

เครื่องแยกขยะโดยใช้ AI

AI waste classification machine

ธรรมนุญ

จำปาหอม

ธีร์วิชญ์

สิทธิอาษา

พิชัยยุทธ

แสงแก้ว



ปริญญานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรบัณฑิต

สาขาวิชาวิศวกรรมการวัดคุม


คณะวิศวกรรมศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

ปีการศึกษา 2564

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

AI waste classification machine



TUMMANOON JUMPAHOM
TEETAWIT SITTIASA
PICHAIYUT SAENKAEW

A THESIS SUBMITTED IN PARTIAL FUFILLMENT
OF THE REQUIREMENT FOR THE DEGREE OF
BACHELOR OF ENGINEERING IN INSTRUMENTATION ENGINEERING
FACULTY OF ENGINEERING
KING MONGKUT'S INSTITUE OF TECNNOLGY LARDKRABANG
ACADEMIC YEAR 2021

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ปริญญาานิพนธ์ปีการศึกษา 2564
คณะวิศวกรรมศาสตร์
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
ใบรับรองปริญญาานิพนธ์

.....

หัวข้อวิทยานิพนธ์ เครื่องแยกขยะโดยใช้ AI
AI waste classification machine

นักศึกษาผู้จัดทำ นายธรรมบุญ จำปาหอม รหัสนักศึกษา 61010483
นายธีร์ธวิษญ์ สิทธิอาษา รหัสนักศึกษา 61010515
นายพิชัยยุทธ แสงแก้ว รหัสนักศึกษา 61010746

ปริญญา วิศวกรรมศาสตรบัณฑิต
สาขาวิชา วิศวกรรมการวัดคุม
ปีการศึกษา 2564

อาจารย์ผู้ควบคุมปริญญาานิพนธ์	ลายมือชื่อ
รศ.ทรงชัย วีระทวิมาศ	

หัวข้อวิทยานิพนธ์	เครื่องแยกขยะโดยใช้ AI			
	AI waste classification machine			
นักศึกษาผู้จัดทำ	นายธรรมนุญ	จำปาหอม	รหัสนักศึกษา	61010483
	นายธีร์ธวิษญ์	สิทธิอาษา	รหัสนักศึกษา	61010515
	นายพิชัยยุทธ	แสงแก้ว	รหัสนักศึกษา	61010746
อาจารย์ที่ปรึกษา	รองศาสตราจารย์ทรงชัย วีระทวีมาศ			
ปีการศึกษา	2564			

บทคัดย่อ

วิทยานิพนธ์ฉบับนี้เสนอการนำโปรแกรม CiRA CORE มาใช้ในการคัดแยกชนิดของขยะโดยการประยุกต์ใช้โปรแกรม CiRA CORE ซึ่งนำมาศึกษาและเรียนรู้เชิงลึก เพื่อใช้งานร่วมกับระบบ Computer vision ในการประมวลผลรูปภาพที่ซับซ้อนปัจจุบันมนุษย์สามารถนำเทคโนโลยีการเรียนรู้เชิงลึก มาพัฒนาโดยการถอดความรู้จากมนุษย์ รวมไปถึงสามารถนำความรู้นั้นไปประมวลผลและออกแบบเพื่อให้เป็นระบบสำหรับการแก้ปัญหาเฉพาะส่วน โดยโปรแกรม CiRA CORE ได้พัฒนาภายใต้ระบบปฏิบัติการ Windows โดยตัวโปรแกรมจะทำการประมวลและแสดงผลพิกัดในรูปแบบของสัญลักษณ์รูปภาพ ซึ่งจะใช้หลักการ Machine learning โดยการใส่รูปภาพตัวอย่างของตัววัตถุที่ต้องการจะแยกให้มากที่สุดในตัวโปรแกรม CiRA CORE แล้วบันทึกไว้เป็นหมวดหมู่ต่างๆโดยใช้กล้องเว็บแคมในการตรวจจับตัววัตถุและเชื่อมต่อกับตัว Arduino เพื่อควบคุม Servo motor ที่เชื่อมต่อกับกรวยคัดแยกเพื่อควบคุมทิศทางของรางเลื่อนให้หมุนไปตามถังของตัวชนิดของวัตถุนั้นๆ ซึ่งเป็นการตรวจจับแบบเรียลไทม์ และสามารถนำไปประยุกต์ใช้ในการแยกขยะหรือการแยกสิ่งของรวมถึงการพัฒนาต่อยอดในระดับอุตสาหกรรมได้

Thesis Title	AI waste classification machine	
Authors	Mr.Tummanoon	Jumpahom
	Mr.Teetawit	Sittiasa
	Mr.Pichaiyut	Saengkaew
Thesis advisor	Assoc. Prof.Songchai Weerathaweemas	
Year	2564	

ABSTRACT

This thesis presents the application of CiRA CORE program in waste classification. CiRA CORE is a deep learning that used with computer vision to process images. In this day and age, we can improve deep learning technology by mimicking human intelligence. Moreover, it can apply the knowledge to process and solve the problems. CiRA CORE is developed by Windows operation system, the program will process and show the results in form of image symbols by machine learning theory. First, taking variety images and recording the results by using webcam camera to detect the objects. Then, using Arduino to control slide rail that connected with belt for controlling the direction of slide rail and rotate around the objects which is real-time object detection. In addition, it can be applied in waste classification including industrial level.

กิตติกรรมประกาศ

ปริญญาานิพนธ์ฉบับนี้สำเร็จลุล่วงได้ด้วยดีด้วยความกรุณาและความอนุเคราะห์จากอาจารย์ที่ปรึกษา รศ.ดร.ทรงชัย วีรทวิมาศ ที่กรุณารับเป็นอาจารย์ที่ปรึกษาปริญญาานิพนธ์ โดยที่ได้ให้คำแนะนำ คำปรึกษาและข้อเสนอแนะในการแก้ปัญหาหรือข้อสงสัยต่างๆแก่ข้าพเจ้าเสมอมา รวมถึงให้ความดูแลเอาใจใส่ในการทำงานสอบถามความก้าวหน้าอย่างสม่ำเสมอ ทำให้ข้าพเจ้าทำงานอย่างเป็นระบบและใช้เวลาอย่างมีประสิทธิภาพ

ขอบคุณภาคีวิชาวิศวกรรมการวัดคุมที่ได้เอื้อเฟื้อสถานที่รวมถึงอุปกรณ์และเครื่องมือต่างๆในการทำวิจัย จนข้าพเจ้าสามารถทำปริญญาานิพนธ์ฉบับนี้ได้เสร็จสิ้น

สุดท้ายนี้ข้าพเจ้าขอกราบขอบพระคุณผู้ให้กำเนิดซึ่งได้วางรากฐานชีวิตพื้นฐานทางความคิดให้ผู้เขียนมีความเชื่อมั่นในสิ่งที่ถูกต้องและได้เป็นกำลังใจแก่ผู้เขียนเสมอมาอันเป็นแนวทางไปสู่ความสำเร็จของผู้เขียน ตลอดจนครอบครัว เพื่อน ที่เป็นกำลังใจให้ผู้เขียนตลอดมา

สำหรับคุณงามความดีอันใดที่เกิดจากปริญญาานิพนธ์ฉบับนี้ ข้าพเจ้าขอมอบให้กับบิดามารดา ซึ่งเป็นที่รักและเคารพยิ่ง ตลอดจนครูอาจารย์ที่เคารพทุกท่านที่ได้ประสิทธิ์ประสาทวิชาความรู้และถ่ายทอดประสบการณ์ที่ดีให้แก่คณะผู้จัดทำเสมอมา

คณะผู้จัดทำ

สารบัญ

	หน้า
บทคัดย่อ	i
ABSTRACT	ii
กิตติกรรมประกาศ	iii
สารบัญ	iv
สารบัญตาราง	viii
สารบัญรูป	ix
บทที่ 1 บทนำ	1
1.1 ความสำคัญของปริภูมยานิพนธ์	1
1.2 วัตถุประสงค์ของปริภูมยานิพนธ์	2
1.3 ขอบเขตของปริภูมยานิพนธ์	2
1.4 ขั้นตอนการศึกษา	2
1.5 ประโยชน์ที่คาดว่าจะได้รับ	2
บทที่ 2 หลักการและทฤษฎี	3
2.1 ระบบคอมพิวเตอร์วิชั่น	3
2.1.1 หลักการทำงานของระบบคอมพิวเตอร์วิชั่น	4
2.1.2 การเรียนรู้เชิงจักรกล	5
2.1.3 การทำงานของ การเรียนรู้เชิงจักรกล	5
2.2 Supervised Learning	7
2.2.1 Regression	7
2.2.1.1 Linear Regression	8
2.2.1.2 Logistic Regression	8

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ(ต่อ)

	หน้า
2.2.2 Classification.....	9
2.2.2.1 decision trees (แผนผังการตัดสินใจแบบรูปต้นไม้).....	10
2.2.2.2 Naive Bayes Classifier (ตัวจำแนกแบบเบย์อย่างง่าย)	10
2.2.2.3 support vector machines (ขั้นตอนแบบ Supervised Learning). 10	
2.3 เทคนิคการเรียนรู้เชิงลึก.....	11
2.3.1 หลักการทำงานของการเรียนรู้เชิงลึก	13
2.3.2 Convolutional Neural Network (CNNs).....	13
2.3.2.1 การทำงานของโครงข่ายประสาทคอนโวลูชัน	14
2.3.3 Recurrent Neural Networks.....	17
2.3.3.1 ประเภทของ Recurrent Neural Networks	19
2.3.4 ความแตกต่างระหว่าง การเรียนรู้เชิงจักรกล และ การเรียนรู้เชิงลึก	21
2.4 YOLO	22
2.4.1 YOLO V1.....	22
2.4.2 YOLO V2.....	23
2.4.3 YOLO V3.....	24
2.4.4 สถาปัตยกรรม Features Pyramid Networks (FPN).....	26
2.5 การทำให้เป็นมาตรฐาน หรือ Data Normalization	27
2.5.1 Rescaling (Min-Max Normalization).....	27
2.5.2 Mean Normalization	28
2.5.3 การกำหนดมาตรฐาน (Z-Score Normalization).....	28
2.5.4 Scale to Unit Length	29
2.6 Threshold.....	29
2.6.1 Threshold OpenCV คืออะไร	30

สารบัญ (ต่อ)

	หน้า
บทที่ 3 หลักการออกแบบและสร้าง.....	32
3.1 อุปกรณ์และเครื่องมือที่ใช้ในการดำเนินการ.....	32
3.1.1 คอมพิวเตอร์.....	32
3.1.2 กล้อง Webcam 1080.....	33
3.1.3 Arduino Uno R3.....	34
3.1.4 สายแพสี่รู้ง เข้าหัว Jumper Wire 20 cm.....	35
3.1.5 สานพานลำเลียง Conveyor belt 40x10 cm.....	35
3.1.6 Servo Motor MG995.....	36
3.1.7 Power Supply 12V 5A 60W.....	36
3.1.8 PWM Motor DC Controller 12V-40V 10A.....	37
3.1.9 โครงสร้างชิ้นงาน.....	38
3.2 ซอฟต์แวร์ที่ใช้ในการดำเนินการ.....	38
3.2.1 Windows.....	38
3.2.2 Arduino IDE.....	39
3.2.3 CiRA CORE.....	39
3.2.4 กล้องเครื่องมือพื้นฐานใน CiRA CORE ที่ใช้ในการดำเนินการ.....	40
3.2.5 CiRA Arduino io.....	41
3.2.6 แผนผังการดำเนินการให้คอมพิวเตอร์เรียนรู้ด้วยตนเองโดยใช้ข้อมูลมาสอน.....	42
3.3 ขั้นตอนในการสอนให้ระบบคอมพิวเตอร์เรียนรู้ด้วยตนเองโดยใช้ข้อมูลมาสอน.....	43
บทที่ 4 ผลการดำเนินงาน.....	52
4.1 การเก็บข้อมูลรูปภาพเป็น Dataset.....	52
4.1.1 กราฟแสดงรูปภาพที่เป็น Dataset สำหรับโปรแกรม CiRA CORE.....	52
4.1.2 ค่า AVG ของโปรแกรม CiRA CORE ค่า AVG ของโปรแกรม CiRA CORE.....	52
4.2 การตรวจสอบความถูกต้องของการตรวจจับและคัดแยกถูกประเภท.....	53
4.2.1 ประเภทกระป๋อง.....	52
4.2.2 ประเภทกล่องนม.....	52

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ (ต่อ)

4.2.3 ประเภทขวดพลาสติก.....	52
4.2.4 ประเภทขวดแก้ว.....	52
4.3 สรุปผลการทดลอง.....	60
บทที่ 5 สรุปผลปัญหาและข้อเสนอแนะ.....	61
5.1 สรุปผลการดำเนินงาน.....	61
5.2 ข้อเสนอแนะ.....	61
บรรณานุกรม.....	61
ภาคผนวก ค่าตาราง และ Code การทำงาน.....	64
ประวัติผู้เขียน.....	67



สารบัญตาราง

ตารางที่	หน้า
3-1 คอมพิวเตอร์ที่ใช้งานและใช้ Train AI ต้องมีคุณสมบัติ ดังนี้.....	32
3-2 สเปคคอมพิวเตอร์ที่ใช้งาน	33
3-3 คุณสมบัติของบอร์ด Arduino.....	34
3-4 คุณสมบัติของ Servo Motor MG995	36
3-5 คุณสมบัติของ Power Supply 12V 5A.....	37
3-6 คุณสมบัติ PWM Motor DC Controller	37
4-1 แสดงผลการทดสอบ ครั้งที่ 1 ของชุดข้อมูลตัวอย่างเพื่อหาความผิดพลาด	54
4-2 แสดงผลการทดสอบ ครั้งที่ 2 ของชุดข้อมูลตัวอย่างเพื่อหาความผิดพลาด	55
4-3 แสดงผลการทดสอบ ครั้งที่ 3 ของชุดข้อมูลตัวอย่างเพื่อหาความผิดพลาด	56
4-4 แสดงผลการทดสอบ ครั้งที่ 4 ของชุดข้อมูลตัวอย่างเพื่อหาความผิดพลาด	57
4-5 แสดงผลการทดสอบ ครั้งที่ 5 ของชุดข้อมูลตัวอย่างเพื่อหาความผิดพลาด	58
4-6 แสดงสรุปผลการทดสอบ 5 ครั้งของชุดข้อมูลตัวอย่างเพื่อหาความผิดพลาด	59

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญรูป

รูปที่	หน้า
รูปที่ 2.1	การทำงานของระบบคอมพิวเตอร์วิชั่น..... 3
รูปที่ 2.2	การประมวลผลภาพและสีของคอมพิวเตอร์วิชั่น 5
รูปที่ 2.3	รูปภาพแสดงการทำงานของMachine Learning..... 6
รูปที่ 2.4	การเรียนรู้แบบ Supervised learning..... 7
รูปที่ 2.5	กราฟแสดงอัลกอริทึมของ Linear Regression..... 8
รูปที่ 2.6	กราฟแสดงอัลกอริทึมของ Logistic Regression..... 9
รูปที่ 2.7	กราฟแสดงอัลกอริทึมของ decision trees 10
รูปที่ 2.8	กราฟแสดงอัลกอริทึมของ support vector machines 10
รูปที่ 2.9	neural network architectures จัดเป็นชั้นประกอบด้วยชุดของโหนดที่เชื่อมต่อถึงกัน 12
รูปที่ 2.10	แสดงค่าเอาต์พุตและอินพุตในการเชื่อมต่อค่าพิกเซล 15
รูปที่ 2.11	แสดงตัวอย่างการตรวจจับรูปจักรยาน..... 16
รูปที่ 2.12	แสดงตัวอย่าง Recurrent Neural Network และ Feedforward Neural Network 18
รูปที่ 2.13	แสดงตัวอย่างการทำงานของ Recurrent Neural Network..... 18
รูปที่ 2.14	แสดงตัวอย่างการทำงานของ Recurrent Neural Networkแบบone-to-one..... 19
รูปที่ 2.15	แสดงตัวอย่างการทำงานของ Recurrent Neural Networkแบบone-to-many..... 20
รูปที่ 2.16	แสดงตัวอย่างการทำงานของ Recurrent Neural Network แบบ Many-to-one 20
รูปที่ 2.17	แสดงตัวอย่างการทำงานของ Recurrent Neural Network แบบ Many-to-many .. 20
รูปที่ 2.18	เปรียบเทียบการเรียนรู้แบบเชิงลึกและแบบการเรียนรู้เชิงจักรกล..... 22
รูปที่ 2.19	โครงสร้างสถาปัตยกรรมของอัลกอริทึม YOLO V1 23
รูปที่ 2.20	โครงสร้างสถาปัตยกรรมของอัลกอริทึม YOLO V2 24
รูปที่ 2.21	โครงสร้างสถาปัตยกรรมของอัลกอริทึม YOLO V3 24
รูปที่ 2.22	การตรวจจับรูปภาพโดยสถาปัตยกรรมโครงสร้างของ Tiny YOLO V3 26
รูปที่ 2.23	โครงสร้างสถาปัตยกรรม Features Pyramid Networks (FPN)..... 27
รูปที่ 2.24	กราฟการ Standardization ของ Mean Normalization..... 28
รูปที่ 2.25	เอ๊าท์พุทของThreshold 29
รูปที่ 2.26	ตารางแสดงถึงค่าของ Pixel..... 30

สารบัญรูป (ต่อ)

รูปที่	หน้า
รูปที่ 2.27 รูปตัวอย่างแสดงการทำงานของThreshold 5 ประเภท.....	31
รูปที่ 3.1 ภาพคอมพิวเตอร์.....	32
รูปที่ 3.2 กล้อง Webcam.....	33
รูปที่ 3.3 Arduino Uno R3.....	34
รูปที่ 3.4 สายแพสีรุ้งเข้าหัว Jumper Wire.....	35
รูปที่ 3.5 Conveyor belt 40x10 cm.....	35
รูปที่ 3.6 Servo Motor MG995	36
รูปที่ 3.7 Power Supply 12V 5A 60W.....	36
รูปที่ 3.8 PWM Motor DC Controller 12V-40V 10A.....	37
รูปที่ 3.9 โครงสร้างชิ้นงาน	38
รูปที่ 3.10 หน้าต่างการใช้งาน CiRA CORE.....	39
รูปที่ 3.11 เครื่องมือการใช้งาน CiRA CORE	40
รูปที่ 3.12 หน้าต่างการทำงาน CiRA Arduino io.....	41
รูปที่ 3.13 แผนผังการเรียนรู้ด้วยตนเองโดยการสอน.....	42
รูปที่ 3.14 ขั้นตอนนำรูปมาทำ Label เพื่อเตรียมการ Train.....	43
รูปที่ 3.15 ขั้นตอน Generate ไฟล์ Label	43
รูปที่ 3.16 ให้คอมพิวเตอร์ Deep learning ข้อมูลที่ใส่ลงไป.....	44
รูปที่ 3.17 Deep learning Avg ใกล้เคียง 0.00	44
รูปที่ 3.18 รูปแสดงการตรวจจับ	45
รูปที่ 3.19 รูปโครงสร้างชิ้นงาน.....	45
รูปที่ 3.20 ตัวอย่างโปรแกรมการตัดแยกกระป๋อง.....	46
รูปที่ 3.21 ตัวอย่างโปรแกรมการตัดแยกกล่องนม	46
รูปที่ 3.22 ตัวอย่างโปรแกรมการตัดแยกขวดสปรอย.....	47
รูปที่ 3.23 ตัวอย่างโปรแกรมการตัดแยกขวดพลาสติก	47

สารบัญรูป (ต่อ)

รูปที่	หน้า
รูปที่ 3.24 ตัวอย่างโปรแกรมการคัดแยกขวด C-vit.....	48
รูปที่ 3.25 ตัวอย่างโปรแกรมการคัดแยกขวด Energy drink.....	48
รูปที่ 3.26 การทำงานของ servo ของการตรวจจับกระป๋อง.....	49
รูปที่ 3.27 การทำงานของ servo ของการตรวจจับกล่องนม.....	49
รูปที่ 3.28 การทำงานของ servo ของการตรวจจับ C – vit.....	50
รูปที่ 3.29 การทำงานของ servo ของการตรวจจับ ขวดพลาสติก.....	50
รูปที่ 3.30 การทำงานของ servo ของการตรวจจับกระป๋องผิดรูป.....	51
รูปที่ 3.31 การทำงานของ servo ของการตรวจจับกล่องนมผิดรูป.....	51
รูปที่ 4.1 กราฟแสดงจำนวนรูปภาพที่เป็น Dataset สำหรับการทดลองโปรแกรม CiRA CORE	52
รูปที่ 4.2 กราฟแสดงค่า AVG จากการเรียนรู้เชิงลึกของโปรแกรม CiRA CORE.....	52

