

■ Research Article



บริการเอพีไอเพื่อการจำแนกระดับความเสี่ยงการเกิดแผลกดทับของผู้ป่วยติดเตียง โดยบูรณาการการเรียนรู้ของเครื่องและชุดเซนเซอร์ไร้สาย

An API services for classifying risk level of bedsores of bedridden patients by integrating machine learning and wireless sensor

วิไลวรรณ แสนชนะ¹, ฤทธิรงค์ แสงสร้อย² รมนวรรณ บุญไทย² ปรกฤกษ์ สายหส์ดี² และปราโมทย์ สิกธิจักร^{2*}

¹สาขาวิชาเทคโนโลยีสารสนเทศ คณะวิทยาศาสตร์และเทคโนโลยีการเกษตร มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี ปทุมธานี, 52 หมู่ 7 ต.บ้านสร้าง อ.เมือง จ.ปทุมธานี 65000
²สาขาวิชาเทคโนโลยีสารสนเทศ คณะบริหารธุรกิจและการบัญชี มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี ปทุมธานี, 93 หมู่ 5 ต.สมอแข อ.เมือง จ.ปทุมธานี 65000

บทคัดย่อ

แผลกดทับเป็นสาเหตุสำคัญที่ส่งผลให้ผู้ป่วยติดเตียงในกระแสเลือด จนทำให้ผู้ป่วยเสียชีวิตในเวลาอันรวดเร็ว จึงเป็นโจทย์สำคัญในงานวิจัยนี้ โดยมีวัตถุประสงค์เพื่อค้นหาคุณลักษณะของชุดข้อมูลในการจำแนกระดับความเสี่ยงการเกิดแผลกดทับของผู้ป่วยติดเตียง เพื่อพัฒนาและประเมินประสิทธิภาพของโมเดลและบริการเอพีไอเพื่อการจำแนกระดับความเสี่ยงการเกิดแผลกดทับของผู้ป่วยติดเตียง โดยการเรียนรู้ของเครื่องและเซนเซอร์ รวบรวมชุดข้อมูลด้วยแบบประเมินของบาร์เดนร่วมกับใช้เซนเซอร์เพื่อตรวจจับการเคลื่อนไหวด้วย MPU-650 กับผู้ป่วยติดเตียงในกลุ่มโรคไม่ติดต่อเรื้อรัง โรงพยาบาลวัดโบสถ์ จังหวัดปทุมธานี จำนวน 78 คน ทดสอบประสิทธิภาพการจำแนกระดับความเสี่ยงการเกิดแผลกดทับเพื่อเลือกอัลกอริทึมที่มีประสิทธิภาพมากที่สุด ได้แก่ อัลกอริทึม KNN, WKNN การเพิ่มเทคนิคการเลือกคุณลักษณะ และเซนเซอร์ ผลการวิจัยพบว่า การเพิ่มคุณลักษณะจากเซนเซอร์ในการนับจำนวนการขยับร่างกาย/เปลี่ยนท่าทาง ในโมเดล KNN กับ Information gain แบบ 5 คุณลักษณะช่วยเพิ่มความถูกต้องในการทำนายเฉลี่ยร้อยละ 7 โดยให้ความถูกต้องสูงสุด 93.6% ที่ $k = 3$ และ 7 สามารถนำมาพัฒนาบริการเอพีไอต่อเชื่อมกับโมเดลและเซนเซอร์ เพื่อรองรับการเข้าถึงจากซอฟต์แวร์ภายนอกที่พัฒนาด้วยภาษา PHP

คำสำคัญ: บริการเอพีไอ แผลกดทับ ผู้ป่วยติดเตียง การเรียนรู้ของเครื่อง เซนเซอร์ MPU-650

Received:

2 October 2024

Revised:

26 December 2024

Accepted:

27 December 2024

Published:

27 December 2024

*Corresponding

Author:

pramotes@plu.ac.th

Copyright:

© Rajamangala University of Technology Lanna. All right reserved

ISSN

Print: 2586-8500

Electronic: 2586-8632

Abstract

Pressure ulcers are a significant cause of bloodstream infections, leading to rapid patient mortality. This research aims to identify data attributes for classifying the risk levels of pressure ulcers in bedridden patients, to develop and evaluate the effectiveness of a model and API service for this classification. The approach integrates machine learning and sensor technology. Data was collected using the Braden Scale and sensors to detect movement with an MPU-650 sensor in 78 bedridden patients with chronic non-communicable diseases at Wat Bot Hospital in Phitsanulok Province. The study tested the efficiency of pressure ulcer risk classification to select the most effective algorithm, including KNN and WKNN, incorporating feature selection techniques and sensors. The research findings indicate that adding sensor-derived features, such as the count of body movements/ position changes, to the KNN model with Information Gain of 5 features, increased the prediction accuracy by an average of 7%, achieving a maximum accuracy of 93.6% at $k = 3$ and 7. This can be further developed into an API service that integrates with the model and sensors, supporting access from external software developed in PHP.

Keywords: API services, Bedsores, Patients lying on bed, Machine learning, MPU-650 sensor

1. บทนำ

ในปัจจุบันประชาชนส่วนใหญ่อประสบปัญหาจากการเจ็บป่วยด้วยโรคไม่ติดต่อเรื้อรัง (NCDs) เป็นจำนวนมากยิ่งขึ้นทุก ๆ ปี เช่น โรคเบาหวาน โรคเมะเร็ง โรคความดันโลหิตสูง โรคหัวใจและหลอดเลือด โรคหลอดเลือดสมอง และโรคไตวายเรื้อรัง ซึ่งผู้ป่วยควรได้รับการดูแลอย่างต่อเนื่อง เพราะอาการของโรคอาจมีระดับความรุนแรงเพิ่มขึ้นและมีภาวะแทรกซ้อนซึ่งทำให้ผู้ป่วยเสียชีวิตในเวลาอันสั้น ในพื้นที่อำเภอวัดโบสถ์ จังหวัดพิษณุโลก ซึ่งเป็นพื้นที่เป้าหมายการวิจัย พบว่ามีผู้ป่วยจำนวนมากนอนติดเตียงด้วยโรคไม่ติดต่อเรื้อรังที่บ้าน แพทย์ไม่สามารถติดตามได้อย่างต่อเนื่องและดูแลได้อย่างใกล้ชิด และผู้ป่วยบางรายเสียชีวิตจากแผลกตกับและภาวะโลหิตเป็นพิษรุนแรง (Watbot hospital, 2016) นี้อคือความสำคัญของการวิจัยและพัฒนากการจำแนกความเสี่ยงของแผลกตกับของผู้ป่วยที่นอนอยู่บนเตียงด้วยโรค NCDs โดยใช้การเรียนรู้แบบมีผู้สอน ในกลุ่มอัลกอริทึมการจำแนกข้อมูล เช่น K Nearest Neighbor (KNN) และ Weighted Nearest Neighbor (WKNN) ซึ่งอัลกอริทึมการจำแนกข้อมูลซึ่งเป็นที่นิยม และไม่ซับซ้อน (Sadegh Bafandeh Imandoust and Mohammad Bolandraftar, 2013)

