

ระบบการเช็คชื่อเข้าชั้นเรียนด้วยการตรวจจับใบหน้าโดยใช้ CNN และ Deep Learning Time Attendance System with Face Recognition Using CNN and Deep Learning

เกรียงศักดิ์ มะโนชัย¹ กฤษกร ริ้วสุนทร¹ พรณนุษา แท้ภักดี^{1*} และ ชนาเนตร อรรถยุกติ¹
Kriangsak Manochai¹, Kitsakorn Riwsoontorn¹, Phornthanusa Tarepakdee^{1*}, and Chananate Arthayukti¹

¹ สาขาวิชาเทคโนโลยีสารสนเทศ คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยเทคโนโลยีราชมงคลกรุงเทพ 10120

¹ Division of Information Technology, Faculty of Science and Technology, Rajamangala University of Technology Krungthep, 10120

*Corresponding Author: 645021000510@mail.rmutk.ac.th

Received 6 พฤศจิกายน 2567; Revised 18 มกราคม 2568; Accepted 24 กุมภาพันธ์ 2568

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อทดสอบประสิทธิภาพความแม่นยำของระบบการเช็คชื่อเข้าชั้นเรียนด้วยการตรวจจับใบหน้าโดยใช้ CNN และ Deep learning และพัฒนาระบบลงชื่อด้วยการตรวจจับใบหน้า โดยลดข้อผิดพลาดในการบันทึกข้อมูลได้อย่างมีประสิทธิภาพด้วยโมเดลการจดจำใบหน้าที่พัฒนาโดยใช้เทคนิคการเรียนรู้เชิงลึก Convolutional Neural Networks (CNN) ร่วมกับเทคโนโลยีตรวจจับใบหน้า Histogram of Oriented Gradients (HOG) โปรแกรมประยุกต์ได้รับการพัฒนาด้วย Python และส่วนของเว็บไซต์ถูกพัฒนาการใช้ PHP ร่วมกับ React.js ฐานข้อมูลผู้ใช้ และรายงานการเข้าเรียนถูกจัดเก็บไว้ใน MySQL ระบบได้รับการทดสอบภายใต้สภาพแสงภายในอาคารระยะการตรวจจับใบหน้า 2, 3, 4 และ 5 เมตร จำนวนใบหน้าเป้าหมาย 4, 6, 8, 10, 12, 14 และ 16 คน ทดสอบ 20 ครั้งภายใต้แต่ละเงื่อนไขการทดสอบ โดยสรุปผลการทดสอบได้ว่า 1) การใช้งานระบบการเช็คชื่อเข้าชั้นเรียนด้วยการตรวจจับใบหน้าโดยใช้ CNN และ Deep learning ควรใช้รูปภาพที่มีรายละเอียดของใบหน้าชัดเจน (เช่น ดวงตา จมูก ปาก และหน้าผาก) จะทำให้ระบบตรวจจับใบหน้าทำงานได้อย่างแม่นยำ และมีประสิทธิภาพ 2) การตรวจจับใบหน้าในระยะการตรวจจับที่ไกล (2 เมตร) และจำนวนของใบหน้าเป้าหมายในรูปภาพ ที่จำนวน 4 คน ต่อ 1 รูปภาพ จะให้ผลลัพธ์ที่แม่นยำมากที่สุด โดยค่าความสอดคล้องอยู่ในช่วงเฉลี่ยร้อยละ 100 3) การตรวจจับใบหน้าในระยะการตรวจจับที่ไกล (5 เมตร) และจำนวนของใบหน้าเป้าหมายในรูปภาพ ที่จำนวน 16 คน ต่อ 1 รูปภาพ จะให้ผลลัพธ์ที่แม่นยำน้อยที่สุด โดยค่าความสอดคล้องอยู่ในช่วงเฉลี่ยร้อยละ 30 4) ความแม่นยำในการตรวจจับใบหน้าขึ้นอยู่กับความละเอียดของใบหน้าในรูปภาพ หากความละเอียดของใบหน้าในรูปภาพน้อยลง ก็จะส่งผลให้ค่าเฉลี่ยความแม่นยำน้อยลงเช่นกัน 5) การตรวจจับใบหน้าของผู้เข้าร่วมชั้นเรียนทั้งหมดมีความแม่นยำเฉลี่ยร้อยละ 75

คำหลัก: การตรวจจับใบหน้า; ระบบเช็คชื่อเข้าชั้นเรียน; การเรียนรู้เชิงลึก

Abstract

This research aims to evaluate the accuracy and performance of a classroom attendance system utilizing facial detection with CNN and Deep Learning. It also aims to develop a facial recognition-based attendance system that effectively minimizes data recording errors. The facial recognition model was developed using Deep Learning techniques, particularly Convolutional Neural Networks (CNN), combined with the Histogram of Oriented Gradients (HOG) facial detection technology. The application was developed

using Python, while the website interface was built using PHP and React.js. User databases and attendance reports were stored in MySQL. The system was tested under indoor lighting conditions at face detection distances of 2, 3, 4, and 5 meters, with target face counts of 4, 6, 8, 10, 12, 14, and 16 people. Each condition was tested 20 times. The results can be summarized as follows: 1) For optimal accuracy and efficiency, the system requires clear facial features (e.g., eyes, nose, mouth, and forehead) for recognition. 2) The most accurate results were achieved at a detection distance of 2 meters with 4 target faces per image, yielding an average accuracy of 100%. 3) The least accurate results were observed at a detection distance of 5 meters with 16 target faces per image, with an average accuracy of 30%. 4) Facial detection accuracy decreases as the resolution of facial details in the image decreases. 5) The average facial detection accuracy across all test conditions was 75%.

Keywords: Facial detection; Time Attendance System; Deep Learning

1. บทนำ

การเช็คชื่อเข้าชั้นเรียนเป็นขั้นตอนที่สำคัญในการประเมินความรับผิดชอบ และการเข้าร่วมของนักเรียนในแต่ละวิชา แต่การเช็คชื่อในรูปแบบดั้งเดิม เช่น การเรียกชื่อ การสแกนลายนิ้วมือ การใช้ QR Code หรือการเช็คชื่อผ่านแบบฟอร์มทางออนไลน์ มักประสบกับปัญหาหลายประการ เช่น การใช้เวลาในการเช็คชื่อที่มากเกินไป ความผิดพลาดจากการลืมเช็คชื่อหรือแม้กระทั่งการโกงการเช็คชื่อโดยการให้บุคคลอื่นเช็คชื่อแทน

การนำเทคโนโลยี การจดจำใบหน้า (Facial Recognition) เข้ามาประยุกต์ใช้ในระบบการเช็คชื่อเข้าชั้นเรียนถือเป็นหนึ่งในแนวทางที่มีประสิทธิภาพ เนื่องจากสามารถตรวจสอบและยืนยันตัวตนของนักศึกษาได้อย่างรวดเร็วและแม่นยำ เทคโนโลยีการจดจำใบหน้าใช้หลักการของการประมวลผลภาพ (Image Processing) ได้มีบทบาทสำคัญในการวิเคราะห์และประมวลผลข้อมูลภาพที่ใช้ในการสร้างระบบตรวจจับและจดจำใบหน้า โดยเพิ่มความแม่นยำโดยอาศัยการวิเคราะห์ลักษณะใบหน้าที่เป็นเอกลักษณ์ของแต่ละบุคคล

การวิจัยนี้มีเป้าหมายเพื่อพัฒนาระบบเช็คชื่อเข้าชั้นเรียนโดยใช้เทคโนโลยีการจดจำใบหน้า ซึ่งสามารถลดเวลาการเช็คชื่อ เพิ่มความแม่นยำในการยืนยันตัวตน และป้องกันการทุจริตในการเช็คชื่อ นอกจากนี้ยังเป็นการศึกษาเกี่ยวกับประสิทธิภาพและความเป็นไปได้ในการนำระบบนี้ไปใช้ในสถานศึกษา

1.1 วัตถุประสงค์ของการวิจัย

1.1.1 เพื่อทดสอบประสิทธิภาพความแม่นยำ ระบบการเช็คชื่อเข้าชั้นเรียนด้วยการตรวจจับใบหน้าโดยใช้ CNN และ Deep learning

