

การคัดแยกเอกสารสำคัญออกจากเอกสารทั่วไปด้วยวิธีอัตโนมัติ



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิគฤตศาสตรมหาบัณฑิต

สาขาวิชาวิគฤตศาสตร์คอมพิวเตอร์และโทรคมนาคม คณะวิគฤตศาสตร์ มหาวิทยาลัยธุรกิจบัณฑิตย์

พ.ศ. 2555

Confidential Document Classification from General Document Using SVM



A Thesis Submitted in Partial Fulfillment of the Requirements

for the Degree of Master of Engineering

Department of Computer and Telecommunication

Faculty of Engineering, Dhurakij Pundit University

2012

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้ประสบผลสำเร็จลงได้ ด้วยความช่วยเหลืออย่างดีอ่ำงคือของอาจารย์ในภาควิชาชีวกรรมคอมพิวเตอร์ และโภคณนาคม ท่านอาจารย์ ดร.ชัยพร เบมະกาตะพันธ์ อาจารย์ที่ปรึกษาวิทยานิพนธ์ ที่ให้คำแนะนำ ชี้แนะข้อคิดต่างๆ ในการศึกษาวิจัย ตลอดจนแนวทางในการแก้ไขปัญหาต่างๆ ทบทวนวิธีการวิจัย เพื่อความสมบูรณ์ และถูกต้อง และเอาใจใส่ข้าพเจ้ามาโดยตลอด จึงขอกราบขอบพระคุณเป็นอย่างสูงมา ณ โอกาสนี้

ขอขอบพระคุณ ดร.ประสาสน์ จันทร์พิพิธ ประธานคณะกรรมการสอบวิทยานิพนธ์ รวมทั้ง ดร.ณรงค์เดช กิรติพرانนท์ และ ดร.เงนจัน วีระพาณิชเจริญ ที่สละเวลา มาเป็นกรรมการสอบวิทยานิพนธ์ และกรุณากล่าวให้คำแนะนำที่เป็นประโยชน์ต่องานวิจัย ขอบคุณ เจ้าหน้าที่ทุกท่านที่ช่วยดำเนินเรื่องต่างๆ ให้เป็นอย่างดี

ขอขอบพระคุณอาจารย์ และเจ้าหน้าที่ในภาควิชาชีวกรรมคอมพิวเตอร์ และโภคณนาคมทุกท่านที่ได้ประสิทธิประสานวิชาความรู้ และให้ความช่วยเหลือมาโดยตลอด ขอบคุณเพื่อนทุกท่าน ที่ให้คำปรึกษา ให้ความช่วยเหลือ ตลอดระยะเวลาการศึกษา รวมทั้ง เจ้าหน้าที่ของสายงานเทคโนโลยีสารสนเทศ การประสานครุหลวง ที่ได้ให้กำลังใจ และให้ความช่วยเหลือข้าพเจ้ามาโดยตลอด

ความดีอันเกิดจากการศึกษาค้นคว้านี้ ผู้เขียนขอขอบคุณบิดา มารดา ครู อาจารย์ และผู้มีพระคุณทุกท่าน ผู้เขียนมีความซาบซึ้งในความกรุณาอันดีอ่ำงจากทุกท่านที่ได้กล่าวมา และขอกราบขอบพระคุณมา ณ โอกาสนี้

อรทิพิพิธ เลือยงาม

สารบัญ

	หน้า
บทคัดย่อภาษาไทย	๔
บทคัดย่อภาษาอังกฤษ.....	๕
กิตติกรรมประกาศ.....	๖
สารบัญตาราง	๗
สารบัญรูป	๘
บทที่ 1 บทนำ.....	1
1.1 ที่มาของงานวิจัย.....	1
1.2 วัตถุประสงค์.....	2
1.3 ขอบเขตของการวิจัย.....	2
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	2
1.5 แผนการดำเนินงาน.....	3
บทที่ 2 ทฤษฎีและผลงานวิจัยที่เกี่ยวข้อง.....	4
2.1 เทคโนโลยีการป้องกันข้อมูลรั่วไหล (Data Leakage Prevention :DLP).....	4
2.2 Symantec DLP Solution.....	9
2.3 มาตรฐานด้านความมั่นคงปลอดภัยทางด้านสารสนเทศ ISO/IEC27001:2005	12
2.4 กฎหมายกับความมั่นคงปลอดภัยสารสนเทศ.....	15
2.5 เทคโนโลยีการแยกประเภทเอกสาร (Document Classification).....	15
2.6 ทฤษฎี SVM (Support Vector Machine).....	21
2.7 งานวิจัยที่เกี่ยวข้อง.....	25
บทที่ 3 ระเบียบวิธีวิจัย.....	32
3.1 แนวทางการวิจัยและพัฒนา.....	32
3.2 กระบวนการนำเสนอเอกสาร.....	37
3.3 กระบวนการหาค่า \hat{y} หนักคำ และเลือกคุณลักษณะ.....	39
3.4 กระบวนการแยกประเภทเอกสาร.....	44
3.5 อัตราความถูกต้อง (Accuracy Rate).....	46

สารบัญ (ต่อ)

	หน้า
บทที่ 4 ผลการศึกษา.....	47
4.1 กระบวนการทดสอบ.....	48
4.2 การวัดประสิทธิภาพ.....	51
4.3 ผลการทดสอบ.....	52
บทที่ 5 สรุปผลการศึกษา.....	63
5.1 สรุปผลการศึกษา.....	63
5.2 ปัญหา และข้อเสนอแนะ.....	64
บรรณานุกรม.....	65
ภาคผนวก.....	70
ประวัติผู้เขียน.....	81

สารบัญตาราง

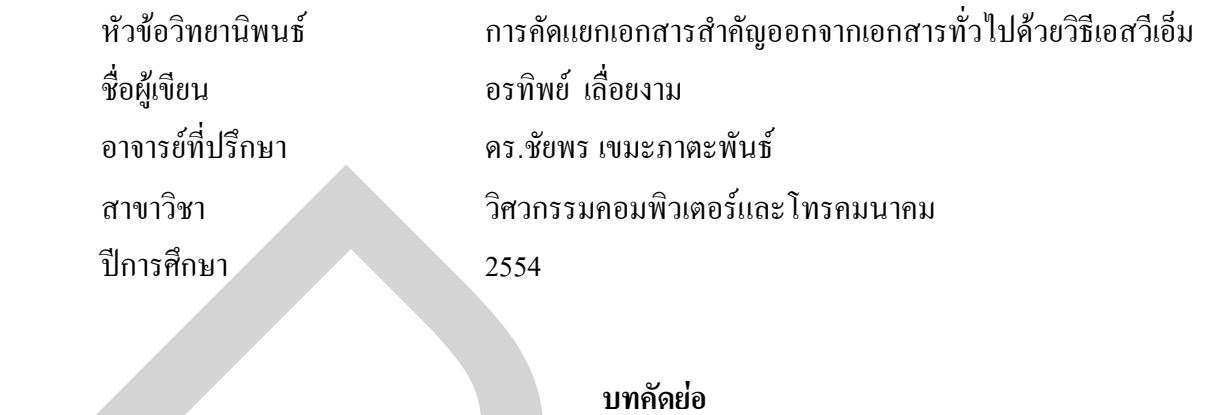
ตารางที่		หน้า
2.1	คุณสมบัติการทำงานของผลิตภัณฑ์ DLP ที่มีจำนวนข่ายอยู่ในปัจจุบัน.....	8
2.2	ชนิดของเครื่องพิมพ์ฟังก์ชั่น.....	25
3.1	รายละเอียดกระบวนการของขั้นตอนในการดำเนินงานวิจัย.....	33
3.2	แสดงตัวอย่างค่าเวกเตอร์ลักษณะสำคัญ (Feature Vector).....	41
3.3	ค่าน้ำหนักคำของเอกสาร D_i และคำ W_j	42
4.1	รายละเอียดของเอกสารที่ใช้ในการฝึกสอนและทดสอบการแยกประเภทเอกสาร	48
4.2	ค่าน้ำหนักคำของแต่ละเอกสารที่แบ่งตามค่าคุณลักษณะ (Feature) ที่ได้เลือกไว้	50
4.3	ค่าตัวแปรที่ได้จากการแยกประเภทเอกสารชุดฝึกสอน.....	53
4.4	ค่าน้ำหนักคำตามคุณลักษณะของเอกสารชุดทดสอบจำนวน 60 เอกสาร.....	54
4.5	เปรียบเทียบค่าความถูกต้องของการคัดแยกประเภทเอกสารด้วยจำนวนคุณลักษณะในการทดสอบกับข้อมูลชุดทดสอบอกรุ่นปีหมาย.....	60
4.6	เปรียบเทียบค่าความถูกต้องของการคัดแยกประเภทเอกสารด้วยจำนวนคุณลักษณะในการทดสอบกับข้อมูลชุดทดสอบกลุ่มปีหมาย.....	61

สารบัญ

รูปที่	หน้า
2.1 รูปแบบของ DLP (Data Loss Prevention System Model).....	5
2.2 โครงสร้างเครือข่ายของการใช้งานระบบ DLP.....	9
2.3 แผนผังการทำงานของ Symantec Data Loss Prevention.....	10
2.4 การทำงานระหว่าง Data Insight และ Symantec Data Loss Prevention Server ..	11
2.5 การตอบสนองแบบอัตโนมัติต่อเหตุการณ์ต้องสงสัย.....	12
2.6 Plan-Do-Check-Act Cycle.....	13
2.7 กระบวนการของการสกัดลักษณะสำคัญและแบ่งกลุ่มข้อมูล.....	19
2.8 รูปแบบแสดงความสัมพันธ์ระหว่างคำ และเอกสารทั้งหมดด้วยเวกเตอร์ 2 มิติ...	21
2.9 แผนผังการทำงานของ Support Vector Machines.....	22
2.10 ตัวอย่างการแยกข้อมูลด้วย SVM.....	23
3.1 แผนผังการทำงานของการนำเอกสารที่ถูกแยกประเภทแล้วเข้าสู่ Symantec DLP	34
3.2 กระบวนการของขั้นตอนในการดำเนินงานวิจัย.....	35
3.3 ขั้นตอนการแปลงไฟล์เอกสาร (Text Processing).....	36
3.4 แปลงไฟล์เอกสาร Microsoft word.doc เป็นไฟล์ข้อความ .txt.....	37
3.5 การตัดคำภาษาไทย โดยใช้โปรแกรม SWATH.....	38
3.6 การกำจัดคำหยุด.....	39
3.7 การหาค่าน้ำหนักคำของแต่ละเอกสาร.....	39
3.8 การเลือกคุณลักษณะและสกัดค่าคุณลักษณะ.....	40
3.9 ขั้นตอนการทำงานของ LS-SVM Model.....	45
3.10 กราฟเปรียบเทียบประสิทธิภาพของ Kernel Function.....	46
4.1 ขั้นตอนการฝึกสอนและทดสอบการแยกประเภทเอกสาร โดยวิธี LS-SVM.....	49
4.2 กราฟแสดงผลการแยกประเภทเอกสารชุดฝึกสอนด้วยวิธี LS-SVM จำนวน 145 เอกสาร โดยใช้จำนวนคุณลักษณะ 40 คุณลักษณะ.....	52
4.3 กราฟแสดงผลการแยกประเภทเอกสารด้วยวิธี LS-SVM กับชุดข้อมูลทดสอบ จำนวน 60 เอกสาร โดยใช้คุณลักษณะจำนวน 10 คุณลักษณะ.....	56

สารบัญรูป (ต่อ)

รูปที่	หน้า
4.4 กราฟแสดงผลการแยกประเภทเอกสารด้วยวิธี LS-SVM กับชุดข้อมูลทดสอบ จำนวน 60 เอกสาร โดยใช้คุณลักษณะจำนวน 20 คุณลักษณะ.....	57
4.5 กราฟแสดงผลการแยกประเภทเอกสารด้วยวิธี LS-SVM กับชุดข้อมูลทดสอบ จำนวน 60 เอกสาร โดยใช้คุณลักษณะจำนวน 30 คุณลักษณะ.....	58
4.6 กราฟแสดงผลการแยกประเภทเอกสารด้วยวิธี LS-SVM กับชุดข้อมูลทดสอบ จำนวน 60 เอกสาร โดยใช้คุณลักษณะจำนวน 40 คุณลักษณะ.....	59



วิทยานิพนธ์นี้นำเสนอและออกแบบกระบวนการคัดแยกเอกสารสำคัญออกจากเอกสารทั่วไปด้วยวิธีอสูร์เอนซ์ เพื่อใช้เป็นต้นแบบสำหรับการกรองเอกสารในระบบการป้องกันข้อมูลรั่วไหลด้วย Data Loss Prevention (DLP) โดยเป็นผลิตภัณฑ์ของ Symantec เพื่อใช้ในการบริหารจัดการความมั่นคงของข้อมูล ซึ่งการประปานครหลวงได้นำมาพัฒนาใช้งานเพื่อป้องกันเอกสารที่เป็นความลับรั่วไหล อย่างไรก็ตามระบบดังกล่าวยังขาดประเภทเอกสารที่เป็นต้นแบบของการกรองข้อมูลสำคัญ และเพื่อลดเวลาการคัดแยกเอกสารซึ่งมีปริมาณมากและยากต่อการทำหนดระดับความสำคัญ จึงทำการพัฒนาวิธีการคัดแยกประเภทเอกสาร โดยใช้เทคนิคการแยกประเภทแบบมีผู้สอนด้วยวิธี SVM โดยประมาณลอกสารเป็นเวกเตอร์คำนำหนัก TF-IDF นำคำนำหนักที่ได้เข้าสู่กระบวนการแยกประเภทเอกสารด้วย LS-SVM โดยมีข้อจำกัดว่าเอกสารต้นแบบดังกล่าวต้องไม่มีการแก้ไขระดับความสำคัญอีกในภายหลัง ผลการทดสอบประสิทธิภาพการคัดแยกประเภทเอกสาร โดยแบ่งออกเป็น 2 กรณีได้แก่ กรณีที่ 1 คือการคัดแยกประเภทเอกสารกับชุดทดสอบนอกกลุ่มเป้าหมาย ได้ค่าความถูกต้องตามคุณลักษณะที่เลือกใช้คำสำคัญจำนวน 10, 20, 30 และ 40 คำ เป็น 83.33%, 81.67%, 80.00% และ 83.33% ตามลำดับ ขณะที่กรณีที่ 2 คือการคัดแยกประเภทเอกสารกับชุดทดสอบกลุ่มเป้าหมาย ให้ค่าความถูกต้องตามคำสำคัญที่เลือกใช้คำสำคัญจำนวน 10, 20, 30 และ 40 คำ เป็น 83.33%, 88.33%, 86.67% และ 86.67% ตามลำดับ จากผลการทดสอบแสดงให้เห็นว่ากระบวนการที่นำเสนอ มีค่าความถูกต้องอยู่ในเกณฑ์สูงและยอมรับได้ อย่างไรก็ตามค่าความถูกต้องของกระบวนการคัดแยกประเภทเอกสารในกลุ่มเป้าหมายสูงกว่าเมื่อเทียบกับการทดสอบกับข้อมูลนอกกลุ่มเป้าหมาย ดังนั้นถ้าสามารถจำกัดขอบเขตของกลุ่มเป้าหมายและคัดเลือกคุณลักษณะเป็นตัวแทนที่ดีของชุดเอกสาร รวมทั้งจำนวนคุณลักษณะที่เลือกใช้อย่างเหมาะสม ก็จะมีประสิทธิภาพในการคัดแยกประเภทเอกสารดีขึ้น

Thesis Title	Confidential Document Classification from General Documents Using SVM
Author	Orathip Lueyngam
Thesis Advisor	Dr. Chiyaporn Khemapatapan
Department	Computer and Telecommunication Engineering
Academic Year	2011

ABSTRACT

This thesis proposes and designs the procedure for classifying confidential documents from general documents by using SVM method. The classified document will be used as a reference for filtering document in Data Loss Prevention (DLP) system, the Symantec's product, used in security management. Metropolitan Waterworks Authority (MWA) adopt this Symantec's system to use in the organization to protect the leakage of confidential documents. However, the system needs many reference documents to be used as filtering references. Thus, the system takes much time before use if references are manually selected. So, document classifying procedure based on training using SVM method has been proposed. The procedure will process the documents for finding TF-IDF weight and classify documents by using LS-SVM. The limitation of this procedure is that reference documents cannot be revised later. The results from 2 testing cases found that 1) testing documents out of target documents will provide accuracy about 83.33%, 81.67%, 80.00% and 83.33% for the feature set of 10, 20, 30 and 40 words, respectively, 2) testing documents in target documents will provide accuracy about 83.33%, 88.33%, 86.67% and 86.67% for the feature set of 10, 20, 30 and 40 words, respectively. It can be noted that the proposed procedure has high accuracy and is acceptable. However, testing documents in target group can provide higher accuracy than testing documents out of target group. Thus, if document can be targeted and grouped before processing, the procedure will be more efficiency.

บทที่ 1

บทนำ

1.1 ที่มาของงานวิจัย

ในสังคมยุคดิจิตรัลทุกวันนี้ องค์กรต่างๆ มีการปรับตัว โดยนำระบบคอมพิวเตอร์มาใช้ในการจัดการในเรื่องของข้อมูลอย่างแพร่หลาย ไม่ว่าจะเป็นสื่อสารผ่านอินเทอร์เน็ต การสื่อสารผ่านสื่ออิเล็กทรอนิกส์ นั่นแสดงว่าข้อมูล และสารสนเทศต่างๆ มีการจัดทำขึ้นมากมาย เพื่อใช้ในการดำเนินธุรกิจ และถือว่าเป็นสินทรัพย์ของธุรกิจ สินทรัพย์เหล่านี้มีความสำคัญที่องค์กรต้องป้องกัน จากสภาพแวดล้อมในปัจจุบันที่ต้องติดต่อสื่อสารกันมากขึ้น ทำให้เกิดปัญหา และจุดอ่อนหลักหลายรูปแบบที่ทำให้สารสนเทศนั้นเสียหาย หากมองอีกมุมมองหนึ่งก็เป็นภัยร้ายแรงต่อองค์กรได้ เช่นกัน หากข้อมูลต่างๆ เหล่านี้ตกอยู่ในมือของผู้ที่ไม่ประสงค์ดี หรือผู้ที่ไม่สมควร

สิ่งเหล่านี้นำไปสู่การรั่วไหลของข้อมูล ได้ทั้งนั้น และพบว่าสาเหตุของการรั่วไหลส่วนมากเกิดจากบุคลากรในองค์กร สิ่งสำคัญ คือความเข้าใจในเรื่องของช่องทางการรั่วไหลของข้อมูลว่ามีช่องทางใดบ้าง จะได้กำหนด และจัดทำมาตรการควบคุมที่เหมาะสม การจัดหมวดหมู่ของข้อมูล การแยกประเภทข้อมูลตามคุณค่าที่มีต่องค์กร และผลกระทบถ้าหากข้อมูลเหล่านี้ถูกนำไปเผยแพร่ หรือแก้ไข

จากปัญหาข้างต้น จึงได้นำเสนอระบบการจัดประเภทเอกสารเพื่อนำเข้าสู่กระบวนการทำงานร่วมกับโซลูชันด้านการรักษาความมั่นคงปลอดภัยของเอกสาร ในส่วนของการป้องกันข้อมูลรั่วไหล DLP (Data Leakage Prevention) เพื่อควบคุมการไหลของเอกสารสำคัญ และบังคับใช้นโยบายการป้องกันข้อมูลสำคัญ โดยศึกษาเทคนิคที่ใช้กันอยู่ในปัจจุบันคือเทคนิคการจำแนกประเภทเอกสาร โดยมีการทำหนดประเภทเอกสารไว้ล่วงหน้า เทคนิคนี้จะทำการสอนให้ระบบรู้จำรูปแบบเอกสาร ในแต่ละประเภทเดียวกัน หลังจากนั้นจึงนำเอกสารที่ต้องการจำแนกประเภทเข้าไปในระบบ ให้ระบบทำการแยกประเภทเอกสารเพื่อสร้างโครงรูป (Template) ตามประเภทเอกสารที่กำหนด (เอกสารสำคัญ และเอกสารทั่วไป) โดยใช้ทฤษฎีที่เกี่ยวข้องคือ TF-IDF (Term Frequency and Inverse Document Frequency) เป็นวิธีการคำนวณค่าน้ำหนักจากความถี่ของคำที่ปรากฏในเอกสาร และ SVM (Support Vector Machine) เป็นขั้นตอนการใช้งานตัวจำแนก นำมาสนับสนุนการแยกประเภทเอกสาร ก่อนนำเข้าสู่โซลูชันของการป้องกันข้อมูลรั่วไหลเพื่อลดเวลา

ในการคัดแยกประเภทเอกสารเพื่อสร้างโครงรูปไประบบ และทดสอบประสิทธิภาพของการคัดแยกประเภทเอกสาร โดยหาค่าความถูกต้อง (Accuracy Rate)

จากการแก้ปัญหาข้างต้น ยังส่งผลเพื่อสร้างความมั่นใจว่าข้อมูลความลับ และสารสนเทศ ยังถูกเก็บรักษาอยู่ครบถ้วนปลอดภัย และเพื่อป้องกันการดำเนินธุรกิจให้เป็นไปอย่างต่อเนื่อง ซึ่งสอดคล้องกับการนำระบบต่างๆ มาใช้เพื่อให้มีประสิทธิภาพ และเกิดความน่าเชื่อถือในการที่จะควบคุมข้อมูลต่างๆ ให้เป็นไปอย่างสาคด เช่น COBIT, ITIL, ISO/IEC27001:2005, ISO17799:2005 และระบบที่เป็นที่นิยมใช้กันอย่างแพร่หลาย ครอบคลุมข้อมูลทุกประเภท และมีความน่าเชื่อถือในระดับสาคดคือ ISO/IEC27001:2005 และ ISO17799:2005

1.2 วัตถุประสงค์ของงานวิจัย

- 1 ศึกษาการบริหารจัดการเกี่ยวกับการป้องกันข้อมูลรั่วไหล เพื่อให้เกิดความชัดเจนในเรื่องของกระบวนการทำงานของระบบ
- 2 ศึกษาเทคนิคที่นำมาปรับใช้สำหรับการแยกประเภทเอกสาร เพื่อนำไปใช้งานเป็นโครงรูปในการคัดกรองของระบบการป้องกันเอกสารรั่วไหล
3. พัฒนาระบบการแยกประเภทเอกสารสำคัญออกจากเอกสารทั่วไปก่อนนำเข้าระบบการป้องกันเอกสารรั่วไหลของ การประปานครหลวงผ่านทางอุปกรณ์ Symantec DLP
4. ทดสอบประสิทธิภาพของการแยกประเภทเอกสาร โดยใช้ค่าความถูกต้อง (Accuracy Rate)

1.3 ขอบเขตของงานวิจัย

1. วิเคราะห์และศึกษาหลักการทำงานของระบบการป้องกันการรั่วไหลของข้อมูล เทคนิคการให้หน้าหนักคำ และเทคนิคการแยกประเภทเอกสาร เพื่อนำผลลัพธ์จากการแยกประเภทเอกสารไปเป็นโครงรูปในการคัดกรองของระบบการป้องกันเอกสารรั่วไหล
2. พัฒนาระบบการแยกประเภทเอกสารลับออกจากเอกสารทั่วไปก่อนนำเข้าระบบการป้องกันเอกสารรั่วไหลของ การประปานครหลวงผ่านทางอุปกรณ์ Symantec DLP

1.4 ประโยชน์ที่คาดว่าจะได้รับ

ความชัดเจนเกี่ยวกับหลักการทำงานของระบบการป้องกันการรั่วไหลของข้อมูล และสามารถแยกประเภทเอกสารลับออกจากเอกสารทั่วไป เพื่อกำหนดประเภทของข้อมูลจากเอกสาร สำคัญที่ต้องการป้องกัน โดยสามารถลดระยะเวลาที่ใช้ในการคัดแยกประเภทเอกสาร และนำ

ผลลัพธ์ที่ได้จากการคัดแยกไปเป็นโครงรูปในการคัดกรองของระบบการป้องกันข้อมูลรั่วไหล Symantec DLP เพื่อเพิ่มประสิทธิภาพการทำงานของระบบการป้องกันข้อมูลรั่วไหลต่อไป

1.5 แผนการดำเนินงาน

เหตุ因	2553		2554						2555	
	ตค.	ธค.	กพ.	เมย.	มิย.	สค.	ตค.	ธค.	กพ.	เมย.
1. ศึกษาระบบการป้องกันข้อมูลรั่วไหล	↔	↔								
1.1 เทคโนโลยี DLP	↔									
1.2 นโยบายการป้องกันข้อมูลรั่วไหล	↔	↔								
1.3 การทำงานของ Symantec DLP	↔	↔								
2. ศึกษาการแยกประเภทเอกสาร		↔	↔							
2.1 เทคนิคการตัดคำภาษาไทย		↔								
2.2 เทคนิคการให้น้ำหนักคำ TF-IDF		↔								
2.3 ทฤษฎี SVM		↔								
3. วิเคราะห์และศึกษาแนวทางการพัฒนา			↔	↔						
3.1 พัฒนาระบบการแยกประเภทเอกสาร				↔	↔					
3.2 กระบวนการนำเข้าเอกสาร				↔	↔					
3.3 กระบวนการแยกประเภทเอกสาร				↔	↔					
4. วิเคราะห์ผลการทดสอบ					↔	↔				
5. ศึกษาวิธีการตรวจสอบความน่าเชื่อถือของทดสอบ Accuracy Rate						↔	↔			
6. รวบรวมข้อมูลจัดทำวิทยานิพนธ์							↔	↔		

บทที่ 2

ทฤษฎีและผลงานวิจัยที่เกี่ยวข้อง

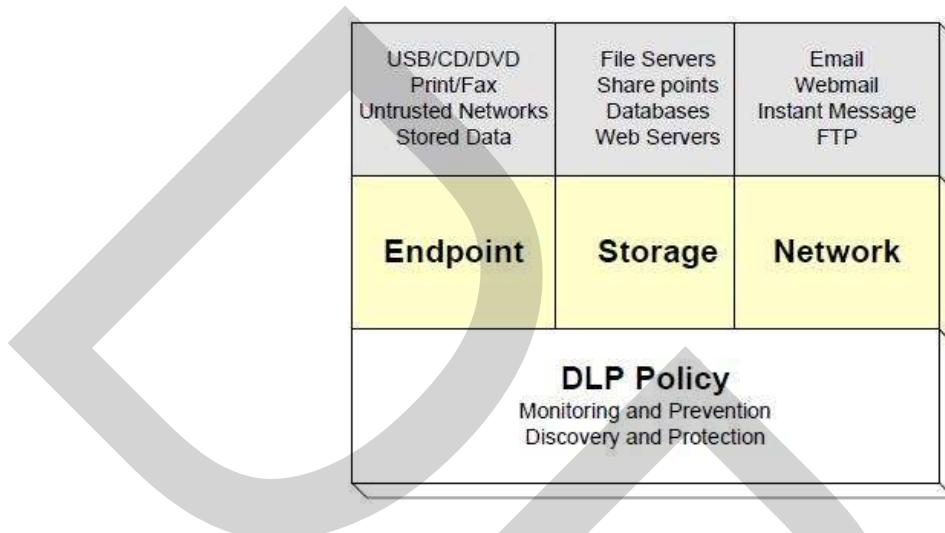
2.1 เทคโนโลยีการป้องกันข้อมูลรั่วไหล (Data Leakage Prevention : DLP)

กระบวนการทำงานและวิธีการป้องกันการรั่วไหลของข้อมูลสำคัญ ในการถ่ายโอนโดยไม่ได้รับอนุญาต หรือเปิดเผยข้อมูลสำคัญ เพื่อลดความเสี่ยงจากการถูกขโมย และสูญเสียโอกาส ความสามารถทางธุรกิจ โดยการตรวจสอบและควบคุมการใช้งานข้อมูล รวมทั้งกำหนดนโยบายให้สอดคล้องกับกลยุทธ์และกระบวนการทางธุรกิจ

2.1.1 เทคโนโลยีพื้นฐานของ DLP (Data Leakage Prevention) เทคโนโลยีพื้นฐานของระบบ DLP จะมีโครงสร้างการทำงานดังแสดงในรูปที่ 2.1 และในการสร้างรูปแบบข้อมูลสำคัญนั้น ต้องมีการระบุข้อมูลก่อนการถ่ายโอน โดยใช้อัลกอริทึมในการระบุข้อมูลที่มีรูปแบบ หรือประเภทเดียวกับข้อมูลสำคัญที่ได้ระบุไว้ ลิ่งเหล่านี้อาจทำให้การประมวลผลซ้ากว่าปกติ อัลกอริทึมที่นำมาใช้ปรับใช้ครั้งละภาระการทำงานที่เป็นระบบ และสามารถระบุข้อมูลสำคัญ โดยลดข้อมูลเดียวที่เกี่ยวกับเอกสารให้เล็กลง เพื่อจ่ายต่อการนำไปใช้ในระบบ ส่วนประกอบที่ได้รับการพิจารณาเพื่อป้องกันการรั่วไหลของข้อมูลภายในองค์กรประกอบด้วยข้อมูลเคลื่อนไหว (Data in motion) คือ ข้อมูลใด ๆ ที่มีการเคลื่อนไหวผ่านทางเครือข่ายไปยังภายนอกผ่านทางอินเทอร์เน็ต ข้อมูลที่มีอยู่ (Data at rest) คือ ข้อมูลที่อยู่ในระบบแฟ้มฐานข้อมูล หรือการจัดเก็บข้อมูลด้วยวิธีการอื่น และข้อมูล ณ จุดปลายทาง (Data in Use) คือ ข้อมูล ณ จุดสิ้นสุดของเครือข่ายสำหรับเครื่องคอมพิวเตอร์ และอุปกรณ์ต่อพ่วง รวมถึงอุปกรณ์จัดเก็บข้อมูลแบบพกพา โดยพื้นฐานแล้วจะต้องทราบเกี่ยวกับความหมายของการรั่วไหล ช่องทางการรั่วไหล และวิธีการที่ทำให้ข้อมูลรั่วไหล รวมทั้งผลกระทบที่อาจเกิดขึ้นได้ ดังต่อไปนี้

2.1.1.1 การรั่วไหลของข้อมูล เกิดจากช่องโหว่ของการจัดเก็บไฟล์ข้อมูล ซึ่งเป็นข้อมูลที่มีค่าต่อองค์กร และเกิดผลกระทบถ้าหากข้อมูลถูกนำไปเผยแพร่หรือนำไปใช้ประโยชน์เพื่อแสวงหาผลประโยชน์ของผู้ประสงค์ร้ายหรือนำไปใช้อย่างไม่เหมาะสม โดยแบ่งระดับความสำคัญของข้อมูลออกเป็น 4 ระดับคือ ข้อมูลสาธารณะ (เปิดเผยสู่สาธารณะชนได้โดยไม่ส่งผลกระทบใดๆ ต่อองค์กร) ข้อมูลภายใน (เอกสารที่ใช้ติดต่อภายในองค์กร บันทึกข้อความ หรือข้อมูลที่เกิดจากดำเนินธุรกิจ) ข้อมูลลับ (ข้อมูลทางธุรกิจ การเงิน และข้อมูลอื่นที่ไม่ใช่ข้อมูลทางห้ามหาก)

ข้อมูลเหล่านี้ถูกเผยแพร่อาจส่งผลเสียต่อองค์กรได้ ข้อมูลทางห้าม (ข้อมูลที่ประกอบด้วยข้อมูลที่มีการควบคุมการเข้าถึง การจัดเก็บ หรือประมวลผลตามกฎหมาย หรือข้อบังคับที่องค์กรกำหนด)



รูปที่ 2.1 รูปแบบของ DLP (Data Loss Prevention System Model)

2.1.1.2 การรั่วไหลแบ่งออกได้เป็น การรั่วไหลโดยตั้งใจ เช่นการส่งข้อมูลออกภายนอกองค์กร ซึ่งอาจจะเป็นการขโมย ลับ หรือแก้ไขข้อมูลสำคัญ หรือการรั่วไหลโดยไม่ตั้งใจ เช่นการแนบไฟล์เอกสารไปกับจดหมายอิเล็กทรอนิกส์ การนำไปแสดงไว้บนเว็บบอร์ด หรือเว็บไซต์ที่ให้บริการอัพโหลด ดาวน์โหลด โดยที่ไม่ถึงการณ์ ลิ่งเหล่านี้อาจเกิดจากบุคคลในองค์กรที่ขาดความรู้ความเข้าใจในเรื่องของการใช้งานเทคโนโลยี และความรู้ที่ไม่ถึงการณ์ หรือบุคคลภายนอกองค์กร ซึ่งถือว่าเป็นภัยคุกคามที่มากับการใช้งานเครื่อข่ายโดยขาดความรู้ความเข้าใจและตระหนักในเรื่องของความปลอดภัย ทำให้นำพาภัยคุกคามเข้ามาติดตั้งที่เครื่องคอมพิวเตอร์ กล้ายเป็นช่องโหว่ของระบบ และเป็นอิกุดหนึ่งที่ทำให้ข้อมูลสำคัญหลุดรั่วออกไป

2.1.1.3 วิธีการรั่วไหล แบ่งออกได้เป็น 2 ช่องทางใหญ่ๆ คือการรั่วไหลผ่านทางเครือข่าย และอุปกรณ์ปลายทาง รวมทั้งอุปกรณ์ต่อพ่วงด้วย การรั่วไหลผ่านทางเครือข่าย (การแนบไฟล์ไปกับจดหมายอิเล็กทรอนิกส์ หรือนำไปวางไว้บนเครือข่ายอินเตอร์เน็ตที่ให้บริการอัพโหลด หรือดาวน์โหลด) การรั่วไหลผ่านทางอุปกรณ์ปลายทาง (คอมพิวเตอร์ โทรศัพท์มือถือ สมาร์ทโฟน แท็บเล็ต หรือ CD/DVD, USB, MP3)

2.1.1.4 ผลกระทบ เมื่อบุคคลผู้ไม่มีสิทธิ์ได้รับข้อมูลสำคัญเหล่านี้ ไม่เพียงแต่จะทำให้เกิดความเสียหายต่อความสามารถในการแข่งขันทางธุรกิจเท่านั้น แต่ในปัจจุบันด้วยกฎระเบียบใน

เรื่องการป้องกันความลับของข้อมูล โดยเน้นพางานสำคัญ เช่น ธุรกิจการบริการซึ่งต้องรักษาความลับของลูกค้าไว้ ธุรกิจการเงิน และการแพทย์ ถึงแม้ว่าจะมีการรั่วไหลเพียงเล็กน้อยเดียว ก็อาจจะทำให้องค์กรต้องถูกฟ้องร้องจากเจ้าของข้อมูล และหน่วยงานภาครัฐที่ควบคุมกฎหมายเบียบในเรื่องของการป้องกันความลับของข้อมูลด้วย

2.1.2 พื้นฐานของนโยบายการรักษาความปลอดภัย ในการรักษาของข้อมูลสำคัญนั้น พื้นฐานของนโยบายการรักษาความปลอดภัยมีความสำคัญด้วยเหตุผลทางการ ในเรื่องของบทบาทความรับผิดชอบของเจ้าหน้าที่ขององค์กร และผู้ที่เข้ามาปฏิบัติงานจากภายนอก ซึ่งช่องโหว่จากภัยคุกคามที่เกิดขึ้นกับข้อมูลสำคัญ เป็นปัญหาที่เกี่ยวข้องกับระบบสารสนเทศที่พบในปัจจุบัน ขึ้นตอนในการป้องกัน

2.1.2.1 การประเมินความเสี่ยงเพื่อกำหนดกลยุทธ์ และวิธีการในการป้องกันข้อมูลที่เป็นความลับ ในขั้นตอนการดำเนินการสำรวจและประเมินความเสี่ยง

2.1.2.2 ระบุและแยกประเภทข้อมูลที่เป็นความลับ เพื่อกำหนดข้อมูลที่เป็นความลับ หรือไม่เป็นความลับ และกำหนดระดับการป้องกันที่เหมาะสมโดยใช้การจำแนกประเภทข้อมูล

2.1.2.3 พัฒนานโยบายและวิธีการในการป้องกันข้อมูล กำหนดความรับผิดชอบในการป้องกันข้อมูล ทำการเปรียบเทียบข้อมูลที่มีอยู่กับนโยบาย และสร้างนโยบายสำหรับการใช้งานระบบ โดยใชซอฟต์แวร์มาเป็นเครื่องมือในการปฏิบัติตามนโยบาย กันハウว่าข้อมูลที่เป็นความลับเก็บไว้ที่ไหน (Data Discover) เพื่อร่วงการใช้ข้อมูลที่เป็นความลับ (Data Monitor) ปกป้องและป้องกันข้อมูลที่เป็นความลับ (Data Protection) และบริหารจัดการและบังคับใช้นโยบายในการรักษาความปลอดภัยของข้อมูล

2.1.2.4 ปรับใช้เทคโนโลยีเข้ามาช่วยในการบังคับใช้และปฏิบัติตามนโยบาย โดยการนำเทคโนโลยีมาปรับใช้เพื่อช่วยในการดำเนินการตามนโยบาย และบังคับใช้แบบอัตโนมัติ

