

การประยุกต์ใช้เทคนิคค่าเฉลี่ยกับค่าสหสัมพันธ์ไขว้ในการจำแนกอารมณ์บนใบหน้า An Application of K-Means and Cross-Correlation Techniques for Facial Emotion Recognition

สุชาติ แยมเม่น¹ และ พันธุ์ธิดา ลิ้มศรีประพันธ์^{1*}

¹ภาควิชาวิศวกรรมไฟฟ้าและคอมพิวเตอร์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยนเรศวร sucharty@nu.ac.th, phantidal62@nu.ac.th*

บทคัดย่อ

งานวิจัยนี้นำเสนอสถาปัตยกรรมสำหรับการรู้จำอารมณ์บนใบหน้า (Facial Emotion Recognition - FER) แบบจำเพาะเจาะจงบุคคล ที่มีประสิทธิภาพสูงและสามารถอธิบายผลได้ เพื่อแก้ไขข้อจำกัดด้านความซับซ้อนในการคำนวณของแบบจำลองการเรียนรู้เชิงลึก เปรียบวิธีที่นำเสนอมีพื้นฐานจากการประมวลผลสัญญาณดิจิทัล โดยประยุกต์ใช้เทคนิคค่าเฉลี่ย (K-Means) เพื่อสกัดเวกเตอร์คุณลักษณะต้นแบบ (Template Vector Feature) จากพื้นที่การเปลี่ยนแปลง (Area of Change) ที่สำคัญ และใช้ชุดตัวกรองเปรียบเทียบ (Matched Filter) ภายใต้โครงสร้างแบบสองขั้นตอน (Two-Stage Structure) เพื่อจำแนกอารมณ์ ผลการทดสอบบนชุดข้อมูล JAFFE สำหรับบุคคลเป้าหมายโดยใช้การทวนสอบแบบไขว้ แสดงให้เห็นว่าสถาปัตยกรรมที่นำเสนอสามารถจำแนกอารมณ์พื้นฐานทั้ง 7 ได้อย่างสมบูรณ์ด้วยความแม่นยำ 100% ผลลัพธ์นี้ยืนยันศักยภาพของแนวทางที่นำเสนอในการสร้างระบบรู้จำอารมณ์ที่มีความแม่นยำสูง น้ำหนักเบา และสามารถปรับให้เข้ากับผู้ใช้แต่ละรายได้อย่างมีประสิทธิภาพ

คำสำคัญ: ค่าสหสัมพันธ์ไขว้ อัลกอริทึมค่าเฉลี่ย การจำแนกอารมณ์บนใบหน้า

Abstract

This research proposes a high-performance, explainable, and person-specific architecture for Facial Emotion Recognition (FER) that addresses the computational complexity limitations commonly found in deep learning models. The proposed methodology is based on digital signal processing and leverages K-Means clustering to extract template vector features from critical areas of change. A matched filter set under a two-stage structure is then applied for emotion classification. Experiments conducted on the JAFFE dataset using cross-validation for targeted individuals demonstrate that the proposed architecture can perfectly classify all seven basic emotions with an accuracy of 100%. These results highlight the potential of the proposed approach in building highly accurate, lightweight, and user-adaptive emotion recognition systems.

Keywords: Cross-Correlation, K-mean Algorithm, Facial Emotion Recognition

1. ข้อมูลทั่วไป


ระบบรู้จำอารมณ์บนใบหน้า (Facial Expression Recognition - FER) เป็นเทคโนโลยีที่มีบทบาทสำคัญอย่างยิ่งในหลายสาขา ไม่ว่าจะเป็นการแพทย์ทางไกล ระบบปฏิสัมพันธ์ระหว่างมนุษย์กับเครื่องจักร (HCI) และการเฝ้าระวังด้านความปลอดภัย ความสามารถของระบบ FER ในการวิเคราะห์อารมณ์จากภาพใบหน้าโดยอัตโนมัติช่วยเพิ่มความเข้าใจอย่างลึกซึ้งในสถานะทางอารมณ์ของผู้ใช้งาน ซึ่งเป็นสิ่งสำคัญสำหรับการพัฒนาระบบที่มีความเข้าใจและตอบสนองได้ดียิ่งขึ้น [1 – 5]

ปัจจุบันเทคนิคโครงข่ายประสาทเทียมแบบลึก (Deep Learning) โดยเฉพาะโครงข่ายคอนโวลูชัน (Convolutional Neural Network: CNN) เป็นแนวทางหลักที่ได้รับความนิยมและแม่นยำสูง อย่างไรก็ตามการประยุกต์ใช้โมเดลเหล่านี้บนอุปกรณ์ที่มีทรัพยากรจำกัด เช่น ระบบสมองกลฝังตัว หรือ อุปกรณ์พกพา ยังคงเป็นความท้าทาย เนื่องจากโมเดลเหล่านี้มักประกอบด้วยพารามิเตอร์จำนวนมาก จึงต้องการหน่วยความจำและพลังงานในการประมวลผลสูง อีกทั้งยังขาดความสามารถในการตีความภายในอย่างชัดเจน [6 – 9] นอกจากนี้วิธีการประมวลผลสัญญาณดิจิทัล (Digital Signal Processing - DSP) เช่น ตัวกรองแบบ Gabor หรือ การวิเคราะห์ลักษณะภาพด้วย Local Binary Patterns (LBP) สามารถสกัดคุณลักษณะใบหน้าจากฐานข้อมูล JAFFE หรือ FER2013 ได้ดีในสถานะแวดล้อมที่ควบคุมได้ ยังคงมีข้อจำกัดสำคัญเมื่อต้องเผชิญกับความแปรปรวนในโลกความเป็นจริง ได้แก่ สภาพแสง มุมกล้อง และความแตกต่างเฉพาะตัวของใบหน้าแต่ละบุคคล อีกทั้งยังขาดความสามารถในการประมวลผลแบบเรียลไทม์บนอุปกรณ์ที่มีทรัพยากรจำกัด เช่น IoT หรือ Edge Computing [10 - 11]