ในปัจจุบันมีงานวิจัยจำนวนมากที่ใช้เทคนิคการจำแนกประเภทในการทำนายระดับความรุนแรงของโรค โดย Jabbar, M. A. et al. (2013) ได้พัฒนาตัวจำแนก KNN ซึ่งช่วยทำนายการปรากฏตัวของโรคหัวใจในผู้ป่วย และ Arpita Joshi และ Ashish Mehta (2018) ใช้ KNN สำหรับการวินิจฉัยเมะเร็งเต้านมวิสคอนซินในสภาพแวดล้อมของชุดข้อมูลจากโปรแกรม R ซึ่งเทคนิค KNN พร้อมเทคนิคการวิเคราะห์จำแนกเชิงเส้นให้ความแม่นยำที่ดีขึ้น (97.06%) เมื่อเทียบกับ KNN และ KNN ด้วยการวิเคราะห์องค์ประกอบหลัก (PCA) ซึ่งการเก็บรวบรวมชุดข้อมูลในการวิจัยครั้งนี้ ประกอบด้วยคุณลักษณะของข้อมูลตามแบบประเมินความเสี่ยงของแผลกตกับของบาร์เดน โดยความเสี่ยงของแผลกตกับแต่ละประเภทได้รับการจัดอันดับในระดับ 1 ถึง 4 ไม่รวมหมวดหมู่แรงเสียดทานและแรงเฉือน ซึ่งจัดอยู่ในระดับ 1-3 ซึ่งรวมทั้งหมด 23 คะแนน คะแนนที่สูงขึ้น หมายถึง มีความเสี่ยงต่ำในการเกิดแผลกตกับ และในทางกลับกันคะแนนต่ำ หมายถึง มีความเสี่ยงที่รุนแรงที่สุดในการเกิดแผลกตกับ (Jiricka MK et al., 1995) รวมทั้งในงานวิจัยนี้ได้บูรณาการกับการตรวจจับจำนวนครั้งในการขยับตัวด้วยเซนเซอร์ไอโรสโคป เพื่อให้เกิดการรับค่าที่นำเข้าสู่โมเดลการทำนายแบบเรียลไทม์ ร่วมกับการทำนายด้วยชุดข้อมูลตามคุณลักษณะของบาร์เดน เพื่อค้นหาวิธีการในการทำนายที่มีความถูกต้องแม่นยำสูงที่สุดมาใช้พัฒนาซอฟต์แวร์การบริการ API ที่สนับสนุนการเชื่อมต่อกับโมเดลการจำแนก และสนับสนุนการมีปฏิสัมพันธ์และการแบ่งปันข้อมูลบนเว็บและสมาร์ตโฟนสำหรับโปรแกรมภายนอกอื่น ๆ ของโรงพยาบาลและการใช้งานของบุคคลที่สนใจที่พัฒนาขึ้นด้วยภาษา PHP ใน API ต้นแบบในเวอร์ชันแรก

2. วัตถุประสงค์

2.1 เพื่อสร้างชุดข้อมูลในการจำแนกระดับความเสี่ยงการเกิดแผลกตกับของผู้ป่วยติดเตียง

2.2 เพื่อพัฒนาโมเดลและบริการเอพีไอเพื่อการจำแนกระดับความเสี่ยงการเกิดแผลกตกับของผู้ป่วยติดเตียง โดยการเรียนรู้ของเครื่องและเซนเซอร์

2.3 เพื่อประเมินประสิทธิภาพของโมเดลและบริการเอพีไอเพื่อการจำแนกระดับความเสี่ยงการเกิดแผลกตกับของผู้ป่วยติดเตียง โดยการเรียนรู้ของเครื่องและเซนเซอร์

3. แนวคิดทฤษฎีที่เกี่ยวข้อง

การเรียนรู้ของเครื่อง (Machine Learning) การเรียนรู้ของเครื่อง (ML) เป็นสาขาหนึ่งของปัญญาประดิษฐ์ที่มุ่งเน้นการพัฒนาวิธีการที่ช่วยให้คอมพิวเตอร์สามารถเรียนรู้จากข้อมูลและทำการพยากรณ์หรือการตัดสินใจได้โดยไม่ต้องถูกตั้งโปรแกรมอย่างชัดเจน (Mitchell, T. M., 1997) การเรียนรู้ของเครื่องสามารถใช้ในการวิเคราะห์ข้อมูลและการทำนายความเสี่ยงการเกิดแผลกดทับจากข้อมูลที่ได้รับจากเซนเซอร์และแบบประเมินต่าง ๆ ได้

เซนเซอร์ไร้สาย (Wireless Sensors) เซนเซอร์ไร้สายถูกนำมาใช้ในการตรวจจับการเคลื่อนไหวและสัญญาณชีพของผู้ป่วย โดยข้อมูลที่ได้จากเซนเซอร์จะถูกส่งผ่านเครือข่ายไร้สายไปยังระบบประมวลผลเพื่อวิเคราะห์และประเมินความเสี่ยงต่างๆ (Akyildiz, I. F. et al, 2002)

การพัฒนาบริการเอพีไอ (API Development) บริการเอพีไอ (Application Programming Interface) ช่วยให้ระบบสามารถเชื่อมต่อและสื่อสารกับแอปพลิเคชันภายนอกได้อย่างราบรื่น บริการเอพีไอสามารถใช้ในการส่งข้อมูลจากเซนเซอร์ไปยังโมเดลการเรียนรู้ของเครื่อง และรับผลลัพธ์จากโมเดลเพื่อแสดงผลแก่ผู้ใช้งาน (Fielding, R. T., 2000)

4. วิธีดำเนินการวิจัย

ผู้วิจัยได้กำหนดวิธีการทดลองที่มีความสอดคล้องกับวัตถุประสงค์ของการวิจัย ดังนี้

4.1 การค้นหาคุณลักษณะของชุดข้อมูลในการจำแนกระดับความเสี่ยงการเกิดแผลกดทับของผู้ป่วยติดเตียง

