การเปรียบเทียบเทคนิคการคัดเลือกคุณลักษณะแบบการกรองและการควบรวมของการทำเหมืองข้อความเพื่อการจำแนกข้อความ

วาทินี นุ้ยเพียร[1,2*] และ พยุง มีสัจ[3]

บทคัดย่อ

ปัญหาหนึ่งของการทำเหมืองข้อความคือข้อมูลมีปริมาณมาก นักวิจัยจำนวนมากใช้เทคนิคการคัดเลือกคุณลักษณะเพื่อได้คำที่เหมาะสมในการแทนเอกสารและเพิ่มประสิทธิภาพในการจำแนกเอกสารให้มีค่าความถูกต้องมากขึ้น เทคนิคที่ใช้แบ่งเป็น 2 วิธีได้แก่ การกรองและการควบรวม โดยเทคนิคการควบรวมสามารถใช้เทคนิคการทำเหมืองข้อความร่วมกับการค้นหาข้อมูล ในงานวิจัยนี้ได้ทำการเปรียบเทียบการคัดเลือกคุณลักษณะแบบการกรอง โดยเลือกใช้อินฟอร์เมชันเกน เกนเรโช และไคสแควร์ วิธีคัดเลือกแบบไคสแควร์ให้ผลดีที่สุดวัดประสิทธิภาพโดยรวม 92.2% และ การควบรวมใช้เทคนิคซัพพอร์ตเวกเตอร์แมชชีน (SVM) ร่วมกับการค้นหาด้วยวิธีเชิงพันธุกรรม (SVMGA) และการค้นหาด้วยวิธีละโมบ (SVMGD) โดยวิธีคัดเลือกแบบ SVMGD ให้ผลดีที่สุดวัดประสิทธิภาพโดยรวม 94% ซึ่งการจำแนกข้อความทั้งสองวิธีใช้ขั้นตอนวิธีแบบซัพพอร์ตเวกเตอร์แมชชีนโดยใช้เคอร์เนลแบบเรเดียลเบสิสฟังก์ชัน (SVMR) เมื่อเปรียบเทียบประสิทธิภาพทั้งวิธีการกรองและการควบรวมสรุปได้ว่าประสิทธิภาพโดยรวมของการควบรวมมีค่ามากกว่าการกรอง 1.8% ซึ่งทำให้นักวิจัยสามารถนำเทคนิคของการควบรวมไปใช้เพิ่มประสิทธิภาพการจำแนกข้อความ

คำสำคัญ : การทำเหมืองข้อความ, การคัดเลือกคุณลักษณะแบบการกรอง, การคัดเลือกคุณลักษณะแบบการควบรวม, การค้นหาด้วยวิธีเชิงพันธุกรรม, การค้นหาด้วยวิธีละโมบ, ซัพพอร์ตเวกเตอร์แมชชีน

---

[1] สำนักคอมพิวเตอร์และเทคโนโลยีสารสนเทศ, มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

[2] ภาควิชาคอมพิวเตอร์ศึกษา คณะครุศาสตร์อุตสาหกรรม, มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

[3] คณะเทคโนโลยีสารสนเทศ, มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

[*] ผู้ติดต่อ, อีเมล์: vtn@kmutnb.ac.th รับเมื่อ 27 พฤษภาคม 2556 ตอบรับเมื่อ 11 กันยายน 2556

A Comparison of Filter and Wrapper Approaches with Text Mining for Text Classification

Vatinee Nuipian[1,2*] and Phayung Meesad[3]

Abstract

The main problem for text categorization is the highest dimensionality of feature space. Many researchers focus on instruction feature selection techniques to represent a document which in turn, increases the overall efficiency of a classification model. There are two general feature selection approaches: the Filter approach and the Wrapper approach. The Filter approach used Information Gain, Gain Ratio and Chi-square. The results showed that Chi-Square had highest performance with F-measure equaling 92.2%, the Wrapper approach used Support Vector Machine consisting of Genetic Algorithm (SVMGA) and Greedy (SVMGD). The results also found that Greedy (SVMGD) was the best algorithm with F-measure which equaled 94%. Both feature selection approaches employed Support Vector Machine with kernel Radial basis function as a classifier. When comparing the effectiveness of Filter approaches to Wrapper approaches, evaluated via F-measure shown that the value of Wrapper approaches were higher than that of Filter approaches at 1.8%. In conclusion, this technique enables researchers to increase the efficiency of a wrapper approach when implemented for information classification.

Keywords : Text Mining, Filter Approach, Wrapper Approach, Genetic Algorithm, Greedy, Support Vector Machine

[1] Institute of Computer and Information Technology, King Mongkut University of Technology North Bangkok.

[2] Department of Computer Education, Faculty of Technical Education, King Mongkut University of Technology North Bangkok.

[3] Faculty of Information Technology, King Mongkut University of Technology North Bangkok.

[*] Corresponding author, E-mail: vtn@kmutnb.ac.th Received 27 May 2013, Accepted 11 September 2013

