

การประเมินประสิทธิภาพระบบคัดกรองอีเมลขยะโดยเจ้าของอีเมล

นายอรรถกร องค์ศิริพร

ศูนย์วิทยทรัพยากร จุฬาลงกรณ์มหาวิทยาลัย

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตร์มหาบัณฑิต

สาขาวิชาวิทยาศาสตร์คอมพิวเตอร์ ภาควิชาวิศวกรรมคอมพิวเตอร์

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

ปีการศึกษา 2552

ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

PERFORMANCE EVALUATION OF SPAM FILTER BY E-MAIL OWNERS

Mr. Athakorn Ongsiriporn

ศูนย์วิทยทรัพยากร
จุฬาลงกรณ์มหาวิทยาลัย
A Thesis Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Science Program in Computer Science

Department of Computer Engineering

Faculty of Engineering

Chulalongkorn University

Academic Year 2009

Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์ การประเมินประสิทธิภาพระบบคัดกรองอีเมลขยะโดย
เจ้าของอีเมล
โดย นายอรวรรถ คงศิริพง
สาขาวิชา วิทยาศาสตร์คอมพิวเตอร์
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก อาจารย์ ดร.ยรวรยง เต็งอำนวย

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้นับวิทยานิพนธ์ฉบับนี้เป็นส่วน
หนึ่งของการศึกษาตามหลักสูตรปริญญามหาบัณฑิต

..... คณบดีคณะวิศวกรรมศาสตร์
(รองศาสตราจารย์ ดร.บุญสม เลิศหรรษ์วงศ์)

คณะกรรมการสอบวิทยานิพนธ์

..... ประธานกรรมการ
(อาจารย์ จาจุมาตรา ปันทอง)

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก
(อาจารย์ ดร.ยรวรยง เต็งอำนวย)

..... กรรมการ
(อาจารย์ ดร.เกริก กิริมย์โสภาค)

..... กรรมการภายนอกมหาวิทยาลัย
(ดร.โกเมน พิบูลย์โภจน์)

ขอรับรอง ของศิริพงษ์ : การประเมินประสิทธิภาพระบบคัดกรองอีเมลขยายโดยเจ้าของอีเมล.
 (PERFORMANCE EVALUATION OF SPAM FILTER BY E-MAIL OWNERS) อ.ที่
 ปรีกษาวิทยานิพนธ์หลัก : อ.ดร.ยรวร阳 เต็งจันวย, 41 หน้า.

การประเมินประสิทธิภาพระบบคัดกรองอีเมลขยายเป็นกระบวนการที่สำคัญ โดยผลการประเมินใช้สำหรับเบรี่ยนเพื่อเลือกใช้ และเป็นแนวทางในการพัฒนาประสิทธิภาพของระบบคัดกรองอีเมลขยาย ปัจจุบันการประเมินมิได้ทำในสภาพแวดล้อมที่ใกล้เคียงกับความเป็นจริง ผู้ใช้งานไม่มีส่วนร่วมในกระบวนการประเมิน อีกทั้งมีปัญหาความเป็นส่วนตัว ทำให้ผลการประเมินไม่สอดคล้องกับความเป็นจริง งานวิจัยนี้นำเสนอกระบวนการวิธีสำหรับประเมินประสิทธิภาพระบบคัดกรองอีเมลขยาย ในสภาพแวดล้อมที่ใกล้เคียงกับความเป็นจริง ให้อีเมลจริงจากองค์กร เป็นอย่างมาก และผู้ใช้งานจะเป็นอาสาสมัครในกระบวนการประเมินเพื่อหลีกเลี่ยงการละเมิดความเป็นส่วนตัว กระบวนการวิธีนี้ใช้การสุ่มตัวอย่างอีเมลเพื่อทดลองงานของอาสาสมัคร บุกเบิกให้ใช้งานได้ง่ายและมีค่าใช้จ่ายต่ำ โดยมีสมมติฐานว่าอาสาสมัครเป็นระบบคัดกรองในอุดมคติซึ่งคัดกรองอีเมลได้ถูกต้องเสมอ ผลการทดลองบ่งชี้ว่ากระบวนการวิธีนี้สามารถประเมินประสิทธิภาพของระบบคัดกรองอีเมลขยายได้เป็นอย่างดี และอาสาสมัครตอบรับเข้าร่วมกระบวนการประเมินอย่างรวดเร็ว

ศูนย์วิทยทรัพยากร จุฬาลงกรณ์มหาวิทยาลัย

ภาควิชา วิศวกรรมคอมพิวเตอร์ ลายมือชื่อนิสิต _____
 สาขาวิชา วิทยาศาสตร์คอมพิวเตอร์ ลายมือชื่อ อ.ที่ปรีกษาวิทยานิพนธ์หลัก _____
 ปีการศึกษา 2552

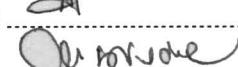
5071458921 : MAJOR COMPUTER SCIENCE

KEYWORDS : SPAM / FILTER / EVALUATION / MANUAL / PRIVACY

ATHAKORN ONGSIRIPORN: PERFORMANCE EVALUATION OF SPAM
FILTER BY E-MAIL OWNERS. THESIS ADVISOR: YUNYONG TENG-
AMNUAY, Ph.D., 41 pp.

Performance evaluation of spam filter is an important process for choosing and improvement of spam filter. Nowadays, the evaluation does not based on realistic environment. Users do not participate in the process and privacy problems are always encountered. In this research, we propose a framework which evaluate in realistic environment. The framework uses a corpus of real e-mails. Users are volunteers who evaluate their e-mails without privacy problems. This is an ease of use and cheap framework. It uses a sampling method for reducing volunteers' jobs. Volunteers in this framework are an ideal spam filter which always gives correct classification. The result show a capability of this framework for spam filters evaluation and volunteer have quick response to our process.

ศูนย์วิทยทรัพยากร จุฬาลงกรณ์มหาวิทยาลัย

Department : Computer Engineering Student's Signature 
Field of Study : Computer Science Advisor's Signature 
Academic Year : 2009

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงได้ด้วยดี เนื่องมาจากความช่วยเหลืออย่างดียิ่ง
ของอาจารย์ ดร.ยรวรรณ เต็งคำนวย อาจารย์ที่ปรึกษาวิทยานิพนธ์ ที่ได้สละเวลาให้คำปรึกษา^๑
แนะนำแนวทางและการแก้ปัญหาต่างๆ เกี่ยวกับงานวิจัยอย่างดีตลอดมานานเสร็จสมบูรณ์
ตลอดจนคำปรึกษาคำแนะนำข้อคิดสำหรับการดำเนินชีวิตต่อไปในอนาคต และผู้วิจัยขอกราบ
ขอบพระคุณ อาจารย์จารุมาตรา ปืนทอง อาจารย์ ดร.เกริก ภิรมย์สถาpa และดร.โภเมน พิบูลย์ใจเจ^๒
คณะกรรมการสอบวิทยานิพนธ์ทุกท่านที่ได้ให้คำแนะนำ ข้อคิดเห็น ข้อเสนอแนะ และแนวทางใน
การพัฒนางานวิจัยนี้ให้สมบูรณ์ยิ่งขึ้น และขอบพระคุณคณาจารย์ทุกท่านที่กรุณาประสิทธิ
ประสาทวิชาความรู้อันมีคุณค่ายิ่งแก่ผู้วิจัย

ขอขอบพระคุณ คุณชนยา ลิมจิตติ คุณปณิตา บุญมา แห่งสำนักงานเทคโนโลยี
สารสนเทศ จุฬาลงกรณ์มหาวิทยาลัย ที่ให้ความช่วยเหลือในการเก็บรวบรวมข้อมูลในการทำวิจัย
และคำนวณความสอดคล้องในการทำวิจัยในครั้งนี้

ขอขอบคุณเพื่อนๆ และพี่ๆ ทุกคนที่ให้คำปรึกษา ให้กำลังใจ ข้อคิดเห็น และ
แนวคิดที่ดีทุกๆ ด้าน โดยเฉพาะอย่างยิ่ง คุณอรจิรา จริงจิตรา ที่ให้กำลังใจ และช่วยเหลือในการ
ทำงานวิจัยนี้

ท้ายนี้ขอขอบพระคุณ คุณพ่อ คุณแม่ ที่ให้การสนับสนุนและเอื้อ貸ผู้วิจัย
เป็นอย่างดี ตลอดจนเป็นกำลังใจให้สามารถทำงานวิจัยนี้สำเร็จลุล่วงได้ด้วยดี

**ศูนย์วิทยทรัพยากร
จุฬาลงกรณ์มหาวิทยาลัย**

สารบัญ

	หน้า
บทคัดย่อภาษาไทย	๗
บทคัดย่อภาษาอังกฤษ	๘
กิตติกรรมประกาศ.....	๙
สารบัญ	๙
บทที่ 1 บทนำ.....	1
1.1 ความเป็นมาและความสำคัญของปัญหา	1
1.2 วัตถุประสงค์ของการวิจัย.....	1
1.3 ขอบเขตของการวิจัย	1
1.4 ขั้นตอนของการวิจัย	2
1.5 ประโยชน์ที่คาดว่าจะได้รับ.....	2
1.6 โครงสร้างของวิทยานิพนธ์	3
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง	4
2.1 อีเมลขยะ	4
2.2 การป้องกันอีเมลขยะ.....	5
2.3 ความเป็นส่วนตัวของอีเมล	6
บทที่ 3 วิธีดำเนินการวิจัย.....	7
3.1 ศึกษาระบบอีเมลปัจจุบันขององค์กรเป้าหมาย.....	8
3.1.1 ระบบอีเมลของจุฬาลงกรณ์มหาวิทยาลัย.....	8
3.1.2 อีเมลแอดเดรสของผู้ใช้งาน	10
3.2 รวมรวมและวิเคราะห์คลังอีเมล.....	10
3.3 คัดเลือกอาสาสมัคร	12
3.3.1 ตรวจสอบผลการคัดกรองของระบบคัดกรองที่ต้องการประเมิน	
3.3.2 คัดกรองกลุ่มตัวอย่างอีเมลที่สูญจากคลังอีเมล.....	12
3.4 เตรียมระบบคัดกรองที่ต้องการประเมินประสิทธิภาพ.....	13
3.5 สร้างระบบคัดกรองอ้างอิงจากงานวิจัย.....	14
3.5.1 ศึกษางานวิจัยเกี่ยวกับอีเมลขยะ	14
3.5.2 สร้างระบบคัดกรองอ้างอิง	14

บทที่	หน้า
3.6 ปัจฉนคลังอีเมลผ่านระบบคัดกรองที่ต้องการประเมินประสิทธิภาพ	15
3.7 ติดต่อกลุ่มอาสาสมัคร	16
3.8 สุมอีเมลของอาสาสมัครแต่ละคนและประเมินอีเมลของตนด้วยตา	20
3.9 วิเคราะห์และสรุปผลการประเมินประสิทธิภาพ	22
3.9.1 ประสิทธิภาพโดยรวมของระบบคัดกรอง	23
3.9.2 การวิเคราะห์จุดแข็งและจุดด้อยของระบบคัดกรอง	24
บทที่ 4 ผลการวิจัย	25
4.1 ผลการรับรวมและวิเคราะห์คลังอีเมลและการคัดเลือกอาสาสมัคร	25
4.2 ผลการคัดกรองโดยระบบคัดกรอง	27
4.3 ผลการประเมินอีเมลของตนด้วยตาของอาสาสมัคร	28
4.4 ผลการวิเคราะห์และเปรียบเทียบประสิทธิภาพระบบคัดกรองอีเมลขยะ	30
4.4.1 ประสิทธิภาพโดยรวมของระบบคัดกรอง	32
4.4.2 การวิเคราะห์จุดแข็งและจุดด้อยของระบบคัดกรอง	32
บทที่ 5 สรุปผลการวิจัยและข้อเสนอแนะ	34
5.1 สรุปผลการวิจัย	34
5.2 ปัญหาและข้อเสนอแนะ	34
5.3 งานวิจัยในอนาคต	36
รายการอ้างอิง	37
ภาคผนวก	39
ค่ามาตรฐานของโปรแกรมสแปมแอกซ์แซฟชัน	40
ประวัติผู้เขียนวิทยานิพนธ์	41

จุฬาลงกรณ์มหาวิทยาลัย

สารบัญตาราง

ตารางที่ 3.1	รายละเอียดซอฟต์แวร์ของระบบคัดกรองข้างอิง	14
ตารางที่ 3.2	ตู้จดหมายปลายทางที่ผ่านการระบบคัดกรองประเภทต่างๆ.....	15
ตารางที่ 3.3	กำหนดความหมายของผลการคัดกรอง.....	22
ตารางที่ 3.4	ความหมายทางภาษาของผลการคัดกรอง	22
ตารางที่ 4.1	รายละเอียดของคลังอีเมล	26
ตารางที่ 4.2	ตารางเจกแจงความถี่ของปริมาณอีเมลเข้า	26
ตารางที่ 4.3	ผลการคัดกรองของระบบคัดกรองอีเมลขยะ	28
ตารางที่ 4.4	ผลการติดต่ออาสาสมัคร.....	28
ตารางที่ 4.5	รายละเอียดของการประเมินด้วยตาของอาสาสมัคร.....	29
ตารางที่ 4.6	ผลการคัดกรองตัวอย่างอีเมลของอาสาสมัคร	29
ตารางที่ 4.7	ตารางค่อนติงเจนซีของแต่ละระบบคัดกรองอีเมลขยะ	30
ตารางที่ 4.8	ค่า FPR และ TPR ของแต่ละระบบคัดกรอง	30
ตารางที่ 4.9	ค่า AUC ของแต่ละระบบคัดกรอง	32
ตารางที่ 4.10	สรุปผลการประเมินประสิทธิภาพ.....	33

**ศูนย์วิทยทรัพยากร
จุฬาลงกรณ์มหาวิทยาลัย**

สารบัญภาพ

รูปที่ 3.1	ภาพรวมของระบบประมีนประสิทธิภาพ	7
รูปที่ 3.2	ระบบอีเมลขณะเริ่มวิจัยของจุฬาลงกรณ์มหาวิทยาลัย	8
รูปที่ 3.3	ระบบอีเมลใหม่ของจุฬาลงกรณ์มหาวิทยาลัย	9
รูปที่ 3.4	การนับจำนวนอีเมลของผู้ใช้แต่ละคน	11
รูปที่ 3.5	การเชื่อมต่อของคอมพิวเตอร์เพื่อป้อนคลังอีเมลผ่านระบบคัดกรอง	15
รูปที่ 3.6	การป้อนคลังอีเมลผ่านระบบคัดกรองที่มาทดสอบ	16
รูปที่ 3.7	ตัวอย่างจดหมายข้อความว่ามีอีก	18
รูปที่ 3.8	ตัวอย่างจดหมายตอบกลับจากระบบ	19
รูปที่ 3.9	การเข้าร่วมงานวิจัยของอาสาสมัคร	19
รูปที่ 3.10	ตัวอย่างหน้าจอสำหรับประมีนอีเมลของตนด้วยตา	21
รูปที่ 3.11	พื้นที่ใต้แผนภูมิ ROC	23
รูปที่ 4.1	แผนภูมิ ROC ของการประมีนประสิทธิภาพระบบคัดกรองอีเมลขยะ	31
รูปที่ 4.2	แผนภูมิ ROC ของการประมีนสำหรับคำนวนค่า AUC	31

**ศูนย์วิทยทรัพยากร
จุฬาลงกรณ์มหาวิทยาลัย**

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

อีเมลขยะเป็นปัญหาที่สำคัญของระบบเครือข่ายคอมพิวเตอร์ เนื่องจากสัดส่วนของอีเมลขยะคิดเป็นร้อยละ 85.9 [1] ของปริมาณอีเมลทั้งหมด และจะเพิ่มเป็นร้อยละ 95 ในปี 2015 [2] ทำให้สิ้นเปลืองทรัพยากรของระบบเครือข่ายจำนวนมากและสร้างปัญหาแก่ผู้ใช้ การป้องกันอีเมลขยะโดยทั่วไปจะใช้วิธีคัดกรอง (filter) ทั้งการคัดกรองที่เครื่องแม่ข่าย และเครื่องคอมพิวเตอร์ส่วนบุคคล โดยถูกปรับปุ่นและพัฒนาอย่างต่อเนื่องเพื่อให้สามารถคัดกรองอีเมลขยะได้อย่างมีประสิทธิภาพและทันต่อการคัดกรองอีเมลขยะรูปแบบใหม่ๆ [3]

การประเมินประสิทธิภาพระบบคัดกรองมีความสำคัญสำหรับกำหนดแนวทางในการปรับปุ่นและพัฒนา แต่ในปัจจุบันวิธีการประเมินยังห่างไกลจากสภาพความเป็นจริง [3] [4] [5] [6] [7] [8] เนื่องจากคลังอีเมลที่ใช้ในการทดสอบมิได้มาจากระบบเครือข่ายที่ใช้งานจริงขององค์กรเป้าหมาย รูปแบบของอีเมลที่ผ่านเข้ามายังระบบเป้าหมายอาจมีความแตกต่างจากคลังอีเมลจากแหล่งอื่นที่นำมาทดสอบ และผู้ใช้งานในระบบก็มิได้มีส่วนในการประเมิน รวมถึงมิได้มีความสัมพันธ์กับคลังอีเมลที่ใช้ทดสอบ ผลการประเมินที่ได้จะไม่ใช่ผลที่ได้จากการณ์การทำงานจริงของระบบคัดกรองนั้นๆ

งานวิจัยนี้จึงเสนอกระบวนการวิธีสำหรับประเมินระบบคัดกรองอีเมลขยะ โดยใช้กลุ่มอีเมลจริงจากองค์กรที่เป็นสถาบันการศึกษาขนาดใหญ่ มีผู้ใช้งานจำนวนมาก และให้เจ้าของอีเมลมีส่วนร่วมในขั้นตอนการประเมิน เพื่อที่จะมีละเมิดความเป็นส่วนตัวของผู้ใช้งาน

