

ระบบตรวจจับป้ายจราจรโดยใช้การเรียนรู้เชิงลึก
Traffic Signs Detection System by Using Deep Learning

ณัฐภัทร ศิริคง

ภาควิชาวิทยาศาสตร์ประยุกต์ คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏนครสวรรค์
natthapat.s@nsru.ac.th

บทคัดย่อ

การรู้จำป้ายจราจรเป็นงานวิจัยที่มีท้าทายกับระบบขับเคลื่อนอัตโนมัติ ซึ่งการรู้จำป้ายจราจรที่มีประสิทธิภาพขึ้นอยู่กับประสิทธิภาพการตรวจจับป้ายจราจรที่มีประสิทธิภาพ การวิจัยครั้งนี้มีวัตถุประสงค์เพื่อ (1) ออกแบบและพัฒนาระบบตรวจจับป้ายจราจรโดยใช้การเรียนรู้เชิงลึก และ (2) วัดประสิทธิภาพของระบบพัฒนาระบบตรวจจับป้ายจราจรโดยใช้การเรียนรู้เชิงลึก การออกแบบระบบตรวจจับป้ายจราจรประกอบไปด้วย 4 ส่วน คือ (1) การเตรียมชุดข้อมูลฝึกฝน (2) การสร้างตัวตรวจจับ (3) การทดสอบตัวตรวจจับ และ (4) การวัดประสิทธิภาพตัวตรวจจับ วิธีการที่นำเสนอนี้ได้รับการทดสอบด้วยชุดข้อมูลป้ายจราจรจำนวน 108 ภาพ และมีค่าความเที่ยงร้อยละ 0.87 ค่ารีคอลร้อยละ 0.89 และค่าการวัดเอฟร้อยละ 0.88 ตามลำดับ

คำสำคัญ: ตรวจจับ, ป้ายจราจร, การเรียนรู้เชิงลึก

Abstract

Traffic Signs recognition is a challenge topic in autonomous driving system. The efficiency of traffic signs detection will have influence on the performance result of traffic signs recognition. This research at (1) designing and developing a traffic signs detection system by using deep learning, and (2) evaluate accuracy of precision recall and F-measure in a traffic signs detection system by using deep learning. The design of traffic sign detection system consists of 4 parts: (1) preparing training data (2) creating a detector (3) testing the detector and (4) performance evaluation a detector. The proposed method was tested with 108 images of dataset and the measurement results were 88 % for precision, 89 % for recall and 87 % for F-measure respectively.

Keywords: Detection, Traffic Signs, Deep Learning

บทนำ

ในปัจจุบันมีผู้คนจำนวนไม่น้อยที่ขับขี่รถในขณะที่อยู่ในสถานะเสี่ยงต่อการเกิดอันตรายอันเนื่องมาจากร่างกายอ่อนเพลีย ตาพร่ามัว พักผ่อนไม่เพียงพอ มีนเมาจากการดื่มแอลกอฮอล์ หรืออาจมีสาเหตุมาจากผู้ขับขี่ที่ไม่ปฏิบัติตามกฎจราจร เช่น ใช้ความเร็วเกินกำหนด แชนในที่ห้ามแชน กลับรินที่ห้ามกลับ เป็นต้น หรืออาจเกิดจากการมองป้ายสัญญาณจราจรไม่ชัดเจน ไม่ทราบความหมายที่ถูกต้องของสัญญาณจราจรนั้น ซึ่งเป็นสาเหตุของการเกิดอุบัติเหตุบนท้องถนน (ธนัญชัย บุญหนัก, กุหลาบ รัตนสังธรรม, ชิงชัย เมธพัฒน์ และ ทนงค์ศักดิ์ ยิ่งรัตนสุข, 2559) การขับขี่อัตโนมัติ (Autonomous Driving) จึงเป็นทางเลือกหนึ่งในการลดการเกิด