ผู้วิจัยทำการรวบรวมชุดข้อมูลความเสี่ยงของแผลกดทับของผู้ป่วยติดเตียงในกลุ่มโรคไม่ติดต่อเรื้อรัง ทั้งที่รักษาตัวอยู่ที่โรงพยาบาล และได้กลับไปฟื้นฟูร่างกายที่บ้าน ที่ป่วยด้วยโรคเมะเร็ง โรคหัวใจและหลอดเลือด โรคหลอดเลือดสมอง และโรคไตวายเรื้อรัง จำนวน 78 คน ซึ่งโรงพยาบาลวัดโบสถ์ จังหวัดพิษณุโลก ได้มีการบันทึกผลการประเมินไว้ในระบบฐานข้อมูลในระหว่างปีพ.ศ. 2561-2562 จากนั้นได้จัดประชุมสนทนากลุ่มกับแพทย์และพยาบาลผู้เชี่ยวชาญ จำนวน 5 ท่าน เพื่อพิจารณาระดับความเสี่ยงของแผลกดทับ ในแต่ละรายการข้อมูลในชุดข้อมูล โดยสามารถแสดงโครงสร้างของชุดข้อมูลที่รวบรวมได้ ประกอบด้วย 6 คุณลักษณะ (ดังตารางที่ 1) ตามทฤษฎีของบาร์เดน (Bergstrom N, Braden BJ, Laguzza A, Holman V, 1987) และได้เพิ่มคุณลักษณะของจำนวนการขยับร่างกาย/เปลี่ยนท่าทางที่ตรวจจับได้จากเซนเซอร์ เพื่อเพิ่มประสิทธิภาพการทำนาย โดยสามารถนำเสนอเกณฑ์การแบ่งระดับคะแนนการประเมิน ดังนี้

คะแนนรวม ≤ 9 หมายถึง มีความเสี่ยงการเกิดแผลกดทับสูงมาก

คะแนนรวม 10 – 12 หมายถึง มีความเสี่ยงการเกิดแผลกดทับสูง

คะแนนรวม 13 – 14 หมายถึง มีความเสี่ยงการเกิดแผลกดทับปานกลาง

คะแนนรวม 15 – 18 หมายถึง มีความเสี่ยงการเกิดแผลกดทับเล็กน้อย

คะแนนรวม 19 – 23 หมายถึง ไม่มีความเสี่ยงการเกิดแผลกดทับ

การวิจัยครั้งนี้ได้แบ่งออกคลาสของระดับความเสี่ยงในการเกิดแผลกดทับ ที่มีความสอดคล้องกับเกณฑ์ของบาร์เดน และคุณลักษณะเพิ่มเติมของจำนวนการขยับร่างกาย/เปลี่ยนท่าทางที่ตรวจจับได้จากเซนเซอร์ ดังตารางที่ 1

**ตารางที่ 1 คุณลักษณะ คะแนน และคลาสคำตอบในการจำแนกระดับความเสี่ยงในการเกิดแผลกดทับสำหรับ
 การเรียนรู้ของเครื่อง**

Code	Feature	Score	Class
A1	Sensory	1 - 4	- Very high risk
A2	Skin moisture	1 - 4	- High risk
A3	Activity ability	1 - 4	- Moderate risk
A4	Movement ability	1 - 4	- Mild risk
A5	Nutrition	1 - 4	- No risk
A6	Strength friction and shear strength	1 - 3	
A7	Body movement step	0 - n	

4.2 การพัฒนาโมเดลและบริการเอพีไอเพื่อการจำแนกระดับความเสี่ยงการเกิดแผลกดทับของผู้ป่วยติดเตียง โดยการเรียนรู้ของเครื่องและเซนเซอร์

ผู้วิจัยทำการฝึกสอนโมเดลการจำแนกข้อมูลระดับความเสี่ยงในการเกิดแผลกดทับ จากชุดข้อมูลที่รวบรวมได้ในข้อที่ 1 ในรูปแบบ 6 คุณลักษณะ ตามทฤษฎีของบาร์เดน และเพิ่มคุณลักษณะจำนวนการขยับร่างกาย/เปลี่ยนท่าทางที่ตรวจจับได้จากเซนเซอร์ ด้วยอัลกอริธึม KNN ซึ่งเป็นอัลกอริทึมการเรียนรู้ที่ไม่ซับซ้อน และมีประสิทธิภาพสำหรับการจำแนกข้อมูลและการรับรู้วัตถุ ซึ่ง KNN จะคำนวณระยะทางโดยปริภูมิแบบยุคลิด (S. Bo, D. Junping, and G. Tian, 2009) ดังสมการที่ 1

$$D(p, q) = \sqrt{(p_1 - q_1)^2 + (p_2 - q_2)^2 + \dots + (p_n - q_n)^2} \quad (1)$$

หลังจากนั้นพิจารณาเสียงข้างมากของจำนวนคลาสที่ใกล้ที่สุด K สำหรับการทำนายคลาสนั้น ๆ เป็นคำตอบ และ WKNN จะมีการปรับปรุงมาจาก KNN โดยจะเรียงลำดับจุดที่มีระยะทางใกล้กับจุดที่ต้องการทำนาย จำนวน K จุด และคำนวณค่าน้ำหนักแต่ละจุดไปยังจุดที่ต้องการทำนาย แล้วนำค่าน้ำหนักของจุดที่จำแนกอยู่ในคลาสนั้น ๆ มารวมค่าน้ำหนักของจุดในแต่ละคลาสเข้าด้วยกัน ซึ่งค่าน้ำหนักของจุดในคลาสนั้นไหนมากกว่ากัน ก็จะทำนายคลาสนั้นออกมาเป็นคำตอบ โดยสมการการหาค่าน้ำหนักของระยะทางดังสมการที่ 2

$$w_i = \frac{dk - di}{dk - d1} \quad (2)$$

การทดลองนี้ ได้พยายามที่จะใช้เทคนิคการเลือกคุณลักษณะ (Information Gain) เพื่อลดคุณลักษณะของชุดข้อมูลในการจำแนกระดับความเสี่ยงในการเกิดแผลกดทับ ซึ่งสูตรการคำนวณเอนโทรปีของชุดข้อมูลทั้งหมดและแต่ละคุณลักษณะของคลาสนั้นแสดงในสมการที่ 3

$$\text{Entropy} = \sum_i -p_i \log_2 p_i \quad (3)$$

จากนั้นคำนวณข้อมูลที่ได้รับในแต่ละคุณลักษณะ ในสมการที่ 4

$$\text{Gain}(S, A) = \text{Entropy}(S) - \sum_{i=1}^n \frac{|s_i|}{|s|} * \text{Entropy}(S_i) \quad (4)$$