1.2 วัตถุประสงค์ของการวิจัย

เพื่อออกแบบกระบวนการวิธีสำหรับประเมินประสิทธิภาพของระบบคัดกรองอีเมลขยะที่เครื่องแม่ข่าย โดยอาศัยเจ้าของอีเมลที่ใช้งานจริงในระบบโดยไม่มีละเมิดความเป็นส่วนตัว

1.3 ขอบเขตของการวิจัย

- 1.3.1 ออกแบบกระบวนการวิธีสำหรับประเมินประสิทธิภาพระบบคัดกรองอีเมลขยะ
- 1.3.2 สามารถประเมินประสิทธิภาพได้แม่ระบบคัดกรองเพียงระบบเดียว
- 1.3.3 ประเมินเฉพาะระบบคัดกรองอีเมลขยะที่ทำงานบนเครื่องแม่ข่าย

1.3.4 ใช้ข้อมูลจากมหาวิทยาลัยในประเทศไทย โดยมี นิสิต นักศึกษา และบุคลากร ไม่ต่ำกว่า 30,000 คน เช่น จุฬาลงกรณ์มหาวิทยาลัย

1.3.5 กลุ่มอาสาสมัครเป็นกลุ่มบุคลากรในจุฬาลงกรณ์มหาวิทยาลัย

1.3.6 แยกแยกกลุ่มอาสาสมัครตามประเภทของผู้ใช้ เช่น คณาจารย์ เจ้าหน้าที่ นิสิต ระดับปริญญาตรี ปริญญาโท และปริญญาเอก

1.3.7 ใช้วิธีของ ท่าโธ ยามานเ [9] กำหนดขนาดตัวอย่างอีเมล

1.3.8 การประเมินอีเมลด้วยตาของอาสาสมัครไม่มีความผิดพลาด และยอมรับในวิจารณญาณของการประเมินด้วยตาของอาสาสมัคร

1.3.9 กระบวนการคัดกรองอีเมลแต่ละฉบับด้วยตานั้นให้สามารถเปิดอ่านได้เฉพาะเจ้าของเท่านั้น

1.4 ขั้นตอนของการวิจัย

1.4.1 ศึกษาวิธีการประเมินระบบคัดกรองอีเมลขยะ

1.4.2 ศึกษาวิธีคัดกรองอีเมลขยะจากการงานวิจัย และวิธีที่ใช้งานอย่างแพร่หลายในปัจจุบัน

1.4.3 ออกแบบกระบวนการวิธีประเมินระบบคัดกรองอีเมลขยะที่ใช้กลุ่มอีเมลของกลุ่มอาสาสมัครที่ใช้งานระบบเป้าหมาย

1.4.4 สร้างระบบคัดกรองอีเมลขยะอ้างอิง

1.4.5 สร้างระบบประเมินระบบคัดกรองอีเมลขยะโดยใช้กลุ่มอีเมลของกลุ่มอาสาสมัครที่ใช้งานระบบเป้าหมาย

1.4.6 ทดสอบวิธีการประเมินระบบคัดกรองอีเมลขยะกับระบบคัดกรองที่ใช้งานปัจจุบัน ระบบคัดกรองเก่า และระบบคัดกรองอ้างอิง

1.4.7 วิเคราะห์ผลการประเมิน

1.4.8 สรุปผลและเรียบเรียงวิทยานิพนธ์

1.5 ประโยชน์ที่คาดว่าจะได้รับ

1.5.1 เป็นเครื่องมือสำหรับผู้ดูแลระบบ และองค์กร ในการประเมินประสิทธิภาพระบบคัดกรองอีเมลขยะ

1.5.2 สร้างความมั่นใจให้กับผลการประเมินระบบคัดกรองอีเมลขยะ เนื่องจากใช้ข้อมูลจริงและผู้ใช้งานระบบมีส่วนร่วมในการประเมิน

1.5.3 ลดค่าใช้จ่าย และความเสี่ยงให้กับองค์กรในการตัดสินใจเลือกซื้อ และเลือกใช้งานระบบคัดกรองอีเมลขยะ

1.5.4 เป็นระบบที่ใช้งานได้ง่าย มีค่าใช้จ่ายที่ต่ำ และไม่ต้องใช้เจ้าหน้าที่เทคนิค ทำให้สามารถประเมินได้ป้อยครึ่งตามต้องการ

1.5.5 รักษาความเป็นส่วนตัวของผู้ใช้

1.5.6 การประเมินได้ป้อยทำให้สามารถปรับตามความต้องการและความสนใจของผู้ใช้งานที่เปลี่ยนไปได้

1.5.7 ผลการประเมินให้เป็นแนวทางสำหรับผู้ดูแลระบบในการปรับปรุง พัฒนาระบบคัดกรอง และสามารถใช้เป็นตัวชี้วัดระดับของวิจารณญาณในเรื่องอีเมลขยะของผู้ใช้งานในองค์กรได้ด้วย

1.6 โครงสร้างของวิทยานิพนธ์

เนื้อหาของวิทยานิพนธ์ฉบับนี้แบ่งออกเป็น 5 บทดังนี้ คือ บทที่ 1 เป็นบทนำของงานวิจัย บทที่ 2 กล่าวถึงทฤษฎีและงานวิจัยที่เกี่ยวข้องกับงานวิจัยชิ้นนี้ บทที่ 3 กล่าวถึงวิธีการดำเนินงานวิจัยในแต่ละขั้นตอนอย่างละเอียด บทที่ 4 เป็นการอธิบายผลการทดลอง และบทที่ 5 เป็นการสรุปผลการทดลองและข้อเสนอแนะจากงานวิจัย ซึ่งอาจเป็นประโยชน์กับการวิจัยเพิ่มเติมในอนาคต

**ศูนย์วิทยทรัพยากร
จุฬาลงกรณ์มหาวิทยาลัย**

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 อีเมลขยะ

สันนิษฐานว่า คำว่า “สแปม (Spam)” มาจากละครสั้นทางโทรทัศน์ชื่อ Monty Python's Flying Circus ซึ่งมีการร้องประسانเสียงคำว่า S-P-A-M ซ้ำไปซ้ำมาและร้องดังทำให้ไม่สามารถได้ยินบทสนทนากันอีกในละคร บางกลุ่มนิษฐานว่ามาจากเนื้อกรอบป้องที่รับประทานในมื้อกลางวันซึ่งส่วนใหญ่ประกอบด้วยเนื้อเทียม บางกลุ่มกล่าวว่า มาจากพฤติกรรมของสมาชิกชุมชน MUSH (Multi User Shared Hallucination) ซึ่งมักพิมพ์ คำว่า S-P-A-M เพื่อทำให้ผู้ใช้รายอื่นไม่สามารถเข้าร่วมสนทนาก่อนไลน์ของกลุ่มได้ [10]

ยังไม่มีคำจำกัดความที่ชัดเจน และเป็นที่ยอมรับ นัยโดย เซอร์เยน [10] กล่าวว่า คำจำกัดความที่หมายความของอีเมลขยะต้องครอบคลุมคุณสมบัติต่างๆ คือ พฤติกรรมเกี่ยวกับการโฆษณา จิตวิทยาของผู้รับ บริบททางกฎหมาย ข้อคิดเห็นทางเศรษฐศาสตร์ และปัญหาทางเทคโนโลยี OECD [10] ให้คำจำกัดความว่า เป็นอีเมลที่ผู้รับไม่ต้องการ ถูกส่งไปยังผู้รับครั้งละมากๆ ซึ่งอาจไม่รู้จักผู้รับมาก่อน มีการส่งซ้ำหลายครั้ง โดยหวังผลเกี่ยวกับการค้า มีเนื้อหาโกหก หรือทำให้ไม่พอใจ [10] อีเมลขยะถูกเรียกว่า Unsolicited Bulk E-mail (UBE) [11] หรือ Unsolicited Commercial E-mail (UCE)

อีเมลขยะถูกนำเสนอเป็น Internet Request for Comments (RFC) ในปี ค.ศ. 1975 และนำเสนอในวารสาร “Communications of the ACM” ต่อมาในปี ค.ศ. 1982 อีเมลขยะฉบับแรกส่งจาก DEC marketing ไปยังอีเมลทั้งหมดใน Arpanet แต่คำว่าอีเมลขยะถูกใช้เมื่อนายเคน เดอว์ และนายซีเกล ได้กระจายข่าวเกี่ยวกับความไม่ยุติธรรมของการซิงเชค U.S. Green Card [10]

อีเมลขยะแบ่งออกเป็นประเภทต่างๆ ตามเป้าหมายของผู้ส่ง เช่น การโฆษณาสินค้า การประกาศต่างๆ การปล่อยข่าวหลอกลวง (fraud) การแอบอ้างชื่อผู้อื่น (phishing) การเตือน การขอความเมตตา (hoaxes) จดหมายลูกโซ่ (chain e-mail) เนื้อหาว่างานผู้อื่น (joe jobs) กระจายซอกฟ์แวร์ที่เป็นอันตราย เช่น ไวรัส มัลแวร์ อีเมลตอบรับ หรือยืนยันบริการต่างๆ (bounce message)

2.2 การป้องกันอีเมลขยะ

มีงานวิจัย องค์กร และหน่วยงานจำนวนมากค้นคว้าหาวิธีป้องกันอีเมลขยะ โดยนำเสนอวิธีป้องกันอีเมลขยะหลายวิธี เช่น การออกแบบหมายເພີດກັບຜູ້ສົ່ງອື່ນຂະໜາດ [2] [10] การจัดตั้งองค์กรเพื่อความร่วมมือในการต่อต้านอีเมลขยะ (SpamCop) [12] การป้องกันມີເຫັນວິທີຜູ້ສົ່ງອື່ນຂະໜາດ ດັກຈັບທີ່ອຸ່ນອື່ນເມດ [10]

เนื่องจากອື່ນຂະໜາດມີປົກລົງມານີ້ ຈຶ່ງນິຍມໃຊ້ເຫຼືອໄລໍ້ທາງຄອມພິວເຕອຣີໃນການປັບປຸງກັນປະກອບດ້ວຍວິທີດັ່ງຕໍ່ໄປນີ້

2.2.1 ระบบการติดต่อกັບເຄີ່ງຄອມພິວເຕອຣີ ຮ່ວມເກືອຂ່າຍທີ່ສົ່ງອື່ນຂະໜາດ (IP Blocking)

2.2.2 ກຳທັນດັບຝູ້ສົ່ງອື່ນເມດ (Blacklisting) ຮະບູທີ່ອຸ່ນອື່ນເມດ ມາຍເລີ້ມໄອຟີ ຮ່ວມເກືອຂ່າຍເລີ້ມໄອຟີ ຊື່ໂດມັນ ທີ່ສົ່ງອື່ນຂະໜາດເປັນປະຈຳ ເພື່ອດໍາເນີນໃຫ້ບົງກັບຂໍ້ມູນໃນຮາຍການດັ່ງກ່າວ ຕ້າຍຢ່າງບັງວິທີດັ່ງຕໍ່ໄປນີ້ Domain Name System Blacklists (DNSBLs), Exploits Block List (XBL), Spamhaus block list (SBL) ເປັນຕົ້ນ [2] [10]

2.2.3 ກຳທັນດັບຝູ້ສົ່ງຂາວ (Whitelisting) ທຳກຳໃນລັກຂະນະເດີຍກັບບັງວິທີດັ່ງຕໍ່ໄປນີ້ ລາຍການທີ່ອຸ່ນຫຼາຍໃຫ້ໃຫ້ບົງກັບສົ່ງອື່ນເມດໄດ້ ຕ້າຍຢ່າງບັງວິທີດັ່ງຕໍ່ໄປນີ້ ດັ່ງກ່າວ Domain Name System Whitelists (DNSWLs) [10]

2.2.4 ບັງວິທີເຫາ (Graylisting) ຈະໃຫ້ພຸດທິກຽມການໄມ່ສົ່ງອື່ນຂໍ້ເມື່ອໄມ່ສາມາດສົ່ງອື່ນເມດສໍາເລັດໃນການທຳກຳ ເມື່ອມີການໃຫ້ບົງກັບສົ່ງອື່ນເມດ ມາຍເລີ້ມໄອຟີ ຮ່ວມເກືອຂ່າຍເລີ້ມໄອຟີ ຊື່ໂດມັນ ທີ່ອຸ່ນຫຼາຍໃຫ້ບົງວິທີເຫາ ຈະດໍາເນີນໃຫ້ບົງກັບສົ່ງອື່ນເມດ ໃຫ້ບົງກັບສົ່ງອື່ນເມດ ພໍາເຊົາມາ [2]

2.2.5 ກາຣັດກຣອງ (Filtering) ເປັນວິທີອັດໂນມັດທີ່ໃໝ່ງານສະດວກ ກາຣັດກຣອງຈະຕຽບສອບເນື້ອຫາທີ່ໜ້າຂອງອື່ນເມດ ຮ່ວມເກືອຂ່າຍເລີ້ມໄອຟີ ຊື່ໂດມັນ ທີ່ສົ່ງອື່ນເມດ ສໍາເລັດໃນການທຳກຳ ອຸ່ນຫຼາຍໃຫ້ບົງກັບສົ່ງອື່ນເມດ ຮ່ວມເກືອຂ່າຍເລີ້ມໄອຟີ ຊື່ໂດມັນ ທີ່ອຸ່ນຫຼາຍໃຫ້ບົງວິທີເຫາ ຈະດໍາເນີນໃຫ້ບົງກັບສົ່ງອື່ນເມດ ພໍາເຊົາມາ [10]

2.2.6 ວິທີອື່ນໆ ເຊັ່ນ ກາຣັດກຣອງໃຫ້ບົງກັບສົ່ງອື່ນເມດ ຮ່ວມເກືອຂ່າຍເລີ້ມໄອຟີ (TCP Blocking) ກາຣັດກຣອງກ່ອນການໃຫ້ບົງກັບສົ່ງອື່ນເມດ (authentication) ກາຣັດກຣອງຜູ້ສົ່ງ (verification) ຈຳກັດການໃຫ້ຫຼວຍປະມາລຸພລກລາງ ນໍາວ່າຄວາມຈຳຫັກ ຮ່ວມເກືອຂ່າຍເລີ້ມໄອຟີ ຈຳກັດປົກລົງການສົ່ງອື່ນເມດ ກາຣັດກຣອງທີ່ອຸ່ນຫຼາຍໃຫ້ບົງກັບສົ່ງອື່ນເມດ ຈຳກັດປົກລົງການສົ່ງອື່ນເມດ ກາຣັດກຣອງທີ່ອຸ່ນຫຼາຍໃຫ້ບົງກັບສົ່ງອື່ນເມດ ພໍາເຊົາມາ

2.3 ความเป็นส่วนตัวของอีเมล

ข้อมูลที่ส่งทางอีเมลบางครั้งเป็นความลับระหว่างผู้ส่งและผู้รับไม่ว่าในระดับองค์กรหรือส่วนบุคคล วัตถุประสงค์หลักของการรักษาความเป็นส่วนตัวคือ อนุญาตให้เฉพาะเจ้าของข้อมูลเท่านั้นสามารถเข้าถึงข้อมูลดังกล่าวได้ การถูกละเมิดความเป็นส่วนตัวของผู้ใช้งานอีเมลมาจากการหลâyสารเหตุ เช่น การโคนใจมิเต็จจากอีเมลของ นโยบายการตรวจสอบอีเมลของบุคลากรในหน่วยงาน การถูกดักจับข้อมูลระหว่างการส่งทั้งทางจากผู้ไม่ประสงค์ดีหรือหน่วยงานของรัฐ การละเมิดความเป็นส่วนตัวโดยผู้ดูแลระบบ การรักษาความเป็นส่วนตัวนั้นมิใช่ผลิตภัณฑ์ แต่เป็นกระบวนการ [13] เช่น การตั้งรหัสผ่านเพื่อเข้าระบบอีเมล การเชื่อมต่อผ่านช่องทางที่ปลอดภัย การเข้ารหัสข้อมูลของอีเมลก่อนส่ง เป็นต้น

ในประเทศไทยมีกฎหมายการรับรองเรื่องการรักษาความลับและมีกฎหมายคุ้มครองเกี่ยวกับการติดต่อสื่อสารทางจดหมายได้ให้การคุ้มครองการติดต่อสื่อสารทางอีเมลในลักษณะเดียวกัน โดยคุ้มครองการละเมิดความเป็นส่วนตัวทุกรูปแบบ

สิทธิการเข้าถึงข้อมูลอีเมลนั้นไม่อนุญาตให้มีคนนอกเจ้าของสามารถเข้าถึงข้อมูลดังกล่าวได้ เมื่อว่าอีเมลจะถูกเก็บรักษาไว้ที่ผู้ให้บริการอินเทอร์เน็ต และผู้ให้บริการอินเทอร์เน็ตนั้นไม่มีสิทธิในการเข้าถึงเนื้อความของอีเมลเหล่านั้น นอกจากนี้อีเมลจะถูกจัดการตามสิทธิ์ของเจ้าของ เช่น การสำรวจข้อมูล เป็นต้น [14]

