



การประชุมวิชาการนำเสนอผลงานวิจัยระดับชาติและนานาชาติ ครั้งที่ 14
 "Global Goals, Local Actions: Looking Back and Moving Forward 2021"
 วันพุธที่ 18 สิงหาคม 2564

การวิเคราะห์ปัจจัยด้านความซับซ้อนของตัวแบบที่มีผลต่อความทนทานของโครงข่ายประสาทเทียม
 แบบสังวัตนาการต่อฉลากรบกวนแบบสุ่ม
 Analysis of Model Complexity Factors Affecting the Robustness of Convolutional
 Neural Network towards Random Label Noise

พิชชยานาฏ รีรักษ์

Pichayanart_r@cmu.ac.th

จักรเมธ บุตรกระจำง

Jakramate.b@cmu.ac.th

ภาควิชาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์ มหาวิทยาลัยเชียงใหม่

บทคัดย่อ

การวิจัยครั้งนี้มีวัตถุประสงค์เพื่อวิเคราะห์ปัจจัยที่มีผลต่อความทนทานของโครงข่ายประสาทเทียมแบบสังวัตนาการต่อฉลากรบกวนแบบสุ่ม โดยผู้วิจัยทำการออกแบบและพัฒนาโปรแกรมด้วยภาษา Python บนพื้นฐานไลบรารี Keras และ Tensorflow เพื่อศึกษาผลกระทบของฉลากรบกวน และวัดค่าความแม่นยำของโมเดลบนชุดข้อมูลทดสอบที่เรียนรู้จากชุดฝึกหัดที่มีฉลากรบกวนหลายระดับ ตั้งแต่ 0% ถึง 40% ในการศึกษาโมเดล CNN จะทำการเรียนรู้จากชุดฝึกหัดซึ่งประกอบด้วยข้อมูลรูปภาพทั้งหมด 15,000 ภาพในหมวดยานพาหนะ แบ่งเป็น 5 ชั้นข้อมูล ได้แก่ รถจักรยาน, รถบัส, รถมอเตอร์ไซด์, รถไฟ, รถยนต์ ผลการทดลองพบว่าฉลากรบกวนมีผลต่อการเรียนรู้ของโครงข่ายประสาทเทียมแบบสังวัตนาการจริง ทั้งนี้ผู้วิจัยพบว่าเทคนิค Dropout และ Regularization สามารถนำมาประยุกต์ใช้เพื่อให้โมเดลสามารถเรียนรู้และทนทานต่อฉลากรบกวนได้มากขึ้น

คำสำคัญ โครงข่ายประสาทเทียมแบบสังวัตนาการ, ฉลากรบกวนแบบสุ่ม, ความซับซ้อนของตัวแบบ

Abstract

The objective of this research is to analyze the factors affecting the robustness of the convolutional neural network (CNN) towards random labelling errors. A Python program based on Keras and Tensorflow deep learning libraries was designed and developed for studying the effects of label noise by measuring the accuracy of the CNN model trained on various degree of label noises. The CNN model was trained on 15,000 images of common vehicles divided into 5 classes, including bicycle, bus, motorbike, train and car with random label noise ranging from 0% to 40%. The results showed that random label noise interferes with the learning of the standard CNN. We also found that by increasing the number of training example and using



การประชุมวิชาการนำเสนอผลงานวิจัยระดับชาติและนานาชาติ ครั้งที่ 14
"Global Goals, Local Actions: Looking Back and Moving Forward 2021"
วันพุธที่ 18 สิงหาคม 2564

Dropout and various form of weight Regularization techniques, it is possible to make the model better learns from noisy label.