อุบัติเหตุบนท้องถนนลงได้ (รถยนต์ไร้คนขับทิศทางใหม่แห่งนวัตกรรมวงการรถยนต์, 2558) และเป็นส่วนหนึ่งของระบบการขนส่งอัจฉริยะ (Intelligent Transport System) เป็นความพยายามในการควบคุมพาหนะให้สามารถขับขึ้นบนท้องถนนไปยังจุดหมายปลายทางโดยไม่เกิดอุบัติเหตุและถูกต้องตามกฎหมาย โดยระบบขับอัตโนมัตินั้นจะสามารถตัดสินใจได้อย่างสมเหตุสมผลในทุกสภาวะแวดล้อม สิ่งที่สามารถเป็นตัวช่วยในการนำทางสำหรับการขับคือ ป้ายจราจร

ป้ายจราจรเป็นอุปกรณ์งานทางที่ติดตั้งบนถนนเพื่ออำนวยความสะดวกและเสริมสร้างความปลอดภัยในการเดินทางแก่ผู้ขับขี่ ประเภทป้ายที่สำคัญในการใช้งานทั่วไป ได้แก่ 1) ป้ายบังคับ ใช้เพื่อบังคับให้ผู้ขับขี่รวมถึงคนเดินเท้าทราบถึงสิทธิและหน้าที่ของตนเองในการปฏิบัติบนท้องถนน 2) ป้ายเตือน ใช้เพื่อเตือนให้ผู้ขับขี่ทราบล่วงหน้าถึงสิ่งที่จะเป็นอันตรายหรือสิ่งที่จะต้องเพิ่มความระมัดระวังมากขึ้น และ 3) ป้ายแนะนำ ใช้เพื่อแนะนำให้ผู้ขับขี่ทราบถึงข้อมูลที่สำคัญขณะใช้เส้นทาง (กรมทางหลวง, 2561)

ในการวิจัยครั้งนี้ผู้วิจัยได้ออกแบบและพัฒนาระบบตรวจจับป้ายจราจรโดยใช้การเรียนรู้เชิงลึก ซึ่งใช้ตัวแบบของโครงข่ายประสาทเทียมแบบคอนโวลูชันที่ได้รับการฝึกฝนมาแล้ว ในส่วนที่สกัดคุณลักษณะของป้ายจราจร คือ YOLO (You Only Look Once) และเพิ่มส่วนการจำแนกประเภทที่ใช้ในการรู้จำเป็นข้อมูลป้ายจราจรแบบป้ายบังคับ จำนวน 9 ป้าย คือ ป้ายห้ามแซง ป้ายห้ามกลับรถไปทางขวา ป้ายห้ามกลับรถไปทางซ้าย ป้ายห้ามเลี้ยวขวา ป้ายห้ามเลี้ยวซ้าย ป้ายห้ามเลี้ยวขวาหรือกลับรถ ป้ายห้ามเลี้ยวซ้ายหรือกลับรถ ป้ายห้ามเปลี่ยนช่องเดินรถ ไปทางขวา และป้ายห้ามเปลี่ยนช่องเดินรถไปทางซ้าย การออกแบบระบบตรวจจับป้ายจราจรประกอบไปด้วย 4 ส่วน คือ การเตรียมชุดข้อมูลฝึกฝน การสร้างตัวตรวจจับ การทดสอบตัวตรวจจับ และการวัดประสิทธิภาพตัวตรวจจับ

วัตถุประสงค์ของการวิจัย

1. เพื่อออกแบบและพัฒนาระบบตรวจจับป้ายจราจรโดยใช้การเรียนรู้เชิงลึก
2. เพื่อวัดประสิทธิภาพของระบบพัฒนาระบบตรวจจับป้ายจราจรโดยใช้การเรียนรู้เชิงลึก