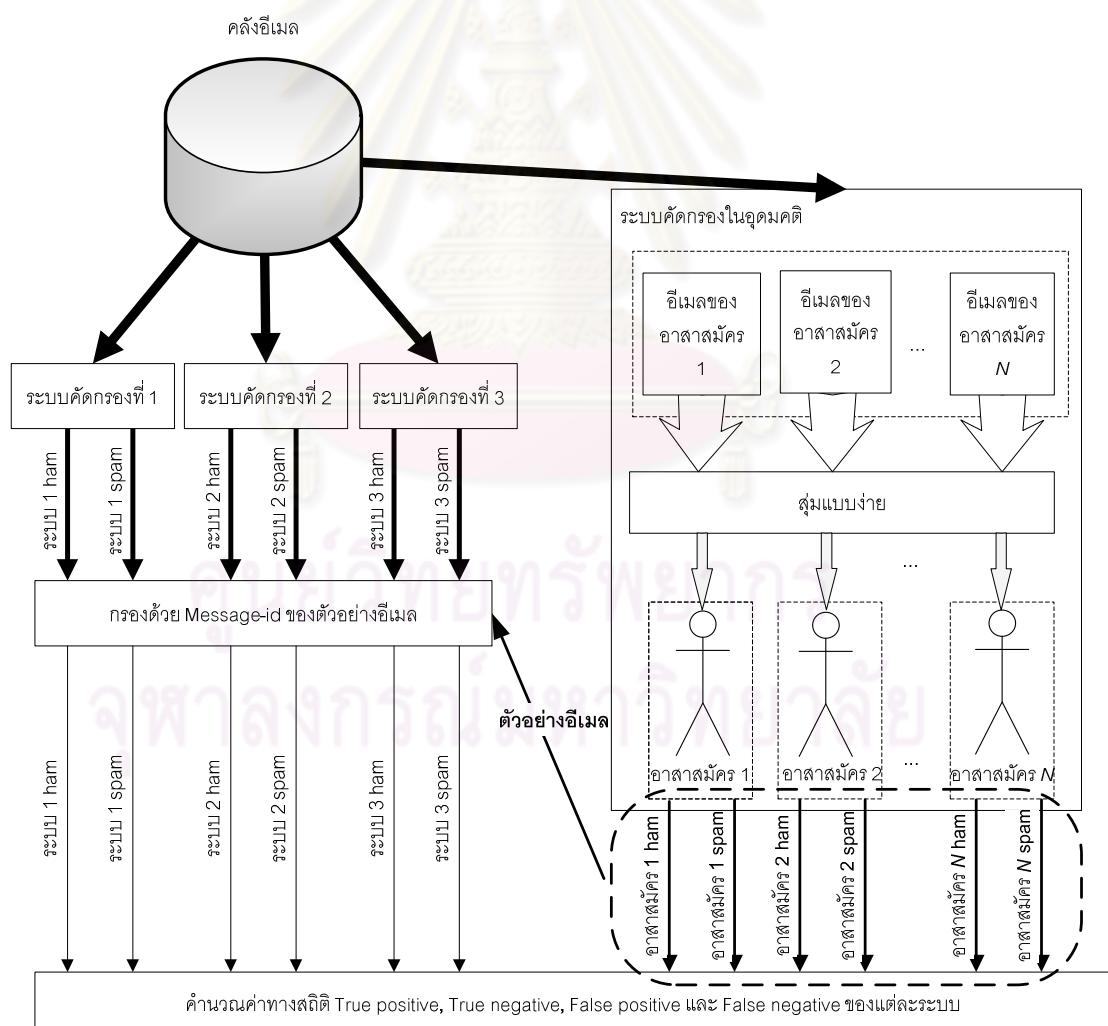
ศูนย์วิทยทรัพยากร
จุฬาลงกรณ์มหาวิทยาลัย

บทที่ 3

วิธีดำเนินการวิจัย

จากปัญหาที่เกิดขึ้นของกระบวนการวิธีสำหรับประมวลผลสิทธิภาพระบบคัดกรองอีเมลขยะในปัจจุบันที่ได้กล่าวไว้ข้างต้น ซึ่งวิธีการประมวลนั้นยังห่างไกลจากสภาพความเป็นจริง โดยไม่ได้ใช้อีเมลจริงขององค์กรเป้าหมายในการประมวล และผู้ใช้งานไม่มีส่วนร่วมในการประมวล งานวิจัยนี้จึงมีจุดมุ่งหมายเพื่อนำเสนอกระบวนการวิธีในการประมวลผลสิทธิภาพระบบคัดกรองอีเมลขยะโดยเจ้าของอีเมล ใช้คลังอีเมลที่รวบรวมมาจากอีเมลจริงขององค์กรเป้าหมายในการประมวล และกระบวนการประมวลนี้จะไม่ก่อให้เกิดปัญหาความเป็นส่วนตัว โดยภาพรวมของระบบแสดงดังรูปที่

3.1



รูปที่ 3.1 ภาพรวมของระบบประมวลผลสิทธิภาพ

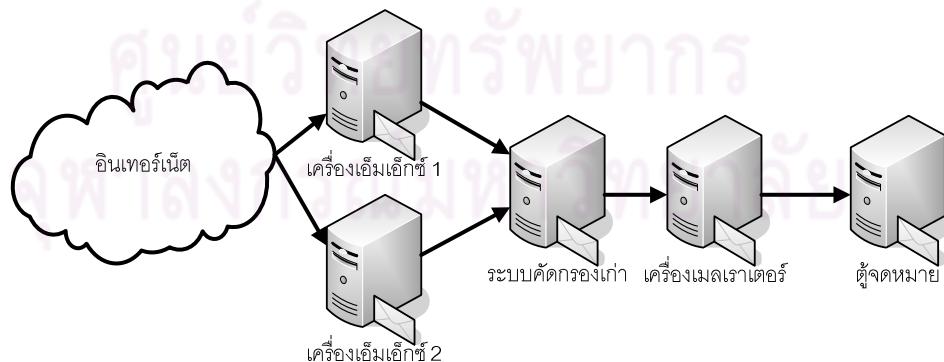
จากรูปที่ 3.1 คลังอีเมลจะถูกผ่านไปยังระบบคัดกรองทั่วไปและระบบในอุดมคติ ของ อีเมลที่ถูกคัดกรองด้วยระบบทั่วไปด้วย Message-id ของอีเมลที่ถูกคัดกรองโดยระบบในอุดมคติ เปรียบเทียบผลการคัดกรองของระบบทั่วไปกับระบบในอุดมคติ และคำนวนหาค่าทางสถิติเพื่อ เปรียบเทียบประสิทธิภาพ จากราฟรวมของระบบสามารถออกแบบวิธีดำเนินการวิจัยได้ดังต่อไปนี้

1. ศึกษาระบบอีเมลปัจจุบันขององค์กรเป้าหมาย
2. รวบรวมและวิเคราะห์คลังอีเมล
3. คัดเลือกอาสาสมัคร
4. เตรียมระบบคัดกรองที่ต้องการประเมินประสิทธิภาพ
5. สร้างระบบคัดกรองขึ้นของงานวิจัย
6. ป้อนคลังอีเมลผ่านระบบคัดกรองที่ต้องการประเมินประสิทธิภาพ
7. ติดต่อกลุ่มอาสาสมัคร
8. สุ่มอีเมลของอาสาสมัครแต่ละคนและให้ประเมินอีเมลของตนด้วยตัว
9. วิเคราะห์และสรุปผลการประเมินประสิทธิภาพ

3.1 ศึกษาระบบอีเมลปัจจุบันขององค์กรเป้าหมาย

3.1.1 ระบบอีเมลของจุฬาลงกรณ์มหาวิทยาลัย

การทำวิจัยครั้งนี้ผู้วิจัยกำหนดให้จุฬาลงกรณ์มหาวิทยาลัยเป็นองค์เป้าหมาย ซึ่ง มีบุคลากรและนิสิตรวมกันประมาณ 30,000 คน มากพอสำหรับทำการวิจัย และสามารถใช้งาน ทรัพยากรของระบบเครือข่ายคอมพิวเตอร์ได้พอสมควร

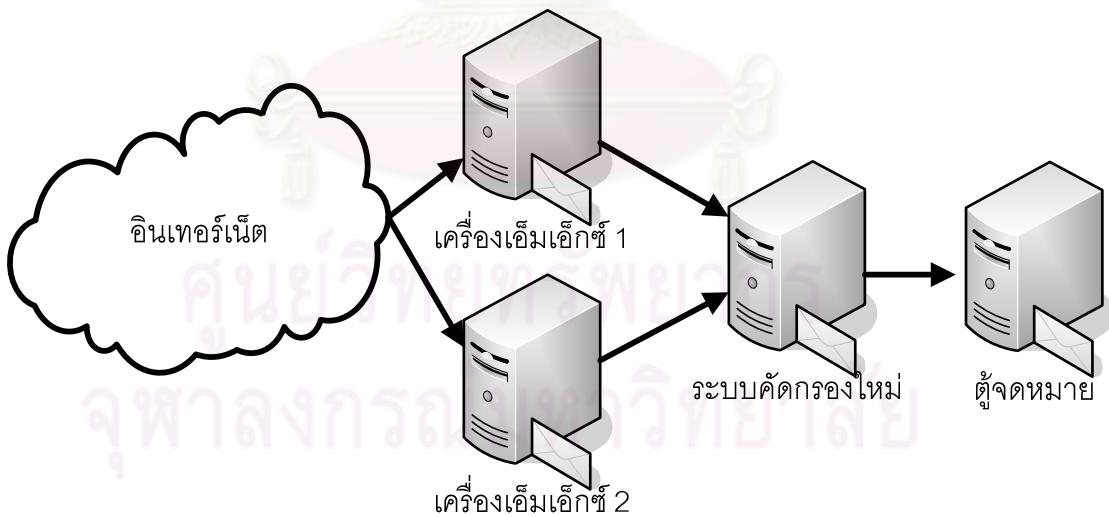


รูปที่ 3.2 ระบบอีเมลขนาดใหญ่ของจุฬาลงกรณ์มหาวิทยาลัย

ในขณะเดียวกัน ระบบอีเมลของจุฬาลงกรณ์มหาวิทยาลัยมีโครงสร้าง และ องค์ประกอบดังรูปที่ 3.2 เมื่ออีเมลจากภายนอกส่งมาอย่างผู้รับในมหาวิทยาลัย เครื่องคอมพิวเตอร์

ເຄີມເອັກໜີ 1 ແລະ ເຄີມເອັກໜີ 2 ຜຶ້ງທໍານາທີ່ເປັນເມືລເອັກເຫັນເຈອວັບອື່ນເມືລທີ່ສົ່ງລຶ່ງຜູ້ຮັບຂອງມາວິທຍາລັບ ຮະບັບຈະຕຽບສອບຕົ້ນທາງຂອງອື່ນເມືລວ່າເປັນແລ້ວສົ່ງອື່ນເມືລຂະໝະຫຼື່ອໄວ່ ໂດຍຕຽບສອບຈາກສູ່ນຳຂໍ້ມູນ ອາວົປີແອດ (RBL) ໄດ້ແກ່ abuseat.org, dsbl.org ແລະ spamhaus.org ແລະຕຽວຈາງຍື່ອອື່ນເມືລຂອງ ຜູ້ຮັບກ່າມື່ອຢູ່ໃນຮະບັບທີ່ໝີ່ໄວ່ ໂດຍຕຽບສອບຈາກສູ່ນຳຂໍ້ມູນແບບເບຣິກເລ໌໌ ຕີບີ (Berkley DB) ຜ່ານ ໂປຣໂຕຄອລແລລແດປ (LDAP) ພັນຈາກນັ້ນຈະສົ່ງອື່ນເມືລຕ່ອໄປຢັ້ງເຄື່ອງ SPAM Filter ຜຶ້ງທໍານາທີ່ກັດ ກຽກອື່ນເມືລທີ່ໄດ້ຮັບວ່າເປັນອື່ນເມືລຂະໝະຫຼື່ອແນປໄວ້ສມາດ້ວຍຫຼື່ອໄວ່ ຕິດຕັ້ງໂປຣແກຣມໄອເຄີມເອັກເອັດ ອຸ່ນ 7.0 (IMSS 7.0) ເປັນໂປຣແກຣມດັດກຽກອື່ນເມືລຂະໝະຫຼື່ອແນປໄວ້ສມາດ້ວຍຫຼື່ອໄວ່ ທັກພບວ່າເປັນອື່ນເມືລຂະໝະໃຫ້ແກຣກ ຂໍ້ຄວາມ “SPAM” ໃນສ່ວນທັງໝົດຂອງອື່ນເມືລ ອື່ນເມືລຈະຖຸກສັງຕອໄປຢັ້ງເຄື່ອງເມືລເຮົາເຕືອນ ຜຶ້ງມີທີ່ກັນຫາ ແລະສົ່ງອື່ນເມືລໄປຢັ້ງເຄື່ອງຄອມພິວເຕອນທີ່ມີຕູ້ຈັດໝາຍຂອງຜູ້ຮັບອູ່ ຜຶ້ງມີທີ່ກັບອື່ນເມືລຂອງຜູ້ໃໝ່ງານ ທັ້ງໝົດ ແລະໃຫ້ບົກກາວອ່ານອື່ນເມືລຜ່ານໂປຣໂຕຄອລ ປຶ້ອບ ອຸ່ນທີ່ 3 (POP3) ແລະ ໄອແມພ ອຸ່ນທີ່ 4 (IMAP4) ເຄື່ອງທີ່ມີຕູ້ຈັດໝາຍຈະມີກະຈາຍໄປຢັ້ງໜ່ວຍງານຕ່າງໆ ຩີວ່ອສຳຮັບແຕ່ລະໂດເມນຍ່ອຍໃນ ມາວິທຍາລັບເພື່ອຮັບອື່ນເມືລທີ່ສົ່ງມາຍັງໂດເມນຍ່ອຍນັ້ນ

ລຳນັກເທິກໂນໂລຢີສາຮສນເທີກ ຈຸ່າລັງກຣນົມມາວິທຍາລັບ ມີຄວາງກວ່າຈະເປົ່າຍິນ ຮະບັບດັດກຽກອື່ນເມືລຂະໝະຕາມຮູບທີ່ 3.2 ໂດຍໜັງຈາກມີກາງເປົ່າຍິນແປ່ງຮະບັບດັດກຽກອື່ນເມືລຂະໝະແລ້ວ ທຳໄໝຮະບັບອື່ນເມືລຂອງຈຸ່າລັງກຣນົມມາວິທຍາລັບ ເປັນດັ່ງຮູບທີ່ 3.3



ຮູບທີ່ 3.3 ຮະບັບອື່ນເມືລໃໝ່ຂອງຈຸ່າລັງກຣນົມມາວິທຍາລັບ

ຈາກຮູບທີ່ 3.3 ເນື້ອເປົ່າຍິນເຫັນກັບຮູບທີ່ 3.2 ພບກວ່າໄດ້ມີກາງຮັມຫັ້ນທີ່ຂອງເຄື່ອງທີ່ ເປັນຮະບັບດັດກຽກອື່ນເມືລຂະໝະແລະເຄື່ອງເມືລເຮົາເຕືອນ ເນື້ອຈາກຮະບັບດັດກຽກອື່ນເມືລຂະໝະໃໝ່ສາມາດຮັບ ທໍານາທີ່ດັ່ງກ່າວໄວ່ໄດ້ໃນຕົວເອງ

หลังจากติดตั้งเครื่องคอมพิวเตอร์เครื่องใหม่ให้แก่ระบบอีเมลแล้ว ระบบเดิมก็ยังคงทำงานอยู่แต่แบ่งหน้าที่รับผิดชอบโดย ระบบใหม่จะรับผิดชอบในการคัดกรองอีเมลของอาจารย์และเจ้าหน้าที่ และระบบเก่าจะรับผิดชอบในการคัดกรองอีเมลของนิสิต

3.1.2 อีเมลแอดเดรสของผู้ใช้งาน

ผู้ใช้งานระบบอีเมลของจุฬาลงกรณ์มหาวิทยาลัยแต่ละคนจะมีอีเมลแอดเดรสอย่างน้อย 1 ประเททชีประจำบอตด้วย

3.1.2.1 อีเมลหลัก คืออีเมลที่องค์กรสร้างให้เพื่อปริการแก่ผู้ใช้งานแต่ละคน มีการใช้งานอยู่เป็นประจำ เช่น First.L@Chula.ac.th

3.1.2.2 อีเมลกลุ่ม คืออีเมลแอดเดรสที่สร้างขึ้นเพื่อนำเสนอไปยังบุคคลที่สนใจ เช่น การกระจายข่าวของกลุ่มผู้ดูแลระบบ หรือกลุ่มอาจารย์เป็นต้น อีเมลกลุ่มจะประกอบด้วยอีเมลสมาชิก เมื่อมีเมลมาถึงอีเมลกลุ่ม ระบบอีเมลจะกระจายส่งอีเมลนั้นไปยังอีเมลสมาชิกทุกอีเมล เช่น noc@it.chula.ac.th เป็นต้น