สุดท้ายสามารถใช้คุณลักษณะที่ผ่านการกรองสำหรับการฝึกอบรมในรูปแบบ KNN และ WKNN เพื่อหาโมเดลที่มีประสิทธิภาพสูงสุดไปใช้ในการพัฒนาบริการ API ในขั้นต่อไป

4.3 การประเมินประสิทธิภาพของโมเดลและบริการเอพีไอเพื่อการจำแนกระดับความเสี่ยงการเกิดแผลกดทับของผู้ป่วยติดเตียง โดยการเรียนรู้ของเครื่องและเซนเซอร์
 ผู้วิจัยแบ่งชุดข้อมูลที่ใช้ในการฝึกสอนโมเดล และทดสอบความถูกต้องแม่นยำในการทำนาย ในอัตราส่วน 60 : 40 และได้กำหนดวิธีทดสอบประสิทธิภาพความแม่นยำในการจำแนกระดับความเสี่ยงของการเกิดแผลกดทับ แบ่งออกเป็น 3 ส่วน ได้แก่ 1) ผลการทดสอบประสิทธิภาพของ KNN และ KNN กับเทคนิค Information gain 2) ผลการทดสอบประสิทธิภาพของ WKNN และ WKNN กับเทคนิค Information gain และ 3) ผลการทดสอบประสิทธิภาพการเพิ่มคุณลักษณะ A7 ในการนับจำนวนการขยับร่างกาย/เปลี่ยนท่าทางมาเพิ่มในโมเดล KNN และ WKNN ที่มีการใช้ Information gain คัดคุณลักษณะออกจากเหลือ 3,4 และ 5 คุณลักษณะ

5. ผลการวิจัย

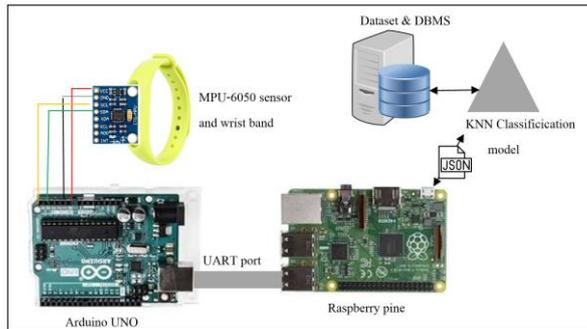
5.1 ผลการสร้างชุดข้อมูลในการจำแนกระดับความเสี่ยงการเกิดแผลกดทับของผู้ป่วยติดเตียง ที่รวบรวมจากแบบประเมินของบาร์เดน และเพิ่มเติมคุณลักษณะของจำนวนการขยับร่างกาย/เปลี่ยนท่าทางที่ตรวจจับได้จากเซนเซอร์ จากนั้นทำการระบุคลาสระดับความเสี่ยงของแผลกดทับในแต่ละรายการข้อมูลของผู้ป่วยโดยแพทย์และพยาบาลผู้เชี่ยวชาญ ดังแสดงในตารางที่ 2

ตารางที่ 2 ตัวอย่างจากชุดข้อมูลจริงที่ใช้ในการจำแนกระดับความเสี่ยงการเกิดแผลกดทับของผู้ป่วยติดเตียง

Patient code	A1	A2	A3	A4	A5	A6	A7	Total score (A1-A6)	Class
01	1	2	1	2	1	1	5	8	Very high risk
02	2	2	1	2	2	2	6	11	High risk
03	2	3	1	2	2	3	9	13	Moderate risk
04	2	4	3	2	3	3	10	17	Mild risk
05	3	4	3	4	3	3	13	20	No risk

5.2 ผลการพัฒนาโมเดลและบริการเอพีไอเพื่อการจำแนกระดับความเสี่ยงการเกิดแผลกดทับของผู้ป่วยติดเตียง แบ่งออกเป็น 3 ส่วน ดังนี้

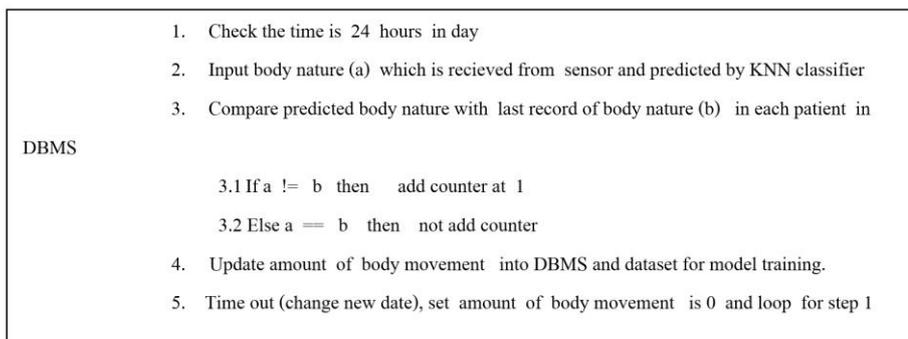
5.2.1 ผลการพัฒนาอุปกรณ์อิเล็กทรอนิกส์เพื่อเชื่อมต่อกับเซนเซอร์เพื่อนับจำนวนการขยับร่างกาย/เปลี่ยนท่าทาง เพื่อการทำนายระดับความเสี่ยงการเกิดแผลกดทับของผู้ป่วยติดเตียง โดยสามารถอธิบายการประสานงานของอุปกรณ์ฮาร์ดแวร์และซอฟต์แวร์ที่ใช้พัฒนาดังรูปที่ 1



รูปที่ 1 การเชื่อมต่ออุปกรณ์ฮาร์ดแวร์และซอฟต์แวร์เพื่อบันทึกจำนวนการขยับร่างกาย/เปลี่ยนท่าทาง

จากรูปที่ 1 บอร์ด Raspberry pine ใช้ในการประมวลผลเพื่อฝึกสอนโมเดลการจำแนกท่าทางและการนับจำนวนการเปลี่ยนท่าทาง โดยรับค่าของการหมุนของแกน x,y และ z ที่รับมาจากเซนเซอร์ MPU รุ่น 6050 ที่เชื่อมต่อกับบอร์ด Arduino รุ่น UNO ผ่านพอร์ต UART ไปยังโมเดลการจำแนกท่าทางที่ฝึกสอนจาก Dataset ที่ได้ทำการสร้างรายการข้อมูลเพื่อฝึกสอนให้โมเดลรับรู้ท่าทาง 5 ลักษณะ ได้แก่ นอนหงาย นอนคว่ำ นอนตะแคงขวา นอนตะแคงซ้าย และนั่ง จากนั้นจะส่งผลการทำนายไปยังเก็บในระบบจัดการฐานข้อมูล (DBMS) และทำการนับจำนวนการขยับตัวของผู้ป่วยในระยะเวลา 24 ชั่วโมง (ขั้นตอนวิธีดังรูปที่ 2) โดยการแลกเปลี่ยนข้อมูลระหว่างบอร์ด Raspberry pine กับการประมวลผลในการทำนายและการจัดการฐานข้อมูลในซอฟต์แวร์ฝั่ง Backend จะใช้การเข้าและถอดรหัสในรูปแบบ JSON

