

การพยากรณ์น้ำหนักผู้ป่วยติดเตียงผ่านอุปกรณ์โคเนคโดยใช้กระบวนการปรับปรุงภาพด้วยตัวกรองแบบมีพื้นฐานร่วมกับโครงข่ายประสาทเทียม

วรพล มะโนสร้อย¹ อภิศักดิ์ พรหมผาย^{2*} และ ดุษฎี บุญธรรม³

มหาวิทยาลัยราชภัฏอุตรดิตถ์ อ.เมือง จ.อุตรดิตถ์ 53000

* Corresponding Author: Apisak.phr@uru.ac.th

¹ อาจารย์ หลักสูตรวิศวกรรมอิเล็กทรอนิกส์อัจฉริยะ คณะเทคโนโลยีอุตสาหกรรม

² ผู้ช่วยศาสตราจารย์ หลักสูตรวิศวกรรมคอมพิวเตอร์ คณะเทคโนโลยีอุตสาหกรรม

³ ผู้ช่วยศาสตราจารย์ หลักสูตรวิศวกรรมโลจิสติกส์ คณะเทคโนโลยีอุตสาหกรรม

ข้อมูลบทความ

บทคัดย่อ

ประวัติบทความ :

รับเพื่อพิจารณา : 20 กรกฎาคม 2564

แก้ไข : 9 สิงหาคม 2565

ตอบรับ : 16 สิงหาคม 2565

DOI : 10.14456/kmuttrd.2022.20

คำสำคัญ : โคเนค /

โครงข่ายประสาทเทียม /

การประมวลผลภาพ

การส่งถ่ายยาเพื่อรักษาผู้ป่วยติดเตียงจำเป็นต้องคำนวณปริมาณยาที่จะให้ผู้ป่วย โดยอ้างอิงจากน้ำหนักของผู้ป่วย ปัจจุบัน การหาค่าน้ำหนักของผู้ป่วยติดเตียงพบปัญหาหลายประการ เช่น กรณีการเคลื่อนย้ายผู้ป่วยไปยังน้ำหนัก อาจส่งผลให้ผู้ป่วยบาดเจ็บเพิ่มขึ้น การใช้เตียงที่สามารถชั่งน้ำหนักได้ ซึ่งมีราคาสูง ก็ส่งผลให้ต้นทุนในการรักษาเพิ่มขึ้น และการคาดคะเนน้ำหนักจากรูปร่างของผู้ป่วยก็มีความคลาดเคลื่อนสูง งานวิจัยนี้จึงนำเสนอวิธีพยากรณ์น้ำหนักผู้ป่วยติดเตียงผ่านโคเนค โดยใช้กระบวนการปรับปรุงภาพด้วยตัวกรองแบบมีพื้นฐานร่วมกับโครงข่ายประสาทเทียม ซึ่งทดสอบกับบุคคลทั่วไปแทนผู้ป่วยติดเตียงจำนวน 100 คน โดยแบ่งข้อมูลสำหรับการฝึกสอนโครงข่ายประสาทเทียม ทดสอบ และตรวจสอบความถูกต้อง เป็น 70% 15% และ 15% ตามลำดับ ออกแบบสถาปัตยกรรมของโครงข่ายประสาทเทียมทั้งหมด 18 รูปแบบ จากการทดสอบ พบว่า โครงข่ายประสาทเทียมที่เหมาะสมในการนำไปใช้พยากรณ์น้ำหนักมีจำนวนนิเวรอนในชั้นซ่อนเท่ากับ 3 วิธี ใช้การฝึกสอนโครงข่ายโดยอาศัย Levenberg-Marquardt algorithm และ ฟังก์ชันกระตุ้นเป็น tan-sigmoid transfer function โดยมีค่า R และ RMSE เท่ากับ 0.93393 และ 5.92 ตามลำดับ

Weight Prediction of Bedridden Patients via Kinect by Image Enhancement with Median Filler and Artificial Neural Network

Worapon Manosroi¹, Apisak Phromfaiy^{2*} and Dussadee Buntam³

Uttaradit Rajabhat University, Maung, Uttaradit 53000

* Corresponding Author: Apisak.phr@uru.ac.th

¹ Lecturer, Smart Electronic Engineering, Faculty of Industrial Technology at Uttaradit.

² Assistant Professor, Computer Engineering, Faculty of Industrial Technology at Uttaradit.

³ Assistant Professor, Logistic Engineering, Faculty of Industrial Technology at Uttaradit.

Article Info

Article History:

Received: July 20, 2021

Revised: August 9, 2022

Accepted: August 16, 2022

DOI : [10.14456/kmuttrd.2022.20](https://doi.org/10.14456/kmuttrd.2022.20)

Keywords : Kinect / Neural Network / Image Processing

Abstract

Drug dosage for treatment of bedridden patients need to calculated based on patient body weight. Currently, the methods for calculating such a weight exhibit many limitations, including the need to move a patient to weigh, which may worsen the symptoms of a patient. Weighing bed, which yields high accuracy, is nevertheless very expensive, making the treatment cost higher. Prediction of the weight from the patient size is also normally not accurate. The present research therefore proposed a method for predicting the weight of a bedridden patient by Kinect, with image enhancement using median filter and artificial neural network. One hundred weight data of normal people, which were used instead of those belonging to real patients, were divided into 3 groups for training, testing, and validation at 70%, 15%, and 15%, respectively. Eighteen neural network architectures were designed. The results showed that the suitable artificial neural network that could be used to predict the body weight consisted of 3 nodes in the hidden layers; Lavenberg-Maquardt algorithm should be used as the training function, while tan-sigmoid transfer function should be used as the activation function; R and RMSE values were noted to be 0.93393 and 5.92, respectively.