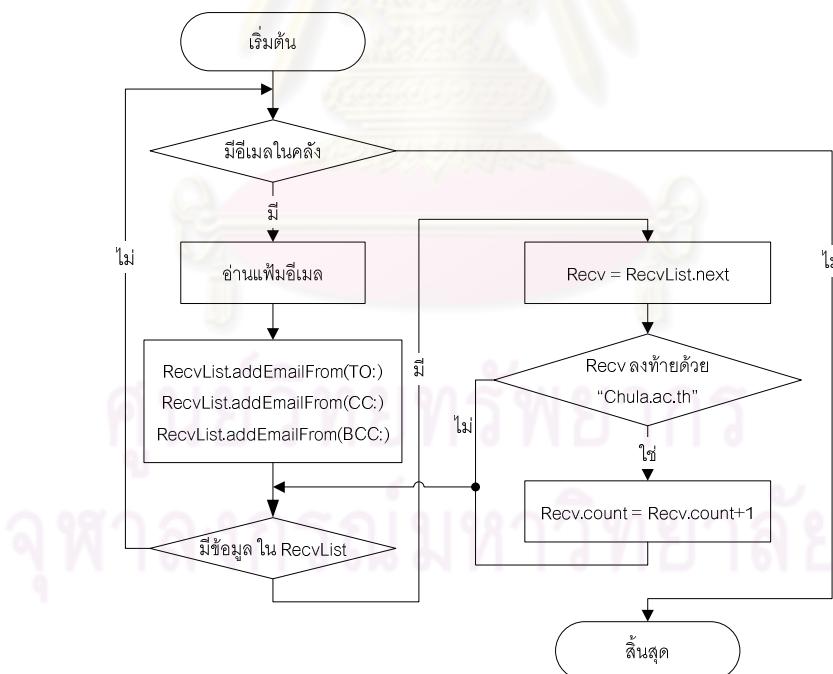
3.2 รวมรวมและวิเคราะห์คลังอีเมล

จุดมุ่งหมายและวัตถุประสงค์ของงานวิจัยนี้ คือการประเมินประสิทธิภาพของระบบคัดกรองอีเมลขยะในสถานการณ์ที่ใกล้เคียงกับความเป็นจริง ให้ผู้ใช้งานมีส่วนร่วมในกระบวนการประเมิน และใช้อีเมลจริงในการประเมินโดยไม่ก่อให้เกิดปัญหาความเป็นส่วนตัว ดังนั้นคุณสมบัติของคลังอีเมลที่ใช้ในการวิจัยครั้นนี้ต้องเป็นอีเมลจริงประจำบอตด้วยอีเมลตัวเอง ซึ่งสังถึงผู้ใช้งานทุกคนและผ่านระบบอีเมลของจุฬาลงกรณ์มหาวิทยาลัย อีเมลทั้งหมดต้องไม่ผ่านการคัดกรองด้วยระบบคัดกรองที่ใช้ทดสอบตัวได้มาก่อน หากใช้คลังอีเมลซึ่งผ่านการคัดกรองมาแล้วด้วยระบบคัดกรองใด คลังอีเมลทั้งหมดจะไม่ถูกคัดกรองหรือตัดสินว่าเป็นอีเมลขยะอีกเมื่อถูกคัดกรองซ้ำด้วยระบบคัดกรองนั้นอีก เป็นผลทำให้ผลการคัดกรองและการประเมินประสิทธิภาพผิดพลาด จากข้อมูลทางสถิติพบว่ามีสิ่งที่สำคัญที่สุดคือการใช้งานอีเมลของมหาวิทยาลัยต่ำากลังไม่เหมาะสมที่จะใช้เป็นกลุ่มอาสาสมัครในการวิจัย อีกทั้งการเก็บรวบรวมอีเมลจากระบบอีเมลของนิสิตยังทำได้ยากลำบาก เนื่องจากโปรแกรมไอกิ้มເක්සເກ්ස ไม่สามารถทำสำเนาอีเมลทั้งหมดไปยังตู้จดหมายอีนได้ ทางผู้วิจัยจึงเลือกอีเมลของคณาจารย์ และเจ้าหน้าที่ของมหาวิทยาลัยซึ่งมีการใช้งานอย่างต่อเนื่องเป็นคลังอีเมลของงานวิจัยนี้

จากคุณสมบัติของคลังอีเมลที่ต้องการนำไปสู่วิธีการเก็บรวบรวมคลังอีเมลจากระบบอีเมลของจุฬาลงกรณ์มหาวิทยาลัย แต่เนื่องจากขณะเริ่มต้นระบบอีเมลได้เปลี่ยนแปลงไป

ดังแสดงในรูป 3.3 ซึ่งส่งผลให้การเก็บรวบรวมอีเมลของกลุ่มเป้าหมายที่ต้องการทำได้สะดวกขึ้น เนื่องจากระบบคัดกรองใหม่คัดกรองเฉพาะอีเมลของอาจารย์และเจ้าหน้าที่เท่านั้น หลังติดตั้งระบบคัดกรองใหม่ อีเมลเข้าของอาจารย์และเจ้าหน้าที่ทั้งหมดจะต้องผ่านระบบคัดกรองใหม่นี้ ก่อนที่จะถูกส่งไปยังตู้จดหมายของผู้รับ ตั้งนั้นการรวบรวมคลังอีเมลจะต้องสำเนาอีเมลที่ผ่านระบบคัดกรองใหม่ โดยปรับตั้งให้ระบบคัดกรองใหม่ให้ทำสำเนาอีเมลที่เป็นอีเมลขยะและอีเมลดีมากที่ต้องรับจดหมายของผู้วิจัย

เนื่องจากระบบคัดกรองใหม่มีระบบเซนเตอร์เดอร์เบส (SenderBase) [15] ที่คงอยู่ ตรวจสอบความน่าเชื่อถือของอีเมลโดยอาศัยคุณสมบัติต่างๆ เช่น ตรวจสอบหมายเลขไอพีของเครื่องผู้ส่งว่าถูกขึ้นบัญชีคำหรือไม่หรือถูกรายงานจากผู้รับว่าผู้ส่งอีเมลนักส่งอีเมลขยะเป็นต้น ระบบเซนเตอร์เดอร์เบสสามารถกำจัดอีเมลได้มากถึงร้อยละ 85 ก่อนที่จะเข้ามายังระบบอีเมลของจุฬาลงกรณ์มหาวิทยาลัย ทำให้มีอีเมลผ่านเข้ามาเพียงร้อยละ 15 เท่านั้น อย่างไรก็ตาม กระบวนการนี้มีความล่าช้ามากพอที่จะนำมาใช้ในงานวิจัย และเมื่อรวบรวมคลังอีเมลได้แล้วน้ำค้างลังอีเมลมาวิเคราะห์เพื่อนับจำนวนอีเมลที่ส่งถึงผู้รับแต่ละคนต่อไป



รูปที่ 3.4 การนับจำนวนอีเมลของผู้ใช้งานแต่ละคน

จากรูปที่ 3.4 กระบวนการคลังอีเมลเพื่อนับจำนวนอีเมลเข้าของผู้ใช้งานแต่ละคน จะอ่านอีเมลครั้งละฉบับจากคลังอีเมล อ่านรายชื่อผู้รับอีเมลจากอีเมลนั้นประกอบด้วย ผู้รับ (TO)

ควรบอนก็อบปี (CC) และไบรด์คาร์บอนก็อบปี (BCC) อีเมลแอดเดรสต้องลงท้ายด้วยโดเมนเนม “Chula.ac.th” เท่านั้น หากเพิ่มจำนวนอีเมลเข้ามาก็ต้องแต่ละผู้รับ แล้วอ่านอีเมลฉบับถัดไปจนหมดคลังอีเมล

3.3 คัดเลือกอาสาสมัคร

จากสถิติการใช้งานอีเมลของจุฬาลงกรณ์มหาวิทยาลัยพบว่า กลุ่มผู้ใช้ที่มีการใช้งานอย่างต่อเนื่องคือกลุ่มคณาจารย์และเจ้าหน้าที่มหาวิทยาลัย ส่วนนิสิตมีสถิติการใช้งานต่ำนี่เองจากนิสิตนิยมใช้งานพร้อมๆ กัน ดังนั้นกลุ่มอาสาสมัครของงานวิจัยนี้เลือกจากเหล่าคณาจารย์ และเจ้าหน้าที่มหาวิทยาลัย การคัดเลือกอาสาสมัครอาศัยสถิติการใช้งาน ซึ่งได้จากการประเมินอีเมลของผู้ใช้งานแต่ละคนในคลังอีเมลเป็นเกณฑ์ในการคัดเลือกกลุ่มอาสาสมัคร กลุ่มอาสาสมัครต้องมีส่วนรวมในการประเมินประสิทธิภาพระบบคัดกรองอีเมลขยะที่จะถูกนำมาใช้งานในองค์กร ของกลุ่มอาสาสมัครนั้น เพื่อให้ได้ระบบคัดกรองที่เหมาะสมกับสถานการณ์ในการใช้งานจริงและกลุ่มผู้ใช้งานในองค์กร เพราะความถูกต้องของการคัดกรอง อีเมลขี้นอยู่กับเจ้าของอีเมลเป็นหลัก โดยงานวิจัยนี้มีสมมติฐานว่าอาสาสมัครเป็นระบบคัดกรองในอุดมคติตั้ดสินใจได้ถูกต้องเสมอโดยไม่มีข้อผิดพลาดใดๆ มีหน้าที่ 2 ประการคือ

3.3.1 ตรวจสอบผลการคัดกรองของระบบคัดกรองที่ต้องการประเมินประสิทธิภาพ

การตัดสินว่าอีเมลฉบับใดเป็นอีเมลขยะหรือไม่ ผู้ที่มีสิทธิตัดสินคือเจ้าของอีเมล แต่เพียงผู้เดียวเท่านั้น เนื่องจากอีเมลเป็นข้อมูลส่วนตัว ดังนั้นการตรวจสอบผลการคัดกรองของระบบคัดกรอง จำเป็นต้องใช้เจ้าของอีเมลฉบับนั้นมาตรวจสอบ ระบบคัดกรองอีเมลขยะจะแยกอีเมลออกเป็น 2 กลุ่มคือ อีเมลดีและอีเมลขยะ เจ้าของจะต้องตรวจสอบอีเมลทั้ง 2 กลุ่มว่ามีผลลบลง หรือผลบวกลงหรือไม่ เพื่อนำค่าที่ได้มาเปรียบเทียบประสิทธิภาพของระบบคัดกรองแต่ละระบบต่อไป

3.3.2 คัดกรองกลุ่มตัวอย่างอีเมลที่สูญจากคลังอีเมล

กลุ่มอาสาสมัครต้องประเมินอีเมลของตนในกลุ่มอีเมลตัวอย่างที่ถูกสูญ掉จากคลัง อีเมล เพื่อคำนวนหาปริมาณอีเมลขยะที่แท้จริงของคลังอีเมล และนำไปเปรียบเทียบกับปริมาณ อีเมลขยะที่ระบบคัดกรองสามารถคัดกรองได้

3.4 เตรียมระบบคัดกรองที่ต้องการประเมินประสิทธิภาพ

งานวิจัยนี้สร้างกระบวนการวิธีสำหรับประเมินประสิทธิภาพของระบบคัดกรองอีเมลขยะ
จะต้องมีระบบคัดกรองอีเมลขยะเข้าร่วมทั้งหมด 3 ระบบ ดังนี้

3.4.1 ระบบเก่า

คือระบบคัดกรองอีเมลขยะที่ใช้งานก่อนการเปลี่ยนระบบคัดกรองอีเมลขยะของ
สำนักเทคโนโลยีสารสนเทศ จุฬาลงกรณ์มหาวิทยาลัย ในเดือน กันยายน 2551 โดยระบบคัดกรอง
นี้ใช้โปรแกรมไอกีเมลแอสเซส รุ่นที่ 7 เป็นระบบคัดกรองอีเมลขยะ ให้บริการคัดกรองอีเมลของนิสิต

3.4.2 ระบบปัจจุบัน

คือระบบคัดกรองอีเมลขยะที่ สำนักเทคโนโลยีสารสนเทศ จุฬาลงกรณ์
มหาวิทยาลัย เปลี่ยนและใช้งานตั้งแต่เดือน กันยายน 2551 เป็นต้นมา ซึ่งเป็นเครื่องคอมพิวเตอร์
เฉพาะสำหรับจัดการระบบอีเมล และคัดกรองอีเมลขยะ ให้บริการแก่คณาจารย์และเจ้าหน้าที่
มหาวิทยาลัย

3.4.3 ระบบอ้างอิง

คือระบบที่สร้างขึ้นโดยนำวิธีการคัดกรองอีเมลขยะจากงานวิจัย และวิธีที่ใช้กัน
อย่างแพร่หลายในปัจจุบัน โดยรายละเอียดแสดงในหัวข้อ 3.5

เนื่องจากการเปรียบเทียบ และวิเคราะห์ผลการประเมินระบบคัดกรองอีเมลขยะ
จำเป็นต้องมีระบบคัดกรองอีเมลขยะซึ่งเป็นที่ยอมรับ เพื่อข้างอิงผลลัพธ์ และประสิทธิภาพในการ
คัดกรอง วิธีการคัดกรองอีเมลขยะมีการวิจัย และพัฒนาอย่างต่อเนื่อง ดังนั้นระบบอ้างอิงจาก
งานวิจัย ควรพัฒนาให้ทันสมัย เช่น การสร้างหรือปรับปรุงระบบอ้างอิงรุ่นต่อๆ มาให้ใช้วิธีการคัด
กรองที่ทันสมัยที่สุดเป็นต้น เพื่อเพิ่มความถูกต้องของผลการประเมิน โดยกระบวนการสร้างระบบ
อ้างอิงจะกล่าวถึงในลำดับถัดไป

การเปรียบเทียบผลการคัดกรองระหว่าง ระบบเก่า และระบบปัจจุบัน กับระบบอ้างอิง
เพื่อเปรียบเทียบผลการตัดกรองระหว่างระบบคัดกรองที่ข้ายในท้องตลาด กับระบบคัดกรองโอลูเอน
ชอร์สซึ่งไม่มีค่าใช้จ่าย อีกทั้งเป็นการนำเสนอทางเลือกใหม่สำหรับระบบคัดกรองอีเมลขยะ

อีเมลที่ถูกคัดกรองโดยระบบคัดกรองทั้ง 3 ประเภทจะถูกตรวจสอบความถูกต้องด้วยตา
ของกลุ่มอาสาสมัคร

3.5 สร้างระบบคัดกรองอ้างอิงจากงานวิจัย

กระบวนการสร้างระบบคัดกรองอ้างอิงจากงานวิจัยนั้นมีกระบวนการดังต่อไปนี้

3.5.1 ศึกษางานวิจัยเกี่ยวกับอีเมลขยะ

ในปี ค.ศ. 2007 คอร์เม็ค และคณะ [4] ทำการประเมินประสิทธิภาพของโปรแกรมโอเพนซอร์สสำหรับคัดกรองอีเมลขยะและใช้งานกันอย่างแพร่หลาย 6 โปรแกรม ซึ่งให้ความสำคัญกับโปรแกรม สแปมแอสแซฟซิน (Spamassassin) เป็นหลัก โดยเปรียบเทียบประสิทธิภาพการคัดกรองของวิธีการคัดกรองต่างๆ ที่โปรแกรมสแปมแอสแซฟซินรองรับ

ดังนั้นงานวิจัยนี้จึงนำสแปมแอสแซฟซินมาเป็นระบบอ้างอิงของงานวิจัยเพื่อใช้เปรียบเทียบกับผลการคัดกรองของ ระบบเก่า และระบบปัจจุบัน โดยปรับตั้งให้โปรแกรมใช้การค่ามาตรฐานในการทำงาน

3.5.2 สร้างระบบคัดกรองอ้างอิง

การสร้างระบบคัดกรองอ้างอิงใช้คอมพิวเตอร์ส่วนบุคคลติดตั้งโปรแกรม ดังรายละเอียดตามตารางที่ 3.1

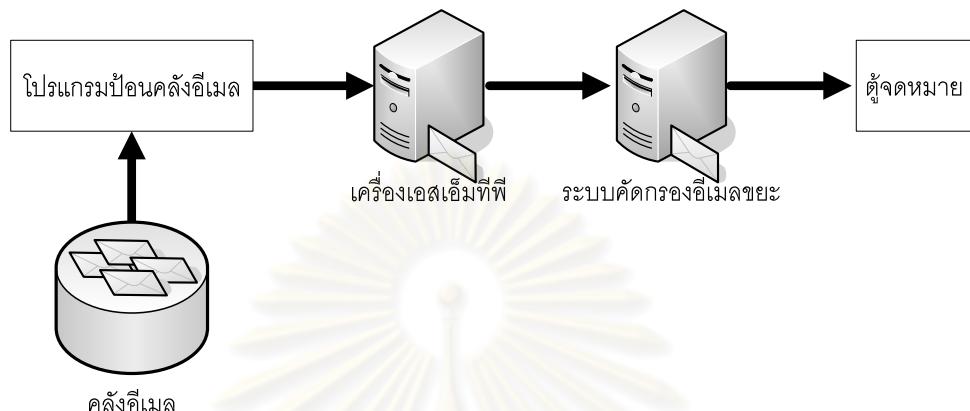
ตารางที่ 3.1 รายละเอียดซอฟแวร์ของระบบคัดกรองอ้างอิง

ประเภท	รายละเอียด
ระบบปฏิบัติการ	ฟรีบีโอดี รุ่น 7.0 (FreeBSD 7.0)
โปรแกรมแม่ข่ายอีเมล	โพสฟิก รุ่น 2.3 (Postfix 2.3)
โปรแกรมคัดกรองอีเมลขยะ	สแปมแอสแซฟซิน รุ่น 3.2.5 (Spamassassin 3.2.5)

หลังจากติดตั้งระบบปฏิบัติการเรียบร้อยแล้ว ติดตั้งโปรแกรมโพสฟิก และโปรแกรมสแปมแอสแซฟซิน ให้โปรแกรมสแปมแอสแซฟซินรุ่นที่ 3.2.5 ที่บนระบบปฏิบัติการฟรีบีโอดี รุ่นที่ 7 การปรับตั้งค่าของโปรแกรมสแปมแอสแซฟซินจะใช้ค่ามาตรฐานของโปรแกรม และปรับตั้งให้ระบุผลการคัดกรองไว้ที่หัวข้อของอีเมล โดยรายละเอียดของค่ามาตรฐานแสดงในภาคผนวก จากการปรับตั้งค่าข้างต้นเมื่อพบว่า อีเมลฉบับใดเป็นอีเมลขยะ โปรแกรมจะเพิ่มข้อความ “****SPAM****” ด้านหน้าหัวข้ออีเมลนั้นเพื่อแยกอีเมลตีอອກจากอีเมลขยะ

3.6 ป้อนคลังอีเมลผ่านระบบคัดกรองที่ต้องการประเมินประสิทธิภาพ

การป้อนคลังอีเมลผ่านระบบคัดกรองที่ต้องการประเมินประสิทธิภาพ เพื่อให้ระบบคัดกรองวิเคราะห์คลังอีเมล แยกอีเมลดี และอีเมลขยะออกจากกัน ดังนี้รายละเอียดดังนี้