1.1.2 พัฒนาระบบลงชื่อด้วยการตรวจจับใบหน้า

1.2 ขอบเขตของงาน

1.2.1. ระบบสามารถตรวจจับใบหน้าโดยวิเคราะห์จากภาพถ่ายและจำแนกข้อมูลของนักศึกษาเป็นรายบุคคล จากภาพถ่ายแบบกลุ่มได้

1.2.2 ระบบสามารถแสดงข้อมูลชื่อนามสกุลและรหัสนักศึกษาของนักศึกษาที่ระบบสามารถทำการตรวจจับใบหน้าจากรูปภาพได้

1.2.3 ผู้ดูแลระบบสามารถจัดการข้อมูลนักศึกษา จัดการข้อมูลพื้นฐาน จัดการข้อมูลตารางสอน จัดการข้อมูลนักศึกษาในกลุ่มเรียนลงฐานข้อมูลได้

1.2.4 สามารถยืนยันตัวตนโดยใช้ระบบ Google Login ได้

1.2.5 สามารถสรุปข้อมูลการเข้าชั้นเรียนของนักศึกษาได้

1.3 ประโยชน์ที่คาดว่าจะได้รับ

1.3.1 การเช็คชื่อเข้าชั้นเรียนด้วยการตรวจจับใบหน้าช่วยลดความผิดพลาดที่อาจเกิดขึ้น เช่น การเช็คชื่อแทนกัน

1.3.2 การเช็คชื่อเข้าชั้นเรียนด้วยการตรวจจับใบหน้า
ช่วยลดภาระงานของครูหรืออาจารย์ในการติดตามและ
ตรวจสอบการเข้าชั้นเรียนของนักเรียน

1.3.3 การเช็คชื่อเข้าชั้นเรียนด้วยการตรวจจับใบหน้า
ช่วยลดการใช้ทรัพยากรกระดาษ

1.4 การรู้จำใบหน้าด้วยการเรียนรู้เชิงลึก (Deep Learning Facial Recognition)

การรู้จำใบหน้า (Facial Recognition) เป็นกระบวนการที่ใช้ในการระบุหรือยืนยันตัวตนของบุคคลจากใบหน้า กระบวนการนี้มักจะเริ่มต้นจากการตรวจจับใบหน้าในภาพ จากนั้นทำการวิเคราะห์ และเปรียบเทียบกับข้อมูลใบหน้าที่เก็บไว้ในฐานข้อมูล การรู้จำใบหน้าด้วย Deep Learning เป็นวิธีที่มีประสิทธิภาพ และได้รับความนิยมมาก เนื่องจากความสามารถในการเรียนรู้ลักษณะเฉพาะของใบหน้าได้อย่างละเอียดและแม่นยำ Deep Learning เป็นส่วนหนึ่งของ Machine Learning ที่ใช้โครงข่ายประสาทเทียม (Neural Networks) ที่มีหลายชั้นหรือที่เรียกว่า Deep Neural Networks การรู้จำใบหน้าด้วย Deep Learning แบ่งออกเป็น 3 ขั้นตอนดังนี้

1) การตรวจจับใบหน้า (Face Detection) เป็นกระบวนการนำเข้าสู่ข้อมูลเพื่อค้นหาขอบเขตของใบหน้าจากภาพหนึ่ง และทำการระบุตำแหน่งของใบหน้าบุคคลที่พบ


2) การแปลงใบหน้าเป็นเวกเตอร์ (Face Representation) เป็นกระบวนการแปลงใบหน้าให้เป็นเวกเตอร์เชิงตัวเลข (Feature Vector) ซึ่งเป็นการนำภาพใบหน้ามาผ่านโครงข่ายประสาทเทียมแบบลึก CNNs (Convolutional Neural Networks) โดยถูกใช้ในการแปลงใบหน้าให้เป็นเวกเตอร์ โดยโมเดลจะดึงฟีเจอร์สำคัญ เช่น รูปร่างของใบหน้า ขนาดของดวงตา และลักษณะอื่นๆ ที่เป็นเอกลักษณ์

3) การจับคู่ใบหน้า (Face Matching) เป็นกระบวนการเปรียบเทียบระหว่างชุดตัวเลขเวกเตอร์ใบหน้า (Face Embedding) ที่ตรวจจับได้กับชุดตัวเลขเวกเตอร์ใบหน้าในฐานข้อมูล (Face Template) เพื่อใช้ในการยืนยันตัวบุคคล โดยที่ระบบจะทำการคำนวณระยะห่าง (Distance) ระหว่างเวกเตอร์ของใบหน้านั้นกับเวกเตอร์ของใบหน้าที่เก็บไว้ในฐานข้อมูล หากระยะห่างมีค่าน้อยกว่าค่าที่

กำหนด (Threshold) ระบบจะทำการจับคู่ใบหน้านั้นกับใบหน้าที่ตรงกันในฐานข้อมูล [1]

1.5 Convolutional Neural Networks (CNN)

Convolutional Neural Network (CNN) เป็นประเภทหนึ่งของ Neural Networks เป็นโครงข่ายประสาทเทียมหนึ่งในกลุ่ม bio-inspired โดยที่จำลองการมองเห็นของมนุษย์ที่มองพื้นที่เป็นที่ย่อย ๆ และนำกลุ่มของพื้นที่ย่อย ๆ มาพาสานกัน [2]



รูปที่ 1 ส่วนประกอบด้วยชั้นหลักของ CNNs [3]

CNN มีส่วนประกอบด้วยชั้นหลัก ได้แก่

- Convolutional Layer เป็นชั้นหลักที่ใช้ในการเรียนรู้ฟีเจอร์ต่างๆ ของข้อมูล โดยจะใช้ฟิลเตอร์ (Filters) หรือเคอร์เนล (Kernels) ในการทำการ convolute กับข้อมูล โดยผลลัพธ์ที่ได้จะเป็นฟีเจอร์แมพ (Feature Map) ที่แสดงถึงการปรากฏของฟีเจอร์ต่างๆ ในข้อมูล [4]

- Activation Function หลังจากเลเยอร์ การ convolute จะมีการใช้ ฟังก์ชันกระตุ้น (Activation Function) เช่น ReLU (Rectified Linear Unit) เพื่อเพิ่มความไม่เป็นเชิงเส้นในโมเดล ทำให้โมเดลสามารถเรียนรู้ฟีเจอร์ที่ซับซ้อนได้ [5]

- Pooling Layer มีหน้าที่ลดขนาดของฟีเจอร์แมพที่เกิดขึ้นจากชั้นการ convolute โดยปกติจะใช้การดำเนินการประเภท Max Pooling หรือ Average Pooling เพื่อทำการย่อขนาดข้อมูลและลดจำนวนพารามิเตอร์ ในขณะเดียวกันยังคงรักษาข้อมูลที่สำคัญไว้ [6]

- Fully Connected Layer (Dense Layer) เป็นชั้นที่ใช้หลังจากเลเยอร์การ convolute และการ pooling โดยจะเชื่อมต่อกับฟีเจอร์ที่ได้จากเลเยอร์ก่อนหน้า ซึ่งจะช่วยในการจำแนกประเภทข้อมูลออกเป็นคลาสต่างๆ ฟีเจอร์ที่ได้จากเล

เยอร์ก่อนหน้านั้นจะถูกแบนลงเป็นเวกเตอร์ 1 มิติและส่งผ่านไปยังเลเยอร์นี้ [7]


- Output Layer เป็นชั้นสุดท้ายที่ใช้ในการจำแนกประเภทหรือให้ผลลัพธ์ในรูปแบบที่ต้องการ เช่น การใช้ Softmax Function เพื่อให้ได้ผลลัพธ์ในรูปแบบของความน่าจะเป็นของแต่ละคลาส [8]

1.6 Histogram of Oriented Gradients (HOG)

Histogram of Oriented Gradients (HOG) เป็นอัลกอริทึมที่ใช้ในการดึงคุณลักษณะของภาพ ทำงานโดยการคำนวณ ทิศทางของขอบเขต (gradients) ภายในภาพ โดยเฉพาะขอบที่สำคัญ เช่น จุดรอยต่อระหว่างวัตถุและพื้นหลังของภาพแต่ละจุด แล้วนำข้อมูลทิศทางของขอบเขตเหล่านี้มาสร้างเป็น ฮิสโตแกรม ของทิศทางของการเคลื่อนที่ของขอบเขต (gradients) ที่พบในแต่ละพื้นที่ของภาพ หลักการทำงานของ HOG แบ่งได้ดังนี้ [9]