2.1.2.5 สื่อสารและศึกษาผู้มีส่วนได้ส่วนเสียในการสร้างวัฒนธรรมในการใช้งาน โดยแจ้งให้พนักงานและผู้มีส่วนได้ส่วนเสียในการป้องกันข้อมูลสำคัญ และกระตุ้นพฤติกรรมในการป้องกัน โดยแจ้งให้ทราบ ฝึกอบรม และมีการสื่อสารกันอย่างต่อเนื่อง

2.1.2.6 รวมรวมวิธีการป้องกันข้อมูลในกระบวนการธุรกิจ เพื่อป้องกันข้อมูลที่เป็นความลับขององค์กร โดยรวมรวมกระบวนการทางธุรกิจ และข้อมูลที่เป็นความลับ นำเข้าสู่ระบบ การรักษาข้อมูล

2.1.2.7 ตรวจสอบการใช้งานของผู้เกี่ยวข้อง ตรวจสอบค่าการติดตั้ง และดำเนินการตรวจสอบวิธีการในการประเมินขั้นตอนการป้องกันข้อมูล โดยใช้เทคโนโลยีในการเฝ้าระวัง และเครื่องมือในการตรวจสอบ

2.1.3 วิธีการป้องกันการรั่วไหลของข้อมูล แบ่งออกได้เป็น 3 ขั้นตอนคือ

2.1.3.1 การค้นหาข้อมูล (Data Discover) เป็นกระบวนการค้นหาข้อมูลความลับ ไฟล์เอกสาร และข้อมูลสำคัญต่างๆ ที่กระจัดกระจายอยู่ตามเครื่องถูกบ่าย และไฟล์เซฟเวอร์ต่างๆ เช่น ข้อมูลลูกค้า ข้อมูลทรัพย์สินทางปัญญา รวมทั้งข้อมูลสำคัญอื่นๆ วัตถุประสงค์หลักคือทำให้องค์กรทราบว่าข้อมูลสำคัญขององค์กรถูกจัดเก็บอยู่ที่ใดบ้าง ใครเป็นผู้ใช้ข้อมูล และแต่ละข้อมูลมีระดับความเสี่ยงที่จะถูกนำไปเกิดความสูญเสียในระดับใด การค้นหานั้นระบบเครือข่าย (ข้อมูลในขณะนี้การโอนถ่าย) การค้นหาข้อมูลที่อยู่บนระบบ(ข้อมูลที่จัดเก็บอยู่บน Disk Drive) และการวิเคราะห์ข้อมูล

2.1.3.2 การแยกประเภทข้อมูล (Data Classification) เป็นกระบวนการในการจำแนกข้อมูลตามมูลค่ารวมถึงผลกระทบที่มีต่อองค์กรเมื่อมีการรั่วไหลของข้อมูลจำเป็นต้องมีการจัดลำดับความสำคัญ ในระดับของการควบคุมที่เหมาะสม โดยมีการจำแนกตามการพัฒนามาตรฐาน หรือนโยบายสำหรับการจำแนกข้อมูล ระบุชนิดของข้อมูล โดยแบ่งตามหน่วยงาน ผู้ดูแลระบบ ผู้ใช้งาน แต่ละชนิดข้อมูล การนำร่องรักษาระบบ การประเมินผล หรือการจัดเก็บข้อมูลแต่ละประเภท การจำแนกประเภทของข้อมูลจะเพิ่มตัวควบคุม เพื่อจำกัดการเข้าถึง และการ โอนถ่ายข้อมูลสำคัญ ซึ่งจะช่วยลดปริมาณการรั่วไหลของข้อมูลภายในองค์กร

2.1.3.3 การเฝ้าระวังข้อมูล (Data Monitor) เป็นกระบวนการในการตรวจสอบช่องทางการสื่อสารต่างๆ ขององค์กร การเข้าเว็บไซต์ การใช้งานอีเมลล์ การใช้งานโปรแกรมสนทนากลุ่ม อาทิ Facebook, Twitter, LinkedIn และอื่นๆ ตามนโยบายที่กำหนด เพื่อช่วยตรวจสอบข้อมูลในลักษณะของข้อมูลที่มีการถ่ายโอน ซึ่งจะบอกถึงต้นทาง ปลายทาง และช่องทางที่ทำให้ข้อมูลรั่วไหลออกไปได้ รวมทั้งเพิ่มความสามารถในการจัดการ และควบคุมข้อมูลรั่วไหลในระดับการใช้งานที่เครื่องคอมพิวเตอร์ส่วนบุคคล เป็นการบริหารจัดการเครื่องถูกบ่าย และอุปกรณ์ต่อพ่วงต่างๆ ที่ข้อมูลถูกจัดเก็บไว้บนตัวเครื่องและที่อยู่บนระบบเครือข่าย รวมไปถึงการกำหนดสิทธิ์ของแต่ละบุคคลในการเข้าถึงข้อมูล และการใช้งานอุปกรณ์ต่อพ่วง

2.1.3.4 การป้องกันข้อมูล (Data Protection) เป็นกระบวนการที่ดำเนินการ ตามนโยบายที่ได้กำหนดไว้ในเชิงป้องกัน ที่ระบุต้นทาง ปลายทาง และวิธีการที่อาจทำให้ข้อมูลรั่วไหลออกไปได้ ซึ่งจะเน้นนโยบายการป้องกันข้อมูลกับกระบวนการทางธุรกิจ ให้สามารถรู้ได้ว่า ใคร ทำอะไร ที่ไหน อย่างไร ทำให้สามารถป้องกันข้อมูลสำคัญ และข้อมูลความลับในลักษณะของข้อมูลที่ใช้งาน และข้อมูลที่มีการถ่ายโอนได้โดยกำหนดให้มีการตอบสนองต่อการเข้าถึงข้อมูล เช่น การจำกัดการใช้งานกักข้อมูล เพื่อพิจารณาต่อนอนุญาตให้กระทำการใดๆ กับข้อมูลหรือการเข้ารหัสข้อมูลก่อนการถ่ายโอน รวมทั้งแจ้งเตือนไปยังผู้เกี่ยวข้อง หรือเจ้าของข้อมูลด้วย

จากการศึกษาพบว่าผลิตภัณฑ์ด้านการรักษาความมั่นคงปลอดภัย ในส่วนของการป้องกันข้อมูลรั่วไหลที่มีใช้งานอยู่ในปัจจุบัน มักจะใช้เครื่องมือที่แตกต่างกัน เช่น รูปแบบของข้อมูลสำคัญ ขั้นตอนวิธีการ และกลไกการอกรายงาน สำหรับระบบข้อมูลเพื่อสร้างโครงสร้างพื้นฐานให้เห็นภาพรวมของระบบการป้องกันข้อมูลรั่วไหล จากการค้นคว้าคุณลักษณะของผลิตภัณฑ์ต่างๆ ที่มีอยู่ในปัจจุบันพบว่าบางบริษัททั้ง Code Green Network, GTB Technologies, Vericept, Websense จะนำเสนอผลิตภัณฑ์ DLP ที่ทำในส่วนของการป้องกันข้อมูลรั่วไหลโดยตรง และในส่วนของผู้ผลิตรายใหญ่ เช่น IBM, McAfee, Symantec และ TrendMicro มีการเพิ่มฟังก์ชันของ DLP เพื่อขยายขอบเขตของความปลอดภัย โดยมีการควบรวม เช่น Cisco system ผ่านทาง IronPort ซึ่งเป็นบริษัทย่อยของทาง Cisco เอง โดยได้คุณสมบัติของ DLP เข้าไปในผลิตภัณฑ์ที่เกี่ยวข้องกับการป้องกันเครือข่าย ดังจะนำเสนอคุณลักษณะความสามารถของผลิตภัณฑ์ต่างๆ ตารางที่ 2.1 จะเห็นได้ว่าผลิตภัณฑ์ที่มีอยู่ในปัจจุบันมีฟังก์ชันการใช้งาน ตามคุณสมบัติหลักของระบบ การป้องกันข้อมูลรั่วไหลคือ การกันหาข้อมูล การเฝ้าระวัง และการป้องกัน ซึ่งในแต่ละคุณสมบัติ จะมีการนำเทคโนโลยีเข้ามาช่วย ในการแยกประเภทข้อมูลเพื่อรับ หรือจำแนกข้อมูลที่จะกำหนดให้เป็นข้อมูลระดับไหนข้อมูลที่เป็นความลับ หรือข้อมูลทั่วไป

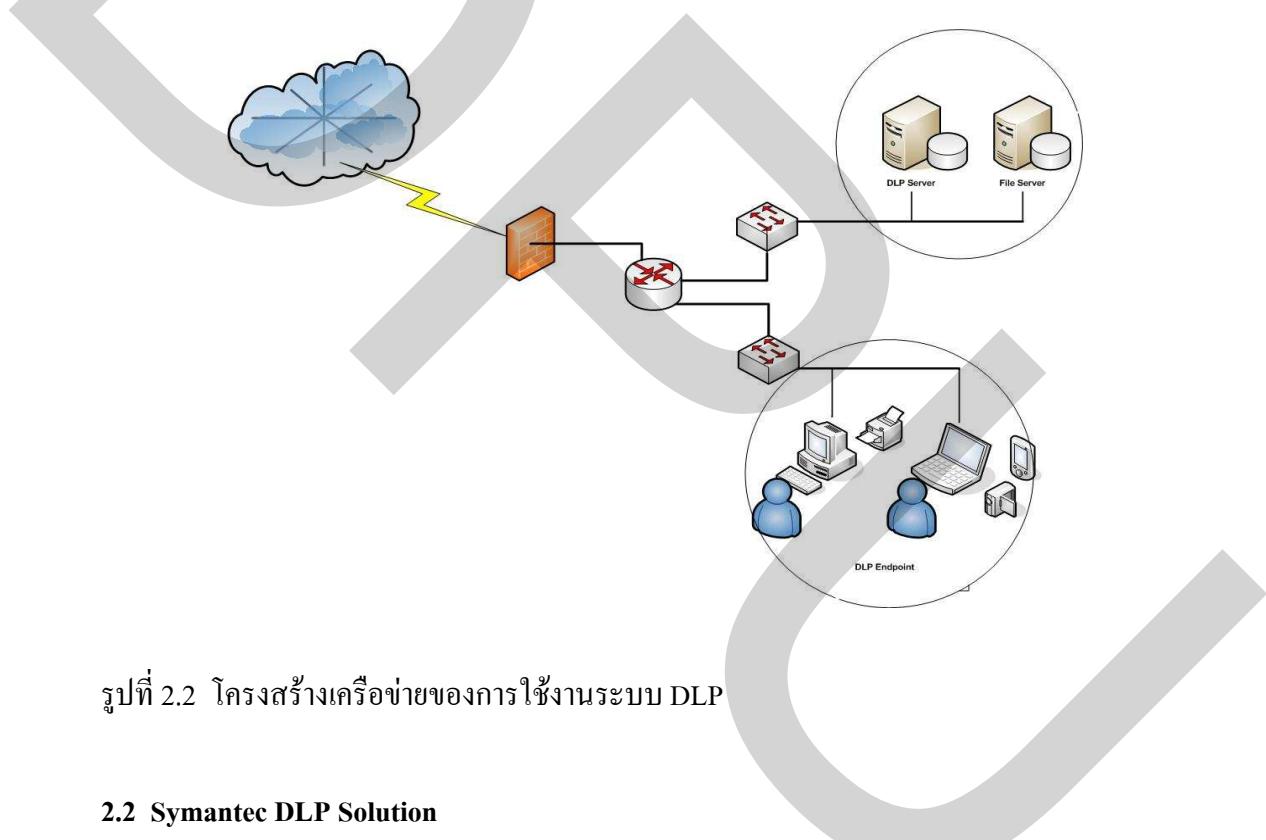
ตารางที่ 2.1 คุณสมบัติการทำงานของผลิตภัณฑ์ DLP ที่มีจำหน่ายอยู่ในปัจจุบัน

Solution	Classificate	Discover	Monitor												Data Protection				
			Data In Motion						Data In Use						Allow	Block	Notification	Quarantine	Encrypt
			TCP	SMTP	FTP	HTTP	HTTPS	USB	CD/DVD	Copy/Past	PrintScreen	Print	Fax						
BitArmor	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	
Bluecoat	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	
CA	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	
Checkpoint	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	
CiscoIronport	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	
CodeGreen	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	
EndpointProtection	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	
GTB	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	
NextTier	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	
NextLabs	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	
PalisadeSystem	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	
RSA	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	
Sophos	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	
Symantec	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	
Trustwave	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	
Vericept	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	
Websense	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	/	

ระบบการป้องกันข้อมูลรั่วไหล มีการออกแบบเพื่อให้ผู้ใช้งานตรวจสอบการเข้าถึงข้อมูลโดยโปรแกรมบนเครือข่าย จำกัดการใช้งาน เช่นการตรวจสอบช่องทาง และโปรแกรมการกรองเนื้อหาสำคัญ ก่อนที่จะสามารถส่งออกผ่านทางอุปกรณ์ต่อพ่วง โดยสามารถอกรายงานเหตุการณ์การเข้าสู่ระบบ หรือการจัดการความปลอดภัยของช่องทางการติดต่อ เพื่อแก้ไขปัญหาการ

สูญเสียข้อมูลสำคัญ การควบคุมการเคลื่อนไหวของข้อมูล โดยด้วยการติดต่อสื่อสารทางอิเล็กทรอนิกส์ผ่านตัวกรองที่กำหนดไว้ล่วงหน้า และถูกใช้กับข้อมูลที่มีการจำแนกประเภทข้อมูลไว้แล้ว เพื่อเพิ่มประสิทธิภาพ และความสามารถในการคัดกรองได้อย่างถูกต้อง

จากการศึกษาพบว่าในปัจจุบันยังไม่มีองค์กรใดออกมาทำงานเกี่ยวกับระบบงานนี้ และไม่มีมาตรฐานของระบบการป้องกันข้อมูลรั่วไหลอย่างชัดเจน ซึ่งถือว่าเป็นเรื่องยากสำหรับเครื่องมือในการป้องกันข้อมูลรั่วไหล เพื่อจะอธิบายรูปแบบของข้อมูลสำคัญ จึงได้นำเสนอการจำแนกประเภทเอกสาร (Data Classification) เพื่อจัดรูปแบบของข้อมูลก่อนที่จะนำเข้าสู่ระบบการป้องกันข้อมูลรั่วไหลต่อไป

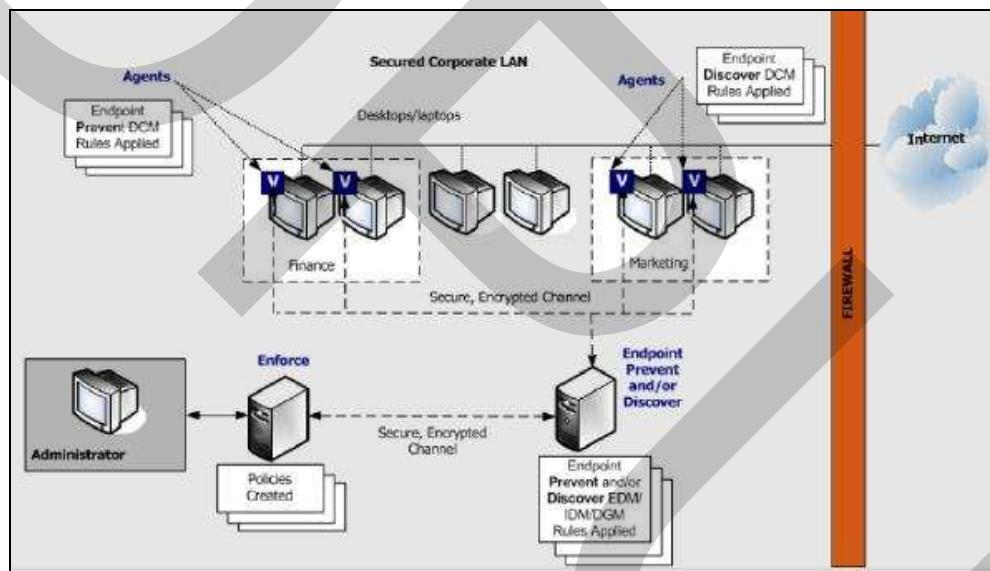


รูปที่ 2.2 โครงสร้างเครือข่ายของการใช้งานระบบ DLP

2.2 Symantec DLP Solution

Symantec Data Loss Prevention คือระบบการรักษาความปลอดภัยให้กับข้อมูลสำคัญขององค์การ ซึ่งมีขั้นตอนการทำงานหลักๆ คือ การค้นหาข้อมูล และการเฝ้าระวังข้อมูลสำคัญ โดยในขั้นตอนของการค้นหาข้อมูลสำคัญ จะทำการตรวจหาข้อมูลสำคัญผ่านทางโปรแกรมย่อย (Agent) ที่ติดตั้งไว้ที่เครื่องลูกข่าย และจะทำการเฝ้าระวังอยู่อย่างสม่ำเสมอ โดยการกำหนดความถี่ของการตรวจสอบผลที่ได้คือทราบตำแหน่งที่อยู่ของเอกสารสำคัญ และจะมีการรวมรวมตำแหน่งการจัดเก็บของเอกสารสำคัญไว้ และจะมีการบังคับใช้นโยบายการป้องกันข้อมูล โดยมีการวางแผนโครงสร้างเครือข่ายดังรูปที่ 2.2

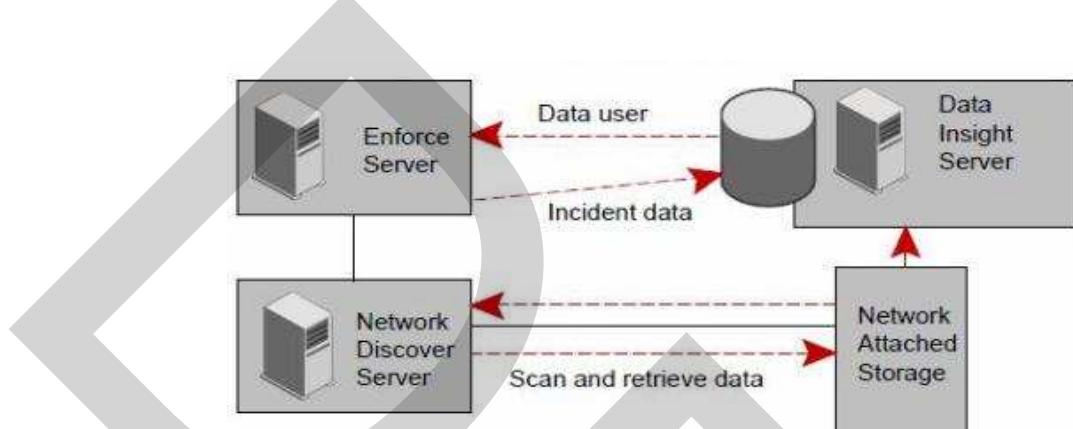
แสดงรูปแบบการติดตั้ง Symantec DLP Server (DLP Server + File Server) บนเครือข่าย จะบอกถึงตำแหน่งของเครื่องปลายทางที่ติดตั้งโปรแกรมย่อย (Agent) ไว้เพื่อเฝ้าระวังข้อมูลสำคัญ DLP Endpoint และอุปกรณ์ทางเครือข่ายที่เข้ามาเกี่ยวข้องกับระบบการป้องกันข้อมูลร่วมกัน โดยในลักษณะการวางแผนจะอยู่ในระบบเครือข่ายภายในหลังอุปกรณ์ Firewall ในส่วนของขั้นตอนการเฝ้าระวังนั้นจะทำการตรวจสอบการใช้งานข้อมูล ไม่ว่าจะเป็นการใช้งานอีเมลล์ เว็บไซต์ โปรแกรมสนทนาระหว่างผู้ใช้งาน หรือการโอนถ่ายข้อมูล โดยจะทำการตรวจสอบเนื้อหาของข้อมูลสำคัญ และแจ้งเตือนเมื่อพบเหตุการณ์ต้องสงสัย ผลที่ได้คือทราบถึงกิจกรรมการใช้งานที่เกิดขึ้นในเครือข่าย ทำให้การทำงานร่วมกันหน่วยงานภายในองค์กร เช่น ลูกค้าหรือคู่ค้า มีความปลอดภัยมากขึ้น



รูปที่ 2.3 แผนผังการทำงานของ Symantec Data Loss Prevention

ระบบโครงสร้างของ Symantec DLP ดังแสดงในรูปที่ 2.3 ประกอบไปด้วยส่วนหลักๆ 2 ส่วนคือ DLP Server ซึ่งทำหน้าที่ในการบังคับใช้นโยบาย(Enforce) และในส่วนของโปรแกรมย่อย (Agent) ที่ติดตั้งอยู่ที่เครื่องลูกข่ายเพื่อรับรับนโยบายที่ได้รับจากส่วนกลาง รวมทั้งทำหน้าที่ในการรับคำสั่งในการตรวจสอบการใช้งานข้อมูลสำคัญดังที่ได้กล่าวไปข้างต้นด้วย การทำงานร่วมกันของ DLP Server และโปรแกรมย่อยที่ติดตั้งไว้ที่เครื่องลูกข่าย หรือคอมพิวเตอร์ส่วนบุคคล ดังแสดงในรูปที่ 2.4 แสดงการไหลของข้อมูลระหว่าง DLP Server ซึ่งแบ่งการทำงานออกเป็น 3 ส่วน คือในส่วนของการบังคับใช้นโยบาย (Enforce Server) การค้นหาข้อมูลสำคัญ (Network

Discover Server) จะทำการสแกนไฟล์ และไฟล์เดอร์ที่ถูกจัดเก็บในเครือข่าย และเฝ้าระวังการใช้งานข้อมูลสำคัญ (Data Insight Server) ที่จัดเก็บข้อมูลที่กำหนดไว้ให้เป็นข้อมูลสำคัญ และจัดเก็บข้อมูลในส่วนผู้ใช้งานด้วย



รูปที่ 2.4 การทำงานระหว่าง Data Insight และ Symantec Data Loss Prevention Server

รูปแบบของนโยบายเกี่ยวกับเอกสารสารสำคัญใน Symantec DLP จะอยู่ในรูปแบบของ IDM Rule หรือการทำดัชนีเอกสารสารสำคัญ กฎนี้จะมองเนื้อหาจากเอกสารเฉพาะที่มีการลงทะเบียนไว้ (เอกสารสำคัญ) และจะมีการตรวจสอบความเหมือนต้องมีค่าเป็น 80% หรือมากกว่าเมื่อเทียบกับเอกสารต้นฉบับ โดยจะประกอบไปด้วย 2 เงื่อนไขซึ่งทั้งสองเงื่อนไขนี้จะต้องตรงกับกฎที่ตั้งไว้ถึงจะเรียกว่าเหตุการณ์ต้องสงสัย เงื่อนไขแรกเกิดจากการรวมกันของคำหลักจากคำหลักที่เป็นความลับ (Confidential Keywords) ตามเอกสารต้นฉบับที่ได้กำหนดไว้แล้วว่าเป็นความลับ ตามการเปรียบเทียบกับคำในพจนานุกรมที่กำหนดไว้ หรือตามชนิดของไฟล์ที่ได้กำหนด และระบบรองรับ เช่น Excel_macro, xls, works_spred, sylk, Quattro pro, mod, csv, applix_spread, 123, doc, pdf, ppt ซึ่งมีในส่วนของการกำหนดการบังคับให้มีเมื่อเกิดเหตุการณ์ต้องสงสัยดังรูปที่ 2.5 ซึ่งแบ่งออกเป็น 4 การตอบสนองต่อการตรวจพบเหตุการณ์ต้องสงสัย การเก็บรักษาข้อมูลเหตุการณ์ที่เกิดขึ้น (Limit incident data retention) ช่วยในการระบุล่วงของเนื้อหาที่จะจัดเก็บในการบันทึกเหตุการณ์ที่เกิดขึ้น การป้องกันที่จุดปลายทาง การปิดกั้น (Block) โดยจะบล็อกหรือปิดกั้นการถ่ายโอนข้อมูลที่ละเอียดนโยบายที่ได้กำหนดไว้ การป้องกันที่จุดปลายทาง การแจ้งเตือน (Notify) ที่หน้าจอจะแสดงผลการแจ้งเตือนไปยังผู้ใช้งานปลายทางเมื่อมีข้อมูลที่เป็นความลับกำลังจะถูกถ่ายโอนผ่านโปรโตคอลไปยังปลายทางการป้องกันที่จุดปลายทาง การยกเลิกโดยผู้ใช้งาน (User

Cancel) ช่วยให้ผู้ใช้งานสามารถยกเลิกนโยบายเพื่อที่จะทำการถ่ายโอนข้อมูลที่ซึ่งละเมิดนโยบายออกໄປได้ ซึ่งถือว่าเป็นตัวเลือกที่ต้องใช้งานอย่างระมัดระวังมาก

Response Rule	
All: Limit Incident Data Retention	Lets you specify the parts of the content to retain in the incident record. See "All: Limit Incident Data Retention response rule action" on page 326.
Endpoint Prevent: Block	Blocks the transfer of data that violates the policy. For example, a copy of confidential data from an endpoint computer to removable media (a USB flash drive, for example). Optionally, it displays an on-screen notification to the endpoint user. See "Endpoint Prevent: Block response rule action" on page 330.
Endpoint Prevent: Notify	Displays an on-screen notification to the endpoint user when confidential data is transferred from the endpoint protocol or destination (except local drive). See "Endpoint Prevent: Notify response rule action" on page 332.
Endpoint Prevent: User Cancel	Lets users override a policy to allow transfer of data that violates the policy. The override option is time sensitive. See "Endpoint Prevent: User Cancel" on page 335.

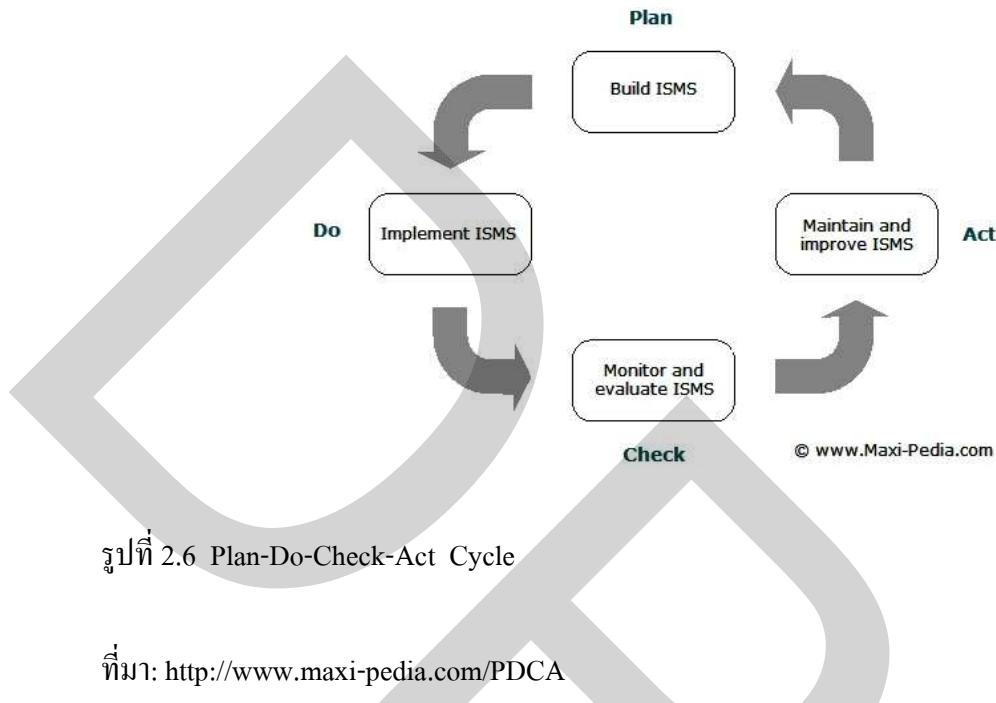
รูปที่ 2.5 การตอบสนองแบบอัตโนมัติต่อเหตุการณ์ต้องสงสัย

2.3 มาตรฐานด้านความมั่นคงปลอดภัยทางด้านสารสนเทศ ISO/IEC27001:2005

การนำระบบคอมพิวเตอร์มาใช้ในการจัดการ เรื่องของข้อมูลอย่างแพร่หลาย ไม่ว่าจะ เป็นอินเตอร์เน็ต การสื่อสารอิเล็กทรอนิกส์ ก่อให้เกิดความเสี่ยงสำคัญรูปแบบหนึ่งคือการโจงใจ ข้อมูล หรือการสูญหายของข้อมูลที่มีความสำคัญ ISO/IEC 27001:2005 เป็นมาตรฐานที่ดีที่สุด ใน การจัดการด้านระบบรักษาความปลอดภัยข้อมูลองค์กร ด้วยมาตรฐานนี้ สามารถสร้างกลยุทธ์ และ กำหนดทิศทางสำหรับการประเมิน การวัดค่า และการป้องกันการคุกคามจากภายนอก โดยผ่าน กระบวนการจัดการความเสี่ยงของมาตรฐานได้

ISO/IEC 27001:2005 หรือ Information Security Management System (ISMS) ซึ่ง ข้อกำหนดด้านกำหนดขึ้นโดยองค์กรที่มีชื่อเสียง และมีความน่าเชื่อถือระดับประเทศ คือ ISO (The International Organization for Standardization) และ IEC(The International Electrotechnical Commission) เป็นมาตรฐานสากลที่กล่าวถึงมาตรฐานของระบบบริหารจัดการเพื่อความมั่นคง ปลอดภัยของข้อมูล มีพื้นฐานมาจากแนวทางการจัดการความเสี่ยง (Risk Approach) เพื่อรักษาไว้ซึ่ง ความลับ (Confidentiality) ความถูกต้องครบถ้วน (Integrity) และความพร้อมใช้งาน (Availability)

ของข้อมูลสารสนเทศ รวมทั้งทรัพย์สินอื่นๆ ที่มีความสำคัญขององค์กรตามหลัก Plan-Do-Check-Action (PDCA Model) แสดงในรูปที่ 2.6



เพื่อให้เกิดวิธีปฏิบัติงานที่เป็นระบบ และมีการพัฒนาขึ้นอย่างต่อเนื่อง (Continuous Improvement) โดยเริ่มตั้งแต่ การสร้าง การดำเนินงาน การนำระบบมาใช้ การตรวจสอบ การวัดผล การทบทวน การบำรุงรักษา และการปรับปรุงระบบบริหารความมั่นคงปลอดภัย โดยจุดประสงค์ ของมาตรฐานนี้เพื่อจะทำให้องค์กร สามารถบริหารจัดการทางด้านความปลอดภัยได้อย่างมีระบบ และเพียงพอเหมาะสมต่อการดำเนินธุรกิจขององค์กร โดยเริ่มแรกองค์กรต้องทำการวิเคราะห์ความเสี่ยงของระบบจากภัยคุกคาม และจุดอ่อนต่างๆ ในระบบจากนั้นจึงวิเคราะห์และเลือกแนวทางการควบคุม และป้องกันสารสนเทศต่างๆอย่างเหมาะสม

2.3.1 ISO/IEC 27001:2005 หรือ Information Security Management System (ISMS) เป็นระบบการจัดการความปลอดภัยข้อมูลเพื่อให้ระบบข้อมูลสารสนเทศขององค์กรมีคุณสมบัติในด้านต่างๆดังต่อไปนี้

2.3.1.1 Confidentiality ข้อมูลต่างๆ สามารถเข้าถึงได้เฉพาะผู้ที่มีสิทธิ์ที่จะเข้าเท่านั้น

2.3.1.2 Integrity ข้อมูลมีความถูกต้อง ครบถ้วนสมบูรณ์ โดยไม่ได้ถูกเปลี่ยนแปลงหรือแก้ไข จากผู้ที่ไม่ได้รับอนุญาต

2.3.1.3 Availability ข้อมูลพร้อมที่จะใช้งาน โดยผู้ที่มีสิทธิในการเข้าถึงข้อมูลสามารถเข้าถึงข้อมูลได้ทุกเมื่อหากต้องการ

2.3.2 สำหรับระบบ ISO/IEC 17799:2005 เป็นกรอบด้านการควบคุมระบบ ความปลอดภัย ข้อมูล ซึ่งแบ่งออกเป็น 11 การควบคุมหลัก ดังต่อไปนี้

2.3.2.1 Security Policy นโยบายความมั่นคงปลอดภัยขององค์กร

2.3.2.2 Organization Information Security โครงสร้างความมั่นคงปลอดภัยขององค์กร

2.3.2.3 Asset Management การจัดหมวดหมู่ และการควบคุมทรัพย์สินขององค์กร

2.3.2.4 Human Resource Security มาตรฐานของบุคลากรเพื่อสร้างความมั่นคงปลอดภัย ให้กับองค์กร

2.3.2.5 Physical and Environment Security ความมั่นคงปลอดภัยทางกายภาพ และ สิ่งแวดล้อมขององค์กร

2.3.2.6 Communications and operations management เป็นการบริหารจัดการด้านการ สื่อสาร และการดำเนินงานของเครือข่ายสารสนเทศขององค์กร

2.3.2.7 Access Control การควบคุมการเข้าถึงระบบสารสนเทศขององค์กร

2.3.2.8 Information System acquisition, development and maintenance การพัฒนาและ ดูแลระบบสารสนเทศ

2.3.2.9 Information security incident management การบริหารจัดการเหตุการณ์ละเอียด ความมั่นคงปลอดภัย

2.3.2.10 Business continuity management การบริหารความต่อเนื่องในการดำเนินงาน ขององค์กร

2.3.2.11 Compliance การปฏิบัติตามข้อกำหนดทางด้านกฎหมาย และบทลงโทษของ การละเมิดนโยบาย

โดยระบบ ISO/IEC 27001:2005 จะต้องมีการแนะนำให้ประยุกต์ตามข้อกำหนดของ ISO/IEC17799:2005 มาใช้ในการควบคุมและจัดการเกี่ยวกับความเสี่ยงที่เกิดขึ้น (ตามข้อกำหนด 4.2g ของ ISO/IEC27001:2005) ระบบการจัดการความปลอดภัยข้อมูล ISO/IEC27001:2005 หรือ ISMS เป็นระบบ dynamic system ที่มีการประยุกต์หลักการ PDCA Cycle ที่สามารถประยุกต์ใช้ได้ กับทุกธุรกิจ เพื่อให้ระบบข้อมูลขององค์การ มี Confidentiality ให้แน่ใจว่าข้อมูลต่างๆ สามารถ เข้าถึงได้เฉพาะผู้ที่มีสิทธิ์ที่จะเข้าเท่านั้น มี Integrity ป้องกันให้ข้อมูล มีความถูกต้อง และความ สมบูรณ์ และ Availability ผู้ที่มีสิทธิ์ในการเข้าถึงข้อมูล สามารถเข้าถึงได้เมื่อมีความต้องการ โดย ไม่ใช่ให้ระบบไม่มีความเสี่ยงเลย หรือไม่เกิดปัญหาเลย ทำให้เกิดประสิทธิภาพในการใช้ทรัพยากร ในการลงทุนสำหรับการจัดการความปลอดภัยของข้อมูลอย่างมีประสิทธิภาพ โดยส่วนใหญ่จะมี การใช้งานร่วมกับ ระบบ ISO/IEC17799:2005 เพื่อให้เกิดประสิทธิภาพในการดำเนินงาน

2.4 กฎหมายกับความมั่นคงปลอดภัยสารสนเทศ

พระราชบัญญัติกำหนดหลักเกณฑ์ และวิธีการในการทำธุรกรรมทางอิเล็กทรอนิกส์ ภาครัฐ พ.ศ.2549 ประกาศบังคับใช้เมื่อ 10 มกราคม พ.ศ.2550 การประกาศบังคับใช้กฎหมายฉบับนี้เป็นกฎหมายลำดับรองของ พรบ.ว่าด้วยธุรกรรมอิเล็กทรอนิกส์ โดยมีจุดมุ่งหมายเพื่อให้การทำธุรกรรมอิเล็กทรอนิกส์ภาครัฐมีผลทางกฎหมาย เพื่อพัฒนาการทำธุรกรรมทางออนไลน์ของภาครัฐให้อยู่ภายใต้มาตรฐาน หรือทิศทางเดียวกัน การจัดทำแนวโน้มฯ/แนวทางปฏิบัติในการรักษาความมั่นคงปลอดภัยสารสนเทศ ทั้งในด้าน Physical และ Electronically โดยต้องมีการควบคุมการเข้าถึง และใช้สารสนเทศ การทำการสำรวจข้อมูลในสภาพพร้อมใช้งาน และมีแผนฉุกเฉิน รวมไปถึงการตรวจสอบ และประเมินความเสี่ยงอย่างต่อเนื่อง (มาตรา 5) จัดทำแนวโน้มฯ/แนวทางปฏิบัติในการคุ้มครองข้อมูลส่วนบุคคล ในกรณีที่มีการรวบรวมจัดเก็บ ใช้ หรือเผยแพร่ข้อมูลที่ระบุตัวตนได้ (มาตรา 6)