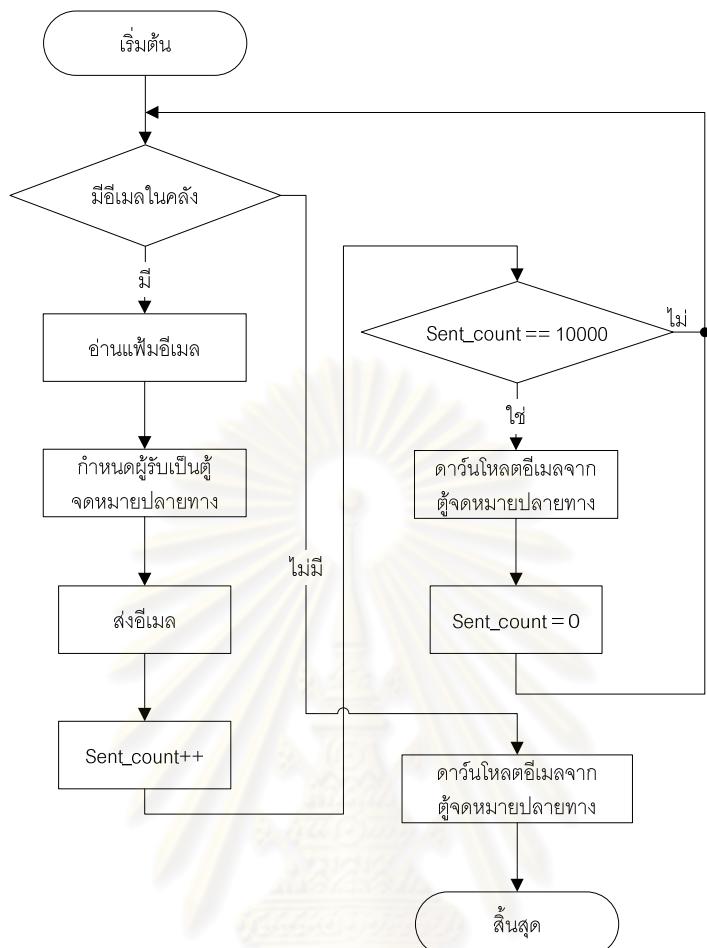
รูปที่ 3.5 การเชื่อมต่อของคอมพิวเตอร์เพื่อป้อนคลังอีเมลผ่านระบบคัดกรอง

จากรูปที่ 3.5 การป้อนคลังอีเมลผ่านระบบคัดกรองอีเมลขยันนั้น งานวิจัยนี้กำหนดให้สามารถป้อนคลังอีเมลผ่านระบบคัดกรองได้เพียงครั้งละ 1 ระบบคัดกรองเท่านั้น จากการศึกษาระบบคัดกรองของจุฬาลงกรณ์มหาวิทยาลัยดังกล่าวในตอนต้น การส่งอีเมลผ่านระบบคัดกรองระบบเก่าและระบบปัจจุบัน สามารถทำได้โดยส่งอีเมลไปยังตู้จดหมายของนิสิตเมื่อต้องการป้อนคลังอีเมลผ่านระบบเก่า และส่งอีเมลไปยังตู้จดหมายของคณาจารย์หรือเจ้าหน้าที่เมื่อต้องการป้อนคลังอีเมลผ่านระบบปัจจุบัน ผู้วิจัยได้แจ้งสำนักเทคโนโลยีสารสนเทศ จุฬาลงกรณ์มหาวิทยาลัยให้สร้างตู้จดหมายให้แก่ผู้วิจัยโดยมีสิทธิเทียบเท่าตู้จดหมายของคณาจารย์เพื่อให้รับอีเมลหลังจากผ่านการคัดกรองโดยระบบปัจจุบัน และใช้ตู้จดหมายของผู้วิจัยรับอีเมลซึ่งผ่านการคัดกรองโดยระบบเก่า

สำหรับระบบคัดกรองอ้างอิงนี้ผู้วิจัยได้สร้างระบบคัดกรองอ้างอิงขึ้น โดยติดตั้งภายในห้องทดลอง ทำการป้อนคลังอีเมลผ่านระบบดังกล่าว และสร้างตู้จดหมายเพื่อรับอีเมลจากระบบคัดกรองนั้น ตู้จดหมายสำหรับระบบคัดกรองแต่ละประเภทแสดงดังตารางที่ 3.2

ตารางที่ 3.2 ตู้จดหมายปลายทางที่ผ่านกระบวนการคัดกรองประเภทต่างๆ

ประเภทของระบบคัดกรอง	ตู้จดหมายปลายทาง
ระบบคัดกรองเก่า	Athakorn.O@student.Chula.ac.th
ระบบคัดกรองปัจจุบัน	Athakorn.O@Chula.ac.th
ระบบคัดกรองอ้างอิง	Athakorn.O@[หมายเลขอ菲 Guy ใน]



รูปที่ 3.6 การป้อนคลังอีเมลผ่านระบบคัดกรองที่มาทดสอบ

จากรูปที่ 3.6 การป้อนคลังอีเมลผ่านระบบคัดกรองแต่ละประเภทเริ่มต้นโดยอ่าน อีเมลจากคลังอีเมลครั้งละฉบับ กำหนดชื่อผู้รับตามตารางที่ 3.2 โดยพิจารณาว่ากำลังทดสอบ ระบบคัดกรองใด จากนั้นส่งอีเมลตั้งกล่าวไปยังปลายทาง เมื่อส่งอีเมลครบ 10,000 ฉบับแล้ว ให้ ดึงอีเมลจากตู้รับจดหมายปลายทางมากวิเคราะห์ว่าเป็นอีเมลขยะหรือไม่เพื่อป้องกันตู้จดหมายเต็ม เป็นผลให้ไม่สามารถส่งอีเมลเข้าไปได้ และเมื่อส่งอีเมลหมดคลังแล้วให้ทำการดึงอีเมลจากตู้รับ จดหมายอีกครั้งเพื่อให้แน่ใจว่าอีเมลทั้งหมดในคลังถูกคัดกรองและบันทึกผลการคัดกรองเรียบร้อย แล้ว

3.7 ติดต่อกลุ่มอาสาสมัคร

การติดต่อกลุ่มอาสาสมัครจะทำการติดต่อผ่านทางอีเมลของอาสาสมัคร มีการใช้งานอยู่ เป็นประจำ โดยส่งอีเมลเพื่อข้อความร่วมมือไปยังกลุ่มอาสาสมัคร

เรื่อง ขอความร่วมมือเพื่อเข้าร่วมงานวิจัยเรื่อง "การประเมินประสิทธิภาพระบบคัดกรองอีเมลขยะโดยผู้ใช้งาน"

เรียน ท่านอาสาสมัคร เจ้าของอีเมล Athakorn.O@Chula.ac.th

ข้าพเจ้านายอรรถกร องค์ศิริพร นิสิตคณะวิศวกรรมศาสตร์ ภาควิชาวิศวกรรมคอมพิวเตอร์ หลักสูตรวิทยาศาสตรมหาบัณฑิตสาขาวิชาที่ยวิศวกรรมศาสตร์คอมพิวเตอร์ (ภาคนอกเวลาราชการ) รหัสประจำตัว 5071458921 กำลังทำวิทยานิพนธ์ ในหัวข้อ "การประเมินประสิทธิภาพระบบคัดกรองอีเมลขยะโดยผู้ใช้งาน" โดย มี อ.ดร.ยุรยาง เต็งอำนวย (Yunyong.T@Chula.ac.th) เป็นอาจารย์ที่ปรึกษา และได้รับการสนับสนุนจากสำนักเทคโนโลยีสารสนเทศ จุฬาลงกรณ์มหาวิทยาลัย

เนื่องด้วยท่านอาสาสมัครมีการใช้งานอีเมลของ จุฬาลงกรณ์มหาวิทยาลัย อย่างต่อเนื่อง และมีปริมาณเพียงพอ ข้าพเจ้าจึงได้ขอความกรุณานำอีเมลของท่านเป็นข้อมูลในการวิจัยและขอความร่วมมือท่านอาสาสมัคร เข้าร่วมการทำวิจัยในครั้งนี้ อีเมลของท่านจะถูกเก็บไว้เป็นความลับโดยมีเพียงท่านอาสาสมัครเท่านั้น ที่สามารถดูอีเมลของท่านได้

การร่วมทำวิจัยท่านอาสาสมัครต้องพิจารณาอีเมลของท่านเองด้วยตา เป็นจำนวน 20 ฉบับ และตัดสินว่าเป็นอีเมลขยะ (SPAM) หรือไม่ ผู้วิจัยขออนุญาตเก็บข้อมูลส่วนตัวของท่านอันประกอบด้วย เพศ อายุ สถานภาพ เพื่อประกอบการวิเคราะห์ โดยจะดำเนินการในช่วงเดือน ธันวาคม 2552 และการทำวิจัยในครั้งนี้จะไม่สร้างภาระให้แก่ท่านอาสาสมัครจนเกินไป

ผู้จัดทำจะประสานงานกับท่านอาสาสมัครผ่านทางอีเมล การเข้าร่วมการวิจัยจะทำผ่านทางเว็บไซด์ isel.cp.eng.chula.ac.th/SpamFilterEvaluationWeb

ผู้จัดทำขอขอบพระคุณในความร่วมมือของท่าน

ยินดีเข้าร่วม - กรุณาตอบอีเมล (Reply) ฉบับนี้

ขอแสดงความนับถืออย่างสูง

(นายอรรถกร องค์ศิริพร)

ตัวอย่างหน้าจอสำหรับประเมินอีเมลของตนเองด้วยตา



Chulalongkorn University SPAM Filter Evaluation System

อีเมลของท่านฉบับนี้เป็นอีเมลขยะ (SPAM) หรือไม่

(หากท่านติดว่าเป็นอีเมลขยะคด "เป็น" ถ้าท่านติดว่าไม่เป็นอีเมลขยะคด "ไม่เป็น")

ฉบับที่ 1 / 20

Subject: Fwd: Weekly summary 1 November 2007

From: Athakorn Ongsiriporn
To: 50714589@student.netserv.chula.ac.th
Sat Nov 03 23:24:07 ICT 2007
Attachment: A.Yunyong & Athakorn weekly summary 3 01 Nov 2007.doc

Note: forwarded message attached.

Do You Yahoo?
Tired of spam? Yahoo! Mail has the best spam protection around
<http://mail.yahoo.com>

NOD32 3727 (20081231) Information

This message was checked by NOD32 antivirus system.
<http://www.eset.com> Note: forwarded message attached.

Do You Yahoo? Tired of
spam? Yahoo! Mail has the best spam protection around
<http://mail.yahoo.com>

NOD32 3727 (20081231) Information This message was
checked by NOD32 antivirus system. <http://www.eset.com>

Note: forwarded message attached.

Do You Yahoo?
Tired of spam? Yahoo! Mail has the best spam protection around
<http://mail.yahoo.com>

Note: forwarded message attached.

รูปที่ 3.7 ตัวอย่างจดหมายขอความร่วมมือ

จากรูปที่ 3.7 กลุ่มอาสาสมัครจะได้รับจดหมายขอความร่วมมือจากผู้ทำการวิจัย เนื้อหาของจดหมายจะมีเนื้อหา เช่น รายละเอียดของการเข้าร่วมงานวิจัยในครั้งนี้ ประกอบด้วย ข้อมูลส่วนตัวของผู้วิจัย เหตุผลที่อาสาสมัครท่านนั้นถูกเลือกให้เข้าร่วมการวิจัย รายละเอียดของการวิจัย และช่วงเวลาในการวิจัย

ระบบจะส่งอีเมลไปยังอาสาสมัครที่ยินดีเข้าร่วมงานวิจัยอีกครั้งเพื่อแจ้งวิธีการประเมินระบบแก้อาสาสมัคร

เรียน ท่านศาสตราจารย์ ดร. อรุณรัตน์ อธากอร์ อีเมล Athakorn.O@Chula.ac.th

ขอขอบคุณสำหรับการร่วมงานวิจัย "การประเมินประสิทธิภาพระบบคัดกรองอีเมลขยะโดยผู้ใช้งาน"

เริ่มต้นการประเมินอีเมลของท่านที่

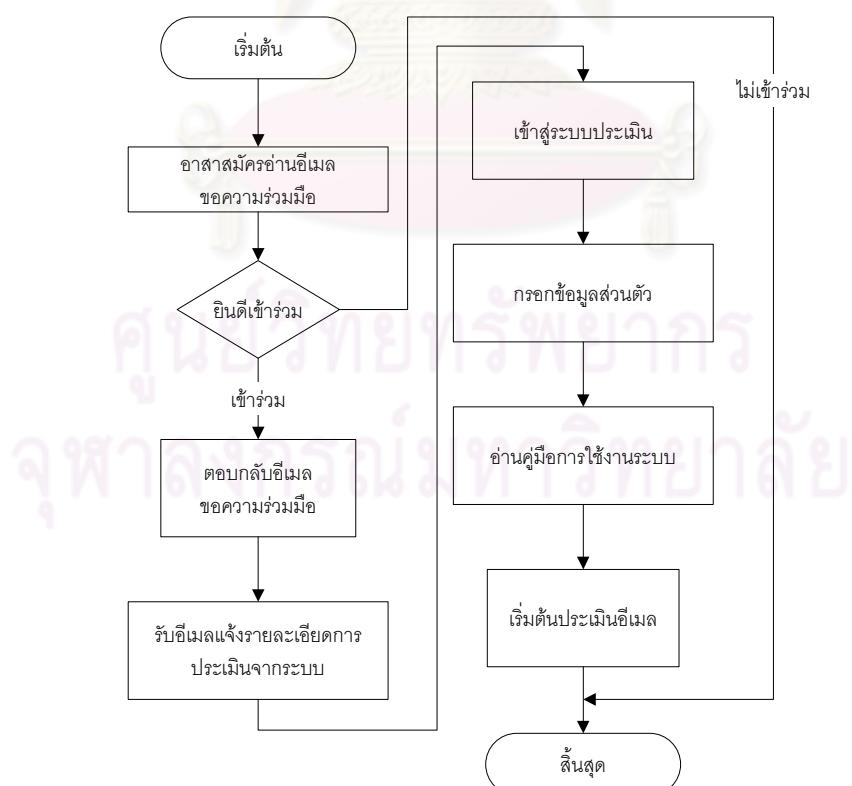
<http://isel.cp.eng.chula.ac.th/SpamFilterEvaluationWeb?acceptedEmail=QXRoYWtvcm4uT0BTdHVkZW50LmNodWxhLmFjLnRo>

ขอแสดงความนับถืออย่างสูง

(นายอรุณรัตน์ อุ่งศรีพิริ)

รูปที่ 3.8 ตัวอย่างจดหมายตอบกลับจากระบบ

รูปที่ 3.8 แสดงจดหมายตอบกลับจากผู้ทำการวิจัย เนื้อหาของจดหมายแจ้งที่อยู่เว็บไซต์ที่อาสาสมัครจะใช้ประเมินอีเมลของตนด้วยตา



รูปที่ 3.9 การเข้าร่วมงานวิจัยของอาสาสมัคร

จากรูปที่ 3.9 เมื่ออาสาสมัครได้รับจดหมายขอความร่วมมือเรียบร้อยแล้ว หากอาสาสมัครยินดีเข้าร่วมงานวิจัย อาสาสมัครจะต้องตอบกลับอีเมลขอความร่วมมืออย่างผู้ส่ง และได้รับอีเมลแจ้งที่อยู่เว็บไซต์สำหรับประเมินอีเมลของตนด้วยตา

เมื่ออาสาสมัครเข้าไปในเว็บไซต์ต้องแสดงตัวโดยการเข้าสู่ระบบ และใช้ชื่อผู้ใช้และรหัสผ่านสำหรับการตรวจสอบอีเมลของจุฬาลงกรณ์มหาวิทยาลัยในการเข้าสู่ระบบ เมื่อทำการเข้าสู่ระบบเรียบร้อยอาสาสมัครต้องกรอกข้อมูลส่วนตัวเพื่อประกอบในการวิเคราะห์ผลการวิจัย ประกอบด้วย เพศ อายุ และสถานภาพ เมื่อกรอกข้อมูลเรียบร้อย ระบบจะแสดงคู่มือการใช้งานแก่อาสาสมัคร เมื่ออาสาสมัครอ่านคู่มือเรียบร้อยระบบจะจึงเริ่มต้นแสดงอีเมลให้อาสาสมัครประเมินทันที

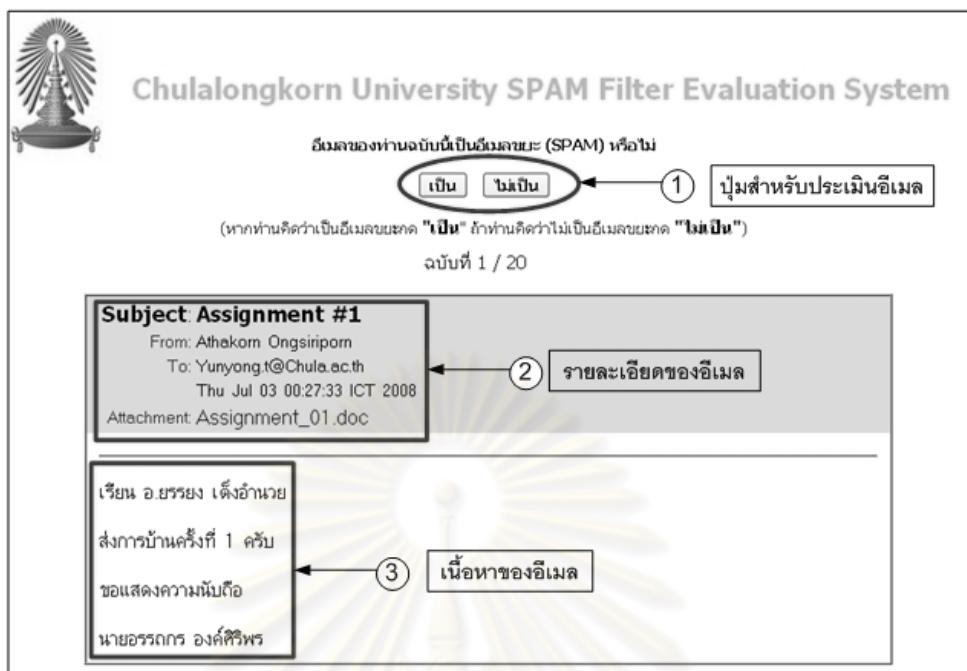
3.8 สุ่มอีเมลของอาสาสมัครแต่ละคนและประเมินอีเมลของตนด้วยตา