ดังนั้น งานวิจัยนี้จึงนำเสนอระบบรู้จำอารมณ์บนใบหน้าแบบจำเพาะเจาะจงที่มีประสิทธิภาพสูง ใช้ทรัพยากรในการคำนวณน้อย น้ำหนักเบา และสามารถอธิบายผลลัพธ์ได้ โดยออกแบบบนพื้นฐานของเทคนิคประมวลผลสัญญาณดิจิทัลควบคู่กับการวิเคราะห์กลุ่มข้อมูล (Cluster Analysis) และประยุกต์ใช้วิธีค่าเฉลี่ย (K-Means) เพื่อสกัดเวกเตอร์คุณลักษณะจากพื้นที่การเปลี่ยนแปลง (Area of Change) สำคัญบนใบหน้า และนำไปใช้ร่วมกับชุดตัวกรองเปรียบเทียบ (Matched Filter Bank) ภายใต้โครงสร้างการจำแนกอารมณ์แบบสองขั้นตอน (Two-Stage Classification) ที่ถูกออกแบบเพื่อเพิ่มความแม่นยำการจำแนกระหว่างอารมณ์ที่มีลักษณะคล้ายคลึงกันจากอารมณ์พื้นฐานทั้งเจ็ด ได้แก่ ความสุข (Happiness), ความประหลาดใจ (Surprise), ความเศร้า (Sadness), ความรังเกียจ (Disgust), ความกลัว (Fear), ความโกรธ (Anger), และอารมณ์เป็นกลาง (Neutral) โดยประเมินประสิทธิภาพระบบที่นำเสนอบนชุดข้อมูล JAFFE โดยใช้วิธีทวนสอบแบบไขว้ (Cross-Validation)

2. วิธีการวิจัย

ในการวิจัยครั้งนี้ คณะวิจัยใช้ชุดข้อมูล JAFFE (Japanese Female Facial Expression Database) ที่ประกอบด้วยภาพนิ่งของผู้หญิงญี่ปุ่นจำนวน 10 คน รวมทั้งสิ้น 213 ภาพ ที่แสดงอารมณ์พื้นฐาน 7 อารมณ์ ซึ่งจัดสภาพแวดล้อมที่ควบคุมทั้งด้านแสง มุมกล้อง และท่าทางทำให้เหมาะสมสำหรับการออกแบบและทดสอบระบบ FER ที่มุ่งจำแนกอารมณ์จากใบหน้าบุคคลเดียวโดยไม่พึ่งพาข้อมูลจากหลายบุคคล [12 - 13] ระบบที่พัฒนามีขั้นตอนหลัก 4 ขั้นตอน ได้แก่ การปรับปรุงคุณภาพภาพ การสร้างเวกเตอร์คุณลักษณะและชุดตัวกรองเปรียบเทียบ การสร้างระบบจำแนกประเภทอารมณ์แบบสองขั้นตอน และการประเมินประสิทธิภาพของระบบ ดังรูปที่ 1



รูปที่ 1 สถาปัตยกรรมระบบจำแนกอารมณ์ที่นำเสนอ

2.1 การปรับปรุงคุณภาพภาพ

การเตรียมภาพใบหน้าให้มีคุณภาพดีและพร้อมสำหรับการวิเคราะห์เป็นขั้นตอนแรกที่สำคัญ คณะวิจัยได้ดำเนินการ 2 ขั้นตอน ดังนี้

2.1.1 การประมาณการภาพด้วยตัวทำนายเชิงเส้น

ในขั้นตอนการปรับปรุงคุณภาพภาพ เทคนิคการทำนายเชิงเส้น (Linear Prediction) ถูกนำมาประยุกต์ใช้เพื่อลดสัญญาณรบกวน โดยมีแนวคิด คือ การประมาณค่าพิกเซลจุดศูนย์กลางใดๆ จากผลรวมเชิงเส้นของพิกเซลใกล้เคียงทั้ง 8 ทิศทาง

สำหรับภาพระดับเทา $I \in \mathbb{R}^{M \times N}$ เราจะสร้างปัญหากำลังสองน้อยที่สุด (Least Squares Problem) โดยพิจารณาจากหน้าต่างย่อย (patch) ขนาด 3×3 ที่จะเลื่อนไปที่ละพิกเซล จำนวน $K = (M - 2)(N - 2)$ หน้าต่างในภาพ ทำให้ได้เมทริกซ์ข้อมูล $X \in \mathbb{R}^{K \times 8}$ และเวกเตอร์เป้าหมาย $\bar{y} \in \mathbb{R}^{K \times 1}$ ดังสมการ (1)

$$X = \begin{bmatrix} \bar{x}_1 \\ \bar{x}_2 \\ \vdots \\ \bar{x}_K \end{bmatrix}, \quad \bar{y} = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_K \end{bmatrix} \quad (1)$$

โดยที่สำหรับแต่ละหน้าต่างย่อยที่ i ซึ่งมีจุดศูนย์กลางอยู่ที่พิกเซล $I_{(r,c)}$

$\bar{x}_i \in \mathbb{R}^{1 \times 8}$ คือ เวกเตอร์พิกเซลใกล้เคียงทั้ง 8 ของพิกเซล $I_{(r,c)}$

y_i คือ พิกเซลจุดศูนย์กลาง $I_{(r,c)}$ ของหน้าต่างย่อยที่ i

จากนั้นทำการหาค่าเวกเตอร์น้ำหนัก $\bar{w} \in \mathbb{R}^{8 \times 1}$ ที่เรียนรู้จากข้อมูลด้วยวิธีกำลังสองน้อยที่สุด (Least Squares) ซึ่งให้ผลเฉลยดังสมการ (3)

$$\bar{w} = (X^T X)^{-1} X^T \bar{y} \quad (3)$$

เวกเตอร์น้ำหนัก $\bar{w}$ ที่ได้จะถูกนำไปใช้ประมาณค่าพิกเซลจุดศูนย์กลางทั้งหมดเพื่อสร้างเวกเตอร์ประมาณการ $\hat{y} \in \mathbb{R}^{K \times 1}$ ดังสมการ (4)

$$\hat{y} = X \bar{w} \quad (4)$$

สุดท้ายเวกเตอร์ประมาณการ $\hat{y}$ จะถูกปรับเปลี่ยนรูปทรง (reshape) กลับไปเป็นเมทริกซ์ของภาพประมาณการ $\hat{I} \in \mathbb{R}^{M \times N}$ ที่ขอบภาพยังคงใช้ค่าพิกเซลเดิม แต่มีสัญญาณรบกวนลดลง (อัตราส่วนสัญญาณต่อสัญญาณรบกวน หรือ SNR สูงขึ้น) ทำให้มีความคมชัดพร้อมสำหรับขั้นตอนต่อไป

2.1.2 การลงทะเบียนใบหน้าแบบ 3 จุดเชิงเรขาคณิต

ขั้นตอนนี้ใช้เทคนิคการปรับภาพให้ตรงกัน (Image Registration) เพื่อให้ภาพใบหน้าทุกภาพอยู่ในพิกัดเดียวกันกับภาพต้นแบบอ้างอิง โดยมีวัตถุประสงค์เพื่อให้ตำแหน่งของการเปลี่ยนแปลงของกล้ามเนื้อใบหน้า (Facial Action Units: AUs) มีความแม่นยำตรงกันทุกภาพ ซึ่งจะช่วยให้ค่าพิกเซลที่เบี่ยงเบนสะท้อนเฉพาะการเคลื่อนไหวของกล้ามเนื้อใบหน้า ไม่ถูกรบกวนจากการขยับศีรษะ ใบหน้า หรือ มุมกล้อง

