

การตรวจจับการล้มด้วย Kinect โดยการวิเคราะห์แบบต้นไม้ตัดสินใจ Fall Detection by Kinect with Decision Tree Algorithm

นาย ปรัชญา อนันตเมฆ^{1,2}, นาย พงศ์ธร พงษ์กันทรารกร², นายพีรนิษฐ์ พุ่มชุมพล²,
นาย อนุชา ปราบพรหม², ดร.รุจ เอกะวิภาต^{1,3}, ดร.ลลิตา นฤปิยะกุล^{1,2*}

¹ศูนย์ปฏิบัติการด้านชีววิทยาศาสตร์คอมพิวเตอร์ มหาวิทยาลัยมหิดล จังหวัดนครปฐม

²ภาควิชาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยมหิดล จังหวัดนครปฐม

³ภาควิชาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์ มหาวิทยาลัยเกษตรศาสตร์ จังหวัดกรุงเทพฯ

E-mail: lalita.nar@mahidol.edu*

บทคัดย่อ

โครงการนี้พัฒนาขึ้นเพื่อเป็นระบบต้นแบบสำหรับตรวจจับการล้มของผู้สูงอายุที่พ้ออาศัยเพียงลำพัง ซึ่งผู้สูงอายุเหล่านี้มีโอกาสที่จะประสบอุบัติเหตุจากการล้มโดยไม่มีผู้ช่วยเหลือและปฐมพยาบาลได้ทันเวลา การล้มเป็นหนึ่งในอาการบาดเจ็บที่พบเจอบ่อยที่สุดในผู้สูงอายุ ในโครงการนี้ผู้วิจัยได้พัฒนาการรู้จำท่าทางการล้มโดยใช้ข้อมูลจากเซ็นเซอร์ Kinect ระบบจะสามารถตรวจจับการล้มได้ถ้าหากผู้สูงอายุเกิดอุบัติเหตุล้มลงกะทันหัน โครงการนี้จะใช้เซ็นเซอร์รับสัญญาณ Kinect ทำการตรวจจับโครงสร้างของร่างกาย ทั้งหมด 20 จุด และนำข้อมูลของพิกัดจุดทั้งแนวแกน X, Y และ Z มาทำการหาค่าความต่างเฉลี่ยของแต่ละจุด โดยแยกแกน X, Y และ Z ตามระยะทางการเคลื่อนที่ในหนึ่งหน่วยเวลา โดยจะเปรียบเทียบกับกลุ่มข้อมูล 3 กลุ่มข้อมูลดังนี้คือ (1) กลุ่มชุดข้อมูลก่อนเกิดการล้ม (2) กลุ่มชุดข้อมูลระหว่างล้ม (3) กลุ่มชุดข้อมูลหลังจากการล้มเกิดขึ้นแล้ว โดยระบบจะทำการเปรียบเทียบหารูปแบบการล้ม ข้อมูลทั้ง 3 กลุ่มตามแกน X, Y, Z ว่าผู้ทดลองหรือไม่และล้มทิศทางใด จากนั้นจะนำข้อมูลที่ได้ออกวิเคราะห์ด้วยวิธี C4.5 เพื่อตรวจสอบและยืนยันผลลัพธ์ตรงกับเงื่อนไขและทิศทางการล้มหรือไม่ จากผลการทดลองผลลัพธ์ที่ได้มีความถูกต้อง 91.43% จากชุดข้อมูลทั้งหมด 103 ชุด ข้อมูล จากผลการทดลองที่ได้สามารถบอกได้ว่าผู้สูงอายุล้มหรือไม่ และล้มไปในทิศทางใด

คำสำคัญ: ตรวจสอบการล้ม, อุปกรณ์ตรวจจับความลึก, การรู้จำการล้ม

Abstract

Falling is one of major accidents among seniors. The injuries from falling can become serious if assistance is not provided at the early stage. To detect a fall, we designed a system based on a Kinect 3D sensor. This system analyzes 20 joints 3D positions derived from the 3D sensor data to track a human body. A decision model for detecting a fall is a decision tree generated from running the C4.5 algorithm on the set of videos containing 103 postures mixing between

falling and non-falling. Our experimental results show that the system can detect a fall with 91.43 percent of accuracy