Keywords Convolutional Neural Network, Random Label Noise, Model Complexity

บทนำ

การจำแนกข้อมูล (Classification) หมายถึง การจัดแบ่งข้อมูลเข้ากลุ่มที่กำหนดไว้ ในบริบทของการเรียนรู้ของเครื่อง (Machine Learning) จะมุ่งหาตัวแบบ (Model) เพื่อจัดแบ่งข้อมูลอัตโนมัติ โดยใช้ชุดข้อมูลที่มีอยู่จำนวนหนึ่งในการสร้างตัวแบบดังกล่าว ซึ่งตัวแบบที่ได้รับนั้น ควรสามารถนำไปใช้ในการกำหนดกลุ่มของข้อมูลอย่างแม่นยำ การจำแนกข้อมูลจึงอาจมองเป็นกระบวนการปรับพารามิเตอร์ของตัวแบบโดยใช้กลุ่มตัวอย่างข้อมูลที่เรียกว่าข้อมูลฝึกฝน (Training Data) ซึ่งในแต่ละแถวของชุดข้อมูลฝึกฝนประกอบด้วยฟิลต์หรือแอทริบิวท์ที่สุ่มสละจากข้อมูลดิบที่ซึ่งอาจจะอยู่ในรูปแบบของตัวเลข ตัวหนังสือ รูปภาพ เสียง และฉลากบอกกลุ่ม (Label) ของข้อมูลแต่ละตัว ซึ่งส่วนใหญ่จะกำหนดไว้ล่วงหน้าโดยผู้เชี่ยวชาญ การเรียนรู้ของตัวแบบและปรับพารามิเตอร์แบบมีฉลากบอกกลุ่มจัดเป็นการเรียนรู้แบบมีผู้สอน (Supervised Learning) ทั้งนี้ฉลากบอกกลุ่มอาจมีความผิดพลาดได้ อันเกิดจาก 1. มีความรู้ไม่เพียงพอในการกำหนดฉลาก 2. ความผิดพลาดจากผู้เชี่ยวชาญที่กำหนดฉลาก 3. ข้อจำกัดทางการสื่อสารที่ทำให้เกิดข้อผิดพลาด ทำให้ฉลากที่แท้จริงถูกรบกวน ซึ่งเราเรียกว่าฉลากรบกวน (Label Noise) [1] หรือฉลากที่ไม่ตรงกับความเป็นจริง ซึ่งส่งผลต่อการเรียนรู้ของตัวแบบ

ในปัจจุบันเทคนิคในการจำแนกข้อมูลที่มีความนิยมคือโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network : CNN) โครงข่ายประสาทเทียมแบบนี้เป็นโครงข่ายประสาทเทียมที่เป็นที่นิยม ในการแก้ปัญหาการจำแนกประเภท โดยเฉพาะอย่างยิ่งกับข้อมูลนำเข้าแบบรูปภาพ เพราะเป็นการจำลองการรับภาพของประสาทตามนุษย์ ทั้งนี้เนื่องจากเป็นโมเดลที่มีความซับซ้อนสูง ซึ่งตามหลักการแล้ว ความเป็นไปได้ที่ CNN จะไวต่อฉลากรบกวน เนื่องจากมีโอกาสเกิด Overfitting ได้ง่าย ซึ่งลักษณะเด่นของ CNN คือในขั้นตอนของการฝึกสอน (Train) จะทำการคัดเลือกคุณลักษณะเอง และทำซ้ำไปเรื่อยๆ จนกว่าจะได้คุณลักษณะที่มีความสัมพันธ์กับผลลัพธ์มากที่สุด แต่มีจุดอ่อนคือ ถ้าคุณลักษณะของภาพมีความซับซ้อน จะยากต่อการกำหนดคุณลักษณะจะทำให้คอมพิวเตอร์เรียนรู้ได้ไม่ดี และผลลัพธ์ที่ได้ไม่มีประสิทธิภาพเท่าที่ควร ทั้งนี้ประสิทธิภาพในการทำนายของ CNN ขึ้นอยู่กับจำนวนและลักษณะของภาพที่ใช้ในการฝึกสอนให้คอมพิวเตอร์เรียนรู้ ซึ่งจำเป็นต้องใช้ภาพจำนวนมากในการฝึกสอน ดังนั้นการกำหนดจำนวนภาพและลักษณะของภาพจึงเป็นสิ่งสำคัญแต่ CNN มีข้อเสียคือใช้ทรัพยากรและเวลาในการประมวลผลมาก Liu, T. & Tao, D [2] ได้มีการสำรวจโครงข่าย CNN ว่าสามารถฝึกฝนข้อมูลที่มีฉลากรบกวนได้อย่างไร และได้เสนอการฝึกโมเดล AlexNet และ ConvNets เพื่อศึกษาการปรับปรุงความทนทานของสัญญาณรบกวน โดยเน้นที่สัญญาณรบกวนประเภทต่างๆ โดยใช้ชุดข้อมูลรูปภาพจาก ImageNet 900 ตัวอย่าง/คลาส ซึ่งทำให้การทดลองทั้งสองวิธีให้ประสิทธิภาพที่สำคัญ ได้เปรียบกว่ารุ่นมาตรฐาน และควรนำไปใช้ในการเรียนรู้เชิงลึกให้มากขึ้น



การประชุมวิชาการนำเสนอผลงานวิจัยระดับชาติและนานาชาติ ครั้งที่ 14
"Global Goals, Local Actions: Looking Back and Moving Forward 2021"
วันพุธที่ 18 สิงหาคม 2564