1. บทนำ

การจำแนกเอกสารเป็นวิธีหนึ่งที่เข้ามาช่วยจัดการกับกลุ่มเอกสารที่มีจำนวนมากขึ้น เช่น ข้อมูลในอินเทอร์เน็ต จึงทำให้การค้นคืนไม่ตรงตามความต้องการของผู้ใช้ทำให้ไม่สามารถสรุปความ ประมวลความหมายหรือหาความสัมพันธ์ของคำได้อย่างตรงประเด็น จึงมีนักวิจัยหลายท่านพยายามพัฒนาระบบการค้นคืนเชิงความหมาย โดยขั้นตอนแรกอาจใช้เทคนิคการทำเหมืองข้อความเข้ามาช่วยเพื่อให้คอมพิวเตอร์สามารถทำงานได้แบบอัตโนมัติ หรือกึ่งอัตโนมัติ ซึ่งผลลัพธ์ของเทอมที่ได้จากการคัดเลือกคุณลักษณะที่ดีสามารถนำมาสร้างคลาสตามความต้องการของการสร้างออนโทโลยีหรือระบบค้นคืนเชิงความหมายและการทำงานในส่วนนี้สามารถแบ่งเบาภาระของผู้เชี่ยวชาญได้เป็นอย่างดี การใช้เทคนิคการทำเหมืองข้อความจัดการกับเทอม เพื่อทำการทดสอบประสิทธิภาพของการจำแนกข้อความแต่ปัญหาหนึ่งที่พบเช่นข้อมูลมีมิติมาก เนื่องจากรายละเอียดของชุดข้อมูลที่ดีต้องมีความถูกต้อง น่าเชื่อถือ และครบถ้วน โดยเฉพาะเอกสารเป็นชุดข้อความที่มีเทอมไม่ซ้ำหรือคำที่เกิดขึ้นในเอกสารทั้งหมด สามารถเกิดขึ้นเป็นหลักล้านคำทำให้ข้อมูลมีมิติมากนักวิจัยจึงต้องประยุกต์ใช้อัลกอริธึมต่างๆ เพื่อการลดมิติข้อมูล เช่นการเลือกคำที่มีความถี่มากกว่าค่าที่กำหนด (Document Frequency) [1-2] เพื่อประหยัดทรัพยากรและใช้เวลาประมวลผลน้อย ดังนั้นนักวิจัยส่วนหนึ่งจึงใช้วิธีการคัดเลือกคุณลักษณะของข้อมูลโดยการทำให้ข้อมูลเดิมมีขนาดลดลงและสูญเสียลักษณะสำคัญของข้อมูลน้อยที่สุด การคัดเลือกคุณลักษณะในปัจจุบันใช้แบบการกรอง (Filter Approach) และการควบรวม (Wrapper Approach) ซึ่งการกรองส่วนใหญ่เลือกใช้เทคนิคแบบอินฟอร์เมชันเกน (Information Gain: IG) เกนเรโช (Gain Ratio : GR) ไคสแควร์ (Chi-square : χ^2) Haruechaiyasak และคณะ [1] และ Thongklin [2] ได้ใช้วิธีการคัดเลือกคุณลักษณะเป็นวิธีที่สำคัญสำหรับการเพิ่มประสิทธิภาพและการหาค่าความถูกต้องของการจัดกลุ่มข้อมูล หลังจากนั้นจึงวัดประสิทธิภาพของการจำแนกข้อความ ด้วยวิธีการที่หลากหลาย เช่น เคเนียเรสต์เนเบอร์ (K-Nearest Neighbor: KNN) [1], [3] เบย์ (Bayesian Network: BN) [1-4] และ ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM) [1], [3] ส่วนวิธีการควบรวม เป็นการนำอัลกอริธึมของการจำแนกข้อความร่วมกับการค้นหาข้อมูล เพื่อใช้ในการคัดเลือกคุณลักษณะข้อมูล [3, 10] ซึ่ง Saengsiri และคณะ [3] ได้แนะนำวิธีค้นหาชุดของคุณลักษณะ คือ การค้นหาด้วยวิธีเชิงพันธุกรรม (Genetic Algorithm) และการค้นหาด้วยวิธีละโมบ (Greedy Search) และทำการเปรียบเทียบวิธีการคัดเลือกข้อมูลที่ดีที่สุด

ดังนั้นในงานวิจัยนี้ ผู้วิจัยจึงทำการคัดเลือกคุณลักษณะข้อมูลที่ดีด้วยวิธีการเปรียบเทียบการคัดเลือกคุณลักษณะแบบการกรอง และการควบรวมเพื่อเลือกใช้อัลกอริธึมที่ดีที่สุดสำหรับการจำแนกข้อความและนำไปสร้างคลาสในส่วนของออนโทโลยี สำหรับการพัฒนาระบบค้นคืนเชิงความหมายแบบกึ่งอัตโนมัติ

2. ทฤษฎีที่เกี่ยวข้อง

การทำเหมืองข้อความเริ่มจากการตัดคำเนื่องจากการค้นคืนส่วนใหญ่ใช้หลักการค้นคืนจากคำสำคัญ ซึ่งใช้วิธีเทียบคำค้นกับเอกสาร (Matching) ที่มีอยู่ในฐานข้อมูล จึงใช้การตัดคำแบบคำเดี่ยว (Single Terms)

แต่ปัญหาหนึ่งที่พบคือข้อมูลมีมิติมากจึงต้องใช้ขบวนการในการคัดเลือกคุณลักษณะ (Feature Selection) ที่เหมาะสม ประกอบด้วย 2 แบบ คือ การกรอง และการควบรวม หลังจากนั้นจึงทำการจำแนกข้อความด้วยวิธีเคเนียเรสต์เนเบอร์ [4] เบย์ [1-4] และซัพพอร์ตเวกเตอร์แมชชีน [2]

2.1 การสกัดข้อความ (Text Extraction)

การสกัดข้อความคือเลือกสกัดเฉพาะส่วนที่ต้องการ เช่น ชื่อผู้แต่ง ชื่อเรื่อง คำสำคัญ ฯลฯ เนื่องจากคอมพิวเตอร์ไม่สามารถจำแนกหมวดหมู่ของเอกสารซึ่งเป็นภาษาธรรมชาติได้โดยตรง ดังนั้นจึงต้องแปลงเอกสารให้อยู่ในรูปแบบที่คอมพิวเตอร์สามารถใช้ในการเรียนรู้ได้วัตถุประสงค์ที่สำคัญคือการดึงคุณลักษณะของเอกสารมาแสดง ซึ่งจากการสำรวจงานวิจัยที่ผ่านมาพบว่าสามารถแทนคุณลักษณะด้วยคำเดี่ยว พยางค์ วลี กลุ่มของคำ ประโยค เพื่อใช้เป็นตัวแทนของเอกสาร และใช้ค่าความถี่ของคำที่ปรากฏในเอกสารเป็นค่าของคุณลักษณะ [1], [5], [6] โดยต้องผ่านกระบวนการหารากศัพท์ และการกำจัดคำหยุด