Keywords: Fall detection, Depth sensor, Fall recognition

1. บทนำ

ปัจจุบันผู้สูงอายุในประเทศไทยมีจำนวนเพิ่มมากขึ้นทุกปี สำนักงานสถิติแห่งชาติ [1] ได้จัดทำการศึกษาประชากรสูงอายุในประเทศไทย พ.ศ. 2557 พบว่า มีจำนวนผู้สูงอายุคิดเป็นร้อยละ 14.9 ของประชากรทั้งหมด จากจำนวนผู้สูงอายุทั้งสิ้น 10,014,699 คน เป็นชาย 4,514,812 และ หญิง 5,499,887 คน หรือคิดเป็นชายร้อยละ 45.1 และหญิงร้อยละ 54.9 ของ ผู้สูงอายุทั้งหมด ในสหรัฐอเมริกา[2] พบว่า ผู้สูงอายุจะได้รับบาดเจ็บจนถึงเสียชีวิตได้ 3 ทางคือ ลื่นหกล้ม (พบมากที่สุด) อุบัติเหตุรถยนต์ และแผลไฟไหม้ เรียงตามลำดับของอุบัติการณ์ที่พบมากที่สุดไปสู่น้อย สาเหตุที่ผู้สูงอายุมักหกล้มง่ายเนื่องจาก ความเสื่อมของร่างกายตามวัย มีระบบประสาทและกล้ามเนื้อทำงานประสานกันไม่ดี ผู้สูงอายุมักเดินช้า ตามองไม่ชัด การได้ยินเสียงและความจำไม่ดี รวมทั้งมักมีอาการเวียนศีรษะจึงพลัดตกหกล้มได้ง่าย เนื่องจากการบาดเจ็บส่วนใหญ่ที่เกิดขึ้นกับผู้สูงอายุในชีวิตประจำวันเกิดจากการล้ม และจากการที่ผู้สูงอายุต้องอยู่ที่พ้ออาศัยโดยลำพัง หากเกิดอุบัติเหตุจากการล้ม และไม่ได้รับการปฐมพยาบาลอย่างทันท่วงที ผู้สูงอายุอาจได้รับอันตรายถึงชีวิตได้ ซึ่งประโยชน์จากการตรวจจับการล้ม คือ เมื่อระบบสามารถตรวจจับการล้มได้ ระบบสามารถแจ้งเตือนผู้ดูแลหรือผู้ใกล้ชิดและผู้สูงอายุมีโอกาสที่จะได้รับการปฐมพยาบาลเบื้องต้นอย่างถูกต้องและรวดเร็ว ช่วยให้บรรเทาอาการบาดเจ็บที่เกิดขึ้นหรือก่อให้เกิดอันตรายต่อการเสียชีวิตน้อยลง

จากการค้นคว้าพบว่ามีงานวิจัยที่เกี่ยวข้องกับการวิเคราะห์การล้มหลากหลายวิธี [3] และในปัจจุบันมีอุปกรณ์ตรวจจับการล้มอยู่หลายประเภท เช่น Myo เป็นอุปกรณ์ตรวจจับการทำงานของกล้ามเนื้อ แขน โทรศัพท์มือถือและอุปกรณ์อื่น ๆ ที่มี Accelerometer โดยในโครงการนี้เลือกใช้เซ็นเซอร์รับสัญญาณ Kinect เป็นตัวรับสัญญาณเพื่อนำมาใช้ในการตรวจจับท่าทางและนำข้อมูลที่ได้ออกวิเคราะห์รูปแบบการล้มในแบบต่างๆ เนื่องจาก Kinect เป็นอุปกรณ์ภายนอกซึ่งไม่จำเป็นต้องยึด

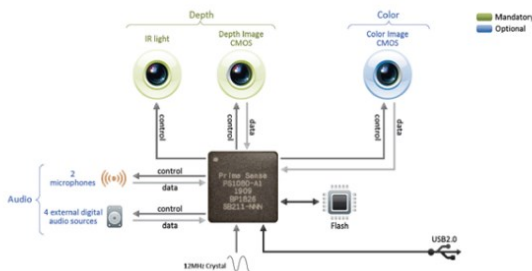
ติดกับร่างกาย ทำให้สะดวกต่อการใช้งาน มีความหลากหลายและยืดหยุ่นในการทำงานสูง เช่น สามารถเลือกการบันทึกภาพอินฟราเรดแทนภาพจริงได้ การวัดความลึกของภาพ และการบันทึกภาพในรูปแบบสตรีมของกระดูกของร่างกาย