1. บทนำ

ปัจจุบันโรงพยาบาลต่าง ๆ มีผู้ป่วยมากมายที่เข้ามารักษา ซึ่งมีผู้ป่วยหลายประเภทด้วยกันไม่ว่าจะเป็น ผู้ป่วยที่ได้รับบาดเจ็บหรือเป็นโรคต่าง ๆ ที่สามารถช่วยเหลือตนเองได้ และไม่สามารถช่วยเหลือตนเองได้ ซึ่งการจ่ายยาให้กับผู้ป่วยนั้น เภสัชกรจะทำการคำนวณว่าผู้ป่วยคนนั้นจะต้องรับยาปริมาณเท่าไรจึงจะเหมาะสมโดยอ้างอิงจากน้ำหนัก ถ้าให้ยาเกินขนาด อาจจะทำให้ผู้ป่วยเป็นอันตรายได้ จาก การสำรวจข้อมูลเบื้องต้นพบว่า การชั่งน้ำหนักผู้ป่วยติดเตียง แบ่งเป็น 3 ประเภท 1) พยาบาลอุ้มผู้ป่วยพร้อมกับชั่งน้ำหนัก แล้วลบด้วยน้ำหนักของพยาบาลออก 2) พยาบาลทำการคาดคั้นด้วยสายตาจากการตรวจสอบจากรูปร่างภายนอก 3) ใช้เตียงผู้ป่วยที่มีเครื่องชั่งน้ำหนักในตัว ซึ่งมีราคาสูงและใช้ได้กับผู้ป่วยรายเดียว ซึ่งโดยทั่วไปหลายโรงพยาบาลจะใช้วิธีการคาดคั้นด้วยสายตาจากการตรวจสอบจากรูปร่างภายนอก เนื่องจากเป็นวิธีที่สะดวก แต่จะต้องใช้ประสบการณ์ จากการศึกษาโคเนค [1] มีคุณลักษณะในการจับภาพทั่วไปด้วย RGB Camera และยังมี 3D Depth Sensors ประกอบด้วย Depth Projector และ Depth Sensor ใช้ในการคำนวณหาระยะทางที่ห่างจากกล้องในช่วง 0.85 ถึง 4 เมตร และองศาการมองเห็น ในแนวนอน 57 องศา แนวตั้ง 43 องศา สามารถรวบรวมข้อมูลความลึกภายใต้ สภาพแสงใด ๆ ข้อมูลตำแหน่งพื้นผิววัตถุจะอยู่ในรูปแบบจุดพิกัดสามมิติ (X, Y และ Z) โดยตำแหน่งของจุดกำเนิด (X = Y = Z = 0) จะเป็นตำแหน่งของกล้องที่ใช้ในการตรวจจับการเคลื่อนไหว และมีทิศทางของแกน X, Y และ Z ซึ่งแกน Z จะเป็นทิศทางที่กล้องตรวจจับ ค่า X จะเป็นค่าแสดงระยะทางที่ห่างออกไปจากจุดกำเนิดตามแนวนอนสัมพันธ์กับกล้องที่ตรวจจับ ดังรูปที่ 1 [2]

ปัจจุบันมีการนำกล้องโคเนคมาประยุกต์กับหลายงานวิจัย เช่น Berger และคณะ [3] ได้ทำการศึกษาเกี่ยวกับการตรวจจับการเคลื่อนไหวโดยใช้โคเนค ทั้งหมด 4 ตัวในหลาย ๆ มุมมอง แล้วนำภาพความลึกของกล้องแต่ละตัวไปคำนวณหาตำแหน่งของข้อต่อของร่างกายผู้ถูกตรวจจับ Darina และคณะ [4] ได้ศึกษาหุ่นยนต์สร้างแผนที่สามมิติ โดยได้นำอุปกรณ์โคเนคเข้ามาใช้งานร่วมกับหุ่นยนต์ เพื่อใช้เป็นอุปกรณ์รับภาพ และความลึกเพื่อนำไปประมวลผลและสร้างแผนที่สามมิติในพื้นที่ที่มีความเสี่ยง สำหรับการ

วิเคราะห์น้ำหนักของวัตถุ มีหลายงานวิจัยที่ได้นำโคเนคและกล้องถ่ายภาพ 3 มิติมาประยุกต์ เช่น การนำโคเนคถ่ายภาพมุมมองด้านบนของสุกร 78 ตัว และนำภาพมาคำนวณทางคณิตศาสตร์โดยคิดรวมของพิกเซลในภาพของสุกรทั้งหมด [5-6] การประเมินน้ำหนักโคพินธุ์พื้นเมืองโดยการประมวลผลภาพ [7] การประเมินน้ำหนักลูกแกะด้วยกล้อง 3 มิติ [8] สำหรับการพยากรณ์มีหลายงานวิจัยได้นำโครงข่ายประสาทเทียมมาประยุกต์ใช้ เช่น Kavalerov และคณะ [9] ได้นำเสนอสถาปัตยกรรมโครงข่ายประสาทเทียมสำหรับการสร้างแบบจำลองการกำหนดค่าต่าง ๆ ในระบบไฟฟ้า Chen และคณะ [10] ได้สร้างโมเดลการทำนายค่าฝุ่น PM2.5 โดยใช้โครงข่ายประสาทเทียมแบบผสมโดยโมเดลนี้สามารถทำนายค่าฝุ่น PM2.5 ได้ทันที Chaisuwan และคณะ [11] ได้พัฒนาการคัดเลือกแบบแข่งขันของขั้นตอนวิธีทางพันธุกรรม สำหรับการพยากรณ์ปริมาณน้ำฝนด้วยโครงข่ายประสาทเทียม Prapaporn [12] ได้ศึกษาการวิเคราะห์ความสัมพันธ์ของปริมาณวัสดุก่อสร้างสำหรับอาคารคอนกรีตเสริมเหล็ก ระหว่างวิธีแบบจำลองการถดถอยเชิงซ้อน และวิธีโครงข่ายประสาทเทียม พบว่า วิธีโครงข่ายประสาทเทียมสามารถวิเคราะห์ความสัมพันธ์ได้แม่นยำกว่าวิธีแบบจำลองการถดถอยเชิงซ้อน