2.1.1 การหารากศัพท์ (Stemming)

รูปแบบของคำที่ยังไม่เติมคำหน้า (Prefix) หรือคำท้าย (Suffix) เพื่อจัดคำหลายคำที่มีความหมายคล้ายคลึงกันเป็นคำประเภทเดียวกัน เช่น Compatible กับ Compatibility ตัด –ible กับ ibility ซึ่งรากศัพท์ (Stem) ที่เหลือคือคำเดียวกัน [1, 4]

2.1.2 การกำจัดคำหยุด (Stop Words)

คือการนำคำที่ไม่มีนัยสำคัญออกไป โดยไม่ทำให้ความหมายของเอกสารเปลี่ยน เช่น he, and, in, or, all, again [1, 4]

2.2 การคัดเลือกคุณลักษณะ (Feature Selection)

การคัดเลือกคุณลักษณะของเอกสาร คือการนำเอกสารจากระบบต่าง ๆ เช่น เอกสารข่าวจากเว็บไซต์ บทคัดย่อ มาแปลงเพื่อให้เอกสารอยู่ในรูปแบบเดียวกัน มีองค์ประกอบของเอกสารที่เหมือนกัน และแทนคุณลักษณะในเอกสารโดยใช้คำเดี่ยว พยางค์ วลี กลุ่มของคำ ประโยค เพื่อเป็นตัวแทนคุณลักษณะของเอกสาร และทำการคำนวณหาค่าน้ำหนักของคุณลักษณะ อาจใช้เทคนิคการวิเคราะห์ทางภาษาเข้ามาช่วย (Language Analysis) เพื่อตัดคำที่ไม่จำเป็นออก หรือตัดคำตามสถิติของคลังประโยค เพื่อลดมิติของขนาดเอกสาร

เนื่องจากชุดของเอกสารเป็นชุดข้อความที่มีเทอมไม่ซ้ำหรือคำที่เกิดขึ้นในเอกสารทั้งหมด โอกาสเกิดของคำสามารถเกิดขึ้นเป็นหลักล้านคำทำให้ข้อมูลมีมิติมาก จึงต้องประยุกต์ใช้การคัดเลือกคุณลักษณะที่ดีเพื่อนำมาหาประสิทธิภาพ ลดเวลาในการประมวลผลและทรัพยากร [1, 3-4] การคัดเลือกคุณลักษณะแบ่งได้ 2 วิธีได้แก่การกรอง (Filter Approach) และการควบรวม (Wrapper Approach)

2.2.1 การกรอง

การกรอง คือการคัดเลือกคุณลักษณะซึ่ง Meesad และคณะ [7] ได้ทำการเปรียบเทียบการลดมิติข้อมูลหลาย ๆ แบบเพื่อเลือกใช้เทคนิคที่ดีที่สุด คือ ไคสแควร์ และ เกนเรโช ส่วน Haruechaiyasak และคณะ [1] แนะนำอินฟอร์เมชันเกน เพื่อใช้ในการคัดเลือกคุณลักษณะที่ดีที่สุดของข้อมูลเพื่อใช้ในการจำแนกข้อความ ประมวลผลได้รวดเร็วและใช้ทรัพยากรน้อย

1) อินฟอร์เมชันเกน (IG) คือการประเมินค่าเพื่อใช้ในการแบ่งข้อมูลด้วยการคำนวณค่า Gain สำหรับแต่ละ

มิติข้อมูลถ้ามิติข้อมูลใดมีค่า Gain สูงสุด จะถูกเลือกให้เป็นกลุ่มย่อยที่มีอำนาจจำแนก ดังสมการที่ 1 แสดงการคำนวณค่า Entropy และคำนวณค่า Gain [8]

$$Entropy \quad (p) = -\sum_{i=0}^{c-1} p(j \mid t) \log_2 p(j \mid t) \tag{1}$$

โดยที่ $\sum_i$ คือผลรวมของความน่าจะเป็นของค่า j ที่เกิดในคลาส t

p ($j \mid t$) คือค่าความถี่ที่มีความสัมพันธ์ของกลุ่ม j กับโหนด t

$$Gain \quad = Entropy \quad (p) - \left(\sum_{i=1}^{k} \frac{n_i}{n} Entropy \quad (i) \right) \tag{2}$$

โดยที่ Entropy (p) คือค่า Entropy ของตัว Root

$\sum_{i=1}^{k} \frac{n_i}{n} Entropy \quad (i)$ คือค่า Entropy ในแต่ละโหนดย่อย

2) เกนเรโช (GR) เป็นการประเมินความน่าเชื่อถือของมิติข้อมูลโดยการวัด Gain Ratio ในแต่ละคลาสการคำนวณ GR โดยใช้ค่า SplitINFO ในสมการที่ 3 และการคำนวณค่าการวัด Gain Ratio [9] ดังสมการที่ 4

$$SplitINFO \quad = -\sum_{i=1}^{k} \frac{n_i}{n} \log_2 \frac{n_i}{n} \tag{3}$$

$$GainRatio \quad = \frac{\Delta INFO}{SplitINFO} \tag{4}$$

3) ไคสแควร์ (χ^2) คือการประเมินค่าของ แอททริ-บิวต์ โดยคำนวณค่า Chi-Square ทางสถิติ [3] ดังแสดงใน สมการที่ 5

$$\chi^2 = \sum_{i=1}^{n} \frac{(O_i - E_i)^2}{E_i} \tag{5}$$

2.2.2 การควบรวม (Wrapper Approach)