บทที่ 1

บทนำ

1.1 ความสำคัญของปัญญาประดิษฐ์

ประเทศไทยมีปริมาณขยะสูงขึ้นต่อเนื่องขึ้นทุกปี จากรายงานสถานการณ์ขยะมูลฝอยชุมชนของประเทศไทย ปี 2559 พบว่ามีปริมาณการเกิดขยะรวมกันทั้งประเทศ 27.06 ล้านตันต่อปี คิดเป็นประมาณ 74,130 ตันต่อวัน เฉลี่ยเป็นปริมาณขยะ 1.14 กิโลกรัมต่อคนต่อวัน ยังไม่รวมขยะตกค้างสะสมที่เพิ่มขึ้นทุกปีไม่ต่ำกว่าปีละ 10 ล้านตัน [1] ปัญหาขยะในเมืองไทยนั้น เป็นเวลาหลายสิบปีที่เจ้าหน้าที่ทางราชการ หน่วยงานวิจัย สถาบันทางการศึกษา พยายามหาหนทางในการแก้ไขปัญหาเรื่องขยะล้นเมือง เป็นปัญหาที่อยู่คู่กับเมืองไทยมาอย่างยาวนาน ถึงแม้ในปัจจุบันจะมีเทคโนโลยีมากมายที่สามารถจะนำมาใช้ในการแก้ไขปัญหาเรื่องขยะ และหนึ่งในสาเหตุของปัญหานี้มากจากการที่คนไทยมักไม่คัดแยกขยะในการนำไปทิ้งโดยปัจจุบันการที่ไม่แยกขยะก่อนนำไปทิ้งไม่ว่าจะเป็นขยะที่สามารถนำกลับมาใช้ใหม่ หรือส่วนที่สามารถนำมารีไซเคิลได้ ดังนั้นขยะทั้งหมดที่ไม่แยกจะถูกนำไปทิ้งและฝังกลบลงหลุมโดยตรง และจะส่งผลให้หลุมนั้นจะปล่อยก๊าซพิษออกมา เช่น ก๊าซมีเทนเมื่อขยะได้ทำการย่อย ดังนั้นทางกลุ่มจึงเล็งเห็นปัญหานี้และต้องการนำความรู้ด้านปัญญาประดิษฐ์มาแก้ไขปัญหาที่ซับซ้อนได้ เช่นเดียวกับมนุษย์ที่เป็นผู้เชี่ยวชาญสำหรับการแก้ปัญหา แต่ในการที่ระบบคอมพิวเตอร์จะสามารถกระทำเช่นนี้ได้จะต้องจำลองกระบวนการ เพื่อหาเหตุผลของมนุษย์ เช่นการสอนหรือการป้อนข้อมูลที่จำเป็นให้แก่ระบบ เพื่อให้เกิดการประมวลผลอย่างมีประสิทธิภาพสูงสุด และเนื่องจากการสอนคอมพิวเตอร์ให้มองเห็น แยกแยะความสัมพันธ์ของวัตถุได้นั้นมีความจำเป็นอย่างยิ่งที่จะต้องใช้อุปกรณ์รูปภาพ หรือข้อมูลอย่างมหาศาล (Big Data) ทั้งหมดที่กล่าวมาข้างต้นนี้ก็คือการทำงานโดยอัตโนมัติ (Automation) ที่เรียกกันว่า ปัญญาประดิษฐ์ (Artificial Intelligence) หรือ ปัญญาประดิษฐ์นั่นเอง

ปัจจุบันได้มีการใช้ทรัพยากรมนุษย์ในหลากหลายรูปแบบ เช่น การออกแบบ การควบคุมดูแลกระบวนการ รวมไปถึงงานที่เป็นงานด้านการบริการ ไม่ว่าจะเป็นการบริหาร หรือแม้กระทั่งการใช้แรงงาน ดังนั้นปัญหาที่ตามมาคือความผิดพลาดที่เกิดขึ้นจากมนุษย์ ไม่ว่าจะเป็นการตั้งใจหรือด้วยความประมาท แต่ก็มักจะส่งผลให้เกิดความเสียหายต่อรูปแบบของงาน โดยในปัจจุบันเทคโนโลยีมีความก้าวหน้าและมีความสำคัญอย่างมาก จึงสามารถนำ ปัญญาประดิษฐ์ มาใช้แทนบทบาทของมนุษย์ ทั้งในแง่กำลังคน และข้อมูล ความเฉลียวฉลาด ดังนั้น กลุ่มของผู้ทำโครงการจึงเล็งเห็นว่าการนำสิ่งเหล่านี้มาในอุตสาหกรรมเพื่อใช้ในการคัดแยกขยะและสิ่งปฏิกูล สามารถถูกแทนที่ได้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ด้วยเครื่องจักรและปัญญาประดิษฐ์โดยไม่จำเป็นต้องอาศัยบทบาทของกำลังคน ทั้งการ วิเคราะห์ และ ระบุชนิดของวัสดุและขยะในการคัดแยกซึ่งจะให้ปัญญาประดิษฐ์ทำการเรียนรู้และนำข้อมูลที่เก็บฐานข้อมูลไปใช้ระบุทำงานร่วมกับกำลังของเครื่องจักร ได้อย่างมีประสิทธิภาพ เพื่อแก้ไขปัญหาความผิดพลาดที่เกิดจากมนุษย์

1.2 วัตถุประสงค์ของปริญญานิพนธ์

1. เพื่อพัฒนาระบบที่สามารถคัดแยกชนิดของวัตถุ โดยทำการประมวลผลด้วยเทคนิคการเรียนรู้เชิงลึก (Deep learning)
2. เพื่อลดความผิดพลาดและระยะเวลาเนื่องจากประสิทธิภาพของมนุษย์ที่มีจำกัด โดยใช้ระบบปัญญาประดิษฐ์และเครื่องจักรเข้ามาแทนที่กำลังคน
3. เพื่อประยุกต์ใช้เทคโนโลยีที่มีอยู่ในปัจจุบันเพื่อนำมาใช้อำนวยความสะดวกในกระบวนการอุตสาหกรรม

1.3 ขอบเขตของปริญญานิพนธ์

เป็นการใช้ความรู้ในเรื่องระบบ CIRA CORE สำหรับการตรวจจับและคัดแยกวัตถุโดยจะใช้เทคนิคการเรียนรู้เชิงลึกและการใช้อุปกรณ์ตรวจวัด (Sensor) ในรูปแบบของกล้องที่ใช้ในการตรวจจับรูปร่าง ขนาด และลักษณะของวัตถุเข้ากับเทคนิคการเรียนรู้เชิงลึก (Deep learning) เพื่อนำข้อมูลภาพวัตถุที่ได้มาทำการแยกประเภทจัดหมวดหมู่และประเภทของขยะ และประมวลผลออกมาและส่งไปทำงานร่วมกับโปรแกรม ARDUINO เพื่อที่จะหมุนSERVO MOTORเพื่อลำเลียงวัตถุหรือขยะให้แยกไปลงถังแต่ละชนิดตามที่กำหนดไว้

1.4 ขั้นตอนการศึกษา

1. ศึกษาทำความเข้าใจหลักการทำงานของโปรแกรม CIRA CORE
2. ศึกษาการเรียนรู้เชิงลึกของโปรแกรมARDUINO UNO
3. ศึกษาทำความเข้าใจการเชื่อมต่ออุปกรณ์ระหว่าง CIRA CORE และ ARDUINO

1.5 ประโยชน์ที่คาดว่าจะได้รับ

1. ช่วยลดปัญหาการแยกประเภทของขยะ
2. ช่วยลดระยะเวลาและแรงงานคนในอุตสาหกรรมการรีไซเคิล
3. ช่วยลดปัญหากำจัดขยะแต่ละประเภทผิดวิธีเนื่องจากไม่ได้แยกชนิดของขยะ
4. สามารถใช้หรือศึกษาโปรแกรม CIRA CORE ได้


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 2

หลักการและทฤษฎี

2.1 ระบบคอมพิวเตอร์วิชั่น

คอมพิวเตอร์วิชั่นเป็นสาขาหนึ่งของปัญญาประดิษฐ์ (AI) ที่ช่วยให้คอมพิวเตอร์และระบบได้รับข้อมูลจากภาพดิจิทัล วิดีโอ และอินพุตภาพอื่นๆ และดำเนินการหรือให้คำแนะนำตามข้อมูลนั้น โดยปัญญาประดิษฐ์ จะช่วยให้คอมพิวเตอร์สามารถคิด ระบบคอมพิวเตอร์วิชั่นจะช่วยให้คอมพิวเตอร์มองเห็น สังเกต และเข้าใจได้ คอมพิวเตอร์วิชั่นทำงานเหมือนกับการมองเห็นของมนุษย์มาก ยกเว้นมนุษย์มีจุดเริ่มต้น การมองเห็นของมนุษย์มีข้อได้เปรียบในช่วงอายุของบริบทในการฝึกที่จะแยกแยะวัตถุออกจากกันอย่างไรอยู่ไกลแค่ไหนเคลื่อนไหวหรือไม่ [2] และมีบางอย่างผิดปกติในรูปภาพหรือไม่ คอมพิวเตอร์วิชั่นจะฝึกเครื่องจักรเพื่อทำหน้าที่เหล่านี้ แต่ต้องทำโดยใช้เวลาน้อยกว่ามากโดยใช้ ข้อมูล และอัลกอริทึมมากกว่าเรตินา เส้นประสาทตา และคอร์เทกซ์การมองเห็น เนื่องจากระบบที่ได้รับการฝึกอบรมให้ตรวจสอบผลิตภัณฑ์ หรือคุณสมบัติการผลิตสามารถวิเคราะห์ผลิตภัณฑ์หรือกระบวนการนับพันรายการต่อนาที โดยสังเกตข้อบกพร่องหรือปัญหาที่มองไม่เห็นจึงเกินความสามารถของมนุษย์ได้อย่างรวดเร็ว คอมพิวเตอร์วิชั่นถูกนำมาใช้ในอุตสาหกรรมต่างๆ ตั้งแต่พลังงานและสาธารณสุขไปจนถึงการผลิตและยานยนต์ [3]



<https://xd.adobe.com>, [Online]

รูปที่ 2.1 การทำงานของระบบคอมพิวเตอร์วิชั่น


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

รูปแบบของเทคโนโลยีคอมพิวเตอร์วิชั่นและการทำงานในสถานการณ์มีดังนี้

- 1) Object classification เป็นการแยกวิเคราะห์เนื้อหาที่เป็นภาพและจัดประเภทวัตถุบนภาพถ่ายและวิดีโอเป็นหมวดหมู่ที่กำหนดไว้ตัวอย่างเช่น ระบบสามารถค้นหาสุนัขจากวัตถุทั้งหมดในภาพ
- 2) Object identification เป็นระบบจะแยกวิเคราะห์เนื้อหาที่เป็นภาพและระบุวัตถุเฉพาะบนภาพถ่ายและวิดีโอตัวอย่างเช่น ระบบสามารถค้นหาสุนัขตัวใดตัวหนึ่งจากสุนัขในภาพ
- 3) Object tracking เป็นระบบประมวลผลวิดีโอค้นหาวัตถุ (หรือวัตถุ) ที่ตรงกับเกณฑ์การค้นหาและติดตามการเคลื่อนไหวของวัตถุ

2.1.1 หลักการทำงานของระบบคอมพิวเตอร์วิชั่น

เทคโนโลยีของคอมพิวเตอร์วิชั่น มีแนวโน้มที่จะเลียนแบบการทำงานของสมองของมนุษย์ สมมติฐานระบุว่าสมองของมนุษย์อาศัยรูปแบบในการถอดรหัสวัตถุแต่ละชิ้น แนวคิดนี้ใช้ในการสร้างระบบคอมพิวเตอร์วิชั่น อัลกอริทึมการมองเห็นด้วยคอมพิวเตอร์ที่มนุษย์ใช้ในปัจจุบันขึ้นอยู่กับ การจดจำรูปแบบมนุษย์สอนคอมพิวเตอร์เกี่ยวกับข้อมูลภาพจำนวนมหาศาล หลังจากนั้นคอมพิวเตอร์ จะประมวลผลภาพ ติดป้ายกำกับ (labels) วัตถุบนพวกมัน และค้นหารูปแบบในวัตถุเหล่านั้น ตัวอย่างเช่น ถ้าส่งภาพถ่ายดอกไม้บนล้านภาพ คอมพิวเตอร์จะวิเคราะห์ ระบุรูปแบบที่คล้ายกับดอกไม้ทั้งหมด และเมื่อสิ้นสุดกระบวนการนี้ จะสร้างแบบจำลอง "ดอกไม้" ส่งผลให้คอมพิวเตอร์สามารถ ตรวจสอบได้อย่างแม่นยำว่าภาพใดภาพหนึ่งเป็นดอกไม้ทุกครั้งที่ส่งภาพ Image Processing and Computer Vision ให้รายละเอียดทางเทคนิคเกี่ยวกับกระบวนการที่เครื่องติดตามในการตีความภาพ กล่าวโดยย่อว่า เครื่องจะตีความภาพเป็นชุดของพิกเซล โดยแต่ละชุดมีค่าสีต่างกัน ตัวอย่างเช่น ด้านล่างเป็นรูปภาพของอับราฮัม ลินคอล์น ความสว่างของแต่ละพิกเซลในภาพนี้แสดงด้วยตัวเลข 8 บิต เท่านั้น ตั้งแต่ 0 (สีดำ) ถึง 255 (สีขาว) ตัวเลขเหล่านี้คือสิ่งที่ซอฟต์แวร์เห็นเมื่อป้อนรูปภาพ ข้อมูลนี้ จัดทำขึ้นเพื่อเป็นข้อมูลป้อนเข้าสู่อัลกอริทึมการมองเห็นด้วยคอมพิวเตอร์ ซึ่งจะรับผิดชอบในการ วิเคราะห์และตัดสินใจเพิ่มเติม [4]



<https://xd.adobe.com>, [Online]

รูปที่ 2.2 การประมวลผลภาพและสีของคอมพิวเตอร์วิชั่น

2.1.2 การเรียนรู้เชิงจักรกล

การเรียนรู้เชิงจักรกลเป็นสาขาหนึ่งของปัญญาประดิษฐ์(AI) และวิทยาการคอมพิวเตอร์ ที่เน้นการใช้ข้อมูลและอัลกอริทึมเพื่อเลียนแบบวิธีที่มนุษย์เรียนรู้ โดยค่อยๆ ปรับปรุงความแม่นยำซึ่งจะมีแตกต่างจากการเขียนโปรแกรมเพราะการเขียนโปรแกรมจะเป็นการเขียนใส่ข้อมูลเข้าไป เพื่อให้คอมพิวเตอร์ ประมวลผลและแสดงผลลัพธ์ออกมา แต่การเรียนรู้เชิงกลนั้นจะเป็นการใส่ข้อมูลหรือผลลัพธ์เข้าไปเพื่อให้คอมพิวเตอร์ได้ทำการเรียนรู้ผลลัพธ์หรือข้อมูลนั้น และทำการประมวลผลโดยจะนำไปใช้ในการคาดการณ์ในอนาคตว่าถ้าหากมีการป้อนข้อมูลเข้าไป ผลลัพธ์ที่แสดงออกมาจะแสดงคำตอบว่าอย่างไรหรือเป็นแบบที่คาดการณ์ไว้หรือไม่


2.1.3 การทำงานของ การเรียนรู้เชิงจักรกล

การทำงานของ การเรียนรู้เชิงจักรกล (Machine learning) จะแบ่งการทำงานของ อัลกอริทึมเป็น 3 ส่วนได้แก่

- 1) กระบวนการตัดสินใจ คือ โดยทั่วไปอัลกอริทึม Machine learning ใช้เพื่อทำนายและจำแนกประเภทขึ้นอยู่กับข้อมูลอินพุตบางส่วนซึ่งสามารถติดป้ายกำกับหรือไม่ติดป้ายกำกับกับอัลกอริทึม จะสร้างค่าประมาณเกี่ยวกับรูปแบบในข้อมูล
- 2) ฟังก์ชันข้อผิดพลาด คือฟังก์ชันข้อผิดพลาดใช้เพื่อประเมินการคาดการณ์ของแบบจำลอง หากมีตัวอย่างที่ทราบฟังก์ชันข้อผิดพลาดสามารถเปรียบเทียบเพื่อประเมินความถูกต้องของแบบจำลองได้
- 3) กระบวนการเพิ่มประสิทธิภาพแบบจำลอง คือ หากแบบจำลองสามารถเข้ากับจุดข้อมูลในชุดการฝึกได้ดีกว่า ข้อมูลจะถูกปรับเพื่อลดความคลาดเคลื่อนระหว่างตัวอย่างที่ทราบและการประมาณการแบบจำลอง อัลกอริทึมจะทำการประเมินซ้ำ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

และปรับกระบวนการให้เหมาะสม โดยอัปเดตข้อมูลโดยอัตโนมัติจนกว่าจะถึงเกณฑ์ความแม่นยำ



<https://xd.adobe.com>, [Online]

รูปที่ 2.3 รูปภาพแสดงการทำงานของMachine Learning

Machine Learning แบ่งได้ 3 แบบ ดังนี้

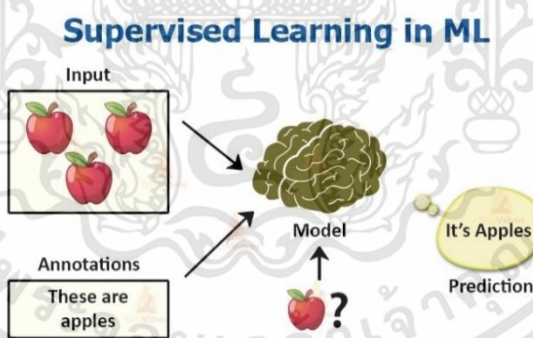
- 1) Supervised Learning คือ เรียนรู้โดยมี ข้อมูล มาสอน Supervised Learning หรือที่เรียกว่าการเรียนรู้ของเครื่องภายใต้การดูแลถูกกำหนดโดยการใช้ชุดข้อมูลที่มีlabelsเพื่อฝึกอัลกอริทึมเพื่อจัดประเภทข้อมูลหรือคาดการณ์ผลลัพธ์ได้อย่างแม่นยำเมื่อป้อนข้อมูลลงในแบบจำลอง ระบบจะWeightจนกว่าแบบจำลองจะติดตั้งอย่างเหมาะสมสิ่งนี้เกิดขึ้นโดยเป็นส่วนหนึ่งของกระบวนการตรวจสอบความถูกต้องข้ามเพื่อให้แน่ใจว่าแบบจำลองจะหลีกเลี่ยงการใส่ข้อมูลมากเกินไปหรือน้อยเกินไป การเรียนรู้ภายใต้การดูแลช่วยให้สามารถแก้ปัญหาต่างๆ ในชีวิตจริงในระดับต่างๆ เช่น การจัดประเภทสแปมในโพลเดอร์ที่แยกจากกล่องจดหมายของคุณ วิธีการบางอย่างที่ใช้ในการเรียนรู้ภายใต้การดูแล ได้แก่ โครงข่ายประสาทเทียม และอื่นๆ
- 2) Unsupervised Learning คือ เรียนรู้โดยไม่มี ข้อมูล สอนเป็นอัลกอริทึมการเรียนรู้ของเครื่องเพื่อวิเคราะห์และจัดกลุ่มชุดข้อมูลที่ labels กำกับ อัลกอริทึมเหล่านี้ค้นหารูปแบบที่ซ่อนอยู่หรือการจัดกลุ่มข้อมูลโดยไม่จำเป็นต้องมีการแทรกแซงของมนุษย์ ความสามารถในการค้นหาความเหมือนและความแตกต่างของข้อมูลทำให้เป็นโซลูชันที่ใช้สำหรับการวิเคราะห์ข้อมูลเชิงสำรวจ และอื่นๆ
- 3) Reinforcement Learning คือ การเรียนรู้ตามสภาพแวดล้อมเป็นอัลกอริทึมที่ไม่มีข้อมูลในการเรียนรู้ประเภทนี้ และไม่ได้สอนอัลกอริทึมอะไรเลย ทำงานโดยการจำลองอัลกอริทึมเพื่อให้โต้ตอบกับสิ่งแวดล้อม และหากอัลกอริทึมทำงานได้ดี ก็จะให้รางวัลแก่อัลกอริทึมนั้นหรือถ้าเกิดความผิดพลาดก็จะลงโทษอัลกอริทึม ด้วยปฏิสัมพันธ์และการเรียนรู้อย่างต่อเนื่อง การเปลี่ยนจากแยะไปเป็นการดีที่สุดเท่าที่จะทำได้สำหรับปัญหาที่ได้รับมอบหมาย [5]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สำหรับปริญญาโทฉบับนี้ใช้ Machine Learning แบบ Supervised Learning โดยเอาข้อมูลใส่เข้าไปในโปรแกรม CIRA CORE หลังจากนั้นโปรแกรมจะทำการแปลงให้เป็นภาษาคอมพิวเตอร์หรือเป็นตัวเลขก่อนเรียกว่า features และให้คำตอบกับข้อมูลเรียกว่า labels เมื่อใส่ Input เสร็จก็จะ Training Model เพื่อให้คอมพิวเตอร์แยกแยะข้อมูลตาม features ดังนั้น เมื่อเอาการเรียนรู้ของเครื่องที่ได้ไปใช้งาน โดยการป้อนภาพที่ไม่ได้อยู่ใน Training Data เครื่องก็จะตอบคำถามได้

2.2 Supervised Learning

Supervised Learning คือกระบวนการสร้างอัลกอริทึมเพื่อเรียนรู้การจับคู่อินพุตกับเอาต์พุตเฉพาะ ซึ่งทำได้โดยใช้ชุดข้อมูลที่มี labels กำกับที่คุณรวบรวมไว้ หากการ mapping ถูกต้อง แสดงว่าอัลกอริทึมได้เรียนรู้สำเร็จแล้ว มิฉะนั้น คุณต้องทำการเปลี่ยนแปลงที่จำเป็นในอัลกอริทึมเพื่อให้สามารถเรียนรู้ได้อย่างถูกต้อง อัลกอริทึมการเรียนรู้ภายใต้การดูแลสามารถช่วยคาดการณ์ข้อมูลใหม่ที่ไม่อยู่ในฐานข้อมูลซึ่งเราได้รับในภายหลัง ซึ่ง สิ่งนี้คล้ายกับสถานการณ์ครูกับนักเรียน มีครูคอยแนะนำนักเรียนให้เรียนรู้จากหนังสือและสื่ออื่นๆ นักเรียนจะได้รับการทดสอบและถ้าถูกต้องนักเรียนผ่าน มิฉะนั้น ครูจะปรับแต่งนักเรียนและทำให้นักเรียนเรียนรู้จากความผิดพลาดที่เขาหรือเธอได้ทำไว้ในอดีต นั่นคือหลักการพื้นฐานของการเรียนรู้ภายใต้การดูแล [6]



<https://techvidvan.com>, [Online]

รูปที่ 2.4 การเรียนรู้แบบ Supervised learning

Supervised learning สามารถแบ่งออกเป็น 2 ประเภท ได้แก่

2.2.1 Regression

Regression เป็นประเภทของการเรียนรู้ภายใต้การดูแลที่เรียนรู้จากชุดข้อมูลที่ติดป้ายกำกับ (labels) และจากนั้นสามารถคาดการณ์ผลลัพธ์ที่มีค่าต่อเนื่องสำหรับข้อมูลใหม่ที่กำหนดให้กับอัลกอริทึม ใช้เมื่อใดก็ตามที่ผลลัพธ์ที่ต้องการเป็นตัวเลข เช่น เงินหรือส่วนสูง เป็นต้น ซึ่งจะเป็น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การป้อนข้อมูลเข้าไปและจะมีผลลัพธ์เป็นตัวเลขโดยเป็นการพยายามที่จะทำนายคำตอบที่เป็น continuous output หรือคำตอบที่ continuous output หรือคำตอบที่ต่อเนื่องกันซึ่งจะเป็นการทำนายชุดข้อมูลอย่างต่อเนื่องจากการสังเกตนั่นคือตัวแปรที่แปรมีการตอบสนอง โดยจะแบ่งเป็น Linear Regression และ Logistic Regression

