

การเปรียบเทียบวิธีวิเคราะห์ความรู้สึกในเว็บอีคอมเมิร์ซสำหรับการตรวจจับรีวิวปลอม

A Comparison of Sentiment Analysis Methods in Web E-Commerce
For Fake Reviews Detection



การค้นคว้าอิสระนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูลและการวิเคราะห์
ศูนย์วิเคราะห์ข้อมูลดิจิทัลอัจฉริยะพระจอมเกล้าลาดกระบัง
คณะวิทยาศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
พ.ศ. 2566

KMITL-2023-SC-M-017-029

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

A Comparison of Sentiment Analysis Methods in Web E-Commerce For Fake Reviews Detection



AN INDEPENDENT STUDY SUBMITTED IN PARTIAL FULFILLMENT OF THE
REQUIREMENT FOR THE DEGREE OF MASTER OF SCIENCE IN DATA SCIENCE AND ANALYTICS
KMUTL DIGITAL ANALYTICS AND INTELLIGENCE CENTER SCHOOL OF SCIENCE
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG
2023
KMUTL-2023-SC-M-017-029

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



COPYRIGHT 2023

SCHOOL OF SCIENCE

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อการค้นคว้าอิสระ	การเปรียบเทียบวิธีวิเคราะห์ความรู้สึกในเว็บอีคอมเมิร์ซสำหรับการตรวจจับรีวิวปลอม
ชื่อนักศึกษา	นางสาวมณีนรุตน์ พุทธรัตนมณี
รหัสประจำตัว	64605090
ปริญญา	วิทยาศาสตรมหาบัณฑิต (วิทยาการข้อมูลและการวิเคราะห์)
พ.ศ.	2566
อาจารย์ที่ปรึกษาการค้นคว้าอิสระ	รองศาสตราจารย์ ดร.ละออ บุญเกษม

บทคัดย่อ

ผู้บริโภคเมื่อทำการซื้อสินค้าหรือผลิตภัณฑ์ออนไลน์ต่าง ๆ มักจะอ่านข้อความรีวิวการซื้อสินค้าจากผู้ที่เคยซื้อสินค้ามาก่อน เพื่อช่วยในการประกอบการตัดสินใจ ดังนั้นข้อความรีวิวสินค้าออนไลน์จึงมีบทบาทสำคัญในการช่วยตัดสินใจเลือกซื้อสินค้า ด้วยเหตุนี้จึงทำให้มีรีวิวปลอมเกิดขึ้น รีวิวปลอมเป็นข้อความรีวิวที่ถูกสร้างขึ้นทั้งจากมนุษย์และคอมพิวเตอร์ด้วยการกระทำที่ไม่สุจริต สร้างเพื่อปลอมแปลงข้อมูลหรือบิดเบือนความเป็นจริงของสินค้านั้น ๆ อีกทั้งยังเป็นการกระตุ้นยอดขายและเพิ่มความนิยมของร้านค้าเป็นต้น งานวิจัยฉบับนี้จึงมีจุดประสงค์เพื่อศึกษาและเปรียบเทียบประสิทธิภาพของแบบจำลองต่าง ๆ ที่ใช้ในการตรวจจับรีวิวปลอมเพื่อช่วยผู้บริโภคในการกรองข้อความรีวิวปลอมออก และสามารถตัดสินใจซื้อสินค้าจากข้อความรีวิวที่เป็นจริง โดยงานวิจัยนี้ใช้ชุดข้อมูล Amazon Review Data (2018) ซึ่งเป็นชุดข้อมูลที่นำเชื่อถือและใช้กันอย่างกว้างขวาง ในส่วนของข้อมูลจะเป็นการดึงข้อมูล 10 หมวดหมู่แรกของสินค้าที่มียอดรีวิวก่อนในเว็บไซต์ amazon.com จากนั้นทำการเตรียมข้อมูลเบื้องต้น เช่น การตัดอักขระพิเศษ การทำ bag of words การทำ TF-IDF เป็นต้น และทำการสอนแบบจำลองเพื่อที่จะนำมาสร้างชุดข้อมูลในการตรวจจับรีวิวปลอม ซึ่งงานวิจัยนี้ได้ใช้แบบจำลองในการเปรียบเทียบประสิทธิภาพของการตรวจจับรีวิวปลอมทั้งหมด 4 แบบจำลองด้วยกัน มีทั้งแบบจำลองที่เป็นการเรียนรู้ของเครื่องและแบบจำลองที่เป็นการเรียนรู้เชิงลึก ได้แก่ GPT-2, NBSVM, BiLSTM, Roberta และมีการปรับจูนค่าไฮเปอร์พารามิเตอร์ต่าง ๆ เพื่อทำการค้นหาค่าที่เหมาะสมกับแบบจำลอง ซึ่งผลการวิจัยสรุปได้ว่าแบบจำลอง Roberta ให้ค่าประสิทธิภาพโดยรวมดีที่สุด โดยมีค่าเท่ากับ 97% GPT-2 มีค่าประสิทธิภาพโดยรวมเท่ากับ 82% NBSVM มีค่าประสิทธิภาพโดยรวมเท่ากับ 95% และ BiLSTM มีค่าประสิทธิภาพโดยรวมเท่ากับ 92%

คำสำคัญ : รีวิวปลอม , GPT-2 , NBSVM , Roberta , BiLSTM

Independent Study Title	A Comparison of Sentiment Analysis Methods in Web E-Commerce For Fake Reviews Detection
Student Name	Miss Maneerat Puttarattanamanee
Student ID	64605090
Degree	Master of Science (Data Science and Analytics) KMITL-Digital Analytics and Intelligence Center
Year	2023
Independent Study Advisor	Assoc. Prof. Dr. Laor Boongasame

Abstract

Online shoppers frequently examine reviews from previous buyers to help them make decisions when purchasing products. Therefore, online product reviews play an important role in assisting shoppers in choosing what to buy. As a result, false reviews are produced. Text reviews that are generated dishonestly by humans as well as computers are known as fake reviews. It is created to fake information or distort the reality of that product, as well as to stimulate sales and increase the popularity of the store, etc. The goal of this research is to examine and evaluate the performance of various methods for identifying fake reviews. The well-known and widely used Amazon Review Data (2018) dataset was used for this research. The first 10 product categories on Amazon.com with favorable feedback will be provided in the data section. After that, perform fundamental data preparation procedures such as special character trimming, bag of words, TF-IDF, etc. The models are trained to create a dataset for detecting fake reviews. This research compares the performance of four different models: GPT-2, NBSVM, BiLSTM, and Roberta. The hyperparameters of the models are also tuned to find the optimal values. The research concludes that the Roberta model performs the best overall, with an accuracy of 97%. GPT-2 has an overall accuracy of 82%, NBSVM has an overall accuracy of 95%, and BiLSTM has an overall accuracy of 92%.

Keywords: Fake reviews, GPT-2, NBSVM, Roberta , BiLSTM

กิตติกรรมประกาศ

งานวิจัยนี้สำเร็จลงด้วยดี ผู้วิจัยขอกราบขอบพระคุณ บุคคล และกลุ่มบุคคลต่างๆที่ได้กรุณาให้คำปรึกษา แนะนำ ช่วยเหลืออย่างดียิ่ง ทั้งในด้านวิชาการ และด้านการดำเนินงานวิจัย ดังต่อไปนี้

ขอกราบขอบพระคุณ รศ.ดร.ละออ บุญเกษม อาจารย์ที่ปรึกษาที่ให้ความรู้ คำปรึกษา และกำลังใจ อีกทั้งยังคอยช่วยปรับปรุงแก้ไขงานวิจัยฉบับนี้ให้มีประสิทธิภาพยิ่งขึ้น ตลอดจนคอยให้ความช่วยเหลือในเรื่องต่างๆ ซึ่งผู้วิจัยรู้สึกซาบซึ้งในความอนุเคราะห์นี้เป็นอย่างมาก

ขอกราบขอบพระคุณ ดร.จิรภัทร์ หยกรัตนศักดิ์ และ ผศ.ดร. พรพิมล ชัยวุฒิศักดิ์ คณะกรรมการสอบที่สละเวลามาให้คำแนะนำและข้อเสนอแนะต่างๆ ซึ่งช่วยให้งานวิจัยฉบับนี้มีประสิทธิภาพมากยิ่งขึ้น

นอกจากนี้ขอขอบคุณ ครู อาจารย์ ทั้งในอดีตและปัจจุบันที่ให้ความรู้แก่ผู้วิจัยอย่างมากมาจนก่อให้เกิดประสิทธิผลวิชาความรู้และความเชี่ยวชาญ ทั้งทางด้านทฤษฎีและการปฏิบัติ

ท้ายที่สุดขอกราบขอบพระคุณ บิดา มารดา ที่ให้กำเนิด อบรม เลี้ยงดู และเพื่อนทุกคนที่คอยส่งเสริมให้ผู้วิจัยมีความรู้ ความสามารถ ทั้งยังเป็นกำลังใจให้แก่ผู้วิจัย จนทำให้งานวิจัยฉบับนี้สำเร็จไปได้ด้วยดี

นางสาวมณีนีรัตน์ พุทธรัตนมณี

สารบัญ

หน้า

บทคัดย่อภาษาไทย	ก
บทคัดย่อภาษาอังกฤษ	ข
กิตติกรรมประกาศ	ค
สารบัญ	ง
สารบัญตาราง	ช
สารบัญภาพ	ฉ
บทที่ 1 บทนำ	1
1.1 ความเป็นมาและความสำคัญของปัญหา	1
1.2 วัตถุประสงค์ของงานวิจัย	2
1.3 ขอบเขตของงานวิจัย	2
1.4 ประโยชน์ที่คาดว่าจะได้รับ	2
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง	3
2.1 ทฤษฎีที่เกี่ยวข้อง	3
2.1.1 การวิเคราะห์ความรู้สึก (Sentiment Analysis)	3
2.1.2 กระบวนการเตรียมข้อมูลเพื่อการวิเคราะห์ข้อความ (Text Preprocessing)	4
1. Tokenization	4
2. Bag of words	5
3. Term Frequency – Invert Document Frequency	6
4. Word Embedding	7
5. Word2Vec	7
2.1.3 โครงข่ายประสาทเทียมแบบวนกลับ Recurrent Neural Network	8
2.1.4 หน่วยความจำระยะสั้นยาว (Long Short-Term Memory Model)	10
2.1.5 Bidirectional Encoder Representations from Transformers (BERT)	15
2.1.6 Generative Pre-trained Transformer (GPT-2)	16
2.1.7 การจำแนกแบบเบย์อย่างง่าย (Naïve Bayesian Classifier)	17
2.1.8 ซัพพอร์ทเวกเตอร์แมชชีน (Support Vector Machine: SVM)	17

สารบัญ (ต่อ)

	หน้า
2.1.9 เมทริกซ์วัดประสิทธิภาพ (Confusion Matrix)	18
1. ค่าความถูกต้อง	18
2. ค่าความเที่ยง	19
3. ค่าความไวหรือค่าระลึก	20
4. ค่าเฉลี่ยของ Precision และ Recall	20
2.2 งานวิจัยที่เกี่ยวข้อง	20
2.2.1 กลุ่มงานวิจัยด้านการทำนายการตรวจจ็บริวิปลอม	20
1. การวิเคราะห์ความคิดเห็นตามภววิทยาสำหรับการตรวจจ็บริวิปลอม	21
2. การทบทวนการนำการเรียนรู้แบบกึ่งมีผู้สอนสำหรับการตรวจจ็บริวิปลอม	21
3. การตรวจจ็บริวิปลอมผ่านการวิเคราะห์คุณสมบัติทางภาษา	21
4. การสร้างและการตรวจจ็บริวิปลอมของการซื้อสินค้าออนไลน์	22
5. กลุ่มแบบจำลองสำหรับการตรวจจ็บริวิปลอมโดยอิงพื้นฐานจากการสุมข้อมูลตัวอย่างการตัดคุณลักษณะและการปรับค่าพารามิเตอร์ที่เหมาะสม	22
6. การระบุกลุ่มผู้เขียนรีวิปลอมโดยใช้หลักการเรียนรู้กึ่งมีผู้สอน	23
7. ผลกระทบของการเขียนรีวิปลอมที่มีต่อเว็บอีคอมเมิร์ซในระหว่างและหลังการแพร่ระบาดของโรคโควิด-19	23
2.2.2 กลุ่มการทำนายการตรวจจ็ขาวปลอม	23
1. การจำแนกประเภทขาวปลอมโดยใช้หลักการของหน่วยความจำระยะสั้นยาวและ BERT	24
บทที่ 3 วิธีการดำเนินงานวิจัย	27
3.1 กรอบแนวคิดการวิจัย	27
3.1.1 ขั้นตอนที่ 1 : การแปลงข้อมูลให้อยู่ในรูปแบบที่คอมพิวเตอร์สามารถประมวลผลได้	27
3.1.2 ขั้นตอนที่ 2 : การสร้างแบบจำลองการวิเคราะห์ความรู้สึกจากข้อความ	29

สารบัญ (ต่อ)

	หน้า
3.2 ชุดข้อมูล	29
3.3 การออกแบบแบบจำลองในการวิเคราะห์รีวิพลอม	31
3.3.1 แบบจำลองวิเคราะห์รีวิพลอมด้วยอัลกอริทึม Generative Pre-trained Transformer 2 (GPT-2)	32
3.3.2 แบบจำลองวิเคราะห์รีวิพลอมด้วยอัลกอริทึม Naive Bayes Support Vector Machine	32
3.3.3 แบบจำลองวิเคราะห์รีวิพลอมด้วยอัลกอริทึม Robustly Optimized BERT Pretraining Approach (Roberta)	32
3.3.4 แบบจำลองวิเคราะห์รีวิพลอมด้วยอัลกอริทึม Bi-directional Long Short-Term Memory Model (BiLSTM)	33
3.4 การนิยามแบบจำลอง BiLSTM และ Roberta	34
บทที่ 4 ผลการวิจัยและการอภิปรายผล	36
4.1 ผลการทดสอบประสิทธิภาพของแต่ละอัลกอริทึม	36
4.1.1 การทดลองแบบจำลองวิเคราะห์รีวิพลอมด้วยอัลกอริทึม Generative Pre-trained Transformer 2 (GPT-2)	36
4.1.2 การทดลองแบบจำลองวิเคราะห์รีวิพลอมด้วยอัลกอริทึม Naive Bayes Support Vector Machine (NBSVM)	37
4.1.3 การทดลองแบบจำลองวิเคราะห์รีวิพลอมด้วยอัลกอริทึม Robustly Optimized BERT Pretraining Approach (Roberta)	37
4.1.4 การทดลองแบบจำลองวิเคราะห์รีวิพลอมด้วยอัลกอริทึม Bi-directional Long Short-Term Memory Model (BiLSTM)	38
4.2 ผลการทดสอบของอัลกอริทึมที่ทำการปรับค่า Hyperparameter	39
4.2.1 ผลการทดสอบของอัลกอริทึม BiLSTM	39
4.2.2 ผลการทดสอบของอัลกอริทึม Roberta	40
4.3 การอภิปรายผล	43

สารบัญ (ต่อ)

	หน้า
บทที่ 5 สรุปผลการวิจัยและข้อเสนอแนะ	45
5.1 สรุปผลการวิจัย	45
5.2 ข้อเสนอแนะ	45
เอกสารอ้างอิง	47
ประวัติผู้เขียน	49



สารบัญตาราง

ตารางที่	หน้า
2.1 ตัวอย่าง Confusion Matrix	19
2.2 แสดงการเปรียบเทียบประสิทธิภาพของงานวิจัย [4]	22
2.3 เปรียบเทียบความแตกต่างระหว่างงานวิจัยที่เกี่ยวข้อง	25
3.1 ตัวอย่างชุดข้อมูลที่ใช้ในงานวิจัย	30
3.2 รายละเอียดแบบจำลอง Roberta ตั้งต้น	33
3.3 รายละเอียดแบบจำลอง BiLSTM ตั้งต้น	34
4.1 ผลการทดลองแบบจำลองวิเคราะห์รีวิวปลอมด้วยอัลกอริทึม GPT-2	36
4.2 ผลการทดลองแบบจำลองวิเคราะห์รีวิวปลอมด้วยอัลกอริทึม NBSVM	37
4.3 ผลการทดลองแบบจำลองวิเคราะห์รีวิวปลอมด้วยอัลกอริทึม Roberta	37
4.4 ผลการทดลองแบบจำลองวิเคราะห์รีวิวปลอมด้วยอัลกอริทึม BiLSTM	38
4.5 ประสิทธิภาพของแบบจำลองที่ได้ เมื่อมีการปรับจูนค่า Learning Rate ของ BiLSTM	39
4.6 ประสิทธิภาพของแบบจำลองที่ได้ เมื่อมีการปรับจูนค่า Epochs ของ BiLSTM	40
4.7 ประสิทธิภาพของแบบจำลองที่ได้ เมื่อมีการปรับจูนค่า Batch Size ของ BiLSTM	40
4.8 ประสิทธิภาพของแบบจำลองที่ได้ เมื่อมีการปรับจูนค่า Learning Rate ของ Roberta	41
4.9 ประสิทธิภาพของแบบจำลองที่ได้ เมื่อมีการปรับจูนค่า Batch Size ของ Roberta	42
4.10 ประสิทธิภาพของแบบจำลองที่ได้ เมื่อมีการปรับจูนค่า Epochs ของ Roberta	42
4.11 ประสิทธิภาพโดยรวมของแต่ละแบบจำลอง	43

สารบัญภาพ

ภาพที่	หน้า
2.1 ตัวอย่างเข้ารหัสด้วย One-Hot encoding	5
2.2 ตัวอย่างการทำงานในเซลล์ของอัลกอริทึม โครงข่ายแบบ RNN	8
2.3 ตัวอย่างการทำงานในเซลล์ของอัลกอริทึมโครงข่ายประสาทแบบ LSTM	10
2.4 แสดงตัวอย่างการทำงานของ input gate	11
2.5 แสดงตัวอย่างการทำงานของ forget gate	12
2.6 แสดงตัวอย่างการทำงานของ Memory Cell State	13
2.7 แสดงการทำงานของ Output Gate	14
2.8 ตัวอย่าง SVM ใน 2 มิติ	18
3.1 กรอบแนวคิดวิธีการแปลงข้อมูล	28
3.2 กรอบแนวคิดการสร้างแบบจำลองสำหรับทำนายผล	29
4.1 แสดง ROC ของแต่ละแบบจำลอง	44

