกว่าเป็นการสัญญาณการหกล้มหรือไม่ โดยโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับสามารถใช้วิธีการเรียนรู้ได้หลายรูปแบบได้แก่ Gradient Descent Backpropagation algorithm, Gradient Descent with Momentum Backpropagation algorithm, Variable Learning Rate with Momentum

Backpropagation algorithm, Resilient Backpropagation algorithm, Scaled Conjugate Gradient

เอกสารนี้เป็นเอกสารสิทธิ์ของโครงการวิจัยนี้เพื่อใช้ในการศึกษาเท่านั้น และผู้ดูแลระบบจะไม่รับผิดชอบต่อการใช้งานใดๆ
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


algorithm, Conjugate Gradient with Powell/Beale Restarts Backpropagation algorithm, Fletcher-Reeve Conjugate Gradient Backpropagation algorithm, Polak-Ribière Conjugate Gradient Backpropagation algorithm

จากผลการทดลองในบทที่ 5 เราได้นำเสนอการทดลองระบบการตรวจจับการหกล้มของผู้สูงอายุที่แบ่งออกเป็น 3 ส่วนดังนี้ ส่วนแรกเป็นการทดลองด้วยวิธีการกำหนดค่าขีดเริ่มอย่างเดียว (การใช้ค่าขีดเริ่มขอบบนแทนด้วย TH_{MAX} และค่าขีดเริ่มขอบล่างแทนด้วย TH_{MIN}) ซึ่งผลการทดลองปรากฏว่าค่าขีดเริ่มของค่าขอบล่าง (TH_{MIN}) เท่ากับ $-2.5g$ ค่าขอบบน (TH_{MAX}) เท่ากับ $1.5g$ ได้ค่า Sensitivity และ Specificity 100% เท่ากับ 73.25% ตามลำดับ ซึ่งเป็นผลการทดลองที่ให้ค่าความถูกต้องสูงที่สุด ส่วนที่สองเป็นการทดลองที่ผสมผสานวิธีการกำหนดค่าขีดเริ่มและวิธีโครงข่ายประสาทเทียม โดยนำค่าขีดเริ่มที่ดีที่สุดจากการทดลองในหัวข้อ 5.2.2 มาใช้เป็นค่าขีดเริ่มในอัลกอริทึมการตรวจจับการหกล้มของผู้สูงอายุที่จะนำเสนอในโครงการวิจัยนี้ เมื่ออัลกอริทึมตรวจพบสัญญาณที่อยู่นอกช่วงค่าขีดเริ่ม ระบบจะตัดสัญญาณเพื่อกำหนดสัญญาณที่จะป้อนให้กับโครงข่ายประสาทเทียม ซึ่งโครงข่ายประสาทเทียมที่ได้เลือกใช้คือโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับกับการเรียนรู้ในแบบต่างๆ มาใช้ทดสอบการความถูกต้องและความเร็วในการประมวลผล ซึ่งผลการทดลองปรากฏว่าประสิทธิภาพของวิธีการเรียนรู้แบบ Variable Learning Rate with Momentum Backpropagation algorithm (GDX) ให้ค่า Specificity 96.00% และ 99.25% ตามลำดับ เป็นค่าความถูกต้องที่ดีที่สุด


ต่อมาเมื่อนำโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับกับการเรียนรู้แบบ Variable Learning Rate with Momentum Backpropagation algorithm (GDX) มาทดลองปรับเปลี่ยนค่าขีดเริ่มขอบล่าง (TH_{MIN}) และขอบบน (TH_{MAX}) ดังการทดลองในหัวข้อ 5.2.4 ผลการทดลองปรากฏว่าค่าขีดเริ่มที่ทำให้ค่า Sensitivity และ Specificity ที่ดีที่สุดคือ 100% และ 96% ตามลำดับ โดยมีค่าขีดเริ่มขอบล่าง (TH_{MIN}) และขอบบน (TH_{MAX}) เท่ากับ $-2.0g$ $1.0g$ ตามลำดับ ดังตารางผลการทดลองที่ 5.36 สำหรับรายละเอียดผลการทดลองแต่ละกิจกรรมดังภาพที่ 6.1 (สำหรับค่า sensitivity) และภาพที่ 6.2 (สำหรับค่า specificity) เพราะฉะนั้นการเลือกค่าขีดเริ่มที่เหมาะสมจึงมีความสำคัญต่อระบบตรวจจับการหกล้ม เนื่องจากเป็นตัวกำหนดว่าจะสัญญาณจะถูกส่งไปยังโครงข่ายประสาทเทียมหรือไม่ ถ้ากำหนดขอบเขตที่แคบเกินไปจะทำให้โครงข่ายประสาทเทียมทำงานหนัก เพราะสัญญาณการเคลื่อนไหวปกติจะมีความแรงที่อยู่ในช่วง $\pm 1g$ แต่หากกำหนดค่าขีดเริ่มที่มีขอบเขต

สูงเกินไป ระบบตรวจจับการหกล้มจะเกิดความผิดพลาดได้ไหม เนื่องจากสัญญาณการหกล้มบางครั้งไม่ได้มีค่าความเร่งเกินขอบเขต -2.0g และ 1.0g