1) การแบ่งภาพออกเป็นเซลล์ย่อย (Cell Division) โดยภาพจะถูกแบ่งเป็นกริดที่ประกอบด้วยเซลล์เล็กๆ เช่น 8x8 พิกเซล แต่ละเซลล์จะเป็นพื้นที่ที่คำนวณทิศทางของขอบเขต (gradient direction) [10]

2) การคำนวณ Gradient โดยการคำนวณ gradient ของแต่ละพิกเซลในเซลล์จะช่วยระบุทิศทางการเปลี่ยนแปลงของความเข้มแสงในภาพ โดยปกติจะใช้ฟิลเตอร์ Sobel เพื่อคำนวณการเปลี่ยนแปลงในแนวนอน (X-axis) และแนวตั้ง (Y-axis) [11]




รูปที่ 2 ภาพการคำนวณทิศทางของขอบเขต (gradient direction) [11]

3) การสร้างฮิสโตแกรมของทิศทาง โดยทิศทางของ gradient ในแต่ละเซลล์จะถูกจัดเก็บในฮิสโตแกรมที่มี 9 ช่อง (bins) โดยแต่ละช่องจะเก็บค่าจำนวนพิกเซลที่มีทิศทาง gradient อยู่ในช่วงของมุมนั้น เช่น มุม 0 องศา, 20 องศา,

40 องศา เป็นต้น และค่าที่คำนวณได้จากฮิสโตแกรมนี้จะใช้เป็นคุณลักษณะของเซลล์นั้นๆ [12]

4) การรวมเซลล์ (Normalize Block) โดยการรวมเซลล์ฮิสโตแกรม เข้าด้วยกันเป็นบล็อกใหญ่ (เช่น 2x2 เซลล์) แล้วทำการปรับค่าของฮิสโตแกรม (Normalize) เพื่อจัดการกับความไม่สม่ำเสมอของแสงในภาพ [13]

5) การใช้คุณลักษณะในการตรวจจับใบหน้า เมื่อได้ฮิสโตแกรมที่ทำการรวมเซลล์แล้ว (Normalized) ของบล็อกทั้งหมดในภาพ HOG จะเปรียบเทียบกับคุณลักษณะของภาพนั้นกับแบบจำลองใบหน้าที่ถูกฝึกไว้ล่วงหน้า (pre-trained model) โดยใช้เครื่องมือจำแนก เพื่อตรวจสอบว่ามีใบหน้าอยู่ในภาพหรือไม่ [14]



รูปที่ 3 ภาพการกำหนดทิศทางของขอบเขตด้วยจุดรอยต่อระหว่างวัตถุและพื้นหลังของภาพ [15]

1.7 งานวิจัยที่เกี่ยวข้อง

1.7.1 ชลิตา [16] ศึกษากระบวนการจดจำใบหน้าของบุคคลโดยใช้การเรียนรู้เชิงลึกและการเรียนรู้ของเครื่อง พร้อมเทคโนโลยีการประมวลผลภาพและการรู้จำใบหน้า วัตถุประสงค์ เพื่อศึกษาและพัฒนาระบบที่มีความแม่นยำสูงในการตรวจจับใบหน้า และลดการใช้ทรัพยากรในการประมวลผล วิธีการ เตรียมข้อมูลใบหน้าของบุคคล 15 คนในท่าทางต่าง ๆ รวม 8 แบบ จากนั้นใช้กระบวนการเรียนรู้เชิงลึกในการสกัดคุณลักษณะเด่นของใบหน้า และเปรียบเทียบกับฐานข้อมูลเพื่อตรวจสอบตัวตน ผลสรุป อัลกอริทึมที่นำเสนอมีความแม่นยำสูง โดยใช้ GoogLeNet ร่วมกับ SVM และใช้จุดสำคัญ 13 จุดในการจดจำใบหน้า ทำให้ได้ค่าความแม่นยำถึง 93% ในขณะที่ CNN ทำได้ 80% และใช้เวลานานกว่า วิธีนี้มีความแม่นยำและมีประสิทธิภาพกว่าวิธีเดิม

1.7.2 เอกรัตน์ [17] ศึกษากระบวนการลงทะเบียนใบหน้าและตรวจสอบการเข้าห้องเรียนของนักศึกษาโดยใช้การประมวลผลภาพและเทคนิคการรู้จำใบหน้า วัตถุประสงค์ เพื่อสร้างระบบที่สามารถลงทะเบียนและตรวจสอบการเข้า

เรียนของนักศึกษาได้อย่างแม่นยำและประเมินความพึงพอใจของผู้ใช้ วิธีการ ออกแบบระบบโดยใช้การค้นหาใบหน้า (Face Detection) และการหาขอบภาพ (Edge Detection) จากนั้นทดสอบการเปรียบเทียบใบหน้ากับฐานข้อมูลที่บันทึกไว้เพื่อยืนยันตัวตน ผลสรุป ระบบสามารถตรวจจับใบหน้าได้แม่นยำถึง 92% อย่างไรก็ตาม เมื่อใช้งานกับกล้องวิดีโอแบบเวลาจริง อาจมีข้อผิดพลาดเนื่องจากการเคลื่อนไหวของใบหน้า แต่ระบบสามารถบันทึกข้อมูลการเข้าเรียนย้อนหลังและดึงข้อมูลมาใช้งานได้

1.7.3 ศันสนีย์ และจิระ [18] ศึกษากระบวนการตรวจจับใบหน้าเพื่อยืนยันตัวบุคคลโดยใช้เทคโนโลยีการประมวลผลภาพเพื่อเปรียบเทียบกับฐานข้อมูลอาชญากร วัตถุประสงค์เพื่อพัฒนาระบบที่ช่วยยืนยันตัวบุคคลที่มีประวัติอาชญากรรมได้อย่างรวดเร็วและแม่นยำ ซึ่งจะช่วยลดเวลาในการสืบสวนคดีและเสริมความปลอดภัย วิธีการ ใช้ภาพนิ่งหน้าตรางที่มีสภาพแสงและการแสดงอารมณ์ที่หลากหลายมาเปรียบเทียบกับข้อมูลในทะเบียนอาชญากร ผลสรุป พบว่าจำนวนโอเคนเวกเตอร์ตั้งแต่ 10 แกนขึ้นไป ทำให้ระบบรู้จำใบหน้าได้ถูกต้องถึง 95.71%

1.7.4 ณัฐชนน และคณะ [19] ศึกษากระบวนการลงเวลาปฏิบัติงานด้วยเทคโนโลยีการจดจำใบหน้าในช่วงการแพร่ระบาดของ COVID-19 วัตถุประสงค์ เพื่อพัฒนาระบบลงเวลาที่ลดการสัมผัส เพิ่มความแม่นยำ และความรวดเร็วในการใช้งาน วิธีการ ใช้ MTCNN ในการตรวจจับใบหน้า FaceNet ในการสกัดคุณลักษณะ และ nu-SVC ในการสร้างแบบจำลอง ทดสอบระบบกับพนักงาน 42 คน เป็นเวลา 30 วัน ผลสรุป ระบบมีความแม่นยำ 100% ใช้เวลาเฉลี่ย 7.5 วินาทีต่อคน และได้รับความพึงพอใจจากผู้ใช้งาน

1.7.5 อะดาว และคณะ [20] ศึกษาการประยุกต์ใช้เทคโนโลยีการรู้จำใบหน้าเพื่อบันทึกเวลาเข้าออกของพนักงาน วัตถุประสงค์ เพื่อพัฒนาระบบการบันทึกเวลาเข้าออกของพนักงานด้วยเทคโนโลยีการรู้จำใบหน้า ทดสอบประสิทธิภาพของกล้องวงจรปิด (CCTV) ในการตรวจจับใบหน้า และเปรียบเทียบเทคนิคการรู้จำใบหน้า Eigenface recognition และ Fisher face recognition รวมถึงการศึกษาความพึงพอใจของผู้ใช้งาน วิธีการ ใช้กล้องวงจรปิดตรวจจับใบหน้า และโปรแกรมที่พัฒนาขึ้นสำหรับการจัดการข้อมูล พร้อมทั้งทดสอบกับพนักงานจำนวน 50 คน และประเมินผลโดยผู้เชี่ยวชาญด้านการพัฒนาระบบ 10 คน