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

ด้วยสถานการณ์ในปัจจุบันที่ผู้คนต้องดำเนินวิถีชีวิตใหม่หรือ New Normal เนื่องจากการระบาดของไวรัสเมื่อปี 2019 จึงทำให้จากที่มนุษย์เราเคยออกจากบ้านเพื่อไปทำกิจวัตรประจำวันด้านนอก เช่นไปทำงาน ไปโรงเรียน ต้องหันมาทำทุกอย่างที่บ้านมากขึ้น การเปลี่ยนแปลงนี้ส่งผลให้มีการปรับเปลี่ยนทางด้านธุรกิจและบริการต่างๆ ให้ทันต่อสถานการณ์ในปัจจุบัน จึงทำให้มนุษย์เราหันมาทำสิ่งต่างๆ ผ่านทางช่องทางออนไลน์มากขึ้น จากผลการสำรวจมูลค่าอีคอมเมิร์ซในประเทศไทยของสำนักงานพัฒนาธุรกรรมทางอิเล็กทรอนิกส์ หรือ ETDA เผยว่า ปี 2564 มีมูลค่าเพิ่มขึ้น 6.11% จากปีก่อน ซึ่งจะเห็นได้ว่าสถานการณ์โรคระบาดโควิด-19 ถือเป็นจุดเปลี่ยนสำคัญที่ทำให้คนสังคมใช้ชีวิตเปลี่ยนไป มีการซื้อสินค้าและบริการออนไลน์เพิ่มขึ้นอย่างมาก และยังมีปัจจัยที่มีผลต่อการซื้อสินค้าและบริการออนไลน์อีกหลายอย่าง

หนึ่งในปัจจัยที่สำคัญต่อการส่งผลในการตัดสินใจซื้อสินค้าออนไลน์นั้นก็คือ การอ่านรีวิวของผู้ที่เคยซื้อสินค้าหรือใช้บริการก่อนหน้านี้ การรีวิวสินค้านั้นมีทั้งการรีวิวที่เป็นเชิงบวก กลางๆ และเชิงลบ มีทั้งการรีวิวที่ใช้ความรู้สึกหรืออารมณ์เข้ามาตัดสินตัวสินค้า มีการให้ดาวหรือเรตติ้งของสินค้า แม้ว่าบางครั้งการให้ดาวหรือเรตติ้งจะไม่สอดคล้องกับข้อความที่เขียนรีวิว หรือแม้กระทั่งการถูกจ้างให้มาเขียนรีวิวโดยเฉพาะในบุคคลที่เป็นที่นิยมหรือเป็นที่รู้จักของประชาชนเพื่อทำให้สินค้านั้นขายดี พบได้ในสื่อออนไลน์จำนวนมาก หรือการเขียนรีวิวปลอมขึ้นมาเพื่อโจมตีสินค้าคู่แข่ง หรือเขียนรีวิวปลอมขึ้นมาเพื่อโปรโมตสินค้าของตัวเอง

มีงานวิจัยที่เกี่ยวข้องกับปัญหาการเขียนรีวิวปลอมมายาวนาน ไม่ว่าจะเป็นการพิจารณาวิธีที่จะให้ผู้พิพากษาแยกความแตกต่างระหว่างคำให้การเท็จและคำให้การจริง ปัญหาการตรวจจับการโกหกหรือรีวิวปลอมได้รับการศึกษาอย่างกว้างขวาง ตัวอย่างเช่น การตรวจสอบรีวิวปลอมผ่านการวิเคราะห์คุณสมบัติทางภาษาศาสตร์ โดยดูคุณลักษณะทางภาษาที่ใช้ในการเขียนรีวิวและนำมาตรวจจับการเขียนรีวิวปลอม ชุดข้อมูลที่ใช้คือรีวิวร้านอาหาร การเรียนรู้แบบกึ่งมีผู้สอนในการตรวจจับรีวิวปลอม โดยจะใช้หลักการของการเรียนรู้แบบกึ่งมีผู้สอนกับชุดข้อมูลรีวิวโรงแรม การสร้างและตรวจจับรีวิวปลอมของสินค้าออนไลน์ โดยจะใช้หลักการการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก ในการสร้างรีวิวปลอมและการตรวจจับรีวิวปลอม ชุดข้อมูลที่ใช้คือ Amazon Review Data (2018) เป็นต้น อย่างไรก็ตามงานวิจัยเหล่านี้ยังขาดการประยุกต์ใช้กับการเตรียมข้อมูลในส่วนต่างๆ เช่น การตัดคำ, การตัดอักขระพิเศษ, การใช้เทคนิคการแยกคำตามความสำคัญของคำ และการทดลองกับแบบจำลองที่มีความหลากหลายทั้งที่เป็นการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก

ดังนั้นงานวิจัยนี้มุ่งเน้นไปที่การเปรียบเทียบกระบวนการการวิเคราะห์ความรู้สึกในบทวิจารณ์เว็บอีคอมเมิร์ซเพื่อตรวจสอบรีวิวปลอมโดยจะใช้ชุดข้อมูลมาตรฐานจาก Amazon Review Data (2018) และนำมาเข้ากระบวนการเตรียมข้อมูล การทำความสะอาดข้อมูล การวิเคราะห์ความรู้สึกและการตรวจสอบรีวิวปลอม และจะทำการเปรียบเทียบแบบจำลองที่สร้างขึ้นโดย เพื่อใช้ในการพิจารณาแบบจำลองที่ให้ค่าความแม่นยำสูงเพื่อช่วยให้ผู้บริโภคหรือผู้ซื้อสินค้ามั่นใจว่าตนได้ตัดสินใจเกี่ยวกับการซื้อสินค้านั้นๆ ไม่ได้ซื้อเพราะเป็นการถูกชักจูงจากการเขียนรีวิวปลอม และเพื่อให้เจ้าของสินค้าจะได้นำข้อความรวิวนั้นไปใช้ในการปรับปรุงสินค้าได้อย่างถูกต้อง และตอบโจทย์ความต้องการของลูกค้ามากขึ้น ไม่ใช่พัฒนาสินค้าจากรีวิวปลอมที่อาจจะต้องการโจมตีสินค้าต่างๆที่สินค้าอาจจะได้อยู่แล้วก็เป็นได้

1.2 วัตถุประสงค์ของงานวิจัย

- 1) เพื่อศึกษาการเรียนรู้เทคนิคที่ใช้ในการตรวจสอบรีวิวปลอมของแต่ละแบบจำลอง
- 2) เพื่อเปรียบเทียบประสิทธิภาพโดยรวมของแต่ละแบบจำลองที่เลือกมาใช้ในการตรวจสอบรีวิวปลอม

1.3 ขอบเขตของงานวิจัย

- 1) สามารถวิเคราะห์คุณลักษณะของรีวิวจริงและรีวิวปลอมได้
- 2) สามารถจำแนกรีวิวจริงและรีวิวปลอมได้

1.4 ประโยชน์ที่คาดว่าจะได้รับ

- 1) สามารถทราบรู้เทคนิคที่ใช้ในการตรวจสอบรีวิวปลอม
- 2) สามารถเปรียบเทียบประสิทธิภาพและความแม่นยำของแบบจำลองที่สร้างขึ้น

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

งานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษาและเรียนรู้เทคนิคที่ใช้ในการตรวจจบบรีวิพลอมและทำการเปรียบเทียบประสิทธิภาพและความแม่นยำของแบบจำลองที่สร้างขึ้น โดยข้อมูลที่ผู้วิจัยเลือกใช้ในการทดสอบประสิทธิภาพนั้นคือชุดข้อมูลมาตรฐาน Amazon Review Data (2018) dataset งานวิจัยนี้ได้เลือกตัวแบบที่ใช้ในการพยากรณ์โดยใช้กระบวนการหลักคือการวิเคราะห์ความรู้สึก (Sentiment Analysis) จากข้อความรีวิวสินค้าทั้งในเชิงบวกและเชิงลบทั้งการรีวิวที่ตัวสินค้าหรือการรีวิวที่แบรนด์ของสินค้าก็ตาม จากนั้นนำมาเข้ากระบวนการเตรียมข้อมูลเพื่อการวิเคราะห์ข้อความ (Text Preprocessing) และทำการคัดเลือกคุณสมบัติที่มีความสำคัญ (Features Importance) ในการตรวจสอบว่าข้อความนั้นเป็นรีวิพลอมหรือไม่ โดยงานวิจัยนี้จะใช้แบบจำลองในการพยากรณ์ทั้งหมด 4 แบบ คือ Generative Pre-trained Transformer 2 (GPT-2) , นาอิวเบย์กับซัพพอร์ตเวกเตอร์แมชชีน (Naive Bayes, Support Vector Machine), Robustly Optimized BERT Pretraining Approach (RoBERTa) , Bi-directional Long Short-Term Memory Model (BiLSTM)) ทั้งนี้พบว่าม้งานวิจัยที่เกี่ยวข้องกับการตรวจจบบรีวิพลอมโดยทำการสร้างรีวิพลอมและการทำการตรวจจบบรีวิพลอม ซึ่งงานวิจัยดังกล่าวได้นำเสนอแนวทางการนำเทคนิคที่ช่วยในสร้างรีวิพลอมและการตรวจจบบรีวิพลอม ดังนั้นจึงสามารถนำแนวคิดที่ได้จากการศึกษางานวิจัยมาประยุกต์ใช้เพื่อเป็นแนวทางสำหรับงานวิจัยนี้ ซึ่งก่อนที่จะเข้าสู่กระบวนการและขั้นตอนของการดำเนินงานวิจัย ผู้วิจัยได้ทำการศึกษาทฤษฎีและงานวิจัยที่เกี่ยวข้องดังต่อไปนี้

2.1 ทฤษฎีที่เกี่ยวข้อง

2.1.1 การวิเคราะห์ความรู้สึก (Sentiment Analysis)

Sentiment Analysis หมายถึง การวิเคราะห์อารมณ์และความรู้สึกทั้งในแง่บวกหรือแง่ลบ ที่ได้แสดงออกมาผ่านตัวอักษรหรือข้อความต่างๆ เช่น การรีวิวภาพยนตร์ การรีวิวร้านอาหาร การรีวิวสินค้าออนไลน์ เป็นต้น อีกทั้งยังเป็นวิธีที่มีประสิทธิภาพในการประเมินภาษาเขียนหรือภาษาพูดเพื่อที่จะได้ทำการตัดสินใจว่าการแสดงออกทางความคิดเห็นนั้นเป็นไปในเชิงบวก เชิงลบ กลาง ๆ หรือเป็นสิ่งที่สร้างขึ้นมาเพื่อหลอกลวงหรือโน้มน้าว

เพื่อจุดประสงค์ใดจุดประสงค์หนึ่ง และด้วยประโยชน์ของการวิเคราะห์ความรู้สึกนี้จึงสามารถทำให้ธุรกิจหรือแบรนด์สินค้าต่าง ๆ นำไปใช้ในการวิเคราะห์ความรู้สึกของลูกค้าที่มีต่อสินค้าหรือบริการต่าง ๆ ของธุรกิจว่าเป็นอย่างไร เพื่อที่จะสามารถนำไปพัฒนาหรือปรับปรุงให้ดียิ่งขึ้น

การวิเคราะห์ความรู้สึกเป็นส่วนหนึ่งของ Natural Language Processing ซึ่งจะเป็นเทคนิคที่ใช้สำหรับการจำแนกข้อความออกเป็นกลุ่มโดยส่วนใหญ่จะเป็นการวิเคราะห์เพื่อหาว่าข้อความนั้นแสดงถึงอารมณ์ในรูปแบบใด และการวิเคราะห์ความรู้สึกนั้นได้มีการนำไปประยุกต์ใช้ในงานด้านต่างๆ โดยในปัจจุบันนั้นสามารถสังเกตได้ง่ายที่สุดคือ การใช้งานในแพลตฟอร์มของการซื้อขายสินค้าผ่านระบบอีคอมเมิร์ซ ที่มีการใช้การวิเคราะห์ความรู้สึกในการตัดสินใจความคิดเห็นต่อสินค้าว่าเป็นไปในทิศทางใด เป็นต้น

2.1.2 กระบวนการเตรียมข้อมูลเพื่อการวิเคราะห์ข้อความ (Text Preprocessing)

Text Pre-processing หมายถึง กระบวนการปรับเปลี่ยนข้อมูลหรือการจัดเตรียมข้อมูลให้อยู่ในรูปแบบที่สามารถนำไปวิเคราะห์ได้อย่างถูกต้อง หรือเป็นการทำความสะอาดข้อมูลให้พร้อมที่จะนำไปใช้งาน ซึ่งขั้นตอนนี้ถือว่าเป็นส่วนที่สำคัญมากอย่างหนึ่งในกระบวนการทำวิจัยนี้ เพื่อเป็นการสร้างประสิทธิภาพในการวิเคราะห์ข้อมูลที่ดี และเป็นการลดความซับซ้อนในการวิเคราะห์ของแบบจำลอง โดยในการวิเคราะห์รูปแบบของกระบวนการวิเคราะห์ความรู้สึกนั้น จะมีขั้นตอนในการจัดเตรียมข้อมูลหรือทำความสะอาดข้อมูลในรูปแบบต่าง ๆ โดยทางผู้วิจัยได้ทำการเลือกวิธีในการจัดเตรียมข้อมูลหรือทำความสะอาดข้อมูลโดยมีพื้นฐานจากภาษาอังกฤษ เช่น การปรับตัวอักษรให้เป็นตัวพิมพ์เล็กทั้งหมด ซึ่งจะทำให้ระบบประมวลผลสามารถเข้าใจตัวอักษรนั้นในรูปแบบที่ไปในทิศทางเดียวกัน และการลบอักขระพิเศษหรือลบลักษณะต่างๆออกไปจากชุดข้อมูล การตัดข้อความหรือประโยคออกเป็นคำ การลบคำที่เป็นตัวจบประโยคทิ้งไป และการหาประเภทของคำ เช่น คำนาม คำกริยา

1. Tokenization

Tokenization คือขั้นตอนในการจัดเตรียมข้อมูลโดยทำการตัดข้อความหรือประโยคออกเป็นคำ ทำให้อยู่ในรูปของคำเดี่ยวหรือกลุ่มคำตามที่เราสงใจ จากนั้นจะทำการรวมกลุ่มคำที่แตกต่างกันและทำการนับจำนวนคำที่เราสนใจที่อยู่ในชุดข้อมูล และก็จะกลายเป็น Token ซึ่ง Token เหล่านี้มักจะถูกนำไปใช้งานวิเคราะห์ทางภาษาอื่น ๆ ต่อไป โดยการทำให้ Tokenization นั้น พยางค์หรือคำไม่เพียงแต่มีความหมายในตัวเองนั้น แต่เมื่อมีการนำศัพท์มาต่อกันจะทำให้เกิดความหมายของคำใหม่ซึ่งจะมีความหมายที่มีความเฉพาะเจาะจงมากขึ้น ทำให้สามารถเพิ่มความสำคัญให้กับข้อความหรือประโยคนั้นในส่วนที่เราสนใจได้ และยังสามารถทำการวิเคราะห์ชุดรูปแบบเหล่านี้โดยวิเคราะห์ในรูปแบบของ N-gram ซึ่งเป็นการกำหนดการตัดคำในรูปของคำที่อยู่ติดกันให้อยู่ในรูปของ Token

โดยจะถือว่าคำ 2 คำที่อยู่ติดกันนั้นจะไม่ใช่ตัวเดียวกันกับ Token ที่มาจากคำที่แยกกันและนำมารวมกัน โดย N-gram ที่นิยมใช้ในการวิเคราะห์นั้น ได้แก่ 1-gram หรือ Mono-gram เป็นการวิเคราะห์คำแต่ละคำ และ 2-gram หรือ Bi-gram เป็นการวิเคราะห์คำที่อยู่ติดกัน 2 คำ โดยการสร้าง Tokenization จะต้องทำการวิเคราะห์ข้อมูลข้อความในมุมมองที่หลากหลาย จึงต้องมีการออกแบบคลังคำศัพท์ที่ได้จากการทำ Tokenization

2. Bag of words

Bag of Words เป็นวิธีการในการสร้างคุณลักษณะของข้อความขึ้นมาโดยใช้หลักการของ One-Hot Encoding ในการเข้ารหัสข้อมูลในทุกคำของชุดข้อมูล โดยในการเข้ารหัสนั้นเป็นการเข้ารหัสผ่าน Token ที่ได้ทำการสร้างเอาไว้แล้ว โดยแทนค่าด้วย 1 เมื่อคำเหล่านั้นปรากฏขึ้นในชุดข้อมูล และแทนค่าด้วย 0 เมื่อคำเหล่านั้นไม่ปรากฏในชุดข้อมูล ดังภาพที่ 2.1



id	color
1	Red
2	Blue
3	Green
4	blue

id	color_red	color_blue	color_green
1	1	0	0
2	0	1	0
3	0	0	1
4	0	1	0

ภาพที่ 2.1 ตัวอย่างเข้ารหัสด้วย One-Hot encoding

Bag of Words เป็นวิธีการที่ใช้ในการแปลงข้อความให้อยู่ในรูปที่คอมพิวเตอร์สามารถนำไปประมวลผลได้ง่ายที่สุด และยังเป็นพื้นฐานของอัลกอริทึมอื่น ๆ ด้วย โดย Bag of Words เป็นการนำ Token ที่ได้จากการทำ Tokenization มาประยุกต์ใช้ร่วมกับความรู้ทางด้านสถิติในการรวบรวมข้อมูลของคำในข้อความ โดยจะทำการสร้างคลังคำศัพท์จากชุดข้อมูลที่เราจะใช้ในการวิเคราะห์ โดยส่วนใหญ่คลังคำศัพท์นั้นจะถูกจัดเรียงตามลำดับของ Token มีจำนวนมากที่สุดไปน้อยที่สุด จากนั้นจะทำการกำหนดคีย์หลักสำหรับแทนค่าของ Token นั้น ๆ เพื่อนำไปใช้ในการวิเคราะห์ต่อไป ซึ่งการนำ Bag of Words ไปใช้ประโยชน์มีหลากหลายรูปแบบด้วยกัน โดยสามารถนำไปใช้ประโยชน์ทั้งในด้านของการวิเคราะห์ข้อมูล เพื่อใช้ในการสร้างคลังคำศัพท์หรือกลุ่มคำที่มีการใช้งานมากที่สุด และนำมาสร้างแบบจำลอง