2.2.1.1 Linear Regression

อัลกอริทึมนี้อนุมานว่ามีความสัมพันธ์เชิงเส้นตรงระหว่างตัวแปร 2 ตัว ได้แก่ อินพุต (X) และเอาต์พุต (Y) ของข้อมูลที่ได้เรียนรู้ ตัวแปรอินพุตเรียกว่าตัวแปรอิสระและตัวแปรเอาต์พุตเรียกว่าตัวแปรตาม เมื่อข้อมูลที่ไม่ได้อยู่ในฐานข้อมูลถูกส่งไปยังอัลกอริทึม จะใช้ฟังก์ชัน คำนวณ และ mapping อินพุตกับค่าที่ต่อเนื่องกันสำหรับเอาต์พุต

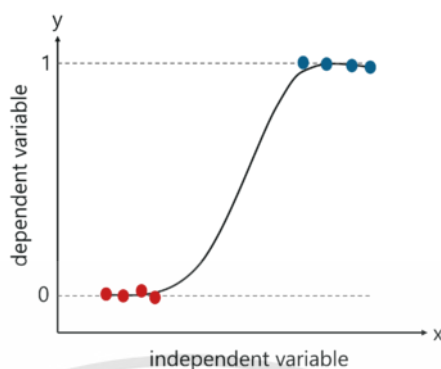


<https://d1jnx9ba8s6j9r.cloudfront.net>, [Online]

รูปที่ 2.5 กราฟแสดงอัลกอริทึมของ Linear Regression

2.2.1.2 Logistic Regression

Logistic Regression หรือเรียกอีกอย่างว่า Loss Function อัลกอริทึมนี้จะคาดการณ์ค่าที่ไม่ต่อเนื่องสำหรับชุดของตัวแปรอิสระ ที่ส่งผ่านไปยังตัวอัลกอริทึมหลังจากนั้นก็ทำการทำนายโดยการจับคู่ข้อมูล ที่ไม่อยู่ในฐานข้อมูลไปยังฟังก์ชัน logit ที่ได้รับการตั้งโปรแกรมไว้ อัลกอริทึมคาดการณ์ความน่าจะเป็นของข้อมูลใหม่ ดังนั้นผลลัพธ์จึงอยู่ระหว่างช่วง 0 ถึง 1



<https://d1jnx9ba8s6j9r.cloudfront.net>, [Online]

รูปที่ 2.6 กราฟแสดงอัลกอริทึมของ Logistic Regression


2.2.2 Classification

เป็นการเรียนรู้ประเภทหนึ่งที่อัลกอริทึมจำเป็นต้อง mapping ข้อมูลใหม่ที่ได้รับกับประเภทใดประเภทหนึ่งจาก 2 ประเภทที่เราสนใจในชุดข้อมูลของเรา คลาสหรือประเภทนั้นจำเป็นต้องจับคู่กับ 1 หรือ 0 ซึ่งในชีวิตจริงแปลว่า "ใช่" หรือ "ไม่ใช่" เช่น ฝนตก"หรือ ไม่ตก เป็นต้น ผลลัพธ์จะเป็นหนึ่งในคลาสและไม่ใช่ตัวเลขเหมือนในการ regression อัลกอริทึมโดยหลักการทำงานของมันจะเป็นการเทรนโมเดลเพื่อจัดประเภทข้อมูลของ Machine Learning โดยจะใช้ตัวแยกประเภทต่างๆ เลือกคุณสมบัติ ระบุแผนการเทรนโมเดลฝึกอบรมและประเมินผลลัพธ์ เพื่อค้นหาประเภทโมเดลการจำแนกที่ดีที่สุด โดยจะมีการจัดหาชุดข้อมูลอินพุตที่รู้จักจากการสังเกตหรือตัวอย่าง และการตอบสนองที่ทราบสำหรับข้อมูล เช่นป้ายกำกับหรือคลาส ที่ใช้ข้อมูลเพื่อฝึกโมเดลที่สร้างการคาดการณ์สำหรับการตอบสนองต่อข้อมูลใหม่

วิธีการจำแนกประเภทข้อมูล ทำจากการเทรนข้อมูลแล้วนำไปตรวจสอบและปรับแต่งโมเดลเพื่อแยกประเภทข้อมูลระหว่างอัลกอริทึมต่างๆ หลังจากนั้นนำมาเปรียบเทียบกับข้อผิดพลาดในการตรวจสอบ และทำการเลือกโมเดลที่ดีที่สุด เพื่อนำไปใช้วิเคราะห์ในขั้นตอนต่อไป โดยจะใช้วิธีเหล่านี้ในการเทรนโมเดลจำแนกประเภท ได้แก่ decision trees (แผนผังการตัดสินใจแบบรูปต้นไม้), Naive Bayes Classifier (ตัวจำแนกแบบเบย์อย่างง่าย), discriminant analysis (การวิเคราะห์แบบแยกแยะ), support vector machines (ขั้นตอนแบบ Supervised Learning) และ logistic regression (การวิเคราะห์การถดถอยแบบตรรกะ)

2.2.2.1 decision trees (แผนผังการตัดสินใจแบบรูปต้นไม้)

โดยจะจัดประเภทตามค่าคุณลักษณะ ซึ่งจะใช้วิธีการรับข้อมูลและค้นหาว่าคุณลักษณะใดของชุดข้อมูลให้ข้อมูลที่ดีที่สุด ทำให้เป็นโหนดรูทและอื่น ๆ จนกว่าพวกเขาจะสามารถจำแนกแต่ละประเภทของชุดข้อมูลได้ ทุกสาขาในแผนผังการตัดสินใจแสดงถึงคุณสมบัติของชุดข้อมูลเป็นหนึ่งในอัลกอริทึมที่ใช้กันอย่างแพร่หลายมากที่สุดสำหรับการจำแนกประเภท



<https://d1jnx9ba8s6j9r.cloudfront.net>, [Online]


รูปที่ 2.7 กราฟแสดงอัลกอริทึมของ decision trees

2.2.2.2 Naive Bayes Classifier (ตัวจำแนกแบบเบย์อย่างง่าย)

เป็นการจำแนกประเภทรูปแบบหนึ่งที่สำคัญหลักการ ของความน่าจะเป็นเข้ามาช่วยในการหาคำตอบของประเภทตัวอย่างใหม่

2.2.2.3 support vector machines (ขั้นตอนแบบ Supervised Learning)

อัลกอริทึม SVM อิงตามทฤษฎีการเรียนรู้ทางสถิติของ Vap Nik โดยจะใช้ฟังก์ชัน Kernel ซึ่งเป็นแนวคิดหลักสำหรับงานการเรียนรู้ส่วนใหญ่ อัลกอริทึมเหล่านี้สร้างไฮเปอร์เพลนที่ใช้ในการจำแนกคลาสทั้งสองออกจากกัน ใน SVM เราจะพล็อตรายการข้อมูลแต่ละรายการในชุดข้อมูลในพื้นที่ N-dimensional โดยที่ N คือจำนวนคุณลักษณะหรือแอตทริบิวต์ในข้อมูล ต่อไป ให้หาไฮเปอร์เพลนที่เหมาะสมที่สุดเพื่อแยกข้อมูล ด้วยเหตุนี้ SVM สามารถทำการจำแนกประเภทข้อมูลไบนารีได้เท่านั้น [7]



<https://d1jnx9ba8s6j9r.cloudfront.net>, [Online]


รูปที่ 2.8 กราฟแสดงอัลกอริทึมของ support vector machines

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.3 เทคนิคการเรียนรู้เชิงลึก

เทคนิคการเรียนรู้เชิงลึก (Deep learning) เป็นเทคนิคของการเรียนรู้เชิงจักรกลที่สอนให้คอมพิวเตอร์ทำในสิ่งที่มนุษย์สามารถทำได้ตามธรรมชาติซึ่งได้จากการเรียนรู้จากตัวอย่าง การเรียนรู้เชิงลึกเป็นเทคโนโลยีหลักที่อยู่เบื้องหลังรถยนต์ไร้คนขับ ทำให้สามารถจดจำป้ายหยุดรถ หรือแยกแยะคนเดินถนนจากเสาไฟได้ การเรียนรู้เชิงลึกได้รับความสนใจเป็นอย่างมากในช่วงที่ผ่านมาและ เป็นการบรรลุผลที่ไม่เคยทำได้มาก่อน ในการเรียนรู้เชิงลึก แบบจำลองคอมพิวเตอร์จะเรียนรู้การทำงานการจัดหมวดหมู่โดยตรงจากภาพ ข้อความหรือเสียง โมเดลการเรียนรู้เชิงลึกสามารถบรรลุความแม่นยำที่ล้ำหน้า ซึ่งบางครั้งก็เกินประสิทธิภาพระดับมนุษย์ โมเดลได้รับการฝึกอบรมโดยใช้ข้อมูลที่มีป้ายกำกับจำนวนมาก และสถาปัตยกรรมเครือข่ายประสาทเทียมที่ประกอบด้วยหลายชั้นวิธีการเรียนรู้เชิงลึกส่วนใหญ่ใช้ neural network architectures ซึ่งเป็นเหตุว่าทำไมแบบจำลองการเรียนรู้เชิงลึก (Deep learning) จึงมักถูกเรียกว่าโครงข่ายประสาทเชิงลึก (deep neural networks) คำว่า "ลึก" จะหมายถึงจำนวนชั้นที่ซ่อนอยู่ในโครงข่ายประสาทเทียม โครงข่ายประสาทเทียมแบบเดิมมีชั้นที่ซ่อนอยู่เพียง 2-3 ชั้น ในขณะที่โครงข่ายประสาทเชิงลึกสามารถมีได้มากถึง 150 ชั้น โมเดลการเรียนรู้เชิงลึกได้รับการฝึกอบรมโดยใช้ชุดข้อมูลที่มี labels จำนวนมากและ neural network architectures ที่เรียนรู้คุณลักษณะต่างๆ โดยตรงจากข้อมูลโดยไม่จำเป็นต้องแยกคุณลักษณะด้วยตนเอง [8]

โดยสมองคนเรามักจะพยายามถอดรหัสข้อมูลที่ได้รับอีกทั้งมักจะมีการตีความและการกำหนดสิ่งต่าง ๆ จะทำการแบ่งแยกเป็นหมวดหมู่ และเมื่อใดก็ตามที่สมองของคนได้รับข้อมูลใหม่สมองของคนจะพยายามเปรียบเทียบกับสิ่งที่ได้รู้ก่อนหน้านี้ ก่อนที่จะทำความเข้าใจกับมัน ซึ่งจะเช่นเดียวกัน Deep Learning ก็สามารถถูกสอนให้ทำงานในลักษณะเดียวกันให้สำเร็จได้โดย Deep Learning จะมีหลาย Hidden Layer ทำให้มันสามารถคำนวณอะไรที่ซับซ้อนได้เยอะมาก และสามารถใส่เทคนิคต่างๆ ได้มากขึ้น ที่สำคัญคือ Deep Learning คิดอย่างเป็นขั้นเป็นตอนและทำการทำนายผลออกมาเป็นผลลัพธ์ให้แม่นยำที่สุด



<https://www.mathworks.com/discovery/deep-learning> ,[Online]

รูปที่ 2.9 neural network architectures จัดเป็นชั้นประกอบด้วยชุดของโหนดที่เชื่อมต่อถึงกัน

deep neural networks ประเภทหนึ่งที่มีความนิยมมากที่สุดเรียกว่าโครงข่ายประสาทเทียม (CNN หรือ ConvNet) CNN รวบรวมคุณลักษณะที่เรียนรู้ด้วยข้อมูลที่ป้อนเข้า และใช้ชั้น Convolutional แบบ 2 มิติ ทำให้โครงสร้างนี้เหมาะสมกับการประมวลผลข้อมูล 2 มิติ เช่น รูปภาพ

CNN จะจัดความจำเป็นในการแยกคุณลักษณะด้วยตนเอง ดังนั้นเราจึงไม่จำเป็นต้องระบุคุณลักษณะที่ใช้ในการจัดประเภทรูปภาพ CNN ทำงานโดยแยกคุณสมบัติออกจากรูปภาพโดยตรง คุณสมบัติที่เกี่ยวข้องไม่ได้รับการฝึกอบรมล่วงหน้าโดยเรียนรู้ ในขณะที่เครือข่ายฝึกเกี่ยวกับคอลเลกชัน Core ของภาพ การแยกคุณลักษณะอัตโนมัตินี้ทำให้โมเดลการเรียนรู้เชิงลึกมีความแม่นยำสูงสำหรับงาน Vision system เช่น การจำแนกวัตถุ โดย CNN จะเรียนรู้ที่จะตรวจจับคุณสมบัติต่างๆ ของรูปภาพ โดยใช้ชั้นที่ซ่อนอยู่นับสิบหรือหลายร้อยชั้น ทุกชั้นที่ซ่อนอยู่จะเพิ่มความซับซ้อนของคุณสมบัติภาพที่เรียนรู้ ตัวอย่างเช่น ชั้นแรกที่ซ่อนอยู่สามารถเรียนรู้วิธีตรวจจับขอบ และชั้นสุดท้ายเรียนรู้วิธีตรวจจับรูปร่างที่ซับซ้อนมากขึ้นซึ่งรองรับรูปร่างของวัตถุที่เราพยายามจดจำโดยเฉพาะ

Deep Learning สร้างโครงข่ายประสาทแบบลึก (deep neural network) ขึ้นมาเป็นรูปแบบชั้น(layers) ที่แตกต่างกันเพื่อเรียนรู้ข้อมูล ความลึกล้ำของโมเดล (model) แสดงออกมาตามจำนวน layer ที่มากขึ้นใน model ตามมา Deep Learning เป็นรูปแบบใหม่ของศิลปะในรูปแบบของปัญญาประดิษฐ์ ใน Deep Learning ช่วงการเรียนรู้จะผ่านโครงข่ายประสาท (neural network) โดย neural network เป็นโครงสร้างชนิดหนึ่งที่มี layer เรียงซ้อน ๆ กันอยู่ข้างบน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.3.1 หลักการทำงานของการเรียนรู้เชิงลึก

Deep Learning neural networks หรือ Convolutional Neural Network (CNNs) จะพยายามเลียนแบบสมองของมนุษย์ผ่านการป้อนข้อมูล องค์ประกอบเหล่านี้ทำงานร่วมกันเพื่อจำแนก และอธิบายวัตถุภายในข้อมูลได้อย่างถูกต้อง Deep neural networks ประกอบด้วย โหนดที่เชื่อมต่อถึงกันหลายชั้น แต่ละชั้นสร้างขึ้นบนชั้นก่อนหน้าเพื่อปรับแต่งและเพิ่มประสิทธิภาพการทำงานหรือการจัดหมวดหมู่ ความก้าวหน้าของการคำนวณผ่านเครือข่ายนี้เรียกว่าการส่งต่อ ชั้นอินพุตและเอาต์พุตของโครงข่ายประสาทเทียมระดับลึกเรียกว่าชั้นที่มองเห็นได้ ชั้นอินพุตเป็นที่ที่โมเดลการเรียนรู้เชิงลึกนำเข้าข้อมูลสำหรับการประมวลผล และชั้นเอาต์พุตเป็นที่ที่การทำนายขั้นสุดท้ายหรือการจัดหมวดหมู่ถูกสร้างขึ้น อีกกระบวนการหนึ่งซึ่งเรียกว่า backpropagation ใช้อัลกอริทึม เช่น การไล่ระดับสีแบบลงล่าง เพื่อคำนวณข้อผิดพลาดในการคาดคะเน แล้วปรับ Weight และ Slope ของฟังก์ชัน โดยเลื่อนย้อนกลับผ่านชั้นต่างๆ [9] เพื่อพยายามฝึกโมเดล การส่งต่อและการส่งต่อกลับร่วมกันทำให้โครงข่ายประสาทเทียมสามารถคาดการณ์และแก้ไขข้อผิดพลาดต่างๆ ได้ตามลำดับ เมื่อเวลาผ่านไป อัลกอริทึมจะค่อยๆ แม่นยำขึ้นเรื่อยๆ ด้านบนนี้อธิบายประเภทโครงข่ายประสาทเทียมแบบลึกที่ง่ายที่สุดในแง่ที่ง่ายที่สุด อย่างไรก็ตาม อัลกอริทึมการเรียนรู้เชิงลึกนั้นซับซ้อนอย่างไม่น่าเชื่อ และมีโครงข่ายประสาทหลายประเภทเพื่อแก้ไขปัญหาหรือชุดข้อมูลที่เฉพาะเจาะจง ตัวอย่างเช่น Convolutional Neural Network (CNNs) และ Recurrent neural network (RNNs)

2.3.2 Convolutional Neural Network (CNNs)

โครงข่ายประสาทเทียมเป็นส่วนย่อยของการการเรียนรู้เชิงจักรกล และเป็นหัวใจสำคัญของอัลกอริทึมการเรียนรู้เชิงลึก ประกอบด้วยชั้นของโหนด ที่มีชั้นอินพุต ชั้นที่ซ่อนอยู่อย่างน้อยหนึ่งชั้น และชั้นผลลัพธ์ แต่ละโหนดเชื่อมต่อกับโหนดอื่นและมี Weight และ เกณฑ์ที่เกี่ยวข้อง หากเอาต์พุตของโหนดใดโหนดหนึ่งสูงกว่าค่าเกณฑ์ที่กำหนด โหนดนั้นจะถูกเปิดใช้งานโดยส่งข้อมูลไปยังชั้นถัดไปของเครือข่าย มิฉะนั้น จะไม่มีการส่งข้อมูลไปยังชั้นถัดไปของเครือข่าย แม้ว่าเราจะเน้นไปที่เครือข่าย feedforward ในบทความนี้เป็นหลัก แต่ก็มี neural nets หลายประเภท ซึ่งใช้สำหรับการใช้งานและประเภทข้อมูลที่แตกต่างกัน ตัวอย่างเช่น โครงข่ายประสาทที่เกิดซ้ำมักใช้สำหรับการประมวลผลภาษาธรรมชาติและการรู้จำเสียง ในขณะที่โครงข่ายประสาทเทียม (ConvNets หรือ CNN) มักใช้สำหรับการจัดหมวดหมู่และงานการมองเห็นด้วยคอมพิวเตอร์ ก่อนหน้า CNNs มีการใช้วิธีการแยกคุณลักษณะแบบแมนนวลและใช้เวลานานเพื่อระบุวัตถุในรูปภาพ อย่างไรก็ตาม โครงข่ายประสาทเทียมในปัจจุบันมีแนวทางที่ปรับขนาดได้มากขึ้นในการจัดหมวดหมู่รูปภาพและงานการจดจำวัตถุ โดยใช้ประโยชน์จากหลักการจากพีชคณิตเชิงเส้น โดยเฉพาะการคูณเมทริกซ์ เพื่อระบุรูปแบบภายในรูปภาพ ที่กล่าวว่าพวกเขาสามารถมีความต้องการทางคอมพิวเตอร์ซึ่งต้องใช้หน่วยประมวลผลกราฟิก (GPU) เพื่อฝึกโมเดล


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.3.2.1 การทำงานของโครงข่ายประสาทคอนโวลูชัน

โครงข่ายประสาทแบบคอนโวลูชัน(Convolutional neural network) แตกต่างจากโครงข่ายประสาทเทียมแบบอื่นๆ เนื่องจากประสิทธิภาพที่เหนือกว่าด้วยสัญญาณภาพ คำพูด หรือสัญญาณเสียง มีชั้นหลักสามประเภท ได้แก่

1) ชั้นคอนโวลูชัน (Convolutional layer)

Convolutional layer เป็นชั้นแรกของโครงสร้างประสาทเทียมแบบคอนโวลูชัน โดยชั้น Convolutional layer สามารถตามด้วยชั้น Convolutional layer ซึ่งซ้อนกันได้หรืออาจจะตามด้วยชั้น Pooling และชั้น FC จะเป็นชั้นสุดท้าย ในแต่ละชั้น CNN จะเพิ่มความซับซ้อน โดยระบุส่วนต่างๆ ของรูปภาพได้มากขึ้น ชั้นก่อนหน้านี้นั้นที่คุณสมบัติที่เรียบง่าย เช่น สีและขอบ เมื่อข้อมูลภาพเคลื่อนผ่านชั้นต่างๆ ของ CNN ข้อมูลจะเริ่มจดจำองค์ประกอบหรือรูปร่างที่ใหญ่กว่าของวัตถุ จนกว่าจะระบุวัตถุที่ต้องการได้ในที่สุด Convolutional Layer เป็นส่วนประกอบหลักของ CNN และเป็นสิ่งที่เกิดการคำนวณส่วนใหญ่ จำเป็นต้องมียังมีองค์ประกอบสองสามอย่าง ได้แก่ ข้อมูลที่ป้อน ตัวกรอง และแผนผังคุณลักษณะ สมมติว่าอินพุตจะเป็นภาพสี ซึ่งประกอบด้วยเมทริกซ์พิกเซลในแบบ 3 มิติ ซึ่งหมายความว่าอินพุตจะมีสามมิติ ได้แก่ ความสูง ความกว้าง และความลึกทำให้สอดคล้องกับ RGB ในภาพ เรายังมีตัวตรวจจับคุณลักษณะ หรือที่เรียกว่าเคอร์เนล(kernel)หรือตัวกรองซึ่งจะย้ายข้ามช่องรับของรูปภาพ ตรวจสอบว่ามีคุณลักษณะนี้หรือไม่ กระบวนการนี้เรียกว่าการคอนโวลูชัน ตัวตรวจจับคุณสมบัตินี้คืออาร์เรย์สองมิติ (2-D) ซึ่งแสดงถึงส่วนหนึ่งของภาพ แม้ว่าขนาดจะแตกต่างกันไป แต่ขนาดตัวกรองโดยทั่วไปจะเป็นเมทริกซ์ 3x3 นอกจากนี้ยังกำหนดขนาดของพื้นที่จากนั้นใช้ฟิลเตอร์กับพื้นที่ของรูปภาพ และผลิตภัณฑ์สเกลาร์จะคำนวณระหว่างพิกเซลอินพุตและ ฟิลเตอร์ผลิตภัณฑ์ สเกลาร์นี้จะถูกป้อนเข้าในอาร์เรย์เอาต์พุต หลังจากนั้น ตัวกรองจะเลื่อนไปหนึ่งก้าวทำซ้ำขั้นตอนจนกว่าเคอร์เนลจะกวาดไปทั่วทั้งภาพผลลัพธ์สุดท้ายจากชุดผลิตภัณฑ์ dot จากอินพุตและตัวกรองเรียกว่าพีเจอร์แมป แผนผังการใช้งาน หรือพีเจอร์แมปรวม