2.4.1 บทบาทหน้าที่ของผู้ใช้บริการ เนื้อความของ พรบ.จะครอบคลุมไปยังบุคคลที่ถือได้ว่า เป็นผู้ใช้บริการทุกคน มีประเด็นความผิดสำคัญ ดังนี้ การเข้าถึงระบบคอมพิวเตอร์ผู้อื่น โดยมิชอบ (มาตรา 5) การล่วงรู้ และเปิดเผยข้อมูลมาตราการป้องกันการเข้าถึงระบบคอมพิวเตอร์ที่ผู้อื่นจัดทำขึ้นเป็นการเฉพาะ (มาตรา 6) การเข้าถึงข้อมูลคอมพิวเตอร์โดยไม่ชอบ (มาตรา 7) การลักลอบดักข้อมูลคอมพิวเตอร์ของผู้อื่น (มาตรา 8) เช่นการทำ Packet Sniffing การทำให้เสียหาย ทำลาย แก้ไขเปลี่ยนแปลง เพิ่มเติมข้อมูลคอมพิวเตอร์ของผู้อื่น โดยไม่ชอบ (มาตรา 9) การกระทำเพื่อให้การทำงานของระบบคอมพิวเตอร์ของผู้อื่น ไม่สามารถทำงานได้ตามปกติ (มาตรา 10) เช่นการทำ Denial of Services เป็นต้น การจำหน่าย หรือเผยแพร่โปรแกรมที่ใช้ในการกระทำความผิด (มาตรา 13) การเผยแพร่ โดยการนำข้อมูลปลอม เท็จ ลามก เข้าสู่ระบบคอมพิวเตอร์ ซึ่งก่อให้เกิดความเสียหายต่อผู้อื่น ต่อกำลังใจ ความมั่นคงของประเทศ ต่อความสงบสุขของประชาชน (มาตรา 14) การเผยแพร่ภาพจากการตัดต่อ ดัดแปลง ตกแต่งข้อมูลคอมพิวเตอร์ที่เป็นภาพของบุคคล (มาตรา 16) อันทำให้ผู้อื่นเสียชื่อเสียง ถูกดูหมิ่น เกลียดชัง หรือได้รับความอับอาย ฐานความผิดของ พรบ. ฉบับนี้ถือเป็นความผิดทางอาญา

2.5 เทคโนโลยีการแยกประเภทเอกสาร (Document Classification)

เทคนิคการแยกประเภทเอกสาร นำมาปรับใช้ในการคัดแยกเอกสารภาษาไทย โดยพิจารณาจากรูปแบบของความน่าจะเป็นที่เกี่ยวข้องกับการตัดสินใจของมนุษย์ ซึ่งประกอบด้วย ขั้นตอนการคัดแยกตั้งแต่ขั้นตอนการตัดคำในเอกสารภาษาไทย การให้น้ำหนักคำของแต่ละเอกสาร และการนำคำน้ำหนักเหล่านั้นมาเป็นอินพุตของระบบการคัดแยกประเภทเอกสาร โดยกำหนด

ลักษณะสำคัญในการแยกประเภทเอกสารเป็นอีกอินพุตหนึ่งของระบบการคัดแยกเพื่อรับประเภทของเอกสาร

2.5.1 การตัดคำในเอกสารภาษาไทย (Thai Word Segmentation) คือกระบวนการในการแยกแต่ละคำในเอกสารภาษาไทย ซึ่งประกอบไปด้วยตัวหนังสือภาษาไทย ตัวหนังสือภาษาอังกฤษ ตัวเลข และสัญลักษณ์พิเศษต่างๆ ออกแบบเป็นแต่ละคำเพื่อนำไปใช้ประโยชน์ในการหาความถี่ของคำ ลักษณะของประโยชน์ในภาษาไทยประกอบไปด้วยคำ ซึ่งในแต่ละคำจะประกอบไปด้วยส่วนต่างๆ แบ่งออกได้เป็นสามส่วน ส่วนที่ส่วน และห้าส่วน ตามอักษรระบุชี ได้แก่ พยัญชนะ สาระ และวรรณยุกต์ เช่นคำว่า กาน กาน กาน เป็นต้น โดยคำว่า กาน ไม่มีรูปวรรณยุกต์ แต่มีเสียงวรรณยุกต์สามัญ ส่วนแบบสี่ส่วน จะเพิ่มเติมตัวสะกดมา เช่น กาน บิน รวม และสุดท้ายแบบห้าส่วน จะเพิ่มในส่วนของการันต์ได้แก่คำว่า การน์ จันน์ เป็นต้น การประสมคำกันระหว่างตัวอักษรจะมีหลักการเพิ่มเติมอีก เช่นการใช้อักษรสูง อักษรกลาง และอักษรต่ำ หรือการวางตำแหน่งของสาระในแต่ละคำ

การตัดคำภาษาไทยโดยการใช้อักษรระบุชีในการตัดคำนั้นสามารถทำได้ในระดับหนึ่งเท่านั้นเนื่องจากคำบางคำเป็นคำที่เลียนเสียงจากภาษาต่างประเทศ ดังนั้นอาจจะเกิดจากการประสมคำนอกเหนือจากอักษรระบุชี โดยเทคนิคการตัดคำโดยทั่วไปจะแบ่งออกเป็น 3 แบบใหญ่ๆ คือ วิธีการตัดคำที่ยาวที่สุด (Longest Matching) เป็นการตัดคำด้วยการค้นหาคำเริ่มจากตัวอักษรที่อยู่ข้างสุดของข้อความนั้นไปยังตัวอักษรถัดไปจนกว่าจะพบคำที่ยาวที่สุดที่มีอยู่ในพจนานุกรม วิธีการตัดคำแบบสอดคล้องมากที่สุด (Maximal Matching) เป็นวิธีการตัดคำโดยคำที่ตัดได้เหล่านั้นอาจจะเป็นไปได้ทั้งหมด และเลือกข้อความที่ตัดได้จำนวนคำน้อยที่สุดมาใช้งาน วิธีการตัดคำแบบคำนวนเชิงสถิติเพื่อหาความเป็นไปได้ (Probabilistic Model) วิธีการนี้นำเอาค่าสถิติของการเกิดของคำนั้นๆ และลำดับหน้าที่ของคำ เข้ามาช่วยในการคำนวนหาความน่าจะเป็นเพื่อที่จะเลือกแบบที่มีโอกาสการเกิดมากที่สุด ซึ่งสามารถตัดคำได้ดีกว่า 2 แบบแรก แต่ข้อจำกัดของวิธีการนี้คือ จะต้องมีฐานข้อมูลที่มีการตัดคำที่ถูกต้องและมีการกำหนดหน้าที่ของคำ เพื่อนำไปใช้ในการสร้างสถิติ และวิธีการตัดคำแบบใช้คุณลักษณะ (Feature-Based Approach) วิธีการตัดคำแบบนี้จะพิจารณาจากบริบท (Context Words) และการเกิดร่วมกันของคำ หรือหน้าที่ของคำ (Collocation) เข้ามาช่วยในการตัดคำ ซึ่งโดยรวมแล้ววิธีการหลักสำหรับตัดคำในเอกสารภาษาไทยจะถูกพิจารณาตามขั้นตอนดังนี้

2.5.1.1 การใช้กฎ ลักษณะของการใช้กฎเพื่อตัดคำในภาษาไทย จะใช้ไวยากรณ์ทางภาษา โดยภาษาไทยจะแบ่งตัวอักษรเป็นหมวดหมู่ตามลักษณะการใช้งาน ได้แก่ กลุ่มพยัญชนะ

กลุ่มสาระ กลุ่มวรรณยุกต์ กลุ่มตัวเลข และกลุ่มตัวอักษรพิเศษ ขั้นตอนการตัดพยางค์จะทำจากซ้ายไปขวาเป็นส่วนใหญ่

2.5.1.2 การใช้พจนานุกรม ซึ่งถูกนำมาปรับใช้ในการวิจัยนี้ผลลัพธ์ที่ได้จะอยู่ในระดับคำ โดยมีหลักการว่าจะทำการตรวจสอบสายอักษร (String) ซึ่งเป็นชุดของตัวอักษรที่ได้จากเอกสาร โดยการค้นหาคำเริ่มจากอักษรตัวซ้ายสุดของข้อความนั้นไปยังอักษรตัวถัดไป และนำไปเทียบกับคำในพจนานุกรม หากพบคำในพจนานุกรมที่สามารถเป็นคำในสายอักษรนั้นได้มากกว่าหนึ่งคำ จะทำการเลือกคำที่ยาวที่สุด (Longest matching) หากอักษรตัวต่อมาไม่พบว่าเป็นคำที่ตรง ในพจนานุกรมที่มีอยู่จะทำการย้อนกลับไปเลือกคำที่สั้นกว่าแทน เรียกวิธีการนี้ว่าการย้อนรอย (Back tracking) การค้นหาคำที่พูก็จากพจนานุกรมจะนำคำที่ได้จากเอกสาร และนำไปแบ่งครั้งแรก ด้วยช่องว่างระหว่างประโยค จากนั้นนำไปแยกในระดับพยางค์โดยการใช้กฎ ผลที่ได้จะถูกเก็บเป็นสองส่วน คือส่วนที่ต้องนำไปค้นหาต่อไปในพจนานุกรม และไม่ต้องนำไปค้นหาต่อ คำที่ไม่ต้องนำไปค้นหาต่อ ได้แก่คำดังนี้ คำที่ปรากฏสัญลักษณ์ - / , . ซึ่งจะถูกตัดออกในขั้นตอนการตัดคำหยุด (Stop Word) และในส่วนของคำที่จะนำไปค้นหาในพจนานุกรม การค้นหาคำหากพบมากกว่าหนึ่งคำปรากฏอยู่จะใช้เทคนิค Longest Matching เพื่อเลือกคำศัพท์ที่ยาวที่สุด

2.5.2 การให้น้ำหนักคำ (Word Weighting) วัตถุประสงค์เพื่อสร้างเนื้อหาของเอกสาร ให้อยู่ในรูปแบบที่คอมพิวเตอร์สามารถเรียนรู้ได้ รูปแบบของค่าน้ำหนักจะถูกใช้ในการจำลอง Vector Space สำหรับการกำหนดความคล้ายคลึงกันของเอกสาร สามารถหาได้จากรูปแบบของความน่าจะเป็นที่เกี่ยวข้องกับการตัดสินใจของมนุษย์ เพื่อใช้ในกระบวนการเรียนรู้ลักษณะของตัวแทนเอกสาร โดยจะอยู่ในรูปแบบของเวกเตอร์น้ำหนักคำ TF-IDF (Term Frequency Inverse Document Frequency)

$$w_{ij} = tf_{ij} \times \log_2 \frac{N}{n_j} \quad (2-1)$$

โดยที่ w_{ij} = น้ำหนักของคำ T_j ในเอกสาร D_i

tf_{ij} = ความถี่ของคำ T_j ในเอกสาร D_i

N = จำนวนเอกสารทั้งหมดในระบบ

n_j = จำนวนเอกสารที่มีคำ T_j ปรากฏอยู่อย่างน้อยหนึ่งครั้ง

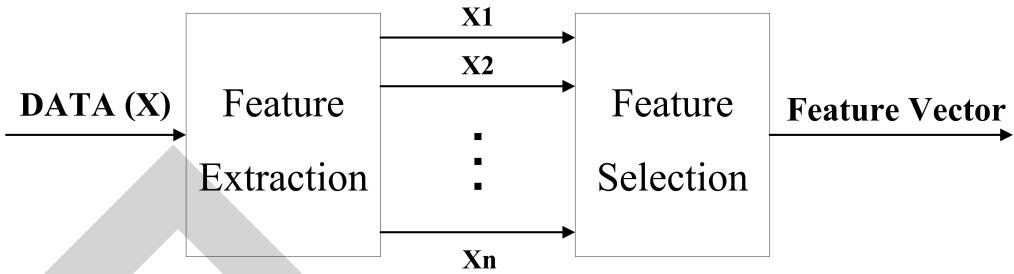
เป็นวิธีที่คำนวนน้ำหนักจากความถี่ ของการปรากฏของคำ T_j ในเอกสาร D_i และพิจารณาความถี่ของคำ T_j ที่ปรากฏในเอกสารอื่นร่วมด้วย โดยมีแนวคิดที่ว่าคำที่ปรากฏใน

เอกสารนี้ยังบันจะมีค่า'n้ำหนักสูง ส่วนคำที่ปรากฏในเอกสารหลายบันจะมีค่าน้ำหนักน้อย
เนื่องจากเป็นคำที่ไม่แสดงลักษณะเฉพาะของเอกสารนั้น ดังสมการ 2-1

พารามิเตอร์ n_j ในสมการจะหาค่าได้เมื่อระบบได้รู้ทุกเอกสารที่มีในระบบ
ตัวอย่างเช่น ถ้าทำการพิจารณาเอกสารที่ประกอบไปด้วยคำ 100 คำที่ปรากฏคำที่กำหนด 3 ครั้ง ทำ
การหาค่าตามสูตร เทอมของความถี่ tf_{ij} สำหรับคำที่เกิดขึ้น $(3/100)=0.03$ ถ้ามีเอกสารจำนวน
1,000 เอกสารและคำนั้นปรากฏใน 100 เอกสารสามารถหาค่าความถี่ของเอกสารได้จาก
 $\log(1,000/100)=10$ ดังนั้นค่า'n้ำหนัก tf-idf หรือ $w_{ij} = 0.03 \times 10 = 0.3$

2.5.3 ขั้นตอนการตัดคำหยุด (stop word) ออกเพื่อกรองคำที่ไม่สื่อถึงความสำคัญของเอกสาร
และลบลัญลักษณ์พิเศษ เช่น \$,#,@,?,! , ตัวเลข หรือคำเชื่อมที่เป็นคำฟุ่มเฟือย เช่น เป็น ออย คือ และ
กี ฯลฯ ดังนั้นคำที่เหลือจะถูกเลือกเป็นคำสำคัญ (significant word) และจะถูกเก็บไว้ และนำ
ความถี่ของคำที่ได้ไปเป็นตัวแทนของเอกสาร ในขั้นตอนนี้จะทำการกำหนดคำหยุดไว้ในอาร์เรย์
ของโปรแกรม เพื่อกรองคำหยุดเหล่านี้ทิ้งก่อนนำคำที่เหลือไปประมวลผลในขั้นตอนต่อไป

2.5.4 การจำแนกประเภทเอกสาร มีวัตถุประสงค์เพื่อปรับปรุงความถูกต้อง และความรวดเร็ว
ในการจำแนกเอกสาร อันเนื่องมาจากจำนวนเอกสารที่มีมากมาก ประกอบกับจำนวนกลุ่มของ
เอกสารที่มีหลากหลาย เมื่อแปลงเอกสารให้อยู่ในรูปของเมตริกซ์ความถี่ของคำสำคัญ ปัญหาที่
เกิดขึ้นคือจำนวนของคำสำคัญที่มีมาก ทำให้ใช้เวลานานในการจำแนกเอกสาร การแก้ปัญหา
จำนวนคำสำคัญที่มีจำนวนมาก ประกอบไปด้วย การเลือกลักษณะสำคัญ (Feature Selection) คือ
การเลือกคำสำคัญบางคำจากคำสำคัญทั้งหมด โดยพิจารณาจากค่าน้ำหนักของคำสำคัญนั้นๆ โดยค่า
ลักษณะสำคัญจะอยู่ในรูปของเวกเตอร์ ซึ่งจะเรียกว่าเวกเตอร์ลักษณะสำคัญ (Feature
Vector) เป็นจำนวนที่นำมาใช้ในการจำแนกวัตถุหรือเหตุการณ์ จำนวนของลักษณะสำคัญนี้อยู่
กับผู้ใช้ต้องการความละเอียดของการแบ่งแยกระหว่างกลุ่มข้อมูลอยู่ในระดับใด อีกวิธีคือ วิธีการ
สกัดลักษณะสำคัญ (Feature Extraction) เป็นวิธีการแปลงลักษณะของเวกเตอร์ค่าน้ำหนักของคำ
สำคัญ ให้อยู่ในรูปแบบใหม่ที่มีมิติที่น้อยลงผลจากการสกัดลักษณะสำคัญมีสองประการ คือ
สามารถลดจำนวนข้อมูลนำเสนอ โดยมีน้อยกว่าคำสำคัญทั้งหมด การแทนเอกสารให้อยู่ในรูปแบบที่
มีขนาดเล็กลง ด้วยการคัดเลือก และสกัดลักษณะสำคัญ สามารถแสดงได้ดังรูปที่ 2.7



รูปที่ 2.7 กระบวนการของการสกัดลักษณะสำคัญและแบ่งกลุ่มข้อมูล

ลักษณะสำคัญที่ดีนั้นควรมีลักษณะที่เหมือนกันสำหรับแบบอย่างทั้งหมดในกลุ่มเดียวกัน และแตกต่างกันสำหรับแบบอย่างที่อยู่ต่างกลุ่มกัน ในการแบ่งประเภทเอกสารที่ใช้ในวิทยานิพนธ์ฉบับนี้ จะทำการแบ่งประเภทตามลักษณะสำคัญของเอกสาร โดยจะแบ่งออกเป็น 2 ประเภท คือ

2.5.4.1 เอกสารสำคัญที่ถือเป็นเอกสารสำคัญ (Secret)

2.5.4.2 เอกสารทั่วไปที่ถือว่าไม่เป็นเอกสารสำคัญ (No Secret)

เพื่อให้สามารถแยกประเภทของเอกสารออกจากกันได้ ดังนั้นจะได้เวกเตอร์ลักษณะสำคัญ X ดังนี้

$$X = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \\ \cdot \\ \cdot \\ \cdot \\ x_n \end{bmatrix} \quad (2-2)$$

เมื่อ $\{x_1, x_2, \dots, x_n\}$ คือลักษณะสำคัญ (ค่าน้ำหนัก) เป็นคำสำคัญที่ถูกเลือกมาเป็นตัวแทนของเอกสารเพื่อการจำแนกหมวดหมู่

2.5.5 การเลือกคุณลักษณะ (Feature Selection) การเลือกคำที่มีความสำคัญน้อยออก เพื่อคุณลักษณะในการทำนายหลังจากที่ได้ตัดคำบางตัวออกซึ่งส่วนใหญ่จะให้ความถูกต้องสูงขึ้น เพราะคำสำคัญที่เหลือจะเป็นคำที่มีเป็นตัวแทนที่ดีของเอกสาร การลดขนาดเอกสารคือการนำคำที่

ไม่มีนัยสำคัญออก ซึ่งจำนวนคุณลักษณะมีผลต่อประสิทธิภาพของการจำแนกหมวดหมู่เอกสาร เนื่องจากอัลกอริทึมที่ใช้ในการเรียนรู้สร้างตัวจำแนกหมวดหมู่ โดยทั่วไปไม่สามารถรองรับการทำางานกับจำนวนคุณลักษณะของเอกสารที่สูงมาก ได้ การลดขนาดจึงเป็นขั้นตอนหนึ่งที่จะต้องทำก่อน

2.5.6 การสกัดคุณลักษณะ (Feature Extraction) เป็นการดึงคุณลักษณะ (Feature) ของเอกสาร ออกมา กับการลดขนาดเอกสารลง ซึ่งการดึงคุณลักษณะออกมานั้น ต้องกำหนดก่อนว่าจะใช้อะไร เป็นตัวแทนคุณลักษณะของเอกสาร และใช้คำใดแทนคุณลักษณะเอกสารนั้น จากการสำรวจ งานวิจัยที่ผ่านมาทั้งในประเทศไทย และต่างประเทศพบว่า ส่วนใหญ่จะใช้คำเป็นตัวแทนคุณลักษณะ ของเอกสาร และใช้พื้นฐานค่าความถี่ หรือค่าน้ำหนักคำ เป็นค่าของคุณลักษณะ ตัวแทนคุณลักษณะ ของเอกสารจะเก็บอยู่ในรูปแบบเวกเตอร์ โดยองค์ประกอบของเวกเตอร์อาจจะเป็นตัวคุณลักษณะ ของค่าความถี่คำ (Word Frequency) หรือแทนด้วยค่าน้ำหนักคำ (Word Weighting) งานวิจัยนี้ใช้ การเลือกคุณลักษณะแบบคำเดียว (Single word) ซึ่งได้จากการตัดคำโดยใช้พจนานุกรม เรียบเรียงแล้ว ผลลัพธ์ที่ได้จากการตัดคำจะได้เป็นคำเดียวจำนวนมาก เพื่อคัดเลือกมาใช้เป็นตัวแทน เอกสารในการเรียนรู้ โดยใช้วิธีเลือกคำที่มีความถี่มากที่สุด หรือคำที่ปรากฏในเอกสารมากที่สุด

2.5.7 การสร้างดัชนี (Indexing) คอมพิวเตอร์ไม่สามารถจำแนกหมวดหมู่ของเอกสารซึ่งเป็นภาษาธรรมชาติโดยตรง ได้ ดังนั้นจึงต้องแปลงเอกสารให้อยู่ในรูปแบบที่คอมพิวเตอร์ใช้ในการ เรียนรู้ได้ ขั้นตอนในการแปลงเอกสาร เรียกว่า การทำดัชนี (Indexing) เพื่อสร้างตัวแทนเนื้อหาของ เอกสาร (Document Representation) สำหรับใช้ในกระบวนการเรียนรู้ วัตถุประสงค์ของการสร้าง ดัชนีคือ การคำนวณค่าที่จะมาใช้เป็นค่าคุณลักษณะของเอกสาร อาจจะเรียกได้ว่าการหาค่าน้ำหนัก การสร้างดัชนี จะเริ่มจากการสร้างเวกเตอร์ตัวแทนเอกสาร จากนั้นจะสร้างเมตริกซ์ของกลุ่มเอกสาร ขึ้นจากเวกเตอร์เอกสารทั้งหมดในกลุ่ม ซึ่งงานวิจัยนี้ใช้วิธีความถี่ของคำที่ปรากฏในเอกสาร ถ้า คำมีค่าความถี่มากจะส่งผลให้ได้ค่าน้ำหนักที่มีค่าสูงตามไปด้วยเมื่อถึงขั้นตอนนี้จะได้รูปแบบที่มี ลักษณะของการแสดงความสัมพันธ์ระหว่างคำ และเอกสารทั้งหมดด้วยเวกเตอร์ 2 มิติ ดังตัวอย่าง ในรูปที่ 2.8

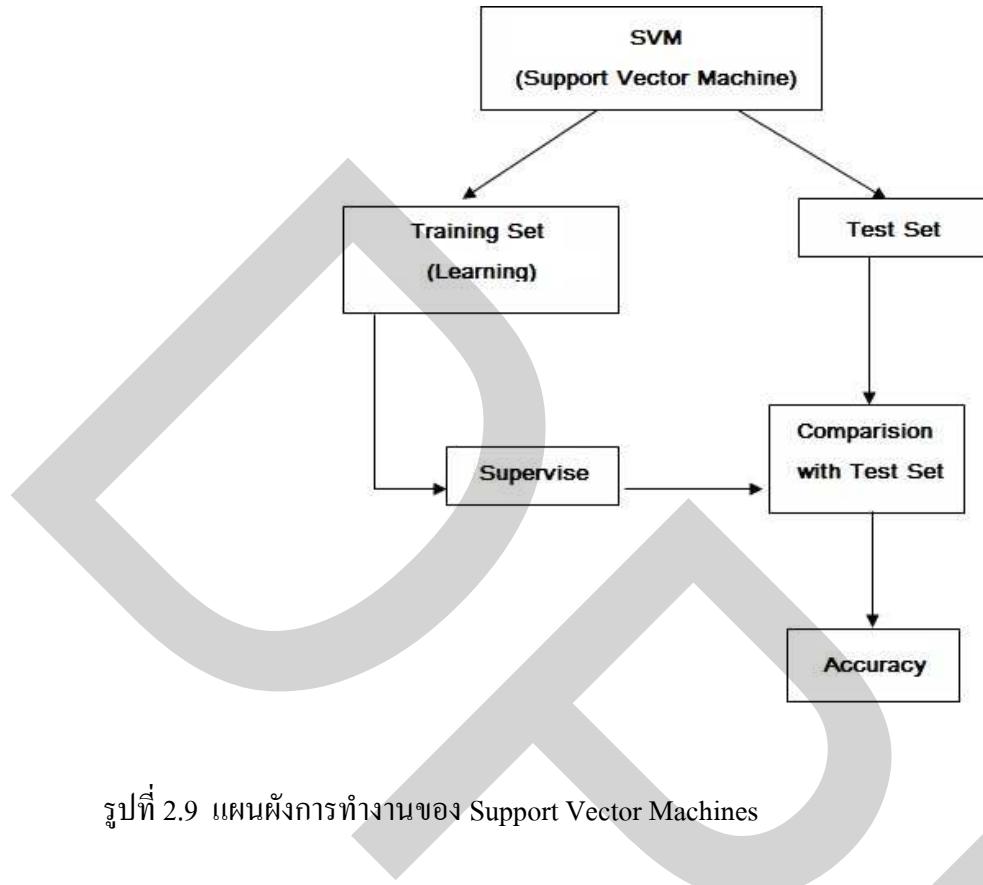
	W_1	W_2	...	W_k	...	W_v
D_1	W_{11}	W_{12}	...	W_{1k}	...	W_{1v}
D_2	W_{21}	W_{22}	...	W_{2k}	...	W_{2v}
D_3	W_{31}	W_{32}	...	W_{3k}	...	W_{3v}
...
D_N	W_{N1}	W_{N2}	...	W_{Nk}	...	W_{Nv}

รูปที่ 2.8 รูปแบบแสดงความสัมพันธ์ระหว่างคำ และเอกสารทั้งหมดคือเวกเตอร์ 2 มิติ

2.6 ทฤษฎี SVM (Support Vector Machines)

เป็นเวกเตอร์ที่ระบุลักษณะเฉพาะ (Identifies) เช่น ใช้สำหรับการทำนายเพื่อเป็นข้อมูลที่ใช้ในการกรองการสืบค้นข้อมูลในการทำนาย แล้วจัดอันดับความเกี่ยวข้องโดยใช้การกำหนดขอบเขตไว้ล่วงหน้า เป็นการแยกประเภทแบบมีผู้สอน โดยแนวคิดหลักของวิธีการนี้ ใช้เพื่อหาระนาบการตัดสินใจในการแบ่งข้อมูลออกเป็นสองส่วน โดยใช้สมการเส้นตรงเพื่อแบ่งเขตข้อมูล 2 กลุ่มออกจากกัน โดยจะพยายามสร้างเส้นแบ่งตรงกึ่งกลางระหว่างกลุ่มให้มีระยะห่างระหว่างขอบเขตของทั้งสองกลุ่มมากที่สุด SVM จะใช้ฟังก์ชันแมปสำหรับนำข้อมูลจาก Input Space ไปยัง Feature Space และสร้างฟังก์ชันวัดความคล้าย เรียกว่า เคอร์แนลฟังก์ชัน (Kernel Function) บน Feature Space เมามะใช้สำหรับข้อมูลที่มีมิติของข้อมูลสูง วิทยานิพนธ์นี้เลือกใช้วิธี SVM เพราะเป็นวิธีการที่ได้รับความนิยม ได้ผลลัพธ์ที่น่าพึงพอใจ และง่ายต่อการพัฒนา ดังแสดงแผนผังการทำงานของ SVM ดังรูปที่ 2.9 โดยทั่วไปแล้วจะนำ SVM มาแบ่งกลุ่มข้อมูลออกเป็น 2 กลุ่ม สมมติให้มีชุดข้อมูลมากกลุ่มหนึ่ง และจะสร้างเส้นแบ่งข้อมูลออกเป็น 2 กลุ่ม โดยมีค่าตอบที่เป็นไปได้คือ $y = \{+1, -1\}$ โดยค่า y นี้จะเป็นผลลัพธ์ที่ต้องการให้ SVM เรียนรู้ เพื่อใช้สำหรับแยกกลุ่มข้อมูลทั้งสองกลุ่มออกจากกัน สำหรับฐานข้อมูลเดิมของ SVM ถูกนำมาใช้กับข้อมูลที่เป็นลักษณะเชิงเส้น แต่ในความเป็นจริงบางครั้งข้อมูลที่นำมาใช้อาจจะมีลักษณะแบบไม่เป็นเชิงเส้น ซึ่งสามารถแก้ไขปัญหาดังกล่าวด้วยการนำ เคอร์แนลฟังก์ชัน (Kernel Function) มาใช้โดยจะกล่าวต่อไปในเรื่อง เคอร์แนลฟังก์ชัน แนวคิดพื้นฐานของทฤษฎีสามารถอธิบายดังนี้

ให้กลุ่มข้อมูลทดลอง $D = \{x_i, y_i ; i = 1, 2, \dots, n\}$ ในขณะที่ $x_i = (x_{i1}, x_{i2}, \dots, x_{in}) \in R^n$ นั้นเป็นข้อมูลนำเข้า และ $y_i \in \{+1, -1\}$ เมื่อ ($+1 =$ “เอกสารสำคัญ”, $-1 =$ “เอกสารทั่วไป”) ซึ่งเป็นการกำหนดกลุ่มเป้าหมายให้ SVM โดยที่ SVM นั้นมุ่งเป้าเพื่อหาฟังก์ชันการตัดสินใจที่สามารถแยกแยะค่าที่ไม่ทราบได้



รูปที่ 2.9 แผนผังการทำงานของ Support Vector Machines

โดยใช้สมการที่

$$y = \text{sign} \left\{ \sum_{i=1}^n w_i \phi_i(x) + b \right\} \quad (2-3)$$

$$\phi(x) = [\phi_1(x), \phi_2(x), \dots, \phi_n(x)]^T \quad (2-4)$$

- เมื่อ sign หมายถึง ถ้าค่าที่ได้มากกว่า 0 จะเป็น +1 แต่ถ้าน้อยกว่า 0 จะเป็น -1
 w_i เป็นเวกเตอร์น้ำหนัก (Weighting) ที่เชื่อมโยงจาก feature space ไปสู่ output space
 x เป็นกลุ่มข้อมูลซึ่งไม่สามารถแยกได้ด้วยสมการเด็นตรงให้อยู่ในรูปแบบที่สามารถใช้สมการแบ่งแยกได้
 $\phi(x)$ แทนฟังก์ชันสำหรับแปลงข้อมูลที่ไม่เป็นเชิงเด่นเป็นข้อมูลที่อยู่ในรูปแบบที่สมการเชิงเด่นสามารถแยกแยะได้
 b เป็นค่าไบอัส (bias) เป็นค่าโน้มเอียงหรือ threshold ที่ตั้งไว้ทำให้สมการที่ (2-5) สำหรับจำแนกข้อมูล

$$f(x) = \sum_{i=1}^n w_i \phi_i(x) + b \quad (2-5)$$

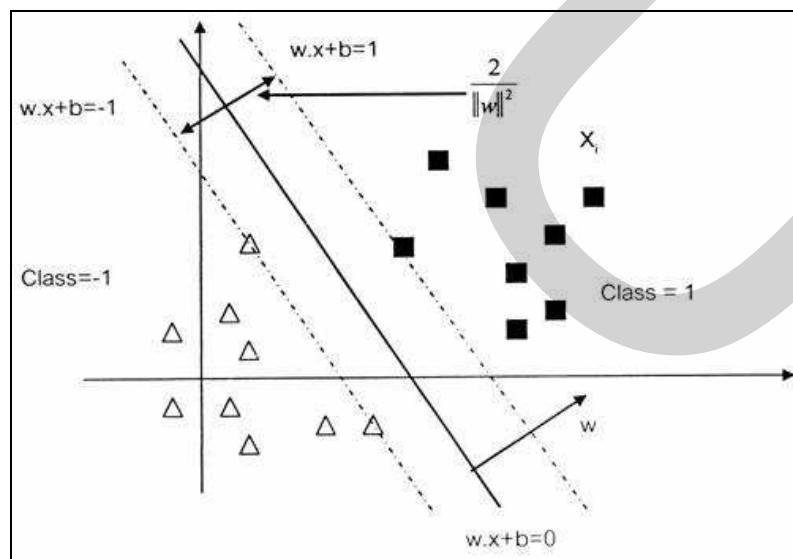
ฟังก์ชันที่สร้างการแบ่งประเภทของข้อมูลเชิงเส้น และได้ฟังก์ชันการแบ่ง $f(x)$ ถ้าข้อมูลเซต D นั้นสามารถแยกโดยใช้สมการแบบเส้นตรง ก็แสดงว่ามีการแบ่งแยกประเภทที่สมบูรณ์ กรณีการจัดแบ่งประเภทสำหรับค่า y ถูกกำหนดให้มีค่าเป็น $+1$ และ -1 ดังนั้นในสมการที่ (2-6) และ (2-7) สามารถเขียนรวมกันได้ดังสมการ (2-8)

$$w^T \cdot x + b \geq +1 ; y_i = +1 \quad (2-6)$$

$$w^T \cdot x + b \leq -1 ; y_i = -1 \quad (2-7)$$

$$y(w^T \cdot x + b) - 1 \geq 0 ; \forall i \quad (2-8)$$

ทำให้สามารถแบ่งแยกข้อมูลทั้ง 2 กลุ่ม ได้อย่างชัดเจน รวมทั้งเป็นการแก้ปัญหาซึ่งเน้นเรื่อง การกำหนดระยะแยกแยะ (Margin) ให้มีขนาดกว้างที่สุด โดยการเลือกไฮเปอร์เพลน (Hyperplane) ที่เหมาะสม โดยมีข้อแม้ว่าในช่วงระยะแยกแยะ ไม่มีข้อมูลอยู่ ดังรูปที่ 2.10 ดังสมการที่เป็นเชิงเส้น และสามารถแยกข้อมูลได้เกิดจากการเพิ่มขอบเขตเส้นแบ่งที่มีความกว้างเท่ากับ $2/\|w\|^2$



รูปที่ 2.10 ตัวอย่างการแยกข้อมูลด้วย SVM

หากแต่บางครั้งก็ไม่สามารถที่จะแยกแยะข้อมูลได้ลูกต้องทั้งหมด ทำให้ต้องมีการกำหนดตัวแปรเพื่อยอมรับค่าความผิดพลาด โดยทำการเพิ่มตัวแปร ξ (Slack Variable) โดยเขียนแสดงรายละเอียดได้ดังสมการ (2-9) และ (2-10)

$$w^T \cdot x + b \geq +1 - \xi ; y_i = +1 \quad (2-9)$$

$$w^T \cdot x + b \geq -1 + \xi ; y_i = -1 \quad (2-10)$$

โดย $\xi > 0$

ทำให้ได้โครงสร้างของ SVM ซึ่งประกอบด้วย 2 ส่วนหลักคือ การเพิ่มระยะแยกแยะมากที่สุด และการแก้ปัญหาด้วยการลดข้อผิดพลาดให้ต่ำที่สุด ดังแสดงในสมการที่ (2-11)

$$\underset{w,b,\xi}{\text{Minimize}} \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i \quad (2-11)$$

โดยที่ : $y_i(w^T \phi(x_i) + b) + \xi_i - 1 \geq 0$

เมื่อ $\xi_i \geq 0, i = 1, 2, \dots, N$

จากสมการ (2-11) พบว่าสมการมีอยู่ 2 ส่วนด้วยกัน ได้แก่ สมการที่ใช้แทนการปรับค่าระยะแยกแยะข้อมูล (Margin) เพื่อใช้ห่างจากเส้นตัดให้远一些 ที่สุด ส่วนที่สองแทนการปรับค่าผิดพลาดให้ต่ำสุด โดยมีค่า C ซึ่งเป็นค่าตัวแปรที่ผู้ใช้สามารถกำหนดค่าได้เอง เพื่อปรับความสมดุลระหว่างการให้ความสำาคัญของระยะแยกแยะสูงสุด หรือให้ความสำาคัญกับค่าความผิดพลาดที่ต้องการให้ต่ำที่สุด โดยปกติค่า C จะกำหนดให้มีค่ามากกว่า 1 以便นั้นทำการแก้ปัญหาด้วยฟังก์ชัน Lagrangian ด้วยการกำหนดค่าตัวแปรแบบเซตคู่ (Dual Sets) เพิ่มเติม แล้วทำการแก้ปัญหาจากการกำหนดข้อจำกัดที่ต้องการให้ต่ำที่สุด (Constrained Optimization) ทำให้ได้ผลดังสมการที่ (2-12)

$$\underset{\alpha}{\text{Minimize}} \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N y_i y_j \alpha_i \alpha_j K(x_i, x_j) - \sum_{i=1}^N \alpha_i \quad (2-12)$$

โดยที่ : $\sum_{i=1}^N y_i \alpha_i = 0$

เมื่อ $0 \leq \alpha_i \leq C, i = 1, 2, \dots, N$

โดยที่ α_i (แอลฟ่า) เป็น Lagrange multipliers เพื่อที่จะใช้สำหรับการแก้ปัญหาที่ดีที่สุด α_i^* เพื่อให้สำเร็จในการจำแนกข้อมูลที่ไม่ได้เป็นพังก์ชันการจำแนกข้อมูลแบบเชิงเส้นดังสมการ (2-13)

$$f(x) = \sum_{j=1}^N w_j \alpha_j^* K(x, x_j + b) \quad (2-13)$$

ในขณะที่ $K(x, x_j) = \phi^T(x)\phi(x_j)$ นั้นเป็น kernel function และมี kernel function ที่พบได้บ่อย 3 แบบด้วยกันดังแสดงในตารางที่ 2.2