สำหรับการวิเคราะห์การตรวจจับท่าทางการล้มในโครงการนี้ถูกแบ่งเป็นสองส่วนหลักๆ คือ (1) การตรวจจับตำแหน่งต่างๆบนร่างกาย เช่น แขน,ตัว,ศีรษะ และหัวไหล่ เป็นต้น จากอุปกรณ์รับสัญญาณ Kinect โดย Kinect จะแปลงค่าพิกัดแกน (X,Y,Z) จากอุปกรณ์รับสัญญาณ หลังจากนั้นจึงคำนวณหาค่าความต่างระหว่างพิกัดของจุดเดียวกัน ณ เวลาที่ต่างกันเพื่อใช้ในการแยกแยะกลุ่มข้อมูลในช่วงก่อนล้ม, หลังล้ม, และระหว่างล้ม เพื่อนำผลลัพธ์ที่ได้มาใช้วิเคราะห์ในขั้นตอนถัดไปเพื่อใช้ในการตัดสินใจว่าเป็นการล้มหรือไม่ และล้มไปในทิศทางใด จากนั้นจึงนำค่าความต่างที่ได้มาหาค่าเฉลี่ยตามพิกัด X,Y,Z ในแต่ละช่วงเวลา จากนั้นจะส่งค่าเหล่านี้ต่อไปยังส่วนต่อไป (2) การวิเคราะห์ข้อมูลโดยวิธี Decision Tree ได้รับข้อมูลจากส่วนแรกแล้วทำการนำข้อมูลมาวิเคราะห์และตรวจสอบการล้ม โดยใช้อัลกอริทึม C4.5 ซึ่งถูกเลือกมาใช้เพื่อใช้ในการวิเคราะห์หาเงื่อนไขการตัดสินใจการล้มจากค่าความต่างของความเร็วในการเคลื่อนที่ของผู้ล้มจากการจับตำแหน่งของร่างกายโดยแบ่งข้อมูลออกเป็นสามกลุ่ม ซึ่งได้ผลเป็นพิกัด X,Y,Z ของตำแหน่งร่างกายนั้นๆ โดยในการวิเคราะห์การความเร็วในการล้มนั้น จะใช้ค่าพิกัดแกน Y ในการวิเคราะห์ และในส่วนของทิศทางในการล้มจะวิเคราะห์โดยใช้ค่าพิกัดแกน X และ Z ซึ่งผลลัพธ์ที่ได้จะสามารถประมวลผลว่าผู้สูงอายุล้มหรือไม่ และล้มในทิศทางใด

2. ความรู้พื้นฐานที่เกี่ยวข้อง

Kinect คือ อุปกรณ์รับสัญญาณเสริมของเครื่องเล่นเกมส์ Xbox360 จาก Microsoft ซึ่งคำว่า Kinect มาจากคำว่า ไคเนติก (Kinetic) รวมกับคำว่าคอนเนค (Connect) โดยเป็นเทคโนโลยีไมซ์น คอนโทลเลอร์ (Motion controller) สามารถจดจำผู้เล่น (Facial Recognition) และให้ผู้เล่นควบคุม เกมส์ผ่านทางเครื่องเคลื่อนไหวร่างกายของผู้เล่นโดยตรง (3D Motion Recognition) โดยไม่จำเป็นต้อง มีอุปกรณ์ควบคุม อีกต่อไปและสามารถจดจำเสียงของผู้เล่นได้ (Voice Recognition) [4]

ภายใน Kinect ประกอบด้วย อุปกรณ์ฉายแสงอินฟราเรด (Infrared) กล้องวัดความลึกของ ภาพ (Depth Camera) กล้องวิดีโอ (Video Camera) ไมโครโฟน และเซนเซอร์ (Sensor)



รูปที่ 1 แสดงไดอะแกรมของ Kinect

ตัวอย่างงานวิจัยที่เกี่ยวข้องกับ Kinect เช่น การใช้เทคโนโลยีของอุปกรณ์รับสัญญาณ Kinect เพื่อช่วยประเมินแนวโน้มออทิสติกในเด็ก นัก วิ จั ย ส อ ง ค น Guillermo Sapiro และ Nikolaos Papanikolopoulos เชื่อว่าสามารถนำเซนเซอร์ของ Kinect มาช่วยได้ โดยเป็นการทดลองของ Institute of Child Development แห่ง University of Minnesota ซึ่งได้ทดลองติดตั้งเซนเซอร์ Kinect 5 ตัวเอาไว้ในห้องที่เด็กๆ ใช้เป็นสถานที่เล่นในโรงเรียน อุปกรณ์จะคอยบันทึกการเคลื่อนไหวของเด็กๆที่มีอายุระหว่าง 3 - 5 ปี แล้วส่งข้อมูลที่ไปยังเครื่องพีซี หลังจากนั้นคอมพิวเตอร์ก็จะทำการคำนวณว่าเด็กคนไหนมีอัตราเสี่ยงต่อการเป็นออทิสติก ดังรูปที่ 2 โดยใช้ข้อมูลพื้นฐานการเคลื่อนไหวของมือและระดับการทำกิจกรรมต่างๆในห้อง เด็กที่มีการทำกิจกรรมต่างจากเพื่อนๆในห้องอย่างมากจะถูกจับตาเป็นพิเศษ และส่งให้แพทย์ผู้เชี่ยวชาญทำการวินิจฉัยต่อไป [5] นักวิจัยยอมรับว่า การใช้วิธีนี้ยังไม่สามารถเข้ามาแทนที่การวินิจฉัยด้วยแพทย์จริงๆ แต่ก็เป็นอีกวิธีที่ช่วยประเมินว่าเด็กคนไหนมีแนวโน้มที่จะเป็นออทิสติก และต้องได้รับการตรวจอาการอย่างใกล้ชิด และหวังว่าจะนำผลที่ได้ไปรวมกับผลของนักวิจัยคนอื่นๆที่ใช้คอมพิวเตอร์ในการช่วยระบุพฤติกรรมออทิสติกตั้งแต่ทารก