ผลสรุป พบว่า Eigenface recognition มีประสิทธิภาพสูงกว่าที่ 92.15% เมื่อเทียบกับ Fisher face recognition ที่ 91.21% และระบบสามารถลดเวลาในการรอคอยการบันทึกเวลาเข้าออกได้เฉลี่ย 93.6% โดยความพึงพอใจของผู้ใช้งานอยู่ในระดับ "มากที่สุด" (ค่าเฉลี่ย 4.36)

2. วิธีดำเนินงานวิจัย

2.1 สมมติฐานการวิจัย

2.1.1 ระบบการเช็คชื่อเข้าชั้นเรียนด้วยการตรวจจับใบหน้าโดยใช้ CNN และ Deep learning มีความแม่นยำในการระบุใบหน้าของนักเรียนมากกว่า 60%

2.1.2 ระบบการเช็คชื่อเข้าชั้นเรียนด้วยการตรวจจับใบหน้าโดยใช้ CNN และ Deep learning มีความแม่นยำในการตรวจจับใบหน้าสูงกว่าระบบการเช็คชื่อด้วยวิธีดั้งเดิม

2.1.3 ระบบการเช็คชื่อเข้าชั้นเรียนด้วยการตรวจจับใบหน้าโดยใช้ CNN และ Deep learning สามารถใช้งานได้จริงในสถานการณ์ที่แสง และมุมมองแตกต่างกัน

2.2 ประชากรที่ใช้ในการศึกษา

2.2.1 นักศึกษา ประชากรมหาวิทยาลัยเทคโนโลยีราชมงคลกรุงเทพ คณะวิทยาศาสตร์และเทคโนโลยี ชั้นปีที่ 4 ที่เป็นผู้ใช้งานระบบเช็คชื่อเข้าชั้นเรียนกลุ่มตัวอย่างสำหรับประเมินประสิทธิภาพ โดยคัดเลือกจากนักศึกษาคณะวิทยาศาสตร์ สาขาเทคโนโลยีสารสนเทศที่เป็นอาสาสมัครจำนวน 27 คน การเก็บรวบรวมรูปภาพที่ใช้ในการทดลองจะใช้วิธีการแบ่งกลุ่มนักศึกษาเพื่อถ่ายรูปแบบกลุ่ม โดยจำกัดนักศึกษาในรูปภาพเป็นจำนวน 4, 6, 8, 10, 12, 14 และ 16 คน และจำกัดระยะการถ่ายรูปภาพที่ระยะ 2, 3, 4, 5 เมตร โดยรูปที่ถ่ายเพื่อนำไปใช้ในการทดลองจะมีจำนวน 20 รูปต่อ 1 เงื่อนไขการทดลอง

2.2.2 ผู้สอน ผู้ใช้ระบบที่มีหน้าที่ในการจัดการ และตรวจสอบการเช็คชื่อของนักศึกษาในกลุ่มตัวอย่างจะคัดเลือกจากอาจารย์ที่มีส่วนเกี่ยวข้องในการใช้ระบบ จำนวน 3 คน โดยใช้วิธีการคัดเลือกแบบเจาะจงเพื่อประเมินประสิทธิภาพและความสะดวกในการใช้งานระบบจากมุมมองของผู้ใช้ระบบและผู้ดูแลระบบ


2.2.3 ผู้ดูแลระบบ ประชากรมหาวิทยาลัยเทคโนโลยีราชมงคลกรุงเทพที่ทำหน้าที่ดูแลระบบ และตรวจสอบความถูกต้องของระบบการเช็คชื่อโดยกลุ่มตัวอย่างจะคัดเลือกจาก

ผู้ดูแลระบบจำนวน 1 คนโดยใช้วิธีการคัดเลือกแบบเจาะจงเพื่อความสะดวกในการเก็บข้อมูลและประเมินประสิทธิภาพของการจัดการระบบ

2.3 การวิเคราะห์ระบบ

การวิเคราะห์ระบบการเช็คชื่อเข้าชั้นเรียนด้วยการตรวจจับใบหน้าโดยใช้ CNN และ Deep learning ประกอบด้วยขั้นตอน ดังนี้

2.3.1 ภาพรวมการทำงานของระบบ




รูปที่ 4 ภาพรวมการทำงานของระบบการเช็คชื่อเข้าชั้นเรียนด้วยการตรวจจับใบหน้าโดยใช้ CNN และ Deep learning ด้วยเว็บแอปพลิเคชัน (Web Application)

จากรูปที่ 4 ภาพรวมการทำงานของระบบการเช็คชื่อเข้าชั้นเรียนด้วยการตรวจจับใบหน้าโดยใช้ CNN และ Deep learning ด้วยเว็บแอปพลิเคชัน (Web Application) อธิบายได้ดังนี้

- 1) ผู้ดูแลระบบ เข้าใช้งานผ่านเว็บเบราว์เซอร์ (Web browser) โดยทำการเข้าสู่ระบบผ่านกูเกิ้ลล็อกอิน (Google Login) เพื่อไปยังหน้าเว็บไซต์ (Website) สำหรับการจัดการข้อมูลนักศึกษา ข้อมูลอาจารย์ ข้อมูลห้องเรียน ข้อมูลวิชาเรียน และข้อมูลตารางสอน จากนั้นบันทึกข้อมูลไปยังฐานข้อมูล
- 2) ผู้สอน เข้าใช้งานผ่านเว็บเบราว์เซอร์ (Web browser) โดยทำการเข้าสู่ระบบผ่านกูเกิ้ลล็อกอิน (Google Login) เพื่อไปยังหน้าเว็บไซต์ (Website) สำหรับการค้นหาตารางสอน และเลือกกลุ่มเรียนที่ต้องการเช็คชื่อ จากนั้นอัปโหลดรูปภาพนักศึกษาแบบกลุ่ม ระบบจะเรียกใช้ API (Application Programming Interface) face_recognition เพื่อนำรูปภาพนักศึกษาแบบกลุ่มที่ผู้สอนอัปโหลดมาทำการเข้ารหัส และนำไปเปรียบเทียบกับชุดรหัสใบหน้าที่รู้จักในฐานข้อมูล จากนั้นส่งผลลัพธ์กลับมายังเว็บเบราว์เซอร์ (Web browser)

2.3.2 การทำงานของระบบการเช็คชื่อเข้าชั้นเรียนด้วยการตรวจจับใบหน้าโดยใช้ CNN และ Deep learning



รูปที่ 5 แผนภาพการทำงานของระบบการเช็คชื่อเข้าชั้นเรียนด้วยการตรวจจับใบหน้าโดยใช้ CNN และ Deep learning

การทำงานของระบบการเช็คชื่อเข้าชั้นเรียนด้วยการตรวจจับใบหน้าโดยใช้ CNN และ Deep learning สามารถอธิบายได้ดังรูปภาพที่ 5 ได้ดังนี้


โดยเริ่มต้นจากการที่ผู้สอนทำการอัปโหลดรูปภาพนักศึกษาแบบกลุ่มเข้ามาในระบบจำนวน 1 รูป หรือมากกว่าเพื่อทำการตรวจจับใบหน้า (Face Detection) โดยมีข้อกำหนดการอัปโหลดรูปภาพ ดังนี้

- 1) รูปภาพต้องเป็นประเภทไฟล์เป็น JPG, JPEG หรือ PNG เท่านั้น
- 2) ความละเอียดของใบหน้าในรูปภาพขั้นต่ำ ควรมีความกว้าง (width) และ ความสูง (height) อย่างน้อย 40 x 40 พิกเซล
- 3) รูปภาพที่อัปโหลดแต่ละรูปต้องมีขนาดไฟล์ไม่เกิน 5 MB

จึงสามารถนำเข้าสู่ระบบได้ จากนั้นระบบจะทำการอ่านรูปภาพทีละรูป โดยมีเงื่อนไขหากพบใบหน้าในรูปภาพ ระบบจะทำการเข้าเข้ารหัสใบหน้า (Face Encoding)

