

การตรวจจับเฟสการเดินแบบเรียลไทม์โดยใช้เซนเซอร์ที่สวมใส่ได้
สำหรับการพัฒนาขาเทียมของผู้ที่ถูกตัดขาผ่านกระดูกหน้าแข้ง
ด้วยอัลกอริทึม kNN



นางสาวอัจฉราวรรณ รัตนศักดิ์

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชาวิศวกรรมโทรคมนาคมและคอมพิวเตอร์
มหาวิทยาลัยเทคโนโลยีสุรนารี
ปีการศึกษา 2565

REAL-TIME GAIT PHASE DETECTION USING WEARABLE SENSOR
FOR TRANSTIBIAL PROSTHESIS BASED ON KNN ALGORITHM



ATCHARAWAN RATTANASAK

A Thesis Submitted in Partial Fulfillment of the Requirements for the
Degree of Master of Engineering in Telecommunication and Computer Engineering
Suranaree University of Technology
Academic Year 2022

การตรวจจับเฟสการเดินแบบเรียลไทม์โดยใช้เซนเซอร์ที่สวมใส่ได้
สำหรับการพัฒนาขาเทียมของผู้ที่ถูกตัดขาผ่านกระดูกหน้าแข้ง ด้วยอัลกอริทึม kNN

มหาวิทยาลัยเทคโนโลยีสุรนารี อนุมัติให้นักวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษาตาม
หลักสูตรปริญญาโทบริหารธุรกิจ

คณะกรรมการสอบวิทยานิพนธ์



(รศ. ดร. ปิยาภรณ์ มีสวัสดิ์)

ประธานกรรมการ



(รศ. ดร. พีระพงษ์ อูซารสกุล)

กรรมการ (อาจารย์ที่ปรึกษาวิทยานิพนธ์)



(ผศ. ดร. อมิยญา ดีคำคำ)

กรรมการ

มหาวิทยาลัยเทคโนโลยีสุรนารี



(รศ. ดร. นัตถชัย โชติชรูยางกูร)

รองอธิการบดีฝ่ายวิชาการและประกันคุณภาพ



(รศ. ดร. พรศิริ จงกล)

คณบดีสำนักวิชาวิศวกรรมศาสตร์

นางสาวอัจฉราวรรณ รัตนศักดิ์ : การตรวจจับเฟสการเดินแบบเรียลไทม์โดยใช้เซนเซอร์ที่สวมใส่ได้สำหรับการพัฒนาขาเทียมของผู้ที่ถูกตัดขาผ่านกระดูกหน้าแข้ง ด้วยอัลกอริทึม KNN (REAL-TIME GAIT PHASE DETECTION USING WEARABLE SENSOR FOR TRANSTIBIAL PROSTHESIS BASED ON kNN ALGORITHM) อาจารย์ที่ปรึกษา : รองศาสตราจารย์ ดร. พิระพงษ์ อุฑารสกุล, 65 หน้า.

คำสำคัญ : การวิเคราะห์การเดิน/การตรวจจับเฟสการเดิน/ขาเทียมสำหรับผู้ที่ถูกตัดขาผ่านกระดูกหน้าแข้ง

ขาเทียมในปัจจุบันมักพบเจอปัญหาในด้านของการใช้งาน เช่น ขาเทียมสวมใส่ลำบาก ขาเทียมมีน้ำหนักเยอะทำให้ใส่แล้วเคลื่อนไหวไม่สะดวก และสิ่งที่เป็นปัญหาสำคัญที่สุดคือ ขาเทียมตรงส่วนของเท้าและข้อเท้าไม่สามารถขยับได้ตามเฟสการเดินจริงของมนุษย์ ทำให้ผู้พิการที่สวมใส่ขาเทียมนั้นไม่สามารถเคลื่อนไหวได้ตามที่ต้องการ ปัจจุบันได้มีการนำเทคโนโลยีต่างๆ มาพัฒนาให้ขาเทียมธรรมดาเป็นขาเทียมกลที่สามารถขยับตรงส่วนของเท้าและข้อเท้าได้ ทำให้ขาเทียมกลสามารถสนับสนุนกิจกรรมการเคลื่อนไหวต่างๆของมนุษย์ได้ดีมากยิ่งขึ้น เทคโนโลยีที่นิยมนำมาพัฒนา คือ เทคโนโลยีในแขนงของวิทยาการปัญญาประดิษฐ์ เนื่องจากเป็นเทคโนโลยีที่สามารถฝึกฝนคอมพิวเตอร์ ให้เรียนรู้ชุดข้อมูล จัดจำ และทำนายผลในสิ่งต่างๆที่ผู้ใช้ป้อนเข้าไปได้

วิทยานิพนธ์นี้ได้นำเสนอการนำวิทยาการปัญญาประดิษฐ์ kNN (k-Nearest Neighbor) มาใช้ในการตรวจจับเฟสการเดินของมนุษย์แบบเรียลไทม์ โดยใช้ควบคู่กับเซนเซอร์รับแรงกดที่ติดตั้งอยู่บริเวณแผ่นพื้นรองเท้า เพื่อทำการพัฒนาขาเทียมของผู้ที่ถูกตัดขาผ่านกระดูกหน้าแข้ง ให้ขาเทียมมีความสามารถในการรองรับกิจกรรมการเคลื่อนไหวต่างๆของผู้ที่สวมใส่ได้อย่างมีประสิทธิภาพ และช่วยให้ผู้ที่สวมใส่ขาเทียมสามารถเดินได้สะดวกมากยิ่งขึ้น

การทำนายเฟสของการเดินเพื่อควบคุมขาเทียมให้มีการขยับส่วนของเท้าและข้อเท้าได้จะช่วยพัฒนาคุณภาพของการเดินแก่ผู้พิการได้ จากการศึกษาในงานวิทยานิพนธ์นี้พบว่างานที่ได้นำเสนอมีความแม่นยำ 81.43% ในการทำนายเฟสของการเดินและสามารถควบคุมขาเทียมได้อย่างมีประสิทธิภาพเมื่อความเร็วของการเดินไม่เกิน 5 กม./ชม. นอกจากนี้อุปกรณ์ที่พัฒนาขึ้นนี้ยังมีขนาดเล็ก น้ำหนักเบา ไม่มีผลกระทบต่อผู้ใช้งาน และเหมาะสมต่อการพัฒนาขาเทียมในอนาคต

สาขาวิชา วิศวกรรมโทรคมนาคม
ปีการศึกษา 2565

ลายมือชื่อนักศึกษา อัจฉราวรรณ
ลายมือชื่ออาจารย์ที่ปรึกษา พิระพงษ์

ATCHARAWAN RATTANASAK : REAL-TIME GAIT PHASE DETECTION USING
WEARABLE SENSOR FOR TRANSTIBIAL PROSTHESIS BASED ON KNN ALGORITHM
ADVISOR : ASSOC. PROF. PEERAPONG UTHANSAKUL, Ph.D., 65 PP.

Keyword : Gait analysis/Gait phase detection/Transtibial prosthesis

Those with disabilities who have lost their legs must use a prosthesis to walk. However, traditional prostheses have the disadvantage of being unable to move and support the human gait because there are no mechanisms or algorithms to control them. This makes it difficult for the wearer to walk.

To overcome this problem, we developed an insole device with a wearable sensor for real-time gait phase detection based on the kNN (k-nearest neighbor) algorithm for prosthetic control. The kNN algorithm is used with the raw data obtained from the pressure sensors in the insole to predict seven walking phases, i.e., stand, heel strike, foot flat, midstance, heel off, toe-off, and swing.

As a result, the predictive decision in each gait cycle to control the ankle movement of the transtibial prosthesis improves with each walk. The results in this study can provide 81.43% accuracy for gait phase detection, and can control the transtibial prosthetic effectively at the normal walking speed of 5 km/h. Moreover, this insole device is small, lightweight and unaffected by the physical factors of the wearer.

School of Telecommunication Engineering
Academic Year 2022

Student's Signature อัฒฉกรรณ
Advisor's Signature Peerapong Uthansakul

กิตติกรรมประกาศ

วิทยานิพนธ์เล่มนี้สำเร็จลุล่วงได้ด้วยดี เนื่องจากได้รับความช่วยเหลืออย่างดียิ่ง ทั้งด้านวิชาการและด้านดำเนินงานวิจัย จากบุคคลและคณะบุคคลต่างๆ ได้แก่ รองศาสตราจารย์ ดร. พิระพงษ์ อุฑารสกุล อาจารย์ที่ปรึกษาวิทยานิพนธ์ที่ให้โอกาสทางการศึกษา ทั้งให้คำปรึกษา คำแนะนำ และแนะแนวทางอันเป็นประโยชน์ยิ่งต่องานวิจัยให้แก่ผู้วิจัยมาโดยตลอด รวมทั้งช่วยตรวจทานและแก้ไขวิทยานิพนธ์เล่มนี้จนเสร็จสมบูรณ์

รองศาสตราจารย์ ดร. ปิยาภรณ์ มีสวัสดิ์ รองศาสตราจารย์ ดร. รังสรรค์ วงศ์สรรคร์ รองศาสตราจารย์ ดร. มนต์ทิพย์ภา อุฑารสกุล ผู้ช่วยศาสตราจารย์ ดร. รังสรรค์ ทองทา ผู้ช่วยศาสตราจารย์ เรืออากาศเอก ดร. ประโยชน์ คำสวัสดิ์ ผู้ช่วยศาสตราจารย์ ดร. วิภาวี หัตถกรรม ผู้ช่วยศาสตราจารย์ ดร. สมศักดิ์ วาณิชอนันต์ชัย ผู้ช่วยศาสตราจารย์ ดร. เศรษฐวิทย์ ภูฉายา ผู้ช่วยศาสตราจารย์ ดร. ชิตพงศ์ เวชโชธรงค์ และ ดร. พิรสันต์ คำสาลี อาจารย์ประจำสาขาวิชา วิศวกรรมโทรคมนาคมและคอมพิวเตอร์ สำนักวิชาวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีสุรนารี ที่ให้ความรู้ด้านวิชาการ คำแนะนำ และให้คำปรึกษาอันเป็นประโยชน์ต่องานวิจัย

ขอขอบคุณนางสาววีรินทร์ อัจฉาญ เลขานุการ สาขาวิชาวิศวกรรมโทรคมนาคมและคอมพิวเตอร์ ที่ให้คำปรึกษาและจัดการด้านเอกสารตลอดระยะเวลาการศึกษา และขอบคุณพี่ เพื่อน น้องบัณฑิตศึกษาทุกท่านที่ คอยให้ความช่วยเหลือและเป็นกำลังใจ

สุดท้ายนี้ผู้วิจัยขอขอบพระคุณอาจารย์ผู้สอนทุกท่านที่ประสิทธิ์ประสาทความรู้ด้านต่าง ๆ ทั้งในอดีตและปัจจุบัน และขอกราบขอบพระคุณ บิดา มารดา รวมถึงญาติพี่น้องของผู้วิจัยทุกท่านที่ให้การอบรมเลี้ยงดูและให้การสนับสนุนทางการศึกษาเป็นอย่างดีมาโดยตลอด ทำให้ผู้วิจัยประสบความสำเร็จในชีวิตเรื่อยมา สำหรับคุณงามความดีอันใดที่เกิดจากวิทยานิพนธ์เล่มนี้ ผู้วิจัยขอมอบให้กับบิดา มารดา และญาติพี่น้องซึ่งเป็นที่รักยิ่งตลอดจนครูอาจารย์ผู้สอนที่เคารพทุกท่านที่ได้ถ่ายทอดประสบการณ์ที่ดีให้แก่ผู้วิจัยทั้งในอดีตและปัจจุบันจนสำเร็จการศึกษาไปได้ด้วยดี

อัจฉราวรรณ รัตนศักดิ์

สารบัญ

หน้า

บทคัดย่อ (ภาษาไทย).....	ก
บทคัดย่อ (ภาษาอังกฤษ).....	ข
กิตติกรรมประกาศ.....	ค
สารบัญ.....	ง
สารบัญตาราง.....	ช
สารบัญรูปภาพ.....	ซ
บทที่	
1 บทนำ	1
1.1 ความเป็นมาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของงานวิจัย	3
1.3 สมมติฐานของการวิจัย.....	4
1.4 ขอบเขตของการวิจัย.....	4
1.5 วิธีดำเนินการวิจัย.....	4
1.5.1 แนวทางการดำเนินงาน	4
1.5.2 เครื่องมือที่ใช้ในการวิจัย.....	4
1.6 ประโยชน์ที่คาดว่าจะได้รับ.....	5
2 ปรัชญาวรรณกรรมและทฤษฎีที่เกี่ยวข้อง	6
2.1 บทนำ	6
2.2 วงจรการเดินของมนุษย์ (Gait cycle).....	6
2.3 การเก็บค่าการเดิน	10
2.3.1 เซนเซอร์วัดแรงเฉื่อย (Inertial Measurement Unit: IMU).....	10
2.3.2 เซนเซอร์รับแรงกด (Force Sensing Resistor: FSR).....	11
2.4 การจำแนกรูปแบบของสัญญาณการเดิน (Classification).....	15
2.5 สรุป	19

สารบัญ (ต่อ)

หน้า

3	วิธีการดำเนินการวิจัย	20
3.1	บทนำ.....	20
3.2	การเก็บข้อมูลการเดินทาง	20
3.2.1	กำหนดเกณฑ์การคัดเลือกอาสาสมัคร	20
3.2.2	การเตรียมอุปกรณ์บันทึกสัญญาณการเดินทาง.....	20
3.2.3	การติดตั้งอุปกรณ์บันทึกสัญญาณการเดินทาง.....	21
3.2.4	การกำหนดรูปแบบท่าทางการเดินให้มีมาตรฐานเดียวกัน	25
3.2.5	พัฒนาโปรแกรมเก็บข้อมูลสัญญาณการเดินทาง	26
3.2.6	การเก็บข้อมูลการเดินทาง	27
3.3	การวิเคราะห์ความแตกต่างของสัญญาณการเดินทาง.....	28
3.4	การตรวจจับเฟสการเดินทาง	30
3.4.1	การจัดเตรียมข้อมูลการเดินทาง	30
3.4.2	การสร้างอัลกอริทึม kNN เพื่อตรวจจับเฟสการเดินทาง	31
3.4.3	การทดสอบประสิทธิภาพอัลกอริทึม kNN	32
3.4.4	การสร้างระบบปรับเทียบน้ำหนักเซนเซอร์อัตโนมัติ.....	33
3.5	สรุป	34
4	ผลการวิจัยและอภิปรายผล	35
4.1	บทนำ.....	35
4.2	ผลการทดสอบพารามิเตอร์ k ที่มีผลต่อประสิทธิภาพของอัลกอริทึม	35
4.3	ผลแสดงค่าความแม่นยำการตรวจจับเฟสการเดินทาง	36
4.4	ผลของความเร็วในการเดินที่ส่งผลกระทบต่อค่าความแม่นยำของอัลกอริทึม	38
4.5	ความหวังเวลาสำหรับการตรวจจับเฟสการเดินทาง.....	39
4.6	การพัฒนาระบบควบคุมขาเทียมกล	40
5	สรุปผลการวิจัยและข้อเสนอแนะ	45
5.1	สรุปผลการวิจัย.....	45
5.2	ข้อเสนอแนะและแนวทางการพัฒนาในอนาคต	46

สารบัญ (ต่อ)

หน้า

รายการอ้างอิง	47
ภาคผนวก	51
ประวัติผู้เขียน	65



สารบัญตาราง

ตารางที่		หน้า
2.1	ลักษณะการเคลื่อนไหวของสะโพก เข่า ข้อเท้า และกล้ามเนื้อในการเดินแต่ละเฟส.....	9
4.1	ตารางแสดงค่าความแม่นยำการตรวจจับเฟสการเดิน 7 เฟส.....	36



สารบัญรูปภาพ

รูปที่	หน้า
1.1	สถานการณ์ด้านคนพิการในประเทศไทยวิเคราะห์ตามประเภทความพิการ (31 มี.ค. 2565) 1
2.1	ลักษณะการเคลื่อนไหวของข้อเท้า..... 6
2.2	วงจรการเดินของมนุษย์ (Gait cycle) 7
2.3	เซนเซอร์ IMU และตัวอย่างตำแหน่งการติดตั้งเซนเซอร์ IMU บนร่างกายมนุษย์..... 11
2.4	ลักษณะโครงสร้างของเซนเซอร์รับแรงกด (Force Sensing Resistor: FSR)..... 11
2.5	ลักษณะโครงสร้างของเท้ามนุษย์ 12
2.6	ภาพแสดงการลงน้ำหนักบริเวณฝ่าเท้าในแต่ละเฟสขณะเดิน 13
2.7	ตำแหน่งการติดตั้งเซนเซอร์รับแรงกดบนฝ่าเท้าที่ถูกต้อง 14
2.8	การแบ่งพื้นที่บริเวณฝ่าเท้าในการตรวจจับเฟสการเดิน 14
2.9	ลักษณะโดยพื้นฐานของ Machine Learning 15
2.10	กระบวนการการแก้ปัญหาของ Machine Learning 15
2.11	รูปแบบพื้นฐานของการเรียนรู้แบบมีผู้สอน (Supervised Learning)..... 16
2.12	ตัวอย่างการทำงานของวิธีการค้นหาเพื่อนบ้านที่ใกล้ที่สุด k ตัว 18
3.1	อุปกรณ์บันทึกสัญญาณการเดินแบบไร้สาย (ก) และบอร์ดไมโครคอนโทรลเลอร์ (ข)..... 20
3.2	บริเวณการติดตั้งเซนเซอร์ในเฟสของ Heel strike 22
3.3	บริเวณการติดตั้งเซนเซอร์ในเฟสของ Foot flat..... 22
3.4	บริเวณการติดตั้งเซนเซอร์ในเฟสของ Midstance 23
3.5	บริเวณการติดตั้งเซนเซอร์ในเฟสของ Heel off และ Toe off 23
3.6	บริเวณการติดตั้งเซนเซอร์ในท่าทางการยืน Stance 24
3.7	รูปแบบการต่อวงจรของอุปกรณ์บันทึกสัญญาณการเดิน 24
3.8	อุปกรณ์บันทึกสัญญาณการเดินแบบไร้สาย 25
3.9	ท่าทางการยืนตรง 25
3.10	ลักษณะท่าทางการเดินตามวงจรการเดิน 26
3.11	โปรแกรมเก็บข้อมูลสัญญาณการเดิน 26

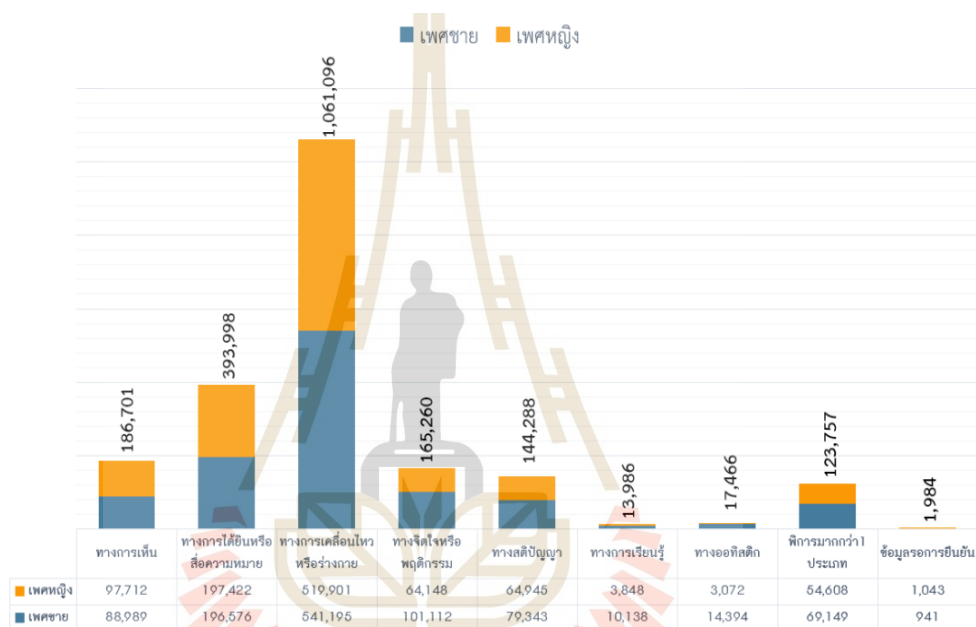
สารบัญรูปร่างภาพ (ต่อ)

รูปที่	หน้า
3.12	ท่าทางการยืนนั่งบนลู่วิ่งไฟฟ้า 27
3.13	การเดินบนลู่วิ่งไฟฟ้าตามมาตรฐานวงจรการเดินของมนุษย์ 28
3.14	ตัวอย่างสัญญาณที่ได้จากการเก็บค่าการเดิน 28
3.15	การพิจารณาสัญญาณที่จะนำไปวิเคราะห์..... 29
3.16	การแบ่งส่วนของข้อมูลขณะก้าว (ไม่รวม Swing phase) 29
3.17	ตัวอย่างการแบ่งสัญญาณข้อมูลการเดินออกเป็น 7 ส่วนที่ต้องการ 30
3.18	ตัวอย่างการเก็บบันทึกข้อมูลการเดิน..... 31
3.19	กระบวนการเรียนรู้ของอัลกอริทึม k-Nearest Neighbor 32
3.20	แบบจำลองการทดสอบหาพารามิเตอร์ k ที่เหมาะสม..... 32
3.21	กระบวนการทดสอบของอัลกอริทึม k-Nearest Neighbor..... 32
3.22	แผนผังการทำงานของระบบการตรวจจับการเดินพร้อมระบบปรับเทียบ น้ำหนักเซนเซอร์รับแรงกดอัตโนมัติสำหรับการควบคุมขาเทียมกล..... 33
4.1	ผลการทดสอบพารามิเตอร์ k ที่มีผลต่อค่าประสิทธิภาพของอัลกอริทึม 35
4.2	ตัวอย่างการทำนายข้ามเฟส หรือ Cross-phase prediction 38
4.3	กราฟแสดงผลของความเร็วในการเดินที่ส่งผลกระทบต่อค่าความแม่นยำของอัลกอริทึม 39
4.4	กราฟแสดงผลความหน่วงเวลาสำหรับการตรวจจับเฟสการเดิน 40
4.5	การออกแบบระบบการควบคุมขาเทียมกล 40
4.6	ผลการควบคุมขาเทียมกล เท้าขวาท่าทาง Heel off และเท้าซ้ายท่าทาง Heel strike..... 41
4.7	ผลการควบคุมขาเทียมกล เท้าขวาท่าทาง Toe off และเท้าซ้ายท่าทาง Foot flat..... 41
4.8	ผลการควบคุมขาเทียมกล เท้าขวาท่าทาง Swing และเท้าซ้ายท่าทาง Midstance..... 42
4.9	ผลการควบคุมขาเทียมกล เท้าขวาท่าทาง Heel strike และเท้าซ้ายท่าทาง Heel off..... 42
4.10	ผลการควบคุมขาเทียมกล เท้าขวาท่าทาง Foot flat และเท้าซ้ายท่าทาง Toe off..... 43
4.11	ผลการควบคุมขาเทียมกล เท้าขวาท่าทาง Midstance และเท้าซ้ายท่าทาง Swing..... 43
4.12	ผลการควบคุมขาเทียมกล เท้าขวา และเท้าซ้ายท่าทาง Stand..... 44

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา



รูปที่ 1.1 สถานการณ์ด้านคนพิการในประเทศไทยวิเคราะห์ตามประเภทความพิการ (31 มี.ค. 2565)

ในปัจจุบัน ประเทศไทยมีจำนวนประชากรประมาณ 69.8 ล้านคน จากรายงานข้อมูลสถานการณ์ด้านคนพิการในประเทศไทย ของกรมส่งเสริมและพัฒนาคุณภาพชีวิตคนพิการ กระทรวงพัฒนาสังคมและความมั่นคงของมนุษย์ (ข้อมูล ณ วันที่ 31 มีนาคม 2565) ได้ระบุว่า ปัจจุบันประเทศไทยของเรามีผู้พิการอยู่ประมาณ 2,108,536 คน โดยประเภทของคนพิการสามารถแบ่งได้ออกเป็นหลายประเภท ได้แก่ ความพิการทางด้านการมองเห็น ความพิการทางด้านการได้ยิน ความพิการทางด้านการเคลื่อนไหว ความพิการทางด้านด้านจิตใจหรือพฤติกรรม ความพิการทางด้านสติปัญญา ความพิการทางด้านการเรียนรู้ ความพิการทางด้านออทิสติก และความพิการทางด้านอื่นๆ จากรูปที่ 1.1 จะเห็นได้ว่า จำนวนของผู้พิการทางด้านการเคลื่อนไหวหรือทางร่างกายนั้นมีจำนวนมากกว่าความพิการประเภทอื่นๆ อย่างเห็นได้ชัด โดยมีจำนวนทั้งหมด 1,061,096 คน คิดเป็นร้อยละ 50.30