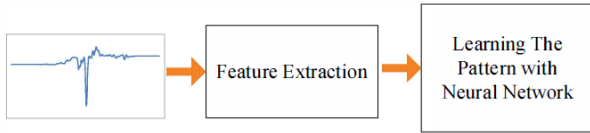


รูปที่ 2 ภาพจากอุปกรณ์รับสัญญาณ Kinect [5]

อีกหนึ่งงานวิจัยที่เกี่ยวข้อง นำเสนอโดย Kawatsu, Li และ Chung [3] ได้ทำการทดลองโดยใช้อัลกอริทึมสองแบบโดยแบบที่ 1 วิเคราะห์การล้มโดยอาศัยภาพเพียงภาพเดียวที่บันทึกได้จากอุปกรณ์รับสัญญาณ Kinect ในขณะที่อีกวิธีหนึ่งมีการเก็บภาพตามเวลาจากอุปกรณ์รับสัญญาณ Kinect เพื่อนำมาวิเคราะห์แยกแยะความแตกต่างระหว่างช่วงเวลาที่ยืน ช่วงเวลาที่ค่อยๆนอนลงกับพื้น และส่งรายงานการล้มไปในรูปแบบ MMS ออกไปผ่านโปรแกรมเข้าไปที่โทรศัพท์ของเครื่องที่ต้องการผลการทดลองในงานวิจัยนี้ได้กล่าวถึงความผิดพลาดในการวิเคราะห์การล้มเมื่อเกิดการล้มที่มีความเร็วสูงหรือต่ำกว่าความเร็วที่ตั้งค่าไว้กับระบบ

การตรวจจับการล้มโดยใช้ Neural Network โดย Adna Sengto และ Dr. Thursak Leauhatong [6] โดยใช้ Accelerometer ในการตรวจจับการล้ม และตรวจสอบการล้มโดย Neural Network โดยในการทดลองจะใช้ Accelerometer ผูกติดกับร่างกายของผู้ทดสอบ 5 คน เป็นเพศชาย 4 คน และ เพศหญิง 1 คน ที่มีช่วงอายุในวัยหนุ่มสาว และมีสุขภาพดี โดยทดสอบด้วยการจำลองกิจกรรมในชีวิตประจำวัน 4 ประเภท ได้แก่ การเดิน, กระโดด, พลิกตัวบนเตียง, ลูกขึ้นจากเตียง และ

จำลองการล้มสี่ประเภท ได้แก่ การล้มไปด้านหน้า, ล้มไปด้านหลัง, ล้มไปด้านซ้าย และล้มไปด้านขวา เพื่อเก็บข้อมูลและตรวจสอบการล้มโดยใช้ Neural Network ในการวิเคราะห์ ซึ่งบทความนี้ได้กล่าวถึงผลการทดลองที่ได้ว่าสามารถตรวจจับการล้มได้ถูกต้องที่ 96.25 เปอร์เซ็นต์และจะทำการทดลองกับผู้สูงอายุในอนาคต



รูปที่ 3 แสดงการรับรู้กระบวนการล้ม ในการตรวจจับการล้มโดยใช้ Neural Network [5]

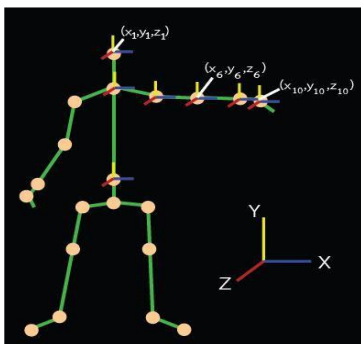
3. การออกแบบและพัฒนาระบบ

ในโครงการนี้แบ่งขั้นตอนทั้งหมดเป็น 3 ขั้นตอนหลักๆ คือ (1) การเก็บข้อมูล (2) การเตรียมข้อมูล (3) การวิเคราะห์ข้อมูล ซึ่งรายละเอียดของแต่ละขั้นตอนจะถูกอธิบายในหัวข้อถัดไป

3.1 การเก็บข้อมูล

ขั้นตอนแรกระบบจะทำการเก็บข้อมูล เริ่มจากศึกษาการล้มในรูปแบบต่างๆ [7] จากนั้นทำการเก็บลักษณะท่าทางของร่างกายที่จะใช้ในการทดสอบทั้งหมด 21 ลักษณะจากอุปกรณ์รับสัญญาณ Kinect แบ่งเป็น 2 ประเภท คือ กลุ่มของลักษณะท่าล้ม 11 ท่า กลุ่มของท่าทางที่ไม่ใช่การล้ม 10 ท่า โดยใช้ผู้ทดลองจำนวน 3 คน ดังตารางที่ 1

จากการเก็บข้อมูลพบว่า จากตำแหน่งร่างกายทั้งหมดจำนวน 20 ตำแหน่ง ดังรูปที่ 4 ซึ่งใน 1 นาทีจะได้ค่าพิกัดทั้งหมด 200 ค่า โดยประมาณ ต่อ 1 ตำแหน่งบนร่างกาย