จากการศึกษางานวิจัยที่เกี่ยวข้องพบว่ายังไม่มีงานวิจัยได้นำหลักการประมวลผลภาพมาวิเคราะห์ร่วมกับโครงข่ายประสาทเทียมสำหรับการพยากรณ์น้ำหนักผู้ป่วยติดเตียงด้วยภาพความลึกจากอุปกรณ์ Kinect ดังนั้น งานวิจัยนี้จึงมีแนวคิดประยุกต์ใช้โคเนคร่วมกับวิธีการประมวลผลภาพและโครงข่ายประสาทเทียม เพื่อนำมาใช้สำหรับพยากรณ์น้ำหนักผู้ป่วยติดเตียง



รูปที่ 1 แกน X, Y และ Z ของกล้องโคเนค

2. วัสดุอุปกรณ์และวิธีการ

การพยากรณ์น้ำหนักผู้ป่วยติดเตียงผ่านโคเนคโดยใช้กระบวนการปรับปรุงภาพด้วยตัวกรองแบบมัลติฐานร่วมกับโครงข่ายประสาทเทียม มีส่วนประกอบและรายละเอียดที่เกี่ยวข้องดังต่อไปนี้

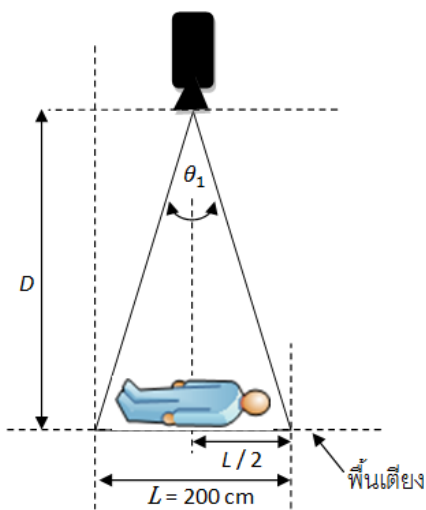
1.1 การออกแบบระยะการติดตั้งอุปกรณ์โคเนค

จากการศึกษาขอบเขตการมองเห็นของโคเนคพบว่า องศาการมองเห็นของโคเนค ในแนวแกน X คือ 57 องศา และแนวแกน Y คือ 43 องศา และขนาดของเตียงผู้ป่วยโดยทั่วไปจะมีขนาด 200 x 90 เซ็นติเมตร ดังนั้นขอบเขตการมองเห็นของโคเนค ที่สามารถมองเห็นทั่วเตียงสามารถคำนวณมุมมองดังต่อไปนี้

1.1.1 การคำนวณขอบเขตการมองเห็นของโคเนคในแนวแกน X

ผู้วิจัยได้กำหนดให้แนวแกน X ของโคเนคอยู่ในแนวเดียวกับด้านยาวของเตียงผู้ป่วยดังรูปที่ 2 และคำนวณหาระยะห่างระหว่างพื้นเตียงกับโคเนคที่สามารถมองเห็นพื้นที่เตียงทั้งหมดดังสมการที่ (1)

$$D = \frac{L/2}{\tan\left(\frac{\theta_1}{2}\right)} \tag{1}$$



รูปที่ 2 ขอบเขตการมองเห็นของโคเนคในแนวแกน X

โดยที่ θ_1 คือ องศาการมองเห็นของโคเนค ในแนวแกน X มีค่าเท่ากับ 57 องศา

D คือ ระยะห่างระหว่างพื้นเตียงกับโคเนค

L คือ ความยาวของเตียง

ดังนั้นความสูงที่ใช้สำหรับการติดตั้งโคเนคคือ 184.17 เซ็นติเมตร

1.1.2 การคำนวณขอบเขตการมองเห็นของโคเนคในแนวแกน Y

แนวแกน Y ของโคเนคอยู่ในแนวเดียวกับด้านกว้างของเตียงผู้ป่วยดังรูปที่ 3 เมื่อติดตั้งโคเนคในระยะที่คำนวณจากสมการที่ (1) จะสามารถคำนวณหาขอบเขตการมองเห็นของในแนวแกน Y ของโคเนคได้ดังสมการที่ (2)


$$W = 2 \left[\tan\left(\frac{\theta_2}{2}\right) \times D \right] \tag{2}$$

โดยที่ θ_2 คือ องศาการมองเห็นของโคเนค ในแนวแกน Y มีค่าเท่ากับ 43 องศา

X คือ ขอบเขตการมองเห็นของในแนวแกน Y

D คือ ระยะห่างระหว่างพื้นเตียงกับโคเนค

ดังนั้นความกว้างที่สามารถมองเห็นได้เมื่อติดตั้งโคเนคห่างจากพื้นเตียงเป็นระยะ 184.17 เซ็นติเมตร มีค่าเท่ากับ 145 เซ็นติเมตร