ของจำนวนประชากรผู้พิการทั้งหมด ผู้พิการทางด้านการเคลื่อนไหวโดยเฉพาะผู้พิการทางขานั้นล้วนแต่มีความยากลำบากอย่างมากในการใช้ชีวิตประจำวัน เนื่องจากสูญเสียอวัยวะสำคัญที่ช่วยในการเคลื่อนที่ไป จึงได้มีการพัฒนาขาเทียม (Prosthetic leg) ขึ้นมาเพื่อจะนำมาเป็นตัวช่วยสำหรับผู้พิการทางขาให้สามารถเคลื่อนไหวได้สะดวกมากยิ่งขึ้น แต่อย่างไรก็ตามขาเทียมในปัจจุบันนั้นก็ยังคงพบเจอปัญหาทางด้านการใช้งานต่างๆ ยกตัวอย่างเช่น ขาเทียมมีน้ำหนักเยอะ การสวมใส่ขาเทียมมีความลำบาก จำเป็นต้องมีคนช่วยพยุงขณะสวมใส่หรือเดิน มีอาการเจ็บขณะสวมใส่ นอกจากนี้สิ่งที่เป็นปัญหาหลักและสำคัญที่สุดของขาเทียม คือ ขาเทียมเป็นเพียงเครื่องมือที่ช่วยในการพยุงและค้ำยันเท่านั้น แต่ไม่ได้ช่วยในเรื่องของการเดินให้สามารถเดินได้ง่ายขึ้น เนื่องจากตรงส่วนของบริเวณข้อเท้าของขาเทียมนั้นไม่สามารถขยับได้ตามการเดินจริงของมนุษย์ ทำให้ผู้พิการที่สวมใส่ขาเทียมนั้นเดินได้อย่างไม่เป็นธรรมชาติ

จากการทบทวนวรรณกรรมในช่วงไม่กี่ปีที่ผ่านมาพบว่ามีหลายงานวิจัยที่ทำการพัฒนาเทคโนโลยีขาเทียมกลเพื่อช่วยเหลือผู้พิการทางขา ซึ่งหนึ่งในเทคโนโลยีที่ได้รับความนิยมและเป็นที่น่าสนใจมากที่สุด คือ เทคโนโลยีการควบคุมขาเทียมกลอัตโนมัติ โดยใช้อุปกรณ์หรือสัญญาณเซนเซอร์หลากหลายชนิดในการตรวจจับเฟสการเดิน (Gait phase detection) ของมนุษย์ เพื่อให้เซนเซอร์เหล่านั้นรับและส่งข้อมูลให้กับอัลกอริทึมที่มีความสามารถทำนายเฟสการเดินในปัจจุบันและอนาคตได้ โดยเทคโนโลยีเหล่านี้ล้วนมีจุดมุ่งหมายในการเพิ่มความสามารถในการควบคุมขาเทียมกล และช่วยให้ผู้พิการทางขาสามารถเคลื่อนไหวได้อย่างราบรื่นมากยิ่งขึ้น ยกตัวอย่างเช่น งานวิจัยของ Huseyin (2007) ได้พัฒนาระบบการควบคุมขาเทียมกล โดยใช้ระบบแมชชีนวิชัน (Machine vision) ร่วมกับอุปกรณ์ตรวจวัดแรงกดฝ่าเท้า (Force plate) ในการตรวจจับแรงกดฝ่าเท้า และลักษณะการเคลื่อนไหวต่างๆ ในขณะเดิน เช่น การเคลื่อนไหวของสะโพก เข่า และมุมของข้อเท้า โดยใช้อัลกอริทึมการเรียนรู้ของเครื่อง (Machine learning) ในการตรวจจับเฟสการเดินของผู้ทำการทดลอง อย่างไรก็ตามในการใช้ระบบแมชชีนวิชันยังคงมีข้อจำกัดในเรื่องของการนำไปใช้งานจริง เนื่องจากการใช้ระบบแมชชีนวิชันในการตรวจจับเฟสการเดิน ผู้ที่ทำการทดลองจำเป็นต้องอยู่ในห้องปฏิบัติการ หรืออยู่ในสถานที่ที่ถูกจัดเตรียมไว้ให้ ด้วยเหตุดังกล่าวจึงไม่สามารถนำมาใช้จริงในชีวิตประจำวันได้ ต่อมาจึงได้มีการพัฒนาให้กลายเป็นอุปกรณ์ตรวจจับเฟสการเดินที่สามารถสวมใส่ได้ (Wearable Device) ร่วมกับเซนเซอร์ที่สวมใส่ได้ (Wearable sensor) เพื่อเพิ่มความสะดวกสบายในการสวมใส่และสามารถนำมาใช้ได้จริงในชีวิตประจำวัน โดยในแต่ละงานวิจัยจะมีความแตกต่างกันไป ทั้งในเรื่องของเซนเซอร์ที่เลือกใช้ ตลอดจนเทคนิคในการประมวลผลข้อมูล งานวิจัยส่วนใหญ่มักจะเลือกใช้เซนเซอร์วัดแรงเฉื่อย (Inertial measurement unit : IMU) และเซนเซอร์รับแรงกด (Force sensing resistor : FSR) เป็นเซนเซอร์หลักในการตรวจจับเฟสการเดิน ส่วนอัลกอริทึมที่ใช้ในการแยกแยะและประมวลผลข้อมูล มักนิยมใช้การเรียนรู้ของเครื่องประเภทต่างๆ ยกตัวอย่างเช่น โครงข่ายประสาท

เทียม (Artificial neural network : ANN), เครือข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network : CNN) และวิธีการเพื่อนบ้านที่ใกล้ที่สุดจำนวน k ตัว (k -Nearest Neighbor : kNN) เป็นต้น ยกตัวอย่างเช่น งานวิจัยของ Haohua, Pan, Ye, Fangmin (2021) เสนอที่จะใช้ เซนเซอร์วัดแรงเฉื่อย เป็นอุปกรณ์หลักในการตรวจจับเฟสการเดินของมนุษย์ โดยทำการติดตั้ง อุปกรณ์ไว้บริเวณภายนอกของรองเท้า อาศัยหลักการของใจโรสโคปในการตรวจจับทิศทางการเคลื่อนที่ของข้อเท้ามนุษย์ในวงจรการเดินต่างๆ นำมาพัฒนาร่วมกับอัลกอริทึมโครงข่ายประสาทแบบ คอนโวลูชัน ในลักษณะที่คล้ายกันกับงานวิจัยของ Ji, Chang, Sang (2020) ได้พัฒนาอุปกรณ์ ตรวจจับเฟสการเดินที่สามารถสวมใส่ได้ แต่เลือกใช้อุปกรณ์เซนเซอร์รับแรงกดเป็นเซนเซอร์หลักใน การตรวจจับเฟสการเดิน และใช้เทคนิคซ์พอร์ตเวกเตอร์แมชชีน (Support Vector Machine : SVM) ในการประมวลผล ทั้งนี้ในการเดินแต่ละเฟสของมนุษย์นั้นจะมีความแตกต่างกัน ทั้งในลักษณะ ท่าทางของเท้า องศาการขยับข้อเท้า รวมไปถึงความแตกต่างของแรงกดบริเวณฝ่าเท้าที่ต่างกัน ซึ่ง ความแตกต่างเหล่านี้สามารถนำมาพัฒนาอัลกอริทึมให้สามารถควบคุมขาเทียมกลอย่างมีประสิทธิภาพได้

อย่างไรก็ตามระบบการตรวจจับเฟสการเดินด้วยการใช้วิธีการต่างๆดังที่กล่าวมาข้างต้น ยังคงพบเจอปัญหา ได้แก่ ปัญหาในเรื่องของการทำนายเฟสการเดินที่ผิดพลาด การหน่วงเวลาในการ ควบคุมขาเทียมกล ความเร็วในการเดินที่มีผลต่อค่าความแม่นยำของอัลกอริทึม และปัญหาที่สำคัญ ที่สุดที่นั่นคือ ปัญหาในเรื่องของน้ำหนักตัวของผู้ที่สวมใส่ เนื่องจากในแต่ละบุคคลนั้นจะมีน้ำหนักตัวที่ แตกต่างกันไป ซึ่งน้ำหนักตัวที่ต่างกันนั้นจะส่งผลกระทบต่อค่าน้ำหนักของเซนเซอร์รับ แรงกด ทำให้มีค่าน้ำหนักที่เปลี่ยนแปลงไป และอาจทำให้เกิดข้อผิดพลาดในการตรวจจับเฟสการเดิน ได้ (Error gait detection) ดังนั้นในงานวิจัยนี้จึงเสนอแนวทางใหม่สำหรับการตรวจจับเฟสการเดิน แบบเรียลไทม์ โดยใช้เซนเซอร์ที่สวมใส่ได้ ด้วยอัลกอริทึม kNN เพื่อการควบคุมขาเทียมกลอย่างมี ประสิทธิภาพ นอกจากนี้ยังสามารถใช้งานได้โดยไม่มีปัญหาในเรื่องของน้ำหนักตัวของผู้ที่สวมใส่ที่ แตกต่างกันอีกด้วย

1.2 วัตถุประสงค์ของงานวิจัย

1.2.1 พัฒนาอุปกรณ์พื้นรองเท้าที่ติดตั้งเซนเซอร์รับแรงกด สำหรับนำมาใช้ในการรับข้อมูล การเดิน วิเคราะห์ข้อมูล และตรวจจับเฟสการเดินของมนุษย์เพื่อเพิ่มประสิทธิภาพให้กับขาเทียม

1.2.2 พัฒนาระบบควบคุมขาเทียมกลให้มีความสามารถในการเคลื่อนไหว และมีความสามารถใกล้เคียงกับขามนุษย์ปกติทั่วไป

1.3 สมมติฐานของการวิจัย

การเดินในแต่ละเฟสของมนุษย์จะมีแรงกดบริเวณฝ่าเท้าที่แตกต่างกัน ซึ่งสามารถจำแนกความแตกต่างได้ด้วยอัลกอริทึมการเรียนรู้ของเครื่องเพื่อนำไปควบคุมขาเทียม โดยจะให้ความถูกต้องในการควบคุมขาเทียมกลตามเฟสการเดินจริงของมนุษย์มากกว่า 80 เปอร์เซ็นต์

1.4 ขอบเขตของการวิจัย

1.4.1 การเก็บข้อมูลการเดิน จะดำเนินการกับผู้ทำการทดลองที่เป็นคนปกติ สุขภาพแข็งแรง ไม่มีปัญหาทางการเดิน และมีช่วงอายุระหว่าง 20-40 ปี

1.4.2 การวิเคราะห์และการทดลองการเดิน จะอยู่ในช่วงความเร็วการเดินปกติของมนุษย์ นั่นคือความเร็วประมาณ 5 กิโลเมตรต่อชั่วโมง

1.4.3 การพัฒนาระบบควบคุมขาเทียมกล จะเป็นขาเทียมกลที่ใช้สำหรับผู้ที่ถูกตัดขาผ่านกระดูกหน้าแข้ง (Transtibial (TT) prosthesis)

1.5 วิธีดำเนินการวิจัย

1.5.1 แนวทางการดำเนินงาน

1.5.1.1 สัมภาษณ์นักวิจัยและงานวิจัยที่เกี่ยวข้องกับวิทยานิพนธ์

1.5.1.2 ศึกษาทฤษฎีที่เกี่ยวข้องกับวงจรการเดินของมนุษย์

1.5.1.3 ศึกษาทฤษฎีของเซนเซอร์รับแรงกดและวิธีการบันทึกสัญญาณแรง

1.5.1.4 ศึกษาวิธีการวิเคราะห์ความแตกต่างของสัญญาณแรงกดบริเวณฝ่าเท้า

1.5.1.5 ศึกษาวิธีการจำแนกความแตกต่างของคลื่นสัญญาณแรงกดบริเวณฝ่าเท้า

1.5.1.6 ออกแบบระบบการตรวจจับเฟสการเดินของมนุษย์

1.5.1.7 วิเคราะห์ความแตกต่างของแรงกดบริเวณฝ่าเท้าตามระบบที่ได้ออกแบบไว้

1.5.1.8 จำแนกความแตกต่างของแรงกดบริเวณฝ่าเท้าตามระบบที่ได้ออกแบบไว้

1.5.1.9 วิเคราะห์และสรุปผลการดำเนินการวิจัย

1.5.2 เครื่องมือที่ใช้ในการวิจัย

1.5.2.1 เซนเซอร์รับแรงกด (Force sensing resistor)

1.5.2.2 บอร์ดไมโครคอนโทรลเลอร์

1.5.2.3 คอมพิวเตอร์ส่วนบุคคล

1.5.2.4 โปรแกรมคอมพิวเตอร์

1.5.2.5 ใบอนุญาตสำหรับการดำเนินการวิจัยในมนุษย์

1.6 ประโยชน์ที่คาดว่าจะได้รับ

1.6.1 เป็นองค์ความรู้พื้นฐานในการพัฒนาเทคโนโลยีที่เกี่ยวข้องกับการตรวจจับเฟสการเดินของมนุษย์

1.6.2 เป็นแนวทางในการพัฒนาระบบการตรวจจับเฟสการเดินของมนุษย์สำหรับนำไปต่อยอด เพื่อช่วยเหลือผู้พิการทางขาได้



บทที่ 2

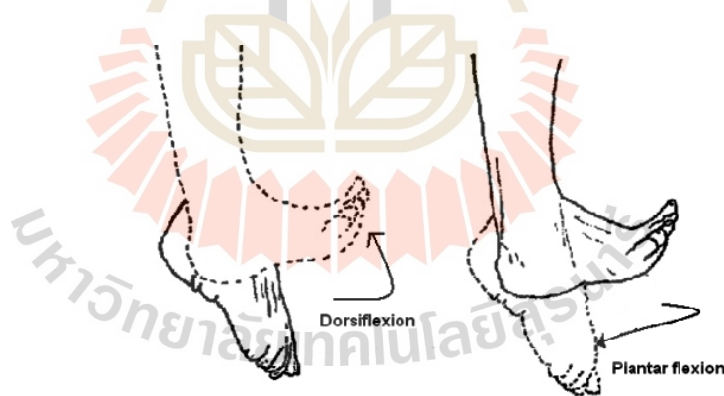
ปรีทัศน์วรรณกรรมและทฤษฎีที่เกี่ยวข้อง

2.1 บทนำ

เนื้อหาในบทนี้จะกล่าวถึงปรีทัศน์วรรณกรรมและทฤษฎีที่เกี่ยวข้องกับเทคโนโลยีการตรวจจับเฟสของเดินตามวงจรการเดินของมนุษย์ที่ถูกใช้เป็นแนวทางสำหรับวิทยานิพนธ์ฉบับนี้ โดยจะอธิบายถึงวงจรการเดินของมนุษย์ ลักษณะการเคลื่อนไหวของร่างกายขณะเดิน การเก็บค่าการเดินด้วยอุปกรณ์ที่แตกต่างกัน ลักษณะการแบ่งพื้นที่ของเท้า การลงน้ำหนักบริเวณฝ่าเท้าขณะเดิน สิ่งสำคัญที่ต้องพิจารณาในการติดตั้งเซนเซอร์ใต้ฝ่าเท้า และการจำแนกรูปแบบของสัญญาณการเดิน

2.2 วงจรการเดินของมนุษย์ (Gait cycle)


การเดินของมนุษย์ คือการเคลื่อนที่ของขาและเท้าทั้งสองข้างที่สัมพันธ์กัน จนเกิดเป็นวงจรการเดินหรือ Gait cycle โดยลักษณะการเคลื่อนไหวของเท้า จะประกอบด้วย การขยับข้อเท้า 2 ลักษณะ ได้แก่ การงอฝ่าเท้าลง (Plantar flexion) และการงอฝ่าเท้าขึ้น (Dorsiflexion) ดังรูปที่ 2.1



รูปที่ 2.1 ลักษณะการเคลื่อนไหวของข้อเท้า

ในวงจรการเดินครบหนึ่งรอบจะถูกนับเป็นเปอร์เซ็นต์ตั้งแต่ 0 ถึง 100 เปอร์เซ็นต์ ซึ่งจะเริ่มต้นจากท่าทางสัมผัสเท้าแต่ละพื้น (Initial Contact : IC หรือ Heel Strike : HS) ของเท้าข้างใดข้างหนึ่ง และสิ้นสุดเมื่อถึงท่าทางสัมผัสเท้าแต่ละพื้นครั้งถัดไปของเท้าข้างเดิม จึงจะนับว่าเป็นการเดินครบหนึ่งรอบ หรือเป็นการครบรอบวงจรการเดิน 100 เปอร์เซ็นต์ ซึ่งวงจรการเดินจะสามารถแบ่งออกเป็นสองช่วงหลักคือ ช่วง Stance phase ซึ่งเป็นช่วงที่เท้าสัมผัสกับพื้นโดยจะครอบคลุมวงวงจรการเดิน

ประมาณร้อยละ 60 ของวงจรกิจการเดิน และช่วง Swing phase เป็นช่วงที่เท้าลอยจากพื้น จะครอบคลุมวงจรกิจการเดินประมาณร้อยละ 40 ของวงจรกิจการเดิน ซึ่งทั้งสองช่วงนี้จะเกิดขึ้นสลับกันเป็นจังหวะ (Huong, Dianbiao, Hoang, Tom, Dirk, Bram, Joost, 2020)



รูปที่ 2.2 วงจรกิจการเดินของมนุษย์ (Gait cycle)

จากรูปที่ 2.2 จะเห็นได้ว่าในสองช่วงหลักของวงจรกิจการเดินของมนุษย์ จะสามารถแบ่งออกเป็นเฟสย่อยได้อีก ดังนี้

1. Stance phase ประกอบด้วยเฟสย่อยทั้งหมด 5 เฟส ดังนี้

- 1.1 Initial contact หรือ Heel strike เป็นจุดเริ่มต้นของวงจรกิจการเดิน ซึ่งเป็นช่วงจังหวะที่ส้นเท้าสัมผัสกับพื้น อยู่ในช่วงร้อยละ 0 ถึง 8 ของวงจรกิจการเดิน และในช่วงนี้น้ำหนักตัวจะเริ่มถูกถ่ายโอนไปยังขาหลังสู่เท้า
- 1.2 Foot flat เป็นระยะที่ฝ่าเท้าสัมผัสกับพื้นบางส่วน โดยในช่วงนี้จะเป็นช่วงสำคัญของการทรงตัวและการเคลื่อนที่ไปด้านหน้า อยู่ในช่วงร้อยละ 8 ถึง 30 ของวงจรกิจการเดิน

1.3 Midstance เป็นระยะที่ฝ่าเท้ารับน้ำหนักร่างกายทั้งหมด และจะสิ้นสุดเมื่อส้นเท้าพ้นจากพื้น อยู่ในช่วงร้อยละ 30 ถึง 40 ของวงจรกิจกรรม

1.4 Heel off เป็นระยะที่ส้นเท้าเริ่มยกขึ้นจากพื้น จนถึงจังหวะที่เหลือแต่ปลายเท้าสัมผัสพื้น อยู่ในช่วงร้อยละ 40 ถึง 60 ของวงจรกิจกรรม

1.5 Toe off เป็นระยะสุดท้ายของ Stance phase อยู่ในท่าทางปลายเท้าสัมผัสกับพื้น โดยในช่วงนี้จะเป็นช่วงที่เกิดแรงผลักดันให้ขาเคลื่อนที่ไปข้างหน้า เพื่อเริ่มต้นเข้าสู่ช่วง Swing phase

2. Swing phase ประกอบด้วยเฟสย่อยทั้งหมด 3 เฟส ดังนี้

2.1 Initial swing เป็นช่วงสิ้นสุดระยะ Toe off และเป็นจุดเริ่มต้นของการ Swing ปลายเท้าเริ่มยกจากพื้น

2.2 Mid swing คือ ช่วงกลางของการ Swing เป็นช่วงที่ฝ่าเท้ายกลอยสูงสุด

2.3 Terminal swing คือ ช่วงปลายของการ Swing เป็นช่วงที่ส้นเท้าเริ่มที่จะสัมผัสพื้นแล้วเข้าสู่ช่วงของ Stance Phase ใหม่

นอกจากการแบ่งเฟสการเดินดังที่ได้กล่าวไปในข้างต้นแล้ว ยังมีในส่วนของช่วง Single support และ Double support ซึ่ง Single support คือช่วงเวลาที่ยกขาข้างใดข้างหนึ่งขึ้นในเวลาเดียวกัน กล่าวอีกนัยหนึ่งว่าเป็นช่วงที่มีขาเพียงข้างเดียวที่ทำการรับน้ำหนักตัวและรักษาสมดุลของร่างกาย ส่วนช่วงของ Double support คือ ช่วงเวลาที่เท้าทั้งสองข้างแตะพื้นในเวลาเดียวกัน หรือก็คือมีขาทั้งสองข้างที่ช่วยกันรับน้ำหนักตัวและรักษาสมดุลของร่างกาย โดยช่วงของ Double support นี้ จะเกิดขึ้น 2 ช่วง ในหนึ่งรอบวงจรกิจกรรม ได้แก่ ช่วงที่ขาข้างใดข้างหนึ่งอยู่ในเฟส Toe off และขาอีกข้างอยู่ในเฟส Heel Strike ซึ่งจะพบช่วงของ Double support ในการเดิน แต่จะไม่พบในการวิ่ง อีกทั้งในแต่ละเฟสของการเดินนั้นจะมีการเคลื่อนไหวของสะโพก เข่า ข้อเท้า และกล้ามเนื้อที่แตกต่างกันไป ดังตารางที่ 2.1

ตารางที่ 2.1 ลักษณะการเคลื่อนไหวของสะโพก เข่า ข้อเท้า และกล้ามเนื้อในการเดินแต่ละเฟส

Phases	Hip (Degree)	Knee (Degree)	Ankle (Degree)	Muscles
Heel strike	Flex 25	Fully extend	Neutral	Gluteus maximus, quadriceps, hamstrings, foot and toe dorsiflexors
Foot flat	Flex 23	Flex 20	Plantarflex 15	Same Heel strike
Midstance	Flex 10	Flex 10	Dorsiflex 3	Iliopsoas, gluteus minimus, tensor fascia lata, quadriceps, plantar flexors
Heel off	Hyperextend 10	Flex 2	Dorsiflex 15	Iliopsoas, hamstring, plantar flexors
Toe off	Flex 10	Flex 40	Plantarflex 20	Iliopsoas, quadriceps, plantar flexors
Acceleration	Flex 5	Flex 65	Neutral	Iliopsoas, quadriceps, foot and toe dorsiflexors
Mid swing	Flex 25	Flex 65	Neutral	Iliopsoas
Deceleration	Flex 25	Fully extend	Neutral	Gluteus maximus, hamstring, foot and toe dorsiflexors

จากตารางที่ 2.1 แสดงถึงค่ามุมที่แตกต่างกันของสะโพก (Hip), เข่า (Knee) และข้อเท้า (Ankle) รวมถึงกล้ามเนื้อที่ถูกใช้งานในแต่ละท่าทางการเดิน โดยที่ค่ามุมของสะโพกจะเป็นค่ามุมเมื่อเทียบกับแนวแกนตั้ง มีมุมงอ (Flex) ตั้งแต่ 25 องศาถึง -25 องศา โดยสามารถแบ่งออกได้เป็น 2 ช่วง คือ ช่วงที่ขาท่อนบนอยู่หน้าลำตัว (ช่วงของเฟส Heel strike, Foot flat, Midstance, Mid swing และ Terminal swing) ช่วงนี้จะมีค่ามุมที่เป็นบวก และช่วงที่ขาท่อนบนอยู่ข้างหลังลำตัว (ช่วงของเฟส Heel off งอไปข้างหลัง (Hyperextend) เกิน 10 องศา, Toe off และ Initial swing) ส่วนของเข่าจะแสดงถึงค่ามุมระหว่างขาท่อนบนและขาท่อนล่าง โดยจะมีมุมงอตั้งแต่ 0 องศา (Fully extend) จนถึง 65 องศา และในส่วนข้อเท้าจะแสดงถึงค่ามุมที่เปลี่ยนแปลงไปจากมุมปกติ (Neutral) คือ มุมตั้งฉากระหว่างขาท่อนล่างและฝ่าเท้า ซึ่งจะประกอบด้วยการขยับข้อเท้าทั้ง 2 ลักษณะ ได้แก่ การงอฝ่าเท้าลง (Plantar Flexion) และการงอฝ่าเท้าขึ้น (Dorsiflexion) สลับกันไป

