

การตรวจจับข้อความประชดประชันด้วยคุณลักษณะร่วมระหว่างบริบทและเนื้อหาข้อความบน
เครือข่ายสังคมออนไลน์

วิทยานิพนธ์
ของ
ปราโมชย์ นามวงศ์

เสนอต่อมหาวิทยาลัยมหาสารคาม เพื่อเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญาปรัชญาดุษฎีบัณฑิต สาขาวิชาวิทยาการคอมพิวเตอร์

กุมภาพันธ์ 2566

ลิขสิทธิ์เป็นของมหาวิทยาลัยมหาสารคาม

การตรวจจับข้อความประชดประชนด้วยคุณลักษณะร่วมระหว่างบริบทและเนื้อหาข้อความบนเครือข่ายสังคมออนไลน์

วิทยานิพนธ์

ของ

ปราโมชย นามวงศ์

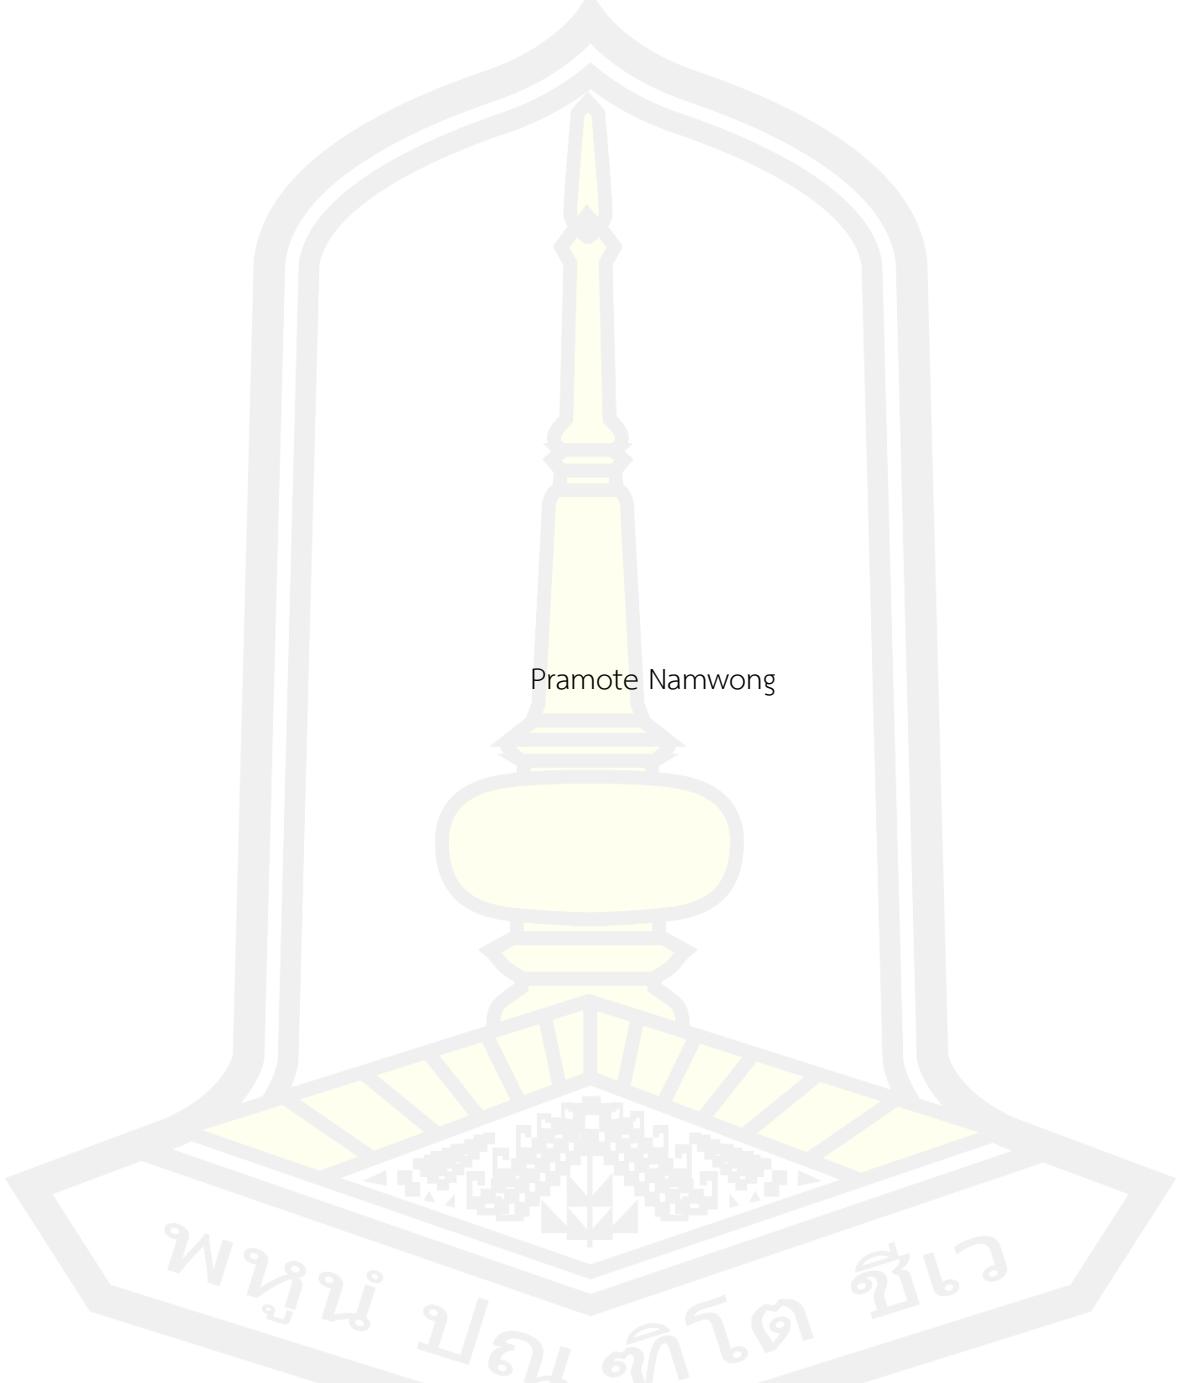
เสนอต่อมหาวิทยาลัยมหาสารคาม เพื่อเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร

ปริญญาปรัชญาดุษฎีบัณฑิต สาขาวิชาวิทยาการคอมพิวเตอร์

กุมภาพันธ์ 2566

ลิขสิทธิ์เป็นของมหาวิทยาลัยมหาสารคาม

Sarcasm Messages Detection using Hybrid Features Extraction Deriving from Context
and Content Sentences on Social Networks



Pramote Namwong

A Thesis Submitted in Partial Fulfillment of Requirements

for Doctor of Philosophy (Computer Science)

February 2023

Copyright of Mahasarakham University



คณะกรรมการสอบวิทยานิพนธ์ ได้พิจารณาวิทยานิพนธ์ของนายปราโมชย์ นามวงศ์
แล้วเห็นสมควรรับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาปรัชญาดุษฎีบัณฑิต สาขาวิชา
วิทยาการคอมพิวเตอร์ ของมหาวิทยาลัยมหาสารคาม

คณะกรรมการสอบวิทยานิพนธ์

ประธานกรรมการ

(ผศ. ดร. วรารัตน์ สงฆ์ແປ່ນ)

อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก

(รศ. ดร. พนิดา ทรงรัมย์)

กรรมการ

(ผศ. ดร. พัฒนพงษ์ ชุมภูวิเศษ)

กรรมการ

(รศ. ดร. สุชาติ คุ้มมะณี)

กรรมการ

(ผศ. ดร. อัตราเกล้า เจริญผล)

มหาวิทยาลัยอนุมัติให้รับวิทยานิพนธ์ฉบับนี้ เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญา ปรัชญาดุษฎีบัณฑิต สาขาวิชาวิทยาการคอมพิวเตอร์ ของมหาวิทยาลัยมหาสารคาม

(รศ. ดร. จันทิมา พลพินิจ)

คณบดีคณวิทยาการสารสนเทศ

(รศ. ดร. กริสัน ชัยมูล)

คณบดีบัณฑิตวิทยาลัย

ชื่อเรื่อง	การตรวจจับข้อความประชดประชันด้วยคุณลักษณะร่วมระหว่างบริบทและเนื้อหาข้อความบนเครือข่ายสังคมออนไลน์		
ผู้วิจัย	ปราโมชย์ นามวงศ์		
อาจารย์ที่ปรึกษา	รองศาสตราจารย์ ดร. พนิดา ทรงรัมย์	สาขาวิชา	วิทยาการคอมพิวเตอร์
ปริญญา	ปรัชญาดุษฎีบัณฑิต	ปีที่พิมพ์	2566
มหาวิทยาลัย	มหาวิทยาลัยมหาสารคาม		

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาการตรวจจับข้อความประชดประชันภาษาไทยบนเครือข่ายสังคมออนไลน์ และทำการศึกษาคุณลักษณะที่สกัดจากบริบทของข้อความและคุณลักษณะที่สกัดจากเนื้อหาของข้อความในการจำแนกข้อความประชดประชัน เทคนิคการเรียนรู้เชิงลึกและเทคนิคการเรียนรู้ของเครื่องถูกลำมาประยุกต์ใช้ในการจำแนกข้อความประชดประชัน จากการทดลองแสดงให้เห็นว่าการสกัดคุณลักษณะจากบริบทของข้อความรวมกับเนื้อหาของข้อความให้ค่าความถูกต้องมากที่สุด และวิธี LSTM ให้ค่าความถูกต้องมากที่สุดคือ 96.79% เมื่อกำหนดพารามิเตอร์ Bidirectional LSTM จำนวน 256 โหนด ใช้ Activation function เป็น ReLU Dropout layer เท่ากับ 0.2, Output activation เป็น Sigmoid, loss function แบบ binary cross entropy และ optimizer เป็น adam

คำสำคัญ : การเรียนรู้ของเครื่อง, คำประชดประชัน, การเรียนรู้เชิงลึก, หน่วยความจำระยะสั้นระยะยาว, ปัญญาประดิษฐ์

TITLE	Sarcasm Messages Detection using Hybrid Features Extraction Deriving from Context and Content Sentences on Social Networks		
AUTHOR	Pramote Namwong		
ADVISORS	Associate Professor Panida Songram , Ph.D.		
DEGREE	Doctor of Philosophy	MAJOR	Computer Science
UNIVERSITY	Mahasarakham University	YEAR	2023

ABSTRACT

This research aims to develop the detection of sarcastic message in Thai language on social networks. Moreover, context-based and content-based features are extracted from messages and studied for detecting sarcastic messages. Deep learning and machine learning techniques are applied to classify sarcastic message. From the experimental results, they show that the combination of context-based and content-based features gives the highest accuracy. LSTM gives the highest accuracy at 96.79% when using bidirectional LSTM with 256 nodes, ReLU is used as active function, dropout layer is 0.2, Sigmoid is used as output activation, loss function is binary cross entropy, and adam is used as optimizer.

Keyword : machine learning, sarcasm, deep learning, long short-term memory, artificial intelligence

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้ สำเร็จลุล่วงได้ด้วยดี ผู้วิจัยขอกราบขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร. พนิดา ทรงรัมย์ อาจารย์ที่ปรึกษาวิทยานิพนธ์ ที่ให้คำแนะนำและคำปรึกษาในการทำงานวิจัย ตลอดจน การตรวจสอบความถูกต้องของวิทยานิพนธ์

ขอกราบขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.วรารัตน์ สงข์ແป็น ประธานกรรมการสอบ วิทยานิพนธ์ ผู้ช่วยศาสตราจารย์ ดร.พัฒนพงษ์ ชมภูวิเศษ และผู้ช่วยศาสตราจารย์ ดร.ฉัตรเกล้า เจริญ ผล กรรมการสอบ และผู้ช่วยศาสตราจารย์ ดร.สุชาติ คุ้มมะณี กรรมการสอบ ที่กรุณาให้คำแนะนำ ตลอดจนคำแนะนำในการปรับปรุงแก้ไขวิทยานิพนธ์ให้มีความสมบูรณ์มากขึ้น

ขอขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.ทัยรัตน์ ควรรุ่ดี คณะดีคณบดีบริหารธุรกิจและการ จัดการ มหาวิทยาลัยราชภัฏอุบลราชธานี ที่กรุณาให้คำแนะนำ ให้กำลังใจ สนับสนุน ให้คำปรึกษา และ ให้เวลาในการทำวิทยานิพนธ์ให้สำเร็จลุล่วงได้ด้วยดี

ขอขอบพระคุณมหาวิทยาลัยราชภัฏอุบลราชธานีที่มอบทุนอุดหนุนการศึกษาและค่าใช้จ่ายใน การทำวิจัยให้กับผู้วิจัยในการศึกษาระดับปริญญาเอกในครั้งนี้

ขอขอบพระคุณ ครู อาจารย์ ทั้งในอดีตและปัจจุบันที่ให้ความรู้แก่ผู้วิจัยอย่างมากมายจน ประสบความสำเร็จ

ท้ายที่สุดขอขอบพระคุณ บิดา มารดา ผู้ให้กำเนิด ญาติพี่น้อง ภรรยาและลูก ที่ส่งเสริมให้ ผู้วิจัยมีเวลาในการดำเนินการวิจัย ทั้งยังให้กำลังใจแก่ผู้วิจัยจนประสบความสำเร็จใจชีวิต

ปราโมชย นามวงศ์

พนัน ปณ. กิตติ ชีว

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	๑
บทคัดย่อภาษาอังกฤษ.....	๑
กิตติกรรมประกาศ.....	๒
สารบัญ.....	๓
บทที่ 1 บทนำ	1
1.1 หลักการและเหตุผล	1
1.2 วัตถุประสงค์ของการวิจัย	3
1.3 ความสำคัญของการวิจัย.....	3
1.4 ขอบเขตของการวิจัย	3
1.5 นิยามศัพท์เฉพาะ	4
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง	5
2.1 การวิเคราะห์ข้อคิดเห็นประชดประชัน.....	5
2.2 การเตรียมข้อมูล	6
2.2.1 การตัดคำ (Tokenization).....	6
2.2.2 การสกัดคุณลักษณะ	8
2.2.3 รูปแบบการแทนข้อความ (Document representation)	10
2.2.3.1 โมเดลเชิงพื้นที่แบบเวกเตอร์ (Vector Space Model).....	10
2.2.3.2 Word Embedding	10
2.3 การจำแนกข้อมูลด้วยวิธีการเรียนรู้ด้วยเครื่อง.....	11
2.4 เทคนิคการเรียนรู้เชิงลึก.....	14
2.4.1 Deep Neural Network.....	14

2.4.2 Long Short-Term Memory	15
2.5 การวัดประสิทธิภาพการจำแนก	18
2.6 งานวิจัยที่เกี่ยวข้อง	20
บทที่ 3 วิธีดำเนินการวิจัย	38
3.1 การรวบรวมข้อมูล	38
3.2 การเตรียมข้อมูล	40
3.2.1 การสกัดคุณลักษณะจากบริบทในข้อความ	40
3.2.1.1 การทำความสะอาดข้อความ	40
3.2.1.2 การตัดคำ	40
3.2.1.3 การให้ค่าน้ำหนักข้อความ	42
3.2.1.4 การสร้างตัวแทนเชิงความหมายของคำ	43
3.2.2 การสกัดคุณลักษณะจากเนื้อหาในข้อความ	44
3.2.3 คุณลักษณะการรวมบริบทในข้อความและเนื้อหาในข้อความ	49
3.3 การสร้างตัวจำแนก	50
3.3.1 การสร้างตัวจำแนกด้วยวิธีการเรียนรู้ด้วยเครื่อง	50
3.3.2 การสร้างตัวจำแนกด้วยวิธีการเรียนรู้เชิงลึก	50
3.4 การวัดประสิทธิภาพ	51
บทที่ 4 ผลการวิจัยและการอภิปรายผล	54
4.1 เครื่องมือและข้อมูลที่ใช้ในการทดลอง	54
4.1.1 เครื่องมือที่ใช้ในการทดลอง	54
4.1.2 ผลการรวบรวมข้อมูลในการทดลอง	54
4.2 ผลการทดลองจำแนกข้อมูลจากบริบทในข้อความ	55
4.2.1 การทดลองเปรียบเทียบ Remove Stop Words และ ไม่ Remove Stop Words ..	55
4.2.2 การทดลองการกำหนดจำนวน K ที่ดีที่สุดสำหรับ KNN	56

4.2.3 ผลการทดลองด้วยคุณลักษณะ Boolean Weighting	57
4.2.4 ผลการทดลองด้วยคุณลักษณะ TF Weighting.....	57
4.2.5 ผลการทดลองด้วยคุณลักษณะ TF-IDF Weighting.....	58
4.2.4 ผลการทดลองด้วยคุณลักษณะ Word Embedding.....	58
4.3 ผลการทดลองจำแนกข้อมูลจากเนื้อหาในข้อความ.....	59
4.4 ผลการทดลองจำแนกข้อมูลจากบริบทในข้อความและเนื้อหาในข้อความ	60
4.4.1 ผลการทดลองด้วยคุณลักษณะ Boolean Weighting + Content	60
4.4.2 ผลการทดลองด้วยคุณลักษณะ TF Weighting + Content	61
4.4.3 ผลการทดลองด้วยคุณลักษณะ TF-IDF Weighting + Content	61
4.4.4 ผลการทดลองด้วยคุณลักษณะ Word Embedding + Content.....	62
4.5 ผลการทดลองด้วยคุณลักษณะ Word Embedding ด้วยวิธี Hold out	62
บทที่ 5 สรุปผล อภิปรายผล และข้อเสนอแนะ	64
5.1 สรุปผล.....	64
5.2 อภิปรายผล	65
5.3 ข้อเสนอแนะ	66
บรรณานุกรม.....	67
ภาคผนวก ก ตารางแสดงคำารมณ์เชิงบวก	75
ภาคผนวก ข ตารางแสดงคำารมณ์เชิงลบ	79
ประวัติผู้เขียน	89

บทที่ 1

บทนำ

1.1 หลักการและเหตุผล

การเติบโตของเครือข่ายสังคมออนไลน์เป็นไปอย่างรวดเร็ว การสื่อสารผ่านช้อความมีความสะดวกและรวดเร็วมากขึ้น ทำให้จำนวนข้อความแสดงความคิดเห็น ทัศนคติ ผ่านทางเครือข่ายสังคมออนไลน์มีแนวโน้มว่าจะเพิ่มสูงมากขึ้น ซึ่งข้อความที่เกิดขึ้นจำนวนมากนั้น มีทั้งข้อความที่เป็นข้อเท็จจริงและความคิดเห็น ข้อความคิดเห็นเป็นข้อความที่แสดงออกถึงอารมณ์และความรู้สึกของผู้เขียน ข้อความคิดเห็นสามารถแบ่งออกเป็น 3 ข้อหลักๆ คือ ข้อความคิดเห็นที่แสดงความคิดเห็นในเชิงบวก (Positive Opinions) และความคิดเชิงลบ (Negative Opinions) และความคิดเห็นที่เป็นกลาง (Neutral Opinions) ข้อความคิดเห็นที่เพิ่มขึ้นจำนวนมหาศาลบนเครือข่ายสังคมออนไลน์ได้ถูกนำมาใช้ในการวิเคราะห์ด้านต่างๆ เช่น ผู้ลงทะเบียนเลือกตั้งสามารถนำข้อความคิดเห็นมาใช้ในการสำรวจความนิยมของประชาชนต่อพระราชกรณีย์ของตนหรือเพื่อนำเสนอเรื่องที่ประชาชนให้ความสนใจ ผู้ให้บริการโรงแรมสามารถสำรวจความพึงพอใจต่อการให้บริการเพื่อใช้ในการปรับปรุงการให้บริการโดยใช้ข้อความคิดเห็น ผู้ผลิตสินค้าและบริการสามารถสำรวจความพึงพอใจของผู้บริโภคต่อสินค้าและบริการผ่านข้อความคิดเห็น เพื่อนำผลการวิเคราะห์ไปใช้ในการปรับปรุงสินค้าและบริการให้ดียิ่งขึ้น หรือเพื่อ พัฒนาสินค้าให้ตรงตามความต้องการของผู้บริโภค นอกจากนี้ข้อความคิดเห็นยังสามารถนำไปในด้านการศึกษา โดยการสำรวจความพึงพอใจของผู้เรียนต่อการจัดการเรียนการสอน สิ่งสนับสนุนการเรียนรู้จากข้อความคิดเห็น เพื่อนำมาปรับปรุงในการจัดการเรียนการสอนให้มีประสิทธิภาพมากยิ่งขึ้น เป็นต้น ปัจจุบันมีการนำเสนotechnique ทางด้านคอมพิวเตอร์เพื่อใช้ในการวิเคราะห์อารมณ์ความรู้สึกหรือทัศนคติ (Sentiment Analysis) จากข้อความคิดเห็น วิธีการที่ได้รับความนิยมมากที่สุด คือ การทำเหมืองความคิดเห็น (Opinion Mining) ซึ่งเป็นวิธีการในการสกัดเอารความรู้สึกจากข้อความจำนวนมหาศาล มาใช้ประโยชน์ นักวิจัยจำนวนมากทำการศึกษาในด้านนี้ เช่น Chan และ Chong [1] ได้ศึกษาการวิเคราะห์ความรู้สึกของนักลงทุนในตลาดหุ้น ซึ่งการวิเคราะห์ความรู้สึกของนักลงทุนที่แสดงออกมายังผ่านข้อความนั้นจะเป็นประโยชน์ต่อการวิเคราะห์แนวโน้มในตลาดหุ้น Tartir และ Abdul-Nabi [2] ได้นำเสนอการค้นหาวิเคราะห์ความรู้สึก ทัศนคติและข้อมูลเชิงลึกทางธุรกิจจากสื่อสังคมออนไลน์ทวิตเตอร์ของอาหรับ โดยศึกษาความรู้สึกที่แตกต่างกัน ทำให้เข้าใจความรู้สึกของนิติบุคคลบางอย่างที่เป็นสิ่งสำคัญสำหรับใช้ในการตัดสินใจของผู้ผลิต ในการวางแผนที่จะขยายงานในอนาคต Gitto และ Mancuso [3] นำเสนอการวิเคราะห์ทัศนคติ ความพึง

พอใจของผู้รับบริการของสนามบินโดยการวิเคราะห์ความรู้สึกของลูกค้า ความคิดด้านบวก (Positive) ด้านลบ (Negative) และ ความคิดเห็นเป็นกลาง (Neutral) เพื่อนำผลการวิเคราะห์ไปปรับปรุงการให้บริการของสนามบิน เป็นต้น

ในการวิเคราะห์ความรู้สึกเพื่อทราบถึงทัศนคติในทางบวกหรือทางลบ นั้นบางครั้ง ไม่เพียง พอที่จะทำให้ทราบถึงความคิดเห็นที่แท้จริง ทำให้การวิเคราะห์ข้อมูลนั้นอาจ ผิดพลาดได้ เพราะ บางครั้งข้อความที่สื่อสารออกมานั้นไม่ตรงกับความหมายที่แท้จริง ข้อความที่สื่อออกมานี้ลักษณะนี้ เรียกว่าเป็นข้อความประлага “การประชดประชัน” คือ ข้อความนั้นมีความหมายตรงกันข้ามกับ ความหมายที่แท้จริง เช่น “วันนี้อากาศดีจริงเลยยิယยิယยิယ” “โรงเรียนนี้บริการดีมากจนอยาก กลับมาพักอีกจะเมื่อไหร่” “นายกรัฐมนตรีบริหารงานดีมากจนประชาชนอดอยาก ขอให้ท่าน บริหารงานต่อเลื่อนประชานทนได้” “I love being ignored all the time” เป็นต้น จากประโยชน์ ตัวอย่างจะเห็นได้ว่าข้อความที่เขียนขึ้นเขียนโดยใช้คำเชิงบวกแต่ต้องการจะสื่อถึงความรู้สึกเชิงลบ หรือบางข้อความเขียนขึ้นโดยใช้คำในเชิงลบแต่ต้องการสื่อถึงความรู้สึกเชิงบวก ดังนั้นการพิจารณา ความหมายของคำจากข้อความเหล่านี้ว่าเป็นบวก ลบ นั้นยังไม่เพียงพอที่จะทำให้ทราบถึงความ คิดเห็นที่มีความหมายจริงๆ ของข้อความ การจำแนกข้อความประชดประชันนั้นจึงเป็นเรื่องที่ยาก และท้าทายในงานด้านการวิเคราะห์ความรู้สึก

ปัจจุบันได้มีการนำเสนotechnique วิธีการจำแนกข้อความประชดประชัน ด้วยวิธีการเรียนรู้แบบ มีผู้สอน (Supervised Learning) เช่น Jasso และ Meza [4] จำแนกข้อความประชดประชันในภาษา สเปน ที่อยู่บนเครือข่ายสังคมออนไลน์ทวิตเตอร์ โดยใช้ขั้นตอนวิธี Support Vector Machine และ Random Forest, Bouazizi และ Otsuki [5] ใช้รูปแบบของข้อความในการตรวจจับข้อความประชด ประชัน Razali และคณะ [6] ใช้เทคนิคการเรียนรู้เชิงลึกกับคุณลักษณะบริบทของข้อความในการ ตรวจจับข้อความประชดประชัน และยังมีนักวิจัยให้ความสนใจในการศึกษาการจำแนกข้อความ คิดเห็นประชดประชันในหลากหลายภาษาอย่างคงเป็นงานที่ท้าทายเนื่องจากแต่ละภาษา มีเอกลักษณ์ ทางภาษาที่แตกต่างกัน ทำให้กระบวนการวิธีในการจำแนกแตกต่างกันไป เช่น ภาษาไทยเป็นภาษาที่ มีความซับซ้อนกว่าภาษาอังกฤษ การจำแนกข้อความประชดประชันภาษาไทยจึงถือว่าเป็นงานที่ท้า ทายและยังถือเป็นเรื่องใหม่เนื่องจากยังไม่ได้มีการศึกษาการจำแนกข้อความประชดประชันภาษาไทย

ดังนั้นงานวิจัยนี้จึงนำเสนอกระบวนการในการจำแนกข้อความคิดเห็นประชดประชันภาษาไทยบนเครือข่ายสังคมออนไลน์และศึกษาคุณลักษณะที่สามารถจำแนกข้อความคิดเห็นประชดประชันภาษาไทยได้อย่างมีประสิทธิภาพ

1.2 วัตถุประสงค์ของการวิจัย

1. เพื่อพัฒนากระบวนการวิธีการจำแนกข้อความประชดประชันภาษาไทยบนเครือข่ายสังคมออนไลน์
2. เพื่อศึกษาคุณลักษณะที่ใช้ในการจำแนกข้อความประชดประชัน

1.3 ความสำคัญของการวิจัย

1. งานวิจัยนี้นำเสนอกระบวนการในการจำแนกข้อความประชดประชันภาษาไทยเพื่อให้ทราบถึงความรู้สึกที่แท้จริงและซึ่งจะช่วยเพิ่มประสิทธิภาพในงานด้านการวิเคราะห์อารมณ์ความรู้สึกได้ถูกต้องมากยิ่งขึ้น
2. งานวิจัยนี้ทำการศึกษาคุณลักษณะข้อความของภาษาไทยที่สามารถใช้ในการจำแนกข้อความประชดประชัน ทำให้ทราบถึงคุณลักษณะที่เหมาะสมในการจำแนกข้อความประชดประชันภาษาไทยและพบว่าการรวมกันระหว่างคุณลักษณะจากบริบทของข้อความ (Context-based feature) และ คุณลักษณะจากเนื้อหาในข้อความ (Content-based feature) ช่วยให้การจำแนกข้อความประชดประชันมีประสิทธิภาพยิ่งขึ้น

1.4 ขอบเขตของการวิจัย

1. จำแนกข้อความประชดประชันภาษาไทยที่อยู่บนเครือข่ายสังคมออนไลน์ Facebook จำนวน 10,800 ข้อความ แบ่งเป็นข้อความประชดประชันจำนวน 5,400 ข้อความ และข้อความไม่ประชดประชันจำนวน 5,400 ข้อความ
2. คุณลักษณะที่ใช้ในการจำแนกข้อความประชดประชันประกอบไปด้วยคุณลักษณะจากบริบทของข้อความและคุณลักษณะจากเนื้อหาในข้อความซึ่งสกัดจากข้อความภาษาไทย เครื่องหมายวรรคตอนและไอคอนแสดงอารมณ์ (Emoticons)
3. ใช้แฮชแท็ก #ประชด #ประชดประชัน สำหรับเก็บรวบรวมข้อความประชดประชัน
4. การจำแนกข้อความประชดประชันแบ่งออกเป็น 2 แบบ คือ ข้อความประชดประชัน และ ข้อความไม่ประชดประชัน

5. ประเมินประสิทธิภาพในการจำแนกข้อความประชดประชัน โดยใช้ ค่าความถูกต้อง ค่าระลีก ค่าความแม่นยำ และค่าประสิทธิภาพโดยรวม

1.5 นิยามศัพท์เฉพาะ

1. การจำแนกความคิดเห็นประชดประชัน คือ การจำแนกข้อความประชดประชันที่สามารถบ่งบอกว่าข้อความนั้นเป็นข้อความประชดประชันหรือเป็นข้อความไม่ประชดประชัน
2. คุณลักษณะจากบริบทของข้อความ คือ การใช้คำในชุดข้อมูลมาสร้างเป็นคุณลักษณะเพื่อใช้เป็นตัวแทนคุณลักษณะทั้งหมดของชุดข้อความ
3. คุณลักษณะจากเนื้อหาในข้อความ คือ การใช้เนื้อหาในชุดข้อมูลมาสร้างเป็นคุณลักษณะ เช่น การมีอคอนแสดงอารมณ์ การมีเครื่องหมายคำถาม การมีข้อความแสดงการหัวเราะ เป็นต้น
4. การวิเคราะห์ความรู้สึกบนเครือข่ายสังคมออนไลน์ คือ การวิเคราะห์ความรู้สึก ทัศนคติ ผ่านข้อความที่ผู้ใช้เครือข่ายสังคมออนไลน์ได้ โพสต์ การแสดงความคิดเห็น การรีวิวสินค้า

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

งานวิจัยนี้ได้ศึกษา ทบทวนทฤษฎีและงานวิจัยที่เกี่ยวข้อง เพื่อใช้ในการดำเนินงานวิจัย ซึ่งมีหัวข้อดังต่อไปนี้ การวิเคราะห์ข้อมูลเห็นประชดประชัน การเตรียมข้อมูล (Data Preparation) วิธีการเรียนรู้ของเครื่อง (Machine Learning approach) วิธีการเรียนรู้เชิงลึก (Deep Learning) การวัดประสิทธิภาพการจำแนก และงานวิจัยที่เกี่ยวข้อง เพื่อใช้เป็นทฤษฎีในการศึกษาการพัฒนา วิธีการจำแนกข้อความประชดประชันสำหรับการวิเคราะห์ความรู้สึกข้อความภาษาไทยบนเครือข่าย สังคมออนไลน์ โดยรายละเอียดในแต่ละหัวข้อมีดังนี้

2.1 การวิเคราะห์ข้อมูลเห็นประชดประชัน

การประชดประชัน เป็นลักษณะที่สื่อถึงการแสดงออกทางข้อความที่มีความหมายที่อาจจะตรงข้ามกับความหมายที่แท้จริงของผู้สื่อสาร ซึ่งแสดงออกถึงอารมณ์หลากหลาย [5] เช่น การแสดงการประชดประชันที่แสดงออกถึงการตกลงขั้น การแสดงถึงการแสดงออกที่มีแนวโน้มการพูดเกินจริง การใช้น้ำเสียงที่แตกต่าง การแสดงออกถึงการเสียดสีที่แสดงออกถึงความรำคาญหรือมีความโกรธ การใช้คำที่ใช้การสื่อสารในแบบอย่างมากเพื่ออธิบายสถานการณ์เชิงลบ หรือการใช้คำเสียดสี ประชดประชันเพื่อแสดงออกถึงสถานการณ์ที่ต้องการหลีกเลี่ยงการให้คำตอบที่ชัดเจน บุคคลนั้นจะใช้ประโยชน์ที่ซับซ้อน คำที่ไม่ได้ใช้ในปกติทั่วไป และใช้นิพจน์บางอย่างที่ไม่ปกติ การแสดงออกถึงการประชดประชันนั้นบุคคลสามารถรับรู้ได้ยากจากการแสดงออกนั้นเกิดขึ้นซึ่งๆ หน้า การแสดงออกต่อหน้า เห็นสีหน้าท่าทาง ได้ยินเสียงจะสามารถวิเคราะห์ได้ว่าบุคคลแสดงออกถึงการประชดประชัน หรือไม่ แต่การแสดงถึงการประชดประชันด้วยข้อความบนเครือข่ายสังคมออนไลน์นั้น เป็นเรื่องยากที่จะทราบได้ว่าบุคคลนั้นได้แสดงออกถึงการประชดประชันหรือไม่ นอกจากผู้ที่เป็นเจ้าของข้อความนั้น ตั้งนั้นงานด้านการวิเคราะห์ข้อความประชดประชันบนเครือข่ายสังคมออนไลน์นั้นจึงเป็นงานที่มีความสำคัญที่จะช่วยส่งเสริมการพัฒนางานด้านการวิเคราะห์อารมณ์ความรู้สึกให้มีประสิทธิภาพมากขึ้น

การวิเคราะห์ความรู้สึกเป็นเทคนิคในการระบุความคิดเห็น ทศนคติ และอารมณ์ของบุคคลที่มีต่อสิ่งต่างๆ [1, 2, 7, 8] โดยมีวัตถุประสงค์ในการจำแนกความคิดเห็นโดยการนำหลักการทำเหมืองความคิดเห็น (Opinion Mining) ในการวิเคราะห์ความรู้สึกนั้นจะช่วยให้เห็นว่าผู้บริโภคชอบและไม่ชอบ พึงพอใจต่อสินค้าและบริการหรือไม่ ความคิดเห็นของผู้ใช้งานจากสื่อสังคมออนไลน์เป็นแหล่งที่มีประโยชน์อย่างมาก เนื่องจากเป็นเครือข่ายที่ใหญ่ มีผู้คนแสดงความคิดเห็น หรือโพสต์ข้อความอยู่

ตลอดเวลา งานวิจัยด้านการวิเคราะห์ความรู้สึกนั้นมีการนำมาประยุกต์ใช้กับข้อมูลการแสดงความคิดเห็นต่อสินค้าและบริการ จุดประสงค์เพื่อวิเคราะห์ความรู้สึกของผู้บริโภค ว่ามีความรู้สึกอย่างไรต่อสินค้าและบริการ สามารถวิเคราะห์ความคิดเห็นออกเป็น ความคิดเห็นเป็นบวก ลบ และเป็นกลางต่อสินค้าและบริการนั้น

ในบางครั้งข้อความที่สื่อถ่องมาอาจจะเป็นข้อความที่มีความหมายไม่ตรงกับความหมายที่แท้จริง สาเหตุเนื่องจากเหตุผลบางอย่างที่ทำให้ไม่สามารถแสดงความคิดเห็นได้ เช่น ความคิดเห็นที่แสดงออกไปอาจผิดกฎหมาย จึงจำเป็นต้องหลีกเลี่ยงการใช้คำที่มีความตรึงๆ เปลี่ยนไปใช้คำที่ต่างจากปกติ หรือ ใช้สัญลักษณ์อื่นๆ ในการแสดงข้อความประเภทนี้ เรียกว่า “ข้อความคิดเห็นประชดประชัน” ซึ่งในการแสดงความคิดเห็นประชดประชันนั้นเกิดจากเหตุผลหลายอย่าง เช่น มีจุดประสงค์เพื่อต้องการสื่อถึงเรื่องตอกขับขัน แสดงออกเมื่อมีอารมณ์โกรธ และแสดงอาการในการหลีกเลี่ยงการตอบคำถาม เป็นต้น ในการจำแนกหรือการวิเคราะห์ความคิดเห็นนั้นบางครั้งหากข้อความเหล่านั้นถูกวิเคราะห์ความเห็นถ่องมาเป็นความหมายเชิงบวก ซึ่งความหมายที่แท้จริงหากข้อความนั้นเป็นข้อความประชบทประชันนั้นอาจจะให้ความหมายเชิงลบ ดังนั้น ในงานทางด้านการตรวจจับข้อความคิดเห็นประชดประชันนั้นถือว่าเป็นงานที่มีความสำคัญที่จะช่วยส่งเสริมให้งานด้านการวิเคราะห์อารมณ์ความรู้สึกสามารถวิเคราะห์ข้อมูลได้ถูกต้องตามความหมายที่แท้จริงมากยิ่งขึ้น

2.2 การเตรียมข้อมูล

ขั้นตอนในการเตรียมข้อมูลนั้นเป็นขั้นตอนที่สำคัญในการที่จะนำข้อมูลไปทำการวิเคราะห์เนื่องจากข้อความคิดเห็นเป็นข้อมูลที่อยู่ในรูปแบบไม่มีโครงสร้าง (Unstructured Data) จึงจำเป็นต้องแปลงข้อมูลให้อยู่ในรูปแบบที่มีโครงสร้างก่อน โดยวิธีการเตรียมข้อมูล [9-11] เพื่อทำการกำจัดข้อมูลที่มีสิ่งรบกวน (Noise) และข้อมูลที่ไม่สำคัญกับการนำไปใช้งาน เพื่อให้ได้ข้อมูลให้อยู่ในรูปแบบเดียวกัน (Consistency) ที่สามารถนำไปประมวลผลและทำให้การวิเคราะห์ข้อมูลไม่ผิดพลาด ทำให้มีความถูกต้อง (Accuracy) มาถึงขั้น โดยกระบวนการเตรียมข้อมูลประกอบไปด้วยดังหัวข้อต่อไปนี้

2.2.1 การตัดคำ (Tokenization)

การตัดคำถือได้ว่าเป็นความจำเป็นพื้นฐานที่สำคัญขั้นตอนหนึ่งที่เกี่ยวข้องกับการประมวลผลภาษาธรรมชาติ (Natural Language Processing) ซึ่งข้อความเกิดจากการรวมกันของคำ เป็นประโยชน์ ดังนั้นกระบวนการตัดคำคือกระบวนการที่การนำเอาเอกสารหรือข้อความมาแบ่งเป็น

ประโยค (Sentence) หรือ คำ (Word) [12, 13] การตัดคำในข้อความภาษาอังกฤษนิยมใช้ ช่องว่าง (White Space) คอมมา (Comma: ,) จุดทศนิยม (Point: .) เครื่องหมายอัม加分 (Semicolon: ;) เครื่องหมายคำถาม (Question Mark: ?) เครื่องหมายวรรคตอนหรือสัญลักษณ์ต่างๆ ในขั้นตอนการตัดคำจะเริ่มจากการค้นหาตรวจสอบข้อความทั้งหมดเพื่อหาขอบเขตของคำและประโยค ซึ่งในภาษาอังกฤษนั้นจะใช้ช่องว่างในการแบ่งคำออกจากกัน และใช้จุดเป็นตัวบอกว่าจบประโยค ในส่วนของการตัดคำในภาษาไทยนั้น สามารถทำได้หลายวิธี เช่น การตัดคำโดยการเทียบคำที่ยาวที่สุด (Longest Matching) วิธีนี้จะค้นหาคำ โดยเริ่มจากการพิจารณาข้อความทั้งข้อความแล้วเปรียบเทียบกับคำในพจนานุกรมว่ามีคำนั้นหรือไม่ หากไม่มี จะพิจารณาตัดตัวอักษรตัวสุดท้ายออกและนำข้อความที่เหลือไปเปรียบเทียบกับคำในพจนานุกรมอีกครั้ง และจะทำซ้ำไปเรื่อยจนกว่าจะได้ข้อความที่มีในพจนานุกรม ตัวอย่างเช่น การแบ่งคำในประโยค "ฉันนั่งตากลมที่ริมหาด" จะเริ่มพิจารณาทั้งประโยคแล้วนำไปเปรียบเทียบกับพจนานุกรม หากพบว่าทั้งข้อความมีอยู่ในพจนานุกรมก็จะได้ข้อความนั้น หากไม่พบก็จะเริ่มตัดตัวอักษรออกทีละตัวจนพบข้อความ หลังจากนั้น ก็จะทำการเปรียบเทียบต่อไป ซึ่งจะได้ผลลัพธ์ออกมาคือ "ฉัน นั่ง ตาก ลม ที่ ริม หาด" ตัวอย่างการตัดคำดังแสดงในตารางที่ 1