คณะวิจัยได้กำหนดใช้จุดศูนย์กลางของตำแหน่งอ้างอิง 3 จุดบนใบหน้า ได้แก่ ตาซ้าย (P_L) ตาขวา (P_R) และปลายจมูก (P_N) ซึ่งเป็นตำแหน่งที่มีความเสถียรและสามารถตรวจจับได้อย่างแม่นยำในทุกอารมณ์และท่าทางของใบหน้า โดยภาพต้นแบบอ้างอิง (T) ถูกสร้างจากค่าเฉลี่ยของภาพใบหน้าอารมณ์เป็นกลางจำนวน 3 ภาพของบุคคลหนึ่งเพื่อใช้เป็นแม่แบบในการจัดแนว จากนั้นนำภาพใบหน้าผ่านการปรับปรุงคุณภาพที่ต้องการจัดแนว มากำหนดตำแหน่ง P_L, P_R, P_N เช่นกัน

การหาตัวแปลงเชิงเรขาคณิตแบบ Similarity Transform ที่เหมาะสมระหว่างจุด P_L, P_R, P_N ของภาพเป้าหมายและภาพอ้างอิง ทำได้โดยวิธีกำลังสองน้อยที่สุดของ Umeyama [14] เพื่อคำนวณพารามิเตอร์การแปลงที่ดีที่สุด ได้แก่ มุมหมุน (θ) การปรับขนาด (s) และเวกเตอร์การเลื่อนตำแหน่ง (t_x, t_y) พารามิเตอร์เหล่านี้สามารถนิยามในรูปของเมทริกซ์เอกพันธ์ (homogeneous Transformation matrix) ดังสมการ (5)


$$A = \begin{bmatrix} s \cdot \cos(\theta) & -s \cdot \sin(\theta) & t_x \\ s \cdot \sin(\theta) & s \cdot \cos(\theta) & t_y \\ 0 & 0 & 1 \end{bmatrix} \quad (5)$$

ค่า A ที่คำนวณได้จะถูกนำไปใช้ในการแปลงพิกเซลของภาพเป้าหมายให้ตรงกับภาพอ้างอิงโดยใช้เทคนิค inverse mapping และ bilinear interpolation เพื่อให้ได้ค่าพิกเซลที่แม่นยำในภาพที่ลงทะเบียนแล้ว ผลลัพธ์ คือ ภาพใบหน้าที่ทุกๆ จุดสำคัญ ถูกจัดให้อยู่ตำแหน่งพิกเซลเดียวกันกับภาพต้นแบบทำให้พร้อมสำหรับการเปรียบเทียบและสกัดคุณลักษณะในขั้นตอนต่อไป

2.2 การสกัดและสร้างเวกเตอร์คุณลักษณะต้นแบบ

2.2.1 การกำหนดพื้นที่การเปลี่ยนแปลง

หลังจากภาพทั้งหมดได้ผ่านการปรับปรุงคุณภาพภาพ ขั้นตอนต่อไป คือ การกำหนดพื้นที่สำหรับการสกัดเวกเตอร์คุณลักษณะเพื่อนำไปสร้างตัวกรองเปรียบเทียบ ในงานวิจัยนี้ได้เลือกพื้นที่การเปลี่ยนแปลง (Area of Change - AOC) จำนวน 16 พื้นที่บนใบหน้าอารมณ์เป็นกลางของบุคคลต้นแบบใช้ในการศึกษาดังรูปที่ 2



รูปที่ 2 ตำแหน่ง 16 พื้นที่การเปลี่ยนแปลงบนอารมณ์เป็นกลางที่กำหนด

พื้นที่ที่เลือกมีความสอดคล้องกับการเปลี่ยนแปลงทางกายภาพที่สำคัญเมื่อแสดงทั้ง 7 อารมณ์ในชุดข้อมูล JAFFE และเชื่อมโยงกับหน่วยการเคลื่อนไหวกล้ามเนื้อบนใบหน้า (Facial Action Units - AUs) ในระบบ Facial Action Coding System (FACS) ของ Ekman & Friesen [15] ดังตารางที่ 1

ตารางที่ 1 ความเชื่อมโยงระหว่าง AOC และ AUs ที่เกี่ยวข้อง

AOC	AUs	คำอธิบายและเหตุผลในการเลือก
A1, A2, A3	AU1: Inner Brow Raiser, AU4: Brow Lowerer	ครอบคลุมบริเวณหน้าผากและหัวคิ้ว เพื่อตรวจจับการเลี้ยวที่เป็นลักษณะเฉพาะของอารมณ์ประหลาดใจและกลัว หรือ การขมวดคิ้วของอารมณ์โกรธและเสียใจ
A4, A5	AU2: Outer Brow Raiser	การยกตัวของหางคิ้วซึ่งเป็นลักษณะเฉพาะของอารมณ์ประหลาดใจและกลัว
A6, A7	AU5: Upper Lid Raiser, AU7: Lid Tightener	บริเวณเปลือกตาบนและล่าง เพื่อตรวจจับการเปิดตากว้างที่เป็นลักษณะของอารมณ์ประหลาดใจและกลัว หรือ การหรี่ตาที่เป็นลักษณะของอารมณ์โกรธและรังเกียจ
A8	AU9: Nose Wrinkler	บริเวณสันจมูกเป็นตัวบ่งชี้ที่สำคัญอย่างยิ่งสำหรับอารมณ์รังเกียจ
A9	AU10: Upper Lip Raiser	บริเวณเหนือริมฝีปากบน เพื่อตรวจจับการยกริมฝีปากบนขึ้นของอารมณ์รังเกียจและโกรธ
A10, A11	AU11: Nasolabial Furrow Deepener	บริเวณร่องแก้ม ซึ่งจะลึกขึ้นอย่างเห็นได้ชัดในอารมณ์มีความสุขและอารมณ์รังเกียจ
A12, A13	AU12: Lip Corner Puller, AU15: Lip Corner Depressor	บริเวณมุมปาก เป็นส่วนที่สำคัญที่สุดในการแยกแยะอารมณ์มีความสุข (ยกมุมปาก) และ อารมณ์เสียใจ (คว่ำมุมปาก)
A14	AU17: Chin Raiser	บริเวณคาง เพื่อตรวจจับการยกและยื่นของคาง ซึ่งมักพบในอารมณ์เสียใจและอารมณ์โกรธ
A15, A16	AU23: Lip Tighten, AU26: Jaw Drop	บริเวณริมฝีปากและใต้ริมฝีปาก เพื่อตรวจจับอารมณ์โกรธ (การเม้มปาก) หรือ อารมณ์ประหลาดใจ (การอ้าปาก)