2.3 การเก็บค่าการเดิน


การวิเคราะห์การเดิน (Gait Analysis) เป็นการวิเคราะห์ที่เป็นที่รู้จักและเป็นที่ยอมรับอย่างมากในงานวิจัย เนื่องจากข้อมูลในการเดินนั้นมีประโยชน์ในหลายด้าน ยกตัวอย่างเช่น ในด้านการแพทย์ มักใช้การวิเคราะห์การเดินเพื่อตรวจจับโรคที่เกี่ยวข้องกับการเดินและฝ่าเท้า อีกทั้งในทางด้านวิศวกรรมศาสตร์สามารถนำข้อมูลการเดินมาวิเคราะห์ความสัมพันธ์ของการเคลื่อนไหวระหว่างขาและเท้า เพื่อนำมาพัฒนาเทคโนโลยีการควบคุมขาเทียมสำหรับผู้พิการให้มีประสิทธิภาพมากยิ่งขึ้นได้ ดังนั้นการเก็บค่าการเดินจึงเป็นสิ่งที่สำคัญมากในการวิเคราะห์การเดิน โดยวิธีการเก็บข้อมูลการเดินนั้นมีอยู่หลายวิธี ซึ่งจะแตกต่างกันไปตามอุปกรณ์ที่เลือกใช้ อุปกรณ์ที่นิยมใช้ในการเก็บค่าการเดินมีทั้งหมด 3 อุปกรณ์ ได้แก่ เซนเซอร์วัดแรงเฉื่อย (Inertial Measurement Unit : IMU), เซนเซอร์รับแรงกด (Force Sensing Resistor : FSR) และอุปกรณ์วัดคลื่นไฟฟ้ากล้ามเนื้อ (Electromyography : EMG) แต่อย่างไรก็ตามการใช้อุปกรณ์วัดคลื่นไฟฟ้ากล้ามเนื้อ มักถูกเลือกใช้ในการตรวจจับเฟสการเดินน้อยกว่าการใช้เซนเซอร์วัดแรงเฉื่อย และเซนเซอร์รับแรงกด เนื่องจากอุปกรณ์นี้มีประสิทธิภาพต่ำเมื่อนำมาใช้ในงานจริง ยกตัวอย่างเช่น การเปลี่ยนแปลงตำแหน่งของอิเล็กโทรด การเปลี่ยนแปลงของกล้ามเนื้อ เหนือตามร่างกาย การสวมใส่ที่มีความลำบาก และมักพบเจอปัญหาในเรื่องของสัญญาณรบกวน และความซับซ้อนของข้อมูล (Nazmi, Rahman, Yamamoto, Ahmad, 2019)

2.3.1 เซนเซอร์วัดแรงเฉื่อย (Inertial Measurement Unit: IMU)

เซนเซอร์วัดแรงเฉื่อย หรือ IMU เป็นหน่วยตรวจวัดการเคลื่อนไหวภายในเพื่อตรวจจับว่าอุปกรณ์นั้นๆ กำลังเคลื่อนที่ไปในทิศทางใดหรือกำลังหมุนไปในทิศทางใด IMU อาศัยการทำงานด้วย 2 องค์ประกอบหลัก คือ

- (1) Accelerometers : อุปกรณ์ที่ใช้วัดความเร่งตามแนวแกน 3 ทิศทาง
- (2) Gyroscopes : อุปกรณ์สำหรับการวัดความเร็วเชิงมุม 3 ทิศทาง

ในช่วงหลายปีที่ผ่านมาได้มีการพัฒนางานวิจัยที่ได้พัฒนาการตรวจจับเฟสการเดิน (Gait phase detection) โดยใช้ IMU เป็นอุปกรณ์หลักในการเก็บค่าการเดิน โดยทำการตรวจวัดองค์ประกอบในการเคลื่อนไหวของอวัยวะในร่างกายต่างๆ ในระหว่างการเดินหรือการวิ่ง โดยแต่ละงานวิจัยก็จะมีการนำข้อมูลที่ได้จาก IMU มาวิเคราะห์ที่แตกต่างกันไป ยกตัวอย่างเช่น ใช้เพียงข้อมูล Accelerometers ในการวิเคราะห์ หรือใช้เพียงแค่ข้อมูล Gyroscopes ในการวิเคราะห์ ตลอดจนใช้ทั้งสองข้อมูลร่วมกันในการวิเคราะห์การเดิน เซนเซอร์ IMU มักจะถูกติดตั้งไว้กับส่วนต่างๆ ของร่างกาย เช่น หน้าอก แขน สะโพก ต้นขา เข่า และข้อเท้า ดังรูปที่ 2.3 เพื่อตรวจจับสัญญาณการเคลื่อนไหว ซึ่งตำแหน่งที่ติดตั้งเซนเซอร์ IMU ที่ให้ค่าความแม่นยำในการจำแนกเฟสการเดินสูงที่สุด คือตำแหน่งของเท้า และขา (Huong, Dianbiao, Hoang, Tom, Dirk, Bram, Joost, 2020)




รูปที่ 2.3 เซนเซอร์ IMU และตัวอย่างตำแหน่งการติดตั้งเซนเซอร์ IMU บนร่างกายมนุษย์

อย่างไรก็ตามการใช้เซนเซอร์วัดแรงเฉื่อย หรือ IMU ในการตรวจจับเฟสการเดินต่างๆขณะเดินหรือวิ่ง ยังคงพบข้อผิดพลาดในเรื่องของสัญญาณรบกวน การเปลี่ยนแปลงของสัญญาณ หรือ Signal drifting รวมถึงพบเจอปัญหาในเรื่องของการหน่วงเวลาขณะที่เริ่มต้นการเดินหรือขณะกำลังจะหยุดเดินอีกด้วย

2.3.2 เซนเซอร์รับแรงกด (Force Sensing Resistor : FSR)

เซนเซอร์รับแรงกด หรือ Force Sensing Resistor (FSR) เป็นอุปกรณ์ตรวจจับแรงกดแบบค่าความต้านทาน มีโครงสร้างของตัวตรวจจับ ดังรูปที่ 2.4 ประกอบด้วยแผ่นสารกึ่งตัวนำแบบอ่อนที่เป็นตัวกำหนดค่าความต้านทานไฟฟ้าประกบเข้ากับแผ่นขั้วไฟฟ้าแบบอ่อน โดยมีแผ่นฉนวนแบบอ่อนคั่นกลาง ทำให้เกิดค่าความต้านทานไฟฟ้าขึ้นระหว่างขาคู่ใช้งาน เมื่อมีการกดน้ำหนักลงบนแผ่นขั้วนำไฟฟ้า จะทำให้เกิดการสัมผัสระหว่างสารกึ่งตัวนำกับขั้วไฟฟ้า ส่งผลให้ค่าความต้านทานไฟฟ้าเกิดการเปลี่ยนแปลง กล่าวอีกนัยหนึ่งว่าแรงดันไฟฟ้าที่ตกคร่อมตัวตรวจจับจะมีค่าลดลง เมื่อมีแรงมากระทำบนแผ่นตรวจจับ



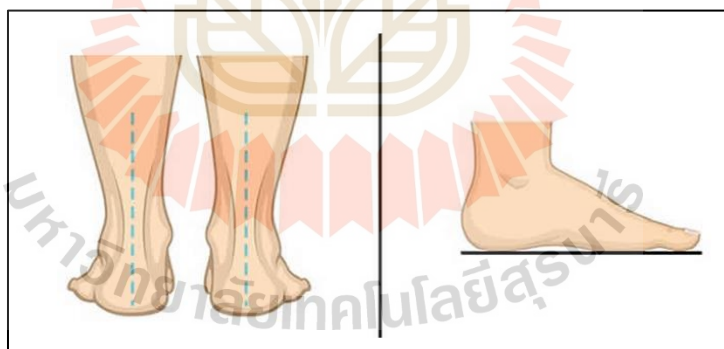
รูปที่ 2.4 ลักษณะโครงสร้างของเซนเซอร์รับแรงกด (Force Sensing Resistor : FSR)

เซนเซอร์รับแรงกด เป็นอุปกรณ์ที่นิยมนำมาใช้ในการเก็บค่าการเดินเพื่อทำการวิเคราะห์การเดิน โดยมักจะติดตั้งเซนเซอร์ไว้บริเวณใต้ฝ่าเท้าเพื่อรับแรงกดจากฝ่าเท้าเมื่อสัมผัสกับ

พื้นในขณะที่เดินหรือวิ่ง เซนเซอร์รับแรงกดนี้มีข้อดีหลายประการ ยกตัวอย่างเช่น ในด้านทางกายภาพ เซนเซอร์จะมีลักษณะคล้ายแผ่นฟิล์มที่มีความบางเพียง 0.13 มิลลิเมตร และมีความยืดหยุ่นสูง สามารถนำเซนเซอร์ไปติดตั้งภายในรองเท้าได้ง่ายโดยที่ผู้สวมใส่ไม่รู้สึกรังเกียจ อีกทั้งยังมีความทนทานในด้านการนำไปใช้งาน มีความสามารถในการรับแรงกระแทกขณะเดินได้ นอกจากนี้เซนเซอร์รับแรงกดยังมีความเหมาะสมในการนำไปใช้ในการเก็บค่าการเดิน รวมถึงการวิ่ง และการกระโดดสำหรับ ผู้ใหญ่อีกด้วย (Muhammad, Zoran, Kevin, 2015) การติดตั้งเซนเซอร์รับแรงกดภายใต้ฝ่าเท้า นั้น จำเป็นที่จะต้องพิจารณาสิ่งสำคัญ ดังต่อไปนี้

(1) ลักษณะโครงสร้างของเท้ามนุษย์

เท้าเป็นหนึ่งในอวัยวะที่สำคัญที่สุดในร่างกาย เนื่องจากมนุษย์จำเป็นต้องใช้เท้าสำหรับการเคลื่อนที่ กระดูกเท้าแต่ละข้างมีจำนวน 26 ชิ้น รวมเท้าซ้ายและเท้าขวาเป็น 52 ชิ้น ซึ่งสามารถแบ่งออกได้เป็น 3 ส่วน คือ ส่วนกระดูกข้อเท้า 7 ชิ้น กระดูกฝ่าเท้า 5 ชิ้น กระดูกนิ้วเท้า 14 ชิ้น กระดูกเท้าจัดวางเรียงตัวในลักษณะที่มีความโค้ง มีผลทำให้เกิดความยืดหยุ่นในการลงน้ำหนัก การจัดเรียงตัวดังกล่าวทำให้ทางด้านบนของเท้ามีลักษณะโค้งงอ แต่อย่างไรก็ตามความโค้งของเท้า จะแบนลงเมื่อมีน้ำหนักตัวกดลงมา เช่นในขณะที่ยืนและจะคืนตัวเมื่อนั่งหรือนอน ความโค้งของเท้า นั้น มีประโยชน์เพื่อให้เกิดการกระจายน้ำหนักในขณะที่ทำการเคลื่อนไหว ลักษณะโครงสร้างของเท้ามนุษย์ จะเป็นดังรูปที่ 2.5




รูปที่ 2.5 ลักษณะโครงสร้างของเท้ามนุษย์

(2) การลงน้ำหนักบริเวณฝ่าเท้าในแต่ละเฟสของการเดิน

โดยปกติในขณะที่ยืนลักษณะของฝ่าเท้ามนุษย์จะไม่ได้รับน้ำหนักเต็มพื้นที่ฝ่าเท้า แต่จะมีการลงน้ำหนักแค่บางส่วนของฝ่าเท้า โดยจะมีส่วนโค้งเว้าบริเวณตรงกลางฝ่าเท้า (Mid foot) ทั้งสองข้าง ซึ่งเป็นลักษณะโครงสร้างที่ช่วยทำให้เกิดความยืดหยุ่นในการลงน้ำหนัก และช่วยในเรื่องของการรักษาสมดุลขณะทำการเคลื่อนไหวต่างๆ เช่นเดียวกับกับขณะเดิน การเดินของมนุษย์ในแต่ละเฟส ก็จะมี ความแตกต่างกันในเรื่องของการลงน้ำหนักบนฝ่าเท้า ดังรูปที่ 2.6 โดยที่การแสดงผลของสีจะ

เป็นตัวบ่งบอกถึงแรงที่กระทำกับฝ่าเท้า เริ่มต้นจากสีน้ำเงินเข้ม คือ มีแรงมากกระทำน้อยกว่า 0 kPa และจะสิ้นสุดที่สีแดง คือ มีแรงมากกระทามากกว่า 230 kPa (Linah, Aladin, John, Syed, Rezaul, 2015)




รูปที่ 2.6 ภาพแสดงการลงน้ำหนักบริเวณฝ่าเท้าในแต่ละเฟสขณะเดิน

ซึ่งจากรูปที่ 2.6 จะเห็นได้ว่าการเดินในแต่ละเฟสของมนุษย์ จะมีแรงกดบริเวณฝ่าเท้าที่แตกต่างกันไปตามลักษณะท่าทางของเท้าที่สัมผัสพื้น โดยเริ่มจากเฟส Heel Strike (HS) และ Foot Flat (FF) จะมีแรงกดสูงสุดอยู่บริเวณส้นเท้า ต่อมาในเฟสของ Midstance (MSt) น้ำหนักตัวจะถูกกระจายออกไปอย่างสม่ำเสมอทั่วบริเวณฝ่าเท้า จากนั้นแรงกดจะถูกถ่ายโอนไปยังในส่วนของปลายเท้า ในช่วงของเฟส Heel off (HO) และ Toe off (TO) เนื่องจากต้องขับเคลื่อนร่างกายไปข้างหน้า ทำให้มีแรงกดที่สูงขึ้นในช่วงของปลายเท้า และเมื่อสิ้นสุดกระบวนการของ Stance phase เข้าสู่ช่วง Swing Phase แรงกดบริเวณฝ่าเท้าจะมีความแรงที่ต่ำมากหรือแทบจะไม่มีเลย เนื่องจากเป็นช่วงที่ฝ่าเท้าลอยอยู่ในอากาศ และไม่ได้สัมผัสพื้น

(3) พื้นที่ในการวางตำแหน่งของเซนเซอร์รับแรงกด

ตำแหน่งการวางเซนเซอร์รับแรงกดใต้ฝ่าเท้านั้นมีความสำคัญอย่างมากต่อการเก็บค่าการเดิน เนื่องจากหากทำการติดตั้งเซนเซอร์ในพื้นที่ที่ได้รับแรงที่ไม่มากพอ หรือพื้นที่ที่ได้รับแรงมากเกินไป อาจส่งผลกระทบต่อค่าน้ำหนักของเซนเซอร์รับแรงกดได้ ทำให้ข้อมูลที่จะนำไปวิเคราะห์นั้นไม่มีประสิทธิภาพ และเกิดข้อผิดพลาดได้ ดังนั้นตำแหน่งในการวางเซนเซอร์ที่เหมาะสมที่สุด ควรจะอยู่ในตำแหน่ง M ดังรูปที่ 2.7 โดยที่พื้นที่สีแดงคือพื้นที่ที่ได้รับแรงกดที่น้อยที่สุด และพื้นที่สีชมพูคือพื้นที่ที่ได้รับแรงกดที่มากที่สุด



รูปที่ 2.7 ตำแหน่งการติดตั้งเซนเซอร์รับแรงกดบนฝ่าเท้าที่ถูกต้อง

ดังนั้นสำหรับงานวิจัยที่เกี่ยวข้องกับการตรวจจับเฟสการเดิน จึงนิยมแบ่งพื้นที่ในการติดตั้งเซนเซอร์บริเวณฝ่าเท้าออกเป็น 4 พื้นที่ใหญ่ และ 15 พื้นที่ย่อยตามลักษณะการลงน้ำหนักของฝ่าเท้ามนุษย์ (Abdul, Aladin, Rezaul, Yufridin, 2012) ดังรูปที่ 2.8



รูปที่ 2.8 การแบ่งพื้นที่บริเวณฝ่าเท้าในการตรวจจับเฟสการเดิน


- บริเวณที่ 1 คือ ส่วนของส้นเท้า ได้แก่ พื้นที่หมายเลข 1 ถึงหมายเลข 3
- บริเวณที่ 2 คือ ส่วนของกลางเท้า ได้แก่ พื้นที่หมายเลข 4 ถึงหมายเลข 5
- บริเวณที่ 3 คือ ส่วนของปลายเท้า ได้แก่ พื้นที่หมายเลข 6 ถึงหมายเลข 10
- บริเวณที่ 4 คือ ส่วนของนิ้วเท้า ได้แก่ พื้นที่หมายเลข 11 ถึงหมายเลข 15

ซึ่งตำแหน่งในการติดตั้งเซนเซอร์บริเวณฝ่าเท้าในงานวิจัยของเรา จะกล่าวถึงในบทถัดไป แต่อย่างไรก็ตามในหลายงานวิจัยการใช้เซนเซอร์รับแรงกดในการตรวจจับเฟสการเดินของมนุษย์มักพบเจอปัญหาในเรื่องของลักษณะทางกายภาพของผู้ที่สวมใส่นั้นคือน้ำหนักตัว ซึ่งมนุษย์แต่ละคนก็จะมีน้ำหนักตัวที่แตกต่างกัน โดยค่าน้ำหนักตัวที่ต่างกันนั้นจะส่งผลกระทบต่อค่าน้ำหนักของเซนเซอร์รับแรงกด ทำให้เซนเซอร์รับแรงกดมีค่าน้ำหนักที่เปลี่ยนแปลงไป และอาจทำให้เกิดข้อผิดพลาดในการตรวจจับเฟสการเดินได้ (Error gait phases detection) นอกจากนี้ยังมี

ผลกระทบในเรื่องของความเร็วในการเดินที่ส่งผลกระทบต่อความแม่นยำการตรวจจับเฟสการเดินอีกด้วย โดยความเร็วการเดินที่เพิ่มขึ้นจะยิ่งทำให้ความแม่นยำในการตรวจจับเฟสการเดินลดลง (Bufu, Meng, Xi, Yangsheng, 2007)

2.4 การจำแนกรูปแบบสัญญาณการเดิน (Gait classification)

เป็นขั้นตอนในการสังเกต วิเคราะห์ และแยกแยะสัญญาณการเดิน หนึ่งในวิธีการที่ได้รับ ความนิยมมากที่สุดในการตรวจจับเฟสการเดินของมนุษย์คือ เทคโนโลยีการเรียนรู้ของเครื่อง หรือ Machine Learning โดยมีวัตถุประสงค์หลักเพื่อสร้างเครื่องมือที่มีความสามารถในการเรียนรู้ใน ประเด็นที่เราสนใจจากกลุ่มข้อมูล (Data) สามารถจดจำและแยกแยะรูปแบบ รวมถึงการทำนายผล ของกลุ่มข้อมูลต่างๆได้ ดังรูปที่ 2.9



รูปที่ 2.9 ลักษณะโดยพื้นฐานของ Machine Learning

การเรียนรู้ของเครื่องจะเรียนรู้จากการค้นพบรูปแบบหรือแบบแผนเดิมซ้ำๆ ผ่านส่วนของ ข้อมูล (data) และสามารถถูกฝึก (train) เพื่อที่จะเพิ่มความแม่นยำในการพยากรณ์กระบวนการหรือ คุณสมบัติต่างๆที่ถูกใช้เพื่อแก้ปัญหา เรียกว่า Feature vector นั่นคือ เมื่อ Model ถูกสร้างขึ้นมา อัลกอริทึมจะถูกทดสอบกับข้อมูลที่ไม่เคยได้เรียนรู้มาก่อน โดยข้อมูลที่เหล่านี้นจะถูกแปลงให้ กลายเป็น Feature vector และถูกรวบรวมให้กลายเป็น Model ดังรูปที่ 2.10




รูปที่ 2.10 กระบวนการการแก้ปัญหาของ Machine Learning

การเรียนรู้ของเครื่องสามารถแบ่งการเรียนรู้ออกเป็น 2 แบบ

1) การเรียนรู้แบบไม่มีผู้สอน (Unsupervised learning) เป็นวิธีการเรียนรู้แบบไม่มีการกำหนดป้ายกำกับ (Label) หรือประเภทของข้อมูลให้กับเครื่อง ซึ่งเครื่องจะทำการจัดเรียงโครงสร้างด้วยตัวเองตามคุณลักษณะของข้อมูลที่ได้รับ ผลลัพธ์ของการเรียนรู้ประเภทนี้จะเป็นการระบุกลุ่มของข้อมูลที่ใส่เข้าไปโดยอิงจากวิธีการจัดกลุ่มซึ่งได้เรียนรู้จากข้อมูลที่เครื่องเคยพบมา

2) การเรียนรู้แบบมีผู้สอน (Supervised Learning) เป็นวิธีการเรียนรู้แบบมีการกำหนดป้ายกำกับ หรือประเภทของข้อมูลให้กับเครื่อง ซึ่งการเรียนรู้ประเภทนี้เครื่องจะสามารถหาคำตอบของปัญหาได้ด้วยตัวเอง หลังจากเรียนรู้จากชุดข้อมูลตัวอย่างไปแล้วระยะหนึ่ง โดยวัตถุประสงค์หลักของการเรียนรู้ประเภทนี้คือ การสร้างโมเดลเพื่อทำนายผลลัพธ์ และสามารถจับคู่ชุดข้อมูลที่เข้ามาให้เข้ากับผลลัพธ์โดยให้มีความคลาดเคลื่อนน้อยที่สุด ดังรูปที่ 2.11



รูปที่ 2.11 รูปแบบพื้นฐานของการเรียนรู้แบบมีผู้สอน (Supervised Learning)

- Labels คือ ส่วนที่ผู้สอนกำหนดว่าป้ายกำกับหรือคำตอบของข้อมูลนั้นคืออะไร
- Predictive model คือ โมเดลที่ได้จากการเรียนรู้ของเครื่อง เป็นโมเดลที่ใช้ในการทำนายผลลัพธ์
- Prediction คือ ผลที่เครื่องทำการทำนาย
- New data คือ ข้อมูลใหม่ที่นำมาใช้วัดประสิทธิภาพของโมเดล

ซึ่งหนึ่งในวิธีการเรียนรู้ของเครื่องแบบมีผู้สอนที่ได้รับความนิยมคือ วิธีการค้นหาเพื่อนบ้านที่ใกล้ที่สุด k ตัว หรือ k -Nearest Neighbor (kNN) ซึ่งนิยมนำมาใช้ในการจำแนกกลุ่มของข้อมูล (Data classification), การจดจำรูปแบบ (Pattern recognition) และการจำแนกรูปภาพ (Picture classification) โดย kNN จะจัดเก็บชุดข้อมูลที่ได้ทำการเรียนรู้ทั้งหมดเป็นกลุ่มๆ และใช้

เทคนิคในการตัดสินใจว่าจุดทดสอบที่ได้รับเข้ามาใหม่นั้นอยู่ในกลุ่มใด โดยจะพิจารณาจากฟังก์ชันระยะทางทุกๆสองจุดข้อมูล และทำการจัดเรียงจุดข้อมูลใหม่ โดยจะทำการเรียงจากจุดข้อมูลที่อยู่ใกล้กับจุดทดสอบมากที่สุดจำนวน k ตัว และพิจารณาว่าจุดข้อมูลของกลุ่มข้อมูลใดที่มีจำนวนมากที่สุดก็จะสามารถอนุมานว่าจุดทดสอบอยู่ในกลุ่มนั้น

k-Nearest Neighbor หรือ kNN เป็นวิธีที่ถูกกล่าวถึงในหลายๆงานวิจัยในด้านการเปรียบเทียบความเหมาะสมและประสิทธิภาพในการทำงานกับวิธีการ Machine learning ประเภทอื่นๆ ยกตัวอย่างเช่น งานวิจัยของ Alaqtash (2011) ได้ทำการเปรียบเทียบค่าความแม่นยำของอัลกอริทึม kNN กับอัลกอริทึมเครือข่ายประสาทเทียม หรือ ANN ในการจำแนกรูปแบบการเดินออกเป็น 3 แบบ ผ่านข้อมูลที่ได้จาก Ground reaction force ในการเดิน ซึ่งผลปรากฏว่าการใช้อัลกอริทึม kNN ได้ค่าความแม่นยำที่สูงกว่าการใช้เครือข่ายประสาทเทียม อีกทั้งในงานวิจัยของ Pogorelc (2011) ได้ทำการจำแนกเฟสการเดินต่างๆทั้งหมด 5 แบบ โดยใช้อัลกอริทึม kNN, SVM, Decision Tree (DT), ANN และ Naivebayes (NB) เปรียบเทียบกัน โดยจากงานวิจัยพบว่าวิธีการ kNN และ ANN มีค่าความแม่นยำสูงถึง 100% รองลงมาคือ 97.9% สำหรับวิธีการ SVM, 97.2% สำหรับวิธีการ NB และ 90.1% สำหรับวิธีการ DT ด้วยเหตุนี้เราจึงพบว่า kNN เป็นวิธีการที่เหมาะสม และได้ค่าความแม่นยำที่สูง ดังนั้นในงานวิจัยของเราจึงเลือกใช้อัลกอริทึม kNN เป็นอัลกอริทึมหลักในการตรวจจับเฟสการเดิน