ขอบเขตของการวิจัย

1. การวิจัยครั้งนี้เป็นการวิจัยประยุกต์ โดยทำการพัฒนาระบบตรวจจับป้ายจราจรด้วยการเรียนรู้เชิงลึก
2. ข้อมูลที่ใช้ในการฝึกฝนและทดสอบเป็นภาพถ่ายจากสมาร์ทโฟนในช่วงเวลากลางวันที่มีแสงสว่างเพียงพอ จำนวน 540 ภาพ แบ่งออกเป็นป้ายจราจรแบบป้ายบังคับ จำนวน 9 รูปแบบ ได้แก่ 1) ป้ายห้ามแซง 2) ป้ายห้ามกลับรถไปทางขวา 3) ป้ายห้ามกลับรถไปทางซ้าย 4) ป้ายห้ามเลี้ยวขวา 5) ป้ายห้ามเลี้ยวซ้าย 6) ป้ายห้ามเลี้ยวขวาหรือกลับรถ 7) ป้ายห้ามเลี้ยวซ้ายหรือกลับรถ 8) ป้ายห้ามเปลี่ยนช่องเดินรถไปทางขวา และ 9) ป้ายห้ามเปลี่ยนช่องเดินรถไปทางซ้าย
3. พื้นที่ในการดำเนินงานวิจัยครั้งนี้ คือ จังหวัดนครสวรรค์
4. ระยะเวลาที่ใช้ในการวิจัย ตั้งแต่เดือนมิถุนายน พ.ศ. 2562 ถึงเดือนสิงหาคม พ.ศ. 2562
5. ตัวแปรที่ศึกษา
ตัวแปรอิสระ คือ ระบบตรวจจับป้ายจราจรโดยใช้การเรียนรู้เชิงลึก
ตัวแปรตาม คือ ผลการวัดประสิทธิภาพของระบบตรวจจับป้ายจราจรโดยใช้การเรียนรู้เชิงลึก

ข้อตกลงเบื้องต้น

1. การเก็บข้อมูลภาพถ่ายในสถานที่ที่แตกต่างกันไม่มีผลทำให้เปลี่ยนแปลงไป
2. ช่วงเวลาของการฝึกฝนและทดสอบไม่มีผลต่อการวิจัย

การทบทวนวรรณกรรม

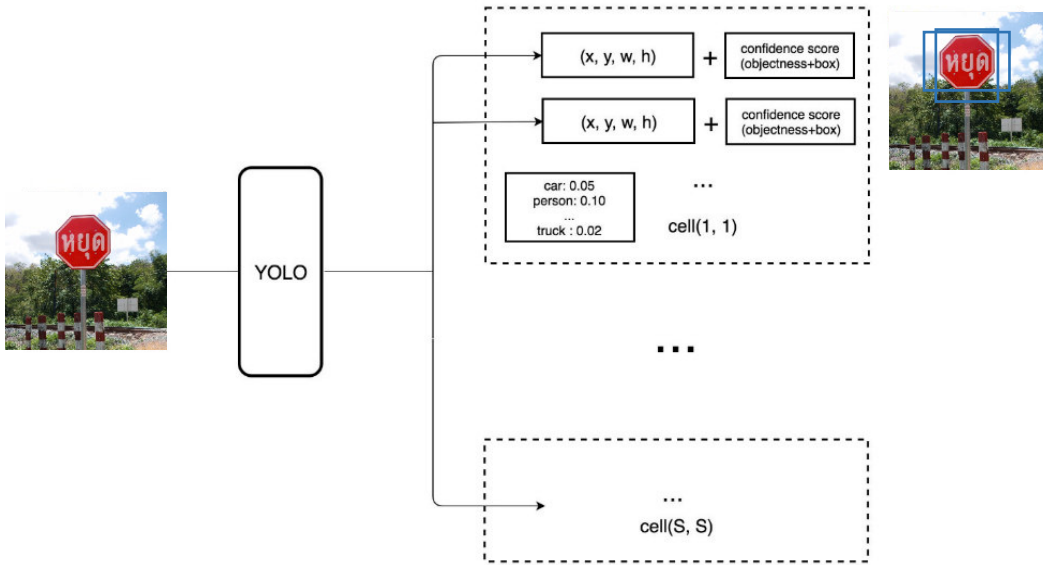
การจำแนกวัตถุในรูปภาพเป็นการเรียนรู้เชิงลึกในการประมวลผลภาพ (Image Processing) และเป็นรูปแบบหนึ่งของการเรียนรู้ของเครื่อง (Machine Learning) ด้วยการเลียนแบบการทำงานของสมองมนุษย์ ที่ทำให้คอมพิวเตอร์รู้จักคิดและจดจำจากการเรียนรู้ข้อมูลที่มีอยู่ เพื่อใช้ทำนายข้อมูลในลักษณะเดียวกัน (Koomsubha, T., & Vateekul, P., 2017) ที่เรียกว่า โครงข่ายประสาทเทียม (Neural Network) การเรียนรู้เชิงลึกสามารถแบ่งได้เป็นโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network: CNN) เครื่องจักรโบลทซ์มันน์เชิงจำกัด (Restricted Boltzmann Machine: RBM) และ ตัวเข้ารหัสอัตโนมัติ (Autoencoder: AN) ซึ่งแต่ละวิธีมีความเหมาะสมในการใช้งานที่แตกต่างกัน เช่น โครงข่ายประสาทเทียมแบบสังวัตนาการเหมาะกับงานด้านการรู้จำวัตถุ โครงข่ายความเชื่อแบบลึก (Deep Belief Networks) เหมาะกับงานด้านการรู้จำตัวอักษร ตัวเข้ารหัสอัตโนมัติแบบลดการรบกวน (Denoising Autoencoder: DAN) เหมาะกับงานด้านการจำแนกข้อมูลตัวอักษร (Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S. & Lew, M. S., 2016)