2.2.2 การสร้างเวกเตอร์คุณลักษณะด้วยเทคนิคค่าเฉลี่ย

ในขั้นตอนนี้ จะใช้ภาพอ้างอิงของบุคคลต้นแบบที่ผ่านการปรับปรุงคุณภาพของแต่ละอารมณ์จำนวน 7 ภาพ เพื่อดึงข้อมูลพื้นที่ของการเปลี่ยนแปลงระดับเทาที่แทนด้วยเมทริกซ์ $A_{i,k} \in \mathbb{R}^{W \times H}$ โดยที่ i คือ ตำแหน่งพื้นที่การเปลี่ยนแปลง $i \in \{1, 2, 3, \dots, 16\}$ และ k คือ ดัชนีแทนอารมณ์บนใบหน้า $k \in \{1, 2, 3, \dots, 7\}$ ซึ่งมีความหมายดังตารางที่ 2

ตารางที่ 2 การอธิบายดัชนี k ที่แทนอารมณ์บนใบหน้า

ดัชนี k	อารมณ์บนใบหน้า	ตัวย่อ	จำนวนภาพ
1	อารมณ์เป็นกลาง (Neutral)	NE	3
2	อารมณ์ประหลาดใจ (Surprise)	SU	3
3	อารมณ์โกรธ (Anger)	AN	3
4	อารมณ์รังเกียจ (Disgust)	DI	3
5	อารมณ์มีความสุข (Happiness)	HA	4
6	อารมณ์ความเศร้า (Sadness)	SA	3
7	อารมณ์ความกลัว (Fear)	FE	4

จากนั้น เมทริกซ์ $A_{i,k}$ จะถูกแปลงเป็นเวกเตอร์ $\vec{a}_{i,k} \in \mathbb{R}^{WH \times 1}$ เพื่อประยุกต์ใช้แนวคิดการวิเคราะห์กลุ่มข้อมูล (Cluster Analysis) และ อัลกอริทึมค่าเฉลี่ยเค (K-mean) เพื่อหาจุดศูนย์กลาง $c_{i,k}$ เพื่อเป็นตัวแทนของการกระจายค่าความเข้มในพื้นที่การเปลี่ยนแปลงที่ดีที่สุดและทนทานต่อค่าผิดปกติ (Outliers) [16-17] การกำหนดปัญหาในลักษณะนี้สามารถเขียนในรูปค่าที่เหมาะสมที่สุด (Optimization Problem) ที่ต้องการลดค่าแอลนอร์ม (L_1 - norm) ของเวกเตอร์ความคลาดเคลื่อนระหว่างค่าพิกเซลจุดศูนย์กลางของกลุ่มดังกล่าว (6)

$$c_{i,k} = \min_c \|\vec{a}_{i,k} - \vec{c}\|_1 \quad (6)$$

ค่าจุดศูนย์กลาง $c_{i,k}$ ที่ได้จะถูกนำไปใช้สร้างเวกเตอร์คุณลักษณะ (Feature Vector) $\vec{e}_{i,k}$ ที่ถูกจัดอรรถิพลของค่าความสว่างโดยรวม (Global Intensity) ในบริเวณนั้นออกไปเหลือไว้เพียงรูปแบบการกระจายของความเข้มที่สำคัญต่อการจำแนกอารมณ์ ดังสมการ (7)

$$\vec{e}_{i,k} = \vec{a}_{i,k} - c_{i,k} \quad (7)$$

เวกเตอร์คุณลักษณะ $\vec{e}_{i,k}$ ที่ได้จะถูกนำไปใช้ในการวิเคราะห์เพื่อสร้างเวกเตอร์คุณลักษณะต้นแบบสำหรับใช้ตรวจสอบหาลักษณะเฉพาะของการเปลี่ยนแปลงเชิงพื้นที่สำหรับแต่ละอารมณ์ในขั้นตอนต่อไป

2.3 การสร้างเวกเตอร์เปรียบเทียบจำแนกอารมณ์

2.3.1 ค่าสหสัมพันธ์ไขว้เทียบมาตรฐาน

เพื่อลดความซับซ้อนของการคำนวณ คณะผู้วิจัยจึงต้องการคัดเลือกเฉพาะพื้นที่การเปลี่ยนแปลงที่มีนัยสำคัญในการจำแนกอารมณ์เท่านั้น จึงทดสอบโดยใช้เวกเตอร์คุณลักษณะ $\vec{e}_{i,k}$ สำหรับทุกอารมณ์ k ของพื้นที่การเปลี่ยนแปลงที่ $i = 1 \dots 16$ จากภาพอ้างอิงที่ใช้ในขั้นตอนการสร้างเวกเตอร์เปรียบเทียบ เพื่อหาค่าสหสัมพันธ์ไขว้เทียบมาตรฐาน $NCC_{i,k}$ (Normalized Cross-Correlation) สำหรับตรวจสอบค่าความเหมือนระหว่างแต่ละอารมณ์ในพื้นที่เปลี่ยนแปลงเดียวกัน ดังสมการ (8)

$$NCC_{i,k} = \frac{\sum_{n=1}^L \vec{e}_{i,k}(n) \vec{F}_{i,k}(n)}{\|\vec{e}_{i,k}\|_2 \|\vec{F}_{i,k}\|_2} \quad (8)$$

กำหนดให้ $\vec{F}_{i,k}$ คือ เวกเตอร์คุณลักษณะต้นแบบในพื้นที่การเปลี่ยนแปลงที่ i ของอารมณ์ k ค่า $NCC_{i,k}$ ที่ได้จะอยู่ในช่วง $[-1, +1]$ โดยหากค่ายังเข้าใกล้ $+1$ แสดงว่า เวกเตอร์คุณลักษณะของพื้นที่การเปลี่ยนแปลงนั้นมีความเหมือนกับตัวกรองเปรียบเทียบที่กำลังพิจารณาสูง ค่านี้จะถูกนำมาใช้เป็นค่าขีดเริ่มเปลี่ยน (Threshold) ในการบ่งชี้ว่าพื้นที่การเปลี่ยนแปลงนั้น สามารถจำแนกอารมณ์ k ได้มากน้อยเพียงใดในการสร้างชุดตัวกรองจำแนกอารมณ์ที่ต้องการนำเสนอ ผลการทดสอบ พบว่า พื้นที่บริเวณคิ้ว (A4, A5) พื้นที่บริเวณเปลือกตาบน (A6, A7) และพื้นที่บริเวณมุมปาก (A12, A13) เป็นบริเวณที่ให้ค่าความเหมือนสูงสุดในการจำแนกและครอบคลุมความแตกต่างของอารมณ์หลักได้ดีที่สุด