พื้นฐานของวิธีการค้นหาเพื่อนบ้านที่ใกล้ที่สุด k ตัว จะประกอบไปด้วย ชุดข้อมูลที่มีการกำหนดป้ายกำกับ หรือคำตอบของชุดข้อมูล เพื่อให้เครื่องกลทำการเรียนรู้ จดจำ และสามารถแยกแยะความแตกต่างของแต่ละชุดข้อมูลได้ จากนั้นเมื่อมีชุดข้อมูลใหม่เข้ามาโดยที่เครื่องไม่เคยทำการเรียนรู้มาก่อน เครื่องจะทำการประมวลผลโดยใช้ฟังก์ชันระยะทางแบบยูคลิด หรือ Euclidean distant ดังสมการที่ 2.1 ดังนี้

$$Dist(p, q) = Dist(q, p) = \sqrt{\sum_{i=1}^n (q_i - p_i)^2} \quad (2.1)$$

โดยที่ q คือ เวกเตอร์ตัวที่ 1

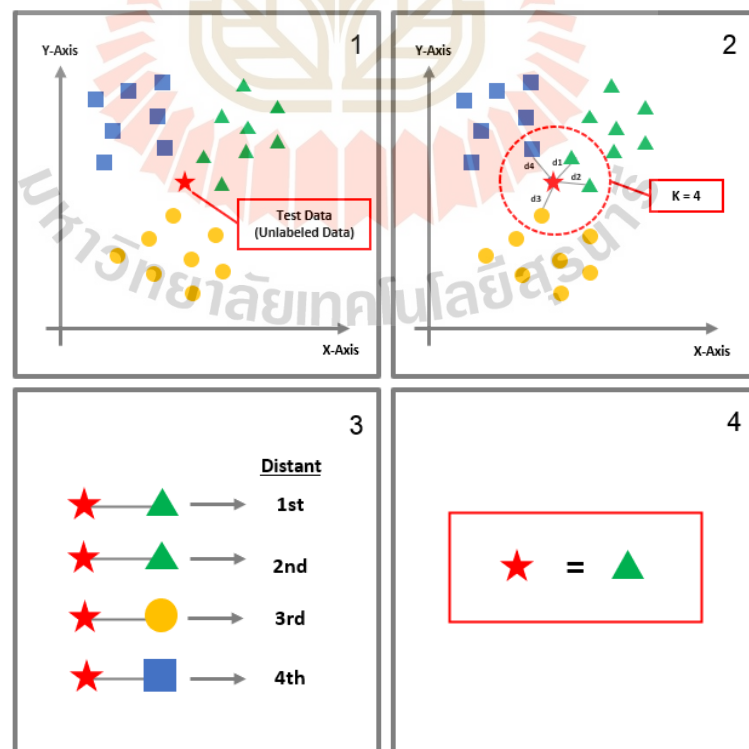
p คือ เวกเตอร์ตัวที่ 2

n คือ จำนวนมิติของเวกเตอร์

การวัดระยะทางแบบยูคลิด เป็นการวัดค่าความห่างระหว่างข้อมูล 2 ข้อมูล ในระบบพิกัดคาร์ทีเซียนที่มาจากทฤษฎีบทพีทาโกรัส ซึ่งถ้าหากข้อมูลทั้งสองตัวมีความคล้ายกันมาก แสดงว่าข้อมูลแต่ละตัวจะอยู่ใกล้กันมาก ซึ่งจะทำให้ค่ายูคลิดมีค่าน้อยและเข้าใกล้ศูนย์

สิ่งสำคัญที่จำเป็นที่จะต้องพิจารณาในวิธีการค้นหาเพื่อนบ้านที่ใกล้ที่สุด k ตัว คือ ค่าพารามิเตอร์ k เนื่องจากถ้ากำหนดให้ค่าพารามิเตอร์ k มีค่ามากหรือน้อยเกินไปจะส่งผลให้ค่าความแม่นยำในการทำนายผลเฟสการเดินเปลี่ยนแปลงไป ซึ่งถ้าค่าพารามิเตอร์ k มีค่ามากเกินไปก็จะมีโอกาสครอบคลุมพื้นที่ของข้อมูลที่ไม่เกี่ยวข้อง (ข้อมูลคนละประเภท) มากขึ้นเท่านั้น และถ้าหากค่า k มีค่าน้อยเกินไป ก็จะมีควมไวต่อการทำนายมากเกินไป ซึ่งส่งผลให้การทำนายไม่มีประสิทธิภาพ อีกทั้งการกำหนดค่า k ควรที่จะกำหนดเป็นเลขจำนวนคี่ เพื่อหลีกเลี่ยงปัญหาในการตัดสินใจของเครื่องในกรณีที่มีประเภทและจำนวนกลุ่มเท่ากันในการทำนาย

ยกตัวอย่างการทำงานของวิธีการค้นหาเพื่อนบ้านที่ใกล้ที่สุด k ตัว ดังรูปที่ 2.12 ตัวอย่างนี้ มีชุดข้อมูลที่เครื่องทำการเรียนรู้แล้วทั้งหมด 3 กลุ่มข้อมูล ได้แก่ กลุ่มของสามเหลี่ยมสีเขียว และวงกลม จุดรูปดาวสีแดง คือจุดทดสอบที่เครื่องยังไม่เคยได้เรียนรู้มาก่อน นำไปให้เครื่องกลการทำนายว่าจุดทดสอบนี้ควรที่จะอยู่ในกลุ่มใด โดยกำหนดให้ $K = 4$ ดังนั้น จุดทดสอบจะดึงชุดข้อมูลที่อยู่ใกล้กับจุดทดสอบมาทั้งหมด 4 ตัว โดยใช้สมการหาระยะทาง Euclidean Distance เพื่อที่จะหาว่าจุดทดสอบอยู่ใกล้กับจุดข้อมูลไหนมากที่สุด ซึ่งในตัวอย่างนี้จะเห็นได้ว่าจุดทดสอบนั้น อยู่ใกล้กับจุดข้อมูลของสามเหลี่ยม สามเหลี่ยม วงกลม และสี่เหลี่ยมตามลำดับ ซึ่งจะเห็นได้ว่ากลุ่มของสามเหลี่ยมมีจำนวนมากที่สุด ดังนั้นเครื่องจึงสามารถอนุมานหรือทำนายได้ว่าจุดทดสอบนั้นควรที่จะอยู่ในกลุ่มของสามเหลี่ยม



รูปที่ 2.12 ตัวอย่างการทำงานของวิธีการค้นหาเพื่อนบ้านที่ใกล้ที่สุด k ตัว

2.5 สรุป

จากเนื้อหาที่กล่าวมาข้างต้นในบทนี้พบว่าเฟสการเดินแต่ละเฟสในวงจรการเดินของมนุษย์นั้นจะมีลักษณะการเคลื่อนไหวและการลงน้ำหนักบริเวณฝ่าเท้าของที่แตกต่างกันไป ซึ่งการเก็บข้อมูลการเดินจะช่วยให้เข้าใจเกี่ยวกับการเคลื่อนไหวของเท้ามนุษย์มากขึ้น โดยวิธีการการเก็บค่าการเดินที่ได้รับความนิยมมากที่สุดคือการใช้อุปกรณ์ตรวจจับแรงกดที่เรียกว่า Force sensing resistor (FSR) เนื่องจากมีข้อดีหลายประการทั้งในด้านกายภาพของเซนเซอร์ที่มีความบาง ความยืดหยุ่น ด้านการนำไปใช้งาน เช่น การสวมใส่ที่ง่ายและไม่รู้สึกเจ็บ อย่างไรก็ตามจากการสำรวจปริทัศน์วรรณกรรมที่เกี่ยวข้องยังพบว่างานวิจัยที่ผ่านมา มักพบเจอปัญหาในเรื่องของลักษณะทางกายภาพของผู้ที่สวมใส่นั้นคือเรื่องของน้ำหนักตัวของผู้ที่สวมใส่ น้ำหนักตัวที่แตกต่างกันนั้นจะมีผลกระทบโดยตรงต่อค่าน้ำหนักของเซนเซอร์รับแรงกด ทำให้เซนเซอร์รับแรงกดมีค่าน้ำหนักที่เปลี่ยนแปลงไปและอาจทำให้เกิดข้อผิดพลาดในการตรวจจับเฟสการเดินได้ ดังนั้นผู้วิจัยจึงเสนอแนวทางใหม่สำหรับการตรวจจับเฟสการเดิน โดยการพัฒนาอุปกรณ์การเดินไร้สายร่วมกับอัลกอริทึม k-Nearest Neighbor (kNN) ที่สามารถสวมใส่ได้โดยไม่มีปัญหาในเรื่องของลักษณะทางกายภาพของผู้ที่สวมใส่ ซึ่งจะอธิบายในบทถัดไป



บทที่ 3

วิธีการดำเนินการวิจัย

3.1 บทนำ

เนื้อหาในบทนี้ จะกล่าวถึงการออกแบบระบบการตรวจจับเฟสการเดิน (Gait phase detection system) ซึ่งขั้นตอนในการดำเนินการวิจัยประกอบไปด้วย 3 ส่วนหลักดังนี้ การเก็บข้อมูลการเดิน, การวิเคราะห์ความแตกต่างของสัญญาณการเดินในแต่ละเฟส และการตรวจจับเฟสการเดิน


3.2 การเก็บข้อมูลการเดิน

3.2.1 กำหนดเกณฑ์การคัดเลือกอาสาสมัคร

- (1) มีความยินยอมเข้าร่วมการทดลองตามที่ผู้วิจัยกำหนด
- (2) ไม่เป็นผู้ที่มีอาการผิดปกติ หรือเป็นโรคที่เกี่ยวข้องกับขา เท้า และการเดิน
- (3) เป็นผู้ที่มีอายุระหว่าง 20-40 ปี

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของโครงการวิจัยที่ได้รับการรับรองการทำวิจัยในมนุษย์จากคณะกรรมการวิจัยในมนุษย์มหาวิทยาลัยเทคโนโลยีสุรนารี รหัส License EC-64-30 COA No. 67/2564

3.2.2 การเตรียมอุปกรณ์บันทึกสัญญาณการเดิน



รูปที่ 3.1 อุปกรณ์บันทึกสัญญาณการเดินแบบไร้สาย (ก) และบอร์ดไมโครคอนโทรลเลอร์ (ข)

ในงานวิจัยนี้ใช้อุปกรณ์บันทึกสัญญาณการเดินที่มีชื่อว่า Force sensing resistor 402 (FSR 402) ดังแสดงในรูปที่ 3.1 (ก) และอุปกรณ์ที่ใช้สำหรับการประมวลผลบอร์ดไมโครคอนโทรลเลอร์ ESP-WROOM-32 ดังแสดงในรูปที่ 3.1 (ข)

Force sensing resistor 402 มีข้อมูลทางเทคนิคดังนี้

- (1) Sensing Area : Diameter 14.68mm
- (2) Force measure range : 100g ~ 10KG
- (3) Thickness : $\leq 0.3\text{mm}$
- (4) Force repeatable (single part) : $\pm 2.5\%$, 8KG applied, 10 times
- (5) Force repeatable (part to part) : $\pm 20\%$
- (6) Hysteresis : 10% average
- (7) Drift : 5%, 10KG 24hours, logarithmic 10 time
- (8) Off resistance : $2\text{M}\Omega$
- (9) Force resolution : Continuous
- (10) Response time : $< 1\text{ msec}$
- (11) Operating temperature : $-30\text{ }^{\circ}\text{C} \sim 60\text{ }^{\circ}\text{C}$
- (12) Life time : 2 million
- (13) Connector : Female 2.54mm / Male Pin 2.54mm


บอร์ดไมโครคอนโทรลเลอร์ ESP-WROOM-32 มีข้อมูลทางเทคนิคดังนี้

- (1) MCU : Xtensa® Dual-Core 32-bit LX6 600 DMIPS
- (2) Bluetooth : Bluetooth 4.2 and below
- (3) Typical Frequency : 160 MHz
- (4) SRAM : 512 Kbytes
- (5) Flash : SPI Flash, up to 16 Mbytes
- (6) GPIO : 36
- (7) Hardware/Software PWM : 1/16 Channels
- (8) ADC : 12-bit
- (9) Working Temperature : $-40\text{ }^{\circ}\text{C} \sim 125\text{ }^{\circ}\text{C}$

3.2.3 การติดตั้งอุปกรณ์บันทึกสัญญาณการเดิน

การติดตั้งอุปกรณ์บันทึกสัญญาณการเดินใต้ฝ่าเท้านั้นจะทำการติดตั้งให้อยู่ในบริเวณที่กำหนด โดยในแต่ละเฟสของการเดินจะมีการลงน้ำหนักบนฝ่าเท้าที่แตกต่างกันไปในแต่ละเฟสการเดินของมนุษย์ ซึ่งจะสัมพันธ์กับการติดตั้งตำแหน่งของเซนเซอร์ดังนี้

1. Heel Strike (HS) เป็นช่วงการเดินที่ส้นเท้าสัมผัสกับพื้น โดยจะมีการลงน้ำหนักบริเวณส้นเท้ามากกว่าบริเวณอื่นอย่างเห็นได้ชัด โดยครอบคลุมพื้นที่หมายเลข 1 ถึง 3 เราจึงเลือกติดตั้งเซนเซอร์รับแรงกดตัวที่ 1 (S1) ไว้ที่บริเวณส้นเท้า ดังรูปที่ 3.2




รูปที่ 3.2 บริเวณการติดตั้งเซนเซอร์ในเฟสของ Heel strike

2. Foot Flat (FF) เป็นช่วงการเดินหลังจากสิ้นสุดเฟส Heel strike ซึ่งมีการลงน้ำหนักบริเวณส้นเท้ามากกว่าบริเวณอื่น รวมไปถึงบริเวณปลายเท้าเล็กน้อย โดยครอบคลุมพื้นที่หมายเลข 1 ถึง 4 เราจึงเลือกติดตั้งเซนเซอร์รับแรงกดตัวที่ 2 (S2) ไว้บริเวณดังรูปที่ 3.3




รูปที่ 3.3 บริเวณการติดตั้งเซนเซอร์ในเฟสของ Foot flat

3. Midstance (MSt) เป็นช่วงการเดินที่ฝ่าเท้าสัมผัสกับพื้นทั้งหมด โดยจะมีการกระจายน้ำหนักทั่วบริเวณกลางเท้าและปลายเท้าในน้ำหนักที่ใกล้เคียงกัน โดยครอบคลุมพื้นที่หมายเลข 3 ถึง 4 เราจึงเลือกติดตั้งเซนเซอร์รับแรงกดตัวที่ 3 และ 4 (S3-S4) ไว้ที่บริเวณกลางเท้าและปลายเท้า ดังรูปที่ 3.4




รูปที่ 3.4 บริเวณการติดตั้งเซนเซอร์ในเฟสของ Midstance

4. Heel Off (HO) และ Toe Off (TO) เป็นช่วงการเดินที่ปลายเท้าและนิ้วเท้าสัมผัสกับพื้น โดยจะมีการลงน้ำหนักบริเวณปลายเท้ามากกว่าบริเวณอื่นอย่างเห็นได้ชัด โดยครอบคลุมพื้นที่หมายเลข 6 ถึง 15 เราจึงเลือกติดตั้งเซนเซอร์รับแรงกดตัวที่ 5 (S5) ไว้ที่บริเวณปลายเท้า ดังรูปที่ 3.5




รูปที่ 3.5 บริเวณการติดตั้งเซนเซอร์ในเฟสของ Heel off และ Toe off

5. Stand (ST) เป็นท่าทางการยืนตรง โดยจะมีการกระจายน้ำหนักทั่วบริเวณฝ่าเท้า โดยส่วนที่ได้รับแรงมากที่สุดจะเป็นช่วงบริเวณส้นเท้า (พื้นที่หมายเลข 1 ถึง 3) และปลายเท้า (พื้นที่หมายเลข 6 ถึง 10) โดยบริเวณที่ติดตั้งเซ็นเซอร์รับแรงกดตัวที่ 1 ถึง 5 ได้ครอบคลุมพื้นที่ที่ได้รับแรงกดทั้งหมด ดังรูปที่ 3.6




รูปที่ 3.6 บริเวณการติดตั้งเซ็นเซอร์ในท่าทางการยืน Stance

โดยรูปแบบการต่อวงจรของอุปกรณ์บันทึกสัญญาณ จะเป็นดังรูปที่ 3.7 และมีการเพิ่มสัญญาณไฟ LED เพื่อบ่งบอกสถานการณ์การทำงานของอัลกอริทึม รวมถึงแบตเตอรี่เพื่อการทำงานแบบไร้สายให้มีความสะดวกในการสวมใส่และสามารถเดินเก็บค่าการเดินได้ง่ายขึ้น



รูปที่ 3.7 รูปแบบการต่อวงจรของอุปกรณ์บันทึกสัญญาณการเดิน

ซึ่งเมื่อนำมาพัฒนาจริงจะได้อุปกรณ์บันทึกสัญญาณการเดินแบบไร้สาย ดังรูปที่ 3.8



รูปที่ 3.8 อุปกรณ์บันทึกสัญญาณการเดินแบบไร้สาย

3.2.4 การกำหนดรูปแบบท่าทางการเดินให้มีมาตรฐานเดียวกัน


การเดินของมนุษย์แต่ละคนจะมีความแตกต่างกันไปตามความเคยชินของตนเอง เช่น การเดินแบบลากเท้า หรือการเดินแบบย่อ ซึ่งอาจจะทำให้ข้อมูลที่ได้จากการเก็บค่าการเดินนั้นเกิดความผิดพลาดได้ ดังนั้นการกำหนดรูปแบบท่าทางการเดินที่เป็นมาตรฐานเดียวกันจึงเป็นเรื่องที่สำคัญ เพื่อให้แต่ละคนสามารถเดินได้ถูกต้องตามหลักวงจรการเดินของมนุษย์ ดังนี้

ขั้นตอนที่ 1 เริ่มต้นจากการยืนตรง ขาสองข้างเหยียดตรง บริเวณเท้าผ่าเท้าทั้งสองสัมผัสพื้น เตรียมพร้อมในการเดิน ดังรูปที่ 3.9




รูปที่ 3.9 ท่าทางการยืนตรง

ขั้นตอนที่ 2 เมื่อเริ่มเดินจะก้าวเท้าขวาก่อนเสมอ จากนั้นทำการเดินตามวงจรการเดินเป็นขั้นตอน ดังนี้ ขั้นตอนแรกท่าทางของ Heel strike จะอยู่ในลักษณะส้นเท้าแตะพื้น จากนั้นค่อยๆ ถ่ายเท้าหน้าหนักจากส้นเท้าไปยังกลางเท้า นั่นคือเฟสของ Foot flat และ Midstance จากนั้นถ่ายเท้าหน้าหนักไปยังปลายเท้าและนิ้วเท้า นั่นคือ เฟสของ Heel off และ Toe off จากนั้นจะเริ่มเข้าสู่เฟส Swing ปลายเท้าจะยกขึ้นเหนือพื้น จากนั้นจึงวนไปท่าทาง Heel strike อีกรอบหนึ่ง วนซ้ำไปเรื่อย ๆ จนกว่าจะหยุดเดิน โดยในขณะที่เดินจะต้องคำนึงถึงท่าทางการเดินที่ถูกต้องในแต่ละเฟสการเดินด้วย ดังรูปที่ 3.10



รูปที่ 3.10 ลักษณะท่าทางการเดินตามวงจรการเดิน

3.2.5 พัฒนาโปรแกรมเก็บข้อมูลสัญญาณการเดิน



รูปที่ 3.11 โปรแกรมเก็บข้อมูลสัญญาณการเดิน


ภาพรวมของโปรแกรมเก็บข้อมูลสัญญาณการเดิน แสดงในรูปที่ 3.11 โปรแกรมที่เลือกใช้คือโปรแกรม Telemetry Viewer (Version 0.6) โดยโปรแกรมนี้จะทำงานร่วมกับโปรแกรม Arduino IDE ในการเขียนคำสั่งการรับข้อมูลจากเซนเซอร์รับแรงกดทั้ง 5 ตัวที่ติดตั้งอยู่บริเวณใต้ฝ่าเท้า รวมถึงการเขียนคำสั่งให้ส่งข้อมูลแบบไร้สาย (Bluetooth) อีกด้วย โดยเมื่อทำการอัปโหลดคำสั่งที่เกี่ยวข้องต่าง ๆ ลงในบอร์ดไมโครคอนโทรลเลอร์แล้ว โปรแกรม Telemetry Viewer นี้จะทำหน้าที่ในการแสดงผลข้อมูลที่ได้รับมาผ่านหน้าต่างโปรแกรม โดยในการแสดงผลสามารถรองรับการแสดงผลในรูปแบบต่างๆ เพื่อให้มนุษย์สามารถเข้าใจได้ง่าย เช่น รูปแบบของกราฟทางเวลา กราฟทางความถี่ การแสดงผลสามมิติ เป็นต้น โดยโปรแกรมนี้สามารถรองรับการรับข้อมูลที่อัตราเร็ว 100 ข้อมูลต่อวินาที อีกทั้งยังสามารถทำการบันทึกข้อมูลที่ได้รับมาเป็นไฟล์ .CSV อีกด้วย กระบวนการทำงานของโปรแกรมเก็บข้อมูลการเดิน สามารถแบ่งออกเป็น 3 ส่วนหลักดังนี้ 1) เมื่อผู้ทำการทดลองพร้อมที่จะเริ่มต้นเดินให้ทำการกดปุ่ม Connect เพื่อเป็นการเชื่อมต่อระหว่างบอร์ดไมโครคอนโทรลเลอร์และโปรแกรม Telemetry Viewer 2) โปรแกรมจะเริ่มบันทึกสัญญาณการเดินตามข้อมูลที่ได้รับจากเซนเซอร์โดยอัตโนมัติ 3) เมื่อสิ้นสุดการเดินให้ทำการกดปุ่ม Export CSV Log เพื่อเป็นการบันทึกข้อมูลการเดินเป็นไฟล์ .CSV

3.2.6 การเก็บข้อมูลการเดิน

การเก็บข้อมูลการเดินจะดำเนินการด้วยขั้นตอนดังนี้ 1) ให้ผู้ทำการทดลองสวมอุปกรณ์บันทึกสัญญาณการเดินแบบไร้สาย 2) ใช้โปรแกรมเก็บข้อมูลการเดินแบบไร้สายที่พัฒนาขึ้น 3) เริ่มต้นทดลองการเดิน โดยในขั้นตอนแรกผู้ทำการทดลองจะยืนนิ่งเป็นเวลา 10 วินาที ดังรูปที่ 3.12 จากนั้นผู้ทำการทดลองจะเริ่มเดินบนลู่วิ่งไฟฟ้าตามมาตรฐานวงจรการเดินของมนุษย์ นั่นคือ ตั้งแต่เฟส Heel strike, Foot flat, Midstance, Heel off, Toe off จนถึง Swing และเริ่มต้นที่ Heel strike ใหม่อีกครั้ง ดังรูปที่ 3.13 โดยจะเดินที่อัตราเร็วการเดินปกติของมนุษย์ นั่นคือประมาณ 1.39 เมตรต่อนาที หรือประมาณ 5 กิโลเมตรต่อชั่วโมง