ตารางที่ 2.2 ชนิดของคอร์เนลฟังก์ชัน

ชนิดของคอร์เนลฟังก์ชัน	คอร์เนลฟังก์ชัน
Radial Basis Function (RBF)	$K(x, x_i) = \exp(-\ x - x_i\ ^2 / 2\sigma^2)$
Polynomial	$K(x, x_i) = (x_i^T x + r)^d$
Linear	$K(x, x_i) = x_i^T x$

สำหรับในวิทยานิพนธ์ฉบับนี้ได้นำคอร์เนลแบบ Radial Basis Function (RBF) เป็น Kernel Function มาใช้เพื่อทำการเปรียบเทียบกับการแบ่ง SVM แบบ Linear เนื่องจากได้มีผู้วิจัยหลายท่านได้ทดลองแล้วพบว่า Kernel function นี้ให้ผลลัพธ์ที่ดี จานนั้นจะทำการทดสอบตามขั้นตอนที่ผู้วิจัยกำหนดขึ้นซึ่งขั้นตอนการดำเนินงานในการทดสอบจะได้กล่าวถึงในบทต่อไป

2.7 งานวิจัยที่เกี่ยวข้อง

ได้ทำการศึกษาเกี่ยวกับลักษณะการทำงานของระบบงานการป้องกันข้อมูลรั่วไหล และให้ความสนใจในประเด็นในส่วนของการแยกประเภทเอกสารก่อนนำเข้าระบบ งานวิจัยที่เกี่ยวกับการออกแบบระบบป้องกันข้อมูลรั่วไหล ผลกระทบของการรั่วไหลของข้อมูลสำคัญ และช่องทางการรั่วไหลของข้อมูล ออกมายในช่วงหลังนี้อย่างต่อเนื่อง รวมทั้งงานวิจัยเกี่ยวกับการแบ่งประเภทข้อมูลออกมาในช่วงหลายปีที่ผ่านมา ซึ่งสามารถนำมาใช้ในการวิเคราะห์และศึกษาได้เป็นอย่างดี

Gilberto และคณะ (2010) ได้นำเสนอ Security Framework สำหรับการป้องกันภัยคุกคามที่มากับ Social Network โดยกล่าวถึงเทคโนโลยี Data Loss Prevention เป็นวิธีป้องกันการรั่วไหลของข้อมูลสำคัญ วิธีการที่ใช้โดยทั่วไปประกอบด้วยโซลูชัน องค์ประกอบเครือข่าย หรือทั้ง

สองส่วน ก่อว่าถึงพื้นฐานของนโยบายการรักษาความปลอดภัย ความปลอดภัยของเอกสารสำคัญ ก่อว่าถึงความสำคัญของนโยบายที่เกินกว่าคำนิยามของบทบาทความรับผิดชอบสำหรับเจ้าหน้าที่ และบุคคลผู้เกี่ยวข้อง หรือคู่ค้า เอกสารสำคัญเป็นสาเหตุทำให้เกิดช่องโหว่จากภัยคุกคาม ที่อาจก่อให้เกิดปัญหาและส่งผลกระทบต่อสารสนเทศที่พัฒนาขึ้นอย่างรวดเร็วในปัจจุบัน พื้นฐานของการป้องกันการสูญหายของข้อมูล ครอบคลุมทุกอย่างตั้งแต่ข้อมูลที่เป็นความลับเกี่ยวกับลูกค้า หนังสือไปรษณีย์ บุคลากรของบริษัท ที่ถูกส่งไปรษณีย์ ฯลฯ การสูญหายของข้อมูล พนักงานที่มีโอกาสเกิดขึ้นได้ตลอดเวลา กับบุคคลที่สาม หรือบุคคลภายนอกที่มีการลักลอบนำข้อมูลลูกค้า การเงินหรือทรัพย์สินทางปัญญา และข้อมูลที่เป็นความลับอื่นๆ ซึ่งถือเป็นการละเมิดนโยบายขององค์กร โดยมีอยู่ 3 ส่วนที่นำมาพิจารณาเพื่อลดการสูญเสีย คือ ข้อมูลเคลื่อนไหว เป็นข้อมูลใดๆที่มีการเคลื่อนไหวผ่านทางเครือข่ายไปรษณีย์ ข้อมูล ณ จุดปลายทางซึ่งเป็นจุดสิ้นสุดของเครือข่าย สำหรับอุปกรณ์ USB และแล็ปท็อป แสดงให้เห็นรูปแบบ DLP ระบบข้อมูลการป้องกัน และแก้ไขปัญหาการสูญเสียและใช้การควบคุมข้อมูลเคลื่อนไหวในโหมดของการติดต่อสื่อสารทางอิเล็กทรอนิกส์ผ่านตัวกรอง ที่กำหนดไว้ล่วงหน้า หรือป้ายชื่อในการจำแนกข้อมูลลงในไฟล์

Daeseon และคณะ (2006) ได้นำเสนอ method สำหรับการป้องกันข้อมูลส่วนบุคคลที่มีการร่วมกันผ่านทางระบบอินเตอร์เน็ต ก่อว่า “ทุกๆ packet ที่ถูกส่งผ่านทางเครือข่ายจากคอมพิวเตอร์ส่วนบุคคลออกไปยังอินเตอร์เน็ต เชิฟเวอร์ จะถูกเช็คถ้าหาก packet ดังกล่าวประกอบด้วยข้อมูลส่วนบุคคลจะถูกตรวจสอบและมีการตัดสินใจเกี่ยวกับการส่งข้อมูลนั้นๆ โดยการตัดสินใจดังกล่าว ขึ้นอยู่บนพื้นฐานของนโยบายที่ได้ทำการควบคุม เป็นการนำเสนอรูปแบบการควบคุมข้อมูลส่วนบุคคลในการ transfer และ description ของระบบโครงสร้าง ก่อว่าถึงข้อมูลส่วนบุคคล เช่น ID และ password เป็นเหตุให้มีการสวมสิทธิ์ เนื้อหาข้อมูล เช่น อีเมลล์แอดเดรส และหมายเลขโทรศัพท์เป็นเหตุให้มีอีเมลล์เบอร์ หรือโทรศัพท์ก่อกรณ หมายเลขบัตรเครดิต หรือเลขบัญชีธนาคาร ที่ถูกใช้สำหรับอาชญากรรมบนโลกอินเตอร์เน็ต มีหลายช่องทางที่ข้อมูลเหล่านี้จะหลุดรอดออกໄไป อาจจะโดยการหลอกลวงผ่านทาง อินเตอร์เน็ตหรือทางเว็บไซต์ปลอมที่ทำให้เหมือนเป็นหน้าเว็บจริง และหลอกให้มีการกรอกข้อมูลสำคัญลงໄไป ชอร์ฟแวร์หลอกลวงที่ถูกติดตั้งลงในคอมพิวเตอร์ส่วนบุคคลและพยายามดักจับข้อมูลผ่านการกดแป้นพิมพ์ โดยชอร์ฟแวร์เหล่านี้จะส่งข้อมูลไปยังผู้ประสงค์ร้าย ที่ได้ทำการติดตั้งชอร์ฟแวร์หลอกลวงนี้ไว้ โดยผู้วิจัยได้นำเสนอวิธีสำหรับการป้องกันการร่วมกัน โดยใช้พื้นฐานที่ว่าจะไม่ส่งข้อมูลส่วนบุคคลออกໄไป “Do not send the personal information to the hazardous recipient” มีการนำเสนอ รูปแบบการควบคุมการถ่ายโอนข้อมูลส่วนบุคคลซึ่งประกอบด้วยองค์ประกอบดังนี้ ข้อมูลส่วนบุคคล ผู้ใช้งาน

โปรแกรมที่ใช้ส่ง หรือรูปแบบการส่ง ปลายทาง ข้อมูล log ของการถ่ายโอนข้อมูลส่วนบุคคล นโยบาย และขั้นตอนในการควบคุมด้วย ในส่วนของ ระบบควบคุมการถ่ายโอนข้อมูลส่วนบุคคล ประกอบด้วยองค์ประกอบดังต่อไปนี้ เครื่องมือในการตัดสินใจ นโยบายในการบริหารจัดการ ความน่าเชื่อถือของการบริหารจัดการ ระบบเฝ้าระวังของ packet และ http traffic และกลไกของ การทำงาน ประกอบด้วย เครื่องมือในการติดป้ายกำกับ การจับคู่กับต้นแบบ การจับคู่กับมูลค่า และ การวิเคราะห์ของ การรักษาความมั่นคงปลอดภัย

Yuguo Wang (2008) ได้นำเสนอการปรับใช้พื้นฐานของการจัดหมวดหมู่แบบ SVM มาใช้สำหรับการจัดหมวดหมู่สำหรับเอกสารห้องสมุดอิเล็กทรอนิกส์ ได้นำเสนอทฤษฎีของ SVM ที่ใช้ในการฝึกสอนและทดสอบในการแยกประเภทเอกสาร เนื่องจาก SVM เป็นเครื่องมือที่ได้รับ ความนิยม และมีความสามารถในการเรียนรู้จากชุดข้อมูลตัวอย่างขนาดเล็กในขั้นตอนการฝึกสอน และมีประสิทธิภาพสูงในการคำนวณ โดยทดสอบกับเอกสารจำนวน 10,000 ฉบับจาก 10 หัวข้อ ของห้องสมุดอิเล็กทรอนิกส์ ในเอกสาร 1,000 ฉบับของแต่ละหัวข้อ โดยแต่ละเอกสารจะถูกแทน ด้วยค่าเวกเตอร์ TFIDF และนำเข้ากระบวนการ SVM เพื่อจำแนกประเภท ทำการทดลองกับ 4 ลักษณะ ทำการแยกประเภทที่แตกต่างกัน คือ 1vs1, DSAGSVM, 1vs.rest และ Tree SVM ประสิทธิภาพที่ได้จากการทดลองพบว่า 1vs1 มีประสิทธิภาพในการแยกประเภทมากที่สุด ในเมื่อ ของความเร็วประมวลผล ส่วน Tree SVM ใช้เวลาน้อยกว่าแบบ 1vs1 ถึง 13 เท่าแต่มีประสิทธิภาพ ใน การแยกประเภทน้อยกว่าถึง 20% เมื่อเทียบกับการแยกประเภทโดยวิธีอื่น

Zhijie และคณะ (2010) นำเสนอขั้นตอนวิธีการจัดหมวดหมู่ตามตัวอักษร SVM เปรียบเทียบกับการจัดหมวดหมู่ด้วยวิธีการอื่น โดยในขั้นตอนของการวนการแยกประเภท ข้อความ จะทำการเตรียมชุมข้อมูลและสกัดให้อยู่ในรูปแบบของคุณลักษณะ ตามรูปแบบที่ระบบ ต้องการ ขนาดของชุดข้อมูลจะปรับช่วงของข้อมูลเป็น [-1,1] เพื่อหลีกเลี่ยงคุณลักษณะที่มีขนาด ใหญ่ และลดปัญหาในการคำนวณเชิงตัวเลขของการฝึกสอนชุดข้อมูล รูปแบบที่ได้จากการ ดำเนินการทดสอบและพยากรณ์ สุดท้ายจะได้ผลลัพธ์จากการจัดหมวดหมู่ กล่าวถึงกระบวนการ ทั่วไปของการจัดหมวดหมู่ ข้อความ ด้วย 4 โมดูล การเตรียมข้อความ การสกัดคุณลักษณะ การ ฝึกอบรม และรูปแบบการฝึกอบรม โดยอธิบายพื้นฐานของ SVM ในขั้นตอนการจำแนกข้อความ และนำเสนอรูปแบบการจัดหมวดหมู่ การวิเคราะห์ข้อมูล และการจัดหมวดหมู่ข้อความผ่านการจัด หมวดหมู่อัตโนมัติ ทำให้สามารถแยกประเภทข้อความได้ ช่วยให้ผู้เกี่ยวข้องสามารถค้นหาและ วิเคราะห์ความสำคัญของเอกสาร ได้ มีการใช้ SVM ซึ่งอยู่บนพื้นฐานของทฤษฎีการเรียนรู้ ข้อดี ของ SVM คือมีโครงสร้างการทำงานที่ง่าย และมีประสิทธิภาพ กล่าวถึงเทคนิคการจัดหมวดหมู่ที่ ประกอบด้วยวิธีการแบบ Descision Tree, KNN, Naïve Bayesian และ SVM กล่าวถึงลักษณะของ

วิธีการแต่ละประเภท มีการนำเสนอการจัดหมวดหมู่ข้อความบนพื้นฐานของ SVM กระบวนการประมวลผลข้อความ การดึงลักษณะ การฝึกสอน และการทดสอบ ผลที่ได้จากการทดลองการแยกประเภทแบบ KNN, Naïve Bayesian และ SVM พบว่า อัตราความถูกต้อง (Accuracy Rate) และอัตราการเรียกคืน (Recall rate) ของคุณภาพการจัดหมวดหมู่ SVM ให้ค่าความถูกต้องมากกว่าการจัดหมวดหมู่แบบ KNN และ Naïve Bayesian

พรพล ธรรมรงค์รัตน์ (2552) นำเสนองานวิจัย การจำแนกประเภทเว็บโดยวิธีการลดขนาดลักษณะเฉพาะและซัพพอร์ตເගເຕອຣ໌ແມ່ຊື້ນ “ได้นำเสนอขั้นตอนการจำแนกประเภทเว็บ โดยแบ่งขั้นตอนการทำงานเป็น 4 ขั้นตอนคือการเตรียมข้อมูลเว็บ การสร้างลักษณะเฉพาะ การลดขนาดลักษณะเฉพาะ การจำแนกประเภท และการให้คะแนนเสียง โดยการวิจัยได้ใช้เทคนิคการให้น้ำหนักคำ TFIDF การลดขนาดลักษณะเฉพาะ และใช้เทคนิคซัพพอร์ตເගເຕອຣ໌ແມ່ຊື້ນ SVM ร่วมกับอัลกอริทึม การให้คะแนนเสียงมาสร้างแบบจำลอง เพื่อให้ได้ผลการจำแนกประเภทที่ถูกต้องมากขึ้น

ปอยชร และกานดา (2548) ได้นำเสนองานวิจัยเกี่ยวกับการปรับปรุงกฎสำหรับการตัดคำในเอกสารภาษาไทย กล่าวถึงลักษณะของคำในภาษาไทย ที่นอกจากจะมีคำไทยแท้แล้ว ยังมีบางคำที่มาจากภาษาต่างประเทศ ที่ถูกสะกดอยู่ในรูปของคำอ่านภาษาไทย และบางคำจะมีการผสมอักษรที่แตกต่าง ลักษณะของประโยชน์ในภาษาไทยมีการเปลี่ยนติดกันทำให้การแยกและคำมีปัญหา จึงได้นำหลักเกณฑ์ ที่เรียกว่าอักษรวิธีมาใช้ในการแยกและระดับย่อของคำ วิธีการหลักสำหรับการตัดคำในเอกสารภาษาไทย คือ การใช้กฎเพื่อตัดคำภาษาไทยโดยการใช้ไวยกรณ์ทางภาษา แบ่งตัวอักษรเป็นหมวดหมู่ตามลักษณะการใช้งาน ได้แก่ กลุ่มพยัญชนะ กลุ่มสรร กลุ่มวรรณยุกต์ กลุ่มตัวเลข และอักษรพิเศษ ขั้นตอนการตัดพยางค์จากชัยไปขวาเป็นส่วนใหญ่ การใช้พจนานุกรม ผลลัพธ์ที่ได้จะอยู่ในระดับคำ โดยทำการตรวจสอบสายอักษร ซึ่งเป็นชุดของตัวอักษรที่ได้จากเอกสาร จากนั้นนำไปค้นหาคำในพจนานุกรม หากพบคำในพจนานุกรมที่สามารถเป็นคำในสายอักษรนั้น ได้มากกว่าหนึ่งคำ จะทำการเลือกคำที่ยาวที่สุด (Longest Matching) หากอักษรตัวต่อมานไม่พบคำที่ตรงในพจนานุกรมที่มีอยู่ จะทำการย้อนกลับไปเลือกคำที่สั้นกว่าแทน และกฎที่งานวิจัยได้นำเสนอเพิ่มเติมจากกฎที่มีอยู่ คือการตัดคำที่มีความเกี่ยวข้องกับภาษาต่างประเทศ และคำที่อยู่นอกเหนือจากการประสมตามอักษรวิธี คำที่ได้จากเอกสารจะถูกนำไปแบ่งครั้งแรกด้วยช่องว่างระหว่างประโยชน์ และนำไปแยกในระดับพยางค์โดยใช้กฎ ผลที่ได้จากการแบ่งด้วยกฎจะถูกจัดเก็บเป็นสองส่วน คือส่วนที่ต้องนำไปค้นหาต่อในพจนานุกรม และไม่ต้องนำไปค้นหาต่อ ได้แก่ สัญลักษณ์ - / , . คำที่มีตัวเลขและคำที่ตัวอักษรต่างประเทศอยู่ระหว่างประโยชน์ที่ถูกแบ่งด้วยช่องว่างซึ่งถือเป็นคำที่สมบูรณ์แล้ว

อภิชาต งานทอง และคณะ (2546) ได้นำเสนอผลงานวิจัย การสรุปใจความสำคัญของเอกสาร โดยเลือกประโยคที่แสดงถึงเนื้อหาหลักของเอกสาร และนำประโยคที่ได้มาสร้างเป็นใจความสำคัญของเอกสาร เป็นการนำทฤษฎีการให้น้ำหนักคำโดยใช้สูตรการหาค่า TFIDF และการประเมินใจความสำคัญที่ได้ เพื่อหาแนวทางในการสรุปใจความสำคัญของเอกสารภาษาไทย เนื่องจากโครงสร้างประโยคภาษาไทยมีความซับซ้อน การหาข้อมูลของประโยคจึงทำได้ยาก ซึ่งแนวทางของการสรุปใจความสำคัญจะแบ่งตามลักษณะได้เป็น การยึดตามค่าความถี่เป็นหลักสำคัญ (Frequency-Based) โดยวิธีนี้จะดูที่ความถี่และตำแหน่งของคำในเอกสารเป็นหลัก และยึดหลักตามฐานความรู้ (Knowledge -Base) โครงสร้างหลักของเอกสารที่ได้ จะขึ้นอยู่กับการตีความจากฐานความรู้ที่มีอยู่โดยใช้เทคนิคของการแยกแยะ (Classification) มีการสร้างโครงรูป (Template) ตามประเภทเอกสาร และยึดตามความสอดคล้องและความเข้ากันได้ (Discourse-Based) โดยยึดตามโครงสร้างของประโยคภาษาบ้านๆ โดยขั้นตอนในการสรุปใจความสำคัญ แบบดึงจากต้นฉบับ มีขั้นตอนหลักๆ 3 ขั้นตอน คือการแยกคำสำคัญ การแยกประโยค และการเรียงประโยค เป็นใจความสำคัญ ในขั้นตอนการแยกคำสำคัญ นั้นจะขึ้นอยู่กับการพิจารณาความสำคัญของเอกสาร ความสำคัญของคำ จะขึ้นอยู่กับจำนวนครั้งของคำที่ปรากฏอยู่ในประโยค โดยปกติแล้วคำที่ออกในประโยคจะถูกพิจารณาว่าเป็นคำสำคัญสำคัญนั้นปรากฏอย่างครั้งในประโยค แต่ปรากฏน้อยครั้งในเอกสารทั้งหมด โดยใช้สูตรการหาค่า TFIDF ใน การแยกประโยค และนำมารวบรวมห้องความสำคัญของประโยค เป็นผลต่อเนื่องจากความถี่ของคำสำคัญ และตำแหน่งของคำสำคัญที่พบในประโยคนั้น โดยในส่วนของคำที่มีความถี่สูงเกินไป และความถี่น้อยเกินไป จะถูกตัดทิ้ง ก็จะได้ข้อมูลของคำที่มีประโยคชนิดในการพิจารณาความสำคัญของประโยค

นนท์ บุญนิธิประเสริฐ (2553) นำเสนอผลงานวิจัยเกี่ยวกับการกรองข้อความภาษาไทย และภาษาอังกฤษของบริการส่งข้อความสั้นบนเครือข่ายโทรศัพท์เคลื่อนที่ เป็นการพัฒนาวิธีการกรองข้อความสั้น ที่สามารถใช้งานได้กับข้อความภาษาไทย ภาษาอังกฤษ และภาษาไทยปนภาษาอังกฤษ ให้สามารถกรองข้อความแปลงอักษรจากบริการส่งข้อความสั้นในเครือข่ายโทรศัพท์เคลื่อนที่ โดยการทำงานจะอธิบายการกรองข้อความ เมื่อตัวกรองได้รับข้อความจากชุมสาย (BTS/MSC) และถอดข้อความจาก SMPP Message ให้อยู่ในรูปของ text เข้าสู่กระบวนการ TN เพื่อลบ Character ที่ไม่สามารถตัดเป็นคำออกไป เช่น @ # ! . รวมถึงตัวเลข เมื่อข้อความพร้อมจะทำการตัดคำภาษาอังกฤษด้วยการตรวจสอบการเร้นวรรคจากนั้นจะลบคำที่จัดอยู่ในประเภท Stop words ออก และทำการเปลี่ยนเที่ยงคำเข้ากับ TFIDF ตามอัลกอริทึมการกรองเพื่อสรุปผลของข้อความว่าจัดเป็นข้อความปกติหรือข้อความแปลง ใช้วิธีการคืนหาลักษณะเด่นของเอกสาร ให้อยู่ในรูปของกลุ่มข้อมูล (Feature Vector) โดยอ้างอิงจากชุดตัวอักษรหรือคำในเอกสาร

และจำนวนเอกสารทั้งหมดที่ถูกกำหนดให้เป็นข้อมูลฝึกสอน ใช้วิธี TFIDF ในการแปลงเอกสารที่ต้องการนำไปคำนวณให้เป็นชุดข้อมูล Vector เพื่อนำไประบุการจำแนก นำข้อมูลเข้าสู่กระบวนการตัดคำ และนำเข้าสู่กระบวนการจำแนกโดยใช้เทคนิค SVM เนื่องจากง่ายต่อการพัฒนา และให้ผลลัพธ์เป็นที่น่าพึงพอใจ ก่อนจะนำคำจำแนกมาใช้ต้องมีการฝึกฝนโดยใช้ลักษณะที่จะใช้บ่งบอกแต่ละพฤติกรรม ลักษณะดังกล่าวจะถูกปรับค่าเพื่อให้อยู่ในช่วงที่เหมาะสม โดยกำหนดช่วงที่เหมาะสมเป็น [-1,1] เพื่อหลีกเลี่ยงปัญหาความซับซ้อนจากการคำนวณ โดยการปรับค่าจะถูกใช้สำหรับลักษณะที่ใช้ในการฝึกฝนและลักษณะที่จะทดสอบ

จันทิมา พลพินิจ และคณะ (2549) “ได้นำเสนองานวิจัย เกี่ยวกับการสร้างตัวกรองเว็บออนไลน์ แบบอัตโนมัติ และวิธีการกรองเว็บโดยใช้ฐานข้อมูล มีการประยุกต์ในเรื่องของการจัดกลุ่มเอกสารโดยใช้ ความเป็นไปได้ในการแยกประเภท ได้แก่ คำถึงระบบการกรองเว็บซึ่งแบ่งออกเป็น 2 ลักษณะ คือ พื้นฐานของ Metadata ซึ่งเป็นระบบการกรองเว็บโดยอาศัยข้อมูลหรือสารสนเทศจากภายนอกเว็บ และการใช้ฐานข้อมูล เป็นระบบการกรองเว็บที่ใช้สารสนเทศบนหน้าเว็บ เช่น ข้อความ รูปภาพ เป็นส่วนสำคัญในการสร้างโมเดลหรือตัวกรอง โดยนำเสนอกระบวนการวิจัยแบ่งขั้นตอนเป็นการตัดคำแบบพจนานุกรม โดยวิธีการเทียบคำที่ยาวที่สุด (Longest matching) การหาความถี่และน้ำหนักคำโดยสมการหาความถี่และน้ำหนักคำ TFIDF การวัดประสิทธิภาพโดยการหาค่า F-Measure และจำแนกประเภทโดยใช้ตัวแยกประเภท นาอีฟเบลส์ (Naïve Bayes) และผลลัพธ์ที่ได้จะเกิดจากการประมวลผลค่าในเชิงสถิติ ถูกเรียกว่า “Probabilistic Classifier” โดยโครงสร้างโมเดลกรองจาก Web Site จำนวน 200 Web Site (Training Set) และทดสอบจาก 120 Web Site (Test Set) ขนาดเวกเตอร์ของคำ 6,189 คำ จากผลการทดลองพบว่า จำนวนคำที่พบในเอกสารเป็นปัจจัยสำคัญในการสร้างโมเดลสำหรับการกรองเว็บโดยอาศัยข้อความ ดังนั้นหากเพิ่มขนาดของ bag of words ให้มีขนาดใหญ่ขึ้นอาจจะถึงความถูกต้องในการทดลองที่เพิ่มขึ้นด้วย

นิเวศ จิระวิชิตชัย (2554) การพัฒนาประสิทธิภาพการจัดหมวดหมู่เอกสารภาษาไทย แบบอัตโนมัติ เป็นงานวิจัยที่นำเสนอแบบจำลองการจัดหมวดหมู่เอกสารภาษาไทย โดยการลดคุณลักษณะของเอกสารก่อนนำไปประมวลผลด้วยเครื่องจักรเรียนรู้ เพื่อลดความซ้ำของข้อมูล และลดระยะเวลาประมวลผล ประยัดทรัพยากรของระบบและเพิ่มประสิทธิภาพในการจัดหมวดหมู่ โดยวัดประสิทธิภาพการจัดหมวดหมู่เอกสารที่ระดับคุณลักษณะที่ดีที่สุดพบว่าอัลกอริทึม SVM ให้ประสิทธิภาพสูงสุดคือ 94.3% รองลงมาเป็นอัลกอริทึม Naive Baye 86.2% และอัลกอริทึม RBF 86.1% อัลกอริทึม J48 79.7% อัลกอริทึม Ripper 78.9% และอัลกอริทึม KNN 70.3% ตามลำดับ

กรัณยา จำมุกครัตน์ (2552) การเปรียบเทียบประสิทธิภาพการคัดเลือก และจำแนกข้อมูลด้วยวิธีการทางเครื่อข่ายประสาทเทียม เป็นการเปรียบเทียบประสิทธิภาพในการจำแนกข้อมูลโดยใช้เครื่องมือทางเครื่อข่ายประสาทเทียม ผลที่ได้อยู่ในระดับที่ยอมรับ ได้ที่จะนำวิธีการดังกล่าวไปใช้เพื่อพยากรณ์สถานะ (Class) ว่าปกติหรือผิดปกติ จากผลการทดลองที่ได้ จะเห็นว่าค่าประสิทธิภาพของแต่ละวิธีจากการใช้ข้อมูลชุดเดียวกันในการทดสอบนั้นๆ พบว่าค่าประสิทธิภาพการจัดกลุ่มของชุดข้อมูลที่ใช้ในการทดสอบแบบ SVM ที่ใช้ Kernel แบบ RBF จะให้ผลการทดสอบที่สูงกว่า MLP ได้ค่าความถูกต้อง 96.55 - 100 เปอร์เซ็นต์ การนำเทคนิคการคัดเลือกข้อมูลที่เหมาะสม เพื่อเพิ่มประสิทธิภาพการทำนาย เพื่อสังเคราะห์โมเดลได้อย่างรวดเร็ว และเพื่อลดความซับซ้อนของรูปแบบ โมเดลนี้ จะพบว่าผลของประสิทธิภาพการจำแนกไม่ต่างกับการคัดเลือกใช้เครื่องมือที่ทั่งหมดมากนัก โดยเฉพาะในการทดสอบแบบ SVM

บทที่ 3

ระเบียบวิธีวิจัย

3.1 แนวทางการวิจัยและพัฒนา

เนื่องด้วยมีการพัฒนาระบบงาน การป้องกันข้อมูลรั่วไหล เข้ามาใช้ในองค์กรด้วย อุปกรณ์ Symantec DLP เพื่อบริหารจัดการความปลอดภัยของข้อมูล สนับสนุนด้วยมาตรฐานด้าน ความมั่นคงปลอดภัยด้านเทคโนโลยีสารสนเทศ ISO/IEC27001:2005 เพื่อรักษาไว้ซึ่งความลับ (Confidentiality) ความถูกต้องครบถ้วน(Integrity) และความพร้อมใช้ (Availability) ของข้อมูล โดย ข้อมูลจะถูกเข้าถึงโดยผู้ที่มีสิทธิ์เท่านั้น และจะไม่ถูกแก้ไขดัดแปลง หรือเคลื่อนย้าย ถ้าไม่ได้รับ อนุญาต โดยตรงกับหลักความคุ้มหลักของระบบ ISO/IEC27001:2005 ในเรื่องของนโยบายความ มั่นคงปลอดภัย การจัดหมวดหมู่ของสินทรัพย์ ซึ่งข้อมูลสำคัญถือเป็นสินทรัพย์ขององค์กรรวมทั้ง การบริหารจัดการด้านการบริหารจัดการด้านการสื่อสาร และการเข้าถึงระบบข้อมูลสารสนเทศด้วย ยังสนับสนุน กฎหมายความมั่นคงปลอดภัยสารสนเทศ ที่ออกเป็นพรบ. ว่าด้วยธุรกรรม อิเล็กทรอนิกส์ ที่ประกาศบังคับใช้เมื่อ พ.ศ.2550 ที่ว่าด้วยการควบคุมการเข้าถึง และใช้สารสนเทศ รวมไปถึงการตรวจสอบ และประเมินความเสี่ยง (มาตรา 5) การคุ้มครองข้อมูลส่วนบุคคลในกรณี ที่มีการรวบรวมจัดเก็บข้อมูลไว้ ให้ทำการเผยแพร่ข้อมูลที่ระบุตัวตน เมื่อไม่ได้รับอนุญาต (มาตรา 6) การลักลอบดักข้อมูลคอมพิวเตอร์ของผู้อื่น ทั้งด้วยทาง Physical เช่น การก่อปี๊ ไฟล์ข้อมูลผ่านทางไดร์ฟพกพา ส่งผ่านแนบไฟล์ทางสื่ออิเล็กทรอนิกส์ หรือทาง Logical เช่นการทำ Packet Sniffing ข้อมูลคอมพิวเตอร์ของผู้อื่น การทำให้เสียหาย ทำลาย แก้ไข เปลี่ยนแปลง หรือ เพิ่มเติมข้อมูลคอมพิวเตอร์ของผู้อื่น โดยไม่ชอบ (มาตรา 9)

ด้วยความสามารถของอุปกรณ์ Symantec DLP จะทำงานในส่วนของการเฝ้าระวัง ข้อมูลสำคัญ และบังคับใช้นโยบายที่ได้กำหนดขึ้นเท่านั้น ยังขาดขั้นตอนการกำหนดข้อมูลสำคัญ และเป็นความลับขององค์กรก่อนนำเข้าสู่ระบบเพื่อเป็นข้อมูลด้านแบบในการกรองของระบบ ซึ่งใน ปัจจุบันมีการจัดเก็บในรูปแบบอิเล็กทรอนิกส์เป็นปริมาณมาก ยากต่อการระบุ และแยกประเภท ของเอกสาร จึงมีวัตถุประสงค์ในการออกแบบวิธีการแยกประเภทเอกสารในหน่วยงานย่อยต่างๆ โดยการสร้างระบบการคัดแยกประเภทเอกสาร เพื่อคัดแยกเอกสารสำคัญ ออกจากเอกสารทั่วไป ดัง กระบวนการของขั้นตอนการดำเนินงานวิจัยในตารางที่ 3.1

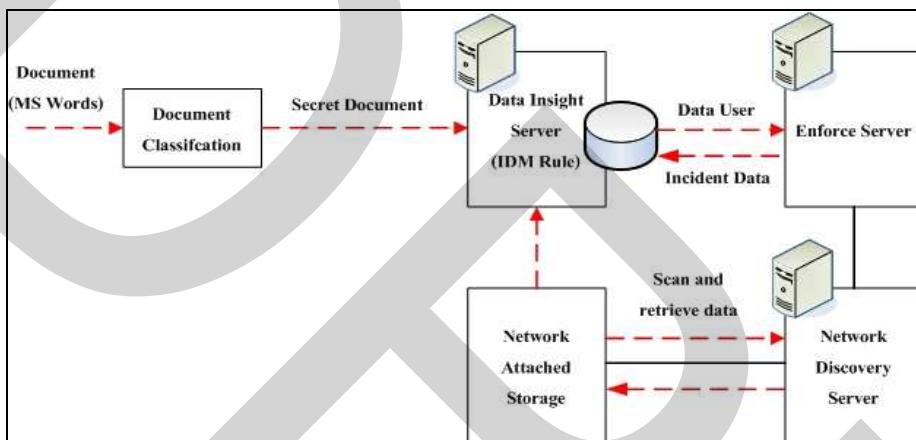
ตารางที่ 3.1 รายละเอียดกระบวนการของขั้นตอนในการดำเนินงานวิจัย

ขั้นตอนการ ทำงาน	วิธีการทำงาน
1	นำเอกสาร Microsoft Word (.doc) เข้าระบบ
2	แปลงไฟล์เอกสารจาก .doc ไปเป็นไฟล์ .txt โดยใช้โปรแกรม Antiword
3	นำเข้าไฟล์ .txt เข้าสู่กระบวนการตัดคำภาษาไทยโดยใช้โปรแกรม SWATI
4	นำคำที่ได้จากการตัดคำมาเปรียบเทียบกับข้อมูลคำหยุด และลบคำหยุดออก
5	คำนวณหาค่าคำน้ำหนักคำของแต่ละเอกสาร โดยใช้สมการ TF-IDF
6	กำหนดคุณลักษณะสำคัญ (Feature Selection) และสกัดคุณลักษณะสำคัญ (Feature Extraction) สำหรับเป็นข้อมูลนำเข้าในการแยกประเภทเอกสาร
7	นำเข้าค่าคุณลักษณะสำคัญ (คำน้ำหนักคำ) เพื่อคำนวณการแยกประเภทเอกสาร โดยใช้ LS-SVM
8	คำนวณอัตราความถูกต้องของการคัดแยกประเภทเอกสาร
9	นำเอกสารสำคัญที่ได้จากการแยกประเภทแล้วเข้าสู่ระบบป้องกันการรั่วไหลข้อมูล Symantec DLP

นำเอกสารที่ถูกกำหนดว่าเป็นเอกสารสำคัญ โดยหน่วยงานเจ้าของเอกสารนั้นๆ และเอกสารทั่วไป นำมาเป็นข้อมูลชุดฝึกสอน และชุดทดสอบ เรานำต้นแบบเอกสาร 145 ฉบับ มาทำการฝึกสอนเพื่อทำการแยกประเภทเอกสาร และจะนำชุดฝึกสอนนั้นมาเป็นต้นแบบในการทดสอบ กับชุดข้อมูลอื่นๆ ต่อไป ในวิทยานิพนธ์นี้ใช้เทคนิคการให้น้ำหนักคำ TF-IDF ร่วมกับเทคนิคชั้พ พอร์ตเวย์เตอร์แมชชีน (SVM) มาสร้างแบบจำลอง และพัฒนาโปรแกรมสำหรับแยกประเภทเอกสาร เพื่อความถูกต้องของผลการแยกประเภทเอกสาร และลดเวลาการคัดแยกเอกสารสำคัญออก จากเอกสารทั่วไป โดยมีเงื่อนไขว่าต้องเป็นเอกสารที่ถือว่าลึกลับไม่มีการเปลี่ยนแปลงเนื้อหา และระดับความสำคัญของเอกสาร ถ้าหากมีการเปลี่ยนแปลงจะต้องทำการแยกประเภทเอกสารใหม่อีกครั้ง เมื่อได้ผลลัพธ์จากการแยกประเภทเอกสารแล้ว จะนำเอกสารสำคัญมาเป็นโครงรูป ในการกรองเอกสารของระบบ การป้องกันข้อมูลรั่วไหล Symantec DLP ในส่วนของ IDM (Indexed Document Matching) Rule หรือการทำดัชนีเอกสารสำคัญบนเครื่อง Data Insight Server ซึ่งจะมี Database Relation ที่ทำงานร่วมกับ Enforce Server หรือเครื่องเซิฟเวอร์ที่ทำหน้าที่กำหนด และ