งานวิจัยนี้ใช้อาสาสมัครที่เป็นผู้ใช้งานอีเมลขององค์กรเป้าหมายในกระบวนการประเมินประสิทธิภาพ โดยมีหน้าที่ดังกล่าวไปแล้วในหัวข้อ 3.3.1 และ 3.3.2 เมื่ออาสาสมัครผ่านขั้นตอนต่างๆ ดังแสดงในผังงานรูปที่ 3.9 เรียบร้อยแล้ว ระบบจะสุ่มอีเมลของอาสาสมัครคนนั้นขึ้นมาให้ประเมินว่าอีเมลฉบับดังกล่าวเป็นอีเมลขยะหรือไม่

จากการวิเคราะห์ระบบปัจจุบันตามหัวข้อ 3.1 แสดงให้เห็นว่าอาสาสมัครแต่ละคนสามารถมีอีเมลแอดเดรสได้มากกว่า 1 ตัว ดังนั้นการสุ่มอีเมลให้อาสาสมัครแต่ละคนประเมินด้วยตาต้องสุ่มจากทุกอีเมลแอดเดรสที่อาสาสมัครคนนั้นเป็นเจ้าของ

อาสาสมัครแต่ละคนสามารถได้รับจดหมายขอความร่วมมือมากกว่า 1 ฉบับจากผู้วิจัย โดยแต่ละฉบับจะระบุถึงอีเมลที่อาสาสมัครผู้นั้นเป็นเจ้าของ เมื่ออาสาสมัครตอบรับยินดีเข้าร่วมการวิจัยแล้ว การสุ่มอีเมลให้อาสาสมัครพิจารณาด้วยตาต้องสุ่มจากอีเมลทั้งหมดที่อาสาสมัครเป็นเจ้าของหรือเป็นสมาชิกอีเมลกลุ่มนั้น ระบบจะแสดงอีเมลที่ถูกสุ่มให้อาสาสมัครดูด้วยตา และตัดสินว่าอีเมลฉบับนั้นเป็น อีเมลขยะหรือไม่

การสุ่มอีเมลจากคลังอีเมลนั้นใช้วิธีการสุ่มตัวอย่างแบบง่าย (Simple Random Sampling) ซึ่งถือว่าอีเมลทุกฉบับของอาสาสมัครมีความน่าจะเป็นเท่ากันที่จะถูกเลือกให้อาสาสมัครประเมินในแต่ละครั้ง อีเมลที่ถูกประเมินไปแล้วจะไม่ถูกสุ่มขึ้นมาซ้ำอีก และระบบจะสุ่มอีเมลเฉพาะที่อาสาสมัครคนนั้น เป็นเจ้าของเพื่อป้องกันปัญหาความเป็นส่วนตัว



รูปที่ 3.10 ตัวอย่างหน้าจอสำหรับประเมินอีเมลของตนด้วยตา

จากรูปที่ 3.10 หน้าจอสำหรับประเมินอีเมลของตนด้วยตา ถูกออกแบบให้ใช้งานได้ง่าย และไม่สร้างภาระให้แก่ผู้ใช้งาน อาทิ ไม่ต้องอ่านตัวอักษรที่ซ้อนกัน หรือต้องจำลักษณะของตัวอักษร เช่น ตัวอักษรตัวใหญ่ ตัวอักษรตัวเล็ก ตัวอักษรตัวเดียว ตัวอักษรสองตัว เป็นต้น แต่จะใช้การจดจำรูปแบบของอีเมลที่เคย见过 แล้วสามารถจดจำได้โดยอัตโนมัติ

1. ปุ่มสำหรับประเมินอีเมล ประกอบด้วย ปุ่ม “เป็น” และ “ไม่เป็น” อาศัยสมัครใจกดปุ่ม เพื่อตัดสินว่าอีเมลที่ถูกแสดงอยู่นั้น เป็น หรือไม่เป็น อีเมลขยะ

2. รายละเอียดของอีเมล แสดงรายละเอียดของอีเมลที่ถูกแสดงอยู่ในขณะนั้น ประกอบด้วย

- หัวข้อของอีเมล (Subject)
- ผู้ส่ง (From)
- ผู้รับ (To)
- วันที่
- แฟ้มแนบ (Attachment)

3. เนื้อหาของอีเมล แสดงเนื้อหาของอีเมลที่ถูกสูญเสียมาให้ประเมินในขณะนั้น

อาสาสมัครแต่ละคนต้องทำการวิเคราะห์อีเมลของตนเป็นจำนวน 20 อัน แต่สามารถประเมินต่อไปได้หากอาสาสมัครต้องการ ทั้งนี้การไม่สร้างภาระให้แก่อาสาสมัครมากจนเกินไปทำให้สามารถประเมินได้บ่อยครั้งตามต้องการ

3.9 วิเคราะห์และสรุปผลการประเมินประสิทธิภาพ

หลังจากอีเมลถูกคัดกรองโดยระบบคัดกรองแล้วต้องนำมาเปรียบเทียบกับผลการประเมินด้วยตาโดยอาสาสมัคร การวิเคราะห์ผลการประเมินจะต้องกำหนดความหมายของผลการคัดกรองโดยระบบคัดกรองและการประเมินด้วยอาสาสมัคร โดยกำหนดความหมายของค่า True positive (TP), False positive (FP), True negative (TN) และ False negative (FN) ดังแสดงในตารางที่ 3.3 และความหมายทางภาษาพดังแสดงในตารางที่ 3.4

ตารางที่ 3.3 ตารางค่อนพิวชันของผลการคัดกรอง

		ประเมินด้วยอาสาสมัคร	
		อีเมลขยะ	อีเมลดี
คัดกรองโดยระบบคัดกรอง	อีเมลขยะ	TP (%)	FP (%)
	อีเมลดี	FN (%)	TN (%)

ตารางที่ 3.4 ความหมายทางภาษาพดังของผลการคัดกรอง

ผลการคัดกรอง	ความหมายทางภาษาพดัง
TP	สามารถระบุอีเมลขยะได้
TN	สามารถระบุอีเมลดีได้
FP	ระบุอีเมลดีว่าเป็นอีเมลขยะ (อีเมลดีสูญหาย)
FN	ระบุอีเมลขยะว่าเป็นอีเมลดี (อีเมลขยะหลุดลอด)

งานวิจัยนี้วิเคราะห์และสรุปผลการประเมินประสิทธิภาพของระบบคัดกรองอีเมลขยะในประเด็นต่างๆ ดังต่อไปนี้

3.9.1 ประสิทธิภาพโดยรวมของระบบคัดกรอง

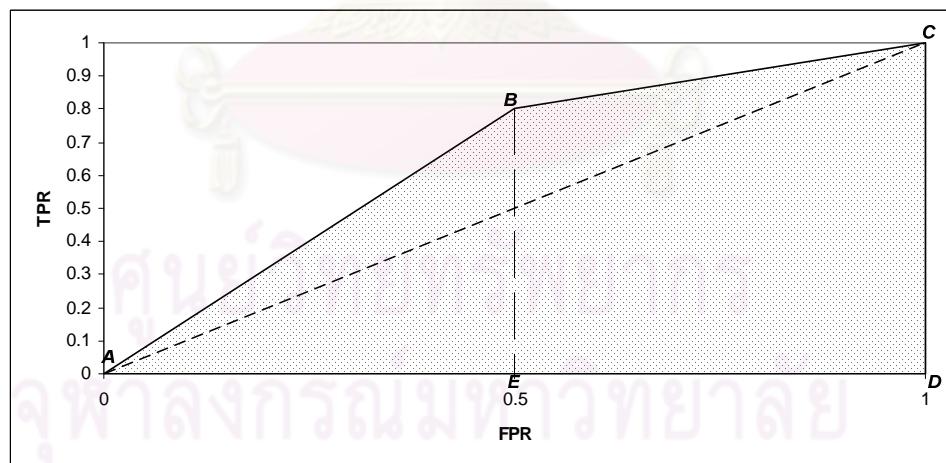
ใช้วิธีทางสถิติวิเคราะห์ประสิทธิภาพของระบบคัดกรองอีเมลขยะ โดยใช้แผนภูมิ Receiver operating characteristic (ROC) [16] และคำนวณพื้นที่ใต้กราฟ (Area under an ROC curve, AUC) เปรียบเทียบค่า AUC ของแต่ละระบบ ระบบใดมีค่า AUC สูงกว่าหมายถึงมีประสิทธิภาพในการคัดกรองอีเมลขยะที่ดีกว่า

แผนภูมิ ROC วัดค่า False positive rate (FPR) บนแกน X และค่า True positive rate (TPR) บนแกน Y ค่า FPR และ TPR คำนวณได้จากสมการที่ (1) และ (2) ตามลำดับ

$$\text{False positive rate (FPR)} = \frac{FP}{(FP + TN)} \quad (1)$$

$$\text{True positive rate (TPR)} = \frac{TP}{(TP + FN)} \quad (2)$$

การวิเคราะห์ด้วยตัวของอาสาสมัครณ์ จัดเป็นตัวคัดกรองแบบดิสครีต (Discrete classifier) [16] ซึ่งมีตารางค่อนพิวชันเพียงตารางเดียว จึงมีเพียง 1 จุดบนแผนภูมิ ROC



รูปที่ 3.11 พื้นที่ใต้แผนภูมิ ROC

จากรูปที่ 3.11 แสดงการพื้นที่ใต้แผนภูมิ ROC สามารถคำนวณพื้นที่ใต้กราฟได้จากสมการที่ (3)

$$AUC = \text{พื้นที่ } ABE + \text{พื้นที่ } BCDE \quad (3)$$

3.9.2 การวิเคราะห์จุดแข็งและจุดด้อยของระบบคัดกรอง

งานวิจัยนี้จะวิเคราะห์จุดแข็งและจุดด้อยของระบบคัดกรองแต่ละตัวโดยวิเคราะห์จากค่า TPR และ FPR โดยมีรายละเอียดดังนี้

3.9.2.1 ระบบคัดกรองที่มีอัตราอีเมลดีสูงหมายน้อยที่สุด

พิจารณาได้จากค่า FPR ของแต่ละระบบคัดกรอง คำนวนได้จากสมการที่ (1) ระบบใดมีค่า FPR ต่ำกว่าหมายถึงมีอัตราอีเมลดีสูงหมายน้อยกว่า แต่ปริมาณอีเมลขยะอาจเพิ่มขึ้น

3.9.2.2 ระบบคัดกรองที่มีอัตราการถูกรบกวนจากอีเมลขยะน้อยที่สุด

พิจารณาได้จากค่า TPR ของแต่ละระบบคัดกรอง คำนวนได้จากสมการที่ (2) ระบบใดมีค่า TPR สูงกว่าหมายถึงมีอัตราการคัดกรองอีเมลที่ดีกว่า แต่อาจมีอีเมลหายบางส่วน

การวิเคราะห์ดังกล่าวจะเป็นทางเลือกให้แก่องค์กรเพื่อเลือกระบบคัดกรองที่เหมาะสมกับความต้องการขององค์กร

**ศูนย์วิทยทรัพยากร
จุฬาลงกรณ์มหาวิทยาลัย**

บทที่ 4

ผลการวิจัย

จากวิธีดำเนินงานวิจัย ผลการวิจัยมีรายละเอียดประกอบด้วย

1. ผลการรวบรวมและวิเคราะห์คลังอีเมลและการคัดเลือกอาสาสมัคร
2. ผลการคัดกรองโดยระบบคัดกรอง
3. ผลการประเมินอีเมลของตนด้วยตัวของอาสาสมัคร
4. ผลการวิเคราะห์และเปรียบเทียบประสิทธิภาพระบบคัดกรองอีเมลขยะ

4.1 ผลการรวบรวมและวิเคราะห์คลังอีเมลและการคัดเลือกอาสาสมัคร

การรวบรวมคลังอีเมลจากระบบเครือข่ายขององค์กรเป้าหมายนั้นต้องรวบรวมอีเมลขาเข้าทั้งอีเมลดีและอีเมลขยะ ระบบอีเมลที่ใช้งานอยู่ในปัจจุบันไม่สามารถสำเนาอีเมลขาเข้าทั้งหมดได้ทันทีเนื่องจากข้อจำกัดของระบบและการรักษาความปลอดภัย อย่างไรก็ต้องสามารถสำเนาอีเมลที่ถูกคัดกรองว่าเป็นอีเมลขยะและอีเมลดีหลังจากทำการคัดกรองแล้วออกมายield ทำให้สามารถรวบรวมได้ทั้งอีเมลดีและอีเมลขยะ ดังนั้นจึงต้องค่าของอีเมลเกตเวย์ให้สำเนามาที่ตู้จดหมายปลายทางเพื่อนำมาใช้เป็นคลังอีเมล

อีเมลที่ถูกคัดลอกจากตู้จดหมายถูกแยกออกเป็น 1 แฟ้มต่ออีเมล 1 ฉบับ วิธีการคัดลอกนั้นสามารถทำได้หลายวิธี เช่น คัดลอกจากตู้จดหมายโดยตรงบนเครื่องแม่ข่าย หรือใช้โปรแกรมอีเมลไคลเอนต์ดาวน์โหลดอีเมลทั้งหมด

ในงานวิจัยนี้ตู้จดหมายที่รวบรวมคลังอีเมลจัดเก็บอีเมล 1 แฟ้มต่อ 1 อีเมลแต่การคัดลอกโดยตรงทำได้ลำบากเนื่องจากต้องใช้สิทธิของผู้ดูแลระบบเท่านั้นในการคัดลอก ผู้วิจัยจึงใช้โปรแกรมอีเมลไคลเอนต์ดาวน์โหลดอีเมลทั้งหมดมาที่เครื่องคอมพิวเตอร์ส่วนบุคคล แต่โปรแกรมอีเมลไคลเอนต์นั้นเก็บอีเมลทุกฉบับในแฟ้มเดียวด้วยรูปแบบของแฟ้มเมลบ็อก (mbox) การแยกออกเป็น 1 แฟ้มต่อ 1 อีเมลใช้โปรแกรม git-mailsplit บนระบบปฏิบัติการพรีบีโ.os ดีแยกอีเมล โดยตั้งชื่อแฟ้มของอีเมลแต่ละฉบับเป็นลำดับตัวเลขคือ 1, 2, 3 ตามลำดับ โดยมีรายละเอียดของการรวบรวมอีเมลจากองค์กรเป้าหมายดังแสดงในตารางที่ 4.1

ตารางที่ 4.1 รายละเอียดของคลังอีเมล

หัวข้อ	ข้อมูล
เริ่มต้นรวม	14 กรกฎาคม 2552
รวมรวมถึง	5 สิงหาคม 2552
รวมระยะเวลา	22 วัน
ขนาดคลังอีเมล	134,167 ฉบับ
จำนวนอีเมลถึงตู้จดหมายผู้รับ	165, 085 ฉบับ (ฉบับเดียวถึงหลายคน)

หลังจากการบรวมคลังอีเมลแล้วจึงทำการวิเคราะห์เพื่อหาอีเมลแอดเดรสที่มีปริมาณอีเมล
ขาเข้ามากที่สุด โดยใช้วิธีในข้อ 3.2 และใช้ตารางแจกแจงความถี่วิเคราะห์หาอีเมลแอดเดรสที่มี
ปริมาณอีเมลที่เหมาะสมสำหรับเป็นกลุ่มอาสาสมัคร

ตารางที่ 4.2 ตารางแจกแจงความถี่ของปริมาณอีเมลขาเข้าแต่ละอีเมลแอดเดรส

ชั้นที่	จำนวนอีเมล	อีเมลแอดเดรส	ชั้นที่	จำนวนอีเมล	อีเมลแอดเดรส
1	1-50	7,517	26	1,251-1,300	1
2	51-100	653	27	1,301-1,350	2
3	101-150	238	28	1,351-1,400	0
4	151-200	96	29	1,401-1,450	0
5	201-250	50	30	1,451-1,500	0
6	251-300	27	31	1,501-1,550	0
7	301-350	25	32	1,551-1,600	0
8	351-400	12	33	1,601-1,650	2
9	401-450	7	34	1,651-1,700	1
10	451-500	1	35	1,701-1,750	0
11	501-550	1	36	1,751-1,800	0
12	551-600	2	37	1,801-1,850	0
13	601-650	0	38	1,851-1,900	0
14	651-700	2	39	1,901-1,950	2
15	701-750	3	40	1,951-2,000	0
16	751-800	0	41	2,001-2,050	0
17	801-850	0	42	2,051-2,100	0

ตารางที่ 4.2 (ต่อ)

ชั้นที่	จำนวนอีเมล	อีเมลแอดเดรส	ชั้นที่	จำนวนอีเมล	อีเมลแอดเดรส
18	851-900	0	43	2,101-2,150	0
19	901-950	1	44	2,151-2,200	0
20	951-1,000	1	45	2,201-2,250	0
21	1,001-1,050	0	46	2,251-2,300	1
22	1,051-1,100	0	47	2,301-2,350	0
23	1,101-1,150	0	48	2,351-2,400	2
24	1,151-1,200	0	49	2,401-2,450	0
25	1,201-1,250	0	50	2,451-2,500	1

จากตารางที่ 4.2 อีเมลส่วนใหญ่มีปริมาณอีเมลขาเข้า 1 ถึง 50 ฉบับในระยะเวลา 22 วัน ซึ่งคิดเป็น 2.27 ฉบับต่อวัน และเมื่อคูณจากข้อมูลดิบแล้วพบว่า ส่วนมากมีจำนวน 1 ฉบับเท่านั้น แสดงถึงปริมาณการใช้งานที่ต่ำเกินไป ดังนั้นจึงให้เจ้าของอีเมลแอดเดรสที่มีปริมาณอีเมลขาเข้ามากกว่า 50 ฉบับ เป็นก渌ุ่มอาสาสมัครในการวิจัยนี้โดยมีจำนวนทั้งสิ้น 849 อีเมลแอดเดรส