<https://www.ibm.com/cloud/learn/convolutional-neural-networks> , [Online]

รูปที่ 2.10 แสดงค่าเอาต์พุตและอินพุตในการเชื่อมต่อค่าพิกเซล

ในภาพด้านบน ค่าเอาต์พุตแต่ละค่าในแผนผังคุณลักษณะไม่จำเป็นต้องเชื่อมต่อกับค่าพิกเซลแต่ละค่าในภาพอินพุต ต้องเชื่อมต่อกับฟิลต์ที่เปิดกว้างเท่านั้นซึ่งกำลังใช้ตัวกรอง เนื่องจากอาร์เรย์เอาต์พุตไม่จำเป็นต้องจับคู่โดยตรงกับค่าอินพุตแต่ละค่า ค่าในตัวตรวจจับคุณสมบัติจะคงที่ในขณะที่เคลื่อนผ่านรูปภาพซึ่งเรียกอีกอย่างว่าการแชร์พารามิเตอร์บางอย่าง เช่นค่า Weight ปรับระหว่างการฝึกผ่านกระบวนการขยายพันธุ์ด้านหลังและการไล่ระดับสี อย่างไรก็ตาม มีไฮเปอร์พารามิเตอร์สามตัวที่ส่งผลต่อขนาดระดับเสียงของเอาต์พุตที่ จำเป็นต้องตั้งค่าก่อนเริ่มการฝึกของโครงข่ายประสาทเทียม ได้แก่

1. จำนวนตัวกรองส่งผลต่อความลึกของเอาต์พุต ตัวอย่างเช่น ตัวกรองที่แตกต่างกันสามตัว จะสร้างแผนที่คุณลักษณะที่แตกต่างกันสามแผนที่ สร้างความลึกเป็นสาม
2. Stride คือระยะทางหรือจำนวนพิกเซลที่เคอร์เนลเคลื่อนผ่านเมทริกซ์อินพุต แม้ว่าค่าการก้าวเท้าตั้งแต่สองก้าวขึ้นไปนั้นหาได้ยาก การก้าวที่ใหญ่ขึ้นย่อมให้ผลลัพธ์ที่น้อยกว่า
3. Zero-padding เมื่อฟิลเตอร์ไม่พอดีกับภาพที่ป้อน ซึ่งจะตั้งค่าองค์ประกอบทั้งหมดที่อยู่นอกเมทริกซ์อินพุตให้เป็นศูนย์ ทำให้เกิดเอาต์พุตที่ใหญ่ขึ้นหรือมีขนาดเท่ากันโดย padding มีสามประเภทคือValid padding คือการ convolution ครั้งสุดท้ายจะลดลงหากมิติไม่สอดคล้องกัน Same padding คือช่องว่างภายในนี้ช่วยให้แน่ใจว่าชั้นเอาต์พุตมีขนาดเท่ากับชั้นอินพุต Full padding คือ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การเติมประเภทนี้จะเพิ่มขนาดของเอาต์พุต โดยการเพิ่มศูนย์ที่เส้นขอบของอินพุตหลังจากการconvolutionแต่ละครั้ง CNN จะนำ Rectified Linear Unit (ReLU) ไปใช้กับแผนผังคุณลักษณะ โดยแนะนำความไม่เป็นเชิงเส้นให้กับแบบจำลอง ดังที่เราได้กล่าวไว้ก่อนหน้านี้ ชั้นการบิดตัวอื่นสามารถติดตามชั้นการบิดตัวเริ่มต้นได้ เมื่อสิ่งนี้เกิดขึ้น โครงสร้างของ CNN สามารถกลายเป็นลำดับชั้นได้เนื่องจากชั้นในภายหลังสามารถเห็นพิกเซลภายในพื้นที่ที่เปิดกว้างของชั้นก่อนหน้า ตัวอย่างเช่น สมมติว่าเรากำลังพยายามตรวจสอบว่ารูปภาพมีจักรยานหรือไม่ คุณสามารถมองจักรยานเป็นผลรวมของชิ้นส่วนต่างๆ ประกอบด้วยเฟรม แฮนด์จับ ล้อ แป้นเหยียบ และอื่นๆ แต่ละส่วนของจักรยานประกอบขึ้นเป็นลวดลายระดับล่างในโครงข่ายประสาท และการรวมกันของชิ้นส่วนแสดงถึงรูปแบบระดับสูงขึ้นไป ทำให้เกิดลำดับชั้นของคุณลักษณะภายใน CNN

<https://www.ibm.com/cloud/learn/convolutional-neural-networks> , [Online]

รูปที่ 2.11 แสดงตัวอย่างการตรวจจ็กรูปจักรยาน

2) ชั้นพูลลิง (Pooling Layer)

Pooling Layer หรือการปรับขนาดของข้อมูล โดยในขั้นนี้แทนที่เราจะใช้ข้อมูลภาพทั้งหมด เราจะแบ่งเป็นพื้นที่และเลือกพื้นที่นั้นซึ่งจะดำเนินการลดมิติ โดยลดจำนวนพารามิเตอร์ในอินพุต คล้ายกับชั้น Convolution การดำเนินการรวมกลุ่มจะกวาดตัวกรองทั่วทั้งอินพุตทั้งหมดเคอร์เนล(kernel) ใช้ฟังก์ชันการรวมกับค่าภายในพื้นที่(field)การรับแทน โดยใส่อาร์เรย์เอาต์พุต การรวมกันมีสองประเภทหลัก ได้แก่

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Max pooling และ Average pooling Max pooling คือขณะที่ตัวกรองเคลื่อนผ่านอินพุต ตัวกรองจะเลือกพิกเซลที่มีค่าสูงสุดเพื่อส่งไปยังอาร์เรย์เอาต์พุตแนวทางนี้มีแนวโน้มที่จะใช้บ่อยกว่าเมื่อเปรียบเทียบกับ Average pooling คือ ขณะที่ตัวกรอง (filter) เคลื่อนผ่านอินพุต ตัวกรองจะคำนวณค่าเฉลี่ยภายในฟิลด์ที่เปิดกว้างเพื่อส่งไปยังอาร์เรย์เอาต์พุต แม้ว่าข้อมูลจำนวนมากจะสูญหายไปในการรวมแต่ก็ยังมีประโยชน์มากมายสำหรับ CNN ช่วยลดความซับซ้อน ปรับปรุงประสิทธิภาพ และจำกัดความเสี่ยงจากการใส่มากเกินไป


3) ชั้นเชื่อมโยงแบบสมบูรณ์ (Fully-Connected Layer)

ในชั้นนี้ค่าพิกเซลของภาพที่ป้อนเข้าไม่ได้เชื่อมต่อโดยตรงกับชั้นเอาต์พุต ในชั้นที่เชื่อมต่อบางส่วน ใน Fully-Connected Layer แต่ละโหนดในชั้นเอาต์พุตจะเชื่อมต่อโดยตรงกับโหนดในชั้นก่อนหน้า ชั้นนี้ทำหน้าที่จัดหมวดหมู่ตามคุณลักษณะที่แยกจากชั้นก่อนหน้า และตัวกรองต่างๆ ในขณะที่ Convolution layer และ Pooling มักจะใช้ฟังก์ชัน ReLu ชั้น FC มักจะใช้ประโยชน์จากฟังก์ชันการเปิดใช้งาน softmax เพื่อจัดประเภทอินพุตอย่างเหมาะสม ทำให้เกิดความน่าจะเป็นตั้งแต่ 0 ถึง 1 [10]

2.3.3 Recurrent Neural Networks

Recurrent Neural Networks (RNN) เป็นโครงข่ายประสาทเทียมชนิดหนึ่งซึ่งใช้ข้อมูลแบบต่อเนื่องหรือข้อมูลอนุกรมเวลา อัลกอริทึมการเรียนรู้เชิงลึกเหล่านี้มักใช้สำหรับปัญหาลำดับหรือปัญหาชั่วคราว เช่น การแปลภาษา การประมวลผลภาษาธรรมชาติ (nlp) การรู้จำคำพูด และคำบรรยายภาพ รวมอยู่ในแอปพลิเคชันยอดนิยม เช่น Siri การค้นหาด้วยเสียง และ Google Translate เช่นเดียวกับเครือข่าย feedforward และคอนโวลูชัน (CNNs) Recurrent Neural Networks (RNN) จะใช้ข้อมูลการฝึกอบรมเพื่อเรียนรู้พวกเขาโดดเด่นด้วย "หน่วยความจำ" ของพวกเขาเนื่องจากใช้ข้อมูลจากอินพุตก่อนหน้าเพื่อมีอิทธิพลต่ออินพุตและเอาต์พุตปัจจุบัน ในขณะที่โครงข่ายประสาทเทียมแบบลึกดั้งเดิมถือว่าอินพุตและเอาต์พุตเป็นอิสระจากกันเอาต์พุตของโครงข่ายประสาทเทียมที่เกิดซ้ำจะขึ้นอยู่กับองค์ประกอบก่อนหน้าภายในลำดับ แม้ว่าเหตุการณ์ในอนาคตจะเป็นประโยชน์ในการกำหนดผลลัพธ์ของลำดับที่กำหนด แต่โครงข่ายประสาทเทียมที่เกิดซ้ำแบบทิศทางเดียวไม่สามารถอธิบาย

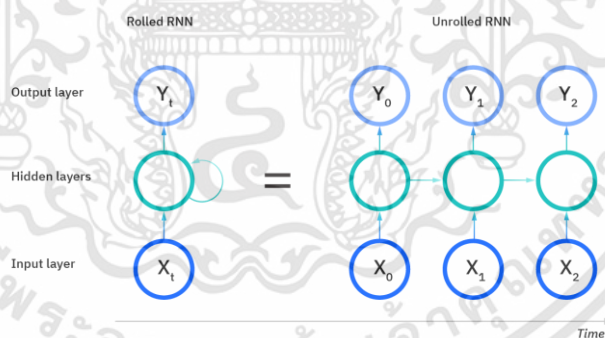
เหตุการณ์เหล่านี้ในการคาดคะเนได้ Recurrent Neural Network และ Feedforward Neural Network



<https://www.ibm.com/cloud/learn/recurrent-neural-networks> , [Online]

รูปที่ 2.12 แสดงตัวอย่าง Recurrent Neural Network และ Feedforward Neural Network

จากรูปภาพตัวอย่างที่ ภาพ Roll ของ RNN แสดงถึงโครงข่ายประสาทเทียมทั้งหมด ซึ่งอาจมากกว่าที่คาดการณ์ไว้ทั้งหมด เช่น ความรู้สึกภายใต้สภาพอากาศ ภาพ Unroll แสดงถึงแต่ละชั้นหรือขั้นตอนเวลาของโครงข่ายประสาทเทียม แต่ละชั้นจับคู่กับค่าเดียวในประโยคนั้น เช่น สภาพอากาศ อินพุตก่อนหน้า เช่น ความรู้สึก และ ภายใต้ จะแสดงเป็นสถานะที่ซ่อนอยู่ในขั้นตอนที่สามเพื่อทำนายผลลัพธ์



<https://www.ibm.com/cloud/learn/recurrent-neural-networks> , [Online]

รูปที่ 2.13 แสดงตัวอย่างการทำงานของ Recurrent Neural Network

ข้อดีของ Recurrent Neural Network คือสามารถแบ่งปันพารามิเตอร์ข้ามแต่ละชั้นของเครือข่าย แม้ว่าเครือข่าย feedforward จะมีค่าของweightที่แตกต่างกันในแต่ละโหนด แต่ของ Recurrent Neural Network จะใช้พารามิเตอร์เดียวกันภายในแต่ละชั้นของเครือข่าย ซึ่ง weight เหล่านี้จะยังคงถูกปรับผ่านกระบวนการ backpropagation และ gradient descent เพื่ออำนวยความสะดวกในการเรียนรู้การเสริมแรง(reinforcement learning)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Recurrent Neural Network จะใช้ประโยชน์จากอัลกอริทึม backpropagation through time (BPTT) เพื่อกำหนด gradients ซึ่งแตกต่างจากการแพร่กระจายกลับแบบเดิมเล็กน้อย เนื่องจากมีความเฉพาะเจาะจงสำหรับข้อมูลลำดับ หลักการของ BPTT นั้นเหมือนกับการแพร่กลับแบบเดิม โดยที่โมเดลจะฝึกตัวเองโดยการคำนวณข้อผิดพลาดจากชั้นเอาต์พุตไปยังชั้นอินพุต การคำนวณเหล่านี้ทำให้เราสามารถปรับและปรับพารามิเตอร์ของแบบจำลองได้อย่างเหมาะสม BPTT แตกต่างจากวิธีการแบบเดิมที่ BPTT รวมข้อผิดพลาดในแต่ละขั้นตอนในขณะที่เครือข่าย feedforward ไม่จำเป็นต้องรวมข้อผิดพลาดเนื่องจากไม่ได้แชร์พารามิเตอร์ในแต่ละชั้น [11]

ด้วยกระบวนการนี้ RNN มักจะพบปัญหาสองประการที่เรียกว่าการไล่ระดับสีแบบระเบิดและการไล่ระดับสีที่หายไป ปัญหาเหล่านี้กำหนดโดยขนาดของความลาดชัน ซึ่งเป็นความชันของฟังก์ชันการสูญเสียตามเส้นโค้งข้อผิดพลาด เมื่อการไล่ระดับสีเล็กเกินไปการไล่ระดับสีจะเล็กลงเรื่อยๆ โดยอัปเดตพารามิเตอร์ weight จนกว่าจะเป็น 0 เมื่อสิ่งนั้นเกิดขึ้น อัลกอริทึมจะไม่เรียนรู้อีกต่อไป การไล่ระดับสีแบบระเบิดเกิดขึ้นเมื่อการไล่ระดับสีมีขนาดใหญ่เกินไป ทำให้เกิดโมเดลที่ไม่เสถียร ในกรณีนี้ Weight ของแบบจำลองจะมีขนาดใหญ่เกินไป และในที่สุดจะแสดงเป็น NaN วิธีแก้ไขปัญหานี้วิธีหนึ่งคือการลดจำนวนชั้นที่ซ่อนอยู่ภายในโครงข่ายประสาทเทียมขจัดความซับซ้อนบางอย่างในแบบจำลอง RNN

2.3.3.1 ประเภทของ Recurrent Neural Networks

Feedforward networks จะจับคู่อินพุตหนึ่งรายการกับเอาต์พุตหนึ่งรายการ และในขณะที่แสดงภาพ Recurrent Neural Networks ในลักษณะนี้ในไดอะแกรมด้านบน เครือข่ายเหล่านี้ไม่มีข้อจำกัดนี้จริงๆ อินพุตและเอาต์พุตอาจแตกต่างกันไปตามความยาว และ RNN ประเภทต่างๆ จะถูกใช้สำหรับกรณีการใช้งานที่แตกต่างกัน เช่น การสร้างเพลง การจัดประเภทความรู้สึก และการแปลด้วยเครื่อง RNN ประเภทต่างๆ มักจะแสดงโดยใช้ไดอะแกรมต่อไปนี้

- 1) One-to-one RNN ใช้สำหรับการเรียนรู้เชิงจักรกล ซึ่งมีอินพุตเดียวและเอาต์พุตเดียว




<https://www.ibm.com/cloud/learn/recurrent-neural-networks> [Online]

รูปที่ 2.14 แสดงตัวอย่างการทำงานของ Recurrent Neural Network แบบ one-to-one

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


2) One-to-many RNN สำหรับประเภที่มีอินพุตเดียวและหลายเอาต์พุต



<https://www.ibm.com/cloud/learn/recurrent-neural-networks> , [Online]

รูปที่ 2.15 แสดงตัวอย่างการทำงานของ Recurrent Neural Network แบบ one-to-many


3) Many-to-one RNN สำหรับประเภที่ใส่ลำดับของอินพุตและสร้างเอาต์พุตเดียว การวิเคราะห์ความรู้สึกเป็นตัวอย่างที่ดีของเครือข่ายประเภนี้



<https://www.ibm.com/cloud/learn/recurrent-neural-networks> , [Online]

รูปที่ 2.16 แสดงตัวอย่างการทำงานของ Recurrent Neural Network แบบ Many-to-one

4) Many-to-many RNN ประเภทนี้ใช้ลำดับของอินพุตและสร้างลำดับของเอาต์พุต เช่น การแปลด้วยคอมพิวเตอร์(machine translation)



<https://www.ibm.com/cloud/learn/recurrent-neural-networks> , [Online]

รูปที่ 2.17 แสดงตัวอย่างการทำงานของ Recurrent Neural Network แบบ Many-to-many

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.3.4 ความแตกต่างระหว่าง การเรียนรู้เชิงจักรกล และ การเรียนรู้เชิงลึก

ความแตกต่างระหว่างการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกคือ การเรียนรู้เชิงลึกเป็นรูปแบบเฉพาะของการเรียนรู้เชิงจักรกล การทำงานของการเรียนรู้เชิงจักรกลเริ่มต้นด้วยพีเจอร์ที่เกี่ยวข้องโดยดึงมาจากรูปภาพ จากนั้นใช้คุณลักษณะต่างๆ เพื่อสร้างแบบจำลองที่จัดหมวดหมู่วัตถุในภาพ ด้วยการทำงานของการเรียนรู้เชิงลึก คุณลักษณะที่เกี่ยวข้องจะถูกดึงออกจากรูปภาพโดยอัตโนมัติ นอกจากนี้ การเรียนรู้เชิงลึกยังดำเนินการ "การเรียนรู้แบบ end-to-end" โดยที่เครือข่ายจะได้รับข้อมูลดิบและงานที่ต้องทำ เช่น การจัดประเภท และเรียนรู้วิธีดำเนินการโดยอัตโนมัติ ความแตกต่างที่สำคัญอีกประการหนึ่งคืออัลกอริทึมการเรียนรู้เชิงลึกปรับขนาดด้วยข้อมูล ในขณะที่การเรียนรู้แบบต้นมาบรรจบกัน การเรียนรู้แบบต้นมา หมายถึงวิธีการเรียนรู้ของเครื่องที่จะหยุดการทำงานในระดับหนึ่ง เมื่อคุณเพิ่มตัวอย่างและข้อมูลการฝึกฝนในเครือข่าย ข้อได้เปรียบที่สำคัญของเครือข่ายการเรียนรู้เชิงลึก คือเครือข่ายมักจะปรับปรุงต่อไปเมื่อขนาดของข้อมูลของคุณเพิ่มขึ้นโดยอัลกอริทึมการเรียนรู้เชิงจักรกล จะใช้ประโยชน์จากข้อมูลที่มีโครงสร้างและติดป้ายกำกับเพื่อคาดการณ์ ซึ่งหมายความว่าคุณลักษณะเฉพาะถูกกำหนดจากข้อมูลที่ป้อนเข้าสำหรับโมเดลและจัดเป็นตาราง ไม่ได้หมายความว่าจะไม่ใช้ข้อมูลที่ไม่มีโครงสร้างเสมอไป มันหมายความว่าถ้าเป็นเช่นนั้นโดยทั่วไปจะต้องผ่านการประมวลผลล่วงหน้าเพื่อจัดระเบียบให้อยู่ในรูปแบบที่มีโครงสร้าง การเรียนรู้เชิงลึกช่วยจัดการประมวลผลข้อมูลล่วงหน้าบางส่วนซึ่งโดยทั่วไปแล้วจะเกี่ยวข้องกับการเรียนรู้เชิงจักรกล อัลกอริทึมเหล่านี้สามารถนำเข้าและประมวลผลข้อมูลที่ไม่มีโครงสร้าง เช่น ข้อความและรูปภาพ และทำการแยกคุณลักษณะโดยอัตโนมัติ ขจัดการพึ่งพาผู้เชี่ยวชาญที่เป็นมนุษย์บางส่วน ตัวอย่างเช่น สมมติว่าเรามีรูปถ่ายสัตว์เลี้ยงหลายชุด และเราต้องการจัดหมวดหมู่ตาม แมว สุนัข หนู แฮมสเตอร์ เป็นต้น อัลกอริทึมการเรียนรู้เชิงลึกสามารถกำหนดว่าคุณลักษณะใด (เช่น หู) ที่สำคัญที่สุดในการแยกแยะสัตว์แต่ละตัวออกจากสัตว์อื่น ในการเรียนรู้เชิงจักรกล ลำดับชั้นของพีเจอร์นี้สร้างขึ้นด้วยตนเองโดยผู้เชี่ยวชาญที่เป็นมนุษย์ จากนั้น ในกระบวนการของการไล่ระดับการไล่ระดับสีและการแพร่กระจายย้อนกลับ อัลกอริทึมการเรียนรู้เชิงลึกจะปรับและเหมาะสมกับตัวเองเพื่อความแม่นยำ ทำให้สามารถคาดการณ์เกี่ยวกับภาพถ่ายใหม่ของสัตว์ได้อย่างแม่นยำยิ่งขึ้น โมเดลการเรียนรู้เชิงจักรกลและการเรียนรู้เชิงลึกก็มีความสามารถในการเรียนรู้ประเภทต่างๆ เช่นกัน ซึ่งมักจะจัดอยู่ในหมวดหมู่การเรียนรู้ภายใต้การดูแล การเรียนรู้แบบไม่มีผู้ดูแล และการเรียนรู้แบบเสริมกำลัง การเรียนรู้ภายใต้การดูแลจะใช้ชุดข้อมูลที่มีป้ายกำกับเพื่อจัดหมวดหมู่หรือคาดการณ์ สิ่งนี้ต้องการการแทรกแซงของมนุษย์เพื่อติดป้ายกำกับข้อมูลที่ป้อนอย่างถูกต้อง ในทางตรงกันข้าม การเรียนรู้แบบ unsupervised ไม่ต้องการชุดข้อมูลที่มีป้ายกำกับ แต่จะตรวจจบบรูปแบบในข้อมูลแทน โดยจัดกลุ่มตามลักษณะที่แตกต่าง การเรียนรู้การเสริมแรงเป็นกระบวนการที่ตัวแบบเรียนรู้ที่จะ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