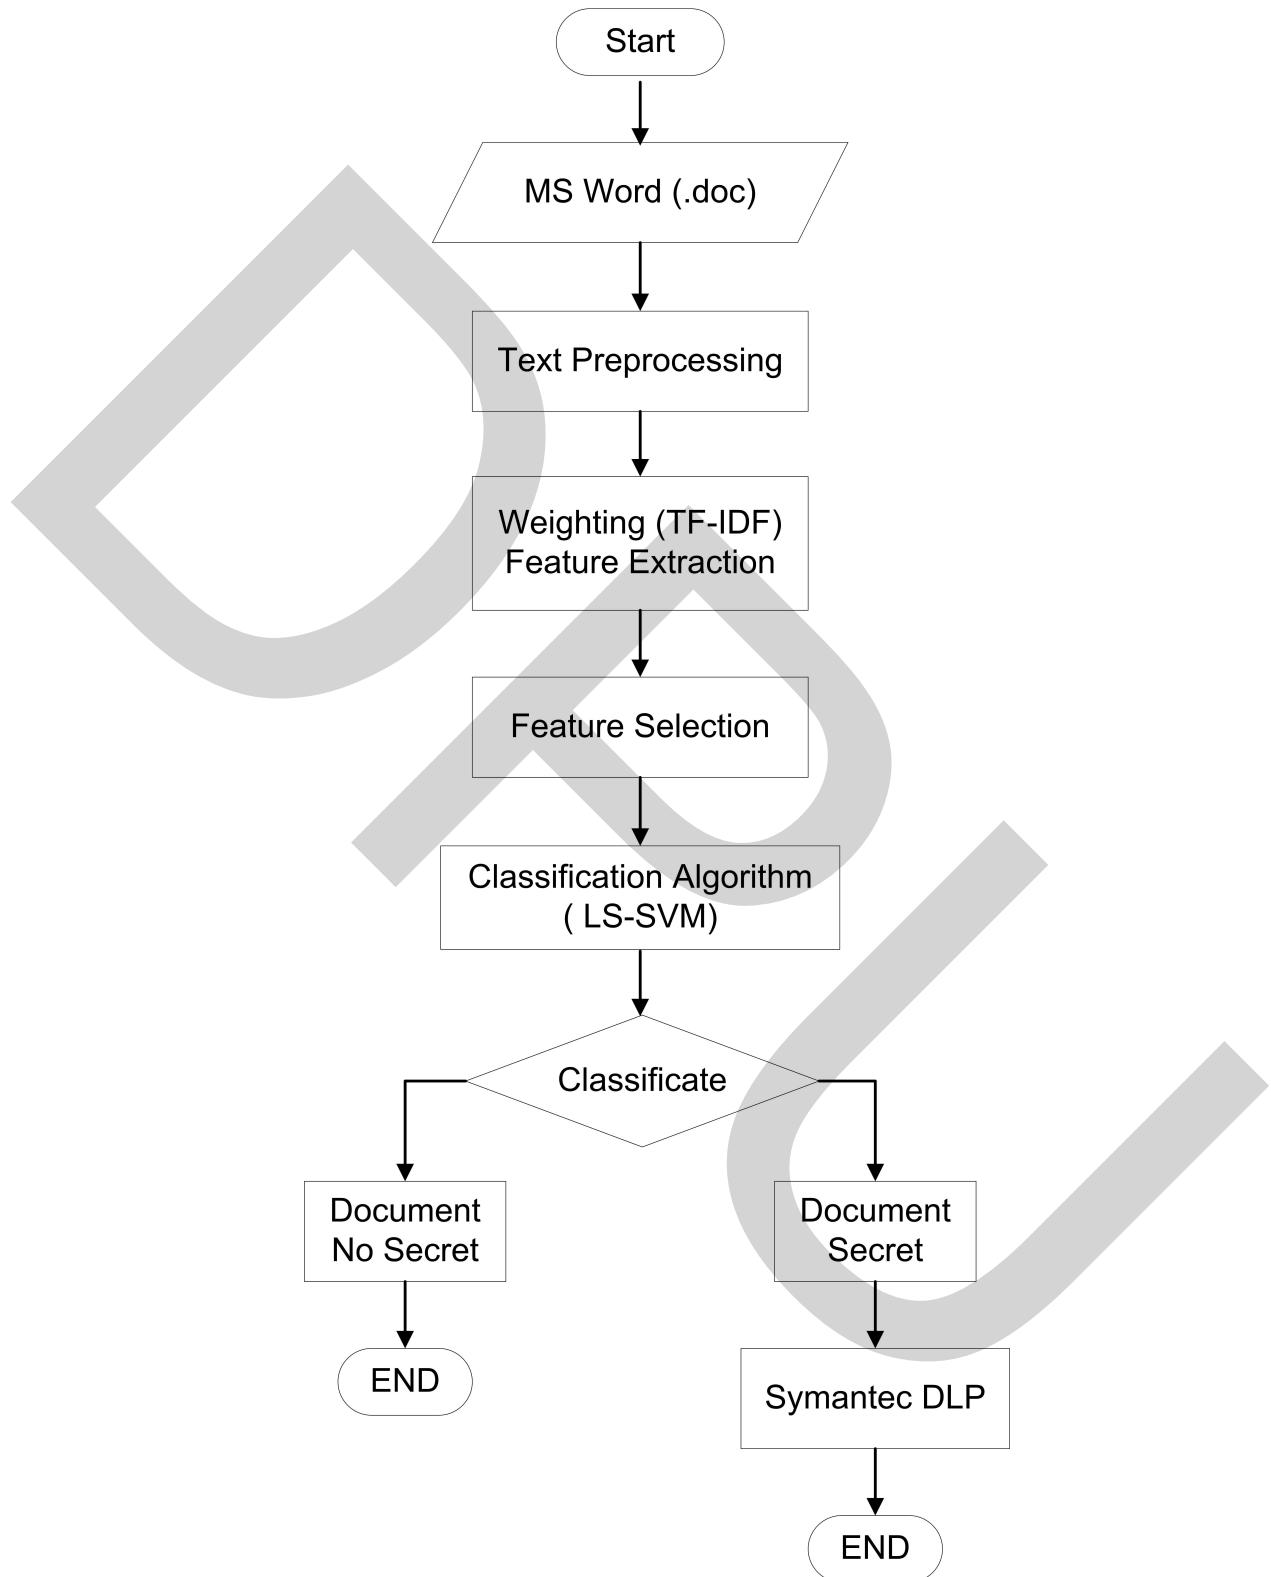
บังคับใช้นโยบายการป้องกันข้อมูล ส่วนของ Network Discovery Server ช่วยตรวจสอบการไหลของข้อมูลผ่านทาง DLP Agent ที่ติดตั้งอยู่บนเครื่องลูกข่าย

กฎของ IDM Rule จะทำการพิจารณาเนื้อหาจากเอกสารเฉพาะที่มีการลงทะเบียนไว้ว่าสำคัญ (เอกสารสำคัญที่เป็นเอกสารต้นฉบับ) และมีการตรวจสอบความเหมือนของเนื้อหาในเอกสารที่มีความเหมือน 80% หรือมากกว่าจากเอกสารต้นฉบับที่ได้ระบุไว้ใน IDM Rule ซึ่งเป็นเอกสารสำคัญที่ได้จากการแยกประเภทไว้ก่อนนำเข้าสู่ระบบ ดังแสดงการทำงานในรูปที่ 3.1



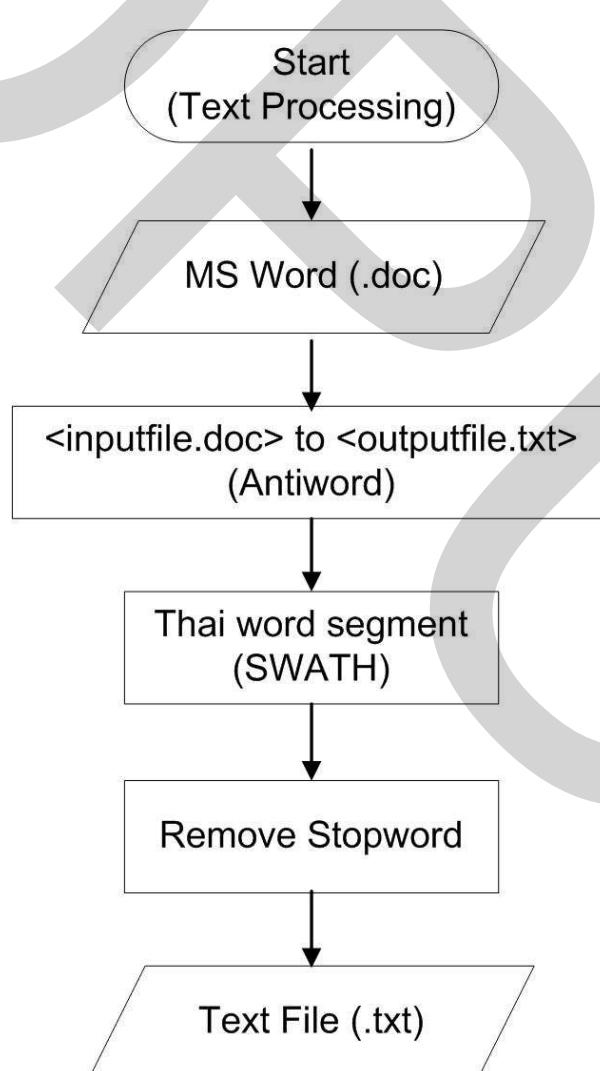
รูปที่ 3.1 แผนผังการทำงานของการนำเอกสารที่ถูกแยกประเภทแล้วเข้าสู่ Symantec DLP

มีข้อจำกัดว่าเอกสารที่นำมาเข้าสู่กระบวนการจะต้องไม่มีการเปลี่ยนแปลง และแก้ไขระดับความสำคัญ เช่นการระบุว่าเป็นเอกสารสำคัญในภายหลัง หลังจากกำหนดเป็นเอกสารทั่วไปแล้ว และไม่ครอบคลุมถึงเอกสารที่มีการเปลี่ยนแปลงในภายหลังจากการแยกประเภทแล้วจะทำการทดสอบการแยกประเภทเอกสาร ตามขั้นตอนในการดำเนินงานวิจัยดังรูปที่ 3.2 จากรายละเอียดกระบวนการของขั้นตอนในการดำเนินงานวิจัย ในตารางที่ 3.1 จะอธิบาย กระบวนการของขั้นตอนการทำงานของระบบการแยกประเภทเอกสาร แสดงผังกระบวนการทำงาน ในรูปที่ 3.2 ขั้นตอนแรก เป็นขั้นตอนนำเข้าเอกสาร ไม่ใชซอฟต์แวร์ ผ่านกระบวนการ Text Processing ซึ่งจะกล่าวต่อไปตามรูปที่ 3.3 ผลลัพธ์ที่ได้จะได้คำภาษาไทยที่ถูกประมวลผลในขั้นตอนการตัดคำภาษาไทย และจำกัดคำหยุด ออกแล้ว คำที่เหลือจากการกระบวนการ Text Processing จะนำเข้าสู่กระบวนการหาค่าน้ำหนักคำ TF-IDF ในขั้นตอนนี้จะนำเข้าไฟล์เอกสาร .txt เข้าสู่โปรแกรม PHP เรียกใช้ฟังก์ชัน TF-IDF เพื่อหาค่าน้ำหนักคำ เมื่อได้ค่าน้ำหนักคำ ซึ่งคือว่าเป็นขั้นตอนในการทำ Feature Extraction ด้วย นั่นก็คือการหาค่าคุณลักษณะนั้นเอง



รูปที่ 3.2 กระบวนการของขั้นตอนในการดำเนินงานวิจัย

มีการคัดเลือกคุณลักษณะ (Feature Selection) ตามความถี่ของคำที่ปรากฏในเอกสาร มาก่อนบันทึกเอกสารแต่ละประเภท และเมื่อได้ค่าคุณลักษณะมาเป็นตัวแทนของเอกสารแล้ว จะนำเข้าสู่กระบวนการแยกประเภทเอกสาร โดยนำเข้าโปรแกรม MATLAB ซึ่งเป็นภาษาที่มีประสิทธิภาพสูงทางด้านเทคนิคในการคำนวณ มีรูปแบบโปรแกรมที่ง่ายต่อการใช้งาน และมีเครื่องมือที่หลากหลาย ในที่นี้จะใช้เครื่องมือชั้นพอร์ตเวกเตอร์แมชชีนแบบค่ากำลังสองน้อยที่สุด (Least Squares Support Vector Machine: LS-SVM) เป็นการพัฒนาต่อจาก SVM เพื่อสนับสนุนการทำงานกับข้อมูลปริมาณมาก มาใช้ในการเรียนรู้เพื่อแบ่งเขตข้อมูลออกเป็นกลุ่มตามที่ได้กำหนดไว้ โดยใช้ฟังก์ชันเกอร์เนลชนิด ฟังก์ชันเรเดียลเบซิส (RBF Kernel Function) มาประยุกต์ใช้สำหรับการพยากรณ์



รูปที่ 3.3 ขั้นตอนการแปลงไฟล์เอกสาร (Text Processing)

และในขั้นตอนการทดสอบจะนำข้อมูลชุดฝึกสอนทดสอบกับข้อมูลชุดทดสอบเพื่อแยกประเภทเอกสารสำคัญ ออกจากเอกสารทั่วไป พร้อมหาอัตราความถูกต้อง (Accuracy Rate) ของการคัดแยกประเภทเอกสารจากชุดข้อมูลฝึกสอน และนำเอกสารสำคัญที่แยกประเภทออกมายield ไป เป็นต้นแบบในการกรองเอกสารสำคัญของระบบ Symantec DLP ต่อไป

3.2 กระบวนการนำเข้าเอกสาร

เอกสารที่จะนำเข้าระบบจะอยู่ในรูปแบบของเอกสาร Microsoft Word (.doc) ต้องทำการแปลงไฟล์เอกสารให้อยู่ในรูปแบบของไฟล์ข้อความชาร์มดา (.txt) ก่อนดังแสดงขั้นตอนกระบวนการแปลงไฟล์เอกสาร (Text Processing) ในรูป 3.3 แสดงการทำงานในการแปลงไฟล์เอกสาร Microsoft words ให้เป็นไฟล์ข้อความ (.txt) เพื่อเป็นอินพุตการหาคำนำหน้าหักคำ TF-IDF การสกัดลักษณะสำคัญ และการคัดเลือกคุณลักษณะสำคัญต่อไป

3.2.1 อ่านไฟล์เอกสาร Microsoft Word ให้เป็นไฟล์ข้อความ Text ขั้นตอนแรกแสดงขั้นตอนการอ่านไฟล์เอกสารไมโครซอฟท์เวิร์ด (.doc) ให้อยู่ในรูปไฟล์ข้อความ (.txt) โดยผ่านโปรแกรมย่อย Antiword ดังแสดงในรูปที่ 3.4



รูปที่ 3.4 แปลงไฟล์เอกสาร Microsoft word .doc เป็นไฟล์ข้อความ .txt

จากการวนการนำเข้าเอกสาร ซึ่งเป็นเอกสาร Microsoft Word (.doc) และทำการแปลงไฟล์จากเอกสาร .doc เป็นไฟล์ข้อความ .txt โดยใช้โปรแกรม Antiword เพื่อเป็นข้อมูลนำเข้า นำไฟล์เอกสารไมโครซอฟท์เวิร์ดเข้าสู่โปรแกรมย่อย Antiword Version 3.7 ใน PHP Program ซึ่งเป็นฟรีโปรแกรมที่ถูกนำมาใช้เพื่อแสดงความหมายของเอกสารไมโครซอฟท์เวิร์ดให้แสดงผลอยู่ในรูปแบบของไฟล์ข้อความ (plain text) โปรแกรม Antiword จะถูกเรียกผ่านทาง command line

ตามรูปแบบ Antiword <source_path>.doc <destination_path>.txt เมื่อ source_path ก็อ ໄدر์ที่เก็บไฟล์ข้อมูล .doc ส่วน destination_path ก็อ ໄدر์ปลายทางที่จะเก็บไฟล์ข้อมูล .txt

3.2.2 การตัดคำ (Word Segmentation) นำไฟล์ข้อความที่ได้นำเข้าสู่กระบวนการตัดคำภาษาไทยเพื่อเพิ่มประสิทธิภาพของการจำแนกหมวดหมู่เอกสารภาษาไทย การตัดคำภาษาไทย ซึ่งมีลักษณะการเขียนติดต่อกันเป็นสายอักขระ โดยไม่มีเครื่องหมายวรรคตอนแสดงการแบ่งคำ ซึ่งเป็นอุปสรรคอย่างหนึ่งที่แบ่งสายอักขระเหล่านี้ออกเป็นคำๆ ในที่นี้จึงเรียกใช้ฟังก์ชั่น SWATH ซึ่งเป็นฟรีโปรแกรมจากเนคเทค ที่จะทำการตัดคำแบบยาวที่สุด (Longest Matching) ที่เข้ามาจากการตัดคำภาษาไทย แล้วทำต่อไปเรื่อยๆ จนจบสายอักขระ ดังแสดงตัวอย่างการตัดคำภาษาไทย ในรูปที่ 3.5

ตามที่ ผงป. ขอความร่วมมือหน่วยงาน ทบทวนรายการลงทุน
ที่จะขอด้วยประจำปีงบประมาณ 2555 - 2558



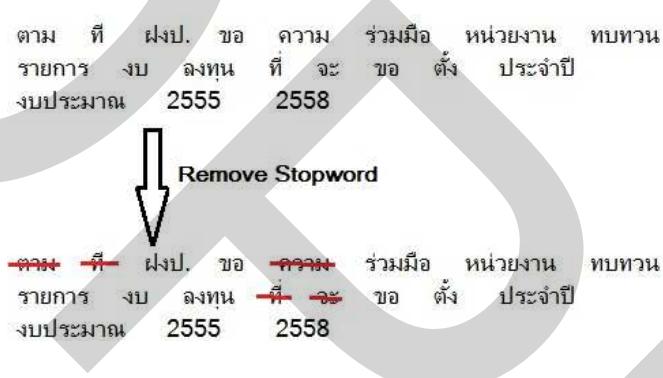
รูปที่ 3.5 การตัดคำภาษาไทย โดยใช้โปรแกรม SWATH

โปรแกรมการตัดคำภาษาไทย SWATH โปรแกรมตัดคำภาษาไทย ถูกพัฒนาโดยศูนย์เทคโนโลยีอิเล็กทรอนิกส์และคอมพิวเตอร์แห่งชาติ หรือ NECTEC ในวิทยานิพนธ์นี้ใช้ SWATH Version 2.0 ลักษณะการทำงานจะทำการเปรียบเทียบคำที่ปรากฏในเอกสาร กับข้อมูลที่มีอยู่ในฐานข้อมูลพจนานุกรม โดยข้อมูลที่นำมาใช้กับโปรแกรมนี้ต้องเป็นไฟล์ข้อความเท่านั้นซึ่งได้มาราบบกับไฟล์จากกระบวนการแปลงไฟล์จาก MS Word เป็นไฟล์ txt โดยจะเลือกตัดคำแบบเดียวกับคำที่ยาวที่สุด (Longest Matching) โดยมีรูปแบบการเรียกใช้โดย swath.exe -b " " -d data < text.txt > out.txt เมื่อ text.txt เป็นไฟล์นำเข้าที่ได้รับจากการอ่านไฟล์ข้อความจากเอกสารในโทรศัพท์เวิร์ด และ out.txt ก็อ ไฟล์เอาท์พุตที่ได้จากการตัดคำภาษาไทย

3.2.3 การกำจัดคำหยุด (Remove Stop Word) เป็นการนำคำที่ไม่มีนัยสำคัญออก โดยไม่ทำให้ความหมายของเอกสารเปลี่ยนแปลง คำที่ไม่มีนัยสำคัญในที่นี้หมายถึงคำที่ใช้กันโดยทั่วไป เมื่อตัดออกจากเอกสารแล้วไม่ทำให้ความของเอกสารเปลี่ยนแปลงตัวอย่างเช่น คำบุพบพทเป็นคำที่ใช้เชื่อมคำ หรือกลุ่มคำให้สัมพันธ์กัน คำสันธานที่ทำหน้าที่เชื่อมคำกับคำบรรยายที่ใช้แทนคำนาม

ที่กล่าวถึงมาแล้วในประวัติการค้นหานี้ เป็นต้น ดังนั้นการจำกัดคำหยุดจึงเป็นกระบวนการที่ควรทำก่อนการหาค่าน้ำหนัก เพื่อจำกัดคุณลักษณะที่ไม่เป็นประวัติของ ตัวอย่างคำหยุด เช่น ที่ ใน ว่า และ จะ มี ได้ ตาม ให้ ความ เป็นต้น ตัวอย่างการจำกัดคำหยุด ดังแสดงในรูปที่ 3.6

การจำกัดคำหยุด (Remove Stop word) หรือคำฟู่มีเพียงที่ไม่สื่อความหมายโดยทำการระบุคำหยุดเหล่านี้ไว้ในอาร์เรย์ ในส่วนของโปรแกรม PHP ในขั้นตอนนี้จะตัดคำที่ไม่มีความหมายออก และคงคำที่สื่อความหมายไว้เพื่อเพิ่มประสิทธิภาพในการหาค่าน้ำหนักคำต่อไปนี้คำที่เหลือทั้งหมดคามาหาค่าน้ำหนักคำ เมื่อได้ผลลัพธ์ของมาอยู่ในรูปแบบของเมตริกซ์เวกเตอร์ เป็นข้อมูลนำเข้าระบบการแยกประเภทเอกสาร LS-SVM ต่อไป



รูปที่ 3.6 การจำกัดคำหยุด

3.3 กระบวนการหาค่าน้ำหนักคำ และเลือกคุณลักษณะ

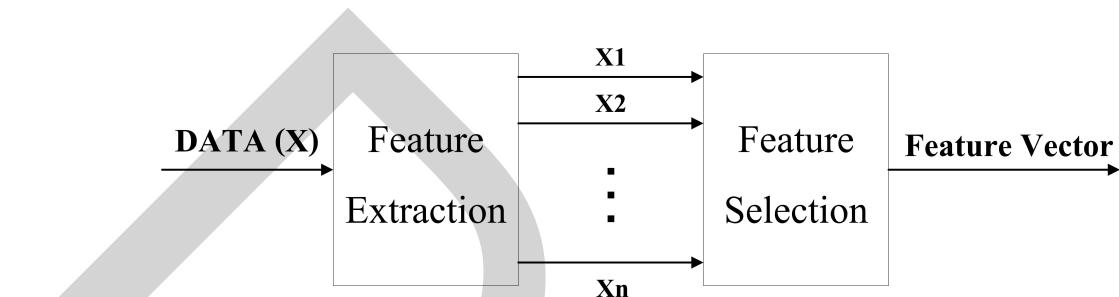
นำความถี่ของคำที่เหลือจากการจำกัดคำหยุด เข้าสู่กระบวนการหาค่าน้ำหนักคำ ในเอกสารนำเข้า TFIDF สมการ (3-1) ดังแสดงกระบวนการในรูปที่ 3.7 นำค่าน้ำหนักที่อยู่ในรูปของเมตริกซ์เวกเตอร์ เป็นอินพุตเข้ากระบวนการคัดแยกประเภทเอกสารต่อไป



รูปที่ 3.7 การหาค่าน้ำหนักคำของแต่ละเอกสาร

วัตถุประสงค์ของขั้นตอนการสกัดคุณลักษณะเอกสารคือการดึงคุณลักษณะ (Feature) ของเอกสารออกมานำเสนอ การลดขนาดเอกสารลง การดึงคุณลักษณะในงานวิจัยนี้จะใช้คำเดี่ยวเป็น

ตัวแทนคุณลักษณะของเอกสาร และให้คำน้ำหนักตัวแทนค่าคุณลักษณะ (Feature vector) ของเอกสารนั้นๆ ดังแสดงกระบวนการคัดเลือก และสกัดคุณลักษณะในรูปที่ 3.8



รูปที่ 3.8 การเลือกคุณลักษณะ และสกัดค่าคุณลักษณะ

การคัดเลือกคุณลักษณะ ก็คือการนำคำที่ไม่มีนัยสำคัญออก จำนวนคุณลักษณะมีผลต่อประสิทธิภาพของการจำแนกหมวดหมู่เอกสาร เนื่องจากอัลกอริทึมที่ใช้ในการเรียนรู้เพื่อสร้างตัวจำแนกหมวดหมู่ โดยทั่วไปไม่สามารถรองรับการทำงานกับจำนวนคุณลักษณะของเอกสารที่สูงมากได้ดี

3.3.1 การคัดเลือกคุณลักษณะ เป็นขั้นตอนแรกที่จะต้องทำก่อนในขั้นตอนการแยกประเภทงานวิจัยนี้ จึงเลือกคำที่มีความถี่ของคำที่ปรากฏในเอกสารมากนับ แล้วมาเป็นตัวแทนของเอกสารทั้งในส่วนของเอกสารสำคัญ และเอกสารทั่วไป ดังแสดงตัวอย่างของคุณลักษณะ (Feature) ดังต่อไปนี้

3.3.1.1 เอกสารสำคัญ แต่ละเอกสารจะปรากฏคำสำคัญที่ชี้ให้เป็นเอกสารสำคัญ ดังต่อไปนี้ [หน่วยงาน ข้อความ บันทึก กอง ผอ ดำเนินการ พิจารณา ฝปค เทคโนโลยี แจ้ง งบประมาณ เบิกเอกสาร ฝบบ เห็นชอบ โปรแกรม สาขา SAP สารสนเทศ ศพส]

3.3.1.2 เอกสารทั่วไป แต่ละเอกสารปรากฏคำสำคัญที่ชี้ว่าเป็นเอกสารทั่วไป ดังต่อไปนี้ [ทำงาน ปัญหา วิธี มือ ไทย เมือง ข่าว ระดับ พื้นที่ ป่วย ทีม อนาคต หมวด ลงทุน เทคนิค ประวัติ พาณิชย์ หน้าจอ สั่งเสริม เงื่อนไข]

ตารางที่ 3.2 แสดงตัวอย่างค่าเวกเตอร์ลักษณะสำคัญ (Feature Vector)

เอกสาร	คุณลักษณะที่ตัดเลือกจากเอกสารสำคัญ						คุณลักษณะที่ตัดเลือกจากเอกสารทั่วไป					
	งบประมาณ	หน่วยงาน	ดำเนินการ	...	SAP	เบิก	ส่งเสริม	เงื่อนไข	ลงทุน	...	ระดับ	ปัญหา
Doc 1	0.307	0.271	0.271	...	0.000	0.000	0.000	0.000	0.236	...	0.000	0.000
Doc 2	0.000	0.236	0.236	...	0.000	0.000	0.000	0.000	0.000	...	0.000	0.000
Doc 3	0.000	0.379	0.236	...	0.236	0.000	0.000	0.000	0.000	...	0.000	0.000
Doc 4	0.000	0.236	0.214	...	0.000	0.000	0.000	0.000	0.000	...	0.000	0.000
Doc 5	0.236	0.271	0.236	...	0.286	0.000	0.000	0.000	0.000	...	0.000	0.307
Doc 61	0.000	0.000	0.000	...	0.000	0.000	0.000	-0.162	0.000	...	-0.162	0.000
Doc 62	0.000	0.000	0.000	...	0.000	0.000	-0.162	0.000	0.000	...	-0.162	0.000
Doc 63	0.000	0.000	0.000	...	0.000	0.000	-0.162	0.000	-0.162	...	0.000	0.000
Doc 64	0.000	0.000	0.000	...	0.000	0.000	0.000	0.000	0.000	...	0.000	0.038
Doc 65	0.000	0.000	0.000	...	0.000	0.000	0.000	0.000	0.000	...	0.000	-0.085

นำคำทั้งหมดมาจัดเรียงตามลำดับจากความถี่ที่ปรากฏจากน้อยไปมาก ทำการเลือกคำสำคัญที่มีความถี่มากที่สุดมานเป็นคุณลักษณะสำคัญ (Feature) จากนั้นจะสร้างเมตริกซ์ของคุณลักษณะที่มีความถี่มากที่สุดนี้จากเวกเตอร์เอกสารทั้งกลุ่ม ถือว่าเป็นการสร้าง เวกเตอร์ตัวแทนของเอกสาร ด้วยค่าน้ำหนักคำตามคุณลักษณะที่ได้ทำการคัดเลือกไว้ ดังแสดงตัวอย่างเวกเตอร์คุณลักษณะ ดังตารางที่ 3.2 งานวิจัยนี้ใช้วิธี TF-IDF ซึ่งคำนวณจากค่าความถี่ของคำที่ปรากฏในเอกสารหนึ่งๆ เพียงกับคำที่ปรากฏในเอกสารทุกฉบับในชุดเอกสาร คำที่ปรากฏในเอกสารมาก มีความถี่มาก ก็จะส่งผลให้ได้ค่าน้ำหนักมีค่าสูงมากตาม เมื่อถึงขั้นตอนนี้จะได้รูปแบบที่มีลักษณะของการแสดงความสัมพันธ์ระหว่างคำ (Words :Feature) และเอกสารทั้งหมด (Document: DOC) ทำการเลือกคุณลักษณะที่เลือกมาจากชุดเอกสารสำคัญ {หน่วยงาน ข้อความ บันทึก กอง ผอ ดำเนินการ พิจารณา ...} และคุณลักษณะที่ถูกเลือกจากชุดเอกสารทั่วไป {ทำงาน ปัญหา วิธี มือ ไทย เมือง ข้าว ...} มาเป็นตัวแทนของเอกสารแต่ละฉบับ ซึ่งจะให้ค่าน้ำหนักคำของแต่ละคำ ในแต่ละเอกสาร เพื่อเป็นตัวแทนของเอกสาร

ค่าน้ำหนักคำเป็นค่าคุณลักษณะนำมาเป็นตัวแทนของเอกสาร การลดขนาดของค่าคุณลักษณะ (Dimension Reduction) เพื่อเตรียมข้อมูล สำหรับเป็นตัวแทนเอกสารในการคัดแยกประเภทเอกสารสาเหตุที่ต้องลดขนาดของค่าคุณลักษณะเนื่องจากเมื่อข้อมูลมีค่าคุณลักษณะสูง และไม่ได้ไปในทิศทางเดียวกันทำให้ข้อมูลเกิดการกระจาย จะทำให้บางชุดอาจจะไม่มีข้อมูลอยู่เลย ดังนั้นการที่มีข้อมูล และขนาดของข้อมูลจำนวนมาก นอกจากจะทำให้ใช้เวลาในการคำนวณมาก

แล้ว ยังทำให้เกิดปัญหาในเรื่องของการตีความกลุ่มข้อมูล ซึ่งถ้ามีตัวแปรของข้อมูลต่างๆ และค่าของข้อมูลที่ไม่ห่างกันมาก ก็จะทำให้ข้อมูลมีลักษณะของการเกากลุ่มกัน ในทางตรงกันข้ามถ้าข้อมูลมีค่าสูง และแตกต่างกันมาก ก็อาจจะทำให้ถูกตีความว่าเป็นคนละกลุ่มกัน ได้ งานวิจัยนี้จึงได้ทำการลดค่าคุณลักษณะของข้อมูลเพื่อลดตัวแปรนำเข้า

การลดค่าคุณลักษณะของข้อมูลนำเข้า เพื่อให้การสร้างโมเดลทำได้ง่าย และช่วยให้เพิ่มความแม่นยำของการวิเคราะห์ข้อมูล โดยมีจุดมุ่งหมายในการลดค่าคุณลักษณะเพื่อเจาะจงกลุ่มของคุณลักษณะ และทำให้ได้ผลลัพธ์ของการพยากรณ์สามารถนำไปใช้ประโยชน์ได้เต็มที่ ก่อนจะนำค่าคุณลักษณะไปเป็นตัวแทนของเอกสาร และนำเข้าสู่กระบวนการฝึกสอนการคัดแยกประเภทเอกสาร ใน LS-SVM

3.3.2 การเลือกคุณลักษณะสำคัญ การเลือกคำที่มีความสำคัญน้อยออก เพื่อคุณลักษณะที่ไม่จำเป็น ในการทำงานหลังจากที่ได้ตัดคำบางตัวออกซึ่งส่วนใหญ่จะให้ค่าความถูกต้องสูงขึ้น จำนวนคุณลักษณะมีผลต่อประสิทธิภาพของการจำแนกหมวดหมู่เอกสาร ตัวแทนคุณลักษณะของเอกสาร และใช้ค่าได้แทนคุณลักษณะเอกสารนั้น จากการสำรวจงานวิจัยที่ผ่านมาทั้งในประเทศ และต่างประเทศพบว่า ส่วนใหญ่จะใช้คำเป็นตัวแทนคุณลักษณะของเอกสาร และใช้พื้นฐานค่าความถี่ หรือค่าน้ำหนักคำ เป็นค่าของคุณลักษณะ ตัวแทนคุณลักษณะของเอกสารจะเก็บอยู่ในรูปแบบเวกเตอร์ งานวิจัยนี้ใช้การเลือกคุณลักษณะแบบคำเดียว (Single word) ซึ่งได้จากขั้นตอนการตัดคำ โดยใช้พจนานุกรมเรียนรู้อยแล้ว ผลลัพธ์ที่ได้จากการตัดคำจะได้เป็นคำเดียวจำนวนมาก เพื่อคัดเลือกมาใช้เป็นตัวแทนเอกสารในการเรียนรู้ โดยใช้วิธีเลือกคำที่มีความถี่มากที่สุด หรือคำที่ปรากฏในเอกสารมากฉบับ ดังแสดงตามสมการ 3-1, 3-2 และตารางที่ 3.3 แสดงตัวอย่างของตัวแปรที่ใช้ในสมการ เมื่อค่าคุณลักษณะถูกแทนด้วยค่าน้ำหนักคำ w_{ij}

ตารางที่ 3.3 ค่าน้ำหนักคำของเอกสาร D_i และคำ W_j

<i>Document / Word</i>	W_1	W_2	W_3	...	W_n
D_1	w_{11}	w_{12}	w_{13}	...	w_{1n}
D_2	w_{21}	w_{22}	w_{23}	...	w_{2n}
D_3	w_{31}	w_{32}	w_{33}	...	w_{3n}
...
D_m	w_{m1}	w_{m2}	w_{m3}	...	w_{mn}

จากตาราง 3.3 แสดงจำนวนเอกสาร D_1, D_2, \dots, D_m ที่ปรากฏคำ W_1, W_2, \dots, W_n และค่าน้ำหนักคำ w_{mn} ซึ่งแสดงค่าน้ำหนักคำของเอกสาร D_m และคำ W_n และแสดงวิธีการหาความถี่ C_j ของการปรากฏคำ W_n ในเอกสาร D_1, D_2, \dots, D_m ดังสมการ (3-1) โดยถ้าหากคำ W_n มีค่ามากกว่า 0 จะถูกนับเป็น 1 ($x_{ji} = 1$) แต่ถ้าหากคำ W_n ไม่มีค่าเท่ากับ 0 ($x_{ji} = 0$) จะไม่ถูกนับ ดังสมการ (3-2)

$$C_j = \sum_{i=1}^m x_{ij} \quad (3-1)$$

$$x_{ij} = \begin{cases} 1 & \text{if } w_{mn} > 0 \\ 0 & \text{if } w_{mn} = 0 \end{cases} \quad (3-2)$$

กำหนดให้ w_{ij} เป็นค่าน้ำหนักคำที่ j เอกสารที่ i

โดยที่ $j = 1, 2, \dots, n$

$i = 1, 2, \dots, m$

จากสมการ 3-1 แสดงวิธีการคัดเลือกคุณลักษณะ เมื่อ C_j คือคุณลักษณะที่คำนวณจากความถี่ของคำ x_{ij} จากเอกสาร D_m ที่ $i = 1, \dots, m$ และคำ W_n ที่ $j = 1, \dots, n$ เมื่อ x_{ij} จะถูกนับเป็น 1 เมื่อค่าน้ำหนักคำ w_{mn} มีค่ามากกว่า 0 ตามสมการที่ 3-2 คัดเลือกคุณลักษณะโดยเรียงความถี่คุณลักษณะที่ปรากฏ C_j เลือกคุณลักษณะที่มีความถี่ที่ปรากฏคำในเอกสารมากฉบับ ที่เรียงจากมากไปยังน้อย ตามจำนวนคุณลักษณะที่ต้องการใช้ เมื่อคุณลักษณะถูกแทนด้วยค่าน้ำหนักคำ w_{mn} ของคำที่ n และเอกสารที่ m

Assume sorted data $M(C_1), \dots, M(C_n)$

Binsearch (x)

put left, right fingers on 0 and C_j

while x not equal $M(\text{left finger})$

set midpoint halfway between fingers

if $M(\text{midpoint}) < x$

then move left finger to midpoint

else move right finger to midpoint

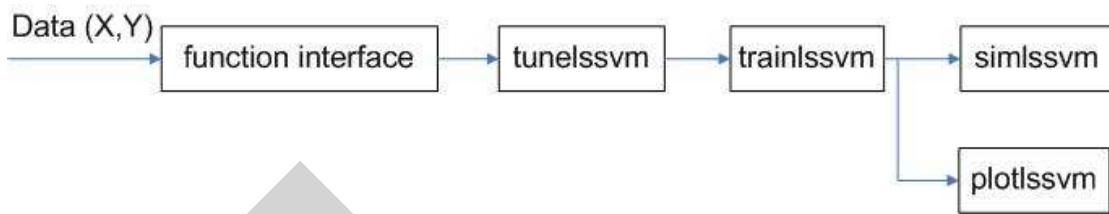
end while

แสดงขั้นตอนจำลองการคัดเลือกคุณลักษณะ โดยการเรียงลำดับตามความถี่ของคำที่ปรากฏในเอกสารมากบันจากมากไปหาน้อย โดยทำการเรียงลำดับข้อมูล C_1 ถึง C_j ตามรหัสเทียม (Pseudo Code) ที่แสดงถึงขั้นตอนการเรียงลำดับด้วยภาษาที่เข้าใจง่าย เรียงลำดับแบบไบนารี เสิร์ช นำข้อมูลมาแบ่งเป็น 2 ส่วน แล้วนำข้อมูลเปรียบเทียบกับข้อมูลตำแหน่งกลาง M(midpoint) โดยให้ค่า $M(C_j)$ เป็นต้นเป็นค่า x ถ้ามีค่ามากกว่าให้นำมาเรียงในส่วนหน้า แต่ถ้ามากกว่าให้จัดเรียงไว้ในส่วนหลัง ซึ่งเป็นวิธีการเรียงลำดับที่มีประสิทธิภาพสูง เพราะไม่จำเป็นต้องคิดตั้งแต่ตัวแรกทำให้สามารถลดระยะเวลาในการจัดลำดับ ได้เป็นอย่างดี