รูปที่ 3 ขอบเขตการมองเห็นของโคเนคในแนวแกน Y

2.2 ขั้นตอนการพยากรณ์น้ำหนักผู้ป่วยติดเตียง

2.2.1 การพยากรณ์น้ำหนักผู้ป่วยติดเตียง

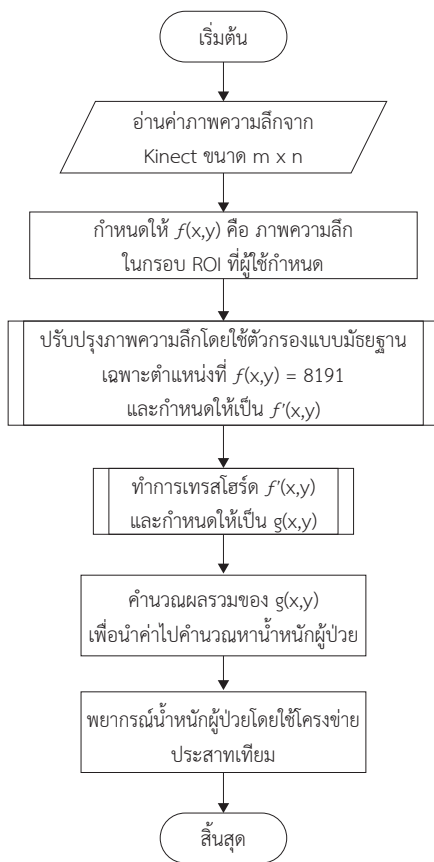
ด้วยโครงข่ายประสาทเทียม

ภาพความลึกคือระยะห่างระหว่างวัตถุกับโคเนคในพิกัด x, y ใด ๆ ซึ่งเมื่อนำเอาระยะห่างระหว่างวัตถุกับโคเนคของทุกพิกัด x, y มารวมกันจะได้ปริมาตรของพื้นผิววัตถุ อย่างไรก็ตามการหาปริมาตรของผู้ป่วยยังคงต้องผ่านกระบวนการดังรูปที่ 4 กระบวนการทำงานหาปริมาตรของผู้ป่วย ซึ่งประกอบด้วย 4 ขั้นตอนคือ

1) ขั้นตอนการสร้างกรอบ ROI

การสร้างกรอบ ROI คือการกำหนดขอบเฉพาะบริเวณที่ผู้ป่วยนอนราบกับพื้นเตียงเท่านั้น ซึ่งพยาบาลจะเป็นผู้กำหนด โดย ROI ที่เลือกใช้เป็นแบบกรอบสี่เหลี่ยม

2) ขั้นตอนการปรับปรุงภาพโดยใช้ตัวกรองแบบมัลติฐาน




รูปที่ 4 ขั้นตอนการพยากรณ์น้ำหนักผู้ป่วยติดเตียง

เนื่องจากภาพความลึกที่ได้จากโคเนคนั้น หากเกิดข้อผิดพลาดในการตรวจสอบค่าในตำแหน่งพิกเซลใด ๆ แล้วโคเนคจะคืนค่า 8191 ในตำแหน่งที่ตรวจสอบไม่ได้ เมื่อนำข้อมูลภาพความลึกมาแสดงเป็นภาพและผ่านกระบวนการ Negative Transformation ทำให้สามารถมองเห็นจุดผิดพลาดที่ชัดเจน ดังนั้นเพื่อลดค่าผิดพลาดที่เกิดจากโคเนค ผู้วิจัยจึงได้เลือกใช้ตัวกรองแบบมัลติฐานมาปรับปรุงภาพ เนื่องจากการกรองแบบนี้เหมาะกับการกำจัดสัญญาณรบกวนที่เป็นแบบสุ่มและไม่ลดความคมชัดของภาพ [13] แสดงดังรูปที่ 5 และแสดงเงื่อนไขการปรับปรุงภาพดังสมการที่ (3)


$$g(x, y) = \begin{cases} f'(x, y) & \text{if } f'(x, y) \geq T \\ 0 & \text{otherwise} \end{cases} \quad (3)$$

โดยสมการ ได้กำหนดค่าของสมการดังนี้ $f(x, y)$ คือ ภาพความลึกที่ได้จากโคเนค $f'(x, y)$ คือ ภาพความลึกที่ผ่านการกรองด้วย

median



(ก)



(ข)

รูปที่ 5 ภาพความลึกของผู้ป่วย (ก) ภาพต้นฉบับ (ข) ภาพหลังผ่านตัวกรองแบบมัลติฐาน

3) การทำเทรส์โฮร์ด

งานวิจัยนี้ได้นำค่าภาพความลึกที่ผ่านการกรองแบบมัลติสเกล ในช่วงกรอบ ROI ที่กำหนดถึงกรอบใหม่ที่มีขนาดเล็กกว่าเดิมด้านละ 10 พิกเซล ดังรูปที่ 6 มาคำนวณค่าเทรส์โฮร์ด (T) ดังสมการที่ (4) และสมการที่ (5) ขั้นตอนนี้เป็นกระบวนการย่อยต่อระหว่างผู้ป่วยกับพื้นเตียงออกจากกัน เพื่อให้สามารถหาผลรวมของปริมาตรผู้ป่วยได้ถูกต้องยิ่งขึ้น ซึ่งแสดงภาพหลังการทำเทรส์โฮร์ดดังรูปที่ 7

$$g(x, y) = \begin{cases} f'(x, y) & \text{if } f'(x, y) \geq T \\ 0 & \text{otherwise} \end{cases} \quad (4)$$

$$T = \frac{\sum_{x=0}^{m-1} \sum_{y=0}^{n-1} f'(x, y) - \sum_{x=9}^{m-10} \sum_{y=9}^{n-10} f'(x, y)}{(m \times n) - [(m-10) \times (n-10)]} \quad (5)$$


โดยสมการ ได้กำหนดค่าของสมการดังนี้

- $g(x, y)$ คือ ภาพความลึกที่ผ่านการทำเทรส์โฮร์ด
- T คือ ค่าเทรส์โฮร์ด
- m คือ จำนวนแถว
- n คือ จำนวนหลัก