โครงข่ายประสาทเทียมแบบสังวัตนาการเป็นโครงข่ายประสาทแบบหลายชั้น (Multilayer Perceptron) มีลักษณะแตกต่างจากโครงข่ายประสาทเทียมทั่วไป คือ มีชั้นของเซลล์ประสาทอยู่ในรูปแบบ 3 มิติ คือ มีความกว้าง ความสูง และความลึก โดยการรวมส่วนของการสกัดคุณลักษณะและการจำแนกข้อมูลไว้ด้วยกัน จึงมีความเหมาะสมสำหรับข้อมูลเชิงพื้นที่ การรู้จำวัตถุ และการวิเคราะห์ภาพโดยใช้โครงสร้างเซลล์ประสาทเทียมแบบหลายมิติ (Multidimensional Neural Network) โครงข่ายประสาทเทียมแบบสังวัตนาการไม่ได้ถูกฝึกฝนแบบขั้นต่อขั้น แต่จะทำการปรับค่าน้ำหนักเพื่อลดฟังก์ชันความคลาดเคลื่อนด้วยวิธีการแพร่ค่าความผิดพลาดย้อนกลับ คุณลักษณะของข้อมูลจะถูกดึงออกมาโดยอัตโนมัติด้วยการเรียนรู้หน้ากาคอนโวลูชันที่เกิดจากแผนภาพคุณลักษณะ (Feature Maps) โครงสร้างของโครงข่ายประสาทเทียมแบบสังวัตนาการประกอบด้วยชั้นที่ทำหน้าที่เปลี่ยนแปลงข้อมูลโดยการเรียนรู้จากคุณลักษณะของข้อมูลนำเข้า ชั้นที่พบมากที่สุดประกอบด้วยชั้นคอนโวลูชันตามด้วยชั้นสุ่มตัวอย่าง เรียกว่า ชั้นการสกัดคุณสมบัติ (Feature Extractor Layer) ส่วนชั้นสุดท้ายเป็นชั้นเชื่อมต่อแบบทั่วถึง ซึ่งเป็นชั้นที่แปลงผลลัพธ์จากการทำคอนโวลูชันและดำเนินการสร้างผลลัพธ์สุดท้าย เรียกว่า ชั้นจำแนก (Classification Layer) (Shelhamer, E., Long, J. & Darrell, T., 2017)