การควบรวม คือการนำอัลกอริธึมของการทำเหมืองข้อความร่วมกับการค้นหาข้อมูล มาช่วยในการคัดเลือกคุณลักษณะของข้อมูล จึงให้ผลลัพธ์ที่ดีกว่าแบบการกรอง แต่ใช้เวลาในการคำนวณมากกว่า ซึ่ง Saengsiri และคณะ [3] ได้แนะนำวิธีค้นหาชุดของคุณลักษณะ คือ การค้นหาด้วยวิธีเชิงพันธุกรรม (Genetic Algorithm) และการค้นหาด้วยวิธีละโมบ (Greedy Search) โดยใช้วิธีการค้นแบบเดินหน้า (Forward Selection) และย้อนกลับ (Backward Selection) และทำการเปรียบเทียบวิธีการคัดเลือกข้อมูลด้วยวิธีการกรอง และวิธีการควบรวม ซึ่งวิธีการควบรวมให้ค่าความถูกต้องที่ดีกว่า สุคนธ์ ทิพย์ [10] ได้ทำการเปรียบเทียบการคัดเลือกคุณลักษณะที่เหมาะสมของวิธีการกรองและการควบรวม ซึ่งพบว่าวิธีการ Hybrid Classification ที่ใช้การค้นหาด้วยวิธีเชิงพันธุกรรมร่วมกับ Wrapper โดยใช้อัลกอริทึม C4.5 ให้ค่าความถูกต้องสูงที่สุดและสามารถลดคุณลักษณะที่ต้องนำมาใช้

1) การค้นหาด้วยวิธีเชิงพันธุกรรม (Genetic Algorithm: GA) นำเสนอโดย Holland [11] เป็นวิธีการผสมพันธุกรรมตามธรรมชาติ (Natural Selection) จะเห็นว่าในธรรมชาติ พันธุกรรมของสิ่งมีชีวิตทุกชนิดมีการพัฒนาโดยเลือกสิ่งที่ดีที่สุดในสายพันธุ์เพื่อสืบทอดไปยังรุ่นต่อไป ในการคำนวณ ใช้จากประสบการณ์ที่มีขั้นตอนการคำนวณมาก่อนหน้าเพื่อค้นหาคำตอบที่ดีกว่าในขั้นตอนต่อไป คำตอบที่ต้องการหาถูกกำหนดในรูป Genome (หรือ Chromosome) จากนั้น GA จะสร้างและปรับปรุงคุณภาพของประชากร

(Population) โดยผ่านกระบวนการต่าง ๆ เช่น Mutation Crossover เพื่อสืบหาคำตอบในหมู่ประชากรที่ดีที่สุด จุดเด่นคือการแก้ ปัญหาที่เป็น Discrete Continuous หรือผสมได้

2) การค้นหาด้วยวิธีละโมบ (Greedy Search) เป็นการค้นหาแบบดีที่สุดก่อน หลักการของการค้นหาแบบนี้คือเลือกเส้นทางที่ดีที่สุดก่อนเพื่อให้เข้าใกล้เป้าหมาย พิจารณาจากเส้นทางที่มองเห็นเท่านั้น โดยเลือกโหนด 1 โหนดเป็นสถานะปัจจุบันและสร้าง heuristic (h (n)) จากจุด n ไปยัง goal ที่ใกล้ที่สุด โดย
h(n) = ค่าประมาณต้นทุนจากจุด n ไป goal โดยเป็นระยะทางที่สั้นที่สุด

การกำหนดทิศทางสำหรับการค้นหามี 2 แบบดังนี้

1) Forward Chaining จุดเริ่มต้น + การใช้กฎ > เป้าหมาย

2) Backward Chaining เป้าหมาย + การใช้กฎ > จุดเริ่มต้น

2.3 การจำแนกข้อความ

การจำแนกข้อความเรียนรู้แบบมีผลเฉลย (Supervised Learning) มีขั้นตอนในการจำแนก 2 ขั้นตอนคือ การเรียนรู้เพื่อสร้างเอกสารต้นแบบและการแยกหมวดหมู่ของเอกสารที่สนใจ โดยการตรวจหาความคล้ายกับกลุ่มเอกสารต้นแบบประกอบด้วยเทคนิคดังต่อไปนี้

2.3.1 เบย์ (Bayes)

คือวิธีการเรียนรู้ที่ใช้หลักการของความน่าจะเป็น ซึ่งมีพื้นฐานมาจากทฤษฎีของเบย์ (Bayes's theorem) [12] เช่นกำหนดให้การเกิดของเหตุการณ์ต่างๆ ที่ใช้ในการจำแนกกลุ่มนั้นเป็นอิสระต่อกัน แนวคิดทฤษฎีของเบย์ สามารถทำนายเหตุการณ์ที่พิจารณาได้จากการเกิดของเหตุการณ์ต่างๆ ได้ ดังสมการที่ 6

$$\Pr(class = c|X) = \frac{\Pr(X|class = c)}{\Pr(class = c)|\Pr(X)} \quad (6)$$

ข้อสังเกต $\Pr(X)$ ไม่เปลี่ยนสำหรับค่าคลาส c ที่เปลี่ยนไป

$\Pr(class = c) \approx$ ความถี่สัมพัทธ์ของตัวอย่างในคลาส c

$\Pr(class = c|X)$ สูงสุดก็ต่อเมื่อ

$\Pr(X|class = c) = \Pr(class = c)$ สูงสุด

นาอีฟเบย์คือการใช้วิธีการของเบย์พร้อมสมมติฐานของการเป็นอิสระต่อกันของตัวแปรอิสระทุกตัว ดังสมการที่ 7

$$\Pr(x_1,..,x_k|class = c) = \Pr(x_1|class = c)... \Pr(x_k|class = c) \quad (7)$$

ถ้าลักษณะประจำ i เป็น categorical : $\Pr(x_i \mid class = c)$ ประมาณด้วยความถี่สัมพัทธ์ของตัวอย่างที่มีค่า x_i ในคลาส c

ถ้าลักษณะประจำ i เป็น continuous : $\Pr(x_i \mid class = c)$ ประมาณด้วยฟังก์ชันความหนาแน่น Gaussian