ภาพความลึกที่ผ่านการทำเทรส์โฮร์ดจะถูกนำมาคำนวณหาปริมาตรของผู้ป่วยโดยการรวมค่าความลึกแต่ละพิกเซลของภาพความลึกดังสมการที่ (6) ซึ่งสามารถแสดงตัวอย่างข้อมูลค่าปริมาตรของผู้ป่วยและน้ำหนักจริงได้ดังตารางที่ 1 จากนั้นข้อมูลจะถูกนำไปพยากรณ์น้ำหนักผู้ป่วยติดเตียงด้วยโครงข่ายประสาทเทียม

$$V = \sum_{x=0}^{m-1} \sum_{y=0}^{n-1} g(x, y) \quad (6)$$

- โดยที่ V คือ ปริมาตรของผู้ป่วย
- m คือ จำนวนแถวของภาพที่ผ่านการทำเทรส์โฮร์ด
- n คือ จำนวนหลักของภาพที่ผ่านการทำเทรส์โฮร์ด



รูปที่ 6 กรอบ ROI สำหรับคำนวณหาค่าเทรส์โฮร์ด



รูปที่ 7 ภาพผู้ป่วยหลังการทำเทรส์โฮร์ด

ตารางที่ 1 ข้อมูลปริมาตรของผู้ป่วยจากภาพความลึกและน้ำหนักจริงของผู้ป่วย

Number	Volume	Weight (Kg)
1	6074322	42.4
2	6311674	46.3
3	6752098	51.9
4	6930388	54.3
5	7744364	58.3
6	8020024	60.8
...
98	14846360	98.4
99	16101000	103.6
100	16530640	106

(4) การประยุกต์โครงข่ายประสาทเทียม


โครงข่ายประสาทเทียมเป็นการจำลองการทำงานของโครงข่ายประสาทในสมองมนุษย์ เพื่อสร้างโมเดลทางคณิตศาสตร์ที่ช่วยในการเรียนรู้ การจดจำรูปแบบ เช่นเดียวกับสมองของมนุษย์ สำหรับงานวิจัยนี้ได้นำโครงข่ายประสาทเทียมแบบแพร่กระจายย้อนกลับ (Feed-forward Back-propagation) [14] มาประยุกต์ใช้ในการพยากรณ์น้ำหนักผู้ป่วยติดเตียง โดยข้อมูลป้อนเข้าเป็นผลรวมปริมาตรของผู้ป่วย ผลลัพธ์ที่ต้องการเป็นน้ำหนักผู้ป่วยติดเตียงแสดงดังรูปที่ 8 การออกแบบการทดลองเพื่อหาสถาปัตยกรรมของโครงข่ายประสาทเทียมที่เหมาะสม (Optimum Model) ที่ทำให้ค่ารากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ยในการพยากรณ์ต่ำที่สุด ผู้วิจัยได้ออกแบบสถาปัตยกรรมของโครงข่ายประสาทเทียมจำนวน 18 รูปแบบ โดยแต่ละรูปแบบจะมีจำนวนนิวรอนในชั้นซ่อนที่แตกต่างกันคือ 3 และ 5 นิวรอน สำหรับการกำหนดค่าผลลัพธ์ของโครงข่ายประสาทเทียมจะถูกกำหนดโดยฟังก์ชันกระตุ้น (Activation Function) ในบทความนี้เลือกใช้ 3 ฟังก์ชันซึ่งเป็นวิธีที่ได้รับความนิยมเป็นอย่างมาก ได้แก่ 1) Linear Transfer Function (purelin) 2) log-sigmoid transfer function (logsig) และ 3) tan-sigmoid transfer function (tansig) โดยคำนวณได้จากสมการ (7) (8) และ (9) ตามลำดับ

$$f(n) = n \tag{7}$$

$$f(n) = \frac{1}{1 + e^{(-n)}} \tag{8}$$

$$f(n) = \frac{1 - e^{(-n)}}{1 + e^{(-n)}} \tag{9}$$

โดยที่ n = ข้อมูลนำเข้า
 f = ฟังก์ชันกระตุ้น



รูปที่ 8 โครงข่ายประสาทเทียม

สำหรับฟังก์ชันการฝึกสอนโครงข่ายประสาทเทียมประกอบด้วย 3 ฟังก์ชัน ได้แก่ 1) Batch Gradient Descent (traingd) 2) Batch Gradient Descent with Momentum (traingdm) 3) Levenberg-Marquardt (trainlm) [15]

2.2.2 การพยากรณ์น้ำหนักผู้ป่วยติดเตียงด้วยการถดถอยเชิงเส้น

การวิเคราะห์การถดถอยเชิงเส้นอย่างง่ายเป็นสถิติที่ใช้ในการหาความสัมพันธ์ระหว่างตัวแปรอิสระ 1 ตัวและตัวแปรตาม 1 ตัวโดยตัวแปรทั้งสองมีความสัมพันธ์เชิงเส้นตรงกันอาจเป็นความสัมพันธ์ตามกันหรือผกผันก็ได้ ซึ่งการวิเคราะห์นี้เป็นพื้นฐานที่ง่ายที่สุดของการวิเคราะห์การถดถอยเชิงเส้น [16] โดยสามารถเขียนได้ดังสมการที่ (10)

$$Y_i = \beta_0 + \beta_i X_i + \varepsilon_i$$

โดยที่ Y_i = ตัวแปรตาม

X_i = ตัวแปรอิสระ

β_i = ค่าสัมประสิทธิ์

ε_i = ค่าความคลาดเคลื่อน

(10)

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Q_i - E)^2}$$

(12)

โดยที่ Q = น้ำหนักจริงของผู้ป่วยติดเตียง
 E = น้ำหนักที่ได้จากการพยากรณ์
 N = จำนวนข้อมูลทั้งหมด