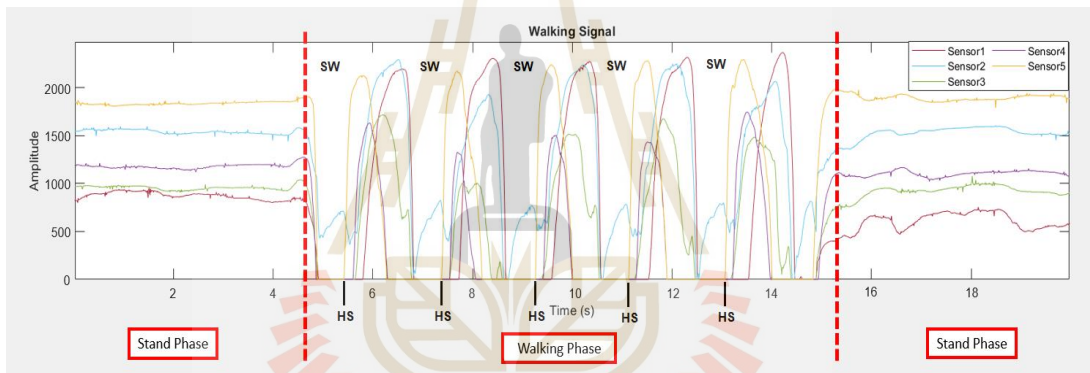


รูปที่ 3.12 ท่าทางการยืนนิ่งบนลู่วิ่งไฟฟ้า



รูปที่ 3.13 การเดินบนลู่วิ่งไฟฟ้าตามมาตรฐานวงจรการเดินของมนุษย์


3.3 การวิเคราะห์ความแตกต่างของสัญญาณการเดิน



รูปที่ 3.14 ตัวอย่างสัญญาณที่ได้จากการเก็บค่าการเดิน


สัญญาณการเดินที่ได้จากการเก็บค่าด้วยอุปกรณ์ไร้สายที่ได้พัฒนาขึ้น แสดงดังรูปที่ 3.14 เส้นสัญญาณสีแดง หมายถึง ค่าของเซนเซอร์รับแรงกดตัวที่ 1 เส้นสัญญาณสีฟ้า หมายถึง ค่าของเซนเซอร์รับแรงกดตัวที่ 2 เส้นสัญญาณสีเขียว หมายถึง ค่าของเซนเซอร์รับแรงกดตัวที่ 3 เส้นสัญญาณสีม่วง หมายถึง ค่าของเซนเซอร์รับแรงกดตัวที่ 4 และเส้นสัญญาณสีเหลือง หมายถึง ค่าของเซนเซอร์รับแรงกดตัวที่ 5 ซึ่งจะเห็นได้ว่าสัญญาณได้นั้นจะแบ่งออกเป็น 2 ช่วงอย่างชัดเจน นั่นคือ ช่วงของการยืนนิ่ง และช่วงของการเดิน ช่วงของการยืนนิ่งนั้นจะมีลักษณะของค่าสัญญาณที่คงที่ เนื่องจากช่วงของการยืนนิ่งจะเป็นช่วงที่ฝ่าเท้าสัมผัสกับพื้นตลอดเวลา และน้ำหนักตัวเกิดการกระจายน้ำหนักไปยังบริเวณต่างๆของฝ่าเท้า แต่ในช่วงของการเดินนั้นสัญญาณเซนเซอร์รับแรงกดทั้ง 5 ตัวจะเปลี่ยนแปลงไปตามน้ำหนักแรงที่ได้รับ และในช่วงเฟสของ Swing (SW) เราจะเห็นได้ว่าค่าสัญญาณเซนเซอร์รับแรงกดจะมีค่าใกล้เคียงศูนย์ หรือเท่ากับศูนย์ เนื่องจากช่วงของการ Swing บริเวณของฝ่าเท้าทั้งหมดนั้นจะไม่มีส่วนใดสัมผัสกับพื้นเลย จึงทำให้ไม่มีแรงจากพื้นมากระทำกับ

เซนเซอร์รับแรงกด ซึ่งสิ่งที่เราต้องการคือการแยกแยะเฟสการเดินทั้งหมด 7 เฟส ได้แก่ Heel strike, Foot flat, Midstance, Heel off, Toe off, Swing และ Stand ดังนั้นเราจึงต้องทำการพิจารณา ช่วงของการยืนนิ่ง และใน 1 ช่วงของการก้าวเดิน นั่นคือตั้งแต่เฟส Heel strike จนถึงเฟส Heel strike ครั้งต่อไปของเท้าข้างเดิม ดังรูปที่ 3.15



รูปที่ 3.15 การพิจารณาสัญญาณที่จะนำไปวิเคราะห์


สำหรับการวิเคราะห์สัญญาณการเดิน เราจะใช้โปรแกรม Matrix laboratory หรือ MATLAB ในการแบ่งส่วนของสัญญาณออกให้เป็น 7 ส่วน หรือก็คือ 7 เฟสการเดินที่เราสนใจ ได้แก่ Stand (ST), Heel strike (HS), Foot flat (FF), Midstance (MSt), Heel off (HO), Toe off (TO) และ Swing (SW) สำหรับเฟส Stand และ Swing จะเห็นได้ว่าสัญญาณทั้งสองจะมีความเป็นเอกลักษณ์ ตามที่กล่าวไปข้างต้น แต่ในช่วงของการก้าวหนึ่งครั้ง (ไม่รวมเฟส Swing) นั่นคือเฟส Heel strike , Foot flat , Midstance , Heel off และ Toe off จะมีความซับซ้อนของสัญญาณข้อมูลทำให้ แยกแยะได้ยาก เพราะฉะนั้นหลังจากเก็บข้อมูลการเดินเรียบร้อยแล้ว เราจำเป็นต้องจัดเรียงข้อมูล ใหม่ โดยจากการทดลองการก้าวหนึ่งครั้ง (ไม่รวมเฟส Swing) จะใช้เวลาประมาณ 1 วินาที ซึ่ง โปรแกรมการเก็บค่าแบบไร้สายที่ได้พัฒนาขึ้นสามารถรับค่าข้อมูลการเดินได้ทั้งหมด 100 ค่า ใน 1 วินาที และเนื่องจากเฟสแต่ละเฟสของการเดินนั้น มีลักษณะที่เรียงกันเป็นวงจรการเดินที่ต่อเนื่องกัน ดังนั้น เราจึงใช้วิธีการแบ่งส่วนของข้อมูลขณะก้าวทั้งหมด 100 ข้อมูล ออกเป็น 5 ส่วนย่อย เพื่อแยก ส่วนข้อมูลให้ได้ข้อมูลตามเฟสที่เราต้องการ ดังรูปที่ 3.16



รูปที่ 3.16 การแบ่งส่วนของข้อมูลขณะก้าว (ไม่รวม Swing phase)

จากนั้นจะนำข้อมูลทั้ง 25 ข้อมูลของแต่ละเฟสนั้นทำการหาค่าเฉลี่ยของข้อมูล (Average data) เพื่อที่จะได้ข้อมูลหนึ่งค่าในแต่ละเฟสของการก้าวหนึ่งครั้ง กล่าวคือ ในการก้าว 1 ครั้ง จะได้ข้อมูลในการเก็บค่าเฟสละ 1 ข้อมูลเท่านั้น

เมื่อนำข้อมูลที่วิเคราะห์มาแสดงผลในรูปแบบของกราฟ จะได้ดังรูปที่ 3.17 ซึ่งจะเห็นได้ว่าการก้าว 1 ครั้ง (ไม่รวม Swing phase) จะได้ข้อมูลของสัญญาณการเดินครบทั้ง 5 เฟสพอดี



รูปที่ 3.17 ตัวอย่างการแบ่งสัญญาณข้อมูลการเดินออกเป็น 7 ส่วนที่ต้องการ

3.4 การตรวจจับเฟสการเดิน

การตรวจจับเฟสการเดินในงานวิจัยนี้จะดำเนินการด้วยการสร้างอัลกอริทึมโดยใช้วิธีการเพื่อนบ้านที่ใกล้ที่สุด k ตัว (k-Nearest Neighbor : kNN) ซึ่งเป็นส่วนหนึ่งของการเรียนรู้ของเครื่องแบบมีผู้สอน ซึ่งการพัฒนาอัลกอริทึมนี้จะใช้โปรแกรม Arduino IDE เป็นโปรแกรมหลักในการพัฒนา โดยมีรายละเอียดดังต่อไปนี้ การจัดเตรียมข้อมูลสัญญาณการเดินเพื่อใช้ในการฝึกฝนการเรียนรู้ของเครื่อง, การสร้างอัลกอริทึม kNN เพื่อตรวจจับเฟสการเดิน, การทดสอบประสิทธิภาพของอัลกอริทึม และการสร้างระบบเปรียบเทียบน้ำหนักเซนเซอร์อัตโนมัติ

3.4.1 การจัดเตรียมข้อมูลการเดิน

ในการบันทึกข้อมูลการเดินหนึ่งรอบ แต่ละเฟสจะได้รับข้อมูลการเดินจำนวน 20 ชุด ข้อมูล รวมเป็น 140 ข้อมูล โดยในแต่ละชุดข้อมูลจะประกอบด้วยค่าเซนเซอร์ตัวที่ 1 ถึง 5 ที่ผ่านการวิเคราะห์จากโปรแกรม MATLAB มาแล้ว ซึ่งจะบันทึกโดยใช้โปรแกรม Excel เพื่อความง่ายต่อการนำไปใช้งาน ดังแสดงในรูปที่ 3.18

1	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q
2	SET	NUMBER	HEEL STRIKE					FOOT FLAT					MID STANCE				
3		R	CH1	CH2	CH3	CH4	CH5	CH1	CH2	CH3	CH4	CH5	CH1	CH2	CH3	CH4	CH5
4		1	0	544	0	0	882	0	640	375	1457	2192	336	1472	1055	1744	2179
5		2	0	425	0	0	1727	0	605	390	1412	2324	0	1585	1251	1824	2205
6		3	0	556	0	0	1382	0	704	573	1417	2325	484	1835	1500	1669	1915
7		4	0	533	0	0	1451	0	720	471	1433	2256	797	2000	1642	1726	1772
8		5	0	509	6	0	2018	15	1061	688	1332	2202	1111	1676	1317	1447	1930
9		6	0	549	81	645	2143	288	1379	1005	1567	2208	1282	1584	1051	1162	1851
10		7	0	400	0	211	1981	0	1556	1228	1697	2185	1478	2085	1581	1153	1153
11		8	0	599	279	590	2232	113	1439	1133	1599	2234	1808	1779	1227	704	1392
12		9	0	793	222	409	2122	214	1171	899	1398	2258	1663	1700	1186	881	1600
13		10	0	592	263	710	2092	0	1302	1002	1532	2317	1060	1337	1040	1226	2151
14		11	0	489	0	71	1992	62	1310	911	1473	2127	1260	1995	1567	1472	1570
15		12	0	657	0	0	645	0	657	386	1003	2081	975	1358	1006	1117	2002
16		13	0	583	51	0	2029	134	1319	954	1483	2226	1467	1857	1393	1244	1546
17		14	0	459	0	0	1660	0	675	635	1248	2231	667	1547	1175	1383	2053
18		15	0	606	62	0	2011	0	1317	1072	1617	2289	577	1749	1470	1631	2019
19		16	0	622	0	0	1205	0	451	270	1007	2139	703	1519	1086	1458	2139
20		17	0	630	0	0	839	0	541	496	1127	2119	471	1457	1136	1413	2151
21		18	0	540	180	415	2066	851	1610	1155	1361	2013	1745	1802	1249	670	1347
22		19	0	496	0	0	1972	0	1073	949	1485	2288	142	1917	1808	1795	1796
23		20	0	672	336	684	2026	810	1242	969	1227	2146	1645	1503	957	608	1649
24		AVG	0	563	74	187	1724	124	1039	778	1394	2208	984	1688	1285	1316	1821

R	S	T	U	V	W	X	Y	Z	AA	AB	AC	AD	AE	AF	AG	AH	AI	AJ	AK
HEEL OFF					TOE OFF					SWING					STAND				
CH1	CH2	CH3	CH4	CH5	CH1	CH2	CH3	CH4	CH5	CH1	CH2	CH3	CH4	CH5	CH1	CH2	CH3	CH4	CH5
1625	1733	1112	1261	1675	2169	1936	905	0	0	0	383	0	0	0	769	1650	975	1374	1774
1561	2000	1424	1263	1413	2222	2117	731	0	0	0	800	0	0	0	832	1649	977	1369	1777
2122	1945	1180	0	563	2346	1952	529	0	0	0	492	0	0	0	806	1648	974	1371	1787
2022	2087	1362	167	411	2239	1833	143	0	0	0	637	0	0	0	877	1663	954	1303	1707
1889	1936	1434	808	1147	2262	1984	637	0	0	0	756	0	0	0	783	1633	932	1333	1754
1935	1871	995	80	894	2304	1856	83	0	0	0	12	0	0	0	732	1634	944	1359	1757
2333	1998	903	0	0	2423	1775	282	0	0	0	264	0	0	0	684	1619	929	1376	1801
2161	2087	1407	0	0	2337	1935	498	0	0	0	410	0	0	0	842	1597	965	1088	1783
2275	1984	1198	0	0	2407	1974	437	0	0	0	564	0	0	0	819	1582	954	1091	1771
2112	1706	1063	80	1071	2349	1890	399	0	0	0	576	0	0	0	880	1609	1085	1104	1785
1879	2150	1717	745	560	2147	2251	1457	0	0	0	505	0	0	0	609	1431	842	1184	1917
1991	1659	967	198	1217	2157	1851	823	0	0	0	363	0	0	0	603	1429	839	1186	1922
2080	2142	1507	0	0	2185	2238	1095	0	0	0	732	0	0	0	608	1429	851	1185	1922
1805	2135	1671	869	779	2153	2251	1509	0	0	0	365	0	0	0	617	1436	849	1184	1923
1661	1825	1392	1052	1488	2134	2032	1262	0	0	5	470	0	0	0	1037	1718	1050	1017	1725
1596	2064	1510	1150	1321	1946	2287	1602	0	0	0	595	0	0	0	1008	1713	1046	1023	1729
2257	2031	1197	0	0	2352	2002	369	0	0	0	645	0	0	0	1002	1734	1046	1030	1735
2074	2000	1245	0	0	2096	2239	703	0	0	0	183	0	0	0	592	1430	921	987	1839
1133	2200	1954	1399	965	1955	2320	1886	0	0	0	676	0	0	0	554	1421	917	1002	1902
2189	1887	1117	0	280	2336	1724	0	0	0	0	799	0	0	0	528	1407	911	1009	1908
1935	1972	1318	454	689	2229	2022	768	0	0	0	508	0	0	0	759	1572	948	1179	1812

รูปที่ 3.18 ตัวอย่างการเก็บบันทึกข้อมูลการเดิน

ในงานวิจัยนี้ มีข้อมูลการเดินที่ทำการบันทึกมีทั้งหมด 700 ข้อมูล โดยจะทำการแบ่งเป็น 2 ส่วน ได้แก่ 1) ส่วนของชุดข้อมูลที่ใช้ในการฝึกสอนการเรียนรู้ของเครื่อง (Training sets) ทั้งหมด 490 ข้อมูล (คิดเป็นร้อยละ 70 ของข้อมูลทั้งหมด) 2) ส่วนของชุดข้อมูลที่ใช้ในการทดสอบประสิทธิภาพโมเดล (Testing sets) ทั้งหมด 210 ข้อมูล (คิดเป็นร้อยละ 30 ของข้อมูลทั้งหมด)

3.4.2 การสร้างอัลกอริทึม kNN เพื่อตรวจจับเฟสการเดิน

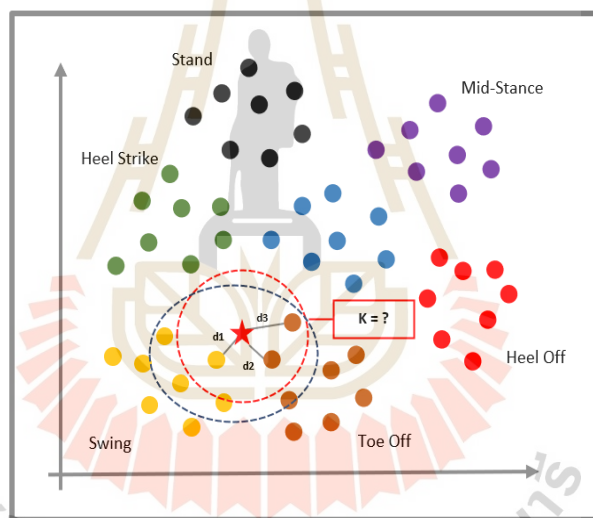
การสร้างอัลกอริทึมตรวจจับเฟสการเดิน โดยใช้วิธีการเพื่อนบ้านที่ใกล้ที่ k ตัว (k-Nearest Neighbor) จะดำเนินการโดยนำชุดข้อมูลการเดินแบบมีป้ายกำกับที่ถูกต้อง (Labeled training data sets) ที่จัดเตรียมไว้ไปทำการฝึกสอนให้กับอัลกอริทึม เพื่อให้อัลกอริทึมเกิดการเรียนรู้จดจำ และสร้างโมเดลในการทำนาย ดังแสดงในรูปที่ 3.19



รูปที่ 3.19 กระบวนการเรียนรู้ของอัลกอริทึม k-Nearest Neighbor


3.4.3 การทดสอบประสิทธิภาพอัลกอริทึม kNN

สำหรับอัลกอริทึม k-Nearest Neighbor ก่อนการทดสอบประสิทธิภาพของอัลกอริทึม จะต้องมีการทดสอบการหาพารามิเตอร์ k ที่เหมาะสมก่อน เนื่องจากพารามิเตอร์ตัวนี้มีผลสำคัญอย่างมาก โดยการใช้ส่วนหนึ่งของชุดข้อมูลการทดสอบเป็นข้อมูลนำเข้าแล้วดูความถูกต้องของการทำนายว่า พารามิเตอร์ k ที่เท่าไรที่ให้ค่าความแม่นยำของอัลกอริทึมสูงที่สุด เราก็จะใช้ค่าพารามิเตอร์นั้นเป็นค่ามาตรฐานของอัลกอริทึม ดังรูปที่ 3.20



รูปที่ 3.20 แบบจำลองการทดสอบหาพารามิเตอร์ k ที่เหมาะสม

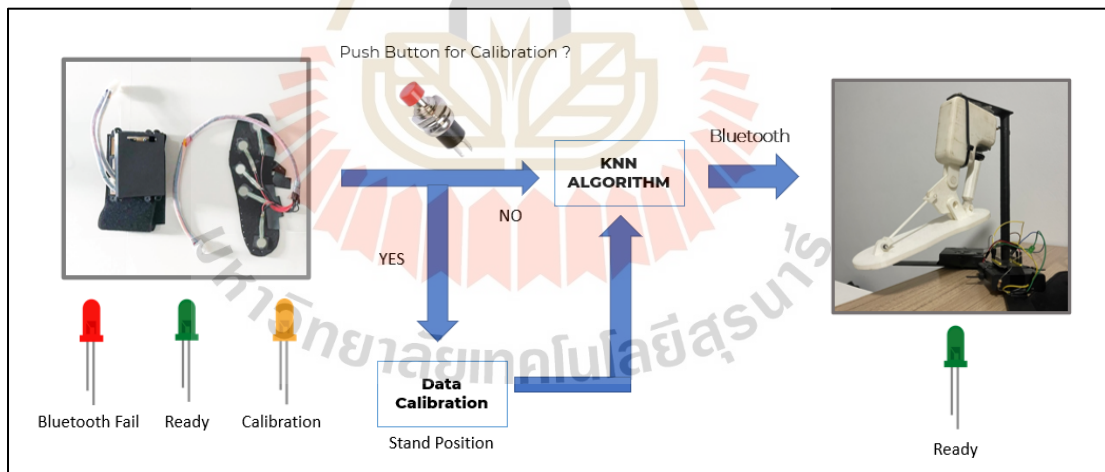
เมื่อเราได้ค่าพารามิเตอร์ k ที่เหมาะสมกับอัลกอริทึมแล้ว ต่อไปจะเป็นขั้นตอนการทดสอบประสิทธิภาพของอัลกอริทึม โดยเราจะนำชุดข้อมูลการเดินแบบไม่มีป้ายกำกับ (Unlabeled testing data sets) หรือก็คือชุดข้อมูลที่อัลกอริทึมไม่เคยเรียนรู้มาก่อนที่จัดเตรียมไว้ไปทำการทดสอบ กระบวนการทดสอบของอัลกอริทึม k-Nearest Neighbor แสดงในรูปที่ 3.21



รูปที่ 3.21 กระบวนการทดสอบของอัลกอริทึม k-Nearest Neighbor

3.4.4 การสร้างระบบปรับเทียบน้ำหนักเซนเซอร์อัตโนมัติ

ในงานวิจัยที่เกี่ยวข้องกับการตรวจจับเฟสการเดินส่วนใหญ่ มักพบเจอปัญหาในเรื่องของลักษณะทางกายภาพของผู้ที่สวมใส่ ยกตัวอย่างเช่น น้ำหนักตัวของผู้ที่สวมใส่ เนื่องจากน้ำหนักตัวนั้นจะส่งผลกระทบต่อค่าน้ำหนักของเซนเซอร์รับแรงกด ทำให้เซนเซอร์รับแรงกดมีค่าน้ำหนักที่เปลี่ยนแปลงไป และอาจทำให้เกิดข้อผิดพลาดในการตรวจจับเฟสการเดินได้ เราจึงได้เพิ่มระบบกดปุ่มเพื่อปรับเทียบน้ำหนักเซนเซอร์โดยอัตโนมัติสำหรับการสวมใส่ของมนุษย์ที่มีน้ำหนักตัวที่แตกต่างกัน โดยทุกครั้งก่อนที่จะเริ่มทำการเดินหรือทำการทดลองการเดินใดๆ ผู้ที่ทำการทดลองจะต้องอยู่ในท่าทางการยืนตรง เพื่อให้เซนเซอร์รับรู้ถึงน้ำหนักที่กระจายบริเวณทั่วฝ่าเท้า จากนั้นกดปุ่มเพื่อทำการปรับเทียบน้ำหนักเซนเซอร์ โดยระบบจะทำการคำนวณด้วยวิธีการทางคณิตศาสตร์เพื่อให้ช่วงค่าข้อมูลของเซนเซอร์ทั้ง 5 ตัวนั้นทำงานอยู่ในช่วงค่ามาตรฐานเดียวกันกับที่ชุดข้อมูลของอัลกอริทึม kNN ได้เรียนรู้ไว้ ซึ่งแผนผังการทำงานของระบบการตรวจจับการเดินพร้อมระบบปรับเทียบน้ำหนักเซนเซอร์รับแรงกดอัตโนมัติสำหรับการควบคุมขาเทียมกล แสดงดังรูปที่ 3.22 นอกจากนี้ยังมีการเพิ่ม LED เพื่อบ่งบอกถึงสถานการณ์ทำงานของอุปกรณ์ ได้แก่ LED สีแดง บ่งบอกถึงสถานการณ์เชื่อมต่อ Bluetooth ไม่สำเร็จ, LED สีเขียว บ่งบอกถึงสถานการณ์เชื่อมต่อ Bluetooth สำเร็จ และ LED สีส้ม บ่งบอกถึงสถานการณ์ปรับเทียบน้ำหนักเซนเซอร์



รูปที่ 3.22 แผนผังการทำงานของระบบการตรวจจับการเดินพร้อมระบบปรับเทียบน้ำหนักเซนเซอร์รับแรงกดอัตโนมัติสำหรับการควบคุมขาเทียมกล

3.5 สรุป

เนื้อหาในบทนี้ได้นำเสนอวิธีการเก็บข้อมูลการเดินโดยใช้อุปกรณ์เก็บข้อมูลการเดินแบบไร้สายที่พัฒนาขึ้น รวมถึงบอกตำแหน่งการติดตั้งเซนเซอร์บริเวณฝ่าเท้า อีกทั้งยังกำหนดมาตรฐานสำหรับการเดินเพื่อให้ผู้ทำการทดลองทุกคนเดินในรูปแบบและท่าทางเดียวกัน ซึ่งข้อมูลการเดินที่ได้จะถูกนำไปวิเคราะห์ และแยกแยะสัญญาณการเดินผ่านโปรแกรม MATLAB โดยจะแบ่งสัญญาณแบ่งออกเป็น 7 เฟส ได้แก่ เฟสของ Stand (ST), Heel strike (HS), Foot flat (FF), Midstance (MSt), Heel off (HO), Toe off (TO) และ Swing (SW) จากนั้นชุดข้อมูลทั้งหมดจะถูกนำไปแบ่งเป็น 2 ส่วน คือ ชุดข้อมูลในการเรียนรู้ เพื่อการสร้างโมเดลการตรวจจับเฟสการเดินของมนุษย์ และชุดข้อมูลในการทดสอบเพื่อนำไปทดสอบประสิทธิภาพของโมเดล นอกจากนี้ยังอธิบายถึงขั้นตอนการสร้างระบบปรับเทียบน้ำหนักของเซนเซอร์โดยอัตโนมัติ หรือ Calibration system