อย่างไรก็ตามมีงานวิจัยบางงาน รายงานว่าผลการรบกวนส่งผลต่อ CNN ไม่มาก ซึ่งได้มีการออกแบบการทดลองเพื่อทดสอบความทนทานของโครงข่ายประสาทเทียมแบบสังวัตนาการที่มีข้อมูลการฝึกที่มีผลการรบกวนเพื่อพิจารณาว่าผลลัพท์ของชุดข้อมูลมีการรบกวนต่อผลลัพท์อย่างไร โดยสร้างแบบจำลองของการใช้ Softmax Classifier เพื่อใช้ในการทดสอบที่ใช้ค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐานในการทดลองเพื่อทดสอบความทนทานของโครงข่ายประสาทเทียมแบบสังวัตนาการ และผลการทดลองเห็นได้ชัดเจนว่าค่าความแม่นยำในการทดสอบมีการลดลงเมื่อมีผลการรบกวนที่เพิ่มขึ้น [3] จึงทำให้น่าสงสัยว่าเหตุใด จึงขัดกับหลักการดังกล่าว ผู้วิจัยคาดว่าอาจมีปัจจัยบางอย่างที่ส่งผลต่อความทนทาน หรือความอ่อนไหวต่อผลการรบกวนของ CNN โดยงานวิจัยใน [4] ก็ชี้ให้เห็นถึงผลกระทบนี้ในบริบทของการจำแนกเสียง โดยวัดผลกระทบที่เกิดจากการจัดคำอธิบายประกอบบนผลลัพท์ที่ไม่ตรงกับผลลัพท์ที่แท้จริงเพื่อตรวจสอบความแม่นยำในการติดผลลัพท์ที่ต้องเพื่อให้ได้ประสิทธิภาพที่เพิ่มขึ้น การศึกษานี้จะศึกษาว่าปัจจัยใดบ้าง ที่มีผลต่อความทนทานต่อสัญญาณรบกวนแบบสุ่มของ CNN และในงานวิจัย [5] ได้เสนอวิธีการใหม่ในการจัดผลลัพท์การรบกวนจากชุดข้อมูล โดยใช้วิธีแนวคิดระยะทางแบบยุคลิด ทำให้สามารถทำความสะอาดผลลัพท์การรบกวนได้อย่างรวดเร็วและสามารถลบผลลัพท์ที่ไม่ถูกต้องได้มากกว่า 90% และมีการตรวจสอบผลกระทบของสัญญาณรบกวน โดยแยกประเภทการเรียนรู้ [6][7][8] การศึกษาการเรียนรู้ของเครื่องส่วนใหญ่มุ่งเน้นไปที่การตรวจจับการรบกวนใน Class ถึงในเรื่องของการเพิ่มคุณภาพของข้อมูลที่เกิดขึ้น และการแก้ไขสัญญาณรบกวนเป็นอีกวิธีหนึ่งในการระบุข้อมูลที่ติดผลลัพท์ผิด จึงต้องมีปริมาณของข้อมูลการฝึกฝนที่มีขนาดใหญ่ในการวิเคราะห์ โดยปัจจัยที่จะมุ่งศึกษาในงานวิจัยนี้ได้แก่ ขนาดของข้อมูลฝึกฝน, เปอร์เซนต์ของผลลัพท์การรบกวนในชุดข้อมูล และความซับซ้อนของโมเดล CNN โดยใช้ข้อมูลฝึกฝนและข้อมูลทดสอบ จำนวนข้อมูลทั้งหมด 15,000 ภาพ

วัตถุประสงค์ของการวิจัย

เพื่อวิเคราะห์ปัจจัยที่มีผลต่อความทนทานของโครงข่ายประสาทเทียมแบบสังวัตนาการและการใช้ Dropout และ Regularization เพื่อลดผลกระทบของผลลัพท์การรบกวนแบบสุ่ม

ขอบเขตการวิจัย

1. ขอบเขตข้อมูล

ข้อมูลฝึกฝนและข้อมูลทดสอบประกอบด้วยรูปภาพขนาด 200 พิกเซล คูณ 133 พิกเซล ทั้งหมด 15,000 ภาพ ในหมวดยานพาหนะ แบ่งเป็น 5 Class ได้แก่ รถจักรยาน, รถบัส, รถมอเตอร์ไซค์, รถไฟ และรถยนต์

2. ขอบเขตทางสถาปัตยกรรม

2.1 ฮาร์ดแวร์ (Hardware)