เรดมอน, ดิวาลา, เกอร์ซิกซ์ และฟาร์ฮาดี (Redmon, J., Divvala, S., Girshick, R. & Farhadi, A., 2016) ได้นำเสนอเทคนิคการตรวจจับวัตถุ (Object Detection) ที่ชื่อว่า YOLO ซึ่งสามารถประมวลผลได้ตามเวลาจริง (Real-Time) ด้วยความเร็ว 45 ภาพต่อวินาที โดยเร็วกว่า Fast R-CNN ถึง 90 เท่า ต่อมาได้พัฒนาเป็น YOLO9000 (Redmon, J. & Farhadi, A., 2017) และ YOLOv3 (Redmon, J. & Farhadi, A., 2018) ตามลำดับ

ขั้นตอนวิธีของ YOLO มีหลักการทำงานพื้นฐาน คือ การแบ่งรูปภาพที่นำเข้าออกเป็นเซลล์กริด (Grid Cell) ขนาด $S \times S$ โดยทั่วไปจะกำหนดให้ $S = 7$ โดยแต่ละเซลล์กริดจะสามารถทำนายวัตถุได้เพียงวัตถุเดียวเท่านั้นจากทั้งหมดจำนวน C ประเภท เมื่อพิจารณาเซลล์กริด พบว่า ระบบทำนายเป็น Object ซึ่งใช้กล่อง

ขอบเขต (Bounding Box) จำนวนเท่ากับสอง ($B = 2$) และคำนวณความน่าจะเป็นของคลาสตามเงื่อนไข C ดังรูปที่ 1



กล่องขอบเขตสี่น้ำเงินจะมีค่าลักษณะพิเศษ (Parameter) อยู่ภายใน คือ (p, x, y, w, h) โดยที่ p แทน กล่องความเชื่อมั่น (box confidence score) มีค่า $0 \leq p \leq 1$ และมักจะใช้ค่า $p > 0.5$ สามารถอธิบายได้ว่า ในกล่องขอบเขตนี้มีวัตถุหนึ่งใน C ประเภทที่สนใจหรือไม่ โดยถ้า p มีค่าเป็น 0 หมายถึง สิ่งที่อยู่ในกล่องขอบเขตไม่ใช่วัตถุในเซต C , x แทน (พิกัดจุดกึ่งกลางความกว้างของกล่องขอบเขต-ความกว้างของเซลล์กริด)/ความกว้าง ของเซลล์กริด, y แทน (พิกัดจุดกึ่งกลางความสูงของกล่องขอบเขต-ความสูงของเซลล์กริด)/ความสูงของเซลล์กริด, w แทน ความกว้างของกล่องขอบเขต/ความกว้างของภาพ และ h แทน ความสูงของกล่องขอบเขต/ความสูงของภาพ


วิธีดำเนินการวิจัย

1. การเตรียมชุดข้อมูลฝึกฝน

ชุดข้อมูลฝึกฝนเป็นภาพถ่ายป้ายจราจรจากสมาร์ตโฟน โดยสุ่มเลือกภาพถ่ายจำนวน 432 ภาพ เป็นชุดข้อมูลฝึกฝน คิดเป็นร้อยละ 80 และภาพถ่ายจำนวน 108 ภาพ เป็นชุดข้อมูลทดสอบ คิดเป็นร้อยละ 20 จากนั้นทำการพิกัด 4 จุด จากภาพถ่ายป้ายจราจร ที่เป็นชุดข้อมูลฝึกฝน ได้แก่ X_{min} , Y_{min} , X_{max} และ Y_{max} เพื่อตีกรอบล้อมรอบบริเวณที่เป็น ป้ายจราจร จากนั้นบันทึกเป็นไฟล์ XML เพื่อนำเข้าไปในการสร้างตัวตรวจจับป้ายจราจรต่อไป