บทที่ 4

ผลการวิจัยและอภิปรายผล

4.1 บทนำ

ในบทนี้จะกล่าวถึงผลการตรวจจับเฟสการเดินของมนุษย์ ด้วยอัลกอริทึม k-Nearest Neighbor ที่พัฒนาขึ้น พร้อมทั้งอภิปรายผลกระทบที่มีผลต่อค่าความแม่นยำในการทำนายผลของอัลกอริทึม ซึ่งจะประกอบด้วย 4 ส่วน ได้แก่ ผลการทดสอบพารามิเตอร์ k ที่มีผลต่อประสิทธิภาพของอัลกอริทึม, ผลแสดงค่าความแม่นยำการตรวจจับเฟสการเดิน, ผลของความเร็วในการเดินที่ส่งผลกระทบต่อค่าความแม่นยำของอัลกอริทึม, ความหน่วงเวลาสำหรับการตรวจจับเฟสการเดิน และการพัฒนาระบบควบคุมขาเทียมกล

4.2 ผลการทดสอบพารามิเตอร์ k ที่มีผลต่อประสิทธิภาพของอัลกอริทึม



รูปที่ 4.1 ผลการทดสอบพารามิเตอร์ k ที่มีผลต่อค่าประสิทธิภาพของอัลกอริทึม

จากรูปที่ 4.1 จะแสดงถึงค่าความแม่นยำในการตรวจจับเฟสการเดินของมนุษย์ โดยใช้ อัลกอริทึม k-Nearest Neighbor ที่แตกต่างกันตามค่าพารามิเตอร์ k ที่เปลี่ยนแปลงไป โดยจากการ ทดสอบในช่วงที่ค่าพารามิเตอร์ k มีค่าเท่ากับ 1 ถึง 32 จะเห็นได้ว่า ค่าความแม่นยำของอัลกอริทึม

มีลักษณะที่สูงต่ำแตกต่างกันไป ซึ่งค่าพารามิเตอร์ k ที่ส่งผลให้มีค่าความแม่นยำในการตรวจจับเฟสการเดินสูงที่สุด 3 อันดับ ได้แก่ ค่าพารามิเตอร์ k เท่ากับ 1 จะได้ค่าความแม่นยำในการตรวจจับเฟสการเดินเท่ากับร้อยละ 80.95 ค่าพารามิเตอร์ k เท่ากับ 3 จะได้ค่าความแม่นยำในการตรวจจับเฟสการเดินเท่ากับร้อยละ 81.43 และ ค่าพารามิเตอร์ k เท่ากับ 17 จะได้ค่าความแม่นยำในการตรวจจับเฟสการเดินเท่ากับร้อยละ 80.57 โดยช่วงหลังจากนั้นจะเห็นได้ว่ายิ่งค่าพารามิเตอร์ k เพิ่มสูงขึ้นมากเท่าไร ค่าความแม่นยำในการทำนายก็จะยิ่งลดต่ำลงมากเท่านั้น ดังนั้นค่าพารามิเตอร์ k ที่เหมาะสมที่สุดในอัลกอริทึม k -Nearest Neighbor ที่พัฒนาขึ้นนี้มีค่าเท่ากับ 3 ซึ่งเราจะกำหนดค่าพารามิเตอร์ k ที่ $k=3$ เป็นมาตรฐานสำหรับอัลกอริทึมนี้

4.3 ผลแสดงค่าความแม่นยำการตรวจจับเฟสการเดิน

ตารางที่ 4.1 ตารางแสดงค่าความแม่นยำการตรวจจับเฟสการเดิน 7 เฟส

Gait Cycle	Precision	Recall	F1-Score	Accuracy (%)
Stand	0.750	0.700	0.724	70.00
Heel Strike	0.875	0.933	0.903	93.34
Foot Flat	0.880	0.733	0.800	73.33
Midstance	0.606	0.667	0.635	66.67
Heel Off	0.846	0.733	0.786	73.33
Toe Off	0.778	0.933	0.848	93.34
Swing	1	1	1	100.00

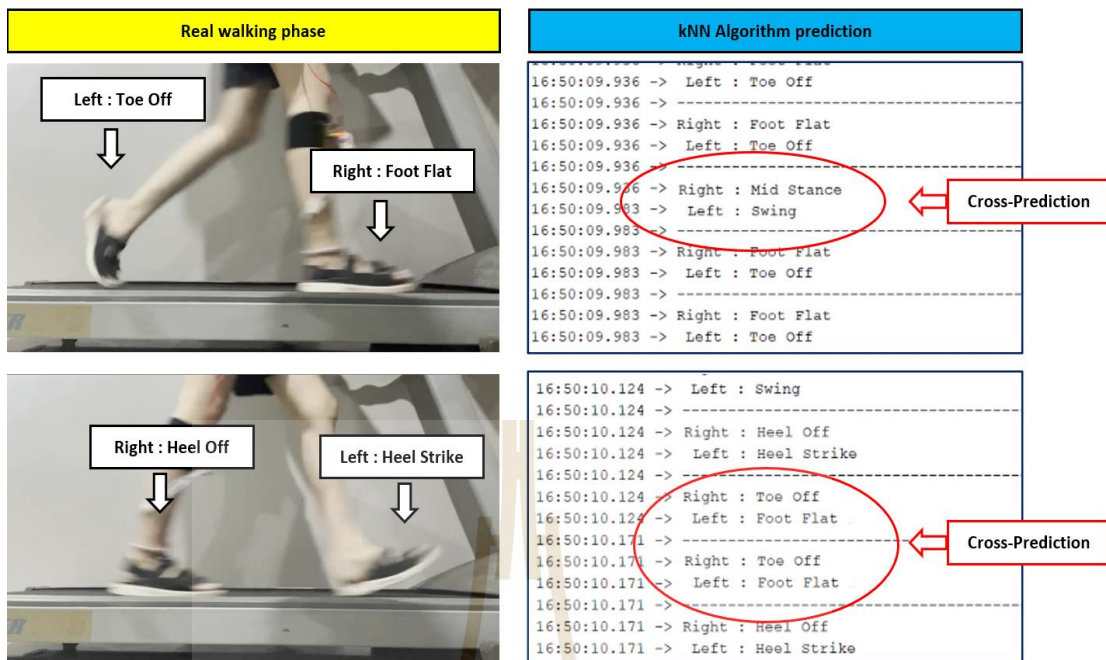
ตารางที่ 4.1 แสดงค่าความแม่นยำของการจำแนกเฟสการเดินทั้งหมด 7 เฟส ได้แก่ Stand (ST), Heel strike (HS), Foot flat (FF), Midstance (MSt), Heel off (HO), Toe off (TO) และ Swing (SW) โดยใช้อัลกอริทึม k NN ที่มีค่าพารามิเตอร์ k เท่ากับ 3 จะเห็นได้ว่าเฟสของการ Swing นั้นมีค่าความแม่นยำในการจำแนกเท่ากับร้อยละ 100 ซึ่งเป็นค่าความแม่นยำในการจำแนกที่สูงมาก เนื่องจากเฟสการ Swing เป็นช่วงที่ทำทางของฝ่าเท้านั้นลอยอยู่บนอากาศ ไม่ได้สัมผัสพื้น จึงทำให้สัญญาณของเซนเซอร์ทั้ง 5 ที่ติดตั้งอยู่บริเวณใต้ฝ่าเท้าไม่มีแรงมากกระทำหรือมีแรงมากกระทำแต่มีค่าน้อยมาก ทำให้เซนเซอร์ทั้ง 5 มีค่าใกล้เคียงศูนย์หรือเท่ากับศูนย์ ($S_1, S_2, S_3, S_4, S_5 \approx 0$) ด้วยเหตุนี้เฟสของการ Swing จึงง่ายต่อการเรียนรู้ และการแยกแยะสัญญาณของอัลกอริทึม

ค่าความแม่นยำในการตรวจจับเฟสการเดินที่สูงเป็นอันดับสอง ได้แก่ เฟสของ Heel strike และ Toe off ทั้งสองเฟสมีค่าความแม่นยำในการจำแนกที่เท่ากัน เท่ากับร้อยละ 93.34 เนื่องจากทั้งสองเฟสนี้มีรูปแบบลักษณะของสัญญาณที่การเดินคล้ายคลึงกัน แต่แตกต่างกันตรงที่รูปแบบของสัญญาณอยู่ในตำแหน่งและเวลาที่ต่างกัน นั่นคือเฟสของ Heel strike จะเป็นช่วงจังหวะที่ส้นเท้าสัมผัสกับพื้น ทำให้เซนเซอร์รับแรงกดตรงบริเวณส่วนของส้นเท้าจะมีค่ามากกว่าเซนเซอร์ตัวอื่นๆที่ติด

ตั้งอยู่บริเวณใต้ฝ่าเท้าอย่างเห็นได้ชัด ($S1 \gg S2, S3, S4, S5$) และในทำนองเดียวกันของเฟส Toe off จะเป็นช่วงการเดินที่ปลายเท้าสัมผัสกับพื้น โดยจะมีการลงน้ำหนักบริเวณปลายเท้ามากกว่าบริเวณอื่น ทำให้เซนเซอร์ตัวที่ 5 มีความแรงของสัญญาณมากกว่าเซนเซอร์ตัวอื่นอย่างเห็นได้ชัด ($S5 \gg S1, S2, S3, S4$)

สำหรับเฟสของ Stand และ Midstance มีค่าความแม่นยำในการทำนายเฟสการเดินเท่ากับร้อยละ 70 และร้อยละ 66.67 ตามลำดับ จะเห็นได้ว่าทั้งสองเฟสนี้มีค่าความแม่นยำในการทำนายที่น้อยที่สุด โดยการจำแนกที่ผิดพลาดของทั้งสองเฟสนี้มาจากการทำนายเฟสสลับกัน เช่นคำตอบของการทำนายที่ถูกต้องคือเฟสของ Midstance แต่อัลกอริทึมกลับทำนายว่าเป็นเฟสของ Stand เนื่องจากทั้งสองเฟสนี้มีลักษณะที่เหมือนกัน ทั้งในเรื่องของลักษณะท่าทางของเท้า ค่ามุมมองขาในการกระดกเท้า และการลงน้ำหนักที่ฝ่าเท้า ซึ่งเป็นการลงน้ำหนักที่ฝ่าเท้ารองรับน้ำหนักร่างกายทั้งหมด โดยจะมีการกระจายน้ำหนักทั่วบริเวณฝ่าเท้า ทำให้เซนเซอร์ทั้ง 5 ได้รับแรงกดที่ใกล้เคียงกัน ($S1 \approx S2 \approx S3 \approx S4 \approx S5$) ด้วยเหตุนี้จึงเป็นเรื่องยากสำหรับการเรียนรู้และการแยกแยะความแตกต่างของสัญญาณทั้งสองเฟสนี้ออกจากกัน อย่างไรก็ตามทั้งสองเฟสนี้มีค่ามุมมองขาในการกระดกเท้า และลักษณะท่าทางของเท้าที่เหมือนกัน ทำให้ไม่ส่งผลกระทบต่อการใช้งานอัลกอริทึมนี้ไปใช้งานกับการควบคุมเท้าเทียมกล

สุดท้ายคือเฟสของ Foot flat และ Heel off ทั้งสองเฟสนี้มีค่าความแม่นยำในการทำนายที่เท่ากัน เท่ากับร้อยละ 73.33 โดยการทำนายที่ผิดพลาดของทั้งสองเฟสนี้ส่วนใหญ่จะเป็นในเรื่องของการทำนายข้ามเฟส หรือ Cross-phase prediction หมายถึงการทำนายเฟสการเดินเร็วกว่าเฟสการเดินจริงไปหนึ่งเฟส โดยการทำนายข้ามเฟสนี้มักจะเกิดกับเฟสของ Foot flat และ Heel off ยกตัวอย่างเช่น ณ ตอนนี้อยู่ในเฟสของ Heel strike เฟสต่อไปที่อัลกอริทึมควรที่จะทำนายได้คือเฟสของ Foot flat แต่อัลกอริทึมไปทำนายว่าเป็น Midstance แทน และ ณ ตอนนี้อยู่ในเฟสของ Midstance เฟสต่อไปที่อัลกอริทึมควรที่จะทำนายได้คือเฟสของ Heel off แต่อัลกอริทึมไปทำนายว่าเป็น Toe off แทน ดังรูปที่ 4.2

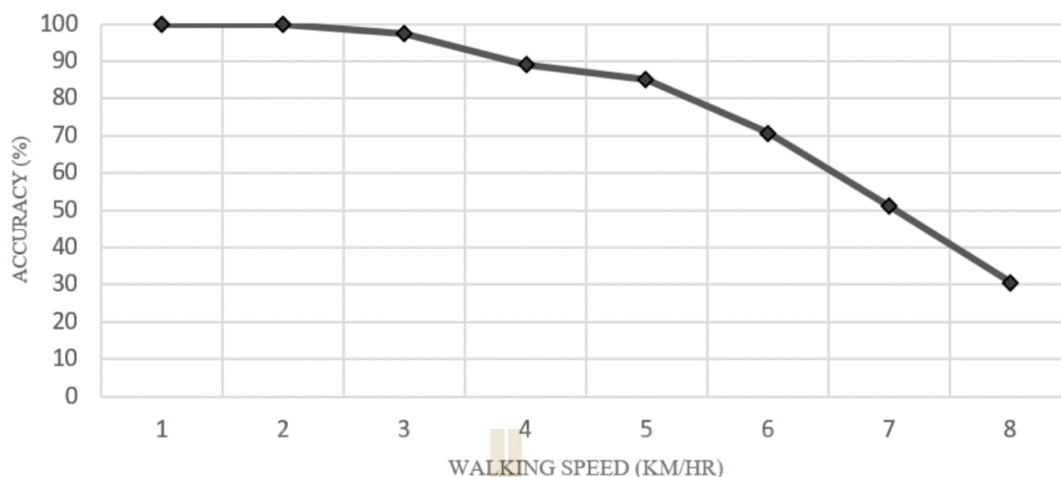


รูปที่ 4.2 ตัวอย่างการทำนายข้ามเฟส หรือ Cross-phase prediction

4.4 ผลของความเร็วในการเดินที่ส่งผลกระทบต่อค่าความแม่นยำของอัลกอริทึม

ในการทดสอบความเร็วของการเดินที่ส่งผลต่อค่าความแม่นยำในการทำนายเฟสการเดินนั้น เราดำเนินการโดยให้ผู้ทำการทดลองเดินบนลู่วิ่งไฟฟ้า ด้วยความเร็วตั้งแต่ 1 ถึง 8 กิโลเมตรต่อชั่วโมง ซึ่งจากกราฟแสดงผลของความเร็วในการเดินที่ส่งผลกระทบต่อค่าความแม่นยำของอัลกอริทึม ดังรูปที่ 4.3 จะเห็นได้อย่างชัดเจนว่าความเร็วในการเดินที่เพิ่มขึ้น จะทำให้ค่าความแม่นยำในการจำแนกเฟสการเดินลดต่ำลง โดยความเร็วในการทดลองการเดินจะแบ่งออกเป็น 3 ช่วง ได้แก่

1. ช่วงการเดินช้า หรือ Slow walking (1~2 กิโลเมตรต่อชั่วโมง)
2. ช่วงการเดินปกติ หรือ Normal walking (3~5 กิโลเมตรต่อชั่วโมง)
3. ช่วงการเดินเร็ว หรือ Fast walking (6~8 กิโลเมตรต่อชั่วโมง)




รูปที่ 4.3 กราฟแสดงผลของความเร็วในการเดินที่ส่งผลกระทบต่อค่าความแม่นยำของอัลกอริทึม

ช่วงการเดินช้า หรือ Slow walking จะมีค่าความแม่นยำในการจำแนกเฟสการเดินที่สูงมาก ประมาณร้อยละ 90.00 ~ 100.00 เนื่องจากการเดินด้วยความเร็วที่ช้าจะส่งผลให้การเปลี่ยนเฟสในการเดินนั้นช้าลงด้วย ทำให้เซนเซอร์รับแรงกดได้ฝ่าเท้าสามารถรับค่าสัญญาณการเดินได้อย่างเต็มที่ ซึ่งจะช่วยให้อัลกอริทึมสามารถทำงานได้อย่างมีประสิทธิภาพ ช่วงการเดินปกติ หรือ Normal walking จะมีค่าความแม่นยำในการจำแนกเฟสการเดินที่สูงกว่าช่วงการเดินเร็วแต่น้อยกว่าช่วงการเดินช้าเล็กน้อย นั่นคืออยู่ในช่วงประมาณร้อยละ 85.14 ถึง 97.43 สำหรับช่วงของการเดินเร็ว หรือ Fast walking จะมีค่าความแม่นยำในการจำแนกเฟสการเดินน้อยกว่าทั้งสองแบบนี้คืออยู่ในช่วงประมาณร้อยละ 30.71 ถึง 70.81 เนื่องจากการเดินที่เร็วขึ้นจะยิ่งทำให้เกิดการผิดพลาดในการจำแนกเฟสการเดินที่มากขึ้น เช่นการทำนายข้ามเฟส หรือ Cross-phase prediction เป็นต้น ซึ่งในงานวิจัยของเรามีขอบเขตในการใช้งานอยู่ที่ความเร็วในการเดินปกติของมนุษย์ หรือประมาณ 5 กิโลเมตรต่อชั่วโมงเท่านั้น


4.5 ความหน่วงเวลาสำหรับการตรวจจับเฟสการเดิน

สำหรับความหน่วงเวลาขณะการตรวจจับเฟสการเดินในแต่ละเฟส จะแสดงดังรูปที่ 4.4 ซึ่งช่วงเวลาการเดินจริงกับช่วงเวลาการตรวจจับแต่ละเฟสที่ทำนายได้โดยเฉลี่ยจะมีความหน่วงเวลาเท่ากับ 15 ± 2 มิลลิวินาทีเท่านั้น ซึ่งเป็นค่าความหน่วงเวลาที่น้อยมาก



รูปที่ 4.4 กราฟแสดงผลความหน่วงเวลาสำหรับการตรวจจับเฟสการเดิน


4.6 การพัฒนาระบบควบคุมขาเทียมกล



รูปที่ 4.5 การออกแบบระบบการควบคุมขาเทียมกล

สำหรับขาเทียมกลที่นำมาพัฒนาจะมีการออกแบบระบบการควบคุมไว้ดังรูปที่ 4.5 โดยขาเทียมกลจะมี Servo เป็นอุปกรณ์หลักในการควบคุมมอเตอร์และขับเคลื่อนขากล ซึ่งสามารถควบคุมการหมุนได้ตั้งแต่ 0-180 องศา โดยความสามารถในการควบคุมการหมุนของ Servo นี้สามารถนำมาประยุกต์ใช้กับการควบคุมองศาการขยับของข้อเท้าที่แตกต่างกันไปในแต่ละเฟสการเดินได้ โดยจะเห็นได้ว่าการหมุนของ Servo ที่ 0 องศา คือท่าทางของ Heel strike, 45 องศา คือท่าทางของ Foot flat, 90 องศา คือท่าทางของ Swing, Midstance และ Stand, 135 องศา คือท่าทางของ Heel off และ 180 องศา คือท่าทางของ Toe off โดยในการทดลองนี้จะทำการสวมใส่อุปกรณ์ที่เท้าด้านขวา ทำหน้าที่ควบคุมขาเทียมกลให้ขยับตามท่าทางเท้าด้านซ้าย ดังนี้

1. เท้าขวาท่าทาง Heel off และเท้าซ้ายท่าทาง Heel strike




รูปที่ 4.6 ผลการควบคุมขาเทียมกล เท้าขวาท่าทาง Heel off และเท้าซ้ายท่าทาง Heel strike

2. เท้าขวาท่าทาง Toe off และเท้าซ้ายท่าทาง Foot flat



รูปที่ 4.7 ผลการควบคุมขาเทียมกล เท้าขวาท่าทาง Toe off และเท้าซ้ายท่าทาง Foot flat

3. เท้าขวาท่าทาง Swing และเท้าซ้ายท่าทาง Midstance




รูปที่ 4.8 ผลการควบคุมขาเทียมกล เท้าขวาท่าทาง Swing และเท้าซ้ายท่าทาง Midstance

4. เท้าขวาท่าทาง Heel strike และเท้าซ้ายท่าทาง Heel off



รูปที่ 4.9 ผลการควบคุมขาเทียมกล เท้าขวาท่าทาง Heel strike และเท้าซ้ายท่าทาง Heel off

5. เท้าขวาท่าทาง Foot flat และเท้าซ้ายท่าทาง Toe off



รูปที่ 4.10 ผลการควบคุมขาเทียมกล เท้าขวาท่าทาง Foot flat และเท้าซ้ายท่าทาง Toe off

6. เท้าขวาท่าทาง Midstance และเท้าซ้ายท่าทาง Swing



รูปที่ 4.11 ผลการควบคุมขาเทียมกล เท้าขวาท่าทาง Midstance และเท้าซ้ายท่าทาง Swing

7. เท้าขวา และเท้าซ้ายท่าทาง Stand



รูปที่ 4.12 ผลการควบคุมขาเทียมกล เท้าขวา และเท้าซ้ายท่าทาง Stand

จากผลการทดลองจะเห็นได้ว่าเมื่อนำอัลกอริทึมการทำนายเฟสการเดินมาประยุกต์ร่วมกับการควบคุมขาเทียมกล จะสามารถควบคุมขาเทียมกลให้สามารถขยับตามเฟสการเดินของมนุษย์ได้จริง โดยมีค่าความหน่วงเวลาเฉลี่ยของแต่ละเฟสการเดินเท่ากับ 15 ± 2 มิลลิวินาทีเท่านั้น

บทที่ 5

สรุปผลการวิจัยและข้อเสนอแนะ

5.1 สรุปผลการวิจัย

ผู้พิการทางด้าน การเคลื่อนไหว โดยเฉพาะผู้ที่พิการทางขา จะมีความยากลำบากอย่างมากในการใช้ชีวิตประจำวัน เนื่องจากสูญเสียอวัยวะสำคัญที่ช่วยในการเคลื่อนที่ไป จึงได้มีการพัฒนาขาเทียม (Prosthetic leg) ขึ้นมาเพื่อจะนำมาช่วยทดแทนกับขาจริงที่สูญเสียไป แต่ขาเทียมในปัจจุบันนั้นก็ยังพบเจอปัญหาด้านการใช้งานเช่น ขาเทียมมีน้ำหนักเยอะ การสวมใส่ขาเทียมมีความลำบาก จำเป็นต้องมีคนช่วยพุงขณะสวมใส่หรือเดิน มีอาการเจ็บขณะสวมใส่ และสิ่งที่เป็นปัญหาหลักๆ และสำคัญที่สุดของขาเทียม คือ ขาเทียมเป็นแค่เครื่องมือที่ช่วยในการพุงและค้ำยันเท่านั้น แต่ไม่ได้ช่วยในเรื่องของการที่จะทำให้ผู้พิการเดินได้ง่ายขึ้น เนื่องจากตรงส่วนของบริเวณข้อเท้าของขาเทียมไม่สามารถขยับได้ตามการเดินจริงของมนุษย์ ทำให้ผู้พิการที่สวมใส่ขาเทียมนั้นเดินได้อย่างไม่เป็นธรรมชาติ ซึ่งจากการทบทวนวรรณกรรมในช่วงไม่กี่ปีที่ผ่านมาพบว่ามีหลายงานวิจัยในการพัฒนาเทคโนโลยีขาเทียมกลเพื่อช่วยเหลือผู้พิการทางขา ซึ่งหนึ่งในเทคโนโลยีที่ได้รับความนิยมและเป็นที่น่าสนใจ คือ เทคโนโลยีการควบคุมขาเทียมกลอัตโนมัติ โดยใช้อุปกรณ์หรือสัญญาณเซนเซอร์ต่างๆ ในการตรวจจับเฟสการเดิน (Gait phase detection) ของมนุษย์ เพื่อให้อัลกอริทึมสามารถทำนายเฟสการเดินในปัจจุบันและอนาคตได้ โดยเทคโนโลยีเหล่านี้ล้วนมีจุดมุ่งหมายในการเพิ่มความสามารถในการควบคุมขาเทียมกล และช่วยให้ผู้พิการทางขาสามารถเคลื่อนไหวได้อย่างราบรื่นมากยิ่งขึ้น ซึ่งอย่างไรก็ตามระบบการตรวจจับเฟสการเดินด้วยการใช้วิธีการต่างๆดังที่กล่าวมาข้างต้น ยังคงพบเจอปัญหา เช่น ปัญหาในเรื่องของสัญญาณรบกวน การทำนายที่ผิดพลาด การหน่วงเวลาในการควบคุมขาเทียมกล ความเร็วในการเดิน และปัญหาที่สำคัญที่สุดที่นั่นคือ ปัญหาในเรื่องของลักษณะทางกายภาพของผู้ที่สวมใส่อุปกรณ์ เช่น น้ำหนักตัวของผู้ที่สวมใส่ ทำให้การตรวจจับเฟสการเดินผิดพลาดไป ดังนั้นในงานวิจัยนี้จึงเสนอแนวทางใหม่สำหรับการตรวจจับเฟสการเดิน โดยการพัฒนาอุปกรณ์การเดินไร้สายร่วมกับอัลกอริทึม k-Nearest Neighbor (kNN) ให้สามารถทำนายการเดินในเฟสต่างๆทั้งหมด 7 เฟสได้ ได้แก่ เฟสของ Stand (ST), Heel strike (HS), Foot flat (FF), Midstance (MSt), Heel off (HO), Toe off (TO) และ Swing (SW) ซึ่งอุปกรณ์ที่พัฒนาขึ้นนี้สามารถสวมใส่ได้โดยไม่มีปัญหาในเรื่องของลักษณะทางกายภาพของผู้สวมใส่ โดยได้เพิ่มระบบกดปุ่มเพื่อปรับเทียบน้ำหนักเซนเซอร์โดยอัตโนมัติสำหรับการสวมใส่ของมนุษย์ที่มีน้ำหนักตัวที่แตกต่างกัน โดยผลการวิจัยพบว่า