- Ubuntu 18.04.3 LTS
- Intel (R) Core (TM) i9-9900K CPU @ 3.60GHz
- NVIDIA GEFORCE RTX 2080 Ti 11GB GDDR6



การประชุมวิชาการนำเสนอผลงานวิจัยระดับชาติและนานาชาติ ครั้งที่ 14
 "Global Goals, Local Actions: Looking Back and Moving Forward 2021"
 วันพุธที่ 18 สิงหาคม 2564

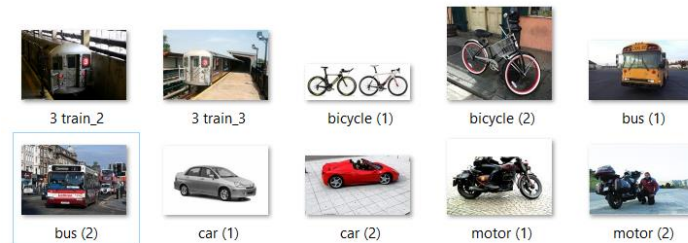
- RAM 16 GB
- 2.2 ซอฟต์แวร์ (Software)
 - Keras
 - Tensorflow
 - Anaconda 4.7.12 with Python 3.7.3
- 2.3 สถาปัตยกรรมของโครงข่ายประสาทเทียมแบบสังวัตนาการ
 - VGG16

วิธีดำเนินการวิจัย

1. แบ่งชุดข้อมูล 15,000 ภาพ ออกเป็นชุดข้อมูลฝึกฝนและชุดข้อมูลทดสอบ โดยวิธี Holdout method

1.1 การจัดเก็บข้อมูลรูปภาพเพื่อการฝึกฝน

ผู้วิจัยได้จัดเตรียมข้อมูลรูปภาพทั้ง 5 Class โดยแบ่งเป็นจำนวนภาพสำหรับชุดฝึกฝน เป็น 6,000, 8,000, 10,000, 12,000 ตามลำดับ จากนั้นนำรูปภาพที่ได้จัดเก็บเป็น Class โดยแยกเป็นแฟ้มข้อมูลของแต่ละ Class และแบ่งรูปภาพในจำนวนที่เท่ากัน ตัวอย่างแสดงดังภาพที่ 1



ภาพที่ 1 แสดงตัวอย่างรูปภาพชุดฝึกฝนโดยแยกเป็นแฟ้มข้อมูลแต่ละ Class


1.2 จำลองฉลากรบกวนในชุดข้อมูลฝึกฝน ตั้งแต่ 0% 10% 20% 30% 40% เช่นสมมติว่าชุดข้อมูลฝึกฝนมีจำนวน 10,000 ภาพ การจำลองฉลากรบกวน 40% คือ มีรูปภาพจำนวน 4,000 ภาพที่ฉลากไม่ตรงกับรูป เช่น ภาพรถไฟ แต่มีฉลากบอกกลุ่มเป็น จักรยาน การจำลองฉลากรบกวนในชุดฝึกฝนจะใช้เพื่อทดสอบความทนทานของโครงข่ายประสาทเทียมแบบสังวัตนาการเมื่อเรียนรู้จากชุดฝึกฝนที่มีฉลากรบกวน

2. เมื่อได้ชุดข้อมูลฝึกฝนแล้วจะทำการประมวลผล โดยให้โมเดล CNN เรียนรู้จากชุดฝึกฝนที่มีฉลากรบกวน การทดสอบความทนทานจะอาศัยการวัดค่าความแม่นยำของโมเดลบนชุดข้อมูลทดสอบ หากโมเดลมีความทนทานต่อฉลากรบกวนสูง ค่าความแม่นยำควรจะสูงไปด้วย

3. ทดสอบความทนทานโดยวัดค่าความแม่นยำของโมเดลบนชุดข้อมูลทดสอบ ถ้าความแม่นยำไม่ต่างจากกรณีที่มีฉลากรบกวน 0% แสดงว่าโมเดลทนทานต่อฉลากรบกวน ดังภาพที่ 2



การประชุมวิชาการนำเสนอผลงานวิจัยระดับชาติและนานาชาติ ครั้งที่ 14
 "Global Goals, Local Actions: Looking Back and Moving Forward 2021"
 วันพุธที่ 18 สิงหาคม 2564