วิธีการตัดคำแบบเมื่อนมากที่สุดหรือให้มีจำนวนคำน้อยที่สุด (Maximal Matching) โดยจะใช้รูปในการตัดคำที่สามารถจะเป็นไปได้ทั้งหมด จากนั้นจะเลือกจำนวนคำที่น้อยที่สุดเป็นคำตอบ เช่น การแบ่งคำในประโยค "ฉันชอบไปโรงเรียน" เมื่อตรวจสอบตามพจนานุกรมจะได้ผลลัพธ์การตัดคำออกมาเป็นสองแบบคือ “ฉัน ชอบ ไป โรง เรียน” และ “ฉัน ชอบ ไป โรงเรียน” แบบที่ 1 ได้จำนวนคำ 5 คำ แบบที่ 2 ได้จำนวนคำ 4 คำ ดังนั้นจริงเลือกแบบที่ 2 ซึ่งมีจำนวนคำน้อยกว่า ดังแสดงตัวอย่างในตารางที่ 2

ตารางที่ 1 ตัวอย่างการตัดคำโดยการเทียบคำที่ยาวที่สุด (Longest Matching)

ประโยค	Longest Matching	ผลของการตัด
"ฉันนั่งตากลมที่ริมหาด"	ฉันนั่งตากลมที่ริมหาด	
	ฉันนั่งตากลมที่ริมหาด	
	.	
	.	
	ฉันนั่งตากลมที่ริมหาด	ฉัน
	นั่งตากลมที่ริมหาด	ฉัน นั่ง

ตารางที่ 1 ตัวอย่างการตัดคำโดยการเทียบคำที่ยาวที่สุด (Longest Matching) (ต่อ)

	ตากล้มหริมหาก	ฉัน นั่ง ตาก
	ลมหริมหาก	ฉัน นั่ง ตาก ลม
	หริมหาก	ฉัน นั่ง ตาก ลม ที่
	ริมหาก	ฉัน นั่ง ตาก ลม ที่ ริม
	หาด	ฉัน นั่ง ตาก ลม ที่ ริม หาด

ตารางที่ 2 ตัวอย่างการตัดคำภาษาไทยจำนวนคำน้อยที่สุด (Maximal Matching)

ประโยชน์	Maximal Matching	จำนวนคำ
ฉันชอบไปโรงเรียน	ฉัน ชอบ ไป โรง เรียน	5
	ฉัน ชอบ ไป โรงเรียน	4

2.2.2 การสกัดคุณลักษณะ

การสกัดคุณลักษณะ [10] หมายถึง การนำเอาคุณลักษณะของเอกสารออกมานี้ ซึ่งคำที่นำมาเป็นคุณลักษณะนั้นจะต้องสามารถเป็นตัวแทนของเอกสารนั้นได้ ซึ่งในการเลือกคุณลักษณะนั้นสามารถทำได้หลายวิธี เช่น วิธีแบบชุดลำดับคำ (N-Grams) [4, 5] การใช้การแทนข้อความด้วยถุงคำ (Bag-of-Word) [14] การใช้หน้าที่ของคำ (Part of Speech) [15-17] หลังจากคำคุณลักษณะที่เป็นตัวแทนแล้วจะแทนค่าคุณลักษณะเหล่านั้นให้อยู่ในรูปแบบเวกเตอร์ (Vector) โดยมีวิธีการคำนวณค่า น้ำหนักได้หลายวิธีและที่นิยมใช้เพื่อแทนค่าคุณลักษณะ มีดังนี้

1) Boolean Weighting เป็นการคำนวณค่าน้ำหนักจากการประภูมิคำในเอกสาร ซึ่งได้รวบรวมไว้แล้วในถุงคำ หากมีคำประภูมิอยู่ในเอกสารที่ตรงกับถุงคำ จะให้ค่าน้ำหนักเป็น 1 ถ้าไม่ประภูมิอยู่ในเอกสาร จะให้ค่าน้ำหนักเป็น 0 ค่าน้ำหนักในลักษณะนี้เรียกว่าอย่างว่า ค่าคุณลักษณะ ความจริง (Boolean Feature) ซึ่งมีค่าเป็นใบหนารี ดังแสดงในสมการที่ (1)

$$B_{td} = \begin{cases} 1, & \text{for term present in document} \\ 0, & \text{otherwise} \end{cases} \quad (1)$$

โดยที่ B_{td} คือ ค่าการเกิดคุณลักษณะ t ในเอกสาร d

ตัวอย่างการคำนวณค่า Boolean Weighting ของข้อความ ต่อไปนี้ “เป็นไปไม่ได้”, “ความพยายามอยู่ที่ไหน”, “ทำดีຍ່ອມໄດ້ສີ” เมื่อตัดคำแล้วแค่ค่าในตารางเวกเตอร์สเปส แล้วแทนค่าน้ำหนักในถุงคำ ซึ่งหากมีคำดังนี้ “เป็น, ไป, ໄດ້, ໄນ, ຮັກ, ຄວາມ, ພຍາມາ, ເສມອ, ດີ, ທຳ” ตัวอย่างดังแสดงในตารางที่ 3

ตารางที่ 3 ตัวอย่างการคำนวณค่า Boolean Weighting

Doc	เป็น	ไป	ได้	ไม่	รัก	ความ	พยาบาล	เสมอ	ดี	ทำ
1	1	1	1	1	0	0	0	0	0	0
2	0	0	0	0	0	1	1	0	0	0
3	0	0	1	0	0	0	0	0	1	1

2) Term Frequency: TF [12] เป็นการแทนข้อความด้วยค่าน้ำหนักความถี่ในการเกิดคำในเอกสาร หากคุณลักษณะใดปรากฏบ่อยในเอกสารค่าน้ำหนักความถี่ย่อมมีค่าสูงและหากคำใดไม่ปรากฏในเอกสารเลยจะให้ค่าน้ำหนักความถี่เป็น 0 สามารถคำนวณได้ดังสมการที่ (2) ในกรณีที่เอกสารแต่ละเอกสารมีความยาวไม่เท่ากัน หรือแตกต่างกันมาก เช่น เอกสารที่ 1 มี 5 คำ แต่เอกสารที่ 2 มีจำนวน 100 คำ เพื่อป้องกันไม่ให้ความยาวของเอกสารมีผลต่อการคำนวณและช่วยป้องกันไม่ให้เกิดความแตกต่างกันในการคำนวณของแต่ละเอกสารนิยมนิยมนิยม normalization ซึ่งหมายความว่าสำหรับข้อมูลที่มีความยาวของเอกสารไม่เท่ากัน ดังสมการที่ (3)

$$tf_{td} = freq(t, d) \quad (2)$$

เมื่อ $freq(t, d)$ คือ ค่าความถี่ของการปรากฏคุณลักษณะ t ในเอกสาร d

$$Normalization(tf_{td}, K) = K + (1 - K) \frac{freq(t, d)}{\max(freq(d))} \quad (3)$$

เมื่อ K คือ มีค่าอยู่ระหว่าง 0 ถึง 1

เมื่อ $\max(freq(d))$ คือ ค่าความถี่สูงสุดของการปรากฏคุณลักษณะในเอกสาร d

3) Term Frequency – Inverse Document Frequency: TF-IDF เป็นการคำนวณค่าน้ำหนักระหว่างความถี่และความถี่ผกผันของการปรากฏคำ ในเอกสาร และจะพิจารณาความถี่ของคำที่ปรากฏในเอกสาร ร่วมด้วย การคำนวณด้วยวิธีนี้เมื่อการแทนค่าความถี่การปรากฏของคุณลักษณะอย่างเดียวไม่เพียงพอ เนื่องจากจะไม่สามารถจำแนกได้หากคุณลักษณะนั้นปรากฏขึ้นเป็นจำนวนมากในทุกเอกสาร และดงว่าคุณลักษณะดังกล่าวไม่สามารถใช้เป็นตัวแทนของเอกสารนั้นได้ การหาค่าน้ำหนักแบบ TF-IDF สามารถคำนวณได้ดังสมการที่ (4)

$$idf_{td} = \log\left(\frac{N}{D_t}\right) \quad (4)$$

เมื่อ N คือ จำนวนเอกสารทั้งหมด

D_t คือ จำนวนเอกสารทั้งหมดที่มีคุณลักษณะ t ปรากฏอยู่

การหาจำนวนหาค่าความถี่และความถี่ผกผัน จะคำนึงถึงความถี่ของการปรากฏคุณลักษณะในเอกสาร และค่าความถี่ผกผัน สามารถคำนวณได้ดังสมการที่ (5)

$$tfidf_{td} = tf_{td} \times idf_{td} \quad (5)$$

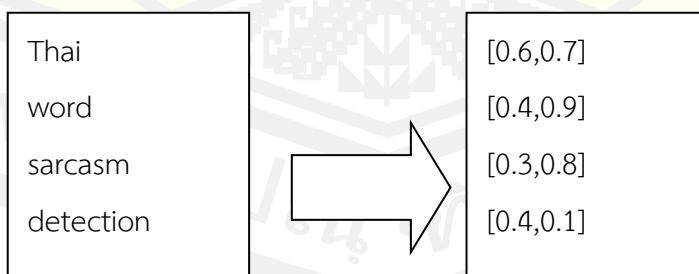
2.2.3 รูปแบบการแทนข้อความ (Document representation)

2.2.3.1 โมเดลเชิงพื้นที่แบบเวกเตอร์ (Vector Space Model)

โมเดลเชิงพื้นที่แบบเวกเตอร์ [18] เป็นรูปแบบในการแทนข้อความ ซึ่งมีวัตถุประสงค์เพื่อใช้ตัวเลขเป็นตัวแทนของเอกสารเป็นการให้ค่าน้ำหนักคำเอกสารที่ไม่มีโครงสร้างเพื่อให้อยู่ในรูปแบบที่คอมพิวเตอร์สามารถประมวลผลได้ ซึ่งในเอกสารสามารถระบุเอกสาร $D = d_x, x = 1, 2, 3, \dots, n$ ซึ่งแต่ละ d_x แทนจำนวนคำที่ไม่ซ้ำกันที่มาจากการจัดเรียงของเอกสาร D

2.2.3.2 Word Embedding

Word Embedding [19-21] เป็นวิธีการสร้างคุณลักษณะของประโยคหรือเอกสารขึ้นมาให้อยู่ในรูปแบบเวกเตอร์ หรือเรียกว่าการสร้างคุณลักษณะเวกเตอร์ขึ้นมาจากประโยคหรือเอกสารที่มีอยู่ในข้อมูลเพื่อสร้างคุณลักษณะที่อยู่ในรูปแบบตัวเลข โดยการเข้ารหัสคำแต่ละคำให้อยู่ในรูปแบบที่สามารถนำไปคำนวณที่คอมพิวเตอร์สามารถทำความเข้าใจได้ ซึ่งข้อดีของการทำ Word Embedding นั้นจะสามารถนำไปใช้ในการคำนวณความคล้ายคลึงกับคำอื่น ๆ ในบริบทของคำที่แตกต่างกันได้ โดยลักษณะการสร้างเวกเตอร์คุณลักษณะจะเริ่มจากการเข้ารหัสคำแต่ละคำด้วยวิธี One-Hot Encoding ซึ่งจะทำงานโดยการนำจำนวนคำที่ปรากฏขึ้นมาในชุดข้อมูล และนำประโยคในชุดข้อมูลหรือเอกสารที่ได้ทำการกำหนดไว้ในชุดข้อมูลมาเข้ารหัส ทำให้ได้เวกเตอร์ตามจำนวนคำในประโยคที่กำหนดให้อยู่ในรูปของบิต จากนั้นทำการรวมเวกเตอร์ที่ได้จาก One-Hot Encoding ซึ่งสามารถกำหนดจำนวนมิติหรือคุณลักษณะของเวกเตอร์ได้ ตัวอย่างการใช้งาน Word Embedding ในการแปลงข้อความเป็นเวกเตอร์ ดังแสดงในรูปที่ 1



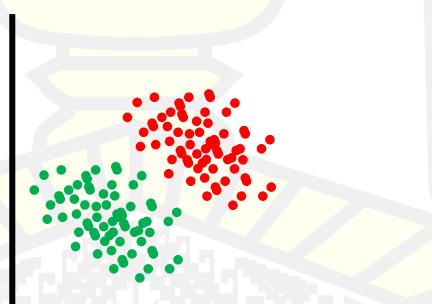
รูปที่ 1 ตัวอย่างการใช้งาน Word Embedding ในการแปลงข้อความให้อยู่ในรูปแบบเวกเตอร์

2.3 การจำแนกข้อมูลด้วยวิธีการเรียนรู้ด้วยเครื่อง

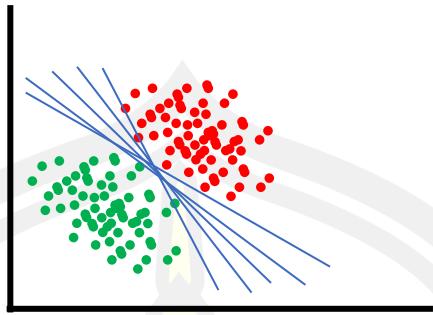
การจำแนกข้อมูลด้วยวิธีการเรียนรู้ด้วยเครื่อง (Machine Learning approach) เป็นความพยายามทำให้เครื่องคอมพิวเตอร์หรือเครื่องอิเล็กทรอนิกส์ให้สามารถทำงานที่มีความคลาดได้ โดยการสร้างเครื่องจักรที่สามารถเรียนรู้ได้ ซึ่งเป็นเทคนิคนึงที่ใช้ในการจำแนกข้อมูลหรือเอกสาร ซึ่งนิยมนำมาใช้ในงานด้านการวิเคราะห์ความรู้สึก [3, 22-24] โดยจะใช้เทคนิควิธีการเรียนรู้แบบมีผู้สอน (Supervised Learning) ซึ่งเป็นเทคนิคในการเรียนรู้ด้วยเครื่องซึ่งเป็นการนำเข้าข้อมูลที่มีอยู่เข้าสู่ระบบเพื่อใช้สร้างข้อมูลชุดสอน (Training dataset) เพื่อใช้สำหรับการทำนายค่าตอบให้กับชุดข้อมูลใหม่ที่ยังไม่รู้คำตอบ (Testing dataset) และวิธีการที่นิยมในการจำแนกความคิดเห็นประกอบไปด้วย ชั้ฟพอร์ทเวกเตอร์เมคชีน นาอีฟเบย์ เพื่อบันทึกที่สุด ต้นไม้ตัดสินใจ

1) ชัฟพอร์ทเวกเตอร์เมคชีน

ชัฟพอร์ทเวกเตอร์เมคชีนนิยมนำมาใช้ในการจัดกลุ่มข้อมูล [4, 17, 25] ซึ่งเป็นการแบ่งข้อมูลในลักษณะการใช้เส้นตรงเรียกว่าเส้นระนาบแบ่งข้อมูล (Hyper plane) ในการแบ่งข้อมูลออกจากกันเพื่อหาเส้นแบ่งที่เหมาะสมที่สุด ข้อดีของชัฟพอร์ทเวกเตอร์เมคชีนคือสามารถแบ่งกลุ่มข้อมูลได้ทั้งรูปแบบข้อมูลที่แบ่งกลุ่มที่เป็นเส้นตรงและไม่เป็นเส้นตรง นอกจากนี้ยังรองรับคุณลักษณะจำนวนมากได้ เนื่องจากเป็นการใช้การแทนข้อมูลด้วยเวกเตอร์และพิจารณาเส้นแบ่งข้อมูลจากเวกเตอร์ชัฟพอร์ท (Support Vector) แต่ข้อเสียคือต้องทดลองเพื่อปรับค่าพารามิเตอร์ให้เหมาะสมสมสำหรับแต่ละเคอร์เนล (Kernel) ที่เลือกใช้ จากชุดข้อมูลดังรูปที่ 2 และ รูปที่ 3



รูปที่ 2 ตัวอย่างกลุ่มข้อมูล



รูปที่ 3 เส้นไฮเปอร์เพลนแบ่งกลุ่มข้อมูล

จากรูปที่ 3 เส้นไฮเปอร์เพลนที่ใช้ในการแบ่งข้อมูลที่เกิดขึ้นมากกว่า 2 เส้น จึงต้องหาเส้นแบ่งที่เหมาะสมที่สุด คือเส้นที่ทำให้ชุดข้อมูลทั้งสองกลุ่มมีระยะห่างกันมากที่สุด (Maximum Margin Hyper plane: MMH) กำหนดให้ชุดข้อมูลเรียนรู้ $D = \{\vec{x}_i, y_i\}$ โดยที่ $\vec{x}_i(w_{i1}, w_{i2}, w_{i3},..w_{im})$ เป็นข้อมูลเวกเตอร์ตัวแทนของข้อความ และแต่ละ \vec{x}_i ถูกกำหนดคลาสไว้ด้วยคลาส เมื่อ เป็นค่าจำนวนจริงตั้งแต่ -1 ถึง +1 ดังสมการที่ (6)

$$y = \begin{cases} +1, \vec{w}^* \vec{x} + b > 0 \\ -1, \vec{w}^* \vec{x} + b > 0 \end{cases} \quad (6)$$

โดย \vec{w} คือ เวกเตอร์ที่ตั้งฉากกับเส้นไฮเปอร์เพลน

\vec{x}_i คือ ค่าเวกเตอร์ข้อมูล

b คือ ค่าโน้มเอียง (Bias)

เมื่อมีข้อมูล \vec{x} เข้ามาใหม่ จะคำนายหาคลาส y จากชุดข้อมูลเรียนรู้ (\vec{x}_i, y_i) ที่มีค่าใกล้เคียงที่สุด

2) นาอีฟเบย์ (Naïve Bayes)

เป็นวิธีการเรียนรู้แบบมีผู้สอนวิธีการหนึ่งที่จัดว่าง่ายและได้รับความนิยมนำมาใช้ในการจำแนกความคิดเห็นที่มีพื้นฐานมาจากทฤษฎีความน่าจะเป็นของเบย์ (Bayes theorem) [26] หรือกฎของเบย์ ตั้งชื่อตามโทมัส เบย์ (Tomas Bayes) นักสถิติและนักประษฐ์ชาวอังกฤษ ซึ่งกล่าวถึงความสัมพันธ์ระหว่างเหตุการณ์ในปัจจุบันและสิ่งที่เกิดก่อนหน้า โดยมีความน่าจะเป็นจะเป็นแบบมีเงื่อนไขเป็นประเดิมสำคัญในทฤษฎีนี้ ความน่าจะเป็นแบบมีเงื่อนไข (Conditional Probability) หมายถึงความน่าจะเป็นของการเกิดเหตุการณ์ A เมื่อกำหนดว่าเหตุการณ์ B เกิดขึ้นแล้ว แทนด้วยสัญลักษณ์ $P(A | B)$ ซึ่งสามารถคำนวณได้จากการน่าจะเป็นร่วม (Joint Probability) แทนด้วยสัญลักษณ์ $P(A \wedge B)$ หรือความน่าจะเป็นที่เหตุการณ์ A และเหตุการณ์ B เกิดขึ้นร่วมกันดังสมการที่ (7)

$$P(A | B) = \frac{P(A \wedge B)}{P(B)} \quad (7)$$

การจำแนกประเภทด้วยทฤษฎีของเบย์ [26] เพื่อใช้ในการจำแนกประเภท (Classification) จากกฎของเบย์สามารถกำหนดได้ดังสมการที่ (8)

$$P(h | D) = \frac{P(D | h)P(h)}{P(D)} \quad (8)$$

โดยที่ $P(D)$ คือ ความน่าจะเป็นก่อนของเซตตัวอย่างฝึกฝน D หรือเรียกว่า “Evidence”

$P(h)$ คือ ความน่าจะเป็นก่อน ของสมมติฐาน $h \in H$ หรือเรียกว่า “Prior”

$P(h | D)$ คือ ความน่าจะเป็นภายหลังของสมมติฐาน h เมื่อกำหนดเซตตัวอย่างฝึกฝน D

หรือเรียกว่า “Posterior”

$P(D | h)$ คือ ความน่าจะเป็นภายหลังของเซตตัวอย่างฝึกฝน D เมื่อกำหนดสมมติฐาน h หรือเรียกว่า “Likelihood”

3) เพื่อนบ้านใกล้ที่สุด (K-Nearest Neighbor: K-NN)

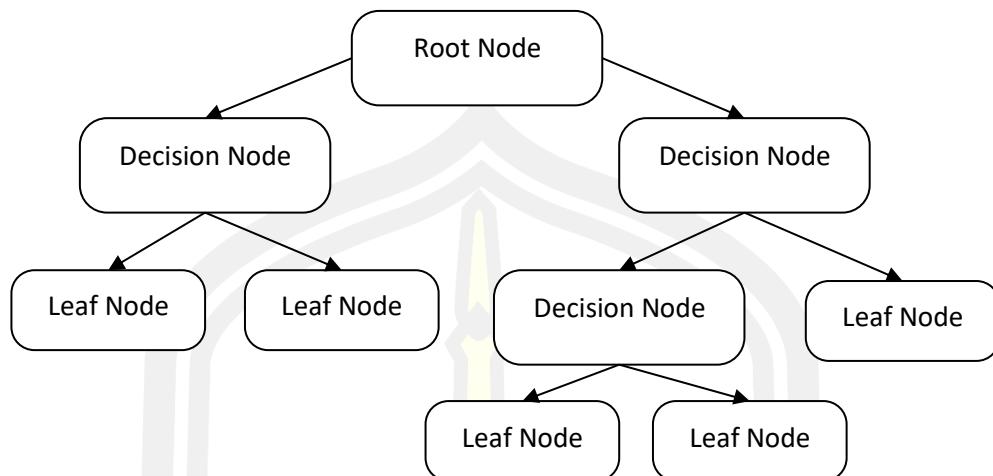
วิธีการจำแนกข้อมูลด้วย K-Nearest Neighbor หรือ เพื่อนบ้านที่ใกล้ที่สุด [27, 28] ถูกนำมาใช้ในการจัดกลุ่มข้อมูลที่อยู่ใกล้กันหรือเป็นกลุ่มข้อมูลเดียวกัน ซึ่งจะมีการกำหนดค่า K เป็นจำนวนกลุ่ม ซึ่งสามารถคำนวณหาระยะห่างระหว่างข้อมูลในแต่ละกลุ่มด้วยระยะห่างจากสมการที่ (9)

$$D_{Euclidian}(X_i, Y_i) = \sqrt{\sum_{k=1}^n (X_{i,k} - X_{j,k})^2} \quad (9)$$

โดยที่ $D_{Euclidian}(X_i, Y_i)$ คือ ระยะห่างระหว่างข้อมูล X_i และ Y_i
 k คือ คุณลักษณะทั้งหมดของตัวอย่าง

4) ต้นไม้ตัดสินใจ (Decision tree)

วิธีการจำแนกข้อมูลด้วย Decision tree หรือ ต้นไม้ตัดสินใจ [29] เป็นเทคนิคเรียนรู้ในการจำแนกข้อมูลในลักษณะโครงสร้างแบบต้นไม้ เพื่อแสดงเส้นทางในการตัดสินใจที่เป็นไปได้และผลลัพธ์ของแต่ละเส้นทาง โครงสร้างของต้นไม้ตัดสินใจดังแสดงในรูปที่ 4



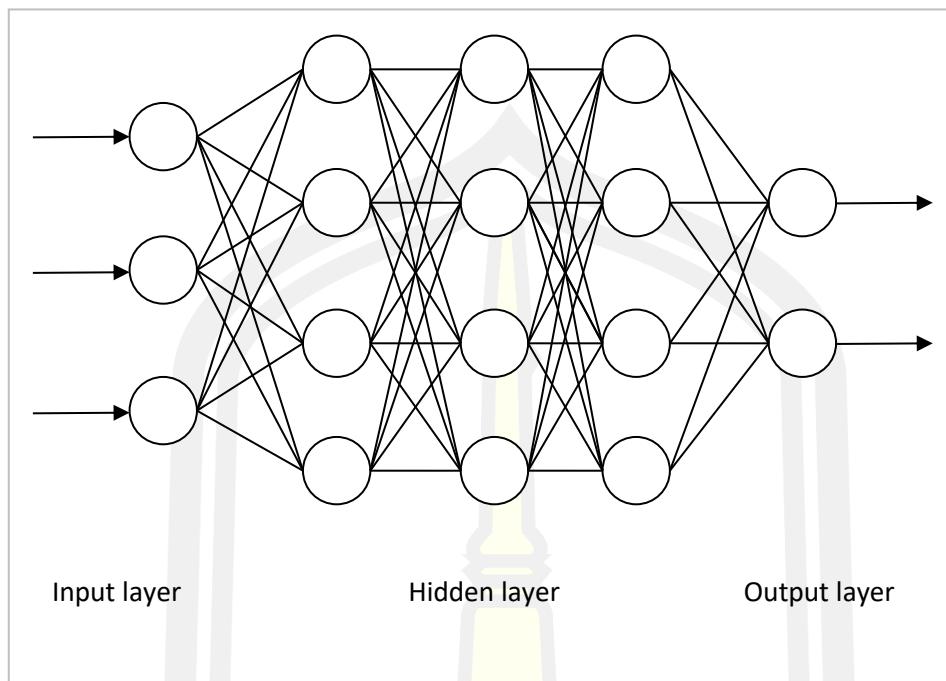
รูปที่ 4 โครงสร้างสำหรับการตัดสินใจของต้นไม้ตัดสินใจ

2.4 เทคนิคการเรียนรู้เชิงลึก

เทคนิคการเรียนรู้เชิงลึก (Deep learning) [6, 20, 30] เป็นวิธีการหนึ่งของการเรียนรู้ของเครื่อง (Machine Learning) [31] เป็นการพัฒนาเพื่อทำให้เครื่องจักรหรือคอมพิวเตอร์สามารถเลียนแบบวิธีการทำงานของโครงข่ายประสาท (Neurons) ที่เปรียบเสมือนสมองของมนุษย์ที่เรียกว่าโครงข่ายประสาทเทียม (Neural Network: NN) โดย Deep Learning ถูกสร้างขึ้นจากการนำเอา NN หลายชั้น (Layer) มาใช้ในการวิเคราะห์มากกว่า 2 ชั้น

2.4.1 Deep Neural Network

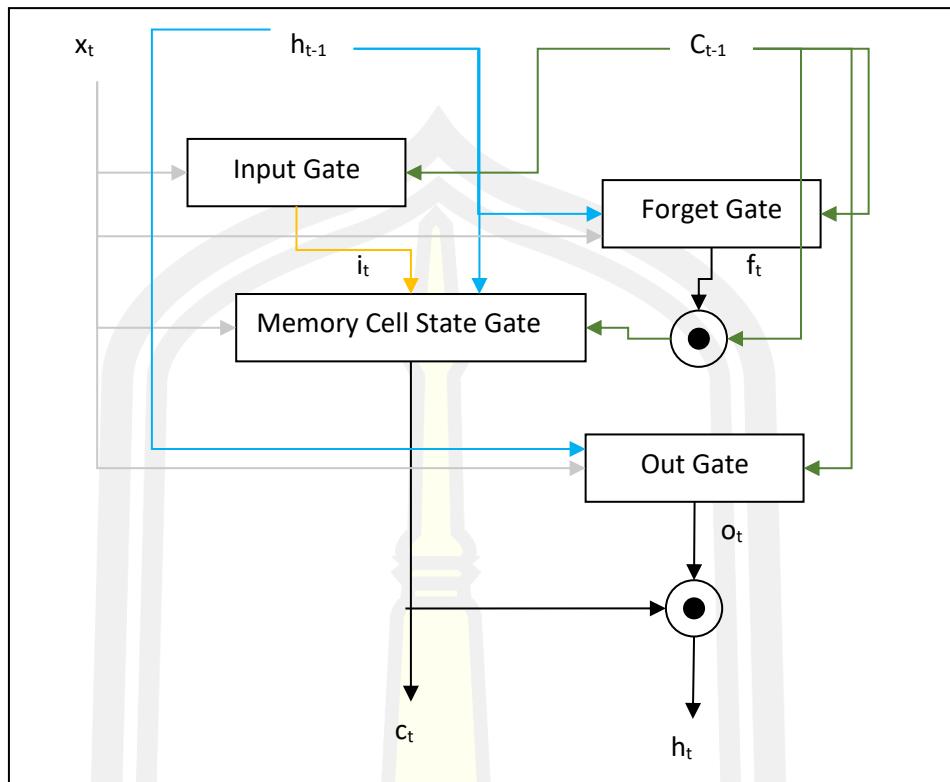
เทคนิคการเรียนรู้โครงข่ายประสาทเชิงลึก (Deep Neural Network: DNN) [19, 32] เป็นวิธีการนำอัลกอริทึมการเรียนรู้เชิงลึกไปใช้งานในรูปแบบที่ง่ายที่สุด โดยเป็นการต่อยอดมาจากโครงข่ายประสาทเทียมด้วยการเพิ่มจำนวนชั้นเข้าไป ทำให้มีตัวแปรที่ใช้ในการแยกคุณลักษณะที่มากขึ้น เพื่อเพิ่มประสิทธิภาพในการวิเคราะห์และการจำแนก ซึ่งการทำงานของโครงสร้างนั้นมีลักษณะเช่นเดียวกันกับโครงข่ายประสาทเทียมดังแสดงในรูปที่ 5



รูปที่ 5 ตัวอย่างโครงสร้างอัลกอริทึม Deep Neural Network

2.4.2 Long Short-Term Memory

เทคนิคการเรียนรู้หน่วยความจำระยะยาว-ระยะสั้น (Long Short-Term Memory: LSTM) [19, 33, 34] เป็นอัลกอริทึมที่ถูกพัฒนาต่อยอดมาจาก Recurrent Neural Network (RNN) [35] ซึ่งสามารถใช้งานได้ดีกับข้อมูลที่มีความต่อเนื่องกัน เช่น ข้อความ ข้อมูลเสียง รูปภาพ หรือ รูปแบบอนุกรมเวลา การปรับปรุงจาก RNN ผู้สร้าง LSTM ได้นำ RNN มาปรับปรุงโดยใช้วิธีการเพิ่มฟังก์ชัน จาก tanh และประกอบกับประตุที่มี 3 ประตุ ได้แก่ ประตุทางเข้า (Input Gate) ประตุลืม (Forget Gate) และ ประตุทางออก (Output Gate) พร้อมกับสถานะหน่วยอัปเดต (Update Cell State) ดังแสดงในรูปที่ 6



รูปที่ 6 ตัวอย่างโครงสร้างโครงข่ายประสาทแบบ LSTM
ที่มา [19]

Input Gate เป็นหน่วยที่ใช้ในการกำหนดว่าข้อมูลที่นำเข้ามายังเคราะห์ในเซลล์โดยพิจารณาสถานะข้อมูลที่ซ่อนอยู่จากขั้นตอนก่อนหน้าประตูเข้าเพื่อกำหนดว่าข้อมูลที่ป้อนมีค่าควรเก็บไว้หรือไม่ ดังแสดงในสมการที่ (10) [19, 36]

$$i_t = \sigma W_{xi} x_t + W_{hi} h_{t-1} + W_{ci} c_{t-1} + b_i \quad (10)$$

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 ที่ได้มาจากการคำนวณในหน่วยเวลา ก่อนหน้า
	W_{ci}	แทนค่าน้ำหนักสำหรับคำนวณ Memory Cell State ใน Input Gate
	c_{t-1}	แทนค่า Memory Cell State ที่ได้จากการคำนวณในหน่วยเวลา ก่อนหน้า
	b_i	แทนค่า Bias ที่ใช้ในการคำนวณใน Input Gate

Forget Gate เป็นหน่วยที่นำมาใช้ในการกำหนดข้อมูลที่จะนำมาทำการวิเคราะห์ใน Cell โดยทำการกำหนดค่าข้อมูลนั้นควรจะถูกบันทึกหรือถูกลืม โดยสามารถกำหนดได้จากสมการที่ (11) [19, 36]

$$f_t = \sigma W_{xf}x_t + W_{hf}h_{t-1} + W_{cf}c_{t-1} + b_f \quad (11)$$

เมื่อ	f_t	แทนผลลัพธ์ที่ได้จากการคำนวณของ 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 ที่ได้มาจากการคำนวณในหน่วยเวลา ก่อนหน้า
	W_{cf}	แทนค่าน้ำหนักสำหรับคำนวณ Memory Cell State ใน Input Gate
	c_{t-1}	แทนค่า Memory Cell State ที่ได้จากการคำนวณในหน่วยเวลา ก่อนหน้า
	b_f	แทนค่า Bias ที่ใช้ในการคำนวณใน Forget Gate

Memory Cell Gate เป็นหน่วยที่นำมาใช้ในการกำหนดข้อมูลที่จะนำมาทำการวิเคราะห์ใน Cell และทำการคำนวณค่าสถานะ เพื่อใช้ในการคำนวณค่าในครั้งถัดไป โดยสามารถกำหนดได้จาก สมการที่ (12) [19, 36]

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tanh W_{xc}x_t + W_{hc}h_{t-1} + b_c \quad (12)$$

เมื่อ	c_t	แทนผลลัพธ์ที่ได้จากการคำนวณของ Memory Cell Gate
	f_t	แทนผลลัพธ์ที่ได้จากการคำนวณของ Forget Gate
	c_{t-1}	แทนค่า Memory Cell Gate จากหน่วยเวลา ก่อนหน้า
	i_t	แทนค่าผลลัพธ์ที่ได้จากการคำนวณของ 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 ที่ได้มาจากการคำนวณในหน่วยเวลา ก่อนหน้า
	b_c	แทนค่า Bias ที่ได้มาจากการคำนวณใน Forget Gate

Output Gate เป็นหน่วยที่นำมาใช้ในการคำนวณ Output ของ Cell ซึ่งผลลัพธ์ที่ได้จาก Cell นี้จะมีอยู่ 2 อย่าง ได้แก่ Output และ Hidden State สำหรับใช้ในการคำนวณครั้งถัดไป โดยสามารถกำหนดได้จากสมการที่ (13) และสมการที่ (14) ตามลำดับ [19, 36]

$$o_t = \sigma W_{xo} x_t + W_{ho} h_{t-1} + W_{co} c_{t-1} + b_o \quad (13)$$

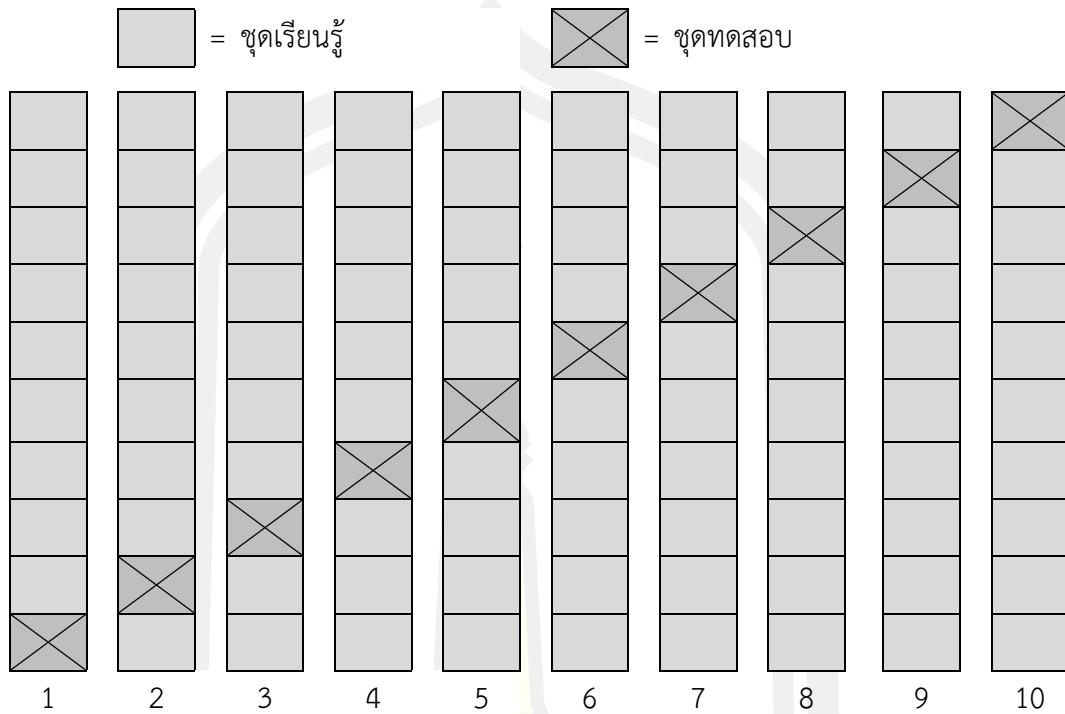
$$h_t = o_t \cdot \tanh c_t \quad (14)$$

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

2.5 การวัดประสิทธิภาพการจำแนก

ในการวัดประสิทธิภาพการจำแนกนั้นโดยทั่วไปจะใช้วิธีการวัดประสิทธิภาพ ได้แก่ [7, 17] การวัดค่าความแม่นยำ (Precision) ค่าความระลึก (Recall) ค่าเฉลี่ยประสิทธิภาพโดยรวม (F-Measure) และค่าความถูกต้อง (Accuracy) ของผลลัพธ์ที่ได้จากแต่ละอัลกอริทึม ใช้วิธีการ k-fold cross validation ในการแบ่งชุดข้อมูลเรียนรู้ (training set) และชุดข้อมูลทดสอบ (testing set) โดยแบ่งข้อมูลออกเป็น 10 ชุดข้อมูลเท่า ๆ กัน ($k = 10$) และทำการประเมินประสิทธิภาพของตัวจำแนกในแต่ละรอบ โดยรอบแรกชุดข้อมูลที่ 2 ถึง 10 ถูกนำไปเป็นชุดข้อมูลเรียนรู้เพื่อสร้างตัวจำแนก ชุดข้อมูลที่ 1 เป็นชุดข้อมูลทดสอบเพื่อวัดประสิทธิภาพของตัวจำแนก รอบที่สองชุดข้อมูลที่ 2 เป็นชุดข้อมูลทดสอบ การแบ่งข้อมูลด้วยวิธีการ Cross-validation Test ดังแสดงในรูปที่ 7 และชุดข้อมูลที่เหลือเป็นชุดข้อมูลเรียนรู้ ในแต่ละรอบจะทำการวัดประสิทธิภาพด้านต่าง ๆ ซึ่งสามารถอธิบายได้โดยใช้ตาราง Confusion Matrix ซึ่งเป็นตารางในรูปแบบจัตุรัส ที่มีจำนวนคอลัมน์เท่ากับจำนวนแคลสและเท่ากับจำนวนคลาส เช่น มีคลาสของชุดสอน 2 คลาส คือ C1 และ C2 โดยคลาสที่

เป็นการทำนาย (Predicted) อยู่ด้านคอลัมน์ และคลาสที่เป็นชุดสอน (Actual) อยู่ด้านแถวตั้งตารางที่ 4



รูปที่ 7 ตัวอย่างขั้นตอนการทำงานของ 10-Fold Cross Validation

ตารางที่ 4 ตารางแสดง Confusion Matrix

		Predicted	
		C1	C2
Actual	C1	a	b
	C2	c	d

เมื่อ a คือ จำนวนข้อมูลที่ทำนายถูกว่าเป็นคลาส C1

b คือ จำนวนข้อมูลที่ทำนายว่าเป็นคลาส C2 แต่คำตอบคือ C1

c คือ จำนวนข้อมูลที่ทำนายว่าเป็นคลาส C1 แต่คำตอบคือ C2

d คือ จำนวนข้อมูลที่ทำนายถูกว่าเป็นคลาส C2

1) การวัดค่าความถูกต้อง (Accuracy)

การวัดค่าความถูกต้องในการจำแนกโดยรวมเป็นการคำนวณจากผลรวมของค่าที่ทำนายถูกต้องว่าเป็นคลาสที่ต้องการพิจารณา หารด้วยผลรวมของจำนวนทั้งหมด ซึ่งสามารถคำนวณได้ดังสมการที่ (15)

$$Accuracy = \frac{(a + d)}{(a + b + c + d)} \quad (15)$$

2) การวัดค่าความแม่นยำ (Precision)

ในการวัดค่าความแม่นยำเป็นการคำนวณจากค่าที่ทำนายถูกต้องว่าเป็นคลาสที่ต้องการพิจารณา หารด้วยผลรวมของค่าที่ทำนายถูกต้องว่าเป็นคลาสที่กำลังพิจารณาและค่าที่ทำนายว่าเป็นคลาสอื่นแต่ความจริงแล้วเป็นคลาสที่กำลังพิจารณา ดังแสดงในสมการที่ (16) (17)

$$\text{Precision}_{c1} = \frac{a}{a + c} \quad (16)$$

$$\text{Precision}_{c2} = \frac{d}{b + d} \quad (17)$$

3) การวัดค่าความระลึก (Recall)

เป็นการวัดค่าความระลึก โดยจะคำนวณจากค่าที่สามารถทำนายถูกต้องว่าเป็นคลาสที่กำลังพิจารณา หารด้วยผลรวมของค่าที่ทำนายถูกต้องว่าเป็นคลาสที่กำลังพิจารณาและค่าที่ทำนายว่าเป็นคลาสที่กำลังพิจารณาแต่คำตอบเป็นคลาสอื่น ดังแสดงในสมการที่ (18) และ (19)

$$\text{Recall}_{c1} = \frac{a}{a + b} \quad (18)$$

$$\text{Recall}_{c2} = \frac{d}{c + d} \quad (19)$$

4) การวัดค่าเฉลี่ยประสิทธิภาพโดยรวม (F-measure)