แม่นยำมากขึ้น สำหรับการดำเนินการในสภาพแวดล้อมตามผลตอบรับเพื่อที่จะได้ผลตอบแทนสูงสุด สำหรับข้อมูลเจาะลึกเกี่ยวกับความแตกต่างระหว่างเทคโนโลยีต่างๆ โปรดดูที่ ปัญญาประดิษฐ์ เทียบกับ Machine Learning กับ Deep Learning กับ Neural Networks: What's the Difference



<https://www.mathworks.com/discovery/deep-learning.html>, [Online]

รูปที่ 2.18 เปรียบเทียบการเรียนรู้แบบเชิงลึกและแบบการเรียนรู้เชิงจักรกล


2.4 YOLO

เป็นอัลกอริทึมการเรียนรู้จำวัตถุที่ใช้วิธีการที่เรียกว่า Fast single-shot detection ซึ่งจะเป็นวิธีการที่สามารถตรวจจับวัตถุได้ จากการส่งผ่านรูปภาพเข้าไปในระบบเพียงครั้งเดียว โดยใช้หลักการโครงข่ายประสาทแบบคอนโวลูชันอัลกอริทึม YOLO มีการพัฒนาอย่างต่อเนื่องโดย YOLO มีหลายรุ่น (version) ซึ่งแต่ละรุ่นจะมีโครงสร้างสถาปัตยกรรมที่แตกต่างกัน [12]

2.4.1 YOLO V1

YOLO v1 ดังแสดงในรูปที่ 2.19 มีทั้งหมด 30 ชั้น 24 ชั้นแบบคอนโวลูชัน ชั้นรวมสูงสุด 4 ชั้น และชั้นที่เชื่อมต่อประเภทสมบรูณ์ 2 ชั้น ใช้รูปภาพเป็นอินพุตและปรับขนาดเพื่อให้มีอัตราส่วนกว้างยาวเท่ากัน แต่มีขนาด 448×448 โดยการเติมรูปภาพ และใช้การหมุน 1×1 ตามด้วยการหมุน 3×3 เพื่อลดจำนวนช่องสัญญาณ, Leaky ReLU เป็นฟังก์ชันการเปิดใช้งาน และการทำให้เป็นมาตรฐานแบบกลุ่มสำหรับการทำให้เป็นมาตรฐาน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



<https://towardsdatascience.com/yolo-v3-explained-ff5b850390f> ,[Online]


รูปที่ 2.19 โครงสร้างสถาปัตยกรรมของอัลกอริทึม YOLO V1

2.4.2 YOLO V2

YOLO v2 ให้การปรับปรุงใน YOLO v1 ในขณะที่ยังคงความเร็วของการคาดคะเน โครงสร้างชั้นอธิบายไว้ในรูปที่ 2.20 ในการปรับปรุงมีดังนี้

- 1) Batch normalization หรือ การทำให้เป็นมาตรฐานแบบกลุ่ม คือ การเพิ่มชั้นการเพื่อปรับข้อมูลให้เป็นมาตรฐาน ส่งผลให้มีการรวมกันกันของโมเดลเร็วขึ้น ซึ่งส่งผลให้การฝึกเร็วขึ้น นอกจากนี้ยังหมายความว่าความต้องการสำหรับประเภทการทำให้เป็นมาตรฐานอื่นๆ เช่น การออกกลางคั่น ถูกตัดออกไปโดยไม่มีความเสี่ยงที่จะเกิดการโอเวอร์ฟิตติง การเพิ่มการทำให้เป็นมาตรฐานแบบกลุ่มยังเพิ่มความแม่นยำเฉลี่ยเฉลี่ย (mAP)
- 2) High-resolution classifier หรือ ความคลาสสิกที่มีความละเอียดสูง คือ เมื่อเทียบกับ YOLO v1 ซึ่งใช้อิมเมจอินพุตของขนาด (224 x 224) แล้ว YOLO v2 จะใช้อิมเมจของขนาด (448 x 448) เป็นอินพุต ส่งผลให้เครือข่ายมีเวลามากขึ้นในการปรับฟิลเตอร์สำหรับภาพที่มีความละเอียดสูงขึ้น การเพิ่มขนาดอินพุตส่งผลให้ mAP เพิ่มขึ้น 4%
- 3) Anchor boxes เป็นฟังก์ชันการทำงานของ YOLO กรณีถ้าในแต่ละกริดมีวัตถุมากกว่าหนึ่งอย่าง คือการสร้าง Anchor box ในรูปทรงต่างๆ และคำนวณใหม่ เพื่อให้ได้ผลลัพธ์ที่ครอบคลุมและ แม่นยำมากขึ้น ซึ่งช่วยเพิ่มความแม่นยำในการวาง ตำแหน่ง Bounding box และเป็นชั้นที่เชื่อมต่อกันใน YOLO v1 ใช้เพื่อคาดการณ์กล่องที่มีขอบเขตบนวัตถุในภาพ ซึ่งแตกต่างจากสถาปัตยกรรมที่ใหม่กว่า เช่น R-CNN ซึ่งการคาดการณ์พิกัดของวัตถุ ใน YOLO v2 ชั้นที่เชื่อมต่อทั้งหมดจะถูกลบออก และใช้กล่องยึดแทนกล่องที่มีขอบ ใน YOLO v2 รูปภาพที่ป้อนจะถูกแบ่งออกเป็นเซลล์ 13 x 13 และกล่องยึดห้ากล่องในแต่ละเซลล์ เครือข่ายคาดการณ์พารามิเตอร์ของกรอบล้อมรอบ เช่น พิกัดศูนย์กลาง ความสูง และความกว้าง แล้วแก้ไขตำแหน่งของกล่องที่มีอยู่ [13]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




<https://towardsdatascience.com/yolo-v3-explned-ff5b850390f> [Online]

รูปที่ 2.20 โครงสร้างสถาปัตยกรรมของอัลกอริทึม YOLO V2

2.4.3 YOLO V3

โดยปัจจุบันอัลกอริทึม YOLO V3 มีประสิทธิภาพทั้งด้านความแม่นยำ และความเร็วในการประมวลผลที่ดีที่สุด โดยโครงสร้างสถาปัตยกรรมของรุ่นนี้มีจำนวนชั้น (Layers) 106 ชั้น ซึ่งเป็นจำนวนชั้นที่ถูกกำหนดโดยผู้พัฒนา และถูกบรรจุเป็นกรอบหรือเฟรมเวิร์คที่เรียกว่า Darknet framework ซึ่งในปัจจุบันทางผู้พัฒนายังไม่เปิดให้มีการแก้ไขหรือปรับเปลี่ยนโครงสร้าง ซึ่งลักษณะการทำงานของโครงสร้างแต่ละจำนวนชั้นจะมีการทำงานที่แตกต่างกัน โดยสรุปลักษณะการทำงานต่างๆ ดังนี้ ชั้นของคอนโวลูชัน ชั้นของการเพิ่มอัตราสุ่มชั้นของการทำนายผล




<https://towardsdatascience.com/yolo-v3-explned-ff5b850390f> [Online]

รูปที่ 2.21 โครงสร้างสถาปัตยกรรมของอัลกอริทึม YOLO V3

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ทั้งนี้อัลกอริทึม YOLO จะมีสถาปัตยกรรมแบบ Tiny ซึ่งมีการลดทอนจำนวนชั้นบางชั้นออกไป ทำให้โครงสร้างมีความซับซ้อนน้อยกว่าอัลกอริทึม YOLO แบบสมบูรณ์โดยส่งผลดีในด้านความเร็วในการประมวลผล แต่ความถูกต้องแม่นยำจะลดลง

ในงานวิจัยนี้ได้เลือกใช้ Tiny YOLOv3 ซึ่งเป็นรุ่นที่มีการพัฒนาประสิทธิภาพในด้านความถูกต้องแม่นยำให้มากขึ้นจากรุ่นเก่า โดย Tiny YOLOv3 มีจำนวนชั้นของโครงสร้างเครือข่ายประสาทเทียม (Layers) จำนวน 24 ชั้น ซึ่งมีจำนวนน้อยกว่าอัลกอริทึม แบบ YOLO ประเภทสมบูรณ์ที่มีจำนวน 106 ชั้น ทำให้ลดเวลาและลดการใช้ทรัพยากรในการประมวลผลลงได้อย่างมากในอัลกอริทึม YOLO การดำเนินการจำแนกวัตถุว่าเป็นชนิดอะไร (classification) และดำเนินการหาตำแหน่งของวัตถุ (localization) โดยใช้กรอบล้อมวัตถุ (Bounding Box) จะทำไปพร้อม ๆ กัน กรรมวิธีของ YOLO ไม่ได้พิจารณาดำเนินการจากภาพทั้งภาพ แต่จะแบ่งภาพออกเป็นส่วน ๆ ซึ่งวิธีการแบบนี้ส่งผลดีในด้านความเร็วของการประมวลผล YOLO มีขั้นตอนการทำงานของ YOLO จะเป็นในลักษณะการแบ่งรูปภาพเป็นส่วนๆ หรือกริด (grid) จากนั้นทำการเลื่อนการคำนวณไปที่ละจุดตามที่แบ่งกริดไว้ (Sliding Windows) พร้อมกับคำนวณหาว่าวัตถุจะมีอยู่จริงหรือไม่ มากน้อยเพียงไรจากความน่าจะเป็นของวัตถุที่ปรากฏในพื้นที่นั้นๆ ด้วยกระบวนการ Intersection over Union (IoU) ซึ่งคำนวณจากอัตราส่วนของพื้นที่ซ้อนทับ (ของพื้นที่ที่ทำนายกับพื้นที่จริง) กับ พื้นที่รวม (ของพื้นที่ที่ทำนายกับพื้นที่จริง) ในการทำงานกรอบล้อมวัตถุจะได้ข้อมูลเป็นชุดข้อมูลประเภทอาร์เรย์ ซึ่งประกอบด้วยข้อมูลการมีอยู่จริงของวัตถุตำแหน่ง และขนาดของกรอบล้อมวัตถุ และชนิดของวัตถุ กรณีถ้าในแต่ละกริดมีวัตถุมากกว่าหนึ่งอย่าง YOLO มีกระบวนการ Anchor box เพื่อแก้ปัญหาดังกล่าว แนวคิดคือการสร้าง Anchor box ในรูปทรงต่างๆ และคำนวณใหม่ เพื่อให้ได้ผลลัพธ์ที่ครอบคลุมและ แม่นยำมากขึ้น เมื่อระบบสร้างกรอบล้อมวัตถุจนหมดแล้ว จะเข้าสู่กระบวนการ Non-max Suppression ซึ่งขั้นตอนนี้จะเป็นการลดจำนวนกรอบล้อมวัตถุที่เป็นวัตถุเดียวกัน และอยู่ในพื้นที่เดียวกันที่มี ความน่าจะเป็นน้อยกว่าค่าที่กำหนดไว้ (threshold) โดยอัลกอริทึม YOLO ถูกนำไปประยุกต์ใช้ในงานที่เป็นลักษณะ ของการรู้จำวัตถุที่หลากหลาย เช่น ระบบการตรวจจับเครื่องบินที่จอดอยู่บนพื้น ด้วยการถ่ายภาพจากอากาศยานแบบไร้คนขับ ซึ่งผลการทดลองของบทความนี้พบว่า ความแม่นยำของอัลกอริทึม YOLO v3 อยู่ที่ 81%–91% ส่วน Tiny YOLO v3 อยู่ที่ 72%–90% ในด้านของความเร็วในการประมวลผลพบว่า อัลกอริทึม YOLO v3 อยู่ที่ประมาณ 13 รูปต่อวินาที ส่วน Tiny YOLO v3 อยู่ที่ประมาณ 41 รูปต่อวินาที จากบทความ ดังกล่าวพบว่าอัลกอริทึม Tiny YOLO v3 ใช้เวลาในการประมวลผลน้อยกว่าถึง 2–3 เท่า ส่วนความแม่นยำที่ลดน้อยลง แต่ยังอยู่ในระดับที่สามารถนำไปใช้งานได้ [14]



https://www.researchgate.net/figure/YOLOv3-tiny-Network_fig1_340017457[Online]

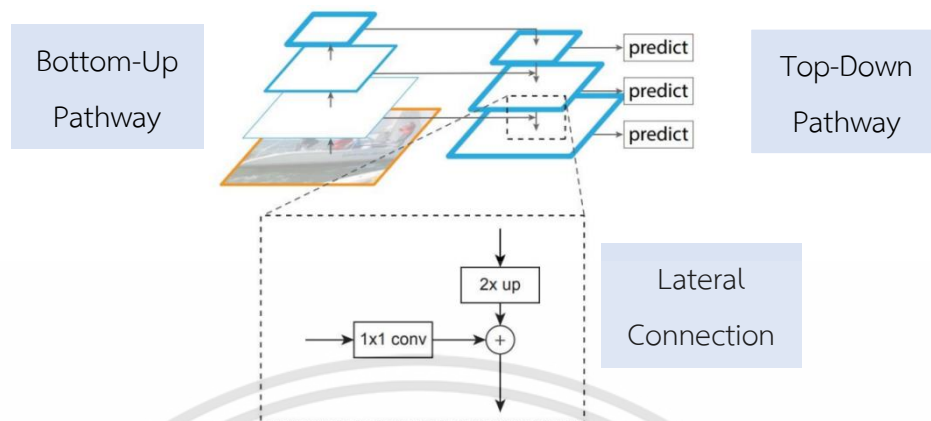
รูปที่ 2.22 การตรวจจับรูปภาพโดยสถาปัตยกรรมโครงสร้างของ Tiny YOLO V3

2.4.4 สถาปัตยกรรม Features Pyramid Networks (FPN)

สถาปัตยกรรม FPN เป็นการนำเสนอการใช้ประโยชน์จากความหลายมาตราส่วน บนระดับพีระมิดของโครงข่ายคอนโวลูชันเพื่อสร้างพีระมิดคุณลักษณะ โดยมีการเพิ่มการเชื่อมต่อ ด้านข้างเพื่อสร้างแผนภาพคุณลักษณะที่มีความหมายระดับสูงในทุกระดับชั้นพีระมิด รูปแบบการเชื่อมต่อของสถาปัตยกรรม FPN มี 3 รูปแบบดังรูปที่ 2.23 ได้แก่ การเชื่อมต่อในแนว bottom-up pathway การเชื่อมต่อในแนว top-down pathway และการเชื่อมต่อในแนว lateral connection โดยแต่ละแนวการเชื่อมต่อมีรายละเอียดดังนี้

- 1) Bottom-Up Pathway ในขั้นนี้เป็นการประมวลผลแบบการดำเนินการไปข้างหน้า (feedforward computation) ของโครงข่าย backbone คอนโวลูชัน เพื่อทำการแยกคุณลักษณะภาพ โดยจะได้ภาพที่มีหลายมาตราส่วนที่ระดับพีระมิตต่างกัน โดยที่ระดับพีระมิตสูงความละเอียดเชิงพื้นที่จะลดลง ค่าความหมายคุณลักษณะภาพสูงขึ้น ผลลัพธ์จากขั้นสุดท้ายของแต่ละระดับพีระมิต ถูกใช้เป็นแผนภาพคุณลักษณะเพื่อดำเนินการแนว lateral แล้วผสมเข้ากับการดำเนินการในแนว Top-Down Pathway
- 2) Top-Down Pathway ภาพอ้างอิงจากผลลัพธ์สุดท้ายของแต่ละระดับพีระมิตในแนว bottom-up pathway ถูกใช้เป็นแผนภาพเริ่มต้นเพื่อทำการ up-sampling เพิ่มขนาดเชิงพื้นที่ให้มีขนาดเพิ่ม เป็น 2 เท่า และข้อมูลจะถูกปรับความละเอียดเชิงพื้นที่ด้วยการผสม (Addition method) เข้ากับ ผลลัพธ์จากการ convolution ของการเชื่อมต่อในแนว lateral connection จากนั้นผลลัพธ์ที่ได้ จากการผสมคุณลักษณะแต่ละระดับพีระมิตในแนว Top-Down Pathway จะถูก convolution เพื่อสร้างแผนภาพคุณลักษณะสุดท้ายรวมถึงการลด aliasing effect จากการ up-sampling

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



<http://nuir.lib.nu.ac.th/dspace/bitstream/123456789/2323/3/61061932.pdf> [Online]

รูปที่ 2.23 โครงสร้างสถาปัตยกรรม Features Pyramid Networks (FPN)

2.5 การทำให้เป็นมาตรฐาน หรือ Data Normalization

การทำให้เป็นมาตรฐาน เป็นการปรับขนาดคุณลักษณะ จะเป็นการปรับค่าในช่วงขอบเขตของข้อมูลที่อยู่ในช่วงเดียวกันในแต่ละ Feature (Field) และนำค่าไปประมวลผลต่อ เช่น ช่วงข้อมูล [0, 1] หรือ [-1, 1] จะได้ผลลัพธ์อยู่ในช่วงที่กำหนดซึ่งเราจะเรียกว่า Data Normalization โดยเราจะนิยมนำไปจัดการข้อมูลก่อนแล้วจึงจะนำไปเทรนข้อมูลต่อไป

ในการป้อนข้อมูลของอัลกอริทึม Machine Learning หลาย ๆ ตัว มันจะไม่สามารถรับข้อมูลหลากหลาย Scale ได้โดยตรง โดยเราจะต้องจำเป็นที่จะทำให้เป็น Normalization ก่อนถึงจะทำการป้อนข้อมูลให้กับโมเดลได้ และจะทำให้อัลกอริทึมถึงจะสามารถทำงานได้ ยกตัวอย่างเช่น L2 Loss หรือ Mean Squared Error ถ้าค่ายิ่งแตกต่างกันมาก Loss ก็ยิ่งมากเป็นทวีคูณ เนื่องจากยกกำลังสอง ทำให้ Feature Weight ที่จำนวนใหญ่กว่า ช่วงใหญ่กว้างกว่า จะบดบัง Feature อื่น ๆ ไปหมด แต่ถ้าเรา Normalize ทุก Feature ให้เป็น [0, 1] เท่ากันหมด ก็จะแก้ปัญหานี้ได้ การ Normalization ข้อมูล ทำให้ อัลกอริทึม Gradient Descent สามารถ Converge ได้เร็วขึ้น

2.5.1 Rescaling (Min-Max Normalization)

Rescaling หรือ หรือการปรับค่า เป็นการทำให้ข้อมูลที่มีค่าสูงสุดและค่าต่ำสุดในรูปแบบมาตรฐาน ซึ่งเป็นการปรับค่าในช่วงของข้อมูลให้อยู่ในช่วง [0, 1] ด้วยการทำค่าของข้อมูลเฉพาะ หรือค่าของแถว ๆ นั้น โดยจะมีการนำค่าที่มันน้อยที่สุดนำไปลบแล้วทำการหารด้วยช่วงของข้อมูล

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)}$$

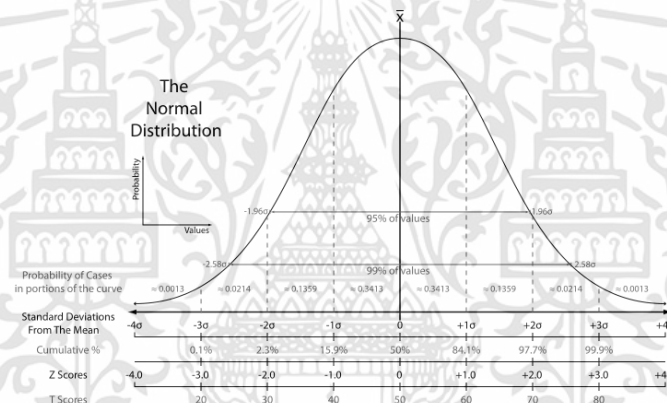
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.5.2 Mean Normalization

Mean Normalization จะเป็นการทำข้อมูลที่มีลักษณะคล้ายกับปรับขนาด Rescaling ด้านบน แต่จะมีความแตกต่างกันที่ใช้ค่ากลางแทนค่าต่ำสุด ทำให้ช่วงของ Output ที่ $[-0.5, 0.5]$ มีทั้งบวก และลบ ซึ่งจะทำให้มีความสมดุลกันของทั้ง 2 ข้าง

$$x' = \frac{x - \text{average}(x)}{\text{max}(x) - \text{min}(x)}$$

เรามักจะเห็น Mean Normalization อีกวิธีการคิดโดยการนำค่า Standard Deviation ไปหาร เพื่อให้ Output ที่ออกมา มี Standard Deviation เป็น 1 โดยเราจะเรียกว่า Standardization



<https://www.bualabs.com/archives> , [Online]

รูปที่ 2.24 กราฟการ Standardization ของ Mean Normalization

2.5.3 การกำหนดมาตรฐาน (Z-Score Normalization)

Standardization หรือ Z-Score Normalization คือ การนำข้อมูลที่มีลักษณะเฉพาะ หรือข้อมูลที่เป็นแถวมาทำการให้ค่ามีค่าเท่ากับศูนย์ และส่วนเบี่ยงเบนมาตรฐานมีค่าเท่ากับหนึ่ง

$$x' = \frac{x - \bar{x}}{\sigma}$$

โดยอัลกอริทึมของ Machine Learning หลาย ๆ ตัวที่มีจะต้องทำการปรับเปลี่ยนข้อมูล ให้เป็นแบบนี้ก่อนที่จะป้อนให้โมเดลใช้เทรน โดยซึ่งเราจะต้องเก็บค่าในรูปของค่ากลางและส่วน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เพียงเบนมาตรฐานไว้ด้วย เวลาที่เราทดสอบก็ต้องใช้ค่าเดียวกันกับตอนเทรนในการปรับข้อมูล Validation Set / Test Set