2.3.2 เคเนียเรสต์เนเบอร์

เคเนียเรสต์เนเบอร์ คือการตัดสินใจของคลาสสำหรับแทนเงื่อนไขหรือกรณีใหม่ โดยการตรวจสอบจำนวนบางจำนวน หรือเงื่อนไขที่เหมือนกันหรือใกล้เคียงกันมากที่สุด ใช้เวลาในการคำนวณสูงเพราะการคำนวณเป็นการเพิ่มขึ้นแบบแฟคทอเรียลตามจุดทั้งหมด ขณะที่ Decision Tree หรือโครงข่ายประสาทเทียมประมวลผลเพื่อสร้างเงื่อนไขได้เร็วกว่า เพราะเค

เนียเรสต์เนเบอร์ มีการคำนวณทุกครั้งที่มีกรณีใหม่ ดังนั้นเพื่อความรวดเร็วข้อมูลทั้งหมดที่ใช้บ่อยต้องถูกเก็บไว้ในหน่วยความจำ ชื่อว่า Memory-Based Reasoning [13]

2.3.3 ซัพพอร์ตเวกเตอร์แมชชีน (SVM)

นำเสนอโดย [14] ใช้เพื่อหาระนาบการตัดสินใจในการแบ่งข้อมูลออกเป็นสองส่วน โดยใช้สมการเส้นตรงเพื่อแบ่งเขตข้อมูล 2 กลุ่มออกจากกันมุ่งหาผลลัพธ์ที่ดีที่สุดของการเรียนรู้ (Discriminative Training) บนการเรียนรู้จากสถิติของข้อมูล ซึ่งทำงานโดยการหาค่าระยะขอบที่มากที่สุด (Maximum Margin) ของระนาบตัดสินใจ (Decision Hyper Plane) ในการแบ่งแยกกลุ่มข้อมูลที่ใช้ฝึกฝนออกจากกัน โดยใช้ฟังก์ชันแม็ปข้อมูลจาก Input Space ไปยัง Feature Space และสร้างฟังก์ชันวัดความคล้ายที่เรียกว่า เคอร์เนลฟังก์ชันบน Feature Space โดยมีวัตถุประสงค์เพื่อพยายามลดความผิดพลาดจากการทำนาย (Minimize Error) พร้อมกับเพิ่มระยะแยกแยะให้มากที่สุด (Maximized Margin) ซึ่งต่างจากเทคนิคโดยทั่วไปเช่น โครงข่ายประสาทเทียม (Artificial Neural Network: ANN) ที่มุ่งเพียงทำให้ความผิดพลาดจากการทำนายให้ต่ำที่สุดเพียงอย่างเดียว เหมาะสำหรับข้อมูลที่มีลักษณะมิติของข้อมูลมีปริมาณมาก โดยแบ่งแยกกลุ่มจากระนาบหลายมิติให้ประสิทธิภาพที่ดีกว่าวิธีการโดยทั่วไป เคอร์เนลที่พบได้บ่อยคือโพลิโนเมียล (Polynomial) เป็นการคำนวณหาเส้นแบ่งโดยใช้สมการเชิงเส้นที่มี Degree มากกว่าสอง และเรเดียลเบสิสฟังก์ชัน (Radial basis Function) โดยมีค่า C เป็นค่าตัวแปรที่ปรับความสมดุลระหว่างการให้ความสำคัญของระยะแยกแยะสูงสุด หรือให้ความสำคัญกับค่าความผิดพลาดที่ต้องการให้ต่ำที่สุด โดยปกติค่า C จะกำหนดให้มีค่ามากส่วนค่า Gamma มีค่าน้อย ซึ่งสมการทั้งหมดปรากฏในหนังสือ [15] ส่วนค่าเคอร์เนลแสดงดังสมการที่ (8) และ (9) ได้แก่

Polynomial kernel: (SVMP)

$$\gamma \times \mu' \times v + coef\,0)\text{^}\deg ree \quad (8)$$

Radial basis function kernel : (SVMR)

$$\exp(-\gamma \times |\mu - v|\text{^}2) \quad (9)$$

3. อุปกรณ์และวิธีการวิจัย

วิธีการวิจัยเริ่มต้นโดยการเตรียมข้อมูล ทำการคัดเลือกคุณลักษณะของคำที่ดี ประกอบด้วย 2 วิธีคือ การกรองและการควบรวม ทำการจำแนกกลุ่มข้อมูลและประเมินประสิทธิภาพการจำแนกกลุ่มข้อมูลเพื่อสร้างโมเดลดังแสดงในรูปที่ 1

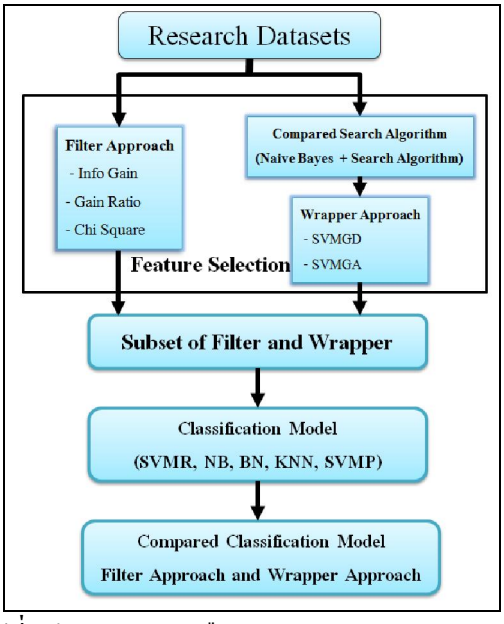

รูปที่ 1 โมเดลการคัดเลือกคุณลักษณะและการจำแนกข้อความ

3.1 การเตรียมข้อมูล

ข้อมูลที่ใช้ในการทดลองในครั้งนี้เป็นบทคัดย่อภาษาอังกฤษจากฐานข้อมูล ACM Digital Library [16] โดเมน Information System แบ่งเป็น 2 กลุ่ม คือ Database Management, Information Storage and Retrieval Information ปี 2009-2010 สกัดข้อความโดยเลือกเฉพาะคอลัมน์ที่ต้องการเช่น ชื่อผู้แต่ง ชื่อเรื่อง คำสำคัญ ฯลฯ เลือกข้อมูลที่ครบทุกคอลัมน์ และ 1 บทความมี 1 กลุ่ม เลือกคำสำคัญของเอกสารมาสร้างเป็นตัวแทนเอกสารเพื่อแทนข้อมูลทั้งหมดของเอกสาร ผลการคัดเลือกบทความจำนวน 1,009 เอกสาร ทำการสกัดข้อความโดยผ่านกระบวนกำจัดคำหยุด การหารากศัพท์ เพื่อสร้างคำสำคัญแบบคำเดี่ยวจำนวน = 2,354 คำ