ภาพที่ 2 แสดงขั้นตอนการฝึกฝนโมเดล CNN จากชุดฝึกฝนที่มีผลการบวกรวม

4. ทำซ้ำในข้อที่ 1-3 เพิ่ม/ลด จำนวนภาพในชุดฝึกฝนเป็น 6,000, 8,000, 10,000, 12,000
5. ทำซ้ำในข้อที่ 1-3 ปรับความซับซ้อนของโมเดล โดยใช้เทคนิค Dropout Regularization และกำหนด Dropout Parameter เป็น 0.1, 0.3, 0.5, 0.7, 0.9 หรือเทคนิค Regularization แบบ L1 และ L2 โดยกำหนด Regularization Parameter เป็น 0.1, 0.01, 0.001 ตามลำดับ แล้วทดสอบความแม่นยำ โดยสมมติฐานของการใส่ Regularization คือการลดความซับซ้อนของโมเดลด้วยวิธีดังกล่าวอาจสามารถปรับปรุงความทนทานของผลการบวกรวมต่อโมเดลได้ระดับหนึ่ง

ผลการวิจัย

การทดลองนี้จะทำการวิเคราะห์ปัจจัยที่มีผลต่อความทนทานของโครงข่ายประสาทเทียมแบบสังวัตนาการต่อผลการบวกรวมแบบสุ่ม และเทคนิคในการจำแนกข้อมูลที่ได้รับค่านิยมคือโครงข่ายประสาทเทียมแบบสังวัตนาการ ใช้ในการจำแนกประเภท โดยเฉพาะอย่างยิ่งกับข้อมูลนำเข้าแบบรูปภาพ เพราะเป็นการ



การประชุมวิชาการนำเสนอผลงานวิจัยระดับชาติและนานาชาติ ครั้งที่ 14
 "Global Goals, Local Actions: Looking Back and Moving Forward 2021"
 วันพุธที่ 18 สิงหาคม 2564

จำลองการรับภาพของประสาทตามนุษย์และเป็นโมเดลที่มีความซับซ้อนสูง จึงจะศึกษาผลการทดลองว่าฉลาก
 ครอบงวนมีผลต่อความทนทานของโครงข่ายประสาทเทียมแบบสังวัตนาการหรือไม่ ในการแบ่งชุดข้อมูล 15,000
 ภาพ เพื่อทดสอบประสิทธิภาพของโครงข่ายประสาทเทียมแบบสังวัตนาการต่อฉลากครอบงวนแบบสุ่มนั้น
 จะแบ่งชุดข้อมูลออกเป็นชุดข้อมูลฝึกฝนและชุดข้อมูลทดสอบ และเพิ่ม/ลดจำนวนภาพในชุดฝึกฝนเป็น 6,000,
 8,000, 10,000, 12,000 จำลองฉลากครอบงวนในชุดข้อมูลฝึกฝน ตั้งแต่ 0% 10% 20% 30% 40% เนื่องจาก
 ข้อจำกัดของพื้นที่นำเสนอ ผู้วิจัยจะแสดงผลบางส่วนที่น่าสนใจดังนี้

ตารางที่ 1 แสดงผลการทดลองชุดฝึกฝน 8,000 ฉลากครอบงวน 20% ไม่ใช่ L1 และ L2 Regularization