รูปที่ 4 แสดงการเก็บค่าพิกัดในพิกัดต่างๆ ทั้ง 20 จุด [4]

การเก็บค่าพิกัด จะเก็บในรูปแบบของค่า (X,Y,Z) โดย X ตามแกนแนวนอน Y ตามแกนแนวตั้งและ Z ตามแกนแนวลึก ดังรูปที่ 5

ตารางที่ 1 ตารางแสดงท่าต่างๆในการทดสอบ

สถานะ	ลักษณะท่าทางของร่างกาย
กลุ่มของลักษณะท่าล้ม	1. ล้มไปข้างหน้า
	2. ล้มไปข้างหน้าเฉียงซ้าย
	3. ล้มไปข้างหน้าเฉียงขวา
	4. ล้มไปทางขวา
	5. ล้มไปข้างหลัง
	6. ล้มไปข้างหลังเฉียงซ้าย
	7. ล้มไปข้างหลังเฉียงขวา
	8. ล้มแบบก้นกระแทก
	9. ล้มไปทางซ้าย
	10. สะดุดสิ่งของล้มลงไปข้างหน้า
	11. ล้มพียงไปทางขวา
กลุ่มของท่าทางที่ไม่ใช่การล้ม	1. กระโดดสูง
	2. ย่อเข้ากระโดด
	3. นั่งลงกับพื้น
	4. ก้มเก็บของครึ่งตัว
	5. ก้มเก็บของแบบย่อเข้า
	6. วิดพื้น
	7. นั่งเก้าอี้
	8. สะดุดสิ่งของแล้วไม่ล้ม
	9. นั่งยองๆ
	10. นอน



รูปที่ 5 แสดงภาพในแกน 3 มิติ [4]

จากตัวอย่างข้อมูลดังตารางที่ 2 แสดงข้อมูลที่ได้รับจากอุปกรณ์รับสัญญาณ Kinect โดยข้อมูลที่ได้อยู่ในรูปแบบคู่ลำดับ (X, Y, Z) ของตำแหน่งต่างๆบนร่างกายจำนวน 20 จุด

ตารางที่ 2 ตัวอย่างข้อมูลที่ได้จากอุปกรณ์รับสัญญาณ Kinect

เฟรมที่	ศีรษะ	ส่วนกลางหัวไหล่	ไหล่ซ้าย	ไหล่ขวา
แกน X				
1	1.321	1.43	1.391	1.522
10	1.099	1.223	1.223	1.315
20	0.751	0.889	0.986	1.013
30	0.436	0.554	0.604	0.616
40	0.239	0.339	0.22	0.145
50	0.299	0.178	-0.082	0.334
แกน Y				
1	0.760	0.594	0.440	0.471
10	0.72	0.565	0.423	0.452
20	0.673	0.519	0.296	0.418
30	0.436	0.287	0.163	0.211
40	-0.303	-0.436	-0.564	-0.585
50	-0.310	-0.281	-0.412	-0.372
แกน Z				
1	3.259	3.247	3.405	3.132
10	3.189	3.169	3.344	3.040
20	3.253	3.172	3.283	3.038
30	3.447	3.364	3.462	3.102
40	3.208	3.059	3.157	2.835
50	3.133	3.242	3.208	3.188

3.2 การเตรียมข้อมูล

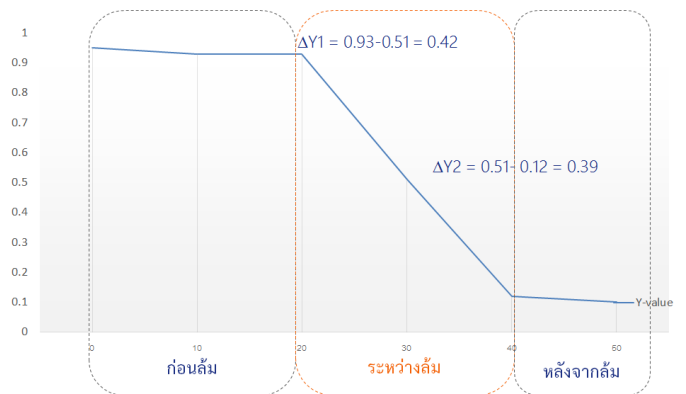
หลังจากเก็บข้อมูลขั้นตอนต่อมา ข้อมูลการล้มในแต่ละชุดข้อมูลจะถูกนำมาแบ่งออกเป็น 3 กลุ่มคือ กลุ่มที่อยู่ในช่วงเวลาก่อนล้ม , ระหว่างล้ม และหลังล้ม ตามรูปที่ 6 แล้วจึงหาค่าค่าเฉลี่ยของความแตกต่างระหว่างช่วงเวลาอีกครั้งหนึ่ง โดยกำหนดให้ P_i คือค่าพิคัดของช่วงเวลา i ตามสมการที่ 1 และกำหนดให้ $\Delta X, \Delta Y, \Delta Z$ คือค่าความต่างตามแกน X, Y และ Z ในหนึ่งช่วงเวลา หลังจากหาค่า ΔP_i ที่ได้จากสมการที่ 2 แล้วจึงนำมาหาค่าเฉลี่ยรวมอีกครั้งหนึ่ง

$$P_i = (X_i, Y_i, Z_i) \quad (1)$$

$$\begin{aligned} \Delta P_i &= (\Delta X_i, \Delta Y_i, \Delta Z_i) \\ &= (X_i - X_{i-1}, Y_i - Y_{i-1}, Z_i - Z_{i-1}) \end{aligned} \quad (2)$$