เป็นการพิจารณานำเอาค่าความระลึกและค่าความแม่นยำมาพิจารณาร่วมกัน ระบบที่มีประสิทธิภาพจะต้องมีค่าความแม่นยำและค่าความระลึกสูงใกล้เคียงกัน ดังสมการที่ (20) (21)

$$F - \text{measure}_{c1} = 2 \times \frac{\text{Precision}_{c1} \times \text{Recall}_{c1}}{\text{Precision}_{c1} + \text{Recall}_{c1}} \quad (20)$$

$$F - \text{measure}_{c2} = 2 \times \frac{\text{Precision}_{c2} \times \text{Recall}_{c2}}{\text{Precision}_{c2} + \text{Recall}_{c2}} \quad (21)$$

2.6 งานวิจัยที่เกี่ยวข้อง

Razali และคณะ [6] นำเสนอวิธีการตรวจจับข้อความประชดประชันข้อความจากทวิตเตอร์ โดยใช้คุณลักษณะที่ได้จากเทคนิคการเรียนรู้เชิงลึกรวมกับคุณลักษณะจากบริบทข้อความ โดยใช้ขั้นตอนวิธีจากสถาปัตยกรรม Neural Network Convolutional (CNN) ในการสกัดคุณลักษณะเพื่อค้นหาคุณลักษณะที่ดีที่สุด และการรวมกันของคุณลักษณะที่รวมรวมจากเนื้อหาในข้อความ ผลการทดลองพิจารณาจากการวัดค่าประสิทธิภาพโดยรวมเท่ากับ 0.94 ซึ่งได้ผลดีกว่าผลการทดลองที่นำมาเปรียบเทียบคือเทคนิคการเรียนรู้ของเครื่องด้วยขั้นตอนวิธี Logistic regression

Pasupa และ Seneewong [30] นำเสนอโมเดลสำหรับการวิเคราะห์อารมณ์ความรู้สึกบนภาษาไทยด้วยวิธีการเรียนรู้เชิงลึกแบบไฮบริด โดยใช้คลังข้อมูล Thai-SenticNet5 โดยการใช้คุณลักษณะการฝังคำ การใช้บางส่วนของคำพูด คุณลักษณะที่ลงทะเบียนอ่อน และการผสมผสานคุณลักษณะเหล่านี้เข้าด้วยกัน อีกทั้งยังใช้เทคนิคอัลกอริทึมการเรียนรู้เชิงลึก (Convolutional neural Network) และอัลกอริทึมหน่วยความจำสั้นระยะยาวแบบสองทิศทาง (Bidirectional long short term memory) และเปรียบเทียบกับชุดข้อมูลภาษาไทย 3 ชุด ได้แก่ ThaiTales, ThaiEconTwitter และ Wisesight ผลการทดลองด้วยเทคนิคการเรียนรู้เชิงแบบไฮบริดที่มีประสิทธิภาพดีที่สุดคือ BLSTM-CNN ได้ค่าคะแนนประสิทธิภาพโดยรวม (F-measure) เท่ากับ 0.7436, 0.7707 และ 0.5521 บนชุดข้อมูล ThaiTales, ThaiEconTwitter และ Wisesight ตามลำดับ จากผลการทดลองสรุปได้ว่าการผสมผสานคุณลักษณะและอัลกอริทึมการเรียนรู้เชิงลึกแบบไฮบริดสามารถปรับปรุงประสิทธิภาพโดยรวมได้

A. Onan และ M. A. Tocoglu [33] นำเสนอการวิจัยโดยมีวัตถุประสงค์เพื่อการนำเสนอกรอบการประชดประชันที่มีประสิทธิภาพบนข้อมูลโซเชียลมีเดียโดยดำเนินตามกระบวนการทัศน์ของแบบจำลองภาษาธรรมชาติและโครงข่ายประสาทเทียมเชิงลึก พิจารณาคุณลักษณะตัวแทนของข้อความด้วยการฝังคำแบบถ่วงน้ำหนัก และนำเสนอการใช้เทคนิคน่วยความจำระยะสั้นระยะยาว 3 ชั้นเลเยอร์ โมเดลที่นำเสนอให้ผลลัพธ์ด้วยความแม่นยำในการจำแนกประเภทที่ 95.30%

C. I. Eke และคณะ [37] นำเสนอเทคนิคคุณลักษณะตามบริบทสำหรับการระบุการประชดประชันโดยใช้เทคนิคการเรียนรู้เชิงลึกด้วยโมเดล BERT โดยใช้ชุดข้อมูล Twitter และ Internet Argument Corpus เวอร์ชันที่สอง (IAC-v2) ส่องชุด ใช้สำหรับการจัดประเภทโดยใช้โมเดลการเรียนรู้สามรูปแบบ โมเดลแรกใช้การแทนแบบฝังผ่านโมเดลการเรียนรู้เชิงลึกที่มีหน่วยความจำระยะสั้นแบบสองทิศทาง (Bi-LSTM) ซึ่งเป็นตัวแปรของ Recurrent Neural Network (RNN) โดยใช้การแสดงเวกเตอร์ GloVe เพื่อสร้างการฝังคำ (word embedding) และบริบทการเรียนรู้ โมเดลที่สองใช้การแสดงข้อมูล Encoder แบบสองทิศทางล่วงหน้าและ Transformer (BERT) ในทางตรงกันข้าม โมเดลที่สามอิงจากการผสมผสานคุณลักษณะที่ประกอบด้วยคุณลักษณะ BERT ที่เกี่ยวข้องกับความรู้สึก เกี่ยวกับการสร้างประโยค และคุณลักษณะการฝัง GloVe ด้วยการเรียนรู้ของเครื่องแบบเดิม ประสิทธิภาพของเทคนิคนี้ได้รับการทดสอบด้วยการทดลองประเมินผลต่างๆ อย่างไรก็ตาม การประเมินเทคนิคบนชุดข้อมูลเปรียบเทียบ Twitter ส่องชุดมีความแม่นยำสูงสุด 98.5% และ 98.0% ตามลำดับ ในทางกลับกัน ชุดข้อมูล IAC-v2 มีความแม่นยำสูงสุด 81.2% ซึ่งแสดงให้เห็นถึงความสำคัญของเทคนิคที่เสนอเนื้อแนวทางพื้นฐานสำหรับการวิเคราะห์การประชดประชัน

Thititorn Seneewong และคณะ [34] ศึกษาเกี่ยวกับการวิเคราะห์อารมณ์ความรู้สึกภาษาไทยด้วยเทคนิค LSTM-CNN แบบสองทิศทางด้วยเวกเตอร์แบบฝังตัวและใช้คุณลักษณะด้วย

Sentic ซึ่งพยายามรวมคุณลักษณะเพิ่มเติมอีก 2 อย่าง ได้แก่ ส่วนหนึ่งของคำพูดและคุณลักษณะที่ละเอียดอ่อน เพื่อให้การวิเคราะห์มีความแม่นยำมากขึ้น คุณลักษณะส่วนหนึ่งของคำพูดจะระบุประเภทของคำที่สื่อถึงความรู้สึกต่างๆ ได้ดีกว่า ในขณะที่คุณลักษณะเกี่ยวกับความรู้สึกจะระบุอารมณ์ที่อยู่ภายใต้คำบางคำ การสมมตานหน่วยความจำรายสั้นแบบสองทิศทางและโมเดล Convolutional Neural Networks เข้ากับคุณลักษณะต่างๆ ที่กล่าวถึง เราทำการวิเคราะห์ความคิดเห็นเกี่ยวกับเรื่องราวของเด็กไทย และพบว่าการรวมกันของคุณลักษณะทั้งสามให้ผลลัพธ์ที่ดีที่สุดที่ค่า F1-score 78.89%

Rajadesingan และคณะ [38] นำเสนอวิธีการรูปแบบของพฤษติกรรมที่มีผลกระทบต่อการตรวจจับข้อความประชดประชันบนทวิตเตอร์ การเก็บรวบรวมข้อมูลจากเว็บไซต์ทวิตเตอร์โดยใช้แฮชแท็ก (#sarcasm, #not) ในการรวมรวมข้อมูล ข้อมูลที่ได้ผ่านกระบวนการในการเตรียมข้อมูล โดยฟิลเตอร์ข้อมูลที่ไม่สนใจ เช่น กำจัดข้อมูลที่ไม่ใช่ภาษาอังกฤษ ไม่สนใจข้อความที่เป็นรีทวิตต์ ไม่สนใจข้อมูลที่อยู่ในเว็บไซต์ รูปภาพหรือวิดีโอ และไม่สนใจข้อความที่มีจำนวนคำน้อยกว่า 3 คำ การเลือกคุณลักษณะที่สำคัญในการวิเคราะห์ ได้เลือกใช้ จำนวน 10 คุณลักษณะ ดังนี้ 1) เปอร์เซ็นต์ของไอลคอนแสดงอารมณ์ในข้อความทวิต 2) เปอร์เซ็นต์ของคำคุณศัพท์ในทวิต 3) เปอร์เซ็นต์ของคำที่เป็นอดีตกับคะแนนด้านอารมณ์ความรู้สึกเท่ากับ 3 4) จำนวนของคำหล้ายพยางค์ในทวิต 5) ความหนาแน่นของข้อความทวิต 6) เปอร์เซ็นต์ของคำที่เป็นอดีตกับคะแนนด้านอารมณ์ความรู้สึกเท่ากับ 2 7) เปอร์เซ็นต์ของคำที่เป็นอดีตกับคะแนนด้านอารมณ์ความรู้สึกเท่ากับ -3 8) จำนวนโพสของคำประชดประชันที่ผ่านมา 9) เปอร์เซ็นต์ของการเปลี่ยนแปลงอารมณ์ความรู้สึกจากบวกไปลบที่สร้างโดยผู้ใช้งาน 10) เปอร์เซ็นต์ของแฮชแท็กที่ใช้ตัวอักษรตัวพิมพ์ใหญ่ในทวิต โดยจากคุณลักษณะข้างต้นได้นำมากำหนดกลุ่มของคุณลักษณะได้ดังนี้ 1) กลุ่มของคุณลักษณะด้านการแสดงออก ได้แก่ คุณลักษณะข้อ 1,2,5,10 2) กลุ่มของคุณลักษณะด้านอารมณ์ ได้แก่ คุณลักษณะข้อ 3,6,7 3) กลุ่มของคุณลักษณะด้านความคุ้นเคยหรือมีความใกล้เคียง ได้แก่ คุณลักษณะข้อ 8 4) กลุ่มของคุณลักษณะด้านความแตกต่างหรือความตรงกันข้าม ได้แก่ คุณลักษณะข้อ 9 และ 5) กลุ่มของคุณลักษณะด้านความยุ่งยากซับซ้อน ได้แก่ คุณลักษณะข้อ 4 ในส่วนของวิธีการที่ใช้ในวัดประสิทธิภาพโดยใช้เทคนิค 10-fold cross-validation ผลของการทดลองจากการวิเคราะห์กลุ่มของคุณลักษณะได้ค่าความถูกต้องโดยรวมที่ 83.46% โดยกลุ่มของคุณลักษณะที่ให้ประสิทธิภาพดีที่สุดคือ กลุ่มที่ 1 กลุ่มของคุณลักษณะด้านการแสดงออกให้ค่าความถูกต้องเท่ากับ 76.72%

Bouazizi M และ Otsuki [5] นำเสนอวิธีการแนวทางตามรูปแบบในการจำแนกคำประชดประชันบนเครือข่ายสังคมออนไลน์ทวิตเตอร์ ใช้ข้อมูลจากทวิตเตอร์จากเดือนธันวาคม 2014 ถึงมีนาคม 2015 วิธีการเก็บข้อมูลโดยดึงข้อมูลโดยใช้อินเทอร์เฟซ API ของทวิตเตอร์ที่เป็นคำประชดประชันที่มีเครื่องหมายแฮชแท็ก #sarcasm โดยเก็บข้อมูลจำนวน 58,609 รายการ โดยหลังจากทำความ

สามารถข้อมูลแล้วได้แบ่งข้อมูลเป็น 3 ส่วน 1) ข้อมูล 6,000 ทวิต ใช้คนสองคนที่ไม่มีประสบการณ์ด้านการทวิตในการตรวจสอบและจำแนกระดับของคำประชดประชันโดยแบ่งเป็น 6 คลาส จากระดับ 1 มีความประชดประชันน้อย ถึง ระดับ 6 มีระดับความประชดประชันมากในการให้คลาสขึ้นอยู่กับทัศนคติของผู้ที่ติดคลาส เมื่อติดคลาสแล้วจะได้ข้อความที่ประชดประชัน และไม่ประชดประชันเท่ากับ 50/50 ซึ่งใช้ข้อมูลชุดนี้เป็นชุดสอน (Training set) 2) ข้อมูลชุดนี้ประกอบด้วยข้อความประชดประชัน 1,128 ข้อความ และไม่ประชดประชัน 1,128 ข้อความ ซึ่งนำมาใช้เป็นข้อมูลชุดเพิ่มประสิทธิภาพ (Optimization set) 3) ประกอบด้วยข้อความประชดประชัน 500 ข้อความ และไม่ประชดประชัน 500 ข้อความ นำมาใช้เป็นข้อมูลชุดทดสอบ (Test set) และใช้นำมาใช้ในการประเมินผลการทดลอง การสกัดคุณลักษณะใช้วิธีดังนี้ 1) คุณลักษณะที่เกี่ยวข้องกับอารมณ์ (Sentiment-related features) เป็นวิธีการโดยใช้ฐานข้อมูล SentiStrength ในการตรวจสอบความคิดเห็นที่เป็นบวก และลบ โดยกำหนดเป็น 2 คุณลักษณะ คือ pw, nw การใช้หน้าที่ของคำในการวิเคราะห์ค่าความเป็นบวกหรือลบ โดย คำคุณศัพท์ คำริยา และคำวิเศษณ์ มีค่านำหนักในด้านอารมณ์มากกว่าคำนาม และใช้สัญลักษณะแสดงอารมณ์ร่วมด้วย เช่น “ :P ” 2) คุณลักษณะที่เกี่ยวข้องกับเครื่องหมายวรรคตอน (Punctuation-related features) โดยพิจารณาจากการจำนวนเครื่องหมาย เช่น จำนวนของเครื่องหมายตกใจ (Exclamation marks) เครื่องหมายคำถาม (Question marks) เครื่องหมายจุด (Dots) การพิมพ์เป็นตัวอักษรพิมพ์ใหญ่ทั้งหมด (All-capital words) เครื่องหมายคำพูด (Quotes) และจำนวนของสรระ 3) คุณลักษณะประโยชน์และความหมาย (Syntactic and Semantic features) พิจารณาจากคำที่ไม่ปกติ (Uncommon words) จำนวนของคำที่ไม่ปกติ (Number of uncommon words) การมีคำประชดประชันในประโยชน์ (Existence of common sarcastic expressions) จำนวนของคำหยาบคาย (rude) การแสดงอารมณ์ขัน (Laughing expressions) 4) คุณลักษณะที่เกี่ยวข้องกับรูปแบบ (Pattern-related features) เป็นการพัฒนารูปแบบที่ใช้หน้าที่ของคำในการกำหนดรูปแบบ ผลการทดลอง ทดสอบโดยใช้ K-fold cross validation ใช้การจำแนกด้วยอัลกอริทึม Random Forest, Support Vector Machine, K-NN และ Maximum Entropy การประเมินประสิทธิภาพของการทดลองในระหว่างการทดสอบให้ค่าความแม่นยำที่ 91.1% ค่าความถูกต้องที่ 83.1% และค่าความระลึกที่ 73.4%

Mukherjee และ Pradip [39] นำเสนอวิธีการจำแนกข้อความประชดประชันบนทวิตเตอร์ มีจุดประสงค์ในการเพิ่มประสิทธิภาพการจำแนก ด้วยวิธีการเรียนรู้แบบมีผู้สอน สกัดคุณลักษณะโดยวิธี Content words, Function Words, Part of Speech tags, Part of speech n-grams, Content Words+Function Words, Function Words+Part of speech n-grams และ Content Words+Function Words+Part of speech n-grams และใช้วิธีการจำแนกด้วย Naïve Bayesian classifier และใช้วิธีการจัดกลุ่มด้วยวิธีการเรียนรู้แบบไม่มีผู้สอน (Unsupervised

learning) ด้วย Fuzzy C-mean (FCM) algorithm ผลการทดลองเปรียบเทียบทั้งสองอัลกอริทึมพบว่า วิธีการจัดกลุ่มด้วย Fuzzy ให้ประสิทธิภาพน้อยกว่า Naïve Bayes สำหรับการจำแนกข้อความประชดประชัน ค่าความถูกต้องที่ 65%

Dave และ Desai [25] นำเสนอวิธีโดยการศึกษาความเข้าใจเทคนิคในการจำแนกสำหรับการตรวจจับคำพูดส่อเสียด ประชดประชัน บนข้อความ โดยมีวัตถุประสงค์โดยศึกษาเทคนิคที่แตกต่างที่เป็นไปได้สำหรับการจำแนกคำประชดประชันและเปรียบเทียบประสิทธิภาพแต่ละวิธีการทดลองกับประโยชน์ในภาษาอินดู การสกัดคุณลักษณะโดยใช้ TF-IDF หน้าที่ของคำ (Part of Speech) ประโยชน์และคำแสดงความคิดเห็น (Opinion word and Phrase) และการปฏิเสธ (Negation) เช่น not happy มีความหมายเดียวกับ sad การเลือกคุณลักษณะด้วยวิธี ค่าสารสนเทศร่วม (Point wise Mutual Information) และ สติติไคสแควร์ (Chi-square) การจำแนกด้วยวิธีเรียนรู้ด้วยเครื่องใช้อัลกอริทึมที่ใช้ในการจำแนก Naïve Bayes, Maximum Entropy, Support Vector Machine และ Conditional Random Field การทดลองด้วยข้อมูลที่เป็นบวก 150 ข้อความ และข้อมูลที่เป็นลบ 150 ข้อความ เพื่อใช้เป็นชุดสอน โดยใช้ Support Vector Machine ด้วยใช้การตรวจสอบด้วย 10X Validation ด้วยคุณลักษณะถุกคำ (Bag of words) และวัดคุณลักษณะด้วย TF-IDF ใช้ข้อมูลสำหรับเป็นชุดทดสอบจำนวน 25 ข้อความ เพื่อใช้ทดสอบโมเดล ผลการทดลองได้ค่าความถูกต้องเท่ากับ 50%

Santosh และคณะ [7] นำเสนอวิธีการแยกการรับรู้ความรู้สึกประชดประชันบนทวิตเตอร์ วิธีการที่นำเสนอ มีสองวิธีคือ 1) อัลกอริทึมการวิเคราะห์ตามพจนานุกรม (Parsing-Based lexicon generation algorithm: PBLGA) 2) การจำแนกตามการปรากฏขึ้นของคำอุทาน (Occurrence of the interjection word) การรวมกันของทั้งสองวิธีเมื่อเปรียบเทียบกับศาสตร์ของการจำแนกคำประชดประชัน แสดงให้เห็นว่า วิธีแรกให้ค่าความแม่นยำที่ 89% ค่าระลึกที่ 96% และค่าเฉลี่ยประสิทธิภาพโดยรวมที่ 84% วิธีที่สอง ให้ค่าความแม่นยำที่ 85% ค่าระลึกที่ 96% และค่าเฉลี่ยประสิทธิภาพโดยรวมที่ 90% ในข้อความทวิตที่ใช้แฮชแท็ก (#sarcasm)

Archana และ Chitrakala [40] ได้นำเสนอวิธีการในการจัดการข้อความประชดประชันใน การคำนวนระดับ ความรู้สึกบนทวิตเตอร์โดยใช้วิธีบิ๊กเดต้า โดยข้อมูลที่นำมาใช้ในการทดลองมาจากการรับรู้ความรู้สึกบนทวิตเตอร์โดยใช้ TwitterR API จำนวน 1,150,000 ทวิต และใช้ Hadoop Map-reduce ช่วยในการจัดการข้อมูลขนาดใหญ่ ซึ่งผลการทดลองในการวัดประสิทธิภาพของการใช้ Map-reduce ให้ความเร็วในการประมวลผลที่เร็วว่าการไม่ใช้ โดยวัดจากค่า ความแม่นยำ, ค่าระลึก และการวัด

ประสิทธิภาพโดยรวมจากการใช้ Map-reduce มีค่าเท่ากับ 0.714, 0.51 และ 0.586 ตามลำดับ การใช้วิธีพื้นฐานมีค่าเท่ากับ 0.318, 0.296 และ 0.306 ตามลำดับ

Satoshi และ Kazutaka [41] นำเสนอวิธีการในการสกัดรูปแบบของคำประชันเพื่อประเมินผลการแสดงอารมณ์ ข้อมูลที่นำมาใช้ในการทดลองเป็นข้อมูลเกี่ยวกับการรีวิวสินค้าจาก Rakuten Ichiba ประเทศไทยจำนวน 10,000 รีวิว ซึ่งมีจำนวนประโยคทั้งหมด 34,917 ประโยค วิธีการที่นำเสนอ คือการจำแนกข้อความประชันประชันออกเป็น 8 คลาส และทำการตรวจสอบประสิทธิภาพในการจำแนกตามกฎของ 8 คลาส ผลการทดลองวิธีที่นำเสนอให้ประสิทธิภาพดีกว่าวิธีพื้นฐานโดยว่าจากค่าความแม่นยำ, ค่าระลึก และค่าประสิทธิภาพโดยรวม ดังนี้ วิธีพื้นฐานเท่ากับ 0.006, 0.414 และ 0.012 วิธีที่นำเสนอ 0.028, 0.543 และ 0.053 ตามลำดับ และผลการประเมินประสิทธิภาพจากค่าความแม่นยำของการทดลองจากข้อมูลชุดทดสอบ วิธีที่นำเสนอให้ประสิทธิภาพดีกว่าวิธีพื้นฐาน เท่ากับ 0.036 และ 0.009

Salas และคณะ [42] นำเสนอวิธีการตรวจจับข้อความประชันอัตโนมัตินวิศวกรรม ด้วยวิธีการทางจิตวิทยา การรวบรวมข้อมูลจากทวิตเตอร์โดยใช้ Twitter4J โดยรวมรวมสองส่วนคือ จากรสเปนและแม็กซิโก แยกเป็นข้อความประชันประชันอย่างละ 5,000 ทวิต และ ข้อความทั่วไปที่ไม่ใช่ข้อความประชันประชันอย่างละ 5,000 ข้อความ เมื่อนำมาผ่านกระบวนการในการเตรียมข้อมูล แล้วจะได้ข้อมูล ที่เป็นคำประชันประชันจำนวน 5,000 ข้อความ (สเปน 2,500, แม็กซิโก 2,500) และไม่ประชันประชัน 5,000 ข้อความ (สเปน 2,500, แม็กซิโก 2,500) อัลกอริทึมที่ใช้คือ Sequential Minimal Optimization (SMO), J48 Decision tree และ Bayes Net ผลการการทดลองโดยการวัดค่าความถูกต้อง ความความแม่นยำ ค่าความระลึก ค่าความถูกต้องโดยรวม เท่ากับ SMO คือ 85.50%, J48 คือ 75.20% และ BayesNet คือ 75.60%, 75.70%, 75.60%, 75.60% ตามลำดับ

Bouazizi และ Ohtsuki [43] นำเสนอการทำเหมืองความคิดเห็นบนทวิตเตอร์เพื่อการเพิ่มประสิทธิภาพการวิเคราะห์อารมณ์ความรู้สึกในข้อความประชัน หัวข้อที่เก็บข้อมูล คือ การเมือง รีวิวโทรศัพท์ กีฬา รีวิวหนัง และ สินค้าอิเล็กทรอนิก โดยข้อมูลที่ใช้เป็นชุดтренจำนวน 20,000 ทวิตและ 1,000 ทวิตใช้เป็นชุดทดสอบ อัลกอริทึมที่ใช้ คือ Support Vector Machine Maximum Entropy และ Naïve Bayes ผลการทดลองสรุปได้ว่า Support Vector Machine ให้ประสิทธิภาพดีกว่า Maximum Entropy และ Naïve Bayes ผลจากการทดลองโดยการวัดค่า Recall ของการจำแนกซึ่งเปรียบเทียบกับวิธีการพื้นฐาน ได้ดังนี้ ผลของค่า Recall วิธีพื้นฐาน Naïve Bayes 83.9%, SVM 85.7% และ Maximum Entropy 82.3% ผลของวิธีการที่นำเสนอ Naïve Bayes 85.9%, SVM 92.0% และ Maximum Entropy 83.8% ซึ่งให้ผลดีกว่าวิธีแบบพื้นฐาน

Miljana และคณะ [44] นำเสนอวิธีการในการใช้คลังคำในการจำแนกข้อความเสียดสีและประชัน ข้อมูลที่ใช้เป็นภาษาเซอเปียร์ จากทวิตเตอร์ โดยรวมรวมข้อมูลจากคำนับโดยใช้แซช

แท็ก #irony, #sarcasm, #not, #yeahright ในกระบวนการนำข้อมูลมาวิเคราะห์โดยการนำแซชแท็กออก คลังคำที่นำมาใช้ในการจำแนกจาก Serbian WordNet ซึ่งเป็นพจนานุกรมที่บรรจุคำจำนวน 4,593 ข้อความ ซึ่งเป็นข้อความที่มีข้าความรู้สึก และ 62 วลี ข้อมูลที่ใช้ในการทำมาทดลองจำนวน 2,127 รายการ ประสิทธิภาพได้ค่าความแม่นยำเท่ากับ 68.6% และค่าความถูกต้องเท่ากับ 86.1%

Thu และ New [45] นำเสนอวิธีการใช้คุณลักษณะทางอารมณ์ในการตรวจจับข้อความเสียดสีประดิษฐ์ ประเภทของชุดข้อมูลที่ใช้มีสอบประเภทคือข้อความประดิษฐ์และไม่ประดิษฐ์ เกี่ยวกับบทความข่าวจำนวน 226 ข้อความ และ 674 ข้อความ, รีวิวสินค้าอเมซอน จำนวน 1,000 ข้อความ และข้อมูลจากทวิตเตอร์ จำนวน 22,126 ข้อความ และ 32,681 ข้อความ วิธีการที่ใช้ในการสะกดคุณลักษณะ 1) word-based ใช้โมเดล N-grams โดยเลือกคำที่พบบ่อยที่สุด 1,000 คำ 2) Emotion ใช้การแสดงอารมณ์ 8 ตัว คือ ความโกรธ ความคาดหมาย รังเกียจ ความกลัว ความสุข ความเศร้า แปลกใจ และความไว้วางใจ 3) Sentiment ใช้ข้อความแสดงอารมณ์ บวก ลบ เป็นกลาง และ ค่าคะแนนความเชื่อมั่น 4) Bag-of Sorted Emotion (BOSE) เป็นรวมระหว่างการแสดงอารมณ์ 8 ตัวและข้าความรู้สึก ในการเรียงลำดับ 5) BOSE-TFIDF การทำวิธีการที่ 4 มาให้ค่าน้ำหนักด้วย TFIDF 6) BOSE-TFRF เป็นการคำนวณแบบจำลองโดยใช้ความถี่และแล้วความเกี่ยวข้องกันของความถี่ 7) SenticNet คือฐานข้อมูล จำนวน 13,000 คำที่มี 4 มิติทางอารมณ์ คือ ความรู้สึกໄว, ไหวพริบ, ความสนใจ และ ความร่าเริง ในการทดสอบประสิทธิภาพของแบบจำลองด้วย 10-Fold cross-validation อัลกอริทึมที่ใช้ Support Vector Machine และ Ensemble โดยสรุปแล้วลักษณะอารมณ์ที่คลุมเคลือการจำแนกด้วย SVM ให้ประสิทธิภาพได้ไม่ได้ในวิธีการคุณลักษณะพื้นฐานอารมณ์ (Emotion-based features) ในขณะเดียวกันการจำแนกด้วยตัวจำแนก Ensemble Classifier ให้ประสิทธิภาพ ค่าความถูกต้องที่ดีขึ้นในข้อความสั้นและยาว

Reganti และคณะ [46] นำเสนอแบบจำลองเสียดสีในข้อความภาษาอังกฤษสำหรับการตรวจจับอัตโนมัติ ด้วยวิธีการคุณลักษณะคลังคำเพื่อเปรียบเทียบกับวิธีพื้นฐาน (n-grams) โดยวิธีที่ใช้ในการเลือกคุณลักษณะ คือ Lexical Feature ซึ่งเป็นคลังคำทางอารมณ์ที่บรรจุคำจำนวน 14,000 คำ ซึ่งแต่ละข้อความได้ระบุความรู้สึกที่เป็น Positive และ Negative และ 8 สัญลักษณ์ทางอารมณ์ คือ ความโกรธ ความคาดหมาย รังเกียจ ความกลัว ความสุข ความเศร้า แปลกใจ และความไว้วางใจ และใช้ SenticNet ซึ่งเป็นคลังคำความรู้สึกที่ใหญ่แต่ละแนวคิดของอารมณ์ถูกระบุขึ้นจำนวนของข้อบวก ลบ และเป็นกลาง โดยจะถูกนำมาใช้เป็นคุณลักษณะ ชุดข้อมูลที่ใช้คือ 1) รีวิวสินค้าอเมซอน จำนวน 1,254 ข้อความ แบ่งเป็นข้อมูลประชัดจำนวน 437 ข้อความ และไม่ประชัดจำนวน 817 ข้อความ 2) เอกสารข่าว จำนวน 4,000 ข้อความ และจำนวน 233 ข้อความ ที่เป็นบทความคิดประชัด 3) ทวิตเตอร์โพสต์ จำนวน 3,000 ข้อความประชัด จากการใช้คำค้น #satire, #irony และ

#sarcasm อัลกอริทึมที่ใช้ในการจำแนกคือ Logistic Regression(LR), Random Forest(RF), Support Vector Machine(SVM), Decision Tree(DT) และ Ensemble ผลการจำแนกประสิทธิภาพโดยรวมแต่ละชุดข้อมูลทุกคุณลักษณะ 1) รีวิวสินค้าเมื่อตอน 75.30%, 68.93%, 66.63%, 67.22% และ 77.96% 2) เอกสารข่าว 75.88%, 63.89%, 69.34%, 63.22% และ 79.02% 3) ทวิตเตอร์โพสต์ 76.89%, 71.06%, 74.03%, 68.11% และ 78.16% สรุปได้ว่า อัลกอริทึมที่ให้ประสิทธิภาพในการจำแนกดีที่สุดคือ Ensemble เท่ากับ 77.96%, 79.02% และ 78.16% จากชุดข้อมูลทั้งสามชุดตามลำดับ

Suhaimin และคณะ [47] นำเสนอวิธีการตรวจจับข้อความประชดประชันด้วยคุณลักษณะ การประมวลผลภาษาธรรมชาติในข้อความสองภาษาบนเครือข่ายสังคมออนไลน์ ชุดข้อมูลที่นำมาใช้ ในการวิจัยเป็นหัวข้อความคิดเห็นเกี่ยวกับข่าวด้านเศรษฐกิจจากเพสบุ๊คแฟนเพจสาธารณะ จำนวน 3,000 รายการ แยกเป็นข้อความประชด 969 ความคิดเห็น และ 1,001 ข้อความคิดเห็นที่ไม่ใช่ ความคิดเห็นประชดประชัน วิธีการที่ใช้ในการสกัดคุณลักษณะในรูปแบบการแปลสองภาษาตาม 5 กลุ่มของการประมวลผลภาษาธรรมชาติ คือ Lexical, Pragmatic, Prosodic, Syntactic และ Idiosyncratic จำแนกโดยใช้อัลกอริทึม Non-linear Support Vector Machine จากการทดลองให้ ประสิทธิภาพโดยรวมที่ดีกว่าวิธีพื้นฐานโดยคำคำนึงค่าประสิทธิภาพโดยรวมที่ 85.2%

Jasso และ Meza [4] นำเสนอวิธีการตรวจจับคำเสียดสีรูปแบบข้อความสั้นในภาษาสเปน ด้วยวิธี 1) รูปแบบคำ (Word Based) ใช้วิธี word N-grams และ Word2Vec 2) รูปแบบตัวอักษร (Character Based) ใช้วิธี Character N-grams โดยพิจารณาลักษณะเครื่องหมายวรรคตอน และ ไอคอนแสดงอารมณ์ร่วมด้วย ชุดข้อมูลที่ใช้เป็นคำเสียดสีและไม่ใช่คำเสียดสี แบ่งเป็น 3 กลุ่ม 1) รายการชุดเรียนรู้ที่มีความสมดุล (14,511, 14,511) ชุดทดสอบ (1,483, 1,483) 2) รายการชุดเรียนรู้ ที่ไม่มีความสมดุล (14,511, 33,859) ชุดทดสอบ (1,483, 3,458) และ 3) รายการชุดเรียนรู้ที่นำเสนอ (14,511, 130,599) ชุดทดสอบ (1,483, 13,347) ผลการจำแนกด้วยอัลกอริทึม Support vector machine (SVM) และ Random Forest (RF) โดยการวัดประสิทธิภาพโดยรวม (F-score) ของทั้งสอง วิธีกับข้อมูลทั้ง 3 ชุด ข้อมูลชุดที่ 1 ให้ผลดังนี้ 1) รูปแบบคำ word-gram ผลคือ (RF = 68%, SVM = 67%) word2vec ผลคือ (RF = 76%, SVM = 78%) 2) รูปแบบตัวอักษร char-gram ผลคือ (RF = 87%, SVM = 86%) ข้อมูลชุดที่ 2 ให้ผลดังนี้ 1) รูปแบบคำ word-gram ผลคือ (RF = 48%, SVM = 37%) word2vec ผลคือ (RF = 38%, SVM = 61%) 2) รูปแบบตัวอักษร char-gram ผลคือ (RF = 80%, SVM = 80%) ข้อมูลชุดที่ 3 ใช้วิธีรูปแบบตัวอักษร char-gram ผลคือ (RF = 87%, SVM = 86%)

Justo และคณะ [48] นำเสนอวิธีการในการสกัดความรู้ที่เกี่ยวข้องสำหรับการตรวจจับ ข้อความประชดประชันและข้อความหยาบคายบนเว็บเครือข่ายสังคมนำเสนอชุดของการเรียนรู้แบบมี

ผู้สอนในการทดลองตรวจจับข้อความประชดประชันและความหมายในกล่องโต้ตอบออนไลน์ (Onling Dialog) เพื่อเปรียบเทียบช่วงของชุดคุณลักษณะที่พัฒนาโดยใช้เกณฑ์ที่แตกต่างกัน โดยนำเสนอวิธีการดังนี้ วิธีการค้นหาการตั้งค่าที่เหมาะสมของคุณลักษณะสำหรับประเภทที่แตกต่างกัน ของภาษาในสังคม วิธีการจัดหมวดหมู่อย่างชัดเจนว่าพิจารณาความเป็นไปในรูปแบบที่แตกต่างกัน ของการเสียดสี เช่น พูดและประชด วิธีการใช้คุณลักษณะที่ชัดเจนในการพิจารณาความหมายและ ปัญหาที่เกิดจากความยาวของคำพูดที่รวมทั้งเป้าหมายประเกทของประโยชน์เช่น ประโยชน์ประชด ประชัน รวมทั้งไม่ได้อยู่ในหมวดหมู่ของเป้าหมาย เช่น ไม่ได้ประชด วิธีการเปรียบเทียบความสอดคล้อง การตรวจสอบข้อความทั้งสองประเภท ประชดและหมายเหตุ ในบริบทที่เหมือนกัน วิธีการที่เลือกใช้ในการสกัดคุณลักษณะ 1) Mechanical Turk Cues เป็นการพิจารณาคุณสมบัติที่ประกอบด้วยตัวชี้นำที่ระบุว่าเป็นการวัดการประชดประชันหรือข้อความหมาย 2) Statistical Cues เนื่องจากการระบุตัวชี้นำที่เกี่ยวข้องกับอารมณ์การใช้วิธีที่ 1 อาจไม่เพียงพอในการระบุอารมณ์ที่ต้องการได้อย่างถูกต้อง ดังนั้นชุดคุณลักษณะที่สองจึงถูกนำออกมากจากชุดเรียนรู้โดยอัตโนมัติ ซึ่งชุดนี้ประกอบด้วย unigrams, bigrams และ trigrams ที่สกัดจากคำพูดแต่ละคำในชุดทดสอบ จากนั้นจะมีการใช้ขั้นตอนการเลือกคุณลักษณะเพื่อลดจำนวนคุณลักษณะที่จะลบข้อมูลที่ไม่เกี่ยวข้องออกไป 3) Linguistic information ข้อมูลทางภาษาศาสตร์ เพื่อพิจารณาทางสถิติ จำเป็นต้องมีชุดเรียนรู้ขนาดใหญ่เพื่อตีดังชุดตัวชี้นำให้เพียงพอเพื่อใช้กับชุดทดสอบต่างๆ จึงได้นำคุณลักษณะทางด้านภาษา POS-tagging ที่เกี่ยวข้องกับแต่ละคำ ในชุดนี้เป็นการใช้งานชุด POS n-grams ซึ่ง $n = 1, 2, 3$ 4) Semantic information ข้อมูลเกี่ยวกับความหมาย: แม้ว่ารูปแบบบางอย่างอาจเป็นตัวชี้นำที่ดีต่ออารมณ์ที่แตกต่างกัน แต่ก็มีข้อมูลเพิ่มเติมในการสนทนากลุ่มที่มีความหมาย เช่น ความหมายของคำพูดและคำที่มีความหมาย เช่น คำว่า “ดี” หรือ “ไม่ดี” 5) Length information ข้อมูลความยาว เนื่องจากคลังข้อมูลที่เฉพาะเจาะจงที่กำลังรับมือซึ่งในโพสต์ความยาวแตกต่างกันมากจึงสังเกตเห็นว่าข้อมูลความยาวสามารถเป็นประโยชน์อย่างมากสำหรับการตีความคุณลักษณะชุดก่อนหน้านี้อย่างถูกต้อง ดังนั้นในงานนี้จะมีเวกเตอร์ที่มีข้อมูลต่อไปนี้สำหรับคำพูดแต่ละคำ เช่น จำนวนคำ จำนวนอักษร จำนวนประโยค จำนวนคำเดี่ยวนอกตัวอักษร 6) Concept and Polarity Information แนวคิดและข้อมูลเกี่ยวกับข้อความ เช่น ความหมายของคำพูดและคำที่มีความหมาย เช่น คำว่า “ดี” หรือ “ไม่ดี” 7) Rule-based classifier และ Naïve Bayes classifier ประเภทคือ rule-based classifier และ Naïve Bayes classifier

Kunneman และคณะ [49] ได้นำเสนอระบบการตรวจจับข้อความประชดประชันสำหรับทวิต ข้อความบนไมโครบล็อกจากเว็บไซต์ทวิตเตอร์ ในการเก็บรวบรวมข้อมูลสำหรับการทำวิจัยใช้ข้อมูลจากแพลตฟอร์มที่มีความสามารถในการเข้าใจภาษา เช่น SenticNet-3.0 ภูมิภาคเอเชียตะวันออกเฉียงใต้ จีน ญี่ปุ่น ไทย อินเดีย ปากีสถาน ฯลฯ ในการทำวิจัยนี้ ได้ใช้โมเดล Naïve Bayes และ Support Vector Machine (SVM) ในการฝึกอบรมและทดสอบ ผลลัพธ์แสดงว่า SVM ให้ประสิทธิภาพสูงกว่า Naïve Bayes ในการจัดจำแนกข้อความประชดประชัน

แยชแท็ก เช่น #sarcasm or #not โดยข้อมูลที่เก็บรวบรวมในภาษาตัวมานจำนวน 2.25 ล้านทวิต จำนวนชุดเรียนรู้ทั้งหมด 406000 ทวิตที่ไม่มีแท็กดังกล่าว อัลกอริทึมที่ใช้ในการจำแนกคือ Winnow classification การจำแนกด้วยค่าคุณภาพ AUC (Area Under the Curve) มีค่าเท่ากับ 0.84 และสามารถระบุจุดที่ต้องการได้อย่างถูกต้อง 309 จาก 353 ทวิตในจำนวน 2.25 ล้านทวิตที่ทำเครื่องหมายแยชแท็กที่อาเครื่องหมายแยชแท็กออก จากการทดสอบโดยตัวแบ่งประเภทใน 250 อันดับแรกของทวิตที่ได้รับการจัดอันดับมากที่สุดน่าจะเป็นข้อความประชดที่ไม่มีแยชแท็กประชด แต่ มีความแม่นยำเพียง 35%เท่านั้น