เพื่อให้ได้ลักษณะเฉพาะของใบหน้า (Face Extraction) ออกมา แต่หากไม่พบใบหน้าในรูปภาพระบบจะให้ผู้สอนทำการอัปเดตรูปภาพใหม่อีกครั้ง เมื่อได้ลักษณะเฉพาะของใบหน้า (Face Extraction) แล้วระบบจะนำรหัสใบหน้าไปเปรียบเทียบกับข้อมูลรหัสใบหน้าของบุคคลที่มีอยู่ในฐานข้อมูล โดยกำหนดเงื่อนไขดังนี้ หากรหัสใบหน้าที่มีความใกล้เคียงกันกับรหัสใบหน้าในฐานข้อมูล โดยที่กำหนดค่าความคลาดเคลื่อนไม่เกิน 0.5 ระบบจะทำการจับคู่ใบหน้าระหว่างรหัสใบหน้าที่ตรวจจับเจอในรูปภาพ และรหัสใบหน้าของบุคคลในฐานข้อมูล แต่หากรหัสของใบหน้าที่ตรวจจับเจอในรูปภาพ มีค่าความคลาดเคลื่อนเกิน 0.5 ระบบจะทำการส่งข้อความแจ้งเตือนการไม่พบรายชื่อในกลุ่มเรียน และเมื่อเปรียบเทียบใบหน้าสำเร็จแล้ว ระบบจะทำการบันทึกเวลาการเข้าเรียนพร้อมระบุสถานะ (เช่น ตรงเวลา มาสาย ขาดเรียน) โดยอ้างอิงจากเงื่อนไขเวลาที่กำหนดการเข้าเรียนในแต่ละสัปดาห์ จากนั้นแสดงผลออกมาในรูปแบบของรายงานการเข้าเรียนรายวัน เมื่อสรุปผลสำเร็จผู้สอนสามารถเลือกที่จะบันทึกรายงาน และอัปเดตฐานข้อมูล หรือไม่บันทึกรายงานและไม่อัปเดตฐานข้อมูลได้ จากนั้นสิ้นสุดการทำงาน

2.3.3 วิเคราะห์ระบบด้วยแผนภาพยูสเคส (Use case diagram)



รูปที่ 6 แผนภาพยูสเคสของระบบการเช็คชื่อเข้าชั้นเรียน
ด้วยการตรวจจับใบหน้าโดยใช้ CNN และ Deep learning
จากรูปที่ 6 สามารถแบ่งกลุ่มผู้ที่มีส่วนเกี่ยวข้องกับระบบเป็น 2 กลุ่ม คือผู้ดูแลระบบและผู้สอนซึ่งอธิบายความต้องการของระบบได้ดังนี้

2.3.3.1 ส่วนของผู้ดูแลระบบ สามารถจัดการข้อมูลห้องเรียน ข้อมูลนักศึกษา ข้อมูลผู้สอน ข้อมูลวิชาเรียน ข้อมูลตารางสอน และสามารถนำออกรายชื่อนักศึกษา

2.3.3.2 ส่วนของผู้สอน สามารถนำออกรายชื่อนักศึกษารูปแบบไฟล์ .xlsx ค้นหาข้อมูลตารางสอน นำเข้าข้อมูลรายชื่อนักศึกษาในกลุ่มเรียนในรูปแบบไฟล์ .xlsx ลบข้อมูลนักศึกษาในกลุ่มเรียน แก้ไขเวลาการเข้าชั้นเรียน เช็คชื่อเข้าชั้นเรียน และดูรายละเอียดผลสรุปการเข้าร่วมการเช็คชื่อเข้าชั้นเรียน

2.4 การออกแบบระบบ

การออกแบบระบบการเช็คชื่อเข้าชั้นเรียนด้วยการตรวจจับใบหน้าโดยใช้ CNN และ Deep learning ประกอบด้วยขั้นตอน ดังนี้

2.4.1 การออกแบบระบบส่วนนำเข้าข้อมูล (Input Design) ประกอบด้วย

- 1) การจัดการข้อมูลนักศึกษา อาจารย์ ห้องเรียน วิชาเรียนและตารางสอน
- 2) การนำเข้าข้อมูลนักศึกษาในกลุ่มเรียน
- 3) การอัปเดตรูปภาพนักศึกษาเพื่อการเช็คชื่อ
- 4) การแก้ไขเวลาการเข้าชั้นเรียน


2.4.2 การออกแบบระบบส่วนแสดงผลลัพธ์การทำงานข้อมูล (Output Design) ประกอบด้วย

- 1) การแสดงผลข้อมูลนักศึกษา อาจารย์ ห้องเรียนและวิชาเรียน
- 2) การนำออกรายชื่อนักศึกษา
- 3) การแสดงผลตารางสอนและกลุ่มเรียน
- 4) การแสดงผลตารางการเข้าเรียน 15 สัปดาห์
- 5) การแสดงผลรายงานการเข้าเรียนรายวัน

2.4.3 การออกแบบโมดูลการรู้จำใบหน้า

โมดูลการรู้จำใบหน้าเป็นองค์ประกอบที่มีความสำคัญอย่างยิ่งต่อระบบการเช็คชื่อเข้าชั้นเรียนด้วยการตรวจจับใบหน้าโดยใช้ CNN และ Deep learning เนื่องจากเป็นส่วนที่ใช้ในเรียนรู้ข้อมูลใบหน้า โดยจะทำการดึงข้อมูล


รูปภาพใบหน้าจากฐานข้อมูลนักศึกษา เพื่อนำไปสร้างรหัสชุดข้อมูลต้นแบบเฉพาะบุคคล และบันทึกลงฐานข้อมูลกลุ่มเรียน โดยมีแผนภาพแสดงการทำงาน (Flowchart) ของการออกแบบโมดูลการรู้จำใบหน้า ดังรูปภาพที่ 7



รูปที่ 7 แผนภาพการทำงานของโมดูลการรู้จำใบหน้า

2.4.4 การออกแบบโมดูลการตรวจจับและเปรียบเทียบใบหน้า

โมดูลการตรวจจับและเปรียบเทียบใบหน้าเป็นอีกหนึ่งองค์ประกอบที่สำคัญในระบบการเช็คชื่อเข้าชั้นเรียน ด้วยการตรวจจับใบหน้าโดยใช้ CNN และ Deep learning โดยหน้าที่ของโมดูลนี้คือการระบุตำแหน่งใบหน้าปรากฏในรูปภาพที่อัปโหลด จากนั้นทำการเข้ารหัสใบหน้า และนำไปเปรียบเทียบกับรหัสใบหน้าในฐานข้อมูล เพื่อใช้ระบุตัวตนของนักศึกษาในชั้นเรียนได้ โดยมีแผนภาพแสดงการทำงาน (Flowchart) ของการออกแบบโมดูลการตรวจจับและเปรียบเทียบใบหน้า ดังรูปภาพที่ 8



รูปที่ 8 แผนภาพการทำงานของโมดูลการตรวจจับและเปรียบเทียบใบหน้า

2.5 เทคโนโลยี/อุปกรณ์ที่ใช้ในการพัฒนาระบบ

2.5.1 พัฒนาโปรแกรมประยุกต์ด้วยภาษา Python

2.5.2 พัฒนาคำสั่งการใช้ PHP ร่วมกับ React.js

2.5.3 กล้องบนอุปกรณ์มือถือ

2.5.4 MySQL สำหรับจัดเก็บข้อมูลผู้ใช้และประวัติการเข้าร่วมเช็คชื่อเข้าชั้นเรียน

2.5.5 Apache ทำหน้าที่เป็นเครื่องให้บริการเว็บ

2.5.6 HOG สำหรับช่วยให้การตรวจจับใบหน้าที่มีความแม่นยำมากขึ้น



รูปที่ 9 แผนภาพสถาปัตยกรรมระบบการเช็คชื่อเข้าชั้นเรียน ด้วยการตรวจจับใบหน้าโดยใช้ CNN และ Deep learning

2.6 การทดสอบระบบ

การทดสอบระบบมีวัตถุประสงค์เพื่อประเมินความแม่นยำ และความสมบูรณ์ของระบบว่าสามารถตอบสนองต่อความต้องการของผู้ใช้งานได้หรือไม่ โดยพิจารณาว่าระบบที่พัฒนาขึ้นสามารถใช้งานได้จริง รวมถึงสามารถตรวจจับ และระบุตัวตนบุคคลจากใบหน้าได้อย่างถูกต้อง และแม่นยำ ผู้พัฒนาเลือกใช้วิธีการทดสอบระบบเช็คชื่อเข้าชั้นเรียนด้วยเทคโนโลยีการตรวจจับใบหน้า ผ่านเว็บแอปพลิเคชัน (Web Application) โดยเป็นการทดสอบในสถานการณ์จริง พร้อมใช้ข้อมูลจริงในการประเมินผล เพื่อให้มั่นใจว่าระบบสามารถทำงานได้ตามที่คาดหวัง