2.5.4 Scale to Unit Length

Scale to Unit Length คือ การกรณที่ข้อมูลมีค่าเป็น Vector และเราจะทำการหารด้วย Euclidean Norm เพื่อให้ค่าของ Vector ปรับให้เป็นค่าของ Unit Vector [15]

$$x' = \frac{x}{\|x\|}$$

2.6 Threshold

เทรชโฮลด์ (threshold) คือ ค่าอินพุตที่น้อยที่สุดที่เครื่องมือวัด (instrument) หรือ ทรานสดิวเซอร์ (transducer) เริ่มแสดงเอาต์พุตออกมา โดยในช่วงเริ่มต้นเครื่องมือวัดอยู่ในตำแหน่งศูนย์ (ไม่มีอินพุต) เมื่อได้รับอินพุตเครื่องมือวัดยังคงไม่แสดงเอาต์พุตออกมาจนกระทั่งถึงอินพุตค่าหนึ่ง เครื่องมือวัดจะแสดงเอาต์พุตออกมา (ดังรูป) โดยเทรชโฮลด์เป็นคุณลักษณะหนึ่งของเครื่องมือวัดที่ใช้สำหรับอธิบาย การเกิดบริเวณไร้การตอบสนอง (dead zone/dead band) ของเครื่องมือวัดหรือทรานสดิวเซอร์ [16]



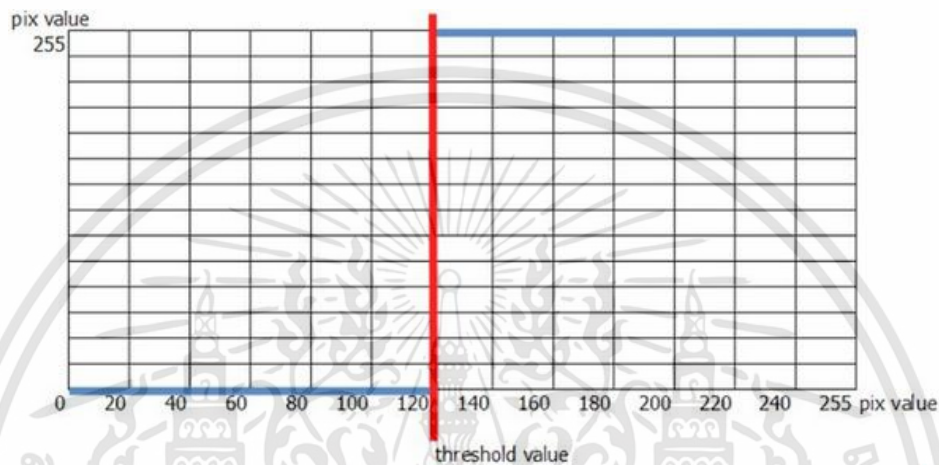
<https://www.foodnetworksolution.com/wiki/word/1073/threshold> , [Online]

รูปที่ 2.25 เอาท์พุตของ Threshold

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.6.1 Threshold OpenCV

หลักการการทำงานของ Threshold เป็นหลักการที่ใช้ค่าคงที่ค่าหนึ่ง ในการเปรียบเทียบกับค่าของ Pixel ในแต่ละพื้นที่ ถ้าค่าของ Pixel ในพื้นที่นั้นมีค่าน้อยกว่าค่าคงที่ ก็จะเปลี่ยนค่า Pixel ของพื้นที่นั้นเป็น 0 แต่ถ้าค่าของ Pixel ในพื้นที่นั้นมีค่ามากกว่าก็จะเปลี่ยนค่า Pixel ของพื้นที่นั้นเป็น 255 โดยภาพ input จะต้องเป็นภาพ Grayscale [17]



<http://kengzer.blogspot.com/2013/01/emgu-cv-lab-6-threshold.html> , [Online]

รูปที่ 2.26 ตารางแสดงถึงค่าของ Pixel


จากภาพกำหนดให้ค่า Threshold = 120 จะสังเกตว่าค่าไหนที่มีค่าน้อยกว่า 120 จะถูกปรับให้เป็น 0 แต่ถ้าค่าไหนมีค่ามากกว่าจะถูกปรับให้เป็น 255 ดังนั้นสมการฟังก์ชันของ Threshold คือ

$$g(x,y) = 0 \quad \text{if } f(x,y) < \text{Thresholdvalue}$$

$$g(x,y) = 255 \quad \text{if } f(x,y) \geq \text{Thresholdvalue}$$

ฟังก์ชัน Threshold มี 5 แบบ

- 1) Threshold Binary
- 2) Threshold Binary, Inverted
- 3) Truncate
- 4) Threshold to Zero
- 5) Threshold to Zero, Inverted



<http://kengzer.blogspot.com/2013/01/emgu-cv-lab-6-threshold.html> , [Online]

รูปที่ 2.27 รูปตัวอย่างแสดงการทำงานของ Threshold 5 ประเภท

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 3

หลักการออกแบบและสร้าง

3.1 อุปกรณ์และเครื่องมือที่ใช้ในการดำเนินการ

3.1.1 คอมพิวเตอร์



<https://notebookspec.com>, [Online]

รูปที่ 3.1 ภาพคอมพิวเตอร์

ตารางที่ 3-1 คอมพิวเตอร์ที่ใช้งานและใช้ Train AI ต้องมีคุณสมบัติ ดังนี้

สเปกขั้นต่ำสำหรับเครื่องที่ใช้งาน	สเปกแนะนำสำหรับเครื่องที่ใช้งานและ Train AI ที่มีค่าแม่นยำ
1. CPU intel core i3	1. CPU intel core i5
2. ram DDR 4 GB	2. RAM DDR ตั้งแต่ 4 GB ขึ้นไป
	3. การ์ดจอ Nvidia GPU ตั้งแต่ 4 GB ขึ้นไป

** สำหรับระบบปฏิบัติการ Windows ต้องใช้ Windows 10 64 Bit เท่านั้นถึงจะสามารถติดตั้ง

CIRA CORE เวอร์ชัน Beta ได้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3-2 สเปคคอมพิวเตอร์ที่ใช้งาน

Graphics	GeForce 1650
OS	64 bit
Disk	512 GB
Memory	16 GB
Processor	AMD Ryzen 7 3750 H

3.1.2 กล้อง Webcam 1080



รูปที่ 3.2 กล้อง Webcam

<https://thaipick.com>, [Online]

ตารางที่ 3.2 คุณสมบัติ ของอุปกรณ์

Resolution	1080 p
Frame rate	30 fps
Lens	12 MP Optical lens

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.1.3 Arduino Uno R3



<https://www.thai-corporation.net/>

รูปที่ 3.3 Arduino Uno R3

ตารางที่ 3-3 คุณสมบัติของบอร์ด Arduino

Microcontroller	8-bit AVR family microcontroller
Operating Voltage	5V
Recommended Input Voltage	7-12V
Input Voltage Limits	6-20V
Analog Input Pins	6(A0-A5)
Digital I/O Pins	14(Out of which 6 provide PWM output)
DC Current on 3.3 V Pin	50 mA
Flash Memory	32 KB (0.5 KB is used for Bootloader)
SRAM	2 KB
EEPROM	1 KB

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.1.4 สายแพสีรุ้ง เข้าหัว Jumper Wire 20 cm



<https://www.spebanmoh-online.com>, [Online]

รูปที่ 3.4 สายแพสีรุ้งเข้าหัว Jumper Wire

เป็นสายนำสัญญาณมีตัวนำหลายเส้น ส่วนมากมักใช้มากกับการเชื่อมต่ออุปกรณ์ภายในคอมพิวเตอร์ ทั้งการเชื่อมต่อฮาร์ดดิสก์, ไดรฟ์ซีดี และ ไดรฟ์ฟลอปปีดิสก์ในระบบ ATA และ ไมโครคอมพิวเตอร์ยุคแรกๆ บางระบบ จะใช้เชื่อมต่อกับอุปกรณ์ภายนอก

3.1.5 สานพานลำเลียง Conveyor belt 40x10 cm.



(ก)



(ข)



(ค).

รูปที่ 3.5 Conveyor belt 40x10 cm

(ก) สายพานด้านข้าง

(ข) สายพานด้านหน้า

(ค) สายพานด้านบน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.1.6 Servo Motor MG995



<https://www.cybertice.com>, [Online]

รูปที่ 3.6 Servo Motor MG995

ตารางที่ 3-4 คุณสมบัติของ Servo Motor MG995

Operating Speed	0.17 sec/60 degrees
Stall Torque	9 kg-cm
Operation Voltage	4.8-7.2 V

3.1.7 Power Supply 12V 5A 60W



<https://www.ptsmartengineering.com>

รูปที่ 3.7 Power Supply 12V 5A 60W


1x Switching power supply AC 100-240V to DC 12V 5A 60W module ระบบ
ตัดไฟอัตโนมัติ เมื่อมีการช้อตวงจร

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3-5 คุณสมบัติของ Power Supply 12V 5A

แรงดันอินพุต	100-240VAC
แรงดันเอาต์พุต	12Vdc
กำลังเอาต์พุต	60W
ขนาด	110*78*36mm

3.1.8 PWM Motor DC Controller 12V-40V 10A



<https://sea.banggood.com>, [Online]

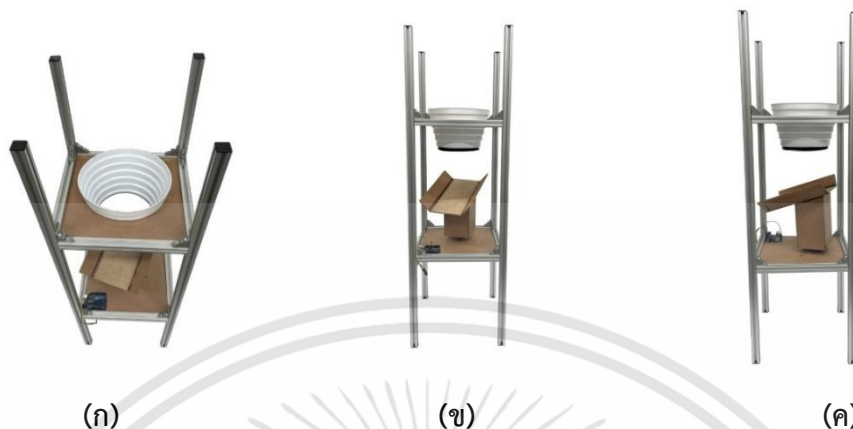
รูปที่ 3.8 PWM Motor DC Controller 12V-40V 10A

ตารางที่ 3-6 คุณสมบัติ PWM Motor DC Controller

แรงดันไฟฟ้าที่ใช้งานได้:	DC 12V-40V
แรงดันไฟฟ้าขาเข้า:	9-50V DC
ควบคุมการใช้พลังงาน	0.01-400W
กระแสไฟสถิต	0.02 A (สแตนด์บาย)
PWM อัตราการสุมตัวอย่าง	0% -100%
ความถี่ PWM:	13 kHz

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.1.9 โครงสร้างชิ้นงาน



รูปที่ 3.9 โครงสร้างชิ้นงาน
 (ก) โครงสร้างด้านบนข้าง (ข) โครงสร้างด้านหน้า (ค) โครงสร้างด้านหน้าข้าง

3.2 ซอฟต์แวร์ที่ใช้ในการดำเนินการ

3.2.1 Windows

Windows คือ ระบบปฏิบัติการคอมพิวเตอร์ระบบหนึ่ง (operating system) สร้างขึ้นโดยบริษัทไมโครซอฟต์ เนื่องจากความยากในการใช้งานดอสทำให้บริษัทไมโครซอฟต์ได้มีการพัฒนาซอฟต์แวร์ที่เรียกว่า Windows ที่มีลักษณะเป็น GUI (Graphic-User Interface) ที่นำรูปแบบของสัญลักษณ์ภาพกราฟิกเข้ามาแทนการป้อนคำสั่งที่ละบรรทัด ซึ่งใกล้เคียงกับแมคอินทอชโอเอส เพื่อให้การใช้งานดอสทำได้ง่ายขึ้น แต่วินโดวส์จะยังไม่ใช่ระบบปฏิบัติการจริงๆ เนื่องจากมันจะทำงานอยู่ภายใต้การควบคุมของดอสอีกที กล่าวคือจะต้องมีการติดตั้งดอสก่อนที่จะติดตั้งระบบปฏิบัติการ Windows และผู้ใช้จะสามารถเรียกใช้คำสั่งต่างๆที่มีอยู่ในดอสได้โดยผ่านทาง Windows ซึ่ง Windows จะง่ายต่อการใช้งานมากกว่าดอส

ระบบปฏิบัติการ windows ใช้หลักการแบ่งงานเป็นส่วนเรียกว่า หน้าต่างงาน (windows) ที่แสดงผลลัพธ์แต่ละโปรแกรม ปัจจุบันมีการผลิตและจำหน่ายหลายรุ่น เช่น Windows XP , Windows Vista, Windows 7 Windows 10 และ Windows 11 เป็นต้น

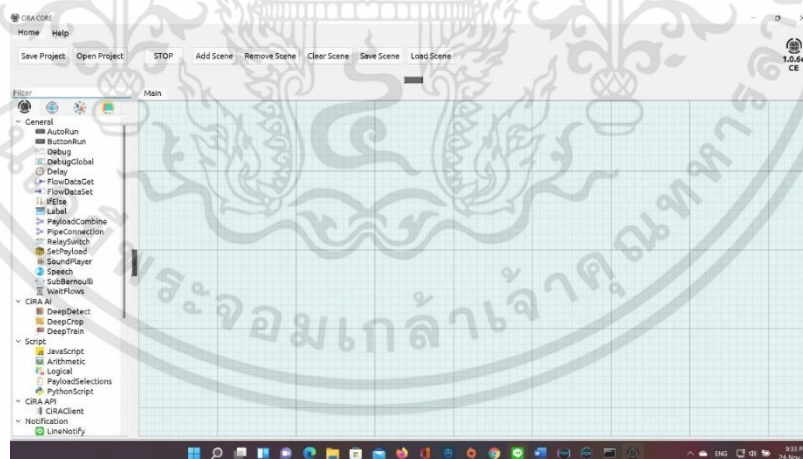
3.2.2 Arduino IDE

Arduino อ่านว่า (อาดฺยโน้ หรือ อา-ดู-อิ-โน้) เป็นแพลตฟอร์มอิเล็กทรอนิกส์แบบโอเพนซอร์สบนพื้นฐานของฮาร์ดแวร์และซอฟต์แวร์ที่ง่ายต่อการใช้งาน สามารถนำไปประยุกต์ใช้งานได้หลายอย่าง เช่น ควบคุมอุปกรณ์อิเล็กทรอนิกส์ขนาดเล็ก อ่านค่าเซ็นเซอร์วัดสภาพแวดล้อมต่างๆ แล้วแสดงค่าที่เซ็นเซอร์สามารถอ่านได้ออกมาทางจอแสดงผลนำไปประยุกต์เข้าเป็นชิ้นงานทางอิเล็กทรอนิกส์ เพื่ออำนวยความสะดวกในการใช้ชีวิตประจำวัน เป็นต้น

ปัจจุบัน Arduino ถือได้ว่าเป็นแพลตฟอร์มที่ได้รับความนิยมสูงจากทั่วโลก เนื่องมาจากจากราคาของตัวบอร์ด Arduino ไม่ค่อยสูงมาก เป็นโอเพนซอร์สทั้งทางด้านฮาร์ดแวร์และซอฟต์แวร์ คอมมิวนิตีและฟอรัมนี้ ในการถามตอบเรื่องเกี่ยวกับการใช้งานร่วมกับอุปกรณ์อิเล็กทรอนิกส์ต่างๆ ตัวอย่างโปรแกรมเบื้องต้นและไลบรารีสำหรับใช้งาน และอื่นๆ

3.2.3 CIRA CORE


แพลตฟอร์มที่ใช้ในกระบวนการในการประมวลผลแบบ Deep Learning สำหรับ Train Waste เช่น กระจก ขวดพลาสติก ก่อถล่ม ขวดแก้ว และใช้งานร่วมกับกล้อง Webcam เพื่อตรวจจับ Waste โดยใช้งานกับกล้อง Webcam ตรวจจับในการรับภาพและส่งไปประมวลผลในตัวโปรแกรม โดยหลักการการทำงานของแพลตฟอร์ม CIRA CORE ใช้เครือข่ายประสาทเทียม



รูปที่ 3.10 หน้าตาการใช้งาน CIRA CORE

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.2.4 กล่องเครื่องมือพื้นฐานใน CiRA CORE ที่ใช้ในการดำเนินการ




รูปที่ 3.11 เครื่องมือการใช้งาน CiRA CORE

โดยหน้าที่ของแต่ละกล่องเครื่องมือ

- 1) AutoRun คือ สำหรับกดเพื่อเริ่มต้นการทำงาน
- 2) Debug คือ แสดงผลและข้อมูลของการทำงาน
- 3) DeepDetect คือ ตรวจสอบการทำงานเชิงลึก
- 4) Deeptrain คือ สอนให้โปรแกรมเกิดการเรียนรู้ โดยป้อนข้อมูล ขยะ (Waste)
- 5) Webcam คือ ดึงข้อมูลรูปภาพจากกล้อง Webcam

3.2.5 CiRA Arduino io


เป็นซอฟต์แวร์ส่วนหนึ่งของ CiRA CORE ที่ใช้สำหรับเชื่อมต่อรับส่งค่ากับ Arduino โดยโปรแกรม CiRA CORE จะส่งค่า 0 กับ 1 มาที่ Arduino โดยใช้ CiRA Arduino io เป็นช่องทางการส่งค่าไปยังบอร์ด Arduino เพื่อสั่งการทำงานส่วนอื่นต่อไป เช่น การสั่งการทำงานของ Servo



รูปที่ 3.12 หน้าต่างการทำงาน CiRA Arduino io

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.2.6 แผนผังการดำเนินการให้คอมพิวเตอร์เรียนรู้ด้วยตนเองโดยใช้ข้อมูลมาสอน

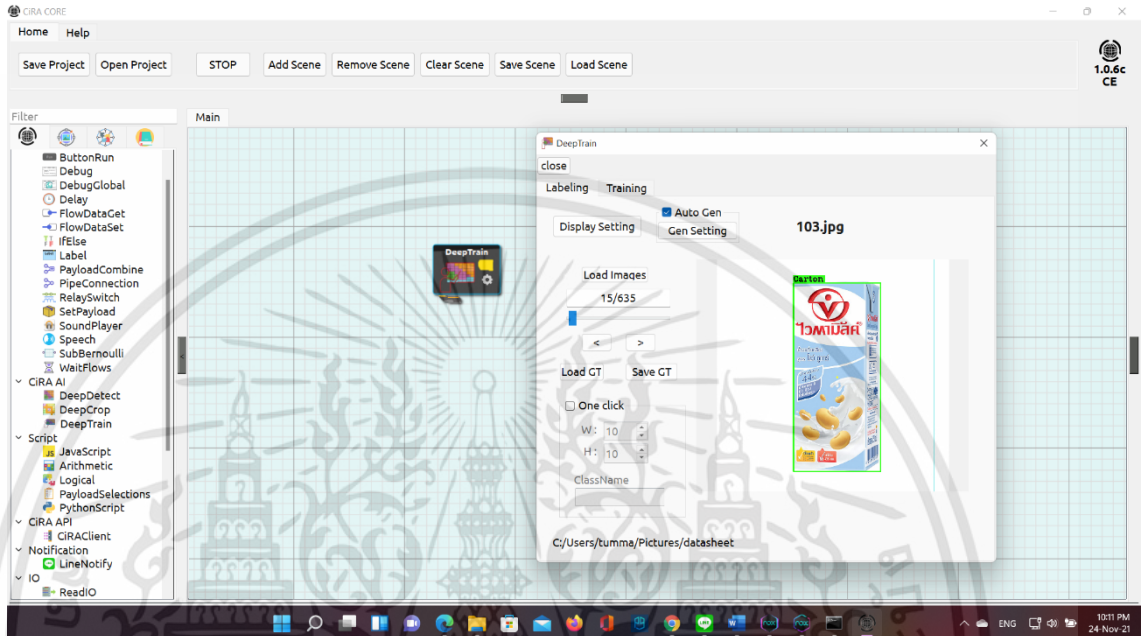


รูปที่ 3.13 แผนผังการเรียนรู้ด้วยตนเองโดยการสอน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


3.3 ขั้นตอนในการสอนให้ระบบคอมพิวเตอร์เรียนรู้ด้วยตนเองโดยใช้ข้อมูลมาสอน

- 1) เลือกกล่องเครื่องมือ Deep Train ออกมาที่ส่วนของ Workspace และ Load Images (นำเข้าไฟล์รูปที่ต้องการ) และทำการ Label



รูปที่ 3.14 ขั้นตอนนำรูปมาทำ Label เพื่อเตรียมการ Train

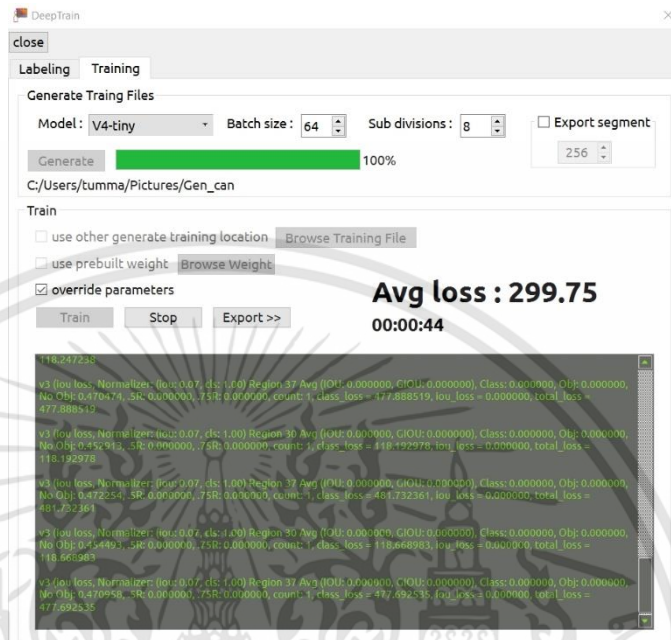
- 2) Generate ข้อมูลรูปภาพ Waste เพื่อทำการ Train ให้ระบบคอมพิวเตอร์ โดยเลือก model เป็น V4- tiny ซึ่งมีความละเอียดสูง หลังจากนั้นกดปุ่ม Train เพื่อให้ระบบคอมพิวเตอร์เกิดการเรียนรู้