Schifanella และคณะ [50] นำเสนอการศึกษาความสัมพันธ์ระหว่างแง่มุมของข้อความและภาพในบทความแบบหลายรูปแบบจากแพลตฟอร์มสื่อสังคมออนไลน์ Instagram, Tumblr และ Twitter สิ่งที่ศึกษามีดังนี้ 1) การศึกษาการมีอิทธิพลซึ่งกันและกันระหว่างข้อความและรูปภาพในโพสของสื่อสังคมทั้งสาม 2) ศึกษาคุณภาพของการตรวจจับข้อความประชดด้วยภาพเปรียบเทียบกับการติดคลาสสุดท้ายมนุษย์ 3) แสดงให้เห็นถึงประสิทธิภาพที่ดีขึ้นเมื่อเทียบกับแพลตฟอร์มพื้นฐานและวิธีการต่างๆ ที่เป็นข้อความ ชุดของข้อมูลเก็บรวบรวมข้อมูลที่เป็นข้อความและมีรูปภาพประกอบในข้อความ จาก Instagram, Tumblr และ Twitter การใช้ตัวกรองข้อมูลโดยไม่สนใจโพสที่ไม่มีรูปภาพ , ตัดข้อความที่เป็น @username, URL, ไม่สนใจข้อความที่มีคำ sarcasm อยู่โดยไม่มีแยชแท็ก และข้อความที่มีจำนวนน้อยกว่า 4 คำ ในแต่ละแพลตฟอร์มได้จำนวนชุดข้อมูลที่ได้มาจากการสุ่มจำนวนแพลตฟอร์มละ 10000 โพส วิธีการที่นำมาใช้ในการจำแนก คือ 1) SVM Approach ในส่วนของ NLP Features (Lexical, Subjectivity and sentiment score, n-grams, word2vec และ combination) 2) Deep learning ในส่วนของ Visual features (Visual Semantics Features: VSF) โดยสรุปการใช้วิธีการรวมกันระหว่าง NLP Features และ VSF ให้ประสิทธิภาพที่สูง คือ Instagram เท่ากับ 82.3% Tumblr เท่ากับ 81.0% และ Twitter เท่ากับ 80.0%

Taslioglu และ Karagoz [51] นำเสนอเทคนิคในการตรวจจับข้อความประชดประชันบนไมโครบล็อกไซต์ทวิตเตอร์ในภาษาตุรกี ด้วยวิธีการเรียนรู้ด้วยเครื่อง ชุดข้อมูลที่ใช้ศึกษาถูกเก็บรวบรวมจากทวิตเตอร์ด้วยทวิตเตอร์โอเพ่นไอ (Twitter API) จำนวน 54362 ทวิต เป็นทวิตภาษาตุรกีในช่วงเวลาตุลาคม 2556 – กันยายน 2557 วิธีการที่เลือกใช้ในการสกัดคุณลักษณะ ซึ่งคุณลักษณะบางอย่างเหล่านี้มีเฉพาะสำหรับตุรกีเท่านั้น การใช้เครื่องหมายวรรคตอน “!”, “?”, “ ” ”, “.”, “:”, “,”, คำอุทาน, ตัวอักษรพิมพ์ใหญ่ และ ช่องว่างระหว่างค่าคุณภาพรู๊สิก ใช้วิธีการเรียนรู้ด้วยเครื่องแบบมีผู้สอนด้วยอัลกอริทึม Naïve Bayes, Support Vector Machine, K-Nearest Neighbors และ Random Forest ผลการเปรียบเทียบแต่ละอัลกอริทึม K-Nearest Neighbors ให้ประสิทธิภาพสูงที่สุด precision = 94.4% Recall = 93.8% และ F1 = 93.7%

Freitas และคณะ [45] ได้ศึกษาการตรวจสอบข้อความประชดบันทึก นำเสนอรูปแบบภาษาสำหรับการประชด โดยเก็บรวบรวมข้อมูลทวิตภายในตัวหัวข้อ “End of the world” ประกอบด้วย 2779 ทวีต (55663 คำ) การจำแนกประเภทที่ถูกนำมาใช้มีจำนวน 6 ประเภท ดังนี้ รายชื่อ (lists), การแสดงออกที่แน่นอน (exact expressions), หน้าที่ของคำ (Part of speech) + exact expressions, หน้าที่ของคำ (Part of speech) + lists, Part of speech + named entities และ สัญลักษณ์ (Symbols) สามารถอธิบายรูปแบบของคุณลักษณะได้ดังนี้คือ 1) รายการของการแสดงอาการหัวเราะ (List of Laughter Expression) 2) รายการของสัญลักษณ์แสดงอารมณ์ (List of Emoticons) 3) só que ในภาษาบราซิล เป็นวิธีที่มีอยู่แล้วในการแสดงให้เห็นว่า คำพูดไม่ได้หมายความว่าสิ่งที่เห็นได้ชัด 4) sim แสดงให้เห็นถึงความสำคัญของสิ่งที่จะกล่าวและทำให้อาจหมายถึงการประชด 5) na boa นิพจน์นี้มีมากกว่าหนึ่งความหมาย ใช้เมื่อพูดถึงหัวข้อที่อาจทำให้เกิดความเห็นแย้งและตกลง 6) การใช้ #ironia #sarcasmo #joking #kidding แท็กนี้เป็นที่ชัดเจนว่าผู้ใช้ต้องการเน้นความเห็นขั้น 7) tāo + Adjective หรือ tāo + Adverb ซึ่งเป็นคำวิเศษณ์ในภาษาโปรตุเกส อาจใช้เพื่อทำเครื่องหมายระดับความเท่าเทียมกันของคำวิเศษณ์อื่น ๆ ของคุณศัพท์ แต่อาจให้ความรุนแรงกับคำเหล่านี้ด้วย 8) Adjective + list of Emoticons ถ้าทวีตนำคุณศัพท์เชิงบวก แต่อารมณ์เป็นลบจะไปสำหรับรายการของผลงานจากนี้คุณศัพท์เชิงลบและอีโมติคอนในเชิงบวกแสดงให้เห็นถึงผลดี ถ้าคุณศัพท์และอีโมติคอนมีข้ามเดียวกันทวีตจะถูกปฏิเสธ 9) DET + ADJ + (PREP+DET) + NE รูปแบบนี้ต้องการการวิเคราะห์ Part of speech ในลำดับที่แน่นำ 10) Demonstrative Pronouns + NE การเกิดขึ้นของคำสรรพนามเช่น This, that ให้ประสิทธิผลดี 11) <EXPR>! การบรรยายข้อความประชดประชันผู้เขียนมักจะเขียนต้องการเพิ่มความคิดเห็นซึ่งเป็นการแสดงความคิดเห็นเกี่ยวกับสิ่งที่ได้กล่าวมาก่อนหน้า 12) !*|?*!-*?*|?*!* การใช้เครื่องหมายวรรคตอนส่งเนื้อหาเพิ่มเติมไปยังคำพูด โดยเฉพาะการใช้เครื่องหมายอัศจรรย์และเครื่องหมายคำตามทำให้อาจได้อารมณ์จากการสื่อสาร 13) Quotation Marks นอกเหนือจากการถ่ายทอดสิ่งที่คนพูดไว้ในข้อความสัญลักษณ์เหล่านี้ใช้เพื่อเน้นคำบางคำหรือสำนวนและให้ความสำคัญกับความหมายที่เป็นรูปเป็นร่าง เช่น เรื่องประชดประชัน

Dana และ คณะ [52] ได้นำเสนอการตรวจสอบข้อความประชดประชันในภาษาอาрабิกบนเครือข่ายสังคมออนไลน์ทวิตเตอร์ โดยใช้เทคนิคและอัลกอริทึมด้านดาต้าไม่นิ่ง โดยการเก็บรวบรวมข้อมูลภาษาอาрабิก จำนวน 350 ที่เป็นคำประชดและไม่ใช่คำประชดจาก 11 แซทแทกที่แตกต่างกันโดยไม่สนใจรูปภาพและวิดีโอ กระบวนการในการเตรียมข้อมูลโดยการนำแซทแทก ไอคอนแสดงอารมณ์ และ ที่อยู่เว็บไซต์ออกจากข้อความ จากนั้นจะได้ข้อมูลจำนวน 344 ทวีต แบ่งเป็น 238 เป็นข้อความประชดประชัน และ 106 ที่ไม่ใช่ข้อความประชดประชัน การเลือกคุณลักษณะโดยการใช้เครื่องหมาย เช่น !, ?, ..., (), “ ”, คำที่เป็น เชิงบวก และ เชิงลบ ซึ่งหากพบคำที่เป็นเชิงบวกและเชิง

ลับในข้อความเดียวกันจะระบุว่าข้อความนั้นเป็นข้อความประชดประชัน การทดลองใช้อัลกอริทึมนาอีฟเบย์ ในการจำแนก วัดประสิทธิภาพโดยใช้ค่า ความแม่นยำ ค่าความระลึก และค่าประสิทธิภาพ โดยรวม ผลการวัดประสิทธิภาพ ค่าความแม่นยำเท่ากับ 65.9% ค่าความระลึก 71% และค่าประสิทธิภาพโดยรวมเท่ากับ 67.6%

Hiai และ Shimada [41] นำเสนอบริการในการสกัดรูปแบบในการประเมินผลข้อความประชดประชัน ซึ่งได้ให้ข้อคิดเห็นว่าการแสดงด้วยข้อความประชดประชันนั้นเป็นการแสดงทางความหมายที่เป็นเชิงลบด้วยข้อความเชิงบวก ซึ่งงานทางด้านการตรวจสอบหรือตรวจหาข้อความประชดประชันจะช่วยเพิ่มประสิทธิภาพในงานทางด้านการวิเคราะห์อารมณ์ความรู้สึก ดังนั้นจึงได้เสนอวิธีการสกัดประโยชน์คุณภาพของข้อมูลจากข้อความรีวิวสินค้า โดยการจำแนกประโยชน์คุณภาพเป็น 8 คลาส ชุดข้อมูลที่ใช้เป็นชุดข้อมูลความคิดเห็นจากรีวิวสินค้าญี่ปุ่น จากบริษัท รากุเทน อิชิบะ (Rakuten Ichiba) โดยข้อมูลประกอบด้วยชื่อสินค้า การให้คะแนนสินค้า หัวข้อรีวิว และประโยชน์ที่รีวิว จำนวนทั้งหมด 10,000 รีวิว ที่มีจำนวนประโยชน์ทั้งหมด 34,917 ประโยชน์ ใน การวิเคราะห์ประโยชน์เพื่อจำแนกคลาส ทั้ง 8 คลาส ได้ดังนี้ 1) การแสดงข้อความที่เป็นเชิงบวก และ เชิงลบที่ให้คะแนนในระดับน้อยในประโยชน์เดียวกัน 2) การแสดงข้อความคิดเห็นในเชิงบวกในหัวข้อการรีวิวและแสดงความคิดเห็นเชิงลบในข้อความเนื้อหารีวิว ซึ่งให้ความสำคัญถึงความหมายเชิงลบ 3) การแสดงข้อความ “ii” ซึ่งหมายถึง “Good” ในภาษาอังกฤษ ซึ่งการรวมกันของข้อความที่มีความหมายซับซ้อน เช่น “ii (Good)” และ “nedan (price)” ทำให้เปลี่ยนความหมายเป็น เพียงมาก (too expensive) เป็นการแสดงออกเชิงบวกของคลาสนี้ 4) คลาสนี้แสดงเป้าหมายของการประเมินผลในด้านการส่งของ แต่ไม่ใช่ผลิตภัณฑ์ที่ต้องส่ง ดังนั้นจึงเป็นการให้ความหมายเชิงลบกับผลิตภัณฑ์ซึ่งแสดงออกผ่านข้อความเชิงบวก 5) การแสดงออกในเชิงบวกในสถานการณ์ที่ไม่ดี เช่น มีข้อความ “ii (better)” การสูญเสียเงินอีกครั้ง ซึ่งแสดงถึงความหมายเชิงลบ 6) การแสดงออกในเชิงบวกกับผลิตภัณฑ์อื่น ซึ่งเป็นการบงบอกว่าผลิตภัณฑ์นี้ไม่ดี 7) การแสดงออกเชิงบวกโดยใช้ข้อความที่ไม่ใช่ข้อความปกติ ซึ่งเป็นการบงบอกถึงความหมายเชิงลบกับผลิตภัณฑ์ ด้วยการแสดงข้อความเชิงบวก 8) เป็นการแสดงออกเชิงบวกแต่ไม่ได้แสดงถึงจุดบวกที่ชัดเจนเกี่ยวกับผลิตภัณฑ์ กล่าวอีกนัยหนึ่งผลิตภัณฑ์ไม่มีจุดเด่นชัดแม้ว่าประโยชน์นั้นจะมีนิพจน์เชิงบวก

Jain และคณะ [53] นำเสนอวิธีการในการตรวจจับข้อความประชดประชันบนทวิตเตอร์ โดยให้ความเห็นว่า การตรวจจับข้อความประชดประชันนี้ถือเป็นงานที่ท้าทายเนื่องจากข้อความประชดประชันที่ผู้คนสื่อสารออกแบบผ่านเครือข่ายสังคมออนไลน์นั้นมีลักษณะคลุมเคลือประกอบด้วยข้อความที่เป็นคำแสง การแสดงออกถึงประโยชน์ที่เป็นเชิงบวกหรือเชิงลบ แต่ใช้โคลอนแสดงอารมณ์ที่เป็นลักษณะตรงกันข้ามกับข้อความที่สื่อสารออกแบบ และการแสดงสื่อสารอารมณ์ความรู้สึกเชิงบวกในสถานการณ์ที่เป็นเชิงลบ วิธีการที่นำเสนอสำหรับการจำแนกข้อความประชดประชันนั้นใช้ชุดข้อมูล

จากทวิตเตอร์โดยเก็บข้อมูลจำนวน 35,000 เพื่อใช้เป็นชุดการเรียนรู้และจำนวน 15,000 เพื่อใช้เป็นข้อมูลทดสอบรูปแบบการเก็บข้อมูลโดยใช้แฮชแท็ก #sarcasm และ #sarcastic ด้วยทวิตเตอร์เอง ในการทำความสะอาดข้อมูลสิ่งที่กำจัดออกไปเนื่องจากไม่สนใจในงานนี้คือ เครื่องหมายวรรคตอน ข้อมูลตัวเลข และตรวจสอบและแก้ไขการสะกดคำ ขั้นตอนในการสะกดคุณลักษณะใช้ N-grams และใช้หน้าที่ของคำในการระบุความหมาย เช่น ใช้ 1-Gram โดยใช้ VERB ในการระบุข้อในเชิงบวกหรือเชิงลบ การให้ค่าน้ำหนักได้เลือกใช้ TF-IDF การใช้เทคนิคด้านการจำแนกโดยใช้การเรียนรู้ของเครื่องและเหมืองข้อมูล คือ นาอีฟเบย์ ลินเนียร์เกรสชัน แรนdomฟอร์เรส และ ใช้การให้ค่าน้ำหนักในการเลือกวิธีการวัดการจำแนกด้วยอัลกอริทึม นาอีฟเบย์ ลินเนียร์เกรสชัน แรนdomฟอร์เรส ผลการทดลอง พบว่าค่าความถูกต้องด้วยวิธีการเรียนรู้ที่ดีและอัลกอริทึมแรนdomฟอร์เรส ด้วยค่าความถูกต้อง 84 และ 85%

Razali และคณะ [54] นำเสนอการศึกษาความสำคัญในการจำแนกข้อความประชิดประชัน สำหรับงานด้านการวิเคราะห์อารมณ์ความรู้สึก ซึ่งได้ศึกษาวิธีการต่างๆ ดังนี้ 1) การใช้วิธีการจำแนกด้วยกฎแฮชแท็ก โดยกฎระบุว่า หากพบทะเข้ากัน (#sarcasm) ก็จะไม่สนใจข้อความอื่นๆ นั้น หมายถึงเป็นข้อความประชิดประชันและหากมีการใช้กริยาที่เป็นเชิงบวกในสถานการณ์ที่เป็นเชิงลบก็ จำแนกได้ว่าเป็นข้อความประชิดประชัน 2) วิธีที่สองใช้วิธีทางสถิติโดยใช้รูปแบบเป็นฐานของคุณลักษณะโดยพิจารณาจากสถานการณ์ที่ตรงกัน สถานการณ์ที่แตกต่างกัน และ สถานการณ์ที่ไม่เกี่ยวข้องกัน ฐานข้อมูลด้านอารมณ์ความรู้สึก และไอคอนแสดงอารมณ์ได้ถูกนำมาใช้ในการพิจารณ์ด้วย 3) ใช้วิธีการการเรียนรู้เชิงลึก (Deep learning) ในการพิจารณาเนื้หาจากรูปภาพ เนื่องจากการแสดงการประชิดประชันบนเครื่อข่ายสังคมออนไลน์มีการใช้รูปภาพประกอบเป็นจำนวนมาก

Gidhe และ Ragha [55] นำเสนอวิธีการจำแนกข้อความคิดเห็นประชิดประชันบนข้อความที่ไม่มีแฮชแท็กด้วยวิธี Multilayer perceptron-Backpropagation (MLP-BP) โดยให้เหตุผลของ การศึกษาว่า ข้อความประชิดประชันนั้นเป็นข้อความที่แสดงถึงอารมณ์ความรู้สึกที่ถูกซ่อนเอาไว้ซึ่ง สื่อสารออกมาผ่านข้อความที่มีความหมายถึงกันข้าม ชุดข้อมูลที่นำมาใช้จากฐานข้อมูล Reddit การสะกดคุณลักษณะมีดังนี้ 1) คุณลักษณะทางโครงสร้าง โดยการนำการเกิดขึ้นของเครื่องหมายวรรคตอน เครื่องหมายทางการสนทนา และไอคอนแสดงอารมณ์ 2) คุณลักษณะทางอารมณ์โดยใช้คลังคำแสดงอารมณ์จาก Whissell Dictionary 3) คุณลักษณะเชิงความหมายของความคล้ายคลึงกันระหว่างคำ ประชิดประชันกับความรู้สึกที่แท้จริงของคำเป้าหมาย

Chaudhari และ Chandankhede [56] นำเสนอการศึกษาในการสำรวจเกี่ยวกับการทดลองการจำแนกข้อความประชิดประชัน จากการศึกษาพบว่าสามารถแบ่งชนิดของการจำแนกคำประชิดประชันได้ดังนี้ 1) คำประชิดประชันที่การบ่งบอกความแตกต่างของอารมณ์ความรู้สึก เช่น ความแตกต่างระหว่างอารมณ์ความรู้สึกทางบวกและสถานการณ์ทางลบ ความแตกต่างระหว่าง

อารมณ์ความรู้สึกทางลบและสถานการณ์ทางบวก ความแตกต่างทางความหมาย ความแตกต่างระหว่างปัจจุบันกับอดีต การปฏิเสธความจริง และการกล่าวถึงข้อเท็จจริงชั่วคราว 2) คำประชดประชันที่เป็นสื่อในการถ่ายทอดอารมณ์ความรู้สึก เช่น การแสดงความรอบรู้และความเฉลียวฉลาดหรือมีปฏิภาน การแสดงถึงอารมณ์การคร่าครวย การพูดเลอะเทอะ การแสดงการพูดหลบหลีก การพูดเลียงหรือการพูดโกหก การแสดงออกถึงความรุนแรง การอาละวาด 2) คำประชดประชันที่เป็นรูปแบบของการแสดงออกเป็นลายลักษณ์อักษร เช่น การใช้เครื่องหมายวรรคตอน การใช้ตัวอักษรพิมพ์ใหญ่ทั้งหมด เพื่อเป็นตัวบ่งชี้ถึงการประชดประชัน การแสดงออกในรูปแบบโครงสร้างของประโยคซึ่งมีสองส่วนในประโยคเดียวที่มีข้อแตกต่างกัน การแสดงออกในรูปแบบการวิเคราะห์คำศัพท์ซึ่งส่วนนี้เป็นการใช้แยชแท็ก เช่น #sarcasm #irony 3) คำประชดประชันที่เป็นการแสดงออกถึงการมีความเชี่ยวชาญ เช่น ความเชี่ยวชาญทางด้านภาษา, แสดงถึงทักษะความรู้ทางสภาพแวดล้อม ในส่วนของการเลือกชนิดของคุณลักษณะ 1) คุณลักษณะทางคำศัพท์ ในส่วนนี้ เช่น bigram, n-gram, skip-gram, #hashtag 2) คุณลักษณะในการปฏิบัติ เช่น การใช้สัญลักษณ์ต่างๆ เช่น รูปภาพไอคอนแสดงอารมณ์ 3) คุณลักษณะของการใช้คำพูดเกินจริง เช่น การเน้น้ำเสียง คำอุทาน เครื่องหมายคำพูด เครื่องหมายวรรคตอนต่างๆ 4) คุณลักษณะตามรูปแบบ เช่น รูปแบบการเกิดคำที่ปรากฏซ้ำๆ 5) คุณลักษณ์ของประโยค เช่น การรวมกันของลักษณะของหน่วยคำ หน้าที่ของคำ 6) คุณลักษณะตามบริบท ที่ใช้ข้อมูลจากเห็นใจจากข้อความ เช่น สัญลักษณ์ต่างๆ 7) คุณลักษณะของคำอุปมาอุปมัย เช่น คำนามที่มีความหมายเชิงบวกหรือเชิงลบ ลักษณะของการเน้นคำคุณศัพท์, สุภาษิตและคำพังเพย ประเด็นปัญหาของการจำแนกข้อความประชดประชัน ได้นำเสนอไว้ดังนี้ 1) ปัญหาทางของชุดข้อมูล ประเด็นด้านข้อมูลที่นำมาใช้ในการวิเคราะห์ทางด้านนี้ยังค่อนข้างคลุมเครือเนื่องจากผู้ที่ศึกษาด้านนี้ส่วนมากใช้การรวบรวมข้อมูลโดยใช้แยชแท็ก ซึ่งเมื่อนำแยชแท็กออก ข้อความเหล่าจะมีความที่ไม่ใช่ข้อความประชดประชันทันที 2) ปัญหาของคุณลักษณะ ประโยคที่เป็นข้อความประชดประชัน การใช้ตัวจำแนกด้านอารมณ์ความรู้สึกประสิทธิภาพการจำแนกอาจลดลง ด้านความรู้สึกสามารถใช้เป็นคุณลักษณะสำหรับตัวจำแนกประเภทได้และเป็นต้องใช้ข้อของประโยค ดังนั้นคุณลักษณะใหม่ควรมีการสำรวจและใช้งานร่วมกับคุณลักษณะอื่นที่มีอยู่เพื่อให้ได้ความถูกต้องที่ดียิ่งขึ้น 3) ปัญหาทางด้านการเลือกใช้ตัวจำแนก ซึ่งบางครั้งนักวิจัยอาจใช้ชุดข้อมูลที่มีขนาดใหญ่ หรือขนาดเล็ก ซึ่งก็ไม่ใช่ประเด็นสำคัญ เพราะสามารถทำให้ข้อมูลมีความสมดุลกันได้ ดังนั้นควรใช้เทคนิคในการจำแนกประเภทที่ถูกต้องในชุดข้อมูลเพื่อจำแนกประเภทของประโยคประชดประชันและไม่ประชดประชันที่ถูกต้อง

Bhan และ D'silva [57] นำเสนอรูปแบบหัวข้อข้อความประชดประชันด้วยการวิเคราะห์อารมณ์ความรู้สึก โดยใช้การเรียนรู้ของเครื่อง ชุดของข้อมูลประกอบด้วย 3 ส่วน จากวิเตอร์ คือ ชุดเรียนรู้ ชุดการปรับปรุงคุณภาพ และชุดทดสอบ คุณลักษณะที่ใช้ ประกอบด้วย 4 คุณลักษณะคือ

คุณลักษณะที่เกี่ยวข้องกับอารมณ์ความรู้สึก คำที่เป็นเชิงบวก เชิงลบ คุณลักษณะที่เกี่ยวข้องกับเครื่องหมายวรรคตอน ซึ่งใช้การนับจำนวนของเครื่องหมายเหล่านี้ เช่น เครื่องหมายอัศจรรย์ เครื่องหมายคำนาม จุด การใช้ตัวอักษรพิมพ์ใหญ่ทั้งหมด เครื่องหมายคำพูด คุณลักษณะทางศัพท์และประโยค เช่น การนับจำนวนของการใช้คำที่ไม่ปกติ การแสดงข้อความที่เป็นคำประชดทั่วๆ ไป จำนวนของคำอุทาน จำนวนของของการแสดงอารมณ์ขบขัน การใช้คุณลักษณะที่เกี่ยวข้องกับรูปแบบของคำและหน้าที่ของคำ อัลกอริทึมที่ใช้ในการจำแนก คือ ชัพพร์ทเวก์เตอร์แมคชีน โลจิสติกรีเกรชั่น และ นาอีฟเบย์ ซึ่งชัพพร์ทเวก์เตอร์แมคชีน โลจิสติกรีเกรชั่น ให้ประสิทธิภาพโดยรวมเท่ากับ 86% และ นาอีฟเบย์ได้ค่าประสิทธิภาพโดยรวมเท่ากับ 83%

Miljana และคณะ [44] นำเสนอการจำแนกข้อความประชดประชันด้วยเทคนิคลังคำ ชุดข้อมูลที่ใช้ในการทดสอบเป็นชุดข้อมูลที่ไม่สมดุล 319 เป็นข้อความประชดประชันและ 1,413 เป็นข้อความไม่ประชดประชัน คุณลักษณะที่ใช้มีดังนี้ การเปรียบเทียบกับ Serbian wordnet, การจับคู่ระหว่างสมาชิกที่มีข้อความรู้สึกเชิงบวก, การเรียงลำดับของแท็กอารมณ์ความรู้สึก, หน้าที่ของคำ และการสืบถึงข้อความประชดประชันโดยตรง ผลของการจำแนกที่ได้ประสิทธิภาพสูงที่สุดคือ การรวมกันของทุกคุณลักษณะ ได้ค่าความถูกต้องเท่ากับ 86.10%

Manohar และ Kulkarni [58] นำเสนอการศึกษาการพัฒนาการวิเคราะห์ข้อความประชดประชันโดยใช้การประมวลผลภาษาธรรมชาติตัววิธีการใช้คลังคำ โดยใช้ข้อมูลจำทวิตเตอร์ด้วยทวิตเตอร์เอปีโอล การเตรียมข้อมูลโดยการกำจัดข้อความที่ไม่สนใจ เช่น ชื่อผู้ใช้งาน ที่อยู่เว็บไซต์ และแฮชแท็กออก และให้ความสนใจไอคอนแสดงอารมณ์ การตัดคำใช้โมเดล uni-gram โดยใช้ช่องว่าง มีการใช้คุณลักษณะด้วยการหาหน้าที่ของคำ และวิธีการแบบคลังคำ ในการวัดประสิทธิภาพด้วยค่าความถูกต้องเท่ากับการหาจำนวนของคำที่เป็นคำประชดประชันหารด้วยจำนวนของข้อความผลของการจำแนกแบบเรียลไทม์ให้ผลลัพท์ที่ดี

Jihen และคณะ [59] นำเสนอวิธีการในการจำแนกข้อความประชดประชันในภาษาอาрабิคบนเครือข่ายสังคมออนไลน์ โดยให้เหตุผลของการศึกษาว่าการจำแนกข้อความประชดประชันบนเครือข่ายสังคมออนไลน์นั้นมีความยากเนื่องจากข้อความเหล่านั้นเป็นข้อความที่ยากที่จะเข้าใจ ความหมายว่าผู้โพสข้อความนั้นต้องการสื่อสารกับใครอย่างไร ในกรณีศึกษานี้ได้ใช้ชุดข้อมูลทั้งหมด 5,479 โดยแบ่งเป็นข้อความประชดประชันจำนวน 1,733 และ ข้อความที่ไม่ใช่ข้อความประชดประชันจำนวน 1,733 ข้อความ วิธีการเลือกคุณลักษณะ 1) Surface features โดยพิจารณาสัญลักษณ์ เช่น เครื่องหมายวรรคตอน, ไอคอนแสดงอารมณ์, เครื่องหมายคำพูด, คำที่เป็นความหมายถึงกันข้าม (but), จำนวนและลำดับของเครื่องอัศจรรย์และเครื่องหมายคำนาม, การรวมกันของเครื่องอัศจรรย์และเครื่องหมายคำนาม, คำพูดที่ไม่ได้แสดงถึงความขัดแย้ง, คำอุทาน และจำนวนของไอคอนแสดงอารมณ์ 2) Sentiment features การใช้คลังคำที่รวมคำที่มีความหมายเชิงบวกและ

เชิงลบ เช่น การแปลจากคลังคำ Bing Liu ซึ่งมีคำที่มีความหมายเชิงบวกจำนวน 2,006 และที่มีความหมายเชิงลบจำนวน 4,783 คำ โดยใช้เครื่องมือแปลภาษาของกูเกิล การแปลคลังคำที่รวมคำเชิงบวก เป็นกลาง และเชิงลบ จำนวน 2,718, 570 และ 4,911 ตามลำดับ จากคลังคำ MPQA Subjectivity, คลังคำไอลคอนแสดงอารมณ์จากภาษาอาрабิก ซึ่งมีความคิดเห็นอยู่ระหว่าง -7 และ 7 ของคำที่เป็นเชิงลบ และเชิงบวกจำนวน 22,962 และ 20,342 และ คลังคำแฮชแท็กภาษาอาрабิกมีคำเชิงบวกและเชิงลบ จำนวน 11,941 และ 8,179 จากนั้นจะได้คำที่เป็นเชิงบวกและเชิงลบจำนวนทั้งสิ้น 26,777 และ 22,239 ซึ่งได้กำจัดคำที่ซ้ำกันออก การทดลองใช้เครื่องมือ Weka toolkit โดยใช้อัลกอริทึม ชัพพอร์ทเวกร์เตอร์แมคชีน, นาอีฟเบรย์, โลจิสติก รีเกรชั่น, ลินีย์ รีเกรชั่น, แรนดอมทรี และ แรนดอมฟอร์ส โดยใช้ 10-cross validation ในการทดสอบ ผลที่ได้ประสิทธิภาพมากที่สุดคือ แรนดอมฟอร์ส จากการวัดด้วยค่าความถูกต้องเท่ากับ 72.36 เปอร์เซนต์ ค่าความแม่นยำเท่ากับ 72.90% ค่าความระลึกเท่ากับ 73.50% และค่าประสิทธิภาพโดยรวมเท่ากับ 72.70%

Liebrecht และคณะ [60] นำเสนอวิธีการในการจำแนกข้อความประชดประชันบนทวิตเตอร์ในภาษาดัช โดยการเก็บข้อมูลทวิตเตอร์จำนวน 78,000 ทวิตด้วยแฮชแท็ก (#sarcasme) ซึ่งหมายถึงคำประชดประชันในภาษาดัช การเตรียมข้อมูลในส่วนของการตัดคำให้ความสนใจเครื่องหมายวรรคตอน และตัวอักษรตัวพิมพ์ใหญ่ กรณีข้อความที่สั้นและแฮชแท็กถูกกำจัดออก ใช้โมเดล Uni, Bi, Trigrams ในกระบวนการนำเข้าเป็นคุณลักษณะ

Ahmad และคณะ [61] นำเสนอวิธีการตรวจจับข้อความประชดประชันจากเอกสารบนเว็บโดยใช้เทคนิควิธีการเรียนรู้ของเครื่อง ชุดข้อมูลที่ใช้ในการศึกษาจำนวน 2795 แบ่งเป็นข้อมูลไม่ประชดประชันจำนวน 2624 และ ข้อความประชดประชันจำนวน 171 การเตรียมข้อมูลใช้เครื่องมือ NLTK took kit จากนั้นกำจัดคำหยุดซึ่งเป็นคนที่ไม่มีความสำคัญออกไป และ ทำการหารากศัพท์เพื่อลดจำนวนคุณลักษณะ วิธีการที่เลือกใช้ในการสะกัดคุณลักษณะคือ TF-IDF (Term Frequency - Inverse Document Frequency), TF-BNS (Term Frequency Bi-normal separation), BIN (Binary) และ TF-BNS-IDF (Term Frequency – Bi-normal separation scaling – Inverse Document Frequency) อัลกอริทึมที่ใช้ในการเรียนรู้คือชัพพอร์ทเวกร์เตอร์แมคชีน วัดประสิทธิภาพการทดลองด้วย ค่าความถูกต้อง ค่าความแม่นยำ ค่าระลึก และค่าประสิทธิภาพโดยรวม โดยผลการทดลองแยกตามคุณลักษณะดังนี้ 1) TF-IDF ค่าความถูกต้องเท่ากับ 83.41% ค่าความแม่นยำเท่ากับ 72.20% ค่าระลึกเท่ากับ 73.20% และค่าประสิทธิภาพโดยรวมเท่ากับ 72.70% 2) BIN ค่าความถูกต้องเท่ากับ 84.08% ค่าความแม่นยำเท่ากับ 74.60% ค่าระลึกเท่ากับ 78.80% และค่าประสิทธิภาพโดยรวมเท่ากับ 76.70% 3) BNS ค่าความถูกต้องเท่ากับ 89.92% ค่าความแม่นยำเท่ากับ 80.20% ค่าระลึกเท่ากับ 85.90% และค่าประสิทธิภาพโดยรวมเท่ากับ 82.90% และ 4) TF-IDF ค่าความถูก

ต้องเท่ากับ 92.75% ค่าความแม่นยำเท่ากับ 82.60% ค่าระลึกเท่ากับ 87.00% และค่าประสิทธิภาพโดยรวมเท่ากับ 84.00%

Vateekul และคณะ [62] ได้ศึกษาเกี่ยวกับการวิเคราะห์อารมณ์ความรู้สึกข้อความภาษาไทย บนทวิตเตอร์ โดยใช้เทคนิค Long Short-Term Memory (LSTM) และ Dynamic Convolutional Neural Network (DCNN) เพื่อเปรียบเทียบประสิทธิภาพกับการเรียนรู้ของเครื่องด้วยอัลกอริทึม Naïve Bayes, Support Vector Machine และ Maximum Entropy ซึ่ง LSTM และ DCNN ให้ประสิทธิภาพดีกว่า และ DCNN ให้ค่าความถูกต้องมากที่สุด โดยมีผลลัพธ์ค่าความถูกต้องดังนี้ DCNN 75.35% LSTM 75.30% MaxEnt 75.13% SVM 74.71% และ NB 74.05%

จากการศึกษางานวิจัยที่เกี่ยวข้องจะเห็นได้ว่าการศึกษางานทางด้านการจำแนกข้อความประชดประชนนั้นยังมีความท้าทายและยังมีการศึกษาวิจัยเพื่อเพิ่มประสิทธิภาพในการจำแนกข้อความประชดประชนอย่างต่อเนื่อง ในหลากหลายภาษา ซึ่งโครงสร้างทางด้านภาษาของแต่ละภาษาต่างมีความแตกต่างกัน ทั้งนี้ในภาษาไทยยังไม่มีงานวิจัยทางด้านการตรวจสอบข้อความประชดประชนจากข้อมูลเครือข่ายสังคมออนไลน์ ผู้วิจัยจึงให้ความสนใจที่จะศึกษาเพื่อหาระเบียบวิธีในการตรวจสอบข้อความประชดประชนภาษาไทยจากข้อมูลเครือข่ายสังคมออนไลน์ คำหรือข้อความประชดประชนเป็นรูปแบบของข้อความที่มีการสื่อสารอกรามมีความหมายตรงกันข้ามกับความหมายที่แท้จริง มีความยากในการตรวจสอบข้อความประชดประชนจากข้อความ การใช้ข้อความเชิงบวกในสถานการณ์ทางลบ การใช้ข้อความสั้น จากการศึกษางานวิจัยที่เกี่ยวข้องในงานทางด้านการตรวจจับ/การจำแนกข้อความประชดประชนกับความนั้นยังถือเป็นเรื่องที่ท้าทายและยังถือเป็นเรื่องยากในการที่การเรียนรู้ของเครื่องจะสามารถทำได้ตรงกับการความหมายที่แท้จริง ทั้งนี้ยังมีการศึกษาวิจัยอย่างต่อเนื่อง ซึ่งสามารถสรุปประเด็นต่างๆ ได้ดังนี้ 1) การเลือกชุดข้อมูลส่วนใหญ่เลือกข้อมูลจากเครือข่ายสังคมออนไลน์ เช่น Twitter, Amazon product review, Facebook, Instagram เป็นต้น ภาษาที่มีการศึกษา ภาษาอังกฤษ, ภาษาอินดู, ภาษาดัช, ภาษาสเปน, ภาษาญี่ปุ่น, ภาษาอินโด, ภาษาเซอเบียร์, ภาษาตุรกี, ภาษาบรากิล เนื่องจากเป็นแหล่งข้อมูลที่สามารถรวบรวมได้ง่ายและมีจำนวนมาก วิธีการในการรวมรวมข้อมูลใช้การค้นหาจากแพลตฟอร์มตัวอย่างเช่น #sarcasm, #sarcastic, #irony, #satire, #not เท yönelikของการใช้แซชแท็กในการเก็บข้อมูล เพราะจะได้ข้อมูลที่เป็นตัวแทนของคำประชดประชนที่ใช้ในการศึกษางานด้านการจำแนกข้อความประชดประชนได้ดีที่สุด เพราะหากไม่ใช้แซชแท็กอาจจะได้ชุดข้อมูลที่มีความหลากหลายมากเกินไป ทั้งนี้ขันตอนแรกในการเตรียมข้อมูลนั้น ผู้วิจัยได้กำจัดแซชแท็กออก แล้วให้ผู้เชี่ยวชาญระบุคลาสหรือลาเบลสำหรับคลาสประชดประชน และไม่ประชดประชน 2) การเลือกคุณลักษณะเลือกจากคุณลักษณะต่างๆ เช่น N-gram, Hashtag, Semantic, Syntactic, POS-tagging, Bag-of-word, Emoticons, Punctuation, Lexical feature, Pattern-based feature, Contextual feature,

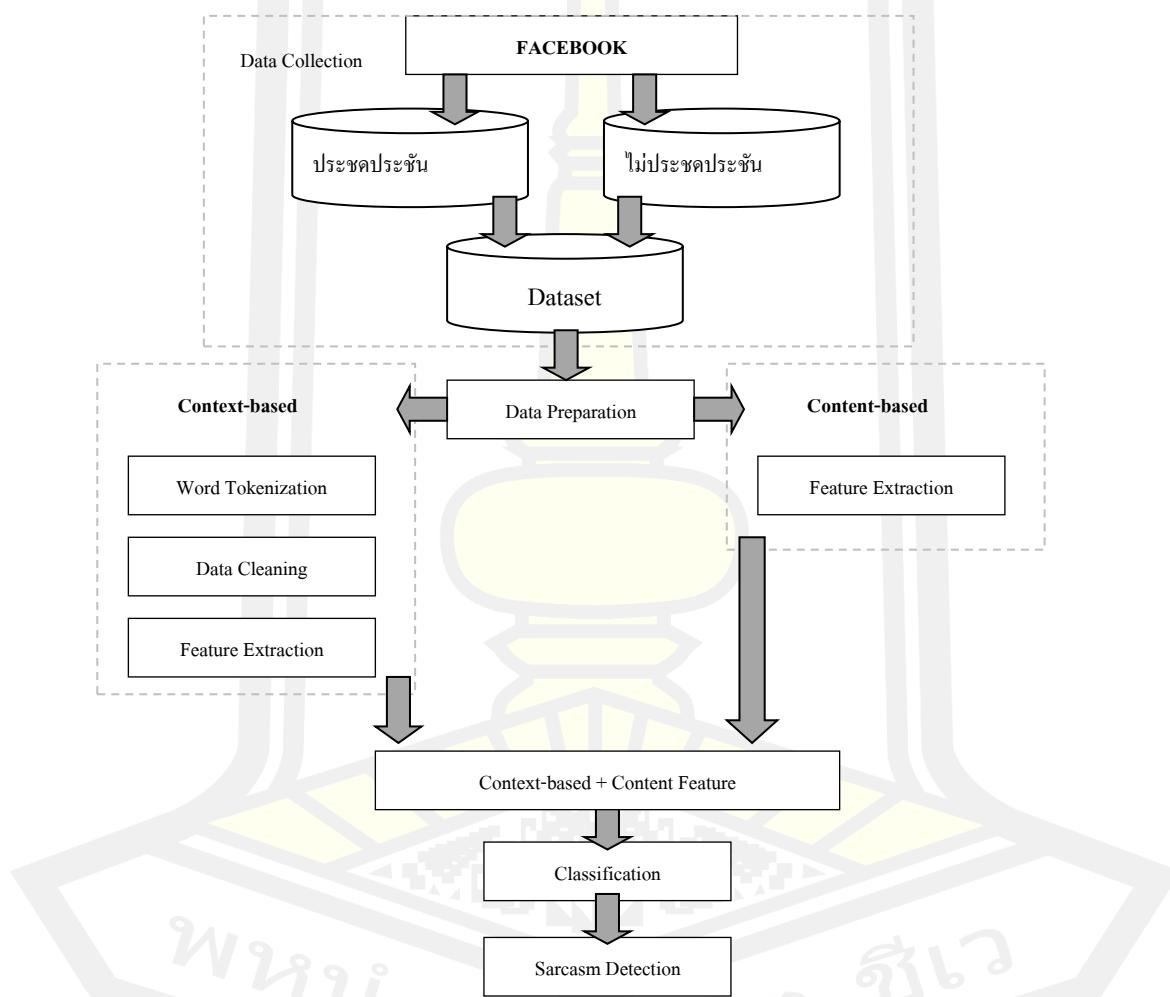
Word2Vec 3) การเลือกใช้อัลกอริทึมที่ใช้ในการเรียนรู้ ใช้วิธีจำแนกด้วยการเรียนรู้ของเครื่องแบบมีผู้สอน ด้วยอัลกอริทึม ดังนี้ Logistic Regression/Maximum Entropy, Winnow class, Naïve Bayes, Support Vector Machine, Tree-based, Random Forest, Ensemble, K-nearest Neighbor และการใช้การเรียนรู้เชิงลึก Long Short-Term Memory 4) การวัดประสิทธิภาพในการจำแนก ใช้ 10-fold cross validation เพื่อแบ่งข้อมูลในการวัดประสิทธิภาพ การประเมินผลการจำแนกรือการทดสอบประเมินผลเพื่อหาความถูกต้องของการจำแนก โดยวัดค่า ค่าความถูกต้อง, ค่าความแม่นยำ, ค่าระลึก, ค่าประสิทธิภาพโดยรวม