2.6.1 การออกแบบการทดสอบ

เพื่อหาสภาพแวดล้อมที่เหมาะสมสำหรับการใช้งานระบบการเช็คชื่อเข้าชั้นเรียนด้วยการตรวจจับใบหน้า โดยใช้ CNN และ Deep learning มีข้อกำหนดการทดลองภายในสภาพแวดล้อม ดังนี้

- 1) สภาพแสง (Lighting Conditions) เป็นพื้นที่ร่ม (Indoor) ที่มีแสงสว่างภายในอาคาร
- 2) ลักษณะของใบหน้าไม่สวมหมวก ไม่ใส่หน้ากากอนามัย
- 3) ท่าทางของใบหน้าหันหน้าตรง

4) เงื่อนไขการทดลอง

- ระยะการตรวจจับใบหน้า (Distance)
ระหว่างโทรศัพท์มือถือกับใบหน้า ได้แก่ 2 เมตร, 3 เมตร, 4 เมตร และ 5 เมตร


- จำนวนเป้าหมายใบหน้าในการตรวจจับแต่ละครั้ง (Number of target faces in each detection)
ได้แก่ 4 คน, 6 คน, 8 คน, 10 คน, 12 คน, 14 คน และ 16 คน

- จำนวนภาพใบหน้าต้นแบบต่อคน (Number of prototype facial images per person)
สามารถแบ่งได้ ดังนี้ รูปภาพที่ 1 มุมมองใบหน้าตรง รูปภาพที่ 2 มุมมองใบหน้าหันทางซ้าย 45 องศา และรูปภาพที่ 3 มุมมองใบหน้าหันทางขวา 45 องศาโดยมีเงื่อนไขในการเตรียมรูปภาพใบหน้าต้น ดังนี้

1) รูปภาพต้องเป็นประเภทไฟล์เป็น JPG, JPEG หรือ PNG เท่านั้น

2) ความละเอียดของใบหน้าในรูปภาพขั้นต่ำควรมีความกว้าง (width) และ ความสูง (height) อย่างน้อย 160 x 200 พิกเซล

3) รูปภาพที่อัปโหลดแต่ละรูปต้องมีขนาดไฟล์ไม่เกิน 5 MB



รูปที่ 10 แผนภาพแบบจำลองขณะใช้งานระบบการเช็คชื่อ
เข้าชั้นเรียนด้วยการตรวจจับใบหน้าโดยใช้ CNN และ Deep
learning

3. ผลและการอภิปรายผลการวิจัย

ผลที่ได้จากการพัฒนาระบบการเช็คชื่อเข้าชั้นเรียนด้วย
การตรวจจับใบหน้าโดยใช้ CNN และ Deep learning
สามารถสรุปได้ดังนี้

3.1 ผลการพัฒนาระบบ

3.1.1 ผลที่ได้จากการพัฒนาระบบมีดังนี้

Number of Uploaded Images: 1
Upload Time: 2024-10-15 15:32:38



รูปที่ 11 หน้าจอแสดงผลการเข้าร่วมชั้นเรียนด้วยการ
ตรวจจับใบหน้า

Present Group:

Student Id: 64502100087-4
Name: กฤษกร รวีสุนทร
Attendance time: 2024-10-19 08:37:34

Student Id: 64502100082-5
Name: สรดิษ เสาสาเนียง
Attendance time: 2024-10-19 08:37:34

Student Id: 64502100030-4
Name: เกรียงศักดิ์ มะโนชัย
Attendance time: 2024-10-19 08:37:34

Student Id: 64502100090-8
Name: ญาณิศา เนาวสุข
Attendance time: 2024-10-19 08:37:34

Late Group:

Student Id: 64502100053-6
Name: พีรพีช เจริญทรัพย์
Attendance time: 2024-10-19 13:37:40

Student Id: 64502100059-3
Name: ศักดิ์พัฒน์ เกตุพุด
Attendance time: 2024-10-19 13:37:40

รูปที่ 12 หน้าจอแสดงผลรายงานสรุปการเข้าชั้น
เรียน

Report Attendance					
Attendance History Table					
Attendance Date/Time	Present group	Late group	Absent group	Total	
2024-10-15 15:41:50	9	0	0	9	More

รูปที่ 13 หน้าจอแสดงประวัติการเช็คชื่อเข้าชั้นเรียน

3.2 ผลการทดสอบประสิทธิภาพของโมเดลการ

ตรวจจับใบหน้า

3.2.1 ผลการทดลองความแม่นยำ (Accuracy) ของโมเดลการตรวจจับใบหน้า สามารถคำนวณได้ดังสมการ


$$\text{Accuracy} = \frac{\text{จำนวนครั้งที่ตรวจจับใบหน้าถูกต้อง}}{\text{จำนวนครั้งทดสอบทั้งหมด}} \times 100\%$$

ตารางที่ 1 ตารางผลการทดสอบความแม่นยำ

ระยะการตรวจจับใบหน้า	จำนวนครั้งในการทดสอบ	จำนวนเป้าหมายใบหน้าในการตรวจจับแต่ละครั้ง	เปอร์เซ็นต์ ค่าเฉลี่ยความแม่นยำ
2 เมตร	140 ครั้ง	4 คน	100%
		6 คน	100%
		8 คน	95%
		10 คน	95%
		12 คน	85%
		14 คน	75%
3 เมตร	140 ครั้ง	4 คน	100%
		6 คน	100%
		8 คน	90%
		10 คน	85%
		12 คน	80%
		14 คน	70%
4 เมตร	140 ครั้ง	4 คน	95%
		6 คน	95%
		8 คน	80%
		10 คน	75%
		12 คน	75%
		14 คน	65%
5 เมตร	140 ครั้ง	4 คน	90%
		6 คน	80%
		8 คน	70%
		10 คน	50%
		12 คน	45%
		14 คน	30%

จากผลการทดสอบพบว่า

- ระยะการตรวจจับใบหน้าเป้าหมายในรูปภาพที่อยู่ในระยะ 2 เมตร มีค่าเฉลี่ยความแม่นยำมากที่สุดในการตรวจจับใบหน้า และเมื่อระยะห่างเพิ่มขึ้นเป็น 3 เมตร 4 เมตร และ 5 เมตร ความแม่นยำในการตรวจจับใบหน้าจะลดลงอย่างเห็นได้ชัด
- เมื่อจำนวนใบหน้าที่ระบบต้องตรวจจับในการทดลองแต่ละครั้งมี 4 คน ระบบสามารถตรวจจับได้แม่นยำกว่าเมื่อมีจำนวนเป้าหมายใบหน้าเพิ่มขึ้นเป็น 6 คน 8 คน 10 คน 12 คน 14 คน และ 16 คน ในการตรวจจับแต่ละครั้ง



รูปที่ 14 แผนภูมิแสดงการเปรียบเทียบระยะการตรวจจับใบหน้า 2 เมตร ถึง 5 เมตร

3.2.2 ผลการทดสอบเมตริกซ์ประสิทธิภาพ (Performance Metrics) ของโมเดลการตรวจจับใบหน้า สามารถคำนวณได้จาก Confusion Matrix Table

ตารางที่ 2 ตารางผลการทดสอบเมตริกซ์ประสิทธิภาพ

Predicted condition \ Actual condition	Actual condition	
	Positive	Negative
Actual positive	True positive (TP)	False positive (FN)
Actual negative	False positive (FP)	True negative (TN)

1) Precision = สัดส่วนของจำนวนใบหน้าที่โมเดลตรวจจับและระบุได้อย่างถูกต้อง (True Positives) ต่อจำนวนใบหน้าที่โมเดลตรวจจับได้ทั้งหมด (True Positives + False Positives) โดยคำนวณได้ดังสมการ

$$\text{Precision} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Positives}}$$

ในบริบทของการตรวจจับใบหน้า Precision จะแสดงถึงความแม่นยำของระบบในการตรวจจับใบหน้าที่แท้จริงโดยไม่มีการตรวจจับผิดพลาด เช่น การระบุวัตถุอื่นเป็นใบหน้า (False Positives)