ขั้นตอนวิธีในการนับจำนวนการขยับตัวของผู้ป่วยในระยะเวลา 24 ชั่วโมง แสดงได้ดังรูปที่ 2

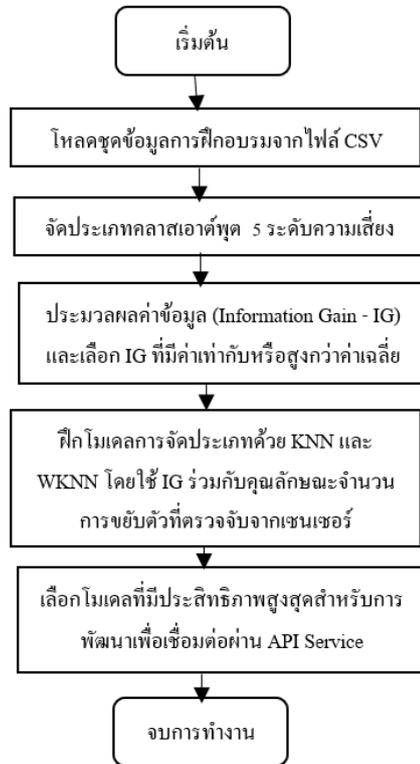


รูปที่ 2 ขั้นตอนวิธีในการนับจำนวนการขยับตัวของผู้ป่วยในระยะเวลา 24 ชั่วโมง

จากรูปที่ 2 ขั้นตอนวิธีเริ่มจากระบบจะมีการเริ่มจับและตรวจสอบเวลาว่าอยู่ใน 24 ชั่วโมงของวันที่ประมวลผลใช้หรือไม่ หากใช้จะมีการรับค่าการตรวจจับท่าทางจากเซนเซอร์และผลการทำนายลักษณะท่าทางว่าในปัจจุบันผู้ป่วยอยู่ในท่าทางใด ได้แก่ นอนหงาย นอนคว่ำ นอนตะแคงขวา นอนตะแคงซ้าย หรือนั่ง จากนั้นระบบทำการเปลี่ยนท่าทางปัจจุบันกับท่าทางก่อนหน้าที่เก็บไว้ในฐานข้อมูล ซึ่งหากมีการเปลี่ยนท่าทาง (ท่าทางไม่เหมือนกัน) ให้เพิ่มตัวนับการเปลี่ยนท่าอีก 1 แต่หากเป็นท่าทางเดิม จะไม่มีการนับเพิ่ม จากนั้นระบบจะทำการปรับปรุงจำนวนการเปลี่ยนท่าทางลงในฐานข้อมูล และไปปรับใน Dataset ในคุณลักษณะ (A7) Body movement step

เพื่อใช้ฝึกสอนโมเดลการจำแนกความเสี่ยงการเกิดแผลกดทับ และหากมีการตรวจ
 นับจนครบ 24 ชั่วโมง ก็จะเริ่มนับใหม่ และวนซ้ำมาทำงานในขั้นตอนที่ 1
 โดยกล่องจูลตรรกณีนี้อธิบายขั้นตอนแบบสองเกรด

5.2.2 กระบวนการพัฒนาโมเดลการจำแนกความเสี่ยงการเกิดแผลกดทับ
 ของผู้ป่วยติดเตียง เพื่อนำไปสู่การพัฒนาบริการ API มีดังนี้



รูปที่ 3 กระบวนการพัฒนาโมเดลการจำแนกความเสี่ยงการเกิดแผลกดทับของผู้ป่วยติดเตียง เพื่อนำไปสู่การพัฒนาบริการ API

ผลจากการประมวลผลและจัดอันดับของคุณลักษณะของความเสี่ยงในการเกิดแผลกดทับ สามารถเลือกคุณลักษณะที่มีการเรียงตามน้ำหนักสูงไปต่ำ และแบ่งเป็น 3 รอบ ในการทดสอบ เพื่อทดลองเลือกคุณลักษณะที่มีน้ำหนักต่ำออก เพื่อหาโมเดลที่มีประสิทธิภาพที่ดีที่สุดสำหรับการสร้างบริการ API ดังตารางที่ 3

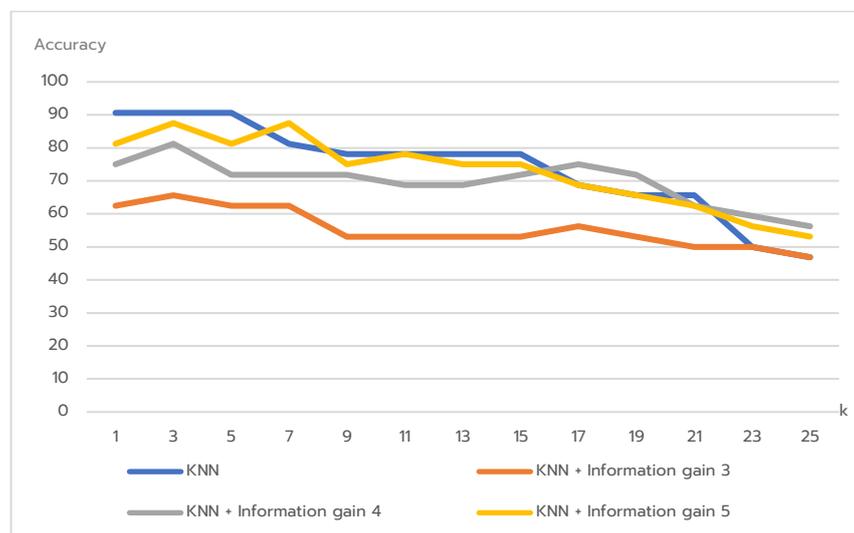
ตารางที่ 3 การประมวลผลและจัดอันดับของคุณลักษณะของความเสี่ยงในการเกิดแผลกดทับด้วยเทคนิค Information gain

Code	Feature	Information gain	Ranking	Select to KNN/WKNN (Round)		
				1	2	3
A1	Sensory	0.821	1	/	/	/
A2	Skin moisture	0.687	2	/	/	/
A3	Activity ability	0.633	4		/	/
A4	Movement ability	0.618	5			/
A5	Nutrition	0.636	3	/	/	/