สำหรับขั้นตอนการวิเคราะห์นั้น คณะผู้วิจัยได้นำข้อมูลค่าปริมาตรของผู้ป่วยและน้ำหนักจริงจากตารางที่ 1 มาตรวจสอบตามลำดับดังนี้ 1) ตรวจสอบส่วนตกค้างของข้อมูลว่ามีการกระจายแบบปกติหรือไม่ 2) วิเคราะห์ความแปรปรวน 3) วิเคราะห์สมการถดถอยเชิงเส้น

3. ผลการทดลอง

3.1 ผลการวิเคราะห์การพยากรณ์น้ำหนักด้วย

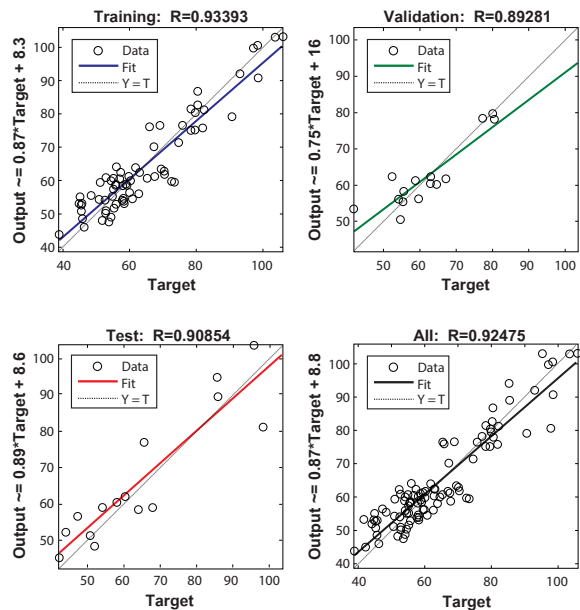
โครงข่ายประสาทเทียม

งานวิจัยนี้ได้ทดสอบกับบุคคลทั่วไปแทนผู้ป่วยติดเตียง จำนวน 100 คน ซึ่งมีน้ำหนักอยู่ระหว่าง 40-110 กิโลกรัม โดยแบ่งข้อมูลสำหรับการฝึกสอนโครงข่ายประสาทเทียม ทดสอบ และ ตรวจสอบความถูกต้องเป็น 70% 15% และ 15% ตามลำดับ ในการแบ่งสัดส่วนของชุดข้อมูลไม่มีสูตรสำเร็จตายตัว แต่หลักการใหญ่ทั่วไปคือ ข้อมูลที่ใช้ในการฝึกสอนควรมีสัดส่วนมากกว่าชุดทดสอบ เพื่อให้เกิดความแม่นยำ [17] จากการทดลองเพื่อหาค่าตัวแบบพยากรณ์ที่เหมาะสมในการพยากรณ์น้ำหนัก จากตัวแบบพยากรณ์ทั้ง 18 ตัวแบบ ค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation coefficient: R) และค่ารากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Squared Error : RMSE) แสดงดังสมการที่ (11) และ (12) ตามลำดับ [18] ได้ถูกนำมาใช้สำหรับการพิจารณาเลือกสถาปัตยกรรมของโครงข่ายประสาทเทียมที่เหมาะสมที่สุดสำหรับการพยากรณ์น้ำหนัก

$$R = \frac{\sum_{i=1}^N (Q_i - \bar{Q})(E_i - \bar{E})}{\sqrt{\sum_{i=1}^N (Q_i - \bar{Q})^2 \sum_{i=1}^N (E_i - \bar{E})^2}}$$

(11)

จากตารางที่ 2 พบว่าสถาปัตยกรรมของโครงข่ายประสาทเทียมที่เหมาะสม ที่จะนำไปใช้ในการพยากรณ์น้ำหนัก พิจารณาจากค่า R และ RMSE ซึ่งแสดงให้เห็นถึงความสามารถในการเรียนรู้ความสัมพันธ์ระหว่างข้อมูลป้อนเข้ากับผลลัพธ์ได้เป็นอย่างดีที่สุด พบว่าโครงข่ายประสาทเทียมที่เหมาะสมในการนำไปใช้พยากรณ์น้ำหนักคือรูปแบบที่ 9 ซึ่งมีค่า R และ RMSE เท่ากับ 0.93393 และ 5.92 ตามลำดับ โดยมีจำนวนนิวรอนในชั้นซ่อนเท่ากับ 3 มีวิธีการฝึกสอนโครงข่ายที่เหมาะสมคือ วิธี Levenberg-Marquardt Algorithm และฟังก์ชันกระตุ้นคือ tan-sigmoid transfer function ซึ่งสามารถแสดงความสัมพันธ์ระหว่างน้ำหนักจริงและน้ำหนักที่พยากรณ์ ดังรูปที่ 9



รูปที่ 9 ความสัมพันธ์ระหว่างน้ำหนักจริงและน้ำหนักที่พยากรณ์ด้วยวิธีโครงข่ายประสาทเทียม

ตารางที่ 2 ประสิทธิภาพการพยากรณ์น้ำหนักของสถาปัตยกรรมของโครงข่ายประสาทเทียม 18 รูปแบบ

Model	Topology	Activation Function	Training Function	Correlation coefficient (Training)	RMSE
1	1-3-1	purelin	traingd	0.89168	14.14
2	1-3-1	purelin	traingdm	0.92769	14.56
3	1-3-1	purelin	trainlm	0.92998	5.94
4	1-3-1	logsig	traingd	0.83596	8.82
5	1-3-1	logsig	traingdm	0.85779	13.49
6	1-3-1	logsig	trainlm	0.92393	5.66
7	1-3-1	tansig	traingd	0.88405	11.77
8	1-3-1	tansig	traingdm	0.83363	11.65
9	1-3-1	tansig	trainlm	0.93393	5.92
10	1-5-1	purelin	traingd	0.54625	23.35
11	1-5-1	purelin	traingdm	0.88638	6.46
12	1-5-1	purelin	trainlm	0.90598	5.86
13	1-5-1	logsig	traingd	0.84245	15.94
14	1-5-1	logsig	traingdm	0.89587	8.35
15	1-5-1	logsig	trainlm	0.92227	5.82
16	1-5-1	tansig	traingd	0.87158	16.18
17	1-5-1	tansig	traingdm	0.87885	12.32
18	1-5-1	tansig	trainlm	0.93344	5.7