นอกจากนี้ยังพบว่า จากการศึกษางานวิจัยที่ผ่านมาอย่างไม่มีการศึกษาการจำแนกข้อความประชดประชันด้วยข้อความภาษาไทย และยังไม่มีการเลือกใช้คุณลักษณะที่รวมกันระหว่างบริบทในข้อความและเนื้อหาในข้อความ ซึ่งการเลือกคุณลักษณะที่ดีนั้นจะช่วยเพิ่มประสิทธิภาพในการจำแนกข้อความประชดประชันได้ดียิ่งขึ้น

บทที่ 3

วิธีดำเนินการวิจัย

งานวิจัยนี้มีวัตถุประสงค์เพื่อการตรวจจับข้อความประชดประชันบนเครือข่ายสังคมออนไลน์ เพื่อให้บรรลุวัตถุประสงค์ผู้วิจัยได้นำเสนอกระบวนการในการดำเนินการวิจัย 5 ขั้นตอน ได้แก่ 1) การรวบรวมข้อมูล (Data Collection) 2) การเตรียมข้อมูล (Data Processing) 3) การสกัดคุณลักษณะ (Feature Extraction) 4) การสร้างตัวจำแนก (Classifier) 5) การวัดประสิทธิภาพการจำแนก (Evaluation) ดังรูปที่ 8 แสดงให้เห็นถึงขั้นตอนของการดำเนินการวิจัยในภาพรวมทั้งหมด



รูปที่ 8 ขั้นตอนในการดำเนินการวิจัย

3.1 การรวบรวมข้อมูล

งานวิจัยนี้ได้เก็บรวบรวมข้อมูลข้อความจากเฟสบุ๊ค ที่มีแฮชแท็ก #ประชดประชัน ซึ่งจาก การศึกษางานวิจัยที่เกี่ยวข้อง [5, 38, 40, 44, 46, 49] พบร่วมกัน พบว่าการรวมรวมข้อมูลด้านการประชดประชันนั้นใช้วิธีการรวบรวมข้อมูลโดยใช้คำค้นแฮชแท็ก ตัวอย่างการวิจัยที่เป็นข้อความภาษาอังกฤษ

ใช้คำค้น #sarcasm, #sarcastic, #irony เป็นต้น งานวิจัยภาษาอื่น เช่น ภาษาดัช [49] ใช้คำค้น #sarcasme ดังนั้นในงานวิจัยนี้จึงใช้วิธีการรวบรวมข้อมูลโดยการใช้แฮชแท็ก ซึ่งรวมข้อมูลด้วย แฮชแท็กที่มีคำค้นดังนี้ 1) ข้อความที่เป็นข้อความประชดประชันใช้แฮชแท็ก #ประชด และ #ประชดประชัน 2) ข้อความไม่ประชดประชันรวมรวมข้อมูลทั่วๆไป ซึ่งใช้หลักการการเก็บข้อมูลรูปแบบเดียวกันกับการเก็บข้อความประชดประชัน โดยประยุกต์ใช้แฮชแท็ก #สิงค์ดี, #คิดดี, มีสุข, ความสุข, #โชคดีจัง ใน การระบุคลาสนั้นผู้วิจัยใช้วิธีการระบุคลาสจากแฮชแท็ก โดยข้อความที่ได้จากแฮชแท็กประชด ถูกระบุคลาสเป็น ประชดประชัน ประกอบด้วยชุดข้อมูลทั้งหมด 5,400 รายการ และ ข้อความที่ได้จากข้อความทั่วไปที่ไม่ระบุแฮชแท็กประชดประชัน ระบุคลาสเป็นไม่ประชดประชัน ประกอบด้วยชุดข้อมูลทั้งหมด 5,400 รายการ ตัวอย่างข้อความดังแสดงในตารางที่ 5 ตารางที่ 5 ตัวอย่างข้อความในชุดข้อมูล

ข้อความ	คลาส
ยุติธรรมจริงๆๆๆ	Sarcasm
ชื่นชมในความคิดสร้างสรรค์ 😊😊😊	Sarcasm
เมื่อสั่งให้เพื่อนไปเด็กรถินมากินกับส้มตำโดยเด็ดมาทีกินได้ทั้งหมู่บ้าน 😊😊😊 5555	Sarcasm
ຍ..ຍາຍທອງດីເວຍនឹងតាតាໄປດោយនាមទៅអាជីវកម្មរបបុណ្ណោះໄប់ឡើ	Sarcasm
ឧូគុនដើរបានជូនជូនដើរបានជូនជូន	Sarcasm
មីគាមសុខពីនិងការរំលែកប៉ុណ្ណោះ	Non-Sarcasm
ឃើមឃើមមុនមុនមីគាមសុខ	Non-Sarcasm
ទាំបុណ្យវានីថ្ងៃមីគាមសុខ	Non-Sarcasm
មីគាមសុខយោងបុកឱ្យក្នុងក្នុង	Non-Sarcasm
មីគាមសុខទុកទាំងទុកទាំងទុកទាំងទុក	Non-Sarcasm
ទាក់ទងក្នុងក្នុងក្នុងក្នុងក្នុងក្នុង	Non-Sarcasm
មីគាមសុខចងក្រោមក្នុងក្នុងក្នុងក្នុងក្នុងក្នុងក្នុងក្នុងក្នុងក្នុងក្នុង	Non-Sarcasm

3.2 การเตรียมข้อมูล

3.2.1 การสกัดคุณลักษณะจากบริบทในข้อความ

การสกัดคุณลักษณะจากบริบทของข้อความใช้ข้อมูลเฉพาะข้อความที่เป็นข้อความประชดและไม่ประชดจากการเก็บรวบรวมข้อมูล [37] ซึ่งใช้หลักการของการทำเหมืองข้อความ (Text Mining) โดยจะทำการแปลงข้อมูลข้อความให้อยู่ในรูปของเวกเตอร์สเปส (Vector Space Model) ก่อนที่จะเข้าสู่กระบวนการสร้างตัวจำแนก เนื่องจากข้อความเป็นข้อมูลมีคุณลักษณะที่ไม่มีโครงสร้างที่แน่นอน (Unstructured Data) ดังนั้นจะต้องแปลงข้อความให้อยู่ในรูปของข้อมูลที่มีโครงสร้าง (Structural Data) โดยทำการสร้างเวกเตอร์ โดยหนึ่งเวกเตอร์จะแทนหนึ่งเอกสารหรือหนึ่งข้อความจำนวนมิติของเวกเตอร์ คือ จำนวนคุณลักษณะที่สกัดได้ และค่าที่อยู่ในเวกเตอร์จะคือค่าน้ำหนักของแต่ละคุณลักษณะ โดยขั้นตอนการเตรียมข้อมูลให้อยู่ในรูปของเวกเตอร์มีดังนี้

3.2.1.1 การทำความสะอาดข้อความ

ในกระบวนการทำความสะอาดข้อความจากชุดข้อมูลประชดและไม่ประชด ซึ่งในการวิจัยนี้ศึกษาข้อความภาษาไทย ดังนั้นก่อนเข้าสู่กระบวนการตัด จึงทำการกำจัดภาษาอังกฤษ สัญลักษณ์ต่างๆ และตัวเลขออกจากข้อความ สัญลักษณ์ถูกขจัดออกไปเนื่องจากไม่มีนัยสำคัญในการตรวจสอบข้อความ

3.2.1.2 การตัดคำ

งานวิจัยนี้ได้ประยุกต์การตัดคำ 2 วิธีคือ 1) การตัดคำโดยใช้ [63, 64] ซึ่งเป็นการใช้เทคนิคการเรียนรู้เชิงลึกพัฒนามาจากการตัดคำด้วย Deepcut [65] ในการตัดคำภาษาไทยที่เรียนรู้จากคลังคำจากสื่อสังคมออนไลน์ภาษาไทย VISTEC-TP-TH-2021 (VISTEC) ซึ่งประกอบด้วยข้อความจำนวน 49,997 ข้อความ เป็นตัวอย่างข้อความจากทวิตเตอร์ตั้งแต่ปี 2560 – 2562 มีจำนวนประโยชน์ 49,997 ประโยชน์และมีจำนวนคำทั้งหมด 3.39 ล้านคำ ผลการตัดคำที่ให้ประสิทธิภาพมากที่สุดคือ Deep stacked ensemble (DSE) โมเดล LST20 ให้ประสิทธิภาพการตัดตัวอักษร 99.01% ประสิทธิภาพการตัดคำ 97.33% ดังแสดง

ตารางที่ 6 ผู้วิจัยจึงเห็นว่าเป็นเทคนิคการตัดคำที่เหมาะสมที่สุดที่จะนำมาใช้ในการวิจัยครั้งนี้ ผลการตัดคำดังแสดงได้ดังตารางที่ 7

ตารางที่ 6 ผลการทดลองการตัดคำด้วย OSKut

ที่มา [64]

Method	WS160		TNHC		LST20		TWS21	
	Char	Word	Char	Word	Char	Word	Char	Word
DC	93.47	84.03	89.48	75.40	94.60	84.15	92.77	81.78
AC	93.50	84.04	88.82	73.71	95.24	87.21	91.47	79.31
TL-DC	96.30	90.60	95.43	88.60	98.63	96.30	96.78	90.99
TD-AC	94.10	85.00	90.57	77.54	98.04	94.77	95.47	89.27
SE-DC	95.20	86.90	95.20	84.10	94.96	87.72	94.76	86.33
SE-AC	94.50	85.60	93.70	83.90	96.30	89.87	93.86	84.43
DSE-DC	96.67	91.51	95.71	89.14	99.01	97.33	97.36	92.91
DSE-AC	94.57	86.24	95.71	88.52	98.46	95.79	97.31	92.78

ตารางที่ 7 ตัวอย่างการตัดภาษาไทย (OSKut Thai Word Segmentation, tl-deepcut-lst20)

ข้อความ	ผลการตัดคำ	คลาส
ยุติธรรมจริงๆๆๆ	['ยุติธรรม', 'จริง', 'ๆ', 'ๆ', 'ๆ', 'ๆ', 'ๆ']	ประชด
ยิ่มให้กับวันทำงานที่แสนสดใส หลอกตัวเอง ว่าวันอาทิตย์ได้มี้ายยย	['ยิ่ม', 'ให้', 'กับ', 'วัน', 'ทำงาน', 'ที่', 'แสน', 'สดใส', ' ', 'หลอก', 'ตัวเอง', 'ว่า', 'วัน', 'อาทิตย์', 'ได้', 'มี้ายยย']	ประชด
ไม่ต้องการคู่กระ Thompson เดียวถือได้	['ไม่', 'ต้องการ', 'คู่', 'กระ', ' Thompson', 'อัน', 'เดียว', 'ถือ', 'ได้']	ประชด
นานแค่ไหนแล้วไม่ได้สนุกขนาดนี้	['นาน', 'แค่', 'ไหน', 'แล้ว', 'ไม่', 'ได้', 'สนุก', 'ขนาด', 'นี้']	ไม่ประชด
ประทับใจในความน่ารักกวนไปค่าาาา	['ประทับใจ', 'ใน', 'ความ', 'น่า', 'รัก', 'นวน', 'ไป', 'ค่าาาา']	ไม่ประชด

3.2.1.3 การใช้ค่าน้ำหนักข้อความ

จำนวนคำที่เหลือจากการจัดคำหยุดออกจะถูกนำไปใช้เป็นคุณลักษณะ ในงานวิจัยนี้ทำการสกัดคุณลักษณะออกเป็นแบบ unigram ซึ่งคุณลักษณะแต่ละคุณลักษณะคือถุงคำหรือคำที่ตัดได้

จากนั้นทำการสร้างเวกเตอร์จากคุณลักษณะที่สกัดได้ โดย 1 เวกเตอร์ คือ 1 ข้อความ จำนวนคอลัมน์ของแต่ละเวกเตอร์เท่ากับจำนวนคุณลักษณะทั้งหมด ค่าที่อยู่ในแต่ละคุณลักษณะคือค่าน้ำหนักของคุณลักษณะ โดยงานวิจัยนี้ทำการทดลองกำหนดค่าน้ำหนักให้กับคุณลักษณะ 4 วิธี คือ Boolean weighting, TF weighting และ TF-IDF weighting เพื่อหาค่าน้ำหนักที่เหมาะสม ตัวอย่างเวกเตอร์ที่ได้จากการใช้คุณลักษณะแบบ unigram และกำหนดค่าน้ำหนักให้คุณลักษณะแบบ Boolean weighting แสดงได้ในตารางที่ 8 โดยค่าน้ำหนักเท่ากับ 1 หากถึง pragmatique คุณลักษณะในเอกสาร ถ้าค่าน้ำหนัก 0 หากไม่ถึง pragmatique คุณลักษณะในเอกสาร เช่น ในเอกสาร d_1 pragmatique คุณลักษณะหรือคำว่า เดิน ดังนั้นค่าน้ำหนักของคุณลักษณะดังกล่าวเท่ากับ 1 แต่ในเอกสาร d_2 ไม่ pragmatique คุณลักษณะ เดิน ดังนั้นค่าน้ำหนักของคุณลักษณะจึงมีค่าเท่ากับ 0 และตัวอย่างเวกเตอร์ที่ได้จากการใช้คุณลักษณะแบบ unigram และกำหนดค่าน้ำหนักให้คุณลักษณะแบบ TF weighting แสดงได้ดังตารางที่ 9 โดยค่าน้ำหนักของแต่ละเวกเตอร์ คือ จำนวนครั้งที่ pragmatique คุณลักษณะ เช่น ในเอกสาร d_1 pragmatique คุณลักษณะ สุข จำนวน 2 ครั้ง ดังนั้นค่าน้ำหนักของคุณลักษณะดังกล่าวในเอกสาร d_1 มีค่าเท่ากับ 2 และตารางที่ 10 ตัวอย่างเวกเตอร์ที่ใช้คุณลักษณะแบบ unigram และ TF-IDF weighting คือ การคำนวณค่าน้ำหนักของการเกิดคุณลักษณะในเอกสาร d_1 ปรากฏอยู่ในเอกสารอื่น ๆ หรือไม่ เช่น คุณลักษณะ เดิน ปรากฏอยู่ทั้งเอกสาร d_1 และ d_2 ผลการคำนวณดังตารางที่ 10

ตารางที่ 8 ตัวอย่างเวกเตอร์ที่ใช้คุณลักษณะแบบ unigram และ Boolean weighting

Documents	เดิน	ทาง	เห็นอย	สุข	ที่สุด
d_1	1	0	1	1	1
d_2	0	1	1	0	0
d_3	1	1	1	1	1

ตารางที่ 9 ตัวอย่างเวกเตอร์ที่ใช้คุณลักษณะแบบ unigram และ TF weighting

Documents	เดิน	ทาง	เห็นอย	สุข	ที่สุด
d_1	1	0	1	2	1
d_2	2	2	1	0	0
d_3	0	1	1	1	1

ตารางที่ 10 ตัวอย่างเวกเตอร์ที่ใช้คุณลักษณะแบบ unigram และ TF-IDF weighting

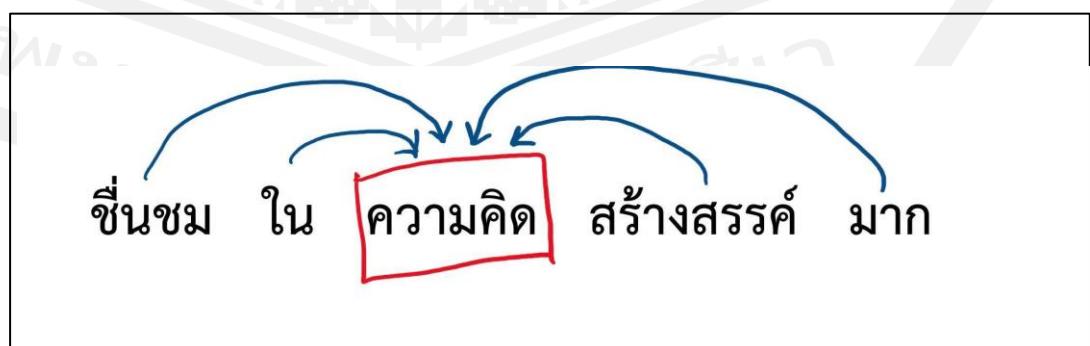
Documents	เดิน	ทาง	เห็นอย	สุข	ที่สุด
d_1	0.18	0	0	0.35	0.18
d_2	0.35	0.35	0	0	0

3.2.1.4 การสร้างตัวแทนเชิงความหมายของคำ

การสร้างตัวแทนเชิงความหมายของคำ (Word Embedding) เทคนิคนี้เป็นวิธีการในการแปลงข้อความให้อยู่ในรูปแบบเวกเตอร์ ซึ่งคำหนึ่งสามารถแทนค่าคำด้วยเวกเตอร์ที่ทำให้จำนวนมิติลดลง ซึ่งวิธีที่ใช้คือ Word2Vec [66] ซึ่งจะนำมาใช้แก้ปัญหาการแทนความค่าคำด้วยวิธี one-hot encoding จากตารางที่ 11 จะเห็นว่าการ encode ด้วยวิธีนี้ทำให้สั้นเปลืองหน่วยความจำ และขาดการสื่อความหมาย เช่นคำว่า “ประเทศ” และ “ประเทศประชัน” ต้องถูก encode ด้วยเวกเตอร์สองอันที่ไม่เหมือนกันเลยทั้งที่ความหมายของสองคำนี้มีความหมายเหมือนหรือคล้ายกัน ดังนั้นจึงมีวิธี word embedding เพื่อช่วยแก้ปัญหานี้ด้วยวิธี word2vec ซึ่งจะสร้างเวกเตอร์ของแต่ละคำขึ้นมา และดูความสัมพันธ์ระหว่างคำคำนั้นกับคำที่อยู่รอบข้าง วิธีนี้เป็นการกำหนดมิติของข้อมูลโดยที่ไม่จำเป็นต้องใช้จำนวนมิติของข้อมูลเท่ากับจำนวนคำที่ได้ ซึ่งโดยส่วนมากแล้วจะกำหนดมิติอยู่ที่ระหว่าง 100-300 ซึ่งเพียงพอสำหรับใช้เป็นตัวแทนของคำเพื่อนำไปใช้งานต่อไปได้ สำหรับการวิเคราะห์คำในประโยคโมเดลจะนำเอา word vectors ของคำที่อยู่รอบ ๆ ของคำคำนั้นๆ ภายในระยะของบริบท (context size) ที่กำหนดมาใช้เป็น input สำหรับการจำแนก และใช้คำที่กำลังพิจารณาซึ่งตำแหน่งอยู่ตรงกลางเป็นเป้าหมายในการทำนาย ดังแสดงในรูปที่ 9

ตารางที่ 11 การแทนค่าคำด้วยวิธี one-hot encoding

Index	1	2	...	8999	9000	9001	...	10800
ประเทศ				1				
ประเทศประชัน						1		



รูปที่ 9 การพิจารณาเวกเตอร์ของคำจากบริบทรอบข้าง

3.2.2 การสกัดคุณลักษณะจากเนื้อหาในข้อความ

ในการสกัดคุณลักษณะจากเนื้อหาในข้อความ เป็นการสกัดคุณลักษณะจากข้อความและองค์ประกอบของข้อความ เนื่องจากข้อความประเภทคำประชดประชัน ที่สื่อสารออกแบบผ่านข้อความนั้น มีคุณลักษณะที่ผู้สื่อสารแสดงออกมากโดยมีความหมายตรงข้ามกับความหมายที่แท้จริง ดังนั้นในการสกัดคุณลักษณะนี้จึงเป็นการพิจารณาเนื้อหาในข้อความ ซึ่งศึกษาจากการวิจัย [5] ตัวอย่างข้อความดังแสดงในตารางที่ 17 สำหรับงานวิจัยนี้ใช้คุณลักษณะจำนวน 15 คุณลักษณะ ดังนี้

1. การมีข้อความที่แสดงอารมณ์เชิงบวก (F1) การใช้ความแตกต่างระหว่างข้อของอารมณ์เชิงบวกอยู่ในข้อความเป็นคุณลักษณะที่สำคัญในการพิจารณาถึงการแสดงออกถึงข้อความประชดประชัน ซึ่งการวิจัยนี้ใช้ข้อความเชิงบวกจาก [67] ดังแสดงในภาคผนวก ก เป็นข้อความในการเปรียบเทียบว่ามีคำที่แสดงอารมณ์เชิงบวก

2. การมีข้อความที่แสดงอารมณ์เชิงลบ (F2) การใช้ความแตกต่างระหว่างข้อของอารมณ์เชิงลบอยู่ในข้อความเป็นคุณลักษณะที่สำคัญในการพิจารณาถึงการแสดงออกถึงข้อความประชดประชัน ซึ่งการวิจัยนี้ใช้ข้อความเชิงลบจาก [67] เป็นข้อความในการเปรียบเทียบว่ามีคำที่แสดงอารมณ์เชิงลบ ดังแสดงในภาคผนวก ข

3. การใช้คำที่ไม่ปึกติ (F3) คุณลักษณะดังกล่าวถูกนำมาใช้พิจารณาข้อความประชดประชัน เนื่องจากสมมติฐานที่ว่า ข้อความที่เป็นการใช้คำที่ไม่ปึกติหรือไม่ใช้ข้อความที่เขียนอย่างถูกต้องตามพจนานุกรม ตัวอย่างคำที่ไม่ปึกติที่นำมาพิจารณา เช่น รักกอกกอกกอกกอก การใช้ตัวอักษรที่มากเกิน 5 ตัวอักษร ทำให้มีเหตุที่สื่อได้ว่าเป็นการแสดงออกซึ่งข้อความประชดประชัน เพราะเป็นการสื่อสารที่เป็นเกิดจากความตั้งใจที่ผิดปกติจากการใช้ข้อความเพื่อการสื่อสารทั่ว ๆ ไป ตัวอย่างคุณลักษณะนี้ดังแสดงในตารางที่ 12

ตารางที่ 12 ตัวอย่างการใช้คำที่ไม่ปึกติ

ตัวอย่างข้อความ	ตัวอย่างข้อความ	ตัวอย่างข้อความ
มากกอกกอก	ยังงงงงง	เดียดดดดดด
เหรออออออ	แล้วววววว	เรียบร้อยยยยย

4. การใช้ปรัศนี (?) (F4) คุณลักษณะดังกล่าวถูกนำมาใช้พิจารณาข้อความประชดประชัน เนื่องจากสมมติฐานที่ว่า ข้อความที่มีการใช้เครื่องหมายปรัศนีที่มากเกิน 5 ตัวอักษร ทำให้มีเหตุที่สื่อได้ว่ามีความตั้งใจในการแสดงออกซึ่งข้อความประชดประชัน เพราะเป็นการสื่อสารที่เป็นเกิดจากความตั้งใจที่ผิดปกติจากการใช้ข้อความเพื่อการสื่อสารทั่ว ๆ ไป ตัวอย่างเช่น สงสัย? หรือ สงสัย???????? หากมีคุณลักษณะนี้ให้แทนค่าข้อความตามคุณลักษณะนี้เป็น 1 หากไม่มีให้กำหนดเป็น 0

5. การแสดงคำหัวเราะ (F5) จำนวนของการใช้คำแสดงการหัวเราะในประโยคอาจมีส่วนในการบอกถึงการแสดงออกซึ่งการประชดประชัน หากมีคุณลักษณะนี้ให้แทนค่าข้อความตามคุณลักษณะนี้เป็น 1 หากไม่มีให้กำหนดเป็น 0

6. การมีคำที่แสดงถึงการประชดประชันโดยทั่วไป (F6) การมีคำที่เป็นคำเฉพาะที่บ่งบอกได้ถึงการแสดงออกอย่างชัดเจนถึงการประชดประชัน หากมีคุณลักษณะนี้ให้แทนค่าข้อความตามคุณลักษณะนี้เป็น 1 หากไม่มีให้กำหนดเป็น 0 ตัวอย่างตั้งแสดงในตารางที่ 13

ตารางที่ 13 ตารางแสดงคำประชดประชันโดยทั่วไป

เลี้ย	แหม	แหม*	เอօ	เหรออ	แร้ว
เอิ่ม	ปะวะ	เก็น	เก่งเก็น	จริง	เลี้ย
تنید	จริงจริง	เรีย	ดีดี	ดีอก	เก่งเก็น
เก่งมากจ้า	เปล่าไม่มีไร	ดีมากจ้า	สนุกสุดสุด	เหอะตอก	เหอะๆ
เหอะ	เห้อ	เชอะ	ใช้สี	ເຄອະ	ເຈົ້າ
ເຈາໄປເຄອະ	ช่างแม่ง	ແລ້ວແຕ່ຈ້າ	ໄປຫິນກີໄປ	ເຮັດເວອງ	ເຮັມນັ້ນໄມ້ເດືອງ
ตามสบายเลย	ເອາທີ່ສບາຍໃຈ	ເອາເລີຍຍ	ອື່ຈ້າ	ຈີ່ແລະ	ກຸໄປເອງ
ໄມ່ມາປີ່ຫນ້າວ່ອ	ໄມ່ຕ້ອງຮັບກຽວ ອູ່	ອ່ອຍມາກກກ	ສນໃຈກຸດີ	ກົງອ່ອະ	ໄມ່ຕ້ອງຮັກ ຫຮອກ
ໄມ່ຕ້ອງສົນໃຈ	ໄມ່ຕ້ອງຫຮອກ	ໂສດມາກຈ້າ	ໂສດເວີ່ຍຍຍ	ໂສດຕັວເທ່າ ບ້ານ	ໂສດຕັວເທ່າ គາຍ
ໂສດກີ້	ສາຍດີເນວະ	ສາຍຈ້າສາຍ	ໄມ່ເຫັນຈະແຄຣ	ອູ້ໄດ້ໄປເຄອະ	ຄິດວ່າດີກີ້ທຳໄປ
ມີຄວາມສຸຂົກົງທຳ ໄປ	ມີຄວາມສຸຂົດີ	ເຄົ້າກ່ອນ	ນານເກີນ	ກົດີ	ກົງ
ກົງແລະ	ໄມ່ເປັນໄຈຈະພື້ ຮອໄດ້	ຍອມໂຈ່	ຮອໄດ້ຈິງໆ	ຂອໃຫ້ຮັກກັນ ນານໆ	ເຂົ້າຂ້າງກູ້ມືບ ຫາຍ
ໂຈດີ	ໄມ່ຕ້ອງມາຍຸ່ງ	ຜິດຕລວດ ແລະ	ແພັດລວດ	ສູ້ເຂົາໄມ້ໄດ້	ຕາມສບາຍ

ตารางที่ 13 ตารางแสดงคำประชดประชันโดยทั่วไป (ต่อ)

ເຊີ້ມເລຍຈ້າ	ເຊີ້ມເລຍ	ໄມ່ຕ້ອງມາ ຫຮອກ	ຄນດີມາກ	ດີດີມາກ	ຈະຮ້ອງໄຫ້ເລີຍງຸ
ເອາເລຍ!	ເຕັມທີ່ຈ້າ	ແດກຕາມ ສບາຍ	ໄມ່ຕ້ອງເກຮັງໃຈ	ໜີໄປໄກລໆ	ໄມ່ມືອະໄຈະ ຄຸມ

เรอาอยู่ได้	เราโวคे	ໂຄ'	ໂຄ'ເວຍ	ເວັ້ນເຂັ້ມ	
-------------	---------	-----	--------	------------	--

7. การใช้เครื่องหมายอัศเจรีย์ (!)(F7) ซึ่งโดยทั่วไปใช้เป็นเครื่องหมายที่ใช้เขียนไว้ข้างหลังคำหรือกลุ่มคำที่แสดงอารมณ์และความรู้สึกต่าง ๆ เช่น เสียใจ! ตกใจ! คุณลักษณะดังกล่าวถูกนำมาใช้พิจารณาข้อความประชดประชัน เนื่องจากสมมติฐานที่ว่า ข้อความที่มีการใช้เครื่องหมายอัศเจรีย์ที่มากเกินไป ตัวอย่าง เช่น รัก!!!!!!! การใช้เครื่องหมายอัศเจรีย์ที่มากเกิน 5 ตัวอักษร ทำให้มีเหตุที่ส่อได้ว่ามีความตั้งใจในการแสดงออกซึ่งข้อความประชดประชัน เพราะเป็นการสื่อสารที่เป็นเกิดจากความตั้งใจที่ผิดปกติจากการใช้ข้อความเพื่อการสื่อสารทั่ว ๆ ไป เช่น รัก! หากมีคุณลักษณะนี้ให้แทนค่าข้อความตามคุณลักษณะนี้เป็น 1 หากไม่มีให้กำหนดเป็น 0

8. การใช้มหัพภาค (.) (F8) คุณลักษณะดังกล่าวถูกนำมาใช้พิจารณาข้อความประชดประชัน เนื่องจากสมมติฐานที่ว่า ข้อความที่มีการใช้เครื่องหมายจุลภาคที่มากเกิน 5 ตัวอักษร ทำให้มีเหตุที่ส่อได้ว่ามีความตั้งใจในการแสดงออกซึ่งข้อความประชดประชัน เพราะเป็นการสื่อสารที่เป็นเกิดจากความตั้งใจที่ผิดปกติจากการใช้ข้อความเพื่อการสื่อสารทั่ว ๆ ไป หากมีคุณลักษณะนี้ให้แทนค่าข้อความตามคุณลักษณะนี้เป็น 1 หากไม่มีให้กำหนดเป็น 0

9. คำหยาบ (F9) การใช้คำหยาบในประโยคอาจมีส่วนในการบอกถึงการแสดงออกซึ่งการประชดประชัน ซึ่งการมีคำหยาบคายในประโยคเมื่อร่วมกับคำอื่นอาจมีความหมายที่ตรงข้าม หากมีคุณลักษณะนี้ให้แทนค่าข้อความตามคุณลักษณะนี้เป็น 1 หากไม่มีให้กำหนดเป็น 0 ซึ่งการวิจัยนี้ใช้ข้อความคำหยาบ [67] ดังแสดงในตารางที่ 14 ทั้งนี้เพื่อความเหมาะสมในการแสดงข้อความจึงขอแสดงตัวอย่างเฉพาะบางคำเท่านั้น

ตารางที่ 14 ตารางแสดงคำหยาบคาย

ຈົ້າ	ເຢື່ອງ	ໜາ
ພາຍ	ໜາບ້າ	ນັຈຈຸරາຈ
ສັນຕິນ	ชาຕີໜ້ວ	ສຸດ
គາຍ	ແຮດ	ກະທິງ
ເຄື່ອຍ	ເຂີຍ	ແມັດາ
ຮະຢາ	ສັນດານ	ທມີພ

10. การใช้บุพสัญญา (”) (F10) คุณลักษณะดังกล่าวถูกนำมาใช้พิจารณาข้อความประชดประชัน เนื่องจากสมมติฐานที่ว่า ข้อความที่มีการใช้เครื่องหมายจุลภาคที่มากเกิน 5 ตัวอักษร ทำให้มีเหตุที่ส่อได้ว่ามีความตั้งใจในการแสดงออกซึ่งข้อความประชดประชัน เพราะเป็นการสื่อสารที่เป็นเกิดจากความตั้งใจที่ผิดปกติจากการใช้ข้อความเพื่อการสื่อสารทั่ว ๆ ไป หากมีคุณลักษณะนี้ให้แทนค่าข้อความตามคุณลักษณะนี้เป็น 1 หากไม่มีให้กำหนดเป็น 0

11. การใช้ไม้ยมก (ๆ) (F11) คุณลักษณะดังกล่าวถูกนำมาใช้พิจารณาข้อความประชดประชัน เนื่องจากสมมติฐานที่ว่า ข้อความที่มีการใช้เครื่องหมายจุลภาคที่มากเกิน 5 ตัวอักษร ทำให้มีเหตุที่ส่อได้ว่ามีความตั้งใจในการแสดงออกซึ่งข้อความประชดประชันเพราเป็นการสื่อสารที่เป็นเกิดจากความตั้งใจที่ผิดปกติจากการใช้ข้อความเพื่อการสื่อสารทั่ว ๆ ไป หากมีคุณลักษณะนี้ให้แทนค่าข้อความตามคุณลักษณะนี้เป็น 1 หากไม่มีให้กำหนดเป็น 0

12. ไอคอนแสดงอารมณ์เชิงลบ (F12) การใช้ความแตกต่างระหว่างข้อของอารมณ์ กับ ไอคอนแสดงอารมณ์ อาจบ่งบอกได้ว่าถึงการแสดงออกถึงการประชดประชัน เช่น เอื้องน่ารักจริง ๆ ☺ โดยเลือกใช้รูปแบบไอคอนแสดงอารมณ์ที่สามารถใช้ได้บนเฟสบุ๊ค ตัวอย่างดังแสดงในตารางที่ 15 หากมีคุณลักษณะนี้ให้แทนค่าข้อความตามคุณลักษณะนี้เป็น 1 หากไม่มีให้กำหนดเป็น 0

ตารางที่ 15 แสดงไอคอนแสดงอารมณ์เชิงลบ

😊	☺	😑	Ӧ
Ӧ	Ӧ	Ӧ	Ӧ
Ӧ	Ӧ	Ӧ	Ӧ
Ӧ	Ӧ	Ӧ	Ӧ
Ӧ	Ӧ	Ӧ	Ӧ
Ӧ	Ӧ	Ӧ	Ӧ
Ӧ	Ӧ	Ӧ	Ӧ
Ӧ	Ӧ	Ӧ	Ӧ
Ӧ	Ӧ	Ӧ	Ӧ
Ӧ	Ӧ	Ӧ	Ӧ

13. ไอคอนแสดงอารมณ์เชิงบวก (F13) การใช้ความแตกต่างระหว่างข้อของอารมณ์ กับ ไอคอนแสดงอารมณ์ อาจบ่งบอกได้ว่าถึงการแสดงออกถึงการประชดประชัน เช่น เอื้องน่ารักจริง ๆ ☺ โดยเลือกใช้รูปแบบไอคอนแสดงอารมณ์ที่สามารถใช้ได้บนเฟสบุ๊ค ดังแสดงในตารางที่ 16 ตารางที่ 16 แสดงไอคอนแสดงอารมณ์เชิงบวก

😊	☺	😑	Ӧ
Ӧ	☺	Ӧ	Ӧ
Ӧ	☺	Ӧ	Ӧ
Ӧ	☺	Ӧ	Ӧ
Ӧ	☺	Ӧ	Ӧ
Ӧ	☺	Ӧ	Ӧ
Ӧ	☺	Ӧ	Ӧ
Ӧ	☺	Ӧ	Ӧ
Ӧ	☺	Ӧ	Ӧ

14. การใช้เครื่องหมายบวก (+) (F14) คุณลักษณะดังกล่าวถูกนำมาใช้พิจารณาข้อความประชดประชัน เนื่องจากสมมติฐานที่ว่า ข้อความที่มีการใช้เครื่องหมายบวกที่มากเกิน 5 ตัวอักษร ทำให้มีเหตุที่ส่อได้ว่ามีความตั้งใจในการแสดงออกซึ่งข้อความประชดประชันเพราเป็นการสื่อสารที่เป็นเกิดจากความตั้งใจที่ผิดปกติจากการใช้ข้อความเพื่อการสื่อสารทั่ว ๆ ไป หากมีคุณลักษณะนี้ให้แทนค่าข้อความตามคุณลักษณะนี้เป็น 1 หากไม่มีให้กำหนดเป็น 0

15. การใช้เครื่องหมายลบ (-) (F15) คุณลักษณะดังกล่าวถูกนำมาใช้พิจารณาข้อความ ประชดประชัน เนื่องจากสมมติฐานที่ว่า ข้อความที่มีการใช้เครื่องหมายลบที่มากเกิน 5 ตัวอักษร ทำให้มีเหตุที่สื่อได้ว่ามีความตั้งใจในการแสดงออกซึ่งข้อความประชดประชัน เพราะเป็นการสื่อสารที่เป็นเกิดจากความตั้งใจที่ผิดปกติจากการใช้ข้อความเพื่อการสื่อสารทั่ว ๆ ไป หากมีคุณลักษณะนี้ให้แทนค่าข้อความตามคุณลักษณะนี้เป็น 1 หากไม่มีให้กำหนดเป็น 0

ตารางที่ 17 ตัวอย่างข้อความจากการสกัดคุณลักษณะจากเนื้อหาในข้อความ

Text	F1	F2	F3	F4	F5	F6	F7	F8	F9	F10	F11	F12	F13	F14	F15	Class
เราง吉กินให้หมด น้ำเลยเทอทำให้ เราโกรด!!!!สำนักไว้ เลยนะจะะเทอทำ เราอ้วน	1	1	1	0	0	1	0	0	0	0	1	0	0	0	0	1
ໄວຍຍບຍບນີ່ເມື່ອ ¹ ດ້ອງຈັດສອບໃຫ້ ເສີຍເວລາຈຳງຽງ ມາສອນຕ່ອເຕົວະ ຄະ	0	1	1	0	0	1	0	0	0	0	1	0	0	0	0	1
นอกจากເບື້ນແມ່ ທຸກຫ຾ວແລ້ວຍັງເປັນ ແມ່ເນັນດ້ວຍນະຮັບ ສັກທີມັຍຄະມື ຄວາມສຸຂອຍໆກັບ ອາຫາຣ	1	1	0	0	1	0	1	0	0	1	0	0	0	0	0	2
ກາພບອກ ຄວາມຮູ້ສຶກກີ່ຈະ ປະມານນີ້ແທ ລ່ວມື້ກໍາເຮົາ ໃໝ່ທີ່ມີຄວາມສຸຂ	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0	2

จากการสกัดคุณลักษณะจากเนื้อหาในข้อความ สามารถสรุปการเลือกคุณลักษณะในส่วนนี้ได้ว่า คุณลักษณะที่เลือกใช้เป็นคุณลักษณะที่มีนัยสำคัญที่บ่งบอกได้ว่าข้อความประชดประชัน ส่วนมาก มีการสื่อออกมาเป็นข้อความในรูปแบบที่ไม่ปกติ หรือเกิดจากความตั้งใจสื่อสารออกมาให้ไม่ปกติจากผู้สื่อสาร เพื่อบ่งบอกว่าข้อความเหล่านี้มีนัยเป็นการประชดประชัน ซึ่งอาจบอกได้ว่า ข้อความประชดประชันนั้นมีรูปแบบ [5] การสื่อสารที่แตกต่างจากข้อความปกติ ซึ่งการเลือกกำหนดจำนวนคุณลักษณะที่นำมาใช้เป็นตัวแทนของเอกสารที่เป็นข้อความประชดเพียงแค่ 15 คุณลักษณะ

ดังกล่าวนี้ อาจจะเป็นข้อจำกัดในการจำแนกข้อความไม่ประชดประชัน เพราะคุณลักษณะเหล่านี้ถูกกำหนดให้เป็นตัวแทนของข้อความประชดประชันในชุดข้อมูลการทดลองในการวิจัยนี้เท่านั้น

3.2.3 คุณลักษณะการรวมบริบทในข้อความและเนื้อหาในข้อความ

การใช้วิธีการรวมคุณลักษณะระหว่างคุณลักษณะที่สกัดจากบริบทในข้อความรวมกับคุณลักษณะที่สกัดจากเนื้อหาในข้อความ สามารถรวมกันได้ดังนี้ 1) การรวมกันระหว่าง Boolean Weighting และ 16 คุณลักษณะจากเนื้อหาในข้อความ ดังแสดงในตารางที่ 18 2) การรวมกันระหว่าง TF Weighting และ 16 คุณลักษณะจากเนื้อหาในข้อความ 3) การรวมกันระหว่าง TF-IDF Weighting และ 16 คุณลักษณะจากเนื้อหาในข้อความ ซึ่งข้อจำกัดของการรวมกันทั้งสามข้อคือจะทำให้มีความโน้มเอียงในการประมวลผล เนื่องจากเป็นการรวมกันของข้อมูลที่มีรูปแบบไม่เหมือนกัน สำหรับการรวมกันของรูปแบบที่ 2 และ 3