2) Recall = สัดส่วนของจำนวนใบหน้าที่โมเดลตรวจจับและระบุได้อย่างถูกต้อง (True Positives) ต่อจำนวนใบหน้าที่ทั้งหมดที่มีอยู่ในภาพ (True Positives + False Negatives) โดยคำนวณได้ดังสมการ

$$\text{Recall} = \frac{\text{True Positives}}{\text{True Positives} + \text{False Negatives}}$$

ในบริบทของการตรวจจับใบหน้า Recall จะแสดงถึงความสามารถของระบบในการตรวจจับใบหน้าที่ทั้งหมดที่มีอยู่ในภาพ โดยไม่มีการพลาด (False Negatives)

3) F1-Score = ค่า Harmonic Mean ระหว่างค่าความถูกต้อง (Precision) และค่าความครอบคลุม (Recall) ดังสมการ

$$F1 \text{ Score} = 2 * (Precision * Recall) / (Precision + Recall)$$

F1-Score สะท้อนถึงสมดุลระหว่างความถูกต้อง (Precision) และความครอบคลุม (Recall) ของการตรวจจับใบหน้า โดยเป็นตัวชี้วัดสำคัญสำหรับประเมินประสิทธิภาพของระบบในกรณีที่มีความไม่สมดุลระหว่างจำนวนใบหน้าที่ตรวจจับได้ถูกต้องกับจำนวนใบหน้าที่ทั้งหมดในภาพ

ตารางที่ 3 ตารางผลการทดสอบเมตริกซ์ประสิทธิภาพ

ระยะการตรวจจับใบหน้า	จำนวนครั้งในการทดสอบ	จำนวนใบหน้าที่พบในการตรวจจับแต่ละครั้ง	ค่า F1-Score	ค่า Precision	ค่า Recall
2 เมตร	140 ครั้ง	4 คน	1	1	1
		6 คน	1	0.95	0.97
		8 คน	1	0.90	0.95
		10 คน	0.90	0.85	0.87
		12 คน	0.91	0.85	0.88
		14 คน	0.91	0.70	0.79
3 เมตร	140 ครั้ง	16 คน	0.85	0.70	0.77
		4 คน	1	1	1
		6 คน	1	0.9	0.95
		8 คน	0.87	0.85	0.86
		10 คน	0.89	0.85	0.87
		12 คน	0.83	0.75	0.79
4 เมตร	140 ครั้ง	14 คน	0.76	0.7	0.73
		16 คน	0.79	0.65	0.71
		4 คน	0.79	0.90	0.84
		6 คน	0.74	0.85	0.79
		8 คน	0.76	0.80	0.78
		10 คน	0.71	0.70	0.70
5 เมตร	140 ครั้ง	12 คน	0.69	0.65	0.67
		14 คน	0.69	0.65	0.67
		16 คน	0.67	0.60	0.63
		4 คน	0.78	0.80	0.79
		6 คน	0.71	0.75	0.73
		8 คน	0.65	0.70	0.67
	140 ครั้ง	10 คน	0.63	0.50	0.56
		12 คน	0.56	0.45	0.50
		14 คน	0.51	0.30	0.37
		16 คน	0.49	0.25	0.33

จากผลการทดสอบพบว่า

- ค่า F1-Score, Precision และ Recall สูงสุดที่เงื่อนไขการทดลองที่ระยะการตรวจจับไกลที่สุด (2 เมตร) และจำนวนเป้าหมายใบหน้าที่ในการตรวจจับแต่ละครั้งน้อยที่สุด (4 คน) ซึ่งมีค่า F1-Score อยู่ที่ 1 Precision อยู่ที่ 1 และ Recall อยู่ที่ 1

- ค่า F1-Score, Precision และ Recall ต่ำสุดที่เงื่อนไขการทดลองที่ระยะการตรวจจับไกลที่สุด (5 เมตร) และจำนวนเป้าหมายใบหน้าที่ในการตรวจจับแต่ละครั้งมากที่สุด (16 คน) ซึ่งมีค่า F1-Score อยู่ที่ 0.49 Precision อยู่ที่ 0.25 และ Recall อยู่ที่ 0.33

- ระยะการตรวจจับ และจำนวนเป้าหมายใบหน้าที่ในการตรวจจับแต่ละครั้งมีผลต่อค่าเมตริกซ์ประสิทธิภาพได้อย่างชัดเจน

- ระยะการตรวจจับไกลที่สุด (2 เมตร) ให้ค่าเมตริกซ์ประสิทธิภาพสูงกว่าระยะการตรวจจับที่ใกล้ขึ้น (3 เมตร 4 เมตร และ 5 เมตร)

- จำนวนเป้าหมายใบหน้าที่ในการตรวจจับแต่ละครั้งน้อยที่สุด (4 คน) ให้ค่าเมตริกซ์ประสิทธิภาพสูงกว่าจำนวนเป้าหมายใบหน้าที่ในการตรวจจับแต่ละครั้งมากขึ้น (6 คน 8 คน 10 คน 12 คน 14 คน และ 16 คน)

จากผลการวิจัยสามารถอภิปรายผลได้ดังนี้ ระบบการเช็คชื่อเข้าชั้นเรียนด้วยการตรวจจับใบหน้าโดยใช้ CNN และ Deep learning นี้แสดงถึงความเหมาะสมในเชิงเทคนิค และการใช้งานจริงในสถานศึกษา โดยเฉพาะอย่างยิ่งสำหรับการใช้งานในสภาพแวดล้อมที่มีการจัดการอย่างเป็นระบบ และมีแสงเพียงพอ นอกจากนี้ระบบสามารถช่วยแก้ไขปัญหาที่พบในวิธีการเช็คชื่อแบบดั้งเดิม เช่น การเรียกชื่อ การสแกนลายนิ้วมือ การใช้ QR Code หรือการเช็คชื่อผ่านแบบฟอร์มทางออนไลน์ โดยใช้การยืนยันตัวตนด้วยใบหน้าที่เป็นเอกลักษณ์เฉพาะตัว ทำให้มั่นใจได้ว่าข้อมูลการเข้าเรียนของนักศึกษาเป็นไปอย่างถูกต้องและโปร่งใส

4. สรุปผลการวิจัย

จากการพัฒนาระบบการเช็คชื่อเข้าชั้นเรียนด้วยการตรวจจับใบหน้าโดยใช้ CNN และ Deep learning ซึ่งมีวัตถุประสงค์เพื่อทดสอบประสิทธิภาพความแม่นยำของระบบการเช็คชื่อเข้าชั้นเรียนด้วยการตรวจจับใบหน้าโดยใช้ CNN และ Deep learning และพัฒนาระบบลงชื่อด้วยการตรวจจับใบหน้า โดยลดข้อผิดพลาดในการบันทึกข้อมูล ผลการวิจัยสามารถสรุปได้ ดังนี้

การใช้งานระบบการเช็คชื่อเข้าชั้นเรียนด้วยการตรวจจับใบหน้าโดยใช้ CNN และ Deep learning ควรใช้รูปภาพที่มีรายละเอียดของใบหน้าที่ชัดเจน (เช่น ดวงตา จมูก ปาก และหน้าผาก) จะทำให้ระบบตรวจจับใบหน้าที่ทำงานได้อย่างแม่นยำ และมีประสิทธิภาพ จาก

การทดลองในตารางที่ 1 สรุปได้ว่าระยะการตรวจจับที่ไกล (2 เมตร) มีความแม่นยำสูงที่สุด โดยค่าความสอดคล้องอยู่ในช่วงเฉลี่ยร้อยละ 75 ถึง 100 สำหรับกลุ่ม 4 ถึง 16 คน และเมื่อระยะการตรวจจับเพิ่มขึ้น (3, 4 และ 5 เมตร) ค่าความสอดคล้องลดลงอย่างชัดเจน โดยเฉพาะเมื่อจำนวนคนในภาพเพิ่มขึ้น ทั้งนี้ขึ้นอยู่กับความละเอียดของใบหน้าในรูปภาพ หากความละเอียดของใบหน้าในรูปภาพน้อยลง ก็จะส่งผลให้ค่าเฉลี่ยความแม่นยำน้อยลงเช่นกัน