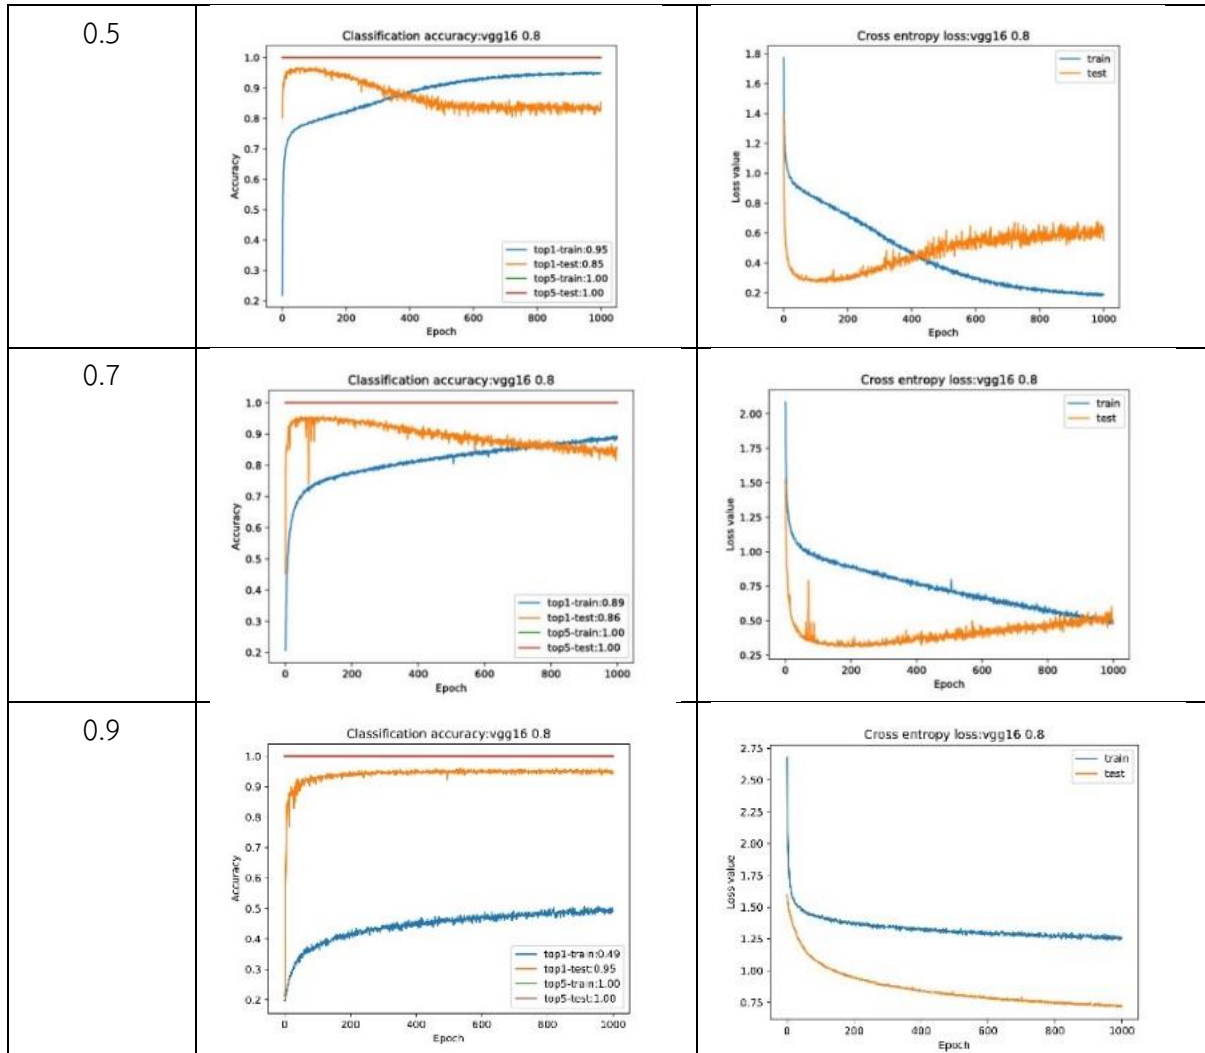
Dropout	Accuracy	Loss
0.0		
0.1		
0.3		



广西中医药大学
GUANGXI UNIVERSITY OF CHINESE MEDICINE



การประชุมวิชาการนำเสนอผลงานวิจัยระดับชาติและนานาชาติ ครั้งที่ 14
"Global Goals, Local Actions: Looking Back and Moving Forward 2021"
วันพุธที่ 18 สิงหาคม 2564



จากตารางที่ 1 ผลการทดลองชุดฝึกฝน 8,000 ภาพที่ปะปนด้วยฉลากรบกวน 20% และไม่ใช้ L1 หรือ L2 Regularization พบว่า Dropout มีผลในการชะลอการเกิด Overfitting กับฉลากรบกวน ดังสังเกตได้จากจุดตัดของเส้น Training Accuracy (ส้ม) และเส้น Test Accuracy (น้ำเงิน) จะเกิดขึ้นช้าขึ้นระหว่างกระบวนการฝึกฝน หลังจากที่เส้นกราฟตัดกันค่าความแม่นยำบนชุดทดสอบก็มีแนวโน้มลดลงเรื่อย ๆ ทั้งที่ความแม่นยำบนชุดฝึกหัดเพิ่มขึ้น แสดงให้เห็นถึงสถานการณ์ Overfitting ทั้งนี้เมื่อใช้ Dropout เท่ากับ 0.9 พบว่าเส้นกราฟทั้งสองไม่ตัดกันเลย แสดงให้เห็นว่าไม่เกิดการ Overfitting ขึ้นกับฉลากรบกวน และเป็นหลักฐานหนึ่งที่แสดงว่าเมื่อกำหนดค่าเหมาะสม Dropout จะช่วยลดความซับซ้อนของโมเดลและทำให้โมเดลมีการเรียนรู้จากข้อมูลที่มีฉลากรบกวนได้ดีขึ้น