ตารางที่ 18 ตัวอย่างข้อมูลคุณลักษณะจากบริบทในข้อความด้วย Boolean Weighting รวมกับคุณลักษณะที่สกัดจากเนื้อหาในข้อความ

Documents	เดิน	ทาง	เหนื่อย	สุข	ที่สุด	Positive Sentiment	Negative Sentiment	Positive Emoticon	Negative Emoticon
d_1	1	0	1	1	1	1	0	0	1
d_2	0	1	1	0	0	1	1	1	1
d_3	1	1	1	1	1	0	1	1	0

ตารางที่ 19 ตัวอย่างข้อมูลคุณลักษณะจากบริบทในข้อความด้วย TF Weighting รวมกับคุณลักษณะที่สกัดจากเนื้อหาในข้อความ

Documents	เดิน	ทาง	เหนื่อย	สุข	ที่สุด	Positive Sentiment	Negative Sentiment	Positive Emoticon	Negative Emoticon
d_1	1	0	1	2	1	1	0	0	1
d_2	2	2	1	0	0	1	1	1	1
d_3	0	1	1	1	1	0	1	1	0

ตารางที่ 20 ตัวอย่างข้อมูลคุณลักษณะจากบริบทในข้อความด้วย TF-IDF Weighting รวมกับคุณลักษณะที่สกัดจากเนื้อหาในข้อความ

Documents	เดิน	ทาง	เหนื่อย	สุข	ที่สุด	Positive Sentiment	Negative Sentiment	Positive Emoticon	Negative Emoticon
d_1	0.18	0	0	0.35	0.18	1	0	0	1
d_2	0.35	0.35	0	0	0	1	1	1	1

3.3 การสร้างตัวจำแนก

3.3.1 การสร้างตัวจำแนกด้วยวิธีการเรียนรู้ด้วยเครื่อง

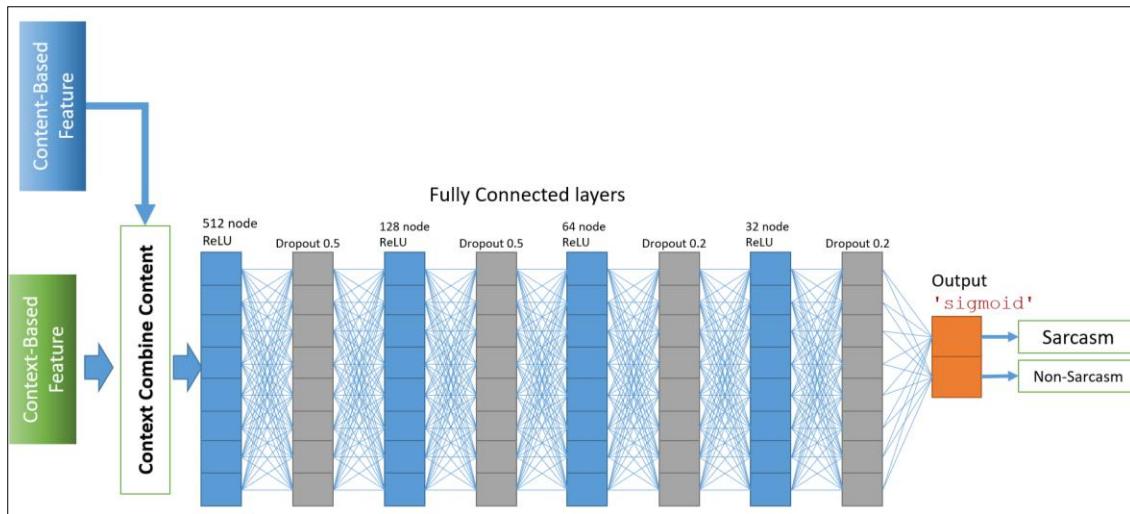
จากการศึกษางานวิจัยที่เกี่ยวข้องทำให้ทราบถึงความนิยมในการเลือกใช้ตัวจำแนกที่มีความนิยมและมีประสิทธิภาพในการจำแนก ทั้งนี้ผู้วิจัยได้เลือกใช้ตัวจำแนกโดยเลือกมา 4 ตัวจำแนก ดังต่อไปนี้ 1) นาอีฟเบย์ 2) ชัพพอร์ทเวกเตอร์แมคชีน 3) เพื่อนบ้านไกล์ที่สุด 4) ต้นไม้ตัดสินใจ เนื่องจากเป็นอัลกอริทึมที่นักวิจัยด้านการตรวจสอบข้อความประชดประชันส่วนมากนำมาใช้ในการจำแนก ซึ่งจะนำมาเปรียบเทียบกับประสิทธิภาพ การใช้เฉพาะคุณลักษณะจากบริบทในข้อความและการรวมคุณลักษณะจากบริบทในข้อความกับคุณลักษณะจากเนื้อหาในข้อความ ซึ่งในอัลกอริทึมแต่ละตัวเลือกใช้พารามิเตอร์ในการจำแนกของแต่ละวิธีดังนี้

1. ขั้นตอนวิธีชัพพอร์ทเวกเตอร์แมคชีน เลือกใช้ linear kernel ใน การเรียนรู้สำหรับการสร้างตัวจำแนก
2. ขั้นตอนวิธีนาอีฟเบย์ ไม่มีการเลือกใช้พารามิเตอร์ในวิธีนี้ เนื่องจากไม่มีการปรับพารามิเตอร์
3. ขั้นตอนวิธีต้นไม้ตัดสินใจ ใช้อัลกอริทึม ID3 เลือกใช้ Gini เป็นพารามิเตอร์สำหรับเกณฑ์ในการสร้างโครงสร้างการตัดสินใจ ในการเรียนรู้สำหรับการสร้างตัวจำแนก
4. ขั้นตอนวิธีเพื่อนบ้านไกล์ที่สุด เลือกใช้ Euclidean distance และกำหนดค่า K แตกต่างกันในการเรียนรู้สำหรับการสร้างตัวจำแนก

3.3.2 การสร้างตัวจำแนกด้วยวิธีการเรียนรู้เชิงลึก

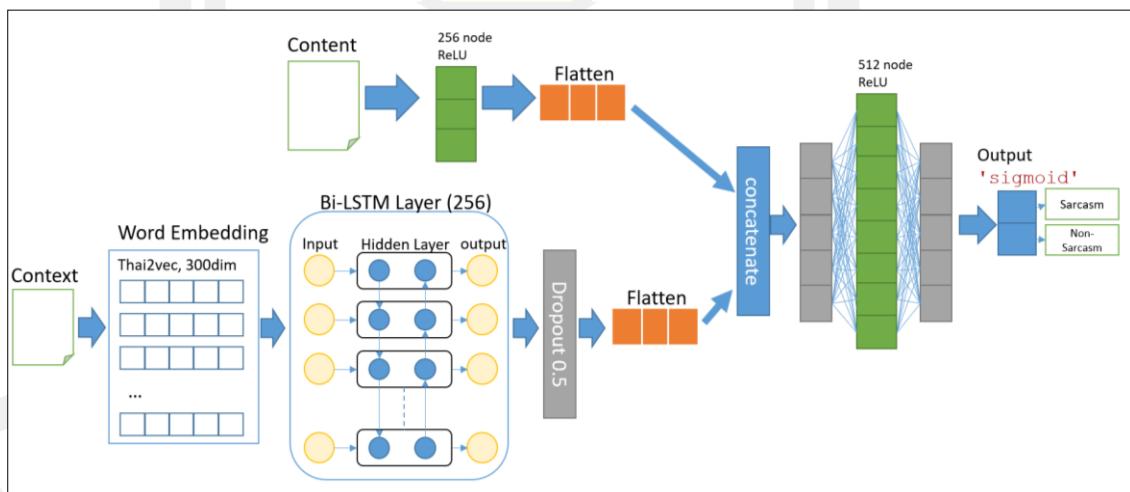
จากการศึกษางานวิจัยที่เกี่ยวข้อง [32, 33, 68] ทำให้ทราบถึงความนิยมในการเลือกใช้ตัวจำแนกด้วยเทคนิควิธีการเรียนรู้เชิงลึก ใน การวิจัยนี้ผู้วิจัยเลือกใช้อัลกอริทึม 2 อย่างคือ Deep Neural Network และ Long Short-Term Memory ซึ่งในอัลกอริทึมแต่ละตัวเลือกใช้พารามิเตอร์ในการจำแนกของแต่ละวิธีดังนี้

1. ขั้นตอนวิธี Deep Neural Network (DNN) ปรับค่าพารามิเตอร์ในการเรียนรู้ดังนี้ Dense = 512, Activation Function = ReLU, Dropout = 0.2, Output Activation = Sigmoid, loss Function = binary_crossentropy และกำหนด Optimizer = adam



รูปที่ 10 แสดงแผนภาพโมเดล DNN

- ขั้นตอนวิธี Long Short-Term Memory (BiLSTM) ปรับค่าพารามิเตอร์ในการเรียนรู้ดังนี้ เลือกใช้การเรียนรู้ Bidirectional LSTM จำนวน 256 node, Activation Function = ReLU, Dropout = 0.2, Output Activation = Sigmoid, loss Function = binary_crossentropy และกำหนด Optimizer = adam



รูปที่ 11 แสดงแผนภาพโมเดล Bi-LSTM

3.4 การวัดประสิทธิภาพ

ขั้นตอนในการวัดประสิทธิภาพการจำแนก เป็นขั้นตอนในการประเมินความสามารถในการจำแนกข้อมูลของตัวจำแนก งานวิจัยนี้ พิจารณาใช้ค่า ความถูกต้อง ความแม่นยำ ค่าความระลึก และค่าประสิทธิภาพโดยรวม ใช้ 10-fold cross validation ในการแบ่งชุดข้อมูลการเรียนรู้ (Training set) และชุดข้อมูลการทดสอบ (Testing set) ซึ่งจะแบ่งข้อมูลออกเป็น 10 ชุดข้อมูลในจำนวนเท่าๆ

กัน และจะทำการประเมินประสิทธิภาพแต่ละรอบ ในรอบที่ 1 ข้อมูลชุดที่ 1 จะถูกนำมาใช้เป็นข้อมูลชุดทดสอบเพื่อวัดประสิทธิภาพของตัวจำแนก ข้อมูลชุดที่ 2 ถึง 10 จะถูกนำมาเป็นชุดข้อมูลการเรียนรู้ ในรอบที่ 2 ข้อมูลชุดที่ 2 จะถูกนำมาใช้เป็นข้อมูลชุดทดสอบ และข้อมูลชุดที่ 6 และ ข้อมูลชุดที่ 3 ถึง 10 จะถูกนำมาเป็นข้อมูลชุดการเรียนรู้ และในแต่ละรอบจะทำการวัดประสิทธิภาพ ดังนี้ โดยพิจารณาจากตาราง Confusion Matrix ดังตารางที่ 21

ตารางที่ 21 Confusion Matrix

		Predicted	
		Sarcasm	Non-Sarcasm
Actual	Sarcasm	a	b
	Non-Sarcasm	c	d

- เมื่อ a คือ จำนวนข้อมูลที่ทำนายถูกว่าเป็นข้อความประชดประชัน
 b คือ จำนวนข้อมูลที่ทำนายว่าไม่เป็นข้อความประชดประชัน แต่คำตอบคือ เป็นข้อความประชดประชัน
 c คือ จำนวนข้อมูลที่ทำนายว่าเป็นข้อความประชดประชัน แต่คำตอบคือ ไม่เป็นข้อความประชดประชัน
 d คือ จำนวนข้อมูลที่ทำนายถูกว่าไม่เป็นข้อความประชดประชัน

1. การวัดค่าความถูกต้องในการจำแนกโดยรวม (Accuracy) ในการจำแนกข้อความประชดประชัน และไม่ประชดประชัน ซึ่งสามารถคำนวณได้ดังสมการที่ (22)

$$Accuracy = \frac{(a + d)}{(a + b + c + d)} \quad (22)$$

2. การวัดค่าความแม่นยำ (Precision) ในการจำแนกข้อความประชดประชัน ซึ่งสามารถคำนวณได้ดังสมการที่ (23)

$$Precision_{sarcasm} = \frac{a}{(a + c)} \quad (23)$$

3. การวัดค่าความแม่นยำ ในการจำแนกข้อความไม่ประชดประชัน ซึ่งสามารถคำนวณได้ดังสมการที่ (24)

$$Precision_{non-sarcasm} = \frac{d}{(b + d)} \quad (24)$$

4. การวัดค่าความระลึก (Recall) ในการจำแนกข้อความประชดประชัน ซึ่งสามารถคำนวณได้ดังสมการที่ (25)

$$\text{Recall}_{\text{sarcasm}} = \frac{a}{(a + b)} \quad (25)$$

5. การวัดค่าความระลึก (Recall) ในการจำแนกข้อความไม่ประชดประชัน ซึ่งสามารถคำนวณได้ดังสมการที่ (26)

$$\text{Recall}_{\text{non-sarcasm}} = \frac{d}{(c + d)} \quad (26)$$

6. การวัดค่าเฉลี่ยประสิทธิภาพโดยรวม (F-measure) เป็นการพิจารณานำเอาค่าความระลึกและค่าความแม่นยำของคลาสประชดประชันและไม่ประชดประชัน มาพิจารณาร่วมกัน ระบบที่มีประสิทธิภาพจะต้องมีค่าความแม่นยำและค่าความระลึกสูงใกล้เคียงกัน ดังสมการที่ (27) และ (28) ตามลำดับ

$$F - \text{measure}_{\text{sarcasm}} = 2 \times \frac{\text{Precision}_{\text{sarcasm}} \times \text{Recall}_{\text{sarcasm}}}{\text{Precision}_{\text{sarcasm}} + \text{Recall}_{\text{sarcasm}}} \quad (27)$$

$$F - \text{measure}_{\text{non-sarcasm}} = 2 \times \frac{\text{Precision}_{\text{non-sarcasm}} \times \text{Recall}_{\text{non-sarcasm}}}{\text{Precision}_{\text{non-sarcasm}} + \text{Recall}_{\text{non-sarcasm}}} \quad (28)$$

บทที่ 4

ผลการวิจัยและการอภิปรายผล

การทดลองการวิจัยนี้ เป็นการทดลองการใช้การสกัดคุณลักษณะจากบริบทในข้อความ และคุณลักษณะจากเนื้อหาในข้อความ การให้ค่าน้ำหนักคุณลักษณะจากบริบทในข้อความด้วย Boolean weighting TF Weighting TF-IDF Weighting และ Word Embedding ซึ่งทำการทดลอง 3 รูปแบบ คือ 1) ทดลองด้วยคุณลักษณะจากบริบทในข้อความอย่างเดียว 2) ทดลองด้วยคุณลักษณะจากเนื้อหาในข้อความอย่างเดียว และ 3) ทดลองด้วยการการรวมคุณลักษณะระหว่างบริบทในข้อความและเนื้อหาในข้อความ และเปรียบเทียบด้วยเทคนิคการเรียนรู้ของเครื่องแบบมีผู้สอน 4 เทคนิคคือ 1) อัลกอริทึมชั้พพอร์ทเวอร์เตอร์แมคชีน 2) อัลกอริทึมนาอีฟเบย์ 3) อัลกอริทึมเพื่อนบ้านใกล้ที่สุด 4) อัลกอริทึมตันไม้ตัดสินใจ และเทคนิคการเรียนรู้เชิงลึกใช้การเรียนรู้ 2 อัลกอริทึมคือ 1) DNN และ 2) BiLSTM ซึ่งแสดงผลการทดลอง ได้ดังนี้

4.1 เครื่องมือและข้อมูลที่ใช้ในการทดลอง

4.1.1 เครื่องมือที่ใช้ในการทดลอง

เครื่องมือที่ใช้ในการทดลองในการวิจัย ได้แก่ ด้านハードแวร์ ประกอบด้วย เครื่องคอมพิวเตอร์แบบพกพา Apple MacBook Pro 16-inch, 2019 ซีพียู 2.3 GHz 8-Core Intel Core i9 แรม 16 GB ด้านซอฟต์แวร์และภาษาที่ใช้ในการเขียนการทดลอง ได้แก่ ระบบปฏิบัติการ macOS Monterey 12.1.1 64-bit พัฒนาซอฟต์แวร์โดยใช้ภาษาไพธอน (Python) บนบริการระบบคลาวด์ของบริษัท Google (Google Colaboratory Pro) และใช้ Library ด้าน Machine Learning ได้แก่ Tensorflow เวอร์ชัน 2.8.0

4.1.2 ผลการรวมข้อมูลในการทดลอง

การรวมข้อมูลผู้วิจัยรวมข้อมูลที่ใช้ในการวิจัยนี้จากเครือข่ายสังคมออนไลน์เฟสบุ๊คจำนวน 1 ชุดข้อมูล ข้อมูลทั้งหมดถูกรวบรวมด้วยการใช้คำค้นด้วยแฮชแท็กจำนวนทั้งหมด 10,800 ข้อความ โดยแบ่งเป็นข้อความ 1) ข้อความประชดประชัน ใช้แฮชแท็ก #ประชด และ #ประชดประชัน จำนวนข้อมูล 5,400 ข้อความ และ 2) ข้อความไม่ประชดประชัน ใช้แฮชแท็ก #สิ่งดีดี, #คิดดี, มีสุข, ความสุข, #โชคดีจัง จำนวนข้อมูล 5,400 ข้อความ จำนวนข้อมูลทั้งหมดที่ใช้ในการทดลองแสดงตารางที่ 22

ตารางที่ 22 ลักษณะข้อมูลที่ในในงานวิจัย

ข้อมูล	จำนวนข้อความ
ข้อความประชดประชัน	5,400

ตารางที่ 22 ลักษณะข้อมูลที่ในงานวิจัย (ต่อ)

ข้อความไม่ประชดประชัน	5,400
ความยาวต่ำสุดของข้อความ (คำ)	2
ความยาวสูงสุดของข้อความ (คำ)	252
ความยาวเฉลี่ยของข้อความ (คำ)	16

4.2 ผลการทดลองจำแนกข้อมูลจากบริบทในข้อความ

งานวิจัยนี้ได้ทำการคัดเลือกจำนวนข้อความที่เป็นข้อความประชดประชันทั้งหมด 5,400 รายการและไม่ประชดประชันทั้งหมด 5,400 ข้อความ จากข้อความบนเฟสบุ๊คโดยใช้แฮชแท็ก #ประชด และ #ประชดประชัน และข้อความไม่ประชดประชันจากข้อความบนเฟสบุ๊คโดยใช้แฮชแท็ก #สิงดีดี #คิดดี #มีสุข #ความสุข #โชคดีจัง เมื่อได้ชุดข้อมูลแล้วทำการทดสอบข้อมูลและทำการตัดข้อมูลด้วยวิธีการตัดคำ และแปลงข้อมูลให้อยู่ในรูปแบบเวกเตอร์จะได้เวกเตอร์ที่มีคุณลักษณะจำนวน 12,973 คุณลักษณะ โดยในชุดข้อมูลมีจำนวนคำที่น้อยที่สุดคือ 2 คำ และจำนวนคำที่มากที่สุดคือ 252 คำ จากนั้นกำหนดค่าคุณลักษณะแต่ละคุณลักษณะโดยทำการคำนวณค่าน้ำหนักของคุณลักษณะด้วยวิธีการ 4 วิธี คือ Boolean weighting, TF weighting, TF-IDF weighting และ Word Embedding จากนั้นการทดลองจำแนกข้อมูลกับชุดข้อมูลกับตัวจำแนกที่สร้างขึ้นด้วย 1) เทคนิคการเรียนรู้ของเครื่องโดยใช้อัลกอริทึม ชัพพร์ทเวกเตอร์แมคชีน, นาอิฟเบย์, ตันไม้ตัดสินใจ และ เพื่อนบ้านใกล้เคียงที่สุด 2) เทคนิคการเรียนรู้เชิงลึกด้วย DNN และ BiLSTM และทำการวัดประสิทธิภาพโดยใช้ 10-fold cross validation ในการแบ่งข้อมูลเรียนรู้และทดสอบ และวัดค่าความถูกต้องเฉลี่ยค่าความแม่นยำเฉลี่ย ค่าระลึกเฉลี่ย ค่าอัตราการเรียนรู้เฉลี่ยสำหรับแต่ละคลาส และเวลาในการประมวลผล ซึ่งผลการทดลองแสดงได้ดังนี้

4.2.1 การทดลองเปรียบเทียบ Remove Stop Words และ ไม่ Remove Stop Words

การทดลองเปรียบเทียบการลบคำที่ไม่สำคัญออกและการไม่ลบคำไม่สำคัญออก ซึ่งโดยปกติแล้วการลบคำที่ไม่สำคัญออกนั้นทำให้คุณลักษณะของข้อมูลลดลง ช่วยทำให้การประมวลผลเร็วขึ้น และให้ประสิทธิภาพในการทดลองไม่แตกต่างจากเดิม จากการทดลองนี้แสดงผลการทดลองด้วยเทคนิคการเรียนรู้ของเครื่อง โดยการใช้คุณลักษณะจากบริบทในข้อความ ด้วยการวัดค่าน้ำหนักด้วยวิธี Boolean Weighting เพื่อแสดงการทดลองการลบคำที่สำคัญและการไม่ลบคำที่ไม่สำคัญจากการทดลองแสดงให้เห็นว่าการไม่ลบคำสำคัญออกทำให้ได้ค่าความถูกต้องในการทดลองมากขึ้นเกือบทุกเทคนิค มีเพียงเทคนิค KNN เท่านั้นที่การลบคำสำคัญให้ค่าความถูกต้องมากกว่าการไม่ลบคำสำคัญ

ผลการทดลองดังแสดงในตารางที่ 23 ดังนั้นในการทดลองในการวิจัยนี้จึงเลือกใช้การไม่ลบคำสำคัญออก

ตารางที่ 23 การทดลองเปรียบเทียบการ Remove Stop Words และ ไม่ Remove Stop Words

Accuracy	Precision		Recall		F-measure	
	Sarcasm	Non-Sarcasm	Sarcasm	Non-Sarcasm	Sarcasm	Non-Sarcasm
With Stop words						
KNN	71.72	97.86	45.59	64.26	95.54	77.56
SVM	89.31	92.95	85.68	86.66	92.39	89.69
Decision-Tree	84.94	89.92	79.96	81.78	88.82	85.65
Naïve Bayes	86.38	85.58	87.19	87.02	85.77	86.28
DNN	89.38	89.27	89.49	89.27	89.49	89.49
LSTM	92.96	90.98	87.83	88.18	90.75	89.55
Remove Stop words						
KNN	75.78	86.70	64.83	71.16	83.03	78.14
SVM	86.64	90.60	82.71	83.95	89.76	87.14
Decision-Tree	82.44	87.19	77.71	79.61	85.86	83.21
Naïve Bayes	85.91	84.43	87.47	87.04	84.86	85.69
DNN	87.81	88.90	86.74	86.78	88.86	87.83
LSTM	91.39	90.45	89.58	89.70	90.38	90.03

4.2.2 การทดลองการกำหนดจำนวน K ที่สุดสำหรับ KNN

จากการเลือกใช้เทคนิค KNN การสร้างแบบจำลองด้วยการเรียนรู้ของเครื่อง เพื่อหาจำนวน K ที่เหมาะสมที่สุด จึงทดลองเปรียบเทียบจำนวนการเลือกใช้ K เท่ากับ 3, 5, 7 และ 9 โดยการใช้คุณลักษณะจากบริบทในข้อความ ด้วยการวัดค่าน้ำหนักด้วยวิธี Boolean Weighting ดังตารางที่ 24 จากผลการทดลองแสดงให้เห็นว่าจำนวน K ที่ให้ความถูกต้องมากที่สุดคือ K เท่ากับ 5 ดังนั้นในการวิจัยนี้จึงเลือกใช้จำนวน K = 5 กับการทดลองสำหรับ KNN

ตารางที่ 24 ผลการทดลองเปรียบเทียบการเลือกใช้จำนวน K สำหรับเทคนิค KNN

Accuracy	Precision		Recall		F-measure		times
	Sarcasm	Non-Sarcasm	Sarcasm	Non-Sarcasm	Sarcasm	Non-Sarcasm	
KNN=3	71.58	98.60	44.58	64.02	96.96	77.61	61.02
KNN=5	71.72	97.86	45.59	64.26	95.54	77.56	61.68
KNN=7	69.40	98.70	40.11	62.23	96.87	76.31	56.70
KNN=9	67.47	99.02	35.92	60.71	97.36	75.26	52.43

4.2.3 ผลการทดลองด้วยคุณลักษณะ Boolean Weighting

จากการทดลองในตารางที่ 25 จะเห็นได้ว่าขั้นตอนวิธี LSTM ให้ค่าความถูกต้องมากที่สุด โดยให้ค่าความถูกต้อง 91.39% ด้วยค่า $std = 0.03$ นอกจากนี้ยังให้ค่าระลึกดีที่สุดในการทำนายข้อความประชดประชัน โดยให้ค่าระลึกเท่ากับ 89.70% ส่วน KNN ให้ค่าความแม่นยำดีที่สุดในการทำนายข้อความประชดประชัน โดยให้ค่าความแม่นยำในการทำนายข้อความประชดประชันถึง 97.67% แต่เมื่อพิจารณาค่า F-measure จะเห็นได้ว่า LSTM ให้ค่า F-measure สูงสุด คือ 89.94% ส่วนขั้นตอนวิธี Naïve bayes ใช้เวลาในการประมวลผลน้อยที่สุด กล่าวโดยสรุปขั้นตอนวิธี LSTM ให้ประสิทธิภาพโดยรวมในการทำนายดีที่สุด เมื่อสกัดคุณลักษณะแบบ Boolean weighting แต่อย่างไรก็ LSTM ใช้เวลาในการประมวลผลมากที่สุดเป็นอันดับที่ 4 ซึ่งโดยคุณลักษณะการทำงานของโมเดล Bi-LSTM ที่มีการทำงานที่เหมาะสมในการคำนวณค่าแบบต่อเนื่อง ซึ่งเหมาะสมกับการทำงานกับข้อมูลรูปแบบข้อความ อีกทั้งยังมีการคำนวณค่าแบบสองทิศทางทำให้เรียนรู้รูปแบบข้อความได้ดี จึงทำให้ประสิทธิภาพโดยรวมในการทำงานให้ผลดีที่สุด

ตารางที่ 25 ผลการทดลองด้วยคุณลักษณะ Boolean Weighting

Accuracy	Precision		Recall		F-measure		times	STD	
	Sarcasm	Non-Sarcasm	Sarcasm	Non-Sarcasm	Sarcasm	Non-Sarcasm			
KNN	69.07	97.67	44.26	63.67	94.97	77.08	60.36	49.99	0.01
SVM	84.44	85.90	82.78	83.33	85.42	84.59	84.07	3145.48	0.01
Decision-Tree	77.50	79.99	77.23	77.83	79.43	78.88	78.30	537.39	0.01
Naïve Bayes	84.07	82.83	86.61	86.14	83.44	84.44	84.98	22.33	0.01
DNN	85.65	84.20	87.09	86.82	84.57	85.47	85.79	653.88	0.01
LSTM	91.39	90.45	89.58	89.70	90.38	90.03	89.94	132.60	0.03

4.2.4 ผลการทดลองด้วยคุณลักษณะ TF Weighting

จากการทดลองในตารางที่ 26 จากการสกัดคุณลักษณะแบบ TF Weighting จะเห็นได้ว่า ขั้นตอนวิธี LSTM ให้ค่าความถูกต้องมากที่สุด โดยให้ค่าความถูกต้องเท่ากับ 93.61% ด้วยค่า SD เท่ากับ 0.05 นอกจากนี้ยังคงให้ค่าความระลึกมากที่สุดในการทำนายข้อความประชดประชัน ซึ่งให้ค่าระลึกเท่ากับ 91.31% และเมื่อพิจารณาค่า F-measure จะเห็นได้ว่า LSTM ให้ค่า F-measure สูงสุดคือ 90.43% ทั้งนี้ขั้นตอนวิธี Naïve Bayes ยังคงใช้เวลาในการประมวลผลน้อยที่สุด จากการใช้คุณลักษณะที่สกัดแบบ TF Weighting แต่อย่างไรก็ตาม LSTM ใช้เวลาในการประมวลผลมากที่สุด เป็นอันดับที่ 3

ตารางที่ 26 ผลการทดลองด้วยคุณลักษณะ TF Weighting

Accuracy	Precision		Recall		F-measure		times	STD	
	Sarcasm	Non-Sarcasm	Sarcasm	Non-Sarcasm	Sarcasm	Non-Sarcasm			
KNN	71.85	96.51	49.36	65.59	93.43	78.09	64.55	50.52	0.01
SVM	83.24	85.53	83.17	83.60	85.15	84.54	84.14	3206.56	0.01
Decision-Tree	77.04	80.76	77.41	78.13	80.10	79.41	78.72	488.22	0.02
Naïve Bayes	83.52	83.26	85.39	85.10	83.59	84.16	84.47	22.03	0.01
DNN	86.11	85.75	86.89	86.77	85.92	86.23	86.38	99.24	0.01
LSTM	93.61	89.60	91.69	91.31	90.11	90.43	90.87	125.28	0.05

4.2.5 ผลการทดลองด้วยคุณลักษณะ TF-IDF Weighting

จากผลการทดลองในตารางที่ 27 จากการสกัดคุณลักษณะแบบ TF Weighting จะเห็นได้ว่า ขั้นตอนวิธี LSTM ให้ค่าความถูกต้องมากที่สุด โดยให้ค่าความถูกต้องเท่ากับ 93.61% ด้วยค่า SD เท่ากับ 0.04 นอกจากนี้ยังคงให้ค่าความถูกต้องมากที่สุดในการทำนายข้อความประชดประชัน ซึ่งให้ค่าระลีกเท่ากับ 89.91% และเมื่อพิจารณาค่า F-measure จะเห็นได้ว่า LSTM ให้ค่า F-measure สูงสุดคือ 92.48% ทั้งนี้ขั้นตอนวิธี Naive Bayes ยังคงใช้เวลาในการประมวลผลน้อยที่สุด จากการใช้คุณลักษณะที่สกัดแบบ TF-IDF Weighting แต่อย่างไรก็ตาม LSTM ใช้เวลาในการประมวลผลมากที่สุดเป็นอันดับที่ 3

ตารางที่ 27 ผลการทดลองด้วยคุณลักษณะ TF-IDF Weighting

Accuracy	Precision		Recall		F-measure		times	STD	
	Sarcasm	Non-Sarcasm	Sarcasm	Non-Sarcasm	Sarcasm	Non-Sarcasm			
KNN	71.57	95.96	47.28	64.56	92.24	77.18	62.46	48.85	0.02
SVM	84.81	89.16	82.61	83.71	88.37	86.34	85.38	3563.93	0.01
Decision-Tree	74.63	78.88	76.94	77.39	78.43	78.12	77.67	594.39	0.02
Naïve Bayes	83.61	78.10	89.13	87.79	80.28	82.65	84.46	14.52	0.01
DNN	84.44	86.31	85.30	85.51	86.20	85.87	85.70	87.16	0.01
LSTM	93.61	95.22	89.31	89.91	95.01	92.48	92.06	125.36	0.04

4.2.4 ผลการทดลองด้วยคุณลักษณะ Word Embedding

จากผลการทดลองในตารางที่ 28 จากการสกัดคุณลักษณะแบบ Word Embedding ซึ่งทดลองกับเทคนิค LSTM จะเห็นได้ว่าให้ค่าความถูกต้องเท่ากับ 91.39% ด้วยค่า SD เท่ากับ 0.03 และให้ค่าความแม่นยำในการทำนายข้อความประชดประชันได้เท่ากับ 90.45% เมื่อเปรียบเทียบการ

ใช้คุณลักษณะ Boolean, TF, TF-IDF Weighting ในเทคนิคเว็บ LSTM ให้ค่าประสิทธิภาพโดยรวม F-measure อยู่ในอันดับที่ 3 ซึ่งเท่ากับวิธี Boolean Weighting เท่ากับ 90.03% และใช้เวลาในการประมวลผลเท่ากัน

ตารางที่ 28 ผลการทดลองด้วยคุณลักษณะ Word Embedding

Accuracy	Precision		Recall		F-measure		times	STD	
	Sarcasm	Non-Sarcasm	Sarcasm	Non-Sarcasm	Sarcasm	Non-Sarcasm			
LSTM	91.39	90.45	89.58	89.70	90.38	90.03	89.94	132.60	0.03

จากผลการทดลองด้วยคุณลักษณะของข้อมูลจากบริบทในข้อความ โดยการสกัดคุณลักษณะทั้ง 4 แบบจากตารางที่ 26 ตารางที่ 27 และตารางที่ 28 สรุปผลการทดลองได้ว่าวิธีที่ให้ค่าความถูกต้องในการทำนายคือคุณลักษณะที่สกัดด้วย TF และ TF-IDF ซึ่งให้ค่าความถูกต้องเท่ากันคือ 93.61% แต่ทั้งนี้คุณลักษณะ TF-IDF ให้ค่าความแม่นยำในการทำนายข้อความประชดประชนมากกว่าเท่ากับ 95.22% และให้ประสิทธิภาพโดยรวมมากที่สุด ซึ่งขั้นตอนวิธีที่ให้ประสิทธิภาพสูงที่สุดคือเทคนิคเว็บ LSTM ในทุกคุณลักษณะ

4.3 ผลการทดลองจำแนกข้อมูลจากเนื้อหาในข้อความ

การทดลองโดยการใช้คุณลักษณะจากเนื้อหาในข้อความ ซึ่งประกอบด้วย การมีข้อความที่แสดงอารมณ์เชิงบวก การมีข้อความที่แสดงอารมณ์เชิงลบ การใช้คำที่ไม่ปึกเตี้ย จำนวนของการใช้ปรัศนี จำนวนของการแสดงคำหัวเราะ การมีคำที่แสดงถึงการประชดประชนโดยทั่วไป จำนวนของการใช้เครื่องหมายอักเจริญ จำนวนของการใช้มหัพภาคิณ จำนวนของคำหยาบคาย จำนวนของการใช้บุพสัญญา จำนวนของการใช้เมี้ยมก ไอคอนแสดงอารมณ์เชิงบวก ไอคอนแสดงอารมณ์เชิงลบ จำนวนของการใช้เครื่องหมายบวก และจำนวนของการใช้เครื่องหมายลบ ด้วยเทคนิคการเรียนรู้ของเครื่อง และ ด้วยเทคนิคการเรียนรู้เชิงลึก โดยแสดงผลการทดลองดังในตารางที่ 29 จะเห็นได้ว่าขั้นตอนวิธี DNN ให้ค่าความถูกต้องมากที่สุด โดยให้ค่าความถูกต้องเท่ากับ 80.86% ด้วยค่า SD เท่ากับ 0.02 และให้ค่าประสิทธิภาพโดยรวมเป็นอันดับที่ 2 เท่ากับ 78.78% แต่อย่างไรก็ตาม DNN ใช้เวลาในการประมวลผลมากที่สุดเป็นอันดับที่ 2 ส่วนขั้นตอนวิธี Decision Tree ใช้เวลาในการประมวลผลน้อยที่สุด

ตารางที่ 29 ผลการทดลองจำแนกข้อมูลจากเนื้อหาในข้อความ

Accuracy	Precision		Recall		F-measure		times	STD	
	Sarcasm	Non-Sarcasm	Sarcasm	Non-Sarcasm	Sarcasm	Non-Sarcasm			
KNN	49.17	99.89	0.23	50.03	43.81	66.65	0.45	1.37	0.02
SVM	80.00	72.09	88.98	86.72	76.13	78.71	82.03	13.06	0.01

ตารางที่ 29 ผลการทดลองจำแนกข้อมูลจากเนื้อหาในข้อความ (ต่อ)

Decision-Tree	80.00	72.04	89.01	86.75	76.10	78.69	82.03	0.20	0.01
Naïve Bayes	78.15	57.66	97.57	96.01	69.73	71.93	81.27	0.21	0.01
DNN	80.86	71.80	89.74	87.26	76.47	78.78	82.57	76.18	0.02
LSTM	80.37	80.67	81.56	81.46	80.91	80.99	81.16	7550.22	0.01

4.4 ผลการทดลองจำแนกข้อมูลจากบริบทในข้อความและเนื้อหาในข้อความ

การทดลองโดยการใช้คุณลักษณะจากบริบทในข้อความรวมกับคุณลักษณะจากเนื้อหาในข้อความ ด้วยการวัดค่า f_{α} 4 แบบคือ 1) Boolean Weighting 2) TF Weighting 3) TF-IDF Weighting และ 4) Word Embedding ด้วยเทคนิคการเรียนรู้ของเครื่องและด้วยเทคนิคการเรียนรู้เชิงลึก โดยคุณลักษณะจากบริบทในข้อความนั้นเป็นคำที่สกัดได้จากชุดข้อความ และคุณลักษณะจากเนื้อหาในข้อความสกัดได้จากชุดข้อความซึ่งประกอบด้วย การมีข้อความที่แสดงอารมณ์เชิงบวก การมีข้อความที่แสดงอารมณ์เชิงลบ การใช้คำที่ไม่ปกติ จำนวนของการใช้ปรัศนี จำนวนของการแสดงคำหัวเราะ การมีคำที่แสดงถึงการประชดประชันโดยหัวไป จำนวนของการใช้เครื่องหมายอักเจริญ จำนวนของการใช้มหัพภาค จำนวนของคำหยาบคาย จำนวนของการใช้บุพสัญญา จำนวนของการใช้ไม้ยอก ไอคอนแสดงอารมณ์เชิงบวก ไอคอนแสดงอารมณ์เชิงลบ จำนวนของการใช้เครื่องหมายบวก และจำนวนของการใช้เครื่องหมายลบ ผลการทดลองการรวมคุณลักษณะจากบริบทในข้อความและคุณลักษณะจากเนื้อหาในข้อความ สรุปผลการทดลองได้ดังนี้

4.4.1 ผลการทดลองด้วยคุณลักษณะ Boolean Weighting + Content

การทดลองโดยการใช้คุณลักษณะจากบริบทในข้อความรวมกับคุณลักษณะจากเนื้อหา โดยการให้ค่า f_{α} ด้วยวิธี Boolean weighting ดังแสดงในตารางที่ 30 จะเห็นได้ว่าขั้นตอนวิธี LSTM ให้ค่าความถูกต้องมากที่สุด โดยให้ค่าความถูกต้อง 95.46% ด้วยค่า $\text{std} = 0.04$ นอกจากนี้ยังให้ค่าระลึกดีที่สุดในการทำนายข้อความประชดประชัน โดยให้ค่าระลึกเท่ากับ 92.44% ส่วน KNN ให้ค่าความแม่นยำที่สุดในการทำนายข้อความประชดประชัน โดยให้ค่าความแม่นยำในการทำนายข้อความประชดประชันถึง 92.77% แต่เมื่อพิจารณาค่า F-measure จะเห็นได้ว่า LSTM ให้ค่า F-measure สูงสุด คือ 91.42% ส่วนขั้นตอนวิธี KNN ใช้เวลาในการประมวลผลน้อยที่สุด อย่างไรก็ตาม ขั้นตอนวิธี LSTM ใช้เวลาในการประมวลผลมากที่สุดเป็นลำดับที่ 3

ตารางที่ 30 ผลการทดลองด้วยคุณลักษณะ Boolean Weighting + Content Feature

	Accuracy	Precision		Recall		F-measure		times	STD
		Sarcasm	Non-Sarcasm	Sarcasm	Non-Sarcasm	Sarcasm	Non-Sarcasm		
KNN	77.59	92.77	64.63	77.45	89.94	81.34	75.16	37.22	0.02

ตารางที่ 30 ผลการทดลองด้วยคุณลักษณะ Boolean Weighting + Content Feature (ต่อ)

SVM	87.87	87.69	87.43	87.48	87.63	87.58	87.52	1902.80	0.01
Decision-Tree	81.67	84.06	83.32	83.46	83.93	83.75	83.62	306.79	0.01
Naïve Bayes	88.06	88.11	89.37	89.27	88.38	88.68	88.81	44.22	0.01
DNN	89.81	88.66	89.20	89.14	88.69	88.89	88.94	111.92	0.01
LSTM	95.46	90.47	92.63	92.44	90.74	91.42	91.66	144.64	0.04