โดยสามารถสรุปได้ว่าใบหน้าเป้าหมายในรูปภาพที่อยู่ในระยะ 2 เมตร มีค่าเฉลี่ยความแม่นยำมากที่สุด เนื่องจากมีความละเอียดของใบหน้าในรูปภาพสูง และใบหน้าเป้าหมายในรูปภาพที่อยู่ในระยะ 5 เมตร มีค่าเฉลี่ยความแม่นยำน้อยที่สุด เนื่องจากมีความละเอียดของใบหน้าในรูปภาพต่ำจึงยากต่อการตรวจจับ และระบุตัวตนของบุคคลในรูปภาพโดยการตรวจจับใบหน้าของผู้เข้าร่วมการทดลองทั้งหมดมีความแม่นยำเฉลี่ยร้อยละ 75

โดยระบบการเช็คชื่อเข้าชั้นเรียนด้วยการตรวจจับใบหน้าโดยใช้ CNN และ Deep learning มีข้อจำกัดในการใช้งานในสภาพแวดล้อมที่มีแสงน้อย ภาพที่มีใบหน้าเป้าหมายอยู่ในระยะไกล และภาพที่มีความละเอียดต่ำเนื่องจากอาจส่งผลให้เกิดข้อผิดพลาดในการตรวจจับใบหน้าและยืนยันตัวตน นอกจากนี้การใช้งานระบบการเช็คชื่อเข้าชั้นเรียนด้วยการตรวจจับใบหน้าโดยใช้ CNN และ Deep learning จำเป็นต้องได้รับความยินยอมจากผู้ใช้ในการจัดเก็บรูปภาพใบหน้าต้นแบบ ซึ่งการได้รับความยินยอมดังกล่าวมีความสำคัญอย่างยิ่งในการรักษาความเป็นส่วนตัว และปกป้องข้อมูลส่วนบุคคลของผู้ใช้งาน

เอกสารอ้างอิง

[1] A. A. M. Alshiha, M. W. Al-Neama, and A. R. Qubaa, "Parallel Hybrid Algorithm for Face Recognition Using Multi-Linear Methods," *International Journal of Electrical*

and Electronics Research, vol. 11, no. 4, pp. 1013–1021, Nov. 2023.

- [2] Z. Li, F. Liu, W. Yang, S. Peng and J. Zhou, "A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 33, no. 12, pp. 6999–7019, Dec. 2022.
- [3] S. Sakib, N. Ahmed, A. J. Kabir, and H. Ahmed, "An overview of convolutional neural network: Its architecture and applications," *Bangladesh: Preprints*, 2018.
- [4] R. Yamashita, M. Nishio, R. K. G. Do, and K. Togashi, "Convolutional Neural networks: an Overview and Application in Radiology," *Insights into Imaging*, vol. 9, no. 4, pp. 611–629, Jun. 2018.
- [5] S. R. Dubey, S. K. Singh, and B. B. Chaudhuri, "Activation functions in deep learning: A comprehensive survey and benchmark," *Neurocomputing*, vol. 503, pp. 93–108, Sep. 2022.
- [6] A. Zafar, M. Aamir, N. Mohd Nawi, A. Arshad, S. Riaz, A. Alruban, A. K. Dutta, and S. Almotairi, "A Comparison of Pooling Methods for Convolutional Neural Networks," *Applied Sciences*, vol. 12, no. 17, p. 8643, Jan. 2022.
- [7] X. Zhao, L. Wang, Y. Zhang, X. Han, M. Deveci, and M. Parmar, "A review of convolutional neural networks in computer vision," *Artificial Intelligence Review*, vol. 57, pp. 99–142, Mar. 2024.
- [8] Nwankpa, C. E., Ijomah, W., Gachagan, A., and Marshall, S. "Activation functions: comparison of trends in practice and research for deep learning," in *Proc. 2nd International Conference on Computational Sciences and Technology*, Jamshoro, Pakistan. 2021. pp.123 - 133.

- [9] P. Carcagni, M. Del Coco, M. Leo, and C. Distant, "Facial expression recognition and histograms of oriented gradients: a comprehensive study," *SpringerPlus*, vol. 4, no. 645, pp. 1–25, 2015.
- [10] W. Zhou, S. Gao, L. Zhang, and X. Lou, "Histogram of Oriented Gradients Feature Extraction from Raw Bayer Pattern Images," *IEEE Transactions on Circuits and Systems II: Express Briefs*, vol. 67, no. 12, pp. 3502–3506, Dec. 2020.
- [11] Chaiyadecha, S. , " Image Classification: Histogram of Oriented Gradients," *Medium*, Mar. 23, 2022. [Online] . Available: <https://lengyi.medium.com/image-classification-histogram-of-oriented-gradients-87ab7b657b6b>.
- [12] S. S. Umar, Z. S. Iro, A. Y. Zandam, and S. S. Shitu, "Accelerated Histogram of Oriented Gradients for Human Detection," *Dutse Journal of Pure and Applied Sciences (DUJOPAS)*, vol. 9, no. 1a, pp. 44–56, Mar. 2023.
- [13] L. Ke and Y. Luo, "A new pedestrian detection method based on histogram of oriented gradients and support vector data description," in *Electronics, Communications and Networks*, vol. 10, pp. 333–342, 2024.
- [14] อรวรรณ เลียบศิริ, "การจำแนกอารมณ์ตัวการ์ตูนด้วยอี ส โ ต แ ก ร ม ข อ ง ท ศ ท ำ ง ต ำ ค ำ เ ก ร เดียนท์," *วิทยานิพนธ์ วท.ม. (วิทยาการคอมพิวเตอร์)* มหาวิทยาลัยธรรมศาสตร์, กรุงเทพฯ, 2559.
- [15] Mahmoudi, K. , " Understanding Histogram of Oriented Gradients (HOG) for Face Detection," Kaamraan, Jan. 22, 2024. [Online]. Available: https://kaamraan.com/understanding-histogram-of-oriented-gradients-hog-for-face-detection/?fbclid=IwY2xjawHm4VpleHRuA2FlbQlxMAABHScZFsjCy47aTiivHij-tn9OSpAqphhex2hSZ3QNV1WORKeldA5T8q7jpA_aem_5X4rPpW9wc8LUBOho_Y5zg.
- [16] ชลิดา ภัทรณิกุล, "ระบบการจดจำใบหน้าของบุคคลโดยใช้การเรียนรู้เชิงลึกและการเรียนรู้ของเครื่อง" *วิทยานิพนธ์ วท.ม. (วิศวกรรมไฟฟ้า)* มหาวิทยาลัยศรีนครินทรวิโรฒ, กรุงเทพฯ, 2566.
- [17] เอกรัตน์ สุขสุนทร, "ระบบลงทะเบียนใบหน้าและตรวจสอบนักศึกษาเข้าห้องเรียน ด้วยหลักการประมวลผลภาพร่วมกับเทคนิคการรู้จำใบหน้า," *วารสารวิชาการสมาคมสถาบันอุดมศึกษาเอกชนแห่งประเทศไทย*, ปีที่ 10, ฉบับที่ 2, หน้า 30-39, กรกฎาคม – ธันวาคม, 2564.
- [18] ศันสนีย์ หิรัญจันทร์ และจิระ ทิวถาวรวงศ์ (2563). "ระบบตรวจจับใบหน้าเพื่อยืนยันตัวตนบุคคลเพื่อสนับสนุนระบบทะเบียนอาชญากร," *วารสารวิทยาศาสตร์ เทคโนโลยีและนวัตกรรม*, ปีที่ 1, ฉบับที่ 6, หน้า 1-7, พฤศจิกายน – ธันวาคม, 2563.
- [19] ณัฐชนน ภูกลาง, ณสิทธิ์ เหล่าเส้น, พิธา จารุพูนผล, และ ธนภุช จันทร์แสง, "ระบบลดเวลาการเข้าทำงานด้วยเทคโนโลยีการจดจำใบหน้าในช่วงการแพร่ระบาดของโควิด-19," ใน *รายงานการประชุมและนำเสนอผลงานวิชาการระดับชาติด้านการศึกษ ครั้งที่ 2*, มหาวิทยาลัยราชภัฏชัยภูมิ, 2565.
- [20] อติดา น้อยวี, บุญชัย แซ่ลัว และศุภรัชชัย วรรัตน์, "การประยุกต์ใช้เทคโนโลยีการรู้จำใบหน้าเพื่อบันทึกเวลาเข้าออกของพนักงาน," *วารสารการจัดการเทคโนโลยี มหาวิทยาลัยราชภัฏมหาสารคาม*, ปีที่ 8, ฉบับที่ 1, หน้า 99–113, มกราคม–มิถุนายน, 2564.