ดังนั้น โครงการวิจัยนี้จึงสรุปว่าระบบการตรวจจับสัญญาณการหกล้มประกอบด้วย 2 ขั้นตอนการประมวลผลดังนี้ ขั้นตอนการประมวลผลด้วยวิธีการกำหนดค่าขีดเริ่ม และขั้นตอนการประมวลผลด้วยวิธีการจดจำรูปแบบด้วยโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ ซึ่งจากผลการทดลองจึงได้เลือกโครงข่ายประสาทเทียมที่มีโครงสร้างแบบ 3 ชั้น และในแต่ละชั้นประกอบด้วยจำนวนนิวรัลดังนี้ ชั้นสัญญาณขาเข้ามีจำนวน 300 นิวรัล ชั้นซ่อนมีจำนวน 102 นิวรัล และชั้นสัญญาณขาออกมีจำนวน 2 นิวรัล โดยใช้วิธีการเรียนรู้แบบ Variable Learning Rate with Momentum Backpropagation algorithm (GDX) และกำหนดให้ค่าขีดเริ่มขอบล่าง (TH_{MIN}) เท่ากับ 2.0g และขอบบน (TH_{MAX}) เท่ากับ 1.0g เนื่องจากให้ผลค่าความถูกต้องสูงที่สุด



ภาพที่ 6.1 ประสิทธิภาพการทำงานของอัลกอริทึมการตรวจจับการหกล้มด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้แบบ Variable Learning Rate with Momentum (GDX)



ภาพที่ 6.2 ประสิทธิภาพการทำงานของอัลกอริทึมการตรวจจับการหกล้มด้วยอัลกอริทึมที่นำเสนอกับการเรียนรู้แบบ Variable Learning Rate with Momentum (GDX)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับครู/ช่างงานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปเผยแพร่บนสื่อออนไลน์ การคัดลอกหรือการนำข้อมูลไปใช้โดยไม่ได้รับอนุญาตถือว่าผิดกฎหมาย และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สำหรับการตรวจจับที่ผิดพลาดในบางกิจกรรมเช่น การกระโดด การลุกจากเตียง และการล้มตัวนอน เนื่องจากบางจังหวะของการเคลื่อนไหวอาจจะเกิดการเคลื่อนไหวแบบฉับพลัน ซึ่งทำให้สัญญาณความเร่งที่เกิดขึ้นมีค่าใกล้เคียงกับสัญญาณการหกล้ม อัลกอริทึมจึงมีความผิดพลาดขึ้น แต่ทั้งนี้เมื่อพิจารณาจากผลการทดลองก็ยังคงแสดงให้เห็นว่า การตรวจจับสัญญาณการหกล้มด้วยวิธีผสมระหว่างการใช่วิธีการกำหนดค่าขีดเริ่มและโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับสามารถตรวจจับสัญญาณการหกล้มได้อย่างมีประสิทธิภาพ และถึงแม้ว่าวิธีการของโครงข่ายประสาทเทียมมีการคำนวณที่ช้ากว่าวิธีของงานวิจัยในอดีต แต่เนื่องจากมีกระบวนการตรวจจับสัญญาณการหกล้มและการเคลื่อนไหวแบบฉับพลัน จึงไม่จำเป็นต้องคำนวณด้วยโครงข่ายประสาทเทียมตลอดเวลาจึงเป็นการลดเวลาในการคำนวณ อีกทั้งยังใช้สัญญาณการเคลื่อนไหวจากตัวตรวจจับความเร่งเพียงแกนเดียวเท่านั้น

สำหรับการศึกษาวิจัยในอนาคต อาจจะต้องเพิ่มชนิดของกิจกรรมการเคลื่อนไหวประเภทต่างให้มากขึ้นเช่น การวิ่ง การหกล้มในแบบต่าง ๆ เป็นต้น หรืออาจจะไปพัฒนาการคัดคุณลักษณะของสัญญาณสัญญาณขาเข้าให้มีขนาดที่เล็กลงเพื่อให้ลดเวลาการประมวลผล และนำระบบตรวจวัดสัญญาณการเคลื่อนไหวและอัลกอริทึมทดสอบกับผู้สูงอายุ

บทที่ 7

Web Application แจ้งเตือนการล้ม

Web Application แจ้งเตือนการล้ม เป็นโปรแกรมที่ถูกติดตั้งใน Server ของโรงพยาบาล ซึ่งติดตั้งโปรแกรม Apache Web Server และ MySQL และรับสัญญาณ SMS โดยใช้โมดูล SIM300CZ ดังแสดงในภาพที่ 7.1 ตัวโปรแกรมถูกพัฒนาโดยภาษา PHP, SQL Javascript Visual Basic AT Command และ JGraph



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

7.1 ฐานข้อมูลสำหรับการแจ้งเตือนการล้มของผู้สูงอายุ

ตารางที่ 7.1 ฐานข้อมูลของแพทย์ผู้ดูแลผู้สูงอายุ

docname	
PK	d_id
	d_name
	d_surname
	d_depart
	d_address
	d_username
	d_password
	d_tel
	d_date
	d_time
	d_pic
	lat
	lon

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


ตารางที่ 7.2 ฐานข้อมูลของผู้สูงอายุ

patients	
PK	p_id
	d_id
	p_name
	p_surname
	p_tel
	p_address
	p_pic
	p_date
	p_time
	p_pic
	Lat
	lon