การใช้งาน Bag of Words นั้นยังติดปัญหาในส่วนของการนับจำนวนคำศัพท์อย่างเดียวแต่ไม่ได้มีการนับจำนวนของเอกสารที่คำนั้นปรากฏ ซึ่งทำให้เกิดปัญหาในส่วนของคำที่ปรากฏพบเป็นจำนวนมากในเอกสารเพียงชุดเดียวหรือพบเป็นจำนวนน้อย ๆ ทำให้การวิเคราะห์ข้อมูลออกมาแล้วสูญเสียความแม่นยำบางส่วนในชุดข้อมูล จึงได้มีการนำ Term Frequency – Invert Document Frequency เข้ามาช่วย โดยรายละเอียดจะอธิบายในหัวข้อถัดไป

3. Term Frequency – Invert Document Frequency

Term Frequency – Invert Document Frequency (TF-IDF) ได้มีการพัฒนามาจาก Bag of Words ซึ่งเป็นเทคนิคการคัดแยกคำตามความสำคัญโดยการให้น้ำหนักคำในแต่ละคำ โดยใช้ปัจจัยหลักๆในการทำคือ TF และ IDF โดยจะมีสูตรการคำนวณดังสมการที่ 2.1 และ 2.2 ดังนี้

$$TF(t, d) = \log(1 + \text{freq}(t, d)) \quad (2.1)$$

เมื่อ TF(t,d) แทนฟังก์ชัน Term Frequency
t แทนจำนวนคำที่ปรากฏใน Document
d แทนจำนวนคำทั้งหมดใน Document

$$IDF(t) = \log \left[\frac{(1 + n)}{(1 + DF(t))} \right] + 1 \quad (2.2)$$

เมื่อ IDF แทนฟังก์ชัน Invert Document Frequency
t แทนจำนวนคำที่ปรากฏใน Document
d แทนจำนวนคำทั้งหมดใน Document
D แทน Document ทั้งหมดชุดข้อมูล

สมการข้างต้นสามารถแบ่งการคำนวณออกเป็น 2 ส่วนได้แก่ ส่วน Term Frequency ดังสมการที่ 2.1 และ ส่วน Invert Document Frequency ดังสมการที่ 2.2 โดยในส่วนของ Term Frequency จำทำการคำนวณของ Token แต่ละตัวว่ามีความสำคัญอย่างไร จากนั้นทำการคำนวณ Invert Document Frequency เพื่อค้นหาว่าคำศัพท์นั้นไปปรากฏอยู่บ่อยเท่าใดในชุดข้อมูลทั้งหมดของ Token จากนั้นจึงทำการนำค่าที่ได้จากทั้ง 2 สมการมาคำนวณหาค่าคะแนนความสำคัญของ Token เพื่อทำการจัดลำดับความสำคัญดังสมการที่ 2.3

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$\text{TFIDF}(t, d, D) = \text{TF}(t, d) \times \text{IDF}(t, D) \quad (2.3)$$

เมื่อ	$\text{TFIDF}(t, d, D)$	แทนฟังก์ชัน Term Frequency – Invert Document Frequency
	$\text{TF}(t, d)$	แทนฟังก์ชัน Term Frequency
	$\text{IDF}(t, D)$	แทนฟังก์ชัน Invert Document Frequency
	t	แทนจำนวนคำที่ปรากฏใน Document
	d	แทนจำนวนคำทั้งหมดใน Document
	D	แทน Document ทั้งหมดชุดข้อมูล

4. Word Embedding

Word Embedding คือการสร้างเวกเตอร์คุณลักษณะ (Feature Vector) ขึ้นมาจาก Token ที่เราได้ทำการสร้างไว้ โดยทำการสร้างเวกเตอร์คุณลักษณะขึ้นมาจากประโยคหรือเอกสารที่มีอยู่ในข้อมูลของเราเพื่อทำการสร้างคุณลักษณะที่อยู่ในรูปของตัวเลขที่สามารถนำไปใช้ในการคำนวณต่อได้ ซึ่งลักษณะเด่นของเวกเตอร์คุณลักษณะที่ได้จาก Word Embedding นั้นจะสามารถนำไปใช้คำนวณความคล้ายคลึงกับคำอื่นๆ ในบริบทของคำที่แตกต่างกันได้ ซึ่งจะทำการสร้างเวกเตอร์คุณลักษณะ โดยเริ่มจากการเข้ารหัสคำแต่ละคำด้วยวิธีการแบบ One-Hot encoding โดยการนำจำนวนคำที่ปรากฏขึ้นมาในชุดข้อมูล และนำประโยคในชุดข้อมูลหรือเอกสารที่เราได้ทำการกำหนดไว้ในชุดข้อมูลมาเข้ารหัส ทำให้ได้เวกเตอร์ตามจำนวนคำในประโยคที่กำหนดจำนวน Dimension หรือ Features ของ Vector ได้ ซึ่งจากผลของเวกเตอร์คุณลักษณะที่ได้จาก Word Embedding นั้น จะสามารถหาความสัมพันธ์ได้ผลคูณของเวกเตอร์คุณลักษณะของคำ เพื่อหาค่าของความคล้ายคลึงกันของคำ (Word Similarity)

5. Word2Vec


Word2Vec คือแบบจำลองที่ใช้สร้าง word embedding ซึ่งก็คือการแสดง “คำ” ให้อยู่ในรูปของ “vector” ซึ่งจะได้ใช้ One-Hot Encoding ในการสร้างตัวเลข vector แบบเดิมแล้ว แต่ Word2Vec จะใช้วิธีการคำนวณตัวเลขของคำนั้นๆ จากบริบทรอบๆ คำนั้น และเนื่องจากการทำ Word2Vec มีการนำ vector 2 ตัวมาดอทกันหรือมาคูณ นั่นก็หมายถึงการหาค่าความคล้ายกันของ 2 vector หรือที่เรียกว่า PMI (point-wise mutual information) ดังนั้นเราจึงสามารถหาค่าความคล้ายกันของคำ (Word similarity) ได้ด้วยวิธีนี้อีกด้วย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.1.3 โครงข่ายประสาทเทียมแบบวนกลับ Recurrent Neural Network

โครงข่ายประสาทเทียมแบบวนกลับ Recurrent Neural Network (RNN) เป็นอัลกอริทึมของการเรียนรู้เชิงลึกซึ่งใช้หลักการวิเคราะห์ข้อมูลในรูปแบบของอนุกรมลำดับเหตุการณ์ (Sequence) ซึ่งข้อมูลในรูปแบบนี้จะมีลำดับของเหตุการณ์ที่ชัดเจน และสามารถเปลี่ยนบริบทของเหตุการณ์ตามลำดับได้โดยตัวอย่างข้อมูลในลักษณะนี้ได้แก่พวกข้อมูลหุ้น ที่มีการเก็บบันทึกประจำวัน ข้อมูลที่อยู่ในรูปแบบของอนุกรมเวลา (Time Series) และข้อมูลข้อความต่าง ๆ เป็นต้น

RNN ได้รับการพัฒนาเพิ่มเติมมาจากเดิมที่โครงข่ายประสาทเทียมนั้นจะมีการป้อนค่า Input เข้าไปแล้วได้ค่า Output ออกมา โดย RNN ได้ทำการออกแบบใหม่ให้สามารถนำค่า Output ไปคำนวณย้อนกลับเป็น Input ได้อีกครั้ง ดังแสดงในภาพที่ 2.2



ภาพที่ 2.2 ตัวอย่างการทำงานในเซลล์ของอัลกอริทึม โครงข่ายแบบ RNN

ที่มา : <https://www.i2tutorials.com/>

จากภาพที่ 2.2 โครงข่ายประสาทแบบ RNN นั้นจะมีโครงสร้างที่แตกต่างจากโครงข่ายประสาทเทียม โดยโครงสร้างของ RNN ที่เล็กที่สุดจะเรียกว่า Cell โดย Cell ของ RNN นั้นจะมีทั้งในส่วนของ Hidden State ที่ใช้ในการเก็บข้อมูลการวิเคราะห์จากข้อมูลในชุดที่ผ่านมา เพื่อใช้ในการวิเคราะห์ในตัวเองต่อไป ซึ่งในการปรับค่าพารามิเตอร์ต่าง ๆ นั้น RNN จะใช้วิธีการป้อนข้อมูลแบบย้อนกลับเพื่อทำการปรับค่าพารามิเตอร์ต่างๆในแบบจำลองที่ได้ทำการพัฒนาขึ้น โดยใช้หลักการกฎของลูกโซ่ (Chain Rule) ในการปรับค่าพารามิเตอร์ โดยทำการคำนวณเพื่อหาค่า Gradient ที่ได้จาก Error สำหรับการปรับพารามิเตอร์ของแบบจำลอง ดังสมการที่ 2.4 และ 2.5

$$h_t = f(W_{xh}x_t + W_{hh}h_{t-1} + b_h) \quad (2.4)$$

$$\hat{y}_t = g(W_{yh}h_t + b_y) \quad (2.5)$$

เมื่อ	h_t	แทนค่า Hidden State ของหน่วยเวลา
	f	แทนฟังก์ชันสำหรับคำนวณค่า Hidden State ของหน่วยเวลา
	W_{xh}	แทนค่าน้ำหนักสำหรับคำนวณค่า Input ใน Hidden State
	x_t	แทนค่า Input ของข้อมูล
	W_{hh}	แทนค่าน้ำหนักสำหรับคำนวณค่า Hidden จากหน่วยเวลาก่อนหน้าใน Hidden State
	h_{t-1}	แทนค่า Hidden State จากหน่วยเวลาก่อนหน้า
	b_h	แทน Bias สำหรับคำนวณค่า Hidden State
	$\hat{y}_t$	แทนค่า Output ที่ได้จากแบบจำลอง RNN
	g	แทนฟังก์ชันสำหรับคำนวณค่า Output
	W_{yh}	แทนค่าน้ำหนักสำหรับคำนวณค่า Hidden State
	b_y	แทนค่า Bias สำหรับคำนวณค่า Output

จากสมการที่ 2.4 ในการปรับค่าพารามิเตอร์ในส่วนของ Hidden State นั้น ได้เกิดปัญหาขึ้นจากการใช้งานโครงข่ายประสาทเทียมแบบ RNN ได้เนื่องจากการกำหนดลำดับของข้อมูลที่มีขนาดยาวเกินไป ทำให้ค่า Gradient มีค่าลดลงจนไม่สามารถเห็นการเปลี่ยนแปลงได้ จึงทำให้โครงข่ายประสาทแบบ RNN นั้นมีข้อจำกัดในการใช้งานวิเคราะห์ข้อมูลที่มีความยาวที่มากเกินไป


โครงข่ายแบบ RNN ได้รับความนิยมนำไปใช้งานกับข้อมูลที่อยู่ในรูปของข้อความอย่างมากโดยเฉพาะการประยุกต์ใช้ทางด้านของ Language Modeling และ Machine Translation ซึ่งเป็นเพราะการมองข้อความให้อยู่ในรูปแบบข้อมูลแบบลำดับ และการทำการวิเคราะห์โดยคำนึงถึงตำแหน่งของ Input ทำให้ RNN สามารถวิเคราะห์ข้อมูลข้อความได้อย่างมีประสิทธิภาพ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.1.4 หน่วยความจำระยะสั้นยาว (Long Short-Term Memory Model)


จากหัวข้อของ RNN ในการนำไปใช้งานจริงพบว่าเกิดปัญหาขึ้นจากการใช้ลำดับของข้อมูลในการวิเคราะห์ที่มีจำนวนมากเกินไป ทำให้ค่า Gradient ที่ได้นั้นมีการเปลี่ยนแปลงจนไม่สามารถสังเกตการเปลี่ยนแปลงได้ และไม่สามารถนำมาวิเคราะห์ได้ ซึ่งปัญหานี้คือปัญหาของ Gradient Vanishing จึงได้ทำการปรับปรุงโครงข่ายประสาทแบบ RNN ให้สามารถแก้ปัญหาของ Gradient Vanishing ออกไปได้ โดยการเพิ่มฟังก์ชันการทำงานเพิ่มเติม คือ อัลกอริทึม Long Short-Term Memory

หน่วยความจำระยะสั้นยาว (Long Short-Term Memory Model) เป็นอัลกอริทึมที่ถูกพัฒนาต่อยอดมาจาก RNN โดยทำการแก้ไขปัญหาในส่วนของ Gradient Vanishing ด้วยการออกแบบการทำงานในส่วนของ Cell ใหม่ ให้สามารถเก็บสถานะของการคำนวณได้ โดยใน Cell ของ LSTM นั้นมีหน่วยคำนวณย่อยเรียกว่า Gate ซึ่งประกอบด้วย Input Gate , Memory Cell State Gate และ Output Gate ดังแสดงในภาพที่ 2.3



ภาพที่ 2.3 ตัวอย่างการทำงานในเซลล์ของอัลกอริทึมโครงข่ายประสาทแบบ LSTM

Input Gate เป็นหน่วยย่อยในการกำหนดข้อมูลที่จะนำเข้ามาวิเคราะห์ใน Cell โดยรับข้อมูลเข้ามาเพื่อทำการเขียนค่าลงไปในแต่ละ Cell แสดงการทำงานดังภาพที่ 2.4 และสมการที่ 2.6




ภาพที่ 2.4 แสดงตัวอย่างการทำงานของ input gate

ที่มา : <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + W_{ci}c_{t-1} + b_i) \quad (2.6)$$

เมื่อ	i_t	แทนผลลัพธ์ที่ได้จาก Input Gate
	σ	แทนฟังก์ชัน Sigmoid
	W_{xi}	แทนค่าน้ำหนักสำหรับคำนวณ Input ใน Input Gate
	x_t	แทนค่า Input ที่นำเข้ามาคำนวณ
	W_{hi}	แทนค่าน้ำหนักสำหรับคำนวณ Hidden State ใน Input Gate
	h_{t-1}	แทนค่า Hidden State ที่ได้จากการคำนวณในหน่วยเวลาก่อนหน้า
	W_{ci}	แทนค่าน้ำหนักสำหรับคำนวณ Memory Cell State ใน Input Gate
	c_{t-1}	แทนค่า Memory Cell State ที่ได้จากการคำนวณในหน่วยเวลาก่อนหน้า
	b_i	แทนค่า Bias ที่ใช้ในการคำนวณใน Input Gate

Forget Gate เป็นหน่วยย่อยที่ใช้ในการกำหนดข้อมูลที่จะนำเข้ามาวิเคราะห์ใน Cell โดยทำการกำหนดว่าข้อมูลนั้นควรที่จะถูกบันทึกหรือถูกลืม โดยสามารถกำหนดได้จากภาพที่ 2.5 และสมการที่ 2.7



ภาพที่ 2.5 แสดงตัวอย่างการทำงานของ forget gate


ที่มา : <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + W_{cf}c_{t-1} + b_f) \quad (2.7)$$

เมื่อ	f_t	แทนผลลัพธ์ที่ได้จาก Forget Gate
	σ	แทนฟังก์ชัน Sigmoid
	W_{xf}	แทนค่าน้ำหนักสำหรับคำนวณ Input ใน Forget Gate
	x_t	แทนค่า Input ที่นำเข้ามาคำนวณ
	W_{hf}	แทนค่าน้ำหนักสำหรับคำนวณ Hidden State ใน Forget Gate
	h_{t-1}	แทนค่า Hidden State ที่ได้จากการคำนวณในหน่วยเวลาก่อนหน้า
	W_{cf}	แทนค่าน้ำหนักสำหรับคำนวณ Memory Cell State ใน Forget Gate
	c_{t-1}	แทนค่า Memory Cell State ที่ได้จากการคำนวณในหน่วยเวลาก่อนหน้า
	b_i	แทนค่า Bias ที่ใช้ในการคำนวณใน Forget Gate

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Memory Cell State Gate เป็นหน่วยย่อยในการกำหนดข้อมูลที่น่าเข้ามาวิเคราะห์ใน Cell และทำการคำนวณค่าสถานะ เพื่อใช้ในการคำนวณในครั้งถัดไป โดยแสดงตัวอย่างการทำงานดังภาพที่ 2.6 และมีสมการดังสมการที่ 2.8



ภาพที่ 2.6 แสดงตัวอย่างการทำงานของ Memory Cell State


ที่มา : <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>

$$c_t = f_t * c_{t-1} + i_t * \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \quad (2.8)$$

เมื่อ	c_t	แทนค่า Memory Cell State ในช่วงหน่วยเวลา
	f_t	แทนผลลัพธ์ที่ได้จาก Forget Gate
	c_{t-1}	แทนค่า Memory Cell State จากหน่วยเวลาก่อนหน้า
	i_t	แทนผลลัพธ์ที่ได้จาก Input Gate
	$\tanh$	แทนฟังก์ชัน Hyperbolic tangent
	W_{xc}	แทนค่าน้ำหนักสำหรับคำนวณค่า Input จาก Memory Cell State Gate
	x_t	แทนค่า Input ที่นำเข้ามาคำนวณ
	W_{hc}	แทนค่าน้ำหนักสำหรับคำนวณ Hidden State ใน Memory Cell State Gate
	h_{t-1}	แทนค่า Hidden State ที่ได้มาจากการคำนวณในหน่วยเวลาก่อนหน้า
	b_c	แทนค่า Bias ที่ใช้ในการคำนวณใน Forget Gate

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Output Gate เป็นหน่วยย่อยสำหรับการคำนวณ Output ของ Cell ซึ่งผลลัพธ์ที่ได้จาก Cell นี้จะมีอยู่ 2 อย่าง ได้แก่ Output และ Hidden State สำหรับใช้ในการคำนวณครั้งถัดไป โดยแสดงตัวอย่างการทำงานดังภาพที่ 2.7 และมีสมการดังสมการที่ 2.9 และ 3.0



ภาพที่ 2.7 แสดงการทำงานของ Output Gate

ที่มา : <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + W_{co}c_{t-1} + b_o) \quad (2.9)$$

$$h_t = o_t * \tanh(c_t) \quad (3.0)$$

เมื่อ	o_t	แทนผลลัพธ์ที่ได้จาก Output Gate
	σ	แทนฟังก์ชัน Sigmoid
	W_{xo}	แทนค่าน้ำหนักสำหรับคำนวณ Input ใน Output Gate
	x_t	แทนค่า Input ที่นำเข้ามาคำนวณ
	W_{ho}	แทนค่าน้ำหนักสำหรับคำนวณ Hidden State ใน Output Gate
	h_{t-1}	แทนค่า Hidden State ที่ได้จากการคำนวณในหน่วยเวลาก่อนหน้า