A6	Strength and shear strength	friction	0.586	6
Average			0.664	

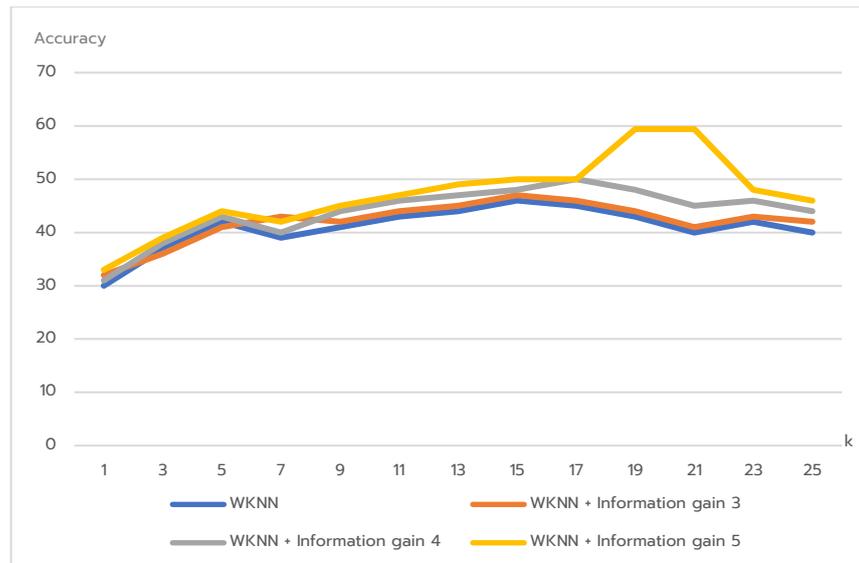
จากตารางที่ 3 เลือกคุณลักษณะที่มีค่าน้ำหนัก IG สูงสุดเพื่อฝึกสอนโมเดล KNN และ WKNN รอบแรกเลือก A1, A2 และ A5 รอบที่สองเพิ่ม A3 และรอบที่สามเพิ่ม A4

ผู้วิจัยนำเสนอผลการทดสอบประสิทธิภาพความแม่นยำในการจำแนกระดับความเสี่ยงของการเกิดแผลกดทับ แบ่งออกเป็น 3 ส่วน ได้แก่ 1) ผลการทดสอบประสิทธิภาพของ KNN และ KNN กับเทคนิค Information gain 2) ผลการทดสอบประสิทธิภาพของ WKNN และ WKNN กับเทคนิค Information gain และ 3) ผลการทดสอบประสิทธิภาพการเพิ่มคุณลักษณะ A7 ในการนับจำนวนการขยับร่างกาย/เปลี่ยนท่าทางมาเพิ่มในโมเดล KNN และ WKNN ที่มีการใช้ Information gain คัดคุณลักษณะออกจากเหลือ 3, 4 และ 5 คุณลักษณะ ซึ่งสามารถแสดงผลการทดสอบประสิทธิภาพดังรูปที่ 4 - รูปที่ 7



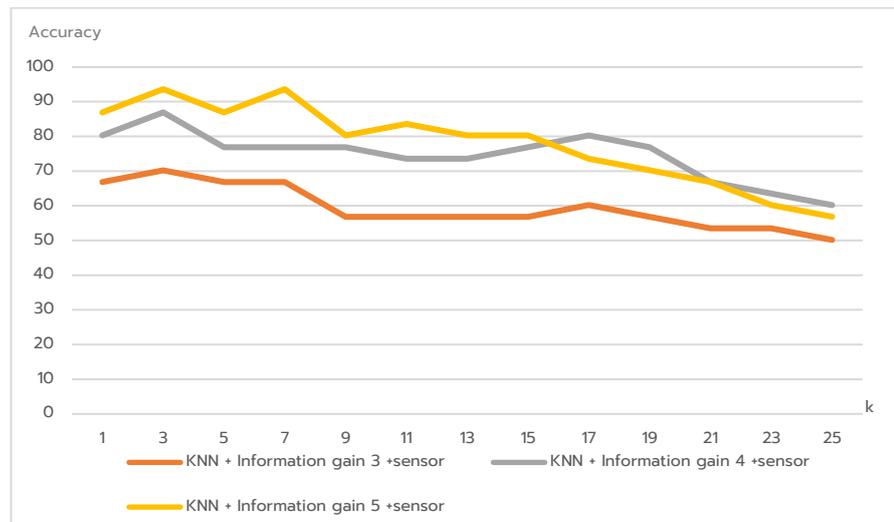
รูปที่ 4 ผลการทดสอบประสิทธิภาพของ KNN และ KNN กับเทคนิค Information gain

จากรูปที่ 4 พบว่า การจำแนกความเสี่ยงของแผลกดทับโดยใช้ KNN แบบทุกคุณลักษณะ (A1 - A6) ให้ความแม่นยำดีที่สุดที่ 90.6% ที่ k = 1, 3 และ 5 รองลงมาคือ KNN ที่ใช้ Information gain ในการลดคุณลักษณะ ดังนี้ 1) KNN แบบ 5 คุณลักษณะ (A1, A2, A3, A4 และ A5) ให้ความแม่นยำ 87.5% ที่ k = 3 และ 7 2) KNN แบบ 4 คุณลักษณะ (A1, A2, A3 และ A5) ให้ความแม่นยำ 81.3% ที่ k = 3 และ 3) KNN แบบ 3 คุณลักษณะ (A1, A2 และ A5) ให้ความแม่นยำ 65.6% ที่ k = 3



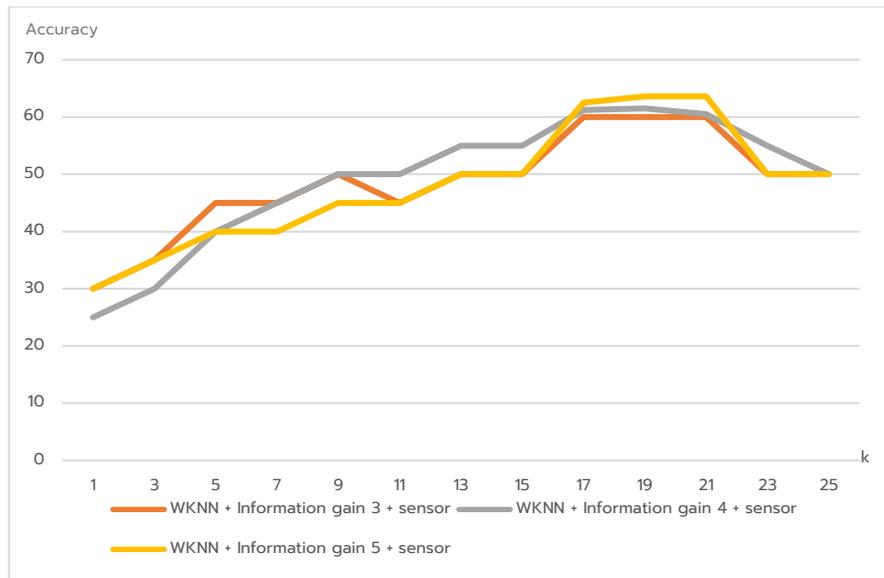
รูปที่ 5 ผลการทดสอบประสิทธิภาพของ WKNN และ WKNN กับเทคนิค Information gain