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Home LOGIN

--!!! EMERGENCY !!!--
Edit Profile & Add Patients



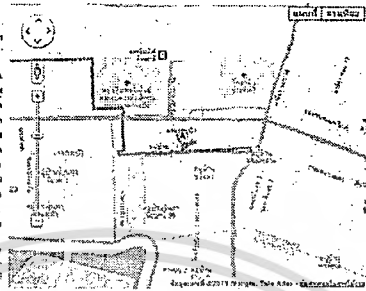
Name : Suravich
Address : 4641 ถนนวิภาวดีรังสิต แขวงสามเสนนอก เขตห้วยขวาง 10499
Reference : 1

Surname : Sem-aree
Telephone : 0877777777
Medical History

LOCATION PATIENTS

1. สถานีตำรวจนครบาล 10 เขต

1. สถานีตำรวจนครบาล 10 เขต
2. สถานีตำรวจนครบาล 10 เขต
3. สถานีตำรวจนครบาล 10 เขต
4. สถานีตำรวจนครบาล 10 เขต
5. สถานีตำรวจนครบาล 10 เขต
6. สถานีตำรวจนครบาล 10 เขต
7. สถานีตำรวจนครบาล 10 เขต
8. สถานีตำรวจนครบาล 10 เขต
9. สถานีตำรวจนครบาล 10 เขต
10. สถานีตำรวจนครบาล 10 เขต
11. สถานีตำรวจนครบาล 10 เขต



ภาพที่ 7.2 โปรแกรมแจ้งเตือนการล้มของผู้สูงอายุ

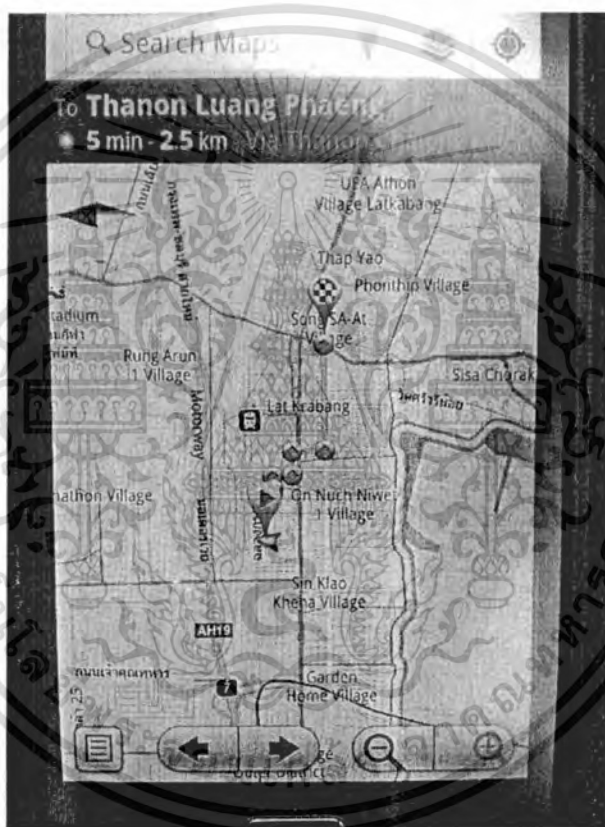


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 8

โปรแกรมนำทางรถพยาบาล

โปรแกรมนำทางรถพยาบาลเป็นโปรแกรมที่ใช้แสดงแผนที่บ้านของผู้สูงอายุ และเส้นทางจากโรงพยาบาลไปยังบ้านของผู้สูงอายุ และข้อมูลอื่นๆของผู้สูงอายุเช่น เบอร์โทรศัพท์ของผู้สูงอายุ และญาติที่ใกล้ชิด โรคประจำตัว แพทย์ผู้ดูแล เป็นต้น โปรแกรมที่ถูกพัฒนาบนโทรศัพท์ระบบ Android โดยใช้ภาษา Java



ภาพที่ 8.1 โปรแกรมนำทางรถพยาบาล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เอกสารอ้างอิง

- [1] United Nations, Department of Economic and Social Affairs, Population Division (2011). World Population Prospects: The 2010 Revision, Volume I: Comprehensive Tables ST/ESA/SER.A/313 S. R. Lord, C. Sherrington, and H. B. Menz, Falls in older people: Risk factors and strategies for prevention. Cambridge: Cambridge University Press, 2001
- [2] Perry, J.T.; Kellog, S.; Vaidya, S.M.; Jong-Hoon Youn; Hesham Ali; Sharif, H.; , "Survey and evaluation of real-time fall detection approaches," High-Capacity Optical Networks and Enabling Technologies (HONET), 2009 6th International Symposium on , vol., no., pp.158-164, 28-30 Dec. 2009
- [3] Narayanan, Michael R., et all. "Falls Management: Detection and Prevention, using a Waist-mounted Triaxial Accelerometer," Int. Conf. of the IEEE-EMBS Cité International, Lyon, France, August 23-26, 2007.
- [4] Chia-Chi Wang, C.-Y. C.-Y.-C.-T.-N.-T. (2008). "Development of a Fall Detecting System for the Elderly Residents." ICBBE 2008. The 2nd International Conference on Bioinformatics and Biomedical Engineering.
- [5] 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
- [6] Sim, S.Y.; Jeon, H.S.; Chung, G.S.; Kim, S.K.; Kwon, S.J.; Lee, W.K.; Park, K.S.; , "Fall detection algorithm for the elderly using acceleration sensors on the shoes," Engineering in Medicine and Biology Society, EMBC, 2011 Annual International Conference of the IEEE , vol., no., pp.4935-4938, Aug. 30 2011-Sept. 3 2011
- [7] Yan Yang; Xingqun Zhao; "Development of a fall detection algorithm based on a tri-axial accelerometer," Biomedical Engineering and Informatics (BMEI), 2011 4th International Conference on , vol.3, no., pp.1371-1374, 15-17 Oct. 2011