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

W_{co}	แทนค่าน้ำหนักสำหรับคำนวณ Memory Cell State ใน Output Gate
c_{t-1}	แทนค่า Memory Cell State ที่ได้จากการคำนวณในหน่วยเวลาก่อนหน้า
b_o	แทนค่า Bias ที่ใช้ในการคำนวณใน Output Gate
h_t	แทนค่า Hidden State จากการคำนวณ

จากที่กล่าวมาด้านบนจะเห็นได้ว่าวงจร LSTM ประกอบไปด้วย Input Gate, Output Gate, Forget Gate, Cell State และมีขาส่งข้อมูลเวกเตอร์ออก 2 ขา ซึ่ง LSTM เหมาะที่จะใช้งานในรูปแบบที่ต้องการดูข้อมูลเป็นลำดับ นอกจาก LSTM ยังมีการทำงานแบบ BiLSTM คือสามารถวิเคราะห์บริบทของข้อมูลได้ 2 ทิศทาง ไม่เพียงแต่สามารถนำข้อมูลในอดีตมาเป็นส่วนขยายในการวิเคราะห์เท่านั้น แต่ยังสามารถนำข้อมูลในอนาคตมามีส่วนร่วมในการช่วยตัดสินใจได้อีกด้วย ด้วยเหตุนี้จึงเป็นการแก้ไขปัญหาในกรณีที่อาจมีการสูญเสียข้อมูลเมื่อมีการย้อนกลับไปปรับค่าน้ำหนัก หากมีการรับข้อมูลขาเข้าที่มีความยาวมาก ๆ ก็จะช่วยแก้ไขปัญหานี้ได้

2.1.5 Bidirectional Encoder Representations from Transformers (BERT)

Bidirectional Encoder Representations from Transformers (BERT) ถูกพัฒนาโดย Google ซึ่งก็คือ Artificial Intelligent (AI) ของ Google Algorithm เวอร์ชันใหม่ล่าสุด เหมือนเป็นเครื่องมือที่สามารถเรียนรู้ภาษามนุษย์ Natural Language Processing (NLP) ได้ดีขึ้น ทำให้สามารถวิเคราะห์และตีความหมายคำค้นต่างๆ ทั้งจากผู้ใช้งานและผู้สร้างเนื้อหาได้

BERT ต่างจากอัลกอริทึมอื่นตรงที่ถูกออกแบบมาให้เลือกใช้เฉพาะส่วนที่เป็น Encoder ซึ่งจะทำหน้าที่ในการแปลงคำในประโยคให้เปลี่ยนเป็น vector เพื่อให้ Encoder สามารถทำหน้าที่เป็น Language Model ได้ BERT จึงเพิ่มแบบจำลองอีกหนึ่งตัว ต่อจาก Encoder ที่มีอยู่เดิม เพื่อทำหน้าที่เป็น Classifier แล้วนำ vector ที่ได้จาก Encoder ไปคำนวณต่อให้ได้คำตอบในรูปแบบที่คล้ายๆ กับ Language Model ทั่วๆ ไป ดังนั้นในภาพรวมแล้ว BERT ไม่ต่างจากแบบจำลองเชิงลึกตัวอื่นๆ มากนัก ส่วนที่มีความแตกต่างที่ชัดที่สุดคือ เรื่องขนาด เนื่องจาก BERT สามารถขยายขนาดให้มีจำนวน Attention Head มากขึ้น มีจำนวน layer มากขึ้น และสามารถเพิ่มขนาด Embedding Vector เพื่อให้มั่นใจได้ว่าแบบจำลองนี้สามารถเรียนรู้คุณสมบัติทางภาษาให้ได้มากที่สุด

นอกจากขนาดแบบจำลองที่ใหญ่กว่าเดิม อีกองค์ประกอบสำคัญที่ BERT แตกต่างจากแบบจำลองตัวอื่นๆ ก็คือ Activation Function ที่มีการเปลี่ยนจาก ReLU ที่ใช้ในแบบจำลองเชิงลึกตัวอื่นๆ เป็น GELU (Gaussian Error Linear Unit) โดย GELU เป็นการเพิ่มความสามารถให้กับ ReLU เพื่อแก้ปัญหา Dead neurons ซึ่งเกิดขึ้นเมื่อข้อมูลจาก neurons มีค่าน้อยกว่าศูนย์จำนวนมาก โดยค่าที่เป็นลบเหล่านี้ จะส่งผลให้ ReLU ให้ผลลัพธ์เป็นศูนย์ไปด้วย มีผลต่อเนื่องทำให้เกิดการอัปเดตใน neurons กลุ่มนั้นไปตลอดการเทรน ดังนั้นในภาพรวมแต่ละรอบของการสอน BERT จะทำการรับคู่ของประโยคซึ่งจะมีค่าบางส่วนหายไป จากนั้น BERT ก็จะพยายามทายคำในช่องว่าง พร้อมกับทายว่าประโยคทั้ง 2 อันที่ได้รับมาเป็นประโยคที่อยู่ติดกันหรือไม่ แล้วนำคำตอบที่ได้จากทั้ง 2 คำถามไปทำการคำนวณความถูกต้อง และทำการอัปเดตแบบจำลอง ซึ่งสิ่งนี้ทำให้ BERT สามารถเรียนรู้ความสัมพันธ์ทั้งในระดับคำและระดับประโยคไปพร้อม ๆ กัน และถัดมาในปี 2019 ทาง Facebook AI Research ได้มีการนำเสนอเทคนิคการเทรนแบบจำลองทางภาษาให้มีประสิทธิภาพมากยิ่งขึ้น โดยใช้ชื่อว่า Robustly Optimized BERT Pretraining Approach (RoBERTa) ซึ่งเป็นแบบจำลองที่มีการพัฒนาต่อยอดมาจาก BERT โดยมีการแก้ไขไฮเปอร์พารามิเตอร์หลักบางตัวใน BERT มีการลบประโยคที่จะใช้ในการคำนวณถัดไปตรงส่วนของการ Pre-Train Model ออก โดยวิธีนี้ช่วยให้ประสิทธิภาพในการแยกประเภทของคำดีขึ้น

2.1.6 Generative Pre-trained Transformer (GPT-2)

Generative Pre-trained Transformer (GPT-2) เป็นหนึ่งในแบบจำลองของตระกูล Transformers ถูกพัฒนาโดย OpenAI เป็นแบบจำลองปัญญาประดิษฐ์สำหรับทำความเข้าใจภาษามนุษย์โดยใช้เพียงข้อมูลจากอินเทอร์เน็ตที่ไม่ต้องจัดรูปแบบ (label) ข้อมูลไว้ล่วงหน้า แต่ยังคงได้แบบจำลองที่สามารถทำงานได้หลากหลาย ทั้งการเขียนบทความ, ตอบคำถามแสดงความเข้าใจเนื้อหา, แปลภาษา และเขียนสรุป แบบจำลอง GPT-2 ถูกฝึกสอนโดยข้อมูลจากอินเทอร์เน็ตขนาดถึง 40 GB โดยไม่มีการจัดรูปแบบข้อมูลใด ๆ แต่จะทำการฝึกแบบจำลองด้วยเป้าหมายง่าย ๆ คือให้ทำนายคำต่อไปหลังจากที่ได้เห็นข้อความก่อนหน้านี้ ด้วยความที่แบบจำลอง GPT-2 ออกแบบมาเพื่อทำนาย “คำต่อไป” ทำให้เราสามารถใช้อย่างไรก็ได้ในการสร้างบทความได้ เพียงแค่ใส่ประโยคสั้น ๆ เข้าไป หรือสามารถใส่คำถามเข้าไป แบบจำลองนี้ก็สามารถตอบคำถามออกมาได้

ถึงแม้ในตอนแรกจะมีข้อถกเถียงกันมากมายถึงการปล่อยแบบจำลอง GPT-2 ออกมาสู่สาธารณะนั้นจะเป็นอันตรายหรือไม่ เพราะคนสามารถนำไปใช้ในการสร้างข่าวปลอมหรือรีวิวลปลอม ต่าง ๆ ได้ อย่างไรก็ตามหลังจากที่ทีม OpenAI ได้ทำการศึกษาข้อดีข้อเสียร่วมกับทีม AI อื่นๆ อีกหลายทีม ก็ได้ผลสรุปว่าข้อดีนั้นมีมากกว่าข้อเสีย จึงทำให้ทีม OpenAI ตัดสินใจเผยแพร่แบบจำลอง GPT-2 ให้คนทั่วไปได้ใช้กันมากที่สุด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.1.7 การจำแนกแบบเบย์อย่างง่าย (Naïve Bayesian Classifier)

การจำแนกแบบเบย์อย่างง่ายเป็นการจำแนกที่อาศัยทฤษฎีความน่าจะเป็นของเบย์ (Bayes' theorem) และเป็นสมมติฐานที่ให้แต่ละเหตุการณ์เป็นอิสระต่อกัน โดยสามารถคำนวณได้จากสมการที่ 3.1

$$P(h | D) = \frac{[P(D|h)*P(h)]}{P(D)} \quad (3.1)$$

$P(h | D)$ คือ ความน่าจะเป็นในการเกิดเหตุการณ์ h เมื่อเกิดเหตุการณ์ D

$P(D | h)$ คือ ความน่าจะเป็นในการเกิดเหตุการณ์ D เมื่อเกิดเหตุการณ์ h

$P(h)$ คือ ความน่าจะเป็นที่จะเกิดเหตุการณ์ h


$P(D)$ คือ ความน่าจะเป็นที่จะเกิดเหตุการณ์ D

การทำงานของอัลกอริทึมการจำแนกแบบเบย์อย่างง่าย (Naïve Bayesian Classifier) คือ การวิเคราะห์ความสัมพันธ์ระหว่างตัวแปรพยากรณ์แต่ละตัวกับตัวแปรตาม นำมาสร้างเงื่อนไขค่าความน่าจะเป็นของแต่ละความสัมพันธ์ แต่การจำแนกแบบเบย์อย่างง่ายจะมีความแม่นยำเมื่อตัวแปรพยากรณ์แต่ละตัวเป็นอิสระต่อกัน ซึ่งในทางปฏิบัติตัวแปรพยากรณ์มักพบความสัมพันธ์กันเอง นอกจากนี้การจำแนกแบบเบย์อย่างง่าย (Naïve Bayesian Classifier) ยังไม่รองรับข้อมูลตัวแปรที่เป็นค่าต่อเนื่อง ดังนั้นหากข้อมูลตัวแปรเป็นค่าต่อเนื่องจะต้องแปลงเป็นช่วงค่าที่เหมาะสมเพื่อให้การจำแนกมีความแม่นยำ

2.1.8 ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM)

ซัพพอร์ตเวกเตอร์แมชชีนเป็นอัลกอริทึมที่นำมาใช้อย่างกว้างขวางในการจำแนกกลุ่ม โดยหลักการของ SVM คือการเพิ่มมิติให้ข้อมูลตัวแปรพยากรณ์ที่ใช้ฝึกหัด โดยกลุ่มของคุณลักษณะของตัวแปรพยากรณ์ที่สามารถอธิบายตัวแปรตามได้จะเรียกว่าเวกเตอร์ (vector) จะแสดงเวกเตอร์ในรูปแบบสเปซ 2 มิติอยู่ในระนาบ xy หรือ 3 มิติในระนาบ xyz โดยทำการสร้างไฮเปอร์เพลน (hyperplane) ด้วยฟังก์ชันเคอร์เนล (kernel function) ไฮเปอร์เพลนคือเส้นตรงระนาบที่แยกกลุ่มตัวแปรตามออกจากกันได้ดีที่สุดที่นั่นหมายถึงเส้นแบ่งมีระยะห่างจากตัวแปรมากที่สุดซึ่ง SVM เป็นเทคนิคที่ช่วยในการเรียนรู้ ซึ่งมีลักษณะการทำงานคล้ายกับโครงข่ายประสาทเทียม (artificial neural network) แต่มีความแตกต่างกันคือเทคนิคโครงข่ายประสาทเทียมจะใช้หลักการลดความเสี่ยงเชิงการทดสอบให้มีค่าต่ำที่สุด (empirical risk minimization) ส่วน SVM การแก้สมการหาค่าน้ำหนักใช้ในการแก้สมการ quadratic ที่มีข้อบังคับเชิงเส้น (linear constrained) ลดความเสี่ยงเชิงโครงสร้างให้ต่ำที่สุด (Structural

risk minimization) โดย SVM ประยุกต์การใช้งานได้ 2 รูปแบบ คือการวิเคราะห์การถดถอย (regression) หรือการประมาณค่าของฟังก์ชันและการจำแนกประเภท (classification)



ภาพที่ 2.8 ตัวอย่าง SVM ใน 2 มิติ

ที่มา : <http://kokzard.blogspot.com/2011/10/jfjkdshfkjsldf.html>

2.1.9 เมทริกซ์วัดประสิทธิภาพ (Confusion Matrix)

ในการทดลองทางด้านการจำแนกประเภทของข้อมูล (Classification) จะต้องมีการวัดประสิทธิภาพการทำงานของแบบจำลอง เพื่อประเมินว่าแบบจำลองสามารถนำไปใช้งานจริงได้หรือไม่ โดยทางผู้วิจัยได้ทำการศึกษามาตรวัดต่าง ๆ ดังนี้

1.ค่าความถูกต้อง

ค่าความถูกต้อง (Accuracy) คือค่าทางสถิติที่ใช้สำหรับการเปรียบเทียบข้อมูลการทำนายผลระหว่างผลลัพธ์เป้าหมาย กับผลลัพธ์ที่ทำนายได้ ว่ามีความสัมพันธ์กันอย่างไร โดยการคำนวณค่าความถูกต้องนั้น จะต้องทำการสร้าง เมทริกซ์วัดประสิทธิภาพ (Confusion Matrix) ขึ้นมา โดยมีรายละเอียด ดังแสดงในตารางที่ 1

	Actual Positive (1)	Actual Negative (0)
Predicted Positive (1)	True Positive (TP)	False Positive (FP)
Predicted Negative (0)	False Negative (FN)	True Negative (TN)

ตารางที่ 2.1 ตัวอย่าง Confusion Matrix

จากตารางที่ 2.1 เมื่อแบ่งให้ข้อมูลมี 2 ประเภท ได้แก่ข้อมูลด้านบวก (Positive) และข้อมูลด้านลบ (Negative) สามารถอธิบายค่าต่าง ๆ ของ Confusion Matrix ออกได้เป็น 4 กรณี ได้แก่

1. True Positive (TP) หมายถึงจำนวนข้อมูลที่ได้ทำการทำนายว่าเป็นจริงและผลลัพธ์จริงมีค่าเป็นจริง
 2. False Positive (FP) หมายถึงจำนวนข้อมูลที่ได้ทำการทำนายว่าเป็นจริงแต่ผลลัพธ์จริงมีค่าเป็นเท็จ
 3. False Negative (FN) หมายถึงจำนวนข้อมูลที่ได้ทำการทำนายว่าเป็นเท็จแต่ผลลัพธ์จริงมีค่าเป็นจริง
 4. True Negative (TN) หมายถึงจำนวนข้อมูลที่ได้ทำการทำนายว่าเป็นเท็จและผลลัพธ์จริงมีค่าเป็นเท็จ
- จากข้อมูลข้างต้น สามารถนำมาคำนวณค่าความแม่นยำ เพื่อหาค่าความถูกต้องของแบบจำลอง ได้ดังสมการ 3.2

$$\text{Accuracy} = \frac{TP+TN}{TP+FP+FN+TN} \quad (3.2)$$

2. ค่าความเที่ยง

ค่าความเที่ยง (Precision) เป็นค่าที่ใช้สำหรับการวัดประสิทธิภาพในการทำนายของแบบจำลอง โดยคำนวณจาก TP เทียบกับกลุ่มของข้อมูลที่ทำนายเป็นด้านบวกทั้งหมด (TP + FP) ดังสมการ 3.3

$$\text{Precision} = \frac{TP}{TP+FP} \quad (3.3)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3. ค่าความไวหรือค่าระลึก

ค่าความไว หรือค่าระลึก (Recall) เป็นค่าที่ใช้สำหรับการวัดประสิทธิภาพในการทำนายของแบบจำลอง โดยคำนวณจากค่า TP เทียบกับกลุ่มของข้อมูลที่มีผลลัพธ์เป้าหมายเป็นจริงทั้งหมด ดังสมการที่ 3.4

$$\text{Recall} = \frac{TP}{TP + FN} \quad (3.4)$$

4.ค่าเฉลี่ยของ Precision และ Recall

ค่าเฉลี่ยของ Precision และ Recall (F-measure) เป็นค่าที่ใช้สำหรับการวัดประสิทธิภาพในการทำนายของแบบจำลอง โดยคำนวณจากค่าเฉลี่ย Precision และ Recall โดยสามารถคำนวณได้จากสมการที่ 3.5

$$\text{F-measure} = 2 * \left(\frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \right) \quad (3.5)$$

2.2 งานวิจัยที่เกี่ยวข้อง

จากการศึกษางานวิจัยที่เกี่ยวข้อง พบว่ามีงานวิจัยที่ศึกษาเกี่ยวกับแบบจำลองที่ใช้ในการตรวจจับรีวิวปลอมในหลายๆรูปแบบ ทั้งการเรียนรู้แบบมีผู้สอนและการเรียนรู้แบบกึ่งมีผู้สอน โดยการสร้างแบบจำลองนั้นได้มีการศึกษาทั้งในส่วนของการออกแบบและพัฒนาอัลกอริทึมเพื่อใช้ในการตรวจจับรีวิวปลอม สามารถทำความเข้าใจได้ และการออกแบบและพัฒนาอัลกอริทึมที่ใช้สำหรับสร้างแบบจำลอง โดยงานวิจัยที่เกี่ยวข้องที่ได้ทำการศึกษาและสามารถแบ่งออกเป็น 2 กลุ่ม คือกลุ่มงานวิจัยด้านการทำนายการตรวจจับรีวิวปลอมและกลุ่มการทำนายการตรวจจับข่าวปลอม นอกจากนี้ยังได้เปรียบเทียบความแตกต่างของงานวิจัยที่เกี่ยวข้องทั้งหมดที่ได้ทำการศึกษามา โดยอธิบายรายละเอียดได้ดังนี้

2.2.1 กลุ่มงานวิจัยด้านการทำนายการตรวจจับรีวิวปลอม

งานวิจัยกลุ่มนี้นำเสนอวิธีการในการสร้างแบบจำลองที่นำมาใช้ในการทำนายการตรวจจับรีวิวปลอม ในชุดข้อมูลที่มีความแตกต่างกัน เช่น ชุดข้อมูลรีวิวจากเว็บอีคอมเมิร์ซ ชุดข้อมูลรีวิวจากโรงแรม ชุดข้อมูลรีวิวจากร้านอาหาร ชุดข้อมูลรีวิวที่เป็นมาตรฐานจาก Yelp , Amazon , TripAdvisor โดยมีการประยุกต์ใช้การทำการ