2. การสร้างตัวตรวจจับ

การวิจัยครั้งนี้ผู้วิจัยได้ใช้ขั้นตอนวิธีการสกัดคุณลักษณะของ YOLO ที่สามารถเพิ่มการเชื่อมต่อโดยทำการตัดแปลงจำนวนชั้นที่ผ่านการฝึกฝนมาแล้วล่วงหน้าบนฐานข้อมูล Microsoft COCO โดยการนำข้อมูลเข้าผ่านการปรับรูปภาพเป็นการแสดงสีแบบอาร์จีบี (RGB) ขนาด $(448, 448, 3)$ และข้อมูลนำออก (Output Tensor) ขนาด $(S, S, B \times 5 + C) = (7, 7, 1 \times 5 + 9)$ โดย S แทนเซลล์กริด, B แทนกล่องขอบเขต, C แทนป้ายจราจร ที่ต้องการ คือ 9 จะได้ข้อมูลนำออกขนาด $(7, 7, 14)$ ดังรูปที่ 2



3. การทดสอบตัวตรวจจับ

การทดสอบตัวตรวจจับป้ายจราจร ทำงานบนเครื่องคอมพิวเตอร์ที่มีหน่วยประมวลผลกลาง (CPU) Intel Core i7 4790 3.60 Ghz หน่วยความจำหลัก (RAM) 16 GB หน่วยประมวลผลกราฟิก (GPU) NVIDIA GeForce GTX 1060 6GB ระบบปฏิบัติการ (OS) Windows 10 พัฒนาระบบด้วยภาษา Python ใช้ TensorFlow เป็นไลบรารีสำหรับพัฒนาการเรียนรู้ของเครื่อง ใช้ Keras เป็นไลบรารีสำหรับการเรียนรู้เชิงลึก การทดสอบเริ่มจากการนำเข้าภาพที่เป็นภาพถ่ายป้ายจราจร นำมาเข้าตัวตรวจจับป้ายจราจรที่ทำการฝึกฝน จากนั้นตัวตรวจจับป้ายจราจรจะแสดงคำตอบออกมาเป็นเซตของจุดพิกัด 4 จุด รอบบริเวณที่เป็นป้ายจราจร

4. การวัดประสิทธิภาพ

การวัดประสิทธิภาพของระบบตรวจจับป้ายจราจรโดยใช้การเรียนรู้เชิงลึก ประกอบไปด้วยการวัดประสิทธิภาพ 3 แบบ คือ ค่าความเที่ยง (Precision) ค่ารีคอล (Recall) และค่าการวัดเอฟ (F-Measure)

ผลการวิจัย

จากการนำภาพถ่าย จำนวน 108 ภาพ มาทดสอบตัวตรวจจับป้ายจราจรที่ประกอบด้วยป้ายจราจรแบบป้ายบังคับ จำนวน 9 ป้าย ได้แก่ ป้ายห้ามแซงนิยามให้เป็น No_overtaking ป้ายห้ามกลับรถไปทางขวานิยามให้เป็น No_U_turn_right ป้ายห้ามกลับรถไปทางซ้ายนิยามให้เป็น No_U_turn_left ป้ายห้ามเลี้ยวขวานิยามให้เป็น No_right_turn ป้ายห้ามเลี้ยวซ้ายนิยามให้เป็น No_left_turn ป้ายห้ามเลี้ยวขวาหรือกลับรถนิยามให้เป็น No_right_turn_or_U_turn ป้ายห้ามเลี้ยวซ้ายหรือกลับรถนิยามให้เป็น No_left_turn_or_U_turn ป้ายห้ามเปลี่ยนช่องเดินรถไปทางขวานิยามให้เป็น No_changing_lanes_right ป้ายห้ามเปลี่ยนช่องเดินรถไปทางซ้ายนิยามให้เป็น No_changing_lanes_left ซึ่งป้ายจราจรแต่ละประเภทจะมีลักษณะที่แตกต่างกัน ดังรูปที่ 3