4.2 ผลการคัดกรองโดยระบบคัดกรอง

งานวิจัยนี้ทำการทดสอบระบบคัดกรอง 3 ประเภท คือระบบเก่า ระบบปัจจุบัน และระบบอ้างอิง ขณะทำการทดลองเป็นระบบคัดกรองเก่าและระบบปัจจุบัน กำลังใช้งานอยู่ในองค์กร เป้าหมายดังนั้นการทดลองต้องคำนึงถึงผลกระทบต่อผู้ที่กำลังใช้งาน โดยไม่ป้อนคลังอีเมลผ่านระบบคัดกรองดังกล่าวในช่วงไม่ทำงาน

ระบบปัจจุบันที่ใช้งานในองค์กรเป้าหมายนั้นเป็นระบบคัดกรองใหม่ที่นำมาใช้งานจึงมีความทันสมัยและมีระบบรักษาความปลอดภัยที่ดี การป้อนอีเมลผ่านระบบดังกล่าวจะดำเนินต่อไป ป้อนครั้งละน้อยๆ การป้อนอีเมลปริมาณมากจะทำให้ระบบคัดกรองบันทึกหมายเลขอพีของเครื่องคอมพิวเตอร์ในบัญชีดำเนินการของระบบพบร่วมกับเครื่องคอมพิวเตอร์ที่มีแนวโน้มในการส่งอีเมลขยะเข้ามาทำให้ไม่สามารถป้อนอีเมลผ่านไปได้ สำหรับระบบเก่าสามารถป้อนคลังอีเมลได้อย่างสะดวกไม่มีปัญหาดังเช่นระบบคัดกรองปัจจุบัน ด้านระบบอ้างอิงเป็นระบบที่สร้างขึ้นภายในห้องทดลองดังนั้นจึงสามารถควบคุมและตั้งค่าต่างๆ ได้ การป้อนคลังอีเมลผ่านจึงทำได้จำกัดที่สุด ผลการคัดกรองแสดงดังตารางที่ 4.3

ตารางที่ 4.3 ผลการคัดกรองของระบบคัดกรองอีเมลขยะ

ระบบ คัดกรอง	อีเมลขยะ	ร้อยละอีเมลขยะ	อีเมลดี	ร้อยละอีเมลดี	รวม (ฉบับ)
ระบบเก่า	85,417	51.74%	79,668	48.26%	165,085
ระบบปัจจุบัน	67,262	40.74%	97,823	59.26%	165,085
ระบบข้างอิส	82,572	50.02%	82,513	49.98%	165,085

จากตารางที่ 4.3 ระบบคัดกรองข้างต้นจะต้องนำไปเปรียบเทียบกับการประเมินด้วยตาของอาสาสมัครเพื่อตรวจสอบความถูกต้องของผลการคัดกรอง เพื่อให้ประเมินประสิทธิภาพของแต่ละระบบ

ในช่วงเริ่มต้นทดลองการป้อนคลังอีเมลบางครั้งเกิดปัญหา เช่น โปรแกรมสำหรับป้อนคลังอีเมลยังมีข้อผิดพลาดบางส่วน เป็นผลให้ทำงานผิดพลาดและจัดการกับข้อผิดพลาดไม่เหมาะสมทำให้ต้องทดลองซ้ำบ่อยครั้ง แต่เมื่อทำการทดลองมาเป็นระยะเวลาหนึ่งโปรแกรมมีเสถียรภาพมากขึ้น และข้อผิดพลาดถูกแก้ไข ทำให้ปัญหาในการทดลองลดน้อยลง

4.3 ผลการประเมินอีเมลของตนด้วยตาของอาสาสมัคร

จากการวิเคราะห์ในหัวข้อ 4.1 อาสาสมัครของงานวิจัยนี้คือเจ้าของอีเมลที่มีปีริมาณอีเมลเข้ามากกว่า 50 ฉบับ จากหัวข้อ 3.7 เมื่อส่งอีเมลขอความร่วมมือและขออนุญาตไปยังอาสาสมัครที่มีปีริมาณอีเมลเข้าตามจำนวนที่กำหนด อาสาสมัครบางส่วนตอบรับเข้าร่วมในทันที ซึ่งรายละเอียดการติดต่อไปยังอาสาสมัครแสดงดังตารางที่ 4.4

ตารางที่ 4.4 ผลการติดต่ออาสาสมัคร

หัวข้อ	จำนวน
จำนวนอาสาสมัครที่ติดต่อ	849 คน
จำนวนอาสาสมัครที่ตอบรับ	60 คน
ร้อยละของอาสาสมัครที่ตอบรับ	7.06

มีอาสาสมัครตอบรับเข้าร่วมงานวิจัยทั้งสิ้น 60 คน คิดเป็นร้อยละ 7.06 ของกลุ่มอาสาสมัครที่ปีริมาณอีเมลตามเกณฑ์ อาสาสมัครบางกลุ่มทำการประเมินด้วยตาในทันทีหลังจากตอบรับเข้าร่วมงานวิจัย ซึ่งรายละเอียดของการประเมินและการประเมินแสดงดังตารางที่ 4.5

ตารางที่ 4.5 รายละเอียดของการประเมินด้วยตาของอาสาสมัคร

หัวข้อ	จำนวน
จำนวนอีเมลที่ถูกประเมิน	2,783 ฉบับ
ร้อยละของจำนวนอีเมลที่ถูกประเมิน	1.69
เฉลี่ยประเมินคนละ (กำหนดไว้ที่ 20 ฉบับ)	46.38 ฉบับ
ระยะเวลา	14 วัน

จากตารางที่ 4.5 อาสาสมัครที่เข้าร่วมงานวิจัยทั้ง 60 คน ประเมินอีเมลรวมกันทั้งหมด 2,783 ฉบับ คิดเป็นร้อยละ 1.69 ของปริมาณอีเมลในคลัง อาสาสมัครแต่ละคนทำการประเมินโดยเฉลี่ย 46.38 ฉบับ จากข้อมูลข้างต้นอาสาสมัครให้การตอบรับอย่างดีต่อกระบวนการประเมินประสิทธิภาพระบบคัดกรองอีเมลขยะขององค์กรเป็นอย่างมาก เนื่องจากอาสาสมัครมีอัตราการประเมินอีเมลที่สูง การประเมินโดยอาสาสมัครใช้เวลาทั้งสิ้น 14 วัน ตั้งแต่เริ่มดำเนินติดต่อไปยังอาสาสมัคร

จากหัวข้อ 3.3 หน้าที่ของอาสาสมัครในการประเมินประสิทธิภาพระบบคัดกรองอีเมล ขymee 2 ประการ จากหัวข้อ 3.3.2 ผลการคัดกรองกลุ่มตัวอย่างอีเมลที่สูญจากคลังอีเมลแสดงดัง ตารางที่ 4.6

ตารางที่ 4.6 ผลการคัดกรองตัวอย่างอีเมลของอาสาสมัคร

อีเมลขยะ (ฉบับ)	ร้อยละอีเมลขยะ	อีเมลดี (ฉบับ)	ร้อยละอีเมลดี	รวม (ฉบับ)
1,604	57.64%	1,179	42.36%	2,783

จากตารางที่ 4.6 จำนวนอีเมลที่ถูกประเมินคือ 2,783 ฉบับ เป็นอีเมลขยะ 1,604 ฉบับ คิดเป็นร้อยละ 57.64 ของอีเมลที่ถูกประเมิน และเป็นอีเมลดี 1,179 ฉบับ คิดเป็นร้อยละ 42.36 ของอีเมลที่ถูกประเมิน เมื่อเปรียบเทียบข้อมูลจากตารางที่ 4.3 และตารางที่ 4.6 พบร่วมกันว่า ผลการคัดกรองของระบบคัดกรองเก่าและระบบคัดกรองอ้างอิงนั้นใกล้เคียงกับผลการคัดกรองของอาสาสมัคร อย่างไรก็ได้กิจกรรมที่ถูกประเมินของระบบคัดกรองทั้งสาม จำต้องวิเคราะห์ในรายละเอียดดังได้อธิบายไว้ในข้อ 3.9

จากวิธีการกำหนดขนาดกลุ่มตัวอย่างของ ทาโว่ ยามานะ [9] อีเมลที่ถูกประเมินด้วยตาของอาสาสมัครมีปริมาณมากพอเพื่อให้เป็นกลุ่มตัวอย่างของคลังอีเมลในงานวิจัยนี้ที่ระดับความ

เชื่อมั่น $95\% \pm 2\%$ ดังนั้นสามารถใช้เป็นตัวแทนอีเมลทั้งหมดในคลังอีเมลได้ และจะนำมาเปรียบเทียบกับผลการคัดกรองของระบบคัดกรองอีเมลขยะต่อไป

4.4 ผลการวิเคราะห์และเปรียบเทียบประสิทธิภาพระบบคัดกรองอีเมลขยะ

การวิเคราะห์ประสิทธิภาพของระบบคัดกรองให้วิธีตามหัวข้อ 3.9 โดยคำนวณค่าตามตารางค่อนติงเจนซีของแต่ละระบบเพื่อวิเคราะห์ประสิทธิภาพของแต่ละระบบคัดกรอง ผลการคำนวณแสดงตามตารางที่ 4.7 นำค่าจากตารางที่ 4.7 มาคำนวณค่า TPR และ FPR เพื่อวัดแผนภูมิ ROC ตารางที่ 4.8 แสดงค่าทั้งสองของแต่ละระบบคัดกรอง และวัดแผนภูมิ ROC ดังรูปที่ 4.1

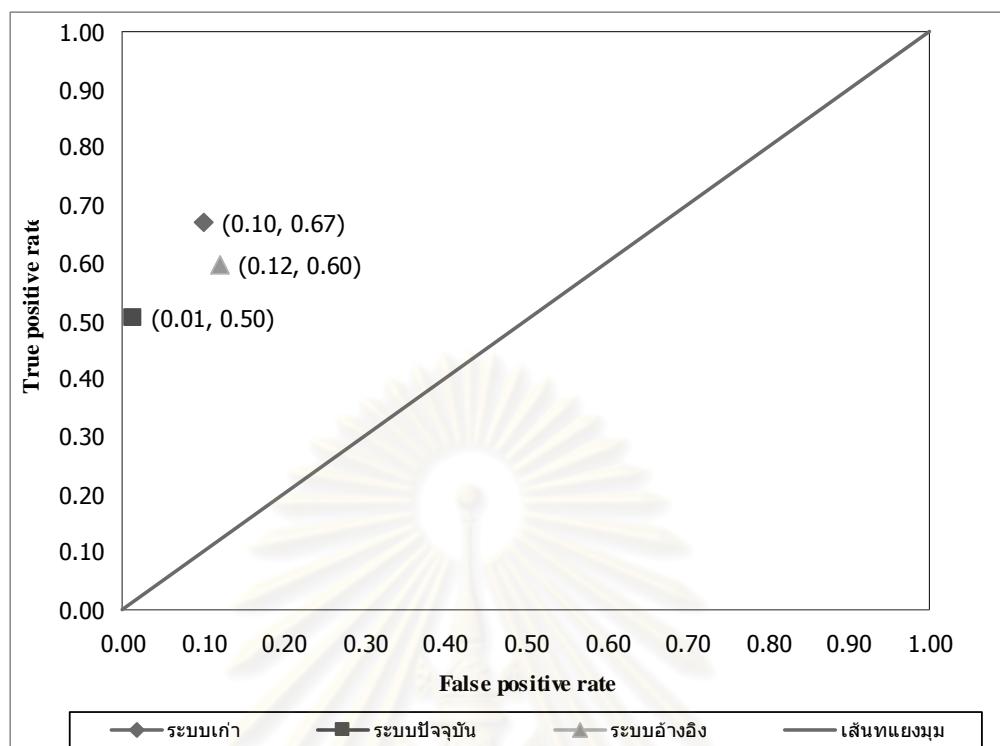
ตารางที่ 4.7 ตารางค่อนติงเจนซีของแต่ละระบบคัดกรองอีเมลขยะ

ระบบคัดกรอง	TP	FP	FN	TN
ระบบเก่า	38.52%	4.31%	19.12%	38.05%
ระบบปัจจุบัน	29.03%	0.54%	28.60%	41.83%
ระบบอ้างอิง	34.35%	5.17%	23.28%	37.19%

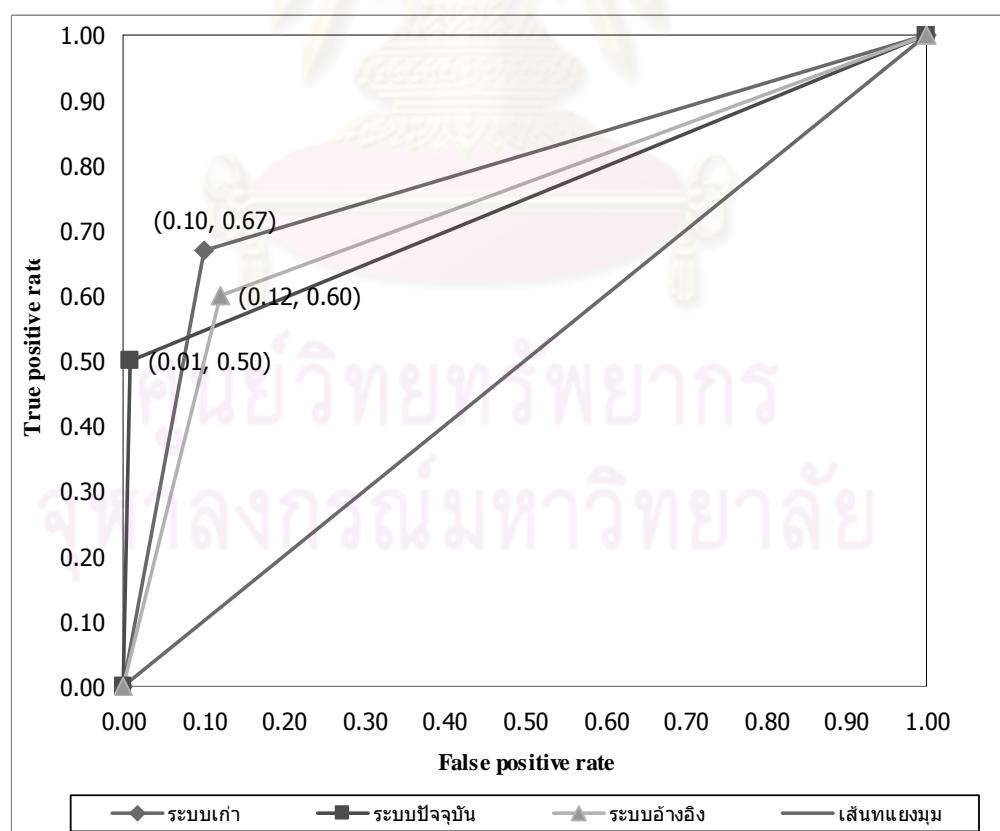
ตารางที่ 4.8 ค่า FPR และ TPR ของแต่ละระบบคัดกรอง

ระบบคัดกรอง	FPR	TPR
ระบบเก่า	0.10	0.67
ระบบปัจจุบัน	0.01	0.50
ระบบอ้างอิง	0.12	0.60

ศูนย์วิทยทรพยากร
จุฬาลงกรณ์มหาวิทยาลัย



ຮູບທີ 4.1 ແຜນກຸມ ROC ຂອງກາງປະເມີນປະສິທິພາພະບັບດັດກາຮອງອື່ເມລຂະຢະ



ຮູບທີ 4.2 ແຜນກຸມ ROC ຂອງກາງປະເມີນສໍາຮັບຄຳນວນຄ່າ AUC

จากรูปที่ 4.1 ลากเส้นจากจุด (0,0) ผ่านจุด (FPR,TPR) ไปยังจุด (1,1) ได้ดังภาพที่ 4.2 คำนวณหาค่า AUC จากรูปที่ 4.2 เพื่อวิเคราะห์ประสิทธิภาพของระบบคัดกรองอีเมลขยะดังแสดงในตารางที่ 4.9

ตารางที่ 4.9 ค่า AUC ของแต่ละระบบคัดกรอง

ระบบคัดกรอง	AUC
ระบบเก่า	0.79
ระบบปัจจุบัน	0.75
ระบบอ้างอิง	0.74

จากผลการทดลองที่กล่าวมาสามารถสรุปและวิเคราะห์ผลการทดลองได้ดังนี้

4.4.1 ประสิทธิภาพโดยรวมของระบบคัดกรอง

จากค่า AUC ตามตารางที่ 4.9 ระบบคัดกรองอีเมลขยะที่มีประสิทธิภาพโดยรวมสูงสุดในการคัดกรองอีเมลขยะคือระบบคัดกรองเก่า ซึ่งมีค่า AUC สูงสุด โดยมีประสิทธิภาพในการคัดกรองอีเมลขยะได้ดีที่สุด

4.4.2 การวิเคราะห์จุดแข็งและจุดด้อยของระบบคัดกรอง

จากผลการทดลองจากตารางที่ 4.8 สามารถวิเคราะห์ถึงจุดเด่นและจุดด้อยของแต่ละระบบซึ่งผลการทดลองจะชี้ให้เห็นข้อดีและข้อเสียของแต่ละระบบคัดกรอง ในงานวิจัยนี้จะวิเคราะห์ 2 ด้าน ซึ่งกำหนดไว้ในข้อ 3.9 ดังต่อไปนี้

4.4.2.1 ระบบคัดกรองที่มีอัตราอีเมลถูกหลอกน้อยที่สุด

จากตารางที่ 4.8 ค่า FPR ของระบบปัจจุบันมีค่าต่ำที่สุด แสดงว่ามีอัตราอีเมลถูกคัดกรองเป็นอีเมลขยะน้อยที่สุดหรือมีอัตราที่อีเมลสำคัญจะหายน้อยที่สุด แต่จะมีปริมาณอีเมลขยะเพิ่มขึ้นมาในตู้จดหมายมากขึ้น หากองค์กรเป้าหมายต้องการระบบคัดกรองที่ปลดภัยคือไม่ทำอีเมลสำคัญหายระบบคัดกรองปัจจุบันเป็นตัวเลือกที่เหมาะสมที่สุด