- [8] Bourke, Alan K.; O'Donovan, Karol J.; Nelson, John; O'Laughlin, Gearoid M.; , "Fall-detection through vertical velocity thresholding using a tri-axial accelerometer characterized using an optical motion-capture system," Engineering in Medicine and Biology Society, 2008. EMBS 2008 30th Annual International Conference of the IEEE, vol., no., pp.2832-2835, 20-25 Aug. 2008
- [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] Samantha Ng, Adel Fakhri, Adam Fournier, 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.
- [11] J. Boyle, M. Karunanithi, "Simulated Fall Detection via Accelerometers", Int. IEEE-EMBS, Vancouver, August 20-24, 2008
- [12] Qiang Li; Stankovic, J.A.; Hanson, M.A.; Barth, A.T.; Lach, J.; Gang Zhou; , "Accurate, Fast Fall Detection Using Gyroscopes and Accelerometer-Derived Posture Information," Wearable and Implantable Body Sensor Networks, 2009. BSN 2009. Sixth International Workshop on, vol., no., pp.138-143, 3-5 June 2009
- [13] Howard Demuth Mark Beale. Neural Network Toolbox User's Guide. 3 Apple Hill Drive Natick, MA 01760-2098. , 2010
- [14] Bio-Inspired Artificial Intelligence Theories, Methods, and Technologies, Dario Floreano Claudio Mattiussi The MIT Press Cambridge, Massachusetts London, England, 2008

ข้อมูลประวัติคณะผู้วิจัย

ประวัติส่วนตัว

ชื่อ-สกุล นาย.เทอดศักดิ์ ลีวหาทอง.....

ตำแหน่งปัจจุบัน อาจารย์ระดับ 7

ประวัติการศึกษา

ชื่อย่อปริญญา	สาขา	สถาบันที่จบ	ปีที่จบ
Doctor of Engineering	Science and Technology	มหาวิทยาลัยโตเกียว	2552
วิศวกรรมศาสตร มหาบัณฑิต วศ.ม.	วิศวกรรมไฟฟ้า	สถาบันเทคโนโลยีพระจอมเกล้า เจ้าคุณทหารลาดกระบัง	2540
วิศวกรรมศาสตรบัณฑิต วศ.บ.	อิเล็กทรอนิกส์	สถาบันเทคโนโลยีพระจอมเกล้า เจ้าคุณทหารลาดกระบัง	2535

สาขาวิจัยที่มีความชำนาญพิเศษ (แตกต่างจากวุฒิการศึกษา).....

- ระบบไมโครคอนโทรลเลอร์ และระบบสมองกลฝังตัว.....

- การออกแบบวงจรอิเล็กทรอนิกส์.....

- การประมวลผลภาพ (Image Processing) และการประมวลผลสัญญาณดิจิทัล (Digital Signal Processing).....

- โปรแกรมจัดเก็บและบริหารภาพทางการแพทย์ (Picture Archives and Communication System : PACS).....

ทุนการศึกษาและทุนวิจัยที่เคยได้รับ

ปี พ.ศ.	ทุนการศึกษาและทุนวิจัย	สถาบันที่ให้
2552	โครงการประยุกต์ข้อมูลทางการแพทย์ (Medical Information Application)	ศูนย์การแพทย์สมเด็จพระเทพ รัตนราชสุดาฯ สยามบรมราชกุมารี
2552	โครงการวิจัยเรื่องระบบการแยกส่วนภาพ เซลล์เม็ดเลือดขาว	งบประมาณเงินรายได้ของคณะ วิศวกรรมศาสตร์ สถาบันเทคโนโลยี พระจอมเกล้าเจ้าคุณทหารลาดกระบัง
2553	โครงการวิจัยเรื่องระบบดูแลผู้สูงอายุ ทางไกลผ่านโทรศัพท์เคลื่อนที่	งบประมาณเงินรายได้ของคณะ วิศวกรรมศาสตร์ สถาบันเทคโนโลยี พระจอมเกล้าเจ้าคุณทหารลาดกระบัง
2554	ระบบการค้นหารูปภาพด้วยรายละเอียดของ ภาพ	สำนักงานคณะกรรมการวิจัยแห่งชาติ
2555	ระบบแจ้งเตือนการล้มของผู้สูงอายุผ่าน โทรศัพท์เคลื่อนที่	งบประมาณเงินรายได้ของคณะ วิศวกรรมศาสตร์ สถาบันเทคโนโลยี พระจอมเกล้าเจ้าคุณทหารลาดกระบัง

ผลงานวิจัย/งานสร้างสรรค์

ผลงานวิจัย/งานสร้างสรรค์ที่ตีพิมพ์เผยแพร่ (ระดับชาติและนานาชาติ)

การเสนอผลงานวิชาการ

1. Sengto, A.; Leauhatong, T., "Human falling detection algorithm using back propagation neural network," *Biomedical Engineering International Conference (BMEiCON), 2012* , vol., no., pp.1,5, 5-7 Dec. 2012