การประชุมวิชาการนำเสนอผลงานวิจัยระดับชาติและนานาชาติ ครั้งที่ 14
 "Global Goals, Local Actions: Looking Back and Moving Forward 2021"
 วันพุธที่ 18 สิงหาคม 2564

ตารางที่ 2 แสดงผลการทดลองชุดฝึกฝน 12,000 บนฉลากรบกววน 40% และ Regularization แบบ L1 โดย
 ไม่ใช่ Dropout

L1 Regularization	Accuracy	Loss
0.001		
0.01		
0.1		

จากตารางที่ 2 ทดลองบนชุดฝึกฝน 12,000 ภาพ และฉลากรบกววน 40% Regularization แบบ L1 จะเห็นได้ว่าเมื่อไม่มีการกำหนดค่า Dropout แต่มีการใช้ Regularization แบบ L1 ณ ค่า 0.01 สามารถลดความซับซ้อนของโมเดลและทำให้โมเดลทนทานต่อฉลากรบกววนได้ โดยเส้นกราฟของค่าความแม่นยำบนชุดฝึกฝน ไม่ตัดกับเส้นกราฟค่าความแม่นยำบนชุดทดสอบ และได้ความแม่นยำใกล้เคียงกับกรณีสร้างโมเดลบนข้อมูลที่ไม่มีฉลากรบกววนปะปน



การประชุมวิชาการนำเสนอผลงานวิจัยระดับชาติและนานาชาติ ครั้งที่ 14
 "Global Goals, Local Actions: Looking Back and Moving Forward 2021"
 วันพุธที่ 18 สิงหาคม 2564

ตารางที่ 3 แสดงผลการทดลองชุดฝึกฝน 8,000 จำลองฉลากรบกวน 20% Regularization แบบ L2 และ
 ไม่ใช่ Dropout

L2 Regularization	Accuracy	Loss
0.001		
0.01		
0.1		

ตารางที่ 3 ซึ่งแสดงผลการทดลองบนชุดฝึกฝน 8,000 ภาพและจำลองฉลากรบกวน 20% พบว่า Regularization แบบ L2 ไม่แสดงให้เห็นความสามารถในการลดความซับซ้อนของโมเดล โดยสังเกตได้ว่ายังเกิด Overfitting ณ ทุกค่าของ Regularization เพียงแต่เกิดช้าหรือเร็วเท่านั้น



การประชุมวิชาการนำเสนอผลงานวิจัยระดับชาติและนานาชาติ ครั้งที่ 14
 "Global Goals, Local Actions: Looking Back and Moving Forward 2021"
 วันพุธที่ 18 สิงหาคม 2564

อภิปรายผลการวิจัย

จากการวิเคราะห์ปัจจัยด้านความซับซ้อนของตัวแบบที่มีผลต่อความทนทานของฉลากรบวงแบบสุ่มโดยใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ อภิปรายผลการวิจัยได้ดังนี้

โครงข่ายประสาทเทียมแบบสังวัตนาการมีความอ่อนไหวต่อปริมาณของฉลากรบวงแบบสุ่มในชุดข้อมูลฝึกหัด ซึ่งเมื่อมีการจำลองฉลากรบวง 0% ถึง 40% ในชุดฝึกฝน จะพบว่าโครงข่ายประสาทเทียมได้รับผลกระทบ โดยสังเกตจากแนวโน้มที่จะเกิด Overfitting กับฉลากที่ผิดพลาดมากขึ้น ว่าเมื่อมีการกำหนดค่า Dropout เพื่อใช้ลดความซับซ้อนของโมเดล ด้วยค่า Dropout Parameter ที่เหมาะสม (ในที่นี้พบว่าค่าดังกล่าวมีค่าเท่ากับ 0.9) จะส่งผลให้ไม่เกิด Overfitting ดังแสดงผลด้วยกราฟ Classification Accuracy และทำให้โมเดลมีความแม่นยำในการทำนายข้อมูลทดสอบใกล้เคียงกับกรณีที่สร้างตัวแบบจากข้อมูลฝึกหัดที่ไม่มีฉลากรบวง ซึ่งสามารถอธิบายในเชิงความซับซ้อนของตัวแบบได้ว่า Dropout ไปลดความซับซ้อนของโครงข่ายประสาทเทียมแบบสังวัตนาการทำให้เกิด Overfitting น้อยลงหรือไม่เกิดเลย