ตัวอย่างเช่น จากรูปที่ 7 หากพิจารณาจากกลุ่มข้อมูลระหว่างล้ม ความแตกต่างพิคัด ณ ตำแหน่งร่างกายที่จุดเดิม แต่เวลาเปลี่ยนไปจะคำนวณได้ดังนี้ เช่น $Y_{20} = 0.93$ และ $Y_{30} = 0.51$ (กำหนดให้ Y ค่าพิคัด

ตามแกน Y ในเฟรมที่ 20 และเฟรมที่ 30) ดังนั้นค่าความต่างที่ $\Delta Y_1 = 0.93 - 0.51 = 0.42$ เป็นต้น



รูปที่ 6 แสดงกลุ่มช่วงเวลาในการล้มตามแกน Y

3.3 การวิเคราะห์ข้อมูล

นำข้อมูลที่ได้จากการคำนวณในข้อ 3.2 มาวิเคราะห์ว่าเกิดการล้มหรือไม่และล้มไปในทิศทางใด โดยอาศัยอัลกอริทึม C4.5 [8] ซึ่งอยู่ในกลุ่มของ Tree-based learner หรือที่เรียกว่า Decision Tree โดยมีขั้นตอนในการวิเคราะห์เพื่อใช้จำแนกข้อมูลเริ่มจาก (1) เลือกแอททริบิวต์ที่ทำหน้าที่เป็น root node (2) สร้างเส้นทางเชื่อมจาก root node ไปยังโหนดลูก (internal nodes) จำนวนเส้นทางเชื่อมจะเท่ากับจำนวนค่าที่เป็นไปได้ทั้งหมดของแอททริบิวต์ที่เป็น root node และ (3) ถ้าโหนดลูกเป็นกลุ่มของข้อมูลที่อยู่ในคลาสเดียวกันทั้งหมด ก็จะหยุดทำการสร้างแผนภาพต้นไม้ต่อไป ซึ่งในโครงการนี้ข้อมูลที่ได้จากค่าเฉลี่ยความต่างระหว่างช่วงเวลาของแต่ละท่าจะถูกนำมาวิเคราะห์เพื่อสร้างรูปแบบการตัดสินใจสำหรับการวิเคราะห์การล้ม ซึ่งผลที่ได้จะถูกรายงานในหัวข้อถัดไป