4.4.2 ผลการทดลองด้วยคุณลักษณะ TF Weighting + Content

การทดลองโดยการใช้คุณลักษณะจากบริบทในข้อความรวมกับคุณลักษณะจากเนื้อหา โดยการให้ค่าน้ำหนักด้วยวิธี TF weighting ดังแสดงในตารางที่ 31 จะเห็นได้ว่าขั้นตอนวิธี LSTM ให้ค่าความถูกต้องมากที่สุด โดยให้ค่าความถูกต้อง 95.37% ด้วยค่า std = 0.03 นอกจากนี้ยังให้ค่าระลึกดีที่สุดในการทำนายข้อความประชดประชัน โดยให้ค่าระลึกเท่ากับ 94.08% ส่วน KNN ให้ค่าความแม่นยำดีที่สุดในการทำนายข้อความประชดประชัน โดยให้ค่าความแม่นยำในการทำนายข้อความประชดประชันถึง 95.28% แต่เมื่อพิจารณาค่า F-measure จะเห็นได้ว่า LSTM ให้ค่า F-measure สูงสุด คือ 93.15% ส่วนขั้นตอนวิธี Naïve Bayes ใช้เวลาในการประมวลผลน้อยที่สุด อย่างไรก็ตาม ขั้นตอนวิธี LSTM ใช้เวลาในการประมวลผลมากที่สุดเป็นลำดับที่ 2

ตารางที่ 31 ผลการทดลองด้วยคุณลักษณะ TF Weighting + Content Feature

Accuracy	Precision		Recall		F-measure		times	STD	
	Sarcasm	Non-Sarcasm	Sarcasm	Non-Sarcasm	Sarcasm	Non-Sarcasm			
KNN	76.11	95.28	58.08	69.49	92.58	80.34	71.29	70.04	0.01
SVM	87.22	87.59	86.29	86.49	87.43	87.02	86.84	4242.45	001
Decision-Tree	82.68	83.76	83.48	83.53	83.71	83.64	83.59	730.66	0.01
Naïve Bayes	87.31	88.78	87.46	87.66	88.62	88.21	88.03	51.67	0.01
DNN	89.81	88.32	90.26	90.08	88.55	89.18	89.38	107.86	0.01
LSTM	95.37	92.27	94.29	94.08	92.54	93.15	93.39	146.56	0.03

4.4.3 ผลการทดลองด้วยคุณลักษณะ TF-IDF Weighting + Content

การทดลองโดยการใช้คุณลักษณะจากบริบทในข้อความรวมกับคุณลักษณะจากเนื้อหา โดยการให้ค่าน้ำหนักด้วยวิธี TF weighting ดังแสดงในตารางที่ 32 จะเห็นได้ว่าขั้นตอนวิธี LSTM ให้ค่าความถูกต้องมากที่สุด โดยให้ค่าความถูกต้อง 96.67% ด้วยค่า std = 0.05 นอกจากนี้ยังให้ค่าระลึกดีที่สุดในการทำนายข้อความประชดประชัน โดยให้ค่าระลึกเท่ากับ 92.05% และยังให้ค่าความแม่นยำดีที่สุดในการทำนายข้อความประชดประชัน โดยให้ค่าความแม่นยำในการทำนายข้อความประชด

ประชันถึง 93.91% แต่เมื่อพิจารณาค่า F-measure จะเห็นได้ว่า LSTM ให้ค่า F-measure สูงสุด คือ 92.96% ส่วนขั้นตอนวิธี Naïve Bayes ใช้เวลาในการประมวลผลน้อยที่สุด อย่างไรก็ตามขั้นตอนวิธี LSTM ใช้เวลาในการประมวลผลมากที่สุดเป็นลำดับที่ 2

ตารางที่ 32 ผลการทดลองด้วยคุณลักษณะ TF Weighting + Content Feature

	Accuracy	Precision		Recall		F-measure		times	STD
		Sarcasm	Non-Sarcasm	Sarcasm	Non-Sarcasm	Sarcasm	Non-Sarcasm		
KNN	83.52	77.51	91.06	89.71	80.19	83.14	85.26	33.65	0.02
SVM	88.15	87.61	89.80	89.60	87.85	88.85	88.801	2105.68	0.01
Decision-Tree	81.57	82.75	83.46	83.34	82.88	83.04	83.16	353.71	0.01
Naïve Bayes	88.55	77.17	94.75	93.64	80.58	84.60	87.09	23.05	0.01
DNN	90.00	87.48	89.66	89.48	87.76	88.44	88.67	90.78	0.01
LSTM	96.67	93.91	91.97	92.05	93.90	92.96	92.91	159.02	0.05

4.4.4 ผลการทดลองด้วยคุณลักษณะ Word Embedding + Content

การทดลองโดยการใช้คุณลักษณะจากบริบทในข้อความรวมกับคุณลักษณะจากเนื้อหา โดยการให้ค่าน้ำหนักด้วยวิธี Word Embedding ดังแสดงในตารางที่ 33 ด้วยขั้นตอนวิธี LSTM โดยให้ค่าความถูกต้องมากที่สุดเมื่อเปรียบเทียบกับทุกวิธีที่กล่าวมาข้างต้น ซึ่งมีค่าเท่ากับ 96.79% ด้วยค่า std = 0.01 นอกจากนี้ยังให้ค่ารัฐกิจที่สุดในการทำนายข้อความประชัดประชันมากที่สุด โดยให้ค่ารัฐกิจเท่ากับ 95.08% และเมื่อพิจารณาค่า F-measure จะเห็นได้ว่าให้ค่า F-measure สูงสุด คือ 96.88% และเมื่อพิจารณาผลการทดลองโดยรวมทั้งหมดวิธีนี้ให้ประสิทธิภาพสูงที่สุด

ตารางที่ 33 ผลการทดลองด้วยคุณลักษณะ Word Embedding

	Accuracy	Precision		Recall		F-measure		times	STD
		Sarcasm	Non-Sarcasm	Sarcasm	Non-Sarcasm	Sarcasm	Non-Sarcasm		
LSTM	96.79	98.80	94.72	95.08	98.79	96.88	96.68	802.58	0.01

4.5 ผลการทดลองด้วยคุณลักษณะ Word Embedding ด้วยวิธี Hold out

จากการทดลองสรุปได้ว่าคุณลักษณะที่ดีที่สุดที่ใช้ในการทดลองที่ให้ประสิทธิภาพสูงที่สุดคือ Word Embedding + Content Feature ด้วยขั้นตอนวิธี LSTM ซึ่งใช้วิธีการทดลองในการแบ่งชุดข้อมูลแบบ 10-Fold Cross Validation ดังนั้นการทดลองนี้จึงใช้การทดลองที่ให้ผลลัพธ์ที่สุดมาทำการแบ่งชุดการทดลองเป็นชุดสร้างโมเดล 70% และแบ่งเป็นชุดทดสอบ 30% เพื่อเปรียบเทียบผลการทดลองว่าผลการทดลองด้วย 10-Fold Cross Validation ซึ่งผลการทดลองดังแสดงในตารางที่ 34

ซึ่งผลการทดลองแสดงให้เห็นว่า ค่าความถูกต้องเมื่อเปรียบเทียบกับการทดลองด้วยวิธี 10-Fold ได้ค่าความถูกต้องลดลงจาก 96.79% เป็น 86.33% ดังนั้นจากผลการทดลองที่ลดลงแสดงให้เห็นว่าชุดข้อมูลที่ใช้สร้างโมเดลส่วนมากที่เมื่อนำมาสร้างโมเดลแล้วทำให้สามารถทำนายคลาสได้ดีหรือกล่าวอีกนัยหนึ่งคือชุดข้อมูลสามารถแบ่งแยกแต่ละคลาสได้ยังนั้นเอง การแก้ไขปัญหาจะต้องเก็บข้อมูลเพิ่มมากขึ้น ซึ่งเป็นข้อเสนอแนะเพิ่มเติมในการวิจัยครั้งต่อไป

ตารางที่ 34 ผลการทดลองจำแนกข้อมูลจากบริบทในข้อความและเนื้อหาในข้อความ Word

Embedding ด้วยวิธี Hold out

Accuracy	Precision		Recall		F-measure		times	
	Sarcasm	Non-Sarcasm	Sarcasm	Non-Sarcasm	Sarcasm	Non-Sarcasm		
LSTM	86.60	88.43	84.74	85.50	87.81	86.94	86.25	44.75

จากการทดลองทำให้ทราบว่าการใช้คุณลักษณะจากบริบทในข้อความรวมกับคุณลักษณะจากเนื้อหา ให้ประสิทธิภาพที่ดีกว่าการใช้คุณลักษณะจากบริบทของข้อความอย่างเดียว หรือการใช้คุณลักษณะจากเนื้อหาในข้อความอย่างเดียว เนื่องจากการใช้แค่คุณลักษณะจากบริบทในข้อความไม่สามารถจำแนกข้อความประชดประชันที่เป็นข้อความที่ไม่ใช่ข้อความที่สื่อสารอภิมาแบบข้อความทั่วๆ ไป บางข้อความที่สื่อภิมาไม่มีความหมายตรงกันข้ามกับความหมายที่แท้จริงของผู้สื่อสาร ทำให้การใช้คุณลักษณะจากบริบทในข้อความจำแนกได้ไม่ดี ทั้งนี้การใช้คุณลักษณะจากเนื้อหาในข้อความอย่างเดียวจะสามารถจำแนกข้อความประชดประชันได้ดีเนื่องจากคุณลักษณะจากเนื้อหาในข้อความถูกสกัดจากข้อความที่เป็นข้อความประชดประชันทำให้จำแนกข้อความประชดประชันได้ไม่ดี ดังนั้นการรวมคุณลักษณะทั้งสองแบบจึงเป็นวิธีที่เหมาะสมในการจำแนกข้อความประชดประชัน เนื่องจากมีคุณลักษณะที่เป็นตัวแทนของการเป็นตัวแทนของข้อความประชดประชันที่ดีกว่า จึงทำให้ประสิทธิภาพการจำแนกมีประสิทธิภาพมากขึ้น ทั้งนี้เทคนิคอัลกอริทึมการเรียนรู้ของเครื่องแบบมีผู้สอนที่ให้ประสิทธิภาพสูงที่สุดคือ SVM ส่วนเทคนิคอัลกอริทึมที่ให้ประสิทธิภาพสูงที่สุดและเหมาะสมที่จะนำไปใช้งานมากที่สุดคือการใช้คุณลักษณะจากการแปลงข้อความเป็นเวกเตอร์ด้วย Word Embedding ซึ่งมีข้อดีในการเรียนรู้รูปแบบของข้อความและสามารถวิเคราะห์ความคล้ายคลึงของรูปแบบการเกิดข้อความ และนำมาเรียนรู้ด้วยเทคนิคการเรียนรู้เชิงลึกด้วยอัลกอริทึม Bi-LSTM ซึ่งเป็นการเรียนรู้ข้อความแบบสองทิศทางทำให้เรียนรู้ข้อความรอบข้างได้ใกล้ชิด จึงเหมาะสมมากที่สุดในการนำมาใช้เป็นโมเดลสำหรับการจำแนกข้อความประชดประชันบนเครือข่ายสังคมออนไลน์ภาษาไทยในการวิจัยนี้

บทที่ 5

สรุปผล อภิปรายผล และข้อเสนอแนะ

5.1 สรุปผล

งานวิจัยนี้เป็นการทดลองการตรวจจับข้อความประชดประชันบนเครือข่ายสังคมออนไลน์ ชุดข้อมูลที่ใช้ในการทดลองเป็นการเก็บข้อมูลจากผู้ใช้งานเครือข่ายสังคมออนไลน์เฟสบุ๊ค ซึ่งใช้วิธีการรวบรวมข้อมูลจากเว็บไซต์เฟสบุ๊คโดยการค้นหาจากคำค้นโดยใช้แฮสแท็ก #ประชดประชัน จากนั้นทำการศึกษาคุณลักษณะ 2 แบบเพื่อใช้ในการตรวจสอบข้อความประชดประชัน คุณลักษณะแรกที่ศึกษา คือ คุณลักษณะที่สกัดจากบริบทของข้อความ (Context-based features) ซึ่งเป็นคุณลักษณะที่ใช้คำในข้อความเพื่อเป็นถุงคำของคุณลักษณะ แบบที่สอง คือ คุณลักษณะที่สกัดจากเนื้อหาในข้อความ (Content-based feature) จากนั้นใช้คุณลักษณะแบบแรกและแบบที่สองรวมกันเพื่อใช้เป็นคุณลักษณะในการตรวจจับข้อความประชดประชัน ซึ่งสามารถอภิปรายผลการใช้งานคุณลักษณะทั้งสองแบบได้ดังนี้ 1) คุณลักษณะจากบริบทของข้อความ คุณลักษณะจากบริบทของข้อความใช้หลักการวิธีในการจำแนกข้อความ ซึ่งประกอบด้วยวิธีการดังนี้ 1) การทำความสะอาดข้อความ โดยการตัดข้อความภาษาอังกฤษ ตัวเลข สัญลักษณ์พิเศษต่าง ๆ ออกจากข้อความ 2) การตัดคำภาษาไทย ซึ่งใช้วิธีการตัดคำจากการวิจัย [63, 64] มาใช้ในการตัดคำ 4) การกำหนดค่าหน้าหนักของคุณลักษณะใช้การคำนวณด้วยวิธี Boolean Weighting TF Weighting TF-IDF Weighting และ Word Embedding 2) คุณลักษณะจากเนื้อหาในข้อความ เป็นคุณลักษณะที่ดึงจากองค์ประกอบจากเนื้อหาในข้อความ เช่น การมีข้อความที่แสดงอารมณ์เชิงบวก-ลบ การใช้คำที่ไม่ปกติ การใช้ปรัศน์ การแสดงคำหัวเราะ การมีคำที่แสดงถึงการประชดประชันโดยทั่วไป การใช้เครื่องหมายอัศจรรย์ การใช้มหัพภาค คำหยาบคาย การใช้บุพสัญญา การใช้ไม้ยอก ไอคอนแสดงอารมณ์เชิงบวก-ลบ การใช้เครื่องหมายบวก และการใช้เครื่องหมายลบ ซึ่งได้ผลการศึกษาที่สามารถสรุปได้ ดังนี้

1. คุณลักษณะจากบริบทในข้อความ ซึ่งจากการทดลองในงานวิจัยนี้เลือกใช้คุณลักษณะทั้งหมดที่สกัดได้ แล้วใช้เทคนิควิธีการเรียนรู้ด้วยอัลกอริทึมสองแบบคือ การเรียนรู้ของเครื่อง และการเรียนรู้เชิงลึก ผลการทดลองสำหรับการเรียนรู้จากคุณลักษณะด้วยบริบทในข้อความนั้นได้ค่าความถูกต้องเท่ากับ 93.61% ด้วยคุณลักษณะ TF Weighting ซึ่งเท่ากับ TF-IDF Weighting แต่คุณลักษณะการใช้ค่าน้ำหนักด้วย TF-IDF ให้ประสิทธิภาพโดยรวมมากกว่าคือเท่ากับ 92.48% ด้วยขั้นตอนวิธี LSTM

2. คุณลักษณะจากในข้อความ ซึ่งจากการทดลองในงานวิจัยนี้เลือกใช้คุณลักษณะที่สกัดได้จากเนื้อหาในข้อความซึ่งประกอบด้วย การมีข้อความที่แสดงอารมณ์เชิงบวก การมีข้อความที่แสดงอารมณ์เชิงลบ การใช้คำที่ไม่ปกติ จำนวนของการใช้ปรัศน์ จำนวนของการแสดงคำหัวเราะ การมีคำที่

แสดงถึงการประชดประชันโดยทั่วไป การใช้เครื่องหมายอักเจรี๊ย การใช้มหัพภาค คำหยาบคาย การใช้บุพสัญญา การใช้ไม้ยมก ไอคอนแสดงอารมณ์เชิงบวก ไอคอนแสดงอารมณ์เชิงลบ การใช้เครื่องหมายบวก และการใช้เครื่องหมายลบ และใช้เทคนิคิวีการเรียนรู้ด้วยอัลกอริทึมสองแบบคือ การเรียนรู้ของเครื่อง และการเรียนรู้เชิงลึก ผลการทดลองสำหรับการเรียนรู้จากคุณลักษณะด้วยเนื้อหาในข้อความนั้นได้ค่าความถูกต้องเท่ากับ 80.86% ด้วยวิธีการเทคนิคอัลกอริทึม DNN

3. การรวมกันระหว่างคุณลักษณะบริบทในข้อความและคุณลักษณะจากเนื้อหาในข้อความ โดยการเลือกใช้คุณลักษณะจากบริบทในข้อความเลือกคุณลักษณะที่สกัดได้ทั้งหมด รวมกับคุณลักษณะจากเนื้อหาในข้อความ ซึ่งประกอบด้วย การมีข้อความที่แสดงอารมณ์เชิงบวก การมีข้อความที่แสดงอารมณ์เชิงลบ การใช้คำที่ไม่ปึกติ จำนวนของการใช้ปรัศนี จำนวนของการแสดงคำหัวเราะ การมีคำที่แสดงถึงการประชดประชันโดยทั่วไป จำนวนของการใช้เครื่องหมายอักเจรี๊ย จำนวนของการใช้มหัพภาค จำนวนของคำหยาบคาย จำนวนของการใช้บุพสัญญา จำนวนของการใช้ไม้ยมก ไอคอนแสดงอารมณ์เชิงบวก ไอคอนแสดงอารมณ์เชิงลบ จำนวนของการใช้เครื่องหมายบวก และจำนวนของการใช้เครื่องหมายลบ และใช้เทคนิคิวีการเรียนรู้ด้วยอัลกอริทึมสองแบบคือ การเรียนรู้ของเครื่อง และการเรียนรู้เชิงลึก ขั้นตอนวิธี การเรียนรู้เชิงลึกด้วยอัลกอริทึม LSTM ให้ประสิทธิภาพการจำแนกข้อความประชดประชันสูงที่สุดคือ 96.79%

5.2 อภิรายผล

จากการศึกษาวิจัยการตรวจจับข้อความประชดประชันบนเครือข่ายสังคมออนไลน์สามารถอภิรายผลได้ดังนี้

1. การเรียนรู้ข้อความประชดประชันบนเครือข่ายสังคมออนไลน์ ซึ่งโดยทั่วไปเป็นข้อความที่มีลักษณะเนื้อหาที่แตกต่างจากการใช้ข้อความปกติ ลักษณะการสื่อสารส่วนมากบ่งบอกถึงการแสดงออกที่ตรงข้ามกับความหมายที่แท้จริงของของเจ้าของข้อความ การเลือกคุณลักษณะที่จะเป็นตัวแทนของข้อความประชดประชันที่ดีนั้นจึงเป็นสิ่งสำคัญในการศึกษางานด้านการจำแนกข้อความประชดประชัน

2. การวิจัยนี้แสดงให้เห็นว่า การเลือกคุณลักษณะจากบริบทในข้อความอย่างเดียว หรือใช้คุณลักษณะจากเนื้อหาในข้อความอย่างเดียวไม่เพียงพอต่อการจำแนก แต่การรวมกันระหว่างคุณลักษณะบริบทในข้อความและคุณลักษณะที่สกัดจากเนื้อหาในข้อความ สามารถให้ประสิทธิภาพที่สูงขึ้นและการเรียนรู้เชิงลึกด้วยอัลกอริทึม LSTM ให้ผลการทดลองที่ดีที่สุดเนื่องเป็นเทคนิคิวีที่เหมาะสมกับข้อมูลในรูปแบบข้อความซึ่งเป็นการข้อมูลรูปแบบต่อเนื่อง

5.3 ข้อเสนอแนะ

จากการทดลองพบว่า ผลการจำแนกด้วยแบบจำลองที่จะทำให้มีประสิทธิภาพการจำแนกที่สูงนั้น การเลือกใช้อัลกอริทึมที่เหมาะสมเป็นเพียงปัจจัยหนึ่งในการทำการวิจัย หากแต่กระบวนการวิจัยทั้งหมดมีความสำคัญทั้งสิ้น ไม่ว่าจะเป็นการเก็บข้อมูลให้ได้จำนวนที่มากพอเพื่อให้ได้แบบจำลองที่น่าเชื่อถือ การสร้างคุณลักษณะที่สามารถเป็นตัวแทนของข้อมูลที่นำมาใช้ในการวิเคราะห์ อีกชั้นสำคัญในการทำการวิจัยด้านการวิเคราะห์ข้อความที่เป็นภาษาไทย คือ การเลือกใช้วิธีการตัดคำที่มีประสิทธิภาพ ทั้งนี้ปัญหาการตัดคำนั้นยังเป็นปัญหาในภาษาไทย เนื่องจากข้อมูลที่นำมาใช้ทดลองนั้นมาจากสื่อสังคมออนไลน์ ที่ผู้ใช้งานพิมพ์ผิด การใช้ภาษาที่ไม่ตรงกับคำศัพท์ การหลีกเลี่ยงการพิมพ์ข้อความที่สามารถสื่อความหมายได้โดยตรง ดังนั้น การวิจัยทางการด้านการวิเคราะห์ภาษาไทย ยังเป็นความท้าทายสำหรับนักวิจัยที่ทำงานทางด้านการประมวลผลภาษาธรรมชาติสำหรับภาษาไทย ซึ่งงานวิจัยในอนาคตมีดังนี้

1. การรวมรวมข้อความประชดประชันจำนวนมากขึ้นซึ่งข้อความจำนวนมากจะเรียนรู้การสร้างโมเดลที่ดียิ่งขึ้น
2. การศึกษาข้อความประชดประชันจากข้อความหลากหลายภาษา เช่น ความคิดเห็นด้านการเมือง ความคิดเห็นด้านรีวิวสินค้า เป็นต้น
3. การทดลองการเลือกใช้ตัวตัดคำภาษาไทยที่มีประสิทธิภาพมากขึ้นในอนาคตเนื่องจากข้อความประชดประชันมีลักษณะการพิมพ์ข้อความที่มีรูปแบบที่ไม่ปกติทำให้การตัดคำได้ไม่ดีเท่าที่ควรทำให้ต้องทำความสะอาดข้อมูลให้ดีขึ้น
4. การศึกษาวิธีการเลือกคุณลักษณะจากบริบทในข้อความเพื่อค้นหาตัวแทนของชุดข้อมูลที่แท้จริงและช่วยลดเวลาในการประมวลผล
5. การใช้วิธีการเพิ่มหรือสกัดคุณลักษณะด้วยวิธีอื่น เช่น การใช้หน้าที่ของคำ การเพิ่มคุณลักษณะจากเนื้อหาในข้อความ
6. การเลือกเทคนิคอัลกอริทึมการเรียนรู้แบบอื่นที่เหมาะสมกับการเรียนรู้ข้อมูลชนิดข้อความ เช่น Gated Recurrent Unit (GRU), Convolutional Neural Network-Gated Recurrent Unit (CNN-GRU), Recurrent Convolutional Neural Networks (RCNN), Random Multi-model Deep Learning (RMDL) และ Hierarchical Deep Learning for Text (HDLTex)

บรรณานุกรม



បរណាណក្រម

- [1] Chan SWK, Chong MWC. Sentiment analysis in financial texts. *Decision Support Systems* 2017; 94:53-64.
- [2] Tartir S, Abdul-Nabi I. Semantic Sentiment Analysis in Arabic Social Media. *Journal of King Saud University - Computer and Information Sciences* 2017; 29:229-233. [2017-08-24 16:34:03]
- [3] Gitto S, Mancuso P. Improving airport services using sentiment analysis of the websites. *Tourism Management Perspectives* 2017; 22:132-136. [2017-08-24 16:34:37]
- [4] Jasso G, Meza I. Character and Word Baselines Systems for Irony Detection in Spanish Short Texts. *Procesamiento Del Lenguaje Natural* 2016; [56]: 41-48.
- [5] Bouazizi M, Otsuki T. A Pattern-Based Approach for Sarcasm Detection on Twitter. *Ieee Access [Article]* 2016; 4:5477-5488.
- [6] Razali MS, Halin AA, Ye L, Doraisamy S, Norowi NM. Sarcasm Detection Using Deep Learning With Contextual Features. *IEEE Access* 2021; 9:68609-68618.
- [7] Bharti SK, Babu KS, Jena SK. Parsing-based Sarcasm Sentiment Recognition in Twitter Data. 2015; 1373-1380.
- [8] Bouazizi M, Ohtsuki T. Opinion Mining in Twitter How to Make Use of Sarcasm to Enhance Sentiment Analysis. 2015; 1594-1597.
- [9] Kumar AA, S.Chandrasekhar. Text Data Pre-processing and Dimensionality Reduction Techniques for Document Clustering. *International Journal of Engineering Research & Technology* July 2012; 1[5]: 1-6.
- [10] Shivaprasad TK, Shetty J. Sentiment analysis of product reviews: A review. 2017 International Conference on Inventive Communication and Computational Technologies (ICICCT); March 2017; 298-301.
- [11] C.Ramasubramanian, R.Ramya. Effective Pre-Processing Activities in Text Mining using Improved Porter's Stemming Algorithm. *International Journal of Advanced Research in Computer and Communication Engineering* December 2013; 2[12]: 4536-4537.

- [12] Nasim Z, Rajput Q, Haider S. Sentiment analysis of student feedback using machine learning and lexicon based approaches. 2017 International Conference on Research and Innovation in Information Systems (ICRIIS); July 2017; 1-6.
- [13] Qin Z, Petrounias I. A Semantic-Based Framework for Fine Grained Sentiment Analysis. 2017 IEEE 19th Conference on Business Informatics (CBI); July 2017; 295-301.
- [14] Wicana SG, İbisoglu TY, Yavanoglu U. A Review on Sarcasm Detection from Machine-Learning Perspective. 2017 IEEE 11th International Conference on Semantic Computing (ICSC); January 2017; 469-476.
- [15] Bharti SK, Vachha B, Pradhan RK, Babu KS, Jena SK. Sarcastic sentiment detection in tweets streamed in real time: a big data approach. Digital Communications and Networks 2016; 2108-121. [2017-09-14 22:48:29]
- [16] Mukherjee S, Bala PK. Sarcasm detection in microblogs using Naïve Bayes and fuzzy clustering. Technology in Society 2017; 4819-27. [2018-06-01 11:22:36]
- [17] Fersini E, Pozzi FA, Messina E. Detecting irony and sarcasm in microblogs: The role of expressive signals and ensemble classifiers. 2015 IEEE International Conference on Data Science and Advanced Analytics (DSAA); October 2015; 1-8.
- [18] Belwal RC, Rai S, Gupta A. Text summarization using topic-based vector space model and semantic measure. Information Processing & Management 2021; 58[3]: 102536. [2022-02-22 04:21:16]
- [19] ภูมิรพี ภูมิค้า. เทคนิคการเรียนรู้เชิงลึกเพื่อวิเคราะห์ความรู้สึกจากผู้ใช้ผลิตภัณฑ์. Thesis: สาขาวิชาวิศวกรรมคอมพิวเตอร์ สำนักวิชาวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีสุรนารี; 2562.
- [20] Pasupa K, Ayutthaya TSN. Thai sentiment analysis with deep learning techniques: A comparative study based on word embedding, POS-tag, and sentic features. Sustainable Cities and Society 2019; 50
- [21] Ahuja R, Sharma SC. Transformer-Based Word Embedding With CNN Model to Detect Sarcasm and Irony. Arabian Journal for Science and Engineering 2021;
- [22] Khan FH, Qamar U, Bashir S. Senti-CS: Building a lexical resource for sentiment analysis using subjective feature selection and normalized Chi-Square-based feature weight generation. Expert Systems 2016; 33[5]: 489-500. [2018-06-01 11:21:15]

- [23] Vilares D, Alonso MA, Gómez-Rodríguez C. Supervised sentiment analysis in multilingual environments. *Information Processing & Management* 2017; 53:595-607. [2017-08-24 16:32:31]
- [24] Huang F, Zhang S, Zhang J, Yu G. Multimodal learning for topic sentiment analysis in microblogging. *Neurocomputing* 2017; 253:144-153. [2017-08-24 16:30:21]
- [25] Dave AD, Desai NP. A comprehensive study of classification techniques for sarcasm detection on textual data. *2016 International Conference on Electrical, Electronics, and Optimization Techniques (ICEEOT)*; March 2016; 1985-1991.
- [26] ปริญญา สงวนสัตย์. *Artificial Intelligence with Machine Learning, AI สร้างได้ด้วยแมชีนเลร์นนิ่ง*. บริษัท ซีเอ็ดดูเคชั่น จำกัด (มหาชน); 2019.
- [27] วรรษา เงินดี, วีรยุทธ เจริญเรืองกิจ. *BOOK RECOMMENDATION WITH DATA MINING USING RAPIDMINER*. 2021; [2022-02-19 02:00:49]
- [28] ปิยารรณ นิลถอน, ธนาพร มาลัย, สายชล สินสมบูรณ์ทอง. การเปรียบเทียบประสิทธิภาพการทำนายผลการแปลงข้อมูลในการจำแนกด้วยเทคนิคการทำเหมืองข้อมูล. *Thai Journal of Science and Technology* 2021; 10[1]: [2022-02-19 02:08:58]
- [29] อัชฌาพร กว้างสวاستี, เพียงฤทธิ์ หนูสวัสดี, วรاءี คงหมาย, ปริญญา ทิพยากรุ่งกษ์, บุษกร สังขันนท์. ระบบทำนายระดับความเครียด ด้วยเทคนิคต้นไม้การตัดสินใจ. *Rattanakosin Journal of Science and Technology* 2019; 1[2]: 13-26. [2022-02-19 12:06:11]
- [30] Pasupa K, Seneewong Na Ayutthaya T. Hybrid Deep Learning Models for Thai Sentiment Analysis. *Cognitive Computation* 2021;
- [31] ทรงกรด พิมพิศาล ณัฐวุฒิ ศรีวิบูลย์. การประมวลผลภาพสำหรับการจำแนกรูปภาพพื้นดินโดยใช้การเรียนรู้เชิงลึก. *JOURNAL OF INFORMATION SCIENCE AND TECHNOLOGY* 2020; 10[2]: 19-25. [2022-02-15 01:14:41]
- [32] Chunyan Y, Chen Y, Zuo W. Multi-Task Deep Neural Networks for Joint Sarcasm Detection and Sentiment Analysis. *Pattern Recognition and Image Analysis* 2021; 31[1]: 103-108. <https://dx.doi.org/10.1134/s105466182101017x>
- [33] Onan A, Tocoglu MA. A Term Weighted Neural Language Model and Stacked Bidirectional LSTM Based Framework for Sarcasm Identification. *IEEE Access* 2021; 97701-7722. <https://dx.doi.org/10.1109/ACCESS.2021.3049734>
- [34] Ayutthaya TSN, Pasupa K. Thai Sentiment Analysis via Bidirectional LSTM-CNN Model with Embedding Vectors and Sentic Features. *2018 International Joint*

Symposium on Artificial Intelligence and Natural Language Processing (iSAI-NLP); 2018-11; 1-6.

- [35] ภาณุพงษ์ ร่องอ้อ และ นวีร์ วิวัฒน์วนนา. THE IMPACT OF FEATURE EXTRACTION AND DATA IMPUTATION ON PM2.5 FORECASTING MODEL FOR BANGKOK AREA. Thesis: Srinakharinwirot University; 2020.
- [36] B P, K.p. S, Kumar MA. A deep learning approach for Malayalam morphological analysis at character level. Procedia Computer Science 2018; 13247-54. [2022-02-22 07:21:55]
- [37] Eke CI, Norman AA, Shuib L. Context-Based Feature Technique for Sarcasm Identification in Benchmark Datasets Using Deep Learning and BERT Model. IEEE Access 2021; 948501-48518. <https://dx.doi.org/10.1109/ACCESS.2021.3068323>
- [38] Rajadesingan A, Zafarani R, Liu H. Sarcasm Detection on Twitter: A Behavioral Modeling Approach. 2015; New York, NY, USA: ACM; 97–106.
- [39] Mukherjee S, Bala PK. Detecting sarcasm in customer tweets: an NLP based approach. Industrial Management & Data Systems 2017; 117[6]: 1109-1126. [2018-06-01 11:22:15]
- [40] Boudad N, Faizi R, Oulad Haj Thami R, Chiheb R. Sentiment analysis in Arabic: A review of the literature. Ain Shams Engineering Journal 2017; [2017-08-24 16:30:43]
- [41] Hiai S, Shimada K. A Sarcasm Extraction Method Based on Patterns of Evaluation Expressions. 2016; 31-36.
- [42] Salas-Zárate MdP, Paredes-Valverde MA, Rodriguez-García MÁ, Valencia-García R, Alor-Hernández G. Automatic detection of satire in Twitter: A psycholinguistic-based approach. Knowledge-Based Systems 2017; 12820-33. [2018-06-01 13:15:07]
- [43] Bouazizi M, Ohtsuki T. Opinion mining in Twitter: How to make use of sarcasm to enhance sentiment analysis. 2015 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining (ASONAM); August 2015; 1594-1597.
- [44] Mladenović M, Krstev C, Mitrović J, Stanković R. Using Lexical Resources for Irony and Sarcasm Classification. 2017; New York, NY, USA: ACM; 13:11–13:18.
- [45] de Freitas LA, Vanin AA, Hogetop DN, Bochernitsan MN, Vieira R. Pathways for Irony Detection in Tweets. 2014; New York, NY, USA: ACM; 628–633.

- [46] Reganti AN, Maheshwari T, Kumar U, Das A, Bajpai R. Modeling Satire in English Text for Automatic Detection. 2016 IEEE 16th International Conference on Data Mining Workshops (ICDMW); December 2016; 970-977.
- [47] Suhaimin MSM, Hijazi MHA, Alfred R, Coenen F. Natural language processing based features for sarcasm detection: An investigation using bilingual social media texts. 2017 8th International Conference on Information Technology (ICIT); May 2017; 703-709.
- [48] Justo R, Corcoran T, Lukin SM, Walker M, Torres MI. Extracting relevant knowledge for the detection of sarcasm and nastiness in the social web. Knowledge-Based Systems 2014; 69124-133. [2017-08-24 16:11:06]
- [49] Kunneman F, Liebrecht C, van Mulken M, van den Bosch A. Signaling sarcasm: From hyperbole to hashtag. Information Processing & Management 2015; 51[4]: 500-509. [2017-08-24 16:14:03]
- [50] Schifanella R, de Juan P, Tetreault J, Cao L. Detecting Sarcasm in Multimodal Social Platforms. 2016; New York, NY, USA: ACM; 1136–1145.
- [51] Taslioglu H, Karagoz P. Irony Detection on Microposts with Limited Set of Features. 2017; New York, NY, USA: ACM; 1076–1081.
- [52] Al-Ghadban D, Alnkhilan E, Tatwany L, Alrazgan M. Arabic sarcasm detection in Twitter. 2017 International Conference on Engineering MIS (ICEMIS); May 2017; 1-7.
- [53] Jain T, Agrawal N, Goyal G, Aggrawal N. Sarcasm detection of tweets: A comparative study. 2017 Tenth International Conference on Contemporary Computing (IC3); August 2017; 1-6.
- [54] Razali MS, Halin AA, Norowi NM, Doraisamy SC. The importance of multimodality in sarcasm detection for sentiment analysis. 2017 IEEE 15th Student Conference on Research and Development (SCOReD); December 2017; 56-60.
- [55] Gidhe P, Ragha L. Sarcasm detection of non # tagged statements using MLP-BP. 2017 International Conference on Advances in Computing, Communication and Control (ICAC3); December 2017; 1-4.
- [56] Chaudhari P, Chandankhede C. Literature survey of sarcasm detection. 2017 International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET); March 2017; 2041-2046.