วิเคราะห์ความรู้สึกและการเลือกคุณลักษณะที่สำคัญ ซึ่งได้มีการใช้การเรียนรู้ของเครื่องจักรด้วยวิธีการต่างๆ สามารถอธิบายรายละเอียดแต่ละงานวิจัยได้ดังนี้

1.การวิเคราะห์ความคิดเห็นตามภววิทยาสำหรับการตรวจจบบรีวปลอม (Ontology based sentiment analysis for fake review detection)

งานวิจัยนี้ [1] มีจุดประสงค์ที่จะทำการตรวจจบบรีวปลอมในเว็บอีคอมเมิร์ซ โดยใช้หลักการของภววิทยา (Ontology based) และใช้หลักการของคุณลักษณะทางภาษารวมถึงคุณลักษณะที่เกี่ยวข้องกับการเขียนรีวปลอม โดยผู้วิจัยได้ทำการเปรียบเทียบประสิทธิภาพการทำนายโดยดูจากความสัมพันธ์ของคุณลักษณะที่สำคัญ พบว่าคุณลักษณะทางภาษารวมกับการแบ่งประเภทของคำและการวิเคราะห์ความรู้สึกรวมกัน ส่งผลให้การทำนายมีความแม่นยำถึง 88.98%

2. การทบทวนการนำการเรียนรู้แบบกึ่งมีผู้สอนสำหรับการตรวจจบบรีวปลอม (Revisiting Semi-Supervised Learning for Online Deceptive Review Detection)

งานวิจัยนี้ [2] ได้ทำการทดลองนำชุดข้อมูลของรีวโรงแรม 1,600 ข้อความรีวจากทั้งหมด 20 โรงแรมในชิคาโก ประเทศอังกฤษ พบว่ามีข้อความรีวที่เป็นของจริง 800 ข้อความรีว และข้อความรีวที่เป็นของปลอม 800 ข้อความรีว โดยผู้วิจัยได้ทำการเปรียบเทียบประสิทธิภาพการทำนายด้วยกันทั้งหมด 4 วิธี ได้แก่ เคเนียร์เรสเนเบอร์ การถดถอยโลจิสติก ต้นไม้ตัดสินใจ และ Stochastic Gradient Descent (SGD) ซึ่งผลการทดลองแสดงให้เห็นว่าวิธีการถดถอยโลจิสติกให้ประสิทธิภาพดีกว่าวิธีการจำแนกประเภทอื่นๆ ที่นำมาเปรียบเทียบ โดยให้ค่าความถูกต้องอยู่ที่ 83%

3.การตรวจจบบรีวปลอมผ่านการวิเคราะห์คุณสมบัติทางภาษา (Fake Reviews Detection through Analysis of Linguistic Features)

งานวิจัยนี้ [3] มีจุดประสงค์เพื่อต้องการวิเคราะห์คุณสมบัติทางภาษาเพื่อใช้ในการตรวจจบบรีวปลอม โดยทำการทดลองกับชุดข้อมูล 2 ชุด คือ 1.ชุดข้อมูลร้านอาหารที่ทำการเก็บมาจากช่องทางออนไลน์ซึ่งเป็นชุดข้อมูลที่เป็นรีวจริง และ 2.ชุดข้อมูลจาก เว็บไซต์ Amazon ที่เกี่ยวกับสินค้า ซึ่งเป็นรีวปลอม และได้ทำการเลือกใช้คุณลักษณะ 2 ประเภทด้วยกัน ได้แก่ 1.) คุณสมบัติของคำศัพท์ 77 คำ รวมถึง 46 ตัวอักษรพิเศษ และ 31 คำพื้นฐานที่ได้จากจำนวนและความยาวของ Token 2.) 157 คุณลักษณะที่เกี่ยวข้องกับการสร้างประโยค รวมถึง 7 อักษรพิเศษ เช่น ! , @ เป็นต้น และ 150 ฟังก์ชันของคำที่เกิดขึ้น ในการทดลองได้ใช้อัลกอริทึม ซัพพอร์ตเวกเตอร์แมชชีน , นาอ์ฟเบย์, ต้นไม้ตัดสินใจ , การถดถอยโลจิสติก , ป่าสุ่ม , Extreme Gradient-Boosting Trees (XGBT),

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Multilayer Perceptron (MLP) ซึ่งผลการทดลองแสดงให้เห็นว่าวิธี MLP ให้ประสิทธิภาพดีกว่าวิธีการจำแนกประเภทอื่น ๆ ที่นำมาเปรียบเทียบโดยให้ค่าความถูกต้องอยู่ที่ 79.09%

4. การสร้างและการตรวจจับรีวิวปลอมของการซื้อสินค้าออนไลน์ (Creating and detecting fake reviews of online products)

งานวิจัยนี้ [4] ได้ทดลองนำชุดข้อมูลรีวิวสินค้าจาก 10 ประเภทสินค้าอันดับแรกใน Amazon ซึ่งข้อความรีวิวส่วนใหญ่จะเกี่ยวกับ หนังสือ เสื้อผ้า รองเท้า เครื่องประดับ สินค้าที่ใช้ภายในบ้านและห้องครัว อุปกรณ์ไฟฟ้า หรือเครื่องใช้ไฟฟ้า อุปกรณ์กีฬา อุปกรณ์สัตว์เลี้ยง เครื่องมือหรืออุปกรณ์ปรับปรุงบ้าน ของเล่นและเกม ซึ่งชุดข้อมูลดังกล่าวคิดเป็น 88.4% ของข้อความรีวิวพื้นฐานที่มาจากชุดข้อมูลพื้นฐานจาก Amazon ซึ่งทางผู้วิจัยได้ทำการเปรียบเทียบประสิทธิภาพของการทำนายการตรวจจับรีวิวปลอม ดังแสดงในตารางที่ 2

Predictive performance of the classification models. Highest performance highlighted.

Model	Precision ^a	Recall ^b	F1-score ^c
OpenAI	0.83	0.82	0.82
NBSVM	0.95	0.95	0.95
fakeRoBERTa	0.97	0.97	0.97

ตารางที่ 2.2 แสดงการเปรียบเทียบประสิทธิภาพของงานวิจัย [4]

จากตารางที่ 2.2 จะเห็นได้ว่าแบบจำลอง BERT ให้ประสิทธิภาพดีที่สุดในทุกมาตรวัดจึงทำให้ผู้วิจัยเห็นถึงข้อดีและแนวคิดในการที่จะนำแบบจำลองดังกล่าวมาใช้ในการงานวิจัย

5. กลุ่มแบบจำลองสำหรับการตรวจจับรีวิวปลอมโดยอิงพื้นฐานจากการสุ่มชุดข้อมูลตัวอย่าง การตัดคุณลักษณะและการปรับค่าพารามิเตอร์ที่เหมาะสม (An Ensemble Model for Fake Online Review Detection Based on Data Resampling, Feature Pruning, and Parameter Optimization)

งานวิจัยนี้ [5] ได้ทำการทดลองการตรวจจับรีวิวปลอมโดยเน้นไปในส่วนของการทำข้อมูลให้สมดุล โดยมีการใช้หลักการของ SMOTE และ RUS เข้ามาช่วยจัดการในส่วนนี้ มีการตัดคุณลักษณะที่ไม่สำคัญต่อการทำนายออกโดยทำการตัดคุณลักษณะที่ไม่สำคัญออกและวัดประสิทธิภาพของการทำนาย ถ้าประสิทธิภาพของการทำนายไม่มีการเปลี่ยนแปลงผู้วิจัยก็จะทำการตัดคุณลักษณะนั้นออก และสุดท้ายได้มีการปรับค่าพารามิเตอร์ให้เหมาะสม ซึ่งได้นำมาทดสอบกับชุดข้อมูลที่เป็นรีวิวปลอมจาก crowdsourcing โดยใช้ชุดข้อมูล Yelp จากโรงแรมและร้านอาหาร ชุดข้อมูลประกอบไปด้วยรีวิวโรงแรม 85 แห่งในชิคาโก และชุดข้อมูลร้านอาหาร 130 แห่งในชิคาโก และในการ

ทดลองได้ใช้อัลกอริทึม 4 อัลกอริทึม ได้แก่ ป่าสุ่ม ซัพพอร์ตเวกเตอร์แมชชีน หน่วยความจำระยะสั้นยาว โครงข่ายประสาทเทียมแบบวนกลับ ซึ่งผลการทดลองพบว่าอัลกอริทึมป่าสุ่มให้ประสิทธิภาพที่สุดจากอัลกอริทึมทั้งหมดที่นำมาเปรียบเทียบ

6.การระบุกลุ่มผู้เขียนรีวิวปลอมโดยใช้หลักการการเรียนรู้กึ่งมีผู้สอน (Identifying Groups of Fake Reviewers Using a Semi-supervised Approach)

งานวิจัยนี้ [6] มีจุดประสงค์เพื่อศึกษาและทำการจัดกลุ่มการเขียนรีวิวปลอมในขอบเขตของแอปพลิเคชัน โดยนำชุดข้อมูลมาจาก Google Play Store จากทั้งหมด 640 แอปพลิเคชัน 38,123 รีวิว พบว่ามีรีวิวปลอม 2,207 ข้อความ โดยอัลกอริทึมที่ใช้ในการเปรียบเทียบประสิทธิภาพในการทดลองมีทั้งหมด 4 อัลกอริทึม ได้แก่ ซัพพอร์ตเวกเตอร์แมชชีน เคเนียร์เรสเนเบอร์ ป่าสุ่ม J48 ซึ่งผลการทดลองแสดงให้เห็นว่าวิธีเคเนียร์เรสเนเบอร์ ให้ประสิทธิภาพที่ดีกว่าอัลกอริทึมประเภทอื่นที่นำมาเปรียบเทียบ

7. ผลกระทบของการเขียนรีวิวปลอมที่มีต่อเว็บอีคอมเมิร์ซในระหว่างและหลังการแพร่ระบาดของโรคโควิด-19 (The Effect of Fake Reviews on e-Commerce During and After Covid-19 Pandemic: SKL-Based Fake Reviews Detection)

งานวิจัยนี้ [7] มีจุดประสงค์เพื่อศึกษาผลกระทบของการเขียนรีวิวปลอมโดยทดลองกับชุดข้อมูล Yelp จากข้อมูลการรีวิวโรงแรม 20 โรงแรม โดยมีชุดข้อมูลทั้งหมด 1900 ข้อความรีวิว ซึ่งพบว่าเป็นรีวิวจริง 950 ข้อความรีวิวและอีก 950 รีวิวที่เหลือเป็นรีวิวปลอม และได้ทำการแบ่งกลุ่มของข้อมูลออกเป็นเชิงบวกและเชิงลบ ซึ่งผู้วิจัยได้กล่าวว่าการทำคุณลักษณะทางวิศวกรรมไม่ได้มีผลต่อการช่วยตรวจจับรีวิวปลอมมากนัก ใช้อัลกอริทึม และได้ทำการเปรียบเทียบประสิทธิภาพโดยใช้ 3 อัลกอริทึม ได้แก่ ซัพพอร์ตเวกเตอร์แมชชีน การถดถอยโลจิสติก เคเนียร์เรสเนเบอร์ จากผลการทดลองพบว่าเมื่อนำทั้งสามอัลกอริทึมมารวมกันจะให้ประสิทธิภาพในการทดลองสูงที่สุด คือได้ค่าความถูกต้องอยู่ที่ 95%

2.2.2 กลุ่มการทำนายการตรวจจับข่าวปลอม

งานวิจัยกลุ่มนี้นำเสนอวิธีการในการสร้างแบบจำลองเพื่อใช้ในการตรวจจับข่าวปลอม โดยประยุกต์ใช้การทำเหมืองข้อมูล การวิเคราะห์ความรู้สึกและการเรียนรู้ของเครื่องจักรด้วยวิธีการต่าง ๆ ซึ่งสามารถอธิบายรายละเอียดแต่ละงานวิจัยได้ดังนี้

1.การจำแนกประเภทข่าวปลอมโดยใช้หลักการของหน่วยความจำระยะสั้นยาวและ BERT (Fake News Classification using transformer based enhanced LSTM and BERT)

งานวิจัยนี้ [8] มีจุดประสงค์เพื่อเสนอวิธีการตรวจจับข่าวปลอมโดยแบ่งประเภทตามหัวข้อข่าวและเนื้อหาข่าว โดยผู้วิจัยได้ทำการเปรียบเทียบประสิทธิภาพการทำนายโดยใช้แบบจำลองหน่วยความจำระยะสั้นยาว BERT และกรวมแบบจำลองหน่วยความจำระยะสั้นยาวกับ BERT เข้าด้วยกัน โดยทำการทดลองบนชุดข้อมูล 2 ชุด ได้แก่ PolitiFact และ Gossip Cop ซึ่งผลการทดลองพบว่าการรวมแบบจำลองหน่วยความจำระยะสั้นยาวกับ BERT เข้าด้วยกันเป็นวิธีที่มีประสิทธิภาพในการทำนายการตรวจจับข่าวปลอม

จากงานวิจัยต่าง ๆ ที่ผู้วิจัยได้ทำการศึกษาพบว่า การสร้างแบบจำลองทางด้านการวิเคราะห์ความรู้สึกเพื่อตรวจจับรีวิวปลอมด้วยข้อมูลข้อความรีวีนั้น ต้องใช้ความรู้ด้าน Natural Language Processing มาประยุกต์ใช้งาน โดยจะต้องทำการสร้าง Feature สำหรับนำไปใช้ในการเรียนรู้ของอัลกอริทึมทางด้านการเรียนรู้ของเครื่องซึ่งเป็นส่วนสำคัญของงานวิจัยต่างๆที่ได้ศึกษา โดยในส่วนของ การคัดแยกคุณลักษณะนั้น จะสามารถแบ่งออกได้เป็น 2 กลุ่ม โดยเป็นกลุ่มของการสร้างคุณลักษณะสำหรับใช้งานกับอัลกอริทึมทางด้านการเรียนรู้ของเครื่องเช่น TF-IDF และการสร้างคุณลักษณะสำหรับใช้งานกับอัลกอริทึมทางด้านการเรียนรู้เชิงลึก เช่น Word Embedding เป็นต้น นอกจากนี้ในส่วนของการสร้างแบบจำลองสำหรับการตรวจจับรีวิวปลอม นั้น อัลกอริทึม Support Vector Machine สามารถให้ประสิทธิภาพในการทำนายที่สูงกับงานวิจัยในอดีต แต่ในปัจจุบันพบว่าอัลกอริทึมจำพวก การเรียนรู้เชิงลึก เช่น หน่วยความจำระยะสั้นยาว , โครงข่ายประสาทเทียมแบบสังวัตนาการ และ Bidirectional Encoder Representations from Transformers เป็นต้น ได้ให้ประสิทธิภาพในการทำนายที่สูงกว่าเป็นอย่างมาก แต่ทั้งนี้ทั้งนั้นก็ยังมีปัจจัยอีกหลายประการที่สามารถช่วยเพิ่มประสิทธิภาพในการทำนายที่สูง เช่น การทำ Text Preprocessing และการเลือกคุณลักษณะที่สำคัญก็มีผลต่อประสิทธิภาพในการทำนายเช่นกัน

ซึ่งจากงานวิจัยที่เกี่ยวข้องทั้งหมดที่ได้กล่าวมาข้างต้น ทุกงานวิจัยมีจุดประสงค์เพื่อนำเสนอแบบจำลองในการตรวจจับรีวิวปลอมและข่าวปลอม แต่ก็ยังมีความแตกต่างกัน คือ วิธีการสร้างแบบจำลอง มาตรวัดและการประเมินผลแบบจำลอง ทางผู้วิจัยจึงได้จัดทำตารางการเปรียบเทียบความแตกต่างระหว่างงานวิจัยที่เกี่ยวข้องทั้ง 2 กลุ่ม ดังแสดงในตารางที่ 2.3

ตารางที่ 2.3 เปรียบเทียบความแตกต่างระหว่างงานวิจัยที่เกี่ยวข้อง

งานวิจัย	วัตถุประสงค์	เทคนิคที่ใช้	มาตรวัดที่ใช้ในการประเมินผล
กลุ่มงานวิจัยด้านการทำนายการตรวจจบบรีวปลอม			
[1] Ontology based sentiment analysis for fake review detection	ตรวจจบบรีวปลอมในเว็บอีคอมเมิร์ซ โดยใช้หลักการของภววิทยา (Ontology based) และใช้หลักการของคุณลักษณะทางภาษารวมถึงคุณลักษณะที่เกี่ยวข้องกับการเขียนรีวปลอม	1.Text Preprocessing 2.Linguistic Feature 3.POS Feature Extraction 4.Ontology Management	1. Accuracy 2. Precision 3. Recall 4. F-measure
[2] Revisiting Semi-Supervised Learning for Online Deceptive Review Detection	ตรวจจบบรีวปลอมโดยทำการทดลองนำชุดข้อมูลของรีวโรงแรม 1,600 ข้อความรีวจากทั้งหมด 20 โรงแรมในชิคาโก ประเทศอังกฤษ	1.เคเนียร์เรสเนเบอร์ 2.การถดถอยโลจิสติก 3.ต้นไม้ตัดสินใจ 4. Stochastic Gradient Descent (SGD)	1. Accuracy 2. Precision 3. Recall 4. F-measure
[3] Fake Reviews Detection through Analysis of Linguistic Features	วิเคราะห์คุณสมบัติทางภาษาเพื่อใช้ในการตรวจจบบรีวปลอม	1.ซัพพอร์ตเวกเตอร์แมชชีน 2.นาอ์ฟเบย์ 3.ต้นไม้ตัดสินใจ 4.การถดถอยโลจิสติก 5.ป่าสุ่ม 6. XGBT 7. MLP	1. Accuracy 2. F-measure
[4] Creating and detecting fake reviews of online products	ทดลองนำชุดข้อมูลรีวสินค้าจาก 10 ประเภทสินค้าอันดับแรกใน Amazon มาทำการเปรียบเทียบประสิทธิภาพของการทำนายการตรวจจบบรีวปลอม	1.OpenAI 2.NBSVM 3.fakeRoBERTTa	1.Precision 2.Recall 3.F-measure

ตารางที่ 2.3 เปรียบเทียบความแตกต่างระหว่างงานวิจัยที่เกี่ยวข้อง (ต่อ)