ก.ป้ายห้ามกลับรถไปทางซ้าย



ข.ป้ายห้ามกลับรถไปทางขวา



ค.ป้ายห้ามเลี้ยวขวา

รูปที่ 3 ตัวอย่างผลการทดลองตรวจจับป้ายจราจร

จากภาพบริเวณที่เป็นป้ายจราจรทั้งหมด ผลที่ได้จากตัวตรวจหาบริเวณที่มีป้ายจราจรทำการตอบออกมาทั้งหมด 110 บริเวณ ถูกต้องจำนวน 95 บริเวณ โดยความผิดพลาด แบ่งออกได้เป็น 2 กลุ่ม ได้แก่ กลุ่มแรกเป็นกลุ่มที่ตัวตรวจจับหาบริเวณที่มีป้ายจราจรออกมาผิดจำนวน 15 บริเวณ และกลุ่มที่สองเป็นกลุ่มที่ตัวตรวจจับไม่สามารถหาบริเวณที่มีป้ายจราจรออกมาได้จำนวน 12 บริเวณ โดยแสดงดังตารางที่ 1

ประเภทป้ายจราจร	บริเวณที่มีป้ายจราจร	ตัวตรวจจับที่มีป้ายจราจรทั้งหมด	ถูกต้อง (TP)	ตรวจจับผิด (FP)	ตรวจจับไม่เจอ (FN)
ห้ามแซง	12	13	11	2	1
ห้ามกลับรถไปทางขวา	12	11	10	1	2
ห้ามกลับรถไปทางซ้าย	12	13	11	2	1
ห้ามเลี้ยวขวา	12	12	10	2	2
ห้ามเลี้ยวซ้าย	12	12	11	1	1
ป้ายห้ามเลี้ยวขวาหรือกลับรถ	12	12	10	2	1
ป้ายห้ามเลี้ยวซ้ายหรือกลับรถ	12	13	11	2	1
ห้ามเปลี่ยนช่องเดินรถไปทางขวา	12	11	10	1	2
ห้ามเปลี่ยนช่องเดินรถไปทางซ้าย	12	13	11	2	1

จากผลลัพธ์ที่ได้จากตัวตรวจจับถูกวัดออกมาในค่าความเที่ยง ค่ารีคอล และค่าการวัดเอฟ ดังตารางที่ 2

ตารางที่ 2 ผลการวัดประสิทธิภาพของตัวตรวจจับป้ายจราจร

ประเภทป้ายจราจร	ค่าความเที่ยง	ค่ารีคอล	ค่าการวัดเอฟ
ห้ามแซง	0.85	0.92	0.88
ห้ามกลับรถไปทางขวา	0.91	0.83	0.87
ห้ามกลับรถไปทางซ้าย	0.85	0.92	0.88
ห้ามเลี้ยวขวา	0.83	0.83	0.83
ห้ามเลี้ยวซ้าย	0.92	0.92	0.92
ป้ายห้ามเลี้ยวขวาหรือกลับรถ	0.85	0.92	0.88
ป้ายห้ามเลี้ยวซ้ายหรือกลับรถ	0.85	0.92	0.88
ห้ามเปลี่ยนช่องเดินรถไปทางขวา	0.91	0.83	0.87
ห้ามเปลี่ยนช่องเดินรถไปทางซ้าย	0.85	0.92	0.88
ค่าเฉลี่ย	0.87	0.89	0.88

อภิปรายผลการวิจัย

งานวิจัยนี้นำเสนอการพัฒนาาระบบตรวจจับป้ายจราจรโดยใช้การเรียนรู้เชิงลึกที่สามารถรู้คุณลักษณะสำคัญจากชุดข้อมูลฝึกฝน โดยต้องเตรียมชุดข้อมูลที่เป็นพิกัดบริเวณป้ายจราจรเพื่อทำการฝึกฝน ซึ่งผลการทดสอบตัวตรวจจับเพื่อประเมินประสิทธิภาพเฉลี่ยของระบบมีค่าความเที่ยง ร้อยละ 0.87 ค่ารีคอล ร้อยละ 0.89 และค่าการวัดเอฟ ร้อยละ 0.88