การใช้เทคนิค Regularization ก็เป็นอีกเทคนิคหนึ่งที่ใช้เพื่อลดความซับซ้อนของโมเดล โดยจากการทดลองทั้งแบบ L1 และ แบบ L2 เพื่อเพิ่มความทนทานต่อฉลากรบวง โดยไม่มีการกำหนดค่า Dropout พบว่า L1 Regularization สามารถนำมาประยุกต์ใช้เพื่อทำให้โมเดลทนทานต่อฉลากรบวงได้ดี (ในกรณีนี้พบว่าค่าที่เหมาะสมคือ 0.01) อย่างไรก็ตามเทคนิค Regularization แบบ L2 เหมือนจะไม่มีประสิทธิภาพในการลดความซับซ้อนของตัวแบบเพียงพอ สังเกตได้ว่าโครงข่ายประสาทเทียมแบบสังวัตนาการที่ประยุกต์ใช้ Regularization แบบ L2 ยังคงเกิด Overfitting ได้อยู่ เพียงแต่การนำ Regularization แบบ L2 มาใช้จะชะลอการเกิดขึ้นของ Overfitting แต่ยังมีข้อจำกัดในการทดลองเนื่องจากขั้นตอนการฝึกสอนโครงข่ายประสาทเทียมเมื่อใช้ชุดฝึกฝนและชุดทดสอบที่มากขึ้น จำเป็นต้องใช้เวลาในการประมวลผลมากขึ้น เพื่อให้การเรียนรู้มีประสิทธิภาพ จึงต้องใช้เครื่องคอมพิวเตอร์ที่มีการประมวลผลข้อมูลที่มีประสิทธิภาพรองรับการทดลองกับขนาดของข้อมูลจำนวนมากๆ ได้ ซึ่งในการทดลองนี้ได้ใช้เครื่องเซิร์ฟเวอร์ศูนย์วิจัยวิทยาการข้อมูล คณะวิทยาศาสตร์ มหาวิทยาลัยเชียงใหม่

จากงานวิจัยที่ผ่านมาได้กล่าวไว้ว่า ผลการทดลองค่าความแม่นยำในการทดสอบมีการลดลงเมื่อมีฉลากรบวงที่เพิ่มขึ้น จึงทำให้ผู้วิจัยทำการศึกษาข้อมูลและปัจจัยต่างๆที่เกี่ยวข้อง โดยมีปัจจัยบางอย่างที่ส่งผลต่อความทนทาน หรือความอ่อนไหวต่อฉลากรบวงของ CNN ในการศึกษาครั้งนี้ผู้วิจัยจึงได้ทำการทดลองโดยใช้ VGG โมเดลและฉลากรบวงแบบสุ่มเท่านั้น ด้วยเหตุนี้การศึกษาวิจัยบนโครงข่ายประสาทเทียมแบบสังวัตนาการที่นิยมอื่นๆ เช่น ResNet, Inception หรือ DenseNet รวมไปถึงการศึกษาฉลากรบวงแบบไม่สุ่ม ก็เป็นแนวทางที่น่าสนใจศึกษาต่อไปในอนาคต

เอกสารอ้างอิง

- [1] Fréney, B. & Verleysen, M. (2014). Classification in the Presence of Noisy Label: a Survey. IEEE Transactions on Neural Networks and Learning Systems.



การประชุมวิชาการนำเสนอผลงานวิจัยระดับชาติและนานาชาติ ครั้งที่ 14
"Global Goals, Local Actions: Looking Back and Moving Forward 2021"
วันพุธที่ 18 สิงหาคม 2564

-
- [2] Liu, T. & Tao, D. (2016). Classification with Noisy Labels by Importance Reweighting. IEEE Transactions on Pattern Analysis and Machine Intelligence.
 - [3] Flatow, D. & Penner, D. (2018). On the Robustness of ConvNets to Training on Noisy Labels. ArXiv.
 - [4] Kelz, R. & Widmer, G. (2018). Investigating Noisy Label Sensitivity of Convolutional Neural Networks for Fine Grained Audio Signal Labelling. IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP).
 - [5] Malik, A.M. & Kang, M. (2017). Euclidean Distance Based Noisy Label Cleaning”, Ninth International Conference on Ubiquitous and Future Networks (ICUFN).
 - [6] Wigness, M. & Gutstein, S. (2017). On the Impacts of Noise from Group-Based Label Collection for Visual Classification. 16th IEEE International Conference on Machine Learning and Applications.
 - [7] Moura, d. G. K. & Prudencio, C.B.R. (2018). Ensemble Methods for Noisy Label Detection Under the Noisy at Random Model. 7th Brazilian Conference on Intelligent Systems.
 - [8] Zhou, X. & Ding, K.L.P. & Li, B. (2019). Improving Robustness Of Random Forest Under Noisy Label. ”, IEEE Winter Conference on Applications of Computer Vision.