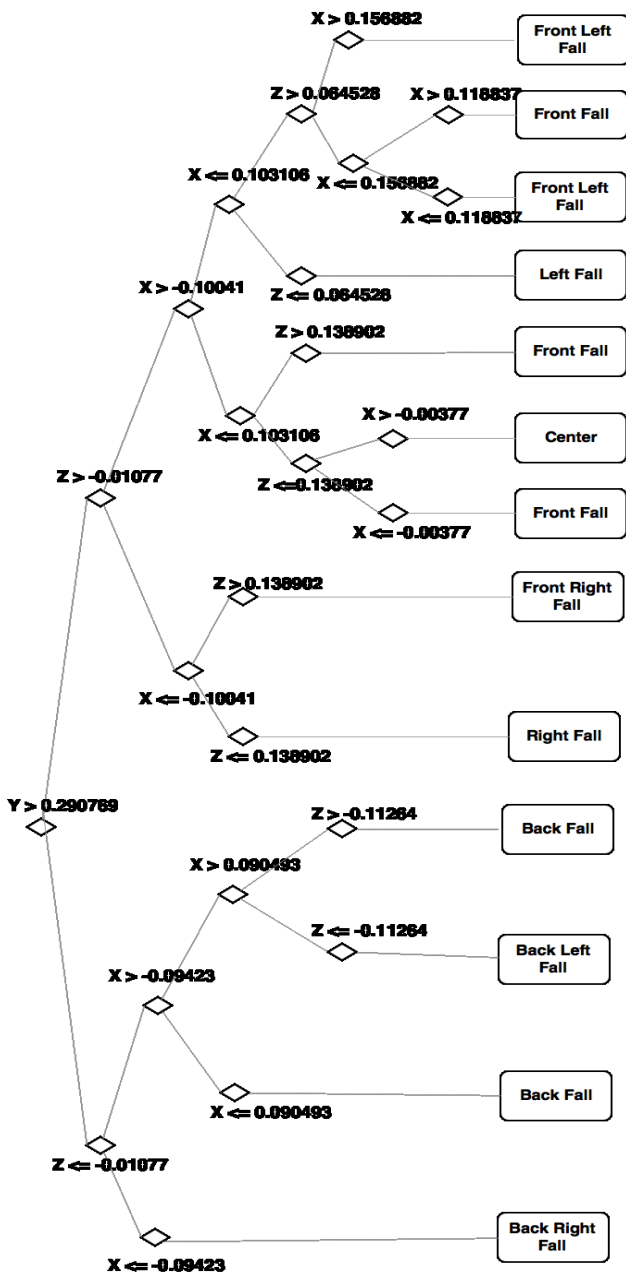
4. ผลการดำเนินการ

การทดลองเริ่มจากการเก็บลักษณะท่าทางของร่างกายที่จะใช้ในการทดสอบ โดยในการทดลองนี้ได้เก็บข้อมูลโดยใช้บุคคล 3 คน ทำการทรง 2 คน และทำการทดสอบ อีก 1 คน ที่มีรูปร่างแตกต่างกันมา การเก็บข้อมูลการล้มในรูปแบบต่างๆ จากการเก็บข้อมูล 21 ท่า แบ่งเป็นการล้ม 11 ท่าและไม่ล้ม 10 ท่า โดยทดลองล้มและไม่ล้มรวมกัน 103 ครั้ง แบ่งเป็นการล้ม 66 ครั้ง ไม่ล้ม 37 ครั้ง

โดยมีขั้นตอนการทดลองคือ นำข้อมูลที่ได้จากการเตรียมข้อมูลมาเพื่อทำการวิเคราะห์โดยใช้โปรแกรม Weka [9] และเลือกอัลกอริทึม C4.5 ในการทดสอบ ซึ่งผลที่ได้จากการวิเคราะห์ สามารถนำมาสร้างเป็นเงื่อนไขในการตัดสินใจการล้มสำหรับชุดข้อมูลที่นำมาทดสอบ และสามารถหามาสร้างเป็นแผนภาพต้นไม้ ตัวอย่างเช่นรูปที่ 7 ถ้าแกน Y มีค่าความต่างมากกว่า 0.290 คือล้ม ต่อมาคือแกน X ถ้าแกน X มีความต่างมากกว่า 0.103 และมีค่าเป็นบวก จะเป็นการล้มไปทางซ้าย ถ้าเป็นลบจะล้มไปทางขวา ต่อมาคือแกน Z ถ้าแกน Z มีผลต่างมากกว่า 0.138 และเป็นบวก จะล้มไปข้างหน้า ถ้าเป็นลบจะล้มไปข้างหลัง ส่วนถ้าแกน X และแกน Z น้อยกว่า 0.1 ทั้งคู่จะเป็นการล้มแบบก้นกระแทก และต่อมาคือแกน Z ถ้าแกน Z มีผลต่างมากกว่า 0.138 และเป็นบวก จะล้มไปข้างหน้า ถ้าเป็นลบ

จะล้มไปข้างหลังส่วนถ้าแกน X และแกน Z น้อยกว่า 0.1 ทั้งคู่จะเป็นการล้มแบบก้นกระแทก และในกรณีที่ไม่ล้มจะมีค่า Y น้อยกว่า 0.290

จากการวิเคราะห์โดยใช้อัลกอริทึม C4.5 ทำให้สามารถเลือกตำแหน่งที่สำคัญต่อการวิเคราะห์การล้มมากที่สุด 4 ตำแหน่งจากทั้งหมด 20 ตำแหน่ง นั่นได้แก่ ศีรษะ ส่วนกลางของหัวไหล่ ไหล่ข้างซ้าย และ ไหล่ข้างขวา จึงได้เก็บข้อมูลเฉพาะตำแหน่งนั้น เพื่อลดการความซับซ้อนของข้อมูล ในการทดลองนี้จะใช้สัดส่วนการเทรน 75% ซึ่งได้ค่าความถูกต้องอยู่ที่ 95.45% และผิดพลาด 4.55% และการทดสอบ 25% ได้ค่าความถูกต้องอยู่ที่ 91.43% และผิดพลาด 8.57 % ซึ่งเป็นสัดส่วนที่ดีที่สุดสำหรับชุดข้อมูลนี้ จากการล้มทั้งหมด 103 ครั้ง ดังอธิบายในรูปที่ 8



รูปที่ 7 แผนภาพต้นไม้ที่ได้จากการวิเคราะห์โดยใช้อัลกอริทึม C4.5 (C4.5 Algorithm) ในการตรวจจับการล้ม

=== Evaluation on training set ===
=== Summary ===

Correctly Classified Instances	95.4545 %
Incorrectly Classified Instances	4.5455 %