3.2 ขั้นการคัดเลือกคุณลักษณะ

การคัดเลือกคุณลักษณะใช้เพื่อลดมิติข้อมูลเนื่องจากจำนวนข้อมูลมีมากซึ่งข้อมูลที่นำมาลดมิติได้มาจากการตัดคำเดี่ยวจำนวน 2,354 คำ ซึ่งใช้ 2 วิธี ได้แก่ การกรองและการควบรวม

3.2.1 การกรอง

การกรอง คือ การคัดเลือกคำที่มีลักษณะเฉพาะตามการคำนวณในแต่ละวิธีและได้คำที่มีอำนาจจำแนกมากที่สุด ซึ่งในการทดลองนี้ใช้สถิติ 3 วิธี ได้แก่ อินฟอร์เมชันเกน เกนเรโช และไคสแควร์ โดยใช้ค่าการคำนวณที่ให้ผลมากกว่า 0 โดยมีรายละเอียดดังต่อไปนี้

1) อินฟอร์เมชันเกน คือการประเมินค่าเพื่อใช้ในการแบ่งข้อมูลด้วยการคำนวณค่า Gain โดยเลือกข้อมูลเฉพาะค่า IG ที่มากกว่า 0

2) เกนเรโช คือการประเมินความน่าเชื่อถือของมิติข้อมูลโดยการวัด Gain Ratio ในแต่ละคลาส โดยเลือกข้อมูลเฉพาะค่า GR ที่มากกว่า 0

3) ไคสแควร์ คือการประเมินค่าของแอททริบิวต์โดยคำนวณค่า χ^2 เลือกข้อมูลเฉพาะค่าไคสแควร์ที่มากกว่า 0 จำนวนคำที่มีลักษณะเฉพาะของอินฟอร์เมชันเกน เกนเรโช และไคสแควร์ มีค่า = 249 คำ

3.2.2 การควบรวม

คือ การใช้เทคนิคการทำเหมืองข้อความร่วมกับวิธีการค้นหา ในงานวิจัยนี้ทำการทดลอง 2 วิธี ดังนี้

1) เปรียบเทียบการค้นหาที่ดีที่สุดด้วยการใช้เทคนิคแบบนาอีฟเบย์ ร่วมกับค้นหาแบบ Best First, Genetic Search, Greedy Stepwise, Linear Forward และ Subset Size Forward และทำการจำแนกข้อความ 5 โมเดลดังตารางที่ 1 และผลลัพธ์ดังตารางที่ 3

2) นำผลจากการเปรียบเทียบใน 1 มาใช้คือ การค้นหาด้วยวิธีเชิงพันธุกรรม (GA) และการค้นหาด้วยวิธีละโมบ(GD) ร่วมกับเทคนิคซัพพอร์ตเวกเตอร์แมชชีน (SVM)

3.3 การจำแนกประเภทข้อมูล

ทำการจำแนกข้อความด้วยวิธี นาอีฟเบย์ (NB) เบย์เซียนเน็ต (BN) เคเนียเรสต์เนเบอร์ (KNN) และซัพพอร์ตเวกเตอร์แมชชีน โดยใช้เคอร์เนลฟังชันแบบโพลิโนเมียล (SVMP) และเรเดียลเบสิสฟังก์ชัน (SVMR) ปรับค่าพารามิเตอร์ให้เหมาะสม ซึ่งในตารางที่ 1 แสดงรายละเอียดโมเดลที่ทดลองในการจำแนกข้อความ

ตารางที่ 1 รายละเอียดโมเดลทดลองในการจำแนกข้อความ

โมเดล	รายละเอียดโมเดลที่ทดลอง	ชื่อย่อ
1.	BayesNet	BN
2.	Naive Bayes	NB
3.	K-nearest neighbor	KNN
4.	Support Vector Machine Polynomial Kernel	SVMP
5.	Support Vector Machine Radial basis Function Kernel	SVMR

งานวิจัยนี้ใช้การตรวจสอบไขว้กันหลายเท่า (K-Fold Cross Validation) เป็นวิธีการในตรวจสอบค่าความผิดพลาด ในการคาดการณ์ของโมเดล โดยพื้นฐานของวิธีการตรวจสอบไขว้กันคือการสุ่มตัวอย่าง (Resampling) ซึ่งใช้แบบ 10 Fold เพื่อใช้การจำแนกข้อความ