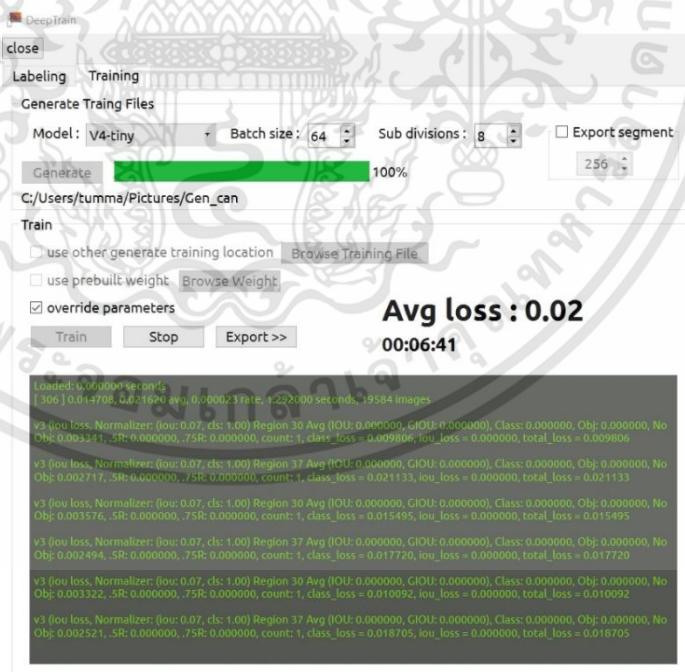
รูปที่ 3.15 ขั้นตอน Generate ไฟล์ Label

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- 3) กด Train ระบบคอมพิวเตอร์ทำการเรียนรู้เชิงลึกจากข้อมูลรูปภาพชุดที่นำเข้าไป เมื่อค่า Avg ใกล้เคียง 0.00 ทำการ Export ไฟล์ Train ออกมา




รูปที่ 3.16 ให้คอมพิวเตอร์ Deep learning ข้อมูลที่ใส่ลงไป



รูปที่ 3.17 Deep learning Avg ใกล้เคียง 0.00

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- 4) หลังจากระบบคอมพิวเตอร์เรียนรู้ข้อมูลรูปภาพ Waste เสร็จเริ่มทำการทดสอบการตรวจจับรูปภาพ Waste โดยกล่องเครื่องมือที่ใช้สำหรับขั้นตอนนี้ คือ AutoRun (ปุ่มเพื่อกดเริ่มต้นการใช้งาน), ImageSlide (แสดงรูปภาพแบบ Slide), DeepDetect (ประมวลผลการตรวจจับ) และ Debug (แสดงผลข้อมูลออกมา)



รูปที่ 3.18 รูปแสดงการตรวจจับ


- 5) ออกแบบโครงสร้างของชิ้นงานที่ใช้สำหรับคัดแยกขยะ 4 ประเภทได้แก่ กระจบง กลุ่มนม ขวดน้ำพลาสติก ขวดแก้วตามลำดับ




รูปที่ 3.19 รูปโครงสร้างชิ้นงาน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- 6) ออกแบบโปรแกรมการทำงานตรวจจับขยะและทำการสั่งการทำงานของ servo motor ให้ทำการหมุนทิศทางการตามที่กำหนดเพื่อคัดแยกขยะ

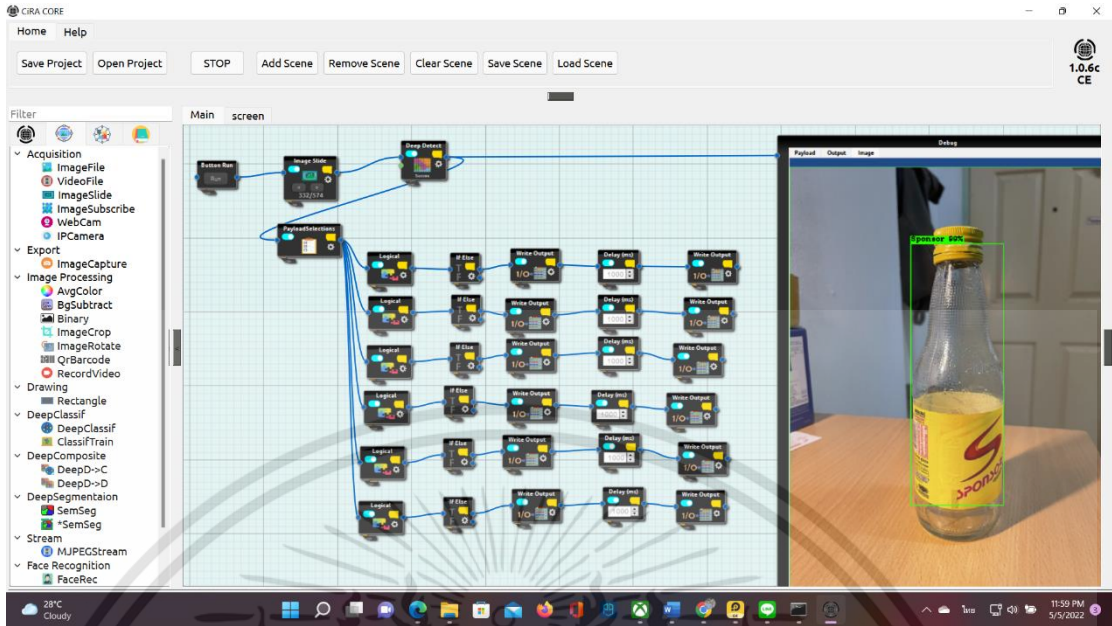


รูปที่ 3.20 ตัวอย่างโปรแกรมการคัดแยกกระป๋อง

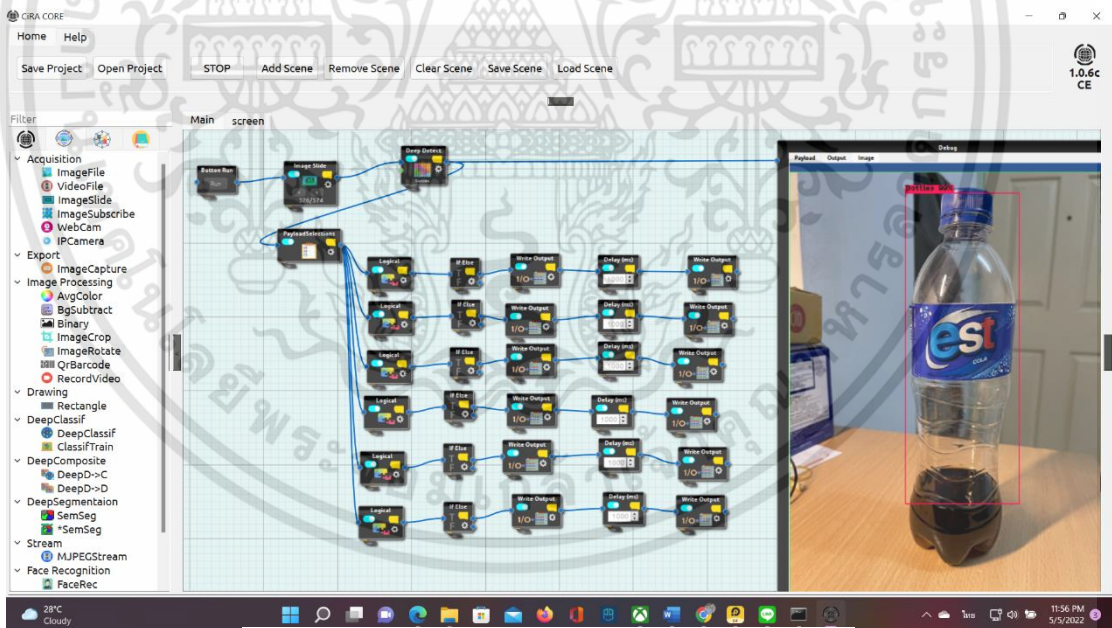


รูปที่ 3.21 ตัวอย่างโปรแกรมการคัดแยกกล่องนม

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 3.22 ตัวอย่างโปรแกรมการคัดแยกขวดสبونเซอร์




รูปที่ 3.23 ตัวอย่างโปรแกรมการคัดแยกขวดพลาสติก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 3.24 ตัวอย่างโปรแกรมการคัดแยกขวด C-vit




รูปที่ 3.25 ตัวอย่างโปรแกรมการคัดแยกขวด Energy drink

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- 7) จัดวางกล้อง Webcam ให้ห่างที่ระยะเท่าเดิมที่ 30 ซม. และเปิด PWM Motor DC Controller เพื่อเริ่มการทำงานและปรับความเร็วสายพานตามที่ต้องการ




รูปที่ 3.26 การทำงานของ servo ของการตรวจจับกระป๋อง




รูปที่ 3.27 การทำงานของ servo ของการตรวจจับกล่องนม

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 3.28 การทำงานของ servo ของการตรวจจับ C - vit




รูปที่ 3.29 การทำงานของ servo ของการตรวจจับ ขวดพลาสติก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.30 การทำงานของ servo ของการตรวจจับกระป๋องผิดรูป



รูปที่ 3.31 การทำงานของ servo ของการตรวจจับกล่องนมผิดรูป

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


บทที่ 4

ผลการดำเนินงาน

4.1 การเก็บข้อมูลรูปภาพเป็น Dataset

ในการเทรนรูปภาพของขยะที่ต้องการตรวจจับของโปรแกรม CiRA CORE จะมีการเก็บข้อมูลรูปภาพเป็นแบบ Dataset เพื่อให้มีรูปภาพมากพอสำหรับการเรียนรู้เชิงลึกที่ตัวโปรแกรม CiRA CORE แล้วมีการเลือกโมเดลให้เหมาะสมกับการใช้งานของผู้พัฒนามากมาย เช่น Model V4 กับ V4-tiny ที่ใช้เวลาการเทรนต่างกันแต่คุณภาพก็ต่างกันด้วย โดยจะมีการเทรน Dataset ทั้งหมด 4 ครั้ง แบ่งเป็นชุดข้อมูล 4 ชั้นตามที่อธิบายในบทที่ 3


4.1.1 กราฟแสดงรูปภาพที่เป็น Dataset สำหรับโปรแกรม CiRA CORE



รูปที่ 4.1 กราฟแสดงจำนวนรูปภาพที่เป็น Dataset สำหรับการทดลองโปรแกรม CiRA CORE

4.1.2 ค่า AVG ของโปรแกรม CiRA CORE ค่า AVG ของโปรแกรม CiRA CORE

เป็นแสดงค่าการเรียนรู้เชิงลึกของโปรแกรม CiRA CORE ว่ามีความแม่นยำในการตรวจจับวัตถุมากแค่ไหน โดยในการเทรนจะได้ค่า AVG มาทั้งหมด 4 ค่าดังนี้



รูปที่ 4.2 กราฟแสดงค่า AVG จากการเรียนรู้เชิงลึกของโปรแกรม CiRA CORE

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.2 การตรวจสอบความถูกต้องของการตรวจจับและคัดแยกถูกประเภท

สำหรับชุดข้อมูลตัวอย่างที่ใช้ทำการตรวจสอบของโปรแกรม CIRA CORE มีทั้งหมด 20 ชุด ข้อมูลโดยจะทำการทดลองทั้งหมด 5 ครั้งเพื่อหาความผิดพลาดโดยชุดตัวอย่าง 20 ชุด แบ่งเป็น 4 ประเภทมีดังนี้

4.2.1 ประเภทกระป๋อง มีทั้งหมด 5 ชั้น

- 1) สิงห์ เลมอนโซดา
- 2) สิงห์ ออเรนโซดา
- 3) แพนด้า
- 4) B – ON วิตามิน B
- 5) โคคาโคล่า

4.2.2 ประเภทกล่องนม มีทั้งหมด 5 ชั้น

- 1) ชังชัง นมถั่วเหลือง
- 2) ยูนิฟ เพรช รสผลไม้ม้วนผักใบเขียว
- 3) นมไทย-เดนมาร์ค
- 4) ดอยคำ
- 5) ไวตามินัลค์

4.2.3 ประเภทขวดพลาสติก มีทั้งหมด 5 ชั้น

- 1) เป๊ปซี่ ขวด 330 มล.
- 2) น้ำวิตามิน ซี
- 3) แพนด้า กลิ่นสตอเบอร์รี่
- 4) กาโตะ
- 5) น้ำดื่ม เซเว่น

4.2.4 ประเภทขวดแก้ว มีทั้งหมด 5 ชั้น

- 1) สปอนเซอร์ รสออริจินอล
- 2) ลิโวิตัน – ดี
- 3) M – 150
- 4) ดับเบิลซี วิตามิน รสส้ม
- 5) C-vit

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4-1 แสดงผลการทดสอบ ครั้งที่ 1 ของชุดข้อมูลตัวอย่างเพื่อหาความผิดพลาด

การทดสอบครั้งที่	ชุดข้อมูล	ตรวจจับในโปรแกรมถูกต้อง	เซอร์วิทันถูกทิศทาง	วัตถุลงในถังถูกชนิด	เปอร์เซ็นต์การทำงาน
1	ประเภทกระป๋อง				
	สิงห์ เลมอนโซดา	✓	✓	✓	100 %
	สิงห์ ออเรนโซดา	✓	✓	✓	100 %
	แฟนต้า	✓	✓	✓	100 %
	B – ON วิตามิน B	✗	✗	✗	0 %
	โคคาโคล่า	✓	✓	✓	100 %
	ประเภทกล่องนม				
	ซังซัง นมถั่วเหลือง	✓	✓	✓	100 %
	ยูนิฟ เฟรช รสผลไม้รวมผักใบเขียว	✓	✓	✓	100 %
	นมไทย-เดนมาร์ค	✗	✗	✗	0 %
	ดอยคำ	✓	✓	✓	100 %
	ไวตามินล์	✓	✓	✓	100 %
	ประเภทขวดพลาสติก				
	เป๊ปซี่ ขนาด 330 มล.	✓	✓	✓	100 %
	น้ำวิตามิน ซี	✓	✓	✓	100 %
	แฟนต้า กลิ่นสตอเบอร์รี่	✓	✓	✓	100 %
	กาโตะ	✓	✓	✓	100 %
	น้ำดื่ม เซเว่น	✓	✓	✓	100 %
	ประเภทขวดแก้ว				
	สปอนเซอร์ รสออริจินอล	✓	✓	✓	100 %
	ลิโพวิตัน - ดี	✓	✓	✓	100 %
	M – 150	✓	✓	✓	100 %
	ดับเบิลซี วิตามิน รสส้ม	✓	✓	✓	100 %
	C-vit รสส้ม	✓	✓	✓	100 %

จากตารางการทดสอบ ตารางที่ 4.1 จะเห็นว่า มี 2 วัตถุที่ไม่สามารถตรวจจับและทำงานได้ตรงเป้าหมายได้แก่ B – ON วิตามิน B และ นมไทย-เดนมาร์ค

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4-2 แสดงผลการทดสอบ ครั้งที่ 2 ของชุดข้อมูลตัวอย่างเพื่อหาความผิดพลาด

การทดสอบครั้งที่	ชุดข้อมูล	ตรวจจับในโปรแกรมถูกต้อง	เซอร์วิทันถูกทิศทาง	วัตถุลงในถังถูกชนิด	เปอร์เซ็นต์การทำงาน
2	ประเภทกระป๋อง				
	สิงห์ เลมอนโซดา	✓	✓	✓	100 %
	สิงห์ ออเรนโซดา	✓	✓	✓	100 %
	แฟนต้า	✓	✓	✓	100 %
	B – ON วิตามิน B	✗	✗	✗	0 %
	โคคาโคล่า	✓	✓	✓	100 %
	ประเภทกล่องนม				
	ซังซัง นมถั่วเหลือง	✓	✓	✓	100 %
	ยูนิฟ เฟรช รสผลไม้รวมผักใบเขียว	✓	✓	✓	100 %
	นมไทย-เดนมาร์ก	✗	✗	✗	0 %
	ดอยคำ	✓	✓	✓	100 %
	ไวตามินัลค์	✓	✓	✓	100 %
	ประเภทขวดพลาสติก				
	เป๊ปซี่ ขนาด 330 มล.	✓	✓	✓	100 %
	น้ำวิตามิน ซี	✓	✓	✓	100 %
	แฟนต้า กลิ่นสตอเบอร์รี่	✓	✓	✓	100 %
	กาโตะ	✓	✓	✓	100 %
	น้ำดื่ม เซเว่น	✓	✓	✓	100 %
	ประเภทขวดแก้ว				
	สปอนเซอร์ รสออริจินอล	✓	✓	✓	100 %
	ลิโพวิตัน - ดี	✓	✓	✓	100 %
	M – 150	✓	✓	✓	100 %
	ดับเบิลซี วิตามิน รสส้ม	✓	✓	✓	100 %
	C-vit รสส้ม	✓	✓	✓	100 %

จากตารางการทดสอบ ตารางที่ 4.1 จะเห็นว่า มี 2 วัตถุที่ไม่สามารถตรวจจับและทำงานได้ตรงเป้าหมายได้แก่ B – ON วิตามิน B และ นมไทย-เดนมาร์ก

ตารางที่ 4-3 แสดงผลการทดสอบ ครั้งที่ 3 ของชุดข้อมูลตัวอย่างเพื่อหาความผิดพลาด

การทดสอบครั้งที่	ชุดข้อมูล	ตรวจจับในโปรแกรมถูกต้อง	เซอร์โวหันถูกทิศทาง	วัตถุลงในถังถูกชนิด	เปอร์เซ็นต์การทำงาน
3	ประเภทกระบอง				
	สิงห์ เลมอนโซดา	✓	✓	✓	100 %
	สิงห์ ออเรนโซดา	✓	✓	✓	100 %
	แฟนต้า	✓	✓	✓	100 %
	B – ON วิตามิน B	✓	✓	✓	100 %
	โคคาโคล่า	✓	✓	✓	100 %
	ประเภทกล่องนม				
	ซังซัง นมถั่วเหลือง	✓	✓	✓	100 %
	ยูนิฟ เฟรช รสผลไม้รวมผักใบเขียว	✓	✓	✓	100 %
	นมไทย-เดนมาร์ก	✓	✓	✓	100 %
	ดอยคำ	✓	✓	✓	100 %
	ไวตามินล์	✓	✓	✓	100 %
	ประเภทขวดพลาสติก				
	เป๊ปซี่ ขนาด 330 มล.	✓	✓	✗	66.67 %
	น้ำวิตามิน ซี	✓	✓	✓	100 %
	แฟนต้า กลิ่นสตอเบอร์รี่	✓	✓	✓	100 %
	กาโตะ	✓	✓	✓	100 %
	น้ำดื่ม เซเว่น	✓	✓	✓	100 %
	ประเภทขวดแก้ว				
	สปอนเซอร์ รสออริจินอล	✓	✓	✓	100 %
	ลิโพวิตัน - ดี	✓	✓	✓	100 %
	M – 150	✓	✓	✓	100 %
	ดับเบิลซี วิตามิน รสส้ม	✓	✓	✓	100 %
C-vit รสส้ม	✓	✓	✓	100 %	

จากตารางการทดสอบ ตารางที่ 4.3 จะเห็นว่า เป๊ปซี่ ขนาด 330 มล. สามารถตรวจจับได้และ Servo หันถูกทิศทางแต่ไม่ลงถัง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4-4 แสดงผลการทดสอบ ครั้งที่ 4 ของชุดข้อมูลตัวอย่างเพื่อหาความผิดพลาด

การทดสอบครั้งที่	ชุดข้อมูล	ตรวจจับใน โปรแกรม ถูกต้อง	เซอร์โวนัน ถูกทิศทาง	วัตถุลงในถัง ถูกชนิด	เปอร์เซ็นต์ การทำงาน
4	ประเภทกระป๋อง				
	สิงห์ เลมอนโซดา	✓	✓	✓	100 %
	สิงห์ ออเรนโซดา	✓	✓	✓	100 %
	แฟนต้า	✓	✓	✓	100 %
	B - ON วิตามิน B	✓	✓	✓	100 %
	โคคาโคล่า	✓	✓	✓	100 %
	ประเภทกล่องนม				
	ซังซัง นมถั่วเหลือง	✓	✓	✓	100 %
	ยูนิฟ เฟรช รสผลไม้รวมผักใบเขียว	✓	✓	✓	100 %
	นมไทย-เดนมาร์ค	✓	✓	✓	100 %
	ดอยคำ	✓	✓	✓	100 %
	ไวตามิ้ลค์	✓	✓	✓	100 %
	ประเภทขวดพลาสติก				
	เป๊ปซี่ ขนาด 330 มล.	✓	✓	✓	100 %
	น้ำวิตามิน ซี	✓	✓	✓	100 %
	แฟนต้า กลิ่นสตอเบอร์รี่	✓	✓	✓	100 %
	กาโตะ	✓	✓	✓	100 %
	น้ำดื่ม เซเว่น	✓	✓	✓	100 %
	ประเภทขวดแก้ว				
	สปอนเซอร์ รสออริจินอล	✓	✓	✓	100 %
	ลิโพวิตัน - ดี	✓	✓	✓	100 %
	M - 150	✓	✓	✓	100 %
	ดับเบิลซี วิตามิน รสส้ม	✓	✓	✓	100 %
	C-vit รสส้ม	✓	✓	✓	100 %

จากตารางการทดสอบ ตารางที่ 4.4 จะเห็นว่าผลการทดลองนี้สามารถตรวจจับและทำงานได้ทุกชุดข้อมูล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4-5 แสดงผลการทดสอบ ครั้งที่ 5 ของชุดข้อมูลตัวอย่างเพื่อหาความผิดพลาด