=== Detailed Accuracy By Class ===

TP Rate	FP Rate	Precision	Recall	F-Measure	ROC Area	Class
1	0.03	0.978	1	0.989	0.985	Normal
0.714	0	1	0.714	0.833	0.993	center
0.885	0.011	0.885	0.885	0.885	0.993	backfall
1	0.003	0.909	1	0.952	0.998	backleftfall
0.917	0.01	0.786	0.917	0.846	0.97	backrightfall
0.968	0.007	0.938	0.968	0.952	0.989	frontfall
0.923	0	1	0.923	0.96	1	frontleftfall
0.923	0	1	0.923	0.96	0.999	frontrightfall
0.875	0	1	0.875	0.933	1	leftfall
0.714	0.003	0.909	0.714	0.8	0.945	rightfall
Weighted Avg.	0.955	0.019	0.956	0.955	0.986	

รูปที่ 8 แสดงผลลัพธ์จากการวิเคราะห์โดยใช้อัลกอริทึม C4.5 (C4.5 Algorithm) ในการตรวจจับการล้ม

5. สรุปผลและข้อเสนอแนะ

การวิเคราะห์การล้มและประมวลลักษณะของการล้ม เป็นทางเลือกหนึ่งเพื่อนำไปพัฒนาต่อระบบต้นแบบของการตรวจจับการล้มในปัจจุบัน ทั้งนี้ระบบยังสามารถพัฒนาเพิ่มเติมส่วนต่างๆเพื่อเพิ่มขีดความสามารถในอนาคต เช่น การเก็บข้อมูลการล้มเพิ่มเติมในระบบโดยใช้กลุ่มบุคคลที่หลากหลายมากขึ้น การเพิ่มระบบแจ้งเตือนผู้ที่เกี่ยวข้องเมื่อผู้สูงอายุเกิดการล้มขึ้น และระบบแสดงการคำแนะนำและขั้นตอนในการปฐมพยาบาลเบื้องต้นให้ถูกต้องกับลักษณะการล้มเพื่อเพิ่มประสิทธิภาพในการรักษาเป็นต้น ในการทำผลการทดลองในอนาคต โครงการนี้มีแผนวางแผนจะทดสอบกับบุคคลหลายคนและหลายลักษณะทางกายภาพ โดยมีเงื่อนไขในการทดสอบคือ จะทดสอบกับกลุ่มบุคคลเฉพาะกลุ่มที่มีความสามารถในการป้องกันตัวจากอุบัติเหตุจากการล้มในการทดสอบ เช่น นักยูโด ซึ่งมีทักษะในการป้องกันตัวจากการบาดเจ็บในการล้มมากกว่ากลุ่มคนทั่วไป

6. กิตติกรรมประกาศ

โครงการนี้ได้รับทุนสนับสนุนจากทุนงบประมาณแผ่นดิน มหาวิทยาลัยมหิดล ประจำปี 2558

เอกสารอ้างอิง

- [1] “รายงานผลเบื้องต้น สํารวจประชากรสูงอายุในประเทศไทย พ.ศ. 2557”[Online] Available <http://service.nso.go.th/nso/nsopublish/themes/files/older57.pdf> [Accessed 1 July 2015]
- [2] Laurence Z. Rubenstein, MD, MPH, Karen R. Josephson, MPH, “Falls and Their Prevention in Elderly People: What Does the Evidence Show?” Geriatric Research Education & Clinical Center (GRECC), VA Sepulveda Ambulatory Care Center & Nursing Home, 16111 Plummer Street, North Hills, CA 91343, USA. (2006)

- [3] Christopher Kawatsu, Jiaying Li, and C.J. Chung, Development of a Fall Detection System with Microsoft Kinect, *Advances in Intelligent Systems and Computing* Volume 208, 2013, pp 623-630.
- [4] “Microsoft Kinect”[Online] Available <http://www.microsoft.com/en-us/kinectforwindows> [Accessed 1 July 2015]
- [5] Hashemi J., Spina T.V., Tepper M., Esler A., Morellas V., Papanikolopoulos M., and Sapiro G., “A computer vision approach for the assessment of autism-related behavioral markers,” in *2012 IEEE International Conference on Development and Learning and Epigenetic Robotics, ICDL*, 2012.
- [6] Adna Sengto , Dr. Thurssak Leauhatong , “Human Falling Detection Algorithm Using Back Propagation Neural Network”, School of Electronics Engineering, Faculty of Engineering King Mongkut's Institute of Technology Ladkrabang Ladkrabang, Bangkok, 10520, Thailand. (2012)
- [7] “การล้มและการป้องกัน” [Online] Available http://medinfo2.psu.ac.th/cancer/db/news_ca.php?newsID=106&typeID=20
- [8] Jiawei Han. & Micheline Kamber. (2006). “Data Mining: Concepts and Techniques” 2 nd ed., Morgan Kaufmann Publisher.
- [9] Ian H. & Eibe Frank. (2005). “Witten Data Mining Practical Machine Learning Tools and Techniques”, 2 nd ed., Morgan Kaufmann Publisher.