3.4 กระบวนการแยกประเภทเอกสาร

วิธีการที่ใช้ในการแยกประเภทเอกสารในวิทยานิพนธ์เล่มนี้คือ LS-SVM เนื่องจากมีความแม่นยำในการแยกประเภท กับข้อมูลปริมาณมาก เมื่อได้ค่าน้ำหนัก TF-IDF ของค่าในเอกสารทั้งหมดแล้วแต่ละฉบับ นำค่าที่ได้นี้เป็นอินพุตเข้ากระบวนการแยกประเภท โดยใช้วิธี LS-SVM วิธีนี้จะต้องให้โปรแกรมทำการเรียนรู้ข้อมูลก่อนที่จะทำการเปรียบเทียบเพื่อแบ่งประเภท ซึ่งผู้วิจัยได้ทำการคัดเลือกคุณลักษณะสำคัญ (Feature Selector) และนำค่าน้ำหนักคำ (Feature Extraction) เพื่อใช้แทนคุณลักษณะของเอกสาร โดยกำหนดประเภทของเอกสารไว้ ให้ประเภทที่ 1 คือประเภทเอกสารสำคัญ (Secret) ประเภทที่ 2 คือประเภทเอกสารทั่วไป (No Secret) แทนด้วยค่า 1 และ -1 ตามลำดับ จากนั้นนำไปลึกน้ำหนักคำตามคุณลักษณะที่ได้คัดเลือกไว้แล้วเป็นข้อมูลนำเข้า ตามทฤษฎีของ LS-SVM

จากทฤษฎี SVM แนวคิดหลักของวิธีการนี้ ใช้เพื่อหาระนาบการตัดสินใจในการแบ่งข้อมูลออกเป็นสองส่วน โดยใช้สมการเส้นตรงเพื่อแบ่งเขตข้อมูล 2 กลุ่มออกจากกัน โดยจะพยายามสร้างเส้นแบ่งตรงกึ่งกลางระหว่างกลุ่มให้มีระยะห่างระหว่างขอบเขตของทั้งสองกลุ่มมากที่สุด SVM จะใช้ฟังก์ชันแม่ปั๊มารับข้อมูลจาก Input Space ไปยัง Feature Space โดยมีคำอวที่เป็นไปได้คือ $y = \{+1, -1\}$ โดยค่า y นี้จะเป็นผลลัพธ์ที่ต้องการให้ SVM เรียนรู้ เพื่อใช้สำหรับแยกกลุ่มข้อมูลทั้งสองกลุ่มออกจากกัน เมื่อทำการกำหนดกลุ่มของข้อมูลที่ต้องการจะแบ่งเรียบร้อยแล้ว จะมีการสร้างเส้นแบ่งข้อมูลที่เหมาะสม (Optimal Separate Hyperplane) เพื่อแยกประเภท การสร้างเส้นแบ่งเขตนั้นเพื่อทำการตรวจสอบการแบ่งข้อมูล แสดงขั้นตอนการทำงาน ระบุรายการของฟังก์ชันที่ถูกใช้ใน LS-SVM Model ที่นำมาใช้เป็นเครื่องมือ (tool) ในโปรแกรม MATLAB คั่งรูปที่ 3.9

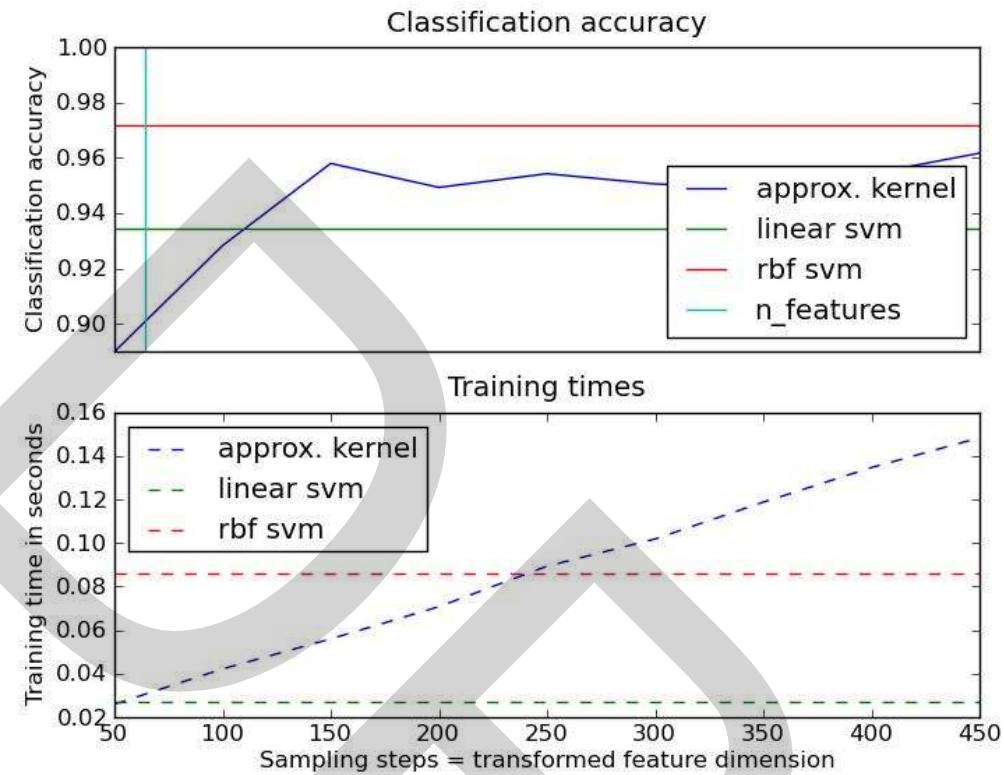


รูปที่ 3.9 ขั้นตอนการทำงานของ LS-SVM Model

อัลกอริทึมการจัดหมวดหมู่ (Classifier Algorithm) อัลกอริทึมในการจัดหมวดหมู่การเรียนรู้แบบมีผลเดลย์ (Supervised Learning) สามารถแบ่งขั้นตอนวิธีการจัดหมวดหมู่เอกสารแบ่งออกเป็น 2 ขั้นตอนคือ การเรียนรู้เพื่อสร้างกลุ่มเอกสารต้นแบบ และแยกหมวดหมู่ของเอกสารที่สนใจ โดยตรวจสอบหากความคล้ายกับกลุ่มเอกสารต้นแบบ โดยข้อมูลนำเข้าอัลกอริทึมเครื่องจักรการเรียนรู้ คือคุณลักษณะของคำเดียวที่อยู่ในรูปแบบเวกเตอร์ ที่ผ่านการลดคุณลักษณะของคำนำหน้ามาเรียบร้อยแล้ว

ชัฟฟอร์ทเวกเตอร์แมชชีน (Support Vector Machine) วิธีการนี้ใช้หาระนาบการตัดสินใจในการแบ่งข้อมูลออกเป็นสองส่วน โดยใช้สมการเส้นตรงเพื่อแบ่งเขตข้อมูลสองกลุ่มออกกัน กัน โดยจะพยายามสร้างเส้นแบ่งตรงกึ่งกลางระหว่างกลุ่มให้มีระยะห่างระหว่างขอบเขตของทั้งสองกลุ่มมากที่สุด SVM จะใช้ฟังก์ชันแมปสำหรับนำข้อมูลจาก Input Space ไปยัง Feature Space อย่างไรก็ตาม SVM มี เคอร์เนลฟังก์ชัน (Kernel Function) ที่สามารถประยุกต์ใช้ในการแก้ปัญหาได้หลายวิธี Kernel Function ที่พบได้บ่อย 3 แบบด้วยกัน เช่น Radial Basis Function (RBF), Polynomial และ Sigmoid สำหรับงานวิจัยนี้ได้เลือกใช้ RBF Kernel (Radial Basis Function) เป็นฟังก์ชันที่ใช้ในการทดสอบ เนื่องจากมีผู้จัดทำท่านได้ทำการทดสอบประสิทธิภาพการใช้งาน Kernel Function พบว่า RBF เป็น Kernel Function ที่ให้ผลการทดสอบมีประสิทธิภาพมากที่สุด ดูได้จากราฟเบรย์นเทียบประสิทธิภาพการทำงานของ Kernel ดังรูปที่ 3.10

โดยทั่วไปแล้วการแยกประเภทเอกสาร จะมีการเลือกใช้เคอร์เนลอยู่ 2 อย่างคือ Linear Kernel และ RBF Kernel จากรูปที่ 3.10 เป็นการเบรย์นเทียบประสิทธิภาพการทำงานของ Kernel Function ในส่วนของความถูกต้องในการคัดแยกประเภท (Classify Accuracy) และเวลาที่ใช้ในการกระบวนการฝึกสอน (Training Time) ระหว่าง Linear Kernel และ RBF Kernel จากกราฟแสดงเวลา และค่าความถูกต้องสำหรับการแยกประเภทกับ Kernel การประมาณการ โดยทำการแยกประเภทกับชุดข้อมูลตัวอย่าง พบว่า เครื่องแบบสีสังข์ (RBF Kernel) ให้ค่าความถูกต้อง (Classify Accuracy) มากกว่า และใช้เวลาในการประมาณผลน้อยกว่าเคอร์เนลเชิงเส้น (Linear Kernel)



รูปที่ 3.10 กราฟเปรียบเทียบประสิทธิภาพของ Kernel Function

ที่มา: Explicit feature map approximation for RBF kernels <http://scikit-learn.sourceforge.net>

3.5 อัตราความถูกต้อง (Accuracy Rate)

วิธีการทดสอบเพื่อเปรียบเทียบประสิทธิภาพ คือความสามารถในการเข้าใกล้ค่าจริง (True Value) ของการวัดผล โดยหาได้จาก สมการ 3-3

$$\frac{\text{Total Document read} - \text{Total Error}}{\text{Total Document read}} \times 100 = \text{Accuracy Rate (\%)} \quad (3-4)$$

D&G

บทที่ 4

ผลการศึกษา

ในส่วนนี้จะกล่าวถึงการทดสอบ ผลการทดสอบการแยกประเภทเอกสาร และรวมถึง การวิเคราะห์ความแม่นยำของข้อมูลชุดฝึกสอน โดยข้อมูลที่ใช้ในการทดสอบจะประกอบไปด้วย ข้อมูลชุดฝึกสอน และข้อมูลชุดทดสอบ โดยแต่ละชุดข้อมูลจะประกอบด้วยข้อมูลที่ถูกกำหนดประเภทไว้ล่วงหน้าทั้งข้อมูลที่เป็นเอกสารสำคัญ (Secret) และข้อมูลที่เป็นเอกสารทั่วไป (No Secret) ข้อมูลนำเข้าจะเป็นไฟล์เอกสาร Microsoft word (.doc) เท่านั้น เป็นเอกสารที่ถือว่าลับสุด ไม่มีการเปลี่ยนแปลงเนื้อหาในเอกสาร และระดับความสำคัญ จะแสดงวิธีการทดสอบตาม กระบวนการที่ได้ออกแบบไว้ในแต่ละขั้นตอน และผลการทดสอบการแยกประเภทเอกสาร ทั้ง การนำไฟล์เอกสาร Microsoft word (.doc) เข้าไปข้างส่วนของโปรแกรม PHP ที่ประกอบไปด้วย โปรแกรมย่ออย่าง Antiword สำหรับดูไฟล์เอกสาร Microsoft word ในรูปแบบของไฟล์ข้อความ ธรรมชาติ Text mode ทำการแปลงไฟล์ (.doc) ให้อยู่ในรูปแบบไฟล์ข้อความ (.txt) นำไฟล์ข้อความ เข้าสู่ขั้นตอนการตัดคำในเอกสารภาษาไทย โดยใช้โปรแกรม SWATH การทำงานของโปรแกรมจะ ทำการเปรียบเทียบคำในเอกสารกับข้อมูลที่มีอยู่ในพจนานุกรมในลักษณะเรียงจากซ้ายไปขวา จะ ทำการเลือกคำที่ยาวที่สุดที่ตรงกัน และตัดคำนั้นออกมา คำที่ได้ทิ้งหมดจะนำเข้าสู่กระบวนการตัด คำหยุด หรือคำที่ไม่สื่อความหมายออก โดยมีการระบุคำเหล่านั้นไว้ในอาร์เรย์ส่วนของการตัดคำใน โปรแกรม PHP นำคำที่เหลือจากการตัดคำหยุดมาหาค่าน้ำหนัก TF-IDF (Term Frequency and Inverse Document Frequency) เป็นกระบวนการคำนวณค่าน้ำหนักจากความถี่ของคำที่ปรากฏใน เอกสารนั้นๆ เพิ่บกับเอกสารอื่นที่เป็นชุดข้อมูลเดียวกัน ทำการคัดเลือกคุณลักษณะสำคัญ (Feature Selector) และนำค่าน้ำหนักคำ (Feature Vector) เพื่อใช้แทนคุณลักษณะของเอกสารด้วย ทำการลดขนาดค่าคุณลักษณะเพื่อเพิ่มประสิทธิภาพในการคัดแยกประเภทเอกสาร ค่าคุณลักษณะ จะมีรูปแบบเป็นไฟล์ข้อมูลเมตริกซ์เพื่อทำการแยกประเภทเอกสาร โดยใช้ LS-SVM (Least Squares Support Vector Machine) เป็นกระบวนการแยกประเภทแบบมีผู้สอน (Supervised Learning) ผ่านทางโปรแกรม MATLAB ภาษาคอมพิวเตอร์ที่มีประสิทธิภาพสูงทางด้านเทคนิค ในการคำนวณ มีรูปแบบโปรแกรมที่ง่ายต่อการใช้งาน ผลลัพธ์ที่ได้จะสามารถแยกประเภทของ เอกสารออกเป็นสองส่วนตามที่ได้กำหนดไว้ข้างต้น คือ เอกสารสำคัญ Secret (1) และเอกสาร

ทั่วไป No Secret(-1) ทำการทดสอบอัตราความถูกต้อง (Accuracy Rate) ของการกรองเอกสาร โดยนำเอกสารชุดทดสอบมาแยกประเภทผ่านข้อมูลชุดฝึกสอน

4.1 กระบวนการทดสอบ

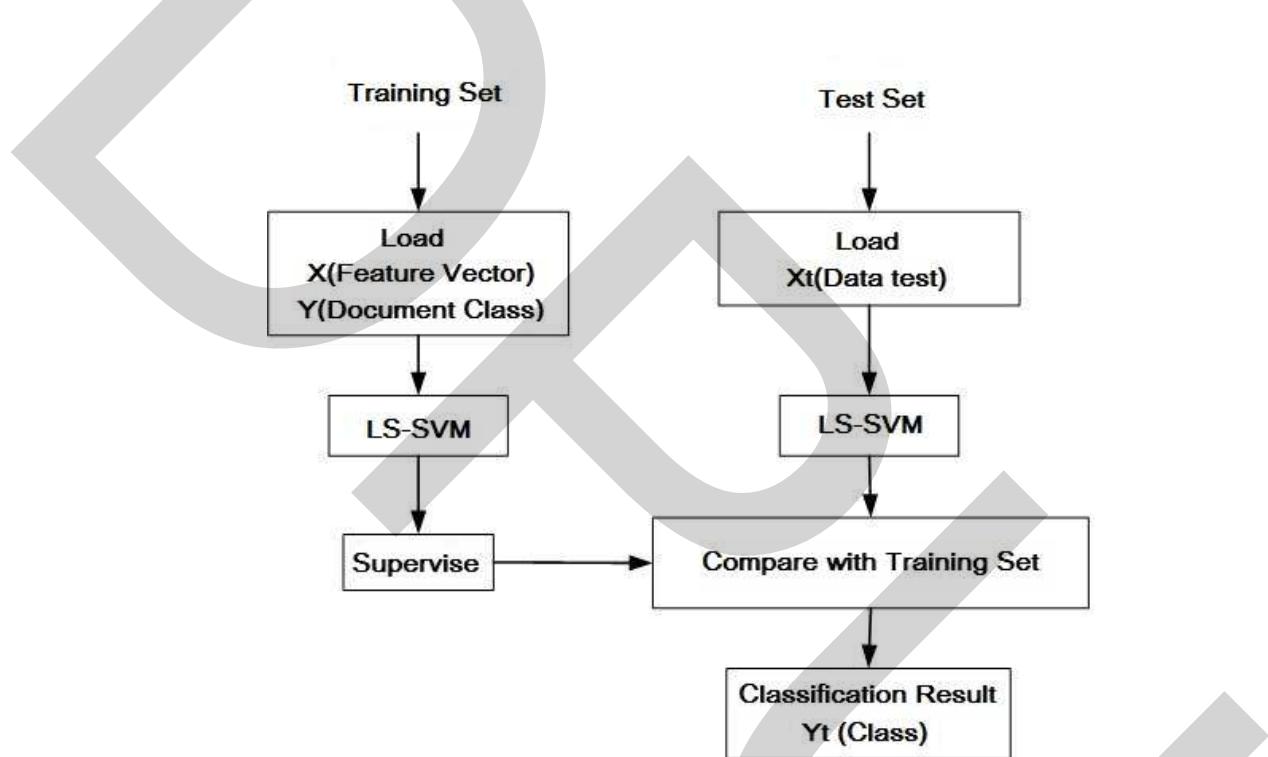
วิธีการแยกประเภทคือ การนำข้อมูลทั้งหมดมาทำการฝึกสอนโดยแยกประเภทให้ข้อมูลชุดฝึกสอนก่อนว่าจัดอยู่ในประเภทเป็นเอกสารความสำคัญ Secret (1) หรือเอกสารทั่วไป No Secret (-1) ทำการทดสอบโดยการนำข้อมูลส่วนหนึ่งของข้อมูลชุดฝึกสอนมาทำการทดสอบตามประเภทที่ได้กำหนดไว้ เริ่มจากนำข้อมูลเอกสารทั้งหมด 145 ฉบับซึ่งถือว่าเป็นข้อมูลชุดฝึกสอนโดยในข้อมูลชุดฝึกสอน จะประกอบด้วยข้อมูลที่เป็นเอกสารสำคัญ และเอกสารทั่วไปประกอบอยู่ซึ่งแบ่งเป็นประเภทเอกสารดังแสดงในตารางที่ 4.1

ตารางที่ 4.1 รายละเอียดของเอกสารที่ใช้ในการฝึกสอนและทดสอบการแยกประเภทเอกสาร

ชุดข้อมูลสำหรับ (Data Set)	ชุดข้อมูลตั้งต้น
ข้อมูลชุดฝึกสอน (Training Set)	145 ข้อมูล
ข้อมูลชุดทดสอบ (Test Set)	60 ข้อมูล/เอกสารสำคัญ 85 ข้อมูล/เอกสารทั่วไป

นำเอกสาร Microsoft Word (.doc) เข้าสู่กระบวนการแปลงให้อยู่ในรูปแบบไฟล์ข้อความธรรมดា (.txt) โดยผ่านโปรแกรม PHP ด้วยโปรแกรมย่อขยาย Antiword นำไฟล์ข้อความที่ได้เข้าสู่กระบวนการตัดคำภาษาไทยโดยการเปรียบเทียบกับพจนานุกรมที่มีโดยใช้โปรแกรมย่อขยาย SWATH นำคำที่ได้มาเปรียบเทียบกับชุดคำหัก (Stop word) ที่ได้กำหนดไว้ นำคำที่เหลือจากการตัดคำหักมาหาค่า�้ำหนักคำโดยใช้ความถี่ของคำในเอกสาร มีแนวคิดที่ว่าคำที่ปรากฏในเอกสารน้อยฉบับจะมีค่าน้ำหนักสูงกว่าคำที่ปรากฏในเอกสารหลายฉบับ จะมีค่าน้ำหนักต่ำเนื่องจากเป็นคำที่ไม่แสดงถึงลักษณะเฉพาะของเอกสารนั้นโดยใช้สมการ TF-IDF เมื่อได้ค่าน้ำหนักคำในเอกสาร ตัวอย่างค่าน้ำหนักดังตารางที่ 3.2 จะแสดงลำดับเอกสาร โดยแต่ละฉบับจะแสดงค่าน้ำหนักของแต่ละคำที่กันพบในแต่ละเอกสาร คำนวณจากความถี่ของคำที่ปรากฏในเอกสารนั้นๆเทียบกับเอกสารทั้งหมดในชุดข้อมูล และทำการคัดเลือกคุณลักษณะสำคัญ จากความถี่ของคำที่ปรากฏมากครั้งในชุดข้อมูลนั้นๆ ทั้งในส่วนของเอกสารสำคัญ และเอกสารทั่วไป และนำค่าน้ำหนักมาเป็นค่าคุณลักษณะ แต่ก่อนจะนำเข้าไปเข้ากระบวนการฝึกสอนเพื่อคัดแยก

ประเกทเอกสารนี้ จำเป็นต้องทำการลดค่าคุณลักษณะ มีจุดมุ่งหมายเพื่อเจาะจงกลุ่มของคุณลักษณะ และทำให้ได้ผลลัพธ์ที่มีความแม่นยำ และนำค่าคุณลักษณะนี้ไปเป็นเมตริกซ์อินพุตเข้าสู่กระบวนการแยกประเกทเอกสารด้วย LS-SVM ผ่านโปรแกรม MATLAB เมื่อทำการฝึกสอนแล้ว จะทำการนำข้อมูลชุดทดสอบเข้าสู่กระบวนการแยกประเกทอีกครั้ง และดูผลการทดสอบว่าผลการแยกประเกทจะตรงกับประเกทเอกสารที่ระบบได้เรียนรู้ไว้หรือไม่ ขั้นตอนที่กล่าวมาแสดงขั้นตอนได้ดังรูปที่ 4.1



รูปที่ 4.1 ขั้นตอนการฝึกสอนและทดสอบการแยกประเกทเอกสาร โดยใช้ LS-SVM

โดยที่ $X = N \times d$ เมตริกซ์ค่าลักษณะสำคัญ (Feature Vector) สำหรับข้อมูลฝึกสอน

$Y = N \times 1$ เป็นเมตริกซ์ของประเกทสำหรับข้อมูลฝึกสอน

$Xt = M \times d$ เป็นเมตริกซ์ของค่านำเข้าสำหรับข้อมูลชุดทดสอบ

$Yt = M \times 1$ เป็นเมตริกซ์ของผลลัพธ์ที่ได้จากการทดสอบ

เมื่อ N = เอกสารนำเข้า

d = คุณลักษณะสำคัญ

M = เอกสารนำเข้าของข้อมูลชุดทดสอบ

$Y = \{+1, -1\}$, $Yt = \{+1, -1\}$

2.2.1 ขั้นตอนการทดสอบ การคัดเลือกคุณลักษณะสำคัญ (Feature Selection) โดยคัดเลือกจากส่องส่วน จำนวน 40 คุณลักษณะ โดยแบ่งเป็นคุณลักษณะจากเอกสารสำคัญ จำนวน 20 คำ มีคุณลักษณะ (Feature) เรียงตามลำดับความถี่ที่ปรากฏในเอกสารมากจนบัน เรียงจากมากไปน้อย [หน่วยงาน ข้อความ บันทึก กอง พอ ดำเนินการ พิจารณา ฝปค เทคโนโลยี แจ้ง งบประมาณ เบิก เอกสาร ฟบบ เที่ยวชม โปรแกรม สาขา SAP สารสนเทศ ศพส] โดยมีค่าคำน้ำหนักคำในแต่ละเอกสาร และคุณลักษณะจากเอกสารทั่วไป จำนวน 20 คำ มีคุณลักษณะ (Feature) เรียงตามลำดับความถี่ที่ปรากฏในเอกสารมากจนบันเรียงจากมากไปน้อย [ทำงาน ปัญหา วิธี มือ ไทย เมือง ข่าว ระดับ พื้นที่ ป้าย ทีม อนาคต หม้อ ลงทุน เทคนิค ประวัติ พาณิชย์ หน้าจอ ส่งเสริม เงื่อนไข] เมื่อเลือกคุณลักษณะเพื่อเป็นตัวแทนของเอกสาร ได้แล้ว ขั้นตอนต่อมาคือคำน้ำหนักของคำเหล่านี้มาเป็นค่าคุณลักษณะ (Feature Vector) ดังแสดงในตารางที่ 4.2 คำน้ำหนักคำของแต่ละเอกสารโดยผ่านกระบวนการหาค่าคำน้ำหนักคำ TF-IDF

ตารางที่ 4.2 คำน้ำหนักคำของแต่ละเอกสารที่แบ่งตามค่าคุณลักษณะ (Feature) ที่ได้เลือกไว้

ประเภทเอกสาร		คุณลักษณะที่คัดเลือกจากเอกสารสำคัญ						คุณลักษณะที่คัดเลือกจากเอกสารทั่วไป					
		งบประมาณ	หน่วยงาน	ดำเนินการ	...	SAP	เบิก	ส่งเสริม	เงื่อนไข	พาณิชย์	...	ระดับ	ปัญหา
เอกสารสำคัญ	Doc 1	0.307	0.271	0.271	...	0.000	0.000	0.000	0.000	0.236	...	0.000	0.000
	Doc 2	0.000	0.236	0.236	...	0.000	0.000	0.000	0.000	0.000	...	0.000	0.000
	Doc 3	0.000	0.379	0.236	...	0.236	0.000	0.000	0.000	0.000	...	0.000	0.000
	Doc 4	0.000	0.236	0.214	...	0.000	0.000	0.000	0.000	0.000	...	0.000	0.000
	Doc 5	0.236	0.271	0.236	...	0.286	0.000	0.000	0.000	0.000	...	0.000	0.307
เอกสารทั่วไป	Doc 61	0.000	0.000	0.000	...	0.000	0.000	0.000	0.038	0.000	...	0.038	0.000
	Doc 62	0.000	0.000	0.000	...	0.000	0.000	0.038	0.000	0.000	...	0.038	0.000
	Doc 63	0.000	0.000	0.000	...	0.000	0.000	0.000	0.000	0.000	...	0.000	0.077
	Doc 64	0.000	0.000	0.000	...	0.000	0.000	0.038	0.000	0.038	...	0.000	0.000
	Doc 65	0.000	0.000	0.000	...	0.000	0.000	0.000	0.000	0.000	...	0.000	0.115

จากค่าคำน้ำหนักคำของแต่ละคำที่ได้เลือกมาเป็นคุณลักษณะ โดยผ่านกระบวนการหาค่าคำน้ำหนักคำ TF-IDF จำนวน 145 เอกสาร โดยแบ่งเป็นเอกสารสำคัญ 60 เอกสาร และเอกสารทั่วไป จำนวน 85 เอกสาร โดยคัดเลือกคุณลักษณะของแต่ละประเภทเอกสารออกมามากกว่าค่าคุณลักษณะของเอกสารแล้ว สังเกตได้ว่าคุณลักษณะจะเป็นตัวบ่งบอกประเภทของเอกสาร ได้อย่างชัดเจน คือคำน้ำหนักของคำคุณลักษณะจะมีจำนวนมากในประเภทของเอกสารนั้นๆ ยกตัวอย่าง เช่น ในส่วนของคุณลักษณะที่ถูกเลือกจากเอกสารสำคัญ ซึ่งก็คือเอกสารที่ 1 – 60 คำน้ำหนักคำของคำที่ถูกเลือกมา

เป็นคุณลักษณะจะมีค่าน้ำหนักคำประกายอยู่ แต่ในส่วนของค่าน้ำหนักคำของคำที่ถูกเลือกเป็นคุณลักษณะของเอกสารทั่วไป จะมีค่าน้ำหนักคำประกายเป็น 0 หรือประกายค่าน้อยมากในเอกสารที่ 1-60 ในกรณีตรงกันข้าม ในส่วนของเอกสารทั่วไป 61-145 จะเห็นได้ว่า ค่าน้ำหนักจะไปประกายในส่วนของคำคุณลักษณะที่ถูกเลือกคุณลักษณะตัวแทนของเอกสารทั่วไป แต่ในส่วนของคำคุณลักษณะตัวแทนของเอกสารสำคัญ จะประกายค่าเป็น 0

ขั้นตอนต่อมาคือการลดขนาดของค่าคุณลักษณะ(Normalize) เนื่องจากข้อมูลดิบที่ได้มาอาจจะทำให้เกิดปัญหาในเรื่องของการตีความกลุ่มข้อมูล ซึ่งถ้ามีตัวแบ่งของข้อมูลต่ำ และค่าของข้อมูลที่ไม่ห่างกันมาก ก็จะทำให้ข้อมูลมีลักษณะของการกระจายกลุ่มกัน ในทางตรงกันข้ามถ้าข้อมูล มีค่าสูง และแตกต่างกันมาก ก็อาจจะทำให้ถูกตีความว่าเป็นคนละกลุ่มกันได้ งานวิจัยนี้จึงได้ทำการลดค่าคุณลักษณะของข้อมูลเพื่อลดตัวแปรนำเข้า เพื่อเพิ่มประสิทธิภาพของการคัดแยกประเภท

จากค่าคุณลักษณะที่ได้หลังจากผ่านการลดค่าคุณลักษณะแล้ว ค่าที่ได้จะมีการกระจายตัวเดียวที่ยังคงไว้ แต่ค่าของข้อมูลไม่ห่างกันมากอยู่ระหว่างค่า 0 และ 1 นำข้อมูลค่าน้ำหนักเข้ากระบวนการคัดแยกประเภทเอกสารด้วยวิธี LS-SVM ร่วมกับค่าผลลัพธ์ของประเภทเอกสารแต่ละฉบับ ที่อยู่ในรูปเมตริกซ์ ถูกกำหนดประเภทไว้แทนด้วยตัวเลข (-1) คือเอกสารทั่วไป และ (+1) คือเอกสารสำคัญ เป็นข้อมูลนำเข้าอีกด้านหนึ่งในชุดการฝึกสอน

ผลการทดสอบดูจากค่า Y_t (ผลที่ได้จากการแยกประเภท) และเปรียบเทียบกับค่า Y (ประเภทของข้อมูลชุดฝึกสอน) ที่กำหนดไว้ ทำการทดสอบอัตราความถูกต้อง (Accuracy Rate) ของการคัดแยกประเภทเอกสาร โดยนำเอกสารชุดทดสอบมาคัดแยกประเภทเอกสารผ่านข้อมูลชุดฝึกสอน และหาค่าความถูกต้องจากผลลัพธ์ของการแยกประเภทที่ได้

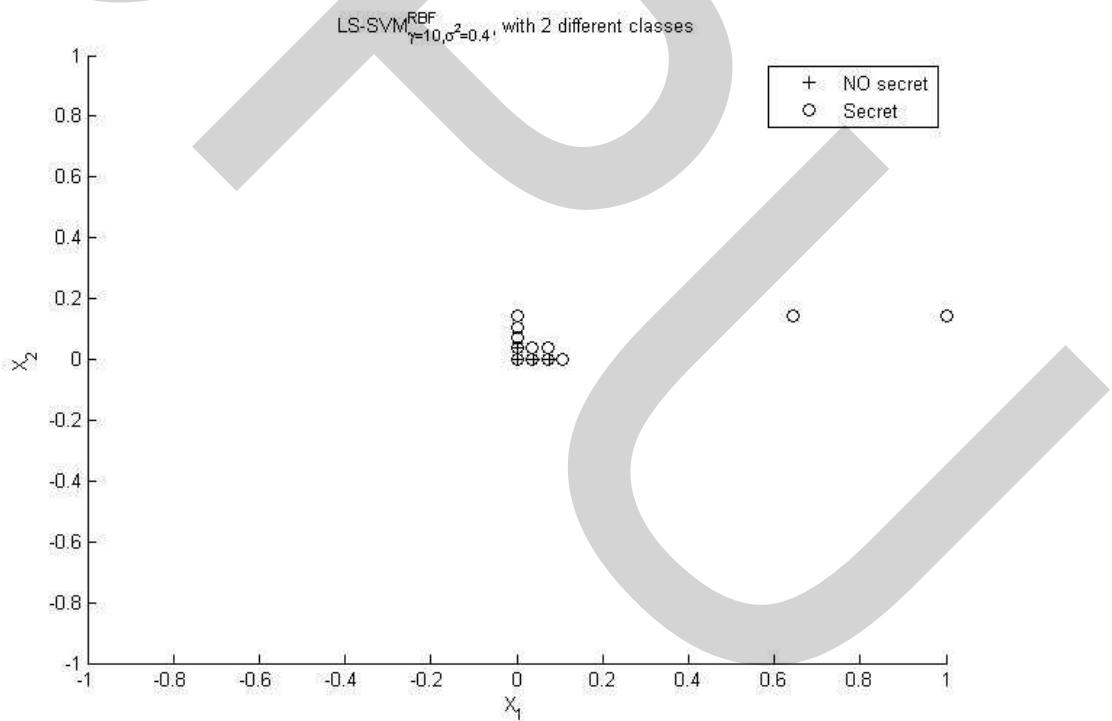
4.2 การวัดประสิทธิภาพ

การวัดประสิทธิภาพการคัดแยกประเภทเอกสารสำคัญ ออกจากเอกสารทั่วไป โดยคำนวณอัตราความถูกต้อง (Accuracy Rate) เป็นวิธีการทดสอบเพื่อเปรียบเทียบประสิทธิภาพ ของการเลือกใช้จำนวนคุณลักษณะ ในแต่ละการทดลองซึ่งการหาอัตราความถูกต้อง คือความสามารถในการเข้าใกล้ค่าจริง (True Value) ของการวัดผล โดยหาได้จาก สมการ 4-1

$$\frac{\text{Total Document read} - \text{Total Error}}{\text{Total Document read}} \times 100 = \text{Accuracy Rate (\%)} \quad (4-1)$$

4.3 ผลการทดสอบ

การทดสอบการแยกประเภทเอกสารของข้อมูลชุดฝึกสอน ซึ่งประกอบไปด้วย เอกสาร สำคัญ 60 เอกสาร และเอกสารทั่วไปจำนวน 85 เอกสาร จำนวนคุณลักษณะสำคัญ (Feature) 40 คุณลักษณะ โดยเลือกคุณลักษณะจากชุดเอกสารสำคัญ 20 คุณลักษณะ และเอกสารทั่วไป 20 คุณลักษณะ หากประสิทธิภาพการคัดแยกประเภทเอกสารสำคัญ ออกจากเอกสารทั่วไป โดยวิธีการหาค่าความถูกต้อง (Accuracy Rate) โดยมีตัวแปรเป็นจำนวนคุณลักษณะที่เลือกใช้ในการทดสอบ แต่ละครั้ง ในทุกๆเอกสารจะถูกแทนด้วยค่าหน้ากของแต่ละคำในชุดเอกสาร และถูกเลือกคำสำคัญมาเป็นคุณลักษณะ (Feature) เพื่อเป็นตัวแทนของเอกสาร หากค่าน้ำหนักคำ (Feature Vector) โดยใช้ทฤษฎี TF-IDF ประเภทเอกสารทั่วไปถูกแทนด้วยตัวเลข (-1) ส่วนเอกสารสำคัญถูกแทนด้วยตัวเลข (1) นำข้อมูลดังกล่าวที่อยู่ในรูปแบบของเมตริกซ์เข้าสู่ระบบการแยกประเภทเอกสาร LS-SVM ดังกราฟแสดงผลการแยกประเภทเอกสารของชุดข้อมูลฝึกสอนตามรูปที่ 4.2



รูปที่ 4.2 กราฟแสดงผลการแยกประเภทเอกสารชุดฝึกสอนด้วยวิธี LS-SVM จำนวน 145 เอกสาร โดยใช้จำนวนคุณลักษณะ 40 คุณลักษณะ

การคัดแยกประเภทของข้อมูลชุดฝึกสอน แสดงออกมาในรูปที่ 4.2 กราฟ LS-SVM ตามฟังก์ชันการพล็อตกราฟของ LS-SVM Model ในโปรแกรม MATLAB ที่แสดงคลาส ที่

แต่ก่อต่างกัน 2 คลาส เครื่องหมาย + แสดงคลาสของเอกสารทั่วไป และ ○ แสดงคลาสของเอกสารสำคัญ บน Feature Space X_1 และ X_2 ที่เกิดจากฟังก์ชันแมป SVM ที่นำข้อมูลจาก Input Space (ข้อมูลต้นฉบับ) ไปยัง Feature Space (ข้อมูลที่ถูกแยกประเภทแล้ว) จากกราฟจะเห็นได้ว่า จุดข้อมูลเอกสารทั่วไปในส่วนของ Feature Space มีลักษณะคล้ายกัน เนื่องจากค่าน้ำหนักคำมีค่าใกล้เคียงกัน และมีค่าน้ำหนักคำเป็น 0 จำนวนมาก รวมทั้งในส่วนของข้อมูลสำคัญ ที่มีการ całegoของข้อมูล เพราะค่าน้ำหนักใน Input Space มีค่าไม่ต่างกันมาก และมีค่าน้ำหนักเป็น 0 จำนวนมาก เช่นกัน