จากรูปที่ 9 แสดงความสัมพันธ์ระหว่างน้ำหนักจริง และน้ำหนักพยากรณ์ที่ได้จากโครงข่ายประสาทเทียม โดยแบ่งข้อมูลเป็น 4 ส่วนได้แก่ ข้อมูลสำหรับฝึกสอนโครงข่ายประสาทเทียม ข้อมูลสำหรับตรวจสอบความถูกต้อง ข้อมูลสำหรับทดสอบ และข้อมูลภาพรวมทั้งหมด พบว่ามีค่า R เป็น 0.93393 0.89281 0.90854 และ 0.92475 ตามลำดับ

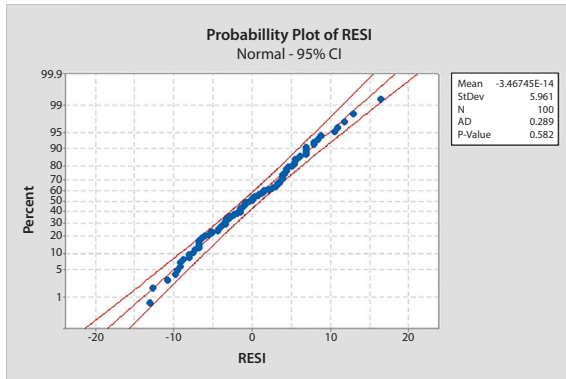
3.2 ผลการวิเคราะห์การพยากรณ์น้ำหนักด้วยการถดถอยเชิงเส้น

การวิเคราะห์การถดถอยเชิงเส้นอย่างง่าย (simple linear regression analysis) คณะผู้วิจัยได้นำข้อมูลค่าปริมาตรของผู้ป่วยและน้ำหนักจริงจากรูปที่ 1 มาตรวจสอบส่วนตกค้างของข้อมูลว่ามีการกระจายแบบปกติ

หรือไม่ จากการพิจารณาการกระจายส่วนตกค้าง ดังรูปที่ 10 พบว่ามีการกระจายตัวตามแนวเส้นตรง แสดงให้เห็นว่าส่วนตกค้างจากผลการทดลอง ไม่แสดงสิ่งผิดปกติ และค่า P-Value มีค่ามากกว่า 0.05 สรุปได้ว่าข้อมูลที่ได้จากการทดลองชุดนี้มีการกระจายแบบแจกแจงปกติ สามารถนำไปวิเคราะห์ความแปรปรวน และวิเคราะห์สมการถดถอยเชิงเส้นได้ แสดงดังตารางที่ 3 และ ตารางที่ 4 ตามลำดับ


จากตารางที่ 3 พบว่าค่า P-value ของสมการถดถอยเชิงเส้นมีค่าน้อยกว่า 0.05 แสดงว่าสมการถดถอยเชิงเส้นส่งผลต่อการทำนายน้ำหนักและตัวแปรอิสระสามารถทำนายตัวแปรตามได้อย่างมีนัยสำคัญ ซึ่งสามารถเขียนสมการถดถอยเชิงเส้นได้ดังสมการที่ (13)

$$Weight = 0.000006Volume + 6.05 \quad (13)$$



รูปที่ 10 กราฟความน่าจะเป็นแบบปกติของส่วนตกค้างของข้อมูล

เมื่อวิเคราะห์ความสัมพันธ์ระหว่างน้ำหนักจริงและน้ำหนักพยากรณ์ที่ได้จากสมการที่ (13) โดยใช้ข้อมูลทั้งหมด 100 ข้อมูล พบว่ามีค่า R เป็น 0.92033 ดังรูปที่ 11



รูปที่ 11 ความสัมพันธ์ระหว่างน้ำหนักจริงและน้ำหนักที่พยากรณ์ด้วยวิธีการถดถอยเชิงเส้น

ตารางที่ 3 การวิเคราะห์ความแปรปรวนของข้อมูลปริมาตรของผู้ป่วยจากภาพความลึกและน้ำหนักจริงของผู้ป่วย

Source	DF	SS	MS	F	P
Regression	1	19479	19479.0	542.59	0.000
Error	98	3518	35.9		
Total	99	22997			

ตารางที่ 4 การวิเคราะห์การถดถอยเชิงเส้นของข้อมูลปริมาตรของผู้ป่วยจากภาพความลึกและน้ำหนักจริงของผู้ป่วย