งานวิจัย	วัตถุประสงค์	เทคนิคที่ใช้	มาตรวัดที่ใช้ในการประเมินผล
[5] An Ensemble Model for Fake Online Review Detection Based on Data Resampling, Feature Pruning, and Parameter Optimization	ทดลองการตรวจจับรีวิวปลอม โดยเน้นไปในส่วนของการทำข้อมูลให้สมดุล โดยมีการใช้หลักการของ SMOTE และ RUS เข้ามาช่วยจัดการ	1.ป่าสุ่ม 2.ซัพพอร์ตเวกเตอร์แมชชีน 3.หน่วยความจำระยะสั้นยาว 4.โครงข่ายประสาทเทียมแบบวนกลับ	1.Precision 2.Recall 3.F-measure
[6] Identifying Groups of Fake Reviewers Using a Semi-supervised Approach	เพื่อศึกษาและทำการจัดกลุ่มการเขียนรีวิวปลอมในขอบเขตของแอปพลิเคชัน	1.ซัพพอร์ตเวกเตอร์แมชชีน 2.เคเนียร์เรสเนเบอร์ 3.ป่าสุ่ม 4.J48	1. Accuracy
[7] The Effect of Fake Reviews on e-Commerce During and After Covid-19 Pandemic: SKL-Based Fake Reviews Detection	เพื่อศึกษาผลกระทบของการเขียนรีวิวปลอมโดยทดลองกับชุดข้อมูล Yelp จากข้อมูลการรีวิวโรงแรม	1.ซัพพอร์ตเวกเตอร์แมชชีน 2.การถดถอยโลจิสติก 3.เคเนียร์เรสเนเบอร์	1.Accuracy 2.Precision 3.Recall 4.F-measure
กลุ่มการทำนายการตรวจจับข่าวปลอม			
[8] Fake News Classification using transformer based enhanced LSTM and BERT	เสนอวิธีการตรวจจับข่าวปลอม โดยแบ่งประเภทตามหัวข้อข่าว และเนื้อหาของข่าว	1.หน่วยความจำระยะสั้นยาว 2. BERT	1.Accuracy 2.Precision 3.Recall 4.F-measure

บทที่ 3

วิธีการดำเนินงานวิจัย

งานวิจัยนี้มีเป้าหมายในการเปรียบเทียบตัวแบบพยากรณ์ต่างๆ เพื่อใช้ในการตรวจจับรีวิพลอม ด้วยวิธีการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก

3.1 กรอบแนวคิดการวิจัย

แนวคิดหลักของงานวิจัยนี้คือการเปรียบเทียบตัวแบบพยากรณ์ต่างๆ โดยการนำเทคนิคการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก มาใช้ในการตรวจจับรีวิพลอม สามารถแบ่งกรอบแนวคิดการวิจัยออกเป็น 2 ขั้นตอนหลัก ได้แก่ ขั้นตอนที่ 1 การแปลงข้อมูลให้อยู่ในรูปแบบที่คอมพิวเตอร์สามารถประมวลผลได้ และขั้นตอนที่ 2 การออกแบบและพัฒนาอัลกอริทึมสำหรับสร้างแบบจำลองเพื่อใช้ในการทำนายผล

3.1.1 ขั้นตอนที่ 1 : การแปลงข้อมูลให้อยู่ในรูปแบบที่คอมพิวเตอร์สามารถประมวลผลได้

ขั้นตอนแรกของงานวิจัยคือการแปลงชุดข้อมูลข้อความที่ได้ ให้อยู่ในรูปแบบของตัวเลขเข้ารหัส ที่คอมพิวเตอร์สามารถนำไปใช้ประมวลผลต่อได้ และทำการนำข้อมูลที่ได้ไปใช้ในการวิเคราะห์ต่อไป โดยจะต้องแปลงสภาพข้อมูลให้ได้คุณลักษณะที่เหมาะสมกับอัลกอริทึมที่เลือกใช้ด้วย ซึ่งมีขั้นตอนแสดงดังรูปที่ 3.1


จากรูปที่ 3.1 กรอบแนวคิดวิธีการแปลงข้อมูลประกอบไปด้วยขั้นตอนย่อย 3 ขั้นตอนดังนี้

1.การทำความสะอาดข้อมูล (Text Cleaning) เป็นขั้นตอนในการทำความสะอาดข้อความต่างๆ สำหรับข้อมูลที่อยู่ในรูปแบบข้อความนั้น จะเป็นการแก้ไขรายละเอียดคำในส่วนที่สะกดผิดเป็นส่วนใหญ่ หรือการปรับตัวอักษรของคำให้อยู่ในรูปแบบเดียวกัน เช่นตัวพิมพ์เล็กในภาษาอังกฤษเนื่องจากคอมพิวเตอร์จะเข้าใจตัวอักษรพิมพ์ใหญ่ และพิมพ์เล็กว่าแตกต่างกัน ไม่ใช่ตัวเดียวกัน เช่น ‘A’ กับ ‘a’ เป็นต้น และการลบสัญลักษณ์ต่างๆ ที่อยู่ในชุดข้อมูลออกไป

2.การสร้างคลังคำศัพท์ (Vocabulary) เป็นขั้นตอนในการสร้างคลังคำศัพท์สำหรับการวิเคราะห์ โดยทำการรวบรวมคำที่มีอยู่ในประโยคและทำการสร้างคลังคำศัพท์โดยทำการนำคำที่แตกต่างกันมาใช้ในการสร้าง ซึ่งสามารถกำหนดขอบเขตของคำที่ใช้ในการศึกษาได้โดยการกำหนดจำนวนคำที่แสดงผลมากที่สุดในช่วงข้อมูล เพื่อลดข้อมูลในส่วนที่ไม่จำเป็นในการวิเคราะห์ออกไป

3.การแปลงข้อความ (Text Transformation) เป็นขั้นตอนที่ใช้ในการแปลงคำต่างๆให้อยู่ในรูปแบบที่คอมพิวเตอร์สามารถนำไปใช้ในการประมวลผลต่อได้ ซึ่งจะต้องทำการแปลงข้อมูลก่อนที่จะนำมาใช้วิเคราะห์ด้วยอัลกอริทึมของการเรียนรู้เชิงลึกและการเรียนรู้ของเครื่อง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




ภาพที่ 3.1 กรอบแนวคิดวิธีการแปลงข้อมูล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.1.2 ขั้นตอนที่ 2 : การสร้างแบบจำลองการวิเคราะห์ความรู้สึกจากข้อความ

การดำเนินการในขั้นตอนที่ 2 จะเป็นการดำเนินงานในส่วนของการนำข้อความที่ได้ทำการแปลงสภาพให้อยู่ในรูปที่คอมพิวเตอร์สามารถทำความเข้าใจได้แล้ว หลังจากนั้นจะทำการฝึกสอนโดยใช้อัลกอริทึมทั้งการเรียนรู้เชิงลึกและการเรียนรู้ของเครื่อง จากนั้นนำมาวัดประสิทธิภาพของแบบจำลอง โดยมีกรอบแนวคิดดังรูปที่ 3.2



ภาพที่ 3.2 กรอบแนวคิดการสร้างแบบจำลองสำหรับทำนายผล

3.2 ชุดข้อมูล

งานวิจัยนี้ได้ทำการเลือกใช้ชุดข้อมูลกรณีศึกษาของการแสดงความคิดเห็นต่อสินค้าบนเว็บไซต์ amazon.com ซึ่งได้ทำการรวบรวมโดย Jianmo Ni, Jiacheng Li, Julian McAuley (2019) ซึ่งชุดข้อมูลดังกล่าว นั้นเปิดให้ใช้งานในรูปแบบสาธารณะ โดยมีชื่อชุดข้อมูลว่า Amazon Review Data (2018) ซึ่งเป็นชุดข้อมูลที่น่าเชื่อถือและใช้กันอย่างกว้างขวาง โดยในส่วนของข้อมูลจะเป็นการดึงข้อมูล 10 หมวดหมู่แรก ของสินค้าที่มียอดขายสูงสุด ในเว็บไซต์ amazon.com ปี พ.ศ. 2561 และทำการสอนแบบจำลองเพื่อที่จะนำมาสร้างชุดข้อมูลในการตรวจจับรีวิวปลอม ซึ่งหมวดหมู่นั้นประกอบไปด้วยหมวดหมู่ ความงาม 5,269 ข้อความ , ยานยนต์ 1,711,519

ข้อความ , บัตรของขวัญ 2,972 ข้อความ , สมัครงานชกนิตยสาร 2,375 ข้อความ, แฟชั่น 3,176 ข้อความ , ซีดีและไวนิล 1,443,755 ข้อความ , ร้านขายของชำและอาหารสเลิศ 1,143,860 ข้อความ , เครื่องดนตรี 231,392 ข้อความ , เครื่องใช้ 2,277 ข้อความ , โทรศัพท์มือถือและอุปกรณ์เสริม 1,128,437 ข้อความ , อุตสาหกรรมและวิทยาศาสตร์ 77,071 ข้อความ , ผลิตภัณฑ์สำนักงาน 800,357 ข้อความ , ศิลปหัตถกรรมและการตัดเย็บ 494,485 ข้อความ , เพลงดิจิตอล 169,781 ข้อความ , สินค้าหรูหราและสวยงาม 34,278 ข้อความ , ลานบ้าน สนามหญ้าและสวน 798,415 ข้อความ หลังจากนั้นได้มีการนำมาเข้ากระบวนการเตรียมข้อมูลเบื้องต้นและทำการจัดเรียงหมวดหมู่ใหม่ทำให้มีหมวดหมู่ดังนี้ Books , (Clothing ,shoes ,and Jewelry) , Electronics, Home and Kitchen , Kindle Store, Movies and TV , Pet Supplies, Sports and Outdoors , Tools and Outdoors , Tools and Home Improvement , Toy and Games รวมทั้งหมด 40,432 ตัวอย่าง ภายในชุดข้อมูลจะถูกแบ่งประเภทออกเป็น 2 กลุ่ม คือ

1. ข้อความที่ถูกสร้างขึ้นโดยคอมพิวเตอร์หรือแบบจำลองที่ใช้ในการสร้างรีวิวปลอมขึ้นมา แทนด้วย CG (Computer Generate)
2. ข้อความที่เป็นข้อความรีวิวจริงๆมนุษย์เป็นคนสร้างขึ้นโดยสันนิษฐานว่าเป็นรีวิวจริง แทนด้วย OR (Original Reviews)

โดยข้อมูลการแสดงความคิดเห็นในกลุ่ม CG มีจำนวน 20,216 แถว และกลุ่ม OR มีจำนวน 20,216 แถว แสดงออกมาเป็นตารางที่มีจำนวน 4 คอลัมน์ ดังตารางที่ 3.1

ตารางที่ 3.1 ตัวอย่างชุดข้อมูลที่ใช้ในงานวิจัย

Category	Rating	label	text
Home_and_Kitchen_5	1	CG	Missing information on how to use it, but it is a great product for the price! I
Clothing_Shoes_and_Jewelry_5	3	OR	Fits well and easy to convert with semi formal wear
Electronics_5	5	CG	Easy to install even without a power supply. Easy to use. Great product! Works

Books_5	4	OR	It's witty and intriguing. I hang on to every word.
Kindle_Store_5	5	CG	This book I can't wait for more by this author. I will definitely be reading the next one
Movies_and_TV_5	1	OR	Remarkably flat and wooden dialog; must have taken some doing.
Pet_Supplies_5	2	CG	The holes are too big the fence receiver slipped out
Sports_and_Outdoors_5	4	OR	Excellent jacket shirt a bit larger than I expected though.
Tools_and_Home_Improvement_5	5	CG	Nice modern look for the price. The only problem is that it comes with a small screw driver.
Toys_and_Games_5	3	OR	Smaller then we thought. Grand daughter enjoyed painting it.

3.3 การออกแบบแบบจำลองในการวิเคราะห์รีวิพลอม

งานวิจัยฉบับนี้จะใช้แบบจำลองทั้งหมด 4 แบบจำลองในการเปรียบเทียบประสิทธิภาพในการตรวจจับรีวิพลอม ได้แก่ Generative Pre-trained Transformer 2 (GPT-2) , นาอ์ฟเบย์กับซัพพอร์ตเวกเตอร์แมชชีน (Naive Bayes Support Vector Machine), Robustly Optimized BERT Pretraining Approach (Roberta) , Bi-directional Long Short-Term Memory Model (BiLSTM) โดยมีขั้นตอนในการทดลอง ดังนี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.3.1 แบบจำลองวิเคราะห์รีวิวปลอมด้วยอัลกอริทึม Generative Pre-trained Transformer 2 (GPT-2)

งานวิจัยนี้ทางผู้วิจัยได้นำแบบจำลอง GPT-2 มาใช้ในการทำนายรีวิวปลอม อีกทั้งยังเป็นแบบจำลองที่ใช้ในการสร้างรีวิวปลอมขึ้นมาอีกด้วย โดยในงานวิจัยนี้จะกล่าวถึงแค่ในส่วนของการนำแบบจำลองมาตรวจจับรีวิวปลอม ซึ่งแบบจำลอง GPT-2 เป็น Language Models แบบ Unsupervised Multitask Learners แต่เราจะเอามาประยุกต์ใช้กับ Supervised Learners เนื่องจากชุดข้อมูลของเรามีการทำความสะดวกข้อมูลเบื้องต้นและแปะ Label มาเรียบร้อยแล้ว จากนั้นนำข้อความมาทำการสร้าง keras Tokenizer Object เพื่อให้ได้ Bag of word ของจำนวนคำทั้งหมด โดยใช้ฟังก์ชัน tokenizer ใน python แล้วนำมาหาความยาวสูงสุดของคำในประโยคเพื่อนำมาทำ padding พร้อมทั้งทำการแปลงคำแต่ละคำในประโยคให้เป็นตัวเลข และทำการเติมเลขศูนย์เข้าไปเพื่อให้ทุกประโยคมีความยาวเท่ากัน นอกจากนี้ก่อนนำข้อมูลเข้าสู่แบบจำลองจะทำการแบ่งข้อมูลออกเป็น Train 80% และ Test 20% จากนั้นทำการทดสอบประสิทธิภาพการทำนายและบันทึกผล

3.3.2 แบบจำลองวิเคราะห์รีวิวปลอมด้วยอัลกอริทึม Naive Bayes Support Vector Machine

งานวิจัยนี้ทางผู้วิจัยได้เลือกแบบจำลอง Naive Bayes Support Vector Machine มาใช้ในการทำนายรีวิวปลอม เนื่องจากเป็นแบบจำลองการเรียนรู้ของเครื่องที่ได้รับความนิยมและใช้กันอย่างมากในงานทางด้าน natural language processing (NLP) เนื่องจากมีประสิทธิภาพในการทนทานสูง จากนั้นทำการเตรียมข้อมูลเพิ่มเติมโดยมีการตัดอักขระพิเศษออกจากข้อความรีวิว และมีการประยุกต์ใช้ bag of word เพื่อจำแนกกลุ่มของคำหรือข้อความ หลังจากนั้นได้สร้างคุณลักษณะ target ขึ้นมา ซึ่งเป็นการนำคุณลักษณะของ label มาแปลงเป็น target โดยกำหนดให้ OR (รีวิวจริง) มีค่าเท่ากับ 1 และ CG (รีวิวปลอม) มีค่าเท่ากับ 0 นอกจากนี้ก่อนนำข้อมูลเข้าสู่แบบจำลองจะทำการแบ่งข้อมูลออกเป็น Train 80% และ Test 20% จากนั้นทำการทดสอบประสิทธิภาพการทำนายและบันทึกผล

3.3.3 แบบจำลองวิเคราะห์รีวิวปลอมด้วยอัลกอริทึม Robustly Optimized BERT Pretraining Approach (Roberta)

งานวิจัยนี้ทางผู้วิจัยได้เลือกแบบจำลอง Robustly Optimized BERT Pretraining Approach (Roberta) มาใช้ในการทำนายรีวิวปลอม ซึ่งเป็นแบบจำลองที่มีการพัฒนาต่อยอดมาจาก BERT โดยมีการแก้ไขไฮเปอร์พารามิเตอร์หลักบางตัวใน BERT มีการลบประโยคที่จะใช้ในการคำนวณถัดไปตรงส่วนของการ Pre-Train Model ออก โดยวิธีนี้ช่วยให้ประสิทธิภาพในการแยกประเภทของคำดีขึ้น ทั้งนี้ในส่วนของการเทรนแบบจำลอง (Train Model) จะมีการกำหนดแบบจำลองตั้งต้นของแบบจำลอง Robustly Optimized BERT Pretraining Approach

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

(Roberta) ดังตารางที่ 3.2 โดยเริ่มการเทรนแบบจำลองที่ค่า Dropout = 0.10 หลังจากนั้นจะมีการปรับจูน Hyperparameters ต่าง ๆ เพื่อใช้ในการเปรียบเทียบและวิเคราะห์ประสิทธิภาพแบบจำลอง ในกรณีที่มีการปรับเปลี่ยนค่าพารามิเตอร์การเพิ่มจำนวนรอบของการเทรนแบบจำลอง ตลอดจนการเปลี่ยนแปลงค่า Dropout จะส่งผลต่อประสิทธิภาพของแบบจำลองหรือไม่ หากมีการส่งผลจะส่งผลอย่างไร เพื่อเป็นการค้นหาแบบจำลองที่ดีที่สุดในการตรวจจับรีวิพลอม นอกจากนี้ก่อนนำข้อมูลเข้าสู่แบบจำลองจะทำการแบ่งข้อมูลออกเป็น Train 80% และ Test 20% จากนั้นทำการทดสอบประสิทธิภาพการทำนายและบันทึกผล

ตารางที่ 3.2 รายละเอียดแบบจำลอง Roberta ตั้งต้น

Hyperparameter	ค่าที่ใช้
Optimizer	Adam
Learning Rate	0.00001
Epochs	1
Batch Sizes	8

3.3.4 แบบจำลองวิเคราะห์รีวิพลอมด้วยอัลกอริทึม Bi-directional Long Short-Term Memory Model (BiLSTM)

งานวิจัยนี้ทางผู้วิจัยได้เลือกแบบจำลอง Bi-directional Long Short-Term Memory Model (BiLSTM)