การทดสอบครั้งที่	ชุดข้อมูล	ตรวจจับใน โปรแกรม ถูกต้อง	เซอร์ไวทัน ถูกทิศทาง	วัตถุลงในถัง ถูกชนิด	เปอร์เซ็นต์ การทำงาน
5	ประเภทกระป๋อง				
	สิงห์ เลมอนโซดา	✓	✓	✓	100 %
	สิงห์ ออเรนโซดา	✓	✓	✓	100 %
	แฟนต้า	✓	✓	✓	100 %
	B – ON วิตามิน B	✓	✓	✓	100 %
	โคคาโคล่า	✓	✓	✓	100 %
	ประเภทกล่องนม				
	ซังซัง นมถั่วเหลือง	✓	✓	✓	100 %
	ยูนิฟ เฟรช รสผลไม้รวมผักใบเขียว	✓	✓	✓	100 %
	นมไทย-เดนมาร์ค	✓	✓	✓	100 %
	ดอยคำ	✓	✓	✓	100 %
	ไวตามินัลส์	✓	✓	✓	100 %
	ประเภทขวดพลาสติก				
	เป๊ปซี่ ขนาด 330 มล.	✓	✓	✓	100 %
	น้ำวิตามิน ซี	✓	✓	✓	100 %
	แฟนต้า กลิ่นสตอเบอร์รี่	✓	✓	✓	100 %
	กาโตะ	✗	✗	✗	0 %
	น้ำดื่ม เซเว่น	✓	✓	✓	100 %
	ประเภทขวดแก้ว				
	สปอนเซอร์ รสออริจินอล	✓	✓	✓	100 %
	ลิโพวิตัน - ดี	✓	✓	✓	100 %
	M – 150	✓	✓	✓	100 %
	ดับเบิลซี วิตามิน รสส้ม	✓	✓	✓	100 %
	C-vit รสส้ม	✓	✓	✓	100 %

จากตารางการทดสอบ ตารางที่ 4.5 จะเห็นว่ามี 1 วัตถุที่ไม่สามารถตรวจจับและทำงานได้ตรงเป้าหมายได้แก่ ขวดกาโตะ

ตารางที่ 4-6 แสดงสรุปผลการทดสอบ 5 ครั้งของชุดข้อมูลตัวอย่างเพื่อหาความผิดพลาด

ชุดข้อมูล	ครั้งที่ 1	ครั้งที่ 2	ครั้งที่ 3	ครั้งที่ 4	ครั้งที่ 5	% ความถูกต้องโดยเฉลี่ย
1) ประเภทกระป๋อง						
สิงห์ เลมอนโซดา	100 %	100 %	100 %	100 %	100 %	100 %
สิงห์ ออเรนโซดา	100 %	100 %	100 %	100 %	100 %	100 %
แฟนต้า	100 %	100 %	100 %	100 %	100 %	100 %
B - ON วิตามิน B	0 %	0 %	100 %	100 %	100 %	60 %
โคคาโคล่า	100 %	100 %	100 %	100 %	100 %	100 %
2) ประเภทกล่องนม						
ซังซัง นมถั่วเหลือง	100 %	100 %	100 %	100 %	100 %	100 %
ยูนิฟ เฟรช รสผลไม้วรรณพักใบเขียว	100 %	100 %	100 %	100 %	100 %	100 %
นมไทย-เดนมาร์ค	0 %	0 %	100 %	100 %	100 %	60 %
ดอยคำ	100 %	100 %	100 %	100 %	100 %	100 %
ไวตามิลค์	100 %	100 %	100 %	100 %	100 %	100 %
3) ประเภทขวดพลาสติก						
เป๊ปซี่ ขวด 330 มล.	100 %	100 %	66.67 %	100 %	100 %	93.33 %
น้ำวิตามิน ซี	100 %	100 %	100 %	100 %	100 %	100 %
แฟนต้า กลิ่นสตอเบอร์รี่	100 %	100 %	100 %	100 %	100 %	100 %
กาโตะ	100 %	100 %	100 %	100 %	0 %	80 %
น้ำดื่ม เซเว่น	100 %	100 %	100 %	100 %	100 %	100 %
4) ประเภทขวดแก้ว						
สปอนเซอร์ รสออริจินอล	100 %	100 %	100 %	100 %	100 %	100 %
ลิโพวิตัน - ดี	100 %	100 %	100 %	100 %	100 %	100 %
M - 150	100 %	100 %	100 %	100 %	100 %	100 %
ดับเบิลซี วิตามิน รสส้ม	100 %	100 %	100 %	100 %	100 %	100 %
C-vit รสส้ม	100 %	100 %	100 %	100 %	100 %	100 %
จำนวนชุดข้อมูลที่ถูกต้อง 100 %	18	18	19	20	19	

จากตารางที่ 4.6 แสดงสรุปผลการทดลอง 5 ครั้ง

การทดลองครั้งที่ 1 และ 2 มีจำนวนชุดข้อมูลที่ถูกต้อง 100 % ทั้งหมด 18 ตัวอย่าง ชุดข้อมูลที่ต่ำกว่า 100 % ได้แก่ กระป๋อง B-ON วิตามินบี และกล่องนมไทย-เดนมาร์คที่มีเปอร์เซ็นต์การทำงานที่ 0 % การทดลองครั้งที่ 3 มีจำนวนชุดข้อมูลที่ถูกต้อง 100 % ทั้งหมด 19 ตัวอย่าง ชุดข้อมูลที่ต่ำกว่า 100 % ได้แก่ เป๊ปซี่ ขวด 330 มล. มีเปอร์เซ็นต์การทำงานที่ 97.67 %

การทดลองครั้งที่ 4 มีจำนวนชุดข้อมูลที่ถูกต้อง 100 % ทั้งหมด 20 ตัวอย่าง ไม่พบชุดข้อมูลที่ต่ำกว่า 100 %

การทดลองครั้งที่ 5 มีจำนวนชุดข้อมูลที่ถูกต้อง 100 % ทั้งหมด 19 ตัวอย่าง ชุดข้อมูลที่ต่ำกว่า 100 % ได้แก่ ขวดน้ำกาโตะ มีเปอร์เซ็นต์การทำงานที่ 0 %

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้คัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

พบว่าชุดข้อมูลทั้ง 20 ตัวอย่างมีค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยที่ 100 % อยู่ 16 ตัวอย่างและ 4 ตัวอย่างที่เหลือได้แก่ กระจบอง B-ON วิตามินบี และกล่องนมไทย-เดนมาร์ค มีค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยที่ 60 % ขวดน้ำกาโตะ มีค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยที่ 80 % และเป๊ปซี่ ขวด 330 มล. มีค่าเปอร์เซ็นต์ความถูกต้องเฉลี่ยที่ 93.33 %

4.3 สรุปผลการทดลอง

จากการทดลองการตรวจจับวัตถุที่เคลื่อนมาตามสายพานโดยใช้โปรแกรม CiRA CORE และ กล้องเว็บแคมในการตรวจจับ ซึ่งวัตถุที่ต้องการตรวจจับและแยก ได้แก่ กล่องนม กระจบอง ขวดน้ำพลาสติก และขวดแก้ว ซึ่งการทดลองจะถูกแบ่งเป็น 2 ส่วน คือ การตรวจจับวัตถุที่เคลื่อนมาตามสายพานและสามารถแยกชนิดของวัตถุนั้นว่าเป็นชนิดไหน และนำข้อมูลนั้นมาส่งแบบดิจิทัลเพื่อควบคุมเซอร์โวมอเตอร์เพื่อหันทิศทางแกนเลื่อนไปตามกล่องที่ต้องการคัดแยกได้ถูกต้อง

จากตารางผลการทดลองทั้งหมด 5 ตารางข้างต้นจะเห็นว่า มีบางวัตถุ บางครั้ง ตรวจจับและทำงานได้ตามเป้าหมายแต่บางครั้งไม่สามารถตรวจจับและทำงานได้ตรงตามเป้าหมาย เช่น B - ON วิตามิน B ขวดน้ำกาโตะและ นมไทย-เดนมาร์ค ซึ่งในฐานข้อมูลการ Training ไม่ได้มีข้อมูลดังนั้น บางครั้งจึงไม่สามารถตรวจจับได้แม่นยำพอที่จะทำการตรวจจับได้เพราะ เราได้ตั้งค่า Threshold ไว้ที่ 85% ทำให้ไม่สามารถตรวจจับได้ในบางครั้ง

ในขวดเป๊ปซี่จากตารางที่ 3 นั้นสามารถตรวจจับและ Servo Motor ทำงานถูกแล้วแต่ลงผิดถึงเกิดจากตอนหล่นลงกรวยคัดแยกแล้วเกิดการเต็งของขวดทำให้ไปตกลงถึงข้างๆ

บทที่ 5

สรุปผลปัญหาและข้อเสนอแนะ

5.1 สรุปผลการดำเนินงาน

จากการทดสอบการเทรนข้อมูลรูปภาพของขยะ 4 ประเภท ด้วยโปรแกรม CiRA CORE ซึ่งเป็นโปรแกรมการตรวจจับรูปภาพโดยใช้เทคนิค Deep learning พบว่าเมื่อเรานำเข้าข้อมูลรูปภาพที่มีปริมาณมากไปทำการเรียนรู้ในโปรแกรมจะต้องใช้ระยะเวลาที่นานขึ้นอยู่กับหลายปัจจัย เช่น ประสิทธิภาพของคอมพิวเตอร์โมเดลที่ใช้ในการเทรน และจำนวนข้อมูลที่นำมาเทรนยิ่งมากจะใช้เวลานาน โครงการนี้ใช้เวลา 9-12 ชม.ต่อ 500+ รูปเพื่อให้ได้ค่า AVG เข้าใกล้ 0.00 มากที่สุด เพราะค่า AVG คือค่าความแม่นยำของการนำไปตรวจจับรูปภาพ ซึ่งจากการทำการทดลองได้ค่า AVG ประมาณ 0.04 โดยผลของการตรวจจับรูปภาพ และการทำงานของ servo โดยมีการตั้งค่าการวางตัวกล้องไว้ห่างจาก สายพานที่ 30 ซม. และตั้งค่า Threshold การตรวจจับข้อมูลที่ 85 % พบว่าถ้าตรวจจับวัตถุได้ถูกต้อง การทำงาน servo ก็จะถูกต้องตามไปด้วย แต่พบว่าจะมีบางตัวอย่างการทดลองที่ทำการตรวจจับได้บ้างและไม่ได้ ทำให้เกิดความผิดพลาดเนื่องจากวัตถุนั้นยังไม่เคยผ่านการเทรน แต่มีบางส่วนที่คล้ายกับวัตถุบางชนิดที่มีพื้นฐานข้อมูลทำได้ตรวจจับได้ในบางครั้ง

5.2 ข้อเสนอแนะ

เนื่องจากข้อมูลของขยะแต่ละประเภทนั้นมีเยอะมากหลากหลายแบรนด์ หลากหลายรูปร่าง-รูปทรงทำให้การจะทำให้มีประสิทธิภาพมากๆ จะต้องใช้ตัวอย่างข้อมูลที่มากและใช้เวลานานเพื่อรองรับการตรวจจับให้หลากหลายมากขึ้น และการจะทำงานได้นั้นยังมีข้อจำกัดที่ต้องเชื่อมต่อกับคอมพิวเตอร์ตลอดอีกด้วย แต่เราสามารถพัฒนาเพื่อให้ทำงานร่วมกันแบบออนไลน์โดยเชื่อมต่อกับ Server โดยใช้ Protocol MQTT ซึ่งได้มีการรองรับในโปรแกรม CiRA CORE เพื่อส่งค่าและสั่งการทำงานต่างผ่านระบบ Server โดยไม่ต้องเชื่อมต่อ กับ Computer ตลอดเวลา

บรรณานุกรม

- [1] “สถานการณ์ปัญหาขยะในประเทศไทย”, 6 กรกฎาคม 2559 , [Online]
Available: <https://www.schoolofchangemakers.com/knowledge/16656/>
- [2] Nick Babich, “What is Computer Vision & How Does it Work?”, 07/07/2022
[Online] Available: <https://xd.adobe.com/ideas/principles/emerging-technology/what-is-computer-vision-how-does-it-work/>
- [3] SAS Institute Inc. 2564, “ประวัติและความเป็นมาของเทคโนโลยี computer vision”
[Online]. Available: https://www.sas.com/th_th/insights/analytics/computer-vision.html
- [4] Nobuyoshi Terashima, Intelligent Communication Systems, “ Computer Vision” ,2002 ,[Online]Available:<https://www.sciencedirect.com/topics/computer-science/computer-vision>
- [5] IBM Cloud Education, “What is Machine Learning?” ,15/07/2020 ,[Online]
Available: <https://www.ibm.com/cloud/learn/machine-learning>
- [6] “What is Supervised Learning and its different types?” , 25/11/2020
[Online] Available: <https://www.edureka.co/blog/supervised-learning/>
- [7] IBM Cloud Education, “What is Supervised Learning?” ,19/08/2020 ,[Online]
Available: <https://www.ibm.com/cloud/learn/machine-learning>
- [8] IBM Cloud Education, “What is Deep Learning?” ,01/05/2020 ,[Online]
Available: <https://www.ibm.com/cloud/learn/machine-learning>
- [9] Matworks.2021, “What Is Deep Learning? | How It Works, Techniques & Applications?” ,[Online],Available:<https://www.mathworks.com/discovery/deep-learning.html>
- [10] IBM Cloud Education, “Convolutional Neural Networks” ,01/05/2020 ,[Online]
Available: <https://www.ibm.com/cloud/learn/convolutional-neural-networks>
- [11] IBM Cloud Education, “Recurrent Neural Networks” ,01/05/2020 ,[Online]
Available: <https://www.ibm.com/cloud/learn/recurrent-neural-networks>
- [12] Zhi-Feng Xu , Rui-Sheng Jia , Yan-Bo Liu, Chao-Yue Zhao “Fast Method of Detecting Tomatoes in a Complex Scene for Picking Robots” , ResearchGate , [Online]
Available:https://www.researchgate.net/publication/340017457_Fast_Method_of_Detecting_Tomatoes_in_a_Complex_Scene_for_Picking_Robots

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- [13] ปราโมทย์ ปัญญาโต, “การสร้างระบบตรวจจับบุคคลแบบเวลาจริงราคาประหยัดบน Raspberry Pi โดยประยุกต์อัลกอริทึม Tiny YOLOV3” , 2019 ,บัณฑิตศึกษา สาขาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีมหานคร
- [14] รัฐพงษ์ นันทาแพร์, “การเรียนรู้เชิงลึกโดยโครงข่ายประสาทเทียมคอนโวลูชันสำหรับกำหนดขอบเขตอัตโนมัติบนอวัยวะที่มีความเสี่ยงของมะเร็งศีรษะและลำคอ”, วิทยานิพนธ์เสนอบัณฑิตวิทยาลัย มหาวิทยาลัยนเรศวรเพื่อเป็นส่วนหนึ่งของการศึกษา หลักสูตรวิทยาศาสตร์มหาบัณฑิตสาขาวิชาฟิสิกส์การแพทย์ปีการศึกษา 2563
- [15] Surapong Kanoktipsatharporn , “Normalization คืออะไร” , 29/09/2019 , [Online] Available: <https://www.bualabs.com/archives/2100/what-is-normalization-feature-scaling-rescaling-normalization-standardization-feedforward-train-machine-learning-preprocessing-ep-2/>
- [16] ผศ.ดร.นวกัฑรา หนูนาคและ ศาสตราจารย์เกียรติคุณ ดร.นิธิยา รัตนานนท์ , “Threshold” , 2555, [Online] Available: <https://www.foodnetworksolution.com/wiki/word/1073/threshold>
- [17] Fary Host , “Threshold OpenCV คืออะไร” , 21/01/2018 , [Online] Available: <https://medium.com/@toshyrat/threshold-opencv>

ภาคผนวก

ค่าตาราง และ Code การทำงาน

ก.1 Code เชื่อมต่อระหว่าง CiRA CORE กับ บอร์ด Arduino

```
Project1
#include "StringSplitter.h"
#include <Servo.h>
Servo myservo; //ประกาศตัวแปรแทน Servo
#define D2 2
#define D3 3
#define D4 4
#define D5 5
int analog_size = 6;
int digital_size = 14;
int incomingByte = 0;

void setup() {
  Serial.begin(9600);
  myservo.attach(9); // กำหนดขา 9 คาบคุม Servo

  for(int i = 2; i < digital_size ; i++){
    pinMode(i, INPUT);
  }
  Serial.println("ready");
}
```

รูปที่ ก. 1 Code การตั้งค่าตัวแปรและนำเข้า Library

```
Project1
void loop() {
  if(digitalRead(D2)==HIGH)
  {myservo.write(0); // สั่งให้ Servo หมุนไปองศาที่ 0

  }else if (digitalRead(D3)==HIGH)
  {
  myservo.write(55); // สั่งให้ Servo หมุนไปองศาที่ 0

  }else if (digitalRead(D4)==HIGH)
  {
  myservo.write(84); // สั่งให้ Servo หมุนไปองศาที่ 0

  }else if (digitalRead(D5)==HIGH)
  {
  myservo.write(145); // สั่งให้ Servo หมุนไปองศาที่ 0

  }
  print();
}
```

รูปที่ ก. 2 Code การทำงานวนซ้ำของโปรแกรม servo

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

Project1
}

void print() {

    if (Serial.available() > 0) {
        String read_string = Serial.readStringUntil('\n');
        //Serial.println(read_string);
        command(read_string);
        delay(10);
    } else {
        Serial.print(String(analogRead(0), DEC));
        Serial.print( "," + String(analogRead(1), DEC));
        Serial.print( "," + String(analogRead(2), DEC));
        Serial.print( "," + String(analogRead(3), DEC));
        Serial.print( "," + String(analogRead(4), DEC));
        Serial.print( "," + String(analogRead(5), DEC));
        Serial.println( "," + String(encode_digital(), DEC));
        delay(100);
    }
}
}

```

รูปที่ ก. 3 Code การทำงานการส่งข้อมูลแบบ Analog

```

Project1

//encode digital pin
int encode_digital() {
    String str;
    for(int i = 0; i < digital_size ; i++){
        str += String(digitalRead(i));
    }
    return strtoul(str.c_str(), NULL, 2);
}

void command(String str) {

    //update uno digital pin mode
    if(str.indexOf("0:") == 0) {

        StringSplitter *splt_ = new StringSplitter(str, ':', 10);
        int i = splt_ ->getItemAtIndex(1).toInt();
        String _digital_mode_binary = String(i, BIN);
        while(_digital_mode_binary.length() < digital_size) {
            _digital_mode_binary = "0" + _digital_mode_binary;
        }
        for(int j = 2; j < _digital_mode_binary.length(); j++){
            change_digital_pinmode(j, _digital_mode_binary[digital_size - 1 - j]);
        }
        delete splt_;
        return;
    }
}

```

รูปที่ ก. 4 Code การทำงานการเข้ารหัส Digital

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

//digital out put write
else if(str.indexOf("1:") == 0){

StringSplitter *spl_ = new StringSplitter(str, ':', 10);
if(spl_>getItemCount() < 2) { delete spl_; return; }
String digital_pins = spl_>getItemAtIndex(1);
delete spl_;
StringSplitter *spl1_ = new StringSplitter(digital_pins, ',', 20);

for(int i = 0; i < spl1_>getItemCount(); i++){
StringSplitter *spl2_ = new StringSplitter(spl1_>getItemAtIndex(i), '=', 2);
if(spl2_>getItemCount() != 2) { delete spl2_; continue; }
int pin = spl2_>getItemAtIndex(0).toInt();
int val = spl2_>getItemAtIndex(1).toInt();

if(val == 0){
digitalWrite(pin, LOW);
//Serial.println("pin" + String(pin));
//Serial.println("val" + String(val));
}
else{
digitalWrite(pin, HIGH);
//Serial.println("pin" + String(pin));
//Serial.println("val" + String(val));
}
delete spl2_;
}
delete spl1_;
}
}

void change_digital_pinmode(int i, char ch){
if(ch == 'I') pinMode(i, INPUT);
else {
pinMode(i, OUTPUT);
digitalWrite(i, LOW);
}
}
}

```

รูปที่ ก. 5 Code การทำงาน Digital Output

ก.2 ตารางผลการทดลองการตรวจจ็ับรูปภาพของขยะที่คัดแยก 4 ประเภท

ครั้งที่	ค่า AVG	จำนวนรูปภาพที่เป็น Dataset (รูป)	จำนวนรูปภาพที่ตรวจจ็ับถูกต้อง (รูป)	จำนวนรูปภาพที่ตรวจจ็ับผิด (รูป)	จำนวนรูปภาพที่ไม่ตรวจจ็ับ (รูป)
1	0.08	352	18	1	1
2	0.06	467	19	0	1
3	0.05	517	20	0	0
4	0.04	547	20	0	0

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ประวัติผู้เขียน



ชื่อ - นามสกุล ธรรมนุญ จำปาหอม
 ที่อยู่ 55/1 หมู่ 2 ตำบล หมอนนาง อำเภอ พนัสนิคม จังหวัด ชลบุรี
 เบอร์โทรศัพท์ 095-779-6615
 E-mail 61010483@kmitl.com
 ประวัติการศึกษา ระดับมัธยมศึกษาตอนปลาย โรงเรียนพนัสพิทยาคาร จังหวัด ชลบุรี
 ประวัติการฝึกงาน Ansell (Thailand) Co Ltd. 74 ซอย ฉลองกรุง แขวง ลำปลาทิว
 เขตลาดกระบัง กรุงเทพมหานคร 10520 โทรศัพท์: 02 326 0660

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ประวัติผู้เขียน(ต่อ)



ชื่อ - นามสกุล ชีร์วิชญ์ สิทธิอาษา
 ที่อยู่ 203 หมู่ 8 ตำบล สันทราษฎร์ อำเภอบึงสามพัน จังหวัด บึงสามพัน
 เบอร์โทรศัพท์ 099-136-0697
 E-mail 61010515@kmitl.ac.th
 ประวัติการศึกษา ระดับมัธยมศึกษาตอนปลาย โรงเรียนสามัคคีวิทยาคม จังหวัด เชียงราย
 ประวัติการฝึกงาน Ansell (Thailand) Co Ltd. 74 ซอย ฉลองกรุง แขวง ลำปลาทิว
 เขตลาดกระบัง กรุงเทพมหานคร 10520 โทรศัพท์: 02 326 0660

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ประวัติผู้เขียน(ต่อ)



ชื่อ - นามสกุล พิชัยยุทธ แสงแก้ว
 ที่อยู่ 147 หมู่ 5 ตำบล คลองปาง อำเภอรัญญา จังหวัด ตรัง
 เบอร์โทรศัพท์ 095-083-5256
 E-mail 61010746@kmitl.ac.th
 ประวัติการศึกษา ระดับมัธยมศึกษาตอนปลาย โรงเรียนบูรณะรำลึก จังหวัด ตรัง
 ประวัติการฝึกงาน Ansell (Thailand) Co Ltd. 74 ซอย ฉลองกรุง แขวง ลำปลาทิว
 เขตลาดกระบัง กรุงเทพมหานคร 10520 โทรศัพท์: 02 326 0660

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้