อัลกอริทึมสามารถตรวจจับเฟสการเดินของมนุษย์ได้ครบทั้งหมด 7 เฟส โดยมีค่าความแม่นยำในการตรวจจับถึง 81.43 เปอร์เซ็นต์ สามารถรองรับการเดินด้วยความเร็วปกติของมนุษย์ได้ อีกทั้งอุปกรณ์การเดินยังเป็นอุปกรณ์ไร้สายซึ่งมีค่าความหน่วงเวลาการทำนายแต่ละเฟสเพียงแค่ 15 ± 2 มิลลิวินาทีเท่านั้น รวมถึงเมื่อนำอัลกอริทึมการทำนายเฟสการเดินมาประยุกต์ร่วมกับการควบคุมขาเทียมกล จะสามารถควบคุมขาเทียมกลให้สามารถขยับตามเฟสการเดินของมนุษย์ได้จริง

5.2 ข้อเสนอแนะและแนวทางการพัฒนาในอนาคต

วิทยานิพนธ์ฉบับนี้ได้นำเสนอแนวทางใหม่สำหรับการตรวจจับเฟสการเดิน โดยการพัฒนาอุปกรณ์การเดินไร้สายร่วมกับอัลกอริทึม k-Nearest Neighbor (kNN) ให้สามารถตรวจจับเฟสการเดินทั้งหมด 7 เฟสได้ ซึ่งการพัฒนาต่อยอดในอนาคตอาจจะนำเสนอแนวทางใหม่ๆ ในการตรวจจับเฟสการเดินของมนุษย์ โดยใช้อัลกอริทึมที่แตกต่างกันไปเพื่อเพิ่มความแม่นยำในการตรวจจับเฟสการเดิน อีกทั้งในด้านของอุปกรณ์ที่ต้องสวมใส่สามารถพัฒนาให้มีขนาดเล็ก และกะทัดรัดมากกว่านี้ ซึ่งผู้วิจัยหวังว่าวิทยานิพนธ์ฉบับนี้จะเป็นประโยชน์แก่ผู้ที่สนใจ

รายการอ้างอิง

- Alahakone, A.U., Senanayake, S.M.N.A., & Senanayake, C.M. (2010). Smart wearable device for real time gait event detection during running. *Proceedings of the 2010 IEEE Asia Pacific Conference on Circuits and Systems* (pp. 612–615). Kuala Lumpur, Malaysia.
- Alaqtash, M., Sarkodie-Gyan, T., Yu, H., Fuentes, O., Brower, R., & Abdelgawad, A. (2011). Automatic classification of pathological gait patterns using ground reaction forces and machine learning algorithms. *Proceedings of the 2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society* (pp. 453–457). Boston, MA, USA.
- Aqueveque, P., Osorio, R., Pastene, F., Saavedra, F., & Pino, E. (2018). Capacitive Sensors Array for Plantar Pressure Measurement Insole fabricated with Flexible PCB. *Proceedings of the 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (pp. 4393–4396) . Honolulu, HI, USA.
- Benbakhti, A. S., Boukhenous, S., Zizoua, C., & Attari, M. (2014). An instrumented shoe for ambulatory prevention of diabetic foot ulceration. *Proceedings of the 2014 4th International Conference on Wireless Mobile Communication and Healthcare—Transforming Healthcare through Innovations in Mobile and Wireless Technologies (MOBIHEALTH)* (pp. 43–46) . Athens, Greece. 3–5 November 2014,
- Chakraborty, S., & Nandy, A. (2020). An Unsupervised Approach For Gait Phase Detection. *Proceedings of the 2020 4th International Conference on Computational Intelligence and Networks (CINE)* (pp. 1–5). Kolkata, India.
- Han, Y.C., Wong, K.I., & Murray, I. (2019). Gait Phase Detection for Normal and Abnormal Gaits Using IMU. *IEEE Sens. J.*, 19, 3439–3448.

- Hu, Y., Li, X., & Liu, Q. (2019). Design and Research of Gait Recognition Method of Upper Knee Prosthesis Based on kNN Algorithm. *Proceedings of the 2019 4th International Conference on Robotics, Control and Automation (ICRCA 2019)*, Association for Computing Machinery (pp. 173–177). New York, USA.
- Huang, B., Chen, M., Shi, X., & Xu, Y. (2007). Gait Event Detection with Intelligent Shoes. *Proceedings of the 2007 International Conference on Information Acquisition* (pp. 579–584). Seogwipo, Korea.
- Huang, H., Zhou, P., & Li, Y., Sun, F. (2021). A Lightweight Attention-Based CNN Model for Efficient Gait Recognition with Wearable IMU Sensors. *Sensors*, 21, 2866.
- Jasni, F., Hamzaid, N.A., Al-Nusairi, T.Y., Yusof, N.H.M., & Shasmin, H.N., Ng, S. (2019). Feasibility of a Gait Phase Identification Tool for Transfemoral Amputees Using Piezoelectric—Based In-Socket Sensory System. *IEEE Sens. J.*, 19, 6437–6444.
- Jumphoo, T., Uthansakul, M., & Uthansakul, P. (2019). Brainwave classification without the help of limb movement and any stimulus for character-writing application. *Cogn. Syst. Res.*, 58, 375–386.
- Jumphoo, T., Uthansakul, M., Duangmanee, P., Khan, N., & Uthansakul, P. (2020). Soft Robotic Glove Controlling Using Brainwave Detection for Continuous Rehabilitation at Home. *Comput. Mater. Contin.*, 66, 961–976.
- Kokkhunthod, K., Jumphoo, T., & Uthansakul, P. (2020). Improving brainwave classification for character-writing application using single effective EEG channel in SUT. *Proceedings of the International Virtual Conference on Science and Technology* (pp. 142–148). Nakhon Ratchasima, Thailand.
- Ledoux, E.D. (2018). Inertial Sensing for Gait Event Detection and Transfemoral Prosthesis Control Strategy. *IEEE Trans. Biomed. Eng.*, 65, 2704–2712.
- Mahoney, J.M., & Rhudy, M.B. (2019). Methodology and validation for identifying gait type using machine learning on IMU data. *J. Med. Eng. Technol*, 43, 25–32.

- Malešević, N., Malešević, J., & Keller, T. (2014). Gait phase detection optimization based on variational bayesian inference of feedback sensor signal. *Proceedings of the 12th Symposium on Neural Network Applications in Electrical Engineering (NEUREL)* (pp. 179–182). Belgrade, Serbia.
- Nagashima, M., Cho, S.-G., Ding, M., Ricardez, G.A.G., Takamatsu, J., & Ogasawara, T. (2019). Prediction of Plantar Forces During Gait Using Wearable Sensors and Deep Neural Networks. *Proceedings of the 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (pp. 3629–3632). Berlin, Germany.
- Park, J.S., Lee, C.M., Koo, S.-M., & Kim, C.H. (2020). Gait Phase Detection Using Force Sensing Resistors. *IEEE Sens. J.*, *20*, 6516–6523.
- Phapatanaburi, K., Kokkhunthod, K., Wang, L., Jumphoo, T., Uthansakul, M., Boonmahitthisud, A., & Uthansakul, P. (2021). Brainwave Classification for Character-Writing Application using EMD-based GMM and KELM approaches. *Comput. Mater. Contin.*, *66*, 3029–3044.
- Pogorelc, B., Bosnić, Z., & Gams, M. (2011). Automatic recognition of gait-related health problems in the elderly using machine learning. *Multimed. Tools Appl.*, *58*, 333–354.
- Prado, A., Cao, X., Ding, X., & Agrawal, S.K. (2020). Prediction of Gait Cycle Percentage Using Instrumented Shoes with Artificial Neural Networks. *Proceedings of the 2020 IEEE International Conference on Robotics and Automation (ICRA)* (pp. 2834–2840). Paris, France.
- Prakash, C., Kumar, R., & Mittal, N. (2016). Automated detection of human gait events from conventional videography. *Proceedings of the 2016 International Conference on Emerging Trends in Communication Technologies (ETCT)* (pp. 1–4). Dehradun, India.

- Senanayake, C.M., & Senanayake, S.M.N.A. (2010). Computational Intelligent Gait-Phase Detection System to Identify Pathological Gait. *IEEE Trans. Inf. Technol. Biomed.*, 14, 1173–1179.
- Shaikh, M.F., Salcic, Z., & Wang, K. (2015). Analysis and selection of the Force Sensitive Resistors for gait characterisation. *Proceedings of the 2015 6th International Conference on Automation, Robotics and Applications (ICARA)* (pp. 370–375). Queenstown, New Zealand.
- Varol, H.A., & Goldfarb, M. (2007). Real-time Intent Recognition for a Powered Knee and Ankle Transfemoral Prosthesis. *Proceedings of the 2007 IEEE 10th International Conference on Rehabilitation Robotics* (pp. 16–23). Noordwijk, The Netherlands.
- Wafai L, Zayegh A, Woulfe J, & Aziz SM, Begg R. (2015). Identification of Foot Pathologies Based on Plantar Pressure Asymmetry. *Sensors (Basel)*, 15(8), 20392-408.
- Wu, C.-C., Wen, Y.-T., & Lee, Y.-J. (2020). IMU sensors beneath walking surface for ground reaction force prediction in gait. *IEEE Sens. J.*, 20, 9372–9376.
- Zhao, H., Wang, Z., Qiu, S., Shen, Y., & Wang, J. (2017). IMU-based gait analysis for rehabilitation assessment of patients with gait disorders. *Proceedings of the 2017 4th International Conference on Systems and Informatics (ICSAI)* (pp. 622–626). Hangzhou, China.
- Zhao, Z., Chen, W., Yixin, Z., Pinghua, A., & Wang, J. (2020). A Wireless Foot Plantar Pressure Distribution Measurement System and Its Application in Gait Analysis. *Proceedings of the 2020 Chinese Control and Decision Conference (CCDC)* (pp. 1397–1402). Hefei, China.



ภาคผนวก

บทความวิชาการที่ได้รับการตีพิมพ์เผยแพร่ในระหว่างการศึกษา

มหาวิทยาลัยเทคโนโลยีสุรนารี

รายชื่อบทความวิชาการที่ได้รับการตีพิมพ์เผยแพร่ระหว่างการศึกษา

Rattanasak, A., Uthansakul, P., Uthansakul, M., Jumphoo, T., Phapatanaburi, K., Sindhupakorn, B., & Rooppakhun, S. (2022). Real-Time Gait Phase Detection Using Wearable Sensors for Transtibial Prosthesis Based on a kNN Algorithm. *Sensors*, 22, 4242



Article

Real-Time Gait Phase Detection Using Wearable Sensors for Transtibial Prosthesis Based on a kNN Algorithm

Atcharawan Rattanasak ¹, Peerapong Uthansakul ^{1,*}, Monthippa Uthansakul ¹, Talit Jumphoo ¹, Khomdet Phapatanaburi ², Bura Sindhupakorn ³ and Supakit Rooppakhun ⁴

¹ School of Telecommunication Engineering, Institute of Engineering, Suranaree University of Technology, Nakhon Ratchasima 30000, Thailand; m6303129@g.sut.ac.th (A.R.); mtp@sut.ac.th (M.U.); drivilmiz@gmail.com (T.J.)

² Department of Telecommunication Engineering, Faculty of Engineering and Technology, Rajamangala University of Technology Isan (RMUTI), Nakhon Ratchasima 30000, Thailand; khomdet.ph@rmuti.ac.th

³ Orthopedic Department, School of Medicine, Suranaree University of Technology, Nakhon Ratchasima 30000, Thailand; bura@sut.ac.th

⁴ School of Mechanical Engineering, Institute of Engineering, Suranaree University of Technology, Nakhon Ratchasima 30000, Thailand; supakit@sut.ac.th

* Correspondence: uthansakul@sut.ac.th; Tel.: +66-850865588



Citation: Rattanasak, A.; Uthansakul, P.; Uthansakul, M.; Jumphoo, T.; Phapatanaburi, K.; Sindhupakorn, B.; Rooppakhun, S. Real-Time Gait Phase Detection Using Wearable Sensors for Transtibial Prosthesis Based on a kNN Algorithm. *Sensors* **2022**, *22*, 4242. <https://doi.org/10.3390/s22114242>

Academic Editor: Lorenzo Scalise

Received: 3 May 2022

Accepted: 31 May 2022

Published: 2 June 2022

Publisher's Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



Copyright: © 2022 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

Abstract: Those with disabilities who have lost their legs must use a prosthesis to walk. However, traditional prostheses have the disadvantage of being unable to move and support the human gait because there are no mechanisms or algorithms to control them. This makes it difficult for the wearer to walk. To overcome this problem, we developed an insole device with a wearable sensor for real-time gait phase detection based on the kNN (k-nearest neighbor) algorithm for prosthetic control. The kNN algorithm is used with the raw data obtained from the pressure sensors in the insole to predict seven walking phases, i.e., stand, heel strike, foot flat, midstance, heel off, toe-off, and swing. As a result, the predictive decision in each gait cycle to control the ankle movement of the transtibial prosthesis improves with each walk. The results in this study can provide 81.43% accuracy for gait phase detection, and can control the transtibial prosthetic effectively at the maximum walking speed of 6 km/h. Moreover, this insole device is small, lightweight and unaffected by the physical factors of the wearer.

Keywords: k-nearest neighbor; wearable sensor; gait analysis; gait phase detection; transtibial prosthesis

1. Introduction

Gait analysis is widely known and researched because it has benefits in many fields. For example, in the medical field, gait analysis is often used to look for various diseases caused by walking disorders [1,2]. In addition, the engineering field can be used to analyze human leg and foot locomotion to detect the gait phase and improve prostheses' performance [3]. There are two essential things in gait phase detection. The first thing is a method of collecting gait information, and the second thing is a method used to identify the gait phase.

Gait phase detection based on a vision system is a method that uses a camera to analyze body movements during walking. In general, a camera is used to measure the characteristics of hip, knee, and ankle angles. In addition, a vision system is usually used with the force plates to increase the efficiency of detecting the gait phase. Varol et al. presented a study on controlling a transfemoral prosthesis using a kNN algorithm with a predominant weighting scheme and a weighting threshold, using seven cameras and two force platforms. The two force plates measured the ground reaction force to increase the effectiveness of real-time recognition of a person's walking intent who would stand or walk at one of three different speeds, including slow (~1.04 m/s), normal (~1.22 m/s), and

fast (~1.51 m/s) [3]. However, this method is only required in a laboratory or controlled environment, so it is unable to be used in daily life. Therefore, detecting the gait phase should be performed with a wearable device that can easily detect the walking distance.

A wearable device uses an inertial measurement unit (IMU) [4–7]. There are many techniques for IMU usage [4]: Huang et al. presented a lightweight convolutional neural network (CNN) model with an attention mechanism for detecting gait characteristics using wearable IMU sensors [5]. In addition, Mahoney et al. presented an artificial neural network (ANN) model that classifies the type of stride with an accelerometer and gyroscope (IMU) affixed to the user's left ankle [6]. Furthermore, Wu et al. demonstrated the feasibility of predicting ground reaction force by using IMU sensors mounted below the walking surface with long short-term memory (LSTM) models [7]. However, errors will occur when using an IMU with speed and location data due to interference and signal drift. Additionally, there are still limitations in terms of training data in machine learning.

One of the most popular ways to detect the gait phase is to have a pressure sensor on the bottom of the wearer's foot to analyze the ground reaction force (GRF) during walking [8–10]. Methods used to identify the gait phase include the center of pressure (COP). The ratio of COP values is used to divide the walking cycle and identify the point of weight movement between the two feet [8]. In addition, a support vector machine (SVM) can identify the gait phase too. The SVM is a neural network for supervised learning. It learns from a sample set of input and output values and can detect discrete walking steps within the round movement of dynamic human walking [9]. A pressure sensor is sometimes used with IMU to increase detection efficiency. Nagashima et al. predicted plantar force during gait to detect walking distance with a deep neural network (DNN). The DNN is used to learn the non-linear relationship between the measured sensor data and future sensor force data by using a trained network [10]. However, when detecting the gait phase, problems are often found in the wearer's physical condition, such as the sensor position, stride speed, and weight [11]. In addition, there are still problems with processing and control delays, making the prosthesis control ineffective.

In terms of the machine learning approaches and their performances in the studied papers, most of the papers [12,13] have used kNN as their machine learning approach to classify the gait cycle pattern. Most of these studies compared the output of the kNN algorithm with those of other approaches. In [12], for the classification of three gait patterns through GRFs data, artificial neural network algorithms (ANN) were used for comparison with the k-nearest neighbor approach. kNN showed the best accuracy of 85%, slightly higher than the ANN at 80%. Another paper [13] has shown five-class classification with SVM, decision tree (DT), ANN, naive Bayes (NB), and kNN. The overall classification accuracy was 97.9% for SVM, 90.1% for DT, 100% for ANN, 97.2% for NB, and 100% for kNN. Thus, in this study, we choose the kNN algorithm for gait classification because the kNN outperforms all other approaches in terms of accuracy.

In this paper, we present a k-nearest neighbor algorithm that can detect a real-time gait phase among seven phases, i.e., stand, heel strike, foot flat, midstance, heel off, toe-off, and swing phase, by using a wearable sensor located in an insole sheet which can be worn with all types of shoes. Furthermore, it can control the prosthesis via Bluetooth with little delay. The wearable device is small, lightweight, and unaffected by the physical factors of the wearer.

2. Materials and Methods

2.1. Hardware Description

The insole device developed in this study consists of three main components, as shown in Figure 1a. Firstly, five plantar force sensors (FSR-402, Interlink Electronics, Camarillo, CA, USA) are attached to the bottom of the insole sheet (S_1 – S_5) to receive the force exerted on the foot as you walk [14,15]. The sensor positions are shown in Figure 1b, though they change according to the shape of the wearer's foot. Next, notice the ~6 V battery that is the power supply for the device, and lastly, notice the microcontroller board which is used to

process the force data and send each force data to the computer for further analysis. We put these three components on a right leg, as shown in Figure 1a.




Figure 1. (a) The equipment of the wearable sensor device to receive data during walking. (b) Five sensors' positions in the insole sheet.

The first step is the procedure for collecting the five sensor values during human walking. The sensor values are transmitted using wires through a computer. It is necessary to collect data with wires because using a wireless data storage method would cause a delay in data transmission and might cause the loss of essential force data. Therefore, it is necessary to collect the sensor value data with wires, and a complete set of parameters is required to observe each sensor's rate of change. A wire we used was a micro-USB type B connecting to USB 2.0 Type-A with a length of 3 m, which was connected to the microcontroller board to send data to the computer.

2.2. Participants and Experimental Procedures

The gait experiment was conducted on two adult females and three males, 26 ± 3 years of age, who were 165 ± 3 cm in height and 53 ± 2 kg. In terms of recorded data, all participants were tested while standing still for 10 s and then walked on a treadmill at speeds from 1 to 8 km/h. There are seven phases of the gait cycle that we were interested in collecting—stand, heel strike, foot flat, midstance, heel off, toe-off, and swing—as shown in Figure 2. The recorded data were sent to a PC using the JAVA telemetry viewer to collect the sensor values while walking. It can collect 100 sensor values per second.



Figure 2. The phases of the gait cycle collected and analyzed in this work.

Figure 3 shows an example of measured signals from five sensors (S_1 – S_5), which are raw force sensor signals, unfiltered. During the walking test, it can be seen that each sensor received the same pattern in each walking cycle. The collected force sensor signal was analyzed and filtered through MATLAB to divide the force sensor signal into seven segments. The seven segments are the seven phases of the walking cycle that we were interested in collecting. We divided the sensor signal using a sampling rate of 20 Hz, and we performed the mean range of the data at each sampling to divide each data into seven segments, as seen in Figure 4. After filtering through MATLAB, some data were used as a training dataset labeled in the machine learning kNN, and some data were used to find the best k value that is most suitable for our algorithm. We used the Arduino IDE and the classified intent onboard ESP-WROOM-32 with Bluetooth 4.2 MCU module and 16 Mb flash memory. This work obtained the ethics committee approval from the human research from Suranaree University of Technology (License EC-64-30 COA number 67/2564). This work was supported by Suranaree University of Technology (SUT), Thailand Science Research and Innovation (TSRI), and the National Science Research and Innovation Fund (NSRF) (NRIIS number 42852), and all participants provided written consent for this study prior to participation.




Figure 3. Examples of measured signals from five sensors. (SW: swing, HS: heel strike).




Figure 4. The example of dividing a sensor signal into 7 segments by MATLAB. (ST: stand, SW: swing, HS: heel strike, FF: foot flat, MS: midstance, HO: heel off, TO: toe-off).

2.3. K-Nearest Neighbor Classification

K-nearest neighbor (kNN) classification is one of the simplest machine learning algorithms based on the supervised learning technique. It is widely used in data classification, pattern recognition, picture classification, and other fields [16]. The kNN algorithm stores the entire training dataset and reclassifies the data points according to the distance between every two points for k neighbors using the Euclidean distance function. This distance function is often modified by scaling the attribute so that the spread of the attribute values across dimensions is approximately the same. This formula can calculate the closeness of all training data points to the data points one is trying to label and use the mean of the nearest neighbor k to predict as expressed in (1).

$$Dist(p, q) = Dist(q, p) = \sqrt{\sum_{i=1}^n (q_i - p_i)^2} \quad (1)$$

One of the many issues that affect the performance of the kNN algorithm is the choice of the hyperparameter k. If k is too small, the algorithm would be more sensitive to overfitting data points. If the value of k is too large, then the model will be inflexible. For example, if k = N (the total number of data points), the model will just dumbly blanket-classify all the test data as the mean of the training data. Moreover, the number of k should be odd to avoid decision problems in the case of two equal classes.

In this study, we collected walking data using five pressure sensors (S₁–S₅) to train in the k-nearest neighbor algorithm. The training data has seven groups named stand, heel strike, foot flat, midstance, heel off, toe-off, and swing. Each class has 70 labeled training sets, so the total is 490 labeled training sets. Additionally, we performed experiments to see which k value is the most suitable for our algorithm and provides the most effective prediction.

2.4. Distance Weighted kNN Algorithm

A distance weighted kNN algorithm or weighted voting is weighted based on calculated similarity. This means that more similar data have a more significant impact on answer formulation than less similar data, solving the problem of prediction errors due to k being too high or too low. As defined in the equations below, it makes the computational model more accurate. Each of our scores has to be weighed in each class. For neighbor k, we sort the distances in ascending order, e.g., d₁, . . . , d_k, where d₁ is the smallest distance, d_k is the furthest distance, and d_i is the original distance of each point. Then, whatever type of total weights the most, let the test point be that class.

$$w_i = \begin{cases} \frac{d_k - d_i}{d_k - d_1} & \text{if } k \neq 1 \\ 1 & \text{if } k = 1 \end{cases} \quad (2)$$

After completing the implementation of this equation, a new distance weighted value of each class will be acquired, and then we can see which group or which class has the largest distance weighted value. Finally, the algorithm predicts that the test point is of that class. Thus, in this paper, we used this distance-weighted kNN to help in terms of improving predictive performance and making walking cycle detection better. Moreover, using a distance-weighted k-nearest neighbor can reduce the number of errors during prediction and make the kNN algorithm work even faster.