มาใช้ในการทำนายรีวิพลอม เนื่องจากทางผู้วิจัยได้ทำการศึกษางานวิจัยที่เกี่ยวข้องกับการตรวจจับรีวิพลอม พบว่ามีงานวิจัยที่ใช้แบบจำลอง BiLSTM ในขอบเขตงานการตรวจจับรีวิพลอมค่อนข้างพบได้น้อย จึงถือว่าเป็นความท้าทายอย่างหนึ่งที่เลือกแบบจำลองนี้ในงานวิจัยฉบับนี้ อีกทั้งแบบจำลองนี้ยังช่วยลดการสูญเสียของข้อมูลเมื่อมีการย้อนกลับไปปรับค่าน้ำหนัก จึงเลือกใช้แบบจำลอง BiLSTM ซึ่งเป็นแบบจำลองที่สามารถวิเคราะห์บริบทของข้อมูลได้ 2 ทิศทาง ไม่เพียงนำข้อมูลในอดีตมามีส่วนช่วยในการวิเคราะห์เท่านั้น แต่ยังสามารถนำข้อมูลในอนาคตมามีส่วนช่วยในการตัดสินใจอีกด้วย อีกทั้งยังเป็นการแก้ปัญหาในกรณีที่อาจมีการสูญเสียข้อมูลเมื่อมีการย้อนกลับไปปรับค่าน้ำหนัก หากมีการรับข้อมูลขาเข้าที่มีความยาวมาก ๆ ได้ พร้อมประยุกต์แบบจำลองเข้ากับการทำ NLK ช่วยในการตัดคำกับตัดประโยค และมีการเตรียมข้อมูลก่อนเข้าแบบจำลองเพิ่มเติมโดยการตัดอักขระพิเศษ และมีการทำ stop word removal คือการนำคำที่เราพบโดยทั่วไปในข้อความแต่ไม่ได้ช่วยสื่อความหมาย

ออก เช่นคำว่า a , and , the , also , just เป็นต้น เพื่อใช้ในการเปรียบเทียบและวัดประสิทธิภาพของแบบจำลองที่เหมาะสมในแต่ละชุดข้อมูล นอกจากนี้ก่อนนำข้อมูลเข้าสู่แบบจำลองจะทำการแบ่งข้อมูลออกเป็น Train 80% และ Test 20% จากนั้นทำการทดสอบประสิทธิภาพการทำนายและบันทึกผล ทั้งนี้ในส่วนของการเทรนแบบจำลอง (Train Model) จะมีการกำหนดแบบจำลองตั้งต้นของแบบจำลอง Bi-directional Long Short-Term Memory Model (BiLSTM) ดังตารางที่ 3.3 โดยเริ่มการเทรนแบบจำลองที่ค่า Dropout = 0.5 หลังจากนั้นจะมีการปรับจูน Hyperparameters ต่างๆเพื่อใช้ในการเปรียบเทียบและวิเคราะห์ประสิทธิภาพแบบจำลอง ในกรณีที่มีการปรับเปลี่ยนค่าพารามิเตอร์การเพิ่มจำนวนรอบของการเทรนแบบจำลอง ตลอดจนการเปลี่ยนแปลงค่า Dropout จะส่งผลต่อประสิทธิภาพของแบบจำลองหรือไม่

ตารางที่ 3.3 รายละเอียดแบบจำลอง BiLSTM ตั้งต้น

Hyperparameter	ค่าที่ใช้
Loss Function	Binary Cross Entropy
Optimizer	Adam
Learning Rate	0.01
Epochs	5
Batch Sizes	128

3.4 การนิยามแบบจำลอง BiLSTM และ Roberta

สำหรับการนิยามแบบจำลองนั้น จะมีการกำหนดแบบจำลองให้เป็นแบบ Sequential และมีการใช้ Optimizer แบบ Adam ในการกำหนดชั้นของ layer โดยจะมีการเรียงลำดับ ดังนี้

- 1) Input Layer: ชั้นสำหรับการป้อนข้อมูลเข้า
- 2) Embedding Layer: ใช้สำหรับการฝังคำ
- 3) Bidirectional Layer: BiLSTM จะใช้ค่าพารามิเตอร์ (Parameter) 150
- 4) Dense Layer: กำหนดขนาดมิติเป็นขนาด 32 และ Activation เป็น Relu
- 5) Dropout Layer: ทำการสุ่มปิดโหนดบางตัวในระบบ เพื่อลดความซับซ้อนของข้อมูล
- 6) Dense Layer: ทำการลดขนาดมิติลง โดยกำหนดขนาดมิติเป็น 1

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- 7) Dropout Layer ทำการสุ่มปิดโหนดอีกครั้ง
- 8) BatchNormalization Layer: เป็นทำการ Normalize ข้อมูลเพื่อแก้ไขปัญหา Overfitting.
- 9) Dense Layer (Output Layer): กำหนด Activation เป็น sigmoid เพื่อให้ผลที่ได้ออกมาอยู่ในช่วง 0 ถึง 1

จากการนิยามแบบจำลองจะเห็นได้ว่าจะมีการใช้ Bidirectional Layer เพื่อหลีกเลี่ยงปัญหาการสูญเสียข้อมูลที่อยู่ในระหว่างการปรับค่าน้ำหนัก แล้วยังมีการใช้ Batch Normalization Layer และ Activation เป็น Relu , Dropout Layer เพื่อแก้ไขปัญ Vanishing gradient และ Overfitting อีกด้วย



บทที่ 4

ผลการวิจัยและการอภิปรายผล

การทดสอบประสิทธิภาพแบบจำลองสำหรับตรวจจับรีวิวลอมในเว็บ amazon.com โดยใช้ชุดข้อมูลมาตรฐาน Amazon Review Data (2018) โดยจะทำการทดสอบด้วยค่าความแม่นยำในการจำแนก (Accuracy) ค่าความเที่ยง (Precision) ค่าความไวหรือค่าระลึก (Recall) และค่า F1-score (ค่าเฉลี่ยของ Precision และ Recall) โดยจะทำการเปรียบเทียบการจำแนกของแบบจำลองที่ถูกฝึกสอนด้วยคุณลักษณะต่าง ๆ ตามที่ผู้วิจัยได้ทำการออกแบบไว้ สำหรับเนื้อหาในบทนี้จะประกอบไปด้วย ผลการทดสอบประสิทธิภาพของแบบจำลองต่าง ๆ และการอภิปรายผล โดยจะแบ่งผลการทดสอบประสิทธิภาพของแบบจำลองออกเป็น 2 ส่วนด้วยกัน คือ ผลการทดสอบประสิทธิภาพของแต่ละอัลกอริทึม และผลการทดสอบของอัลกอริทึมที่ทำการปรับ Hyperparameter

4.1 ผลการทดสอบประสิทธิภาพของแต่ละอัลกอริทึม

สำหรับการทดสอบประสิทธิภาพแบบจำลองสำหรับตรวจจับรีวิวลอมในเว็บ amazon.com โดยใช้ชุดข้อมูลมาตรฐาน Amazon Review Data (2018) ซึ่งในชุดข้อมูลจะประกอบไปด้วยหมวดหมู่ของสินค้า 10 หมวดหมู่ ได้แก่ Home and Kitchen , Clothing Shoes and Jewelry , Electronics , Books , Kindle Store , Movies and TV , Pet Supplies , Sports and Outdoors, Tools and Home Improvement , Toys and Games

4.1.1 การทดลองแบบจำลองวิเคราะห์รีวิวลอมด้วยอัลกอริทึม Generative Pre-trained Transformer 2 (GPT-2)

จากการทดลองสร้างแบบจำลองการตรวจจับรีวิวลอมของข้อความแสดงความคิดเห็นต่อผลิตภัณฑ์ โดยใช้อัลกอริทึม GPT-2 ให้ผลการทดลองดังตารางที่ 4.1

ตารางที่ 4.1 ผลการทดลองแบบจำลองวิเคราะห์รีวิวลอมด้วยอัลกอริทึม GPT-2

Accuracy	Precision	Recall	F1-score
0.82	0.83	0.82	0.82

จากตารางที่ 4.1 จะเห็นได้ว่าประสิทธิภาพโดยรวมของแบบจำลองของอัลกอริทึม GPT-2 มีค่า Accuracy อยู่ที่ 82% ค่า Precision ของ CG (รีวิพลอม) เท่ากับ 76% ส่วนค่า Precision ของ OR (รีวิวจริง) เท่ากับ 90% ค่า Recall ของ CG (รีวิพลอม) เท่ากับ 92% ส่วนค่า Recall ของ (OR) เท่ากับ 72% และค่า F1-score ของ CG (รีวิพลอม) เท่ากับ 84% ส่วนค่า F1-score ของ OR (รีวิวจริง) เท่ากับ 80%

4.1.2 การทดลองแบบจำลองวิเคราะห์รีวิพลอมด้วยอัลกอริทึม Naive Bayes Support Vector Machine (NBSVM)

จากการทดลองสร้างแบบจำลองการตรวจจบบรีวิพลอมของข้อความแสดงความคิดเห็นต่อผลิตภัณฑ์ โดยใช้อัลกอริทึม NBSVM ให้ผลการทดลองดังตารางที่ 4.2

ตารางที่ 4.2 ผลการทดลองแบบจำลองวิเคราะห์รีวิพลอมด้วยอัลกอริทึม NBSVM

Accuracy	Precision	Recall	F1-score
0.95	0.95	0.95	0.95

จากตารางที่ 4.2 จะเห็นได้ว่าประสิทธิภาพโดยรวมของแบบจำลองของอัลกอริทึม NBSVM มีค่า Accuracy อยู่ที่ 95% ค่า Precision ของ CG (รีวิพลอม) เท่ากับ 96% ส่วนค่า Precision ของ OR (รีวิวจริง) เท่ากับ 94% ค่า Recall ของ CG (รีวิพลอม) เท่ากับ 93% ส่วนค่า Recall ของ (OR) เท่ากับ 96% และค่า F1-score ของ CG (รีวิพลอม) และ OR (รีวิวจริง) เท่ากับ 95%

4.1.3 การทดลองแบบจำลองวิเคราะห์รีวิพลอมด้วยอัลกอริทึม Robustly Optimized BERT Pretraining Approach (Roberta)

จากการทดลองสร้างแบบจำลองการตรวจจบบรีวิพลอมของข้อความแสดงความคิดเห็นต่อผลิตภัณฑ์ โดยใช้อัลกอริทึม Roberta ให้ผลการทดลองดังตารางที่ 4.3

ตารางที่ 4.3 ผลการทดลองแบบจำลองวิเคราะห์รีวิพลอมด้วยอัลกอริทึม Roberta

Accuracy	Precision	Recall	F1-score
0.97	0.97	0.97	0.97

จากตารางที่ 4.3 จะเห็นได้ว่าประสิทธิภาพโดยรวมของแบบจำลองของอัลกอริทึม Roberta มีค่า Accuracy อยู่ที่ 97% ค่า Precision ของ CG (รีวิวลอม) เท่ากับ 97% ส่วนค่า Precision ของ OR (รีวิวจริง) เท่ากับ 98% ค่า Recall ของ CG (รีวิวลอม) เท่ากับ 98% ส่วนค่า Recall ของ (OR) เท่ากับ 97% และค่า F1-score ของ CG (รีวิวลอม) และ OR (รีวิวจริง) เท่ากับ 97%

4.1.4 การทดลองแบบจำลองวิเคราะห์รีวิวลอมด้วยอัลกอริทึม Bi-directional Long Short-Term Memory Model (BiLSTM)

จากการทดลองสร้างแบบจำลองการตรวจจับรีวิวลอมของข้อความแสดงความคิดเห็นต่อผลิตภัณฑ์ โดยใช้อัลกอริทึม Roberta ให้ผลการทดลองดังตารางที่ 4.4

จากตารางที่ 4.4 ผลการทดลองแบบจำลองวิเคราะห์รีวิวลอมด้วยอัลกอริทึม BiLSTM แบ่งตาม Category จะเห็นได้ว่าการพัฒนาแบบจำลองวิเคราะห์รีวิวลอมด้วยอัลกอริทึม BiLSTM พบว่า Category : Books ให้ค่า Accuracy สูงที่สุดคือ 91.911162% ซึ่งมีค่า Accuracy สูงกว่า Category อื่น ๆ และมีค่าเฉลี่ยของ Accuracy อยู่ที่ 91.05348%

ตารางที่ 4.4 ผลการทดลองแบบจำลองวิเคราะห์รีวิวลอมด้วยอัลกอริทึม BiLSTM

Accuracy	Precision	Recall	F1-score
0.92	0.92	0.92	0.92

จากตารางที่ 4.4 จะเห็นได้ว่าประสิทธิภาพโดยรวมของแบบจำลองของอัลกอริทึม BiLSTM มีค่า Accuracy อยู่ที่ 92% ค่า Precision ของ CG (รีวิวลอม) เท่ากับ 91% ส่วนค่า Precision ของ OR (รีวิวจริง) เท่ากับ 93% ค่า Recall ของ CG (รีวิวลอม) เท่ากับ 93% ส่วนค่า Recall ของ (OR) เท่ากับ 91% และค่า F1-score ของ CG (รีวิวลอม) และ OR (รีวิวจริง) เท่ากับ 92%

4.2 ผลการทดสอบของอัลกอริทึมที่ทำการปรับค่า Hyperparameter

สำหรับการเทรนแบบจำลองแรกเริ่มของทั้ง 2 แบบจำลอง คือแบบจำลอง Roberta และ BiLSTM ดังแสดงในตารางที่ 3.2 และ 3.3 ของบทที่ 3 โดยเริ่มต้นจากค่า Dropout = 0.1 ในแบบจำลอง Roberta และ Dropout = 0.5 ในแบบจำลอง BiLSTM โดยจะปรับค่า Learning Rate เพื่อค้นหาค่า Learning Rate ที่เหมาะสม ซึ่งหลังจากที่นำข้อมูลเข้าสู่แบบจำลองต่าง ๆ แล้ว จะทำการนำผลลัพธ์ค่าความสูญเสีย (Loss) และค่าความถูกต้องจากทั้ง 2 แบบจำลอง คือ Roberta, BiLSTM มาทำการวิเคราะห์และเปรียบเทียบเพื่อค้นหาแบบจำลองที่ดีที่สุดในช่วงข้อมูล Amazon Reviews Data Set (2018) โดยจะแบ่งผลการทดสอบออกเป็น 2 อัลกอริทึม คือ ผลการทดสอบของอัลกอริทึม Roberta และผลการทดสอบอัลกอริทึม BiLSTM เนื่องจาก 2 อัลกอริทึมนี้เป็นแบบจำลองการเรียนรู้เชิงลึกเหมือนกัน และสามารถปรับจูนค่า Hyperparameter ได้ แต่อัลกอริทึม GPT-2 เป็นอัลกอริทึมที่ถูกเผยแพร่โดย Open AI ซึ่งไม่ได้มีการบอกรายละเอียดของการทำงานของอัลกอริทึมที่ละเอียด จึงทำให้ยากต่อการนำมาปรับจูน Hyperparameter ส่วนอัลกอริทึม NBSVM เป็นอัลกอริทึมการเรียนรู้ของเครื่องมีการทำงานที่แตกต่างจากการเรียนรู้เชิงลึก จึงไม่สามารถนำมาทำการปรับจูนค่า Hyperparameter ได้ ด้วยเหตุนี้ จึงทำให้งานวิจัยนี้มีการปรับจูนค่า Hyperparameter เพียงแค่ 2 อัลกอริทึมจากทั้งหมด 4 อัลกอริทึม ดังนี้

4.2.1 ผลการทดสอบของอัลกอริทึม BiLSTM

สำหรับการทดสอบของอัลกอริทึม BiLSTM หลังจากนำข้อมูลเข้าแบบจำลองตั้งต้นพร้อมทั้งทำการปรับค่า Learning Rate เป็น 0.001 ประสิทธิภาพที่ได้ของแบบจำลองเป็นดังตารางที่ 4.5

ตารางที่ 4.5 ประสิทธิภาพของแบบจำลองที่ได้ เมื่อมีการปรับจูนค่า Learning Rate ของ BiLSTM

Model	Learning Rate	Loss	Accuracy
BiLSTM	0.01	0.2579	92.3564
	0.001	0.3697	91.0597

จากตารางที่ 4.5 ค้นพบว่า เมื่อมีการปรับค่า Learning Rate เป็น 0.001 ทำให้แบบจำลองทำงานได้แย่ลง เนื่องจากมีค่าความถูกต้อง (Accuracy) ลดลงจาก 92.3564% เป็น 91.0597% และมีค่าความ

สูญเสียมากขึ้นจาก 0.2579 เป็น 0.3697 ดังนั้นจึงสรุปได้ว่าแบบจำลอง BiLSTM ทำงานได้ดีบนค่า Learning Rate = 0.01 เนื่องจากค่าความสูญเสียคือ ค่าที่ใช้ในการเปรียบเทียบผลลัพธ์ที่แบบจำลองทำนายมาได้กับค่าจริงว่ามีความคลาดเคลื่อน (Error) เท่าใด ดังนั้นหากยังมีค่าความสูญเสียน้อยยิ่งมีประสิทธิภาพ

หลังจากได้ค่า learning Rate ที่เหมาะสมแล้วขั้นตอนต่อไปจะเป็นการเพิ่มจำนวนรอบของการเทรนแบบจำลอง โดยปรับจูนค่า Epochs เป็น 10 เพื่อวิเคราะห์ว่าจำนวนรอบที่เหมาะสมในการเทรนแบบจำลองควรมีค่าเท่าใด โดยประสิทธิภาพที่ได้จะแสดงรายละเอียดในตารางที่ 4.6

ตารางที่ 4.6 ประสิทธิภาพของแบบจำลองที่ได้ เมื่อมีการปรับจูนค่า Epochs ของ BiLSTM

Model	Epochs	Loss	Accuracy
BiLSTM	5	0.2579	92.3564
	10	0.5927	91.0102

จากตารางที่ 4.6 ค้นพบว่าจำนวน Epochs ที่เหมาะสมในการเทรนแบบจำลองอยู่ที่จำนวน 5 รอบ เนื่องจากมีค่าความถูกต้องที่สูงกว่า เมื่อเปรียบกับการเพิ่มจำนวนรอบเป็น 10 รอบ และค่าความสูญเสียก็น้อยกว่า เมื่อทำการเทรนแบบจำลองที่ 10 รอบ ดังนั้นจึงขอสรุปว่า Epochs = 5 เป็นค่าที่เหมาะสมกับแบบจำลอง BiLSTM กับชุดของมูลนี้