2.3.2 การสร้างชุดตัวกรองการจำแนกอารมณ์

คณะผู้วิจัยเลือกเฉพาะพื้นที่การเปลี่ยนแปลงที่ให้ค่าความเหมือนสูงสุดในการจำแนกจำนวน 6 ตำแหน่ง คือ $i \in \{4,5,6,7,12,13\}$ มาสร้างเป็นเวกเตอร์คุณลักษณะต้นแบบ ซึ่งเกิดจากการต่อเวกเตอร์คุณลักษณะของพื้นที่การเปลี่ยนแปลงที่มีนัยสำคัญมาสร้างเป็นชุดตัวกรองเปรียบเทียบจำนวน 2 ชุด ประกอบไปด้วย

ชุดตัวกรองหลัก (Primary Filter Bank) $\vec{F}_{1,k}$

ทำหน้าที่จำแนกอารมณ์ที่มีการเปลี่ยนแปลงเด่นชัดบริเวณคิ้วทั้งสองข้าง (A4,A5) โดยใช้เวกเตอร์คุณลักษณะจากพื้นที่การเปลี่ยนแปลงที่ $i \in \{4,5\}$ เพื่อจำแนก 5 อารมณ์ ดังสมการ (9)

$$\vec{F}_{1,k} = \begin{bmatrix} \vec{e}_{4,k} \\ \vec{e}_{5,k} \end{bmatrix}, \forall k \in \{1, 2, 3, 4, 5\} \quad (9)$$

ชุดตัวกรองยืนยันผล (Refinement Filter Bank) $\vec{F}_{2,k}$

ทำหน้าที่จำแนกสองอารมณ์ที่ซับซ้อนและไม่สามารถจำแนกได้จากชุดตัวกรองหลัก โดยใช้พื้นที่ที่มีความแตกต่างเด่นชัดระหว่างสองอารมณ์นี้ตามที่ได้อธิบายในตารางที่ 1 ได้แก่ บริเวณเปลือกตาบน (A6, A7) เพื่อตรวจสอบการเบิกตากว้างซึ่งเป็นการเปลี่ยนแปลงที่สำคัญของอารมณ์กลัว (FE) และพื้นที่บริเวณมุมปาก (A12, A13) เพื่อตรวจสอบการความมุมปากซึ่งเป็นการเปลี่ยนแปลงที่สำคัญของอารมณ์เสียใจ (SA) โดยใช้เวกเตอร์คุณลักษณะจากพื้นที่การเปลี่ยนแปลงที่ $i \in \{6,7,12,13\}$ เพื่อจำแนกสองอารมณ์ ดังสมการ (10)

$$\vec{F}_{2,k} = \begin{bmatrix} \vec{e}_{6,k} \\ \vec{e}_{7,k} \\ \vec{e}_{12,k} \\ \vec{e}_{13,k} \end{bmatrix}, \forall k \in \{6, 7\} \quad (10)$$


2.3.3 ระบบชุดตัวกรองจำแนกอารมณ์แบบสองขั้นตอน

เพื่อลดขั้นตอนการทำงานและเพิ่มประสิทธิภาพในการจำแนกอารมณ์ที่ซับซ้อน คณะผู้วิจัยจึงออกแบบระบบจำแนกอารมณ์แบบสองขั้นตอนที่ทำงานอิสระต่อกัน ประกอบไปด้วย ชุดตัวกรองหลักและชุดตัวกรองยืนยันผล โดยใช้ภาพทดสอบที่ผ่านกระบวนการปรับปรุงคุณภาพภาพเป็นสัญญาณนำเข้า ดังแสดงในรูปที่ 3 โดยมีขั้นตอนดังนี้

ขั้นตอนที่ 1 สัญญาณนำเข้าจะถูกสร้างเป็นเวกเตอร์คุณลักษณะ $\vec{e}_{1,test}$ ในลักษณะเดียวกับกระบวนการสร้างตัวกรอง $\vec{F}_{1,k}$ เพื่อนำไปเปรียบเทียบกับตัวกรองเปรียบเทียบแต่ละ k ผลลัพธ์ที่ได้จะถูกป้อนเข้าสู่วงจรตรวจหาค่าสูงสุด (Maximum Detector) สำหรับเปรียบเทียบหาค่าสัญญาณที่ให้การตอบสนองสูงสุดออกมาเป็นผลลัพธ์ R_1 ในรูปแบบคู่ลำดับ ($C_{predict}, NCC_{max}$) โดยที่

NCC_{max} คือ ค่าสหสัมพันธ์ไขว้เทียบมาตรฐานระหว่างตัวกรองเปรียบเทียบกับเวกเตอร์คุณลักษณะภาพทดสอบแต่ละ k ตามลำดับ

$C_{predict}$ คือ คลาสชื่ออารมณ์ที่ทำนายได้ (Predicted Class) ซึ่งเกิดจากดัชนีที่ k ของตัวกรองที่ให้คะแนนความเหมือนสูงสุด



รูปที่ 3 ระบบชุดตัวกรองการจำแนกอารมณ์แบบสองขั้นตอนที่นำเสนอ

ขั้นตอนที่ 2 ค่า $NCC_{1,max}$ ของผลลัพธ์ R_1 จากชุดตัวกรองหลัก ถูกตัดสินใจเทียบกับค่าขีดเริ่มเปลี่ยน (Threshold) ที่กำหนดไว้เท่ากับ 0.8 โดยหากค่าที่ได้สูงกว่าเกณฑ์จะให้ผลลัพธ์การจำแนกเป็นอารมณ์ $C_{predict}$ ซึ่งอยู่ในกลุ่ม $k \in \{1, 2, 3, 4, 5\}$ แล้วจบการทำงาน ในทางกลับกัน หากค่าที่ได้ไม่ผ่านเกณฑ์จะต้องดำเนินการตรวจสอบด้วยชุดตัวกรองยืนยันผลในขั้นตอนต่อไป

ขั้นตอนที่ 3 สัญญาณนำเข้าจะถูกสร้างเป็นเวกเตอร์คุณลักษณะ $\vec{e}_{2,test}$ ในลักษณะเดียวกับกระบวนการสร้างตัวกรอง $\vec{F}_{2,k}$ เพื่อนำผลลัพธ์ไปป้อนผ่านวงจรตรวจหาค่าสูงสุด (Maximum Detector) สำหรับเปรียบเทียบค่า R_2 ในรูปแบบคู่ลำดับเหมือนกับ R_1