- [57] Bhan N, D'silva M. Sarcasmometer using sentiment analysis and topic modeling. 2017 International Conference on Advances in Computing, Communication and Control (ICAC3); December 2017; 1-7.
- [58] Manohar MY, Kulkarni P. Improvement sarcasm analysis using NLP and corpus based approach. 2017 International Conference on Intelligent Computing and Control Systems (ICICCS); June 2017; 618-622.
- [59] Karoui J, Zitoune FB, Moriceau V. SOUKHRIA: Towards an Irony Detection System for Arabic in Social Media. Procedia Computer Science 2017; 117[Supplement C]: 161-168. [2017-12-10 15:32:05]
- [60] Liebrecht CC, Kunneman FA, Bosch APJvd. The perfect solution for detecting sarcasm in tweets #not. <http://aclweb.org/anthology/W/W13/W13-1605.pdf> 2013; [2017-09-18 14:05:40]
- [61] Ahmad T, Akhtar H, Chopra A, Akhtar MW. Satire Detection from Web Documents Using Machine Learning Methods. 2014 International Conference on Soft Computing and Machine Intelligence; Sept 2014; 102-105.
- [62] Vateekul P, Koomsubha T. A study of sentiment analysis using deep learning techniques on Thai Twitter data. 2016 13th International Joint Conference on Computer Science and Software Engineering (JCSSE); July 2016; 1-6.
- [63] Limkonchotiwat P, Phatthiyaphaibun W, Sarwar R, Chuangsawanich E, Nutanong S. Handling Cross- and Out-of-Domain Samples in Thai Word Segmentation. Findings 2021; 2021-08; Online: Association for Computational Linguistics; 1003–1016.
- [64] Phatthiyaphaibun W. OSKut (Out-of-domain StackEd cut for Word Segmentation). 2022-01-23 12:02:59]; <https://github.com/mrpeerat/OSKut>.
- [65] Kittinaradorn R. A Thai word tokenization library using Deep Neural Network. 2022-03-05 05:06:20]; <https://github.com/rkcosmos/deepcut>.
- [66] Mikolov T, Chen K, Corrado G, Dean J. Efficient Estimation of Word Representations in Vector Space. arXiv:13013781 [cs] 2013; [2022-03-05 05:17:17]
- [67] Phatthiyaphaibun W. Thai Sentiment Analysis Toolkit. 2022-03-01T13:12:59Z]; <https://www.kaggle.com/datasets/rtatman/thai-sentiment-analysis-toolkit>.
- [68] Karthik E, Sethukarasi T. Sarcastic user behavior classification and prediction from social media data using firebug swarm optimization-based long short-term

memory. The Journal of Supercomputing 2021; <https://dx.doi.org/10.1007/s11227-021-04028-4>



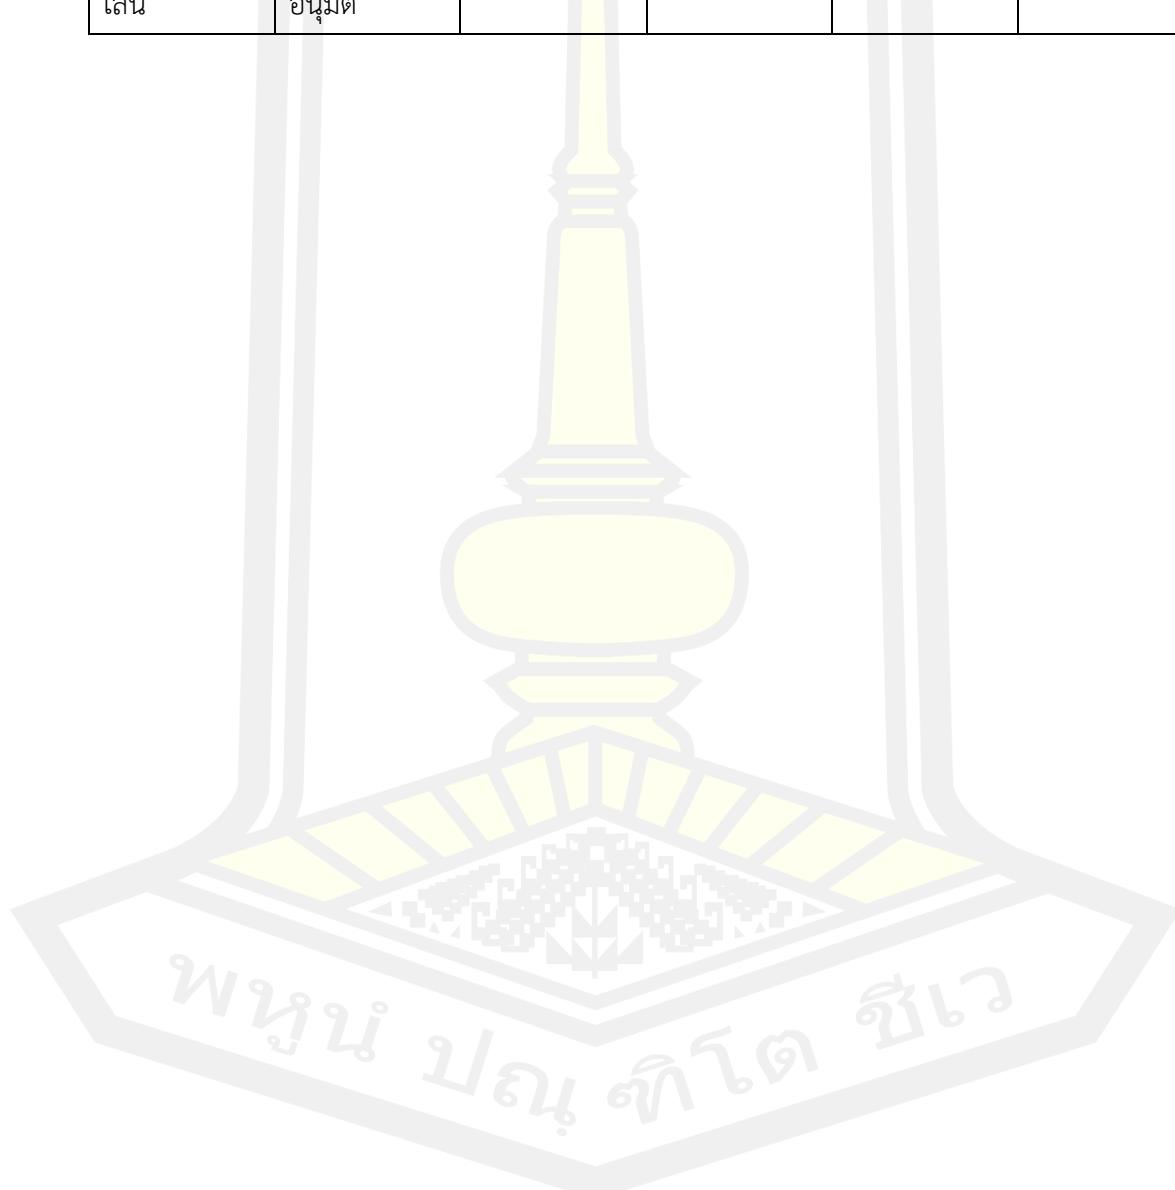
ภาคผนวก ก
ตารางแสดงคำอารมณ์เชิงบวก

กตาะที	กตัญญู	กล้า	กรุณา	กันเอง	ขำ
แข็ง	แข็งแกร่ง	แข็งข้น	แข็งแรง	ครึ่นครึก	ครึกครื้น
แจ่ม	แจ่มใส	ชัดเจน	ชัดชื่น	เขียวชาญ	เด่น
เต็ม	ทันสมัย	ทรหด	แม่น	แท้	นวลด
น่ารัก	นุ่ม	นุน	เน้น	แน่	แน่ชัด
บริบูรณ์	บวก	เบา	เบาใจ	เบิกบาน	ปราดเปรี้ยว
ประณีต	อดทน	หน	ฉลาด	ชัดเจน	ตรง
ตนเอง	โต	แท้	จริง	เน้น	แน่
แน่ชัด	แน่น่าว	แนว	แนวนៃ	บริบูรณ์	บ้องเบ็ว
เบาใจ	เบิกบาน	ประณีต	ประดิษฐ์	ประดิษฐ์	ประหลาด
ปราดเปรี้ยว	ปลิ่ง	แปล	ผ่อง	ผ่องใส	ถูก
พริ้งเพรา	สวยงาม	พะงา	พิทักษ์	พูน	เพราพริ้ง
เพราเพริศ	เพริศแพรัว	เพริศพราย	เพา	มหา	มอน
มนุญ	มั่งคั่ง	มั่งมี	มั่นคง	ยอดเยี่ยม	เยี่ยม
เยี่ยมยอด	ยุ้ย	رجنا	รอบคอบ	รำรวย	รุ่ง
รุ่งเรือง	รุ่งโรจน์	เร็ว	เร้า	เรือง	ลอด
ละเอียด	ละเอียด	ละเอียดมอม	ทันสมัย	ถ้าเลิศ	ถือชี้ง
เล่อ	แล	หวาน	วิรุพท์	ศุกร	สดใส
สนิท	สนิทสนม	สถาบัน	สมจวิง	สมบูรณ์	สร้างสรรค์
สวย	สวยงาม	สห	สะอาด	สะอาด	สันท์
สำรวม	สำเร็จ	สุก	สุข	สุขี	สุภาพ
สูง	สูงส่ง	เสมอ	ใส	หนาแน่น	หนุน
หนุ่มแน่น	เหมาจะเจา	เหมาจะสม	อร่อย	อริ	ใหญ่โต
อติ	อ่อนโยน	อัศจรรย	อิภูมิ	อีด	โอชะ
อ้อ	ເຍິ	ຫາ	ດີ	ດູແລຕ້ວເອງ	ດູແລຮັກໜາ
ดູແລເອາໃຈໃສ	ຕືໃຈ	ທອນ	กรวด	ອຸ່ນໃຈ	ອັນຊູ
ເຂົາຕາ	ເຂົາຕາ	กรວດນຳ	ຮັກ	ຂອບ	กรາບ

กลับใจ	กอด	การันตี	เหลือเชื่อ	เด่น	งดงาม
ก้าว	ก้าวหน้า	เรียน	กรุ่ม	กล้าหาญ	การันตี
พบ	เจอ	ช่วย	เล่น	อนุมัติ	กดเวลา
กตัญญู	กล้า	กรุณา	กันเอง	ขำ	แข็ง
แข็งแกร่ง	แข็งขัน	ปrongดอง	แข็งแรง	ครึ่งครึ่ง	รวดเร็ว
ครึ่งครึ่ง	แจ่ม	แจ่มใส	ชัดเจน	ชัดแจ้ง	ชัดเจ้า
ชัดถ้อยชัดคำ	ชู่ชื่น	โปรด	นิรโทษ	หวาน	น่ารื่นรมย์
ปฏิภาณาริย์	หายาก	เชี่ยวชาญ	เด่น	ไม่เคย	น่ากอด
เต็ม	ทันสมัย	ทรหด	แฉ	ความเป็น กลาง	เป็นกลาง
แท้	นวล	ขอบใจ	ขอบคุณ	น่ารัก	นุ่ม
นุ่น	เน้น	แน่	แน่ชัด	บริบูรณ์	บวก
เบา	เบาใจ	เบิกบาน	ปราดเปรียว	ประณีต	ศานติ
อดทน	ทน	ฉลาด	ประทัยด	คิดถึง	อบอุ่น
ความสุข	สุข	เคราะพ	นับถือ	รักษา	ตรง
คำนึงถึง	สรรเสริญ	ติดตาม	ประทับใจ	บำรุง	ซาบซึ้ง
เชื่อฟัง	ตงฉบิน	ไม่หวั่น	รอยยิ้ม	ยิ้ม	ประทับใจ
ระวัง	โต	นมัสการ	แท้	จริง	เน้น
แน่	แน่ชัด	แน่นอน	แนว	ภูมิใจ	มงคล
มงคลสมรส	มหาเศรษฐี	มหาเศรษฐีใจ	มีความรู้	มีความยินดี	มีความหวัง
แน่แน่	บริบูรณ์	บ้องแบ็ง	เบาใจ	เบิกบาน	ประณีต
ประดิษฐ์	ประดิษฐ์	นำประหลาด	ประหลาด	ปราดเปรียว	ปลั้ง
แปล	ผ่อง	อดออม	อนุโมทนา	ค่าว่างวัล	คัมครอง
คัมครองรักษา	ทำลายสถิติ	ทำสำเร็จ	ที่เชื่อถือได้	ไม่เป็น อันตราย	ผ่องใส
ถูก	พริ้งเพรา	สวยงาม	พงา	พิทักษ์	พูน
เพราพริ้ง	เพราเพริศ	เพริศแพรัว	เพริศพราย	เพา	มหา
มอง	มนุญ	มั่งคั่ง	มั่งมี	มั่งคง	ยอดเยี่ยม
เยี่ยม	เยี่ยมยอด	ยุ้ย	รจนา	เงียบสงบ	ปลอดภัย
ที่ปลอดภัย	ทำบุญ	ทำบุญทำทาน	หยุดนิ่ง	เงียบสงบ	รักสงบ

หมายความ	ตกลง	ชื่อสัตย์	เป็นกันเอง	รอบคอบ	ร่าวย
โอดเด่น	ตามควร	รุ่ง	รุ่งเรือง	รุ่งโรจน์	ขยันหมั่นเพียร
มีประสิทธิภาพ	เร็ว	เร้า	เรือง	loyal	ละเอียด
ละมุน	ละมุนละม่อม	ทันสมัย	ถ้าเลิศ	ลึกซึ้ง	เล่อ
แล้ว	ความชื่นชม	ความชื่นชม	ความชื่นชอบ	ความชื่นบาน	ความดี
ความดึงดูม	ความดีใจ	ความทัดเทียม	ราوا	วิรุพห์	เสถียรภาพ
ชนะ	เสริมสร้าง	ความแข็งแรง	สร้าง	เพลิดเพลิน	ความรัก
ศุกร	สมดุล	ยังชีพ	น่าับถือ	สด	สดใส
สนใจเยี่ยดี	เกียรติ	สนิท	สนิทสนม	สบาย	สมจริง
สมบูรณ์	สร้างสรรค์	สวยงาม	สวยงาม	สห	สะดาวก
สะอาด	สัน净	สำรวม	สำเร็จ	สุก	สุข
สุขี	สุภาพ	สุข	สุขสั่ง	เสมอ	ใส
หนาแน่น	หนุน	หนุนแน่น	เหมาะสม	เหมาะสม	มีประโยชน์
อร่อย	อริ	มีเหตุผล	ทุ่มเท	โรแมนติก	ถูกกาลเทศะ
มีชีวิตชีวา	มีชีวิตรอด	มีชื่อ	มีชื่อเสียง	ตื่นเต้น	กระตือรือร้น
ตื่นเต้น	พร้อม	ใหญ่โต	มั่นคงมั่นใจ	ลงตัว	คล่องแคล่ว
คล่องมือ	คล่องตัว	ใส่ใจ	ไม่ได้ยอมแพ้	เมตตา	มีประสิทธิผล
มีประยุทธ์	มีประโยชน์	มือสรภาพ	มีเงินทอง	มีเงินมีทอง	สนใจ
สุขสันต์	ขอบด้วย	ขอบธรรม	เห็นด้วย	อติ	สนุก
อ่อนโนยน	คงค้า	คงหา	คงหา	คงหาสมาคม	อ่อนโนยน
มนุษย	คนิกา	ความสงบ	สงบ	อัศจรรย์	ประมาณ
อภินิญ	อีด	ประชาธิปไตย	โฉะ	อ้อ	เชิง
ชา	คุณค่า	นับถือ	อย่า	พรี	ให้กำลังใจ
กำลังใจ	ให้ความร่วมมือ	ให้ความสนใจ	ขอพร	ใจรัก	เชื่อมั่น
ความเชื่อมั่น	ความเชื่อมั่น	เอาใจใส่	เอาใจเขามา	ความเอาใจใส่	ความเอื้ออาทร

	ในตนเอง		ใส่ใจเรา		
ความเอื้อเพื่อ	พ่อใจ	น่าพ่อใจ	น่าประทับใจ	น่าพึงพอใจ	น่าฟัง
น่าภาคภูมิใจ	น่ามหัศจรรย์	น่ายกย่อง	น่ายินดี	สนุกสนาน	ดี
ดีใจ	กรวด	กรวดน้ำ	รัก	ชอบ	กราบ
กลับใจ	กอด	การันตี	ก้าว	ก้าวหน้า	เรียน
กรุ่ม	กล้าหาญ	การันตี	พบ	เจอ	ช่วย
เล่น	อนุมัติ				



ภาคผนวก ข

ตารางแสดงคำอารมณ์เชิงลบ

กระจุกกระจิก	กระดาน	แก'	เกรียน	เกร	เกิน
ขวางโลก	ขัดスマชิ	ข่น	คมคาย	กระเซอะกระเซิ่ง	เคร่งชรีม
เครียด	งอ	งอแง	โน่	จังไร	จัญไร
เจือ	เจือจาง	ตា	ตាต้อย	ฉุดชาด	ชัว
ชี้สาว	ชาว	ช้ำ	ช้ำซ้อน	ช้ำร้าย	เข่อ
ดุตน	ดุร้าย	ตigmataiy	ทราม	ทะลุ	ทุเรศ
เที่ยม	นักเลง	ลบ	เบื้อ	ปรัมปรา	เท็จ
ตอแหล	ตาขาว	ฉุนเฉียว	เณโก	เนื่อย	อะงัด
ชี้สาว	ชาว	ช้ำซ้อน	ช้ำร้าย	ชูกชน	เช
เช่อ	เชา	ดื้อ	ดุร้าย	เตียรดาษ	ตกม้าตาย
ตรงข้าม	ตระหนึ่ด เหนี่ยว	ตอแหล	ตาขาว	ตា	ตាต้อย
ติดเชื้อ	เตี้ย	ตัวล	ทรหด	ทราม	ทะลุ
ทือ	ทุเรศ	เท็จ	เที่ยม	น้อย	นักเลง
น่วย	บิน	บุม	เบียง	เบื้อ	ป้อ
ปากเสีย	ปากหมา	ปราซิก	เป็นลม	เปล่าเปลี่ยว	เปื้อย
แปรร่ง	ผรุส	ผิด	ผิดหวัง	เผด็ร้อน	ผล
ແພັນ	พด	พล่าน	พิการ	พី	ຟກ
ເພື່ອນ	ແພງ	ຟກ	ຟາງ	ແພບ	ມ້ວໜອງ
ໂມເນ	ຍັບ	ຢືດ	ຢູ່ເຫຍິງ	ໂຢ້າ	ຮກເຮື້ອ
ຮ່ວແຮ່	ຮັດຖຸມ	ຮ້າຍ	ຮ້າຍກາຈ	ຮົບ	ຮູນແຮງ
ຮູກຮູຍ	ຮ່ຽຍຮ່າຍ	ລົ້ມ	ລັກ	ລໍາສັນຍ	ລຳບາກ
ລຳ	ເລວ	ໂລເລ	ວ່າຍາກ	ວິປໂຍຄ	ວິປະໂຍຄ
ວິເວກ	ສລ້ວ	ສວກ	ສວະ	ສະເໜ່ລ່ວ	ສັ້ນ
ສັນຫລັງຍາ	ສັບປລັບ	ສັພເພເຫະະ	ສິ້ນສຕີ	ສຸຜູ	ເສື່ຍ
ເສື່ອມໄທຮມ	ເສື່ອມເສື່ຍ	ໂສໂຄຣກ	ໂສມນ	ຫຸ້ດຫົງດ	ຫນັດ້ານ
ໜາວ	ໜອງມ້ວ	ໜວິນ	ໜຍາບ	ໜຍອກ	ຫວີ

หลง	ห่วย	หวิว	หวาน	หึง	หัวสูง
เหงา	เหม็น	เหี้ย	เหียก	เหี้ยมໂಹด	ແຫຍ
ໂຫດຮ້າຍ	ໂຫດເຫັຍ ມ	ໄໝ້ມ	ອກຕ້ຄູ່ງ	ອກແຕກ	ອລ້ຳຈື້
ອ້ວກ	ອ້ວນ	ອ່ອງ	ອ່ອນເພີ້ຍ	ອ້ອຈາວ	ເອນ
ໜ່າ	ຕັດ	ໜ່ມ	ໜ່ມຂຶ້ນ	ໜ່ໂມຍ	ຕາຍ
ຕກ	ລົ້ມ	ເສີຢີໃຈ	ກົດຕັນ	ກັກ	ກົດຈື່
ກັກໜັງ	ກະຮະກາກ	ກະຮວນ ກະຮວຍ	ກະແທກ	ກະທີບ	ກ່ອກວນ
ກ່ອກຮົມທຳ ເຂັ້ມ	ກະທຳ ໜໍາເຣາ	ກະທຳ ອນຈາຈາກ	ກະແທກກະທີນ	ກະຕຸກຫນວດ ເສື່ອ	ກະອັກ
ກະທີມ	ກະຮິງໃຈ	ໂກທກ	ກະຮັດເກົ້າຍ	ກະວັດລ້າງ	ກະໂຮກ
ກົດຮາຄາ	ຮ້ອງໃໝ່	ກລົວ	ກລົ້ນແກລັ້ງ	ເສົ້າ	ຮ້ອງໃໝ່
ແພງ	ກຳເຮີບ	ແກວ່ງ	ໜັດໃຈ	ກລ່ວຫາ	ກ້ວກ່າຍ
ກຳຈັດ	ກັ້ງຂາ	ກອບໂກຍ	ກວນ	ກວນຕືນ	ກັດ
ກັງວລ	ເກຮັງ	ເກຮງກລົວ	ເກຮງໃຈ	ເກລື້ອດ	ເກລື້ອນ
ໂກທກ	ແກ່ງແຍ່ງ	ໜ່ມຂວັງ	ໜ່ມື້	ໜ່ມຸ່ງ	ຂວາງ
ໜັດຂຶ້ນ	ໜັດຂອງ	ໜັດຂວາງ	ຮ້ອງເຮືອນ	ໜັງ	ໜາດແຄລນ
ໜາດຖຸນ	ໜາຍໜາດີ	ໜາຍົ້ໆໜ້າ	ໜາຍໜ້າ	ໜາລັງ	ົ້າ
ໜຶດໜ່າ	ໜີ່ມີ	ໜຶນ	ໜຶນໃຈ	ໜູ່	ໜູ່ເຂັ້ມ
ໜຸດຮົດ	ເຂີຍ	ເຂົ້ວຍ	ຄຕ	ຄດໂກງ	ຄຕງວ
ຄຮອບຈຳ	ຄລື່ນໄສ້ ນ	ຄລາດເຄລື່ອ	ຄວ້ານ້ຳເໜລວ	ຄວ່າ	ຄວ່າບາຕຣ
ຄອຮັບປັນ	ຄະນອງ	ຄັບ	ຄັບຄັ້ງ	ຄັດ	ຄັດຄຳນ
ຄ້າງ	ຄ້າງຄາ	ຄ້າງຄາໃຈ	ຄາໃຈ	ຄຸກເຂົ່າ	ຄຸ້ມເກຮງ
ຄຸມໜັງ	ຄຸມຕົວ	ເຄື່ນ	ເຄື່ອງ	ເຄື່ອງເຄີຍດ	ເຄຣະໜີ້ກໍາຮົມ ໜັດ
ເຄື່ອງ	ແຄົນ	ໄຄຮ່ວມ	ໜ່າແກງ	ໜາຕ	ໜ່າຕັດຕອນ
ໜ່າພືນ	ໜ່າໄມ່ຕາຍ ຂາຍໄມ່	ໜ່າຍກຄົວ	ໜ່າລ້າງໂຄຕຣ	ເຂື່ອນ	ໜົງ

	ขาด				
งงงวย	งก	งด	เงี่ยน	จน	จม
จำซ่า	จิก	จำนำ	จิตตก	จับกุม	จำกัด
เจ็บ	เจ็บไข้	เจ็บใจ	ฉ้อ	ฉี่	ฉีก
ชอก	ชดใช้	ช่วงชิง	ช็อก	ชะงัก	ชะลอ
ชัก	ชัก	ชักใย	ชัง	ช้ำใจ	ชิง
ชิงชัง	ชิงดีชิง เด่น	ชิงนรกเกิด	ชิงสุกก่อนห้าม	ชิงhmaเกิด	ช่อน
ชีม	ชีมชาบ	ช้ำเติม	ชูก	ชูกช่อน	แขขวง
แซะ	ไช้	เนรคุณ	ด้อบ	ดัดสันดาน	ดับ
ด่า	ด่าทอ	ดิ้น	ดื้อ	ดີ	ดูแคลน
ดูถูก	ดูหมิ่น	ดูหมิ่นกิน	เดา	เดือด	เดือดดาล
เดือดร้อน	ಡეก	ແಡກຕັ້ນ	ໂດນ	ໄດ້ເສີຍ	ຕກ
ตกงาน	ตกใจ	ตกนรกทั้ง	ตกหลุม	ตกหลุมพระ	ຕັ້ງແຈ່
ตายดาวหน้า	ตรม	ຕປ	ຕບຕາ	ຕរາหน້າ	ຕ່ອຕ້ານ
ตอบโต้	ตอบ	ຕ່ອສູ້	ตอบແລດ	ຕະລຸມບອນ	ຕັດຫາດ
ต้าน	ตาย	ตายด້ານ	ຕາລາຍ	ຕໍ່າຫິນ	ຕີ
ติดเตียน	ติดเชื้ອ	ติดขັດ	ตັດພວ	ຕັດພວຕ່ວ່າ	ຕື່
ตີกິນ	ຄອນ	ຄືບ	ທຽຍສ	ຄົງຂາຕ	ທຽດ
ท่วม	ท້ອ	ທະລົ່ງ	ທັກທ່ວງ	ຖຸບ	ຖຸບຕີ
ເທ	ເທ กระຈາດ	ແທງ	ແທງໃຈດຳ	ນອກໃຈ	ເນຮັດ
บกพร่อง	ບດ	ບ່ນ	ບ່ອນ	ບ່ອນທໍາລາຍ	ບາດ
บาดหมาง	ບານ	ປິດ	ປິດເບືອນ	ເບນ	ເປີຍດ
ເປີຍເປີຍນ	ເປື່ອ	ເປື່ອහ້າ	ໂປ່ຍ	ປົງປົງ	ປດ
ปນ	ประຈານ	ประຈາර	ประຈດ	ประຈດປະຈັນ	ประນາມ

ประท้วง	ประมาท	ปรับ	ปราบ	ปราบปราม	ปลงใจ
ป่วย	ปลงชีวิต	ปลง	ปล้น	ปล้นสะدم	ปลอม
ปรา	ปวด	ปลอมปน	ປະທະ	ປະປນ	ປາດ
เป็นลม	เปลือง	ໂປ່ງ	ຜັກ	ຜັດ	ຜັດວັນປະກັນພຽງ
ผ่า	ເຜິ່ນ	ລືມ	ຫລບໜີ	ຄວາມຂມ່ງຈິນ	ຄວາມຂມຸກຂົວ
ความชຸ່ນເຄືອງ	ຄວາມ	ຄວາມສົບ	ຄວາມຫ້ວໜ້າ	ຄວາມຫ້າໜ້ອນ	ຄວາມຕື້ອ
ความທຽດໂທຮມ	ຟຸ່ມເຟື່ອຍ	ຝູ່ງເຟື່ອ	ກະຈຸກກະຈິກ	ກະດານ	ແກ່
เกรီຢິນ	ຄລຸມເຄື່ອ	ຄລຸມມຸນໜ	ເກເຣ	ເກີນ	ໜ້າ
ວິກຄາຕີ	ເຈັບປວດ	ຄວາມລຶກລັບ	ແຜດີຈກກາຮ	ບັດແຢັ່ງ	ອົງຄວິກາຮ
ຮັງເກີຍຈ	ອກທັກ	ໄຮ້ສາຮະ	ຄນບາດ	ຄບໜູ້	ຄຮ່າ
ຄບໜູ້ສູ່ໜ່າຍ	ກຳກວມ	ມືດ	ເໝືອ	ລຶກລັບ	ກລຸ່ມໃຈ
ນ່າກລ້ວ	ເກີຍຈ ຄຮ້ານ	ໜ່າງໂລກ	ເສົ້າໃຈ	ໄມ່ມີທາງຮັກໝາ	ສິ້ນຫວັງ
ໄຮ້ຜລ	ອັນພາຕ	ເສົ້າສື່ມ	ສລດໃຈ	ທ້ວແທ້	ນ່າເບື່ອ
ກະສັບກະສ່າຍ	ບັດສມາຮີ	ຂຸ່ນ	ຄມຄາຍ	ກະເຊວະກະຮະເຊີງ	ເຄົ່ງຂຽມ
ຄຮ່າຍ	ກະຮ່າຍ	ຄຮ່າມີມ	ເຄີຍດ	ຄປ່າໄມ້ໄດ້	ອໂ
ຈອແງ	ໂໜ່ງ	ຈົ່ງໄຮ	ໄມ່ສນ	ຈົ່ງໄຮ	ເຈືອ
ເຈື່ອຈາງ	ຕໍ່າ	ຕໍ່າຕ້ອຍ	ໜຸດໜາດ	ຫ້າ	ຫຼູ້ສາວ
ໜ່າຍ	ຫ້າ	ຫ້າໜ້ອນ	ຫ້າຮ້າຍ	ເຫຼວ	ດຸດັ່ນ
ດຸຮ້າຍ	ຕກມ້າ ຕາຍ	ທຮາມ	ທະຮຸ	ທຸເຮັດ	ເຖີຍມ
ນັກເລັງ	ລບ	ເປື່ອ	ປັນປາ	ເທົຈ	ຕອແໜລ
ຕາຂາວ	ມຸນເນື່ອວ	ເນົາໂກ	ເນື່ອຍ	ຈະຈັດ	ຫຼູ້ສາວ
ໜ່າຍ	ຫ້າໜ້ອນ	ຫ້າຮ້າຍ	ໜຸກໜນ	ເໜ	ເໜ່ວ
ເໜາ	ຕື້ອ	ດຸຮ້າຍ	ເດີຍຮາຍ	ຕກມ້າຕາຍ	ຕຽນໜ້າມ
ຕະຫະນີ່	ຕອແໜລ	ຕາຂາວ	ຕໍ່າ	ຕໍ່າຕ້ອຍ	ຕິດເຂື້ອ

เห็นี่ยว					
เตี้ย	ตัวล	ทรงด	ทรง	ทะลุ	ทือ
ทุเรศ	เท็จ	เทียม	น้อย	นักเลง	นำย
บิน	บุ่ม	เบียง	เบื้อ	ป้อ	ปากเสีย
ปากหมา	ปราซิก	เป็นลม	เปล่าเปลี่ยว	เปื่อย	แปร่ง
ผรุส	ผิด	ผิดหวัง	ເຟີຣ້ອນ	ແລດ	ແຜລົງ
พด	พล่าน	พิการ	พີ	ຟກ	ເພື່ນ
ແພ	ຟກ	ຟາງ	ແພບ	ມ້ວໜອງ	ໂມເມນ
ຍັບ	ຢຶດ	ຢູ່ເຫັນ	ໂຢ	ຮກເຮືອ	ຮ່ວແຮ
ຮັດກຸມ	ຮ້າຍ	ຮ້າຍກາຈ	ຮົບ	ຮຸນແຮງ	ຮຸກຮູຍ
ຮູ່ຍ່າຍ່າຍ	ລົ້ມ	ລັກ	ລ້າສໍມຍ	ລໍາບາກ	ລ້າ
ເລວ	ໄລເລ	ຍາກ	ວ່າຍາກ	ວິປໂຍຄ	ວິປະໂຍຄ
ວິເວກ	ສັວ	ສວາ	ສວະ	ສະເໜ່ວ່ອ	ສັ້ນ
ສັນຫລັ້ງຍາວ	ສັບປັບ	ສັພເພທະວະ	ສິ້ນສົດ	ສູງ	ໂທຮມ
ເສີຍ	ເສື່ອມ ໂທຮມ	ເສື່ອມເສີຍ	ໂສໂຄກ	ໂສມມ	ໜຸດໜິດ
หน້າດ້ານ	หนາວ	ໝອງນ້ວ	ໝົນ	ໜຍາບ	ໜຍອກ
ຫີ່	ຫລັງ	ຫ່ວຍ	ຫວີ	ຫວະ	ຫິ່ງ
ຫວັງສູງ	ເຫາ	ເໜັນ	ໄມ່ເຂົ້ວ	ເຫຼີຍ	ບຣະລັຍ
ເທີຍກ	ເຫັ້ມໂທ ດ	ແຫຍ	ໂທດ້າຍ	ທຳສົງຄຣາມ	ທຳອັນຕຣາຍ
ທຳເປັນທອງໄມ່ຮູ້ ຮ້ອນ	ທຳເປັນ ເລື່ນ	ທຳເລື່ນໆ	ທຳໂດຍພລກາກ	ທຳເອາເຈັບ	ທຶ້ງຂ້ວ້າງ
ທຶ້ງໆ ຂ້ວ້າງໆ	ໄມ່ຮູ້ຄຸນ	ໄມ່ຮູ້ຈບຽ້ສື້ນ	ທຳໃຈໄມ້ໄດ້	ດີໄມ້ໄດ້	ດ່າ
ດ່າກລັບ	ໄມ່ຮູ້ມື້	ໄມ່ລົງຕ້ວ	ວຸ່ນວາຍ	ວຸ່ນວາຍໃຈ	ກ່ອຄວາມວຸ່ນວາຍ
ສັບສນວຸ່ນວາຍ	ສັບສນ	ໄມ່ຮູ້ສຶກຕ້ວ	ໄມ່ລົງຮອຍ	ໄມ່ລົງຮອຍກັນ	ໄມ່ສບາຍໃຈ
ໄມ່ສມບູຮັນ	ໄມ່ສມ ຮູ້ນະ	ໄມ່ສມໍາເສມອ	ໄມ່ສມຄວຣ	ໄມ່ອ່ອຍ	ໄມ່ເຂົກັນ
ໄມ່ເຈີຍມກລາ ຫວ	ໄມ່ເຂົ້ວ	ໄມ່ເຫມາະສມ	ໄມ່ເຫັນຄ່າ	ໄມ່ເຫັນດ້ວຍ	ລະເລຍ

มีโทษ	มองมา	มองเหล้า	มากเกินไป	มีความผิด	มีชั้น
มีปัญหา	ไม่เอา ไหหน	ไม่ใช่	ไม่ได้เรื่อง	ไม่วิวากใจ	ไม่ไว้หน้าใคร
ไม่วิวใจ	ไม่ไหว	อดไม่ไหว	ทนไม่ไหว	ஸஸิที	ขับไล่
ขับไล่ส่ง	ไล่ออก	เมื่อย	ทำร้าย	ไม่爽	ไม่สะไม่爽
โหนเดี้ยม	ใหม้ม	อกตัญญู	อกแตก	อลัชชี	อ้วก
อ้วน	ทำมิติมิ ร้าย	ทำลายชั่วญ	ทำลายล้าง	อ่อง	อ่อนเพลีย
อื้อชาوا	เอน	ชา	ตัด	ช่ม	ชุ่มชืน
ขโมย	ตาย	ตก	ทุจริต	ล้ม	เสียใจ
กดดัน	กัก	กดซี่	กักขัง	กระซาก	กระวนกระวาย
กระแทก	กระทีบ	ก่อถอน	ก่อกรรมทำ เข็ญ	กระทำชำเรา	กระทำอนาคต
กระแทกระทึ้น	กระตุก หนวด เสือ	กระอัก	กระทึ่ม	กริงใจ	โภก
กราดเกรี้ยว	กราดล้าง	กราโขก	กรดราคาน	ร้องไห้	กลัว
กลั้นแกล้ง	เศรษฐ	ร้อนตัว	ร้าว	ร้าวran	แพง
เม่า	ลดเกียรติ	ลาตาย	ลำบากใจ	ล่ำজม	ล่ำສlays
ล่วงประเวณี	ล่วง ละเมิด	ล่อแหลม	กดหัว	กำเริบ	แก่วง
ขัดใจ	กล่าวหา	ก้าวก่าย	กำจัด	กังขา	กอบโกย
กวาน	กวานตืน	กัด	กังวล	ไฟไหม้	น้ำท่วม
สินามิ	ทำบ้าป	ทำบ้าปทำ กรรม	ไอเวร	ไอบ้า	ไอ
คิดมาก	คิดมิติมิ ร้าย	คิดร้าย	ฤทธิ์	ถุงน้ำลาย	เกรึง
เกรงกลัว	ปادคอด	รุน	รุ่มล้อม	ซั่งแม่ง	แม่ง
มัว	มัวซัว	มัวนิม	มัวสุม	ติดคูก	คูก
เกรงใจ	เกลียด	ไม่มีแรง	ไม่มีคร	ไม่มีสติ	ไม่มีน้ำใจ

ไม่มี	ไม่มี	เกลื่อน	โกหก	แก่งแย่ง	แย่
คอร์ปชั่น	เหลื่อม ล้ำ	ข่มขวัญ	ข่มขี่	ข่มขู่	ขวาง
ขัดขืน	ขัดข้อง	ขัดขวา	ร้องเรียน	ขัง	ขาดแคลน
ขาดทุน	ขายชาติ	ขายขี้หน้า	ขายหน้า	ขາลง	เปี่ยก
ขี้	ขิดข่า	ข้ม	ขึ้น	ขึ้นใจ	ขู่
ขูเจ็ญ	ขุดริด	เจี่ย	ธรรมาน	เจริญ	โภ
คด	คดโงง	คดงอ	ครอบงำ	คลื่นไส้	คลาดเคลื่อน
คว้าน้ำเหลว	ควា	คว่าบาร	คอร์รัปชั่น	คงนอง	คับ
คับคั่ง	ค้างชำระ	ชอบกล	คัด	คัดค้าน	ค้าง
ค้างคา	ค้างคาใจ	คำใจ	คูกเข่า	คุ่มเกรง	คุ่มข้าง
คุณตัว	เค็น	ชัดช้า	ความเหดหู่	เหดหู่	เหดหู่ใจ
ความสูญเสีย	ความ หงุดหงิด	เคร่ง	อย่าง เคร่งเครียด	ตึงเครียด	ความ เคร่งเครียด
ผิด Jarvis ประเพณี	ผิด จังหวะ	ผิดคำพูด	ผิดคำสัตย์	เคร่งเครียด	เคราะห์ชั้กรรม ซัด
เคือง	แคน	ครรคราญ	ฆ่าแกง	มดเทเจ	ฆาต
ฆ่าตัดตอน	ฆ่าฟัน	ฆ่าไม่ตาย ขายไม่ขาด	ฆ่ายกครัว	ฆ่าล้างโคตร	ม้วนหน้า
เขี่ยน	งง	จก	งงวย	งก	งด
เงี่ยน	จน	จม	จำโซ	จิก	จำนำ
จิตตก	จับกุม	จำกัด	เจ็บ	เจ็บไข้	เจ็บใจ
ฉ้อ	ฉี	ฉีก	ซก	ชดใช้	ช่วงชิง
ซือก	ชะังก	ชะลอ	ซัก	ซักกระตุก	ซักไย
ซัง	ซ้ำใจ	ซิง	เซ็ง	ซิงซัง	ซิงดีซิงเด่น
ซิงนรกเกิด	ซิงสุก ก่อนห้าม	ซิงหมายเกิด	ซ่อน	ซึม	ซึมซาบ
ซ้ำเติม	ซูก	ซูกซ่อน	แซว	แซะ	ไซ้

เนอร์คุณ	ಡಡກ	ດ້ວຍ	ລ່ມສລາຍ	ຫ່າງມັນ	ທາສ
ດັດສັນດານ	ດັບ	ກວະມລພິບ	ກວະວິກຸຕີ	ກວະສົງຄຣາມ	ດ່າທອ
ດີນ	ລະເໜີ່ໃຈ	ດື້ວ	ດຸ	ດູແຄລນ	ແຄບ
ດູງກ	ດູງກດູ ແຄລນ	ດູໝົມືນ	ດູໝົມືນຄືນແຄລນ	ອີຈະວິຊຍາ	ເດາ
ເຕືອດ	ເຕືອດ ຕາລ	ເຕືອດຮ້ອນ	ແດກ	ແດກຕັນ	ໂດນ
ໄດ້ເສີຍ	ສົງສາຣ	ໂມໂທ	ໂຮຄຈິຕ	ອື່່າ	ແມ່ງ
ໄມ່ເກຮົງໃຈ	ແທກໂຄ	ແທງ	ເຫັນ້ອຍ	ຕກ	ຕກຈານ
ໂໂຍ້ຫາ	ຝືນ	ຕກໃຈ	ຕກນຽກທັງເປັນ	ຕກຫຸມ	ຕກຫຸມພຣາງ
ຕັ້ງແໜ່ງ	ຕາຍຕາບ ໜັ້ນ	ຕຽມ	ຕບ	ຕບຕາ	ຕຣາຫັ້ນ້າ
ຕ່ອຕ້ານ	ຕອບໂຕ	ຕ່ອຍ	ຕ່ອສູ້	ຕວແຮດ	ຕະລຸມບອນ
ຕັດຂາດ	ຕ້ານ	ຕາຍ	ຕາຍຕ້ານ	ຕາລາຍ	ຕໍ່າຫີ
ຕີ	ຕີເຕີຍນ	ຕິດເຂື້ອ	ຕິດັບັດ	ຕັດພ້ອ	ຕັດພ້ອຕ່ວ່າວ່າ
ຕີ	ຕີກິນ	ຄອນ	ຄືບ	ທຣຍສ	ຄື່ງຂາຕ
ທຽບ	ທ່ວມ	ທ້ອ	ທະລົ່ງ	ທັກທ່ວງ	ຖຸບ
ທຸບຕີ	ເທ	ເທກະຈາດ	ແທງ	ແທງໃຈດໍາ	ນອກໃຈ
ເນຮັດ	ບກພ່ອງ	ຮ່ວງໂຮຍ	ບດ	ບ່ນ	ວໍາເກອໃຈ
ບ່ອນ	ບ່ອນ ທໍາລາຍ	ບາດ	ບາດໝາງ	ບານປລາຍ	ບິດ
ບິດເບື່ອນ	ເບີນ	ເບີຍດ	ເບີຍດເບີຍນ	ຂຶ້ນ້າ	ເບ່ອ
ເບື່ອໜັ້ນ້າ	ໂບຍ	ປົກສີເສີ	ປດ	ປຸນ	ປະຈານ
ປະຈາຣ	ປະຈົດ	ປະຈົດ ປະຈັນ	ປະນາມ	ປະທ້ວງ	ວັນຕຣາຍ
ປະມາທ	ປັບ	ຄວາມ ຜິດພາດ	ຄອຍຫລັງ	ປຣາບ	ປຣາບປຣາມ
ປລັງໃຈ	ປ່ວຍ	ປລັງຫົວິຕ	ປລັງ	ປລັ້ນ	ປລັ້ນສະດມ
ອກຕັ້ງຢູ່	ອດຕາຍ	ອດນອນ	ອດຫລັບອດ ນອນ	ຄວາມໄມ່ແນ່ນອນ	ຄວ່າບາຕຣ

คับอกคับใจ	คับแคร	คับแครบ	คับแคน	คับแคนใจ	คับใจ
คาดโทษ	ปลอม	ปรา	ยอมแพ้	ปวด	ปลอมปน
ประทะ	บ้า	ประปน	เดียดแค้น	ชั่วร้าย	ไม่ทัน
หวานห้าม	ปำด	ล้มเหลว	เครา๊ศก	ไม่ยุติธรรม	น่าเวทนา
ความฉบิบทาย	ขม	ไม่มีอารมณ์	ทุกข์ยาก	ยากจน	ไม่เพียงพอ
อึดอัด	ตกใจ	ไม่ลงรอย กัน	ซึ้งลาด	เงอะอะ	ลังเล
ฉุนเฉียว	ดื้อตึง	หายไป	เป็นลม	เยาะเยี้ย	ปราบปราม
คุณพิน	ชัง	เปลือง	เสแสร้ง	โป๊	ซับซ้อน
ใจร้อน	ผลัก	พังทลาย	พังพินาศ	พังยับเยิน	อกคราก
ข้อจ่าย	ย้ำแย่	ແຍ່ຈັງ	ແຍ່ນາກ	ใจโลຍ	ใจສลาย
เสี่ยง	ขอโทษ	ผัด	อกจะแตก	ผัดวันประกันพรุ	ผ่า
แผ่น	เป็นไป ไม่ได้	ลีມ	ฟังช่าน	ดrama	ดราม่า
ไม่ดี	หมด กำลัง	หมด กำลังใจ	หมดความรู้สึก	หมดค่า	หมดจิตหมดใจ
หมดตัว	ให้การ เท็จ	เสียกำลัง	เสียกำลังใจ	ความเดือดร้อน	ເອາແຕໃຈຕົວເອງ

ประวัติผู้เขียน

ชื่อ	ปราโมชย์ นามวงศ์
วันเกิด	วันที่ 27 พฤษภาคม 2525
สถานที่เกิด	ศรีสะเกษ
สถานที่อยู่ปัจจุบัน	39/145 หมู่ 13 ต.แสนสุข อ.варินชำราบ จ.อุบลราชธานี 34190
ตำแหน่งหน้าที่การทำงาน	พนักงานมหาวิทยาลัย สายวิชาการ
สถานที่ทำงานปัจจุบัน	คณะบริหารธุรกิจและการจัดการ มหาวิทยาลัยราชภัฏอุบลราชธานี เลขที่ 2 ต.ในเมือง อ.เมือง จ.อุบลราชธานี 34000
ประวัติการศึกษา	พ.ศ. 2544 มัธยมศึกษา โรงเรียนสายารวิทยา ตำบลสวนกล้วย อำเภอ กันทรลักษ์ จังหวัดศรีสะเกษ พ.ศ. 2548 ปริญญาวิทยาศาสตรบัณฑิต (วท.บ.) สาขาวิชาวิทยาการคอมพิวเตอร์ มหาวิทยาลัยราชภัฏอุบลราชธานี พ.ศ. 2553 ปริญญาวิทยาศาสตรมหาบัณฑิต (วท.ม.) สาขาวิชาเทคโนโลยีสารสนเทศการเกษตรและพัฒนาชนบท มหาวิทยาลัยอุบลราชธานี พ.ศ. 2566 ปริญญาปรัชญาดุษฎีบัณฑิต (ปร.ด.) สาขาวิชาวิทยาการคอมพิวเตอร์ มหาวิทยาลัยมหาสารคาม

พูน ปัน กิต ชี้เว