Predictor	Coef	Se Coef	T	P
Constant	1	19479	19479.0	542.59
Volume	98	3518	35.9	

S = 5.99165 R-Sq = 84.70% R-Sq(adj) = 84.55%

4. สรุปและอภิปรายผล

งานวิจัยนี้ได้นำเสนอวิธีการพยากรณ์น้ำหนักผู้ป่วยติดเตียงผ่านโคเนคโดยใช้กระบวนการปรับปรุงภาพด้วยตัวกรองแบบมัลติสเกลร่วมกับโครงข่ายประสาทเทียม โดยได้ออกแบบสถาปัตยกรรมของโครงข่ายประสาทเทียมทั้งหมด 18 รูปแบบ จากการทดสอบบุคคลทั่วไปแทนผู้ป่วยติดเตียงจำนวน 100 คน พบว่าโครงข่ายประสาทเทียมที่เหมาะสมในการนำไปใช้พยากรณ์น้ำหนักคือรูปแบบที่ 9 ซึ่งมีค่า R และ RMSE เท่ากับ 0.93393 และ 5.92 ตามลำดับ โดยมีจำนวนนิวรอนในชั้นซ่อนเท่ากับ 3 มีวิธีการฝึกสอนโครงข่ายที่เหมาะสมคือ วิธี Levenberg-Marquardt algorithm ฟังก์ชันกระตุ้นคือ tan-sigmoid transfer function และเมื่อเปรียบเทียบความสัมพันธ์ระหว่างน้ำหนักจริงและน้ำหนักที่พยากรณ์ด้วยข้อมูลทั้งหมด โดยใช้วิธีโครงข่ายประสาทเทียมและวิธีการถดถอยเชิงเส้น มีค่า R เท่ากับ 0.92475 และ 0.92033 ตามลำดับ ดังนั้นวิธีโครงข่ายประสาทเทียมสามารถพยากรณ์ค่าน้ำหนักได้แม่นยำกว่าวิธีการถดถอยเชิงเส้น อย่างไรก็ตาม ค่าน้ำหนักที่ได้จากการพยากรณ์ยังคงมีค่าผิดพลาด ดังนั้นในงานวิจัยในอนาคตคณะผู้วิจัยจึงมีแนวคิดนำกระบวนการ meta heuristic มาประยุกต์ใช้สำหรับการฝึกสอนโครงข่ายประสาทเทียม เพื่อลดค่าผิดพลาดในการพยากรณ์น้ำหนักผู้ป่วยติดเตียง

5. เอกสารอ้างอิง

1. Microsoft Co., 2011, Xbox 360 Kinect Sensor, United States of America, pp. 1-18.
2. Kaenchan, S., Mongkolnam, P., Watanapa, B. and Sathienpong, S., 2013, "Automatic Multiple Kinect Cameras Setting for Simple Walking Posture Analysis," *International Computer Science and Engineering Conference (ICSEC)*, Nakhon Pathom, pp. 245-249.
3. Berger, K., Ruhl, K., Brummer, C., Schroder, Y., Scholz, A. and Magnor, M., 2011, "Markerless Motion Capture using Multiple Color-Depth Sensors," *16th International Workshop on Vision, Modeling, and Visualization (VMV 2011)*, 4-6 October 2011, Berlin, Germany.
4. Darina, K., Alexander R., Miroslav C. and Vladimir T., 2017, "Utilisation of Kinect Sensors for the Design of a Human-robot Collaborative Woekcell," *Advances in Science and Technology Research Journal*, 11 (4), pp. 270-278.
5. Kongsro, J., 2014, "Estimation of Pig Weight Using a Microsoft Kinect Prototype Imaging System," *Computers and Electronics in Agriculture*, 109 (1), pp. 32-35.
6. Pezzuolo, A., Guarino, M., Sartori, L. González, L. and Marinello, F., 2018, "On-barn Pig Weight Estimation Based on Body Measurements by a Kinect v1 Depth Camera," *Computers and Electronics in Agriculture*, 148 (1), pp. 29-36.
7. Wongtrairat, W., Sapon, T. and Wongsuthavas, S., 2016, "Weight Estimation of Native Cow by Image Processing," *Engineering, Science, Technology and Architecture Conference 2016*, Nakhon Ratchasima, pp. 682-685. (In Thai).
8. Samperio, E., Lidón, I., Rebollar, R., Castejón-Limas, M. and Álvarez-Aparicio, C., 2021, "Lambs' Live Weight Estimation Using 3D Images," *Animal*, 15 (8), pp. 1-7.
9. Kavalero, B., Kilin, G. and Suslov, A., 2020, "Neural Network Architecture Choice for Modelling Various Configuration Power System," *International Conference on Innovation Energy 2020 (IE 2020)*, Perm, Russia, pp. 1-7.
10. Chen, Y., Lei, T., Yao, S. and Wang, H., 2020, "PM2.5 Prediction Model Based on Combinational Hammerstein Recurrent Neural Networks," *Mathematics*, 8 (12), pp. 1-23.
11. Chaisuwan, T., Suksawang, P. and Mekpanyup, J., 2020, "Development of Tournament Selection of Genetic Algorithm for Forecasting Rainfall with Artificial Neural Network," *Princess of Naradhiwas University Journal*, 12 (3), pp. 245-261. (In Thai).
12. Prapaporn, W., 2019, «An Analysis on Material Quantity Relationship of Reinforced Concrete Buildings between Multiple Linear Regression and Artificial Neural Network,» *Naresuan University Engineering Journal*, 14 (1), pp. 84 - 102, 2019.
13. Pattajarukul, B., 2013, *Fundamentals of Digital Image Processing*, Se-Education, Bangkok, p. 384.
14. Sibi, P., Joned, S. and Siddarth, P., 2013, "Analysis of Different Activation Functions Using Back Propagation Neural Networks," *Journal of Theoretical and Applied Information Technology*, 47 (3), pp. 1264-1268.
15. The MathWorks, Inc., 2004, *Neural Network Toolbox User's Guide*, Massachusetts, pp. 1-846.
16. N. Katemukda, 2021, "Regression Analysis Applying for Defection Rescreening of Microelectronics Product," *Ladkrabang Engineering Journal*, 38(4), pp. 42-50.
17. Lei, S., Zhang, H., Wang, K. and Su, Z., 2019, "How Training Data Affect the Accuracy and Robustness of Neural Networks for Image Classification,"

International Conference on Learning Representations, New Orleans, Louisiana, pp. 1-14.

18. Buntam, D., Permpoonsinsup, W. and Surin, P., 2020, "The Application of a Hybrid Model Using Mathematical Optimization and Intelligent Algorithms for Improving the Talc Pellet Manufacturing Process," *Symmetry*, 12 (10), pp. 1-18.