3.4 การประเมินประสิทธิภาพ

การประเมินประสิทธิภาพใช้วิธีวัดค่าความแม่นยำ (Precision: P) ค่าความระลึก (Recall: R) และการวัดประสิทธิภาพโดยรวม (F-measure) ดังสมการที่ (10) (11) และ (12) ตามลำดับ

$$P = \frac{|Ra|}{|A|} \tag{10}$$

โดยที่ $|Ra|$ คือ จำนวนข้อมูลที่ถูกต้องที่ค้นคืนออกมาได้

$|A|$ คือ จำนวนข้อมูลทั้งหมดที่ค้นคืนออกมาได้

$$R = \frac{|Ra|}{|R|} \tag{11}$$

|R| คือ จำนวนข้อมูลที่ถูกต้องทั้งหมดในฐานข้อมูล

$$F - measure = \frac{2 \times (R \times P)}{R + P} \tag{12}$$

4. ผลการวิจัยและการอภิปรายผล

การประเมินผลใช้วิธีวัดค่าความถูกต้องจาก ค่าความแม่นยำ ค่าความระลึก และการวัดประสิทธิภาพโดยรวม ดังสมการที่ (10) (11) และ (12) ตามลำดับสามารถอธิบายได้ 4 ขั้นตอนคือ 1) ทำการคัดเลือกคุณลักษณะแบบการกรอง 2) เปรียบเทียบการค้นหาที่ดี 3) คัดเลือกคุณลักษณะแบบการควบรวมโดยใช้การค้นหาที่ดีจาก 2 เพื่อใช้ร่วมกับเทคนิคซัพพอร์ตเวกเตอร์แมชชีน 4) ทำการเปรียบเทียบผลลัพธ์ที่ได้จากการคัดเลือกคุณลักษณะทั้ง 2 แบบคือแบบการกรองและการควบรวม เพื่อนำวิธีที่ดีที่สุดไปสร้างโมเดลในการลดมิติข้อมูล ซึ่งอธิบายรายละเอียดได้ตามขั้นตอนดังต่อไปนี้

ขั้นตอนที่ 1 ทำการคัดเลือกคุณลักษณะแบบการกรอง 3 วิธี คือ อินฟอร์เมชันเกน เกนเรโช และไคสแควร์ เพื่อคัดเลือกคำที่มีลักษณะเฉพาะและนำคำเหล่านั้นมาใช้ในการจำแนกข้อความ 5 โมเดลตามตารางที่ 1 สรุปผลดังตารางที่ 2

ตารางที่ 2 ผลการจำแนกข้อความร่วมกับการคัดเลือกคุณลักษณะแบบการกรอง

Filter	Feature	SVMR	NB	BN	KNN	SVMP
ChiSquare	249	92.2	91.7	91.4	88.7	86.5
InfoGain	249	91.2	91.5	91.4	88.7	86.5
GainRatio	249	91.0	91.5	91.4	88.7	86.5

จากตารางที่ 2 การคัดเลือกคุณลักษณะการกรองแบบไคสแควร์ ใช้วิธีการจำแนกประเภทแบบซัพพอร์ต-เวกเตอร์แมชชีน โดยใช้เคอร์เนลฟังชันเรเดียลเบสิส-ฟังก์ชัน (SVMR) ให้ผลการวัดประสิทธิภาพโดยรวมสูงที่สุดคือ 92.2% นาอีฟเบย์ 91.7% และ เบย์เซี่ยนเน็ต 91.4% ตามลำดับ ซึ่งผลลัพธ์ที่ได้มีความสอดคล้องกับงานวิจัยของ Saengsiri [3] และ Haruechaiyasak [1]

ขั้นตอนที่ 2 เปรียบเทียบวิธีการค้นคืนข้อมูล โดยใช้เทคนิคนาอีฟเบย์ร่วมกับการค้นหา แบบ Best First, Genetic Search, Greedy Stepwise, Linear Forward และ Subset Size Forward ทำการจำแนกข้อความด้วย 5 โมเดลตามตารางที่ 1 เพื่อนำวิธีการค้นหาที่ดีไปใช้งานในขั้นตอนที่ 3 ผลลัพธ์ที่ได้ดังตารางที่ 3

ตารางที่ 3 ผลลัพธ์การใช้เทคนิคแบบนาอีฟเบย์ร่วมกับการค้นหาข้อมูลแบบต่าง ๆ

Search	Feature	SVMR	NB	BN	KNN	SVMP
Best First	21	90.0	89.9	90.0	90.2	90.0
Genetic Search	1,261	73.2	90.0	91.0	82.4	80.9
Greedy Stepwise	21	90.1	89.8	91.1	90.2	90.0
Linear Forward	18	90.0	87.0	89.0	89.3	89.2
Subset Size	18	90.0	86.9	89.0	89.2	89.0

จากตารางที่ 3 การค้นหาข้อมูลที่ดีที่สุดคือ การค้นหาด้วยวิธีเชิงพันธุกรรม 91.0% จำนวนคำที่ใช้ 1,261 คำ และ การค้นหาด้วยวิธีละโมบ 91.1% จำนวนคำที่ใช้ 21 คำ

ขั้นตอนที่ 3 คัดเลือกคุณลักษณะแบบการควบรวม โดยเลือกใช้เทคนิคซัพพอร์ตเวกเตอร์แมชชีนร่วมกับการค้นหาด้วยวิธีเชิงพันธุกรรม (SVMGA) และการค้นหาด้วยวิธีละโมบ (SVMGD) และทำการจำแนกข้อความด้วย 5 โมเดล ตามตารางที่ 1 ผลลัพธ์ที่ได้ดังตารางที่ 4

ตารางที่ 4 ผลลัพธ์การใช้เทคนิคซัพพอร์ตเวกเตอร์แมชชีนร่วมกับการค้นหาด้วยวิธีเชิงพันธุกรรม (SVMGA) และการค้นหาด้วยวิธีละโมบ (SVMGD) และทำการจำแนกข้อความด้วย 5 โมเดล

Method	Feature	SVMR	NB	BN	KNN	SVMP
SVMGD	55	94.0	89.8	90.7	91.3	92.2
SVMGA	629	77.3	86.6	87.5	85.6	84.4

* Support Vector Machine & Greedy Stepwise (SVMGD)

* Support Vector Machine & Genetic Search (SVMGA)

จากตารางที่ 4 การคัดเลือกคุณลักษณะแบบการควบรวมด้วยเทคนิคซัพพอร์ตเวกเตอร์แมชชีนร่วมกับการค้นหาด้วยวิธีละโมบ (SVMGD) ใช้วิธีการจำแนกประเภทแบบซัพพอร์ตเวกเตอร์แมชชีนโดยใช้เคอร์เนลฟังชันเรเดียลเบสิสฟังก์ชัน (SVMR) ให้ผลการวัดประสิทธิภาพโดยรวมสูงที่สุดคือ 94% จำนวนคำที่นำมาพิจารณาในการสร้าง คลาสมีจำนวนค่อนข้างน้อย