ขั้นตอนที่ 4 ค่า $NCC_{2,max}$ ของผลลัพธ์ R_2 จากชุดตัวกรองยืนยันผล ถูกตัดสินใจเทียบกับค่าขีดเริ่มเปลี่ยน (Threshold) ที่กำหนดไว้เท่ากับ 0.8 โดยหากค่าที่ได้สูงกว่าเกณฑ์จะให้ผลลัพธ์การจำแนกเป็นอารมณ์ $C_{predict}$ ซึ่งอยู่ในกลุ่ม $k \in \{6, 7\}$ แล้วจบการทำงาน ในทางกลับกัน หากค่าที่ได้ไม่ผ่านเกณฑ์จะให้ผลลัพธ์การจำแนกเป็นการทำนายที่ไม่สามารถระบุอารมณ์ได้ (Unknow)

3. ผลการทดลองและการวิเคราะห์

ในขั้นตอนการทดสอบประสิทธิภาพระบบรู้จำอารมณ์บนใบหน้า ที่นำเสนอโดยใช้ข้อมูลภาพบุคคลต้นแบบที่ศึกษา ซึ่งมีจำนวนภาพแต่ละอารมณ์ดังตารางที่ 2 รวมทั้งหมด 23 ภาพ และเพื่อประเมินประสิทธิภาพของโมเดลอย่างน่าเชื่อถือ คณะวิจัย ใช้วิธีทดสอบแบบไขว้ที่แบ่งข้อมูลออกเป็น 3 ส่วน (3-Fold Cross-Validation) ซึ่งเป็นวิธีที่ได้รับความนิยมในงานวิจัยด้าน FER [18] โดยในแต่ละรอบของการทดสอบจะใช้ข้อมูลจำนวน 1 fold เป็นชุดฝึกสอน (Train Set) เพื่อสร้างตัวกรองเปรียบเทียบ $\vec{F}_{1,k}$ และ $\vec{F}_{2,k}$ และใช้ข้อมูลจำนวน 2 fold ที่เหลือเป็นชุดทดสอบ (Test Set) โดยผลรวมการจำแนกอารมณ์ที่ถูกต้องหรือผิดพลาดของแต่ละอารมณ์ทั้ง 3 folds จะถูกรวมในเมทริกซ์ความสับสน (Confusion Matrix) ดังแสดงตารางที่ 3 และ 4

ตารางที่ 3: Confusion Matrix ที่ใช้ชุดตัวกรองแบบระดับเดียว $\vec{F}_{1,k}$

อารมณ์จริงของภาพทดสอบ							
อารมณ์	NE	AN	DI	FE	HA	SA	SU
NE	6	0	0	0	0	0	0
AN	0	6	0	0	0	0	0
DI	0	0	6	6	0	0	0
FE	0	0	0	3	0	0	0
HA	0	0	0	0	9	0	0
SA	0	0	0	0	0	6	0
SU	0	0	0	0	0	0	6
Unknow	0	0	0	0	0	0	0

ตารางที่ 4: Confusion Matrix ที่ใช้ชุดตัวกรองแบบระดับเดียว $\vec{F}_{2,k}$

อารมณ์จริงของภาพทดสอบ							
อารมณ์	NE	AN	DI	FE	HA	SA	SU
NE	6	0	0	0	0	3	0
AN	0	3	3	0	0	0	0
DI	0	0	3	0	0	0	0
FE	0	0	0	3	0	0	0
HA	0	0	0	0	6	0	0
SA	0	0	0	0	0	3	0
SU	0	0	0	3	0	0	6
Unknow	0	3	0	3	3	0	0

จากตารางที่ 3 และ 4 พบว่า ชุดตัวกรองแบบขั้นตอนเดียวที่ใช้เพียงพื้นที่การเปลี่ยนแปลงบริเวณผิว $\vec{F}_{1,k}$ หรือ พื้นที่การเปลี่ยนแปลงบริเวณมุมปากและเปลือกตาบน $\vec{F}_{2,k}$ ไม่สามารถจำแนกอารมณ์ได้ถูกต้องทั้งหมด โดยเฉพาะอย่างยิ่งอารมณ์ความกลัว (FE) ที่ผิดพลาดทั้งสองการทดสอบ รวมถึงเกิดการทำนายที่ไม่สามารถระบุอารมณ์ได้ (Unknow) เนื่องจากค่า NCC_{max} ต่ำกว่าเกณฑ์ที่กำหนดไว้ แสดงให้เห็นว่าแต่ละอารมณ์มีพื้นที่การเปลี่ยนแปลงที่เฉพาะเจาะจง และเมื่อทดสอบโดยใช้ชุดตัวกรองแบบสองขั้นตอนที่นำเสนอ ทำให้ได้ผลลัพธ์ดังตารางที่ 5

ตารางที่ 5: Confusion Matrix ผลทดสอบที่ใช้ระบบจำแนกที่นำเสนอ

อารมณ์จริงของภาพทดสอบ								
อารมณ์ที่ทำนายภาพ	อารมณ์	NE	AN	DI	FE	HA	SA	SU
	NE	6	0	0	0	0	0	0
	AN	0	6	0	0	0	0	0
	DI	0	0	6	0	0	0	0
	FE	0	0	0	9	0	0	0
	HA	0	0	0	0	9	0	0
	SA	0	0	0	0	0	6	0
	SU	0	0	0	0	0	0	6
	Unknow	0	0	0	0	0	0	0

และเมื่อทำการวัดประสิทธิภาพของระบบโดยใช้เกณฑ์ค่าความถูกต้องโดยรวม (Overall Accuracy) ซึ่งนิยามถึง สัดส่วนของจำนวนภาพที่จำแนกถูกต้องต่อจำนวนภาพทั้งหมดแล้วคิดเป็นเปอร์เซ็นต์ [19] ดังสมการ (8)

$$\text{Overall Accuracy} = \frac{\text{Number of Correted Prediction}}{\text{Total number of prediction}} \quad (11)$$

เมื่อใช้จากผลจากตารางเมทริกซ์ความสับสนจากที่ตารางที่ 3 และ 4 พบว่า ชุดตัวกรองแบบขั้นตอนเดียว โดยใช้ $\vec{F}_{1,k}$ หรือ $\vec{F}_{2,k}$ สามารถจำแนกอารมณ์ได้ถูกต้องโดยรวม 87.50% และ 62.50% ตามลำดับ โดยอารมณ์ที่จำแนกผิดมากที่สุด คือ อารมณ์กลัว (FE) อย่างไรก็ตาม เมื่อเพิ่มชุดตัวกรองเป็นสองขั้นตอนที่นำเสนอทำให้ประสิทธิภาพของการจำแนกอารมณ์ดีขึ้นอย่างชัดเจนอย่างมีนัยสำคัญโดยให้ค่าความถูกต้องโดยรวมเป็น 100%