The 5th Biomedical Engineering International Conference

BMEiCON

2012

December 5 - 7, 2012
UbonRatchathani, Thailand
& Champasak, Laos

IEEE Catalog Number : CFP1258R-CDR
ISBN : 978-1-4673-4891-1

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Human Falling Detection Algorithm Using Back Propagation Neural Network

Mr. Adna Sengto

School of Electronics Engineering, Faculty of Engineering
King Mongkut's Institute of Technology Ladkrabang
Ladkrabang, Bangkok, Thailand 10520
adna@tmi.ac.th

Dr. Thurdsak Leauhatong

School of Electronics Engineering, Faculty of Engineering
King Mongkut's Institute of Technology Ladkrabang
Ladkrabang, Bangkok, Thailand 10520
thurdsak@hotmail.com

Abstract—A fall monitor system is necessary to reduce the rate of fall fatalities in elderly people. As an accelerometer has been smaller and inexpensive, it has been becoming widely used in motion detection fields. This paper proposes the falling detection algorithm based on back propagation neural network to detect the fall of elderly people. In the experiment, a tri-axial accelerometer was attached to waists of five healthy and young people. In order to evaluate the performance of the fall detection, five young people were asked to simulate four daily-life activities and four falls; walking, jumping, flopping on bed, rising from bed, front fall, back fall, left fall and right fall. The experimental results show that the proposed algorithm can potentially distinguish the falling activities from the other daily-life activities.

Index Terms—Fall, fall detection, neural network.

I. INTRODUCTION

Recently, United Nations [1] has reported that the population over the age of 60 years constituted 11.7 percent of the population in 2011, and it will be increased to 20.2 percent in 2050. As the proportion of the elderly people has been increasing rapidly, the health problems of the elderly people become more serious. Obviously, fall is one of the most dangerous problems, since it causes serious injury or accidental deaths. Furthermore, the elderly people who have fallen would scare about fall, and cannot do any activity or cannot be alone. Hence, a fall monitoring system which can detect and immediately alert the fall of the elderly people is necessary to reduce the fall fatalities.

In literatures, the fall monitoring systems can be categorized into three groups. First, 3D accelerometer-only was utilized to detect the fall [3], [4], [6], [7], [11] and [12]. Second, in order to increase the performance of falling detection, the other sensor such as gyroscope [2, 5], or optical motion-capture [8] were combined to the 3D accelerometer. Last, without accelerometer, sensors such as acoustic sensor [9], or visual sensors [10] were used.

The systems which used acoustic or visual sensor (with or without accelerometer) were unpractical and may lead to some problems. For example, visual sensors must be installed in a fixed area then it was inconvenient to elderly people. In addition, in order to capture the falling image, high power computers were inevitably needed, and the visual systems were

privacy violation to the elderly people. Next, the acoustic systems were easily contaminated by many acoustic noises in their environment such as door slamming, human voices and etc. These noises would disturb the acoustic processing so that the falling detection performance decreases.

As the advances of the recent miniature accelerometer and gyroscope technology, a very small and lightweight motion capture system can be realized. The system can be attached to body of the elderly person to capture his/her motion. The advantages of the system were that the captured motion could not be easily contaminated by environmental noise then it was more reliable than acoustic systems. Since the elderly people can use the system by themselves in all places, then it is very convenient.

For the only acceleration signal, a number of literatures proposed the detection algorithms based on thresholding the magnitude of acceleration or velocity. For example, J. T. Perry and et. [2] developed a falling detection algorithm based on the vectors sum of the 3D accelerometer and 2D gyroscope which were calculated as follows:

$$A = \sqrt{a_x^2 + a_y^2 + a_z^2} \quad (1)$$

$$G = \sqrt{g_x^2 + g_z^2} \quad (2)$$

where a_x , a_y , and a_z were the data from x, y, and z axis of the accelerometer, respectively, and g_x and g_z were the data from x, and z axis of the gyroscope, respectively. The selected thresholding values for A and G were 3g and 1g, respectively.

In order to increase the performance of the falling detection, C-C. Wang [4] proposed three more criteria. First, in order to distinguish the fall from the other daily-life activities, the sum vector of horizontal plane (S_h) was calculated as follows:

$$S_h = \sqrt{a_x^2 + a_y^2} \quad (3)$$

Second, in order to detect more types of the fall, the Timestamp of falling body to be at rest (T_n) and timestamp of

the body's initial contact to the ground (T_{ic}) were defined as follows:

```

int j = i, F = 1;
for(j ≤ i ≤ 400; i++) && (F = 1)
  while (0.5 < Ai < 1.5)
    for(int n = 1; n ≤ 60; n++)
      if(|Ai - Ai+n| ≥ 0.13)
        k = i + n;
        j = i + k;
        n = 1;
      else if (n = 60)
        Tn = i, Tn = j, F = 0;
        endif
      endif
    endif
  endif
endwhile
endfor

```

Last, in order to distinguish the fall from the sudden motion activities, backward integration of reference velocity (V_{max}) was calculated as follows:

$$V_{max} = \int_{T_{ic}}^{T_{ic}} [S_n(t) - 1] dt \Big|_{max} \quad (4)$$

In [8], the authors modified Eq. 1 to compute the moving velocity as follows:

$$v = \int \left(\sqrt{a_x^2 + a_y^2 + a_z^2} - 9.81 \text{ m/s}^2 \right) dt \quad (5)$$

The conventional falling detections are hard to seek the optimal thresholding values, if new types of the falls or daily-life activities are added to the algorithms. In this paper, we propose a new algorithm based on the back propagation neural network to recognize the patterns of the falls and the other activities. The advantages of the proposed algorithm is that the neural network can easily learn the patterns of the new falls or activities. The paper is organized as follows. In section 2, the basic theories of back propagation neural network are given. In section 3, the hardware architecture is implied. In section 4, the proposed algorithm is described. In section 5, the experiments are shown. Finally, the conclusion is discussed.