จากผลการทดสอบประสิทธิภาพระบบตรวจจับป้ายจราจรโดยใช้การเรียนรู้เชิงลึกที่นำเสนอสามารถนำไปต่อยอดใช้บนสมาร์ตโฟนหรือพัฒนาเพิ่มเติมบนอุปกรณ์คอมพิวเตอร์ขนาดเล็ก (Embedded Devices) ที่มีการฝังตัวสมองกลใช้ควบคุมการทำงาน เพื่อให้สามารถประยุกต์ใช้ในระบบการขนส่งอัจฉริยะในการช่วยเหลือและ แจ้งเตือนผู้ขับขี่ให้ปฏิบัติตามป้ายจราจร เพื่อลดอุบัติเหตุบนท้องถนนและปฏิบัติได้ถูกต้องตามกฎหมายจราจรมากยิ่งขึ้น

ข้อเสนอแนะ

ข้อเสนอแนะในการพัฒนาาระบบตรวจจับป้ายจราจร เพื่อให้มีความสมบูรณ์มากขึ้น มีดังนี้

1. การฝึกฝนตัวตรวจจับควรมีชุดข้อมูลฝึกฝนที่มากเพียงพอ
2. ควรเพิ่มจำนวนรอบในการฝึกฝนเพื่อความแม่นยำในการตรวจจับ
3. ควรมีการใช้ชุดข้อมูลฝึกฝนที่ถูกบกรวนในสภาพแวดล้อมที่เลวร้าย เช่น ฝนตก แสงน้อย เป็นต้น
4. ควรมีการเปรียบเทียบประสิทธิภาพของขั้นตอนวิธีหลากหลายรูปแบบ
5. ควรพัฒนาต่อยอดในระบบอุปกรณ์อัจฉริยะขนาดเล็ก

เอกสารอ้างอิง

- กรมทางหลวง. (2561). คู่มือมาตรฐานป้ายจราจร เล่มที่ 1. กรุงเทพฯ: ม.ป.พ.
- ธนัญชัย บุญหนัก, กุหลาบ รัตนสังธรรม, ชิงชัย เมธพัฒน์ และทองศักดิ์ ยิ่งรัตนสุข. (2559). ปัจจัยเสี่ยงด้านพฤติกรรมและความพึงพอใจของผู้ขับขี่รถจักรยานยนต์ในเขตอุตสาหกรรมที่มีผลต่อความรุนแรงของอุบัติเหตุจราจร. สาธารณสุขศาสตร์. 46(3), 261-270.
- รถยนต์ไร้คนขับทิศทางใหม่แห่งนวัตกรรมวงการรถยนต์. (2558). รัฐสารศึกษ. 57(1), 114.
- Guo, Y., Liu, Y., Oerlemans, A., Lao, S., Wu, S. and Lew, M. S. (2016). Deep learning for visual understanding: A review. *Neurocomputing*. 187(2016), 27-48.
- Koomsubha, T. and Vateekul, P. (2017). A character-level convolutional neural network with dynamic input length for Thai text categorization. In 2017 9th International Conference on Knowledge and Smart Technology (KST), 101-105.
- Redmon, J. and Farhadi, A. (2017). YOLO9000: Better, Faster, Stronger. In *Computer Vision and Pattern Recognition (2017CVPR)*.
- _____. (2018). YOLOv3: An Incremental Improvement. In *Computer Vision and Pattern Recognition (2018CVPR)*.
- Redmon, J., Divvala, S., Girshick, R. and Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. In *Computer Vision and Pattern Recognition (2016CVPR)*.
- Shelhamer, E., Long, J. and Darrell, T. (2017). Fully Convolutional Networks for Semantic Segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 39(4), 640-651.