จากรูปที่ 5 พบว่า การจำแนกความเสี่ยงของแผลกดทับโดยใช้ WKNN กับ Information gain ในการลดคุณลักษณะเหลือ 5 คุณลักษณะ (A1, A2, A3, A4 และ A5) ให้ความแม่นยำสูงสุด 59.4% ที่ k = 19 และ 21



รูปที่ 6 ผลการทดสอบประสิทธิภาพการเพิ่มคุณลักษณะจากเซนเซอร์ในโมเดล KNN กับ Information gain

จากรูปที่ 6 พบว่า การเพิ่มคุณลักษณะจากเซนเซอร์ในการนับจำนวนการขยับร่างกาย/เปลี่ยนท่าทาง ร่วมกับการคัดเลือก Information gain แบบ 5 คุณลักษณะ (A1, A2, A3, A4 และ A5) ช่วยให้การสร้างโมเดล KNN มีความถูกต้องในการทำนายเพิ่มขึ้นเฉลี่ยร้อยละ 7 โดยให้ความแม่นยำสูงถึง 93.6% ที่ k = 3 และ 7

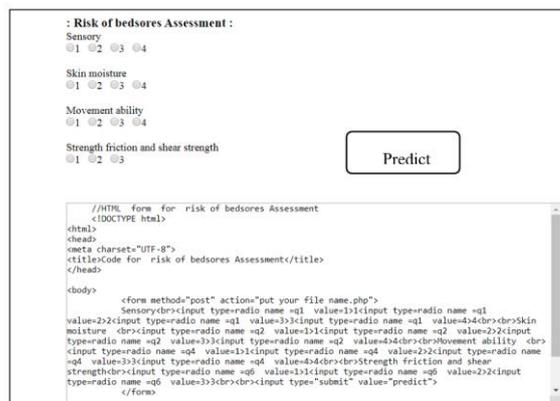


รูปที่ 7 ผลการทดสอบประสิทธิภาพการเพิ่มคุณลักษณะจากเซนเซอร์ในโมเดล WKNN กับ Information gain

จากรูปที่ 7 พบว่า การเพิ่มคุณลักษณะจากเซนเซอร์ในการนับจำนวนการขยับร่างกาย/เปลี่ยนท่าทาง ร่วมกับการคัดเลือก Information gain แบบ 5 คุณลักษณะ (A1, A2, A3, A4 และ A5) ช่วยให้การสร้างโมเดล WKNN มีความถูกต้องในการทำนายเพิ่มขึ้นเป็น 63.6% ที่ k = 19 และ 21

5.2.3 การพัฒนาบริการ API

ผู้วิจัยได้เลือกโมเดลการเพิ่มคุณลักษณะจากเซนเซอร์ในการนับจำนวนการขยับร่างกาย/เปลี่ยนท่าทาง ในโมเดล KNN กับ Information gain แบบนำเข้า 5 คุณลักษณะช่วยเพิ่มความถูกต้องในการทำนาย เจลลี่ร้อยละ 7 ที่ให้ความแม่นยำสูงสุด มาพัฒนาบริการ API โดยมีโครงสร้างที่แสดงด้วย Class diagram ดังรูปที่ 8



รูปที่ 8 บริการ API ส่วนที่ช่วยสร้างแบบฟอร์มรับข้อมูล

จากรูปที่ 8 บริการ API จะสร้างชุดคำสั่งเพื่อให้ผู้ใช้นำไปวางในซอฟต์แวร์ของตนเองใน 2 ส่วน คือ ส่วนที่ช่วยสร้างแบบฟอร์มรับข้อมูล ในรูปที่ 8 และชุดคำสั่ง

ดังผลการทำนาย ในรูปที่ 9 ซึ่งระบบจะทำการเชื่อมประสานมายัง โมเดลการให้บริการจำแนกระดับความเสี่ยงการเกิดแผลกตกับของผู้ป่วยติดเตียง ที่สร้างไว้บน Web server เมื่อ ผู้ใช้ทำการประเมินระดับศักยภาพและกดปุ่ม Predict ระบบก็จะส่งผลการทำนายกลับมาแสดงบนซอฟต์แวร์ของผู้ใช้

You are : At risk
Sum score : 5
Risk level : Very hight

```
//Put php code above or below html form
<?php
$q1=$_POST[q1];$q2=$_POST[q2];$q4=$_POST[q4];$q6=$_POST[q6];$url='http://127.0.0.1:85/knn/1246/'. $q1
.$q2.$q4.$q6;$data = file_get_contents($url);$characters = json_decode($data);$predicted =
$characters->predicted;$sumscore = $characters->sumscore;$result = $characters->result;echo 'You
are : '. $predicted.'  
';echo 'Sum score : '. $sumscore.'  
';echo 'Risk level : '.
$result.'  
'; ?>
```