ขั้นตอนที่ 4 ทำการเปรียบเทียบค่าที่ได้จากการคัดเลือกคุณลักษณะทั้ง 2 แบบคือแบบการกรองและการควบรวม

ผลลัพธ์ที่ได้จากการควบรวมมีค่าการวัดประสิทธิภาพโดยรวมมากกว่าการกรอง 1.8% ซึ่งทำให้นักวิจัยสามารถนำเทคนิคของการควบรวมซึ่งเกิดจากเทคนิคการการทำเหมืองข้อความร่วมกับการค้นหาชุดข้อมูลแบบอื่น ๆ เพื่อใช้ปรับค่าความถูกต้องของข้อมูลให้เพิ่มมากยิ่งขึ้นต่อไป

5. สรุปผลและข้อเสนอแนะ

การเปรียบเทียบเทคนิคการคัดเลือกคุณลักษณะแบบการกรองและการควบรวมของการทำเหมืองข้อความเพื่อการจำแนกข้อความ สรุปได้ว่าการควบรวมให้ผลการวัดค่าประสิทธิภาพโดยรวมได้ดีกว่าแบบการกรอง 1.8% โดยใช้เทคนิคซัพพอร์ตเวกเตอร์แมชชีนร่วมกับการค้นหาด้วยวิธีละโมบ (SVMGD) ทำให้ได้คำที่มีคุณลักษณะที่ดีและนำคำเหล่านั้นมาสร้างคลาสหรือซับคลาสของออนโทโลยีตามรูปแบบการพัฒนาระบบการค้นคืนเชิงความหมายอันก่อให้เกิดการพัฒนาฐานความรู้แบบกึ่งอัตโนมัติและช่วยให้ผู้เชี่ยวชาญทำงานน้อยลงหรือง่ายขึ้น

ดังนั้นระบบการค้นคืนเชิงความหมายสามารถประยุกต์ใช้การคัดเลือกคุณลักษณะด้วยเทคนิคการจำแนกข้อความเพื่อใช้สร้างคลาสหรือซับคลาส ซึ่งปัจจุบันงานส่วนนี้ส่วนใหญ่ต้องให้ผู้เชี่ยวชาญเป็นผู้กำหนด ส่วนการเชื่อมโยงบริบทของคำต่าง ๆ ที่เกิดขึ้นหรือมีความหมายเดียวกันสามารถเลือกใช้จากการหาค่ากฎของความสัมพันธ์ (Association Rule)

6. เอกสารอ้างอิง

[1] C. Haruechaiyasak, W. Jitkrittum, C.Sangkeettra-karn, and C. Damrongrat, “Implementing news article category browsing based on text categorization technique”, The 2008 IEEE/WIC/-ACM International Conference on Web Intelligence (WI-08) workshop on Intelligent Web Interaction (IWI 2008), 2008, pp.143-146.

[2] K. Thongklin, S. Vanichayobon and W. Wett, “Word sense disambiguation and attribute selection using gain ratio and rbf neural network”, IEEE International Conference Innovation and Vision for the Future in Computing & Communication Technologies (RIVF’ 08), 2008.

[3] P. Saengsiri, P. Meesad, S. Na Wichian and U. Herwig, “Comparison of hybrid feature selection models on gene expression data”, IEEE International Conference on ICT and Knowledge Engineering, 2010, pp.13 -18.

[4] V. Nuipian, P. Meesad and P. Boonrawd, "Improve abstract data with feature selection for classification techniques", Advanced Materials Research 403-408, 2012, pp. 3699-3703.

[5] P. Thamrongrat, L. Preechaveerakul and W. Wettayaprasit, "A novel voting algorithm of multi-class svm for web page classification", The 2nd IEEE International Conference on Computer Science and Information Technology, 2009.

[6] R.J. Mooney and U. Nahm, "Text mining with information extraction", Proceedings of the 4th International MIDP Colloquium, September, 2003.

[7] P. Meesad, V. Nuipian and P. Boonrawd, "A Chi-Square-Test for word importance differentiation in text classification" Proceedings of 2011 International Conference on Information and Electronics Engineering (ICIEE 2011), 2011, pp. 110-114.

[8] P.N. Tan, M. Steinbach, and K. Vipin, "*Introduction to Data Mining*", Addison Wesley, 2006, pp.150-163.

[9] J.R. Quinlan, "Induction of decision trees", Machine Learning 1, 1968, pp. 81-106.

[10] W. Sukontip, "Comparison of attribute selection techniques and algorithms in classifying mistaken behaviors of vocational education students", Master Thesis, Department of Computer Science, Kasetsart University, 2008. (in Thai)

[11] J.H. Holland, "Genetic algorithm", Scientific American july, 1992. Available: http://www.-casos.cs.cmu.edu/education/phd/classpapers/Holland_Genetic_1992.pdf, 6 March 2012.

[12] G.L. Bretthorst, "Bayesian spectrum analysis and parameter estimation", Lecture Notes in Statistics, 48, Springer-Verlag, New York, 1988.

[13] B. Links, "A detailed introduction to K-Nearest Neighbor (KNN) algorithm", Available: http://saravananthirumuruganathan.wordpress.com/2010/05/17/a-detailed-introduction-to-k-nearest-neighbor-knn-algorithm/, accessed on 2 February 2011.

[14] V. Vapnik, "*The Nature of Statistical Learning Theory*", Springer, New York, 1995.

[15] C.J. Burges, "A tutorial on support vector machines for pattern recognition", Data Mining and Knowledge Discovery 2, 1998, pp. 121–167.

[16] Association for Computing Machinery (ACM, Copyright 2009-2010), Available: http://portal.-acm.org/portal.cfm, accessed on 4 May 2008.