II. BACK PROPAGATION NEURAL NETWORK (BPNN)

BPNN is a mathematical system which models biological neural networks by interconnecting several neurons. The structure of the BPNN used in this paper comprises three layers, input, hidden, and output layers as shown in Fig. 1. Each layer consists of many neurons. Let n , p , and q be the number of the input, hidden, and output neurons. In general, n is the number of the input signals, and q is the number of recognition patterns. The performance of the overall BPNN depends strongly on the selection of p . If p is too small, it leads to something called under fitting problem. The under fitting problem occurs when there are too few neurons in the hidden layers to adequately detect the patterns in a complicated input

signals. On the other hand, if p is too large, it leads to two main problems, very long time to train the BPNN and over fitting problem. The over fitting problem occurs when the BPNN has so much capacity to process information, but there are not enough training signal to train all of the neurons in the hidden layers.




Fig. 1. Back Propagation Neural Network

Each neuron has links from a single or multiple neurons, and each link has a numerical weight associated with it. The weights are the basic means of long-term memory in the BPNN, and express the strength of each neuron input. The process of the BPNN can be divided into two operations, feed forward and back propagation operations.

In the feed forward operation, n input features are fed to the input neurons. Then the outputs of the hidden and output neurons can be computed as follows:

$$y_h = f_{sig} \left(\sum_{i=1}^n x_i v_{ih} \right), \quad (6)$$

$$z_o = f_{sig} \left(\sum_{h=1}^p y_h w_{ho} \right), \quad (7)$$

respectively, where $f_{sig}(x) = (1 + e^{-x})^{-1}$, x_i is the value of the i^{th} input neuron, v_{ih} is the weight of the link between i^{th} input neuron and h^{th} hidden neuron, y_h is the value of the h^{th} hidden neuron, w_{ho} is the weight of the link between h^{th} hidden neuron and o^{th} output neuron, z_o is the value of the output layer.

Let b_{io} and z_{io} be the desired and actual value of f_{sig} of the o^{th} output neuron, respectively. The weights of all links can be adjusted by back propagating the output neurons to the input neurons as follows:

$$w_{ho}^{new} = w_{ho}^{old} + \eta \sum \delta_o y_h + \alpha \Delta w_{ho}^{old}, \quad (8)$$

$$\delta_o = z_o (1 - z_o) (b_o - z_o), \quad (9)$$

$$v_{ih}^{new} = v_{ih}^{old} + \eta \sum \delta_h x_i + \alpha \Delta v_{ih}^{old}, \quad (10)$$

$$\delta_h = y_h (1 - y_h) \sum_{h=1}^q w_{ho}^{old} \delta_o, \quad (11)$$

where w_{ho}^{new} and v_{ho}^{new} are the update weight in output layer and hidden layer respectively. w_{ho}^{old} and v_{ho}^{old} are update weight each prior iteration in output layer and hidden layer respectively. δ_o and δ_h are the error gradients in output layer and hidden layer respectively. η is the learning rate that has value between 0 and 1. α is momentum factor usually set 0.95.

For the k^{th} pattern, $b_{ko} = 1$, if $k = o$, and $b_{ko} = 0$, if otherwise. The error of the feed forward operation of the k^{th} pattern, E_k , can be expressed as follows:

$$E_k = 0.5 \sum_{n=1}^q (b_{ko} - z_{ko})^2, \quad (12)$$

where $k \in \{1, 2, \dots, q\}$.

In the learning process firstly, all of the weights are initialized to some values, z_{ko} of the initial weights are computed by using the feed forward operation, and the errors of all patterns are computed by using Eq. 7. Next, all of the weights are adjusted until all of the errors are converged to zeros using alternative sequences of the back propagation and feed forward operations.

III. THE PROPOSED HUMAN FALLING DETECTION SYSTEM

In this section, both of the motion capture system and algorithm to detect the fall of elderly people are described.

A. Motion Capture System

The motion capture consists of three parts as shown in Fig. 2. First, a 3D accelerometer, MMA7631 model, is used to measure the acceleration of the elderly people. The selected accelerometer is small and light weight, consumes low power, and can be configured to measure the acceleration with two sensitivity scales, $\pm 4g$ and $\pm 12g$. Second, a versatile microcontroller from Microchip Inc., PIC24FJ128GB110, is used to manipulate the motion capture and read the data from the accelerometer. The microcontroller has some useful features. For example, it consumes low power, can operate 16-bit data, and can convert analog signal to 10-bit digital data. Then it can accurately and efficient process the acceleration data.




Fig. 2. The Block Diagram of Motion Capture System.