สำหรับขั้นตอนสุดท้ายจะทดลองปรับจูนค่า Batch Size จาก 128 เป็น 120 ซึ่งเป็นการค้นหาว่าควรให้แบบจำลองมีการเรียนรู้ข้อมูลกี่ครั้งก่อนการปรับค่าน้ำหนัก จึงจะทำให้ประสิทธิภาพที่ดีที่สุด โดยประสิทธิภาพที่ได้จะแสดงดังตารางที่ 4.7

ตารางที่ 4.7 ประสิทธิภาพของแบบจำลองที่ได้ เมื่อมีการปรับจูนค่า Batch Size ของ BiLSTM

Model	Batch Size	Loss	Accuracy
BiLSTM	128	0.2579	92.3564
	120	0.7806	90.8742

จากตารางที่ 4.7 จะเห็นได้ว่าค่า Batch Size ที่ 128 เป็นค่าที่เหมาะสมกับแบบจำลอง BiLSTM เนื่องจากให้ค่าความถูกต้องสูงกว่า ค่า Batch Size ที่ 120 ดังนั้นจึงสรุปได้ว่า ค่า Hyperparameters ที่เหมาะสมสำหรับชุด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ข้อมูล Amazon Reviews Dataset (2018) ของแบบจำลอง Roberta ครมมีค่า Learning Rate = 0.01, Epochs = 5 และ Batch Size = 128 โดยมีค่าความถูกต้องอยู่ที่ 92.35%

4.2.2 ผลการทดสอบของอัลกอริทึม Roberta

สำหรับการทดสอบของอัลกอริทึม Roberta หลังจากนำข้อมูลเข้าแบบจำลองตั้งต้นพร้อมทั้งทำการปรับค่า Learning Rate เป็น 0.0001 ประสิทธิภาพที่ได้ของแบบจำลองเป็นดังตารางที่ 4.8

ตารางที่ 4.8 ประสิทธิภาพของแบบจำลองที่ได้ เมื่อมีการปรับค่า Learning Rate ของ Roberta

Model	Learning Rate	Loss	Accuracy
Roberta	0.00001	0.1202	97.0276
	0.0001	0.6987	50.8822

จากตารางที่ 4.8 ค้นพบว่า เมื่อมีการปรับค่า Learning Rate เป็น 0.0001 ทำให้แบบจำลองทำงานได้แยกลง เนื่องจากมีค่าความถูกต้อง (Accuracy) ลดลงจาก 97.0276% เป็น 50.8822% และมีค่าความสูญเสียมากขึ้นจาก 0.1202 เป็น 0.6987 ดังนั้นจึงสรุปได้ว่าแบบจำลอง Roberta ทำงานได้ดีบนค่า Learning Rate = 0.00001 เนื่องจากค่าความสูญเสียคือ ค่าที่ใช้ในการเปรียบเทียบผลลัพธ์ที่แบบจำลองทำนายมาได้กับค่าจริงว่ามีความคลาดเคลื่อน (Error) เท่าใด ดังนั้นหากยังมีค่าความสูญเสียน้อยยังมีประสิทธิภาพ

หลังจากได้ค่า learning Rate ที่เหมาะสมแล้ว ลำดับถัดไปจะทำการทดลองปรับค่า Batch Size จากเดิมที่มีค่า 8 เป็น 16 ซึ่งเป็นการค้นหาว่าควรให้แบบจำลองมีการเรียนรู้ข้อมูลกี่ครั้งก่อนการปรับค่าน้ำหนัก จึงจะทำให้ประสิทธิภาพที่ดีที่สุด โดยประสิทธิภาพที่ได้จะแสดงดังตารางที่ 4.9

ตารางที่ 4.9 ประสิทธิภาพของแบบจำลองที่ได้ เมื่อมีการปรับจูนค่า Batch Size ของ Roberta

Model	Batch Size	Loss	Accuracy
Roberta	8	0.1202	97.0276
	16	0.1196	94.7322

จากตารางที่ 4.9 จะเห็นได้ว่า เมื่อทำการเปลี่ยนค่า Batch Size จาก 8 เป็น 16 ประสิทธิภาพของแบบจำลองลดลงจาก 97.0276 เป็น 94.7322 แต่ค่าความสูญเสียลดลง จาก 0.1202 เป็น 0.1196 จะเห็นได้ว่าค่าความสูญเสียลดลงเพียงเล็กน้อย ดังนั้นจึงสรุปได้ว่า ค่า Batch Size ที่เหมาะสมกับแบบจำลอง Roberta เท่ากับ 8

หลังจากที่ได้ค่า Batch Size ที่เหมาะสมแล้ว ลำดับถัดไปจะทำการทดลองปรับจูนค่า Epoch เป็น 5 เพื่อวิเคราะห์ว่าจำนวนรอบที่เหมาะสมในการเทรนแบบจำลองควรมีค่าเท่าใด โดยประสิทธิภาพที่ได้จะแสดงรายละเอียดในตารางที่ 4.10

ตารางที่ 4.10 ประสิทธิภาพของแบบจำลองที่ได้ เมื่อมีการปรับจูนค่า Epochs ของ Roberta

Model	Epochs	Loss	Accuracy
Roberta	1	0.1202	97.0276
	5	0.1175	96.3645

จากตารางที่ 4.10 จะเห็นได้ว่า เมื่อทำการเปลี่ยนค่า Epochs จาก 1 เป็น 5 ประสิทธิภาพของแบบจำลองลดลง ดังนั้นจึงสรุปได้ว่า ค่า Hyperparameters ที่เหมาะสมสำหรับชุดข้อมูล Amazon Reviews Dataset (2018) ของแบบจำลอง Roberta ควรมีค่า Learning Rate = 0.00001, Epochs = 1 และ Batch Size = 8 โดยมีค่าความถูกต้องอยู่ที่ 97.0276%

4.3 การอภิปรายผล


จากผลการทดสอบประสิทธิภาพของแบบจำลองต่างๆเพื่อทำการจำแนกและตรวจจบบริวปลอมในข้อความการแสดงความคิดเห็นต่อสินค้าในหมวดหมู่ต่างๆ ของเว็บไซต์ Amazon.com โดยใช้ชุดข้อมูล Amazon Reviews Data (2018) พบว่า แบบจำลอง Roberta ให้ประสิทธิภาพโดยรวมดีที่สุดทุกค่าไม่ว่าจะเป็น ค่าความถูกต้อง ค่าความไว และค่าการเรียกคืน โดยมีค่าความถูกต้องเท่ากับ 97% รองลงมาคือแบบจำลอง NBSVM มีค่าความถูกต้องเท่ากับ 95% และถัดมาคือแบบจำลอง BiLSTM มีค่าความถูกต้องเท่ากับ 92% และสุดท้ายคือแบบจำลอง GPT-2 มีค่าความถูกต้องอยู่ที่ 82% ดังแสดงในตารางที่ 4.11

ตารางที่ 4.11 ประสิทธิภาพโดยรวมของแต่ละแบบจำลอง

Model	Accuracy	Precision	Recall	F1-score
Roberta	0.97	0.97	0.97	0.97
NBSVM	0.95	0.95	0.95	0.95
BiLSTM	0.92	0.92	0.92	0.92
GPT-2	0.82	0.83	0.82	0.82

จากนั้นก็ได้ทำการใช้ ROC (Receiver Operating Characteristic) และ AUC (Area Under Curve) ซึ่งเป็นเส้นที่ใช้วัดประสิทธิภาพของแบบจำลองที่เป็น Classification ว่าสามารถทำนายประเด็นที่เราสนใจได้อย่างแม่นยำขนาดไหน ดังแสดงในภาพที่ 4.1

จากภาพที่ 4.1 จะเห็นได้ว่าแบบจำลอง Roberta มีค่าเข้าใกล้ 1 มากที่สุด โดยมีค่า AUC = 0.9976 ซึ่งแสดงว่าแบบจำลอง Roberta สามารถทำนายสิ่งที่เราสนใจคือ ตรวจจบบริวปลอม ได้อย่างแม่นยำกว่าแบบจำลองอื่นๆ ที่นำมาใช้ในการเปรียบเทียบประสิทธิภาพในงานวิจัยฉบับนี้ และชุดข้อมูลที่เรานำมาใช้ ตามมาด้วยแบบจำลอง NBSVM ซึ่งดูจากกราฟ ROC ก็มีค่าเข้าใกล้ 1 เช่นเดียวกัน โดยมีค่า AUC = 0.9888 และในลำดับถัดมาจะเป็นแบบจำลอง BiLSTM มีค่า AUC = 0.9753 และสุดท้ายคือแบบจำลอง GPT-2 มีค่า AUC = 0.9226



ภาพที่ 4.1 แสดง ROC ของแต่ละแบบจำลอง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 5

สรุปผลการวิจัยและข้อเสนอแนะ

5.1 สรุปผลการวิจัย

งานวิจัยฉบับนี้สามารถเปรียบเทียบประสิทธิภาพและความแม่นยำของแต่ละแบบจำลองที่ได้เลือกนำมาใช้เปรียบเทียบ ว่าแบบจำลองใดสามารถตรวจจับรีวิพลอมได้อย่างมีประสิทธิภาพที่สุด ในสถานการณ์ที่สร้างขึ้นและในชุดข้อมูลเดียวกัน ตามแต่ละสถานการณ์ที่มีข้อจำกัดตามคุณลักษณะของแบบจำลองนั้นๆ อีกทั้งยังได้เรียนรู้เทคนิคที่ใช้ในการตรวจจับรีวิพลอมของแต่ละแบบจำลอง และยังสามารถจำแนกว่าอันไหนคือรีวิวจริงหรือรีวิพลอมซึ่งถูกสร้างขึ้นโดยคอมพิวเตอร์ ได้ในเบื้องต้น ทว่าการเขียนหรือการสร้างรีวิพลอมขึ้นมานั้นมีหลายรูปแบบ ไม่ว่าจะเป็นการพิมพ์ที่เกิดจากการสร้างขึ้นเองโดยมนุษย์หรือจะถูกสร้างโดยคอมพิวเตอร์ซึ่งใช้อัลกอริทึมช่วยสร้างข้อความรีวิพลอมขึ้นมา ดังนั้นในส่วนนี้ถือเป็นข้อจำกัดในการค้นคว้าอิสระนี้ เนื่องจากในงานวิจัยนี้ได้นำข้อความรีวิพลอมที่ถูกสร้างโดยคอมพิวเตอร์มาทำการทดลองและตรวจจับรีวิพลอม แต่มิได้นำข้อความรีวิพลอมที่ถูกสร้างขึ้นโดยมนุษย์มาทดลอง เนื่องจากลักษณะที่ใช้ในการเขียนข้อความรีวิพลอมว่าจริงหรือปลอม มีลักษณะที่ไม่ได้มีความแตกต่างกันมากอีกทั้งข้อความรีวิพลอนั้นอาจจะถูกเขียนขึ้นด้วยความรู้สึกเพียงชั่วขณะนั้น ไม่ได้เป็นความรู้สึกที่มีต่อผลิตภัณฑ์หรือสินค้านั้น ๆ ตลอด เนื่องจากสิ่งนี้เกิดขึ้นโดยมนุษย์ผู้ซึ่งมีความรู้สึกที่แปรผันตลอดเวลา ไม่เหมือนคอมพิวเตอร์หรืออัลกอริทึม ดังนั้นการตรวจจับรีวิพลอมจึงถือเป็นงานที่ท้าทายและต้องมีการพัฒนาอัลกอริทึมในการตรวจจับอีกเรื่อย ๆ เนื่องจากสิ่งนี้อาจช่วยให้ผู้บริโภคอย่างเรา ไม่ตกเป็นเหยื่อของสินค้าหรือผลิตภัณฑ์ที่ตั้งใจจะหลอกลวงผู้บริโภค โดยสร้างรีวิพลอมขึ้นมาเพื่อเอื้อต่อการขายสินค้าของตนหรือเพื่อโจมตีบริษัทคู่แข่งก็ตาม

5.2 ข้อเสนอแนะ

จากการทดลองพบว่า การที่แบบจำลองจะให้ประสิทธิภาพในการทำนายที่สูงนั้น ไม่เพียงแต่การเลือกอัลกอริทึมที่เหมาะสมสำหรับการสร้างแบบจำลองเท่านั้น แต่ยังรวมไปถึงการคัดเลือกหรือการสร้างคุณลักษณะของข้อมูลที่สามารถนำไปใช้ในการวิเคราะห์ ให้เหมาะสมกับประเภทงานที่จะใช้ในการวิเคราะห์ด้วย และแบบจำลองที่เป็นการเรียนรู้เชิงลึกนั้น จะใช้ทรัพยากรของเครื่องค่อนข้างสูงมาก ใช้เวลาในการรันค่อนข้างนานกว่าการเรียนรู้ของเครื่อง แต่ให้ประสิทธิภาพที่ไม่ได้ต่างกันมากนัก อีกทั้งแบบจำลองของการเรียนรู้เชิงลึกแต่ละ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

แบบจำลองจะมีลักษณะการทำงานที่แตกต่างกันออกไป เป็นข้อจำกัดในการปรับพารามิเตอร์ และในงานวิจัยนี้ ใช้การปรับพารามิเตอร์ทีละค่า โดยมีได้ใช้การปรับพารามิเตอร์แบบอัตโนมัติ จึงทำให้มีการใช้เวลานาน ในการประมวลผล และยังส่งผลต่อประสิทธิภาพของแบบจำลองโดยรวมอีกด้วย ในอนาคตทางผู้วิจัยจะใช้ แหล่งข้อมูลที่เป็นภาษาไทยรวมถึงใช้ชุดข้อมูลข้อความรีวิพลอมที่มนุษย์สร้างขึ้น และค้นหาอัลกอริทึมที่สามารถ ทดลองปรับเปลี่ยนค่าพารามิเตอร์ เพื่อลดความเอนเอียงของแบบจำลองและเพื่อค้นหาแบบจำลองที่เหมาะสมกับ ชุดข้อมูลที่สุดต่อไป



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เอกสารอ้างอิง

- D.U. Vida agama, A.T.P. Silva, A.S. Karun Ananda. 2022. “Ontology based sentiment analysis for fake review detection.” Expert Systems with Applications. 206(2022), Article 117869.
- JITENDRA K., ANMOL D., KIM-KWANG R., SAMBIT B., SANJAY K. 2017. “Revisiting Semi-Supervised Learning for Online Deceptive Review Detection.” Digital Object Identifier 10.1109/ACCESS.2017.2655032
- Faranak Abri, Luis Felipe Gutierrez, Akbar Siami Namin, Keith S. Jones , and David R. W. Sears. 2020. “Fake Reviews Detection through Analysis of Linguistic Features.” Texas Tech University, 8 Oct 2020
- Joni S., Chandrashekhar K., Ahmed Mohamed K., Soon-gyo J., Bernard J. (2022). “Creating and detecting fake reviews of online products.” Journal of Retailing and Consumer Services. 64(2022), Article 102771.
- JIANRONG YAO, YUAN ZHENG, AND HUI JIANG. (2020). “An Ensemble Model for Fake Online Review Detection Based on Data Resampling, Feature Pruning, and Parameter Optimization.” Digital Object Identifier 10.1109/ACCESS.2021.3051174
- Punit Rathore, Jayesh Soni, Nagarajan Prabakar, Marimuthu Palaniswami. (2021). “Identifying Groups of Fake Reviewers Using a Semisupervised Approach.” IEEE TRANSACTIONS ON COMPUTATIONAL SOCIAL SYSTEMS, VOL. 8, NO. 6, DECEMBER 2021
- HINA TUFAIL, M. USMAN ASHRAF, KHALID ALSUBHI AND HANI MOAITEQ ALJAHDALI. (2022). “The Effect of Fake Reviews on e-Commerce During and After Covid-19 Pandemic: SKL-Based Fake Reviews Detection.” Digital Object Identifier 10.1109/ACCESS.2022.3152806

Nishant Rai, Deepika Kumar, Naman Kaushik, Chandan Raj, Ahad Ali. (2022). “Fake News Classification using transformer based enhanced LSTM and BERT.” International Journal of Cognitive Computing in Engineering. 3(2022). pp. 98-105

พนม คล้ายยา, พยุง มีสัจ, งามอาจ อุ่นอนันต์, กมลรัตน์ กิจรุ่งไพศาล. (2564). “การพัฒนาการตรวจจับข่าวปลอมโดยการเรียนรู้ของเครื่องและการตรวจสอบข้อเท็จจริงของประชาชน.” วิทยานิพนธ์นิเทศศาสตรมหาบัณฑิต, จุฬาลงกรณ์มหาวิทยาลัย

สุปัญญา อภิวงศ์โสภณ. (2561). “การตรวจสอบข่าวปลอมด้วยการเรียนรู้ของเครื่อง.” วิทยานิพนธ์วิศวกรรมศาสตรดุษฎีบัณฑิต, จุฬาลงกรณ์มหาวิทยาลัย

M. F. MRIDHA, ASHFIA JANNAT KEYA, MD. ABDUL HAMID, MUHAMMAD MOSTAFA MONOWAR, AND MD. SAIFUR RAHMAN. (2021). “A Comprehensive Review on Fake News Detection with Deep Learning” Digital Object Identifier 10.1109/ACCESS.2021.3129329

Zhi-Yuan Zeng, Jyun-Jie Lin, Mu-Sheng Chen, Meng-Hui Chen, Yanqi lan and Jun-Lin Liu. (2019). “A Review Structure Based Ensemble Model for Deceptive Review Spam.” Information 2019, 10, 243; doi:10.3390/info10070243

Wentao Liu, Weipeng Jing, Yang Li. (2019). “Incorporating feature representation into BiLSTM for deceptive review detection.” Computing (2020) 102:701–715

กฤตณัฐ บัญเกียรติพงษ์. (2554). “การประยุกต์นิเวศเน็ตเวิร์กหลายโครงข่ายบนข้อมูลขนาดใหญ่.” วิทยานิพนธ์วิทยาศาสตรมหาบัณฑิต, จุฬาลงกรณ์มหาวิทยาลัย

ประวัติผู้เขียน

ชื่อ	นางสาวณิรัตน์ พุทธรัตน์มณี
วัน เดือน ปีเกิด	8 มิถุนายน 2539
ที่อยู่ปัจจุบัน	13/72 หมู่ 7 บางแก้ว บางพลี สมุทรปราการ
ประวัติการศึกษา	(2561) วิศวกรรมศาสตรบัณฑิต สาขาวิศวกรรมไฟฟ้าอุตสาหกรรม เกรดเฉลี่ย 2.20 มหาวิทยาลัยธรรมศาสตร์ (2566) วิทยาศาสตรมหาบัณฑิต สาขาวิทยาการข้อมูลและการวิเคราะห์ เกรดเฉลี่ย 3.90 สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