ค่าสัมประสิทธิ์ที่ใช้ในการคำนวณของ LS-SVM ประกอบไปด้วยค่าแอลfa (alpha) หรือ Support Value สนับสนุนการเพิ่มประสิทธิภาพในการคัดแยกประเภท , แกมมา (gam) เป็นค่า trade-off เพื่อลดความผิดพลาดในการคัดแยกประเภท , ซิกมา (sig2) Kernel parameter หรือ ในกรณีใช้คอร์เนลฟังก์ชันเป็น เรเดียลเบลสฟังก์ชัน RBF และค่าไบอัส b หรือค่าความโน้มเอียงใช้สำหรับการจำแนกข้อมูล เป็นสัมประสิทธิ์ที่ได้จากการประมวลผลของ LS-SVM และค่าน้ำหนักเอกสารชุดฝึกสอนจำนวน 145 ฉบับ ซึ่งแบ่งเป็นเอกสารสำคัญ 60 เอกสาร เอกสารทั่วไป 85 เอกสาร คุณลักษณะสำคัญ 40 คำ และให้ผลลัพธ์ของประเภทเอกสารสำคัญแทนด้วย (1) และเอกสารทั่วไปแทนด้วย (-1) No Secret เพื่อแยกประเภทเอกสาร แสดงค่าดังตารางที่ 4.3 แสดงจำนวนชุดข้อมูลชุดฝึกสอน (Feature Vector) มีเมทริกซ์เป็น $X = 145 \times 40$ มีเอกสาร 145 ฉบับและมีคำสำคัญ (Feature) 40 คำในทุกๆ เอกสาร $Y = 145 \times 1$ แสดงประเภทของเอกสารชุดฝึกสอนของแต่ละเอกสาร

ตารางที่ 4.3 ค่าตัวแปรที่ได้จากการแยกประเภทเอกสารชุดฝึกสอน

ตัวแปร	ค่า	ต่ำสุด	สูงสุด
ค่าคุณลักษณะเอกสารชุดฝึกสอน	145×40	0	1
ประเภทของเอกสารชุดฝึกสอน	145×1	-1	1
Support Value (α)	145×1	-10.5819	15.1833
ค่าความโน้มเอียง (b)	0.1667	0.1667	0.1667
ค่า trade-off (gam)	10	10	10
Kernel Parameter (sig2)	0.4000	0.4000	0.4000
Type	<i>Classification</i>		

จากการที่ 4.3 แสดงผลลัพธ์ที่ได้จากการนำเวกเตอร์คุณลักษณะสำคัญของข้อมูลชุดฝึกสอน 145×40 กำหนดค่าคุณลักษณะจำนวน 40 คำ โดยมีค่าน้ำหนักต่ำสุดอยู่ที่ 0 และค่าน้ำหนักสูงสุดที่ 1 เวกเตอร์ประเภทของเอกสารชุดฝึกสอนของแต่ละเอกสาร $Y(145 \times 1)$ โดยกำหนดให้เป็น $[-1,1]$ กำหนดค่าสัมประสิทธิ์ trade off ($gam = 10$) และ Kernel Parameter ($sig2 = 0.4000$) เพื่อหาสัมประสิทธิ์ค่าแอลฟ่า หรือ Support Value และค่าไบอัส b โดยค่าสัมประสิทธิ์ที่ได้จากการคำนวณ $\alpha = -10.5819 \quad 15.1833$ และค่าไบอัส (bias) หรือค่าความโน้มเอียงสำหรับให้ระบบรู้ว่า $b = 0.1667$ เพื่อให้เส้นแบ่งสามารถทำการแบ่งเอกสารได้เป็น 2 ประเภท คือ เอกสารสำคัญ (1) และเอกสารทั่วไป (-1) ตามที่ได้กำหนดไว้

นำข้อมูลชุดฝึกสอนที่ได้ มาทดสอบกับข้อมูลชุดทดสอบ ข้อมูลทดสอบแบ่งออกเป็น 2 ประเภทคือ เอกสารชุดทดสอบที่อยู่ในกลุ่มเป้าหมาย และเอกสารชุดทดสอบที่อยู่นอกกลุ่มเป้าหมาย โดยจะแบ่งการทดสอบเป็น 4 กรณี คือ การทดสอบโดยใช้ค่าคุณลักษณะ 10, 20, 30 และ 40 คำ โดยเป็นคุณลักษณะที่ถูกเลือกจากคำที่ปรากฏความถี่ที่ปรากฏในเอกสารมากฉบับ โดยเรียงจากมากไปน้อย ซึ่งถูกคัดเลือกโดยใช้ข้อมูลชุดเดียวกัน เอกสารชุดทดสอบประกอบไปด้วยเอกสารสำคัญ และเอกสารทั่วไปที่ยังไม่ได้ทำการคัดแยกประเภทดังตารางที่ 4.4

ตารางที่ 4.4 ค่าน้ำหนักคำตามคุณลักษณะของเอกสารชุดทดสอบจำนวน 60 เอกสาร

ประเภทเอกสาร		คุณลักษณะที่ตัดเลือกจากเอกสารสำคัญ						คุณลักษณะที่ตัดเลือกจากเอกสารทั่วไป					
		งบประมาณ	หน่วยงาน	ดำเนินการ	...	SAP	บริษัท	สั่งสร้าง	เงื่อนไข	พารามิเตอร์	...	ระดับ	ปัญหา
เอกสารสำคัญ	Doc 1	0.000	0.179	0.036	...	0.036	0.000	0.000	0.000	0.000	...	0.000	0.000
	Doc 2	0.036	0.072	0.036	...	0.286	0.000	0.000	0.000	0.000	...	0.000	0.107
	Doc 3	0.036	0.464	0.072	...	0.072	0.286	0.036	0.036	0.000	...	0.036	0.000
	Doc 4	0.000	0.036	0.036	...	0.036	0.000	0.000	0.000	0.000	...	0.000	0.000
	Doc 5	0.000	0.072	0.072	...	0.072	0.000	0.000	0.000	0.000	...	0.000	0.000
เอกสารทั่วไป	Doc 61	0.000	0.000	0.000	...	0.000	0.000	0.000	0.100	0.000	...	0.100	0.000
	Doc 62	0.000	0.000	0.000	...	0.000	0.000	0.000	0.000	0.000	...	0.100	0.000
	Doc 63	0.000	0.000	0.000	...	0.000	0.000	0.000	0.000	0.000	...	0.000	0.200
	Doc 64	0.000	0.000	0.000	...	0.000	0.000	0.100	0.000	0.000	...	0.100	0.000
	Doc 65	0.000	0.000	0.000	...	0.000	0.000	0.000	0.000	0.100	...	0.000	0.200

จากการ จะได้ค่าน้ำหนักคำ TF-IDF แทนค่าคุณลักษณะ เป็นตัวแทนของเอกสารฉบับนั้นๆ จากเอกสารสำคัญจะได้ค่าน้ำหนักในช่วงของคุณลักษณะสำคัญที่ดึงมากจากกลุ่มของเอกสารสำคัญ ส่วนค่าน้ำหนักในช่วงของคุณลักษณะที่ดึงมากจากกลุ่มของเอกสารทั่วไปนั้น จะให้

ค่าปีน 0 และในส่วนของเอกสารทั่วไป จะได้ค่าน้ำหนักคำทั้งในส่วนของค่าคุณลักษณะที่ดึงมาจากกลุ่มเอกสารสำคัญ และกลุ่มเอกสารทั่วไป แสดงว่าเอกสารฉบับที่ 31 และ 32 มีคำสำคัญที่ปรากฏตรงกับคุณลักษณะของเอกสารสำคัญนั้นเอง

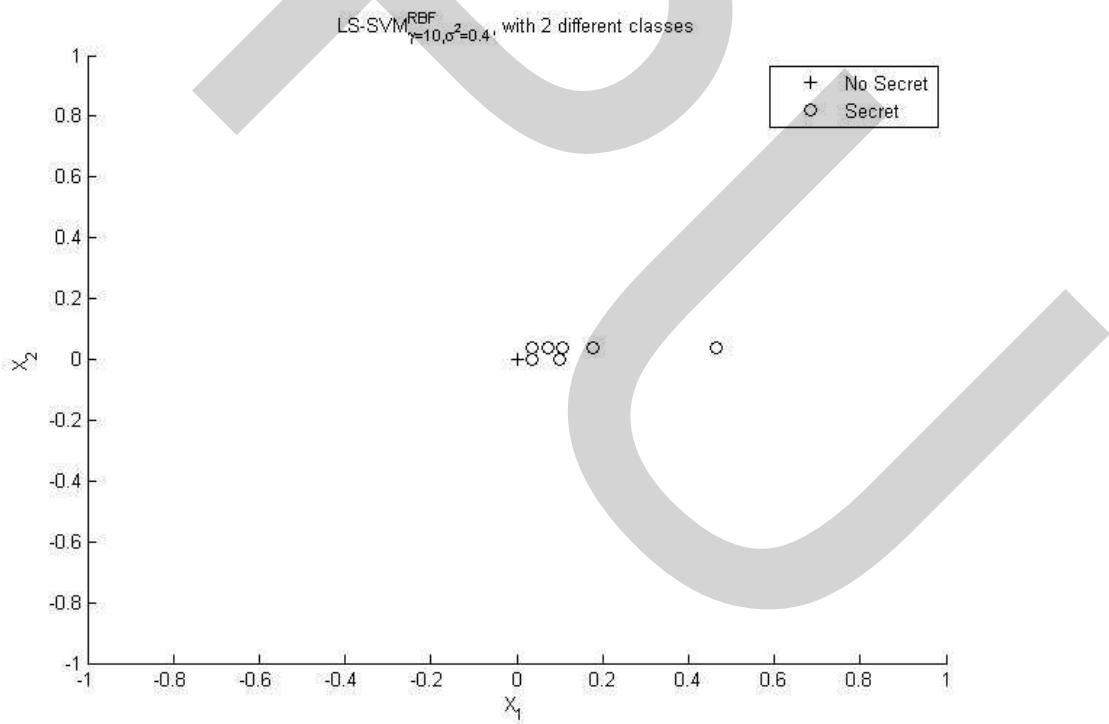
จากค่าคุณลักษณะที่ได้ หลังจากผ่านการลดค่าคุณลักษณะ(Normalize) ค่าที่ได้จะมีการกระจายตัวเดjmakยิ่งขึ้น และค่าของข้อมูลไม่ห่างกันมากอยู่ระหว่างค่า 0 และ 1 นำข้อมูลนี้นำเข้ากระบวนการคัดแยกประเภทเอกสารด้วยวิธี LS-SVM ร่วมกับค่าผลลัพธ์ของประเภทเอกสารแต่ละฉบับ ซึ่งถูกกำหนดประเภทไว้แทนด้วยตัวเลข (-1) คือเอกสารทั่วไป และ (+1) คือเอกสารสำคัญ ทำการทดสอบการแยกประเภทเอกสาร ด้วยชุดข้อมูลฝึกสอน 145 เอกสาร ประกอบไปด้วยข้อมูลที่เป็นเอกสารสำคัญจำนวน 60 เอกสาร และเอกสารทั่วไปจำนวน 85 เอกสารนำมาทดสอบกับข้อมูลชุดทดสอบ โดยการทดสอบจะทำการทดสอบใน 2 กรณี คือทำการทดสอบกับชุดข้อมูลทดสอบที่ไม่อู้ในกลุ่มเป้าหมาย และชุดทดสอบที่อู้ในกลุ่มเป้าหมาย

4.3.1 ทำการทดสอบกับข้อมูลชุดทดสอบที่ไม่อู้ในกลุ่มเป้าหมาย โดยนำชุดข้อมูลฝึกสอนทดสอบการคัดแยกประเภทเอกสารกับข้อมูลชุดทดสอบนอกกลุ่มเป้าหมาย นำเอกสารชุดทดสอบจำนวน 60 ฉบับ จากชุดข้อมูลทดสอบที่อู้นอกเหนือกลุ่มเป้าหมาย และได้กำหนดประเภทเอกสารไว้ล่วงหน้า ให้ข้อมูลชุดทดสอบประกอบด้วยเอกสารสำคัญ 30 เอกสาร และเอกสารทั่วไป 30 เอกสาร โดยมีค่าคุณลักษณะแทนด้วยค่าน้ำหนักคำของเอกสารทั้ง 60 ฉบับ นำเข้าทดสอบกับเอกสารชุดฝึกสอนจำนวน 145 ฉบับ ตามทฤษฎีของ LS-SVM ค่า $Y_t = 60 \times 1$ แสดงผลลัพธ์ที่ได้จากการแยกประเภทเอกสาร Y_t นำมาคำนวณหาอัตราความถูกต้องตามจำนวนคุณลักษณะที่เลือกใช้ในการทดลองแต่ละครั้ง 10, 20, 30 และ 40 คุณลักษณะ ได้อัตราความถูกต้องเป็น 83.33%, 81.67%, 80.00% และ 83.33% ตามลำดับ จะเห็นได้ว่าค่าความถูกต้องมากที่สุด 83.33% โดยใช้จำนวนคุณลักษณะเป็น 10 และ 40 คุณลักษณะ แสดงให้เห็นว่าคุณลักษณะที่ปรากฏในเอกสารชุดทดสอบเป็นคุณลักษณะที่อยู่ในกลุ่มของคุณลักษณะลำดับที่ 1-10 และคุณลักษณะลำดับที่ 31-40

4.3.2 ทำการทดสอบกับข้อมูลชุดทดสอบที่อู้ในกลุ่มเป้าหมาย โดยนำชุดข้อมูลฝึกสอนทดสอบการคัดแยกประเภทเอกสารกับข้อมูลชุดทดสอบที่อู้ในกลุ่มเป้าหมาย นำเอกสารชุดทดสอบจำนวน 60 ฉบับจากชุดข้อมูลทดสอบที่อู้ในกลุ่มเป้าหมาย ซึ่งได้กำหนดประเภทเอกสารไว้ล่วงหน้า ให้ข้อมูลชุดทดสอบประกอบด้วยเอกสารสำคัญ 30 เอกสาร และเอกสารทั่วไปจำนวน 30 เอกสาร โดยมีค่าคุณลักษณะแทนด้วยค่าน้ำหนักคำของเอกสารทั้ง 60 ฉบับ นำเข้าทดสอบกับเอกสารชุดฝึกสอนจำนวน 145 ฉบับ ตามทฤษฎีของ LS-SVM ค่า $Y_t = 60 \times 1$ แสดงผลลัพธ์ที่ได้จากการแยกประเภทเอกสาร Y_t และแบ่งการทดสอบออกเป็น 4 การทดสอบ ตามจำนวนคุณลักษณะที่เลือกใช้ในการทดสอบแต่ละครั้ง นำมาคำนวณหาอัตราความถูกต้องตามจำนวน

คุณลักษณะที่เลือกใช้ในการทดลองแต่ละครั้ง 10, 20, 30 และ 40 คุณลักษณะ ได้อัตราความถูกต้อง เป็น 83.33%, 88.33%, 86.67% และ 86.67% ตามลำดับ ดังแสดงตามผลการทดสอบต่อไปนี้

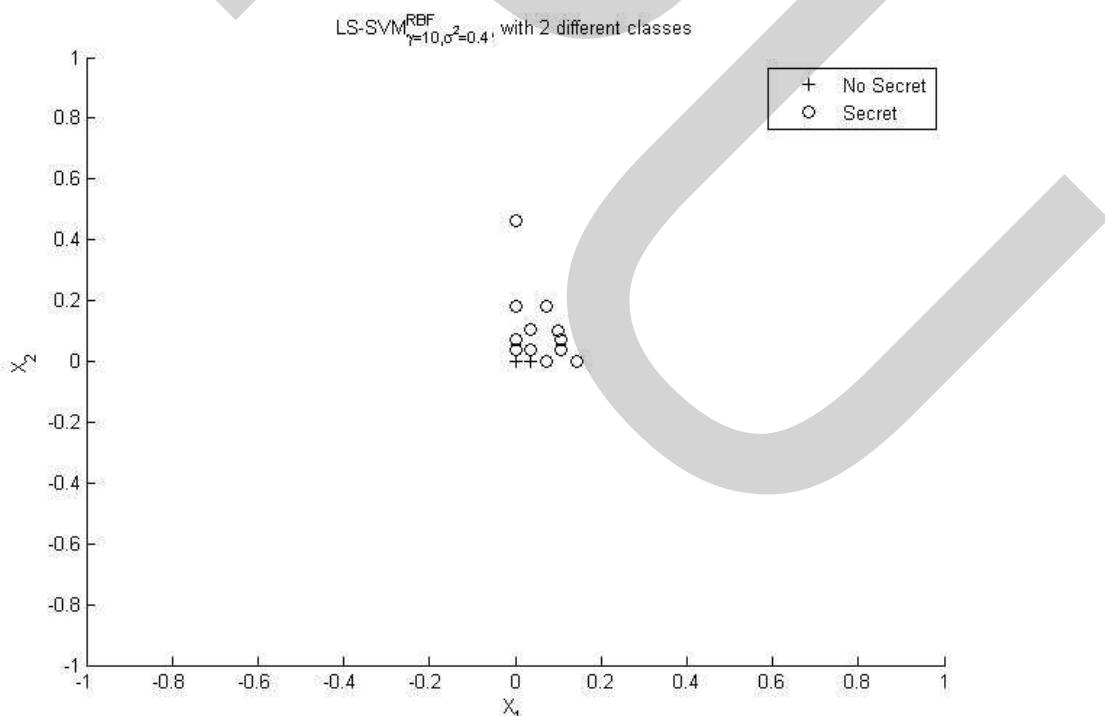
กราฟแสดงการแยกประเภทเอกสาร สามารถแยกได้ 2 ประเภท กือเอกสารสำคัญ แทนด้วยสัญลักษณ์ \circ และเอกสารทั่วไปแทนด้วยสัญลักษณ์ $+$ ค่า $X_t = 60 \times 10$ แสดงจำนวนเอกสารชุดทดสอบจำนวน 60 ฉบับ คัดเลือกคุณลักษณะสำคัญ (Feature Selection) โดยเลือกจากสองส่วน จำนวน 10 คุณลักษณะ โดยแบ่งเป็นคุณลักษณะจากเอกสารสำคัญ จำนวน 5 คำ มีคุณลักษณะเรียงตามลำดับความถี่ที่ปรากฏในเอกสารมากฉบับเรียงจากมากไปน้อย [หน่วยงาน ข้อความ บันทึก กอง พอ] และคุณลักษณะจากเอกสารทั่วไป จำนวน 5 คำ มีคุณลักษณะ เรียงตามลำดับความถี่ที่ปรากฏในเอกสารมากฉบับเรียงจากมากน้อย [ทำงาน ปัญหา วิธี มือ ไทย] ค่าคุณลักษณะแทนด้วยค่าน้ำหนักคำของเอกสารทั้ง 60 ฉบับ นำเข้าทดสอบกับเอกสารชุดฝึกสอนจำนวน 145 ฉบับ ตามทฤษฎีของ LS-SVM ค่า $Y_t = 60 \times 1$ แสดงผลลัพธ์ที่ได้จากการแยกประเภทเอกสาร Y_t ดังในรูปที่ 4.3



รูปที่ 4.3 กราฟแสดงผลการแยกประเภทเอกสารด้วยวิธี LS-SVM กับชุดข้อมูลทดสอบจำนวน 60 เอกสาร โดยใช้คุณลักษณะจำนวน 10 คุณลักษณะ

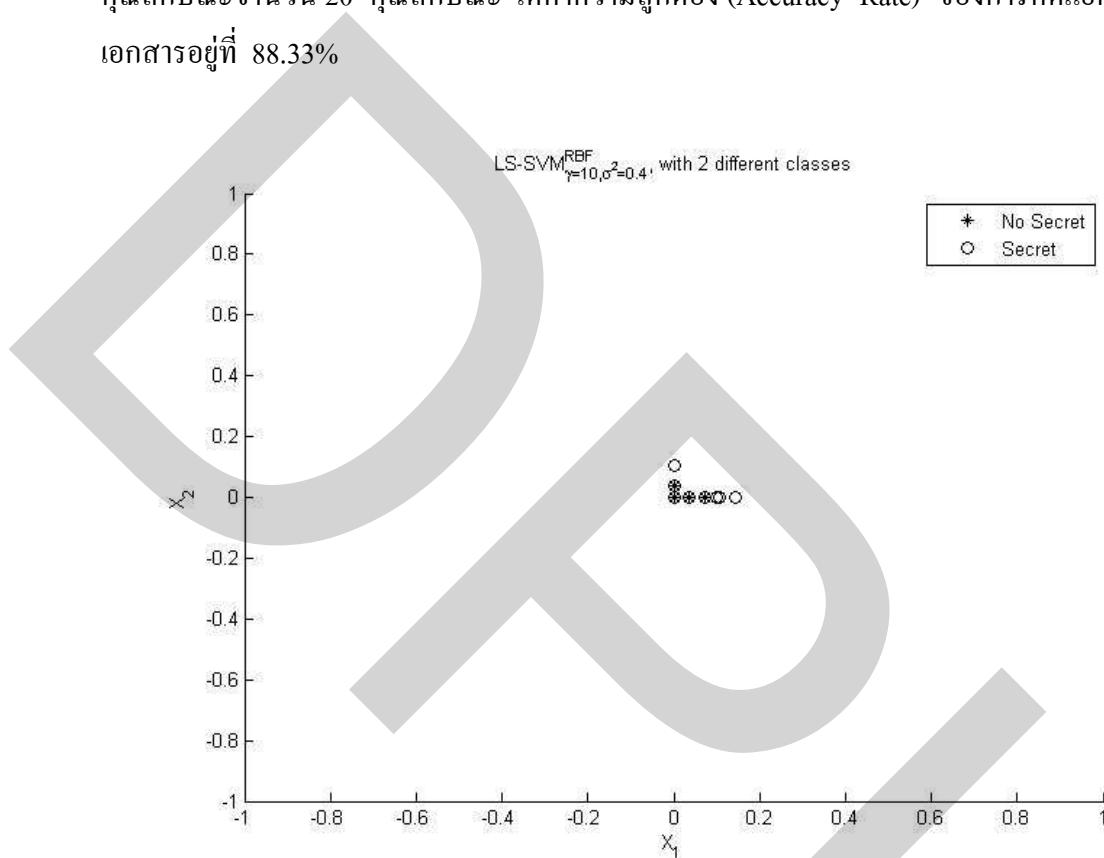
ผลลัพธ์ที่ได้จากการแยกประเภทเอกสารชุดทดสอบจำนวน 60 เอกสารที่อยู่ในกลุ่มเป้าหมาย ประกอบไปด้วยเอกสารสำคัญ และเอกสารทั่วไปประเภท 30 เอกสาร ทดสอบกับข้อมูลชุดฝึกสอนจำนวน 145 เอกสาร โดยใช้ค่าคุณลักษณะจำนวน 10 คุณลักษณะ ได้ค่าความถูกต้อง (Accuracy Rate) ของการคัดแยกประเภทเอกสารอยู่ที่ 83.33%

ทดสอบกับเอกสารชุดทดสอบ โดยใช้จำนวนคุณลักษณะจำนวน 20 คุณลักษณะ เมื่อ $X_t = 60 \times 20$ แสดงจำนวนเอกสารชุดทดสอบจำนวน 60 ฉบับ คัดเลือกคุณลักษณะสำคัญ (Feature Selection) จำนวน 20 คุณลักษณะ โดยแบ่งเป็นคุณลักษณะจากเอกสารสำคัญจำนวน 10 คำ มีคุณลักษณะเรียงตามลำดับความถี่ที่ปรากฏในเอกสารมากฉบับเรียงจากมากไปน้อย [หน่วยงาน ข้อความ บันทึก กอง ผอ ดำเนินการ พิจารณา ฝปค เทคโนโลยี แข้ง] และคุณลักษณะจากเอกสารทั่วไปจำนวน 10 คำ มีคุณลักษณะเรียงตามลำดับความถี่ที่ปรากฏในเอกสารมากฉบับเรียงจากมากไปน้อย [ทำงาน ปัญหา วิธี มือ ไทย เมือง ข่าว ระดับ พื้นที่ ปั่ว] ค่าคุณลักษณะแทนด้วยค่าน้ำหนักคำของเอกสารทั้ง 60 ฉบับ ประกอบด้วยเอกสารสำคัญ และเอกสารทั่วไป นำเข้าทดสอบกับเอกสารชุดฝึกสอนจำนวน 145 ฉบับ ตามทฤษฎีของ LS-SVM ค่า $Y_t = 60 \times 1$ แสดงผลลัพธ์ที่ได้จากการแยกประเภทเอกสาร Y_t ดังในรูปที่ 4.4



รูปที่ 4.4 กราฟแสดงผลการแยกประเภทเอกสารด้วยวิธี LS-SVM กับชุดข้อมูลทดสอบจำนวน 60 เอกสาร โดยใช้คุณลักษณะจำนวน 20 คุณลักษณะ

ผลลัพธ์ที่ได้จากการแยกประเภทเอกสารชุดทดสอบจำนวน 60 เอกสารที่ประกอบไปด้วยเอกสารสำคัญ และเอกสารทั่วไป ทดสอบกับข้อมูลชุดฝึกสอนจำนวน 145 เอกสาร โดยใช้ค่าคุณลักษณะจำนวน 20 คุณลักษณะ ได้ค่าความถูกต้อง (Accuracy Rate) ของการคัดแยกประเภทเอกสารอยู่ที่ 88.33%

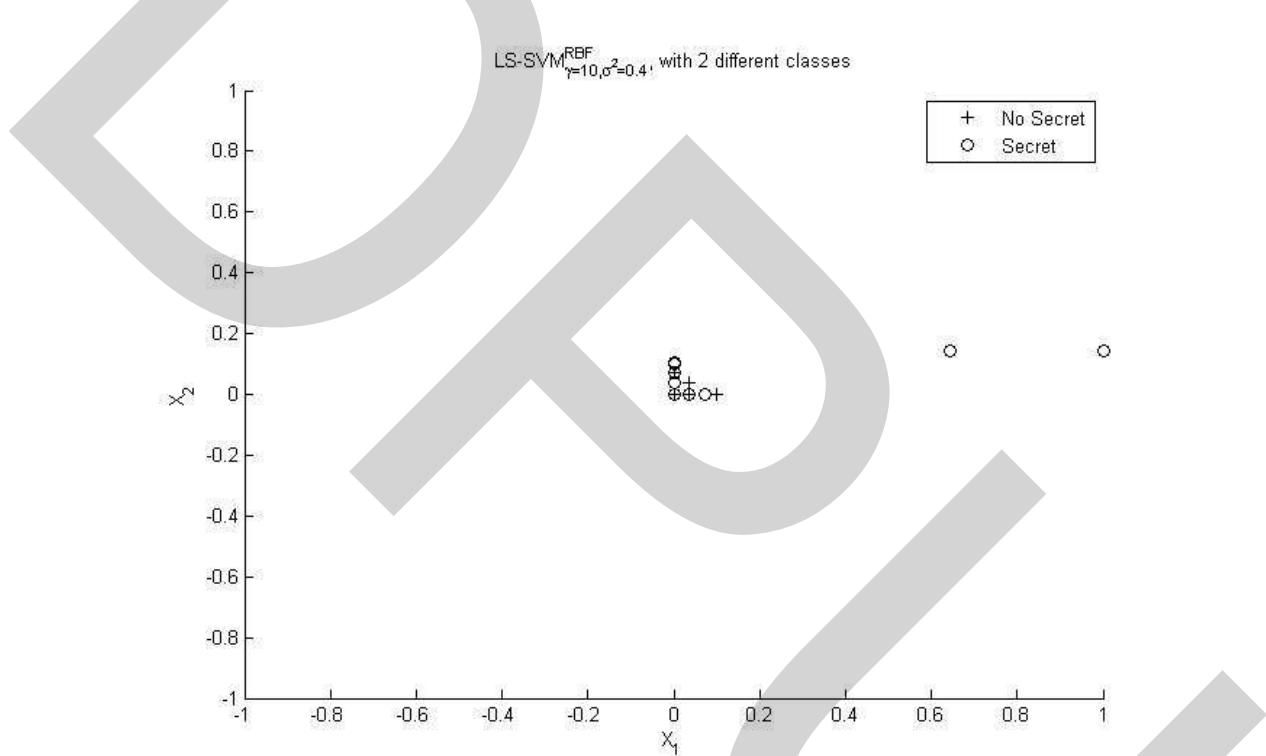


รูปที่ 4.5 กราฟแสดงผลการแยกประเภทเอกสารด้วยวิธี LS-SVM กับชุดข้อมูลทดสอบจำนวน 60 เอกสาร โดยใช้คุณลักษณะจำนวน 30 คุณลักษณะ

ทดสอบกับเอกสารชุดทดสอบ โดยใช้จำนวนคุณลักษณะจำนวน 30 คุณลักษณะ เมื่อ $X_t = 60 \times 30$ แสดงจำนวนเอกสารชุดทดสอบจำนวน 60 ฉบับ คัดเลือกคุณลักษณะสำคัญ (Feature Selection) จำนวน 30 คุณลักษณะ โดยแบ่งเป็นคุณลักษณะจากเอกสารสำคัญจำนวน 15 คำ มีคุณลักษณะเรียงตามลำดับความถี่ที่ปรากฏในเอกสารมากฉบับเรียงจากมากไปน้อย [หน่วยงาน ข้อความ บันทึก กอง พอ ดำเนินการ พิจารณา ฝปค เทคโนโลยี แจ้ง งบประมาณ เปิด เอกสาร ผ่าน เห็นชอบ] และคุณลักษณะจากเอกสารทั่วไป จำนวน 15 คำ มีคุณลักษณะ เรียงตามลำดับความถี่ที่ปรากฏในเอกสารมากฉบับเรียงจากมากไปน้อย [ทำงาน ปัญหา วิธี มือ ไทย เมือง ข่าวระดับ พื้นที่ ป้าย ทีม อนาคต หม้อ ลงทุน เทคนิค] ค่าคุณลักษณะแทนด้วยค่าน้ำหนักคำของเอกสารทั้ง 60 ฉบับ ที่ประกอบไปด้วยเอกสารสำคัญ และเอกสารทั่วไป นำเข้าทดสอบกับเอกสารชุดฝึกสอนจำนวน

145 ฉบับ ตามทฤษฎีของ LS-SVM ค่า $Y_t = 60 \times 1$ แสดงผลลัพธ์ที่ได้จากการแยกประเภทเอกสาร Y_t ดังในรูปที่ 4.5

ผลลัพธ์ที่ได้จากการแยกประเภทเอกสารชุดทดสอบจำนวน 60 เอกสารที่ประกอบไปด้วยเอกสารสำคัญที่ และเอกสารทั่วไป ทดสอบกับข้อมูลชุดฝึกสอนจำนวน 145 เอกสาร โดยใช้คุณลักษณะจำนวน 30 คุณลักษณะ ได้ค่าความถูกต้อง (Accuracy Rate) ของการคัดแยกประเภทเอกสารอยู่ที่ 86.67%



รูปที่ 4.6 กราฟแสดงผลการแยกประเภทเอกสารด้วยวิธี LS-SVM กับชุดข้อมูลทดสอบจำนวน 60 เอกสาร โดยใช้คุณลักษณะจำนวน 40 คุณลักษณะ

ทดสอบกับเอกสารชุดทดสอบ โดยใช้จำนวนคุณลักษณะจำนวน 40 คุณลักษณะ เมื่อ $X_t = 60 \times 40$ แสดงจำนวนเอกสารชุดทดสอบจำนวน 60 ฉบับ คัดเลือกคุณลักษณะสำคัญ (Feature Selection) จำนวน 40 คุณลักษณะ โดยแบ่งเป็นคุณลักษณะจากเอกสารสำคัญ จำนวน 20 คำ มีคุณลักษณะ เรียงตามลำดับความถี่ที่ปรากฏในเอกสารมากฉบับเรียงจากมากไปน้อยเป็น [หน่วยงาน ข้อความ บันทึก กอง พอ ดำเนินการ พิจารณา ฝปค เทคโนโลยี แจ้ง งบประมาณ เบิกเอกสาร ผู้บบ เห็นชอบ โปรแกรม สาขา SAP สารสนเทศ ศทส] และคุณลักษณะจากเอกสารทั่วไป จำนวน 20 คำ มีคุณลักษณะ เรียงตามลำดับความถี่ที่ปรากฏในเอกสารมากฉบับเรียงจากมากไป

น้อย [ทำงาน ปัญหา วิธี มือ ไทย เมือง ข้าว ระดับ พื้นที่ ป่วย ทีม อนาคต หม้อ ลงทุนเทคโนโลยี ประวัติ พาณิชย์ หน้าจอ ส่งเสริม เงื่อนไข] ค่าคุณลักษณะแทนด้วยค่าน้ำหนักคำของเอกสารทั้ง 60 ฉบับ ที่ประกอบไปด้วยเอกสารสำหรับและเอกสารทั่วไป นำเข้าทดสอบกับเอกสารชุดฝึกสอนจำนวน 145 ฉบับ ตามทฤษฎีของ LS-SVM ค่า $Y_t = 60 \times 1$ แสดงผลลัพธ์ที่ได้จากการแยกประเภทเอกสาร Y_t ดังในรูปที่ 4.6

ผลลัพธ์ที่ได้จากการแยกประเภทเอกสารจำนวน 60 เอกสารที่ประกอบไปด้วยเอกสารสำหรับและเอกสารทั่วไป ทดสอบกับข้อมูลชุดฝึกสอนจำนวน 145 เอกสาร โดยใช้คุณลักษณะจำนวน 40 คุณลักษณะ ได้ค่าความถูกต้อง (Accuracy Rate) ของการคัดแยกประเภทเอกสารอยู่ที่ 86.67%

ตาราง 4.5 เปรียบเทียบค่าความถูกต้องของการคัดแยกประเภทเอกสารด้วยจำนวนคุณลักษณะในการทดสอบกับข้อมูลชุดทดสอบนอกกลุ่มเป้าหมาย

Feature	Data Test		error		Accuracy Rate
	Secret	No Secret	Secret	No Secret	
10	30	30	9	1	83.33%
20	30	30	9	2	81.67%
30	30	30	11	1	80.00%
40	30	30	8	2	83.33%

จากตารางเปรียบเทียบค่าความถูกต้องของการคัดแยกประเภทเอกสาร ด้วยจำนวนคุณลักษณะ (Feature) ที่แตกต่างกัน สำหรับข้อมูลชุดฝึกสอน และข้อมูลชุดทดสอบเดียวกัน ชุดฝึกสอนจำนวน 145 เอกสาร โดยแบ่งเป็นเอกสารสำหรับและเอกสารทั่วไปจำนวน 85 เอกสาร กับเอกสารชุดทดสอบที่อยู่นอกกลุ่มเป้าหมาย แบ่งเป็นเอกสารสำหรับ 30 เอกสาร และเอกสารทั่วไปจำนวน 30 เอกสาร จำนวนคุณลักษณะ ที่มีค่าคุณลักษณะ (Feature Vector) ถูกแทนด้วยค่าน้ำหนักคำในชุดเอกสาร ค่าความถูกต้องในการทดสอบดีที่สุดคือ 83.33% โดยใช้จำนวนคุณลักษณะ 10 และ 40 คุณลักษณะ ในขณะที่จำนวนคุณลักษณะ 20 และ 30 คุณลักษณะ ให้ค่าความถูกต้องอยู่ที่ 81.67% และ 80.00% ตามลำดับ

ตาราง 4.6 เปรียบเทียบค่าความถูกต้องของการคัดแยกประเภทเอกสารด้วยจำนวนคุณลักษณะ
ในการทดสอบกับข้อมูลชุดทดสอบกลุ่มเป้าหมาย

<i>Feature</i>	<i>Data Test</i>		<i>error</i>		<i>Accuracy Rate</i>
	<i>Secret</i>	<i>No Secret</i>	<i>Secret</i>	<i>No Secret</i>	
10	30	30	9	1	83.33%
20	30	30	6	1	88.33%
30	30	30	7	1	86.67%
40	30	30	7	1	86.67%

จากตารางเปรียบเทียบค่าความถูกต้องของการคัดแยกประเภทเอกสาร ด้วยจำนวนคุณลักษณะ (Feature) ที่แตกต่างกัน สำหรับข้อมูลชุดฝึกสอน และข้อมูลชุดทดสอบเดียวกัน ชุดฝึกสอนจำนวน 145 เอกสาร โดยแบ่งเป็นเอกสารสำาคัญ 60 เอกสาร และเอกสารทั่วไปจำนวน 85 เอกสาร กับเอกสารชุดทดสอบที่มาจากการกลุ่มเป้าหมาย แบ่งเป็นเอกสารสำาคัญ 30 เอกสาร และเอกสารทั่วไปจำนวน 30 เอกสาร จำนวนคุณลักษณะ ที่มีค่าคุณลักษณะ (Feature Vector) ถูกแทนด้วยค่าน้ำหนักคำในชุดเอกสาร ค่าความถูกต้องในการทดสอบดีที่สุดคือ 88.33% โดยใช้จำนวนคุณลักษณะ 20 คุณลักษณะ ในขณะที่จำนวนคุณลักษณะ 30 และ 40 คุณลักษณะ ให้ค่าความถูกต้องดีที่สุดอยู่ที่ 86.6% และที่จำนวนคุณลักษณะ 10 คุณลักษณะให้ค่าความถูกต้อง 83.33%