4. อภิปราย

ผลการทดสอบที่ให้ค่าความถูกต้อง 100% บนชุดข้อมูลบุคคลอ้างอิง เป็นการพิสูจน์หลักการและประสิทธิภาพของระบบที่นำเสนอว่า สามารถลดความซับซ้อนและทรัพยากรในการคำนวณได้อย่างมีนัยสำคัญ โดยมีปัจจัยสำคัญสองประการ คือ (1) การลดมิติข้อมูล (Dimensionality Reduction) ผ่านการสกัดเวกเตอร์คุณลักษณะต้นแบบจากพื้นที่การเปลี่ยนแปลงที่สำคัญ (AOCs) เพียง 6 ตำแหน่ง และ (2) สถาปัตยกรรมการจำแนกแบบสองขั้นตอน (Two-Stage Classification) โดยในกรณีที่ดีที่สุด (Best Case) ซึ่งครอบคลุมอารมณ์ส่วนใหญ่ ระบบต้องการข้อมูลจากพื้นที่เพียง 1.5% ของภาพทั้งหมด และแม้ในกรณีที่

เลวร้ายที่สุด (Worst Case) ก็ยังใช้ข้อมูลเพียง 3.7% เท่านั้น การลดปริมาณข้อมูลในระดับนี้ ส่งผลให้ความซับซ้อนเชิงเวลา (Time Complexity) ของระเบียบวิธีนี้อยู่ในระดับที่ใกล้เคียงเวลาคงที่ $O(k)$ ซึ่งเป็นข้อได้เปรียบอย่างมากเมื่อเปรียบเทียบกับวิธีการของโครงข่ายประสาทเทียมแบบลึก (Deep Learning) โดยเฉพาะโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) ที่มักจะประมวลผลข้อมูลจากภาพทั้งหมดผ่านหลายชั้นเลเยอร์ ซึ่งทำให้ความซับซ้อนเชิงเวลาเพิ่มขึ้นเป็นสัดส่วนโดยตรงกับจำนวนชั้นเลเยอร์ (L) และจำนวนพิกเซลของภาพทั้งหมด (N)

ดังนั้น ระบบที่นำเสนอแสดงให้เห็นอย่างชัดเจน ในการลดภาระการคำนวณและหน่วยความจำ ความต้องการทรัพยากรในการประมวลผลน้อยกว่าเหมาะสมอย่างยิ่งสำหรับแอปพลิเคชันที่ต้องการตอบสนองแบบทันทีบนอุปกรณ์ที่มีข้อจำกัด แต่ยังคงรักษาข้อมูลสำคัญที่จำเป็นต่อการจำแนกอารมณ์ไว้อย่างครบถ้วน รวมถึงสามารถอธิบาย (Interpretable) กระบวนการตัดสินใจได้อย่างชัดเจน

5. สรุป

ระบบที่นำเสนอและพิสูจน์หลักการของสถาปัตยกรรมสำหรับการรู้จำอารมณ์บนใบหน้าแบบจำเพาะเจาะจงบุคคล ซึ่งใช้หลักการประมวลผลสัญญาณดิจิทัลอย่างสมบูรณ์ เราได้แสดงให้เห็นว่าสถาปัตยกรรมที่ทำงานบนคุณลักษณะซึ่งสกัดมาจากพื้นที่การเปลี่ยนแปลง (Area of Change) ที่สำคัญเพียงไม่กี่แห่ง ผ่านกระบวนการหาคุณลักษณะต้นแบบ (Prototype Feature) และทำงานร่วมกับชุดตัวกรองเปรียบเทียบ (Matched Filter Bank) แบบสองขั้นตอน สามารถให้ประสิทธิภาพการจำแนกแบบจำเพาะเจาะจงบุคคล (Person-Specific) ได้อย่างสมบูรณ์แบบถึง 100%

ผลลัพธ์นี้ตอกย้ำถึงศักยภาพของระเบียบวิธีที่นำเสนอสำหรับงานประยุกต์ที่ต้องการความแม่นยำสูงและสามารถปรับให้เข้ากับผู้ใช้แต่ละคนได้ เช่น ระบบช่วยเหลือส่วนบุคคล หรือส่วนต่อประสานกับผู้ใช้แบบปรับตัวได้ (Adaptive User Interface) ความสำเร็จในการลดจำนวนพื้นที่ที่ต้องพิจารณาอย่างมากโดยยังคงรักษาประสิทธิภาพสูงสุดไว้ได้ แสดงให้เห็นถึงความสามารถของระบบในการทำงานอย่างมีประสิทธิภาพและมีน้ำหนักเบา

จากความท้าทายด้านความแปรปรวนระหว่างบุคคล (Inter-subject Variability) ซึ่งเป็นปัญหาพื้นฐานในงานวิจัยด้าน FER งานวิจัยในอนาคตจึงควรมุ่งเน้นไปที่การพัฒนา ตัวกรองที่เป็นสากล หรือ การพัฒนาเทคนิคการปรับตัวข้ามโดเมน (Domain Adaptation) เพื่อปรับแก้ตัวกรองต้นแบบให้เข้ากับลักษณะของบุคคลเป้าหมายใหม่โดยอัตโนมัติ อันจะเป็นการขยายขอบเขตการใช้งานของระบบให้กว้างขวางและครอบคลุมยิ่งขึ้น

เอกสารอ้างอิง

- [1] M. Kamati, A. Seal, A. Seal, O. Krejcar, O. Krejcar, and A. Yazidi, "FER-net: facial expression recognition using deep neural net," *Neural Computing and Applications*, vol. 33, no. 15, pp. 9125–9136, Jan. 2021, doi: 10.1007/S00521-020-05676-Y.