From our experiments, the falling signals are significantly shown in the vertical accelerometer. In our motion capture system, the sampling rate of the vertical signal is 60 Hz. The recorded signals from ADC circuit are converted to the gravity value as follows:

$$g = \frac{(V_{ADC} \times R_{ADC}) - V_{DD} / 2}{SEN}, \quad (13)$$

$$R_{ADC} = \frac{V_{DD}}{2^n - 1}, \quad (14)$$

where g is the calculated acceleration in m/s^2 , V_{ADC} is the recorded value, V_{DD} is the supply voltage of the accelerometer sensor, n is the number of bits of the ADC circuit ($n = 10$), and SEN is sensitivity of the accelerometer ($SEN = 308 \text{ mV/g}$ for MMA7631). Last, a 32 GB SD card is used to record the acceleration data. The advantages of the SD card are that it is cheap, robust to the falling impact, consumes low power, and can record the acceleration data for whole day.

B. The Human Falling Detection Algorithm

In this study, we categorize the human activities into three groups; 1) the falling activities such as back, forward, left, and right fall, 2) the slow motion activities such as walking, flopping and rising from bed, and 3) the sudden motion activities such as jumping, and running. Three example signals of vertical accelerometer from three groups, back fall, rising from bed, and jumping, are shown in Fig. 3. From our comprehensive observations, the vertical accelerometer signals of the falls have two characteristics which can be used to distinguish them from other activity signals.

- The absolute signal values of the slow motion activities are always lower than the signal value of the sudden motion activities and the falling activities with some threshold value.
- The patterns of the falling signals are a little bit different from the signals of the sudden motion. All of the falling signals have single sharp peaks, positive or negative peak. On the other hand, the sudden motion activities have diverse and complicated patterns. For example, the jumping signals have two or three consecutive sharp peaks. The running signals are periodic patterns.

According to two characteristics, the proposed algorithm consists of two processes. Firstly, a simple threshold process is used to distinguish the slow motion activities from the falls and the other sudden motion activities. Next, if the absolute value of the signals is higher than the threshold value, the back propagation neural network is used to detect the falling signals. The detail of the proposed algorithm can be described as follows.




Fig. 3. Examples of the falling signal (blue line), the slow motion activity signals (green line), and sudden motion activity signal (red line).

1) *The Threshold Process:* In this paper, we use two threshold values, TH_{MIN} and TH_{MAX} , to separate the slow motion activities from the other activities. If the signal values are greater than TH_{MIN} and smaller than TH_{MAX} , the signals are considered the signals of the slow motion activities. From our experiments, the signal value of the slow motion activities are always greater than $-2.5g$ and smaller than $1.5g$ then TH_{MIN} and TH_{MAX} are $-2.5g$ and $1.5g$, respectively. An example of the threshold process is shown in Fig. 4. The walking and falling signals are shown in the left and right side of the green line, respectively. Obviously, the amplitude of the walking signal is in the range of the threshold, and the peak of the falling signal is outside the threshold.




Fig. 4. Threshold algorithm.

2) *The Falling Pattern Recognition Process:* In practical, there are many human sudden motions. Most of their patterns are complex, and some sudden patterns such as jump are similar to the falling patterns. As a result, it is very difficult to design mathematical equation(s) or programming algorithm to separate the falling patterns from the other sudden patterns. However according to the advance of the pattern recognition technologies, it is possible to design the falling recognition process. In this paper, the back propagation neural network is proposed to recognize the falling patterns. The detail of recognition process can be described as follows.





Fig. 5. The Falling Pattern Recognition Process

a) *The Falling and Sudden Motion Signals Extraction:* From our observations, all of the falling signals appear before the falling peak around 2.5 seconds and the end of the signal is after the peak around 2.5 seconds. Then in order to extract the falling signal, we have to detect the time of the falling peak, t_{peak} . We assume that the interval time that the falling peaks should be appear is $[t_{start}, t_{start}+5 \text{ second}]$, where t_{start} is the time that the captured signal is out of range of the slow motion signal, greater than TH_{MAX} or lower than TH_{MIN} . According to our sampling rate, the interval time of the falling peaks is $[t_{start}, t_{start}+299 \text{ samples}]$, and the interval time of the falling signal is $[t_{peak}-150 \text{ samples}, t_{peak}+149 \text{ samples}]$. The pseudo codes of extracting the falling signal are shown as follows:


```

for (i = 0; i < CaptureLength - 1; i++)
    if (x[i] > TH_MAX || x[i] < TH_MIN)
        for (j = i + 1; j < i + 300; j++)
            if (abs(x[j]) > abs(x[j-1]))
                t_peak = j;
}
X = [x[t_peak-150], ..., x[t_peak], ..., x[t_peak+149]];
    
```

where CaptureLength is the length of the captured signal, x is the captured signal, and X is the data set of the extracted signal. Two examples of the falling and jumping signal extraction are shown in Fig. 6.



(a) The falling signal extraction.



(b) The jumping signal extraction.

Fig. 6. Two examples of the signal extractions.

b) *The Pattern Recognition Process:* The number of extracted input signals is 300. In this study, the number of patterns recognized by the BPNN is 8. Hence according to Fig. 1, we used the BPNN structure with one hidden layer that is configured as follows. $n = 300$, $p = 90$ and $q = 8$.