4.4.2.2 ระบบคัดกรองที่มีอัตราการถูกหลอกจากอีเมลขยะน้อยที่สุด

จากตารางที่ 4.8 ค่า TPR ของระบบคัดกรองเก่ามีค่าสูงที่สุด แสดงว่ามีอัตราการคัดกรองอีเมลขยะได้ดีที่สุด ทำให้อีเมลขยะเข้ามายังตู้จดหมายได้น้อย อย่างไรก็ได้อาจ

มีอีเมลสำคัญหลายไปบางส่วน หากองค์กรเป้าหมายต้องการระบบคัดกรองที่สามารถคัดกรองอีเมล ขยะได้ระบบคัดกรองเก่าจะเป็นตัวเลือกที่เหมาะสมที่สุด

ผลการประเมินประสิทธิภาพสามารถสรุปได้ดังตารางที่ 4.10

ตารางที่ 4.10 สรุปผลการประเมินประสิทธิภาพ

หัวข้อ	ระบบคัดกรอง
ระบบที่มีประสิทธิภาพสูงสุด	ระบบเก่า
ระบบที่อีเมลติดลบหายน้อยที่สุด	ระบบปัจจุบัน
ระบบที่อีเมลขยะพบวันน้อยที่สุด	ระบบเก่า

การเลือกระบบคัดกรองให้เหมาะสมกับความต้องการขององค์กร เมื่อข้างต้นจากผลการทดลองข้างต้น ทำให้ประลิทธิภาพการทำงานของระบบคัดกรองดียิ่งขึ้นและถูกต้องตรงกับความต้องการของผู้ใช้งานในองค์กรนั้นๆ เนื่องจากกระบวนการทั้งหมดใช้อีเมลจริงและอาสาสมัครซึ่งเป็นผู้ใช้งานจริงในการประเมินเพื่อให้ใกล้เคียงกับสภาพความเป็นจริงมากที่สุด อย่างไรก็ได้ประเด็นสำคัญที่งานวิจัยนี้เน้นเป็นอย่างยิ่งคือปัญหาความเป็นส่วนตัวของผู้ใช้ กระบวนการต่างๆ อาศัยจำกัดสิทธิ์ของอาสาสมัครแต่ละคนให้สามารถเห็นและประเมินได้เฉพาะอีเมลของตนเท่านั้น

**ศูนย์วิทยทรัพยากร
จุฬาลงกรณ์มหาวิทยาลัย**

บทที่ 5

สรุปผลการวิจัยและข้อเสนอแนะ

5.1 สรุปผลการวิจัย

งานวิจัยนี้นำเสนอกลไตรัตน์ สำหรับประเมินประสิทธิภาพของระบบคัดกรองอีเมลขยะ โดยเจ้าของอีเมล ซึ่งประเมินในสภาพใกล้เคียงกับความเป็นจริง ใช้อีเมลจริงเป็นคลังอีเมลและให้ผู้ใช้งานจริงจากองค์กรเป้าหมายเป็นอาสาสมัครเพื่อเข้าร่วมในกระบวนการประเมิน โดยกระบวนการวิธินี้จะใช้เป็นเครื่องมือสำหรับใช้เปรียบเทียบประสิทธิภาพของระบบคัดกรองอีเมลขยะ เพื่อใช้ผลการประเมินประกอบการตัดสินใจเลือกใช้ จดชื่อ หรือวางแผนในการพัฒนาประสิทธิภาพของระบบคัดกรอง กระบวนการประเมินจะเปรียบเทียบการคัดกรองอีเมลขยะระหว่างระบบคัดกรองทั่วไปกับการคัดกรองโดยอาสาสมัครซึ่งเป็นระบบคัดกรองในอุดมคติ สามารถคัดกรองได้อย่างไม่มีข้อผิดพลาด อาสาสมัครเข้าร่วมการประเมินผ่านเว็บไซต์ที่ง่ายต่อการใช้งานและไม่เป็นภาระแก่อาสาสมัครจนเกินไป กระบวนการประเมินจะไม่ก่อให้เกิดปัญหาความเป็นส่วนต่ออาสาสมัครอาสาสมัครสามารถมองเห็นและประเมินได้เฉพาะอีเมลของตนเท่านั้น เนื่องจากกระบวนการประเมินของอาสาสมัครไม่เป็นภาระแก่อาสาสมัครจนเกินไปทำให้สามารถประเมินได้บ่อยครั้งตามต้องการ ซึ่งเป็นประโยชน์ต่อการปรับปรุงและพัฒนาประสิทธิภาพของระบบคัดกรองอีเมลขยะอาสาสมัครที่เคยเข้าร่วมกระบวนการสามารถกำหนดให้เป็นตัวแทนขององค์กรเป้าหมายสำหรับการประเมินในครั้งต่อๆ ไปได้

ในส่วนของการทดลอง งานวิจัยนี้นำกระบวนการวิธีที่ออกแบบมาสร้างเป็นระบบจริงเพื่อเปรียบเทียบระบบคัดกรองเก่า ระบบปัจจุบัน และระบบข้างต้น กับการประเมินโดยอาสาสมัครโดยมีสมมติฐานว่าอาสาสมัครเป็นระบบคัดกรองในอุดมคติ ระบบทำการป้อนคลังอีเมลผ่านระบบคัดกรองทั้งสามระบบ สูมตัวอย่างอีเมลของอาสาสมัครแต่ละคนจากคลังอีเมลให้เจ้าของอีเมลประเมินด้วยตา ใช้วิธีการกำหนดตัวของ ท่าโrise ยามาเน่ [9] กำหนดขนาดตัวอย่างที่เหมาะสมกับขนาดของคลังอีเมล อาสาสมัครสามารถเลือกประเมินอีเมลของตนได้มากกว่าหรือเท่ากับขนาดตัวอย่างที่กำหนดให้ จากนั้นจึงจะใช้วิธีทางสถิติวิเคราะห์ประสิทธิภาพโดยรวมของระบบคัดกรอง วิเคราะห์ข้อมูลและข้อด้อยของแต่ละระบบ และสรุปผลการประเมินประสิทธิภาพ

ผลการเปรียบเทียบประสิทธิภาพของระบบเก่า และระบบปัจจุบัน กับระบบข้างต้นพบว่า ประสิทธิภาพของระบบคัดกรองข้างต้นใกล้เคียงกับระบบทั้งสอง ซึ่งระบบคัดกรองข้างต้นเป็นอีก

ทางเลือกสำหรับองค์กร หากพัฒนาระบบคัดกรองอ้างอิงอย่างต่อเนื่องอาจทำให้ประสิทธิภาพของ การคัดกรองใกล้เดียงกับระบบคัดกรองที่ขายในห้องตลาด

จากผลการวิจัยและทดสอบกระบวนการวิธีสามารถสรุปได้ดังนี้

5.1.1 กระบวนการวิธีที่ออกแบบและผลการทดลองในงานวิจัยนี้สามารถประเมิน ประสิทธิภาพของระบบคัดกรองอีเมลขยะได้ โดยสามารถวิเคราะห์ค่า TP, TN, FP และ FN สำหรับค่านวนค่า AUC TPR และ FPR เพื่อใช้ในการวิเคราะห์ เปรียบเทียบประสิทธิภาพของระบบคัดกรอง และสรุปผลการประเมินได้

5.1.2 คลังอีเมลที่ใช้ในการวิจัยมีปริมาณอีเมลเพียงพอและประกอบด้วยอีเมลของผู้ใช้งานจำนวนมากที่จะใช้ในงานวิจัย ทำให้สามารถวิเคราะห์และประเมินประสิทธิภาพของระบบคัดกรองอีเมลขยะได้

5.1.3 จากกระบวนการวิธีที่ออกแบบ กลุ่มอาสาสมัครจะประเมินผ่านเครื่องมือที่ใช้งานง่าย อีกทั้งการสุมอีเมลช่วยลดภาระของอาสาสมัคร และมีการรักษาความเป็นส่วนตัวอย่างดี เป็นผลให้อาสาสมัครยินดีเข้าร่วมกระบวนการประเมิน และปริมาณอีเมลที่ถูกประเมินสูงเกินขนาดตัวอย่าง ที่กำหนด ทำให้สามารถสรุปผลการทดลองได้เร็ว

5.1.4 จากผลการทดลองระบบคัดกรองที่มีประสิทธิภาพสูงสุดคือ ระบบที่มีค่า AUC สูงที่สุด ระบบที่ปริมาณอีเมลต่ัญหยานน้อยที่สุดคือ ระบบที่มีค่า FPR ต่ำที่สุด และ ระบบที่มีปริมาณอีเมลขยะรบกวนน้อยที่สุดคือที่มีค่า TPR สูงที่สุด

5.1.5 กระบวนการวิธีที่ออกแบบสามารถประเมินประสิทธิภาพระบบคัดกรองอีเมลขยะได้แม้มีเพียงระบบเดียว โดยเป็นการเปลี่ยนเทียบกับระบบในอดีต

5.2 ปัญหาและข้อเสนอแนะ

5.2.1 ในขณะเริ่มต้นวิจัยองค์กรเป้าหมายมีการเปลี่ยนแปลงระบบอีเมลทำให้การดำเนินการทดลองเป็นไปอย่างยากลำบาก

5.2.2 คลังอีเมลที่ใช้ในการทดลองไม่เก็บสมัยนานกันเนื่องจากถูกรวมก่อนการประเมินโดยอาสาสมัครเป็นเวลาประมาณ 4 เดือน อาจทำให้เนื้อหาในอีเมลนั้นล้าสมัยไป เป็นผลให้การประเมินผิดพลาด ควรใช้คลังอีเมลที่รวมไว้ไม่นานเกินไปในกระบวนการทดลอง

5.2.3 เนื่องจากองค์กรเป้าหมายมีระบบรักษาความปลอดภัยสูง การป้อนอีเมลผ่านระบบคัดกรองปัจจุบันทำได้ยากลำบาก โดยต้องแบ่งป้อนคลังอีเมลครั้งละ 10,000 อีเมล เพื่อป้องกันระบบคัดกรองตัดสินว่ากระบวนการประมวลผลกำลังส่งอีเมลขยะเข้ามาอย่างองค์กรเป้าหมาย ต้องพัฒนาต่อไปให้ระบบประมวลผลประสิทธิภาพเป็นส่วนหนึ่งของอีเมลเพื่อจะสามารถใช้งานได้สะดวกขึ้น

5.2.4 การสุมตัวอย่างอีเมลในการทดสอบนี้ใช้การสุมอีเมลแบบง่าย ควรศึกษาวิธีการสุมตัวอย่างเพิ่มเติม เพื่อให้สามารถกำหนดกลุ่มตัวอย่างได้ดีขึ้น

5.2.5 จากตารางที่ 4.2 อาสาสมัครให้ความร่วมมือเป็นอย่างดี หากพัฒนากระบวนการประมวลและการติดต่อประสานงานกับอาสาสมัครให้ดียิ่งขึ้น อาจทำให้ผู้ใช้งานทุกคนยินดีเข้าร่วมกระบวนการประมวล ทำให้ผลการประมวลมีความถูกต้องมากยิ่งขึ้น

5.2.6 ไม่สามารถปิดระบบ SenderBase ที่องค์กรเป้าหมายใช้งานได้เนื่องจากมีผลกระทบต่องค์กรพสมควร ทำให้ปริมาณอีเมลขยะที่รวมเป็นคลังอีเมลลดลง ควรปิดระบบ SenderBase เพื่อร่วมคลังอีเมลเพื่อให้คลังอีเมลใกล้เคียงกับสภาพการณ์จริงมากยิ่งขึ้น

5.3 งานวิจัยในอนาคต

5.3.1 การเปรียบเทียบระบบคัดกรองอีเมลขยะราคาแพงกับระบบคัดกรองจากโปรแกรมแจกฟรี

5.3.2 โปรแกรมโอลเอนชอร์สสำหรับประมวลประสิทธิภาพระบบคัดกรองอีเมลขยะโดยเจ้าของอีเมล

5.3.3 พัฒนาโมดูลสำหรับประมวลประสิทธิภาพให้เป็นส่วนหนึ่งในระบบอีเมลขององค์กรเป้าหมาย

5.3.4 การวิเคราะห์ความเบี่ยงเบนของการคัดกรองจากผลการคัดกรองของอาสาสมัคร (ระบบในอุดมคติ) ซึ่งนำไปใช้เป็นแนวทางในการปรับปรุงระบบคัดกรอง ทั้งในการใช้งานและข้างในเชิงวิจัย รวมถึงประโยชน์ในการพัฒนาโปรแกรมแจกฟรี หรือโอลเอนชอร์ส

5.3.5 การเพิ่มจำนวนอาสาสมัครเพื่อกำหนดค่าใช้จ่ายของระบบคัดกรองอีเมลขยะโดยเจ้าของอีเมล

รายการอ้างอิง

- [1] The SenderBase Network. Global SPAM Volume. Available from:
http://www.senderbase.org/home/detail_spam_volume. [2010, January 25]
- [2] Hoanca, B. How good are our weapons in the spam wars? Technology and Society Magazine, IEEE 25(1): 22-30, 2006.
- [3] Fumera, G., Pillai, I., and Roli, F. Spam filtering based on the analysis of text information embedded into images Journal of Machine Learning Research, 2699-2720, 2006.
- [4] Blanzieri, E., and Bryl, A. A survey of anti-spam techniques. Technical report. 2006, 2008.
- [5] Cormack, G. V., and Lynam, T. R. Online supervised spam filter evaluation. ACM Trans. 2007.
- [6] Lai, C., and Tsai, M. An empirical performance comparison of machine learning methods for spam e-mail categorization. Hybrid Intelligent Systems. HIS '04. Fourth International Conference on, 5-8 Dec. 2004, 44-48, 2004.
- [7] Tran, M., and Armitage, G. End-users' resource consumption of spam and a 3D anti-spam evaluation framework. TENCON 2005 IEEE Region 10, 2005.
- [8] Yeh, C., Wu, C., and Doong, S. Effective spam classification based on meta-heuristics Systems, Man and Cybernetics. 2005 IEEE International Conference, Vol. 4. 3872-3877, 2005.
- [9] Glenn, D. I. Determining Sample Size. Agricultural education and communication department, Florida cooperative extension service, Institute of food and agricultural sciences, University of Florida, 2003.
- [10] Schryen, G. Anti – Spam Measures analysis and design. New York: Springer. 2005.
- [11] Spamhaus, Spamhaus Statistics: The Top 10, Available from:
<http://www.spamhaus.org/statistics/countries.lasso>, 2006.
- [12] IronPort Systems. Spam Cop. Available from: <http://www.spamcop.net/> [2008, June 21]

- [13] Diesner, J., and Carley, K. M., Exploration of Communication Networks from the Enron Email Corpus. Proceedings of Workshop on Link Analysis, Counterterrorism and Security, SIAM International Conference on Data Mining. Newport Beach, CA, 2005, 3-14.
- [14] Cauce [Online]. Available from: <http://www.cauce.org/> [2008, July 30].
- [15] The SenderBase Network. Cisco IronPort SenderBase Security Network. Available from: <http://www.senderbase.org/>. [2010, January 25]
- [16] F. Tom, "An intorduction to ROC analysis," Pattern recognition letters 27, 861-874, 2006
- [17] Garcia, F. D., Hoepman, J. H., and Van Nieuwenhuizen, J. Spam Filter Analysis. Security and Protection in Information Processing Systems. IFIP TC11 19th International Information Security Conference (SEC2004), 395-410, Toulouse, France: Kluwer Academic Publishers, 2004.



ภาคนวาก

ศูนย์วิทยทรัพยากร จุฬาลงกรณ์มหาวิทยาลัย

ค่ามาตรฐานของโปรแกรมสเปมแอกแซสซิน

```

# This is the right place to customize your installation of SpamAssassin.
#
# See 'perldoc Mail::SpamAssassin::Conf' for details of what can be
# tweaked.
#
# Only a small subset of options are listed below
#
#####
#
# Add *****SPAM***** to the Subject header of spam e-mails
#
rewrite_header Subject *****SPAM*****
#
# Save spam messages as a message/rfc822 MIME attachment instead of
# modifying the original message (0: off, 2: use text/plain instead)
#
report_safe 0
#
# Set which networks or hosts are considered 'trusted' by your mail
# server (i.e. not spammers)
#
# trusted_networks 212.17.35.
#
# Set file-locking method (flock is not safe over NFS, but is faster)
#
# lock_method flock
#
# Set the threshold at which a message is considered spam (default: 5.0)
#
# required_score 5.0
#
# Use Bayesian classifier (default: 1)
#
use_bayes 1
#
# Bayesian classifier auto-learning (default: 1)
#
bayes_auto_learn 1
#
# Set headers which may provide inappropriate cues to the Bayesian
# classifier
#
# bayes_ignore_header X-Bogosity
# bayes_ignore_header X-Spam-Flag
# bayes_ignore_header X-Spam-Status

```

รูปที่ 1 แสดงค่ามาตรฐานของโปรแกรมสเปมแอกแซสซิน

ประวัติผู้เขียนวิทยานิพนธ์

นายอรรถกร องค์ศิริพง เกิดเมื่อวันที่ 20 มีนาคม พ.ศ. 2525 ที่จังหวัดกรุงเทพมหานคร
 สำเร็จการศึกษาหลักสูตรวิทยาศาสตรบัณฑิต (วท.บ.) สาขาวิชาการคอมพิวเตอร์
 คณะวิทยาศาสตร์ มหาวิทยาลัยบูรพา เมื่อปีการศึกษา 2547 และเข้าศึกษาต่อหลักสูตรวิทยา
 ศาสตรบัณฑิต สาขาวิชาวิทยาศาสตร์คอมพิวเตอร์ ภาควิชาวิศวกรรมคอมพิวเตอร์
 คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย ปัจจุบันทำงานอยู่ที่ บริษัท ดีเอสที เวิลด์วายด์
 เชอร์วิส ประเทศไทย จำกัด



**ศูนย์วิทยทรัพยากร
จุฬาลงกรณ์มหาวิทยาลัย**