รูปที่ 9 บริการ API ชุดคำสั่งดังผลการทำนาย

6. อภิปรายผลการวิจัย

จากงานวิจัยที่พัฒนาระบบสำหรับการทำนายความเสี่ยงการเกิดแผลกตกับในผู้ป่วยติดเตียง พบว่า การนำข้อมูลจาก IoT และเซนเซอร์ที่ตรวจจับการเคลื่อนไหว/เปลี่ยนท่าทางมาประยุกต์ร่วมกับการวิเคราะห์ด้วย Machine Learning สามารถเพิ่มประสิทธิภาพในการจำแนกความเสี่ยงได้อย่างชัดเจน โดยเฉพาะเมื่อมีการใช้เทคนิค feature selection ด้วย Information Gain เพื่อลดจำนวนคุณลักษณะให้น้อยลง แต่ยังคงความแม่นยำในการทำนายที่ขึ้นถึงร้อยละ 7 เมื่อเทียบกับวิธีที่ไม่มีการเลือกคุณสมบัตการเปรียบเทียบกับงานวิจัยของ Sirage Zeynu และ Shruti Patil (2018) ซึ่งใช้ Information Gain ในการเลือกคุณลักษณะสำหรับโมเดล KNN ในการทำนายโรคไตวายเรื้อรัง พบว่าแนวทางดังกล่าวสามารถลดจำนวนคุณลักษณะจาก 24 เหลือ 20 คุณลักษณะ แต่ยังคงความถูกต้องได้ถึง 98.75% แสดงให้เห็นว่าการเลือกคุณลักษณะที่เหมาะสมเป็นกลไกสำคัญที่ช่วยเพิ่มความแม่นยำและลดความซับซ้อนของระบบ และการพัฒนาและเปิดให้บริการระบบ API จะช่วยเพิ่มความสะดวกสบายในการเข้าถึงข้อมูล และใช้งานโมเดลทางปัญญาประดิษฐ์ที่มีความซับซ้อนในเชิงเทคนิค โดยใช้ไลบรารี Flask บน Python เพื่อสร้างสภาพแวดล้อมการเชื่อมโยงบริการไปยังผู้ใช้งานปลายทาง ซึ่งจะช่วยให้ระบบสามารถนำเสนอผลลัพธ์ในรูปแบบที่เข้าใจง่ายและพร้อมใช้งาน ซึ่งสอดคล้องกับงานวิจัยของ Modi and et al. (2024) ที่ประยุกต์ใช้ Flask Framework ในการพัฒนาเว็บแอปพลิเคชันที่สามารถวิเคราะห์ความรู้สึก (Sentiment Analysis) ของข้อความในสามประเภท ได้แก่ เชิงบวก เชิงลบ และเป็นกลาง โดยใช้ API ของ Twitter ในการดึงข้อมูลทวีตที่เกี่ยวข้องกับบวส์หรือหัวข้อที่สนใจ หลังจากดึงข้อมูลแล้ว ข้อมูลจะถูกวิเคราะห์และแสดงผลในรูปแบบที่เข้าใจง่ายและเป็นมิตรกับผู้ใช้ผ่านเว็บแอปพลิเคชันที่เปิดให้ผู้ใช้งานเข้าถึงได้อย่างแพร่หลาย

7. บทสรุป

งานวิจัยนี้ค้นหาโมเดลที่มีประสิทธิภาพในการทำนายระดับความเสี่ยงการเกิดแผลกดทับของผู้ป่วยติดเตียง และนำมาพัฒนาบริการ API สำหรับซอฟต์แวร์ภายนอกได้เข้ามาเชื่อมต่อกับบริการเหล่านั้น โดยที่บริการ API จะช่วยสนับสนุนให้โรงพยาบาลและผู้ดูแลผู้ป่วยสามารถเข้าถึงแอปพลิเคชันที่เข้ามาเชื่อมต่อเพื่อผลการทำนายการเกิดการแผลกดทับของผู้ป่วยติดเตียงได้ล่วงหน้าได้อย่างรวดเร็ว และมีความแม่นยำ รวมทั้งได้เสนอแนะวิธีการลดขนาดคุณสมบัติของคำถามการประเมินลงด้วยการใช้เทคนิค information gain โดยใช้คำถามเพียงไม่กี่ข้อร่วมกับคุณลักษณะเกี่ยวกับจำนวนการขยับร่างกายที่ตรวจจับได้จากเซนเซอร์มาใช้ในการสร้างโมเดลการทำนาย ทั้งนี้เทคนิคใหม่นี้ ช่วยทำให้มีความแม่นยำในการทำนายเพิ่มขึ้นถึงร้อยละ 7 นอกจากนี้ องค์ความรู้ของเทคนิคที่นำเสนอนี้ สามารถเป็นแนวทางให้เกิดการต่อยอดในการผสานความสามารถของ IoT กับ Machine Learning ในงานการประเมินและเฝ้าระวังภาวะสุขภาพด้านการแพทย์แบบเรียลไทม์ในกลุ่มโรคอื่นๆ ที่สามารถวินิจฉัยอาการเบื้องต้นได้จากค่าที่ตรวจวัดได้จากชุดเซนเซอร์ในรูปแบบต่างๆ

8. เอกสารอ้างอิง

- Akyildiz, I. F., Su, W., Sankarasubramaniam, Y., & Cayirci, E. (2002). Wireless sensor networks: A survey. *Computer Networks*, 38(4), 393-422.
- Arpita, J., & Ashish, M. (2018). Analysis of K-Nearest Neighbor technique for breast cancer disease classification. *International Journal of Recent Scientific Research*, 9(41), 26126-26130.
- Bergstrom, N., Braden, B. J., Laguzza, A., & Holman, V. (1987). The Braden Scale for Predicting Pressure Sore Risk. *Nursing Research*, 36(4), 205-210.
- Bo, S., Junping, D., & Tian, G. (2009). Study on the improvement of K-Nearest-Neighbor algorithm. In *Proceedings of the International Conference on Artificial Intelligence and Computational Intelligence (AICI 09)* (Vol. 4, pp. 390-393). IEEE Computer Society. <https://doi.org/10.1109/AICI.2009.312>
- Fielding, R. T. (2000). *Architectural styles and the design of network-based software architectures* (Doctoral dissertation, University of California, Irvine).
- Imandoust, S. B., & Bolandraftar, M. (2013). Application of K-Nearest Neighbor (KNN) approach for predicting economic events: Theoretical background. *International Journal of Engineering Research and Applications*, 3(5), 605-610.
- Jabbar, M. A., Deekshatulu, B. L., & Chandra, P. (2013). Classification of heart disease using K-Nearest Neighbor and Genetic Algorithm. In *International Conference on Computational Intelligence: Modeling Techniques and Applications (CIMTA)* (pp. 85-94).

- Jiricka, M. K., Ryan, P., Carvalho, M. A., & Bukvich, J. (1995). Pressure ulcer risk factors in an ICU population. *American Journal of Critical Care*, 4(5), 361-367.
- Mitchell, T. M. (1997). *Machine learning*. McGraw-Hill.
- Modi, A., Shah, K., Shah, S., Patel, S., & Shah, M. (2024). Sentiment analysis of Twitter feeds using flask environment: A superior application of data analysis. *Annals of Data Science*, 11(1), 159-180.
- Watbot Hospital. (2016). Interview contents for gathering problems in health care system of patients lying on bed. Phitsanulok: Watbot Hospital.
- Zeynu, S., & Patil, S. (2018). Prediction of chronic kidney disease using data mining feature selection and ensemble method. *International Journal of Pure and Applied Mathematics*, 118(24).