IV. THE EXPERIMENTS

In the experiments, 5 young and healthy subjects, 4 men and 1 woman, were asked to wear the motion capture system on their waists and to perform 8 activities; walking, jumping, flopping on bed, rising from bed, front fall, back fall, left fall and right fall. Positive x axis of the motion capture system is directed towards the bottom along the vertical axis. The quantities and the interval times for each activity are shown in Table 1. All of the captured signals are separated into 2 groups; training captured signals and testing captured signals. The training captured signals were set to input prototype of the BPNN and then, the testing captured signals were tested by the human falling detection algorithm, BPNN, to classify the falls from other activities. The experimental results were shown in Fig. 7. Detection performance for each fall type was represented in sensitivity and specificity.

TABLE I
SIMULATED ACTIVITIES DATASET

Description of Simulated Activities	Quantity	Interval Time (Second)
Back fall	20	10
Front fall	20	10
Left fall	20	10
Right fall	20	10
Flopping on bed	100	10
Rising from bed	100	10
Jumping	100	10
Walking	100	10

The sensitivity and specificity were calculated as follows:

$$\text{Sensitivity} = \frac{\text{TruePositives}}{\text{TruePositives} + \text{FalseNegatives}}, \quad (15)$$

$$\text{Specificity} = \frac{\text{TrueNegatives}}{\text{TrueNegatives} + \text{FalsePositives}}, \quad (16)$$

where TruePositives is the falling signal was detected as a fall, FalseNegatives is the falling signal was detected as a normal activity, TrueNegatives is the normal activity signal was detected as a normal activity, and FalsePositives is the normal activity signal was detected as a fall. Overall sensitivity was measured to be 96.25 percent and specificity was measured to be 99.50 percent.




Fig. 7. The experimental result

V. CONCLUSION AND FUTURE WORK

As the experimental result, the proposed a human falling detection algorithm can be distinguish between the falling signals from other activity signals with high sensitivity and high specificity by using back propagation neural network.

In the future work, we will add more the simulated activities that will recognized by BPNN such as running, fast flopping on bed, slide fall etc. In addition, we will improve the performance by extracting the suitable feature and reducing feature dimension. Finally, we will test our algorithm with elderly people

REFERENCES

- [1] United Nations, Department of Economic and Social Affairs, Population Division (2011). World Population Prospects: The 2010 Revision, Volume I: Comprehensive Tables.

- [2] ST/ESA/SER.A/313 S. R. Lord, C. Sherrington, and H. B. Menz, Falls in older people: Risk factors and strategies for prevention, Cambridge: Cambridge University Press, 2001
- [2] Perry, J.T.; Kellog, S.; Vaidya, S.M.; Jong-Hoon Youn; Hesham Ali; Sharif, H.; , "Survey and evaluation of real-time fall detection approaches," High-Capacity Optical Networks and Enabling Technologies (HONET), 2009 6th International Symposium on , vol., no., pp.158-164, 28-30 Dec. 2009
- [3] Narayanan, Michael R., et all. "Falls Management: Detection and Prevention, using a Waist-mounted Triaxial Accelerometer." Int. Conf. of the IEEE-EMBS Cité International, Lyon, France, August 23-26, 2007.
- [4] Chia-Chi Wang, C.-Y. C.-Y.-C.-T.-N.-T. (2008). "Development of a Fall Detecting System for the Elderly Residents." ICBBE 2008. The 2nd International Conference on Bioinformatics and Biomedical Engineering.
- [5] 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
- [6] Sim, S.Y.; Jeon, H.S.; Chung, G.S.; Kim, S.K.; Kwon, S.I.; Lee, W.K.; Park, K.S.; , "Fall detection algorithm for the elderly using acceleration sensors on the shoes," Engineering in Medicine and Biology Society, EMBC, 2011 Annual International Conference of the IEEE , vol., no., pp.4935-4938, Aug. 30 2011-Sept. 3 2011
- [7] Yan Yang; Xingqun Zhao; "Development of a fall detection algorithm based on a tri-axial accelerometer," Biomedical Engineering and Informatics (BMEI), 2011 4th International Conference on , vol.3, no., pp.1371-1374, 15-17 Oct. 2011
- [8] Bourke, Alan K.; O'Donovan, Karol J.; Nelson, John; O'Laighin, Genevieve M.; , "Fall-detection through vertical velocity thresholding using a tri-axial accelerometer characterized using an optical motion-capture system," Engineering in Medicine and Biology Society, 2008. EMBS 2008 30th Annual International Conference of the IEEE, vol., no., pp.2832-2835, 20-25 Aug. 2008
- [9] Mihail Popescu, Yan 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] Samantha Ng, Adel Fakh, Adam Fournay, Pascal Poupard, John Zelck, "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.
- [11] J. Doyle, M. Karunanithi, "Simulated Fall Detection via Accelerometers", Int. IEEE-EMBS, Vancouver, August 20-24, 2008
- [12] Qiang Li; Stankovic, J.A.; Hanson, M.A.; Barth, A.T.; Lach, J.; Gang Zhou; , "Accurate, Fast Fall Detection Using Gyroscopes and Accelerometer-Derived Posture Information," Wearable and Implantable Body Sensor Networks, 2009. BSN 2009. Sixth International Workshop on, vol., no., pp.138-143, 3-5 June 2009

ผลงานสิทธิบัตร/สิ่งประดิษฐ์/งานสร้างสรรค์ (ศิลปะ หรือ อื่นๆ)

อื่นๆ



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้