- [2] C. Liu, K. Hirota, J. Ma, Z. Jia, and Y. Dai, "Facial Expression Recognition Using Hybrid Features of Pixel and Geometry," *IEEE Access*, vol. 9, pp. 18876–18889, Jan. 2021, doi: 10.1109/ACCESS.2021.3054332.
- [3] O. Ekundayo and S. Viriri, "Facial Expression Recognition: A Review of Trends and Techniques," *IEEE Access*, vol. 9, pp. 136944–136973, Sep. 2021, doi: 10.1109/ACCESS.2021.3113464.
- [4] P. Jiang, B. Wan, Q. Wang, and J. Wu, "Fast and Efficient Facial Expression Recognition Using a Gabor Convolutional Network," *IEEE Signal Processing Letters*, vol. 27, pp. 1954–1958, Oct. 2020, doi: 10.1109/LSP.2020.3031504.
- [5] J. Kommineni, S. Mandala, M. S. Sunar, and P. M. Chakravarthy, "Accurate computing of facial expression recognition using a hybrid feature extraction technique," *The Journal of Supercomputing*, vol. 77, no. 5, pp. 5019–5044, May 2021, doi: 10.1007/S11227-020-03468-8.
- [6] "Deep Facial Expression Recognition: A Survey," *IEEE Transactions on Affective Computing*, vol. 13, no. 3, pp. 1195–1215, Jul. 2022, doi: 10.1109/taffc.2020.2981446.
- [7] A. Khan, "Facial Emotion Recognition Using Conventional Machine Learning and Deep Learning Methods: Current Achievements, Analysis and Remaining Challenges," *Information*, vol. 13, no. 6, p. 268, May 2022, doi: 10.3390/info13060268.
- [8] "Understanding Deep Learning Techniques for Recognition of Human Emotions Using Facial Expressions: A Comprehensive Survey," *IEEE Transactions on Instrumentation and Measurement*, vol. 72, pp. 1–31, Jan. 2023, doi: 10.1109/tim.2023.3243661.
- [9] S. Saurav et al., "Dual integrated convolutional neural network for real-time facial expression recognition in the wild," *The Visual Computer*, pp. 1–14, Feb. 2021, doi: 10.1007/S00371-021-02069-7.
- [10] Z. Song, "Facial Expression Emotion Recognition Model Integrating Philosophy and Machine Learning Theory," *Frontiers in Psychology*, vol. Volume 12-2021, 2021, doi: 10.3389/fpsyg.2021.759485.
- [11] M. J. Lyons, S. Akamatsu, M. Kamachi, and J. Gyoba, "Coding facial expressions with Gabor wavelets," *IEEE International Conference on Automatic Face and Gesture Recognition*, pp. 200–205, Apr. 1998, doi: 10.1109/AFGR.1998.670949.
- [12] A. A. Kandeel, M. Rahmanian, F. Zulkernine, H. M. Abbas, and H. S. Hassanein, "Facial Expression Recognition Using a Simplified Convolutional Neural Network Model," *International Conference on Communications*, pp. 1–6, Mar. 2021, doi: 10.1109/ICCSA49915.2021.9385739.
- [13] M. Arora and M. Kumar, "AutoFER: PCA and PSO based automatic facial emotion recognition," *Multimedia Tools and Applications*, vol. 80, no. 2, pp. 3039–3049, Jan. 2021, doi: 10.1007/S11042-020-09726-4.
- [14] S. Umeyama, "Least-squares estimation of transformation parameters between two point patterns," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 13, no. 4, pp. 376–380, Apr. 1991, doi: 10.1109/34.88573.
- [15] P. Ekman, W. V. Friesen, and J. C. Hager, "Facial Action Coding System. Manual and Investigator's Guide," 2002.
- [16] X. Zhang, Y. He, Y. Jin, H. Qin, M. Azhar, and J. Z. Huang, "A Robust k-Means Clustering Algorithm Based on Observation Point Mechanism," *Complexity*, vol. 2020, pp. 1–11, Mar. 2020, doi: 10.1155/2020/3650926.
- [17] X. Li and H. Tan, "K-Means Algorithm Based on Initial Cluster Center Optimization," Springer, Cham, 2020, pp. 310–316. doi: 10.1007/978-3-030-43306-2_44.
- [18] S. Jayaraman and A. Mahendran, "CNN-LSTM based emotion recognition using Chebyshev moment and K-fold validation with multi-library SVM," *PLOS ONE*, vol. 20, no. 4, p. e0320058, 2025, doi: 10.1371/journal.pone.0320058.
- [19] S. Yammen and W. Limsripraphan, "Matched Filter Detector for Textile Fiber Classification of Signals with Near-Infrared Spectrum," *Asia-Pacific Signal and Information Processing Association Annual Summit and Conference*, pp. 501–505, Nov. 2022, doi: 10.23919/APSIPAASC55919.2022.9980054.



ดร.สุชาติ แอ้มแมน สำเร็จการศึกษาระดับปริญญาตรี สาขาวิศวกรรมไฟฟ้า (เกียรตินิยม) จากมหาวิทยาลัย เชียงใหม่ ประเทศไทย เมื่อปี พ.ศ. 2531 สำเร็จการศึกษาระดับปริญญาโท และปริญญาเอกจากมหาวิทยาลัยแวนเดอร์บิลต์ เมือง

แนชวิลล์ รัฐเทนเนสซี สหรัฐอเมริกา ในปี พ.ศ. 2541 และ พ.ศ. 2544 ตามลำดับ ความสนใจด้านการวิจัยในปัจจุบันครอบคลุมหลากหลายสาขา ได้แก่ วิศวกรรมไฟฟ้ากำลัง การประมวลผลและวิเคราะห์สัญญาณดิจิทัล ระบบควบคุมอัตโนมัติ วิศวกรรมชีวการแพทย์ วิศวกรรมคอมพิวเตอร์ พลังงานหมุนเวียน การจัดการอนุรักษ์พลังงาน หุ่นยนต์ การระบุและสร้างแบบจำลองระบบ ดร.สุชาติ แอ้มแมน ดำรงตำแหน่งรองศาสตราจารย์ และผู้อำนวยการหน่วยวิจัยด้านวิศวกรรมชีวการแพทย์และนวัตกรรมเพื่อความเสมอภาคทางสังคม (BEISE) คณะวิศวกรรมศาสตร์ มหาวิทยาลัยนเรศวร และยังเป็นสมาชิกวิชาชีพในระดับนานาชาติและระดับประเทศ อาทิ สมาชิกอาวุโสของ IEEE สมาชิกของวิศวกรรมสถานแห่งประเทศไทย ในพระบรมราชูปถัมภ์ (วสท.) สมาชิกของสภาวิศวกร



พันธุธิดา ลิ้มศรีประพันธ์ สำเร็จการศึกษาระดับปริญญาตรี สาขาวิชาวิทยาการคอมพิวเตอร์ และปริญญามหาบัณฑิต สาขาวิชาเทคโนโลยีสารสนเทศ จากมหาวิทยาลัยนเรศวร เมื่อปี พ.ศ. 2543 และ พ.ศ. 2546 ตามลำดับ ปัจจุบันกำลัง

ศึกษาระดับปริญญาดุษฎีบัณฑิต สาขาวิชาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยนเรศวร ความสนใจงานวิจัย ได้แก่ การวิเคราะห์ และการรู้จำอารมณ์จากใบหน้า (Facial Expression Recognition : FER) และการสกัดคุณลักษณะ หรือ การแยกคุณลักษณะ (Feature extraction)