2.5. Calibration System

In research analysis of gait cycles or gait phases, physical problems of the wearer are often identified, such as the wearer's weight affecting the gait cycle detection. This is because most of the algorithms rely primarily on the force of the sensor to detect the gait phase correctly. The weight of the wearer affects the strength of the sensor, and may cause

false detection [17,18]. We have added a calibration system to our wearables to solve this problem. It automatically adjusts the weight on the sensor at the touch of a button.

The schematic of the gait analysis system with a calibration system for controlling the transtibial prosthetic is illustrated in Figure 5. Our devices have LED lights that show all three working states. A red LED means that our wearable device is still unable to connect via Bluetooth with the prosthetic foot. The green LED means the wearable device is successfully connected to the prosthetic foot, and the orange LED indicates that the calibration is in progress. In the process of calibration, when the switch is turned on, the wearer must be in the standing position and press the button. Then, the orange LED is turned on, which means the calibration system is working. Then, the wearer waits until the orange LED turns green. Then, the wearer can start walking. The data of each force sensor are taken to the k-nearest neighbor algorithm to predict the gait cycle phase. Then, the predicted data are transmitted to the prosthetic foot for control via a Bluetooth connection.




Figure 5. The schematic of the gait analysis with the calibration system for controlling the transtibial prosthetic.

3. Results and Discussion

The experiments were conducted on a self-collected dataset that consists of the sensor values gathered from five individuals. One-hundred and forty samples were created for a single person. This, there are in total 700 samples. We split the data into training and testing sets. The training set has 70% of the complete data (490 labeled training sets), and the testing set has 30% of the dataset (210 labeled training sets). Then, each sensor value was analyzed and taken into the kNN process to predict seven gait phases, i.e., stand, heel strike, foot flat, midstance, heel off, toe-off, and swing, using the Euclidean distance function.

The experimental results can be divided into four essential parts. First is the optimal k value for our kNN algorithm, find each gait stage's classification accuracy with optimal k, the walking speed that affected the accuracy of kNN prediction, and the time delay for controlling transtibial prosthesis via Bluetooth connection.

Figure 6 shows the prediction accuracy result of the kNN algorithm with different k values. As seen in Figure 6, the selected k value significantly impacts the accuracy of the gait phase prediction in the k-nearest neighbor algorithm. In the beginning, the value of $k = 1$ had a prediction accuracy of 80.95%, $k = 3$ had a prediction accuracy of 81.43%, and $k = 5$ had a prediction accuracy of 76.19%. After that, it can be seen that the larger the k value, the lower the prediction accuracy. Hence, the most suitable value of k in the k-nearest neighbor algorithm is $k = 3$. That means our kNN algorithm will retrieve every three data points closest to the test point by using the Euclidean distance equation.




Figure 6. Prediction accuracy of the kNN algorithm with different k values.

Table 1 shows the gait classification accuracy for each gait phase using $k = 3$. It can be seen that the swing phase had the highest forecast accuracy (100.00%) because the swing phase is distinguished by its distinct signal. The feet are elevated in the swing action, and just a small amount of force is imparted to the sensors at the bottom of the foot. That means the sensors in S_1, S_2, S_3, S_4 , and S_5 will be subjected to a small amount of force. As a result, the swing phase is simple to learn and has high prediction accuracy via machine learning.

Table 1. Gait classification accuracy with $k = 3$.

Gait Cycle	Precision	Recall	F1-Score	Accuracy (%)
Stand	0.750	0.700	0.724	70.00
Heel Strike	0.875	0.933	0.903	93.34
Foot Flat	0.880	0.733	0.800	73.33
Midstance	0.606	0.667	0.635	66.67
Heel Off	0.846	0.733	0.786	73.33
Toe Off	0.778	0.933	0.848	93.34
Swing	1	1	1	100.00

The second highest prediction accuracy was a tie for heel strike and toe-off, for which we achieved 93.34%. Both phases are equally accurately predicted because both have the same sensor value characteristics, just in different positions. In other words, both the heel strike phase and the toe-off phase have similar sensor signal formats, but the heel strike phase is a gesture of placing weight on the heel, so the signal strength of S_5 is noticeably higher than that of the other sensors ($S_5 \gg S_1, S_2, S_3, S_4$). Similarly, the toe-off phase is a gesture of putting weight on the toe, causing the signal strength of S_1 to be noticeably higher than the signal strength of the other sensors ($S_1 \gg S_2, S_3, S_4, S_5$).

The stand and midstance phase prediction accuracies were 70.00% and 66.67%, respectively. This is because these two phases have the same characteristics, e.g., foot position, ankle angle, and force plantar load. Moreover, they have the same force acting on the $S_1 \approx S_2 \approx S_3 \approx S_4 \approx S_5$. For this reason, machine learning finds it difficult to predict these phases because the two datasets are similar to each other. However, since both phases have the same angle of motion of the ankle, it does not affect the algorithm in the control of prosthetic feet.

The last are foot flat and heel off phases. Both phases had a prediction accuracy of 73.33%. As humans are very fast walkers, both phases are part of the junction phase between the primary phase. The main phases are heel strike, midstance, and toe-off, but the foot flat phase is the junction phase between heel strike and midstance. Similarly, the

heel off phase is the junction phase between midstance and toe-off. The wearer's walking speed increasing may cause cross-phase prediction of these two junction phases to occur.

Cross-phase prediction is one of the error predictions. Predicting the phases in the gait cycle is usually done in the following order: heel strike, foot flat, midstance, heel off, toe-off, and swing. "Cross-phase prediction" is predicting the gait cycle phases earlier than the actual phase. For example, if now it is heel strike phase and the next phase that should be predicted is foot flat, the algorithm could predict midstance instead. It can be seen that the algorithm predicts one phase too early, which is called cross-phase prediction.

Overall, the predictive accuracy of each phase of human gait is an essential variable in prosthetic foot control because the prosthesis is designed to control the angle of the ankle to move up or down according to the phase that machine learning can predict. The highest prediction accuracy of each phase will make the prosthetic foot control be more smooth and more effective. However, suppose the prediction is low accuracy, or there is a prediction error or cross-phase prediction. In that case, the prosthetic foot will not be able to move as it should and will make the wearer of this prosthetic leg unable to walk easily. In the overall results of our individual gait classification accuracy, each phase has a prediction accuracy within the range that the prosthesis could be efficiently controlled without problems.

Nevertheless, the walking speed will affect the prediction performance of the kNN algorithm. Walking speed is one of the major issues in research detecting gait events [19–22]. Most algorithms tend to cross-predict or are unable to predict at all. Therefore, in this work, we focus on real-time gait phase detection research using wearable sensors for the transtibial prosthesis that can only support normal human walking or approximately 1.4 m/s.

In the experiment on walking speed, we tested the accuracy of predicting gait cycles at different speeds by having subjects walk on a treadmill. The speed ranged from 1 to 8 km per hour. The experimental results are shown in Figure 7. It can be seen that the accuracy decreases as the walking speed increases. The walking speed is divided into three parts: slow (1–2 km/h), normal (3–5 km/h), and fast walking (6–8 km/h). First of all, during slow walking, predicting gait cycles was very accurate, in the range of about 90.00–100.00%, because when walking at a slower speed, the gait cycle phase change will also be slow. Furthermore, sensors at the bottom of the foot can perfectly capture the pressure of each gait cycle. This enables machine learning to process and predict gait cycles efficiently.




Figure 7. Walking speed affects the prediction accuracy of the kNN algorithm.

The next phase covers the range of normal human walking speeds. As seen in Figure 8, the results show that there is still high prediction accuracy during this normal walking, but worse than for slow walking. The accuracy of this range is in the range of 85.14–97.43%. For the fast walking speed, the accuracy is 30.71–70.81%. The accuracy in this range of walking speeds is significantly worse compared with slow and normal walking. At a walking speed of 6 km/h, the prediction accuracy is just 70.81% because the model can predict

only primary phases, such as heel strike, midstance, heel off, stand, and swing; and much cross-phase prediction occurs, e.g., of foot flat and heel off phases.

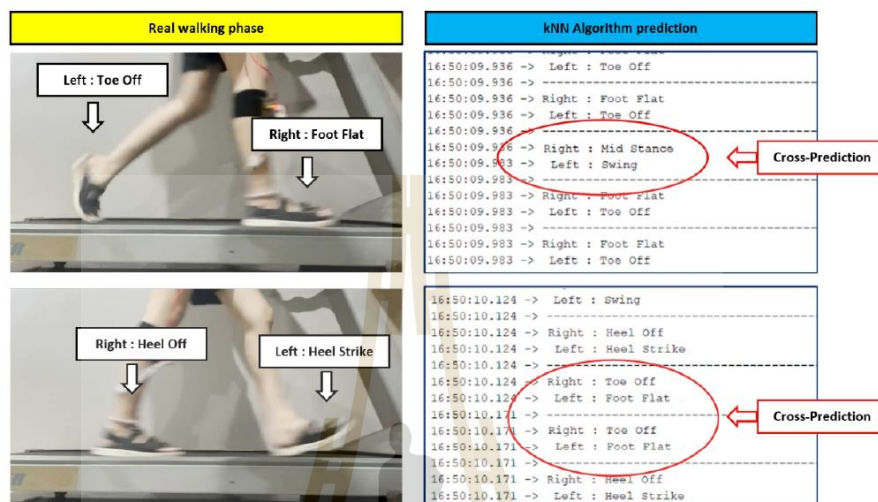


Figure 8. Cross-phase prediction of walking speed at 6 km/h.

The kNN algorithm results in cross-prediction of foot flat and heel off phases. This will not have much impact on transtibial prosthetic control because the primary phase is still predictable. Foot flat and heel off phases just will help control the transtibial prosthesis for smooth flow of walking. When the walking speed reaches 7–8 km/h, it can be seen that the prediction accuracy gradually decreases. As at such speeds, the kNN algorithm predicts foot flat and heel off phases incorrectly, including wrongly predicting the main phases, which would significantly affect foot control. As a result, the prosthetic foot could not move according to the gait phases as it should. From the previous results, it can be concluded that walking speed affects the gait cycle prediction algorithm. The faster the wearer walks, the more errors in the predictions [23,24]. As a result, the kNN algorithm in this paper can control the prosthetic foot effectively at up to 6 km/h.

Figure 8 shows the results of each gait phase prediction at a walking speed of 6 km/h. There were errors at the start of the gait cycle known as cross-phase prediction at this speed. Most likely, the algorithm will begin to predict erroneously in the foot flat phase. Foot flat is often predicted as midstance, and heel off is often predicted as toe-off due to the walking speed. The walking speed makes the sensor installed in the insole area unable to receive the value in that phase immediately. This makes the processing of kNN algorithms through the microcontroller board unpredictable. At this speed, it can be seen that most gait phase predictions are accurate, and the accuracy of gait cycle prediction is very high. However, cross-phase prediction occurs between foot flat and heel off phases at this speed, which are junction phases between the primary phases. That would not affect transtibial prosthetic foot control. For the speed of 7–8 km/h, the kNN algorithm made a lot of prediction errors in multiple phases, including junction and primary phases. That means the kNN algorithm cannot operate at this walking speed and would be unable to control a prosthetic foot. Thus, our algorithm can support a maximum human walking speed of 6 km/h. It can control a prosthesis effectively at that speed.

For the real-time implementation—controlling a transtibial prosthesis—two esp-wroom 32 microcontroller boards were used. One was attached to the leg with a wearable device to run the kNN algorithm for phase prediction and send the phase shift data of the gait cycle to the esp-wroom 32, which was attached to the transtibial prosthetic leg to receive data and use the data of phase change to control the prosthesis. We sent the data via Bluetooth connection, causing a delay and the computation time shown in Figure 9. The black line represents when the actual data were sent from the insole device to the prosthesis for control. The red line indicates when the prosthesis responded to the signal sent by the insole device. The brown dashed line represents the range of responses to the signals produced by the prosthetic foot.




Figure 9. Delay in data transmission via Bluetooth connection for transtibial prosthesis control.

With the actual data transmission time and the length of time the prosthesis takes to respond, there is an approximately average delay of 15 ± 2 ms, which is an acceptable delay for receiving data and would not affect the control of the prosthesis.

Excessive Bluetooth transmission delay values can significantly impact prosthetic control if there is too much delay. Although the algorithm is very accurate at predicting gait cycles, the prosthesis could not move according to the prediction of gait cycles if there were a large delay [25–28]. It will make people with disabilities unable actually to use this prosthetic leg.

4. Conclusions

A wearable device has been developed in this work. Five pressure sensors are attached to the bottom of the insole sheet to receive the force exerted on the foot while walking. The wearable device can perform real-time prediction of the gait cycle regarding seven phases—stand, heel strike, foot flat, midstance, heel off, toe-off, and swing—using the kNN algorithm. The experiment consisted of slow walking (1–2 km/h), resulting in 90–100% prediction accuracy; normal walking (3–5 km/h), resulting in 85.14–97.43% prediction accuracy; and fast walking (6–8 km/h), resulting in 30.71–70.81% prediction accuracy.

The insole device has a wireless data transceiver operating with a low delay of 15 ± 2 ms. This device uses little power and is small, lightweight, and wearable. Moreover, the proposed gait analysis technique is unaffected by the physical conditions of the wearer. Therefore, the device can be applied with a transtibial prosthesis to efficiently control it. However, there is still a limitation: walking speed. Our algorithm can support a maximum human walking speed of 6 km/h.

For future work, we will use a 3D vision system to assess the accuracy of the gait detection technique proposed in the present study and also design equipment that is more comfortable to wear.

Author Contributions: Conceptualization, P.U. and B.S.; data curation, T.J. and S.R.; formal analysis, M.U. and T.J.; funding acquisition, B.S.; investigation, A.R.; project administration, P.U. and B.S.; resources, A.R., P.U. and T.J.; software, K.P.; supervision, P.U. and B.S.; validation, P.U., M.U. and S.R.; writing—original draft, A.R.; writing—review and editing, A.R. All authors were informed about each step of manuscript processing, including submission, revision, revision reminder, etc. via emails

from our system or the assigned Assistant Editor. All authors have read and agreed to the published version of the manuscript.

Funding: This research was supported by Suranaree University of Technology (SUT), Thailand Science Research and Innovation (TSRI), and National Science Research and Innovation Fund (NSRF) (NRIS number 42852).

Institutional Review Board Statement: The study was conducted in accordance with the Declaration of Helsinki, and approved by the Institutional Ethics Committee of Suranaree University of Technology (License EC-64-30 COA number 67/2564 Date of Approval 6 August 2021).

Informed Consent Statement: Informed consent was obtained from all subjects involved in the study.

Data Availability Statement: Not applicable.

Conflicts of Interest: The authors declare no conflict of interest.

References

- Benbakhti, A.S.; Boukhenous, S.; Zizoua, C.; Attari, M. An instrumented shoe for ambulatory prevention of diabetic foot ulceration. In Proceedings of the 2014 4th International Conference on Wireless Mobile Communication and Healthcare—Transforming Healthcare through Innovations in Mobile and Wireless Technologies (MOBIHEALTH), Athens, Greece, 3–5 November 2014; pp. 43–46.
- Aqueveque, P.; Osorio, R.; Pastene, F.; Saavedra, F.; Pino, E. Capacitive Sensors Array for Plantar Pressure Measurement Insole fabricated with Flexible PCB. In Proceedings of the 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Honolulu, HI, USA, 18–21 July 2018; pp. 4393–4396.
- Varol, H.A.; Goldfarb, M. Real-time Intent Recognition for a Powered Knee and Ankle Transfemoral Prosthesis. In Proceedings of the 2007 IEEE 10th International Conference on Rehabilitation Robotics, Noordwijk, The Netherlands, 13–15 June 2007; pp. 16–23.
- Zhao, H.; Wang, Z.; Qiu, S.; Shen, Y.; Wang, J. IMU-based gait analysis for rehabilitation assessment of patients with gait disorders. In Proceedings of the 2017 4th International Conference on Systems and Informatics (ICSAI), Hangzhou, China, 11–13 November 2017; pp. 622–626.
- Huang, H.; Zhou, P.; Li, Y.; Sun, F. A Lightweight Attention-Based CNN Model for Efficient Gait Recognition with Wearable IMU Sensors. *Sensors* **2021**, *21*, 2866. [[CrossRef](#)] [[PubMed](#)]
- Mahoney, J.M.; Rhudy, M.B. Methodology and validation for identifying gait type using machine learning on IMU data. *J. Med. Eng. Technol.* **2019**, *43*, 25–32. [[CrossRef](#)] [[PubMed](#)]
- Wu, C.-C.; Wen, Y.-T.; Lee, Y.-J. IMU sensors beneath walking surface for ground reaction force prediction in gait. *IEEE Sens. J.* **2020**, *20*, 9372–9376. [[CrossRef](#)]
- Park, J.S.; Lee, C.M.; Koo, S.-M.; Kim, C.H. Gait Phase Detection Using Force Sensing Resistors. *IEEE Sens. J.* **2020**, *20*, 6516–6523. [[CrossRef](#)]
- Huang, B.; Chen, M.; Shi, X.; Xu, Y. Gait Event Detection with Intelligent Shoes. In Proceedings of the 2007 International Conference on Information Acquisition, Seogwipo, Korea, 8–11 July 2007; pp. 579–584.
- Nagashima, M.; Cho, S.-G.; Ding, M.; Ricardez, G.A.G.; Takamatsu, J.; Ogasawara, T. Prediction of Plantar Forces During Gait Using Wearable Sensors and Deep Neural Networks. In Proceedings of the 2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Berlin, Germany, 23–27 July 2019; pp. 3629–3632.
- Ledoux, E.D. Inertial Sensing for Gait Event Detection and Transfemoral Prosthesis Control Strategy. *IEEE Trans. Biomed. Eng.* **2018**, *65*, 2704–2712. [[CrossRef](#)] [[PubMed](#)]
- Alaqtash, M.; Sarkodie-Gyan, T.; Yu, H.; Fuentes, O.; Brower, R.; Abdelgawad, A. Automatic classification of pathological gait patterns using ground reaction forces and machine learning algorithms. In Proceedings of the 2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Boston, MA, USA, 30 August–3 September 2011; pp. 453–457.
- Pogorelec, B.; Bosnić, Z.; Gams, M. Automatic recognition of gait-related health problems in the elderly using machine learning. *Multimed. Tools Appl.* **2011**, *58*, 333–354. [[CrossRef](#)]
- Jasni, F.; Hamzaid, N.A.; Al-Nusairi, T.Y.; Yusof, N.H.M.; Shasmin, H.N.; Ng, S. Feasibility of a Gait Phase Identification Tool for Transfemoral Amputees Using Piezoelectric-Based In-Socket Sensory System. *IEEE Sens. J.* **2019**, *19*, 6437–6444. [[CrossRef](#)]
- Shaikh, M.F.; Salic, Z.; Wang, K. Analysis and selection of the Force Sensitive Resistors for gait characterisation. In Proceedings of the 2015 6th International Conference on Automation, Robotics and Applications (ICARA), Queenstown, New Zealand, 17–19 February 2015; pp. 370–375.
- Hu, Y.; Li, X.; Liu, Q. Design and Research of Gait Recognition Method of Upper Knee Prosthesis Based on kNN Algorithm. In Proceedings of the 2019 4th International Conference on Robotics, Control and Automation (ICRA 2019), Association for Computing Machinery, New York, NY, USA, 26–28 July 2019; pp. 173–177.

17. Prado, A.; Cao, X.; Ding, X.; Agrawal, S.K. Prediction of Gait Cycle Percentage Using Instrumented Shoes with Artificial Neural Networks. In Proceedings of the 2020 IEEE International Conference on Robotics and Automation (ICRA), Paris, France, 31 May–31 August 2020; pp. 2834–2840.
18. Zhao, Z.; Chen, W.; Yixin, Z.; Pinghua, A.; Wang, J. A Wireless Foot Plantar Pressure Distribution Measurement System and Its Application in Gait Analysis. In Proceedings of the 2020 Chinese Control And Decision Conference (CCDC), Hefei, China, 22–24 August 2020; pp. 1397–1402.
19. Han, Y.C.; Wong, K.L.; Murray, I. Gait Phase Detection for Normal and Abnormal Gaits Using IMU. *IEEE Sens. J.* **2019**, *19*, 3439–3448. [[CrossRef](#)]
20. Alahakone, A.U.; Senanayake, S.M.N.A.; Senanayake, C.M. Smart wearable device for real time gait event detection during running. In Proceedings of the 2010 IEEE Asia Pacific Conference on Circuits and Systems, Kuala Lumpur, Malaysia, 6–9 December 2010; pp. 612–615.
21. Prakash, C.; Kumar, R.; Mittal, N. Automated detection of human gait events from conventional videography. In Proceedings of the 2016 International Conference on Emerging Trends in Communication Technologies (ETCT), Dehradun, India, 18–19 November 2016; pp. 1–4.
22. Malešević, N.; Malešević, J.; Keller, T. Gait phase detection optimization based on variational bayesian inference of feedback sensor signal. In Proceedings of the 12th Symposium on Neural Network Applications in Electrical Engineering (NEUREL), Belgrade, Serbia, 25–27 November 2014; pp. 179–182.
23. Senanayake, C.M.; Senanayake, S.M.N.A. Computational Intelligent Gait-Phase Detection System to Identify Pathological Gait. *IEEE Trans. Inf. Technol. Biomed.* **2010**, *14*, 1173–1179. [[CrossRef](#)] [[PubMed](#)]
24. Chakraborty, S.; Nandy, A. An Unsupervised Approach For Gait Phase Detection. In Proceedings of the 2020 4th International Conference on Computational Intelligence and Networks (CINE), Kolkata, India, 27–29 February 2020; pp. 1–5.
25. Jumphoo, T.; Uthansakul, M.; Uthansakul, P. Brainwave classification without the help of limb movement and any stimulus for character-writing application. *Cogn. Syst. Res.* **2019**, *58*, 375–386. [[CrossRef](#)]
26. Kokkhunthod, K.; Jumphoo, T.; Uthansakul, P. Improving brainwave classification for character-writing application using single effective EEG channel in SUT. In Proceedings of the International Virtual Conference on Science and Technology, Nakhon Ratchasima, Thailand, 28 August 2020; pp. 142–148.
27. Phapatanaburi, K.; Kokkhunthod, K.; Wang, L.; Jumphoo, T.; Uthansakul, M.; Boonmahitthisud, A.; Uthansakul, P. Brainwave Classification for Character-Writing Application using EMD-based GMM and KELM approaches. *Comput. Mater. Contin.* **2021**, *66*, 3029–3044. [[CrossRef](#)]
28. Jumphoo, T.; Uthansakul, M.; Duangmanee, P.; Khan, N.; Uthansakul, P. Soft Robotic Glove Controlling Using Brainwave Detection for Continuous Rehabilitation at Home. *Comput. Mater. Contin.* **2020**, *66*, 961–976. [[CrossRef](#)]

ประวัติผู้เขียน

นางสาวอัจฉราวรรณ รัตนศักดิ์ เกิดเมื่อวันที่ 14 มีนาคม พุทธศักราช 2542 ที่จังหวัดปราจีนบุรี โดยสำเร็จการศึกษาระดับประถมศึกษาจากโรงเรียนมารีวิทยา ปราจีนบุรี ระดับมัธยมศึกษาตอนต้นและระดับมัธยมศึกษาตอนปลายจากโรงเรียนปราจีนกัลยาณี สำเร็จการศึกษาระดับปริญญาตรี สาขาวิชาวิศวกรรมโทรคมนาคม สำนักวิชาวิศวกรรมศาสตร์ จากมหาวิทยาลัยเทคโนโลยีสุรนารี จังหวัดนครราชสีมา จากนั้นได้ศึกษาต่อในระดับปริญญาโทในสาขาวิชาวิศวกรรมโทรคมนาคมและคอมพิวเตอร์ มหาวิทยาลัยเทคโนโลยีสุรนารี โดยขณะศึกษาได้รับทุนการศึกษาจากโครงการทุนการศึกษาสำหรับผู้มีศักยภาพเข้าศึกษาระดับบัณฑิตศึกษา