สามารถวิเคราะห์ได้ว่าประสิทธิภาพในการคัดแยกประเภทเอกสารนั้นขึ้นอยู่กับคุณลักษณะที่เลือกใช้ และกลุ่มของข้อมูลชุดทดสอบว่าเป็นกลุ่มเป้าหมายเดียวกันกับกลุ่มข้อมูลชุดข้อมูลฝึกสอน หรือชุดข้อมูลที่นำมาคัดเลือกคุณลักษณะสำาคัญหรือไม่ ซึ่งเป็นตัวแปรหลักในการคัดแยกประเภทเอกสาร ถ้าหากคุณลักษณะที่เลือกใช้มีความคล้ายคลึง หรือเหมือนกับคำที่ปรากฏในเอกสารชุดทดสอบมากคำ ก็จะมีประสิทธิภาพ และให้ค่าความถูกต้องมาก ในขณะเดียวกันถ้าหากทำการทดสอบกับชุดทดสอบที่อยู่นอกเหนือจากกลุ่มเป้าหมาย ค่าความถูกต้องก็จะมีค่าน้อยกว่า ถึงแม้จะปรากฏคุณลักษณะที่ตรงกันบ้างแต่ก็ยังน้อยกว่าชุดทดสอบที่อยู่ในกลุ่มเป้าหมาย

ดังนั้นการคัดแยกประเภทเอกสารที่จะให้ประสิทธิภาพ หรือค่าความถูกต้องสูงนั้น จำเป็นต้องทำการคัดเลือกคุณลักษณะที่เป็นตัวแทนที่ดีของชุดเอกสารในกลุ่มเป้าหมาย รวมทั้งจำนวนคุณลักษณะที่เลือกใช้ว่าเหมาะสม และพอดีกับสำารับใช้เป็นตัวแทนที่ดีของชุดเอกสารในการคัดแยกสำารับกลุ่มเป้าหมายที่ต้องการทดสอบ เพราะจะนั้นจำเป็นต้องตั้งค่าคุณลักษณะที่ดีของชุดทดสอบที่อยู่ในกลุ่มเป้าหมายก่อน

และทำการคัดเลือกชุดเอกสารฝึกสอนออกแบบ เพื่อหาคุณลักษณะที่เหมาะสมเพื่อเป็นตัวแทนของชุดเอกสารของกลุ่มเป้าหมาย คำที่ใช้เป็นคุณลักษณะ รวมทั้งจำนวนคุณลักษณะที่เหมาะสม ก็จะทำให้ได้ผลการคัดแยกที่มีความถูกต้อง และมีประสิทธิภาพ



บทที่ 5

สรุปผลการศึกษา

ในบทนี้จะเป็นการอภิปรายเพื่อสรุปผลที่ได้จากการทดสอบงานวิจัย รวมทั้งข้อจำกัดของระบบที่พูดจากการทดสอบระบบ และข้อเสนอแนะสำหรับแนวทางในการพัฒนางานวิจัยให้มีประสิทธิภาพมากขึ้น

5.1 สรุปผลการศึกษา

5.1.1 สรุปผลตามวัตถุประสงค์ของงานวิจัย

5.1.1.1 ศึกษาโครงสร้างการทำงานเกี่ยวกับการป้องกันข้อมูลรั่วไหล เพื่อให้เกิดความชัดเจนในเรื่องของกระบวนการทำงานของระบบ

5.1.1.2 ศึกษาเทคนิคที่นำมาปรับใช้สำหรับการแยกประเภทเอกสาร เพื่อนำไปใช้งาน เป็นโครงรูปในการคัดกรองของระบบการป้องกันเอกสารรั่วไหล โดยเลือกใช้เทคนิค LS-SVM เป็นการแยกประเภทแบบมีผู้สอน (Supervised Learning) ในรูปแบบของเทอมเวกเตอร์ สำหรับแทนเอกสารข้อความ เป็นเวกเตอร์ที่ระบุคุณลักษณะสำคัญ เพื่อเป็นข้อมูลที่ใช้ในการกรองการสืบค้นข้อมูลในการทำดังนี้ และจัดอันดับความเกี่ยวข้อง โดยใช้การกำหนดขอบเขตไว้ล่วงหน้า โดยทฤษฎีของ Support Vector Machine (SVM)

5.1.1.3 พัฒนาระบบทดสอบการแยกประเภทเอกสารสำคัญออกจากเอกสารทั่วไป โดยใช้โปรแกรม PHP ประกอบด้วยโปรแกรมย่อย Antiword , SWATH และ TF-IDF ในขั้นตอนการทำหนังสือ คัดเลือกคุณลักษณะสำคัญเพื่อเป็นตัวแทนของเอกสาร และนำคุณลักษณะสำคัญ (TF-IDF) เข้าสู่ขั้นตอนการแยกประเภทเอกสารผ่านโปรแกรม MATLAB โดยใช้ LS-SVM เพื่อแยกประเภทเอกสารสำคัญออกมา ก่อนนำเข้าระบบการป้องกันเอกสารรั่วไหล Symantec DLP

5.1.1.4 วิเคราะห์ความน่าเชื่อถือในการทดสอบ โดยการคำนวณค่าความถูกต้องของการแยกประเภทเอกสาร เพื่อเปรียบเทียบจำนวนคุณลักษณะที่เลือกใช้ในการทดสอบแต่ละครั้ง

5.1.2 สรุปผลตามขอบเขตของงานวิจัย

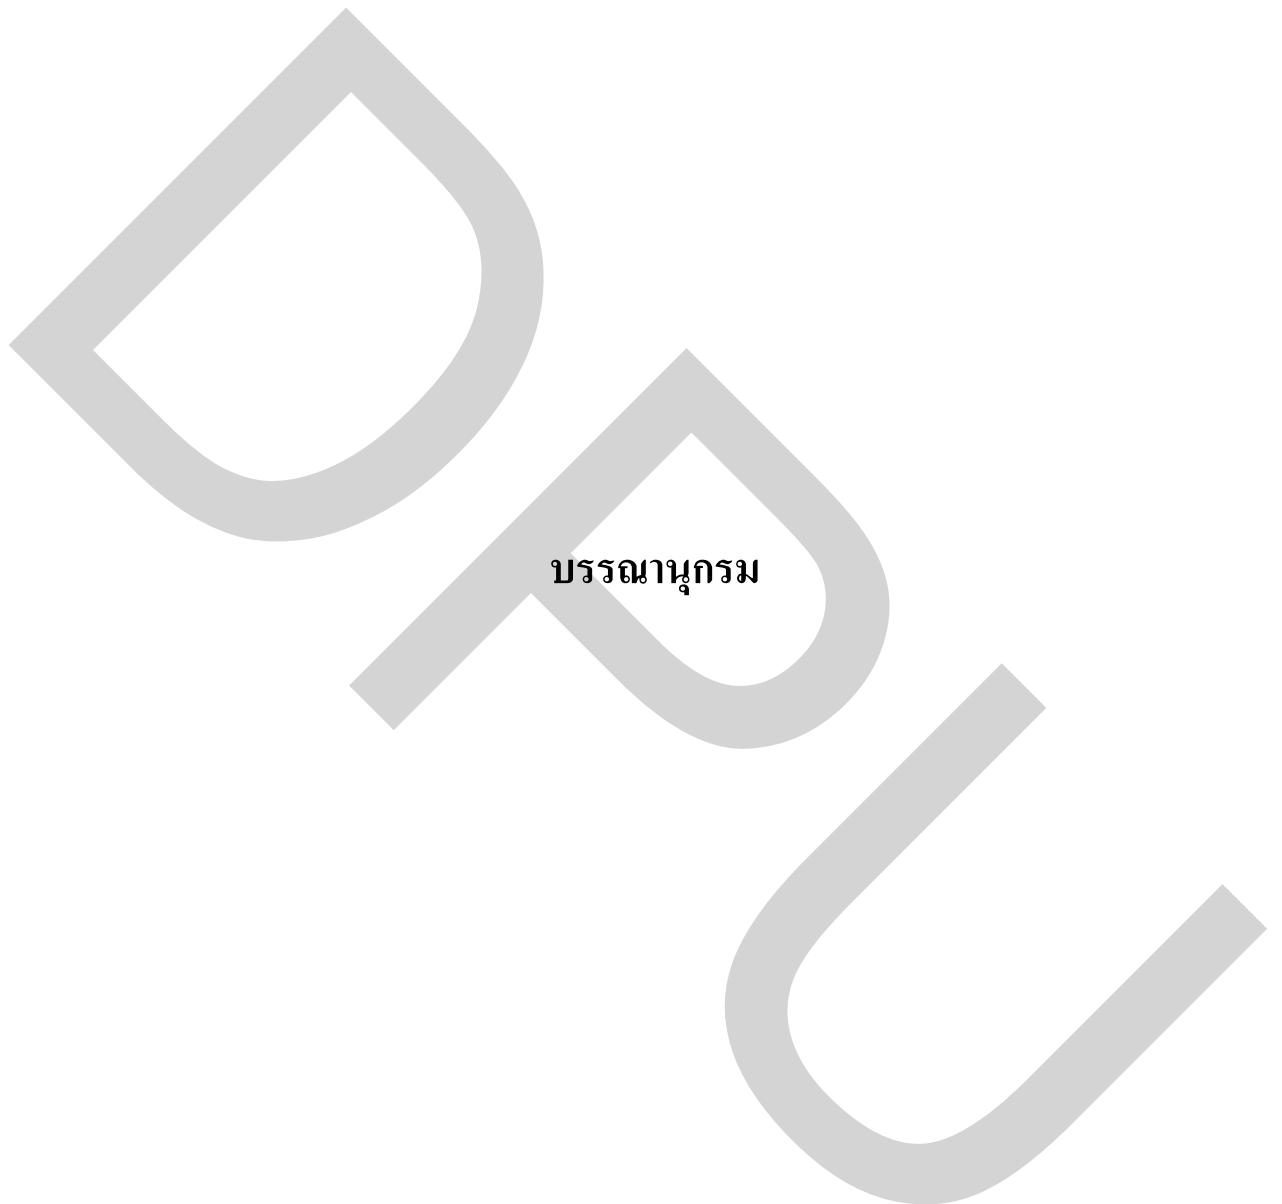
5.1.2.1 ทำการทดสอบโดยใช้เทคนิคการให้หนังสือ TF-IDF และเทคนิคการแยก

ประเพณีเอกสาร LS- SVM เพื่อแยกประเพณีเอกสารสำหรับ ออกจากชุดเอกสารทดสอบที่ยังไม่ได้รับการคัดแยกประเพณี นำผลลัพธ์(เอกสารสำหรับ) ที่ได้จากการแยกประเพณีเอกสารเป็นโครงรูปในการคัดกรองของระบบการป้องกันเอกสารรั่วไหล

5.1.2.2 พัฒนาระบบการทดสอบ เพื่อแยกประเพณีเอกสารสำหรับ ออกจากชุดเอกสารที่ยังไม่ได้มีการคัดแยก ซึ่งชุดเอกสารนี้จะประกอบไปด้วยเอกสารสำหรับ และเอกสารทั่วไป มีการทดสอบประสิทธิภาพโดยคำนวณค่าความถูกต้อง (Accuracy Rate) ของการทดสอบ โดยมีตัวแปรอยู่ที่จำนวนคุณลักษณะที่เลือกใช้

5.2 ปัญหา และข้อเสนอแนะ

การทดสอบดังกล่าวเป็นการทำงานตามขั้นตอน ที่ไม่ต่อเนื่องกัน โดยจะประกอบไปด้วยขั้นตอนในส่วนของข้อมูลนำเข้า Text Preprocessing ขั้นตอนการทำคำนำหน้าคำ และขั้นตอนการคัดแยกเอกสาร ดังนั้นถ้าต้องการเพิ่มประสิทธิภาพการใช้งาน อาจจะต้องพัฒนาให้ระบบกล้ายเป็นโปรแกรมที่ทำงานอัตโนมัติ สามารถทำงานทุกขั้นตอนได้ในระบบเดียว



บรรณานุกรม

ภาษาไทย

บทความ

จันทิมา พลพินิจ, ชุมศักดิ์ สีบุญเรือง, รพีพร ข้าว่อง, อันธรัตน์ ใจติดนอม และสมนึก พ่วงพรพิทักษ์. (2548). “Automated Obscenity Web Sites Filetering System”. **การประชุมวิชาการ สาขาวิชาคอมพิวเตอร์และเทคโนโลยีไทยสู่เศรษฐกิจโลก**, หน้า 325 - 330.

นิเวศ จิระวิชิตชัย, ปริญญา สงวนสัตย์ และ พยุง มีสัจ. (2554). “การพัฒนาประสิทธิภาพการจัดหมวดหมู่เอกสารภาษาไทยแบบอัตโนมัติ”. **วารสารพัฒนบริหารศาสตร์ – ปีที่ 51 ฉบับที่ 3/2554**, หน้า 187-206.

ป.โยธร อุราธรรมกุล และงานค่า รุณนนพวงศ์. (2549). “การปรับปรุงกฎสำหรับตัดคำในเอกสารภาษาไทย”. **The 3rd Joint Conference on Computer Science and Software Engineering (JCSSE 2006)**, หน้า 34-40.

วิทยานิพนธ์

นนท์ บุญนิชิประเสริฐ.(2552). **การกรองข้อความภาษาไทยและภาษาอังกฤษของบริการส่งข้อความสั้นบนเครือข่ายโทรศัพท์เคลื่อนที่**. วิทยานิพนธ์วิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมคอมพิวเตอร์และโทรคมนาคม บัณฑิตวิทยาลัย. กรุงเทพฯ: มหาวิทยาลัยธุรกิจบัณฑิต.

พรพล ธรรมรงค์รัตน์ . (2551). **การจำแนกประเภทเว็บเพจโดยวิธีการลดขนาดลักษณะเฉพาะและซัพพอร์ตเวกเตอร์แมชชีน**. วิทยานิพนธ์วิทยาศาสตรมหาบัณฑิต ภาควิชาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์. สาขาวิชา: มหาวิทยาลัยสงขลานครินทร์. อกิจ/at บ้านทอง, วัลลภา ตันติประสังค์ชัย และ ชุลีรัตน์ จรัสกุลชัย. (2544). **การสรุปใจความสำคัญของเอกสาร**. โครงการวิทยาศาสตรบัณฑิต ภาควิชาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์. กรุงเทพฯ: มหาวิทยาลัยเกษตรศาสตร์ วิทยาเขตบางเขน.

อาริยา เอื้ออภิสิทธิ์วงศ์ . (2549) . การแบ่งประเภทลายนิ้วมือโดยใช้รหัสลายนิ้วมือ.

วิทยานิพนธ์ครุศาสตร์อุดสาหกรรมมหาบัณฑิต สาขาวิชาเทคโนโลยีคอมพิวเตอร์ ภาควิชาคอมพิวเตอร์ศึกษา บัณฑิตวิทยาลัย กรุงเทพฯ: สถาบันเทคโนโลยีพระจอมเกล้าพระนครเหนือ.

สารสนเทศจากสื่ออิเล็กทรอนิกส์

กฎหมายกับความมั่นคงปลอดภัยสารสนเทศ. (2555). สืบค้นเมื่อ มีนาคม 2555,

จาก www.vrhris.com/klc/Article/HR/Manager/Computer Law2550.htm.

ระบบมาตรฐานด้านความปลอดภัยของข้อมูล ISO 27001. (2555). สืบค้นเมื่อ มีนาคม 2555,

จาก www.tuv.com/th/_iso_27001.html.

ระบบการจัดการความปลอดภัยทางข้อมูล ISO27001:2005.(2552). สืบค้นเมื่อ มีนาคม 2555,

จาก <http://itm0052.blogspot.com/2009/02/iso27001bs7799.html>.

ภาษาต่างประเทศ

ARTICLES

DuraiPandian, N., Chellappan, C., Anna Univ. and Madras . (2006). “Dynamic information security level reclassification”. **Wireless and Optical Communications Networks, 2006 IFIP International Conference**, pp.1-3.

Daeseon Choi, Seunghun Jin and Hyunsoo Yoon . (2006). “A Personal Information Leakage Prevention Method on the Internet”. **Consumer Electronics, 2006. ISCE '06. 2006 IEEE Tenth International Symposium**, pp. 646-650.

George Lawton. (2008). “New Technology Prevents Data Leakage”. **IEEE Computer Security September 2008**, pp.14-17.

Gilberto, Pedro, Edmo and Jayme. (2010). “A Security Framework to Protect Against Social Network Services Threats.” **Fifty International Conference on Systems and Networks Communicatoins**, pp. 11-16.

- Hua Zhang, Jun-feng Dial, and Qiao-yan Wen. (2008). "Secure files Management System in Intranet". **2008 International Conference on Internet Computing in Science and Engineering**, pp 306-311.
- Simon Liu, Rick Kuhn . (2010). " Data Loss Prevention". **IT Pro March/April 2010**, Published by the IEEE Computer Society, pp. 10-13.
- Yuguo Wang . (2008). "A Tree-based Multi-class SVM Classifier for Digital Library." **International Conference on MultiMedia and Information Technology**, pp. 15-18.
- Zhang Xiaosong , Liu Fei,Chen Ting and Li Hua . (2009). "Research and Application of the Transparent Data Encryption In Intranet Data Leakage Prevention". **2009 International conference on Computational Intelligence and Security**, pp. 376-379.
- Zhijie Liu, Xueqiang Lv, Kun Liu and Shuicai Shi . (2010). "Study on SVM Compared with the other Text Classification Method". **Information Science and Technology University Beijing China 2010**, pp. 219-222.

ELECTRONIC SOURCES

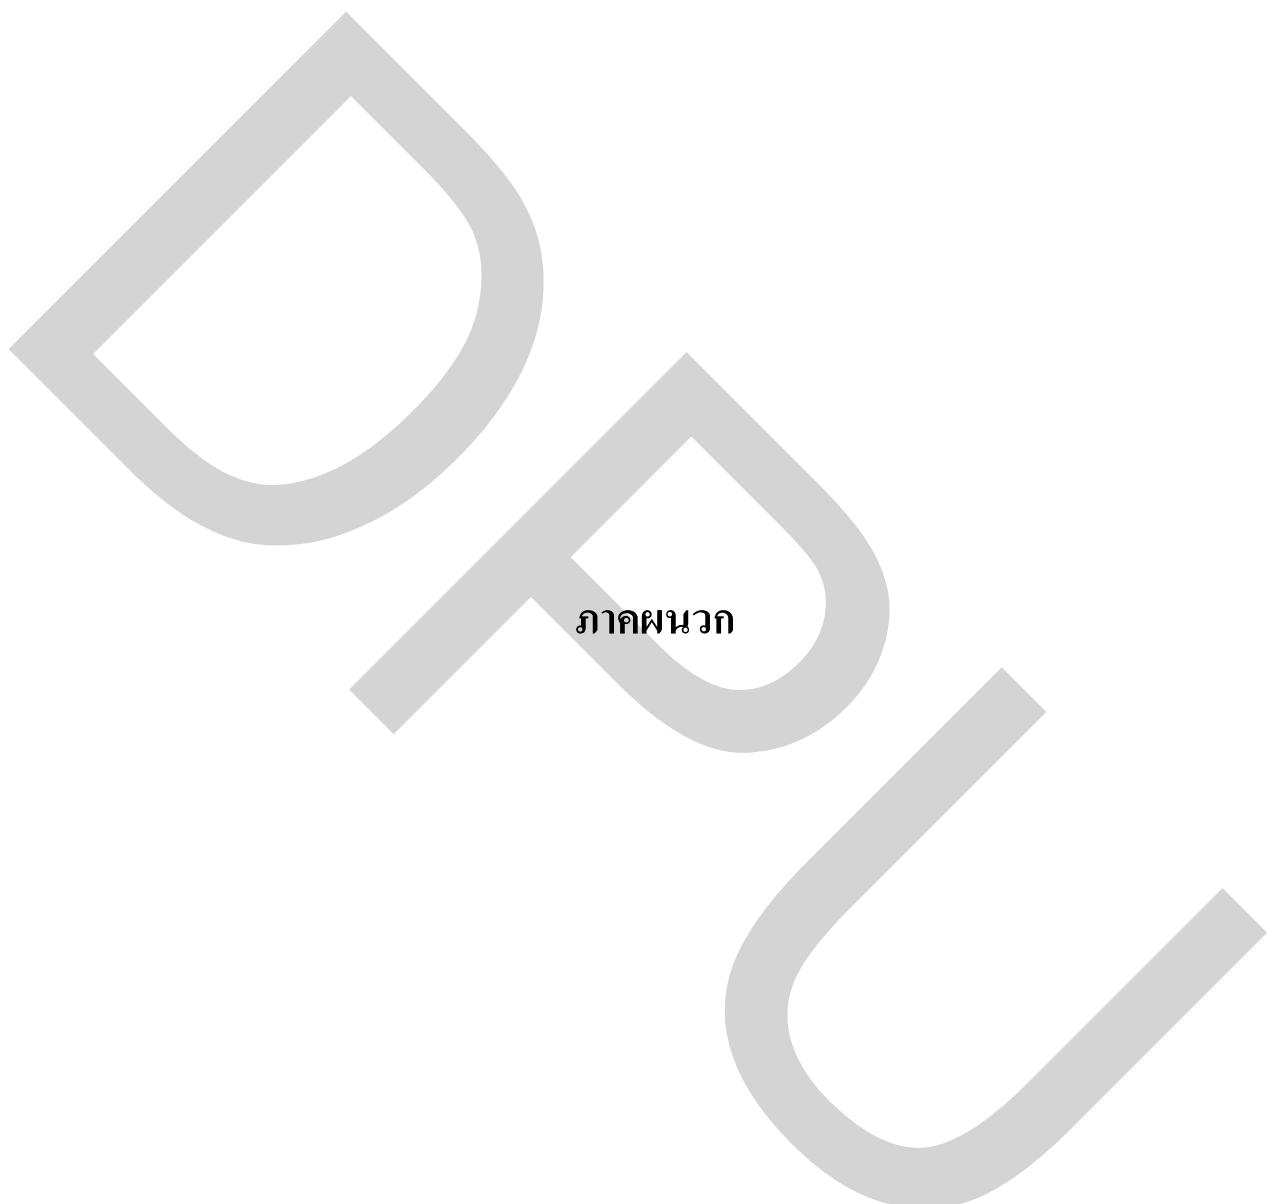
- 7 Step to information Protection 2009. (2010). Symantec;White Paper Data Loss Prevention, Retrieved July 2010, from www.symantec.com.
- Antiword Version 0.37. (2011). Retrieved April 2011, from <http://www.winfield.demon.n>
- Arg max. (2012). Retrieved April 2012, from http://en.wikipedia.org/wiki/Arg_max.
- Binary Search Pseudocode. (2012). Retrieved April 2012, From <http://www.cs.uiuc.edu/class/sp07/cs199lbp/lectures/CS199-Lectures17and18.pdf>.
- Feature map approximation for RBF kernels. (2012). Retrieved March 2012, from <http://scikit-learn.sourceforge.net>.
- ISO/IEC 27001. (2012). Retrieved March 2012, from www.iso27001security.com/html/27001.html.

Kristiaan Pelckmans , Johan A.K. Suykens. (2002). LS-SVMLab : a MATLAB/C toolbox for Least Squares Support Vector Machines, Retrieved July 2010,
from <http://www.esat.kuleuven.be/sista/lssvmlab/>.

LS-SVMLab1.7. (2011). Retrieved April 2011,
from <http://www.esat.kuleuven.ac.be/sista/lssvmlab>.

Software SWATh (Thai Word Segmentation). (2011). Retrieved April 2011,
from <http://www.cs.cmu.edu/paisarn/software.html>.

Symantec Data Loss Prevention Administration Guide Version 10.5. (2010).
Retrieved July 2010, from www.symantec.com.



ໂປຣແກຣມ PHP (ກະບວນກາຮາຄ່ານໍ້າໜັກຄຳ)

//ທຳມອຽນ Input ໄຟລີ່ເອກສາຮ ໂດຍໄສ່ເປັນ Path

```

body{
}

#main{
    width:1000px;
    margin:0 auto 0 auto;
}

#SendingForm {
    width:100%;
    margin:0 auto 0 auto;
}

#result {
    width:100%;
    margin:0 auto 0 auto;
    background-color:#0F0;
}

</style>

<body>

<div id="main">

<div id="SendingForm">

<form enctype="multipart/form-data" action=<?=$PHP_SELF?>" method="post">

<p>

<input type="hidden" name="MAX_FILE_SIZE" value="3000000" />

    URL:
    <input type="text" name="url" size=50 />
    <br />
    <!--<iframe src="swf/upload" width="600" height="300" frameborder="0"></iframe>
-->
    <br />

```

```

Send this file:<!--<br /> <input name="userfile" type="file"/><!--&gt;
&lt;br /&gt;
&lt;input type="submit" value="Send File" /&gt;
&lt;/form&gt;
&lt;/div&gt;
&lt;div id="result"&gt;
&lt;?php
$template = "";
$url = str_replace(" ", "", $_POST['url']);
if ($url != ""){ //Open images directory
    $dir = opendir($url); //List files in images directory
    $i = 0;
    $tmpdir = $url."\\tmp";
    if (! file_exists($tmpdir) ) {
        mkdir($tmpdir);
    }
    while ( ( $file = readdir($dir) ) !== false ){ //
        if ( strpos($file,".doc") ) {
            echo "filename[". $i++. "]: " . iconv("TIS-620", "UTF-8",$file) . "&lt;br
/&gt;";
            $newfile = Date("dmy_His");
            if ( !copy($url."\\\".$file,$tmpdir."\\\".$newfile) ) {
                echo "failed to copy $file...\n";
            }
            $newdata[$i-1] = antiword($tmpdir,$newfile,$i-1);
        }
    }
    $Tr = $i;
}
</pre>

```

```

// กระบวนการหาราค่านำหน้าหักคำ
$num_vectors = sizeof($template[0]);
echo "<table border=\"1\" width=\"100%\">";
echo "<tr>";
for ($k=0;$k<$num_vectors;$k++)
{
    echo "<td>".$template[0][$k]."</td>";
}
echo "</tr>";
echo "<tr>";
for ($k=0;$k<$num_vectors;$k++)
{
    echo "<td><ul>";
    for ($j=0;$j<$Tr;$j++)
    {
        $position = array_search($template[0][$k],$newdata[$j][0]);
        if ($position !== false)
        {
            $Tr_tk = $template[1][$k];
            $tk_dj = $newdata[$j][1][$position];
            $cal_tmp = log10($Tr/$Tr_tk);
            $w[$k][$j] = $tk_dj * $cal_tmp;
        } else
        {
            $Tr_tk = 0;
            $tk_dj = 0;
            $w[$k][$j] = 0;
        }
        echo "<li>".round($w[$k][$j],2)."</li>";
    }
}

```

```

echo "</ul></td>";
}

echo "</tr>";
echo "</table>";
}

else {
if (isset($_FILES['userfile']['name'])) {

$uploadaddir = 'tmp\\';
$upload_file = $uploadaddir . (Date("dmy_His"));
$userfile = $_FILES['userfile']['name'];
if (move_uploaded_file($_FILES['userfile']['tmp_name'],$upload_file)) {
antiword($upload_file);
}
}
}

?>

</div>
</div>
</body>
</html>

//เรียกใช้โปรแกรมย่ออย Antiword (อ่านคำจากไฟล์เอกสาร Microsoft words)

<?

function antiword($dir,$upload_file,$round)
{
$fileread = $dir."\\\".$upload_file;
$filetext = $dir."\\\".$upload_file.".txt";
$command="C:/antiword/antiword -m UTF-8.txt $fileread > $filetext";
exec($command,$error);
if (!$error)
{
}
}

```

```

    $output = swath($filetext,$dir,$round);
}

else die("<BR>ERROR Read Document<BR>");

return $output;
}

?>
//เรียกใช้โปรแกรมย่อ SWATH ตัดคำภาษาไทย และภาษาอังกฤษ
<?

function swath($input_filename , $dir, $round){

echo "<h1>TEST</h1>";

$input_filename = $input_filename;

$output_filename= tempnam($dir, "swath");

$input_text = file_get_contents($input_filename);

$input_text = str_replace("[", "", str_replace("]", "", $input_text));

$input_text = str_replace("~", "", $input_text);

$per = 100;

$txt = split("\r\n", $input_text);

$div = sizeof($txt);

$input_text_tis620 = "";

for ($i=0;$i<$div+1;$i++){

$tmp = $txt[$i];

$input_text_tis620 .= iconv("UTF-8", "TIS-620", $tmp);

}

file_put_contents($input_filename, $input_text_tis620);

$ourFileHandle = fopen($output_filename, 'w') or die("can't open file");

fclose($ourFileHandle); //if ($round == 0)

$cmd = "cd\ && cd C:\AppServ\www\Poi\mail_swath\Swath-2.0 && swath -m bi
<$input_filename> $output_filename";

$cmd = "cd\ && cd C:\AppServ\www\Poi\mail_swath\Swath-2.0 && swath -m bi
<$input_filename> $output_filename";
}

```

```

$rtn = null;
exec($cmd,$rtn);
if(!$rtn){
    /*$data{text = "";
    $f = fopen($output_filename,"r") or die("Error can not open file $file");
    while (!feof($f)){${data:text.=fgetc($f);}
    fclose($f);*/
        $raw = file_get_contents($output_filename);      //echo $raw;
        $raw_utf8 = iconv("TIS-620", "UTF-8", $raw);   //echo $raw_utf8;
    }else{
        die("error");
    }
}

$data = preg_split('/\|/', $raw_utf8);
$newdata = removeStopword($data,$round);
return $newdata;
}

function removeStopword($data,$round)      //Remove Stop Words
{
    global $template;
    $stop_phrase = array (_____); //ใส่คำที่ต้องการให้ตัด
    $pass_phrase = "/[ก-๛າ-zA-Z]/";
    $counts = array_count_values($data);
    arsort($counts);
    $i =0;
    #$echo = "";
}

```

```

//แสดงความถี่ของคำ และตารางคำนำหน้าคำ
foreach($counts as $key => $value)
    if (str_replace("", "", $key) && str_replace("\r\n", "", $key) &&
        preg_match($pass_phrase, $key) && !in_array($key, $stop_phrase) ) {
        $echo .= '$key.' --> '$value.' <br>;
        $new_data[0][$i] = $key;
        $new_data[1][$i] = $value;
        if ($round != 0){
            $position = array_search($key, $template[0]) ;
            if ( $position !== false ){
                $template[0][$position] = $template[0][$position]++;
            } else{
                $template[0][sizeof($template[0])] = $key;
                $template[1][sizeof($template[0])] = 1;
            }
        }
        else{
            $template[0][$i] = $key;
            $template[1][$i] = 1;
        }
        $i++;
    }
}
echo " มีจำนวนคำทั้งหมด ". $i."<br>".$echo;
return $new_data;
}
?>

```

แสดงคำหยุดที่ถูกใช้ในขั้นตอนกำจัดคำหยุด

"พหล","รับ","รวม","หัก","งฝบบ","สนับสนุน","เหมาะสม","ไม่","ลูก","ตนเอง","เขียน","เปลี่ยน",
 "รองรับ","ข้อ","ท้าย","ค่า","ต้อ","เลย","ตั้งแต่","ต้น","สาย","แต่ละ","เพียงพอ","ชอบ","กิจ",
 "งๆ","ลูก","จำ","สะดาวก","ยินดี","ใจ","กอก","ทอยอย","ต่างๆ","อือ","เชื่อมต่อ","พริ้ง","บบๆ",
 "ษทฯ","กะ","เท","ลลินท","ง่าย","ดังนั้น","ชับซ้อน","ยุ่งยาก","บเต","เม","สน","ເສ","รด","ໂປ",
 "สะดาวก","คร","บัง","กระ","ې","คີ","เกรດ","ตัด","ທາ","กร","ໂກ","ວວอรີ","ຄາ","ບຸນ","ກາ","ອາ",
 "ງູ","ໜຶນ","ລຳ","ໄອ","ໂກ","ມອດລົດ","ງູ","ສນິຫ","ທີພຍ","ຟື","ຍື້","ຍານ","ກອ","ວັຕຣ","ຍດ","ຄຄໂດ",
 "ຢຸ່ງ","ຍຄື","ຮົກວິນ","ຈຸ","ຈາມ","ນິ້ມ","ຄໂນາ","ແປ","ຮຸກ","ຈອ","ຮຈິວລວ","ຮີ","ໄຊ","ເລີ່ມ","ໝາ",
 "ຮ້ານ","ນວ","ເວວິນ","ໂອ","ມວິວົກ","ໂຄ","ຝີ່ຍ","ນັດ","ຮພ","ມັນ","ຄະ","ອີ","ເອສພ","ປິ້ງ","ແຮ",
 "ອິມ","ເບີ້ງ","ຍໂບນີ","ສາວ","ວຸດາ","ຍອ","ກຸມ","ອນຸ","ເວສ","ສັນ","ຍໂຣ","ໂນ","ໂໃຊ","ຍູ້","ຮັດ","ນກວ",
 "ຍຈາ","ເບີ້ງ","ນານາ","ໜອ","ສານ","ກຸດາ","ຮັດນີ","ພັດດ","ມັຍ","ຮາງ","ເຄີ່ງ","ຍບີ່ຍື","ອົງ","ດອນ","ເທ",
 "ໜຶນ","ເອກ","ລູກ","ທີພຍ","ຟື","ຄຽວ","ຮັດ","ເພດ","ພັດນີ","ໂພ","ໄທ","ນຫວ","ສີ","ຍດ","ເບີ້ງ","ຮັດ",
 "ຍຈາ","ກຸດາ","ມັຍ","ເຫ","ດຸ","ຍເສ","ເຈົ້າ","ນີ","ສຽງ","ຮັບ","ຈຸ","ລາ","ຈອ","ອົງ","ຍມ","ຄະ",
 "ຄວບ","ຄະ","ຄົດ","ມັວ","ເລັນ","ອາຈ","ອາຍ","ເອາໄຈ","ນີ","ກຳດຳ","ດະ","ມັນ","ທັນ","ຍິງ","ຫດ","ຕ່ອ",
 "ອາຈ","ກຳດຳວາ","ນໍາ","ກາ","ເທົ່າ","ນຮຣມ","ອາ","ນອກ","ພທະ","ຕົວ","ພັນຫຼື","ໄດ້","ມັກ","ນານ",
 "ເພິ່ງ","ທັນ","ຄາດ","ໃໝ່","ສິງຫຼື","ຮະຫວ່າງ","ນາງສາວ","ພກ","ບຮຣຍາຍ","ພວິມກັບ","ກຮອກ",}

โปรแกรม MATLAB เรียกใช้โปรแกรมย้อม LS-SVM

```
X = load('_____ .txt'); //ເອກສາຮູດຝຶກສອນ
Y = load('_____ .txt'); //ຄລາສຂອງເອກສາຮູດຝຶກສອນ
type='classification';
plotlssvm({X,Y,type,gam,sig2,'RBF_kernel'}, {alpha,b}); //ພຶດຕອກຮັບພຶດຕູກສອນ
Xt=load('_____ .txt'); //ເອກສາຮູດທດສອນ
Yt=simlssvm({X,Y,type,gam,sig2,'RBF_kernel'}, {alpha,b},Xt); //ປະມາວລຸດການແຍກປະເກດ
plotlssvm({Xt,Yt,type,gam,sig2,'RBF_kernel'}, {alpha,b}); //ພຶດຕອກຮັບພຶດຕູກສອນ
```

แสดงค่าคุณลักษณะสำคัญ (Feature)

จำนวนคุณลักษณะสำคัญ

10 Feature = {โปรแกรม สาขา SAP สารสนเทศ ศทส ประวัติ พาณิชย์ หน้าจอ ส่งเสริม เงื่อนไข}

20 Feature = {งบประมาณ เปิก เอกสาร ฝบบ เห็นชอบ โปรแกรม สาขา SAP สารสนเทศ ศทส
ทีม อนาคต หมอ ลงทุน เทคนิค ประวัติ พาณิชย์ หน้าจอ ส่งเสริม เงื่อนไข;

30 Feature = {ดำเนินการ พิจารณา ฝปค เทคโนโลยี แจ้ง โปรแกรม สาขา SAP สารสนเทศ ศทส
เมือง ข้าว ระดับ พื้นที่ ป่วย ทีม อนาคต หมอ ลงทุน เทคนิค ประวัติ พาณิชย์ หน้าจอ ส่งเสริม
เงื่อนไข}

40 Feature = {หน่วยงาน ข้อความ บันทึก กอง ผอ งบประมาณ เปิก เอกสาร ฝบบ เห็นชอบ
โปรแกรม สาขา SAP สารสนเทศ ศทส ทำงาน ปัญหา วิธี มือ ไทย เมือง ข้าว ระดับ พื้นที่ ป่วย ทีม
อนาคต หมอ ลงทุน เทคนิค ประวัติ พาณิชย์ หน้าจอ ส่งเสริม เงื่อนไข}

ประวัติผู้เขียน

